



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STAVEBNÍ

FACULTY OF CIVIL ENGINEERING

## ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

INSTITUTE OF LANDSCAPE WATER MANAGEMENT

## POPIS VAZBY PRŮTOKŮ A PLAVENIN VE VYBRANÝCH PROFILECH VODNÍCH TOKŮ

DESCRIPTION OF RELATION BETWEEN FLOW AND SUSPENDED SEDIMENT LOAD IN  
A HYDROMERTIC PROFILES OF A SELECTED RIVERS

### DIPLOMOVÁ PRÁCE

DIPLOMA THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Dominika Bobková

### VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. DANIEL MARTON, Ph.D.

BRNO 2021



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

## FAKULTA STAVEBNÍ

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

## ZADÁNÍ DIPLOMOVÉ PRÁCE

Student	Bc. Dominika Bobková
Název	Popis vazby průtoků a plavenin ve vybraných profilech vodních toků
Vedoucí práce	doc. Ing. Daniel Marton, Ph.D.
Datum zadání	31. 3. 2020
Datum odevzdání	15. 1. 2021

V Brně dne 31. 3. 2020

---

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

---

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

## PODKLADY A LITERATURA

Habersack H., Haimann M., Kerschbaumsteiner W., Lalk P. Leitfaden zur Erfassung des Schwebstofftransportes, Wien, 2017.

Hudíková, D. Vazba průtoků a sedimentů ve vybraném vodoměrném profilu povodí řeky Dyje.

Brno, 2019. 52 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.

MATLAB Tutorials and Learning Resources Link:

[http://www.mathworks.com/academia/student\\_center/tutorials/launchpad.html](http://www.mathworks.com/academia/student_center/tutorials/launchpad.html)

MATLAB and Simulink Tutorials Link:

[http://www.mathworks.com/academia/student\\_center/tutorials/](http://www.mathworks.com/academia/student_center/tutorials/)

Starý, M. Modul 01 Hydrologie, VUT FAST V Brně, Brno 2005

Winkler, S. Vliv sedimentů na hydrologické podmínky toku. Brno, 2018. 42 s., 0 s. příl. Bakalářská práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny.

Vedoucí práce Ing. Daniel Marton, Ph.D.

Zachoval, Z. Splaveniny ve vodních tocích: Modul 1. Brno, 2016.

## ZÁSADY PRO VYPRACOVÁNÍ

Problematika sedimentů jejich transport a následné ukládání v nádržích je důležité téma, které vnímá vodohospodářská odborná veřejnost velice vážně. Bilance toku sedimentů říčním systémem patří k důležitým nástrojům ohodnocení toků a nádrží v povodí z hlediska jejich sedimentačních procesů. Diplomová práce navazuje na výstupy bakalářské práce, které má za cíl dále rozšířit. Cílem práce je odhadnout možné závislosti mezi průměrnými denními průtoky vody a průměrnými denními hodnotami nerozpuštěných látek unášených v suspenzi v měrném profilu toku. K odvození využít regresní metody a metody umělé inteligence. Praktická aplikace bude provedena na vybraných vodoměrných profilech na řece Dyji a řece Svatce.

## 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).

---

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

## **ABSTRAKT**

Problematika vztahu mezi průtokem a koncentrací plavenin je celosvětově velmi řešené téma. Se znalostí koncentrací plavenin v tocích se dá vyhnout problémům s nadměrným zanášením vodních děl a předcházet tak nedostatečné kapacitě vodních nádrží. Tato diplomová práce částečně navazuje na bakalářskou práci, kterou rozšiřuje a zavádí nové postupy. K analýze vztahu mezi průtokem a koncentrací plavenin jsou využity neuronové sítě, přesněji vícevrstvé perceptronové neuronové sítě. Výsledky sítí jsou následně zpracovávány v programu Excel do podoby grafů a hodnoceny pomocí koeficientu determinace, Nash-Sutcliffeova koeficientu a koeficientu RMSE. Praktická aplikace je řešena na dvou profilech – profilu Podhradí nad Dyjí a profilu Židlochovice. Každý profil je zkoumán v jiném časovém období.

## **KLÍČOVÁ SLOVA**

vztah mezi průtokem a koncentrací plavenin, průtok, plaveniny, neuronové sítě, koeficient determinace, koeficient Nash-Sutcliffe, koeficient RMSE

## **ABSTRACT**

The issue of the relationship between water discharge and the suspended sediment loads is a globally highly addressed topic. Knowing the suspended sediment loads in the streams avoids problems with over-filling of water cannons and thus prevents insufficient capacity of water reservoirs. This thesis is partly a follow-up to the bachelor thesis, which extends and introduces new procedures. Neural networks, more specifically multilayer perceptron neural networks, are used to analyse the relationship between water discharge and suspended sediment loads. The results of the networks are then processed in Excel into graphs and evaluated using the coefficient of determination, Nash-Sutcliffe coefficient and RMSE coefficient. The practical application is solved on two profiles - the profile Podhradí nad Dyjí and the profile Židlochovice. Each profile is examined in a different period.

## **KEYWORDS**

discharge-suspended load relationship, discharge, suspended sediment, neural networks, coefficient of determination, Nash-Sutcliffe coefficient, RMSE coefficient

## **BIBLIOGRAFICKÁ CITACE**

Bc. Dominika Bobková *Popis vazby průtoků a plavenin ve vybraných profilech vodních toků*.  
Brno, 2020. 59 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav  
vodního hospodářství krajiny. Vedoucí práce doc. Ing. Daniel Marton, Ph.D.

## **PROHLÁŠENÍ O PŮVODNOSTI ZÁVĚREČNÉ PRÁCE**

Prohlašuji, že jsem diplomovou práci s názvem *Popis vazby průtoků a plavenin ve vybraných profilech vodních toků* zpracoval(a) samostatně a že jsem uvedl(a) všechny použité informační zdroje.

V Brně dne 15. 1. 2021

---

Bc. Dominika Bobková  
autor práce

## **PODĚKOVÁNÍ**

V první řadě děkuji všem pracovníkům Českého hydrometeorologického ústavu za poskytnutí dat ke studii, obzvláště pak paní RNDr. Jarmile Halířové za vstřícné a ochotné konzultování v průběhu řešení práce. Dále děkuji vedoucímu práce doc. Ing. Danielu Martonovi, Ph.D. za vedení, čas strávený nad diplomovou prací a za připomínky. Nakonec největší díky patří mému manželovi a zbytku rodiny za trpělivost a neúnavnou podporu.

# OBSAH

<b>1</b>	<b>ÚVOD</b>	<b>1</b>
<b>2</b>	<b>CÍL PRÁCE</b>	<b>2</b>
<b>3</b>	<b>SOUČASNÝ STAV POZNÁNÍ</b>	<b>3</b>
3.1	Výzkum v rámci projektu SEDECO (ATCZ 28)	3
3.2	Předpověď zatížení říčních systémů plaveninami pomocí neuronových sítí	5
3.3	Predikce koncentrace plavenin pomocí neuronových sítí na řece Ramganga v povodí Gangy, Indie	8
<b>4</b>	<b>METODY</b>	<b>10</b>
4.1	Neuronová síť	10
4.1.1	Vícevrstvá perceptronová síť	11
4.1.2	Učení NS	12
4.2	Standardizace dat	13
4.2.1	Standardizace směrodatnou odchylkou	13
4.2.2	Standardizace rozpětím	14
4.3	Statistické vyhodnocení	14
4.3.1	Střední hodnota	14
4.3.2	Směrodatná odchylka	14
4.3.3	Koeficient asymetrie	14
4.4	Metody vyhodnocení	15
4.4.1	Koeficient korelace $r$	15
4.4.2	Koeficient determinace $R^2$	16
4.4.3	Chyba $RMSE$ (root mean square error)	16
4.4.4	Koeficient Nash-Sutcliff $NSE$	17
<b>5</b>	<b>PRAKTICKÁ APLIKACE</b>	<b>18</b>
5.1	Hlásný profil Podhradí	18
5.1.1	Zpracovávaná data	19
5.1.2	Tvorba neuronových sítí	19
5.1.3	Vstupy vytvořených neuronových sítí a vytvořené sítě	20
5.1.4	Neuronové sítě 1	21
5.1.5	Neuronové sítě 2	23
5.1.6	Neuronové sítě 3	25



5.1.7	Neuronové sítě 4.....	29
5.1.8	Neuronové sítě 5.....	31
5.2	Hlásný profil Židlochovice .....	33
5.2.1	Zpracovávaná data.....	33
5.2.2	Vstupy vytvořených neuronových sítí .....	33
5.2.3	Neuronové sítě 1.....	34
5.2.4	Neuronové sítě 2.....	36
5.2.5	Neuronové sítě 3.....	38
5.2.6	Neuronové sítě 4.....	40
<b>6</b>	<b>SHRNUTÍ VÝSLEDKŮ .....</b>	<b>42</b>
6.1	Výsledky hlásného profilu Podhradí nad Dyjí.....	42
6.1.1	Statistické charakteristiky .....	42
6.1.2	Neuronové sítě 1.....	42
6.1.3	Neuronové sítě 2.....	43
6.1.4	Neuronové sítě 3.....	43
6.1.5	Neuronové sítě 4.....	45
6.1.6	Neuronové sítě 5.....	46
6.2	Výsledky hlásného profilu Židlochovice .....	48
6.2.1	Statistické charakteristiky .....	48
6.2.2	Neuronové sítě 1.....	48
6.2.3	Neuronové sítě 2, 3, 4.....	49
6.3	Zhodnocení výsledků .....	50
6.3.1	Porovnání povodí .....	50
6.3.2	Zhodnocení vstupů a architektury sítí .....	51
<b>7</b>	<b>ZÁVĚR.....</b>	<b>52</b>
<b>8</b>	<b>SEZNAM VYUŽITÉ LITERATURY.....</b>	<b>54</b>
<b>9</b>	<b>SEZNAM OBRÁZKŮ .....</b>	<b>56</b>
<b>10</b>	<b>SEZNAM TABULEK .....</b>	<b>59</b>

# 1 ÚVOD

Voda – životodárný prvek, podmínka k udržení života. Nejstarší osídlování ať na našem území nebo v cizích krajích vždy začínalo v úrodných údolích vodních toků. Egypťská říše, Mezopotámie, staří Inkové, ti všichni vynikali uměním zacházet s vodou, dopravovat ji z míst, kde je jí hodně na místa, kde chybí. Dříve byli lidé odkázáni na velké vodní toky, v současnosti si lidé zvykli na luxus pitné vody z kohoutku. Už malé děti vědí, že se vody v řece nemohou jen tak napít, že to není voda čistá. Později na základní škole se dozvídáme, že voda v tocích teče jako suspenze vody a drobných rozptýlených částic. Při dalších studiích se zjistí, že rozptýlené částice v závislosti na velikosti nazýváme buď plaveninami (částice menší než 0.63  $\mu\text{m}$ ) nebo splaveninami (částice větší než 0.63  $\mu\text{m}$ )[1]. Pohyb plavenin i splavenin je neoddelitelnou součástí proudění vody v tocích a v čase se přirozeně vyvíjí. Na druhou stranu v nádržích a místech, kde voda teče pomaleji mohou částice způsobovat komplikace v podobě neúměrného zanášení. V současnosti je s tímto tématem asi nejčastěji zmiňované zmenšování kapacity nádrží. Díky několika extrémně teplým a suchým rokům se v současnosti více řeší vodní zdroje, zásobování vodou a s tím spojené zásobní prostory na vodních dílech. Opakem byl přelom tisíciletí, kdy se řešil spíše druhý extrém – povodně. V té době se odborníci věnovali problematice využitelné protipovodňové kapacity v nádržích.

Zdroje splavenin a plavenin mohou být bodové, liniové a plošné. Jako bodový zdroj může sloužit např. přítok z kanalizací nebo přítok z melioračních potrubí, liniovým zdrojem je smyv z povrchu povodí a mezi plošné zdroje řadíme třeba vymílání povrchu koryta. Rovněž se musí uvažovat i bodové, liniové a plošné odběry splavenin. Měřením množství plavenin se zabývá v České republice Český hydrometeorologický ústav od roku 1984 [2].

Tím, jak lidstvo bere jako přirozené, že voda teče v suspenzi s dalšími látkami, se nabízí otázka, zda existuje nějaký vztah mezi množstvím vody a množstvím unášených látek. Touto otázkou se zabývá vytvořená diplomová práce. Základní myšlenkou je úvaha o vztahu mezi průtokem a koncentrací plavenin. Na začátku je nutné zdůraznit, že se uvažují pouze plaveniny, a ne dnové splaveniny. K popisu vazby plavenin a průtoků bylo využito neuronových sítí. Neuronové sítě je vhodné využívat v případech, kdy mezi vstupy a výstupy není snadno matematicky popsateľný vztah. Neuronové sítě se vyvíjely přibližně od 40. let minulého století, větší rozmach jim umožnila až nová výpočetní technika. Na území naší republiky se první zmínky o neuronových sítích objevují na konci 80. let, články o využití ve vodním hospodářství se objevují dokonce až od roku 1997 [3].

Práce částečně vychází z dřívější bakalářské práce autorky, ve které byla prokázána závislost mezi průtokem a koncentrací plavenin [4]. V bakalářské práci bylo využito pouze regresních proložení. V diplomové práci už jsou využity složitější metody, které musely být na počátku nastudovány a pochopeny. Pro výzkum jsou využity dva vodoměrné profily: Podhradí nad Dyjí a Židlochovice.

