



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA STAVEBNÍ
ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

FACULTY OF CIVIL ENGINEERING
INSTITUTE OF LANDSCAPE WATER MANAGEMENT

STOCHASTICKÁ PŘEDPOVĚĎ PRŮMĚRNÝCH MĚSÍČNÍCH PRŮTOKŮ VE VYBRANÉM VODOMĚRNÉM PROFILU

STOCHASTIC PREDICTION OF MEAN MONTHLY FLOWS IN SELECTED HYDROMETRIC PROFILE

DIPLOMOVÁ PRÁCE
DIPLOMA THESIS

AUTOR PRÁCE
AUTHOR

BC. JAKUB JANSÁ

VEDOUcí PRÁCE
SUPERVISOR

Ing. DANIEL MARTON, Ph.D.

BRNO 2016



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STAVEBNÍ

Studijní program	N3607 Stavební inženýrství
Typ studijního programu	Navazující magisterský studijní program s prezenční formou studia
Studijní obor	3607T027 Vodní hospodářství a vodní stavby
Pracoviště	Ústav vodního hospodářství krajiny

ZADÁNÍ DIPLOMOVÉ PRÁCE

Diplomant	Bc. Jakub Jansa
Název	Stochastická předpověď průměrných měsíčních průtoků ve vybraném vodoměrném profilu
Vedoucí diplomové práce	Ing. Daniel Marton, Ph.D.
Datum zadání diplomové práce	31. 3. 2015
Datum odevzdání diplomové práce	15. 1. 2016
V Brně dne 31. 3. 2015	

.....
prof. Ing. Miloš Starý, CSc.
Vedoucí ústavu

.....
prof. Ing. Rostislav Drochytka, CSc., MBA
Děkan Fakulty stavební VUT

Podklady a literatura

- MARTON, D.; STARÝ, M.: UNCE- V; UNCE- V Generátor nejistot vstupních hydrologických dat. <http://uvhk.fce.vutbr.cz/software.php>. URL: <http://uvhk.fce.vutbr.cz/software.php>. (software)
- MENŠÍK, P.; STARÝ, M.: ZPP Model; ZPP Model. <http://uvhk.fce.vutbr.cz/software.php>. URL: <http://uvhk.fce.vutbr.cz/software.php>. (software)
- SILVER, N, Signál a šum, Nakladatelství Paseka, Praha, 2014, ISBN: 978-80-7432-440-6, EAN: 9788074324406.
- MENŠÍK, P.; STARÝ, M.; MARTON, D. Using Predictive Model of Mean Monthly Flows for Large Open Reservoirs Hydropower Control. *Procedia Engineering*, 2014, roč. 89, č. 12, s. 1486-1492. ISSN: 1877- 7058.
- MENŠÍK, P.; STARÝ, M.; MARTON, D. Using Predictive Models of Mean Monthly Flows for Operative Outflows Control from Large Open Reservoirs. In *Proceedings ITISE 2014, International work- conference on Time Series*. Spain, Granada: Copicentro Granada S. L, 2014. s. 382-395. ISBN: 978-84-15814-97- 9.
- Beven, K. *Environmental Modelling: An Uncertain Future?*, CRC Press; 1 edition, 2008, ISBN: 978-0415457590.
- NACHÁZEL, K., ZEŽULÁK, J., STARÝ, M. *Užití metod umělé inteligence ve vodním hospodářství*. 1. 1. Praha: Academia, 2004. 320 s. ISBN: 80-200-0229- 4.

Zásady pro vypracování

Diplomová práce si klade za cíl nalezení vhodného propojení mezi náhodně generovanými vstupy v podobě náhodných průběhů reálných průtokových řad, či umělých průtokových řad se standardně používanými hydrologickými předpovědními modely (modely založené na principech umělé inteligence a pravděpodobnostní modely). Výsledkem práce bude ověření postupů a následné sestavení stochastické předpovědi průměrných měsíčních průtoků ve vybraném vodoměrném profilu toku, která by byla dále využita pro účely řízení nádrže, resp. vodohospodářské soustavy.

Struktura bakalářské/diplomové práce

VŠKP vypracujte a rozčleňte podle dále uvedené struktury:

1. Textová část VŠKP zpracovaná podle Směrnice rektora "Úprava, odevzdávání, zveřejňování a uchovávání vysokoškolských kvalifikačních prací" a Směrnice děkana "Úprava, odevzdávání, zveřejňování a uchovávání vysokoškolských kvalifikačních prací na FAST VUT" (povinná součást VŠKP).
2. Přílohy textové části VŠKP zpracované podle Směrnice rektora "Úprava, odevzdávání, zveřejňování a uchovávání vysokoškolských kvalifikačních prací" a Směrnice děkana "Úprava, odevzdávání, zveřejňování a uchovávání vysokoškolských kvalifikačních prací na FAST VUT" (nepovinná součást VŠKP v případě, že přílohy nejsou součástí textové části VŠKP, ale textovou část doplňují).

.....

Ing. Daniel Marton, Ph.D.
Vedoucí diplomové práce

ABSTRAKT

Diplomová práce je zaměřena na předpověď průměrných měsíčních průtoků na vybraném vodoměrném profilu. Výstupem bude vyhodnocení vypočtených hodnot a interpretace výsledků v přehledné podobě. Dále nalezení vhodného propojení mezi náhodně generovanými vstupy v podobě náhodných průběhů reálných průtokových řad se standardně používanými hydrologickými předpovědními modely založenými na principech umělé inteligence a pravděpodobnostním modelu. Výsledkem práce bude ověření postupů a následné sestavení stochastické předpovědi průměrných měsíčních průtoků ve vybraném vodoměrném profilu toku, která by byla dále využita pro účely řízení nádrže, resp. vodohospodářské soustavy.

KLÍČOVÁ SLOVA

Neuronová síť, neuron, MATLAB, koeficient determinace, předpověď průtoků, průměrný měsíční průtok.

ABSTRACT

The diploma thesis is focused on the average monthly flows forecast in the selected hydrometric profile. Aim of this work will be evaluation of the calculated values and the interpretation of the results in understandable form. The next step will be find an appropriate connection between randomly-generated inputs in the form of random real flow series using the standard hydrological prediction models. This models are based on the principles of artificial intelligence and probability model. The result of the work will be verification of procedures and compilation of mean monthly flow stochastic forecast in selected hydrometric profile, which would be used for a reservoirs management, respectively for water systems management.

KEYWORDS

Neural Network, Neuron, MATLAB, Coefficient of Determination, Discharge Prediction, Mean Monthly Discharge.

Bibliografická citace VŠKP

Bc. Jakub Jansa *Stochastická předpověď průměrných měsíčních průtoků ve vybraném vodoměrném profilu*. Brno, 2015. 77 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.

PROHLÁŠENÍ:

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje.

V Brně dne 15. 1. 2016

.....

podpis autora

Bc. Jakub Jansa

PODĚKOVÁNÍ

Tato diplomová práce byla zpracována s využitím infrastruktury Centra AdMaS a také byla podpořena specifickým výzkumným projektem FAST-S-15-2694 “Propagace nejistot v hydrologických a vodohospodářských aplikacích pro zmírnění dopadů sucha na vodní nádrže”. Dále bych na tomto místě chtěl poděkovat vedoucímu své diplomové práce, Ing. Danielovi Martonovi, Ph.D., za odbornou pomoc a rady, které mi poskytoval v průběhu psaní této práce.

OBSAH

1. ÚVOD A CÍL PRÁCE	10
1.1 ÚVOD	10
1.2 CÍL PRÁCE	12
2. Metoda.....	13
2.1 METODA MONTE CARLO.....	13
2.2 STANDARDIZACE DAT	15
2.3 NEURONOVÉ SÍŤ	15
2.3.1 UMĚLÁ NEURONOVÁ SÍŤ.....	16
2.3.2 TOPOLOGIE SÍŤ.....	17
2.4 VYHOTOVENÍ PŘEDPOVĚDI	18
2.5 VYHODNOCENÍ ÚSPĚŠNOSTI PŘEDPOVĚDI	19
2.5.1 KOEFICIENT DETERMINACE	19
2.5.2 KOEFICIENT KORELACE.....	20
2.5.3 ČÁRA PŘEKROČENÍ PRAVDĚPODOBNOSTI	22
2.6 ZONÁLNÍ PRAVDĚPODOBNOSTNÍ PŘEDPOVĚDNÍ MODEL.....	23
3. SESTAVENÍ PŘEDPOVĚDNÍHO MODELU	25
4. PRAKTICKÁ APLIKACE PŘEDPOVĚDNÍHO MODELU	29
4.6 PŘÍPRAVA DAT PRO ZPRACOVÁNÍ	32
4.7 POSTUP ZPRACOVÁNÍ DAT.....	33
4.7.1 NAČTENÍ DAT	33
4.7.2 PRÁCE S NEURONOVÝMI SÍŤEMI V PROSTŘEDÍ MATLAB POMOCÍ OKNA DATA MANAGER.....	34
4.7.3 PRÁCE S NEURONOVÝMI SÍŤEMI V PROSTŘEDÍ MATLAB POMOCÍ KÓDŮ.....	37
4.8 NASTAVENÍ NEURONOVÉ SÍŤE	38
4.9 VYHODNOCENÍ DAT	38
4.9.1 NALEZENÍ OPTIMÁLNÍ DÉLKY VSTUPNÍ MATICE DAT	38
4.10 PŘEDPOVĚDI PRŮTOKŮ.....	39
5. SHRHNUTÍ VÝSLEDKŮ.....	51
5.6 POROVNÁNÍ PREDIKCÍ	65
6. ZÁVĚR.....	67

7. LITERATURA A CITACE	69
7.1 POUŽITÁ LITERATURA.....	69
7.2 CITACE Z LITERATURY	70
8. OBRÁZKY	73
9. TABULKY.....	77

1. ÚVOD A CÍL PRÁCE

1.1 ÚVOD

Účelem hydrologické předpovědi, zejména předpovědi průtoků je snaha předcházet výskytu hydrologických extrémů, tzn. extrémnímu suchu nebo povodním.

S nepříznivým vývojem změny klimatu se dá očekávat pokles kapacity vodních zdrojů. Tyto změny mohou vést k problémům se zásobováním obyvatelstva vodou a mohou ohrozit i některá odvětví průmyslu jako je energetika a zemědělství. Z těchto důvodů se zvyšuje potřeba zlepšit způsoby nakládání s vodami, což vede k vyšší potřebě odhadu přítoků vody do nádrže.

Odtoková bilance v České republice je z důvodu závislosti na srážkách nepříznivá. Samotná proměnlivost srážkových úhrnů je poměrně značná, kdy např. v roce 2002 byl zaznamenán historicky třetí nejvyšší srážkový úhrn a hned na to, v roce 2003, byl zaznamenán druhý nejnižší úhrn za více jak dvě stě let pozorování. Přes značnou proměnlivost ročních úhrnů srážek je od třicátých let minulého století patrná nevýrazná klesající tendence těchto úhrnů.

Oblast ČR zasáhla významná sucha mezi lety 1982-1984 a 1990-1992, dále pak v roce 2003 a také v letech 2014 a 2015. Naopak význačné povodně byly zaznamenány především v letech 1996, 1997 a následně v letech 2002, 2006, 2009, 2010 a 2013. Z uvedených dat je zřejmá zvyšující se intenzita výskytu hydrologických extrémů, která může být zapříčiněna změnou klimatu a na kterou je nutné se postupně adaptovat.

Základním opatřením u povrchových vodních zdrojů, které vede k připravenosti na oba uvedené hydrologické extrémy, je potřeba přehodnocení způsobu, jakým jsou vodní nádrže a vodohospodářské soustavy využívány. To směřuje k optimalizaci jejich řízení tak, aby byly co nejlépe plněny nově definované požadavky na funkci s pohledem do budoucnosti. Z tohoto důvodu je dobré provádět simulační modelování a matematickou optimalizaci. Výsledky následně zohlednit při úpravě manipulačních řádů vodních děl.[1]

Nutným předpokladem pro sledování a optimalizaci procesu adaptace na změnu klimatu a plnění uvedených aktivit je efektivní systém monitorování a vyhodnocování realizovaných adaptačních opatření včetně stanovení adekvátních indikátorů. Je nutné, aby MŽP jako odpovědný orgán nastavilo informační systém v oblasti sběru, zpracování, uchovávání, výstupu, vyhodnocování a přenosu dat a informací, systémů řízení, monitorování a komunikace s dalšími resorty, kraji, jednotlivými obcemi i veřejností v této oblasti.[1]

Počátky neuronových sítí lze datovat do druhé poloviny 20. století, konkrétně do roku 1943, kdy McCulloch a Pittse vytvořili první model neuronu. V roce 1949 se Donald Hebb ve své knize, Organization of Behavior, zabýval schopností učení neuronové sítě. Následovalo období, kdy se v této oblasti nic mimořádného nedělo, které však v roce 1982 narušil článek Johna Hopfielda. Po vydání článku se vědci opět začali více věnovat problematice neuronových sítí a výsledkem byl článek, který se zabýval učícím algoritmem, Back-Propagation, vydaný v roce 1986. Zájem o využití neuronových sítí a jejich význam rostl. Zejména pak jejich uplatnění ve zdravotnictví, letecké dopravě nebo ekonomii.[2]

Problematikou ohledně umělé inteligence a neuronových sítí ve vodním hospodářství se v České republice zabýval například profesor Miloš Starý ve své habilitační práci, která byla zaměřena na užití neuronových sítí v aplikované hydrologii. Na VUT v Brně se zabývají využitím předpovědních modelů při řízení vodohospodářské soustavy především, již zmíněný, prof. Ing. Miloš Starý, CSc., dále pak Ing. Pavel Menšík, Ph.D. a Ing. Daniel Marton, Ph.D. Předpovídáním střednědobých průtoků povrchových toků se zabýval, v dizertační práci, také Ing. Jiří Sázel, Ph.D.[3], který ve spolupráci s profesorem Starým, popisuje předpovídání průtoků pomocí modelu podobnosti. Využití neuronových sítí pro předpovídání průtoků se také zabíral Ing. Milan Šelep ve své diplomové práci, Střednědobá předpověď průtoků vody měrným profilem toku[4].

