

# 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

CONTROL OF STORAGE FUNCTION OF THE RESERVOIR

### BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

### AUTOR PRÁCE

AUTHOR

Matěj Hon

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. TOMÁŠ KOZEL, Ph.D.

BRNO 2020



## VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STAVEBNÍ

<b>Studijní program</b>	B3607 Stavební inženýrství
<b>Typ studijního programu</b>	Bakalářský studijní program s prezenční formou studia
<b>Studijní obor</b>	3647R015 Vodní hospodářství a vodní stavby
<b>Pracoviště</b>	Ústav vodního hospodářství krajiny

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

<b>Student</b>	Matěj Hon
<b>Název</b>	Řízení zásobní funkce nádrže
<b>Vedoucí práce</b>	Ing. Tomáš Kozel, Ph.D.
<b>Datum zadání</b>	30. 11. 2019
<b>Datum odevzdání</b>	22. 5. 2020

V Brně dne 30. 11. 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, m. návody do cvičení 1. vyd. Brno, VUT Brno, 1987.
- Nacházel K., Starý M., Zezulák J.: Využití metod umělé inteligence ve vodním hospodářství, kniha, 320 s., Academia, 2004, ISBN 80-200-0229-4.
- Hirsh R.M.: Syntetic Hydrology and Water Supply reliability, Water Resources Research, No. 6, December, 1979.
- Broža, V.: Methodological instructions for water management solutions of reservoirs, ČVUT v Praze, Praha, 1981.

## ZÁSADY PRO VYPRACOVÁNÍ

Student sestaví dispečerské grafy pro vybranou vodní nádrž, která bude upřesněna vedoucím práce. Dále student využije kombinaci dispečerských grafů a předpovědí průměrných měsíčních přítoků vody do nádrže. Na závěr vyhodnotí obě metody ve zvoleném validačním období.

## STRUKTURA BAKALÁŘSKÉ 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).

## **ABSTRAKT**

Dispečerský graf udává množství vypouštěné vody podle aktuálního stavu objemu vody v nádrži. V práci je popsán postup vytváření zonálního dispečerského grafu a jeho simulování na reálném vodním díle Vranov. Pomocí předpovědí byl model otestován, jak pracuje s možností určení přicházejících přítoků. Metoda dispečerského grafu je řazena mezi deterministické metody řízení. Tyto metody jsou výhodné v jednom výstupu, a tím bývá řídicí veličina. Dalšími možnými metodami jsou stochastické metody, které pracují s pravděpodobností a dávají možnost na výběr řízení. Oba typy metod jsou v práci popsány. Pro předpověď průtoků bylo zvoleno použití neuronové sítě fungující na principu zpětného šíření.

## **KLÍČOVÁ SLOVA**

Vodní nádrž, zásobní objem, deterministické řízení, umělá neuronová síť, dispečerský graf, předpovídání průtoků.

## **ABSTRACT**

Dispatcher graphs state the amount of discharged water according to the current status of a water tank. The thesis describes the technique of creating a zonal dispatcher graph and its simulation on a large open water reservoir Vranov. Using predictions, the model was tested to know how it works with the ability to determine incoming tributaries. The dispatcher graph method is commonly rated among deterministic control methods. These methods are advantageous in one specific output and that is a control variable. Other possible ways are stochastic methods that work with probability and give us the control over the choice of a procedure. Both types of methods are further described in the work. For the suitable prediction of flows, the use of a neural network operating on the principle of reverse propagation was chosen.

## **KEYWORDS**

Large open water reservoir, storage volume, deterministic control, artificial neural network, dispatcher graph, flow prediction.

## **BIBLIOGRAFICKÁ CITACE**

Matěj Hon *Řízení zásobní funkce nádrže*. Brno, 2020. 53 s., 53 s. příl. Bakalářská 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 bakalářské práce s názvem *Řízení zásobní funkce nádrže* je shodná s odevzdanou listinnou formou.

V Brně dne 1. 6. 2020

---

Matěj Hon  
autor práce

## **PROHLÁŠENÍ O PŮVODNOSTI ZÁVĚREČNÉ PRÁCE**

Prohlašuji, že jsem bakalářskou práci s názvem *Řízení zásobní funkce nádrže* zpracoval(a) samostatně a že jsem uvedl(a) všechny použité informační zdroje.

V Brně dne 1. 6. 2020

---

Matěj Hon  
autor práce

### **PODĚKOVÁNÍ:**

Rád bych úvodem poděkoval vedoucímu mé bakalářské práce Ing. Tomášovi Kozlovi, Ph.D. za veškeré informace a cenné rady, jak při tvorbě této práce, tak i během studia. Dále bych rád poděkoval všem mým blízkým za podporu a trpělivost při studiu.



## OBSAH

<b>1. Úvod</b>	<b>11</b>
<b>2. Cíl práce</b>	<b>13</b>
<b>3. Simulace řízení</b>	<b>14</b>
<b>3.1. Chování nádrže</b>	<b>14</b>
<b>4. Metody</b>	<b>16</b>
<b>4.1. Metody řízení</b>	<b>16</b>
4.1.1. <i>Dispečerské grafy</i>	16
4.1.2. <i>Optimalizační metody řízení</i>	17
<b>4.2. Předpovědní modely</b>	<b>18</b>
4.2.1. <i>Stochastické modely</i>	18
4.2.2. <i>Deterministické modely</i>	18
<b>5. Neuronové sítě</b>	<b>22</b>
<b>5.1. Biologické neuronové sítě</b>	<b>22</b>
<b>5.2. Umělé neuronové sítě</b>	<b>22</b>
<b>5.3. Trénování neuronové sítě</b>	<b>24</b>
5.3.1. <i>Metoda zpětného šíření</i>	25
<b>5.4. Použitý software</b>	<b>26</b>
5.4.1. <i>Matlab</i>	26
<b>6. Aplikace</b>	<b>27</b>
<b>6.1. Vodní dílo Vranov</b>	<b>27</b>
6.1.1. <i>Historie</i>	28
6.1.2. <i>Technické parametry</i>	28
<b>6.2. Povodí vodního díla Vranov</b>	<b>30</b>

6.2.1.	<i>Řeka Dyje</i> .....	30
6.2.2.	<i>Řeka Želetavka</i> .....	31
<b>6.3.</b>	<b>Získání dat</b> .....	<b>32</b>
<b>7.</b>	<b>Kalibrace</b> .....	<b>34</b>
7.1.	Dispečerské grafy.....	34
7.2.	Předpovědní model.....	36
7.3.	Dispečerský graf s předpovědí .....	37
<b>8.</b>	<b>Validace</b> .....	<b>38</b>
8.1.	Dispečerské grafy.....	38
8.2.	Předpovědní model.....	38
8.3.	Dispečerský graf s předpovědí .....	39
8.4.	Grafy .....	40
<b>9.</b>	<b>Závěr</b> .....	<b>45</b>
	<b>Seznam zkratk a symbolů</b> .....	<b>47</b>
	<b>Použitá literatura</b> .....	<b>49</b>
	<b>Seznam obrázků</b> .....	<b>52</b>
	<b>Seznam grafů</b> .....	<b>52</b>
	<b>Seznam tabulek</b> .....	<b>53</b>

## 1. Úvod

Hlavním problémem ve vodním hospodářství je nedostatek vody během dlouhých období sucha. Poslední roky 2015–2020 ukázaly, že je nutné vytvořit dostatečný zásobní objem na vodních dílech. Právě dostatečný zásobní objem je potřebný na udržení kvality pitné vody, která je dodávána obyvatelstvu. Také se ukázalo, že během výše zmíněného období je menší výskyt sněhové pokrývky, která je potřeba pro podzemní vody, které jsou nyní na velmi nízké hodnotě zásob. Česká republika je tzv. střechou Evropy a nepřitéká k nám žádný tok, který by nás byl schopen dostatečně zásobit. Nemáme jinou možnost, než si zde co nejvíce zadržet spadlou vodu v nádržích již vybudovaných nebo nově plánovaných.

Metody řízení zásobního objemu na vodohospodářských objektech lze řešit různými způsoby. Záleží, jakým směrem se rozhodneme řízení provozovat, jaké máme možnosti ve výpočetní technice a kolik dat je k dispozici. Rozhoduje se mezi řízením stochastickým nebo deterministickým. Obě tato řízení jsou různými autory zkoušena na základním modelu nádrží případně soustav. Většinou se pro zjednodušení nezapočítávají možné ztráty, které by do modelovaných situací vnesli mnoho dalších proměnných. Proto se používají zejména jen nejvíce přispívající přítoky a také odtok nebo odtoky v případech více odběratelů.

Z deterministického modelování řízení vycházejí dispečerské grafy (DG), které jsou velkým zjednodušením pro řízení vodních nádrží. Jejich hlavním zjednodušením je určení vypouštěné vody podle stávajícího objemu v nádrži. DG jsou vytvořeny pomocí dat historických řad. Lze také zavést předpovědi přicházejících suchých epizod, při kterých bude potřeba využít co největší možný zásobní objem pro dlouhodobé zadržení vody. Je tedy důležité zkoumat celkové vlivy na hydrologickou situaci, které jsou způsobovány klimatickou změnou. Tyto vlivy musí být zahrnuty do DG, ve kterých nejsou zahrnuty suché období z posledních pár let. Případně je vhodné hledat nové způsoby řízení, které by lépe reagovali na další vývoj.

Vhodnou metodou pro budoucí řízení by mohlo být použití DG s předpovědí průtoků. Pro získání předpovědí budoucích průtoků lze využít model používající neuronové sítě v programu Matlab. V práci je stručný popis pracovního postupu neuronových sítí a také stručně jejich vývoj. Neuronové sítě se ve velkém množství

používají v počítačovém a programátorském odvětví, ale i ve vodohospodářské oblasti najdou využití. Při naprogramování jsou neuronové sítě jednou z metod umělé inteligenci. Neuronové sítě je schopna rychlého opakování některých výpočetních úkonů.

Práce je zaměřena na řízení zásobního objemu Vranovské přehrady, která je jednou z větších přehrad v České republice. Vranovská přehrada se nachází na jižní Moravě. Tato oblast je velmi zatížena změnami klimatu. Proto je vhodná pro hledání nových způsobů řízení a pro upravování aktuálního řízení na vodních nádržích. Jelikož do nádrže nepřitéká voda z mnoha toků, je pro ni snadnější hledat způsob modelování, který nebude muset obsahovat tolik proměnných a bude tak jednodušší zajištění dat. Tato vodní nádrž také zajišťuje dodávky vody do okolních obcí a měst, některá z nich jsou Moravské Budějovice a Znojmo. V případě potřeby je voda dodávána i do jaderné elektrárny Dukovany. Také zajišťuje minimální průtok na toku Dyje a dostatek vody i do zavlažovacích kanálů a náhonů na mlýny. Zajišťuje i bezpečný průtok při povodňových epizodách pro všechny obyvatele po toku Dyje.

