

VĚDECKÉ SPISY VYSOKÉHO UČENÍ TECHNICKÉHO V BRNĚ

Edice Habilitační a inaugurační spisy, sv. 727

ISSN 1213-418X

Vojtěch Stehel

**HODNOTA PRO VLASTNÍKY
A JEJÍ GENERÁTORY V PROSTŘEDÍ
MALÝCH A STŘEDNÍCH PODNIKŮ**

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta podnikatelská

Ústav managementu

Ing. Vojtěch Stehel, MBA, PhD.

**HODNOTA PRO VLASTNÍKY
A JEJÍ GENERÁTORY V PROSTŘEDÍ
MALÝCH A STŘEDNÍCH PODNIKŮ**

**SHAREHOLDERS' VALUE
AND ITS GENERATORS IN THE ENVIRONMENT
OF SMALL AND MEDIUM-SIZED ENTERPRISES**

**ZKRÁCENÁ VERZE HABILITAČNÍ PRÁCE
OBOR: EKONOMIKA A MANAGEMENT**



BRNO 2022

KLÍČOVÁ SLOVA

Predikce, Ekonomická přidaná hodnota, Principal component analysis, k-means clustering, Gaussian mixture models, Hierarchical clustering, Kohonenovy sítě, Nejbližší soused, Stromová klasifikace, Naive Bayes klasifikace, Discriminant analýza, Multiclass support machine, dopředné neuronové sítě.

KEYWORDS

Prediction, Economic value added, Principal component analysis, k-means clustering, Gaussian mixture models, Hierarchical clustering, Kohonen networks, Nearest neighbour, Tree clustering, Naive Bayes, Discriminant analysis, Multiclass support machine, Feed-forward neural networks.

MÍSTO ULOŽENÍ

Vysoké učení technické v Brně, Fakulta podnikatelská
Oddělení pro vědu a výzkum, Kolejní 2906/4, 612 00 Brno.

© Vojtěch Stehel, 2022

ISBN 978-80-214-6070-6
ISSN 1213-418X

OBSAH

PŘEDSTAVENÍ AUTORA	4
1 ÚVOD	6
2 RELEVANCE TÉMATU	7
2.1 CÍLE PODNIKU	7
2.2 EKONOMICKÁ PŘIDANÁ HODNOTA VE VARIANTĚ ENTITY	8
2.2.1 <i>CAPM model</i>	9
2.3 RATINGOVÝ MODEL INFA	10
2.3.1 <i>Ekonomická přidaná hodnota pro vlastníky</i>	10
2.4 KOMPARACE POUŽÍVANÝCH MODELŮ	13
3 VYMEZENÍ PROBLÉMU, CÍLE A METODIKY HABILITAČNÍ PRÁCE	13
3.1 CÍL PRÁCE	13
3.2 METODIKA	14
3.2.1 <i>Data</i>	14
3.2.2 <i>Transformace a příprava dat</i>	14
3.2.3 <i>Zpracování dat</i>	15
4 DOSAŽENÉ VÝSLEDKY	15
4.1 PRINCIPAL COMPONENT ANALYTICS	16
4.2 METODY STROJOVÉHO UČENÍ BEZ UČITELE	16
4.2.1 <i>K-Means clustering</i>	16
4.2.2 <i>Gaussian Mixture Models</i>	17
4.2.3 <i>Hierarchické členění</i>	17
4.2.4 <i>Kohonenovy sítě</i>	18
4.3 SOUHRNNÉ VÝSLEDKY UČENÍ S UČITELEM	18
5 SHRNUTÍ A PŘÍNOSY HABILITAČNÍ PRÁCE	21
5.1 PŘÍNOSY V TEORETICKÉ OBLASTI	21
5.2 PŘÍNOSY V PEDAGOGICKÉ OBLASTI	21
5.3 PŘÍNOSY PRO PODNIKOVOU PRAXI	21
5.4 LIMITY PRÁCE	22
6 POUŽITÁ LITERATURA	23
7 ABSTRAKT	29
8 ABSTRACT	29

PŘEDSTAVENÍ AUTORA

Vojtěch Stehel je absolventem studijního programu Ekonomika a management, a to v bakalářském stupni na Vysoké škole technické a ekonomické v Českých Budějovicích a ve stupni magisterském na Vysoké škole finanční a správní. Svou doktorskou disertační práci na téma Využití teorie her při řízení podniku obhájil v roce 2018 na Fakultě prevádzky a ekonomiky dopravy a spojov Žilinské univerzity v Žilině. Získal tak PhD. ve studijním programu Ekonomika a management podniku. Rovněž úspěšně absolvoval kurz MBA v programu Finance podniku a Doplnující pedagogické minimum pro ekonomické obory na Vysoké škole technické a ekonomické v Českých Budějovicích.



Na Vysoké škole technické a ekonomické v Českých Budějovicích působí od roku 2009 postupně jako referent pedagogické činnosti, samostatný referent Kanceláře rektora, odborný referent útvaru prorektora pro praxi a vnější vztahy. Na základě výběrového řízení se stal v roce 2013 odborným asistentem Ústavu znaectví a oceňování VŠTE. Od roku 2015 působil jako vědecký pracovník Ekonomické laboratoře. V roce 2017 se stal prorektorem – statutárním zástupcem rektora VŠTE. Na základě výsledků voleb byl prezidentem republiky jmenován rektorem VŠTE s účinností od 1.1.2021.

Již jako student se aktivně zapojoval do života akademické obce. Pro roky 2008-2010 byl zvolen členem Studentské komory Akademického senátu VŠTE. Přibližně ve stejné době založil a vydával studentský časopis ŠNEK. Rovněž byl zakladatelem a prvním předsedou Studentské unie VŠTE. Svou alma mater reprezentoval v Radě vysokých škol. V letech 2016 a 2017 byl členem Akademického senátu VŠTE – Komory akademických pracovníků. Jako prorektor VŠTE zastával v roce 2018 také post předsedy Interní grantové agentury VŠTE. Od roku 2019 do současnosti je pak jejím členem. Roku 2018 se stal členem Akademické rady VŠTE, které od 1.1.2021 předsedá.

Výuce se věnuje v pozici odborného asistenta od roku 2013. Do současné doby garantoval na VŠTE celkem 10 předmětů, konkrétně Finanční řízení podniku I, Finanční řízení podniku II, Finance podniku 1, Finance podniku 2, Controlling, Organizaci veřejné správy, Oceňování podniku I, Projekt Oceňování a Podnikovou ekonomiku I. Od letního semestru roku akademického roku 2019/2020 byl jmenován garantem předmětu Strojové učení a neuronové. Vznik předmětu žadatel osobně inicioval.

Jak pedagogickou, tak výzkumnou činnost žadatel zaměřuje na podnikové hospodářství zahrnující primární a vybrané sekundární funkce podniku. Přitom klade důraz nejen na samotné podnikové funkce, ale i na podpůrné podnikové procesy. Je autorem a spoluautorem 30 odborných publikací indexovaných v databázi Web of Science (h-index: 9, 484 citací bez autocitací) a 31 publikací v databázi Scopus (h-index: 11, 585 citací bez autocitací). Je členem redakčních rad několika vědeckých časopisů a výborů mezinárodních vědeckých konferencí. Nedílnou součástí vědecké práce žadatele je i řešení několika výzkumných projektů. Kromě 5 externích projektů podpořených Technologickou agenturou České republiky byl řešitelem, nebo spoluřešitelem dvou projektů specifického výzkumu a několika inovačních voucherů.

Autor dlouhodobě a úzce spolupracuje s podnikovou praxí. Aktivně působí v Jihočeské hospodářské komoře, v nejrůznějších pracovních a poradních komisích Jihočeské kraje a města České Budějovice (například Regionální stálé konferenci Jihočeského kraje, Smart regionu, hodnotící komise jihočeských inovačních voucherů). Rovněž je členem dozorčí rady Jihočeského vědeckotechnického parku, dozorčí rady Jihočeské společnosti pro rozvoj lidských zdrojů, z. s. a dalších. V neposlední řadě je soudním znalcem obor Ekonomika, odvětví Ceny a odhady, specializace Oceňování hospodářské činnosti společností a byl členem komise znaleců, která působila jako poradní orgán předsedy krajského soudu pro obor Ekonomika. V této souvislosti vypracoval nebo se podílel na vypracování téměř sta znaleckých posudků.

Autor rovněž dlouhodobě spolupracuje s VUT v Brně, konkrétně s Ústavem soudního inženýrství, Odborem znalectví ve stavebnictví a oceňování nemovitostí. Účastnil se kurzu Institutu celoživotního vzdělávání VUT v Brně „Rodinné podniky ve světovém vinařství“. Odborná spolupráce uchazeče se odvíjí od jeho profesního zaměření. Na úrovni Fakulty podnikatelské participuje na projektu Technologické agentury České republiky „Digitální transformace pro inovace obchodních modelů v malých a středních podnicích v České republice“ (TL02000215). Současně byl také členem řešitelského týmu dalšího projektu Technologické agentury České republiky „Stabilizace a rozvoj MSP ve venkovském prostoru“ (TL01000349).

