



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STAVEBNÍ

FACULTY OF CIVIL ENGINEERING

ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

INSTITUTE OF LANDSCAPE WATER MANAGEMENT

**ŘÍZENÍ ZÁSOBNÍ FUNKCE NÁDRŽE S VYUŽITÍM
METOD UMĚLÉ INTELIGENCE**

MANAGEMENT OF WATER RESERVOIR STORAGE FUNCTION USING METHODS
OF ARTIFICIAL INTELLIGENCE

DIPLOMOVÁ PRÁCE

DIPLOMA THESIS

AUTOR PRÁCE

AUTHOR


Bc. Patrik Urbanec

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. TOMÁŠ KOZEL, Ph.D.

BRNO 2020



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

Student	Bc. Patrik Urbanec
Název	Řízení zásobní funkce nádrže s využitím metod umělé inteligence
Vedoucí práce	Ing. Tomáš Kozel, Ph.D.
Datum zadání	31. 3. 2019
Datum odevzdání	10. 1. 2020

V Brně dne 31. 3. 2019

prof. Ing. Miloš Starý, CSc.
Vedoucí ústavu

prof. Ing. Miroslav Bajer, CSc.
Děkan Fakulty stavební VUT

PODKLADY A LITERATURA

- Starý, M.: Nádrže a vodohospodářské soustavy, skriptum, FAST VUT Brno, 2006
- Starý, M.: Hydrologie, skriptum, FAST VUT Brno, 2005
- Starý, M. Nádrže a vodohospodářské soustavy. Metodické návody do cvičení. 1. vyd. Brno: VUT, 1987. 67 s.
- Starý, M. Nádrže a vodohospodářské soustavy. 1. vyd. Brno: VUT, 1986. 165 s.
- Nacházel, K., Starý, M., Zezulák, J.: Využití metod umělé inteligence ve vodním hospodářství, Academia, nakladatelství Akademie věd České republiky, Praha 2004, ISBN 80-200-02229-4.
- Caudill, M., and C. Butler: Understanding Neural Networks: Computer Explorations, Vols. 1 and 2, Cambridge, MA: The MIT Press, 1992.

ZÁSADY PRO VYPRACOVÁNÍ

Student sestaví algoritmus pro řízení zásobní funkce nádrže s využitím metod umělé inteligence využívající předpovědi budoucích přítoků vody do nádrže. Uvedený algoritmus aplikuje na fiktivní nebo reálnou vodohospodářskou nádrž. Na závěr provede vyhodnocení úspěšnosti sestaveného řídicího algoritmu.

STRUKTURA DIPLOMOVÉ PRÁCE

VŠKP vypracujte a rozčleňte podle dále uvedené struktury:

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

Ing. Tomáš Kozel, Ph.D.
Vedoucí diplomové práce

ABSTRACT

The subject of this thesis is to control the storage function of the reservoir using artificial intelligence methods, including the construction of the appropriate control algorithm. The thesis is divided into the theoretical part and the part of the application of reservoir storage function control. The theoretical part describes the control algorithm and the prediction model. The following are basic optimization methods and artificial intelligence methods. The second part presents the historical data used for the prediction model. The following is a description of calibration and validation of the control module and evaluation of the application results. Finally, there is a comparison and summary of individual results, control algorithm and prediction model. According to the results, the control algorithm can be recommended for further investigation.

KEYWORDS

Neural network, reservoir storage function, optimization, prediction models, probability, stochastics

ABSTRAKT

Předmětem diplomové práce je řízení zásobní funkce nádrže s využitím metod umělé inteligence, včetně sestavení příslušného řídicího algoritmu. Práce je rozdělena na teoretickou část a část aplikace řízení zásobní funkce nádrže. V teoretické části je popsán řídicí algoritmus a předpovědní model. Dále jsou uvedeny základní optimalizační metody a metody umělé inteligence. Ve druhé části jsou představena historická data, která byla použita pro předpovědní model. Následuje popis kalibrace a validace řídicího modulu a vyhodnocení výsledků aplikace. Na závěr je porovnání a shrnutí jednotlivých výsledků, řídicího algoritmu a předpovědního modelu. Dle dosažených výsledků lze řídicí algoritmus doporučit pro další zkoumání.

KLÍČOVÁ SLOVA

Neuronová síť, zásobní funkce nádrže, optimalizace, předpovědní modely, pravděpodobnost, stochastika

BIBLIOGRAFICKÁ CITACE

Bc. Patrik Urbanec *Řízení zásobní funkce nádrže s využitím metod umělé inteligence*. Brno, 2019. 55 s., 11 s. příl. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Tomáš Kozel, Ph.D.

PROHLÁŠENÍ O SHODĚ LISTINNÉ A ELEKTRONICKÉ FORMY ZÁVĚREČNÉ PRÁCE

Prohlašuji, že elektronická forma odevzdané diplomové práce s názvem *Řízení zásobní funkce nádrže s využitím metod umělé inteligence* je shodná s odevzdanou listinnou formou.

V Brně dne 10. 1. 2020

Bc. Patrik Urbanec
autor práce

PROHLÁŠENÍ O PŮVODNOSTI ZÁVĚREČNÉ PRÁCE

Prohlašuji, že jsem diplomovou práci s názvem *Řízení zásobní funkce nádrže s využitím metod umělé inteligence* zpracoval(a) samostatně a že jsem uvedl(a) všechny použité informační zdroje.

V Brně dne 10. 1. 2020

Bc. Patrik Urbanec
autor práce

PODĚKOVÁNÍ

Úvodem bych velice rád poděkoval vedoucímu mé diplomové práce Ing. Tomáši Kozlovi Ph.D. za užitečné rady, náměty a připomínky, které mi dával při výpočtové i textové části diplomové práce. Dále chci poděkovat svým rodičům a mé rodině za velkou psychickou i finanční podporu, kterou mi během celého studia dávali.

OBSAH

1	Úvod	3
2	Cíl diplomové práce	4
3	Metody	5
3.1	Chování nádrže	5
3.2	Řídící algoritmus	6
3.3	Optimalizační metody	8
3.3.1	Mřížková metoda (grid)	9
3.3.2	Metoda monte carlo	10
3.3.3	Genetické algoritmy	11
3.3.4	Diferenciální evoluce	14
3.4	Metody umělé inteligence	17
3.4.1	Neuronové sítě	17
3.4.2	Perceptronové sítě	24
3.4.3	Fuzzy modul	25
4	Předpovědní model	27
4.1	Zonální model	27
4.2	Modifikovaný zonální předpovědní model	27
4.3	Transformace historických dat	29
4.4	Sestavení distribuční funkce	30
4.5	Dispečerské grafy	31
5	Statistické metody	32
5.1	Normální rozdělení a normované normální rozdělení	32
5.2	Čára překročení	34
5.2.1	Možnosti zpracování empirických čar překročení	35
6	Použitý software	36
6.1	Aplikace	36
7	Aplikace řízení zásobní funkce nádrže	36
7.1	Historická data a předpovědní model	37
7.2	Kalibrace a validace řídicích modulů	38

7.3	Korekce	42
7.4	Výsledky a vyhodnocení aplikace	43
7.4.1	Vyhodnocení	43
7.4.2	Výsledky.....	43
8	Závěr.....	48
9	Použitá literatura.....	49
10	Seznam použitých obrázků	50
11	Seznam použitých tabulek	52
12	Seznam zkratk a symbolů	53
13	Přílohy	54

1 ÚVOD

V posledních letech byla v oblasti řízení provozu vodních nádrží řešena převážně problematika spojená s povodňovými průtoky. To bylo dáno častým výskytem extrémním povodní. Na celém území České republiky se však už objevují vleklé problémy s nedostatkem vody, které jsou způsobeny prodlužováním a prohlubováním se suchých období v důsledku klimatických změn. Uvedená skutečnost se může projevit ve vzrůstající napjatosti mezi kapacitou vodních zdrojů a nároky uživatelů vody. Ke značnému vyhrocení došlo v letech 2016 a 2018. Podle odborné veřejnosti a klimatických scénářů (GCM, CzechAdapt, 2016) se bude období sucha prodlužovat a začne se projevovat i pokles průtoků a s ním spojený pokles dlouhodobého průměrného průtoku Q_a , u kterého se výhledově očekává pokles hodnoty pod $0.8Q_a$ (Kašpárek, 2005). Uvedený pokles může mít dopad nejen na oblast zásobování vodou, ale i na jakost vody, kdy by se části toků mohly v konečném důsledku přeměnit na toky připomínající spíše stoky. Z toho důvodu je vhodné zabývat se stochastickými předpovědními modely. Výstavba nových vodohospodářských nádrží, která by vedla ke zlepšení uvedené situace, je v současné době problematičtější, a proto je žádoucí optimalizovat řízení již stávajících nádrží.

2 CÍL DIPLOMOVÉ PRÁCE

Předmětem diplomové práce je řízení zásobní funkce nádrže s využitím metod umělé inteligence. Cílem práce je sestavení příslušného řídicího algoritmu.

Samotná práce je rozčleněna do dvou částí. V první části jsou představeny optimalizační a předpovědní modely. K průtoku vody v měrném profilu lze přistupovat jako k náhodnému procesu a k měřeným hodnotám jako k jeho realizaci a proto je výhodné využít metody umělé inteligence. Předpovědní model extrapoluje naměřené hodnoty v čase modelem vycházejícím z autoregrese a je doplněn o zonální model. Po sestavení předpovědního modelu je provedeno jeho vyhodnocení a jeho předpovědi byly používány pro vlastní simulaci řízení zásobní funkce nádrže.

V druhé části práce je sestaven vlastní algoritmus pro řízení. Ten vychází z principu adaptivity a metod umělé inteligence UI. UI nahrazují tradiční optimalizaci (evoluční algoritmy a genetické algoritmy), které se vyznačují přesností a obecností, ale také svými nároky na strojový čas. Tradiční optimalizace je použita pro vytvoření matice vzorů (neuronové sítě).

Sestavený řídicí algoritmus je použit pro řízení fiktivní nádrže. Fiktivní nádrž byla zvolena z důvodu dostupnosti dostatečně reprezentativních dat pro vytvoření předpovědí přítoků. Při sestavování řídicích algoritmů byly zanedbány nejistoty dalších vstupů a rovněž ztráty spojené s provozem nádrže včetně ztráty výparem.


Předpovědní modely i modely pro řízení jsou naprogramovány v prostředí programu Matlab (The Mathworks, 1984-2013).

3 METODY

Kapitola metody je rozdělena na čtyři části. V první podkapitole je uvedeno základní chování nádrže. V další podkapitole je stručně popsán řídicí algoritmus pro řízení zásobní funkce nádrže. Ve třetí části jsou uvedeny optimalizační metody. Konkrétně to jsou mřížková metoda, metoda Monte-Carlo, genetické algoritmy a diferenciální evoluce. Poslední kapitola uvádí předpovědní modely a metody umělé inteligence. Jedná se o neuronové sítě, perceptronové sítě a fuzzy modul.

3.1 CHOVÁNÍ NÁDRŽE

V rámci práce je řešena zásobní funkce nádrže, která má zajistit požadovaný nalepšený odtok vody O_p . Zásobní objem byl stanoven na hodnotu 44 710 000 m³ a řídicí odtok vody z nádrže O_p na konstantní hodnotu 4.00 m³/s. V následujícím textu lze najít pojmy z matematického modelu pro řízení zásobní funkce nádrže. Teorie je obecně známa, proto by nebylo přínosné jí zde zdlouhavě rozepisovat. Byla popsána jinými autory např. (Starý, 2005). Schéma úlohy je vyobrazeno na obrázku 1. Nádrž má jeden přítok vody $Q(t)$ a jeden odtok vody z nádrže $O(t)$. Při simulování chování nádrže s měsíčním krokem je přítok popsán řadou průměrných měsíčních přítoků Q^τ (okrajové podmínky řešení) a odtok vody z nádrže je popsán řadou odtoků O^τ . Na konci každého časového kroku je objem vody v nádrži V^τ . τ značí u příslušných symbolů pořadí daného měsíce a nabývá hodnot $\tau = 1, 2, \dots, N$, kde N je počet měsíců, ve kterých je prováděno řešení.



Obr. 1 – Schéma nádrže

Chování nádrže je možno popsat základní rovnicí nádrže. Při časovém kroku 1 měsíc je vhodné použít její diferenční tvar

$$Q^t - O^t = \frac{V^t - V^{t-1}}{\Delta t} \quad (1.1)$$

kde V^{t-1} je objem vody v nádrži na počátku příslušného časového kroku a pro časový krok $\tau=1$ je počáteční podmínkou V^0 .

Členy řady O^t pro $t = 1, 2, \dots, N$ mohou nabývat nekonečně mnoho hodnot, které závisí na plnění nádrže a způsobu řízení odtoku vody z nádrže. [Kozel, 2017]

3.2 ŘÍDÍCÍ ALGORITMUS

Při hledání jednotlivých řešení úlohy je ve vztahu (1.1) při každém kroku nahrazena řada Q (okrajové podmínky) řadou předpovědí Q_p a je provedeno adaptivní rekurentní řízení pro všechny časové kroky τ . Počáteční objem vody v nádrži V^0 se při řízení v reálném provozu nahradí objemem získaným měřením. Při simulaci řízení je V^0 pro opakovaný výpočet nahrazen hodnotou V^1 z předchozího výpočtu.

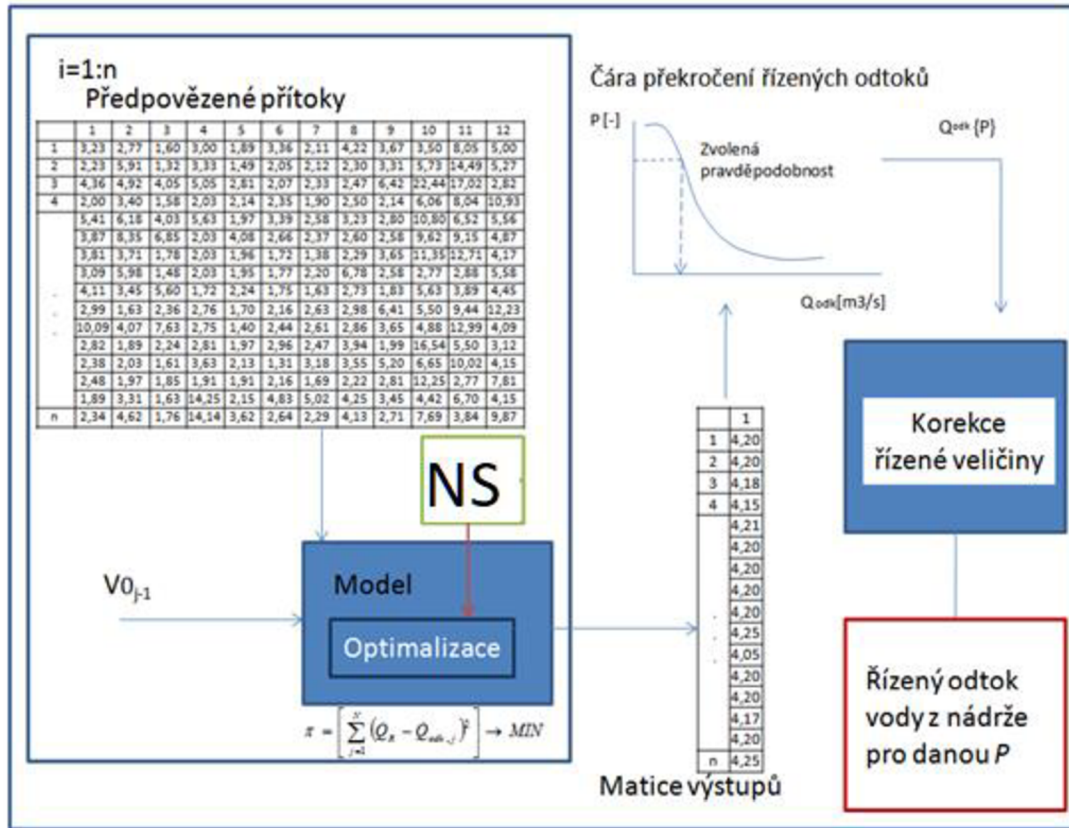
Pokud je hodnota $\tau > 1$ je počáteční podmínka V^{t-1} pro každý další časový krok τ dopočítána podle rovnice (1.1), ve které je na místo reálné hodnoty přítoku použita předpovězená hodnota, která je považována při výpočtu za hodnotu reálnou a za hodnotu odtoku je použita vypočtená hodnota z předchozího časového kroku řízení. Před zahájením dalšího kroku výpočtu je potřeba spočítat podle rovnice (1.1)

skutečnou hodnotu zásobního objemu. Odtok vody z nádrže, který je řízen na hodnotu O_p (řídící odtok), může nabývat hodnot z intervalu $(0, O_p)$. Pokud kapacita zásobního objemu nádrže není schopna přebytečnou vodu pojmout, může odtok vody z nádrže nabývat hodnot vyšších než je O_p . Pokud hodnoty odtoku vypouštěné z nádrže jsou nižší než O_p , vznikne porucha. Cílem algoritmu je provést řízení, při kterém je hodnota kritéria π je minimalizována. Řídící odtok vody z nádrže nabývá v průběhu řešení úlohy v práci konstantní hodnoty pro všechny časové kroky (měsíce). Pro nalezení optimálního řešení podle zvoleného kritéria lze použít velké množství metod (mřížková metoda, gradientní metody, evoluční algoritmy, atd.), prohledávajících prostor Ω , který má rozměr odpovídající počtu hledaných neznámých. V práci byla zvolena pro optimalizaci (modul optimalizace) metoda neuronových sítí.

