



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STAVEBNÍ  
ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY  
FACULTY OF CIVIL ENGINEERING  
INSTITUTE OF LANDSCAPE WATER MANAGEMENT

## STOCHASTICKÉ ŘÍZENÍ ZÁSOBNÍ FUNKCE NÁDRŽE S POMOCÍ METOD UMĚLÉ INTELIGENCE

STOCHASTIC MANAGEMENT STORAGE FUNCTION OF WATER RESERVOIR USING METHOD OF  
ARTIFICIAL INTELLIGENCE

DISERTAČNÍ PRÁCE - ZKRÁCENÁ VERZE  
DISSERTATION THESIS - SHORT VERSION

AUTOR PRÁCE:  
AUTHOR:

Ing. TOMÁŠ KOZEL

ŠKOLITEL:  
SUPERVISOR:

Prof. Ing. MILOŠ STARÝ, CSc.

BRNO 2017

## KLÍČOVÁ SLOVA

### **Keywords:**

*Large open water reservoir, average monthly flow, stochastic forecasting, stochastic management fuzzy, evolution algorithm, neural networks, storage function.*

### **Klíčová slova:**

*Vodní nádrž, průměrný měsíční průtok, stochastická, předpověď, stochastické řízení, fuzzy, neuronová síť, evoluční algoritmy, zásobní funkce.*

Práce je uložena v knihovnickém informačním centru, Fakulta stavební, Vysoké učení technické v Brně, Veveří 331/95, Brno

# OBSAH

|       |                                                                       |    |
|-------|-----------------------------------------------------------------------|----|
| 1.    | ÚVOD .....                                                            | 5  |
| 2.    | SOUČASNÝ STAV POZNÁNÍ .....                                           | 6  |
| 2.1   | Vybrané příbuzné práce využívající metody umělé inteligence (UI)..... | 6  |
| 3.    | CÍLE DISERTAČNÍ PRÁCE .....                                           | 7  |
| 4.    | POUŽITÉ METODY .....                                                  | 7  |
| 4.1   | Zjednodušující předpoklady .....                                      | 8  |
| 4.2   | Chování nádrže .....                                                  | 8  |
| 4.3   | Předpovědní modely přítoku vody do nádrže.....                        | 8  |
| 4.3.1 | Transformace historických dat .....                                   | 9  |
| 4.3.2 | Autoregresní předpovědní modely .....                                 | 9  |
| 4.3.3 | Zonální model.....                                                    | 11 |
| 4.3.4 | Metoda Latin Hypercube Sampling (LHS).....                            | 13 |
| 4.4   | Optimalizační moduly.....                                             | 13 |
| 4.4.1 | EA modul.....                                                         | 14 |
| 4.4.2 | Učící se systémy .....                                                | 14 |
| 4.5   | Princip adaptivity .....                                              | 16 |
| 4.6   | Řídící algoritmus .....                                               | 16 |
| 4.7   | Dispečerské grafy.....                                                | 17 |
| 5.    | POUŽITÝ SOFTWARE .....                                                | 18 |
| 5.1   | Program Somvs .....                                                   | 18 |
| 5.2   | Paralelní výpočty v Clusteru .....                                    | 18 |
| 6.    | APLIKACE STOCHASTICKÉHO ŘÍZENÍ .....                                  | 19 |
| 6.1   | Historická data .....                                                 | 19 |
| 6.2   | Kalibrace a validace řídicích modulů .....                            | 19 |
| 6.3   | Korekce řízení .....                                                  | 20 |
| 6.4   | Vyhodnocení předpovědních modelů I. část .....                        | 21 |
| 6.5   | Vybrané výsledky aplikace .....                                       | 21 |
| 6.5.1 | Předpovědní modely .....                                              | 21 |
| 6.5.2 | Řídící modely .....                                                   | 23 |
| 7.    | SHRNUTÍ VÝSLEDKŮ .....                                                | 25 |
| 8.    | ZÁVĚR.....                                                            | 26 |
| 9.    | POUŽITÁ LITERATURA .....                                              | 28 |
| 10.   | ŽIVOTOPIS AUTORA.....                                                 | 30 |
| 11.   | ABSTRACT.....                                                         | 31 |



# 1. ÚVOD

V posledních letech byla v oblasti řízení provozu vodních nádrží řešena převážně problematika spojená s výskytem povodňových průtoků. To bylo dáno častým výskytem extrémním povodní. V určitých oblastech republiky se však začínají objevovat vleklé problémy s nedostatkem vody, které jsou způsobeny prodlužováním a prohlubováním se málovodých (suchých) období. Uvedená skutečnost se projevuje ve vzrůstající napjatosti mezi kapacitou vodních zdrojů a nároky uživatelů vody. Ke značnému vyhocení došlo v roce 2015. Kromě prodlužování se období sucha se tedy projevuje i pokles průtoků a s ním spojený pokles dlouhodobého průměrného průtoku  $Q_a$ , u kterého se výhledově očekává pokles na hodnoty až  $0.8Q_a$  i více (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. Výstavba nových vodohospodářských nádrží, která by vedla ke zlepšení uvedené situace, je v současné době problematická, a proto je žádoucí optimalizovat řízení již stávajících nádrží.

Průtoky vody v tocích jsou náhodné (stochastické) procesy, u nichž nelze přesně stanovit jejich budoucí hodnoty. Maximálně se dají odhadnout pravděpodobnosti jejich budoucího výskytu. Proto je značným zjednodušením předpovídat jejich hodnoty deterministicky. Deterministická předpověď náhodného procesu však může být zatížena značnou chybou a její použití pro řízení systému může být zavádějící. K problému je třeba přistupovat stochasticky a alespoň kvantifikovat pásmo jejich možného výskytu s určitým pravděpodobnostním rozdělením. Je zřejmé, že i pásmo možného výskytu se s narůstající délkou předpovědi rozšiřuje. Řízení odtoku vody z nádrže bude v dalším textu chápáno jako strategické řízení zásobní funkce nádrže využívající měsíční krok. Předpovědi pásem budoucích výskytů přítoků lze získat sestavením autoregresních modelů vycházejících z historicky měřených průtoků, které jsou realizací náhodného procesu. Uvedený postup je jednodušší než použití srážky jako vstupu a získání přítoků ze srážko-odtokového procesu.

V současné době jsou v praxi používány při řízení zásobní funkce nádrže převážně dispečerské grafy a deterministické modely. Občas se spíše v akademické rovině prosazuje snaha o optimalizaci řízení s využitím deterministických předpovědí. Mylnou výhodou použití deterministických předpovědních modelů je pouze jeden výstup (hodnota) řídicí (řízené) veličiny. Při používání pouze jedné hodnoty dochází díky výraznému zjednodušení problematiky, ke ztrátě přesnosti řízení či mylnému vyhodnocení situace (předpověď se může výrazněji odlišovat od skutečnosti, která byla předpokládána). Oproti tomu stochastické řízení umožňuje pracovat s určitým rozptylem hodnot řízených odtoků (s daným pravděpodobnostním rozdělením). Při řádném vyhodnocení a uchopení možností, které uvažovaný přístup nabízí, je značně sníženo riziko selhání provozu zásobní funkce vodní nádrže. Výhodou stochastického řízení je tedy výběr možnosti řízení pro danou pravděpodobnost překročení daného scénáře řízení. Vějíř řízených odtoků nám tedy poskytne možnost výběru řízeného odtoku podle pravděpodobností překročení. I proto je žádoucí přejít ke změně z deterministického řízení na stochastické.

Řešení problému řízení zásobní funkce nádrže adaptivním způsobem (jedna z metod umělé inteligence) umožňuje problematiku řízení zásobní funkce nádrže s uvažováním stochastických předpovědí průtoků velmi dobře postihnout. K přechodu od deterministického na stochastické řízení při adaptivním způsobu řízení se nabízí využití modelů vycházejících z metody Monte Carlo. Princip metody Monte Carlo je aplikován při vytváření předpovědí, které jsou extrapolacemi historicky měřených průtokových řad, ke kterým je přičtena náhodná složka. Uvedeným způsobem je vytvořen vějíř možných budoucích kombinací přítoků vody do nádrže. Tento modely oblasti vodohospodářského řešení nádrží však často naráží na omezení z hlediska výpočetní techniky (velké

nároky na strojový čas potřebný k výpočtu). Pro rozumné vyhodnocení opakovaných náhodných stavů je zapotřebí alespoň 300 opakování výpočtu. Stochastickým adaptivním řízením budeme v dalším textu chápat takové řízení zásobní funkce nádrže, u kterého v každém kroku výpočtu, při daném plnění zásobního objemu nádrže probíhá výpočet budoucích řízených odtoků z náhodně generovaného spektra předpovězených přítoků určité délky (počet členů řady předpovězených průměrných průtoků). Pro každou předpověď je opakovaně hledán optimální průběh řízeného odtoku. Hodnoty řízených odtoků jsou pak zpracovány do čar překročení.

Avšak výpočetní doba pro běžné počítače typu PC je neúnosná. Velké požadavky na výpočetní techniku jsou způsobeny především optimalizací, která je použita v každém časovém kroku, ve kterém opakovaně korigujeme řízení. Cestou ke snížení časových nároků optimalizace a zmírnění požadavků adaptivity je nahrazení tradičních optimalizačních modulů metodami umělé inteligence (neuronové sítě, fuzzy modely, hybridní neuro-fuzzy modely). Uvedené metody však vyžadují znalost matice vstupně-výstupních vzorů. Výhodou je, že matice je možno sestavit z výsledků provedených optimalizací v předstihu (v historickém období), to jest z řízení uvažovaného systému metodou off-line.

