



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STAVEBNÍ

FACULTY OF CIVIL ENGINEERING

## ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

INSTITUTE OF LANDSCAPE WATER MANAGEMENT

# ŘÍZENÍ ZÁSOBNÍ FUNKCE NÁDRŽE S VYUŽITÍM METOD UMĚLÉ INTELIGENCE

CONTROL OF THE RESERVOIR STORAGE FUNCTION USING ARTIFICIAL  
INTELLIGENCE METHODS

## DIPLOMOVÁ PRÁCE

DIPLOMA THESIS

## AUTOR PRÁCE

AUTHOR

Bc. Matěj Hon

## VEDOUCÍ PRÁCE

SUPERVISOR

Ing. TOMÁŠ KOZEL, Ph.D.

BRNO 2022



## VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STAVEBNÍ

<b>Studijní program</b>	NPC-SIV Stavební inženýrství – vodní hospodářství a vodní stavby
<b>Typ studijního programu</b>	Navazující magisterský studijní program s prezenční formou studia
<b>Specializace</b>	bez specializace
<b>Pracoviště</b>	Ústav vodního hospodářství krajiny

## ZADÁNÍ DIPLOMOVÉ PRÁCE

<b>Student</b>	Bc. Matěj Hon
<b>Název</b>	Řízení zásobní funkce nádrže s využitím metod umělé inteligence
<b>Vedoucí práce</b>	Ing. Tomáš Kozel, Ph.D.
<b>Datum zadání</b>	31. 3. 2021
<b>Datum odevzdání</b>	14. 1. 2022

V Brně dne 31. 3. 2021

---

doc. Ing. Daniel Marton, Ph.D.  
Vedoucí ústavu

---

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



## PODKLADY A LITERATURA

- Starý, M.: Nádrže a vodohospodářské soustavy, skriptum, FAST VUT Brno, 2006
- Starý, M.: Hydrologie, skriptum, FAST VUT Brno, 2005
- Starý, M. Nádrže a vodohospodářské soustavy. Metodické návody do cvičení. 1. vyd. Brno: VUT, 1987. 67 s.
- Starý, M. Nádrže a vodohospodářské soustavy. 1. vyd. Brno: VUT, 1986. 165 s.
- Nacházel, K., Starý, M., Zezulák, J.: Využití metod umělé inteligence ve vodním hospodářství, Academia, nakladatelství Akademie věd České republiky, Praha 2004, ISBN 80-200-02229-4.

## ZÁSADY PRO VYPRACOVÁNÍ

Student sestaví algoritmus pro řízení zásobní funkce u vybrané reálné nádrže s využitím některé z metod umělé inteligence. Ve vlastním algoritmu řízení budou zohledněny zásoby vody ve sněhu nad vybranou nádrží. Dále provede vyhodnocení dosažených výsledků. Samotné výsledky algoritmu budou porovnány s výsledky řízení dosažených s využitím metody dispečerských grafů.

## STRUKTURA DIPLOMOVÉ PRÁCE

VŠKP vypracujte a rozčleňte podle dále uvedené struktury:

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

---

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

## **ABSTRAKT**

Práce se zabývá předpovídáním průtoků s využitím umělé inteligence pro řízení zásobní funkce nádrže. Zaměřuje se na řízení dispečerskými grafy v kombinaci s předpovědí průtoků. Práce je rozdělena na metodickou část a část aplikace. Aplikací část obsahuje předpovědi průtoků a řízení s předpovědí. Pro předpověď průtoků je používán předpovědní model založený na fuzzy metodě. Dále je zde popsáno, jak probíhalo získání historických dat, popis práce dispečerských grafů a předpovědních modelů. V další části je popsána kalibrace a validace předpovědního modelu. V závěru jsou popsány dosažené výsledky předpovědního modelu, dispečerského grafu s předpovědí a porovnání předpovědní fuzzy modelu a neuronové sítě. Podle dosažených výsledků lze výzkum předpovědních modelů s využitím umělé inteligence doporučit k dalšímu výzkumu.

## **KLÍČOVÁ SLOVA**

Vodní nádrž, zásobní objem, deterministické řízení, zonální model, dispečerský graf, předpověď průtoků, fuzzy model, fuzzy logika

## **ABSTRACT**

The diploma thesis deals with flow prediction using artificial intelligence to control the storage function of the reservoir. It focuses on the control of storage function using combination of dispatching graphs and flow prediction. The work is divided into a methodological part and an application part. The methodological part contains describes how the acquisition of historical data, a description of the work of dispatching graphs and forecasting models. The application part contains flow forecasts and outflow control. A prediction model is based on the fuzzy method, and it is used to predict inflows. The calibration and validation of the prediction model is also described. Results of prediction model were evaluated. In next step the results of control method were evaluated and compared with result of dispatching graphs. The results of controlled method were satisfactory.

## **KEYWORDS**

Water reservoir, storage volume, deterministic control, zonal model, dispatcher graph, prediction of flow, fuzzy model, fuzzy logic

## **BIBLIOGRAFICKÁ CITACE**

Bc. Matěj Hon *Řízení zásobní funkce nádrže s využitím metod umělé inteligence*. Brno, 2022. 69 s., 69 s. příl. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Tomáš Kozel, Ph.D.

## **PROHLÁŠENÍ O SHODĚ LISTINNÉ A ELEKTRONICKÉ FORMY ZÁVĚREČNÉ PRÁCE**

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

V Brně dne 10. 1. 2022

---

Bc. Matěj Hon  
autor práce

## **PROHLÁŠENÍ O PŮVODNOSTI ZÁVĚREČNÉ PRÁCE**

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

V Brně dne 10. 1. 2022

---

Bc. Matěj Hon  
autor práce

### **PODĚKOVÁNÍ:**

Poděkování patří zejména vedoucímu diplomové práce Ing. Tomášovi Kozlovi, Ph.D. za odborné vedení, cenné rady a velmi ochotný přístup, jak při tvorbě této práce, tak i během studia. Také děkuji všem mým blízkým za podporu a trpělivost při studiu a ohleduplnosti při tvorbě diplomové práce.

## OBSAH

<b>1. Úvod.....</b>	<b>11</b>
<b>2. Cíl práce .....</b>	<b>13</b>
<b>3. Metody .....</b>	<b>14</b>
<b>3.1. Simulace řízení.....</b>	<b>14</b>
3.1.1. Chování nádrže.....	14
<b>3.2. Metody řízení .....</b>	<b>15</b>
3.2.1. Dispečerské grafy .....	15
<b>3.3. Předpovědní modely – Matematické modely .....</b>	<b>17</b>
3.3.1. Stochastické modely.....	17
3.3.2. Deterministické modely .....	17
<b>3.4. Metody umělé inteligence.....</b>	<b>21</b>
3.4.1. Neuronové sítě .....	21
3.4.2. Fuzzy metody .....	22
3.4.3. Postup fuzzy modelu .....	24
3.4.4. Použitý software .....	26
<b>3.5. Hodnotící kritéria .....</b>	<b>28</b>
3.5.1. Relativní střední kvadratická chyba (RMSE).....	28
3.5.2. Koefficient determinace ( $R^2$ ).....	28
<b>4. Aplikace .....</b>	<b>29</b>
<b>4.1. Získání dat.....</b>	<b>29</b>
4.1.1. Vodní dílo Vranov.....	29
4.1.2. Měrný profil.....	32
<b>4.2. Dispečerský graf .....</b>	<b>35</b>
<b>4.3. Předpovědní model.....</b>	<b>37</b>

4.3.1.	<i>Zonální výběr</i> .....	37
4.3.2.	<i>Fuzzy model</i> .....	38
<b>4.4.</b>	<b>Řídící modul</b> .....	<b>38</b>
<b>5.</b>	<b>Kalibrace</b> .....	<b>40</b>
<b>5.1.</b>	<b>Předpovědní model</b> .....	<b>40</b>
5.1.1.	<i>Zonální výběr dat</i> .....	40
5.1.2.	<i>Fuzzy model</i> .....	41
<b>6.</b>	<b>Validace</b> .....	<b>43</b>
<b>6.1.</b>	<b>Předpovědní model</b> .....	<b>43</b>
6.1.1.	<i>Zonální výběr dat</i> .....	43
<b>6.2.</b>	<b>Fuzzy model</b> .....	<b>44</b>
<b>6.3.</b>	<b>Tání sněhu</b> .....	<b>52</b>
<b>6.4.</b>	<b>Řídící modul</b> .....	<b>54</b>
<b>6.5.</b>	<b>Porovnání fuzzy metody a neuronových sítí</b> .....	<b>56</b>
<b>7.</b>	<b>Závěr</b> .....	<b>59</b>
	<b>Seznam zkratk a symbolů</b> .....	<b>62</b>
	<b>Použitá literatura</b> .....	<b>64</b>
	<b>Seznam obrázků</b> .....	<b>67</b>
	<b>Seznam grafů</b> .....	<b>68</b>
	<b>Seznam tabulek</b> .....	<b>69</b>



## 1. Úvod

V posledních letech se výrazně začíná projevovat globální změna klimatu na vodních nádržích, a proto je nezbytné počítat i s periodami, které mohou překonat historická maxima. A to jak s extrémními suchy, nebo povodněmi, tak i s velmi intenzivními dešti. V letech 2017 a 2018, kdy bylo na jižní Moravě velmi málo sněhu, nebylo možné lokálně využít zásoby podzemní vody. V budoucnu bude pravděpodobně docházet k velkému snížení podzemních vod, proto budeme nuceni přejít na vody povrchové.

S ohledem na samotnou pozici České republiky, kdy na naše území nepřítéká žádná řeka, je potřeba si zde spadlou vodu co nejdéle udržet. A to prostřednictvím stávajících vodních nádrží pomocí úpravy manipulace nebo použití manipulace s předpovědí přítoků, tak i výstavbou dalších menších vodních nádrží. Právě proto by měl být objem dostatečně velký pro transformaci povodňové vlny, a také by měl mít dostatek naakumulované vody v zásobním prostoru pro období sucha. Naakumulovaná voda by měla být v dostatečné kvalitě, aby ji bylo možné jímat pro obyvatelstvo, případně mohla být využita pro zavlažování v zemědělství.

Způsoby řízení na vodních dílech mohou být různé. V České republice jsou používány pro řízení zásobní funkce dispečerské grafy. Hlavní dva typy řešení udávají směr dalších metod, těmito typy jsou stochastické a deterministické metody. Dále se rozhoduje podle velikosti zázemí, tedy jaké jsou možnosti výpočetní techniky a celkové délky historické řady nebo tvorby umělé průtokové řady. Jednotlivé možnosti jsou různými autory testovány na modelech vodních nádrží. Veškeré výpočty a modely jsou zjednodušeny, jelikož ve skutečnosti je množství všech proměnných nepřehledné, a tak se mnohdy celkový model zužuje pouze na přítok do nádrže a odtok z nádrže.

V práci je používán dispečerský graf. Toto řízení vodních nádrží je velkým zjednodušením pro samotnou manipulaci. Sestavení dispečerského grafu je velmi závislé na historických datech, nebo na simulaci umělých průtokových řad. Pokud dochází ke změně klimatu, potom také dochází ke změně průběhu průtoku během roku, a tedy i ke změnám, které se z historických dat nedají příliš odhadnout. V několika následujících letech bude nutné upravit používané dispečerské grafy, aby zvládaly průběh budoucích změn.

Dispečerské grafy pracují na základě určení vypouštěného objemu vody během celého měsíce podle stavu hladiny, nebo objemu vody v nádrži. Odtok je rozdělen do několika zón, které byly sestaveny dle historických dat tím způsobem, aby při průchodu povodní nebo suchém období probíhal bez poškození vodního díla nebo omezení dodávek vody pro obyvatele. Z důvodu použití zón pro stanovení odtoků je tedy možné nazývat dané dispečerské grafy zonálními modely. V práci používaný dispečerský graf je rozdělen do 5 zón. Pro některé měsíce mají tyto zóny stejný odtok, protože v těchto měsících není možné vypouštět větší objemy vody.

S ohledem na vývoj klimatických změn je snaha o kvalitnější řízení. To by mohlo být dosaženo lepším určování dispečerské zóny. K tomu lze využít předpovědi průtoků. Kvalitní předpovědi zamezí nadměrnému vypouštění vody nebo přelití bezpečnostních přelivů při povodni.

K tvorbě předpovědí je možné využít různé metody předpovědních modelů. V bakalářské práci *Řízení zásobní funkce nádrže* (Hon, 2020) byl použit předpovědní model založený na neuronových sítích, který napodobuje fungování biologických neuronů k předávání informací. V této práci bude použit fuzzy model, který využívá rozdělení průtoků do zonálního modelu podle historických průtokových řad. Pomocí těchto zón pak dále určuje budoucí průtoky. Více o fuzzy modelu bude rozebráno dále v této práci. V rámci práce bude testována možnost kombinace dispečerského grafu a předpovídaných přítoků do nádrže. Tento způsob řízení by mohl být využíván pro budoucí průběhy průtoků, které jsou pozměněny vlivem klimatických změn.

Pro zkoumání funkčnosti předpovědního modelu s dispečerským grafem bylo vybráno vodní dílo Vranov, a to zejména kvůli dostupnosti měřených historických dat a vlivu změny klimatu na jižní Moravě. Toto vodní dílo je 7. největším vodním dílem v České republice. Nachází se v blízkosti obce Vranov nad Dyjí, která je v okrese Znojmo na jižní Moravě. Jižní Morava byla zasažena vlivem klimatických změn, které způsobily prodloužení suchých období. Ty ukázaly, že manipulace podle dispečerského grafu na vodním díle Vranov jsou zatím dostačující, ale s možným vývojem klimatu do budoucna je lze považovat za nedostatečné. Využitím dispečerského grafu s předpovědním modelem by mohlo dojít ke zlepšení. Je tedy vhodné zkoumat možnosti předpovědních modelů a úpravy dispečerských grafů pro vývoj změn klimatu.

