

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta stavební

Ústav vodního hospodářství krajiny

Doc. Ing. Miloš Starý, CSc.

**UŽITÍ UMĚLÝCH NEURONOVÝCH SÍTÍ
V APLIKOVANÉ HYDROLOGII**

USE OF ARTIFICIAL NEURAL NETWORKS
IN APPLY HYDROLOGY

ZKRÁCENÁ VERZE HABILITAČNÍ PRÁCE



BRNO 2004

KLÍČOVÁ SLOVA

aplikovaná hydrologie, vodní hospodářství, umělá inteligence, neuronové sítě, genetické algoritmy, fuzzy logik, předpovědní modely, operativní řízení

KEY WORDS

apply hydrology, water management, artificial intelligence, neural networks, genetic algorithm, fuzzy logic, prediction models, operative control

Originál práce je uložen v archivu PVO FAST

Představení autora	4
1 Úvod a cíl práce	6
2 Neuronové sítě	7
2.1 Základní pojmy	8
2.2 Způsob učení (trénování)	11
2.3 Užití genetických algoritmů pro trénování neuronové sítě	13
2.4 Topologie neuronových sítí.....	15
2.5 Standardizace dat	15
2.6 Simulátory neuronových sítí	15
3 Aplikace neuronových sítí	16
3.1 Neuronové sítě ve funkci aproximátoru simulačního modelu	16
3.1.1 Užití neuronových sítí pro předpovídání kulminačních průtoků	17
3.1.2 Užití neuronových sítí pro předpovídání hydrogramů povodňových vln	17
3.2 Modelování povodňových průtoků v systému stanic s využitím neuronových sítí	18
3.3 Předpověď průtoků v systému měrných stanic	21
3.4 Užití metod umělé inteligence při operativním řízení vodohospodářských systémů.....	26
3.4.1 Operativní řízení odtoku vody z dolní části kanalizační sítě v Kodani.....	27
3.4.2 Operativní řízení toku vody soustavou nádrží v dolní části velkého povodí za povodňové situace	30
3.5 Neuronová síť ve funkci analyzátoru stupně ohrožení v povodí s nádržemi	31
4 Závěr.....	34
5 Seznam odkazů na literaturu	38
Summary	40

PŘEDSTAVENÍ AUTORA

Doc. Ing. Miloš Starý, CSc.

Narozen: 5.11.1953 v Blažkově, okres Žďár n/Sázavou



Vzdělání:

- Gymnázium Bystřice n/Pernštejnem (1968-1972)
- Vysoké učení technické v Brně, FAST, studijní obor Vodní stavby a vodní hospodářství (1972-1977)
- CSc.: 1984, téma „Spolehlivost hlinitého těsnění sypaných zemních a kamenitých hrází“, obor: 36-04-9 Hydrotechnika, školitel: Prof.Ing. Jiří Kratochvíl, DrSc.
- Doc.: 1989 – obor Hydrologie a vodní hospodářství

Zaměření:

Hydrologie, aplikovaná hydrologie (operativní hydrologie), nádrže a vodohospodářské soustavy, automatizované systémy řízení, aplikace metod umělé inteligence ve vodním hospodářství.

Zaměstnání:

- 1978 až 1979 - základní vojenská služba na letišti v Žatci
- 1979 až 1982 - Jihomoravské vodovody a kanalizace OZ Žďár n/Sázavou
- 1982 až 2004 – VUT v Brně, FAST, Ústav vodního hospodářství krajiny

Praxe

- Vodohospodář na letišti v Žatci v rámci základní vojenské služby (1978-1979)
- Stavbyvedoucí, vodohospodář a vedoucí provozu Jihomoravských vodovodů a kanalizací na polovině okresu Žďár n/Sázavou (1979-1982)
- Odborný asistent, docent, vedoucí Ústavu vodního hospodářství krajiny VUT FAST (1982-2004)

Odborné stáže

- 1986 - 1 měsíční stáž na VISA, Sofie, Bulharsko (automatizované systémy řízení)
- 1991 - 4 měsíční stáž na Department of Environmental Engineering, Lyngby, Denmark (operativní řízení odtoku vody z urbanizovaného povodí)

Spolupráce s externí sférou

- Spolupráce na zpracování koncepce a rozvoji vodohospodářských dispečinků se zaměřením na operativní prognózování a řízení otoků vody z povodí za průchodu povodní. Jedná se o státní podniky Povodí Odry, Povodí Labe a Povodí Ohře (1994-2004)
- Spolupráce s Českým hydrometeorologickým ústavem Praha na zavádění operativních předpovědních modelů odtoku vody z povodí (pobočky Brno a Ostrava, 1998-2004)
- Spolupráce s ČVUT FS na řešení grantů GAČR orientovaných na využití metod umělé inteligence ve vodohospodářské praxi (1997-2004)
- Spolupráce s VÚV T.G.Masaryka Brno na řešení externích grantů (1994-1998)

Řešené projekty (odpovědný řešitel, resp. spoluředitel)

- 1992-1994 Vliv působení bodových zdrojů znečištění na čistotu malých vodních toků bystřinného typu. Program: Zdraví lidu a zdravá výživa, 738 Minimalizace obsahu nežádoucích látek v systémech půda-voda-rostlina-produkt, VÚMOP Praha, DP 738-01-08/01
- 1996 -1998 Ekologické aspekty ochrany vodního bohatství / Řešení mimořádných situací pod vodohospodářskými díly/ Simulace povodňových průtoků v Dyjsko-svratecké vodohospodářské soustavě. Projekt Rady vlády VaV-510/3/96
- 1995-1997 Metody výpočtu hydrologických dat pro vodní hospodářství a ochranu ŽP v podmínkách antropogenního ovlivnění a klimatických změn, 03- Modelování hydrogramů povodňových vln v systému stanic, VÚV TGM, Praha
- 1997-1999 Metody umělé inteligence v teorii vodohospodářských soustav. GAČR 103/97/0106
- 2001-2003 Problematika operativního řízení vodohospodářských soustav v podmínkách neurčitosti,. GAČR 103/01/0201
- 2004-2006 Teorie řízení vodohospodářských soustav za povodňových situací, GAČR 103/04/0352

Pedagogická činnost

- *magisterský program*
 - *přednášky*: Nádrže a vodohospodářské soustavy (1983-2004), Hydrologie (1986-2004), Automatizované systémy řízení ve VH (1986-1990), Hydraulika a hydrologie (1998-2004), Vodohospodářské stavby (1997-1998), Vodní zdroje – mezioborové studium MZLU LDF a VUT FAST (1990-1991).
 - *vedení diplomantů*: 40 obhájených prací
 - *členství v komisích pro SZZ a obhajoby DP*: VUT FAST Brno, STU FS Bratislava, ČVUT FS Praha
- *doktorský program*
 - *přednášky*: Hydrologie, Aplikovaná hydrologie, Vodohospodářské soustavy
 - *vedení aspirantů a doktorandů*: 5 obhájených prací, z toho jedna v anglickém jazyce a jednou jako školitel specialista
 - *členství v komisích pro obhajoby doktorských disertačních prací*: VUT FAST – Vodní hospodářství a vodní stavby, ČVUT FS – Vodní hospodářství a vodní stavby
 - *členství v oborových radách DSP*: VUT FAST – Vodní hospodářství a vodní stavby (předseda) , ČVUT FS – Vodní hospodářství a vodní stavby (člen)

Publikace

- monografie (*ACADEMIA*): 1x
- editované sborníky vydané knižně v zahraničí: 2x
- recenzované vědecké časopisy a knižnice: 18x
- sborníky mezinárodních vědeckých konferencí: 43x
- sborníky konferencí a ostatní časopisy: 13
- výzkumné a expertní zprávy: 37x
- významné inženýrské dílo (software): 2x
- recenze a odborné posudky (články ve vědeckých časopisech, výzkumné zprávy, projekty, habilitační práce, doktorské práce): 24x
- skripta: 8x

1 Úvod a cíl práce

Vybrané problémy z oblasti aplikované hydrologie, které se vztahují k modelování srážkoodtokového procesu v povodí nebo modelování dílčích problémů s tímto procesem spojených, se vyznačují poměrně značnou složitostí řešení. Srážkoodtokový proces je možno chápat jako postupnou transformaci časově a prostorově proměnlivé srážky, která dopadá na povodí, až na koncentrovaný odtok vody závěrovým profilem. Povodí, ve kterém proces probíhá, je složitým systémem s výraznými dynamickými (přenosovými) vlastnostmi, který pracuje se značným časovým zpožděním. V průběhu uvedené transformace probíhají dvě dílčí transformace. Jedná se o hydrologickou transformaci, která v sobě zahrnuje uplatnění hydrologických ztrát (evapotranspirace, navlhání, intercepce, povrchová retence a infiltrace). Současně však probíhá i hydraulická transformace, kterou rozumíme postupnou koncentraci plošného povrchového a podzemního odtoku vody z povodí až na zmíněný odtok vody závěrovým profilem.

Složitost srážkoodtokového procesu je v posledních letech umocněná očekávanými a částečně se již projevujícími vlivy změn klimatu, spojenými se změnami vydatnosti a časového rozložení vodních zdrojů. To se ve spojitosti s vlivem dlouhých period změn klimatických a hydrologických veličin projevuje nejen vznikem katastrofálních povodní, ale i vznikem extrémně málovodých období. Uvedená problematika často nutí vodohospodáře řešit problémy, na které ne vždy mají dostatečně propracované metodické postupy a nástroje. Zejména se jedná o nutnost rozvíjení nestrukturálních opatření v povodí souvisejících s operativní hydrologií, tj. operativním předpovídáním a operativním řízením odtoku vody z povodí, pokud v povodí existují vhodné regulační prvky, především vodní nádrže.

Je nutno si uvědomit, že řešení uvedených problémů probíhá za výrazných podmínek neurčitosti. Neurčitost chápeme jako vlastnost některých jevů a procesů vyznačujících se buď jejich nahodilostí, nebo vágností. Pro zkoumání nahodilosti se rozvíjí od poloviny 17. století teorie pravděpodobnosti a od přelomu 19. a 20. století teorie náhodných procesů. Pro formalizaci vágnosti položil základy L. Zadeh [45].

Neurčitost se projevuje při řízení vodohospodářských systémů tím, že neznáme přesný průběh vstupů řešení (přítoky do systému, srážky nad povodím apod.). Vstupy jsou převážně náhodné procesy, jejichž průběh v minulosti je zatížen náhodnou chybou měření a predikovaný budoucí průběh vstupních hydrologických veličin je navíc zatížen náhodnou chybou předpovědního modelu. Neurčitost je obsažena i v matematických modelech použitých pro operativní řízení (schematizace systému, nevhodná volba numerického modelu, stanovení parametrů modelu kalibrací, chyby vstupů modelu stanovené měřeními a zpracováním). Zejména při řízení v reálném čase je třeba srážkoodtokové modely výrazně zjednodušit v zájmu přijatelné rychlosti výpočtu. Rychlost výpočtu je v operativní hydrologii pro praktické nasazení modelů veličinou limitující. Model pak spolehlivě zobrazuje jen část reality a pouze výsledky dosažené v praxi jsou mírou přijatelnosti použitého zjednodušení.

V oblasti vývoje metod umělé inteligence se v současnosti projevuje úsilí o řešení problematiky rozhodování za podmínek neurčitosti (inteligentní řízení). Řídící systémy musí být vybaveny schopností využívat zkušenosti a znalosti popsané jen vágně a reagovat na neurčité a předem neznámé situace. Adaptivní přístup, uplatněný při operativním řízení za popsaných podmínek neurčitosti, je určitou cestou jak tyto dopady vhodnou konstrukcí řídicích algoritmů do určité míry eliminovat. Výsledky dosažené v praxi výhody uplatnění adaptivního přístupu k řešení jednoznačně potvrzují, ať již se jedná o jeho uplatnění ve spojitosti s klasickými řídicími algoritmy, založenými na ryze optimalizačních principech, nebo ve spojitosti s řídicími algoritmy využívajícími metody umělé inteligence.

Neuronové sítě jsou jednou z metod umělé inteligence. Vynikají schopností aproximovat i silně nelineární vztahy mezi vstupními a výstupními veličinami řešených problémů, kterých je ve vodním hospodářství přebytek. Především však vynikají rychlostí výpočtů při použití již natrénované neuronové sítě. Obě tyto vlastnosti předurčují oblasti jejich použití.

Práce si klade za cíl posoudit možnosti nasazení neuronových sítí pro řešení problémů v oblasti aplikované hydrologie, především operativní hydrologie. Posouzení je provedeno na základě vybraných úloh, ve kterých byly neuronové sítě použity a v nich dosažených výsledků. Na dílčích problémech jsou však naznačeny i možnosti pro použití jiných metod z oblasti umělé inteligence, tj. genetických algoritmů, které jsou využity pro trénování neuronových sítí a fuzzy-regulátorů, které jsou využity při konstrukci řídicích algoritmů.

První část práce je věnována teoretickému popisu neuronových sítí, přenosovým funkcím, metodám užívaným pro jejich trénování včetně trénování za použití genetických algoritmů, jejich topologii, naznačena je i jejich jistá souvislost s regresními modely a možnost jejich kombinace s fuzzy systémy. V závěru části je uveden popis dostupných vybraných simulátorů neuronových sítí.

Druhá část práce je věnována popisu aplikací neuronových sítí při řešení vybraných úloh. Jedná se o kolekci úloh postupně řešených od roku 1991. Všechny úlohy jsou původní. Řešil jsem je buď samostatně, nebo ve spolupráci s posluchači studijního oboru "V", kteří je zpracovávali pod mým vedením. Většina úloh byla publikována a obsahuje odkazy na příslušné články.

Převážná část práce byla publikována v rámci monografie "Využití metod umělé inteligence ve vodním hospodářství" [18]. Některé z aplikací byly řešeny v rámci projektů Grantové agentury ČR: reg.č.103/97/0106 "Metody umělé inteligence v teorii vodohospodářských soustav" a reg.č.103/01/0201 "Problematika operativního řízení vodohospodářských soustav v podmínkách neurčitosti". Ve vývoji vybraných aplikací z oblasti operativního řízení odtoku vody z povodí je pokračováno v rámci projektu reg.č.103/04/0352 "Teorie operativního řízení vodohospodářských soustav za povodňových situací".

2 Neuronové sítě

Umělé neuronové sítě (dále jen neuronové sítě - NS), dominují v rozpoznávání okamžité závislosti ze vzorů vstupně výstupních vztahů. Tím se liší od expertních systémů, které dosahují výborných výsledků v posloupnosti logických operací a fuzzy logických metod, které se vyznačují schopností reprezentovat znalosti.

První informace o NS bývá spojována se jmény McCullocha & Pittse (1943), kteří sestavili první neuronový model [15]. V roce 1949 navrhl Donald Hebb ve své knize Organization of Behaviour [9] model založený na biologické podobnosti, který je schopný učení. Na popsáných principech je založena řada moderních učících se síťových mechanismů. Dominantní postavou 50. let se v oblasti NS stal Frank Rosenblatt. Vyvinul třídu neuronů nazývaných "Perceptrony" [21]. Jeho přístup výrazně posunul vpřed teorii založenou na rozpoznávání vzorů a na asociativním učení. Na přelomu 60. a 70. let pokračovala intenzivně ve vývoji NS řada vědců. K nejznámějším patří Steven Grossberg, Geoffery Hinton, Teuvo Kohonen, Kunihiko Fukushima a J. A. Anderson.

V roce 1982 publikoval John Hopfield, profesor chemie a biologie v Kalifornii v Technologickém institutu články o NS [10], které byly natolik významné, že stimulovaly řadu vědců a roztočily další kolo rozvoje neuronových sítí. Objevilo se v nich několik klíčových momentů jako popis zpětné vazby mezi neurony, nelinearita přenosových funkcí, koncept globální energetické funkce, teorie energetických stavů a teorie minimalizace energetického toku. V roce 1986 napsal Rumelhart se svým kolektivem první knihu o neuronových sítích [22]. V témže roce se objevily první aplikace teorie zpětného šíření

(back-propagation) při učení NS a byly popsány v článku Sejnowského [23]. V roce 1992 bylo vyvinuto první hardwarové řešení neuronových sítí - neuronové karty (LORAL - USA), které se vkládají do počítače. Dosud byly všechny neuronové sítě řešeny softwarovou simulací. Hardwarové řešení značně urychlilo proces učení. Řádově až tisíckrát i více. V roce 1993 se objevily obdobné komerčně dostupné hardwarové karty (CNAPS), vyvinuté firmou Adaptive Solution rovněž v USA, které je možno využít jako akcelerátor při trénování neuronových sítí.

