



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ
FACULTY OF BUSINESS AND MANAGEMENT

VYUŽITÍ NEURONOVÝCH SÍTÍ PŘI OCENĚNÍ DLUHOPISŮ
VYBRANÝCH SPOLEČNOSTÍ
USE OF NEURAL NETWORKS IN THE VALUATION OF BONDS OF
SELECTED COMPANIES

HABILITAČNÍ PRÁCE V OBORU EKONOMIKA A MANAGEMENT
HABILITATION THESIS IN THE FIELD ECONOMICS AND MANAGEMENT

BRNO 2023

Abstrakt

Oceňování cenných papírů a predikce jejich ceny je aktuálně jedním z intenzivně řešených témat nejen v rámci finanční praxe, ale také v oblasti ekonomického výzkumu. Osvědčené tradiční metody přestávají stačit vysokému tempu obchodování a velmi rychlému tempu nových finančních instrumentů. Výběr vhodné metody a modelu pro predikci finančních časových řad je komplexním problémem. Zatímco v případě analýz a predikce cen obchodovaných dluhopisů jsou intenzivně využívány především výnosové metody, při hledání reálné hodnoty u dalších finančních nástrojů využití těchto metod přestává být efektivní. Předmětem této habilitační práce je ocenění zdánlivě neocenitelných dluhopisů, tedy těch, které nejsou veřejně obchodovány, neboť právě pro tyto případy neexistuje ustálený způsob ocenění takových cenných papírů. Vzhledem k tomu, že jde o reálný problém, se kterým se současná praxe potýká, bylo cílem této práce nalezení a ověření takové metody, která vyřeší problém ocenění těchto zdánlivě „neocenitelných“ nástrojů na příkladu konkrétní společnosti. Pro predikce cen dluhopisů je použita sada metod založených na umělých neuronových sítích. Ty se prezentují velmi vysokým výkonem a dávají přesnější výsledky než jiné konvenční metody. Vzhledem k charakteru řešené problematiky jde o predikce spreadu a bezrizikové úrokové míry, kde výsledky predikcí jsou dále využity pro stanovení diskontní míry a ocenění dluhopisů společností spadajících do oblasti loterijního průmyslu. Ze skupin neuronových sítí jsou pro zpracování měsíčních záznamů dat použity umělé sítě ze skupiny vícevrstevných perceptronových sítí, sítí s GRL vrstvou a neuronových sítí s LSTM vrstvou. Vybráno je vždy pět nejúspěšnějších sítí s nejvyšším výkonem, přičemž ve většině případů dosahují v případě testovací množiny dat sítě výkonu přes 90 procent. Stejná sada metod je také aplikována pro komplexní hodnocení vybraných podniků, a to spolu s finanční analýzou, strategickou analýzou a analýzou trhu. Právě využití umělých neuronových sítí v rámci habilitační práce představuje inovativní řešení, jež přispívá k rozvoji oceňovací praxe a je dalším příspěvkem k bohaté výzkumné základně českého ekonomického výzkumu.

Klíčová slova: ocenění dluhopisů, finanční analýza, umělé neuronové sítě, strategická analýza, analýza trhu, komplexní hodnocení, loterijní průmysl

Abstract

The issue of bond valuation and in particular, the prediction of their price is currently a very topical issue not only for financial analysts. A common problem in analyzing and predicting the price of securities appears to be a selection of appropriate methods and suitable models for predicting financial time series. The application of conventional methods for analyzing and predicting seems to be no longer effective. However, the objective of the habilitation thesis submitted is valuation of non-marketable bonds, since there is no fixed valuation method of such securities. This thesis aims to present correct bond valuation on an example of a specific company. In this case, methods based on artificial neural networks are based for predicting bond price, specifically for predicting spread and risk-free interest rate, where the results of the prediction are further used for determining the discount rate and valuation of bonds of companies operating in lottery industry. For processing monthly reports of data, the used artificial neural networks include multilayer perceptron networks, networks with gradient reversal layer (GRL), and neural networks with LSTM layer. In each case, five most successful neural networks with the highest performance are selected. In most cases, the performance exceeds 90 % in the case of testing dataset. The same methods have been applied for comprehensive evaluation of selected companies, along with the financial and strategic analyses and market analysis. The habilitation thesis proves that in the process of bonds valuation, namely in determining risk free, spread and financial analysis, it is appropriate to use artificial neural networks as they dispose of a very high performance and provide more accurate results than other conventional methods.

Keywords: bond valuation, financial analysis, artificial neural networks, strategic analysis, market analysis, comprehensive evaluation, lottery industry

Čestné prohlášení

Prohlašuji, že předložená habilitační práce s názvem *Využití neuronových sítí při ocenění dluhopisů vybraných společností* je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušil autorská práva (ve smyslu Zákona č. 121/2000 Sb., o právu autorském a oprávek souvisejících s právem autorským).

V Českých Budějovicích 28. dubna 2023

Ing. Jaromír Vrbka, MBA, PhD.

Poděkování

Rád bych touto cestou poděkoval panu prof. Ing. Marku Vochozkovi, MBA, Ph.D., dr. h.c za poskytnutí cenných rad a námětů při zpracování habilitační práce a za jeho maximální dlouholetou podporu.

Obsah

Úvod	8
1 Literární rešerše.....	13
1.1 Dluhopisy	13
1.2 Finanční a strategická analýza – základní východiska pro ocenění dluhopisů.....	29
1.2.1 Finanční analýza.....	29
1.2.2 Komplexní hodnocení podniku	36
1.2.3 Strategická analýza	44
1.3 Analýza trhu.....	47
1.4 Moderní metody ocenění dluhopisů.....	55
1.5 Neuronové sítě.....	58
2 Cíle práce.....	68
3 Výzkumné otázky	69
4 Metodika.....	70
4.1 Finanční analýza	74
4.1.1 Metoda komplexního hodnocení podniku na bázi NN.....	79
4.2 Strategická analýza.....	92
4.3 Analýza trhu.....	93
4.4 Diskontní sazba.....	93
4.4.1 Spread	93
4.4.2 Bezriziková úroková míra	103
4.5 Ocenění dluhopisů	110
5 Výsledky.....	112
5.1 Metody komplexního hodnocení podniku na bázi NN.....	112
5.1.1 Metody využívající vícevrstvou perceptronovou NN	112
5.1.2 Metody využívající NN s GRL vrstvou.....	123
5.1.3 Metody využívající NN s LSTM vrstvou.....	138
5.2 Finanční analýza	153
5.2.1 CHNC, a.s.....	153
5.2.2 SAF, a.s.....	166
5.2.3 TP, a.s.....	177
5.2.4 BS, a.s.	190
5.3 Strategická analýza.....	203
5.3.1 Loterijní průmysl.....	203
5.3.2 Finanční služby	220
5.4 Analýza trhu.....	229
5.4.1 Loterijní průmysl.....	229
5.4.2 Finanční služby	231
5.5 Diskontní sazba.....	233
5.5.1 Spread	233
5.5.2 Bezriziková úroková míra	260
5.6 Ocenění dluhopisů	297

5.6.1	GOS_1	298
5.6.2	SAF_1	299
5.6.3	SAF_2	300
5.6.4	SAF_3	301
5.6.5	TPH_1	302
5.6.6	TPHnet_1	303
6	Diskuse výsledků	304
7	Přínosy habilitační práce	313
7.1	Přínosy pro rozvoj teorie a vědy	313
7.2	Přínosy pro rozvoj praxe.....	313
7.3	Využití výsledků práce ve vzdělávací činnosti	314
7.4	Koncepce směřování vědecké a pedagogické činnosti.....	314
	Závěr	316
	Seznam použité literatury	320
	Seznam tabulek	358
	Seznam obrázků	362
	Seznam zkratk	369
	Přílohy.....	373

Úvod

Oceňování cenných papírů je jednou z nejdůležitějších otázek finančního světa, jejíž význam ještě roste ve volatilních obdobích a v prostředí globální ekonomiky. Validací a predikcí vývoje jejich hodnoty se celosvětově zabývají specializované agentury, útvary finančních institucí, úřadů, centrálních bank i státu, nezpochybnitelný význam má i pro své interní uživatele. Jejich společným hlavním problémem přitom není samotná neexistence oceňovacích metod jako taková. Potíže působí zejména extrémně rychlý vývoj trhů i nástrojů s nimi spojenými, které jejich účastníci vytváří a používají. Globalizace ekonomiky navíc přinesla velmi rychlé a masivní přesuny kapitálu, umocněné jeho rychle rostoucím objemem v důsledku potřeby řešení krizí (finanční a hypoteční krize, potřeba řešení klimatických změn, pandemie nemoci COVID-19 a další). Metody, které ještě začátkem tisíciletí byly vyhovující, zastarávají a finanční svět proto vyžaduje jejich aktualizaci, případně vývoj nových systémů, schopných adaptace na stále probíhající změny, jež se projevují mimo jiné v neshodách výstupů ratingových agentur (Abad, Ferreras a Robles, 2020). Problémem je i velmi intenzivní dynamika vývoje nových finančních struktur a analytických nástrojů, kdy standardní metody velmi často přestávají stačit potřebám jak výzkumníků, tak především účastníků trhu (Albuquerque et al., 2016). I v důsledku sílící kritiky výstupů ratingových hodnocení je hledání vhodných alternativ jedním z nejdůležitějších úkolů současného ekonomického výzkumu (Löffler, 2020).

Hledání obecně použitého modelu vůbec není jednoduché. Jak na příkladu sjednoceného Německa ukazují Goldfayn-Frank a Eohlfart (2020), preference investičních strategií a využití různých finančních nástrojů velmi výrazně závisí na historické zkušenosti jak na osobní, tak institucionální úrovni. Přestože ke znovusjednocení Německa došlo v roce 1990, dodnes výzkumníci identifikují rozdíly ve výši spotřebitelského dluhu a velmi výrazný rozdíl je i v držení dluhopisů a jejich diskontních sazbách, jež, dle nich, vyjadřuje do určité míry i důvěru v jejich emitenty. Hledání optimálního modelu ocenění je, dle Joppa (2020) prakticky průvodním jevem emisí cenných papírů už od začátku dvacátého století. Dokladuje to na analýze aktivit a srovnání klíčových faktorů na Amsterodamské burze, kde posuzoval především vliv politického napětí a následně první světové války právě na trh s obligacemi. Obecně přitom výzkumníci konstatují, že ocenění dluhopisů je mimořádně významné z pohledu nejen emitenta, ale prakticky celého kapitálového trhu, přičemž modely ocenění specifických korporátních, např. konvertibilních, dluhopisů představují značný problém i pro vysoce

etablované finanční instituce (Ma, Xu a Yuan, 2020). Problémem při jejich ocenění je dynamika trhu, vyplývající mimo jiné z jeho propojení, lokální standardy výkaznictví, či neexistence ratingu u veřejně neobchodovaných cenných papírů. Jak prostřednictvím rozsáhlé regresní analýzy dokazují Mollah, Quoreshi a Zafirov (2016), existují přímé korelace mezi takzvanou finanční krizí, jež vypukla ve Spojených státech a tzv. krizí Eurozóny, která do značné míry reagovala na nervozitu a pokles důvěry v cenné papíry v hlavních finančních centrech. Je přitom příznačné, že v největší míře se tyto dopady odrazily v hodnotě cenných papírů, jejichž předchozí ocenění se stalo bezpředmětné a důsledky těchto velmi rychlých změn jsou, podle zmiňovaných autorů, devastující. Se stejnými závěry přichází i Schumacher (2018), který identifikuje klíčová finanční centra, ve kterých vznikají finanční šoky, či je dokáže zesilovat a tlumit. V rámci své analýzy dokazuje, že sledování původu kapitálu umožňuje predikovat dopad budoucích úvěrových selhání, včetně akciových či dluhopisových trhů.

Globální povahu kapitálu alokovaného v cenných papírech je nutné zohledňovat v rámci strategické analýzy společnosti (Benevolo, Penco a Torre, 2020). Integrovanou analýzu výnosnosti podniku a jeho budoucnosti, včetně jeho vnějšího a vnitřního prostředí, vytváří tito autoři prostřednictvím identifikace strategických nástrojů, které mají podnikatelské subjekty k dispozici. Výsledkem je model stanovující potenciální rovnováhu mezi vnějšími faktory (faktory globalizace a místními příležitostmi), zdroji a kompetencemi potřebnými k řízení rizik a obtíže globálního prostředí (vnitřní faktory). Nejde přitom jen o aktuální problematiku zohlednění vlivů globalizace. Dalším významným tématem v rámci strategického směřování společností hraje podle Fatima et al. (2020) i umělá inteligence, která v jejich podání vytváří zcela nové prostředí, do kterého se účastníci trhu, stejně jako celá společnost, musí integrovat. Nejde přitom podle nich pouze o využití prvků umělé inteligence, ale obecně o přijetí paradigmatu, v rámci kterého je nutné akceptovat jak nové směry podnikání a rozhodovacích procesů, tak také částečně heuristický přístup, který vyplývá z procesu dynamického zpracování informací a vytváření, respektive ukončování vazeb a z nich vyplývajících důsledků. Snaha o zahrnutí aktuálních trendů v rámci výzkumu problematiky strategické analýzy je zřejmá v práci řady badatelů. Qin, Liu a Tian (2020) se soustředí na problematiku on-line obchodních a prodejních faktorů, jež se staly v průběhu posledních let klíčovým trhem jak v segmentu B2C, tak také B2B. Trend podle nich směřuje, mimo jiné i zásluhou výše zmiňované umělé inteligence, ke stále silnějšímu prosazování hybridních platforem, v rámci kterých nefungují účastníci trhu pouze jako prodejci, zprostředkovatelé a nakupující, ale jejich role se začínají prolínat, kdy do procesu on-line obchodování stupují formy tržiště, zpětných odkupů, flexibilního cenového a výrobního vyrovnávání nabídky a poptávky, jež se například od prodeje

logistických služeb (např. jízdenek a letenek) přesunuje do většiny aspektů lidského i firemního života. Hranice mezi spoluprací a konkurencí se v současném podnikání stává nejasnou a soupeři se zapojují do aktivit spolupráce (Niu et al., 2020). V rámci rozsáhlé studie nicméně tento tým poukazuje na rizika těchto procesů. Dokazují mimo jiné, že očekávaný zisk nekonkurenčního dodavatele je na úrovni jeho výrobní technologie unimodální, což naznačuje, že nekonkurenční dodavatelé nemusí mít motivaci ke zlepšení své výrobní technologie, jakmile dosáhnou prahových hodnot. Vlivem digitalizace a digitální distribuce se na příkladu původně fyzického zboží, jež bylo kvůli zjevným výhodám převedeno do formy digitálního obsahu, zabývají i Tan a Carrillo (2017). Mimo jiné zkoumají modely ocenění ze strany producentů a následný přebytek spotřebitele s cílem zjistit a aplikovat v nové realitě postupy pro stanovení správných výnosových modelů. Stejným tématem se zabývají i Akçura a Ozdemir (2017), kteří zkoumají životaschopnost online služeb, systémy predikce jejich vývoje a praktické vedení cenových strategií s cílem aktualizovat analytické metody určené jak managementu příslušných firem, tak také externím stakeholderům.

Teorii her do výzkumu strategické analýzy přináší Jain (2019), který se zabývá otázkou maximálního spotřebitelského užitku. Řada produktů podle něj obsahuje funkce, jež spotřebitelé nevyužívají, přesto však mohou být konkurenční výhodou. Řeší proto otázku, jak přiměř užívatelé k využívání těchto funkcí a tím pokračování inovačního procesu na straně výrobců. Formou hyperbolického diskontování dokládá, že rozšiřování spektra funkcí a doplňků je nutnou součástí obchodních strategií, které umožňují firmám vytvářet trh a obstát v konkurenci.

Jedním z nejdůležitějších prvků strategické a finanční analýzy je řízení a správa rizik (Adler, Pittz a Meredith 2016), Právě tyto autoři z pohledu finančního řízení a výsledků přezkoumali 240 výzkumných a vývojových projektů amerického ministerstva obrany, zadaných privátním dodavatelům. Výsledkem jejich vícerozměrné analýzy je zjištění, že větší míru inovací a druhotného rozvoje přináší systémy sdílení rizik mezi dodavateli, případně mezi dodavatelem a investorem. Na význam hodnocení rizik v rámci finanční analýzy poukazují i Sharma a Mehra (2017), kteří na základě jeho posouzení tvoří model optimálního portfolia. To se v jejich podání zaměřuje na optimalizaci výběru cenných papírů akcií v každém sektoru na základě právě finanční analýzy. Tato aktiva následně spojují a vytváří z nich optimální portfolio s jejich váhami finanční analýzy a průměrnými výnosy. V tomto kontextu jsou čtyřmi finančními poměry zahrnutými v této studii návratnost aktiv (poměr zisku), poměr dluhu k aktivům (poměr solventnosti), aktuální poměr (poměr likvidity) a poměr ceny k výdělku (poměr ocenění). Riziko v portfoliu je kvantifikováno pomocí stochastické dominance druhého řádu a za tímto

účelem do procesu výběru přidávají autoři omezení, aby vytvořili optimální portfolia pro investory, kteří se racionálně averzi k riziku vyhýbají.

Finanční systém přitom v současné době prochází, dle Wilsona a Cambella (2016) doslova revolucí způsobenou elektronickým financováním, digitální konvergencí, novými účastníky trhu a vládou podporovanou konkurencí. Noví účastníci trhu, jako jsou Apple, Alibaba, Facebook a Google, vycházejí z průmyslových odvětví, jako jsou IT, maloobchod, sociální média a telekomunikace, a proto na ně nejdou podle výše jmenovaných autorů přímo aplikovat metody tradičních finančních institucionálních struktur. Navíc se, kromě technologií dle Yoo (2017) mění i spotřebitelé a účastníci trhu. Jednou z významných technologických změn užívaných v rámci finančních trhů a institucí je podle něj blockchain, který posunuje jak oblast zabezpečení transakcí, tak také generuje jiné typy dat, se kterými běžné finanční instituce příliš neumí pracovat, ať už ve formě zpracování či validace. O rozsahu problémů s finanční analýzou svědčí o objem publikací. Silva, Kimura a Sobreiro (2017) v rámci své metaanalýzy zkoumají 265 relevantních výstupů z databází Scopus a Web of Science, zaměřených na analýzu finančních rizik, systémová rizika a finančních indikátorů, přičemž konstatují nejen rostoucí zájem o tuto oblast, ale také řadu nedostatků, na které by badatelé měli zaměřit svou pozornost. Další metaanalýzu zaměřenou na finanční výkaznictví firem, jako základní kámen následné finanční analýzy představují Bilal, Chen a Komal (2018), kteří se zabývají výsledky 90 studií se 165 529 pozorováními. Kromě pozitivního hodnocení vlivu zavedení jednotných Systémů správy a řízení společností, Mezinárodních standardů účetního výkaznictví (IFRS) a SOX (Sarbanes-Oxley Act) konstatují z pohledu potřebného zvyšování relevance a kvality výstupů i kvalifikace auditorů a členů regulatorních orgánů.

Na otázku hodnocení efektu sdílení rizik v rámci finanční analýzy se soustředí Wang a Huang (2020). Řeší problém, nakolik je princip sdílení výhodný z pohledu jak celého finančního sektoru, tak také pro jednotlivé účastníky trhu, respektive, zda se efekt sdílení projevuje negativně či pozitivně v portfoliu investorů. Z výsledků jejich studie zpracované na základě systematického Paretova kritéria vyplývá, že zatímco z pohledu sektoru je sdílení rizik přínosem, pro jednotlivé účastníky trhu není dlouhodobě výhodné.

I přes všechny tyto změny, jež se snaží postihnout dynamiku trhu a vývoje společností však platí, že badatelé jednoznačně vymezují potřebu jak strategické, tak i finanční analýzy, která je bezpodmínečně nutná pro pochopení metod ocenění příslušných cenných papírů. Jak konstatuje Vochozka (2020) finanční analýza je formalizovanou metodou, která umožňuje získat představu o finančním zdraví podniku, přináší informace o jeho výkonnosti a potenciálních rizicích a zabývá se i jeho dalším vývojem. Bez ní tak není možné stanovit dostatečně kvalitní

rámec nutný pro vývoj bankrotního modelu společnosti, či metody ocenění cenných papírů, jež emituje.

Tato práce se zabývá oceněním dluhopisů vybraných podniků působících ve velice turbulentním odvětví, jejichž akcie nejsou veřejně obchodovány.

1 Literární rešerše

1.1 Dluhopisy

Dluhopisy, bondy, obligace ... Pojmy, kterými v posledních letech rezonují odborná i mainstreamová média. Důvody jsou podle Debella (2020) jasné. Krizové situace jako severoamerická hypoteční krize, krize eurozóny a v posledním období pandemie COVID-19 vyvolávají obavu ze stability tohoto pilíře finančního trhu, přičemž volatilita se přímo promítá nejen do podnikatelské sféry, ale přímo do života všech obyvatel. Reakce států se podle jeho zjištění zaměřují na fiskální i monetární politiku, přičemž důležité pro udržení stability byly dle Debella (2020) především kroky směřující k udržení nízkých nákladů na financování a zajištění jak nízkých referenčních úrokových sazeb, tak i likvidity korporátních cenných papírů.

Potvrzuje tak výsledky rozsáhlého výzkumu Wang, Zhanga a Zhanga (2020), kteří se orientují na zajišťování likvidity v rámci finanční krize 2008-2009, kdy klíčové podílové fondy, snížily objem nákupu především podnikových dluhopisů. Důsledkem pak byly negativní dopady jak v rámci celé globální ekonomiky, tak také výrazně nižší míra ziskovosti právě investorů, kteří v rámci snižování potenciálního rizika přišli o významnou část výnosů.

Na stejné období se přitom soustředili i Albonico a Tirelli (2020), kteří se orientují na prostředí eurozóny s vydělením takzvaného tvrdého jádra a periferních oblastí, které byly masivně zasaženy takzvanou dluhopisovou krizí v roce 2010. Změnu v čistých kapitálových tocích zohledňují v rámci řešení této krize formou kvantitativního uvolňování na ocenění cenných papírů Perillo a Battiston (2020), podle kterých snaha o stabilizaci veřejných rozpočtů má rozdílné účinky v zemích eurozóny, a to jak ve výši rizikové přírážky, tak také v objemu nákupů jak firemních, tak i státních bondů. Vůbec nejvíc z oznámení Evropské centrální banky (ECB) o programu přímých měnových transakcí (OMT) v roce 2012 týkající se odkupu bondů profitovalo dle Ehrmannova a Fratzsecherova modelu (2017) heteroelasticity denních změn úrokových sazeb sledovaných před a po oznámení Španělska a Itálie, naopak jen minimální vliv zaznamenali u německých a skandinávských obligací. Tento výsledek potvrzují i Eser a Schwaab (2016), kteří analyzují vliv rozhodnutí Evropské centrální banky na volatilitu cen dluhopisů, jež se v souvislosti se zvýšením likvidity pronikavě snížila a stabilizovala. Nelineární vztah mezi veřejným dluhem a poměrem HDP potom odhalují v rámci determinantů výnosů dlouhodobých vládních dluhopisů pro 19 ekonomik Evropské měnové unie (EMU) v období 1995–2018 v rámci vícerozměrného panelu Pappas a Kostakis (2020), kteří poukazují

na význam jiných než státních účastníků trhu s obligacemi v rámci kapitálového zajištění. Na dopad krize eurozóny na trh s dluhopisy se zaměřují i Vukovic, Hanic a Hanic (2017), kteří využívají upravený teoretický model portfolia CAL s cílem ukázat volatilitu zkoumaných determinantů (výnosy a směrodatné odchylky na střednědobých a dlouhodobých trzích dluhopisů triple-A). Podle jejich výsledků se výnosy a standardní odchylky v období krize mnohonásobně zvýšily a dopady volatility na kapitálovém trhu přetrvaly až do roku 2016, kdy se míra konvergence trhů s dluhopisy v eurozóně do značné míry stabilizovala.

Stejně regionální rozdělení na jádro a periferii užívá v souvislosti s oceněním kapitálu i Perego (2020), který se zaměřil na chování společných pohybů na trzích aktiv v eurozóně v období 2010–2014 za použití modelu DSGE. Z jeho analýzy vyplývá, že 50 % růstu rozpětí dluhopisů v takzvaně rizikových zemích souvisí s vyšší mírou rizika, které je státům přisuzováno. Zároveň však všichni tito autoři pracují s různými pojmy, kdy ne vždy jsou regiony myšleny národní státy, ale v řadě případů také oblasti definované jako rozvíjející se a vyspělé ekonomiky (Nispi Landi, 2020), či seskupení států BRICS (Çepni et al., 2020), jež definují některé společné charakteristiky. Druzí jmenovaní využívají pro analýzu prediktivní síly nejistot ohledně kapitálových toků ve formě dluhopisů proměnný Grangerův kauzální rámec, na jehož základě přesvědčivě definují heterogenní strukturu kauzality mezi nejistotou a tokem kapitálu do daného typu ekonomického prostředí. Její zohlednění potom dle autorů může pomoci investorům s identifikací vhodných příležitostí k diverzifikaci portfolia a zpětně také ke zlepšení hodnocení finančních nástrojů emitentů v zemích BRICS. Ve skutečnosti, jak dokazuje Schmidt (2020), je ocenění nejen státních, ale i podnikových dluhopisů velmi významně spojeno s celkových podnikatelským prostředím konkrétního státu, s mírou inflace příslušné měny a obecně riziky vlastními konkrétnímu státu. Impulzní reakce jeho modelu poukazují na jednoznačnou korelaci mezi cenami aktiv a změnami měnové politiky, což podle něj znamená, že trhy aktiv rozlišují mezi různými typy rizik spojenými s vnějším prostředím emitenta.

Jednou z oblastí výzkumu (Pagliacci, 2020) je vzájemná korelace korporátních dluhopisů a makroekonomických údajů konkrétní země. Autorka v případě Latinské Ameriky testuje dopady financování a odpisů podnikových dluhopisů na inflaci nabídky. Její výsledky následně ukazují, že oslabení domácí měny výrazně zvyšuje inflaci nabídky a agregované přírážky, ale zpětné financování podnikových dluhopisů nemá na inflaci nabídky signifikantní vliv. Vzájemné vazby mezi zeměmi týkající se především objemu investic do dluhopisů s vazbou na zpříšňování či uvolňování pravidel pro jejich emise analyzuje Nispi Landi (2020). Podle něj dochází v případě zpříšnění kontroly kapitálu v jedné zemi ke zvýšení objemu zahraničních investic v dalších zemích, což má i přímý vliv na makroekonomické výsledky. Na vliv držitele

dluhu ve formě dluhopisů se zaměřuje Sunder-Plassman (2020), která aplikuje smíšenou dluhovou strukturu do teorie státního dluhu, defaultu a inflace. Podle jejích výsledků je dluh ve formě dluhopisů inflační, pokud je držen v zahraničí, ale snižuje inflaci, pokud je držen domácími věřiteli.

Samostatnou oblastí, jež patří mezi velmi často analyzované zejména v posledních letech, je vliv celospolečenských tendencí směřujících k řešení problematiky ochrany klimatu. Aven a Zio (2020) konstatují, že vlivem technologických inovací došlo k rozvoji průmyslu a s ním souvisejících informací v globálním měřítku, což vedlo ke vzniku globální společnosti spočívající na vzájemně závislé síti nadnárodních technických, ekonomických a sociálních systémů. Tyto systémy jsou podle nich vystaveny kaskádovým scénářům, jejichž dopady se mohou díky svým silným vzájemným závislostem šířit v masovém měřítku s přímými dopady na země, jejich instituce a firemní sféru. V této souvislosti zmiňují především pandemii nemoci COVID-19, dalším významným trendem je potom především trvalá udržitelnost, přičemž de Tollivera et al. (2020) jsou právě zelené inovace a zelené finance dvě klíčové složky udržitelného rozvoje, určující tempo společenských a ekonomických změn v rámci globální společnosti.

I proto se na formu takzvaných zelených dluhopisů aktuálně zaměřuje řada badatelů. Jak konstatuje Liaw (2020), zelené dluhopisy vycházející mimo jiné z iniciativy Climate Bonds Initiative jsou podobné běžným dluhopisům, ale jsou speciálně vyčleněny na získání peněz na financování projektů v oblasti klimatu nebo životního prostředí. Podle tohoto autora většina stávajících analýz poukazuje na to, že výnosy zelených dluhopisů jsou nižší než výnosy ekvivalentního konvenčního. Konfliktní výsledky, které podle něj evokují další výzkumné otázky, lze podle něj ale vysvětlit rozdíly ve výběru vzorků, časových obdobích, metodikách a vlastnostech příslušné emitující entity a dluhopisu.

Trh se zelenými dluhopisy podle Tanga a Zhanga (2020) celosvětově rychle roste od svého debutu v roce 2007. Oba autoři proto představili relativně rozsáhlou empirickou studii o výnosech zelených dluhopisů ve 28 zemích během let 2007–2017 a návaznosti jejich emisí na další hodnocení analyzovaných společností. Po sestavení komplexního datového souboru zelených dluhopisů uvádí prokazatelně pozitivní vliv emise zelených dluhopisů na ceny akcií příslušných společností. Přestože v rámci výzkumu potvrzují neexistující či minimální prémii u těchto specifických bondů, uvádí, že do pozitivních výsledků je nutné započítat pozitivní vliv na hodnotu akcií. Další korelaci v oblasti ocenění zelených dluhopisů přináší Dafermos, Nikolaidi a Galanis (2018), podle kterých by mělo světové společenství zohlednit pozitivní

význam těchto cenných papírů ve vztahu k otázce globálního oteplování a klimatických změn ve smyslu dodatečné prémie pro tyto typy derivátů.

Poměrně zásadní je v oblasti zelených dluhopisů dle Tana et al. (2020) vliv emisních povolenek, jejichž cílem je pomoci omezit rozsah a dopad globálního oteplování a změny klimatu. Mechanismus zpětné vazby v systému „Carbon-Energy-Finance“ činí dynamiku propojenosti informací složitější, protože do systému vnáší majetková a dluhopisová aktiva s přímým dopadem na ceny v energetickém a zpracovatelském sektoru. Pomocí modifikovaného rozkladu odchylek chyb a síťových diagramů kvantifikují a y analyzují, jak se evropský trh s uhlíkem spojuje s informacemi z celé řady dalších trhů. Výsledky výzkumníků potom poukazují na to, že trhy s emisními povolenkami a na ně navázané trhy s fosilními palivy a energiemi jsou úzce spojeny spíše s akciovými trhy než s trhy s obligacemi.

Tyto výsledky částečně potvrzují relativně rozsáhlý výzkum provedený Zerbibem (2019), který takzvané zelené dluhopisy použil jako nástroj k identifikaci vlivu nepeněžních motivů, zejména pro environmentální preference, na ceny na trhu dluhopisů. Na základě metody párování, následované dvoustupňovou regresní procedurou, analyzoval výnosový rozdíl mezi zeleným dluhopisem a srovnávacím konvenčním dluhopisem od července 2013 do prosince 2017, přičemž konstatuje paradoxně negativní premii. Výnos zeleného dluhopisu je v průměru o 2 bazické body nižší než u běžné vazby, což dle něj odpovídá jen nízkému vlivu proenvironmentálních preferencí investorů. Částečně tyto výsledky potvrzují i výzkum Cojoianu et al. (2020), kteří se zaměřují na vliv pandemie COVID-19 na trh dluhopisů, zároveň ale posuzují i dopad změn na dluhopisy orientované na trvalou udržitelnost. Na základě analýzy čerpající z nového souboru údajů o podnikových dluhopisech vydaných v evropském energetickém sektoru od ledna 2020 v kombinaci s nákupy Evropské centrální banky (ECB) v rámci Pandemic Emergency Purchase Program (PEPP), konstatují, že i přes vliv deklarovaných preferencí významných bankovních uskupení v rámci Evropské unie, evidují mírné snížení preferencí investorů v neprospěch klimaticky orientovaných firemních emitentů. V rámci posuzování takzvaného „zeleného“ přístupu k dluhovému financování je nutné připomenout, že se jím nezabývá pouze analýza hodnocení bondů, ale stále častěji je součástí i strategické analýzy sektorů či firem (Ljungkvist a Andersén, 2020).

Techniku kvantilní regrese pro kvantifikaci míry investičního rizika do různých typů aktiv užívají pro specifické africké prostředí Tweneboah, Owsu jr. a Kumah (2020), podle kterých tato metoda umožňuje pracovat s časovou heterogenitou tržních změn.

Na odolnost tržní likvidity se v rámci ocenění aktiv zaměřují Broto a Lamas (2020), kteří se soustředí na souvislost mezi volatilitou výnosů a volatilitou likvidity. Pro analýzu desetiletých

výnosů dluhopisů a pět indikátorů likvidity od ledna 2003 do června 2016 nasadili model bivariační podmíněné korelace (CC-) GARCH, kterým posuzovali perzistenci a přechody mezi těmito proměnnými. I jejich výsledky potvrzují fakt, že míra volatility trhů přímo souvisí s hospodářským cyklem konkrétního prostředí.

Naopak na aspekt vlastnictví firmy, jež emituje dluhopisy, se zaměřují Abinzano, Corredor a Martinez (2020), kteří prostřednictvím modelu Black-Scholes-Merton (BSM) prokazují zájem investorů o méně riziková aktiva, jež spojují například s rodinným vlastnictvím společnosti, jíž poskytují kapitál. Tato jejich tendence podle autorů posiluje v případech, kdy dochází k vyšší volatilitě na trhu. Vlastnictví emitenta je důležitým faktorem i podle Lee, Wang a Ho (2020), kteří posuzovali dopad forem vlastnictví – především tzv. rodinných firem na hodnocení jimi vydávaných obligací. Specificky pro prostředí Tchaj-wanu zjišťují staticky významně vyšší spread u společností, jejichž nejvyšší management je spojen s vlastnictvím či spoluvlastnictvím firmy.

Relativně běžně jsou metody ocenění dluhopisů korelovány s metodami pro hodnocení akcií, v posledních letech ale zároveň Cheah et al. (2020) přidávají do srovnání i metody ocenění bitcoinů. Při užití srovnatelných metod potom konstatují, že klíčovými proměnnými jsou v jejich případě, podobně jako u specifických typů rizikových dluhopisů velmi významné prediktory jako hybnost časových řad, nejistota hospodářské politiky a finanční nejistota.

Významnou proměnnou, která hraje roli v rámci oceňování firemních dluhopisů, je dle Cuny et al. (2020) výše transakčních nákladů. Na základě srovnávací analýzy konstatují, že otevřené zveřejnění transakčních cen do určité míry snižuje výši přírážky příslušného cenného papíru. Problémem ale podle nich může být informační asymetrie, kdy kvalifikovaní investoři disponují větším objemem informací týkajících se transakčních nákladů, a tím dosahují, oproti běžným účastníkům trhu, zjevné výhody na trzích s obligacemi. V rámci výzkumu ocenění dluhopisů badatelé v řadě případů rozlišují množinu státních dluhopisů a na ně navázaných derivátů a firemních dluhopisů. I při jejich posuzování hraje dle Rünger (2020) a dalších roli země původu emitenta, nicméně z pohledu státních dluhopisů hraje region jednu z klíčových rolí (Alfonso a Kazemi, 2020). Tito autoři mimo jiné užívají ke sledování efektu přelévání kapitálu mezi zeměmi Evropské unie implementaci GMM metody (Generalized Methods of Moments) v rámci VAR analýzy, přičemž konstatují, že vlivem rozdílného spreadu lze konstatovat pozitivní efekt těchto přesunů.

Zdaleka ne vždy, podle badatelů platí, že korporátní dluhopisy bývají rizikovější než dluhopisy státní. Meuli, Nellen a Nitschka (2020) jmenují například švýcarské cenné papíry vázané na hypotéky, jež sledují v nepřetržité řadě od roku 1932 do roku 2014, kdy statisticky prokazují

jejich stabilizační vliv v rámci kombinovaných portfolií, a to i ve srovnání se státy emitovanými bondy.

Opakem institucionalizovaného obchodování s obligacemi na úrovni států a centrálních bank je potom investiční chování jednotlivce, který čerpá užitek z poměru mezi jeho spotřebou a endogenním zvykem. Zásady, kterými se přitom řídí, zkoumají Van Bilsen, Bovenberg a Laeven (2020) na základě obecných funkcionalit a náhodných investičních příležitostí vytvořením netriviální linearizace na rozpočtové omezení, kterými charakterizují, nakolik tvorba návyků ovlivňuje mezní sklon ke spotřebě a optimální investice do dluhopisů.

Model čistých kapitálových toků, jenž pracuje s nominálními dluhopisovými aktivy a pasivy představují Devereux, Saito a Yu (2020), kteří dokazují, že dynamika dat je generována pohyby v derivátových (tj. dluhopisových) rizikových premiích, kdy při aplikaci je výnos z hrubých závazků nižší než výnos z hrubých aktiv.

Jednou z oblastí, na kterou se v rámci posuzování modelu ocenění dluhopisů, dlouhodobě badatelé soustředí je vliv daňového zatížení. Rünger (2020) jednoznačně konstatuje, že čím vyšší je daňové zatížení cenných papírů, tím nižší je podíl kapitálových investic v daňově optimálním portfoliu. Zároveň však na vzorku 9053 evropských společností a jimi emitovaných cenných papírech dokazuje, že vztah mezi zdaněním osob a individuálním vlastnictvím cenných papírů je významně zmírněn rizikovým ohodnocením konkrétního podniku.

V rámci situační analýzy připomíná Adarov (2020) nutnost zohlednění inherentní nestability na finančních trzích, jehož analýza odhaluje perzistentní a opakující se povahu finančních cyklů, které mají tendenci kolísat na frekvencích nižších, než jsou obchodní cykly. Dopady omezeného přístupu na kapitálové trhy se potom zabývá Kumar (2020). Likviditní šoky nebo naléhavou poptávkou po likviditě přímo spojuje s poklesem cen dluhopisů. Obchodníci ale následně podle něj vyžadují likviditní premii k vyrovnání potenciálních ztrát, které se přímo mění s úrokovou sazbou.

Modelem změny kapitálových výnosů v portfoliu dluhů sestávajících z dluhopisů rozvíjejících se zemí jako lineární regresi změny kapitálových zisků v portfoliu skládajícím se z dluhopisů US Treasury se zabývá Gubareva a Keddad (2020), kteří konstatují přímou korelaci mezi mírou zisků a aktuálním hospodářským cyklem, v rámci kterého dochází k přímému přelévání kapitálu.

Zjištění, že emise odpisových dluhopisů má pozitivní vliv na alokaci aktiv emitující banky v případě čínského kapitálového trhu potom přináší Li et al. (2020), přičemž uvádí, že u bank, které vydaly odpisy dluhopisů, má vydávající částka odpisových dluhopisů významný dopad na alokaci aktiv.

Už zmiňovaný masivní zájem badatelů o aktuální problematiku „zeleného financování“ se neprojevuje jen v zemích Evropské unie, ale globálně. Mnoho zemí a mezinárodních organizací navrhlo rámce pro rozvoj zeleného financování a stále větší počet společností vydává zelené dluhopisy jako finanční nástroje pro financování zelených projektů. Na rozdíl od konvenčních dluhopisů mají zelené dluhopisy jedinečné vlastnosti a jejich emise se řídí zvláštním procesem (Li et al., 2020). Na modelu v rámci Číny tito badatelé využívají lineární regrese k empirickému prozkoumání dopadu úvěrových hodnocení, sociální odpovědnosti podniků (CSR) a zelené certifikace na výnosový spread zelených dluhopisů, přičemž jejich výsledky prokazují, že všechny tyto faktory mají významný dopad na snížení úrokových nákladů.

Existenci prémie za zelené dluhopisy zkoumají i Immel et al. (2020), kteří ve výsledku rozsáhlé analýzy konstatují statisticky významný vliv hodnocení ESG (hodnocení metod udržitelnosti) na spready dluhopisů. Jednobodové zvýšení váženého průměrného skóre ESG vede ke snížení rozpětí o 6 až 13 bazických bodů. Zajímavé ale je, že tyto výsledky podle nich nejsou odvozeny od ekologické přijatelnosti emitenta zelených dluhopisů, ale spíše správou společnosti.

Vztahem mezi likviditou, úvěrovými ratingy a rozpětím výnosů zelených podnikových dluhopisů v Číně se pomocí panelové analýzy dat a zobecněné metody momentů (GMM) zabývají Chang et al. (2020), kteří konstatují, že likvidita a rating hrají klíčovou roli v ovlivňování výnosových rozpětí zelených podnikových dluhopisů s různými emisními podmínkami.

Rozsáhlou síťovou analýzu trhu se zelenými dluhopisy představují Halkos, Managi a Tsilika (2020), kteří zkoumají projekty a aktiva v 96 zemích od roku 2006 do roku 2017. Zaměřují se na vztah vstupů a výstupů mezi zeměmi a regiony. K identifikaci nejvýznamnějších členů, považovaných za „páteř“ trhu, využívají metodiku založenou na různých opatřeních ústřednosti sítě. Vliv zemí měří z hlediska objemu a četnosti vývozu a dovozu zelených dluhopisů podle konceptů (kritérií) „příliš propojených na selhání“ a „příliš velkých na selhání“. Výsledkem jejich analýzy je konstatování, že hlavní roli v oblasti emisí a ocenění zelených dluhopisů hrají roli trhy v Německu, Švédsku, Lucembursku, Nizozemí, Francii, USA a Spojeném království. Dopad růstu, respektive poklesu přílivu kapitálu do státních dluhopisů a ve formě změn dlouhodobé úrokové sazby v rozvíjejících se ekonomikách analyzuje Inoguchi (2020), který pomocí regresního přístupu dokládá přímou vazbu mezi těmito jevy, a to jak v období před globální finanční krizí, tak i po ní. Změny rozpětí swapů úvěrového selhání státních dluhopisů pomocí modelu kvantilní regrese zkoumá Naifir (2020), který udává, že nejvýznamnějšími proměnnými jsou pro jím posuzovanou kategorii obligací globální finanční nejistota vložená do indexu volatility Chicago Board Options Exchange (CBOE) (VIX) a nejistota globálního

trhu konvenčních dluhopisů vložená do indexu volatility odhadů Merrill Lynch Option (MOVE).

Na arbitrážní příležitosti mezi dluhopisy vázanými na vývoj inflace a nominálními francouzskými státními dluhopisy poukazují De Séverac a Da Fonseca (2020), kteří v návaznosti na teorii arbitráže uplatňují koncept zajišťování rizik, podle níž nelikvidita dluhopisů vázaných na inflaci vysvětluje zjištěné arbitrážní zisky. Zprávy o inflaci jsou podle Cendeseho a Mallucciho (2016) hlavní hnací silou návratnosti mezinárodních dluhopisů. Dokonce do té míry, že ohodnocení dluhopisů především na rozvíjejících se trzích je podle nich se změnou úrokových sazeb spojeno více než ocenění akcií.

Podobně rozsáhlý vzorek 306 podnikových zelených dluhopisů vydaných 85 společnostmi, které odkazují na 1 788 zelených projektů v letech 2013 až 2016 analyzují Russo, Mariani a Cargnano (2020), kteří se zaměřují na tři ukazatele: specifické charakteristiky projektů financovaných prostřednictvím zeleného dluhopisu, širší strategii firmy zaměřenou na udržitelnost podniku a determinanty výkonnosti zelených dluhopisů specifické pro danou zemi, kdy všechny tyto ukazatele podle nich hrají významnou roli v ocenění tohoto typu bondů. Vztah mezi fiskální politikou a rizikovou prémie dluhopisů zkoumají prostřednictvím autoregresních vektorových modelů Bretscher, Hsu a Tamoni (2020), podle kterých je tato korelace závislá především na pozitivním efektu inflační rizikové prémie (účinku na úrovni časové struktury). Jiný přístup potom volí k analýze zelených dluhopisů Monk a Perkins (2020), kteří užívají kvalitativních výzkumných metod k identifikaci procesů, vlivů a dynamiky v technologicky inspirovaných finančních inovacích spojených s řešením problematiky klimatických změn.

Vliv společenských změn a globálních trendů se však nemusí týkat jen ohodnocení zelených dluhopisů. Gulati a Panizza (2020) pomocí kvantitativních údajů a rozhovorů investory dokazují na příkladu dopadů článku „Hunger Bond“ (Hausmann, 2017), jenž se zabývá problematikou upřednostňování úhrady venezuelských dluhopisů na úkor řešení humanitárních problémů, že i pokus o zachování platební morálky ze strany emitenta může být vnímán negativně, přičemž hlavními determinanty pro investory byla podle autorů výzkumu kombinace negativní pozornosti tisku a nesouhlasného stanoviska globální veřejnosti. Podobnou oblast výzkumu volí i Altura (2020), který se zabývá vlivem neekonomických faktorů na investiční rozhodování v rámci prodeje komunálních dluhopisů v rámci 1032 samosprávných celků ve Spojených státech. Jím publikované výsledky kvantitativně-kvalitativní studie ukazují, že rozhodnutí o výběru investičního zprostředkovatele a návazně na úspěšnosti daného cenného papíru do značné míry záleží na sociálním kontextu, jenž mimo jiné zohledňuje i rasovou heterogenitu.

Kromě zelených dluhopisů je dalším specifickým typem obligace tzv. katastrofický dluhopis, orientovaný na přenos specifikovaného souboru rizik z emitenta na investora (Faias a Guedes, 2020), který dle citovaných autorů vyžaduje specifické formy ocenění s přihlédnutím k systému jeho fungování. Nový ekonometrický model využívající pro tento účel řadu regresí OLS s heteroskedasticitou a autokorelací konzistentními standardními chybami představuje Braun (2016), jehož výsledky potvrzují výši očekávané ztráty jako nejdůležitější faktor ocenění. Kromě toho má podle něj významný dopad i zajišťovací cyklus a spread u srovnatelně hodnocených podnikových dluhopisů. K těmto determinantám ještě Götze a Gürtler (2020) přidávají rozpětí swapů úvěrového selhání a flexibilitu emitenta. Statistický popis dynamiky řad celkových výnosů indexů tzv. CAT (katastrofických) dluhopisů přináší v rámci jiného ekonometrického modelu Trottier, Lai a Godin (2016), kteří potvrzují roli těchto dluhopisů jako významného prvku diverzifikace dluhopisových fondů s relativně vysokým výnosem. Likviditní prémie vložené do spreadu těchto dluhopisů. Jejich výsledkem je potom konstatování, že 90,5 % výnosu je dáno rizikovostí tohoto typu obligace. Naopak na dopad výskytu jevu zajišťovaného CAT dluhopisem se zaměřují Carayannopoulos, Kanj a Perez (2020), kteří uvádí, že zatímco tyto typy dluhopisů standardně vykazují celkový klesající trend v hodnotě očekávaného rizika ztráty, velké katastrofy zvyšují jejich ocenění v průměru o 34 %, přičemž tento prudký zvrát vysvětlují změnami averze k investici, která má za následek katastrofické události způsobující ztráty tohoto typu dluhopisů.

Z pohledu obchodování na finančních trzích je podle Nobreho a Nevese (2019) klíčový obchodní signál, který investorovi může poskytnout nejlepší vstupní a výstupní body. Svůj systém predikce optimálních obchodních bodů postavili na kombinaci diskretní vlnkové transformace (DWT), extrémní gradientové podpoře (XGBoost) a genetickém algoritmu optimalizace více cílů (MOO-GA), přičemž cílem jejich modelu je dosažení maximálního možného výnosu z obchodování s cennými papíry při dosažení nejnížší možné úrovně rizika. Jedním z těchto signálů by mohly být například komoditní cenové šoky (Demirer, Ferrer a Shahzad, 2020). Z jejich výzkumu nicméně vyplývá, že dopady těchto prudkých cenových výkyvů jsou v případě dluhopisů spíše heterogenní.

Velmi specifické ocenění korporátního dluhopisu v této souvislosti představuje Dempster (2020), který využívá komplexní stochastické a Monte Carlo simulační analýzy pro posouzení hodnoty dluhopisu společnosti, která obchoduje se specifickými kovy. Dokladuje, že při dostatečné míře znalostí o materiálových akvizicích firmy, jež samostatně analyzuje s desetiletým časovým rozsahem, a i po započítání všech transakčních nákladů, je možné

stanovit nulovou pravděpodobnost selhání emise dluhopisů, jež jsou přitom úročeny 12 % úrokovou sazbou.

Jiný typ experimentu využívají Penalver et al. (2020), kdy zkoumají nákupy firemních dluhopisů během kvantitativního uvolňování (QE). Dluhopisy jsou v jejich modelu náhražkou hotovosti a mají konstantní základní hodnotu, která není ovlivněna racionálním očekáváním. Autoři v tomto případě zjišťují, že QE signifikantně zvyšuje ceny dluhopisů nad ceny v benchmarku bez QE, jež je jedním z významných faktorů cenotvorby.

Kalibrovaného heterogenního modelu založeného na New Keynesian DSGE metodice využívají pro hodnocení alokace kapitálu vkládaného do dluhopisů nefinančních společností Kurtzman a Zeke (2020), kteří takto srovnávají výkonnost cenných papírů firemních emitentů a států. Přechodovou nezávislostí stochastického diskontního faktoru (SDF) na trhu dluhopisů se zabývají Qin, Linetsky a Nie (2018), kteří zde odhalují přímou souvislost s martingalovou transformací. Vychází přitom ze svých předešlých prací Qin a Linetsky (2017), kdy cenový přístup martingale považují za základní kámen kvantitativního financování, který umožňuje posouzení jak obligací, tak také jejich derivátů. Stejný přístup martingale už před nimi nicméně využili pro účely simulační studie cenových modelů zachycujících implikované „kolísání volatility“ finančních produktů Zhu a Ling (2015).

Na faktor definovaný jako výnosový rozdíl mezi nejnegativnějším a nejpozitivnějším portfoliem dluhopisů se v rámci své studie zaměřují Li, Wald a Wang (2020), který podle nich bezprostředně souvisí s celkovým poklesem výnosů spojených s poklesem úrokových sazeb. Chování investorů na thajské dluhopisové burze analyzují Jirasakuldech a Emekter (2020), kteří se zaměřují na spojitost mezi případným stádním chováním a stádií hospodářského cyklu v Asii. Podle očekávání odhalují prostřednictvím strukturální analýzy bodu zlomu a techniky postupné regrese, neracionální chování účastníků trhu během asijské finanční krize v roce 1997, na druhou stranu ale prokazují, že snazší přístup běžných obchodníků na trhy toto chování přímo neovlivňuje.

Relativně masivní výzkumné podněty v oblastech trhu s dluhopisy přinesla tzv. krize eurozóny v letech 2007–2010, kdy badatelé relativně běžně pracují s pojmy jako je „jádro“ a „periferie“ měnové unie (např. Albonico a Tirelli, 2020 či Perego, 2020). Finančnímu propojení mezi ekonomikami Řecka, Irska, Itálie, Portugalska, Španělska a Německa se věnují prostřednictvím rozsáhlého síťového grafu i Magkonis a Tsopanakis (2020), kteří sledují dopady ekonomických problémů na rizikovou přírážku dluhopisů ve všech sledovaných zemích. Prokazují jednoznačné přelévání „finančního stresu“ ze Španělska a Itálie do dalších zemí, vliv

problémů dalších periferních států – Řecka, Irska a Portugalska na dluhové financování v dalších částech EMU ale podle nich signifikantní není.

Stejní autoři (Magkonis a Tsopanakis, 2020) se potom zaměřují i na další jev spojený s krizí eurozóny. Kvantitativní analýzou sledují chování a zajišťování italských bank ve zmiňovaném období, především s důrazem na strukturu kapitálu v jejich aktivech. Podle očekávání odhalují v krizových letech zvyšování objemu státních bondů na úkor korporátních dluhopisů a rovněž dalších typů cenných papírů s rizikovější přírůzkou i navzdory předpokládaným nižším výnosům z takto strukturovaných portfolií.

Jedním z výstupů krize eurozóny je návrh několika reformních řešení, zahrnujících novou strukturu dluhopisového financování, včetně tvorby syntetických evropských bezpečných dluhopisů – ESBies, navrhovaných Brunnermeierem et al. (2017). Jejich návrh následně prošel přezkumem formou komplexní kvantitativní studie o rizicích spojených s těmito bezpečnými dluhopisy a souvisejícími produkty pomocí modelu afinního úvěrového rizika (Frey, Rüdiger a Kurt, 2020), kdy jedním z identifikovaných problémů je náročnost nastavení oceňovacích modelů, mimo jiné s ohledem na velikost a volatilitu úvěrového rozpětí zvažovaných tranší. Zmiňovaná krize vedla i k vytvoření další studie, jež se soustředí na sekuritizaci krytých dluhopisů. Výsledky získané Arifem (2020) pomocí kvadratického modelu a generalizovaného aditivního modelu ukazují na zvýšenou míru rizik především pro menší banky, které ne vždy zahrnují komplexní zohlednění rizik při nákupu obligací. Autor však namísto zpřesnění oceňovacích modelů doporučuje spíše přizpůsobení regulací ve vztahu k velikosti investora ze strany centrální banky.

Kritické zhodnocení nařízení Evropské komise o užívání modelu ocenění závazků a záruk u penzijních fondů, založeného na termínované struktuře bezrizikových úrokových sazeb, představují Jørgensen a Løchte (2018). Poukazují na rozpor s celkovým cílem, kterým je zvýšení finanční stability a ochrana pojistníků prostřednictvím podpory ekonomického ocenění v která způsobuje uměle nastavené vysoké diskontní sazby.

Na závislost mezi finančním a pojistným trhem se v souvislosti s oceněním dluhopisů zaměřuje Fergusson (2020). Výsledkem jeho posouzení je model, který naznačuje, že pokud je diskontovaný index podkladových aktiv daných pojistnou strategií modelován jako časově transformovaný čtvercový Besselův proces, je dosaženo jeho lepšího ocenění aktiv.

Na zaručené dluhopisy, které některé průmyslové společnosti využívají k posílení úvěrů a posílení své vlastní finanční situace se zaměřují Chen et al. (2020). Statisticky prokazují, že na tento typ financování se ve větší míře orientují společnosti s menším hmotným majetkem, nižšími úvěrovými ratingy a výraznějším převisem dluhu. Na druhou stranu, i přes využití

garance třetí zainteresované strany, investoři tyto obligace oceňují relativně vysokou přírážkou, ve kterých spíše intuitivně než na základě výpočtu, zohledňují zmiňované determinanty. Na význam likvidity formou vzorců finančních toků v případě korporátních dluhopisů upozorňují Goldstein, Jiang a David (2017), podle kterých je likvidita trhu jedním z faktorů určujících chování investorů. Relativně složitý vztah mezi derivátem – swapem a podkladovým aktivem – dluhopisem analyzují Fontana a Scheicher (2016) v rozsáhlé studii s důrazem na takzvaný fenomén úniků ke kvalitě, jež je podle nich průvodním jevem významných makroekonomických změn na finančních trzích. V rámci vlastního modelu tyto vztahy rozebírají Falcó, Navarro a Vázquez (2017), kteří se snaží stanovit numerický algoritmus pro oceňování amerických opcí na dluhopisy pomocí konzistentních křivek forwardové sazby.

Na problém velikosti podniku, který emituje obligace, upozorňuje Colonnello (2020), podle kterého především větší, univerzálněji zaměřené banky upřednostňují při ocenění a nákupu dluhopisů firmy podle velikosti a jejich informační otevřenosti, kde právě rostoucí velikost firmy může být jedním z podpůrných kritérií pro jejich vyšší atraktivitu z pohledu institucionálního investora.

Dalším, badateli relativně často zmiňovaným, faktorem pro ocenění obligací je nejistota ohledně hospodářské politiky, jež se dle Smales (2020) projevuje především v diskontní sazbě s přímým dopadem na ocenění velké většiny typů cenných papírů.

Inovativní investiční strategii orientovanou na dynamiku cen cenných papírů vytváří v této souvislosti Ahmed a Safar (2018). Jimi představený model vychází z předpokladu, že minulá cenová výkonnost předpovídá budoucí cenovou úroveň (během příštích 3–12 měsíců), přičemž podle jejich hypotéz jsou minulé ceny dány buď fundamenty, nebo finančně nerelevantními důvody. Využívají proto analýzy finančních výkazů (FSA) k tomu, aby rozlišili tyto dvě hnací síly minulých výnosů. Na základě těchto zjištění následně tvoří hodnocení příslušného aktiva.

Nový hodnotící dynamický model s názvem Stochastic Tail Index (STI) model pro analýzu časově proměnlivého indexu finančních aktiv s využitím vysokofrekvenčních dat potom představují Mao a Zhang (2018). Jeho prostřednictvím relativně přesně kvantifikují dopady především negativních zpráv v rámci denního obchodování na finančních trzích.

Hodnocením účinnosti mechanismů sdílení rizik v Evropě rozdělením složek faktorového výnosu na jejich dílčí komponenty se zabývají Dufrenot, Gossé a Clers (2020), s tím výsledkem, že vyšší integrace na dluhopisových trzích dlouhodobě významně zlepšuje sdílení rizik.

Začleněním okrajových podmínek do stochastického modelu volatility pro numerickou aproximaci cen dluhopisů se zabývají Gómez-Valle, López-Marcos a Martínez-Rodríguez

(2020), kteří na dvoufaktorovém modelu úrokové sazby se stochastickou volatilitou, stanovují okrajové podmínky, jež udržují vlastnost diskontní funkce ceny dluhopisu s nulovým kupónem. Tyto okrajové podmínky následně testují pomocí několika modelů stanovení úrokových sazeb. Třífaktorový oceňovací model zranitelných evropských opcí zahrnující stochastické rozpětí výnosů a úrokové sazby, jež rozšiřuje konstantní rozpětí výnosů a deterministickou úrokovou sazbu, představují Ma, Ma a Xiao (2019), podle kterých je dynamika krátkodobé úrokové sazby implicitně představována stochastickým procesem cen dluhopisů. Za klíčové stochastické faktory přitom považují spotovou cenu podkladového aktiva, sledovanou v geometrickém Brownově pohybovém procesu a rozpětí výnosů nedefaultních dluhopisů. Na základě jejich stanovení potom technikou Mellinovy transformace dochází k cenám zajištění zranitelných aktiv, jejich cena je dána především rizikem, které se k nim pojí. Na samotný stochastický diskontní faktor (SDF) při diskontování návratnosti dlouhého dluhopisu se zaměřují už zmiňovaní Qin a Linetsky (2018), kteří uvádí, že volatilita cen dluhopisů je přímo dána volatilitou jejich forwardové sazby.

Čistou tržní likviditou, tedy diskontní sazbou likvidity se zabývají Chung et al. (2018), kdy se zaměřují na patnáctileté japonské dluhopisy, které v jejich podání představují unikátní případ v důsledku jejich nízké volatility a extrémně stabilního obchodování. Dokazují na nich, že existuje přímá vazba mezi diskontní sazbou a mírou likvidity, především u stabilních obligací. Hyperbolické diskontování v dlouhodobém horizontu představují Griljava et al. (2018). V rámci konvexní experimentu zohledňujícího časový horizont 20 let nacházejí důkazy o poklesu diskontních sazeb, jež souvisí s mírou rizika vyjadřovanou důvěrou investorů.

Oceňováním čínských konvertibilních dluhopisů pomocí simulace Monte Carlo se zabývají Luo a Zhang (2019). Jde podle nich o jednu z mála metod, které umí pracovat s nedostatkem informací intenzitách selhání a volatilitě, což jsou ale zároveň jedny z nejdůležitějších parametrů, jež se k hodnocení tohoto typu obligací pojí. Konvertibilní dluhopisy jsou sice podle ekonomů důležitým segmentem trhu podnikových dluhopisů, a to i přes fakt, že přítomnost komplexních opčních funkcí a obtíže při měření rizikových faktorů velmi výrazně komplikují jejich ocenění (Batten, Khaw a Young, 2018). Zároveň ale podle nich představují výjimečnou investiční příležitost v důsledku jejich podhodnocování. To je podle nich ovlivněno hlavně mírou volatility podkladových aktiv, nižší mírou likvidity a vyšší dluhovou složkou, delší dobou splatnosti a nižší kvalitou informací.

Jiný model, který se soustředí na konvertibilní obligace, tvoří Park, Jung a Lee (2018). Stochastický model představuje investora a emitenta, který optimálně využívá své možnosti a diskontuje výsledné peněžní toky bezrizikovou sazbou. Jimi stanovená cena konvertibilních

dluhopisů výslovně závisí na ratingu v době emise, v průběhu času jsou potom účinky stochastických úrokových sazeb velmi významné, pokud tržní cena úrokového rizika není nulová, klíčovou roli tedy v tomto případě hraje rating už v době emise.

Na domácí – evropské prostředí se soustředí o Reis a Pinho (2020), kteří se zaměřují na nový index sentimentu evropských investorů, EURsent, založený na proxy sentimentu, jako je rozpětí výnosu německých dluhopisů. Soustředí se na přelévání kapitálu mezi USA a Evropou, a především analyzují vliv tohoto nového indexu na volatilitu i výnosy cenných papírů. Využívají především zavedené statistické techniky, jako je analýza hlavních složek, obyčejné metody nejmenších čtverců, autoregresní podmíněná heteroskedasticita (ARCH), generalizovaná ARCH (GARCH) a prahové GARCH modely. Z hlediska této studie je významný především druhý ze závěrů jejich výzkumu, který konstatuje, že dospět k závěru, že jedním z klíčových prediktorů je diskontní sazba, která vedle informace o peněžních tocích má hlavní podíl na výsledcích zkoumaného indexu. Odpovídá to i závěrům rozsáhlé studie Dunbara a Jianga (2020), kteří formou vektorové autoregrese zkoumají zdroje predikcí v rámci obchodních strategií kvalifikovaných investorů. Uvádí, že dominantní vliv na výsledky predikce mají diskontní sazby a peněžní toky.

Souvislostmi mezi výší diskontní sazby a audity se zabývají Fahad, Ma a Scott (2020), kteří na trhu vysoce kvalitních podnikových dluhopisů v Austrálii dokladují přímou korelaci, založenou na míře identifikovaného rizika.

Do určité míry novou a samostatnou kapitolou v oblasti oceňování je analýza kryptoměn a na ně navázaných derivátů, případně posouzení výkonnosti investic do těchto měn a cenných papírů – obligací a akcií, případně volba vhodných investičních modelů, které je zahrnují. Takový model vyvinuli Omane-Adjepong, Ababio a Alagidede (2019), kteří jej založili na vzájemném pohybu trhu mezi dvojicemi mezinárodních aktiv v časovém a frekvenčním spektru. Podle jejich závěrů zahrnutí kryptoměn do diverzifikovaných portfolií významně pozitivně ovlivňuje dynamiku rizika a výnosu diverzifikovaných portfolií. Problematikou systémového rizika se zabývají také Gong et al. (2019), kteří konstruují specifický model, obsahují index systémového rizika (SRISK), mezní očekávaný schodek (MES) a podmíněnou hodnotu v riziku (CoVaR). Ten následně aplikují na čínské banky, cenné papíry a pojišťovací společnosti. Různá opatření systémového rizika použitá v tomto rámci mohou podle nich kvantitativně identifikovat případná rizika u výše zmiňovaných společností či produktů finančního trhu.

Právě identifikace, respektive schopnost určení míry rizika je podle badatelů i výkonných portfolio manažerů a analytiků klíčová pro hodnocení bondů. Smales (2020) přímo konstatuje,

že nejistota je směřována na finanční trhy prostřednictvím efektu diskontní sazby, což má za následek vyšší rizikovou prémii. Neplatí to podle něj pouze pro dluhopisy ale i pro ostatní typy aktiv, kdy efekt nejistoty dominuje jejich ocenění. Do značné míry to potvrzuje i výzkum Kozaka a Santoshe (2020), kteří se zaměřují na průzkum časových řad tržních výnosů v korelaci ke konzistentnímu odhadu měnových výnosů dluhopisů s tržní rizikovou premií. Výsledkem jejich posouzení je, že diskontní sazby jsou vysoké v dobách dosažení jejich mezního užítku.

Obecným problémem je dle prakticky všech relevantních výstupů objem a kvalita informací, vázaných na příslušný cenný papír. Odvíjí se jak od kvality výkaznictví, tak také regionu. Na vztah mezi aktivy a informační kvalitou se zaměřují například Kladakis, Chen a Bellos (2020), kteří na základě diverzifikovaného panelu 699 podniků z 84 zemí a měří nedostatek informativní kvality s neshodami mezi ratingy konkrétních emitentů ratingovými agenturami. I jejich výsledky konstatují obecně pozitivní vliv vyšší kvality zveřejňování informací na rizikovou přírážku cenných papírů. Na zajímavý efekt ratingového hodnocení emitentů poukazují Amin, Jain a Malik (2020), kteří odhalují, že především asijské trhy výrazně masivněji reagují na zvýšení ratingu, a naopak výrazně méně v případě snížení ratingových hodnocení. Vliv exogenního nárůstu informační asymetrie na ceny dluhopisů potom zkoumají i Khalil et al. (2019), podle kterých má včasné a kompletní poskytování informací významný vliv na hodnoty dluhopisů, jež navíc přetrvává i v dalších emisích stejné společnosti.

S ještě většími problémy se potýkají analytici při hodnocení firemních dluhopisů, které jsou ohodnoceny více ratingy či rating postrádají. Huang, Jiang a Wang (2020) řeší tento problém prostřednictvím cenového modelu se stanovenou stochastickou úrokovou sazbou. Jeho výsledkem je konstatování, že cenový profil dluhopisu lze, za předpokladu diskontní sazby odrážející rizika, zachytit spojením vzorů vln se zaručenou cenou dluhopisu s nominální hodnotou rovnou jedné v době splatnosti. Tyto výsledky na zcela konkrétním příkladu potvrzuje Oster (2020), který se zabývá hodnotou prémiové přírážky stanovené investory za dluhopisy umožňující předčasné splacení. Zkoumá proměnné těchto dluhopisů, přičemž konstatuje statisticky velmi významné prémie v průměru 84,1 bazických bodů (bp) u dluhopisů, které postrádají ratingové ohodnocení. Naopak splatné dluhopisy s kvalitním ratingem se obchodují s průměrnou slevou pouze 12,0 bp oproti jejich nevypověditelným ekvivalentům. Významnou roli tak podle něj hraje prostředí s nízkými nebo negativními výnosy a zároveň nízkou averzí investorů k riziku.

Další otázkou je z pohledu analytiků i hodnota samotného ratingu. Motivační konflikty mohou podle Badoera, Demiroglu a Jamese (2019) vést ratingové agentury placené emitentem k poskytování optimisticky zaujatých ratingů. V rámci rozsáhlé studie předkládají důkazy, že

investoři zpochybňují kvalitu ratingů placených emitenty podnikových dluhopisů než srovnávací ratingy placené investory. Jejich výsledky přesvědčivě ukazují na to, kvalita ratingu a také jejich zadavatel mají významný dopad na náklady, které jsou s nimi spojeny a na jejich ohodnocení ve formě rizikové prémie promítnuté do jejich diskontní sazby. Na kvalitu ratingu se soustředí i Hu et al. (2019), kteří zkoumají reputační efekt ratingových agentur v Číně. Zjišťují přitom signifikantně negativní souvislost mezi nižší reputací ratingových agentur a jimi hodnocenými veřejnými obligacemi, u kterých dochází k významnému dopadu do spreadu. Apelují proto na regulaci ratingu, který nemusí poskytovat spolehlivé vodítko investorům, případně vyšší využití služeb CRA (China Bond Rating Co. Ltd), jež by měla fungovat v roli nezávislého arbitra.

De facto zpětný proces sledují Hasanhodzic a Kotlikoff (2019), kteří v rámci simulovaného modelu vstupu vlády či centrální banky na trh s dluhopisy. Konstatují, že tvorba cen krátkodobých a dlouhodobých rizikových závazků je zakotvena v převládajícím bezrizikovém výnosu. Ceny však zásadním způsobem ovlivňují kroky centrálních institucí.

Z tohoto jevu však vyplývá vůbec největší problém při hodnocení obligací. V případě, že nejsou veřejně obchodovány, je jejich ohodnocení omezeno a běžní účastníci trhu, nemají k dispozici relevantní modely, kterými by mohli jejich hodnotu posoudit. Ještě větší problém potom nastává, když jde o emise společností, které nevyužívají mezinárodního účetního výkaznictví (Pignatellová a Tchakoute-Tchigoua, 2020). Na druhou stranu získovat právě těchto dluhopisů vydaných společnostmi s nízkou ziskovostí a nízkým či neexistujícím ratingem překonává výnos z dluhopisů vydaných vysoce ziskovými společnostmi. Tato prémie za ziskovost je v souladu s kompenzací za riziko selhání a lze ji vysvětlit rizikovými faktory selhání. Dopad ziskovosti na výnosy z akcií závisí na relativní důležitosti rizika selhání a riziku, jež se přímo odráží v diskontních sazbách (Campbell, Chichernea a Petkevich, 2016).

Efekt kvality poskytovaných informací řeší Fang-Klinger (2019), který koreluje kvalitu informační otevřenosti podniku prostřednictvím objemu a kvality údajů obsažených ve výročních zprávách s oceněním jimi emitovaných dluhopisů. Dokazuje přitom, že společnosti s kvalitnějším informačním servisem dosahují nižší rizikové přírážky. Oproti tomu obligace firem méně kvalitním informačním servisem trpí vyšším úvěrovým spreadem a jeho vyšší volatilitou spojenou s růstem transakčních nákladů a dalšími negativními efekty. Vliv centralizace sítě týmu vrcholového managementu (TMT) potom na spready výnosů podnikových dluhopisů sledují Qiu, Su a Xiao (2019). Výsledky jimi identifikovaného umírňujícího efektu ukazují, že čím vyšší je index marketingu a čím více analytiků sleduje společnost, tím vyšší je výhoda společnosti vůči spreadu jí emitovaných dluhopisů.

Řešení dilematu mezi rizikem a výnosem nabízí současný výzkum ve formě vývoje nových hodnotících nástrojů, využívajících moderní analyticko-statistické modely, schopné pracovat s velkými objemy dat v silně dynamickém tržním prostředí. Na čele tohoto trendu jsou podle Gulsoy a Kulluk (2018) především banky. Finanční instituce podle nich sice disponují analytickými metodami posuzování rizik, která podstupují, ať už poskytováním úvěru, či nákupem cenných papírů, založenými na odvětvích a zkušenostech. Ty se však v prostředí globálních trhů, a především v silně konkurenci stávají neefektivní. Zvláště jmenují oblast posuzování segmentu středních a malých podniků, pro které podle nich existuje jen minimum prokazatelně funkčních a účinných nástrojů.

Potvrzují to i další badatelé, podle kterých složitost obchodní dynamiky nutí poskytovatele úvěrů či investory rozhodovat na základě subjektivních mentálních modelů odrážejících zkušenosti osob s rozhodovací pravomocí. Výzkum však ukázal, že společnosti dosahují lepších výsledků, když používají rozhodování založené na datech. To vytváří pobídku k zavedení inteligentních datových rozhodovacích modelů, které jsou komplexní a podporují interaktivní vyhodnocení možností rozhodování nezbytných pro obchodní prostředí (Bohanec, Kljajić-Borštnar a Robnik-Šikonja, 2017). Na mysli přitom mají zejména využití nových forem umělých neuronových sítí, které podle nich představují efektivní variantu řešení aktuálních finančních otázek.

1.2 Finanční a strategická analýza – základní východiska pro ocenění dluhopisů

1.2.1 Finanční analýza

Klíčem pro stanovení rámce ocenění cenných papírů je vždy finanční a strategická analýza, v případě firemní sféry potom doplněná správně zvolenou metodou komplexního hodnocení podniku. Přestože na potřebě těchto nástrojů se hodnotitelé shodují, nepadají mezi nimi ale, podle Penga, Van Essena a Penga (2020) shoda na výkladu těchto pojmů a případně, liší se pohledy na jejich vzájemné vazby a aplikace. I proto přichází s metaanalýzou, jež integruje podnikatelskou orientací a tržní orientací do posouzení výkonu firmy. Jejich studie založená na 160 nezávislých vzorcích čerpajících z 35 367 organizací ze 33 zemí ukazuje, že detailní strategická a finanční analýza je především v rozvinutých ekonomikách u velkých společnostech nezbytnou konkurenční výhodou určující přímo úspěch konkrétní společnosti, u malých firem v rozvíjejících se ekonomických regionech nehraje natolik významnou roli, případně její

význam není v jejich případech managementem a stakeholdery rozpoznán. Na druhou stranu, aktuálně dostupné nástroje finanční analýzy poskytují natolik širokou výzkumnou základnu, že je možné ji aplikovat na všechny sféry ekonomiky. Jejich relativní komplexní přehled poskytují Jagannathan et al. (2017), kteří zkoumají akademickou literaturu týkající se nákladů firem na finanční kapitál a prediktivní metody, které využívají jako proměnné, především potom náklady na kapitál, náklady na dluh a jejich relativní váhy.

Na možnosti skýtané jednorozměrnou diskretní analýzou vlnkové transformace (waveletů) v rámci predikce finančních časových řad, na základě běžných trhem poskytovaných údajů, například v rámci finanční analýzy poukazují Rostan a Rostan (2018), podle kterých jde o doplnění, jež umožní efektivnější předpovídání finančních časových řad v silně dynamickém a rozvíjejícím se prostředí. Lin, Sun a Yu (2020), oproti tomu v rámci finanční analýzy zaměřené především na podniky ve finančním sektoru využívají bayesianský přístup k efektivnímu odhadu vícerozměrných opatření k riziku v dynamickém rámci. Na vliv regulace se potom v rámci finanční analýzy zaměřují Liu et al. (2020), kteří pro svůj regresní model založený na využití nelinearity prahového limitu využívají relativně nový index FD navržený Mezinárodním měnovým fondem. Jejich obecné zjištění, že finanční systém rozvíjejících se trhů a zemí s nízkými příjmy ve vzorku významně a pozitivně ovlivňují přímé zahraniční investice, ale tento vztah mezi vyspělými trhy mizí, koreluje i s dalšími autory.

Finanční analýzou bankovního sektoru se zabývají i Wanke et al. (2020), kteří vyvinuli nové modely DEA a SFA Dynamic pro hodnocení 124 bank OECD v letech 2004–2013. Pro definici základních vztahů mezi hlavními účetními a finančními ukazateli využívají především relační vztah zahrnující hlavní ukazatele zisku, ukazatele rozvahy a čistý příjem, do kterého následně začleňují dynamický účinek indikátorů přenosu. Ve výsledku potom konstatují, že dalším faktorem, který působí rozdíly v ohodnocení, jsou dále socioekonomické a obchodní proměnné. Jednou z nich může být i stupeň digitalizace, která by se měla, podle Wang a Huang (2020) stát jedním z kritérií při hodnocení finanční výkonnosti firmy. Tento závěr zakládají na výzkumu 185 amerických a evropských výrobních firem, kdy dokladují, že u těch, které ve vyšší míře a dříve digitalizovaly své výrobní a servisní činnosti, došlo k signifikantnímu pozitivnímu dopadu do finanční výkonnosti, oproti srovnatelně velkým společnostem, které se digitalizaci vyhýbají. Z kritického pohledu však tato studie přímo nezohledňuje celkový finanční stav a výkonnost srovnávaných firem, kdy stupeň může být i indikátorem dostatku prostředků nutných pro inovace, a ne přímou příčinou jejich úspěchu.

Specifický index konstruovaný na základě finanční a fundamentální analýzy severoamerických bank představují Mohanram, Saiya Vyas (2018), podle kterých jde o základní přístup

umožňující základní orientaci investorům i dalším stakeholderům v rámci finančních trhů. Data slovenských podniků, získaná z výročních finančních zpráv za rok 2015 a z nich vypočtené finanční poměry ziskovosti, aktivity, likvidity a zadluženosti využívají v rozsáhlé analýze Valášková, Klieštik a Kováčová (2018) pro to, aby identifikovali klíčová finanční rizika podnikatelských subjektů v tomto regionu. Formou vícenásobné regresní analýzy identifikovali statisticky významné determinanty, které ovlivňují budoucí finanční vývoj společnosti. Z jejich výsledků potom vyplývá, že nejvýznamnějšími prediktory pro tento účel jsou čistý výnos z kapitálu, hotovostní poměr, rychlý poměr, aktuální poměr, čistý pracovní kapitál, poměr RE / TA, poměr současného dluhu, poměr finančního dluhu a obrat oběžných aktiv.

Jedním z hlavních problémů finanční analýzy je dostatečně relevantní a obsáhlý zdroj dat, přičemž relativně častým objektem výzkumu je využití Mezinárodních standardů účetního výkaznictví (IFRS), jejichž relevanci a přínos zavedení posuzují mimo jiné Wu et al. (2016), kteří na příkladu Tchaj-wanu dokazují, že klíčový přínos jejich zavedení spočívá jednak v kvalitě předchozího účetního standardu a následně v rámci jednodušší aplikace mezinárodních pravidel při posuzování dat konkrétních firem, zároveň však v případě rozvinutých ekonomik, dle jejich závěrů nevede k dalšímu zvýšení hodnotové relevantnosti finančních výkazů. Na stejný problém, navíc v korelaci mezi rozvinutými a rozvíjejícími se ekonomikami se zaměřují i Pignatellová a Tchakoute-Chigoua (2020), kteří konstatují efektivitu pobídek mezinárodních finančních institucí pro druhé jmenované. McCallig, Robb a Rohde (2019) řeší problém validity a hodnoty údajů uváděných v rámci finančního výkaznictví společnosti využitím sdílených dat. Řada firemních údajů už je podle nich sdílena s ostatními, na čemž zakládají metodu vícestranného zabezpečení s cílem zvýšit reprezentativní věrnost systémů finančního výkaznictví, s odkazem na data od nezávislých subjektů, transparentní systém a neměnné úložiště s otevřeným přístupem. Úplně jiný pohled na relevantnost údajů poskytovaných v rámci například kvartálního finančního reportingu či výročních zpráv přináší Bryce et al. (2019), kteří akcentují teorii plánovaného chování, v rámci které zkoumají psychologicko-motivační aspekty chování zaměstnanců a představitelů firem při poskytování těchto údajů. Empiricky ověřují efekt sobeckého chování s vlivem na validitu poskytovaných informací. Zdůrazňují proto význam kombinací metod v rámci finanční analýzy, včetně už zmiňovaných sdílených zdrojů.

Jedním ze způsobů, jak se vyrovnat s extrémním růstem finančních dat spojených s volatilitou jejich významu, je relativně časté využití textové analýzy publikovaných finančních materiálů zabývajících se ať už konkrétním podnikem, oborem, komoditou, nebo nejčastěji tržním sentimentem. V rámci korporátní úrovně jeden z modelů přináší Chan a Chong (2017), kteří

k extrakci zkoumaných výrazů uvedených v textech využívají hodnotící heuristiku. Dále potom pracují se standardními metrikami vyhodnocení syntaktické analýzy a následně srovnávacím hodnocením. Prozkoumali textový proud s dvanácti miliony slov, přímo vázaných na hodnocení výkonosti finančních trhů a výsledkem je poměrně překvapivá statistická relevance s hodnocením formou tradičních metod, spolu přesnou predikcí vývoje tržního sentimentu. Problémem však je omezené využití v rámci korporátního sektoru, kdy v rámci posuzování big data neexistují dostatek relevantních textových výstupů týkajících se například středních a menších, či začínajících společností.

Návrh začlenění zpracování přirozeného jazyka (NLP), do finanční analýzy přináší i Lewis a Young (2019), podle kterých dochází k dramatickému nárůstu množství verbálního obsahu, který je nedílnou součástí balíčků zpráv společnosti, který vyžaduje vývoj nových textových analytických přístupů používaných k analýze tohoto obsahu. Jimi představené řešení zahrnuje vyhledávání a počty klíčových slov, slovníky atributů, Bayesovskou klasifikaci, kosinovou podobnost a latentní Dirichletovu alokaci. Textovým obsahem výročních zpráv se už před nimi zabývali Buehlmaier a Whited (2018), kteří na základě analýzy textů sestavili modely určené akciové trhy, dluhové trhy a externí finanční trhy obecně. Tyto nástroje následně použili k sestavení portfolií, které v případě akciového trhu překonalo průměr výkonnosti trhu o 6,5 %. Bankrotní model založený na textové analýze finančních zpráv potom vytváří Nguyen a Huynh (2020), pracující s měřením finančního sentimentu založeným na těžbě textových zpráv pomocí slovníku finančního sentimentu a analýzy pozitivního, negativního či neutrálního kontextu. Využívají prediktivitu textové analýzy pro modelování úvěrového rizika a zároveň kvantifikují odlišnosti textových a tradičních prediktorů. Na relativně velkém vzorku amerických podniků s potom dokazují, že textové kontextuální modely zlepšují klasifikační výkon predikčních modelů, zatím však spíše z hlediska doplňku, či kombinace s tradičními modely.

Stejný inovativní přístup do finanční analýzy přináší i Englert, Koch a Wüstemann (2020), poukazující na selhání tradičních analyticky-hodnotících nástrojů během severoamerické hypoteční krize a tzv. krize eurozóny. I oni začleňují do analýzy i kvantitativní vyhodnocení textů, zaměřují se však primárně na bankovní sektor. Podle nich pojmy jako veřejně známá finanční výkonnost a obeznamenost, se stanou důležitějšími faktory určujícími reputaci organizace s přímým vlivem na riziko jejího selhání, případně s vlivem na potenciální „záchranné“ akce ze strany státu či mezinárodních finančních institucí. Do značné míry tak potvrzují výsledky doplnění analýzy o přístup text-as-data, který užívají i například James, Pagliari a Young (2020), kteří se soustředí na mapování vazeb mezi evropskými finančními institucemi a korporacemi. Ti pomocí kvantitativní textové analýzy 1 300 odpovědí na finanční

regulační konzultace EU v letech 2010 až 2018 mapují vzorce koordinace založené na společném označování a opětovném použití textu v konzultačních odpovědích s relevantními výsledky pro hodnocení postavení těchto institucí na vnitřním evropském trhu. Řada odborných výstupů a praktických aplikací v oblasti analýz a prediktivních modelů založených na analýze textů vyvolala i potřebu jejich závěry kriticky přezkoumat. Zde má základ rozsáhlá studie obchodní strategie založená na sentimentu názorových proudů, kterou na podkladu analýzy výstupů publikovaných na platformě Seeking Alpha po dobu tří let a následné komparaci tržních výsledků zpracovali Kommel, Sillasoo a Lublój (2019). Z jimi publikovaných výsledků potom vyplývá, že prediktivní modely založené na zpracování přirozeného jazyka vykazují horší výsledky než obchodní strategie navržené na základě doporučení finančních analytiků. Podle jejich závěrů je tak zpracování komplexní finanční analýzy významným prvkem pro stanovení obchodních strategií, či přijímání tržních rozhodnutí. Stejným problémem se zabývají i El-Haj et al. (2019), kteří zasazují metody výpočetní lingvistiky (CL) do celkového finančního diskurzu. Zabývají se především významem těchto metod v kombinaci s tradiční finanční analýzou, přičemž řada problémů s jejich aplikací je spojená s obtížnou kvantifikací v rámci komplexního hodnocení podniku. Navrhují proto nové nástroje – rozpoznávání entit (NER), sumarizaci, sémantiku a lingvistiku korpusu, které by měly pomoci k vzájemné integraci hodnotících systémů.

Dalším z problémů rostoucího objemu dat je úprava a hledání nových metodik detekce nesprávných, neúplných či záměrně zavádějících údajů v rámci finančního výkaznictví. Zaměřuje se na něj například Pustynick (2017), který pro tento účel vypracoval model založený na likviditním indikátoru M-Score a ukazateli Delta P-Delta. Jeho zajímavým zjištěním je odlišný výkon obou indikátorů při odhalování statistických či významových nesrovnalostí mezi rozvinutými a rozvíjejícími trhy. V globálním měřítku potom doporučuje využití kombinací obou forem.

Na schopnost bank se sídlem ve Spojeném království odolat důsledkům velké nejistoty, jako je brexit, se v rámci finanční analýzy zaměřují Chabot, Bertrand a Thorez (2019). Využívají analýzu topologie sítí, přičemž charakterizují povahu vztahů mezi finančními výkazy. Na základě panelové analýzy zahrnující proměnné ústřednosti identifikují klíčové proměnné, které mají vliv na finanční stabilitu těchto institucí v případě výskytu krizových situací.

Jinou oblastí výzkumu v oblasti finanční analýz je práce se souborem dat IFR (Internet Financial Reporting), případně volba metod, která s těmito daty pracuje. Například Pinto a Picoto (2016) vytváří kvalitativní komparativní analýzu s fuzzy množinou (fsQCA) dat, kterou zkoumají základ role IFR v posuzování výkonnosti firem. Výsledky fsQCA podle nich

naznačují, že několik kombinací IFR a analýzou rizik poskytuje vysokou míru přesnosti v rámci analýzy konkrétního podniku.

Determinanty podnikového zajištění v rámci finanční analýzy pomocí metaregresní analýzy na vzorku 175 studií řeší Geyer-Klingberg, Hang a Rathgeber (2019). Obecně upozorňují na firmy s vysokými kapitálovými výdaji a výplatami dividend, velkým poměrem dluhu a nízkým úrokovým krytím, přičemž ale konstatují velmi významné rozdíly mezi regiony a státy, které se promítají v kvalitě finančního výkaznictví a metodách finančního zajištění.

Na řešení finanční analýzy zahrnující dynamiku tvorby cen na finančních trzích se zaměřují Biondi a Righi (2016), kteří poměrově hodnotí účetní modely patřící do dvou hlavních skupin: historické nákladové účetnictví a tržní (reálná hodnota) účetní režimy. Režimy založené na měření obchodovaného cenného papíru mezi tržními cenami, které generují vyšší lineární korelaci mezi tržními cenami a základními signály, podle nich zahrnují také vyšší nestabilitu a volatilitu trhu. Obecně síťové modely, metody zátěžového testování a systémy včasného varování přitahují rostoucí zájem jak vědců, tak odborníků z praxe (Battiston a Martinez-Jaramillo, 2018), přičemž jejich zájem se v druhé a třetí dekádě 21. století bude podle jejich soudu soustředit například na problematiku multiplexních sítí, zpracování big data a zpracování vlivu celospolečenských trendů, jak například financování opatření souvisejících s ochranou klimatu. Toto téma se nevyhýbá právě ani finanční analýze, kdy se například studie Xie, Huo a Zou (2019, zkoumající vnitřní mechanismy, které spojují inovace zelených technologií s finanční výkonností firmy, stala jedním z deseti nejcitovanějších materiálů ekonomického výzkumu v roce 2019. S využitím údajů 209 společností, které patří do silně znečišťujících výrobních odvětví, shromážděných metodou obsahové analýzy, zjišťují, že inovace zelených procesů má pozitivní dopad na inovace zelených produktů a že inovace zelených procesů i inovace zelených produktů mohou zlepšit finanční výkon. Podobně Tzouvanase et al. (2020) hledají přímo souvislost mezi enviromentálním zaměřením společnosti a její čistou ziskovostí, případně srovnání výkonnosti firem tradičních a orientovaných na enviromentální aspekty podnikání. Dle jejich závěrů by právě koeficient respektování klimaticky pozitivního přístupu měl být součástí standardní analýzy ve vztahu k predikci vývoje společnosti. Konkrétně na bankovní sektor se s touto otázkou zaměřují Nizam et al. (2019), podle kterých má respektování klimatických cílů přímý vliv na finanční výkonnost bankovního sektoru na celém světě. Na základě průřezových lineárních regresí a nelineárních prahových regresí 713 bank ze 75 zemí v období 2013–2015 konstatují, finanční výkonnost zejména bank s celkovými aktivy nižšími než 2 miliardy USD je signifikantně vyšší než u institucí, které tento přístup nerespektují. Tyto závěry nicméně nejsou odbornou veřejností

přijímány jednoznačně. Ověřením víceúrovňového rámce komplikovaného vztahu mezi vlivem na životní prostředí a finanční návratností a syntézou těchto nekonsenzuálních výsledků se zabývá Liu (2020), který sice nalézá pozitivní vztah mezi environmentálním a finančním výkonem s rozdíly mezi společnostmi a průmyslovými odvětvími v důsledku heterogenit na úrovni společností a odvětví, nicméně zároveň u vybraných firem a průmyslových odvětví identifikuje negativní vztah. Jednou z jeho interpretací je potom obousměrný kauzální vztah mezi environmentální a finanční výkonností, což znamená, že společnosti, které mají dostatečné finanční zdroje k provádění proaktivních environmentálních strategií a iniciativ, vykazují obecně lepší finanční výsledky než firmy, které se potýkají s nedostatkem kapitálu. Tento závěr do značné míry odpovídá výsledkům předchozího výzkumu Hanga, Geyer-Klingeberga a Rathgebera (2019), kteří uvádí, že zvyšování vlivu na životní prostředí nemá krátkodobý vliv na finanční výkonnost podniku, což ale neplatí u dlouhodobého horizontu, kdy se investice a strategie orientované na environmentální aspekty projevují kladně. Jejich výsledky celkově ukazují, že příčinná souvislost mezi environmentálním výkonem a finančním výkonem závisí na časovém horizontu.

Dynamického programování pro komplexní finanční a rizikovou analýzu fiktivní společnosti, která nakupuje skladovatelnou surovinovou komoditu ze spotového trhu s volatilními cenami komodit a přístupem na související trh finančních derivátů využívají Kouvelis, Panga Ding (2018), kteří se soustředí především na korelaci dynamického zajištění zásob a finančního zajištění, s tím výsledkem, že oba tyto přístupy mohou být v dynamickém prostředí plnohodnotnými substituty.

Jiný typ společnosti, tentokrát zaměřený na výrobu a především plug-in hybridních vozidel analyzují Münzel et al. (2019), především s cílem identifikovat v tomto specifickém případě význam vládních či mezinárodních regulací v rámci komplexního hodnocení takového podniku. Potvrzují přitom předpoklad, že finanční pobídky či daňové úlevy mohou být rozhodujícím faktorem jak pro samotné podnikání v této oblasti, tak také klíčové pro finanční výsledky konkrétní firmy.

I přes nesporný význam finanční analýzy se jen relativně málo aktuálních studií věnuje této oblasti pro prostředí České republiky. Problematikou rozdílů mezi tradičním a ekologickým zemědělstvím se zabývá Hampl (2020), který pro rozsáhlou studii 172 konvenčních a 136 ekologických farem, rozdělených do tří velikostních kategorií využívá třístupňový přístup zahrnující obousměrnou vícerozměrnou analýzu rozptylu (MANOVA), neparametrickou obousměrnou analýzu rozptylu (ANOVA), konkrétně Scheirer-Ray-Hareův test a post hoc Dunnův test.

Na důležitou problematiku rozdílů mezi mezinárodními účetními standardy a národní účetní metodikou se potom zaměřuje Krajňák (2020), který poukazuje na možnou úsporu nákladů v případě využití národní metodologie, zároveň ale konstatuje výrazně vyšší míru kvality a důvěryhodnosti, významné právě i z pohledu zajištění kapitálu, při využití mezinárodních účetních standardů.

Částečně odvozeným pojmem od finanční analýzy je potom finanční inženýrství. Orientují se na něj Khabazian a Peng (2019), kteří na základě modelu lineární optimalizace vyvíjí novou rozšířenou analýzu citlivosti, pomocí které charakterizují podmínky, za kterých je podnik solventní, v prodlení nebo zbankrotuje, a jehož pomocí predikují pravděpodobnost jeho platební neschopnosti.

1.2.2 Komplexní hodnocení podniku

Komplexní hodnocení společnosti je nedílnou součástí řízení každé firmy, což umožňuje určovat dopad rozhodnutí obchodního managementu na výsledky výkonnosti, stejně jako směr výsledků a rozhodnutí, která je třeba učinit pro jejich zlepšení (Narkunienė, Ulbinaitė a Tvaronavičienė, 2018). Tradičně je výkon společnosti hodnocen především na základě analýzy ukazatelů finanční výkonnosti, zároveň však podle těchto autorek je nutné stále větší pozornost věnovat i nefinanční výkonnosti, a to především s ohledem na rostoucí dynamiku tržního prostředí. V rámci své široce citované studie proto poskytují rámec zahrnující jak tradiční formy hodnocení, mezi něž zahrnují například ekonomickou přidanou hodnotu, balanced scorecard, hranol výkonu, model Six Sigma případně další metody vícekriteriálních hodnocení výkonnosti, tak také metody pracující s nefinančními ukazateli. Zároveň však konstatují jedinečnost každé posuzované společnosti s doporučením v nejvyšší možné míře přizpůsobovat jak tradiční, tak kombinované modely příslušnému typu firmy a prostředí, ve kterém působí. Model Six Sigma využívají v rámci hodnocení podniku i Wei a Cheng (2020), představující komplexní fuzzy rámec pro kombinování objektivních hodnocení získaných z kvantitativních dat a subjektivních hodnocení získaných z kvalitativní analýzy pro výběr adekvátních projektů na podporu obchodních cílů a strategií. Problém vznikajících nejasností potom využívají metodu fuzzy multiple attribute decision-making (FMADM).

Ekonomický rozvoj světových ekonomik doprovázený jejich rostoucí otevřeností a silnějšími integračními procesy vyvíjí tlak na vzájemnou konfrontaci jejich ekonomické síly na základě jejich rozhodujících zdrojů. Mezinárodní srovnání vyžaduje stanovení komplexu faktorů, které ovlivňují úspěch rozvinutých ekonomik (Ivanová a Čepel, 2018). Hojně citovaná studie těchto autorů stanoví jako klíčový faktor zvyšování konkurenceschopnosti států inovační výkonnost

podniků, která se prostřednictvím inovativních obchodních procesů promítá do inovační výkonnosti ekonomiky jako celku. V rámci rozsáhlé srovnávací studie mezi státy Visegrádské čtyřky (Polsko, Česká republika, Slovensko a Maďarsko) konstatují nejvyšší inovační, a s tím spojený konkurenční potenciál u České republiky, zároveň také ale poukazují na stále rostoucí význam využití inovací v rámci vývoje podniků. Na faktor inovativnosti se zaměřují i Cabaleiro-Cerviiño a Burcharth (2020), kteří zkoumají, zda a v jakém kontextu fungují licenční smlouvy jako signály inovativnosti, které ovlivňují hodnocení investorů veřejných společností. Využívají k tomu empirické strategie, která čerpá ze vzorku 99 společností (2006–2012) a souvisí s reakcí investiční komunity na abnormální výnosy na akciovém trhu v den oznámení a na Tobin Q rok poté. Inovacemi se v rámci hodnocení společností či obchodních modelů zabývají i Heidenreich, Spieth a Petsching (2017), kteří posuzují efektivitu a výkonnost poskytovatelů produkce a provozu vozidel využívajících alternativní paliva a orientovaných na trvalou udržitelnost. Výsledky jejich modelování strukturálních rovnic potvrzují, že úspěšnost tohoto podnikání souvisí pozitivně s inovativností spotřebitelů a že tento účinek lze zesílit poskytováním externích politik, jako jsou infrastruktura, pobídky a komunikační politiky.

Obsahovou analýzu výročních zpráv a zpráv o udržitelnosti k měření indexu zveřejnění na KPI a analýzu datové obálky (DEA) k odhadu finanční výkonnosti představují v rámci komplexního hodnocení společnosti Loprevite, Raucci a Rupo (2020). I jejich studie komplexního pohledu na finanční ukazatele a reporting trvalé udržitelnosti komparuje výhody či nevýhody týkající se nových metod komplexního výkaznictví.

Podle Osinskiho et al. (2017) došlo v prvním desetiletí 21. století přímo ke změně konkurenčního modelu. V této souvislosti podle nich vstoupila společnost do éry, kdy jsou nehmotná aktiva největšími aktivy společnosti. Proto považují za nezbytné v kontextu obchodního, ekonomického a strategického řízení a hodnocení společnosti pracovat i s novými metodami oceňování nehmotných aktiva to specificky pro konkrétní průmyslová odvětví.

Problém dynamiky v oblasti obchodních modelů společností potom řeší Haaker et al. (2017), kteří konstatují, že současná míra nepředvídatelných změnami souvisejících nejen se zaváděním digitálních technologií, ale také v oblasti nových produktů a následné regulaci vyvolává potřebu nového popisu obchodních modelů, u kterých je určit relevantní sadu změn, posoudit jejich dopad a posoudit jejich výsledky s cílem posílení obchodního modelu konkrétní firmy.

Fakt, že v současné době si už nejen výzkumníci, ale také finanční instituce a stakeholderi nevystačí pouze s mírou a extrapolací zisku upozorňuje i Vrbka (2020), který upozorňuje na to, že ke komplexnímu hodnocení společnosti je třeba sledovat řadu cílů, od finanční výkonnosti,

přes jeho vnitřní a vnější vývoj, zvyšování bohatství akcionářů a míry ochrany všech zúčastněných stran. I proto v rámci unikátního modelu využívajícího umělých neuronových sítí vytváří sadu hodnotových faktorů, které mohou tito stakeholderi použít k posouzení růstu EVA Equity, tj. hodnoty pro akcionáře.

Na nové potřeby a metody hodnocení společností poukazují i Ryu a Suh (2020), kteří se v této souvislosti zabývají crowdfundingem. Soustředí se především na obchodní modely a analýzy platform, které crowdfundingové služby nabízí, přičemž jejich výsledky naznačují, že zásadní jsou pro úspěšnost těchto společností kvalitně poskytovaná služba spolu s vybudovanou komunitou, která tvoří jednu z největších hodnotových položek takové společnosti.

Laaksonen a Peltoniemi (2018) se oproti tomu v rámci komplexního hodnocení zaměřují především na vysvětlování výkonnosti firmy prostřednictvím identifikace jejích dynamických schopností, tedy připravenosti reagovat na změny v jejích vnějším i vnitřním prostředí. Dochází přitom k závěru, že zdokonalení operacionalizace dynamických schopností založených především na schopnosti managementu, schopnosti generování potřebných finančních údajů, pozici společnosti a míře využití lidského kapitálu, zvyšuje hodnotu společnosti a umožňuje jí získání rozhodující konkurenční výhody.

Oproti tomu studie Laghiho et al. (2020) si klade za cíl ověřit přímou metodu pro měření relačního kapitálu podniku prostřednictvím odhadu hodnoty firemních značek. Vzhledem k vlivu řízení relačního kapitálu na špičkový výkon a rozvoj značky považují hodnotu značky za proxy hodnotu relačního kapitálu. Navrhují dva ekonometrické modely pro kótované i nekótované společnosti, které berou v úvahu ocenění značky provedené primárními poradenskými subjekty (Interbrand, Brand Finance, BrandZ, European Brand Institute) a násobky odvozené z účetních a tržních dat firem a nachází relativně významnou statistickou korelaci. Sami však uvádí, že statistická významnost analýzy je omezena neobjektivní povahou odhadů hodnoty značky, a to zejména u nekótovaných společností. Výsledkem je potom doporučení využití této metody jako jedné z metod komplexního posuzování, spolu se zhodnocením ekonomických, finančních a majetkových charakteristik.

Nemusí přitom jít o celou firmu. Hodnocení výkonnosti firmy se může zaměřit na konkrétní oblast, která může v rámci posuzování její výkonnosti hrát klíčovou roli. Na hodnocení využívání cloudových služeb použitelné v obchodní praxi pro hodnocení efektivity investic do této oblasti se soustředí Marešová, Soběslav a Krejcar (2016), kteří k tomu využívají opět kombinovaný přístup založený na více metodách jako jsou systematický přehled literatury, analýza služeb, kvalitativní výzkum či případovou studii. Jiným příkladem je posuzování dopadu aktivit společnosti zaměřených na posílení oblasti vztahu se zákazníky, které zapojují

do své vlastní činnosti. Tyto, stále populárnější aktivity mohou mít, podle výsledků studie Beckerse, VanDoorna a Verhoefa (2018) paradoxně negativní dopad na hodnocení celé firmy. Na výběr segmentů trhu, na kterých společnost působí, se potom zaměřují Keshavarz-Ghorabae et al. (2017), kteří v rámci hodnocení navrhují a testují využití metody Fuzzy MCDM (multikriteriálního posuzování), kterou rozšiřují o metodu CODAS (COmbinative Distance-based ASsessment). Výsledkem představují ve formě modelu umožňujícího sofistikované rozhodování či analýzu efektivity penetrace či odchodu z konkrétního tržního prostředí. Na další nový aspekt v hodnocení společnosti se zaměřuje Ecer (2018), který do něj zasazuje schopnost snižování nákladů prostřednictvím logistiky třetích stran (3PL) za využití modelu integrace Fuzzy AHP a vyhodnocení založené na vzdálenosti od průměrného řešení (EDAS).

Specifický případ internacionalizace hodnocení výkonnosti státních podniků v rámci přechodu firmy z regulovaného do tržního prostředí řeší Cheung, Aalto a Nevalainen (2020). Použitím nové digitální historické metody na příkladu přechodu spol. Telecom ve Finsku popisují změny mechanismů správy a řízení v důsledku logického posunu, jež významně ovlivňují geografické a partnerské preference firmy a její výkonnost.

Na metody predikce a hodnocení účinnosti diverzifikace produktového portfolia s dopady na hodnotu firmy se zaměřuje Brzęczek (2020), který formuluje sadu rozhodovacích modelů, jejichž objektivní funkce zahrnují různé míry očekávané chyby predikce. Výsledkem jeho výzkumu je, že expanze produktového portfolia obvykle vede k vyšším předpokládaným prodejům a jejich nominálnímu riziku, ale také k nižšímu relativnímu riziku konkrétní společnosti.

Dopad klastrů na výkon v pěti vybraných průmyslových odvětvích v prostředí České republiky zkoumají Štichauerová, Žižka a Pelloneová (2020), jejichž cílem bylo zjistit, zda mají klastrové organizace pozitivní vliv na výkonnost jejich členských podniků v různých průmyslových odvětvích. Výsledky studie naznačují, že ve čtyřech průmyslových odvětvích (automobilový průmysl, IT, obaly, strojírenství) dosahují členské společnosti klastrových organizací lepších výsledků než nečlenové nebo firmy působící v jiných regionech. Na druhé straně neprokázali pozitivní vztah mezi výkonem společnosti a jejich registrovanými průmyslovými právy, a to ani z pohledu členství v klastru, ani jejich činnosti v příslušném odvětví a regionu.

Vliv velikosti firmy na její hodnocení zkoumají Yang et al. (2019), kteří formou pěti experimentů posuzují vliv velikosti na očekávání spotřebitelů a její hodnocení. Z výzkumu doplněného dvojicí metaanalýz zabývajících se studii spotřebitelských očekávání a šest studií hodnocení společnosti vyplývá, že to, jak jsou společnosti vnímány z hlediska velikosti

a výkonu, vytváří pro spotřebitele smysl, který ovlivňuje jejich očekávání a následné hodnocení.

Náročný cíl v podobě ve snaze vytvořit globální model s vysokou kapacitou pro předpovídání bankrotu v kterékoli oblasti světa si zvolili Alaminos et al. (2016), kteří pro tento účel využívají metodický rámec logistické regrese směřující k identifikaci společných charakteristik, které jsou typické pro firmu ohroženou bankrotem. Problém s nedostatečně vysokým počtem firem čelících bankrotu na Tchaj-wanu řeší potom Chen (2018) formou kombinace analýzy finančního poměru a analýzy potvrzujících faktorů s analýzou logistické regrese k odhadu pravděpodobnosti finančního selhání veřejných korporací. Výsledkem je podle něj model, který lze aplikovat na relativně široký průřez průmyslových odvětví.

Jinou formu bankrotního modelu představují v rámci komplexního hodnocení Hsu a Lee (2020). Pro finální výrok o budoucnosti podniku využívají metodu Random Forrest, kterou úspěšně komparují s dalšími metodami prostřednictvím řady experimentů.

Na vytvoření komplexní metody pro hodnocení průmyslového podniku, kterou lze použít k předpovědi potenciálních budoucích bankrotů potom navazují i Horák et al. (2020), kteří s pomocí souboru finančních výkazů aktivních společností a společností v likvidaci v období 2015–2019 vytváří funkční bankrotní model založený na neuronových sítích, konkrétně logistické regresi z dat zpracovaných v softwarových programech Statistica a Mathematica. Jejich výsledky ukázaly, že modely vytvořené pomocí softwaru Mathematica nejsou vzhledem k parametrům získaných výsledků v praxi použitelné. Naproti tomu umělé neurální struktury získané pomocí modelu neuronové sítě v softwaru Statistica se v jejich podání ukázaly perspektivní díky svému výkonu, který je téměř vždy nad 0,8, a logické ekonomické interpretaci příslušných proměnných. Celkově dosáhli přesnosti téměř 81 %. V případě klasifikace společností schopných přežít finanční tísně dosahovala kvalita predikce až 90 %, u klasifikace společností s rizikem úpadku téměř 55 %.

Logistickou regresi a metodu jackknife používají k testování předvídatelnosti různých modelů s údaji získanými z Growth Enterprise Market pro roky 2000–2010 i Hu Sathye (2015). Ti konstatují, že model, který zahrnuje finanční proměnné specifické pro konkrétní společnost, nefinanční proměnné specifické pro konkrétní společnost a makroekonomickou proměnnou, je lepším prediktorem finanční tísně než model, který obsahuje pouze první sadu proměnných. Rovněž uvádí, že model, který zahrnuje poslední dvě sady proměnných, je lepším prediktorem finanční tísně než model, který zahrnuje pouze první sadu proměnných.

Faktory ohrožujícími faktory zdravý, stabilní a udržitelný rozvoj čínských energetických společností se zabývají De et al. (2018). Problémy identifikují prostřednictvím čtyř dimenzí,

vnějšího základního prostředí, operačního úvěrového rizika, finančního úvěrového rizika a úvěrového rizika transakce, a určují systém indexu hodnocení úvěrového rizika, který zahrnuje 22 faktorů relevantních pro obchodní společnosti s elektřinou. K dosažení tohoto cíle využívají charakteristiky intuitivní fuzzy teorie množin a v nejistém prostředí navrhovaný model hodnocení úvěrového rizika založený na procesu intuitivní fuzzy analytické hierarchie (IFAHP). Autoři zlepšili úroveň identifikace hodnocení úvěrového rizika, navíc do modelu zavádí mechanismus variabilní váhy s možností dynamického přizpůsobení. Právě na problém výběru identifikátorů poukazuje více výzkumníků. Escrig-Olmedo et al. (2017) jej řeší vytvořením rámce, založeného na aplikaci metody fuzzy multi -kriterion decision-making (MCDM), kterým se soustředí jak na kvalitativní charakter indikátorů a složitost vývoje syntetického indexu, tak také na obtížnost správného výběru statistických technik pro agregaci příslušných dat.

Ani oblasti komplexního hodnocení podniku se nevyhýbají aktuální trendy posuzování společenské odpovědnosti, a to zejména v rámci euroatlantického kulturního okruhu. Příkladem je případová studie Tylerové a Vachhianiové (2020) zaměřená na dopady dvojího přístupu spol. Primark vůči LGBT zaměstnancům v kontrastu s jejími veřejnými proklamacemi a následným dopadem snížení důvěryhodnosti jak na straně investorů, tak také zákazníků. Z jiného úhlu pohledu zkoumají význam trvalé udržitelnosti pro hodnocení firmy Janssenová, Van Hammeová a LeBlancová (2017). Zabývají se hypotézou, že spotřebitelé nemusí nutně vnímat luxus a společenskou odpovědnost podniků (CSR) jako slučitelné. Na základě výzkumu v oblasti luxusního zboží konstatují, že na jednu stranu zřetelnost značky konkrétně ovlivňuje míru, v jaké spotřebitelé vnímají odpovědnou luxusní značku jako společensky odpovědnou, na straně druhé tak musí tato značka činit v souladu s dlouhodobou strategií, kdy jednorázové a neuvážené kroky v oblasti CSR mohou vést ke snížení její hodnoty. Stejnou oblast mají na zřeteli i Villamilová a Hallstedtová (2020), které do hodnotících kritérií, která zohledňují především náklady, kvalitu, riziko, výnosy, čas a pozici na trhu, začleňují ještě kritérium udržitelnosti. Mezi jejich hlavní zjištění patří navrhovaná definice konceptu portfolia produktů udržitelnosti a navrhovaná kritéria hodnocení udržitelnosti z hlediska odvětví.

Na obor dopravy se orientují Yazdani et al. (2020). Jejich studie si klade za cíl vyřešit problém měření výkonu systému nákladní dopravy a zároveň vyvinout komplexní rámec se začleněním udržitelných prvků a zavést hrubý rozhodovací přístup založený na souboru. Použitelnost navrhovaného rámce zkoumají prostřednictvím vyhodnocení výkonnosti sedmi společností zabývajících se nákladní dopravou ve Španělsku. Nástroj pro podporu rozhodování vytváří integraci metod hrubého rozhodování založeného rozhodovacím a hodnotícím modelem

DEMATEL a metodo pro víceúčelové srovnávání hraničních oblastí (MABAC) pro hodnocení samotného výkonu.

DEMATEL model využívají pro hodnocení společnosti, případně projektových řešení i Wu a Zhou (2019). Soustředí se především na nedostatek účinné metody hodnocení rizik. Projekty spojené se střešními instalacemi fotovoltaických elektráren v Číně řeší identifikaci kritických rizikových faktorů a následně pro ně navrhuji komplexní rámec pro hodnocení rizik. Komplexní systém hodnocení strukturálního rizika diverzifikovaného financování opět pro čínské prostředí, konkrétně firmy zřizované či majetkovou účastí municipalit vytváří i Wang a Jin (2019). V tomto případě však používají metody nejhoršího možného výsledku (BWM) k empirické analýze a kvantitativnímu studiu optimalizace strukturálního rizika.

Na význam rozhodovacího procesu pro podniky upozorňují v rámci komplexního hodnocení Hanine et al. (2017), kteří do něj vnášejí systém Geospatial Business Intelligence (Geospatial BI) jenž kombinuje vícerozměrnou analýzu a kartografickou vizualizaci. Podle nich právě komplexní řešení v otázkách velkých investičních rozhodnutí, umožňuje získání zásadní výhody v rámci konkurenčního prostředí. Výsledkem jejich výzkumu je potom metodika integrující tři známé rozhodovací techniky, a to Modified Delphi, fuzzy analytický hierarchický proces (fuzzy-AHP) a metodu organizace preferencí pro hodnocení obohacení (PROMETHEE).

Fakt, že firemní i výzkumná sféra vyžadují komplexní hodnocení, které jasně předpovídá finanční situaci v dnešním konkurenčním obchodním světě, je zřejmý, přičemž řada výzkumů dokazuje, že společnosti aplikující využití dat a systémová řešení dosahují lepších výsledků, než firmy řízené dominantně manažersky subjektivním rozhodováním (Bohanec, Klajic Broštnar a Robnik-Šikonja, 2017). Už proto tyto metody hodnocení získaly přijetí moderními společnostmi pro hodnocení jejich činnosti. Hodnotící zprávy poskytují komplexní obraz vycházející z účetních závěrek a poskytují robustní základ pro přijímání rozhodnutí jak managementu, tak například bank (Melo jr. et al., 2020).

Devi a Radhika (2018), tvrdí, že globalizace vedla k přesnější předpovědi finančního stavu podniků, protože věří, že poskytují užitečné informace pro zúčastněné strany a veřejnost. Finanční profil společnosti vyjádřený v jejich finančních výkazech může předpovídat finanční chování (Liu a Wu, 2017).

Přestože statistické metody hodnocení výkonnosti mohou působit zastarale, řada výzkumníků s nimi dosahuje relativně dobrých výsledků a významné jsou i pro korelaci výsledků. S tradičními modely bankrotních modelů, jako jsou Altman Z-Score, Kralickův Quick Test, IN 99 a IN05 pracují například Schönfeld, Kuděj a Smrčka (2018), evoluční dynamiku

a optimalizaci strategie pro určitý druh propojených evolučních her užívají (Fu, Li a Zhao, 2017). V jiném případě používá pro ověření efektivity statistických bankrotních modelů Sant'Anna (2017) metodu Monte Carlo, případně je možné chápat bankrotní model jako multivariantní šedý problém (grey prediction problem) pro jehož řešení užívá Hu (2020) genetické algoritmy. Poměrně častou metodou jsou i fuzzy modely. Wei a Cheng (2020) úspěšně užívají metody fuzzy vícenásobných atributů (FMADM) v rámci modelu Six Sigma pro zvyšování kvality podniku. Jinou fuzzy (Interval Valued Intuitionistic Fuzzy) metodu využívají pro hodnocení rozvojových projektů Mahdiraji et al. (2020). Stejní autoři (2020) potom hodnotí optimalizační procesy i formou vylepšené heuristické metody Kalmanova algoritmu. Specificky municipalitami vlastněné společnosti zkoumají metodou nejlepší/nejhorsí (BWM) prostřednictvím posuzování strukturální rizika jejich diverzifikovaného financování Wang a Jin (2019). Na hodnocení úvěrového rizika u čínských utility společnosti formou intuicionistické teorie fuzzy množin se zohledněním mechanismu variabilní váhy dynamického přizpůsobování se zaměřili De et al. (2019). Jinou kombinací metod, kombinující mimo jiné model souboru pro vyhodnocení kreditního rizika, který integruje vícenásobné vzorkování a fuzzy samoorganizující mapu s více jádry využívají Wang et al. (2020). Rovněž fuzzy teorii s cílem identifikovat kritické rizikové faktory provozovatelů fotovoltaických elektráren v Číně užívají Wu a Zhou (2019). Pearsonova korelačního koeficientu a následně regresních metod využívá při hodnocení společnosti Sajnog (2019), který konstatuje korelaci diverzity mezi výkonnou kompenzací a rentabilitou vypočítanou s čistým ziskem a komplexním výnosem.

Na fakt, že finanční ukazatele hrají důležitou roli při odhalování finančního zdraví podniku, což je role, která pomáhá udržovat konkurenční postavení podniku a dosažení stabilního rozvoje přispívá k eliminaci potenciálních finančních rizik, poukazuje i další studie Klieštika et al. (2020), která se zaměřuje na predikci budoucího finančního vývoje konkrétního podniku a na stanovení potenciálních závislostí mezi národem s ohledem na finanční ukazatele a zemi původu. Analyzují více než 400 predikčních modelů ze Slovenské republiky, České republiky, Polska, Maďarska, Rumunska, Litvy, Lotyšska, Estonska, Chorvatska, Ruska, Ukrajiny a Běloruska. Zásadní význam finančních poměrů v odlišných podmínkách zjišťují pomocí klastrové analýzy, kategorických údajů a korespondenční analýzy. Klastrová analýza identifikovala podobnosti mezi třemi skupinami zemí: i) Bělorusko, Estonsko, Chorvatsko a Lotyšsko; ii) Litva, Rusko, Maďarsko a Ukrajina a iii) Česká republika, Slovensko, Rumunsko a Polsko. Výsledky této analýzy naznačují, že jednotlivé skupiny zemí preferují při vývoji modelů predikce finanční tísně různé finanční poměry. Přesto však konstatují, že přesto

v běžné praxi dál zůstává nejčastěji používaným finančním poměrem v predikčních modelech aktuální poměr celkových závazků k celkovým aktivům a poměr celkových tržeb k celkovým aktivům. I proto zůstává otevřená otázka vhodného výběru modelu.

Na počátku druhého tisíciletí byly nejpopulárnějšími modely hodnocení společnosti a metod predikce jejího přežití či bankrotu především logistické regrese a další techniky, jako jsou univariační a multivariační techniky.

Recenzovaná literatura nicméně ukazuje, že modely neuronové sítě (NN) překonávají výkonnost a jsou v predikci bankrotu efektivnější než ostatní modely. Zejména kvůli složitosti moderních společností a použitelnosti modelu NN ve všech průmyslových odvětvích.

Vědci k tomuto účelu využívají řady metod, od statistických po progresivní modely strojového učení, jež dle Barboza, Kimura a Altmana (2017), vykazují v průměru o 10% vyšší přesnost než první jmenované. Vzhledem k významu hodnocení podniku a dopadům, které správná, případně nepřesná predikce může mít, se tato oblast stále rozvíjí, přičemž výzkumníci užívají jak nové metody, tak také rozvíjejí stávající, případně se snaží zvyšovat výkon a eliminovat nedostatky jejich kombinacemi.

Aktuálně k nejnovějším trendům patří Gated Recurrent neuronové sítě, jež poskytují příležitost díky jimi poskytované architektuře se sítí generátoru ukazatelů, možnost vysoce efektivního zpracování nestructurovaných dat s cílem výběru rozhodujících pojmů (Mahmood et al., 2020).

1.2.3 Strategická analýza

Dalším z faktorů, které mají vždy vliv na proces hodnocení cenných papírů má vždy strategická analýza. I v jejím případě výzkumníci často rozlišují prostředí, které podnik obklopuje. Například Sutherland, Anderson a Hu (2020) rozlišují v rámci strategické analýzy mezi podniky na rozvinutých a rozvíjejících se trzích, přičemž druzí jmenovaní se zaměřují především na strategické posuzování aktiv vázaných na lokalitu a zaměření na zahraniční kapitál. Další problém strategické analýzy spočívá dle Kumbury et al. (2020) v její – především manažerské – interpretaci. Představují proto metodiku zkoumání vazby mezi poznáváním jednotlivců a výkonem společnosti na základě kombinace kognitivní mapy s fuzzy množinou kvalitativní srovnávací analýzy (fsQCA), s cílem zvýšit výkonnost společnosti v rámci konkurenčního prostředí. Další metaanalýzu představují Samba et al. (2020), kteří se soustředí na potřebu a efekt komplexních strategických rozhodnutí a změn v dynamickém tržním prostředí. Na základě dat 37 významných studií zaměřených na strategickou hodnotou komplexnosti rozhodnutí uvádí, že dynamika prostředí se do dopadů strategických posunů projevuje jen minimálně. Třetí významná aktuální metaanalýza v oblasti strategické analýzy se zabývá

vlivem změn souvisejících s výměnou nejvyššího vedení společnosti. Schepker et al. (2017) představující metaanalýzu 60 případových studií od roku 1972 do roku 2013, představujících 13 578 nástupnictví, a zjišťují, že nástupnictví generálního ředitele negativně ovlivňuje výkon firmy v krátkodobém horizontu, přičemž nemá žádný významný přímý vliv na dlouhodobý výkon. Účinky dlouhodobého výkonu jsou místo toho zprostředkovány strategickými změnami a novým původem generálního ředitele (uvnitř firmy i mimo ni). Generální ředitelé vybraní z vlastního prostředí firmy zlepšují dlouhodobý výkon a angažují se v méně strategických změnách, zatímco najímání externího generálního ředitele vede ke strategičtější změně, která má za následek nižší dlouhodobý výkon. Podobné téma v oblasti strategické analýzy zkoumají i Borges a Tan (2016), kteří se soustředí na korelaci vysokého hodnocení úspěšného přijetí automatizovaných a pokročilých výrobních technologií a zároveň podceňovaného lidského faktoru, jako jsou morálka zaměstnanců a dovednosti pracovníků. Na nutnost ocenění nehmotných aktiv a zahrnutí nefinančních ukazatelů se soustředí i Ban et al. (2020). V rámci posouzení významných rumunských společností využívají fuzzy analytické hierarchie. Poté metodou TOPSIS stanovují úroveň výkonnosti pro každou společnost, zvláště pro finanční, nefinanční a všechny ukazatele. Na základě získaných výsledků uvádí, že klíčem k určení celkové výkonnosti společností jsou v současné době právě nefinanční ukazatele.

Jinou aktuální otázkou v oblasti strategického řízení řeší Cardin, Zhang a Nuttall (2017), kteří posuzují v globálním měřítku vhodnost strategických investic do jaderné energetiky. Jejich model je vyvíjen a analyzován prostřednictvím vícestupňového stochastického programovacího rámce, kde jsou rozhodovací pravidla představována jako nepředvídatelná omezení. Toto řešení podle nich poskytuje nový způsob, jak navrhnout a analyzovat adaptační strategie s ohledem na fluktuace dlouhodobé nejistoty, který poskytuje přesnější údaje, že závěry standardních technik analýzy reálných možností, které se obvykle používají k analýze flexibility pro takto rozsáhlé investiční projekty.

Posledním aktuálním trendem, který zasáhl do výzkumu strategické analýzy, stejně jako do dalších oblastí současné ekonomie, je potom příklon k trvalé udržitelnosti. Raut, Cheikhrouhou a Kharat (2017) jej řeší tím, že do fuzzy modelu MCDM, který integruje Balanced Scorecard integrují další – čtvrtou proměnnou. Podnik tak posuzují z pohledu finanční stability, řízení vztahů se zákazníky, interního obchodního procesu a implementace systému řízení zahrnujícího důraz na trvalou udržitelnost. Tento model následně úspěšně aplikují na šest největších indických bank spolu s aplikací jeho výsledků do nastupujícího trendu integrovaného výkaznictví. Na oblast pojišťovnictví se potom zaměřují Kue et al. (2015), kteří se soustředí na základní prvky celkového řízení kvality, mezi něž zahrnují měření výkonu a řízení rizik.

K zjištění efektivity marketingu a efektivity ziskovosti aplikují metodiku analýzy dynamické obálky datových sítí, jež podle nich identifikuje rozhodující konkurenční výhody příslušné společnosti.

Problematiku strategických investic a analýz řeší formou model přechodové dynamiky Mantovi a Schianchi (2019), kteří jej využívají pro kvantifikaci především významných kroků v oblasti cenotvorby. Za pomoci prostředků především novorakouské školy definují hlavní integrály a následně řeší strategickou analýzu formou opčních her. Systému plánování výroby, který odráží produkční prostředí a může poskytnout rozhodující výhodu, se věnují Lee, Jeong a Woo (2018), kteří prostřednictvím příkladu jihokorejským loďařskými firmami, kteří jsou dle jejich tvrzení nejkonkurenceschopnější na světě, chybí relevantní výzkum cílů a komplexní metoda hodnocení pro systemizaci procesu plánování výroby a výsledků plánování výroby. I proto navrhnou rámec pro hodnocení a systém hodnocení pro posouzení plánování výroby na základě integrovaného procesu plánování.