## 2 CÍL PRÁCE

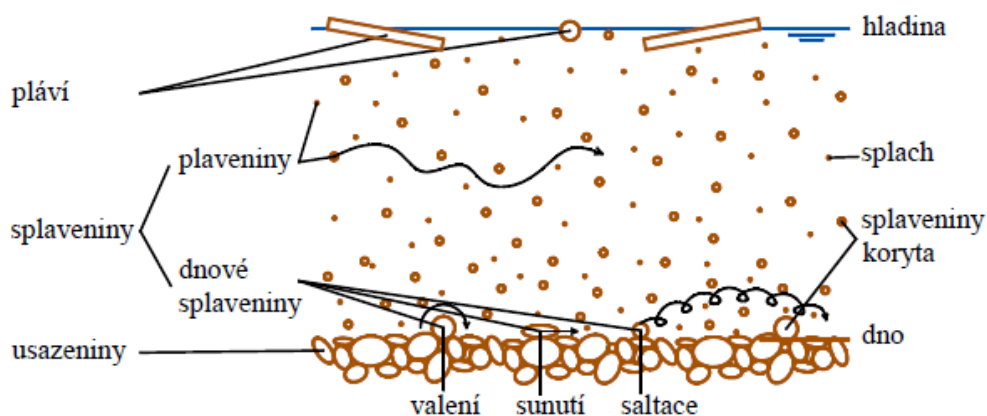
Cílem diplomové práce je analyzovat závislost mezi průměrným denním průtokem  $Q$  a průměrnou denní koncentrací plavenin  $c$  pomocí neuronových sítí na profilech Podhradí nad Dyjí na řece Dyji a na profilu Židlochovice na řece Svatce. Analýza je v případě profilu Podhradí prováděna na datech z 1. 11. 1994 – 31. 10. 1997. U profilu Židlochovice jsou k dispozici přerušovaná data z období 1. 1. 2008 – 31. 12. 2019.

U neuronových sítí byla pozornost zaměřena na tvorbu architektury neuronové sítě, tzn. na volbu vhodných vstupů a také na množství neuronů ve skryté vrstvě. Všechny neuronové sítě byly vytvořeny v programu MATLAB.

Vyhodnocení neuronových sítí bylo provedeno v programu Excel do podoby grafů a tabulek a je uvedeno v této diplomové práci.

### 3 SOUČASNÝ STAV POZNÁNÍ

V celé práci budou řešeny plaveniny. Pod pojmem plaveniny rozumíme neplovoucí drobné částice, pohybující se v proudu v suspenzi. Celá částice je tedy pod hladinou a jakoby se vznáší v proudu, názorně viz Obrázek 1[2].



Obrázek 1: rozdělení částic v toku [2].

S ohledem na pohyb částic v proudu kapaliny můžeme plaveniny popsat jako částice, jejichž usazovací rychlost je menší než rychlost zdvihová [2].

V mnoha publikacích už bylo dokázáno, že mezi koncentrací plavenin v proudu  $c$  a průtokem vody  $Q$  existuje závislost. Tato závislost byla ale dokazována různými způsoby. Díky výkonnějším výpočetním technikám se i v této oblasti využívá čím dál častěji umělé inteligence – přesněji neuronových sítí různého typu, případně fuzzy modely. Níže v této kapitole budou rozebrány některé provedené výzkumy, které jsou velmi blízké tématu této práce buď zkoumanou lokalitou nebo metodami.


#### 3.1 Výzkum v rámci projektu SEDECO (ATCZ 28)

Na půdě fakulty stavební VUT v Brně byl v roce 2019 prováděn výzkum závislosti mezi plaveninami a průtokem panem Ing. T. Kozlem a prof. M. Starým v rámci projektu SEDECO Sedimenty a ekosystémové služby ve vzájemném působení s povodněmi a suchem v pohraniční oblasti AT-CZ. Výzkum se týkal pouze stanice Podhradí nad Dyjí, kde byla využita řada průtoků a denních koncentrací plavenin v období od 1. 1. 1996 do 31. 10. 1997.

Autoři zkoumali závislosti pomocí dvou metod – regresními metodami, kde body byly aproximovány přímkou nebo polynomem  $n$ -tého stupně a pomocí umělé inteligence. Na rozdíl od této práce nebyly využity neuronové sítě, ale fuzzy model. Teorie fuzzy umí pracovat i s různými přechodnými stavy – např. pokud termínu vařící přiřadíme hodnotu 1 a zmrzlý hodnotu 0, přechodnými stavy mohou být vlažný, teplý, studený [5].


Jako kritérium hodnocení úspěšnosti aproximace byl využíván hlavně koeficient determinace  $R^2$ , dále pak Nash-Sutcliffův koeficient  $NSE$  a chyba  $E$ , což je suma kvadrátu

druhých mocnin rozdílu mezi měřenými daty a výsledky použité aproximace. Bylo dokázáno, že s posunem o jeden den se získávají lepší závislosti. Dále autoři zkoumali závislost mezi změnou průtoku a koncentrací plavenin. V této části výzkumu rozdělili data na vzestupnou a sestupnou větev. Každou větev pak aproximovali samostatně a opět uplatnili posun v čase o jeden den. Nakonec ale bylo zjištěno, že aproximace všech dat v celku bez rozdělení dosáhla lepších výsledků (Obrázek 2) [5].



Obrázek 2: porovnání výsledků dosažených aproximacemi v programu Excel [5].

V části, která se věnovala fuzzy modelům autoři vytvořili čtyři typy architektury. První typ měl pouze jeden vstup (průtok  $Q$ ). Druhý typ používal dva vstupy – průtok  $Q$  a průměr z aktuálního průtoku a dvou předchozích průtoků  $Q'$ . Třetí typ využíval opět dva vstupy – průtok  $Q$  a změnu průtoku  $\Delta Q$ . Poslední architektura byla navržena také se dvěma vstupy – se změnou průtoku  $\Delta Q$  a průměrem  $Q'$ . Nejlepších výsledků dosahoval poslední model, který zároveň vykazoval i lepší výsledky než regresní modely (Obrázek 3). [5]




Obrázek 3: porovnání výsledků regresních modelů a umělé inteligence [4].

### 3.2 Předpověď zatížení říčních systémů plaveninami pomocí neuronových sítí

Tento výzkum byl prováděn v USA na řekách Mississippi, Missouri a Rio Grande. Řeka Mississippi pramení na severozápadě Minnesoty a vlévá se do Mexického zálivu. Povodí řeky je hojně využíváno pro zemědělství. Tok samotný je velmi upraven pro plavbu zdymadly, kanály, přehradami. Řeka Missouri pramení v Jižní Montaně a v Kansasu se vlévá do Mississippi. Její povodí je také využíváno hlavně pro zemědělské účely. Poslední tok, Rio Grande, pramení v pohoří San Juan v Jižní Kalifornii a vlévá se také do Mexického zálivu [6].

Pro výzkum byly vybrány tři měrné stanice, na každém toku jedna. Stanice byly vybírány podle nepřetržitého záznamu. Mississippi byla zkoumána v letech 1971-1975, Missouri a Rio Grande v letech 1977-1981. Poloha měrných stanic a povodí viz Obrázek 4 [6].



Obrázek 4: plochy povodí a polohy měrných stanic [6].

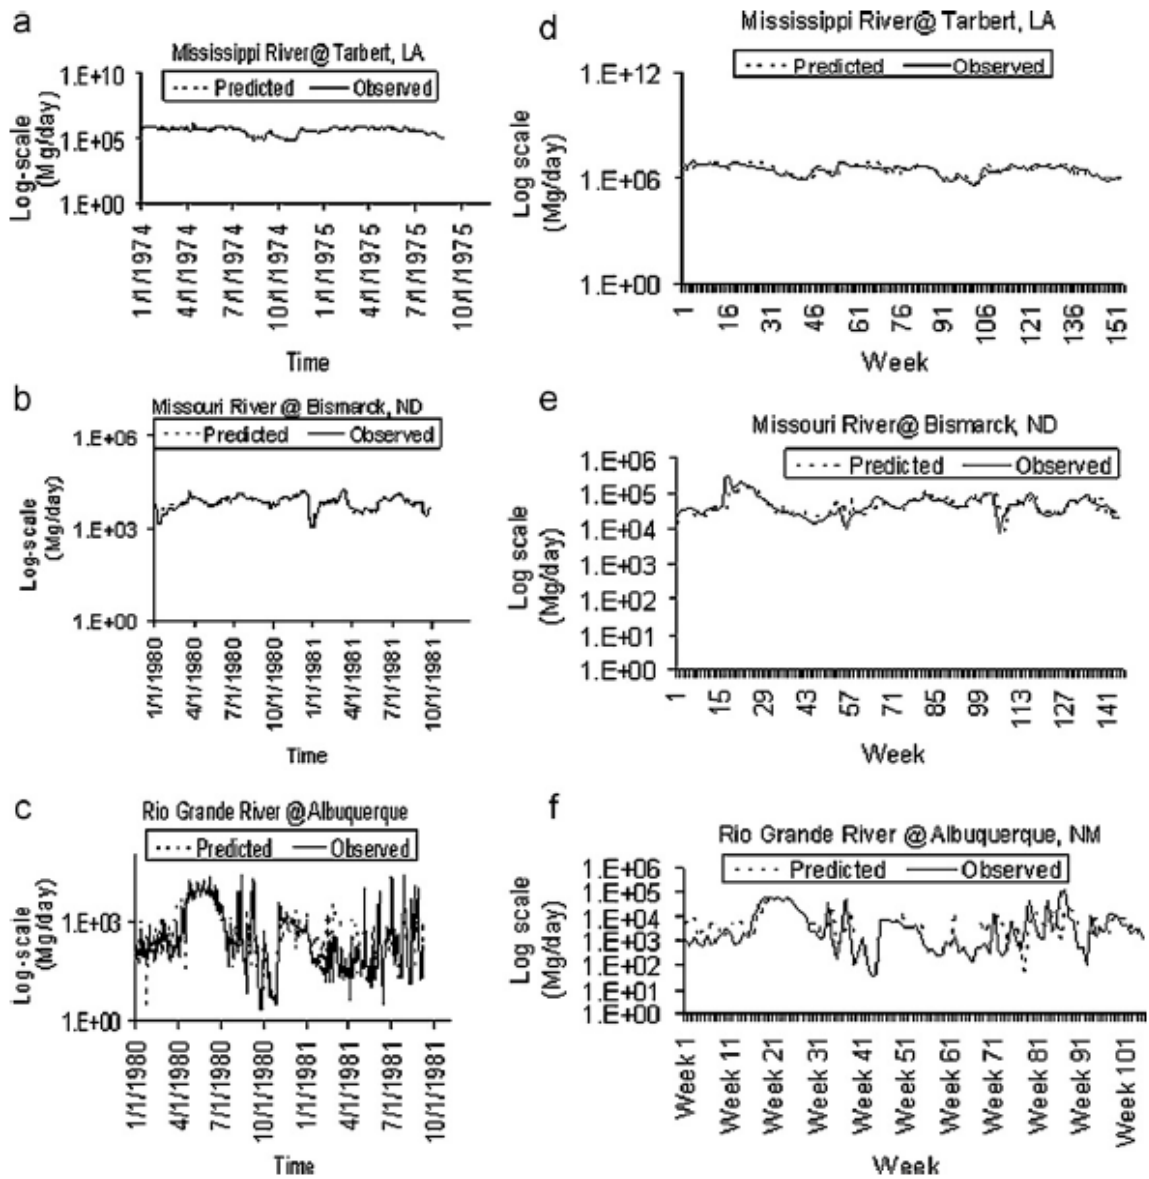
Jako vstupní data sloužily úhrny srážek  $P(t)$ , průměrný průtok  $Q(t)$ , průtok posunutý v čase  $Q(t-1)$ , množství plavenin posunuté v čase  $SL(t-1)$ . Data měla denní a týdenní krok. Všechna údaje byly standardizovány, aby jejich hodnoty byly v rozmezí 0,01-0,99. Dále byla pro všechny tři toky provedena statistická analýza. Ta zahrnovala výpočet disperze (rozptylu), koeficientu variace, koeficientu asymetrie (šikmosti), koeficientu špičatosti. Výsledkem této statistiky bylo zjištění, že řeka Mississippi má téměř normální rozdělení dat. Naopak řeka Rio Grande má velmi vysoký koeficient šikmosti a tím pádem silně asymetrické rozdělení. Také koeficient variace měla řeka Rio Grande vyšší než zbylé dva toky. Vyšší koeficient variace vede ke konvergenčním problémům při trénování neuronové sítě [6].

Simulace byly vytvářeny pomocí vícevrstvé perceptronové neuronové sítě (MLP) s jednou skrytou vrstvou a s algoritmem zpětné propagace (více o neuronových sítích viz kapitola 4.1). V rámci studie byly testovány tři možnosti rozdělení časové řady na trénovací a testovací data – 4 roky trénovací a 1 testovací, 3 roky trénovací a 2 testovací, 2 roky trénovací a 3 testovací. Dále byly vytvořeny tři různé architektury neuronových sítí. V první byly použity všechny vstupy ( $P(t)$ ,  $Q(t)$ ,  $Q(t-1)$ ,  $SL(t-1)$ ). Ve druhé bylo vynecháno  $P(t)$  a ve třetí  $P(t)$  a  $Q(t-1)$  [6].

Úspěšnost simulace byla hodnocena koeficientem determinace  $R^2$ , chybou  $RMSE$  (root mean square error), chybou  $MAPE$  (mean absolut percent error) a koeficientem Nash-Sutcliff  $E$ .

Výsledkem výzkumu bylo zjištěno, že pro řeky Mississippi a Missouri bylo dosaženo úspěšného simulování. U řeky Rio Grande nebylo dosaženo tak pěkných výsledků. Důvodem je nejspíše silně asymetrické rozdělení vstupních dat. Pro všechny tři toky architektura 1 se všemi vstupy a architektura 2 bez  $P(t)$  dávají hodně podobné výsledky. Vědci to vyhodnocují tak, že nejspíše v takto velkých povodích nezáleží na srážkovém úhrnu, ale na intenzitě srážek. Intenzita lépe poukazuje na erozní sílu srážky. V další části se řešilo, jakým způsobem rozdělit data na trénovací a testovací. Pro řeku Mississippi byl nejlepší poměr 4 roky trénovací a 1 testovací, univerzálním se ale ukázal poměr 3 roky trénovací a 2 testovací. Jako poslední část

se zkoumalo, jestli simulace bude lepší pro denní nebo týdenní krok. Bylo zjištěno, že denní krok vychází lépe – znázornění viz Obrázek 5, potvrzeno i koeficientem korelace  $r$ . Výsledky všech ukazatelů úspěšnosti viz Obrázek 6 [6].