1 ÚVOD

Hlavním cílem podniku je podle Kislingerové (2007) růst hodnoty pro akcionáře. Ten můžeme změřit pomocí řady ukazatelů. Mezi těmito ukazateli (Total shareholder value, market value added, free cash flow to equity) zaujímá zajímavou pozici ukazatel ekonomické přidané hodnoty ve variantě ekvity. Jeho hodnota spočívá především v tom, že poměřuje přínos pro akcionáře odvíjející se od rizika, které svou investicí podstupuje. Avšak ekonomická přidaná hodnota, ať už dle Brealey, Mayerse a Allen (2013), Kislingerové (2007) či Neumaierových (2003), je vypočítávána vždy z pohledu akcionáře. Jedná se tak o výpočet zhodnocení vkladu vlastníka, který však neodráží skutečnou tvorbu hodnoty podnikem. Podle teorie výrobních faktorů (Wöhe, 1995) tvoří hodnoty především řídicí práce, výkonná práce, dlouhodobý majetek a materiál. Neexistuje tak přímé spojení mezi ukazatelem hodnoty pro akcionáře a výrobními faktory (generátory hodnoty). Avšak dle manažerských teorií vlastníci vyžadují od managementu naplnění především cílů vlastníka podniku. Hlavním úkolem je najít nástroj řízení podniku, jímž by bylo možné dekomponovat cíl růstu hodnoty do dílčích aktivit podniku.

Vzhledem k tomu, že neexistuje přímá souvislost, hledáme kauzální vztah vstupních veličin, tedy generátorů hodnoty a cíle vlastníků, potažmo podniku. Pokud takový vztah najdeme budeme schopni predikovat výsledek na základě určité kombinace vstupů případně budeme kombinovat vstupy, tak abychom dosáhli tíženého cíle.

Dle Vochozky (2019) nejlepších výsledků pro predikci podniků dosahují neuronové sítě. Neuronové sítě a oblast strojového učení jsou ve společnosti skloňovány častěji, než tomu bylo v minulosti. Již se nejedná pouze o teoretickou vědní disciplínu, ale o vědní disciplínu s mimořádně silným aplikačním potenciálem. Existuje minimum oborů, které lidstvo, v takto rozsáhlém směru, ovlivňují a budou ovlivňovat v budoucnu.

Schopnost neuronových sítí a dalších metod strojového učení se učít na základě vzorů a tyto pak dále aplikovat jim dává možnost řídit automobily, překládat texty, psát zprávy, řídit výrobu složitého procesu a mnoho dalšího. Všechny zmíněné činnosti přitom neuronové sítě začínají zvládat lépe než člověk. Díky tomu je například nehodovost aut řízených pomocí neuronových sítí v současné době řádově menší než v případě lidí. Důvodů je celá řada. Mimo jiné je to i schopnost analyzovat a učít se z množství dat, které by člověk nebyl schopen vstřebat za lidský život. V důsledku toho se neuronová síť může poučit z extrémních situací, které se vyskytují s minimálními pravděpodobnostmi.

Dopad na společnost mají neuronové sítě mimořádný, ten se však bude ještě prohlubovat. Již nyní si díky neuronovým sítím snadno přeložíme článek na internetu z cizího jazyka do naší mateřštiny. V momentě, kdy ale ve velkém začnou být využívány autonomní vozidla, dojde k nejenom zvyšování efektivity dopravních společností, ale také k značnému socio-demografickému efektu, který bude ovlivňovat společnost. Postupné vymizení povolání řidiče přitom nebude ojedinělým důsledkem, naopak se bude jednat o řadu dalších profesí ve výrobních firmách, administrativě atd.

Existuje přitom řada důvodů, které povedou k dalšímu rozvoji neuronových sítí a jejich aplikací. Kromě obchodní války mezi USA, Čínou a dalšími zeměmi je zde především samotný fakt lidské neefektivnosti, kdy člověk sice dokáže kontrolovat kvalitu výrobků, ale musí spát, jíst apod.

V důsledku toho dříve či později bude docházet k rychlejšímu bodu zvratu při realizaci investice do těchto technologií.

Samozřejmě i neuronové sítě mají svá omezení, a proto se nemusíme obávat toho, že by nás alespoň v nejbližších desetiletích umělá inteligence zcela nahradila. Na druhou stranu se bude muset lidská společnost v určitých směrech transformovat a zohlednit tak moderní vývoj. Toto se týká i obchodních společností. Jejich řízení musí být efektivnější, než tomu bylo v minulosti a musí využívat těchto moderních nástrojů. V opačném případě dojde k růstu konkurence, která dříve či později tuto technologii začne využívat.

2 RELEVANCE TÉMATU

Pro řízení je důležité stanovení hlavního cíle, od kterého se odvíjí dílčí cíle. V této kapitole bude vymezena relevantnost daného tématu a související oblasti.

2.1 CÍLE PODNIKU

Existuje mnoho pohledů na hlavní cíl podniku. Často je uváděn pohled dosažení zisku (Brealey, Myers a Allen, 2013). Tento přístup se ale s ohledem na odvod daní částečně transformoval do zvýšení hodnoty pro vlastníky (Kislingerová, 2013). Řada podniků ale může mít i jiné cíle, zejména pokud jsou vlastněny specifickou skupinou osob (například městem). Cíl v takovém případě může být poskytování služeb, krátkodobé zajištění zaměstnanosti apod. a zisk může být až druhotným faktorem. V některých případech se s tímto přístupem můžeme setkat i u rodinných podniků, které v době krize jinak přistupují k propouštění, neboť jsou zde i velké sociální vazby, které mohou mít v některých případech významnější dopad do lidského života než čistě pohled krátkodobé ekonomické ztráty. Z určitého pohledu bychom mohli konstatovat, že pokud bychom se na podnik dívali pohledem samotného podniku nikoli vlastníků, tak je jeho cílem přežít (Kliešтик, Vrbka a Rowland, 2018) i za cenu krátkodobé ekonomické ztráty.

Každý z výše uvedených přístupů má svůj smysl, logiku a limity. Z určitého pohledu se zároveň výše uvedené pohledy prolínají právě v dosahování dlouhodobého a udržitelného zisku. Podmínka dlouhodobosti nám vymezuje limity v tom, že manažeři nemohou krátkodobě rozprodat veškerý hmotný majetek, aby měli mimořádný výsledek hospodaření, protože v následujícím období bude výkonost jistě klesat, pokud podnik neskončí úplně.

Dlouhodobý pohled v sobě rovněž skrývá implicitně vyjádřenou možnost krátkodobého negativního vývoje, který může nastat v situaci, kdy by ekonomické zákonitosti mohly vést k propuštění nejbližšího příbuzného. Toto ale v konečném důsledku může mít negativní sociální vliv, který může překonat krátkodobou ztrátu.

Pokud bude podnik dlouhodobě dosahovat zisku, který bude podložen financemi (nebude se jednat jen o virtuální zisk, jako tomu bylo například u společnosti SAZKA před jejím krachem), bude tento podnik žít. Samozřejmě i tato má své další předpoklady.

Z jiného pohledu na danou problematiku poukazuje Kislingerová (2007), která předpokládá, že krátkodobé a dlouhodobé cíle se integrují v podobě hodnoty akcie, přičemž komplexnost tohoto ukazatele je vidět na následujícím obrázku. Z uvedeného obrázku je patrné, o jak komplexní ukazatel se jedná. Jeho komplexnost však v sobě zahrnuje i negativa. Například nálada na trhu ovlivňuje cenu akcie, a i když management společnosti postupuje ve všech bodech správně, tak tento postup může

být paradoxně negativně hodnocen. Druhou a z pohledu cíle práce zásadnější povahou je nutnost dostatečné likvidity a velikosti podniku. Akciová firma, která nebude dostatečně likvidní z pohledu jejího obchodování na finančním trhu, nemusí být ovlivněna níže uvedenými faktory. V neposlední řadě toto měřítko nelze použít pro malé a střední firmy, které nejsou na finančních trzích obchodovány a často ani nemají povahu akciové společnosti.

Obrázek 1: Faktory ovlivňující cenu akcií



Zdroj: Kislingerová (2007).

2.2 EKONOMICKÁ PŘIDANÁ HODNOTA VE VARIANTĚ ENTITY

V rešerši se dále zaměříme na klasický přístup, kdy budeme posuzovat výkonnost podniku, která více či méně ovlivňuje hodnotu podniku. Hodnota podniku může být stanovena řadou metod (Mařík, 2011). Jednou z velmi často používaných metod je *EVA* (ekonomická přidaná hodnota – Vochozka, 2011). Výše ukazatele *EVA* v sobě zohledňuje nejenom dosažený finanční výsledek, ale rovněž i riziko (Kislingerová, 2007) s jakým bylo tohoto výsledku dosaženo (Neumaierová, 1998 a 2003). V literatuře je výpočet tohoto ukazatele realizován několika způsoby. Podle Kislingerové (2007).

$$EVA = NOPAT - C \cdot WACC \quad (1)$$

kde *NOPAT* je Net operating profit after taxes – čistý provozní zisk,

EVA ekonomická přidaná hodnota,

C kapitál poskytnutý za úplatu, (základní kapitál + dlouhodobé bankovní úvěry),

WACC vážené průměrné náklady na kapitál.

Velmi významné je zde pojetí veličiny *NOPAT*. Nemělo by se zde jednat pouze o klasický provozní zisk, jak je to chybně používáno v řadě znaleckých posudků (osobní zkušenost autora práce), ale o provozní zisk, který je očištěn od jakýchkoli mimořádných vlivů, jako je prodej dlouhodobých aktiv či některé finanční operace, které nesouvisí s hlavní činností podniku (Kislingerová, 2007). Tento vzorec lze pak rozepsat jako:

$$EVA = EBIT \cdot (1 - t) - C \cdot WACC \quad (2)$$

kde *EBIT* zisk před úroky a zdaněním,
t sazba daně z příjmů.

WACC (vážené průměrné náklady na kapitál) představují náklady na celkově investovaný kapitál. Tyto náklady zohledňují jak náklady na ušlý zisk v podobě nákladů na vlastní kapitál, tak i náklady na cizí kapitál. Váhu zde představuje množství jednotlivých složek kapitálu. Ukazatel *WACC* se pak vypočítají jako:

$$WACC = \frac{E}{C} * r_e + \frac{D}{C} * r_d * (1 - t) \quad (3)$$

kde *E* je základní kapitál,
D dlouhodobé bankovní úvěry,
r_e alternativní náklady na základní kapitál,
r_d náklady na cizí kapitál.