## 2. Cíl práce

Cílem této práce je vytvoření metody využívající dispečerského grafu a uvažující jarní tání sněhu, a také bude aplikován předpovědní model. Předpovědní model bude vytvořen pomocí učící se fuzzy metody. Metoda bude testována na letech 2007-2020. Dále bude provedeno porovnání předpovědí s předpověďmi, které byly stanoveny v bakalářské práci *Řízení zásobní funkce nádrže* (Hon, 2020) za pomoci neuronových sítí.

## 3. Metody

### 3.1. Simulace řízení

Simulace byla prováděna na základě chování nádrže, podle které jsou sestavovány dispečerské grafy z historických průtokových řad. Samostatné sestavování dispečerského grafu je tvořeno různými stochastickými metodami, které nyní zohledňují pouze jednoleté cykly. Takto vytvořené grafy je potřeba po nějaké době aktualizovat na nová data získaná z dalšího postupného měření. Také by bylo vhodné přejít na víceleté řízení, které zohlední vliv dřívějších let na přicházející suché období nebo již velmi nasycenou zeminu v okolí nádrže před přicházející povodní, která by neměla prostor pro zasáknutí části přitékající vody. Proto je potřeba, co nejlépe nastavit vypouštění vody z nádrže, aby byl zajištěn prostor pro povodeň nebo bylo zaručeno dostatečné množství vody pro obyvatelstvo během období sucha. S ohledem na vývoj předpovědních modelů a celkově výpočetní techniky je využíváno možnosti sestavování víceletých řídicích dispečerských grafů s použitím předpovědí.

#### 3.1.1. Chování nádrže

Pro zjištění funkčnosti řídicího modelu byl vytvořen skript v Matlabu se simulací řízení. Byl tedy sestaven nový dispečerský graf, který lépe reaguje na přicházející změny průtoku.

„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 nalepšený 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  $V_\tau$ ,  $\tau$  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.



Obr. 1. Schéma nádrže (Kozel, 2017)

Chování nádrže je možno popsat základní rovnicí nádrže 3.1.

$$Q^\tau - O^\tau = \frac{V^\tau - V^{\tau-1}}{\Delta t}, \quad (3.1).$$

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.“ (Hon, 2020, s. 14)

## 3.2. Metody řízení

V práci bylo pro simulaci řízení použito řízení podle dispečerského grafu. K sestavování a optimalizaci řízení byly použity optimalizační metody, které jsou již dříve popsány v práci Hon, 2020.

### 3.2.1. Dispečerské grafy

Dispečerské grafy jsou používány na všech vodních dílech na území České republiky. Jejich jednoduchost spočívá v jednoznačném řízení pro dané objemy v nádrži, které udávají doporučené množství vypouštěné vody z této nádrže. Objemy jsou rozděleny do několika zón. Počet zón je určen dle velikosti nádrže. Velikost jednotlivých zón je rozdělena podle opakování epizod v daných měsících. Zahrnují tak možnosti suchých období v letních měsících, ale také i jarní tání sněhu, které doplňuje nádrž obvykle do plného stavu a v některých případech tvoří i povodňové epizody. Pro

sestrojení dispečerského grafu se využívají dlouhodobé průtokové řady z měrných profilů před vodními díly nebo uměle vytvořené.

S přihlédnutím na vývoj klimatu, je vhodné počítat s delšími obdobími sucha, která budou přicházet. A potom tedy střídání dlouhého sucha a povodňových epizod.

Samotná komplikovanost sestrojění dispečerského grafu je dána množstvím zohledněných proměnných, kterými jsou průsaky hrází, vypařování vody z nádrže, plocha sběrného povodí toků a plocha povodí nádrže. Pro zjednodušení se uvažuje pouze přítok do nádrže samostatnými toky a pouze výtok výpustěmi. Ostatní proměnné jsou zanedbány. Tímto zjednodušením dostaneme charakteristickou čáru překročení, která udává kolik objemu vody nebo jaká výška hladiny má být optimálně během každého měsíce. Čára překročení je obálkou všech historických průtoků na nádrži. Což při jejím překročení znamená, že obsluha na vodním díle může vypustit přebytečnou část objemu z nádrže. Pokles objemu pod čáru neznámá nutně závažnou poruchu v nedodávce vody pro odběratele, ale může být náznakem přicházejícího suchého období. V práci budou použity konstrukce DG dle skript Metodické návody k vodohospodářským řešením nádrží. (Broža, 1981)

Dispečerský graf je převzatý z manipulačního řádu vodní nádrže Vranov, ke kterému byla poskytnuta data průběhu průtoku pro posledních 85 let. Dispečerský graf musel být aktualizován podle nových dat.

### **3.3. Předpovědní modely – Matematické modely**

Matematické modely jsou zjednodušením reálného světa pro výpočetní techniku, která je v současnosti hojně využívána. Tyto modely obsahují soustavy funkcí, rovnic a koeficientů, které společně udávají hledané hodnoty daných problémů.

Dále se tyto modely dělí na lineární a nelineární, které rozlišují stav linearity samostatných funkcí. Deterministické a stochastické, tyto modely jsou popsány dále v práci. A statické a dynamické, které rozlišují zaměření na čas. (Hřebíček, 2017)

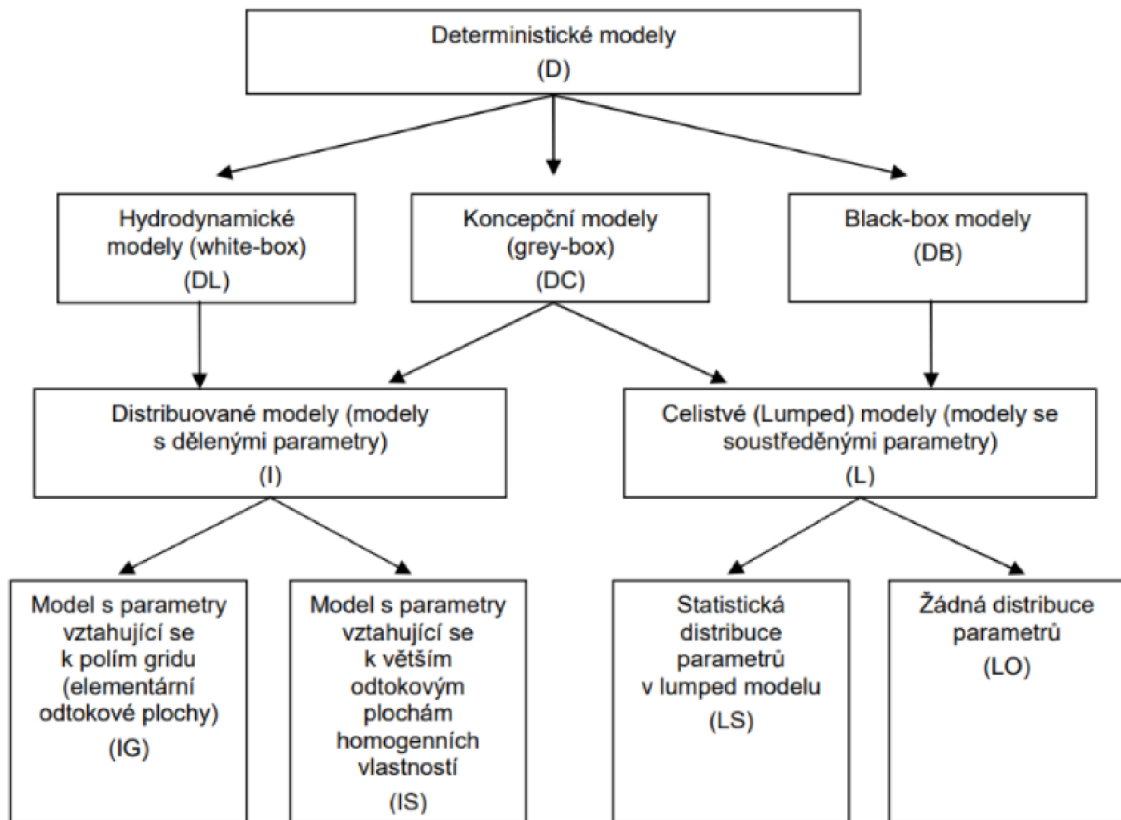
#### **3.3.1. Stochastické modely**

Stochastické modely jsou založeny na určování vypouštěného průtoku podle pravděpodobnostního rozdělení založeného na historických řadách. Je tedy pravděpodobné, že může docházet ke špatnému určení pravděpodobnosti nebo špatnému zařazení průtoku, který je dle historické řady málo obvyklý. K určení a testování pravděpodobnosti je potřeba dostatečně velká výpočetní kapacita, která je schopna rychle opakovat stejné kroky.

#### **3.3.2. Deterministické modely**

Deterministické modely na rozdíl od stochastických nejsou zaměřeny na principu pravděpodobnosti, a tedy neudávají ve výstupních veličinách rozptyl. Jsou většinou závislé na jedné nebo na více vstupních proměnných. Podle těchto proměnných je pak většinou vytvořena rovnice nebo soustava rovnic, která udává výstupní veličinu nebo veličin několik.

Ve vodním hospodářství se deterministické modely využívají pro řízení na vodních dílech. Využíván je zejména zonální model, se kterým se setkáme na všech vodních dílech u nás.



Obr. 2. Rozdělení deterministických modelů (Přeslička, 2012)

### 3.3.2.1. Arima

Metoda Arima s sebou nese několik problémů, jako je vytváření trendů, odchýlení pozorování, sezónnost a mnoho dalších. Tyto problémy lze identifikovat při tvorbě grafu časové řady. Lze jim však předejít vhodnou úpravou na stacionární řadu, nebo také linearizací časové řady, anebo použitím logaritmické transformace. Tyto úpravy mohou mít za následek výskyt záporných hodnot. Transformace má být prováděna před diferencováním časové řady. (Zatloukal, 2008)

### 3.3.2.2. Sarima

Metoda Sarima je identifikována výskytem sezónní složky v časové řadě. Při stanovení použití tohoto modelu je nutné časovou řadu linearizovat logaritmickou transformací. Sezónní výchyly v časové řadě pak indikují tvar výběrové funkce. Ta je charakteristická svou vysokou hodnotou v nesezónní frekvenci. Z výběrových funkcí je potom stanoven typ sezónního modelu a dále je z nich vypočtena hodnota rezidua sezónního modelu. Rozhodne se, zda je potřeba dodat do modelu další složky pro autoregresní proces. Vlivem výchyly výběrových funkcí je možné stanovit pouze odhad



typu a řádu procesu ve složkách. Před stanovením modelu je zkoušeno více nastavení, aby bylo možné statisticky vybrat vhodné nastavení, a i samostatný model. (Zatloukal, 2008)

### 3.3.2.3. Lineární autoregresivní model

Tento model předpoví budoucí měsíční průtoky z lineární kombinace hodnot z předchozích měsíců, autoregresivních koeficientů a náhodných čísel. Autoregresivní koeficienty vychází z Yule-Walkerovy rovnice (Yule, Walker, 1927, 1931). Jednotlivé dvojice koeficientů a transformovaných průtoků se dosazením do rovnice (3.2) určí předpovídaný měsíční průtok. K výpočtu předpovídaných průtoků se zpětně použije daný počet měsíců, a poté se vyhodnotí samotné předpovídané měsíce podle počtu požadovaných měsíců. Při předpovědi delší jak 1 měsíc se výpočet posune o jeden krok a opakuje se. S tímto posunem dojde k začlenění předpovídaných měsíců do výpočtu.

Prvotní rovnice lineárního autoregresivního modelu:

$$Z_{i,j} = a_1 * Z_{i,j-1} + a_2 * Z_{i,j-2} + a_3 * Z_{i,j-3} + \dots + a_k * Z_{i,j-k}, \quad (3.2),$$

$Z_{i,j}$  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)

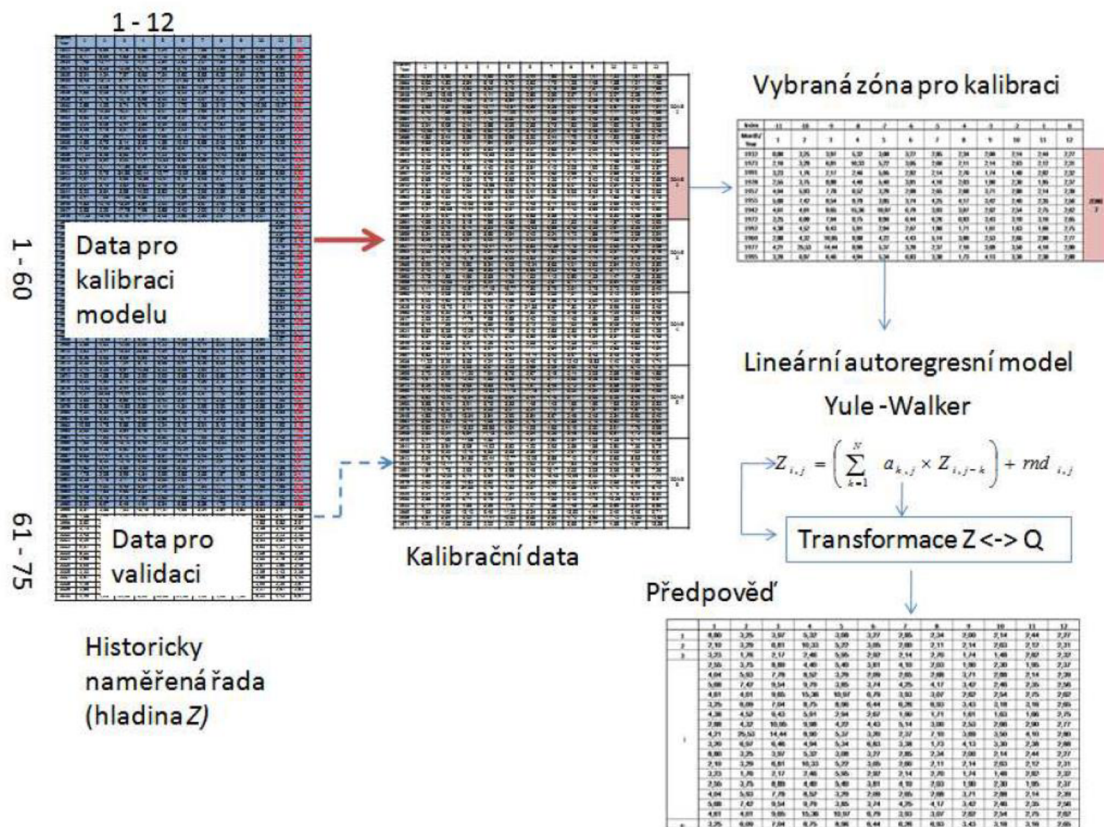
### 3.3.2.4. Zonální model

Pro vytvoření zonálního modelu je potřeba mít naměřené historické průtokové řady pro jednotlivé měsíce, pro které chceme vytvářet předpověď. Tato data jsou rozdělena podle měsíců, a pak seřazena podle jejich hodnot. Takto seřazená data se rozčlení do zón. Nastavení zón lze určovat podle požadavků na pevně daný počet zón nebo na pevně daný počet prvků v zónách s poslední proměnnou zónou. Takto jsou vytvořeny úseky určující pracovní oblast měsíčních průtoků, tedy zóny v modelu. Ostatní data, která se neváží k danému měsíci, nejsou použita. Vzhledem k nerovnoměrnému rozdělení průtoků v zónách musí dojít k úpravě asymetrie průtoků a k vytvoření trojúhelníkového rozdělení. V místech s malým výskytem průtoků dojde k doplnění průtoků o modus z průtoků. Výhodou tohoto doplnění je, že doplněné průtoky jsou spojeny s reálnou řadou z historických dat. (Kozel, 2017)

Model vznikl 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).