V naší odborné veřejnosti je možno zaznamenat první články a publikace týkající se obecného popisu NS až po roce 1988. Z autorů je možno vzpomenout např. Hořejše a Kufudaki [11], Nováka [20], Bílu [3] a Křivana [12].

Co se týká publikací našich autorů zaměřených na užití NS ve vodním hospodářství, je možno uvést příspěvek Nacházela a Tomana [19], zaměřený na problematiku NS a jejich užití pro optimalizaci výroby elektrické energie v soustavě vodních elektráren. Kromě toho lze uvést některé práce Starého, publikované samostatně nebo se spolupracovníky. Z nich je možno vzpomenout [37], ve kterém je uveden popis užití NS při operativním řízení kanalizační sítě v Kodani, dále příspěvek [38], zaměřený na užití NS při modelování změny kvality vody po délce toku Bystřička pod výustí z ČOV Bystřice n/P. V [30] je popsáno použití NS při modelování hydrogramů povodňových průtoků v systému stanic. Z prací, které publikoval v zahraničí, je možno vzpomenout [25], kde byly shrnuty některé zkušenosti s užitím NS v aplikované hydrologii. Článek [34] je zaměřen na předpověď průběhů hydrogramů odtoků z přívalových srážek z povodí řeky Morávka s uzávěrovým profilem Morávka. Fošumpaur se ve své doktorské disertační práci [8] zabývá využitím NS pro operativní předpovědi odtoku vody z povodí.

2.1 Základní pojmy

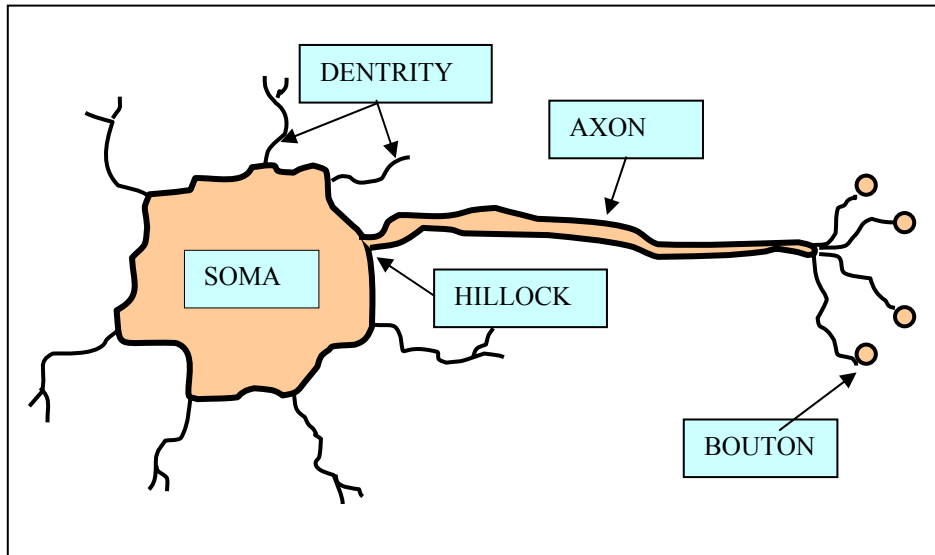
Pro pochopení funkce NS je třeba uvést některé základní pojmy [20]. Lidský mozek sestává ze sítě mnoha biliónů speciálních buněk, které se nazývají neurony. Typický neuron znázorněný na obr.1 se skládá z těla neuronu (soma), z něhož vybíhá nervové vlákno (axon). To je zakončené rozvětvením směřujícím k ostatním neuronovým buňkám v síti, s jejichž těly tvoří elektrochemickou vazbu (synapse).

Dentrity, které spojují neuron s ostatními pomocí synapsí, přenášejí podráždění (vstupní signály) do somy. Zde jsou tyto signály sečteny a je rozhodnuto podle jejich síly a povahy, zda budou propuštěny a s jakou silou (filtrace přes membránu - hillock) do axonu. Ten pak přenáší signál do ostatních neuronů přes boutony s různou velikostí a zpožděním. Každá neuronová buňka se chová jako extrémně jednoduchý počítač [13], jehož schéma je uvedeno na obr.2.


Umělý neuron přijímá vstupní signály (vstupy) a vysílá výstupní signál (výstup). každý neuron přijímá vstupy z mnoha jiných neuronů. Definujme umělou NS jako orientovaný graf $G(N,H)$, ve kterém množinu vrcholů N tvoří těla neuronů (n_i) a množinu hran H tvoří spojnice neuronů (h_{ij}). Necht' jsou v tomto grafu jednotlivé neurony uspořádány do vrstev podle obr.3 tak, že vstupní vrstvu tvoří vstupní neurony, dále následuje skrytá vrstva neuronů (může být více vrstev) a vrstva výstupních neuronů. Neurony jsou v NS průběžně očíslovány. Každý neuron v libovolné skryté vrstvě je spojen hranou s každým neuronem vrstvy předchozí i vrstvy následné.

Funkci typického neuronu v umělé NS je možno popsat na příkladu neuronu n_j , vyjmutého ze skryté vrstvy, který je znázorněn na obr.4. Zde jsou současně zobrazeny tři neurony n_i z předchozí vrstvy, které mu signál předávají a symbolicky dva neurony n_k z následující výstupní vrstvy, které od něj signál přijímají. Na obrázku značí u počáteční a v koncové číslo neuronu n_i předávajícího signál j -tému neuronu podle průběžného číslování neuronů v NS. Označme O_i signál vystupující z i -tého neuronu a O_{ij} signál procházející

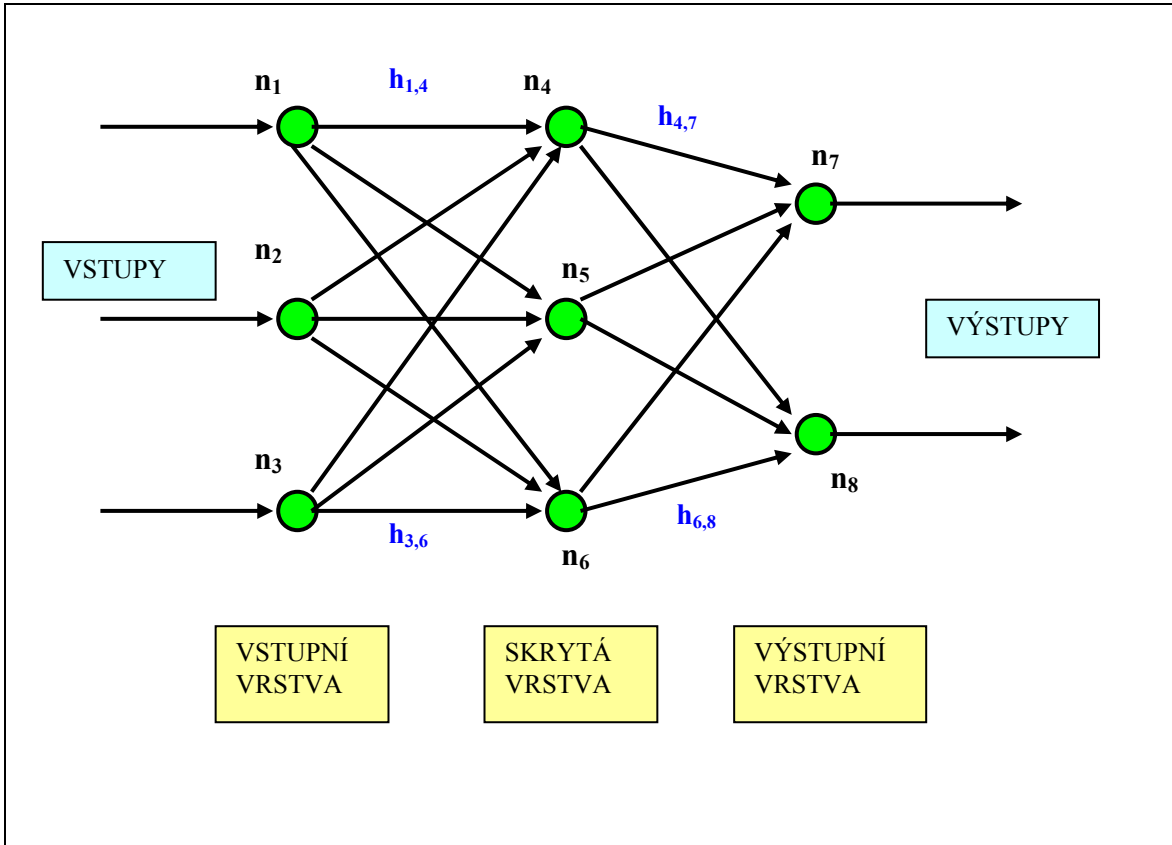
hranou h_{ij} . Platí, že dolní indexy znázorňují směr postupu signálu $O_{i,j}$ hranami $h_{i,j}$ z i -tého neuronu n_i do j -tých neuronů n_j , jejichž počáteční číslo značí r a koncové s . Necht' $W_{i,j}$ a $W_{j,k}$ jsou synoptické váhy, kterými je přenásobena velikost signálu $O_{i,j}$ a $O_{j,k}$, a to vždy na konci příslušné spojnice. Pro signál O_j (stav neuronu) vystupující z j -tého neuronu platí:



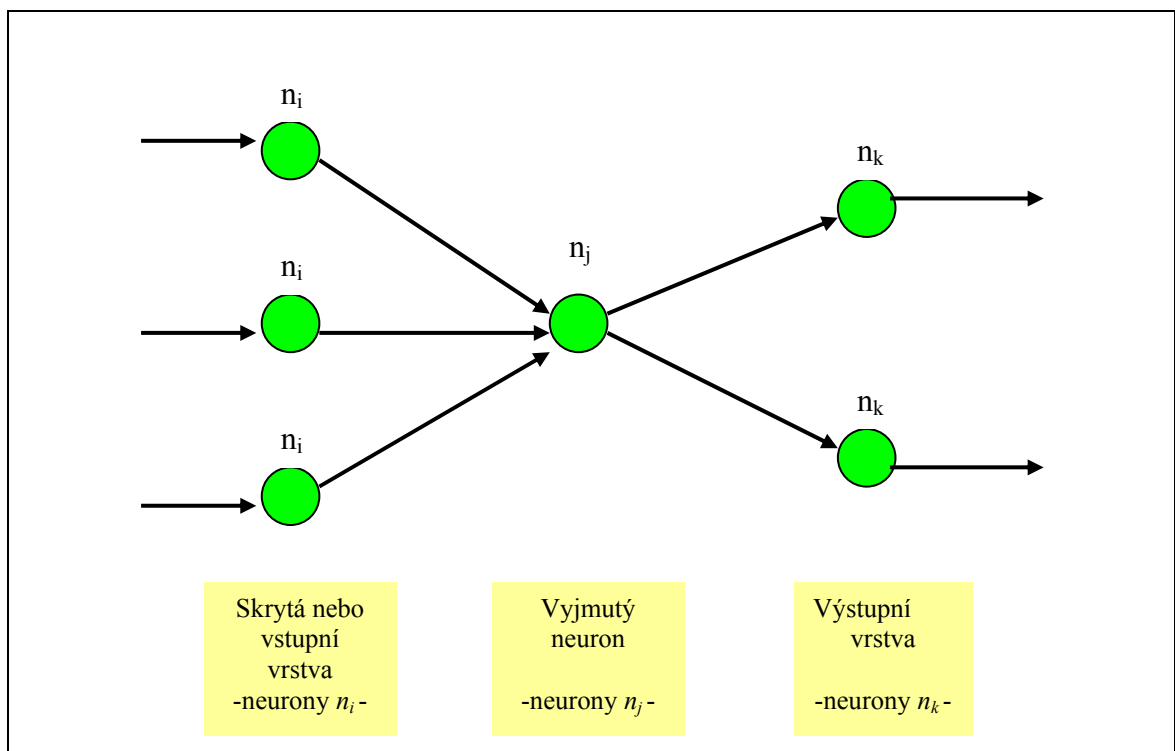
Obr.1. Biologický neuron



Obr.2. Umělý neuron



Obr.3. Umělá neuronová síť



Obr.4. Neuron n_j vyjmutý ze skryté vrstvy

$$O_j = TF_j \left(\sum_{i=u}^v W_{i,j} \cdot O_{i,j} - \theta_j \right), \quad (1)$$

kde $TF_j(\cdot)$ značí přenosovou funkci j-tého neuronu a θ_j značí tzv. práh j-tého neuronu. Nazýváme v dalším textu

$$A_j = \sum_{i=u}^v W_{i,j} \cdot O_{i,j} - \theta_j \quad (2)$$

aktivační funkcí (potenciálem) neuronu n_j . Pokud je aktivační funkce kladná, dochází ke vzplanutí neuronu (neuron je excitován) a propustí signál dále. Pokud jsou váhy kladné, přispívají ke vzplanutí, pokud jsou záporné, působí proti vzplanutí. Je zřejmé, že ke vzplanutí může dojít až když $\sum W_{i,j} \cdot O_{i,j}$ překročí mezní hodnotu - práh θ_j , tj., když platí

$$\sum_{i=u}^v W_{i,j} \cdot O_{i,j} > \theta_j \quad (3)$$

Z formálních důvodů je práh někdy označován jako nultý vstup do j-tého neuronu s hodnotou signálu -1 a s vahou θ_j .

Umělá NS nemůže pracovat spojitě. Umožňuje pouze pro dané hodnoty vstupních signálů vstupujících do vstupních neuronů poskytnout odpovídající hodnoty signálů výstupních. Aby byla schopna plnit tuto funkci, je třeba znát minimálně hodnoty vah $W_{i,j}$, parametry přenosových funkcí (pokud mají složitější tvar a tyto parametry obsahují) a hodnoty prahů, při kterých dochází ke vzplanutí neuronů. Při složitějších typech neuronových sítí může být těchto neznámých veličin více. Smyslem učení (trénování) NS je najít hodnoty těchto veličin.

Podle toho, zda přenosová funkce je lineární nebo nelineární, je možno vytvořit modely lineárních nebo nelineárních neuronových sítí. V nejjednodušším případě je možno u lineárního modelu rovnici (1) přepsat do tvaru, ve kterém je přenosová funkce rovna aktivační funkci:

$$O_j = A_j = \sum_{i=u}^v W_{i,j} \cdot O_{i,j} - \theta_j. \quad (4)$$

Pokud jsou vrcholy a hrany grafu $G(N,H)$ uspořádány jako na obr.3 a signál tedy postupuje pouze jedním směrem - zleva doprava, mluvíme o jednosměrných NS (feedforward networks). Pokud signál vstupuje do neuronů současně i zprava doleva, nazývá se neuronová síť zpětnovazební (feedback networks). Podle autorů nebo uspořádání byla nazvána řada typických modelů: Hopfieldova, BAM, ART, Perceptron, Kohonenova atd.

2.2 Způsob učení (trénování)

Nechť je dána tréninková matice \mathbf{A} , ve které jsou do určitých sloupců zapsány hodnoty vstupních signálů a do zbývajících hodnoty výstupních signálů. Vždy jeden řádek odpovídá jednomu vztahu mezi vstupem a výstupem - tvoří jeden vzor. Schéma takovéto

matic je znázorněno v tab.1. Vstupní veličiny X_1 , X_2 , X_3 a X_4 , jsou zapsány do vstupních sloupců označených symbolem \downarrow , výstupní veličiny Y_1 a Y_2 jsou pak uvedeny ve sloupcích výstupních, označených symbolem \uparrow . Číslo uvedené ve sloupci i udává pořadí příslušného vzoru.

Tab.1. Schéma tréninkové matice

	\downarrow	\downarrow	\downarrow	\downarrow	\uparrow	\uparrow
I	X1	X2	X3	X4	Y1	Y2
1	0.4	12.7	5.1	26.5	6.8	0.3
2	0.8	15.6	3.8	21.7	3.3	0.2
3	0.6	11.1	4.3	29.6	4.4	0.5
.
.
N	0.3	8.5	3.7	18.9	5.1	0.4

V průběhu učení (trénování) vstupují postupně po řádcích do NS vstupní signály (tréninkové vzory). V závislosti na velikostech vah a prahů pak vystupují z výstupních neuronů hodnoty výstupních signálů. Postup se opakuje podle počtu řádků tréninkové matice. Zadané výstupní signály a NS vypočtené signály vykazují odchylku. Součet čtverců těchto odchylek vypočtený pro každý vzor zvlášť je chybou vzoru E_v . Součet chyb vypočtených ze všech vzorů je celková chyba E . V procesu trénování se hledají takové hodnoty vah, aby pro všechny řádky tréninkové množiny tyto odchylky nepřekročily povolenou toleranci.