Řídící algoritmus používá pro řízení jako vstupy předpovědi přítoků vody do nádrže a aktuální hodnotu zásobního objemu. Protože algoritmus pracuje s velkým počtem předpovězených řad přítoků, jsou kladeny velké časové nároky při použití metody zvolené pro optimalizační modul. Jako optimalizační modul byla zvolena metoda umělé inteligence (neuronové sítě), která je schopna výrazně snížit čas potřebný pro výpočet, pokud ji použijeme jako náhradu optimalizačního modulu, kdy samotný optimalizační modul vytvoří v předstihu matice vstupně-výstupních vztahů, podle kterých je metoda UI naučena. Na obrázku 2 je schéma stochastického modelu pro řízení zásobní funkce nádrže. Pro každý měsíc řízení je vytvořena matice předpovězených přítoků vody do nádrže s délkou předpovědi 1 až 11 měsíců. Počet předpovězených přítoků vody je v rozsahu 1 až n . Model provede n opakovaných řízení a vytvoří matici výstupů o n výstupech. Dále je sestavena pravděpodobnostní empirická čára překročení dle Čegodajeva viz. kapitola 5.2.1 řízeného odtoku vody z nádrže pro první měsíc, ze které je odečtena hodnota řízeného odtoku pro zvolenou pravděpodobnost překročení. Uvedenou veličinu je možno ponechat v odečteném tvaru. Pokud je hodnota korigovaného řízeného odtoku větší než hodnota řídícího odtoku O_p , je použita pro řízení hodnota O_p , zbytek vody odtéká ve formě jalového odtoku. [Kozel, 2017]

Ve smyslu adaptivity řízení se celý postup včetně generování nových předpovědí pro další časový krok opakuje.

Krok=měsíc



Obr. 2 - Schéma řídicího algoritmu.

3.3 OPTIMALIZAČNÍ METODY


Metody optimalizace se v práci používají pro optimalizaci zásobní funkce nádrže.

Matematická úloha optimalizace je snahou o nalezení takových hodnot proměnných, pro které daná cílová či účelová funkce nabývá minimální nebo maximální hodnoty. Mnoho teoretických úloh i úloh z reálného světa vede k řešení úlohy optimalizace. Optimalizace se často vyskytuje při modelování fyzikálních jevů, kde cílová funkce má význam energie fyzikálního systému, která má v rovnovážném stavu systému být minimální.


Optimalizace představuje teoretický základ pro operační výzkum.

3.3.1 Mřížková metoda (grid)

Oblast možných hodnot je prohledávána pravidelně s pevným krokem. Přesnost stanovení správné hodnoty regresních koeficientů závisí na velikosti zvoleného roku prohledávání.



Obr. 3 - Princip mřížkové metody při hledání jednoho regresního koeficientu, např. v rovnici $Y = aX$. [Starý, 2005]



Obr. 4 - Princip mřížkové metody při hledání dvou regresních koeficientů na různých rozlišovacích úrovních, např. v rovnici $Y = a_0 + a_1X$. [Starý, 2005]


Pro dosažení vysoké přesnosti řešení je třeba volit malý krok prohledávání. Značnému počtu řešených variant je možno čelit řešením na více rozlišovacích úrovních. Nejdříve započneme prohledávání s hrubým krokem. Po nalezení řešení prohledáváme jeho okolí s jemnějším krokem. Uvedený postup postupného zjemňování opakujeme až po nalezení řešení s požadovanou přesností. [Starý, 2005]

3.3.2 Metoda monte carlo

Random(x) – výběr náhodných čísel. Metoda spočívá v odstřelování oblasti $\langle a_{\min}, a_{\max} \rangle$ konečným dostatečným počtem náhodně volených regresních koeficientů. Je vysoká pravděpodobnost, že jeden ze zásahů bude do minima kriteriální funkce, resp. jeho blízkého okolí. Pro transformaci generovaných náhodných čísel $\xi \in \langle 0,1 \rangle$ na hodnotu regresního koeficientu je možno použít následující vztah


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

Pro generování náhodných čísel se na počítačích využívají procedury Random (ξ).



Obr. 5 - Užití metody Monte Carlo. [Starý, 2005]

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



Obr. 6 – Hustota pravděpodobnosti „bílého šumu“. [Starý, 2005]

Po dosažení řešení je možno opět prohledávat okolí dosaženého regresního koeficientu opakovaným postupem při zmenšení intervalu $\langle a_{\min}, a_{\max} \rangle$.

Obě popsané metody je možno snadno analogickým postupem rozšířit na řešení vícerozměrných úloh. [Starý, 2005]

3.3.3 Genetické algoritmy

Genetické algoritmy byly odvozeny na základě biologické genetiky a teorie evoluce, která ovlivňuje vývoj všeho živého na této planetě. Při vývoji jednotlivých druhů mají geny velký význam. Základem je DNA – deoxyribonukleová kyselina, ve které je zakódován kompletní popis daného jedince. DNA je dlouhý molekulární řetězec tvořený čtyřmi 30 odlišnými složkami. Uspořádání těchto složek reprezentuje genetický kód. V problematice genetických algoritmů se setkáváme s následujícími pojmy: Chromozóm je část DNA, která je stočená do záhybů. Gen jsou jednotlivé části chromozómu. Kompletní genetický popis organismu je tzv. genotyp. V souvislosti s genotypem se ještě uvádí i tzv. fenotyp, který je v podstatě fyzickým popisem genotypu (např. jestliže je v binárním pojetí genotyp „0101“, pak fenotyp je jeho dekadická hodnota „5“). Geny mohou nabývat pouze jistých hodnot, jejichž obecné označení je alela.

Genetické algoritmy pracují v počítačových aplikacích následujícím způsobem: Náhodně je vygenerována množina chromozómů, ze které jsou vybírány dvojice (rodiče) na základě toho, jak dobře splňují kritériální funkci. Potomci jsou tvořeni křížením svých rodičů, jež následně nahrazují. Stejně jako v přírodě, tak i v technických aplikacích hrají důležitou roli náhodné změny – mutace. To se v technice obvykle řeší pomocí generátoru náhodných čísel. Při používání genetických algoritmů v technických aplikacích se používají ještě další pojmy: Objektívni funkce – je to funkce, kterou chceme minimalizovat (v případě neuronových sítí je to globální chyba sítě). Vhodnost (fitness) je číslo, které nám udává vhodnost nového potomka z hlediska kritériální funkce (je to v podstatě matematický popis životního prostředí daného jedince), obvykle to bývá převrácená hodnota objektívni funkce. Čím je toto číslo větší, tím je i daný jedinec vhodnější pro dané okolní podmínky. Schéma je množina genů v chromozómu, které mají jisté specifické hodnoty.


V neuronových sítích se takováto skupina chápe jako skupina genů, která je schopna za určitých podmínek vytvořit žádaný efekt. Obsah genů je variabilní. Nejběžnější je obsah v binární podobě, avšak lze použít i dekadický, symbolický i jiný popis. Vlastní algoritmus genetické optimalizace je cyklus, ve kterém jsou vytvářeni noví potomci (jedinci), tvořící další generaci rodičů. Po každém cyklu testujeme, jestli je splněna podmínka ukončení. Vlastní schéma genetického algoritmu je následující:

1. Navržení genetické struktury
2. Inicializace
3. REPEAT
 - 1) Ohodnocení každého jedince v populaci
 - 2) Konverze genotypu na fenotyp
 - 3) Ohodnocení objektivní funkce
 - 4) Konverze objektivní funkce na vhodnost (fitness)
 - 5) Konverze vhodnosti na selekci rodičů
 - 6) Výběr rodičů
 - 7) Aplikace operátoru křížení na vybrané rodiče a vytvoření potomků, tvořících další generaci rodičů.
 - 8) Aplikace operátoru mutace
4. UNTIL není splněna podmínka ukončení

Z praktických důvodů je vhodné, aby numerické hodnoty fitness byly z otevřeného intervalu (0,1), proto se zavádí tzv. normalizovaná fitness. Normalizovaná fitness F_i^n má pro i . jedince z populace obsahující celkem n jedinců tvar:

$$F_i^n = \frac{F_i}{\sum_{i=1}^n F_i} \text{ [Volná, 2012]}$$

Kde F_i je vypočítaná fitness i . jedince.




Obr. 7 - Výběr rodičů. [Volná, 2012]

Výběr rodičů

Jednotková úsečka je rozdělena na úseky podle velikosti normalizovaných fitness hodnot jedinců z populace. Náhodně vygenerované číslo z intervalu (0,1) představuje polohu na úsečce (je reprezentované hrubou přerušovanou čarou) a podle této polohy určuje chromozóm. Z konstrukce této „rulety“ vyplývá: čím větší je fitness chromozómu, tím větší je i pravděpodobnost jeho výběru. Aplikace operátoru křížení probíhá u dvou vybraných rodičů ve dvou krocích, viz obrázek 8. Nejprve se náhodně stanoví pozice v chromozómu (např. k) a potom se vytvoří z původních dvou chromozómů noví dva jedinci tak, že první potomek je tvořen geny na pozici 1 až k prvním z rodičů a geny $k+1$ až l (l je délka chromozómu) druhého rodiče.

Druhý potomek má pořadí stanoveno opačně, tedy pozice 1 až k jsou získané od druhého rodiče, zatímco geny $k+1$ až l patří prvému z rodičů. Vzniknou tak dva zcela nové chromozomy. [Volná, 2012]



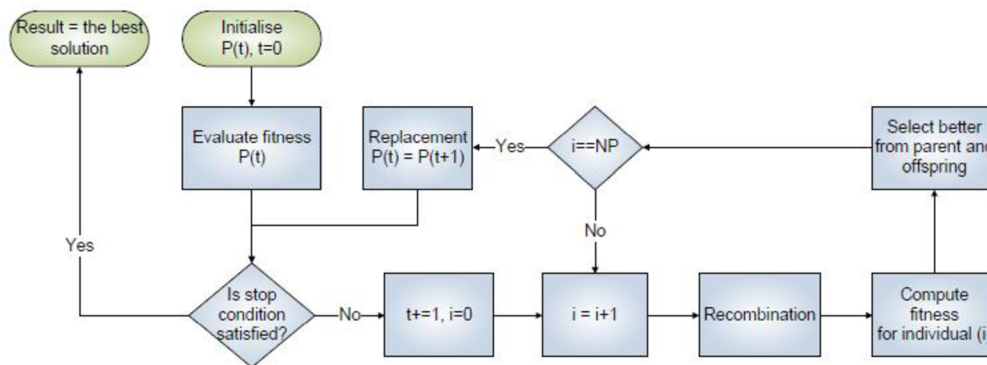
Obr. 8 - Křížení chromozómů. [Volná, 2012]

Mutace

Mutace jsou nezbytnou součástí genetických algoritmů. Díky nim lze mnohdy najít jedince, kteří lépe vyhovují okolním podmínkám a tak zkvalitnit jak genetický proces, tak i množinu jedinců – budoucích rodičů. Při mutaci se prochází jednotlivé geny chromozómu a s určitou velmi malou pravděpodobností se mění jejich hodnota, např. v binárním chromozómu se hodnota 1 změní na 0 a opačně. [Volná, 2012]

3.3.4 Diferenciální evoluce

Diferenciální evoluce (DE) je variantou evolučního algoritmu, která je navržena pro numerickou optimalizaci parametrů v oboru reálných čísel, ale je možno ji využít i k řešení diskretních úloh. Výhoda DE spočívá v jednoduchosti implementace, rychlosti a efektivitě. Zjednodušený vývojový diagram DE je ukázán na obrázku 9. [Weisser, 2010]



Obr. 9 - Vývojový diagram diferenciální evoluce. [Weisser, 2010]

P(t): populace v čase t, NP: velikost populace

Řídící parametry

DE pracuje s množinou NP, D-dimenzionálních parametrických vektorů $x_i^D(t)$, kde $i = 1, 2, \dots, NP$, které tvoří populaci každé generace G v čase t. Pro optimální funkci diferenciální evoluce je důležité správné nastavení velikosti populace NP, faktoru zesílení β a pravděpodobnosti křížení CR. Velikost dimenze D vektoru je dána počtem optimalizovaných parametrů řešeného problému.

- **Velikost populace:** Velikost populace NP má přímý vliv na velikost prohledávaného prostoru. Se zvětšující se velikostí populace roste velikost prohledávaného prostoru, ale také časová složitost algoritmu. Empiricky bylo zjištěno, že velikost populace $NP \approx 10D$. Z důvodu zkrácení výpočetního času se ve skutečnosti používá menší počet jedinců za cenu snížení prohledávaného prostoru $NP > 2n_v + 1$, kde n_v je počet použitých rozdílových vektorů

- **Faktor zesílení:** Určuje velikost mutace, neboli zesílení diferenciálního vektoru, viz. selekční schéma. Platí, že $\beta \in (0, \infty)$, přičemž malá hodnota faktoru zesílení má za následek delší dobu optimalizace a možnost uváznutí v lokálním minimu, a naopak velká hodnota β vede k riziku přeskočení globálního optima. Faktor zesílení by měl být snížen s rostoucí velikostí populace. Empirické studie dokazují, že velká hodnota NP a β často způsobí předčasnou konvergenci. Doporučená hodnota $\beta = 0,5$.
- **Pravděpodobnost křížení:** Má přímý vliv na diverzitu populace diferenciální evoluce. Velikost CR určuje počet zaměněných parametrů rodičovského vektoru $x_i^k(t)$, viz. (2.4.3). Velká hodnota parametru CR vede k zvýšení diverzity populace a k snížení prohledávání blízkého okolí jednotlivých jedinců v populaci. Zvýšení hodnoty CR často vede k rychlejší konvergenci, na druhou stranu snížení pravděpodobnosti křížení zvyšuje robustnost DE. [Weisser, 2010]

Inicializace populace

Inicializace populace se provádí náhodným generováním NP vektorů o velikosti k , která je dána počtem optimalizovaných parametrů:

$$x_i^{Dk}(0) = a^{mink} + r \cdot (a^{maxk} - a^{mink})$$

kde r je náhodně generované reálné číslo z intervalu $\langle 0, 1 \rangle$,

a^{maxk} , a^{mink} jsou konstantní vektory určující hranice jednotlivých částí každého vektoru,

$i = 1, \dots, NP$ je index vektoru v populaci,

$k = 1, \dots, D$ je parametr vektoru. [Weisser, 2010]

Reprodukční cyklus

Pro každého jedince v populaci je vygenerován zkušební vektor z_k , který je vytvořen kombinací rodičovského vektoru a šumového vektoru v . Poté je pro každou dimenzi

generováno náhodné číslo r z intervalu $\langle 0, 1 \rangle$. Je-li toto číslo menší než práh křížení CR , je zkušebnímu jedinci pro aktuální rozměr přiřazen parametr ze šumového vektoru, v opačném případě parametr rodiče, tj.:

$$zk_i^k(t+1) = \begin{cases} v_i^k(t+1) & \text{if } (r < CR) \\ P_i^k(t) & \text{else.} \end{cases} \quad [\text{Weisser, 2010}]$$

Kde: $P_i^k(t)$ je rodičovský vektor aktuální generace v čase t ,

$$i = 1, \dots, NP,$$

$$k = 1, \dots, D.$$

Po vytvoření zkušebního vektoru zk a jeho ohodnocení se tento vektor porovnává s rodičovským vektorem. Do nové generace přechází kvalitnější z obou vektorů.