V předcházejícím textu byla nastíněna problematika a základní myšlenky jejího řešení, které budou v práci dále rozvíjeny.

## **2. SOUČASNÝ STAV POZNÁNÍ**

V samotné práci je popsán historický vývoj problematiky ve světě i v ČR, proto v rámci této kapitoly jsou uvedeny jen některé příbuzné práce.

Samotná práce se dá zařadit mezi stochastické dynamické programování (SPD), které proniklo do hydrologie v 80. letech minulého století (Stedinger, Sule, Loucks, 1984). Práce však nevyužívá obvyklý přístup v dříve uvedených zahraničních, kdy je pracích je volena pravděpodobnost přítoku vody do nádrže a následně je nádrž s takto vytvořenou předpovědí řízena. Na místo toho je nádrž řízena pro každou předpovězenou krátkou řada přítoků a poté je vybrána pravděpodobnost řízeného odtoku.

### **2.1 VYBRANÉ PŘÍBUZNÉ PRÁCE VYUŽÍVAJÍCÍ METODY UMĚLÉ INTELIGENCE (UI)**

V 90. letech dochází k rozšíření použití metod umělé inteligence. Pod pojem umělé inteligence jsou řazeny neuronové sítě, fuzzy logika, evoluční algoritmy, expertní systémy a řada dalších. Detailní popis jednotlivých metod umělé inteligence lze nalézt v pentalogii (Mařík, Štěpánková, Lažanský a kol., 1993, 1997, 2001, 2003, 2007).

Výzkum aplikace metod umělé inteligence probíhal paralelně na půdě katedry hydrotechniky na Stavební fakultě Českého vysokého učení technického (dále jen ČVUT) v Praze a na brněnském Vysokém učení technickém (dále jen VUT). Z mnoha prací zmíníme jen stručný výpis (Fošumpaur, Nacházel, Patera, 2002), (Fošumpaur, Nacházel, Patera, 2003), (Fošumpaurová, 2003), (Starý, 1998), (Starý, 2003), (Jaroš, 2011).

V knižní podobě existuje pro hlubší seznámení se s metodami umělé inteligence dostupná literatura např. (Berka, 1994), (Bíla, 1996), (Vysoký, 1996), (Pokorný 1998), (Jura, 2003) či již zmíněná pentalogie. Publikací, která přináší poznatky z aplikací jednotlivých metod umělé inteligence ve vodním hospodářství v ucelené podobě, je kniha (Nacházel, Starý, Zezulák, 2004).

Přelom století přinesl množství významných povodní, a proto se pozornost vědecké obce zaměřila především uvedeným směrem. Návrat k problematice nejistot ve vodním hospodářství a zásobní funkce nádrže byl zaznamenán až v pracích Marton (2011) a Menšík (2012).

Ze zahraničních prací věnujících se využití metod umělé inteligence v oblasti aplikované hydrologie jmenujme například (Kojiri, Ikebuchi, 1988), (Wang, 1991), (Valdes, Marco, 1995), (Chang, Chen, 1998), (Chang, Chang, 2001), (Ramani, Woo, Faridha, Gopinath, 2007), (Chiang, Chang, 2009), (Yan Han, YuefeiHuang, 2013), (Kang, Park, 2014), (Tukimat, Harun, 2014) a (Zhao T., Zhao J., 2014).

Je samozřejmostí, že uvedený výčet prací není kompletní a posloužil jen jako základní zdroj informací pro pochopení příbuzné problematiky předkládané práce.

### **3. CÍLE DISERTAČNÍ PRÁCE**

Předmětem disertační práce je stochastické řízení zásobní funkce nádrže s pomocí metod umělé inteligence. Cílem práce je sestavení příslušného řídicího algoritmu.

Samotná práce je rozčleněna do dvou částí. V první části jsou řešeny stochastické předpovědní modely. K průtoku vody v měrném profilu lze přistupovat jako k náhodnému procesu a k měřeným hodnotám jako k jeho realizaci, a proto budou předpovědní modely extrapolovat naměřené hodnoty v čase modely vycházejícími z autoregrese doplněné o zonální modely a jejich hybridy. Po sestavení předpovědních modelů bylo provedeno jejich vyhodnocení a byl vybrán nejlepší model, jehož předpovědi byly používány pro vlastní simulaci řízení zásobní funkce nádrže.

V druhé části práce byl sestaven vlastní algoritmus pro řízení, který vychází z principu adaptivity a z optimalizace (evoluční algoritmy a genetické algoritmy), které se vyznačují přesností a obecností, ale také svými nároky na strojový čas. Lze je použít i v předstihu (off-line) pro konstrukci matic vstupně–výstupních vztahů. Metody umělé inteligence byly použity pro aproximaci matice vzorů (fuzzy logika, neuronové sítě).

Sestavený řídicí algoritmus je použit pro řízení hypotetické nádrže. Hypotetická nádrž byla zvolena z důvodu dostupnosti dostatečně reprezentativních dat pro vytvoření předpovědí přítoků. Jednotlivé modely pro řízení byly vyhodnoceny a byla hledána i vhodná pravděpodobnost překročení odtoku.

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

### **4. POUŽITÉ METODY**

Kapitola je členěna do tří hlavních částí. V úvodní části jsou uvedeny zjednodušující předpoklady, které byly zavedeny při zpracování tématiky uvedené v předchozích kapitolách. Ve druhé části kapitoly jsou popsány použité stochastické předpovědní modely průměrných měsíčních průtoků a práce se vstupními daty. V poslední části kapitoly je popsán řídicí algoritmus pro řízení zásobní funkce nádrže a jednotlivé řídicí moduly, které využívá.

## 4.1 ZJEDNODUŠUJÍCÍ PŘEDPOKLADY

Pro dosažení cíle práce, popsaného v předchozí kapitole, bylo zavedeno několik zjednodušujících předpokladů:

- V textu práce se rozumí pod pojmem řízení nádrže, řízení izolované údolní nádrže se zásobní funkcí s jedním přítokem vody do nádrže a s jedním odtokem vody z nádrže.
- Konstantní řídicí odtok vody z nádrže pro všechny měsíce v roce.
- V průběhu konstrukce generátorů umělých průtokových řad byla zanedbána nejistota měření průtoků v měrném profilu.
- Při sestavování řídicích algoritmů byly zanedbány nejistoty hydrologických vstupů a ztráty spojené s provozem nádrže.
- Přítok vody do nádrže je považován za náhodný proces.

## 4.2 CHOVÁNÍ NÁDRŽE

V rámci práce je řešena zásobní funkce nádrže, která má zajistit požadovaný nalepšený odtok vody  $O_p$  nebo zajištění požadovaného odběru. 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). 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  $Q^\tau$  (okrajové podmínky řešení) a odtok vody z nádrže je popsán řadou odtoků  $O^\tau$ . Na konci každého časového kroku objem  $V^\tau$ .  $\tau$  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.

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

$$Q^\tau - O^\tau = \frac{V^\tau - V^{\tau-1}}{\Delta t}, \quad (4.1)$$

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

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

## 4.3 PŘEDPOVĚDNÍ MODEL Y PŘÍTOKU VODY DO NÁDRŽE

Předložená práce používá pro řízení odtoku vody z nádrže předpovědi přítoků vody do nádrže. Řada průměrných měsíčních přítoků vody  $Q^\tau$  pro  $\tau = 1, 2, \dots, N$ , která je okrajovou podmínkou řešení je predikována. Pro potřeby stochastického řízení nádrže bylo zapotřebí sestavení stochastických předpovědních modelů. Byly zvoleny modely, které vycházejí z myšlenky generátorů umělých průtokových řad, kde generátor vytvoří umělou průtokovou řadu, která má délku předpovědi (maximálně 12 měsíců) a je zastaven. Vygenerovaná řada navazuje na reálnou průtokovou řadu, vycházející z historicky měřených průtoků. Všechny dále uvedené předpovědní modely využívají pro generování náhodné složky metodu Monte Carlo. Stochastický přístup vychází z opakovaného generování předpovězených přítoků, které jsou vlastně časovým extrapolacemi reálné průtokové řady, ve kterých se mění náhodná složka. Vznikne tak vějíř předpovězených krátkých průtokových řad

Protože každý měsíc má jiné pravděpodobnostní rozdělení, a proto byla data transformována na stejné rozdělení (normované normální rozdělení).

### 4.3.1 Transformace historických dat

Práce s daty probíhala na úrovni průměrných měsíčních průtoků, kdy se data rozřídily 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  $Z$ . Tam proběhla jejich analýza a následné generování 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 Cox-Boxovou rovnicí (Box, Cox, 1964)

$$Y_{i,j} = \frac{(Q_{i,j})^{r_j} - 1}{r_j}, \quad (4.2)$$

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 Cox-Boxovy 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

$$Z_{i-1,j} = \frac{Y_{i-1,j} - s_{j-1}}{x_{j-1}}, \quad (4.3)$$

$$Y_{i,j} = x_j + s_j \cdot Z_{i,j}, \quad (4.4)$$

kde  $Y_{i,j}$  je transformovaný průměrný měsíční průtok na rozdělení bez asymetrie,  $Z_{i,j}$  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).