Obrázek 5: výsledky simulace pro architekturu se všemi vstupy. Grafy a, b, c jsou pro denní data; d, e, f pro týdenní data [6].

(a)	Mississippi			Missouri			Rio Grande		
	Input 1 <sup>a</sup>	Input 2	Input 3	Input 1	Input 2	Input 3	Input 1	Input 2	Input 3
$R^2$	0.96	0.95	0.93	0.97	0.97	0.92	0.65	0.65	0.56
RMSE	54,928	55,248	63,033	668.3	665.7	1047.4	2072	2073	2377
MAPE	11.7	11.7	12.8	8.1	7.7	12.4	114.5	114.4	71.7
E	0.80	0.75	0.71	0.80	0.94	0.91	0.46	0.46	0.38

(b)	Mississippi			Missouri			Rio Grande		
	Input 1	Input 2	Input 3	Input 1	Input 2	Input 3	Input 1	Input 2	Input 3
$R^2$	0.87	0.84	0.8	0.84	0.7	0.64	0.4	0.4	0.3
RMSE	677,031	722,484	850,516	10,449	15,730	21,208	17,097	16,928	17,869
MAPE	16.8	15.9	25.5	9.7	18.9	21.6	112.5	597.3	104
E	0.6	0.6	0.53	0.55	0.32	0.44	0.25	0.26	0.2

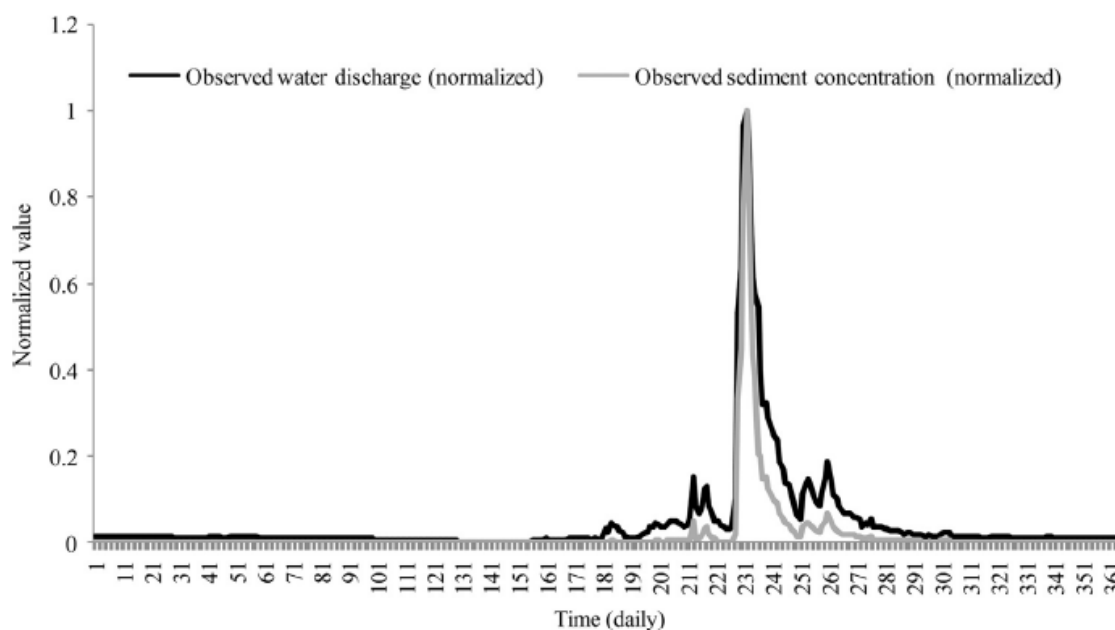
<sup>a</sup>Input 1 –  $P_{(t)}$ ,  $Q_{(t)}$ ,  $Q_{(t-1)}$ ,  $SL_{(t-1)}$ , Input 2 – Input 1 less  $P_{(t)}$  and Input 3 – Input 2 less  $Q_{(t-1)}$ .

Obrázek 6: výsledky ukazatelů úspěšnosti [6].



### 3.3 Predikce koncentrace plavenin pomocí neuronových sítí na řece Ramganga v povodí Gangy, Indie

Tento výzkum byl zveřejněn v roce 2017 a zabývá se výzkumem na toku Ramganga v Indii. Na tomto toku nebyl nikdy dříve dělán podobný výzkum. Řeka pramení v Himalájích a hydrický režim ovlivňuje hlavně období monzunových dešťů, které je od přelomu května a června do října až listopadu. Vědci měli k dispozici data denních koncentrací plavenin a průtoků za roky 2008-2011, které před využitím do neuronových sítí standardizovali, průběh průtoků a koncentrací plavenin po standardizaci viz Obrázek 7 [7].

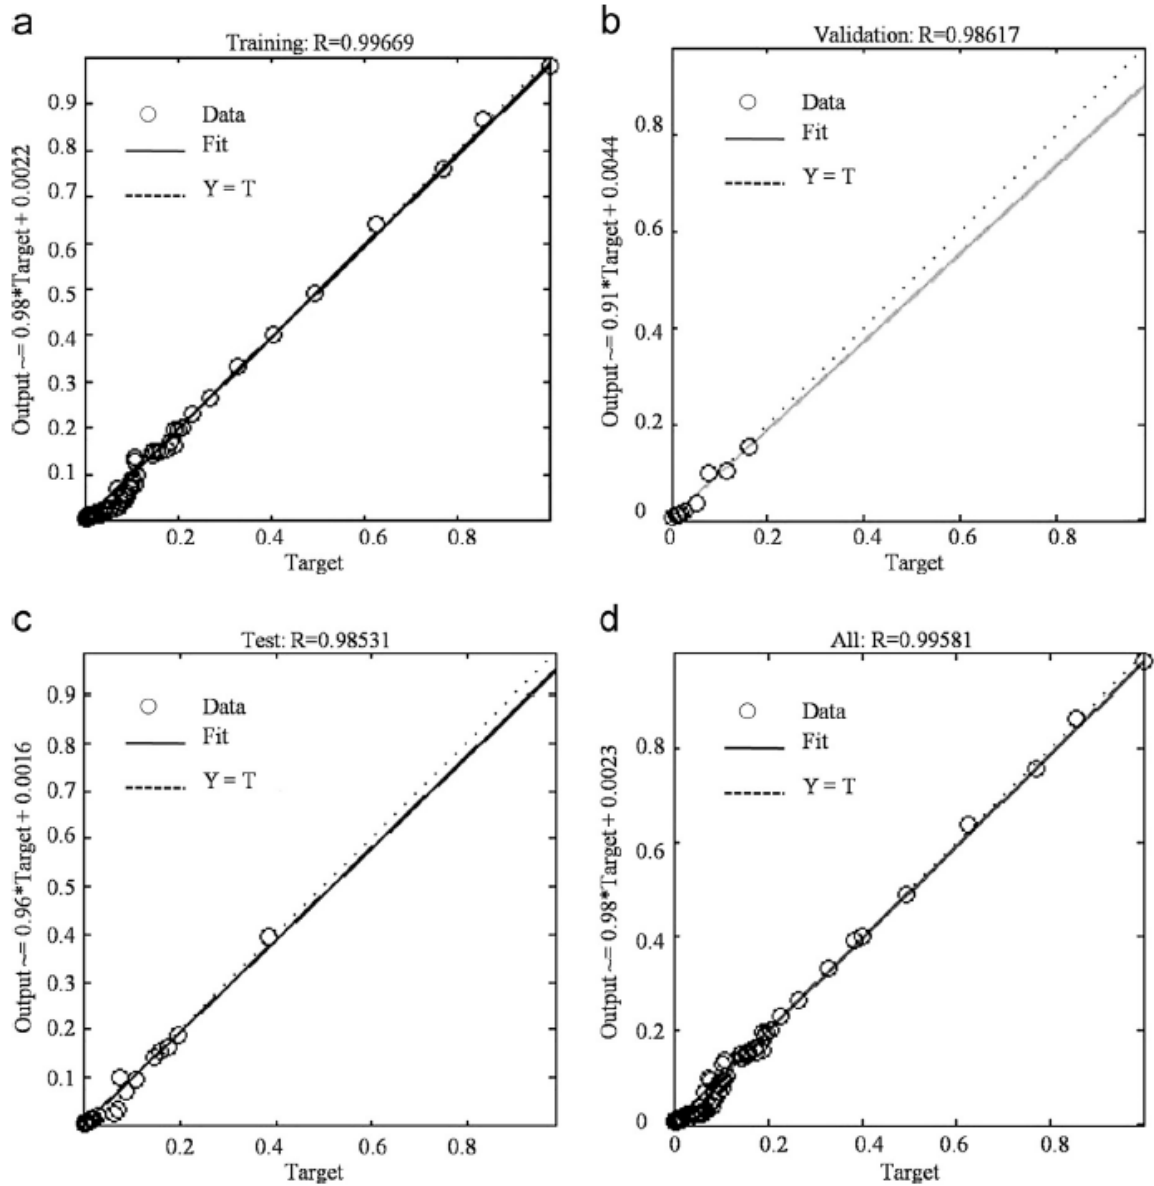


Obrázek 7: standardizované hodnoty průtoků a denních koncentrací plavenin na řece Ramganga [7].

Nejprve byla provedena statistická analýza, zahrnující průměrné hodnoty průtoků a koncentrací plavenin, medián, směrodatnou odchylku, koeficienty šikmosti a variace, autokorelační funkce atd. Dále byly vytvořeny tři neuronové sítě, které byly trénovány a testovány v prostředí MATLAB. V první síti T1 byl pro natrénování použit pouze rok 2010. Výstup z trénování v programu viz Obrázek 8. V další síti (T2) roky 2009 a 2010, v síti T3 roky 2008-2010. Žádná další data nebyla používána. Výzkum se také zaměřil na nalezení optimálního počtu neuronů ve skryté vrstvě, vyzkoušeno bylo od jednoho do deseti neuronů. V NS byl použit Levenberg-Marquardt Back Propagation algoritmus, který využívá sigmoidu jako transformační funkci. Úspěšnost sítí byla hodnocena pomocí koeficientu determinace  $R^2$  a chyby MSE.

Výsledkem je, že nejlepší předpovědi měla síť T1 s osmi neurony ve skryté vrstvě. Stačilo tedy málo dat pro nejpresnější výsledky. Co ovšem z výsledků není úplně jasné, jak mohla síť T1 předpovídat celý rok 2011, když autoři tvrdí, že vždy využívali 75 % dat na trénování a 25 % dat na testování.

Pro síť T2 byla nejlepší topologie s pěti neurony ve skryté vrstvě, T3 se šesti. Pro všechny tři sítě bylo dosaženo velmi vysokých hodnot  $R^2$  (hodnoty okolo 0,99) [7].



Obrázek 8: výstupy trénování, testování a validace pro síť T1 z programu MATLAB [7].

## 4 METODY


### 4.1 Neuronová síť

Neuronová síť (anglicky Artificial Neural Network), dále jen NS, je poslední dobou velmi používaná metoda, pro určení složitých vztahů mezi vstupními a výstupními veličinami. Počátky neuronových sítí sahají do 40. let minulého století. Větší rozšíření ovšem nastalo až s vývojem technologií, protože výpočet NS je poměrně náročný [2][8]. S jejich pomocí můžeme předvídat počasí, pohyb cen na burzách, hledat nebo rozpoznávat vzory v obraze, šifrovat data a spoustu dalších činností [9].

Při aproximaci matematicky těžko popsateľné funkce se jedná o nelineární regresní model, kterému bylo předlohou fungování neuronů v lidském mozku. Podobně, jako se lidský mozek umí učit z předchozích prožitých situací, mají i NS schopnost učit se. Vstupní veličiny mohou mít nahodilý charakter a výsledkem neuronové sítě nemusí být pouze jeden výstup [3][8].

Podle způsobu využití máme množství typů neuronových sítí – např. vícevrstvé perceptronové sítě, Kohonenovy samoorganizační mapy, Hopfieldovy sítě, samoorganizující se sítě... V této práci budou využity pouze vícevrstvé NS.

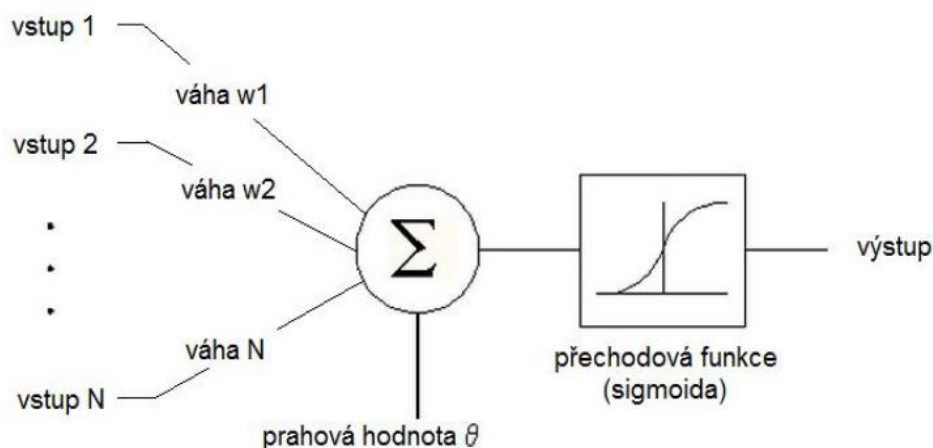
Vícevrstvé NS mají vždy vstupní vrstvu, skrytou vrstvu a vrstvu výstupní, základní schéma pro představu viz Obrázek 9.



Obrázek 9: základní tvar vícevrstvé neuronové sítě [10].