Jako další se v ČR problematikou předpovědí zabýval doc. Dr. Ing. Pavel Fošumpaur z ČVUT v Praze, který se zaměřil na porovnání nelineárního neuronového modelu a lineárního autoregresního modelu ARMAX[5].

Také Výzkumný ústav vodohospodářský TGM, se více jak patnáct let věnuje vývoji hydrologického modelu Bilan. Ten pro vybrané povodí simuluje složky hydrologické bilance na povrchu, v půdní zóně a v zóně podzemní vody.

Mezi slovenské autory patří např. Mgr. Daniela Svetlíková, Ph.D., která se v článku Hybridný model priemerných mesačných prietokov pre povodie horného Hrona[6], zabývala kombinací hydrologického a matematického modelu.

Mimo Evropu se předpovědí průtoků zabýval Amir F. Atiya a kolektiv. Ten se zaměřil na aplikování neuronových sítí při předpovídání průtoků v řece Nil v Egyptě a na porovnání modelů pracujících s neuronovými sítěmi[7]. Pro porovnání pak používal metodu časových řad. Dále se problematikou neuronových sítí a předpovídání průtoků zabývá prof. Chau a jeho spolupracovníci z Čínské lidové republiky[8].

1.2 CÍL PRÁCE

Diplomová práce si klade za cíl nalezení vhodného propojení mezi náhodně generovanými vstupy v podobě náhodných průběhů reálných průtokových řad, se standardně používanými hydrologickými předpovědními modely založenými na principech umělé inteligence a pravděpodobnostních modelů.

Dále bude cílem ověření vhodnosti postupů a následné sestavení stochastické předpovědi průměrných měsíčních průtoků ve vybraném vodoměrném profilu toku. Výsledná data nachystat tak, aby byla možnost je dále využít pro účely řízení nádrže, resp. vodohospodářské soustavy.

2. METODA

Pro úspěšné předpovědi průtoků v měrných profilech Skryje a Dalečín bylo zapotřebí dostatečné množství vstupních dat, ze kterých se predikce stanovuje. Od Českého hydrometeorologického ústavu byla získána data, která byla naměřena v jednotlivých profilech. Následně bylo z těchto dat generováno dalších třicet řad nejistotou zatížených vstupů pomocí metody Monte Carlo. Takto vygenerovaná data byla dále používána pro předpovědi pomocí neuronových sítí, kde byla rozdělena na vstupní, cílová a validační data. Po sestavení předpovědi byla pro porovnání, provedena předpověď také v zonálním pravděpodobnostním modelu pro vybrané roky. Z těchto předpovědi bylo následně provedeno vyhodnocení použitím koeficientu determinace. V závěrečné části byly pomocí čáry překročení pravděpodobnosti sestaveny scénáře předpovědi průtoků pro oba profily, které byly porovnány s originálním naměřeným průtokem.


2.1 METODA MONTE CARLO

Všechny zkoumané veličiny a procesy, které byly zatíženy nejistotou, mají v postupu zavedeny do řešení společný základ, kterým je aplikace metody Monte Carlo. Je to stochastická metoda, u které je přesnost a efektivnost dána kvalitou generátoru náhodných čísel, sestavením racionálního algoritmu, statistickým zpracováním a kontrolou přesnosti získaných výsledků. Pomocí této metody jsou generovány náhodné průběhy průtokových řad.[9]

Numerická metoda optimalizace, která spočívá v odstřelování oblasti $\langle a_{min}, a_{max} \rangle$ dostatečným počtem náhodně volených regresních koeficientů. Pro transformaci generovaných náhodných čísel $\xi \in \langle 0,1 \rangle$ na hodnotu regresního koeficientu je možné použít vztah:

$$a_i = a_{min} + (a_{max} - a_{min}) \cdot \xi_i. \quad (2.1)$$

U kvalitních generátorů náhodných čísel je hustota pravděpodobnosti generovaných náhodných čísel označována jako tzv. „bílý šum“. Mezi náhodnými čísly neexistuje žádná závislost (nulová autokorelační funkce) a jsou generovány se stejnou pravděpodobností.[9]




Obr. 2.1-1 Hustota pravděpodobnosti „bílého šumu“ [10]

Po dosažení řešení je možné, opakovaným postupem při zmenšení intervalu $\langle a_{\min}, a_{\max} \rangle$, opět prohledat okolí dosaženého regresního koeficientu. [9]

Použitím generátoru náhodných čísel a distribučních křivek jsou opakovaně generovány náhodné průběhy řady průměrných měsíčních průtoků. Každé hodnotě průměrného měsíčního průtoku Q_m odpovídá distribuční křivka, která je určena normálním rozdělením $N(\mu_i(Q_m), \sigma_i(Q_m))$, kde pro $i = 1, 2, \dots, n$, a n je počet všech prvků v řadě. [9]

Opakovaně generované náhodné průběhy řad průměrných měsíčních průtoků jsou značeny $NQ_{m,n}$, pro $n = 1, 2, \dots, PO$, kde PO je počet opakovaných generování. Výše popsáný princip je schematicky zobrazen na obr. 2.1-2. [9]



Obr. 2.1-2 Schéma generování náhodných řad průměrných měsíčních průtoků metodou Monte Carlo [11]

2.2 STANDARDIZACE DAT

Aby bylo možné úspěšně natrénovat neuronovou síť, je zapotřebí data nejprve transformovat. Pro neuronové sítě se používají obvykle intervaly pohybující se v blízkosti nuly, protože se ukázalo, že učení neuronové sítě je mnohem rychlejší, když jsou vstupní data symetrická. Při použití např. sigmoidy jako nelineární přenosové funkce budeme pro vstupní data používat interval (0,1), protože i výstupní data z této funkce leží v tomto intervalu. Tato transformace se nazývá standardizace nebo také normalizace dat. Výstupní data je zapotřebí následně transformovat zpět na hodnoty průtoků.

Standardizaci dat je možné provádět po směru sloupců, nebo jako v našem případě po směru řádků, pomocí následujícího vztahu.

$$x = \frac{Q_i - \frac{Q_{\max} + Q_{\min}}{2}}{\frac{Q_{\max} - Q_{\min}}{2}} \quad (2.2)$$


Kde: Q_i hodnota průtoku v čase,

$Q_{\max}$ maximální hodnota průtoku v daném řádku,

$Q_{\min}$ minimální hodnota průtoku v daném řádku.

2.3 NEURONOVÉ SÍTĚ

Neuronová síť je v podstatě algoritmus chovající se podle vzoru, který vychází z činnosti lidského mozku. Lidský mozek je tvořen velkým množstvím, které dosahuje mnoha biliónů, vzájemně propletených buněk. Tyto buňky nazýváme neurony a ty spolu komunikují pomocí elektrických impulzů.




Obr. 2.3-1 Biologický neuron [12]

Na obr 2.3-1 je zobrazen biologický neuron, který se skládá z těla neuronu, které také nazýváme soma. Z těla vybíhá nervové vlákno neboli axon. Toto nervové vlákno je zakončeno rozvětvením, které směřuje k ostatním nervovým buňkám v síti a s těmi tvoří elektronickou vazbu (synapse).

Dendrity, které spojují jednotlivé neurony pomocí synapsí, přenášejí vstupní signály do somy, kde jsou tyto signály sčítány a na základě jejich síly a povahy je rozhodnuto, zda budou propuštěny do axonu, případně s jakou silou. Následně dochází, pomocí axonu, k přenosu signálu s různou velikostí a zpožděním do ostatních neuronů. Dá se tak v podstatě říct, že každá buňka se chová jako extrémně jednoduchý počítač (Lawrence, 1994).

2.3.1 UMĚLÁ NEURONOVÁ SÍŤ

Umělá neuronová síť, která je vytvořena po vzoru biologické neuronové sítě, obsahuje síť mezi sebou propojených umělých neuronů.[12]



Obr. 2.3.1-1 Schéma umělého neuronu [13]

Na schématu umělého neuronu je vidět, že do neuronu směřují vstupní signály, které se vynásobí synoptickou vahou. Následně je odečtena prahová hodnota a zbytek je vynásoben přenosovou funkcí.

$$y_i = f \cdot (\sum_{i=1}^n x_i \cdot w_i - \theta) \quad (2.3)$$

Kde: y_i velikost výstupního signálu,


f přenosová funkce,

x_i velikost vstupního signálu,

w_i synoptická váha,

θ prahová hodnota.

Umělou neuronovou síť můžeme definovat jako orientovaný graf $G(N,H)$, kde množinu vrcholů N tvoří těla neuronů n_i a množinu hran H tvoří spojnice neuronů $h_{i,j}$. V grafu jsou jednotlivé neurony uspořádány do vrstev tak, že vstupní vrstvu tvoří vstupní neurony, následuje skrytá vrstva neuronů, kterých může být i více, a poslední je vrstva výstupních neuronů. Neurony jsou číslovány a každý neuron je spojen hranou s neuronem následující i předcházející vrstvy.



Obr. 2.3.1-2 Umělá neuronová síť [10]

2.3.2 TOPOLOGIE SÍTĚ

Dalším problémem, který je při konstrukci neuronové sítě potřeba vyřešit, je její topologie. Musí se zvážit k čemu má neuronová síť sloužit a podle toho učinit optimální volbu počtu neuronů a počtu skrytých vrstev. Na určení počtu neuronů a skrytých vrstev neexistují žádné vzorce ani pravidla. Postupuje se čistě experimentálně. Buď se zvolí počet skrytých vrstev a počet neuronů se určí jako průměr z počtu neuronů ve vstupní a výstupní vrstvě, nebo se začne s malým počtem neuronů a ten se postupně navyšuje, dokud se přesnost sítě nepřestane měnit. Z toho však plyne, že pokud bude síť obsahovat málo neuronů, nebude schopna dosahovat dostatečné přesnosti. Avšak pokud bude počet parametrů sítě větší než počet vzorů pro trénování, dojde k tzv. přetrénování sítě. Pokud se zvolí příliš mnoho skrytých neuronů, může nastat to, že si neuronová síť zapamatuje vzory, místo aby se podle nich učila. Při příliš malém počtu tréninkových vzorů může nastat problém, že se síť sice natrénuje, ale špatně.

V práci byla použita vícevrstvá síť se zpětným šířením učení (feed-forward back-propagation). V neuronové síti se během trénování mění hodnoty synaptických vah. Tento proces probíhá jak dopředně, tak zpětně od výstupní až do vstupní vrstvy. Během trénování jsou počítány odchylky mezi zadanými a vypočítanými výstupními signály. Odečtením součtu čtverců chyb vzorových a vypočítaných se získá rozdíl celkové chyby. Korekce vah při trénování je ukončena při dosažení optimální celkové chyby.[4]

2.4 VYHOTOVENÍ PŘEDPOVĚDI

Pro úspěšné předpovídání průtoků bylo zapotřebí nejprve nalézt ideální počet měsíců použitých jako vstup, tudíž kolik měsíců zpětně budeme brát jako výchozí matici dat. K tomu posloužil koeficient determinace, podle kterého se určila nejlepší shoda mezi predikovanými daty a počtem vstupujících měsíců. Délka předpovědi vpřed byla po zvážení zvolena na 1 měsíc vpřed. Při volbě optimální délky vstupní matice se postupovalo tak, že pro předpověď jednoho měsíce vpřed se nejprve použil jeden měsíc zpět. Jako další krok pak bylo použito dvou, tří až dvanácti měsíců zpět. Pro všechna predikovaná data byl vypočten koeficient determinace. Součtem průměrných hodnot koeficientů determinace se zjistilo, že nejlepších shod mezi předpovědi a měřenými daty bylo dosaženo při použití tří, deseti a dvanácti měsíců. Jednotlivé hodnoty součtů průměrných koeficientů determinace jsou znázorněny v tabulce 2.4-1. Hodnoty jsou pro přehlednost zvýrazněny barevnou škálou od červené do modré, kde červená barvy značí nejvyšší součet a modrá barva nejhorší. Pro konkrétní předpovědi průtoků, které jsou předpovídány v další části práce, bylo používáno dvanácti měsíců jako vstupní matice dat.