Trénování NS současně pro všechny uvažované vzory představuje minimalizační problém, při kterém se minimalizuje celková chyba E , vypočtená ze všech vzorů. Úloha vede na optimalizaci, při které je vektorem neznámých vektor \mathbf{W} , jehož prvky tvoří neznámé váhy, resp. i parametry přenosových funkcí a hodnoty prahů. Úkolem je nalézt takovou hodnotu vektoru \mathbf{W} , při které všechny uvedené odchylky nebo předepsané procento odchylek (kritériem může být i součet čtverců odchylek, směrodatná odchylka, průměrná odchylka nebo koeficient determinace apod.) nepřekročí zadanou toleranci. Protože dokonce i malé NS mají stovky a tisíce spojnic, mluvíme o "minimalizaci skalárního pole na vektorovém prostoru se stovkami dimenzí". Pro řešení popsaného problému může být použita řada optimalizačních metod.

Nejužívanější metody, vhodné pro nalezení minima kritériální funkce, jsou gradientní metody. Metoda gradientního poklesu zahrnuje změnu proměnných s malým krokem změnou směrem dolů ve směru lokálního gradientu.

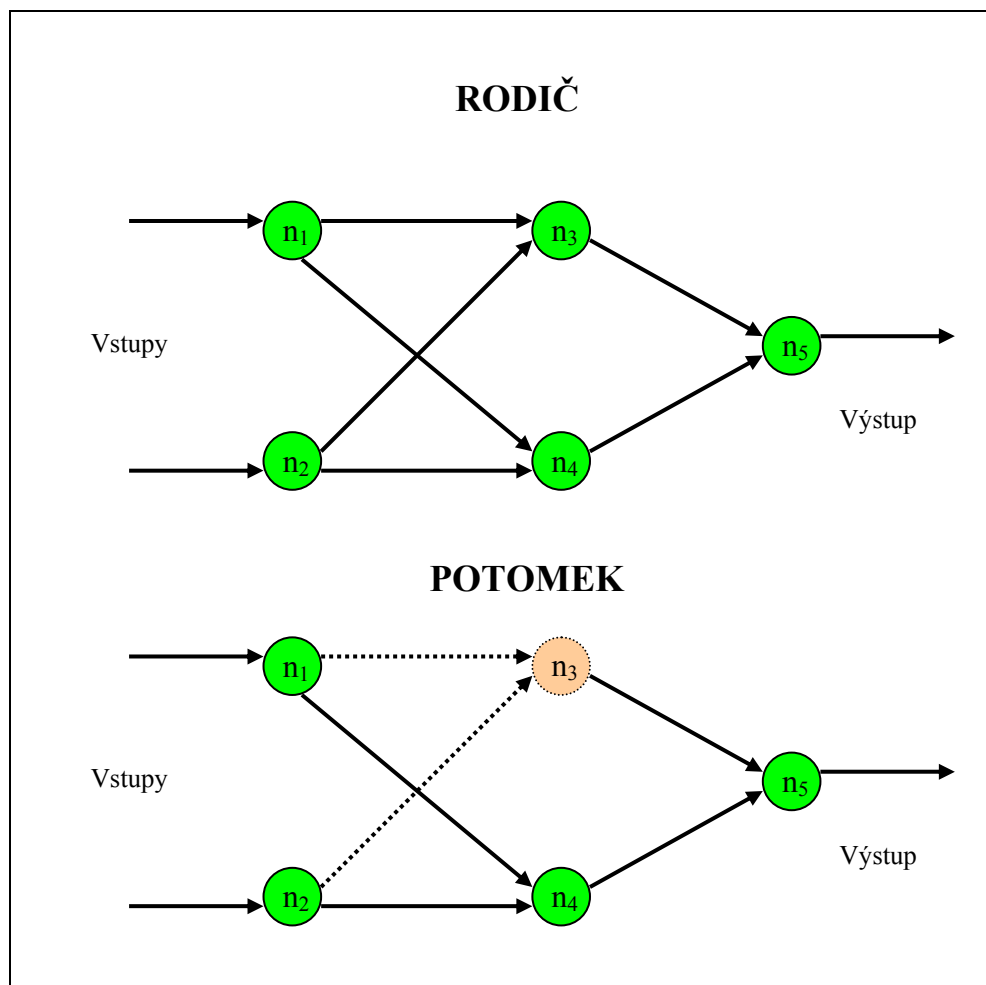
V oblasti jednosměrných NS se velmi často používá metoda *zpětného šíření* (back-propagation) (Sejnowski, Rosenberg, 1988), kterou je možno přiřadit mezi gradientní metody. Podrobný popis metody uvádí např. Lawrencová [13] nebo Šíma a Neruda [44]. Při jejím užití se síť postupně učí pomocí korekce vah v závislosti na odchylce mezi zadanou a vypočtenou hodnotou výstupních signálů ve výstupních neuronech neuronové sítě. Korekce signálů (vah) pak probíhá sítí zpětně od výstupní vrstvy neuronů po vrstvu vstupní - podle toho získala název.

Proces trénování sestává z postupně opakovaných výpočtů výstupů z NS při daných vahách pro každý vzor, kdy signály postupují od vstupní do výstupní vrstvy neuronů (forwards) a je vypočtena chyba vzoru E_v . Následně pak probíhá zpětným směrem (backward) postupný výpočet oprav jednotlivých vah. Je zřejmé, že algoritmus nemůže implementovat celkový (opravdový) gradientní pokles chyby E . Jednotlivé váhy jsou měněny po každé postupné implementaci příslušného vzoru. Praxe však ukazuje, že metoda je funkční v naprosté většině testovaných příkladů.

2.3 Užití genetických algoritmů pro trénování neuronových sítí

Nejnovější verze simulátorů neuronových sítí umožňují trénování pomocí genetických algoritmů. Např. BrainMaker Professional [4] tuto možnost poskytuje pomocí dodatečně zakoupené rutiny - GTO (Genetic Training Option). Algoritmus, který řídí proces učení, vychází ze dvou výše popsaných operací - mutace a křížení. Aplikujeme-li genetické algoritmy na neuronové sítě, je možno nahlížet na spojnice (hrany) mezi neurony a jejich váhy jako na DNA řetězce v živých organizmech.

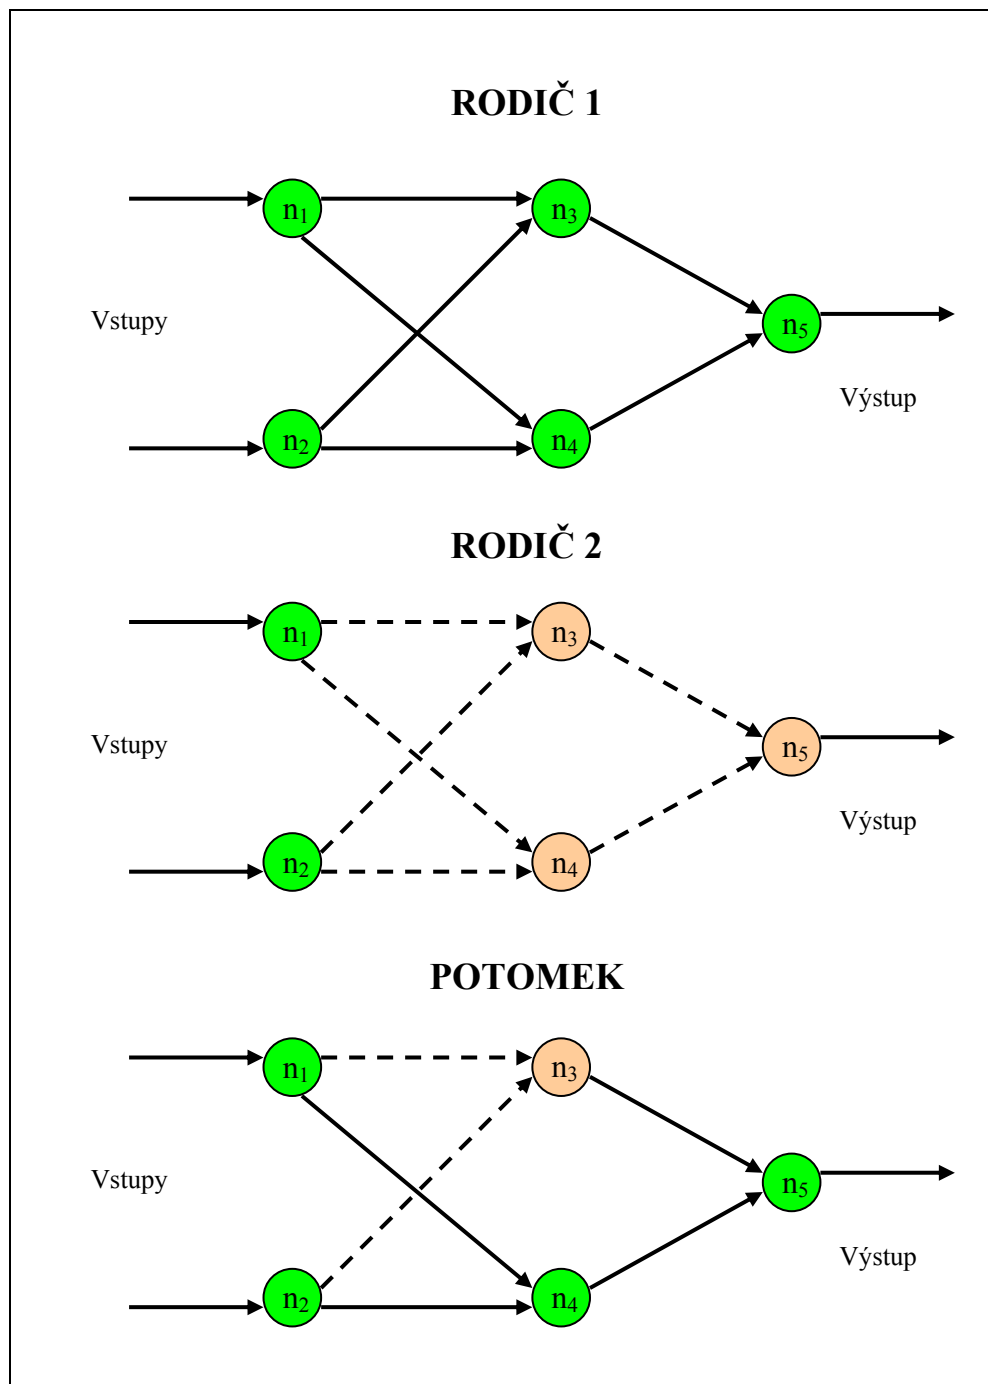
Mutace vyžaduje pouze jednoho rodiče. Během ní je náhodné procento neuronů změněno modifikací vah ve hranách, které je spojují. Frekvence změn a velikost jejich změny je zadána uživatelem, resp. se mohou využít přednastavené hodnoty. Obr.5 znázorňuje neuronovou síť rodiče a neuronovou síť potomka. Na tomto příkladě skrytý neuron n_3 mutoval z rodiče na potomka. Váhy u příslušných hran, které směřují do tohoto neuronu, se změnily.



Obr.5. Schéma mutace neuronové sítě

Křížení vyžaduje dva rodiče. V neuronové síti je možno jej implementovat tak, že ze dvou neuronových sítí - rodičů vytváříme třetí - potomka. Na obr.6 je znázorněno křížení dvou neuronových sítí. Potomek obdržel skrytý neuron n_3 od druhého rodiče a první skrytý neuron od prvního rodiče (rozumí se váhy u příslušných hran).

Po provedené mutaci nebo křížení je testován potomek - nová neuronová síť. Pokud vykazuje potomek lepší vlastnosti než jeden nebo oba rodiče, nová neuronová síť nahradí rodiče nebo jednoho z rodičů. Přenáší tak informace na budoucí generace neuronových sítí.



Obr.6. Schema křížení neuronových sítí

GTO umožňuje kombinovat mutace a křížení. Protože mutace a křížení jsou aplikovány na váhy hran v neuronové síti, je třeba při spuštění GTO vycházet z již natrénované nebo částečně natrénované neuronové sítě, tj. mít dostatečný zásobník neuronových sítí - rodičů.

2.4 Topologie neuronových sítí

Jedním ze zásadních problémů při konstrukci neuronové sítě je určení její topologie. Především je nutno zvážit k jakému účelu bude neuronová síť sloužit, jaké budeme zadávat veličiny vstupní a co bude výstupem. Je třeba dobře promyslet, které veličiny mohou mít vliv na výstup neuronové sítě. V této fázi je třeba zapomenout na různé procedury, pravidla nebo vzorce. Je třeba uvažovat o veličinách a jejich možných vztazích jako takových. Různorodost vstupních dat s vazbou na veličinu výstupní zvyšuje šanci nalézt významnou korelaci mezi veličinami. Dále je třeba si uvědomit, zda budeme mít k dispozici dostatek vzorů obsahujících veličiny vybrané jako vstupy a výstup neuronové sítě. Je zřejmé, že při určení počtu neuronů ve vstupní a výstupní vrstvě se po provedení těchto úvah nevyskytnou žádné větší problémy. Jejich počet je dán počtem vstupních a výstupních veličin. Dimenze vstupní a výstupní vrstvy je tedy dána charakterem řešené úlohy. Problémy však nastávají při určení *počtu skrytých vrstev neuronů a počtu neuronů v těchto vrstvách*. Problém volby počtu skrytých vrstev a skrytých neuronů je záležitostí každého řešitele.

2.5 Standardizace dat

Standardizací vstupních dat rozumíme transformaci, která tato data převede na požadované intervaly. Tyto intervaly mohou být různé a mohou se odlišovat podle toho, zda se jedná o vstupy nebo výstupy neuronové sítě. Pak mluvíme o standardizaci vstupních nebo výstupních dat. Transformaci je nutno provést ještě před započítím trénování neuronové sítě a v řadě případů je podmínkou úspěšného trénování [13].

Například při použití *sigmoidy* jako nelineární přenosové funkce, jejíž výstupy leží v intervalu $(0,1)$, je transformace výstupních dat nutností a plyne z definice této funkce. Po natrénování neuronové sítě a provedeném výpočtu pro nová vstupní data jsou pak výstupy neuronové sítě inverzní transformací převedeny na interval skutečných hodnot výstupních dat.

2.6 Simulátory neuronových sítí

S umělými neuronovými sítěmi se můžeme setkat v hardwarovém nebo softwarovém provedení. První, které využívá speciální hardwarové karty do PC, nahrazuje neurony a jejich spojnice pomocí mikroelektronických obvodů a paměťových čipů přímo na kartě. Toto řešení vyniká značnou rychlostí i v procesu učení a je běžnému uživateli z mnoha důvodů téměř nedostupné. Svoje využití nachází zejména ve speciálním výzkumu a ve vojenské technice.

Druhé provedení je založeno na softwarové simulaci neuronových sítí. Sestavené algoritmy je možno provozovat na běžném PC. Vyznačuje se značnou spotřebou strojového času v procesu učení neuronových sítí. Při učení rozsáhlých neuronových sítí může i na běžných velmi výkonných PC spotřeba strojového času přesáhnout i několik dnů. Protože jsme však schopni sestavit a natrénovat neuronové sítě v předstihu - off line, je možné tento nedostatek ve většině případů pominout. Vlastní výpočet natrénované sítě je však velice rychlý a pohybuje se obvykle v oblast milisekund a mikrosekund.

Softwarových produktů byla pro tento účel ve světě vyvinuta celá řada s větší či menší úspěšností. Z dostupného komerčního software uvádím především program BrainMaker Professional, který byl využit při řešení následujících aplikací. Je produktem společnosti California Scientific Software v USA. Ta má ve světě uznávané vedoucí postavení v oblasti prostředků vyvinutých pro simulaci neuronových sítí. Neuronové sítě, které umožňuje simulovat, jsou převážně jednosměrné vrstevnaté. Software umožňuje výběr z řady běžně užívaných přenosových funkcí. Pro trénování se užívá metoda backpropagation. Software sestává ze dvou částí. První část - *NetMaker* - je určena pro sestavení neuronové sítě. Data je v ní možno přímo zadávat pomocí speciálního editoru podobného známým tabulkovým procesorům. Druhou část software tvoří vlastní softwarový emulátor neuronových sítí - *BrainMaker*. V zásadě umožňuje dotvořit NS (určit počet skrytých neuronových vrstev

a v nich počet neuronů, podmínky a přesnost trénování apod.), natrénovat NS, provést testování její přesnosti a následně spustit pro vstupní soubor výpočet. Novinkou od verze 3.1 je možnost aplikace genetických algoritmů Genetic Training Option (GTO) pro trénování a mřížkové optimalizační rutiny pro automatické dotvoření topologie neuronových sítí.