### 4.3.2 Autoregresní předpovědní modely

V podkapitole jsou uvedeny dva autoregresní modely, které byly používány pro vytváření předpovědi přítoků. Prvním z nich je Burgessův model a druhým použitým modelem je lineární autoregresní model.

### **Upravený Burgessův stochastický model**

Model vychází z Burgessova LN - AR modelu (1972), na místo klasických logaritmických vztahů pro transformaci na hladinu  $Y$ , které se ukázaly jako nedostatečné, používá pro transformaci v předchozí podkapitole popsanou. Dále jsou data transformována podle rovnice (4.3) na normované normální rozdělení. Náhodné číslo  $rnd_{i,j}$  (normované normální rozdělení) a předchozí transformovaný průměrný měsíční průtok  $Z_{i,j-1}$  spolu s koeficientem korelace  $\rho_j$ , který byl určen z transformovaných dat, jsou dosazeny do rovnice (4.5), kde  $j$  určuje měsíc v roce

$$Z_{i,j} = Z_{i,j-1} \cdot \rho_j + (1 - \rho_j)^{1/2} \cdot rnd_{i,j}, \quad (4.5)$$

$rnd_{i,j}$  je náhodné číslo generované z normovaného normálního rozdělení,  $\rho_j$  je koeficient korelace mezi průtoky z předchozího měsíce a předpovídaného měsíce,  $Z_{i,j}$  je předpovězený průměrný měsíční průtok na úrovni hladiny  $Z$ ,  $Z_{i,j-1}$  je předcházející průměrný měsíční průtok transformovaný na hladinu  $Z$ ,  $j$  je pořadí měsíce (pokud předpověď navazuje na reálnou řadu rovná se  $j = 1$  a  $Z_{i,j-1}$  je poslední členem reálné průtokové řady transformovaný na hladinu  $Z$ ) a  $i$  je číslo vydávané předpovědi průtokové řady.

Při opakování je měněna pouze hodnota  $rnd_{i,j}$  v rovnici (4.5). Uvedená veličina je náhodně generována, proto dostaneme pokaždé jinou hodnotu předpovědi. Z uvedené rovnice získáme předpovězený průměrný měsíční průtok, který je transformován z normovaného normálního rozdělení ( $Z$ ) na rozdělení s nulovou asymetrií ( $Y$ ) podle rovnice (4.3) a dále na rozdělení s nenulovou asymetrií měsíce ( $Q$ ), který je předpovídan rovnicí (4.4). V případě předpovědi delší než 1 měsíc je historické měření nahrazeno předpovězeným průtokem a je s ním dále rekurentně pracováno, jako by se jednalo o historický průtok.

Výše uvedený model, který byl používán pro delší předpovídané období než 1 měsíc, je tedy modelem rekurentním. Při vytváření předpovědi je vždy pro každou předpovídanou krátkou řadu i pro její prvky generováno nové náhodné číslo.

### **Lineární autoregresní model**

Jedná se o lineární autoregresní model, který předpovídá hodnoty průměrných měsíčních průtoků na základě lineární kombinace hodnot předchozích průměrných měsíčních průtoků (hladina  $Z$ ), autoregresních koeficientů a náhodných čísel. Pro stanovení autoregresních koeficientů byly použity Yule - Walkerovy rovnice (Yule, Walker, 1927, 1931). Po jejich vyřešení dostaneme koeficienty, které spolu s průtoky transformovanými na normované normální rozdělení tvoří dvojice, s jejichž pomocí podle rovnice (4.6) dostaneme předpovídaný průtok. Při samotném výpočtu model použije předepsaný počet měsíců zpětně (2 - 11) a vypočte rekurentní předpověď na požadovaný počet měsíců dopředu (1 - 12). Při opakování je měněna pouze hodnota  $rnd_{i,j}$  v rovnici (4.6). Uvedená veličina je náhodně generována, proto dostaneme pokaždé jinou hodnotu předpovědi. Předpovědi jsou následně zpětně transformovány na rozdělení, které odpovídá měsíci, pro který byla předpověď vypočtena. Pokud je požadovaná předpověď delší než 1 měsíc, předpověď se posune o jeden krok (měsíc) vpřed a celý výpočet opakuje. Z výše uvedeného textu vyplývá, že pokud je požadována delší předpověď než 1 měsíc, dostávají se do modelu mimo data reálné řady i předpovědi poskytnuté modelem rovnice (4.6). Model nemění velikost matice vstupující do Yule- Walkerovy rovnice.

$$\begin{pmatrix} 1 & \rho(1) & \dots & \rho(k-2) & \rho(k-1) \\ \rho(1) & 1 & \rho(1) & \dots & \rho(k-2) \\ \dots & \dots & \dots & \dots & \dots \\ \rho(1) & \dots & \rho(1) & 1 & \rho(1) \\ \rho(k-1) & \rho(k-2) & \dots & \rho(1) & 1 \end{pmatrix} \cdot \begin{pmatrix} a_1 \\ a_2 \\ \dots \\ a_{k-1} \\ a_k \end{pmatrix} = \begin{pmatrix} \rho(1) \\ \rho(2) \\ \dots \\ \rho(k-1) \\ \rho(k) \end{pmatrix}, \quad (4.6)$$

Základní rovnice lineárního autoregresního modelu:

$$Z_{i,j} = a_1 \cdot Z_{i,j-1} + a_2 \cdot Z_{i,j-2} + a_3 \cdot Z_{i,j-3} + \dots + a_k \cdot Z_{i,j-k} + rnd_{i,j}, \quad (4.7)$$

kde  $a_1$  až  $a_k$  jsou regresní koeficienty,  $Z_{i,j-1}$  až  $Z_{i,j-k}$  jsou předchozí hodnoty průměrných měsíčních průtoků transformované na hladinu  $Z$ ,  $rnd_{i,j}$  je náhodné číslo generované z normovaného normálního rozdělení,  $j$  je pořadí měsíce (pokud předpovědi přímo navazují na reálnou řadu a  $Z_{i,j-1}$  až  $Z_{i,j-k}$  jsou posledními členy reálné průtokové řady transformované na hladinu  $Z$ ) a  $i$  je číslo vydávané předpovědi Yule-Walkerovi rovnice

$$\begin{pmatrix} 1 & \rho(1) & \dots & \rho(k-2) & \rho(k-1) \\ \rho(1) & 1 & \rho(1) & \dots & \rho(k-2) \\ \dots & \dots & \dots & \dots & \dots \\ \rho(1) & \dots & \rho(1) & 1 & \rho(1) \\ \rho(k-1) & \rho(k-2) & \dots & \rho(1) & 1 \end{pmatrix} \cdot \begin{pmatrix} a_1 \\ a_2 \\ \dots \\ a_{k-1} \\ a_k \end{pmatrix} = \begin{pmatrix} \rho(1) \\ \rho(2) \\ \dots \\ \rho(k-1) \\ \rho(k) \end{pmatrix}, \quad (4.8)$$

kde  $a_1$  až  $a_k$  jsou hledané regresní koeficienty a  $\rho(1)$  až  $\rho(k)$  jsou příslušné korelační koeficienty.

### 4.3.3 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.

Data historické řady se seřadí v řešeném měsíci 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.

#### 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 lineární

autoregresní model. Historicky měřené průtoky se převedou na úroveň hladiny Z podle způsobu popsaného v kapitole 0. Zóna je 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 (4.7) vyčíslí regresní koeficienty. Postup modelu je dále stejný jako v případě lineárního autoregresního modelu. Na obrázku 1 je vyobrazeno schéma modelu. 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. Symboly rovnice v obr. 2 jsou vysvětleny v rovnici (4.6).



Obr. 1. Schéma Modifikovaného zonálního modelu.

### Dynamický zonální předpovědní model

Model byl sestaven se snahou o agresivnější řízení, protože předpokládá budoucí výskyt průtoků ve stejné zóně nebo zóně nižší. Uvedený předpoklad vytváří výhodnější podmínky pro nižší hodnoty předpovězených průtoků, protože vysoké přítoky vody do nádrže nejsou z pohledu řízení zásobní funkce nádrže problematické. Při nižších hodnotách průtoků jsou průtoky tvořeny základním odtokem, který lze dobře předpovídat. Naopak při vysokých hodnotách průtoků jsou průtoky tvořeny základním odtokem a velkým povrchovým odtokem (povodně). Povodně lze jen velmi těžko předpovídat vzhledem k jejich velmi nahodilému výskytu.

Model umožňuje migraci dat v zónách, ale pouze z vyšší do nižší zóny. Zóna je určena dle posledního historicky měřeného průtoků. Pokud je naměřený průtok v nejvyšší zóně (zóna nejvyšších průtoků) stává se z dynamického modelu lineární autoregresní model, protože model má přístup ke všem naměřeným průtokům z nižších zón. Pokud je naměřený průtok v nejnižší zóně, dynamický zonální model se stává modelem modifikovaným zonálním.