Tab. 2.4-1 Součet průměrných hodnot koeficientu determinace

PRŮMĚRNÉ R^2	
měsíců zpět	$\sum R^2$
1	2.88985
2	2.87319
3	2.88985
4	1.87088
5	2.09327
6	2.24771
7	2.24224
8	2.62903
9	2.81238
10	2.91754
11	2.77044
12	2.96409

2.5 VYHODNOCENÍ ÚSPĚŠNOSTI PŘEDPOVĚDI

Aby bylo možné určit, s jakou úspěšností se provedla předpověď, je zapotřebí stanovit míru shody mezi předpovězenými hodnotami a skutečnými hodnotami z validačního souboru dat, který byl odebrán ze vstupního souboru ještě před začátkem výpočtů. K tomu se ve vodním hospodářství obvykle používá koeficient determinace nebo koeficient korelace.

2.5.1 KOEFICIENT DETERMINACE

Koeficient determinace, který se značí R^2 , nabývá hodnot $<0;1>$ a nezávisí na počtu prvků vynášených na osu X. Přesnost předpovězených hodnot je odvislá od toho, jaké hodnoty dosáhne koeficient determinace. Čím blíže k horní hranici intervalu se výsledná hodnota pohybuje, tím vyšší je úspěšnost předpovědi. Je tedy možné říci, že když je hodnota nad 0,75, jedná se o dobrou shodu.

Koeficient determinace se spočítá podle následující rovnice.


$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}) \cdot (P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \cdot \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (2.4)[14]$$

Kde: O_i naměřená hodnota průtoku v čase,

$\bar{O}$ průměr z naměřených hodnot průtoků v čase,

P_i předpovězená hodnota průtoku v čase,

$\bar{P}$ průměr z předpovězených hodnot průtoků v čase.



Obr. 2.5.1-1 Ukázka koeficientu determinace [4]

2.5.2 KOEFICIENT KORELACE

Přesnost předpovědi je možné také určit podle koeficientu korelace, který se značí r a vyjadřuje míru lineární vazby mezi dvěma soubory. Výsledný koeficient se nachází v intervalu $<-1;1>$. Vazba mezi soubory je tím silnější, čím více se hodnota koeficientu blíží ke krajním hodnotám intervalu. Když se naopak hodnota koeficientu přibližuje k 0, pak je vazba nejslabší.

Koeficient korelace se spočítá pomocí následujících rovnice.

$$r = \frac{\sum \Delta O \cdot \Delta P}{\sqrt{\Delta O^2 \cdot \Delta P^2}} \quad (2.5)$$

$$\Delta O = O_i - \bar{O} \quad (2.6)$$


$$\Delta P = P_i - \bar{P} \quad (2.7)$$

Kde: O_i naměřená hodnota průtoku v čase,


$\bar{O}$ průměr z naměřených hodnot průtoků v čase,

P_i předpovězená hodnota průtoku v čase,

$\bar{P}$ průměr z předpovězených hodnot průtoků v čase.



Obr. 2.5.2-1 Ukázka koeficientu korelace s nulovou vazbou [4]



Obr. 2.5.2-2 Ukázka koeficientu korelace s nejlepší vazbou [4]

2.5.3 ČÁRA PŘEKROČENÍ PRAVDĚPODOBNOTI


Čára překročení udává, s jakou pravděpodobností bude náhodná veličina větší nebo rovna dané hodnotě. V praxi čára překročení udává, s jakou pravděpodobností bude dosažen nebo překročen určitý průtok.[15]

Sestrojení empirické čáry překročení se provede tak, že se nejprve setřídí všech n předpovězených průtoků v souboru podle velikosti od největšího po nejmenší. Následně se ke každé hodnotě dopočítá pravděpodobnost překročení podle Čegodajeva

$$p = \frac{m-0,3}{n+0,4} \cdot 100 [\%], \quad (2.8)$$

nebo, jako v našem případě, podle Golda

$$p = \frac{m}{n+1} \cdot 100 [\%]. [15] \quad (2.9)$$



Obr. 2.5.3-1 Ukázka čáry překročení pravděpodobnosti [10]

2.6 ZONÁLNÍ PRAVDĚPODOBNOSTNÍ PŘEDPOVĚDNÍ MODEL

V práci bylo provedeno porovnání přístupů hydrologickým predikcím pomocí druhého předpovědního modelu. Pro účely porovnání nám poslouží zonální pravděpodobnostní předpovědní model, který byl vytvořen na VUT v Brně.

Zonální pravděpodobnostní předpovědní model (ZPP) je program, který umožňuje předpovídat průměrné měsíční průtoky na základě aktuálního průtoky s možností volby předpovědi od jednoho po dvanáct měsíců.[16]

Model pracuje na principu, který spočívá z vyčlenění jednotlivých roků $y = 1, 2, \dots, Y$, z několikaleté průtokové řady, kde Y značí celkový počet let. Ze všech roků je následně pro každý měsíc $m = 1, 2, \dots, 12$ vyčleněna množina s průměrnými měsíčními průtoky Q_m pro každý rok množiny Y . Množinu Q_m tedy tvoří průměrné měsíční přítoky vody do nádrže za celé období Y , které odpovídá přítokům v měsíci m . Množina průměrných měsíčních průtoků Q_m je vyčleněna pro každý kalendářní měsíc, kde je následně nalezena maximální $\max Q_m$ a minimální hodnota $\min Q_m$. Interval mezi těmito hodnotami je následně rozdělen na zvolený počet zón. Tyto zóny je pak možné označit jako Z , kde počet zón Z je v každém měsíci stejný, ale velikost intervalu $\langle \min Q_m^Z, \max Q_m^Z \rangle$ může být rozdílná. Velikost zóny, pro jednotlivý měsíc m je stanovena požadavkem na splnění podmínky, že každá zóna musí obsahovat přibližně stejný $q_{m,y}$. Jednotlivé prvky $q_{m,y}$ následně tvoří v příslušné zóně podmnožinu Q_m^Z . [17]

Na základě počáteční průměrné hodnoty přítoku vody Q_m^c v měsíci m , ve kterém je rozhodováno o řízení, je vybrána zóna z , pro kterou platí $Q_m^c \in \langle \min Q_m^Z, \max Q_m^Z \rangle$. Touto zónou prochází vybraný soubor historických řad $s = 1, 2, \dots, S$, kde S je celkový počet řad procházející zónou. Pro každou řadu v souboru S platí, že $q_{m,s} \in Q_m^Z$. Další členy historických řad s souboru S , které jsou představovány průměrnými měsíčními přítoky $q_{m+t,s}$ v měsících $m + t$, kde t je pořadí měsíce předpovědi, jsou pak použity pro určení intervalu zóny předpovědi z_p . Pro t platí $t = 1, 2, \dots, TP$, kde TP je počet předpovídaných kroků (měsíců) a $q_{m+t,s} \in Q_{m+t}^{zp}$. Pro pořadí měsíců $m + t > 12$ platí $m + t - 12$. Pro každý měsíc předpovědi $m + t$ je stanovena pouze jedna zóna předpovědi z_p . [17]

Hodnota předpovězeného průměrného měsíčního přítoku vody do nádrže Q_{m+t}^p v měsíci $m + t$ je rovna hodnotě vyskytující se v intervalu zóny předpovědi z_p s největší pravděpodobností (modus). Průměrné měsíční průtoky jsou potom předpovězeny podle principu, že pro všechny prvky $q_{m+t,s}$ z množiny Q_{m+t}^{zp} je vytvořena hustota rozdělení pravděpodobnosti. Tvar spojitě funkce je pro zjednodušení trojúhelníkový. Spodní hrana je tvořena intervalem $\langle \min Q_{m+t}^{zp}, \max Q_{m+t}^{zp} \rangle$ a vrchol trojúhelníku odpovídá předpokládané poloze modu $Mod(q_{m+t,s})$ veličiny $q_{m+t,s}$. [17]

Výstup ze zonálního pravděpodobnostního předpovědního modelu tvoří předpovězené průměrné měsíční průtoky na jeden nebo více měsíců vpřed.[16]

Zonální pravděpodobnostní předpovědní model

Historické řady průměrných měsíčních průtoků

	1	2	3	4	5	6	7	8	9	10	11	12
	0.4447	0.3641	0.1942	0.1517	1.6305	1.2845	0.9272	0.6474	3.0566	0.661	0.386	0.9872
	0.6204	3.8741	3.3238	2.063	6.3519	5.4214	1.1132	0.6464	0.9592	1.0534	0.7187	0.6323
	0.3621	1.3831	0.8114	0.3412	3.9708	3.7784	2.5251	1.3326	0.3869	0.6755	0.2655	1.0588
	2.7553	2.5704	1.8671	2.6586	3.2589	2.9635	0.7097	0.506	0.7832	0.7367	0.6869	0.5789
	0.505	0.6089	0.6598	2.9701	1.8622	3.2054	0.8491	0.4525	0.6074	0.2279	0.5371	1.6805
	0.8317	1.1761	1.812	1.6362	1.3612	0.8787	0.7009	0.3076	0.872	0.5882	0.2697	0.2577
	0.2994	0.5203	0.7812	1.9427	3.0641	1.1342	0.6839	1.7169	1.3109	1.9671	1.7599	2.8593
	1.5188	1.5177	0.8427	3.9254	2.1401	1.5275	0.9432	3.3401	0.7689	0.4728	0.3019	0.6538
	0.6061	1.2289	1.2389	1.3856	3.014	5.5154	3.9609	1.4589	0.8089	0.3701	0.2817	0.4772
	1.0548	0.3964	0.3686	0.3502	3.6714	2.4605	2.7128	1.1681	0.4694	0.3532	0.7986	0.7277
	1.0239	0.329	0.081	0.3408	2.7486	1.5762	0.6703	0.8473	0.4349	0.5752	0.4032	1.231
	1.14	1.1749	1.4518	1.5212	7.3845	5.5483	3.8478	5.9645	3.7388	1.147	1.0182	0.854
	0.9123	1.2525	0.9595	5.4404	1.5913	1.2553	1.0424	0.9499	3.8622	2.0063	1.5776	0.7258

Načtení řad ze souboru

Aktuální velikost průtoků: m³.s⁻¹

Měsíc měření aktuálního průtoků:

Počet předpovídaných měsíců:

Kalibrace modelu

Předpovězené průměrné měsíční průtoky


0.68 1.15 0.44 1.46 2.78 0.84 0.68 0.45 0.46 0.19 0.45 0.46

Spuštění modelu

Obr. 2.6-1 Ukázka zonálního pravděpodobnostního předpovědního modelu


3. SESTAVENÍ PŘEDPOVĚDNÍHO MODELU

Diplomová práce se může pomyslně rozdělit na dvě části. První část se zabývá nalezením optimální délky vstupní matice dat pomocí koeficientu determinace a celkovým zautomatizováním jednotlivých kroků postupu. Druhá část se potom věnuje praktické aplikaci na profilech Skryje a Dalečín. Jednotlivé nastavování a testování nejprve probíhalo na profilu Skryje, kde se vybral nejvíce vodný, nejméně vodný, průměrný a náhodně zvolený rok, pro který se vyhotovila předpověď průměrných měsíčních průtoků. Pro stejné roky se poté provedla předpověď i na profilu Dalečín. Postup jednotlivých kroků přibližuje schéma na následujícím obrázku.




Obr. 3-1 Schéma postupu zpracování dat

Schéma se dá rozdělit do třech menších částí, kde v první části probíhá zpracování vstupních dat, která byla získána od Českého hydrometeorologického ústavu a z nich následně odvozena řada třiceti vstupů zatížených nejistotou.




Obr. 3-2 Schéma úpravy vstupních dat

V druhé části probíhá zpracování upravených dat v programu MATLAB, který data načte, natrénuje a následně provede simulaci. Predikovaná data následně vyexportuje zpět do vstupního souboru, kde jsou připravena na další zpracování.



Obr. 3-3 Schéma práce s daty v MATLABu


Ve třetí části probíhá výsledné zpracování predikovaných dat, která jsou převáděna zpět na průtoky, poté jsou porovnávána se vstupními daty pomocí koeficientu determinace a graficky vyhodnocena. Následně jsou vytvořeny scénáře pro pesimistickou, optimistickou a neutrální předpověď.



Obr. 3-4 Schéma vyhodnocení dat.

4. PRAKTICKÁ APLIKACE PŘEDPOVĚDNÍHO MODELU

Základní data potřebná pro práci byla získána od Českého hydrometeorologického ústavu. Jednalo se o dva soubory průměrných měsíčních průtoků, měřených kontinuálně od roku 1953 do roku 2008, na profilech Skryje na řece Loučka a Dalečín na řece Svatce. Tato data byla hned na začátku zatížena 5% vstupní nejistotou, abychom dostali větší množství dat pro výpočet. Konkrétně nám vznikly body v rozsahu $\pm 15\%$ okolo naměřených bodů. Z toho vzniklo 30 souborů dat, každý s řadou průměrných měsíčních průtoků za období 56 let.