### 3.3.2.5. Modifikovaný zonální model

Tento model je podobný jako zonální model. Také jsou zde historická data rozdělena do zón pro jednotlivé měsíce. Na rozdíl od normálního zonálního modelu je však využito lineárního regresního modelu ve vybraných zónách. Dále jsou průtoky upraveny a převedeny do hladiny Z. Průtoky se rozdělí pro hledané měsíce podle posledního naměřeného průtoku. Z historických dat je vypočtena korelační matice, která je dále dosazena do Yule-Walkerových rovnic. Do matice nejsou zahrnuta data mimo právě používanou zónu, tedy nejsou v korelační matici. Z Yule-Walkerových rovnic jsou spočteny regresní koeficienty. Postup je dále obdobný jako u lineárně autoregresního modelu. (Kozel, 2017)




Obr. 3. Schéma modifikovaného zonálního modelu (Kozel,2017)

### 3.4. Metody umělé inteligence

#### 3.4.1. Neuronové sítě

Umělé neuronové sítě se vyznačují velkou podobností s biologickými přirozenými neuronovými sítěmi. Jejich významným znakem je schopnost okamžitého rozeznání funkce mezi vstupními a výstupními daty, a tedy mají velkou schopnost učení. Sítě jsou tvořeny několika vrstvami, ve kterých jsou zastoupeny neurony. Schéma takové sítě je zobrazeno na obrázku 4. Umělé neurony jsou velmi podobné biologickým neuronům. Jednotlivé neurony rozdělené v několika vrstvách jsou propojeny neuronovými hranami, které přenášejí signál postupně od vstupních neuronů k výstupním. Vstupní hodnoty udávají sílu vstupního signálu pro první vrstvu neuronů, ty pak podle míry síly signálu vyhodnotí, zda dojde ke vzplanutí v neuronu. Vzplanutím dojde k zapnutí naučené funkce v neuronu a po úpravě propustí upravenou sílu signálu dál. Pokud není signál dostatečně silný, nedojde ke vzplanutí a signál není dále propuštěn. Každému neuronu přísluší jiná míra síly signálu a jiné výstupní funkce, ty jsou stanoveny z trénování na kalibračních datech. Neuronové sítě nejsou schopny pracovat spojitě, vždy jsou vstupní data hodnocena jednotlivě. Pro některé řešené problémy je potřeba více vstupních a výstupních hodnot, v takovém případě je potřebné mít dostatečné množství dat, aby byla neuronová síť dobře natrénovaná. (Nacházel, 2004)



Obr. 4. Schéma neuronu (Nacházel, 2004)

Více informací k neuronovým sítím bylo napsáno v bakalářské práci *Řízení zásobní funkce nádrže* (Hon, 2020).

### 3.4.2. Fuzzy metody

Fuzzy metody používají teorii fuzzy logiky. Fuzzy logika je schopna popisovat hodnoty slovními popisy. Dokáže tedy rozdělovat hodnoty podle ostrých pevně daných hranic, jako jsou přesně dané hodnoty. Pokud je tedy v prostoru  $U$  náhodný prvek  $x$  a chtěli bychom určit, zda náleží do množiny, která je definována v reálných číslech jako  $\delta: A = \{x(x > \delta)\}$ , pak je zvolena ostrá hranice, že prvek  $x$  leží v množině  $A$ , jestliže je  $x > \delta$ .

Fuzzy logika tedy využívá jednoduchosti a přirozenosti slovních popisů. Jsou tedy voleny slovní popisy, které určují polohu hledané třídy a samostatnou příslušnost hodnot prvků k těmto třídám. Příslušnost pak nelze brát jako pravděpodobnost výskytu daného jevu, ale určuje, jak moc lze prvek do dané třídy zařadit a v jaké oblasti se přibližně nachází. Když je příslušnost k třídě nízká, nachází se potom hledaný prvek na okraji této třídy a může mít také v malé míře příslušnost k vedlejší třídě. Podle této třídy je pak určen slovní popis nebo hodnota výstupního prvku.

Ve většině publikací je pak fuzzy množina definována takovým způsobem, že pokud prvky  $x$  jsou souborem prostoru  $U$ , pak fuzzy množina  $A$  v prostoru  $U$  je určena množinou uspořádaných dvojic.

$$A = \{(x, \mu_A(x)), x \in U\}, \quad (3.3),$$

kde  $\mu_A(x)$  je funkcí příslušnosti (FP) fuzzy množiny  $A$ . Příslušnost každého prvku pak nabývá hodnoty z intervalu  $\langle 0,1 \rangle$ .

Prostor  $U$  obsahující fuzzy množinu  $A$ , může být tvořen diskrétním uspořádáním nebo i spojitým prostorem.


Popisuje-li například prvky  $x = \{0,1,2,3,4,5,6\}$  v prostoru  $U$  počet prodaných okurků za den se stupni příslušnosti  $\mu_A(x)$ , pak je možné definovat fuzzy množinu  $A$  podle rozdělení:

$$A = \{(0;0,1), (1;0,3), (2;0,7), (3;1), (4;0,6), (5;0,2), (6;0,1)\}, \quad (3.4),$$

a například definice fuzzy množiny  $B = \text{„rychlost okolo 50“}$  definována vztahem:

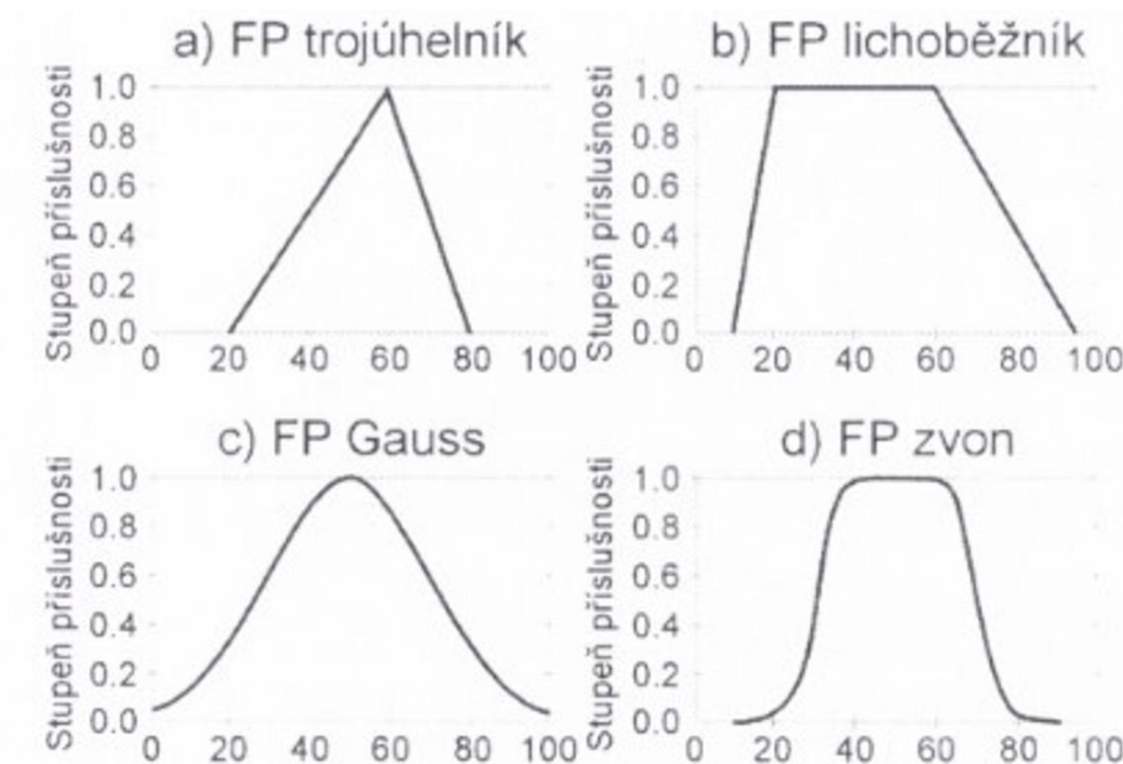
$$B = \{(x, \mu_B(x)), x \in U\}, \quad (3.5).$$

Tvary funkcí výše popsaných množin jsou zobrazeny na obrázku 5.




Obr. 5. Příklady funkcí příslušnosti (Nacházel, 2004)

Samotná tvorba fuzzy množiny je dána dvěma faktory. Volbou vhodného prostoru množiny a vymezení přiměřených funkcí příslušnosti. Tyto volby jsou pak závislé na zkušenosti subjektu pracujícího s určitým problémem. Je tedy pravděpodobné, že při vytváření fuzzy množiny a pravidel, mohou dva subjekty docílit různých výsledků. Jsou také možné různé tvary funkcí příslušnosti, například trojúhelníková, lichoběžníková, Gaussova a zvonová (Obr. 6).



Obr. 6. Příklady tvarů funkcí příslušnosti (Nacházel, 2004)

Řešení fuzzy modelů je děleno na dva základní typy. Ty jsou pojmenovány podle autorů zabývajících se problematikou fuzzy logiky, a to fuzzy inferenční systém Mamdaniho typu a Sugenoova typu. Rozdílem mezi těmito typy je, že při použití Mamdaniho typu mohou být výstupy nelineární systémy a při použití typu Sugenoova jsou výstupy lineární systémy s hodnotou v těžišti plochy. (Nacházel, 2004)



Obr. 7. Schéma fuzzy modelu

### 3.4.3. Postup fuzzy modelu

Samostatný postup fuzzy modelu se řídí třemi kroky, kterými jsou fuzzifikace, fuzzy inference a defuzzifikace. Schéma postupu je zobrazeno na obrázku 8.

#### 3.4.3.1. Fuzzifikace

Fuzzifikace zahrnuje transformaci vstupních ostrých hodnot pomocí databáze a báze pravidel. Také proběhne normalizace vstupních dat tak, aby mohly být použity prostředky fuzzy logiky. Úpravy probíhají v rámci základních měřítek, dle kterých jsou nastavovány fuzzy regulátory. Pak jsou převedeny samotné hodnoty tak, aby mohlo být použito prostředí fuzzy množiny.

#### Metoda Fuzzy C-means (fuzzy shlukování)

Fuzzy shlukování je jednou z metod, která se používá pro určení hodnoty funkce příslušnosti pro jednotlivé body. Pro všechny body samostatně je určena hodnota funkce příslušnosti. Ta udává, s jakou mírou daný bod náleží do shluku v intervalu  $\langle 0,1 \rangle$ . Body s menší hodnotou funkce příslušnosti se rozprostírají na okraji shluku. Funkcí příslušnosti je dobře popsáno rozmístění bodů ve shlucích. Okrajové body mohou náležet do více

shluků zároveň. Funkcí příslušnosti lze rozeznat body náležící k danému shluku a také body, které nelze přiřadit k žádnému shluku. Pro body dosahující hodnoty 1 příslušnosti k nějakému shluku a k ostatním nulovou hodnotou je shlukování označeno za pevné. Naopak jednotlivé shluky jsou neurčitelné, pokud se stupeň příslušnosti každého objektu k libovolnému shluku rovná převrácené hodnotě počtu shluků. Součet koeficientů příslušnosti jednotlivých objektů ke všem shlukům je 1. Algoritmus pak určuje rozpoštění jednotlivých shluků tak, aby bylo možné co nejvíce bodů přiřadit ke shluku.