Metodu Kraljic Portfolio Matrix (KPM) doporučují v rámci strategických analýz využít Montgomery, Ogden a Boehmke (2018), kdy zároveň řeší problém kvalitativní povahy modelu, jež vede k subjektivní metodě vážení a umístění dodavatelů nebo komodit do různých kvadrantů formou dodatečné kvantitativní analýzy. Na strukturu dodavatelského portfolia se potom v rámci strategické analýzy zaměřují Trautrim, McCarthy a Okade (2017), kteří řeší především problematiku spoléhání výrobců na výkon klíčových partnerů dodavatelského řetězce mimo jejich vlastní organizační hranice, zejména pokud jde o inovace produktů. Poznatky potom využívají k podpoře procesů zadávání zakázek a zdrojů na různých úrovních: k identifikaci inovačních aktivních kategorií produktů na úrovni dodavatelského portfolia, k posouzení inovativnosti potenciálních dodavatelů na úrovni kategorie produktu a k určení klíčové vrstvy dodavatelského řetězce. Náročný cíl v podobě návrhu nedílného indikátoru udržitelnosti podnikání a jeho propojení s identifikovaným ukazatelem ekonomické výkonnosti a ekonomickou přidanou hodnotou, si pro slovenské prostředí předsevzali Maciková et al. (2018), kteří zkoumají vztah mezi finanční výkonností společnosti a udržitelností formou komparace metody finančních poměrů a metod korelační a lineární regresní analýzy. Předmětem jejich šetření jsou podniky ze tří vybraných sektorů, přičemž výběrové kritérium pro vzorek je stanoveno na základě podílu prodeje podniků na odvětvových tržbách tak, že do vzorku jsou zahrnuty podniky s celkovým podílem více než 50 %. Badatelé se shodují v tom, že organizace jsou odpovědné za dopad svých rozhodnutí a akcí na společnost a životní prostředí. Tuto odpovědnost by mělo vykonávat mimo jiné transparentní a etické chování, které přispívá k udržitelnému rozvoji, včetně blahobytu a zdraví společnosti, zohledňování očekávání

zúčastněných stran, udržování souladu se stávajícími zákony a soulad s mezinárodními standardy chování, a měly by být integrovány do činnosti organizace a uplatňovány v jejích vztazích (Hawrysz a Maj, 2017). Zároveň se však, dle stejných autorek právě tato identifikace stakeholderů může stát faktorem zvyšujícím formou zájmu investorů, pro které je obecná důvěryhodnost klíčová, rozhodující konkurenční výhodou.

Obecně však dopady různých parametrů jak na aspekt trvalé udržitelnosti, tak na celkový výkon firmy je otázkou pro většinu badatelů. Obecná shoda však panuje v tom, že složitost ovlivňujících parametrů se odráží v multikriteriální povaze optimalizačních problémů, které lze vyřešit vhodným použitím nových či evolučních výpočetních metod (Ojstersek a Buchmeister, 2020).

1.3 Analýza trhu

Nejen firma, ale také sektor, stát, prostředí, právní systém, vývoj technologie, stav a predikce vývoje ekonomiky. To všechno jsou faktory, které do hodnocení cenných papírů automaticky vstupují prostřednictvím analýzy trhu. Ta je sama o sobě extrémně širokým pojmem, který se prolíná řadou ekonomických disciplín a s tím souvisí i relativně rozsáhlý aktuální výzkum. O propojení trhu s dluhopisy a vnějším prostředím, přičemž jde v obou případech vztah se zpětnou vazbou, výzkumníci nepochybují. Pro zvýšení stability finančního systému státu, pomoc se zvládnutím úvěrů a ke zmírnění finančních krizí podnikového sektoru, jsou nezbytné robustní, hluboké a živé trhy s podnikovými dluhopisy (Neemey a Sahay, 2019).

Ve spojitosti s dluhopisy je stále v souvislosti s tržní analýzou nejčastěji zmiňováno riziko, nicméně v tomto ohledu nejčastěji ve spojitosti s vnějším prostředím emitenta. Na rozvíjející se trhy se v této souvislosti zaměřují Demirel a Unal (2020), kteří je analyzují z hlediska návratnosti, volatility a vzájemné korelace 203 různých typů firemních dluhopisů z Indonésie, Brazílie, Indie, Jižní Afriky, Mexika a Turecka. Využívají dynamické podmíněné korelace a frakčně integrovaný zobecněný autoregresní podmíněný model k jejich vzájemnému srovnání a ověření vlivu prostředí na míru rizika a tím i jejich ohodnocení z hlediska investičních příležitostí. Přímou na rizikové prémii dluhopisů v Jižní Koreji, jež je možné označit za relativně menší otevřenou ekonomiku, charakterizovanou vysoce volatilními kapitálovými toky a zemí jejíž Won nejde označit za významnější rezervní měnu /viz. Česká republika/, se zaměřuje v rámci tržní analýzy Yun (2019). Jeho zjištění ukazují, že mezi alternativními prediktivními proměnnými (včetně makroekonomických a globálních faktorů likvidity) pro jednorocní nadměrné výnosy dluhopisů patří především globální faktory likvidity, extrahované ze souboru

dat panelu různých globálních proměnných likvidity. Podobně regresní analýza determinantů odhadovaných rizikových premií dluhopisů (s měsíční i čtvrtletní frekvencí) ukazuje, že obdobně jako v případě amerického dluhopisového trhu jsou rizikové premie u korejských dluhopisů ovlivněny očekávanou domácí inflací, ale co je důležitější, že jsou silně ovlivněny proměnnými globální likvidity, jako jsou toky bankovního kapitálu a expozice globálních bank. Z pohledu ocenění dluhopisů je určení vlivu makroekonomických ukazatelů velmi důležité. Rizikové premie se podle Berndta et al. (2018) do značné míry shodují s makroekonomickými ukazateli, přičemž proticyklická variace poměru premie k očekávané ztrátě je výraznější u emitentů investičního stupně než u emitentů s vysokým (rizikovým) výnosem.

Přímo na evropskou ekonomiku se v rámci tržní analýzy soustředí Schmidt (2020), který se zabývá závislostí podnikových dluhopisů na hospodářské politice konkrétní země. I on se soustředí na rizika, rozlišuje mezi makroekonomickým rizikem, rizikem hospodářské politiky a finančním rizikem a vytváří prahově-vektorový model, který obsahuje aktiva a úrokovou sazbu. Potvrzuje přímou souvislost mezi měnovou politikou a cenovou úrovní korporátních bondů, přičemž nejvyššího výnosu dosahují dluhopisy, které jsou přímo vázány na státní hospodářskou politiku. Vliv státu je mimořádně patrný v případě už zmiňovaných „zelených“ dluhopisů. Ty jsou přímo vázány na investiční pobídky, systém dotací či malusů souvisejících s emisemi. Tyto systémy však, jak připomínají Halkos, Managi a Tsilika (2020) v řadě případů podléhají legislativě jednotlivých členských zemí. Jejich výzkum založený na roční alokaci výnosů od roku 2006 do roku 2017 ukazuje, že vliv zemí z hlediska objemu a četnosti emisí a výnosů zelených dluhopisů podle konceptů (kritérií) „příliš propojených na selhání“ a „příliš velkých na selhání“ dokazuje, že země, jež se soustředí na klimatickou politiku, dominují i ve vlivu na hodnotu tohoto typů obligací. Determinanty korelačních vzorů mezi trhy zelených a tzv. „černých“ (emitovaných podniky užívajícími fosilní zdroje) dluhopisů řeší Broadstock a Cheng (2019). Korelace i determinanty jsou podle nich časově proměnlivé, přičemž je stanovují pomocí dvoustupňové sekvenční metodiky. V první se extrahují dynamické podmíněné korelace (DCC) a v druhé v druhé využívají dynamické průměrování modelu (DMA). Podle očekávání konstatují, že spojení mezi zelenými a černými dluhopisy je citlivé na změny volatility na finančních trzích, na ceny emisních povolenek, nejistotě hospodářské politiky, přičemž navíc konstruují i index pozitivního a negativního zpravodajského sentimentu vůči zeleným dluhopisům.

Z pohledu investorů řeší analýzu trhu prostřednictvím makroekonomických faktorů Amenc et al. (2019), K vytvoření dobře diverzifikovaného portfolia faktorů je podle nich třeba vzít v úvahu skutečnost, že různé faktory mohou mít podobnou závislost na makroekonomických

podmínkách. Autoři proto poskytují metodiku pro výběr příslušných makroekonomických stavových proměnných, které odrážejí změny v očekávání agregátní ekonomiky. Porozumění makroekonomickým rizikům je podle nich předpokladem transparentnosti rizik i zlepšení diverzifikace investic. Stejný problém optimálního portfolia dlouhodobého investora, který plynule kombinuje akciové indexy, dluhopisy a úročený účet peněžního trhu analyzují i Lioui a Tarelli (2019). Faktory, které řídí strukturu termínů a kapitálovou prémii, dávají do souvislosti s makroekonomickými proměnnými – především inflací. Pokud se očekávaná inflace sníží, investor se zaměřuje na akciový trh a dlouhodobé dluhopisy. Optimální poptávka po penězích tak podle nich s sebou nese časové rozdíly v averzi k riziku. Model neúplných trhů, na kterých dochází k mezinárodnímu obchodu s více aktivy, vytváří v souvislosti s tržní analýzou Senay a Sutherland (2019), jejichž analýza ukazuje, že přítomnost více aktiv vytváří potenciálně silnou interakci mezi měnovou politikou a alokací portfolia.

Na citlivost kapitálových trhů rozvíjejících se zemí na volatilitu stabilních aktiv – amerických státních dluhopisů se soustředí Gubareva a Keddad (2019). Představují model kapitálových výnosů v portfoliu dluhů sestávajících z dluhopisů rozvíjejících se trhů jako lineární regresi změny kapitálových zisků v portfoliu skládajícím se z dluhopisů, ve kterých je povoleno přepínání regresních koeficientů mezi třemi režimy. Výsledek potom prokazuje vysokou citlivost kapitálových trhů na krizová období stabilně chápaných aktiv, jež jsou přímo ovlivňovány politikou emitenta. Vzhledem k jejich ekonomickému významu jsou mezinárodní trhy s dluhopisy považovány za pravděpodobné místo pro působení tlaků finančního trhu na vládní politiku rozvíjejících se trhů (Naqvi, 2018). Z pohledu analýzy trhu přitom ale investoři trpí tím, že relativně málo rozeznávají faktory, které formují prostředí, ve kterém se pohybují. Vliv mají nejen regulace politicky definovaného státu, ale především centrální banky. Kenourgios, Drakonaki a Dimitriou (2019) zkoumají účinky nekonvenční měnové politiky zahájené Evropskou centrální bankou v roce 2012, s druhou fází o dva roky později, na korelaci mezi trhy mezi dluhopisovými, akciovými a měnovými forwardovými trhy. Zjišťují, že nová fáze uvolňování zahájená v roce 2014 má výraznější dopad a zdůrazňují jak rozdíly v dopadu mezi dřívější a novou vlnou UMP a napříč trhy, přičemž evidují i významné rozdíly mezi členskými zeměmi. Dopady postkrizové finanční regulace zahrnující zákon Dodd-Frank a Basel III na tržní likviditu podnikových a státních dluhopisů s pevným výnosem analyzují iTrebbi a Xiao (2017). Zaměřují se na tvrzení, že postkrizová regulace poškozují likviditu, kterou ale formou rozsáhlé analýzy vyvrací a konstatují, že správně nastavená regulační opatření neznamenají nutně snížení likvidity nejen podnikových dluhopisů, ale také dalších cenných papírů.

Na vztah mezi pojišťovny a obchodníky na trhu korporátních dluhopisů poukazují Hendershot et al. (2020), kteří konstatují, že regulatorní omezení obchodu a tvorby portfolia zvyšují náklady na zajištění a snižují výnosy z rezerv. Další regulatorní omezení, respektive jeho částečné uvolnění, analyzují na trhu dluhopisů Crespi, Giacomini a Mascia (2019), kteří sledují dopady možnosti rekapitalizace z vnitřních zdrojů v lednu 2016 na ceny italských bankovních dluhopisů. Pomocí datového souboru 1 798 dluhopisů s pevnou úrokovou sazbou, vydaných v období 2013–2016, zjišťují zvýšení spreadu při vydání dluhopisů s možností rekapitalizace z vnitřních zdrojů ve srovnání s dluhopisy, které nejsou pro tento účel použitelné. Na konsekvence spojené s dalším regulatorním opatřením – zákazem a omezením spekulací na pokles se soustředí Atmaz a Basak (2019), kteří se v nejprve soustředí na to, jak se toto omezení projevuje na cenách opcí. Vypracovanou metodiku následně aplikují na trh firemních dluhopisů, kdy dokladují stejně významný efekt, jako v případě opcí.

Dopad změn faktorů výnosové křivky na spready úvěrového selhání (CDS) průmyslových odvětví USA zkoumá Aman (2019). Jeho výsledky potvrzují, že dlouhodobý faktor výnosové křivky je negativně významným determinantem prémie CDS bez ohledu na sektor a stav trhu a také naznačují významný inverzní vztah mezi spready CDS a výnosy cenných papírů.

Na stanovení faktorů, jež, mimo samotného ratingu, ovlivňují spready podnikových dluhopisů v eurozóně v období 2001–2015 se soustředí Dewachter et al. (2019). Vytváří bezrizikovou křivku, měřenou sazbami jednodenního swapového indexu a podnikové výnosové křivky pro dvě ratingové třídy (A a BBB). Jejich model zahrnuje čtyři rozložené a šest nerozložených faktorů, přičemž zjišťují, že obecně, ekonomické (reálná aktivita a inflace) a finanční faktory (zastupující averzi k riziku, únik k likviditě a obecný stres na finančním trhu) hrají významnou roli při určování rozpětí spreadu podnikových dluhopisů zemí eurozóny. Dokonce u podnikových bondů s hodnocením A a BBB vysvětlují vybrané finanční proměnné v průměru 50 % variací spreadu během posledního desetiletí (2008–2018). Tyto faktory mohou dle Christensen a Van Der Wel (2019) hrát dvojí roli, jak kovariančního generování běžných šoků, které zvyšují výnosy, tak determinantů tržních cen rizika v průřezových cenách. Jimi předkládané důkazy upřednostňují časově proměnlivé rizikové ceny, které významně souvisejí s druhou Stock-Watsonovou hlavní složkou makroekonomických proměnných a se změnami indexu průmyslové produkce.

Výsledky, jež potvrzují velmi významný vliv vnějšího evropského prostředí, potvrzují i Vukovic, Lapshina a Maiti (2019), kteří analyzují trh dluhopisů Evropské měnové unie s různým hodnocením a splatností v období 2005 až 2017. Uvádí přitom, že minulé a současné trendy a vzorce výnosů dluhopisů, jež definují pomocí statistických metod korelace

a ekonometrické analýzy, závisí především na splatnosti dluhopisů a ekonomické situaci na trhu.

Významné přelévání měnové politiky na mezinárodní trhy dluhopisů dokladují Albagli et al. (2019). Ti jednak konstatují významně vyšší zranitelnost dluhopisových trhů v rozvíjejících se ekonomikách a zároveň uvádí, že endogenní účinky měnových intervencí na dlouhodobé výnosy obligací by měly být přidány do standardní analýzy nákladů, kdy jejich vliv může zásadním způsobem ovlivnit výnos těchto cenných papírů. Podobně vztah mezi toky dluhopisových fondů, výnosy na akciovém trhu a finančními politikami v rozvinutých a rozvíjejících se ekonomikách zkoumají Qureshi et al. (2019). Konstatují, že expanzivní měnová politika má negativní dopad na výnosy dluhopisů, zatímco expanzivní fiskální politika na ně má pozitivní vliv. Kromě toho dluhopisové fondy podle nich vzkvétají v době nízké ekonomické aktivity v rozvinutých i rozvojových zemích. Hofstedeho šest dimenzí národní kultury, tedy de facto vnějšího podnikového prostředí, využívá ke studiu implikovaných úrovní volatility na patnácti hlavních mezinárodních trzích s cennými papíry Liu (2019), který v rámci své studie prokazuje jejich velmi významný vliv na stanovení rizik a s nimi spojených výnosů. Význam institucí, právního prostředí a kultury ve všech aspektech globálních podniků zdůrazňují i Filatotchev, Poulsen a Bell (2019), kteří v rámci metaanalýzy řeší teoretické a empirické mezery v předchozích finančních a mezinárodních obchodních studiích spojených s problémy corporate governance a efektivitou řešení zajišťování kapitálu. Aby problémů s celkovou analýzou trhu nebylo málo, přidávají se i nejasnosti v oblasti rovnovážných cen. Teoretické definice jednotlivých typů cen (např. rovnovážná cena, hodnota na volném trhu, nabídková cena) podle Vrbky et al. (2020) poukazují na to, že každý ze zkoumaných typů cen je velmi specifický a je formován vlivem mnoha faktorů. Jako praktický příklad přímo uvádí teoretický základ cenových strategií v oblasti nemovitostí, princip však platí prakticky ve všech oblastech.

Naopak pozitivní vliv opatření na podporu podnikání analyzují v Polsku Zajkowski a Domańska (2019), kteří formou numerické analýzy modelu lineární regrese zkoumají efektivitu institucí orientovaných na podporu podnikání a jimi poskytované prostředky. Jako závislou proměnnou používají dvojitou proměnnou, která popisuje dvě skupiny podniků, tj. ty, které podporu nedostávají, a ty, které veřejnou podporu získávají. Výsledek odpovídá očekávání, podle kterého jsou podniky, které dlouhodobě využívají podpory podnikání, inovativnější a jsou méně náchylné k bankrotu.

Model, jenž formou vektorového autoregresního modelování identifikuje šoky na poptávku, nabídku, měnovou politiku a výnosy pomocí omezení z obecného modelu rovnováhy

představují Liu et al. (2019). Dokladují touto formou efektivitu zásahů státních a centrálních institucí do fungování trhu. Jejich analýza odhaluje důležité změny statistických vlastností klíčových makroekonomických proměnných a jejich reakce na identifikované šoky. Během krizového období v druhé dekádě 21. století se podle nich šíření šoků stalo klíčové pro pohyby nezaměstnanosti a inflace. Zároveň hodnotí důležitost nižšího rozpětí spreadu dluhopisů během krizí a naznačují, že rozsáhlé nákupy aktiv Fedem pomohly snížit míru nezaměstnanosti přibližně o 0,6 procentního bodu a zároveň zvýšit inflaci přibližně o 1 procentní bod. Na propojení trhů nejrůznějších typů finančních aktiv a rychlost přelévání kapitálů upozorňují Yoon et al. (2019). Prostřednictvím síťové analýzy kvantifikují přenos šoků a oznámení z jednoho trhu na druhý (akcie, dluhopisy, měna a komodity) od prosince 1999 do června 2016. Zároveň touto metodou měří i čistou směrovou propojenost pro každý trh (třidu aktiv) a konstatují stále rychlejší reakce trhu na oznámení, regulace a další typy zásahů a šoků. Podobná zjištění týkající se volatility (stresu) v rámci přelévání kapitálu mezi akciemi, trhem s nemovitostmi, dluhopisy a měnami a přelévání nejistoty hospodářské politiky v sedmi zemích přináší i Liow, Liao a Huang (2018), kteří uvádí, že efekt přelévání kapitálu a nejistoty představuje přibližně 72 %, resp. 50 % dynamiky stresu na finančním trhu v sedmi zkoumaných ekonomikách. Vyvozují z toho mimo jiné i závěr o omezené roli národních finančních institucí v současném globalizovaném světě.

Mimořádně rozsáhlou studii časových variací v integraci globálního finančního trhu představují Zaremba, Kambouris a Karathanasopoulos (2019). Pomocí jedinečného komplexního datového souboru zkoumají výnosy z akcií, státních dluhopisů, pokladničních poukázek a měn v 83 zemích během období téměř dvou století. Jejich studie ukazuje, že integrace ekonomiky postupuje ve vrcholech a nikoliv lineárně. Ačkoli trhy po roce 2000 vykazují nejsilnější integraci v historii, některé třídy aktiv v letech 1860 a 1930 zaznamenaly srovnatelnou úroveň, přesto ale konstatují, že vysoký stupeň současné integrace je spíše výsledkem prudkého nárůstu, který začal až v roce 1970, než důsledkem postupného procesu trvajícího několik století, tedy globální trendy je nutné zohledňovat v tržních analýzách až v posledních padesáti letech. Dobře je to vidět na krizi Eurozóny, kde nejistota na trzích poznamenala ceny dluhopisů, nicméně došlo k tomu velmi nerovnoměrně. Rozsáhlá studie Gregoriho a Sacchiho (2019) zkoumá, zda zprávy o odchodu Řecka z eurozóny ovlivnily výnosy státních dluhopisů ostatních evropských zemí. Jejich empirická analýza zahrnuje více než 64 000 denních zpráv v období od prosince 2014 do října 2015. Na jejich základě vytváří index intenzity Grexit, který zachycuje politické obavy ohledně rozpadu v eurozóně. Vyšší intenzita zpráv o Grexitu signifikantně zvyšuje

rizikovou přírážku – výnosy státních dluhopisů v okrajových zemích (Itálie, Portugalsko a Španělsko, s výjimkou Irska), zatímco na klíčové země nemá významný vliv.

Zpětný pohled, kdy se výzkumníci zaměřují v rámci analýzy trhu na dopad vývoje trhu dluhopisů na vnější prostředí je spíše výjimečný. Soustředí se na něj například Neemey a Sahay (2019), kteří analyzují růst trhu indických korporátních dluhopisů a jeho dopad na některé vybrané měnové, fiskální a ekonomické proměnné v letech 2006 až 2017. Konstatují přitom, že klíčovou proměnnou je mírný dopad na HDP, u dalších ukazatelů nicméně konstatují, že trh podnikových dluhopisů není spojen s dalšími ekonomickými, měnovými a fiskálními proměnnými ani negativně, ani pozitivně. Podobný vztah zkoumají i Yin a Feng (2019), snažící se identifikovat dynamický vztah mezi nejistotou na ropném trhu a mezinárodním hospodářským cyklem. Prostřednictvím dynamické panelové analýzy s využitím postupu Arellano-Bond GMM zjišťují, že riziková prémie za volatilitu ropy má významný vliv na růst produkce s přímým dopadem na trh. Obecně přitom konstatují, že nejistota ropného trhu má celkově lineární účinek na mezinárodní hospodářský cyklus a dopady jsou relativně široké.

Zatímco o potřebě zohlednění vnějších faktorů při oceňování dluhopisů (stejně jako všech dalších typů aktiv) výzkumníci nepochybují, názory na využití metod se liší. Nabízí řadu variant, od konstrukcí vlastních indexů (Gregoriho a Sacchi, 2019), až po SWOT analýzu, kterou pro posouzení perspektiv rozvoje vozidel na methanol v Číně používají Li, Negnevitsky a Wang (2020). Problémem je komplexnost a velmi obtížné zohlednění váhy a vazeb vnějších faktorů, které se do ocenění firmy, respektive jí vydávaných obligací, promítají, navíc oceňovací modely nejsou na analýze trhu založeny, ale pouze ji zohledňují. I proto řada autorů využívá pro tento účel základní či rozšířenou verzi PEST analýzy, jež dovoluje postihnout vnější prostředí v celé jeho šíři.

Na otázku, proč mnoho technologicky zaměřených řešení složitých environmentálních výzev nedosahuje svých zamýšlených cílů, odpovídají prostřednictvím široké politicko-ekonomické, sociální a technologické analýzy Larkin, Hoolohan a McLachlan (2020), kteří představují radikálně odlišné konfigurace sociálně-technologických systémů nejen ve vztahu k řešení klimatické krize. Podobný problém řeší i Pearseová (2020), která prostřednictvím této analýzy sleduje možnosti nových energetických řešení. Poukazuje mimo jiné na historické vztahy mezi energií a společností, krizové tendence energetického kapitálu, nebo prostorové rekonfigurace spojené s přechody na nové zdroje energie. Obecně je energetika jedním z hlavních cílů zájmu vědců, kteří aplikují metodu PEST (resp. PESTEL) jak na jednotlivé projekty, firmy, tak i oblasti. Patří k nim i Segura, Morales a Somolinos (2018). Ve své relativně často citované studii zaměřené na analýzu využití a návratnosti energetických projektů využívajících

přílivovou energii moře, přímo uvádí, že většina recenzních prací týkajících se těchto systémů je zaměřena na technická témata. Stále však existují omezené informace o dalších aspektech, jako jsou aspekty ekonomické, sociální, politické, legislativní a environmentální povahy, které je třeba společně s jejich vzájemnými vztahy řešit jako celek, aby bylo možné odhalit klíčové faktory, které by mohly ovlivnit úspěch nebo neúspěch při uvádění technologií přílivové energie na trh. Cílem jejich práce je potom identifikace rizik a návrh řešení, jak je eliminovat či snížit během uvádění této technologie do komerčního života. Opět energetikou se v rámci této analytické metody zabývají Tsangas et al. (2019), kteří jejím prostřednictvím posuzují efektivitu a rizika související s těžbou nově objevených ložisek zemního plynu u pobřeží Kypru. Využívají vstupy čtyř hodnotitelů zastupujících různé zúčastněné strany, přičemž zajímavé je, že jako nejdůležitější jsou hodnoceny sektory životního prostředí, a až poté následované ekonomickými faktory. Technologickou transformaci energetického průmyslu řeší stejnou metodou i Quiceno et al. (2019), kteří hledají příležitosti i rizika v rámci nové regulace a nastavené podpory nízkoemisních zdrojů v Kolumbii. Jednoznačně přitom konstatují, že společnosti s dostatečně robustní adaptivní strategií zvládají lépe hrozby a mají lepší ekonomickou perspektivu než firmy, které preferují realizaci zisků na úkor investic do nových technologií.

Přímo strukturální model korelací mezi kvalitou podnikatelského prostředí (QBE) a faktory určujícími kvalitu podnikatelského prostředí vytváří Cepel et al. (2020). Na základě vzorku 329 podniků ze Slovenské republiky využívají konfirmační faktorovou analýzu a modelování strukturální rovnice ke kvantifikaci regresní a kauzální korelace mezi QBE a vybranými faktory. Jejich zjištění poté do značné míry potvrzuje výsledky předchozích výzkumů, když ustanovuje jako nejdůležitější faktor makroekonomické prostředí, na něž navazuje měnová politika a úrokové sazby.

Úzký vztah mezi ekonomickou konkurenceschopností země a rychlostí jejího ekonomického růstu zkoumají prostřednictvím rozsáhlé PEST analýzy na příkladu Ukrajiny (Fyliuk, Honchar a Kolosha, 2019). Využívají při tom mimo jiné globální index konkurenceschopnosti (GCI), přičemž konstatují, že jedním z hlavních indikátorů úrovně konkurenceschopnosti je HDP na obyvatele, přičemž tento faktor odráží objemy spotřeby na obyvatele a je vysoce korelovan s úrovní blahobytu v zemi.

Přístup PESTLE-SWOT používají k výběru identifikovaných faktorů pro efektivní řízení a správu mezinárodní výrobní sítě Mishra et al. (2019). Výsledkem je potom konstatování, které z hlediska efektivnosti výroby staví na přední pozici vládní a hospodářskou stabilitu, ekonomickou svobodu, trvalou udržitelnost a dostupnost surovin. Stejný cíl, tedy identifikaci klíčových

faktorů, tentokrát ale pro růst sdílené ekonomiky si kladou v rámci podobně rozsáhlé analýzy i Grybaitė a Stankevičienė (2018), které dělí vybrané ukazatele do čtyř hlavních skupin: technologické, politické a regulační prostředí, ekonomické a sociálně-kulturní prostředí a aplikují je v Litvě, Lotyšsku, Estonsku a Spojeném království. Výsledkem je tvrzení, že na rozvoj sdílené ekonomiky mají klíčový vliv technologická připravenost a sociálně-kulturní prostředí.

Částečně kritické posouzení rozsáhlých analýz nabízí Diaz-Ruiz et al. (2020), kteří posuzují efektivitu klíčových nástrojů pro skenování trhu – analýzu pěti sil a nástroje PESTEL – a posuzují jejich výkonost při predikci faktorů ovlivňujících trh. Výsledkem jejich snahy je vytvoření dalšího koeficientu, který nazývají manažerskou krátkozrakostí, a v jejich podání omezuje schopnost zaregistrovat sociálně zakotvenou systémovou povahu složitých současných trhů.

Přesto však badatelé jednoznačně doporučují PEST (PESTEL) analýzu jako efektivní a relativně snadno využitelný prvek hodnocení firmy či jejího produktu, který jako jeden z mála dovoluje postihnout i obtížně kvantifikovatelná rizika a příležitosti. Není přitom bez zajímavosti, že je stále častěji využívána, jak dokladují na příkladech na energetického využití odpadů v Číně Song, Sun a Jin (2017), v situacích, kdy dochází k prolínání sektorů, zájmů a v čase sílí regulace.

1.4 Moderní metody ocenění dluhopisů

Vzhledem k významu dluhopisů pro globální prostředí je výzkum zaměřený na jejich ocenění relativně rozsáhlý. V řadě případů doporučují autoři využití kombinací metod či užití obecných modelů jako jsou například víceúrovňové nebo hierarchické lineární modely (Xu, Dishon a Dishop, 2020), kteří ji doplňují o Bollenovo a Brandovo modelování strukturálních rovnic (SEM).

Rozsáhlý výzkum ocenění podnikových dluhopisů představují i Chen et al. (2020), kteří se zaměřují na interakce mezi selháním a likviditou bondů. Na základě výzkumu emisí mezi lety 1996 až 2015 konstatují, že e interakce selhání a likvidity se promítá 10–24 % v úrovni úvěrového spreadu a rovněž kvantifikují náklady na držení tohoto typu dluhopisů, jež se podle nich pohybují na úrovni 6 % z nominální hodnoty za sledované období.

Specifické měřítko pro ocenění dluhopisů v podobě křížových měnových swapů využívají při určování hlavních zdrojích rozdílů úvěrového rozpětí Du, Wenxin a Jesse Schreger (2016),

kteří ve svých závěrech poukazují ve výsledcích svého modelu především na pozitivně korelované úvěrové a měnové riziko a riziko selektivního selhání.

Novou třídu lineárně-rationálních modelů termínových struktur, ve kterých je modelována hustota cen tak, aby se ceny dluhopisů staly lineárně-rationální funkcí faktorů, přináší Filipović et al. (2017), která podle nich výrazně efektivnějším způsobem, než stávající metody zachycuje především struktury termínů, volatility a dynamiky rizikové prémie posuzovaných tříd obligací. Jiný oceňovací rámec založený na zkreslení stochastické volatility, ve kterém latentní stochastická varianta sleduje proces šikmé difúze, představují pro ocenění vybraných druhů obligací (především s nulovým kuponem) Ding, Cui a Wang (2020), jejichž metoda je založena na základě aproximace Markovova řetězce v nepřetržitém čase k podkladovému stochastickému procesu. I oni však naráží na limity obecného modelu a přistupují k omezení využití pouze na specifické typy bondů.

Specifickou kombinací metod ocenění dluhopisů zahrnující formulaci Knightianovy nejistoty v rámci stochastického modelu zahrnujícího singulární priority tvoří Lin a Riedel (2020), z jejichž výsledků vyplývá klíčový vliv úrokových sazeb na celém trhu s cennými papíry, jež jsou podle nich hlavními proměnnými z pohledu investorů.

Metodu vlnkové komprese pro stanovení měřítka dynamických korelací mezi výnosy amerických dluhopisů a obligací rozvíjejících se trhů užívají Yeh, Chiu a Chang (2020), kteří touto formou poukazují na nízkou efektivitu diverzifikovaných portfolií a upřednostňují vyšší ohodnocení severoamerických bondů, vykazující relativně vysokou míru stability, což zohledňuje i jejich ocenění.

Hodnotové účinky finančního a provozního zajištění v režimu řízeného plovoucího směnného kurzu s přísnými omezeními obchodování s finančními deriváty zkoumají prostřednictvím Tobbin Q Hadian a Adaoglu (2020). Zjišťují, že zajišťování derivátů vytváří v průměru krátkodobé rozmezí hodnotové prémie 7,88–8,21 % a v dlouhodobém horizontu 18,81–19,80 %. Pozitivní efekt zajištění derivátů by měl podle nich motivovat obchodníky a manažery malajských společností k zajištění expozice v cizí měně prostřednictvím derivátů a povzbudit tvůrce trhu při vývoji dalších finančních derivátů.

Jinou metodu využívají už zmiňovaní Albuquerque et al. (2016), kteří vytváří teorii oceňování aktiv, ve které hrají ústřední roli poptávkové šoky. Tyto šoky podle jejich závěrů vedou k oceňovacímu riziku, které modelu umožňuje zohlednit klíčové momenty oceňování aktiv, jako je kapitálová prémie, prémie za dluhopisy a slabá korelace mezi výnosy akcií a fundamenty. Další z oceňovacích modelů, který mimo jiné i vysvětluje přelévání kapitálu mezi dluhopisovým a akciovým trhem, vystavěli Campell, Pflueger a Vicera (2020) na definici

časově proměnných rizikových premií vycházejících z logaritmické makroekonomické dynamiky ve formě Eulerovy rovnice spotřeby, přičemž za rozhodující prvek považují inflaci, jež má negativní dopad na výnos neindexovaných obligací.

O stanovení rozhodujících ekonomických a finančních faktorů, které ovlivňovaly spread podnikových dluhopisů v eurozóně v období 2001–2015 se v rámci modelu zahrnujícího čtyři rozložené a šest nerozložených faktorů pokouší Dewachter et al. (2020), kteří uvádí, že čistě finanční proměnné mají padesátiprocentní vliv na spread evropských korporátních obligací v posledním desetiletí, a předpokládají, že tento trend bude i nadále mírně posilující.

Zásadním problémem při hodnocení dluhopisů je predikce finančních časových řad, což je výzva, které čelí řada finančních analytiků a činitelů s rozhodovací pravomocí (Khashei a Hajirahimi, 2017). Obecně podle těchto autorů ústí snaha o nalezení vhodného modelu tvorby kombinovaných modelů, mezi které oni sami řadí mimo jiné autoregresní integrovaný klouzavý průměr (ARIMA) a vícevrstvé perceptronové sítě (MLP), případně paralelní hybridní modely jako jednoduchý průměr, lineární regrese a modely genetického algoritmu.

Analýzu finančních aktiv v takzvaných klidných a neklidných dobách řeší pomocí vektorového autoregresního modelování dlouhých a krátkých časových řad Berger (2016), který konstatuje významný rozdíl ve validitě dat mezi relativně nevýkonnou analýzou jednoho a výrazně přesnější analýzou více časových řad.

Zcela zásadní je pro hodnocení společností, jejich projektů či jí emitovaných cenných papírů stanovení rizik (Li et al., 2017). Sami se zaměřují na oblast energetiky, kdy kombinují granulované výpočty a analýzy vztahů k určení váhy indikátorů a následně do modelu implementují rozšíření o hodnocení rizika v rámci optimální rozhodnutí.

Příkladem korelace mezi vybranými ukazateli a rizikem, jež se následně odráží v diskontní sazbě, je například rozsáhlá studie, jež hodnotí potenciální investice do ropy a zemního plynu, kterou zveřejnili Li et al. (2020). Podstatou jejich studie je identifikace klíčových investičních rizik pro ropu a plyn. Následně, na základě konceptu kompenzace rizika, navrhují různé kompenzační mechanismy specifické pro každé riziko. Rizika a přínosy jsou objektivně integrovány do vývoje komplexního modelu hodnocení opravou zpětně získatelné rezervy, úpravou parametrů vyhodnocení přínosů, jako jsou investice do průzkumu a vývoje, a kompenzací změn rizikových faktorů v čase prostřednictvím dynamické diskontní sazby.

Jednou z klíčových otázek podle řady autorů je zahrnutí systematického rizika a stanovení premii za riziko, jež se následně odráží ve spreadu dluhopisů, jak například dokládá na využití váženého průměrného skóre ESG Immel et al. (2020). Zvláště citelný je tento problém

u obligací, jež nedisponují ratingem. Jedním z nejefektivnějších řešení jsou proto neuronové sítě.

1.5 Neuronové sítě

Obecně největším problémem při ocenění dluhopisů je podle výzkumníků především dynamika a rostoucí množství dat produkovaných na finančních trzích. Jedním z nejefektivnějších řešení jsou podle Ou et al. (2019) metody strojového učení, které dle nich umožňují efektivně sledovat a hodnotit mimo jiné i mechanismy propuknutí a šíření systémového rizika v prostředí finančních trhů, přičemž mají schopnost dokonce zefektivnit jejich současnou regulaci. Přímou se přitom zaměřují na korelace a možné kombinace metod pro hodnocení a měření finančního systémového rizika v kombinaci s technologiemi strojového učení, včetně analýzy big data, síťové analýzy a analýzy sentimentu.

Badatelé už přitom nemají zpravidla pochybnosti o tom, že využití strojového učení, případně z něj vyplývajících metod patří mezi aktuálně využívané prediktivní modely. Stále častěji však řeší otázku, zda je výhodnější užívat je jako jedinou, či doplňkovou část analýzy. Hluboké srovnání mezi hybridním souborem a metodou hlubokého učení proto nabízí například Kim, Lee a Shin (2019), kteří na souboru testů konstatují, že samostatný model hlubokého učení překonává jimi zvolené hybridní metody. Velmi podobný problém řeší i Loureiro, Miguéis a Da Silva (2018). Jejich studie porovnává predikce získané pomocí přístupu hlubokého učení s těmi, které byly získány souborem mělkých technik, tj. Random Forest (RF), podpora vektorové regrese, umělé neuronové sítě a lineární regrese. Z jejich výsledků následně vyplývá, že model využívající hluboké učení má nejlepší predikční výkon pro předvídaní prodeje, avšak pro část zvažovaných hodnotících metrik nepodává výrazně lepší výsledky než metoda RF. Další podobné srovnání nabízí i Petropoulos et al. (2020), kteří využívají řadu technik modelování predikce platební neschopnosti bank. Jejich výsledky naznačují, že metoda RF má velmi dobrý prediktivní výkon zejména při využití systematizovaných dat, srovnatelný s běžnými neuronovými sítěmi, které umí pracovat s méně utříděnými daty, ale jsou účinnější až při dostatku dat

Relativně časté využití metod RF v případě dluhopisů navazuje na výzkum využití moderních metod celkově v oblasti finančnictví. Li a Chen (2019) navrhuje kombinovaný algoritmus logistické regrese a model umělé neurální sítě pro zlepšení prediktivního výkonu založeného na skutečných datech běžné komerční banky. Kombinovaný model podle nich vyžaduje využití entropie k určení parametrů modelu logistické regrese a modelu umělé neuronové sítě.

Experimentální výsledky podle nich ale ukazují, že navrhovaný kombinovaný model překonává dva základní modely na čtyřech hodnotících metrikách: přesnost (ACC), plocha pod křivkou (AUC), statistika Kolmogorov-Smirnov (KS) a Brierovo skóre (BS). Na omezení metody Random Forrest naráží i další výzkumníci. Ye, Dong a Ma (2018) se snaží obohatit tuto metodu o faktor ziskovosti na straně poskytovatele kapitálu. Proto představují model optimalizovaný pomocí genetického algoritmu se ziskovým skóre (RFoGAPS). Nejprve, s ohledem na skutečné a potenciální výnosy a ztráty, navrhuje skóre zisku, které stanovují jako cíl optimalizace. Poté vytvořený genetický algoritmus využívají k optimalizaci kombinace rozhodovacích stromů, jež vyhodnocují datovou sadou Lending Club.

Jiný hybridní model, který kombinuje extrakci funkcí časových řad a hlubokou neuronovou síť k identifikaci regionálních charakteristik využívají pro kvantifikaci dopravních systémů v Číně Zhao, Fan a Zhai (2020), podle kterých je daná metoda vysoce efektivní právě pro řešení otázek spojených s nestabilním prostředím.

Kombinované finanční modely, které se snaží překlenout omezení dané tradičními metodami, mají řadu využití. Například Wang et al. (2020) vytváří nový dynamický model založený na hlubokých neuronových sítích s cílem vytvořit odhad návratnosti investic ve filmovém průmyslu, mimo jiné umožňující predikci návštěvnosti kin v Číně.

Pro evropské prostředí je silně aktuální jiný prediktivní model založený na umělých neuronových sítích. Soustředí se na predikci cen uhlíkových povolenek, jež jsou přímo svázány mimo jiné s cenami komodit jako uhlí a přeneseně i s cenami elektřiny. Na podkladě 1074 denních analýz cen uhlíkových povolenek, které byly shromážděny, aby obsahovaly užitečný soubor časových řad a pro vyhodnocení navrhovaných technik, vytváří Atsalakis (2016) model pro řízení rizika nákupem a prodejem futures na emisní povolenky založený na strojovém učení. Využívá nový hybridní neurofuzzní ovladač, který tvoří mechanismus zpětné vazby s uzavřenou smyčkou zvaný PATSOS, systém založený na umělé neuronové síti (NN) a adaptivní neurofuzzní odvozovací systém (ANFIS).

Jiný hybridní model kombinující analýzu hlavních komponent (PCA) a analýzu NeuroEvolution of Augmenting Topologies (NEAT) představují Nadkarni a Ferreira-Neves (2018). Závěrem testů na reálných denních datech čtyř finančních trhů různých odvětví s odlišnými charakteristikami je konstatování o jeho relativně vysoké výkonnosti především při denním obchodování především s akciemi. Oblibu hybridních modelů dokazují i Qiao et al. (2020), kteří do něj vkládají adaptivní filtr Volterra. Následně jej srovnávají s pokročilou neuronovou sítí se zpětným šířením, která podle nich není vhodná právě pro všechny typy predikcí.

Jednou z metod, které umožňují řešit aktuální přetlak informací a dynamický vývoje je podle Kou et al. (2019) strojové učení. Podle závěrů jejich metanalýzy je mimořádně vhodné zejména pro predikaci a hodnocení rizik především v kombinaci s analýzami big data, síťovými analýzami a analýzami sentimentu.

Právě problém dynamiky a extrémně velkého množství dat řeší podle Zhang, Yan a Aasma (2020) hluboké učení, které je velmi vhodné pro extrakci abstraktních prvků na vysoké úrovni z velkého množství nezpracovaných dat bez spoléhání se na předchozí znalosti, což je potenciálně atraktivní při předpovídání finančních časových řad. Využívají sítě s dlouhodobou krátkodobou pamětí (LSTM) pro které vytvořili novou metodologii predikce hlubokého učení a na její základě toho hybridní predikční model hlubokého učení pro akciové finanční trhy. V tomto modelu doplňují LSTM ještě souborový empirický režim rozkladu (CEEMD), který umožňuje vyhlazování a rozklad sekvencí, fluktuací nebo trendů různých měřítek časových řad a následně generuje řadu funkcí vnitřního režimu (IMF) s různými charakteristikami váhy. Poté do sítí LSTM zavádí abstraktní prvky na vysoké úrovni, aby pro každou komponentu predikovali závěrečnou cenu následujícího obchodního dne. V rámci obchodních simulací na šesti reálných indexech konstatují, že navrhovaný model významně překonává srovnávací modely, pokud jde o prediktivní přesnost, tj. nižší testovací chybu a vyšší směrovou symetrii. Využití metod strojového učení jako efektivnější alternativy k prognózám cen aktiv rozšířením nebo zevšeobecněním možných specifikací modelu ve srovnání s konvenčními metodami lineární regrese není úplnou novinkou. Dle Götze, Gürtlera a Witowskiho (2020) vylepšené metody strojového učení často vedou k lepší kvalitě predikce než tradičně využívané metody. Na druhou stranu při jejich aplikaci na CAT dluhopisy dosáhly lepšího výkonu modely založené na metodě Random Forrest, následované modely lineární regrese a až poté neuronovými sítěmi. Tomuto výsledku však odporuje specifický model Caoa (2020), který konstruuje metodu predikce vývoje cen jiných cenných papírů – akcií. Ten nejprve prostřednictvím analýzy dat hlavních světových finančních indexů stanovuje hlavní komponenty (PCA) pro vytvoření finančního indikátoru. Poté jej spolu s indikátory transakce využívá jako vstupní proměnné v rámci neuronové sítě zpětného šíření (BP). Výsledky podle něj ukazují, že neuronová síť BP založená na Bayesiánském regularizačním algoritmu má nejvyšší přesnost predikce a může se vyhnout nežádoucímu „přetrénování“. V rámci testování navíc tento model srovnává s dalšími prediktivními metodami, ze kterých vychází modely neuronových sítí jako efektivnější, především pro účely zpracování velkých objemů dat, či v situaci silné volatility.

Směšování globálního a lokálního odhadu a kombinace explicitního modelování s čistě datově adaptivním odvozením (tzv. semiparametrické modelování) využívají při implementaci

strojového učení v rámci analýzy pěti typů cenných papírů španělského hodnotově váženého indexu IBEX35 Sarabia et al. (2020), podle nichž je právě využití tohoto přístupu vhodné pro modelování zavádění nových tříd distribučních řad pro finanční data a predikci jejich vývoje.

Na oblast práce s Big data v oblasti výroby se soustředí Yadegaridehkord et al. (2018). Podle nich je, navzdory obchodním příležitostem, které tato technologie nabízí, její přijetí v mnoha průmyslových odvětvích stále v rané fázi. Jejich studie se proto zaměřuje identifikaci a seřazení významných faktorů ovlivňujících přijetí velkých objemů dat a následně na predikci vlivu práce s konceptem výkonnosti výrobních společností pomocí hybridního rozhodovacího modelu DEMATEL a adaptivního neurofuzního odvozovacího systému (ANFIS). DEMATEL, konkrétně tzv. šedou verzi, využívají i Cui et al. (2019), kteří se soustředí na predikci selhání trvale udržitelných projektů. Výstupy této metody zasazují do teorie životního cyklu společnosti a jejím cílem je identifikace rizikových faktorů selhání.

Pozornost odborné veřejnosti si získaly v rámci aktuálního výzkumu i bankrotní modely založené na umělých neuronových sítích. Využíváno je hned několik typů. Jordan Recurrent Neural Networks (JRNN) ke klasifikaci a předpovědi bankrotu společnosti na základě finančních poměrů využívají Hardinata, Warsito a Suparti (2018), kteří s ní dosahují v predikci bankrotu průměrné úspěšnosti 81,3785 %. Ještě lepších výsledků, nicméně s omezeným využitím v rámci klasifikační struktury potom dosahují s bankrotním modelem založeným na neuronových sítích spolu s klasifikační metodou Support Vector Machine Horák, Vrbka a Šuleř (2020). Navazují tak na práci Vrbky, Nicové a Podhorské (2019), která se zabývala analýzou rozsáhlého souboru účetních závěrek 11 604 podniků, které se v České republice zabývaly obchodními aktivitami v roce 2016 prostřednictvím Kohohnenových sítí.

Jednou z hlavních výhod neuronových sítí je schopnost pracovat s velkými datovými sadami. Využívají toho například Huber et al. (2019) pro řešení problematiky optimalizace objemu objednávek v rámci B2C sektoru. Využívají přitom metody řešení založené na datech založené na strojovém učení a kvantilní regrese, které nevyžadují předpoklad distribuce konkrétní poptávky. Ve výsledku potom dosahují prostřednictvím strojového učení výrazně lepších výsledků než původní postupy založené především na extrapolaci trendů.

Strojové učení v počátku především pomáhalo překonat nevýhody tradičních statistických metod. Postupně však přerostlo do neustále masivně rozvíjeného výzkumu. Modely Neural Network (NN) podle Hardinata a Warsito (2018), kteří také potvrzují výsledky Messai a Gallali (2015), v predikci bankrotu fungují s průměrnou úspěšností 81,3785 % a dle Abdou et al. (2017) obecně překonávají statistické modely. Obecně jsou pro predikci úspěchu či bankrotu plně kvalifikované a výrazně překonávají například diskriminační analýzu (Azayite a Achchab,

2016). Aktuálně přitom dochází k řadě aplikací a vzniku nových prediktivních modelů založených například na tréninku autoregresivního modelu recidivující neuronové sítě (Salinas et al., 2020). Na nutnost zohlednění rozdílů ve velikosti podniku, a tedy úprav metod hodnocení prostřednictvím NN poukazují Gulsoy a Kulluk (2018). Ne vždy je prostřednictvím neuronových sítí posuzován celý podnik. Například Wang et al. (2020) využívají hluboké neuronové sítě, k predikci úrovně kvality filmu, a především jeho návštěvnosti z upoutávek, a to včetně dopadů na očekávaný komerční výkon. Algoritmy neuronové sítě zpětného šíření potom používají pro predikci stavu zásob Cao a Wang (2020). Model podpory investičního rozhodování v elektronickém obchodování založený na výpočtu hloubkového učení a posouzení stavu účastníka trhu vytváří Lei (2020).

Využití rekurentních neuronových sítí v této oblasti patří mezi nejnovější a nejefektivnější metody výzkumu. Využití jednotlivých typů rekurentních sítí se však liší. Například Elman NN jsou v oblasti podnikové ekonomie častěji orientovány na využití obnovitelných zdrojů (Li et al., 2019) a optimální využití jejich potenciálu a řízení (Nasruddin et al., 2018), stejně jako je tomu i u rekurzivních NN (Li et al., 2019). Pozoruhodné využití Jordan NN předkládají pro predikci inflace Šestanović a Arnerić (2020), kteří udávají jejich výrazně vyšší výkon při srovnání se sítěmi dopředného šíření. V rámci ekonomie jde však spíše o výjimku, další aplikace se týkají spíše energetiky či zemědělství (Abdipour et al., 2019). Další velmi výjimečně využívanou sítí v ekonomii je Hopfield, či Hopfield Lagrangeova síť (HLN), kterou pro trhy s elektřinou využívají Duong et al. (2019). Rovněž spíše výjimečné je ekonomii použití Echo state network, kterou pro optimalizaci ekonomické efektivity průmyslového podniku používají Wang et al., 2020.

V oblasti ekonomie je z rodiny rekurentních sítí nejprogresivnější využití LSTM (long short term memory). Díky své efektivitě v postihování dynamického chování a vysokému výkonu v oblasti dlouhodobých závislostí je využívána v řadě aplikací (Karevan a Suykens, 2020). Podle Sagheerr a Kotb (2019) je přitom už možné konstatovat, že hluboká architektura rekurentní neuronové sítě (RNN) a její varianta LSTM jsou přesnější než tradiční statistické metody v modelování dat časových řad. Experimentální výsledky LSTM modelu Panga et al. (2020) s vloženou vrstvou prokázaly vysokou úspěšnost predikcí u kompozitního akciového modelu na úrovni 56,9 % a 52,4 % pro jednotlivé akcie. A další výsledky už efektivitu LSTM jednoznačně potvrzují, jako při predikci volatility a časových skoků ve finančních řadách v rámci analýzy 11 globálních akciových trhů (Au Yeung et al., 2020), nebo při odhadu vývoje akciových trhů Dinga a Qina (2020), jejichž model přidruženého LSTM modelu vykázal přesnost predikce přes 95 %. K podobnému výsledku predikce volatility akcií

potom dospěl opět metodou LSTM Liu (2019). Efektivitu LSTM a DNN (dopředných neuronových sítí) potom řeší Zhang a Mahadevan (2020) s tím, že LSTM jsou méně přesné, ale s výrazně delším predikčním horizontem. Ve stejné oblasti prokázali Yang, Wang a Li (2020), že LSTM mají v porovnání s vektorovým modelováním vyšší přesnost, vyšší rychlost odezvy a silnější generalizační schopnost. Pro obnovitelné zdroje porovnávali prediktivní metody založené na standardních neuronových a LSTM Correa-Jullian et al. (2020) s tím, že LSTM modely dosáhly nejnižšího chybového skóre RMSE, nejnižší odchylky a nejnižší relativní chyby. Efektivitu LSTM při srovnáním výkonu LSTM RNN inicializovanými metodami přenosu učení a náhodně inicializovanými opakujícími se neuronových sítí potom prokazují Fong et al. (2020). Jinou variantu nazvanou CTS-LSTM, pro kolektivní předpovídání korelovaných časových řad opět s cílem zvýšit předpovědní výkon modelu představují Wan et al. (2020). Problém heterogenity časových řad řeší zabudováním pojmu podobnosti mezi časovými řadami Bandara, Bergmeir a Smyl (2020). O zlepšení výkonu klasifikace prostřednictvím interakce mezi faktory architektury modelu a dimenzemi charakteristik souboru dat usilují Park, Song a Shin (2020), podle kterých v daných aspektech dominují obousměrné LSTM. S jiným modelem automatické regresivní dlouhé krátkodobé paměti (WAR-LSTM) potom přichází Zhang et al. (2019), kteří ji využívají k extrahování reprezentativních dat z více proměnných. Jiný evoluční model LSTM, zaměřený na přenos sdílených parametrů s cílem zvýšení výkonnosti predikce ve více časových úsecích vytvořili Li et al. (2019).

Oblast výzkumu LSTM je mimořádně rozsáhlá. Díky své efektivitě v postihování dynamického chování a vysokému výkonu v oblasti dlouhodobých závislostí je využívána v řadě aplikací (Karevan a Suykens, 2020). Podle Sagheer a Kotb (2019) je přitom už možné konstatovat, že hluboká architektura rekurentní neuronové sítě (RNN) a její varianta LSTM jsou přesnější než tradiční statistické metody v modelování dat časových řad.

Na druhou stranu ale ne vždy vychází jako nejlepší pro všechny posuzované oblasti. Z porovnání LSTM a hybridního modelu konvoluční neuronové sítě a přístupu MHSA, vychází dle Xiao et al. (2020) pro oblast phishingu o 6,5 % lépe právě MHSA. Stejně tak speciálně konstruovaná síť CSAN překonala prediktivní časoprostorové modely Cony-LSTM ve frekvenční predikci trestné činnosti (Wang et al., 2020). Rovněž z rozsáhlého porovnání metod logických vztahů určených pro fuzzy predikce časových řad vzešly z posouzení technik strojového učení, LSTM a podpůrných vektorových nástrojů dle Panigrahiho a Behera (2020) jako výkonnější poslední jmenované a stejně tak dle Liu et al. (2020) překonal model adaptivní vlnové transformace (AWTM) model LSTM při predikci časově-frekvenčního rozkladu

vícefrekvenčního obchodování na akciových trzích. Na druhou stranu však experimentální výsledky LSTM modelu Panga et al. (2020) s vloženou vrstvou prokázaly vysokou úspěšnost predikcí u kompozitního akciového modelu na úrovni 56,9 % a 52,4 % pro jednotlivé akcie. A další výsledky už efektivitu LSTM jednoznačně potvrzují, jako při predikci volatility a časových skoků ve finančních řadách v rámci analýzy 11 globálních akciových trhů (Au Yeung et al., 2020), nebo při odhadu vývoje akciových trhů Dinga a Qina (2020), jejichž model přidruženého LSTM modelu vykázal přesnost predikce přes 95 %. K podobnému výsledku predikce volatility akcií potom dospěl opět metodou LSTM Liu (2019).

Model LSTM typicky užívají výzkumníci pro tvorbu modelů a řešení problémů například v oblasti zpracování řeči či gest. Kombinací se s deklarovanými vynikajícími výsledky zabývají Adeel, Gogate a Hussain (2020), stejně, jako se úspěšnou klasifikací modelů pracujících s mechanismem pozornosti a vícekanalovými funkcemi (SAMF-BiLSTM) zabývají Li et al. (2020). Velmi vysoké přesnosti 99,44 % potom dosáhly modely filtrace spamu využívající výše jmenované metody Roye, Singha a Banerjeeho (2020).

Mezi další oblasti, které LSTM velmi často využívají, jsou lékařství a energetika. Výzvou je například kombinace obtížné predikce výroby obnovitelných zdrojů a spotřeby, kdy řešením udržení stability sítě může být, dle Wanga et al. (2019) využití LSTM modulu interaktivní paralelní predikce. Opět v oblasti energetiky úspěšně řeší predikci a model optimalizace využití Li-ion baterií Tian et al. (2020), poruchy a anomálie při provozu větrných turbín potom prostřednictvím LSTM řeší Chatterjee a Dethlefs (2020). Na stabilitu a robustnost této metody poukazují v dané oblasti Hong et al. (2019), kteří ji ověřují desetinásobnou křížovou validací a rozsáhlou srovnávací analýzou.

Výhody využití LSTM ve srovnání s tradičními modelovými řešeními se zabývají Yang, Wang a Li (2020). Efektivitu LSTM a DNN potom řeší Zhang a Mahadevan (2020) s tím, že LSTM jsou méně přesné, ale s výrazně delším predikčním horizontem. Ve stejné oblasti prokázali Yang, Wang a Li (2020), že LSTM mají v porovnání s vektorovým modelováním vyšší přesnost, vyšší rychlost odezvy a silnější generalizační schopnost. Pro obnovitelné zdroje porovnávali prediktivní metody založené na standardních neuronových a LSTM Correa-Jullian et al. (2020) s tím, že LSTM modely dosáhly nejnižšího chybového skóre RMSE, nejnižší odchylky a nejnižší relativní chyby. Vynikající schopnost LSTM zachytit časovou závislost časových řad využívá pro predikci spotřeby elektřiny, respektive krátkodobé zatížení sítě Liu (2019). Rovněž pro predikci spotřeby, nicméně plynu, používají Wei et al. (2019) kombinovaný model analýzy singulárního spektra (ISSA) a LSTM. Spotřebu energie prostřednictvím další varianty ISCOA-LSTM na konkrétním příkladu řeší Somu a Ramamritham (2020), podle kterých jde o vysoce

účinný prognostický nástroj. Obecně zvýšení energetické účinnosti kombinací LSTM a bootstrappingu řeší Zhu et al. (2020).

Téměř stoprocentní úspěšnosti dosáhl prediktivní model produkce ropy aplikovaný na skutečnou těžbu v Číně Liu, Liu a Gu (2020). Aplikací vysoce efektivní integrované konvoluční neurální sítě (CNN) s LSTM se pro predikci budoucího energetického mixu Číny zabývají Li, He a Zhang (2020).

Velmi efektivní je dle řady výzkumů využití LSTM pro predikci vývoje cen. Hybridní model založený na waveletové transformaci (WT), skládaném autoencoderu (SAE) a LSTM vykazuje dle Qiao a Yanga (2020) velmi vysokou úspěšnost při predikci cen elektřiny ve Spojených státech. Další hybridní model WT-Adam_LSTM pro vývoj cen elektřiny potvrzený čtyřmi případovými studii představují Chang, Zheng a Chen (2019).

Model LSTM je díky své progresivitě posuzován a rozvíjen řadou autorů. Z posouzení funkční odezvy špiček LSTM a Spiking Neural Network (SNN) vychází dominance druhého z modelů (Xie et al., 2020). End-to-end hlubokou učební strukturu, která integruje tradiční kódovaný kontextový vektor a vektor časové pozornosti pro společné učení časové reprezentace na základě modelu LSTM představují Du et al. (2019). Řešením problému dlouhodobé závislosti v sekvenčních datech kvůli nedostatečné kapacitě paměti v LSTM buňkách se zabývají Wang et al. (2020) formou využití obousměrné opakující se neuronové sítě (ABMRNN). Novou prediktivní metodu kombinující LSTM a RF a její výkonnost ve srovnání s dalšími metodami jako jsou neuronové sítě, vícenásobná regrese, ARIMAX a další představují Punia et al. (2020). Efektivitu Long Short Term Memory při srovnání výkonu LSTM RNN inicializovanými metodami přenosu učení a náhodně inicializovanými opakujícími se neuronovými sítmi potom prokazují Fong et al. (2020). Jinou variantu nazvanou CTS-LSTM, pro kolektivní předpovídání korelovaných časových řad opět s cílem zvýšit předpovědní výkon modelu představují Wan et al. (2020). Problém heterogenity časových řad řeší zabudováním pojmu podobnosti mezi časovými řadami Bandara, Bergmeir a Smyl (2020). O zlepšení výkonu klasifikace prostřednictvím interakce mezi faktory architektury modelu a dimenzemi charakteristik souboru dat usilují Park, Song a Shin (2020), podle kterých v daných aspektech dominují obousměrné LSTM. S jiným modelem automatické regresivní dlouhé krátkodobé paměti (WAR-LSTM) potom přichází Zhang et al. (2019), kteří ji využívají k extrahování reprezentativních dat z více proměnných. Jiný evoluční model LSTM, zaměřený na přenos sdílených parametrů s cílem zvýšení výkonnosti predikce ve více časových úsecích, vytvořili Li et al. (2019). Na zefektivnění řešení složitých vícerozměrných úloh klasifikace časových řad se zaměřili Karim et al. (2019) formou transformace stávajících univariačních klasifikačních

modelů na multivariační. Na aktivační funkce se potom zaměřují Farazad, Masha Yekhi a Hassanpour (2019), podle kterých kvantitativní výsledky prokazují, že nejnižší průměrné chyby je dosaženo pomocí funkce aktivace Elliott a jejích modifikací. Jiný hybridní model založený na exponenciálním vyhlazování v kombinaci pokročilými sítěmi dlouhodobé paměti potom představuje Smyl (2020).

Samostatnou kapitolou výzkumu je využití potenciálu LSTM pro řízení finančních rizik či přímo predikci bankrotu společnosti. I přes jeho využití stále řada autorů pracuje s tradičními modely bankrotních modelů, jako jsou Altman Z-Score, Kralickův Quick Test, IN 99 a IN05 (Schönfeld, Kuděj a Smrčka, 2018), hybridními modely klasifikace a regresních stromů (CART) a multivariačních adaptivních regresních spline (MARS) modelů (Affes a Hentati-Kaffel, 2019), nebo evoluční dynamikou a optimalizací strategie pro určitý druh propojených evolučních her (Fu, Li a Zhao, 2017). V jiném případě používá pro ověření efektivity statistických bankrotních modelů Sant'Anna (2017) metodu Monte Carlo, případně je možné chápat bankrotní model jako multivariantní šedý problém (grey prediction problem) pro jehož řešení užívá Hu (2020) genetické algoritmy.

Otázkou je také ověření metod, kdy z posouzení výkonnosti bankrotních modelů (mimo jiné diskriminační analýzy, logistické regrese a vícevrstvé perceptronové sítě) vychází dle Nyitraie a Virága (2019) jako nejefektivnější rozhodovací strom, případně přímo úspěšnost bankrotních modelů, jež je dle Kuběnký a Myškové (2019) v celkovém srovnání tří metod nižší, než jakou autoři výzkumů uvádějí.

Využití strojového učení není v případě bankrotních modelů novinkou. Zhou a Lai (2017) efektivně využívají pro predikci bankrotu algoritmus AdaBoost kombinovaný s imputačními metodami a přímo přínosy hlubokého učení na podporu rozhodování při řízení finančních rizik oproti tomu zkoumají Kim et al. (2020). Modely LSTM s technologií blockchain potom ke zvýšení finanční efektivity a snížení rizik využívají i Li et al. (2020). Čistou hodnotu aktiv prostřednictvím rekurentních neuronových sítí LSTM a porovnáním výkonu jednovrstvých, vícevrstvých či jednosměrných a obousměrných sítí se zabývají Koudjonou a Rout (2020). Samotné bankrotní modely založené na LSTM jsou však zatím, i přes mimořádný pokrok této metody, a její efektivitu zvláště v dynamicky se vyvíjejících situacích a při nedostatku dat, relativně málo využívané. Výjimku tvoří hluboký model učení pro predikci firemního bankrotu pomocí textových informací představený Mai et al. (2019). Na podkladu komplexní databáze bankrotů 11 827 amerických firem ukazují, že modely hlubokého učení přinášejí vynikající předpovědní výkon, přičemž zajímavostí je, že jednodušší modely, jako je průměrování, jsou podle nich účinnější než konvoluční neuronové sítě.

Že jde o vysoce funkční model, potvrzuje i studie Vochozky, Vrbky a Šuleře (2020), jejíž závěry jednoznačně potvrzují, že LSTM NN lze efektivně použít jako nástroj pro predikci úspěchu či selhání společnosti, a to včetně menších a středních podniků. Jde o natolik flexibilní metodu, že umožňuje predikovat případné selhání i u firem, ke kterým nemusí mít vždy plnohodnotnou sadu informací, což může být i případě posuzovaných firem, respektive jimi emitovaných cenných papírů.

Přímo pro investiční prostředí vyvíjí prediktivní model založený na hlubokém učení Lei (2020). Používá investiční data související s internetovým a elektronickým obchodem a metodu hodnocení kvality investičního rozhodování a ve výsledku jej převádí do metody hodnocení kvality rozhodování společnosti na základě algoritmu hlubokého učení. Výsledek potom koreluje s reálnými výkony jak indexů, tak i jednotlivých investic. Výsledkem je potom podle něj model, využitelný v řadě investičních rozhodnutí.

Poslední, ale relativně často využívanou oblastí výzkumu hodnocení podniku, je potom práce s komplexním výkaznictvím, orientovaným na trvale udržitelný rozvoj. Takzvané „zelené“ dodavatelské řetězce hodnotí v této oblasti pomocí metod fuzzy ortopairu Wang a Li (2018), komplexní hodnocení dodavatelského řetězce potom řeší Luo et al. (2020). Výzkumníci orientovaní na aplikaci trvalé udržitelnosti využívají mimo jiné posouzení environmentální výkonnosti společnosti (CEP), které označují za komplexní a konzistentní, přičemž velmi časté je využití fuzzy multikriteriálního rozhodování (MCDM), které užívají například Escrig-Olmedo et al. (2017). V této souvislosti je zvlášť vyčleňována oblast CSR, kdy Fatma a Khan (2020) užívají pro hodnocení podniku teorii sociální identity. Obecně výzkumníci v této oblasti hledají metody zhodnocení jejich vlivu. Teorie přesvědčování, atribuční teorie a kvalitativního zkoumání pravosti využívají Schaefer, Terlutter a Diehl (2019).

2 Cíle práce

Jak vyplývá z předchozího textu, existují sofistikované způsoby ocenění dluhopisů. Je však pravdou, že všechny pracují s peněžními toky spojenými s dluhopisy a pracují s diskontní sazbou. Přitom peněžní toky jsou dány již emisními podmínkami dluhopisů. Správná cena dluhopisu tedy následně vychází ze správného určení diskontní sazby pro stanovení čisté současné hodnoty peněžních toků – kuponových plateb a vratky jistiny. V praxi využívají oceňovatelé především analogii s jinými dluhopisy. Ta je však použitelná, pokud jsou dluhopisy veřejně obchodovány, nebo prokazatelně existují dluhopisy, které jsou velmi podobné a oceňovatel má potřebné informace, aby analogie mohl využít. V takovém případě může využít metodiky České národní banky. V opačném případě nikoliv. V případě nedostatku informací, považuje metodika dluhopis za rizikový a vlastně ani neumožňuje stanovit jeho hodnotu.

Předmětem této habilitační práce však bude ocenění dluhopisů, které nejsou veřejně obchodovány, neboť právě pro tyto případy neexistuje ustálený způsob ocenění takových cenných papírů.

Cílem práce je ocenit správně dluhopisy na příkladu konkrétní společnosti. Při ocenění budou využity v případě, kde to bude možné a smysluplné, umělé neuronové sítě. Dílčí cíle práce jsou definovány takto:

1. Provést finanční analýzu podniku. Její součástí bude komplexní metoda hodnocení podniku postavená na neuronových sítích.
2. Provést strategickou analýzu (vybrané metody).
3. Provést analýzu trhu.
4. Stanovit diskontní sazbu pro stanovení časové hodnoty dluhopisů.
5. Ocenit dluhopis k vybranému datu.

3 Výzkumné otázky

S ohledem na provedenou rešerši a cíle práce jsou stanoveny následující výzkumné otázky:

VO1: Nabízí metoda komplexního hodnocení podniku zkonstruovaná na bázi Gated Recurrent NN lepší výsledky než metody konstruované pomocí diskrétní analýzy?

VO2: Je vhodné určit diskontní sazbu pro stanovení časové hodnoty obligací pomocí neuronových sítí?

VO3: Lze objektivně stanovit diskontní sazbu pro stanovení časové hodnoty obligací?

4 Metodika

Metodika bude sledovat odpovědi na jednotlivé výzkumné otázky. Samotné odpovědi následně povedou ke splnění stanoveného hlavního cíle a cílů dílčích.

Aby bylo možné zobecnit výsledky práce, je nutné pracovat s několika dluhopisy. Pro splnění cíle práce byly vybrány následující emise dluhopisů¹:

1. Dluhopis vydaný společností GOS, a.s. Po restrukturalizaci emitenta přešly závazky plynoucí z emise dluhopisu na společnost CHNC, a.s. V práci bude tato emise označována rovněž zkratkou GOS_1. Nominální hodnota jednoho dluhopisu činí 1 CZK.
2. Dluhopis vydaný společností SAF, a.s. (v práci bude označen jako SAF_1). Nominální hodnota jednoho dluhopisu činí 1 CZK.
3. Dluhopis vydaný společností SAF, a.s. (v práci bude označen jako SAF_2). Nominální hodnota jednoho dluhopisu činí 1 CZK.
4. Dluhopis vydaný společností SAF, a.s. (v práci bude označen jako SAF_3). Nominální hodnota jednoho dluhopisu činí 1 CZK.
5. Dluhopis vydaný společností TPH, a.s. Po restrukturalizaci přešly závazky plynoucí z emise dluhopisů částečně na společnost TP, a.s. a částečně na společnost BS, a.s. (v práci bude dluhopis označen jako TPH_1). Nominální hodnota jednoho dluhopisu činí 1 CZK.
6. Dluhopis vydaný společností TPHnet, a.s. Po restrukturalizaci přešly závazky plynoucí z emise dluhopisů na společnost TPnet, a.s., později přejmenované na BS, a.s. (v práci bude dluhopis označen jako TPHnet_1). Nominální hodnota jednoho dluhopisu činí 1 CZK.

Dluhopisy budou oceněny k 30. 9. 2020.

GOS_1

Společnost CHNC, a.s. je provozovatelem hazardních her – zejména kurzových sázek na sportovní příležitosti. V minulosti fúzovala společnost GOS, a.s., a tím na ni přešly povinnosti plynoucí z emise GOS_1. Bližší podmínky emise jsou v Tabulce č. 1.

¹ Názvy společností budou pro tuto práci pozměněny s ohledem na obchodní zájmy emitentů dluhopisů.

Tabulka 1 Emisní podmínky dluhopisů GOS_1

Název dluhopisů	Dluhopis GOS_1
Druh dluhopisů	Zaknihovaný
Původní emitent	GOS, a.s.
Datum emise	19. prosince 2012
Splatnost	19. prosince 2032
Hodnota jednoho dluhopisu	1 CZK
Celková výše emise	500 000 000 CZK
Pevný úrokový výnos	12 % p.a.
Forma dluhopisů	Na doručitele
Vyplácení úroků	Čtvrtletně zpětně, vždy k 19. dni 3. měsíce příslušného kalendářního čtvrtletí
Úroková konvence	BCK Standard 30E/360

Zdroj: Vlastní.

Celkový úrok v nominální hodnotě činí 1,2 mld. CZK. K 31. 8. 2020 bylo vyplaceno na úrocích 450 mil. CZK. Zbývá tedy do doby splatnosti jistiny vyplatit ještě 750 mil. CZK.

Celkový úrok v nominální hodnotě činí 1,2 mld. CZK. K 31. 8. 2020 bylo vyplaceno na úrocích 450 mil. CZK. Zbývá tedy do doby splatnosti jistiny vyplatit ještě 750 mil. CZK.

SAF_1

Společnost SAF, a.s. podniká v oblasti služeb finančního zprostředkování jinde nezařazených. Bližší podmínky emise dluhopisů SAF_1 jsou uvedeny v Tabulce č. 2.

Tabulka 2 Emisní podmínky dluhopisů SAF_1

Název dluhopisů	Dluhopis SAF_1
Druh dluhopisů	listinný
Původní emitent	SAF, a.s.
Datum emise	1. září 2019
Splatnost	1. září 2039
Hodnota jednoho dluhopisu	1 CZK
Celková výše emise	200 000 000 CZK
Pevný úrokový výnos	11 % p.a.
Forma dluhopisů	Na řad
Vyplácení výnosů	Čtvrtletně zpětně, vždy k 19. dni 3. měsíce příslušného kalendářního čtvrtletí (vyjímaje kalendářního čtvrtletí při emisi)

Zdroj: Vlastní.

Celkový úrok v nominální hodnotě činí 440 mil. CZK. K 31. 8. 2020 bylo vyplaceno na úrocích 17,6 mil. CZK. Zbývá tedy do doby splatnosti jistiny vyplatit ještě 422,4 mil. CZK.

SAF_2

Společnost SAF, a.s. podniká v oblasti služeb finančního zprostředkování jinde nezařazených. Bližší podmínky emise dluhopisů SAF_2 jsou uvedeny v Tabulce č. 3.

Tabulka 3 Emisní podmínky dluhopisů SAF_2

Název dluhopisu	Dluhopis SAF_2
Druh dluhopisu	Zaknihovaný
Původní emitent	SAF, a.s.
Datum emise	19. 12. 2012
Splatnost	19. 12. 2032
Hodnota jednoho dluhopisu	1 CZK
Celková výše emise	1 000 000 000 CZK
Pevný úrokový výnos	11 % p.a.
Forma dluhopisů	na majitele
Vyplácení výnosů	Čtvrtletně zpětně, vždy k 19. dni 3. měsíce příslušného kalendářního čtvrtletí

Zdroj: Vlastní.

Celkový úrok v nominální hodnotě činí 2,2 mld. CZK. K 31. 8. 2020 bylo vyplaceno na úrocích 825 mil. CZK. Zbývá tedy do doby splatnosti jistiny vyplatit ještě 1,395 mld. CZK.

SAF_3

Společnost SAF, a.s. podniká v oblasti služeb finančního zprostředkování jinde nezařazených. Bližší podmínky emise dluhopisů SAF_3 jsou uvedeny v Tabulce č. 4.

Tabulka 4 Emisní podmínky dluhopisů SAF_3

Název dluhopisu	Dluhopis SAF_3
Druh dluhopisu	Listinný
Původní emitent	SAF, a.s.
Datum emise	2. 6. 2020
Splatnost	1. 6. 2040
Hodnota jednoho dluhopisu	1 CZK
Celková výše emise	80 000 000 CZK
Pevný úrokový výnos	11 % p.a.
Forma dluhopisů	Na řad
Vyplácení výnosů	Čtvrtletně zpětně, vždy k 19. dni 3. měsíce příslušného kalendářního čtvrtletí (vyjímaje kalendářního čtvrtletí při emisi)

Zdroj: Vlastní.

Celkový úrok v nominální hodnotě činí 176 mil. CZK. K 31. 8. 2020 bylo vyplaceno na úrocích 0 CZK. Zbývá tedy do doby splatnosti jistiny vyplatit ještě 176 mil. CZK.

TPH_1

Dluhopisy TPH_1 byly emitovány společností TPH, a.s. Následně společnost fúzovala se společností TP, a.s. Po této fúzi přešla všechna práva a povinnosti plynoucí z emise stávajících dluhopisů na společnost TP, a.s. a BS, a.s. Bližší podmínky emise dluhopisů TPH_1 jsou uvedeny v Tabulce č. 5.

Tabulka 5 Emisní podmínky dluhopisů TPH_1

Název dluhopisů	dluhopis TPH_1
Druh dluhopisů	Listinný
Původní emitent	TPH, a.s.
Datum emise	20. srpna 2012
Splatnost	20. srpna 2032
Hodnota jednoho dluhopisu	1 CZK
Celková výše emise	1 900 000 000 CZK
Část práv a povinností přecházející na TP, a.s.	1 129 093 061 CZK
Část práv a povinností přecházející na BS, a.s.	770 906 939 CZK
Pevný úrokový výnos	12 % p.a.
Forma dluhopisů	Na jméno
Vyplácení úroků	Měsíčně zpětně, vždy k poslednímu dni příslušného kalendářního měsíce
Úroková konvence	BCK Standard 30E/360

Zdroj: Vlastní.

Celkový úrok v nominální hodnotě činí 4,56 mld. CZK. K 31. 8. 2020 bylo vyplaceno na úrocích 1 830 333 333 CZK. Zbývá tedy do doby splatnosti jistiny vyplatit ještě 2 729 666 667 CZK.

TPHnet_1

Dluhopisy TPHnet_1 byly emitovány společností TPHnet, a.s. Následně společnost fúzovala se společností TPnet, a.s. Po této fúzi přešla všechna práva a povinnosti plynoucí z emise stávajících dluhopisů na společnost TPnet, a.s. Následně změnila společnost TPnet, a.s. svůj obchodní název na BS, a.s. Bližší podmínky emise dluhopisů TPHnet_1 jsou uvedeny v Tabulce č. 6.

Tabulka 6 Emisní podmínky dluhopisů TPH_1

Název dluhopisů	dluhopis TPHnet_1
Druh dluhopisů	Listinný
Původní emitent	TPHnet, a.s.
Datum emise	20. srpna 2012
Splatnost	20. srpna 2032
Hodnota jednoho dluhopisu	1 CZK
Celková výše emise	4 250 000 000 CZK
Pevný úrokový výnos	12 % p.a.
Forma dluhopisů	Na jméno
Vyplácení úroků	Měsíčně zpětně, vždy k poslednímu dni příslušného kalendářního měsíce
Úroková konvence	BCK Standard 30E/360

Zdroj: Vlastní.

Celkový úrok v nominální hodnotě činí 10,2 mld. CZK. K 31. 8. 2020 bylo vyplaceno na úrocích 4 320 000 000 CZK. Zbývá tedy do doby splatnosti jistiny vyplatit ještě 6 480 000 000 CZK.

4.1 Finanční analýza

Zdrojem dat pro finanční analýzu podniku budou především výkazy finanční závěrky emitenta. Konkrétně se bude jednat o rozvahu, výkaz zisků a ztrát, výkaz o peněžních tocích, přílohu účetní závěry a výroční zprávu k 31. 12. 2015, 31. 12. 2016, 31. 12. 2017, 31. 12. 2018, 31. 12. 2019 a k 31. 8. 2020. V případě výkazů k 31. 12. se jedná vždy o auditované výkazy.

Finanční analýza bude zahrnovat analýzu absolutních ukazatelů (horizontální a vertikální analýzu), analýzu poměrových ukazatelů a analýzu pomocí metod komplexního hodnocení podniku. Pro účely této práce budou vytvořeny bankrotní modely pracující s neuronovými sítěmi (též „NN“).

Analýza absolutních ukazatelů

Analýza absolutních ukazatelů bude založena na vybraných ukazatelích o hodnocených společnostech. Přehled vybraných ukazatelů je uveden v Tabulce č. 7.

Tabulka 7 Ukazatele analýzy absolutních ukazatelů finanční analýzy emitentů

Zkratka použitá ve vzorcích	Název položky	Výkaz	Položka ve výkazu
WC	Pracovní kapitál	Rozvaha	(C.I+C.III+C.IV+D.I.2) - (B.III+B.IV.2+B.IV.3+C.I.1)
A	Aktiva celkem	Rozvaha A	A + B + C + D
Z	Zásoby	Rozvaha A	C.I.
POHL	Pohledávky	Rozvaha A	C.III.
KFM	Krátkodobý finanční majetek	Rozvaha A	C.IV.
OA	Oběžná aktiva	Rozvaha A	C
VK	Vlastní kapitál	Rozvaha P	A.
DL	Dluhopisy a směnky	Rozvaha P	B.II.6 a B.II.7
-	Běžné BÚ a fin. výpomoci	Rozvaha P	B.IV.2 a B.IV.3
-	Dlouhodobé BÚ	Rozvaha P	B.IV.1
-	Krátkodobé závazky	Rozvaha P	B.III
ZZ	Zadržený zisk	Rozvaha P	A.III.2+A.IV+A.V
CK	Cizí kapitál	Rozvaha P	B
KCK	Krátkodobý cizí kapitál	Rozvaha P	B.III + B.IV
UZ	Úplatné zdroje	Rozvaha P	A + B.IV. + B.II.6 + B.III.9
-	Tržby za prodané zboží	VZZ	I.
N	Náklady na prodané zboží	VZZ	A.
-	Výkony	VZZ	II.
-	Výkonová spotřeba	VZZ	B.
-	Osobní náklady	VZZ	C.
A	Odpisy	VZZ	E.
UM, i	Nákladové úroky	VZZ	N.
HV, EAT	Hospodářský výsledek za účetní období po zdanění	VZZ	***
V	Výnosy celkem	VZZ	I. + II. + ... + XIII.
N	Náklady celkem	VZZ	A + B + ... + T
EBIT	Zisk před úroky a zdaněním	VZZ	*** + S+ Q + N
T	Tržby	VZZ	I. + II.1.

Zdroj: Vochozka et al. (2020).

Bude provedena analýza absolutních ukazatelů v jejich výši. Dále bude provedena analýza v čase (horizontální analýza dat). Bude hodnocení vývoj vybraných položek výkazů účetní závěrky (dle Tabulky č. 7). Dále bude provedeno relativní srovnání vybraných položek vůči vybraným ukazatelům. V případě rozvahových položek bude jako jmenovatel položena bilanční suma. V případě položek výkazu zisků a ztrát budeme využívat součet tržeb za prodané výkony a za prodané zboží.

Je však nutné upozornit, že sázkové kanceláře a herny účtují velmi specificky o tržbách a přímých nákladech na ně. Sázkové kanceláře a herny účtují na účtu tržby za vlastní výrobky nikoliv o tržbách, ale o rozdílu tržeb a nákladů na sázka (tj. od celkových tržeb, tedy sázek, odečítají vyplacené výhry). Svým způsobem tak účtují v rámci core business o zisku na účtu tržby za vlastní výrobky (výkony).

Analýza poměrových ukazatelů

V rámci analýzy poměrových ukazatelů bude provedena analýza ukazatelů rentability (ziskovosti), aktivity, zadluženosti a likvidity.

Postup výpočtu jednotlivých ukazatelů je uveden v Tabulce číslo 8.

Tabulka 8 Ukazatele analýzy poměrových ukazatelů finanční analýzy emitentů

Ukazatel	Zdrojová data
<i>Ukazatele rentability</i>	
ROA – Rentabilita celk. aktiv	$(VH \text{ před zdaň.} + N.) / \text{aktiva celkem}$
Rentabilita tržeb	$(VH \text{ před zdaň.} + N.) / (I. + II.1.)$
Obrat celk. aktiv	$(I. + II.1.) / \text{aktiva celkem}$
ROCE – Rentabilita kapitálu	$(VH \text{ před zdaň.} + N.) / (A. + B.I. + B.II. + B.IV.1.)$
ROE – Rentabilita vl. kapitálu	$VH \text{ za úč. období} / A.$
Rentabilita tržeb	$VH \text{ za úč. období} / (I. + II.1.)$
Obrat celk. aktiv	$(I. + II.1.) / \text{aktiva celkem}$
Finanční páka	$\text{aktiva celkem} / A.$
Rentabilita z vlastních fin. zdrojů	$(\text{Provozní CF}) / A.$
Rentabilita tržeb	$VH \text{ za úč. období} / (I. + II.1.)$
Mzdová náročnost tržeb I	$C.1. / (I. + II.1.)$
Mzdová náročnost tržeb II (z celkových osobních nákladů)	$C / (I. + II.1.)$
<i>Ukazatele aktivity</i>	
Obrat aktiv	$(I. + II.1.) / \text{aktiva celkem}$
Obrat zásob	$(I. + II.1.) / C.I.$
Doba obratu aktiv	$\text{aktiva celkem} / [(I. + II.1.) / 360]$
Doba obratu zásob	$C.I. / [(I. + II.1.) / 360]$
Doba inkasa pohledávek	$(C.II. + C.III.) / [(I. + II.1.) / 360]$
Doba splatnosti krátk. závazků	$(B.III.) / [(I. + II.1.) / 360]$
<i>Ukazatele zadluženosti</i>	
Equity Ratio	$A. / \text{aktiva celkem}$
Debt Ratio I.	$B. / \text{aktiva celkem}$
Debt Equity Ratio	$B. / A.$
Úrokové krytí I.	$(VH \text{ před zdaň.} + N.) / N.$
Úrokové krytí II.	$(VH \text{ před zdaň.} + N. + E.) / N.$
<i>Ukazatele likvidity</i>	
Pracovní kapitál, Working Capital	$C. - C.II. - (B.III. + B.IV.2. + B.IV.3.)$
Pracovní kapitál na aktiva	$[C. - (B.III. + B.IV.2. + B.IV.3.)] / \text{aktiva celkem}$
Ukazatel kapitalizace	$B. / (A. + B.I. + B.II. + B.IV.1.)$
Celková likvidita	$C. / (B.III. + B.IV.2. + B.IV.3.)$
Běžná likvidita	$(C.III. + C.IV.) / (B.III. + B.IV.2. + B.IV.3.)$
Peněžní likvidita	$C.IV. / (B.III. + B.IV.2. + B.IV.3.)$
Doba splatnosti krátk. závazků	$B.III. / [(I. + II.1.) / 360]$

Zdroj: Vochozka et al. (2020).

Poměrové ukazatele budou prezentovány jednak samostatně, jednak v souvislostech jejich časového vývoje a jednak v souvislostech ostatních poměrových ukazatelů finanční analýzy.

Vybrané metody komplexního hodnocení podniku

Metody komplexního hodnocení podniku můžeme dělit na bonitní (zkoumající potenciál podniku tvořit zisk, tržby a cash flow), bankrotně-bonitní (zkoumající potenciál podniku tvořit

zisk, tržby a cash flow na straně jedné, a k případným obtížím na straně druhé) a metody bankrotní (hodnotí to, zda podnik v případě finanční tísně přežije, či nikoliv). Pro tuto práci budou vybrány tyto metody komplexního hodnocení podniku: Index bonity, IN 95, IN 95, Tafflerův index a metoda komplexního hodnocení podniku (bankrotní model) s využitím NN.

Výpočet Indexu bonity je užíván hlavně ve středoevropských zemích, a to zejména v Německu, Rakousku a Švýcarsku.

Index bonity

Index bonity se vypočítá ze vztahu:

$$IB = 1,5 * \frac{Cash\ flow}{Cizí\ zdroje} + 0,8 * \frac{Aktiva}{Cizí\ zdroje} + 10 * \frac{Zisk}{Aktiva} + 5 * \frac{Zisk}{Výnosy} + 0,3 * \frac{Zásoby}{Výnosy} + 0,1 * \frac{Výnosy}{Aktiva} \quad (1)$$

Index bonity rozděluje podniky na bankrotní a bonitní. Kritickou hodnotou v tomto ohledu je nula (blíže Tabulka č. 9).

Tabulka 9 Hodnocení Indexem bonity

Výsledek	Hodnocení	Podnik
$IB \in (-\infty; -2)$	extrémně špatná ekonomická situace	bankrotní podnik
$IB \in < -2; -1)$	velmi špatná ekonomická situace	bankrotní podnik
$IB \in < -1; 0)$	špatná ekonomická situace	bankrotní podnik
$IB \in < 0; 1)$	problematická ekonomická situace	bonitní podnik
$IB \in < 1; 2)$	dobrá ekonomická situace	bonitní podnik
$IB \in < 2; 3)$	velmi dobrá ekonomická situace	bonitní podnik
$IB \in < 3; \infty)$	extrémně dobrá ekonomická situace	bonitní podnik

Zdroj: Vochozka et al. (2020).

Index IN95

Jedná se o bankrotně-bonitní, tzv. věřitelský, model sestavený manželi Neumaierovými. Je počítán ze vztahu:

$$IN95 = 0,022 * \frac{Aktiva}{Cizí\ zdroje} + 0,11 * \frac{Zisk}{Nákladové\ úroky} + 8,33 * \frac{Zisk}{Aktiva} + 0,52 * \frac{Výnosy}{Aktiva} + 0,1 * \frac{Oběžná\ aktiva}{Kr.\ cizí\ kapitál} - 16,8 * \frac{Závazky\ po\ splatnosti}{Výnosy} \quad (2)$$

Podniky vyhodnocené tímto modelem jako bankrotní se nachází v hodnotách indexu IN95 nižších nebo rovných jedné. Bonitní podniky nabývají hodnot indexu IN95 vyšších nebo rovných dvěma. Mezi hodnotami 1 a 2 se nachází takzvaná šedá zóna. Konkrétní hodnocení nabízí Tabulka č. 10.

Tabulka 10 Hodnocení indexem IN05

Výsledek	Hodnocení
$IN95 \in < 2 ; \infty$	bonitní podnik
$IN95 \in (1 ; 2)$	šedá zóna
$IN95 \in (- \infty ; 1 >$	bankrotní podnik

Zdroj: Vochozka et al. (2020).

IN99

Model IN99 byl vytvořen stejně jako IN99 manželi Neumaierovými. Jedná se o tzv. vlastnický model. Bonitu podniku hodnotí z pohledu jeho schopnosti tvořit hodnotu pro vlastníky, tedy schopnosti podniku plnit jeho základní cíl (tedy zajistit růst hodnoty pro vlastníky). Model je dán vztahem:

$$IN99 = -0,017 * \frac{Aktiva}{Cizí zdroje} + 4,573 * \frac{Zisk}{Aktiva} + 0,481 * \frac{Výnosy}{Aktiva} + 0,015 * \frac{Oběžná aktiva}{Kr. cizí kapitál} \quad (3)$$

Podniky tvořící hodnotu, dosahují indexu IN99 vyššího než 1,59. Naopak, podniky netvořící hodnotu nabývají hodnoty 1,22 a nižší. Hodnotící škále je předmětem Tabulky 11.

Tabulka 11 Hodnocení indexem IN99

Výsledek	Hodnocení
$IN99 \in < 2,070 ; \infty$	podnik tvoří hodnotu
$IN99 \in (1,590 ; 2,070 >$	podnik spíše tvoří hodnotu
$IN99 \in (1,220 ; 1,590 >$	šedá zóna
$IN99 \in (0,684 ; 1,220 >$	podnik spíše netvoří hodnotu
$IN99 \in (- \infty ; 0,684 >$	podnik netvoří hodnotu

Zdroj: Vochozka et al. (2020).

Tafflerův index

Pro tuto práci bude využita modifikovaná varianta Tafflerova indexu vycházející ze vztahu:

$$T2 = 0,53 * \frac{Zisk}{Krátkodobé závazky} + 0,13 * \frac{Oběžná aktiva}{Cizí kapitál} + 0,18 * \frac{Krátkodobé závazky}{Aktiva} + 0,16 * \frac{Tržby}{Aktiva} \quad (4)$$

Jedná se opět o model zkoumající na jedné straně bonitu podniku. Přitom na druhé straně stanovené škály hodnocení stojí případná tendence podniku k bankrotu (tedy vstup do likvidace). Hodnocení výsledků na škále je předmětem Tabulky č. 12.

Tabulka 12 Hodnocení modifikovaným Tafflerovým indexem

Výsledek	Hodnocení
$T2 \in (0,3 ; \infty)$	bonitní podnik
$T2 \in <0,2 ; 0,3 >$	šedá zóna
$T2 \in (-\infty ; 0,2)$	bankrotní podnik

Zdroj: Vochozka et al. (2020).

4.1.1 Metoda komplexního hodnocení podniku na bázi NN

Jak je z literární rešerše práce patrné, NN dosahují při současném stupni poznání vynikající výsledky při řešení řady úloh. Můžeme jmenovat regresní analýzu, klasifikační analýzu, regresní analýzu časových řad, shlukovou analýzu, rozpoznávání obrazu a další. NN pracují stejně, jako pracuje lidský mozek. Vytvoříme umělou neuronovou strukturu, kterou následně učíme konkrétní úloze. Pravdou je, že ji už její fyziologií (strukturou) předurčíme žádané úloze. Konkrétní schopnosti jí však vtiskne až samotný trénink, výuka (pokud neuvažujeme shlukovou analýzu, kterou provádí např. Kohonenovy sítě). Avšak NN bývají mnohdy velmi složité a je takřka nemožné jejich celou strukturu prezentovat. Ve složitých LSTM NN by mohl popis struktury sítě, jednotlivých neuronů, spojů, aktivačních funkcí a bran může zabírat až stovky tisíc stran textu. Je tak možné je prezentovat pouze ve zjednodušené struktuře a nabídnout uživateli samotnou neuronovou strukturu.

4.1.1.1 Data a metody

Je tak patrné, že pro vznik metody komplexního hodnocení podniku je nutné znát vstupní veličiny, které mohou sehrávat význam v konečném hodnocení, zda se jedná o podnik, který přežije, či nepřežije, případnou finanční tíseň. Dále musíme znát, jak si za určité kombinace vstupů vede konkrétní podnik. Tedy umíme přiřadit nezávislou proměnou proměnné závislé. V tomto případě se jedná buď o stav „v likvidaci“ (tedy podnik, který případnou finanční tíseň nepřežije) a podnik „aktivní“ (tj. podnik schopný přežít případnou finanční tíseň). Jedná se tak o úlohu klasifikační, pro níž je vhodná aplikace NN.

Data

Zdroj dat

Zdrojem dat o průmyslových podnicích působících v ČR bude databáze Albertina. Průmyslové

podniky budou pocházet ze sekce „C“ odvětvové klasifikace ekonomických činnosti CZ NACE, konkrétně tedy ze skupin 10–33.

Datový soubor bude obsahovat 5 po sobě jdoucích hospodářských let (v letech 2015–2019). Soubor bude obsahovat, jak podniky schopné přežít případnou finanční tíseň (dále též podniky „aktivní“), tak podniky v likvidaci. Budou k dispozici výkazy účetní závěrky 20 000 podniků (po úpravě bude ponecháno náhodným výběrem 2 500 podniků aktivních a 2 500 podniků v likvidaci). Z dat budou vyřazeny datové řádky (jeden podnik a rok představuje jeden datový řádek) obsahující nesmyslné údaje (např. záporné peníze v pokladně), nebo bude velký objem informací naopak chybět. Po eliminaci bude opět vyrovnán vzájemný poměr podniků aktivních a v likvidaci na jedna ku jedné.

Pro analýzu budou využity vybrané položky výkazů finanční závěrky, konkrétně rozvahy a výkazu zisků a ztrát:

Pro tuto analýzu budou použity pouze některé položky:

- **AKTIVACELK** – jedná se o položku aktiv celkem, která je důsledkem hospodářských operací uskutečněných v minulosti. Jde tedy o budoucí ekonomický prospěch podniku.
- **STALAA** – položka stálá aktiva je dlouhodobá, fixní a neoběžná. Zahrnuje majetkové složky sloužící činnosti podniku dlouhodobě (déle než 1 rok) a postupem času se spotřebovávají.
- **Z** – zásoby reprezentují jeden z výrobních faktorů podniku. V tomto případě se jedná o disponibilní objem daného výrobního faktoru. V rámci položky se objevují především zásoby materiálu, nedokončené výroby, polotovarů a zboží.
- **KP** – krátkodobé pohledávky mají v době vzniku dobu splatnosti kratší než 1 rok a vyjadřují právo věřitele požadovat po druhé straně plnění určitého závazku, uspokojením závazku pak pohledávka zaniká.
- **FM** – krátkodobý finanční majetek tvoří společně se zásobami a krátkodobými pohledávkami oběžný majetek. Jedná se o majetek, který mění svou podstatu nejdéle v časovém horizontu jednoho roku. Peníze, které jsou součástí krátkodobého finančního majetku, jsou některými ekonomy považovány za výrobní faktor. Jiní jej pak považují za formu kapitálu, zásob. Jedná se tak o zvláštní druh statku, s nímž lze zacházet jako s materiálem.
- **VLASTNIJM** – vlastní kapitál představuje vlastní zdroj financování obchodního majetku pro tvorbu kapitálu. Zahrnuje zejména vklady zakladatelů (vlastníků či

společníků) do základního kapitálu podniku a složky, které vznikly během hospodaření podniku.

- CIZIZDROJE – cizí zdroje jsou dluhem podniku, který je musí v určité době splatit. Jsou to závazky podniku vůči jiným subjektům.
- VS – výkonová spotřeba zahrnuje spotřebu výrobních faktorů – tedy především lidské práce (a to jak řídicí, tak výkonné) a materiálu.
- TRZPRCIN – tržby z provozní činnosti reprezentují core business podniku. Jedná se tak o tržby za prodej vlastních výkonů (výrobků a služeb) a tržby za prodané zboží. Tržby z provozní činnosti odrážejí schopnost, či neschopnost podniku nejen přeměnit výrobní faktory na produkty, ale zároveň své produkty umístit na trhu výrobků a služeb. Tržby z provozní činnosti tak dokládají, že je podnik schopen produkovat takové statky, které dokážou uspokojit potřeby a přání spotřebitele.
- OHANIM – odpisy hmotného a nehmotného dlouhodobého majetku odráží spotřebu dalšího výrobního faktoru – tedy dlouhodobého majetku. Ten je charakterizován jedním významným výdajem. Avšak do nákladů běžného roku se promítá jeho spotřeba právě pomocí odpisů. Vlastně se odpisy nejvíce blíží i vyjádření spotřeby dlouhodobé majetku v ekonomické teorii. Ta pracuje s cenou kapitálu (resp. kapitálového statku) v penězích za hodinu používání.
- NU – nákladové úroky představují cenu cizího kapitálu. Jedná se tak o náklad, který neznamena přímo schopnost produkovat statky schopné uspokojovat přání a potřeby jednotlivce. Je však nezbytným nákladem, neboť cizí kapitál pomáhá překonávat kapitálovou nedostatečnost podniku. Je otázkou samozřejmě, jaký přístup má podnik k vlastnímu kapitálu, cizímu kapitálu a jaká je jejich cena. Manažer vždy volí takovou strukturu kapitálu, která znamená co nejnižší cenu celkového kapitálu při přijatelném podnikatelském riziku.
- HOSPVZUO – výsledek hospodaření za účetní období zahrnuje hospodářský výsledek z provozní, finanční a mimořádné činnosti.
- STAV – jedná se o cílový stav klasifikační úlohy, který může nabývat hodnotu „Aktivní“ pro podniky schopné přežít případnou finanční tíseň a „V likvidaci“ označující podniky, které krachují. Jedná se o stav definovaný novým občanským zákoníkem (zákonem č. 89/2021 Sb. ve znění novel) a zákonem o obchodních korporacích (zákonem 90/2021 Sb. ve znění novel).

Absolutní ukazatele charakterizují podnik z několika pohledů. Hodnotí robustnost podniku (aktiva celkem), strukturu majetku podniku (dlouhodobý majetek, oběžný majetek – zásoby, krátkodobé pohledávky, finanční majetek), likviditu podniku (struktura oběžného majetku), strukturu kapitálu podniku (vlastní kapitál, cizí k, cena cizího kapitálu), jeho technologickou úroveň (prostřednictvím výkonové spotřeby), schopnost realizovat svou hlavní činnost, tedy přetvářet výrobní faktory na produkty (tržby z provozní činnosti) a plnit jeden z hlavních cílů své existence (tvořit zisk).

Úprava dat

V souboru byly ponechány podniky splňující všechny následující podmínky:

1. s kladnými aktivy,
2. s kladným dlouhodobým majetkem,
3. s kladným dlouhodobým finančním majetkem,
4. s kladným dlouhodobým nehmotným majetkem,
5. s kladným oběžným majetkem,
6. s kladnými zásobami,
7. s kladnými dlouhodobými pohledávkami,
8. s kladnými krátkodobými pohledávkami,
9. s kladnými pohledávkami z obchodních vztahů,
10. s kladnými pohledávkami k přidruženým společnostem,
11. s kladným základním kapitálem,
12. s kladnými rezervními fondy,
13. s kladnými rezervami,
14. s kladnými penězi,
15. s kladnými tržbami za zboží,
16. s kladným spotřebovaným materiálem,
17. s kladnou výkonovou spotřebou,
18. s kladnými výkony,
19. s kladnými náklady na zboží,
20. s kladnými odpisy,
21. s kladnými tržbami z prodeje dlouhodobého majetku,
22. s kladnými tržbami z prodeje materiálu,
23. s kladnou zůstatkovou cenou prodaného dlouhodobého majetku,
24. s kladnými nákladovými úroky,

25. se mzdovými náklady vyššími než 120 tis. Kč za rok,
 26. s ROA v intervalu (-100 %, +100 %),
 27. s ROE v intervalu (-100 %, +100 %),
 28. s alternativními náklady na vlastní kapitál v intervalu (0 %, +100 %),
 29. s tržbami za zboží a za vlastní výkony v součtu alespoň v částce 120 tis. Kč za rok.

Jak již bylo konstatováno výše, budou ponechány údaje o 2 500 podniků aktivních a 2 500 podniků v likvidaci. Data budou rozdělena do dvou množin dat: trénovací a testovací. Trénovací soubor dat bude sloužit k natrénování neuronové struktury a bude jej z datového souboru tvořit 70 % záznamových řádků. Testovací soubor dat bude využit při validaci výsledku a bude jej tvořit 30 % záznamových řádků. Statistické charakteristiky jednotlivých položek datového souboru v rozdělení na trénovací a testovací soubor jsou předmětem Tabulky č. 13.

Tabulka 13 Statistické charakteristiky datového souboru

Položka	Trénovací				Testovací			
	Minimum	Maximum	Průměr	Směrodatná odchylka	Minimum	Maximum	Průměr	Směrodatná odchylka
Aktiva celkem	0	62924684	62586,95	1079915	0	26514587	661441,2	2601042
Dlouhodobý majetek	0	30832576	27081,73	530134,3	0	7454341	144435,9	612194,2
Zásoby	0	4164875	9064,812	98951,71	0	2294529	47481,95	196064,8
Krátkodobé pohledávky	0	27683668	20666,89	466465,2	0	9957935	266339,8	993220,5
Krátkodobý finanční majetek	0	771943	3427,319	20888,16	0	9957935	180117,2	852441,7
Vlastní jmění	-20871611	53318744	25970,18	963599,5	-742466	8936364	204760,8	860492,3
Cizí zdroje	0	27125364	36127,75	498664,2	0	18190667	446993,4	1737063
Výkonová spotřeba	0	28974087	51220,59	652315,4	0	30102512	650491,4	2639297
Tržby z provozní činnosti	0	35680883	63112,51	803289,7	0	20574727	534953,1	2074899
Odpisy hmotného a nehmotného dlouhodobého majetku	0	1085482	2329,157	26666,95	-194609	602466	8806,854	41405,22
Nákladové úroky	0	196580	373,1098	4974,179	0	275710	1357,669	10520,26
Výsledek hospodaření za účetní období	-5031681	700092	432,742	87411,61	-1496207	957984	9345,103	109640,8

Zdroj: Vlastní.

Metody

V případě bankrotu se jedná o klasifikační úlohu. V tomto případě vstoupí do výpočtu 12 spojitých proměnných. Výstupem bude definice stavu podniku, tedy zda se jedná o podnik „aktivní“ nebo podnik „v likvidaci“. Pro vytvoření bankrotního modelu budou využity tři druhy

NN. Konkrétně to bude vícevrstvá perceptronová NN (s Linear Layer), NN s Gated Recurrent Layer (dále též „GRL“) a NN s LSTM.

Neuronová síť s Linear layer (vícevrstvá perceptronová síť)

Jedná se o základní síť, která využívá základních neuronových buněk – perceptronů. Schéma navrhované NN je předmětem Obrázku č. 1.

Obrázek 1 Schéma vícevrstvé perceptronové sítě (s Linear Layer)



Zdroj: Vlastní.

Ze schématu je patrné, že se NN bude skládat z pěti vrstev, z nichž tři můžeme označit za vrstvu skryté:

1. Vstupní vrstva neuronů: bude se jednat o vektor nezávislých proměnných charakterizovaných v části „Výběr dat“ (tj. aktiva celkem, stálá aktiva, zásoby, krátkodobé pohledávky, krátkodobý finanční majetek, vlastní kapitál, cizí zdroje, výkonová spotřeba, tržby z provozní činnosti, odpisy hmotného a nehmotného dlouhodobého majetku, nákladové úroky, výsledek hospodaření za účetní období).
2. 1. skrytá vrstva neuronů: bude tvořena vrstvou Linear Layer. Výstupem bude vektor mající n členů (pro zjednodušení je na obrázku uveden vektor mající 100 členů). Počet členů na výstupu bude určen experimentem. Vybrána bude ta NN, která bude mít největší výkon. Ten budeme určovat velikostí koeficientu korelace. Velikost vektoru ovlivní predikční schopnost modelu. Příliš malý počet členů může způsobit větší nepřesnost výsledku. Naopak, velký počet členů vektoru může způsobit, že model bude příliš složitý a přetrénovaný a bude vykazovat vynikající parametry natrénované neuronové sítě, avšak odhad budoucího vývoje bude nesmyslný. Počet členů bude stanoven na intervalu od 5 do 6 000. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (5)$$

b. Sinus (Sin):

$$f(x) = \sin x. \quad (6)$$

c. Ramp (někdy se též ReLU):

$$R(x): R \rightarrow R_0^+. \quad (7)$$

d. Logistická funkce (Logistic Sigmoid):


$$f(x) = \frac{1}{1 + e^{-x}}. \quad (8)$$

4. 3. skrytá vrstva neuronů: tuto vrstvu bude opět tvořit Linear Layer. Na jejím vstupu přichází vektor o n členech (v případě schématu na obrázku č. 1 má vektor 100 členů) a odchází vektor, který má dva členy.
5. Poslední vrstva je tvořena dekodérem. Ten určí podle velikosti jednotlivých členů vektoru vycházejícího ze 4. vrstvy (tedy ze 3. skryté vrstvy), zda se bude jedna o podnik „aktivní“ (schopný přežít případnou finanční tíseň) nebo podnik „v likvidaci“ (potenciálně krachující).

Neuronová síť s Gated Recurrent Layer (rekurentní síť)

Předpokládané schéma GRL je předmětem Obrázku 2.

Obrázek 2 Schéma rekurentní sítě (s Gated Recurrent Layer)



Zdroj: Vlastní.

Ze schématu je patrné, že NN bude obsahovat celkem sedm vrstev, z nichž pět můžeme označit za skryté vrstvy:

1. Vstupní vrstva neuronů: bude se jednat o matici $n \times 12$ nezávislých proměnných charakterizovaných v části „Výběr dat“ (tj. aktiva celkem, stálá aktiva, zásoby, krátkodobé pohledávky, krátkodobý finanční majetek, vlastní kapitál, cizí zdroje, výkonová spotřeba, tržby z provozní činnosti, odpisy hmotného a nehmotného dlouhodobého majetku, nákladové úroky, výsledek hospodaření za účetní období).
2. 1. skrytá vrstva neuronů: bude tvořena vrstvou GRL. Výstupem bude matice $n \times m$ (pro zjednodušení je na obrázku uvedeno $n \times 100$ – tedy matice na vstupu $n \times 12$ údajů, matice na výstupu z vrstvy $n \times 100^2$). Počet členů matice na výstupu vrstvy bude určen experimentem. Vybrána bude ta NN, která bude mít největší výkon. Ten budeme určovat velikostí koeficientu korelace. Velikost vektoru ovlivní predikční schopnost modelu. Příliš malý počet členů matice může způsobit větší nepřesnost výsledku. Naopak, velký počet členů matice může způsobit, že model bude příliš složitý a přetrénovaný model, který bude vykazovat vynikající parametry natrénované neuronové sítě, avšak odhad budoucího vývoje bude nesmyslný. Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (9)$$

- b. Sinus (Sin):

$$f(x) = \sin x. \quad (10)$$

- c. Ramp (někdy se též ReLU):

$$R(x): R \rightarrow R_0^+. \quad (11)$$

² Chápejme spíše jako n vektorů majících 100 členů.

d. Logistická funkce (Logistic Sigmoid):


$$f(x) = \frac{1}{1 + e^{-x}}. \quad (12)$$

4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
5. 4. skrytá vrstva: jde o Catenate Layer. Ta spojí vstupy, které do ní přijdou ze druhé a třetí skryté vrstvy. Výstupem je matice 2×100 (při zjednodušení na obrázku č. 2).
6. 5. skrytá vrstva neuronů: tuto vrstvu bude tvořit Linear Layer. Na jejím vstupu přichází matice $2 \times m$, (v případě schématu na obrázku č. 2 má vektor 100 členů) a odchází vektor, který má dva členy.
7. Poslední vrstva je tvořena dekodérem. Ten určí podle velikosti jednotlivých členů vektoru vycházejícího z 5. vrstvy (tedy ze 4. skryté vrstvy), zda se bude jednat o podnik „aktivní“ (schopný přežít případnou finanční tíseň) nebo podnik „v likvidaci“ (potenciálně krachující).

Neuronová síť s Long Short Term Memory Layer (rekurentní síť)

Třetí neuronová struktura bude obsahovat vrstvu LSTM. Schéma této NN je předmětem Obrázku č. 3.

Obrázek 3 Schéma rekurentní sítě (s Long Short Term Memory Layer)



Zdroj: Vlastní.

Bankrotní model bude zpracován pomocí umělé neuronové sítě hlubokého učení s LSTM vrstvou. Výsledná struktura NN bude dána experimentem. Jednotlivé vrstvy se však budou sestávat z těchto součástí:

1. Vstupní vrstva neuronů: bude se jednat o matici $n \times 12$ nezávislých proměnných charakterizovaných v části „Výběr dat“ (tj. aktiva celkem, stálá aktiva, zásoby, krátkodobé pohledávky, krátkodobý finanční majetek, vlastní kapitál, cizí zdroje,

výkonová spotřeba, tržby z provozní činnosti, odpisy hmotného a nehmotného dlouhodobého majetku, nákladové úroky, výsledek hospodaření za účetní období).

2. 1. skrytá vrstva neuronů: bude tvořena vrstvou LSTM. Výstupem bude matice $n \times 100$, kde počet členů matice bude částí experimentu. Velikost matice ovlivní predikční schopnost modelu. Příliš malý počet členů může způsobit větší nepřesnost výsledku. Naopak, velký počet členů matice může způsobit, že model bude příliš složitý a přetrénovaný (vykáže vynikající parametry výkonu u trénovacího souboru dat, avšak v případě testovacího souboru prokáže naprostou neschopnost zatřídit podnik správně. Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (13)$$

- b. Sinus (Sin):

$$f(x) = \sin x. \quad (14)$$

- c. Ramp (někdy se též ReLU):

$$R(x): \mathbb{R} \rightarrow \mathbb{R}_0^+. \quad (15)$$

- d. Logistická funkce (Logistic Sigmoid):

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (16)$$

4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
5. 4. skrytá vrstva: je určena vrstvou Plus. Jejím úkolem bude mezi sebou spojit (sečíst) signál 2. a 3. skryté vrstvy a tento signál poslat dál.

6. 5. skrytá vrstva: bude se jednat opět o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
7. 6. skrytá vrstva neuronů: tuto vrstvu opět tvoří LSTM. Na jejím vstupu přichází matice o $n \times m$ členech (v případě schématu na obrázku č. 3 je matice určena $n \times 100$ členy) a odchází matice 1×2 .
8. Výstupní vrstva: je tvořena dekodérem. Ten určí podle velikosti jednotlivých členů matice 1×2 vycházející ze 7. vrstvy (tedy ze 6. skryté vrstvy), zda se bude jednat o podnik „aktivní“ (schopný přežít případnou finanční tíseň) nebo podnik „v likvidaci“ (potenciálně krachující).

Gated Recurrent Layer

GRL představuje samostatnou NN. Jde o specifický typ rekurentní NN. Ve své podstatě je dalším vývojovým stupněm Basic Recurrent NN. Basic Recurrent NN pracuje s input gate a output gate. GRL přidává ještě reset gate a memory gate. Stav buňky je určen tímto vztahem:

$$s_t = (1 - i_t) * m_t + i_t * s_{t-1}, \quad (17)$$

kde: s_t představuje nový stav proměnné,
 i_t input gate,
 m_t memory gate,
 s_{t-1} původní stav proměnné.

Input gate je pak dána vztahem:

$$i_t = \sigma[W_{ix}x_t + W_{is}s_{t-1} + b_i], \quad (18)$$

kde: σ znamená Logistic Sigmoid,
 W_{ix} vstupní váhu v input gate, matici $n \times k$,
 x_t vstupní proměnnou, matici $n \times k$,
 W_{is} váhu stavu v input gate, matici $n \times n$,
 s_{t-1} předchozí stav,
 b_i bias, vektor velikosti n .

Reset gate vychází ze vztahu:

$$r_t = \sigma[W_{rx}x_t + W_{rs}s_{t-1} + b_r], \quad (19)$$

kde: σ znamená Logistic Sigmoid,

W_{rx} vstupní váhu v reset gate, matici $n \times k$,
 x_t vstupní proměnnou, matici $n \times k$,
 W_{rs} váhu stavu v reset gate, matici $n \times n$,
 s_{t-1} předchozí stav buňky,
 b_r bias, vektor velikosti n .

Memory gate je určena jako:

$$m_t = \text{Tanh}[W_{mx}x_t + r_t * (W_{ms}s_{t-1}) + b_m], \quad (20)$$

kde: W_{mx} představuje vstupní váhu v memory gate, matici $n \times k$,
 W_{ms} váhu stavu v memory gate, matici $n \times n$,
 B_m bias, vektor velikosti n .

Long-Short Term Memory Layer

LSTM je sama o sobě považována za specifický druh rekurentní NN. Považujeme je za další vývojový stupeň rekurentních NN. Skládá se z několika součástí. Lze identifikovat elementwise layer s funkcí Logistic Sigmoid a hyperbolický tangens, linear layer, concatenate layer, copy layer a transfer dat v podobě vektorů.

Základní procesy LSTM jsou definovány v podobě input gate, output gate, forget gate a memory gate. Přitom stav buňky je definován takto:

$$c_t = f_t * c_{t-1} + i_t * m_t, \quad (21)$$

kde: c_t představuje nový stav proměnné,
 f_t forget gate,
 c_{t-1} původní stav proměnné,
 i_t input gate,
 m_t memory gate.

Přitom input gate je definována jako:

$$i_t = \sigma[W_{ix}x_t + W_{is}s_{t-1} + b_i], \quad (22)$$

kde: σ znamená Logistic Sigmoid,
 W_{ix} vstupní váhu v input gate, matici $n \times k$,
 x_t vstupní proměnnou, matici $n \times k$,
 W_{is} váhu stavu v input gate, matici $n \times n$,
 s_{t-1} předchozí stav,

b_i bias, vektor velikosti n .

Stav je dán vztahem:

$$s_t = o_t * \text{Tanh}[c_t], \quad (23)$$

kde: s_t značí stav proměnné,
 o_t output gate,
 Tanh hyperbolický tangens.

Output gate je představován vztahem:

$$o_t = \sigma[W_{ax}x_t + W_{as}s_{t-1} + b_o], \quad (24)$$

kde: W_{ax} představuje vstupní váhu v output gate, matici $n \times k$,
 W_{as} váhu stavu v output gate, matici $n \times n$,
 b_o bias, vektor velikosti n .

Významnou inovací LSTM je určitě forget gate:

$$f_t = \sigma[W_{fx}x_t + W_{fs}s_{t-1} + b_f], \quad (25)$$

kde: W_{fx} určuje vstupní váhu ve forget gate, matice $n \times k$,
 W_{fs} váhu stavu ve forget gate, matice $n \times n$,
 b_f bias, vektor velikosti n .

Z hlavních procesů zbývá ještě determinovat memory gate:

$$m_t = \text{Tanh}[W_{mx}x_t + W_{ms}s_{t-1} + b_m], \quad (26)$$

kde: W_{mx} představuje vstupní váhu v memory gate, matici $n \times k$,
 W_{ms} váhu stavu v memory gate, matici $n \times n$,
 B_m bias, vektor velikosti n .

Elementwise Layer

Jedná se o jednoduchou vrstvu neuronovou vrstvu, která převezme n vstupů z předchozí vrstvy. Do výpočtu vloží nelinearitu a n výstupů předává další vrstvě NN. Jejím úkolem bude vnášet do NN nelinearitu. Ač bude využito pouze hyperbolického tangens (Tanh), sinu (Sin), Ramp (standardně se označuje jako ReLU) a logistické funkce (Logistic Sigmoid), Elementwise Layer umožňuje použít celou řadu jiných funkcí (cos, tan, cotg a další), nebo dokonce umožní použít funkce vlastní. Čtyři využívané jsou považovány dle dostupných zdrojů v šíření signálu

v NN za nejúspěšnější.

Hodnocení úspěšnosti sítí

V rámci zmíněného experimentu vznikne vždy 1 200 neuronových sítí lišících se velikostí vektoru nebo matice vycházející z první skryté vrstvy a aktivační funkcí dalších vrstev NN.

Hodnocení sítí proběhne pomocí:

1. Výkonu jednotlivých sítí v trénovací a testovací množině dat.
2. Konfuzní matice charakterizující správnou klasifikaci podniků mezi „Aktivní“ a firmy a firmy „V likvidaci“. Rovněž konfuzní matice bude sestavena jak pro trénovací, tak pro testovací množinu dat.

Nejlepší NN budou následně popsány z pohledu svých charakteristik blíže.

4.2 Strategická analýza

Strategická analýza je jedním z výchozích bodů oceňování podniku, prostřednictvím něhož lze definovat celkový potenciál oceňovaného podniku. Strategická a finanční analýza jsou zpracovávány s cílem potvrdit nebo vyvrátit princip „going concern“ posuzovaného podniku, jakožto jednoho z předpokladů při následné volbě metody ocenění. Dalším důvodem zpracování strategické a finanční analýzy je posouzení finanční kondice společnosti a prostředí společnosti, ve kterém se nachází k zajištění efektivní reakce na neustále změny v okolí. V případě znaleckého posudku je princip trvalého pokračování podniku důležitý v souvislosti s dostáním podniku svých povinností vůči věřitelům, a tak splácením úroků z emitovaných dluhových cenných papírů.

U podniku rozeznáváme dva výnosové potenciály podniku: vnitřní a vnější. Vnější výnosový potenciál je závislý na podnikatelském prostředí, v němž se daný podnik vyskytuje, nabízených příležitostí a hrozcích rizicích v rámci trhu. Naopak vnitřní výnosový potenciál především zahrnuje, jakou konkurenční výhodou podnik disponuje oproti konkurentům. Jde především o identifikaci zdrojů a kompetencí, ve kterých podnik vyniká, ale zároveň i zaostává.

Kvalitně zpracovaná strategická analýza slouží k nalezení odpovědi na otázky, jaká je budoucí perspektiva podniku z dlouhodobého hlediska (zda se jedná o zdravý podnik, kde lze předpokládat trvalé pokračování podniku – tzv. going concern, slabší podnik nebo dokonce akutně ohrožený podnik), jaký bude vývoj konkurence, podnikových tržeb, vývoj trhu a jaká lze predikovat s podnikem spojená rizika.

Strategická analýza bude provedena zvlášť pro emise dluhopisů SAF_1, SAF_2 a SAF_3 a zvlášť pro emise GOS_1, TPH_1 a TPHnet_1. V prvním případě se bude jednat o strategickou analýzu bankovního sektoru ČR a analýzu odvětví. Ve druhém případě se bude jednat o strategickou analýzu loterijního průmyslu v ČR a analýzu odvětví.

4.3 Analýza trhu

Analýza trhu bude rovněž probíhat pro podnik SAF, a.s. poskytující služby finančního zprostředkování jinde nezařazené a zvlášť pro podniky působící v oblasti heren a kurzového sázení (tedy pro BS, a.s., CHNC, a.s., TP, a.s. a TPnet, a.s.). Bude se jednat především o analýzu konkurence. Budou identifikováni hlavní konkurenti a trend vývoje konkurenčního prostředí.

4.4 Diskontní sazba

Diskontní sazba je jedním ze základních determinantů ceny dluhopisů. Diskontní sazba bude odrážet bezrizikovou úrokovou míru, systematické riziko a prémii za riziko. Bude se jednat o aplikaci modelu CAPM. To je dáno jednak tím, že věřitelé (držitelé dluhopisů) jsou zároveň majiteli emitentů, a jednak tím, že nositelem podnikatelského rizika je především vlastní kapitál. Vlastníci (držitelé kmenových akcií) jsou uspokojeni v likvidaci obvykle jako poslední. Věřitelé jsou uspokojeni z podílu na likvidačním zůstatku před majiteli. Investiční riziko věřitelů je menší nebo rovno investičnímu riziku akcionářů. Proto model CAPM dokáže postihnout maximální výši investičního rizika věřitele. Diskontní sazba tedy zohledňuje bezrizikovou úrokovou míru – tedy zhodnocení investice, které je při vkladu do státních dluhopisů zcela jisté. Avšak platí vztah, že čím vyšší je riziko, tím vyšší musí být výnos investice. Proto se hodnota diskontní sazby zvyšuje o riziko podnikání v dané zemi a na konkrétním trhu.

4.4.1 Spread

V tomto případě se bude jednat o regresní analýzu. Známe vstupní veličiny, které ovlivní vývoj cílové proměnné. Vstupní veličiny, které budou využity, vychází od Damodarana (2020), který svým způsobem kopíruje rating vybraných světových agentur, např. Moody's. Bude stanoveno šest vstupních veličin. Cílovou proměnnou bude spread. V tomto případě spreadem bude součin systematického rizika a premie za riziko. Bezriziková sazba bude stanovena zvlášť a bude se ke spreadu přičítat.

4.4.1.1 Data a metody

Data pro analýzu budou vycházet z prostředí konkrétního trhu. Budou využity informace o podnicích, které působily v období let 2015–2019 na trhu finančních služeb jinde nezařazených a na trhu kurzového sázení a heren. Budeme hledat model, jenž popíše vztah mezi vstupními veličinami a spreadem. Pro tuto úlohu jsou rovněž vhodné NN. Bude se jednat o regresní analýzu, kdy na vstupu bude šest poměrových ukazatelů a na výstupu spread.

Data

Zdrojem dat o firmách působících v odvětví heren a služeb finančního zprostředkování jinde nezařazených působících v ČR bude databáze Albertina. V případě finančních služeb jinde nezařazených se jedná o kód NACE 649900, v případě heren pak 92000.

Výběr dat

Datový soubor bude obsahovat data za 5 po sobě jdoucích hospodářských let (v letech 2015–2019). K dispozici budou výkazy účetní závěrky 127 podniků působících v oblasti služeb finančního zprostředkování jinde nezařazených a 252 podniků pohybujících se na trhu kurzového sázení a heren (tedy všech, které na trhu ve zkoumaném období působily). Z dat budou vyřazeny datové řádky (jeden podnik a rok představuje jeden datový řádek) obsahující nesmyslné údaje (např. záporné peníze v pokladně), nebo bude velký objem informací naopak chybět.

Pro analýzu budou využity vybrané položky výkazů finanční závěrky. Konkrétně budou vypočteny následující ukazatele (blíže Damodaran, 2020):

- EBIT Interest coverage: jedná se úrokové krytí, kdy veličinou, která kryje splátku úroku, je zisk před úrokem a zdaněním. Damodaran předpokládá pro americké společnosti při ratingu AAA (tedy nejlepší známce) hodnotu 12,9 a vyšší.
- EBITDA Interest Coverage: jde opět o úrokové krytí. Veličinou, která kryje nákladové úroky, je zisk před odpisy, úrokem a daní. Damodaran uvádí pro americké společnosti hodnocené AAA hodnotu 18,7 a vyšší.
- Funds/Debt Employed (%): vypočítává podíl fondů ku investovanému kapitálu. Pro společnosti hodnocené AAA Damodaran předpokládá hodnotu 89,7 a vyšší.
- Free Operational CF/Total Debt (%): poměr volný provozní cash flow k celkovému cizímu kapitálu má dle Damodarana pro společnosti AAA vycházet 30,6 a více.