Obr. 4-1 Umístění profilů v ČR [18]



Obr. 4-2 Umístění profilů v povodí Dyje [19]

Evidenční list hlášeného profilu č.372a																																																					
Stanice kategorie : B																																																					
Tok:	Loučka (Bobruvka)				Stanice:	Skryje																																															
Kraj:	Jihomoravský kraj				ORP:	Tišnov		Obec:																																													
Provozovatel stanice:					ČHMÚ Brno																																																
Centrum automatického sběru dat:					RPP ČHMÚ Brno																																																
Staničení:	10,25	[km]	Číslo hydrologického pořadí:			4-15-01-096																																															
Plocha povodí:	222,01	[km ²]	Zeměpisné souřadnice:			161912 v.d. 492247 s.š.																																															
Nula vodočtu:	310,06	[m.n.m.]	Procento plochy povodí toku:			57,0																																															
Stupně povodňové aktivity:		[cm]	[m ³ .s ⁻¹]		Platnost SPA pro úsek toku:																																																
bdělost		90	12		Skryje - Dolní Loučky																																																
pohotovost		120	24,1		Kritické místo:																																																
ohrožení		150	37,2																																																		
Průměrný roční stav:	40	[cm]	N-leté průtoky:		Q ₁	Q ₅	Q ₁₀	Q ₅₀	Q ₁₀₀																																												
Průměrný roční průtok:	1,47	[m ³ .s ⁻¹]	[m ³ .s ⁻¹]		17	35,1	44,3	68,4	80																																												
Odesílatel zpráv:			Četnost hlášení SPA:		I.	1x denně																																															
OÚ Horní Loučky					II.	4x denně																																															
					III.	3hodinové hlášení																																															
Odesílatel podá zprávu:			Spojení na adresáta:			Příjemce dále vyrozumí:																																															
Nejvyšší zaznamenané vodní stavy: <table style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="width: 10%;">[cm]</th> <th style="width: 10%;">V. - XI.</th> <th style="width: 10%;">[cm]</th> <th style="width: 10%;">XII. - IV.</th> </tr> </thead> <tbody> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> <tr><td> </td><td> </td><td> </td><td> </td></tr> </tbody> </table> Popis umístění profilu : ca 200 m nad silničním mostem (k bývalé továrněTylex), levý břeh Mapa v měřítku 1:50 000 : 										[cm]	V. - XI.	[cm]	XII. - IV.																																								
[cm]	V. - XI.	[cm]	XII. - IV.																																																		

30

Druhý profil je v kraji Vysočina na toku Svratka, která protéká obcí Dalečín ležící nad vodní nádrží Vír I.

Evidenční list hlášeného profilu č.371									
Stanice kategorie : A									
Tok:	Svratka	Stanice:	Dalečín						
Kraj:	Vysočina	ORP:	Bystřice nad Pernštejnem	Obec:	Dalečín				
Provozovatel stanice:		ČHMÚ Brno			Předpovědní profil ČHMÚ PP*				
Centrum automatického sběru dat:		RPP ČHMÚ Brno, VHD Povodí Moravy Brno							
Staničení:	125,70 [km]	Číslo hydrologického pořadí:	4-15-01-033						
Plocha povodí:	366,94 [km²]	Zeměpisné souřadnice:	161448 v.d. 493543 s.š.						
Nula vodočtu:	470,07 [m.n.m.]	Procento plochy povodí toku:	9,1						
Stupně povodňové aktivity:		[cm]	[m³.s⁻¹]	Platnost SPA pro úsek toku:					
bdělost		120	24,6	Jimramov - VD Vír					
pohotovost		150	42,5	Kritické místo:					
ohrožení		180	63,5						
Průměrný roční stav:	65 [cm]	N-leté průtoky:	Q ₁	Q ₅	Q ₁₀	Q ₅₀	Q ₁₀₀		
Průměrný roční průtok:	3,44 [m³.s⁻¹]	[m³.s⁻¹]	39,2	73,9	91,6	139	162		
Odesílatel zpráv:	Četnost hlášení SPA:	I.	1 x denně						
OÚ Dalečín		II.	4 x denně						
		III.	3hodinové hlášení						
Odesílatel podá zprávu:		Spojení na adresáta:				Příjemce dále vyrozumí:			
MěÚ Bystřice nad Pernštejnem		566590313, 566590321, 566590300, 725105421, 603582659				OÚ Strachujov, OÚ Unčín			
HZS Bystřice nad Pernštejnem		566552222							
VHD Povodí Moravy Brno		541 211 737, 541 637 250				Povodí Moravy - obsluha VD Vír			
RPP ČHMÚ Brno		541212485, 541421071, fax 541421018							
Nejvyšší zaznamenané vodní stavy:			Mapa v měřítku 1:50 000 :						
[cm]	V. - XI.	[cm]	XII. - IV.						
263	08.07.1997	194	25.03.1955						
232	17.07.1965	235	31.03.2006						
163	21.10.1960	190	31.03.1962						
156	07.06.1964	180	08.12.1974						
		179	28.12.1954						
Popis umístění profilu :									
silniční most pod továrnou KOH-I-NOR, levý břeh									

Obr. 4-4 Evidenční list profilu Dalečín č. 371 [19]

4.6 PŘÍPRAVA DAT PRO ZPRACOVÁNÍ

Veškerá vstupní data se musí ještě před vstupem do programu MATLAB, kde bude provedeno jejich načtení pro neuronové sítě, upravit. Úprava spočívá v tom, že se provede výše zmíněná standardizace a transformace dat pro lepší manipulaci s daty. Následně jsou data připravena pro načtení. Při načítání se data dělí na vstupní data, validační data a cílová data. Pro diplomovou práci byla získána data ve formátu hydrologického roku, tzn. od listopadu do října následujícího roku. Pro oba profily máme řadu 56 let po sobě jdoucích a to od roku 1953 až do roku 2008. Pro práci bylo použito vždy prvních 46 let a posledních 10 let sloužilo pouze jako validační soubor pro stanovení přesnosti předpovědi. Ze vstupní řady 46 let poté byly vybrány nejvíce vodný rok (12), nejméně vodný rok (38), průměrně vodný rok (8) a nakonec náhodně zvolený rok (40).

Standardizace dat

Standardizace neboli normalizace dat slouží ke zpřesnění a zrychlení trénování dat. Postup standardizace se provede pomocí rovnice (2.2), popsané v kapitole 2.2. Po provedené standardizaci jsou data v intervalu $<-1;1>$.

Tab. 4.6-1 Ukázka vstupních dat před standardizací

rok	poř. číslo	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
1953	1	0.445	0.364	0.194	0.152	1.631	1.285	0.927	0.647	3.057	0.661	0.386	0.987
1954	2	0.620	3.874	3.324	2.063	6.352	5.421	1.113	0.646	0.959	1.053	0.719	0.632
1955	3	0.362	1.383	0.811	0.341	3.971	3.778	2.525	1.333	0.387	0.676	0.266	1.059
1956	4	2.755	2.570	1.867	2.659	3.259	2.964	0.710	0.506	0.783	0.737	0.687	0.579
1957	5	0.505	0.609	0.660	2.970	1.862	3.205	0.849	0.453	0.607	0.228	0.537	1.681
1958	6	0.832	1.176	1.812	1.636	1.361	0.879	0.701	0.308	0.872	0.588	0.270	0.258
1959	7	0.299	0.520	0.781	1.943	3.064	1.134	0.684	1.717	1.311	1.967	1.760	2.859
1960	8	0.606	1.229	1.239	1.386	3.014	5.515	3.961	1.459	0.809	0.370	0.282	0.477
1961	9	1.055	0.396	0.369	0.350	3.671	2.461	2.713	1.168	0.469	0.353	0.799	0.728
1962	10	1.024	0.329	0.081	0.341	2.749	1.576	0.670	0.847	0.435	0.575	0.403	1.231

Tab. 4.6-2 Ukázka vstupních dat po standardizaci

rok	poř. číslo	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
1953	1	-0.798	-0.854	-0.971	-1.000	0.018	-0.220	-0.466	-0.659	1.000	-0.649	-0.839	-0.425
1954	2	-1.000	0.135	-0.057	-0.497	1.000	0.675	-0.828	-0.991	-0.882	-0.849	-0.966	-0.996
1955	3	-0.948	-0.397	-0.705	-0.959	1.000	0.896	0.220	-0.424	-0.934	-0.779	-1.000	-0.572
1956	4	0.634	0.500	-0.011	0.564	1.000	0.785	-0.852	-1.000	-0.799	-0.832	-0.869	-0.947
1957	5	-0.814	-0.744	-0.710	0.842	0.098	1.000	-0.583	-0.849	-0.745	-1.000	-0.792	-0.024
1958	6	-0.261	0.182	1.000	0.774	0.420	-0.201	-0.430	-0.936	-0.210	-0.575	-0.985	-1.000
1959	7	-1.000	-0.840	-0.651	0.189	1.000	-0.396	-0.722	0.025	-0.268	0.206	0.057	0.852
1960	8	-0.876	-0.638	-0.634	-0.578	0.044	1.000	0.406	-0.550	-0.799	-0.966	-1.000	-0.925
1961	9	-0.576	-0.972	-0.989	-1.000	1.000	0.271	0.423	-0.507	-0.928	-0.998	-0.730	-0.773
1962	10	-0.293	-0.814	-1.000	-0.805	1.000	0.121	-0.558	-0.425	-0.735	-0.629	-0.758	-0.138

4.7 POSTUP ZPRACOVÁNÍ DAT

4.7.1 NAČTENÍ DAT

Připravená data bylo možné dále zpracovávat v programu MATLAB. Nejprve jsou data načtena, přímo z aplikace Excel, do paměti programu a roztržena na vstupní (input), cílová (target) a validační (sample). Vstupní i cílová data slouží pro trénink neuronové sítě a validační data slouží pro simulaci.

Data lze načítat pomocí příkazu `xlsread`, ve kterém se volí zdroj dat a název pod kterým se mají data načíst.

```
%načtení více řad (input, target, sample)
%načtení pomocí xlsread
%načítám jednotlivé průtokové řady z jednoho souboru
spojeni=ddeinit('excel','DP_data.xls'); %navázání spojení s excelem
%input data 1 (listopad - říjen)
input1_01=xlsread('DP_data', 1, 'AC1:BV1 ');
input1_02=xlsread('DP_data', 1, 'AC2:BV2 ');
input1_03=xlsread('DP_data', 1, 'AC3:BV3 ');
input1_04=xlsread('DP_data', 1, 'AC4:BV4 ');
input1_05=xlsread('DP_data', 1, 'AC5:BV5 ');
input1_06=xlsread('DP_data', 1, 'AC6:BV6 ');
input1_07=xlsread('DP_data', 1, 'AC7:BV7 ');
input1_08=xlsread('DP_data', 1, 'AC8:BV8 ');
input1_09=xlsread('DP_data', 1, 'AC9:BV9 ');
input1_10=xlsread('DP_data', 1, 'AC10:BV10 ');
input1_11=xlsread('DP_data', 1, 'AC11:BV11 ');
input1_12=xlsread('DP_data', 1, 'AC12:BV12 ');
```

Obr. 4.7.1-1 Ukázka načítání dat v MATLABu - input

```
%target data 1 (listopad - říjen)
target1_01=xlsread('DP_data', 1, 'AC2:BV2 ');
target1_02=xlsread('DP_data', 1, 'AC3:BV3 ');
target1_03=xlsread('DP_data', 1, 'AC4:BV4 ');
target1_04=xlsread('DP_data', 1, 'AC5:BV5 ');
target1_05=xlsread('DP_data', 1, 'AC6:BV6 ');
target1_06=xlsread('DP_data', 1, 'AC7:BV7 ');
target1_07=xlsread('DP_data', 1, 'AC8:BV8 ');
target1_08=xlsread('DP_data', 1, 'AC9:BV9 ');
target1_09=xlsread('DP_data', 1, 'AC10:BV10 ');
target1_10=xlsread('DP_data', 1, 'AC11:BV11 ');
target1_11=xlsread('DP_data', 1, 'AC12:BV12 ');
target1_12=xlsread('DP_data', 1, 'AC13:BV13 ');
```

Obr. 4.7.1-2 Ukázka načítání dat v MATLABu – target

```

%sample data 1 (listopad - říjen)
sample1_01=xlsread('DP_data', 1, 'BW2:CF2 ');
sample1_02=xlsread('DP_data', 1, 'BW3:CF3 ');
sample1_03=xlsread('DP_data', 1, 'BW4:CF4 ');
sample1_04=xlsread('DP_data', 1, 'BW5:CF5 ');
sample1_05=xlsread('DP_data', 1, 'BW6:CF6 ');
sample1_06=xlsread('DP_data', 1, 'BW7:CF7 ');
sample1_07=xlsread('DP_data', 1, 'BW8:CF8 ');
sample1_08=xlsread('DP_data', 1, 'BW9:CF9 ');
sample1_09=xlsread('DP_data', 1, 'BW10:CF10 ');
sample1_10=xlsread('DP_data', 1, 'BW11:CF11 ');
sample1_11=xlsread('DP_data', 1, 'BW12:CF12 ');
sample1_12=xlsread('DP_data', 1, 'BW13:CF13 ');


```

Obr. 4.7.1-3 Ukázka načítání dat v MATLABu - sample

Po načtení jsou data uložena v pracovním prostoru, odkud se načítají při dalším zpracování, kterým je načtení do neuronové sítě.

4.7.2 PRÁCE S NEURONOVÝMI SÍTĚMI V PROSTŘEDÍ MATLAB POMOCÍ OKNA DATA MANAGER


Práce s neuronovými sítěmi v prostředí MATLAB je možná dvěma způsoby. Prvním způsobem je pomocí jednoduchého prostředí nástroje Neural Network Toolbox, který je předinstalovaný do aplikace již od výrobce.



Obr. 4.7.2-1 Ukázka nástroje pro práci s NS – nntool


Při práci s oknem Neural Network/Data Manager je zapotřebí nejprve zvolit vstupní, cílová a validační data, která se nahrají z pracovního prostoru do příslušných oken.