V současnosti existuje řada dalších softwarových simulátorů neuronových sítí, např.:

- Software ARTINT ver.2.0 byl vyvinut společnostmi Mentar a EGÚ v naší republice. Je možno jej považovat za první komerční software u nás [2].
- MATLAB [14] je integrované prostředí pro vědeckotechnické výpočty, které obsahuje vlastní programovací jazyk, vestavěné algoritmy, různé analýzy a prezentace dat, grafy, numerické výpočty a simulace. Toto prostředí doplněné knihovnou Neural Networks Toolbox představuje velmi flexibilní prostředí pro simulaci většiny známých neuronových sítí a používá řadu učících metod včetně základního algoritmu backpropagation.

3 Aplikace neuronových sítí

Na kolekci úloh jsou v práci naznačeny možnosti využití neuronových sítí pro řešení vybraných problémů z aplikované hydrologie. Neuronové sítě v nich byly využity ve funkcích:

- **Analyzátoru** naměřených dat, kdy umožňují nalézt vztah mezi řadami hydrologických veličin získaných měřeními. Vztahy mezi veličinami však není možno popsat analyticky, protože nejsou známé, nebo jsou příliš složité. Do této kategorie úloh patří analýza kvantitativních a kvalitativních dat vodního zdroje Březová, popsána v kap. 6.1 habilitační práce (HP) a modelování povodňových průtoků v systému měrných stanic řeky Jizery s využitím neuronových sítí, popsána v kap. 6.3 HP.
- **Aproximátoru** simulačního modelu, kdy demonstrují možnost vytvoření tréninkové matice pomocí vstupů a výstupů simulačního modelu. Natrénovaná neuronová síť pak může simulační model v určitých případech nahradit. Naznačený postup je použit při užití neuronových sítí pro předpovídání kulminačních průtoků v povodí Ostravice v kap. 6.2.1 HP. a při předpovídání hydrogramů povodňových vln v povodí Morávky v kap. 6.2.2 HP. Jako aproximátoru matice cílového chování je naznačeno využití neuronové sítě v kap. 6.6.2.1 HP při operativním řízení odtoku vody z dolní části kanalizační sítě v Kodani. V kap. 6.6.2.2 HP je pak naznačena možnost pro využití neuronové sítě ve funkci neuro-regulátoru, kdy při řízení odtoku vody z velkých povodí soustavou nádrží může nahradit aplikovaný fuzzy-regulátor.
- **Prediktoru** průtoků v systému měrných stanic v povodí řeky Svratky - viz. kap. 6.4.1 HP a v dolní části Dyjsko-svratecké vodohospodářské soustavy - viz. kap. 6.4.2 HP, prediktoru srážkoodtokového procesu v povodí Jihlavy - viz. kap. 6.5 HP a prediktoru stupně ohrožení v povodí s nádržemi - viz. kap. 6.6.2.3 HP.

V následujícím textu jsou uvedeny ukázky některých z uvedených úloh a v nich dosažených výsledků.

3.1 Neuronové sítě ve funkci aproximátoru simulačního modelu

V kapitole jsou popsány dvě jednoduché aplikace neuronových sítí. Jejich smyslem bylo ukázat, s jakou přesností neuronová síť, natrénovaná z výsledků simulačního modelu srážkoodtokového procesu v povodí, může pro jiná vstupní data tento simulační model nahradit. Jedná se tedy o aproximaci silně nelineárních vstupně-výstupních vztahů, které srážkoodtokový proces popisují.

První aplikace se omezuje na určení pouze kulminačního průtoku a objemu povodně predikovaného hydrogramu odtoku vody z povodí. Druhá je zaměřena na predikci hydrogramu povodňové vlny.

3.1.1 Užití neuronových sítí pro předpovídání kulminačních průtoků

Na příkladu předpovědi kulminačních průtoků a objemů povodní nad dlouhodobým průměrným průtokem v povodí toku Ostravice se závěrovým profilem Šance (bez nádrže) bylo provedeno srovnání přesnosti dosažených výsledků za použití software BrainMaker 3.1-GTO a ARTINT 2.0 [32]. Pro vytvoření vzorů tréninkové matice **A** byly použity výstupy ze srážkoodtokového distribučního modelu HYDROG [27]. Rovněž vstupní matice **B** byla vytvořena pomocí tohoto modelu a byly srovnány kulminační průtoky a objemy povodňových vln simulované a předpovězené pomocí NS.

Schematizace uvažované lokality i kalibrace modelu byly převzaty z Povodí Odry státní podnik. Řešení ve všech případech předpokládalo nerovnoměrné ustálené proudění vody v říční síti před příchodem příčné přívalové srážky. Model HYDROG vyžaduje pro jeho výpočet zadání průtoku v závěrovém profilu. Tato hodnota byla pro všechny simulované srážkoodtokové epizody zadána hodnotou dlouhodobého průměrného průtoku $Q_a = 3,11 \text{ m}^3 \cdot \text{s}^{-1}$.

Výsledky zjednodušeného statistického vyhodnocení přesnosti, s jakou NS nahradily simulované hodnoty programem HYDROG, jsou následující – tab.2a, 2b:

Tab.2.a. Kulminační průtoky

	ARTINT	BrainMaker
Průměrná odchylka [$\text{m}^3 \cdot \text{s}^{-1}$]	2.557	3.117
Směrodatná chyba odhadu [$\text{m}^3 \cdot \text{s}^{-1}$]	2.778	4.659
Koeficient determinace	0.998	0.996

Tab.2.b. Objemy povodní nad $Q_a = 3.11 \text{ m}^3 \cdot \text{s}^{-1}$


	ARTINT	BrainMaker
Průměrná odchylka [mil. m^3]	0.040	0.047
Směrodatná chyba odhadu [mil. m^3]	0.042	0.067
Koeficient determinace	0.998	0.996

3.1.2 Užití neuronových sítí pro předpovídání hydrogramů povodňových vln

V úloze byl program HYDROG opět použit pro namodelování spektra srážkoodtokových epizod nutných pro sestavení tréninkové matice neuronové sítě. Ta pak sloužila pro predikci průběhu hydrogramu povodňové vlny.

Uvedený postup byl aplikován na povodí horního toku řeky Morávky se závěrovým profilem Morávka/hráz [34]. Vypočtené průběhy odtoků neuronovou sítí (pro mezilehlé vstupy oproti vstupům použitým v tréninkové matici) byly porovnány s odpovídajícími hodnotami průtoků získanými simulací programem HYDROG.

Příklad srovnání dosažených výsledků je uveden na obr.7, kde je průběh hydrogramů odtoku linearizován. Ukázka znázorněného hydrogramu dokumentuje velmi dobrou shodu obou průběhů průtoku. V zásadě reprezentuje téměř celou oblast srovnávacích výpočtů.



Obr.7. Srovnání hydrogramů $\tau=65\text{min}$, $i=20\text{mm.h}^{-1}$, $H_S=15\text{mm}$

3.2 Modelování povodňových průtoků v systému stanic s využitím neuronových sítí

Pohyb vody v korytě popisují v oblasti jednorozměrného proudění stavové veličiny, např. průtok $Q(x,t)$ a průtočná plocha $A(x,t)$. Proměnná x zde značí směr proudění a t čas. Hodnoty těchto veličin, vyčíslené ve zvoleném časovém intervalu, jsou jednoznačně určeny svými počátečními a okrajovými podmínkami, tj. $Q(x,0)$ a $A(x,0)$, resp. $Q(0,t)$ a $A(0,t)$.

V korytě může nastat ustálený nebo neustálený stav proudění. Ustálený stav proudění chápeme v teorii výpočetní hydrauliky [1] jako mezní stav neustáleného proudění, ke kterému dojde při udržování okrajových podmínek na konstantní úrovni. K rovnovážnému stavu dojde po uplynutí doby potřebné pro propagaci poruchy podél toku (v tomto případě chápeme poruchy jako časové změny v okrajových podmínkách, které byly původně konstantní). Dojde-li k další poruše, proces se opakuje. Období mezi dvěma rovnovážnými stavy se vyznačuje přechodovými jevy, které lze popsat průběhem stavových veličin $Q(x,t)$, $A(x,t)$. Modelování přechodových jevů v říční síti představuje dynamické chování systému. Jejich hydraulickým řešením se zabývá rozsáhlá literatura z oboru hydrauliky otevřených koryt [1,5] a další.

Zcela jiný metodický přístup k odhadu průtoků v dolním profilu daného systému nabízejí umělé neuronové sítě. Navržené metodické postupy výrazně zjednodušují řešení tím, že nevyžadují popis proudění pomocí $Q(x,t)$ a $A(x,t)$, ale uvažují pouze hodnoty průtoků ve vstupních a výstupních profilech říční sítě. Hodnoty spojitého průběhu průtoků v těchto profilech se přitom vzorkují s pevným časovým krokem (v řešeném příkladu byla zvolena jedna hodina). Při řešení nebyl uvažován vliv srážek, teploty, výparu a dalších klimatických činitelů.

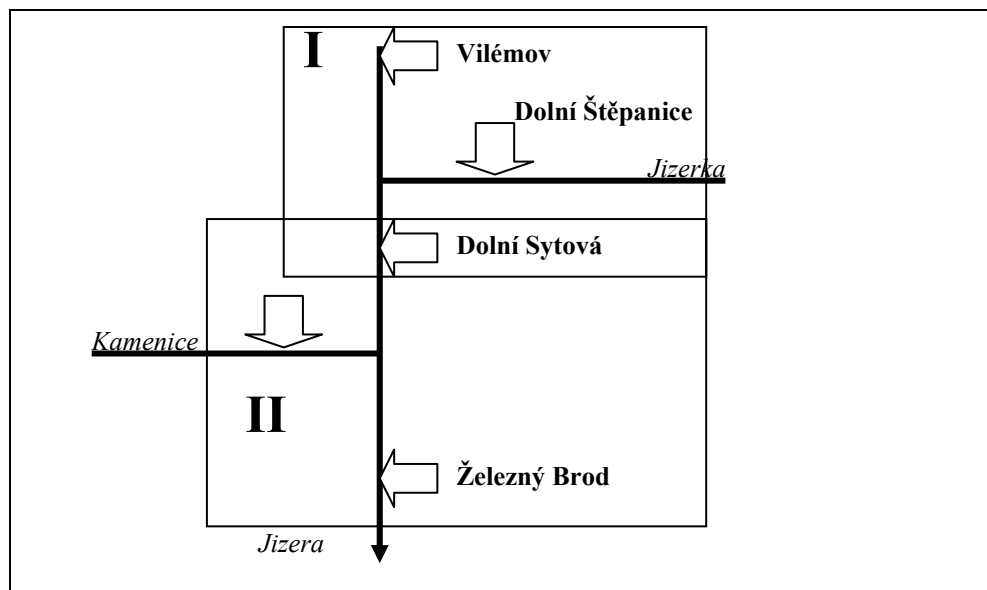
Zájmovým povodím, na kterém bylo provedeno testování, bylo povodí řeky Jizery [7,30]. Řešení bylo provedeno pro dva subsystémy - obr.8, tab.3.

- **Subsystém I** má dva horní vstupní měrné profily *Vilémov* na řece Jizeře a *Dolní Štěpanice* na přítoku Jizerka a dolní výstupní profil *Dolní Sytová* na řece Jizeře.

- **Subsystém II** má dva horní vstupní měrné profily *Dolní Sytová* na řece Jizeře a *Bohuňovsko* na řece Kamenici a dolní výstupní profil *Železný Brod* na řece Jizeře.

Tab.3. Základní informace o řešených subsystémech


Subsystém	Vzdálenost mezi horním a dolním profilem (km)	Plocha mezipovodí (km ²)	Vstupní hydrogram na přítoku z mezipovodí	Počet uvažovaných povodňových vln
I	17.40	175.11	ano	21
II	20.76	469.62	ano	37



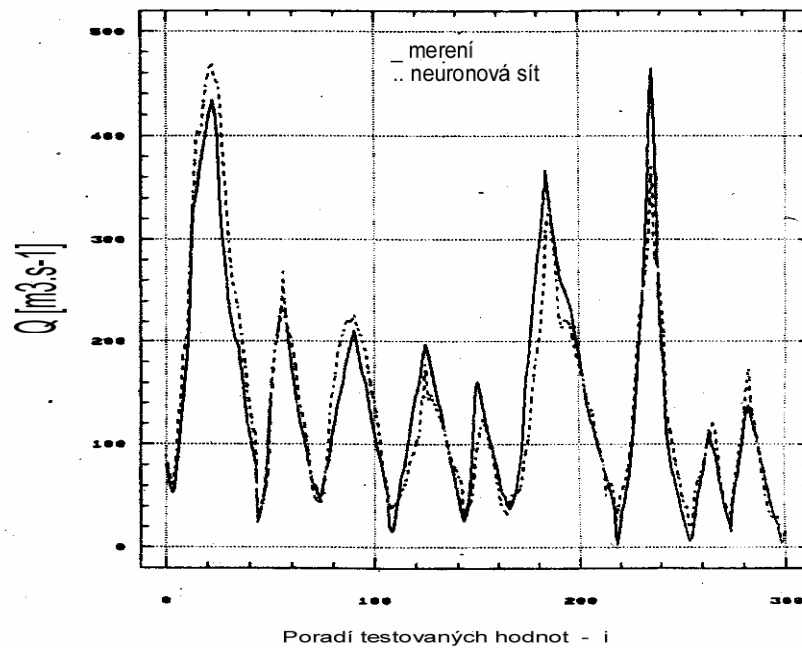
Obr.8. Schéma lokality

Navržený postup pro aplikaci neuronových sítí byl pro oba subsystémy ověřen následujícím postupem. Použité hydrogramy povodňových vln, popsané posloupností okamžitých průtoků s hodinovým krokem, byl vzájemně propojeny a byla z nich sestavena tréninková matice. Posloupnost řádků v tréninkové matici, popisující vždy jeden průchod povodňové vlny, byla z tréninkové matice vyjmuta a neuronová síť byla natrénována na zbývající řádky matice. Po jejím natrénování byla posloupnost vyjmutých řádků použita jako matice vstupní. Pro ni byl proveden výpočet s použitím natrénované neuronové sítě. Původní hodnoty průtoků v závěrovém profilu a nové vypočtené hodnoty těchto průtoků pomocí neuronové sítě byly využity pro posouzení kvality modelu. Popsaný postup byl postupně opakován pro všechny průběhy povodňových vln a oba subsystémy I a II. Svoji logikou odpovídá stavu v praxi, kdy jsme schopni ze známých průběhů povodní sestavit a natrénovat neuronovou síť. Při průchodu nové povodně pak je možno ze současných a předchozích hodnot průtoků v horních profilech subsystému odhadnout hodnoty průtoků v profilu dolním.

Ukázka grafického znázornění části průběhů měřených a vypočtených průtoků pro subsystém I je uvedena na obr.9 a pro subsystém II na obr.10. Jednotlivé povodňové vlny jsou pro jednoduchost interpretace spojeny postupně za sebe. Na obrázcích není respektován přesný časový posun okamžitých hodinových průtoků. Na ose úseček je znázorněno pouze jejich pořadí.