- Operational Income/Sales (%): provozní zisk k tržbám předpokládá Damodaran pro AAA společnosti 30,9 a více.
- Long-Term Debt/Capital (%): jde o poměr dlouhodobého cizího kapitálu a celkového kapitálu. Damodaran pro nejlepší společnosti předpokládá hodnotu 21,4 a nižší.

V podstatě se jedná o regresní analýzu. Výše uvedené jsou nezávislými proměnnými. Za závislou proměnnou budeme uvažovat spread ($r_e - r_f$).

Je nutné si uvědomit, že posuzované dluhopisy nejsou dosud volně obchodovány. Zároveň není k dispozici dostatek informací o hospodaření společností. Je možné využít pouze data z veřejných zdrojů. Nelze je tak ocenit, ani stanovit diskontní sazbu, analogií k podobným dluhopisům. Je pak otázkou, jak takový dluhopis ocenit. Předpokládejme proto, že nositelem podnikatelského rizika je vlastní kapitál. V případě oceňovaných dluhopisů jsou prozatím jejich držitelé vlastníci podniků. Navíc, ze zákona jsou v případě likvidace nejprve uspokojeny nároky věřitelů. Tedy, pokud půjdeme logicky, nejvyšší možná míra rizika je na úrovni alternativních nákladů na vlastní kapitál. Alternativní náklady na vlastní kapitál jsou nejnižší sazbou zhodnocení, kterou by měl při svém vkladu vlastník očekávat. Vzhledem k tomu, že budou v případě likvidace společnosti jeho nároky uspokojeny v řadě až na posledním místě, je tak logické, že držitelé dluhopisů podstupují nižší riziko. Prozatím jsou práva vlastníků a držitelů dluhopisů v rukách stejných osob, jeví se tedy jako nejvhodnější cesta ocenění dluhopisů využití diskontu ve výši alternativních nákladů na vlastní kapitál.

Bezrizikovou výnosovou míru (r_f) budeme určovat samostatně. Odvodíme ji pomocí analýzy časových řad a predikce budoucího vývoje. V případě určení diskontní sazby se jedná o regresní analýzu. Budeme předpokládat, že se do budoucna nebude měnit kapitálová struktura podniku, ani struktura tržeb. Do výpočtu zahrneme šest proměnných, stejně jako u Damodarana (2020). Budeme zkoumat, jaký je vztah mezi šesti proměnnými a spreadem. Spreadem rozumíme součin systematického rizika a prémie za riziko:

$$Spread = \beta * (E(r_m) - r_f), \quad (27)$$

kde: β představuje systematické riziko daného aktiva,
 $E(r_m)$ prémie za riziko, resp. očekávanou výnosovou míru trhu,
 r_f bezrizikovou výnosovou míru.

Diskontní sazba pak bude součtem fixní části (spreadu) a variabilní složky (bezrizikové výnosové míry).

Výstupem bude definice vztahu vstupních šesti proměnných a spreadu. Tedy, na základě vstupních proměnných (EBIT Interest coverage, EBITDA Interest Coverage, Funds/Debt Employed, Free Operational CF/Total Debt (%), Operational Income/Sales (%), Long-Term Debt/Capital (%)) budeme schopni odvodit výsledný spread, k němuž následně připočteme bezrizikovou výnosovou míru.

Úprava dat

V souboru byly ponechány podniky splňující všechny následující podmínky:

1. s kladnými aktivy,
2. s kladným dlouhodobým majetkem,
3. s kladným dlouhodobým finančním majetkem,
4. s kladným dlouhodobým nehmotným majetkem,
5. s kladným oběžným majetkem,
6. s kladnými zásobami,
7. s kladnými dlouhodobými pohledávkami,
8. s kladnými krátkodobými pohledávkami,
9. s kladnými pohledávkami z obchodních vztahů,
10. s kladnými pohledávkami k přidruženým společnostem,
11. s kladným základním kapitálem,
12. s kladnými rezervními fondy,
13. s kladenými rezervami,
14. s kladnými penězi,
15. s kladnými tržbami za zboží,
16. s kladným spotřebovaným materiálem,
17. s kladnou výkonovou spotřebou,
18. s kladnými výkony,
19. s kladnými náklady na zboží,
20. s kladnými odpisy,
21. s kladnými tržbami z prodeje dlouhodobého majetku,
22. s kladnými tržbami z prodeje materiálu,
23. s kladnou zůstatkovou cenou prodaného dlouhodobého majetku,
24. s kladnými nákladovými úroky,
25. se mzdovými náklady vyššími než 120 tis. Kč za rok,
26. s ROA v intervalu (-100 %, +100 %),

27. s ROE v intervalu (-100 %, +100 %),
28. s alternativními náklady na vlastní kapitál v intervalu (0 %, +100 %),
29. s tržbami za zboží a za vlastní výkony v součtu alespoň v částce 120 tis. Kč za rok.

V datovém souboru zůstaly výkazy účetní závěry 116 podniků působících ve službách finančního zprostředkování jinde nezařazené a 209 podniků působících v oblasti heren.

Data budou rozdělena do dvou množin dat: podniky působících ve službách finančního zprostředkování jinde nezařazené a podniky působící v oblasti heren. Statistické charakteristiky jednotlivých obou množin datového souboru jsou uvedeny v Tabulce 14.

Tabulka 14 Statistické charakteristiky datového souboru

Položka	Podniky působící ve službách finančního zprostředkování jinde nezařazené				Podniky působící v oblasti heren			
	Minimum	Maximum	Průměr	Směrodat. odchylka	Minimum	Maximum	Průměr	Směrodat. odchylka
EBIT Interest coverage	-47,43	16949,00	639,29	1649,19	-1185,50	33744,00	791,72	2383,87
EBITDA Interest Coverage	-18,44	17022,00	642,19	1655,62	-1185,50	33837,00	825,62	2419,78
Funds/Debt Employed	-1,58	95247,10	1924,22	10947,99	-1,03	1000,00	5,49	69,31
Free Operational CF/Total Debt (%)	-113,90	140,09	2,39	22,79	-849,20	45,40	-7,10	64,35
Operational Income/Sales (%)	-340,00	560,38	19,93	81,98	-558,98	849,43	5,22	76,74
Long-Term Debt/Capital (%)	-55380,00	1000,00	-687,20	8308,50	-10805,50	1000,00	1,22	944,02
Spread (%)	3,91	65,56	15,32	10,16	-116,23	3656,76	49,02	323,84
Alternativní náklady vlastního kapitálu (%)	1,90	63,55	13,31	10,16	0,21	58,63	13,59	7,50

Zdroj: Vlastní.


Metody

Pro vytvoření regresního modelu budou využity tři druhy NN. Připomeňme, že právě NN dokážou najít závislost i v silně nelineárním prostředí, při chybějících datech atd. Stejně jako v případě konstrukce bankrotního modelu bude využita vícevrstvá perceptronová NN (s Linear Layer), NN s GRL a NN s LSTM. Jejich aplikace v tomto druhu úlohy se však bude svou vnitřní strukturou od metody komplexního hodnocení podniku významně lišit.

Neuronová síť s Linear layer (vícevrstvá perceptronová síť)

Jedná se o základní síť, která využívá základních neuronových buněk – perceptronů. Schéma navrhované NN je předmětem Obrázku č. 4. Zjednodušení schématu spočívá v tom, že je předem definováno, že z první skryté vrstvy odchází vektor mající 100 členů.

Obrázek 4 Schéma vícevrstvé perceptronové sítě (s Linear Layer)



Zdroj: Vlastní.

Ze schématu je patrné, že se NN bude skládat ze sedmi vrstev. NN tedy obsahuje pět skrytých vrstev:

1. Vstupní vrstva neuronů: bude se jednat o vektor nezávislých proměnných charakterizovaných v části „Výběr dat“ (tj. EBIT Interest coverage, EBITDA Interest Coverage, Funds/Debt Employed, Free Operational CF/Total Debt (%), Operational Income/Sales (%), Long-Term Debt/Capital (%)).
2. 1. skrytá vrstva neuronů: bude tvořena vrstvou Linear Layer. Výstupem bude vektor mající n členů (pro zjednodušení je na obrázku uveden vektor mající 100 členů). Počet členů na výstupu bude určen experimentem. Vybrána bude ta NN, která bude mít největší výkon. Výkon budeme určovat velikostí koeficientu korelace. Velikost vektoru ovlivní predikční schopnost modelu. Je však nutné se vyhnout tomu, aby byl model přetrénován. V takovém případě bude vykazovat vynikající parametry natrénované neuronové sítě, avšak jeho aplikace bude vracet nesmyslnou výši spreadu. Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (28)$$

b. Sinus (Sin):

$$f(x) = \sin x. \quad (29)$$

c. Ramp (někdy se též ReLU):

$$R(x): R \rightarrow R_0^+. \quad (30)$$

d. Logistická funkce (Logistic Sigmoid):


$$f(x) = \frac{1}{1 + e^{-x}}. \quad (31)$$

4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
5. 4. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
6. 5. skrytá vrstva neuronů: tuto vrstvu bude opět tvořit Linear Layer. Na jejím vstupu přichází vektor o n členech (v případě schématu na Obrázku č. 4 má vektor 100 členů) a odchází vektor, který má jeden člen.
7. Poslední vrstva je tvořena dekodérem. Vektor 6. vrstvy prezentuje jako výši spreadu odpovídající kombinaci výší jednotlivých vstupních proměnných.

Neuronová síť s Gated Recurrent Layer (rekurentní síť)

Předpokládané schéma GRL je předmětem Obrázku 5. Opět je v modelu využito zjednodušení spočívající v nastavené matici 1×100 vycházející z první skryté vrstvy NN.

Obrázek 5 Schéma rekurentní sítě (s Gated Recurrent Layer)



Zdroj: Vlastní.

Ze schématu je patrné, že NN bude obsahovat celkem osm vrstev, z nichž šest můžeme označit za skryté vrstvy:

1. Vstupní vrstva neuronů: bude se jednat o matici $n \times 7$ nezávislých proměnných charakterizovaných v části „Výběr dat“ (tj. EBIT Interest coverage, EBITDA Interest Coverage, Funds/Debt Employed, Free Operational CF/Total Debt (%), Operational Income/Sales (%), Long-Term Debt/Capital (%)).
2. 1. skrytá vrstva neuronů: bude tvořena vrstvou GRL. Výstupem bude matice $n \times m$ (pro zjednodušení je na obrázku uvedeno $n \times 100$ – tedy matice na vstupu $n \times 7$ údajů, matice na výstupu z vrstvy $n \times 100^3$). Počet členů matice na výstupu vrstvy bude určen experimentem. Vybrána bude ta NN, která bude mít největší výkon. Ten budeme určovat velikostí koeficientu korelace. Velikost matice ovlivní predikční schopnost modelu. Příliš malý počet členů matice může způsobit větší nepřesnost výsledku. Naopak, velký počet členů matice může způsobit, že model bude příliš složitý a přetřénovaný model, který bude vykazovat vynikající parametry natrénované neuronové sítě, avšak odhad budoucího vývoje bude nesmyslný. Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (32)$$

- b. Sinus (Sin):

$$f(x) = \sin x. \quad (33)$$

- c. Ramp (někdy se též ReLU):

$$R(x): R \rightarrow R_0^+. \quad (34)$$

³ Chápejme spíše jako n vektorů majících 100 členů.

d. Logistická funkce (Logistic Sigmoid):


$$f(x) = \frac{1}{1 + e^{-x}}. \quad (35)$$

4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
5. 4. skrytá vrstva: jde o Plus Layer. Ta spojí vstupy, které do ní přijdou ze druhé a třetí skryté vrstvy. Výstupem je opět matice $n \times 100$ (při zjednodušení na obrázku č. 2).
6. 5. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
7. 6. skrytá vrstva neuronů: tuto vrstvu bude tvořit Linear Layer. Na jejím vstupu přichází matice $n \times 100$ (resp. při zjednodušení ve schématu matice 1×100) a odchází vektor, který má jeden člen.
8. Poslední vrstva je tvořena dekodérem. Vektor 6. vrstvy prezentuje jako výši spreadu odpovídající kombinaci výši jednotlivých vstupních proměnných.

Neuronová síť s Long Short Term Memory Layer (rekurentní síť)

Třetí neuronová struktura bude obsahovat vrstvu LSTM. Schéma této NN je předmětem Obrázku č. 6. Rovněž i v tomto případě zjednodušení vyplývá v nastavené matici 1×100 vycházející z první skryté vrstvy NN.

Obrázek 6 Schéma rekurentní sítě (s Long Short Term Memory Layer)



Zdroj: Vlastní.

Bankrotní model bude zpracován pomocí umělé neuronové sítě hlubokého učení s LSTM vrstvou. Výsledná struktura NN bude dána experimentem. Jednotlivé vrstvy se však budou sestávat z těchto součástí:

1. Vstupní vrstva neuronů: bude se jednat o matici $n \times 7$ nezávislých proměnných charakterizovaných v části „Výběr dat“ (tj. EBIT Interest coverage, EBITDA

Interest Coverage, Funds/Debt Employed, Free Operational CF/Total Debt (%), Operational Income/Sales (%), Long-Term Debt/Capital (%)).

2. 1. skrytá vrstva neuronů: bude tvořena vrstvou LSTM. Výstupem bude matice $n \times 100$, kdy počet členů matice bude částí experimentu. Velikost matice ovlivní predikční schopnost modelu. Příliš malý počet členů může způsobit větší nepřesnost výsledku. Naopak, velký počet členů matice může způsobit, že model bude příliš složitý a přetrénovaný (vykáže vynikající parametry výkonu u trénovacího souboru dat, avšak v případě testovacího souboru prokáže naprostou neschopnost zatřídit podnik správně. Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (36)$$

- b. Sinus (Sin):

$$f(x) = \sin x. \quad (37)$$

- c. Ramp (někdy se též ReLU):

$$R(x): \mathbb{R} \rightarrow \mathbb{R}_0^+. \quad (38)$$

- d. Logistická funkce (Logistic Sigmoid):

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (39)$$

4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).

5. 4. skrytá vrstva: bude se jednat opět o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
6. 5. skrytá vrstva neuronů: tuto vrstvu bude tvořit Linear Layer. Na jejím vstupu přichází matice $n \times 100$ (resp. matice 1×100) a odchází vektor, který má jeden člen.
7. Poslední vrstva je tvořena dekodérem. Vektor 6. vrstvy prezentuje jako výši spreadu odpovídající kombinaci výši jednotlivých vstupních proměnných.

Hodnocení úspěšnosti sítí

Trénink NN proběhne pomocí optimalizačního algoritmu ADAM (blíže Kingma a Ba, 2015). V rámci zmíněného experimentu vznikne vždy 1 200 neuronových sítí lišících se velikostí vektoru nebo matice vycházející z první skryté vrstvy a aktivační funkcí dalších vrstev NN. Hodnocení sítí proběhne pomocí výkonu jednotlivých sítí v trénovací množině dat. Výkon bude měřen velikostí Pearsonova korelačního koeficientu.

Nejlepší NN budou následně popsány z pohledu svých charakteristik blíže.

4.4.2 Bezriziková úroková míra

Bezriziková úroková míra sděluje informaci investorovi, že když nepodstoupí (téměř) žádné investiční riziko, měl by požadovat zhodnocení své investice nejméně o bezrizikovou úrokovou míru. Jejím ekvivalentem je úroková míra desetiletých státních dluhopisů.

4.4.2.1 Data a metody

Ve své podstatě se jedná o analýzu časové řady. Je možné využít regresi časové řady. V takovém případě je vstupní proměnou čas a výstupní proměnou pak konkrétní hodnota vyrovnávané časové řady. V posledních měsících, možná letech se stále více využívá pro tento typ úlohy pouhá regrese na základě předchozích údajů. Vykazuje lepší výsledky. A právě tato metoda bude využita pro stanovení vývoje časové řady bezrizikové úrokové míry.

Data

Pro stanovení risk free sazby (tedy bezrizikové úrokové míry) se ustálilo v ČR používání desetiletých státních dluhopisů. Česká republika je z pohledu investora nejlikvidnějším emitentem cenných papírů, a tedy investice do státem vydaných dluhopisů představuje téměř nulové riziko. Kýženým výsledkem bude predikce vývoje časové řady úrokové míry

desetiletých státních dluhopisů do konce roku 2040 (do doby splatnosti posledního z emitovaných dluhopisů). Bude se jednat o měsíční vývoj úrokové míry. Je tak zapotřebí ideálně ucelené časové řady měsíčních údajů o úrokové míře státních dluhopisů. Ty jsou dostupné na webové stránce ČNB dle maastrichtského kritéria (ČNB, 2020). Maastrichtské kritérium vychází z teorie efektivních kapitálových trhů. Jde v podstatě o schopnost promítnout své pochybnosti o udržitelnosti konvergence do rizikových přírážek zakomponovaných do výnosů cenných papírů. Hodnota úrokové míry bude vypočtena na základě časové řady měsíčních údajů počínající 30. 4. 2000 a končící 31. 8. 2020. Vyrovnána bude časová řada čítající 245 údajů. Minimální hodnoty dosahovala úroková míra desetiletých státních dluhopisů 30. 9. 2016, konkrétně 0,25 %. Naopak, nejvyšší hodnotu představoval úrok 7,59 % dne 30. 11. 2000. Průměrná hodnota úrokové míry pak činila ve sledovaném seku časové řady 3,27 %, standardní odchylka 0,018.


Metody

Budeme vyrovnávat časovou řadu čítající měsíčních 245 údajů o roční úrokové míře desetiletých státních dluhopisech. Na základě získaného modelu pak určíme její další vývoj do 31. 12. 2040. Budeme tak predikovat dalších 244 údajů o úrokové míře. Budeme provádět regresi časové řady pomocí NN. Stejně jako při stanovení bankrotního modelu a určení diskontní sazby bude regrese časové řady provedena pomocí stejných druhů NN (při jiné struktuře, která více vyhoví danému typu úlohy). Bude využita vícevrstvá perceptronová NN (s Linear Layer), NN s GRL a NN s LSTM. Jejich aplikace v tomto druhu úlohy se však bude svou vnitřní strukturou od metody komplexního hodnocení podniku významně lišit. Do určité míry se však bude podobat úloze určení diskontní sazby významně lišit. Řada modelů bere jako nezávislou proměnnou při vyrovnávání časových řad samotný čas. V tomto případě by se jednalo o den vyhlášení úrokové sazby. Čas v našem pojetí však není spojitou veličinou, ale textem. Mathematica, MS Excel či TIBCO Statistica proto čas vyjadřují počtem dnů, které uplynuly od 1. 1. 1900. V našem případě však nezávislými proměnnými budou hodnoty cílové proměnné předcházející hodnotě vyrovnávané. Ve své podstatě se tak bude jednat o regresi, kdy vstupní i výstupní proměnnou bude informace o úroku desetiletých státních dluhopisů. Abychom odhalili případné sezonní výkyvy, budeme pracovat s údaji vyhlášenými vždy dvanáct měsíců před hledanou cílovou hodnotou.

Neuronová síť s Linear layer (vícevrstvá perceptronová síť)

Jedná se o základní síť, která využívá základních neuronových buněk – perceptronů. Schéma navrhované NN je předmětem Obrázku č. 7. Zjednodušení schématu spočívá v tom, že je předem definováno, že z první skryté vrstvy odchází vektor mající 100 členů.

Obrázek 7 Schéma vícevrstvé perceptronové sítě (s Linear Layer)



Zdroj: Vlastní.

Ze schématu je patrné, že se NN bude skládat ze sedmi vrstev. NN tedy obsahuje pět skrytých vrstev:

1. Vstupní vrstva neuronů: bude se jednat o vektor nezávislých proměnných, tedy o údaje o úrokové míře desetiletých státních dluhopisů za dvanáct předcházejících měsíců.
2. 1. skrytá vrstva neuronů: bude tvořena vrstvou Linear Layer. Výstupem bude vektor mající n členů (pro zjednodušení je na obrázku uveden vektor mající 100 členů). Počet členů na výstupu bude určen experimentem. Vybrána bude ta NN, která bude mít největší výkon. Výkon budeme určovat velikostí koeficientu korelace, nejmenším součtem reziduí a absolutních reziduí (tedy rozdíly vyrovnané časové řady a vyrovnané časové řady). Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (40)$$

- b. Sinus (Sin):

$$f(x) = \sin x. \quad (41)$$

c. Ramp (někdy se též ReLU):

$$R(x): \mathbb{R} \rightarrow \mathbb{R}_0^+ \quad (42)$$

d. Logistická funkce (Logistic Sigmoid):


$$f(x) = \frac{1}{1 + e^{-x}} \quad (43)$$

4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
5. 4. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
6. 5. skrytá vrstva neuronů: tuto vrstvu bude opět tvořit Linear Layer. Na jejím vstupu přichází vektor o n členech (v případě schématu na Obrázku č. 7 má vektor 100 členů) a odchází vektor, který má jeden člen.
7. Poslední vrstva je tvořena dekodérem. Vektor 6. vrstvy prezentuje predikovanou výši úrokové míry desetiletých státních dluhopisů. Ač je úroková míra roční, je vyhlášována, a tedy i predikována měsíčně.

Neuronová síť s Gated Recurrent Layer (rekurentní síť)

Předpokládané schéma GRL je předmětem Obrázku 8. Opět je v modelu využito zjednodušení spočívající v nastavené matici 12×100 vycházející z první skryté vrstvy NN.

Obrázek 8 Schéma rekurentní sítě (s Gated Recurrent Layer)



Zdroj: Vlastní.

Ze schématu je patrné, že NN bude obsahovat celkem osm vrstev. Šest vrstev bude představovat vrstvy skryté:

1. Vstupní vrstva neuronů: bude se jednat o matici 12 x 1 nezávislých proměnných, tj. údajů o úrokové míře desetiletých státních dluhopisů za dvanáct předcházejících měsíců.
2. 1. skrytá vrstva neuronů: bude tvořena vrstvou GRL. Výstupem bude matice 12 x m (pro zjednodušení je na obrázku uvedeno 12 x 100 – tedy matice na vstupu 12 x 1 údajů, matice na výstupu z vrstvy 12 x 100). Počet členů matice (konkrétně položky m) na výstupu vrstvy bude určen experimentem. Vybrána bude ta NN, která bude mít největší výkon. Ten budeme určovat velikostí koeficientu korelace, nejmenším součtem reziduí a absolutních reziduí (tedy rozdíly vyrovnané časové řady a vyrovnávané časové řady). Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.
3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (44)$$

- b. Sinus (Sin):

$$f(x) = \sin x. \quad (45)$$

- c. Ramp (někdy se též ReLU):

$$R(x): \mathbb{R} \rightarrow \mathbb{R}_0^+. \quad (46)$$

- d. Logistická funkce (Logistic Sigmoid):

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (47)$$


4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).

5. 4. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
6. 5. skrytá vrstva: jde o Times Layer. Ta mezi sebou vynásobí vstupy, které do ní přijdou ze třetí a čtvrté skryté vrstvy. Jak je dáno vazbou mezi čtvrtou a pátou skrytou vrstvou, hodnoty čtvrté skryté vrstvy budou mocněny na druhou. Výstupem je opět matice 12×100 (při zjednodušení na Obrázku č. 8).
7. 6. skrytá vrstva neuronů: tuto vrstvu bude tvořit Linear Layer. Na jejím vstupu přichází matice 12×100 (resp. můžeme uvažovat 12 vektorů majících vždy 100 členů) a odchází vektor, který má jeden člen.
8. Poslední vrstva je tvořena dekodérem. Vektor 6. vrstvy prezentuje predikovanou výši úrokové míry desetiletých státních dluhopisů.

Neuronová síť s Long Short Term Memory Layer (rekurentní síť)

Třetí neuronová struktura bude obsahovat vrstvu LSTM. Schéma této NN je předmětem Obrázku č. 9. Rovněž i v tomto případě zjednodušení vyplývá v nastavené matici 12×100 vycházející z první skryté vrstvy NN.

Obrázek 9 Schéma rekurentní sítě (s Long Short Term Memory Layer)



Zdroj: Vlastní.

Bankrotní model bude zpracován pomocí umělé neuronové sítě hlubokého učení s LSTM vrstvou. Výsledná struktura NN bude dána experimentem. Jednotlivé vrstvy se však budou sestávat z těchto součástí:

1. Vstupní vrstva neuronů: bude se jednat o matici 12×1 nezávislých proměnných, tj. údajů o úrokové míře desetiletých státních dluhopisů za dvanáct předcházejících měsíců.
2. 1. skrytá vrstva neuronů: bude tvořena vrstvou LSTM. Výstupem bude matice 12×100 , kdy počet členů matice (m) bude částí experimentu. Vybrána bude ta NN, která bude mít největší výkon. Ten budeme určovat velikostí koeficientu korelace,

nejmenším součtem reziduí a absolutních reziduí (tedy rozdíly vyrovnané časové řady a vyrovnávané časové řady). Velikost matice ovlivní predikční schopnost modelu. Příliš malý počet členů může způsobit větší nepřesnost výsledku. Naopak, velký počet členů matice může způsobit, že model bude příliš složitý a přetrénovaný (vykáže vynikající parametry výkonu u trénovacího souboru dat, avšak v případě testovacího souboru prokáže naprostou neschopnost zařadit podnik správně. Počet členů bude stanoven na intervalu od 5 do 6 000 členů. Krok bude určen na 5.

3. 2. skrytá vrstva: bude se jednat o Elementwise Layer (jednoduchou síť pracující s perceptrony). Jejím úkolem je vnést do NN určitou míru nelinearity. I v tomto případě nastavíme dílčí experiment. Budeme testovat vhodnost funkcí, které budou přenášet signál z jednoho neuronu na druhý. Funkce bude pro tuto vrstvu vybírána náhodně z následujících možností:

- a. Hyperbolický tangens (Tanh):

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (48)$$

- b. Sinus (Sin):

$$f(x) = \sin x. \quad (49)$$

- c. Ramp (někdy se též ReLU):

$$R(x): R \rightarrow R_0^+. \quad (50)$$

- d. Logistická funkce (Logistic Sigmoid):

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (51)$$

4. 3. skrytá vrstva: bude se jednat o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
5. 4. skrytá vrstva: jde o Plus Layer. Ta spojí vstupy, které do ní přijdou ze druhé a třetí skryté vrstvy. Výstupem je opět matice 12 x 100 (při zjednodušení na obrázku č. 3).

6. 5. skrytá vrstva: bude se jednat opět o Elementwise Layer. Její další nastavení bude odpovídat 2. skryté vrstvě (tj. konkrétní funkce pro šíření signálu bude opět určena náhodně).
7. 6. skrytá vrstva: jde o Times Layer. Ta mezi sebou vynásobí vstupy, které do ní přijdou ze třetí a páté skryté vrstvy. Výstupem je opět matice 12 x 100 (při zjednodušení na obrázku č. 3).
8. 7. skrytá vrstva neuronů: tuto vrstvu bude tvořit Linear Layer. Na jejím vstupu přichází matice 12 x 100 (resp. můžeme uvažovat 12 vektorů majících vždy 100 členů) a odchází vektor, který má jeden člen.
9. Poslední vrstva je tvořena dekodérem. Vektor 6. vrstvy prezentuje predikovanou výši úrokové míry desetiletých státních dluhopisů.

Hodnocení úspěšnosti sítí

Trénink NN proběhne pomocí optimalizačního algoritmu ADAM (blíže Kingma a Ba, 2015). V rámci zmíněného experimentu vznikne vždy 1 200 neuronových sítí lišících se velikostí vektoru nebo matice vycházející z první skryté vrstvy a aktivační funkcí dalších vrstev NN. Hodnocení sítí proběhne pomocí výkonu jednotlivých sítí v trénovací množině dat. Výkon bude měřen velikostí Pearsonova korelačního koeficientu, reziduí a absolutních reziduí. Nejlepší NN budou následně popsány z pohledu svých charakteristik blíže.

4.5 Ocenění dluhopisů

Dluhopis bude oceněn sumou současné hodnoty peněžních toků spojených s dluhopisem. Technicky se bude jednat o současnou hodnotu kuponových plateb a vrácené jistiny. Tedy, bude platit tento vztah:

$$NPV = \sum_{n=1}^m \frac{C_n}{(1+i)^n} \cdots \frac{C_{m-1}}{(1+i)^{m-1}} + \frac{C_m + F_m}{(1+i)^m}, \quad (52)$$

- kde: NPV představuje čistou současnou hodnotu peněžních toků, tedy cenu dluhopisu,
 n počet výplat kuponové platby ode dne ocenění dluhopisu,
 m celkový počet výplat kuponové platby do doby splatnosti dluhopisu,
 i diskontní sazbu,

C kuponovou platbu

F_m splátku dluhu provedenou v den poslední platby kuponu.

Jedná se však o zjednodušený vztah, neboť z metodiky vyplývá, že úrok bude s největší pravděpodobností pro každou kuponovou platbu odlišný. Proto úrok vyjádříme vztahem:

$$i = \sum_{i=1}^n i_1 * \dots * i_n. \quad (53)$$

5 Výsledky

Kapitola výsledky pojednává primárně o výsledcích použitých metod neuronových sítí v případě komplexního hodnocení podniku společně s metodami finanční analýzy, strategické analýzy a analýzy trhu. Součástí je také komentář výsledků neuronových sítí v případě predikce spreadu a bezrizikové úrokové míry u dluhopisů s následným použitím pro stanovení diskontní sazby, která je použita pro konečné ocenění dluhopisů vybraných společností, konkrétně pak pro stanovení ceny emise korunových dluhopisů.

5.1 Metody komplexního hodnocení podniku na bázi NN

Pro komplexní hodnocení podniků jsou v této kapitole využity primárně umělé neuronové sítě. Konkrétně skupiny vícevrstevných perceptronových sítí, sítí s grL vrstvou a sítí s LSTM vrstvou. Výsledkem je konfuční matice, tedy takzvaná matice záměn aktivních a bankrotních podniků.

5.1.1 Metody využívající vícevrstvou perceptronovou NN

Tabulka 15 představuje přehled pěti nejlepších uchovaných vícevrstevných perceptronových sítí. V tabulce je zaneseno ID jednotlivých sítí, název sítí a výkon trénovací a testovací množiny dat. Lze pozorovat, že výkon trénovací množiny dat se pohybuje od 88 procent do 92, což značí vysoký výkon. V případě testovací množiny dat hovoříme o výkonu pohybujícím se mezi 65 až 70 procenty.

Tabulka 15 Přehled uchovaných vícevrstevných perceptronových sítí


ID sítě	Název sítě	Train performance	Test performance
B-NN_LIN1	12-LinearLayer[1905]-Tanh-2-1	0,887168	0,6925
B-NN_LIN2	12-LinearLayer[3490]-Tanh-2-1	0,900166	0,65375
B-NN_LIN3	12-LinearLayer[3470]-Tanh-2-1	0,913164	0,69875
B-NN_LIN4	12-LinearLayer[4810]-Tanh-2-1	0,918971	0,7075
B-NN_LIN5	12-LinearLayer[6035]-Tanh-2-1	0,920907	0,70125

Zdroj: Vlastní.

B-NN_LIN1

Obrázek 10 zobrazuje základní strukturu sítě B-NN_LIN1, která je tvořena třemi vrstvami. První vrstva je lineární, vystřídána druhou vrstvou hyperbolického tangensu a třetí vrstva opět lineární.

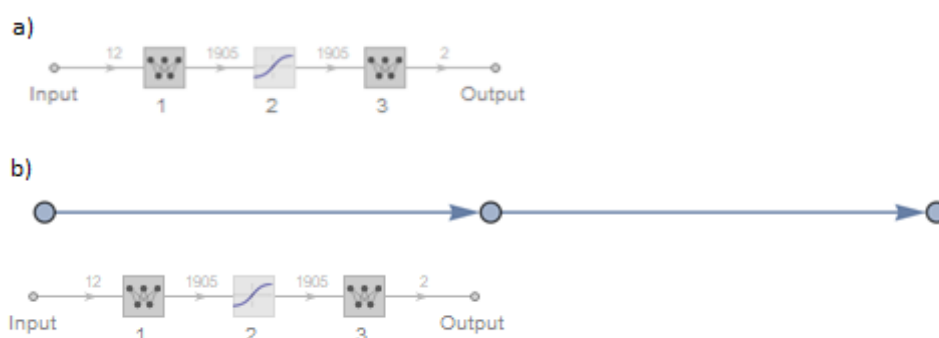
Obrázek 10 Základní struktura sítě B-NN_LIN1



Zdroj: Vlastní.

Základní strukturu sítě v grafické podobě zobrazuje Obrázek 11. Zároveň zobrazuje graf jednotlivých vrstev NN.

Obrázek 11 Základní struktura sítě B-NN_LIN1 – graficky

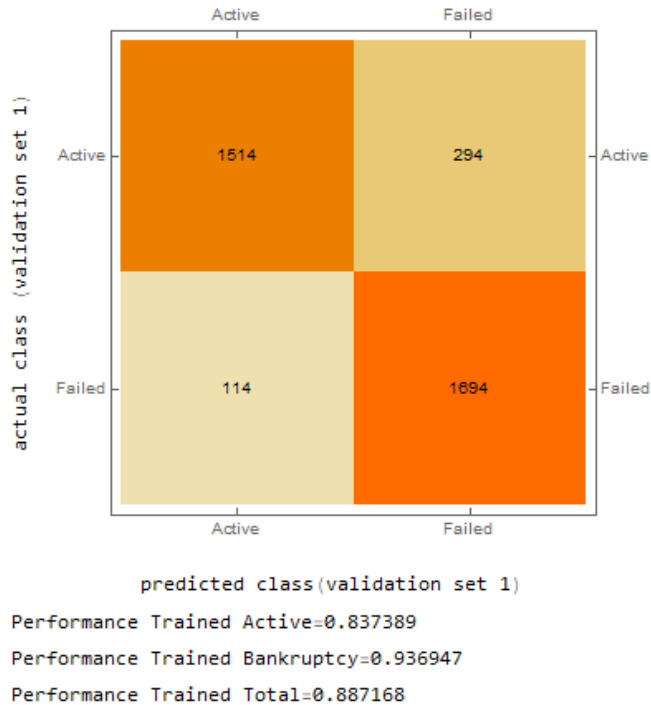


Zdroj: Vlastní.

Na obrázku 12 lze pozorovat konfuzní matici trénovacího souboru. Konfuzní matice, mnohdy také označována jako matice chybová či matice záměn, je kontingenční maticí, kde sloupce prezentují takzvanou skutečnou hodnotu předpovídané třídy a řádky představují předpověď třídy klasifikátorem. Označení „Active“ představuje podniky aktivní a označení „Failed“ pak podniky v likvidaci (v bankrotu). Maticové buňky nesou četnosti toho, kolikrát došlo na zkoumané množině dat k dané kombinaci skutečné a predikované hodnoty. Na diagonále matice záměn jsou uvedeny ty případy, které byly klasifikovány správně. Mimo diagonálu se pak jedná o chyby. Při pohledu na matici z Obrázku 12, kde cílem klasifikátoru bylo rozeznat podniky aktivní a podniky v bankrotu, můžeme určit, že 1 694 podniků bylo správně klasifikováno jako bankrotní podniky a 114 podniků bylo klasifikováno mylně, a byly označeny jako podniky aktivní. Dále došlo k 294 případům, kde klasifikátor chybně zaměnil aktivní podniky za podniky bankrotní. 1 514 podniků bylo správně zařazeno mezi podniky aktivní. Výkon sítě v případě využití trénovací množiny dat je uveden na Obrázku 12, kde výkon

trénovací množiny dat aktivních podniků je po zaokrouhlení roven hodnotě 0,837, v případě bankrotních podniků je výkon roven 0,937 a celkový výkon je roven hodnotě 0,887.


Obrázek 12 Konfuzní matice trénovacího souboru dat – B-NN_LIN1



Zdroj: Vlastní.

Zaměříme-li se na Obrázek 13, a na něm zobrazenou konfuzní matici testovací množiny dat, je zřejmé, že 285 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo ke 115 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 269 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 131 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon sítě v případě využití trénovací množiny dat je uveden na Obrázku 13, kde výkon testovací množiny dat aktivních podniků je po zaokrouhlení roven hodnotě 0,673, v případě bankrotních podniků je výkon roven 0,713 a celkový výkon je roven hodnotě 0,692.

Obrázek 13 Konfuzní matice testovacího souboru dat – B-NN_LIN1




Zdroj: Vlastní.

B-NN_LIN2

Obrázek 14 prezentuje základní strukturu sítě, kde dimenze je rovna 3 490, první vrstva je lineární, druhá vrstva je představena hyperbolickým tangensem a třetí vrstva je opět lineární. Výstupem jsou takzvané třídy.

Obrázek 14 Základní struktura sítě B-NN_LIN2




Zdroj: Vlastní.

U konfuzní matice trénovací množiny dat z Obrázku 15, lze určit, že 1 742 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 66 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 1513 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 295 podniků došlo k záměně aktivních podniků za podniky

bankrotní. Výkon sítě v případě využití trénovací množiny dat je uveden na Obrázku 15, kde výkon trénovací množiny dat aktivních podniků je po zaokrouhlení roven hodnotě 0,837, v případě bankrotních podniků je výkon roven 0,963 a celkový výkon je roven hodnotě 0,9.

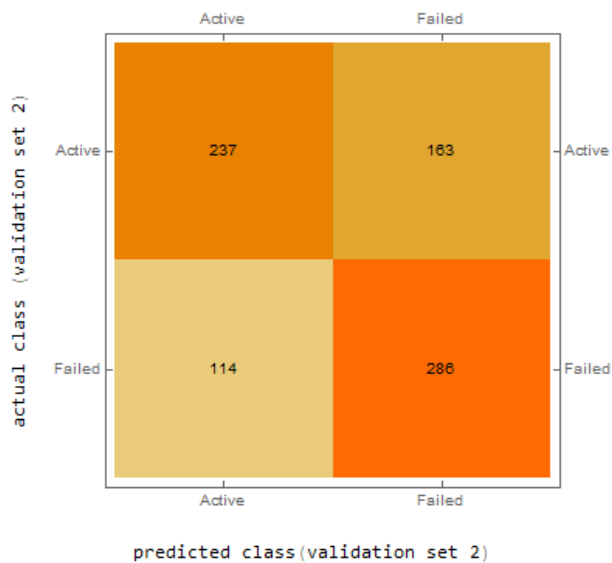
Obrázek 15 Konfuzní matice trénovacího souboru dat – B-NN_LIN2



Zdroj: Vlastní.

Konfuzní matici testovací množiny dat ukazuje Obrázek 16, kde cílem klasifikátoru bylo rozeznat podniky aktivní a podniky v bankrotu. Zde je možné určit, že 286 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 114 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 237 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 163 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon trénovací množiny dat aktivních podniků po zaokrouhlení je roven hodnotě 0,593, v případě bankrotních podniků je výkon roven 0,715 a celkový výkon je roven hodnotě 0,654.

Obrázek 16 Konfuzní matice testovacího souboru dat – B-NN_LIN2




Performance Test Active=0.5925
 Performance Test Bankruptcy=0.715
 Performance Test Total=0.65375

Zdroj: Vlastní.

B-NN_LIN3

Obrázek 17 ukazuje základní strukturu sítě, kde dimenze je rovna 3 470, první vrstva je lineární, druhá vrstva je představena hyperbolickým tangensem a třetí vrstva je opět lineární. Výstupem jsou takzvané třídy.

Obrázek 17 Základní struktura sítě B-NN_LIN3




Zdroj: Vlastní.

Z konfuzní matice trénovací množiny dat na Obrázku 18 lze určit, že 1 734 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 74 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 1 568 podniků bylo správně zařazeno mezi podniky aktivní, avšak 240 podniků bylo chybně klasifikováno jako podniky bankrotní,

i přes skutečnost, že podniky jsou aktivní. Výkon sítě v případě trénovacího souboru dat je uveden na Obrázku 18, kde výkon trénovací množiny dat aktivních podniků je roven hodnotě 0,867, v případě bankrotních podniků je výkon roven 0,959 a celkový výkon je roven hodnotě 0,913.


Obrázek 18 Konfuzní matice trénovacího souboru dat – B-NN_LIN3



Zdroj: Vlastní.

U konfuzní matice testovacího souboru dat z Obrázku 19 vyplývá, že 286 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 114 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 273 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 127 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon testovací množiny dat aktivních podniků je roven hodnotě 0,683, v případě bankrotních podniků je výkon roven 0,715 a celkový výkon je roven hodnotě 0,699.

Obrázek 19 Konfuzní matice testovacího souboru dat – B-NN_LIN3




Zdroj: Vlastní.

B-NN_LIN4

Obrázek 20 prezentuje základní strukturu sítě pod označením, kde dimenze je rovna 4 810. Síť má tři vrstvy a výstupem jsou takzvané třídy.

Obrázek 20 Základní struktura sítě B-NN_LIN4

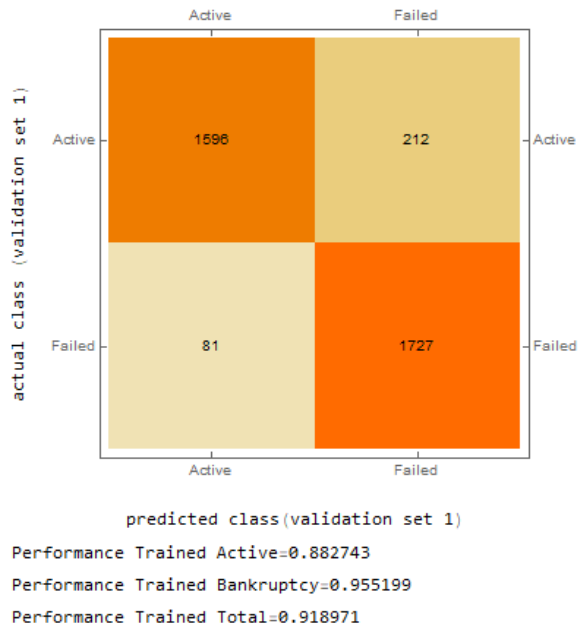


Zdroj: Vlastní.

Při pohledu na matici na Obrázku 21, kde cílem klasifikátoru bylo rozeznat podniky aktivní a podniky v bankrotu, lze stanovit, že 1 727 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 81 případům, kde klasifikátor prohodil bankrotní podniky za podniky aktivní. 1 596 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 212 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon trénovací množiny dat aktivních

podniků je roven hodnotě 0,883, v případě bankrotních podniků je výkon roven 0,955 a celkový výkon je roven hodnotě 0,919.


Obrázek 21 Konfuzní matice trénovacího souboru dat – B-NN_LIN4



Zdroj: Vlastní.

Konfuzní matice testovací množiny dat z Obrázku 22 říká, že 288 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 112 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 278 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 288 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon testovací množiny dat aktivních podniků je roven hodnotě 0,695, v případě bankrotních podniků je výkon roven 0,72 a celkový výkon je roven hodnotě 0,708 po zaokrouhlení.

Obrázek 22 Konfuzní matice testovacího souboru dat – B-NN_LIN4




Zdroj: Vlastní.

B-NN_LIN5

Obrázek 23 ukazuje základní strukturu neuronové sítě, kde výstupem jsou takzvané třídy.

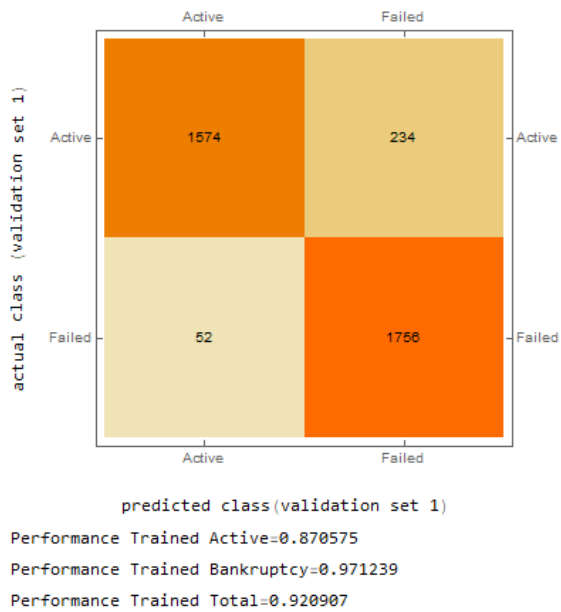
Obrázek 23 Základní struktura sítě B-NN_LIN5



Zdroj: Vlastní.

Při pohledu na matici z Obrázku 24, kde cílem klasifikátoru bylo rozeznat podniky aktivní a podniky v bankrotu, je možné určit, že 1 756 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 52 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 1 574 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 47 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkony sítě v případě aktivních podniků a bankrotních podniků a zároveň celkový výkon sítě jsou zaneseny pod maticí na Obrázku 24.


Obrázek 24 Konfuzní matice trénovacího souboru dat – B-NN_LIN5



Zdroj: Vlastní.

Konfuzní matice testovací množiny dat vypovídá o tom, že 295 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 105 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 266 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 134 podniků došlo k záměně aktivních podniků za podniky bankrotní (viz Obrázek 25).

Obrázek 25 Konfuzní matice testovacího souboru dat – B-NN_LIN5



Zdroj: Vlastní.

5.1.2 Metody využívající NN s GRL vrstvou

Tabulka 16 představuje přehled pěti nejlepších uchovaných vícevrstevných perceptronových sítí. V tabulce je zaneseno ID jednotlivých sítí, název sítí a výkon trénovací a testovací množiny dat. Lze pozorovat, že výkon trénovací množiny dat se pohybuje od 77 procent do necelých 79 procent, což značí vcelku uspokojivý výkon. V případě testovací množiny dat hovoříme o výkonu pohybujícím se mezi 68 až necelými 74 procenty.

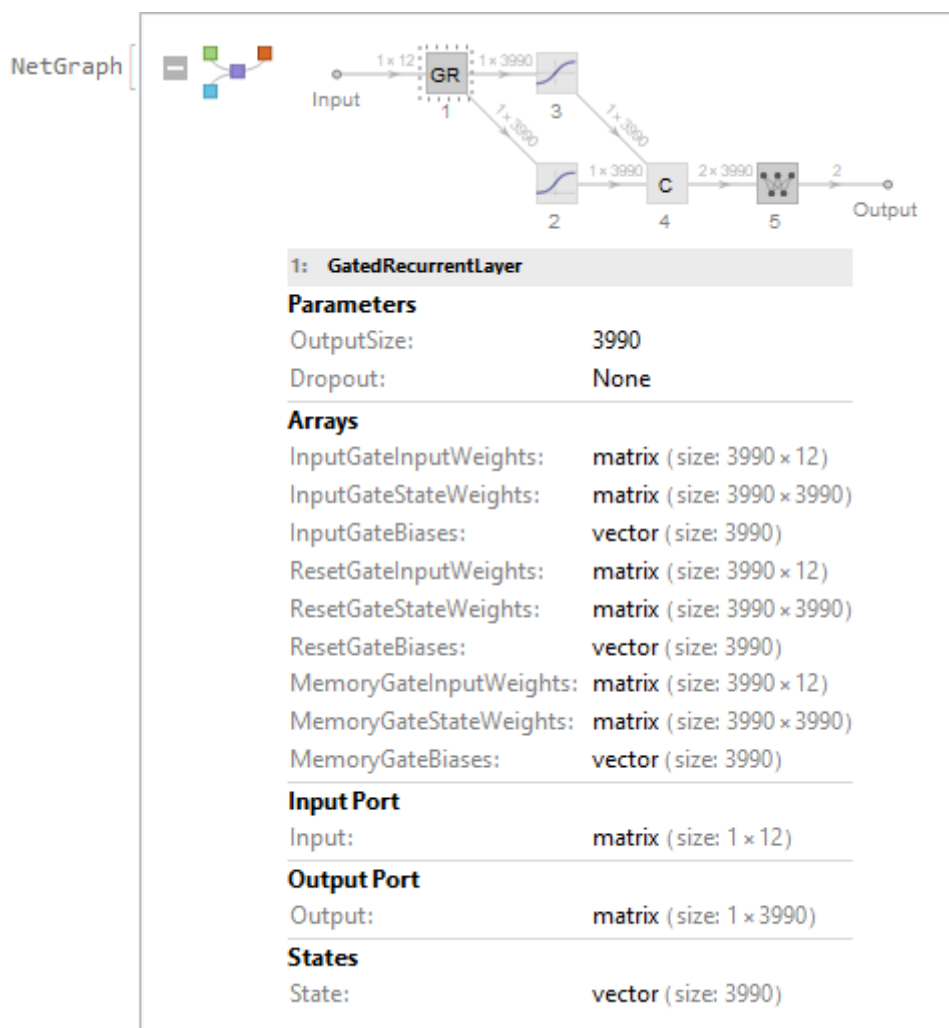
Tabulka 16 Přehled uchovaných NN s GRL vrstvou

ID sítě	Název sítě	Train performance	Test performance
B-NN_GRL1	12-GatedRecurrentLayer[3990]-LogisticSigmoid-Tanh-2-1	0,776272	0,6875
B-NN_GRL2	12-GatedRecurrentLayer[4705]-Sin LogisticSigmoid-2-1	0,776549	0,71375
B-NN_GRL3	12-GatedRecurrentLayer[3390]-Tanh-LogisticSigmoid-1	0,779038	0,7375
B-NN_GRL4	12-GatedRecurrentLayer[4985]-Tanh-Ramp-2-1	0,783186	0,71125
B-NN_GRL5	12-GatedRecurrentLayer[3640]-LogisticSigmoid-Tanh-2-1	0,787334	0,72125

B-NN_GRL1

Základní struktura sítě B-NN_GRL1 je zobrazena na Obrázku 26. Výstupní dimenze je rovna 3 990, funkci zde představuje logistický Sigmoid a hyperbolický tangens a výstupem jsou takzvané třídy.

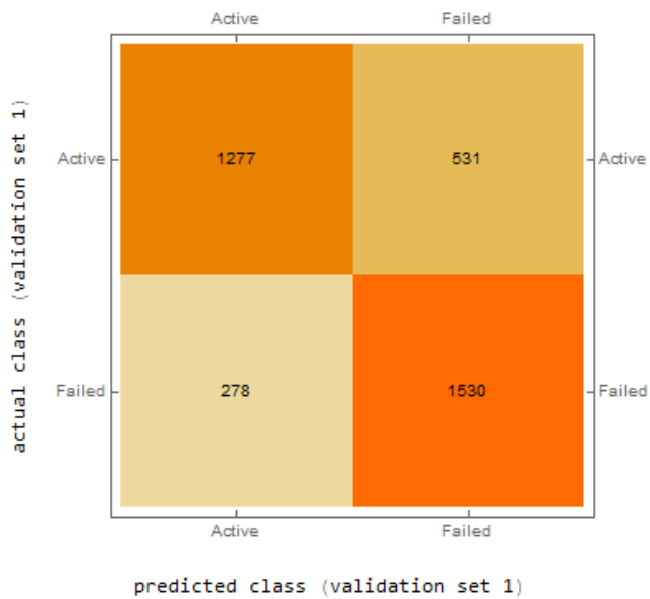
Obrázek 26 Základní struktura sítě B-NN_GRL1



Zdroj: Vlastní.

I v případě GRL NN je výsledkem konfuzní matice, kterou lze pozorovat na Obrázku 27, a matice říká, že 1 530 podniků bylo správně klasifikováno jako podniky bankrotní, 278 podniků bylo zařazeno jako podniky bankrotní i přes skutečnost, že jde o podniky aktivní. Celkem 1 277 podniků bylo správně klasifikováno jako podniky aktivní a 531 podniků bylo chybně označeno za podniky v likvidaci, avšak jednalo se o podniky aktivní. Výkon sítě v případě aktivních a bankrotních podniků, a taktéž celý výkon sítě, je uveden pod maticí na Obrázku 27.

Obrázek 27 Konfuzní matice trénovacího souboru dat – B-NN_GRL1

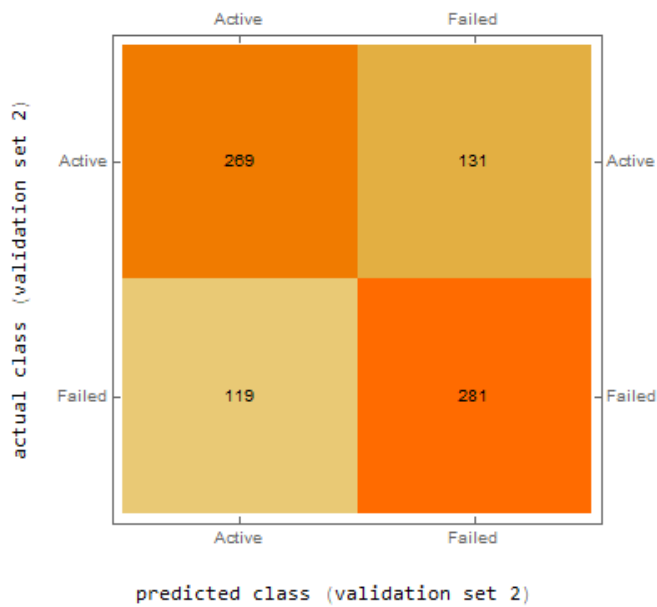


Performance Trained Active=0.706305
Performance Trained Bankruptcy=0.846239
Performance Trained Total=0.776272

Zdroj: Vlastní.

Při zaměření se na konfuzní matici testovacího souboru dat z Obrázku 28 je patrné, že 281 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 119 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 269 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 131 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon sítě v případě aktivních a bankrotních podniků, a taktéž celý výkon sítě, je uveden pod maticí na Obrázku 28.

Obrázek 28 Konfuzní matice testovacího souboru dat – B-NN_GRL1



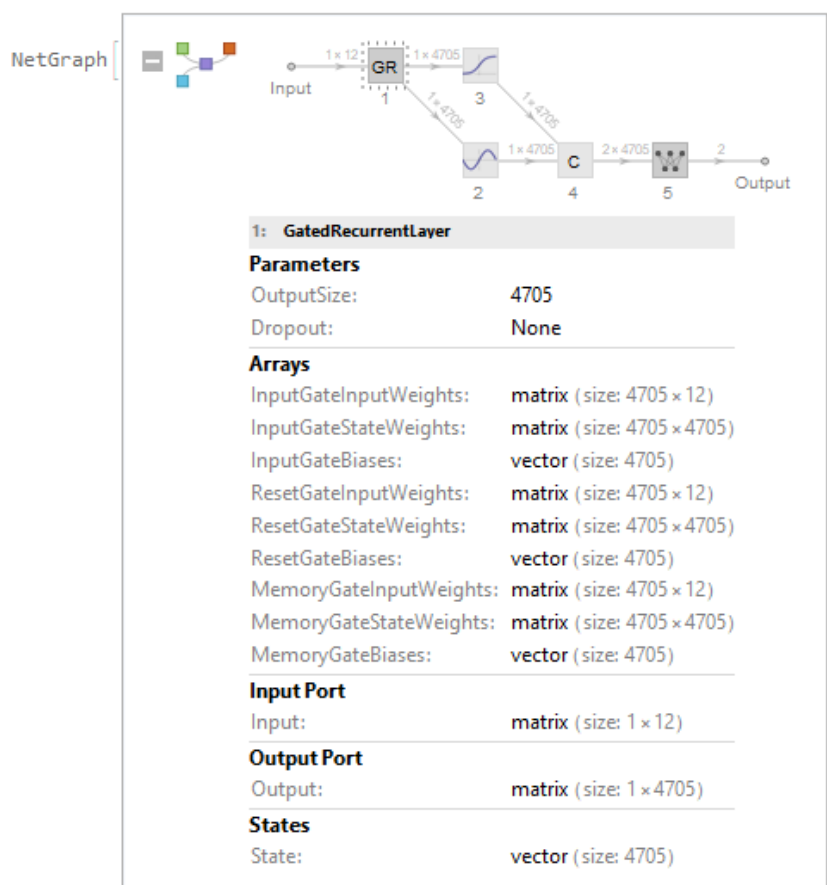
Performance Test Active=0.6725
Performance Test Bankruptcy=0.7025
Performance Test Total=0.6875

Zdroj: Vlastní.

B-NN_GRL2

Základní struktura sítě B-NN_GRL2 je zobrazena na Obrázku 29. Výstupní dimenze je rovna 4 705, funkci zde představuje sinus a logistický tangens a výstupem jsou takzvané třídy.

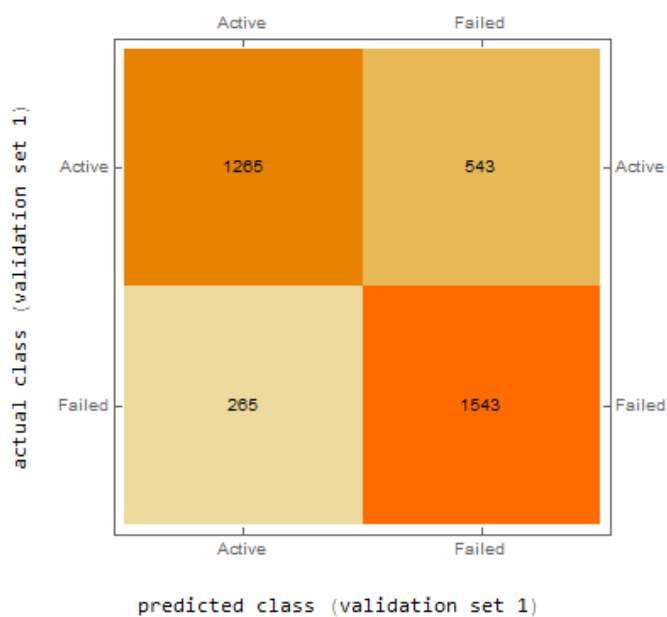
Obrázek 29 Základní struktura sítě B-NN_GRL2



Zdroj: Vlastní.

U konfuzní matice trénovacího souboru dat z Obrázku 30 lze určit, že 1 543 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 265 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 1 265 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 543 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon trénovací množiny dat u aktivních podniků je po zaokrouhlení roven hodnotě 0,7, v případě bankrotních podniků je výkon roven 0,853 a celkový výkon je roven hodnotě 0,777.

Obrázek 30 Konfuzní matice trénovacího souboru dat – B-NN_GRL2




Performance Trained Active=0.699668
Performance Trained Bankruptcy=0.853429
Performance Trained Total=0.776549

Zdroj: Vlastní.

Při zaměření se na konfuzní matici testovací množiny dat z Obrázku 31 je patrné, že 288 podniků bylo správně klasifikováno jako bankrotní podniky. U 112 případů klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 283 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 117 podniků došlo k záměně aktivních podniků za podniky bankrotní.

Obrázek 31 Konfuzní matice testovacího souboru dat – B-NN_GRL2



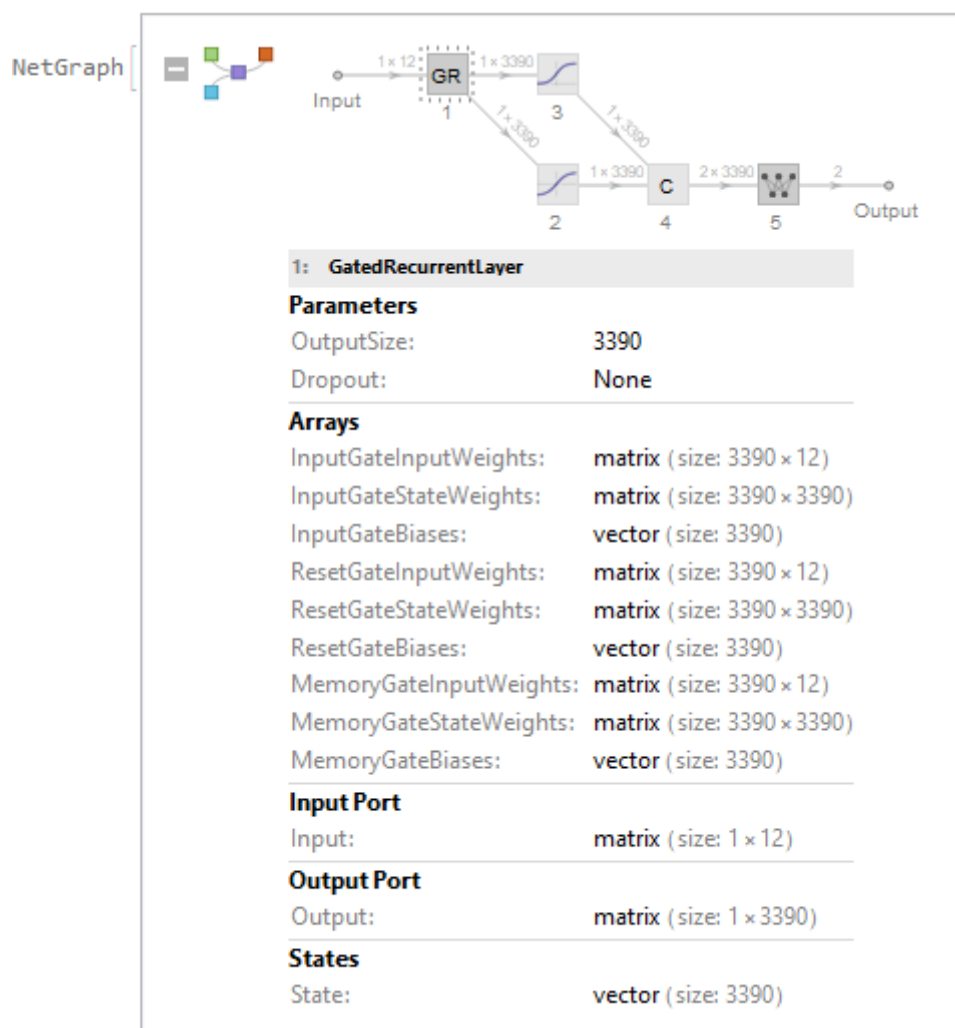
Performance Test Active=0.7075
Performance Test Bankruptcy=0.72
Performance Test Total=0.71375

Zdroj: Vlastní.

B-NN_GRL3

Základní struktura sítě B-NN_GRL3 je zobrazena na Obrázku 32. Výstupní dimenze je rovna 3 990, funkci zde představuje logistický Sigmoid a hyperbolický tangens a výstupem jsou takzvané třídy.

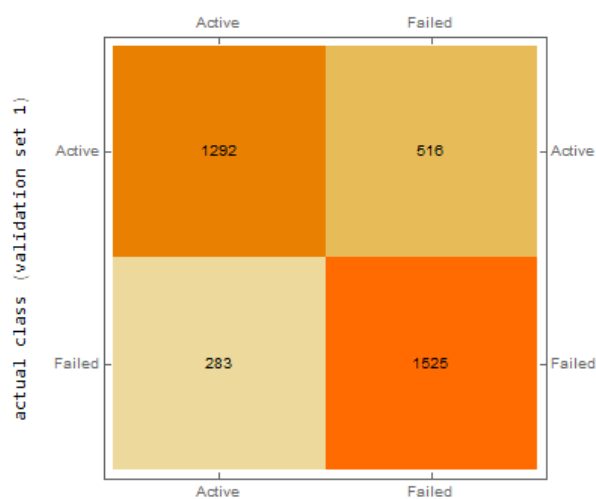
Obrázek 32 Základní struktura sítě B-NN_GRL3



Zdroj: Vlastní.

Z konfuzní matice zobrazené na Obrázku 33 je možno vidět, že 1 525 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo ke 283 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 1 292 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 516 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon v případě využití trénovací množiny dat u aktivních podniků je roven po zaokrouhlení hodnotě 0,715, v případě bankrotních podniků je výkon roven 0,843 a celkový výkon je roven hodnotě 0,779.

Obrázek 33 Konfuzní matice trénovacího souboru dat – B-NN_GRL3



predicted class (validation set 1)

Performance Trained Active=0.714602

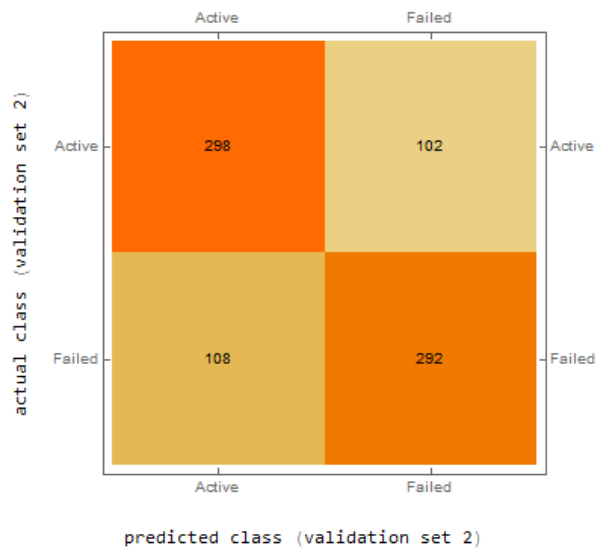
Performance Trained Bankruptcy=0.843473

Performance Trained Total=0.779038

Zdroj: Vlastní.

Obrázek 34 ukazuje konfuzní matici testovací množiny dat, ze které je možno vyčíst, že 292 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 108 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 298 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 102 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon testovací množiny dat aktivních podniků je roven hodnotě 0,745, v případě bankrotních podniků je výkon roven 0,73 a celkový výkon je roven hodnotě 0,7375.

Obrázek 34 Konfuzní matice testovacího souboru dat – B-NN_GRL3



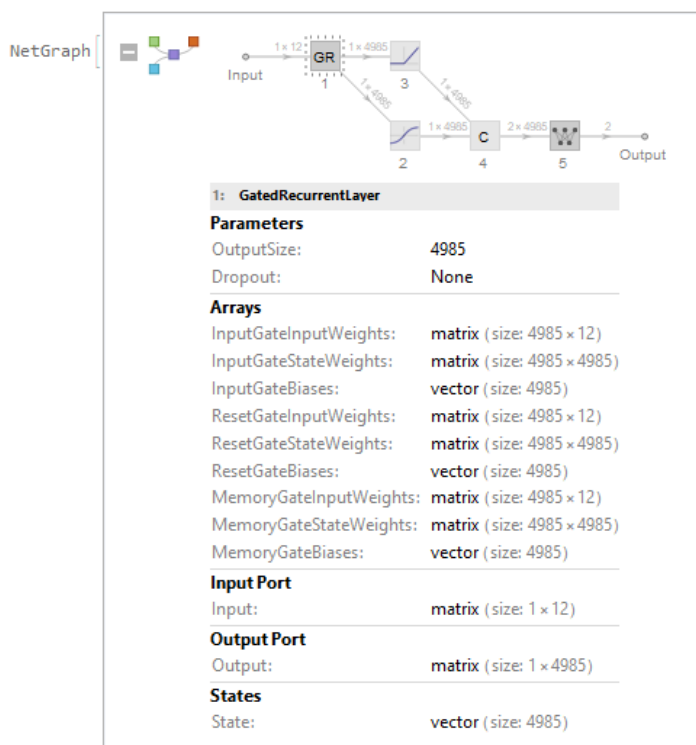
Performance Test Active=0.745
Performance Test Bankruptcy=0.73
Performance Test Total=0.7375

Zdroj: Vlastní.

B-NN_GRL4

Základní struktura sítě B-NN_GRL4 je zobrazena na Obrázku 35. Výstupní dimenze je rovna 4 985, funkci zde představuje hyperbolický tangens a funkce ramp a výstupem jsou takzvané třídy.


Obrázek 35 Základní struktura sítě B-NN_GRL4



Zdroj: Vlastní.

Z konfuzní matice trénovacího souboru dat (viz. Obrázek 36) lze určit, že 1 566 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 242 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 1266 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 542 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výsledky výkonů sítě u aktivních podniků, bankrotních podniků a celkového výkonu jsou uvedeny pod maticí na Obrázku 36.

Obrázek 36 Konfuzní matice trénovacího souboru dat – B-NN_GRL4



predicted class (validation set 1)

Performance Trained Active=0.700221


Performance Trained Bankruptcy=0.86615

Performance Trained Total=0.783186

Zdroj: Vlastní.

Na Obrázku 37 lze vidět konfuzní matici testovacího souboru dat, ze které je možno vyčíst, že 300 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo ke 100 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 269 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 131 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon testovací množiny dat aktivních podniků po zaokrouhlení je roven hodnotě 0,673, v případě bankrotních podniků je výkon roven 0,75 a celkový výkon je roven hodnotě 0,711.

Obrázek 37 Konfuzní matice testovacího souboru dat – B-NN_GRL4



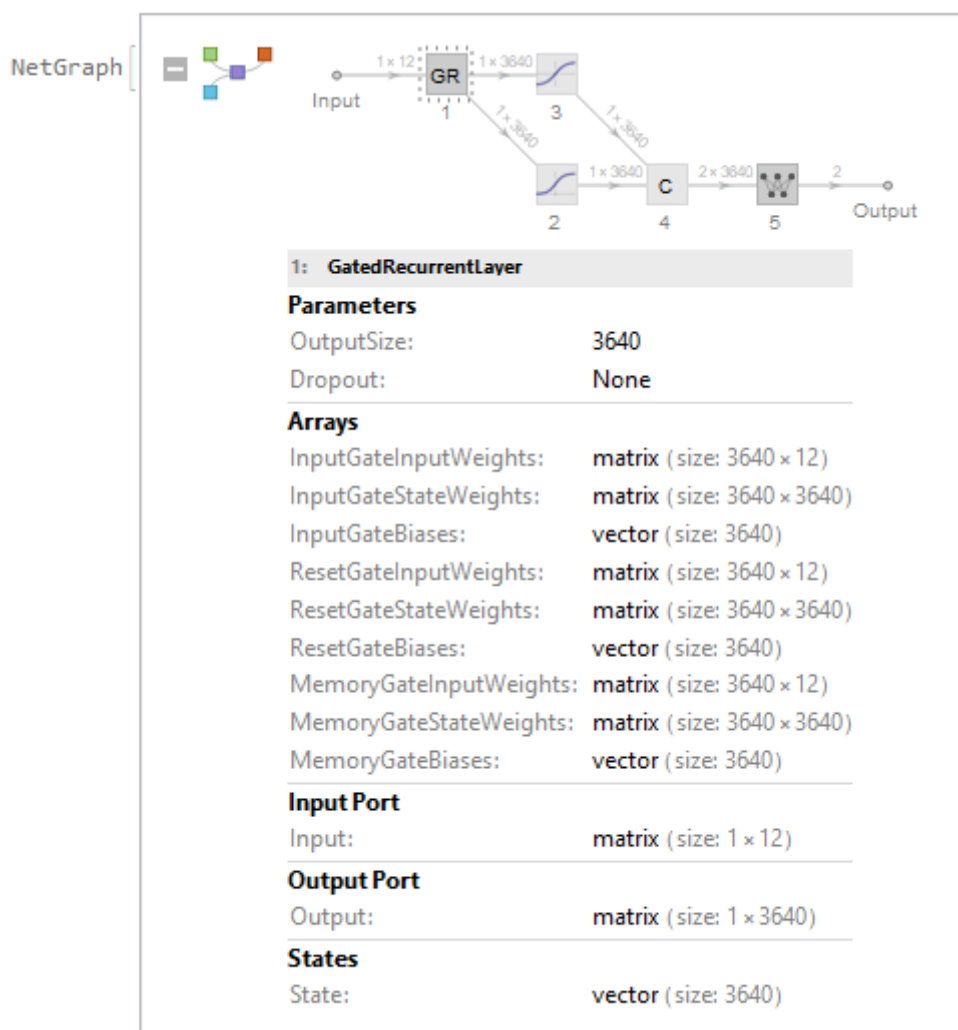
Performance Test Active=0.6725
Performance Test Bankruptcy=0.75
Performance Test Total=0.71125

Zdroj: Vlastní.

B-NN_GRL5

Základní struktura sítě B-NN_GRL5 je zobrazena na Obrázku 38. Výstupní dimenze je rovna 4 985, funkci zde představuje logistický Sigmoid a funkce hyperbolický tangens a výstupem jsou takzvané třídy.


Obrázek 38 Základní struktura sítě B-NN_GRL5



Zdroj: Vlastní.

Z Obrázku 39 lze určit, že 1 519 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 289 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 1 328 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 480 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkony v případě aktivních podniků, bankrotních podniků a celkový výkon sítě jsou uvedeny na Obrázku 39.


Obrázek 39 Konfuzní matice trénovacího souboru dat – B-NN_GRL5



Zdroj: Vlastní.

Při pohledu na konfuzní matici testovacího souboru dat (Obrázek 40) je viditelné, že 281 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 119 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 296 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 104 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkony v případě aktivních podniků, bankrotních podniků a celkový výkon sítě jsou uvedeny na Obrázku 40.

Obrázek 40 Konfuzní matice testovacího souboru dat – B-NN_GRL5



Zdroj: Vlastní.

5.1.3 Metody využívající NN s LSTM vrstvou

Tabulka 17 představuje přehled pěti nejlepších uchovaných vícevrstevých perceptronových sítí. V tabulce je zaneseno ID jednotlivých sítí, název sítí a výkon trénovací a testovací množiny dat. Lze pozorovat, že výkon trénovací množiny dat se pohybuje od 61 procent do necelých 67 procent, což značí průměrný výkon. V případě testovací množiny dat hovoříme o výkonu pohybujícím se mezi 55 až necelými 65 procenty.

Tabulka 17 Přehled uchovaných NN s LSTM vrstvou

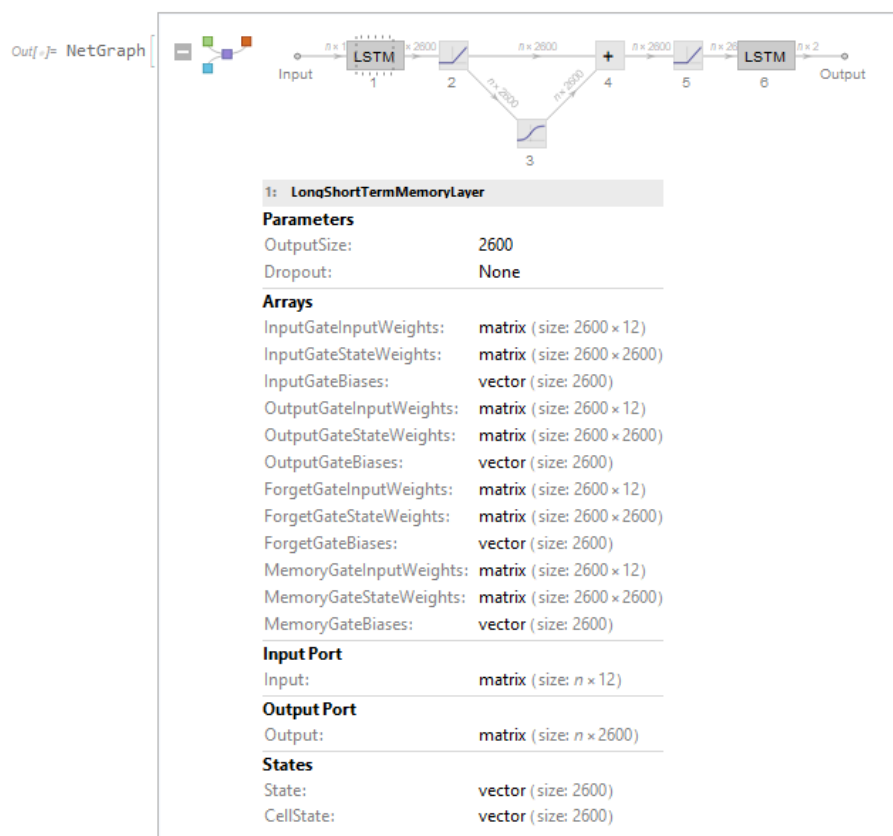
ID sítě	Název sítě	Train performance	Test performance
B-NN_LSTM1	12-LongShortTermMemoryLayer[2600]-Ramp-LogisticSigmoid-Ramp-2-1	0,6651	0,64125
B-NN_LSTM2	12-LongShortTermMemoryLayer[4025]-Sin-Ramp-LogisticSigmoid-2-1	0,618639	0,58625
B-NN_LSTM3	12-LongShortTermMemoryLayer[275]-LogisticSigmoid -Ramp-LogisticSigmoid-2-1	0,619469	0,555
B-NN_LSTM4	12-LongShortTermMemoryLayer[2820]-Tanh-LogisticSigmoid-Tanh-2-1	0,628872	0,60375
B-NN_LSTM5	12-LongShortTermMemoryLayer[2705]-LogisticSigmoid-Ramp-Tanh-2-1	0,635232	0,595

Zdroj: Vlastní.

B-NN_LSTM1

Základní struktura sítě B-NN_LSTM1 je zobrazena na Obrázku 41. Výstupní dimenze je rovna 2 600, funkci zde představuje logistický Sigmoid a funkce ramp a výstupem jsou takzvané třídy.


Obrázek 41 Základní struktura sítě B-NN_LSTM1



Zdroj: Vlastní.

Z konfuzní matice trénovacího souboru dat, viz Obrázek 42, je možné vypočítat, že 1 526 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 282 případům, kde klasifikátor chybně nahradil bankrotní podniky těmi aktivními. 879 podniků bylo správně zařazeno mezi podniky aktivní, leč u 929 podniků došlo k zaměnění aktivních podniků za podniky bankrotní.

Obrázek 42 Konfuzní matice trénovacího souboru dat – B-NN_LSTM1



Performance Trained Active=0.486173

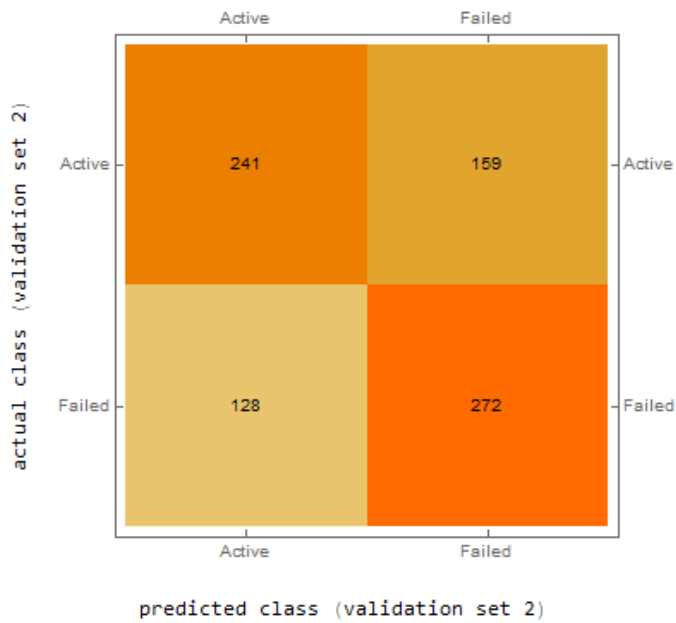
Performance Trained Bankruptcy=0.844027

Performance Trained Total=0.6651

Zdroj: Vlastní.

I v případě trénovacího souboru dat je výsledkem konfuzní matice, kterou lze pozorovat na Obrázku 43, a matice říká, že 272 podniků bylo správně klasifikováno jako podniky bankrotní, 128 podniků bylo zařazeno jako podniky bankrotní i přes skutečnost, že jde o podniky aktivní. Celkem 241 podniků bylo správně klasifikováno jako podniky aktivní a 159 podniků bylo chybně označeno za podniky v likvidaci, avšak jednalo se o podniky aktivní. Výkon sítě v případě aktivních a bankrotních podniků, a taktéž celý výkon sítě, je uveden pod maticí na Obrázku 43.

Obrázek 43 Konfuzní matice testovacího souboru dat – B-NN_LSTM1



Performance Test Active=0.6025
Performance Test Bankruptcy=0.68
Performance Test Total=0.64125

Zdroj: Vlastní.

B-NN_LSTM2

Základní strukturu sítě B-NN_LSTM2 zobrazuje Obrázek 44. Výstupní dimenze je rovna 4 025, funkce zde představují logistický Sigmoid, sinus a funkce ramp a výstupem jsou takzvané třídy.


Obrázek 44 Základní struktura sítě B-NN_LSTM2



Zdroj: Vlastní.

Z obrázku 45 vyplývá, že 1 637 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo ke 171 případům, kde klasifikátor chybně určil bankrotní podniky jako podniky aktivní. 600 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 1 208 podniků došlo k záměně aktivních podniků za podniky bankrotní.

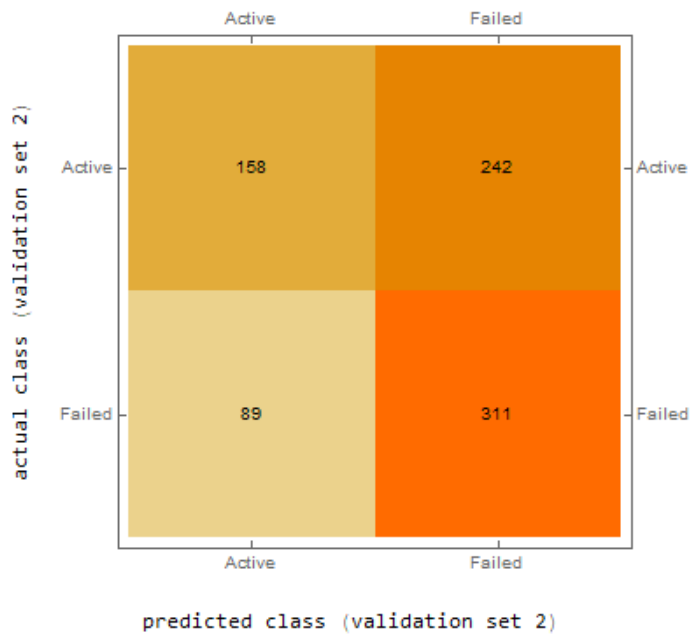
Obrázek 45 Konfuzní matice trénovacího souboru dat – B-NN_LSTM2



Zdroj: Vlastní.

Obrázek 46 ukazuje, že 311 podniků bylo správně klasifikováno jako bankrotní podniky. U 89 případů klasifikátor chybně určil bankrotní podniky jako podniky aktivní. 158 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 242 podniků došlo k záměně aktivních podniků za podniky bankrotní.

Obrázek 46 Konfuzní matice testovacího souboru dat – B-NN_LSTM2



Performance Test Active=0.395
Performance Test Bankruptcy=0.7775
Performance Test Total=0.58625

Zdroj: Vlastní.

B-NN_LSTM3

Základní struktura sítě B-NN_LSTM3 je zobrazena na Obrázku 47. Výstupní dimenze je rovna 2 820, funkci zde představuje logistický Sigmoid a funkce ramp a výstupem jsou takzvané třídy.


Obrázek 47 Základní struktura sítě B-NN_LSTM3



Zdroj: Vlastní.

Při bližším pohledu na Obrázek 48, a na něm zobrazenou konfuzní matici trénovací množiny dat, lze konstatovat, že 1 632 podniků bylo správně klasifikováno jako bankrotní podniky. Ve 176 případech klasifikátor zaměnil bankrotní podniky za podniky aktivní. 608 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 1 200 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkon testovací množiny dat aktivních podniků je po zaokrouhlení roven hodnotě 0,336, v případě bankrotních podniků je výkon roven 0,903 a celkový výkon je roven hodnotě 0,619.

Obrázek 48 Konfuzní matice trénovacího souboru dat – B-NN_LSTM3



predicted class (validation set 1)

Performance Trained Active=0.336283

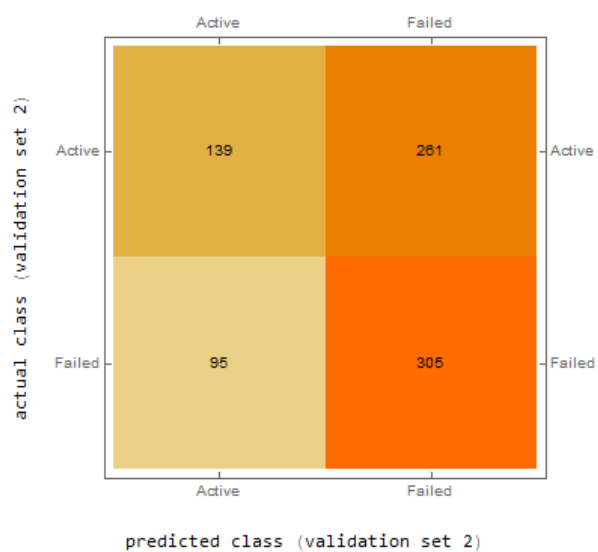
Performance Trained Bankruptcy=0.902655

Performance Trained Total=0.619469

Zdroj: Vlastní.

Záměrem klasifikátoru bylo diferencovat podniky na aktivní a podniky v bankrotu. Z Obrázku 49 je možné určit, že 305 podniků bylo správně klasifikováno jako bankrotní podniky. V 95 případech klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 139 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 261 podniků došlo k prohození aktivních podniků za podniky bankrotní.

Obrázek 49 Konfuzní matice testovacího souboru dat – B-NN_LSTM3



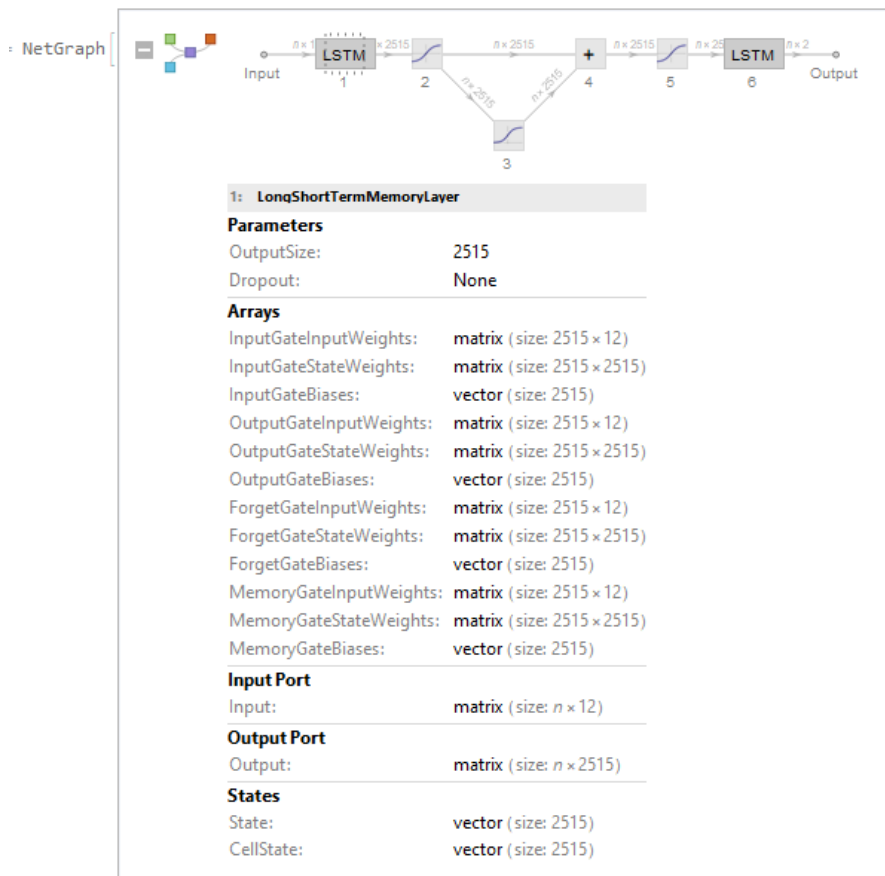
Performance Test Active=0.3475
Performance Test Bankruptcy=0.7625
Performance Test Total=0.555

Zdroj: Vlastní.

B-NN_LSTM4

Základní strukturu sítě B-NN_LSTM4 zobrazuje Obrázek 50. Výstupní dimenze je rovna 2 515, funkce zde představují logistický Sigmoid, a funkce ramp a výstupem jsou takzvané třídy.

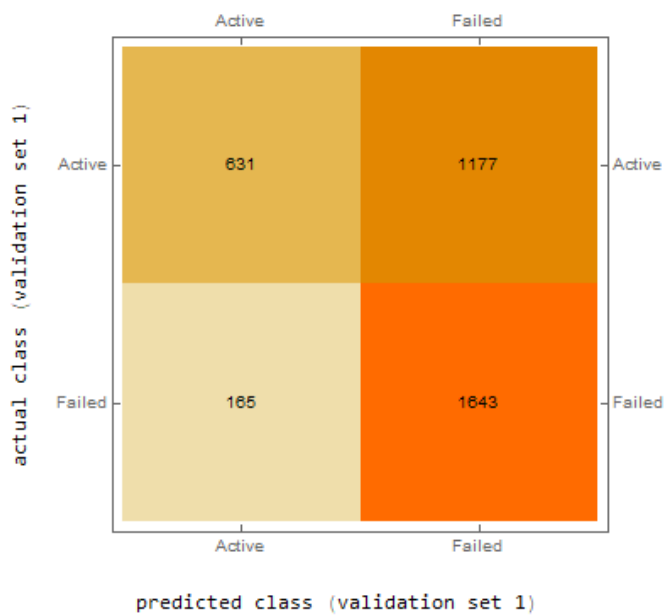
Obrázek 50 Základní struktura sítě B-NN_LSTM4



Zdroj: Vlastní.

Z konfuzní matice trénovacího souboru dat viz Obrázek 51 je možno určit, že 1 643 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 165 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 631 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 1 177 podniků došlo k zaměnění aktivních podniků za podniky bankrotní. Výkony jsou uvedené pod maticí.

Obrázek 51 Konfuzní matice trénovacího souboru dat – B-NN_LSTM4



Performance Trained Active=0.349004


Performance Trained Bankruptcy=0.908739

Performance Trained Total=0.628872

Zdroj: Vlastní.

Obrázek 52 ukazuje, že 329 podniků bylo správně klasifikováno jako bankrotní podniky. V 71 případech klasifikátor chybně určil bankrotní podniky jako podniky aktivní. 154 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 246 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkony jsou zobrazeny pod konfuzní maticí.

Obrázek 52 Konfuzní matice testovacího souboru dat – B-NN_LSTM4



Zdroj: Vlastní.

B-NN_LSTM5

Základní strukturu sítě B-NN_LSTM5 zobrazuje Obrázek 53. Výstupní dimenze je rovna 2 705, funkce zde představují logistický Sigmoid, hyperbolický tangens a funkce ramp. Výstupem jsou takzvané třídy.


Obrázek 53 Základní struktura sítě B-NN_LSTM5



Zdroj: Vlastní.

Při zaměření se na konfuzní matici trénovacího souboru dat je patrné, že 1 534 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 274 případům, kde klasifikátor chybně zaměnil bankrotní podniky za podniky aktivní. 763 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 1 045 podniků došlo k prohození aktivních podniků za podniky bankrotní (viz Obrázek 54).

Obrázek 54 Konfuzní matice trénovacího souboru dat – B-NN_LSTM5



Performance Trained Active=0.422013


Performance Trained Bankruptcy=0.848451

Performance Trained Total=0.635232

Zdroj: Vlastní.

Z konfuzní matice testovacího souboru datna Obrázku 55, lze určit, že 270 podniků bylo správně klasifikováno jako bankrotní podniky. Dále došlo k 130 případům, kde klasifikátor chybně vyměnil bankrotní podniky za podniky aktivní. 206 podniků bylo správně zařazeno mezi podniky aktivní, avšak u 194 podniků došlo k záměně aktivních podniků za podniky bankrotní. Výkony jsou uvedeny pod konfuzní maticí.

Obrázek 55 Konfuzní matice testovacího souboru dat – B-NN_LSTM5



Performance Test Active=0.515
Performance Test Bankruptcy=0.675
Performance Test Total=0.595

Zdroj: Vlastní.

5.2 Finanční analýza

Finanční analýza je v tomto případě zpracována na podnicích CHNC, a.s., SAF, a.s., TP, a.s., BS, a.s.

5.2.1 CHNC, a.s.

Tato kapitola je věnována rozboru finančního zdraví společnosti CHNC, a.s. prostřednictvím finanční analýzy. Finanční analýza je zpracována v tomto rozsahu:

- horizontální analýza pro posouzení vývoje aktiv, pasiv a výsledku hospodaření,
- vertikální analýza aktiv a pasiv,
- analýza poměrových ukazatelů (rentabilita, aktivita, likvidita a zadluženost),
- komplexní hodnocení podniku (index bonity, index IN95, index IN99, mod. Tafflerův index).


Všechna uváděná data k roku 2020 jsou vztažena k datu ocenění, tj. 31. 8. 2020.

Horizontální analýza

Vývoj aktiv a pasiv

Následující grafy (Obrázek 56 a 57) znázorňují vývoj aktiv a pasiv společnosti CHNC, a.s. v období 2014–2020.

Obrázek 56 Vývoj aktiv společnosti CHNC, a.s. (v tis. Kč)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Celková aktiva společnosti CHNC, a.s. kontinuálně rostla po celou dobu sledovaného období (vyjímaje roku 2018, kdy byl zaznamenán mírný pokles). Na začátku sledovaného období disponovala společnost aktivy v hodnotě 339 408 tis. Kč, po šesti letech a osmi měsících se celková aktiva více než ztrojnásobila a dosahovala 1 248 352 tis. Kč (aktiva k 31. 8. 2020). Rostoucí vývoj aktiv je obecně považován jako pozitivní a chtěnou změnu podniku.

Obrázek 57 Vývoj pasiv společnosti CHNC, a.s. (v tis. Kč)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Celková pasiva po sledované období měla téže rostoucí vývoj, jak tomu bylo i u aktiv. Z grafu je zřejmé, že v každém roce cizí kapitál převyšoval kapitál vlastní. V roce 2014 společnost vykázala záporný vlastní kapitál – nebylo to z důvodu záporného výsledku hospodaření, ale hlavně v důsledku záporné hodnoty ostatních kapitálových fondů⁴. Záporný vlastní kapitál v tomto roce zapříčinil i to, že cizí kapitál měl vyšší hodnotu než celková pasiva.

Vývoj výsledku hospodaření před zdaněním

Následující Tabulka 18 a graf (Obrázek 58) informují o hospodaření společnosti (před zdaněním) za období 2014–2020.

Tabulka 18 Vývoj VH před zdaněním společnosti CHNC, a.s. (v tis. Kč)

Rok	HV před zdaněním	Rok	HV před zdaněním
2014	29 409 tis. Kč	2018	181 694 tis. Kč
2015	168 796 tis. Kč	2019	328 664 tis. Kč
2016	156 248 tis. Kč	2020	250 838 tis. Kč
2017	248 342 tis. Kč		

Zdroj: Vlastní.


Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

CHNC, a.s. ve sledovaném období pokaždé vykázala kladný hospodářský výsledek – zisk. Vývoj výsledku hospodaření před zdaněním doprovázely pravidelné změny, kdy po nárůstu VH následovalo vždy období, ve kterém došlo k jeho snížení a opačně. Nejnižší hodnota VH před zdaněním byla dosažena roku 2014 ve výši 29 409 tis. Kč a nejvyšší roku 2019 ve výši 328 664 tis. Kč.

Při porovnání prvního a posledního sledovaného roku je zjevné, že došlo k vysokému nárůstu výsledku hospodaření před zdaněním. CHNC, a.s. v roce 2019 převýšila zisk z roku 2014 o více než jedenáctkrát.

⁴ Nákup obchodního podílu na společnosti CHNC, a.s. uskutečněný v roce 2013 společností GOS, A.S. byl v rámci sloučeného účetnictví po realizované fúzi obou společností zaúčtován jako snížení vlastního kapitálu, jako záporný ostatní kapitálový fond.

Obrázek 58 Vývoj VH před zdaněním společnosti CHNC, a.s. (v tis. Kč)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Datům ocenění je 31. 8. 2020, je tedy na místě uvést i hospodaření podniku v tomto roce. Následující graf na Obrázku 88 zobrazuje výsledek hospodaření před zdaněním společnosti CHNC, a.s. v prvních osmi měsících roku 2020. Vývoj VH před zdaněním CHNC, a.s. v jednotlivých měsících roku 2020 zaznamenává každoměsíční nárůst. Při porovnání dosaženého zisku ke konci srpna 2020 s ostatními lety lze zmínit, že CHNC, a.s. i za pouhých 8 měsíců hospodaření dosáhla druhý nejlepší výsledek hospodaření ve sledovaných letech, vyjma roku 2019.

Obrázek 59 Vývoj VH před zdaněním (za jednotlivé měsíce) roku 2020 společnosti CHNC, a.s. (v tis. Kč)



Zdroj: Vlastní.

Vertikální analýza

Prostřednictvím vertikální analýzy je analyzována struktura aktiv a pasiv zkoumané společnosti, viz Tabulka 19 a 20. V tomto případě lze aktiva a pasiva označit za syntetické

ukazatele (tvoří 100 %), které jsou podrobeny rozkladu na dílčí části. Cílem vertikální analýzy je určit strukturu, tj. procentuální zastoupení dílčích ukazatelů na syntetických účtech.

Tabulka 19 Vertikální analýza aktiv společnosti CHNC, a.s.

Položka	2014	2015	2016	2017	2018	2019	2020
Aktiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Dl. majetek	5,4 %	25,7 %	44,1 %	58,8 %	56,7 %	42,6 %	39,9 %
Dl. majetek hmotný	5,1 %	2,8 %	2,0 %	1,9 %	1,9 %	1,6 %	1,2 %
Dl. majetek nehmotný	0,2 %	0,1 %	0,1 %	0,0 %	0,0 %	0,0 %	0,0 %
Dl. majetek finanční	0,0 %	22,7 %	42,0 %	56,8 %	54,8 %	41,1 %	38,6 %
Oběžná aktiva	90,5 %	72,8 %	54,7 %	40,1 %	41,5 %	56,1 %	60,0 %
Zásoby	2,4 %	1,2 %	0,6 %	0,3 %	0,3 %	0,1 %	0,0 %
Dl. pohledávky	0,0 %	0,0 %	12,8 %	0,0 %	0,0 %	0,0 %	0,0 %
Kr. pohledávky	1,8 %	28,7 %	10,5 %	4,4 %	1,7 %	1,0 %	2,3 %
Kr. majetek finanční	86,3 %	42,9 %	30,8 %	35,5 %	39,5 %	54,9 %	57,6 %
Časové rozlišení aktiv	4,1 %	1,6 %	1,2 %	1,1 %	1,8 %	1,3 %	0,2 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Mimo roky 2014 a 2015 dlouhodobá nebo oběžná aktiva zastupovala maximálně 60 % celkových aktiv – v těchto letech pojímal největší podíl aktiv dlouhodobý finanční majetek a krátkodobý finanční majetek (tj. peněžní prostředky). Již jmenované roky byly specifické zejména tím, že v roce 2014 tvořila oběžná aktiva více než 90 % celkových aktiv a oběžná aktiva byla z hlavní části tvořena peněžními prostředky. V dalším období stále zastupovala oběžná aktiva hlavní položku aktiv, ale už v menší míře (72,8 %) a jiném složení – nárůst zaznamenaly především krátkodobé pohledávky.

Tabulka 20 Vertikální analýza pasiv společnosti CHNC, a.s.

Položka	2014	2015	2016	2017	2018	2019	2020
Pasiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Vlastní kapitál	-64,8 %	9,4 %	7,2 %	28,8 %	23,8 %	31,2 %	46,4 %
Základní kapitál	29,0 %	17,3 %	13,3 %	12,5 %	13,0 %	10,8 %	9,1 %
Fondy	-93,3 %	-29,9 %	-20,7 %	-5,7 %	-5,9 %	-4,9 %	0,0 %
VH minulých let	-2,8 %	-0,3 %	0,0 %	0,0 %	0,0 %	0,0 %	17,2 %
VH běžného úč. období	2,2 %	22,2 %	14,6 %	22,0 %	16,7 %	25,3 %	20,1 %
Cizí zdroje	163,2 %	89,6 %	91,9 %	70,4 %	75,4 %	68,6 %	53,6 %
Dl. závazky	127,4 %	75,8 %	58,5 %	55,2 %	57,3 %	47,6 %	40,2 %
Rezervy	15,3 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Kr. závazky	20,6 %	13,7 %	33,3 %	15,2 %	18,1 %	21,0 %	13,4 %
Časové rozlišení pasiv	1,6 %	1,1 %	0,9 %	0,9 %	0,8 %	0,2 %	0,0 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ve složení pasiv společnosti CHNC, a.s. převládající podíl po celé období zastupovaly cizí zdroje. Největší položkou cizích zdrojů byly vždy dlouhodobé závazky v podobě emitovaných dluhopisů. Vysoký poměr cizího kapitálu vůči vlastnímu kapitálu (roku 2014 dokonce 163,2 %) měl původ zvláště v evidenci záporné hodnoty ostatních kapitálových fondů. Doporučovaným poměrem této proporce je 1:1. V žádném roce společnost tuto doporučenou hodnotu nespĺnila, avšak v průběhu sledovaného období dochází ke zvyšování vlastního kapitálu na celkových pasivech a došlo ke značnému zlepšení struktury pasiv. 31. 8. 2020 poměr mezi vlastním a cizím kapitálem je téměř rovnocenný, 46:54.

Analýza poměrových ukazatelů

Následující odstavce obsahují výpočet a popis poměrových ukazatelů, konkrétně ukazatelů rentability, aktivity, likvidity a zadluženosti společnosti CHNC, a.s.

Ukazatele rentability

V následující Tabulce 21 jsou uvedeny ukazatele rentability společnosti CHNC, a.s. za sledované období 2014–2020.

Tabulka 21 Ukazatele rentability společnosti CHNC, a.s. (v procentech)

Položka	2014	2015	2016	2017	2018	2019	2020
ROA	24,38	34,65	25,20	33,87	27,60	36,90	23,15
ROE	-37,61	369,68	347,82	117,64	115,99	118,32	49,89
ROCE	31,34	40,66	38,31	40,35	34,03	46,81	26,73
ROS	12,81	47,80	32,82	37,85	25,42	30,89	29,95


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

V grafu na Obrázku 60 je uvedeno grafické zobrazení dvou základních ukazatelů rentability, a to rentabilita vlastního kapitálu (ROE) a rentabilita celkových aktiv (ROA). ROE je řazena mezi jeden z nejdůležitějších ukazatelů pro podnik, jelikož vyjadřuje, do jaké míry je podnik schopen zhodnotit svůj vlastní kapitál, jeho pohyb proběhl drastickými změnami, kdy v roce 2014 ROE společnost vykazovala záporné hodnoty (- 37,61 %), což bylo zapříčiněno vykázaním záporného vlastního kapitálu. Od následujícího roku došlo ke skokovému zlepšení ROE na 369,69 % (rok 2015), které s mírným poklesem vydrželo do roku 2016. Od roku 2017 následoval strmější pokles ROE, který se do konec sledovaného období pohyboval okolo 115 %. Výrazné změny rentability vlastního kapitálu byly zapříčiněny zejména změnu jeho výše.

Rentabilita aktiv oproti ROE neprošla za sledované období dramatickým vývojem a její hodnota oscilovala mezi 23–37 %.

Obrázek 60 Vývoj ROA a ROE společnosti CHNC, a.s. (v procentech)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele aktivity

V následující Tabulce 22 jsou uvedeny ukazatele aktivity společnosti CHNC, a.s. za sledované období 2014–2020.

Tabulka 22 Ukazatele aktivity společnosti CHNC, a.s.

Položka	2014	2015	2016	2017	2018	2019	2020
Obrat aktiv	1,904	0,725	0,768	0,895	1,086	1,194	0,773
Doba obratu aktiv	189,072	496,702	468,783	402,338	331,548	301,388	465,725
Doba inkasa pohledávek	3,294	13,189	4,666	11,923	0,263	0,573	0,429
Doba splatnosti krátkodobých závazků	38,979	68,226	156,249	61,162	59,972	63,148	62,414

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Tabulka výše znázorňuje ukazatele aktivity mezi roky 2014–2020. Obrat aktiv vyjadřuje míru využití aktiv, kdy společnost aktiva využila nejvíce společnost v roce 2014. V letech 2015–2017 a 2020 CHNC, a.s. nedosáhla obratem aktiv na hodnotu 1, tedy svá aktiva v těchto období neobrátila. Nejdelší Doba inkasa pohledávek byla v roce 2015 – 13,2 dnů, naopak nejkratší doba inkasa pohledávek byla v letech 2018, 2019 a 2020, kdy vymáhání pohledávek nečinilo ani den.

Ukazatele likvidity

V následující Tabulce 23 jsou uvedeny ukazatele likvidity společnosti CHNC, a.s. za sledované období 2014–2020. Vývoj likvidit je také ukázán graficky na Obrázku 61.

Tabulka 23 Ukazatele likvidity společnosti CHNC, a.s.


Položka	2014	2015	2016	2017	2018	2019	2020
Běžná likvidita	4,391	5,297	1,640	2,637	2,293	2,676	4,475
Pohotová likvidita	4,275	5,212	1,238	2,620	2,278	2,672	4,472
Hotovostní likvidita	4,188	3,125	0,923	2,333	2,185	2,622	4,301

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Všechny tři ukazatele likvidity společnosti CHNC, a.s. dosahovaly po celé období průměrných až nadprůměrných hodnot. V žádném období se společnost nedostala pod doporučené hodnoty likvidity. U vybraných let 2014, 2017, 2018, 2019 a 2020 byly rozdíly mezi jednotlivými ukazateli likvidity minimální, bylo to zapříčiněno zejména tím, že oběžná aktiva tvořila v těchto letech z hlavní části právě peněžní prostředky. Nejnižší likvidita byla naměřena k roku 2016, kdy společnost oproti ostatním období pokrývala nejméně svými aktivy krátkodobé závazky – bylo to z důvodu nárůstu krátkodobých závazků.

Obrázek 61 Vývoj likvidity společnosti CHNC, a.s.



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele zadluženosti

V následující Tabulce 24 jsou uvedeny ukazatele zadluženosti společnosti CHNC, a.s. za sledované období 2014–2020. Graficky znázorněn je také vývoj ukazatelů zadluženosti na Obrázku 62.

Tabulka 24 Ukazatele zadluženosti společnosti CHNC, a.s.


Položka	2014	2015	2016	2017	2018	2019	2020
Zadluženost I.	-2,518	9,557	12,679	2,444	3,169	2,199	1,155
Zadluženost II.	1,632	0,896	0,919	0,704	0,754	0,686	0,536
Úrokové krytí	1,442	3,813	3,604	5,139	4,028	6,478	7,572

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

V tabulce výše jsou uvedeny ukazatele zadluženosti společnosti CHNC, a.s. Nepříliš obvyklé je, aby zadluženost I. vyšla v záporné hodnotě, jako tomu bylo v roce 2014. Záporná hodnota je způsobena záporným vlastním kapitálem, který společnost k tomuto roku evidovala. Zadluženost I. v letech 2015 a 2016 vykazovala vysoké hodnoty hlavně z důvodu, že cizí kapitál markantně převyšoval vlastní kapitál. V dalších letech se zadluženost I. výrazně snížila především kvůli nárůstu vlastního kapitálu. Úrokové krytí nedosáhl v žádném z období hodnoty 1, tedy nikdy nebyl celý zisk použit na krytí nákladových úroků společnosti.

Obrázek 62 Vývoj ukazatelů zadluženosti společnosti CHNC, a.s.



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Komplexní hodnocení podniku

Pro komplexní hodnocení podniku CHNC, a.s. je využito indexu Bonity, indexu IN95, indexu IN99 a modifikovaného Tafflerova indexu.

Index bonity

V následující Tabulce 25 je uveden index bonity společnosti CHNC, a.s. za sledované období 2014–2020.

Tabulka 25 Index bonity společnosti CHNC, a.s.

Index bonity	Váha	2014	2015	2016	2017	2018	2019	2020
Cash flow/cizí zdroje	1,5	0,02	0,25	0,16	0,32	0,23	0,37	0,37 ⁵
aktiva/Cizí zdroje	0,08	0,61	1,12	1,09	1,42	1,33	1,46	1,87
Zisk/aktiva	10	0,07	0,26	0,18	0,27	0,21	0,31	0,20
Zisk/výnosy	5	0,04	0,35	0,24	0,30	0,19	0,26	0,26
Zásoby/výnosy	0,3	0,01	0,02	0,01	0,00	0,00	0,00	0,00
Výnosy/aktiva	0,1	1,90	0,72	0,77	0,89	1,09	1,19	0,77
Index bonity		1,22	4,87	3,42	4,93	3,58	5,22	4,10
Hodnocení ekonomické situace	Dobrá	Extrémně dobrá	Extrémně dobrá	Extrémně dobrá	Extrémně dobrá	Extrémně dobrá	Extrémně dobrá	Extrémně dobrá
	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

V případě společnosti CHNC, a.s. výsledek bonity (vyjma roku 2014) vyšel dle hodnocení ekonomické situace podniku jako extrémně dobrý. Data v průběhu času ukazují na stabilní a pozitivní výsledek, i když na počátku sledovaného období index bonity vyšel 1,22 s výsledkem dobrého ekonomického hodnocení. Nejlepší výsledek bonity dosáhla společnost v letech 2015, 2017 a 2019. Při sledování uceleného trendu bonity podniku, finanční zdraví podniku vyšlo jako velice dobré. Důležité je zejména, že posledních 5 letech hodnocení ekonomické situace podniku vyšlo jako extrémně dobré.

⁵ Pro rok 2020 se nerovná Cash flow součtu výsledku hospodaření po zdanění a odpisů (Vochozka et al., 2020) jako je tomu v předchozích letech, nýbrž součtu výsledku hospodaření před zdaněním a odpisů z důvodu, že za jednotlivé měsíce roku 2020 nebyla vyčíslena daň z příjmů právnických osob.

Index IN95

V následující Tabulce 26 je uveden index IN95 společnosti CHNC, a.s. za sledované období 2014–2020.

Tabulka 26 Index IN95 společnosti CHNC, a.s.

Index IN95	Váha	2014	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	0,022	0,61	1,12	1,09	1,42	1,33	1,46	1,87
EBIT/nákladové úroky	0,11	1,44	3,81	3,60	5,14	4,03	6,48	7,57
EBIT/aktiva	8,33	0,24	0,35	0,25	0,34	0,28	0,37	0,23
Výnosy/aktiva	0,52	1,90	0,72	0,77	0,89	1,09	1,19	0,77
Oběžná aktiva/kr. cizí kapitál	0,10	4,39	5,30	1,64	2,64	2,29	2,68	4,48
Závazky po spl. / výnosy	-16,80	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Index IN95		3,63	4,24	3,08	4,15	3,57	4,71	3,65
Hodnocení		Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Při hodnocení společnosti CHNC, a.s. vyšel v každém roce index IN95 vyšší než 2, tudíž zkoumaná společnost po celé sledované období spadala do zóny bonitních podniků. Dílčí výsledky ve sledovaném období relativně kolísají. Nejhoršího výsledku bylo dosaženo v roce 2016 a nejlepšího pak v roce 2019. Rozdíl byl způsoben vývojem krátkodobých závazků a ziskem před zdaněním a úroky (tj. EBIT).

Index IN99

V následující Tabulce 27 je uveden index IN99 společnosti CHNC, a.s. za sledované období 2014–2020.

Tabulka 27 Index IN99 společnosti CHNC, a.s.

Index IN99	Váha	2014	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	-0,017	0,61	1,12	1,09	1,42	1,33	1,46	1,87
EBIT/aktiva	4,57	0,24	0,35	0,25	0,34	0,28	0,37	0,23
Výnosy/aktiva	0,48	1,90	0,72	0,77	0,89	1,09	1,19	0,77
Oběžná aktiva/kr. cizí kapitál	0,02	4,39	5,30	1,64	2,64	2,29	2,68	4,48
Index IN99		2,08	1,99	1,53	1,99	1,80	2,28	1,47
Hodnocení		Podnik tvoří hodnotu	Podnik spíše tvoří hodnotu	Šedá zóna	Podnik spíše tvoří hodnotu	Podnik spíše tvoří hodnotu	Podnik tvoří hodnotu	Šedá zóna

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Výsledek indexu IN99 společnosti CHNC, a.s. vyšel (vyjma let 2016 a 2020) vždy vyšší než 1,59, tudíž společnost v tomto období tvořila hodnotu. V průběhu času hodnocení indexem IN99 vyšlo střídavě jako „podnik tvoří hodnotu“ a „podnik tvoří spíše hodnotu a dvakrát „šedá zóna“ (rok 2016 a 2020). Společnost CHNC, a.s. je tak hodnocena souhrnně kladně, kdy v nejhroším případě za celé sledované období se dostala dvakrát do šedé zóny, kdy svou hodnotou v období 2016 byla velice blízko pásma podniků tvořící hodnotu, a v 2020 data vyšla z 8 měsíců, tudíž tento výsledek není nijak alarmující.

Modifikovaný Tafflerův index

V následující Tabulce 28 je uveden modifikovaný Tafflerův index společnosti CHNC, a.s. za sledované období 2014–2020.

Tabulka 28 Modifikovaný Tafflerův index společnosti CHNC, a.s.

Modifikovaný Tafflerův index	Váha	2014	2015	2016	2017	2018	2019	2020
EBIT/kr. závazky	0,53	1,18	2,52	0,76	2,23	1,53	1,76	1,73
Oběžná aktiva/cizí kapitál	0,13	0,55	0,81	0,60	0,57	0,55	0,82	1,12
Kr. závazky / aktiva	0,18	0,85	0,40	1,32	0,45	0,66	0,57	0,58
Tržby / aktiva	0,16	1,90	0,72	0,77	0,89	1,09	1,19	0,77
Modifikovaný Tafflerův index		1,16	1,63	0,84	1,48	1,17	1,33	1,29
Hodnocení		Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

CHNC, a.s. je hodnocena modifikovaným Tafflerovým indexem velmi dobře – jako bonitní podnik v celém sledovaném období. Dílčí výsledky ve sledovaném období relativně kolísají. Nejlepšího výsledku bylo dosaženo v roce 2015 a nejhrošího pak v roce 2016. Rozdíl byl způsoben meziročním nárůstem krátkodobých závazků.

Aplikované metody komplexního hodnocení podniku na bázi NN

Tabulka 29 přináší výsledky vícevrstevných perceptronových sítí.

Tabulka 29 Výsledky vícevrstevných perceptronových sítí

ID sítě	Název sítě	Predikce
B-NN_LIN1	12-LinearLayer[1905]-Tanh-2-1	Aktivní
B-NN_LIN2	12-LinearLayer[3490]-Tanh-2-1	Aktivní
B-NN_LIN3	12-LinearLayer[3470]-Tanh-2-1	Aktivní
B-NN_LIN4	12-LinearLayer[4810]-Tanh-2-1	Aktivní
B-NN_LIN5	12-LinearLayer[6035]-Tanh-2-1	Aktivní

Zdroj: Vlastní.

Tabulka 30 nabízí výsledky NN obsahující GRL vrstvu.

Tabulka 30 Výsledky NN obsahující GRL vrstvu

ID sítě	Název sítě	Predikce
B-NN_GRL1	12-GatedRecurrentLayer[3990]-LogisticSigmoid-Tanh-2-1	Aktivní
B-NN_GRL2	12-GatedRecurrentLayer[4705]-Sin-LogisticSigmoid-2-1	Aktivní
B-NN_GRL3	12-GatedRecurrentLayer[3390]-Tanh-LogisticSigmoid-1	Aktivní
B-NN_GRL4	12-GatedRecurrentLayer[4985]-Tanh-Ramp-2-1	Aktivní
B-NN_GRL5	12-GatedRecurrentLayer[3640]-LogisticSigmoid-Tanh-2-1	Aktivní

Zdroj: Vlastní.

Tabulka 31 prezentuje výsledky NN obsahující LSTM vrstvu.

Tabulka 31 Výsledky NN obsahující LSTM vrstvu

ID sítě	Název sítě	Predikce
B-NN_LSTM1	12-LongShortTermMemoryLayer[2600]-Ramp-LogisticSigmoid-Ramp-2-1	Aktivní
B-NN_LSTM2	12-LongShortTermMemoryLayer[4025]-Sin-Ramp-LogisticSigmoid-2-1	V likvidaci
B-NN_LSTM3	12-LongShortTermMemoryLayer[275]-LogisticSigmoid-Ramp-LogisticSigmoid-2-1	V likvidaci
B-NN_LSTM4	12-LongShortTermMemoryLayer[2820]-Tanh-LogisticSigmoid-Tanh-2-1	V likvidaci
B-NN_LSTM5	12-LongShortTermMemoryLayer[2705]-LogisticSigmoid-Ramp-Tanh-2-1	V likvidaci

Zdroj: Vlastní.

Závěr finanční analýzy společnosti CHNC, a.s.

Analýzou finanční stránky společnosti CHNC, a.s. bylo zjištěno, že v důsledku fúze, je v prvním roce sledovaného období (rok 2014) evidován záporný vlastní kapitál. Právě fúzí akciové společnosti CHNC, a.s. a společností GOS, A.S., kdy nástupnickou společností je právě společnost CHNC, a.s. (rozhodný den od 1. ledna 2013), byl nákup obchodního podílu na společnosti CHNC, a.s. a společností GOS, A.S. v rámci sloučeného účetnictví zaúčtován jako snížení vlastního kapitálu, jako záporný ostatní kapitálový fond.

Mimo tuto skutečnost společnost CHNC, a.s. v období 2014–2019 vždy vykazovala zisk, který se za sledované období více jak zjedenačtinásobil. V roce 2014 výsledek hospodaření před zdaněním byl 29 409 tis. Kč a v roce 2019 již 328 664 tis. Kč.

Celková aktiva po celou sledovanou dobu kontinuálně rostla (vyjímaje roku 2018, kdy byl zaznamenán mírný pokles). Na začátku sledovaného období disponovala společnost aktivy v hodnotě 339 408 tis. Kč, po šesti letech se celková aktiva více než zdvojnásobila a dosahovala 1 053 273 tis. Kč. Rostoucí vývoj aktiv je obecně považován jako pozitivní a chtěnou změnu podniku.

Po celé období byla společnost financována z větší části z cizích zdrojů, přičemž postupem času se stále zvyšovalo zastoupení vlastního kapitálu na celkových pasivech. V roce 2016, jak je již zmíněno výše, akciová společnost CHNC, a.s. vykázala záporný vlastní kapitál ve výši -64,8 % celkových pasiv, po šesti letech v roce 2019 činil vlastní kapitál již 31,2 %. Rostoucí tendence vlastního kapitálu, alespoň do výše 50 % pasiv je vnímána jako pozitivní jev. Od roku 2016 vykazovala nulový výsledek hospodaření minulých let, který byl v minulosti záporný.

Ukazatele likvidity byly vždy vyměřeny jako nadprůměrné z důvodu vlastnění velkého množství peněžních prostředků, které až na rok 2016 vždy převyšovaly hodnotu krátkodobých závazků.

Záporný vlastní kapitál zapříčinil i záporný výsledek zadluženosti I. v roce 2014. V dalších letech 2015 a 2016 zadluženost I. měla vysoké hodnoty hlavně z důvodu, že cizí kapitál markantně převyšoval vlastní kapitál. V dalších letech se zadluženost I. výrazně snížila především kvůli nárůstu vlastního kapitálu.

Komplexní hodnocení CHNC, a.s. dle indexu bonity přineslo pozitivní výsledek. Po celé období podnik spadal do zóny bonitních podniků. Pouze v prvním roce index bonity dosáhl nejhorší hodnoty 1,22 s výsledkem dobrého ekonomického hodnocení. Od roku 2015 se bonita zlepšila a po zbytek sledovaného období dle indexu bonity byla společnost v extrémně dobré finanční situaci.

Finanční stránka společnosti CHNC, a.s. byla negativně poznamenána fúzí se společností GOS, A.S., kdy k roku 2014 měla horší výsledky, než tomu je v dalších letech. Na druhou stranu, společnost právě od tohoto roku začala zlepšovat svoji finanční kondici, která se projevila například nárůstem výsledku hospodaření před zdaněním, aktiv, vlastního kapitálu, rentabilitou aktiv, rentabilitou vlastního kapitálu atd.

5.2.2 SAF, a.s.


Důležité je zmínit, že společnost SAF, A.S. ve sledovaném období nevykázala žádné tržby z prodeje zboží a tržby z prodeje výrobků a služeb (vyjma roku 2014, kdy tyto tržby byly v porovnání s VH mizivé). Oblast působení této společnosti je poskytování úvěrů a půjček, proto pro následující výpočty jsou hodnoty „tržeb“ zaměněny hodnotami „výnosových úroků“ plynoucích z poskytnutých úvěrů – výnosové úroky z poskytnutých úvěrů, lze tedy chápat jako tržby za poskytnuté služby.

Horizontální analýza

Vývoj aktiv a pasiv

Grafy na Obrázcích 63 a 64 znázorňují vývoj aktiv a pasiv společnosti SAF, A.S. v období 2015–2020.

Obrázek 63 Vývoj aktiv společnosti SAF, A.S. (v tis. Kč)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Celková aktiva společnosti SAF, A.S. za šestileté sledované období zaznamenala nárůst, především největší kladná meziroční změna aktiv byla zaznamenána mezi lety 2018–2019. Do roku 2018 byl stav majetku v podstatě neměnný. Změna však nastala v roce 2019, kdy došlo k snížení dlouhodobého majetku a zároveň ke skokovému nárůstu oběžných aktiv v podobě dlouhodobých pohledávek. Nárůst oběžných aktiv byl větší než pokles dlouhodobého majetku, co mělo ve výsledku vliv na celkové zvýšení aktiv na 1 485 879 tis. Kč roku 2019. V nadcházejícím období celková aktiva vzrostla na konečných 1 631 539 tis. Kč.

Obrázek 64 Vývoj pasiv společnosti SAF, A.S. (v tis. Kč)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Vývoj pasiv zkoumané společnosti, stejně tak jako vývoj aktiv, měl v průběhu času rostoucí tendenci. Růst od roku 2018 celkových pasiv zapříčinil především nárůst cizího kapitálu – dlouhodobých závazků v podobě vydaných dluhopisů. V letech 2016-2018 výše emitovaných dluhopisů činila 1 000 000 tis. Kč, v následujícím roce již 1 309 000 tis. Kč poté 1 389 000 tis. Kč. Z grafu není příliš patrný vývoj vlastního kapitálu, ale v každém období došlo k jeho nárůstu. V roce 2015 činil vlastní kapitál 2 981 tis. Kč a o šest let déle 61 564 tis. Kč.

Vývoj výsledku hospodaření před zdaněním

Tabulka 32 a graf na Obrázku 65 informují o hospodaření společnosti (před zdaněním) za období 2015–2019.

Tabulka 32 Vývoj VH před zdaněním společnosti SAF, A.S. (v tis. Kč)


Rok	HV před zdaněním	Rok	HV před zdaněním
2015	2 976 tis. Kč	2018	7 685 tis. Kč
2016	4 580 tis. Kč	2019	47 848 tis. Kč
2017	7 690 tis. Kč	2020	1 292 tis. Kč

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z tabulkového a grafického zobrazení vývoje VH před zdaněním je zřejmé, že SAF, A.S. každoročně vykázala kladný hospodářský výsledek před zdaněním. Každé následující období doprovázelo navýšení zisku – pouze v období 2018 byla zaznamenána stagnace. Nejlepšího výsledku hospodaření společnost docílila roku 2019 ve výši 47 848 tis. Kč. Za osmiměsíční období roku 2020 byl dosažen HV před zdaněním ve výši 1 292 tis. Kč, nelze tento výsledek rovnocenně porovnat z ostatními, jelikož ostatní období jsou data převzata za celý rok.