#### **3.4.3.2. Fuzzy inference**

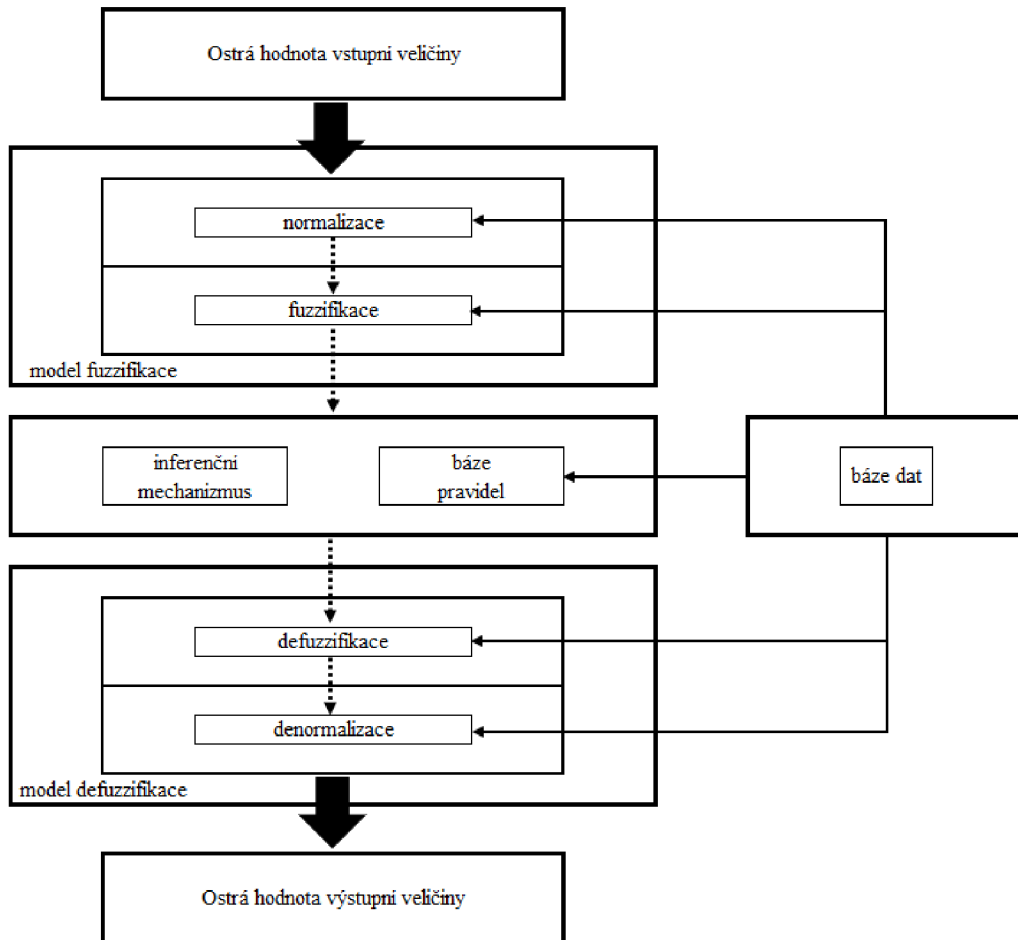
Dále proběhne hodnocení pomocí báze pravidel. Tato pravidla určí ke každé hodnotě funkci příslušnosti a přiřadí jí třídu. V této fázi lze využít dva postupy, a to individuální a kompoziční přístup. Při využití individuálního postupu vstupují fuzzy množiny do hodnotící jednotky a jsou hodnoceny jednotlivě každým pravidlem. Výsledkem je pak fuzzy množina. Pokud probíhá hodnocení více pravidly výsledek se získá agregací.

#### **3.4.3.3. Defuzzifikace**

V poslední fázi probíhá transformace zpět na původní ostré hodnoty. Tento proces může probíhat třemi způsoby.

1. Výstupní hodnota je váženým průměrem výstupu každého pravidla a funkce příslušnosti.
2. Výstupní hodnota je dána metodou středu plochy (těžiště), středu maxima nebo prvního maxima. Ty jsou určovány z grafů pravidel a funkcí příslušnosti.
3. Výstup je lineární kombinací vstupních hodnot, které jsou hodnoceny pravidly a z nich je stanoven vážený průměr. (Nacházel, 2004)





Obr. 8. Schéma ústředního členu fuzzy regulátoru (Nacházel, 2004)

### 3.4.4. Použitý software


Jako předávací médium historických dat byl použit tabulkový program Microsoft Excel, který byl taktéž používán při sestrojování dispečerského grafu. K simulaci řízení a k předpovědi průtoků pro testování funkčnosti předpovědního modelu založeného na fuzzy modelu byl použit program Matlab.

#### 3.4.4.1. Matlab

Tento program slouží pro inženýrské a vědecké výpočty, simulace, vizualizace, analýzu dat a vývoj algoritmů. Dává také možnosti v oblasti aplikované matematiky, strojového učení, zpracování signálů a komunikace. Matlab je schopen komunikovat s programy, které mají programovací jazyk C, C++, Java, .NET a Microsoft Excel.



V práci byl využit již naprogramovaný nástroj pro vytváření fuzzy modelu.  
(Matlab, 2001)



*Obr. 9. Program Matlab*

### 3.5. Hodnotící kritéria

#### 3.5.1. Relativní střední kvadratická chyba (RMSE)

Relativní střední kvadratická chyba (z anglického root-mean-square error) je míra rozdílů mezi předpovídanými hodnotami a reálnými. Je spočtena dle vzorce 3.6.

$$RMSE = \sqrt{\frac{(\theta - \hat{\theta})^2}{n}}, \quad (3.6),$$

kdy  $\hat{\theta}$  je předpověď prvku,  $\theta$  je reálný prvek a  $n$  je celkový počet porovnávaných prvků. Tato chyba pak udává, jakou mírou se liší předpovídané hodnoty od hodnot reálných. Čím nižší je hodnota RMSE, tím jsou předpovídané hodnoty přesnější. (Root-mean-square deviation, 2001)

#### 3.5.2. Koeficient determinace ( $R^2$ )

Koeficient determinace udává, jakou mírou je predikce přesná. Nabývá hodnot  $\langle 0, 1 \rangle$ . Pokud jsou hodnoty velmi odlišné bude  $R^2$  blízké k 0, v opačném případě bude  $R^2$  nabývat hodnot blízkých 1. Tyto hodnoty pak lze převést na procentní vyjádření. Rovnice  $R^2$  je zobrazena rovnicí 3.7.

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2}, \quad (3.7),$$

kde  $y_i$  je  $i$  tá porovnávaná proměnná,  $\bar{y}$  je střední hodnota proměnné  $y$  a  $\hat{y}_i$  je  $i$  tý odhad proměnné  $y$ . (Tauberová, 2018)


## 4. Aplikace

### 4.1. Získání dat

Výsledky práce byly také porovnány pomocí simulace na vodním díle Vranov. Vodní dílo Vranov bylo vybráno z důvodu dostupnosti dostatečného množství dlouhodobě měřených dat. V místě vodního díla Vranov je na vodním toku Dyje dlouhodobý průměrný průtok  $8,81 \text{ m}^3/\text{s}$ .

#### 4.1.1. Vodní dílo Vranov


Vodní dílo Vranov se nachází na jižní Moravě u obce Vranov nad Dyjí na řece Dyji. V místě vodního díla, to je na 175,41 říčním km, je v blízkosti ústí Štítarského potoka do Dyje. Výškové a objemové rozdělení prostorů nádrže jsou zobrazeny v tabulce 1 na následující straně, kde jsou zobrazeny i hloubky nádrže na obrázku 10. Hráz je postavena jako tížná betonová hráz s prohnutím proti proudu pro rozložení sil do zakotvení ve skalním masivu. Na návodním líci jsou umístěny betonové šachty s ovládáním bezpečnostních šoupat spodních výpustí. Na vzdušném líci se pak nachází vodní elektrárna, kterou prochází 3 výpusti. Ve střední části jsou umístěny 4 spodní výpusti, a to 2 s válcovým uzávěrem a 2 s Johnsonovým uzávěrem. Těleso hráze je tvořeno 19 dilatačními bloky z nichž 9 je opatřeno bezpečnostním přelivem. Na bočních 6 bloků dále navazuje kaskáda s 10 stupni. Plánek tělesa hráze je zobrazen na obrázku 11. Pod hrází je pak vývar s betonovými bloky pro rozrážení přepadající vody. (Povodí Moravy, s.p., 2018)



Obr. 10. Zobrazení hloubky v nádrži (Husák, c2010-2022)

Tabulka 1. - Rozdělení prostorů v nádrži (Povodí Moravy, c2010–2022)

Prostor v nádrži	Hladina		Výška prostoru	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	79,67
Retenční prostor ovladatelný	348,45	350,2	1,65	11,16
Retenční prostor neovladatelný	350,2	351,45	1,35	10,03
Celkový prostor	306,75	351,45	44,81	132,69



Obr. 11. Plánek přehrady (Vranovská přehrada, c2012)

#### 4.1.2. Měrný profil

Historické měřené průtoky byly získány z měrného profilu na řece Dyji u obce Podhradí nad Dyjí s evidenčním číslem 358. Tok řeky je zobrazen na obrázku 12. Naměřená data byla poskytnuta ze školní databáze, které jsou poskytovány z ČHMÚ. ČHMÚ je vlastníkem a provozovatelem měrného profilu. Měrná stanice u měrného profilu zaznamenává průtok od roku 1935. Stanice je umístěna na pravém břehu řeky na 190,09 říčním km. Do měrného profilu stéká voda z povodí o celkové ploše 1755,49 km<sup>2</sup>. Tok je v místě měrného profilu označen číslem hydrologického pořadí 4-14-02-007-0-00. Na grafu 1 je zobrazena průtoková řada ze zmíněného profilu. Průměrný roční průtok  $Q_a$  je v tomto místě 8,81 m<sup>3</sup>/s. V místě měrného profilu jsou stanoveny N-leté průtoky, které jsou zobrazeny v tabulce 2. (Evidenční list hlásného profilu č.358)

*Tabulka 2. - N-leté průtoky na Dyji v měrném profilu [m<sup>3</sup>/s] (Evidenční list hlásného profilu č.358)*

Q <sub>1</sub>	Q <sub>5</sub>	Q <sub>10</sub>	Q <sub>50</sub>	Q <sub>100</sub>
97,8	157	196	320	390

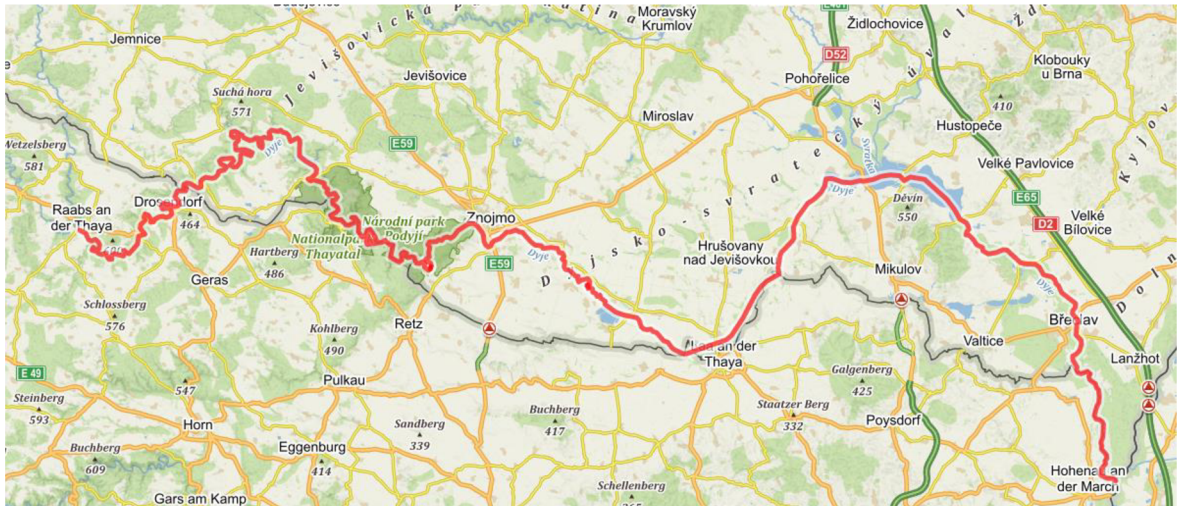
Dyje není jediným přítokem do nádrže. Dalšími přítoky jsou třeba řeka Želetavka, Bítovský a Štítarský potok. Tyto přítoky byly v práci zohledněny jako 10 % přítoku řeky Dyje, a to z důvodu zjednodušení výpočtů a dostupnosti měřených dat.

Po celé České republice jsou rozmístěny měrné stanice, které jsou rozděleny podle zřizovatele na dvě kategorie. Veškeré evidované měrné stanice jsou zobrazeny na obrázku 9.

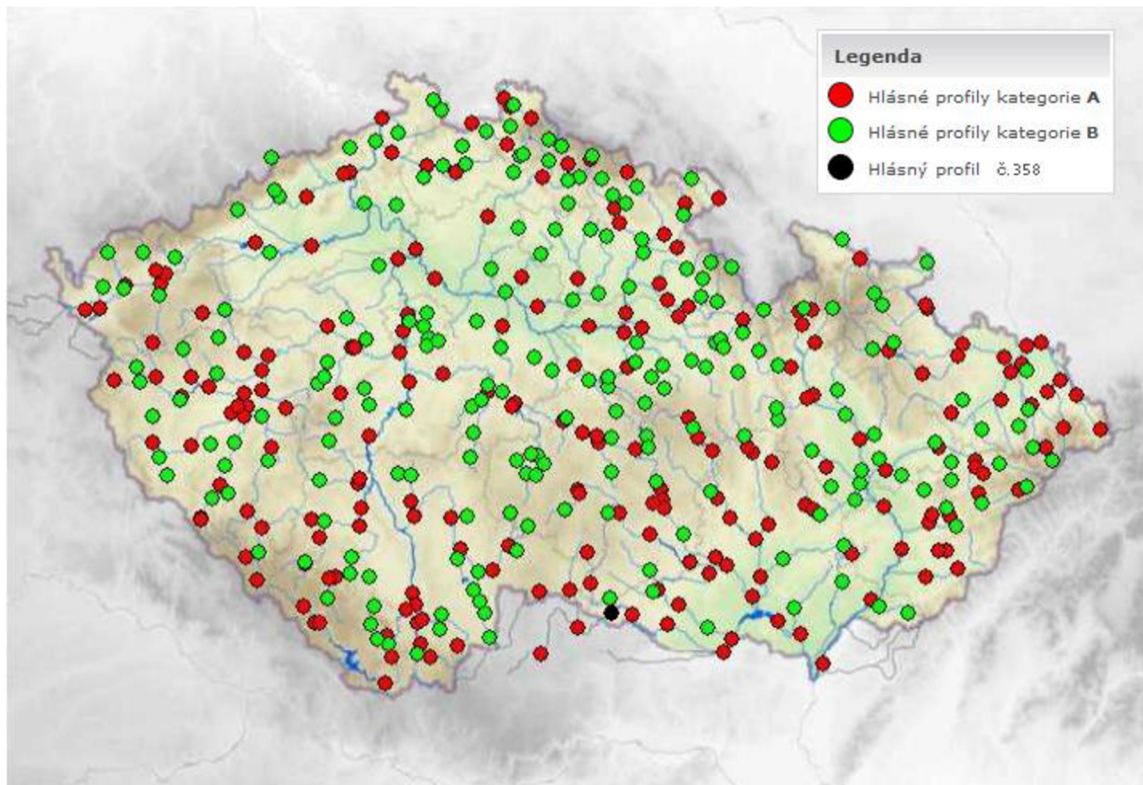
Rozdělení měrných stanic:

- 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
- Poloha stanic je zobrazena na obrázku 13.