K výpočtu šumového vektoru je možno použít více než jeden diferenční vektor, který určuje velikost mutace. Jestliže n_v je počet použitých diferenčních vektorů a NP je velikost populace, potom celkový počet diferenčních odchylek je dán:

$$\binom{NP}{2n_v} 2n_v! \approx O(NP^{2n_v}) \quad [\text{Weisser, 2010}]$$

Selekční schéma

Šumový vektor v se vytváří podle některého ze selekčních schémat. Tyto schémata se označují jako DE/x/y/z a představují různé druhy výběru vektorů, počet použitých diferenčních vektorů a způsob křížení. V případě použití tohoto zápisu x určuje způsob výběru cílového vektoru, y udává počet diferenčních vektorů a určuje způsob křížení. [Weisser, 2010]

Auto-adaptivní diferenciální evoluce- SaDE

Auto-adaptivní DE (*Self-adaptive Differential Evolution*) (SaDE) kombinuje 2 odlišné způsoby mutace v jedné variantě diferenciální evoluce. Tyto mutace jsou voleny v závislosti na parametru p , který značí pravděpodobnost vybrání dané metody mutace a je postupně adaptován v závislosti na vývoji evoluce. [Weisser, 2010]

3.4 METODY UMĚLÉ INTELIGENCE

Metody umělé inteligence se dají použít k nahrazení optimalizačních metod.

Umělá inteligence představuje obor zabývající se tvorbou algoritmů a technik, které se snaží přiblížit projevům inteligentního chování. V poslední době řada autorů pod pojmem umělá inteligence míní především populární obor umělých neuronových sítí. Toto úzké zařazení opomíjí celou řadu přístupů z oblasti strojového učení, tvorby expertních systémů, algoritmů inspirovaných přírodními procesy - např. evoluční a genetické techniky nebo algoritmy prohledávání stavového prostoru. V této práci si představíme dvě metody umělé inteligence. Neuronové sítě, které byly v práci použity a metoda umělé inteligence s Fuzzy logikou. Obě metody řadíme do učících se systémů.

3.4.1 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. V roce 1949 navrhl Donald Hebb ve své knize Organization of Behaviour model založený na biologické podobnosti, který je schopný učení. Dominantní postavou 50. let se v oblasti NS stal Frank Rosenblatt. Vyvinul třídu neuronů nazývaných "Perceptrony". Jeho přístup výrazně posunul vpřed teorii založenou na rozpoznávání vzorů a na asociativním učení.

V roce 1982 publikoval John Hopfield, profesor chemie a biologie v Kalifornii v Technologickém institutu články o NS, 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 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, Nováka, Bílu a Křivana.

Co se týká publikací našich autorů zaměřených na užití NS ve vodním hospodářství, je možno uvést příspěvek Nacházela a Tomana, zaměřený na problematiku NS a jejich užití pro optimalizaci výroby elektrické energie v soustavě vodních elektráren. Kromě toho lze uvést některé práce doc. Ing. Miloše Starého, publikované samostatně nebo se spolupracovníky. Z nich je možno vzpomenout Modelování hydrogramů povodňových vln v systému stanic s využitím neuronových sítí. Z prací, které publikoval v zahraničí, je možno vzpomenout Neural Networks and Predictions in Applied Hydrology, kde byly shrnuty některé zkušenosti s užitím NS v aplikované hydrologii. [Nacházel, Starý, Zezulák, 2004]

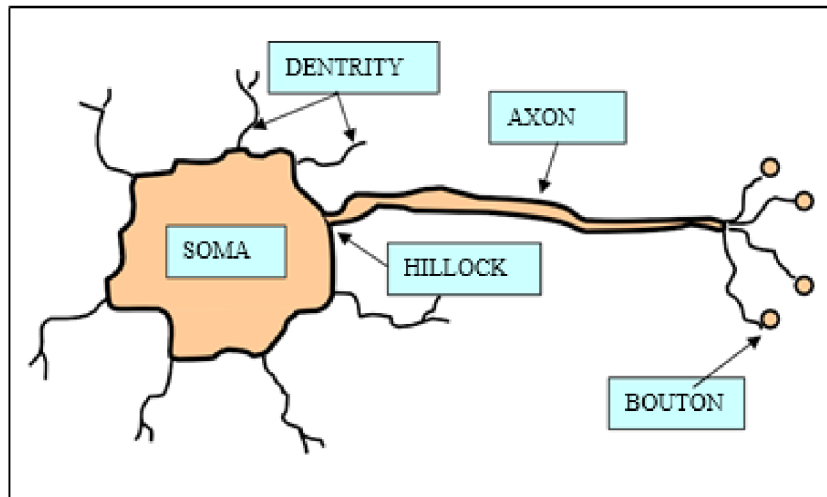
Základní pojmy

Pro pochopení funkce NS je třeba uvést některé základní pojmy. Lidský mozek se sestává ze sítě mnoha biliónů speciálních buněk, které se nazývají neurony. Typický neuron znázorněný na obrázku 10 se skládá z těla neuronu (soma), z něhož vybíhá nervové vlákno (axón). 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, jehož schéma je uvedeno na obrázku 11.

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 obrázku 12 tak, že vstupní vrstvu tvoří vstupní neurony, dále následuje skrytá vrstva neuronů (může být více vrstev) a vrstva

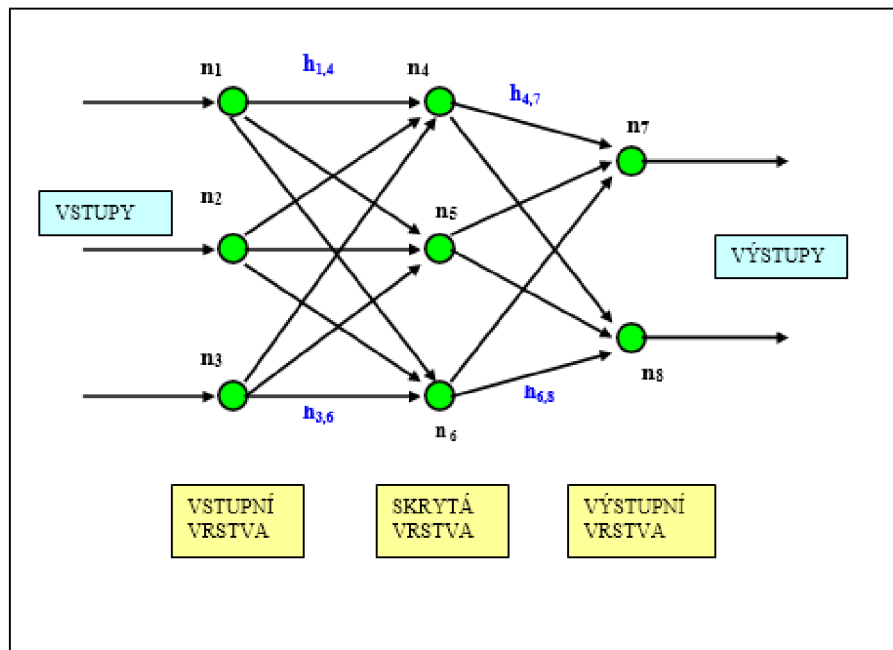
výstupních neuronů. Neurony jsou v NS průběžně očíslovány. Každý neuron v libovolné skryté vrstvě je spojen hranou s každým neuronem vrstvy předchozí i vrstvy následné. [Nacházel, Starý, Zezulák, 2004]



Obr. 10 - Biologický neuron. [Nacházel, Starý, Zezulák, 2004]



Obr. 11 - Umělý neuron. [Nacházel, Starý, Zezulák, 2004]



Obr. 12 - Umělá neuronová síť. [Nacházel, Starý, Zezulák, 2004]

Způsob učení (trénování)

Je dána tréninková matice, 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 takové matice je znázorněno v tab.1. Vstupní veličiny X_1 , X_2 , X_3 a X_4 , jsou zapsány do vstupních sloupců označených symbolem \square , výstupní veličiny Y_1 a Y_2 jsou pak uvedeny ve sloupcích výstupních, označených symbolem $\square\uparrow$.

Číslo uvedené ve sloupci i udává pořadí příslušného vzoru. [Nacházel, Starý, Zezulák, 2004]

Tab. 1 - Schéma tréninkové matice [Nacházel, Starý, Zezulák, 2004]

	□	□	□	□	↑	↑
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 W , jehož prvky tvoří neznámé váhy, resp. i parametry přenosových funkcí a hodnoty prahů. Úkolem je nalézt takovou hodnotu vektoru 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 změn 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 nebo Šíma a Neruda. 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 se 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. [Nacházel, Starý, Zezulák, 2004]

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. [Nacházel, Starý, Zezulák, 2004]

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.

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. [Nacházel, Starý, Zezulák, 2004]

Simulátory neuronových sítí

Celá práce se programovala v softwaru MATLAB od společnosti MathWorks. Další softwarových produktů byla pro tento účel ve světě vyvinuta celá řada s větší či menší úspěšností. V současnosti existuje mnoho dalších softwarových simulátorů neuronových sítí. Jedním z nich je software ARTINT ver.2.0, který byl vyvinut společnostmi Mentar a EGÚ v naší republice. Je možno jej považovat za první komerční software u nás. Jako další tu je MATLAB, který má 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 flexibilní prostředí pro simulaci většiny známých neuronových sítí a používá řadu učících metod včetně základního algoritmu backpropagation.

Z dostupného komerčního software je uváděn 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. [Nacházel, Starý, Zezulák, 2004]

3.4.2 Perceptronové sítě

Jedním z nejdůležitějších modelů používaných dodnes je tzv. perceptron, jehož potenciál je definovaný jako vážený součet vstupních signálů. Pokud tento vnitřní potenciál neuronu překonává jeho prahovou hodnotu ϑ , dojde k excitaci neuronu na hodnotu 1. V opačném případě je neuron inhibován, což je reprezentováno hodnotou 0.


Matematicky to lze vyjádřit jako funkce signum:

$$y = \text{Sgn}\left(\sum_{i=1}^n w_i x_i - \vartheta\right) \quad \begin{array}{l} \text{Sgn}(x) = 1, x > 0 \\ \text{Sgn}(x) = 0, x \leq 0 \end{array} \quad [\text{Novák, 1998}]$$

Zavedením stálého neuronu na vstupu se stavem excitace $x_0 = 1$ a vazbou k neuronu $w_0 = -\theta$ lze předchozí funkci zjednodušit takto:

$$y = \text{Sgn} \left(\sum_{i=1}^n w_i x_i \right) \quad [\text{Novák, 1998}]$$

Pokud provedeme analýzu výrazu v závorce, získáme rovnici nadroviny, v dvourozměrném případě reprezentovanou přímkou.



Tato rovina rozděluje vstupní prostor na dva poloprostory. Jinými slovy, jsme schopni prostřednictvím perceptronu rozlišit dvě třídy vstupů. [Novák, 1998]


Existují i jiné sítě např. Kohonenova neuronová síť nebo radiální neuronová síť. Tyto sítě nebyly v práci použity.

3.4.3 Fuzzy modul

Fuzzy modul vychází z teorie fuzzy logic. Teorie fuzzy je schopna využít slovní popis, který běžné matematické modely nejsou schopny využít. Je tedy schopna přiřadit veličině nejen výrok pravda (horký, 1) a nepravda (studený, 0), ale i různé přechody mezi stavy (horký, teplý, vlažný, studený). Pro řízení systémů se v práci používá učící se fuzzy model, který je schopen nejen přiřadit popis hodnoty, ale i provést řízení na základě matice pravidel, matice vzorového řízení (vstupně-výstupních vztahů) a nalezených funkcí příslušnosti pro jednotlivé vstupní i výstupní proměnné. Z fuzzy modulu se stává učící se fuzzy modul po provedení optimalizace poloh jednotlivých bodů a tvaru funkcí příslušnosti a báze pravidel. [Kozel, 2017]

Základní pojmy z teorie fuzzy

V podkapitole je uvedeno několik základních pojmů z teorie fuzzy. Jednotlivé pojmy jsou popsány pouze stručně, protože podrobnější popis lze najít v pracích jiných autorů (Jura, 1996), (Nacházel, Starý, Zezulák, 2004). Celý proces lze rozdělit do tří základních částí: fuzzifikace, fuzzy inference a defuzzifikace.



Fuzzifikace

Tato operace převádí reálné proměnné do jazykových proměnných. Může se například jednat o reálnou proměnnou, a to cenu výrobku, po fuzzifikaci (transformaci) vznikne jazyková proměnná cena, např. s pěti atributy (malá, spíše malá, střední, spíše vyšší, vysoká).

Fuzzy inference

Fuzzy inference transformuje ostré hodnoty vstupů na fuzzy množinu podle báze pravidel, poloh a tvarů funkcí příslušnosti.

Defuzzifikace

Defuzzifikace transformuje výsledky fuzzy logiky, což je fuzzy množina, do ostré hodnoty. V závislosti na pravidlech a hodnotách vstupních veličin a tvaru a rozmístění funkcí příslušnosti. V literatuře můžeme najít mnoho typů metod defuzzifikace. Mezi nejčastěji používané se řadí metoda těžiště ploch (COA) a metoda středu ploch (BOA).

Fuzzy modely

Fuzzy modely jsou použity jako náhrada optimalizačního modulu (modely EA) za účelem zkrácení doby výpočtu a využití vlastností učícího se systému. [Kozel, 2017]

4 PŘEDPOVĚDNÍ MODEL

V kapitole předpovědní modely, je popsán zonální a modifikovaný zonální předpovědní model. Dále je zde uvedena transformace historických, distribuční funkce a nakonec jsou stručně zmíněny dispečerské grafy.

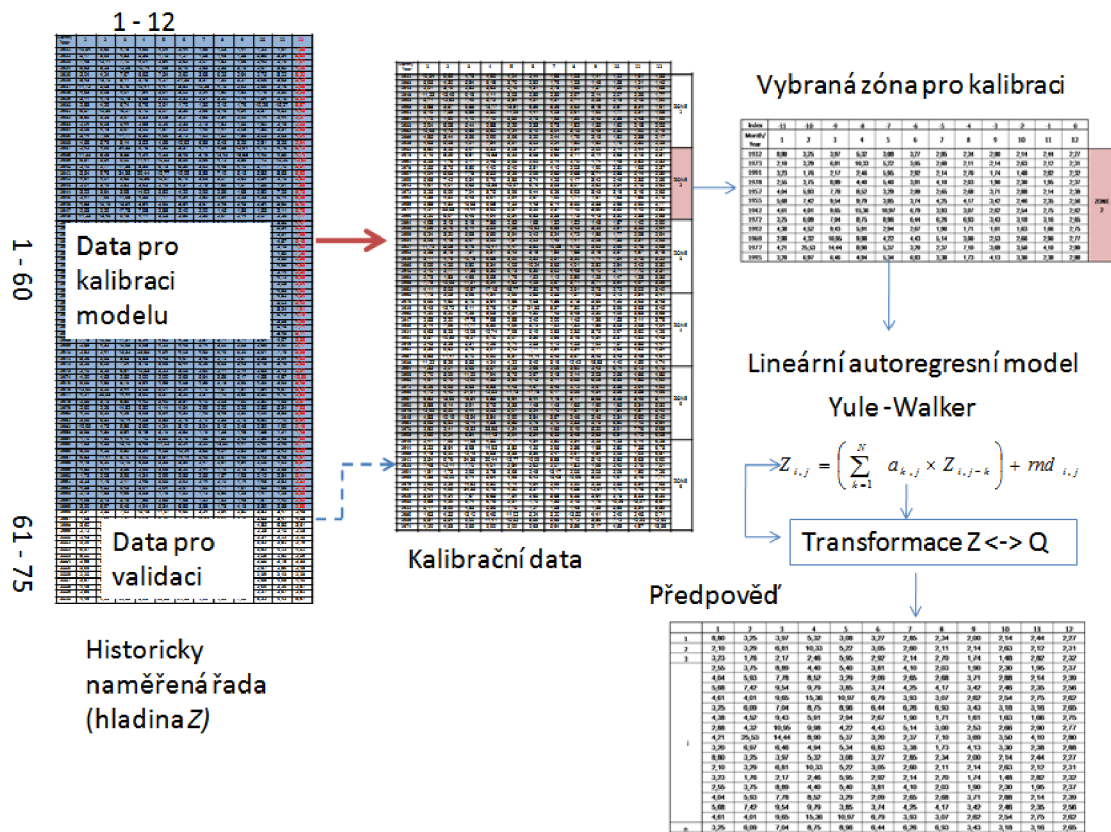
4.1 ZONÁLNÍ MODEL

Výhodou zonálních předpovědních modelů (Marton, Menšík, Starý, 2015) oproti klasickým předpovědním modelům je, že se historicky naměřená data (průměrné měsíční průtoky) v řešeném měsíci, ve kterém se vydává předpověď, rozdělí do zón výskytu. Průměrné měsíční průtoky historické řady se seřadí v řešeném měsíci, na jehož konci je vydávána předpověď (např. ve všech lednech) od nejmenšího k největšímu dle měsíce s posledním měřeným průtokem a rozdělí se do předem určeného počtu zón. Průměrné měsíční průtoky reálné průtokové řady ležící v dané zóně a jejich následné průběhy (délka je určena délkou předpovědi průtoků) tvoří pracovní oblast průtoků (zón). Ostatní historické průběhy reálné průtokové řady nejsou pro tvorbu předpovědi využity. Poté jsou ve zvolené zóně data zbavena asymetrie a z takto transformovaných dat je zkonstruováno trojúhelníkové rozdělení (aproximace hustoty pravděpodobnosti vzhledem k malému počtu realizací v některých zónách). Za předpovězený průtok je vybrán modus předpovědi. Výhodou zatřídění průtoků je, že pokud se průtok, podle kterého je předpověď zatříděna do zóny, nachází v zóně malých průtoků, předpověď bude v rozmezí průtoků, které jsou s uvedenou zónou spojeny historickým výskytem. [Kozel, 2017]

4.2 MODIFIKOVANÝ ZONÁLNÍ PŘEDPOVĚDNÍ MODEL

Rozdělení pracovní oblasti průtokových řad do zón je provedeno stejně jako u dříve popsaného zonálního modelu. Modifikovaný zonální model se liší tím, že na vybranou zónu je aplikován neuronová síť. Historicky měřené průtoky se převedou na úroveň hladiny Z podle způsobu popsaného v kapitole 4.3, zóna je pro pracovní měsíc určena vždy podle posledního naměřeného průtoků.