Obrázek 65 Vývoj VH před zdaněním společnosti SAF, A.S. (v tis. Kč)



Zdroj: Vlastní.

Následující graf na Obrázku 66 představuje vývoj výsledku hospodaření před zdaněním za prvních osm měsíců roku 2020 společnosti SAF, A.S. v tis. Kč. Obchodní korporace SAF, A.S. je specifická svojí podnikatelskou činností, kdy její hlavní výnosové a nákladové položky tvoří výnosové, popř. nákladové úroky z poskytnutých, popř. přijatých úvěrů a půjček. Z grafu je zřejmé, že v prvních dvou měsících společnost nevykazovala téměř žádnou aktivitu. Výsledek hospodaření začala tvořit až od 3. měsíce daného roku, to bylo způsobeno tím, že výnosové (nákladové) úroky z poskytnutých (přijatých) úvěrů byly obdrženy (vypláceny) čtvrtletně.

Obrázek 66 Vývoj VH před zdaněním za jednotlivé měsíce roku 2020 společnosti SAF, A.S. (v tis. Kč)



Zdroj: Vlastní.

Vertikální analýza

Prostřednictvím vertikální analýzy je analyzována struktura aktiv a pasiv zkoumané společnosti (Tabulka 33 a 34). V tomto případě lze aktiva a pasiva označit za syntetické ukazatele (tvoří 100 %), které jsou podrobeny rozkladu na dílčí části. Cílem vertikální analýzy je určit strukturu, tj. procentuální zastoupení dílčích ukazatelů na syntetických.

Tabulka 33 Vertikální analýza aktiv společnosti SAF, A.S.

Položka	2015	2016	2017	2018	2019	2020
Aktiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Dl. majetek	99,6 %	98,9 %	98,4 %	97,9 %	40,4 %	36,8 %
Dl. majetek hmotný	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Dl. majetek nehmotný	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Dl. majetek finanční	99,6 %	98,9 %	98,4 %	97,9 %	40,4 %	36,8 %
Oběžná aktiva	0,4 %	0,7 %	1,2 %	1,7 %	59,5 %	63,2 %
Zásoby	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Dl. pohledávky	0,0 %	0,0 %	0,0 %	0,0 %	48,0 %	51,2 %
Kr. pohledávky	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,1 %
Kr. majetek finanční	0,4 %	0,7 %	1,2 %	1,7 %	11,5 %	12,0 %
Časové rozlišení aktiv	0,0 %	0,4 %	0,4 %	0,4 %	0,2 %	0,0 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z vertikální analýzy aktiv zkoumané společnosti lze vyčíst, že struktura majetku se v prvních čtyřech letech (tj. 2015–2018) výrazným způsobem nelišila. V tomto období hlavní podíl celkových aktiv tvořil dlouhodobý majetek, konkrétně dlouhodobý finanční majetek ve výši vždy nad 97 %. Výrazná změna struktury majetku nastala až v roce 2019, kdy byl zaznamenán skokový nárůst oběžného majetku, který dokonce tvořil necelých 60 % aktiv, zbylých 40 % připadalo dlouhodobému finančnímu majetku. V období 2020 společnost měla téměř identické zastoupení majetkových položek, jak tomu bylo i o rok dříve.

Tabulka 34 Vertikální analýza pasiv společnosti SAF, A.S.

Položka	2015	2016	2017	2018	2019	2020
Pasiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Vlastní kapitál	0,7 %	0,9 %	1,5 %	2,1 %	4,1 %	3,8 %
Základní kapitál	0,4 %	0,3 %	0,3 %	0,3 %	0,2 %	0,2 %
Fondy	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
VH minulých let	0,0 %	0,2 %	0,6 %	1,2 %	1,3 %	3,5 %
VH běžného úč. období	0,3 %	0,4 %	0,6 %	0,6 %	2,6 %	0,1 %
Cizí zdroje	99,3 %	98,7 %	98,1 %	97,5 %	95,6 %	96,2 %
Dl. závazky	99,3 %	98,7 %	98,1 %	97,5 %	88,1 %	85,1 %
Rezervy	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Kr. závazky	0,1 %	0,0 %	0,1 %	0,0 %	7,5 %	11,1 %
Časové rozlišení pasiv	0,0 %	0,4 %	0,4 %	0,4 %	0,3 %	0,0 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Po celé sledované období společnost kryla své zdroje z hlavní části zdroji cizími. Vlastní kapitál společnosti SAF, A.S. tvořil pouhé desetiny a jednotky procent celkových pasiv. Dominantní položkou cizího kapitálu byly po celé období dlouhodobé závazky v podobě emitovaných dluhopisů. Roku 2019 byl zaznamenán i výrazný nárůst krátkodobých závazků, které tvořily 7,5 % celkových aktiv. V dalších období vzrostly krátkodobé závazky o další čtyři procentní body na celých 11,1 %.

Analýza poměrových ukazatelů

Následující odstavce obsahují výpočet a popis poměrových ukazatelů, konkrétně ukazatelů rentability, likvidity a zadluženosti společnosti SAF, A.S. Společnost ve sledovaném období nevykázala žádné tržby z prodeje zboží a tržby z prodeje výrobků a služeb (vyjma roku 2014). Oblast působení této společnosti je poskytování úvěrů a půjček, proto pro následující výpočty jsou hodnoty „tržeb“ zaměněny hodnotami „výnosových úroků“ plynoucích z poskytnutých úvěrů – výnosové úroky z poskytnutých úvěrů lze tedy chápat jako tržby za poskytnuté služby.

Ukazatele rentability

V následující Tabulce 35 jsou uvedeny ukazatele rentability společnosti SAF, A.S. za sledované období 2015–2020.

Tabulka 35 Ukazatele rentability společnosti SAF, A.S. (v procentech)


Položka	2015	2016	2017	2018	2019	2020
ROA	8,02	11,11	11,54	11,48	11,44	4,19
ROE	1190,28	1236,86	767,66	545,95	282,01	111,13
ROCE	8,03	11,16	11,59	11,52	12,41	4,72
ROS	98,78	99,88	99,96	99,96	130,18	99,91

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Pro výpočet rentability tržeb je namísto celkových tržeb (tj. tržby z prodeje zboží a tržby z prodeje výrobků a služeb) použita hodnota úrokových výnosů z důvodu povahy společnosti. Rentabilita aktiv roku 2016 zaznamenala nárůst z předešlých 8,02 % na 11,11 % (viz. Obrázek 96). Po zbytek sledovaného období, až do roku 2019 ROA oscilovala kolem hodnoty 11,5 %. V roce 2020 rentabilita aktiv zaznamenala značný pokles, který byl zapříčiněn jednak poklesem ukazatele EBIT a také, že údaje k tomuto období jsou ke dni 31. 8. daného roku.

Obrázek 67 Vývoj ROA společnosti SAF, A.S. (v procentech)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Uvedený Obrázek 68 obsahuje grafické zobrazení vývoje rentability vlastního kapitálu společnosti SAF, A.S. v období 2015–2020. Z grafu je patrné, že ve sledovaném období ukazatel ROE klesal. Tento pokles byl způsoben značným nárůstem vlastního kapitálu i přes skutečnost, že EBIT v průběhu let rostl (vyjma roku 2020). I přes tento pokles rentabilita vlastního kapitálu společnosti SAF, A.S. dosahovala vysokých hodnot.

Obrázek 68 Vývoj ROE společnosti SAF, A.S. (v procentech)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele likvidity

V následující Tabulce 36 jsou uvedeny ukazatele aktivity společnosti SAF, A.S. za sledované období 2015–2020.

Tabulka 36 Ukazatele likvidity společnosti SAF, A.S.

Položka	2015	2016	2017	2018	2019	2020
Běžná likvidita	5,674	16,464	16,071	60,520	7,923	5,707
Pohotová likvidita	5,674	16,464	16,071	60,520	1,529	1,086
Hotovostní likvidita	5,674	16,464	16,071	60,520	1,529	1,081


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Likvidita zkoumané společnosti na uvedených úrovních v průběhu sledovaného období vykazovala vysokých hodnot. V každém případě měla SAF, A.S. dostatek peněžních prostředků na uhrazení svých krátkodobých závazků, avšak vysoké hodnoty poukazují na vázání mnoha aktiv ve formě pohotových prostředků, které přinášejí minimální úrok (Vochozka et al., 2020). V porovnání s ostatními roky nižší naměřené hodnoty pohotové a hotovostní likvidity roku 2019 byly vyvolány nárůstem krátkodobých závazků.

V období 2015–2018 byla v každém roce běžná, pohotová i hotovostní likvidita ve stejné výši – bylo tomu z důvodu, že peněžních prostředky tvořily 100 % oběžných aktiv (Obrázek 69).

Obrázek 69 Vývoj likvidity společnosti SAF, A.S.



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele zadluženosti

V následující Tabulce 37 jsou uvedeny ukazatele zadluženosti společnosti SAF, A.S. za sledované období 2015–2020.

Tabulka 37 Ukazatele zadluženosti společnosti SAF, A.S.

Položka	2015	2016	2017	2018	2019	2020
Zadluženost I.	147,342	109,915	65,276	46,404	23,568	25,498
Zadluženost II.	0,993	0,987	0,981	0,975	0,956	0,962
Úrokové krytí	1,049	1,042	1,070	1,070	1,392	1,019


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Vochozka et al. (2020) zmiňují, že bezpečnou mírou zadlužení je 40 % cizího kapitálu v poměru k vlastnímu, jinými slovy že ukazatel zadluženosti I. v bezpečném zadlužení podniku by měl být 0,40. Ani v jednom období z výše uvedených se SAF, A.S. nedokázala této hodnotě přiblížit. Naměřené hodnoty poukazují na vysokou zadluženost společnosti, která v minulosti byla vyvolána enormním převýšením cizího kapitálu nad vlastním.

Pozitivnější výsledky vykazovalo v jednotlivých letech úrokové krytí, které vždy převýšilo hranici 1. Společnost tedy v každém roce byla schopna uhradit ze zisku své nákladové úroky (Obrázek 70).

Obrázek 70 Vývoj ukazatelů zadluženosti společnosti SAF, A.S.



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Komplexní hodnocení podniku

Pro komplexní hodnocení podniku SAF, A.S. je využito indexu IN95 a indexu IN99. Bonita společnosti není měřena prostřednictvím indexu bonity z důvodu absence zásob, které vstupují do jeho výpočtu a mají vliv na vyhodnocení bonity společnosti. Není využito ani modifikovaného Tafflerova indexu, jelikož charakter společnosti stojí na půjčování si finančních prostředků a následném poskytování úvěrů v dlouhodobém měřítku – společnost má zanedbatelné zastoupení krátkodobých závazků, který se u výpočtu modifikovaného Tafflerova indexu využívají.

Index IN95

V následující Tabulce 38 je uveden index IN95 společnosti SAF, A.S. za sledované období 2015–2020.

Tabulka 38 Index IN95 společnosti SAF, A.S.

Index IN95	Váha	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	0,022	1,01	1,01	1,02	1,03	1,05	1,04
EBIT/nákladové úroky	0,11	1,05	1,04	1,07	1,07	1,39	1,02
EBIT/aktiva	8,33	0,08	0,11	0,12	0,11	0,11	0,04
Výnosy/aktiva	0,52	0,08	0,11	0,12	0,11	0,09	0,04
Oběžná aktiva/kr. cizí kapitál	0,10	5,67	16,46	16,07	60,52	7,92	5,71
Závazky po spl. / výnosy	-16,80	0,00	0,00	0,00	0,00	0,00	0,00
Index IN95		1,42	2,77	2,77	7,21	1,97	1,08
Hodnocení		Šedá zóna	Bonitní podnik	Bonitní podnik	Bonitní podnik	Šedá zóna	Šedá zóna

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Zkoumaná společnost byla delší část sledovaného období označována jako bonitní podnik. Přitom nejlepšího výsledku dosáhla v roce 2018, kdy index IN95 byl ve výši 7,21. Nejhorší výsledek byl naopak vykázan v roce 2015. V tomto období podnik se přibližoval více zóně bankrotních podniků nežli bonitním.

Index IN99

V následující tabulce je uveden index IN99 společnosti SAF, A.S. za sledované období 2015–2020.

Tabulka 39 Index IN99 společnosti SAF, A.S.

Index IN99	Váha	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	-0,017	1,01	1,01	1,02	1,03	1,05	1,04
EBIT/aktiva	4,57	0,08	0,11	0,12	0,11	0,11	0,04
Výnosy/aktiva	0,48	0,08	0,11	0,12	0,11	0,09	0,04
Oběžná aktiva/kr. cizí kapitál	0,02	5,67	16,46	16,07	60,52	7,92	5,71
Index IN99		0,47	0,79	0,81	1,47	0,67	0,28
Hodnocení		Podnik netvoří hodnotu	Podnik spíše netvoří hodnotu	Podnik spíše netvoří hodnotu	Šedá zóna	Podnik netvoří hodnotu	Podnik netvoří hodnotu

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Společnost SAF, A.S. není dle metody IN99 hodnocena pozitivně. Podnik netvořil ve sledovaném období hodnotu. Ač se hodnoty v čase především díky běžné likviditě (tj. ukazatel oběžná aktiva / krátkodobý cizí kapitál) mění, nejde o tak významné změny, aby měly za následek pozitivní hodnocení celého podniku. V ideálním případě, v období 2018 se podnik dostal do šedé zóny – tento „nejlepší“ výsledek byl způsoben především poklesem krátkodobého kapitálu.

Aplikované metody komplexního hodnocení podniku na bázi NN

Tabulka 40 přináší výsledky vícevrstvých perceptronových sítí.

Tabulka 40 Výsledky vícevrstvých perceptronových sítí

ID sítě	Název sítě	Predikce
B-NN_LIN1	12-LinearLayer[1905]-Tanh-2-1	V likvidaci
B-NN_LIN2	12-LinearLayer[3490]-Tanh-2-1	Aktivní
B-NN_LIN3	12-LinearLayer[3470]-Tanh-2-1	Aktivní
B-NN_LIN4	12-LinearLayer[4810]-Tanh-2-1	Aktivní
B-NN_LIN5	12-LinearLayer[6035]-Tanh-2-1	V likvidaci

Zdroj: Vlastní.

Tabulka 41 nabízí výsledky NN obsahující GRL vrstvu.

Tabulka 41 Výsledky NN obsahující GRL vrstvu

ID sítě	Název sítě	Predikce
B-NN_GRL1	12-GatedRecurrentLayer[3990]-LogisticSigmoid-Tanh-2-1	V likvidaci
B-NN_GRL2	12-GatedRecurrentLayer[4705]-Sin-LogisticSigmoid-2-1	V likvidaci
B-NN_GRL3	12-GatedRecurrentLayer[3390]-Tanh-LogisticSigmoid-1	V likvidaci
B-NN_GRL4	12-GatedRecurrentLayer[4985]-Tanh-Ramp-2-1	V likvidaci
B-NN_GRL5	12-GatedRecurrentLayer[3640]-LogisticSigmoid-Tanh-2-1	V likvidaci

Zdroj: Vlastní.

Tabulka 42 prezentuje výsledky NN obsahující LSTM vrstvu.

Tabulka 42 Výsledky NN obsahující LSTM vrstvu

ID sítě	Název sítě	Predikce
B-NN_LSTM1	12-LongShortTermMemoryLayer[2600]-Ramp-LogisticSigmoid-Ramp-2-1	V likvidaci
B-NN_LSTM2	12-LongShortTermMemoryLayer[4025]-Sin-Ramp-LogisticSigmoid-2-1	V likvidaci
B-NN_LSTM3	12-LongShortTermMemoryLayer[275]-LogisticSigmoid -Ramp-LogisticSigmoid-2-1	V likvidaci
B-NN_LSTM4	12-LongShortTermMemoryLayer[2820]-Tanh-LogisticSigmoid-Tanh-2-1	V likvidaci
B-NN_LSTM5	12-LongShortTermMemoryLayer[2705]-LogisticSigmoid-Ramp-Tanh-2-1	V likvidaci

Zdroj: Vlastní.

Závěr finanční analýzy společnosti SAF, A.S.

U zkoumané společnosti je důležité upozornit na skutečnost, že SAF, A.S. se nechová jako „běžná“ obchodní společnost. Obchodní model společnosti je založen na získávání peněžních prostředků od věřitelů (z emise dluhopisů) a další poskytování těchto peněžních prostředků ve formě nakoupení cenných papírů od dalších osob. Realizovaný výsledek hospodaření je tak vysokou měrou ovlivněn rozdílem mezi nákladovými úroky z vydaných dluhopisů, které společnost hradí věřitelům, a výnosovými úroky obdržených z nakoupených cenných papírů. Z tohoto důvodu jsou v jednotlivých metodách zaměněny výnosové úroky za celkové tržby, protože tyto přijaté úroky mají charakter tržeb.

Po celé sledované období, tj. 2015–2020, SAF, A.S. vykázala kladný hospodářský výsledek – zisk. Průběh zisku v čase měl vzestupnou tendenci, kdy nejnižší VH před zdaněním byl vykázán roku 2015 ve výši 2 976 tis. Kč naopak nejvyšší v roce 2019 ve výši 47 848 tis. Kč. Stejný vývoj jako VH před zdaněním zaznamenala i celková aktiva, v průběhu sledovaného času došlo k navýšení celkových aktiv téměř o dvojnásobek – z 799 860 Kč (rok 2015) na 1 485 879 Kč (rok 2019). V letech 2015–2018 celková aktiva tvořila vždy z převládající části

dlouhodobý finanční majetek – vždy okolo 98–99 %. Změna nastala posledního roku sledovaného období, kdy došlo ke snížení dlouhodobého finančního majetku, ale zároveň k navýšení oběžného majetku v podobě dlouhodobých pohledávek. Ve sledovém období byla SAF, A.S. financována hlavně cizími zdroji – emitovanými dluhopisy. Výše vydaných dluhopisů se pohybovala ve sledovaném období v rozmezí 793 903 tis. Kč – 1 309 000 tis. Kč. Rentabilita aktiv od roku 2016 zaznamenala nárůst z předešlých 8,02 % na 11,11 %. Po zbytek sledovaného období ROA oscilovala kolem hodnoty 11,5 %.

Naměřené ukazatele likvidity dosahovaly vyšších hodnot než doporučených, které uvádí odborná literatura (např. Vochozka et al., 2020). Znamenalo to, že společnost byla po celé období schopna z příslušných aktiv hradit své krátkodobé závazky, ale zároveň vážala mnoho aktiv ve formě pohotových prostředků, které společnosti přinášely minimální úrok.

Komplexní metody hodnocení podniku odhalily, že se společnost nenacházela v ideálním postavení. Relativně pozitivní výsledek přinesl index IN95, kdy se SAF, A.S. pohybovala v zóně bonitních podniků a šedé zóně. Avšak horší hodnocení ekonomické situace podniku přinesl právě index IN99, kde ani v jednom roce sledovaného období společnost netvořila hodnotu. V nejlepším případě se dostala v roce 2018 do šedé zóny s výsledkem 1,47 indexu IN99 – v tomto roce se tak podnik nejvíce přiblížil bodu, odkud je tvořena hodnota.

Při náhledu na finanční zdraví společnosti SAF, A.S. z širšího hlediska, je nutné poznamenat, že společnost i přes horší výsledky komplexních metod, vykazovala následující pozitivní ukazatele, které vypovídají o celkové dobré finanční kondici podniku. Celková aktiva zaznamenala každoroční nárůst. Stejně tak i každoročně společnost navýšovala vlastní kapitál, na kterém měl především velký podíl rostoucí kladný hospodářský výsledek. Dobré výsledky vykazaly i poměrové ukazatele, především ukazatele rentability a likvidity.

5.2.3 TP, a.s.

Tato kapitola je věnována rozboru finančního zdraví společnosti TP, a.s. prostřednictvím finanční analýzy. Finanční analýza je zpracována v tomto rozsahu:

- horizontální analýza pro posouzení vývoje aktiv, pasiv a výsledku hospodaření,
- vertikální analýza aktiv a pasiv,
- analýza poměrových ukazatelů (rentabilita, aktivita, likvidita a zadluženost),
- komplexní hodnocení podniku (index bonity, index IN95, index IN99, mod. Tafflerův index).


Všechna uváděná data v této kapitole (tj. kapitola 0) k roku 2020 jsou vztažena k datu ocenění, tj. 31. 8. 2020.

Horizontální analýza

Vývoj aktiv a pasiv

Obrázky 71 a 72 znázorňují vývoj aktiv a pasiv společnosti TP, a.s. v období 2013–2020.

Obrázek 71 Vývoj aktiv společnosti TP, a.s. (v tis. Kč)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z grafu je zřejmé, že vývoj aktiv za sledované období neprodělal žádné výrazné změny. V každém roce se dlouhodobý majetek společnosti pohyboval v rozmezí 500 000 tis. Kč – 650 000 tis. Kč, při čemž dominantní zastoupení dlouhodobého majetku tvořil vždy dlouhodobý finanční majetek. Oběžný majetek od roku 2014 postupně rostl až do roku 2016, kde dosáhl svého maxima 1 000 000 tis. Kč. Od tohoto bodu nastal prudký pokles, který se zastavil za 2 účetní období, kdy oběžná aktiva nedosáhla ani poloviny předloňského roku. Příčina nárůstu a poklesu oběžných aktiv za sledované období je zejména dána vývojem krátkodobých pohledávek a peněžních prostředků.

Obrázek 72 Vývoj pasiv společnosti TP, a.s. (v tis. Kč)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Po celé sledované období společnost kryla své zdroje z větší části cizími zdroji. Největší rozdíl mezi vlastním a cizím kapitálem nastal v roce 2017, kdy TP, a.s. vznikly (oproti ostatním rokům ve výrazné výši) krátkodobé závazky z obchodních vztahů, které mají vliv na výraznější nárůst cizího kapitálu v tomto roce. V období 2017 nastal zároveň i značný pokles vlastního kapitálu, konkrétně základního kapitálu. Vlastní kapitál oproti předešlému období klesl z 732 689 tis. Kč na 164 767 tis. Kč.

Vývoj výsledku hospodaření před zdaněním

Následující Tabulka 43 a Obrázek 73 informují o hospodaření společnosti (před zdaněním) za období 2013–2020.

Tabulka 43 Vývoj VH před zdaněním společnosti TP, a.s. (v tis. Kč)

Rok	HV před zdaněním	Rok	HV před zdaněním
2013	66 455 tis. Kč	2017	11 355 tis. Kč
2014	16 002 tis. Kč	2018	121 628 tis. Kč
2015	151 285 tis. Kč	2019	179 165 tis. Kč
2016	208 987 tis. Kč	2020	54 600 tis. Kč


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z níže uvedeného grafického zobrazení výsledku hospodaření po zdanění společnosti TP a.s. (Obrázek 102), je patrné, že společnost ve sledovaném období v každém roce vykazovala zisk. Tvar vývoje výsledku hospodaření před zdaněním připomíná sinusoidu, přičemž za sledované období se střídaly roky s lepším i horším výsledkem hospodaření. Nejmenší VH před zdaněním byl vykázán v roce 2017 ve výši 11 355 tis. Kč. Naopak nejvyšší hodnotu VH před zdaněním

společnosti dosáhla v roce 2016 a 2019, kdy v obou případech se nezdaněný zisk pohyboval okolo 200 000 tis. Kč.

Obrázek 73 Vývoj VH před zdaněním společnosti TP, a.s. (v tis. Kč)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Na první pohled z výše uvedeného grafu na Obrázku 73 je HV před zdaněním společnosti TP, a.s. za rok 2020 zkreslený, jelikož data jsou brána k 31. 8. 2020, nikoli ke konci roku. Z tohoto důvodu je uvedeno i grafické zobrazení vývoje hospodářského výsledku před zdaněním za jednotlivé měsíce roku 2020, které má lepší vypovídací hodnotu než předešlý graf (Obrázek 74).

Obrázek 74 Vývoj VH před zdaněním (za jednotlivé měsíce) roku 2020 společnosti TP, a.s. (v tis. Kč)



Zdroj: Vlastní.

Z Obrázku 74 je patrné, že v prvních 8 měsících roku 2020 měl vývoj VH před zdaněním společnosti TP, a.s. rostoucí tendenci. Naopak v lednu tohoto roku byl hospodářský výsledek

dokonce záporný. Sledování VH po jednotlivých měsících není zcela vhodné, protože toto sledování naráží na princip akuality. Kdy například náklady vynaložené v lednu (např. v podobě marketingu) se projeví ve výnosových položkách (např. tržby za služby) až po několika měsících. Měsíční růst zisku byl zapříčiněn především růstem tržeb z výrobků a služeb. Dále VZZ je kumulativním výkazem, za dané období, tedy rostoucí tendence je očekávatelná již i ze samotného pojení daného výkazu.

Vertikální analýza

Prostřednictvím vertikální analýzy je analyzována struktura aktiv a pasiv zkoumané společnosti (Tabulka 44 a 45). V tomto případě lze aktiva a pasiva označit za syntetické ukazatele (tvoří 100 %), které jsou podrobeny rozkladu na dílčí části. Cílem vertikální analýzy je určit strukturu, tj. procentuální zastoupení dílčích ukazatelů na syntetických.

Tabulka 44 Vertikální analýza aktiv společnosti TP, a.s.

Položka	2013	2014	2015	2016	2017	2018	2019	2020
Aktiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Dl. majetek	41,9 %	50,2 %	46,1 %	37,0 %	49,2 %	63,4 %	53,1 %	68,7 %
Dl. majetek hmotný	5,4 %	4,8 %	3,7 %	2,7 %	1,4 %	1,2 %	0,8 %	0,7 %
Dl. majetek nehmotný	1,6 %	1,1 %	0,8 %	0,4 %	0,4 %	0,8 %	0,4 %	0,3 %
Dl. majetek finanční	34,9 %	44,3 %	41,7 %	33,9 %	47,4 %	61,4 %	51,9 %	67,6 %
Oběžná aktiva	53,9 %	47,8 %	53,1 %	62,7 %	50,4 %	36,0 %	46,3 %	31,2 %
Zásoby	2,5 %	1,4 %	0,7 %	0,4 %	0,0 %	0,0 %	0,0 %	0,0 %
Dl. pohledávky	0,2 %	0,0 %	0,0 %	4,5 %	3,1 %	8,0 %	10,8 %	11,0 %
Kr. pohledávky	24,8 %	17,1 %	22,8 %	24,9 %	8,3 %	4,7 %	21,8 %	8,4 %
Kr. majetek finanční	26,5 %	29,3 %	29,6 %	32,9 %	39,1 %	23,3 %	13,6 %	11,8 %
Časové rozlišení aktiv	4,2 %	2,0 %	0,8 %	0,3 %	0,4 %	0,6 %	0,6 %	0,1 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Podíl dlouhodobých a oběžných aktiv na celkových aktivech byl ve sledovaném období proměnlivý, avšak v každém období jedna či druhá položka nepřekročila výši 69 % celkových aktiv. Dlouhodobý majetek pokaždé tvořil ze značné části dlouhodobý finanční majetek v podobě podílů v ovládaných a řízených osobách. Oběžná aktiva zahrnovala zejména krátkodobé pohledávky a krátkodobý finanční majetek. Zásoby a dlouhodobé pohledávky v jednotlivých letech tvořily nepatrnou část oběžných aktiv – v jejich součtu maximálně 11 % celkových aktiv. Časové rozlišení aktiv v jednotlivých letech zastupovalo minoritní postavení ve struktuře celkových aktiv, v každém roce čítalo jednotky procent.

Tabulka 45 Vertikální analýza pasiv společnosti TP, a.s.

Položka	2013	2014	2015	2016	2017	2018	2019	2020
Pasiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Vlastní kapitál	35,6 %	34,6 %	39,4 %	45,5 %	13,6 %	28,2 %	40,0 %	45,2 %
Základní kapitál	8,4 %	8,1 %	7,1 %	6,2 %	-39,1 %	-48,3 %	-42,9 %	-43,2 %
Fondy	1,7 %	1,6 %	1,4 %	-0,1 %	47,1 %	58,5 %	51,9 %	52,3 %
VH minulých let	21,1 %	24,7 %	22,0 %	28,2 %	4,9 %	6,6 %	16,0 %	31,2 %
VH běžného úč. období	4,5 %	0,2 %	8,9 %	11,3 %	0,6 %	11,4 %	15,0 %	5,0 %
Cizí zdroje	63,6 %	65,0 %	60,1 %	54,1 %	86,2 %	71,5 %	59,7 %	54,8 %
Dl. závazky	49,0 %	47,2 %	41,6 %	36,3 %	47,9 %	59,2 %	52,5 %	52,9 %
Kr. závazky	14,6 %	12,9 %	14,2 %	17,8 %	38,3 %	12,3 %	7,2 %	1,9 %
Časové rozlišení pasiv	0,8 %	0,4 %	0,5 %	0,3 %	0,2 %	0,3 %	0,3 %	0,0 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z vertikální analýzy pasiv lze vyčíst, že po celé sledované období cizí zdroje tvořily větší podíl na celkových pasivech, než to mu bylo u vlastního kapitálu. Struktura dílčích složek na celkových pasivech v letech 2013–2016 neutrpěla výrazných změn a procentuální zastoupení jednotlivých položek se změnilo o jednotky procent. Výrazná změna nastala od roku 2017, kdy společnost evidovala záporný základní kapitál⁶ a oproti předešlým obdobím v závislosti převedení vlastních podílů do vytvořených fondů ze zisku. Časové rozlišení pasivních položek v každém roce netvořilo ani 1 % pasiv. K roku 2017 společnost také vykázala výrazně nižší VH minulých let, který měl zásadní vliv na zastoupení vlastního kapitálu na celkových pasivech.

Analýza poměrových ukazatelů

Následující odstavce obsahují výpočet a popis poměrových ukazatelů, konkrétně ukazatelů rentability, aktivity, likvidity a zadluženosti společnosti TP, a.s.

Ukazatele rentability

V následující Tabulce 46 jsou uvedeny ukazatele rentability společnosti TP, a.s. za sledované období 2013–2020.

Tabulka 46 Ukazatele rentability společnosti TP, a.s. (v procentech)

Položka	2013	2014	2015	2016	2017	2018	2019	2020
ROA	9,58	6,91	15,72	17,31	6,65	19,43	22,44	9,18
ROE	26,93	19,96	39,87	38,01	49,07	68,99	56,14	20,29
ROCE	11,33	7,97	18,42	21,14	10,82	22,25	24,27	9,35
ROS	18,25	11,79	28,63	31,04	21,48	46,57	53,76	40,46


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

⁶ Základní kapitál je po celé sledované období ve výši 100 000 tis. Kč – v důsledku součtového řádku v rozvaze pasiv A. I. dochází k součtu základního kapitálu a vlastních podílů. Vlastní podíly byly ve sledovaném období záporné. Na první pohled však zkreslují skutečnou výši základního kapitálu, která byla neměnná. Ve výši vlastních podílů byly vytvořené fondy ze zisku.

Jak je patrné z Obrázku 75, rentabilita aktiv i vlastních zdrojů společnosti TP, a.s. měla mezi roky 2013–2020 téměř obdobný průběh. Výrazný výkyv rentability aktiv v roce 2017 byl doprovázen především poklesem výsledku hospodaření. Naopak nárůst rentability vlastního kapitálu od roku 2017 byl zapříčiněn snížením vlastního kapitálu.

Obrázek 75 Vývoj ROA a ROE společnosti TP, a.s. (v %)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele aktivity

V následující Tabulce 47 jsou uvedeny ukazatele aktivity společnosti TP, a.s. za sledované období 2013–2020.

Tabulka 47 Ukazatele aktivity společnosti TP, a.s.

Položka	2013	2014	2015	2016	2017	2018	2019	2020
Obrat aktiv	0,525	0,586	0,549	0,558	0,310	0,417	0,417	0,227
Doba obratu aktiv	685,791	614,628	655,635	645,470	1162,839	862,825	862,478	1587,219
Doba inkasa pohledávek	53,743	55,852	95,124	56,421	32,169	5,993	178,759	47,816
Doba splatnosti krátkodobých závazků	100,318	79,034	92,943	114,880	445,612	106,371	62,465	29,926

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Obrat aktiv je měřítkem celkového využití aktiv, v jiném slova smyslu informuje, kolikrát se celková aktiva v podniku obrátí za rok. Ukazatel obratu aktiv je maximalizační ukazatel a v ideálním případě by měl dosahovat co nejvyšších hodnot, minimálně však 1. TP, a.s. ani v jednom roce nedosáhla tížené hodnoty a její obrat aktiv dosahuje maximálně hodnoty 0,586 v roce 2014. Doba inkasa pohledávek podává informaci o tom, za kolik dní společnost inkasuje

své pohledávky. Markantní rozdíl nastává mezi lety 2018 a 2019, kdy se ukazatel doby inkasa pohledávek změnil z necelých 6 dnů na 179 dnů – tento rozdíl byl zapříčiněn zejména v nárůstu evidovaných pohledávek. Dle ukazatele doby splatnosti krátkodobých závazků lze určit za kolik dní společnost hradí své závazky. U doby splatnosti krátkodobých závazků byl nejvíce zajímavý rok 2017, kdy společnost TP, a.s. hradila své krátkodobé závazky za 445,6 dnů, což souvisí s celkovým vývojem struktury pasiv.

Ukazatele likvidity

V následující Tabulce 48 jsou uvedeny ukazatele likvidity společnosti TP, a.s. za sledované období 2013–2020.

Tabulka 48 Ukazatele likvidity společnosti TP, a.s. (v %)


Položka	2013	2014	2015	2016	2017	2018	2019	2020
Běžná likvidita	3,685	3,714	3,743	3,521	1,316	2,917	6,395	16,551
Pohotová likvidita	3,501	3,603	3,695	3,248	1,235	2,272	4,894	10,716
Hotovostní likvidita	1,808	2,276	2,088	1,847	1,019	1,891	1,883	6,277

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z provedeného šetření je zřejmé, že TP, a.s. mimo rok 2017 neměla žádné problémy s likviditou a dosahovala významně pozitivních hodnot, což lze přisuzovat obecně nízkému stavu závazků a vhodné výši příslušných aktiv. Negativní výkyv v roce 2017 byl způsoben výrazným meziročním nárůstem krátkodobých závazků a poklesem výsledku hospodaření minulých let (Obrázek 76).

Obrázek 76 Vývoj likvidity společnosti TP, a.s. (v %)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele zadluženosti

V následující Tabulce 49 jsou uvedeny ukazatele zadluženosti společnosti TP, a.s. za sledované období 2013–2020.

Tabulka 49 Ukazatele zadluženosti společnosti TP, a.s.

Položka	2013	2014	2015	2016	2017	2018	2019	2020
Zadluženost I.	1,788	1,876	1,524	1,189	6,362	2,539	1,494	1,211
Zadluženost II.	0,636	0,650	0,601	0,541	0,862	0,715	0,597	0,548
Úrokové krytí	2,379	1,230	3,177	4,006	1,163	2,750	3,578	2,179


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Informace o tom, že ukazatel zadluženosti I. po celé sledované období vychází vyšší než 1 je způsoben tím, že společnost kryla svůj majetek z větší části zdroji cizími nežli vlastními. Dramatický nárůst zadluženosti I. v období 2017 zapříčinil nárůst cizího kapitálu (konkrétně krátkodobých závazků z obchodních styků) a větší vahou i pokles vlastního kapitálu z důsledku nárůstu záporných vlastnických podílů. Obecně za základní bezpečnou míru zadlužení je bráno 40 % cizího kapitálu v poměru k vlastnímu (Vochozka et al., 2020) – od tohoto doporučeného poměru zadlužení se TP, a.s. výrazně odchyluje.

Úrokové krytí vždy ve sledovaném období převyšovalo hodnotu 1, tedy i přes případný pokles hodnoty zisku v minulých letech by byla společnost schopna uhradit úroky z celého zisku podniku. V posledních 3 letech byla hodnota úrokového krytí výrazně lepší, než tomu bylo v roce 2017 (Obrázek 77).

Obrázek 77 Vývoj zadluženosti společnosti TP, a.s. (v %)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Komplexní hodnocení podniku

Pro komplexní hodnocení podniku TP, a.s. je využito indexu bonity, indexu IN95, indexu IN99 a modifikovaného Tafflerova indexu.

Index bonity

V Tabulce 50 je uveden index bonity společnosti TP, a.s. za sledované období 2013–2020.

Tabulka 50 Index bonity společnosti TP, a.s.

Index bonity	Váha	2013	2014	2015	2016	2017	2018	2019	2020
Cash flow/cizí zdroje	1,5	0,07	0,03	0,17	0,21	0,01	0,16	0,25	0,09 ⁷
aktiva/Cizí zdroje	0,08	1,57	1,54	1,66	1,85	1,16	1,40	1,67	1,83
Zisk/aktiva	10	0,06	0,01	0,11	0,13	0,01	0,12	0,16	0,05
Zisk/výnosy	5	0,11	0,02	0,20	0,24	0,03	0,30	0,39	0,22
Zásoby/výnosy	0,3	0,05	0,02	0,01	0,01	0,00	0,00	0,00	0,00
Výnosy/aktiva	0,1	0,50	0,58	0,54	0,55	0,31	0,42	0,42	0,23
Index bonity		1,40	0,48	2,52	2,99	0,38	3,11	4,11	1,90
Hodnocení ekonomické situace	Dobrá	Problematická	Velmi dobrá	Velmi dobrá	Problematická	Extrémně dobrá	Extrémně dobrá	Dobrá	
	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Index bonity zkoumá, jaká je ekonomická situace konkrétního podniku. Ač je z konstrukce indexu bonity zřejmé, že jednotlivé roky byly posuzovány samostatně a je popřena meziroční vazba zkoumaných dat a výsledků. Po celé sledované období neklesl index bonity pod krizovou hodnotu 0, tedy je jisté že TP, a.s. nebyla v žádném období ohrožena bankrotem. Nejhorší bonitu měla společnost v letech 2014 a 2017, naopak v období 2018 a 2019 byla bonita podniku vyhodnocena jako extrémně dobrá. Hodnocení zkoumaného podnik dle jednotlivých let bez jakékoliv provázanosti vyšlo velmi kladné, až na roky 2014 a 2017, v nichž ekonomická situace podniku dle Indexu bonity byla problematická.

Index IN95

V Tabulce 51 je uveden index IN95 společnosti TP, a.s. za sledované období 2013–2020.

⁷ Pro rok 2020 se nerovná Cash flow součtu výsledku hospodaření po zdanění a odpisů (Vochozka et al., 2020) jako je tomu v předchozích letech, nýbrž součtu výsledku hospodaření před zdaněním a odpisů z důvodu, že za jednotlivé měsíce roku 2020 nebyla vyčíslena daň z příjmů právnických osob

Tabulka 51 Index IN95 společnosti TP, a.s.

Index IN95	Váha	2013	2014	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	0,022	1,57	1,54	1,66	1,85	1,16	1,40	1,67	1,83
EBIT/nákladové úroky	0,11	2,38	1,23	3,18	4,01	1,16	2,75	3,58	2,18
EBIT/aktiva	8,33	0,10	0,07	0,16	0,17	0,07	0,19	0,22	0,09
Výnosy/aktiva	0,52	0,50	0,58	0,54	0,55	0,31	0,42	0,42	0,23
Oběžná aktiva/kr. cizí kapitál	0,10	3,68	3,71	3,74	3,52	1,32	2,92	6,40	16,55
Závazky po spl. / výnosy	-16,80	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Index IN95		1,72	1,42	2,35	2,56	0,9997	2,46	3,16	2,82
Hodnocení		Šedá zóna	Šedá zóna	Bonitní podnik	Bonitní podnik	Bankr. podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Společnost TP, a.s. dle výsledků indexu IN95 prodělala za sledované období výrazné změny. V letech 2013 a 2014 podnik spadal do tzv. šedé zóny, u které nelze jednoznačně určit, zda jde o bonitní či bankrotní podnik, avšak v roce 2013 se podnik nacházel blízko bonitní zóny. V ostatních letech vyjímaje roku 2017 byla společnost vždy bonitní s nejlepším výsledkem v období 2019. Nejhorší výsledkem indexu IN95 byl jednoznačně rok 2017, kdy společnost spadla do zóny bankrotních podniků. Je zřejmé, že tento negativní výsledek je způsoben především snížením výsledku hospodaření a nárůstu cizího kapitálu. Určitou polehčující okolností je, že pokud by byl výsledek o tři tisíce lepší, podnik by již spadl do tzv. šedé zóny.

Index IN99

V Tabulce 52 je uveden index IN99 společnosti TP, a.s. za sledované období 2013–2020.

Tabulka 52 Index IN99 společnosti TP, a.s.

Index IN99	Váha	2013	2014	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	-0,017	1,57	1,54	1,66	1,85	1,16	1,40	1,67	1,83
EBIT/aktiva	4,57	0,10	0,07	0,16	0,17	0,07	0,19	0,22	0,09
Výnosy/aktiva	0,48	0,50	0,58	0,54	0,55	0,31	0,42	0,42	0,23
OA /kr. cizí kapitál	0,02	3,68	3,71	3,74	3,52	1,32	2,92	6,40	16,55
Index IN99		4,35	4,30	4,71	4,56	1,76	4,00	7,61	17,06
Hodnocení		Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik spíše tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Společnost TP, a.s. je indexem IN99 hodnocena jako velmi úspěšný podnik. Ve sledovaném období podnik vždy tvořil hodnotu. I přes méně úspěšný výsledek indexu IN99 v roce 2017, který vyšel jako „podnik spíše tvoří hodnotu“, lze označit jednotlivé výsledky jako velmi pozitivní. Nejlepšího výsledku bylo dosaženo v roce 2020 a nejhoršího pak v roce 2017. Extrémně dobrý výsledek z roku 2020 byl způsoben ukazatelem „oběžná aktiva / krátkodobý cizích kapitál“, především splacením krátkodobých závazků.

Modifikovaný Tafflerův index

V Tabulce 53 je uveden index modifikovaný Tafflerův index společnosti TP, a.s. za sledované období 2013-2020.

Tabulka 53 Modifikovaný Tafflerův index společnosti TP, a.s.

Modifikovaný Tafflerův index	Váha	2013	2014	2015	2016	2017	2018	2019	2020
EBIT/kr. závazky	0,53	0,65	0,54	1,11	0,97	0,17	1,58	3,10	4,87
Oběžná aktiva/cizí kapitál	0,13	0,85	0,74	0,88	1,16	0,59	0,50	0,78	0,57
Kr. závazky / aktiva	0,18	0,15	0,13	0,14	0,18	0,38	0,12	0,07	0,02
Tržby / aktiva	0,16	0,50	0,58	0,54	0,55	0,31	0,42	0,42	0,23
Modifikovaný Tafflerův index		0,56	0,50	0,81	0,79	0,29	0,99	1,82	2,69
Hodnocení		Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Šedá zóna	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Modifikovaný Tafflerův index hodnotí společnost TP, a.s. ve sledovaném období jako bonitní. Pouze rok 2017 byl výrazně slabší, kdy se společnost řadila do tzv. šedé zóny. Tento výsledek byl způsoben výrazně horším ukazatelem podílu EBIT a krátkodobých závazků, z důvodu skokovému navýšení právě krátkodobých závazků a také snížení ukazatele EBIT.

Aplikované metody komplexního hodnocení podniku na bázi NN

Tabulka 54 přináší výsledky vícevrstevných perceptronových sítí.

Tabulka 54 Výsledky vícevrstevných perceptronových sítí

ID sítě	Název sítě	Predikce
B-NN_LIN1	12-LinearLayer[1905]-Tanh-2-1	Aktivní
B-NN_LIN2	12-LinearLayer[3490]-Tanh-2-1	Aktivní
B-NN_LIN3	12-LinearLayer[3470]-Tanh-2-1	Aktivní
B-NN_LIN4	12-LinearLayer[4810]-Tanh-2-1	Aktivní
B-NN_LIN5	12-LinearLayer[6035]-Tanh-2-1	Aktivní

Zdroj: Vlastní.

Tabulka 55 nabízí výsledky NN obsahující GRL vrstvu.

Tabulka 55 Výsledky NN obsahující GRL vrstvu

ID sítě	Název sítě	Predikce
B-NN_GRL1	12-GatedRecurrentLayer[3990]-LogisticSigmoid-Tanh-2-1	Aktivní
B-NN_GRL2	12-GatedRecurrentLayer[4705]-Sin-LogisticSigmoid-2-1	Aktivní
B-NN_GRL3	12-GatedRecurrentLayer[3390]-Tanh-LogisticSigmoid-1	Aktivní
B-NN_GRL4	12-GatedRecurrentLayer[4985]-Tanh-Ramp-2-1	Aktivní
B-NN_GRL5	12-GatedRecurrentLayer[3640]-LogisticSigmoid-Tanh-2-1	Aktivní

Zdroj: Vlastní.

Tabulka 56 prezentuje výsledky NN obsahující LSTM vrstvu.

Tabulka 56 Výsledky NN obsahující LSTM vrstvu

ID sítě	Název sítě	Predikce
B-NN_LSTM1	12-LongShortTermMemoryLayer[2600]-Ramp-LogisticSigmoid-Ramp-2-1	Aktivní
B-NN_LSTM2	12-LongShortTermMemoryLayer[4025]-Sin-Ramp-LogisticSigmoid-2-1	V likvidaci
B-NN_LSTM3	12-LongShortTermMemoryLayer[275]-LogisticSigmoid-Ramp-LogisticSigmoid-2-1	V likvidaci
B-NN_LSTM4	12-LongShortTermMemoryLayer[2820]-Tanh-LogisticSigmoid-Tanh-2-1	V likvidaci
B-NN_LSTM5	12-LongShortTermMemoryLayer[2705]-LogisticSigmoid-Ramp-Tanh-2-1	V likvidaci

Zdroj: Vlastní.

Závěr finanční analýzy společnosti TP, a.s.

Ze zpracované finanční analýzy společnosti TP, a.s. je zřejmé, že finanční zdraví během sledovaného období prošlo jistými změnami, ale v zásadě lze finanční situaci společnosti TP, a.s. označit jako velmi dobrou.

Důležitým ukazatelem je, že společnost vykázala v každém roce kladný výsledek hospodaření. Vývoj zisku v jednotlivých letech prošel výraznými změnami, kdy nehorší výsledky byly zaznamenány v letech 2014 a 2017 ve výši 16 002 tis. Kč a 11 355 tis. Kč. Naopak nejvyšších zisků dosáhla společnost v letech 2016 a 2019 ve výši 208 987 tis. Kč a 179 165 tis. Kč.

Struktura dlouhodobého majetku ve sledovaném období se pohybovala v rozmezí 500 000 tis. Kč – 650 000 tis. Kč, kdy podstatnou část dlouhodobého majetku tvořil vždy dlouhodobý finanční majetek v podobě podílů v ovládaných a řízených osobách. Oscilace oběžných aktiv byla zapříčiněna zejména změnou krátkodobých pohledávek – oběžná aktiva byla ve svém maximu v roce 2016 ve výši 1 008 377 tis. Kč.

Důležité je upozornit na skutečnost, že společnost po celé sledované období byla financována z větší části z cizích zdrojů. Největší rozdíl mezi cizím a vlastním kapitálem byl v roce 2017, kdy cizí kapitál tvořil přes 86 % bilanční sumy. Tato skutečnost byla dána nárůstem

krátkodobých závazků, a hlavně snížením výsledku hospodaření minulých let o necelých 400 000 tis. Kč.

Tento odliv hospodářského výsledku minulých let má zásadní vliv i na další ukazatele jako je například likvidita, která v ostatních letech vykazovala dobré výsledky. Dále také v roce 2017 výrazně vzrostla zadluženost I., opět zapříčiněna nárůstem poměru cizích zdrojů vůči vlastním. Výsledek komplexního hodnocení podniku za využití indexu bonity je, že podnik v každém byl bonitní a vytvářel hodnotu – nejhorší výsledek je přičítán opět roku 2017. Naopak hodnocení společnosti indexem IN95 vyšlo, že společnost v tomto roce byla dokonce bankrotním podnikem (pouze o tři tisíce). Dle modifikovaného Tafflerova indexu se řadila akciová společnost do zóny bonitních po celé sledované období vyjma roku 2017. Horší výsledky komplexního hodnocení podniku z období 2017 byly vyvolány především zhoršením ukazatelů ROA, EBIT a zvýšení krátkodobých závazků. Především rentabilita aktiv hraje v metodách komplexního hodnocení (konkrétně index bonity, IN95 a IN99) klíčovou roli a nese tak nejvyšší podíl na výsledném hodnocení podniku. Důležité je neopomenout, že v následujících letech 2018 a 2019 TP, a.s. dosahovala nejlepších výsledků po celé sledované období – například pouze za tyto roky dle indexu bonity vyšla ekonomická situace podniku jako extrémně dobrá.

5.2.4 BS, a.s.

Tato kapitola je věnována rozboru finančního zdraví společnosti BS, a.s. prostřednictvím finanční analýzy. Finanční analýza je zpracována v tomto rozsahu:

- horizontální analýza pro posouzení vývoje aktiv, pasiv a výsledku hospodaření,
- vertikální analýza aktiv a pasiv,
- analýza poměrových ukazatelů (rentabilita, aktivita, likvidita a zadluženost),
- komplexní hodnocení podniku (index bonity, index IN95, index IN99, mod. Tafflerův index).


Všechna uváděná data k roku 2020 jsou vztažena k datu ocenění, tj. 31. 8. 2020.

Horizontální analýza

Vývoj aktiv a pasiv

Obrázky 78 a 79 znázorňují vývoj aktiv a pasiv společnosti BS, a.s. v období 2014–2020.

Obrázek 78 Vývoj aktiv společnosti BS, a.s. (v tis. Kč)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z grafu vývoje aktiv společnosti BS, a.s. je zřejmé, že v průběhu sledovaného období došlo k výraznému snížení majetku. Nejvíce aktiv společnost vlastnila v roce 2015 ve výši 1 963 459 tis. Kč nejméně pak v roce 2019 v hodnotě 84 264 tis. Kč. Pokles aktiv byl zapříčiněn zejména kvůli odlivu peněžních prostředků, který nastal v roce 2016. Snížení celkových aktiv v tomto roce nebyl tak drastický jako v nadcházejícím období z důvodu nárůstu krátkodobých pohledávek. Ke konci roku 2014 evidovala společnost peníze na účtech a hotovosti v součtu ve výši 1 230 983 tis. Kč, o rok později už pouze 141 186 tis. Kč.

Obrázek 79 Vývoj pasiv společnosti BS, a.s. (v tis. Kč)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Vývoj pasiv akciové společnosti BS, a.s. neprošel ve sledovaném období výraznými změnami – vlastní i cizí kapitál měl pozvolný průběh. Zajímavé ovšem je, že společnost v každém roce

evidovala záporný vlastní kapitál. Bylo to z důvodu, že dne 27. 6. 2012 došlo k prodeji obchodního podílu na společnosti Tipsport.net a.s. drženého společností TIPSPORT a.s. ve prospěch společnosti Tipsport.net Holding a.s., ve výši 5 847 929 tis. Kč. V rámci sloučeného účetnictví byla tato transakce zaúčtována jako snížení vlastní kapitálu souvztažně se závazkovým účtem.

Vývoj výsledku hospodaření před zdaněním

Následující Tabulka 57 a Obrázky 80 a 81 informují o hospodaření společnosti (před zdaněním) za období 2014–2020.

Tabulka 57 Vývoj VH před zdaněním společnosti BS, a.s. (v tis. Kč)

Rok	HV před zdaněním	Rok	HV před zdaněním
2014	-568 037 tis. Kč	2018	27 421 tis. Kč
2015	330 777 tis. Kč	2019	22 525 tis. Kč
2016	193 617 tis. Kč	2020	24 685 tis. Kč.
2017	392 682 tis. Kč		


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Od roku 2014, kdy BS, a.s. docílila záporného výsledku hospodaření před zdaněním, vykazovala vždy zisk. Největší zisk společnost dosáhla roku 2017 ve výši 392 682 tis. Kč. V dalších letech došlo k poklesu výsledku hospodaření na 27 421 Kč (tj. rok 2018) a 22 525 tis. Kč (tj. rok 2019).

Tento pokles byl především způsoben poklesem výnosů z prodeje služeb. Příčina ztráty z roku 2014 je největší měrou přisuzována nízkému provoznímu výsledku hospodaření, zejména tvorbě rezerv ve výši 700 000 tis. Kč.


Obrázek 80 Vývoj VH před zdaněním společnosti BS, a.s. (v tis. Kč)



Zdroj: Vlastní.

Z grafu uvedeného níže je patrný vývoj hospodářského výsledku před zdaněním za jednotlivé měsíce (do srpna) roku 2020 společnosti BS, a.s. Každý měsíc docházelo k nárůstu výsledku hospodaření. Hlavní výnosovou položkou BS, a.s. byly tržby z prodeje výrobků a služeb, naopak hlavní nákladovou položkou byly každý měsíc nákladové úroky.

Obrázek 81 Vývoj VH před zdaněním (za jednotlivé měsíce) roku 2020 společnosti BS, a.s. (v tis. Kč)



Zdroj: Vlastní.

Vertikální analýza

Prostřednictvím vertikální analýzy je analyzována struktura aktiv a pasiv zkoumané společnosti (Tabulka 58 a 59). V tomto případě lze aktiva a pasiva označit za syntetické ukazatele (tvoří 100 %), které jsou podrobeny rozkladu na dílčí části. Cílem vertikální analýzy je určit strukturu, tj. procentuální zastoupení dílčích ukazatelů na syntetických účtech.

Tabulka 58 Vertikální analýza aktiv společnosti BS, a.s.

Položka	2014	2015	2016	2017	2018	2019	2020
Aktiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Dl. majetek	8,7 %	30,0 %	46,5 %	17,7 %	13,6 %	14,1 %	5,3 %
Dl. majetek hmotný	2,3 %	1,8 %	2,5 %	11,0 %	7,9 %	8,0 %	3,2 %
Dl. majetek nehmotný	0,4 %	0,7 %	1,4 %	6,6 %	5,7 %	6,0 %	2,1 %
Dl. majetek finanční	6,0 %	27,6 %	42,6 %	0,0 %	0,0 %	0,0 %	0,0 %
Oběžná aktiva	78,1 %	69,0 %	53,5 %	82,3 %	86,4 %	85,9 %	94,7 %
Zásoby	0,1 %	0,2 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Dl. pohledávky	0,0 %	0,0 %	5,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Kr. pohledávky	9,8 %	6,1 %	39,1 %	41,2 %	5,9 %	77,8 %	53,0 %
Kr. majetek finanční	68,3 %	62,7 %	9,4 %	41,2 %	80,5 %	8,1 %	41,7 %
Časové rozlišení aktiv	13,2 %	0,9 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Vertikální analýza poukazuje na každoročně vyšší zastoupení oběžných aktiv než aktiv dlouhodobých. V letech 2014, 2015, 2017 a 2018 tvořil největší podíl celkových aktiv vždy krátkodobý finanční majetek v podobě peněžních prostředků na bankovním účtu a hotovosti. Údaje z vertikální analýzy mohou být na první pohled zavádějící, protože v průběhu let se razantně změnila výše celkových aktiv, a například téměř zčtyřnásobení krátkodobého finančního majetku mezi lety 2016 a 2017 by mohlo vyvolat dojem, že peněžní prostředky se v absolutním vyjádření také zčtyřnásobily. Avšak ve skutečnosti došlo k poklesu peněžních prostředků v řádů desítek tis. Kč.

Tabulka 59 Vertikální analýza pasiv společnosti BS, a.s.

Položka	2014	2015	2016	2017	2018	2019	2020
Pasiva	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %
Vlastní kapitál	-522,0 %	-299,2 %	-432,6 %	-2721,4 %	-3557,5 %	-7229,1 %	-4709,9 %
Základní kapitál	8,5 %	5,1 %	6,6 %	44,4 %	58,2 %	118,7 %	77,6 %
Fondy	-479,9 %	-287,5 %	-427,7 %	-2860,3 %	-3628,7 %	-7369,3 %	-4820,8 %
VH minulých let	0,0 %	-30,3 %	-21,8 %	-77,3 %	0,0 %	0,0 %	14,1 %
VH běžného úč. období	-50,6 %	13,6 %	10,3 %	171,8 %	12,9 %	21,6 %	19,2 %
Cizí zdroje	621,1 %	398,8 %	532,6 %	2821,4 %	3657,5 %	7329,1 %	4810,0 %
Dl. závazky	509,3 %	324,4 %	409,9 %	2805,4 %	3656,8 %	7328,9 %	4803,7 %
Rezervy	85,0 %	50,9 %	66,4 %	0,0 %	0,0 %	0,0 %	0,0 %
Kr. závazky	26,8 %	23,4 %	56,4 %	16,0 %	0,7 %	0,2 %	6,3 %
Časové rozlišení pasiv	0,9 %	0,4 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z vertikální analýzy pasiv je pozoruhodné, že ve sledovaném období vlastní kapitál tvoří -299 % až -7229 % a naopak cizí kapitál ve stejné výši vždy převyšuje celková pasiva. Tyto nadměrné hodnoty, které převyšují hranici 100 %, jsou vyvolané tím, že společnost v těchto letech evidovala ostatní kapitálové fondy se záporným zůstatkem v důsledku fúze společnosti a vzájemnému zaúčtování. Tyto ostatní kapitálové fondy však mnohonásobně převyšují výši celkových pasiv, proto jednotlivé položky vertikální analýzy převyšují stoprocentní hranici. Od roku 2015 nastal nárůst cizích zdrojů, alarmující je rok 2019, kdy cizí kapitál tvořil 7329,1 % celkových pasiv, a společnost v této výši využívala financování z cizích zdrojů. V letech 2017, 2018 a 2019 bylo zvyšování zastoupení cizího kapitálu na celkových pasivech zapříčiněno snížením vlastního kapitálu v důsledku vykazování nižšího výsledku hospodaření za běžnou činnost.

Analýza poměrových ukazatelů

Následující odstavce obsahují výpočet a popis poměrových ukazatelů, konkrétně ukazatelů rentability, aktivity, likvidity a zadluženosti společnosti BS, a.s.

Ukazatele rentability

V Tabulce 60 jsou uvedeny ukazatele rentability společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 60 Ukazatele rentability společnosti BS, a.s. (v procentech)


Položka	2014	2015	2016	2017	2018	2019	2020
ROA	8,87	54,22	63,81	502,26	446,27	903,75	400,00
ROE	-1,70	-18,12	-14,75	-18,46	-12,54	-12,50	-8,49
ROCE	0,12	0,71	1,46	5,98	4,50	9,06	4,27
ROS	23,40	184,59	155,21	509,46	347,96	351,54	356,70

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Graf níže na Obrázku 82 uvádí vývoj rentability aktiv společnosti BS, a.s. Z grafu je čitelné, že rentability aktiv ve sledovaném období skokově rostla, nejvíce tomu bylo v roce 2019, kdy dosáhla hodnoty 903,75 procent (vyjma roku 2020). Dramatické zvýšení ROA v letech 2017, 2018 a 2019 bylo zapříčiněno zejména odlivem majetku společnosti. Ukazatel EBIT v letech 2018 a 2019 dokonce doprovázelo snížení.

Obrázek 82 Vývoj ROA společnosti BS, a.s. (v procentech)




Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Od roku 2014 až po rok 2020 rentabilita vlastního kapitálu byla záporná. Záporná hodnota ROE byla bezpochyby vyvolána záporným vlastním kapitálem a podává informaci o tom, že ve sledovaném období každá koruna investovaného kapitálu akcionářem nepřinesla zisk. Prohloubení záporné ROE v roce 2015 bylo vyvoláno nárůstem ukazatele EBIT (Obrázek 83).

Obrázek 83 Vývoj ROE společnosti BS, a.s. (v procentech)



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele aktivity

V Tabulce 61 jsou uvedeny ukazatele aktivity společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 61 Ukazatele aktivity společnosti BS, a.s.

Položka	2014	2015	2016	2017	2018	2019	2020
Obrat aktiv	1,364	1,057	1,480	3,549	4,617	9,255	4,037
Doba obratu aktiv	263,947	340,448	243,237	101,433	77,970	38,898	89,175
Doba inkasa pohledávek	19,915	19,992	79,543	29,757	1,014	30,034	45,135
Doba splatnosti krátkodobých závazků	70,661	79,673	137,208	16,230	0,582	0,078	5,586

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Každá společnost usiluje o dosažení nejvyšších hodnot obratu aktiv, minimálně by však měly být rovny 1 (Vochozka et al., 2020). Tuto definici zkoumaná společnost splňuje a v posledních letech dokonce zvyšuje ukazatel obratu aktiv.

Doba inkasa pohledávek se mimo rok 2016 pohybovala maximálně do 30 dnů, tedy společnost dostala zapláceno za své pohledávky právě do 30 dnů. Roku 2016 doba inkasa pohledávek byla téměř 80 z důvodu skokového nárůst krátkodobých pohledávek.

Ukazatele likvidity

V Tabulce 62 jsou uvedeny ukazatele likvidity společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 62 Ukazatele likvidity společnosti BS, a.s.


Položka	2014	2015	2016	2017	2018	2019	2020
Běžná likvidita	2,919	2,950	0,948	5,146	115,708	430,875	15,120
Pohotová likvidita	2,914	2,941	0,860	5,146	115,708	430,875	15,120
Hotovostní likvidita	2,550	2,679	0,166	2,572	107,791	40,827	6,660

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Z provedené analýzy likvidity je patrné, že BS, a.s. se vyjma roku 2016 nepotýkala s problémem splácení krátkodobých závazků na žádné z uvedených úrovní. Značné snížení krátkodobých závazků v letech 2018 a 2019 vedlo k výraznému nárůstu hodnoty likvidity (Obrázek 84). Naopak nedostačující hodnoty likvidity (dle Vochozky et al., 2020) byly zjištěny k roku 2016 v souvislosti s nárůstem krátkodobých závazků.

Obrázek 84 Vývoj likvidity společnosti BS, a.s.



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ukazatele zadluženosti

V Tabulce 63 jsou uvedeny ukazatele zadluženosti společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 63 Ukazatele zadluženosti společnosti BS, a.s.

Položka	2014	2015	2016	2017	2018	2019	2020
Zadluženost I.	-1,190	-1,333	-1,231	-1,037	-1,028	-1,014	-1,021
Zadluženost II.	6,211	3,988	5,326	28,214	36,575	73,291	48,100
Úrokové krytí	0,155	1,451	1,252	1,531	1,037	1,030	1,050


Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

V tabulce výše jsou uvedeny ukazatele zadluženosti společnosti BS, a.s. Po celé sledované období vyšla zadluženost I. záporně. Každoročně se opakující záporná hodnota způsobena záporným vlastním kapitálem uvádí nedobrou finanční pozici společnosti.

U zadluženosti II. byly naměřeny v průběhu času vysoké hodnoty, což je známka toho, že společnost vlastnila méně majetku než cizích zdrojů. Vypočtené hodnoty poukazují na vysokou zadluženost podniku, která se navíc v průběhu let stále zvyšuje. Vývoj ukazatelů zadluženosti společnosti BS, a.s. je znázorněn na Obrázku 85.

Obrázek 85 Vývoj ukazatelů zadluženosti společnosti BS, a.s.



Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Komplexní hodnocení podniku

Pro komplexní hodnocení podniku BS, a.s. je využito indexu bonity, indexu IN95, indexu IN99 a modifikovaného Tafflerova indexu.

Index bonity

V následující Tabulce 64 je uveden index bonity společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 64 Index bonity společnosti BS, a.s.

Index bonity	Váha	2014	2015	2016	2017	2018	2019	2020
Cash flow/cizí zdroje	1,5	-0,08	0,04	0,02	0,06	0,00	0,00	0,00 ⁸
aktiva/Cizí zdroje	0,08	0,16	0,25	0,19	0,04	0,03	0,01	0,02
Zisk/aktiva	10	-0,48	0,17	0,13	1,74	0,16	0,27	0,19
Zisk/výnosy	5	-0,35	0,16	0,09	0,49	0,03	0,03	0,05
Zásoby/výnosy	0,3	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Výnosy/aktiva	0,1	1,36	1,06	1,48	3,55	4,62	9,25	4,04
Index bonity		-6,57	2,66	1,91	20,33	2,24	3,75	2,57
Hodnocení ekonomické situace		Extrémně špatná	Velmi dobrá	Dobrá	Extrémně dobrá	Velmi dobrá	Extrémně dobrá	Velmi dobrá
		Bankrotní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Ekonomická situace akciové společnosti BS, a.s. podle hodnocení indexu bonity v průběhu času byla velmi rozdílná. Střídali se období s extrémně špatnou, dobrou velmi dobrou, dokonce i extrémně dobrou ekonomickou situací. Pouze v prvním období (tj. rok 2014) vyšla zkoumaná společnost jako bankrotní. Do této nepříznivé ekonomické situace se společnost dostala především v důsledku záporného výsledku hospodaření. Následující období se společnost pohybovala vždy v pásmu bonitních podniků. Na nejlepším výsledku bonity v roce 2017 měl největší podíl ukazatel „zisk / aktiva“.

Index IN95

V Tabulce 65 je uveden index IN95 společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 65 Index IN95 společnosti BS, a.s.

Index IN95	Váha	2014	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	0,022	0,16	0,25	0,19	0,04	0,03	0,01	0,02
EBIT/nákladové úroky	0,11	0,16	1,45	1,25	1,53	1,04	1,03	1,05
EBIT/aktiva	8,33	0,09	0,54	0,64	5,02	4,46	9,04	4,00
Výnosy/aktiva	0,52	1,36	1,06	1,48	3,55	4,62	9,25	4,04
Oběžná aktiva/kr. cizí kapitál	0,10	2,92	2,95	0,95	5,15	115,71	430,88	15,12
Závazky po spl. / výnosy	-16,80	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Index IN95		1,76	5,53	6,32	44,37	51,26	123,30	37,05
Hodnocení		Šedá zóna	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

⁸ Pro rok 2020 se nerovná Cash flow součtu výsledku hospodaření po zdanění a odpisů (Vochozka et al., 2020) jako je tomu v předchozích letech, nýbrž součtu výsledku hospodaření před zdaněním a odpisy z důvodu, že za jednotlivé měsíce roku 2020 nebyla vyčíslena daň z příjmů právnických osob.

Akciová společnost BS, a.s. vyšla podle indexu IN95 v každém roce jako bonitní podnik, vyjma roku 2014, kdy spadala do tzv. šedé zóny. Při pohledu na jednotlivé výsledky indexu IN95 v průběhu času zkoumané společnosti lze konstatovat, že finanční pozice se rok od roku zlepšovala. Nejlepší výsledek indexu IN95 byl zaznamenán v roce 2019 ve výši 123,3. V tomto roce takto vysoce naměřená hodnota byla způsobena vysokou rentabilitou aktiv (tj. ukazatel EBIT/aktiva) a hlavně nízkou měrou krátkodobých závazků.

Index IN99

V Tabulce 66 je uveden index IN99 společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 66 Index IN99 společnosti BS, a.s.

Index IN99	Váha	2014	2015	2016	2017	2018	2019	2020
Aktiva/cizí zdroje	-0,017	0,16	0,25	0,19	0,04	0,03	0,01	0,02
EBIT/aktiva	4,57	0,09	0,54	0,64	5,02	4,46	9,04	4,00
Výnosy/aktiva	0,48	1,36	1,06	1,48	3,55	4,62	9,25	4,04
Oběžná aktiva/kr. cizí kapitál	0,02	2,92	2,95	0,95	5,15	115,71	430,88	15,12
Index IN99		1,10	3,03	3,64	24,75	24,36	52,24	20,46
Hodnocení		Podnik spíše netvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu	Podnik tvoří hodnotu

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

Výsledek indexu IN99 v podstatě kopíruje výsledek indexu IN95, kdy od prvního roku se situace podniku stále zlepšovala a hodnota vypočteného indexu IN99 každoročně vzrostla. Roku 2014 BS, a.s. dle indexu IN99 vyšlo, že „podnik spíše netvořil hodnotu“ a v následujících letech vždy „tvořil hodnotu“. Opět jako u indexu IN95 hlavní podíl na nejlepších výsledcích v závěru sledovaného období byly rentabilita aktiv a nízká výše krátkodobých závazků.

Modifikovaný Tafflerův index

V Tabulce 67 je uveden modifikovaný Tafflerův index společnosti BS, a.s. za sledované období 2014–2020.

Tabulka 67 Modifikovaný Tafflerův index společnosti BS, a.s.

Modifikovaný Tafflerův index	Váha	2014	2015	2016	2017	2018	2019	2020
EBIT/kr. závazky	0,53	0,33	2,32	1,13	31,39	597,84	4 532,94	63,85
Oběžná aktiva/cizí kapitál	0,13	0,13	0,17	0,10	0,03	0,02	0,01	0,02
Kr. závazky / aktiva	0,18	0,27	0,23	0,56	0,16	0,01	0,00	0,06
Tržby / aktiva	0,16	1,36	1,06	1,48	3,55	4,62	9,25	4,04
Modifikovaný Tafflerův index		0,46	1,46	0,95	17,24	317,60	2 403,94	34,50
Hodnocení		Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik	Bonitní podnik

Zdroj: Vlastní.

Pozn.: Údaje za rok 2020 jsou k 31. 8. 2020. Údaje za ostatní roky jsou vždy k 31. 12. daného roku.

V průběhu celého sledovaného období se BS, a.s. pohybovala nad hranicí 0,3 modifikovaného Tafflerova indexu, tudíž v každém roce byla dle Tafflerova hodnocení bonitním podnikem. V posledních čtyřech letech, tj. 2017, 2018, 2019 a 2020, oproti ostatním obdobím byly naměřeny vysoké hodnoty modifikovaného Tafflerova indexu, které byla zapříčiněny dramatickým snižováním krátkodobých závazků.

Aplikované metody komplexního hodnocení podniku na bázi NN

Tabulka 68 přináší výsledky vícevrstvých perceptronových sítí.

Tabulka 68 Výsledky vícevrstvých perceptronových sítí

ID sítě	Název sítě	Predikce
B-NN_LIN1	12-LinearLayer[1905]-Tanh-2-1	Aktivní
B-NN_LIN2	12-LinearLayer[3490]-Tanh-2-1	Aktivní
B-NN_LIN3	12-LinearLayer[3470]-Tanh-2-1	Aktivní
B-NN_LIN4	12-LinearLayer[4810]-Tanh-2-1	Aktivní
B-NN_LIN5	12-LinearLayer[6035]-Tanh-2-1	Aktivní

Zdroj: Vlastní.

Tabulka 69 nabízí výsledky NN obsahující GRL vrstvu.

Tabulka 69 Výsledky NN obsahující GRL vrstvu

ID sítě	Název sítě	Predikce
B-NN_GRL1	12-GatedRecurrentLayer[3990]-LogisticSigmoid-Tanh-2-1	V likvidaci
B-NN_GRL2	12-GatedRecurrentLayer[4705]-Sin LogisticSigmoid-2-1	V likvidaci
B-NN_GRL3	12-GatedRecurrentLayer[3390]-Tanh-LogisticSigmoid-1	Aktivní
B-NN_GRL4	12-GatedRecurrentLayer[4985]-Tanh-Ramp-2-1	V likvidaci
B-NN_GRL5	12-GatedRecurrentLayer[3640]-LogisticSigmoid-Tanh-2-1	Aktivní

Zdroj: Vlastní.

Tabulka 70 prezentuje výsledky NN obsahující LSTM vrstvu.

Tabulka 70 Výsledky NN obsahující LSTM vrstvu

ID sítě	Název sítě	Predikce
B-NN_LSTM1	12-LongShortTermMemoryLayer[2600]-Ramp-LogisticSigmoid-Ramp-2-1	Aktivní
B-NN_LSTM2	12-LongShortTermMemoryLayer[4025]-Sin-Ramp-LogisticSigmoid-2-1	Aktivní
B-NN_LSTM3	12-LongShortTermMemoryLayer[275]-LogisticSigmoid -Ramp-LogisticSigmoid-2-1	Aktivní
B-NN_LSTM4	12-LongShortTermMemoryLayer[2820]-Tanh-LogisticSigmoid-Tanh-2-1	V likvidaci
B-NN_LSTM5	12-LongShortTermMemoryLayer[2705]-LogisticSigmoid-Ramp-Tanh-2-1	Aktivní

Zdroj: Vlastní.

Závěr finanční analýzy společnosti BS, a.s.

Pro posouzení finanční situace akciové společnosti BS, a.s. je důležité upozornit na skutečnost, která nastala v roce 2012. Dne 27. 6. 2012 došlo k prodeji obchodního podílu společnosti BS, a.s. ve prospěch další společnosti ve výši 5 487 929 tis. Kč. V rámci sloučeného účetnictví je tato transakce zaúčtována jako snížení vlastního kapitálu souvztažně se závazkovým účtem.

Od tohoto data až k poslednímu roku sledovaného období (tj. 2020) BS, a.s. disponuje záporným vlastním kapitálem, který se pohyboval okolo 6 mld. Kč.

Po celé sledované období (vyjma 2014) zkoumaná společnost dosáhla kladného hospodářského výsledku – zisku. Nejvíce tomu bylo roku 2017, kdy zisk byl ve výši 392 682 tis. Kč. V dalších letech došlo k poklesu výsledku hospodaření na 27 421 Kč (tj. rok 2018) a 22 525 tis. Kč (tj. rok 2019).

Tento pokles byl především způsoben poklesem výnosů z prodeje služeb. Příčina ztráty z roku 2014 je největší měrou přisuzována nízkému provoznímu výsledku hospodaření, zejména tvorbě rezerv.

V průběhu času celková aktiva prošly výraznou změnou. Nejvíce aktiv společnost vlastnila v roce 2015 ve výši 1 963 459 tis. Kč nejméně pak v roce 2019 v hodnotě 84 264 tis. Kč. Pokles aktiv byl zapříčiněn zejména kvůli odlivu peněžních prostředků, který nastal v roce 2016. Snížení celkových aktiv v tomto roce nebyl tak drastický jako v nadcházejícím období z důvodu nárůstu krátkodobých pohledávek. Ke konci roku 2014 evidovala společnost peníze na účtech a hotovosti v součtu ve výši 1 230 983 tis. Kč, o rok později už pouze 141 186 tis. Kč. Průběh struktury vlastního a cizího kapitálu neprodělal významné změny, je ovšem důležité upozornit na skutečnost, že vlastní kapitál byl v každém roce vykazován záporný. Hlavní položkou cizího kapitálu byly dlouhodobé závazky, emitované dluhopisy.

Rentabilita aktiv za sledované období skokově vzrostla, nejvíce tomu bylo v roce 2019, kdy dosáhla ROA hodnoty 903,75 procent. Vysoká rentabilita je tížená vlastnost, avšak

u společnosti BS, a.s. zvýšení ROA v posledních letech bylo zapříčiněno zejména odlivem majetku, dokonce poslední 2 období doprovázelo snížení EBIT. U zadluženosti II. byly naměřeny v průběhu času vysoké hodnoty, což je známka toho, že společnost vlastnila méně majetku než cizích zdrojů. Vypočtené hodnoty poukazují na vysokou zadluženost podniku, která se navíc v průběhu let stále zvyšuje.

Výsledek komplexního hodnocení podniku podle všech třech použitých metod vyšel velmi podobný. Nejhorší výsledky společnosti byly naměřeny roku 2014, kdy dle indexu bonity vyšel podnik jako bankrotní a podle indexu IN99, že spíše netvoří hodnotu. Pozitivnější zpráva pro podnik je, že v průběhu let docházelo k průběžnému zlepšování a nejlepší výsledky byly vyčísleny k roku 2019. Na nejlepších výsledcích z posledního roku sledovaného období měla zásluhu především nízká hodnota krátkodobých závazků a vysoká úroveň rentability aktiv.

I přes relativně dobré výsledky, které vyšly z metod komplexního hodnocení podniku je zřejmé, že společnost se potýká s obrovskou zadlužeností a disponuje zejména cizím kapitálem. Vlastní kapitál byl po celé sledované období záporný, což také nepoukazuje na dobrou finanční kondici podniku. V průběhu let byl zaznamenán i odliv peněžních prostředků a celkové snížení majetku společnosti, což je opět bráno za negativní ukazatel správného fungování podniku (Vochozka et al., 2020).

5.3 Strategická analýza

Strategická analýza je v tomto případě zpracována pro loterijní průmysl a sektor finančních služeb.

5.3.1 Loterijní průmysl

V této kapitole je zpracována strategická analýza loterijního průmyslu v ČR, ve kterém působí společnost, Berounská servisní a.s. Strategická analýza loterijního průmyslu v ČR je zpracována v tomto rozsahu: Analýza loterijního průmyslu v ČR a analýza odvětví.

Analýza loterijního průmyslu v ČR

Předmětem podnikání, resp. hlavním rizikem na výnosové části společnosti Berounská servisní a.s. je provozování hazardních her, především kursových sázek na sportovní události prostřednictvím online prostředí – internetu nebo kamenných poboček. Sázkové hry a loterie jsou velmi dynamickým podnikatelským odvětvím, které se z hlediska podnikatelů vyznačuje velkými příležitostmi, ale zároveň i velkými riziky. Příležitosti loterijního průmyslu vycházejí

zejména z prudkého technického a technologického rozvoje, elektronizace oboru sázkových her a sílicího trendu provozovat sázkové hry prostřednictvím internetové sítě, což odpovídá životnímu stylu nastupující generace konzumentů sázkových her. Rizika loterijního průmyslu vyplývají zejména z vysoké nestability podnikatelského prostředí způsobené častými změnami legislativy v oblasti zdanění i licencí a také v segmentu heren a kasin živelnou tvorbou místních vyhlášek ze strany místních samospráv.

Vývoj právní úpravy o loteriích v letech 2011–2015

Zákon o loteriích v období, od přijetí komplexní novely č. 300/2011 Sb. až do svého zrušení k 1. lednu 2017, byl celkem pětkrát novelizován, z toho první tři novely byly přijaty již v roce 2011. Šlo nicméně většinou o formální a nikterak zásadní technické úpravy do legislativy.

Novelou č. 420/2011 Sb. 169 došlo k přizpůsobení zákona o loteriích nové úpravě trestní odpovědnosti právnických osob. Tato skutečnost pouze pozměnila ustanovení § 4a zákona o loteriích upravujícího podmínku bezúhonnosti žadatelů o povolení k provozování loterie nebo jiné podobné hry.

V části první zákona č. 457/2011 Sb. 170 byla zakotvena změna právního předpisu zákona o loteriích u příležitosti přijetí nového zákona o Finanční správě České republiky. Oproti dvou zmíněných předchozích novel z roku 2011 však tato novela nabyла účinnosti až 1. ledna 2013. Poslední právní úprava z roku 2011 byl zákon č. 458/2011 Sb., jehož účelem bylo sjednocení odvodů upravených v zákoně o loteriích. Tato změna byla učiněna v souladu s Programovým prohlášením vlády ze dne 4. srpna 2010, které předpokládalo vyšší zdanění hazardu a odstranění výjimek v této oblasti. Proto byla následně do zákona o loteriích vložena část šestá, v níž byly přehledně upraveny všechny náležitosti týkající se odvodové povinnosti. Tato nová úprava zavedla odvody s lineární sazbou 20 % plátcí pro všechny druhy hazardních her s drobnou odchylkou u výherních hracích automatů oproti stávající progresivní sazby v rozmezí 6 až 20 %. Z hlediska provozovatelů hazardní her se tedy jednalo o velmi zpřísnující opatření zvyšující jejich daňovou zátěž.

Odvodová povinnost bez výjimek setrvala v zákoně o loteriích pouze do 1. ledna 2014, kdy nabyла účinnosti novela č. 215/2013 Sb., která provozovatelům loterií a kurzových sázek umožnila uplatnit slevu na dílčím odvodu v případě, že v odvodovém období provozovatel zmíněných hazardních her poskytl peněžitý dar Českému olympijskému výboru.

Poslední novelou zákona o loteriích, zákonem č. 380/2015 Sb., byla v souladu s Programovým prohlášením vlády odvodová sazba zvýšena z 20 na 23 %, respektive 28 % pro výherní hrací přístroje a jiná technická zařízení. U těchto hracích zařízení došlo současně k navýšení pevného

poplatku z 55 Kč na 80 Kč za den. Návrh tohoto zákona předložila vláda Poslanecké sněmovně dne 13. října 2015, tedy v době, kdy, již byly sněmovnou projednávány zcela nové předpisy upravující problematiku hazardních her, které mimo jiné počítaly s navýšením zdanění provozovatelů hazardních her. Ačkoli se může jevit předložení návrhu novely č. 380/2015 Sb. v tomto kontextu jako redundantní, je třeba brát v úvahu, že proces přijetí nové koncepce úpravy hazardu mohl vzhledem k historickým zkušenostem trvat i mnoho let, kdy navíc přijetí zákona či zákonů nemohlo být zaručeno, kdežto jednotlivé novely zákona o loteriích mnohdy Parlamentem procházely bez větších obtíží a průtahů. Ministerstvo financí ČR si touto novelou v podstatě zajistilo naplnění Programového prohlášení vlády pro případ, když by návrhy koncepčně zcela nové právní úpravy nebyly z jistých důvodů Parlamentem přijaty.

Dále kontinuálně již od roku 2010 probíhala široká diskuse o budoucích uvažovaných změnách loterijního zákona.

Novela loterijního zákona 2017

Dne 1. 1. 2017 vstoupil v platnost nový zákon č. 186/2016 Sb., o hazardních hrách, který nahrazuje zákon č. 202/1990 Sb. Tento zákon s sebou přináší řadu změn, jež se týkají jak provozovatelů živých heren, tak online kasin, ale také hráčů samotných. Mezi nejdůležitější změny patří:

- Legalizují se zahraniční herny a sázkové kanceláře (za podmínky udělení licence).
- Nelicencovaným hernám může Ministerstvo financí ČR zablokovat webové stránky i veškeré platby.
- Vznik rejstříku, do kterého se musí zaregistrovat všichni hráči. Má se zabránit hraní nezletilým, ale i lidem, kteří pobírají sociální dávky.
- Maximální možná sázka v hernách je 100 Kč a v kasinech a na internetu 1 000 Kč.
- Omezuje se maximální možná výhra z jedné hry na 500 000 Kč.
- Zákon o hazardu zvyšuje daň z 28 % na 35 % na výherní automaty.
- Definitivně končí hazardní zařízení v nelicencovaných provozovnách, tedy zejména restauracích a menších barech s několika hrami.
- Hráči v živých kasinech již nesmí dostávat zdarma alkohol a ruší se non-stop provoz.

Rizika spojená s provozováním hazardních her

Subjekty provozující svoji podnikatelskou činnost v oblasti loterijního průmyslu musí čelit řadě rizik, která odpovídají vysoké nestabilitě podnikatelského prostředí způsobené například

častými změnami legislativy v oblasti zdanění a licencí, rizik plynoucích ze hry a v segmentu heren a kasin živelnou tvorbou místních vyhlášek ze strany místních samospráv.

Rizika ze hry

Značným rizikem pro společnosti vyskytujících se v loterijním průmyslu, tedy i pro společnosti Berounská servisní a.s., jsou zejména rizika spojená s provozováním hazardních her. Tyto rizika vychází ze samotné podstaty předmětu podnikání zmíněných společností, tj. provozování kurzových sázek a jsou reprezentována především pravděpodobností mimořádně velkých výher sázkařem nebo skupinou sázkařů. Sázkařský byznys vychází z předpokladu, že existuje nízká pravděpodobnost toho, aby nastaly všechny uvažované události tak, jak jsou očekávány nebo naopak, aby všechny tyto události nastaly tak, jak očekávány vůbec nejsou. Základní premisou je zvolení správné míry pravděpodobnosti, že daná událost nenastane.

Sázkové společnosti rozdělují obvykle rizika ze hry do tří oblastí dle charakteru a velikosti rizika na: riziko spojené s 1 událostí, vysoké prohry a mimořádně vysoké prohry.

Riziko spojené s 1 událostí

Jde o riziko, které je spojenou s jednou sázkovou příležitostí. S tímto rizikem, u kterého je vysoká pravděpodobnost výskytu, ale jeho dopad (prohra) není zcela zničující (v řádu stovek tisíc až milionů českých korun), se subjekty provozující kurzové sázky setkávají téměř denně. Shodnost většího množství sázek na totožný stav světa je dát celospolečenským očekáváním a sdílením informací v sázkařské komunitě. Jde například o atraktivní zápasy (fotbalové derby FC Real Madrid vs FC Barcelona).

Vysoká prohra

Riziko v kategorii „vysoká prohra“ je klasifikováno jako riziko s řádově vyšším dopadem než „riziko spojené s 1 událostí“, jeho dopad je očekáván v řádu stovek milionů Kč a vysokou frekvencí tohoto rizika (denně). Z celkového počtu všech vsazených tiketů za den se jedná o méně než 0,1 % z nich, kdy jsou vsazeny na jevy světa, které mají poměrně nízkou pravděpodobnost, že nastanou, avšak díky vysokému kurzu těchto jevů a příp. jejich kombinací by možný dopad (prohra) byl ve výši až stovek milionů Kč. Toto riziko je tak charakteristické velmi nízkou pravděpodobností (vysokým sázkařským kurzem) a hrozbou vysoké prohry, která by měla citelný dopad na podnik, pokud by daný stav světa nastal. Nelze ovšem tvrdit, že dané riziko je zanedbatelné, ale spíše naopak, při uvážení celkového počtu vsazených tiketů (cca 500 000) s každodenní frekvencí je s tímto rizikem nutno kalkulovat.

Mimořádně vysoká prohra

Třetí kategorií rizika s nejvyšším dopadem je kategorie „mimořádně vysoká prohra“. V tomto případě se jedná zpravidla o velké, mezinárodní, atraktivní a společensky sledované akce (olympijské hry, mistrovství světa, fotbalové šampionáty, velké tenisové turnaje). Tyto akce jsou zpravidla známy všem dlouho dopředu stejně jako zápasy v základních skupinách, a právě sázkové kanceláře vypisují kurzy a kurzové sázky na známé zápasy taktéž v předstihu. Navzdory tomu, že zápasy v základních skupinách jsou známy dlouho dopředu a stejně tak jsou na ně vypsány i kurzy, jsou odehrány během několika málo dní. Právě značný časový odstup mezi prvním vypsáním kurzů a samotnou událostí (zápasem) působí jako negativní faktor při stanovení sázkařského kurzy, který se s přibližující se událostí více zpřesňuje, stejně tak tento časový odstup dává možnost vsazení velkého množství stejných nebo obdobných tiketů. Kombinace akumulace více drobných sázek vsazených na stejný stav světa při vysokém kurzu poté přináší vůbec to nejvyšší riziko.

Druhy hazardních her

Zákon č. 186/2016 Sb., o hazardních hrách vymezuje jednotlivé druhy hazardních her a podmínky jejich provozování. Hazardní hrou se rozumí hra, sázka nebo los, do nichž sázející vloží sázku, jejíž návratnost se nezaručuje, a v nichž o výhře nebo prohře rozhoduje zcela nebo zčásti náhoda nebo neznámá okolnost. Zákon o hazardních hrách upravuje tyto hazardní hry:

- loterii,
- kurzovou sázku,
- totalizátorovou hru,
- bingo,
- technickou hru,
- živou hru,
- tombolu,
- turnaj malého rozsahu.

Loterie (§18)

Loterií se dle zákon člení na číselnou loterii, peněžitou loterii, věcnou loterii a okamžitou loterii. Číselná loterie je hazardní hra, u níž je výhra podmíněna uhodnutím určitého čísla, kombinací čísel, několika čísel nebo číselného pořadí. Peněžitá a věcná loterie jsou hazardní hry, u níž je výhra podmíněna vylosováním určitého losu a okamžitá loterie je hazardní hra, u níž je výhra podmíněna výherní kombinací po setření zakryté části losu.

Kurová sázka (§ 27)

Kurovou sázkou se rozumí hazardní hra, u níž je výhra podmíněna uhodnutím sázkové příležitosti, kdy sázkovou příležitostí je zejména myšleno sportovní výsledek nebo událost veřejné pozornosti. Princip kurové sázky spočívá v tom, že sázkař vsadí určitou sumu peněz, a v případě správného uhodnutí výsledku dané sázkové příležitosti, vyhraje vsazenou částku znásobenou kurzem, který byl stanoven pro danou sázkovou příležitost.

Totalizátorová hra (§ 32)

Totalizátorová hra je hazardní hra, která je svým způsobem velice podobná kurové sázce. Liší se především v tom, že provozovatel předem stanoví výši výhry v předem stanoveném poměru k přijatým vkladům. Výsledná výše výhry je tak závislá na poměru počtu výherců k celkové výši vkladů a předem stanovenému objemu peněžních prostředků určených na výhry.

Bingo (§ 39)

U hazardní hry bingo je výhra podmíněna dosažením předem stanoveného vzorce na sázkovém tiketu, který sázející vyplní na základě postupného losování čísel. Předem stanovený vzorec je povinen určit provozovatel v herním plánu, který má být na sázkovém tiketu vytvořen k dosažení výhry.

Technická hra (§ 42)

Technickou hrou se rozumí hazardní hra provozovaná prostřednictvím technického zařízení přímo obsluhovaného sázejícím (např. válcová hra, elektromechanická ruleta a elektromechanické kostky).

Živá hra (§ 57)

U živé hry hraje sázející proti krupiérovi, nebo jeden proti druhému u hracího stolu, aniž by byl předem určen počet sázejících a výše sázky do jedné hry. Mezi jednotlivé druhy živé hry patří zejména hra kostky, ruleta a karetní hra (provozována i formou turnaje).

Tombola (§ 61)

Tombolou se rozumí hazardní hra, u níž se výhry rozdělují na základě slosování, do kterého se zahrnou pouze prodané sázkové tikety. Tyto tikety mohou být prodávány a výhry vydávány pouze v den a na místě slosování.

Turnaj malého rozsahu (§64)

Turnaj malého rozsahu je turnaj vyřazovacího typu v karetní hře, při kterém je počet účastníku předem určen – nejméně 3 a nejvýše 90. Turnaj malého rozsahu je specifikován vyšší úhrnného vkladu, který u jednotlivého účastníka nesmí převýšit 500 Kč za 24 hodin.


Dalším rozřazovacím kritériem hazardních her je místo provozování. Pokud jsou hazardní hry provozovány prostřednictvím kamenných poboček, kasin a heren jde o tzv. land-based hazardní hry. V případě provozování těchto her pomocí internetu, webových portálů či stránek, jedná se o tzv. on-line hazardní hry.

Analýza odvětví

Objem a struktura trhu

Dle Obrázku 86 v roce 2018 hráči hazardních her prohráli v ČR celkem 31,3 mld. Kč. Celkem do hazardní her vložili 249,5 mld. Kč a na výhrách jim bylo vyplaceno 218,2 mld. Kč. Objem vložených finančních prostředků do hazardních her každoročně roste. V roce 2018 hráči vsadili více než dvojnásobný objem peněz než před pěti lety a o 11 % více než tomu bylo v roce 2017. V porovnání mezi roky 2017 a 2018 klesl provozovatelům příjem z hazardních her o 8,5 mld. Kč (z 39,8 mld. Kč na 31,3 mld. Kč), resp. o 21 %⁹.

Obrázek 86 Objem trhu s hazardními hrami v ČR v 2002–2018, v mld. Kč




Zdroj: Ministerstvo financí ČR (2019b), převzato z Mravčík et al. (2019).

Obrázek 87 poukazuje na vývoj příjmů z hraní hazardních her v období 2002–2019 v mld. Kč.

⁹ V roce 2018 Ministerstvo financí ČR změnilo metodiku vykazování sázek a výher hráčů, resp. co je považováno za “vsazenou částku” a co za “výhru“. Údaje o vkladech a výhrách hráčů za r. 2018 nejsou tedy zcela porovnatelné s údaji z předchozích let. Údaji porovnatelnými s minulými roky jsou údaje o prohraných částkách, které představují hrubý příjem provozovatelů.

Obrázek 87 Příjmy z hazardních her v ČR 2002–2019, v mld. Kč



Zdroj: Mravčík et al. (2020).

Na ekonomické ukazatele podle jednotlivých typů hazardních her v roce 2019 poukazuje obrázek níže, údaje jsou seřazeny podle podílu typů hazardních her na celkových příjmech ze hry. Nejvyšší podíl příjmu ze hry připadl stejně jako v minulých letech na technické hry v prostředí land-based, které tvořily přes 41 % trhu a utržily 15,1 mld. Kč. Kursové sázky online utržily 7,7 mld. Kč (21,3 % trhu, meziroční nárůst o pět procentních bodů), loterie land-based 6,0 mld. Kč (19 % trhu, meziroční nárůst o 1,2 %), podíl ostatních her na celkových příjmech činil pod 10 %.

Bez rozlišování hazardních her na land-based a on-line tvořily technické hry 49,5 %, kursové sázky 24,3 % a loterie 19,8 % příjmů provozovatelů ze hry. V land-based prostředí byl výherní podíl 85,9 % a v on-line prostředí 92,4 % (Obrázek 88).

Obrázek 88 Celkový objem peněz vložených do hry a vyplacených na výhrách podle typu hry v r. 2019

Typ hazardních her	Vloženo		Vyplaceno		Příjmy ze hry		Výherní podíl* (%)
	mil. Kč	Podíl (%)	mil. Kč	Podíl (%)	mil. Kč	Podíl (%)	
Technické hry land-based	196 453	50,5	181 342	51,4	15 111	41,7	92,3
Kurzové sázky on-line	78 415	20,1	70 686	20,0	7 729	21,3	90,1
Loterie land-based	14 384	3,7	8 174	2,3	6 210	17,1	56,8
Technické hry on-line	68 790	17,7	65 956	18,7	2 834	7,8	95,9
Živé hry land-based	16 325	4,2	14 262	4,0	2 063	5,7	87,4
Kurzové sázky land-based	6 544	1,7	5 443	1,5	1 101	3,0	83,2
Loterie on-line	2 229	0,6	1 241	0,4	988	2,7	55,7
Živé hry on-line	6 017	1,5	5 793	1,6	223	0,6	96,3
Bingo land-based	31	0,0	23	0,0	8	0,0	75,0
Totalizátorové hry land-based	8	0,0	6	0,0	2	0,0	69,8
Tombola land-based	0	0,0	0	0,0	0	0,0	10,5
Malý karetní turnaj land-based	0	0,0	0	0,0	0	0,0	94,2
Totalizátorové hry on-line	0	0,0	0	0,0	0	0,0	–
Bingo on-line	0	0,0	0	0,0	0	0,0	–
Technické hry celkem	265 243	68,2	247 298	70,1	17 945	49,5	93,2
Kurzové sázky celkem	84 958	21,8	76 129	21,6	8 830	24,3	89,6
Loterie celkem	16 612	4,3	9 415	2,7	7 198	19,8	56,7
Živé hry celkem	22 341	5,7	20 055	5,7	2 286	6,3	89,8
Land-based celkem	233 745	60,1	209 249	59,3	24 496	67,5	89,5
On-line celkem	155 450	39,9	143 676	40,7	11 773	32,5	92,4
Celkem	389 195	100,0	352 926	100,0	36 269	100,0	90,7

Zdroj: Ministerstvo financí ČR (2019c), převzato z Mravčík et al. (2020).

Detailněji jsou analyzovány příjmy provozovatelů ze hry. Zatímco v roce 2016 se příjmy provozovatelů ze hry meziročně zvýšily u všech typů hazardních her a celý trh s hazardními hrami vzrostl o 29 %, příjmy vzrostly v roce 2017 o 1 % a v roce 2018 se dokonce snížily o 21 %. Celý pokles příjmů lze přičíst poklesu z technických her land-based, který se snížil o 9,5 mld. Kč. Menší objem peněz také prohráli hráči v online technických hrách (o 5 %), v kurzových sázkách (o 4 %).

Obrázek 89 shrnuje změny v příjmech provozovatelů za pětileté období 2013–2018. Za sledovaných pět let nejvíce vzrostl příjem z kurzových sázek (o 156 %), loterií (o 73 %) a živých her (o 54 %). Příjem z on-line hazardních her se za sledovaných 5 let zvýšil o 266 % a z land-based hazardních her snížil o 15 %. Tento trend vychází z příležitosti loterijního průmyslu (tj. technologický rozvoj, elektronizace sázkových her, prosazování hazardních her prostřednictvím on-line sítě).


Obrázek 89 Změna objemu příjmu provozovatelů podle jednotlivých typů hazardních her v l. 2013–2018, v %

Typ hry	Změna meziročně			Změna za 3 roky	Změna za 5 let
	2015–2016	2016–2017	2016–2017	2015–2018	2013–2018
Technická hra land-based	36,3	-10,3	-42,4	-29,6	-32,7
Kurzová sázka on-line	24,6	18,8	3,1	52,7	155,6
Loterie land-based	12,7	-10,1	9,4	10,8	55,4
Technická hra on-line	-	-	-4,8	-	-
Živá hra land-based	53,1	26,8	5,8	105,4	41,8
Kurzová sázka land-based	1,5	-18,7	-3,7	-20,5	-25,2
Loterie on-line	-	-	78,0	-	-
Živá hra on-line	-	-	46,5	-	-
Technická hra celkem	36,3	-2,3	-39,3	-19,2	-22,7
Kurzová sázka celkem	18,6	10,4	2,0	33,5	85,4
Loterie celkem	12,7	-3,9	13,8	23,2	72,7
Živá hra celkem	53,1	34,4	8,1	122,5	53,5
Land-based celkem	30,1	-8,9	-28,6	-15,5	-14,9
On-line celkem	24,6	66,9	5,1	118,7	266,0
Celkem	29,3	1,1	-21,3	2,9	9,6

Zdroj: Ministerstvo financí ČR (2019b), převzato z Mravčík et al. (2019).

Při pohledu na vývoj podílů jednotlivých typů hazardních her na trhu podle příjmů provozovatelů (prohraných peněz) je patrný dlouhodobý růst podílu kurzových sázek on-line. Podíl živé hry vzrostl za sledované čtyři roky ze 3 % na 6,3 %. V posledních letech také výrazně vzrostl podíl loterií, a to na 21 % (rok 2018) a 20 % (rok 2019), což je nejvíce za sledované období od roku 2006–2019 viz Obrázek 90.


Obrázek 90 Vývoj podílů typů hazardních her na trhu podle příjmů ze hry v I. 2006–2019, v %



Zdroj: Ministerstvo financí ČR (2019c), převzato z Mravčík et al. (2020).

Obrázek 91 znázorňuje vývoj trhu s hazardními hrami podle typu hazardní hry v absolutních hodnotách příjmů provozovatelů ze hry za osmnáctileté období od roku 2006 do roku 2019. Je zjevný zejména dlouhodobý nárůst příjmů provozovatelů z kurzových sázek a loterií a prudký pokles u technických her, který v posledním roce 2019 vykázal 3% nárůst.

Obrázek 91 Vývoj příjmů ze hry u hlavních typů hazardních her v I. 2002–2019, v mld. Kč



Zdroj: Ministerstvo financí ČR (2019c), převzato z Mravčík et al. (2020).

Pokud jde o strukturu trhu podle vsazených peněz, největší podíl byl vsazen do technických her land-based (41 %), kurzových sázek on-line (25 %) a technických her on-line (17 %). Podíl

technických her land-based dlouhodobě klesá, v posledních dvou letech však výrazně narostl podíl peněz vložených do technických her on-line, a to na 17 %. Technické hry jsou tak stále dominantní hrou na trhu. Dlouhodobý růst podílu kurzových sázek se zastavil v roce 2015 na 29 %, v roce 2018 dokonce klesl na 28 %, na kurzové sázky on-line připadlo 25 %. Podíl loterií byl v posledních sledovaných třech letech přibližně 6 %. Dlouhodobě roste podíl objem peněz vložených do hazardních her on-line. V roce 2018 bylo on-line vloženo 45 % všech peněz vložených do hazardních her.

PEST analýza loterijního průmyslu ČR

Politicko-právní vlivy

Jak je již zmíněno v předchozích kapitolách, podnikání v loterijním průmyslu nese řadu příležitostí i rizik. Jedním z mnoha rizik je neustálá změna legislativy v oblasti provozování hazardních her za účelem nastavení pevných norem tohoto podnikání a celkového snížení počtu hráčů hazardních her. Od roku 2014 je problematika hazardního hraní součástí integrované protidrogové politiky ČR. Koordinačním a poradním orgánem vlády v otázkách protidrogové politiky je Rada vlády pro koordinaci protidrogové politiky. Mravčík a kolektiv (2020) ve své publikaci uvádí následující přehled, který znázorňuje změnu legislativy v období 2012–2020 v oblasti zdanění příjmů z hazardních her v období:


- Do 1. 1. 2012 provozovatelé hazardních her odváděli tzv. odvody na veřejně prospěšné účely ve výši 6–20 % z příjmů ze hry; příjmy hazardních her nebyly ani předmětem daně z příjmu, ani jiné daně či odvodu.
- Od 1. 1. 2012 jsou provozovatelé hazardních her plátcí daně z příjmu právnických osob, bylo zavedeno zdanění hazardních her formou odvodu ve výši 20 % z příjmů ze hry (tj. z rozdílu mezi vklady do hry a vyplacenými výhrami), u technické hry navíc poplatkem 55 Kč denně za každý povolený přístroj; povinnost odvodu na veřejně prospěšné účely byla zrušena.
- Od 1. 1. 2014 měli na základě novely zákona o loteriích provozovatelé loterií a kurzových sázek (nikoliv jiných her) možnost zákonem předepsaný dílčí odvod z loterií a kurzových sázek (KS) snížit z 20 % až na 15 % o částku, kterou poskytl jako peněžitý dar Českému olympijskému výboru na účely tělovýchovné a sportovní.
- Od 1. 1. 2016 existovaly na základě vládní novely zákona o loteriích dvě sazby zdanění: technické hry byly zdaněny sazbou 28 % z příjmů ze hry a poplatkem 80

Kč za přístroj a den. Pro ostatní hazardní hry byla daňová sazba 23 % z příjmů ze hry.

- Od 1. 1. 2017 zavedl zákon č. 187/2016 Sb., o dani z hazardních her, dvě sazby zdanění: 35 % pro technické hry a 23 % pro ostatní hazardní hry; současně byla zrušena možnost slevy na dani o dar poskytnutý Českému olympijskému výboru.
- V květnu 2019 schválila vláda návrh na změnu daňových sazeb, podle nějž mají být zavedeny 3 daňové sazby: sazba ve výši 25 % u kurzových sázek, tombol, turnajů malého rozsahu a totalizátorových her (původně 23 %), sazba ve výši 30 % u loterií, binga a živých her (původně 23 %) a sazba ve výši 35 % u TH zůstane zachována. Původní znění zákona počítalo se zvýšením sazeb daně z hazardních her i u ostatních dílčích základů daně, nicméně návrh zákona prošel několika pozměňovacími návrhy a ostatní zvýšení sazeb daně byla z návrhu zákona vypuštěna.
- Od 1. 1. 2020 novelizací zákona č. 187/2016 Sb., o dani z hazardních her, došlo k úpravě sazby daně u loterií na 35 % (původně 23 %) zatímco ostatní sazby daně zůstaly zachovány. Nynější znění tohoto zákona zahrnuje dvě sazby zdanění: 35 % pro technické hry a loterie a 23 % pro ostatní hazardní hry.
- Od 1. 1. 2020 zároveň platí zdanění příjmů z hazardních her nad 1 000 000 Kč. Daň z příjmů ve výši 15 % dopadá na čisté výhry z hazardu převyšující tento limit.

Dle Obrázku 92 v letech 2013–2015 se celkový objem odvodů z příjmů získaných provozováním hazardních her (de facto daně z hazardních her) pohyboval ve výši přibližně 8 mld. Kč, v nadcházejících dvou letech rostl a v roce 2017 dosáhl 12,1 mld. Kč. V dalším roce, tj. roce 2018 došlo k poklesu odvodů na 9,7 mld. Kč, což je o 20 % méně než v roce 2017. Odvody v roce 2018 tak byly nižší než v roce 2016. Důvodem tohoto snížení je pokles inkasa daně z technických her vlivem zmenšení trhu s technickými hrami v důsledku přísnější regulace. V roce 2018 byly odvody z technických her 5,9 mld. Kč (8,8 mld. Kč v r. 2017) a z ostatních hazardních her 3,7 mld. Kč (3,4 mld. Kč v roce 2017). Meziroční pokles se týká státního rozpočtu (o 14 %), ale především rozpočtů obecních (o 25 %).

Obrázek 92 Odvody z technických her a ostatních hazardních her v I. 2013–2019, v mil. Kč




Zdroj: Ministerstvo financí (2019c), převzato z Mravčík et al. (2020).

Pozn.: Jde o odvody, které proběhly v daném roce, tzn. jsou v nich zahrnuty odvody za 1. až 3. čtvrtletí uvedeného roku a za 4. čtvrtletí roku předcházejícího. TH = technické hry.

Problematika zdanění loterijního průmyslu může mít velký vliv i na možný odchod českých společností z českého trhu do zahraničí. Tento krok by mohl mít dopad i na výši nezaměstnanosti. V roce 2015 Robert Chvátal (generální ředitel společnosti Sazka a.s.) v rozhovoru pro Novinky.cz uvedl, že loterijní průmysl je v České republice nejvíce zdaněným průmyslovým odvětvím a v případě dalšího navyšování daní z hazardních her by uvažoval o možném odchodu Sazky a.s. z českého podnikatelského prostředí. Dle údajů České komory loterijního průmyslu (ČKLP) loterijní průmysl vytváří více než 20 000 pracovních míst v České republice a odchod takto velké společnosti jako je Sazka a.s. by způsobil značné zúžení pracovních míst v tomto sektoru. Obrázek 93 přináší pohled na podíl státního rozpočtu a obecních rozpočtů na celkových příjmech veřejných rozpočtů ze zdanění hazardních her ve sledovaném období.


Obrázek 93 Podíl státního rozpočtu a obecních rozpočtů na celkových příjmech veřejných rozpočtů ze zdanění hazardních her v I. 2013–2019, v %



Zdroj: Ministerstvo financí ČR (2019c), převzato z Mravčík et al. (2020).

Dalším omezení provozování hazardních her z pozice státu, přichází z řad obcí. Obce jsou oprávněny regulovat dostupnost kasin a heren na svém území, zákon o hazardních hrách jim umožňuje na základě obecně závazné vyhlášky (dále „OZV“) omezit místně a časově provozování binga, technické hry, živé hry a turnaje malého rozsahu. Zákon jim umožňuje dokonce i úplné zákaz provozování těchto druhů hazardních her. Podle zákona o hazardních hrách vydávají povolení k umístění herního prostoru se stanovením konkrétních hazardních her obecní úřady obcí, neměl by tak nastat rozpor mezi vydaným povolením k umístění herního prostoru a OZV. Viz Obrázek 94.

Obrázek 94 Vývoj počtu obcí s OZV regulující provozování hazardních her v ČR v l. 2009–2019



Zdroj: Ministerstvo financí ČR (2019c), převzato z Mravčík et al. (2020).

Pozn.: Údaje za r. 2018 jsou k 18. 3. 2019. Údaje za předchozí roky jsou vždy k 31. 12. daného roku. Vzhledem ke komplikované evidenci OZV jde o orientační údaje.

Z Obrázku 94 výše je patrné, že počet obcí s OZV regulujícími hazardní hry na svém území od roku 2009 stále roste. K 12. 3. 2019 mělo OZV regulující hazardní hry na svém území 685 obcí, což je o 45 více než na konci roku 2017. Z toho 418 obcí úplně zakázalo provoz TH na svém území, což je o 44 více než na konci roku 2017 a přibližně dvakrát více než na konci roku 2013. Více než 60 % obcí s OZV regulujícími hazardní hry zvolilo možnost úplného zákazu technických her na svém území. Krajskými městy s plošným zákazem technických her či heren na svém území byly v roce 2018 České Budějovice, Jihlava a Brno. Z dalších větších měst s úplným zákazem technických her jsou to např. Kolín, Havířov či Frýdek-Místek.

Ekonomické vlivy

Ekonomické vlivy patří mezi další faktory, které mají zásadní vliv na průběh fungování firem a celého odvětví. Společnosti nejčastěji sledují vývoj HDP (hrubý domácí produkt), inflaci,

úrokové míry a nezaměstnanosti. U loterijního průmyslu dané faktory mají také značný vliv, ale ne tak zásadní jako je to u jiných odvětví. Hraní hazardních her je označováno státem jako droga a řada hráčů jsou ve stavu závislosti na konzumaci hazardní her. Například u patologicky nemocných hráčů poptávka po hazardních hrách není žádným způsobem ovlivněna vývojem makroekonomických ukazatelů. Od roku 2008 s přicházející finanční krizí objem vynaložených peněz do trhu hazardních her po dobu 6 let stagnoval, ale nijak zvlášť se nepropadl. Hráči vložené finanční prostředky v období 2008-2013 oscilovaly okolo 125 mld. Kč ročně (max. 128,5 mld. Kč v roce 2008, min 123,9 mld. Kč v roce 2013). Od tohoto roku vklady hráčů už jen stoupaly, po 5 letech v roce 2018 se více než zdvojnásobily (viz **Chyba! Nenalezen zdroj odkazů.**).

Sociálně kulturní vlivy


Národní monitorovací středisko pro drogy a závislosti společně s agenturou ppm factum resarch provedlo od roku 2012 do roku 2018 celkem 15 studií ve 3 řadách, které zjišťovaly míru zkušenosti s hazardním hraním (prevalenci¹⁰) v obecné populaci:

- Národní výzkum užívání návykových látek (Národní výzkum) – 2 vlny v l. 2012 a 2016.
- Výzkum názorů a postojů občanů České republiky k otázkám zdravotnictví a k problematice zdraví ve spolupráci s agenturou INRES-SONES (Výzkum občanů) – 6 vln v l. 2013–2018.
- Prevalence užívání drog v populaci ČR ve spolupráci s agenturou ppm factum research (Prevalence užívání drog) – 7 vln v l. 2012–2018.

Při pohledu na trendy se zdá, že míra hraní hazardních her v dospělé populaci současně roste. Účast na hazardních hrách v posledních sledovaných měsících uvádí přibližně 30–40 % dospělých. Tento nárůst je zřejmě zapříčiněn otevřením on-line prostředí v České republice pro všechny typy hazardních her (viz Obrázek 95).

¹⁰Prevalence je podíl počtu jedinců trpících danou nemocí k počtu všech jedinců ve sledované populaci.


Obrázek 95 Prevalence hazardního hraní v dospělé populaci 15+ let – srovnání studií realizovaných v l. 2012–2018, v %



Zdroje: Mravčík et al. (2019).

Obdobný trend je patrný u mužů i žen a rovněž ve skupině mladých dospělých ve věku 15–34 let (viz Obrázek 96).

Obrázek 96 Prevalence hazardního hraní v populaci mladých dospělých 15–34 let – srovnání studií realizovaných v l. 2012–2018, v %




Zdroj: Mravčík et al. (2019).

Technicko-technologické vlivy

Technicko-technologické prostředí se v posledních letech velice rychle a dynamicky rozvíjí. Společnosti, které chtějí být konkurenceschopnými na trhu a poskytovat jedny z nejlepších služeb, musí investovat do nových technologií, nápadů, startupů atd. Právě loterijní průmysl vychází zejména z prudkého technicko-technologického rozvoje, elektronizace oboru

hazardních her a silícího trendu provozovat hazardní hry prostřednictvím online prostředí – internetu, čemuž odpovídá i životní styl nastupující generace konzumentů hazardních her. Následující obrázek, který vypovídá o podílu příjmů z land-based a on-line hazardních her potvrzuje, že se od roku 2008 postupně a jistě přesouvá hraní hazardních her z land-based do on-line prostředí. V roce 2008 prakticky všechny příjmy provozovatelů hazardních her plynuly z land-based hazardních her. Po uplynutí jedenácti let příjmy z on-line hazardních her činil 32,5 % celkových příjmů provozovatelů. Provozovatelům tak dlouhodobě roste podíl příjmů z on-line hazardních her (Obrázek 97).

Obrázek 97 Vývoj podílu land-based a on-line hazardních her na trhu podle příjmu provozovatelů v l. 2008–2019, v %



Zdroj: Ministerstvo financí ČR (2019c), převzato z Mravčík et al. (2020).

Závěr strategické analýzy loterijního průmyslu ČR

Loterijní průmysl každým rokem roste. V uplynulých letech 2002–2019 každoroční objem vložených peněz do hazardních her vzrostl, vyjma období finanční krize (2008–2013), při kterém výše vsazených finančních prostředků stagnovala a pohybovala se přibližně okolo 125 mld. Kč ročně. Od roku 2013 však nastal prudký nárůst vsazených peněz a za 5 let, tedy v roce 2018, překročila hranice vložených peněz na hazardní hry dvojnásobek, nežli tomu bylo v roce 2013 (z 123,9 mld. Kč na 249,5 mld. Kč).

Provozovatelé hazardních her stejně jako jiná odvětví pocítují obrovské příležitosti v technologickém rozvoji. V roce 2008 činily příjmy provozovatelů hazardních her ze 100 % pouze z land-based hazardních her, v roce 2019 už to bylo jen 67,5 %. Chybějících 32,5 % celkových příjmů přísluší právě on-line hazardním hrám. Společnosti působící v loterijním odvětví reagují na životní styl nastupující generace a nabízejí jim hraní hazardních her

prostřednictvím on-line prostředí – internetu. Provozovatelům tak dlouhodobě roste podíl příjmů z on-line hazardních her.

Na druhou stranu mezi největší rizika spadají především neustálé změny v legislativě upravující provozování hazardních her (takřka každým rokem dochází ke změně sazeb daně z hazardních her), rostoucí tendence obcí a měst omezovat a zakazovat provozování heren a kasin na svém území prostřednictvím obecně závazné vyhlášky a utržení vysoké, popř. mimořádně vysoké prohry spojenou s rizikem ze hry.

Při pohledu na trendy se zdá, že míra hraní hazardních her v dospělé populaci současně roste. Účast na hazardních hrách v posledních sledovaných měsících uvádí přibližně 30–40 % dospělých. Tento nárůst je zřejmě zapříčiněn otevřením on-line prostředí v České republice pro všechny typy hazardních her. Obdobný trend je patrný u mužů i žen a rovněž ve skupině mladých dospělých ve věku 15–34 let.

5.3.2 Finanční služby

V této kapitole je zpracována strategická analýza bankovního sektoru. I přes to, že společnost SAF, A.S. není přímo banka, ale subjektem poskytující úvěry a půjčky (přesně SAF, A.S. je dle klasifikace ESA2010 ostatním finančním zprostředkovatelem kromě pojišťovacích společností a penzijních fondů, pod zahraniční kontrolou – Kód 12503), je strategická analýza zpracována na nejbližší odvětví – tj. bankovní. Strategická analýza je zpracována v rozsahu: Analýza bankovního sektoru ČR, analýza odvětví.

U zkoumané společnosti je důležité upozornit na skutečnost, že SAF, A.S. se nechová jako „běžná“ obchodní společnost poskytující úvěry a půjčky. Obchodní model společnosti je založen na získávání peněžních prostředků od věřitelů (z emise dluhopisů) a dalším využití těchto peněžních prostředků na nákup cenných papírů od dalších subjektů. Realizovaný výsledek hospodaření je tak vysokou měrou ovlivněn rozdílem mezi nákladovými úroky plynoucími z vydaných dluhopisů, které společnost hradí věřitelům, a výnosovými úroky obdrženými z nakoupených cenných papírů, které získává od dlužníků. Tedy v přeneseném slova smyslu SAF, A.S. si půjčuje finanční prostředky a následně je poskytuje dalším společnostem s vyšším úrokem, než který musí hradit věřitelům.

Teoretický základ při zpracování strategické analýzy bankovního sektoru vychází z publikací autorů Žehrová (2014), Polouček (2009) a Rejnuš (2014).

Analýza bankovního sektoru ČR

Banky jsou obecně považovány za nejvýznamnější podnikatelské subjekty finančního trhu. Z toho také vyplývá, že všechny bankovní instituce musí působit jako součást zpravidla přísně regulovaného bankovního systému (ať už určitého státu, nebo nadnárodního ekonomického společnosti, pokud je příslušní část jeho součástí). „*Bankovní systém (označovaný též jako bankovní soustava) lze definovat jako systém tvořený centrální bankou a všemi obchodními bankami působícími v dané zemi, resp. teritoriu příslušného nadnárodního ekonomického společnosti, jejich vzájemnými vztahy a vazbami k okolí*“ (Rejnuš, 2014).

Bankovní soustava ČR

Bankovní soustavu České republiky tvoří všechny druhy bank na území českého státu a jejich vzájemné vztahy. Do 2. 1. 1990 v České republice fungoval jednostupňový bankovní systém v čele s výrazným monopolem Státní banky československé (SBČS). Hlavní nevýhodou jednostupňového bankovního systému je obtížná regulace inflace, v případě potřeby peněžních prostředků, je „monobanka“ hradí z emise peněz.

V současné době v České republice, stejně tak jako v řadě dalších zemí s rozvinutou ekonomikou, existuje dvoustupňová bankovní soustava. První stupeň bankovní soustavy tvoří centrální (ústřední) banka – Česká národní banka (ČNB). Druhý stupeň bankovní soustavy zastupují obchodní, investiční, hypoteční a další banky a spořitelny.

Česká národní banka

Česká národní banka je též Centrální emisní banka, která se zásadně liší od ostatních bank tím, že má výsadní právo emitovat hotovostní peníze na daném území – v České republice.

Postavení ČNB vymezuje zákon č. 6/1993 Sb., o České národní bance ve znění pozdějších předpisů. Dle tohoto zákon je ČNB ústřední bankou České republiky a orgánem, který vykonává dohled na finančním trhem. Česká národní banka je právnickou osobou veřejného práva, tudíž není zapsána v obchodním rejstříku, a působí jako správní úřad ve věcech bankovníctví a devizového hospodářství. ČNB tedy není obchodní organizací podle obchodního zákoníku ani univerzální bankou podle zákona o bankách. ČNB je také součástí Evropského systému centrálních bank podle Smlouvy o fungování Evropské unie a Protokolu o statutu Evropského systému centrálních bank a Evropské centrální banky.

Funkce ČNB

ČNB v souladu se svým hlavním cílem určuje měnovou politiku, vydává bankovní a mince, řídí peněžní oběh, platební sty a zúčtování bank, vykonává dohled nad osobami působícími na finančním trhu, pečuje o bezpečné fungování a rozvoj finančního trhu.

Mezi hlavní funkce České národní banky patří emise peněz, měnová politika, regulace a dohled, bankovní regulace a dohled, povinné zajištění vkladů, centrální registr úvěrů, banka státu (vlády), správa devizových rezerv a reprezentace vůči zahraničí.

Regulace a dohled

Dohled nad osobami působícími na finančním trhu, analýzu vývoje finančního systému, péči o bezpečné fungování a rozvoj finančního trhu vykonává ČNB.

ČNB vykonává dohled nad:

- Bankami, pobočkami zahraničních bank, spořitelními a úvěrními družstvy, institucemi elektronický peněz, nad bezpečným fungováním bankovního systému.
- Pojišťovnami, zajišťovnami, penzijními fondy, penzijními společnostmi, doplňkovým penzijním spořením a důchodovým spořením.
- Obchodníky s cennými papíry, emitenty cenných papírů, centrálním deponitářem, jinými osobami, které vedou evidenci investiční nástrojů, investičními společnostmi, provozovateli vypořádacích systémů, investičními fondy, nad organizátory trhu s investičními nástroji, stanoví zvláštní právní předpisy, kterými upravují podnikání na kapitálovém trhu.
- Bezpečným, efektivním a spolehlivým fungováním platebních systémů.
- Činnosti jiných osob, které mají povolení podle zvláštních právních předpisů.

Mezi hlavní činnosti dohledu patří:

- Rozhodování o žádostech o udělení licencí k povolení k činnosti.
- Dodržování a kontrolu podmínek stanovených v licenci o povolení k činnosti.
- Získávání informací potřebných pro výkon dohledu, jejich vymáhání, ověřování jejich aktuálnosti a pravdivosti.
- Kontrolu dodržování zákonů, které to ČNB ukládají, kontrolu plnění vyhlášek a opatření vydaných ČNB.
- Ukládání opatření k nápravě, sankcí, řízení o správních deliktech a přestupcích.

Dohled nad finančním trhem vykonává výbor pro finanční trh. Výbor sleduje a projednává především obecné koncepce, přístupy a strategie k dohledu nad finančním trhem, včetně nových trendů. Na kapitálový trh dohlíží ČNB v oblasti podnikání na kapitálovém trhu, obhospodařování a administraci investičních fondů, práva obchodních společností, doplňkové penzijního spoření a dluhopisů. Rozhoduje o právech a povinnostech účastníků kapitálových trhů a kontroluje jejich povinnosti.

Úvěr

Úvěr (též nazýván jako půjčka¹¹) je forma dočasného poskytnutí peněžních prostředků věřitelem (tj. úvěrující) dlužníkovi (tj. úvěrovaný), která je založena na principu návratnosti. Dlužník je při přijetí úvěru povinen za přijetí této půjčky po uplynutí nebo v průběhu doby splatnosti zaplatit nad rámec půjčené částky i určitý úrok.

Druhy úvěrů

Klasifikace úvěrů využívá různá hlediska. Nejčastější způsobem členění úvěrů je dle doby splatnosti a metody úvěrování.

Úvěry dle doby splatnosti

Úvěry dle doby splatnosti se členění na krátkodobé, střednědobé a dlouhodobé. U krátkodobých úvěrů je splatnost do jednoho roku, u střednědobých do čtyř let a u dlouhodobých úvěrů je doba splatnosti delší čtyř let.

Do krátkodobých úvěrů se zahrnují především směnky, směnečné eskontní úvěry, akceptační úvěry, lombardní úvěry a malé osobní úvěry.

Do střednědobých a dlouhodobých úvěrů se řadí:

- Emisní půjčka je úvěr poskytnutý odkoupení dluhopisů, které dlužník emituje za účelem opatření finančních zdrojů.
- Úvěrový zápis či závazková listina je alternativou emisní půjčky. Jde o úvěr, který banky poskytují na základě podepsaného úvěrového listu, tj. písemné závazkové listiny. Dlužník podepisuje úvěrový úpis (závazkovou listinu), na jehož podkladě banka poskytuje úvěrovou částku. Tento doklad slouží věřiteli jako důkaz o pohledávce.

¹¹ Rozdíl mezi úvěrem a půjčkou není pro pochopení dané problematiky příliš podstatný. Půjčka se nemusí týkat peněz a nemusí být spojena s úrokovou sazbou, resp. úrokem. Naopak úvěr se vždy týká peněz a je spojen s úrokem (Šoba a Širůček, 2017).