Obr. 12. Řeka Dyje (Mapy.cz, 2022)



Obr. 13. Poloha měrné stanice (ČHMÚ, c2022)



Graf 1. Historická průtoková řada



## 4.2. Dispečerský graf

Dispečerský graf byl převzat z manipulačního řádu vodního díla Vranov. V tabulce 3 je uvedeno rozdělení objemů do zón a v tabulce 4 je rozdělení odtoků.


*Tabulka 3. - Rozdělení objemů do zón*

DG V [m <sup>3</sup> ]	1	2	3	4	5	6	7	8	9	10	11	12
Zóna 0	79.67	79.67	79.67	79.67	79.67	79.67	79.67	79.67	79.67	79.67	79.67	79.67
Zóna 1	67.22	70.00	70.00	78.67	79.67	74.66	76.50	72.90	67.03	59.67	53.37	53.45
Zóna 2	67.22	70.00	69.70	70.00	70.00	65.00	63.00	60.00	55.00	59.60	53.37	53.45
Zóna 3	67.22	70.00	69.20	62.50	60.00	57.50	54.00	47.50	40.00	59.00	53.37	53.45
Zóna 4	67.22	70.00	68.20	55.00	55.00	50.00	45.00	40.00	35.00	48.00	53.37	53.45
Zóna 5	67.22	70.00	65.00	40.00	40.00	35.00	30.00	25.00	20.00	35.00	53.37	53.45

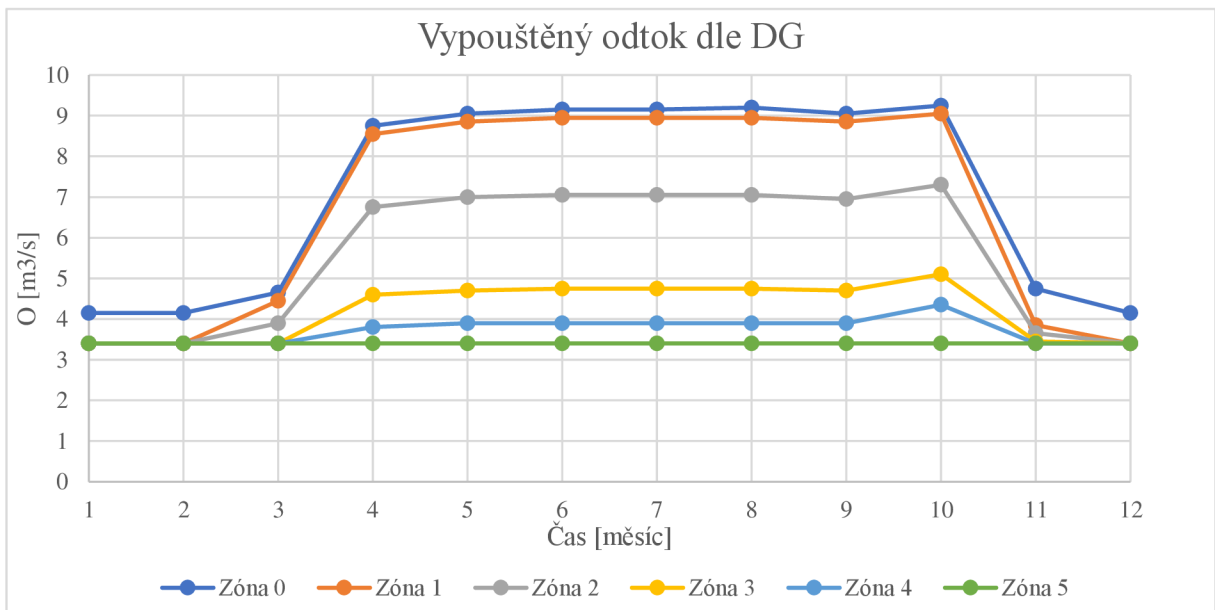
*Tabulka 4. - Rozdělení odtoků do zón*

DG Op [m <sup>3</sup> /s]	1	2	3	4	5	6	7	8	9	10	11	12
Zóna 0	4.2	4.2	4.7	8.8	9.1	9.2	9.2	9.2	9.1	9.3	4.8	4.2
Zóna 1	3.4	3.4	4.5	8.6	8.9	9.0	9.0	9.0	8.9	9.1	3.9	3.4
Zóna 2	3.4	3.4	3.9	6.8	7.0	7.1	7.1	7.1	7.0	7.3	3.7	3.4
Zóna 3	3.4	3.4	3.4	4.6	4.7	4.8	4.8	4.8	4.7	5.1	3.5	3.4
Zóna 4	3.4	3.4	3.4	3.8	3.9	3.9	3.9	3.9	3.9	4.4	3.4	3.4
Zóna 5	3.4	3.4	3.4	3.4	3.4	3.4	3.4	3.4	3.4	3.4	3.4	3.4

V následujících grafech 2 a 3 je grafické zobrazení dispečerského grafu převzatého z manipulačního řádu vodního díla Vranov.



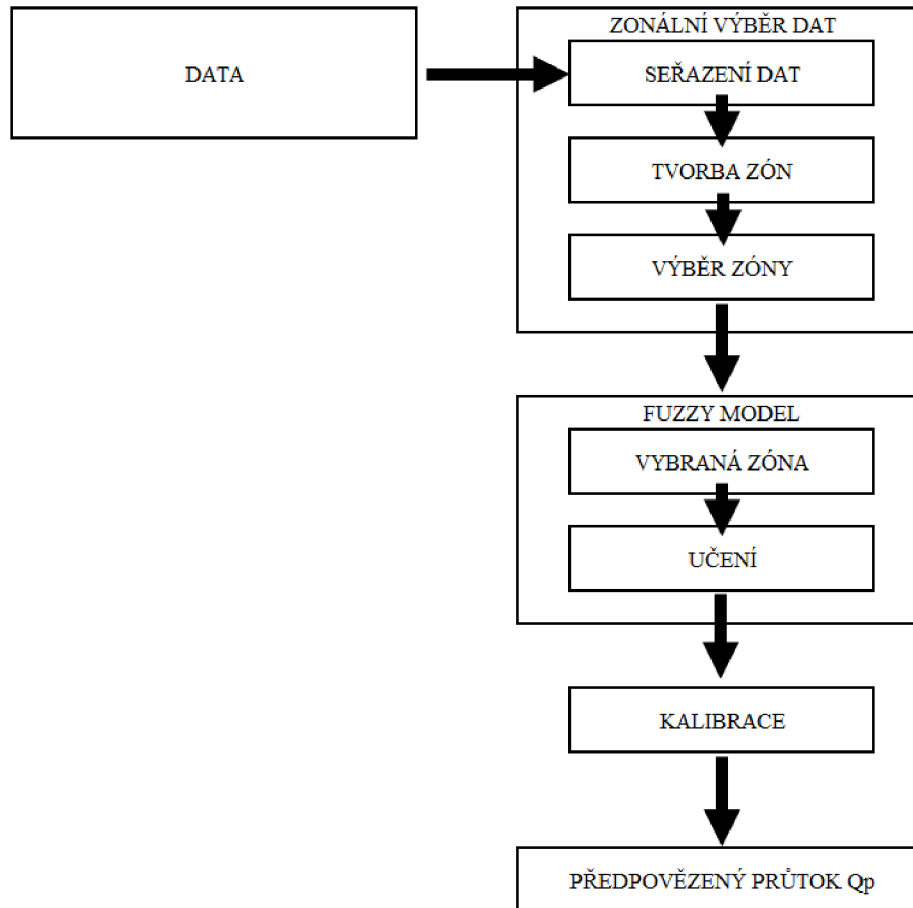
Graf 2. Vymezení zón v DG



Graf 3. Vypouštěné množství podlé zón v DG

### 4.3. Předpovědní model

Předpovědní model je založen na učícím se fuzzy modelu a zonálním modelu. Schématické zobrazení předpovědního modelu je na následujícím obrázku 14.



Obr. 14. Schéma předpovědního modelu

#### 4.3.1. Zonální výběr

Byl vytvořen zonální model pro výběr dat, podle kterých se předpovědní model učil. Zonálnímu modelu byla poskytnuta data předpovídaného měsíce. Tato data byla dále seřazena. Seřazené průtoky pak byly rozděleny dle pevného počtu zón. Bylo by možné také tato data třídit podle pevného počtu prvků v zóně, ale byla zvolena první zmíněná možnost.

### 4.3.2. Fuzzy model

Předpovědní model je založený na fuzzy modelu typu Mamdani. Vstupními daty ke stanovení předpovědi průtoku byly poslední dva reálné průtoky.

Tato data musela být fuzzifikována pomocí funkcí příslušnosti. Jejich body se stanovily metodou fuzzy c-mean.

Defuzzifikace výstupních hodnot probíhá pomocí metody těžiště ploch. Plochy jsou určovány z kombinace funkcí příslušnosti dvou vstupních prvků.

Z důvodu postupu má každý člen předpovědi vlastní naučený fuzzy model.

Pracovní postup fuzzy modelu byl popsán dříve v kapitole 3.4.2 Fuzzy metody.

## 4.4. Řídící modul

Řídící modul pro řešení simulace řízení na vodním díle je sestaven tak, aby docházelo k vhodné manipulaci. Vhodná manipulace zabrání krátkým a hlubokým poruchám, místo nich pak zavádět dlouhé a mělké. Standardně jsou používány pro řízení dispečerské grafy.

Pro každou metodu řízení je potřeba nejdříve stanovit vstupní hodnoty. U dispečerských grafů je potřeba znát pouze počáteční hodnotu objemu vody v nádrži  $V_0$ , ze které je použitím dispečerského grafu určen řízený odtok. Pro simulaci řízení je také potřeba mít průměrné měsíční přítoky do nádrže  $Q_r$ .

Řídící modul porovnává objemy v dispečerském grafu podle objemu vody v nádrži na začátku měsíce. Po nalezení objemu je stanovena zóna dispečerského grafu. Zóna udává, jaký by měl být, vypouštěný odtok vody z nádrže během měsíce  $O_r$ . Navrhovaná metoda používá kombinaci dispečerského grafu a předpovědi, a proto může docházet k úpravě řízeného odtoku vody z nádrže s pomocí změn zón v dispečerském grafu. Z nastavené zóny jsou načteny pozdější vypouštěné odtoky a ty jsou vloženy s členy předpovědi průtoků do upravené rovnice nádrže (4.1). Podle této rovnice se dopočte možný budoucí objem, který stanoví budoucí zónu. Pokud dochází ke změně zóny, pak je tato změna aplikována již na první člen řízeného vektoru, který bude v následujícím kroku aplikován.

Po aplikaci případných změn dojde k vybrání odtoku ze změněné zóny. Odtok z dané zóny je vložen do rovnice nádrže (4.1), kterou je dopočítán objem nádrže pro další krok.

$$V_{\tau} = V_{\tau-1} + (-O_{\tau} + Q_{\tau}) * \Delta t, \quad (4.1).$$


K tomuto objemu musí být přidány dvě okrajové podmínky. Ty stanovují omezení pro maximální a minimální objem. Tyto podmínky jsou dány objemem zásobního prostoru nádrže, jelikož řízení probíhá pouze v něm a při předkročení dochází k mimořádným manipulacím na vodním díle. Pokud tedy objem stoupne nad maximální hodnotu, pak je výslednou hodnotou právě maximální objem. Při poklesu objemu do záporné hodnoty je objem stanoven na nulu.

## 5. Kalibrace

Zde je popsán postup vytváření a kalibrování předpovědního modelu. Kalibrace probíhala na validačním období řídicího modulu, na kterém byly předpovědi i hodnoceny.

### 5.1. Předpovědní model

Předpovědní model je založen na učícím se modelu fuzzy a zonálním modelu. Pro jeho učení pak byla použita data z rozšiřující se kalibrační průtokové řady 1935-2006. Počáteční kalibrační průtoková řada je zobrazena na grafu 4.



Graf 4. Kalibrační průtoková řada 1935–2006


#### 5.1.1. Zonální výběr dat

Zonální výběr dat vychází ze zonálního modelu. Dochází tak k roztřídění dat a výběru zóny, které jsou dříve popsány v kapitole 3.3.2.4 Zonální model.

Nastavení počtu zón v tomto modelu bylo testováno od 2 do 11 zón. Počet zón velmi ovlivňuje naučení předpovědního modelu, a proto testování jejich počtu bylo důležité. Pro vyhodnocení vhodného počtu zón byla použita kritérium RMSE. Výsledky jsou zobrazeny v tabulce 5. V grafu 8 jsou zobrazeny vybrané předpovědní řady s různým počtem zón.


### 5.1.2. Fuzzy model

Druhou částí předpovědního modelu je fuzzy model. Ten je založený na fuzzy modelu typu Mamdani. Vstupními daty ke stanovení předpovědi průtoku byly poslední dva reálné průtoky. Uvedené tvrzení je platné i pro předpovědi dalších členů. Při procesu učení v daném kroku předpovědi jsou u jednotlivých vektorů předpovědi měněny pouze data cílového chování. Data cílového chování odpovídají předpovídanému měsíci a jsou vybrána ze zvolené zóny



Obr. 15. Fuzzy model

Vstupní hodnoty je potřeba nejdříve fuzzifikovat s využitím funkcí příslušnosti. Funkce příslušnosti musí být nastaveny tak, aby docházelo k vhodné transformaci dat. Její nastavení probíhalo v prostředí Matlab. Prvotní nastavení obsahovalo 4 matice pravidel, které udávají počet funkcí příslušnosti s Gaussovou křivkou. Funkce příslušnosti pro transformaci hodnoty je zobrazena křivkami na obrázku 16.