Obr.9. Měřené a vypočtené průtoky v profilu Dolní Sytová (subsystém I)



Obr.10. Měřené a vypočtené průtoky v profilu Železný Brod (subsystém II)

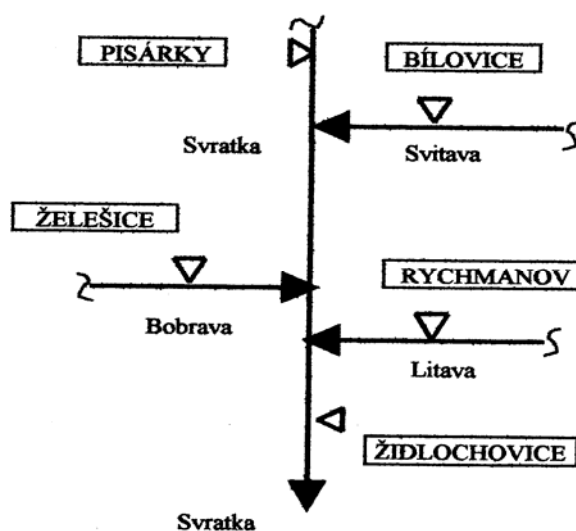
Tab.4. Jednoduché statistické zhodnocení vypočtených průběhů průtoků

	<i>Subsystém I</i>	<i>Subsystém II</i>
Koeficient determinace	0.950	0.891
Směrodatná chyba odhadu [m^3s^{-1}]	15.98	34.55
Průměrná abs. odchylka [m^3s^{-1}]	11.48	28.23

3.3 Předpověď průtoků v systému měrných stanic

Je zřejmé, že neuronové sítě sestavené způsobem popsaným v předchozí kapitole mohou sloužit pouze pro odhad průběhů hydrogramů povodňových vln v dolních profilech uvažovaných subsystémů. Mohou tedy být použity například pro rekonstrukci hydrogramů povodňových vln v systému stanic, když v některé chybí měření, filtraci průtoků, apod. Neuronové sítě, použité tímto způsobem poskytují informaci pouze o velikosti průtoků v uvažovaných profilech, nikoliv o čase, ve kterém tyto průtoky nastanou, a době dotoku z profilu do profilu. Pro potřeby varovných systémů, resp. operativní řízení průtoků v rámci vodohospodářských soustav za průchodu povodní, jsou však tyto údaje nezastupitelné. V dalším textu jsou naznačeny některé z možných způsobů využití neuronových sítí pro předpovídání průtoků.

Ověřené postupy, uplatněné v povodí řeky Jizery, byly rozšířeny a aplikovány pro uvedený účel na subsystém stanic v dolní části povodí řeky Svratky [16]. Schéma uvažovaného subsystému je znázorněno na obr.11. Vstupní profily uvažovaného subsystému tvoří měrné profily Pisárky na toku Svratka, Bílovice na toku Svitava a Rychmanov na toku Litava. Výstupním profilem je profil Židlochovice na toku Svratka. Profily Pisárky a Židlochovice jsou od sebe vzdáleny po toku cca 21 km, profily Rychmanov a Židlochovice cca 14 km a profily Bílovice a Židlochovice cca 27 km. Plocha uvažovaného mezipovodí řeky Svratky činí 572 km². Cílem bylo ověření možnosti užití neuronových sítí pro vydávání operativních předpovědí průtoků vody dolním profilem uvažovaného subsystému na 2, 4 a 6 hodin dopředu ze znalosti okamžitých a minulých průtoků v horních profilech a průtoků vody v dolním profilu.



Obr.11. Schéma uvažovaného subsystému povodí Svratky

Vlastní řešení se zabývalo pouze vztahy mezi průtoky, které jsou v dolní části povodí řeky Svratky rozhodující. Vstupem pro řešení byly opět synchronní řady okamžitých průtoků v měrných profilech toků, odvozené ze vzorkování stavů hladin vody s hodinovým krokem. Řešení bylo provedeno pro epizody uvedené v tab.5.

Tab.5. Řešené epizody

Epizoda	E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11	E12	E13
Začátek	16.3. 1970	15.5. 1972	10.7. 1974	5.12. 1974	11.1. 1976	2.3.5. 1979	14.7 1980	6.4. 1981	16.5. 1985	4.8. 1985	4.6. 1986	15.3. 1987	5.5. 1987
Trvání h]	628	254	84	191	191	228	167	312	299	315	104	455	154


Z použitých hydrogramů byly ponechány pouze výrazně vzestupné a sestupné větve. Dále byly vynechány oblasti nízkých hodnot průtoků před nástupem povodně a po jejím průchodu, které mohou způsobit „zašumění“ řešení.

Vstupem pro řešení byly opět synchronní řady okamžitých průtoků v horních a dolním měrném profilu. Tréninková matice byla vytvořena obdobným způsobem jako v předchozí úloze. Vzhledem k tomu, že byl model určen pro předpovídání průtoků, byly v této matici průtoky v horních profilech, uvedené ve vstupních sloupcích, na každém řádku posunuty v čase zpět minimálně o délku předpovědi v hodinách. Bylo možno využít pouze ty informace, které jsou v době vydávání předpovědi k dispozici.

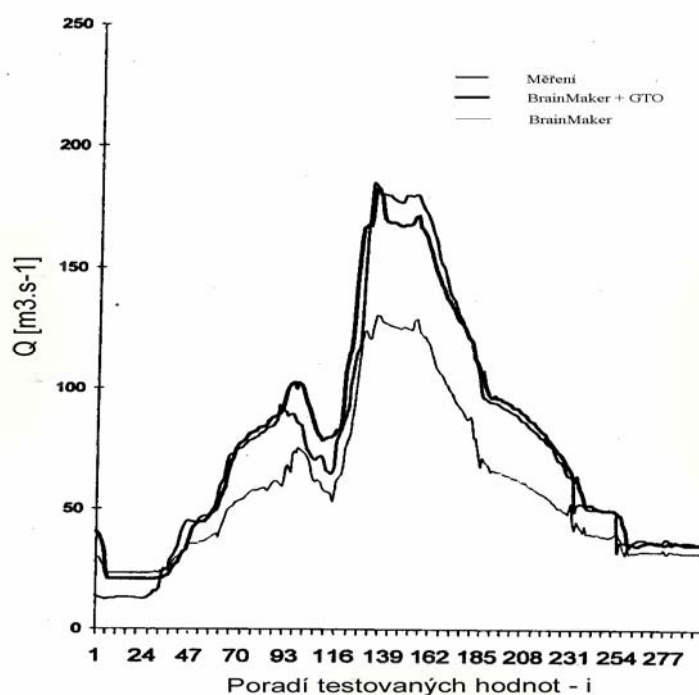
Ve snaze najít nejvhodnější topologii neuronové sítě bylo provedeno variantní řešení. Odlišnost jednotlivých variant spočívala v různém zadávání vstupních sloupců neuronové sítě (vstupní neurony). Byla testována varianta I, kdy vstupní sloupce neuronové sítě tvořily přítoky do vstupních profilů subsystému a průtoky vody v závěrovém profilu, obojí posunuté minimálně o příslušnou délku předpovědi průtoků v čase zpět. Dále byla testována varianta II, kdy vstupní sloupce, popisující minulý průtok v závěrovém profilu, zcela absentovaly. Na závěr pak byla testována extrémně zjednodušená varianta III [16], ve které byl pro sestavení neuronové sítě použit místo více vstupních neuronů, do nichž vstupují průtoky v jednotlivých vstupních profilech, jediný neuron, do kterého vstupuje součet průtoků ve vstupních profilech s přibližně stejnou dobou dotoku do závěrového profilu. U vstupních profilů, které mají výrazně jinou dobu dotoku, je třeba při přičítání k uvedené řadě zohlednit časový rozdíl mezi dotokem a respektovat při sčítání jejich časový posun. Tato úprava vstupních sloupců odpovídající tréninkové matice se dá velmi snadno zalgoritmizovat. Řešení pak bylo uvedeným postupem zjednodušeno na uvažování pouze dvou profilů, které byly analyzovány. Horní vstupní náhradní profil (je určen profilem, který leží nejbliže předpovědnímu profilu), ve kterém byla zadána řada součtů průtoků a dolní předpovědní profil s řadou měřených průtoků. V této variantě byly užity pro trénování neuronové sítě pro srovnání rovněž genetické algoritmy.

V praxi by pro vydání předpovědi jediné hodnoty průtoků v dolním profilu na 2, 4, resp. 6 hodin dopředu byla vstupní matice zredukována na jediný vstupní řádek.

Za velmi příznivé lze považovat výsledky ve variantě, která výrazně zjednodušila konstrukci neuronové sítě extrémní redukcí počtu vstupních neuronů. Bylo v ní dosaženo nejlepších výsledků. Pro názornost a vizuální posouzení dosažených výsledků jsou na obr.12 znázorněny průběhy měřených a předpovězených průtoků. Je patrná velmi dobrá shoda měřených a předpovězených hydrogramů povodňových vln. Větší rozdíly jsou pouze u dvou největších povodňových vln, kdy měla neuronová síť problémy s extrapolací. Nesporný je kladný přínos genetických algoritmů pro trénování neuronové sítě - viz. obr.13.




Obr.12. Měřené a předpovězené průtoky v extrémně zjednodušené variantě- předpověď na 4h



Obr.13. Srovnání předpovězených průtoků v epizodě z května 1985 - GTO

Postup použitý v předchozí úloze ve variantě III, umožňující výraznou redukci rozsahu neuronové sítě, byl rozšířen na dolní část rozsáhlé Dyjsko-svratecké vodohospodářské soustavy se závěrovým profilem nádrže Nové Mlýny (profil Dolní Věstonice) – obr.14 [33].



Obr.14. Schéma uvažované lokality s vyznačením stanic

Podkladem pro sestavení neuronové sítě byly opět synchronní řady okamžitých hodinových průtoků (dále jen průtoků) v profilech Rychmanov (Litava), Bílovice (Svratka), Pisárky (Svratka), odtok z nádrže Mostiště (Oslava), odtok z nádrže Mohelno (Jihlava), Moravský Krumlov (Rokytná), Božice (Jevišovka), odtok z nádrže Vranov (Dyje). Dále pak to byly řady přítoků do nádrží Nové Mlýny samostatně z řeky Svratky, Jihlavy a Dyje.


Z uvedeného je zřejmé, že se jedná o velmi složitý systém obsahující značný počet stanic. Počet vstupních profilů zredukován na tři náhradní profily. Vstupní profily v povodí řeky Svratky byly nahrazeny náhradním profilem Rychmanov, vstupní profily v povodí řeky Jihlavy byly nahrazeny náhradním profilem Moravský Krumlov a vstupní profily v povodí řeky Dyje byly nahrazeny náhradním profilem Božice.

Pro sestavení tréninkové matice byly použity řady průtoků ve výše citovaných profilech v epizodách ET1 až ET6 dle tab.6.


Tab.6. Vybrané epizody

Název	Začátek [h]	Trvání [h]
ET1 – 0780	14.7.80 v 0 ⁰⁰ h	330
ET2 – 0585	16.5.85 v 0 ⁰⁰ h	360
ET3 – 0885	4.8.85 v 0 ⁰⁰ h	470
ET4 – 0587	16.5.87 v 0 ⁰⁰ h	350
ET5 – 0891	1.8.91 v 0 ⁰⁰ h	300
ET6 – 0797	1.7.97 v 0 ⁰⁰ h	300

Postup testování byl analogický s předchozími úlohami. Byla testována přesnost předpovědi celkového přítoku do nádrží Nové Mlýny na délku předpovědi 2, 6 a 12 hodin. Pro srovnání jsou uvedeny výsledky řešení, kdy neuronová síť byla trénována obvyklým způsobem a výsledky, kdy byla trénována pomocí genetických algoritmů.



Obr.15. Předpovědi průtoků – BrainMaker



Obr.16. Předpovědi průtoků - BrainMaker + GTO

Na obr.15 a obr.16 jsou uvedeny dosažené výsledky, kdy předpovědi byly opakovaně vydávány vždy po hodině. Je z nich patrný značný vliv GTO na přesnost dosažených výsledků.

Použití neuronových sítí pro řešení daného problému prokázalo (přes značná zjednodušení problému) oprávněnost použití i u tak rozsáhlého a složitého systému, jaký dolní část Dyjsko-svratecké vodohospodářské soustavy představuje. Jednoznačně byla opět prokázána přednost užití genetických algoritmů pro trénování neuronových sítí. Jejich užití přispělo k výraznému zpřesnění předpovědí zejména v oblasti kulminačních průtoků.

3.4 Užití metod umělé inteligence při operativním řízení odtoku vody z povodí

Při použití metod umělé inteligence v rámci operativního řízení odtoku vody z povodí za povodňových situací, ať již se jedná o neuro-regulátory, fuzzy-regulátory, nebo různé učící se hybridní regulační systémy, je zásadní otázkou *stanovení průběhu řídicích veličin* v návaznosti na měnícím se stavu řízeného systému a případných dalších vstupních veličinách (poruchy). To platí zejména u dynamických systémů, které pracují s výrazným zpožděním. V našem případě se hledá závislost řídicích průtoků - alt.I [35] (resp. poloh regulačních uzávěrů - alt.II [42]) u jednotlivých nádrží na časově a prostorově se měnících srážkách nad povodím, průtoky vody v říční síti a plnění jednotlivých nádrží.

Všechny vstupní veličiny, které popisují aktuální stav systému včetně průběhů srážek minulých, předpovězených průběhů srážek budoucích a případné další veličiny nutné pro stanovení řídicích průtoků (poloh regulačních uzávěrů) vytváří prostor vstupů řešení.

U složitých vícerozměrných systémů, které povodí s více nádržemi a značným množstvím srážkoměrných stanic představuje, je prostor reálných vstupů řešení značně rozsáhlý a pro subjektivní zásahy do řešení často nepřehledný. Proto se nabízí určovat řídicí veličiny klasickými optimalizačními algoritmy. Kriteřiem optimalizace mohou být např. hodnoty kulminačních průtoků ve vybraných profilech říční sítě, které následně minimalizujeme. Z numerických experimentů vyplynulo, že řešené budoucí období, ve kterém analyzujeme stav systému, by nemělo mít delší trvání než trvání období předpovězených srážek ve srážkoměrných stanicích. Jinak dochází k výraznému poklesu přesnosti řešení.

Jakým způsobem je tedy možno využít metody umělé inteligence při operativním řízení odtoku vody z povodí za průchodu povodní? Nabízí se několik možností [18]:

A. Nahradit reálný spojitý prostor vstupů řešení diskretním a v diskretních bodech tohoto prostoru určit hodnoty řídicích veličin optimalizací. Polohy těchto diskretních bodů většinou vyplynou z typů řešených úloh a dostupnosti podkladů pro řešení. Samozřejmě je nutné, aby prostor vstupních veličin byl pokryt pokud možno rovnoměrně na přijatelné rozlišovací úrovni. Pro každý diskretní bod prostoru vstupů řešení jsou pak v předstihu výpočtem určeny hodnoty řídicích veličin. Takto vytvořené vzory příslušných veličin lze pak zapsat do vstupně-výstupní matice, která popisuje *cílové chování řízeného systému*. Matici je pak možno využít jako tréninkovou matici a následně z ní natrénovat neuronovou síť (nebo jakýkoliv učící se hybridní systém, apod.), která vztah mezi diskretními body prostoru vstupů řešení a příslušnými vypočtenými řídicími průtoky (resp. přímo polohami regulačních uzávěrů) aproximuje a pro konkrétní aktuální vstupy velice rychle stanoví odpovídající hodnoty řídicích veličin (resp. přímo polohy regulačních uzávěrů). Přínos tohoto postupu je tedy v *rychlosti řešení*, která je nezbytná pro operativní řízení u rychle se měnících stavů systému (malá a velmi malá povodí), aby proces vlastního řízení probíhal skutečně v reálném čase.

Popsaný přístup je možno aplikovat jen u malých povodí s jednou nebo více nádržemi, kde intenzitu srážky nad povodím je možno považovat za konstantní a prostor vstupních veličin tudíž méně složitý. Obdobou jsou i samostatně řešené dolních částí rozsáhlých povodí, kde povodně již převážně pouze procházejí (je zanedbán vliv srážek, apod.).

B. Neřešit předem relaci: diskretní body prostoru vstupů řešení - odpovídající řídicí veličiny (řídicí odtoky z nádrží), ale v každém časovém bodě, ve kterém měníme řídicí veličiny (řízení), provést následující. Na základě aktuálního stavu systému a odhadu budoucích přítoků (předpověď srážek), tj. v aktuálním diskretním bodě prostoru vstupů řešení, vypočítat hodnoty řídicích průtoků pomocí optimalizačního algoritmu. Zde je možno využít simulační model s optimalizovanou volbou parametrů, kde parametry jsou neznámé řídicí průtoky. Přitom součástí tohoto algoritmu je neuro-regulátor, resp. fuzzy-regulátor, který v závislosti na hodnotě řídicího průtoku (který je neznámou) v každém časovém kroku výpočtu přímo vyčísluje hodnoty nastavení poloh regulačních uzávěrů, a tím umožňuje výpočet odpovídajících řízených průtoků. Průběh akčního zásahu a řízených veličin se pak mění téměř spojitě. Uvedené vyčíslení je možno provést rovněž klasickým způsobem za pomoci známých vztahů z hydrauliky. Přednost užití např. fuzzy regulace je v *jednoduchosti řešení*, což každý, kdo sestavoval oba typy regulátorů pro stejný účel, jistě ocení. Podmínkou úspěchu je samozřejmě kvalitní software.