- Sanační úvěr je úvěr, kterým banka napomáhá financovat obnovení likvidity, náklady nápravných opatření a záchrany hospodářské existence podniku.
- Hypotéční úvěr je úvěr, který banka poskytuje na bytové potřeby. Splácení tohoto úvěru je zajištěno hypotékou, tj. zástavním právem k nemovitosti, na kterou je úvěr žádán nebo k zástavním právem k jiné nemovitosti.

Úvěry dle metody úvěrování

Nejčastějšími typy úvěrů dle metody úvěrování jsou:

- Účelový úvěr – jednorázové poskytnutí peněžních prostředků na domluvený účel.
- Kontokorentní úvěr – při bankovním kontokorentu jde o dohodu, že se vzájemné pohledávky klienta a věřitele nebudou vyúčtovávat jednotlivě, ale v dohodnutých termínech (měsíčně, čtvrtletně apod.)
- Revolvingový úvěr – jde o poskytnutí peněžních prostředků na úvěrování takových potřeb, které se neustále pravidelně opakují. Např. každý patnáctý den v měsíci je bankou poskytnut úvěr ve stanovené výši, který klient musí k 15. dni splatit.

Měnové agregáty

„Měnové agregáty představují souhrn peněžních prostředků s jistým stupněm likvidity, obvykle se značí velkým písmenem M a příslušnou číslicí. Každý měnový agregát s vyšším číslem obsahuje celý předchozí měnový agregát plus určitou další část méně likvidních peněžních prostředků“ (Žehrová, 2014).

Stabilita peněz

Stabilita peněz závisí na vývoji hrubého domácího produktu (tj. souhrnný ukazatel objemu výkonu ekonomiky), změnách v rychlosti oběhu peněz a vývoji cen hrubého domácího produktu. Přiměřené množství peněz v oběhu má zabezpečovat sektor bankovníctví, neboť ten vytváří peníze. Velikost a struktura měnové báze by měla odpovídat potřebám zdravého vývoje ekonomiky. Stabilita peněz je právě ovlivněna právě tím, jak měnová báze odpovídá těmto potřebám.


Inflace

Pod pojmem inflace si lze představit dlouhodobější nepřetržitý růst cenové hladiny, který je spojen s nadměrnou emisí peněz, a který zároveň vede k jejím znehodnocení. Znehodnocení peněz je ve stejném slova smyslu pokles kupní síly peněz.

„Inflace je statisticky měřená indexem spotřebitelským cen (CPI), vyjadřujícím změnu cen koše vybraného spotřebního zboží a služeb“ (Žehrová, 2014).

Pro výpočet ceny změn jsou používány indexy spotřebitelských cen. Tyto indexy poměřují úroveň cen vybraného koše výrobků a služeb ve dvou obdobích, přičemž váha položky ve spotřebním koši odpovídá podílu spotřeby na celkové spotřebě domácností. Přírůstek indexů spotřebitelských cen je míra inflace. Spotřební koše se člení na potraviny, nepotravinářské zboží a služby. Průměrná roční míra inflace v letech 2000–2019 je znázorněna na Obrázku 98.

Obrázek 98 Průměrná roční míra inflace v letech 2000–2019 (v procentech)



Zdroj: Český statistický úřad (2020).

Pozn. Míra inflace vyjádřená přírůstkem průměrného ročního indexu spotřebitelských cen vyjadřuje procentní změnu průměrné cenové hladiny za 12 posledních měsíců proti průměru 12 předchozích měsíců.

Úroková míra

Úroková míra je další faktor, který ovlivňuje stabilitu měny – patří vedle inflace a nabídky a poptávky po penězích mezi nejdůležitější faktory. Dle Žehrové (2014) „úroková míra je podíl úroku a zapůjčené částky kapitálu vyjádřen v reálném čísle. Konkrétní úroková míra pro určitou operaci se nazývá úroková sazba (i), je vyjádřena v procentech na roční bázi a vyjadřuje cenu za půjčené prostředky.“

Sazby ČNB


Výsledné clientské úrokové sazby, za které si domácnosti a firmy v soukromých bankách mohou půjčovat a ukládat, se mění v závislosti na změnách měnově politických sazeb ČNB. Hodnoty clientských úrokových sazeb pak ovlivňují poptávku – v jakém měřítku budou domácnosti spotřebovávat a firmy investovat, a naopak, v jakém množství budou spořit. Měnově politické sazby, které stanovuje Česká národní banka, tvoří:

- limitní sazba pro dvoutýdenní repo-operace (tj. 2T repo sazba),
- diskontní sazba,
- lombardní sazba.

2T repo sazba je hlavní nástrojem monetární politiky ČNB, kdy její výše ovlivňuje vývoj krátkodobých sazeb peněžního trhu. Výnosy pro delší splatnosti jsou trhem odvozovány na základně zahrnutí inflačních očekávání a jiných faktorů.

Lombardní a diskontní sazba vytvářejí tzv. koridor pro pohyb krátkodobých úrokových sazeb peněžního trhu. Diskontní sazba představuje dolní mez tohoto koridoru – touto sazbou je úročena tzv. jednodenní depozitní facilitita (tj. přebytek likvidity, který obchodní banky nejsou schopny uložit na peněžním trhu). Naopak lombardní sazba tvoří horní mez pohybu krátkodobých sazeb peněžního trhu – touto sazbou je úročena tzv. jednodenní zapůjčení facilitita (tj. nedostatek likvidity, který obchodní banky nedokáží získat na peněžním trhu). Vývoj úrokových sazeb ČNB (v %) je zobrazen na Obrázku 99.


Obrázek 99 Vývoj úrokových sazeb ČNB (v %)



Zdroj: Vlastní zpracování dle Česká národní banka (2020b).

Počátkem roku 2020 v důsledku celosvětové pandemie COVID-19 se Česká národní banka snížením 2T repo sazby snažila podpořit českou ekonomiku. Snížení 2T repo sazby mělo vliv na snížení klientských úvěrových úrokových sazeb u domácností a nefinančních podniků. Snížení limitní sazby pro dvoutýdenní repo-operace také vliv na snížení úrokových sazeb na běžných a spořicíh účtech – viz Obrázek 100.

Obrázek 100 Vývoj vybraných úrokových sazeb MFI (v %)




Zdroj: Vlastní zpracování dle Česká národní banka (2020b).
Pozn. MFI, tj. měnové finanční instituce.

Analýza odvětví

Obrázek 101 graficky znázorňuje vývoj poskytování úvěrů soukromého sektoru a roční míry růst úvěrů nefinančním podnikům a domácnostem. Konkrétně lze z obrázku vyčíst výši poskytnutých úvěrů pojišťovněm a penzijním fondům, domácnostem, nefinančním podnikům a ostatním finančním zprostředkovatelům.


Obrázek 101 Úvěry soukromému sektoru a roční míry růstu úvěrů nefinančním podnikům a domácnostem (v mld. Kč)



Zdroj: Česká národní banka (2020a).

Z Obrázku 101 je patrné, že v desetiletém časovém horizontu došlo k nárůstu poskytování úvěrů v soukromém sektoru. V roce 2010 byly poskytnuty úvěry ve výši necelých 2 000 mld. Kč úvěrů v soukromém sektoru, v roce 2020 (hodnoty za první pololetí 2020) už tomu bylo přibližně 3 250 mld. Kč. Z uvedených dat je zjevné, že trend poskytování úvěrů má rostoucí tendence, protože hodnota půjčených peněžních prostředků se zvýšila v desetiletém období téměř o 65 %. Obrázek 102 zobrazuje emitované dluhopisy v ČR.

Obrázek 102 Emitované dluhopisy v ČR (v mil. Kč)



Zdroj: Vlastní zpracování dle Česká národní banka (2020b).

Vývoj emitovaných dluhopisů má stejný průběh jako vývoj poskytnutých půjček, tedy rostoucí (Obrázek 102). Největším emitentem dluhopisů po celé sledované období byl vždy stát (tj. vládní instituce), jeho emise dluhopisů se pohybovala v daném období okolo 50 % celkové emise dluhopisů České republiky.

Závěr strategické analýzy bankovního sektoru

Zkoumaná společnost SAF, A.S. je specifická svým předmětem podnikání, společnost se nechová jako „běžná“ obchodní společnost poskytující úvěry a půjčky. Obchodní model společnosti je založen na získávání peněžních prostředků od věřitelů (z emise dluhopisů) a dalším využití těchto peněžních prostředků na nákup cenných papírů od dalších subjektů. Realizovaný výsledek hospodaření je tak vysokou měrou ovlivněn rozdílem mezi nákladovými úroky plynoucími z vydaných dluhopisů, které společnost hradí věřitelům, a výnosovými úroky obdrženými z nakoupených cenných papírů, které získává od dlužníků. Tedy v přeneseném

slova smyslu SAF, A.S. si půjčuje finanční prostředky a následně je poskytuje dalším společnostem s vyšším úrokem, než který musí hradit věřitelům. I přes to, že společnost SAF, A.S. není přímo banka, ale subjektem poskytující úvěry a půjčky, je strategická analýza zpracována na nejbližší odvětví – tj. bankovní. Konkrétně je SAF, A.S. dle klasifikace ESA2010¹² ostatním finančním zprostředkovatelem kromě pojišťovacích společností a penzijních fondů, pod zahraniční kontrolou (Kód 12503).

Podle ukazatele poskytnutých úvěrů soukromému sektoru v České republice za období 2010–2020 (hodnoty roku 2020 jsou za první pololetí) lze konstatovat, že bankovní sektor má vzestupnou tendenci a každým rokem roste. Za toto desetileté období objem poskytnutých úvěrů soukromého sektoru v ČR vzrostl téměř o 65 %. Roku 2010 bylo poskytnuto necelých 2 000 mld. Kč, o 10 let později, v roce 2020 už 3 250 mld. Kč. Růst bankovního průmyslu potvrzuje i údaj o výši emitovaných dluhových cenných papírů na území České republiky – celkovým objem emise měl v období 2010–2019 rostoucí trend. Největším emitentem dluhopisů byl v každém roce stát (tj. vládní instituce).

5.4 Analýza trhu

Analýza trhu je v tomto případě zpracována pro loterijní průmysl a sektor finančních služeb.

5.4.1 Loterijní průmysl

Trh s hazardními hrami

V současné době mohou být v ČR provozovány hazardní hry na základě povolení vydaného podle loterijního zákona (dále „ZoL“ i podle zákona o hazardních hrách (dále „ZHH“). K 1. 1. 2019 mělo alespoň podle jednoho z nich povolení provozovat určitý typ hazardní hry v ČR 57 společností, což je o 3 provozovatele méně než o rok dříve.

Tabulka 71 zobrazuje počet společností s povolením k provozování hazardních her.

¹² ESA2010 (The European System of National and Regional Accounts) je mezinárodně porovnatelný účetní rámec pro systematický a podrobný popis celkového hospodářství (tj. regionu, země nebo skupiny zemí), jeho jednotlivých složek a jeho vztahů s ostatními hospodářskými celky.

Tabulka 71 Počet společností s povolením k provozování hazardních her (ZoL i ZHH) podle typu, k 1. 1. 2018, k 1. 1. 2019 a k 1. 1. 2020

Typ povolené hry	Počet společností		
	K 1. 1. 2018	K 1. 1. 2019	K 1.1. 2020
Loterie	9	9	9
Kurové sázky	14	11	11
Technické hry	40	45	46
Živé hry	39	37	37
Bingo	1	1	0

Zdroj: Vlastní zpracování, převzato z Mravčík et al. (2020), původní zdroj Ministerstvo financí ČR (2019c).

Provozovatelé kurzových sázek

Na provozování land-based kurzových sázek k 1. 1. 2019 mělo povolení v České republice 8 společností (o jednu méně než v roce 2018). Ve skutečnosti však k 4. 1. 2019 provozovalo land-based kurzové sázky pouze 5 společností, které měly celkem 2 085 sázkových kanceláří na 1 951 adresách. V roce 2017 odešla například Sazka z trhu land-based kurzových sázek, která ukončila provozování kurzových sázek na téměř 900 místech, nadále však provozuje on-line kurzové sázky. Stejným způsobem se zachovala i společnost Synot Tip. Mezi společnosti s největším počtem sázkových kanceláří patřily společnosti Tipsport.net (734) a Fortuna game (567).

Tabulka 72 zobrazuje provozovatelé land-based kurzových sázek k 4. 1. 2019.

Tabulka 72 Provozovatelé land-based kurzových sázek k 4. 1. 2019

Název společnosti	Sídlo	Počet sázkových kanceláří
Evona Electronic	SR	168
Fortuna Game	ČR	567
Chance	ČR	197
Slot Group	ČR	419
Tipsport.net	ČR	734
Celkem		2085

Zdroj: Vlastní zpracování dle Ministerstvo financí ČR (2019a).

Značná většina kurzového sázení probíhá v současnosti prostřednictvím internetu v on-line prostředí. K 1. 1. 2020 mělo povolení provozovat on-line kurzové sázky celkem 8 společností (o 1 méně než rok předchozí). Online kurzové sázky však provozovalo pouze 7 společností.

Tabulka 73 zobrazuje seznam provozovatelů on-line kurzových sázek na území České republiky k 1. 1. 2020.

Tabulka 73 Provozovatelé on-line kurzových sázek k 1. 1. 2020

Provozovatel	Sídlo	Povolení podle	Webová stránka	Provozování
Fortuna Game	ČR	ZHH	ifortuna.cz	ano
Chance	ČR	ZHH	chance.cz	ano
Maxi-Tip	ČR	ZHH	maxitip.cz	ano
Sazka	ČR	ZoL	sazkabet.cz	ano
Slot Group	ČR	ZoL	czechbet.cz	ne
Synot Tip	ČR	ZoL	synotip.cz	ano
Tipsport.net	ČR	ZHH	tipsport.net	ano
TSG Interactive	Malta	ZHH	betstars.cz	ano

Zdroj: Vlastní zpracování dle Ministerstvo financí ČR (2020).

5.4.2 Finanční služby

Tabulka 74 zobrazuje výčet měnových finanční institucí, které působily k 31. 7. 2020 na území České republiky.

Tabulka 74 Měnové finanční instituce v ČR k 31. 7. 2020


Název společnosti	Název společnosti
Air Bank a.s.	Komerční banka, a.s.
Artesa, spořitelní družstvo	mBank S.A., organizační složka
Bank Gutmann Aktiengesellschaft, pobočka Česká republika	Modrá pyramida stavební spořitelna, a.s.
Bank of Communications Co., Ltd., Prague Branch odštěpný závod	MONETA Money Bank, a.s.
Bank of China (CEE) Ltd. Prague Branch	MONETA Stavební Spořitelna, a.s.
Banka CREDITAS a.s.	MUFG Bank (Europe) N.V. Prague Branch
BNP Paribas Personal Finance SA, odštěpný závod	NEY spořitelní družstvo
BNP Paribas S.A., pobočka Česká republika	Oberbank AG pobočka Česká republika
Citfin, spořitelní družstvo	PARTNER BANK AKTIENGESELLSCHAFT, odštěpný závod
Citibank Europe plc, organizační složka	Peněžní dům, spořitelní družstvo
COMMERZBANK Aktiengesellschaft, pobočka Praha	PKO BP S.A., Czech Branch
Česká exportní banka, a.s.	Podnikatelská družstevní záložna
Česká národní banka	Poštová banka, a.s., pobočka Česká republika
Česká spořitelna, a.s.	PPF banka a.s.
České spořitelní družstvo	PRIVAT BANK der Raiffeisenlandesbank Oberösterreich Aktiengesellschaft, pobočka Česká republika
Českomoravská stavební spořitelna, a.s.	Privatbanka, a.s., pobočka Česká republika
Českomoravská záruční a rozvojová banka, a.s.	Raiffeisen stavební spořitelna a.s.
Československá obchodní banka, a. s.	Raiffeisenbank a.s.
Československé úvěrní družstvo	Saxo Bank A/S, organizační složka
Deutsche Bank Aktiengesellschaft Filiale Prag, organizační složka	Sberbank CZ, a.s.
Družstevní záložna Kredit	SMBC Bank EU AG Prague Branch
Družstevní záložna PSD	Stavební spořitelna České spořitelny, a.s.
Equa bank a.s.	TRINITY BANK a.s.
Expobank CZ a.s.	UniCredit Bank Czech Republic and Slovakia, a.s.
Fio banka, a.s.	Volksbank Raiffeisenbank Nordoberpfalz eG pobočka Cheb
HSBC France – pobočka Praha	Všeobecná úvěrová banka a.s., pobočka Praha; zkráceně: VUB, a.s., pobočka Praha
Hypoteční banka, a.s.	Waldviertler Sparkasse Bank AG

Industrial and Commercial Bank of China Limited, Prague Branch, odštěpný závod	Western Union International Bank GmbH, organizační složka
ING Bank N.V.	Wüstenrot hypoteční banka a.s.
J & T BANKA, a.s.	x

Zdroj: Vlastní zpracování, dle Česká národní banka (2020b).

Neustále narůstající tempo poskytnutých úvěrů a půjček dokládá i zvyšující se počet obchodníků s cennými papíry v ČR. Dle statistiky České národní banky počet subjektů, který obchodovaly s cennými papíry v průběhu posledních devíti let (tj. 2010–2019) kontinuálně roste. Za toto období se změnil počet subjektů z 58 na 84 (Obrázek 103).

Obrázek 103 Obchodující subjekty s cennými papíry v ČR



Zdroj: Vlastní zpracování dle Česká národní banka (2020b).

Z analýzy konkurence bankovního sektoru ČR jasné vyplývá, že k 31. 7. 2020 na území České republiky působilo celkem 59 měnových finančních institucí. Měnovými finančními institucemi se rozumí centrální banka, rezidentské banky ČR a všechny ostatní rezidentské finanční instituce, předmětem jejichž činnosti je přijímat vklady a/nebo prostředky velmi podobným vkladům od jiných subjektů než měnových finančních institucí a na vlastní účet poskytovat úvěry a/nebo investovat do cenných papírů. V ČR je sektor měnových finančních institucí tvořen centrální bankou, obchodními bankami, spořitelními a úvěrními družstvy a fondy peněžního trhu.

5.5 Diskontní sazba

Předmětem této kapitoly je stanovení diskontní sazby za použití predikovaných údajů o dluhopisech, jako je spread a bezriziková úroková míra.

5.5.1 Spread

Spread je v této části stanoven za pomoci třech skupin neuronových sítí (vícevrstvé perceptronové sítě, NN s GRL vrstvou a NN s LSTM vrstvou), a to v rozsahu finančních služeb jinde nezařazených a služeb heren a kurzového sázení.

5.5.1.1 Finanční služby jinde nezařazené

Spread stanovený pomocí vícevrstevných perceptronových NN

Tabulka 75 ukazuje přehled uchovaných vícevrstevných perceptronových sítí v případě stanovení spreadu. Lze si všimnout, že výkony sítí se pohybují nad hranicí devadesáti procent, což značí velmi dobrý výkon sítí.

Tabulka 75 Přehled uchovaných vícevrstevných perceptronových sítí

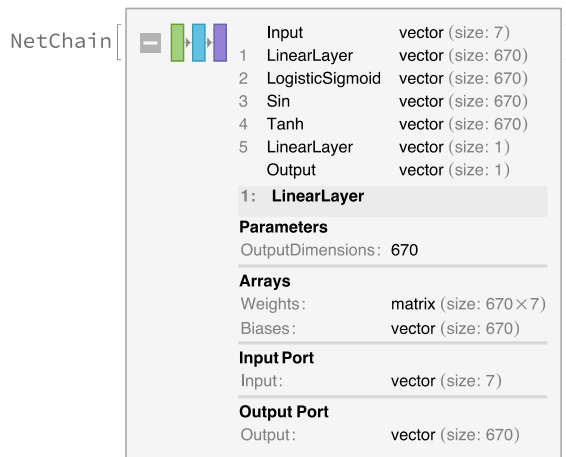
ID sítě	Název sítě	Výkon sítě
D-FS-NN_LIN1	7-LinearLayer[670]-LogisticSigmoid-Sin-Tanh-1	0,981344
D-FS-NN_LIN2	7-LinearLayer[1175]-LogisticSigmoid-Sin-Sin-1	0,982033
D-FS-NN_LIN3	7-LinearLayer[5985]-Ramp-Sin-Tanh-1	0,982534
D-FS-NN_LIN4	7-LinearLayer[6475]-Ramp-Sin-Sin-1	0,985414
D-FS-NN_LIN5	7-LinearLayer[5770]-Ramp-Sin-Sin-1	0,994862

Zdroj: Vlastní.

D-FS-NN_LIN1

Základní strukturu sítě D-FS-NN_LIN1 lze pozorovat na Obrázku 104. Zde můžeme vidět, že jsou použity funkce lineární, logistický Sigmoid, sinus a hyperbolický tangens. Výstupní dimenze je rovna 670.

Obrázek 104 Základní struktura sítě D-FS-NN_LIN1

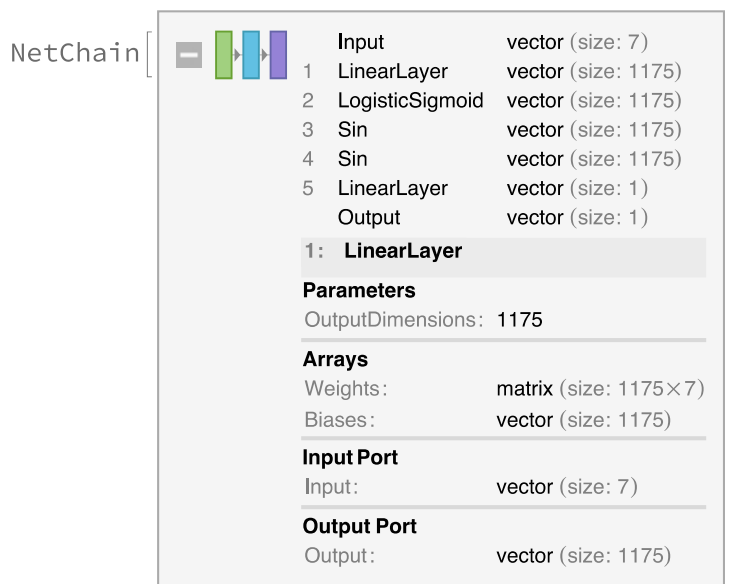


Zdroj: Vlastní.

D-FS-NN_LIN2

Základní strukturu sítě D-FS-NN_LIN2 je možné vidět na Obrázku 105. Zde je patrné, že jsou použity funkce lineární, logistický Sigmoid a sinus. Výstupní dimenze je rovna 1 175.

Obrázek 105 Základní struktura sítě D-FS-NN_LIN2

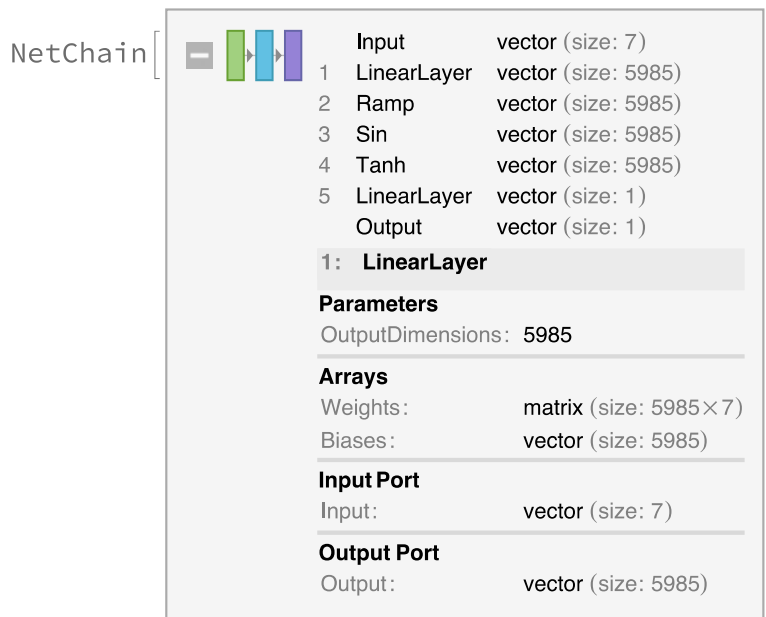


Zdroj: Vlastní.

D-FS-NN_LIN3

Základní strukturu sítě D-FS-NN_LIN2 lze pozorovat na Obrázku 106. Ve struktuře jsou použity funkce lineární, ramp, sinus a hyperbolický tangens. Výstupní dimenze je rovna 5 985.

Obrázek 106 Základní struktura sítě D-FS-NN_LIN3

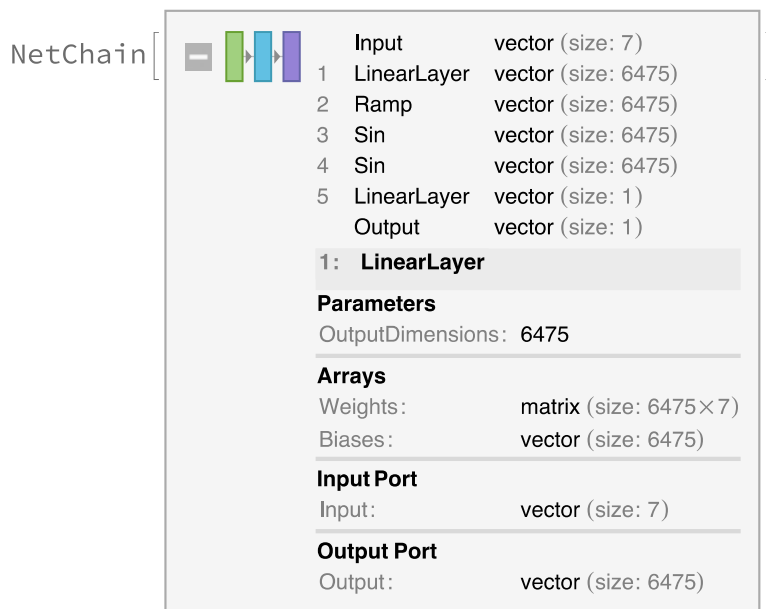


Zdroj: Vlastní.

D-FS-NN_LIN4

Základní struktura použité sítě D-FS-NN_LIN4 je zobrazena na Obrázku 107.

Obrázek 107 Základní struktura sítě D-FS-NN_LIN4

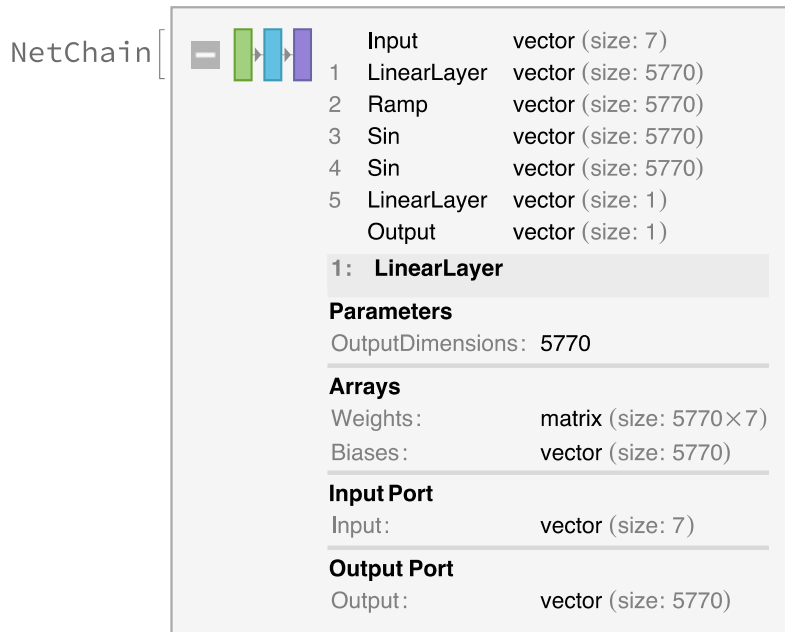


Zdroj: Vlastní.

D-FS-NN_LIN5

Základní struktura použité sítě D-FS-NN_LIN5 je zobrazena na Obrázku 108. Na obrázku lze pozorovat, že výstupní dimenze je rovna 5 770.

Obrázek 108 Základní struktura sítě D-FS-NN_LIN5



Zdroj: Vlastní.

Spread stanovený pomocí NN s GRL vrstvou

Tabulka 76 představuje sítě pro stanovení spreadu, a to za pomoci sítí obsahující GRL vrstvu. Výkon sítí i v tomto případě přesahuje devadesát procent, což značí velmi vysoký výkon.

Tabulka 76 Přehled uchovaných NN s GRL vrstvou

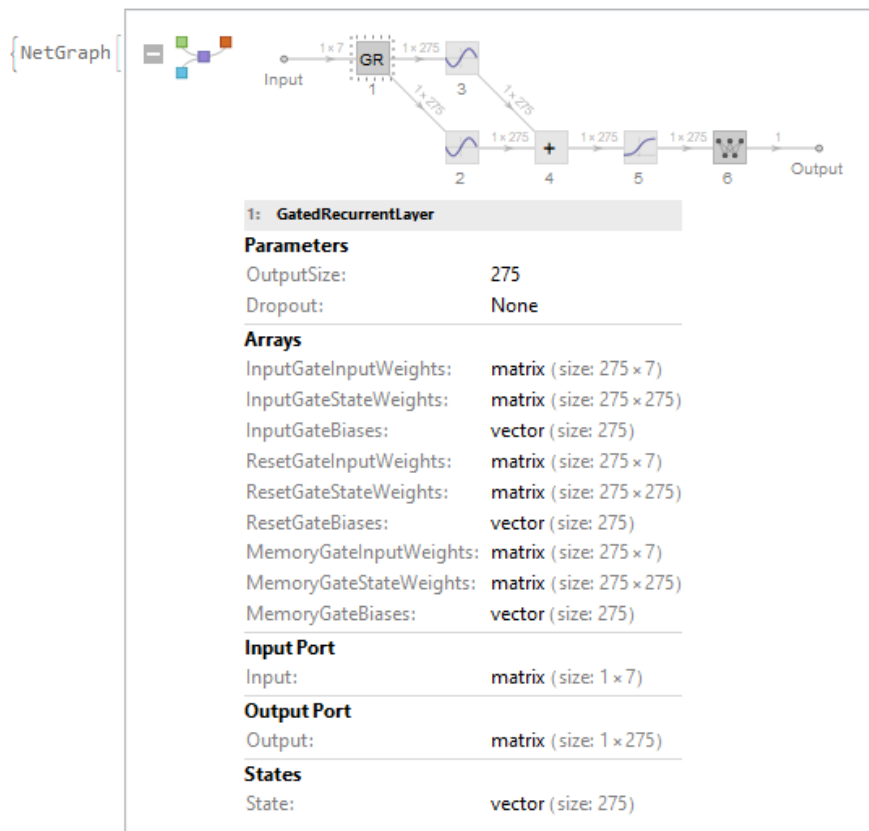
ID sítě	Název sítě	Výkon sítě
D-FS-NN_GRL1	7-GatedRecurrentLayer[275]-Sin-Sin-LogisticSigmoid-1	0,965016
D-FS-NN_GRL2	7-GatedRecurrentLayer[220]-Sin-Ramp-Tanh-1	0,965946
D-FS-NN_GRL3	7-GatedRecurrentLayer[290]-Ramp-Sin-Sin-1	0,966471
D-FS-NN_GRL4	7-GatedRecurrentLayer[480]-Ramp-Sin--1	0,969918
D-FS-NN_GRL5	7-GatedRecurrentLayer[75]-LogisticSigmoid-LogisticSigmoid-Sin-1	0,972959

Zdroj: Vlastní.

D-FS-NN_GRL1

Obrázek 109 ukazuje základní strukturu sítě D-FS-NN_GRL1. Lze pozorovat, že velikost výstupu je rovna 275.

Obrázek 109 Základní struktura sítě D-FS-NN_GRL1

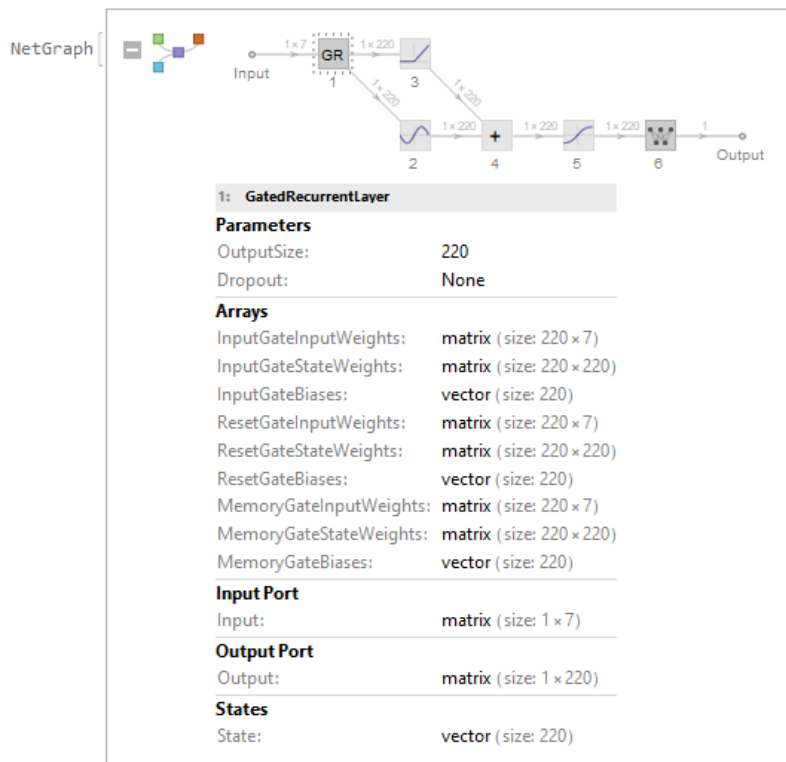


Zdroj: Vlastní.

D-FS-NN_GRL2

Základní struktura použité sítě D-FS-NN_GRL2 je zobrazena na Obrázku 110. Velikost výstupu je rovna 220.

Obrázek 110 Základní struktura sítě D-FS-NN_GRL2

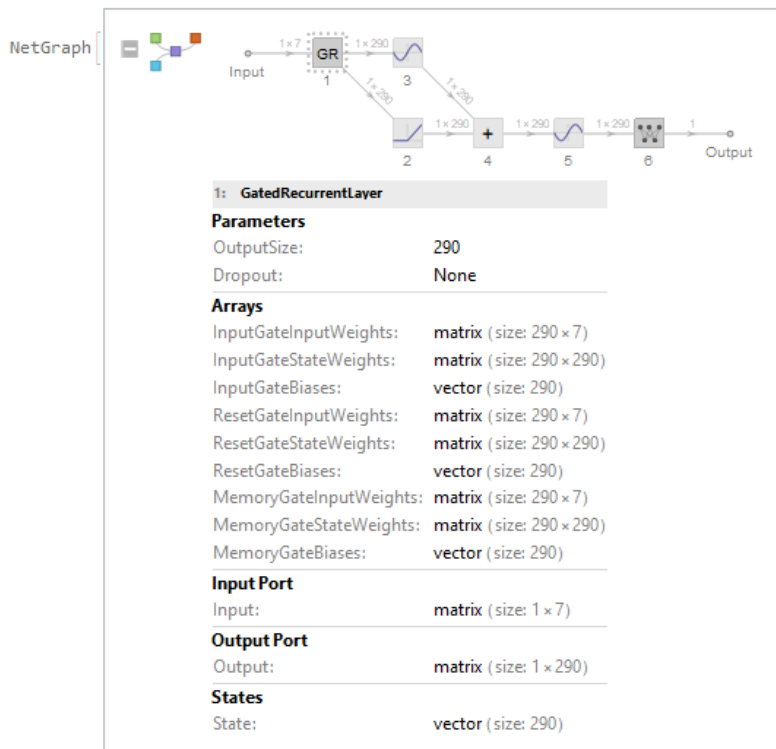


Zdroj: Vlastní.

D-FS-NN_GRL3

Obrázek 111 ukazuje základní strukturu sítě D-FS-NN_GRL3. Lze sledovat, že velikost výstupu je rovna 290.

Obrázek 111 Základní struktura sítě D-FS-NN_GRL3

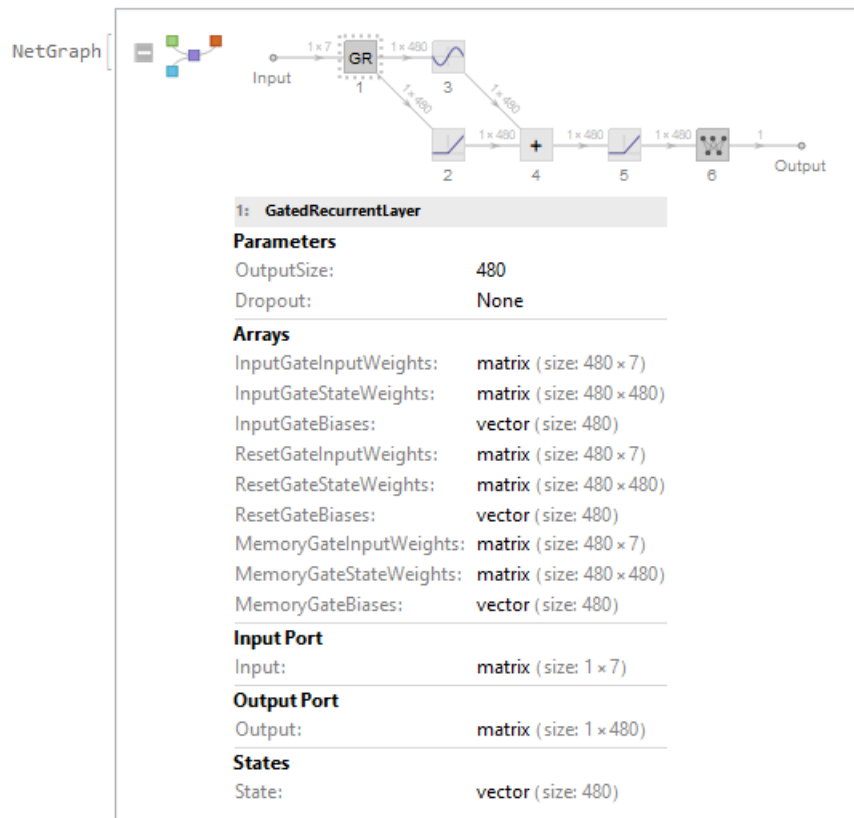


Zdroj: Vlastní.

D-FS-NN_GRL4

Struktura sítě D-FS-NN_GRL4 v základním provedení je ukázána na Obrázku 112.

Obrázek 112 Základní struktura sítě D-FS-NN_GRL4



Zdroj: Vlastní.

D-FS-NN_GRL5

Základní strukturu sítě D-FS-NN_GRL5 je možno sledovat na Obrázku 113. Je možno vidět, že velikost výstupu je rovna hodnotě 75.

Obrázek 113 Základní struktura sítě D-FS-NN_GRL5



Zdroj: Vlastní.

Spread stanovený pomocí NN s LSTM vrstvou

Tabulka 77 ukazuje přehled uchovaných neuronových sítí s LSTM vrstvou. Opět lze pozorovat Výkon sítě v tabulce. I v tomto případě se jedná o výkony přesahující hranici devadesáti procent.

Tabulka 77 Přehled uchovaných NN s LSTM vrstvou

ID sítě	Název sítě	Výkon sítě
D-FS-NN_LSTM1	7-LongShortTermMemoryLayer[275]-Ramp-Ramp-Ramp-1	0,969177
D-FS-NN_LSTM2	7-LongShortTermMemoryLayer[275]-Sin-Sin-Sin-1	0,969693
D-FS-NN_LSTM3	7-LongShortTermMemoryLayer[275]-Tanh-Tanh-Tanh-1	0,975851
D-FS-NN_LSTM4	7-LongShortTermMemoryLayer[275]-LogisticSigmoid-Sin-Sin-1	0,976239
D-FS-NN_LSTM5	7-LongShortTermMemoryLayer[275]-Tanh-Ramp-Ramp-1	0,976867

Zdroj: Vlastní.

D-FS-NN_LSTM1

První uchovanou sítí s LSTM vrstvou je síť D-FS-NN_LSTM1. Základní strukturu sítě je možné vidět na Obrázku 114.

Obrázek 114 Základní struktura sítě D-FS-NN_LSTM1

Layer	Type	Size
Input	matrix	(size: 1 × 7)
1 LongShortTermMemoryLayer	matrix	(size: 1 × 735)
2 Ramp	matrix	(size: 1 × 735)
3 Ramp	matrix	(size: 1 × 735)
4 Ramp	matrix	(size: 1 × 735)
5 LinearLayer	vector	(size: 1)
Output	vector	(size: 1)

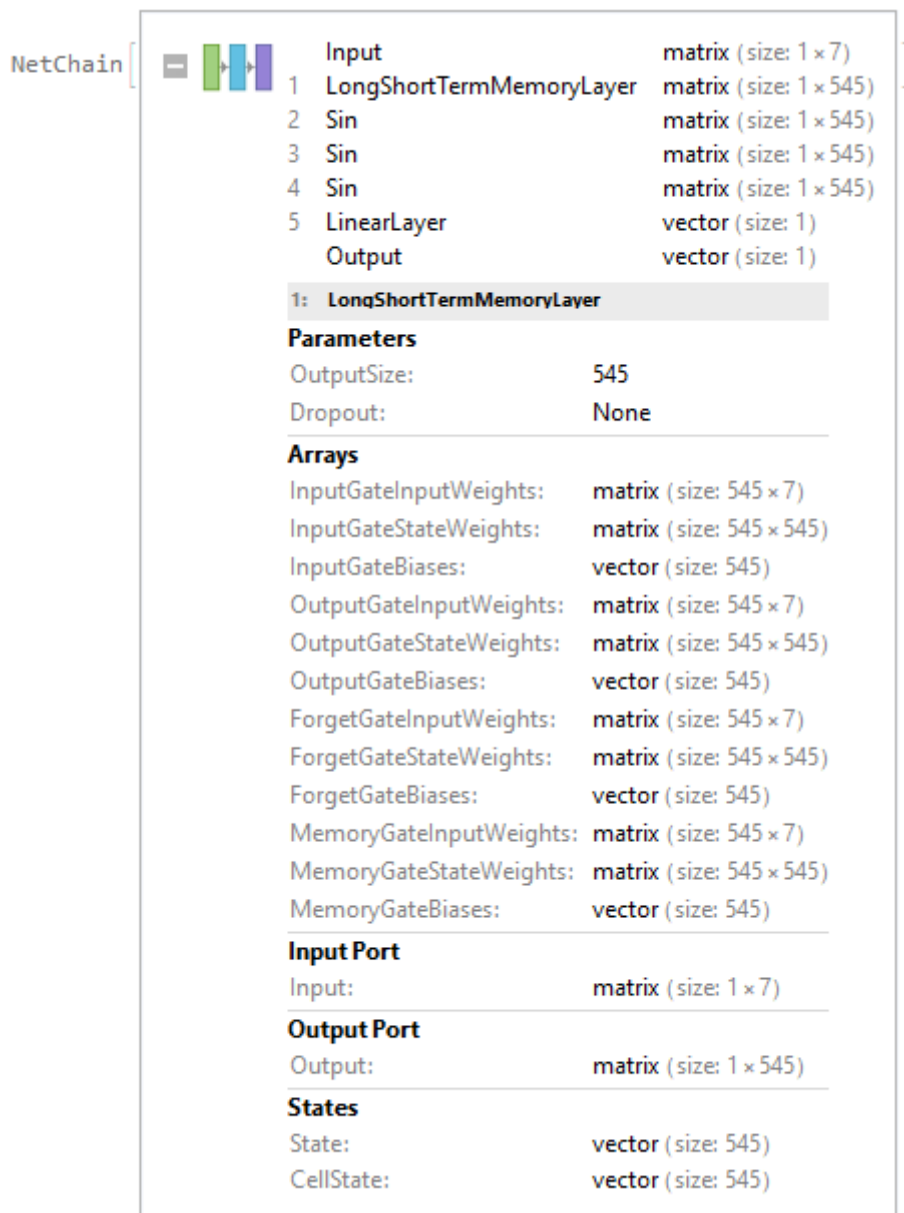
1: LongShortTermMemoryLayer	
Parameters	
OutputSize:	735
Dropout:	None
Arrays	
InputGateInputWeights:	matrix (size: 735 × 7)
InputGateStateWeights:	matrix (size: 735 × 735)
InputGateBiases:	vector (size: 735)
OutputGateInputWeights:	matrix (size: 735 × 7)
OutputGateStateWeights:	matrix (size: 735 × 735)
OutputGateBiases:	vector (size: 735)
ForgetGateInputWeights:	matrix (size: 735 × 7)
ForgetGateStateWeights:	matrix (size: 735 × 735)
ForgetGateBiases:	vector (size: 735)
MemoryGateInputWeights:	matrix (size: 735 × 7)
MemoryGateStateWeights:	matrix (size: 735 × 735)
MemoryGateBiases:	vector (size: 735)
Input Port	
Input:	matrix (size: 1 × 7)
Output Port	
Output:	matrix (size: 1 × 735)
States	
State:	vector (size: 735)
CellState:	vector (size: 735)

Zdroj: Vlastní.

D-FS-NN_LSTM2

Druhá síť ze skupiny neuronových sítí s LSTM vrstvou je síť D-FS-NN_LSTM2. Její základní strukturu zobrazuje Obrázek 115. Lze vysledovat, že velikost výstupu je rovna hodnotě 545.

Obrázek 115 Základní struktura sítě D-FS-NN_LSTM2



Zdroj: Vlastní.

D-FS-NN_LSTM3

Třetí uchovanou sítí s LSTM vrstvou je síť D-FS-NN_LSTM3. Základní strukturu sítě je možné vidět na Obrázku 116.

Obrázek 116 Základní struktura sítě D-FS-NN_LSTM3

Layer	Type	Size
Input	matrix	(size: 1 × 7)
1 LongShortTermMemoryLayer	matrix	(size: 1 × 135)
2 Tanh	matrix	(size: 1 × 135)
3 Tanh	matrix	(size: 1 × 135)
4 Tanh	matrix	(size: 1 × 135)
5 LinearLayer	vector	(size: 1)
Output	vector	(size: 1)

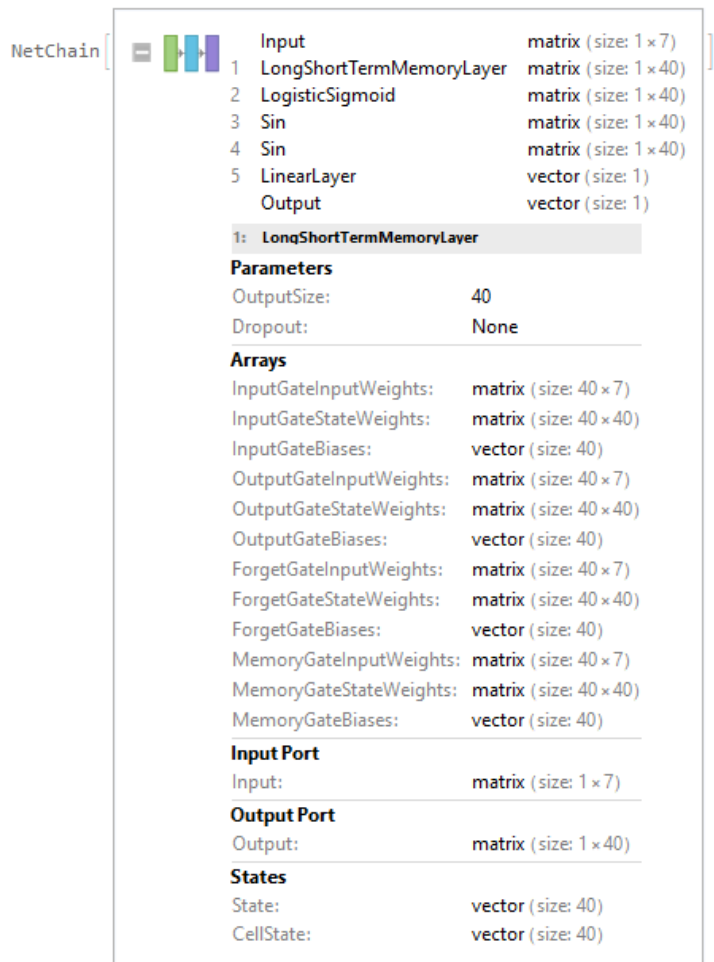
1: LongShortTermMemoryLayer	
Parameters	
OutputSize:	135
Dropout:	None
Arrays	
InputGateInputWeights:	matrix (size: 135 × 7)
InputGateStateWeights:	matrix (size: 135 × 135)
InputGateBiases:	vector (size: 135)
OutputGateInputWeights:	matrix (size: 135 × 7)
OutputGateStateWeights:	matrix (size: 135 × 135)
OutputGateBiases:	vector (size: 135)
ForgetGateInputWeights:	matrix (size: 135 × 7)
ForgetGateStateWeights:	matrix (size: 135 × 135)
ForgetGateBiases:	vector (size: 135)
MemoryGateInputWeights:	matrix (size: 135 × 7)
MemoryGateStateWeights:	matrix (size: 135 × 135)
MemoryGateBiases:	vector (size: 135)
Input Port	
Input:	matrix (size: 1 × 7)
Output Port	
Output:	matrix (size: 1 × 135)
States	
State:	vector (size: 135)
CellState:	vector (size: 135)

Zdroj: Vlastní.

D-FS-NN_LSTM4

Čtvrtá síť ze skupiny neuronových sítí s LSTM vrstvou je síť D-FS-NN_LSTM4. Její základní strukturu zobrazuje Obrázek 117. Lze vysledovat, že velikost výstupu je rovna hodnotě 40.

Obrázek 117 Základní struktura sítě D-FS-NN_LSTM4

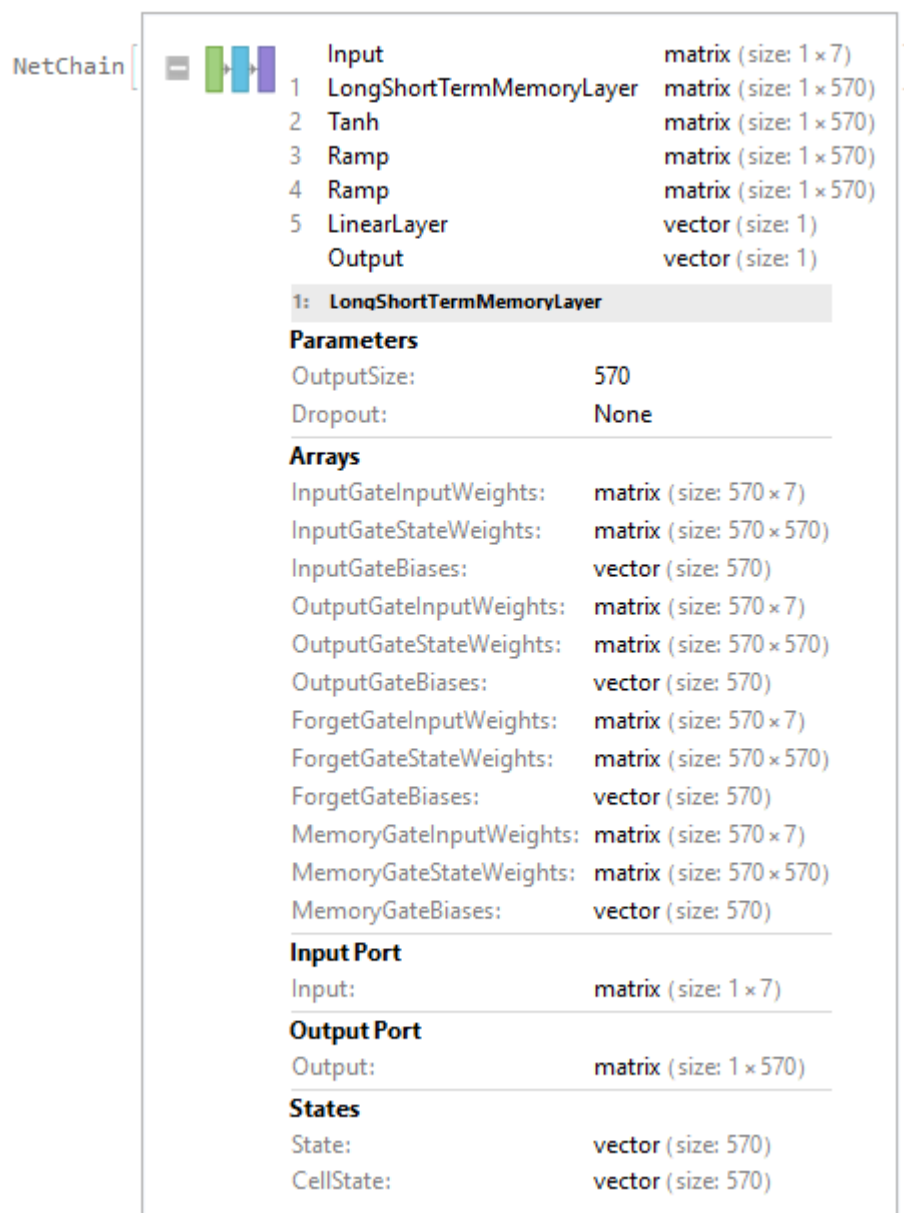


Zdroj: Vlastní.

D-FS-NN_LSTM5

Poslední sítí ze skupiny sítí s LSTM vrstvou je síť D-FS-NN_LSTM5. Základní struktura této sítě je uvedena na Obrázku 118.

Obrázek 118 Základní struktura sítě D-FS-NN_LSTMS



Zdroj: Vlastní.

Výsledný spread hodnocených dluhopisů

Tabulka 78 představuje predikci velikosti Spreadu dluhopisů podle vícevrstevných perceptronových sítí pro SAF_1, SAF_2 a SAF_3. Predikce spreadu se pohybuje u jednotlivých sítí v rozmezí hodnot 0,113808 až 0,176093. Nevyšší hodnoty spreadu dosáhla síť D-FS-NN_LIN4, a to s hodnotou 0,176093.

Tabulka 78 Predikce Spreadu podle vícevrstvých perceptronových sítí pro SAF_1, SAF_2 a SAF_3.

ID sítě	Název sítě	Predikce
D-FS-NN_LIN1	7-LinearLayer[670]-LogisticSigmoid-Sin-Tanh-1	0,125648
D-FS-NN_LIN2	7-LinearLayer[1175]-LogisticSigmoid-Sin-Sin-1	0,126212
D-FS-NN_LIN3	7-LinearLayer[5985]-Ramp-Sin-Tanh-1	0,174935
D-FS-NN_LIN4	7-LinearLayer[6475]-Ramp-Sin-Sin-1	0,176093
D-FS-NN_LIN5	7-LinearLayer[5770]-Ramp-Sin-Sin-1	0,113808

Zdroj: Vlastní.

Tabulka 79 představuje taktéž predikci velikosti Spreadu, avšak nyní za pomoci neuronových sítí s GRL vrstvou pro SAF_1, SAF_2 a SAF_3. Predikce spreadu se pohybuje u jednotlivých sítí v rozmezí hodnot 0,112937 až 0,156378. Nevyšší hodnoty spreadu dosáhla síť D-FS-NN_LIN4, a to s hodnotou 0,156378.

Tabulka 79 Predikce Spreadu podle NN s GRL vrstvou pro SAF_1, SAF_2 a SAF_3.

ID sítě	Název sítě	Predikce
D-FS-NN_GRL1	7-GatedRecurrentLayer[275]-Sin-Sin-LogisticSigmoid-1	0,124479
D-FS-NN_GRL2	7-GatedRecurrentLayer[220]-Sin-Ramp-Tanh-1	0,141536
D-FS-NN_GRL3	7-GatedRecurrentLayer[290]-Ramp-Sin-Sin-1	0,112937
D-FS-NN_GRL4	7-GatedRecurrentLayer[480]-Ramp-Sin--1	0,156378
D-FS-NN_GRL5	7-GatedRecurrentLayer[75]-LogisticSigmoid-LogisticSigmoid-Sin-1	0,115626

Zdroj: Vlastní.

Tabulka 80 ukazuje jednotlivé velikosti spreadu určené na základě neuronových sítí s LSTM vrstvou pro SAF_1, SAF_2 a SAF_3. Predikce spreadu se pohybuje u jednotlivých sítí v rozmezí hodnot 0,120326 až 0,153149. Nevyšší hodnoty spreadu dosáhla síť D-FS-NN_LIN4, a to s hodnotou 0,153149.

Tabulka 80 Predikce Spreadu podle NN s LSTM vrstvou pro SAF_1, SAF_2 a SAF_3.

ID sítě	Název sítě	Predikce
D-FS-NN_LSTM1	7-LongShortTermMemoryLayer[275]-Ramp-Ramp-Ramp-1	0,120326
D-FS-NN_LSTM2	7-LongShortTermMemoryLayer[275]-Sin-Sin-Sin-1	0,153149
D-FS-NN_LSTM3	7-LongShortTermMemoryLayer[275]-Tanh-Tanh-Tanh-1	0,147506
D-FS-NN_LSTM4	7-LongShortTermMemoryLayer[275]-LogisticSigmoid-Sin-Sin-1	0,144668
D-FS-NN_LSTM5	7-LongShortTermMemoryLayer[275]-Tanh-Ramp-Ramp-1	0,136187

Zdroj: Vlastní.

5.5.1.2 Služby heren a kurzového sázení

Spread stanovený pomocí vícevrstvých perceptronových NN

V Tabulce 81 lze nalézt přehled uchovaných vícevrstvých perceptronových sítí, za jejichž pomoci bude predikován spread. Výkony sítí přesahují opět hranici devadesáti procent.

Tabulka 81 Přehled uchovaných vícevrstevých perceptronových sítí

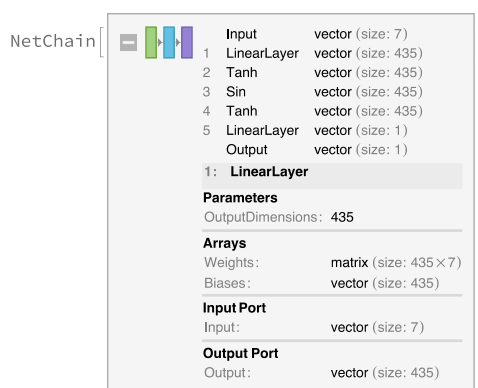
ID sítě	Název sítě	Výkon sítě
D-HAZ-NN_LIN1	7-LinearLayer[435]- Tanh -Sin-Tanh-1	0,920653
D-HAZ-NN_LIN2	7-LinearLayer[535]-Ramp - Ramp - LogisticSigmoid -1	0,922889
D-HAZ-NN_LIN3	7-LinearLayer[1070]- Tanh - Tanh -Tanh-1	0,923261
D-HAZ-NN_LIN4	7-LinearLayer[1075]-Ramp- LogisticSigmoid - Tanh -1	0,923549
D-HAZ-NN_LIN5	7-LinearLayer[530]-Ramp- Ramp - Tanh -1	0,926783

Zdroj: Vlastní.

D-HAZ-NN_LIN1

Obrázek 119 ukazuje základní strukturu sítě D-HAZ-NN_LIN1. Velikost výstupní dimenze je zde rovna hodnotě 435. Funkce zahrnuté do této struktury jsou: lineární, hyperbolický tangens a sinus.

Obrázek 119 Základní struktura sítě D-HAZ-NN_LIN1

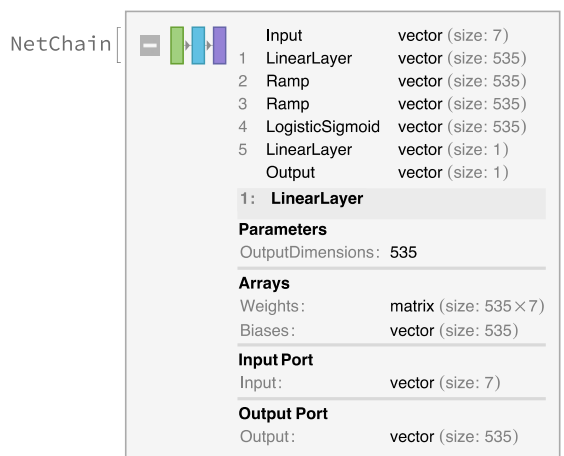


Zdroj: Vlastní.

D-HAZ-NN_LIN2

Druhou sítí je síť D-HAZ-NN_LIN2. její strukturu lze pozorovat na Obrázku 120. Výstupní dimenze je v tomto případě rovna hodnotě 535.

Obrázek 120 Základní struktura sítě D-HAZ-NN_LIN2

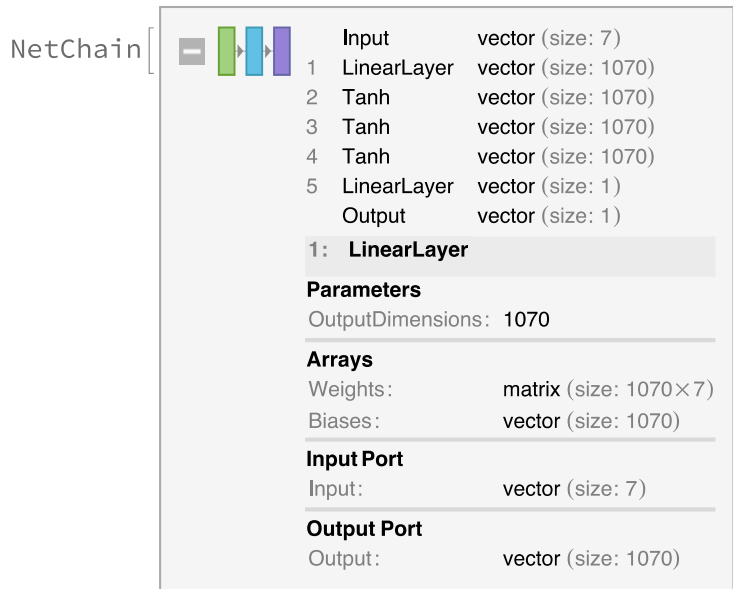


Zdroj: Vlastní.

D-HAZ-NN_LIN3

Třetí sítí v pořadí je síť D-HAZ-NN_LIN3. Základní strukturu sítě je možné vidět na Obrázku 121. Z obrázku je možno vyčíst, že výstupní dimenze je rovna hodnotě 1 070.

Obrázek 121 Základní struktura sítě D-HAZ-NN_LIN3

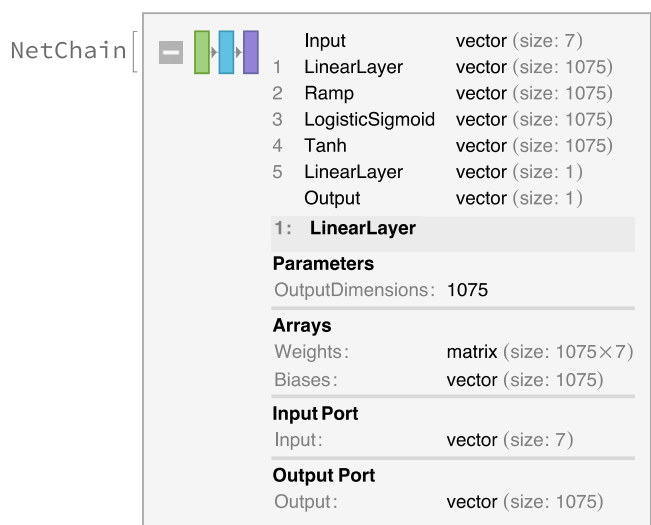


Zdroj: Vlastní.

D-HAZ-NN_LIN4

Čtvrtou sítí je síť s označením D-HAZ-NN_LIN4. Základní struktura této sítě je vyobrazena na Obrázku 122. Výstupní dimenze je zde rovna 1 075.

Obrázek 122 Základní struktura sítě D-HAZ-NN_LIN4

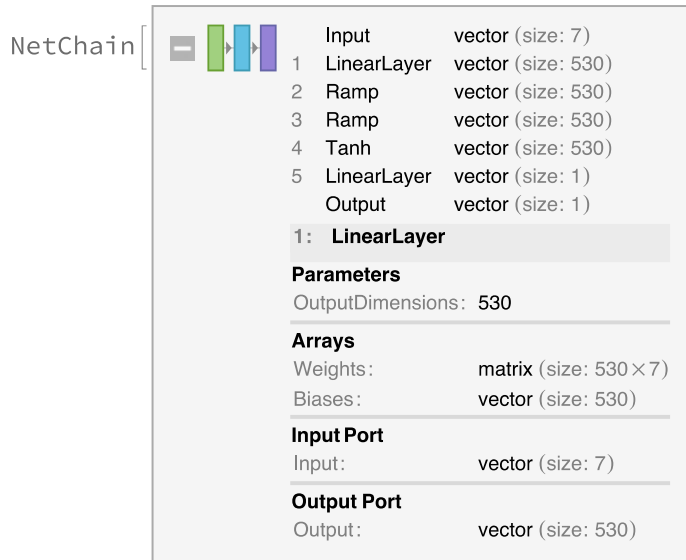


Zdroj: Vlastní.

D-HAZ-NN_LIN5

D-HAZ-NN_LIN5 je pátou a poslední sítí ve skupině těchto sítí. Její základní struktura je uvedena na Obrázku 123. Obrázek říká, že výstupní dimenze je rovna 530. zahrnutý jsou funkce ramp, lineární a hyperbolický tangens.

Obrázek 123 Základní struktura sítě D-HAZ-NN_LIN5



Zdroj: Vlastní.

Spread stanovený pomocí NN s GRL vrstvou

Tabulka 82 ukazuje výkony jednotlivých sítí, za pomoci kterých byla stanovena velikost spreadu. Výkony sítí se opět pohybují nad hranicí devadesáti procent, což značí vysoký výkon sítí.

Tabulka 82 Přehled uchovaných NN s GRL vrstvou

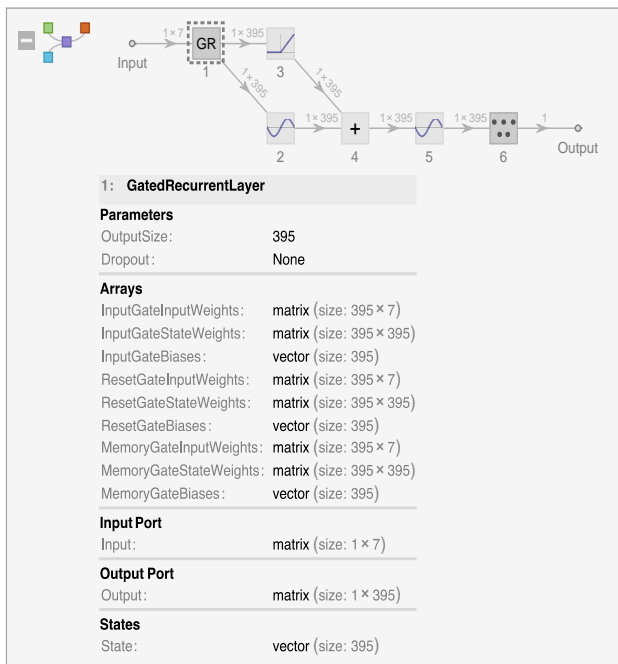
ID sítě	Název sítě	Výkon sítě
D-HAZ-NN_GRL1	7-GatedRecurrentLayer[395]-Sin- Ramp - Sin -1	0,919229
D-HAZ-NN_GRL2	7-GatedRecurrentLayer[75]- Ramp - LogisticSigmoid - Sin -1	0,920071
D-HAZ-NN_GRL3	7-GatedRecurrentLayer[155]-Ramp-Sin- Tanh -1	0,920091
D-HAZ-NN_GRL4	7-GatedRecurrentLayer[40]-Ramp- Ramp - Tanh -1	0,922666
D-HAZ-NN_GRL5	7-GatedRecurrentLayer[170]- Sin - Ramp - Tanh -1	0,922918

Zdroj: Vlastní.

D-HAZ-NN_GRL1

První sítí ze skupiny neuronových sítí s GRL vrstvou je sít' s ID D-HAZ-NN_GRL1. Základní struktura této sítě je ukázána na Obrázku 124.

Obrázek 124 Základní struktura sítě D-HAZ-NN_GRL1

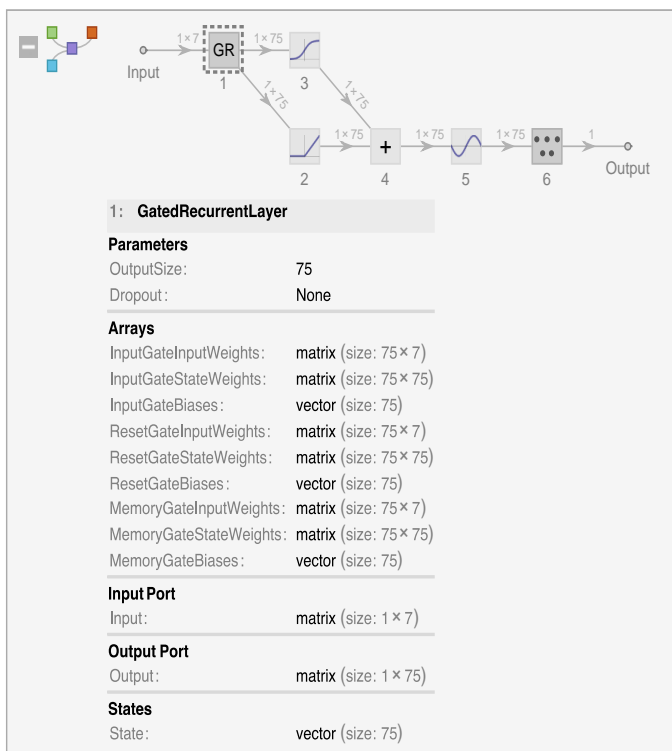


Zdroj: Vlastní.

D-HAZ-NN_GRL2

Druhou sítí ze skupiny sítí s GRL vrstvou je síť s označením D-HAZ-NN_GRL2. Základní struktura této sítě je vyobrazena na Obrázku 125. Velikost výstupu je rovna 75.

Obrázek 125 Základní struktura sítě D-HAZ-NN_GRL2



Zdroj: Vlastní.

D-HAZ-NN_GRL3

Základní struktura sítě D-HAZ-NN_GRL3 je uvedena na Obrázku 126.

Obrázek 126 Základní struktura sítě D-HAZ-NN_GRL3



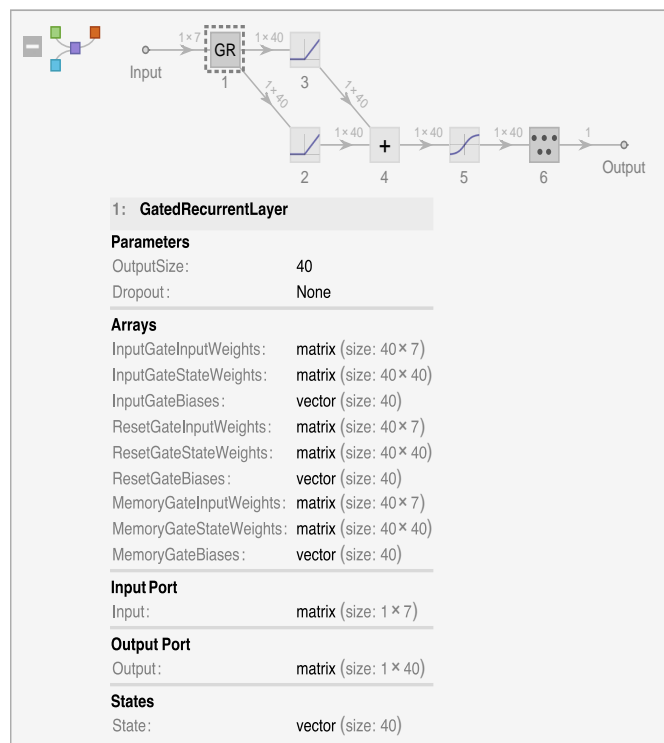
Zdroj: Vlastní.

D-HAZ-NN_GRL4

Základní struktura čtvrté sítě ze skupiny sítí s GRL vrstvou je zobrazena na Obrázku 127.

Velikost výstupní velikost je rovna hodnotě 40.

Obrázek 127 Základní struktura sítě D-HAZ-NN_GRL4

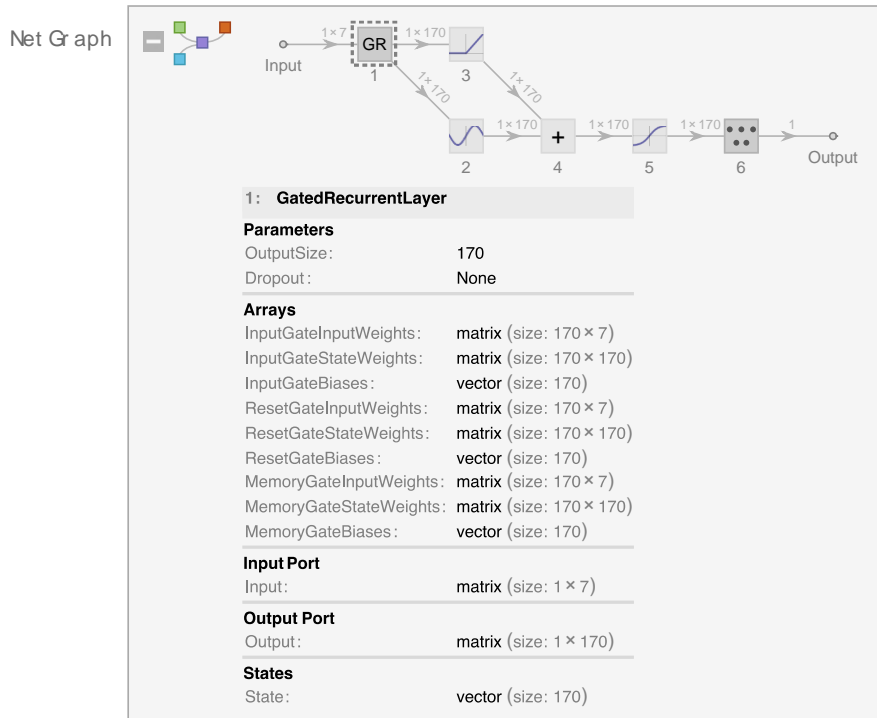


Zdroj: Vlastní.

D-HAZ-NN_GRL5

Poslední síť ze skupiny NN s GRL vrstvou je síť s ID D-HAZ-NN_GRL5. Základní struktura sítě je k vidění na Obrázku 128.

Obrázek 128 Základní struktura sítě D-HAZ-NN_GRL5



Zdroj: Vlastní.

Spread stanovený pomocí NN s LSTM vrstvou

Výkony neuronových sítí s LSTM vrstvou použité pro predikci velikosti spreadu jsou uvedeny v Tabulce 83. Výkon jednotlivých sítí se pohybuje nad hranicí 92 procent.

Tabulka 83 Přehled uchovaných NN s LSTM vrstvou

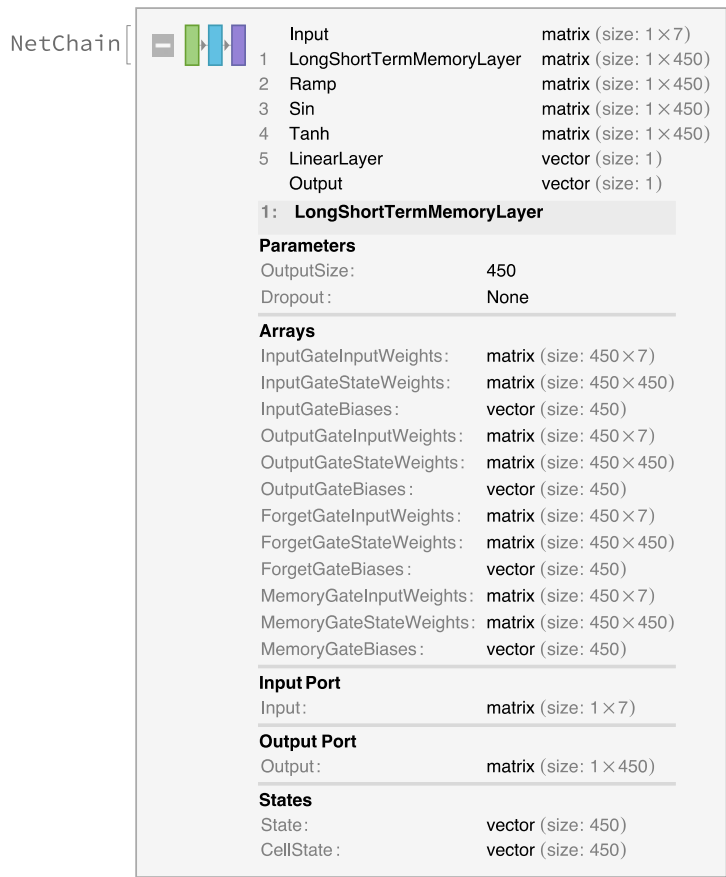
ID sítě	Název sítě	Výkon sítě
D-HAZ-NN_LSTM1	7-LongShortTermMemoryLayer[450]-Ramp- Sin - Tanh -1	0,923525
D-HAZ-NN_LSTM2	7-LongShortTermMemoryLayer[590]- Ramp -Sin- Tanh -1	0,924221
D-HAZ-NN_LSTM3	7-LongShortTermMemoryLayer[180]- Sin - Ramp - Ramp -1	0,924825
D-HAZ-NN_LSTM4	7-LongShortTermMemoryLayer[110]- Tanh - Ramp - Ramp -1	0,926425
D-HAZ-NN_LSTM5	7-LongShortTermMemoryLayer[115]- Ramp -Ramp-Ramp-1	0,927034

Zdroj: Vlastní.

D-HAZ-NN_LSTM1

První síť z řady sítí s LSTM vrstvou je síť D-HAZ-NN_LSTM1. její struktura je k vidění na Obrázku 129.

Obrázek 129 Základní struktura sítě D-HAZ-NN_LSTM1

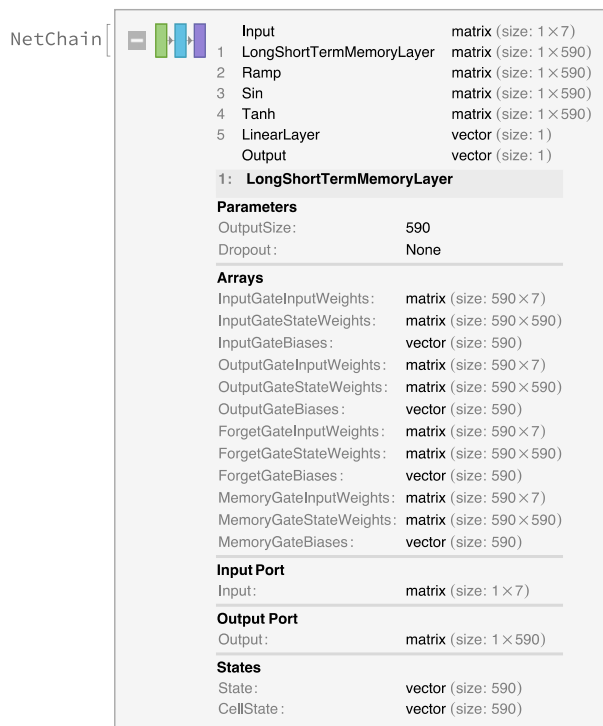


Zdroj: Vlastní.

D-HAZ-NN_LSTM2

Druhou sítí, která se řadí mezi sítě s LSTM vrstvou, je síť D-HAZ-NN_LSTM2. Základní struktura této sítě je předmětem Obrázku 130.

Obrázek 130 Základní struktura sítě D-HAZ-NN_LSTM2



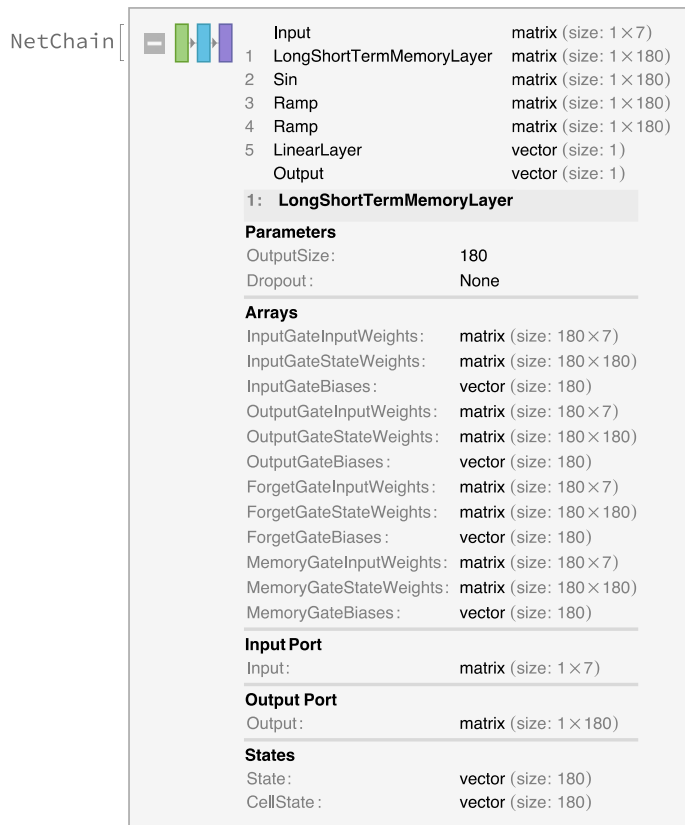
Zdroj: Vlastní.

D-HAZ-NN_LSTM3

D-HAZ-NN_LSTM3 je třetí sítí ve skupině sítí s LSTM vrstvou pro predikci velikosti spreadu.

Základní struktura této sítě je k vidění na Obrázku 131.

Obrázek 131 Základní struktura sítě D-HAZ-NN_LSTM3

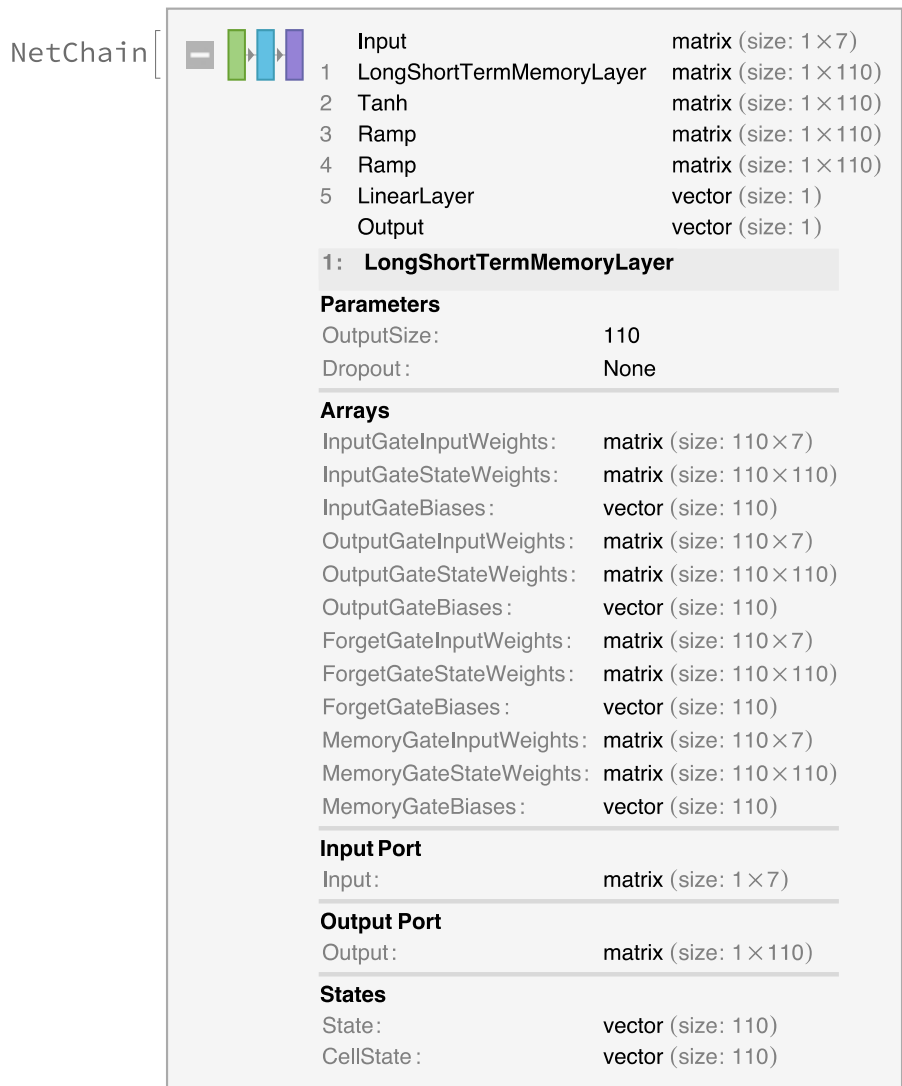


Zdroj: Vlastní.

D-HAZ-NN_LSTM4

Neuronová síť D-HAZ-NN_LSTM4 je čtvrtou sítí z pěti neuronových sítí, které mají LSTM vrstvu. Základní struktura této sítě je k vidění na Obrázku 132.

Obrázek 132 Základní struktura sítě D-HAZ-NN_LSTM4

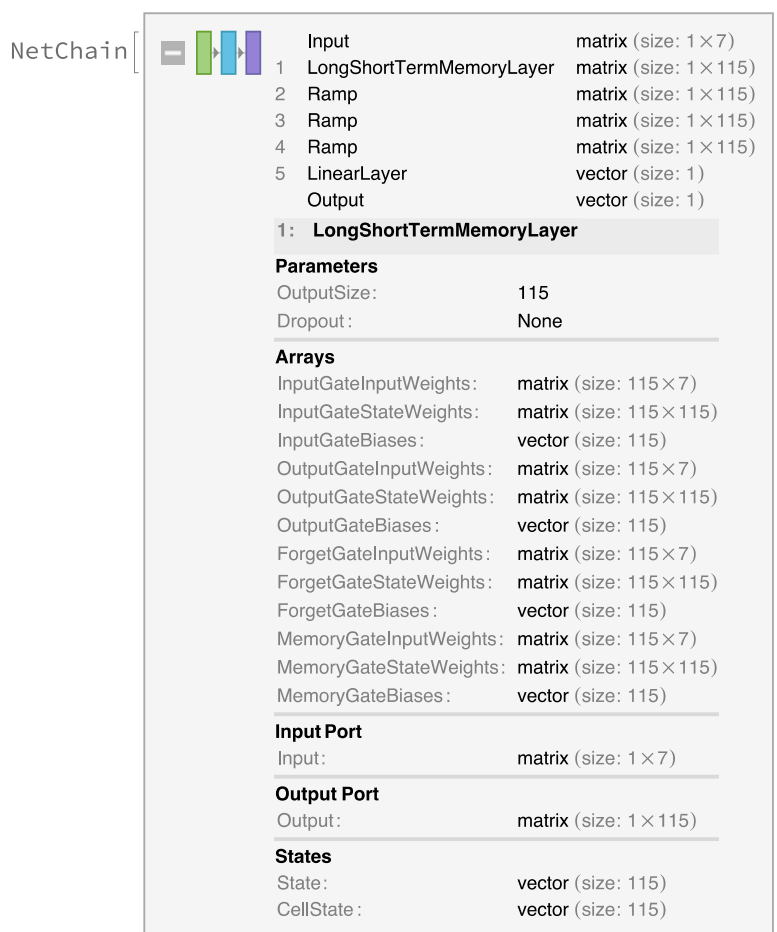


Zdroj: Vlastní.

D-HAZ-NN_LSTM5

Pátou a poslední sítí ze skupiny neuronových sítí s LSTM vrstvou pro predikci velikosti spreadu je síť D-HAZ-NN_LSTM5. Výstupní velikost je zde dána hodnotou 115. Jako funkce jsou zde uvedeny funkce lineární a funkce ramp. Základní struktura sítě je k vidění na Obrázku 133.

Obrázek 133 Základní struktura sítě D-HAZ-NN_LSTM5



Zdroj: Vlastní.

Výsledný spread hodnocených dluhopisů

Výsledné predikce velikostí spreadů na základě použití jednotlivých vícevrstevých perceptronových sítí pro GOS_1, TPH_1 a TPHnet_1 jsou uvedeny v Tabulce 84. Predikce jsou vázány ke společnostem BS, a.s.; CHNC, a.s. a TP, a.s. Za povšimnutí stojí výsledky TP, a.s., kde jsou hodnoty velikosti spreadu v záporných číslech.

Tabulka 84 Predikce Spreadu podle vícevrstevných perceptronových sítí pro GOS_1, TPH_1 a TPHnet_1.

ID sítě	Název sítě	Výkon sítě	Predikce	
D-HAZ-NN_LIN1	7-LinearLayer[435]- Tanh - Sin-Tanh-1	0,920653	BS, a.s.	0,079507
			CHNC, a.s.	0,001194
			TP, a.s.	-0,04665
D-HAZ-NN_LIN2	7-LinearLayer[535]-Ramp - Ramp - LogisticSigmoid -1	0,922889	BS, a.s.	0,082017
			CHNC, a.s.	0,021661
			TP, a.s.	-0,02061
D-HAZ-NN_LIN3	7-LinearLayer[1070]- Tanh - Tanh -Tanh-1	0,923261	BS, a.s.	0,083907
			CHNC, a.s.	0,025083
			TP, a.s.	-0,0244
D-HAZ-NN_LIN4	7-LinearLayer[1075]-Ramp- LogisticSigmoid - Tanh -1	0,923549	BS, a.s.	0,086484
			CHNC, a.s.	0,031971
			TP, a.s.	-0,00521
D-HAZ-NN_LIN5	7-LinearLayer[530]-Ramp- Ramp - Tanh -1	0,926783	BS, a.s.	0,080536
			CHNC, a.s.	0,001918
			TP, a.s.	-0,01502

Zdroj: Vlastní.

Výsledné predikce velikostí spreadů na základě použití neuronových sítí s GRL vrstvou pro GOS_1, TPH_1 a TPHnet_1 jsou uvedeny v Tabulce 85. Predikce jsou vázány ke společnostem BS, a.s.; CHNC, a.s. a TP, a.s. Za povšimnutí opět stojí výsledky TP, a.s., kde jsou hodnoty velikosti spreadu opět v záporných číslech.

Tabulka 85 Predikce Spreadu podle NN s GRL vrstvou pro GOS_1, TPH_1 a TPHnet_1.

ID sítě	Název sítě	Výkon sítě	Predikce	
D-HAZ-NN_GRL1	7-GatedRecurrentLayer[395]- Sin- Ramp - Sin -1	0,919229	BS, a.s.	0,087884
			CHNC, a.s.	0,014445
			TP, a.s.	-0,0209
D-HAZ-NN_GRL2	7-GatedRecurrentLayer[75]- Ramp - LogisticSigmoid - Sin -1	0,920071	BS, a.s.	0,086294
			CHNC, a.s.	0,002866
			TP, a.s.	-0,03315
D-HAZ-NN_GRL3	7-GatedRecurrentLayer[155]- Ramp-Sin- Tanh -1	0,920091	BS, a.s.	0,078543
			CHNC, a.s.	0,012207
			TP, a.s.	-0,02869
D-HAZ-NN_GRL4	7-GatedRecurrentLayer[40]- Ramp- Ramp - Tanh -1	0,922666	BS, a.s.	0,087846
			CHNC, a.s.	0,009172
			TP, a.s.	-0,0295
D-HAZ-NN_GRL5	7-GatedRecurrentLayer[170]- Sin - Ramp - Tanh -1	0,922918	BS, a.s.	0,088105
			CHNC, a.s.	0,014716
			TP, a.s.	-0,0206

Zdroj: Vlastní.

Výsledné predikce velikostí spreadů na základě použití neuronových sítí s LSTM vrstvou pro GOS_1, TPH_1 a TPHnet_1 jsou uvedeny v Tabulce 86. Predikce jsou vázány ke společnostem BS, a.s.; CHNC, a.s. a TP, a.s. Některé hodnoty spreadů sahají až do záporných hodnot, jako je tomu například u společnosti TP, a.s.

Tabulka 86 Predikce Spreadu podle NN s LSTM vrstvou pro GOS_1, TPH_1 a TPHnet_1.

ID sítě	Název sítě	Výkon sítě	Predikce	
D-HAZ-NN_LSTM1	7-LongShortTermMemoryLayer[450]-Ramp- Sin - Tanh -1	0,923525	BS, a.s.	0,088281
			CHNC, a.s.	0,000581
			TP, a.s.	-0,01544
D-HAZ-NN_LSTM2	7-LongShortTermMemoryLayer[590]-Ramp -Sin- Tanh -1	0,924221	BS, a.s.	0,080307
			CHNC, a.s.	-0,00141
			TP, a.s.	-0,02238
D-HAZ-NN_LSTM3	7-LongShortTermMemoryLayer[180]-Sin - Ramp - Ramp -1	0,924825	BS, a.s.	0,084162
			CHNC, a.s.	-0,01249
			TP, a.s.	-0,02616
D-HAZ-NN_LSTM4	7-LongShortTermMemoryLayer[110]-Tanh - Ramp - Ramp -1	0,926425	BS, a.s.	0,085324
			CHNC, a.s.	-0,0001
			TP, a.s.	-0,02449
D-HAZ-NN_LSTM5	7-LongShortTermMemoryLayer[115]-Ramp -Ramp-Ramp-1	0,927034	BS, a.s.	0,08433
			CHNC, a.s.	0,007475
			TP, a.s.	-0,0169

Zdroj: Vlastní.

5.5.2 Bezriziková úroková míra

Bezriziková úroková míra je v této části výsledků stanovena za pomoci třech skupin neuronových sítí (vícevrstvé perceptronové sítě, NN s GRL vrstvou a NN s LSTM vrstvou).

5.5.2.1 Bezriziková úroková míra stanovena pomocí vícevrstevných perceptronových NN

Tabulka 87 ukazuje přehled uchovaných vícevrstevných perceptronových sítí použitých pro stanovení bezrizikové úrokové míry, kde sítě byly uchovány na základě jejich nejlepšího výkonu, který je taktéž uveden v tabulce.

Tabulka 87 Přehled uchovaných vícevrstevných perceptronových sítí

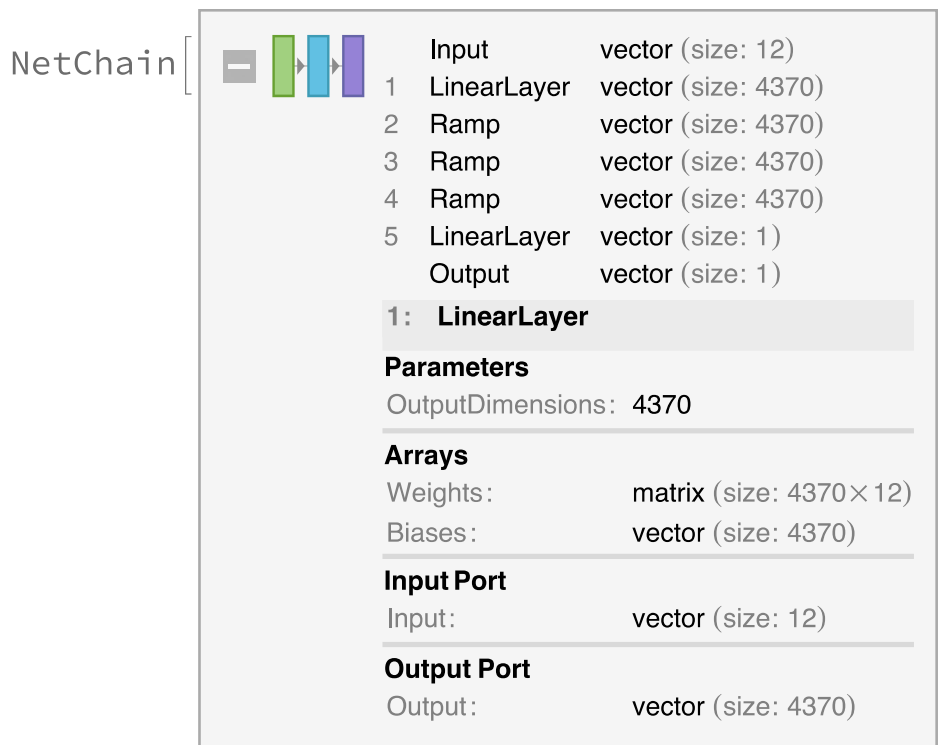
ID sítě	Název sítě	Výkon sítě
RF-NN_LIN1	12-LinearLayer[4370]-Ramp-Ramp-Ramp-1	0,998111
RF-NN_LIN2	12-LinearLayer[4650]-Ramp-Ramp-Sin-1	0,998131
RF-NN_LIN3	12-LinearLayer[1720]-Ramp-Tanh-Ramp-1	0,998157
RF-NN_LIN4	12-LinearLayer[4000]-Ramp-Tanh-Ramp-1	0,998189
RF-NN_LIN5	12-LinearLayer[2430]-Ramp-Tanh-Sin-1	0,998445

Zdroj: Vlastní.

RF-NN_LIN1

Základní struktura sítě RF-NN_LIN1 je zobrazena na Obrázku 134.

Obrázek 134 Základní struktura sítě RF-NN_LIN1

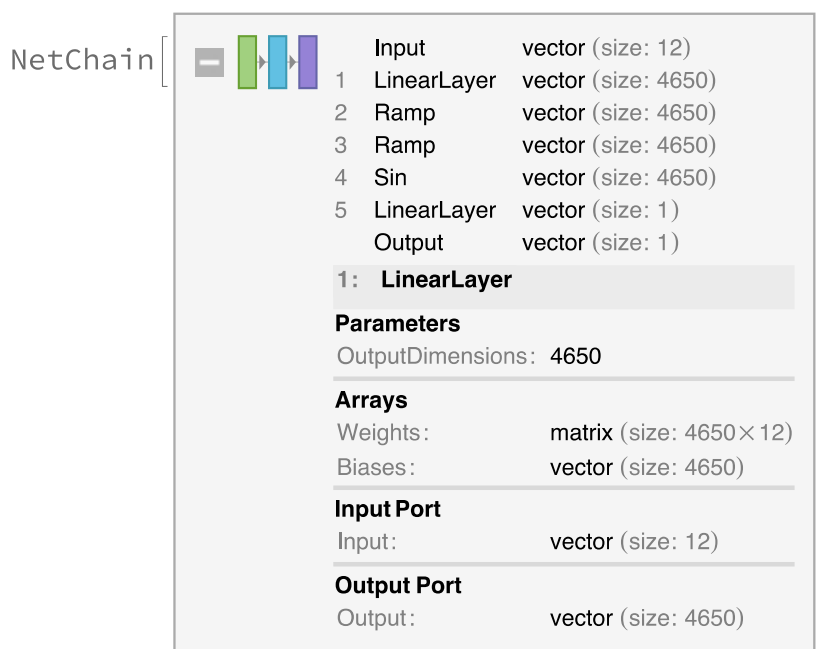


Zdroj: Vlastní.

RF-NN_LIN2

Základní struktura sítě RF-NN_LIN2 je zobrazena na Obrázku 135. Výstupní dimenze je dána hodnotou 4 650.

Obrázek 135 Základní struktura sítě RF-NN_LIN2

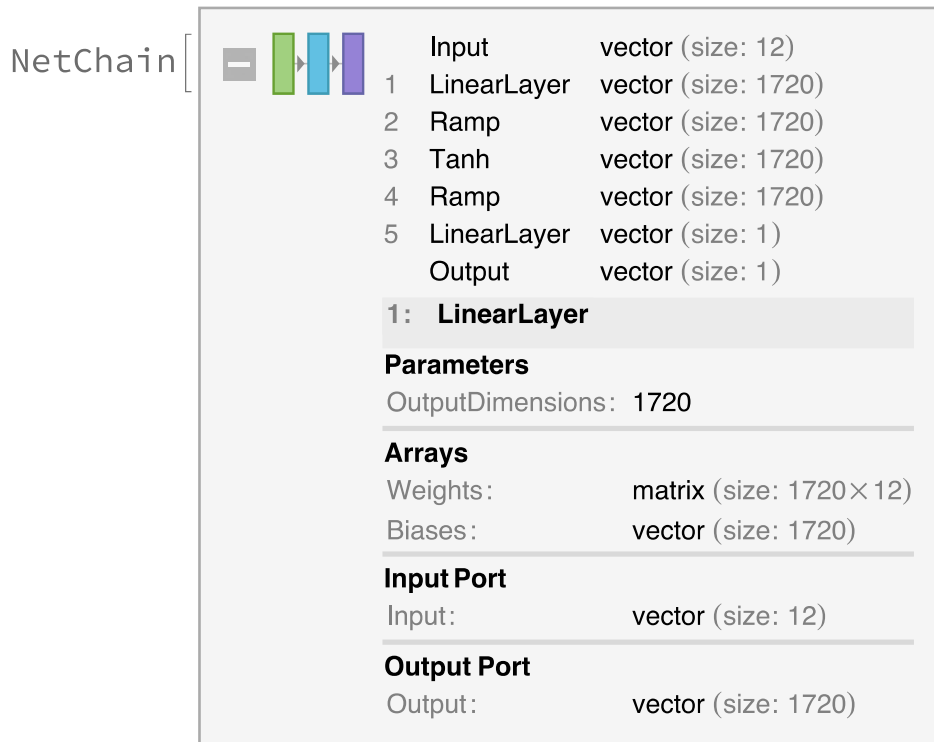


Zdroj: Vlastní.

RF-NN_LIN3

Základní strukturu sítě RF-NN_LIN3 lze sledovat na Obrázku 136. Zde můžeme vidět, že výstupní dimenze je rovna 1 720.

Obrázek 136 Základní struktura sítě RF-NN_LIN3

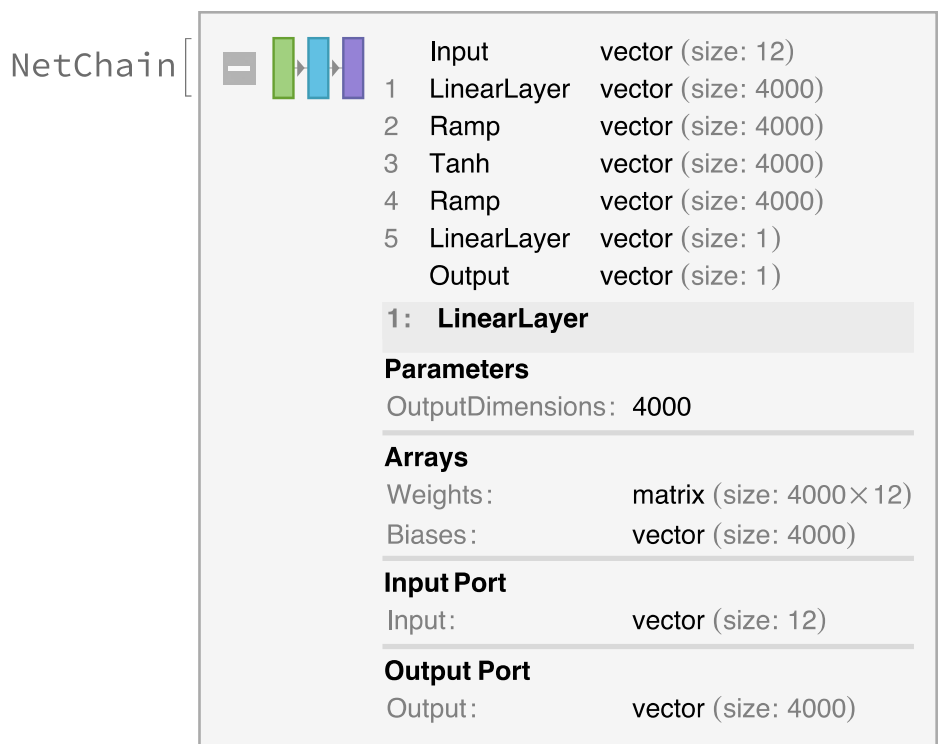


Zdroj: Vlastní.

RF-NN_LIN4

Čtvrtou sítí pro predikci bezrizikové úrokové míry je síť RF-NN_LIN4. Výstupní dimenze je zde dána hodnotou 4 000. Jako funkce jsou zde uvedeny funkce lineární, hyperbolický tangens a funkce ramp. Základní struktura sítě je k vidění na Obrázku 137.

Obrázek 137 Základní struktura sítě RF-NN_LIN4

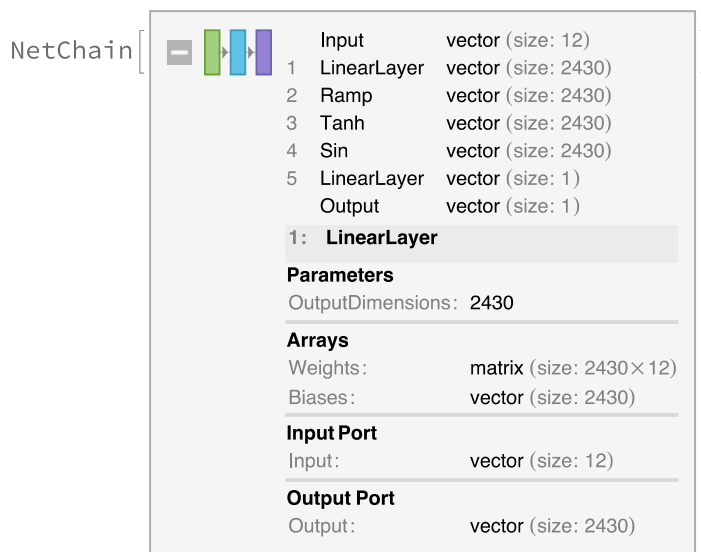


Zdroj: Vlastní.

RF-NN_LIN5

Pátou sítí je neuronová síť s ID RF-NN_LIN5. Základní struktura této sítě je k vidění na Obrázku 138. Výstupní dimenze je dána hodnotou 2 430.

Obrázek 138 Základní struktura sítě RF-NN_LIN5



Zdroj: Vlastní.

5.5.2.2 Bezriziková úroková míra stanovená pomocí NN s GRL vrstvou

Druhou skupinou sítí pro stanovení bezrizikové úrokové míry jsou sítě s GRL vrstvou. V Tabulce 88 jsou k vidění výkony jednotlivých sítí. Výkony sítí přesahují ve všech případech 99 procent.

Tabulka 88 Přehled uchovaných NN s GRL vrstvou

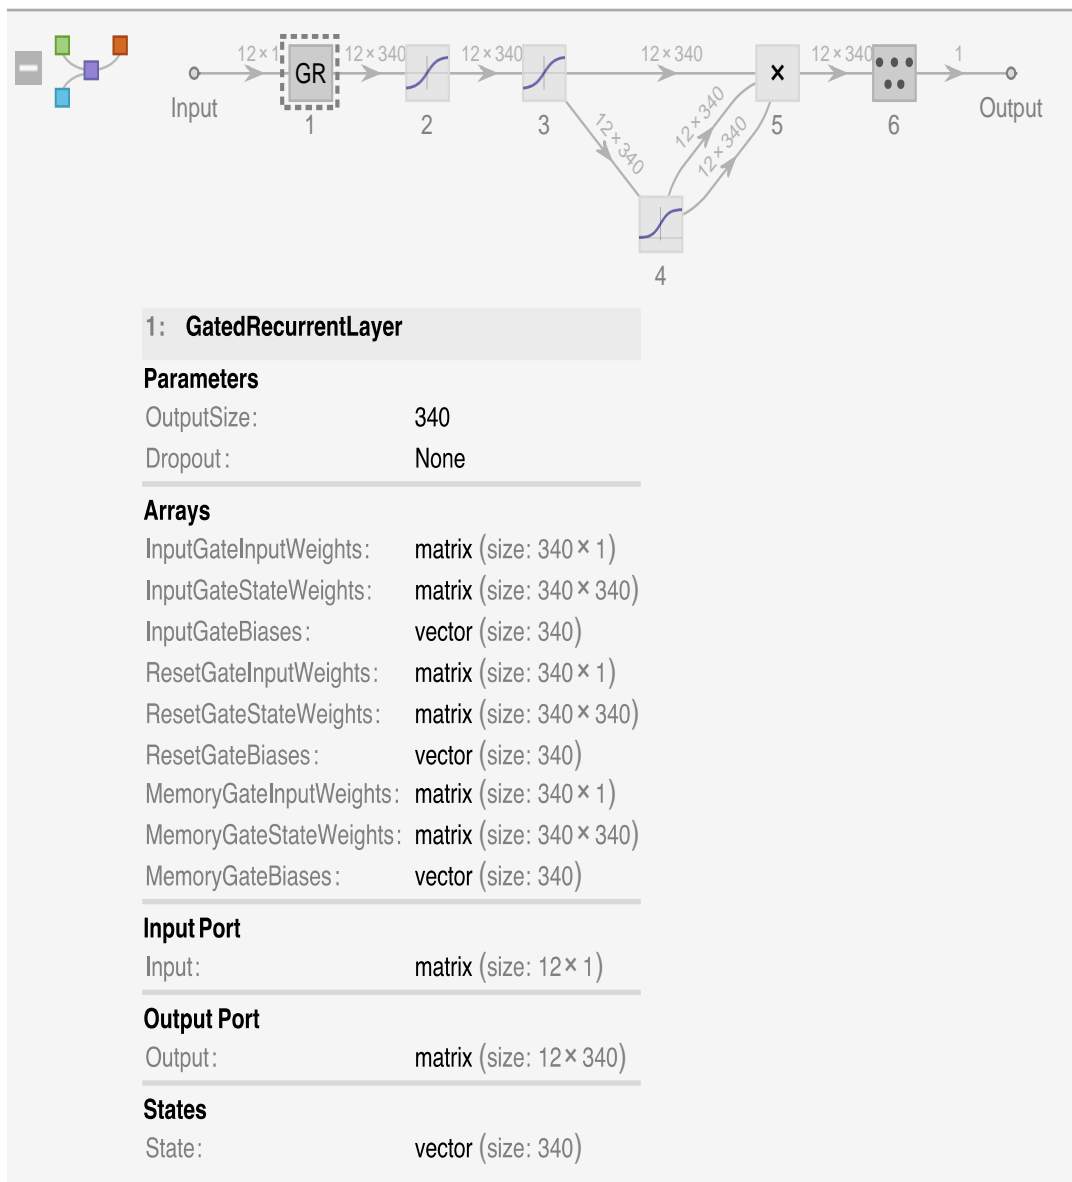
ID sítě	Název sítě	Výkon sítě
RF-NN_GRL1	12-GatedRecurrentLayer[340]-Tanh-Tanh-LogisticSigmoid-1	0,992714
RF-NN_GRL2	12-GatedRecurrentLayer[300]-Tanh-Ramp-LogisticSigmoid-1	0,992803
RF-NN_GRL3	12-GatedRecurrentLayer[450]-Sin-Tanh-LogisticSigmoid-1	0,992931
RF-NN_GRL4	12-GatedRecurrentLayer[270]-Sin-Sin-LogisticSigmoid-1	0,992997
RF-NN_GRL5	12-GatedRecurrentLayer[240]-Ramp-Sin-LogisticSigmoid-1	0,994099

Zdroj: Vlastní.

RF-NN_GRL1

První ze třídy sítí s GRL vrstvou pro stanovení bezrizikové úrokové míry je síť RF-NN_GRL1. Základní struktura sítě je k vidění na Obrázku 139.

Obrázek 139 Základní struktura sítě RF-NN_GRL1

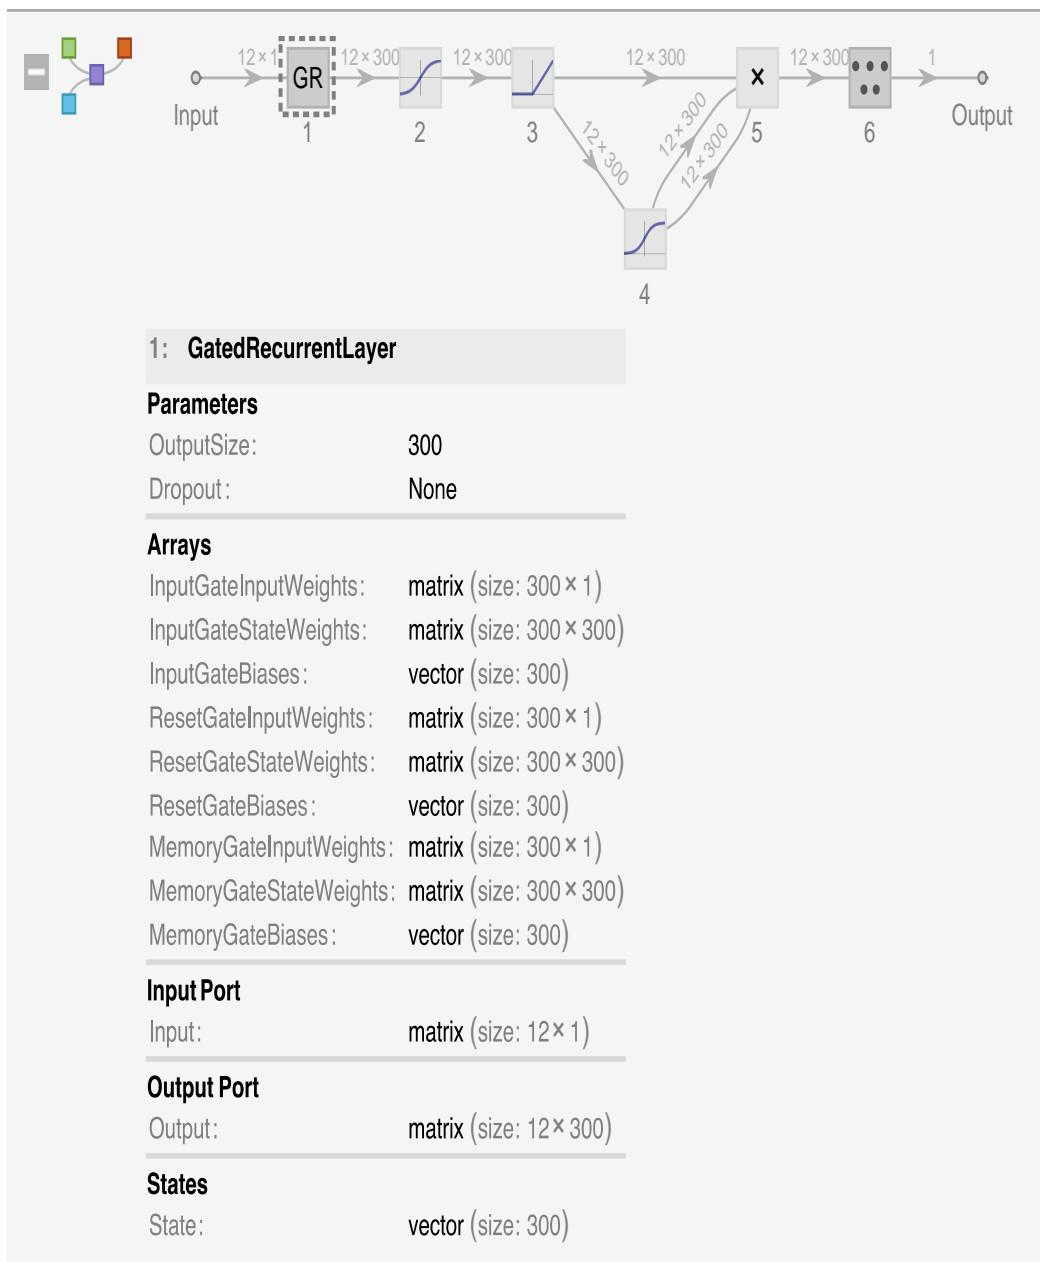


Zdroj: Vlastní.

RF-NN_GRL2

Základní struktura sítě s ID RF-NN_GRL2 je vyobrazena na Obrázku 140.

Obrázek 140 Základní struktura sítě RF-NN_GRL2

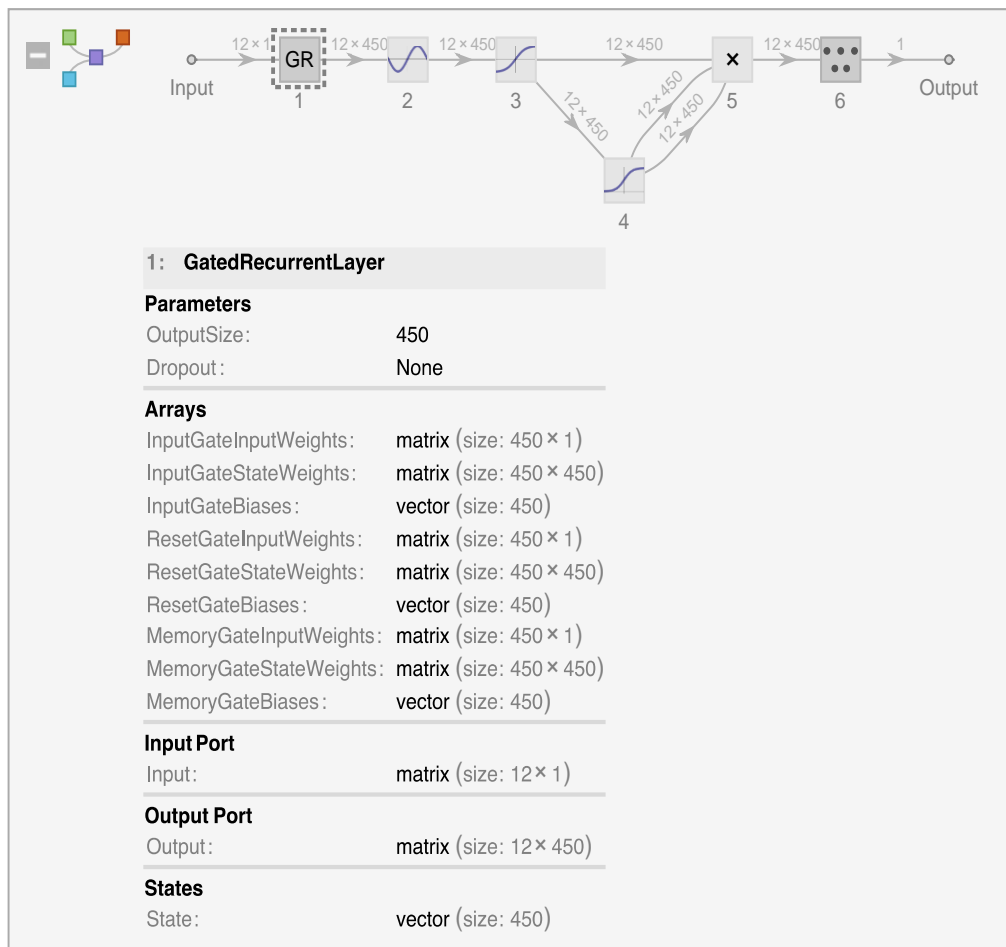


Zdroj: Vlastní.

RF-NN_GRL3

Základní struktura sítě RF-NN_GRL3 je zobrazena na Obrázku 141.

Obrázek 141 Základní struktura sítě RF-NN_GRL3

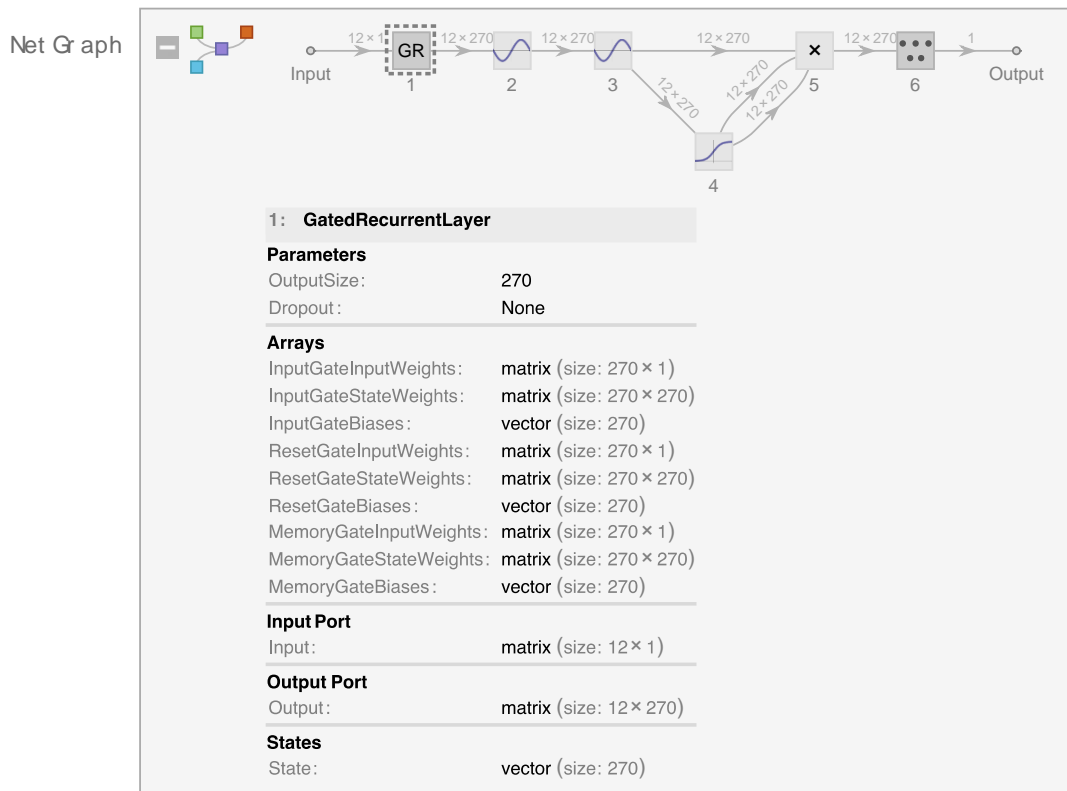


Zdroj: Vlastní.

RF-NN_GRL4

Základní struktura sítě RF-NN_GRL4 je ukázána na Obrázku 142.