Obr. 16. Funkce příslušnosti s Gaussovou křivkou

Počet funkcí příslušnosti také ovlivňoval přesnost výsledků. Jejich počet byl testován od 2 do 10.

V rámci fuzzy modelu byla také prováděna defuzzifikace hodnot. Ta probíhá transformací párových dvojic poskytnuté fuzzifikací. Výstupní hodnoty jsou určeny metodou těžištěm plochy.

Ve fuzzy modelu musel být dále nastaven počet iterací k jeho dostatečnému naučení a počáteční hodnoty, pro které se začíná iterovat. Nastavování těchto dvou hodnot probíhalo stejným způsobem jako u předchozích hledaných nastavení.

Předpovědní model má obecné schéma zobrazené na obrázku 15. Předpovědní model byl učen na datech z měrného profilu na toku Dyje. Předpovídané průtoky jsou předpovídaný pouze pro tento tok. Další přítoky vtékající do vodního díla Vranov byly připočteny jako 10 % z toku Dyje. Na následujícím obrázku 17 je zobrazena ukázka skriptu předpovědního modelu.

```
22 - for j = 1 : pzon
23 -     B(j,1) = ppzon * (j-1) +1;
24 -     B(j,2) = ppzon * j;
25 - end
26 - B(pzon,2)=x1 + 1;
27 - As = sortrows (A,n);
28 - Q = A2(i+864,1);
29 - Q2 = A2(i+863,1);
30 - Q3 = A2(i+862,1);
31 - [r,c] = find (As>Q);
32 - TF = isempty (r);
33 -     if TF ==1
34 -         r = x1;
35 -     end
36 - r1=r(1,1);
37 - [r2,c2] = find(B(:,1)<=r1);
38 - r3 = max (r2(:,1));
39 - %r3 = r2 (end,1);
40 - clear r2
41 - clear r
42 -     if B (r3,2)>x1
43 -         B (r3,2)=x1;
44 -     end
45 - AD = As ( B(r3,1):B (r3,2),n+1:n+12);
46 - AD3 = As ( B(r3,1):B (r3,2),n+24);
47 - [xx,yy]= size (AD);
48 - for L= 1: xx
49 -     AD2(L,:) = A2 (AD3(L,1)-2:AD3(L,1),1)';
50 - end
51 - ADD = [AD2 AD];
52 - clear AD
53 - clear AD2
54 - Qp=Fuzzys(ADD,ppp,Q,Q2);
```

Obr. 17. Ukázka skriptu předpovědního modelu



## 6. Validace

V kapitole jsou popsány konečné výsledky s nastavením všech pravidel pro předpovědní model, převzetí dispečerského grafu, stanovení tání sněhu a porovnání předpovědí mezi fuzzy modelem a neuronovými sítěmi.

### 6.1. Předpovědní model


V rámci nastavení předpovědního modelu byli nastavováni obě části modelu současně. Z důvodu posloupností předpovědního modelu je prvně popsáno nastavení zonálního výběru dat.

#### 6.1.1. Zonální výběr dat

Předpovědní model je založen na fuzzy metodě. Při sestavování předpovědního modelu bylo potřeba otestovat mnoho nastavení. Nejdříve byla sestavena první část modelu, která poskytuje seřazená a rozdělená data do zón. Tato část byla testována na rozdělení dat do pevného počtu zón. Počty zón byli testovány na pevně zvoleném nastavení fuzzy modelu. Vhodná nastavení fuzzy modelu jsou zobrazena v následující kapitole. Ukázalo se, že vhodným počtem zón je pět zón. S ohledem na opakované přeučování předpovědního modelu, musel být výpočet několikrát zopakován, aby bylo možné dostat statisticky vhodný počet zón. Několik pokusů je zobrazeno v tabulce 5 a graficky v grafu 5 jsou zobrazeny průtoky vybraných předpovědí s různým počtem zón.

*Tabulka 5. - Porovnání výsledků počtu zón*

Počet zón		2	3	4	5	6	7	8	9	10
RMSE	1.pokus	7,165	7,888	7,544	5,984	6,544	7,155	6,857	7,779	7,566
	2.pokus	7,276	7,918	7,638	6,128	6,392	7,094	7,102	7,899	7,818
	3.pokus	7,243	7,868	7,605	6,089	6,442	7,077	7,261	7,779	7,774



Graf 5. Porovnání výsledků vybraných předpovědí při změně počtu zón

## 6.2. Fuzzy model

Vstupními daty pro předpovědní model byly poslední dva reálné průtoky. Jejich hodnoty musely být nejdříve fuzzifikovány. Fuzzifikace probíhala metodou hledání funkcí příslušnosti, které byly nastavovány ve fuzzy modelu maticemi pravidel. Počet matic pravidel udává počet funkcí příslušnosti. Počet funkcí je po testování stanoven na 6 funkcí. Tabulka 6 zobrazuje výsledky testování počtu funkcí. Rozložení funkcí pro průtoky  $Q_t$ ,  $Q_{t-1}$  je zobrazeno na obrázku 18 a 19.


Tabulka 6. - Porovnání výsledků počtu matic

Počet funkcí příslušnosti		2	3	4	5	6	7	8	9	10
RMSE	1. pokus	6,876	6,339	6,150	5,983	5,819	6,006	6,113	6,188	6,057
	2. pokus	6,909	6,339	6,022	6,062	5,888	5,887	5,973	5,975	5,950
	3. pokus	6,876	6,339	5,937	5,898	6,014	6,054	5,770	5,943	5,971




Graf 6. Vybrané předpovědi porovnání počtu matic

Na grafu lze vidět, že počet 6 funkcí je schopen vhodně fuzzifikovat vstupní data.



Obr. 18. Rozdělení funkcí příslušnosti  $Q_t$



Obr. 19. Rozdělení funkcí příslušnosti  $Q_{t-1}$

Dále bylo potřeba stanovit od jaké hodnoty bude prováděna iterace po několika pokusech vycházela nejlépe hodnota 2. Další hledanou hodnotou byl počet potřebných iterací, aby došlo k vhodnému určení předpovědi. Tato hodnota byla určena na 600


iterací. Výsledky těchto dvou hodnot jsou zobrazeny v následujících tabulkách 7 a 8. Dále porovnání vybraných předpovědí na grafech 7 a 8.

*Tabulka 7. - Porovnání výsledků nastavení počáteční hodnoty iterací*


Hodnota počátku iterací	2	3	4	5	6	7	8	9	10	
RMSE	1. pokus	5,920	6,542	6,063	5,896	6,249	6,772	6,520	7,147	6,724
	2. pokus	5,922	6,276	6,176	6,576	6,495	6,427	6,593	6,803	6,851
	3. pokus	5,940	6,390	6,412	5,962	6,503	7,110	6,978	6,762	6,932

*Tabulka 8. - Porovnání výsledků počtu iterací*

Počet iterací	200	250	300	350	400	450	500	550	
RMSE	1. pokus	5,908	5,904	5,901	5,901	5,851	5,761	5,811	5,987
	2. pokus	5,911	5,790	5,728	6,021	5,782	5,965	6,029	5,841
	3. pokus	5,991	5,991	5,893	5,755	6,064	6,034	5,856	5,813
	4. pokus	5,800	6,055	6,042	5,874	5,984	5,870	6,017	6,012
	5. pokus	5,814	5,769	5,984	5,904	6,052	5,817	5,865	5,852
Počet iterací	600	650	700	750	800	850	900		
RMSE	1. pokus	5,847	5,896	6,010	5,839	5,821	5,871	5,988	
	2. pokus	5,716	5,691	5,803	5,794	5,869	5,878	5,806	
	3. pokus	5,723	5,871	5,903	5,953	5,883	5,822	5,836	
	4. pokus	6,128	6,019	6,167	5,871	5,901	5,781	5,767	
	5. pokus	5,946	6,015	6,046	5,878	5,726	5,800	6,020	




*Graf 7. Vybrané předpovědi porovnání počátku iterací*




Graf 8. Vybrané předpovědi porovnání počtu iterací

Po fuzzifikaci je předpovědní model schopen stanovit předpověď, která je stanovena fuzzy logikou Mamdaniho typu. Defuzzifikací je z páru hodnoty a hodnoty funkce příslušnosti stanovena předpověď průtoku. Defuzzifikace probíhá pomocí metodami stanovení těžiště ploch, která navazuje na hledání funkcí příslušnosti. Grafy metody stanovení těžiště jsou zobrazeny na obrázku 18 a ve 3D na obrázku 21.




Obr. 20. Stanovení těžiště ploch



Obr. 21. Předpovědní rovina zobrazená ve 3D

Z výsledných hodnot předpovědního modelu bylo patrné, že v některých měsících má tendenci nadhodnocovat, proto byla stanovena pravidla pro jejich úpravu. Porovnání reálného průtoku a předpovědi pro první člen bez pravidel je zobrazena na následujícím grafu 9.




Graf 9. Porovnání reálného průtoku a prvního členu předpovědi

Pro jejich vyhodnocení jsou použita dvě kritéria. První z nich je relativní střední kvadratické odchytky (RMSE) a druhý pak koeficientem determinace ( $R^2$ ). Pomocí RMSE jsou hodnoceny jednotlivé měsíce samostatně, výsledky jsou zobrazeny v tabulce 9.

*Tabulka 9. - Hodnoty RMSE pro jednotlivé členy*

Předpověď měsíce	1	2	3	4	5	6
RMSE	5,758	6,657	6,953	8,717	9,200	8,141
Předpověď měsíce	7	8	9	10	11	12
RMSE	9,598	8,037	10,191	8,537	8,524	8,738

Na grafu 10 jsou porovnány předpovědi prvních tří členů.



*Graf 10. Porovnání předpovědi prvního, druhého a třetího členu*

V tabulce lze vidět zhoršení předpovědi od předpovědi třetího měsíce dopředu. Koeficientem determinace je hodnocena celá předpovědní řada pro 1 člen s výslednou hodnotou 0,40 to může naznačovat, že výsledné předpovědi nejsou úplně přesné. K úpravě nedostatečných předpovědi by mohlo být nastavení některých kritérií. Bylo tedy zavedena úprava březnového průtoku přidáním tání sněhu

*Tabulka 10. - Hodnoty RMSE pro jednotlivé měsíce na různých pozicích*

Pozice členu	1	2	3	4	5	6	7	8	9	10	11	12
Leden	1,036	1,626	3,057	1,695	4,440	3,581	4,428	2,392	4,377	1,938	3,167	2,595
Únor	2,012	2,264	2,046	2,323	2,595	2,177	3,308	2,120	3,233	4,067	3,055	3,729
Březen	2,270	2,965	3,866	3,531	3,700	3,469	4,318	3,378	4,991	3,786	3,742	3,955
Duben	1,503	1,659	1,814	1,800	1,690	1,786	1,931	1,729	2,736	2,879	2,167	1,950
Květen	1,050	1,439	1,444	1,397	1,855	1,383	1,423	1,030	1,268	1,261	1,249	1,838
Červen	2,146	2,917	2,514	2,472	2,582	2,484	2,673	2,703	2,921	2,427	2,631	2,586
Červenec	1,799	2,001	2,474	2,081	2,128	2,221	2,617	2,053	2,231	1,949	2,044	2,185
Srpen	1,832	1,863	1,770	2,116	1,795	1,713	1,715	2,142	1,666	1,791	1,674	1,770
Září	1,031	1,451	1,070	1,214	1,335	1,265	1,103	1,103	1,253	1,154	1,172	1,130
Říjen	1,059	1,224	1,377	1,850	1,330	2,138	1,183	1,363	0,921	1,250	1,129	0,927
Listopad	0,700	0,660	0,940	1,398	1,485	1,024	1,637	1,897	1,597	1,016	1,825	1,633
Prosinec	0,964	0,855	1,094	1,462	2,489	1,138	1,110	2,738	1,929	1,036	1,216	1,479

V tabulce 10 lze vidět porovnání všech měsíců se všemi pozicemi při předpovědi. Nejlépe předpovídaným měsícem je listopad. To může být způsobeno malým výskytem extrémů v tomto měsíci.

Předpovědní model byl programován v programu Matlab. Na následující straně na obrázku 22 je zobrazena část použitého skriptu.



```
1 function [Qp]=Fuzzys (ADD, ppp, Q, Q2)
2     Xin=ADD(:, 2:3);
3     a1=min(ADD(:, 2));
4     a2=min(ADD(:, 3));
5
6     b1=max(ADD(:, 2));
7     b2=max(ADD(:, 3));
8
9     if a1>Q2
10        Q2=a1;
11    end
12    if a2>Q
13        Q=a2;
14    end
15    if b1<Q2
16        Q2=b1;
17    end
18    if b2<Q
19        Q=b2;
20    end
21 for i=1:ppp
22     Xout= ADD(:, i+3);
23     fismat = genfis3(Xin,Xout, 'mamdani', 6, [2, 600, 1e-5, 1]);
24     inputs=[Q2 Q];
25     Qp(1,i) = evalfis(fismat,inputs);
26 end
27 end
```

Obr. 22. Ukázka skriptu předpovědního modelu fuzzy části

### 6.3. Tání sněhu

Na základě předchozích výsledků bylo přistoupeno ke korekci předpovědi táním sněhu. V jarních měsících byly přidány předpokládané zohlednění průtoků z tání sněhu. Ten byl vždy připočten v březnu, kdy dochází k jeho největšímu tání. Data byla poskytnuta od ČHMÚ. Poskytnutá data obsahovala o kolik se přibližně zvedá průtok při jeho tání. S těmito daty bylo možné z historické řady stanovit při jakém průtoku je potřeba přičíst navýšení průtoku sněhem. Rozdělení navýšení průtoků z tání sněhu je rozděleno v tabulce 11.