Korelační matice, která je základním vstupem do Yule-Walkerových rovnic, je počítána pouze z historicky měřených průtoků vyskytujících se v přiřazené zóně. Ke zbytku dat nemá model při tvorbě korelační matice přístup. Ze sestavené korelační matice se s využitím Yule-Walkerových rovnic vyčíslí regresní koeficienty. Postup modelu je dále stejný jako v případě lineárního autoregresního modelu. Na obrázku 13 je vyobrazeno schéma modelu a jeho kalibrace a validace. Svislý text u matice měřených dat zobrazuje rozsah měřených roků použitých pro kalibraci (1 - 60) a rozsah měřených průtoků použitých pro validaci (61 -75) pro první krok řešení, protože data pro kalibraci se postupně rozšiřují o již historicky proběhlé roky z pohledu validace (pro 62. rok je již 61. rok historií, a proto může být použit pro kalibraci). Vodorovný text zobrazuje měsíce v roce. [Kozel, 2017]



Obr. 13 - Schéma Modifikovaného zonálního modelu. [Kozel, 2017]

4.3 TRANSFORMACE HISTORICKÝCH DAT

Práce s daty probíhala na úrovni průměrných měsíčních průtoků, kdy se data roztřídily dle měsíce, ve kterém se vyskytly. Každý měsíc v roce má jiné pravděpodobnostní rozdělení a jinou autokorelační funkci. Z uvedeného důvodu by bylo generování průtokových řad problematické. Proto byl pro generování použit obvyklý postup, kdy se řady transformují na normované normální rozdělení $N(0, 1)$ - hladina Z . Některé stochastické modely potřebují přidat náhodné číslo (parametr), kdy je velmi výhodné toto náhodné číslo přidat na úrovni Z . Tam proběhla jejich analýza a následné generování krátké umělé řady. Vygenerovaná řada se pak vrací inverzní transformací na původní rozdělení.

Transformace dat byla provedena ve dvou krocích. Prvním krokem bylo odstranění asymetrie dat - transformace na hladinu Y . V první fázi řešení byly použity různé typy logaritmických transformací, jejichž výsledky byly nepřesvědčivé. Proto bylo přistoupeno k odstranění asymetrie Box-Coxovou rovnicí (Box, Cox, 1964)

$$Y_{i,j} = \frac{(Q_{i,j})^{r_j-1}}{r_j} \quad [\text{Hanousek, Charamza, 1992}]$$

kde $Y_{i,j}$ je transformovaný průměrný měsíční průtok na rozdělení bez asymetrie, $Q_{i,j}$ je průměrný měsíční průtok, který je transformován, r_j je koeficient transformace pro vybraný měsíc, j je pořadí měsíce (1-12, leden je 1 a prosinec je 12) a i je index průtoků.

Problémem při použití Box-Coxovy rovnice se ukázal parametr r , který lze jen obtížně dopočítat, a proto bylo přikročeno k jeho stanovení numerickou optimalizací pomocí mřížkové metody. Kritériem optimalizace byla odchylka koeficientu asymetrie od nuly, která byla minimalizována. Optimalizace se zastavila, pokud hodnota asymetrie byla v rozmezí hodnot -0.001 až +0.001 (předpoklad normálního rozdělení).

Dalším krokem byla samotná transformace členů průtokové řady z hladiny Y na hladinu Z , kde dosahují normovaného normálního rozdělení. Transformace proběhla za použití běžných transformačních vztahů

$$Z_{i-1,j} = \frac{Y_{i-1,j} - X_{j-1}}{S_{j-1}} \quad [\text{Hanousek, Charamza, 1992}]$$

$$Y_{i,j} = x_j + s_j \cdot Z_{i,j} \quad [\text{Hanousek, Charamza, 1992}]$$

kde Y_{ij} je transformovaný průměrný měsíční průtok na rozdělení bez asymetrie, Z_{ij} je předpovězený průměrný měsíční průtok, který je transformován, x_j je průměr hodnot v předpovězeném měsíci, s_j je směrodatná odchylka předpovídaného měsíce, j je pořadí měsíce (1-12, leden je 1, prosinec je 12) a i je číslo předpovědi (1 - 1000). [Kozel, 2017]

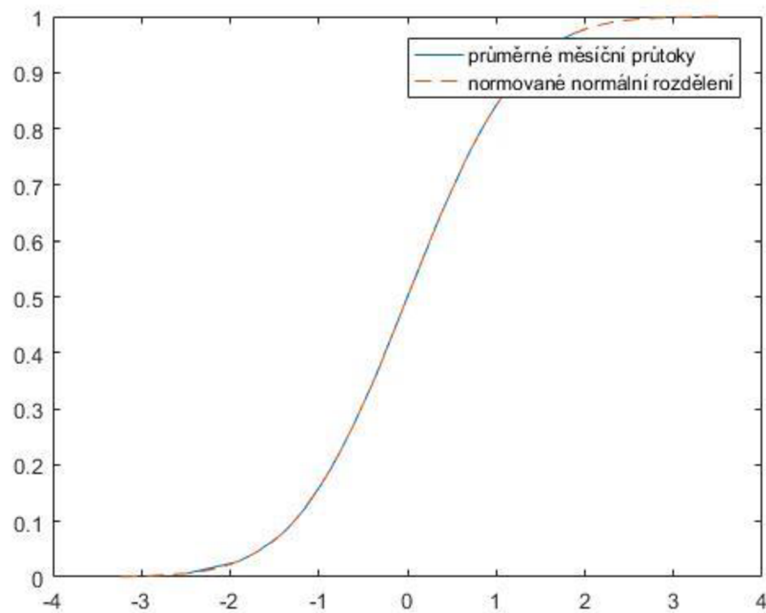
4.4 SESTAVENÍ DISTRIBUČNÍ FUNKCE

Bylo rozhodnuto, že pro každý měsíc bude sestavena kumulativní distribuční funkce, protože průtoky v každém měsíci podléhají jinému pravděpodobnostnímu rozdělení. Otázkou tak zůstalo, jakou metodu zvolit pro sestavení distribuční funkce. Nakonec byla zvolena metoda, která byla použita pro stochastické předpovědní modely. Data naměřená v jednotlivých měsících jsou zbavena asymetrie pomocí Box-Coxova pravidla a dále jsou transformována pomocí běžných transformačních vzorců na normální normované rozdělení.

Před použitím výše uvedeného postupu se musel ověřit předpoklad normovaného normálního rozdělení na hladině Z . Z dat transformovaných uvedeným postupem byla vykreslena distribuční funkce normálního normovaného rozdělení s parametry $N(0,1)$. Z ní bylo ve druhém kroku vygenerováno 1000 náhodných čísel z normálního normovaného rozdělení s parametry $N(0,1)$ a byla z nich sestavena distribuční funkce normálního normovaného rozdělení. Obě takto získané distribuční funkce byly pro všechny měsíce porovnány.

Z porovnání distribučních funkcí bylo zjištěno, že distribuční funkce transformovaných dat je téměř shodná s reálnou distribuční funkcí normálního normovaného rozdělení, a proto bylo rozhodnuto, že jako distribuční funkce lze použít distribuční funkce normálního normovaného rozdělení a z ní získané vzorky


transformovat pomocí zpětných transformačních vztahů na pravděpodobnostní rozdělení každého měsíce. [Kozel, 2017]



Obr. 14 – Srovnání distribuční funkce pro vybraný měsíc.

4.5 DISPEČERSKÉ GRAFY

Dispečerské řízení pomocí grafu je vhodné pro zásobní i ochrannou funkci nádrže, kde záleží na dodržování spádových poměrů pro energetiku, nebo manipulaci s hladinou dle požadavků v období rekreace. Dispečerský graf předepisuje funkci O ($V(t)$) v základní rovnici nádrže (převážně pro jeden rok) na základě dosažených výsledků při simulaci v historickém období. Na obrázku 15 jsou uvedeny dva základní dispečerské grafy. Dispečerský graf na obrázku a) je znázorněn protiporuchovou čarou $VD(t)$, která omezuje zdola oblast zvýšeného odběru, kde může být $O > O_p$. Nestanoví, o kolik je možno O_p zvýšit. Proto je nutno pro zvýšení odtoku stanovit určitou konvenci. Výhodnější je dispečerský graf na obrázku b), z kterého je možno přímo odečíst velikost odtoku z nádrže v závislosti na plnění zásobního objemu a čase. [Starý, 2006]



Obr. 15 - Základní typy dispečerských grafů. [Starý, 2006]

Sestrojení dispečerského grafu je možné, má-li přítok do nádrže v letech s výraznými málovodnými obdobími (blízkými návrhovému období) aspoň přibližně shodný průběh. Důležitý je časový výskyt vodných a málovodných období, který by se měl ve všech rocích přibližně shodovat. Základní podmínkou pro sestavení dispečerského grafu je existence ročního průtokového cyklu. Čím je roční cyklus průtoků pravidelnější, tím určitější dispečerský graf lze sestavit.

Podmínkou pro sestavení je existence ročního průtokového cyklu, vodné a málovodné období se musí opakovat v každém roce, reálná nebo umělá průtoková musí být co nejdelší, aby byla ideálním podkladem pro sestavení. [Starý, 2006]

5 STATISTICKÉ METODY

5.1 NORMÁLNÍ ROZDĚLENÍ A NORMOVANÉ NORMÁLNÉ ROZDĚLENÍ

Normální rozdělení neboli Gaussovo rozdělení je jedno z nejdůležitějších rozdělení pravděpodobnosti spojité náhodné veličiny. Jeho důležitost ukazuje centrální limitní věta, která tvrdí, že součet či aritmetický průměr velkého počtu libovolných

vzájemně nezávislých a nepříliš „divokých“ náhodných veličin se vždy podobá normálně rozdělené náhodné veličině.

Normální rozdělení proto za určitých podmínek dobře aproximuje řadu jiných pravděpodobnostních rozdělení, i když v praxi málokteré rozdělení je přesně normální. [Hanousek, Charamza,1992]


Distribuční funkci normálního rozdělení náhodné veličiny určíme podle vztahu:

$$F(x) = \int_{-\infty}^x \frac{1}{\sigma_x \sqrt{2\pi}} e^{-\frac{(t-\mu_2)^2}{2\sigma_2^2}} dt \quad [\text{Hanousek, Charamza,1992}]$$

Hustotu pravděpodobnosti normálního rozdělení náhodné veličiny určíme podle vztahu:

$$f(x) = \frac{1}{\sigma_x \sqrt{2\pi}} e^{-\frac{(x-\mu_x)^2}{2\sigma_x^2}}$$

[Hanousek, Charamza,1992]



Obr. 16 - Hustota pravděpodobnosti obecného normálního rozdělení. [Hanousek, Charamza,1992]

Rozdělení $N(0,1)$ bývá označováno jako normované normální rozdělení.

Distribuční funkci normovaného normálního rozdělení náhodné veličiny určíme podle vztahu:


$$F(u) = \int_{-\infty}^u \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$$

[Hanousek, Charamza,1992]

Hustotu pravděpodobnosti normovaného normálního rozdělení náhodné veličiny určíme podle vztahu:

$$f(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}}$$

[Hanousek, Charamza,1992]



*Obr. 17 - Hustota pravděpodobnosti normovaného normálního rozdělení.
[Hanousek, Charamza,1992]*

5.2 ČÁRA PŘEKROČENÍ


Čára překročení je zcela zásadní pracovní nástroj v hydrologii. Poskytuje informaci kolikrát nebo po jakou dobu byla určitá hodnota znaku v určitém období (např. pozorování) dosažena nebo překročena. Výsledkem zpracování čar překročení jsou mimo jiné návrhové veličiny pro projektování vodohospodářských a jiných staveb.

Empirické čáry překročení: Výsledek zpracování jednotlivých statistických souborů.

Teoretické čáry překročení: Využívají se základní statistické charakteristiky souborů a zákony rozdělení pravděpodobnosti. Smyslem vyrovnání průběhu ve střední části a extrapolace do oblasti extrémních hodnot. [Bém, Bémová, 1963]

5.2.1 Možnosti zpracování empirických čar překročení

1. Pro rozsáhlé soubory se v minulosti používala metoda založená na rozdělení prvků statického souboru do dílčích tříd – intervalů. Ty byly charakterizovány počtem výskytů – histogram četnosti. Čára překročení je potom součtovou čar k histogramu četnosti.



Obr. 18 - Ukázka empirické čáry překročení. [Bém, Bémová, 1963]

2. Na základě výpočtu pravděpodobnosti po seřazení souboru o n prvcích dle velikosti, m je potom pořadové číslo prvku.

Základní rovnice
$$p = \frac{m}{n} \quad [\text{Bém, Bémová, 1963}]$$

Čegodajev
$$p = \frac{m-0,3}{n+0,4} \quad [\text{Bém, Bémová, 1963}]$$

3. V případě sloupcového zobrazení čáry jevu seřazením jednotlivých sloupců dle velikosti klesajícím pořadí.
4. Obecně z čáry četnosti jako součtovou čáru k čáře diferenciální. [Bém, Bémová, 1963]

6 POUŽITÝ SOFTWARE

MATLAB je interaktivní platforma, která je navržena s programovacím jazykem čtvrté generace. Je z velké části používán pro výpočetní úkoly v matematice na vysoké úrovni nebo v jiných oblastech. Ačkoli to bylo zpočátku pouze pro výpočetní účely, nyní se diverzifikovalo do různých dalších oblastí. Byla upravena tak, aby měla různé nové funkce, které zlepšily jeho výkon ve všech aplikacích, ve kterých se používá. Společné komodity, které tento programovací jazyk používají, jsou většinou oddělení akademické sféry. Věda, inženýrství a ekonomika jsou doménami, které maximálně využívají programovací software MATLAB. [Matlab, 2007]