### 4.3.4 Metoda Latin Hypercube Sampling (LHS)

Metodu poprvé popsali McKay (1979) a Eglas (1977). Dále ji rozvinul Iman (1981), který spolu se svými spolupracovníky zveřejnil zdrojový kód a manuál k použití. Základním principem metody LHS je rozdělení definičního oboru funkce hustoty pravděpodobnosti každé základní náhodné veličiny  $X_i$  (průměrné měsíční průtoky) na  $N_{Sim}$  disjunktních intervalů. Intervaly se volí o stejné pravděpodobnosti  $1/N_{Sim}$ . Současná praxe získává reprezentativní parametr intervalu jako střed daného intervalu  $N_{Sim}$  na distribuční funkci a uvažuje jej jako výchozí pro získání reprezentativní hodnoty veličiny pomocí inverzní transformace distribuční funkce. Jedná se o stratifikační metodu, kde vrstva oboru hodnot kumulativní distribuční funkce náhodné veličiny je nahrazena jedinou hodnotou. Rozdělení na intervaly zajišťuje, že rozsah každé náhodné veličiny je realizován rovnoměrně vzhledem k distribuční funkci (Vořechovský, 2002). Dále je uvedeným postupem dosaženo, že žádná reálná hodnota není předem vyloučena. Každá vrstva se použije jednou. Posledním krokem je vhodná kombinace vzorků pomocí celých náhodných permutací.

Metoda je běžně používaná v teorii kontinua, kde bylo ověřeno, že dokáže při malém počtu opakování dosáhnout s určitou ztrátou přesnosti stejně dobrých výsledků jako při použití většího počtu opakování u metody Monte Carlo. V úvodu práce již byla nastíněna časová náročnost metody Monte Carlo, proto bylo přistoupeno k vytvoření předpovědi s využitím metody LHS a k jejich aplikaci na řízení nádrže.

## 4.4 OPTIMALIZAČNÍ MODULY

V následujícím textu jsou rozepsány jednotlivé moduly, které prohledávají oblast přípustných řešení  $\Omega$ , která má počet rozměrů roven počtu předpovídaných měsíců vydávané předpovědi průtokové řady. Moduly vyčíslí řadu odtoků vody z nádrže pro zadaný počáteční objem vody v nádrži a předpovězené přítoky vody do nádrže v řešeném období. Kritériem optimalizace je suma rozdílů druhých mocnin mezi  $O_p$  a řadou  $O$  která je minimalizována

$$\pi = \left[ \sum_{j=1}^N (O_p - O_j)^2 \right] \rightarrow MIN, \quad (4.9)$$

kde  $O_p$  je hodnota řídicího odtoku (průměrný měsíční nalepšený průtok),  $O_j$  je hodnota vypočteného řízeného průměrného měsíčního odtoku,  $N$  je počet měsíců,  $j$  je číslo měsíce a  $\pi$  je hodnota kritériální funkce.

Samotná podkapitola je členěna do dvou hlavních částí. V první části jsou uvedeny optimalizační moduly, které jsou schopny přímo hledat řešení v prostoru  $\Omega$  (polohu bodu, která odpovídá minimální hodnotě kritéria  $\pi$ ). Jedná se o dva typy evolučních algoritmů. Evoluční algoritmy byly také použity pro vytváření matic vstupně–výstupních vztahů (matice vzorů) pro učící se systémy, které jsou popsány v druhé části podkapitoly. V následujícím textu budou představeny základní modely, které jsou využívány jednotlivými moduly. Podrobnější popis teorie související s jednotlivými module lze najít v samotné práci nebo v práci doporučené literatuře.

#### 4.4.1 EA modul

##### Model EA 1 - Genetické algoritmy

Model využívá metodu binárního genetického algoritmu, který provádí vyčíslení odtoků pro zadané vstupy podle kritériální funkce  $\pi$  v oblasti  $\Omega$ . Vstupy jsou tvořeny řadou předpovědí průměrných měsíčních přítoků  $Q_p^\tau$  a objem vody v nádrži na začátku řešení  $V^0$ . Výstupem je řada řízených odtoků  $O^\tau$ . Model dále provede kontrolu řady řízených odtoků vody, jestli je nádrž schopna zajistit pro všechny časové kroky  $\tau$  vypočtené hodnoty řízených odtoků vody. Pro řízení je použit pouze první člen řady.

Hodnota křížení byla nastavena na hodnotu 0.5 a hodnota mutace na hodnotu 0.2. Chromosomy jsou zakódovány jako 16 bitový řetězec. Model vychází z popsaného algoritmu (Haupt a Haupt, 2003). Metoda nejlepšího výběru byla použita jako metoda selekce. Výpočet modelu je ukončen po 200 generacích, nebo pokud se hodnota kritériální funkce nemění o více než 0.01% po 10 generacích.

##### Model EA 2 - Diferenciální evoluce

Model provádí vyčíslení odtoků pro zadané vstupy podle kritériální funkce  $\pi$  v oblasti  $\Omega$ . Vstupy jsou tvořeny řadou předpovědí průměrných měsíčních přítoků  $Q_p^\tau$  a objem vody v nádrži na začátku řešení  $V^0$ . Výstupem je řada řízených odtoků  $O^\tau$ . Model dále provede kontrolu řady řízených odtoků vody, jestli je nádrž schopna zajistit pro všechny časové kroky  $\tau$  vypočtené hodnoty řízených odtoků vody. Pro řízení je použit pouze první člen řady.

Model je plně schopen nahradit pro deterministické výpočty programu SOMWS, uvedené výpočty sloužily pro tvorbu matic vstupně-výstupních vztahů pro fuzzy moduly a NS moduly. Model EA 2 používá diferenciální evoluci se třemi rodiči a jeho parametry byly určovány experimentálně. Uvedený přístup byl použit pro nalezení kombinace hodnot parametrů, které poskytly průběh řízení ve validační období téměř totožný s programem SOMWS a přitom čas potřebný pro výpočet byl nejmenší.

#### 4.4.2 Učící se systémy

V uvedené podkapitole jsou rozepsány učící se systémy, které jsou schopny nahradit optimalizační modul při určité ztrátě přesnosti. Jedná se o modely vycházející z neuronových sítí a fuzzy logiky. Z fuzzy modelu se stává učící se fuzzy model po provedení optimalizace poloh jednotlivých bodů a tvaru funkcí příslušnosti a báze pravidel.

##### Fuzzy modul

Součástí fuzzy module jsou tři fuzzy modely, které jsou popsány v následujícím textu.

##### Fuzzy model typu SW

Jádrem je jeden fuzzy model. Vstupem do modelu je objem vody v nádrži na počátku řešeného kroku a řada předpovězených přítoků vody do nádrže. Výstupem je jeden řídicí odtok vody z nádrže O1. Model má velmi obtížně uživatelsky definovatelnou matici pravidel, proto musí být matice pravidel optimalizována.

##### Fuzzy model typu SU

Model využívá sekvenční řízení. Jádrem modelu je opakovaně volaný fuzzy model. Vstupem do modelu je objem vody v nádrži na počátku řešeného kroku  $V_{\tau-1}$  a jeden předpovězený přítok vody do nádrže  $Q_{\tau}$  pro příslušný časový krok  $\tau$ . Výstupem je řízený odtok vody z nádrže  $O_{\tau}$ . Pokud je řízení prováděno s použitím delší předpovědi než jeden měsíc, je na konci každého časového kroku  $\tau$

vyčíslen objem  $V_\tau$  pomocí bilance vody v nádrži (rovnice 4.1) a pro následující časový krok  $\tau+1$  se objem  $V_\tau$  stává objemem  $V_{\tau-1}$  (okrajová podmínka). Do rovnice vstupuje vypočtený řízený odtok vody  $O_\tau$ , předpovězený přítok vody pro aktuální krok  $Q_\tau$  a objem vody v nádrži  $V_{\tau-1}$ . Celý postup se opakuje, dokud není použita celá řada předpovězených přítoků. Z celé řady řízených odtoků vody z nádrže je použit pro řízení vždy pouze první člen. Zbytek řady slouží pouze k určení korekcí odtoku vody z nádrže. Model typu SU má velmi jednoduchou architekturu, proto může být každý vstup i výstup popsán desítkami funkcí příslušnosti a matice pravidel bude i přes to velmi jednoduše sestavena.

#### Model typu SA

Model využívá myšlenku zmíněnou v pracích Janál (2009), Ježík (2016), kde jsou jednotlivé vstupní veličiny postupně agregovány. Model provede řízení vždy pro kombinaci dvou vstupů. Vstupem do modelu pro první časový krok  $\tau$  je objem vody v nádrži na počátku řešeného kroku  $V^0$  a jeden předpovězený průměrný měsíční přítok vody do nádrže  $Q^\tau$  pro příslušný časový krok  $\tau$ . Výstupem je řízený průměrný měsíční odtok vody z nádrže  $O^I$ . Pro všechny další kroky je kombinace vstupů tvořena jedním předpovězeným průměrným měsíčním přítokem vody do nádrže  $Q^\tau$  pro příslušný časový krok  $\tau$  a řízeným průměrným měsíčním průtokem  $O^I$  spočteným v předchozím časovém kroku  $\tau-1$ . Pro každou dvojici vstupů model koriguje řízený odtok vody z nádrže  $O^I$ . Pro vlastní řízení je použit poslední korigovaný řízený průměrný měsíční odtok vody  $O^I$ . Model typu SA má velmi jednoduchou architekturu, každý vstup i výstup může obsahovat desítky funkcí příslušnosti a matice pravidel bude i tak velmi jednoduše sestavena.