## **2. Cíl práce**

Cílem této práce je zhodnocení řízení nastaveného podle dispečerského grafu na vodním díle Vranov s možností využití předpovědního modelu. Dále vytvořit předpovědní model pomocí neuronových sítí a zhodnotit funkčnost uvedeného řízení.

### 3. Simulace řízení

V dnešní době jsou přehradní nádrže řízeny zejména podle DG. Tyto grafy byly vytvořeny při jejich stavbě pomocí stochastických metod a jsou po několika letech aktualizovány s ohledem na nová data. A však nejsou tak úplně schopny zachytit velké epizody sucha, neboť jsou tvořeny jen na jednoleté řízení. Podle aktuálních dat a předpovědí, kdy přicházejí dlouhé epizody sucha a pak krátké intenzivní doby dešťů, je potřeba zachytit tyto rozdílné doby a co nejvíce využívat zásobních objemů vodních děl. Z tohoto důvodu jsou hledány další formy pro řízení přehradních nádrží.

V této kapitole bude popsán průběh řízení přehradní nádrže.

#### 3.1. Chování nádrže

K simulaci řízení byl použit zejména tabulkový program Microsoft Excel a v něm vývojářský podprogram Visual Basic. Jako podkladní data byly použity průtoky z let 1935 až 2003. Řízení bylo zjednodušeno o veškeré ztráty, které by zahrnovaly další úpravy při řízení. Hlavním úkolem nádrže je zajistit nejlepší odtok vody  $O_p$ . Dále budou popsány pojmy z matematického modelu pro řízení zásobní funkce nádrže. Teorie je obecně známa, proto by nebylo přínosné ji zde zdlouhavě rozepisovat. Byla popsána jinými autory např. [Starý, 2005]. Schéma úlohy je zobrazeno na obrázku 1., nádrž má jeden přítok  $Q(t)$  a jeden odtok  $O(t)$ . 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 stanoveného časového kroku je objem vody v nádrži  $V_\tau$ .  $T$  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 (Kozel,2017)

Chování nádrže je možno popsat základní rovnicí nádrže.

$$Q^{\tau} - O^{\tau} = \frac{V^{\tau} - V^{\tau-1}}{\Delta t}, \quad (3,1)$$

Při časovém kroku 1 měsíc je vhodné použít její diferenční tvar, 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. (Kozel,2017)

## 4. Metody

V této kapitole jsou popsány způsoby řízení přehradních nádrží a dále také možnosti určení budoucích průtoků.

### 4.1. Metody řízení

#### 4.1.1. Dispečerské grafy

Vodohospodářský dispečink a dispečerské řízení odtoku jsou pojmy spojované s provozem vodních nádrží anebo celých soustav. Výhoda DG je, že nepotřebují k řízení předpověď budoucích průtoků. Vystačí si pouze s aktuálním stavem přítoku a stavem výšky hladiny. Pro jejich sestavení se používají historické průtokové řady nebo řady uměle generované. Je také nutné přihlédnout k budoucím prognózám a vývoje klimatu v místě řízené nádrže. Je vhodné pro zajištění bezporuchového provozu snížit návrhové průtoky tak, aby se při klimatické změně daly zachytit hrozící velmi suchá období. Také je důležité myslet na složitost všech hydrologických podmínek, a proto se nejčastěji navrhuje velmi zjednodušené dispečerské grafy. Tato zjednodušená forma obsahuje jednu charakteristickou protiporuchovou čáru, která udává požadovaný objem nebo výšku hladiny v nádrži ke každému datu v roce. Pokud je zásobní objem nádrže nad touto čarou, může se s ohledem na účele nádrže a přibližné hydrologické předpovědi vypustit. Nastane-li větší pokles zásobního objemu, než je uvedeno v dispečerském grafu v danou dobu, nemusí to znamenat hrozící poruchu v dodávce vody, protože graf je konstruován jako obálka všech vyskytlých nároků na objem vody v nádrži. V práci budou použity konstrukce DG dle skript Metodické návody k vodohospodářským řešením nádrží. (Broža, 1981)

Dispečerský graf na přehradní nádrži Vranov je zonálním DG. Tento graf je rozdělen do zón dle aktuálního stavu zásobního objemu vody v nádrži. V této práci bude vyzkoušeno možného dispečerského řízení s předpovědí několika dalších následujících období.



## 4.1.2. Optimalizační metody řízení

### 4.1.2.1. Metoda Mřížková

Mřížková metoda je jedna z nejjednodušších optimalizačních metod. Zvolením pevného kroku a kombinováním hodnot parametrů dostáváme pravidelnou mřížku v oblasti  $\Omega$ . S ohledem na určený počet parametrů je dán i konečný počet variant. Výhodou této metody je systematické prohledávání v oblasti  $\Omega$ , při níž budou nalezeny všechny globální extrémní kritériální funkce. Je teda potřeba využít všechny možné kombinace parametrů, aby nebyla vynechána nějaká část. Pro zkrácení vyhledávacího času můžeme snížit velikost jednoho kroku, čímž snížíme počet opakování. Ale může dojít k nezachycení některých oblastí s extrémem. Při dalším postupu se sníží krok vyhledávání a také prohledávaná oblast, která byla určena z dřívějšího postupu. (Starý,2006)

### 4.1.2.2. Metoda Monte Carlo

Metoda Monte Carlo je založena na náhodném prohledávání přípustných intervalů parametrů. Metoda je také nazvána jako metoda náhodného vzorkování. Hledané extrémní jsou lokalizovány v daných funkcích pomocí opakovaných náhodných pokusů. Také lze touto metodou řešit i deterministické úlohy. Body (vzorky) na oblasti  $\Omega$  jsou určovány zcela náhodně. Řešení úloh probíhá podle rovnice 3,2 a pro každý hledaný náhodný bod  $(V_1^{\xi_1}, V_2^{\xi_2})$  na oblasti  $\Omega$  platí:

$$\begin{aligned} V_1^{\xi_1} &= V_1^{MIN} + (V_1^{MAX} - V_1^{MIN}) \cdot \xi_1 \\ V_2^{\xi_2} &= V_2^{MIN} + (V_2^{MAX} - V_2^{MIN}) \cdot \xi_2, \end{aligned} \quad (4,1)$$

kde  $\xi_1$ , a  $\xi_2$  jsou náhodná čísla náhodně generovaná z intervalu  $\langle 0,1 \rangle$ . Množství řešených variant je možné snížit změnou velikosti jednoho kroku, jak to bylo i u mřížkové metody. (Starý,2006)

## 4.2. Předpovědní modely

V kapitole jsou popsány možnosti vytvoření předpovědí pro budoucí hodnoty veličin s náhodným rozdělením.

### 4.2.1. Stochastické modely

Stochastické metody fungují na principu výběru řídicích průtoků na dané pravděpodobnostní rozdělení. Může tedy dojít k výběru nevhodného postupu předloženého v pravděpodobnostním scénáři. Některé stochastické metody jsou omezeny výpočetní technikou, na které jsou závislé, a to zejména při opakování daných postupů pro zjištění pravděpodobného výsledku.

### 4.2.2. Deterministické modely

V současnosti jsou z velké části ve vodohospodářství používány metody deterministické pro řízení zásobních objemů vodních nádrží. Hlavní výhodou těchto metod je minimální počet výstupů, většinou jeden, určených na množině několika vstupů nebo také jen jednoho. Výstupy jsou řídicími hodnotami pro manipulaci s vodním objem a jsou závislé obvykle na objemu vody v nádrži, která určuje její hladinu. Tímto dochází ke zjednodušení pro řízení zásobních objemů a jsou tak používány v manipulačních řádech na mnoha vodních dílech.

#### 4.2.2.1. Arima

Při metodě Arima často dochází k vytváření nestacionárních řad. Ty jsou tvořeny zejména přítomností trendu, odchýlená pozorování, sezónnost apod. Tyto projevy lze spatřit již při pozorování grafu z identifikace časové řady. Na základě zjištění těchto problémů může být řešením vhodná úprava nebo transformace na stacionární časovou řadu. Lze také použít úpravy pomocí linearizace časové řady nebo stabilizace rozptylu pomocí logaritmické transformace. Těmito úpravami je možné získat záporné hodnoty po diferencování, proto je důležité provádět transformace před samotným diferencováním časové řady.

Následuje odhadnutí výpočtů odhadů PCF (parciální autokorelační funkce) a ACF (autokorelační funkce) původní časové řady. Zdali je potřeba upravit časovou řadu, lze zjistit z těchto odhadů.

Dále se určí, jaký proces časovou řadu generuje. Pro určení modelů AR a MA (proces klouzavých součtů) se aplikuje výběrové ACF a PACF. Předpokladem pro toto určení je podobnost výběrové ACF a PACF s teoretickými ACF a PACF, kterými se proces B-J (Box-Jenkins) jednoznačně vyznačuje.

Poté, co byla provedena úprava časové řady je snaha určit, který proces časovou řadu generuje. Využívají se výběrové procesy ACF a PACF pro identifikaci modelů AR (autoregresní proces) a MA (proces klouzavých součtů). Identifikace se opírá o princip podobnosti výběrové ACF a PACF s teoretickými ACF a PACF, na kterých je proces B-J (Box-Jenkins) založen. (Zatloukal,2008)

#### 4.2.2.2. Lineární autoregresivní model

Jde o model předpovídající budoucí měsíční průtoky podle lineární kombinace hodnot předchozích průměrných měsíčních průtoků, autoregresních koeficientů a náhodných čísel. Rovnice Yule-Walkerovy (Yule, Walker, 1927, 1931) lze použít ke stanovení autoregresních koeficientů. Koeficienty s transformovanými průtoky na normální rozdělení tvoří dvojce a slouží k předpovídání průtoků za pomoci rovnice (3,3). Pro samotný výpočet se zpětně použije předepsaný počet měsíců a vyhodnotí se předpověď na požadovaný počet měsíců dopředu (1–12). Při zpětné úpravě se hodnoty rozdělí podle odpovídajících měsíců. Když je předpověď delší jak 1 měsíc, předpověď se posune o jeden krok a výpočet se opakuje. Tímto se dostanou do výpočtu i předpovězené měsíce, a tak i data mimo reálnou řadu.

Prvotní rovnice lineárního autoregresního modelu:

$$Z_{i,j} = a_1 * Z_{i,j-1} + a_2 * Z_{i,j-2} + a_3 * Z_{i,j-3} + \dots + a_k * Z_{i,j-k}, \quad (5,1)$$

$Z_{i,j}$  až  $Z_{i,j-k}$  značí předchozí hodnoty průměrných měsíčních průtoků transformované na hladinu  $Z$ .  $a_1, a_2, a_3, \dots, a_k$  jsou regresní koeficienty. (Kozel,2017)

#### 4.2.2.3. Sarima

Model SARIMA se identifikuje podle přítomnosti sezónní složky, která je v časové řadě. Postup je stejný jako u modelu ARIMA.

Po určení modelu SARIMA je třeba časovou řadu upravit. Pokud je to nutné, řadu linearizujeme pomocí logaritmické transformace. S ohledem na sezónní výchyly

obsahující diferenci prostou diferencujeme řadu. Úprava pomocí sezónní difference signalizuje na tvar výběrové ACF a PACF. Funkce jsou charakterizovány svými vysokými hodnotami v nesezónních frekvencích.