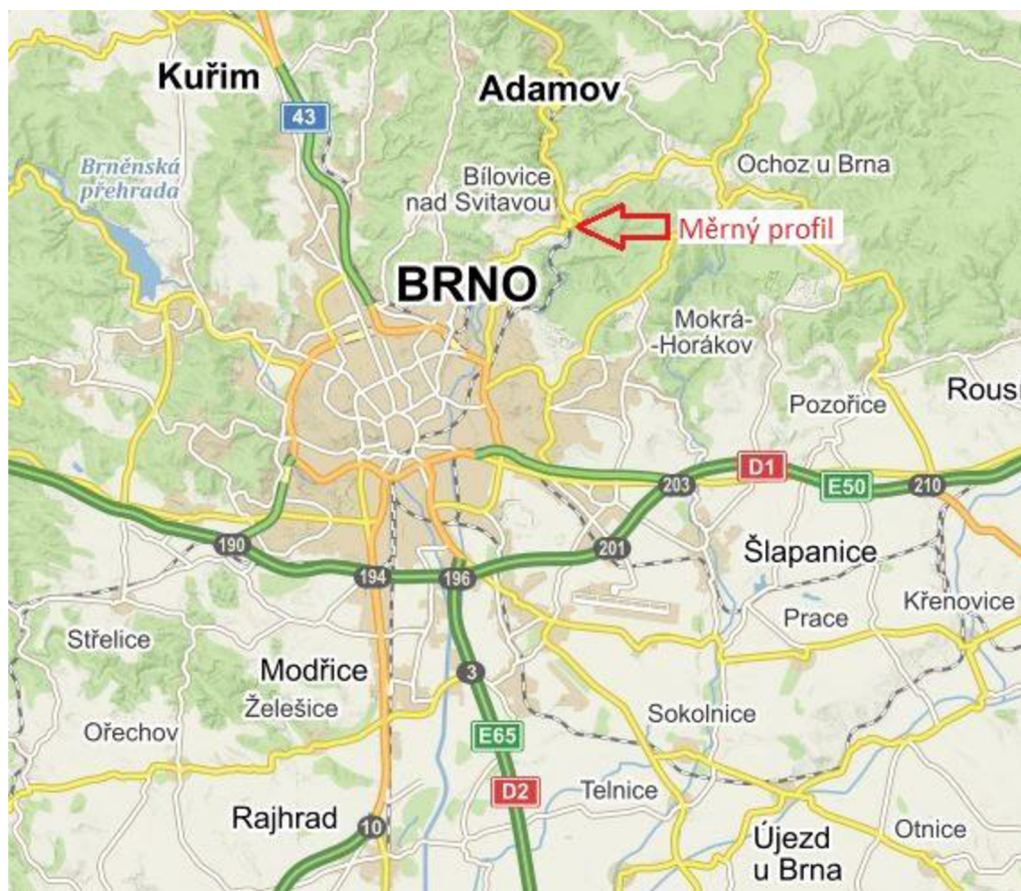
6.1 APLIKACE

Programovací jazyk MATLAB se stal velmi užitečným v mnoha univerzálních polích. S funkcemi, jako je vektorový výpočet, numerická matice a také schopnost manipulovat s algoritmem, se software používá pro mnoho aplikací. První a nejdůležitější aplikace je vyrábět řešení pro nejkompexnější systém rovnic. Mnozí studenti jsou závislí na softwaru MATLAB, který řeší výpočty na vysoké úrovni. Stimulace je další významnou aplikací tohoto softwaru. Některé z dalších triviálních aplikací jsou zobrazování, analýza, vizualizace a průzkum. [Matlab, 2007]

7 APLIKACE ŘÍZENÍ ZÁSOBNÍ FUNKCE NÁDRŽE

Řízení bylo aplikováno na fiktivní vodní nádrž, která byla navržena v měrném profilu Bílovice nad Svitavou. Základní parametry fiktivní nádrže byly stanoveny následovně. Zásobní objem na hodnotu $44\,710\,000\text{ m}^3$ a řídicí odtok vody z nádrže O_p na konstantní hodnotu $4.00\text{ m}^3/\text{s}$. Profil byl vybrán z důvodu dostupnosti dat,

kteřá byla k dispozici na pracovišti, a dlouhé řady reálných průměrných měsíčních průtoků, kteřá je velmi málo ovlivněna řízením velké vodní nádrže situované v horní části povodí. Nádrž je navržena tak, aby během jejího řízení vznikaly dostatečně dlouhé a hluboké poruchy proto, aby se použitá metoda aplikovaná na řízení její zásobní funkce mohla dostatečně projevit. Při sestavování řídicích algoritmů byly zanedbány nejistoty dalších vstupů a rovněž ztráty spojené s provozem nádrže včetně ztráty výparem.

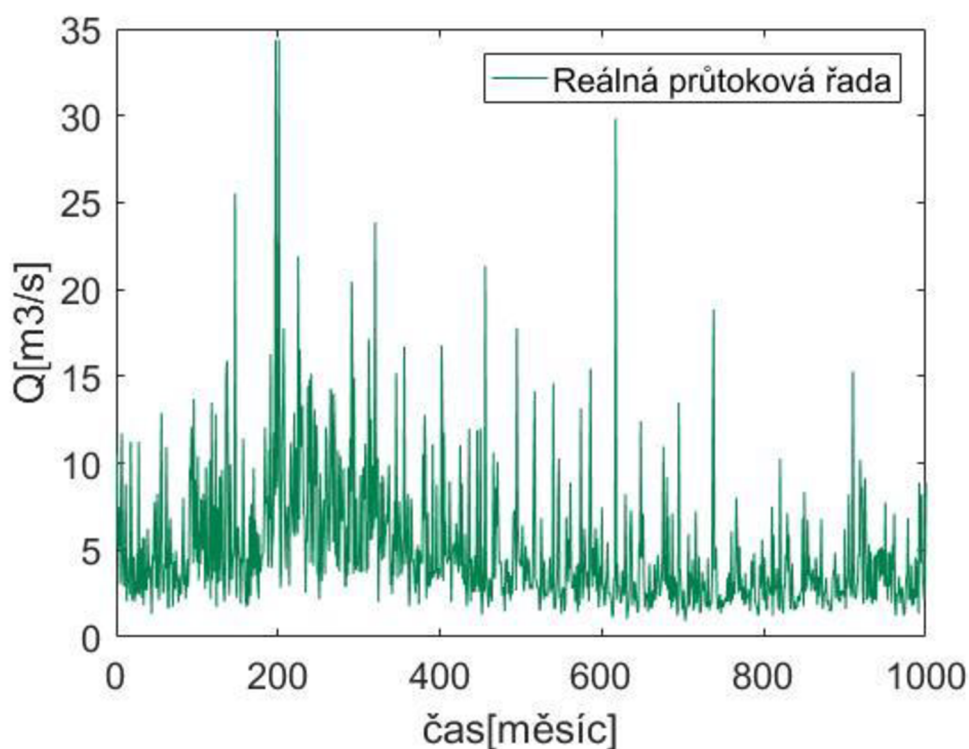


Obr. 19 – Měrná stanice Bílovice nad Svitavou.

7.1 HISTORICKÁ DATA A PŘEDPOVĚDNÍ MODEL

Pro sestavení i následnou validaci předpovědního modelu byla použita 90 let dlouhá řada průměrných měsíčních průtoků (od roku 1921 do roku 2010). Reálná řada je vykreslena na obrázku 20, kde mřížka má krok 12 měsíců. Řada vznikla měřením v měrném profilu Bílovice nad Svitavou, který se nachází na řece Svitavě.

Dlouhodobý průměrný průtok Q_a na měrném profilu je $4,87 \text{ m}^3/\text{s}$. Nad profilem se nenachází žádné velké nádrže, které by ovlivňovaly přirozený průběh řady. Řada byla rozdělena na dvě části. Prvních 75 let bylo použito pro kalibraci předpovědního modelu a posledních 15 let bylo použito pro validaci modelu. Průtoky v každém měsíci mají jiné pravděpodobnostní rozdělení, proto pro potřeby předpovědního modelu bylo přistoupeno k jejich transformaci na jednotné rozdělení (normované normální rozdělení viz kapitola 5.1).



Obr. 20 – Reálná průtoková řada na měrné stanici Bílovice nad Svitavou.


7.2 KALIBRACE A VALIDACE ŘÍDÍCÍCH MODULŮ

Kapitola se zabývá kalibrací a validací řídicího modulu a ověřením schopnosti neuronové sítě nahradit optimalizační modul. Řídicí modul používal 100% předpovědi (výšky reálné řady) pro svou kalibraci a validaci, a proto nepotřebují předpovědní modely.

U učícího se modulu (NS) byla v první fázi vytvořena matice vstupně-výstupních vztahů (matice vzorů), která byla získána pomocí diferenciální evoluce, která je popsána v kapitole 3.3.4. Matice vzorů obsahovala optimalizované průběhy objemů vody v nádrži a odtoky vody z nádrže. Předpovědi přítoků vody do nádrže byly nahrazeny příslušnými oddíly reálné průtokové řady.

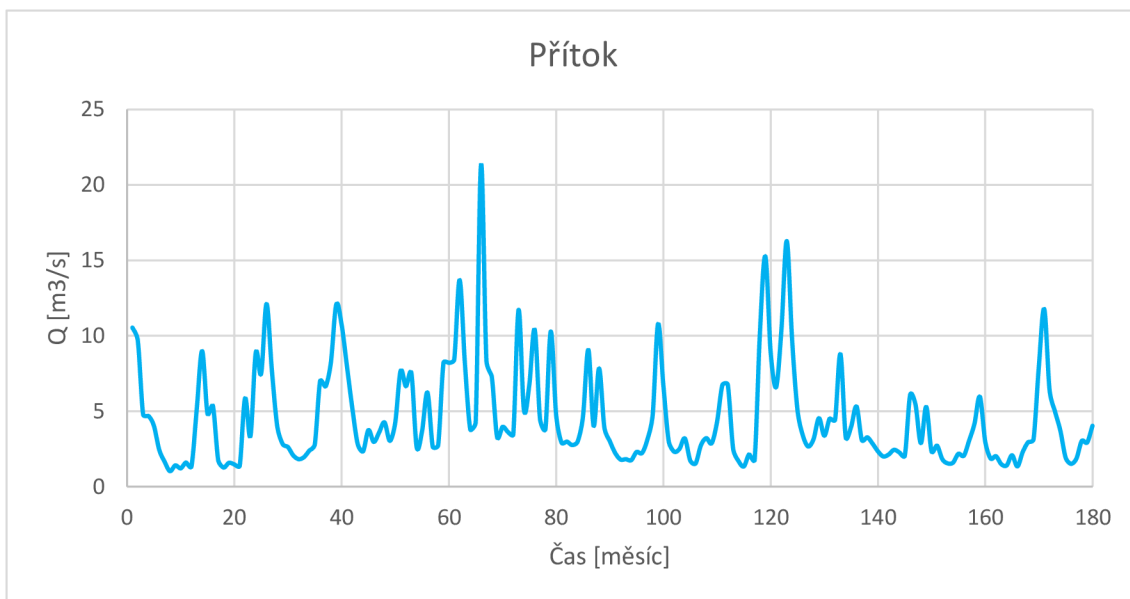
Kalibrační období byly zvoleny dvě a to v letech 1981 – 1995, v letech 1920 - 1990 a validační bylo 1996 – 2010. První kalibrační období bylo vybráno s ohledem na zvýšený výskyt malovodých období, které jsou problematické z pohledu řízení zásobní funkce nádrže. Pokud by se pro kalibraci modelů zvolila celá reálná řada (mimo období validace), modely by byly při kalibraci zahlceny vodnými roky, které nejsou problematické z pohledu zásobní funkce nádrže. V práci byly testovány dvě kalibrační období a to na 17 a 70 let. Někteří autoři zkoušeli pouze krátká kalibrační období, a proto jsem se rozhodl vyzkoušet i delší kalibrační období z důvodu testování delší tréninkové matice a její vliv na výsledky. Validací bylo zkráceno na délku 171 měsíců z důvodu snížení časové náročnosti výpočtů.

V rámci kalibrace se také hledalo vhodné nastavení neuronové sítě, které by přineslo nejlepší výsledky. Testovaly se tři typy nastavení neuronové sítě – dvouvrstvá, třívrstvá a čtyřvrstvá neuronová síť. Kalibrace spočívala v měnění počtu vrstev neuronové sítě a v počtu skrytých neuronů. Jako nejlepší varianta byla vyhodnocena třívrstvá neuronová síť, která je zobrazena na obrázku 21. Tato varianta se skládala z první skryté vrstvy, která obsahovala 15 skrytých neuronů. Druhá skrytá vrstva obsahovala 8 skrytých neuronů. Obě vrstvy měly jako transformační funkci sigmoidu. Poslední skrytá vrstva obsahovala počet zpětných měsíců, v našem případě 11 měsíců. Jako tréninková metoda byla zvolena metoda zpětného šíření (Zezulák, Starý, 2005).

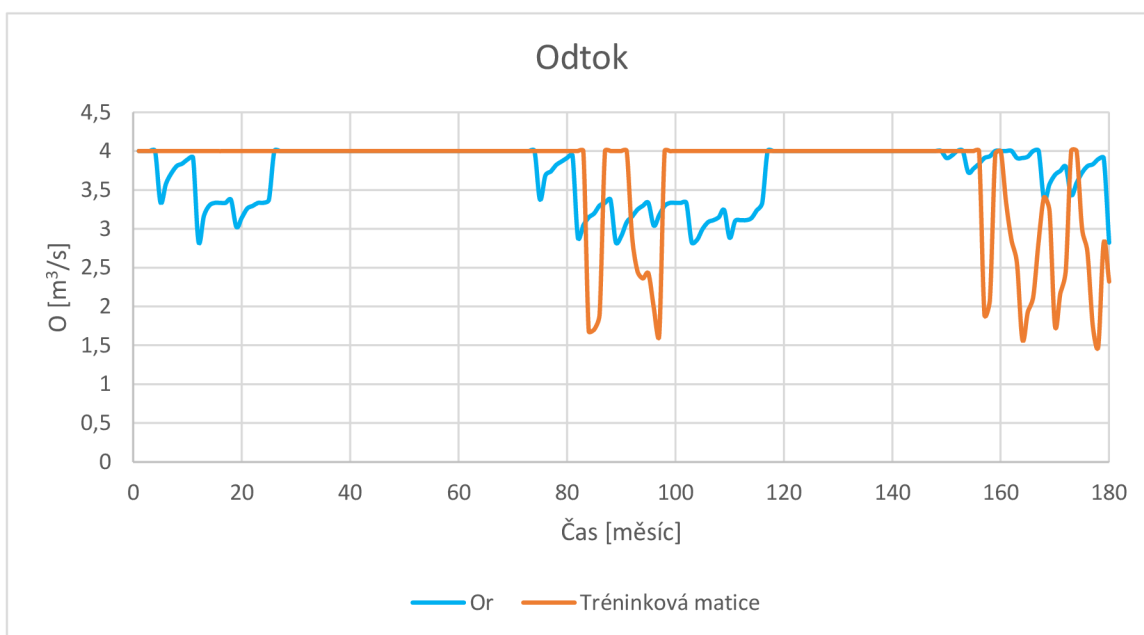


Obr. 21 - Třívrstvá neuronová síť.

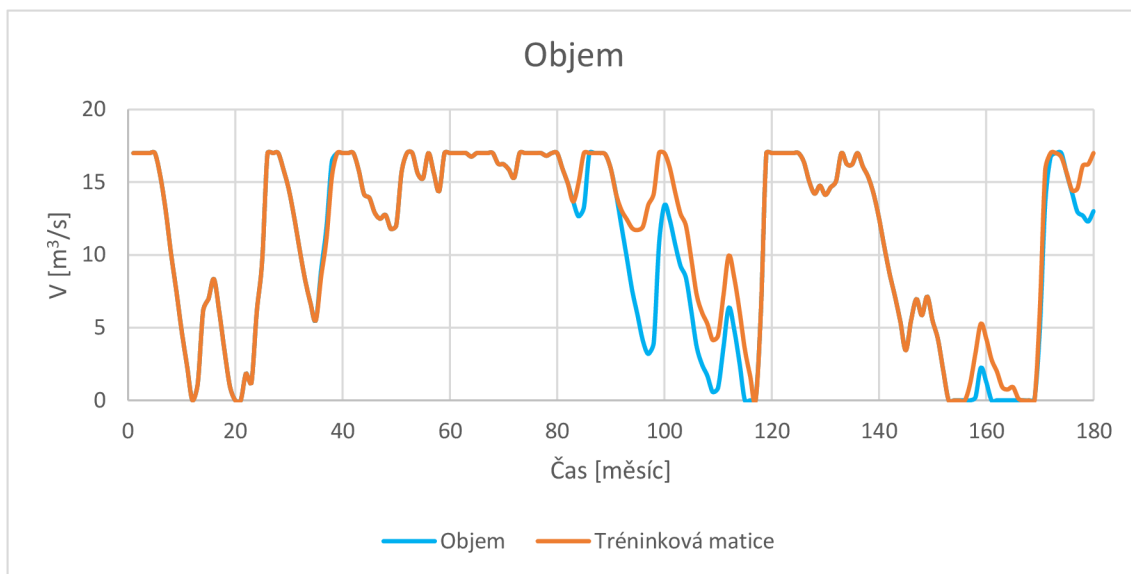
Řídící modul (NS) vycházející z metod umělé inteligence byl nejprve kalibrován a validován jako deterministický (při použití 100% předpovědi), aby se ověřila jeho schopnost řídit vodohospodářskou nádrž se zásobní funkcí. Na grafech 22, 23 a 24 je ukázán průběh řízení pro fiktivní nádrž. Všechny grafy mají na vodorovné ose čas v měsících. Na grafu 22 je vykreslen časový přítok vody do fiktivní nádrže. Graf 23 ukazuje řídicí odtok z nádrže a na posledním grafu 24 je zobrazen průběh objemů vody v nádrži. Matice vzorů obsahuje maximální hodnotu odtoků vody $4 \text{ m}^3/\text{s}$. Hodnoty vyšší než O_p byly uměle omezeny na hodnotu $4 \text{ m}^3/\text{s}$, i když jejich hodnota byla vyšší.



Obr. 22 - Průběh přítoku vody do nádrže.