#### **Modely využívající neuronovou síť**

Pro řízení zásobní funkce nádrže byly sestaveny dva hlavní modely vycházející z neuronových sítí, které se liší jen v architektuře neuronové sítě. Modely vycházející z neuronových sítí (NS model) jsou schopny výrazného urychlení výpočtu při určité ztrátě přesnosti a jsou alternativou modelům vycházejícím z fuzzy logiky.

#### NS model typu SU

Vstupem do NS modelu je objem vody v nádrži na počátku řešení  $V_0$  a řada předpovězených průměrných měsíčních přítoků vody do nádrže. Výstupem je řada řízených odtoků vody z nádrže  $O_\tau$ . Neuronová síť není opakovaně volána jako v případě fuzzy SU modelu, ale NS model poskytne na základě vstupů řadu řízených odtoků, která má délku rovnou délce předpovězené řady přítoků. Model dále provede kontrolu řady řízených odtoků vody, jestliže je nádrž schopna zajistit pro všechny časové kroky  $\tau$  vypočtené hodnoty řízených odtoků. Pro řízení je použit pouze první člen řady.

U modelu byly sestaveny dva typy architektury. NS model 1 obsahuje jednu dvouvrstvou perceptronovou síť. První skrytá vrstva obsahuje 12 skrytých neuronů a transformační funkcí je sigmoida. Druhá skrytá vrstva obsahuje počet skrytých neuronů, který je roven počtu průměrných měsíčních odtoků vody z nádrže a má lineární transformační funkci.

NS model 2 obsahuje jednu třívrstvou perceptronovou síť. První skrytá vrstva obsahuje 15 skrytých neuronů a transformační funkcí je sigmoida. Druhá skrytá vrstva obsahuje 8 skrytých neuronů a transformační funkcí je sigmoida. Třetí skrytá vrstva obsahuje počet skrytých neuronů, který je roven počtu hledaných průměrných měsíčních odtoků vody z nádrže a má lineární transformační funkci.

Neuronová síť je učena na matici vzorů získané pomocí tradiční metody optimalizace (evoluční algoritmy). Pro natrénování sítě u obou modelů byla použita metoda zpětného šíření. Pro řízení byly zvoleny dva přístupy, které jsou představeny v následujícím textu.

#### NS model typu SW

Model odpovídá fuzzy modelu typu SW. Vstupem do NS modelu je objem vody v nádrži na počátku řešení  $V^0$  a řada předpovězených přítoků vody do nádrže. Výstupem je jeden řízený odtok  $O^l$  pro danou kombinaci vstupů. Model používá architekturu NS modelu NS 1 uvedenou v předchozím textu.

### **4.5 PRINCIP ADAPTIVITY**

Adaptivita samotná je velmi účinným prostředkem proti vlivu neurčitosti (Nacházel, Starý, Zezulák, 2004). Řídicí algoritmus využívá adaptivitu, kdy v každém kroku řízení je opakovaně prováděna optimalizace odtoku vody z nádrže tak, aby bylo dosaženo minimalizace kritériální funkce  $\pi$  rovnice (4.9). Algoritmus využívající adaptivitu provádí optimalizaci v každém časovém kroku řízení, proto je lépe schopen se přizpůsobit změnám prostředí (změna vnějších vlivů), a tím vytvořit mělčí a delší poruchy, které jsou výhodnější než kratší a hlubší. Řízení spojené s předpověďmi přináší chyby v řízení (předpovězený přítok vody do nádrže se liší od skutečného), a proto je potřeba na začátku každého kroku provést opravu vstupních hodnot (objem vody v nádrži, nové předpovědi). Při reálném řízení se provede měření hladiny nádrže. U simulovaného řízení se použijí předchozí naměřené hodnoty (objem, přítok) a provede se bilance vody v nádrži. Při použití adaptivního řízení se použije jen první člen řady řízených odtoků. Učící se systém je zvláštním případem adaptivního systému.

### **4.6 ŘÍDICÍ ALGORITMUS**

Při hledání jednotlivých řešení úlohy je ve vztahu (4.1) při každém kroku nahrazena řada  $Q$  (okrajové podmínky) řadou předpovědí  $Q_p$  a je provedeno adaptivní rekurentní řízení pro všechny časové kroky  $\tau$ . 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  $V^l$  z předchozího výpočtu.


Pokud je hodnota  $\tau > 1$  je počáteční podmínka  $V^{\tau-1}$  pro každý další časový krok  $\tau$  dopočítána podle rovnice (4.1), 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 (4.1) skutečnou hodnotu zásobního objemu. Odtok vody z nádrže, který je řízen na hodnotu  $O_p$  (řídicí odtok), může nabývat hodnot 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  $\pi$  je minimalizována dle rovnice (4.8). Řídicí 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  $\Omega$ , který má rozměr odpovídající počtu hledaných neznámých. V práci byly zvoleny pro optimalizaci (modul optimalizace) metody evolučních algoritmů (genetické algoritmy a metoda diferenciální evoluce).

Řídicí 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 metod zvolených pro optimalizační modul, který používá

adaptivního řízení. Oproti tomu metody umělé inteligence (fuzzy, neuronové sítě) jsou schopny výrazně snížit čas potřebný pro výpočet, pokud je použijeme jako náhradu optimalizačního modulu, kdy samotný optimalizační modul vytvoří v předstihu matice vstupně-výstupních vztahů, podle kterých jsou metody UI naučeny. 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 12 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 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. Je však možno ji korigovat ve smyslu konjugovaných gradientů a zkombinovat ji s hodnotami řízených odtoků použitých v předchozích krocích řízení. Pokud je hodnota korigovaného řízeného odtoku větší než hodnota řídicího odtoku  $O_p$ , je použita pro řízení hodnota  $O_p$ , zbytek odtéká ve formě jalového odtoku. Vztah použitý v obrázku je popsán v podkapitole 0.

Krok=měsíc



Obr. 2. Schéma řídicího algoritmu.

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

## 4.7 DISPEČERSKÉ GRAFY

Dispečerské řízení odtoku je pojem, který je spojován obvykle s provozem vodních nádrží nebo celých soustav. Jejich velkou výhodou je, že pro svoji aplikaci nepotřebují předpovědi budoucích přítoků do nádrže. Pro jejich sestavení se využívá historických průběhů průtokové řady (v některých případech uměle generovaná řada). Při sestavení dispečerských grafů, je třeba uvažovat velmi složité hydrologické podmínky. V reálných podmínkách se často používá pouze značně zjednodušená forma dispečerských grafů s jedinou charakteristickou protiporuchovou čarou, uvádějící požadovaný objem

vody v nádrži ke všem datům v průběhu roku. Pokud je k vybranému datu vyšší hodnota zásobního objemu než předepisuje dispečerský graf, přebytek vody se může v souladu s účely díla vhodně využít nebo vyprázdnit. Při hodnotě zásobního objemu, která je nižší než předepisuje dispečerský graf, nemusí nutně porucha nastat, protože čára dispečerského grafu je konstruována jako horní obálka vyskytujících se nároků na objem vody v nádrži. V práci se bude používat konstrukce dispečerských grafů dle skript Metodické návody k vodohospodářským řešením nádrží (Broža, 1981).

Dispečerský graf může být zkonstruován jako zonální, kdy aktuální plnění nádrže v konkrétním čase přímo určuje příslušnost k určité zóně, která předepisuje hodnotu řízeného odtoku. V práci jsou použity oba způsoby.

## 5. POUŽITÝ SOFTWARE

V kapitole jsou vypsány jednotlivé podprogramy, které byly programovány v rámci práce mimo program SOMWS, který byl převzat. V poslední části je popsáno využití paralelních výpočtů v clusteru. Samotný popis programu SUWARERO, který vznikl pro potřeby stochastického řízení nádrže a obsahuje i uživatelské rozhraní je uveden v práci.

### - Statistický modul a transformace dat.

#### - Předpovědní modely:

- upravený Burgessův model
- autoregresní lineární model
- modifikovaný zonální model
- dynamický zonální model
- LHS model.

#### - Moduly pro řízení:

- fuzzy modul
- NS modul
- EA modul.

#### - Doplnkový software.

### 5.1 PROGRAM SOMVS

Program SOMVS je licencovaný program Vysokého učení technického v Brně (Menšík, Starý, 2012). Byl použit při hledání nastavení parametrů modelu EA 2 a také v první fázi výzkumu pro konstrukci matic vstupně-výstupních vztahů pro modely vycházející z metod umělé inteligence (fuzzy, neuronové sítě). Pro vlastní řízení a pozdější konstrukci matic vstupně-výstupních vztahů byl plně nahrazen modelem EA 2, který byl sestaven v prostředí programu Matlab.

### 5.2 PARALELNÍ VÝPOČTY V CLUSTERU

K paralelním výpočtům na clusteru bylo přistoupeno z důvodu očekávané velké časové náročnosti výpočtů využívající modely EA. Cluster byl původně sestaven ze starších PC z výpočetní učebny, které byly zasítovány. Vlastní paralelní výpočet byl prováděn s využitím toolboxu Paralel Computing programu Matlab. Algoritmy modelů EA musely být upraveny pro paralelní výpočty. Cluster se skládal z 6 počítačů (5x4 + 1x2 jader, 5 MB RAM, klasický disk) + síťový disk (přístup k datům). První testy clusteru ukázaly, že je několikrát rychlejší než výkonný počítač typu PC (procesor i7,

paměť 16 MB RAM, Ssd Disk). Po počátečním úspěchu bylo tedy přikročeno k vylepšením výpočetního clusteru. Nový cluster se skládal z 6 počítačů (24 jader, 10 MB RAM, Ssd disk) + společný síťový Ssd disk umístěný v prvním PC. Uvedeným vylepšením se zdvojnásobil výpočetní výkon clusteru.