Během dalšího kroku se vypočítá ACF a PACF pro časovou řadu, podle kterého se vyhodnotí typ sezónních modelů SAR (sezónní autoregresní proces), SMA (sezónní proces klouzavých průměrů) nebo SARMA (smíšené sezónní a nesezónní procesy) (sezónní frekvence jsou od nuly statisticky velmi odlišné, a však nejsou tak vysoké, aby šlo časovou řadu uvažovat za nestacionární). Po zařazení typu sezónní složky se spočte výběrová ACF a PACF pro rezidua sezónního modelu. Rozhodne se, jestli je potřeba dodat do modelu i složky AR, MA nebo ARMA (autoregresivní proces klouzavých součtů).

Z důvodu výchyly ACF a PACF oproti teoretickým hodnotám je umožněn pouze přibližný odhad typu a řádu procesu ve složkách. Obvykle je vyzkoušeno více modelů, ze kterých se vybere podle statisticky významných parametrů. (Zatloukal,2008)

#### **4.2.2.4. Zonální model**

Zonální předpovědní model má výhodu oproti normálnímu předpovědnímu modelu zejména v tom, že historická naměřená data jsou rozdělena do zón podle výskytu a jsou také rozdělena podle řešeného měsíce. Průměrné měsíční průtoky z historické řady jsou seřazeny v daném měsíci od nejmenšího po největší a rozděleny do zón, podle kterých se rozhoduje řízení do dalšího kroku. Reálné průměrné měsíční průtoky ležící v dané zóně a které jsou rozděleny časovými úseky určuje pracovní oblast daných průtoků neboli zón v modelu. Další historická data průběhů reálných průtoků nejsou využita pro tvorbu předpovědi k danému měsíci. Dále se vytvoří trojúhelníkové rozdělení pomocí transformace, a to odstraněním asymetrie dat v daných zónách. Dojde k odhadu dat v místech s nízkým počtem realizací v určitých zónách malého výskytu. Modus předpovědi volíme jako předpovězený průtok. Jestliže je předpověď zařazena do zóny s nízkými průtoky, má to výhodu, že toto rozmezí je spojeno s výskytem historicky nízkých průtoků. (Kozel,2017)

Model vznik při spolupráci autorů článku Analysis of the influence of input data uncertainties on determining the reliability of reservoir storage capacity. Miloš STARÝ, Daniel MARTON, Pavel MENŠÍK (Marton,2015).

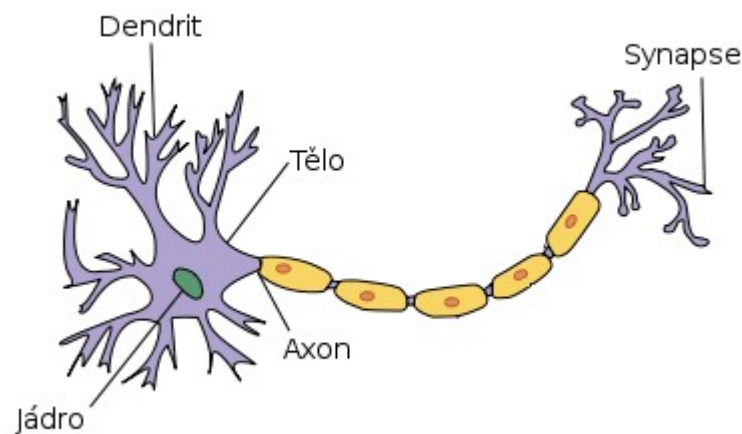
#### 4.2.2.5. Modifikovaný zonální model

Tato metoda vychází z deterministického zonálního modelu, podle kterého je prohledávaná oblast průtokových řad také rozdělena na předem určené zóny. Zonální model je v této práci rozebrán v další kapitole. Rozdílem modifikovaného zonálního modelu je použití lineárního autoregresního modelu ve vybraných zónách. Naměřené historické průtoky jsou upraveny a převedeny do hladiny  $Z$ . Pro pracovní měsíce se rozdělí zóny podle posledního naměřeného průtoku v daném měsíci. Korelační matice, jenž je počítána pouze z historicky naměřených průtoků vyskytujících se v dané zóně, je hlavním vstupem do Yule-Walkerových rovnic. Data, která neleží v dané zóně, nejsou při tvorbě korelační matice modelu přístupná a nejsou tedy do této matice zahrnuty. Za pomoci Yule-Walkerových rovnic se ze získané korelační matice spočtou regresní koeficienty. Dále je postup obdobný s lineárně autoregresním modelem. (Kozel,2017)

## 5. Neuronové sítě

### 5.1. Biologické neuronové sítě

Základním funkčním prvkem je nervová buňka, neuron. Neurony jsou samostatné specializované buňky sloužící k přenosu, zpracování a ukládání informací, které jsou potřeba k fungování živého organismu. Samostatný neuron je složen z několika částí tělo neuronu (somatu), vstupní přenosový kanál (dendrit) a výstupní přenosový kanál (axon). Neurony jsou propojeny pomocí synapsí, které jsou vytvářeny mezi vstupními a výstupními kanály. Celá neuronová síť je napojena na vstupní receptory umístěné na orgánech a ty vyvolávají podmínky ke spuštění samostatných neuronů. Výsledný výstup z neuronové sítě vydá povel k reakci na daný podmět. (Volná,1998)



Obr. 2. Biologický neuron (Neuron, 2001)

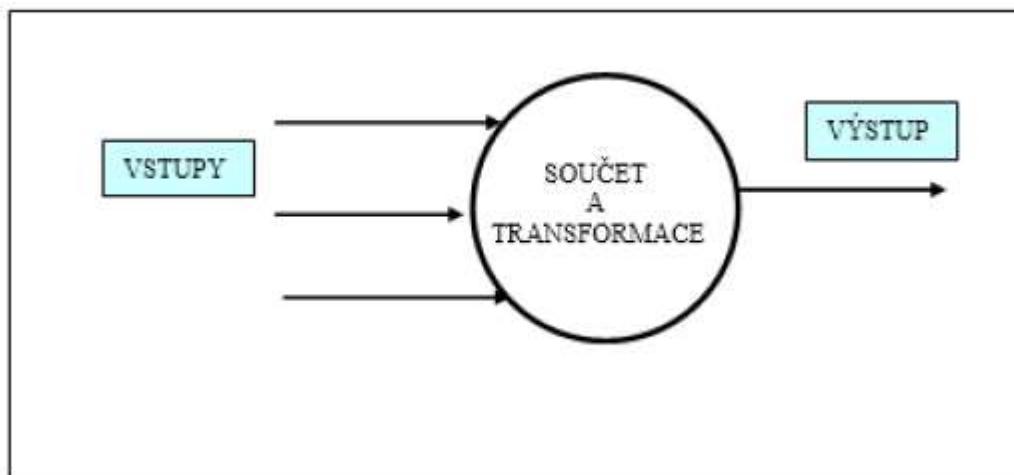
### 5.2. Umělé neuronové sítě

Umělé neuronové sítě dominují v okamžitém rozpoznávání funkcí z podobností ve vstupně-výstupních vztazích. Na rozdíl od logických operací a fuzzy logických metod, které jsou užitečné zejména v reprezentativnosti znalostí.

První neuronové sítě jsou spojovány s pány McCulloch a Pitts, ti sestavili první neuronový model. Další neuronový model, který byl už založený na biologické podobnosti a schopen se učit, sestrojil pan Hebb. Na těchto základech bylo dále vyvinuto mnoho dalších forem neuronových sítí.

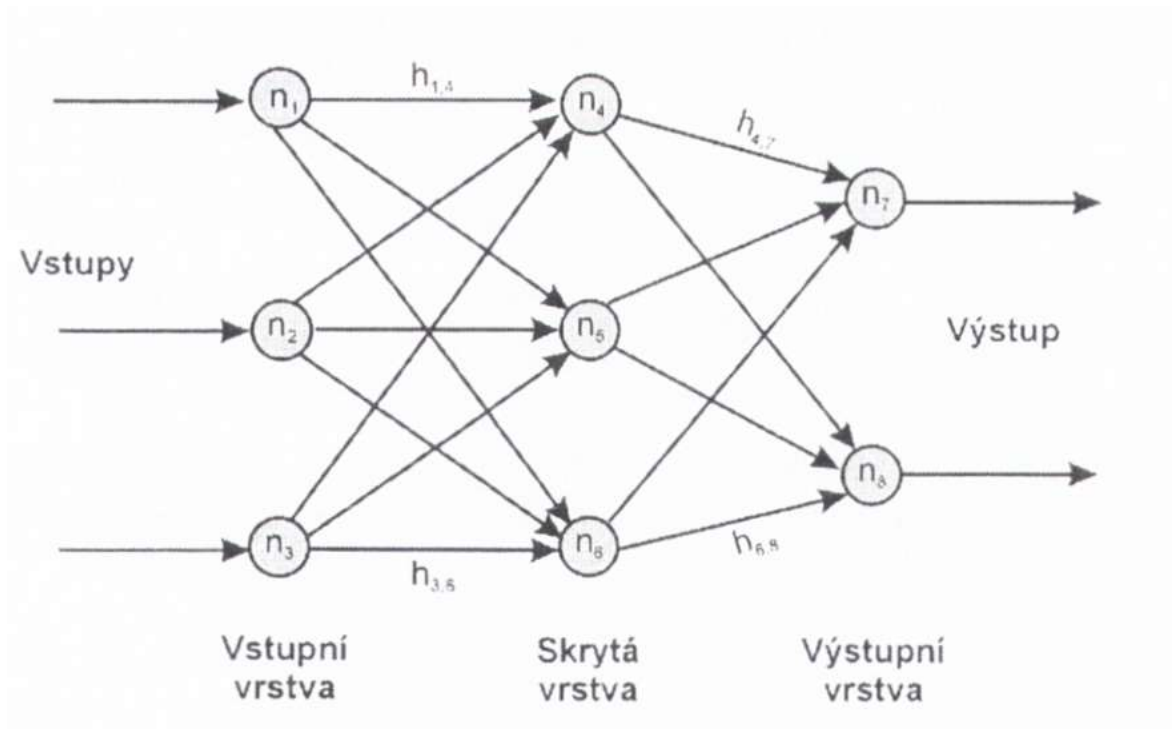
Umělý neuron má velkou podobnost s neuronem biologickým. Neuron umělý přijímá vstupy z mnoha dalších neuronů přes takzvané neuronové hrany, po hranách

vycházející z tohoto neuronu se vysílají další informace. Vstupními signály v umělých neuronových sítích jsou vstupní data a síla jejich signálu, jenž určí vzplanutí nebo také zapnutí funkce v některých následujících neuronech. Neurony, které nedostanou dostatečný impulz, nevyšlou do dalších vrstev signál a naopak. Každý neuron je modifikován podle trénování a dostávají tak každý jinou funkci nebo hodnotu pro zapnutí. Neuronové sítě nemohou pracovat spojitě. Umožňují pouze pro dané hodnoty vyhodnotit dané výstupy, protože neurony propouští pouze odpovídající signál daných hodnot. Učením neuronových sítí dochází ke změně vah určující rozdíl mezi hodnotou vybranou sítí při učení a hodnotou určenou pro zaučení této sítě. Při komplikovaných typech úloh může být více vstupních veličin. Z tohoto důvodu je potřeba mít dostatečné množství dat pro zaučení neuronové sítě.