Obr. 23 - Průběh odtoku z nádrže.



Obr. 24 - Průběh objemu vody v nádrži.

Průběh řízení poskytnuté neuronovou sítí ztratil podle očekávání určitou přesnost, avšak neztratil schopnost reagovat na změny vnějšího prostředí. Modul UI vykazuje tendenci držet vyšší hladinu zásobního objemu při delších obdobích sucha. Uvedená vlastnost by mohla být velmi přínosnou v podmínkách neurčitosti, které panují při používání předpovědí pro řízení.

7.3 KOREKCE

Korekce byla zavedena pro ustálení průběhu výsledného řízení a jako ochrana před náhlými poklesy přítoku vody do nádrže, které nemohou být podchyceny předpovědním modelem nebo jsou podchyceny jen pro velmi vysoké pravděpodobnosti řízených odtoků.

Pokud je opravný řízený odtok menší než původní, je počáteční objem pro i -tý krok zmenšen o rozdíl mezi řízeným odtokem a opravným řízeným odtokem. Když je opravný řízený odtok vyšší, počáteční objem vody pro i -tý se nemění. Tento postup je možno aplikovat i na další předchozí kroky řízení, avšak doba potřebná pro výpočet je přímo úměrná počtu opravných řízení.

Samotná neuronová síť není schopná extrapolace. V případě, že předpovídaný odtok O_p je větší či menší o 50% než odtok v předchozím kroku, řídicí algoritmus

bere hodnotu z předešlého kroku. Pokud vychází hodnoty odtoku nad výseč ($4 \text{ m}^3/\text{s}$), pak je hodnota přepsána na hodnotu $4 \text{ m}^3/\text{s}$.

7.4 VÝSLEDKY A VYHODNOCENÍ APLIKACE

Kapitola je rozčleněna do dvou hlavních částí. První část kapitoly je zaměřena na vyhodnocení kvality předpovědního modelu. Konec této části kapitoly je zaměřený na vyhodnocení řídicího modulu používaného pro předpovědi.

7.4.1 Vyhodnocení

Vyhodnocení úspěšnosti stochastických modelů bylo značně problematické, protože jednomu historicky naměřenému údaji může odpovídat i více než 1000 předpovězených hodnot. Rovněž musíme brát v úvahu, že předpovědní modely byly sestaveny pro stochastické řízení zásobní funkce nádrže. Nejedná se tedy o klasické předpovědní modely.

Řídicí modul testoval různé délky předpovědí, které mají velký vliv na výsledný průběh řízení, a proto byly modely testovány pro všechny délky předpovědi (1 až 11). Řídicí modul také testoval různou délku kalibračního období a průběh řízení při použití předpovědi s různým počtem měsíců zpětně. V našem případě bylo zvoleno kalibrační období 17 a 70 let.

7.4.2 Výsledky

Obecně se ukázalo, že předpovědi kratší než 4 měsíce zpětně vykazovaly mnohem lepších výsledků, než u delších předpovědí. Nejlepších výsledků bylo dosaženo při použití délky předpovědi na sedm měsíců při použití jednoho měsíce zpětně a nastavení modelu u obou kalibračních období. Použitím více měsíců zpětně při kalibraci modelu se zhoršovalo výsledné řízení odtoku. Nejhorších výsledků dosáhl předpovědní model při použití délky předpovědi na osm měsíců a použití sedmi měsíců zpětně u kalibračního období 17 let a při použití délky předpovědi na jeden měsíc při použití sedmi měsíců zpětně u kalibračního období 70 let. Tabulka se skládá z délky předpovědi (1 až 11 měsíců) a z pravděpodobnosti řízení. Pravděpodobnost řízení představuje kvantil, pro který jsou odečítány hodnoty z čáry

překročení dle Čegodajeva viz kapitola 5.2. Veškeré výsledky byly porovnávány s řízením na nalepšený odtok. V tabulkách 2 a 3 jsou ukázány nejlepší výsledky a v tabulkách 4 a 5 jsou uvedeny nejhorší výsledky pro řízení zásobní funkce nádrže. Nejlepších výsledků dosahoval kvantil 95%, naopak nejhorších kvantil 65%. Nekvalitní výsledky jsou v tabulce značeny červenou barvou. Kvalitní výsledky jsou značeny barvou zelenou.

Tab. 2 - Kalibračního období 17 let - 1 měsíc zpětně

		Pro délku předpovědi byl použit 1 měsíc zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	28,51787	23,44626	20,37135	19,27529	18,37683	19,0928	19,22909
	2.	15,88968	16,36625	17,3022	17,89377	19,36326	21,30235	21,12859
	3.	16,76217	16,38518	16,29084	17,07065	17,99989	18,58076	18,90026
	4.	26,09622	23,93186	23,12892	22,81695	22,33286	21,14057	20,04171
	5.	20,72415	17,1254	16,3992	15,66219	14,37679	14,13138	12,74566
	6.	34,46018	34,39377	33,68675	32,022	31,39007	30,29781	29,18251
	7.	21,85449	18,72679	16,09683	13,45933	11,88809	11,0486	10,10588
	8.	27,80546	27,33314	26,53845	25,97689	25,0502	24,51639	23,49501
	9.	21,02397	18,45953	15,64758	14,92135	15,46888	14,63697	13,94286
	10.	22,55249	20,15128	18,49247	15,83739	15,38846	14,32518	13,95689
	11.	22,42429	18,81156	13,90872	11,7501	11,16608	10,96854	10,53521

Tab. 3 - Kalibrační období 70 let - 1 měsíc zpětně

		Pro délku předpovědi byl použit 1 měsíc zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	27,94453	26,77572	25,79506	25,16059	24,62211	24,12343	23,6529
	2.	21,52741	21,82512	21,79247	22,38038	22,56592	21,63764	20,85378
	3.	25,63895	25,45385	23,03296	23,75828	25,46927	21,5403	21,4751
	4.	20,64881	20,06294	18,9833	18,13195	17,69448	17,38365	16,31659
	5.	20,7627	20,76238	21,28027	21,27048	19,21983	17,65413	19,03319
	6.	15,36976	13,94622	13,23347	12,03244	12,21775	13,00077	13,4143
	7.	15,23343	13,86023	12,79856	12,41484	12,03103	11,40323	11,06662
	8.	13,97962	12,33537	11,60176	11,21802	10,80498	10,87066	11,4089
	9.	16,21422	14,74765	15,6882	12,56284	12,25976	12,36544	11,55837
	10.	18,65669	17,23333	15,73377	13,59679	14,02091	14,90119	13,34357
	11.	16,233	13,63405	12,02334	11,26471	11,38993	11,69465	11,16698

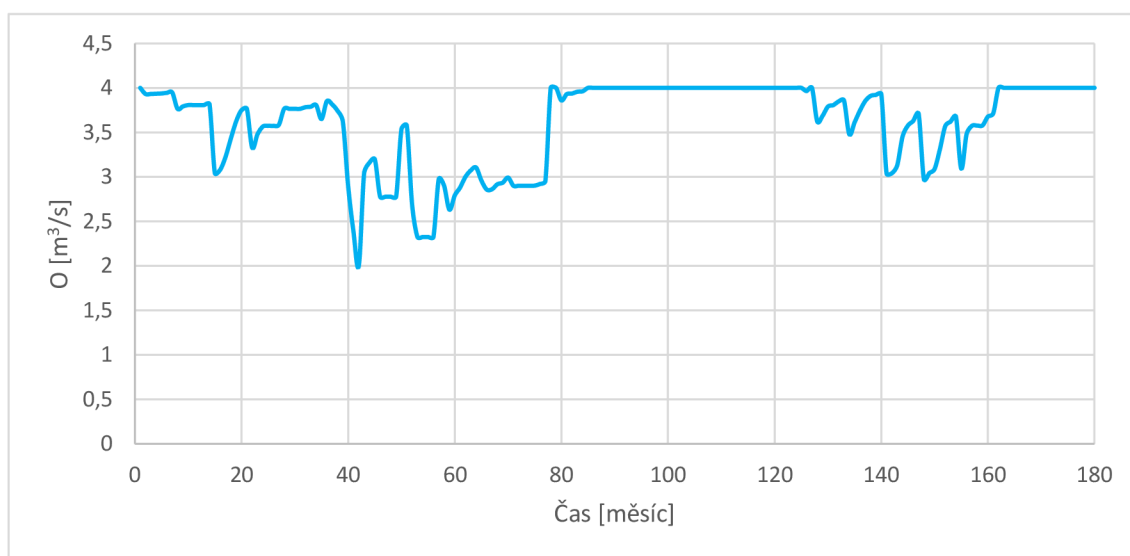
Tab. 4 - Kalibrační období 17 let - 7 měsíců zpětně

		Pro délku předpovědi bylo použito 7 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	68,12021	51,47881	41,36041	33,67985	27,2499	23,32003	21,03946
	2.	50,84365	44,8543	41,08439	37,89705	34,22563	31,05518	28,62332
	3.	53,41494	43,70107	36,32431	31,72191	27,89318	24,50068	22,00849
	4.	52,14306	42,71471	35,58855	30,46569	25,64762	22,29539	19,39562
	5.	27,67835	21,06202	17,22019	15,79883	16,28078	15,24776	15,34407
	6.	106,4656	99,04743	92,75971	87,78284	79,8637	77,11176	72,73067
	7.	26,84921	20,92394	19,44025	18,19963	17,20259	17,6259	18,00122
	8.	144,2716	133,9389	120,9147	111,617	99,92952	91,55396	86,61501
	9.	32,34584	28,25748	25,08788	22,33944	20,43648	18,61809	16,97118
	10.	34,20751	30,46422	28,15091	27,72633	26,06421	25,17598	24,42145
	11.	36,92283	31,48507	26,22524	22,89548	20,29699	18,13114	16,08696


Tab. 5 - Kalibrační období 70 let – 7 měsíců zpětně

		Pro délku předpovědi bylo použito 7 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	34,51164	30,35009	27,86577	27,63813	27,06064	26,72895	25,87959
	2.	25,00507	25,48148	25,3524	25,13656	25,03038	24,85052	24,21144
	3.	28,71281	28,09173	27,38392	26,87571	26,37846	25,82577	25,26691
	4.	22,6299	24,38757	24,43292	24,51719	24,32555	24,3021	23,89454
	5.	21,51178	22,74219	23,16944	23,38799	23,00767	22,80799	22,56807
	6.	20,49833	20,65215	23,11848	23,5571	24,38466	24,68249	24,40351
	7.	15,91664	16,50803	17,76104	19,77219	20,09115	20,28687	20,56684
	8.	24,4073	24,52329	24,17872	23,94444	23,79665	23,40006	22,8918
	9.	20,52621	21,98427	21,9424	21,80158	21,74428	21,49384	21,10218
	10.	14,88405	14,84225	15,57235	15,77587	16,40363	17,37792	17,33829
	11.	17,49887	18,28435	19,38193	19,99578	20,68454	21,09203	21,05009

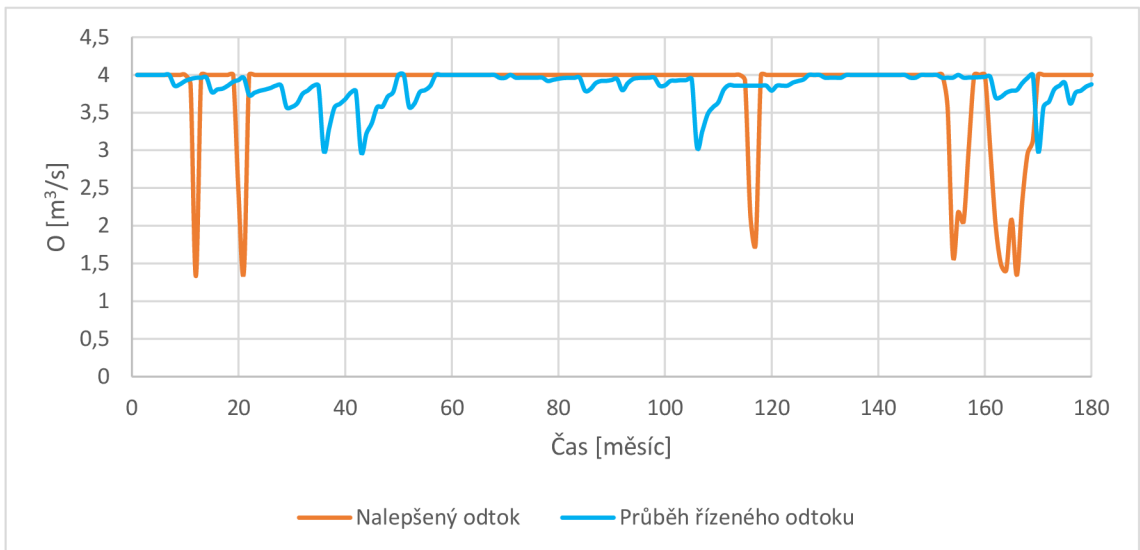
Na obrázcích 25 a 26 jsou ukázány kvalitní výsledky průběhu řízeného odtoku, tedy pro délku předpovědi 7 a 8 měsíců pro předpověď 1 měsíc zpětně. Na obrázku 27 je srovnání nalepšeného odtoku s nejlepším výsledkem průběhu řízeného odtoku.



Obr. 25 - Průběh řízeného odtoku pro předpověď 1 měsíce zpětně a délku předpovědi 7 měsíců



Obr. 27 - Průběh řízeného odtoku pro předpověď 1 měsíce zpětně a délku předpovědi 8 měsíců



Obr. 26 - Srovnání průběhu řízeného odtoku s řízením na nalepšený odtok

8 ZÁVĚR

Cílem práce bylo ověření možnosti využití metod umělé inteligence pro řízení zásobního prostoru fiktivní nádrže na měrném profilu Bílovice nad Svitavou. Použití neuronové sítě jako nahrazení optimalizačního modulu a sestavení příslušného řídicího algoritmu pro jeho použití v praxi. Dosažené výsledky jsou uvedeny v kapitolách 7.4, kde bylo provedeno jejich shrnutí.

Pro řídicí modul byla zvolena jako nejlepší varianta třívrstvá neuronová síť (viz kapitola 7.2).

Z vyhodnocení vyplývá, že středně dlouhá doba předpovědi (7 měsíců) v kombinaci s řídicím modulem dosahovala nejlepší výsledky. Dobré výsledky jsou zapříčiněny včasným škrcením odtoků vody z nádrže. Oproti tomu kratší a delší doba předpovědi dosahovaly horších výsledků. U kratší předpovědi se dá předpokládat, že řídicí algoritmus neměl dostatek času na včasné omezení odtoků z nádrže a následně řídil příliš agresivně. Při delší předpovědi docházelo k horším výsledkům z důvodu nepřesnosti předpovědi. Obecně s délkou předpovědi klesá přesnost.

Výhodou stochastického řízení je, že v každém kroku řízení nám poskytuje vějíř možností řízených odtoků. Další výhodou je, že pravděpodobnosti se dají kombinovat. Nejlepších výsledků pravděpodobnosti řízení dosahoval kvantil 95%. Naopak u menších kvantilů (65%) vycházely špatné výsledky, protože řídicí algoritmus předpokládal větší přítok vody u málovodných měsíců, a proto umožňoval větší odtok z nádrže.

V rámci práce byly zkoušeny dvě různě dlouhé tréninkové období (17 a 70 let), přičemž v obou možnostech vycházely podobné výsledky a proto v tomto případě nezáleží na délce tréninkového období. Z uvedeného textu je zřejmé, že použití stochastického řízení nádrže má smysl. Uvedený cíl diplomové práce je možno považovat za splněný.

Stochastické řízení zásobní funkce nádrže má v budoucnosti velký potenciál a bylo by dobré s ní zabývat.