*Tabulka 11. - Rozdělení průtoků tajícího sněhu*

$Q_{snih}$	0	3	5	7	9	15
$Q_Q$	< 8	< 13	< 18	< 24	< 26	> 26

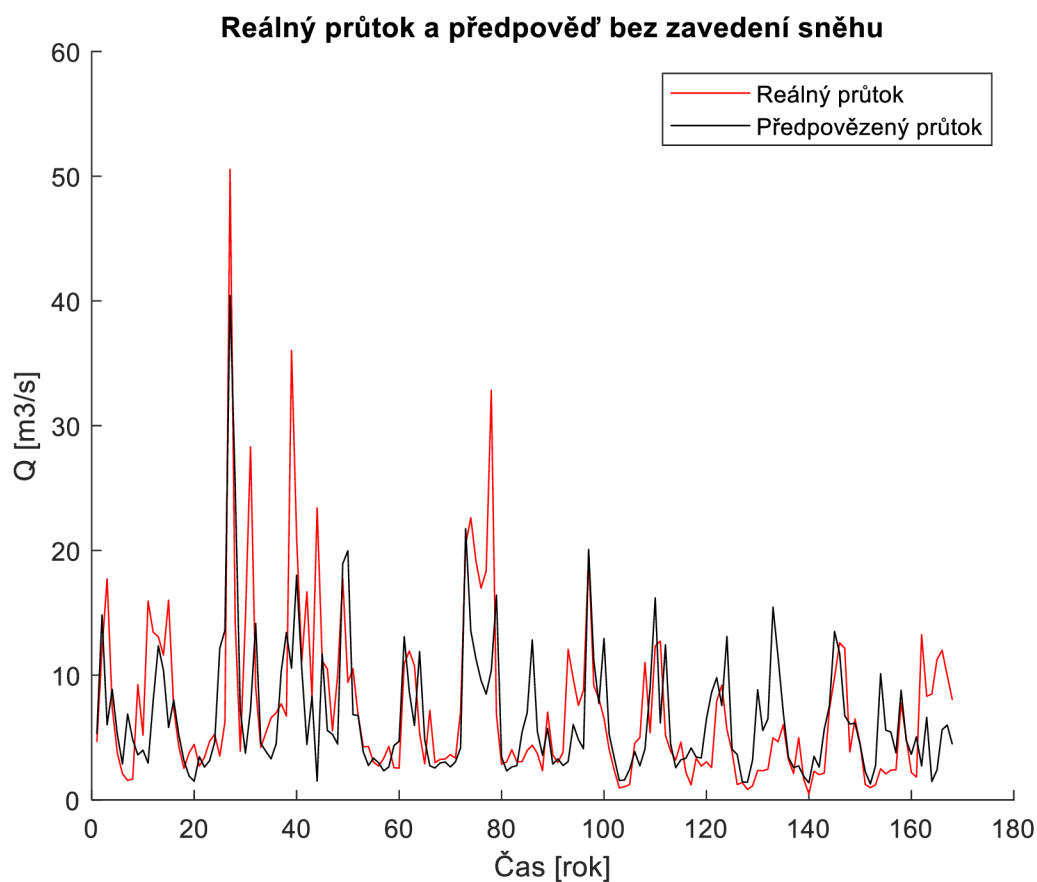
Po úpravě byli porovnány výsledky předpovídané průtoky března a celkového výsledku celé předpovídané řady. Výsledky RMSE jsou zobrazeny v následující tabulce.

*Tabulka 12. - Porovnání RMSE předpovědi měsíce března*


Pozice členu	1	2	3
Březen bez tajícího sněhu	2,270	2,965	3,866
Březen s tajícím sněhem	2,179	2,426	3,512

V tabulce 12 lze vidět zlepšení předpovědi měsíce března po zavedení tajícího sněhu. U koeficientu determinace, kterým je hodnocena celá předpovídaná řada, došlo ke zlepšení z 0,40 na 0,46. Ukázalo se, že přidané průtoky zlepšili celou předpovědní řadu.

Přidání tajícího sněhu se projevilo na roku 2008, kdy lze vidět na grafu 11, zobrazeného na následující straně, že předpovězený průtok v březnu předpovídá pouze z malé části zachytil povodeň. Po přidání tajícího sněhu lze vidět na grafu 12, na následující straně, že předpověď je téměř totožná s reálným průtokem.




Graf 11. Porovnání reálného průtoku a předpovědi bez zavedení sněhem



Graf 12. Porovnání reálného průtoku a předpovědi se zavedeným sněhem

## 6.4. Řídící modul

Řídící modul byl sestaven pro testování řízení pomocí kombinace dispečerského grafu a předpovědního modelu. Řízení bylo prováděno na validačních datech, které jsou zobrazeny v grafu 13.



Graf 13. *Validační řada simulace řízení*

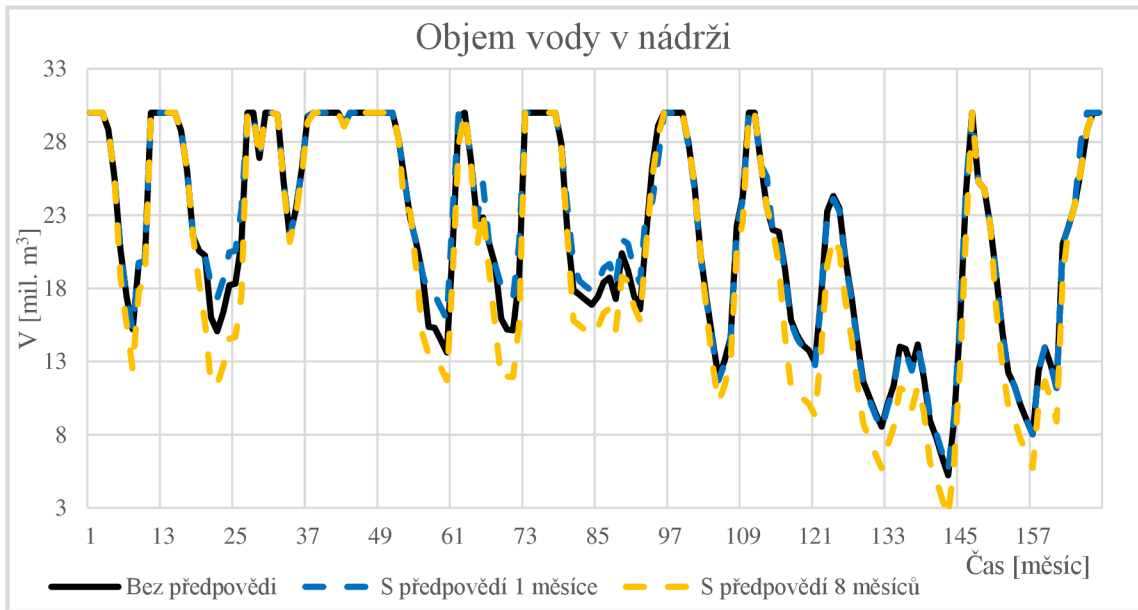
Řídící modul řídí podle dispečerského grafu a předpovědního modelu. Předpovědní model odhaduje budoucí přítoky, které jsou zahrnuty do samotného řízení. Předpovědi tak ovlivňují nastavenou zónu, která může být v důsledku předpovědi snížena nebo zvýšena. Tím dochází k dřívější reakci na přicházející extrém, ale může také dojít při chybné předpovědi zbytečnému vypuštění potřebné vody nebo naopak nedostatečnému upuštění vody z nádrže.

Při hodnocení řízení kritériem RMSE vycházely hodnoty řízení lépe s předpovědí osmi měsíců pouze při porovnání nalepšených odtoků. Při porovnání stavu objemu vody v nádrži vycházelo lépe řízení s předpovědí jednoho měsíce.

Tabulka 13. - *Porovnání simulace řízení*


	Bez předpovědi	S předpovědí 1 měsíce	S předpovědí 8 měsíců
RMSE V	11,055	10,743	12,886
RMSE O <sub>p</sub>	2,847	2,811	2,798

Porovnání simulace řízení samostatného dispečerského grafu a kombinace dispečerského grafu s délkou předpovědi jednoho a osmi měsíců jsou zobrazeny na následujících grafech 14 a 15. Na prvním je zobrazen vliv řízení na zásobní objem vody v nádrži. Na druhém jsou zobrazeny řízené odtoky vody z nádrže k porovnání je zobrazen řídicí odtok.



Graf 14. *Objem vody v nádrži simulace řízení dle dispečerského grafu a s předpovědí jednoho měsíce a osmi měsíců*

Na grafu lze vidět, že v některých suchých obdobích dochází k lepšímu řízení podle kombinace dispečerského grafu a předpovědního modelu než při použití samotného dispečerského grafu.



Graf 15. *Odtok z nádrže simulace řízení dle dispečerského grafu a s předpovědí jednoho měsíce a osmi měsíců*

V místech, kdy došlo k ušetření vody, tak v následujícím kroku mohly být použity lepší řízené odtoky, jak lze například vidět u řízeného odtoku v 94 měsíci s předpovědí 1 měsíce.

## 6.5. Porovnání fuzzy metody a neuronových sítí

S konečným nastavením fuzzy modelu bylo možné porovnat tento předpovědní model s předpovědním modelem tvořeným neuronovými sítěmi označovaný jako model NS. Model NS byl převzat z bakalářské práce *Řízení zásobní funkce nádrže* (HON, 2020). Dostupná data k neuronové síti byla pouze předpověď 3 měsíců pro roky 2003–2018. Porovnání hodnot mezi fuzzy modelem a neuronovou sítí probíhalo na datech z roků 2007-2018. Jejich vyhodnocení probíhalo pomocí RMSE. Porovnávány byli předpovězené průtoky s reálnými hodnotami, výsledky jsou znázorněny v tabulce 14.

*Tabulka 14. - Porovnání předpovědi fuzzy modelu a neuronové sítě*

Pořadí měsíce	Fuzzy model			Neuronová síť		
	1	2	3	1	2	3
RMSE	5,693	6,560	7,826	6,268	6,492	6,548


Z tabulky lze vyčíst, že fuzzy model byl lepší v předpovědi pro první měsíc. V předpovědi druhého a třetího měsíce vychází lépe neuronová síť.

K porovnání byl také použit řídicí modul, kterému byli poskytnuty postupně předpovědi z fuzzy modelu a z neuronové sítě. Pro úplnost porovnání bylo také provedeno řízení bez předpovědi. Výsledky těchto řízení jsou porovnány v tabulce 15.


Ke grafickému srovnání jsou zobrazeny grafy 16 až 19.

*Tabulka 15. - Porovnání řízení*


Délka předpovědi	Bez předpovědi	Fuzzy model			Neuronová síť		
		1	2	3	1	2	3
RMSE	2,4146	2,4041	2,3854	2,3615	1,7770	1,7781	1,7592




Graf 16. Porovnání fuzzy modelu a neuronové sítě v předpovědi 1. měsíce



Graf 17. Porovnání fuzzy modelu a neuronové sítě v předpovědi 2. měsíce



Graf 18. Porovnání fuzzy modelu a neuronové sítě v předpovědi 3. měsíce



Graf 19. Porovnání předpovědních modelů při řízení



## 7. Závěr

V diplomové práci byl vypracován řídicí modul pro řízení zásobní funkce nádrže. Tento modul používá kombinaci dispečerského grafu a předpovědního modelu. Pro potřeby výše zmíněného modulu byl v práci sestaven předpovědní model. Testování řídicího modulu bylo prováděno na vodním díle Vranov. Dispečerský graf pro modul byl převzat z manipulačního řádu vodního díla Vranov. Data pro předpovědní model byla poskytnuta ČHMÚ z měrného profilu Podhradí nad Dyjí umístěného na toku Dyje protiproudě nad vodním dílem Vranov.

Předpovědní model je sestaven ze dvou částí. První část je založena na postupu zonálního modelu, proto je tato část označena jako zonální výběr dat. Hlavní funkce zonálního výběru je rozřídění vstupních dat, která jsou poskytnuta druhé části. Pro kalibraci předpovědního modelu byla použita rozšiřující se historická průtoková řada. Vstupní data jsou rozdělena do několika zón. Z těchto zón je vybrána jedna zóna, na jejíž datech je fuzzy model učen.

Druhá část je tvořena fuzzy modelem. Fuzzy model je učen z dat poskytnutých zonálním výběrem. Vstupními daty byly poslední dva naměřené průtoky z průtokové řady. Výstupní hodnotou je předpovězený průtok. Podle požadavků lze pak měnit, jak dlouhý má být předpovídaný vektor. Učením dochází k hledání poloh bodů funkcí příslušnosti, které jsou obsaženy ve fuzzy modelu. V rámci kalibrace fuzzy modelu byl hledán vhodný počet funkcí příslušnosti a rozpoložení jejich bodů.

Samotná kalibrace předpovědního modelu byla komplikovaná, protože určení vhodného počtu zón muselo probíhat současně s nastavováním druhé části předpovědního modelu. Obě části modelu se tak navzájem ovlivňovaly.

Pro hodnocení přesnosti předpovědního modelu byla použita vyhodnocovací kritéria relativní střední kvadratická chyba (RMSE) a koeficient determinace ( $R^2$ ). Kritéria byla použita při samotné tvorbě předpovědního modelu k nastavování jednotlivých částí modelu.

Nejlepších hodnot kritérií bylo dosaženo pro 5 zón. Fuzzy model byl nastaven s počtem 6 funkcí příslušnosti, pro tvar funkcí příslušnosti byl vybrán tvar Gaussovy

křivky, stanovenou počáteční hodnotou pro iteraci předpovědi byla zvolena hodnota 2. Dalšími nastavenými hodnotami byl počet iterací, který byl nastaven na 600 iterací.

U předpovědi měsíce března bylo možné zaznamenat opakované podhodnocování předpovídaného průtoku. K březnovým předpovězeným průtokům muselo být přidáno jarní tání sněhové pokrývky. Data objemů sněhu stékajícího do měrného profilu byla poskytnuta ČHMÚ. S těmito daty bylo možné stanovit, při jakém objemu právě protékajícího průtoku je možné přidat objem vody z tajícího sněhu. Přidáním průtoků tajícího sněhu k předpovědím došlo ke zlepšení hodnocení předpovědi pro březen.