Obr. 3. Umělý neuron (Nacházel, 2004)

Podle funkce obsažené v neuronech lze rozdělit neuronovou síť na lineární nebo na nelineární. Dále také podle směru vstupu jsou rozděleny na jednosměrné, když signál prostupuje pouze jedním směrem, nebo zpětnovazebné, kde signál prostupuje z obou stran. V umělých neuronových sítích se používají různé druhy přenosových funkcí. Například logistická sigmoidální funkce, skoková přenosová funkce, lineární prahová a Gaussova přenosová funkce. (Nacházel, 2004)



Obr. 4. Umělá neuronová síť (Nacházel, 2004)

### 5.3. Trénování neuronové sítě

Je vytvořena tréninková matice, do které jsou vepsány do zvolených sloupců hodnoty vstupních signálů a do zbytku hodnoty výstupní. Jeden řádek zastupuje vždy jeden vztah mezi vstupem a výstupem – tvoří jeden vzor. Schéma takovéto matice je znázorněno na tabulce 1. Vstupní veličiny  $X_1$ ,  $X_2$ ,  $X_3$  a  $X_4$ , označené symbolem  $\downarrow$  jsou zapsány do vstupních sloupců, výstupní veličiny  $Y_1$  a  $Y_2$  označené symbolem  $\uparrow$  jsou pak zapsány ve sloupcích výstupních. Číslo uvedené ve sloupci  $i$  udává pořadí příslušného vzoru. (Nacházel, 2004)

Toto trénování probíhá podle metody zpětného šíření, které je popsáno dále.

Tabulka 1. - Schéma tréninkové matice (Nacházel, 2004)

	$\downarrow$	$\downarrow$	$\downarrow$	$\downarrow$	$\uparrow$	$\uparrow$
$i$	$X_1$	$X_2$	$X_3$	$X_4$	$Y_1$	$Y_2$
1	0,4	12,7	5,1	26,5	6,8	0,0
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



### 5.3.1. Metoda zpětného šíření

Tato metoda je nejpoužívanější pro učení neuronových sítí. Lze ji zařadit mezi gradientní metody. Při použití této metody dochází k opravě vah v závislosti na odchylce mezi zadanými a vypočtenými hodnotami výstupních hodnot z neuronové sítě a hodnotami zadanými, podle kterých se neuronová síť učí. Úprava neuronů nebo jejich výstupních signálů v síti probíhá sítí zpětně od výstupní vrstvi neuronů po vrstvu vstupní. Z tohoto zpětného postupu je pojmenována tato metoda. Postupem trénování neuronové sítě dochází při každém kroku k výpočtu chybného vzoru  $E_v$ . Při každé zpětné kontrole chyb dojde ke změně vzoru, ze kterého se vychází do dalšího pokusu učení. Z tohoto postupu je zřejmé, že algoritmus není schopen aplikovat zaráz celkovou chybu  $E$ . Jednotlivé chyby nebo jejich váha je implementována do každého zpětného kroku. Praxí bylo dokázáno, že tato metoda je použitelná v naprosté většině testovaných příkladů.


*„Pokud zavedeme do řešení hodnoty prahů  $\Theta$  jako nulté vstupy do neuronů s hodnotou signálu -1 a s váhou  $\Theta$ , pak se hodnota signálu u každého neuronu v průběhu trénování nemění a zůstává rovna -1. Opravy změn prahů se pro každý vzor počítají jiným způsobem obdobným jako u změn vah.“ (Nacházel,2004)*

## 5.4. Použitý software

Pro výpočty byl použit Microsoft Excel a jeho programovací součást Visual Basic. Pro vytváření předpovědního modelu byl použit Matlab, který je dále popsán.

### 5.4.1. Matlab

Matlab je interaktivní nástroj pro inženýrské a vědecké výpočty, analýzu dat, vizualizaci a vývoj algoritmů. Je využíván mnoha vědkyněmi po celém světě pro své vědecké a technické výpočty, maticové operace, analýzu dat, vizualizaci a vývoj algoritmů. Dále dává možnosti v oblastech aplikované matematiky, strojového učení (neuronové sítě), zpracování signálu a komunikace a mnoha dalších operací. Matlab je schopen komunikovat s programy, které mají programovací jazyk C, C++, Java, .NET a Microsoft Excel. (Matlab, 2001)




Obr. 5. Program Matlab

## 6. Aplikace

Výsledky práce byly virtuálně simulovány na vodním díle Vranov. Toto vodní dílo bylo vybráno z důvodu dostupnosti dlouhodobě měřených dat. Na toku Dyje v místě vodního díla je průměrný dlouhodobý roční průtok  $9,74 \text{ m}^3/\text{s}$ .

### 6.1. Vodní dílo Vranov

Vodní dílo Vranov se nachází při ústí Štítarského potoka u obce Vranov nad Dyjí okres Znojmo. Je umístěno na 175,41 říčním km. Ovládání vtokových šoupat je umístěno na návodním líci v betonových šachtách, na vzdušné straně je pak budova elektrárny a strojovna spodních výpustí. Střední část přehrady je tvořena třemi dilatovanými bloky, které jsou na horní části opatřeny bezpečnostním korunovým přepadem. Na střední přepadové pole navazuje dva dilatační bloky spodních výpustí. Do konce je pak dalších šest dilatačních bloků, také s bezpečnostním korunovým přelivem. Aby nedošlo k poškození objektů při přelivu vody, slouží k jejímu usměrnění a utlumení kaskáda navazující na posledních šest bloků. Je tvořena deseti stupni o výšce přibližně 4,5 m a ukončena ve vývaru. V něm jsou umístěny dva mohutné železobetonové bloky, sloužící k rozrážení vody. (Povodí Moravy, s.p.)



Obr. 6. Zobrazení hloubky v nádrži (Husák, c2010-2020)

### 6.1.1. Historie

Z roku 1712 pocházejí první záznamy o regulaci řeky Dyje. Za účelem ochrany před povodněmi, nalepšení průtoků, vytvoření vodních rezerv, energetiky a na podnět zemského sněmu byl v roce 1911 vytvořen plán na výstavbu 37 údolních přehrad na Moravě. Tou mělo být i vodní dílo u Vranova nad Dyjí. Po roce 1918 byl plán předělán, protože během světové války nebyla možnost uskutečnit stavbu těchto přehrad. Základní změnou pro nový plán bylo použití nových metod z litého betonu po vzoru zahraničních vodních děl, které upustili od klasického vyzdívání z lomového kamene. Vodní dílo však nebylo stavěno podle projektu schváleného v roce 1918, ale bylo tvořeno podle prováděcích projektů, které byli zhotovovány během stavby stavební správou.

Samostatné výstavbě předcházely přípravné práce, které spočívaly v odhalení svahů v místech pro zavázání hráze, ve výstavbě nových přístupových cest a komunikací, zařízení dílen, ubytoven, kanceláří a zázemí pro dělníky. Stavba zaměstnávala na stovky stavebních dělníků, několikero techniků a specialistů subdodavatelských firem. Bylo nutné rozdělit stavbu a rozdělení postupu prací na pravý a levý břehy, neboť výstavba díla byla prováděna bez obtokové štoly. Řeka Dyje byla svedena do vyhloubeného pomocného koryta, které bylo v místě budoucího odpadního koryta z vodní elektrárny v pravé části přehradního profilu. Po celém půdorysném profilu hráze byli zapuštěny základy 3 m do skály. V roce 1932 4. ledna se přes stavbu prohnala velká voda, doprovázená chodem ledových ker. Staveniště chráněné ochrannými jímkami bylo zatopeno a dočasně se stavba zpomalila. Začátkem roku 1934 byly instalovány strojní komponenty v elektrárenské části a v dubnu byl zahájen zkušební provoz vodního díla Vranov. (Povodí Moravy, s.p.)


### 6.1.2. Technické parametry

Celkový objem nádrže je 132,70 mil. m<sup>3</sup>, z toho je objem stálého nadržení 31,84 mil. m<sup>3</sup>, zásobní objem 79,67 mil. m<sup>3</sup>, prostor retenční ovladatelný 11,16 mil. m<sup>3</sup> a neovladatelný 10,03 mil. m<sup>3</sup>. Vzduť vodního toku nádrží dosahuje délky cca. 30 km. Kóta koruny hráze je 353,39 m n.m., výška hráze nade dnem je 47 m a od základu 59,87m, délka koruny je 290,45 m, šířka v koruny hráze 7 m a poloměr zakřivení hráze je 500 m. Vodní dílo má 4 spodní výpusti o průměru 1600 mm s kapacitou 143 m<sup>3</sup>/s. Na vtoku jsou

tabulové uzávěry chráněné česlemi, dvě výpusti mají válcový uzávěr a další dvě Johnsonovy uzávěry. Přehradní nádrž je také využívána pro výrobu elektrické energie, k její výrobě jsou v tělese hráze umístěny 3 turbíny typu Francis s výkonem 18,9 MW. (Povodí Moravy, s.p.)

Tabulka 2. - Rozdělení prostoru v nádrži

Prostor v nádrži	HLADINA		Výška	Objem vody
	MIN.	MAX.		
	m n.m.	m n.m.	m	mil.m <sup>3</sup>
Stálé nadržení	306,75	331,45	24,8	31,84
Zásobní prostor	331,45	348,45	17,0	79,67
Retenční prostor ovladatelný	348,4	350,20	1,65	11,16
Retenční prostor neovladat.	350,20	351,45	1,35	10,03
Prostor celkový	306,75	351,45	44,81	132,69



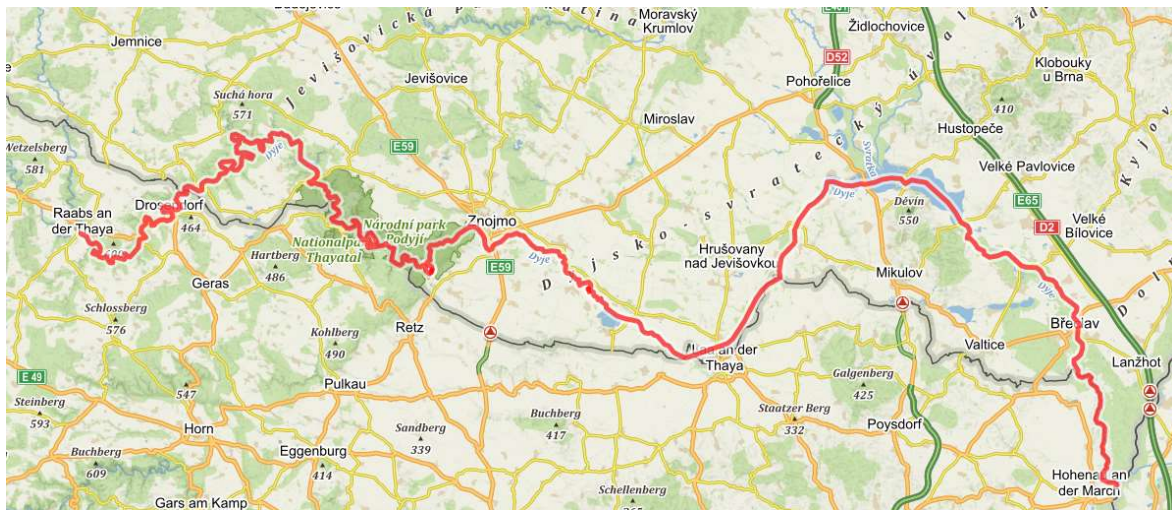
Obr. 7. Plánek přehrady (Vranovská přehrada, c2012)

## 6.2. Povodí vodního díla Vranov

Celková plocha povodí je 2 211,80 km<sup>2</sup>. V blízkosti vodní nádrže je povodí z většiny zalesněné a břehy jsou využívány k rekreačním účelům. V celém povodí nejsou významní znečišťovatelé. Výše na tocích řek Dyje a Želetavky jsou tvořeny meandry. V okolí řek se nacházejí lesní porosty, zemědělská půda, obce a města.