Je zřejmé, že každý výpočet pro tento postup může vyžadovat u velmi rozsáhlých povodí s velkým počtem nádrží značnou spotřebu strojového času. Zejména pokud součástí řídicích algoritmů je i spojitě modelování srážkoodtokových procesů. Protože však doby dotoků vody systémem (zpoždění) mají u středních a velkých povodí mnohem delší trvání, pojem reálného času zde má jinou dimenzi. V povodí Ostravice se při užití programu HYDROG potvrdilo, že je postačující měnit při operativním řízení za povodní polohy regulačních uzávěrů v rozpětí 1 až 3 hodin. Současná výpočetní technika (na úrovni PC) však umožnila tento čas podstatně zkrátit.

Zjednodušený popis konstrukce takového algoritmu (využívá fuzzy-regulátor) byl publikován např. v [28, 35]. V těchto aplikacích nejedná o přímou aplikaci neuronových sítí, ale o jiný nástroj z oblasti umělé inteligence. Fuzzy-regulátor však může být nahrazen neuro-regulátorem - postup je naznačen. Pro čitatele neobeznámeného s teorií fuzzy-logic obsahuje příloha č. 2 ve své druhé části základní informace týkající se fuzzy řízení, fuzzy-regulátorů, inferenčního mechanismu a defuzzifikace včetně příkladu inferenčního mechanismu.

C. Následující možnost je kombinací postupů popsaných v odstavcích A a B. Neuronová síť (resp. hybridní učící se systém) je sestavena a následně natrénována z předem provedených optimalizačních výpočtů řídicích veličin v diskretních bodech prostoru vstupů řešení pomocí optimalizačních algoritmů. Přitom součástí těchto algoritmů jsou např. fuzzy-regulátory, které v jednotlivých časových bodech řešení určují nastavení regulačních uzávěrů a následně umožňují vyčíslit průběh řízených odtoků. Při aktuálním stavu vstupních veličin pak natrénovaná neuronová síť rychle určí hodnoty řídicích průtoků (resp. přímo polohy regulačních uzávěrů). Ty jsou pak rychle zpracovány např. opět fuzzy regulátorem. Aplikace tohoto typu úlohy je popsána v [6] a v [18] v části věnované určení cílového chování systému optimalizací.

D. Pro stanovení požadovaných průběhů řídicích veličin je však možno použít i jiné postupy, např. respektovat názory expertů a ty pak využít při sestavení funkcí příslušnosti fuzzy-regulátoru, nebo určit ve vybraných profílech říční sítě mezní (kritické) hodnoty průtoků a pomocí specializovaného ladění nakalibrovat příslušný neuro-fuzzy regulátor. Postup je popsán rovněž v [6] a v [18] v části věnované specializovanému ladění regulátoru.

Některé z uvedených možností využití metod umělé inteligence byly více či méně ověřeny v následujících aplikacích. Týkají se simulace operativního řízení odtoku jak z malého urbanizovaného povodí, tak i z velkých povodí.

3.4.1 Ad. A - operativní řízení odtoku vody z dolní části kanalizační sítě v Kodani


Aplikace byla zařazena do přehledu proto, aby bylo dokumentováno v té době téměř prvotní řešení problematiky operativního řízení kvality vody v konkrétním

vodohospodářském systému. Smyslem uvedení je ukázat, jak složité nelineární průběhy řízené veličiny byla schopna neuronová síť aproximovat [37].

Úkolem bylo ověření možnosti sestavení řídicího algoritmu použitelného pro operativní řízení, který by minimalizoval hmotnostní tok konzervativní znečišťující látky (zjednodušení) do moře za extrémně velkých průtoků způsobených přívalovými srážkami nad povodím Kodaně.

Schéma řízeného subsystému, do kterého ústí všechny kmenové stoky s různým stupněm znečištění odpadních vod je uvedeno na obr.17. Systém obsahuje dvě kmenové stoky a celkem 6 retenčních nádrží. Délka kanálů mezi nádržemi se pohybovala v rozmezí několika desítek až stovek metrů. Celková délka jednotlivých uvažovaných kmenových stok byla přibližně 1,2 km. Vstupní profily, do kterých ústí přítoky vody do systému č.1 až č.7, jsou označeny kroužky.

Z nádrží č.1 až č.5 je voda čerpána do pravého kanálu, který ústí v nádrži č.6 a odsud je voda čerpána na čistírnu odpadních vod (ČOV). Při přeplnění nádrží odtéká voda přes přelivy do levého kanálu a odtud bez čištění do moře. Při chybném řízení systému je spodní 6. nádrž rychle přeplněna a velké množství nevyčištěné vody odtéká přes přeliv do moře.



Obr.17. Schéma řízeného kanalizačního subsystému.


∇ - nádrž, O - přítok, □ - odtok přes přeliv

Vlastní řešení bylo značně zjednodušeno. Kmenové stoky byly rozděleny na úseky o délce několika desítek metrů. Jejich průtočný profil byl nahrazen obdélníkovým profilem a proudění vody bylo řešeno jako neustálené proudění s volnou hladinou. Pro simulaci toku vody systémem byla použita kinematická vlnová aproximace (Roos), šíření znečištění v kanalizačním systému bylo řešeno pouze jako transportní problém a byly zanedbány vnitřní zdroje a propady. Základní rovnice nádrží byly řešeny metodou Runge-Kutta 4. řádu. Kriteriační funkce π byla zvolena tak, aby minimalizovala koncentraci znečišťující látky odtékající levým kanálem do moře bez vyčištění.

Řídicí algoritmus, sestavený pro řešení daného problému, byl sestaven na adaptivním principu. Požadovaná čerpaná množství vody (řídicí veličiny) byla počítána pro nádrže 1 až 5. Vlastní regulátor, který následně vyčísloval numerické hodnoty čerpaných odtoků (akční veličiny) včetně odtoků přes přelivy v závislosti na hodnotách řídicích odtoků a stavu nádrží, pak byl sestaven klasickým postupem za použití vztahů známých z hydrauliky.

Výpočet predikovaných průběhů přítoků vody do subsystému z příčných srážek byl proveden programem MOUSE [17]. Výpočet však byl vždy proveden jednorázově pro zadanou příčinnou srážku náhradní intenzity. Opakující se predikce přítoků vody do systému na budoucím období τ tak byly zcela přesné, což neodpovídá realitě. Rozhodovací časové body byly vzájemně posunuty o 20 min a čerpané množství vody ze všech nádrží bylo uvažováno na tomto intervalu jako konstantní (pokud nedošlo k vyprázdnění nádrže). Trvání budoucího období, pro které byla vydávána předpověď přítoků vody do subsystému, bylo testována v rozpětí 40 až 120 minut. Nelineární optimalizační problém výpočtu čerpaných množství vody byl řešen metodou Hooka-Jeevese. Úloha byla zprogramována jako DOS - aplikace v programovacím jazyku FORTRAN 77.


Testováním řídicího algoritmu bylo zjištěno, že poskytuje logické výsledky z hlediska nalezení účinných způsobů manipulace s odtoky vody z nádrží za nepříznivých hydrologických situací. Jeho značnou slabinou byla doba výpočtu čerpaných množství vody z nádrží. Problém spočíval v tom, že řešený subsystém byl malý a doba dotoku z horního vstupního profilu do závěrového profilu trvala pouze několik minut. Řízení přestávalo v takovýchto případech probíhat v reálném čase. Proto bylo rozhodnuto ověřit pro tento účel užití neuronových sítí. Z možných způsobů jejich aplikace byla využita *možnost popsána v předchozí podkapitole pod bodem A*. Tréninková matice neuronové sítě byla zkonstruována z výsledků simulací řízení provedených pomocí výše popsaného algoritmu. Výpočty byly provedeny pro srážkoodtokové epizody jejichž vstupní srážky byly určeny body č. 1, 2, 3, 4 a 5 na obr.18.



Obr.18. Sít' vstupních příčných srážek dané náhradní intenzity i a trvání τ

Znázorněný srovnávací výpočet byl proveden pro vloženou srážkoodtokovou epizodu učenou vstupní srážkou odpovídající bodu 6 na obr.18. Výpočet řízených odtoků (čerpaná množství vody z jednotlivých nádrží) byl proveden jednak optimalizací a pro srovnání byly řízené odtoky z nádrží v každém rozhodovacím časovém bodě vypočteny pomocí natrénované neuronové sítě. Příklad srovnání průběhů řízených odtoků vypočtených optimalizací a pomocí natrénované neuronové sítě je uvedeno na obr.19 pro řízené odtoky z nádrže č.1.

Vzhledem ke značně řídké síti příčných dešťů byly výsledky povzbudivé. Proto byla tato síť doplněna o body č.7, 8, 9, 10 a byla zkonstruována nová rozšířená neuronová síť. Srovnání výsledků řízení za použití optimalizace a výsledků nově rozšířené neuronové sítě je uvedeno rovněž na obr.19. Z něj je zřejmé, že rozdíly mezi průběhy řízených odtoků jsou nyní zanedbatelné. Pro všechny ostatní nádrže byly výsledky obdobné.



Obr.19. Srovnání simulovaných průběhů řízených odtoků z nádrží č. 1 stanovených pomocí: - nelineární optimalizace (—————), neuronové sítě (-.-.-.-.-) sestavené pro srážky - viz. body č. 1,2,3,4,5, a neuronové sítě (-.-.-.-) sestavené pro srážky - viz body č. 1,2,3,4,5,7,8,9,10

3.4.2 Ad. B - operativní řízení toku vody soustavou nádrží v dolní části velkého povodí

Aplikace je uvedena pro úplnost přehledu možných aplikací metod umělé inteligence v řídicích algoritmech. Očekávaný neuro-regulátor však nahrazuje fuzzy-regulátor. Aplikace se liší od předchozí značným rozsahem horní části povodí, ze které odtéká voda do systému a rozsahem regulovaného systému. Doby dotoku vody regulovaným systémem i pojem reálného času tu má zcela jinou dimenzi.

Řídicí algoritmus je založen na kombinaci nelineární optimalizace (určení řídicího průtoku – veličina řídicí) a fuzzy-regulace (určení dílčích řízených odtoků vody z nádrže - veličiny řízené). Na spolupráci kaskády nádrží Vranov a Znojmo, situovaných v dolní části rozsáhlého povodí řeky Dyje, je provedeno srovnání obou přístupů [36].

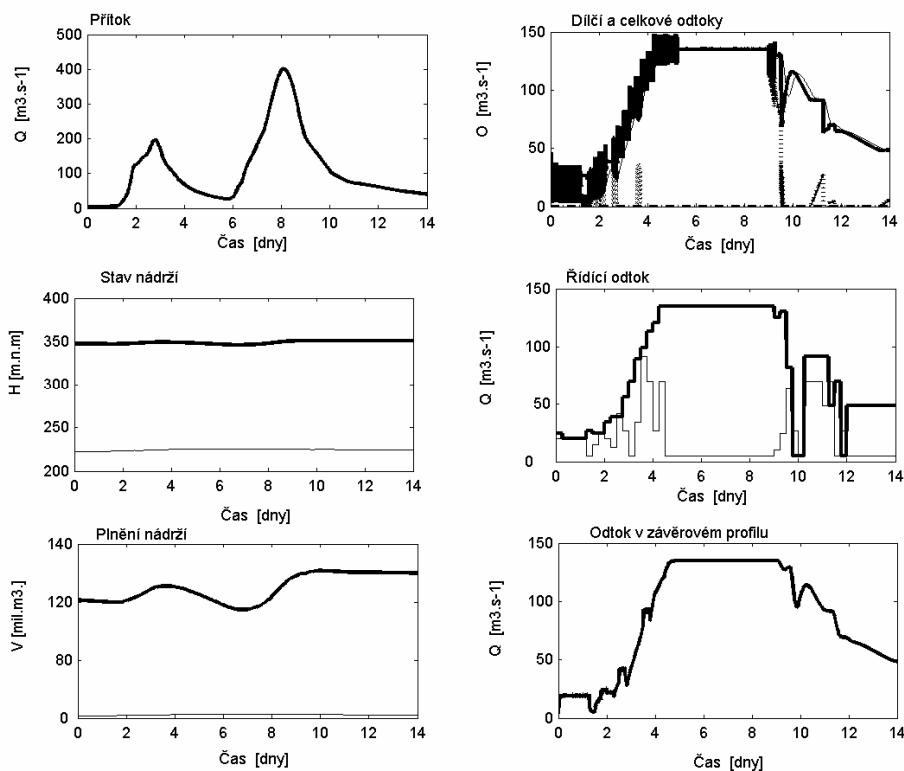
Popsaný řídicí algoritmus byl zprogramován v prostředí MATLAB [14] s využitím Fuzzy Logic Toolboxu pod názvem RIZS1. Program umožňuje simulovat operativní řízení odtoku v historickém období (předpovězené přítoky jsou nahrazeny skutečně naměřenými průběhy přítoků vody do systému). Umožňuje analyzovat vliv délky předpovědi přítoku vody do nádrže na dosažené efekty řízení apod. Vzhledem k tomu, že předpovědi přítoku vody do nádrže v reálném provozu nejsou přesné, je zřejmě určité nadhodnocení dosažených efektů.

Program byl použit pro simulaci operativního řízení toku vody kaskádou nádrží Vranov a Znojmo na Dyji za průchodu povodně v srpnu 2002. Smyslem aplikace bylo testování funkčnosti algoritmu, i když poměr retenčních schopností obou nádrží je vzhledem k jejich objemu nesrovnatelný. Byl minimalizován kulminační průtok v profilu pod nádrží Znojmo – závěrový profil - obr.20.

Ukázka výsledků řešení je znázorněna na obr.21 pro délku předpovědi přítoku vody do systému 120 h. V dílčím obrázku "Dílčí a celkové odtoky" značí slabá čára vždy odtok spodní výpustí.



Obr.20. Schéma kaskády nádrží



Obr.21. Výstupy z programu RIZSI - délka předpovědi průtoku 120 h

Sestavení **neuro-regulátoru**, který může v daném algoritmu nahradit fuzzy regulátor, nepředstavuje zásadní problém. Je třeba sestavit neuronovou síť jejíž vstupní sloupce budou tvořit regulační odchylky a změny regulační odchylky. Výstupním sloupcem neuronové sítě budou změny procentuálního nastavení otevření spodních výpustí. Bázi pravidel z fuzzy-regulátoru pak nahradí řádky v tréninkové matici. Velikosti dosažených příslušných hodnot pak musí korespondovat s odpovídajícími hodnotami zvolenými ve funkcích příslušnosti.

3.5 Neuronová síť ve funkci analyzátoru stupně ohrožení v povodí s nádržemi

Před zahájením operativního řízení odtoku vody z povodí za povodňové situace se dispečer nachází v obtížné situaci. Činnost spojená s operativním řízením je v praxi velmi složitá. Je započata po získané předpovědi srážek nutnou kontrolou spojení se všemi měřícími

prvky v povodí, uvedením dispečinku a obsluhy na všech objektech do pohotovosti a spuštěním řídicího algoritmu. Teprve analýza jeho výstupů nám poměrně přesně zodpoví na otázku, zda předchozí činnost nebyla zbytečná a zda je nutno operativní řízení započít. Stupeň ohrožení je pak rozhodující pro další návaznou činnost dispečera.

Aplikace je zaměřena na ověření možnosti vytvoření takového prostředku a užití neuronové sítě ve funkci rychlého analyzátoru počátečního stavu systému při získání první předpovědi příčinné srážky [18,26,39,40,43].


Neuronová síť natrénovaná z řady variant různých kombinací vstupů (různé stavy systému a prognózy srážek) a odpovídajících hodnot výstupů (kulminační průtoky ve vybraných profilech), může být použita pro rychlou analýzu dat. Může pomoci určit při dané prognóze srážek a daném stavu systému následující stupně ohrožení (SO):

- I.** *Není třeba na danou situaci reagovat, systém má dostatečné transformační schopnosti pro bezpečné převedení povodní i bez operativního řízení.*
- II.** *Je nutno přistoupit k operativnímu řízení. Regulační schopnosti systému jsou však dostatečné pro bezpečné převedení povodní. Neškodné odtoky v řídicích profilech nebudou překročeny.*
- III.** *Je nutno přistoupit k operativnímu řízení. Regulační schopnosti systému nejsou dostatečné pro bezpečné převedení povodní. Hrozí překročení neškodných odtoků v řídicích profilech.*
- IV.** *Je nutno přistoupit k operativnímu řízení. Jde o havarijní stav. Hrozí výrazné překročení neškodných průtoků v řídicích profilech a přelítí hrází.*

Pro konkrétní povodí s nádržemi lze tyto stupně ohrožení získat opakovanou simulací operativního řízení průchodu povodní existujícím řídicím algoritmem, vyhodnocením dosažených maximálních průtoků ve vybraných profilech a následnou klasifikací každého vybraného profilu příslušným stupněm ohrožení. Nejhorší klasifikace ze všech vybraných profilů odpovídá stupni ohrožení celého povodí.