### 4.1.1 Vícevrstvá perceptronová síť

Terminologie u NS vychází z pojmů v lidském mozku. Uzlům NS se říká neurony. Každá vstupní proměnná  $x_i$  je na vstupu do neuronu  $j$  násobena koeficientem váhy  $w_i$ . Váha reprezentuje intenzitu vazby mezi neuronem a proměnnou a nabývá hodnot reálných čísel. Čím větší váha, tím významnější je daný vstup. Pokud má váha  $w$  hodnotu  $<0$ , dochází k útlumu daného vstupu. V případě vícevrstevných sítí se vazbám mezi proměnnou a neurony říká synapse. V neuronu probíhají dva procesy – výpočet potenciálu a výpočet hodnoty výstupu pomocí aktivační (přenosové funkce), schéma modelu neuronu viz Obrázek 10 [8][11].



Obrázek 10: model neuronu [12].

Matematicky můžeme výstup z neuronu obecně zapsat takto (1) [9]:

$$Y = f\left(\theta + \sum_{i=1}^n w_i x_i\right) \quad (1)$$

$x_i$  – vstup do neuronu,

$w_i$  – váha,


$\theta$  – prahová hodnota,

$f$  – aktivační (přenosová) funkce.

Pokud je  $\sum_{i=1}^n w_i x_i$  menší než prahová funkce  $\theta$ , neuron není aktivní [13].


Jako aktivační funkce se nejčastěji používá sigmoidea s rozsahem hodnot 0-1, ale je možnost použít i skokové, lineární prahové nebo třeba Gausovy funkce[8][11]. Funkční předpis sigmoidy podle rovnice (2), grafické zobrazení Obrázek 11 [13]:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$



Obrázek 11: graf sigmoidy [13].

Neurony bývají uspořádány do několika vrstev, kde propojení mezi vrstvami nazýváme topologie neuronové sítě (Obrázek 12) [12][14]. Neurony v rámci jedné vrstvy nemají propojení – pracujeme s nezávislými vstupy. Spojení mezi neurony, které představují dráhu šíření signálu, jsou orientována a každý spoj je ohodnocen svou vahou [14]. NS obsahuje kromě vstupní vrstvy alespoň jednu skrytou vrstvu neuronů, za kterou následují výstupní proměnné nebo jinak výstupní vrstva. Pokud by NS měla pouze vstupní a výstupní vrstvu, jednalo by se o lineární regresi [8][11].



Obrázek 12: topologie NS [14].

#### 4.1.2 Učení NS

Jak bylo zmíněno v úvodu, NS mají schopnost učit se z předchozích situací. Učení je takový proces, kdy je úkolem nastavit váhy vstupů  $w$  případně prahovou hodnotu neuronu tak, aby probíhala požadovaná transformace vstupů na výstupy. Učení obstarává algoritmus zpětného šíření chyby (backpropagation), který, zpravidla na základě iteračního postupu a výpočtu chyby metodou nejmenších čtverců, nastavuje hodnoty vah [8][13][14]. Tento algoritmus je nejrozšířenějším adaptačním algoritmem u vícevrstvých NS. Zároveň je obsažen i v programu MATLAB.

Algoritmus má tři etapy: dopředné šíření vstupního signálu s náhodnou hodnotou vah  $w$ , zpětné šíření chyby, a nakonec korekce váhových hodnot. Tyto tři etapy se opakují, dokud není dosaženo dostatečně malé chyby sítě nebo mezního počtu iterací nebo jiného kritéria pro zastavení iterací [13].

Aby proces probíhal správně, musíme na počátku výpočtů poskytnout systému data vstupní a jim odpovídající výstupy. Po nalezení vah předpokládáme, že získaná transformace bude dostatečně obecná, aby se dala využít i pro další neznámé dané oblasti, i když to tak nemusí být. Proto se množina dat rozděluje na dvě, případně tři části – na množinu dat trénovacích (využívané k učení), testovacích a případně validačních. Trénovací data by měla představovat největší část množiny. Nikde není napsána přesná hodnota, ale ve většině publikací se doporučuje okolo 70 % využít na trénování NS [14].

Problém učení u NS může nastat v několika momentech. Zaprvé je to případ, kdy byla zvolena špatná topologie sítě, přesněji bylo zvoleno malé množství neuronů a vrstev pro složitý problém. Neuronová síť se při hledání vah dostane do oblasti lokálního minima a není dosaženo požadovaných výsledků. Druhý problém může nastat v opačném případě – pokud je síť moc velká, může dojít k tzv. přeučení sítě (overfitting). Při přeučení dochází k tomu, že síť poskytuje dobré výsledky pro trénovací data, ovšem při použití na jakoukoli jinou množinu vstupů jsou výsledky nevyhovující [13].

## 4.2 Standardizace dat

Standardizace dat se využívá ve chvíli, kdy je potřeba pracovat s proměnnými, které mají různé jednotky. V případě této práce má průtok  $Q$  jednotky  $m^3/s$  a koncentrace plavenin  $c$  se udávají v  $mg/l$ . Dalším důvodem standardizace dat bylo využití sigmoidální aktivační funkce. Jak už bylo napsáno výše, sigmoida pracuje s rozsahem hodnot  $(0;1)$ . Všechny výpočty v programech Excel a MATLAB byly prováděny na standardizovaných datech. Pro standardizaci dat se může využívat několik metod, které jsou popsány v kapitolách 4.2.1 a 4.2.2.

### 4.2.1 Standardizace směrodatnou odchylkou

Tento typ standardizace je jedním z nejvyužívanějších, pracuje s ním i program Excel pod příkazem STANDARDIZE. Pro získání standardizované hodnoty je zapotřebí získat průměr hodnot a směrodatnou odchylku proměnné [15]. Standardizace se vypočte podle vzorce (3) [15].

$$y_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma} \quad (3)$$

$x_{ij}$  – původní hodnota,

$\bar{x}_j$  – průměr původních hodnot,

$\sigma$  – směrodatná odchylka

Pokud mají data normální rozložení, rozsah hodnot přibližně od -3 do 3 [15]. Pro zkoumané profily jsou data silně nerovnoměrná, hodnoty vychází přibližně v rozmezí -0,5 až 25. Zároveň pro další použití v programech by záporné hodnoty nedávaly smysl, byl tedy zvolen jiný druh standardizace.

## 4.2.2 Standardizace rozpětím

Někdy se také v literatuře uvádí jako „min-max normalizace“. Doporučuje se právě v případech, kdy proměnné nemají normální rozdělení nebo obsahují odlehlé hodnoty. Díky této standardizaci získáváme proměnné v rozmezí 0-1. Standardizace se vypočítá podle vzorce (4) [15].

$$y_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)} \quad (4)$$

$x_{ij}$  – původní hodnota,

$\min(x_j)$  – minimální hodnota proměnných,


$\max(x_j)$  – maximální hodnota proměnných.

Tento typ standardizace byl využit pro všechna vstupní data.

## 4.3 Statistické vyhodnocení

### 4.3.1 Střední hodnota

Střední hodnotu značíme  $\mu_x$  a udává x-ovou souřadnici těžiště hustoty pravděpodobnosti. Vypočítá se jako hodnota prvního obecného momentu [3].



Obrázek 13: grafické zobrazení střední hodnoty [3].

### 4.3.2 Směrodatná odchylka


Odmocnina ze druhého centrálního momentu (případně odmocnina z disperze nebo také rozptylu) se nazývá směrodatná odchylka, kterou značíme jako  $\sigma_x$ . [3]

### 4.3.3 Koeficient asymetrie

Nebo také koeficient šikmosti popisuje naklonění grafu hustoty pravděpodobnosti. Určí se jako podíl třetího centrálního momentu a třetí mocniny směrodatné odchylky [3]. V programu Excel se dá vyvolat funkcí SKEW.

$$C_{s,x} = \frac{M_3(x)}{\sigma^3(x)} \quad (5)$$

Pokud je koeficient  $C_s=0$ , graf hustoty pravděpodobnosti je symetrický. Pokud je  $C_s>0$ , graf je nakloněný doleva, když je  $C_s<0$ , naklání se doprava. Názorněji je vše zobrazeno na Obrázek 14.



Obrázek 14: koeficient asymetrie [3].

## 4.4 Metody vyhodnocení

### 4.4.1 Koeficient korelace $r$

Koeficient korelace ukazuje na míru lineární vazby mezi dvěma soubory dat. Může nabývat hodnot  $<-1;1>$  a čím blíže leží výsledek  $\pm 1$ , tím výraznější je vztah mezi dvojicí dat. Od hodnoty 0,6 uvažujeme závislost mezi soubory [3].

Koeficient korelace se vypočítá podle vztahu (6) [4]:

$$r = \left( \frac{\sum_{i=1}^n (O_i - \bar{O}) \cdot (P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \cdot \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right) \quad (6)$$


$O_i$  – naměřená hodnota

$P_i$  – předpovězená hodnota v čase

$\bar{O}$  – průměr z naměřených hodnot

$\bar{P}$  – průměr z předpovězených hodnot





Obrázek 15: grafické znázornění koeficientu korelace [3].

#### 4.4.2 Koeficient determinace $R^2$

Koeficient determinace se vypočítá podle rovnice (7)[6]:

$$R^2 = \left( \frac{\sum_{i=1}^n (O_i - \bar{O}) \cdot (P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \cdot \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (7)$$

$O_i$  – naměřená hodnota

$P_i$  – předpovězená hodnota v čase

$\bar{O}$  – průměr z naměřených hodnot

$\bar{P}$  – průměr z předpovězených hodnot

Pomocí koeficientu determinace se vyjadřuje míra závislosti. Koeficient determinace může nabývat hodnot  $\langle 0;1 \rangle$ . Pokud je  $R^2 > 0,5$ , uvažujeme mezi veličinami závislost. Čím více se hodnota blíží 1, tím více jsou na sobě veličiny závislé [6].

#### 4.4.3 Chyba $RMSE$ (root mean square error)

$RMSE$  se vypočítá s použitím vztahu (8) [6]:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (8)$$

$O_i$  – naměřená hodnota

$P_i$  – předpovězená hodnota v čase

$n$  – počet naměřených hodnot

Chyba  $RMSE$  nabývá pouze kladných hodnot a je velmi citlivá na velké chyby. V praxi se snažíme  $RMSE$  vždy minimalizovat. Dobře se hodí na porovnání chyby různých modelů konkrétní proměnné, méně se hodí na porovnávání chyb modelů mezi různými proměnnými [4][6].

#### 4.4.4 Koeficient Nash-Sutcliff *NSE*

Nash-Sutcliffův koeficient se vypočítá podle rovnice (9) [4]:

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (9)$$

$O_i$  – naměřená hodnota

$P_i$  – předpovězená hodnota v čase

$\bar{O}$  – průměr z naměřených hodnot

Koeficient může nabývat hodnot  $(-\infty; 1]$  s tím, že hodnoty menší než 0 signalizují, že předpovídané hodnoty jsou horším ukazatelem než měřené hodnoty, což je u matematických modelů nepřijatelné. Nevýhoda koeficientu *NSE* je, že rozdíly mezi naměřenými a předpovídanými hodnotami jsou umocňovány, takže větší hodnoty jsou silně nadhodnocovány a nižší hodnoty jsou podhodnocovány. Ideálně by se měly hodnoty *NSE* co nejvíce blížit jedné [4].

## 5 PRAKTICKÁ APLIKACE

Praktická aplikace měla následující posloupnost:

1. Volba hlásných profilů – diplomová práce volně navazuje na bakalářskou práci [14], ovšem jako hlavní profil výzkumu byl tentokrát zvolen profil v Podhradí nad Dyjí. Při bližším zkoumání profilu Trávní Dvůr byl tento profil vyhodnocen jako nevyhovující pro nalezení závislostí mezi koncentrací plavenin a průtoků. Dále byl zvolen profil Židlochovice.
2. Získání dat z ČHMÚ.
3. Standardizace dat – s ohledem na další využití dat v programu MATLAB byla zvolena standardizace rozpětím (viz kapitola 4.2.2). Po standardizaci nabývají data hodnot  $<0;1>$ , což je nutné pro transformaci sigmoidální aktivační funkcí v NS.
4. Výpočet dalších statistických charakteristik – koeficient korelace, koeficient šikmosti, směrodatná odchylka.
5. Vytvoření strategie výpočtů NS.
6. Rozdělení dat na trénovací (cca 70 % dat), testovací (cca 20 % dat) a validační, tvorba tréninkových matic.
7. Tvorba typologie NS.
8. Vyhodnocení NS pomocí koeficientů  $R^2$ ,  $RMSE$ ,  $NSE$ .

### 5.1 Hlásný profil Podhradí

Profil se nachází v Jihomoravském kraji v obci Podhradí nad Dyjí, na pravém břehu Dyje 200 metrů pod jezem. Provozovatelem stanice je ČHMÚ Brno. Data ze stanice sbírá ČHMÚ Brno a Vodohospodářský dispečink Povodí Moravy Brno. [17]

Číslo hydrologického pořadí:	4-14-02-007
Plocha povodí:	1755,49 km <sup>2</sup>
Nula vodočtu:	348,36 m n. m.
Průměrný roční stav:	69,0 cm
Průměrný roční průtok:	8,81 m <sup>3</sup> ·s <sup>-1</sup>



Obrázek 16: poloha měrného profilu v Podhradí nad Dyjí [18].


### 5.1.1 Zpracovávaná data

Na profilu Podhradí ČHMÚ provádělo měření průměrné denní koncentrace plavenin  $c$  (dále jen koncentrace plavenin) a průměrných denních průtoků  $Q$  (dále jen průtoků) v hydrologických letech 1995-1997. Pro model byla využita celá řada od 1. 11. 1994 do 31. 10. 1997. Data nejsou přerušena výpadky v měření. Jak bylo uvedeno v americké studii, NS dosahují lepších výsledků při ponechání denního časového kroku než kroku hrubšího (např. měsíc). Proto i v tomto případě jsou využívány průměrné denní koncentrace plavenin a průměrné denní průtoky.