### 6.2.1. Řeka Dyje

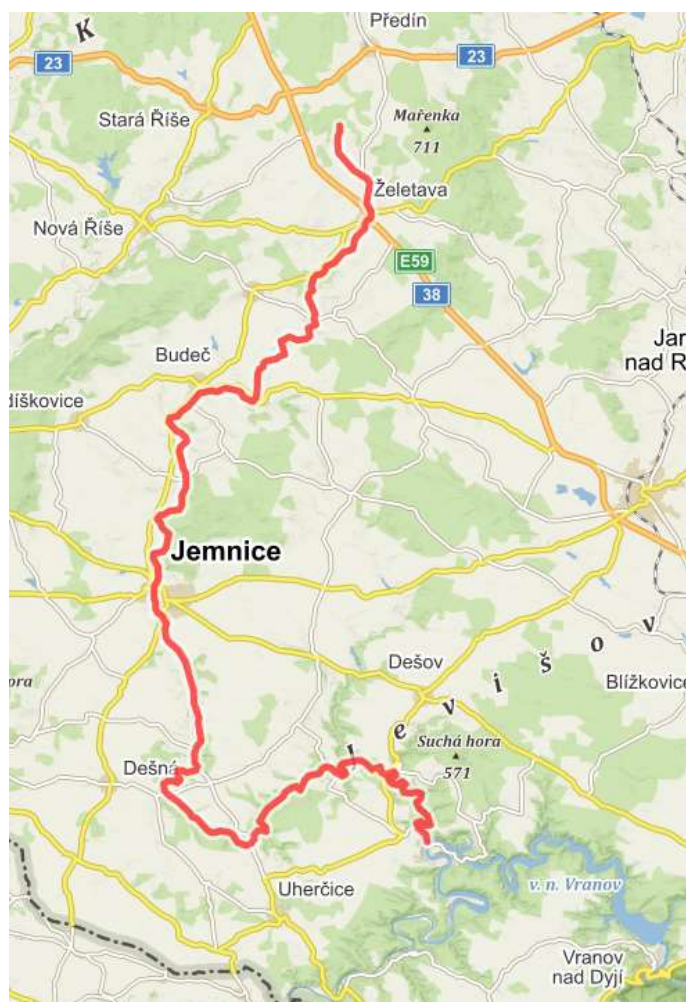
Řeka Dyje vzniká na soutoku dvou jejích zdrojnic Moravské Dyje a Rakouské Dyje u rakouského hradu Rakous. Dále pak meandruje na pomezí hranic České a Rakouské republiky, více spíše na české straně. Celková délka toku Dyje je 235,4 km s Moravskou Dyjí a 311 km s Rakouskou Dyjí. Do Dyje se vtéká několik dalších řek, některé významnější řeky jsou Želetavka, Jihlava a Svratka. Také protéká Národním parkem Podyjí, kde vytváří vhodné podmínky pro rozvoj místního biotopu. Průměrný roční průtok udávaná v době psaní této práce je 8,81 m<sup>3</sup>/s. (Dyje, 2020)



Obr. 9. Řeka Dyje (Mapy.cz, 2020)

## 6.2.2. Řeka Želetavka

Želetavka pramení v Třebíčském okrese západně od obce Lesná. Pramen se nachází v nadmořské výšce 660 m. Délka toku je 55,8 km, její průměrný roční průtok činí 1,21 m<sup>3</sup>/s. (Želetavka, 2019)



Obr. 10. Řeka Želetavka (Mapy.cz, 2020)

### 6.3. Získání dat

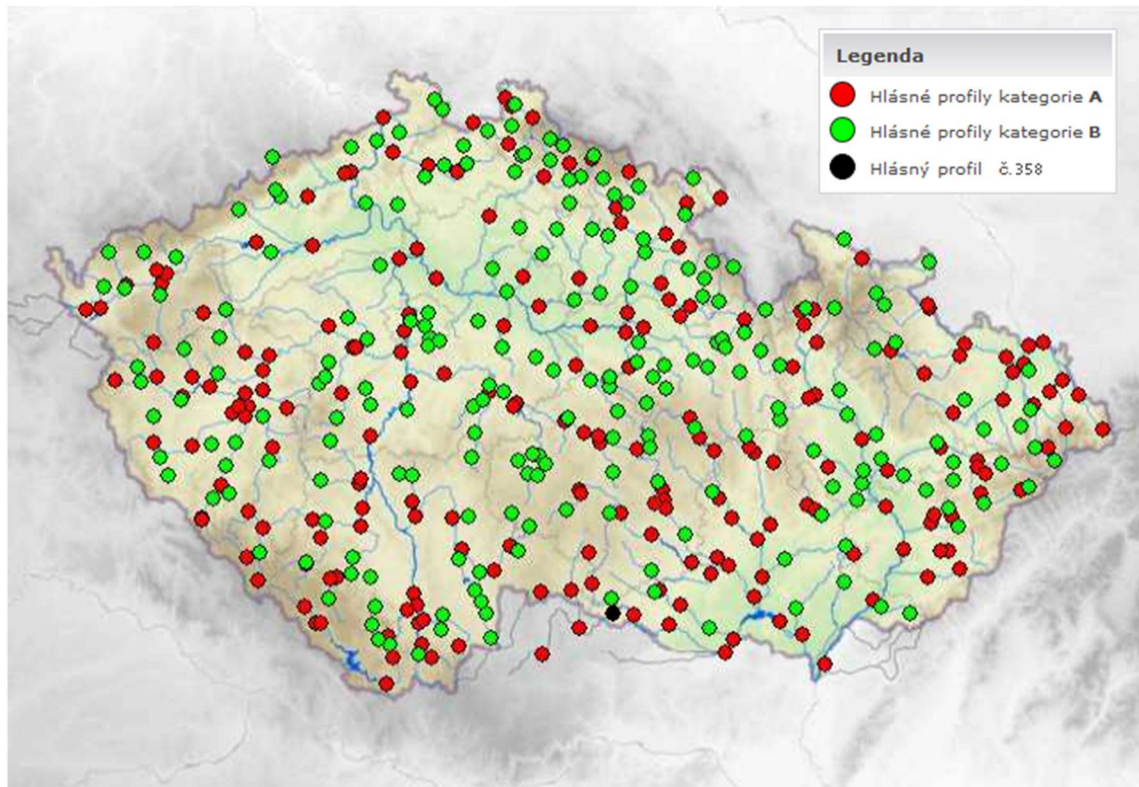
Data poskytnutá ze školní databáze byla získána z měrného profilu Podhradí nad Dyjí. Měrná stanice je umístěna na toku Dyje na 190,09 říčním km. Provozovatelem měrné stanice je ČHMÚ Brno. Plocha povodí nad tímto měrným profilem činí 1755,49 km<sup>2</sup>. Číslo hydrologického pořadí je 4-14-02-007. Měření bylo započato od roku 1935 až dodnes, a však jsou použita pouze do roku 2018. Rok 2019 zatím nebyl ucelený a schválen k poskytnutí. [Evidenční list hlásného profilu č.358]

V datech je zahrnut i přítok z vedlejší řeky Želetavky. Neboť není tak významným přítokem do vodní nádrže, je započten jako podíl přitékající vody z řeky Dyje. Tento podíl byl určen na 10 % z průtoku na řece Dyji. Při nízkých průtocích na Dyji, je i na Želetavce zanedbatelný průtok, proto byla celkově zanedbána z výpočtů pro stanovení předpovědních průtoků.


Na obrázku 10 jsou zobrazeny hlásné profily České republiky a jsou rozděleny do dvou kategorií:

- Kategorie A – hlásný profil zřizuje a provozuje stát prostřednictvím ČHMÚ nebo Povodí, s.p.
- Kategorie B – hlásný profil zřizuje krajský úřad a provozuje po dohodě ČHMÚ, Povodí, s.p. nebo místně příslušná obec





Obr. 11. Poloha měrné stanice (ČHMÚ, c2020)




Graf 1. Průtoková řada 2003–2018

## 7. Kalibrace

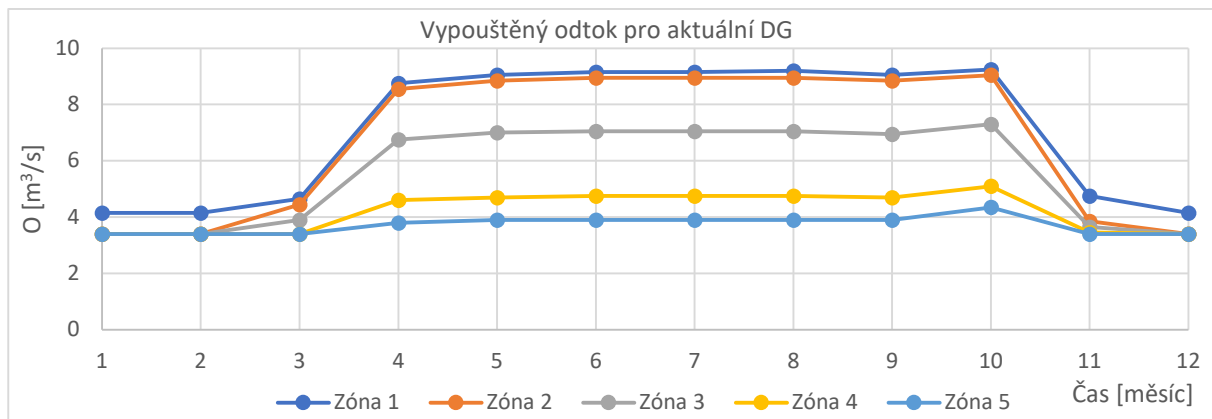
V této kapitole bude popsán postup sestavování a nastavování dispečerských grafů a předpovědního modelu.