2.2.1 CAPM model

Stanovení hodnoty *r_e*, jež představuje alternativní náklady na vlastní kapitál, je často velmi obtížné, neboť se jedná o ušlý zisk za předpokladu stejné rizikovosti. K výpočtu alternativních nákladů na vlastní kapitál se používá model CAPM, který se vypočítá jako:

$$r_e = r_f + \beta(r_m - r_f) \quad (4)$$


kde *r_e* je očekávaná míra výnosnosti podílu,
r_f bezrizikový výnos (stanovuje se na úrovni úrokové míry státních dluhopisů),
β systematické riziko (riziko plynoucí z vývoje ekonomiky),
(*r_m* - *r_f*) prémie za riziko.

Model vychází z principu, který je zobrazen na následujícím obrázku. Jedná se o regresní model výkonnosti jednotlivých akciových titulů, kde křivka představuje ideální portfolio (investici). Křivka má rostoucí gradient, neboť za zvyšující se riziko (osa x) by měl následovat vyšší zisk (osa y). Koeficient beta pak představuje směrnici dané přímky, tedy to, jak moc je změna rizika spojená se změnou výnosu. Riziko je zde měřeno rozptylem. Z těchto důvodů se *β* vypočte jako:

$$\beta = \frac{COV(r_i, r_m)}{\sigma_m^2} \quad (5)$$

kde *r_i* je výnosnost *i*-té akcie,
r_m výnosnost akciového indexu,
σ směrodatná odchylka.

Obrázek 2: CAPM model



Zdroj: Vlastní tvorba dle Brealey, Myers, Allen (2013).

Nedostatky modelu jsou následující:

- předpoklad informační symetrie,
- předpoklad normálního rozdělení rizika,
- předpoklad racionálního investora,
- předpoklad nekonečně mnoho aktiv a bezrizikové investice.

Kromě výše uvedeného je zřejmé, že model pracuje s akciovým trhem a s aktivy, které jsou na tomto trhu likvidní a lze u nich měřit výkonnost a rizikovost. K výše uvedeným nedostatkům, které jistě nejsou kompletním výčtem, by autor práce proto doplnil i prakticky minimální využitelnost pro malé a střední podniky.

2.3 RATINGOVÝ MODEL INFA

Alternativním modelem je ratingový model vyvinutý manžely Neumaierovými (2003). Jedná se o model, u kterého se dle ekonomické teorie analyzují alternativní náklady na kapitál. Jinými slovy – ekonomická přidaná hodnota vzniká tam, kde výnosnost přesahuje alternativní náklady na kapitál. Tato metoda je využívána i Ministerstvem průmyslu a obchodu ČR (2021) a má následující podobu.

2.3.1 Ekonomická přidaná hodnota pro vlastníky

V první fázi se vypočítají náklady na vlastní kapitál dle následujícího vzorce:

$$r_e = \frac{WACC * \frac{C}{A} - (1 - t) * \frac{r_d}{D} * \left(\frac{C}{A} * \frac{E}{A}\right)}{\frac{E}{A}} \quad (6)$$

kde A představuje celková aktiva,

E vlastní kapitál,

D dlouhodobé závazky,

r_d náklady na cizí kapitál,

WACC průměrné vážené náklady na kapitál.

Průměrné vážené náklady na kapitál se vypočítají jako:

$$WACC = r_f + r_{LA} + r_{business} + r_{FinStab} \quad (7)$$

kde $r_{business}$ je podnikatelské riziko,

$r_{FinStab}$ riziko finanční stability,

r_f bezriziková sazba,

r_{LA} riziko spojené s kapitálovou strukturou.

Ekonomická přidaná hodnota se vypočte jako:

$$EVA = (ROE - r_e) \cdot E \quad (8)$$

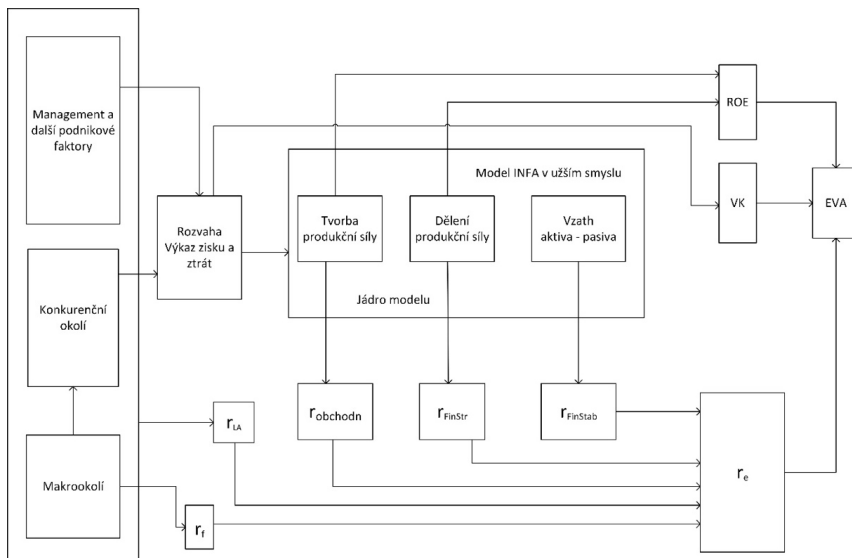
kde ROE je návratnost vlastního kapitálu,

r_e alternativní náklady na kapitál,

E vlastní kapitál.

Princip výpočtu metody *EVA* dle ratingového modelu, který je využíváný MPO je vidět na následujícím obrázku. Z obrázku je patrný vliv jednotlivých složek na výsledek v podobě ekonomické přidané hodnoty. Ze schématu je zřejmé, že vše vychází z mikro a makro prostředí, kde mikroprostředím se rozumí prostředí, které bezprostředně ovlivňuje osoby, které podnik řídí, a makrookolí je naopak podnikem neovlivitelné. Makrookolí ovlivňuje přímo bezrizikovou sazbu, která vstupuje do výpočtu nákladů na vlastní kapitál (r_e). Společně s mikrookolím jsou ovlivňovány další faktory, které definují podnik, nebo konkurenční prostředí. Každý z těchto faktorů se do určité míry podílí na tvorbě hodnoty.

Obrázek 3: Princip *EVA* dle INFA

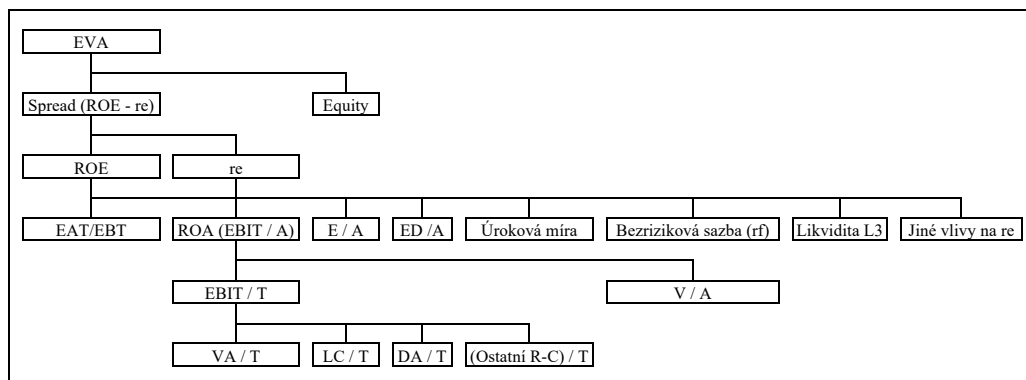


Zdroj: Neumaierová (2003).

Výše uvedené schéma je principiální, a nelze proto z něho odvodit, jak například jednotlivé složky rozhodování manažerů ovlivňují *EVA*. K posouzení tohoto vlivu v obecné rovině bude s největší pravděpodobností vždy existovat nedostatek dat (obchodní tajemství). Vliv jednotlivých

složek účetní závěrky je však možné snadno analyzovat, neboť každá společnost v ČR má povinnost zveřejňovat svoje účetní závěrky. Výsledek dekompozice parametru *EVA* je vidět na následujícím obrázku.

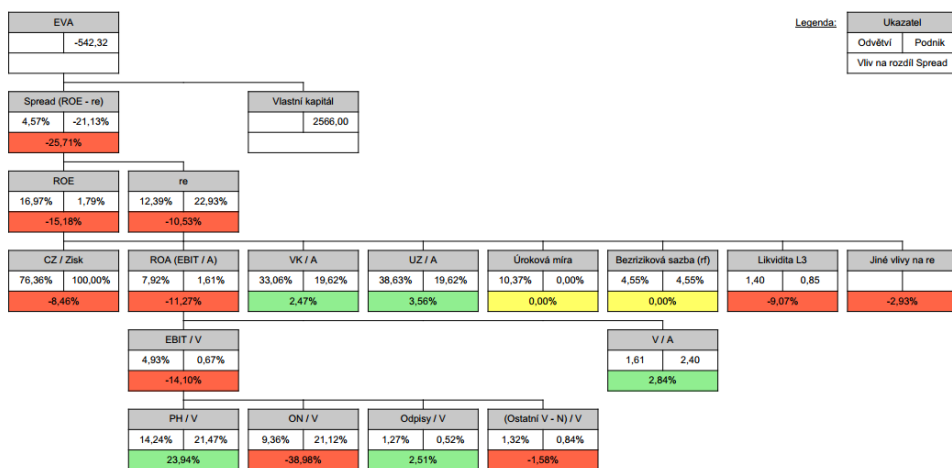
Obrázek 4: Rozklad hodnoty *EVA* na dílčí komponenty



Zdroj: Ministerstvo průmyslu a obchodu 2021.