9 POUŽITÁ LITERATURA

- [1] BÉM, Jiří a Ivana BÉMOVÁ. *Základy hydrauliky a hydrologie*. Praha: SNTL, 1963. Učební texty vysokých škol.
- [2] HANOUSEK, Jan a Pavel CHARAMZA. *Moderní metody zpracování dat: matematická statistika pro každého*. Praha: Grada, 1992. Educa '99. ISBN 80-85623-31-5.
- [3] KOZEL, Tomáš. *Stochastické řízení zásobní funkce nádrže pomocí metod umělé inteligence*. Brno, 2017. Disertační práce. Vysoké učení technické v Brně. Vedoucí práce Prof. Ing. MILOŠ STARÝ, CSc
- [4] NACHÁZEL, Karel, Miloš STARÝ a Jiří ZEZULÁK. *Využití metod umělé inteligence ve vodním hospodářství*. Praha: Academia, 2004, 318 s. : il. ISBN 80-200-0229-4.
- [5] NOVÁK, Mirko. *Umělé neuronové sítě: teorie a aplikace*. Praha: C.H. Beck, 1998. ISBN 80-7179-132-6.
- [6] MATLAB Programming Language. *Altius Directory* [online]. South Grafton, USA: Altius Directory, 2007 [cit. 2018-05-17]. Dostupné z: <http://www.altiusdirectory.com/Computers/matlab-programming-language.php>
- [7] STARÝ, Miloš. *Hydrologie*. Brno, 2005. Skripta. Vysoké učení technické v Brně.
- [8] STARÝ, Miloš. *Nádrže a vodohospodářské soustavy (MODUL 01)*. Brno: VUT, 2006
- [9] VOLNÁ, Eva. *Evoluční algoritmy a neuronové sítě*. Ostrava, 2012. Studijní opora. Ostravská univerzita v Ostravě.
- [10] VOTRUBA, L. a V. BROŽA. *Hospodaření s vodou v nádržích. 2 přeprac. vyd.* [online]. Praha: SNTL, 1980.
- [11] WEISSER, Roman. *Evoluční optimalizace řídicích algoritmů*. Brno, 2010. Dizertační práce. Vysoké učení technické v Brně.

10 SEZNAM POUŽITÝCH OBRÁZKŮ

Obr. 1 – Schéma nádrže.....	6
Obr. 2 - Schéma řídicího algoritmu.	8
Obr. 3 - Princip mřížkové metody při hledání jednoho regresního koeficientu, např. v rovnici $Y = aX$. [Starý, 2005]	9
Obr. 4 - Princip mřížkové metody při hledání dvou regresních koeficientů na různých rozlišovacích úrovních, např. v rovnici $Y = a_0 + a_1X$. [Starý, 2005]	9
Obr. 5 - Užití metody Monte Carlo. [Starý, 2005].....	10
Obr. 6 – Hustota pravděpodobnosti „bílého šumu“. [Starý, 2005].....	10
Obr. 7 - Výběr rodičů. [Volná, 2012]	12
Obr. 8 - Křížení chromozomů. [Volná, 2012].....	13
Obr. 9 - Vývojový diagram diferenciální evoluce. [Weisser, 2010].....	14
Obr. 10 - Biologický neuron. [Nacházel, Starý, Zezulák, 2004].....	19
Obr. 11 - Umělý neuron. [Nacházel, Starý, Zezulák, 2004]	19
Obr. 12 - Umělá neuronová síť. [Nacházel, Starý, Zezulák, 2004].....	20
Obr. 13 - Schéma Modifikovaného zonálního modelu. [Kozel, 2017].....	28
Obr. 14 – Srovnání distribuční funkce pro vybraný měsíc.....	31
Obr. 15 - Základní typy dispečerských grafů. [Starý, 2006]	32
Obr. 16 - Hustota pravděpodobnosti obecného normálního rozdělení. [Hanousek, Charamza, 1992].....	33
Obr. 17 - Hustota pravděpodobnosti normovaného normálního rozdělení. [Hanousek, Charamza, 1992].....	34
Obr. 18 - Ukázka empirické čáry překročení. [Bém, Bémová, 1963].....	35
Obr. 19 – Měrná stanice Bílovice nad Svitavou.	37
Obr. 20 – Reálná průtoková řada na měrné stanici Bílovice nad Svitavou.	38
Obr. 21 - Třívrstvá neuronová síť.....	40
Obr. 22 - Průběh přítoku vody do nádrže.	41
Obr. 23 - Průběh odtoku z nádrže.....	41
Obr. 24 - Průběh objemu vody v nádrži.	42
Obr. 25 - Průběh řízeného odtoku pro předpověď 1 měsíce zpětně a délku předpovědi 7 měsíců.....	46

Obr. 26 - Průběh řízeného odtoku pro předpověď 1 měsíce zpětně a délku předpovědi 8 měsíců.....	47
Obr. 27 - Srovnání průběhu řízeného odtoku s nalepšeným odtokem.....	47

11 SEZNAM POUŽITÝCH TABULEK

Tab. 1 - Schéma tréninkové matice [Nacházel, Starý, Zezulák, 2004]	21
Tab. 2 - Kalibračního období 17 let – 1 měsíc zpětně	44
Tab. 3 - Kalibrační období 70 let – 1 měsíc zpětně.....	45
Tab. 4 - Kalibrační období 17 let – 7 měsíců zpětně	45
Tab. 5 - Kalibrační období 70 let – 7 měsíců zpětně	46
Tab. 6 - Kalibrační období 17 let – 1 měsíc zpětně.....	54
Tab. 7 - Kalibrační období 17 let – 2 měsíce zpětně.....	54
Tab. 8 - Kalibrační období 17 let – 3 měsíce zpětně.....	55
Tab. 9 - Kalibrační období 17 let – 4 měsíce zpětně.....	55
Tab. 10 - Kalibrační období 17 let – 5 měsíců zpětně	56
Tab. 11 - Kalibrační období 17 let – 6 měsíců zpětně	56
Tab. 12 - Kalibrační období 17 let – 7 měsíců zpětně	57
Tab. 13 - Kalibrační období 17 let – 8 měsíců zpětně	57
Tab. 14 - Kalibrační období 17 let – 9 měsíců zpětně	58
Tab. 15 - Kalibrační období 17 let – 10 měsíců zpětně.....	58
Tab. 16 - Kalibrační období 17 let – 11 měsíců zpětně.....	59
Tab. 17 - Kalibrační období 17 let – 11 měsíců zpětně.....	59
Tab. 18 - Kalibrační období 70 let – 2 měsíce zpětně	60
Tab. 19 - Kalibrační období 70 let – 3 měsíce zpětně	60
Tab. 20 - Kalibrační období 70 let – 4 měsíce zpětně	61
Tab. 21 - Kalibrační období 70 let – 5 měsíců zpětně	61
Tab. 22 - Kalibrační období 70 let – 6 měsíců zpětně	62
Tab. 23 - Kalibrační období 70 let – 7 měsíců zpětně	62
Tab. 24 - Kalibrační období 70 let – 8 měsíců zpětně	63
Tab. 25 - Kalibrační období 70 let – 9 měsíců zpětně	63
Tab. 26 - Kalibrační období 70 let – 10 měsíců zpětně.....	64
Tab. 27 - Kalibrační období 70 let – 11 měsíců zpětně.....	64

12 SEZNAM ZKRATEK A SYMBOLŮ

NS...	Neuronová síť
EA...	Evoluční algoritmus
$Q_a...$	Dlouhodobý průměrný průtok
$O_p...$	Řídící odtok vody z nádrže
$S_{i,j}...$	Směrodatná odchylka
$N(0,1)...$	Normální normované rozdělení
Z...	Průměrný měsíční průtok transformovaný na normované normální rozdělení
$Y_{i,j}...$	Transformovaný průměrný měsíční průtok na rozdělení bez asymetrie
$Q_{i,j}...$	Průměrný měsíční průtok
$Z_{i,j}...$	Předpovězený průměrný měsíční průtok
Y ...	Průměrný měsíční průtok z rozdělení zbaveného asymetrie
r ...	Koeficient transformace na rozdělení bez asymetrie
m ...	Pořadové číslo prvku
Or...	Řízený odtok
$V^{\tau-1}...$	Objem vody v nádrži na počátku příslušného časového kroku
$\tau...$	Pořadí daného měsíce
DNA...	Deoxyribonukleová kyselina
$V^0...$	Počáteční objem vody v nádrži
N...	Množina vrcholů
$X_i...$	Vstupní veličiny tréninkové matice
<i>Sgn</i> ...	Funkce signum
COA...	Metoda těžiště ploch
BOA...	Metoda středu ploch
j...	Pořadí měsíce
i...	Číslo předpovědi

13 PŘÍLOHY

Tab. 6 - Kalibrační období 17 let – 1 měsíc zpětně

		Pro délku předpovědi byl použit 1 měsíc zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	28,51787	23,44626	20,37135	19,27529	18,37683	19,0928	19,22909
	2.	15,88968	16,36625	17,3022	17,89377	19,36326	21,30235	21,12859
	3.	16,76217	16,38518	16,29084	17,07065	17,99989	18,58076	18,90026
	4.	26,09622	23,93186	23,12892	22,81695	22,33286	21,14057	20,04171
	5.	20,72415	17,1254	16,3992	15,66219	14,37679	14,13138	12,74566
	6.	34,46018	34,39377	33,68675	32,022	31,39007	30,29781	29,18251
	7.	21,85449	18,72679	16,09683	13,45933	11,88809	11,0486	10,10588
	8.	27,80546	27,33314	26,53845	25,97689	25,0502	24,51639	23,49501
	9.	21,02397	18,45953	15,64758	14,92135	15,46888	14,63697	13,94286
	10.	22,55249	20,15128	18,49247	15,83739	15,38846	14,32518	13,95689
	11.	22,42429	18,81156	13,90872	11,7501	11,16608	10,96854	10,53521

Tab. 7 - Kalibrační období 17 let – 2 měsíce zpětně

		Pro délku předpovědi byly použity 2 měsíce zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	18,80925	21,0641	22,17809	23,29527	24,25282	24,27306	24,23915
	2.	16,74769	17,60687	18,40656	20,01976	20,02139	20,83058	20,8434
	3.	21,31997	18,32378	17,6526	16,66654	15,88296	15,36013	15,05891
	4.	19,21398	18,5242	19,60788	19,36016	17,35473	16,35524	17,37291
	5.	29,86055	24,15339	19,30076	16,46153	14,94613	12,8132	12,03166
	6.	24,17619	20,03082	17,63909	15,14529	13,645	12,35664	11,37448
	7.	42,34742	38,75996	37,02206	36,55875	35,85767	35,36049	35,32691
	8.	33,54094	31,51553	30,39751	29,16692	26,84749	26,23833	25,73974
	9.	20,02073	17,51345	15,6893	14,64883	13,4841	12,52631	12,02612
	10.	36,90702	33,7768	31,16951	29,43873	27,38493	25,51519	24,42052
	11.	30,50506	20,25054	15,39337	14,19299	14,40589	13,79632	13,30375

Tab. 8 - Kalibrační období 17 let – 3 měsíce zpětně

		Pro délku předpovědi byly použity 3 měsíce zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	16,54381	16,46008	16,54097	16,67513	16,82123	17,00235	17,18611
	2.	88,21651	79,10205	67,60454	59,77634	54,02702	49,48383	43,73518
	3.	45,44927	37,9237	31,06683	26,76562	23,09074	19,97808	18,58591
	4.	56,42464	54,17645	51,87677	49,20539	46,0883	44,81442	43,25985
	5.	61,01071	57,57278	52,18259	45,54197	40,47675	37,60923	34,17572
	6.	22,76072	20,64179	19,31139	18,21509	17,49804	17,27222	16,83223
	7.	32,05085	26,94803	24,08729	21,52513	19,54002	18,61979	17,74186
	8.	24,73004	21,44572	17,72461	14,34583	13,01722	11,88381	13,06491
	9.	23,42041	19,70024	17,4223	14,93393	12,88692	11,35348	10,58171
	10.	33,10385	29,93684	27,37936	25,46597	23,03422	21,18977	19,78328
	11.	43,68676	39,12853	35,26625	29,15788	23,73308	18,84008	15,1093

Tab. 9 - Kalibrační období 17 let – 4 měsíce zpětně

		Pro délku předpovědi byly použity 4 měsíce zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	23,57527	21,54096	21,74085	20,65918	20,20723	20,58946	20,06334
	2.	51,3536	44,97381	39,60851	35,35754	32,15203	29,5985	27,55522
	3.	44,57664	35,29601	30,13722	25,32644	22,92872	21,03438	20,18711
	4.	44,81823	34,29484	27,05283	22,70649	21,20231	19,77583	19,05089
	5.	28,4131	28,20918	27,67182	26,9018	24,91642	23,34066	21,84292
	6.	46,64203	36,69171	29,98199	25,16532	22,29729	19,70531	17,71911
	7.	36,32479	34,65652	33,23177	31,11413	27,90668	24,30615	20,65553
	8.	18,63477	16,20115	14,94446	13,94958	13,32692	13,59388	14,16526
	9.	39,79734	38,51298	36,83815	35,48119	34,36193	32,86524	31,43029
	10.	45,44521	37,12917	31,69969	27,94426	23,88614	20,50764	17,66011
	11.	20,06569	18,32373	17,0217	16,02689	15,14132	14,56301	14,14999

Tab. 10 - Kalibrační období 17 let - 5 měsíců zpětně

		Pro délku předpovědi bylo použito 5 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	39,45877	31,63474	25,1705	22,24834	19,16484	15,82958	14,24183
	2.	37,06792	33,13618	30,199	29,76393	28,43823	24,9476	23,53087
	3.	35,15321	25,48551	19,39924	15,32827	14,20813	14,50953	14,31951
	4.	41,2991	33,39433	29,92683	27,59661	25,03994	24,17775	22,46947
	5.	28,19521	24,14683	21,69926	19,71301	18,18577	16,82641	15,93495
	6.	21,05195	17,98011	16,78406	15,70264	15,72141	15,76179	16,49353
	7.	25,48553	25,28842	24,7028	24,23203	23,85446	24,21915	23,73701
	8.	24,20713	20,90131	18,67325	16,75366	15,03797	13,79705	12,93216
	9.	31,12496	25,99614	21,47615	18,17222	16,08996	14,71824	15,14291
	10.	42,17534	39,48209	36,52159	32,90407	30,17406	26,72991	23,33654
	11.	20,8785	19,70881	18,91275	17,81092	17,00826	16,27992	15,82754

Tab. 11 - Kalibrační období 17 let - 6 měsíců zpětně

		Pro délku předpovědi bylo použito 6 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	76,09857	70,04946	63,64607	57,82439	53,70103	50,56167	46,00074
	2.	39,04184	33,1962	29,44001	25,44417	23,24965	20,90533	19,10042
	3.	59,00493	55,91365	52,26227	45,98126	39,89089	34,9875	30,77893
	4.	42,52528	35,35691	31,9836	27,72944	24,43102	21,85536	19,43445
	5.	34,80076	27,64372	23,51007	20,48602	18,68643	16,92857	15,60154
	6.	30,0652	23,30198	20,74004	17,35188	15,83487	15,08241	13,5452
	7.	34,6659	29,58115	25,67685	22,48048	19,52735	17,06987	15,35899
	8.	70,24573	56,1496	50,18076	44,70235	39,93222	34,68038	32,01423
	9.	33,3163	27,5568	23,42939	20,7692	18,9319	17,81221	18,16209
	10.	43,327	40,7553	37,18359	33,55834	31,44559	29,33955	27,83388
	11.	18,75876	16,1491	15,19019	14,91843	15,26011	15,27228	15,46715

Tab. 12 - Kalibrační období 17 let – 7 měsíců zpětně

		Pro délku předpovědi bylo použito 7 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	68,12021	51,47881	41,36041	33,67985	27,2499	23,32003	21,03946
	2.	50,84365	44,8543	41,08439	37,89705	34,22563	31,05518	28,62332
	3.	53,41494	43,70107	36,32431	31,72191	27,89318	24,50068	22,00849
	4.	52,14306	42,71471	35,58855	30,46569	25,64762	22,29539	19,39562
	5.	27,67835	21,06202	17,22019	15,79883	16,28078	15,24776	15,34407
	6.	106,4656	99,04743	92,75971	87,78284	79,8637	77,11176	72,73067
	7.	26,84921	20,92394	19,44025	18,19963	17,20259	17,6259	18,00122
	8.	144,2716	133,9389	120,9147	111,617	99,92952	91,55396	86,61501
	9.	32,34584	28,25748	25,08788	22,33944	20,43648	18,61809	16,97118
	10.	34,20751	30,46422	28,15091	27,72633	26,06421	25,17598	24,42145
	11.	36,92283	31,48507	26,22524	22,89548	20,29699	18,13114	16,08696

Tab. 13 - Kalibrační období 17 let – 8 měsíců zpětně

		Pro délku předpovědi bylo použito 8 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	43,17176	29,73097	27,03142	24,25895	24,27449	23,81767	24,27092
	2.	49,56059	41,73604	35,5146	30,59711	27,95614	25,01666	23,10141
	3.	48,4778	39,54501	35,32323	30,2699	25,89484	23,35616	20,69595
	4.	76,80992	77,5349	76,8601	74,08534	70,4774	67,44998	63,79564
	5.	39,42355	31,28126	26,65092	23,04045	20,7505	18,707	17,77179
	6.	47,30455	36,67789	32,09678	26,95181	23,44199	21,1118	18,99732
	7.	29,98601	25,49509	23,28591	20,82145	18,35985	16,33819	15,06343
	8.	36,41754	31,57315	28,17621	26,20527	24,63529	23,32666	21,66868
	9.	23,61935	18,6817	15,49297	13,52269	12,42784	11,73868	11,48166
	10.	43,01918	37,65705	34,8182	32,2453	31,00509	29,10475	28,55443
	11.	25,82907	19,0734	16,69171	14,94715	13,38759	12,10294	11,38564