### 7.1. Dispečerské grafy


Naměřená data se rozdělila na dvě části. Kalibrační data byla určena od roku 1935 do roku 2002. Zbylé roky 2003 až 2018 jsou zvoleny jako validační. Na kalibračních datech bylo provedeno řízení podle doporučených odtoků, které byly použity z manipulačního řádu Vranovské přehrady. Na tomto řízení byly zjištěny roky, které vytvářejí vnější obálku pro návrh dispečerského grafu. Dále byly převzaty minimální průtoky pro zachování toku Dyje pod vodní nádrží. Rozdíl mezi obálkou a minimálními průtoky byl rozdělen na rovnoměrný díl podle stanoveného počtu zón v dispečerském grafu. Tento počet byl předběžně stanoven na 6, aby byla dodržena podobnost podle dispečerského grafu z manipulačního řádu. Dále se vytvořila funkce pro simulaci řízení zásobního objemu v programu Microsoft Visual Basic. Tato funkce rozhoduje dle aktuálního stavu objemu odtok na další krok. Při následující kalibraci dispečerského grafu byly změněny přestupové objemy, které určují, jaký má být odtok z nádrže. Také byly upravovány jednotlivé hodnoty odtoků. Dále byli vytvořeny grafy pro vizualizaci DG, byli rozděleny na navrhovaný (DGN) a aktuální (DGA). Kdy DGA je nyní používán na vodním díle Vranov a navrhovaný byl řešen v této práci. Pro kontrolu množství vypuštěné vody byla nastavena funkce  $H_0$ , která udává relativní množství nedodané vody ve srovnání maximálním možným odtokem. DGA byl vytvořen na datech z let 1935–2010.




Graf 2. Odtok navrhovaný DG



Graf 3. Odtok aktuální DG




Graf 4. Zóny navrhovaného DG



*Graf 5. Zóny aktuálního DG*

## 7.2. Předpovědní model

Pro vytvoření předpovědí byl použit program Matlab a jeho simulační podprogram k simulování umělé neuronové sítě. Síť byla naprogramována na vytvoření tří vrstev neuronů, dvě vrstvy tvoří skryté neurony a třetí je výstupní. Data byla použita podle rozdělení do dvou skupin kalibrační (tréninková) od roku 1935 až po rok 2002. Roky 2003 až 2018 jsou použity k validaci. Za vstupní data byl určen průměr z 6 měsíců a 3 hodnoty průměrných měsíčních průtoků z předchozích měsíců. Jako převodní funkce byla použita funkce logaritmická sinusoida. V první skryté vrstvě je vloženo 15 umělých neuronů a ve druhé 8 neuronů, jak lze vidět na obrázku 11. V dalších krocích byl náhodně měněn počet neuronů ve vrstvách, a i samostatný počet vrstev byl testován od 3 do 5 vrstev. Pro hledání vhodného počtu částí v neuronové síti proběhlo srovnání reálných dat s předpovězenou řadou. K tomuto srovnání byla použita velikost odchylek mezi řadami a kontrola v oblasti suchých epizod, zda byla dodržena kolísavost průtoků. Výstupními data jsou podle délky předpovědi 1 až 3 předpovídané průtoky na následující měsíce. Neboť z výsledků kontroly odchylek bylo vidět nadhodnocování hodnot v suchých měsících, bylo stanoveno pravidlo, pokud je předpovězená hodnota menší než  $7 \text{ m}^3/\text{s}$ , tak dojde ke snížení této hodnoty  $2 \text{ m}^3/\text{s}$ .



Obr. 12. Grafické zobrazení neuronové sítě

### **7.3. Dispečerský graf s předpovědí**

Po vytvoření předpovědi z předpovědního modelu a kontrole výstupních dat. Jsou tato data vložena do simulace řízení. Řídící funkce byla upravena, tak aby od objemu odečetla předpokládané následující měsíční odtoky a přičetla předpovězené průměrné měsíční přítoky (předpověď). Podle výsledného objemu se určí budoucí zóna, pokud dojde ke změně zóny v DG použije se průměr z odtoků ze zóny aktuální a zóny určené. Hlavním úkolem funkce bylo určení kdy se má snížit vypouštěný odtok, aby bylo zachováno dostatečné množství zásobní vody i v dlouhodobě trvajícím suchu, a také když následovalo mokré období včasné vyprazdňování zásobního objemu pro přicházející vysoké průtoky. Dále byla rozšířena na předpovídání dle určeného počtu předpovědí. Z důvodu testování nejvhodnějšího počtu předpovídaných měsíců.

## 8. Validace

V kapitole jsou popsány konečné výsledky, které byly dosaženy nejvhodnějším nastavením výpočetních parametrů.

### 8.1. Dispečerské grafy

Jako nejvhodnější se ukázalo řízení se 6 zónami, které bylo již navrženo v dřívějším DG. Bylo ale upraveno rozdělení zón a také množství vypouštěné vody, tak aby došlo k lepšímu zachycení suchých období. Rozdělení zón a určené odtoky lze vidět na obrázcích 2 až 5 v kapitole 7. Vyhodnocovací funkce  $H_o$  a minimální zásobní objem byly využity k hodnocení funkčnosti řízení (tabulka 3).

$$H_o = \sum_{i=1}^n (O_{mi} - O_{ni})^2, \quad (8,1)$$

$O_m$  značí optimální nalepšený odtok a  $O_n$  označuje vypouštěný odtok.

Při poklesu přítoků o 10 % se projevilo, že řízení podle DGN je mnohem vhodnější, neboť mnohem lépe manipulovalo s nedostatkem vody.

### 8.2. Předpovědní model

Nejlépe dosažených předpovědí dosáhla neuronová síť se čtyřmi vrstvami a s rozdělenými neurony dle obrázku 12. Předpovědi byly vyhodnocovány pomocí pravidla  $H_n$ , které určuje rozdíl mezi předpovídaným průtokem a reálným průměrným měsíčním průtokem.


$$H_n = \sum_{i=1}^n (Q_{ri} - Q_{pi})^2 \quad (8,2)$$

$Q_r$  značí reálný přítok do nádrže a  $Q_p$  předpovězený přítok.

Výsledky kritéria  $H_n$  jsou znázorněny v tabulce 3.

Tabulka 3. - Hodnoty kritéria  $H_n$

	$H_n$		
	1. měsíc	2. měsíc	3. měsíc
sít se 3 vrstvami a rozdělením 15, 8 a 3	989,3434	966,8581	962,4544
sít se 4 vrstvami a rozdělením 20, 10, 5 a 3	924,4805	934,841	939,9459
sít se 4 vrstvami a rozdělením 20, 10, 5, 3 a zavedeným pravidlem	795,7369	847,0962	868,0936



Obr. 13. Nejvhodnější neuronová síť

### 8.3. Dispečerský graf s předpovědí

DG s předpovědí byl schopen dříve snížit průtoky před přicházejícím suchým obdobím a tím bylo dosaženo dostatečné zachování zásobního objemu.

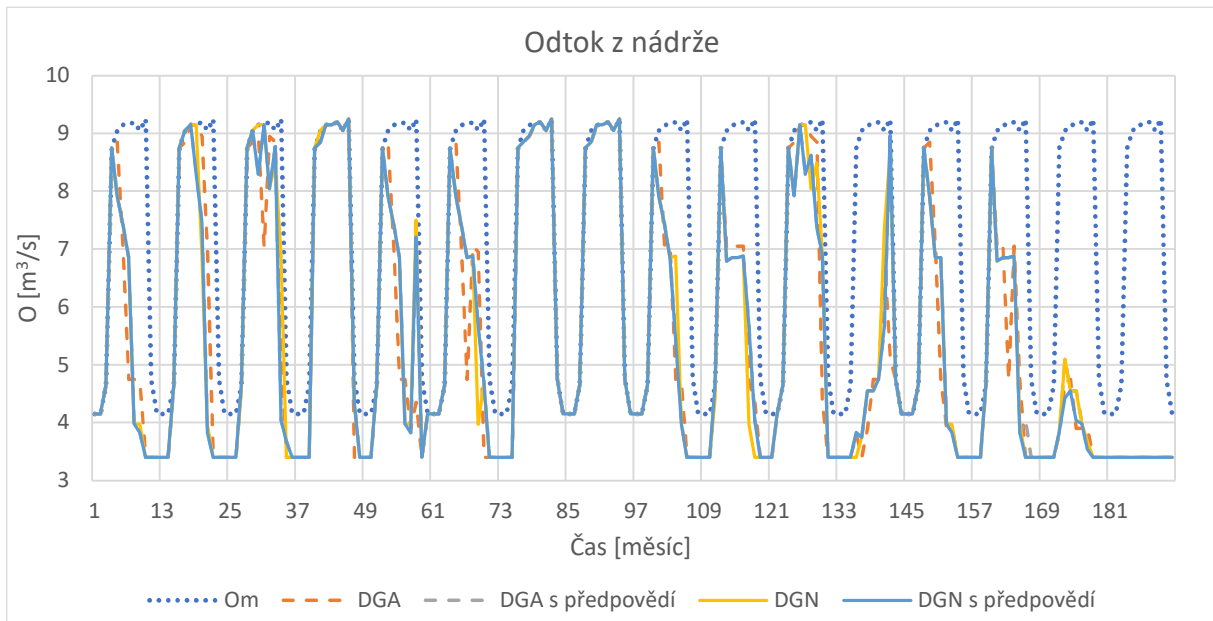
V následující tabulce jsou uvedeny hodnoty pro kritérium  $H_0$  a minimální hodnoty zásobního objemu vody v nádrži jsou značené jako Min. vody.