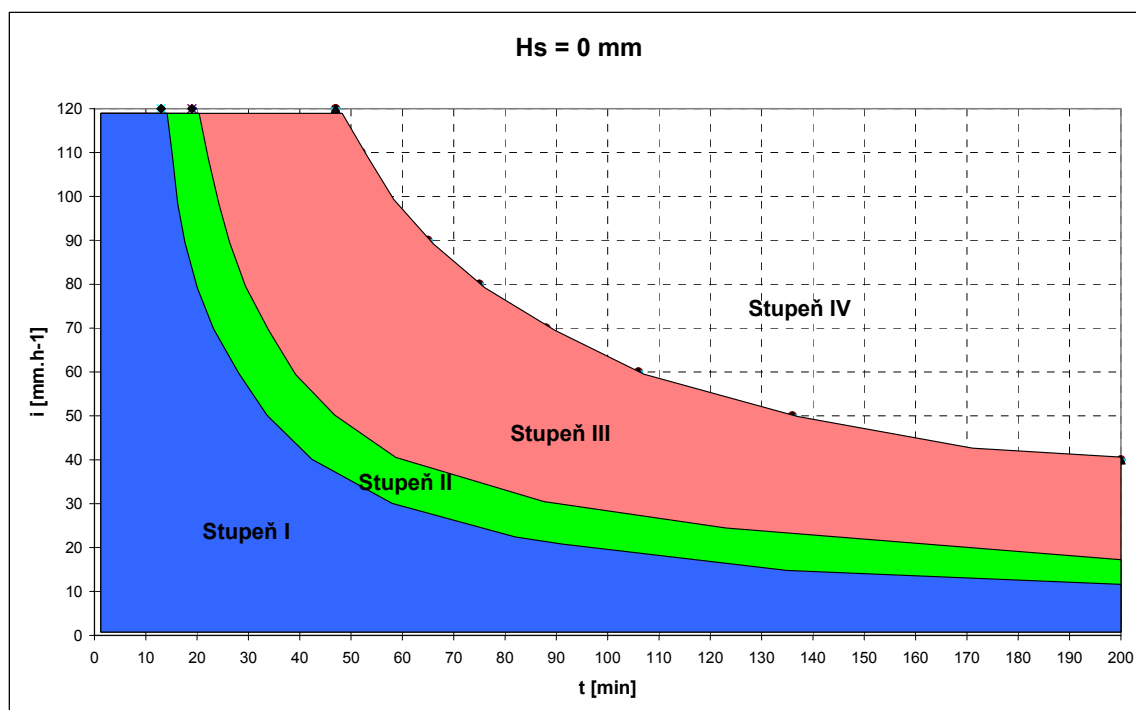
Simulace řízení průchodu povodní je třeba opakovat pro různé počáteční stavy plnění nádrží, různé ukazatele předchozích srážek, například úhrny srážek v předchozím týdnu H_s , které ovlivňují infiltraci vody do půdy a různé intenzity i a trvání příčinných dešťů τ - vždy pro celé spektrum reálných možných hodnot těchto veličin. Je zřejmé, že u srážek bude třeba vzhledem k časové a prostorové nerovnoměrnosti provést určitá zjednodušení. V nejjednodušším případě, který je v dalším textu naznačen, se nabízí nahradit jejich intenzitu v celém povodí konstantní hodnotou - náhradní intenzitou a uvažovat hladinu vody v nádržích na maximálních zásobních hladinách.

Vztahy mezi trváním τ , intenzitou předpovězené srážky i , úhrnem srážek v předchozím týdnu H_s a výsledným stupněm ohrožení jsou silně nelineární. Zde se nabízí užití neuronové sítě sestavené z výsledků opakovaných simulací operativního řízení pro aproximaci uvedeného vztahu. Pro různé kombinace vstupních veličin a vypočtený stupeň ohrožení sestavit neuronovou síť se třemi vstupními a čtyřmi výstupními neurony - obr.22. Čtyři výstupní neurony byly užity z nutnosti použít popis výstupu ve formě symbolů - každý stupeň ohrožení pak má svůj vlastní výstupní neuron. Symboly 0 (ne) nebo 1 (ano) pak vyjadřují dosažený stupeň ohrožení. A takovým způsobem se dosazuje do tréninkové matice.



Obr.22. Schéma neuronové sítě

Popsaný postup byl aplikován na povodí řeky Ostravice (nádrže Šance, Morávka, Žermanice, Baška a Olešná). Vybrané profily, ve kterých se vyhodnotily stupně ohrožení, tvořily odtoky ze všech stávajících nádrží a dále profil Frýdek-Místek a Ostrava. Pro jednoduchost se předpokládalo počáteční plnění všech nádrží po korunu pevného přelivu (nejrizikovější stav), konstantní časové a prostorové rozložení předpovězené srážky nad povodím a počáteční ustálené proudění vody v říční síti. Pro opakovanou simulaci řízení byl opět využit distribuční model HYDROG, který ve své plné verzi umožňuje operativní řízení.



Obr.23. Stupně ohrožení (SO) pro $H_s=0$ mm

Pro názornost je příklad získaných stupňů ohrožení pro hodnotu srážkového úhrnu v předchozím týdnu $H_s=0$ mm uveden na obr.23. Z nich je patrný i testovaný rozsah intenzity srážek a rozsah trvání srážek. Úhrn předchozích srážek byl testován od 0 do 60 mm.

Způsob konstrukce tréninkové matice neuronové sítě je naznačen v tab.7. Vstupní sloupce jsou opět označeny symbolem ↓, výstupní sloupce jsou označeny symbolem ↑.

Tab.7. Ukázka konstrukce tréninkové matice neuronové sítě

↓	↓	↓	↑	↑	↑	↑
H_s [mm]	i [mm.h ⁻¹]	τ [min]	S1	S2	S3	S4
0	40	10	1	0	0	0
0	40	20	1	0	0	0
0	40	30	1	0	0	0
.

Pro testování přesnosti dosažených výsledků bylo náhodně vygenerováno 100 kombinací intenzit i , trvání příčinných dešťů t a předchozího srážkového úhrnu H_s . Tyto kombinace byly postupně zadány jako vstupy do natrénované neuronové sítě. Dosažený stupeň ohrožení byl signalizován maximální hodnotou čísla v příslušném sloupci - viz.tab.8.

Tab.8. Ukázka výstupů z neuronové sítě

↓	↓	↓	↑	↑	↑	↑
H_s [mm]	i [mm.h ⁻¹]	τ [min]	S1	S2	S3	S4
0	40	40	0.5828	0.4461	0.2608	0.2359
0	10	700	0.3016	0.3660	0.4725	0.3811
80	10	1400	0.3125	0.7100	0.3963	0.0003
80	10	2200	0.2571	0.8057	0.3052	0.0003
10	110	50	0.4842	0.4903	0.4842	0.5098

Výstupy z tab.8 jsou následně interpretovány pomocí SO uvedených v tab.9.

Tab.9. Výsledná interpretace výstupů z tab.8

↓	↓	↓	↑	↑	↑	↑
H_s [mm]	i [mm.h ⁻¹]	τ [min]	S1	S2	S3	S4
0	40	40	1	0	0	0
0	10	700	0	0	1	0
80	10	1400	0	1	0	0
80	10	2200	0	1	0	0
10	110	50	0	0	0	1

Současně bylo pro stejné vstupní hodnoty i , t a H_s opakovaně simulováno operativní řízení programem HYDROG. Oba výstupy byly porovnány. Dosažené výsledky byly téměř identické. Pouze v blízkosti hranic, mezi sousedními stupni ohrožení, se v několika odpovídajících výstupních sloupcích neuronové sítě vyskytla přibližně stejná čísla signalizující blízkost této hranice.

4 Závěr

Typické vlastnosti neuronových sítí jsou rozhodující pro využití v aplikacích. Lawrencová z California Scientific Software v [13] shrnuje tyto vlastnosti do bodů, jejichž obsah byl v řešených aplikacích potvrzen:

- Neuronové sítě jsou vynikajícím prostředkem pro rozpoznávání závislostí mezi vstupními a výstupními údaji. Pokud potřebujete nějakou závislost rozpoznat a oklasifikovat, neuronová síť daný problém vyřeší vždy rychleji a přesněji než člověk. Neuronová síť dokáže opticky rozpoznat cokoli a určit, co to je dokonce, i když část dat je neúplných nebo jsou neplatná. Tato vlastnost se s velkým úspěchem využívá v medicíně při určování diagnóz (rozpoznávání rakovinných buněk při analýze provedených snímků), při

identifikaci letadel z odražených radarových signálů, ale i trhlin v betonu z odražených zvukových vln, apod.

- Pokud není možno popsat vztah mezi soubory dat exaktním vztahem, ale pokud je známo, které veličiny jsou vstupní a mají vliv na veličiny výstupní, neuronové sítě mohou nalézt požadovaný vztah. Ať už je absence exaktního vztahu dána jeho značnou složitostí nebo prostě tím, že není znám.
- Neuronové sítě nevynikají přesností. Pokud se neuronové sítě zeptáte, kolik je součet ze 4.01 a 4.02, získáte pravděpodobně hrubou odpověď, že 8. Pokud tedy potřebujete provádět výpočty s vysokou přesností, neuronové sítě nebudou vhodným prostředkem.
- Pokud však bude rychlost výpočtu důležitější než přesnost, neuronové sítě jsou tím pravým prostředkem pro řešení.

Uvedené vlastnosti neuronových sítí je možno rozšířit i na problematiku aplikované hydrologie a vodního hospodářství vůbec:

- Vlastnosti rozpoznávat závislost mezi vstupními a výstupními údaji lze využít ve vodním hospodářství při konstrukci varovných systémů před povodňovými průtoky v ohrožených lokalitách, kdy mohou pomoci odhalit hrozící nebezpečí a zároveň je kvantifikovat stupněm ohrožení. Sestavení tréninkových matic pomocí jiných technik řešení pak je nezbytnou podmínkou zejména v povodích s nádržemi, z nichž je odtok řízen. V povodích bez nádrží pak je podmínkou úspěšnosti dostatečné množství naměřených dat.
- Vlastnosti aproximovat i silně nelineární vztahy mezi soubory dat, které nejsou exaktně dány, resp. jsou velmi složité a problematické, je možno využít při filtraci měřených meteorologických a hydrologických dat, prověřování jejich věrohodnosti, při rozpoznávání závislosti mezi různými hydrologickými veličinami, například mezi srážkou a odtokem vody z povodí, mezi průtoky v různých profilech v říční síti, apod. Důležitou oblastí využití pak je možnost extrapolace těchto veličin v čase, neboli konstrukce předpovědních modelů. Důkazem perspektiv užití neuronových sítí v této oblasti jsou již vyvinuté srážkoodtokové simulační a předpovědní modely, předpovědní modely průtoků v systému stanic v říční síti, apod. Uvedené aplikace prokázaly, že nasazení neuronových sítí pro konstrukci předpovědních modelů odtoků vody z povodí, resp. předpovědi průtoků vody v říční síti má smysl. S výhodou je možno využívat schopnosti neuronových sítí počítat souběžně několik výstupních veličin. Například kromě kulminačního průtoku, který je při předpovědi odtoku vody z povodí rozhodující pro pobřežníky, je možno paralelně získat odhad objemu povodňové vlny, který je rozhodující pro řízení odtoku vody z povodí nádrží.
- Vlastnost týkající se rychlosti výpočtu při použití natrénované neuronové sítě najde svoje uplatnění při řešení problémů, jejichž matematický model je znám a existují modely umožňující jeho řešení. Vlastní výpočet však při jejich použití vyžaduje i při současné úrovni rozvoje výpočetní techniky značnou spotřebu strojového času. Trvání výpočtu pak znehodnocuje dosažené výsledky z hlediska jejich aktuálnosti. Ve vodním hospodářství se nabízí využití této vlastnosti při operativním řízení vodohospodářských objektů a soustav, které probíhá za značných podmínek neurčitosti. Mám zde na mysli především operativní řízení odtoku z povodí nádržemi za povodňových situací, kdy může být výpočet řídicích průtoků, resp. nastavení poloh regulačních uzávěrů, při použití řídicích algoritmů zkonstruovaných na bázi simulační techniky, velmi zdlouhavý a tudíž nevyhovující. Analýza stavů řízených systémů klasickými optimalizačními nástroji a výpočet nastavení regulačních uzávěrů může překročit svým trváním přípustné zpoždění, které limituje použitelnost řídicího algoritmu pro operativní řízení systému. Zde je použití neuronové sítě pro aproximaci matice cílového chování, resp. využití neuro-regulátorů, případně

fuzzy-regulátorů možným řešením. Výpočty na natrénovaných neuronových sítích probíhají řádově v milisekundách.

Dosažené výsledky byly ve všech uvedených aplikacích hodnoceny individuálně a je možno je považovat za velmi nadějně. Závěry však nedoporučuji přeceňovat. U neuronových sítí velmi záleží na nastavení parametrů užitých při trénování. Jedná se zejména o volbu kritéria, povolenou toleranci, nastavený počet skrytých vrstev neuronů, volbu typu přechodové funkce atd. Jejich úspěšné použití vyžaduje určité zkušenosti a intuici. Přes uvedené nesporné klady mají neuronové sítě i svoje problematická místa související s jejich konstrukcí (topologií), trénováním a způsobem použití v aplikacích.

Především je třeba mít na mysli, že neuronové sítě nevynikají přesností při extrapolaci, tj. použijeme-li natrénovanou neuronovou síť pro vstupní údaje, které leží mimo tréninkovou oblast. V některých aplikacích, kdy tréninková matice byla sestavena přímo z měřených dat a nebyl dostatek měření, bylo dosaženo lepších výsledků po dodatečném vložení řádků s byť i odhadnutou relací mezi vstupními a výstupními veličinami. Které však pokrývaly oblast možné extrapolace mimo tréninkovou oblast.

Často uváděnou výhodou neuronových sítí je, že pokud se proces, který řídíme, resp. analyzujeme a vyhodnocujeme poněkud změní, je postačující doplnit nové tréninkové vzory do tréninkové matice a provést dotrénování neuronové sítě. Aplikace neuronových sítí však ukázaly, že i s takovýmto postupem se mohou vyskytnout problémy. V případech, kdy máme již natrénovanou neuronovou síť na sérii vstupních vzorů a postupně získáváme např. měřeními nebo doplňujícími výpočty nové vzory vstupních dat, se nabízí rozšíření tréninkové matice o tyto vzory a dotrénování neuronové sítě. Praxe však ukazuje, že takovýto opakovaný postup se může zdařit pouze několikrát. Strojový čas potřebný na dotrénování se začne postupně neúměrně prodlužovat, až neuronová síť nepůjde dotrénovat vůbec. Pokud tento jev nastane, je řešením neuronovou síť kompletně znovu přetrénovat. Je to však podstatně jednodušší, než sestavení nového výpočetního vzorce, resp. provedení případných změn pravidel použitých pro řízení systému a s tím spojeného následného přepisu řídicích programů.