Tab. 14 - Kalibrační období 17 let - 9 měsíců zpětně

		Pro délku předpovědi bylo použito 9 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	63,67548	51,16105	41,32358	35,59157	30,71923	27,01609	24,9831
	2.	39,60056	31,24354	25,65111	22,49203	20,75751	20,28915	19,47925
	3.	40,88891	34,40633	30,35427	26,43832	23,677	21,04998	18,93773
	4.	44,2022	36,09235	31,31788	27,82585	24,82457	22,55147	20,62415
	5.	32,83534	28,59913	25,30926	23,54254	21,28339	19,35701	17,73783
	6.	41,93796	33,0492	27,47734	23,9598	21,15001	19,13205	17,38537
	7.	33,65876	25,27134	20,26963	17,62707	15,47327	14,48226	14,03869
	8.	35,5823	28,05558	24,61679	20,38719	17,71176	15,82653	14,40357
	9.	19,82591	17,35524	15,65005	14,43451	13,66156	13,07015	12,67161
	10.	31,19099	26,36204	22,48133	19,92259	18,40782	16,47778	15,28534
	11.	51,92533	43,78951	36,08854	30,31117	26,00035	22,53719	20,21727

Tab. 15 - Kalibrační období 17 let - 10 měsíců zpětně

		Pro délku předpovědi bylo použito 10 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	53,19803	43,90702	37,71505	32,69654	28,2034	24,89387	21,83694
	2.	61,30287	55,57549	51,65767	49,42362	46,76885	45,29245	43,34672
	3.	34,97291	27,88709	24,73333	21,75753	20,57977	19,70506	19,70107
	4.	55,18982	45,03333	36,92227	30,81284	27,42459	23,89448	21,23769
	5.	33,38135	27,37752	24,41391	21,01121	18,24109	16,71748	15,6645
	6.	38,07122	29,63904	25,23744	21,72578	18,98738	16,33412	14,84313
	7.	27,65628	22,08778	18,84678	16,46187	14,7839	13,47783	13,04816
	8.	25,29243	19,89925	17,65388	16,39771	15,91478	15,98262	15,97053
	9.	29,35595	23,45421	20,1151	17,52105	15,53804	14,11407	12,83771
	10.	27,60022	25,59304	23,87552	22,43984	21,16181	20,02533	19,09648
	11.	45,00652	37,15795	31,56733	27,08352	24,25405	21,33495	18,80877

Tab. 16 - Kalibrační období 17 let – 11 měsíců zpětně

		Pro délku předpovědi bylo použito 11 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	59,78222	51,2916	44,00961	38,1942	33,89362	29,6181	26,78835
	2.	45,11546	40,81734	37,02297	33,66868	30,92578	28,56675	25,82505
	3.	44,71255	33,60956	27,40408	23,93102	20,9991	18,70936	16,84294
	4.	44,14095	34,78799	28,58377	24,60842	21,57818	18,87545	17,61533
	5.	21,47214	17,37567	15,00017	13,59921	13,18694	13,42505	13,41386
	6.	31,54862	23,489	19,0175	16,69385	15,88977	16,29154	15,68291
	7.	33,86046	27,53702	22,82285	19,18136	16,9274	15,22539	13,91236
	8.	29,96873	24,91965	21,86428	19,41436	17,52153	16,21548	15,00681
	9.	28,2094	25,7818	23,07232	20,43564	18,46031	16,80891	15,19664
	10.	29,14803	25,11736	22,87313	20,21083	18,15808	16,27807	15,19598
	11.	59,99746	51,52694	47,08413	42,04472	38,39178	35,09654	32,20972

Tab. 17 - Kalibrační období 17 let – 11 měsíců zpětně

		Pro délku předpovědi byl použit 1 měsíc zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	27,94453	26,77572	25,79506	25,16059	24,62211	24,12343	23,6529
	2.	21,52741	21,82512	21,79247	22,38038	22,56592	21,63764	20,85378
	3.	25,63895	25,45385	23,03296	23,75828	25,46927	21,5403	21,4751
	4.	20,64881	20,06294	18,9833	18,13195	17,69448	17,38365	16,31659
	5.	20,7627	20,76238	21,28027	21,27048	19,21983	17,65413	19,03319
	6.	15,36976	13,94622	13,23347	12,03244	12,21775	13,00077	13,4143
	7.	15,23343	13,86023	12,79856	12,41484	12,03103	11,40323	11,06662
	8.	13,97962	12,33537	11,60176	11,21802	10,80498	10,87066	11,4089
	9.	16,21422	14,74765	15,6882	12,56284	12,25976	12,36544	11,55837
	10.	18,65669	17,23333	15,73377	13,59679	14,02091	14,90119	13,34357
	11.	16,233	13,63405	12,02334	11,26471	11,38993	11,69465	11,16698

Tab. 18 - Kalibrační období 70 let – 2 měsíce zpětně

		Pro délku předpovědi byly použity 2 měsíce zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	26,12801	25,64886	24,92827	24,52019	24,10381	23,62131	23,33789
	2.	23,75492	25,25335	26,73393	26,73916	26,92122	26,30323	25,83591
	3.	26,51181	26,71973	25,99796	25,06997	24,8143	24,41598	23,9986
	4.	26,6788	23,96877	24,83151	25,85127	25,69612	25,27708	24,65696
	5.	20,94946	20,91551	18,66903	18,86892	18,94741	20,33548	20,81537
	6.	23,01433	22,74414	21,62368	21,94413	22,65608	22,35241	22,12331
	7.	36,87818	29,67855	29,5109	22,58644	17,61313	18,87427	19,20256
	8.	20,06877	17,80711	16,25282	16,01546	15,65453	16,14941	16,47227
	9.	21,08049	20,50835	19,70895	19,96351	20,24158	20,77292	20,27017
	10.	22,56092	19,6837	17,88381	16,84239	15,86251	15,32033	15,80558
	11.	18,29297	17,26576	16,95345	16,97923	15,33368	15,05569	16,3606

Tab. 19 - Kalibrační období 70 let – 3 měsíce zpětně

		Pro délku předpovědi byly použity 3 měsíce zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	21,97162	27,01003	27,21136	26,97831	26,79796	26,67662	26,74012
	2.	24,12355	24,5325	24,96956	25,41012	25,09753	24,66397	24,34626
	3.	23,93976	24,73842	24,86853	24,62654	24,62486	24,42689	24,10444
	4.	23,97612	23,8631	24,14785	24,34604	24,54525	24,23311	23,64583
	5.	19,16704	21,27331	21,90855	22,12139	22,1595	22,3776	22,51797
	6.	19,13309	19,84919	22,06956	22,31544	22,4733	22,95972	22,804
	7.	17,96472	18,77918	20,92798	21,88729	21,95998	21,9364	21,7621
	8.	18,69852	16,96267	17,5366	18,58765	19,78916	20,20664	20,03193
	9.	19,81611	17,74018	17,18728	17,79415	19,09543	20,27861	21,18479
	10.	22,18454	21,97522	22,09452	22,38499	23,29376	23,03058	22,37548
	11.	26,0537	23,51237	21,46192	20,56188	19,03537	17,82088	18,67402

Tab. 20 - Kalibrační období 70 let - 4 měsíce zpětně

		Pro délku předpovědi byly použity 4 měsíce zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	26,13821	27,85524	27,1105	25,9433	25,01756	24,54381	24,24038
	2.	27,07933	26,53842	26,09399	25,7565	25,30735	24,73998	24,35426
	3.	21,77818	20,40885	21,9335	24,33818	24,40835	24,53378	23,88527
	4.	25,62096	25,68234	25,5921	25,18874	24,79756	24,53121	23,91068
	5.	18,29566	19,67687	22,15891	23,06864	23,94451	24,30041	24,26624
	6.	22,64533	22,30379	22,17396	21,97643	21,85614	21,52443	21,12938
	7.	18,60419	19,33369	20,92203	21,77115	21,70571	21,46704	20,92866
	8.	14,99906	15,91239	16,17365	16,53091	17,06102	17,52003	17,99086
	9.	18,02939	16,87214	15,67585	15,62999	16,09169	17,79512	18,54143
	10.	24,50831	23,43893	22,97967	23,13012	23,3146	23,33676	22,76993
	11.	17,4139	17,72113	17,19105	17,5286	18,55934	18,90011	18,99796

Tab. 21 - Kalibrační období 70 let - 5 měsíců zpětně

		Pro délku předpovědi bylo použito 5 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	19,49096	20,56827	21,7289	21,74905	22,09722	22,44998	22,39386
	2.	27,616	26,50076	26,36919	26,04147	25,89806	25,70641	25,28574
	3.	22,30964	23,48121	24,05416	24,24739	24,35129	24,37296	24,12394
	4.	23,6522	24,38089	24,86765	25,06638	25,05555	24,98604	24,51917
	5.	21,2413	18,69025	19,22168	21,88103	23,30295	23,24975	23,7233
	6.	21,78918	23,06818	23,64615	23,58145	23,9801	23,97992	23,44183
	7.	20,13801	21,596	22,78154	23,28943	23,25014	23,22546	22,87153
	8.	14,86362	15,36901	16,02495	17,86286	18,9038	19,30884	19,80809
	9.	17,75965	18,37073	18,43945	19,39631	19,57667	19,72825	19,66437
	10.	16,5126	16,56818	16,9165	17,69235	17,8618	18,19635	18,64612
	11.	14,17333	15,10327	15,96112	16,32395	17,18756	18,20319	18,85106

Tab. 22 - Kalibrační období 70 let - 6 měsíců zpětně

		Pro délku předpovědi bylo použito 6 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	25,01749	24,55389	24,51392	24,40043	24,44057	24,1123	23,90735
	2.	27,22174	26,99488	26,61716	26,14652	25,45121	24,88032	24,62718
	3.	24,81073	25,80033	25,51051	25,30703	25,13175	24,99159	24,55576
	4.	23,30519	23,95329	23,92503	24,89072	25,44679	24,95185	24,29815
	5.	16,29817	16,69975	17,62738	18,56766	19,12208	19,73702	20,2798
	6.	18,07861	19,12425	21,8308	22,70369	23,03627	23,23894	22,97755
	7.	15,87646	16,56378	18,44744	20,04916	20,67836	21,21792	21,13038
	8.	21,29175	22,39709	21,96041	21,61615	21,58187	21,45163	21,01858
	9.	18,41325	17,2867	16,85518	16,59569	16,51909	17,41827	19,01585
	10.	16,84211	17,86078	18,71383	20,11325	20,4355	20,6324	20,78186
	11.	15,25424	15,81902	16,06488	16,83127	18,27183	19,11132	19,70519

Tab. 23 - Kalibrační období 70 let - 7 měsíců zpětně

		Pro délku předpovědi bylo použito 7 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	34,51164	30,35009	27,86577	27,63813	27,06064	26,72895	25,87959
	2.	25,00507	25,48148	25,3524	25,13656	25,03038	24,85052	24,21144
	3.	28,71281	28,09173	27,38392	26,87571	26,37846	25,82577	25,26691
	4.	22,6299	24,38757	24,43292	24,51719	24,32555	24,3021	23,89454
	5.	21,51178	22,74219	23,16944	23,38799	23,00767	22,80799	22,56807
	6.	20,49833	20,65215	23,11848	23,5571	24,38466	24,68249	24,40351
	7.	15,91664	16,50803	17,76104	19,77219	20,09115	20,28687	20,56684
	8.	24,4073	24,52329	24,17872	23,94444	23,79665	23,40006	22,8918
	9.	20,52621	21,98427	21,9424	21,80158	21,74428	21,49384	21,10218
	10.	14,88405	14,84225	15,57235	15,77587	16,40363	17,37792	17,33829
	11.	17,49887	18,28435	19,38193	19,99578	20,68454	21,09203	21,05009

Tab. 24 - Kalibrační období 70 let – 8 měsíců zpětně

		Pro délku předpovědi bylo použito 8 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	27,19028	27,42924	26,84757	26,21161	25,64087	24,86123	24,33351
	2.	19,46131	20,17089	19,84634	20,84219	22,01017	23,03548	23,89727
	3.	28,63575	27,45996	26,72806	27,03564	26,54774	25,6657	24,74593
	4.	21,25324	23,13351	23,37989	23,41002	23,59264	23,67615	23,48114
	5.	25,93347	25,65209	25,36204	25,23423	25,06957	24,67888	24,22573
	6.	24,59352	25,05603	25,1345	25,11359	25,00189	24,52961	24,0108
	7.	21,47433	23,42166	23,52472	23,78152	23,95432	23,87269	23,36905
	8.	20,37531	19,71348	19,71176	20,67156	21,67285	22,01239	21,95686
	9.	20,27445	17,66873	17,16136	18,2817	19,77363	20,28188	20,8716
	10.	15,59339	15,69802	16,16247	17,49045	18,10583	18,39928	18,93503
	11.	17,8426	17,61045	17,76843	18,4957	19,6262	19,58722	19,77777

Tab. 25 - Kalibrační období 70 let – 9 měsíců zpětně

		Pro délku předpovědi bylo použito 9 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	29,04074	27,2063	26,15368	25,50694	25,2134	24,64169	24,60672
	2.	28,89756	28,12572	27,57619	27,14032	26,69641	26,1876	25,66693
	3.	24,63477	18,46995	16,89637	16,39498	16,20602	16,76676	16,93493
	4.	21,09376	22,27992	24,38211	24,94396	24,91017	24,45371	24,001
	5.	18,93927	21,7479	23,03214	23,33175	23,5835	23,58925	23,23477
	6.	19,78604	20,84633	21,34723	22,29022	22,43773	22,30474	21,99132
	7.	17,33107	19,06819	20,64315	21,96736	22,83389	22,85158	22,43583
	8.	17,67988	20,01403	22,28326	22,28874	22,3651	22,13274	21,79548
	9.	14,39143	15,46453	16,20354	17,49201	19,19657	20,54072	20,79836
	10.	13,94803	15,02674	15,9692	17,09829	17,31151	17,65732	18,11102
	11.	15,26071	15,112	15,50506	16,45828	17,08461	17,38312	17,7088

Tab. 26 - Kalibrační období 70 let – 10 měsíců zpětně

		Pro délku předpovědi bylo použito 10 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	23,78841	22,14972	22,46964	22,79932	22,76582	22,3626	22,42942
	2.	20,22409	22,94737	23,55375	23,97558	24,39978	24,20928	23,73848
	3.	25,01184	25,79068	24,91667	25,19578	25,36893	25,43595	24,90222
	4.	15,60362	16,32634	17,71067	19,92342	21,56574	21,97473	21,72705
	5.	17,44996	20,97232	22,59784	23,26603	23,58359	23,77472	23,50248
	6.	24,01866	24,60265	24,67322	24,5775	24,3987	23,83087	23,23603
	7.	21,9033	23,18707	23,5457	23,61393	23,7453	23,52604	22,93661
	8.	23,30437	23,70972	23,46395	23,42218	23,33384	22,86165	22,08167
	9.	14,76433	15,18031	15,63658	16,28889	17,93807	19,10518	19,90822
	10.	17,03694	17,48246	18,43541	19,51305	19,81702	20,31555	20,35927
	11.	12,5141	13,39206	13,71329	14,06054	14,57465	14,70019	14,62985

Tab. 27 - Kalibrační období 70 let – 11 měsíců zpětně

		Pro délku předpovědi bylo použito 11 měsíců zpětně						
		Pravděpodobnost řízení [%]						
		65	70	75	80	85	90	95
Délka předpovědi	1.	35,2297	34,7258	32,11305	29,63812	28,671	27,81232	26,40815
	2.	21,6562	21,79402	22,784	23,49969	24,26799	24,85353	24,76016
	3.	20,31612	18,42669	18,63661	18,43569	20,09663	21,50021	22,03039
	4.	19,05698	19,2216	21,60354	23,33322	24,10984	24,26452	24,09185
	5.	21,49566	23,80991	24,02515	24,32294	24,62562	24,48132	24,05625
	6.	23,58216	24,68372	24,51694	24,78679	24,19109	23,81088	23,27132
	7.	19,63509	20,77542	22,74576	23,04448	23,11064	23,02539	22,66656
	8.	32,12944	24,0026	18,78745	16,45734	16,74253	17,55803	18,11177
	9.	14,80771	14,48709	14,22506	13,98067	14,39053	15,42773	15,67797
	10.	15,72258	16,0923	17,16719	19,01124	19,33552	19,48769	19,57139
	11.	17,73524	16,91147	16,20079	16,27253	17,06434	17,05349	17,16468