Když jsou data roztržiděna, může se pokračovat ve tvorbě neuronové sítě a následnému trénování.




Obr. 4.7.2-2 Ukázka tvorby neuronové sítě

Pokud je vše nastaveno, může se přejít k trénování neuronové sítě.




Obr. 4.7.2-3 Ukázka trénování neuronové sítě

Po úspěšném natrénování se provede simulace a výstupem je výsledná predikce průtoků.



Obr. 4.7.2-4 Ukázka simulace neuronové sítě

Jako poslední krok je export výsledné predikce zpět do souboru s upravenými vstupními daty.



Obr. 4.7.2-5 Ukázka exportu predikovaných dat

Celý tento způsob je přehledný, ale při větším množství dat poměrně dost zdlouhavý. To nás vede k druhému způsobu práce s neuronovými sítěmi v MATLABu.

4.7.3 PRÁCE S NEURONOVÝMI SÍTĚMI V PROSTŘEDÍ MATLAB POMOCÍ KÓDŮ

Druhým způsobem je sepsání jednotlivých kroků, které se dělají v prvním způsobu, pomocí programovacích kódů v prostředí MATLAB. Psaní kódů je poněkud složitější oproti první variantě, ale je to výrazné usnadnění a zrychlení postupu při větším množství dat.

Vytvoření neuronové sítě, trénování i simulaci lze sepsat pomocí příkazů, které se postupně spouští. Do jednotlivých příkazů se zapíše jednotlivá nastavení pro neuronovou síť, trénování i pro simulaci.

```
%Neuronove site: nacteni, trenovani, predpoved ve vystupnim souboru output
%Data_1
%Načtení neuronové sítě 1
net1_01=newff(input1_01,target1_01, [5 1],{'logsig' 'purelin'},'trainlm','learngdm','mse');
%trénování neuronové sítě 1
net.trainParam.epochs=1000;
net.trainParam.goal=0;
net.trainParam.mu=1;
[net1_01,tr]=train(net1_01,input1_01,target1_01);
%simulace neuronové sítě 1
output1_01=sim(net1_01,sample1_01);
```

Obr. 4.7.3-1 Ukázka neuronové sítě pomocí skriptu

Dalším krokem už bylo vyexportování jednotlivých řad předpovězených průtoků zpět do Excelu. Na to slouží jednoduchý příkaz export, ve kterém se zvolí výstupní soubor a místo kam se mají data vyexportovat.

```
%export dat (output/předpovědi) z matlabu do excelu
xlswrite('DP_data',output1_01, 1, 'CH1:CQ1 ')
xlswrite('DP_data',output1_02, 1, 'CH2:CQ2 ')
xlswrite('DP_data',output1_03, 1, 'CH3:CQ3 ')
xlswrite('DP_data',output1_04, 1, 'CH4:CQ4 ')
xlswrite('DP_data',output1_05, 1, 'CH5:CQ5 ')
xlswrite('DP_data',output1_06, 1, 'CH6:CQ6 ')
xlswrite('DP_data',output1_07, 1, 'CH7:CQ7 ')
xlswrite('DP_data',output1_08, 1, 'CH8:CQ8 ')
xlswrite('DP_data',output1_09, 1, 'CH9:CQ9 ')
xlswrite('DP_data',output1_10, 1, 'CH10:CQ10 ')
xlswrite('DP_data',output1_11, 1, 'CH11:CQ11 ')
xlswrite('DP_data',output1_12, 1, 'CH12:CQ12 ')
```

Obr. 4.7.3-2 Ukázka exportu dat

4.8 NASTAVENÍ NEURONOVÉ SÍTĚ

Nastavení neuronové sítě bylo provedeno podle diplomové práce [4], která byla zpracována v předchozích letech a zabírala se střednědobou předpovědí průtoků měrným profilem toku.

Struktura sítě byla nastavena jako dvouvrstvá s jednou skrytou a jednou výstupní vrstvou. Počet neuronů ve skryté vrstvě byl nastaven na pět a výstupní vrstvě na jeden. Jako aktivační funkce ve skryté vrstvě byla zvolena logická sigmoidální (*logsig*) a ve výstupní vrstvě lineární (*purelin*). Pro trénování byla vybrána funkce *trainlm*, která upravuje hodnoty synoptických vah. Učící se funkce byla zvolena *learngdm*. Validační funkce byla defaultně nastavena na *mse*, což je průměr kvadratických normalizovaných chyb. Pro trénink bylo zvoleno 1000 tréninkových epoch a koeficient *mu* byl zvolen 1.[4]

4.9 VYHODNOCENÍ DAT

Vyhodnocení dat se dělí na dvě části. První část určí optimální délku matice vstupních dat pro předpověď. V druhé části bude vyhodnocena praktická aplikace a předpověď průtoků pro extrémně vodný, málo vodný, průměrný a náhodně zvolený rok pro měrný profil Skryje a pro měrný profil Dalečín.

4.9.1 NALEZENÍ OPTIMÁLNÍ DÉLKY VSTUPNÍ MATICE DAT

Pro stanovení optimálního počtu vstupních měsíců pro předpověď bylo využito koeficientu determinace. Výpočet koeficientu je uveden v kapitole 2.5.1. Konkrétně byly použity sumy průměrných hodnot koeficientů determinací pro jednotlivé délky vstupů. V následující tabulce je přehledně zobrazen výpis všech průměrných koeficientů determinace pro jednotlivé délky i s jejich sumami.

Tab. 4.9.1-1 Sumy průměrů koeficientů determinace

měsíců zpět	PRŮMĚRNÉ KOEFICIENTY DETERMINACE													
	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen	průměr	suma
1	0.13133	0.06124	0.19558	0.00533	0.69498	0.57668	0.29757	0.15730	0.15721	0.30451	0.24958	0.05854	0.24082	2.88985
2	0.50733	0.16773	0.43732	0.06261	0.10001	0.47683	0.06164	0.15927	0.03563	0.67176	0.17005	0.02300	0.23943	2.87319
3	0.13133	0.06124	0.19558	0.00533	0.69498	0.57668	0.29757	0.15730	0.15721	0.30451	0.24958	0.05854	0.24082	2.88985
4	0.14695	0.24651	0.38425	0.02082	0.18603	0.23103	0.03832	0.17933	0.11230	0.25450	0.02287	0.04794	0.15591	1.87088
5	0.19500	0.23141	0.37257	0.02757	0.27829	0.17425	0.05060	0.17342	0.14557	0.38834	0.02376	0.03248	0.17444	2.09327
6	0.23062	0.24158	0.35268	0.01484	0.29762	0.23277	0.06379	0.17269	0.22134	0.36818	0.01713	0.03445	0.18731	2.24771
7	0.20582	0.23865	0.34583	0.01341	0.30011	0.22408	0.05441	0.19017	0.24447	0.35657	0.01533	0.05338	0.18685	2.24224
8	0.25699	0.25322	0.37117	0.01193	0.39505	0.35548	0.05961	0.26176	0.24069	0.33693	0.03801	0.04819	0.21909	2.62903
9	0.22525	0.24186	0.35449	0.01765	0.52102	0.41627	0.11147	0.26196	0.25511	0.35705	0.01930	0.03096	0.23437	2.81238
10	0.24389	0.25007	0.35815	0.01322	0.57542	0.49993	0.16593	0.15527	0.24704	0.33169	0.02592	0.05099	0.24313	2.91754
11	0.25317	0.23978	0.31330	0.01480	0.45988	0.58268	0.16848	0.17710	0.22683	0.28623	0.00800	0.04022	0.23087	2.77044
12	0.22679	0.22368	0.22034	0.02133	0.43896	0.72624	0.26399	0.16883	0.25443	0.34553	0.01886	0.05511	0.24701	2.96409


Nejlepší hodnoty podle tabulky vychází pro vstupní délku 12 měsíců. Druhou nejlepší hodnotu dosahovali predikce tehdy, když vstupní soubor obsahoval deset měsíců zpět.

4.10 PŘEDPOVĚDI PRŮTOKŮ


Praktická aplikace spočívala ve stanovení předpovědi průtoků pro předem vybrané roky a následné porovnání předpovězených průtoků s validačním souborem, který byl odebrán ze vstupní řady. V první části byl získán optimální počet měsíců pro předpověď jednoho měsíce vpřed a tento poznatek se následně aplikuje na předpověď konkrétních dat v konkrétních profilech. Předpověď probíhala tak, že pro každý měsíc předpovědi bylo načteno předchozích dvanáct měsíců, následně se provedla rotace o jeden měsíc vřed a znovu se postup opakoval. Takto se postupovalo, dokud nebyla předpovězena celá řada.

Předpověď byla prováděna postupně pro nejvíce vodný, nejméně vodný a průměrný rok v profilu Skryje. Jako další pak byl vybrán náhodně zvolený rok a pro ten se stanovila předpověď také. Celý postup se opakoval totožně i na měrném profilu Dalečín, kde byly zvoleny roky, které odpovídaly rokům předpovídaným v profilu Skryje.


Na obrázcích 4.10-1 až 4.10-4 je zobrazeno porovnání předpovědi průměrných měsíčních průtoků s originálními průtoky pro roky 1961 (průměrně vodný rok), 1965 (nejvíce vodný rok), 1991 (nejméně vodný rok) a 1993 v profilu Skryje.




Obr. 4.10-1 Porovnání predikce a skutečnosti pro průměrně vodný rok v profilu Skryje



Obr. 4.10-2 Porovnání predikce a skutečnosti pro nejvíce vodný rok v profilu Skryje




Obr. 4.10-3 Porovnání predikce a skutečnosti pro nejméně vodný rok v profilu Skryje




Obr. 4.10-4 Porovnání predikce a skutečnosti pro náhodně zvolený rok v profilu Skryje


Na obrázcích 4.10-5 až 4.10-8 je zobrazeno porovnání předpovědi průměrných měsíčních průtoků s originálními průtoky pro roky 1961 (průměrně vodný rok), 1965 (nejvíce vodný rok), 1991 (nejméně vodný rok) a 1993 v profilu Dalečín.




Obr. 4.10-5 Porovnání predikce a skutečnosti pro průměrně vodný rok v profilu Dalečín



Obr. 4.10-6 Porovnání predikce a skutečnosti pro nejvíce vodný rok v profilu Dalečín



Obr. 4.10-7 Porovnání predikce a skutečnosti pro nejméně vodný rok v profilu Dalečín




Obr. 4.10-8 Porovnání predikce a skutečnosti pro náhodně zvolený rok v profilu Dalečín


V dalším kroku byla provedena předpověď pro data, která byla náhodně vygenerována z původních originálních dat. Data byla předpovídána stejným způsobem jako v předcházející části a výstupem byly opět předpovězené roky s maximálním, minimálním a průměrným měsíčním průtokem. Stejně tak byl k těmto třem rokům přidán náhodně vybraný rok, který se shoduje s rokem předpovídaným u ordinálních vstupních dat.

Podobně jako v předešlé části, tak i zde obrázky 4.10-9 až 4.10-12 zobrazují porovnání předpovědi průměrných měsíčních průtoků, z vygenerovaných dat, s originálními průtoky pro roky 1961 (průměrně vodný rok), 1965 (nejvíce vodný rok), 1991 (nejméně vodný rok) a 1993 v profilu Skryje.


V grafech je tlustou červenou čarou zobrazen průběh originálně naměřených dat a jednotlivé čáry pak zobrazují předpovědi pro jednotlivá vygenerovaná data.




Obr. 4.10-9 Porovnání predikce pro generovaná data a skutečnosti pro průměrně vodný rok v profilu Skryje



Obr. 4.10-10 Porovnání predikce pro generovaná data a skutečnosti pro extrémně vodný rok v profilu Skryje




Obr. 4.10-11 Porovnání predikce pro generovaná data a skutečnosti pro nejméně vodný rok v profilu Skryje




Obr. 4.10-12 Porovnání predikce pro generovaná data a skutečnosti pro náhodně zvolený rok v profilu Skryje


Stejným způsobem byla vyhodnocena i vygenerovaná data pro profil Dalečín. Taktéž i v těchto grafech je tlustou červenou čarou zobrazen průběh originálně naměřených dat a jednotlivé čáry zobrazují předpovědi pro jednotlivá vygenerovaná data.




Obr. 4.10-13 Porovnání predikce pro generovaná data a skutečnosti pro průměrně vodný rok v profilu Dalečín



Obr. 4.10-14 Porovnání predikce pro generovaná data a skutečnosti pro extrémně vodný rok v profilu Dalečín




Obr. 4.10-15 Porovnání predikce pro generovaná data a skutečnosti pro nejméně vodný rok v profilu Dalečín




Obr. 4.10-16 Porovnání predikce pro generovaná data a skutečnosti pro náhodně zvolený rok v profilu Dalečín

Pro porovnání s výstupy, které nám vyšly pomocí neuronových sítí, byly pomocí zonálního pravděpodobnostního předpovědního modelu předpovězeny průtoky pro extrémně vodný rok a málo vodný rok. Na obrázcích 4.10-17 a 4.10-18 jsou zobrazeny průběhy předpovězených průměrných měsíčních průtoků a originální naměřená data v profilu Skryje.