Velkou výhodou výše uvedeného modelu je možnost analyzovat, jak dané vlivy určují hodnotu *EVA*. Díky tomu byl i vyvinut benchmarkingový systém na základě kterého mohou jednotlivé podniky analyzovat svoji výkonnost a porovnávat se tak se zbytkem trhu v dané oblasti podnikání (sekce NACE). Aplikace přehledně a snadno spočítá, jak si podnik stojí a výsledek zobrazí dle příkladu níže:

Obrázek 4: analýza *EVA* za pomoci metody INFA



Zdroj: Ministerstvo průmyslu a obchodu 2021.

Zelené složky představují pozitivní vliv na hodnotu *EVA*. Žluté složky mají neutrální vliv a červené složky mají negativní vliv na hodnotu *EVA*. Díky tomuto pohledu existuje pro podniky metodika, která jim umožňuje srovnat se s konkurencí v dané oblasti podnikání. V důsledku této

skutečnosti je možné následně řídit dílčí cíle podniku takovým způsobem, aby postupně společnost dosahovala požadovaných výsledků EVA. Toto řízení lze realizovat dle rozpadu dílčích komponent.

2.4 KOMPARACE POUŽÍVANÝCH MODELŮ

Při porovnání obou běžně používaných metod lze konstatovat že metoda CAPM je globálnější z pohledu celkového použití. Je parametrizovaná na větší společnosti a celosvětově byla podrobena mnohem větší diskusi ve vědecké komunitě (Roll, 1977). Tato metoda však v sobě skrývá řadu nedostatků, díky kterým by její aplikace na malé a střední podniky nebyla příliš smysluplná.

Oproti tomu metoda INFA (Neumaierová a Neumaier, 2006) poskytuje výsledky, které jsou mnohem lépe interpretovatelné. Díky tomu je jejich využití pro běžného manažera je daleko snadnější. Metoda byla navíc vyvinuta v lokálních podmínkách, a proto v sobě bude již implicitně zahrnovat řadu skrytých vzorců typických pro Českou republiku.

Především při ocenění podniků se využívají nevíce výše uvedené metody (Mařík, 2011). Využití *CAPM* metody pro malý podnik na obci s pár obyvateli je zcela zjevně chybný postup, který dle názoru autora nelze ani korigovat tzv. expertními odhady v posudcích, jak se často děje, neboť tyto expertní odhady nejsou nikterak ověřitelné. Metoda INFA je oproti tomu mnohem více realisticky využitelná v Českém prostředí, ale oproti předchozí metodě zde stále chybí empirický výzkum, který by ve větší míře a s ohledem na další kategorie podniku, než na kterých byla metoda vyvinuta, ověřil, jak daná metoda funguje z hlediska determinace výsledků pro vlastníky. S ohledem na výše uvedený stav poznání toto bude hlavním zaměřením práce, jejíž výzkumný cíl, respektive úkol bude zkoumán moderními metodami, které budou popsány níže.

3 VYMEZENÍ PROBLÉMU, CÍLE A METODIKY HABILITAČNÍ PRÁCE

V této kapitole bude pospán cíl práce, data, jejich transformace a metodika jejich zpracování.

3.1 CÍL PRÁCE

Cílem práce je provedení kauzální analýzy generátorů hodnoty a *EVA* ve variantě ekvity na souboru dat malých a středních podniků působících v České republice a vývoj modelu pro řízení hodnoty pro vlastníky malých a středních podniků.

Mimo hlavního cíle podniku byly stanoveny tyto výzkumné otázky:

- Ovlivňuje místo podnikání v České republice výsledek hospodaření?
- Dosahují vyšších hodnot *EVA* podniky s více zaměstnanci?
- Existuje podstatný rozdíl mezi zaměřením podniku a tvorbou hodnoty *EVA*?

3.2 METODIKA

V této kapitole bude uveden zdroj dat, jejich transformace, příprava pro další zpracování a metody dalšího zpracování.

3.2.1 Data

Datový soubor obsahoval po vygenerování setu z databáze Albertina společnosti Bisnode celkem 42592 datových řádků. Přitom každý řádek obsahoval:

1. identifikaci firmy: název firmy, IČO, obec kraj, velikost obce,
2. údaje o firmě: NACE, počet zaměstnanců, kód NACE5A, M_NACE, OKEČ5A, rok účetní závěrky,
3. výkazy účetní závěrky za daný rok působení firmy: rozvahu, výkaz zisků a ztrát, výkaz o peněžních tocích,
4. vybrané ukazatele rentability, aktivity, likvidity, zadluženosti, produktivity a další.

3.2.2 Transformace a příprava dat

Vyexportovaná data byla dále upravena v MS Excel. Konkrétně došlo k:

1. výpočtu EBIT (přičtením daně a úroků k EAT),
2. výpočtu ROA (EBIT/Aktiva).
3. výpočtu ROE (EAT/Vlastní kapitál).
4. výpočtu EVA Equity (Ministerstvo průmyslu a obchodu (2021)).

V souboru byly ponechány podniky splňující podmínky pro relevantnost analýzy. Z důvodu rozsahu je výčet uveden jen v samotné habilitační práci. Touto úpravou se zmenšil datový soubor ze 42592 řádků na 29611 řádků:

Rok	Původní datový soubor	Upravený datový soubor
2013	7 976	5 705
2014	8 059	5 492
2015	8 046	5 449
2016	8 803	5 982
2017	9 708	6 983
Celkem	42 592	29 611

Výsledný soubor zároveň obsahuje kompletní účetní závěrku s některými dopočtenými daty, které jsou uvedeny výše. Tyto údaje jsou tak prediktory, kterých je více jak 100. Z těchto důvodů byl výsledný soubor podniků zredukován na hlavní komponenty a dále bude podle metodiky Ministerstvo průmyslu a obchodu (2021) stanovena kategorie podniku dle schématu:

- podniky tvořící hodnotu (kladná hodnota EVA) – $ROE > r_e$,
- podniky s kladným ziskem a zároveň se zápornou hodnotou EVA, které však překonávají bezrizikovou sazbu $r_f - r_e > ROE > r_f$,
- podniky s kladným ziskem, kde ROE nedosahuje ani bezrizikové sazby – $r_e > r_f > ROE > 0$,
- Podniky se záporným ziskem.

Tyto údaje pak vstupovaly do dalších analýz. Hlavními komponentami jsou:

- kraj,
- velikost obce,

- počet zaměstnanců,
- sekce CZ-NACE,
- rok účetní závěrky,
- aktiva celkem - tis. Kč,
- dlouhodobý majetek - tis. Kč,
- oběžná aktiva - tis. Kč,
- vlastní kapitál - tis. Kč,
- cizí zdroje - tis. Kč,
- krátkodobé závazky,
- osobní náklady - tis. Kč,
- odpisy dlouhodobého nehmotného a hmotného majetku - tis. Kč,
- provozní výsledek hospodaření - tis. Kč,
- nákladové úroky - tis. Kč,
- finanční výsledek hospodaření - tis. Kč,
- výsledek hospodaření za účetní období (+/-) - tis. Kč,
- daň z příjmů za běžnou a mimořádnou činnost,
- obrat,
- kategorie podniku.

3.2.3 Zpracování dat

Pro zpracování byl použit SW Matlab a následující metody:

- Popisná analýza,
- Principal Component Analysis (PCA),
- Strojové učení bez učitele:
 - K-Means Clustering,
 - Gaussian Mixture Models,
 - Hierarchical Clustering,
- Strojové učení s učitelem:
 - Nearest Neighbor Classification,
 - Classification trees,
 - Naive Bayes klasifikace,
 - Discriminant Analysis,
 - Multiclass Support Vector Machines,
- Kohonenovy sítě,
- Dopředné vícevrstvé neuronové sítě.

4 DOSAŽENÉ VÝSLEDKY

První výzkumná otázka byla zaměřena na vazbu mezi místem podnikání v České republice a výsledkem hospodaření. Z analýzy vyplynulo, že místo podnikání ovlivňuje počet podniků, které dosahují kladných hodnot *EVA*, obdobně se liší i další sledované kategorie. Míra ovlivnění je na druhé straně relativně malá.

Další otázka byla cílena na vztah mezi výší hodnot *EVA* a počtem zaměstnanců u příslušné skupiny MSP. Z analýzy vyplynulo, že vyšší počet zaměstnanců u malých a středních podniků nemá přímý vliv na vyšší hodnotu *EVA*.


Poslední stanovenou otázkou bylo, zdali existuje podstatný rozdíl mezi zaměřením podniku a tvorbou hodnoty EVA. Z analýzy vyplynula výrazná sektorová diference z hlediska tvorby přidané hodnoty.

4.1 PRINCIPAL COMPONENT ANALYTICS


Principal Component Analysis byla provedena na normalizované sadě dat, která obsahovala (první fáze) a později neobsahovala (druhá fáze) informace o hospodaření podniků. Vzhledem k tomu, že informace o hospodaření podniků byla klíčová pro jejich segmentaci dle metody INFA došlo v první fázi k rozdělení dat v prostoru takovým způsobem, kdy bylo snadné definovat klíčové shluky i přesto, že se nejedná o metodu učení s učitelem. V druhé fázi, tedy při odstranění těchto prediktorů, se jednotlivé množiny navzájem překrývaly. Porovnání obou výsledků je patrné z obrázku níže. V levé části obrázku (obrázek č. 5.a) jsou ve výsledcích obsaženy údaje o hospodaření podniku, pravá část pak tyto údaje nevstupovaly do provedené analýzy.