Výsledné předpovězené hodnoty byly porovnávány s reálnou průtokovou řadou. Hodnocení probíhalo již zmíněnými kritérii. Předpověď jednotlivých členů vycházela nejlépe podle RMSE hodnota 1. členu, pro další členy dochází k výraznému zhoršení. Nejlépe předpovídaným měsícem při hodnocení 1. členu předpovědi je listopad.

Dále byl sestaven řídicí modul, který je schopen řízení pomocí dispečerského grafu a kombinace dispečerského grafu s předpovědním modelem. Řídicí modul stanovuje podle objemu vody v nádrži možný řízený odtok. Pro přidání předpovědního modelu byl v práci tento modul upraven, aby podle počtu předpovězených měsíců vybral stejný počet řízených průtoků. Z předpovězených průtoků a budoucích řízených odtoků je stanovena zóna. Předpovězená zóna je porovnána s aktuální zónou. Pokud jsou odlišné, dojde ke změně aktuální zóny. Podle nové zóny je stanoven nový řízený odtok. Poté je spočten výsledný objem nádrže.

Při řízení se projevila schopnost kombinace dispečerského grafu a předpovědního modelu reagovat na přicházející sucha. Nejlepších výsledků dosáhlo řízení s délkou předpovědi 8 měsíců. Při kratší předpovědní řadě nebylo řízení schopno včas reagovat, při delší předpovědi docházelo k velké nepřesnosti předpovědi, a tak došlo ke zhoršení výsledků.

K porovnání řídicího modulu bylo použito řízení samotným dispečerským grafem. Výsledky tohoto řízení jsou zobrazeny na grafech v kapitole 6.4 Řídicí modul. Na těchto grafech lze vidět, že při použití kombinace dispečerského grafu a předpovědi dochází k většímu držení zásobního objemu vody v nádrži. Ušetřená voda je pak dále použita v obdobích extrémně suchých epizod.

Další částí této práce bylo porovnání předpovědních modelů používající fuzzy model a neuronové sítě. Porovnávaný fuzzy model byl z této diplomové práce a neuronový model byl převzat z bakalářské práce *Řízení zásobní funkce nádrže* (Hon, 2020). Porovnání proběhlo srovnáním předpovědaných průtoků s reálnou průtokovou řadou a porovnání průběhu řízení s použitím kombinace dispečerského grafu a těmito modely. Při jejich porovnávání byla použita již dříve zmíněná vyhodnocovací kritéria.

Bylo zjištěno, že využití kombinace dispečerského grafu a předpovědního modelu (obou předpovědních modelů) vychází v porovnání s řízením samostatným dispečerským grafem lépe. Mezi porovnávanými předpovědními modely při řízení dopadla lépe neuronová síť. Pro předpovědi 1. měsíčního průtoku dopadl lépe fuzzy model. Při předpovědi 2. a 3. měsíce se ukázala být lepší neuronová síť. Kdyby bylo možné porovnat řízení delší předpovědní řady, mohl by být předpovědní model z fuzzy modelu lepší. Jak bylo dříve zmíněno, řízení s délkou předpovědní řady 8 měsíců bylo lepší než řízení s předpovědí 1 měsíce.

Metoda předpovědního modelu je komplikovaná. Tato metoda převyšuje svoji komplikovaností dispečerské grafy a její výsledky v průměrných a extrémně vodných letech nejsou výrazně lepší. V suchých letech byla schopna lepšího reagování na přicházející sucha.

Pokud by měla být vypracovaná metoda použita v praxi, je vhodné uvažovat nad jejím užitkem v poměru s její složitostí.

S ohledem vývoje budoucích průtoků bude muset dojít k úpravě dispečerských grafů, které nebudou schopny podchytit dlouhá a suchá období. Jednou z možných alternativ řízení nádrží by mohla být kombinace dispečerského grafu s předpovědním modelem.

## Seznam zkratek a symbolů

ARIMA...	Autoregresní integrovaný klouzavý průměr
$t$ ...	Čas
$\Delta t$ ...	Časový krok
ČHMÚ...	Český hydrometeorologický ústav
$i$ ...	Číslo prvku
DG...	Dispečerský graf
FP...	Funkce příslušnosti
$\mu_A(x)$ ...	Funkce příslušnosti prvku $x$ k prostoru $A$
$\mu_B(x)$ ...	Funkce příslušnosti prvku $x$ k prostoru $B$
$R^2$ ...	Koeficient determinace
Matlab...	Matrix laboratory
MAX...	Maximum
m n.m. ...	Metrů nad mořem
mil....	Milionů
MIN...	Minimum
$x, y$ ...	Náhodné veličiny, proměnné
$O_p$ ...	Nalepšený odtok vody
$Q_1, Q_5, Q_{10}$ ....	N-leté průtoky
$\hat{y}$ ...	Odhad proměnné $y$
$O$ ...	Odtok
$O_\tau$ ...	Odtok z nádrže za daný měsíc
$V$ ...	Objem vody
$V_\tau$ ...	Objem vody v nádrži za daný měsíc
$A, B$ ...	Označení množin

$V_{0...}$	Počáteční objem vody
$N...$	Počet měsíců
$n...$	Počet předpovězených průtoků
$Q_{Q...}$	Poměr k průtoku
$y_i...$	Porovnávaná proměnná
$\tau...$	Pořadí časového kroku
$j...$	Pořadí měsíce
$U...$	Prostor proměnných
$Q_{\tau...}$	Průměrný měsíční průtok
$X_i...$	Průměrné měsíční průtoky
$Q...$	Průtok, přítok do nádrže
$Q_{\tau...}$	Průtok za daný měsíc
$Q_{snih...}$	Průtok přidání sněhem
$\hat{\theta}...$	Předpověď reálného prvku
$Z_{i,j...}$	Předpovězený průměrný průtok
$Q_p...$	Předpovězený průměrný měsíční průtok
$Q_r...$	Reálný průměrný měsíční průtok
$\theta...$	Reálný prvek
$a_1, a_2, a_3...a_k...$	Regresní koeficienty
RMSE...	Relativní střední kvadratická chyba (ang. root-mean-square error)
$\bar{y}...$	Střední hodnota proměnné $y$

## Použitá literatura

ČHMÚ, c2022. Hlásné profily. In: *ČHMÚ* [online]. Praha: ČHMÚ, 5.1.2022 [cit. 2022-01-05]. 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. 2022-01-05]. 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>

HON, Matěj, 2020. *Řízení zásobní funkce nádrže*. Brno, 53 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny.

HŘEBÍČEK, J. a J. KALINA. Klasifikace modelů [online]. Brno: Institut biostatistiky a analýz, 2017 [cit. 2022-01-03]. Dostupné také z: [https://is.muni.cz/el/1431/podzim2017/Bi3101/um/02\\_klasifikace\\_modelu.pdf](https://is.muni.cz/el/1431/podzim2017/Bi3101/um/02_klasifikace_modelu.pdf)

HUSÁK, Vladimír, c2010-2022. VD Vranov: 2. část. In: *Povodí Moravy* [online]. Brno: Mapový podklad ČÚZK [cit. 2022-01-05]. 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, 2022. Dyje. In: *Mapy.cz* [online]. Brno: Mapy.cz, 5. 1. 2022 [cit. 2022-01-05]. Dostupné z:  
<https://mapy.cz/zakladni?x=16.2936352&y=48.8300957&z=10&source=osm&id=143109918>

MATLAB, 2001-. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 5. 1. 2020 [cit. 2022-01-05]. Dostupné z:  
<https://cs.wikipedia.org/wiki/MATLAB>

NACHÁZEL, Karel, Jiří ZEZULÁK 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: VD Vranov* [online], c2010–2022. Brno: Media Age Digital [cit. 2022-01-07]. Dostupné z: <http://www.pmo.cz/cz/uzitecne/vodni-dila/vranov/>

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

PŘESLIČKA, Jiří. *Zpracování přehledu a popisu epizodních modelů srážko-odtokových událostí pro odnos látek*. České Budějovice, 2012. Bakalářská práce. Jihočeská univerzita v Českých Budějovicích, Zemědělská fakulta. Vedoucí práce Jana Moravcová.

Root-mean-square deviation, 2001. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 6 Srpna 2021 [cit. 2022-01-09]. Dostupné z:  
[https://en.wikipedia.org/wiki/Root-mean-square\\_deviation](https://en.wikipedia.org/wiki/Root-mean-square_deviation)

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.

TAUBEROVÁ, Dariana, 2018. *Systémový přístup k predikci vývoje cen na trhu rezidenčních nemovitostí*. Brno: Vysoké učení technické v Brně, Ústav soudního inženýrství. Disertační. Vysoké učení technické v Brně, Ústav soudního inženýrství. Vedoucí práce doc. Ing. et Ing. Stanislav Škapa, Ph.D.

Vranovská přehrada: Jak vzniklo toto vodní dílo, c2012. In: *Vranovsko.cz* [online]. Vranov nad Dyjí [cit. 2022-01-05]. 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.



## Seznam obrázků

Obr. 1.	Schéma nádrže (Kozel, 2017) .....	15
Obr. 2.	Rozdělení deterministických modelů (Přeslička, 2012) .....	18
Obr. 3.	Schéma modifikovaného zonálního modelu (Kozel,2017).....	20
Obr. 4.	Schéma neuronu (Nacházel, 2004) .....	21
Obr. 5.	Příklady funkcí příslušnosti (Nacházel, 2004).....	23
Obr. 6.	Příklady tvarů funkcí příslušnosti (Nacházel,2004) .....	23
Obr. 7.	Schéma fuzzy modelu .....	24
Obr. 8.	Schéma ústředního členu fuzzy regulátoru (Nacházel, 2004).....	26
Obr. 9.	Program Matlab .....	27
Obr. 10.	Zobrazení hloubky v nádrži (Husák, c2010-2022) .....	30
Obr. 11.	Plánek přehrady (Vranovská přehrada, c2012).....	31
Obr. 12.	Řeka Dyje (Mapy.cz, 2022) .....	33
Obr. 13.	Poloha měrné stanice (ČHMÚ, c2022) .....	33
Obr. 14.	Schéma předpovědního modelu .....	37
Obr. 15.	Fuzzy model.....	41
Obr. 16.	Funkce příslušnosti s Gaussovou křivkou.....	41
Obr. 17.	Ukázka skriptu předpovědního modelu .....	42
Obr. 18.	Rozdělení funkcí příslušnosti $Q_t$ .....	45
Obr. 19.	Rozdělení funkcí příslušnosti $Q_{t-1}$ .....	45
Obr. 20.	Stanovení těžiště ploch .....	47
Obr. 21.	Předpovědní rovina zobrazená ve 3D .....	48
Obr. 22.	Ukázka skriptu předpovědního modelu fuzzy části .....	51

## Seznam grafů

Graf 1.	Historická průtoková řada.....	34
Graf 2.	Vymezení zón v DG.....	36
Graf 3.	Vypouštěné množství podlé zón v DG.....	36
Graf 4.	Kalibrační průtoková řada 1935–2006.....	40
Graf 5.	Porovnání výsledků vybraných předpovědí při změně počtu zón .....	44
Graf 6.	Vybrané předpovědi porovnání počtu matic.....	45
Graf 7.	Vybrané předpovědi porovnání počátku iterací .....	46
Graf 8.	Vybrané předpovědi porovnání počtu iterací.....	47
Graf 9.	Porovnání reálného průtoku a prvního členu předpovědi.....	48
Graf 10.	Porovnání předpovědí prvního, druhého a třetího členu .....	49
Graf 11.	Porovnání reálného průtoku a předpovědi bez zavedení sněhem .....	53
Graf 12.	Porovnání reálného průtoku a předpovědi se zavedeným sněhem .....	53
Graf 13.	Validační řada simulace řízení.....	54
Graf 14.	Objem vody v nádrži simulace řízení dle dispečerského grafu a s předpovědí jednoho měsíce a osmi měsíců .....	55
Graf 15.	Odtok z nádrže simulace řízení dle dispečerského grafu a s předpovědí jednoho měsíce a osmi měsíců .....	55
Graf 16.	Porovnání fuzzy modelu a neuronové sítě v předpovědi 1. měsíce .....	57
Graf 17.	Porovnání fuzzy modelu a neuronové sítě v předpovědi 2. měsíce .....	57
Graf 18.	Porovnání fuzzy modelu a neuronové sítě v předpovědi 3. měsíce .....	58
Graf 19.	Porovnání předpovědních modelů při řízení.....	58

## Seznam tabulek

Tabulka 1. -	Rozdělení prostorů v nádrži (Povodí Moravy, c2010–2022).....	30
Tabulka 2. -	N-leté průtoky na Dyji v měrném profilu [ $\text{m}^3/\text{s}$ ] (Evidenční list hlásného profilu č.358) .....	32
Tabulka 3. -	Rozdělení objemů do zón.....	35
Tabulka 4. -	Rozdělení odtoků do zón.....	35
Tabulka 5. -	Porovnání výsledků počtu zón .....	43
Tabulka 6. -	Porovnání výsledků počtu matic .....	44
Tabulka 7. -	Porovnání výsledků nastavení počáteční hodnoty iterací .....	46
Tabulka 8. -	Porovnání výsledků počtu iterací .....	46
Tabulka 9. -	Hodnoty RMSE pro jednotlivé členy .....	49
Tabulka 10. -	Hodnoty RMSE pro jednotlivé měsíce na různých pozicích .....	50
Tabulka 11. -	Rozdělení průtoků tajícího sněhu .....	52
Tabulka 12. -	Porovnání RMSE předpovědí měsíce března .....	52
Tabulka 13. -	Porovnání simulace řízení .....	54
Tabulka 14. -	Porovnání předpovědí fuzzy modelu a neuronové sítě .....	56
Tabulka 15. -	Porovnání řízení .....	56