Obr. 4.10-17 Porovnání predikce a skutečného průtoků pro extrémně vodný rok v profilu Skryje




Obr. 4.10-18 Porovnání predikce a skutečného průtoků pro málo vodný rok v profilu Skryje

Na obrázcích 4.10-19 a 4.10-20 jsou také zobrazeny průběhy průměrných měsíčních průtoků předpovězených zonálním pravděpodobnostním předpovědním modelem v porovnání s originálními naměřenými daty, tentokrát však v profilu Dalečín.



Obr. 4.10-19 Porovnání predikce a skutečného průtoků pro extrémně vodný rok v profilu Dalečín



Obr. 4.10-20 Porovnání predikce a skutečného průtoků pro málo vodný rok v profilu Dalečín

5. SHRHNUTÍ VÝSLEDKŮ


Výsledkem práce předchozích kapitol bylo stanovení předpovědi hodnot průměrných měsíčních průtoků ve vybraných vodoměrných profilech. Dále byly tyto výstupy zpracovávány tak, aby se mohly určit scénáře pro průběh průtoků. Scénáře byly stanovovány jako pesimistická, optimistická a neutrální předpověď. Vycházejí z čáry překročení pravděpodobnosti, která byla sestrojena z předpovězených průtoků. Čára překročení nám udává, s jakou pravděpodobností bude dosažen nebo překročen předpovězený průtok vycházející z náhodně generovaných vstupních dat.

Nejprve byla vypočtena pravděpodobnost překročení podle Golda a následně byly seřazeny předpovězené průtoky od největšího po nejmenší.

Tab. 5-1 Data pro čáry překročení pravděpodobnosti v profilu Skryje

data/měsíc	p	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
n		Q _m	Q _m	Q _m	Q _m	Q _m	Q _m	Q _m	Q _m	Q _m	Q _m	Q _m	Q _m
1	0.0333	3.6758	3.5788	5.0024	7.3036	5.9087	3.5021	2.9240	2.9831	2.0280	1.5339	2.1278	2.6359
2	0.0667	3.6248	3.1786	4.7088	6.3168	5.2603	3.3817	2.5604	2.5340	1.8671	1.4886	2.0298	2.5289
3	0.1000	3.4264	3.1311	4.6502	6.1960	5.0306	3.1934	2.4277	2.4651	1.8152	1.4482	1.8175	2.1481
4	0.1333	3.3492	3.0965	4.6462	6.1605	4.9363	3.1781	2.4016	2.3501	1.7514	1.4140	1.8170	2.1393
5	0.1667	3.2712	3.0065	4.6234	6.1032	4.8988	3.0222	2.3437	2.2078	1.7327	1.4018	1.8075	2.1315
6	0.2000	3.2343	3.0012	4.4850	6.0758	4.8963	3.0158	2.2800	2.1419	1.6576	1.3993	1.7956	2.0579
7	0.2333	3.2179	2.9709	4.3723	6.0672	4.8627	2.9509	2.2727	2.1001	1.6457	1.3872	1.7841	2.0248
8	0.2667	3.1423	2.9274	4.2779	6.0419	4.8323	2.8826	2.2615	2.0664	1.6076	1.3757	1.7640	2.0137
9	0.3000	3.1165	2.8717	4.0215	5.9919	4.7709	2.8180	2.2551	1.9871	1.5946	1.3743	1.7484	1.9992
10	0.3333	3.0540	2.8614	3.8539	5.9890	4.7525	2.7835	2.2246	1.9805	1.5937	1.3712	1.7151	1.9695
11	0.3667	2.9985	2.8099	3.8358	5.9472	4.7491	2.7778	2.2128	1.9693	1.5868	1.3619	1.7146	1.9652
12	0.4000	2.9483	2.7892	3.7749	5.9063	4.7336	2.7692	2.2123	1.9507	1.5774	1.3609	1.6726	1.9527
13	0.4333	2.9276	2.7662	3.7388	5.8935	4.7330	2.7658	2.2079	1.9234	1.5609	1.3409	1.6485	1.9499
14	0.4667	2.9162	2.7571	3.7252	5.8904	4.6806	2.7593	2.1561	1.9180	1.5524	1.3320	1.6344	1.9428
15	0.5000	2.8991	2.7460	3.6166	5.8611	4.6350	2.7552	2.0940	1.9122	1.5457	1.3243	1.6226	1.9386
16	0.5333	2.8499	2.7349	3.5577	5.7951	4.5800	2.7375	2.0760	1.9085	1.5312	1.3203	1.6052	1.9324
17	0.5667	2.8348	2.7309	3.5547	5.7938	4.4919	2.7119	2.0759	1.8983	1.5299	1.3179	1.5943	1.8950
18	0.6000	2.7872	2.7199	3.4332	5.7915	4.4745	2.6836	2.0709	1.8861	1.5243	1.3168	1.5902	1.8909
19	0.6333	2.7852	2.7150	3.4117	5.7165	4.4426	2.6808	2.0465	1.8824	1.5241	1.3060	1.5831	1.8903
20	0.6667	2.7689	2.5905	3.3576	5.7018	4.4354	2.6798	2.0268	1.8805	1.5077	1.2960	1.5547	1.8693
21	0.7000	2.6779	2.5776	3.3027	5.6391	4.3923	2.6613	1.9914	1.8676	1.4786	1.2951	1.5513	1.8588
22	0.7333	2.6775	2.5278	3.2416	5.5819	4.3763	2.6573	1.9763	1.8469	1.4435	1.2929	1.5507	1.8455
23	0.7667	2.5480	2.4390	3.2406	5.5738	4.2682	2.6293	1.9693	1.8056	1.4311	1.2910	1.5415	1.8197
24	0.8000	2.4969	2.4095	3.2377	5.5628	4.2062	2.5730	1.9670	1.7083	1.4231	1.2859	1.5213	1.8007
25	0.8333	2.3915	2.4025	3.2007	5.5534	4.1860	2.5650	1.9230	1.7071	1.4127	1.2733	1.4576	1.7456
26	0.8667	2.3828	2.3250	3.1919	5.4856	4.1846	2.5290	1.8850	1.6766	1.4061	1.2582	1.4177	1.7408
27	0.9000	2.1856	2.2061	3.0140	5.4774	4.1545	2.5206	1.8552	1.6642	1.3689	1.2555	1.4083	1.7022
28	0.9333	2.1128	2.0251	2.9139	5.4664	4.0946	2.3988	1.8469	1.6568	1.3262	1.2256	1.4004	1.6896
29	0.9667	1.9485	2.0091	2.7811	5.3990	4.0521	2.2865	1.8044	1.6526	1.3108	1.2055	1.3995	1.6221
30	1.0000	1.8942	0.6287	2.7451	5.1831	4.0429	1.8068	1.7417	1.4528	1.1424	1.1556	1.3735	1.5823

Z takto upravených dat byla sestrojena čára pravděpodobnosti překročení.



Obr. 5-1 Ukázka čáry překročení pravděpodobnosti


Z čáry překročení byly následně interpolací zjištěny hodnoty pro 5%, 50% a 95% pravděpodobnost překročení.

Tab. 5-2 Ukázka interpolace hodnot pro tvorbu scénářů předpovědi


P	Q _m	P	Q _m	P	Q _m
0.933	2.113	0.500	2.899	0.033	3.676
0.950	2.031	0.500	2.899	0.050	3.650
0.967	1.948	0.533	2.850	0.067	3.625
Scénáře předpovědi			Q _m		
optimistická předpověď			3.650	m³/s	
průměrná předpověď			2.899	m³/s	
negativní předpověď			2.031	m³/s	

Z takto získaných hodnot byly následně sestrojeny křivky, které nám ukazují pravděpodobnostní scénáře průběhu průtoků.


Tyto scénáře byly vyhotoveny jak pro profil Skryje, tak i pro profil Dalečín, kdy nejprve jsou na obrázcích 5-2 až 5-5 zobrazeny scénáře pro námi předpovídané roky 1961, 1965, 1991 a 1993. Následně jsou pro tyto roky zobrazeny v obrázcích 5-6 až 5-9 scénáře, do kterých byly promítnuty předpovězené roky i originální průběh naměřených dat v profilu Skryje.




Obr. 5-2 Průběh scénářů průtoků pro průměrně vodný rok v profilu Skryje



Obr. 5-3 Průběh scénářů průtoků pro extrémně vodný rok v profilu Skryje




Obr. 5-4 Průběh scénářů průtoků pro málo vodný rok v profilu Skryje




Obr. 5-5 Průběh scénářů průtoků pro náhodně zvolený rok v profilu Skryje

U jednotlivých scénářů předpovědi bylo provedeno vyhodnocení pomocí koeficientu determinace. Byla porovnávána podobnost předpovězeného průběhu se skutečně naměřenými hodnotami průtoků. Po vypočtení dosahoval koeficient determinace, pro průměrně vodný rok (1961) v profilu Skryje těchto hodnot. Pro pesimistickou předpověď $R^2=0,266$, pro průměrnou předpověď $R^2=0,341$ a pro optimistickou předpověď $R^2=0,444$.




Obr. 5-6 Průběh scénářů a průtoků pro průměrně vodný rok v profilu Skryje

Pro extrémně vodný rok (1965), v profilu Skryje, vycházelo pro pesimistickou předpověď $R^2=0,022$, pro průměrnou předpověď $R^2=0,016$ a pro optimistickou předpověď $R^2=0,028$.




Obr. 5-7 Průběh scénářů a průtoků pro extrémně vodný rok v profilu Skryje

Pro málo vodný rok (1991), v profilu Skryje, vycházelo pro pesimistickou předpověď $R^2=0,025$, pro průměrnou předpověď $R^2=0,033$ a pro optimistickou předpověď $R^2=0,035$.




Obr. 5-8 Průběh scénářů a průtoků pro málo vodný rok v profilu Skryje

Pro náhodně zvolený rok (1993), v profilu Skryje, vycházelo pro pesimistickou předpověď $R^2=0,063$, pro průměrnou předpověď $R^2=0,052$ a pro optimistickou předpověď $R^2=0,019$.




Obr. 5-9 Průběh scénářů a průtoků pro náhodně zvolený rok v profilu Skryje


Na obrázcích 5-10 až 5-17 jsou také zobrazeny scénáře průběhu průtoků a porovnání průběhu scénářů s průběhem předpovědí průtoků pro vybrané roky, tentokrát však v profilu Dalečín.




Obr. 5-10 Průběh scénářů průtoků pro průměrně vodný rok v profilu Dalečín



Obr. 5-11 Průběh scénářů průtoků pro extrémně vodný rok v profilu Dalečín




Obr. 5-12 Průběh scénářů průtoků pro málo vodný rok v profilu Dalečín




Obr. 5-13 Průběh scénářů průtoků pro náhodně zvolený rok v profilu Dalečín

Pro průměrně vodný rok (1961), v profilu Dalečín, vycházelo pro pesimistickou předpověď $R^2=0,266$, pro průměrnou předpověď $R^2=0,204$ a pro optimistickou předpověď $R^2=0,310$.




Obr. 5-14 Průběh scénářů a průtoků pro průměrně vodný rok v profilu Dalečín

Pro extrémně vodný rok (1965), v profilu Dalečín, vycházelo pro pesimistickou předpověď $R^2=0,047$, pro průměrnou předpověď $R^2=0,023$ a pro optimistickou předpověď $R^2=0,033$.




Obr. 5-15 Průběh scénářů a průtoků pro extrémně vodný rok v profilu Dalečín

Pro málo vodný rok (1991), v profilu Dalečín, vycházelo pro pesimistickou předpověď $R^2=0,012$, pro průměrnou předpověď $R^2=0,014$ a pro optimistickou předpověď $R^2=0,009$.




Obr. 5-16 Průběh scénářů a průtoků pro málo vodný rok v profilu Dalečín

Pro náhodně zvolený rok (1993), v profilu Dalečín, vycházelo pro pesimistickou předpověď $R^2=0,096$, pro průměrnou předpověď $R^2=0,025$ a pro optimistickou předpověď $R^2=0,043$.




Obr. 5-17 Průběh scénářů a průtoků pro náhodně zvolený rok v profilu Dalečín

Na obrázcích 5-18 až 5-21 jsou zobrazeny scénáře průtoků, které byly opět stanoveny pomocí čáry překročení pravděpodobnosti tentokrát však z průtoků, které byly předpovězeny pomocí zonálního pravděpodobnostního předpovědního modelu a na posledních dvou obrázcích jsou zobrazeny scénáře včetně průměrných měsíčních průtoků v profilu Skryje.




Obr. 5-18 Průběh scénářů a průtoků pro extrémně vodný rok v profilu Skryje




Obr. 5-19 Průběh scénářů a průtoků pro málo vodný rok v profilu Skryje

Oba roky byly opět vyhodnoceny pomocí koeficientu determinace pro extrémně vodný rok (1965), v profilu Skryje, vycházelo pro pesimistickou předpověď $R^2=0,24$, pro průměrnou předpověď $R^2=0,34$ a pro optimistickou předpověď $R^2=0,39$.




Obr. 5-20 Porovnání scénářů předpovědí a skutečného průtoků pro extrémně vodný rok v profilu Skryje

Pro málo vodný rok (1991), v profilu Skryje, vycházelo pro pesimistickou předpověď $R^2=0,011$, pro průměrnou předpověď $R^2=0,049$ a pro optimistickou předpověď $R^2=0,052$.