Obrázek 142 Základní struktura sítě RF-NN_GRL4

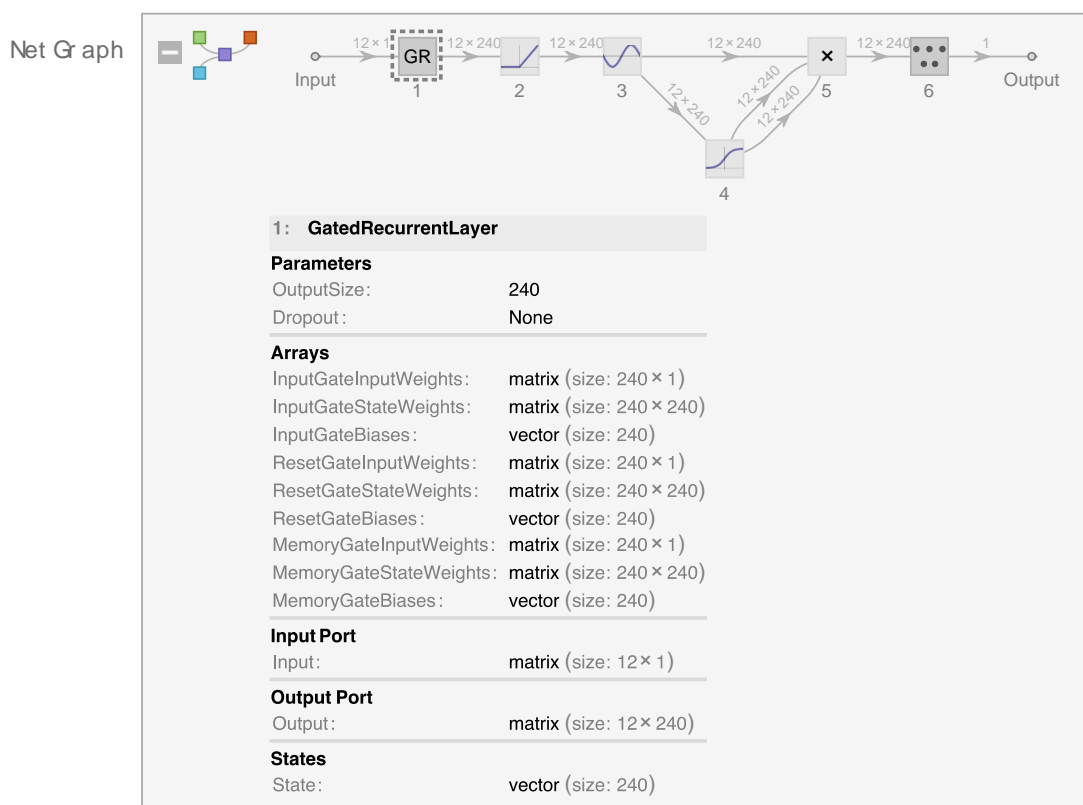


Zdroj: Vlastní.

RF-NN_GRL5

Poslední z řady neuronových sítí s GRL vrstvou, je síť s ID RF-NN_GRL5. Základní struktura této sítě je na Obrázku 143.

Obrázek 143 Základní struktura sítě RF-NN_GRL5



Zdroj: Vlastní.

5.5.2.3 Bezriziková úroková míra stanovená pomocí NN s LSTM vrstvou

Poslední skupinou neuronových sítí pro stanovení bezrizikové úrokové míry jsou sítě s LSTM vrstvou. Na základě Tabulky 89 lze říci, že výkon všech sítí přesahuje hodnotu 99 procent.

Tabulka 89 Přehled uchovaných NN s LSTM vrstvou

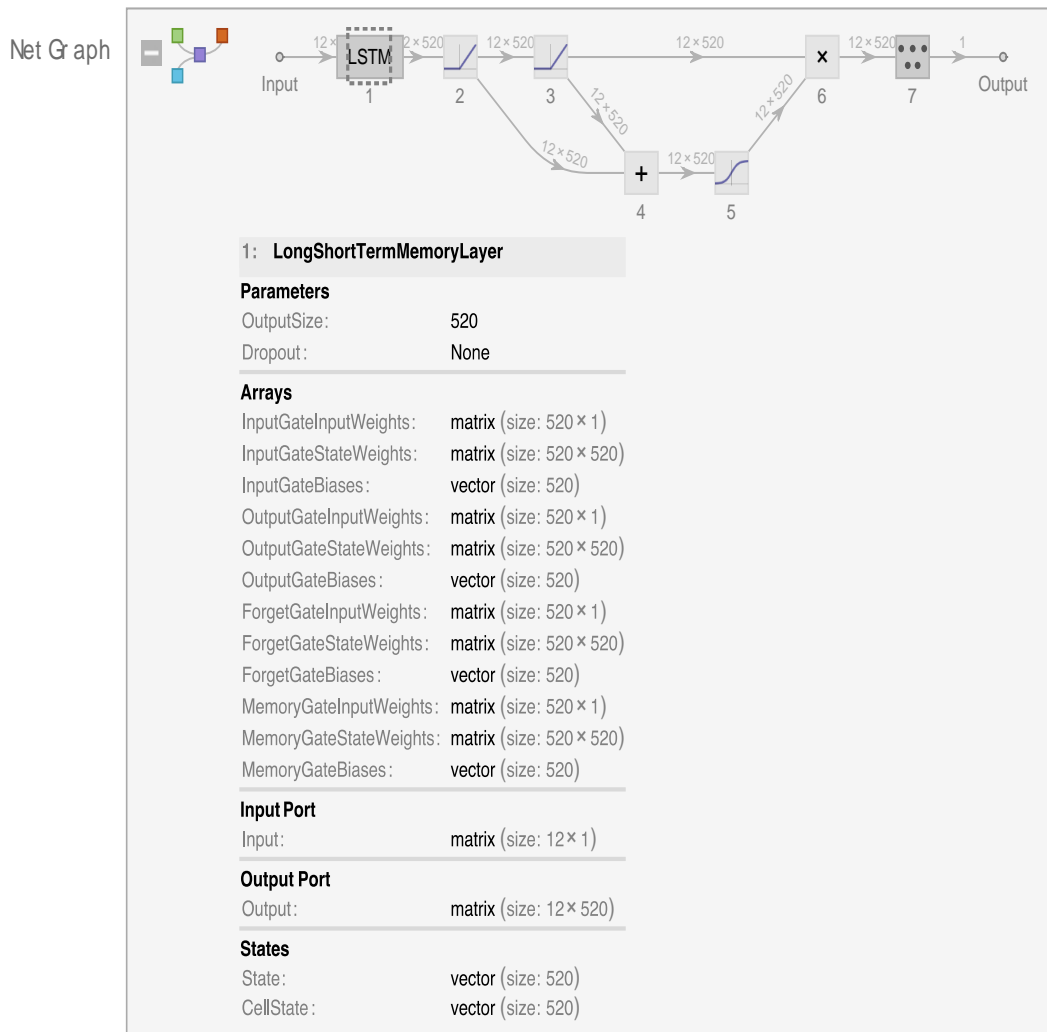
ID sítě	Název sítě	Výkon sítě
RF-NN_LSTM1	12-LongShortTermMemoryLayer[520]-Ramp-Ramp-LogisticSigmoid-1	0,991443
RF-NN_LSTM2	12-LongShortTermMemoryLayer[200]-Tanh-Ramp-LogisticSigmoid-1	0,991619
RF-NN_LSTM3	12-LongShortTermMemoryLayer[420]-Ramp-Ramp-LogisticSigmoid-1	0,992087
RF-NN_LSTM4	12-LongShortTermMemoryLayer[180]-Tanh-Ramp-LogisticSigmoid-1	0,992196
RF-NN_LSTM5	12-LongShortTermMemoryLayer[400]-Ramp-Ramp-LogisticSigmoid-1	0,992723

Zdroj: Vlastní.

RF-NN_LSTM1

Základní struktura sítě je k vidění na Obrázku 144.

Obrázek 144 Základní struktura sítě RF-NN_LSTM1

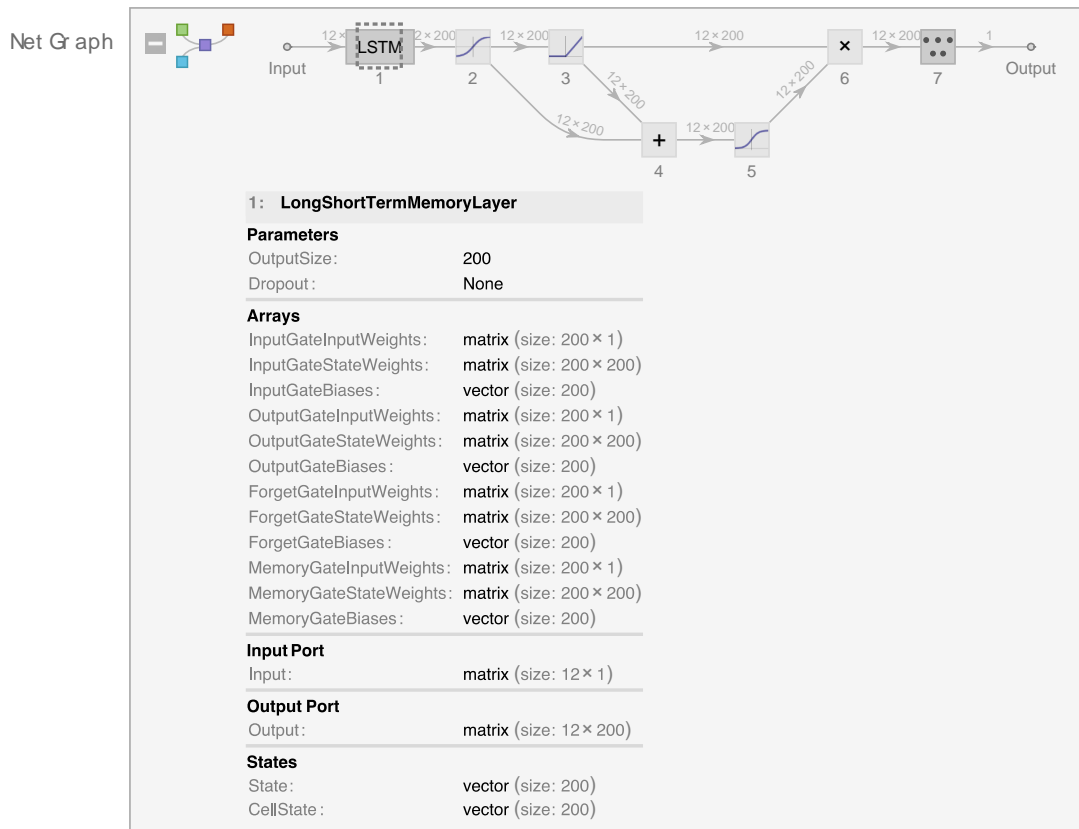


Zdroj: Vlastní.

RF-NN_LSTM2

Základní struktura sítě RF-NN_LSTM2 je k vidění na Obrázku 145.

Obrázek 145 Základní struktura sítě RF-NN_LSTM2

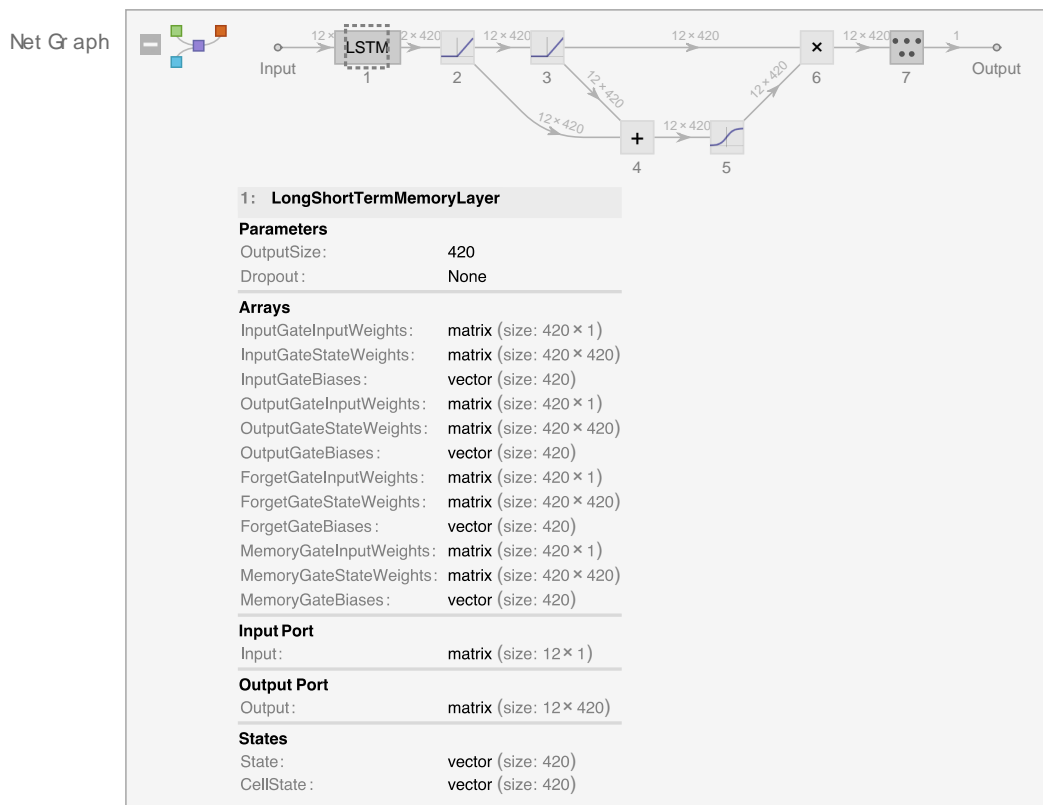


Zdroj: Vlastní.

RF-NN_LSTM3

Třetí z řady sítí s vrstvou LSTM je síť s ID RF-NN_LSTM3. Základní struktura sítě je k vidění na Obrázku 146.

Obrázek 146 Základní struktura sítě RF-NN_LSTM3

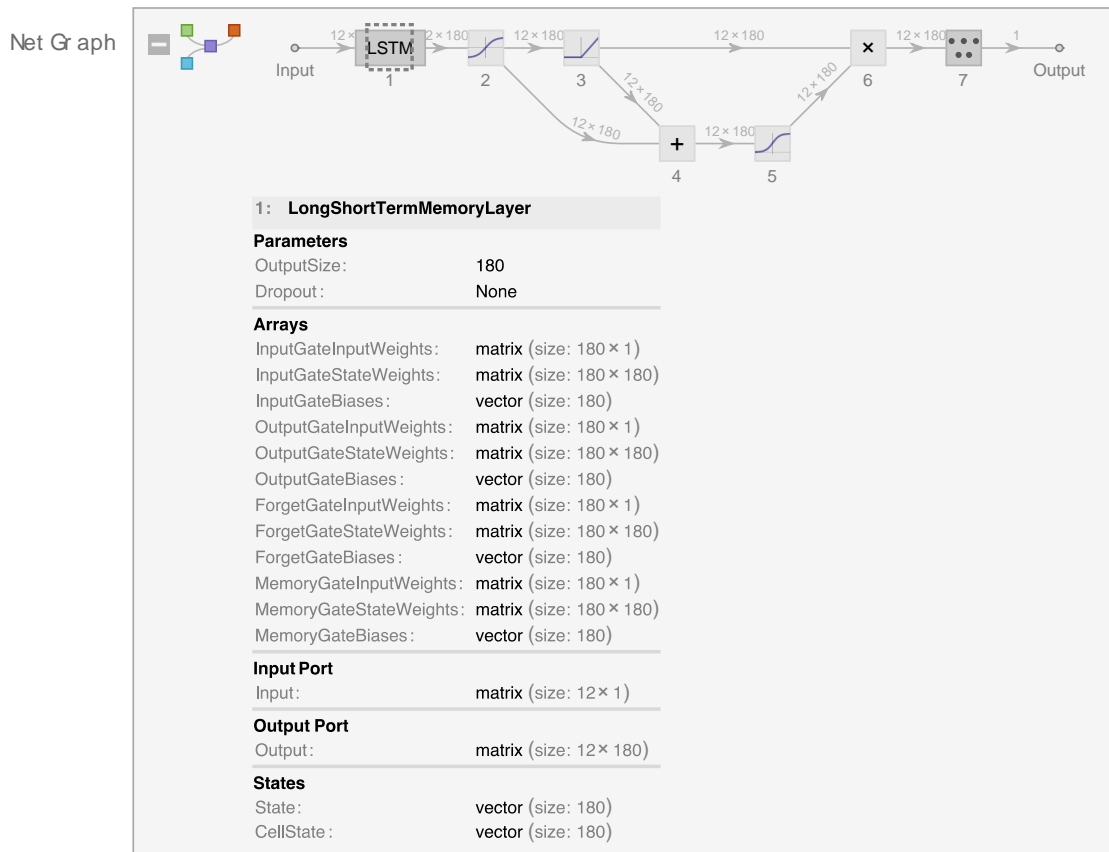


Zdroj: Vlastní.

RF-NN_LSTM4

Předposlední sítí ze skupiny sítí s LSTM vrstvou je síť s ID RF-NN_LSTM4. Její základní struktura je k vidění na Obrázku 147.

Obrázek 147 Základní struktura sítě RF-NN_LSTM4



Zdroj: Vlastní.

RF-NN_LSTM5

Poslední sítí ze skupiny neuronových sítí s LSTM vrstvou pro stanovení bezrizikové úrokové míry je sít' s ID RF-NN_LSTM5. Základní struktura této sítě je k vidění na Obrázku 148.

Obrázek 148 Základní struktura sítě RF-NN_LSTMS




Zdroj: Vlastní.

5.5.2.4 Predikovaná bezriziková sazba do doby splatnosti

Obrázek 149 ukazuje červenou křivku skutečného vývoje bezrizikové sazby mezi lety 2000 a 2020. Predikované hodnoty za pomoci vícevrstvé perceptronové sítě RF-NN_LIN1 představuje modrá křivka. Z grafu je viditelné, že křivka predikovaných hodnot věrně kopíruje křivku skutečných hodnot.


Obrázek 149 Predikce risk free pomocí vícevrstevých perceptronových NN – RF-NN_LIN1



Zdroj: Vlastní.

Vzniklá rezidua, tedy odchylky predikovaných hodnot od naměřených, jsou viditelná na Obrázku 150. Rozsah reziduí je v tomto případě velmi úzký.


Obrázek 150 Rezidua RF-NN_LIN1



Zdroj: Vlastní.

Obrázek 151 ukazuje vývoj skutečných naměřených hodnot v porovnání s hodnotami predikovanými. Křivka skutečného vývoje bezrizikové sazby mezi lety 2000 a 2020 je označena červenou barvou. Predikované hodnoty za pomoci vícevrstvé perceptronové sítě RF-NN_LIN2 představuje zelená křivka. Z grafu je viditelné, že křivka predikovaných hodnot kopíruje tvar křivky skutečných hodnot, avšak jsou viditelná rezidua.


Obrázek 151 Predikce risk free pomocí vícevrstevných perceptronových NN – RF-NN_LIN1



Zdroj: Vlastní.

Vzniklá rezidua, tedy odchylky predikovaných hodnot od naměřených, jsou viditelná na Obrázku 152.


Obrázek 152 Rezidua RF-NN_LIN2



Zdroj: Vlastní.

Třetí síť, která byla využita pro predikci vývoje risk free, je síť NN – RF-NN_LIN3. Křivku predikovaných hodnot za pomoci sítě NN – RF-NN_LIN3 je možné vidět na Obrázku 153, a to jako zlatě zbarvenou. Červenou barvou je pak znázorněna křivka vývoje skutečných naměřených hodnot.


Obrázek 153 Predikce risk free pomocí vícevrstevných perceptronových NN – RF-NN_LIN3



Zdroj: Vlastní.

V tomto případě jsou rezidua, která jsou k vidění na Obrázku 154, velmi malého rozsahu. Tudiž lze konstatovat, že predikce je v tomto případě velmi přesná.


Obrázek 154 Rezidua RF-NN_LIN3



Zdroj: Vlastní.

Obrázek 155 ukazuje vývoj skutečných naměřených hodnot bezrizikové sazby v porovnání s hodnotami predikovanými. Křivka skutečného vývoje bezrizikové sazby mezi lety 2000 a 2020 je označena červenou barvou. Predikované hodnoty za pomoci vícevrstvé perceptronové sítě RF-NN_LIN4 představuje zelená křivka. Z grafu je viditelné, že křivka predikovaných hodnot věrně kopíruje tvar křivky skutečných hodnot. Predikce se tak zdá být opět velmi přesná.


Obrázek 155 Predikce risk free pomocí vícevrstevných perceptronových NN – RF-NN_LIN4



Zdroj: Vlastní.

Vzniklá rezidua, tedy odchylky predikovaných hodnot od naměřených, jsou viditelná na Obrázku 156. Rezidua jsou v tomto případě minimální. Pohybují se ještě v menším rozsahu, než tomu bylo u předchozí sítě RF-NN_LIN3.


Obrázek 156 Rezidua RF-NN_LIN4



Zdroj: Vlastní.

Poslední síť využitou pro predikci vývoje risk free, je síť NN – RF-NN_LIN5. Křivku predikovaných hodnot za pomoci sítě NN – RF-NN_LIN5 je možné pozorovat na Obrázku 157, a to jako purpurově zbarvenou. Červenou barvou je pak znázorněna křivka vývoje skutečných naměřených hodnot.


Obrázek 157 Predikce risk free pomocí vícevrstevných perceptronových NN – RF-NN_LIN4



Zdroj: Vlastní.

V tomto případě jsou rezidua, která jsou k vidění na Obrázku 158, opět velmi malého rozsahu. Tudiž lze konstatovat, že predikce je v tomto případě velmi přesná.


Obrázek 158 Rezidua RF-NN_LIN4



Zdroj: Vlastní.

Obrázek 159 ukazuje za pomoci červené křivky vývoj skutečných hodnot bezrizikové sazby. Ostatní křivky představují predikce za pomoci jednotlivých perceptronových sítí. Největší odchylky od červené křivky lze pozorovat u křivky zelené (RF-NN_LIN2).

Obrázek 159 Predikce risk free pomocí vícevrstvých perceptronových sítí – přehled všech predikcí



Zdroj: Vlastní.

Tabulka 90 ukazuje statistiky časové řady a vyrovnaných časových řad.


Tabulka 90 Statistika časové řady a vyrovnaných časových řad

ID sítě	Minimum	Maximum	Průměr	Standardní odchylka	Rozptyl
Risk Free	0,0025	0,0759	0,0327127	0,0180898	0,00032724
RF-NN_LIN1	0,0027	0,0544	0,0294689	0,0154319	0,000238143
RF-NN_LIN2	0,0037	0,0573	0,0311524	0,0160567	0,000257817
RF-NN_LIN3	0,002	0,0534	0,0291204	0,0151802	0,000230438
RF-NN_LIN4	0,0032	0,0547	0,0296764	0,0153699	0,000236232
RF-NN_LIN5	0,0031	0,0547	0,0297387	0,0153872	0,000236766

Zdroj: Vlastní.

Predikce uskutečněné za pomoci všech zmíněných vícevrstvých perceptronových sítí je možné v jednom grafu pozorovat na Obrázku 160.

Obrázek 160 Přehled všech predikovaných vývoji bezrizikových sazeb za pomoci vícevrstvých perceptronových sítí



Zdroj: Vlastní.

Statistiky predikovaných časových řad je možné vidět v Tabulce 91.


Tabulka 91 Statistika predikovaných časových řad

ID sítě	Minimum	Maximum	Průměr	Standardní odchylka	Rozptyl
RF-NN_LIN1	0,0033	0,02	0,0133926	0,00367394	0,0000134978
RF-NN_LIN2	-1,2429	0,4353	-0,0323816	0,230792	0,0532648
RF-NN_LIN3	0,0035	0,0239	0,0104516	0,00630545	0,0000397587
RF-NN_LIN4	0,0074	0,0207	0,0138615	0,00200249	4,00955 * 10 ⁻⁶
RF-NN_LIN5	0,0095	0,0207	0,0150631	0,00289258	8,36703 * 10 ⁻⁶

Zdroj: Vlastní.

Obrázek 161 ukazuje vývoj všech predikovaných časových řad, včetně skutečné časové řady vývoje risk free. Je možné vidět, že síť RF-NN_LIN2 vykazuje zmatečné chování a její predikci není možné považovat za odpovídající.

Obrázek 161 Přehled všech predikcí včetně křivky skutečných hodnot risk free



Zdroj: Vlastní.

Tabulka 92 představuje měsíční predikce risk free pro každou z vícevrstevných perceptronových sítí. Z důvodu velikosti tabulky je zde v textu uvedeno pouze prvních a posledních 5 případů, kompletní tabulka je znázorněna v Příloze A této práce.


Tabulka 92 Predikce za pomoci RF-NN_LIN1–RF-NN_LIN5

Datum	RF-NN_LIN1	RF-NN_LIN2	RF-NN_LIN3	RF-NN_LIN4	RF-NN_LIN5
30.09.2020	0,0086	0,01	0,009	0,0096	0,0096
31.10.2020	0,0089	0,0117	0,0088	0,0099	0,0105
30.11.2020	0,0093	0,013	0,0088	0,0098	0,0111
31.12.2020	0,0089	0,0135	0,0087	0,0095	0,0108
31.01.2021	0,0083	0,0132	0,0086	0,0091	0,0108
.
.
.
31.08.2040	0,0177	-0,5683	0,0074	0,014	0,0124
30.09.2040	0,0177	-0,7813	0,0081	0,014	0,0127
31.10.2040	0,0176	0,2886	0,0088	0,014	0,0131
30.11.2040	0,0175	-0,5616	0,0095	0,014	0,0136
31.12.2040	0,0173	-0,9255	0,0104	0,014	0,0141

Zdroj: Vlastní.

Za pomoci neuronových sítí s GRL vrstvou byla predikována časová řada, která byla následně porovnána se skutečným vývojem bezrizikové sazby. Na Obrázku 162 je možné vidět v podobě červené křivky skutečný vývoj risk free. Modrá křivka poté ukazuje predikovaný vývoj za pomoci sítě RF-NN_GRL1. Modrá křivka kopíruje tvar křivky červené, avšak jsou zde viditelné odchylky v podobě reziduí.


Obrázek 162 Predikce risk free pomocí RF-NN_GRL1



Zdroj: Vlastní.

Rezidua je možné vidět na Obrázku 163.


Obrázek 163 Rezidua RF-NN_GRL1



Zdroj: Vlastní.

Na Obrázku 164 je možné pozorovat v podobě červené křivky skutečný vývoj risk free. Zelená křivka poté ukazuje predikovaný vývoj za pomoci sítě RF-NN_GRL2.


Obrázek 164 Predikce risk free pomocí RF-NN_GRL2



Zdroj: Vlastní.

Zelená křivka kopíruje tvar křivky červené, avšak jsou zde viditelná rezidua, která jsou také předmětem Obrázku 165.

Obrázek 165 Rezidua RF-NN_GRL2




Zdroj: Vlastní.

Predikci za pomoci třetí neuronové sítě ze skupiny sítí s GRL vrstvou (RF-NN_GRL3), lze pozorovat na Obrázku 166. Predikce vývoje za pomoci této sítě je zvýrazněna zlatou barvou.

Obrázek také ukazuje skutečný vývoj risk free, a to za pomoci červené křivky. Lze pozorovat, že vývoj predikce je velmi podobný vývoji predikce za pomoci předchozí sítě.


Obrázek 166 Predikce risk free pomocí RF-NN_GRL3



Zdroj: Vlastní.

Vzniklá rezidua v podobě odchylky skutečných a predikovaných hodnot je možné vidět na Obrázku 167.

Obrázek 167 Rezidua RF-NN_GRL3

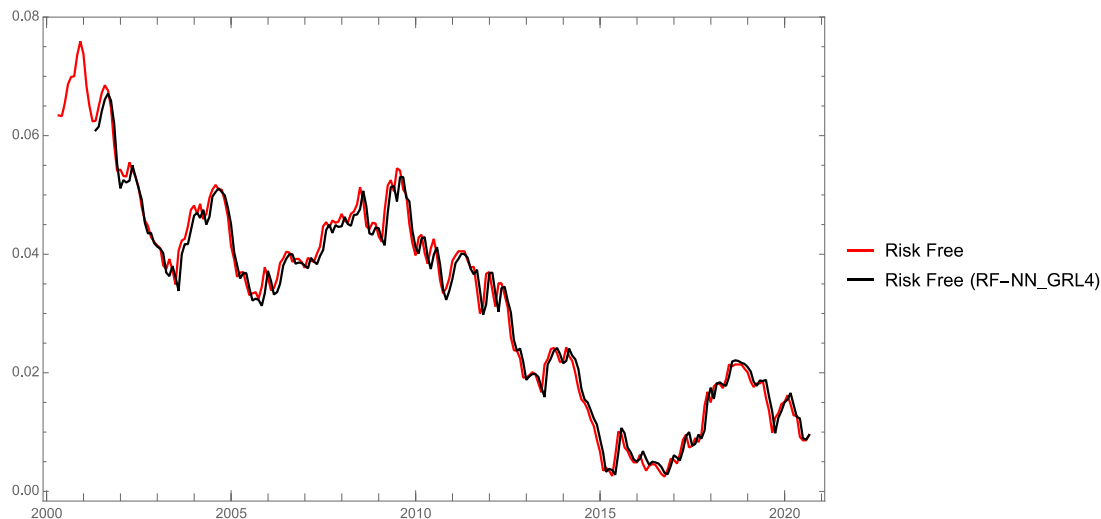


Zdroj: Vlastní.

Obrázek 168 ukazuje vývoj skutečných naměřených hodnot bezrizikové sazby v porovnání s hodnotami predikovanými. Křivka skutečného vývoje bezrizikové sazby mezi lety 2000 a 2020 je označena červenou barvou. Predikované hodnoty za pomoci neuronové sítě s GRL

vrstvou č. 4 představuje černá křivka. Z grafu je viditelné, že křivka predikovaných hodnot kopíruje tvar křivky skutečných hodnot, ale rezidua jsou viditelná. Predikce se tak zdá být přesná, ale s malými odchylkami.


Obrázek 168 Predikce risk free pomocí RF-NN_GRL4



Zdroj: Vlastní.

Vzniklá rezidua, tedy odchylky predikovaných hodnot od naměřených, jsou viditelná na Obrázku 169. Rezidua jsou v tomto případě četnější a větší, než tomu bylo v předchozím případě (RF-NN_GRL3).


Obrázek 169 Rezidua RF-NN_GRL4



Zdroj: Vlastní.

Predikci za pomoci poslední neuronové sítě ze skupiny sítí s GRL vrstvou (RF-NN_GRL5), lze vidět na Obrázku 170. Predikce vývoje risk free za pomoci této sítě je zvýrazněna purpurovou barvou. Obrázek také ukazuje skutečný vývoj risk free, a to za pomoci červené křivky. Lze pozorovat, že vývoj predikce je velmi podobný vývoji skutečného risk free.


Obrázek 170 Predikce risk free pomocí RF-NN_GRL5



Zdroj: Vlastní.

Vzniklá rezidua v podobě odchylky skutečných a predikovaných hodnot je možné vidět na Obrázku 171.


Obrázek 171 Rezidua RF-NN_GRL5



Zdroj: Vlastní.

Obrázek 172 ukazuje za pomoci červené křivky vývoj skutečných hodnot bezrizikové sazby. Ostatní křivky představují predikce za pomoci jednotlivých neuronových sítí s GRL vrstvou. Největší odchylky od červené křivky lze pozorovat u křivky zelené (RF-NN_LIN2).

Obrázek 172 Predikce risk free pomocí neuronových sítí s GRL vrstvou – přehled všech predikcí



Zdroj: Vlastní.

Statistiky časové řady a vyrovnaných časových řad ukazuje Tabulka 93.


Tabulka 93 Statistiky časové řady a vyrovnaných časových řad

ID sítě	Minimum	Maximum	Průměr	Standardní odchylka	Rozptyl
Risk Free	0,0025	0,0759	0,0327127	0,0180898	0,00032724
RF-NN_GRL1	0,0018	0,054	0,0283822	0,0151333	0,000229016
RF-NN_GRL2	0,0035	0,0533	0,0285458	0,0149422	0,000223269
RF-NN_GRL3	0,002	0,0548	0,0290124	0,0153219	0,00023476
RF-NN_GRL4	0,0028	0,055	0,0295578	0,0151512	0,000229559
RF-NN_GRL5	0,0038	0,0542	0,0293196	0,0151364	0,00022911

Zdroj: Vlastní.

Predikce uskutečněné za pomoci všech zmíněných vícevrstvých perceptronových sítí je možné v jednom grafu pozorovat na Obrázku 173.

Obrázek 173 Přehled všech predikovaných vývoju bezrizikových sazeb za pomoci neuronových sítí s GRL vrstvou



Zdroj: Vlastní.

Statistiky jednotlivých predikovaných časových řad jsou předmětem Tabulky 94.


Tabulka 94 Statistiky predikovaných časových řad

ID sítě	Minimum	Maximum	Průměr	Standardní odchylka	Rozptyl
RF-NN_GRL1	-0,0137	0,0091	-0,011891	0,00455618	0,0000207588
RF-NN_GRL2	0,0047	0,0089	0,00545574	0,00045876	2,10461*10 ⁻⁷
RF-NN_GRL3	-0,0145	0,0093	-0,0109906	0,00593732	0,0000352518
RF-NN_GRL4	0,0101	0,0231	0,0218852	0,00290735	8,4527 * 10 ⁻⁶
RF-NN_GRL5	0,009	0,011	0,0108975	0,000362312	1,3127 * 10 ⁻⁷

Zdroj: Vlastní.

Přehled všech predikcí (NN s GRL vrstvou) včetně křivky skutečných hodnot risk free je zaznamenán na Obrázku 174.

Obrázek 174 Přehled všech predikcí (NN s GRL vrstvou) včetně křivky skutečných hodnot risk free



Zdroj: Vlastní.

Tabulka 95 představuje měsíční predikce risk free pro každou z neuronových sítí s GRL vrstvou. Z důvodu obsáhlosti tabulky je v Tabulce 95 uvedeno pouze prvních a posledních 5 případů. Kompletní tabulka je předmětem Přílohy B.


Tabulka 95 Predikce za pomoci RF-NN_GRL1–RF-NN_GRL5

Datum	RF-NN_GRL1	RF-NN_GRL2	RF-NN_GRL3	RF-NN_GRL4	RF-NN_GRL5
30.09.2020	0,0091	0,0089	0,0093	0,0101	0,0091
31.10.2020	0,0086	0,0089	0,0092	0,0108	0,0093
30.11.2020	0,008	0,0086	0,0089	0,0114	0,0097
31.12.2020	0,0071	0,0082	0,0084	0,0116	0,0098
31.01.2021	0,0059	0,0075	0,0076	0,0117	0,0096
.
.
.
31.08.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2040	-0,0137	0,0054	-0,0145	0,0231	0,011

Zdroj: Vlastní.

Obrázek 175 ukazuje časovou řadu skutečného vývoje risk free, ta je označena červenou barvou. Modrá křivka představuje vyrovnanou predikovanou časovou řadu za pomoci RF-NN-LSTM1.


Obrázek 175 Predikce risk free pomocí RF-NN_LSTM1



Zdroj: Vlastní.

Modrá křivka přibližně kopíruje průběh křivky červené, avšak jsou viditelné odchylky v podobě reziduí, která jsou viditelná na Obrázku 176.


Obrázek 176 Rezidua RF-NN_LSTM1



Zdroj: Vlastní.

Na Obrázku 177 je možné pozorovat v podobě červené křivky skutečný vývoj risk free. Zelená křivka poté ukazuje predikovaný vývoj za pomoci sítě RF-NN_LSTM2.


Obrázek 177 Predikce risk free pomocí RF-NN_LSTM2



Zdroj: Vlastní.

Zelená křivka kopíruje tvar vývoje křivky červené, avšak v tomto případě jsou rezidua mnohem znatelnější, než v případě předchozí sítě. Rezidua jsou viditelná na Obrázku 178.


Obrázek 178 Rezidua RF-NN_LSTM2



Zdroj: Vlastní.

V případě predikce risk free za pomoci neuronové sítě s LSTM vrstvou (RF-NN_LSTM3) lze na Obrázku 179 pozorovat, že průběh predikované časové řady je velmi podobný průběhu skutečného vývoje časové řady, která je zde označena červenou barvou. Vyrovnaná časová řada predikce je označena zlatou barvou.


Obrázek 179 Predikce risk free pomocí RF-NN_LSTM3



Zdroj: Vlastní.

Rezidua jsou v tomto případě menšího rozsahu, než tomu bylo u předešlé sítě (RF-NN_LSTM2). Rezidua je možné pozorovat na Obrázku 180.


Obrázek 180 Rezidua RF-NN_LSTM3



Zdroj: Vlastní.

Obrázek 181 ukazuje vývoj skutečných naměřených hodnot bezrizikové sazby v porovnání s hodnotami predikovanými. Křivka skutečného vývoje bezrizikové sazby mezi lety 2000 a 2020 je označena červenou barvou. Predikované hodnoty za pomoci neuronové sítě s LSTM vrstvou č. 4 představuje černá křivka.


Obrázek 181 Predikce risk free pomocí RF-NN_LSTM4



Zdroj: Vlastní.

Z grafu je možné vyzorovat, že křivka predikovaných hodnot kopíruje tvar křivky skutečných hodnot, a rezidua jsou mnohem více viditelná než v případě předchozí sítě RF-NN_LSTM3. Vzniklá rezidua, tedy odchylky predikovaných hodnot od naměřených, jsou viditelná na Obrázku 182.


Obrázek 182 Rezidua RF-NN_LSTM4



Zdroj: Vlastní.

Pátá a poslední síť RF-NN_LSTM5, a primárně křivka vývoje predikovaných hodnot za pomoci této neuronové sítě, je viditelná na Obrázku 183, kde je křivka označena purpurovou barvou. Průběh této křivky je porovnáván s křivkou červenou, která označuje skutečně naměřené hodnoty risk free v letech 2000–2020.


Obrázek 183 Predikce risk free pomocí RF-NN_LSTM5



Zdroj: Vlastní.

Rezidua jsou v tomto případě velmi podobného rozsahu, jako tomu bylo v případě sítě s ID RF-NN_LSTM4. Rozsah reziduí je možné vidět na Obrázku 184.


Obrázek 184 Rezidua RF-NN_LSTM5



Zdroj: Vlastní.

Na Obrázku 185 je možné vidět pod červenou křivkou vývoj skutečných hodnot bezrizikové sazby. Ostatní křivky představují predikce za pomoci jednotlivých neuronových sítí s LSTM vrstvou. Největší odchylky od červené křivky lze pozorovat u křivky zelené (RF-NN_LSTM2).

Obrázek 185 Predikce risk free pomocí neuronových sítí s LSTM vrstvou – přehled všech predikcí



Zdroj: Vlastní.

Statistiky časové řady a vyrovnaných časových řad je možné vidět v Tabulce 96.


Tabulka 96 Statistiky časové řady a vyrovnaných časových řad

ID sítě	Minimum	Maximum	Průměr	Standardní odchylka	Rozptyl
Risk Free	0,0025	0,0759	0,0327127	0,0180898	0,00032724
RF-NN_LSTM1	0,0039	0,0557	0,0302516	0,0153533	0,000235724
RF-NN_LSTM 2	0,0028	0,0525	0,0284591	0,0151551	0,000229678
RF-NN_LSTM 3	0,0032	0,0558	0,0300453	0,0156962	0,000246372
RF-NN_LSTM 4	0,0023	0,0554	0,0292262	0,0158676	0,000251781
RF-NN_LSTM 5	0,0028	0,0546	0,0288636	0,0152508	0,000232586

Zdroj: Vlastní.

Predikce vývoje risk free do roku 2040 uskutečněné za pomoci všech zmíněných neuronových sítí s LSTM vrstvou je možné v jednom grafu vidět na Obrázku 186.

Obrázek 186 Přehled všech predikovaných vývoju bezrizikových sazeb za pomoci neuronových sítí s LSTM vrstvou



Zdroj: Vlastní.

Statistiky predikovaných časových řad jsou předmětem Tabulky 97.


Tabulka 97 Statistiky predikovaných časových řad

ID sítě	Minimum	Maximum	Průměr	Standardní odchylka	Rozptyl
RF-NN_LSTM1	0,0097	0,0218	0,015304	0,00194421	$3,77996 * 10^{-6}$
RF-NN_LSTM 2	0,0033	0,0085	0,00401721	0,000694623	$4,82501 * 10^{-7}$
RF-NN_LSTM 3	0,0091	0,0151	0,0121889	0,00135179	$1,82733 * 10^{-6}$
RF-NN_LSTM 4	0,0019	0,0085	0,00265328	0,000842315	$7,09495 * 10^{-7}$
RF-NN_LSTM 5	0,0027	0,0115	0,00952623	0,0017589	$3,09371 * 10^{-6}$

Zdroj: Vlastní.

Přehled všech predikcí (NN s LSTM vrstvou) včetně křivky skutečných hodnot risk free je zaznamenán na Obrázku 187.

Obrázek 187 Přehled všech predikcí (NN s LSTM vrstvou) včetně křivky skutečných hodnot risk free



Zdroj: Vlastní.

Tabulka 98 je tabulkou měsíčních predikcí hodnot risk free do roku 2040 za pomoci neuronových sítí s LSTM vrstvou. Díky rozsahu tabulky je zde v textu uvedena pouze její část – 5 prvních a 5 posledních případů. Kompletní verze tabulky je předmětem Přílohy C.

Tabulka 98 Predikce za pomoci RF-NN_LSTM1–RF-NN_LSTM5

Datum	RF-NN_LSTM1	RF-NN_LSTM2	RF-NN_LSTM3	RF-NN_LSTM4	RF-NN_LSTM5
30.09.2020	0,0097	0,0084	0,0091	0,0085	0,0089
31.10.2020	0,0105	0,0085	0,0094	0,0084	0,009
30.11.2020	0,0111	0,0083	0,0096	0,0081	0,009
31.12.2020	0,0118	0,008	0,0098	0,0075	0,009
31.01.2021	0,0121	0,0074	0,0096	0,0067	0,0087
.
.
.
31.08.2040	0,0152	0,0039	0,0132	0,0025	0,0101
30.09.2040	0,015	0,0039	0,0132	0,0025	0,0101
31.10.2040	0,0148	0,0039	0,0131	0,0025	0,0101
30.11.2040	0,0146	0,0039	0,013	0,0025	0,0101
31.12.2040	0,0144	0,0039	0,0129	0,0025	0,0101

Zdroj: Vlastní.

5.6 Ocenění dluhopisů

Tato kapitola představuje stanovení diskontních sazeb (na základě predikovaných údajů z předchozích kapitol) v případě GOS_1, SAF_1, SAF_2, SAF_3, TPH_1 a TPHnet_1 s následným použitím výpočtů pro ocenění jednotlivých dluhopisů.

5.6.1 GOS_1

V Tabulce 99 je možné vidět záznam predikovaného risk free a spreadu z předchozích kapitol, které posloužily jako součást výpočtu diskontních sazeb až do roku 2032. Díky rozsahu tabulky je zde uvedeno pouze prvních a posledních 5 případů. Kompletní verze tabulky je umístěna v Příloze D této práce.

Tabulka 99 Diskontní sazba GOS_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,007475	0,017075	0,00426875
31.12.2020	0,0108	0,007475	0,018275	0,00456875
31.03.2021	0,0101	0,007475	0,017575	0,00439375
30.06.2021	0,0121	0,007475	0,019575	0,00489375
.
.
.
31.03.2032	0,0118	0,007475	0,019275	0,00481875
30.06.2032	0,0121	0,007475	0,019575	0,00489375
30.09.2032	0,0122	0,007475	0,019675	0,00491875
31.12.2032	0,0125	0,007475	0,019975	0,00499375

Zdroj: Vlastní.

Tabulka 100 představuje ocenění dluhopisů na základě diskontní sazby vypočtené v předchozí Tabulce 99. Vzhledem k rozsahu tabulky je v Tabulce 100 uvedeno prvních a posledních 5 případů, přičemž kompletní tabulka je předmětem Přílohy E.

Tabulka 100 Ocenění dluhopisů GOS_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,00426875	15 000 000,00 Kč		14 936 240,92 Kč
19.12.2020	1,008857003	15 000 000,00 Kč		14 868 311,32 Kč
19.03.2021	1,013289668	15 000 000,00 Kč		14 803 269,46 Kč
19.06.2021	1,018248455	15 000 000,00 Kč		14 731 178,75 Kč
.
.
.
19.03.2032	1,303229258	15 000 000,00 Kč		11 509 870,51 Kč
19.06.2032	1,309606936	15 000 000,00 Kč		11 453 818,39 Kč
19.09.2032	1,316048565	15 000 000,00 Kč		11 397 755,68 Kč
19.12.2032	1,322620582	15 000 000,00 Kč	500 000 000,00 Kč	389 378 486,05 Kč
Total		750 000 000,00 Kč		1 030 450 871,99 Kč

Zdroj: Vlastní.

Cena emise korunových dluhopisů GOS_1 činí 1 030 450 871,99 Kč.

5.6.2 SAF_1

Diskontní sazby v Tabulce 101 jsou vypočteny na základě risk free a spreadu, které byly predikovány v předchozích kapitolách. Tabulka je zkrácena na prvních a posledních 5 případech. Kompletní verze tabulky je předmětem Přílohy F.

Tabulka 101 Diskontní sazba SAF_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,113808	0,123408	0,030852
31.12.2020	0,0108	0,113808	0,124608	0,031152
31.03.2021	0,0101	0,113808	0,123908	0,030977
30.06.2021	0,0121	0,113808	0,125908	0,031477
30.09.2021	0,0147	0,113808	0,128508	0,032127
.
.
.
31.12.2038	0,0158	0,113808	0,129608	0,032402
31.03.2039	0,0138	0,113808	0,127608	0,031902
30.06.2039	0,0136	0,113808	0,127408	0,031852
30.09.2039	0,0127	0,113808	0,126508	0,031627

Zdroj: Vlastní.

Diskontní sazby poslouží v další Tabulce 102 pro ocenění dluhopisů podniku SAF_1. I zde je z důvodu velkého rozsahu tabulka zkrácena na prvních a posledních 5 případech. Kompletní verze tabulky s oceněním dluhopisů SAF_1 je uvedena v Příloze G této práce.

Tabulka 102 Ocenění dluhopisů SAF_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,030852	5 500 000,00 Kč		5 335 392,47 Kč
19.12.2020	1,062965102	5 500 000,00 Kč		5 174 205,62 Kč
19.03.2021	1,095892571	5 500 000,00 Kč		5 018 740,11 Kč
19.06.2021	1,130387982	5 500 000,00 Kč		4 865 586,05 Kč
19.09.2021	1,166703957	5 500 000,00 Kč		4 714 135,04 Kč
.
.
.
19.09.2038	10,15885395	5 500 000,00 Kč		541 399,65 Kč
19.12.2038	10,48802114	5 500 000,00 Kč		524 407,79 Kč
19.03.2039	10,82260999	5 500 000,00 Kč		508 195,34 Kč
19.06.2039	11,16733176	5 500 000,00 Kč		492 507,98 Kč
19.09.2039	11,52052097	4 400 000,00 Kč	200 000 000,00 Kč	17 742 253,20 Kč
Total		422 400 000,00 Kč	200 000 000,00 Kč	173 232 120,15 Kč

Zdroj: Vlastní.

Cena emise korunových dluhopisů SAF_1 činí 173 232 120,15 Kč.

5.6.3 SAF_2

Diskontní sazby v Tabulce 103 jsou vypočteny na základě predikovaného risk free a spreadů z předchozích kapitol. Z důvodu rozsahu je tabulka i zde zkrácena na prvních a posledních 5 případech. Kompletní verze je předmětem Přílohy H

Tabulka 103 Diskontní sazba SAF_2

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,113808	0,123408	0,030852
31.12.2020	0,0108	0,113808	0,124608	0,031152
31.03.2021	0,0101	0,113808	0,123908	0,030977
30.06.2021	0,0121	0,113808	0,125908	0,031477
30.09.2021	0,0147	0,113808	0,128508	0,032127
.
.
.
31.12.2031	0,0128	0,113808	0,126608	0,031652
31.03.2032	0,0118	0,113808	0,125608	0,031402
30.06.2032	0,0121	0,113808	0,125908	0,031477
30.09.2032	0,0122	0,113808	0,126008	0,031502
31.12.2032	0,0125	0,113808	0,126308	0,031577

Zdroj: Vlastní.

V Tabulce 104 dochází k ocenění dluhopisů společnosti SAF_2 na základě údajů z předchozí Tabulky 103. Je uvedena opět zkrácená verze tabulky dle výše uvedeného pravidla. Kompletní verze je přiložena v Příloze I.

Tabulka 104 Ocenění dluhopisů SAF_2

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,030852	27 500 000,00 Kč		26 676 962,36 Kč
19.12.2020	1,062965102	27 500 000,00 Kč		25 871 028,09 Kč
19.03.2021	1,095892571	27 500 000,00 Kč		25 093 700,53 Kč
19.06.2021	1,130387982	27 500 000,00 Kč		24 327 930,27 Kč
19.09.2021	1,166703957	27 500 000,00 Kč		23 570 675,19 Kč
.
.
.
19.12.2031	4,306742255	27 500 000,00 Kč		6 385 336,84 Kč
19.03.2032	4,441982575	27 500 000,00 Kč		6 190 929,28 Kč
19.06.2032	4,58180286	27 500 000,00 Kč		6 002 004,20 Kč
19.09.2032	4,726138814	27 500 000,00 Kč		5 818 703,40 Kč
19.12.2032	4,875376099	47 500 000,00 Kč	1 000 000 000,00 Kč	214 855 219,09 Kč
Total		1 395 000 000,00 Kč	1 000 000 000,00 Kč	888 565 639,79 Kč

Zdroj: Vlastní.

Cena emise korunových dluhopisů SAF_2 činí 888 565 639,79 Kč.

5.6.4 SAF_3

Diskontní sazby v Tabulce 105 jsou vypočteny pomocí predikovaného risk free a spreadů z předchozích kapitol. Je uvedena opět zkrácená verze tabulky. Je znázorněno prvních a posledních 5 případů, přičemž kompletní verze je uložena v Příloze J této práce.

Tabulka 105 Diskontní sazba SAF_3

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,113808	0,123408	0,030852
31.12.2020	0,0108	0,113808	0,124608	0,031152
31.03.2021	0,0101	0,113808	0,123908	0,030977
30.06.2021	0,0121	0,113808	0,125908	0,031477
30.09.2021	0,0147	0,113808	0,128508	0,032127
.
.
.
30.06.2039	0,0136	0,113808	0,127408	0,031852
30.09.2039	0,0127	0,113808	0,126508	0,031627
31.12.2039	0,0117	0,113808	0,125508	0,031377
31.03.2040	0,0121	0,113808	0,125908	0,031477
30.06.2040	0,0122	0,113808	0,126008	0,031502

Zdroj: Vlastní.

Tabulka 106 ukazuje ocenění dluhopisů SAF_3, a to za pomoci diskontních sazeb vypočtených v předchozí Tabulce 105. Tabulka 106 je zkrácena na prvních a posledních 5 případů, kompletní verze je uložena v Příloze K.

Tabulka 106 Ocenění dluhopisů SAF_3

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,030852	2 200 000,00 Kč		2 134 156,99 Kč
19.12.2020	1,062965102	2 200 000,00 Kč		2 069 682,25 Kč
19.03.2021	1,095892571	2 200 000,00 Kč		2 007 496,04 Kč
19.06.2021	1,130387982	2 200 000,00 Kč		1 946 234,42 Kč
19.09.2021	1,166703957	2 200 000,00 Kč		1 885 654,01 Kč
.
.
.
19.06.2039	11,16733176	2 200 000,00 Kč		197 003,19 Kč
19.09.2039	11,52052097	2 200 000,00 Kč		190 963,59 Kč
19.12.2039	11,88200035	2 200 000,00 Kč		185 154,01 Kč
19.03.2040	12,25601008	2 200 000,00 Kč		179 503,77 Kč
19.06.2040	12,64209891	2 200 000,00 Kč	80 000 000,00 Kč	6 502 084,87 Kč
Total		176 000 000,00 Kč	80 000 000,00 Kč	69 253 653,01 Kč

Zdroj: Vlastní.

Cena emise korunových dluhopisů SAF_3 činí 69 253 653,01 Kč.

5.6.5 TPH_1

V Tabulce 107 je možné vidět stanovené diskontní sazby, které jsou potřebné pro ocenění dluhopisů TPH_1, a to za pomoci predikovaného risk free a spreadu. I v případě tabulky 107 se jedná o zkrácenou verzi, přičemž kompletní je uložena v příloze L.

Tabulka 107 Diskontní sazba TPH_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.m.
30.09.2020	0,0096	0,0342161	0,0438161	0,00365134
31.10.2020	0,0105	0,0342161	0,0447161	0,00372634
30.11.2020	0,0111	0,0342161	0,0453161	0,00377634
31.12.2020	0,0108	0,0342161	0,0450161	0,00375134
31.01.2021	0,0108	0,0342161	0,0450161	0,00375134
.
.
.
31.05.2032	0,0119	0,0342161	0,0461161	0,00384301
30.06.2032	0,0121	0,0342161	0,0463161	0,00385967
31.07.2032	0,0122	0,0342161	0,0464161	0,00386801
31.08.2032	0,0122	0,0342161	0,0464161	0,00386801
30.09.2032	0,0122	0,0342161	0,0464161	0,00386801

Zdroj: Vlastní.

V Tabulce 108 je možné vidět ocenění dluhopisů TPH_1 do roku 2032, a to za pomoci zjištěné diskontní sazby z předchozí Tabulky 107. Jedná se opět o zkrácenou verzi tabulky, kompletní verze je předmětem přílohou M.

Tabulka 108 Ocenění dluhopisů TPH_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
30.09.2020	1,003651341	19 000 000,00 Kč		18 930 876,91 Kč
31.10.2020	1,007391289	19 000 000,00 Kč		18 860 595,89 Kč
30.11.2020	1,011195542	19 000 000,00 Kč		18 789 639,80 Kč
31.12.2020	1,014988882	19 000 000,00 Kč		18 719 416,87 Kč
31.01.2021	1,018796452	19 000 000,00 Kč		18 649 456,40 Kč
.
.
.
30.04.2032	1,777102765	19 000 000,00 Kč		10 691 559,53 Kč
31.05.2032	1,783932185	19 000 000,00 Kč		10 650 629,08 Kč
30.06.2032	1,790817583	19 000 000,00 Kč		10 609 679,17 Kč
31.07.2032	1,79774448	19 000 000,00 Kč		10 568 798,97 Kč
31.08.2032	1,80469817	12 666 667,00 Kč	1 900 000 000,00 Kč	1 059 826 346,03 Kč
Total		2 729 666 667,00 Kč	1 900 000 000,00 Kč	3 112 084 637,16 Kč

Zdroj: Vlastní.

Cena emise korunových dluhopisů TPH_1 činí 3 112 084 637,16 Kč.

5.6.6 TPHnet_1

Tabulka 109 představuje záznam vypočtených diskontních sazeb potřebných pro ocenění dluhopisů podniku TPHnet_1, a to za pomoci predikovaného risk free a spreadu. Kompletní verze tabulky je uvedena v Příloze N.

Tabulka 109 Diskontní sazba TPHnet_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.m.
30.09.2020	0,0096	0,08433	0,09393	0,0078275
31.10.2020	0,0105	0,08433	0,09483	0,0079025
30.11.2020	0,0111	0,08433	0,09543	0,0079525
31.12.2020	0,0108	0,08433	0,09513	0,0079275
31.01.2021	0,0108	0,08433	0,09513	0,0079275
.
.
.
31.05.2032	0,0119	0,08433	0,09623	0,00801917
30.06.2032	0,0121	0,08433	0,09643	0,00803583
31.07.2032	0,0122	0,08433	0,09653	0,00804417
31.08.2032	0,0122	0,08433	0,09653	0,00804417
30.09.2032	0,0122	0,08433	0,09653	0,00804417

Zdroj: Vlastní.

Tabulka 110 představuje ocenění dluhopisů TPHnet_1 do roku 2032, a to za pomoci zjištěné diskontní sazby z předchozí Tabulky 109. Kompletní verze tabulky je uložena v Příloze O této práce.

Tabulka 110 Ocenění dluhopisů TPHnet_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
30.09.2020	1,0078275	45 000 000,00 Kč		44 650 498,23 Kč
31.10.2020	1,015791857	45 000 000,00 Kč		44 300 414,20 Kč
30.11.2020	1,023869942	45 000 000,00 Kč		43 950 894,71 Kč
31.12.2020	1,031986671	45 000 000,00 Kč		43 605 214,37 Kč
31.01.2021	1,040167745	45 000 000,00 Kč		43 262 252,87 Kč
.
.
.
30.04.2032	3,177335085	45 000 000,00 Kč		14 162 812,17 Kč
31.05.2032	3,202814664	45 000 000,00 Kč		14 050 141,74 Kč
30.06.2032	3,228551949	45 000 000,00 Kč		13 938 137,19 Kč
31.07.2032	3,254522959	45 000 000,00 Kč		13 826 911,21 Kč
31.08.2032	3,280702884	45 000 000,00 Kč	4 500 000 000,00 Kč	1 385 373 854,50 Kč
Total		6 480 000 000,00 Kč	4 500 000 000,00 Kč	5 149 638 933,29 Kč

Zdroj: Vlastní.

Cena emise korunových dluhopisů TPHnet_1 činí 5 149 638 933,29 Kč.

6 Diskuse výsledků

V rámci první fáze výsledkové části této práce byla nejprve provedena finanční analýza podniku, jejíž součástí byla komplexní metoda hodnocení podniku postavená na neuronových sítích. Konkrétně se jedná o tři druhy neuronových sítí, tedy o vícevrstvou perceptronovou neuronovou síť, neuronovou síť s GRL vrstvou a neuronovou síť s LSTM vrstvou. U každé metody komplexního hodnocení podniku využívající tyto výše uvedené skupiny sítí, bylo zachováno celkem 5 sítí vykazující nejlepší výkon. Lze konstatovat, že v případě zachovaných vícevrstevných perceptronových sítí vykazuje nejlepší výkon v testovací množině síť B-NN_LIN4 (0,707 %), přičemž hned po ní následuje síť B-NN_LIN5 s výkonem v testovací množině (0,701 %). Co se týká výkonu zachovaných neuronových sítí s GRL vrstvou, zde se jako nejlepší jeví síť B-NN_GRL3, jejíž výkon v testovací množině je 0,737 % a síť B-NN_GRL5 s výkonem 0,721 %. Ze skupiny uchovaných neuronových sítí s LSTM vrstvou dle nejvyššího výkonu v testovací množině je vítězem B-NN_LSTM1 (0,641 %) a s druhým nejvyšším výkonem síť B-NN_LSTM4 (0,603 %).

Následující část práce se prostřednictvím finanční analýzy orientovala na rozbor finančního zdraví u čtyř akciových společností, a to společnosti CHNC, a. s., SAF, a. s., TP, a. s. a BS, a. s. V rámci finanční analýzy u každé této společnosti byla provedena horizontální analýza pro posouzení vývoje aktiv, pasiv a výsledků hospodaření, vertikální analýza aktiv a pasiv, analýza poměrových ukazatelů (rentabilita, aktivita, likvidita a zadluženost) a rovněž provedeno komplexní hodnocení podniku (index bonity, index IN95, index IN99, Tafflerův index). Z výsledků provedené finanční analýzy společnosti CHNC, a. s. vyplývá, že finanční stránka společnosti CHNC, a.s. byla negativně poznamenána fúzí se společností GOS, a. a., kdy k roku 2014 měla horší výsledky, než tomu je v dalších letech. Na druhou stranu, společnost právě od tohoto roku začala zlepšovat svoji finanční kondici, která se projevila například nárůstem výsledku hospodaření před zdaněním, aktiv, vlastního kapitálu, rentabilitou aktiv, rentabilitou vlastního kapitálu apod. Při náhledu na finanční zdraví společnosti SAF, a.s. z širšího hlediska, je nutné poznamenat, že společnost i přes horší výsledky komplexních metod, vykazovala následující pozitivní ukazatele, které vypovídají o celkové dobré finanční kondici podniku. Celková aktiva zaznamenala každoroční nárůst. Stejně tak i každoročně společnost navyšovala vlastní kapitál, na kterém měl především velký podíl rostoucí kladný hospodářský výsledek. Dobré výsledky vykázaly i poměrové ukazatele, především ukazatele rentability a likvidity. Ze zpracované finanční analýzy společnosti TP, a.s. je zřejmé, že finanční zdraví během sledovaného období prošlo jistými změnami, ale v zásadě lze finanční situaci společnosti TP,

a.s. označit jako velmi dobrou. Vypíchnout lze především rok 2018 a 2019, kdy firma dosahovala za celé sledované období nejlepších výsledků. Jako příklad je možno uvést index bonity podle, kterého vyšla ekonomická situace této společnosti jako extrémně dobrá. Co se společnosti BS, a. s. a jejího finančního zdraví týká, tak lze konstatovat, že i přes relativně dobré výsledky, které vyšly z metod komplexního hodnocení podniku je zjevné, že společnost se potýká s obrovskou zadlužeností a disponuje zejména cizím kapitálem. Vlastní kapitál byl po celé sledované období záporný, což také nepoukazuje na dobrou finanční kondici podniku. V průběhu let byl zaznamenán i odliv peněžních prostředků a celkové snížení majetku společnosti, což je opět bráno za negativní ukazatel správného fungování podniku. Z výsledků tedy vyplývá, že nejhorší finanční kondici má poslední zmiňovaná firma, BS, a. s.

Po provedení finančních analýz byla další část textu věnována zpracování strategické analýzy loterijního průmyslu v ČR, ve kterém působí společnost Berounská servisní, a. s., a dále provedení strategické analýzy zaměřené na bankovní sektor u společnosti SAF, a. s. Rozsah strategické analýzy loterijního průmyslu zahrnoval analýzu loterijního průmyslu v ČR a dále analýzu odvětví. Na základě výsledků strategické analýzy loterijního průmyslu ČR lze konstatovat, že loterijní průmysl každým rokem roste. V uplynulých letech 2002–2019 každoroční objem vložených peněz do hazardních her vzrostl, vyjma období finanční krize (2008–2013), při kterém výše vsazených finančních prostředků stagnovala a pohybovala se přibližně okolo 125 mld. Kč ročně. Provozovatelé hazardních her stejně jako jiná odvětví pocítují obrovské příležitosti v technologickém rozvoji a jejich příjmy tak dlouhodobě rostou, zejména díky online hazardním hrám. Při pohledu na trendy se zdá, že míra hraní hazardních her v dospělé populaci současně roste. Účast na hazardních hrách v posledních sledovaných měsících uvádí přibližně 30–40 % dospělých, což je nejspíše zapříčiněno právě otevřením hazardních her pro online prostředí. Dále bylo zjištěno, že k největším rizikům ohrožující tento průmysl patří neustálé změny v legislativě, omezování a zákazy provozování heren a nejrůznější typy závazných vyhlášek. Co se týká strategické analýzy bankovního sektoru, tak její rozsah zahrnuje obdobné jako v předchozím případě, tedy analýzu bankovního sektoru ČR a analýzu odvětví. Zde je nutné ještě jednou připomenout, že zkoumaná společnost SAF, a. s. není přímo banka, ale subjektem poskytující úvěry a půjčky, tedy strategická analýza byla zpracována na nejbližší odvětví – tj. bankovní. Na základě výsledků této analýzy, respektive dle ukazatele poskytnutých úvěrů soukromému sektoru v České republice za období 2010–2020 (hodnoty roku 2020 jsou za první pololetí) lze konstatovat, že bankovní sektor má vzestupnou tendenci a každým rokem roste. Za toto desetileté období objem poskytnutých úvěrů soukromého sektoru v ČR vzrostl téměř o 65 %. Roku 2010 bylo poskytnuto necelých 2 000

mld. Kč, o 10 let později, v roce 2020 už 3 250 mld. Kč. Růst bankovního průmyslu potvrzuje i údaj o výši emitovaných dluhových cenných papírů na území České republiky – celkovým objem emise měl v období 2010–2019 rostoucí trend. Největším emitentem dluhopisů byl v každém roce stát (tj. vládní instituce).

Následující fáze představovala dále provedení analýzy trhu loterijního průmyslu a bankovního sektoru. V případě analýzy trhu loterijního průmyslu bylo zjištěno, že trh s hazardními hrami může být v ČR provozován pouze na základě povolení vydaného loterijního zákona, přičemž toto povolení mělo k 1. 1. 2019 v ČR celkem 57 společností. Z analýzy dále vyplynulo, že na provozování land-based kursových sázek k 1. 1. 2019 mělo povolení v České republice 8 společností, ovšem ve skutečnosti však k 4. 1. 2019 provozovalo land-based kursové sázky pouze 5 společností. Největší počet sázkových kanceláří je připsán společností Tipsport.net (734) a Fortuna game (567). Analýza také ukazuje, že podstatná většina kursového sázení v současnosti probíhá prostřednictvím internetu v on-line prostředí, kdy k 1. 1. 2020 mělo povolení provozovat on-line kursové sázky celkem 8 společností, ovšem jen 7 z nich je provozovalo. Z výsledků analýzy bankovního sektoru se lze dozvědět, že k 31. 7. 2020 působilo v ČR celkem 59 měnových finančních institucí, přičemž v ČR je sektor měnových finančních institucí tvořen centrální bankou, obchodními bankami, spořitelními a úvěrními družstvy a fondy peněžního trhu. Neustále narůstající tempo poskytnutých úvěrů a půjček dokládá i zvyšující se počet obchodníků s cennými papíry v ČR. Dle statistiky České národní banky počet subjektů, které obchodovaly s cennými papíry v průběhu posledních devíti let (tj. 2010–2019) kontinuálně roste. Za toto období se změnil počet subjektů z 58 na 84.

K další důležité součásti této práce patřilo stanovení diskontní sazby za účelem konečného stanovení časové hodnoty dluhopisů. Aby k tomuto mohlo dojít, bylo nejdříve zapotřebí stanovit spread. V této práci byl spread stanoven pro dvě skupiny služeb, tedy skupinu „Finanční služby a nezařazené“ a „Služby heren a kurzového sázení“. V obou případech byl spread stanovován opět pomocí tří druhů neuronových sítí, tj. vícevrstevných perceptronových sítí, neuronových sítí s GRL vrstvou a neuronových sítí s LSTM vrstvou, přičemž pro každou skupinu jich bylo dle nejlepšího výkonu opět uchováno 5 nejlepších. Pro první skupinu služeb u spreadu stanoveného pomocí vícevrstevných perceptronových neuronových sítí je za nejlepší síť s nejvyšším výkonem považována D-FS-NN_LIN5 (0,994 %), u spreadu stanoveného pomocí neuronových sítí s GRL vrstvou je to rovněž síť D-FS-NN_GRL5 s výkonem 0,972 % a u spreadu stanoveného pomocí neuronových sítí s LSTM vrstvou činí výkon nejlepší sítě D-FS-NN_LSTM5 (0,976 %). Výsledný spread hodnocených dluhopisů, s kterým bylo poté nadále počítáno, byl následující: nejvyšší hodnoty spreadu dle vícevrstevných perceptronových

sítí dosáhla síť D-FS-NN_LIN4 (0,176 %), nejvyšší hodnotu spreadu za pomoci neuronových sítí s GRL vrstvou vykazovala síť D-FS-NN_LIN4, a to s hodnotou 0,156 % a v poslední řadě nejvyšší hodnota spreadu dle neuronových sítí s LSTM D-FS-NN_LIN4 vrstvou činila 0,153 %.

Zcela stejně bylo postupováno v případě druhé skupiny služeb, tj. Služeb heren a kurzového sázení. Dle výsledků lze spatřit, že u spreadu stanoveného pomocí vícevrstevných perceptronových neuronových sítí lze za nejlepší síť s nejvyšším výkonem považovat D-HAZ-NN_LIN5 (0,926 %), u spreadu stanoveného pomocí neuronových sítí s GRL vrstvou je to rovněž síť D-HAZ-NN_GRL5 s výkonem 0,922 % a u spreadu stanoveného pomocí neuronových sítí s LSTM vrstvou činí výkon nejlepší sítě D-HAZ-NN_LSTM5 (0,927 %). Rovněž i zde následovalo zjištění výsledného spreadu hodnocených dluhopisů na základě jednotlivých druhů neuronových sítí, přičemž jednotlivé predikce jsou vázány ke společnostem BS, a.s.; CHNC, a.s. a TP, a.s. Výsledky ukazují, že některé spready, zejména u společnosti TP, a. s. vykazují záporné hodnoty.

Následující krok se zabýval stanovováním bezrizikové úrokové míry neboli tzv. risk free, přičemž opět zde bylo využito třech stejných skupin sítí, jako v předchozích případech. Z výsledků lze konstatovat, že nejlepšího výkonu z uchovaných vícevrstevných perceptronových sítí použitých pro stanovení bezrizikové míry dosahuje síť RF-NN_LIN5 (0,9984 %). V případě stanovení bezrizikové úrokové míry pomocí NN s GRL vrstvou vykazuje nejlepší výkon síť RF-NN_GRL5 (0,994 %). Na základě přehledu uchovaných NN s LSTM vrstvou lze říci, že výkon všech sítí převyšuje 99 %, ale zcela nejvyšší výkon je připisán síti RF-NN_LSTM5 (0,9927 %). Při porovnání výsledků predikce risk free prostřednictvím všech tří skupin sítí, lze konstatovat, že zde existují pouze drobné odchylky. K nejpřesnějším sítím, z pěti uchovaných, ze skupiny vícevrstevných perceptronových sítí, jež byla schopna nejlepší predikce, patří síť RF-NN_LIN2. V případě NN s GRL vrstvou pak vykazovala nejlepší predikci síť RF-NN_GRL3 a v rámci NN s LSTM vrstvou je to pak síť RF-NN_LSTM4

Na základě predikovaných údajů, tj. predikovaného spreadu a predikované risk free došlo v posledním kroku k ocenění dluhopisů, přičemž toto ocenění proběhlo celkem u 6 podniků – GOS_1, SAF_1, SAF_2, SAF_3, TPH_1 a TPHnet_1. Lze tedy konstatovat, že cena emise korunovaných dluhopisů GOS_1 činí 1 030 450 871,99 Kč. Cena emise korunových dluhopisů SAF_1 činí 173 232 120,15 Kč. Cena emise korunových dluhopisů SAF_2 činí 888 565 639,79 Kč. Cena emise korunových dluhopisů SAF_3 činí 69 253 653,01 Kč. Cena emise korunových dluhopisů TPH_1 činí 3 112 084 637,16 Kč a cena emise korunových dluhopisů TPHnet_1 činí 5 149 638 933,29 Kč.

Zaměříme-li se na výsledky obdobných výzkumů týkající se problematiky oceňování dluhopisů, lze se odkázat na celou řadu studií.

Velmi zajímavý je výzkum Brennan a Brabazon (2004), kteří se v rámci svého výzkumu zabývali hodnocením podnikových dluhopisů, a to prostřednictvím neuronových sítí. Konkrétně zkoumali užitečnost neuronové sítě zpětného šíření při modelování procesu hodnocení emitenta podnikových dluhopisů. K trénování a testování vyvinutého modelu použili autoři finanční údaje a související ratingy emitenta Standard & Poor's od 791 amerických společností čerpané z období 1999–2000. Na základě jejich výsledků bylo zjištěno, že model je schopen rozlišovat mezi hodnocením investičního a subinvestičního stupně mezi vzorky s přesností 90,48 % a mimo vzorek s přesností 84 %. Složitějším úkolem byla předpověď přesných úvěrových ratingů emitenta mezi více diskrétními ratingovými třídami. V tomto případě byl model schopen předpovědět rating emitenta s tolerancí jedné třídy od jeho skutečného ratingu s přesností 92,89 % ve vzorku a 87 % mimo vzorek. Výsledky dále naznačily, že úvěrové ratingy přidělené emitentům dluhopisů lze s přiměřenou přesností předpovědět z relativně omezené podmnožiny finančních údajů specifických pro firmy pomocí neuronové sítě zpětného šíření. Zhou et al. (2007) zase pomocí umělých neuronových sítí navrhli neparametrickou metodu, jež slouží pro odhad ceny konvertibilních dluhopisů kótovaných na šanghajské burze cenných papírů. Z výsledků jejich výzkumu vyplynulo, že výkonnost navrhovaného modelu produkuje často lepší cenu směnitelných dluhopisů než jiné parametrické modely. Výsledky modelové simulace byly mírně nižší než skutečné tržní ceny obecně, které jsou významné a liší se od předchozích studií. Neuronové sítě, respektive pravděpodobnostní neuronové sítě (PNN) využili za účelem svého výzkumu i Long a Pavlova (1999), a to konkrétně ke klasifikaci podnikových dluhopisů vydávaných britskými společnostmi, přičemž celkový vzorek dat obsahoval 55 těchto firem. Neuronová síť byla trénována pomocí pěti finančních poměrů. Všechny provedené experimenty ukázaly, že PNN byly schopny klasifikovat podnikové dluhopisy, přičemž stupeň přesnosti vždy závisel na volbě modelu PNN a na datech použitých k trénování a testování konkrétního modelu. Výsledky ukázaly, že dva z pěti modelů klasifikujících podnikové dluhopisy dokázaly překonat validaci, přičemž vyšší z těchto výsledků dosáhl 75,47% přesnosti klasifikace. Strojové učení konkrétně autoencoder využil Suimon (2020), pomocí něhož vyvinul dlouhodobou strategii pro oceňování japonských státních dluhopisů, která je schopna určit jejich nadhodnocenost či podhodnocenost. Z výsledků výzkumu vyplynulo, že navrhovaný model využívající autoencoder je pro oceňování aktiv dlouhodobých státních dluhopisů velmi efektivní. Entrop et al. (2013) v rámci svého výzkumu zase kvantifikovali a vysvětlili oceňovací rozdíly mezi

swapy úvěrového selhání (CDS) a podnikovými dluhopisy, a to na vzorku evropských společností s investičním stupněm. Na základě všech informací získaných kalibrací úvěrového modelu stochastické intenzity k časové řadě křivky CDS emitenta definovali autoři nové měřítko oceňovacího rozdílu specifické pro podnikové dluhopisy. Výsledky jejich výzkumu ukázaly, že rizikové prémie implikované v podnikových dluhopisech v průměru převyšují prémie na trzích CDS v mnohem menším rozsahu, než bylo doposud zjištěno v jiných studiích. Za pomoci panelové datové analýzy autoři zjistili průřezový vliv opatření likvidity dluhopisů a zjistili významný dopad obecné úrovně úvěrového rizika na změnu časové řady rozdílu v ocenění. Fan (2014) zase pomocí endogenního modelu čistého selhání a splatného podnikového dluhopisu provedl analýzu ocenění pevných dluhopisů a úvěrového selhání. Rozložením podnikového dluhopisu jako srovnávacího dluhopisu vložené opce, analýzou faktorů efektu úvěrového rozpětí a komplexní demontáží dopadů exogenního šoku na vložené opce autoři zjistili, že kreditní rozpětí je ovlivněno pevnou hodnotou. Přičemž nižší počáteční pevná hodnota znamená vyšší úvěrové rozpětí. Rozdíl mezi spready je však menší než rozdíl mezi pevnou hodnotou a pravděpodobností neutrálního rizika. Dong et al. (2019) navrhli nový model oceňování podnikových dluhopisů, který představuje modifikaci klasického Mertonova modelu. V tomto novém modelu autoři upustili od předpokladu likvidity procesu hodnoty aktiv společnosti a předpokládali, že na trhu existuje likvidně obchodovatelné aktivum, jehož hodnota koreluje s hodnotou aktiv firmy a že všechna portfolia lze sestavovat pouze pomocí tohoto aktiva a účtu peněžního trhu. Tržní cenu podnikového dluhopisu formulovali jako optimální cenu produktu replikujícího se portfolia, kde k představovala nezápornou konstantu. Jako další lze uvést studii Hu a Park (2019), v rámci níž tito autoři představili nový rovnovážný model pro oceňování zajištěných dluhových obligací (CDO). Model je založen na teorii cen opcí a nabízí velikost náhodného skoku, jenž zohledňuje výchozí korelaci mezi referenčními entitami. Výsledky simulace ukázaly, že volatilita velikosti skoku, zachycující nejistotu ohledně velikosti současných podnikových výchozích hodnot, je klíčovým parametrem při stanovení cen CDO. Účinek volatility velikosti skoku na CDO spready je podstatný a závisí na relativní poloze střední velikosti skoku k limitům ztráty. Cílem studie Maruddani et al. (2015) bylo ocenit kupónový dluhopis na jedno období kupónového dluhopisu, který v období dluhopisu poskytuje pouze jeden časový kupón. Autoři předpokládali, že model dává držiteli dluhopisů právo na reorganizaci firmy, pokud její hodnota klesne pod danou hranici. Pro výchozí pravidlo času byl použit revidovaný přístup prvního času. Výsledkem bylo, že pro tento specifikovaný model jsou odvozeny vzorce vlastního kapitálu, odpovědnosti a pravděpodobnosti selhání. Pro odvození těchto vzorců se použila přímá integrace za rizikové

neutrální ceny. Pro aplikaci byl analyzován dluhopis Bank Rakyat Indonesia (BRI) jako jedné z největších bank v Indonésii. Výpočet R ukázal, že hodnota vlastního kapitálu činí 453 724 549 000 000 IDR, závazek činí 2 657 394 000 000 IDR a pokud výchozí hodnota činí 5 645 305 E pravděpodobnost je 47 %. Liang et al. (2015) představili cenový model pro podnikový dluhopis s rizikem migrace ratingu. Autoři pomocí technologie ocenění užitek lhostejnosti dle Markovova modulovaného rámce analyzovali cenu dluhopisu s více ratingy. Pro tři ratingy tak získali uzavřené cenové vzorce, dle kterých analyzovali dopady parametrů na lhostejnou cenu. Cíl studie Lin et al. (2003) zase spočíval v ocenění Euro-konvertibilních dluhopisů (ECB), což jsou hybridní cenné papíry s vlastnostmi akcií i dluhopisů. Za účelem tohoto ocenění použili autoři přístup LSM – Least Square Monte Carlo simulation vyvinutý v roce 2001 Longstaffem a Schwartzem. Hodnota konverzní opce a měnové opce vložených do ECB byla získána z rozdílů mezi hodnotami čistých podnikových dluhopisů, převoditelných dluhopisů (CB) a ECB. Záměrem Zmeskala a Dluhosove (2017) bylo odvodit a popsat modely cen dluhopisů za rizika, flexibility a interakce, přičemž interakce se zabývala teorií her. Ceny dluhopisů autoři vypočítali a následně porovnávali na základě binomického modelu založeného na modelu Ho-Lee arbitrage pro forwardové sazby. Na základě výsledků výzkumu dospěli autoři k závěru, že podmínky oceňování podstatně ovlivňují ceny dluhopisů, a proto musí být zahrnuty do procesu oceňování. Porovnání tří oceňovacích modelů konvertibilních dluhopisů se v rámci svého výzkumu věnovali Zobolotnyuk et al. (2010). Autoři uplatnili inovativní přístup, kde byly všechny parametry modelu odhadovány Marquardtovým algoritmem pomocí podvorku cen konvertibilních dluhopisů, přičemž parametry modelu pak použili pro předpovědi cen konvertibilních dluhopisů mimo vzorek. Z výsledků výzkumů vyplynulo, že průměrná absolutní odchylka je 1,86 % pro model Ayache-Forsyth-Vetzal, pro model Tsiveriotis-Fernandes 1,94 %, a pro model Brennan-Schwartz 3,73 %. Z tohoto, a dalších hledisek přizpůsobení překonaly modely Ayache-Forsyth-Vetzal a Tsiveriotis-Fernandes model Brennan-Schwartz. Výzkum Landskroner a Raviv (2008) se týkal odvození oceňovacího modelu konvertibilních dluhopisů indexovaných inflací obchodovaných na burze v Tel Avivu, který zahrnoval cenu akcií společnosti, indexaci inflace a úvěrové riziko firmy. Autoři zjistili, že teoretické hodnoty dluhopisů jsou v průměru o 1,94 % vyšší než sledované tržní ceny. Na rozdíl od předchozích studií bylo zjištěno, že podbízení roste s peněžností konvertibilního vozu. Dále se přišlo na to, že s prodlužováním splatnosti se podhodnocování zvyšuje. Za zmínku stojí také výzkum Lin a Ren (2006), kteří na základě empirické literatury o modelech úvěrového rizika stanovili model oceňování dluhopisů se selháním, který zohledňuje riziko likvidity. Likvidní prémii modelovanou jako výhodný výnos autoři do modelu přidali za sníženého

úvěrového rizika. Tento výzkum využívá údajů o podnikových dluhopisech na čínských trzích. Na základě výsledků tohoto výzkumu lze konstatovat, že v porovnání s tradičními modely oceňování dluhopisů může tento rozšířený navrhovaný oceňovací model lépe odpovídat tržním datům. Výsledky dále ukázaly, že na čínských trzích podnikových dluhopisů existuje zjevná likvidní prémie. Tradiční modely oceňování dluhopisů, které zanedbávají riziko likvidity, mají tendenci nadhodnocovat míru selhání.

Na základě výše zpracovaných kapitol a dosažených výsledků může nyní dojít k zodpovězení stanovených výzkumných otázek:

VO1: Nabízí metoda komplexního hodnocení podniku zkonstruovaná na bázi Gated Recurrent NN lepší výsledky než metody konstruované pomocí diskrétní analýzy?

ANO. Při hodnocení podniků, dosahovala GRL NN v případě trénovací množiny dat výkonů od 77 % do necelých 79 %. V případě testovací množiny dat u metody konstruované pomocí diskrétní analýzy hovoříme o výkonu pohybujícím se mezi 68 % až necelými 74 %. Na základě těchto výsledků lze tedy konstatovat, že metoda komplexního hodnocení podniku zkonstruovaná na bázi Gated Recurrent nabízí lepší výsledky, ovšem neliší se nikterak zásadně. Odkázat se lze například na studii Altman et al. (2017), která se zabývala hodnocením výkonu klasifikace modelu Z-Score při předpovídání bankrotu a dalších typů podnikových potíží s cílem posoudit užitečnost modelu pro všechny strany, zejména pro banky, které působí v mezinárodním měřítku a potřebují posoudit riziko selhání firem. Analyzována byla výkonnost modelu Z-Score pro firmy z 31 evropských a tří mimoevropských zemí pomocí různých modifikací původního modelu. Kromě Spojených států a Číny byly společnosti ve vzorku primárně soukromé a zahrnovaly nefinanční společnosti napříč všemi průmyslovými odvětvími. Z výsledků tohoto výzkumu vyplynulo, že obecný model Z-skóre funguje ve většině zemí přiměřeně dobře (přesnost predikce je přibližně 0,75) a přesnost klasifikace lze dále zlepšit (nad 0,90) pomocí odhadu specifického pro zemi, který zahrnuje další proměnné. I přes tento fakt, ovšem existují důkazy o tom, že modely Z-Score predikce bankrotu byly překonány konkurenčními tržními modely nebo modely rizik.

O ne zcela dobré vypovídací schopnosti Altmanova modelu poskytli důkazy Munoz et al. (2020). Tito autoři v rámci svého výzkumu provedli analýzu užitečnosti kombinace účetních a auditorských údajů za účelem předpovědi finanční tísně společnosti. Konkrétně autoři zkoumali, zda informace z auditní zprávy jsou schopny postupně předpovídat tíseň nad tradičním účetním modelem: Altmanovým Z-skóre. Z datového souboru 1 821 španělských soukromých firem v tísní analyzovali vzorek firem v tísní a vyvinuli logické predikční modely. Jejich výsledky ukázaly, že zatímco Altmanovo Z-skóre vykazovalo přesnost

klasifikace 77 %, kombinované modely účetních a auditorských údajů vykazovaly podstatně vyšší přesnost, a to asi 87 %.

Kubíčková (2015) zase v rámci své studie prezentovala výsledky zkoumající finanční stabilitu prostřednictvím Ohlsonova modelu, Altmanova modelu a modelu IN05. Zkoumaným vzorkem byl soubor 2014 firem ve zpracovatelském průmyslu v České republice za období let 2012 a 2013. Výsledky výzkumu ukázaly, že Ohlsonův model a model IN05 potvrdily dobrou finanční situaci společností v 80 % případů, Altmanův model jen ve 49 % případů. Všechny tři modely se shodovaly při hodnocení finanční situace firem, a to v 52 % případech.

VO2: Je vhodné určit diskontní sazbu pro stanovení časové hodnoty obligací pomocí neuronových sítí?

ANO. Určení diskontní sazby pro stanovení časové hodnoty obligací je prostřednictvím neuronových sítí vhodné. Toto tvrzení bylo prokázáno na základě stanovování diskontní míry pro potřeby této práce, respektive k predikci spreadu a bezrizikové úrokové míry. Pro tyto potřeby neuronové sítě vykázaly velmi vysoký výkon, což značí jejich vhodnost uplatnění. Neuronové sítě postihnou dynamiku vývoje, navíc je lze přetrénovat a vykazují velmi vysokou přesnost.

VO3: Lze objektivně stanovit diskontní sazbu pro stanovení časové hodnoty obligací?

ANO. Je možné objektivně stanovit diskontní sazbu pro stanovení časové hodnoty obligací. Přesněji byly stanoveny jednotlivé komponenty diskontní sazby, proto bude pravděpodobněji přesnější i celá diskontní sazba.

7 Přínosy habilitační práce

Práce se opírá o myšlenku, že veškeré způsoby ocenění jsou založené na peněžních tocích spojených s dluhopisy a následně také diskontní sazbě a k ocenění se využívá analogie s jinými dluhopisy, přičemž problém nastává ve chvíli, kdy se oceňují dluhopisy neveřejně obchodovatelné či prokazatelně neexistují takové cenné papíry, které jsou velmi podobné. Výsledkem habilitační práce je návrh metodického postupu pro ocenění neveřejně obchodovaných dluhopisů, neboť právě pro tyto případy neexistuje ustálený způsob ocenění takových dluhopisů. Práce v teoretické rovině rozvíjí téma dluhopisů, základní východiska pro ocenění dluhopisů a téma umělých neuronových sítí. Přínosy výsledků habilitační práce se promítají i do praxe a vzdělávací činnosti školy.

7.1 Přínosy pro rozvoj teorie a vědy

Zásadním přínosem habilitační práce je prohloubení poznatků v oblasti oceňování dluhopisů a využití neuronových sítí v oceňování. Přínosy pro rozvoj teorie a vědy lze shrnout do následujících bodů:

- zasazení principu umělých neuronových sítí do kontextu oceňování dluhopisů,
- zmapování aktuálních poznatků a studií věnujících se dluhopisům a způsobům jejich ocenění, včetně zhodnocení úspěšnosti takových modelů,
- rozšíření poznatků a systematické shrnutí přínosů využití umělé inteligence při oceňování dluhopisů,
- zhodnocení stávajícího konceptu oceňování dluhopisů a jeho modifikace v souladu s aktuálním poznáním v dotyčné oblasti,
- návrh univerzálně použitelného metodického postupu oceňování neveřejně obchodovaných dluhopisů či dluhopisů, pro které neexistují cenné papíry, podle nichž by takové dluhopisy mohly být oceněny.

7.2 Přínosy pro rozvoj praxe

Habilitační práce rozvíjí téma aplikace umělých neuronových sítí do oceňování zvláštních druhů dluhopisů. Za přínosy pro rozvoj praxe lze považovat:

- navržená metodika se může stát efektivním nástrojem pro ocenění dluhopisů, které nejsou veřejně obchodovatelné či pro ty typy dluhopisů, pro které prokazatelně neexistují analogické dluhopisy,
- metodika umožňuje oceňovateli/znalci s vysokou přesností ke stanovenému datu ocenit dluhopis,
- metodika využívá nejmodernější metody, které prokazatelně zvyšují celkovou úspěšnost ocenění,
- metodika bere v úvahu různé aspekty, které ovlivňují hodnotu dluhopisu – finanční analýzu, strategickou analýzu, analýzu trhu, diskontní sazbu pro stanovení časové hodnoty dluhopisů – a smysluplně kombinuje stávající konvenční metody s umělými neuronovými sítěmi,
- metodika umožňuje i v případě nedostatku informací stanovit hodnotu dluhopisu – při standardních případech se v případě nedostatku informací dluhopis považuje za rizikový a není možné jeho hodnotu stanovit.

7.3 Využití výsledků práce ve vzdělávací činnosti

Výsledky dosavadního výzkumu mají přesah do výuky předmětů Finance podniku, Finanční řízení podniku či připravovaného předmětu Oceňování finančního majetku. Výsledky umožní studentům porozumět tématu oceňování dluhopisů, speciálním případům ocenění takových cenných papírů, a to za předpokladu využití moderních nástrojů. Zpracovaná aplikace na reálných datech umožní lepší pochopení dané problematiky.

7.4 Koncepce směřování vědecké a pedagogické činnosti

Oceňování cenných papírů, a konkrétně dluhopisů, je rozsáhlým a dynamickým tématem. Vědecká činnost bude směřovat do oblasti využití umělé inteligence při ocenění dluhopisů či jiných cenných papírů. Při oceňování dluhopisů totiž existují určité mezery, přičemž je nutné najít efektivní sofistikované možnosti ocenění jakéhokoli dluhopisu, a to již z toho pohledu, že v posledních letech nastal doslova boom zejména korporátních dluhopisů. Jedná se o důsledek uvolněné regulace ze strany ČNB a Ministerstva financí. Aktuální legislativní úprava umožňuje vydání dluhopisu prakticky jakémukoliv ekonomickému subjektu. Se speciálními případy dluhopisů se tak oceňovatelé/znalci setkávají čím dál tím častěji, přičemž jednotná metodika pro ocenění takových typů dluhopisů dosud neexistuje. Umělá inteligence a speciálně umělé

neuronové sítě jsou úspěšně aplikovány u celé řady činností, aplikací a setkáváme se s nimi, ač možná nevědomky, denně. Ve velkém se rozvíjí jejich aplikace do podnikového hospodářství, přičemž oblast oceňování cenných papírů v tomto ohledu není příliš dotčena. Výsledky výzkumu budou reflektovány ve výuce předmětů Finance podniku, Finanční řízení podniku či v případě úspěšné akreditace také v předmětu Oceňování finančního majetku.

Závěr

V případě ocenění dluhopisů je možné najít efektivní sofistikované možnosti, jak dluhopisy ocenit. Avšak dostáváme-li se detailněji k ocenění, zjišťujeme, že veškeré způsoby ocenění jsou založené na peněžních tocích spojených s dluhopisy a následně také na diskontní sazbě. Zároveň je však všeobecně známo, že veškeré peněžní toky jsou dány emisními podmínkami dluhopisů. K dosažení správné ceny dluhopisu je tedy potřeba určení správné diskontní sazby pro stanovení čisté současné hodnoty peněžních toků (kuponové platby a vratky jistiny). K ocenění je hojně používána jinými znalci takzvaná analogie s jinými dluhopisy. Problém nastává ve chvíli, kdy dluhopisy nejsou veřejně obchodovány, či prokazatelně neexistují takové cenné papíry, které jsou velmi podobné, znalec má možnost získat potřebné informace, a mohly by být použity pro analogii. V případě, že by cenné papíry splňovaly podmínky a problémy výše zmíněné by nenastaly, tudíž by byly dluhopisy veřejně obchodovány či by prokazatelně existovaly podobné cenné papíry, je možné využít metodiku ČNB. Pakliže podmínky splněny nejsou, a metodiku ČNB tak není možné použít pro ocenění dluhopisů, je takovýto dluhopis považován za rizikový, a ve své podstatě není možné stanovit jeho hodnotu, a to z důvodu nedostatku informací. Z toho plyne, že neexistuje ustálený způsob ocenění cenných papírů, které nejsou veřejně obchodovány, a právě ocenění dluhopisů, které nejsou veřejně obchodovány, bylo cílem této práce.

Cílem práce bylo ocenit správně dluhopisy na příkladu konkrétní společnosti. Při ocenění by měly být využity v případě, kde to bude možné a smysluplné, umělé neuronové sítě. Tato podmínka splnění cíle práce byla taktéž splněna, jelikož umělé neuronové sítě byly v případě výzkumné části práce použity jako metody pro komplexní hodnocení podniků, pro predikci stanovení spreadu a bezrizikové úrokové míry dluhopisů, kde výsledky predikce spreadu a bezrizikové úrokové míry byly využity pro stanovení diskontní sazby použité pro ocenění dluhopisů veřejně neobchodovaných.

Jedním z dílčích cílů celé práce bylo taktéž provedení finanční analýzy podniku, kde součástí této finanční analýzy je i komplexní metoda hodnocení podniku založena na neuronových sítích. Finanční analýza včetně zmíněného využití metod NN byla provedena, a to v případě podniků CHNC, a.s., SAF, a.s., TP, a.s. a BS, a.s.

U podniku CHNC, a.s. bylo pomocí finanční analýzy zjištěno, že v důsledku fúze byl v prvním roce sledovaného období (rok 2014) evidován záporný vlastní kapitál. Nákup obchodního podílu v rámci sloučeného účetnictví byl zaúčtován jako snížení vlastního kapitálu, jako záporný ostatní kapitálový fond. Mimo tuto skutečnost společnost CHNC, a.s. v období

2014–2019 vždy vykazovala zisk, který se za sledované období více jak zjedenáctinásobil. Celková aktiva po celou sledovanou dobu kontinuálně rostla (vyjímaje roku 2018, kdy byl zaznamenán mírný pokles). Rostoucí vývoj aktiv je obecně považován jako pozitivní a chtěnou změnu podniku. Po celé období byla společnost financována z větší části z cizích zdrojů. Ukazatele likvidity byly vždy vyměřeny jako nadprůměrné z důvodu vlastnění velkého množství peněžních. Komplexní hodnocení CHNC, a.s. dle indexu bonity přineslo pozitivní výsledek. Po celé období podnik spadal do zóny bonitních podniků. Finanční stránka společnosti CHNC, a.s. byla negativně poznamenána fúzí se společností GOS, A.S., kdy k roku 2014 měla horší výsledky, než tomu je v dalších letech. Dalším podnikem podrobeným finanční analýze je podnik SAF, a.s., kde je nutné poznamenat, že společnost i přes horší výsledky komplexních metod, vykazovala následující pozitivní ukazatele, které vypovídají o celkové dobré finanční kondici podniku. Celková aktiva zaznamenala každoroční nárůst. Stejně tak i každoročně společnost navyšovala vlastní kapitál, na kterém měl především velký podíl rostoucí kladný hospodářský výsledek. Dobré výsledky vykazaly i poměrové ukazatele, především ukazatele rentability a likvidity. V případě podniku TP, a.s. při podrobení finanční analýze vyplynulo, že finanční zdraví během sledovaného období prošlo jistými změnami, ale v zásadě lze finanční situaci společnosti TP, a.s. označit jako velmi dobrou.

Výsledek komplexního hodnocení podniku za využití indexu bonity je, že podnik v každém byl bonitní a vytvářel hodnotu. K nejhorsím výsledkům finanční analýzy dospěl podnik BS, a.s., kde i přes relativně dobré výsledky, které vyšly z metod komplexního hodnocení podniku je zjevné, že společnost se potýká s obrovskou zadlužeností a disponuje zejména cizím kapitálem. V průběhu let byl zaznamenán i odliv peněžních prostředků a celkové snížení majetku společnosti, co je opět bráno za negativní ukazatel správného fungování podniku. Po zhodnocení finančního zdraví všech podniků za pomoci finanční analýzy, lze považovat tento dílčí cíl za naplněný.

Spolu s finanční analýzou byla provedena taktéž strategická analýza loterijního průmyslu a finančních služeb. Z výsledků strategické analýzy loterijního průmyslu vyplynulo, že loterijní průmysl každým rokem roste. V uplynulých letech 2002–2019 každoroční objem vložených peněz do hazardních her vzrostl, vyjma období finanční krize (2008–2013), při kterém výše vsazených finančních prostředků stagnovala a pohybovala se přibližně okolo 125 mld. Kč ročně. Bylo také zjištěno, že provozovatelé hazardních her stejně jako jiná odvětví pocítují obrovské příležitosti v technologickém rozvoji. Mezi největší rizika spadají především neustálé změny v legislativě upravující provozování hazardních her.

Při pohledu na trendy se zdá, že míra hraní hazardních her v dospělé populaci současně roste. V případě strategické analýzy finančního sektoru, dle ukazatele poskytnutých úvěrů soukromému sektoru v České republice za období 2010–2020 (hodnoty roku 2020 jsou za první pololetí) lze konstatovat, že bankovní sektor má vzestupnou tendenci a každým rokem roste.

O sektoru finančních služeb, v rámci dílčího cíle analýzy trhu, po analýze konkurence bankovního sektoru ČR lze konstatovat, že k 31. 7. 2020 na území České republiky působilo celkem 59 měnových finančních institucí. Důležitou zjištěnou informací vyplývající z analýzy trhu loterijního průmyslu je, že značná většina kursového sázení probíhá v současnosti prostřednictvím internetu v on-line prostředí. K 1. 1. 2020 mělo povolení provozovat on-line kursové sázky celkem 8 společností (o 1 méně než rok předchozí). Online kursové sázky však provozovalo pouze 7 společností.

Po naplnění zmíněných dílčích cílů práce, je na místě zodpovědět výzkumné otázky, které s ohledem na provedenou rešerši a cíle práce byly stanoveny následovně:

VO1: Nabízí metoda komplexního hodnocení podniku zkonstruovaná na bázi Gated Recurrent NN lepší výsledky než metody konstruované pomocí diskrétní analýzy?

VO2: Je vhodné určit diskontní sazbu pro stanovení časové hodnoty obligací pomocí neuronových sítí?

VO3: Lze objektivně stanovit diskontní sazbu pro stanovení časové hodnoty obligací?

Zaměříme-li se na VO1, tedy na otázku, zda nabízí metoda komplexního hodnocení podniku zkonstruovaná na bázi Gated Recurrent NN lepší výsledky než metody konstruované pomocí diskrétní analýzy, je potřeba říci, že metoda GRL NN v případě hodnocení podniků, dosahovala v případě trénovací množiny dat výkonů od 77 procent do necelých 79 procent, což značí uspokojivý výkon. V případě testovací množiny dat hovoříme o výkonu pohybujícím se mezi 68 až necelými 74 procenty. Odpověď na VO2 je však jednoznačná. Ano, je vhodné určit diskontní sazbu pro stanovení časové hodnoty obligací pomocí neuronových sítí. To bylo prokázáno v kapitole 5.5 Diskontní sazba, kde za pomoci třech skupin umělých neuronových sítí byla stanovena diskontní míra v případě cenných papírů veřejně neobchodovatelných. Neuronové sítě zde byly primární metodou pro predikci spreadu a bezrizikové úrokové míry, kde výsledky posloužily ke stanovení diskontní míry. Výkon trénovacích a testovacích množin dat v případě využití třech skupin neuronových sítí (vícevrstvé perceptronové sítě, neuronové sítě s GRL vrstvou a neuronové sítě s LSTM vrstvou) pro predikci spreadu a risk free vybraných dluhopisů se pohybovat nad hranicí devadesátí procent. Což lze považovat za velmi vysoký

výkon sítí, což dokazuje i vhodnost použití metod založených na neuronových sítích jako metod pro určení diskontní sazby pro stanovení časové hodnoty obligací. Tímto se dostáváme ke třetí výzkumné otázce, která byla vázána na objektivní stanovení diskontní sazby pro stanovení časové hodnoty obligací., konkrétně na možnost objektivního stanovení diskontní sazby pro stanovení časové hodnoty obligací. Zde lze na základě výsledků výzkumné části říci, že je možné objektivně stanovit diskontní sazbu pro stanovení časové hodnoty obligací, jelikož tak bylo učiněno. Cena emise korunových dluhopisů GOS_1 byla predikována na 1 030 450 871,99 Kč, v případě SAF_1 byla cena emise korunových dluhopisů predikována na 173 232 120,15 Kč. Cena emise korunových dluhopisů SAF_2 byla predikována na 888 565 639,79 Kč, u SAF_3 253 653,01 Kč, v případě TPH_1 3 112 084 637,16 Kč a u TPHnet_1 byla predikována cena emise dluhopisů na 5 149 638 933,29 Kč

Výsledkem je tedy ocenění neveřejně obchodovaných dluhopisů, kde pro ocenění takovýchto cenných papírů není známa oficiální metodika, dle které by mohlo ocenění proběhnout. Výsledkem této práce je proto taktéž navržení metodiky, která by mohla posloužit při oceňování neveřejně obchodovaných cenných papírů, a to nejen v případě dluhopisů společností spadajících do loterijního nebo dopravního průmyslu, díky velké podobnosti ekonomických pochodů v obou odvětvích. Výsledkem práce je také detailní analýza loterijního průmyslu a nejvýznamnějších společností v něm působících.

Seznam použité literatury

- [1] ABAD, Pilar, Rodrigo FERRERAS a M.-Dolores ROBLES. Information opacity and corporate bond returns: The dynamics of split ratings. *Journal of International Financial Markets, Institutions and Money*. 2020, **68**. ISSN 1042-4431.
- [2] ABDIPOUR, Moslem, Mehdi YOUNESSI-HMAZEKHANLU, Seyyed Hamid Reza RAMAZANI a Amir Hassan OMIDI. Artificial neural networks and multiple linear regression as potential methods for modeling seed yield of safflower (*Carthamus tinctorius* L.). *Industrial Crops and Products*. 2019, **127**, 185-194. ISSN 0926-6690.
- [3] ABDOU, Hussein, Wael ABD ALLAH, James MULKEEN, Collins Gyakari NTIM a Yan WANG. Prediction of financial strength ratings using machine learning and conventional techniques. *Investment Management and Financial Innovation*. 2017, **14**(4), 194-211. ISSN 1812-9358.
- [4] ABINZANO, Isabel, Pilar CORREDOR a Beatriz MARTINEZ. Does family ownership always reduce default risk? *Accounting & Finance*. 2020. ISSN 0810-5391.
- [5] ADAROV, Amat. Financial cycles around the world. *International Journal of Finance & Economics*. 2020. ISSN 1076-9307.
- [6] ADEEL, Ahsan, Mandar GOGATE a Amir HUSSAIN. Contextual deep learning-based audio-visual switching for speech enhancement in real-world environments. *Information Fusion*. 2020, **59**, 163-170. ISSN 1566-2535.
- [7] ADLER, Terry R., Thomas G. PITZ a Jack MEREDITH. An analysis of risk sharing in strategic R&D and new product development projects. *International Journal of Project Management*. 2016, **34**(6), 914-922. ISSN 0263-7863.
- [8] AFFES, Zeineb a Rania HENTATI-KAFFEL. Forecast bankruptcy using a blend of clustering and MARS model: case of US banks. *Annals of Operations Research*. 2019, **281**(1-2), 27-64. ISSN 0254-5330.
- [9] AFONSO, António a Mina KAZEMI. Sovereign bond yield spreads spillovers in the Economic and Monetary Union. *International Journal of Finance & Economics*. 2020. ISSN 1076-9307.
- [10] AHMED, Anwer S. a Irfan SAFDAR. Dissecting stock price momentum using financial statement analysis. *Accounting & Finance*. 2018, **58**, 3-43. ISSN 0810-5391.
- [11] AKÇURA, M. Tolga a Zafer D. OZDEMIR. A Strategic Analysis of Multi-Channel Expert Services. *Journal of Management Information Systems*. 2017, **34**(1), 206-231. ISSN 0742-1222.

- [12] ALAKA, Hafiz A., Lukumon O. OYEDELE, Hakeem A. OWOLABI, Vikas KUMAR, Saheed O. AJAYI, Olugbenga O. AKINADE a Muhammad BILAL. Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Systems with Applications*. 2018, **94**, 164-184. ISSN 0957-4174.
- [13] ALAMINOS, David, Agustín DEL CASTILLO, Manuel Ángel FERNÁNDEZ a Giovanni PONTI. A Global Model for Bankruptcy Prediction. *PLOS ONE*. 2016, **11**(11). ISSN 1932-6203.
- [14] ALBAGLI, Elias, Luis CEBALLOS, Sebastian CLARO a Damian ROMERO. Channels of US monetary policy spillovers to international bond markets. *Journal of Financial Economics*. 2019, **134**(2), 447-473. ISSN 0304-405X.
- [15] ALBONICO, Alice a Patrizio TIRELLI. Financial crises and sudden stops: Was the European monetary union crisis different? *Economic Modelling*. 2020, **93**, 13-26. ISSN 0264-9993.
- [16] ALBUQUERQUE, Rui, Martin EICHENBAUM, Victor XI LUO a Sergio REBELO. Valuation Risk and Asset Pricing. *The Journal of Finance*. 2016, **71**(6), 2861-2904. ISSN 0022-1082.
- [17] ALTMAN, Edward I., Malgorzata IWANICZ-DROZDOWSKA, Erkki K. LAITINEN a Arto SUVAS. Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model. *Journal of International Financial Management & Accounting*. 2016, **28**(2), 131-171. ISSN 1467-646X.
- [18] ALTURA, Thomas G. When does Main Street prefer Wall Street? Legitimacy, status, and decision-making. *Management Decision*. 2020. ISSN 0025-1747.
- [19] AMAN, Asia. Are CDS Spreads Sensitive to the Term Structure of the Yield Curve? A Sector-Wise Analysis under Various Market Conditions. *Journal of Risk and Financial Management*. 2019, **12**(4). ISSN 1911-8074.
- [20] AMENC, Noël, Mikheil ESAKIA, Felix GOLTZ a Ben LUYTEN. Macroeconomic Risks in Equity Factor Investing. *The Journal of Portfolio Management*. 2019, **45**(6), 39-60. ISSN 0095-4918.
- [21] AMIN, Abu S., Pawan JAIN a Mahfuja MALIK. Stock market reaction to credit rating changes: new evidence*. *Asia-Pacific Journal of Accounting & Economics*. 2020, **27**(6), 667-684. ISSN 1608-1625.
- [22] ANTUNES, Francisco, Bernardete RIBEIRO a Francisco PEREIRA. Probabilistic modeling and visualization for bankruptcy prediction. *Applied Soft Computing*. 2017, **60**, 831-843. ISSN 1568-4946.

- [23] ARIF, Ahmed. Effects of securitization and covered bonds on bank stability. *Research in International Business and Finance*. 2020, **53**. ISSN 0275-5319.
- [24] ATMAZ, Adem a Suleyman BASAK. Option prices and costly short-selling. *Journal of Financial Economics*. 2019, **134**(1), 1-28. ISSN 0304-405X.
- [25] ATSALAKIS, George S. Using computational intelligence to forecast carbon prices. *Applied Soft Computing*. 2016, **43**, 107-116. ISSN 1568-4946.
- [26] AU YEUNG, Jay F. K., Zi-kai WEI, Kit Yan CHAN, Henry Y. K. LAU a Ka-Fai Cedric YIU. Jump detection in financial time series using machine learning algorithms. *Soft Computing*. 2020, **24**(3), 1789-1801. ISSN 1432-7643.
- [27] AVEN, Terje a Enrico ZIO. Globalization and global risk: How risk analysis needs to be enhanced to be effective in confronting current threats. *Reliability Engineering & System Safety*. 2021, **205**. ISSN 0951-8320.
- [28] AZAYITE, Fatima Zazayite a Said ACHCHCAB. Hybrid Discriminant Neural Networks for bankruptcy prediction and risk scoring. *Procedia Computer Science*. 2016, **83**, 670-674. ISSN 1877-0509.
- [29] BADOER, Dominique C., Cem DEMIROGLU a James CHRISTOPHER M. Ratings Quality and Borrowing Choice. *The Journal of Finance*. 2019, **74**(5), 2619-2665. ISSN 0022-1082.
- [30] BAN, Adrian Ioan, Olimpia Iuliana BAN, Victoria BOGDAN, Diana Claudia SABAU POPA a Delia TUSE. Performance Evaluation Model of Romanian Manufacturing Listed Companies by Fuzzy AHP and TOPSIS. *Technological and Economic Development of Economy*. 2020, **26**(4), 808-836. ISSN 2029-4913.
- [31] BANDARA, Kasun, Christoph BERGMEIR a Slawek SMYL. Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*. 2020, **140**. ISSN 0957-4174.
- [32] BARBOZA, Flavio, Herbert KIMURA a Edward ALTMAN. Machine learning models and bankruptcy prediction. *Expert Systems with Applications*. 2017, **83**, 405-417. ISSN 0957-4174.
- [33] BATTEN, Jonathan A., Karren Lee-Hwei KHAW a Martin R. YOUNG. Pricing convertible bonds. *Journal of Banking & Finance*. 2018, **92**, 216-236. ISSN 0378-4266.
- [34] BATTISTON, Stefano a Serafin MARTINEZ-JARAMILLO. Financial networks and stress testing: Challenges and new research avenues for systemic risk analysis and financial stability implications. *Journal of Financial Stability*. 2018, **35**, 6-16. ISSN 1572-3089.

- [35] BECKERS, Sander F. M., Jenny VAN DOORN a Peter C. VERHOEF. Good, better, engaged? The effect of company-initiated customer engagement behavior on shareholder value. *Journal of the Academy of Marketing Science*. 2018, **46**(3), 366-383. ISSN 0092-0703.
- [36] BENEVOLO, Clara, Lara PENCO a Teresina TORRE. Entrepreneurial decision-making for global strategies: a “heart–head” approach. *Management Decision*. 2020. ISSN 0025-1747.
- [37] BERGER, Theo. Forecasting Based on Decomposed Financial Return Series: A Wavelet Analysis. *Journal of Forecasting*. 2016, **35**(5), 419-433. ISSN 0277-6693.
- [38] BERNDT, Antje, Rohan DOUGLAS, Darrell DUFFIE a Mark FERGUSON. Corporate Credit Risk Premia. *Review of Finance*. 2018, **22**(2), 419-454. ISSN 1572-3097.
- [39] BILAL, Songsheng CHEN a Bushra KOMAL. Audit committee financial expertise and earnings quality: A meta-analysis. *Journal of Business Research*. 2018, **84**, 253-270. ISSN 0148-2963.
- [40] BIONDI, Yuri a Simone RIGHI. What does the financial market pricing do? A simulation analysis with a view to systemic volatility, exuberance and vagary. *Journal of Economic Interaction and Coordination*. 2016, **11**(2), 175-203. ISSN 1860-711X.
- [41] BOHANEC, Marko, Mirjana KLJAJIĆ BORŠTNAR a Marko ROBNIK-ŠIKONJA. Explaining machine learning models in sales predictions. *Expert Systems with Applications*. 2017, **71**, 416-428. ISSN 0957-4174.
- [42] BORGES, Lilian Adriana a Kim Hua TAN. Incorporating human factors into the AAMT selection: a framework and process. *International Journal of Production Research*. 2016, **55**(5), 1459-1470. ISSN 0020-7543.
- [43] BRAUN, Alexander. Pricing in the Primary Market for Cat Bonds: New Empirical Evidence. *Journal of Risk and Insurance*. 2016, **83**(4), 811-847. ISSN 0022-4367.
- [44] BRENNAN, David a Anthony BRABAZON. Corporate bond rating using neural networks. *International Conference on Artificial Intelligence/International Conference on Machine Learning, Models, Technologies and Applications*. 2004, 161-167. ISBN 978-193241533-9.
- [45] BRETSCHER, Lorenzo, Alex HSU a Andrea TAMONI. Fiscal policy driven bond risk premia. *Journal of Financial Economics*. 2020, **138**(1), 53-73. ISSN 0304-405X.
- [46] BROADSTOCK, David C. a Louis T.W. CHENG. Time-varying relation between black and green bond price benchmarks: Macroeconomic determinants for the first decade. *Finance Research Letters*. 2019, **29**, 17-22. ISSN 1544-6123.

- [47] BROTO, Carmen a Matías LAMAS. Is market liquidity less resilient after the financial crisis? Evidence for US Treasuries. *Economic Modelling*. 2020, **93**, 217-229. ISSN 0264-9993.
- [48] BRUNNERMEIER, Markus K, Sam LANGFIELD, Marco PAGANO, Ricardo REIS, Stijn VAN NIEUWERBURGH a Dimitri VAYANOS. ESBies: safety in the tranches. *Economic Policy*. 2017, **32**(90), 175-219. ISSN 0266-4658.
- [49] BRYCE, Cormac, Thorsten CHMURA, Rob WEBB, Joel STIEBALE a Carly CHEEVERS. Internally Reporting Risk in Financial Services: An Empirical Analysis. *Journal of Business Ethics*. 2019, **156**(2), 493-512. ISSN 0167-4544.
- [50] BRZEŃCZEK, Tomasz. Optimisation of product portfolio sales and their risk subject to product width and diversity. *Review of Managerial Science*. 2020, **14**(5), 1009-1027. ISSN 1863-6683.
- [51] BUEHLMAIER, Matthias M. M. a Toni M. WHITED. Are Financial Constraints Priced? Evidence from Textual Analysis. *The Review of Financial Studies*. 2018, **31**(7), 2693-2728. ISSN 0893-9454.
- [52] CABALEIRO-CERVIÑO, Goretti a Ana BURCHARTH. Licensing agreements as signals of innovation: When do they impact market value? *Technovation*. 2020, **98**. ISSN 0166-4972.
- [53] CAMPBELL, T. Colin, Doina C. CHICHERNEA a Alex PETKEVICH. Dissecting the bond profitability premium. *Journal of Financial Markets*. 2016, **27**, 102-131. ISSN 1386-4181.
- [54] CAO, Jiasheng a Jinghan WANG. Exploration of stock index change prediction model based on the combination of principal component analysis and artificial neural network. *Soft Computing*. 2020, **24**(11), 7851-7860. ISSN 1432-7643.
- [55] CARAYANNOPOULOS, Peter, Olga KANJ a M. Fabricio PEREZ. Pricing dynamics in the market for catastrophe bonds. *The Geneva Papers on Risk and Insurance - Issues and Practice*. 2020. ISSN 1018-5895.
- [56] CARDIN, Michel-Alexandre, Sizhe ZHANG a William J. NUTTALL. Strategic real option and flexibility analysis for nuclear power plants considering uncertainty in electricity demand and public acceptance. *Energy Economics*. 2017, **64**, 226-237. ISSN 0140-9883.
- [57] CENEDESE, Gino a Enrico MALLUCCI. What moves international stock and bond markets? *Journal of International Money and Finance*. 2016, **60**, 94-113. ISSN 0261-5606.

- [58] CEPPEL, Martin, Jan DVORSKY, Elena GREGOVA a Jaromir VRBKA. Business environment quality model in the SME segment. *TRANSFORMATIONS IN BUSINESS & ECONOMICS*. 2020, **19**(1), 262-283. ISSN 1648-4460.
- [59] ÇEPNI, Oğuzhan, Selçuk GÜL, Yavuz Selim HACIHASANOĞLU a Muhammed Hasan YILMAZ. Global uncertainties and portfolio flow dynamics of the BRICS countries. *Research in International Business and Finance*. 2020, **54**. ISSN 0275-5319.
- [60] COJOIANU, T. F., E. COLLINS, A. G. F. HOEPNER, D. MAGILL, T. O'NEILL a F. I. SCHNEIDER. In the Name of COVID-19: Is the ECB Fuelling the Climate Crisis? *Environmental and Resource Economics*. 2020. ISSN 0924-6460.
- [61] COLONNELLO, Stefano. The Real Effects of Universal Banking: Does Access to the Public Debt Market Matter? *Journal of Financial Services Research*. 2020. ISSN 0920-8550.
- [62] CORREA-JULLIAN, Camila, José Miguel CARDEMIL, Enrique LÓPEZ DROGUETT a Masoud BEHZAD. Assessment of Deep Learning techniques for Prognosis of solar thermal systems. *Renewable Energy*. 2020, **145**, 2178-2191. ISSN 0960-1481.
- [63] CRESPI, Fabrizio, Emanuela GIACOMINI a Danilo V. MASCIA. Bail-in rules and the pricing of Italian bank bonds. *European Financial Management*. 2019, **25**(5), 1321-1347. ISSN 1354-7798.
- [64] CUI, Li, Hing Kai CHAN, Yizhuo ZHOU, Jing DAI a Jia Jia LIM. Exploring critical factors of green business failure based on Grey-Decision Making Trial and Evaluation Laboratory (DEMATEL). *Journal of Business Research*. 2019, **98**, 450-461. ISSN 0148-2963.
- [65] CUNY, Christine, Omri EVEN-TOV a Edward M. WATTS. From Implicit to Explicit: The Impact of Disclosure Requirements on Hidden Transaction Costs. *Journal of Accounting Research*. 2021. ISSN 0021-8456.
- [66] ČESKÁ NÁRODNÍ BANKA. *ARAD systém časových řad* [online]. 2020b [vid. 16. října 2020]. Dostupné z: https://www.cnb.cz/cnb/STAT.ARADY_PKG.STROM_DRILL?p_strid=0&p_lang=CS
- [67] ČESKÁ NÁRODNÍ BANKA. *Měnová statistika VII/2020* [online]. 2020a [vid. 16. října 2020]. Dostupné z: https://www.cnb.cz/cs/statistika/menova_bankovni_stat/
- [68] ČESKÝ STATISTICKÝ ÚŘAD. *Průměrná roční míra inflace v letech 2000–2019** [online]. 2020 [vid. 14. října 2020]. Dostupné z: https://www.czso.cz/documents/10180/132433649/inflace_2000_2019.pdf

- [69] ČNB, 2020. Dlouhodobé úrokové sazby pro konvergenční účely (%) [online]. *Česká národní banka* [vid. 12. října 2020]. Dostupné z: https://www.cnb.cz/cnb/stat.ARADY_PKG.PARAMETRY_SESTAVY?p_strid=AEBA&p_sestuid=375&p_lang=CS
- [70] DAFERMOS, Yannis, Maria NIKOLAIDI a Giorgos GALANIS. Climate Change, Financial Stability and Monetary Policy. *Ecological Economics*. 2018, **152**, 219-234. ISSN 0921-8009.
- [71] DAMODARAN, Aswath. *Damodaran online* [online]. 2020 [vid. 8. října 2020]. Dostupné z: <http://pages.stern.nyu.edu/~adamodar/>
- [72] DE SÉVERAC, Béatrice a José S. DA FONSECA. Relative pricing of French Treasury inflation-linked and nominal bonds: an empirical approach using arbitrage strategies. *Portuguese Economic Journal*. 2020. ISSN 1617-982X.
- [73] DE, Gejirifu, Zhongfu TAN, Menglu LI, Lilin HUANG, Qiang WANG a Huanhuan LI. A credit risk evaluation based on intuitionistic fuzzy set theory for the sustainable development of electricity retailing companies in China. *Energy Science & Engineering*. 2019, **7**(6), 2825-2841. ISSN 2050-0505.
- [74] DEBELLE, Guy. The Reserve Bank of Australia's policy actions and balance sheet. *Economic Analysis and Policy*. 2020, **68**, 285-295. ISSN 0313-5926.
- [75] DEELSTRA, Griselda, Pierre DEVOLDER, Kossi GNAMEHO a Peter HIEBER. Valuation of Hybrid Financial and Actuarial Products in Life Insurance by a Novel Three-step Method. *ASTIN Bulletin*. 2020, **50**(3), 709-742. ISSN 0515-0361.
- [76] DEMIREL, Mustafa a Gazanfer UNAL. Applying multivariate-fractionally integrated volatility analysis on emerging market bond portfolios. *Financial Innovation*. 2020, **6**(1). ISSN 2199-4730.
- [77] DEMIRER, Rıza, Román FERRER a Syed Jawad Hussain SHAHZAD. Oil price shocks, global financial markets and their connectedness. *Energy Economics*. 2020, **88**. ISSN 0140-9883.
- [78] DEMPSTER, M. A. H. Bond flotation with exotic commodity collateral. *Quantitative Finance*. 2020, **20**(12), 1903-1925. ISSN 1469-7688.
- [79] DEVEREUX, Michael B., Makoto SAITO a Changhua YU. International capital flows, portfolio composition, and the stability of external imbalances. *Journal of International Economics*. 2020, **127**. ISSN 0022-1996.

- [80] DEWACHTER, Hans, Leonardo IANIA, Wolfgang LEMKE a Marco LYRIO. A macro-financial analysis of the corporate bond market. *Empirical Economics*. 2019, **57**(6), 1911-1933. ISSN 0377-7332.
- [81] DIAZ RUIZ, Carlos A., Jonathan J. BAKER, Katy MASON a Kieran TIERNEY. Market-scanning and market-shaping: why are firms blindsided by market-shaping acts? *Journal of Business & Industrial Marketing*. 2020, **35**(9), 1389-1401. ISSN 0885-8624.
- [82] DING, Guangyu a Liangxi QIN. Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*. 2020, 11, 1307-1317. ISSN 1868-8071.
- [83] DING, Kailin, Zhenyu CUI a Yongjin WANG. A Markov chain approximation scheme for option pricing under skew diffusions. *Quantitative Finance*. 2020. 1-20. ISSN 1469-7688.
- [84] DONG, Juan, Lyudmila KOROBENKO a Deniz A. SEZER. A variation of Merton's corporate bond valuation model for firms with illiquid but observable assets. *Quantitative Finance*. 2019, **20**(3), 483-497. ISSN 1469-7696.
- [85] DU, Shengdong, Tianrui LI, Yan YANG a Shi-Jinn HORNG. Multivariate time series forecasting via attention-based encoder-decoder framework. *Neurocomputing*. 2020, **388**, 269-279. ISSN 0925-2312.
- [86] DU, Wenxin a Jesse SCHREGER. Local Currency Sovereign Risk. *The Journal of Finance*. 2016, **71**(3), 1027-1070. ISSN 0022-1082.
- [87] DUFRÉNOT, Gilles, Jean-Baptiste GOSSÉ a Caroline CLERC. Risk sharing in Europe: new empirical evidence on the capital markets channel. *Applied Economics*. 2020. 1-15. ISSN 0003-6846.
- [88] DUNBAR, Kwamie a Jing JIANG. What do movements in financial traders' net long positions reveal about aggregate stock returns? *The North American Journal of Economics and Finance*. 2020, **51**. ISSN 1062-9408.
- [89] DUONG, Thanh Long, Phuong Duy NGUYEN, Van-Duc PHAN, Dieu Ngoc VO a Thang Trung NGUYEN. Optimal Load Dispatch in Competitive Electricity Market by Using Different Models of Hopfield Lagrange Network. *Energies*. 2019, **12**(15). ISSN 1996-1073.
- [90] ECER, Fatih. Third-Party Logistics (3PLS) Provider Selection via Fuzzy AHP and EDAS Integrated Model. *Technological and Economic Development of Economy*. 2018, **24**(2), 615-634. ISSN 2029-4913.