Tabulka 4. - Zhodnocení nedodané vody

	DGN		DGA	
	$H_0$	Min. vody	$H_0$	Min. vody
Bez předpovědi	2233,126	0,081426	2244,31	0,521426
S 1 měsícem	2208,67	0,536426	2239,167	1,021426
S 2 měsícem	2212,619	1,086426	2233,959	1,671426
S 3 měsícem	2239,732	1,351426	2172,145	1,221426

## 8.4. Grafy

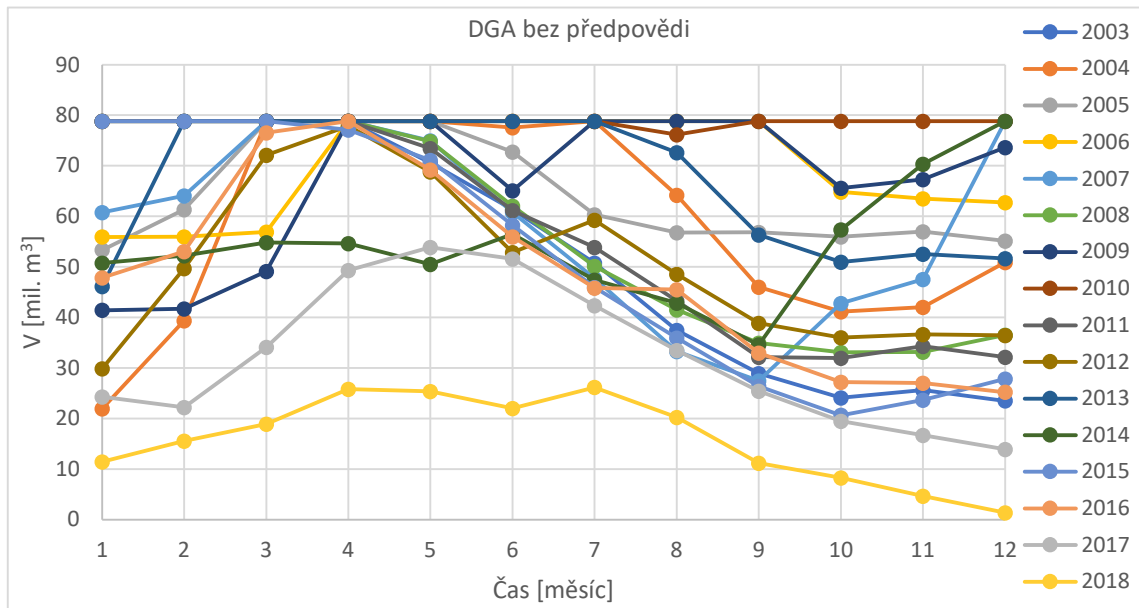
Následující graf znázorňuje průběh odtoků z nádrže během validačního období.



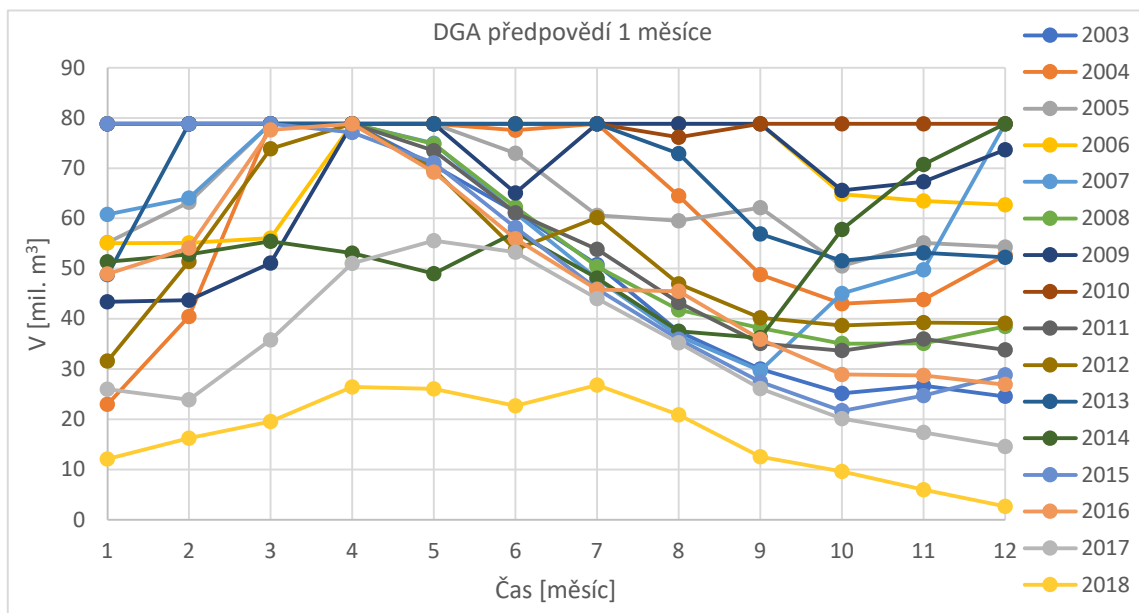
Graf 6. Odtok z nádrže

Na následujících grafech jsou znázorněny průběhy objemů ve validačním období, kde byla provedena kontinuální simulace řízení. Na ose  $x$  je měsíční krok a na  $y$  je objem vody v nádrži. Jednotlivé čáry značí samostatné roky. Popis platí pro grafy 7 až 14.

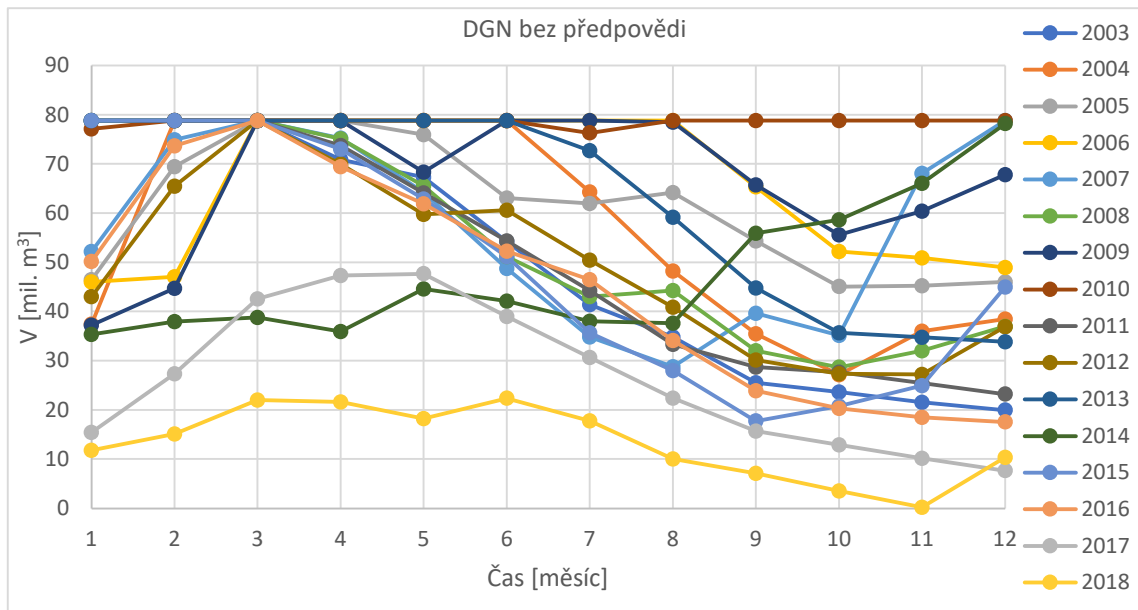




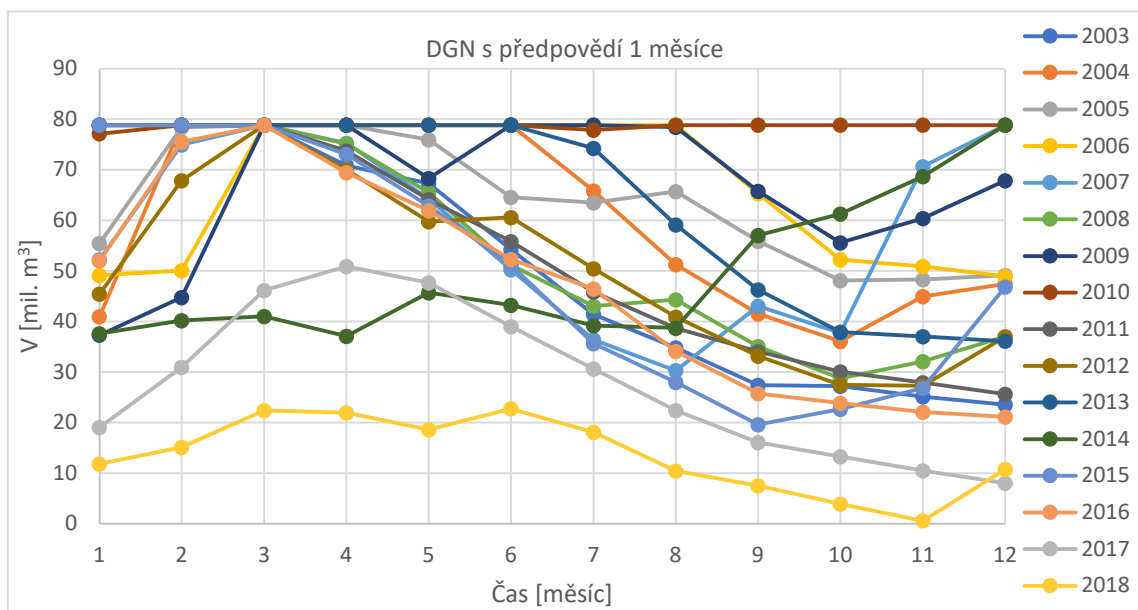
Graf 7. DGA bez předpovědi



Graf 8. DGA s předpovědi 1 měsíce




Graf 9. DGN bez předpovědi




Graf 10. DGN s předpovědí 1 měsíce

Na grafech lze vidět, sezónní změny objemu a poslední 2 roky velké snížení zásobního objemu z nedostatku vody. Při použití DGN dochází k lepšímu rozložení zásobního objemu vody a k jeho maximálnímu využití. Žádný z roků validačního období nezaznamenal úplné vyprázdnění tohoto objemu.


V dalším kroku proběhlo testování limitů DG a jejich kombinace. Testování proběhlo pomocí snížením přítoku vody o 10 %. Simulace řízení při tomto snížení, jsou znázorněny v následujících grafech. V některých letech bylo dosaženo úplnému vypuštění zásobního objemu.




Graf 11. DGA při snížení přítoku o 10 % bez předpovědi



Graf 12. DGA při snížení přítoku o 10 % s předpovědí 1 měsíce



Graf 13. DGN při snížení přítoku o 10 % bez předpovědi



Graf 14. DGN při snížení přítoku o 10 % s předpovědí 1 měsíce

## 9. Závěr

V rámci bakalářské práce byl vytvořen nový dispečerský graf pro vodní dílo Vranov. DGA byl vytvořen na datech z let 1935–2010, ale neobsahoval významně suchá období, která se projevovala v letech 2015 až 2018. DGN zahrnuje do řízení nová data z velmi suchých období, při kterých musel DGA žádat o mimořádné manipulační postupy. DGN zabránil poruchám při nedodávkách vody, a také snížil hodnotu nedodané vody s porovnáním maximálního možného vypouštění. Pro vyhodnocení DG bylo použito kritérium  $H_o$ , které stanovovalo sumou rozdílů druhých mocnin mezi řídicími odtoky a řízenými stanoveným pomocí řízení. Porovnání výsledků je zobrazeno v tabulce 3 a bylo provedeno pro roky 2003 až 2018.

Dále byl navržen předpovědní model pomocí neuronových sítí. Nejlepších výsledků dosahoval při nastavení 4 vrstev s rozdělením neuronů v počtu 20, 10, 5 a 3. Pomocí kritéria  $H_n$  aplikovaného na předpovědi a reálné přítoky bylo zjištěno, že tento model předpovídá suchá období s mírným nadhodnocováním a nevystihuje tak dostatečně budoucí průměrné měsíční průtoky. Tyto hodnoty bylo potřeba snížit navýšené hodnoty pomocí pravidla, které snižovalo hodnoty průtoků o  $2 \text{ m}^3/\text{s}$  od hodnot nižších než  $7 \text{ m}^3/\text{s}$ .