Obr. 5-21 Porovnání scénářů předpovědí a skutečného průtoků pro málo vodný rok v profilu Skryje

Na obrázcích 5-22 až 5-25 jsou také zobrazeny scénáře průtoků stanovené pomocí čáry překročení pravděpodobnosti, opět z průtoků, které byly předpovězeny pomocí zonálního pravděpodobnostního předpovědního modelu a na posledních dvou obrázcích jsou scénáře průběhu průtoků včetně průměrných měsíčních průtoků v profilu Dalečín.




Obr. 5-22 Průběh scénářů a průtoků pro extrémně vodný rok v profilu Dalečín




Obr. 5-23 Průběh scénářů a průtoků pro málo vodný rok v profilu Dalečín

Oba roky byly opět vyhodnoceny pomocí koeficientu determinace pro extrémně vodný rok (1965), v profilu Dalečín, vycházelo pro pesimistickou předpověď $R^2=0,135$, pro průměrnou předpověď $R^2=0,004$ a pro optimistickou předpověď $R^2=0,0006$.



Obr. 5-24 Porovnání scénářů předpovědí a skutečného průtoků pro extrémně vodný rok v profilu Dalečín


Pro málo vodný rok (1991), v profilu Dalečín, vycházelo pro pesimistickou předpověď $R^2=0,004$, pro průměrnou předpověď $R^2=0,0004$ a pro optimistickou předpověď $R^2=0,00005$.




Obr. 5-25 Porovnání scénářů předpovědí a skutečného průtoků pro málo vodný rok v profilu Dalečín

5.6 POROVNÁNÍ PREDIKCÍ

Na obrázku 5.6-1 a 5.6-2 je zobrazen modrou křivkou průběh předpovězených průtoků pro nejvodnatější rok (rok 1965) a nejméně vodný rok (rok 1991) za sledované období pomocí neuronových sítí. Zelená čára nám ukazuje průběh průtoků předpovězený pomocí zonálního pravděpodobnostního předpovědního modelu. Červená čára ukazuje skutečný průběh průtoků v daném roce v profilu Skryje.




Obr. 5.6-1 Porovnání predikcí a skutečného průtoků pro extrémně vodný rok v profilu Skryje




Obr. 5.6-2 Porovnání predikcí a skutečného průtoků pro málo vodný rok v profilu Skryje

Obdobně je pak na obrázcích 5.6-3 a 5.6-4 vyobrazen průběh předpovězených a skutečných průtoků pro nejvodnatější a nejméně vodný rok. Modrá křivka ukazuje průběh předpovězených průtoků pomocí neuronových sítí. Zelená čára zobrazuje průběh předpovězený průtoků pomocí zonálního pravděpodobnostního předpovědního modelu a červená čára ukazuje skutečný průběh průtoků v daném roce v profilu Dalečín.



Obr. 5.6-3 Porovnání predikcí a skutečného průtoků pro extrémně vodný rok v profilu Dalečín



Obr. 5.6-4 Porovnání predikcí a skutečného průtoků pro málo vodný rok v profilu Dalečín

6. ZÁVĚR

Diplomová práce si kladla za cíl nalezení vhodného propojení mezi náhodně generovanými vstupy, které měly podobu reálných nebo náhodně generovaných průtokových řad, se standardně používanými hydrologickými předpovědními modely, založenými na principech umělé inteligence a pravděpodobnostního modelu. Jako další cíl práce bylo sestavení předpovědi průměrných měsíčních průtoků ve vybraných profilech, kterými byly profily Skryje a Dalečín.

Součástí práce bylo zpracování dat získaných z Českého hydrometeorologického ústavu, která byla měřena kontinuálně od roku 1953 do roku 2008. Data byla získána jako soubor měsíčních průměrných průtoků, což odpovídalo 672 záznamům hodnot průtoků pro jeden měřený profil. Z těchto dat bylo vygenerováno 30 náhodně generovaných průtokových řad, které byly následně zpracovávány.

Zpracování probíhalo pomocí aplikace Excel, kde proběhly úpravy dat ve smyslu přípravy vstupů pro neuronové sítě. Po základních úpravách už byla data zpracována aplikací MATLAB, ze které byly výsledné predikce přeneseny zpět k úpravě do aplikace Excel, kde bylo možné porovnávat výsledky se skutečně naměřenými hodnotami.

Prvním krokem pro sestavení předpovědi, bylo nalezení optimálního počtu měsíců pro předpověď. To se provedlo pomocí výpočtu koeficientu determinace. Postupovalo se tak, že se nejprve provedl výpočet pro jeden vstupní měsíc a dále se přidávaly další vstupní měsíce, až do využití všech dvanácti měsíců. Koeficient vyšel v rozmezí od 1,87 pro čtyři vstupní měsíce, až po 2,96 pro dvanáct vstupních měsíců.

Druhým krokem pak bylo sestavení výsledných předpovědí. K tomu bylo využito scénářů předpovědi průtoků, které byly stanoveny pro jednotlivé roky pro oba profily.

Ze shrnutí výsledků je možné posoudit, jak přesně se povedlo určit průběhy předpovědi. Obecně je známo, že za dobrou shodu předpovědi s měřenými hodnotami lze považovat ty předpovědi, u kterých je koeficient determinace vyšší než 0,75. Tuto hodnotu spočítané koeficienty nepřesáhly. Pomocí neuronových sítí se této hodnotě nejvíce přiblížil scénář předpovědi pro průměrně vodný rok v profilu Skryje, kde koeficient pro optimistický scénář předpovědi vyšel 0,444. Naopak nejnižší hodnotu koeficientu, která byla 0,009, vykazoval málo vodný rok v profilu Dalečín.

Pro Zonální pravděpodobnostní předpovědní model vykazoval lepší shodu extrémně vodný rok v profilu Skryje, a koeficient zde dosahoval maximální hodnoty 0,39. Zato koeficient pro málo vodný rok v profilu Dalečín dosahoval nejnižší hodnoty ze všech provedených předpovědí. Tato hodnota byla 0,00005.

Srovnáním Zonálního pravděpodobnostního předpovědního modelu, s modelem založených na neuronových sítích se předpovědi od sebe podstatně lišily. Z výsledných grafů, které zobrazují právě porovnání obou modelů, je patrné mnoho odlišností a to zejména v extrémních rocích. Zonální pravděpodobnostní model byl úspěšný v předpovědi podobnějšího průběhu, podařilo se mu lépe vystihnout jednotlivé výkyvy. Model založený na neuronových sítích lépe zachytil rozkolísanost velikosti extrémních průtoků, a tudíž lépe předpověděl maximum, kterého bylo ve skutečnosti dosaženo. Při podrobnějším porovnání křivek předpovězených pomocí neuronových sítí je patrná jistá podobnost. Můj předpoklad je, že nastavení tréninkové matice pro predikci provede trénink na podobný průběh křivky u všech předpovědí. To lze považovat za určitou nevýhodu, ale je otázkou, zda by změna nastavení parametrů nevedla k přesnější předpovědi.

Tato práce byla zaměřena pouze na předpověď průtoků a na srovnání hydrologických předpovědí, tudíž nebyla zkoumána efektivita na řízení nádrží a vodohospodářských soustav. Tomu by však mohla předpověď pomoci.

Zde se otevírá prostor pro další práci. V návaznosti na předpovědi průtoků by pak bylo možné upravit dlouhodobé řízení vodohospodářských soustav, na které by průtoky v daných profilech měly vliv. Tím by se dalo předejít škodám, které by vznikly vlivem povodní nebo extrémního sucha.

Další problematika, která s touto prací souvisí, je citlivost nastavení neuronové sítě. Nastavení jednotlivých parametrů může ovlivnit výslednou predikci. Je tedy důležité si toto nastavení předem promyslet. Podrobné testování jednotlivých nastavení a různé možnosti úpravy vstupů by mohli mít různý vliv na přesnost předpovídaných průtoků. Stejně tak by se do předpovědí mohlo začlenit předpovídání srážek a odtokových poměrů v dané lokalitě a kombinací různých vstupů získat přesnější výstupy. Jednotlivé úpravy v nastavení neuronové sítě a případné rozšíření vlivu vstupů by mohly být námětem na další práci.

Neuronové sítě mají potenciál, ale je důležité je dobře uchopit a do předpovědních modelů zapracovat. Práce jen ukázala možnou cestu jak posunout uvedenou problematiku zase o krůček dále.

7. LITERATURA A CITACE

Všechny informace jsem čerpal z důvěryhodných zdrojů.

7.1 POUŽITÁ LITERATURA

Literatura:

1. STARÝ, MILOŠ. HYDROLOGIE: MODUL 01. BRNO, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
2. STARÝ, MILOŠ. HYDROLOGIE: MODUL 02. BRNO, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
3. SILVER, Nate. Signál a šum: mnoho předpovědí selže, některé ne. Vyd. 1. Praha: Paseka, 2014, 542 s. ISBN 978-80-7432-440-6.
4. MARTON, D.; STARÝ, M.; MENŠÍK, P. The Influence of Uncertainties in the Calculation of Mean Monthly Discharges On Reservoir Storage. Journal of Hydrology and Hydromechanic, 2011, roč. 59, č. 4, s. 228-237. ISSN: 0042- 790X.
5. NOVÁK, MIRKO. NEURONOVÉ SÍTĚ A NEUROPOČÍTAČE. 1. VYD. PRAHA: SENZO, 1992, 186 s.
6. NACHÁZEL, Karel, Jiří ZEŽULÁK a Miloš STARÝ. *Využití metod umělé inteligence ve vodním hospodářství*. Vyd. 1. Praha: Academia, 2004, 318 s. ISBN 80-200-0229-4.
7. FABIAN, František a Zdeněk KLUIBER. *Metoda Monte Carlo: a možnosti jejího uplatnění*. 1. vyd. Praha: Prospektrum, 1998, 148 s. ISBN 80-7175-058-1.
8. JIŘINA, Marcel. Jak na neuronové sítě v programu STATISTICA Neuronové sítě. 1. vyd. Praha: StatSoft, 2003, 73 s. ISBN 978-80-904033-0-7. Dostupné z: <http://krameriusndktest.mzk.cz/search/handle/uuid:aa05a8c0-6aa2-11e2-8aec-005056827e52>
9. NACHÁZEL, Karel, Jiří ZEŽULÁK a Miloš STARÝ. *Využití metod umělé inteligence ve vodním hospodářství*. Vyd. 1. Praha: Academia, 2004, 318 s. Česká matice technická (Academia). ISBN 80-200-0229-4.
10. STARÝ, Miloš. *Užití umělých neuronových sítí v aplikované hydrologii: Use of artificial neural networks in apply hydrology: zkrácená verze habilitační práce*. Brno: VUTUM, 2004, 40 s. ISBN 80-214-2746-9.

11. Bc. Milan Šelepa, *Střednědobá předpověď průtoků vody měrným profilem toku*. Brno, 2014. 82 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.
12. KRAUSE, P., BOYLE, D. P., and BÄSE, F.: *Comparison of different efficiency criteria for hydrological model assessment*, Adv. Geosci., 5, 89-97, doi:10.5194/adgeo-5-89-2005, 2005.
13. MENŠÍK, P., M. STARÝ a D. MARTON. Using Predictive Model of Mean Monthly Flows for Large Open Reservoirs Hydropower Control. *Procedia Engineering* [online]. 2014, 89: 1486-1492. DOI: 10.1016/j.proeng.2014.11.435. ISSN 18777058. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1877705814025508>
14. ROŽNOVSKÝ, Jaroslav a Tomáš LITSCHMANN. *Extrémy počasí a podnebí: sborník abstraktů a CD-ROM s články*. 1. vyd. Brno: Česká bioklimatologická společnost v nakl. Český hydrometeorologický ústav, 2004, 42 s. ISBN 80-86690-12-1.
15. ČSN ISO 690. BIBLIOGRAFICKÉ CITACE: Obsah, forma a struktura. Praha: ČESKÝ NORMALIZAČNÍ INSTITUT, 1996.
16. ČSN ISO 7144. Dokumentace - Formální úprava disertací a podobných dokumentů. Praha: ČESKÝ NORMALIZAČNÍ INSTITUT, 1996.
17. ČSN 01 6910. Úprava písemností zpracovaných textovými editory. Praha: ČESKÝ NORMALIZAČNÍ INSTITUT, 2007.

Internetové odkazy:

1. <http://www.chmi.cz/>
2. <http://cs.wikipedia.org/>
3. <https://www.google.com/>

7.2 CITACE Z LITERATURY

- [1] MINISTERSTVO ŽIVOTNÍHO PROSTŘEDÍ ČR. *Strategie přizpůsobení se změně klimatu v podmínkách ČR*. Praha, 2015.
- [2] KAČENKA, Petr. *Neuronové sítě: Historie, využití neuronových sítí a často používané typy sítí*. Mariánská, 1998.
- [3] SÁZEL, J.; STARÝ, M. *Střednědobé předpovědi průtoků povrchových toků*. *Vodní hospodářství*, 2014, roč. 64, č. 1, s. 5-8. ISSN: 1211-0760.