Přesto, že v prvním případě je množina snadno rozdělitelná, a tedy i predikovatelná, mělo smysl věnovat se predikci dat na množině, která nebude obsahovat informace o hospodářském výsledku. Pokud by totiž informace v množině byla, pak by osoba, která potřebuje znát výsledek zatřídění podniku, mohla hodnotu vypočítat ze známých vzorců a nemusela by využít klasifikačních metod. Rovněž by tento přístup nebyl v souladu se stanoveným cílem práce. Metoda PCA byla dále použita pro vizualizaci výsledků dalších metod s ohledem na redukci n dimenzionální úlohy.

Obrázek 5.a: PCA s údaji o hospodaření



Obrázek 6.b: PCA bez údajů o hospodaření




Zdroj: Vlastní tvorba.

4.2 METODY STROJOVÉHO UČENÍ BEZ UČITELE


4.2.1 K-Means clustering

Metoda K-Means Clustering byla opět využita jako metoda bez učitele. Výsledky rozdělení jsou patrné z obrázku níže kde v levé části (obrázek č. 6.a) je vidět dělení do segmentů dle metody a vpravo data, reprezentující reálné členění. Z uvedeného obrázku je patrné, že členění zde probíhá na základě zcela jiných vlastností, a proto je s ohledem na cíle práce nevyužitelné.

Obrázek 7.a: Výsledky K-Means Clustering



Obrázek 8.b: Reálné rozdělení podniků




Zdroj: Vlastní tvorba.


4.2.2 Gaussian Mixture Models

V případě využití o Gaussian Mixture Models se získané výstupy jeví na první pohled výrazně pozitivnější a průkaznější (obrázek č. 7.a). Při podrobnější analýze se však tato kvalita výsledků neprokázala, neboť uvedená data se významně překrývala. Díky tomu i rozdělení podniků pomocí této metody nebylo příliš využitelné s ohledem na cíl práce.

Obrázek 9.a: Gaussian Mixture Models



Obrázek 10.b: Reálné rozdělení podniků




Zdroj: Vlastní tvorba.

4.2.3 Hierarchické členění

Hierarchické členění přineslo výsledek v mnohém shodný s výsledky metody PCA s daty o hospodářském výsledku. Jelikož tato data nemohla být využita pro predikci, tak i výsledky z této analýzy nelze využít pro snadnou klasifikaci z důvodu stanovených cílů práce.

Obrázek 11.a: Výsledek hierarchického členění Obrázek 12.b: Reálné rozdělení podniků



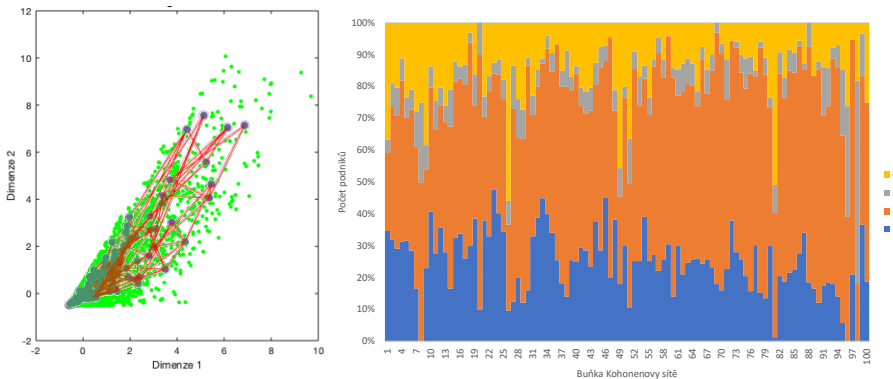
Zdroj: Vlastní tvorba.

4.2.4 Kohonenovy sítě

Další metodou, která byla využita pro klasifikaci bez učitele, byla Kohonenova síť. Výsledek ve variantě 100 neuronů (síť 10x10) je patrný z obrázku č. 9.a. Výstup SW Matlab nám jednoduše neumožňuje rozložení neuronů probarvit jednotlivými clustery, proto jsme pro analýzu využili další graf, který je vidět na obrázku vpravo (obrázek č. 9.b). Z obrázku je patrné, že žádný z neuronů nereprezentuje nějakou sledovanou skupinu podniků. V případě, že nějaká skupina podniků v daném clusteru chybí, je to způsobeno nedostatkem predikovaných dat (počet zatřížení menší jak 100). I v tomto případě není tato metoda využitelná pro naplnění stanovených cílů práce.

Obrázek 13.a: Neuronová síť

Obrázek 14.b: Jednotlivé neurony



Zdroj: Vlastní tvorba.

4.3 SOUHRNNÉ VÝSLEDKY UČENÍ S UČITELEM

Souhrnné výsledky jednotlivých algoritmů, které byly použity pro predikci, jsou uvedeny v tabulce č. 3. Data vychází z konfusních matic sestavených pro každý model. Z důvodu rozsahu zde neuvádíme vizualizaci jednotlivých modelů. Z tabulky je zřejmé, že úspěšnost predikce se pohybovala od 40 do 54 %. Data v tabulce představují procento správně zatřížených dat na dané množině. Z tabulky je rovněž patrné, že optimalizace hyperparametrů nejrůznějšími (vlastními i automatickými způsoby) nepřinesla zásadní vliv na výsledek. V řadě případů je zřejmé, že výsledná predikce kategorizace podniků dle hodnoty má lepší procento, než je tomu u jiných metod, ale

metoda sama o sobě zcela ignoruje predikci 3 a v některých případech i 4. kategorie podniků. S ohledem na cíl je nesporné, že tento typ predikce pro nás není prakticky využitelný. Z hlediska našich potřeb jsou využitelné ty metody, které predikují podniky ve všech kategoriích. Z těchto metod nejlépe vychází metoda stromové klasifikace, která dosáhla 45 % úspěšnosti.

Tabulka 1: Souhrnné výsledky metod učení s učitelem

Metoda	Kategorie podniku				Celková úspěšnost (%)
	1	2	3	4	
Nearest Neighbor Classification	37,8	50,2	16,3	41,2	43,1
Classification trees	44,6	51,1	11,6	43	45,0
Classification trees – optimalizace parametrů	51,3	73,4	0	36,8	54,4
Naive Bayes	37,7	44,2	13,1	20,9	41,7
Naive Bayes – optimalizace parametrů	26	74,1	0,3	28,6	45,1
Discriminant Analysis	3,3	95,3	1,9	0,5	41,4
Discriminant Analysis – optimalizace parametrů	12,6	96,3	0	0	44,8
Multiclass Support Vector Machines	29,5	78,2	0	7,2	43,4
Multiclass Support Vector Machines – opt. p.	20,8	84	0	14,6	44,7
Feed Forward Networks	38,1	49	0	40	45,2
Feed Forward Networks - optimalizace parametrů	36,3	48,7	0	43	46,2
Průměr	33,7	65,5	3,9	25,1	45,0
Max	51,3	95,3	16,3	43,0	54,4
Min	3,3	44,2	0,0	0,0	41,4

Zdroj: Vlastní tvorba.

Procento 45 % úspěšnosti modelu by mohlo působit negativně z pohledu dosažených výsledků. Je však třeba si uvědomit, že jsou zařazovány 4 kategorie podniku. Z pohledu náhodného zařazení by tak měla být úspěšnost okolo 25 %. Model tak dosahuje prokazatelně řádově větší přesnosti. Tato přesnost není zajištěna zacílením na nejčtenější množinu, což je velmi důležitý parametr s ohledem na ostatní modely. Dále je třeba zohlednit cíle vlastníků a manažerů malých a středních podniků. Tito manažeři a vlastníci velmi často ani neznají ekonomickou přidanou hodnotu, nebo se jí v praxi neřídí. Klíčové pro ně je, aby podnik dlouhodobě prosperoval a dosahoval „zisku“ nad úroveň bezrizikových investic. Zisk je zde uveden v uvozovkách, neboť musíme vzít v úvahu častou optimalizaci hospodaření podniku z pohledu daňových odvodů. Tato skutečnost je v našich podmínkách velmi frekventovaná a prakticky představuje jednu z nezávadnějších limitů prováděných analýz.

Pro lepší interpretovatelnost výsledků modelu stromu je vhodné použít zobrazení v kompletní konfuzní matici (obrázek níže). Z obrázku můžeme vysledovat, že pokud model určí, že se podnik bude nacházet v kategorii 1 (44,6 % pravděpodobnost) nebo v kategorii 2. (51,1 % pravděpodobnost), bude podnik z více jak 80 % pravděpodobností dosahovat zisku nad úroveň bezrizikové sazby r_f . Z této hodnoty jasně vyplývá, že výsledky výzkumu mohou být použity pro model benchmarkingu a následně v rámci nastavení vnitropodnikových cílů.

Obrázek 15: Konfusní matice – stromový model

Předikce	1	1529 13.8%	1302 11.8%	140 1.3%	459 4.2%	44.6% 55.4%
	2	1443 13.1%	2364 21.4%	222 2.0%	594 5.4%	51.1% 48.9%
	3	177 1.6%	301 2.7%	77 0.7%	106 1.0%	11.6% 88.4%
	4	548 5.0%	650 6.2%	102 0.9%	1004 9.1%	43.0% 57.0%
		41.4% 58.6%	50.9% 49.1%	14.2% 85.8%	46.4% 53.6%	45.0% 55.0%
	1	2	3	4		
	Predikce					

Zdroj: Vlastní tvorba.