Byla použita kombinace DG s předpovědí pro řízení. Při této aplikaci bylo zjištěno, že nejvhodnější dle kritéria  $H_o$  je délka předpovědi 1 měsíc. Při použití delších předpovědí bylo dosaženo horších výsledků. Funkčnost této kombinace je značně omezena na přesnosti předpovědního modelu a počtu předpovídaných měsíců. Bylo by vhodné při budoucím sestavování DG uvažovat s předpovědním modelem, který by napomáhal určovat přicházející epizody suchých nebo mokrých období. Celkové použití kombinace DG s předpovědí dosahovala lepších výsledků než samostatné DG.

K otestování limitů řízení založených na DG a jejich kombinace s předpovědí, byli sníženy přítoky vody do nádrže o 10 %. Při snížení přítoků o 10 % nastalo při použití DGA k úplnému vypuštění zásobního objemu a tato porucha trvala několik měsíců. Při použití DGN k těmto poruchám došlo také, ale v mnohem menší míře pouze 1 měsíc byl poruchový. S použitím předpovědi se však povedlo snížení počtu poruch u DGN k úplnému bez poruchovému řízení a u DGA snížení poruch na 2 měsíce v letech 2003 až 2018. Bylo by vhodné uvažovat o zahrnutí předpovědí do manipulačních řádů

na vodních dílech a případný další výzkum s možností řízení dle DG s předpovědními modely. Při sestavování předpovědního modelu je potřeba mít dostatečné množství dat, aby došlo při používání neuronových sítí k dostatečnému natrénování (kalibraci).

Z dosažených výsledků řízení je patrné, že při pravděpodobném snížení průměrných měsíčních průtoků bude muset dojít k úpravám dispečerských grafů a k případnému vytvoření kombinací DG s předpověďmi. Případně se budou muset hledat další způsoby řízení, třeba samotné řízení neuronovými sítěmi.

## Seznam zkratk a symbolů

ACF...	Autokorelační funkce
ARIMA...	Autoregresní integrovaný klouzavý průměr
AR...	Autoregresivní proces
ARMA...	Autoregresivní proces klouzavých součtů
B-J...	Box-Jenkins
t...	Čas
$\Delta t$ ...	Časový krok
ČHMÚ...	Český hydrometeorologický ústav
i...	Číslo předpovědi
DG...	Dispečerský graf
DGA...	Dispečerský graf aktuální
DGN...	Dispečerský graf navrhovaný
$\Theta$ ...	Hodnota prahů
K...	Kritérium na snížení předpovídaného přítoku
Matlab...	Matrix laboratory
$\xi$ ...	Náhodně generované číslo od 0 do 1
X1, X2...	Náhodné veličiny
Op...	Nalepšený odtok vody
O <sub>n</sub> ...	Nalepšený odtok vypouštěný
O...	Odtok
V...	Objem vody
V <sub><math>\tau</math></sub> ...	Objem vody v nádrži za daný měsíc
O <sub>m</sub> ...	Optimálně nalepšený odtok
PCF...	Parciální autokorelační funkce

PACF...	Parciální autokorelační funkce
N...	Počet měsíců
$\tau$ ...	Pořadí časového kroku
j...	Pořadí měsíce
MA...	Proces klouzavých součtů
$\Omega$ ...	Prohledávaná oblast
$x_i$ ...	Průměr hodnot v předpovězeném měsíci
$Q_\tau$ ...	Průměrný měsíční průtok
$X_i$ ...	Průměrné měsíční průtoky
Q...	Průtok, přítok do nádrže
Y1, Y2...	Předpovězené veličiny
$Z_{i,j}$ ...	Předpovězený průměrný průtok
$Q_p$ ...	Předpovězený průměrný měsíční průtok
$Q_r$ ...	Reálný průměrný měsíční průtok
$a_1, a_2, a_3 \dots a_k \dots$	Regresní koeficienty
SAR...	Sezónní autoregresní proces
SMA...	Sezónní proces klouzavých průměrů
$s_j$ ...	Směrodatná odchylka předvídaného měsíce
SARMA...	Smíšené sezónní a nesezónní procesy
SARIMA...	Stacionarizovaný autoregresní integrovaný klouzavý průměr
↓ ...	Vstupní data
Ho...	Vyhodnocovací funkce dodaného množství vody
Hn...	Vyhodnocovací funkce podobnosti předpovědi s realitou
↑ ...	Výstupní data



## Použitá literatura

ČHMÚ, c2020. Hlásné profily. In: ČHMÚ [online]. Praha: ČHMÚ, 19.5.2020 [cit. 2020-05-19]. Dostupné z: [http://hydro.chmi.cz/hpps/hpps\\_main.php?kat=HLPRF](http://hydro.chmi.cz/hpps/hpps_main.php?kat=HLPRF)

Evidenční list hlásného profilu č.358, *Hlásná a předpovědní povodňová služba: Český hydrometeorologický ústav* [online]. [cit. 2020-05-13]. Dostupné z: [http://hydro.chmi.cz/hpps/hpps\\_prfbk\\_detail.php?seq=2505251](http://hydro.chmi.cz/hpps/hpps_prfbk_detail.php?seq=2505251)

MARTON, Daniel, Miloš STARÝ a Pavel MENŠÍK, 2015. Analysis of the influence of input data uncertainties on determining the reliability of reservoir storage capacity. *Journal of Hydrology and Hydromechanics* [online]. Sciendo, **63**(4), 287-294 [cit. 2020-06-04]. DOI: 10.1515/johh-2015-0036. Dostupné z: <https://doaj.org/article/2aa24eb357fb4018a9110c316aea27e3>

Dyje, 2001-. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 28. 3. 2020 [cit. 2020-05-18]. Dostupné z: <https://cs.wikipedia.org/wiki/Dyje>

HUSÁK, Vladimír, c2010-2020. VD Vranov: 2.část. In: *Povodí Moravy* [online]. Brno: Mapový podklad ČÚZK [cit. 2020-05-19]. Dostupné z: <http://www.pmo.cz/download/vranov2.pdf>

KOZEL, Tomáš, 2017. *Stochastické řízení zásobní funkce nádrže s pomocí metod umělé inteligence*. Brno, 131 s. Disertační práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce prof. Ing. Miloš Starý, CSc.

MAPY.CZ, 2020. Dyje. In: *Mapy.cz* [online]. Brno: Mapy.cz, 19. 5. 2020 [cit. 2020-05-19]. Dostupné z: <https://mapy.cz/zakladni?x=16.2936352&y=48.8300957&z=10&source=osm&id=143109918>

MAPY.CZ, 2020. Želetavka. In: *Mapy.cz* [online]. Brno: Mapy.cz, 19. 5. 2020 [cit. 2020-05-19]. Dostupné z:  
<https://mapy.cz/zakladni?x=15.6353004&y=49.0600463&z=11&source=osm&id=1017114866>

MATLAB, 2001-. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 13. 4. 2020 [cit. 2020-05-20]. Dostupné z:  
<https://cs.wikipedia.org/wiki/MATLAB>

NACHÁZEL, Karel, Jiří ZEŽULÁK a Miloš STARÝ, 2004. *Využití metod umělé inteligence ve vodním hospodářství*. Praha: Academia, 318 s. Česká matice technická (Academia). ISBN 80-200-0229-4.

Povodí Moravy, s.p., 2018. *Informační brožura o Vranovské přehradě.: Vodní dílo Vranov*. Dřevařská 11, 602 00 Brno.

STARÝ, Miloš, 2005. *Hydrologie: Modul 01*. Brno: Vysoké učení technické v Brně, Fakulta stavební.

STARÝ, Miloš, 2006. *Nádrže a vodohospodářské soustavy: Modul 02*. Brno: Vysoké učení technické v Brně, Fakulta stavební.

VOLNÁ, Eva, 1998. *Neuronové sítě a genetické algoritmy*. Ostrava: Ostravská univerzita. ISBN 80-704-2762-0.

Neuron, 2001-. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 12. 5. 2020 [cit. 2020-05-19]. Dostupné z:  
<https://cs.wikipedia.org/wiki/Neuron>

Vranovská přehrada: Jak vzniklo toto vodní dílo, c2012. In: *Vranovsko.cz* [online]. Vranov nad Dyjí [cit. 2020-05-19]. Dostupné z: <http://www.vranovsko.cz/vranovska-prehrada-jak-vzniklo-toto-vodni-dilo/>

ZATLOUKAL, Radomír, 2008. *Analýza a předpověď časových řad pomocí statistických metod se zaměřením na metodu Box-Jenkins*. Brno, 51 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství. Vedoucí práce RNDr. Libor Žák Ph.D.

Želetavka, 2001-. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 26. 11. 2019 [cit. 2020-05-18]. Dostupné z: <https://cs.wikipedia.org/wiki/%C5%BDeletavka>

## Seznam obrázků

Obr. 1.	Schéma nádrže (Kozel,2017) .....	15
Obr. 2.	Biologický neuron (Neuron, 2001) .....	22
Obr. 3.	Umělý neuron (Nacházel,2004) .....	23
Obr. 4.	Umělá neuronová síť (Nacházel, 2004) .....	24
Obr. 5.	Program Matlab .....	26
Obr. 6.	Zobrazení hloubky v nádrži (Husák, c2010-2020) .....	27
Obr. 7.	Plánek přehrady (Vranovská přehrada, c2012).....	29
Obr. 9.	Řeka Dyje (Mapy.cz, 2020).....	30
Obr. 10.	Řeka Želetavka (Mapy.cz, 2020).....	31
Obr. 11.	Poloha měrné stanice (ČHMÚ, c2020) .....	33
Obr. 12.	Grafické zobrazení neuronové sítě .....	36
Obr. 13.	Nejvhodnější neuronová síť .....	39

## Seznam grafů

Graf 1.	Průtoková řada 2003–2018.....	33
Graf 2.	Odtok navrhovaný DG .....	35
Graf 3.	Odtok aktuální DG.....	35
Graf 4.	Zóny navrhovaného DG.....	35
Graf 5.	Zóny aktuálního DG.....	36
Graf 6.	Odtok z nádrže .....	40
Graf 7.	DGA bez předpovědi .....	41
Graf 8.	DGA s předpovědí 1 měsíce .....	41
Graf 9.	DGN bez předpovědi .....	42
Graf 10.	DGN s předpovědí 1 měsíce .....	42
Graf 11.	DGA při snížení přítoku o 10 % bez předpovědi.....	43
Graf 12.	DGA při snížení přítoku o 10 % s předpovědí 1 měsíce.....	43
Graf 13.	DGN při snížení přítoku o 10 % bez předpovědi .....	44
Graf 14.	DGN při snížení přítoku o 10 % s předpovědí 1 měsíce .....	44

## Seznam tabulek

Tabulka 1. - Schéma tréninkové matice (Nacházel, 2004).....	24
Tabulka 2. - Rozdělení prostoru v nádrži .....	29
Tabulka 3. - Hodnoty kritéria Hn.....	39
Tabulka 4. - Zhodnocení nedodané vody.....	39