S pomocí clusteru bylo očekáváno výrazné snížení doby potřebné pro výpočty využívající EA modely.

## 6. APLIKACE STOCHASTICKÉHO ŘÍZENÍ

Stochastické řízení bylo aplikováno na fiktivní vodní nádrž, která byla navržena v měrném profilu Bílovice nad Svitavou. Profil byl vybrán z důvodu dostupnosti dat, která byla k dispozici na pracovišti, a dlouhé řady reálných průměrných měsíčních průtoků, která 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 použité metody aplikované na řízení její zásobní funkce mohly dostatečně projevit. Zásobní objem byl stanoven na hodnotu 51 811 000 m<sup>3</sup> (poměrný zásobní objem 19.7 m<sup>3</sup>/s) a řídicí odtok vody z nádrže  $O_p$  na konstantní hodnotu 4.25 m<sup>3</sup>/s.

### 6.1 HISTORICKÁ DATA

Pro sestavení i následnou validaci byla použita 90 let dlouhá řada průměrných měsíčních průtoků (od roku 1921 do roku 2010). Řada vznikla měřením v měrném profilu Bílovice nad Svitavou, který se nachází na řece Svitavě. 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 předpovědních modelů (modulů) a posledních 15 let bylo použito pro validaci modelu. Průtoky v každém měsíci mají jiné pravděpodobnostní rozdělení, proto bylo přistoupeno k jejich transformaci na jednotné rozdělení (normované normální rozdělení) viz. kapitola 4.3.1.

### 6.2 KALIBRACE A VALIDACE ŘÍDÍCÍCH MODULŮ

Kapitola se zabývá kalibrací a validací jednotlivých modulů a ověřením schopnosti učících se modulů nahradit optimalizační modul. Řídicí moduly používaly 100% předpovědi (výseky reálné řady) pro svou kalibraci a validaci, a proto nepotřebují předpovědní modely. V úvodním odstavci jsou řešeny EA modely. Dále je řešena kalibrace učících se modulů (modelů).


U modelů EA popsaných v kapitole 4.4.1 bylo hledáno vhodné nastavení jednotlivých parametrů, při kterém modely rychle konvergovaly k ideálnímu průběhu řízení. Ideální průběh řízení byl vypočten programem SOMWS, který použil místo předpovědí reálnou průtokovou řadu. Modely typu EA mohou být použity přímo pro deterministické nebo stochastické výpočty.

U učících se modelů byla v první fázi vytvořena matice vstupně-výstupních vztahů (matice vzorů), která byla získána pomocí EA modelu verze EA 2, který je popsán v kapitole 4.4.1. Matice vzorů obsahovaly data podle potřeb jednotlivých modelů (optimalizované průběhy objemů vody v nádrži a odtoky vody z nádrže).

Kalibrační období bylo zvoleno v letech 1981 – 1995 a validační bylo 1996 – 2010. 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 vodními roky, které nejsou problematické z pohledu

zásobní funkce nádrže. Validační období bylo zkráceno na délku 150 měsíců z důvodu snížení časové náročnosti výpočtů a proto, že v následujících měsících se nevyskytly zajímavé události z pohledu řízení zásobní funkce nádrže.

Oba moduly (fuzzy a NS) vycházející z metod umělé inteligence (UI) byly nejprve kalibrovány a validovány jako deterministické (při použití 100% předpovědi), aby se ověřila jejich schopnost řídit vodohospodářskou nádrž se zásobní funkcí. Oba učící se moduly uspěly při aplikaci na kalibrační i validační období (obr. 3). Obrázek 3 je tvořen třemi dílčími grafy. Všechny dílčí grafy mají na vodorovné ose čas v měsících. Na prvním (horním) dílčím grafu je vykreslen časový průběh přítoků vody do nádrže  $Q(t)$ . Na druhém dílčím grafu je zobrazen průběh objemů vody v nádrži  $V(O(t), Q(t))$ . Na posledním dílčím grafu je znázorněn řízený odtok vody z nádrže  $O(t)$ . Výjimkou byl model fuzzy typu SW, který pro své špatné výsledky byl vyřazen. Průběhy řízení poskytnuté učícími se modely ztratily podle očekávání určitou přesnost, avšak neztratily schopnost reagovat na změny vnějšího prostředí. Moduly UI vykazují tendenci držet vyšší hladinu zásobního objemu při delších obdobích sucha. Uvedená vlastnost by mohla být velmi přínosnou v podmínkách neurčitosti, které panují při používání předpovědi pro řízení.



**Obr. 3.** Srovnání průběhu výsledků programu SOMWS a fuzzy modelu pro validační období - deterministické řízení (délka předpovědi 8 měsíců).

### 6.3 KOREKCE ŘÍZENÍ

Korekce byly zavedeny pro ustálení průběhu výsledného řízení a jako ochrana před náhlými poklesy přítoku vody do nádrže, které nemohou být podchyceny předpovědními modely nebo jsou podchyceny jen pro velmi vysoké pravděpodobnosti řízených odtoků.

V práci jsou celkem použity tři typy korekcí. Korekce I vychází z metody konjugovaných gradientů a průměruje řízené odtoky vody z předchozích realizovaných kroků řízení s vypočteným. Korekce II provádí opravu hodnoty objemu  $V_{i-1}$ , o hodnotu rozdílu mezi řízeným odtokem  $O^i$  a znovu vypočteným řízeným odtokem  $O^i$  v kroku  $i$ . Korekce III zmírňuje dopad skokovitého prázdnění

zásobního objemu a opravuje hodnoty řízeného odtoku, které jsou nízké i když je zásobní prostor téměř plný.

## 6.4 VYHODNOCENÍ PŘEDPOVĚDNÍCH MODELŮ I. ČÁST


V první části proběhlo vyhodnocení na základě histogramů a průměrné entropie. Při použití histogramů byl hledán průměrný počet výskytů předpovědí v intervalu, do kterého náležel reálný průtok. Z vyhodnocení pomocí histogramů bylo vyvozeno vyřazení Burgessova předpovědního modelu z dalšího vyhodnocení. Vyhodnocení entropie ukázalo, že klasický autoregresní model ztrácí s narůstající délkou předpovědi schopnost přenášet pásmo nízkých průtoků a vysokých průtoků. U modifikovaného předpovědního modelu uvedená vlastnost nebyla pozorována.

## 6.5 VYBRANÉ VÝSLEDKY APLIKACE


V podkapitole jsou uvedeny vybrané výsledky jednotlivých předpovědních modelů (první část) a řídicích modulů. Na obrázcích je na svislé ose uveden řízený odtok vody z nádrže a na vodorovné ose je znázorněn čas v měsících. Uvedený popis je platný pro všechny následující obrázky uvedené v práci.

### 6.5.1 Předpovědní modely


Předpovědi vytvořené předpovědními modely byly aplikovány s použitím řídicího modelu fuzzy typ SU pro řízení nádrže. Na jednotlivých obrázcích jsou uvedeny jednotlivé průběhy řízených odtoků vody pro vybrané pravděpodobnosti překročení.




**Obr. 4.** Srovnání výsledků dynamického zonálního modelu (sedm měsíců zpětně pro tvorbu) s modifikovaným zonálním modelem.



**Obr. 5.** Srovnání výsledků dynamického zonálního modelu (tři měsíců zpětně pro tvorbu) s modifikovaným zonálním modelem.




**Obr. 6.** Srovnání autoregresního lineárního modelu s modifikovaným zonálním modelem.




**Obr. 7.** Srovnání modifikovaného zonálního modelu se třemi a šesti zónami.

## 6.5.2 Řídící modely


Výsledky jednotlivých řídicích modulů pro předpovědi vytvořené modifikovaným zonálním modelem.



**Obr. 8.** Srovnání výsledků poskytnutých modely NS 2 a Fuzzy.



**Obr. 9.** Srovnání výsledků poskytnutých modely EA 2 a Fuzzy.



**Obr. 10.** Srovnání výsledků poskytnutých modely NS 2 a EA 2.

## 7. SHRnutí VÝSLEDKŮ

V následujícím textu je stručně popsána cesta, která vedla k vytvoření předpovědních modelů a řídicích modulů.

Pro stochastické řízení zásobní funkce nádrže musely být nejdříve sestaveny stochastické předpovědní modely. V práci byly sestaveny čtyři základní předpovědní modely (Burgessův, lineární autoregresní, dynamický zonální, modifikovaný zonální). Dynamický zonální model a modifikovaný zonální model náleží mezi hybridní modely, protože využívají základní myšlenku zonálního modelu a do zón aplikují lineární regresní model. Uvedené modely byly v první fázi vyhodnoceny na základě průměrné měsíční četnosti. Pro špatné výsledky byl Burgessův model vyřazen z dalšího vyhodnocování. Při vyhodnocování modelů byl objeven nečekaný nárůst hodnoty průměrné četnosti s narůstajícím pořadím předpovědi, a proto byly modely (modifikovaný zonální a lineární autoregresní) dále vyhodnocovány za pomoci průměrné entropie. Dynamický zonální model byl z vyhodnocení průměrné entropie vyřazen z důvodu horších výsledků v porovnání s vybranými modely.