Tři hydrologické roky tvoří 1096 dní. Tento počet je potřeba rozdělit na data trénovací, testovací a validační. Pro natrénování bylo použito 731 dní (67 % dat) z časového intervalu 1. 11. 1995 – 31. 10. 1997. Pro testování bylo použito 242 dní (22 %) z období 1. 11. 1994 – 30. 6. 1996. Na validaci byla použita zbylá data (11 %) z období 1. 7. 1995 – 31. 10. 1995. Toto rozdělení dat bylo zvoleno, protože je vhodné mít v rámci trénovacích dat pokryty extrém – minimální a maximální hodnotu [2]. Rozdělení je shodné pro všechny typy NS, které byly pro profil Podhradí vytvořeny.

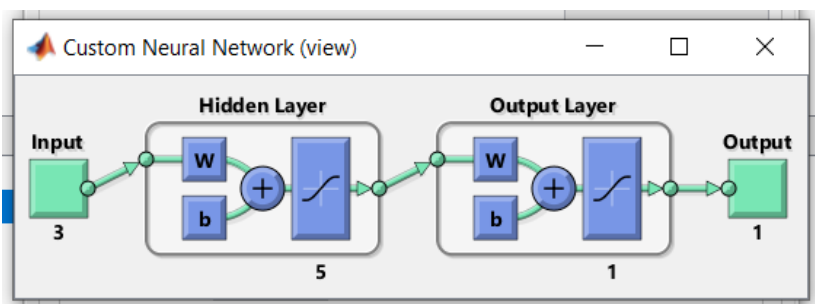
### 5.1.2 Tvorba neuronových sítí

Všechny NS byly vytvořené v programu MATLAB. Nástroj pro vytváření sítí se vyvolá příkazem *nntool* a další práce je poměrně intuitivní. Jako vstupní data (*Input*) je potřeba nahrát všechna data, která potřebujeme jako vstup. Takže data trénovací, testovací i validační. Jako výstup (*Target*) nahráváme data trénovací a validační. Názorně viz Obrázek 17.



Obrázek 17: import dat pro vytvoření NS v programu MATLAB.

Po importu dat vytvoříme neuronovou síť. Zde se udává typ NS (Feed-forward backpropagation), vstupy a výstupy (trénovací data), aktivační funkce (sigmoida), počet vrstev (2) a počet neuronů ve skryté vrstvě (Obrázek 18).



Obrázek 18: schéma vytvořené NS se třemi vstupy a pěti neurony ve skryté vrstvě.

Počet vstupů a neuronů ve skryté vrstvě byly jediné dva parametry, které se měnily. V dalších kapitolách budou jednotlivé architektury více popsány. Cílem práce bylo nalézt optimální vstupy do NS a zároveň optimální počet neuronů ve skryté vrstvě. Minimální počet neuronů byl volen jako počet vstupů do NS. Maximální počet neuronů byl vzat přibližně jako dvojnásobek vstupů.

### 5.1.3 Vstupy vytvořených neuronových sítí a vytvořené sítě

Do neuronových sítí byly postupně vkládány tyto vstupy – viz Tabulka 1. Vstupy jsou všechny bezrozměrné, vkládané po standardizaci, proto nejsou uváděny jednotky. Výstupem ze všech NS je průměrná denní koncentrace plavenin  $c$ . Seznam vytvořených sítí je znázorněn v Tabulka 2.

Tabulka 1: vstupy použité do NS pro profil Podhradí.

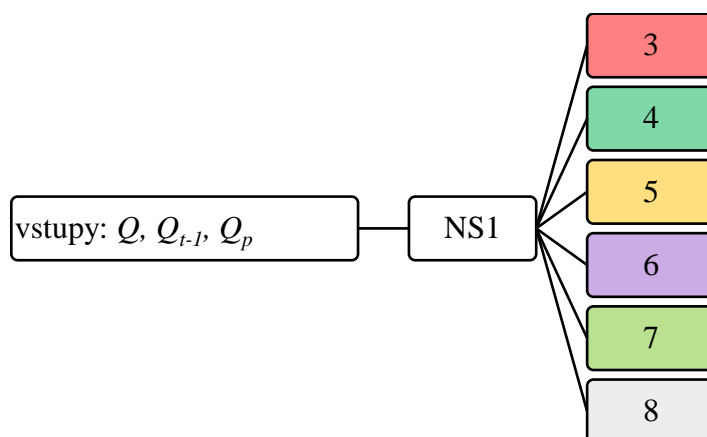
Vstup	Značka
průměrný denní průtok	$Q$
průměrný denní průtok z předchozího dne	$Q_{t-1}$
průměr průměrných denních průtoků aktuálního dne a dvou předešlých dnů	$Q_p$
průměrná denní koncentrace plavenin z předchozího dne	$c_{t-1}$
denní úhrn srážky	$H$
průměrný denní úhrn srážek ze tří měrných stanic	$H_p$
průměrný denní úhrn srážek ze tří měrných stanic z předchozího dne	$H_{p-1}$

Tabulka 2: NS vytvořené pro profil Podhradí.

Název neuronových sítí	Počet neuronů ve skryté vrstvě	Vstupy
NS1	3-8	$Q, Q_{t-1}, Q_p$
NS2	4-9	$Q, Q_{t-1}, Q_p, c_{t-1}$
NS3	5-10	$Q, Q_{t-1}, Q_p, c_{t-1}, H$
NS4	5-10	$Q, Q_{t-1}, Q_p, c_{t-1}, H_p$
NS5	5-10	$Q, Q_{t-1}, Q_p, c_{t-1}, H_{p-1}$

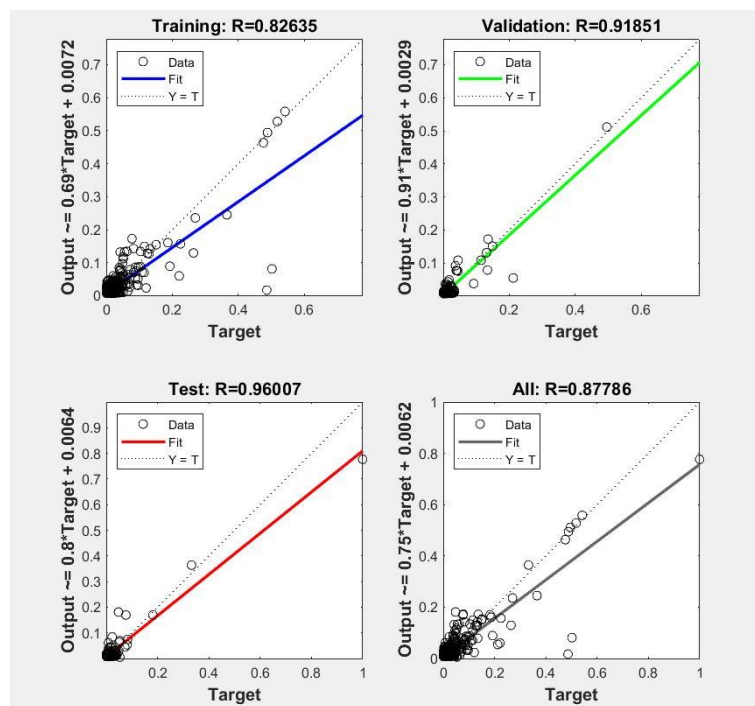
#### 5.1.4 Neuronové sítě 1

Neuronová síť 1 – dále jen NS1 má tři vstupy: průměrný denní průtok  $Q$ , průměrný denní průtok  $Q$  v čase  $t-1$  ( $t = \text{den}$ ) a průměr aktuálního průtoku  $Q$  a průtoků ve dvou předchozích dnech  $Q_{t-1}$  a  $Q_{t-2}$ . Výstup je pouze jeden – průměrná denní koncentrace plavenin. Ve schématu jsou nalevo vypsány vstupy, a čísla napravo ukazují počty neuronů ve skryté vrstvě. Stejný systém je využit pro všechna schémata NS.




Obrázek 19: schéma stupňů a počtu neuronů ve skryté vrstvě NS1.

Pro skrytou vrstvu bylo zvoleno 3-8 neuronů, vzniklo tedy 6 různých NS. Každá NS byla natrénovaná tak, že ukazatele  $R$  dosahovaly hodnot alespoň 0.8 – čím blíže je hodnota 1, tím lépe je NS natrénovaná (Obrázek 20).




Obrázek 20: trénování NS.

Pro testovací a validační data byly následně v programu Excel vypočítány hodnotící koeficienty –  $RMSE$ ,  $R^2$ ,  $NSE$ .



Obrázek 21: výsledky simulace denní koncentrace plavenin pro testovací data NS1.

V grafu na Obrázek 21 je vidět, že všechny NS u testovacích dat simulovaly přibližně střední hodnotu a pouze v pár místech, kdy koncentrace prudce narostla, je i v simulaci vidět nějaký výraznější vzestup. Na první pohled je ale zřejmé, že NS s těmito vstupy nedokážou dobře reagovat na denní průběh koncentrací plavenin. Zajímavé jsou výsledky s průběhy simulací na validačních datech (Obrázek 22).



Obrázek 22: výsledky simulace denní koncentrace plavenin pro validační data NS1.

Při porovnání výsledků na simulování trénovacích a testovacích dat (Obrázek 21 a Obrázek 22) je až zarážející podobnost. Síť v obou případech přibližně po třech měsících nasimuluje strmý nárůst koncentrace plavenin, v případě validačních dat je ale tento nárůst naprosto mimo.

Tabulka s výsledky hodnotících koeficientů jen potvrzuje nevyhovující výsledky (Tabulka 3). Všechny sítě mají hodnotu  $R^2$  hluboko pod hranici 0.5, která určuje hranici dobré simulace. Navíc hodnoty koeficientu  $NSE$  jsou pro validační data menší než 0, což značí špatné schopnosti simulace.


Tabulka 3: výsledky hodnotících koeficientů NS1 pro testovací a validační data.

Neuronů	Testovací data			Validační data		
	RMSE	$R^2$	NSE	RMSE	$R^2$	NSE
3	0.015	0.133	0.072	0.015	0.026	-0.131
4	0.015	0.108	0.087	0.018	0.019	-0.551
5	0.014	0.182	0.169	0.019	0.026	-0.648
6	0.014	0.139	0.121	0.019	0.013	-0.672
7	0.014	0.184	0.167	0.019	0.031	-0.715
8	0.014	0.177	0.140	0.018	0.030	-0.594

### 5.1.5 Neuronové sítě 2

Neuronová síť 2 – dále jen NS2, má čtyři vstupy. Tak jako v NS1 byly použity průměrný denní průtok  $Q$ , průměrný denní průtok  $Q$  v čase  $t-1$  ( $t = \text{den}$ ) a průměr aktuálního průtoku  $Q$  a průtoků ve dvou předchozích dnech  $Q_{t-1}$  a  $Q_{t-2}$ . Navíc byly přidány hodnoty průměrné denní koncentrace plavenin v čase  $t-1$  ( $c_{t-1}$ ). Výstup je opět pouze simulace průběhu denní koncentrace plavenin  $c$ .







Obrázek 23: schéma vstupů a počtu neuronů ve skryté vrstvě NS2.

Díky tomu, že NS má čtyři vstupy i ve skryté vrstvě byly zvoleny minimálně čtyři neurony. Maximálně bylo ve skryté vrstvě použito devět neuronů, tím vznikl stejný počet NS jako v případě NS 1.

Výsledky simulací NS jsou znázorněny na Obrázek 24 a Obrázek 25.



Obrázek 24: výsledky simulace denní koncentrace plavenin pro testovací data NS2.



Obrázek 25: výsledky simulace denní koncentrace plavenin pro validační data NS2.

NS2 dosáhla při simulování trénovacích dat lepších výsledků než NS1, pro validační data ovšem vychází podobně neuspokojivé výsledky jako v případě NS1. Podobnost mezi oběma sítěmi je vidět v grafech, NS2 stejně jako NS1 vytvořila v září ve validačních datech nesmyslný skokový vrchol. Zajímavé je, že pro síť s osmi neurony byla u koeficientu  $R^2$  překročena hranice 0.5 pro testovací data ( $R^2 = 0.533$ ). Validační data ale ukazují, že síť nesimuluje dobře, protože koeficient NSE vychází menší než nula ( $NSE = -0.102$ ) a  $R^2$  výrazně menší než 0.5 ( $R^2 = 0.091$ ).


Všechny výsledky NS viz Tabulka 4.

Tabulka 4: výsledky hodnotících koeficientů NS2 pro testovací a validační data.

Neuronů	Testovací data			Validační data		
	RMSE	$R^2$	NSE	RMSE	$R^2$	NSE
4	0.012	0.411	0.353	0.017	0.069	-0.342
5	0.013	0.338	0.314	0.018	0.051	-0.486
6	0.013	0.288	0.261	0.019	0.035	-0.694
7	0.014	0.429	0.204	0.016	0.055	-0.270
8	0.012	0.533	0.333	0.015	0.091	-0.102
9	0.013	0.438	0.330	0.020	0.049	-0.865


### 5.1.6 Neuronové síť 3

Neuronová síť 3 (NS3) vychází ze vstupů NS2 ( $Q$ ,  $Q_{t-1}$ ,  $c_{t-1}$ , průměr  $Q-Q_{t-2}$ ), plus jsou přidána data denních úhrnů srážek ( $H$ ).