Ve stromové analýze, stejně jako v jiných analýzách, byly využity prediktory, které mohou manažeři ovlivnit. Stejně tak byly využity i prediktory, které jsou dány okolím (velikost obce, kraj, ...). Tyto skutečnosti manažer téměř nemůže ovlivnit, ale může s nimi pracovat z pohledu diverzifikace portfolia, neboť je zřejmé, že některé typy podnikání mají v určitých krajích lepší podmínky pro další rozvoj (pravděpodobně snadnější dodavatelsko-odběratelská struktura, přístup úřadů, ...). Cílem práce nebylo analyzovat o jaké faktory se jedná v rámci vnějšího prostředí, neboť toto by vyžadovalo samostatnou studii.

S ohledem na cíl práce je model základní stromové klasifikace hlavním výsledkem této práce. Model v SW Matlab dokáže predikovat úspěšnost pohledu, a tedy i jeho zařazení na základě (prediktorů) výše uvedených dat. V práci je zároveň popsán podrobný postup sestavení daného modelu. Jednotlivé složky modelu, které mohou podniky ovlivnit, pak mohou být předmětem vnitropodnikových cílů. Při jejich realizaci pak podnik může dosahovat ekonomické přidané hodnoty s vyšší mírou pravděpodobnosti a model tak může sloužit jako efektivní benchmarking.

5 SHRnutí A PŘínOSY HABILITAČNÍ PRÁCE

5.1 PŘínOSY V TEORETICKÉ OBLASTI

O novosti a reprezentativnosti v teoretické oblasti poznání způsobů kategorizace podniků na základě generování přidané hodnoty u MSP lze hovořit z pohledu rozsahu testovaného souboru (více jak 25 tis. malých a středních podniků v České republice za období 5 let). Podniky byly analyzovány z pohledu ekonomické přidané hodnoty ve variantě ekvity. Předmětem analýzy byl vztah mezi řadou prediktorů (15 položek vyjmenovaných v metodice) a kategorií podniku, která byla stanovena na základě dosažených výsledků. Z nově získaných výsledků je zřejmé, že uvedené prediktory ovlivňují prokazatelně výsledky podniků. Přínos pro rozvoj teoretického poznání v řešené problematice byl proveden:

- návrhem postupu a vlastní realizací rozsáhlé analýzy souboru dat malých a středních podniků v ČR s ohledem na jejich dosažené výsledky dle ekonomické přidané hodnoty s návrhem na formu interpretace výsledků (grafická i textová),
- zmapováním aktuálních poznatků o oblasti ekonomické přidané hodnoty,
- konstrukcí nového modelu pro predikci zatřídění podniků do příslušných kategorií na základě výsledků ekonomické přidané hodnoty.

5.2 PŘínOSY V PEDAGOGICKÉ OBLASTI

Využití výstupů a poznatků získaných z řešení v rámci pedagogické oblasti byl proveden:

- koncepcí nového předmětu „Strojové učení a neuronové sítě“ v rámci akreditace profesně zaměřeného (SP) Ekonomika podniku, a to jak v oblasti přednášek, tak praktických cvičení,
- uplatnění dílčích výstupů v předmětech:
 - Metodika odborné práce (příloha anotace předmětů),
 - Finance podniku I a II (příloha anotace předmětů),
 - a Controlling (příloha anotace předmětů),
- uplatnění dílčích výstupů při výuce v rámci předmětů programů BBA a MBA,
- při zadávání témat bakalářských a diplomových prací,
- v rámci realizaci kurzů a školení v rámci CŽV,
- při řešení smluvního výzkumu,
- v průběhu poradenská a konzultační činnost.

5.3 PŘínOSY PRO PODNIKOVOU PRAXI

Praktický přínos realizovaného výzkumu nastal:

- konstrukcí a ověřením nového, snadno aplikovatelného modelu v podnikové praxi,
- využitím modelu pro tvorbu jednoduchého softwaru v Matlab, MS Excel nebo jiném programu pro klasifikaci MSP z hlediska generování přidané hodnoty,
- využitím modelu jako součásti benchmarkingového systému v podniku a jeho následné využití pro tvorbu vnitropodnikových cílů a jejich průběžnou inovaci dle dosahovaných výsledků a ekonomického cyklu,
- využitím modelu jako významného nástroje, resp. podkladu pro finanční řízení podniků,
- možností využití modelu jako zdrojového informačního materiálu pro podnikový controlling a jeho budoucí směřování,

- navržením základních rozhodovacích schémat nejprogressivnějšího modelu umožňujícího managementu podniků posoudit, zdali je pro ně model smysluplný, a zdali je vhodné upravit některé podnikové cíle,
- uplatnění výsledků v rámci řešení projektů TA ČR:
 - TA ČR TREND „Optimalizace zakázkové kusové výroby v reálném čase využitím IoT a digitálních technologií, FW01010460, VUSTE-APIS, s.r.o. řešitel, VŠTE v Českých Budějovicích spoluřešitel, doba řešení 2020–2023,
 - TA ČR ÉTA „Stabilizace a rozvoj MSP ve venkovském prostoru“ TL01000349, Vysoká škola technická a ekonomická v Českých Budějovicích, oblast řešení finanční řízení MSP, doba řešení 2018–2021,
 - TA ČR ÉTA „Digitální transformace pro inovace obchodních modelů v malých a středních podnicích v České Republice“ TL02000215, VUT v Brně, Fakulta podnikatelská řešitel, VŠTE v Českých Budějovicích spoluřešitel, doba řešení 2019 – 2022.

Výsledky byly konzultovány s HK pro Jihočeský kraj jako inovační nástroj řešení ekonomické udržitelnosti hospodaření MSP.

5.4 LIMITY PRÁCE

Limity výzkumu spočívají především v oblasti vstupních dat. Je zřejmé, že podkladová data jsou zatížena informačními šumy, které je nezbytné a možné redukovat, jak již bylo dokumentováno v předložené práci. I přes tuto skutečnost lze do určité míry algoritmy s danými chybami automaticky eliminovat. Za zásadní nedostatek v podobě vstupních dat lze spatřovat skutečnost, že řada malých a středních podniků nevyplňuje výkazy účetní závěrky. Zejména lze předpokládat, že se bude jednat o podniky s horšími ekonomickými výsledky.

Další limitou, kterou je nutné vzít v úvahu u malých a středních podniků, je daňová optimalizace, která se u menších podniků provede snadněji s větším dopadem na hospodářský výsledek. S největší pravděpodobností existuje řada podniků, které splňují cíle vlastníků i manažerů, ale z pohledu hospodářského výsledku se nachází pod úrovní bezrizikové sazby.

Limitace spočívá i v provedených analýzách, které sledují závislosti mezi prediktory a kategorií podniku. Neproběhla však další analýza spočívající v příčinném ověření výsledných závislostí. Toto je dáno zejména rozsahem, kdy výsledky pouze jedné analýzy mohou být předmětem zkoumání dalších několika podobně rozsáhlých výzkumných aktivit.

6 POUŽITÁ LITERATURA

Abbod, M. F., 2007. Application of Artificial Intelligence to the Management of Urological Cancer. *The Journal of Urology*. 178 (4): 1150–1156. doi:10.1016/j.juro.2007.05.122. PMID 17698099

Abdi, H., Williams, L.J., 2010. Principal component analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*. 2 (4): 433–459. arXiv:1108.4372. doi:10.1002/wics.101.

Altman, N. S., 1992. An introduction to kernel and nearest-neighbor nonparametric regression (PDF). *The American Statistician*. 46 (3): 175–185.

Améndola, C., et al., 2015. Moment varieties of Gaussian mixtures. *Journal of Algebraic Statistics*. 7. arXiv:1510.04654. Bibcode:2015arXiv151004654A. doi:10.18409/jas.v7i1.42

Beyer, K., et al., 1999. When is nearest neighbor meaningful?. *Database Theory—ICDT'99*, 217–235

Boser, B. E., Guyon, I. M., Vapnik, V. N., 1992. A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory – COLT '92*. p. 144. CiteSeerX 10.1.1.21.3818. doi:10.1145/130385.130401. ISBN 978-0897914970.

Bousquet, O., von Luxburg, U., Raetsch, G., eds., 2004. *Advanced Lectures on Machine Learning*. Springer-Verlag. ISBN 978-3540231226.

Brealey, R. A, S. C. Myers, F. Allen, 2013. *Principles of corporate finance*. 11th ed. New York: McGraw-Hill Irwin, p. cm. ISBN 00-780-3476-0.

Buhmann, J., Kuhnel, H., 1992. Unsupervised and supervised data clustering with competitive neural networks. [Proceedings 1992] *IJCNN International Joint Conference on Neural Networks*. 4. IEEE. pp. 796–801. doi:10.1109/ijcnn.1992.227220. ISBN 0780305590

Ciresan, D., Meier, U., Schmidhuber, J., 2012. Multi-column deep neural networks for image classification. *IEEE Conference on Computer Vision and Pattern Recognition*. pp. 3642–3649.

Coates, A., Ng, A. Y., 2012. Learning feature representations with k-means (PDF). In Montavon, G., Orr, G. B., Müller, K.-R. (eds.). *Neural Networks: Tricks of the Trade*. Springer.

Cortes, C., Vapnik, V. N., 1995. Support-vector networks (PDF). *Machine Learning*. 20 (3): 273–297. CiteSeerX 10.1.1.15.9362. doi:10.1007/BF00994018.

Cover T.M., Hart P.E. , 1967. Nearest neighbor pattern classification (PDF). *IEEE Transactions on Information Theory*. 13 (1): 21–27. CiteSeerX 10.1.1.68.2616.

Coomans D., D.L. Massart, 1982. Alternative k-nearest neighbour rules in supervised pattern recognition : Part 1. k-Nearest neighbour classification by using alternative voting rules. *Analytica Chimica Acta*. 136: 15–27. doi:10.1016/S0003-2670(01)95359-0

Freedman D. A. , 2009. *Statistical Models: Theory and Practice*. Cambridge University Press. ISBN 978-1-139-47731-4.