Druhá fáze vyhodnocení předpovědních modelů probíhala přímo na řízení nádrže se zásobní funkcí. Pro vlastní proces řízení byl zvolen fuzzy model SU. Prvním testovaným modelem byl lineární autoregresní model (obr. 6). Fuzzy model nebyl schopen určit oblast hlavní poruchy, vyprázdnil celý zásobní objem, a proto byl lineární autoregresní model prohlášen za nevyhovující. Dynamický zonální model byl testován, jako druhý v pořadí (obr. 5). Během sledovaného období nebyl vyprázdňen zásobní objem a průběh řízení v oblasti hlavní poruchy byl velmi dobrý, avšak množství a hloubky vytvořených poruch se ukázaly být neúnosnými. Posledním testovaným předpovědním modelem byl modifikovaný zonální model, u kterého byl testován počet zón. Nejdříve byl testován se třemi zónami (obr. 6), ale výsledky řízení se blížily výsledkům dosažených pomocí dynamického zonálního modelu, proto bylo rozhodnuto o navýšení počtu zón na šest (obr. 7). Po zvýšení počtu zón se výsledné řízení výrazně zlepšilo. Délka a především hloubka vytvářených poruch klesla na přijatelnou mez. Celkový průběh řízení lze prohlásit za velmi dobrý. Z výše uvedených výsledků lze říci, že je možné využít stochastické předpovědi pro řízení zásobní funkce nádrže.

Paralelně s druhou polovinou první fáze probíhalo sestavení a vyhodnocení různých řídicích modulů řízení zásobní funkce nádrže. Proběhlo ověření, zda všechny ostatní řídicí moduly poskytují podobné výsledky na základě předpovědních modelů, jako tomu bylo u fuzzy modelu SU. Bylo konstatováno, že pro další testování předpovědních modelů bude použit fuzzy model SU.

Modely pro řízení používaly předpovědi vytvořené modifikovaným zonálním modelem. Vlastní řízení probíhalo na fiktivní nádrži (měrný profil Bílovice nad Svitavou) z důvodu dostupnosti dat. Fiktivní nádrž byla navržena tak, aby v průběhu řízení musely vzniknout poruchy. Nejdříve byly sestaveny modely vycházející z metod umělé inteligence (fuzzy, NS), pro které byly vytvořeny matice vzorů za pomoci programu SOMVS. Modely vycházející z fuzzy logiky se vyhodnocovaly jako první. Celkově byly sestaveny a testovány tři fuzzy modely, které tvoří fuzzy modul (SW, SU, SA). Model SU a SA poskytly srovnatelné výsledky.

Dále byly testovány modely vycházející z neuronových sítí. Za účelem nalezení vhodné architektury NS byly sestaveny dva hlavní modely lišící se počtem vrstev (2-vrstvé, 3-vrstvé). Pro oba typy architektury byly sestaveny dva typy modelu SW a SU. Z výsledků řízení pro oba modely vyplynulo, že je potřeba zavést korekce. Po zavedení korekcí I a II začaly oba modely poskytovat velmi dobré průběhy řízení odtoků pro vybrané pravděpodobnosti.

Modely využívající metody EA byly v kombinaci se stochastickými výpočty vyhodnocovány jako poslední, protože mají velké nároky na strojový čas potřebný pro výpočet. Doba potřebná pro výpočet jedné pravděpodobnosti (celkový počet předpovědí 500, délka období 150 měsíců, délka předpovědí 8 měsíců) byla 24.5 hodiny na výkonném PC (8 jader) pro model EA 1 (Genetické algoritmy). Pro porovnání, stejný výpočet by trval fuzzy modelu 12.5 minuty na stejném PC. Vzhledem k velkým časovým nárokům výpočtů bylo rozhodnuto, že modely EA budou počítány paralelně v clusteru. Výpočty dále probíhaly na sestaveném clusteru (24 jader), který byl schopen provést stejný výpočet za 1 hodinu. První výsledky modelů EA se ukázaly jako nedostatečné, protože ani jeden z modelů nebyl schopen určit oblast hlavní poruchy bez předchozího vyprázdnění. Po zavedení korekcí se výsledný průběh řízení výrazně zlepšil. Při vzájemném porovnání výsledků obou modelů EA bylo zjištěno, že výsledný průběh řízení poskytnutý modelem EA 2 dosahuje dobrých výsledků pro větší rozsah pravděpodobností, a proto je vhodnější než model EA 1 pro stochastické řízení nádrže.

V dalším kroku byly porovnány moduly mezi sebou (fuzzy, NS, EA). Nejdříve byly výsledky obou modulů vycházející z metod umělé inteligence porovnány s výsledky modelu EA 2 (obr. 9 a obr. 10). Výsledné řízení poskytnuté fuzzy modelem se blížilo více průběhu řízení získaného modelem EA 2 než tomu bylo v případě výsledků modelu NS 2. Výsledné řízení obou modelů vycházejících z UI se ukázalo jako logické a velmi dobré v porovnání s modelem EA 2, a proto je lze oba doporučit jako náhradu optimalizačního modulu (DE). Závěrem bylo konstatováno, že výsledky fuzzy modelu SU jsou nejlepší, proto budou používány pro srovnání s výsledky jiných metod řízení (obr. 8).

Posledním krokem vyhodnocení byl vliv celkového počtu předpovědí na řízení, protože všechny modely byly testovány s hodnotou 1000 předpovědí. Pro vyhodnocení byla zvolena kombinace předpovědí vytvořených modifikovaným zonálním modelem a řídicím fuzzy modelem SU. Z výsledných průběhů řízení vyplynulo, že hodnota hlavního kritéria pro řízení se ustálila okolo hodnoty 500 a její další zvyšování nepřineslo výrazné zlepšení průběhu řízení. Pokud byla hodnota počtu celkových předpovědí nižší než 300 výsledné řízení se lišilo při použití opakovaně vygenerovaných předpovědí.

Pro srovnání s dispečerskými grafy byly vybrány výsledky průběhů řízených odtoků poskytnuté fuzzy modelem SU, který používal předpovědi vydávané šestizonálním modifikovaným modelem. Porovnání bylo provedeno pouze v oblasti poruch, kde je nádrž téměř prázdná. Z výsledků je patrné, že oba druhy dispečerských grafů provádí náhlé skokové poruchy v řízeném odtoku vody. Řízení fuzzy modelem zavádí velmi dlouhou a pozvolně propagovanou poruchu, což je žádoucí.

Výsledky kombinace předpovědního modelu LHS a řídicího modelu fuzzy SU byly srovnávány s výsledky předpovědního šestizonálního modifikovaného modelu a řídicího modelu fuzzy SU. Z výsledků je patrné, že při použití metody LHS se 40 intervaly jsou výsledky srovnatelné jako při použití metody Monte Carlo s počtem opakování 500. Při použití metody LHS je však třeba zajistit, aby jednotlivé soubory předpovězených průtoků měly koeficient korelace blízký hodnotě 0 (-0.3, 0.3).

## 8. ZÁVĚR

Cílem práce bylo ověření možnosti využití stochastického řízení zásobní funkce nádrže a sestavení příslušného řídicího algoritmu pro jeho použití v praxi. Proto byl vytvořen software, který umožňuje simulovat stochastické řízení nádrže tak, aby bylo možno provést jeho vyhodnocení. Uvedený cíl je možno považovat za splněný. Příslušné softwarové moduly byly sestaveny a na konkrétním případě údolní nádrže byly otestovány. Dosažené výsledky jsou podrobně uvedeny v kapitolách 6 a 7, kde

bylo provedeno jejich shrnutí. Z uvedeného textu je zřejmé, že použití stochastického řízení nádrže má smysl.

Stochastické předpovědní modely pro předpovědi průměrných měsíčních průtoků považuje hydrologická komunita obecně za problematické. Testované modely vycházející čistě z autoregrese, uvedenou skutečnost potvrdily (Burgessův model, lineární autoregresní model). V práci bylo prokázáno, že použití na pracovišti vyvinutých zonálních předpovědních modelů a jejich modifikace s autoregresními modely, může být cestou jak daný problém řešit.

Stochastické adaptivní řízení je velmi dobrou metodou pro řízení zásobní funkce nádrže. Zejména lze očekávat jeho přínos při potlačení vlivu neurčitostí vývoje budoucích trendů přítoku vody do nádrže. Lze očekávat, že budoucí změny klimatu a následné změny průtoků nebudou běžně používané metody (DG) schopny dobře postihnout, protože budoucí změny, které se v průtokových řadách projeví nejsou obsaženy v existujících historických průtokových řadách. Naproti tomu popsáné stochastické adaptivní řízení je schopno postihnout vysokou rozmanitost a variabilitu budoucích přítoků. Silnou stránkou zpracovaných algoritmů je především generalizace vstupně-výstupních vztahů obsažených v matici vzorů, které v sobě implicitně nesou metody umělé inteligence (učící se fuzzy modely, neuronové sítě).