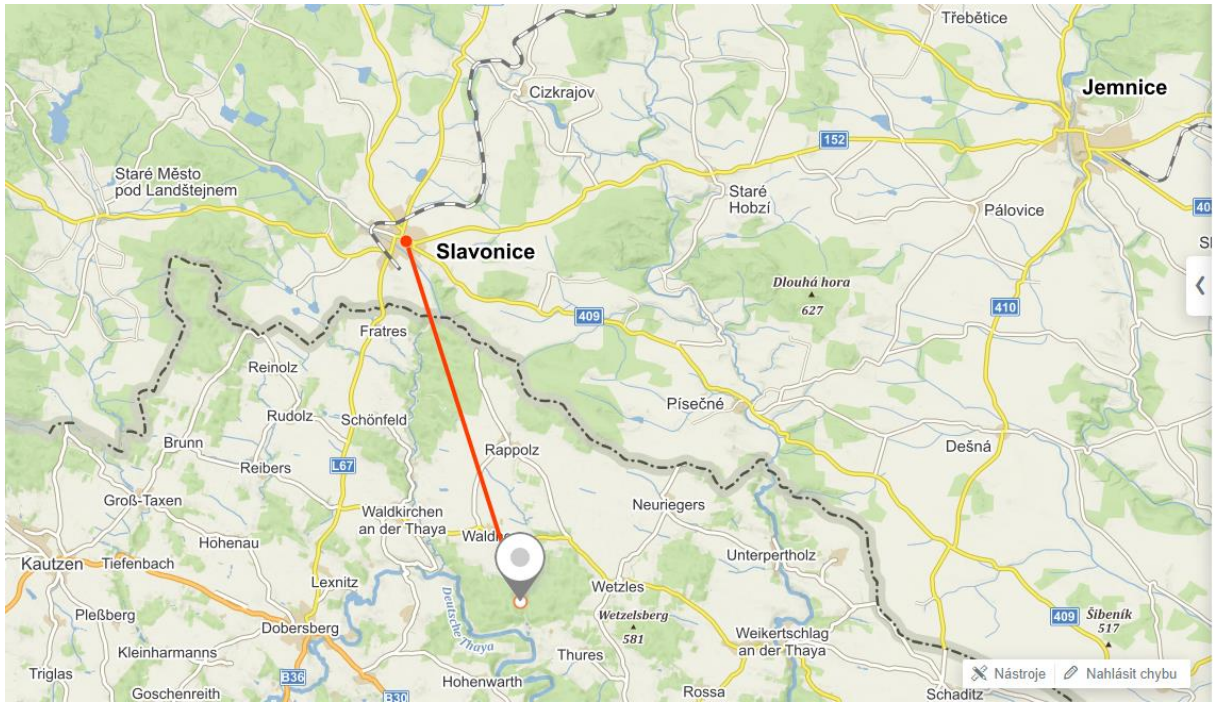
**Obrázek 26: schéma vstupů a počtu neuronů ve skryté vrstvě NS3.**

Nejprve bylo potřeba určit hranice povodí po profil Podhradí nad Dyjí. Pro přesnější simulaci by nejspíše bylo vhodné využít větší množství srážkoměrných stanic, v začátcích ale nebylo jisté, jak moc data denních úhrnů srážek ovlivní síť. V Americké studii (viz kapitola 3.2) bylo popsáno, že v jejich případě data denních úhrnů velký vliv neměla. Srážkoměrná stanice byla volena co nejbližší k těžišti povodí. K nalezení těžiště byl využit program QGIS3 a data z Digitální báze vodohospodářských dat (DIBAVOD) – přesněji data povodí III. a IV. řádu [18]. Díky tomu, že Dyje tvoří v mnoha místech hranici s Rakouskem, velká část jejího povodí zasahuje právě i do Rakouska a zde také leží těžiště zkoumané oblasti.




**Obrázek 27: povodí Dyje po profil Podhradí nad Dyjí.**

Při hledání srážkoměrné stanice bylo vycházeno z předpokladu snadnějšího přístupu k datům z České republiky. Proto byla vybrána stanice ve Slavonicích, které leží vzdušnou čarou necelých devět kilometrů od těžiště zkoumané oblasti (Obrázek 28).




Obrázek 28: vzdálenost těžiště zkoumané oblasti od srážkoměrné stanice ve Slavonicích [18].

Díky tomu, že je pět vstupů, bylo do skryté vrstvy voleno minimálně pět neuronů. Maximálně bylo využito deset neuronů do skryté vrstvy, tím vzniká stejné množství NS jako v případě NS1 a NS2.



Obrázek 29: výsledky simulace denní koncentrace plavenin pro testovací data NS3.



Obrázek 30: výsledky simulace denní koncentrace plavenin pro validační data NS3.

Při pohledu na graf simulování testovacích dat (Obrázek 29) je na první pohled zřejmé, že sítě dokázaly lépe reagovat na změny v koncentracích plavenin. U validačních dat některé sítě opět nasimulovaly extrémní nárůst koncentrací plavenin (Obrázek 30), ale obecně si v porovnání s NS1 a NS2 s problémem poradily nejlépe. Tomu odpovídají i výsledky pro validační data – poprvé se hodnoty NSE dostaly ve většině případů nad hodnotu nula (Tabulka 5).

Tabulka 5: výsledky hodnotících koeficientů NS3 pro testovací a validační data.

Neuronů	Testovací data			Validační data		
	RMSE	R <sup>2</sup>	NSE	RMSE	R <sup>2</sup>	NSE
5	0.012	0.473	0.400	0.005	0.060	0.471
<b>6</b>	<b>0.011</b>	<b>0.484</b>	<b>0.471</b>	<b>0.001</b>	<b>0.373</b>	<b>0.227</b>
7	0.013	0.236	0.227	0.002	0.035	0.178
8	0.014	0.192	0.178	0.002	0.013	0.131
9	0.014	0.133	0.131	0.002	0.024	0.205
10	0.014	0.280	0.205	0.001	0.100	0.000

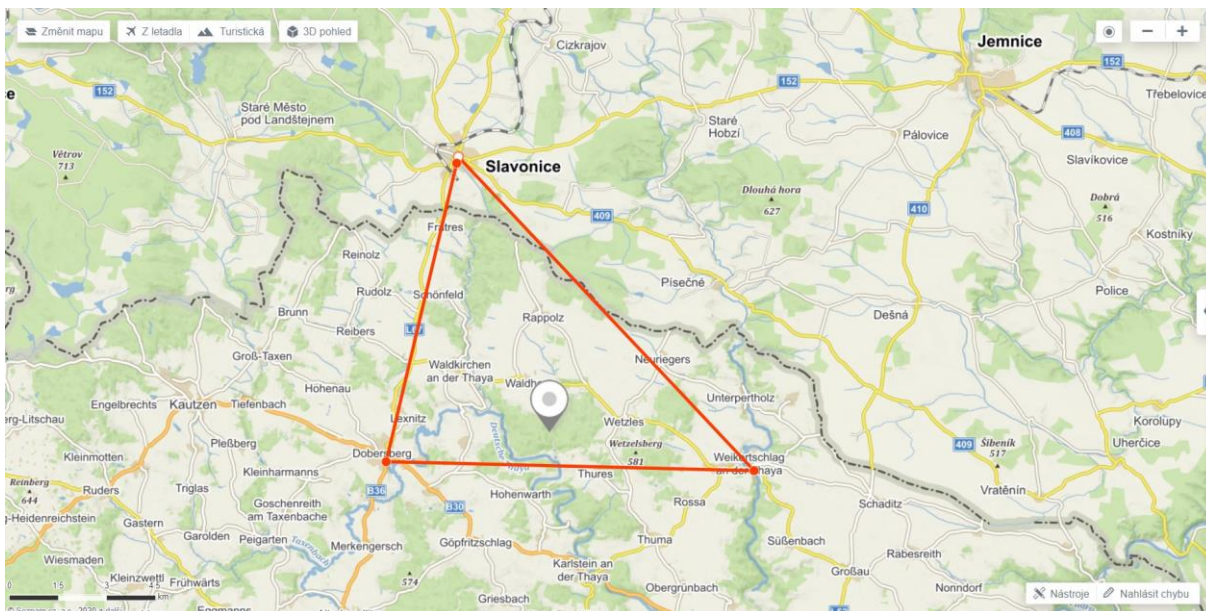
V tabulce s výsledky je vidět, že sítě s pěti a šesti neurony ve skryté vrstvě dosáhly v případě testovacích dat hodnot koeficientu determinace poblíž 0.5. Ovšem pro validační data má síť s pěti neurony ve skryté vrstvě horší schopnosti, síť se šesti neurony dosahuje lepších výsledků. Všechny předešlé sítě nedokázaly na menší změny v koncentracích reagovat a simulovaly přibližně konstantní hodnoty.

Z dosažených výsledků můžeme udělat závěr, že data denních úhrnů srážek jsou dobrým vstupem do NS. Proto bylo dále zkoumáno, jak s pomocí srážek sítě ještě vylepšit.




### 5.1.7 Neuronové síť 4

V další síti bylo pokračováno v lepším zakomponování dat denních úhrnů. Byl získán přístup k datům ze srážkoměrných stanic z Rakouska, které jsou blíže k těžišti zkoumané části povodí. Přesněji byly vybrány dvě stanice – v obci Dobersberg a obci Weikertschlag an der Thaya. Tyto dvě stanice společně se stanicí ve Slavonicích tvoří trojúhelník srážkoměrných stanic (Obrázek 31). Data z těchto tří míst byla zprůměrována a použita v síti NS4.



Obrázek 31: trojice použitých srážkoměrných stanic okolo těžiště povodí [18].

Do NS4 vstupují  $Q$ ,  $Q_{t-1}$ ,  $c_{t-1}$ , průměr  $Q-Q_{t-2}$  a průměr denních úhrnů ze tří stanic  $H_p$ . Počet vstupů je stejný jako v NS3, tím je stejný i počet neuronů ve skryté vrstvě (od pěti do deseti).




Obrázek 32: schéma vstupů a počtu neuronů ve skryté vrstvě NS4.


Výsledkem simulace jsme dostaly dvě sítě (s pěti a sedmi neurony ve skryté vrstvě), které mají hodnotu  $R^2$  blízko 0.5 pro testovací data, v případě sítě s pěti neurony se pro testovací data získala i lepší hodnota  $R^2$  než u sítě NS3 (Obrázek 33). Validační data ale u sítě NS4 obecně vychází hůř než v případě NS3. U sítí se šesti a osmi neurony byly hodnoty  $NSE$  dokonce menší než nula. To se v případě NS3 nestalo u žádné ze sítí. Všechny výsledky hodnotících koeficientů viz Tabulka 6.

**Tabulka 6: výsledky hodnotících koeficientů NS4 pro testovací a validační data.**

Neuronů	Testovací data			Validační data		
	RMSE	R <sup>2</sup>	NSE	RMSE	R <sup>2</sup>	NSE
5	0.011	0.498	0.446	0.001	0.185	0.106
6	0.013	0.233	0.232	0.002	0.064	-0.681
7	0.011	0.473	0.441	0.001	0.233	0.121
8	0.013	0.335	0.298	0.001	0.074	-0.096
9	0.013	0.372	0.264	0.001	0.295	0.200
10	0.013	0.430	0.305	0.001	0.183	0.127




**Obrázek 33: výsledky simulace denní koncentrace plavenin pro testovací data NS4.**



**Obrázek 34: výsledky simulace denní koncentrace plavenin pro validační data NS4.**

### 5.1.8 Neuronové sítě 5

Posledním typem je NS 5, která využívá vstupy NS4 ( $Q$ ,  $Q_{t-1}$ ,  $c_{t-1}$ , průměr  $Q-Q_{t-2}$ ), ale  $H_p$  je nahrazeno  $H_p$  s posunem o jeden den zpět ( $H_{p-1}$ ). Ve skryté vrstvě bylo opět použito pět až deset neuronů.




Obrázek 35: schéma vstupů a počtu neuronů ve skryté vrstvě v NS5.

Výsledkem této simulace je síť s deseti neurony ve skryté vrstvě, která dosáhla koeficientu determinace pro testovací data  $R^2 = 0.584$  a pro validační data  $R^2 = 0.408$ . I ostatní koeficienty mají přijatelné hodnoty, takže tuto síť můžeme uvažovat jako dobrý výsledek. Další síť z NS5 už nedosahují tak dobrých výsledků, většina z nich má u validace hodnoty  $NSE$  menší než nula, což je neakceptovatelné. Všechny hodnotící parametry pro NS5 viz Tabulka 7. Tím, že síť nevychází dobře, tak pouze pro ilustraci výsledky z testovacích dat viz Obrázek 36.

Tabulka 7: výsledky hodnotících koeficientů NS5 pro testovací a validační data.

Neuronů	Testovací data			Validační data		
	RMSE	$R^2$	NSE	RMSE	$R^2$	NSE
5	0.014	0.185	0.183	0.001	0.011	-0.189
6	0.016	0.060	-0.132	0.001	0.002	-0.132
7	0.012	0.415	0.346	0.001	0.134	0.002
8	0.014	0.166	0.154	0.001	0.101	-0.062
9	0.014	0.242	0.188	0.001	0.098	-0.009
<b>10</b>	<b>0.010</b>	<b>0.584</b>	<b>0.583</b>	<b>0.001</b>	<b>0.408</b>	<b>0.085</b>





Obrázek 36: výsledky simulace denní koncentrace plavenin pro testovací data NS5.

V návaznosti na dobré výsledky s časovým posunem denního úhrnu srážek o jeden den byly vytvořeny ještě nějaké další sítě (např. s posunem srážek o dva dny nebo s vynecháním průměru průtoků). Jejich výsledky ale nedosahovaly akceptovatelných výsledků, takže zde už nebudou zmíněny.

## 5.2 Hlásný profil Židlochovice

Tento profil se nachází na řece Svatce na pravém břehu toku v obci Židlochovice. Provozování a sběr dat má na starosti ČHMÚ Brno [19].

Číslo hydrologického pořadí:	4-15-03-114
Plocha povodí:	3938.12 km <sup>2</sup>
Nula vodočtu:	177.89 m n. m.
Průměrný roční stav:	87.00 cm
Průměrný roční průtok:	15.10 m <sup>3</sup> ·s <sup>-1</sup>



Obrázek 37: hlásný profil Židlochovice.