Demir, G. K., Ozmehmet, K., 2005. Online Local Learning Algorithms for Linear Discriminant Analysis. *Pattern Recogn. Lett.* 26 (4): 421–431. doi:10.1016/j.patrec.2004.08.005. ISSN 0167-8655.

Duda, R. O., Hart, P. E., Stork, D. G., 2001. *Unsupervised Learning and Clustering. Pattern classification* (2nd ed.). Wiley. ISBN 0-471-05669-3.

Fiala P., Karhan P., Ptáček J., 2014. Neuronové sítě a možnosti jejich využití. [cit. 2021-10-12] Dostupné online z: http://www.csfm.cz/userfiles/file/Udalosti_2014/KRF2014/fiala.pdf

Freund, Y. a R. E. Schapire, 1997. *A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting*. J. of Computer and System Sciences, Vol. 55, pp. 119–139.

Ghosh and Reilly, Credit card fraud detection with a neural-network, 1994 Proceedings of the Twenty-Seventh Hawaii International Conference on System Sciences, Wailea, HI, USA, 1994, pp. 621-630. doi: 10.1109/HICSS.1994.323314

Hall P, Park B.U., Samworth R.J., 2008. Choice of neighbor order in nearest-neighbor classification. *Annals of Statistics*. 36 (5): 2135–2152. arXiv:0810.5276. doi:10.1214/07-AOS537

Hamerly, G., Elkan, C., 2002. Alternatives to the k-means algorithm that find better clusterings (PDF). Proceedings of the eleventh international conference on Information and knowledge management (CIKM).

Hastie, T., Tibshirani, R., Friedman, J. H., 2009. *The Elements of Statistical Learning* (second ed.). Springer-Verlag. ISBN 978-0-387-84858-7. Archived from the original on 2009-11-10.

Haykin, S., 1999. 9. Self-organizing maps. *Neural networks - A comprehensive foundation* (2nd ed.). Prentice-Hall. ISBN 978-0-13-908385-3.

Hinton, G, Sejnowski, T. J., eds., 1999. *Unsupervised Learning: Foundations of Neural Computation*. MIT Press. ISBN 0-262-58168-X

Hotelling, H., 1933. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24, 417–441

Christianini, N., and J. C. Shawe-Taylor. *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. Cambridge, UK: Cambridge University Press, 2000.

Jiřina, M., 2008. Jak na neuronové sítě v programu STATISTICA Neuronové sítě. 2. vyd. Praha: StatSoft. ISBN 978-80-904033-1-4.

Karimi K., H.J. Hamilton, 2011, Generation and Interpretation of Temporal Decision Rules, *International Journal of Computer Information Systems and Industrial Management Applications*, Volume 3

Kaelbling, L. P., Littman, M. L., Moore, A. W., 1996. Reinforcement Learning: A Survey. *Journal of Artificial Intelligence Research*. 4: 237–285. arXiv:cs/9605103. doi:10.1613/jair.301. Archived from the original on 2001-11-20.

Kamiński, B., Jakubczyk, M., Szufel, P., 2017. A framework for sensitivity analysis of decision trees. *Central European Journal of Operations Research*. 26 (1): 135–159. doi:10.1007/s10100-017-0479-6. PMC 5767274. PMID 29375266

Kaufman, L., Roussew, P. J., 1990. *Finding Groups in Data - An Introduction to Cluster Analysis*. A Wiley-Science Publication John Wiley & Sons.

Kislingerová, E. 2007. Manažerské finance (Managerial Finance). Second revised and expanded edition. Prague: C. H. Beck. ISBN 978-80-7179-903-0.

Klecka, W. R., 1980. Discriminant analysis. Quantitative Applications in the Social Sciences Series, No. 19. Thousand Oaks, CA: Sage Publications.

Klieščík, T., J. Vrbka a Z. Rowland, 2018. Bankruptcy prediction in Visegrad group countries using multiple discriminant analysis. *Equilibrium-Quarterly Journal of Economics and Economic Policy*, Torun, Polsko: Inst Economic Research-Poland, 2018, roč. 13, č. 3, s. 569-593. ISSN 2353-3293. doi:10.24136/eq.2018.028.

Kohonen, T., 1982. Self-Organized Formation of Topologically Correct Feature Maps. *Biological Cybernetics*. 43 (1): 59–69. doi:10.1007/bf00337288.

Kohonen, T., 1989. Self-organizing and associative memory. (3rd ed.), Berlin: Springer-Verlag.

Kohonen, T., 2001. Self-Organizing Maps. Third, Extended Edition. Springer Series in Information Sciences vol. 30, Berlin, Germany: Springer-Verlag, ISBN 978-3-540-67921-9

Kriegel, H-P., Schubert, E., Zimek, A., 2016. The (black) art of runtime evaluation: Are we comparing algorithms or implementations?. *Knowledge and Information Systems*. 52 (2): 341–378. doi:10.1007/s10115-016-1004-2. ISSN 0219-1377.

Smith M.R., Martinez, T., 2011. Improving Classification Accuracy by Identifying and Removing Instances that Should Be Misclassified. *Proceedings of International Joint Conference on Neural Networks (IJCNN 2011)*. pp. 2690–2697. CiteSeerX 10.1.1.221.1371. doi:10.1109/IJCNN.2011.6033571

MacQueen, J. B., 1967. Some Methods for classification and Analysis of Multivariate Observations. *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*. 1. University of California Press. pp. 281–297.

Malý, M., 2007. Vícevrstvé dopředné neuronové sítě: úvod do teorie a aplikací. Ústí nad Labem: Univerzita J.E. Purkyně, Přírodovědecká fakulta, 2007. ISBN 978-80-7044-915-8.

Mařík, M., 2011. Metody oceňování podniku: proces ocenění - základní metody a postupy. 3., upr. a rozš. vyd. Praha: Ekopress, 2011. ISBN 978-80-86929-67-5.

Matlab documentation [online]. USA: The MathWorks, 2021 [cit. 2021-10-12]. Dostupné z: <https://www.mathworks.com/help/matlab/index.html>

Matlab-pdist. MathWorks [online]. United States: The MathWorks, ©1994-2021 [cit. 2021-08-08]. Dostupné z: <https://www.mathworks.com/help/stats/pdist.html>

Matlabacademy: Machine Learning with MATLAB [online]. USA: The MathWorks, 2021 [cit. 2021-10-12]. Dostupné z: <https://matlabacademy.mathworks.com>

McCulloch, W., W. Pitts, 1943. A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*. 5 (4): 115–133. doi:10.1007/BF02478259

McLachlan, G. J., 2004. Discriminant Analysis and Statistical Pattern Recognition. Wiley Interscience. ISBN 978-0-471-69115-0. MR 1190469

Mead, A., 1992. *Review of the Development of Multidimensional Scaling Methods*. Journal of the Royal Statistical Society. Series D (The Statistician). 41 (1): 27–39. JSTOR 234863

Mehryar M., A., Rostamizadeh, A., Talwalkar, (2012) *Foundations of Machine Learning*, The MIT Press ISBN 9780262018258.

Miljanovic, M., 2012. Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction (PDF). Indian Journal of Computer and Engineering. 3 (1).

Ministerstvo průmyslu a obchodu 2021. [online]. [cit. 2021-10-12]. Available from WWW: <https://www.mpo.cz/cz/rozcestnik/analyticke-materialy-a-statistiky/analyticke-materialy/>

Mogull, R. G., 2004. *Second-Semester Applied Statistics*. Kendall/Hunt Publishing Company. p. 59. ISBN 978-0-7575-1181-3.

Moustafa, R., Wegman, E., J., 2002. On Some Generalizations of Parallel Coordinate Plots (PDF). Seeing a Million, A Data Visualization Workshop, Rain Am Lech (nr.), Germany. Archived from the original (PDF) on 2013-12-24.

Neumaierová, I., 1998. *Řízení hodnoty (Value Management)*. Prague: University of Economics in Prague. Faculty of Business Administration, 1998. 137 pp ISBN 80-7079-921-8.

Neumaierová, I., 2003. *Aplikace řízení hodnoty (Value Management Application)*. Prague: University of Economics in Prague. Faculty of Business Administration. 95 pp ISBN 80-245-0536-3.

Neumaierová, I., Neumaier, I., 2006. Proč se ujal index IN a nikoli pyramidový systém ukazatelů INFA [online]. [cit. 2021-10-12].

Ojha, V. K., Abraham, A., Snášel, V., 2017. Metaheuristic design of feedforward neural networks: A review of two decades of research. *Engineering Applications of Artificial Intelligence*. 60: 97–116. arXiv:1705.05584. Bibcode:2017arXiv170505584O. doi:10.1016/j.engappai.2017.01.013.

Pearson, K., 1901. *On Lines and Planes of Closest Fit to Systems of Points in Space*. *Philosophical Magazine*. 2 (11): 559–572. doi:10.1080/14786440109462720.

Pelleg, D., Moore, A., 1999. Accelerating exact k -means algorithms with geometric reasoning. *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining - KDD '99*. San Diego, California, United States: ACM Press: 277–281. doi:10.1145/312129.312248. ISBN 9781581131437.

Press, W. H., Teukolsky, S. A., Vetterling, W. T., Flannery, B. P., 2007. Section 16.1. Gaussian Mixture Models and k-Means Clustering. *Numerical Recipes: The Art of Scientific Computing (3rd ed.)*. New York (NY): Cambridge University Press. ISBN 978-0-521-88068-8.

Quinlan, J. R., 1987. Simplifying decision trees. *International Journal of Man-Machine Studies*. 27 (3): 221–234. CiteSeerX 10.1.1.18.4267. doi:10.1016/S0020-7373(87)80053-6.