Z pohledu ročního řízení odtoků je možno očekávat spíše menší přínos stochastického adaptivního řízení oproti použití DG. Jeho síla se však projeví při víceletém řízení odtoku vody z nádrže, kde použití DG je problematické. Metoda adaptivního stochastického řízení je pro víceleté řízení vhodná a podle dosažených výsledků je schopna úspěšně uřídit odtok vody u nádrže v krátkých i dlouhých málovodých obdobích při vhodně nastavené agresivitě řízení. Tu je možno nastavit vhodně zvolenou pravděpodobností překročení řízených odtoků.

V práci byla pro každý model hledána vhodná pravděpodobnost překročení odtoku (příslušný kvantil). Výsledky ukázaly, že modely poskytovaly velmi dobré výsledky pro kvantily P85 až P95. Vyšší pravděpodobnosti překročení představují vyšší použitou agresivitu řízení. Nelze opomenout, že výsledné řízení je závislé na celkovém počtu i délce předpovědi. Pro většinu modulů bylo dosaženo nejlepších výsledků pro délku předpovědi šest měsíců. Výjimku tvořil fuzzy model SU, který dosahoval nejlepších výsledků pro délku předpovědi čtyři měsíce.

V práci popsána metoda je aplikovatelná na libovolnou údolní nádrž se zásobní funkcí. Některé nádrže musí pracovat s velmi vysokou napjatostí mezi přítoky a řízenými odtoky. V ČR je obecně situace odlišná a provoz nádrží je bezpečný. Nádrže byly navrženy pro velmi vysokou zabezpečenost. V době oprav (po skončení oprav přijde období sucha) nebo při velkých změnách ve vývoji klimatu a narůstajících nárocích na odběry, lze očekávat nárůst a vyšší frekvenci poruch a s tím spojenou potřebu vhodně řídit odtoky v poruchové oblasti. Popsané metody pak mohou najít svoje uplatnění.

Vyvinutý software lze doporučit pro použití v praxi. Stochastické adaptivní řízení je možno paralelně aplikovat na vybranou nádrž, která je řízena dispečinkem tradičními metodami a zahájit tak poloprovozní ověřování.

Při stochastickém řízení byla prokázána vhodnost využití paralelních výpočtů v clusterech, které jsou schopny výrazně urychlit mnohdy velmi časově náročné operace.

Závěrem lze říci, že uvedená práce je prvotním pokusem o stochastické řízení zásobní funkce nádrže s dostatečně kladným výsledkem motivujícím pokračování dalšího výzkumu v dané oblasti.

## 9. POUŽITÁ LITERATURA

- [1] Jura, P.: Základy fuzzy logiky pro řízení a modelování. In: IEEE Transactions on Systems, Man and Cybernetics, Vol. 23, No. 3, FEI VUT, Brno 1998, 92 s.
- [2] Sugeno, M.: Fuzzy Measures and Fuzzy Integrals. In: Gupta M.M., Saridis G.N., Ganiès B.R.: Fuzzy Automata and Decision Processes, New York, North-Holand, 1977, s. 89-102.
- [3] Tagaki, H., Sugeno, M.: Fuzzy Identification of Systems and Its Applications to Modelling and Control. In: IEEE Trans. On Systems, Man and Cybern., SMC-15(1), 1985, s. 116-132
- [4] Box, G. E. P. and Cox, D. R.: (1964). An analysis of transformations, Journal of the Royal Statistical Society, Series B, 26, 211-252.
- [5] Yule, G. U.: (1927) "On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers", Philosophical Transactions of the Royal Society of London, Ser. A, Vol. 226, 267–298.
- [6] Walker, Gilbert: (1931) "On Periodicity in Series of Related Terms", Proceedings of the Royal Society of London, Ser. A, Vol. 131, 518–532.
- [7] Haupt, R. L. and Haupt, S. E. (2003) Appendix II: MATLAB Code, in Practical Genetic Algorithms, Second Edition, John Wiley & Sons, Inc., Hoboken, NJ, USA. doi: 10.1002/0471671746.app2
- [8] 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.
- [9] Nacházel, K., Fošumpaur, P.: Teorie možnosti v hydrologii a vodním hospodářství. Journal of Hydrology and Hydromechanics. 2010, roč. 58, č. 2, s. 73-97. ISSN 0042-790X. DOI: 10.2478/v10098-010-0008-y.
- [10] Menšík, P., Starý, M., Marton, D.: Water Management Software for Controlling the Water Supply Function of Many Reservoirs in a Watershed. Water resources, 2015, roč. 42, č. 1, s. 133-145. ISSN: 0097- 8078.
- [11] McKay, M.D., Beckman, R.J., Conover, W.J. (May 1979). "A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code". Technometrics (JSTOR Abstract). American Statistical Association. 21 (2): 239–245. doi:10.2307/1268522. ISSN 0040-1706.
- [12] Iman, R. L., Davenport, J. M., and Zeigler, D. K. 'Latin Hypercube Sampling (A Program User's Guide)': Technical Report SAND79-1473, Sandia Laboratories, Albuquerque (1980).

- [13] Kašpárek, L.: Odhad objemu nádrží potřebného pro kompenzaci poklesu odtoku vlivem klimatické změny, VÚV Praha, Praha, 2005.
- [14] Starý M., 2006: Nádrže a vodohospodářské soustavy (MODUL 01), VUT v Brně - Fakulta stavební, Brno, 2006.
- [15] Starý M., 2006: Nádrže a vodohospodářské soustavy (MODUL 02), VUT v Brně - Fakulta stavební, Brno, 2006.
- [16] Menšík, P., Starý, M.: SOMVS; SOMVS - Simulační a Optimalizační Model Vodohospodářské Soustavy. (software)
- [17] K. Price, R. Storn, and J. Lampinen.: "Differential evolution: A practical approach to global optimization," Berlin: Springer-Verlag, 2005.
- [18] Coifman, R.R., M.V.Wickerhauser.: (1992), "Entropy-based Algorithms for best basis selection," *IEEE Trans. on Inf. Theory*, vol. 38, 2, pp. 713–718.
- [19] Broža V., 1981: Metodické návody k vodohospodářským řešením nádrží, ČVUT v Praze, Praha, 1981
- [20] Vořechovský M.: Nové úpravy simulační metody Latin Hypercube Samplinga možnosti využití, 4th Scientific PhD international workshop, 2002, ISBN 80-214-2067-7.
- [21] Marton, D., Menšík, P., Starý, M.: Using Predictive Model for Strategic Control of Multi-reservoir System Storage Capacity, článek v *Procedia Engineering*, ISSN 1877-7058, Elsevier Science Publishers, Amsterdam, 2015
- [22] Eglajs, V., Audze P.: "New approach to the design of multifactor experiments". Problems of Dynamics and Strengths. 35 (in Russian). Riga: Zinatne Publishing House: 104–107, (1977).
- [23] Janál, Petr.: Fuzzy model pro předpověď stupně ohroženosti povodí povodněmi z přívalových dešťů. *Journal of hydrology and hydromechanics*, 2009, Roč. 57, č. 3, s. 145-153. ISSN 0042-790X

Další zdroje jsou uvedeny v disertační práci.

## 10. ŽIVOTOPIS AUTORA

Ing. Tomáš Kozel

Datum a místo narození: 5.5.1988, Brno

Bydliště: Družstevní 9, Ostopovice, Česká republika

Kontakt: email: kozel.t@fce.vutbr.cz

### Vzdělání:

- |                   |                                                                                                                                          |
|-------------------|------------------------------------------------------------------------------------------------------------------------------------------|
| 2004 - 2008       | Střední průmyslová škola stavební, Kudelova 8, Brno<br>Obor Stavebnictví                                                                 |
| 2008 - 2012       | Bakalářské studium (Bc.), VUT Brno, Fakulta stavební,<br>Ústav vodního hospodářství krajiny, obor Vodní<br>hospodářství a vodní stavby   |
| 2012 -2014        | Magisterské studium (Ing.), VUT Brno, Fakulta<br>stavební, Ústav vodního hospodářství krajiny, obor<br>Vodní hospodářství a vodní stavby |
| 2014 – současnost | Doktorské studium, VUT Brno, Fakulta stavební, Ústav<br>vodního hospodářství krajiny, obor Vodní hospodářství<br>a vodní stavby          |

### Zaměstnání:

- |                   |                                                                    |
|-------------------|--------------------------------------------------------------------|
| 2016 - současnost | VUT Brno, Fakulta stavební, Ústav vodního<br>hospodářství krajiny, |
|-------------------|--------------------------------------------------------------------|

## 11. ABSTRACT

*The main advantage of stochastic forecasting is fan of possible value, which deterministic method of forecasting could not give us. Future development of random process is described better by stochastic then deterministic forecasting. We can categorize discharge in measurement profile as random process. Stochastic management is worked with dispersion of controlling discharge value. In thesis is described construction and evaluation of adaptive stochastic model base on fuzzy logic, neural networks and evolution algorithm, which are used stochastic forecast from forecasting models described in thesis. The learning fuzzy model and neural network is used as replacement of classic optimization algorithm (evolution algorithm). Model was tested and validated on made up large open water reservoir. Results were evaluated and were compared with model base on traditional algorithms, which was used for 100% forecast (forecasted values are real values). The management of the large open water reservoir with storage function, which was given by stochastic adaptive managing, was logical. The main advantage of fuzzy model and neural network model is computing speed. Classical optimization model is needed much more time for same calculation as fuzzy and neural network model, therefore classic model used clusters for stochastic calculation.*