- [4] Bc. Milan Šelepa, *Střednědobá předpověď průtoků vody měrným profilem toku*. Brno, 2014. 82 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.
- [5] Fošumpaur, P. *Použití umělých neuronových sítí pro operativní předpovědi říčních průtoků*. Vodní hospodářství, 6, 1999, 121–123
- [6] SVETLÍKOVÁ DANIELA, *Hybridný model priemerných mesačných prietokov pre povodie horného Hrona*, Vodohospodársky spravodajca č. 9 – 10/2009.
- [7] AMIR F. ATIYA, SUZAN M. EL-SHOURA, SAMIR I. SHAHEEN, MOHAMED S. ELSHERIF, *A Comparison Between Neural-Network Forecasting Techniques - Case Study: River Flow Forecasting*, Ieee transactions on neural networks, 3/1999.
- [8] CHAU Kwok-Wing, Riccardo TAORMINA a Bellie SIVAKUMAR. *Neural network river forecasting through baseflow separation and binary-coded swarm optimization*. Journal of Hydrology [online]. 2015, 529, 1788-1797 [cit. 2016-01-07]. DOI: 10.1016/j.jhydrol.2015.08.008. ISSN 00221694. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0022169415005673>
- [9] JANSÁ, Jakub. *Odhad nejistot měření průtoků ve vybraném vodoměrném profilu*. Brno, 2014. 45 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.
- [10] STARÝ, MILOŠ. *HYDROLOGIE: MODUL 01*. BRNO, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ.
- [11] MARTON, D.; STARÝ, M.: UNCE- V; UNCE- V *Generátor nejistot vstupních hydrologických dat*. <http://uvhk.fce.vutbr.cz/software.php>. URL: <http://uvhk.fce.vutbr.cz/software.php>. (software)
- [12] STARÝ, Miloš. *Užití umělých neuronových sítí v aplikované hydrologii: Use of artificial neural networks in apply hydrology: zkrácená verze habilitační práce*. Brno: VUTIUM, 2004, 40 s. ISBN 80-214-2746-9.
- [13] JIŘINA, Marcel. *Jak na neuronové sítě v programu STATISTICA Neuronové sítě*. 1. vyd. Praha: StatSoft, 2003, 73 s. ISBN 978-80-904033-0-7. Dostupné z: <http://krameriusndktest.mzk.cz/search/handle/uuid:aa05a8c0-6aa2-11e2-8aec-005056827e52>
- [14] KRAUSE, P., BOYLE, D. P., and BÄSE, F.: *Comparison of different efficiency criteria for hydrological model assessment*, Adv. Geosci., 5, 89-97, doi:10.5194/adgeo-5-89-2005, 2005.

- [15] STARÝ, MILOŠ. HYDROLOGIE: MODUL 02. BRNO, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
- [16] MENŠÍK, P., M. STARÝ a D. MARTON. *Using Predictive Model of Mean Monthly Flows for Large Open Reservoirs Hydropower Control*. *Procedia Engineering* [online]. 2014, 89: 1486-1492 [cit. 2015-12-24]. DOI: 10.1016/j.proeng.2014.11.435. ISSN 18777058. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1877705814025508>
- [17] Menšík P., Starý M a Marton D., *Using Predictive Models of Mean Monthly Flows for Operative Outflows Control from Large Open Reservoirs*. In *Proceedings ITISE 2014, International work-conference on Time Series*. Spain, Granada: Copicentro Granada S. L, 2014. p. 382-395. [cit. 2015-12-25] ISBN: 978-84-15814-97-9.
- [18] GOOGLE MAPS. [online]. [cit. 2015-12-24]. Dostupné z: Maps.google.com
- [19] ČHMI: Hlásná a předpovědní povodňová služba. [online]. [cit. 2015-12-24]. Dostupné z: <http://hydro.chmi.cz/hpps/>

8. OBRÁZKY

- Obr. 2.1-1** Hustota pravděpodobnosti „bílého šumu“
Převzato z: [STARÝ, MILOŠ. HYDROLOGIE: MODUL 01. BRNO, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ.]
- Obr. 2.1-2** Schéma generování náhodných řad průměrných měsíčních průtoků metodou Monte Carlo
Převzato z: [MARTON, D.; STARÝ, M.: UNCE- V; UNCE- V *Generátor nejistot vstupních hydrologických dat.* <http://uvhk.fce.vutbr.cz/software.php>. URL: <http://uvhk.fce.vutbr.cz/software.php>. (software)]
- Obr. 2.3-1** Biologický neuron
Převzato z: [STARÝ, Miloš. *Užití umělých neuronových sítí v aplikované hydrologii: Use of artificial neural networks in apply hydrology: zkrácená verze habilitační práce.* Brno: VUTUM, 2004, 40 s. ISBN 80-214-2746-9.]
- Obr. 2.3.1-1** Schéma umělého neuronu
Převzato z: [JIRINA, Marcel. Jak na neuronové sítě v programu STATISTICA Neuronové sítě. 1. vyd. Praha: StatSoft, 2003, 73 s. ISBN 978-80-904033-0-7. Dostupné z: <http://kramerusndktest.mzk.cz/search/handle/uuid:aa05a8c0-6aa2-11e2-8aec-005056827e52>]
- Obr. 2.3.1-2** Umělá neuronová síť
Převzato z: [STARÝ, MILOŠ. HYDROLOGIE: MODUL 01. BRNO, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ]
- Obr. 2.5.1-1** Ukázka koeficientu determinace
Převzato z: [Bc. Milan Šelepa, *Střednědobá předpověď průtoků vody měrným profilem toku.* Brno, 2014. 82 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.]
- Obr. 2.5.2-1** Ukázka koeficientu korelace s nulovou vazbou
- Obr. 2.5.2-2** Ukázka koeficientu korelace s nejlepší vazbou
- Obr. 2.5.3-1** Ukázka čáry překročení pravděpodobnosti
Převzato z: [STARÝ, MILOŠ. HYDROLOGIE: MODUL 01. BRNO, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ]
- Obr. 2.6-1** Ukázka zonálního pravděpodobnostního předpovědního modelu

Obr. 3-1	Schéma postupu zpracování dat
Obr. 3-2	Schéma úpravy vstupních dat
Obr. 3-3	Schéma práce s daty v MATLABu
Obr. 3-4	Schéma vyhodnocení dat.
Obr. 4-1	Umístění profilů v ČR Převzato z: [GOOGLE MAPS. [online]. [cit. 2015-12-24]. Dostupné z: Maps.google.com]
Obr. 4-2	Umístění profilů v povodí Dyje Převzato z: [http://www.chmi.cz/]
Obr. 4-3	Evidenční list profilu Skryje č.372a Převzato z: [http://www.chmi.cz/]
Obr. 4-4	Evidenční list profilu Dalečín č. 371 Převzato z: [http://www.chmi.cz/]
Obr. 4.7.1-1	Ukázka načítání dat v MATLABu – input
Obr. 4.7.1-2	Ukázka načítání dat v MATLABu – target
Obr. 4.7.1-3	Ukázka načítání dat v MATLABu – sample
Obr. 4.7.2-1	Ukázka nástroje pro práci s NS – nntool
Obr. 4.7.2-2	Ukázka tvorby neuronové sítě
Obr. 4.7.2-3	Ukázka trénování neuronové sítě
Obr. 4.7.2-4	Ukázka simulace neuronové sítě
Obr. 4.7.2-5	Ukázka exportu predikovaných dat
Obr. 4.7.3-1	Ukázka neuronové sítě pomocí skriptu
Obr. 4.7.3-2	Ukázka exportu dat
Obr. 4.10-1	Porovnání predikce a skutečnosti pro průměrně vodný rok v profilu Skryje
Obr. 4.10-2	Porovnání predikce a skutečnosti pro nejvíce vodný rok v profilu Skryje
Obr. 4.10-3	Porovnání predikce a skutečnosti pro nejméně vodný rok v profilu Skryje
Obr. 4.10-4	Porovnání predikce a skutečnosti pro náhodně zvolený rok v profilu Skryje
Obr. 4.10-5	Porovnání predikce a skutečnosti pro průměrně vodný rok v profilu Dalečín
Obr. 4.10-6	Porovnání predikce a skutečnosti pro nejvíce vodný rok v profilu Dalečín

- Obr. 4.10-7** Porovnání predikce a skutečnosti pro nejméně vodný rok v profilu Dalečín
- Obr. 4.10-8** Porovnání predikce a skutečnosti pro náhodně zvolený rok v profilu Dalečín
- Obr. 4.10-9** Porovnání predikce pro generovaná data a skutečnosti pro průměrně vodný rok v profilu Skryje
- Obr. 4.10-10** Porovnání predikce pro generovaná data a skutečnosti pro extrémně vodný rok v profilu Skryje
- Obr. 4.10-11** Porovnání predikce pro generovaná data a skutečnosti pro nejméně vodný rok v profilu Skryje
- Obr. 4.10-12** Porovnání predikce pro generovaná data a skutečnosti pro náhodně zvolený rok v profilu Skryje
- Obr. 4.10-13** Porovnání predikce pro generovaná data a skutečnosti pro průměrně vodný rok v profilu Dalečín
- Obr. 4.10-14** Porovnání predikce pro generovaná data a skutečnosti pro extrémně vodný rok v profilu Dalečín
- Obr. 4.10-15** Porovnání predikce pro generovaná data a skutečnosti pro nejméně vodný rok v profilu Dalečín
- Obr. 4.10-16** Porovnání predikce pro generovaná data a skutečnosti pro náhodně zvolený rok v profilu Dalečín
- Obr. 4.10-17** Porovnání predikce a skutečného průtoků pro extrémně vodný rok v profilu Skryje
- Obr. 4.10-18** Porovnání predikce a skutečného průtoků pro málo vodný rok v profilu Skryje
- Obr. 4.10-19** Porovnání predikce a skutečného průtoků pro extrémně vodný rok v profilu Dalečín
- Obr. 4.10-20** Porovnání predikce a skutečného průtoků pro málo vodný rok v profilu Dalečín
- Obr. 5-1** Ukázka čáry překročení pravděpodobnosti
- Obr. 5-2** Průběh scénářů průtoků pro průměrně vodný rok v profilu Skryje
- Obr. 5-3** Průběh scénářů průtoků pro extrémně vodný rok v profilu Skryje
- Obr. 5-4** Průběh scénářů průtoků pro málo vodný rok v profilu Skryje
- Obr. 5-5** Průběh scénářů průtoků pro náhodně zvolený rok v profilu Skryje

- Obr. 5-6** Průběh scénářů a průtoků pro průměrně vodný rok v profilu Skryje
- Obr. 5-7** Průběh scénářů a průtoků pro extrémně vodný rok v profilu Skryje
- Obr. 5-8** Průběh scénářů a průtoků pro málo vodný rok v profilu Skryje
- Obr. 5-9** Průběh scénářů a průtoků pro náhodně zvolený rok v profilu Skryje
- Obr. 5-10** Průběh scénářů průtoků pro průměrně vodný rok v profilu Dalečín
- Obr. 5-11** Průběh scénářů průtoků pro extrémně vodný rok v profilu Dalečín
- Obr. 5-12** Průběh scénářů průtoků pro málo vodný rok v profilu Dalečín
- Obr. 5-13** Průběh scénářů průtoků pro náhodně zvolený rok v profilu Dalečín
- Obr. 5-14** Průběh scénářů a průtoků pro průměrně vodný rok v profilu Dalečín
- Obr. 5-15** Průběh scénářů a průtoků pro extrémně vodný rok v profilu Dalečín
- Obr. 5-16** Průběh scénářů a průtoků pro málo vodný rok v profilu Dalečín
- Obr. 5-17** Průběh scénářů a průtoků pro náhodně zvolený rok v profilu Dalečín
- Obr. 5-18** Průběh scénářů a průtoků pro extrémně vodný rok v profilu Skryje
- Obr. 5-19** Průběh scénářů a průtoků pro málo vodný rok v profilu Skryje
- Obr. 5-20** Porovnání scénářů předpovědí a skutečného průtoků pro extrémně vodný rok v profilu Skryje
- Obr. 5-21** Porovnání scénářů předpovědí a skutečného průtoků pro málo vodný rok v profilu Skryje
- Obr. 5-22** Průběh scénářů a průtoků pro extrémně vodný rok v profilu Dalečín
- Obr. 5-23** Průběh scénářů a průtoků pro málo vodný rok v profilu Dalečín
- Obr. 5-24** Porovnání scénářů předpovědí a skutečného průtoků pro extrémně vodný rok v profilu Dalečín

- Obr. 5-25** Porovnání scénářů předpovědí a skutečného průtoků pro málo vodný rok v profilu Dalečín
- Obr. 5.6-1** Porovnání predikcí a skutečného průtoků pro extrémně vodný rok v profilu Skryje
- Obr. 5.6-2** Porovnání predikcí a skutečného průtoků pro málo vodný rok v profilu Skryje
- Obr. 5.6-3** Porovnání predikcí a skutečného průtoků pro extrémně vodný rok v profilu Dalečín
- Obr. 5.6-4** Porovnání predikcí a skutečného průtoků pro málo vodný rok v profilu Dalečín

9. TABULKY

- Tab. 2.4-1** Součet průměrných hodnot koeficientu determinace
- Tab. 4.6-1** Ukázka vstupních dat před standardizací
- Tab. 4.6-2** Ukázka vstupních dat po standardizaci
- Tab. 4.9.1-1** Sumy průměrů koeficientů determinace
- Tab. 5-1** Data pro čáry překročení pravděpodobnosti v profilu Skryje
- Tab. 5-2** Ukázka interpolace hodnot pro tvorbu scénářů předpovědi