Někdy jde sestavená neuronová síť velmi dobře zpočátku trénovat. Pak se však proces trénování zastaví a není schopna dosáhnout předepsané tolerance. Proces učení se značně zpomalí až zastaví. Tento jev může být způsoben existencí špatných vzorů dat v tréninkové matici. V takovémto případě je vhodné proces učení ukončit a posoudit úspěšnost procesu učení ve "špatných vzorech". Vypočtené výstupy se mohou lišit od požadovaných výstupů jen velmi málo, nebo mohou být odchylky značné. V prvním případě je možno ponechat natrénovanou síť ve stavu ukončení tréninku a otestovat ji na nových datech s případně mírně zvětšenou tolerancí. Pokud testování dopadne dobře, je možno natrénovanou neuronovou síť prakticky používat "tak jak je". Případně ji můžeme dotrénovat s povolením určitého procenta vzorů, ve kterých nebude splněna požadovaná tolerance. Tak vyloučíme špatné vzory z procesu učení. Pokud však si jsme jisti, že uvedené "špatné" vzory nemůžeme z dat vyloučit, protože jsou v nich obsaženy vztahy mezi daty, které by neuronová síť měla umět aproximovat, je třeba vyzkoušet možnost doplnění počtu skrytých neuronů. Může se totiž stát, že počet skrytých neuronů je malý pro naučení neuronové sítě aproximovat složité vztahy mezi vstupními a výstupními soubory dat. Tento problém se často vyskytuje, když máme velký počet tréninkových vzorů. Cestou pro vyřešení výše uvedeného problému je rovněž snížení zadané tolerance. Naše požadavky mohou být vzhledem ke kvalitě dat příliš vysoké. To umožní provést neuronové síti větší korekce v méně obvyklých vzorech a menší ve vzorech, ve kterých je vztah mezi vstupy a výstupy jednodušší. Pokud žádné z navržených řešení nepřispěje ke zlepšení procesu učení, může tréninková matice obsahovat chybné vzory, které není možno natrénovat. Takovéto vzory je třeba z dalšího tréninku vyloučit. Někdy však

je řešením i rozšíření tréninkové matice o další vzory, které "zdánlivě špatné" vzory v procesu trénování podpoří a "donutí" neuronovou síť zobecnit vztah mezi vstupy a výstupy i v jiné oblasti prostoru vstupně-výstupních dat. Pokud užíváme pro simulaci neuronové sítě software BrainMaker Professional, je možno při analýze vstupně-výstupních dat použít datový analyzátor. Ten otestuje, zda se v tréninkové matici nevyskytují vzory, které pro obdobné hodnoty vstupních dat nemají zcela odlišné hodnoty dat výstupních. Pokud by tento stav nastal, není možno na těchto vzorech neuronovou síť natrénovat a je třeba chybné vzory vyloučit.

Určitou nevýhodou neuronových sítí (při použití softwarové verze) je poměrně vysoká spotřeba strojového času ve stadiu jejich učení. To se projevuje zejména při trénování složitých neuronových sítí, především pak při jejich trénování za použití genetických algoritmů (GTO). I přes značný nárůst strojového času spojeného s trénováním neuronových sítí pomocí genetických algoritmů se jejich užití ukázalo jako velmi přínosné. Je zřejmé, že klasická metoda zpětného šíření chyby snadno uvázne při složitějších průběžích kritériální funkce v "pasti" lokálního extrému. Genetické algoritmy se s tímto problémem vypořádávají mnohem lépe. Proces trénování se však provádí v předstihu před praktickým nasazením neuronové sítě a dá se eliminovat užitím rychlého čítače. Hardwarové neuronové karty, jejichž vývoj intenzivně probíhá, tréninkovou fázi procesu značně urychlují. Natrénovanou neuronovou síť pak je možno zkompileovat a spouštět mimo vývojové prostředí samostatně nebo pomocí runtime modulu, dle možností konkrétního použitého softwaru.

Pokud se s nasazením neuronových sítí při řešení uvedených aplikací vyskytly problémy, vždy se ukázalo, že chyby byly v použitých datech, resp. v jejich chybné aplikaci, resp. interpretaci, případně i v nepochopení hydrologické podstaty problému. Vlastní neuronové sítě vycházely z řešení převážně jako vítěz.

Sestavování modelů na bázi neuronových sítí určitým způsobem zpětně ovlivňuje myšlení subjektu. Nutí jej více přemýšlet o podstatě problému jako takového, o vztazích mezi vstupními a výstupními veličinami, o veličinách, které mohou mít vliv na řešený problém apod. Řešitel při aplikaci neuronových sítí na modelování složitých vodohospodářských problémů pocítí určitou volnost a svobodu ve srovnání s použitím klasických modelů. Ty jsou založeny na použití přesně formulovaných rovnic, vycházejících z fyzikálních zákonů zachování a stavových rovnic. Zde pak řešitel často skončí v pasti řešení soustavy parciálních diferenciálních rovnic a je více matematikem než odborníkem v daném oboru. Bez náležitých znalostí a zkušeností, resp. při absenci již zpracovaného software, není schopen samostatně pokračovat.

Neuronové sítě představují mocný a perspektivní nástroj, který je svojí podstatou předurčen pro užití v mnoha oblastech aplikované hydrologie. Aby se však mohl projevit při řešených problémech v plné síle, je třeba mít k dispozici dostatečné množství kvalitních informací, popisujících vstupně-výstupní vztahy. Ať již jsou tyto informace získány měřením na reálných systémech, nebo za použití jiných, především simulačních technik výpočtu. I když nasazení neuronových sítí v aplikované hydrologii a ve vodním hospodářství vůbec zaznamenalo v posledním desetiletí poměrně značný nárůst, přesto není takové, jak by mohlo být. Je třeba, aby se informace o řešených aplikacích a o snadném použití tohoto nástroje trvale dostávaly do povědomí odborné veřejnosti s větší intenzitou a přesvědčovaly potenciální uživatele o svých možnostech. Zaslouhují si, stejně jako ostatní metody umělé inteligence, větší publicitu.

5 Seznam odkazů na literaturu

- [1] ABBOTT, M.B.: An Introduction to the Method of Characteristic. Thames and Hudson, London, 1966.
- [2] ARTINT ver.2.0. Systém pro projektování, učení a testování umělých neuronových sítí, Mentar & EGU, Praha, 1995.
- [3] BÍLA, J.: Umělá inteligence a neuronové sítě v aplikacích. FS, ČVLT Praha, 1995.
- [4] BrainMaker ver.3.1. Software pro emulaci umělých neuronových sítí, California Scientific Software, Nevada City, 1996.
- [5] CUNGE, J. - HOLLY, F.M. - VERWEY, A.: Practical aspects of Computational River Hydraulics. Pitman Advanced Publishing Program, London, 1980, 415 s.
- [6] DRBAL, K.: Operativní řízení povodňových průtoků fuzzy regulací v dolní části vodohospodářské soustavy, disertační práce, VUT FAST, Brno, říjen 1999, 158 s.
- [7] DRBAL, K. - STARÝ, M.: Modelování hydrogramů povodňových vln v systému stanic, výzkumná zpráva RÚ 43-210, Praha, 1996, s. 17-25, 96 s. příloh.
- [8] FOŠUMPAUR, P.: Použití umělých neuronových sítí ve vodním hospodářství. Doktorská disertační práce, ČVUT Praha, 1998, 143 s.
- [9] HEBB, D.: The Organization of Behaviour. New York, Wiley Publications, 1949.
- [10] HOPFIELD, J.J.: Neural Networks and Physical Systems with Emergent Collective Computational Abilities. Proc. of the Nat'l Academy of Sciences, 79, 1982, pp. 2554-2558.
- [11] HOŘEJŠ, J. - KUFUDAKI, O.: Počítače a mozek (neuropočítače). In: Sborník referátů Softwarový seminář SOFSEM '88, Malenovice v Beskydech, Ústav výpočetní techniky UJEP Brno a JČMF, 1988.
- [12] KŘIVAN, M.: Úvod do umělých neuronových sítí. Skriptum. VŠE Praha, 1995, 49 s.
- [13] LAWRENCE, J.: Introduction to Neural Networks. Nevada City, California Scientific Software, 6th Edition, July 1994, 348 s.
- [14] MATLAB v. 6.1, The Math Works, Inc., 2001.
- [15] MCCULLOCH, W.S. - PITTS, W.: A logical calculus of the ideas immament in nervous activity. Bull. Math. Biophys., Vol 5, 1943.
- [16] MERTO VÁ, M. - STARÝ, M.: Operativní předpovědi povodňových průtoků v systému stanic za použití umělých neuronových sítí. In: Sborník referátů z konf. Systém povodňové ochrany ČR, Olomouc, 7. symposium, 23.-25.6 1998, str.73-80.
- [17] MOUSE. Software pro simulaci odtoku vody z urb. povodí, DHI, Denmark, 1990.
- [18] NACHÁZEL, K. – STARÝ, M. – ZEZULÁK, J. a kol.: Využití metod umělé inteligence ve vodním hospodářství. ACADEMIA, Praha, 2004, 320 s.
- [19] NACHÁZEL, K. - TOMAN, M.: Problematika umělých neuronových sítí a jejich využití pro optimalizaci výroby elektrické energie v soustavě vodních elektráren. In: Vodohosp. čas., 45, 1997, č.3, s. 129-150.
- [20] NOVÁK, M.: Neuronové sítě a neuropočítače. Praha, Senzo a.s., Výběr, 1992, 192 s.
- [21] ROSENBLAT, F.: The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review 65, 1958, pp.386-408.
- [22] RUMELHART, D. - HINTON, E.G. - WILLIAMS, R.I.: Learning internal representations by error propagation. MIT Pres, Cambridge, MA, 1986.
- [23] SEJNOWSKI, T. - ROSENBERG, Ch.: Net Talk: A Parallel Network That Learns to Read Aloud, In: Neurocomp. Foundations of Research, Cambridge, Mit Press, 1988.
- [24] STARÝ, M.: Modelování hydrogramů povodňových vln v systému stanic s využitím neuronových sítí. In: Sborník referátů z konf. Přehradní dny 1996, Hradec nad Moravicí, Povodí Odry a.s. - Český přehradní výbor, červen 1996, s. 248-252.
- [25] STARÝ, M.: Neural Networks and Predictions in Applied Hydrology. In: Presentation abstracts of PRIMA - Information Technology and Its Use for Environmental Monitoring and Protection, London, 9-11 January 1995, s. 11-12.
- [26] STARÝ, M.: Neural networks applied to the flood warning system in basins with reservoirs. Poster presentation, Workshop IndAgua, Brussels, June, 1999, 15 s.

- [27] STARÝ, M.: HYDROG. Software pro simulaci, predikci a operativní řízení odtoku vody z povodí. Brno, 1991-2004.
- [28] STARÝ, M.: Operativní řízení odtoku vody z nádrže za průchodu povodně, MATLAB 2001, Praha, 2001, 6s.
- [29] STARÝ, M.: Analýza kvantitativních a kvalitativních dat vodního zdroje Březová pro účely prognózy. Studie, Brno, červen 1993, 31 s.
- [30] STARÝ, M.: Modelování hydrogramů povodňových vln v systému stanic s využitím neuronových sítí. In: Sborník referátů z konf. Přehradní dny 1996, Hradec nad Moravicí, Povodí Odry a.s. - Český přehradní výbor, červen 1996, s. 248-252.
- [31] STARÝ, M.: Operativní řízení odtoku vody z nádrže za průchodu povodně, Sborník příspěvků 9. ročníku konference MATLAB 2001, Kongresové centrum ČVUT, Praha, říjen 2001, str.393-398. ISBN 80-7080-446-7.
- [32] STARÝ, M.: Neuronové sítě a předpověď kulminačních průtoků a objemů povodní v povodí řeky Ostravice - uzávěrový profil Šance. In: Vodohospodářský časopis, Vol.46, No.1, 1998, str.45-61.
- [33] STARÝ, M. - BLAŽEK, J.: Operative Forecast of Flood Discharge in Gauging Network, XI.mezinárodní vědecká konference, VUT Brno, 1995, str. 157-162.
- [34] STARÝ, M. – DIVIŠ, L.: Neural Networks and Prediction of Run-off from Small River Basin. In: Presentation referats of International Forum on Problems of Science, Technology and Education, Moskow, May 19-23, 1997, s. 50-53.
- [35] STARÝ, M. - DOLEŽAL, P. Srovnání přístupů k sestavení řídicích algoritmů pro operativní řízení odtoku vody nádrží za průchodu povodně, In: Vodní toky, Hradec Králové, listopad 2003, 7 s.
- [36] STARÝ, M. - DOLEŽAL, P. Operativní řízení odtoku vody kaskádou nádrží Vranov-Znojmo za průchodu povodně. In: WORKSHOP 2003, ČVUT FS, Praha, 2003, 8 s.
- [37] STARÝ, M. - JACOBSE, P. - DAHL, A.: Operativní řízení vodohospodářských systémů za použití neuronových sítí. In: Sborník referátů z 6.symp.Vodohospodářské soustavy, Lázně Bohdaneč, ČVTS, 1993, s. 173-183.
- [38] STARÝ, M. - REC, O.: The Application of Neural Networks for Predicting. Symposium Advances in Water Sciences, St.Lesná, High Tatras, May, 1993, 5 s.
- [39] STARÝ, M. – ŠEBLOVÁ, H.: Neural networks applied to the flood warning system in basins with reservoirs, In.: Sborník mezinárodního workshopu Optimalizace inženýrských úloh ve stokování, VUT FAST, Brno, duben 2000.
- [40] STARÝ, M. - ŠEBLOVÁ, H. - TUREČEK, B.: The operative control of the passage of floods, In: Proceedings of the third international conference on hydroinformatics/ Copenhagen-Denmark/ 24-26 August 1998, str.831-836, ISBN 90 5410 985 8.
- [41] STARÝ, M. - TUREČEK, B.: Simulace povodňových průtoků v povodí Ostravice. In: Vodní hosp., 6/96, s. 191-194.
- [42] STARÝ, M. – TUREČEK, B.: Operative control and prediction of floods in the River Odra basin. In.: Flood Issues in Contemporary Water Management, NATO Science Series, 2.Environmental Security – Vol.71, Kluwer Academic Publishers, 2000, s.229-236, ISBN 0-7923-6452-X.
- [43] ŠEBLOVÁ, H. - STARÝ, M.: The operative predictions of flood discharges in the Jihlava River basin. In.: Sborník mezinárodní vědecké konference Krajina, meliorace a vodní hospodářství na přelomu tisíciletí, Brno, září 1999, s. 279 - 287.
- [44] ŠÍMA, J. - NERUDA, R.: The Empty Neural Expert System and its Application in Medicine. In: Proc. of the Twelfth European Meeting on Cybernetics and System Research, Viena, 1994.
- [45] ZADEH, L. A. Fuzzy sets. Information and Control, 8, 1965, p. 338-353.

Summary

The complexity of rainfall-runoff process was during the last years intensified by expected and partially already shown influences of climate changes, connected with changes of water yield and temporal distribution of water sources. This is shown in a connection with the influence of long periods of climate and hydrologic quantities with formation of not only disastrous floods but also extremely dry periods. These problems often urge water management specialists to solve problems, for which methods and tools are not always sufficient. Mostly it means the necessity of development of nonstructural measures in river basins connected with operative hydrology, e.g. operative prediction and operative control of river basin water runoff, in case there are suitable regulation items, such as water reservoirs, in the river basin. The solving of mentioned problems is carried out at pronounced conditions of uncertainty. In the field of development of artificial intelligence methods an effort to solve deciding problems in the condition of uncertainty (intelligent solution) is shown. Controlling systems have to be equipped with the ability to use experience and knowledge described just vaguely and to react to uncertain and beforehand unknown situations. Adaptive approach, used at operative control during described conditions of uncertainty, is a certain way, how to eliminate to certain extent those impacts with suitable construction of controlling algorithms. The results achieved in practice positively confirm the advantages of use of solution adaptive approach whether in connection with classic controlling algorithms, based on purely optimization principles or in connection with controlling algorithms using the methods of artificial intelligence.

Neural networks are one of the methods of artificial intelligence. They are excellent in ability to approximate even strongly nonlinear relations between input and output quantities of problems in water management. However they excel above all in the speed of computation when using already trained neural network. Both those properties predetermine the sphere of their use.

The goal of this work is to evaluate the possibilities of neural networks use for solving of problems in applied hydrology, mainly operative hydrology. The evaluation is carried out using selected tasks, in which neural networks were successfully used. Partial problems, however, show the possibilities for other methods of artificial intelligence use as well, i.e. genetic algorithms, which are used for training of neural networks and fuzzy regulators in the construction of controlling algorithms.

The first part of the work deals with the theoretic description of neural networks, transmission functions, methods used for their training including training with the use of genetic algorithms, their topology. A certain connection with regressive analysis and their possible combination with fuzzy systems are indicated as well. In the final part the description of available selected neural networks simulators is given.

The second part of the work deals with the description of neural networks applications in solving selected tasks. It is actually a collection of tasks solved progressively since the year 1991. All the tasks are original. I solved them either solo or in cooperation with the students of Water management field of study (they worked under my leadership). Most of the tasks were published and has reference to the relevant articles.

Most of the work was published in monograph "The Use of Artificial Intelligence Methods in Water Management" [18]. Some of the applications were solved in the grants of GAČR: reg.n. 103/97/0106 "Methods of Artificial Intelligence in the Theory of Water Management Systems" and reg.n. 103/01/0201 "Problems of Operative Control of Water Management Systems in the Conditions of Uncertainty ". The development of selected applications in the filed of operative control of water runoff from the river basin is continued in the project reg. n. 103/04/0352 "The Theory of operative Control of Water Management systems during the Flood Events".