### 5.2.1 Zpracovávaná data

V Židlochovicích se provádí měření průtoků a koncentrací plavenin od 1. 1. 2008 do současnosti. S ohledem na vytváření práce bylo zvoleno koncové datum na 31. 12. 2019. Bohužel data nejsou úplně kompletní, například od února do konce září 2011 probíhalo testování nového způsobu měření nebo třeba v září 2015 bylo měření ovlivňováno velmi nízkými hladinami vody, tím docházelo k sání plavenin ze dna.

Celkem je zpracováváno 3896 dní (přibližně 10.5 roku). Chronologicky prvních 2740 dní, 70 % dat, je použito na trénování sítě. Trénovací data opět obsahují oba extrémy. Dalších 791 dní je použito na testování sítě (20 % dat) a posledních 365 dní je využito pro validaci.

Toto rozdělení bylo využito pro všechny NS vytvořené pro profil Židlochovice.

### 5.2.2 Vstupy vytvořených neuronových sítí

Nejdříve bylo předpokládáno, že se pro profil Židlochovice použijí stejné architektury sítí, jako pro profily v Podhradí. Hned po natrénování první sítě byly ale zjištěny problémy se stejnými vstupními parametry, takže byly vytvořeny jiné tréninkové matice. Vstupy do NS jsou opět vypsány v tabulce Tabulka 8 a všechny vytvořené NS jsou v Tabulka 9.

Tabulka 8: vstupy použité v NS pro profil Židlochovice.


Vstup	Značka
průměrný denní průtok	$Q$
průměrný denní průtok z předchozího dne	$Q_{t-1}$
průměr průměrných denních průtoků aktuálního dne a dvou předešlých dnů	$Q_p$
průměrná denní koncentrace plavenin z předchozího dne	$c_{t-1}$
denní úhrn srážky	$H$
průměrný denní úhrn srážek ze tří měrných stanic	$H_p$

Tabulka 9: NS vytvořené pro profil Židlochovice.

Název neuronových sítí	Počet neuronů ve skryté vrstvě	Vstupy
NS1	3-8	$Q, Q_{t-1}, Q_p$
NS2	4-9	$Q, Q_{t-1}, Q_p, c_{t-1}$
NS3	5-10	$Q, Q_{t-1}, Q_p, c_{t-1}, H$
NS4	5-10	$Q, Q_{t-1}, Q_p, c_{t-1}, H_p$
NS5	5-10	$Q, Q_{t-1}, Q_p, c_{t-1}, H_{p-1}$


### 5.2.3 Neuronové síť 1

U NS1 se částečně vycházelo z výsledků pro profil Podhradí. Tam se ukázalo, že volit mezi vstupy pouze průtoky je pro síť nedostatečné, takže kromě průtoků ( $Q, Q_{t-1}, Q_p$ ) byla rovnou zařazena koncentrace plavenin z předchozího dne ( $c_{t-1}$ ). V rámci NS1 byly vytvořeny síť se čtyřmi až devíti neurony ve skryté vrstvě.




Obrázek 38: schéma vstupů a počtu neuronů ve skryté vrstvě v NS1.

Výsledky z NS pro testovací data viz Obrázek 39, výsledky pro validační data viz Obrázek 40.



Obrázek 39: výsledky simulace denní koncentrace plavenin pro testovací data NS1 ze Židlochovic.



Obrázek 40: výsledky simulace denní koncentrace plavenin pro validační data NS1 ze Židlochovic.

Z obou grafů je patrné, že nasimulovaná data nemají od naměřených dat žádné velké odchylky. Netvoří žádné konstantní hodnoty a zdá se, že opravdu pěkně kopírují naměřené hodnoty. Při pohledu na výsledky hodnotících koeficientů získáváme ale poměrně špatné hodnocení, nikde není koeficient determinace  $R^2 > 0.5$  zároveň ale také  $NSE$  není nikde  $< 0$  (viz Tabulka 10)

**Tabulka 10: výsledky hodnotících koeficientů NSI pro testovací a validační data.**

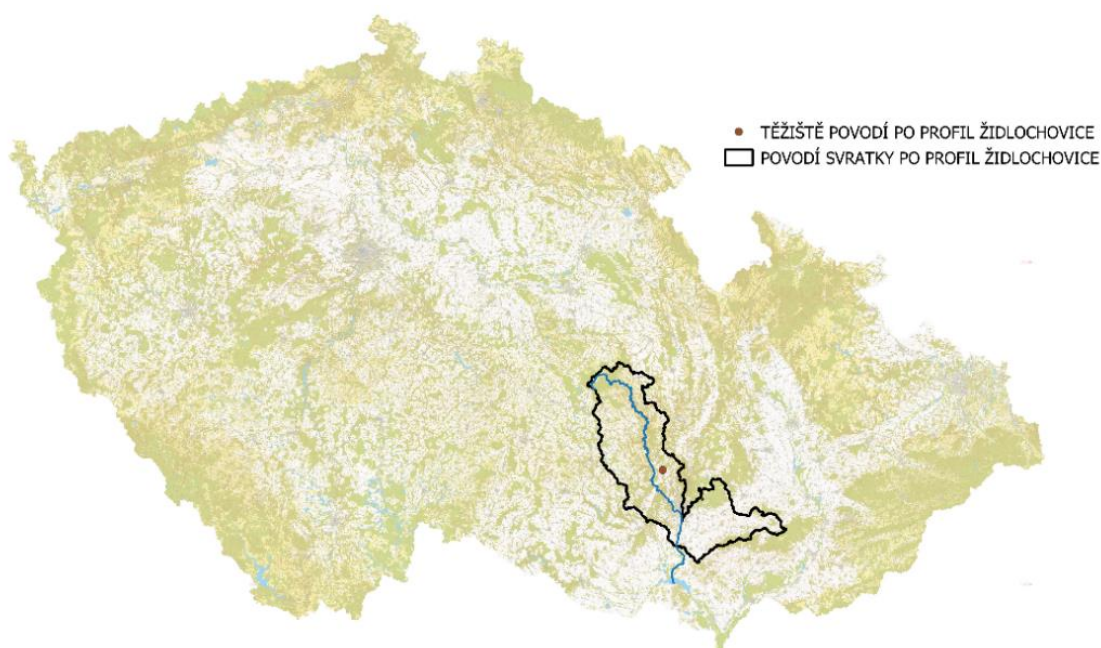
Neuronů	Testovací data			Validační data		
	RMSE	R <sup>2</sup>	NSE	RMSE	R <sup>2</sup>	NSE
4	0.018	0.242	0.870	0.023	0.251	0.136
5	0.018	0.213	0.864	0.021	0.284	0.234
6	0.019	0.215	0.863	0.021	0.240	0.233
7	0.019	0.166	0.857	0.022	0.218	0.166
8	0.018	0.278	0.805	0.022	0.252	0.175
9	0.018	0.249	0.817	0.022	0.241	0.211

Při hledání důvodů takto nízkého hodnocení bylo zjištěno, že síť se naučila vzít si hodnotu koncentrace plavenin z předchozího dne ( $c_{t-1}$ ) a všechny ostatní vstupy hodně potlačit. Tudíž výsledkem neuronové sítě bylo v podstatě pouze uvedení hodnoty koncentrace plavenin z předchozího dne.

Toto chování je pro síť, která by mohla sloužit k predikci nepřijatelné. Proto bylo v dalších sítích byl tento vstup odstraněn a bylo zjišťováno, jak budou síť schopné simulovat.


#### 5.2.4 Neuronové sítě 2

Pro tyto sítě byl mezi vstupy zařazen průměrný denní srážkový úhrn  $H$  ze stanice co nejbliž těžišti povodí. Těžišť povodí bylo opět zjišťováno v programu QGIS3 a jako vstupy byly použity povodí III. a IV. řádu (Obrázek 41). Těžišť bylo nalezeno nejbliž k městu Tišnov, bohužel v těchto místech nebylo prováděno sledování srážkových úhrnů v potřebném rozsahu. Proto byla zvolena srážkoměrná stanice v obci Kuřim, která je od těžišť vzdálena přibližně 6 km (Obrázek 42).




**Obrázek 41: povodí Svatky po profil Židlochovice.**





Obrázek 42: vzdálenost těžiště povodí od obce Kuřim [18].

Jako vstupy do NS 2 byly využity  $Q$ ,  $Q_{t-1}$ ,  $H$ , do skryté vrstvy bylo nastaveno tři až osm neuronů.




Obrázek 43: schéma vstupů a počtu neuronů ve skryté vrstvě v NS2.


Výsledky hodnotících koeficientů jsou v Tabulka 11, výstupy ze simulace jsou na Obrázek 44, Obrázek 45.

Tabulka 11: výsledky hodnotících koeficientů NS2 pro testovací a validační data.

Neuronů	Testovací data			Validační data		
	RMSE	R <sup>2</sup>	NSE	RMSE	R <sup>2</sup>	NSE
3	0.020	0.000	0.796	0.025	0.130	-0.040
4	0.021	0.001	0.748	0.026	0.074	-0.131
5	0.020	0.020	0.793	0.025	0.157	-0.059
6	0.020	0.026	0.804	0.025	0.101	-0.052
7	0.020	0.020	0.794	0.025	0.155	-0.052
8	0.020	0.037	0.805	0.024	0.258	0.062



Obrázek 44: výsledky simulace denní koncentrace plavenin pro testovací data NS2 ze Židlochovic.



Obrázek 45: výsledky simulace denní koncentrace plavenin pro validační data NS2 ze Židlochovic.

Z grafů a tabulky s hodnotícími koeficienty je patrné, že sítě si vedly v simulacích hodně špatně. Jak pro testovací, tak pro validační data jsou vytvořeny téměř konstantní hodnoty, které jsou změněny jen v místech největších výkyvů.  $R^2$  je hodně pod hodnotou 0.5 a  $NSE$  je téměř ve všech případech  $<0$ .

### 5.2.5 Neuronové sítě 3


Pro tyto sítě byly vybrány, podobně jako v Podhradí nad Dyjí, tři srážkoměrné stanice, ze kterých by se udělal průměrný srážkový úhrn  $H_p$ . Bohužel dvě ze tří nejbližších stanic – Tišnov

a Veverská Bitýška neměly data z požadovaného období. Takže se zvolily tři vzdálenější stanice, které měly požadovaný rozsah měření – Velká Bíteš (přibližně 19 km daleko), Sejřek (přibližně 15 km od těžiště), Blansko (přibližně 12 km).



Obrázek 46: trojice využitých stanic [18].

Z těchto tří stanic byl vytvořen průměrný srážkový úhrn  $H_p$ . Jako další vstupy byly použity všechny ze sítě NS2 – celkem tedy NS3 obsahuje čtyři vstupy, dva vstupy s průtoky a dva s hodnotami úhrnů srážek ( $Q$ ,  $Q_{t-1}$ ,  $H$ ,  $H_p$ ).




Obrázek 47: schéma vstupů a počtu neuronů ve skryté vrstvě v NS3.

Při pohledu na výsledné grafy jak pro testovací (Obrázek 48), tak pro validační data (Obrázek 49) je jasné, že síť opět vytváří neakceptovatelné výsledky. I když bylo zvoleno o vstup víc, ničemu to nepomohlo a síť si opět drží téměř konstantní hodnoty. Výsledky hodnotících koeficientů v Tabulka 12.


Tabulka 12: výsledky hodnotících koeficientů NS3 pro testovací a validační data.

Neuronů	Testovací data			Validační data		
	RMSE	R <sup>2</sup>	NSE	RMSE	R <sup>2</sup>	NSE
4	0.020	0.021	0.764	0.026	0.069	-0.145
5	0.021	0.004	0.770	0.026	0.033	-0.180
6	0.020	0.028	0.804	0.025	0.251	-0.021
7	0.020	0.017	0.774	0.025	0.157	-0.064
8	0.020	0.037	0.794	0.025	0.177	-0.024
9	0.020	0.005	0.780	0.025	0.119	-0.069






Obrázek 48: výsledky simulace denní koncentrace plavenin pro testovací data NS3 ze Židlochovic.



Obrázek 49: výsledky simulace denní koncentrace plavenin pro validační data NS3 ze Židlochovic.

## 5.2.6 Neuronové sítě 4

Po předchozích neúspěšných výsledcích byl mezi vstupy přidán další parametr, průměrný průtok v aktuální den a dva dny předchozí ( $Q_p$ ). Tento další parametr by mohl dopomoci k nějakému „rozhybání“ v simulované křivce.



**Obrázek 50:** schéma vstupů a počtu neuronů ve skryté vrstvě v NS4.

Bohužel po otestování prvních dvou sítí s pěti a šesti neurony ve skryté vrstvě byly dosaženy stejně nevyhovující výsledky jako v případě předchozích sítí. Výsledky z testování a validace zde už nebudou prezentovány.

## 6 SHRNU TÍ VÝSLEDKŮ

### 6.1 Výsledky hlásného profilu Podhradí nad Dyjí

#### 6.1.1 Statistické charakteristiky

Statistické charakteristiky byly počítány zvlášt' pro průměrný denní průtok  $Q$  a pro průměrné denní koncentrace plavenin  $c$ . V prvním sloupci v Tabulka 13 jsou vždy uvedeny hodnoty před standardizací, ve druhém sloupci po standardizaci. Popis všech charakteristik viz kapitola 4.3.


Tabulka 13: výsledky statistických charakteristik profilu Podhradí nad Dyjí.

	$Q$		$c$	
	$[\text{m}^3 \cdot \text{s}^{-1}]$	$[-]$	$[\text{mg} \cdot \text{l}^{-1}]$	$[-]$
min	0.70	0.00	0.20	0.00
max	122.00	1.00	768.60	1.00
$\mu$	6.03	0.04	11.40	0.01
$\sigma$	11.41	0.09	43.70	0.06
$C_s$	4.49	4.49	9.10	9.10

#### 6.1.2 Neuronové sítě 1

Tato síť se svými vstupy hledala závislost čistě mezi průtokem  $Q$ , případně posunutým průtokem  $Q$ , a koncentrací plavenin  $c$ . Jak už bylo napsáno v kapitole 5.1.4, NS1 nevykazuje akceptovatelné výsledky, obzvláště v případě validačních dat.