- [91] EHRMANN, Michael a Marcel FRATZSCHER. Euro area government bonds – Fragmentation and contagion during the sovereign debt crisis. *Journal of International Money and Finance*. 2017, **70**, 26-44. ISSN 0261-5606.
- [92] EL-HAJ, Mahmoud, Paul RAYSON, Martin WALKER, Steven YOUNG a Vasiliki SIMAKI. In search of meaning: Lessons, resources and next steps for computational analysis of financial discourse. *Journal of Business Finance & Accounting*. 2019, **46**(3-4), 265-306. ISSN 0306-686X.
- [93] ENGLERT, Mario R., Christopher KOCH a Jens WÜSTEMANN. The Effects of Financial Crisis on the Organizational Reputation of Banks: An Empirical Analysis of Newspaper Articles. *Business & Society*. 2020, **59**(8), 1519-1553. ISSN 0007-6503.
- [94] ENTROP, Oliver, Richard SCHIEMERT a Marco WILKENS. Valuation differences between credit default swap and corporate bond markets. *Journal of Credit Risk*. 2013, **9**(4), 3-46. ISSN 1755-9723.
- [95] ESCRIG-OLMEDO, Elena, María Jesús MUÑOZ-TORRES, María Ángeles FERNÁNDEZ-IZQUIERDO a Juana María RIVERA-LIRIO. Measuring Corporate Environmental Performance: A Methodology for Sustainable Development. *Business Strategy and the Environment*. 2017, **26**(2), 142-162. ISSN 0964-4733.
- [96] ESER, Fabian a Bernd SCHWAAB. Evaluating the impact of unconventional monetary policy measures: Empirical evidence from the ECB's Securities Markets Programme. *Journal of Financial Economics*. 2016, **119**(1), 147-167. ISSN 0304-405X.
- [97] FAHAD, Nafiz, Nelson MA a Tom SCOTT. The consequences of discount rate selection for defined benefit liabilities. *Journal of Contemporary Accounting & Economics*. 2020, **16**(1). ISSN 1815-5669.
- [98] FAIAS, José Afonso a José GUEDES. The diffusion of complex securities: The case of CAT bonds. *Insurance: Mathematics and Economics*. 2020, **90**, 46-57. ISSN 0167-6687.
- [99] FALCÓ, A., LI. NAVARRO a C. VÁZQUEZ. A direct LU solver for pricing American bond options under Hull–White model. *Journal of Computational and Applied Mathematics*. 2017, **309**, 442-455. ISSN 0377-0427.
- [100] FAN, Sheng. The Analysis of Corporate Bond Valuation under an Infinite Dimensional Compound Poisson Framework. *Abstract and Applied Analysis*. 2014. ISSN 1085-3375.
- [101] FANG-KLINGLER, Jieyan. Impact of Readability on Corporate Bond Market. *Journal of Risk and Financial Management*. 2019, **12**(4). ISSN 1911-8074.
- [102] FARZAD, Amir, Hoda MASHAYEKHI a Hamid HASSANPOUR. A comparative performance analysis of different activation functions in LSTM networks for

- classification. *Neural Computing and Applications*. 2019, **31**(7), 2507-2521. ISSN 0941-0643.
- [103] FATIMA, Samar, Kevin C. DESOUZA a Gregory S. DAWSON. National strategic artificial intelligence plans: A multi-dimensional analysis. *Economic Analysis and Policy*. 2020, **67**, 178-194. ISSN 0313-5926.
- [104] FATMA, Mobin a Imran KHAN. An investigation of consumer evaluation of authenticity of their company's CSR engagement. *Total Quality Management & Business Excellence*. 2020. 1-18. ISSN 1478-3363.
- [105] FERGUSSON, Kevin. Less-Expensive Valuation and Reserving of Long-Dated Variable Annuities When Interest Rates and Mortality Rates Are Stochastic. *ASTIN Bulletin*. 2020, **50**(2), 381-417. ISSN 0515-0361.
- [106] FILATOTCHEV, Igor, Annette POULSEN a R. Greg BELL. Corporate governance of a multinational enterprise: Firm, industry and institutional perspectives. *Journal of Corporate Finance*. 2019, **57**, 1-8. ISSN 0929-1199.
- [107] FILIPOVIĆ, Damir, Martin LARSSON a Anders B. TROLLE. Linear-Rational Term Structure Models. *The Journal of Finance*. 2017, **72**(2), 655-704. ISSN 0022-1082.
- [108] FONG, Iat Hang, Tengyue LI, Simon FONG, Raymond K. WONG a Antonio J. TALLÓN-BALLESTEROS. Predicting concentration levels of air pollutants by transfer learning and recurrent neural network. *Knowledge-Based Systems*. 2020, **192**. ISSN 0950-7051.
- [109] FONTANA, Alessandro a Martin SCHEICHER. An analysis of euro area sovereign CDS and their relation with government bonds. *Journal of Banking & Finance*. 2016, **62**, 126-140. ISSN 0378-4266.
- [110] FREY, Rüdiger, Kevin KURT a Camilla DAMIAN. How safe are european safe bonds? An analysis from the perspective of modern credit risk models. *Journal of Banking & Finance*. 2020, **119**. ISSN 0378-4266.
- [111] FU, Shihua, Haitao LI a Guodong ZHAO. Modelling and strategy optimisation for a kind of networked evolutionary games with memories under the bankruptcy mechanism. *International Journal of Control*. 2017, **91**(5), 1104-1117. ISSN 0020-7179.
- [112] FYLIUK, Halyna, Ihor HONCHAR a Vasylyna KOLOSHA. The Interrelation between Economic Growth and National Economic Competitiveness: The Case of Ukraine. *Journal of Competitiveness*. 2019, **11**(3), 53-69. ISSN 1804-171X.
- [113] GAVUROVA, Beata, Miroslava PACKOVA, Maria MISANKOVA a Lubos SMRCKA. Predictive Potential and Risks of Selected Bankruptcy Prediction Models in

- the Slovak Business Environment. *Journal of Business Economics and Management*. 2017, **18**(6), 1156-1173. ISSN 1611-1699.
- [114] GEYER-KLINGEBERG, Jerome, Markus HANG a Andreas W. RATHGEBER. What drives financial hedging? A meta-regression analysis of corporate hedging determinants. *International Review of Financial Analysis*. 2019, **61**, 203-221. ISSN 1057-5219.
- [115] GOLDFAYN-FRANK, Olga a Johannes WOHLFART. Expectation formation in a new environment: Evidence from the German reunification. *Journal of Monetary Economics*. 2020, **115**, 301-320. ISSN 0304-3932.
- [116] GOLDSTEIN, Itay, Hao JIANG a David T. NG. Investor flows and fragility in corporate bond funds. *Journal of Financial Economics*. 2017, **126**(3), 592-613. ISSN 0304-405X.
- [117] GÓMEZ-VALLE, Lourdes, Miguel Ángel LÓPEZ-MARCOS a Julia MARTÍNEZ-RODRÍGUEZ. Incorporating boundary conditions in a stochastic volatility model for the numerical approximation of bond prices. *Mathematical Methods in the Applied Sciences*. 2020, **43**(14), 7993-8005. ISSN 0170-4214.
- [118] GONG, Xiao-Li, Xi-Hua LIU, Xiong XIONG a Wei ZHANG. Financial systemic risk measurement based on causal network connectedness analysis. *International Review of Economics & Finance*. 2019, **64**, 290-307. ISSN 1059-0560.
- [119] GÖTZE, Tobias a Marc GÜRTLER. Hard markets, hard times: On the inefficiency of the CAT bond market. *Journal of Corporate Finance*. 2020, **62**. ISSN 0929-1199.
- [120] GÖTZE, Tobias, Marc GÜRTLER a Eileen WITOWSKI. Improving CAT bond pricing models via machine learning. *Journal of Asset Management*. 2020, **21**(5), 428-446. ISSN 1470-8272.
- [121] GREGORI, Wildmer Daniel a Agnese SACCHI. Has the Grexit news affected euro area financial markets? *The North American Journal of Economics and Finance*. 2019, **49**, 71-84. ISSN 1062-9408.
- [122] GRIJALVA, Therese C., Jayson L. LUSK, Rong RONG a W. Douglass SHAW. Convex Time Budgets and Individual Discount Rates in the Long Run. *Environmental and Resource Economics*. 2018, **71**(1), 259-277. ISSN 0924-6460.
- [123] GRYBAITĖ, Virginija a Jelena STANKEVIČIENĖ. An empirical analysis of factors affecting sharing economy growth. *Oeconomia Copernicana*. 2018, **9**(4), 635-654. ISSN 2353-1827.

- [124] GUBAREVA, Mariya a Benjamin KEDDAD. Emerging markets financial sector debt: A Markov-switching study of interest rate sensitivity. *International Journal of Finance & Economics*. 2020. 1-13 ISSN 1076-9307.
- [125] GULATI, Mitu a Ugo PANIZZA. The Hausmann–Gorky Effect. *Journal of Business Ethics*. 2020, **166**(1), 175-195. ISSN 0167-4544.
- [126] GULSOY, Nihan a Sinem KULLUK. A data mining application in credit scoring processes of small and medium enterprises commercial corporate customers. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. 2018, **9**(3). ISSN 1942-4787.
- [127] HAAKER, Timber, Harry BOUWMAN, Wil JANSSEN a Mark DE REUVER. Business model stress testing: A practical approach to test the robustness of a business model. *Futures*. 2017, **89**, 14-25. ISSN 0016-3287.
- [128] HADIAN, Azadeh a Cahit ADAOGLU. The effects of financial and operational hedging on company value: The case of Malaysian multinationals. *Journal of Asian Economics*. 2020, **70**. ISSN 1049-0078.
- [129] HALKOS, George, Shunsuke MANAGI a Kyriaki TSILIKA. Ranking Countries and Geographical Regions in the International Green Bond Transfer Network: A Computational Weighted Network Approach. *Computational Economics*. 2020. ISSN 0927-7099.
- [130] HAMPL, Filip. A statistical analysis of the financial performance of organic and conventional farms in the Czech Republic with respect to their size. *Agricultural Economics (Zemědělská ekonomika)*. 2020, **66**(1), 1-9. ISSN 0139-570X.
- [131] HANG, Markus, Jerome GEYER-KLINGEBERG a Andreas W. RATHGEBER. It is merely a matter of time: A meta-analysis of the causality between environmental performance and financial performance. *Business Strategy and the Environment*. 2019, **28**(2), 257-273. ISSN 0964-4733.
- [132] HANINE, Mohamed, Omar BOUTKHOUM, Tarik AGOUTI a Abdessadek TIKNIOUINE. A new integrated methodology using modified Delphi-fuzzy AHP-PROMETHEE for Geospatial Business Intelligence selection. *Information Systems and e-Business Management*. 2017, **15**(4), 897-925. ISSN 1617-9846.
- [133] HARDINATA, Lingga, Budi WARSITO a SUPARTI. Bankruptcy prediction based on financial ratios using Jordan Recurrent Neural Networks: a case study in Polish companies. *Journal of Physics: Conference Series*. 2018, **1025**. ISSN 1742-6588.

- [134] HASANHODZIC, Jasmina a Laurence J. KOTLIKOFF. Valuing Government Obligations When Markets Are Incomplete. *Journal of Money, Credit and Banking*. 2019, **51**(7), 1815-1855. ISSN 0022-2879.
- [135] HAUSMANN, Ricardo. *The Hunger Bonds* [online]. 2017 [vid. 20. září 2020]. Dostupné z: <https://www.project-syndicate.org/commentary/maduro-venezuela-hunger-bonds-by-ricardo-hausmann-2017-05?barrier=accesspaylog>
- [136] HAWRYSZ, Liliana, Jolanta MAJ. Identification of Stakeholders of Public Interest Organisations. *Sustainability*. 2017, **9**(9). ISSN 2071-1050.
- [137] HEIDENREICH, Sven, Patrick SPIETH a Martin PETSCHNIG. Ready, Steady, Green: Examining the Effectiveness of External Policies to Enhance the Adoption of Eco-Friendly Innovations. *Journal of Product Innovation Management*. 2017, **34**(3), 343-359. ISSN 0737-6782.
- [138] HENDERSHOTT, Terrence, Dan LI, Dmitry LIVDAN a Norman SCHÜRHOFF. Relationship Trading in Over-the-Counter Markets. *The Journal of Finance*. 2020, **75**(2), 683-734. ISSN 0022-1082.
- [139] HONG, Jichao, Zhenpo WANG, Wen CHEN a Yongtao YAO. Synchronous multi-parameter prediction of battery systems on electric vehicles using long short-term memory networks. *Applied Energy*. 2019, **254**. ISSN 0306-2619.
- [140] HORAK, Jakub, Jaromir VRBKA a Petr SULER. Support Vector Machine Methods and Artificial Neural Networks Used for the Development of Bankruptcy Prediction Models and their Comparison. *Journal of Risk and Financial Management*. 2020, **13**(3). ISSN 1911-8074.
- [141] HORAK, Jakub, Tomas KRULICKY, Zuzana ROWLAND a Veronika MACHOVA. Creating a Comprehensive Method for the Evaluation of a Company. *Sustainability*. 2020, **12**(21). ISSN 2071-1050.
- [142] HSU, Yu-Feng a Wei-Po LEE. Evaluation of the going-concern status for companies: An ensemble framework-based model. *Journal of Forecasting*. 2020, **39**(4), 687-706. ISSN 0277-6693.
- [143] HU, Hui a Milind SATHYE. Predicting Financial Distress in the Hong Kong Growth Enterprises Market from the Perspective of Financial Sustainability. *Sustainability*. 2015, **7**(2), 1186-1200. ISSN 2071-1050.
- [144] HU, May a Jason PARK. Valuation of collateralized debt obligations: An equilibrium model. *Economic Modelling*. 2019, **82**, 119-135. ISSN 0264-9993.

- [145] HU, Xiaolu, Haozhi HUANG, Jing SHI a Hua WANG. CRA Reputation and Bond Yield: Evidence from the Chinese Bond Market. *Asia-Pacific Journal of Financial Studies*. 2019, **48**(2), 185-209. ISSN 2041-9945.
- [146] HU, Yi-Chung. A multivariate grey prediction model with grey relational analysis for bankruptcy prediction problems. *Soft Computing*. 2020, **24**(6), 4259-4268. ISSN 1432-7643.
- [147] HUANG, Zehao, Tianpei JIANG a Zhenzhen WANG. On a multiple credit rating migration model with stochastic interest rate. *Mathematical Methods in the Applied Sciences*. 2020, **43**(12), 7106-7134. ISSN 0170-4214.
- [148] HUBER, Jakob, Sebastian MÜLLER, Moritz FLEISCHMANN a Heiner STUCKENSCHMIDT. A data-driven newsvendor problem: From data to decision. *European Journal of Operational Research*. 2019, **278**(3), 904-915. ISSN 0377-2217.
- [149] CHABOT, Miia, Jean-Louis BERTRAND a Eric THOREZ. Resilience of United Kingdom financial institutions to major uncertainty: A network analysis related to the Credit Default Swaps market. *Journal of Business Research*. 2019, **101**, 70-82. ISSN 0148-2963.
- [150] CHAN, Samuel W.K. a Mickey W.C. CHONG. Sentiment analysis in financial texts. *Decision Support Systems*. 2017, **94**, 53-64. ISSN 0167-9236.
- [151] CHANG, Kai, Yan Ling FENG, Wang LIU, Ning LU a Sheng Ze LI. The impacts of liquidity measures and credit rating on corporate bond yield spreads: evidence from China's green bond market. *Applied Economics Letters*. 2020. 1-12. ISSN 1350-4851.
- [152] CHANG, Zihan, Yang ZHANG a Wenbo CHEN. Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform. *Energy*. 2019, **187**. ISSN 0360-5442.
- [153] CHATTERJEE, Joyjit a Nina DETHLEFS. Deep learning with knowledge transfer for explainable anomaly prediction in wind turbines. *Wind Energy*. 2020, **23**(8), 1693-1710. ISSN 1095-4244.
- [154] CHEAH, Jeremy Eng-Tuck, Di LUO, Zhuang ZHANG a Ming-Chien SUNG. Predictability of bitcoin returns. *The European Journal of Finance*. 2020. 1-20. ISSN 1351-847X.
- [155] CHEBEIR, Jorge, Hope ASALA, Vidhyadhar MANEE, Ipsita GUPTA a Jose A. ROMAGNOLI. Data driven techno-economic framework for the development of shale

- gas resources. *Journal of Natural Gas Science and Engineering*. 2019, **72**. ISSN 1875-5100.
- [156] CHEN, Fang, Jing-Zhi HUANG, Zhenzhen SUN a Tong YU. Why do firms issue guaranteed bonds? *Journal of Banking & Finance*. 2020, **119**. ISSN 0378-4266.
- [157] CHEN, Hong Long. Development of a Stable Corporate Bankruptcy Classification Model: Evidence From Taiwan. *International Journal of Economic Sciences*. 2018, **7**(1), 16-38. ISSN 1804-9796.
- [158] CHEN, Hui, Rui CUI, Zhiguo HE a Konstantin MILBRADT. Quantifying Liquidity and Default Risks of Corporate Bonds over the Business Cycle. *The Review of Financial Studies*. 2018, **31**(3), 852-897. ISSN 0893-9454.
- [159] CHEUNG, Zeerim, Eero AALTO a Pasi NEVALAINEN. Institutional Logics and the Internationalization of a State-Owned Enterprise: Evaluation of International Venture Opportunities by Telecom Finland 1987–1998. *Journal of World Business*. 2020, **55**(6). ISSN 1090-9516.
- [160] CHRISTENSEN, Bent Jesper a Michel VAN DER WEL. An asset pricing approach to testing general term structure models. *Journal of Financial Economics*. 2019, **134**(1), 165-191. ISSN 0304-405X.
- [161] CHUNG, Ji-Yeong, Dong-Hyun AHN, In-Seok BAEK a Kyu Ho KANG. An Empirical Investigation on Funding Liquidity and Market Liquidity*. *Review of Finance*. 2018, **22**(3), 1213-1247. ISSN 1572-3097.
- [162] IMMEL, Moritz, Britta HACHENBERG, Florian KIESEL a Dirk SCHIERECK. Green bonds: shades of green and brown. *Journal of Asset Management*. ISSN 1470-8272.
- [163] INOBUCHI, Masahiro. The impact of foreign capital flows on long-term interest rates in emerging and advanced economies. *Review of International Economics*. ISSN 0965-7576.
- [164] IVANOVA, Eva a Martin CEPEL. The Impact of Innovation Performance on the Competitiveness of the Visegrad 4 Countries. *Journal of Competitiveness*. 2018, **10**(1), 54-72. ISSN 1804-171X.
- [165] JAGANNATHAN, Ravi, José LIBERTI, Binying LIU a Iwan MEIER. A Firm's Cost of Capital. *Annual Review of Financial Economics*. 2017, **9**(1), 259-282. ISSN 1941-1367.
- [166] JAIN, Sanjay. Time Inconsistency and Product Design: A Strategic Analysis of Feature Creep. *Marketing Science*. 2019, **38**(5), 835-851. ISSN 0732-2399.

- [167] JAMES, Scott, Stefano PAGLIARI a Kevin L. YOUNG. The internationalization of European financial networks: a quantitative text analysis of EU consultation responses. *Review of International Political Economy*. 2020. 1-28. ISSN 0969-2290.
- [168] JANSSEN, Catherine, Joëlle VANHAMME a Sina LEBLANC. Should luxury brands say it out loud? Brand conspicuousness and consumer perceptions of responsible luxury. *Journal of Business Research*. 2017, **77**, 167-174. ISSN 0148-2963.
- [169] JIRASAKULDECH, Benjamas a Riza EMEKTER. Empirical Analysis of Investors' Herding Behaviours during the Market Structural Changes and Crisis Events: Evidence from Thailand. *Global Economic Review*. 2020. 1-30. ISSN 1226-508X.
- [170] JOPP, Tobias A. The determinants of sovereign bond liquidity during WWI. *Economics Letters*. 2020, **196**. ISSN 0165-1765.
- [171] JØRGENSEN, Peter Løchte. An analysis of the Solvency II regulatory framework's Smith-Wilson model for the term structure of risk-free interest rates. *Journal of Banking & Finance*. 2018, **97**, 219-237. ISSN 0378-4266.
- [172] KAREVAN, Zahra a Johan A.K. SUYKENS. Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*. 2020, **125**, 1-9. ISSN 0893-6080.
- [173] KARIM, Fazle, Somshubra MAJUMDAR, Houshang DARABI a Samuel HARFORD. Multivariate LSTM-FCNs for time series classification. *Neural Networks*. 2019, **116**, 237-245. ISSN 0893-6080.
- [174] KENOURGIOS, Dimitris, Emmanouela DRAGONAKI a Dimitrios DIMITRIOU. ECB's unconventional monetary policy and cross-financial-market correlation dynamics. *The North American Journal of Economics and Finance*. 2019, **50**. ISSN 1062-9408.
- [175] KESHAVARZ GHORABAEI, Mehdi, Maghsoud AMIRI, Edmundas Kazimieras ZAVADSKAS, Reyhaneh HOOSHMAND a Jurgita ANTUCHEVIČIENĖ. Fuzzy Extension of the Codas Method for Multi-Criteria Market Segment Evaluation. *Journal of Business Economics and Management*. 2017, **18**(1), 1-19. ISSN 1611-1699.
- [176] KHABAZIAN, Aein a Jiming PENG. Vulnerability Analysis of the Financial Network. *Management Science*. 2019, **65**(7), 3302-3321. ISSN 0025-1909.
- [177] KHALIL, Samer, Sattar MANSI, Mohamad MAZBOUDI a Andrew (Jianzhong) ZHANG. Information asymmetry and the wealth appropriation effect in the bond market: Evidence from late disclosures. *Journal of Business Research*. 2019, **95**, 49-61. ISSN 0148-2963.

- [178] KHASHEI, Mehdi a Zahra HAJIRAHIMI. Performance evaluation of series and parallel strategies for financial time series forecasting. *Financial Innovation*. 2017, **3**(1). ISSN 2199-4730.
- [179] KIM, A., Y. YANG, S. LESSMANN, T. MA, M.-C. SUNG a J.E.V. JOHNSON. Can deep learning predict risky retail investors? A case study in financial risk behavior forecasting. *European Journal of Operational Research*. 2020, **283**(1), 217-234. ISSN 0377-2217.
- [180] KIM, Eunji, Jehyuk LEE, Hunsik SHIN, Hoseong YANG, Sungzoon CHO, Seung-Kwan NAM, Youngmi SONG, Jeong-A YOON, Jong-Li KIM. Champion-challenger analysis for credit card fraud detection: Hybrid ensemble and deep learning. *Expert Systems with Applications*. 2019, **128**, 214-224. ISSN 0957-4174.
- [181] KINGMA, Diederik P. a Jimmy Lei BA, 2015. ADAM: A method for stochastic optimization. In: Y. BENGIO and Y. LECUN, eds. *3rd International Conference for Learning Representations*. San Diego, s. 1-15.
- [182] KLADAKIS, George, Lei CHEN a Sotirios K. BELLOS. Bank asset and informational quality. *Journal of International Financial Markets, Institutions and Money*. 2020, **69**. ISSN 1042-4431.
- [183] KLIESTIK, Tomas, Katarina VALASKOVA, George LAZAROIU, Maria KOVACOVA a Jaromir VRBKA. Remaining Financially Healthy and Competitive: The Role of Financial Predictors. *Journal of Competitiveness*. 2020, **12**(1), 74-92. ISSN 1804-171X.
- [184] KOMMEL, Karl Arnold, Martin SILLASOO a Ágnes LUBLÓY. Could crowdsourced financial analysis replace the equity research by investment banks? *Finance Research Letters*. 2019, **29**, 280-284. ISSN 1544-6123.
- [185] KOU, Gang, Xiangrui CHAO, Yi PENG, Fawaz E. ALSAADI a Enrique HERRERA-VIDEVA. Machine Learning Methods for Systemic Risk Analysis in Financial Sectors. *Technological and Economic Development of Economy*. 2019, **25**(5), 716-742. ISSN 2029-4913.
- [186] KOUDJONOU, Koffi Mawuna a Minakhi ROUT. A stateless deep learning framework to predict net asset value. *Neural Computing and Applications*. 2020, **32**(14), 1-19. ISSN 0941-0643.
- [187] KOUVELIS, Panos, Zhan PANG a Qing DING. Integrated Commodity Inventory Management and Financial Hedging: A Dynamic Mean-Variance Analysis. *Production and Operations Management*. 2018, **27**(6), 1052-1073. ISSN 1059-1478.

- [188] KOZAK, Serhiy a Shrihari SANTOSH. Why do discount rates vary? *Journal of Financial Economics*. 2020, **137**(3), 740-751. ISSN 0304-405X.
- [189] KRAJŇÁK, Michal. Financial Statement according to National or International Financial Reporting Standards? A Decision Analysis Case Study from the Czech Republic at Industrial Companies. *Engineering Economics*. 2020, **31**(3), 270-281. ISSN 2029-5839.
- [190] KUBĚNKA, Michal a Renáta MYŠKOVÁ. Obvious and Hidden Features of Corporate Default in Bankruptcy Models. *Journal of Business Economics and Management*. 2019, **20**(2), 368-383. ISSN 1611-1699.
- [191] KUBÍČKOVÁ, Dana. Comparison of the financial stability assesment of the smes in the segment of manufacturing industry based on ohlson's model, model Z-score and IN05. *13th International Scientific Conference on Hradec Economic Days*. 2015, **5**(2), 70-83.
- [192] KUMAR, Vikram. Liquidity shocks: A new solution to the forward premium puzzle. *Economic Modelling*. 2020, **91**, 445-454. ISSN 0264-9993.
- [193] KUMBURE, Mahinda Mailagaha, Anssi TARKIAINEN, Pasi LUUKKA, Jan STOKLASA a Ari JANTUNEN. Relation between managerial cognition and industrial performance: An assessment with strategic cognitive maps using fuzzy-set qualitative comparative analysis. *Journal of Business Research*. 2020, **114**, 160-172. ISSN 0148-2963.
- [194] KUO, Kuo-Cheng, Qian Long KWEH, Irene Wei Kiong TING a Noor Azlinna AZIZAN. Dynamic network performance evaluation of general insurance companies: an insight into risk management committee structure. *Total Quality Management & Business Excellence*. 2015, **28**(5-6), 542-558. ISSN 1478-3363.
- [195] KURTZMAN, Robert a David ZEKE. Misallocation costs of digging deeper into the central bank toolkit. *Review of Economic Dynamics*. 2020, **38**, 94-126. ISSN 1094-2025.
- [196] LAAKSONEN, Ola a Mirva PELTONIEMI. The Essence of Dynamic Capabilities and their Measurement. *International Journal of Management Reviews*. 2018, **20**(2), 184-205. ISSN 1460-8545.
- [197] LAGHI, Enrico, Michele DI MARCANTONIO, Valentina CILLO a Niccolo PAOLONI. The relational side of intellectual capital: an empirical study on brand value evaluation and financial performance. *Journal of Intellectual Capital*. 2020. ISSN 1469-1930.
- [198] LANDSKRONER, Yoram a Alon RAVIV. The valuation of inflation-indexed and FX convertible bonds. *Journal of Futures Markets*. 2008, **28**(7), 634-655.

- [199] LARKIN, A., C. HOLOHAN a C. MCLACHLAN. Embracing context and complexity to address environmental challenges in the water-energy-food nexus. *Futures*. 2020, **123**. ISSN 0016-3287.
- [200] LEE, Chien-Chiang, Chih-Wei WANG a Shan-Ju HO. Family Management and Corporate Bond Spreads: Do Foreign and Government Ownerships Matter? *Emerging Markets Finance and Trade*. 2020. 1-13. ISSN 1540-496X.
- [201] LEE, Jong Moo, Yong-Kuk JEONG a Jong Hun WOO. Development of an evaluation framework of production planning for the shipbuilding industry. *International Journal of Computer Integrated Manufacturing*. 2018, **31**(9), 831-847. ISSN 0951-192X.
- [202] LEI, Zhizhong. Research and analysis of deep learning algorithms for investment decision support model in electronic commerce. *Electronic Commerce Research*. 2020, **20**(2), 275-295. ISSN 1389-5753.
- [203] LEWIS, Craig a Steven YOUNG. Fad or future? Automated analysis of financial text and its implications for corporate reporting. *Accounting and Business Research*. 2019, **49**(5), 587-615. ISSN 0001-4788.
- [204] LI, Chengjiang, Michael NEGNEVITSKY a Xiaolin WANG. Prospective assessment of methanol vehicles in China using FANP-SWOT analysis. *Transport Policy*. 2020, **96**, 60-75. ISSN 0967-070X.
- [205] LI, Jinying, Fan WU, Jinchao LI a Yunqi ZHAO. Research on Risk Evaluation of Transnational Power Networking Projects Based on the Matter-Element Extension Theory and Granular Computing. *Energies*. 2017, **10**(10). ISSN 1996-1073.
- [206] LI, P., Y. HAN, S. LIN a T. QIAO. Chinese write-down bonds: issuance and bank capital structure. *Quantitative Finance*. 2020, **20**(12), 2055-2065. ISSN 1469-7688.
- [207] LI, Peng a Zhaozhang REN. Impact of liquidity risk on defaultable bonds valuation. Fifth Wuhan International Conference on E-Business, Vols 1-3: Integration and Innovation through Measurement and Management. 2006, 1513-1519.
- [208] LI, Weijiang, Fang QI, Ming TANG a Zhengtao YU. Bidirectional LSTM with self-attention mechanism and multi-channel features for sentiment classification. *Neurocomputing*. 2020, **387**, 63-77. ISSN 0925-2312.
- [209] LI, Yan, Yaoyu HE a Meizhen ZHANG. Prediction of Chinese energy structure based on Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM). *Energy Science & Engineering*. 2020, **8**(8), 2680-2689. ISSN 2050-0505.

- [210] LI, Yanfei, Huipeng SHI, Fengze HAN, Zhu DUAN a Hui LIU. Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy. *Renewable Energy*. 2019, **135**, 540-553. ISSN 0960-1481.
- [211] LI, Yiheng a Weidong CHEN. Entropy method of constructing a combined model for improving loan default prediction: A case study in China. *Journal of the Operational Research Society*. 2019. 1-11. ISSN 0160-5682.
- [212] LI, Youru, Zhenfeng ZHU, Deqiang KONG, Hua HAN a Yao ZHAO. EA-LSTM: Evolutionary attention-based LSTM for time series prediction. *Knowledge-Based Systems*. 2019, **181**. ISSN 0950-7051.
- [213] LI, Yulin, John K. WALD a Zijun WANG. Sovereign bonds, coskewness, and monetary policy regimes. *Journal of Financial Stability*. 2020, **50**. ISSN 1572-3089.
- [214] LI, Zhi, Hanyang GUO, Ali Vatankhah BARENJI, W. M. WANG, Yijiang GUAN a George Q. HUANG. A sustainable production capability evaluation mechanism based on blockchain, LSTM, analytic hierarchy process for supply chain network. *International Journal of Production Research*. 1-21. ISSN 0020-7543.
- [215] LI, Zhiyong, Ying TANG, Jingya WU, Junfeng ZHANG a Qi LV. The Interest Costs of Green Bonds: Credit Ratings, Corporate Social Responsibility, and Certification. *Emerging Markets Finance and Trade*. 2020, **56**(12), 2679-2692. ISSN 1540-496X.
- [216] LI, Zu-Xin, Jian-Ye LIU, Dong-Kun LUO a Jian-Jun WANG. Study of evaluation method for the overseas oil and gas investment based on risk compensation. *Petroleum Science*. 2020, **17**(3), 858-871. ISSN 1672-5107.
- [217] LIANG, Jin, Xudan ZHANG a Yuejuan ZHAO. Utility indifference valuation of corporate bond with rating migration risk. *Frontiers of Mathematics in China*. 2015, **10**(6), 1389-1400. ISSN 1673-3452.
- [218] LIAW, K. Thomas. Survey of Green Bond Pricing and Investment Performance. *Journal of Risk and Financial Management*. 2020, **13**(9). ISSN 1911-8074.
- [219] LIN, Edward M.H., Edward W. SUN a Min-Teh YU. Behavioral data-driven analysis with Bayesian method for risk management of financial services. *International Journal of Production Economics*. 2020, **228**. ISSN 0925-5273.
- [220] LIN, Chung-Gee, Chuang-Chang CHANG a Min-Teh YU. The valuation of a Euro-Convertible Bond. *IEEE International Conference on Computational Intelligence for Financial Engineering, Proceedings*. 2003, 115-122. ISBN 0-7803-7654-4.

- [221] LIN, Qian a Frank RIEDEL. Optimal consumption and portfolio choice with ambiguous interest rates and volatility. *Economic Theory*. 2020. ISSN 0938-2259.
- [222] LIOUI, Abraham a Andrea TARELLI. Macroeconomic environment, money demand and portfolio choice. *European Journal of Operational Research*. 2019, **274**(1), 357-374. ISSN 0377-2217.
- [223] LIOW, Kim Hiang, Wen-Chi LIAO a Yuting HUANG. Dynamics of international spillovers and interaction: Evidence from financial market stress and economic policy uncertainty. *Economic Modelling*. 2018, **68**, 96-116. ISSN 0264-9993.
- [224] LIU, Haiyun, Mollah Aminul ISLAM, Muhammad Asif KHAN, Md Ismail HOSSAIN a Khansa PERVAIZ. Does financial deepening attract foreign direct investment? Fresh evidence from panel threshold analysis. *Research in International Business and Finance*. 2020, **53**. ISSN 0275-5319.
- [225] LIU, Philip, Konstantinos THEODORIDIS, Haroon MUMTAZ a Francesco ZANETTI. Changing Macroeconomic Dynamics at the Zero Lower Bound. *Journal of Business & Economic Statistics*. 2019, **37**(3), 391-404. ISSN 0735-0015.
- [226] LIU, Rui a Lu LIU. Predicting housing price in China based on long short-term memory incorporating modified genetic algorithm. *Soft Computing*. 2019, **23**(22), 11829-11838. ISSN 1432-7643.
- [227] LIU, Wei, Wei David LIU a Jianwei GU. Forecasting oil production using ensemble empirical model decomposition based Long Short-Term Memory neural network. *Journal of Petroleum Science and Engineering*. 2020, **189**. ISSN 0920-4105.
- [228] LIU, Wei-han. National culture effects on stock market volatility level. *Empirical Economics*. 2019, **57**(4), 1229-1253. ISSN 0377-7332.
- [229] LIU, Xin, Hui LIU, Qiang GUO a Caiming ZHANG. Adaptive wavelet transform model for time series data prediction. *Soft Computing*. 2020, **24**(8), 5877-5884. ISSN 1432-7643.
- [230] LIU, Yang. Novel volatility forecasting using deep learning–Long Short Term Memory Recurrent Neural Networks. *Expert Systems with Applications*. 2019, **132**, 99-109. ISSN 0957-4174.
- [231] LIU, Yishun, Chunhua YANG, Keke HUANG a Weihua GUI. Non-ferrous metals price forecasting based on variational mode decomposition and LSTM network. *Knowledge-Based Systems*. 2020, **188**. ISSN 09507051.

- [232] LIU, Zuoming. Unraveling the complex relationship between environmental and financial performance - A multilevel longitudinal analysis. *International Journal of Production Economics*. 2020, **219**, 328-340. ISSN 0925-5273.
- [233] LJUNGKVIST, Torbjörn a Jim ANDERSÉN. A taxonomy of ecopreneurship in small manufacturing firms: A multidimensional cluster analysis. *Business Strategy and the Environment*. 2020. ISSN 0964-4733.
- [234] LÖFFLER, Gunter. The Systemic Risk Implications of Using Credit Ratings Versus Quantitative Measures to Limit Bond Portfolio Risk. *Journal of Financial Services Research*. 2020, **58**(1), 39-57. ISSN 0920-8550.
- [235] LONG, A. a O. PAVLOVA. A UK corporate bond rating classification using probabilistic neural network. World Multiconference on Systemics, Cybernetics and Informatics/5th International Conference on Information Systems, Analysis and Synthesis (ISAS 99). 1999, 174-177.
- [236] LOPREVITE, Salvatore, Domenico RAUCCI a Daniela RUPO. KPIs Reporting and Financial Performance in the Transition to Mandatory Disclosure: The Case of Italy. *Sustainability*. 2020, **12**(12). ISSN 2071-1050.
- [237] LOUREIRO, A.L.D., V.L. MIGUÉIS a Lucas F.M. DA SILVA. Exploring the use of deep neural networks for sales forecasting in fashion retail. *Decision Support Systems*. 2018, **114**, 81-93. ISSN 0167-9236.
- [238] LUO, Xiaochun, Zilong WANG, Lin LU a Yan GUAN. Supply Chain Flexibility Evaluation Based on Matter-Element Extension. *Complexity*. 2020, **2020**, 1-12. ISSN 1076-2787.
- [239] LUO, Xin a Jinlin ZHANG. Pricing Chinese Convertible Bonds with Default Intensity by Monte Carlo Method. *Discrete Dynamics in Nature and Society*. 2019, **2019**, 1-8. ISSN 1026-0226.
- [240] MA, Changfu, Wei XU a George YUAN. Valuation model for Chinese convertible bonds with soft call/put provision under the hybrid willow tree. *Quantitative Finance*. 2020, **20**(12), 2037-2053. ISSN 1469-7688.
- [241] MA, Chaoqun, Zonggang MA a Shisong XIAO. A closed-form pricing formula for vulnerable European options under stochastic yield spreads and interest rates. *Chaos, Solitons & Fractals*. 2019, **123**, 59-68. ISSN 0960-0779.
- [242] MACIKOVÁ, Lucia, Marián SMORADA, Peter DORČÁK, Benjamin BEUG a Peter MARKOVIČ. Financial Aspects of Sustainability: An Evidence from Slovak Companies. *Sustainability*. 2018, **10**(7). ISSN 2071-1050.

- [243] MAGKONIS, Georgios a Andreas TSOPANAKIS. The Financial Connectedness Between Eurozone Core and Periphery: A Disaggregated View. *Macroeconomic Dynamics*. 2020, **24**(7), 1674-1699. ISSN 1365-1005.
- [244] MAHDIRAJI, Hannan Amoozad, Edmundas Kazimieras ZAVADSKAS, Marinko SKARE, Fatemeh Zahra Rajabi KAFSHGAR a Alireza ARAB. Evaluating strategies for implementing industry 4.0: a hybrid expert oriented approach of BWM and interval valued intuitionistic fuzzy TODIM. *Economic Research-Ekonomska Istraživanja*. 2020, **33**(1), 1600-1620. ISSN 1331-677X.
- [245] MAHMOOD, Khalid, Fazal Masud KUNDI, Ghulam Muhammad KUNDI a Mahwish KUNDI. Aspect Based Abstractive Review Summarization Using Bi-directional Gated Recurrent Unit. *International Journal of Computer Science and Network Security*. Gomal University Gomal Univ, Inst Comp & Informat Technol, Dera Ismail Khan, Pakistan., 2020, JUN 30 2020, **20**(6), 185-194. ISSN 1738-7906.
- [246] MAI, Feng, Shaonan TIAN, Chihoon LEE a Ling MA. Deep learning models for bankruptcy prediction using textual disclosures. *European Journal of Operational Research*. 2019, **274**(2), 743-758. ISSN 0377-2217.
- [247] MANTOVI, Andrea a Augusto SCHIANCHI. A game-theoretic traverse analysis: Price competition and strategic investment. *Structural Change and Economic Dynamics*. 2019, **49**, 301-311. ISSN 0954-349X.
- [248] MAO, Guangyu a Zhengjun ZHANG. Stochastic tail index model for high frequency financial data with Bayesian analysis. *Journal of Econometrics*. 2018, **205**(2), 470-487. ISSN 0304-4076.
- [249] MARESOVA, Petra, Vladimir SOBESLAV a Ondrej KREJCAR. Cost–benefit analysis – evaluation model of cloud computing deployment for use in companies. *Applied Economics*. 2016, **49**(6), 521-533. ISSN 0003-6846.
- [250] MARUDDANI, Di Asih I., Dedi ROSADI, GUNARDIC, ABDURAKHMAN. One Period Coupon Bond Valuation With Revised First Passage Time Approach and The Application in Indonesian Corporate Bond. *2nd ISM International Statistical Conference 2014 (ISM-II): Empowering the Applications of Statistical and Mathematical Science*. 2015, **1643**, 391-401.
- [251] MCCALLIG, John, Alastair ROBB a Fiona ROHDE. Establishing the representational faithfulness of financial accounting information using multiparty security, network analysis and a blockchain. *International Journal of Accounting Information Systems*. 2019, **33**, 47-58. ISSN 1467-0895.

- [252] MESSAI, A.S. a GALLALI, M.I. Financial leading indicators of banking distress: A micro prudential approach-evidence from Europe. *Asian Social Science*. 2015, 11(21), 78-90. ISSN 1911-2025.
- [253] MEULI, Jonas, Thomas NELLEN a Thomas NITSCHKA. Covered bonds, loan growth and bank funding: The Swiss experience since 1932. *International Finance*. 2020. ISSN 1367-0271.
- [254] MINISTERSTVO FINANCÍ ČR. *Hazardní hry* [online]. 2019a [vid. 11. října 2020]. Zpracováno NMS Market Resarch s.r.o., nepublikováno. Dostupné z: <https://www.mfcr.cz/cs/soukromy-sektor/hazardni-hry>
- [255] MINISTERSTVO FINANCÍ ČR. *Hazardní hry* [online]. 2019c [vid. 16. října 2020]. Zpracováno NMS, nepublikováno. Dostupné z: <https://www.mfcr.cz/cs/soukromy-sektor/hazardni-hry>
- [256] MINISTERSTVO FINANCÍ ČR. *Přehledy sázkových kanceláří* [online]. 2020 [vid. 15. října 2020]. Dostupné z: <https://www.mfcr.cz/cs/soukromy-sektor/hazardni-hry/prehledy-a-statistiky/prehledy-sazkovych-kancelari>
- [257] MINISTERSTVO FINANCÍ ČR. *Výsledky provozování hazardních her v ČR*. Zpracováno NMS Market Resarch s.r.o., 2019b, nepublikováno.
- [258] MISHRA, Shraddha, Surya Prakash SINGH, John JOHANSEN, Yang CHENG a Sami FAROOQ. Evaluating indicators for international manufacturing network under circular economy. *Management Decision*. 2019, 57(4), 811-839. ISSN 0025-1747.
- [259] MOHANRAM, Partha, Sasan SAIY a Dushyantkumar VYAS. Fundamental analysis of banks: the use of financial statement information to screen winners from losers. *Review of Accounting Studies*. 2018, 23(1), 200-233. ISSN 1380-6653.
- [260] MOLLAH, Sabur, A.M.M. Shahiduzzaman QUORESHI a Goran ZAFIROV. Equity market contagion during global financial and Eurozone crises: Evidence from a dynamic correlation analysis. *Journal of International Financial Markets, Institutions and Money*. 2016, 41, 151-167. ISSN 1042-4431.
- [261] MONK, Alexander a Richard PERKINS. What explains the emergence and diffusion of green bonds? *Energy Policy*. 2020, 145. ISSN 0301-4215.
- [262] MONTGOMERY, Robert T., Jeffrey A. OGDEN a Bradley C. BOEHMKE. A quantified Kraljic Portfolio Matrix: Using decision analysis for strategic purchasing. *Journal of Purchasing and Supply Management*. 2018, 24(3), 192-203. ISSN 1478-4092.

- [263] MRAVČÍK, Viktor et al. *Výroční zpráva o hazardním hraní v České republice v roce 2018*. Praha: Úřad vlády České republiky, 2019, 158 s. ISBN 978-80-7440-229-6.
- [264] MRAVČÍK, Viktor et al. *Výroční zpráva o hazardním hraní v České republice v roce 2019*. Praha: Úřad vlády České republiky, 2020, 161 s. ISBN 978-80-7440-248-7.
- [265] MUNOZ-IZQUIERDO, Nora, Erkki K. LAITINEN, Mária-del-Mar CAMACHO-MINANO, David PASCUAL-EZAMA. Does audit report information improve financial distress prediction over Altman's traditional Z-Score model? *Journal of International Financial Management & Accounting*. 2019, **31**(1), 65-97. ISSN 1467-646X.
- [266] MÜNDEL, Christiane, Patrick PLÖTZ, Frances SPREI a Till GNANN. How large is the effect of financial incentives on electric vehicle sales? – A global review and European analysis. *Energy Economics*. 2019, **84**. ISSN 0140-9883.
- [267] NADKARNI, João a Rui FERREIRA NEVES. Combining NeuroEvolution and Principal Component Analysis to trade in the financial markets. *Expert Systems with Applications*. 2018, **103**, 184-195. ISSN 0957-4174.
- [268] NAIFAR, Nader. What Explains the Sovereign Credit Default Swap Spreads Changes in the GCC Region? *Journal of Risk and Financial Management*. 2020, **13**(10). ISSN 1911-8074.
- [269] NAKAJIMA, Makoto. Assessing bankruptcy reform in a model with temptation and equilibrium default. *Journal of Public Economics*. 2017, **145**, 42-64. ISSN 0047-2727.
- [270] NAQVI, Natalya. Manias, Panics and Crashes in Emerging Markets: An Empirical Investigation of the Post-2008 Crisis Period. *New Political Economy*. 2018, **24**(6), 759-779. ISSN 1356-3467.
- [271] NARKUNIENĖ, Judita, Aurelija ULBINAITĖ a Manuela TVARONAVIČIENĖ. Comparative analysis of company performance evaluation methods. *Entrepreneurship and Sustainability Issues*. 2018, **6**(1), 125-138. ISSN 2345-0282.
- [272] NASRUDDIN, SHOLAHUDIN, M. IDRUS ALHAMID a Kiyoshi SAITO. Hot water temperature prediction using a dynamic neural network for absorption chiller application in Indonesia. *Sustainable Energy Technologies and Assessments*. 2018, **30**, 114-120. ISSN 2213-1388.
- [273] NEEMEY, Pooja a Namita SAHAY. Indian Corporate Bond Market: An Analysis of Growth and Impact of Macroeconomic Determinants. *Vision: The Journal of Business Perspective*. 2019, **23**(3), 244-254. ISSN 0972-2629.

- [274] NGUYEN, Ba-Hung a Van-Nam HUYNH. Textual analysis and corporate bankruptcy: A financial dictionary-based sentiment approach. *Journal of the Operational Research Society*. 2020. 1-20. ISSN 0160-5682.
- [275] NISPILANDI, Valerio. Capital controls spillovers. *Journal of International Money and Finance*. 2020, **109**. ISSN 0261-5606.
- [276] NIU, Baozhuang, Jiawei LI, Jie ZHANG, Hsing Kenneth CHENG a Yinliang Ricky TAN. Strategic Analysis of Dual Sourcing and Dual Channel with an Unreliable Alternative Supplier. *Production and Operations Management*. 2019, **28**(3), 570-587. ISSN 1059-1478.
- [277] NIZAM, Esma, Adam NG, Ginanjar DEWANDARU, Ruslan NAGAYEV a Malik Abdulrahman NKOKA. The impact of social and environmental sustainability on financial performance: A global analysis of the banking sector. *Journal of Multinational Financial Management*. 2019, **49**, 35-53. ISSN 1042-444X.
- [278] NOBRE, João a Rui Ferreira NEVES. Combining Principal Component Analysis, Discrete Wavelet Transform and XGBoost to trade in the financial markets. *Expert Systems with Applications*. 2019, **125**, 181-194. ISSN 0957-4174.
- [279] NYITRAI, Tamás a Miklós VIRÁG. The effects of handling outliers on the performance of bankruptcy prediction models. *Socio-Economic Planning Sciences*. 2019, **67**, 34-42. ISSN 0038-0121.
- [280] OJSTERSEK, Robert a Borut BUCHMEISTER. The Impact of Manufacturing Flexibility and Multi-Criteria Optimization on the Sustainability of Manufacturing Systems. *Symmetry*. 2020, **12**(1). ISSN 2073-8994.
- [281] OMANE-ADJEPONG, Maurice, Kofi Agyarko ABABIO a Imhotep Paul ALAGIDEDÉ. Time-frequency analysis of behaviourally classified financial asset markets. *Research in International Business and Finance*. 2019, **50**, 54-69. ISSN 0275-5319.
- [282] OSINSKI, Marilei, Paulo Mauricio SELIG, Florinda MATOS a Darlan José ROMAN. Methods of evaluation of intangible assets and intellectual capital. *Journal of Intellectual Capital*. 2017, **18**(3), 470-485. ISSN 1469-1930.
- [283] OSTER, Philippe. When all concern is gone: the impact of call provisions on gone-concern Tier 2 bond spreads in Europe. *The European Journal of Finance*. 2020, **26**(15), 1529-1568. ISSN 1351-847X.
- [284] OU, Gang, Xiangrui CHAO, Yi PENG, Fawaz E. ALSAADI a Enrique HERRERA-VIEDMA. Machine Learning Methods for Systemic Risk Analysis in Financial

- Sectors. *Technological and Economic Development of Economy*. 2019, **25**(5), 716-742. ISSN 2029-4913.
- [285] PAGLIACCI, Carolina. Financial constraints and inflation in Latin America: The impacts of bond financing and depreciations on supply inflation. *Economic Analysis and Policy*. 2020, **68**, 379-397. ISSN 0313-5926.
- [286] PANG, Xiongwen, Yanqiang ZHOU, Pan WANG, Weiwei LIN a Victor CHANG. An innovative neural network approach for stock market prediction. *The Journal of Supercomputing*. 2020, **76**(3), 2098-2118. ISSN 0920-8542.
- [287] PANIGRAHI, Sibarama a H.S. BEHERA. A study on leading machine learning techniques for high order fuzzy time series forecasting. *Engineering Applications of Artificial Intelligence*. 2020, **87**. ISSN 0952-1976.
- [288] PAPPAS, Anastasios a Ioannis KOSTAKIS. The Driving Factors of EMU Government Bond Yields: The Role of Debt, Liquidity and Fiscal Councils. *International Journal of Financial Studies*. 2020, **8**(3). ISSN 2227-7072.
- [289] PARK, Hyun-jung, Minchae SONG a Kyung-Shik SHIN. Deep learning models and datasets for aspect term sentiment classification: Implementing holistic recurrent attention on target-dependent memories. *Knowledge-Based Systems*. 2020, **187**. ISSN 0950-7051.
- [290] PARK, Keehwan, Mookwon JUNG a Sangki LEE. Credit ratings and convertible bond prices: a simulation-based valuation. *The European Journal of Finance*. 2017, **24**(12), 1001-1025. ISSN 1351-847X.
- [291] PEARSE, Rebecca. Theorising the Political Economy of Energy Transformations: Agency, Structure, Space, Process. *New Political Economy*. 2020. 1-13. ISSN 1356-3467.
- [292] PENALVER, Adrian, Nobuyuki HANAKI, Eizo AKIYAMA, Yukihiro FUNAKI a Ryuichiro ISHIKAWA. A quantitative easing experiment. *Journal of Economic Dynamics and Control*. 2020, **119**. ISSN 0165-1889.
- [293] PENG, Li, Yuan LI, Marc VAN ESSEN a Mike W. PENG. Institutions, resources, and strategic orientations: A meta-analysis. *Asia Pacific Journal of Management*. 2020, **37**(2), 499-529. ISSN 0217-4561.
- [294] PEREGO, Erica. Sovereign risk and asset market dynamics in the euro area. *Journal of International Money and Finance*. 2020, **109**. ISSN 0261-5606.
- [295] PERILLO, Chiara a Stefano BATTISTON. Financialization and unconventional monetary policy: a financial-network analysis. *Journal of Evolutionary Economics*. 2020, **30**(5), 1385-1428. ISSN 0936-9937.

- [296] PETROPOULOS, Anastasios, Vasilis SIAKOULIS, Evangelos STAVROULAKIS a Nikolaos E. VLACHOGIANNAKIS. Predicting bank insolvencies using machine learning techniques. *International Journal of Forecasting*. 2020, **36**(3), 1092-1113. ISSN 0169-2070.
- [297] PIGNATEL, Isabelle a Hubert TCHAKOUTE TCHUIGOUA. Microfinance institutions and International Financial Reporting Standards: An exploratory analysis. *Research in International Business and Finance*. 2020, **54**. ISSN 0275-5319.
- [298] PINTO, Inês a Winnie NG PICOTO. Configurational analysis of firms' performance: Understanding the role of Internet financial reporting. *Journal of Business Research*. 2016, **69**(11), 5360-5365. ISSN 0148-2963.
- [299] POLOUČEK, Stanislav et al. *Peníze, banky, finanční trhy*. 1. vyd. Praha: C. H. Beck, 2009, 415 s. ISBN 978-80-7400-152-9.
- [300] PUNIA, Sushil, Konstantinos NIKOLOPOULOS, Surya Prakash SINGH, Jitendra K. MADAAN a Konstantia LITSIOU. Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail. *International Journal of Production Research*. 2020, 58(16), 4964-4979. ISSN 0020-7543.
- [301] PUSTYLNICK, Igor. Comparison of liquidity based and financial performance based indicators in financial analysis. *Oeconomia Copernicana*. 2017, **8**(1), 83-97. ISSN 2353-1827.
- [302] QIAO, Weibiao a Zhe YANG. Forecast the electricity price of U.S. using a wavelet transform-based hybrid model. *Energy*. 2020, **193**, 511-530. ISSN 0360-5442.
- [303] QIAO, Weibiao, Zhe YANG, Zhangyang KANG a Zhen PAN. Short-term natural gas consumption prediction based on Volterra adaptive filter and improved whale optimization algorithm. *Engineering Applications of Artificial Intelligence*. 2020, **87**. ISSN 0952-1976.
- [304] QIN, Likuan a Vadim LINETSKY. Long-term factorization in Heath–Jarrow–Morton models. *Finance and Stochastics*. 2018, **22**(3), 621-641. ISSN 0949-2984.
- [305] QIN, Likuan a Vadim LINETSKY. Long-Term Risk: A Martingale Approach. *Econometrica*. 2017, **85**(1), 299-312. ISSN 0012-9682.
- [306] QIN, Likuan, Vadim LINETSKY a Yutian NIE. Long Forward Probabilities, Recovery, and the Term Structure of Bond Risk Premiums. *The Review of Financial Studies*. 2018, **31**(12), 4863-4883. ISSN 0893-9454.
- [307] QIN, Xuelian, Zhixue LIU a Lin TIAN. The strategic analysis of logistics service sharing in an e-commerce platform. *Omega*. 2020, **92**. ISSN 0305-0483.

- [308] QIU, Xuemei, Zhong-qin SU a Zuoping XIAO. Do social ties matter for corporate bond yield spreads? Evidence from China. *Corporate Governance: An International Review*. 2019, **27**(6), 427-457. ISSN 0964-8410.
- [309] QUICENO, Grace, Claudia ÁLVAREZ, Raúl ÁVILA, Óscar FERNÁNDEZ, Carlos Jaime FRANCO, Martin KUNC a Isaac DYNER. Scenario analysis for strategy design: A case study of the Colombian electricity industry. *Energy Strategy Reviews*. 2019, **23**, 57-68. ISSN 2211-467X.
- [310] QURESHI, Fiza, Habib Hussain KHAN, Ijaz ur REHMAN, Saba QURESHI a Abdul GHAFOR. The Effect of Monetary and Fiscal Policy on Bond Mutual Funds and Stock Market: An International Comparison. *Emerging Markets Finance and Trade*. 2019, **55**(13), 3112-3130. ISSN 1540-496X.
- [311] RAUT, Rakesh, Naoufel CHEIKHROUHOU a Manoj KHARAT. Sustainability in The Banking Industry: A Strategic Multi-Criterion Analysis. *Business Strategy and the Environment*. 2017, **26**(4), 550-568. ISSN 0964-4733.
- [312] REIS, Pedro Manuel Nogueira a Carlos PINHO. A new European investor sentiment index (EURsent) and its return and volatility predictability. *Journal of Behavioral and Experimental Finance*. 2020, **27**. ISSN 2214-6350.
- [313] REJNUŠ, Ondřej. Finanční trhy. 4. aktualizované a rozšířené vyd. Praha: Grada, 2014, 768 s. ISBN 978-80-247-3671-6.
- [314] ROSTAN, Pierre a Alexandra ROSTAN. The versatility of spectrum analysis for forecasting financial time series. *Journal of Forecasting*. 2018, **37**(3), 327-339. ISSN 0277-6693.
- [315] ROY, Pradeep Kumar, Jyoti Prakash SINGH a Snehasish BANERJEE. Deep learning to filter SMS Spam. *Future Generation Computer Systems*. 2020, **102**, 524-533. ISSN 0167-739X.
- [316] RUNDO, Francesco. Deep LSTM with Reinforcement Learning Layer for Financial Trend Prediction in FX High Frequency Trading Systems. *Applied Sciences*. 2019, **9**(20). ISSN 2076-3417.
- [317] RÜNGER, Silke. Personal taxation and individual stock ownership. *The European Journal of Finance*. 2020. 1-16. ISSN 1351-847X.
- [318] RUSSO, Angeloantonio, Massimo MARIANI a Alessandra CARAGNANO. Exploring the determinants of green bond issuance: Going beyond the long-lasting debate on performance consequences. *Business Strategy and the Environment*. 2020. ISSN 0964-4733.

- [319] RYU, Sunghan a Ayoung SUH. Online service or virtual community? Building platform loyalty in reward-based crowdfunding. *Internet Research*. 2020. ISSN 1066-2243.
- [320] SAGHEER, Alaa a Mostafa KOTB. Unsupervised Pre-training of a Deep LSTM-based Stacked Autoencoder for Multivariate Time Series Forecasting Problems. *Scientific Reports*. 2019, **9**(1). ISSN 2045-2322.
- [321] SAJNÓG, Artur Robert. Executive compensation and comprehensive income: evidence from Polish listed companies. *Oeconomia Copernicana*. 2019, **10**(3), 493-509. ISSN 2353-1827.
- [322] SALINAS, David, Valentin FLUNKERT, Jan GASTHAUS a Tim JANUSCHOWSKI. DeepAR: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*. 2020, **36**(3), 1181-1191. ISSN 0169-2070.
- [323] SAMBA, Codou, Pooya TABESH, Ioannis C THANOS a Vassilis M PAPADAKIS. Method in the madness? A meta-analysis on the strategic implications of decision comprehensiveness. *Strategic Organization*. 2020. ISSN 1476-1270.
- [324] SANT'ANNA, Pedro H. C. Testing for Uncorrelated Residuals in Dynamic Count Models With an Application to Corporate Bankruptcy. *Journal of Business & Economic Statistics*. 2017, **35**(3), 349-358. ISSN 0735-0015.
- [325] SARABIA, José María, Faustino PRIETO, Vanesa JORDÁ a Stefan SPERLICH. A Note on Combining Machine Learning with Statistical Modeling for Financial Data Analysis. *Risks*. 2020, **8**(2). ISSN 2227-9091.
- [326] SEGURA, E., R. MORALES a J.A. SOMOLINOS. A strategic analysis of tidal current energy conversion systems in the European Union. *Applied Energy*. 2018, **212**, 527-551. ISSN 0306-2619.
- [327] SENAY, Ozge a Alan SUTHERLAND. Optimal monetary policy, exchange rate misalignments and incomplete financial markets. *Journal of International Economics*. 2019, **117**, 196-208. ISSN 0022-1996.
- [328] SHARMA, Amita a Aparna MEHRA. Financial analysis based sectoral portfolio optimization under second order stochastic dominance. *Annals of Operations Research*. 2017, **256**(1), 171-197. ISSN 0254-5330.
- [329] SCHAEFER, Sarah Desirée, Ralf TERLUTTER a Sandra DIEHL. Is my company really doing good? Factors influencing employees' evaluation of the authenticity of their company's corporate social responsibility engagement. *Journal of Business Research*. 2019, **101**, 128-143. ISSN 0148-2963.

- [330] SCHEPKER, Donald J., Youngsang KIM, Pankaj C. PATEL, Sherry M.B. THATCHER a Michael C. CAMPION. CEO succession, strategic change, and post-succession performance: A meta-analysis. *The Leadership Quarterly*. 2017, **28**(6), 701-720. ISSN 1048-9843.
- [331] SCHMIDT, Jörg. Risk, asset pricing and monetary policy transmission in Europe: Evidence from a threshold-VAR approach. *Journal of International Money and Finance*. 2020, **109**. ISSN 0261-5606.
- [332] SCHÖNFELD, Jaroslav, Michal KUDĚJ a Luboš SMRČKA. Financial health of enterprises introducing safeguard procedure based on bankruptcy models. *Journal of Business Economics and Management*. 2018, **19**(5), 692-705. ISSN 1611-1699.
- [333] SCHUMACHER, Dieter. The integration of international financial markets: an attempt to quantify contagion in an input–output-type analysis. *Economic Systems Research*. 2018, **31**(3), 345-360. ISSN 0953-5314.
- [334] SILVA, Walmir, Herbert KIMURA a Vinicius Amorim SOBREIRO. An analysis of the literature on systemic financial risk: A survey. *Journal of Financial Stability*. 2017, **28**, 91-114. ISSN 1572-3089.
- [335] SMALES, Lee A. Policy uncertainty in Australian financial markets. *Australian Journal of Management*. 2020. ISSN 0312-8962.
- [336] SMYL, Slawek. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*. 2020, **36**(1), 75-85. ISSN 0169-2070.
- [337] SOMU, Nivethitha, Gauthama Raman M R a Krithi RAMAMRITHAM. A hybrid model for building energy consumption forecasting using long short term memory networks. *Applied Energy*. 2020, **261**. ISSN 0306-2619.
- [338] SONG, Jinbo, Yan SUN a Lulu JIN. PESTEL analysis of the development of the waste-to-energy incineration industry in China. *Renewable and Sustainable Energy Reviews*. 2017, **80**, 276-289. ISSN 1364-0321.
- [339] STICHHAUEROVA, Eva, Miroslav ZIZKA a Natalie PELLONEOVA. Comparison of the Significance of Clusters for Increasing Business Performance. *Journal of Competitiveness*. 2020, **12**(3), 172-189. ISSN 1804-171X.
- [340] SUIMON, Yoshiyuki, Hiroki SAKAJI, Kiyoshi IZUMI a Hiroyasu MATSUSCHIMA. Autoencoder-Based Three-Factor Model for the Yield Curve of Japanese Government Bonds and a Trading Strategy. *Journal of Risk and Financial Management*. 2020, **13**(4). ISSN 1911-8066.

- [341] SUNDER-PLASSMANN, Laura. Inflation, default and sovereign debt: The role of denomination and ownership. *Journal of International Economics*. 2020, **127**. ISSN 0022-1996.
- [342] SUTHERLAND, Dylan, John ANDERSON a Zheyuan HU. A comparative analysis of location and non-location-bounded strategic asset seeking in emerging and developed market MNEs: An application of new internalization theory. *International Business Review*. 2020, **29**(2). ISSN 0969-5931.
- [343] ŠESTANOVIĆ, Tea a Josip ARNERIĆ. Neural network structure identification in inflation forecasting. *Journal of Forecasting*. 2020. ISSN 0277-6693.
- [344] ŠOBA, Oldřich a Martin ŠIRŮČEK. Finanční matematika v praxi. 2. aktualizované vyd. Praha: Grada Publishing a.s., 2017, 336 s. ISBN 978-80-271-0250-1.
- [345] TAN, Xueping, Kavita SIRICHAND, Andrew VIVIAN a Xinyu WANG. How connected is the carbon market to energy and financial markets? A systematic analysis of spillovers and dynamics. *Energy Economics*. 2020, **90**. ISSN 0140-9883.
- [346] TAN, Yinliang Ricky a Janice E. CARRILLO. Strategic Analysis of the Agency Model for Digital Goods. *Production and Operations Management*. 2017, **26**(4), 724-741. ISSN 1059-1478.
- [347] TANG, Dragon Yongjun a Yupu ZHANG. Do shareholders benefit from green bonds? *Journal of Corporate Finance*. 2020, **61**. ISSN 0929-1199.
- [348] TANG, Yajiao, Junkai JI, Yulin ZHU, Shangce GAO, Zheng TANG a Yuki TODO. A Differential Evolution-Oriented Pruning Neural Network Model for Bankruptcy Prediction. *Complexity*. 2019, **2019**, 1-21. ISSN 1076-2787.
- [349] TIAN, Yong, Rucong LAI, Xiaoyu LI, Lijuan XIANG a Jindong TIAN. A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter. *Applied Energy*. 2020, **265**. ISSN 0306-2619.
- [350] TOLLIVER, Clarence, Hidemichi FUJII, Alexander Ryota KEELEY a Shunsuke MANAGI. Green Innovation and Finance in Asia. *Asian Economic Policy Review*. 2020. ISSN 1832-8105.
- [351] TRAUTRIMS, Alexander, Bart L. MACCARTHY a Chetan OKADE. Building an innovation-based supplier portfolio: The use of patent analysis in strategic supplier selection in the automotive sector. *International Journal of Production Economics*. 2017, **194**, 228-236. ISSN 0925-5273.

- [352] TREBBI, Francesco a Kairong XIAO. Regulation and Market Liquidity. *Management Science*. 2019. **65**(5), 1949-1968. ISSN 0025-1909.
- [353] TROTTIER, Denis-Alexandre, Van Son LAI a Frédéric GODIN. A characterization of CAT bond performance indices. *Finance Research Letters*. 2019, **28**, 431-437. ISSN 1544-6123.
- [354] TSANGAS, Michail, Mejdi JEGUIRIM, Lionel LIMOUSY a Antonis ZORPAS. The Application of Analytical Hierarchy Process in Combination with PESTEL-SWOT Analysis to Assess the Hydrocarbons Sector in Cyprus. *Energies*. 2019, **12**(5). ISSN 1996-1073.
- [355] TWENEBOAH, George, Peterson OWUSU JUNIOR a Seyram Pearl KUMAH. Modelling the asymmetric linkages between spot gold prices and African stocks. *Research in International Business and Finance*. 2020, **54**. ISSN 0275-5319.
- [356] TYLER, Melissa a Sheena VACHHANI. Chasing rainbows? A recognition-based critique of Primark's precarious commitment to inclusion. *Organization*. 2020. ISSN 1350-5084.
- [357] TZOUVANAS, Panagiotis, Renatas KIZYS, Ioannis CHATZIANTONIOU a Roza SAGITOVA. Environmental and financial performance in the European manufacturing sector: An analysis of extreme tail dependency. *The British Accounting Review*. 2020, **52**(6). ISSN 0890-8389.
- [358] VALASKOVA, Katarina, Tomas KLIESTIK a Maria KOVACOVA. Management of financial risks in Slovak enterprises using regression analysis. *Oeconomia Copernicana*. 2018, **9**(1), 105-121. ISSN 2353-1827.
- [359] VAN BILSEN, Servaas, A. Lans BOVENBERG a Roger J. A. LAEVEN. Consumption and Portfolio Choice under Internal Multiplicative Habit Formation. *Journal of Financial and Quantitative Analysis*. 2020, **55**(7), 2334-2371. ISSN 0022-1090.
- [360] VILLAMIL, Carolina a Sophie HALLSTEDT. Sustainability integration in product portfolio for sustainable development: Findings from the industry. *Business Strategy and the Environment*. 2020. ISSN 0964-4733.
- [361] VOCHOZKA, Marek, Jaromír VRBKA a Petr ŠULEŘ. Bankruptcy or Success? The Effective Prediction of a Company's Financial Development Using LSTM. *Sustainability*. 2020, **12**(18). ISSN 2071-1050.
- [362] VOCHOZKA, Marek, Vojtěch STEHEL, Jaromír VRBKA, Zuzana ROWLAND, Petr ŠULEŘ, Veronika MACHOVÁ, Tomáš KRULICKÝ a Jakub HORÁK. *Metody*

komplexního hodnocení podniku. 2. aktualizované vyd. Praha: Grada Publishing, a. s., 2020, 479 s. Finanční řízení. ISBN 978-80-271-1701-7.

- [363] VRBKA, Jaromír, Elvira NICA a Ivana PODHORSKÁ. The application of Kohonen networks for identification of leaders in the trade sector in Czechia. *Equilibrium*. 2019, **14**(4), 739-761. ISSN 2353-3293.
- [364] VRBKA, Jaromír, Tomáš KRULICKÝ, Tomáš BRABENEC a Jan HEJDA. The concept of the Equilibrium and the pen market value. *AD ALTA-Journal of Interdisciplinary Research*. 2020, **2020**(1), 319-325. ISSN 1804-7890.
- [365] VRBKA, Jaromír, Zuzana ROWLAND, Jan VÁCHAL, Marek VOCHOZKA a Jakub HORÁK. Stock price development forecasting using neural networks. *SHS Web of Conferences*. 2017, **39**(8). ISSN 2261-2424.
- [366] VRBKA, Jaromír. The use of neural networks to determine value based drivers for SMEs operating in the rural areas of the Czech Republic. *Oeconomia Copernicana*. 2020, **11**(2), 325-346. ISSN 2353-1827.
- [367] VUKOVIC, Darko B., Edin HANIC a Hasan HANIC. Financial integration in the European Union - the impact of the crisis on the bond market. *Equilibrium*. 2017, **12**(2), 195-210. ISSN 2353-3293.
- [368] VUKOVIC, Darko, Kseniya A. LAPSHINA a Moinak MAITI. European Monetary Union bond market dynamics: Pre & post crisis. *Research in International Business and Finance*. 2019, **50**, 369-380. ISSN 0275-5319.
- [369] WAN, Huaiyu, Shengnan GUO, Kang YIN, Xiaohui LIANG a Youfang LIN. CTS-LSTM: LSTM-based neural networks for correlated time series prediction. *Knowledge-Based Systems*. 2020, **191**. ISSN 0950-7051.
- [370] WANG, Bo, Liming ZHANG, Hengrui MA, Hongxia WANG a Shaohua WAN. Parallel LSTM-Based Regional Integrated Energy System Multienergy Source-Load Information Interactive Energy Prediction. *Complexity*. 2019, **2019**, 1-13. ISSN 1076-2787.
- [371] WANG, Lu, Yuangao CHEN, Hui JIANG a Jianrong YAO. Imbalanced credit risk evaluation based on multiple sampling, multiple kernel fuzzy self-organizing map and local accuracy ensemble. *Applied Soft Computing*. 2020, **91**. ISSN 1568-4946.
- [372] WANG, Qi, Guangyin JIN, Xia ZHAO, Yanghe FENG a Jincan HUANG. CSAN: A neural network benchmark model for crime forecasting in spatio-temporal scale. *Knowledge-Based Systems*. 2020, **189**. ISSN 0950-7051.
- [373] WANG, Qiang, Long CHEN, Jun ZHAO a Wei WANG. A deep granular network with adaptive unequal-length granulation strategy for long-term time series forecasting and its

- industrial applications. *Artificial Intelligence Review*. 2020, 53(7), 5353-5381. ISSN 0269-2821.
- [374] WANG, Rui a Yanlai LI. A Novel Approach for Green Supplier Selection under a q-Rung Orthopair Fuzzy Environment. *Symmetry*. 2018, **10**(12). ISSN 2073-8994.
- [375] WANG, Weijia a Shaoan HUANG. Risk sharing and financial stability: a welfare analysis. *Journal of Economic Interaction and Coordination*. 2020. ISSN 1860-711X.
- [376] WANG, Ye, Xinxiang ZHANG, Mi LU, Han WANG a Yoonsuck CHOE. Attention augmentation with multi-residual in bidirectional LSTM. *Neurocomputing*. 2020, **385**, 340-347. ISSN 0925-2312.
- [377] WANG, Yuning a Xiaohua JIN. Structural risk of diversified project financing of city investment company in China based on the best worst method. *Engineering, Construction and Architectural Management*. 2019. ISSN 0969-9988.
- [378] WANG, Z. Jay, Hanjiang ZHANG a Xinde ZHANG. Fire Sales and Impediments to Liquidity Provision in the Corporate Bond Market. *Journal of Financial and Quantitative Analysis*. 2020, **55**(8), 2613-2640. ISSN 0022-1090.
- [379] WANG, Zhaoyuan, Junbo ZHANG, Shenggong JI, Chuishi MENG, Tianrui LI a Yu ZHENG. Predicting and ranking box office revenue of movies based on big data. *Information Fusion*. 2020, **60**, 25-40. ISSN 1566-2535.
- [380] WANKE, Peter, Mike G. TSIONAS, Zhongfei CHEN a Jorge Junio MOREIRA ANTUNES. Dynamic network DEA and SFA models for accounting and financial indicators with an analysis of super-efficiency in stochastic frontiers: An efficiency comparison in OECD banking. *International Review of Economics & Finance*. 2020, **69**, 456-468. ISSN 1059-0560.
- [381] WEI, Chun-Chin a Yung-Lung CHENG. Six Sigma project selection using fuzzy multiple attribute decision-making method. *Total Quality Management & Business Excellence*. 2020, **31**(11-12), 1266-1289. ISSN 1478-3363.
- [382] WEI, Nan, Changjun LI, Xiaolong PENG, Yang LI a Fanhua ZENG. Daily natural gas consumption forecasting via the application of a novel hybrid model. *Applied Energy*. 2019, **250**, 358-368. ISSN 0306-2619.
- [383] WILSON, John P. a Larry CAMPBELL. Financial functional analysis: a conceptual framework for understanding the changing financial system. *Journal of Economic Methodology*. 2016, **23**(4), 413-431. ISSN 1350-178X.

- [384] WU, TsingZai C., Wan Ting HSIEH, Chun Chan YU a Hsin Ti CHU. Value relevance of financial statements in convergence with IFRS: analyses in the abnormal pricing error method. *Applied Economics Letters*. 2016, **24**(7), 490-493. ISSN 1350-4851.
- [385] WU, Yunna a Jianli ZHOU. Risk assessment of urban rooftop distributed PV in energy performance contracting (EPC) projects: An extended HFLTS-DEMATEL fuzzy synthetic evaluation analysis. *Sustainable Cities and Society*. 2019, **47**. ISSN 2210-6707.
- [386] XIAO, Xi, Dianyan ZHANG, Guangwu HU, Yong JIANG a Shutao XIA. CNN–MHSA: A Convolutional Neural Network and multi-head self-attention combined approach for detecting phishing websites. *Neural Networks*. 2020, **125**, 303-312. ISSN 0893-6080.
- [387] XIE, Xiurui, Guisong LIU, Qing CAI, Guolin SUN, Malu ZHANG a Hong QU. An end-to-end functional spiking model for sequential feature learning. *Knowledge-Based Systems*. 2020, **195**. ISSN 0950-7051.
- [388] XIE, Xuemei, Jiage HUO a Hailiang ZOU. Green process innovation, green product innovation, and corporate financial performance: A content analysis method. *Journal of Business Research*. 2019, **101**, 697-706. ISSN 0148-2963.
- [389] XU, Ran, Richard P. DESHON a Christopher R. DISHOP. Challenges and Opportunities in the Estimation of Dynamic Models. *Organizational Research Methods*. 2020, **23**(4), 595-619. ISSN 1094-4281.
- [390] YADEGARIDEHKORDI, Elaheh, Mehdi HOURMAND, Mehrbakhsh NILASHI, Liyana SHUIB, Ali AHANI a Othman IBRAHIM. Influence of big data adoption on manufacturing companies' performance: An integrated DEMATEL-ANFIS approach. *Technological Forecasting and Social Change*. 2018, **137**, 199-210. ISSN 0040-1625.
- [391] YANG, Guotian, Yingnan WANG a Xinli LI. Prediction of the NO emissions from thermal power plant using long-short term memory neural network. *Energy*. 2020, **192**. ISSN 0360-5442.
- [392] YANG, Linyun W, Pankaj AGGARWAL, Laura PERACCHIO, Gita JOHAR a Margaret C CAMPBELL. No Small Matter: How Company Size Affects Consumer Expectations and Evaluations. *Journal of Consumer Research*. 2019, **45**(6), 1369-1384. ISSN 0093-5301.
- [393] YAZDANI, Morteza, Dragan PAMUCAR, Prasenjit CHATTERJEE a Shankar CHAKRABORTY. Development of a decision support framework for sustainable freight

- transport system evaluation using rough numbers. *International Journal of Production Research*. 2020, **58**(14), 4325-4351. ISSN 0020-7543.
- [394] YE, Xin, Lu-an DONG a Da MA. Loan evaluation in P2P lending based on Random Forest optimized by genetic algorithm with profit score. *Electronic Commerce Research and Applications*. 2018, **32**, 23-36. ISSN 1567-4223.
- [395] YEH, Chun-Chieh, Chien-Liang CHIU a Tsangyao CHANG. Dynamic correlations in bond markets between US and emerging countries. *Applied Economics Letters*, 2020. 1-6. ISSN 1350-4851.
- [396] YIN, Libo a Jiabao FENG. Oil market uncertainty and international business cycle dynamics. *Energy Economics*. 2019, **81**, 728-740. ISSN 0140-9883.
- [397] YOO, Soonduck. Blockchain based financial case analysis and its implications. *Asia Pacific Journal of Innovation and Entrepreneurship*. 2017, **11**(3), 312-321. ISSN 2071-1395.
- [398] YOON, Seong-Min, Md AL MAMUN, Gazi Salah UDDIN a Sang Hoon KANG. Network connectedness and net spillover between financial and commodity markets. *The North American Journal of Economics and Finance*. 2019, **48**, 801-818. ISSN 1062-9408.
- [399] YUN, Jaeho. Bond risk premia in a small open economy with volatile capital flows: The case of Korea. *Journal of International Money and Finance*. 2019, **93**, 223-243. ISSN 0261-5606.
- [400] ZAJKOWSKI, Robert a Ada DOMAŃSKA. Differences in perception of regional pro-entrepreneurial policy: does obtaining support change a prospect? *Oeconomia Copernicana*. 2019, **10**(2), 359-384. ISSN 2353-1827.
- [401] ZAREMBA, Adam, George D. KAMBOURIS a Andreas KARATHANASOPOULOS. Two centuries of global financial market integration: Equities, government bonds, treasury bills, and currencies. *Economics Letters*. 2019, **182**, 26-29. ISSN 0165-1765.
- [402] ZERBIB, Olivier David. The effect of pro-environmental preferences on bond prices: Evidence from green bonds. *Journal of Banking & Finance*. 2019, **98**, 39-60. ISSN 0378-4266.
- [403] ZHANG, Xiaoge a Sankaran MAHADEVAN. Bayesian neural networks for flight trajectory prediction and safety assessment. *Decision Support Systems*. 2020, **131**. ISSN 0167-9236.

- [404] ZHANG, Xu, Yuanyuan ZOU, Shaoyuan LI a Shenghu XU. A weighted auto regressive LSTM based approach for chemical processes modeling. *Neurocomputing*. 2019, **367**, 64-74. ISSN 0925-2312.
- [405] ZHANG, Yong'an, Binbin YAN a Memon AASMA. A novel deep learning framework: Prediction and analysis of financial time series using CEEMD and LSTM. *Expert Systems with Applications*. 2020, **159**. ISSN 0957-4174.
- [406] ZHAO, Jiahui, Wei FAN a Xuehao ZHAI. Identification of land-use characteristics using bicycle sharing data: A deep learning approach. *Journal of Transport Geography*. 2020, **82**. ISSN 0966-6923.
- [407] ZHAO, Yang a Min-Teh YU. Measuring the liquidity impact on catastrophe bond spreads. *Pacific-Basin Finance Journal*. 2019, **56**, 197-210. ISSN 0927-538X.
- [408] ZHENG, Chao, Shaorong WANG, Yilu LIU, Chengxi LIU, Wei XIE, Chen FANG a Shu LIU. A Novel Equivalent Model of Active Distribution Networks Based on LSTM. *IEEE Transactions on Neural Networks and Learning Systems*. 2019, **30**(9), 2611-2624. ISSN 2162-237X.
- [409] ZHOU, Ligang a Kin Keung LAI. AdaBoost Models for Corporate Bankruptcy Prediction with Missing Data. *Computational Economics*. 2017, **50**(1), 69-94. ISSN 0927-7099.
- [410] ZHOU, Wei, Meiyong YANG a Liyan HAN. A nonparametric approach to pricing convertible bond via neural network. The ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing/3rd ACIS International Workshop on Self-Assembling Wireless Networks. 2007, 564-569. ISBN 1-5090-8595-5.
- [411] ZHU, Ke a Shiqing LING. Model-based pricing for financial derivatives. *Journal of Econometrics*. 2015, **187**(2), 447-457. ISSN 0304-4076.
- [412] ZMESKAL, Zdeněk a Dana DLUHOSOVA. Bond valuation under risk, flexibility and interaction on a game theory basis. *Financial Management of firms and Financial Institutions: 11th International Scientific Conference*. 2017, 951-958.
- [413] ZOBOLOTNYUK, Yuriy, Robert JONES a Chris VELD. An Empirical Comparison of Convertible Bond Valuation Models. *Financial Management*. 2010, **39**(2), 675-706. ISSN 0046-3892.
- [414] ŽEHROVÁ, Jana. *Finance*. Česká zemědělská univerzita v Praze, 2014, 223 s. ISBN 978-80-213-2440-4.

Seznam tabulek

Tabulka 1 Emisní podmínky dluhopisů GOS_1	71
Tabulka 2 Emisní podmínky dluhopisů SAF_1	71
Tabulka 3 Emisní podmínky dluhopisů SAF_2	72
Tabulka 4 Emisní podmínky dluhopisů SAF_3	72
Tabulka 5 Emisní podmínky dluhopisů TPH_1	73
Tabulka 6 Emisní podmínky dluhopisů TPH_1	74
Tabulka 7 Ukazatele analýzy absolutních ukazatelů finanční analýzy emitentů	75
Tabulka 8 Ukazatele analýzy poměrových ukazatelů finanční analýzy emitentů	76
Tabulka 9 Hodnocení Indexem bonity	77
Tabulka 10 Hodnocení indexem IN05	78
Tabulka 11 Hodnocení indexem IN99	78
Tabulka 12 Hodnocení modifikovaným Tafflerovým indexem.....	79
Tabulka 13 Statistické charakteristiky datového souboru.....	83
Tabulka 14 Statistické charakteristiky datového souboru.....	97
Tabulka 15 Přehled uchovaných vícevrstvých perceptronových sítí.....	112
Tabulka 16 Přehled uchovaných NN s GRL vrstvou.....	123
Tabulka 17 Přehled uchovaných NN s LSTM vrstvou	138
Tabulka 18 Vývoj VH před zdaněním společnosti CHNC, a.s. (v tis. Kč).....	155
Tabulka 19 Vertikální analýza aktiv společnosti CHNC, a.s.	157
Tabulka 20 Vertikální analýza pasiv společnosti CHNC, a.s.	157
Tabulka 21 Ukazatele rentability společnosti CHNC, a.s. (v procentech).....	158
Tabulka 22 Ukazatele aktivity společnosti CHNC, a.s.	159
Tabulka 23 Ukazatele likvidity společnosti CHNC, a.s.	160
Tabulka 24 Ukazatele zadluženosti společnosti CHNC, a.s.	161
Tabulka 25 Index bonity společnosti CHNC, a.s.	162
Tabulka 26 Index IN95 společnosti CHNC, a.s.	163
Tabulka 27 Index IN99 společnosti CHNC, a.s.	163
Tabulka 28 Modifikovaný Tafflerův index společnosti CHNC, a.s.	164
Tabulka 29 Výsledky vícevrstvých perceptronových sítí	164
Tabulka 30 Výsledky NN obsahující GRL vrstvu	165
Tabulka 31 Výsledky NN obsahující LSTM vrstvu.....	165
Tabulka 32 Vývoj VH před zdaněním společnosti SAF, A.S. (v tis. Kč).....	168

Tabulka 33 Vertikální analýza aktiv společnosti SAF, A.S.	169
Tabulka 34 Vertikální analýza pasiv společnosti SAF, A.S.	170
Tabulka 35 Ukazatele rentability společnosti SAF, A.S. (v procentech).....	171
Tabulka 36 Ukazatele likvidity společnosti SAF, A.S.	172
Tabulka 37 Ukazatele zadluženosti společnosti SAF, A.S.	173
Tabulka 38 Index IN95 společnosti SAF, A.S.	174
Tabulka 39 Index IN99 společnosti SAF, A.S.	175
Tabulka 40 Výsledky vícevrstevných perceptronových sítí	175
Tabulka 41 Výsledky NN obsahující GRL vrstvu	176
Tabulka 42 Výsledky NN obsahující LSTM vrstvu.....	176
Tabulka 43 Vývoj VH před zdaněním společnosti TP, a.s. (v tis. Kč)	179
Tabulka 44 Vertikální analýza aktiv společnosti TP, a.s.	181
Tabulka 45 Vertikální analýza pasiv společnosti TP, a.s.	182
Tabulka 46 Ukazatele rentability společnosti TP, a.s. (v procentech)	182
Tabulka 47 Ukazatele aktivity společnosti TP, a.s.....	183
Tabulka 48 Ukazatele likvidity společnosti TP, a.s. (v %)	184
Tabulka 49 Ukazatele zadluženosti společnosti TP, a.s.	185
Tabulka 50 Index bonity společnosti TP, a.s.	186
Tabulka 51 Index IN95 společnosti TP, a.s.	187
Tabulka 52 Index IN99 společnosti TP, a.s.	187
Tabulka 53 Modifikovaný Tafflerův index společnosti TP, a.s.	188
Tabulka 54 Výsledky vícevrstevných perceptronových sítí	188
Tabulka 55 Výsledky NN obsahující GRL vrstvu	189
Tabulka 56 Výsledky NN obsahující LSTM vrstvu.....	189
Tabulka 57 Vývoj VH před zdaněním společnosti BS, a.s. (v tis. Kč)	192
Tabulka 58 Vertikální analýza aktiv společnosti BS, a.s.	193
Tabulka 59 Vertikální analýza pasiv společnosti BS, a.s.....	194
Tabulka 60 Ukazatele rentability společnosti BS, a.s. (v procentech).....	195
Tabulka 61 Ukazatele aktivity společnosti BS, a.s.	196
Tabulka 62 Ukazatele likvidity společnosti BS, a.s.	197
Tabulka 63 Ukazatele zadluženosti společnosti BS, a.s.....	198
Tabulka 64 Index bonity společnosti BS, a.s.	199
Tabulka 65 Index IN95 společnosti BS, a.s.	199
Tabulka 66 Index IN99 společnosti BS, a.s.	200

Tabulka 67 Modifikovaný Tafflerův index společnosti BS, a.s.....	201
Tabulka 68 Výsledky vícevrstvých perceptronových sítí	201
Tabulka 69 Výsledky NN obsahující GRL vrstvu	201
Tabulka 70 Výsledky NN obsahující LSTM vrstvu.....	202
Tabulka 71 Počet společností s povolením k provozování hazardních her (ZoL i ZHH) podle typu, k 1. 1. 2018, k 1. 1. 2019 a k 1. 1. 2020	230
Tabulka 72 Provozovatelé land-based kurzových sázek k 4. 1. 2019	230
Tabulka 73 Provozovatelé on-line kurzových sázek k 1. 1. 2020.....	231
Tabulka 74 Měnové finanční instituce v ČR k 31. 7. 2020.....	231
Tabulka 75 Přehled uchovaných vícevrstvých perceptronových sítí.....	233
Tabulka 76 Přehled uchovaných NN s GRL vrstvou	236
Tabulka 77 Přehled uchovaných NN s LSTM vrstvou	241
Tabulka 78 Predikce Spreadu podle vícevrstvých perceptronových sítí pro SAF_1, SAF_2 a SAF_3.....	247
Tabulka 79 Predikce Spreadu podle NN s GRL vrstvou pro SAF_1, SAF_2 a SAF_3.....	247
Tabulka 80 Predikce Spreadu podle NN s LSTM vrstvou pro SAF_1, SAF_2 a SAF_3.....	247
Tabulka 81 Přehled uchovaných vícevrstvých perceptronových sítí.....	248
Tabulka 82 Přehled uchovaných NN s GRL vrstvou	250
Tabulka 83 Přehled uchovaných NN s LSTM vrstvou	253
Tabulka 84 Predikce Spreadu podle vícevrstvých perceptronových sítí pro GOS_1, TPH_1 a TPHnet_1.....	259
Tabulka 85 Predikce Spreadu podle NN s GRL vrstvou pro GOS_1, TPH_1 a TPHnet_1.	259
Tabulka 86 Predikce Spreadu podle NN s LSTM vrstvou pro GOS_1, TPH_1 a TPHnet_1.	260
Tabulka 87 Přehled uchovaných vícevrstvých perceptronových sítí.....	260
Tabulka 88 Přehled uchovaných NN s GRL vrstvou	264
Tabulka 89 Přehled uchovaných NN s LSTM vrstvou	269
Tabulka 90 Statistiky časové řady a vyrovnaných časových řad	280
Tabulka 91 Statistiky predikovaných časových řad	280
Tabulka 92 Predikce za pomoci RF-NN_LIN1–RF-NN_LIN5	281
Tabulka 93 Statistiky časové řady a vyrovnaných časových řad	287
Tabulka 94 Statistiky predikovaných časových řad	288
Tabulka 95 Predikce za pomoci RF-NN_GRL1–RF-NN_GRL5	289

Tabulka 96 Statistiky časové řady a vyrovnaných časových řad	295
Tabulka 97 Statistiky predikovaných časových řad	296
Tabulka 98 Predikce za pomoci RF-NN_LSTM1–RF-NN_LSTM5	297
Tabulka 99 Diskontní sazba GOS_1	298
Tabulka 100 Ocenění dluhopisů GOS_1	298
Tabulka 101 Diskontní sazba SAF_1	299
Tabulka 102 Ocenění dluhopisů SAF_1	299
Tabulka 103 Diskontní sazba SAF_2	300
Tabulka 104 Ocenění dluhopisů SAF_2	300
Tabulka 105 Diskontní sazba SAF_3	301
Tabulka 106 Ocenění dluhopisů SAF_3	301
Tabulka 107 Diskontní sazba TPH_1	302
Tabulka 108 Ocenění dluhopisů TPH_1	302
Tabulka 109 Diskontní sazba TPHnet_1	303
Tabulka 110 Ocenění dluhopisů TPHnet_1	303

Seznam obrázků

Obrázek 1 Schéma vícevrstvé perceptronové sítě (s Linear Layer).....	84
Obrázek 2 Schéma rekurentní sítě (s Gated Recurrent Layer).....	85
Obrázek 3 Schéma rekurentní sítě (s Long Short Term Memory Layer).....	87
Obrázek 4 Schéma vícevrstvé perceptronové sítě (s Linear Layer).....	98
Obrázek 5 Schéma rekurentní sítě (s Gated Recurrent Layer).....	99
Obrázek 6 Schéma rekurentní sítě (s Long Short Term Memory Layer).....	101
Obrázek 7 Schéma vícevrstvé perceptronové sítě (s Linear Layer).....	105
Obrázek 8 Schéma rekurentní sítě (s Gated Recurrent Layer).....	106
Obrázek 9 Schéma rekurentní sítě (s Long Short Term Memory Layer).....	108
Obrázek 10 Základní struktura sítě B-NN_LIN1	113
Obrázek 11 Základní struktura sítě B-NN_LIN1 – graficky.....	113
Obrázek 12 Konfuzní matice trénovacího souboru dat – B-NN_LIN1	114
Obrázek 13 Konfuzní matice testovacího souboru dat – B-NN_LIN1	115
Obrázek 14 Základní struktura sítě B-NN_LIN2	115
Obrázek 15 Konfuzní matice trénovacího souboru dat – B-NN_LIN2	116
Obrázek 16 Konfuzní matice testovacího souboru dat – B-NN_LIN2	117
Obrázek 17 Základní struktura sítě B-NN_LIN3	117
Obrázek 18 Konfuzní matice trénovacího souboru dat – B-NN_LIN3	118
Obrázek 19 Konfuzní matice testovacího souboru dat – B-NN_LIN3	119
Obrázek 20 Základní struktura sítě B-NN_LIN4	119
Obrázek 21 Konfuzní matice trénovacího souboru dat – B-NN_LIN4	120
Obrázek 22 Konfuzní matice testovacího souboru dat – B-NN_LIN4	121
Obrázek 23 Základní struktura sítě B-NN_LIN5	121
Obrázek 24 Konfuzní matice trénovacího souboru dat – B-NN_LIN5	122
Obrázek 25 Konfuzní matice testovacího souboru dat – B-NN_LIN5	122
Obrázek 26 Základní struktura sítě B-NN_GRL1	124
Obrázek 27 Konfuzní matice trénovacího souboru dat – B-NN_GRL1	125
Obrázek 28 Konfuzní matice testovacího souboru dat – B-NN_GRL1	126
Obrázek 29 Základní struktura sítě B-NN_GRL2.....	127
Obrázek 30 Konfuzní matice trénovacího souboru dat – B-NN_GRL2	128
Obrázek 31 Konfuzní matice testovacího souboru dat – B-NN_GRL2.....	129
Obrázek 32 Základní struktura sítě B-NN_GRL3.....	130

Obrázek 33	Konfuzní matice trénovacího souboru dat – B-NN_GRL3	131
Obrázek 34	Konfuzní matice testovacího souboru dat – B-NN_GRL3.....	132
Obrázek 35	Základní struktura sítě B-NN_GRL4.....	133
Obrázek 36	Konfuzní matice trénovacího souboru dat – B-NN_GRL4	134
Obrázek 37	Konfuzní matice testovacího souboru dat – B-NN_GRL4.....	135
Obrázek 38	Základní struktura sítě B-NN_GRL5.....	136
Obrázek 39	Konfuzní matice trénovacího souboru dat – B-NN_GRL5	137
Obrázek 40	Konfuzní matice testovacího souboru dat – B-NN_GRL5.....	137
Obrázek 41	Základní struktura sítě B-NN_LSTM1	139
Obrázek 42	Konfuzní matice trénovacího souboru dat – B-NN_LSTM1	140
Obrázek 43	Konfuzní matice testovacího souboru dat – B-NN_LSTM1	141
Obrázek 44	Základní struktura sítě B-NN_LSTM2	142
Obrázek 45	Konfuzní matice trénovacího souboru dat – B-NN_LSTM2	143
Obrázek 46	Konfuzní matice testovacího souboru dat – B-NN_LSTM2	144
Obrázek 47	Základní struktura sítě B-NN_LSTM3	145
Obrázek 48	Konfuzní matice trénovacího souboru dat – B-NN_LSTM3	146
Obrázek 49	Konfuzní matice testovacího souboru dat – B-NN_LSTM3	147
Obrázek 50	Základní struktura sítě B-NN_LSTM4	148
Obrázek 51	Konfuzní matice trénovacího souboru dat – B-NN_LSTM4	149
Obrázek 52	Konfuzní matice testovacího souboru dat – B-NN_LSTM4	150
Obrázek 53	Základní struktura sítě B-NN_LSTM5	151
Obrázek 54	Konfuzní matice trénovacího souboru dat – B-NN_LSTM5	152
Obrázek 55	Konfuzní matice testovacího souboru dat – B-NN_LSTM5	153
Obrázek 56	Vývoj aktiv společnosti CHNC, a.s. (v tis. Kč).....	154
Obrázek 57	Vývoj pasiv společnosti CHNC, a.s. (v tis. Kč)	154
Obrázek 58	Vývoj VH před zdaněním společnosti CHNC, a.s. (v tis. Kč)	156
Obrázek 59	Vývoj VH před zdaněním (za jednotlivé měsíce) roku 2020 společnosti CHNC, a.s. (v tis. Kč).....	156
Obrázek 60	Vývoj ROA a ROE společnosti CHNC, a.s. (v procentech)	159
Obrázek 61	Vývoj likvidity společnosti CHNC, a.s.	160
Obrázek 62	Vývoj ukazatelů zadluženosti společnosti CHNC, a.s.....	161
Obrázek 63	Vývoj aktiv společnosti SAF, A.S. (v tis. Kč).....	167
Obrázek 64	Vývoj pasiv společnosti SAF, A.S. (v tis. Kč)	167
Obrázek 65	Vývoj VH před zdaněním společnosti SAF, A.S. (v tis. Kč)	168

Obrázek 66 Vývoj VH před zdaněním za jednotlivé měsíce roku 2020 společnosti SAF, A.S. (v tis. Kč).....	169
Obrázek 67 Vývoj ROA společnosti SAF, A.S. (v procentech)	171
Obrázek 68 Vývoj ROE společnosti SAF, A.S. (v procentech).....	172
Obrázek 69 Vývoj likvidity společnosti SAF, A.S.	173
Obrázek 70 Vývoj ukazatelů zadluženosti společnosti SAF, A.S.....	174
Obrázek 71 Vývoj aktiv společnosti TP, a.s. (v tis. Kč)	178
Obrázek 72 Vývoj pasiv společnosti TP, a.s. (v tis. Kč).....	179
Obrázek 73 Vývoj VH před zdaněním společnosti TP, a.s. (v tis. Kč).....	180
Obrázek 74 Vývoj VH před zdaněním (za jednotlivé měsíce) roku 2020 společnosti TP, a.s. (v tis. Kč).....	180
Obrázek 75 Vývoj ROA a ROE společnosti TP, a.s. (v %)	183
Obrázek 76 Vývoj likvidity společnosti TP, a.s. (v %).....	184
Obrázek 77 Vývoj zadluženosti společnosti TP, a.s. (v %)	185
Obrázek 78 Vývoj aktiv společnosti BS, a.s. (v tis. Kč)	191
Obrázek 79 Vývoj pasiv společnosti BS, a.s. (v tis. Kč).....	191
Obrázek 80 Vývoj VH před zdaněním společnosti BS, a.s. (v tis. Kč).....	192
Obrázek 81 Vývoj VH před zdaněním (za jednotlivé měsíce) roku 2020 společnosti BS, a.s. (v tis. Kč).....	193
Obrázek 82 Vývoj ROA společnosti BS, a.s. (v procentech)	195
Obrázek 83 Vývoj ROE společnosti BS, a.s. (v procentech).....	196
Obrázek 84 Vývoj likvidity společnosti BS, a.s.....	197
Obrázek 85 Vývoj ukazatelů zadluženosti společnosti BS, a.s.....	198
Obrázek 86 Objem trhu s hazardními hrami v ČR v 2002–2018, v mld. Kč.....	209
Obrázek 87 Příjmy z hazardních her v ČR 2002–2019, v mld. Kč.....	210
Obrázek 88 Celkový objem peněz vložených do hry a vyplacených na výhrách podle typu hry v r. 2019.....	210
Obrázek 89 Změna objemu příjmu provozovatelů podle jednotlivých typů hazardních her v l. 2013–2018, v %	211
Obrázek 90 Vývoj podílů typů hazardních her na trhu podle příjmů ze hry v l. 2006–2019, v %	212
Obrázek 91 Vývoj příjmů ze hry u hlavních typů hazardních her v l. 2002–2019, v mld. Kč	212
Obrázek 92 Odvody z technických her a ostatních hazardních her v l. 2013–2019, v mil. Kč.	215

Obrázek 93 Podíl státního rozpočtu a obecních rozpočtů na celkových příjmech veřejných rozpočtů ze zdanění hazardních her v l. 2013–2019, v %	215
Obrázek 94 Vývoj počtu obcí s OZV regulující provozování hazardních her v ČR v l. 2009–2019.....	216
Obrázek 95 Prevalence hazardního hraní v dospělé populaci 15+ let – srovnání studií realizovaných v l. 2012–2018, v %	218
Obrázek 96 Prevalence hazardního hraní v populaci mladých dospělých 15–34 let – srovnání studií realizovaných v l. 2012–2018, v %	218
Obrázek 97 Vývoj podílu land-based a on-line hazardních her na trhu podle příjmu provozovatelů v l. 2008–2019, v %.....	219
Obrázek 98 Průměrná roční míra inflace v letech 2000–2019 (v procentech).....	225
Obrázek 99 Vývoj úrokových sazeb ČNB (v %)	226
Obrázek 100 Vývoj vybraných úrokových sazeb MFI (v %)	227
Obrázek 101 Úvěry soukromému sektoru a roční míry růstu úvěrů nefinančním podnikům a domácnostem (v mld. Kč)	227
Obrázek 102 Emitované dluhopisy v ČR (v mil. Kč)	228
Obrázek 103 Obchodující subjekty s cennými papíry v ČR	232
Obrázek 104 Základní struktura sítě D-FS-NN_LIN1	234
Obrázek 105 Základní struktura sítě D-FS-NN_LIN2.....	234
Obrázek 106 Základní struktura sítě D-FS-NN_LIN3.....	235
Obrázek 107 Základní struktura sítě D-FS-NN_LIN4.....	235
Obrázek 108 Základní struktura sítě D-FS-NN_LIN5.....	236
Obrázek 109 Základní struktura sítě D-FS-NN_GRL1.....	237
Obrázek 110 Základní struktura sítě D-FS-NN_GRL2.....	238
Obrázek 111 Základní struktura sítě D-FS-NN_GRL3.....	239
Obrázek 112 Základní struktura sítě D-FS-NN_GRL4.....	240
Obrázek 113 Základní struktura sítě D-FS-NN_GRL5.....	241
Obrázek 114 Základní struktura sítě D-FS-NN_LSTM1	242
Obrázek 115 Základní struktura sítě D-FS-NN_LSTM2.....	243
Obrázek 116 Základní struktura sítě D-FS-NN_LSTM3	244
Obrázek 117 Základní struktura sítě D-FS-NN_LSTM4.....	245
Obrázek 118 Základní struktura sítě D-FS-NN_LSTM5	246
Obrázek 119 Základní struktura sítě D-HAZ-NN_LIN1	248
Obrázek 120 Základní struktura sítě D-HAZ-NN_LIN2	248

Obrázek 121 Základní struktura sítě D-HAZ-NN_LIN3	249
Obrázek 122 Základní struktura sítě D-HAZ-NN_LIN4	249
Obrázek 123 Základní struktura sítě D-HAZ-NN_LIN5	250
Obrázek 124 Základní struktura sítě D-HAZ-NN_GRL1	251
Obrázek 125 Základní struktura sítě D-HAZ-NN_GRL2	251
Obrázek 126 Základní struktura sítě D-HAZ-NN_GRL3	252
Obrázek 127 Základní struktura sítě D-HAZ-NN_GRL4	252
Obrázek 128 Základní struktura sítě D-HAZ-NN_GRL5	253
Obrázek 129 Základní struktura sítě D-HAZ-NN_LSTM1	254
Obrázek 130 Základní struktura sítě D-HAZ-NN_LSTM2	255
Obrázek 131 Základní struktura sítě D-HAZ-NN_LSTM3	256
Obrázek 132 Základní struktura sítě D-HAZ-NN_LSTM4	257
Obrázek 133 Základní struktura sítě D-HAZ-NN_LSTM5	258
Obrázek 134 Základní struktura sítě RF-NN_LIN1	261
Obrázek 135 Základní struktura sítě RF-NN_LIN2	261
Obrázek 136 Základní struktura sítě RF-NN_LIN3	262
Obrázek 137 Základní struktura sítě RF-NN_LIN4	263
Obrázek 138 Základní struktura sítě RF-NN_LIN5	263
Obrázek 139 Základní struktura sítě RF-NN_GRL1	265
Obrázek 140 Základní struktura sítě RF-NN_GRL2	266
Obrázek 141 Základní struktura sítě RF-NN_GRL3	267
Obrázek 142 Základní struktura sítě RF-NN_GRL4	268
Obrázek 143 Základní struktura sítě RF-NN_GRL5	269
Obrázek 144 Základní struktura sítě RF-NN_LSTM1	270
Obrázek 145 Základní struktura sítě RF-NN_LSTM2	271
Obrázek 146 Základní struktura sítě RF-NN_LSTM3	272
Obrázek 147 Základní struktura sítě RF-NN_LSTM4	273
Obrázek 148 Základní struktura sítě RF-NN_LSTM5	274
Obrázek 149 Predikce risk free pomocí vícevrstvých perceptronových NN – RF-NN_LIN1	274
Obrázek 150 Rezidua RF-NN_LIN1	275
Obrázek 151 Predikce risk free pomocí vícevrstvých perceptronových NN – RF-NN_LIN1	275
Obrázek 152 Rezidua RF-NN_LIN2	276

Obrázek 153 Predikce risk free pomocí vícevrstevých perceptronových NN – RF-NN_LIN3	276
Obrázek 154 Rezidua RF-NN_LIN3.....	277
Obrázek 155 Predikce risk free pomocí vícevrstevých perceptronových NN – RF-NN_LIN4	277
Obrázek 156 Rezidua RF-NN_LIN4.....	278
Obrázek 157 Predikce risk free pomocí vícevrstevých perceptronových NN – RF-NN_LIN4	278
Obrázek 158 Rezidua RF-NN_LIN4.....	279
Obrázek 159 Predikce risk free pomocí vícevrstevých perceptronových sítí – přehled všech predikcí.....	279
Obrázek 160 Přehled všech predikovaných vývoju bezrizikových sazeb za pomoci vícevrstevých perceptronových sítí	280
Obrázek 161 Přehled všech predikcí včetně křivky skutečných hodnot risk free.....	281
Obrázek 162 Predikce risk free pomocí RF-NN_GRL1	282
Obrázek 163 Rezidua RF-NN_GRL1	282
Obrázek 164 Predikce risk free pomocí RF-NN_GRL2	283
Obrázek 165 Rezidua RF-NN_GRL2	283
Obrázek 166 Predikce risk free pomocí RF-NN_GRL3	284
Obrázek 167 Rezidua RF-NN_GRL3	284
Obrázek 168 Predikce risk free pomocí RF-NN_GRL4	285
Obrázek 169 Rezidua RF-NN_GRL4	285
Obrázek 170 Predikce risk free pomocí RF-NN_GRL5	286
Obrázek 171 Rezidua RF-NN_GRL5	286
Obrázek 172 Predikce risk free pomocí neuronových sítí s GRL vrstvou – přehled všech predikcí.....	287
Obrázek 173 Přehled všech predikovaných vývoju bezrizikových sazeb za pomoci neuronových sítí s GRL vrstvou.....	288
Obrázek 174 Přehled všech predikcí (NN s GRL vrstvou) včetně křivky skutečných hodnot risk free.....	289
Obrázek 175 Predikce risk free pomocí RF-NN_LSTM1	290
Obrázek 176 Rezidua RF-NN_LSTM1.....	290
Obrázek 177 Predikce risk free pomocí RF-NN_LSTM2	291
Obrázek 178 Rezidua RF-NN_LSTM2.....	291

Obrázek 179 Predikce risk free pomocí RF-NN_LSTM3	292
Obrázek 180 Rezidua RF-NN_LSTM3.....	292
Obrázek 181 Predikce risk free pomocí RF-NN_LSTM4	293
Obrázek 182 Rezidua RF-NN_LSTM4.....	293
Obrázek 183 Predikce risk free pomocí RF-NN_LSTM5	294
Obrázek 184 Rezidua RF-NN_LSTM5.....	294
Obrázek 185 Predikce risk free pomocí neuronových sítí s LSTM vrstvou – přehled všech predikcí.....	295
Obrázek 186 Přehled všech predikovaných vývoju bezrizikových sazeb za pomoci neuronových sítí s LSTM vrstvou	296
Obrázek 187 Přehled všech predikcí (NN s LSTM vrstvou) včetně křivky skutečných hodnot risk free.....	297

Seznam zkratek

A.S.	Akciová společnost
ABMRNN	Obousměrné opakující se neuronové síť
ACC	Přesnost
ADAM	Optimalizační algoritmus
ANFIS	Adaptivní neurofuzzní odvozovací systém
ANOVA	Analysis of Variance
ARCH	Autoregressive Conditional Heteroskedasticity
ARIMA	Autoregresní integrovaný klouzavý průměr
AUC	Plocha pod křivkou
B2B	Business-to-Business
B2C	Business-to-Consumer
BP	Síť zpětného šíření
BS	Brierovo skóre
BSM	Black-Scholes-Merton
CAPM	Model oceňování kapitálových aktiv
CART	Regresní a klasifikační stromy
CAT	Katastrofické dluhopisy
CBOE	Chicago Board Options Exchange
CDS	Credit Default Swap
CEEMD	Souborový empirický režim rozkladu
CEP	Environmentální výkonnosti společnosti
CL	Computational Linguistics
CNN	Konvoluční neuronové síť
CODAS	Combinative Distance-Based Assessment
CoVAR	Podmíněná hodnota v riziku
COVID-19	Coronavirus Disease 2019 (pandemie koronaviru)
CPI	Index spotřebitelských cen
CRA	China Bond Rating Co. Ltd
CSAN	Caritas Social Action Network
CSR	Společenská odpovědnost firem
CZ NACE	Odvětvová klasifikace ekonomických činností
CZK	Česká koruna

ČKLP	Česká komora loterijního průmyslu
ČNB	Česká národní banka
ČR	Česká republika
DCC	Dynamická podmíněná korelace
DEA	Data Envelopment Analysis (Analýza obálky dat)
DEMATEL	Decision Making Trial and Evaluation laboratoř
DMA	Dynamické průměrování modelu
DNN	Dopředné neuronové sítě
DSGE	Dynamic Stochastic General Equilibrium (Dynamické stochastické modelování obecné rovnováhy)
DWT	Diskrétní vlnková transformace
ECB	Evropská centrální banka
EMU	Evropská měnová unie
ESG	Hodnocení metod udržitelnosti
EU	Evropská unie
EVA	Ekonomická přidaná hodnota
FD	Financial Development Index (Světové ekonomické fórum)
FMADM	Fuzzy Multiple Attribute Decision-Making
GARCH	Generalized Autoregressive Conditional Heteroskedasticity (Autoregresní podmíněný model heteroskedasticity)
GCI	Globální index konkurenceschopnosti
GRL	Generalized Richardson Lucy
HDP	Hrubý domácí produkt
HLN	Hopfield Lagrangeova síť
ID	Identifikační číslo, identifikace
IFAHP	Intuitivní fuzzy analytické hierarchie
IFR	Internet Financial Reporting
IFRS	International Financial Reporting Standards (Mezinárodní standardy účetního výkaznictví)
ISSA	Kombinovaný model analýzy singulárního spektra
JRNN	Jordan Recurrent Neural Networks
KPI	Key Performance Indicator (Klíčové ukazatele výkonnosti)
KPM	Kraljic Portfolio Matrix
KS	Statistika Kolmogorov-Smirnov

LSTM	Long Short-Term Memory (Dlouhodobá krátkodobá paměť)
MABAC	Metoda vícenásobného přiblížení hraniční aproximace
MANOVA	Multivariate Analysis of Variance (Vícerozměrná analýza rozptylu)
MARS	Multivariační adaptivní regresní spline
MCDM	Multi -Criterion Decision-Making (Vícekriteriální analýza variant)
MES	Mezní očekávaný schodek
MLP	Vícevrstvá perceptronová síť
MOO-GA	Genetický algoritmus optimalizace více cílů
MOVE	Merill Lynch Option
NEAT	NeuroEvolution of Augmenting Topologies (Genetický algoritmus)
NER	Named Entity Recognition (Rozpoznání pojmenovaných entit)
NLP	Natural Language Processing (Zpracování přirozeného jazyka)
NN	Neural Network (Neuronová síť)
OECD	Organisation for Economic Co-operation and Development (Organizace pro hospodářskou spolupráci a rozvoj)
OLS	Ordinary Least Squares (Metoda nejmenších čtverců)
OMT	Přímé měnové transakce
OZV	Obecné závazné vyhlášky
PCA	Analýza hlavních komponent
PEPP	Pandemic Emergency Purchase Program
PEST	Analýza politických, ekonomických, sociálních a technologických faktorů
QE	Kvantitativní uvolňování
RF	Random Forest (Náhodný les)
RMSE	Root Mean Square Error (Střední kvadratická chyba)
RNN	Rekurentní neuronové síť
SDF	Stochastický diskontní faktor
SEM	Modelování strukturálních rovnic
SFA	Suitability, Feasibility & Acceptability
SNN	Pulzní neuronové síť
SOX	Sarbanes-Oxley Act
SRISK	Index systémového rizika
STI	Stochastic Tail Index
SWOT	Analýza silných a slabých stránek, příležitostí a hrozeb
TH	Technická hra

TMT	Top Management Team
USA	Spojené státy americké
USD	Americký dolar
VO	Výzkumná otázka
VZZ	Výkaz zisku a ztrát
WT	Waveletova transformace
XGBoost	Extrémní gradientová podpora
ZHN	Zákon o hazardních hrách
ZOL	Zákon o loterijním průmyslu

Přílohy

Příloha A: Tabulka Predikce za pomoci RF-NN_LIN1–RF-NN_LIN5

Datum	RF-NN_LIN1	RF-NN_LIN2	RF-NN_LIN3	RF-NN_LIN4	RF-NN_LIN5
30.09.2020	0,0086	0,01	0,009	0,0096	0,0096
31.10.2020	0,0089	0,0117	0,0088	0,0099	0,0105
30.11.2020	0,0093	0,013	0,0088	0,0098	0,0111
31.12.2020	0,0089	0,0135	0,0087	0,0095	0,0108
31.01.2021	0,0083	0,0132	0,0086	0,0091	0,0108
28.02.2021	0,0073	0,013	0,0084	0,0084	0,0103
31.03.2021	0,0064	0,0131	0,0082	0,0081	0,0101
30.04.2021	0,0054	0,0134	0,0077	0,0074	0,0095
31.05.2021	0,0053	0,0155	0,0076	0,0077	0,0108
30.06.2021	0,0053	0,0177	0,0077	0,0081	0,0121
31.07.2021	0,0051	0,0196	0,0078	0,0085	0,0132
31.08.2021	0,005	0,0208	0,0076	0,0087	0,0139
30.09.2021	0,0051	0,0217	0,0074	0,0089	0,0147
31.10.2021	0,005	0,0222	0,0073	0,009	0,0153
30.11.2021	0,0046	0,0228	0,0072	0,0089	0,0157
31.12.2021	0,0041	0,024	0,0071	0,0089	0,0166
31.01.2022	0,0036	0,0257	0,007	0,009	0,0172
28.02.2022	0,0033	0,0276	0,0068	0,0094	0,018
31.03.2022	0,0033	0,029	0,0065	0,01	0,0187
30.04.2022	0,0037	0,0303	0,0063	0,011	0,0196
31.05.2022	0,0041	0,0318	0,0062	0,012	0,0201
30.06.2022	0,0045	0,0335	0,006	0,0128	0,0204
31.07.2022	0,0051	0,0355	0,0057	0,0134	0,0206
31.08.2022	0,0057	0,0377	0,0054	0,014	0,0207
30.09.2022	0,0061	0,0399	0,0051	0,0147	0,0207
31.10.2022	0,0064	0,0419	0,0048	0,0155	0,0206
30.11.2022	0,0068	0,0439	0,0045	0,0166	0,0204
31.12.2022	0,0073	0,0462	0,0042	0,0178	0,0199
31.01.2023	0,008	0,0487	0,0039	0,0188	0,0194
28.02.2023	0,0088	0,0514	0,0037	0,0196	0,0187
31.03.2023	0,0097	0,0543	0,0036	0,0201	0,0179
30.04.2023	0,0106	0,0572	0,0036	0,0204	0,0168
31.05.2023	0,0115	0,0602	0,0038	0,0206	0,0157
30.06.2023	0,0125	0,0635	0,0041	0,0207	0,0147
31.07.2023	0,0134	0,0666	0,0044	0,0207	0,0141
31.08.2023	0,0143	0,0697	0,0047	0,0205	0,0139
30.09.2023	0,0153	0,0732	0,0051	0,02	0,0139
31.10.2023	0,0163	0,0765	0,0056	0,0193	0,0139
30.11.2023	0,0173	0,0799	0,0062	0,0185	0,0139

31.12.2023	0,0183	0,0832	0,0068	0,0177	0,0138
31.01.2024	0,0191	0,0861	0,0075	0,0169	0,0135
29.02.2024	0,0196	0,0888	0,0082	0,0162	0,0131
31.03.2024	0,0199	0,0913	0,0089	0,0156	0,0125
30.04.2024	0,02	0,0936	0,0097	0,015	0,012
31.05.2024	0,02	0,0956	0,0106	0,0145	0,0118
30.06.2024	0,0198	0,0981	0,0116	0,0141	0,012
31.07.2024	0,0195	0,1002	0,0126	0,0138	0,0122
31.08.2024	0,0191	0,1018	0,0137	0,0136	0,0123
30.09.2024	0,0186	0,103	0,0149	0,0135	0,0123
31.10.2024	0,018	0,1032	0,0161	0,0134	0,0122
30.11.2024	0,0174	0,103	0,0174	0,0133	0,0122
31.12.2024	0,0166	0,1029	0,0186	0,0132	0,0122
31.01.2025	0,0156	0,1032	0,0197	0,0131	0,0123
28.02.2025	0,0146	0,1039	0,0207	0,013	0,0125
31.03.2025	0,0138	0,1049	0,0217	0,013	0,0129
30.04.2025	0,0133	0,1051	0,0225	0,013	0,0134
31.05.2025	0,0131	0,1037	0,0232	0,013	0,0139
30.06.2025	0,0131	0,1016	0,0236	0,0131	0,0143
31.07.2025	0,0132	0,0996	0,0238	0,0132	0,0146
31.08.2025	0,0133	0,0982	0,0237	0,0133	0,015
30.09.2025	0,0133	0,0981	0,0234	0,0133	0,0154
31.10.2025	0,0132	0,099	0,0228	0,0133	0,0159
30.11.2025	0,013	0,0995	0,022	0,0133	0,0164
31.12.2025	0,0127	0,0982	0,0211	0,0134	0,0169
31.01.2026	0,0124	0,0948	0,02	0,0135	0,0174
28.02.2026	0,0122	0,0904	0,0187	0,0136	0,0179
31.03.2026	0,0122	0,0872	0,017	0,0137	0,0183
30.04.2026	0,0123	0,0864	0,0152	0,0138	0,0186
31.05.2026	0,0124	0,0878	0,0139	0,0138	0,0189
30.06.2026	0,0124	0,0895	0,0129	0,0138	0,0191
31.07.2026	0,0124	0,0895	0,012	0,0138	0,0193
31.08.2026	0,0124	0,0865	0,0109	0,0138	0,0194
30.09.2026	0,0124	0,0808	0,0098	0,0138	0,0194
31.10.2026	0,0124	0,0748	0,0089	0,0139	0,0193
30.11.2026	0,0125	0,0719	0,0083	0,014	0,0191
31.12.2026	0,0127	0,0731	0,008	0,014	0,0188
31.01.2027	0,013	0,0767	0,0079	0,014	0,0184
28.02.2027	0,0133	0,0796	0,0081	0,014	0,0179
31.03.2027	0,0136	0,0785	0,0083	0,014	0,0172
30.04.2027	0,0139	0,0735	0,0083	0,014	0,0163
31.05.2027	0,0142	0,0667	0,0081	0,014	0,0154
30.06.2027	0,0145	0,0598	0,0077	0,014	0,0145
31.07.2027	0,0148	0,0579	0,0074	0,014	0,0139
31.08.2027	0,0151	0,061	0,0071	0,014	0,0137

30.09.2027	0,0154	0,065	0,0069	0,014	0,0137
31.10.2027	0,0157	0,0675	0,0067	0,014	0,0137
30.11.2027	0,016	0,0664	0,0065	0,014	0,0136
31.12.2027	0,0163	0,0633	0,0063	0,014	0,0133
31.01.2028	0,0166	0,0579	0,0061	0,014	0,0129
29.02.2028	0,0168	0,0507	0,0059	0,014	0,0125
31.03.2028	0,017	0,0482	0,0056	0,014	0,0121
30.04.2028	0,0171	0,0472	0,0053	0,014	0,0118
31.05.2028	0,0172	0,0462	0,0049	0,014	0,0118
30.06.2028	0,0172	0,0461	0,0045	0,014	0,0119
31.07.2028	0,0172	0,0454	0,0041	0,014	0,012
31.08.2028	0,0171	0,0426	0,0038	0,014	0,0121
30.09.2028	0,017	0,039	0,0036	0,014	0,0122
31.10.2028	0,0168	0,0341	0,0035	0,014	0,0122
30.11.2028	0,0166	0,0284	0,0035	0,014	0,0122
31.12.2028	0,0164	0,0234	0,0037	0,014	0,0123
31.01.2029	0,0161	0,0181	0,004	0,014	0,0125
28.02.2029	0,0158	0,0122	0,0043	0,014	0,0128
31.03.2029	0,0154	0,0055	0,0046	0,014	0,0133
30.04.2029	0,015	0,0003	0,0049	0,014	0,0138
31.05.2029	0,0145	-0,0017	0,0054	0,014	0,0142
30.06.2029	0,014	-0,0002	0,006	0,014	0,0146
31.07.2029	0,0135	0,0021	0,0067	0,014	0,0151
31.08.2029	0,013	0,0053	0,0074	0,014	0,0156
30.09.2029	0,0126	0,0109	0,0081	0,014	0,0161
31.10.2029	0,0123	0,0144	0,0088	0,014	0,0166
30.11.2029	0,0121	0,0105	0,0095	0,014	0,0171
31.12.2029	0,012	0,003	0,0104	0,014	0,0176
31.01.2030	0,0119	-0,0005	0,0114	0,014	0,0181
28.02.2030	0,0118	-0,0019	0,0124	0,014	0,0185
31.03.2030	0,0117	-0,0019	0,0135	0,014	0,0189
30.04.2030	0,0116	-0,0053	0,0147	0,014	0,0192
31.05.2030	0,0115	-0,0102	0,016	0,014	0,0194
30.06.2030	0,0114	-0,0106	0,0172	0,014	0,0195
31.07.2030	0,0113	0,0001	0,0184	0,014	0,0196
31.08.2030	0,0113	0,0124	0,0195	0,014	0,0196
30.09.2030	0,0114	0,0131	0,0206	0,014	0,0195
31.10.2030	0,0115	0,0081	0,0216	0,014	0,0192
30.11.2030	0,0117	0,0071	0,0225	0,014	0,0188
31.12.2030	0,0119	0,0055	0,0232	0,014	0,0183
31.01.2031	0,0121	0,0031	0,0237	0,014	0,0177
28.02.2031	0,0123	0,0084	0,0239	0,014	0,0169
31.03.2031	0,0126	0,0069	0,0239	0,014	0,016
30.04.2031	0,013	-0,0015	0,0236	0,014	0,0151
31.05.2031	0,0134	-0,0126	0,0231	0,014	0,0143

30.06.2031	0,0138	-0,0113	0,0224	0,014	0,0138
31.07.2031	0,0143	-0,0023	0,0214	0,014	0,0137
31.08.2031	0,0148	-0,0017	0,0203	0,014	0,0137
30.09.2031	0,0153	0,0029	0,0191	0,014	0,0137
31.10.2031	0,0158	0,0175	0,0175	0,014	0,0135
30.11.2031	0,0162	0,0175	0,0157	0,014	0,0132
31.12.2031	0,0166	-0,003	0,0143	0,014	0,0128
31.01.2032	0,0169	-0,0002	0,0132	0,014	0,0124
29.02.2032	0,0172	-0,0007	0,0123	0,014	0,012
31.03.2032	0,0174	-0,0051	0,0113	0,014	0,0118
30.04.2032	0,0175	-0,0128	0,0102	0,014	0,0118
31.05.2032	0,0176	-0,0163	0,0092	0,014	0,0119
30.06.2032	0,0176	-0,0218	0,0085	0,014	0,0121
31.07.2032	0,0176	-0,0148	0,0081	0,014	0,0122
31.08.2032	0,0175	0,0074	0,008	0,014	0,0122
30.09.2032	0,0174	0,0167	0,0081	0,014	0,0122
31.10.2032	0,0172	0,0069	0,0083	0,014	0,0122
30.11.2032	0,0169	0,0108	0,0084	0,014	0,0123
31.12.2032	0,0166	0,0111	0,0082	0,014	0,0125
31.01.2033	0,0163	-0,0082	0,0078	0,014	0,0129
28.02.2033	0,0159	-0,0008	0,0075	0,014	0,0134
31.03.2033	0,0154	-0,0015	0,0072	0,014	0,0139
30.04.2033	0,0149	-0,0142	0,0069	0,014	0,0143
31.05.2033	0,0143	-0,0373	0,0066	0,014	0,0147
30.06.2033	0,0137	-0,0247	0,0063	0,014	0,0151
31.07.2033	0,0132	-0,0002	0,006	0,014	0,0155
31.08.2033	0,0128	-0,0058	0,0058	0,014	0,016
30.09.2033	0,0125	-0,0029	0,0056	0,014	0,0165
31.10.2033	0,0123	0,0362	0,0053	0,014	0,017
30.11.2033	0,0122	0,0159	0,0049	0,014	0,0175
31.12.2033	0,0121	-0,0326	0,0045	0,014	0,018
31.01.2034	0,012	-0,0002	0,0041	0,014	0,0184
28.02.2034	0,0118	-0,0157	0,0038	0,014	0,0187
31.03.2034	0,0116	-0,0464	0,0036	0,014	0,019
30.04.2034	0,0114	-0,0506	0,0035	0,014	0,0192
31.05.2034	0,0112	-0,0304	0,0035	0,014	0,0193
30.06.2034	0,0111	-0,0344	0,0037	0,014	0,0194
31.07.2034	0,0111	-0,0264	0,004	0,014	0,0194
31.08.2034	0,0112	0,0368	0,0043	0,014	0,0193
30.09.2034	0,0113	0,0118	0,0046	0,014	0,019
31.10.2034	0,0114	-0,024	0,0049	0,014	0,0186
30.11.2034	0,0115	0,0028	0,0054	0,014	0,0181
31.12.2034	0,0116	0,0059	0,006	0,014	0,0175
31.01.2035	0,0117	-0,0424	0,0067	0,014	0,0168
28.02.2035	0,0119	-0,0207	0,0074	0,014	0,0159