Simkanič, R., 2016, *Deep Learning v analýze obrazu*, VŠB – Technická univerzita Ostrava Fakulta elektrotechniky a informatiky

Rao, C. R., Toutenburg, H., et al., 2008. *Linear Models: Least Squares and Alternatives*. Springer Series in Statistics (3rd ed.). Berlin: Springer. ISBN 978-3-540-74226-5.

Rennie, J., Shih, L., Teevan, J., Karger, D., 2003. Tackling the poor assumptions of Naive Bayes classifiers

Rish, I., 2001. An empirical study of the naive Bayes classifier (PDF). IJCAI Workshop on Empirical Methods in AI.

Rokach, L., Maimon O., 2005. *Clustering methods*. Data mining and knowledge discovery handbook. Springer US.

Roll, R., 1977. A Critique of the Asset Pricing Theory's Tests. *Journal of Financial Economics*. 4 (2): 129–176. doi:10.1016/0304-405X(77)90009-5

Balabin R. M. a Lomakina E. I., 2009. Neural network approach to quantum-chemistry data: Accurate prediction of density functional theory energies. *J. Chem. Phys.* 131 (7): 074104. Bibcode:2009JChPh.131g4104B. doi:10.1063/1.3206326. PMID 19708729.

Roman, V., 2019. *Unsupervised Machine Learning: Clustering Analysis*. Medium. Retrieved 2019-10-01.

Ronald A. Fisher, 1954. *Statistical Methods for Research Workers* (Twelfth ed.). Edinburgh: Oliver and Boyd. ISBN 978-0-05-002170-5.

Russell S. J. a P. Norvig, 2010. *Artificial Intelligence: A Modern Approach*, Third Edition, Prentice Hall ISBN 9780136042594.

Sak, H., S., Andrew, B., Françoise , 2014. Long Short-Term Memory recurrent neural network architectures for large scale acoustic modeling (PDF). Archived from the original (PDF) on 24 April 2018.

SAS Institute, 2019. *The DISTANCE Procedure: Proximity Measures*. SAS/STAT 9.2 Users Guide.. Retrieved 2009-04-26. dostupné online: https://support.sas.com/documentation/cdl/en/statug/63033/HTML/default/viewer.htm#statug_dist_ance_sect016.htm

Seber, G. A. F, 1984. *Multivariate Observations*. Hoboken, NJ: John Wiley & Sons, Inc.

Seiffert, C., T. Khoshgoftaar, J. Hulse, and A. Napolitano, 2008. *RUSBoost: Improving clasification performance when training data is skewed*. 19th International Conference on Pattern Recognition, pp. 1–4.

Shaw P.J.A., 2003 *Multivariate statistics for the Environmental Sciences*, Hodder-Arnold. ISBN 0-340-80763-6.

Soummer, R., Pueyo, L., Larkin, J., 2012. Detection and Characterization of Exoplanets and Disks Using Projections on Karhunen-Loève Eigenimages. *The Astrophysical Journal Letters*. 755 (2): L28. arXiv:1207.4197. Bibcode:2012ApJ...755L..28S. doi:10.1088/2041-8205/755/2/L28

Stehel, V., J. Horak A T. Krulicky, 2021. Business performance assessment of small and medium-sized enterprises: Evidence from the Czech Republic. *Problems and Perspectives in Management*, 2021, roč. 19, č. 3, s. 430-439. ISSN 17277051

Stehel, V. a M. Vochozka 2014. Company Management by Using INFA Method. In 12th International Academic Conference : sborník příspěvků. 1. vyd. Praha: International Institute of Social and Economic Sciences (IISES), 2014. s. 1132-1144, 13 s. ISBN 978-80-87927-04-5.

Székely, G. J., Rizzo, M. L., 2005. Hierarchical clustering via Joint Between-Within Distances: Extending Ward's Minimum Variance Method. *Journal of Classification*. 22 (2): 151–183. doi:10.1007/s00357-005-0012-9.

Šíma, J. a Neruda, J. 1996. Teoretické otázky neuronových sítí. Matfyzpress, Praha.

Šnorek M., Jiřina M., 1998. Neuronové sítě a neuropočítače. ČVUT, Praha, ISBN 80–01–01455–X.

Šťastný, P., 2014. Rozpoznávání objektů pomocí neuronových sítí [online]. Brno, 2014 [cit. 2020-01-05]. Dostupné z: <<https://is.muni.cz/th/rr91b/>>. Diplomová práce. Masarykova univerzita, Fakulta informatiky. Vedoucí práce Jiří Hřebíček.

Titterington, D., Smith, A., Makov, U., 1985. Statistical Analysis of Finite Mixture Distributions. Wiley. ISBN 978-0-471-90763-3.

Utgoff, P. E., 1989. Incremental induction of decision trees. *Machine learning*, 4(2), 161-186. doi:10.1023/A:1022699900025

Vochozka, M. a J. Horák, 2019. Comparison of neural networks and regression time series when estimating the copper price development. In Ashmarina, S., Vochozka, M.. Sustainable Growth and Development of Economic Systems: Contradictions in the Era of Digitalization and Globalization, In: Contributions to Economics. Cham, Switzerland: Springer. s. 169-181, 13 s. ISBN 978-3-030-11753-5.

Vochozka, M., 2011. Metody komplexního hodnocení podniku. 1. vyd. Praha: Grada Publishing, 2011. 246 s. Finanční řízení. ISBN 978-80-247-3647-1.

Vojáček, A., 2006. Samoučící se neuronová síť - SOM, Kohonenovy mapy [online]. [cit. 2021-10-12]. Dostupné z: https://www.kiv.zcu.cz/studies/predmety/uir/NS/Samouc_NN2.pdf

Volná, E., 2008 [online]. *Neuronové sítě 1*. Ostravská univerzita v Ostravě, [cit. 2021-10-12] Dostupné z: http://www1.osu.cz/~volna/Neuronove_site_skripta.pdf

Vondrák, I., 2000 Umělá inteligence a neuronové sítě. 2. vyd. Ostrava: Vysoká škola báňská - Technická univerzita. ISBN 80-7078-949-2.

Warmuth, M., J. Liao, a G. Ratsch, 2006. *Totally corrective boosting algorithms that maximize the margin*. Proc. 23rd Int'l. Conf. on Machine Learning, ACM, New York, pp. 1001–1008.

Widrow, B., et al. , 2013. The no-prop algorithm: A new learning algorithm for multilayer neural networks. *Neural Networks*. 37: 182–188. doi:10.1016/j.neunet.2012.09.020. PMID 23140797

Wöhe, G. 1995. Úvod do podnikového hospodářství. Praha C. H. Beck. ISBN 80-7179-014-1

Zha, H., Ding, C., Gu, M., He, X., Simon, H. D., 2001. Spectral Relaxation for k-means Clustering (PDF). *Neural Information Processing Systems Vol.14 (NIPS 2001)*: 1057–1064.

Zissis, D., 2015. A cloud based architecture capable of perceiving and predicting multiple vessel behaviour. *Applied Soft Computing*. 35: 652–661. doi:10.1016/j.asoc.2015.07.002

7 ABSTRAKT

Práce se zabývá predikcí kategorizace malých a středních podniků v České republice, která je stanovena na základě ekonomické přidané hodnoty. Do provedených analýz v rámci testovaných modelů vstupovaly účetní závěrky a další údaje o více jak 25 tis. podnicích. Data z účetních závěrek byla dále upravována a celkově bylo stanoveno celkem 15 prediktorů, kde 5 prediktorů bylo kategoriálních a zbytek numerických.

Nad uvedeným datovým souborem proběhlo několik analýz strojového učení bez učitele a s učitelem. U metod bez učitele byly použity Principal component analysis, k-means clustering, Gaussian mixture models, Hierarchical clustering a Kohonenovy sítě. V případě metod s učitelem byly provedeny analýzy Nejbližší soused, Stromová klasifikace, Naive Bayes klasifikace, Discriminant analýza, Multiclass support machine a dopředné neuronové sítě. Výsledky jednotlivých metod byly optimalizovány vlastními i automatickými algoritmy. Pro lepší interpretovatelnost výsledků byla data vizualizována.

Za nejvhodnější model lze označit ten, který dosahuje schopnosti klasifikace podniků do čtyř kategorií ve výši 45 % na kontrolní množině podniků. Jedná se o model založený na stromové struktuře. Při zjednodušení zařazení do dvou kategorií dokáže model predikovat kladný výsledek hospodaření nad úrovní bezrizikových výnosů s pravděpodobností přesahující 80 %. Zjednodušený rozhodovací model je přílohou práce a může být na něj navázáno softwarem pro testování podniků či využit pro tvorbu vnitropodnikových cílů.

8 ABSTRACT

The work deals with forecasting a category of enterprises determined based on economic value added. The analysis included financial statements and other data about more than 25,000 enterprises. The financial statements data were further processed and a total of 15 predictors were determined, out of which 5 were categorical predictors, while the remaining 10 predictors were numerical.

The above dataset was subjected to several analysis of machine learning both without and without a supervision. In the case of methods without a supervision, Principal component analysis, k-means clustering, Gaussian mixture models, Hierarchical clustering and Kohonen networks were included. The methods with a supervision included Nearest neighbour, Tree algorithm, Naive Bayes classification, Discriminant analysis, Multiclass support machine, and Feed-forward neural networks. The results of the individual methods were optimized using own and automatic algorithm. For better interpretation of the results obtained, the data were visualised.

The most suitable model is capable to classify the enterprises into four categories of 45 % on the control set of enterprises. It is a model based on tree structure. By simplifying the classification to two categories, the model is able to forecast a positive economic result above the risk-free yield with a probability exceeding 80 %. The simplified decision-making model is attached to the work and can be followed by software or creation of enterprise internal goals.