31.03.2035	0,0122	-0,0175	0,0081	0,014	0,015
30.04.2035	0,0125	-0,0546	0,0088	0,014	0,0142
31.05.2035	0,013	-0,0541	0,0095	0,014	0,0137
30.06.2035	0,0135	0,0215	0,0104	0,014	0,0136
31.07.2035	0,014	0,0024	0,0114	0,014	0,0136
31.08.2035	0,0145	-0,051	0,0124	0,014	0,0135
30.09.2035	0,015	0,0355	0,0135	0,014	0,0133
31.10.2035	0,0154	0,0262	0,0147	0,014	0,013
30.11.2035	0,0158	-0,0682	0,016	0,014	0,0126
31.12.2035	0,0162	-0,0183	0,0172	0,014	0,0122
31.01.2036	0,0166	0,0171	0,0184	0,014	0,0118
29.02.2036	0,0169	-0,0747	0,0195	0,014	0,0116
31.03.2036	0,0172	-0,0732	0,0206	0,014	0,0116
30.04.2036	0,0174	0,0317	0,0216	0,014	0,0118
31.05.2036	0,0176	-0,0481	0,0225	0,014	0,012
30.06.2036	0,0177	-0,1034	0,0232	0,014	0,0121
31.07.2036	0,0177	0,0603	0,0237	0,014	0,0122
31.08.2036	0,0177	-0,009	0,0239	0,014	0,0122
30.09.2036	0,0176	-0,1296	0,0239	0,014	0,0123
31.10.2036	0,0174	0,0026	0,0236	0,014	0,0124
30.11.2036	0,0172	0,0375	0,0231	0,014	0,0127
31.12.2036	0,017	-0,1452	0,0224	0,014	0,0131
31.01.2037	0,0167	-0,0734	0,0214	0,014	0,0137
28.02.2037	0,0164	0,1005	0,0203	0,014	0,0142
31.03.2037	0,016	-0,1574	0,0191	0,014	0,0147
30.04.2037	0,0155	-0,1442	0,0175	0,014	0,0152
31.05.2037	0,0149	0,1553	0,0157	0,014	0,0157
30.06.2037	0,0143	-0,1671	0,0143	0,014	0,0162
31.07.2037	0,0137	-0,1975	0,0132	0,014	0,0167
31.08.2037	0,0131	0,1253	0,0123	0,014	0,0172
30.09.2037	0,0127	-0,1414	0,0113	0,014	0,0177
31.10.2037	0,0124	-0,2795	0,0102	0,014	0,0182
30.11.2037	0,0122	0,0784	0,0092	0,014	0,0186
31.12.2037	0,0121	-0,0805	0,0085	0,014	0,019
31.01.2038	0,0121	-0,3707	0,0081	0,014	0,0193
28.02.2038	0,012	-0,0171	0,008	0,014	0,0195
31.03.2038	0,0118	0,0491	0,0081	0,014	0,0196
30.04.2038	0,0116	-0,428	0,0083	0,014	0,0197
31.05.2038	0,0114	-0,1731	0,0084	0,014	0,0196
30.06.2038	0,0112	0,2815	0,0082	0,014	0,0194
31.07.2038	0,0111	-0,5069	0,0078	0,014	0,0191
31.08.2038	0,0111	-0,3709	0,0075	0,014	0,0187
30.09.2038	0,0111	0,4252	0,0072	0,014	0,0182
31.10.2038	0,0112	-0,6067	0,0069	0,014	0,0176
30.11.2038	0,0113	-0,5076	0,0066	0,014	0,0168

31.12.2038	0,0114	0,4061	0,0063	0,014	0,0158
31.01.2039	0,0115	-0,5952	0,006	0,014	0,0149
28.02.2039	0,0116	-0,749	0,0058	0,014	0,0142
31.03.2039	0,0118	0,3842	0,0056	0,014	0,0138
30.04.2039	0,012	-0,5951	0,0053	0,014	0,0137
31.05.2039	0,0123	-1,1174	0,0049	0,014	0,0137
30.06.2039	0,0127	0,2207	0,0045	0,014	0,0136
31.07.2039	0,0132	-0,516	0,0041	0,014	0,0134
31.08.2039	0,0137	-1,2429	0,0038	0,014	0,0131
30.09.2039	0,0142	-0,069	0,0036	0,014	0,0127
31.10.2039	0,0147	-0,2907	0,0035	0,014	0,0123
30.11.2039	0,0152	-0,9632	0,0035	0,014	0,0119
31.12.2039	0,0156	-0,393	0,0037	0,014	0,0117
31.01.2040	0,016	0,0958	0,004	0,014	0,0118
29.02.2040	0,0164	-0,8022	0,0043	0,014	0,012
31.03.2040	0,0168	-0,6634	0,0046	0,014	0,0121
30.04.2040	0,0171	0,3257	0,0049	0,014	0,0122
31.05.2040	0,0174	-0,7467	0,0054	0,014	0,0122
30.06.2040	0,0176	-0,8426	0,006	0,014	0,0122
31.07.2040	0,0177	0,4353	0,0067	0,014	0,0123
31.08.2040	0,0177	-0,5683	0,0074	0,014	0,0124
30.09.2040	0,0177	-0,7813	0,0081	0,014	0,0127
31.10.2040	0,0176	0,2886	0,0088	0,014	0,0131
30.11.2040	0,0175	-0,5616	0,0095	0,014	0,0136
31.12.2040	0,0173	-0,9255	0,0104	0,014	0,0141

Příloha B: Tabulka Predikce za pomoci RF-NN_GRL1–RF-NN_GRL5

Datum	RF-NN_GRL1	RF-NN_GRL2	RF-NN_GRL3	RF-NN_GRL4	RF-NN_GRL5
30.09.2020	0,0091	0,0089	0,0093	0,0101	0,0091
31.10.2020	0,0086	0,0089	0,0092	0,0108	0,0093
30.11.2020	0,008	0,0086	0,0089	0,0114	0,0097
31.12.2020	0,0071	0,0082	0,0084	0,0116	0,0098
31.01.2021	0,0059	0,0075	0,0076	0,0117	0,0096
28.02.2021	0,0048	0,0068	0,0069	0,0117	0,0094
31.03.2021	0,0037	0,0062	0,0062	0,0117	0,0093
30.04.2021	0,0027	0,0056	0,0055	0,0117	0,009
31.05.2021	0,0021	0,0056	0,0051	0,012	0,0092
30.06.2021	0,0016	0,0056	0,0048	0,0125	0,0094
31.07.2021	0,0011	0,0056	0,0045	0,013	0,0097
31.08.2021	0,0005	0,0054	0,0041	0,0135	0,0098
30.09.2021	-0,0001	0,0053	0,0037	0,014	0,01
31.10.2021	-0,0008	0,005	0,0033	0,0144	0,0101
30.11.2021	-0,0015	0,0048	0,0028	0,0147	0,0102
31.12.2021	-0,0022	0,0047	0,0023	0,015	0,0102
31.01.2022	-0,0029	0,0047	0,0018	0,0153	0,0103
28.02.2022	-0,0035	0,0048	0,0014	0,0156	0,0104
31.03.2022	-0,004	0,005	0,001	0,0159	0,0105
30.04.2022	-0,0045	0,0052	0,0006	0,0163	0,0106
31.05.2022	-0,0049	0,0053	0,0002	0,0167	0,0107
30.06.2022	-0,0053	0,0053	-0,0002	0,0171	0,0108
31.07.2022	-0,0057	0,0053	-0,0006	0,0174	0,0109
31.08.2022	-0,0061	0,0053	-0,001	0,0177	0,011
30.09.2022	-0,0065	0,0053	-0,0014	0,018	0,011
31.10.2022	-0,0069	0,0053	-0,0018	0,0183	0,011
30.11.2022	-0,0073	0,0053	-0,0021	0,0186	0,011
31.12.2022	-0,0077	0,0053	-0,0024	0,0188	0,011
31.01.2023	-0,0081	0,0054	-0,0027	0,019	0,011
28.02.2023	-0,0084	0,0054	-0,003	0,0192	0,011
31.03.2023	-0,0087	0,0054	-0,0033	0,0194	0,011
30.04.2023	-0,009	0,0054	-0,0036	0,0196	0,011
31.05.2023	-0,0093	0,0054	-0,0039	0,0198	0,011
30.06.2023	-0,0096	0,0054	-0,0042	0,02	0,011
31.07.2023	-0,0099	0,0054	-0,0045	0,0202	0,011
31.08.2023	-0,0102	0,0054	-0,0048	0,0204	0,011
30.09.2023	-0,0104	0,0054	-0,0051	0,0206	0,011
31.10.2023	-0,0106	0,0054	-0,0054	0,0208	0,011
30.11.2023	-0,0108	0,0054	-0,0056	0,021	0,011
31.12.2023	-0,011	0,0054	-0,0058	0,0211	0,011
31.01.2024	-0,0112	0,0054	-0,006	0,0212	0,011
29.02.2024	-0,0114	0,0054	-0,0062	0,0213	0,011

31.03.2024	-0,0116	0,0054	-0,0064	0,0214	0,011
30.04.2024	-0,0118	0,0054	-0,0066	0,0215	0,011
31.05.2024	-0,012	0,0054	-0,0068	0,0216	0,011
30.06.2024	-0,0121	0,0054	-0,007	0,0217	0,011
31.07.2024	-0,0122	0,0054	-0,0072	0,0218	0,011
31.08.2024	-0,0123	0,0054	-0,0074	0,0219	0,011
30.09.2024	-0,0124	0,0054	-0,0076	0,022	0,011
31.10.2024	-0,0125	0,0054	-0,0078	0,0221	0,011
30.11.2024	-0,0126	0,0054	-0,008	0,0222	0,011
31.12.2024	-0,0127	0,0054	-0,0082	0,0223	0,011
31.01.2025	-0,0128	0,0054	-0,0084	0,0224	0,011
28.02.2025	-0,0129	0,0054	-0,0086	0,0225	0,011
31.03.2025	-0,013	0,0054	-0,0088	0,0226	0,011
30.04.2025	-0,0131	0,0054	-0,009	0,0227	0,011
31.05.2025	-0,0132	0,0054	-0,0092	0,0228	0,011
30.06.2025	-0,0133	0,0054	-0,0094	0,0229	0,011
31.07.2025	-0,0134	0,0054	-0,0096	0,023	0,011
31.08.2025	-0,0135	0,0054	-0,0098	0,0231	0,011
30.09.2025	-0,0136	0,0054	-0,0099	0,0231	0,011
31.10.2025	-0,0137	0,0054	-0,01	0,0231	0,011
30.11.2025	-0,0137	0,0054	-0,0101	0,0231	0,011
31.12.2025	-0,0137	0,0054	-0,0102	0,0231	0,011
31.01.2026	-0,0137	0,0054	-0,0103	0,0231	0,011
28.02.2026	-0,0137	0,0054	-0,0104	0,0231	0,011
31.03.2026	-0,0137	0,0054	-0,0105	0,0231	0,011
30.04.2026	-0,0137	0,0054	-0,0106	0,0231	0,011
31.05.2026	-0,0137	0,0054	-0,0107	0,0231	0,011
30.06.2026	-0,0137	0,0054	-0,0108	0,0231	0,011
31.07.2026	-0,0137	0,0054	-0,0109	0,0231	0,011
31.08.2026	-0,0137	0,0054	-0,011	0,0231	0,011
30.09.2026	-0,0137	0,0054	-0,0111	0,0231	0,011
31.10.2026	-0,0137	0,0054	-0,0112	0,0231	0,011
30.11.2026	-0,0137	0,0054	-0,0113	0,0231	0,011
31.12.2026	-0,0137	0,0054	-0,0114	0,0231	0,011
31.01.2027	-0,0137	0,0054	-0,0115	0,0231	0,011
28.02.2027	-0,0137	0,0054	-0,0116	0,0231	0,011
31.03.2027	-0,0137	0,0054	-0,0117	0,0231	0,011
30.04.2027	-0,0137	0,0054	-0,0118	0,0231	0,011
31.05.2027	-0,0137	0,0054	-0,0119	0,0231	0,011
30.06.2027	-0,0137	0,0054	-0,012	0,0231	0,011
31.07.2027	-0,0137	0,0054	-0,0121	0,0231	0,011
31.08.2027	-0,0137	0,0054	-0,0122	0,0231	0,011
30.09.2027	-0,0137	0,0054	-0,0123	0,0231	0,011
31.10.2027	-0,0137	0,0054	-0,0124	0,0231	0,011
30.11.2027	-0,0137	0,0054	-0,0125	0,0231	0,011

31.12.2027	-0,0137	0,0054	-0,0126	0,0231	0,011
31.01.2028	-0,0137	0,0054	-0,0127	0,0231	0,011
29.02.2028	-0,0137	0,0054	-0,0128	0,0231	0,011
31.03.2028	-0,0137	0,0054	-0,0129	0,0231	0,011
30.04.2028	-0,0137	0,0054	-0,013	0,0231	0,011
31.05.2028	-0,0137	0,0054	-0,0131	0,0231	0,011
30.06.2028	-0,0137	0,0054	-0,0132	0,0231	0,011
31.07.2028	-0,0137	0,0054	-0,0133	0,0231	0,011
31.08.2028	-0,0137	0,0054	-0,0134	0,0231	0,011
30.09.2028	-0,0137	0,0054	-0,0135	0,0231	0,011
31.10.2028	-0,0137	0,0054	-0,0136	0,0231	0,011
30.11.2028	-0,0137	0,0054	-0,0137	0,0231	0,011
31.12.2028	-0,0137	0,0054	-0,0138	0,0231	0,011
31.01.2029	-0,0137	0,0054	-0,0139	0,0231	0,011
28.02.2029	-0,0137	0,0054	-0,014	0,0231	0,011
31.03.2029	-0,0137	0,0054	-0,0141	0,0231	0,011
30.04.2029	-0,0137	0,0054	-0,0142	0,0231	0,011
31.05.2029	-0,0137	0,0054	-0,0143	0,0231	0,011
30.06.2029	-0,0137	0,0054	-0,0144	0,0231	0,011
31.07.2029	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2029	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2029	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2029	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2029	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2029	-0,0137	0,0054	-0,0145	0,0231	0,011
31.01.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
28.02.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
31.03.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
30.04.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
31.05.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
30.06.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2030	-0,0137	0,0054	-0,0145	0,0231	0,011
31.01.2031	-0,0137	0,0054	-0,0145	0,0231	0,011
28.02.2031	-0,0137	0,0054	-0,0145	0,0231	0,011
31.03.2031	-0,0137	0,0054	-0,0145	0,0231	0,011
30.04.2031	-0,0137	0,0054	-0,0145	0,0231	0,011
31.05.2031	-0,0137	0,0054	-0,0145	0,0231	0,011
30.06.2031	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2031	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2031	-0,0137	0,0054	-0,0145	0,0231	0,011

30.06.2035	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2035	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2035	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2035	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2035	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2035	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2035	-0,0137	0,0054	-0,0145	0,0231	0,011
31.01.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
29.02.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
31.03.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
30.04.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
31.05.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
30.06.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2036	-0,0137	0,0054	-0,0145	0,0231	0,011
31.01.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
28.02.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
31.03.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
30.04.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
31.05.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
30.06.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2037	-0,0137	0,0054	-0,0145	0,0231	0,011
31.01.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
28.02.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
31.03.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
30.04.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
31.05.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
30.06.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2038	-0,0137	0,0054	-0,0145	0,0231	0,011
31.01.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
28.02.2039	-0,0137	0,0054	-0,0145	0,0231	0,011

31.03.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
30.04.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
31.05.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
30.06.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2039	-0,0137	0,0054	-0,0145	0,0231	0,011
31.01.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
29.02.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.03.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
30.04.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.05.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
30.06.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.07.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.08.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
30.09.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.10.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
30.11.2040	-0,0137	0,0054	-0,0145	0,0231	0,011
31.12.2040	-0,0137	0,0054	-0,0145	0,0231	0,011

Příloha C: Tabulka Predikce za pomoci RF-NN_LSTM1–RF-NN_LSTM5

Datum	RF- NN_LSTM1	RF- NN_LSTM2	RF- NN_LSTM3	RF- NN_LSTM4	RF- NN_LSTM5
30.09.2020	0,0097	0,0084	0,0091	0,0085	0,0089
31.10.2020	0,0105	0,0085	0,0094	0,0084	0,009
30.11.2020	0,0111	0,0083	0,0096	0,0081	0,009
31.12.2020	0,0118	0,008	0,0098	0,0075	0,009
31.01.2021	0,0121	0,0074	0,0096	0,0067	0,0087
28.02.2021	0,0126	0,0068	0,0094	0,0059	0,0083
31.03.2021	0,0133	0,0063	0,0094	0,0052	0,0078
30.04.2021	0,014	0,0058	0,0093	0,0046	0,0074
31.05.2021	0,0153	0,0057	0,0099	0,0044	0,0074
30.06.2021	0,0166	0,0055	0,0103	0,0041	0,0074
31.07.2021	0,0177	0,0053	0,0108	0,0038	0,0073
31.08.2021	0,0187	0,0049	0,0112	0,0033	0,0072
30.09.2021	0,0197	0,0047	0,0117	0,0029	0,0071
31.10.2021	0,0204	0,0043	0,0121	0,0025	0,0069
30.11.2021	0,0209	0,004	0,0125	0,0021	0,0066
31.12.2021	0,0213	0,0037	0,0129	0,0019	0,0062
31.01.2022	0,0216	0,0035	0,0133	0,0019	0,0058
28.02.2022	0,0217	0,0034	0,0138	0,002	0,0054
31.03.2022	0,0218	0,0033	0,0142	0,0021	0,005
30.04.2022	0,0218	0,0033	0,0146	0,0023	0,0046
31.05.2022	0,0217	0,0033	0,0149	0,0024	0,0042
30.06.2022	0,0215	0,0033	0,0151	0,0024	0,0038
31.07.2022	0,0213	0,0033	0,0151	0,0024	0,0034
31.08.2022	0,021	0,0033	0,0151	0,0024	0,0031
30.09.2022	0,0207	0,0034	0,015	0,0024	0,0028
31.10.2022	0,0203	0,0034	0,0148	0,0024	0,0027
30.11.2022	0,02	0,0035	0,0146	0,0024	0,0028
31.12.2022	0,0196	0,0036	0,0143	0,0024	0,003
31.01.2023	0,0192	0,0037	0,014	0,0025	0,0034
28.02.2023	0,0189	0,0038	0,0136	0,0025	0,0039
31.03.2023	0,0185	0,0038	0,0132	0,0025	0,0045
30.04.2023	0,0182	0,0039	0,0128	0,0025	0,0051
31.05.2023	0,0178	0,0039	0,0123	0,0025	0,0057
30.06.2023	0,0175	0,0039	0,0118	0,0025	0,0063
31.07.2023	0,0172	0,0039	0,0113	0,0025	0,0069
31.08.2023	0,0169	0,0039	0,0109	0,0025	0,0074
30.09.2023	0,0166	0,0039	0,0105	0,0025	0,0077
31.10.2023	0,0163	0,0039	0,0102	0,0025	0,0079
30.11.2023	0,016	0,0039	0,01	0,0025	0,008
31.12.2023	0,0157	0,0039	0,0099	0,0025	0,0081
31.01.2024	0,0154	0,0039	0,0098	0,0025	0,0083
29.02.2024	0,0151	0,0039	0,0099	0,0025	0,0085
31.03.2024	0,0148	0,0039	0,01	0,0025	0,0087
30.04.2024	0,0145	0,0039	0,0101	0,0025	0,0089
31.05.2024	0,0143	0,0039	0,0103	0,0025	0,0091
30.06.2024	0,014	0,0039	0,0105	0,0025	0,0092
31.07.2024	0,0138	0,0039	0,0107	0,0025	0,0093
31.08.2024	0,0136	0,0039	0,011	0,0025	0,0094
30.09.2024	0,0134	0,0039	0,0113	0,0025	0,0095
31.10.2024	0,0133	0,0039	0,0116	0,0025	0,0096
30.11.2024	0,0132	0,0039	0,012	0,0025	0,0097
31.12.2024	0,0132	0,0039	0,0124	0,0025	0,0098
31.01.2025	0,0132	0,0039	0,0128	0,0025	0,0099
28.02.2025	0,0133	0,0039	0,0132	0,0025	0,01

31.03.2025	0,0134	0,0039	0,0135	0,0025	0,0101
30.04.2025	0,0136	0,0039	0,0138	0,0025	0,0102
31.05.2025	0,0138	0,0039	0,014	0,0025	0,0103
30.06.2025	0,014	0,0039	0,0142	0,0025	0,0104
31.07.2025	0,0143	0,0039	0,0143	0,0025	0,0105
31.08.2025	0,0146	0,0039	0,0143	0,0025	0,0106
30.09.2025	0,0149	0,0039	0,0143	0,0025	0,0107
31.10.2025	0,0152	0,0039	0,0142	0,0025	0,0108
30.11.2025	0,0155	0,0039	0,014	0,0025	0,0109
31.12.2025	0,0158	0,0039	0,0138	0,0025	0,011
31.01.2026	0,016	0,0039	0,0135	0,0025	0,0111
28.02.2026	0,0162	0,0039	0,0132	0,0025	0,0112
31.03.2026	0,0164	0,0039	0,0128	0,0025	0,0113
30.04.2026	0,0165	0,0039	0,0124	0,0025	0,0114
31.05.2026	0,0166	0,0039	0,012	0,0025	0,0114
30.06.2026	0,0166	0,0039	0,0116	0,0025	0,0115
31.07.2026	0,0166	0,0039	0,0112	0,0025	0,0115
31.08.2026	0,0166	0,0039	0,0109	0,0025	0,0115
30.09.2026	0,0165	0,0039	0,0106	0,0025	0,0115
31.10.2026	0,0164	0,0039	0,0104	0,0025	0,0115
30.11.2026	0,0163	0,0039	0,0103	0,0025	0,0115
31.12.2026	0,0161	0,0039	0,0102	0,0025	0,0114
31.01.2027	0,0159	0,0039	0,0102	0,0025	0,0114
28.02.2027	0,0157	0,0039	0,0103	0,0025	0,0113
31.03.2027	0,0155	0,0039	0,0104	0,0025	0,0112
30.04.2027	0,0153	0,0039	0,0106	0,0025	0,0111
31.05.2027	0,0151	0,0039	0,0108	0,0025	0,011
30.06.2027	0,0149	0,0039	0,011	0,0025	0,0109
31.07.2027	0,0147	0,0039	0,0113	0,0025	0,0108
31.08.2027	0,0145	0,0039	0,0116	0,0025	0,0107
30.09.2027	0,0143	0,0039	0,0119	0,0025	0,0106
31.10.2027	0,0141	0,0039	0,0122	0,0025	0,0105
30.11.2027	0,0139	0,0039	0,0125	0,0025	0,0104
31.12.2027	0,0138	0,0039	0,0129	0,0025	0,0104
31.01.2028	0,0137	0,0039	0,0132	0,0025	0,0103
29.02.2028	0,0136	0,0039	0,0135	0,0025	0,0103
31.03.2028	0,0136	0,0039	0,0137	0,0025	0,0102
30.04.2028	0,0136	0,0039	0,0139	0,0025	0,0102
31.05.2028	0,0136	0,0039	0,014	0,0025	0,0101
30.06.2028	0,0137	0,0039	0,0141	0,0025	0,0101
31.07.2028	0,0138	0,0039	0,0141	0,0025	0,0101
31.08.2028	0,0139	0,0039	0,014	0,0025	0,0101
30.09.2028	0,014	0,0039	0,0139	0,0025	0,0101
31.10.2028	0,0142	0,0039	0,0137	0,0025	0,0101
30.11.2028	0,0144	0,0039	0,0135	0,0025	0,0101
31.12.2028	0,0146	0,0039	0,0132	0,0025	0,0101
31.01.2029	0,0148	0,0039	0,0129	0,0025	0,0101
28.02.2029	0,015	0,0039	0,0125	0,0025	0,0101
31.03.2029	0,0152	0,0039	0,0122	0,0025	0,0101
30.04.2029	0,0154	0,0039	0,0118	0,0025	0,0101
31.05.2029	0,0156	0,0039	0,0115	0,0025	0,0101
30.06.2029	0,0157	0,0039	0,0112	0,0025	0,0101
31.07.2029	0,0158	0,0039	0,0109	0,0025	0,0101
31.08.2029	0,0159	0,0039	0,0107	0,0025	0,0101
30.09.2029	0,016	0,0039	0,0105	0,0025	0,0101
31.10.2029	0,016	0,0039	0,0104	0,0025	0,0101
30.11.2029	0,016	0,0039	0,0104	0,0025	0,0101
31.12.2029	0,016	0,0039	0,0104	0,0025	0,0101

31.01.2030	0,0159	0,0039	0,0105	0,0025	0,0101
28.02.2030	0,0158	0,0039	0,0107	0,0025	0,0101
31.03.2030	0,0157	0,0039	0,0108	0,0025	0,0101
30.04.2030	0,0155	0,0039	0,011	0,0025	0,0101
31.05.2030	0,0154	0,0039	0,0112	0,0025	0,0101
30.06.2030	0,0152	0,0039	0,0114	0,0025	0,0101
31.07.2030	0,015	0,0039	0,0117	0,0025	0,0101
31.08.2030	0,0148	0,0039	0,012	0,0025	0,0101
30.09.2030	0,0146	0,0039	0,0123	0,0025	0,0101
31.10.2030	0,0144	0,0039	0,0126	0,0025	0,0101
30.11.2030	0,0142	0,0039	0,0129	0,0025	0,0101
31.12.2030	0,014	0,0039	0,0132	0,0025	0,0101
31.01.2031	0,0139	0,0039	0,0134	0,0025	0,0101
28.02.2031	0,0138	0,0039	0,0136	0,0025	0,0101
31.03.2031	0,0137	0,0039	0,0137	0,0025	0,0101
30.04.2031	0,0137	0,0039	0,0138	0,0025	0,0101
31.05.2031	0,0137	0,0039	0,0138	0,0025	0,0101
30.06.2031	0,0137	0,0039	0,0138	0,0025	0,0101
31.07.2031	0,0137	0,0039	0,0137	0,0025	0,0101
31.08.2031	0,0138	0,0039	0,0136	0,0025	0,0101
30.09.2031	0,0139	0,0039	0,0134	0,0025	0,0101
31.10.2031	0,014	0,0039	0,0132	0,0025	0,0101
30.11.2031	0,0142	0,0039	0,0129	0,0025	0,0101
31.12.2031	0,0144	0,0039	0,0126	0,0025	0,0101
31.01.2032	0,0146	0,0039	0,0123	0,0025	0,0101
29.02.2032	0,0148	0,0039	0,012	0,0025	0,0101
31.03.2032	0,015	0,0039	0,0117	0,0025	0,0101
30.04.2032	0,0152	0,0039	0,0114	0,0025	0,0101
31.05.2032	0,0154	0,0039	0,0112	0,0025	0,0101
30.06.2032	0,0156	0,0039	0,011	0,0025	0,0101
31.07.2032	0,0157	0,0039	0,0108	0,0025	0,0101
31.08.2032	0,0158	0,0039	0,0107	0,0025	0,0101
30.09.2032	0,0159	0,0039	0,0107	0,0025	0,0101
31.10.2032	0,016	0,0039	0,0107	0,0025	0,0101
30.11.2032	0,016	0,0039	0,0108	0,0025	0,0101
31.12.2032	0,016	0,0039	0,0109	0,0025	0,0101
31.01.2033	0,016	0,0039	0,0111	0,0025	0,0101
28.02.2033	0,0159	0,0039	0,0112	0,0025	0,0101
31.03.2033	0,0158	0,0039	0,0114	0,0025	0,0101
30.04.2033	0,0157	0,0039	0,0116	0,0025	0,0101
31.05.2033	0,0155	0,0039	0,0118	0,0025	0,0101
30.06.2033	0,0154	0,0039	0,0121	0,0025	0,0101
31.07.2033	0,0152	0,0039	0,0123	0,0025	0,0101
31.08.2033	0,015	0,0039	0,0126	0,0025	0,0101
30.09.2033	0,0148	0,0039	0,0128	0,0025	0,0101
31.10.2033	0,0146	0,0039	0,013	0,0025	0,0101
30.11.2033	0,0144	0,0039	0,0132	0,0025	0,0101
31.12.2033	0,0142	0,0039	0,0133	0,0025	0,0101
31.01.2034	0,014	0,0039	0,0134	0,0025	0,0101
28.02.2034	0,0139	0,0039	0,0135	0,0025	0,0101
31.03.2034	0,0138	0,0039	0,0135	0,0025	0,0101
30.04.2034	0,0137	0,0039	0,0135	0,0025	0,0101
31.05.2034	0,0137	0,0039	0,0134	0,0025	0,0101
30.06.2034	0,0137	0,0039	0,0133	0,0025	0,0101
31.07.2034	0,0137	0,0039	0,0131	0,0025	0,0101
31.08.2034	0,0137	0,0039	0,0129	0,0025	0,0101
30.09.2034	0,0138	0,0039	0,0127	0,0025	0,0101
31.10.2034	0,0139	0,0039	0,0124	0,0025	0,0101

30.11.2034	0,014	0,0039	0,0121	0,0025	0,0101
31.12.2034	0,0142	0,0039	0,0119	0,0025	0,0101
31.01.2035	0,0144	0,0039	0,0116	0,0025	0,0101
28.02.2035	0,0146	0,0039	0,0114	0,0025	0,0101
31.03.2035	0,0148	0,0039	0,0112	0,0025	0,0101
30.04.2035	0,015	0,0039	0,011	0,0025	0,0101
31.05.2035	0,0152	0,0039	0,0109	0,0025	0,0101
30.06.2035	0,0154	0,0039	0,0108	0,0025	0,0101
31.07.2035	0,0156	0,0039	0,0108	0,0025	0,0101
31.08.2035	0,0157	0,0039	0,0108	0,0025	0,0101
30.09.2035	0,0158	0,0039	0,0109	0,0025	0,0101
31.10.2035	0,0159	0,0039	0,011	0,0025	0,0101
30.11.2035	0,016	0,0039	0,0112	0,0025	0,0101
31.12.2035	0,016	0,0039	0,0114	0,0025	0,0101
31.01.2036	0,016	0,0039	0,0116	0,0025	0,0101
29.02.2036	0,016	0,0039	0,0118	0,0025	0,0101
31.03.2036	0,0159	0,0039	0,012	0,0025	0,0101
30.04.2036	0,0158	0,0039	0,0122	0,0025	0,0101
31.05.2036	0,0157	0,0039	0,0124	0,0025	0,0101
30.06.2036	0,0155	0,0039	0,0126	0,0025	0,0101
31.07.2036	0,0154	0,0039	0,0128	0,0025	0,0101
31.08.2036	0,0152	0,0039	0,013	0,0025	0,0101
30.09.2036	0,015	0,0039	0,0132	0,0025	0,0101
31.10.2036	0,0148	0,0039	0,0133	0,0025	0,0101
30.11.2036	0,0146	0,0039	0,0134	0,0025	0,0101
31.12.2036	0,0144	0,0039	0,0134	0,0025	0,0101
31.01.2037	0,0142	0,0039	0,0134	0,0025	0,0101
28.02.2037	0,014	0,0039	0,0133	0,0025	0,0101
31.03.2037	0,0139	0,0039	0,0132	0,0025	0,0101
30.04.2037	0,0138	0,0039	0,013	0,0025	0,0101
31.05.2037	0,0137	0,0039	0,0128	0,0025	0,0101
30.06.2037	0,0137	0,0039	0,0126	0,0025	0,0101
31.07.2037	0,0137	0,0039	0,0124	0,0025	0,0101
31.08.2037	0,0137	0,0039	0,0122	0,0025	0,0101
30.09.2037	0,0137	0,0039	0,012	0,0025	0,0101
31.10.2037	0,0138	0,0039	0,0118	0,0025	0,0101
30.11.2037	0,0139	0,0039	0,0116	0,0025	0,0101
31.12.2037	0,014	0,0039	0,0114	0,0025	0,0101
31.01.2038	0,0142	0,0039	0,0113	0,0025	0,0101
28.02.2038	0,0144	0,0039	0,0112	0,0025	0,0101
31.03.2038	0,0146	0,0039	0,0111	0,0025	0,0101
30.04.2038	0,0148	0,0039	0,0111	0,0025	0,0101
31.05.2038	0,015	0,0039	0,0111	0,0025	0,0101
30.06.2038	0,0152	0,0039	0,0112	0,0025	0,0101
31.07.2038	0,0154	0,0039	0,0113	0,0025	0,0101
31.08.2038	0,0156	0,0039	0,0114	0,0025	0,0101
30.09.2038	0,0157	0,0039	0,0115	0,0025	0,0101
31.10.2038	0,0158	0,0039	0,0117	0,0025	0,0101
30.11.2038	0,0159	0,0039	0,0119	0,0025	0,0101
31.12.2038	0,016	0,0039	0,0121	0,0025	0,0101
31.01.2039	0,016	0,0039	0,0123	0,0025	0,0101
28.02.2039	0,016	0,0039	0,0125	0,0025	0,0101
31.03.2039	0,016	0,0039	0,0127	0,0025	0,0101
30.04.2039	0,0159	0,0039	0,0129	0,0025	0,0101
31.05.2039	0,0158	0,0039	0,013	0,0025	0,0101
30.06.2039	0,0157	0,0039	0,0131	0,0025	0,0101
31.07.2039	0,0155	0,0039	0,0132	0,0025	0,0101
31.08.2039	0,0154	0,0039	0,0132	0,0025	0,0101

30.09.2039	0,0152	0,0039	0,0132	0,0025	0,0101
31.10.2039	0,015	0,0039	0,0132	0,0025	0,0101
30.11.2039	0,0148	0,0039	0,0131	0,0025	0,0101
31.12.2039	0,0146	0,0039	0,013	0,0025	0,0101
31.01.2040	0,016	0,0039	0,0125	0,0025	0,0101
29.02.2040	0,016	0,0039	0,0127	0,0025	0,0101
31.03.2040	0,0159	0,0039	0,0129	0,0025	0,0101
30.04.2040	0,0158	0,0039	0,013	0,0025	0,0101
31.05.2040	0,0157	0,0039	0,0131	0,0025	0,0101
30.06.2040	0,0155	0,0039	0,0132	0,0025	0,0101
31.07.2040	0,0154	0,0039	0,0132	0,0025	0,0101
31.08.2040	0,0152	0,0039	0,0132	0,0025	0,0101
30.09.2040	0,015	0,0039	0,0132	0,0025	0,0101
31.10.2040	0,0148	0,0039	0,0131	0,0025	0,0101
30.11.2040	0,0146	0,0039	0,013	0,0025	0,0101
31.12.2040	0,0144	0,0039	0,0129	0,0025	0,0101

Příloha D: Tabulka diskontní sazby GOS_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,007475	0,017075	0,00426875
31.12.2020	0,0108	0,007475	0,018275	0,00456875
31.03.2021	0,0101	0,007475	0,017575	0,00439375
30.06.2021	0,0121	0,007475	0,019575	0,00489375
30.09.2021	0,0147	0,007475	0,022175	0,00554375
31.12.2021	0,0166	0,007475	0,024075	0,00601875
31.03.2022	0,0187	0,007475	0,026175	0,00654375
30.06.2022	0,0204	0,007475	0,027875	0,00696875
30.09.2022	0,0207	0,007475	0,028175	0,00704375
31.12.2022	0,0199	0,007475	0,027375	0,00684375
31.03.2023	0,0179	0,007475	0,025375	0,00634375
30.06.2023	0,0147	0,007475	0,022175	0,00554375
30.09.2023	0,0139	0,007475	0,021375	0,00534375
31.12.2023	0,0138	0,007475	0,021275	0,00531875
31.03.2024	0,0125	0,007475	0,019975	0,00499375
30.06.2024	0,012	0,007475	0,019475	0,00486875
30.09.2024	0,0123	0,007475	0,019775	0,00494375
31.12.2024	0,0122	0,007475	0,019675	0,00491875
31.03.2025	0,0129	0,007475	0,020375	0,00509375
30.06.2025	0,0143	0,007475	0,021775	0,00544375
30.09.2025	0,0154	0,007475	0,022875	0,00571875
31.12.2025	0,0169	0,007475	0,024375	0,00609375
31.03.2026	0,0183	0,007475	0,025775	0,00644375
30.06.2026	0,0191	0,007475	0,026575	0,00664375
30.09.2026	0,0194	0,007475	0,026875	0,00671875
31.12.2026	0,0188	0,007475	0,026275	0,00656875
31.03.2027	0,0172	0,007475	0,024675	0,00616875
30.06.2027	0,0145	0,007475	0,021975	0,00549375
30.09.2027	0,0137	0,007475	0,021175	0,00529375
31.12.2027	0,0133	0,007475	0,020775	0,00519375
31.03.2028	0,0121	0,007475	0,019575	0,00489375
30.06.2028	0,0119	0,007475	0,019375	0,00484375
30.09.2028	0,0122	0,007475	0,019675	0,00491875
31.12.2028	0,0123	0,007475	0,019775	0,00494375
31.03.2029	0,0133	0,007475	0,020775	0,00519375
30.06.2029	0,0146	0,007475	0,022075	0,00551875
30.09.2029	0,0161	0,007475	0,023575	0,00589375
31.12.2029	0,0176	0,007475	0,025075	0,00626875
31.03.2030	0,0189	0,007475	0,026375	0,00659375
30.06.2030	0,0195	0,007475	0,026975	0,00674375
30.09.2030	0,0195	0,007475	0,026975	0,00674375
31.12.2030	0,0183	0,007475	0,025775	0,00644375
31.03.2031	0,016	0,007475	0,023475	0,00586875
30.06.2031	0,0138	0,007475	0,021275	0,00531875
30.09.2031	0,0137	0,007475	0,021175	0,00529375
31.12.2031	0,0128	0,007475	0,020275	0,00506875
31.03.2032	0,0118	0,007475	0,019275	0,00481875

30.06.2032	0,0121	0,007475	0,019575	0,00489375
30.09.2032	0,0122	0,007475	0,019675	0,00491875
31.12.2032	0,0125	0,007475	0,019975	0,00499375

Příloha E: Tabulka ocenění dluhopisů GOS_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,00426875	15 000 000,00 Kč		14 936 240,92 Kč
19.12.2020	1,008857003	15 000 000,00 Kč		14 868 311,32 Kč
19.03.2021	1,013289668	15 000 000,00 Kč		14 803 269,46 Kč
19.06.2021	1,018248455	15 000 000,00 Kč		14 731 178,75 Kč
19.09.2021	1,023893369	15 000 000,00 Kč		14 649 963,02 Kč
19.12.2021	1,030055928	15 000 000,00 Kč		14 562 316,08 Kč
19.03.2022	1,036796356	15 000 000,00 Kč		14 467 643,44 Kč
19.06.2022	1,044021531	15 000 000,00 Kč		14 367 519,79 Kč
19.09.2022	1,051375357	15 000 000,00 Kč		14 267 026,42 Kč
19.12.2022	1,058570708	15 000 000,00 Kč		14 170 050,14 Kč
19.03.2023	1,065286015	15 000 000,00 Kč		14 080 725,53 Kč
19.06.2023	1,071191695	15 000 000,00 Kč		14 003 095,87 Kč
19.09.2023	1,076915875	15 000 000,00 Kč		13 928 664,57 Kč
19.12.2023	1,082643722	15 000 000,00 Kč		13 854 973,43 Kč
19.03.2024	1,088050174	15 000 000,00 Kč		13 786 128,95 Kč
19.06.2024	1,093347618	15 000 000,00 Kč		13 719 332,95 Kč
19.09.2024	1,098752855	15 000 000,00 Kč		13 651 841,65 Kč
19.12.2024	1,104157346	15 000 000,00 Kč		13 585 020,34 Kč
19.03.2025	1,109781648	15 000 000,00 Kč		13 516 172,33 Kč
19.06.2025	1,115823021	15 000 000,00 Kč		13 442 992,05 Kč
19.09.2025	1,122204134	15 000 000,00 Kč		13 366 552,08 Kč
19.12.2025	1,129042566	15 000 000,00 Kč		13 285 592,99 Kč
19.03.2026	1,136317834	15 000 000,00 Kč		13 200 532,06 Kč
19.06.2026	1,143867245	15 000 000,00 Kč		13 113 409,85 Kč
19.09.2026	1,151552603	15 000 000,00 Kč		13 025 892,14 Kč
19.12.2026	1,159116865	15 000 000,00 Kč		12 940 886,69 Kč
19.03.2027	1,166267167	15 000 000,00 Kč		12 861 547,02 Kč
19.06.2027	1,172674347	15 000 000,00 Kč		12 791 274,95 Kč
19.09.2027	1,178882192	15 000 000,00 Kč		12 723 917,71 Kč
19.12.2027	1,185005011	15 000 000,00 Kč		12 658 174,32 Kč
19.03.2028	1,190804129	15 000 000,00 Kč		12 596 530,05 Kč
19.06.2028	1,196572087	15 000 000,00 Kč		12 535 809,72 Kč
19.09.2028	1,202457726	15 000 000,00 Kč		12 474 451,02 Kč
19.12.2028	1,208402376	15 000 000,00 Kč		12 413 083,83 Kč
19.03.2029	1,214678516	15 000 000,00 Kč		12 348 946,49 Kč
19.06.2029	1,221382023	15 000 000,00 Kč		12 281 169,79 Kč
19.09.2029	1,228580543	15 000 000,00 Kč		12 209 211,74 Kč
19.12.2029	1,236282208	15 000 000,00 Kč		12 133 152,05 Kč
19.03.2030	1,244433944	15 000 000,00 Kč		12 053 673,14 Kč
19.06.2030	1,252826095	15 000 000,00 Kč		11 972 930,69 Kč
19.09.2030	1,261274841	15 000 000,00 Kč		11 892 729,10 Kč
19.12.2030	1,269402181	15 000 000,00 Kč		11 816 585,97 Kč
19.03.2031	1,276851985	15 000 000,00 Kč		11 747 642,00 Kč
19.06.2031	1,283643241	15 000 000,00 Kč		11 685 489,80 Kč
19.09.2031	1,290438528	15 000 000,00 Kč		11 623 955,48 Kč
19.12.2031	1,296979438	15 000 000,00 Kč		11 565 333,70 Kč
19.03.2032	1,303229258	15 000 000,00 Kč		11 509 870,51 Kč
19.06.2032	1,309606936	15 000 000,00 Kč		11 453 818,39 Kč
19.09.2032	1,316048565	15 000 000,00 Kč		11 397 755,68 Kč
19.12.2032	1,322620582	15 000 000,00 Kč	500 000 000,00 Kč	389 378 486,05 Kč
Total		750 000 000,00 Kč		1 030 450 871,99 Kč

Příloha F: Tabulka diskontní sazby SAF_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,113808	0,123408	0,030852
31.12.2020	0,0108	0,113808	0,124608	0,031152
31.03.2021	0,0101	0,113808	0,123908	0,030977
30.06.2021	0,0121	0,113808	0,125908	0,031477
30.09.2021	0,0147	0,113808	0,128508	0,032127
31.12.2021	0,0166	0,113808	0,130408	0,032602
31.03.2022	0,0187	0,113808	0,132508	0,033127
30.06.2022	0,0204	0,113808	0,134208	0,033552
30.09.2022	0,0207	0,113808	0,134508	0,033627
31.12.2022	0,0199	0,113808	0,133708	0,033427
31.03.2023	0,0179	0,113808	0,131708	0,032927
30.06.2023	0,0147	0,113808	0,128508	0,032127
30.09.2023	0,0139	0,113808	0,127708	0,031927
31.12.2023	0,0138	0,113808	0,127608	0,031902
31.03.2024	0,0125	0,113808	0,126308	0,031577
30.06.2024	0,012	0,113808	0,125808	0,031452
30.09.2024	0,0123	0,113808	0,126108	0,031527
31.12.2024	0,0122	0,113808	0,126008	0,031502
31.03.2025	0,0129	0,113808	0,126708	0,031677
30.06.2025	0,0143	0,113808	0,128108	0,032027
30.09.2025	0,0154	0,113808	0,129208	0,032302
31.12.2025	0,0169	0,113808	0,130708	0,032677
31.03.2026	0,0183	0,113808	0,132108	0,033027
30.06.2026	0,0191	0,113808	0,132908	0,033227
30.09.2026	0,0194	0,113808	0,133208	0,033302
31.12.2026	0,0188	0,113808	0,132608	0,033152
31.03.2027	0,0172	0,113808	0,131008	0,032752
30.06.2027	0,0145	0,113808	0,128308	0,032077
30.09.2027	0,0137	0,113808	0,127508	0,031877
31.12.2027	0,0133	0,113808	0,127108	0,031777
31.03.2028	0,0121	0,113808	0,125908	0,031477
30.06.2028	0,0119	0,113808	0,125708	0,031427
30.09.2028	0,0122	0,113808	0,126008	0,031502
31.12.2028	0,0123	0,113808	0,126108	0,031527
31.03.2029	0,0133	0,113808	0,127108	0,031777
30.06.2029	0,0146	0,113808	0,128408	0,032102
30.09.2029	0,0161	0,113808	0,129908	0,032477
31.12.2029	0,0176	0,113808	0,131408	0,032852
31.03.2030	0,0189	0,113808	0,132708	0,033177
30.06.2030	0,0195	0,113808	0,133308	0,033327
30.09.2030	0,0195	0,113808	0,133308	0,033327
31.12.2030	0,0183	0,113808	0,132108	0,033027
31.03.2031	0,016	0,113808	0,129808	0,032452
30.06.2031	0,0138	0,113808	0,127608	0,031902
30.09.2031	0,0137	0,113808	0,127508	0,031877
31.12.2031	0,0128	0,113808	0,126608	0,031652
31.03.2032	0,0118	0,113808	0,125608	0,031402
30.06.2032	0,0121	0,113808	0,125908	0,031477
30.09.2032	0,0122	0,113808	0,126008	0,031502
31.12.2032	0,0125	0,113808	0,126308	0,031577
31.03.2033	0,0139	0,113808	0,127708	0,031927
30.06.2033	0,0151	0,113808	0,128908	0,032227
30.09.2033	0,0165	0,113808	0,130308	0,032577
31.12.2033	0,018	0,113808	0,131808	0,032952
31.03.2034	0,019	0,113808	0,132808	0,033202

30.06.2034	0,0194	0,113808	0,133208	0,033302
30.09.2034	0,019	0,113808	0,132808	0,033202
31.12.2034	0,0175	0,113808	0,131308	0,032827
31.03.2035	0,015	0,113808	0,128808	0,032202
30.06.2035	0,0136	0,113808	0,127408	0,031852
30.09.2035	0,0133	0,113808	0,127108	0,031777
31.12.2035	0,0122	0,113808	0,126008	0,031502
31.03.2036	0,0116	0,113808	0,125408	0,031352
30.06.2036	0,0121	0,113808	0,125908	0,031477
30.09.2036	0,0123	0,113808	0,126108	0,031527
31.12.2036	0,0131	0,113808	0,126908	0,031727
31.03.2037	0,0147	0,113808	0,128508	0,032127
30.06.2037	0,0162	0,113808	0,130008	0,032502
30.09.2037	0,0177	0,113808	0,131508	0,032877
31.12.2037	0,019	0,113808	0,132808	0,033202
31.03.2038	0,0196	0,113808	0,133408	0,033352
30.06.2038	0,0194	0,113808	0,133208	0,033302
30.09.2038	0,0182	0,113808	0,132008	0,033002
31.12.2038	0,0158	0,113808	0,129608	0,032402
31.03.2039	0,0138	0,113808	0,127608	0,031902
30.06.2039	0,0136	0,113808	0,127408	0,031852
30.09.2039	0,0127	0,113808	0,126508	0,031627

Příloha G: Tabulka ocenění dluhopisů SAF_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,030852	5 500 000,00 Kč		5 335 392,47 Kč
19.12.2020	1,062965102	5 500 000,00 Kč		5 174 205,62 Kč
19.03.2021	1,095892571	5 500 000,00 Kč		5 018 740,11 Kč
19.06.2021	1,130387982	5 500 000,00 Kč		4 865 586,05 Kč
19.09.2021	1,166703957	5 500 000,00 Kč		4 714 135,04 Kč
19.12.2021	1,204740839	5 500 000,00 Kč		4 565 297,22 Kč
19.03.2022	1,244650289	5 500 000,00 Kč		4 418 911,92 Kč
19.06.2022	1,286410795	5 500 000,00 Kč		4 275 461,63 Kč
19.09.2022	1,329668931	5 500 000,00 Kč		4 136 367,99 Kč
19.12.2022	1,374115774	5 500 000,00 Kč		4 002 573,95 Kč
19.03.2023	1,419361285	5 500 000,00 Kč		3 874 982,40 Kč
19.06.2023	1,464961105	5 500 000,00 Kč		3 754 365,89 Kč
19.09.2023	1,511732918	5 500 000,00 Kč		3 638 208,80 Kč
19.12.2023	1,559960221	5 500 000,00 Kč		3 525 730,93 Kč
19.03.2024	1,609219085	5 500 000,00 Kč		3 417 806,84 Kč
19.06.2024	1,659832244	5 500 000,00 Kč		3 313 587,88 Kč
19.09.2024	1,712161775	5 500 000,00 Kč		3 212 313,28 Kč
19.12.2024	1,766098295	5 500 000,00 Kč		3 114 209,45 Kč
19.03.2025	1,822042991	5 500 000,00 Kč		3 018 589,59 Kč
19.06.2025	1,880397562	5 500 000,00 Kč		2 924 913,39 Kč
19.09.2025	1,941138164	5 500 000,00 Kč		2 833 389,25 Kč
19.12.2025	2,004568736	5 500 000,00 Kč		2 743 732,31 Kč
19.03.2026	2,070773627	5 500 000,00 Kč		2 656 012,19 Kč
19.06.2026	2,139579223	5 500 000,00 Kč		2 570 598,90 Kč
19.09.2026	2,21083149	5 500 000,00 Kč		2 487 751,79 Kč
19.12.2026	2,284124975	5 500 000,00 Kč		2 407 924,29 Kč
19.03.2027	2,358934637	5 500 000,00 Kč		2 331 561,00 Kč
19.06.2027	2,434602183	5 500 000,00 Kč		2 259 095,98 Kč
19.09.2027	2,512209997	5 500 000,00 Kč		2 189 307,43 Kč
19.12.2027	2,592040494	5 500 000,00 Kč		2 121 880,43 Kč
19.03.2028	2,673630152	5 500 000,00 Kč		2 057 128,21 Kč
19.06.2028	2,757654327	5 500 000,00 Kč		1 994 448,67 Kč
19.09.2028	2,844525954	5 500 000,00 Kč		1 933 538,34 Kč
19.12.2028	2,934205324	5 500 000,00 Kč		1 874 442,79 Kč
19.03.2029	3,027445566	5 500 000,00 Kč		1 816 713,09 Kč
19.06.2029	3,124632624	5 500 000,00 Kč		1 760 206,93 Kč
19.09.2029	3,226111317	5 500 000,00 Kč		1 704 838,88 Kč
19.12.2029	3,332095526	5 500 000,00 Kč		1 650 612,94 Kč
19.03.2030	3,44264446	5 500 000,00 Kč		1 597 609,07 Kč
19.06.2030	3,557377472	5 500 000,00 Kč		1 546 082,77 Kč
19.09.2030	3,675934191	5 500 000,00 Kč		1 496 218,30 Kč
19.12.2030	3,797339269	5 500 000,00 Kč		1 448 382,57 Kč
19.03.2031	3,920570523	5 500 000,00 Kč		1 402 857,05 Kč
19.06.2031	4,045644564	5 500 000,00 Kč		1 359 486,71 Kč
19.09.2031	4,174607576	5 500 000,00 Kč		1 317 489,11 Kč
19.12.2031	4,306742255	5 500 000,00 Kč		1 277 067,37 Kč
19.03.2032	4,441982575	5 500 000,00 Kč		1 238 185,86 Kč
19.06.2032	4,58180286	5 500 000,00 Kč		1 200 400,84 Kč
19.09.2032	4,726138814	5 500 000,00 Kč		1 163 740,68 Kč
19.12.2032	4,875376099	5 500 000,00 Kč		1 128 118,10 Kč
19.03.2033	5,031032232	5 500 000,00 Kč		1 093 215,02 Kč
19.06.2033	5,193167308	5 500 000,00 Kč		1 059 083,92 Kč
19.09.2033	5,362345119	5 500 000,00 Kč		1 025 670,65 Kč
19.12.2033	5,539045116	5 500 000,00 Kč		992 950,93 Kč

19.03.2034	5,722952492	5 500 000,00 Kč		961 042,40 Kč
19.06.2034	5,913538256	5 500 000,00 Kč		930 069,23 Kč
19.09.2034	6,109879553	5 500 000,00 Kč		900 181,41 Kč
19.12.2034	6,310448569	5 500 000,00 Kč		871 570,37 Kč
19.03.2035	6,513657634	5 500 000,00 Kč		844 379,66 Kč
19.06.2035	6,721130656	5 500 000,00 Kč		818 314,70 Kč
19.09.2035	6,934708025	5 500 000,00 Kč		793 111,98 Kč
19.12.2035	7,153165198	5 500 000,00 Kč		768 890,39 Kč
19.03.2036	7,377431233	5 500 000,00 Kč		745 516,95 Kč
19.06.2036	7,609650636	5 500 000,00 Kč		722 766,43 Kč
19.09.2036	7,849560091	5 500 000,00 Kč		700 676,21 Kč
19.12.2036	8,098603084	5 500 000,00 Kč		679 129,47 Kč
19.03.2037	8,358786906	5 500 000,00 Kč		657 990,22 Kč
19.06.2037	8,630464198	5 500 000,00 Kč		637 277,42 Kč
19.09.2037	8,914207969	5 500 000,00 Kč		616 992,56 Kč
19.12.2037	9,210177502	5 500 000,00 Kč		597 165,47 Kč
19.03.2038	9,517355342	5 500 000,00 Kč		577 891,63 Kč
19.06.2038	9,83430231	5 500 000,00 Kč		559 266,92 Kč
19.09.2038	10,15885395	5 500 000,00 Kč		541 399,65 Kč
19.12.2038	10,48802114	5 500 000,00 Kč		524 407,79 Kč
19.03.2039	10,82260999	5 500 000,00 Kč		508 195,34 Kč
19.06.2039	11,16733176	5 500 000,00 Kč		492 507,98 Kč
19.09.2039	11,52052097	4 400 000,00 Kč	200 000 000,00 Kč	17 742 253,20 Kč
Total		422 400 000,00 Kč	200 000 000,00 Kč	173 232 120,15 Kč

Příloha H: Tabulka diskontní sazby SAF_2

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,113808	0,123408	0,030852
31.12.2020	0,0108	0,113808	0,124608	0,031152
31.03.2021	0,0101	0,113808	0,123908	0,030977
30.06.2021	0,0121	0,113808	0,125908	0,031477
30.09.2021	0,0147	0,113808	0,128508	0,032127
31.12.2021	0,0166	0,113808	0,130408	0,032602
31.03.2022	0,0187	0,113808	0,132508	0,033127
30.06.2022	0,0204	0,113808	0,134208	0,033552
30.09.2022	0,0207	0,113808	0,134508	0,033627
31.12.2022	0,0199	0,113808	0,133708	0,033427
31.03.2023	0,0179	0,113808	0,131708	0,032927
30.06.2023	0,0147	0,113808	0,128508	0,032127
30.09.2023	0,0139	0,113808	0,127708	0,031927
31.12.2023	0,0138	0,113808	0,127608	0,031902
31.03.2024	0,0125	0,113808	0,126308	0,031577
30.06.2024	0,012	0,113808	0,125808	0,031452
30.09.2024	0,0123	0,113808	0,126108	0,031527
31.12.2024	0,0122	0,113808	0,126008	0,031502
31.03.2025	0,0129	0,113808	0,126708	0,031677
30.06.2025	0,0143	0,113808	0,128108	0,032027
30.09.2025	0,0154	0,113808	0,129208	0,032302
31.12.2025	0,0169	0,113808	0,130708	0,032677
31.03.2026	0,0183	0,113808	0,132108	0,033027
30.06.2026	0,0191	0,113808	0,132908	0,033227
30.09.2026	0,0194	0,113808	0,133208	0,033302
31.12.2026	0,0188	0,113808	0,132608	0,033152
31.03.2027	0,0172	0,113808	0,131008	0,032752
30.06.2027	0,0145	0,113808	0,128308	0,032077
30.09.2027	0,0137	0,113808	0,127508	0,031877
31.12.2027	0,0133	0,113808	0,127108	0,031777
31.03.2028	0,0121	0,113808	0,125908	0,031477
30.06.2028	0,0119	0,113808	0,125708	0,031427
30.09.2028	0,0122	0,113808	0,126008	0,031502
31.12.2028	0,0123	0,113808	0,126108	0,031527
31.03.2029	0,0133	0,113808	0,127108	0,031777
30.06.2029	0,0146	0,113808	0,128408	0,032102
30.09.2029	0,0161	0,113808	0,129908	0,032477
31.12.2029	0,0176	0,113808	0,131408	0,032852
31.03.2030	0,0189	0,113808	0,132708	0,033177
30.06.2030	0,0195	0,113808	0,133308	0,033327
30.09.2030	0,0195	0,113808	0,133308	0,033327
31.12.2030	0,0183	0,113808	0,132108	0,033027
31.03.2031	0,016	0,113808	0,129808	0,032452
30.06.2031	0,0138	0,113808	0,127608	0,031902
30.09.2031	0,0137	0,113808	0,127508	0,031877
31.12.2031	0,0128	0,113808	0,126608	0,031652
31.03.2032	0,0118	0,113808	0,125608	0,031402
30.06.2032	0,0121	0,113808	0,125908	0,031477
30.09.2032	0,0122	0,113808	0,126008	0,031502
31.12.2032	0,0125	0,113808	0,126308	0,031577

Příloha I: Tabulka ocenění dluhopisů SAF_2

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,030852	27 500 000,00 Kč		26 676 962,36 Kč
19.12.2020	1,062965102	27 500 000,00 Kč		25 871 028,09 Kč
19.03.2021	1,095892571	27 500 000,00 Kč		25 093 700,53 Kč
19.06.2021	1,130387982	27 500 000,00 Kč		24 327 930,27 Kč
19.09.2021	1,166703957	27 500 000,00 Kč		23 570 675,19 Kč
19.12.2021	1,204740839	27 500 000,00 Kč		22 826 486,09 Kč
19.03.2022	1,244650289	27 500 000,00 Kč		22 094 559,61 Kč
19.06.2022	1,286410795	27 500 000,00 Kč		21 377 308,17 Kč
19.09.2022	1,329668931	27 500 000,00 Kč		20 681 839,94 Kč
19.12.2022	1,374115774	27 500 000,00 Kč		20 012 869,74 Kč
19.03.2023	1,419361285	27 500 000,00 Kč		19 374 912,01 Kč
19.06.2023	1,464961105	27 500 000,00 Kč		18 771 829,45 Kč
19.09.2023	1,511732918	27 500 000,00 Kč		18 191 043,99 Kč
19.12.2023	1,559960221	27 500 000,00 Kč		17 628 654,64 Kč
19.03.2024	1,609219085	27 500 000,00 Kč		17 089 034,21 Kč
19.06.2024	1,659832244	27 500 000,00 Kč		16 567 939,38 Kč
19.09.2024	1,712161775	27 500 000,00 Kč		16 061 566,38 Kč
19.12.2024	1,766098295	27 500 000,00 Kč		15 571 047,25 Kč
19.03.2025	1,822042991	27 500 000,00 Kč		15 092 947,94 Kč
19.06.2025	1,880397562	27 500 000,00 Kč		14 624 566,93 Kč
19.09.2025	1,941138164	27 500 000,00 Kč		14 166 946,23 Kč
19.12.2025	2,004568736	27 500 000,00 Kč		13 718 661,53 Kč
19.03.2026	2,070773627	27 500 000,00 Kč		13 280 060,96 Kč
19.06.2026	2,139579223	27 500 000,00 Kč		12 852 994,51 Kč
19.09.2026	2,21083149	27 500 000,00 Kč		12 438 758,96 Kč
19.12.2026	2,284124975	27 500 000,00 Kč		12 039 621,43 Kč
19.03.2027	2,358934637	27 500 000,00 Kč		11 657 805,00 Kč
19.06.2027	2,434602183	27 500 000,00 Kč		11 295 479,89 Kč
19.09.2027	2,512209997	27 500 000,00 Kč		10 946 537,13 Kč
19.12.2027	2,592040494	27 500 000,00 Kč		10 609 402,15 Kč
19.03.2028	2,673630152	27 500 000,00 Kč		10 285 641,03 Kč
19.06.2028	2,757654327	27 500 000,00 Kč		9 972 243,34 Kč
19.09.2028	2,844525954	27 500 000,00 Kč		9 667 691,72 Kč
19.12.2028	2,934205324	27 500 000,00 Kč		9 372 213,93 Kč
19.03.2029	3,027445566	27 500 000,00 Kč		9 083 565,47 Kč
19.06.2029	3,124632624	27 500 000,00 Kč		8 801 034,65 Kč
19.09.2029	3,226111317	27 500 000,00 Kč		8 524 194,39 Kč
19.12.2029	3,332095526	27 500 000,00 Kč		8 253 064,71 Kč
19.03.2030	3,44264446	27 500 000,00 Kč		7 988 045,33 Kč
19.06.2030	3,557377472	27 500 000,00 Kč		7 730 413,83 Kč
19.09.2030	3,675934191	27 500 000,00 Kč		7 481 091,49 Kč
19.12.2030	3,797339269	27 500 000,00 Kč		7 241 912,84 Kč
19.03.2031	3,920570523	27 500 000,00 Kč		7 014 285,25 Kč
19.06.2031	4,045644564	27 500 000,00 Kč		6 797 433,53 Kč
19.09.2031	4,174607576	27 500 000,00 Kč		6 587 445,53 Kč
19.12.2031	4,306742255	27 500 000,00 Kč		6 385 336,84 Kč
19.03.2032	4,441982575	27 500 000,00 Kč		6 190 929,28 Kč
19.06.2032	4,58180286	27 500 000,00 Kč		6 002 004,20 Kč
19.09.2032	4,726138814	27 500 000,00 Kč		5 818 703,40 Kč
19.12.2032	4,875376099	47 500 000,00 Kč	1 000 000 000,00 Kč	214 855 219,09 Kč
Total		1 395 000 000,00 Kč	1 000 000 000,00 Kč	888 565 639,79 Kč

Příloha J: Tabulka diskontní sazby SAF_3

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.q.
30.09.2020	0,0096	0,113808	0,123408	0,030852
31.12.2020	0,0108	0,113808	0,124608	0,031152
31.03.2021	0,0101	0,113808	0,123908	0,030977
30.06.2021	0,0121	0,113808	0,125908	0,031477
30.09.2021	0,0147	0,113808	0,128508	0,032127
31.12.2021	0,0166	0,113808	0,130408	0,032602
31.03.2022	0,0187	0,113808	0,132508	0,033127
30.06.2022	0,0204	0,113808	0,134208	0,033552
30.09.2022	0,0207	0,113808	0,134508	0,033627
31.12.2022	0,0199	0,113808	0,133708	0,033427
31.03.2023	0,0179	0,113808	0,131708	0,032927
30.06.2023	0,0147	0,113808	0,128508	0,032127
30.09.2023	0,0139	0,113808	0,127708	0,031927
31.12.2023	0,0138	0,113808	0,127608	0,031902
31.03.2024	0,0125	0,113808	0,126308	0,031577
30.06.2024	0,012	0,113808	0,125808	0,031452
30.09.2024	0,0123	0,113808	0,126108	0,031527
31.12.2024	0,0122	0,113808	0,126008	0,031502
31.03.2025	0,0129	0,113808	0,126708	0,031677
30.06.2025	0,0143	0,113808	0,128108	0,032027
30.09.2025	0,0154	0,113808	0,129208	0,032302
31.12.2025	0,0169	0,113808	0,130708	0,032677
31.03.2026	0,0183	0,113808	0,132108	0,033027
30.06.2026	0,0191	0,113808	0,132908	0,033227
30.09.2026	0,0194	0,113808	0,133208	0,033302
31.12.2026	0,0188	0,113808	0,132608	0,033152
31.03.2027	0,0172	0,113808	0,131008	0,032752
30.06.2027	0,0145	0,113808	0,128308	0,032077
30.09.2027	0,0137	0,113808	0,127508	0,031877
31.12.2027	0,0133	0,113808	0,127108	0,031777
31.03.2028	0,0121	0,113808	0,125908	0,031477
30.06.2028	0,0119	0,113808	0,125708	0,031427
30.09.2028	0,0122	0,113808	0,126008	0,031502
31.12.2028	0,0123	0,113808	0,126108	0,031527
31.03.2029	0,0133	0,113808	0,127108	0,031777
30.06.2029	0,0146	0,113808	0,128408	0,032102
30.09.2029	0,0161	0,113808	0,129908	0,032477
31.12.2029	0,0176	0,113808	0,131408	0,032852
31.03.2030	0,0189	0,113808	0,132708	0,033177
30.06.2030	0,0195	0,113808	0,133308	0,033327
30.09.2030	0,0195	0,113808	0,133308	0,033327
31.12.2030	0,0183	0,113808	0,132108	0,033027
31.03.2031	0,016	0,113808	0,129808	0,032452
30.06.2031	0,0138	0,113808	0,127608	0,031902
30.09.2031	0,0137	0,113808	0,127508	0,031877
31.12.2031	0,0128	0,113808	0,126608	0,031652
31.03.2032	0,0118	0,113808	0,125608	0,031402
30.06.2032	0,0121	0,113808	0,125908	0,031477
30.09.2032	0,0122	0,113808	0,126008	0,031502
31.12.2032	0,0125	0,113808	0,126308	0,031577
31.03.2033	0,0139	0,113808	0,127708	0,031927
30.06.2033	0,0151	0,113808	0,128908	0,032227
30.09.2033	0,0165	0,113808	0,130308	0,032577
31.12.2033	0,018	0,113808	0,131808	0,032952
31.03.2034	0,019	0,113808	0,132808	0,033202

30.06.2034	0,0194	0,113808	0,133208	0,033302
30.09.2034	0,019	0,113808	0,132808	0,033202
31.12.2034	0,0175	0,113808	0,131308	0,032827
31.03.2035	0,015	0,113808	0,128808	0,032202
30.06.2035	0,0136	0,113808	0,127408	0,031852
30.09.2035	0,0133	0,113808	0,127108	0,031777
31.12.2035	0,0122	0,113808	0,126008	0,031502
31.03.2036	0,0116	0,113808	0,125408	0,031352
30.06.2036	0,0121	0,113808	0,125908	0,031477
30.09.2036	0,0123	0,113808	0,126108	0,031527
31.12.2036	0,0131	0,113808	0,126908	0,031727
31.03.2037	0,0147	0,113808	0,128508	0,032127
30.06.2037	0,0162	0,113808	0,130008	0,032502
30.09.2037	0,0177	0,113808	0,131508	0,032877
31.12.2037	0,019	0,113808	0,132808	0,033202
31.03.2038	0,0196	0,113808	0,133408	0,033352
30.06.2038	0,0194	0,113808	0,133208	0,033302
30.09.2038	0,0182	0,113808	0,132008	0,033002
31.12.2038	0,0158	0,113808	0,129608	0,032402
31.03.2039	0,0138	0,113808	0,127608	0,031902
30.06.2039	0,0136	0,113808	0,127408	0,031852
30.09.2039	0,0127	0,113808	0,126508	0,031627
31.12.2039	0,0117	0,113808	0,125508	0,031377
31.03.2040	0,0121	0,113808	0,125908	0,031477
30.06.2040	0,0122	0,113808	0,126008	0,031502

Příloha K: Tabulka ocenění dluhopisů SAF_3

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
19.09.2020	1,030852	2 200 000,00 Kč		2 134 156,99 Kč
19.12.2020	1,062965102	2 200 000,00 Kč		2 069 682,25 Kč
19.03.2021	1,095892571	2 200 000,00 Kč		2 007 496,04 Kč
19.06.2021	1,130387982	2 200 000,00 Kč		1 946 234,42 Kč
19.09.2021	1,166703957	2 200 000,00 Kč		1 885 654,01 Kč
19.12.2021	1,204740839	2 200 000,00 Kč		1 826 118,89 Kč
19.03.2022	1,244650289	2 200 000,00 Kč		1 767 564,77 Kč
19.06.2022	1,286410795	2 200 000,00 Kč		1 710 184,65 Kč
19.09.2022	1,329668931	2 200 000,00 Kč		1 654 547,19 Kč
19.12.2022	1,374115774	2 200 000,00 Kč		1 601 029,58 Kč
19.03.2023	1,419361285	2 200 000,00 Kč		1 549 992,96 Kč
19.06.2023	1,464961105	2 200 000,00 Kč		1 501 746,36 Kč
19.09.2023	1,511732918	2 200 000,00 Kč		1 455 283,52 Kč
19.12.2023	1,559960221	2 200 000,00 Kč		1 410 292,37 Kč
19.03.2024	1,609219085	2 200 000,00 Kč		1 367 122,74 Kč
19.06.2024	1,659832244	2 200 000,00 Kč		1 325 435,15 Kč
19.09.2024	1,712161775	2 200 000,00 Kč		1 284 925,31 Kč
19.12.2024	1,766098295	2 200 000,00 Kč		1 245 683,78 Kč
19.03.2025	1,822042991	2 200 000,00 Kč		1 207 435,83 Kč
19.06.2025	1,880397562	2 200 000,00 Kč		1 169 965,35 Kč
19.09.2025	1,941138164	2 200 000,00 Kč		1 133 355,70 Kč
19.12.2025	2,004568736	2 200 000,00 Kč		1 097 492,92 Kč
19.03.2026	2,070773627	2 200 000,00 Kč		1 062 404,88 Kč
19.06.2026	2,139579223	2 200 000,00 Kč		1 028 239,56 Kč
19.09.2026	2,21083149	2 200 000,00 Kč		995 100,72 Kč
19.12.2026	2,284124975	2 200 000,00 Kč		963 169,71 Kč
19.03.2027	2,358934637	2 200 000,00 Kč		932 624,40 Kč
19.06.2027	2,434602183	2 200 000,00 Kč		903 638,39 Kč
19.09.2027	2,512209997	2 200 000,00 Kč		875 722,97 Kč
19.12.2027	2,592040494	2 200 000,00 Kč		848 752,17 Kč
19.03.2028	2,673630152	2 200 000,00 Kč		822 851,28 Kč
19.06.2028	2,757654327	2 200 000,00 Kč		797 779,47 Kč
19.09.2028	2,844525954	2 200 000,00 Kč		773 415,34 Kč
19.12.2028	2,934205324	2 200 000,00 Kč		749 777,11 Kč
19.03.2029	3,027445566	2 200 000,00 Kč		726 685,24 Kč
19.06.2029	3,124632624	2 200 000,00 Kč		704 082,77 Kč
19.09.2029	3,226111317	2 200 000,00 Kč		681 935,55 Kč
19.12.2029	3,332095526	2 200 000,00 Kč		660 245,18 Kč
19.03.2030	3,44264446	2 200 000,00 Kč		639 043,63 Kč
19.06.2030	3,557377472	2 200 000,00 Kč		618 433,11 Kč
19.09.2030	3,675934191	2 200 000,00 Kč		598 487,32 Kč
19.12.2030	3,797339269	2 200 000,00 Kč		579 353,03 Kč
19.03.2031	3,920570523	2 200 000,00 Kč		561 142,82 Kč
19.06.2031	4,045644564	2 200 000,00 Kč		543 794,68 Kč
19.09.2031	4,174607576	2 200 000,00 Kč		526 995,64 Kč
19.12.2031	4,306742255	2 200 000,00 Kč		510 826,95 Kč
19.03.2032	4,441982575	2 200 000,00 Kč		495 274,34 Kč
19.06.2032	4,58180286	2 200 000,00 Kč		480 160,34 Kč
19.09.2032	4,726138814	2 200 000,00 Kč		465 496,27 Kč
19.12.2032	4,875376099	2 200 000,00 Kč		451 247,24 Kč
19.03.2033	5,031032232	2 200 000,00 Kč		437 286,01 Kč
19.06.2033	5,193167308	2 200 000,00 Kč		423 633,57 Kč
19.09.2033	5,362345119	2 200 000,00 Kč		410 268,26 Kč
19.12.2033	5,539045116	2 200 000,00 Kč		397 180,37 Kč

19.03.2034	5,722952492	2 200 000,00 Kč		384 416,96 Kč
19.06.2034	5,913538256	2 200 000,00 Kč		372 027,69 Kč
19.09.2034	6,109879553	2 200 000,00 Kč		360 072,56 Kč
19.12.2034	6,310448569	2 200 000,00 Kč		348 628,15 Kč
19.03.2035	6,513657634	2 200 000,00 Kč		337 751,86 Kč
19.06.2035	6,721130656	2 200 000,00 Kč		327 325,88 Kč
19.09.2035	6,934708025	2 200 000,00 Kč		317 244,79 Kč
19.12.2035	7,153165198	2 200 000,00 Kč		307 556,16 Kč
19.03.2036	7,377431233	2 200 000,00 Kč		298 206,78 Kč
19.06.2036	7,609650636	2 200 000,00 Kč		289 106,57 Kč
19.09.2036	7,849560091	2 200 000,00 Kč		280 270,48 Kč
19.12.2036	8,098603084	2 200 000,00 Kč		271 651,79 Kč
19.03.2037	8,358786906	2 200 000,00 Kč		263 196,09 Kč
19.06.2037	8,630464198	2 200 000,00 Kč		254 910,97 Kč
19.09.2037	8,914207969	2 200 000,00 Kč		246 797,02 Kč
19.12.2037	9,210177502	2 200 000,00 Kč		238 866,19 Kč
19.03.2038	9,517355342	2 200 000,00 Kč		231 156,65 Kč
19.06.2038	9,83430231	2 200 000,00 Kč		223 706,77 Kč
19.09.2038	10,15885395	2 200 000,00 Kč		216 559,86 Kč
19.12.2038	10,48802114	2 200 000,00 Kč		209 763,12 Kč
19.03.2039	10,82260999	2 200 000,00 Kč		203 278,14 Kč
19.06.2039	11,16733176	2 200 000,00 Kč		197 003,19 Kč
19.09.2039	11,52052097	2 200 000,00 Kč		190 963,59 Kč
19.12.2039	11,88200035	2 200 000,00 Kč		185 154,01 Kč
19.03.2040	12,25601008	2 200 000,00 Kč		179 503,77 Kč
19.06.2040	12,64209891	2 200 000,00 Kč	80 000 000,00 Kč	6 502 084,87 Kč
Total		176 000 000,00 Kč	80 000 000,00 Kč	69 253 653,01 Kč

Příloha L: Tabulka diskontní sazby TPH_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.m.
30.09.2020	0,0096	0,0342161	0,0438161	0,00365134
31.10.2020	0,0105	0,0342161	0,0447161	0,00372634
30.11.2020	0,0111	0,0342161	0,0453161	0,00377634
31.12.2020	0,0108	0,0342161	0,0450161	0,00375134
31.01.2021	0,0108	0,0342161	0,0450161	0,00375134
28.02.2021	0,0103	0,0342161	0,0445161	0,00370967
31.03.2021	0,0101	0,0342161	0,0443161	0,00369301
30.04.2021	0,0095	0,0342161	0,0437161	0,00364301
31.05.2021	0,0108	0,0342161	0,0450161	0,00375134
30.06.2021	0,0121	0,0342161	0,0463161	0,00385967
31.07.2021	0,0132	0,0342161	0,0474161	0,00395134
31.08.2021	0,0139	0,0342161	0,0481161	0,00400967
30.09.2021	0,0147	0,0342161	0,0489161	0,00407634
31.10.2021	0,0153	0,0342161	0,0495161	0,00412634
30.11.2021	0,0157	0,0342161	0,0499161	0,00415967
31.12.2021	0,0166	0,0342161	0,0508161	0,00423467
31.01.2022	0,0172	0,0342161	0,0514161	0,00428467
28.02.2022	0,018	0,0342161	0,0522161	0,00435134
31.03.2022	0,0187	0,0342161	0,0529161	0,00440967
30.04.2022	0,0196	0,0342161	0,0538161	0,00448467
31.05.2022	0,0201	0,0342161	0,0543161	0,00452634
30.06.2022	0,0204	0,0342161	0,0546161	0,00455134
31.07.2022	0,0206	0,0342161	0,0548161	0,00456801
31.08.2022	0,0207	0,0342161	0,0549161	0,00457634
30.09.2022	0,0207	0,0342161	0,0549161	0,00457634
31.10.2022	0,0206	0,0342161	0,0548161	0,00456801
30.11.2022	0,0204	0,0342161	0,0546161	0,00455134
31.12.2022	0,0199	0,0342161	0,0541161	0,00450967
31.01.2023	0,0194	0,0342161	0,0536161	0,00446801
28.02.2023	0,0187	0,0342161	0,0529161	0,00440967
31.03.2023	0,0179	0,0342161	0,0521161	0,00434301
30.04.2023	0,0168	0,0342161	0,0510161	0,00425134
31.05.2023	0,0157	0,0342161	0,0499161	0,00415967
30.06.2023	0,0147	0,0342161	0,0489161	0,00407634
31.07.2023	0,0141	0,0342161	0,0483161	0,00402634
31.08.2023	0,0139	0,0342161	0,0481161	0,00400967
30.09.2023	0,0139	0,0342161	0,0481161	0,00400967
31.10.2023	0,0139	0,0342161	0,0481161	0,00400967
30.11.2023	0,0139	0,0342161	0,0481161	0,00400967
31.12.2023	0,0138	0,0342161	0,0480161	0,00400134
31.01.2024	0,0135	0,0342161	0,0477161	0,00397634
29.02.2024	0,0131	0,0342161	0,0473161	0,00394301
31.03.2024	0,0125	0,0342161	0,0467161	0,00389301
30.04.2024	0,012	0,0342161	0,0462161	0,00385134
31.05.2024	0,0118	0,0342161	0,0460161	0,00383467
30.06.2024	0,012	0,0342161	0,0462161	0,00385134
31.07.2024	0,0122	0,0342161	0,0464161	0,00386801
31.08.2024	0,0123	0,0342161	0,0465161	0,00387634
30.09.2024	0,0123	0,0342161	0,0465161	0,00387634
31.10.2024	0,0122	0,0342161	0,0464161	0,00386801
30.11.2024	0,0122	0,0342161	0,0464161	0,00386801
31.12.2024	0,0122	0,0342161	0,0464161	0,00386801
31.01.2025	0,0123	0,0342161	0,0465161	0,00387634
28.02.2025	0,0125	0,0342161	0,0467161	0,00389301
31.03.2025	0,0129	0,0342161	0,0471161	0,00392634

30.04.2025	0,0134	0,0342161	0,0476161	0,00396801
31.05.2025	0,0139	0,0342161	0,0481161	0,00400967
30.06.2025	0,0143	0,0342161	0,0485161	0,00404301
31.07.2025	0,0146	0,0342161	0,0488161	0,00406801
31.08.2025	0,015	0,0342161	0,0492161	0,00410134
30.09.2025	0,0154	0,0342161	0,0496161	0,00413467
31.10.2025	0,0159	0,0342161	0,0501161	0,00417634
30.11.2025	0,0164	0,0342161	0,0506161	0,00421801
31.12.2025	0,0169	0,0342161	0,0511161	0,00425967
31.01.2026	0,0174	0,0342161	0,0516161	0,00430134
28.02.2026	0,0179	0,0342161	0,0521161	0,00434301
31.03.2026	0,0183	0,0342161	0,0525161	0,00437634
30.04.2026	0,0186	0,0342161	0,0528161	0,00440134
31.05.2026	0,0189	0,0342161	0,0531161	0,00442634
30.06.2026	0,0191	0,0342161	0,0533161	0,00444301
31.07.2026	0,0193	0,0342161	0,0535161	0,00445967
31.08.2026	0,0194	0,0342161	0,0536161	0,00446801
30.09.2026	0,0194	0,0342161	0,0536161	0,00446801
31.10.2026	0,0193	0,0342161	0,0535161	0,00445967
30.11.2026	0,0191	0,0342161	0,0533161	0,00444301
31.12.2026	0,0188	0,0342161	0,0530161	0,00441801
31.01.2027	0,0184	0,0342161	0,0526161	0,00438467
28.02.2027	0,0179	0,0342161	0,0521161	0,00434301
31.03.2027	0,0172	0,0342161	0,0514161	0,00428467
30.04.2027	0,0163	0,0342161	0,0505161	0,00420967
31.05.2027	0,0154	0,0342161	0,0496161	0,00413467
30.06.2027	0,0145	0,0342161	0,0487161	0,00405967
31.07.2027	0,0139	0,0342161	0,0481161	0,00400967
31.08.2027	0,0137	0,0342161	0,0479161	0,00399301
30.09.2027	0,0137	0,0342161	0,0479161	0,00399301
31.10.2027	0,0137	0,0342161	0,0479161	0,00399301
30.11.2027	0,0136	0,0342161	0,0478161	0,00398467
31.12.2027	0,0133	0,0342161	0,0475161	0,00395967
31.01.2028	0,0129	0,0342161	0,0471161	0,00392634
29.02.2028	0,0125	0,0342161	0,0467161	0,00389301
31.03.2028	0,0121	0,0342161	0,0463161	0,00385967
30.04.2028	0,0118	0,0342161	0,0460161	0,00383467
31.05.2028	0,0118	0,0342161	0,0460161	0,00383467
30.06.2028	0,0119	0,0342161	0,0461161	0,00384301
31.07.2028	0,012	0,0342161	0,0462161	0,00385134
31.08.2028	0,0121	0,0342161	0,0463161	0,00385967
30.09.2028	0,0122	0,0342161	0,0464161	0,00386801
31.10.2028	0,0122	0,0342161	0,0464161	0,00386801
30.11.2028	0,0122	0,0342161	0,0464161	0,00386801
31.12.2028	0,0123	0,0342161	0,0465161	0,00387634
31.01.2029	0,0125	0,0342161	0,0467161	0,00389301
28.02.2029	0,0128	0,0342161	0,0470161	0,00391801
31.03.2029	0,0133	0,0342161	0,0475161	0,00395967
30.04.2029	0,0138	0,0342161	0,0480161	0,00400134
31.05.2029	0,0142	0,0342161	0,0484161	0,00403467
30.06.2029	0,0146	0,0342161	0,0488161	0,00406801
31.07.2029	0,0151	0,0342161	0,0493161	0,00410967
31.08.2029	0,0156	0,0342161	0,0498161	0,00415134
30.09.2029	0,0161	0,0342161	0,0503161	0,00419301
31.10.2029	0,0166	0,0342161	0,0508161	0,00423467
30.11.2029	0,0171	0,0342161	0,0513161	0,00427634
31.12.2029	0,0176	0,0342161	0,0518161	0,00431801
31.01.2030	0,0181	0,0342161	0,0523161	0,00435967

28.02.2030	0,0185	0,0342161	0,0527161	0,00439301
31.03.2030	0,0189	0,0342161	0,0531161	0,00442634
30.04.2030	0,0192	0,0342161	0,0534161	0,00445134
31.05.2030	0,0194	0,0342161	0,0536161	0,00446801
30.06.2030	0,0195	0,0342161	0,0537161	0,00447634
31.07.2030	0,0196	0,0342161	0,0538161	0,00448467
31.08.2030	0,0196	0,0342161	0,0538161	0,00448467
30.09.2030	0,0195	0,0342161	0,0537161	0,00447634
31.10.2030	0,0192	0,0342161	0,0534161	0,00445134
30.11.2030	0,0188	0,0342161	0,0530161	0,00441801
31.12.2030	0,0183	0,0342161	0,0525161	0,00437634
31.01.2031	0,0177	0,0342161	0,0519161	0,00432634
28.02.2031	0,0169	0,0342161	0,0511161	0,00425967
31.03.2031	0,016	0,0342161	0,0502161	0,00418467
30.04.2031	0,0151	0,0342161	0,0493161	0,00410967
31.05.2031	0,0143	0,0342161	0,0485161	0,00404301
30.06.2031	0,0138	0,0342161	0,0480161	0,00400134
31.07.2031	0,0137	0,0342161	0,0479161	0,00399301
31.08.2031	0,0137	0,0342161	0,0479161	0,00399301
30.09.2031	0,0137	0,0342161	0,0479161	0,00399301
31.10.2031	0,0135	0,0342161	0,0477161	0,00397634
30.11.2031	0,0132	0,0342161	0,0474161	0,00395134
31.12.2031	0,0128	0,0342161	0,0470161	0,00391801
31.01.2032	0,0124	0,0342161	0,0466161	0,00388467
29.02.2032	0,012	0,0342161	0,0462161	0,00385134
31.03.2032	0,0118	0,0342161	0,0460161	0,00383467
30.04.2032	0,0118	0,0342161	0,0460161	0,00383467
31.05.2032	0,0119	0,0342161	0,0461161	0,00384301
30.06.2032	0,0121	0,0342161	0,0463161	0,00385967
31.07.2032	0,0122	0,0342161	0,0464161	0,00386801
31.08.2032	0,0122	0,0342161	0,0464161	0,00386801
30.09.2032	0,0122	0,0342161	0,0464161	0,00386801

Příloha M: Tabulka ocenění dluhopisů TPH_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
30.09.2020	1,003651341	19 000 000,00 Kč		18 930 876,91 Kč
31.10.2020	1,007391289	19 000 000,00 Kč		18 860 595,89 Kč
30.11.2020	1,011195542	19 000 000,00 Kč		18 789 639,80 Kč
31.12.2020	1,014988882	19 000 000,00 Kč		18 719 416,87 Kč
31.01.2021	1,018796452	19 000 000,00 Kč		18 649 456,40 Kč
28.02.2021	1,022575855	19 000 000,00 Kč		18 580 528,68 Kč
31.03.2021	1,026352236	19 000 000,00 Kč		18 512 163,11 Kč
30.04.2021	1,030091245	19 000 000,00 Kč		18 444 967,95 Kč
31.05.2021	1,033955469	19 000 000,00 Kč		18 376 033,18 Kč
30.06.2021	1,037946201	19 000 000,00 Kč		18 305 380,36 Kč
31.07.2021	1,04204748	19 000 000,00 Kč		18 233 334,24 Kč
31.08.2021	1,046225752	19 000 000,00 Kč		18 160 516,47 Kč
30.09.2021	1,050490525	19 000 000,00 Kč		18 086 788,55 Kč
31.10.2021	1,054825207	19 000 000,00 Kč		18 012 462,98 Kč
30.11.2021	1,059212937	19 000 000,00 Kč		17 937 847,37 Kč
31.12.2021	1,063698359	19 000 000,00 Kč		17 862 206,74 Kč
31.01.2022	1,068255961	19 000 000,00 Kč		17 785 999,52 Kč
28.02.2022	1,072904307	19 000 000,00 Kč		17 708 941,87 Kč
31.03.2022	1,077635466	19 000 000,00 Kč		17 631 194,04 Kč
30.04.2022	1,08246831	19 000 000,00 Kč		17 552 476,89 Kč
31.05.2022	1,087367931	19 000 000,00 Kč		17 473 386,38 Kč
30.06.2022	1,092316914	19 000 000,00 Kč		17 394 219,35 Kč
31.07.2022	1,097306626	19 000 000,00 Kč		17 315 123,72 Kč
31.08.2022	1,102328276	19 000 000,00 Kč		17 236 244,78 Kč
30.09.2022	1,107372907	19 000 000,00 Kč		17 157 725,18 Kč
31.10.2022	1,112431395	19 000 000,00 Kč		17 079 704,95 Kč
30.11.2022	1,11749445	19 000 000,00 Kč		17 002 321,58 Kč
31.12.2022	1,122533986	19 000 000,00 Kč		16 925 990,87 Kč
31.01.2023	1,127549477	19 000 000,00 Kč		16 850 701,80 Kč
28.02.2023	1,132521603	19 000 000,00 Kč		16 776 721,91 Kč
31.03.2023	1,137440154	19 000 000,00 Kč		16 704 175,54 Kč
30.04.2023	1,1422758	19 000 000,00 Kč		16 633 461,02 Kč
31.05.2023	1,147027296	19 000 000,00 Kč		16 564 557,85 Kč
30.06.2023	1,151702971	19 000 000,00 Kč		16 497 309,19 Kč
31.07.2023	1,15634012	19 000 000,00 Kč		16 431 151,76 Kč
31.08.2023	1,160976667	19 000 000,00 Kč		16 365 531,31 Kč
30.09.2023	1,165631806	19 000 000,00 Kč		16 300 172,92 Kč
31.10.2023	1,170305611	19 000 000,00 Kč		16 235 075,55 Kč
30.11.2023	1,174998155	19 000 000,00 Kč		16 170 238,15 Kč
31.12.2023	1,179699724	19 000 000,00 Kč		16 105 793,38 Kč
31.01.2024	1,184390613	19 000 000,00 Kč		16 042 004,89 Kč
29.02.2024	1,189060674	19 000 000,00 Kč		15 978 999,57 Kč
31.03.2024	1,193689697	19 000 000,00 Kč		15 917 034,42 Kč
30.04.2024	1,198287004	19 000 000,00 Kč		15 855 967,68 Kč
31.05.2024	1,202882044	19 000 000,00 Kč		15 795 397,47 Kč
30.06.2024	1,207514754	19 000 000,00 Kč		15 734 797,39 Kč
31.07.2024	1,21218543	19 000 000,00 Kč		15 674 169,58 Kč
31.08.2024	1,216884275	19 000 000,00 Kč		15 613 645,76 Kč
30.09.2024	1,221601334	19 000 000,00 Kč		15 553 355,65 Kč
31.10.2024	1,226326497	19 000 000,00 Kč		15 493 426,95 Kč
30.11.2024	1,231069938	19 000 000,00 Kč		15 433 729,16 Kč
31.12.2024	1,235831726	19 000 000,00 Kč		15 374 261,39 Kč
31.01.2025	1,240622232	19 000 000,00 Kč		15 314 895,63 Kč
28.02.2025	1,245451984	19 000 000,00 Kč		15 255 505,82 Kč

31.03.2025	1,250342054	19 000 000,00 Kč	15 195 841,76 Kč
30.04.2025	1,255303421	19 000 000,00 Kč	15 135 782,86 Kč
31.05.2025	1,260336779	19 000 000,00 Kč	15 075 335,66 Kč
30.06.2025	1,265432331	19 000 000,00 Kč	15 014 631,39 Kč
31.07.2025	1,27058012	19 000 000,00 Kč	14 953 799,22 Kč
31.08.2025	1,275791203	19 000 000,00 Kč	14 892 719,09 Kč
30.09.2025	1,281066184	19 000 000,00 Kč	14 831 396,09 Kč
31.10.2025	1,286416354	19 000 000,00 Kč	14 769 712,73 Kč
30.11.2025	1,291842468	19 000 000,00 Kč	14 707 675,64 Kč
31.12.2025	1,297345297	19 000 000,00 Kč	14 645 291,46 Kč
31.01.2026	1,302925622	19 000 000,00 Kč	14 582 566,86 Kč
28.02.2026	1,308584238	19 000 000,00 Kč	14 519 508,52 Kč
31.03.2026	1,31431105	19 000 000,00 Kč	14 456 243,07 Kč
30.04.2026	1,320095781	19 000 000,00 Kč	14 392 895,03 Kč
31.05.2026	1,325938976	19 000 000,00 Kč	14 329 467,91 Kč
30.06.2026	1,331830133	19 000 000,00 Kč	14 266 083,59 Kč
31.07.2026	1,337769662	19 000 000,00 Kč	14 202 743,97 Kč
31.08.2026	1,343746828	19 000 000,00 Kč	14 139 568,26 Kč
30.09.2026	1,349750699	19 000 000,00 Kč	14 076 673,57 Kč
31.10.2026	1,355770148	19 000 000,00 Kč	14 014 174,91 Kč
30.11.2026	1,361793846	19 000 000,00 Kč	13 952 185,24 Kč
31.12.2026	1,367810262	19 000 000,00 Kč	13 890 815,51 Kč
31.01.2027	1,373807665	19 000 000,00 Kč	13 830 174,69 Kč
28.02.2027	1,379774123	19 000 000,00 Kč	13 770 369,87 Kč
31.03.2027	1,385686006	19 000 000,00 Kč	13 711 620,04 Kč
30.04.2027	1,391519293	19 000 000,00 Kč	13 654 140,55 Kč
31.05.2027	1,397272773	19 000 000,00 Kč	13 597 917,58 Kč
30.06.2027	1,402945245	19 000 000,00 Kč	13 542 937,66 Kč
31.07.2027	1,408570599	19 000 000,00 Kč	13 488 851,75 Kč
31.08.2027	1,414195033	19 000 000,00 Kč	13 435 204,87 Kč
30.09.2027	1,419841925	19 000 000,00 Kč	13 381 771,35 Kč
31.10.2027	1,425511365	19 000 000,00 Kč	13 328 550,34 Kč
30.11.2027	1,431191564	19 000 000,00 Kč	13 275 651,19 Kč
31.12.2027	1,436858617	19 000 000,00 Kč	13 223 291,26 Kč
31.01.2028	1,442500215	19 000 000,00 Kč	13 171 575,16 Kč
29.02.2028	1,44811588	19 000 000,00 Kč	13 120 496,96 Kč
31.03.2028	1,453705136	19 000 000,00 Kč	13 070 050,82 Kč
30.04.2028	1,459279622	19 000 000,00 Kč	13 020 122,88 Kč
31.05.2028	1,464875485	19 000 000,00 Kč	12 970 385,67 Kč
30.06.2028	1,470505013	19 000 000,00 Kč	12 920 731,20 Kč
31.07.2028	1,476168429	19 000 000,00 Kč	12 871 159,97 Kč
31.08.2028	1,481865959	19 000 000,00 Kč	12 821 672,49 Kč
30.09.2028	1,487597829	19 000 000,00 Kč	12 772 269,25 Kč
31.10.2028	1,493351869	19 000 000,00 Kč	12 723 056,36 Kč
30.11.2028	1,499128166	19 000 000,00 Kč	12 674 033,10 Kč
31.12.2028	1,504939298	19 000 000,00 Kč	12 625 093,93 Kč
31.01.2029	1,510798039	19 000 000,00 Kč	12 576 134,94 Kč
28.02.2029	1,516717358	19 000 000,00 Kč	12 527 053,84 Kč
31.03.2029	1,522723065	19 000 000,00 Kč	12 477 646,42 Kč
30.04.2029	1,528816	19 000 000,00 Kč	12 427 918,08 Kč
31.05.2029	1,534984275	19 000 000,00 Kč	12 377 976,97 Kč
30.06.2029	1,541228603	19 000 000,00 Kč	12 327 827,27 Kč
31.07.2029	1,547562551	19 000 000,00 Kč	12 277 371,26 Kč
31.08.2029	1,553987012	19 000 000,00 Kč	12 226 614,42 Kč
30.09.2029	1,560502892	19 000 000,00 Kč	12 175 562,19 Kč
31.10.2029	1,567111114	19 000 000,00 Kč	12 124 220,06 Kč
30.11.2029	1,573812616	19 000 000,00 Kč	12 072 593,53 Kč
31.12.2029	1,580608351	19 000 000,00 Kč	12 020 688,10 Kč

31.01.2030	1,587499289	19 000 000,00 Kč		11 968 509,29 Kč
28.02.2030	1,594473187	19 000 000,00 Kč		11 916 161,50 Kč
31.03.2030	1,601530869	19 000 000,00 Kč		11 863 648,94 Kč
30.04.2030	1,60865983	19 000 000,00 Kč		11 811 073,82 Kč
31.05.2030	1,615847335	19 000 000,00 Kč		11 758 536,59 Kč
30.06.2030	1,623080419	19 000 000,00 Kč		11 706 135,93 Kč
31.07.2030	1,630359406	19 000 000,00 Kč		11 653 872,10 Kč
31.08.2030	1,637671038	19 000 000,00 Kč		11 601 841,62 Kč
30.09.2030	1,645001812	19 000 000,00 Kč		11 550 139,25 Kč
31.10.2030	1,652324277	19 000 000,00 Kč		11 498 953,48 Kč
30.11.2030	1,659624259	19 000 000,00 Kč		11 448 374,47 Kč
31.12.2030	1,666887341	19 000 000,00 Kč		11 398 490,79 Kč
31.01.2031	1,674098865	19 000 000,00 Kč		11 349 389,45 Kč
28.02.2031	1,681229981	19 000 000,00 Kč		11 301 249,81 Kč
31.03.2031	1,688265382	19 000 000,00 Kč		11 254 154,83 Kč
30.04.2031	1,695203603	19 000 000,00 Kč		11 208 093,21 Kč
31.05.2031	1,702057325	19 000 000,00 Kč		11 162 961,27 Kč
30.06.2031	1,708867837	19 000 000,00 Kč		11 118 472,47 Kč
31.07.2031	1,71569136	19 000 000,00 Kč		11 074 252,89 Kč
31.08.2031	1,722542129	19 000 000,00 Kč		11 030 209,17 Kč
30.09.2031	1,729420254	19 000 000,00 Kč		10 986 340,63 Kč
31.10.2031	1,736297019	19 000 000,00 Kč		10 942 828,21 Kč
30.11.2031	1,743157721	19 000 000,00 Kč		10 899 759,54 Kč
31.12.2031	1,749987427	19 000 000,00 Kč		10 857 220,86 Kč
31.01.2032	1,756785559	19 000 000,00 Kč		10 815 207,30 Kč
29.02.2032	1,76355154	19 000 000,00 Kč		10 773 714,05 Kč
31.03.2032	1,770314186	19 000 000,00 Kč		10 732 558,18 Kč
30.04.2032	1,777102765	19 000 000,00 Kč		10 691 559,53 Kč
31.05.2032	1,783932185	19 000 000,00 Kč		10 650 629,08 Kč
30.06.2032	1,790817583	19 000 000,00 Kč		10 609 679,17 Kč
31.07.2032	1,79774448	19 000 000,00 Kč		10 568 798,97 Kč
31.08.2032	1,80469817	12 666 667,00 Kč	1 900 000 000,00 Kč	1 059 826 346,03 Kč
Total		2 729 666 667,00 Kč	1 900 000 000,00 Kč	3 112 084 637,16 Kč

Příloha N: Tabulka diskontní sazby TPHnet_1

Datum	Risk Free rate	Spread	Discount rate p.a.	Discount rate p.m.
30.09.2020	0,0096	0,08433	0,09393	0,0078275
31.10.2020	0,0105	0,08433	0,09483	0,0079025
30.11.2020	0,0111	0,08433	0,09543	0,0079525
31.12.2020	0,0108	0,08433	0,09513	0,0079275
31.01.2021	0,0108	0,08433	0,09513	0,0079275
28.02.2021	0,0103	0,08433	0,09463	0,00788583
31.03.2021	0,0101	0,08433	0,09443	0,00786917
30.04.2021	0,0095	0,08433	0,09383	0,00781917
31.05.2021	0,0108	0,08433	0,09513	0,0079275
30.06.2021	0,0121	0,08433	0,09643	0,00803583
31.07.2021	0,0132	0,08433	0,09753	0,0081275
31.08.2021	0,0139	0,08433	0,09823	0,00818583
30.09.2021	0,0147	0,08433	0,09903	0,0082525
31.10.2021	0,0153	0,08433	0,09963	0,0083025
30.11.2021	0,0157	0,08433	0,10003	0,00833583
31.12.2021	0,0166	0,08433	0,10093	0,00841083
31.01.2022	0,0172	0,08433	0,10153	0,00846083
28.02.2022	0,018	0,08433	0,10233	0,0085275
31.03.2022	0,0187	0,08433	0,10303	0,00858583
30.04.2022	0,0196	0,08433	0,10393	0,00866083
31.05.2022	0,0201	0,08433	0,10443	0,0087025
30.06.2022	0,0204	0,08433	0,10473	0,0087275
31.07.2022	0,0206	0,08433	0,10493	0,00874417
31.08.2022	0,0207	0,08433	0,10503	0,0087525
30.09.2022	0,0207	0,08433	0,10503	0,0087525
31.10.2022	0,0206	0,08433	0,10493	0,00874417
30.11.2022	0,0204	0,08433	0,10473	0,0087275
31.12.2022	0,0199	0,08433	0,10423	0,00868583
31.01.2023	0,0194	0,08433	0,10373	0,00864417
28.02.2023	0,0187	0,08433	0,10303	0,00858583
31.03.2023	0,0179	0,08433	0,10223	0,00851917
30.04.2023	0,0168	0,08433	0,10113	0,0084275
31.05.2023	0,0157	0,08433	0,10003	0,00833583
30.06.2023	0,0147	0,08433	0,09903	0,0082525
31.07.2023	0,0141	0,08433	0,09843	0,0082025
31.08.2023	0,0139	0,08433	0,09823	0,00818583
30.09.2023	0,0139	0,08433	0,09823	0,00818583
31.10.2023	0,0139	0,08433	0,09823	0,00818583
30.11.2023	0,0139	0,08433	0,09823	0,00818583
31.12.2023	0,0138	0,08433	0,09813	0,0081775
31.01.2024	0,0135	0,08433	0,09783	0,0081525
29.02.2024	0,0131	0,08433	0,09743	0,00811917
31.03.2024	0,0125	0,08433	0,09683	0,00806917
30.04.2024	0,012	0,08433	0,09633	0,0080275
31.05.2024	0,0118	0,08433	0,09613	0,00801083
30.06.2024	0,012	0,08433	0,09633	0,0080275
31.07.2024	0,0122	0,08433	0,09653	0,00804417
31.08.2024	0,0123	0,08433	0,09663	0,0080525
30.09.2024	0,0123	0,08433	0,09663	0,0080525
31.10.2024	0,0122	0,08433	0,09653	0,00804417
30.11.2024	0,0122	0,08433	0,09653	0,00804417
31.12.2024	0,0122	0,08433	0,09653	0,00804417
31.01.2025	0,0123	0,08433	0,09663	0,0080525
28.02.2025	0,0125	0,08433	0,09683	0,00806917
31.03.2025	0,0129	0,08433	0,09723	0,0081025

30.04.2025	0,0134	0,08433	0,09773	0,00814417
31.05.2025	0,0139	0,08433	0,09823	0,00818583
30.06.2025	0,0143	0,08433	0,09863	0,00821917
31.07.2025	0,0146	0,08433	0,09893	0,00824417
31.08.2025	0,015	0,08433	0,09933	0,0082775
30.09.2025	0,0154	0,08433	0,09973	0,00831083
31.10.2025	0,0159	0,08433	0,10023	0,0083525
30.11.2025	0,0164	0,08433	0,10073	0,00839417
31.12.2025	0,0169	0,08433	0,10123	0,00843583
31.01.2026	0,0174	0,08433	0,10173	0,0084775
28.02.2026	0,0179	0,08433	0,10223	0,00851917
31.03.2026	0,0183	0,08433	0,10263	0,0085525
30.04.2026	0,0186	0,08433	0,10293	0,0085775
31.05.2026	0,0189	0,08433	0,10323	0,0086025
30.06.2026	0,0191	0,08433	0,10343	0,00861917
31.07.2026	0,0193	0,08433	0,10363	0,00863583
31.08.2026	0,0194	0,08433	0,10373	0,00864417
30.09.2026	0,0194	0,08433	0,10373	0,00864417
31.10.2026	0,0193	0,08433	0,10363	0,00863583
30.11.2026	0,0191	0,08433	0,10343	0,00861917
31.12.2026	0,0188	0,08433	0,10313	0,00859417
31.01.2027	0,0184	0,08433	0,10273	0,00856083
28.02.2027	0,0179	0,08433	0,10223	0,00851917
31.03.2027	0,0172	0,08433	0,10153	0,00846083
30.04.2027	0,0163	0,08433	0,10063	0,00838583
31.05.2027	0,0154	0,08433	0,09973	0,00831083
30.06.2027	0,0145	0,08433	0,09883	0,00823583
31.07.2027	0,0139	0,08433	0,09823	0,00818583
31.08.2027	0,0137	0,08433	0,09803	0,00816917
30.09.2027	0,0137	0,08433	0,09803	0,00816917
31.10.2027	0,0137	0,08433	0,09803	0,00816917
30.11.2027	0,0136	0,08433	0,09793	0,00816083
31.12.2027	0,0133	0,08433	0,09763	0,00813583
31.01.2028	0,0129	0,08433	0,09723	0,0081025
29.02.2028	0,0125	0,08433	0,09683	0,00806917
31.03.2028	0,0121	0,08433	0,09643	0,00803583
30.04.2028	0,0118	0,08433	0,09613	0,00801083
31.05.2028	0,0118	0,08433	0,09613	0,00801083
30.06.2028	0,0119	0,08433	0,09623	0,00801917
31.07.2028	0,012	0,08433	0,09633	0,0080275
31.08.2028	0,0121	0,08433	0,09643	0,00803583
30.09.2028	0,0122	0,08433	0,09653	0,00804417
31.10.2028	0,0122	0,08433	0,09653	0,00804417
30.11.2028	0,0122	0,08433	0,09653	0,00804417
31.12.2028	0,0123	0,08433	0,09663	0,0080525
31.01.2029	0,0125	0,08433	0,09683	0,00806917
28.02.2029	0,0128	0,08433	0,09713	0,00809417
31.03.2029	0,0133	0,08433	0,09763	0,00813583
30.04.2029	0,0138	0,08433	0,09813	0,0081775
31.05.2029	0,0142	0,08433	0,09853	0,00821083
30.06.2029	0,0146	0,08433	0,09893	0,00824417
31.07.2029	0,0151	0,08433	0,09943	0,00828583
31.08.2029	0,0156	0,08433	0,09993	0,0083275
30.09.2029	0,0161	0,08433	0,10043	0,00836917
31.10.2029	0,0166	0,08433	0,10093	0,00841083
30.11.2029	0,0171	0,08433	0,10143	0,0084525
31.12.2029	0,0176	0,08433	0,10193	0,00849417
31.01.2030	0,0181	0,08433	0,10243	0,00853583

28.02.2030	0,0185	0,08433	0,10283	0,00856917
31.03.2030	0,0189	0,08433	0,10323	0,0086025
30.04.2030	0,0192	0,08433	0,10353	0,0086275
31.05.2030	0,0194	0,08433	0,10373	0,00864417
30.06.2030	0,0195	0,08433	0,10383	0,0086525
31.07.2030	0,0196	0,08433	0,10393	0,00866083
31.08.2030	0,0196	0,08433	0,10393	0,00866083
30.09.2030	0,0195	0,08433	0,10383	0,0086525
31.10.2030	0,0192	0,08433	0,10353	0,0086275
30.11.2030	0,0188	0,08433	0,10313	0,00859417
31.12.2030	0,0183	0,08433	0,10263	0,0085525
31.01.2031	0,0177	0,08433	0,10203	0,0085025
28.02.2031	0,0169	0,08433	0,10123	0,00843583
31.03.2031	0,016	0,08433	0,10033	0,00836083
30.04.2031	0,0151	0,08433	0,09943	0,00828583
31.05.2031	0,0143	0,08433	0,09863	0,00821917
30.06.2031	0,0138	0,08433	0,09813	0,0081775
31.07.2031	0,0137	0,08433	0,09803	0,00816917
31.08.2031	0,0137	0,08433	0,09803	0,00816917
30.09.2031	0,0137	0,08433	0,09803	0,00816917
31.10.2031	0,0135	0,08433	0,09783	0,0081525
30.11.2031	0,0132	0,08433	0,09753	0,0081275
31.12.2031	0,0128	0,08433	0,09713	0,00809417
31.01.2032	0,0124	0,08433	0,09673	0,00806083
29.02.2032	0,012	0,08433	0,09633	0,0080275
31.03.2032	0,0118	0,08433	0,09613	0,00801083
30.04.2032	0,0118	0,08433	0,09613	0,00801083
31.05.2032	0,0119	0,08433	0,09623	0,00801917
30.06.2032	0,0121	0,08433	0,09643	0,00803583
31.07.2032	0,0122	0,08433	0,09653	0,00804417
31.08.2032	0,0122	0,08433	0,09653	0,00804417
30.09.2032	0,0122	0,08433	0,09653	0,00804417

Příloha O: Tabulka ocenění dluhopisů TPHnet_1

Datum	Discount rate p.a.	Nominal coupon payment	Nominal debt return	NPV
30.09.2020	1,0078275	45 000 000,00 Kč		44 650 498,23 Kč
31.10.2020	1,015791857	45 000 000,00 Kč		44 300 414,20 Kč
30.11.2020	1,023869942	45 000 000,00 Kč		43 950 894,71 Kč
31.12.2020	1,031986671	45 000 000,00 Kč		43 605 214,37 Kč
31.01.2021	1,040167745	45 000 000,00 Kč		43 262 252,87 Kč
28.02.2021	1,048370334	45 000 000,00 Kč		42 923 763,22 Kč
31.03.2021	1,056620135	45 000 000,00 Kč		42 588 626,22 Kč
30.04.2021	1,064882024	45 000 000,00 Kč		42 258 202,30 Kč
31.05.2021	1,073323876	45 000 000,00 Kč		41 925 835,24 Kč
30.06.2021	1,081948928	45 000 000,00 Kč		41 591 611,98 Kč
31.07.2021	1,090742468	45 000 000,00 Kč		41 256 301,39 Kč
31.08.2021	1,099671104	45 000 000,00 Kč		40 921 326,23 Kč
30.09.2021	1,10874614	45 000 000,00 Kč		40 586 387,07 Kč
31.10.2021	1,117951505	45 000 000,00 Kč		40 252 193,24 Kč
30.11.2021	1,127270562	45 000 000,00 Kč		39 919 431,51 Kč
31.12.2021	1,136751847	45 000 000,00 Kč		39 586 476,26 Kč
31.01.2022	1,146369715	45 000 000,00 Kč		39 254 351,73 Kč
28.02.2022	1,156145383	45 000 000,00 Kč		38 922 440,62 Kč
31.03.2022	1,166071854	45 000 000,00 Kč		38 591 103,83 Kč
30.04.2022	1,176171008	45 000 000,00 Kč		38 259 742,58 Kč
31.05.2022	1,186406636	45 000 000,00 Kč		37 929 659,71 Kč
30.06.2022	1,196761	45 000 000,00 Kč		37 601 492,69 Kč
31.07.2022	1,207225678	45 000 000,00 Kč		37 275 549,07 Kč
31.08.2022	1,217791921	45 000 000,00 Kč		36 952 125,59 Kč
30.09.2022	1,228450645	45 000 000,00 Kč		36 631 508,32 Kč
31.10.2022	1,239192422	45 000 000,00 Kč		36 313 972,88 Kč
30.11.2022	1,250007474	45 000 000,00 Kč		35 999 784,76 Kč
31.12.2022	1,26086483	45 000 000,00 Kč		35 689 789,20 Kč
31.01.2023	1,271763956	45 000 000,00 Kč		35 383 924,66 Kč
28.02.2023	1,282683109	45 000 000,00 Kč		35 082 710,36 Kč
31.03.2023	1,2936105	45 000 000,00 Kč		34 786 359,56 Kč
30.04.2023	1,304512403	45 000 000,00 Kč		34 495 647,49 Kč
31.05.2023	1,315386601	45 000 000,00 Kč		34 210 474,68 Kč
30.06.2023	1,326241829	45 000 000,00 Kč		33 930 463,53 Kč
31.07.2023	1,337120327	45 000 000,00 Kč		33 654 413,20 Kč
31.08.2023	1,348065772	45 000 000,00 Kč		33 381 160,59 Kč
30.09.2023	1,359100813	45 000 000,00 Kč		33 110 126,61 Kč
31.10.2023	1,370226186	45 000 000,00 Kč		32 841 293,25 Kč
30.11.2023	1,381442629	45 000 000,00 Kč		32 574 642,66 Kč
31.12.2023	1,392739376	45 000 000,00 Kč		32 310 424,16 Kč
31.01.2024	1,404093684	45 000 000,00 Kč		32 049 143,52 Kč
29.02.2024	1,415493755	45 000 000,00 Kč		31 791 026,88 Kč
31.03.2024	1,42691561	45 000 000,00 Kč		31 536 553,17 Kč
30.04.2024	1,438370175	45 000 000,00 Kč		31 285 409,55 Kč
31.05.2024	1,449892719	45 000 000,00 Kč		31 036 779,08 Kč
30.06.2024	1,461531732	45 000 000,00 Kč		30 789 615,45 Kč
31.07.2024	1,473288537	45 000 000,00 Kč		30 543 915,10 Kč
31.08.2024	1,485152193	45 000 000,00 Kč		30 299 924,96 Kč
30.09.2024	1,497111381	45 000 000,00 Kč		30 057 883,85 Kč
31.10.2024	1,509154395	45 000 000,00 Kč		29 818 022,70 Kč

30.11.2024	1,521294284	45 000 000,00 Kč	29 580 075,64 Kč
31.12.2024	1,533531829	45 000 000,00 Kč	29 344 027,40 Kč
31.01.2025	1,545880594	45 000 000,00 Kč	29 109 622,16 Kč
28.02.2025	1,558354562	45 000 000,00 Kč	28 876 611,97 Kč
31.03.2025	1,570981113	45 000 000,00 Kč	28 644 519,75 Kč
30.04.2025	1,583775462	45 000 000,00 Kč	28 413 118,57 Kč
31.05.2025	1,596739984	45 000 000,00 Kč	28 182 421,97 Kč
30.06.2025	1,609863856	45 000 000,00 Kč	27 952 674,28 Kč
31.07.2025	1,623135842	45 000 000,00 Kč	27 724 112,08 Kč
31.08.2025	1,636571349	45 000 000,00 Kč	27 496 509,72 Kč
30.09.2025	1,650172621	45 000 000,00 Kč	27 269 874,34 Kč
31.10.2025	1,663955688	45 000 000,00 Kč	27 043 989,41 Kč
30.11.2025	1,677923209	45 000 000,00 Kč	26 818 867,37 Kč
31.12.2025	1,692077889	45 000 000,00 Kč	26 594 520,43 Kč
31.01.2026	1,70642248	45 000 000,00 Kč	26 370 960,61 Kč
28.02.2026	1,720959777	45 000 000,00 Kč	26 148 199,74 Kč
31.03.2026	1,735678286	45 000 000,00 Kč	25 926 463,66 Kč
30.04.2026	1,750566066	45 000 000,00 Kč	25 705 970,70 Kč
31.05.2026	1,765625311	45 000 000,00 Kč	25 486 721,18 Kč
30.06.2026	1,78084353	45 000 000,00 Kč	25 268 924,11 Kč
31.07.2026	1,796222598	45 000 000,00 Kč	25 052 574,25 Kč
31.08.2026	1,811749445	45 000 000,00 Kč	24 837 871,55 Kč
30.09.2026	1,827410509	45 000 000,00 Kč	24 625 008,87 Kč
31.10.2026	1,843191722	45 000 000,00 Kč	24 414 172,15 Kč
30.11.2026	1,859078498	45 000 000,00 Kč	24 205 540,56 Kč
31.12.2026	1,875055729	45 000 000,00 Kč	23 999 286,69 Kč
31.01.2027	1,891107768	45 000 000,00 Kč	23 795 576,72 Kč
28.02.2027	1,907218431	45 000 000,00 Kč	23 594 570,65 Kč
31.03.2027	1,923355088	45 000 000,00 Kč	23 396 615,78 Kč
30.04.2027	1,939484023	45 000 000,00 Kč	23 202 047,28 Kč
31.05.2027	1,955602752	45 000 000,00 Kč	23 010 808,28 Kč
30.06.2027	1,97170877	45 000 000,00 Kč	22 822 843,15 Kč
31.07.2027	1,987848849	45 000 000,00 Kč	22 637 536,05 Kč
31.08.2027	2,004087918	45 000 000,00 Kč	22 454 104,73 Kč
30.09.2027	2,020459646	45 000 000,00 Kč	22 272 159,75 Kč
31.10.2027	2,036965118	45 000 000,00 Kč	22 091 689,06 Kč
30.11.2027	2,053588451	45 000 000,00 Kč	21 912 861,84 Kč
31.12.2027	2,070296104	45 000 000,00 Kč	21 736 021,20 Kč
31.01.2028	2,087070678	45 000 000,00 Kč	21 561 320,60 Kč
29.02.2028	2,103911599	45 000 000,00 Kč	21 388 731,36 Kč
31.03.2028	2,120818282	45 000 000,00 Kč	21 218 225,24 Kč
30.04.2028	2,137807804	45 000 000,00 Kč	21 049 600,40 Kč
31.05.2028	2,154933426	45 000 000,00 Kč	20 882 315,65 Kč
30.06.2028	2,172214196	45 000 000,00 Kč	20 716 189,07 Kč
31.07.2028	2,189651646	45 000 000,00 Kč	20 551 214,20 Kč
31.08.2028	2,207247322	45 000 000,00 Kč	20 387 384,58 Kč
30.09.2028	2,225002787	45 000 000,00 Kč	20 224 693,77 Kč
31.10.2028	2,24290108	45 000 000,00 Kč	20 063 301,23 Kč
30.11.2028	2,26094335	45 000 000,00 Kč	19 903 196,60 Kč
31.12.2028	2,279149597	45 000 000,00 Kč	19 744 206,38 Kč
31.01.2029	2,297540434	45 000 000,00 Kč	19 586 162,37 Kč
28.02.2029	2,31613711	45 000 000,00 Kč	19 428 901,60 Kč
31.03.2029	2,334980815	45 000 000,00 Kč	19 272 106,95 Kč
30.04.2029	2,354075121	45 000 000,00 Kč	19 115 787,60 Kč

31.05.2029	2,373404039	45 000 000,00 Kč		18 960 109,30 Kč
30.06.2029	2,392970778	45 000 000,00 Kč		18 805 077,11 Kč
31.07.2029	2,412798535	45 000 000,00 Kč		18 650 541,83 Kč
31.08.2029	2,432891115	45 000 000,00 Kč		18 496 512,13 Kč
30.09.2029	2,453252386	45 000 000,00 Kč		18 342 996,53 Kč
31.10.2029	2,473886283	45 000 000,00 Kč		18 190 003,44 Kč
30.11.2029	2,494796807	45 000 000,00 Kč		18 037 541,13 Kč
31.12.2029	2,515988026	45 000 000,00 Kč		17 885 617,71 Kč
31.01.2030	2,537464081	45 000 000,00 Kč		17 734 241,18 Kč
28.02.2030	2,559208034	45 000 000,00 Kč		17 583 564,69 Kč
31.03.2030	2,581223621	45 000 000,00 Kč		17 433 592,21 Kč
30.04.2030	2,603493127	45 000 000,00 Kč		17 284 470,44 Kč
31.05.2030	2,625998156	45 000 000,00 Kč		17 136 341,05 Kč
30.06.2030	2,648719605	45 000 000,00 Kč		16 989 340,78 Kč
31.07.2030	2,671659724	45 000 000,00 Kč		16 843 462,36 Kč
31.08.2030	2,694798524	45 000 000,00 Kč		16 698 836,52 Kč
30.09.2030	2,718115268	45 000 000,00 Kč		16 555 589,28 Kč
31.10.2030	2,741565807	45 000 000,00 Kč		16 413 977,69 Kč
30.11.2030	2,765127281	45 000 000,00 Kč		16 274 115,23 Kč
31.12.2030	2,788776032	45 000 000,00 Kč		16 136 111,14 Kč
31.01.2031	2,8124876	45 000 000,00 Kč		16 000 070,54 Kč
28.02.2031	2,836213277	45 000 000,00 Kč		15 866 225,71 Kč
31.03.2031	2,859926383	45 000 000,00 Kč		15 734 670,75 Kč
30.04.2031	2,883623257	45 000 000,00 Kč		15 605 367,27 Kč
31.05.2031	2,907324237	45 000 000,00 Kč		15 478 149,78 Kč
30.06.2031	2,931098881	45 000 000,00 Kč		15 352 603,86 Kč
31.07.2031	2,955043516	45 000 000,00 Kč		15 228 202,14 Kč
31.08.2031	2,979183759	45 000 000,00 Kč		15 104 808,44 Kč
30.09.2031	3,003521208	45 000 000,00 Kč		14 982 414,60 Kč
31.10.2031	3,028007414	45 000 000,00 Kč		14 861 258,20 Kč
30.11.2031	3,052617544	45 000 000,00 Kč		14 741 447,08 Kč
31.12.2031	3,07732594	45 000 000,00 Kč		14 623 085,39 Kč
31.01.2032	3,102131751	45 000 000,00 Kč		14 506 153,71 Kč
29.02.2032	3,127034114	45 000 000,00 Kč		14 390 632,90 Kč
31.03.2032	3,152084263	45 000 000,00 Kč		14 276 268,10 Kč
30.04.2032	3,177335085	45 000 000,00 Kč		14 162 812,17 Kč
31.05.2032	3,202814664	45 000 000,00 Kč		14 050 141,74 Kč
30.06.2032	3,228551949	45 000 000,00 Kč		13 938 137,19 Kč
31.07.2032	3,254522959	45 000 000,00 Kč		13 826 911,21 Kč
31.08.2032	3,280702884	45 000 000,00 Kč	4 500 000 000,00 Kč	1 385 373 854,50 Kč
Total		6 480 000 000,00 Kč	4 500 000 000,00 Kč	5 149 638 933,29 Kč