Důvod těchto výsledků je docela zřejmý při vynesení vstupů do grafu (Obrázek 51). Vidíme, že koncentrace plavenin zrovna v tomto úseku s průtoky moc nekorresponduje. Ve chvíli, kdy dojde ke skokovému nárůstu průtoku okolo 18. 9. 1995, koncentrace plavenin si drží téměř konstantní hodnotu.




Obrázek 51: vstupy pro validaci NS1.

Tyto výsledky pěkně ukazují, že koncentrace plavenin není závislá pouze na průtoku, že se jedná o komplexnější problém a je potřeba do NS přidat ještě nějaké vstupy.

### 6.1.3 Neuronové síť 2


Ačkoli v případě NS s osmi neurony ve skryté vrstvě vyšla pro testovací data hodnota koeficientu determinace  $R^2=0.533$ , u validačních dat se setkáváme se stejným problémem jako v případech NS1,  $R^2=0.091$  a  $NSE=-0.102$ . Což ukazuje neakceptovatelný výsledek. I když byla mezi vstupy přidána koncentrace plavenin z předchozího dne, NS ji zřejmě nevyhodnotily jako důležitý vstup a příliš se těmito hodnotami neřídily. Výsledek nejlepší NS viz Obrázek 52.



Obrázek 52: výsledky simulace denní koncentrace plavenin pro testovací data NS2 s osmi neurony ve skryté vrstvě.

### 6.1.4 Neuronové síť 3

U těchto sítí bylo v případě sítě se šesti neurony ve skryté vrstvě dosaženo akceptovatelných výsledků. Proto zde nebudou probírány ostatní sítě, ale pouze tato nejlepší s výsledky  $R^2=0.484$  pro testovací data a  $R^2=0.373$  pro validační data.




**Obrázek 53:** výsledky simulace denní koncentrace plavenin pro testovací data NS3 se šesti neurony ve skryté vrstvě.


V případě testovacích dat (Obrázek 53) je pěkně vidět, že síť dobře reaguje na změny koncentrace od 20. 5. 1995. Všechny předešlé sítě dokázaly zareagovat pouze na nejvyšší hodnoty a jinak simulovaly přibližně konstantní hodnotu.

U validačních dat (Obrázek 54) je velmi patrné, že síť dala větší váhu vstupu o den posunuté koncentrace plavenin ( $c_{t-1}$ ) než vstupu průtoků ( $Q$ ). Ovšem i vstup průtoků je v simulaci patrný a zapříčiňuje skokový nárůst okolo 18. 9. 1995.

Srážky obecně ovlivňují obě veličiny, průtok i koncentraci plavenin. Při přidání hodnot srážkových úhrnů ( $H$ ) do grafu (Obrázek 55) není výrazně znát, že by síť simulovala tyto hodnoty. Ale podle celkových výsledků tvoří hodnoty srážek významný vstup.



Obrázek 54: výsledky simulace denní koncentrace plavenin pro validační data NS3 se šesti neurony ve skryté vrstvě.




Obrázek 55: výsledky simulace denní koncentrace plavenin pro validační data NS3 se šesti neurony ve skryté vrstvě – znázorněn vstup srážek (H).


### 6.1.5 Neuronové síť 4

Jak bylo napsáno v kapitole 5.1.7 o NS4, tyto síť nedosáhly tak dobrých výsledků jako NS3. Testovací data (Obrázek 56) v období od 20. 5. 1995 zvládají hůře reagovat na změny koncentrací plavenin. U validačních dat (Obrázek 57) se opět opakuje velký důraz na vstup průtoků a tím pádem velký skokový nárůst simulovaných hodnot okolo 18. 9. 1995. Hodnoty

koeficientů jsou pro síť s pěti neurony  $R^2=0.498$  pro testovací data a  $R^2=0.185$  pro validační data. U sítě se sedmi neurony bylo dosaženo výsledků  $R^2=0.473$  pro testovací a  $R^2=0.233$  pro validační data.



**Obrázek 56:** výsledky simulace denní koncentrace plavenin pro testovací data NS4 s pěti a sedmi neurony ve skryté vrstvě.




**Obrázek 57:** výsledky simulace denní koncentrace plavenin pro validační data NS4 s pěti a sedmi neurony ve skryté vrstvě.

### 6.1.6 Neuronové síť 5


Jako celek tyto sítě také nedosáhly moc dobrých výsledků, ale nachází se zde síť s deseti neurony ve skryté vrstvě, která dokázala nasimulovat průběh koncentrací nejlépe ze všech sítí.

Koeficienty determinace nabyly hodnot  $R^2=0.584$  pro testovací data a  $R^2=0.408$  pro validační data. Na výsledcích simulace testovacích dat (Obrázek 58) je vidět, že síť velmi dobře reaguje na změny koncentrací plavenin. I výsledek pro validační data vypadá, že síť pěkně koresponduje s měřenými koncentracemi (Obrázek 59). Na rozdíl od všech předchozích simulací validačních dat síť nevytvořila skokový nárůst po přibližně třech měsících.

Na druhou stranu zde musíme vzít v úvahu, že síť jako velmi výrazný vstup zvolila koncentraci plavenin z předchozího dne.



**Obrázek 58:** výsledky simulace denní koncentrace plavenin pro testovací data NS5 s deseti neurony ve skryté vrstvě.



**Obrázek 59:** výsledky simulace denní koncentrace plavenin pro validační data NS5 s deseti neurony ve skryté vrstvě.



## 6.2 Výsledky hlásného profilu Židlochovice

### 6.2.1 Statistické charakteristiky


Pro profil Židlochovice byly také vypočítány statistické charakteristiky (Tabulka 14). V levém sloupci jsou opět hodnoty před standardizací, v pravém po standardizaci.

Tabulka 14: výsledky statistických charakteristik profilu Židlochovice.

	$Q$		$c$	
	$[\text{m}^3 \cdot \text{s}^{-1}]$	$[-]$	$[\text{mg} \cdot \text{l}^{-1}]$	$[-]$
min	2.37	0.00	2.60	0.00
max	186.00	1.00	1046.90	1.00
$\mu$	9.28	0.04	17.05	0.01
$\sigma$	11.21	0.06	44.68	0.04
$C_s$	4.36	4.36	11.41	11.41

### 6.2.2 Neuronové sítě 1

Ačkoli žádná z těchto sítí nedosáhla přijatelných výsledků, zmíníme jeden nejlepší výsledek. Nejlépe si vedla síť s osmi neurony ve skryté vrstvě, která dosáhla koeficientu determinace  $R^2=0.278$  pro testovací data a pro validační  $R^2=0.252$ .




Obrázek 60: výsledky simulace denní koncentrace plavenin pro testovací data NS1 s osmi neurony ve skryté vrstvě.


Na první pohled je vidět, že výsledek sítě značně kopíruje průběh naměřených koncentrací, jak ale bylo popsáno v kapitole 5.2.3, síť pouze vykresluje koncentrace plavenin z předchozího dne, které jsou jedním ze vstupů.

### 6.2.3 Neuronové sítě 2, 3, 4

Všechny ostatní sítě vykázaly ještě horší výsledky než NS1. Nejlepší síť NS2 – síť také s osmi neurony ve skryté vrstvě, dosahuje pro testovací data hodnot  $R^2=0.037$ , zajímavé je, že pro validační data je tato hodnota výrazně vyšší  $R^2=0.258$ .



Obrázek 61: výsledky simulace denní koncentrace plavenin pro testovací data NS2 s osmi neurony ve skryté vrstvě.



Obrázek 62: výsledky simulace denní koncentrace plavenin pro validační data NS2 s osmi neurony ve skryté vrstvě.

Sítě NS3 a NS4 nedosáhly v žádném z případů pro validační data hodnoty  $NSE>0$ , takže nemá cenu se o nich více rozepisovat.

## 6.3 Zhodnocení výsledků

### 6.3.1 Porovnání povodí


Na začátku hodnocení se ještě lehce zastavíme nad možnými důvody úspěchu a neúspěchu v jednotlivých měrných profilech.

Je dokázáno, že pohyb plavenin i splavenin významně ovlivňují vodní stavby [1]. Profil Podhradí nad Dyjí leží relativně na počátcích toku a co je důležité pro tuto práci, režim proudění není ovlivněný žádnou vodní přehradou. Naopak profil Židlochovice leží pod vodní nádrží Vír a pod Brněnskou přehradou, které ovlivňují plaveninový režim. Takže by to mohl být jeden z faktorů.

Dalším faktorem by mohl být tvar povodí. Povodí Dyje má spíše široký, vějířovitý tvar. Za to povodí Svratky je úzké, spíše podlouhlé (viz Obrázek 63) [2].

Nemalý vliv má také využití krajiny v povodí. Při podrobných studiích, ve kterých se hledá závislost mezi koncentrací plavenin a průtokem se dělá analýza pomocí GIS systémů, ve kterých se přesněji určuje sklonitost terénu, plochy náchylné na erozi. Je jasné, že strmá pole v těsné blízkosti vodních toků budou velkým zdrojem plavenin na rozdíl od míst s trvalým travním nebo lesním porostem.

Toto je výčet pár faktorů, na které by se v případné další studii pro profil Židlochovice dalo zaměřit.



Obrázek 63: napravo povodí Svratky po profil Židlochovice, nalevo povodí Dyje po profil Podhradí.

### 6.3.2 Zhodnocení vstupů a architektury sítí

Výhodou a zároveň nevýhodou NS je vhodná volba vstupů a architektury sítě. Tím, že neexistuje žádné univerzální pravidlo, jak volit vstupy a počet neuronů ve skryté vrstvě, pracuje se s NS trochu stylem pokus/omyl. To bylo částečně dokázáno i v této studii, kdy vstupy vhodné pro profil Podhradí byly pro profil Židlochovice nevhodné.

Pro profil Podhradí byly jako nejvhodnější vstupy zvoleny  $Q$ ,  $Q_{t-1}$ ,  $Q_p$ ,  $c_{t-1}$ ,  $H$  (NS3) případně vstupy z NS5  $Q$ ,  $Q_{t-1}$ ,  $Q_p$ ,  $c_{t-1}$ ,  $H_{p-1}$ . Obě sítě ale obsahují ve vstupech koncentraci plavenin z předchozího dne ( $c_{t-1}$ ). Pro účel nalezení závislosti tento vstup nevádí, ale pokud by se chtěly vytvářet předpovědní modely koncentrace plavenin, je tento vstup nepřijatelný.

Dále bylo zkoumáno, jestli existuje „univerzální“ počet neuronů ve skryté vrstvě, který by vykazoval nejlepší výsledek. Vyhodnocení probíhalo pouze na profilu Podhradí, které mělo akceptovatelné výsledky. Tabulka 15 zobrazuje hodnotící parametry nejlepších sítí z profilu Podhradí i s množstvím neuronů ve skryté vrstvě.

Téměř každá síť měla nejlepší výsledek pro jiné množství neuronů ve skryté vrstvě. Takže se nedá říct, že by určitý počet neuronů byl nejlepší.

Tabulka 15: hodnoty nejlepších sítí z profilu Podhradí s uvedením množství neuronů ve skryté vrstvě.

Síť	Neuronů	Testovací data			Validační data		
		RMSE	R <sup>2</sup>	NSE	RMSE	R <sup>2</sup>	NSE
NS3	5	0.012	0.473	0.400	0.005	0.060	0.471
NS3	6	0.011	0.484	0.471	0.001	0.373	0.227
NS4	5	0.011	0.498	0.446	0.001	0.185	0.106
NS4	7	0.011	0.473	0.441	0.001	0.233	0.121
NS5	10	0.010	0.584	0.583	0.001	0.408	0.085

## 7 ZÁVĚR

Práce měla za úkol, zkoumat vztah mezi průměrným denním průtokem  $Q$  a průměrnou denní koncentrací plavenin  $c$  na dvou měrných profilech – Židlochovice a Podhradí nad Dyjí. Tento vztah byl řešen pomocí neuronových sítí v programu MATLAB. Zároveň bylo také hledáno, zda pro tyto případy existuje nějaký univerzální počet neuronů ve skryté vrstvě, který by vykazoval výrazně často nejlepší výsledky.

U profilu Podhradí nad Dyjí byl vztah hledán na spojitých datech z období 1. 11. 1994 – 31. 10. 1997. Tato data poskytl ČHMÚ v Brně. Po standardizaci a rozdělení dat na trénovací, testovací a validační byly vytvářeny tréninkové matice a postupně z výsledků hledány nejlepší vstupy a díky nim nejlepší neuronové sítě.

Naprosto nejlepší výsledky vykazala NS5 s deseti neurony ve skryté vrstvě. V grafech na Obrázek 58 a Obrázek 59 je vidět, jak pěkně data z NS odpovídají datům měřeným. Další akceptovatelné výsledky získáváme z NS4, kde síť s pěti neurony ve skryté vrstvě a se sedmi neurony ve skryté vrstvě dosáhly nejlepších výsledků této sítě. A jako poslední solidní výsledky můžeme uvážit výsledky z NS3, kde síť s pěti a šesti neurony ve skryté vrstvě dosáhly hodnot  $R^2$  blízko hodnotě 0.5. Hodnoty koeficientů těchto nejlepších sítí viz

Tabulka 16: výsledky hodnocících koeficientů nejlepších NS.

Síť	Neuronů ve skryt. v.	Testovací data			Validační data		
		<i>RMSE</i>	$R^2$	<i>NSE</i>	<i>RMSE</i>	$R^2$	<i>NSE</i>
NS3	5	0.012	0.473	0.400	0.005	0.060	0.471
	6	0.011	0.484	0.471	0.001	0.373	0.227
NS4	5	0.011	0.498	0.446	0.001	0.185	0.106
	7	0.011	0.473	0.441	0.001	0.233	0.121
NS5	10	0.010	0.584	0.583	0.001	0.408	0.085

V tabulce je také pěkně vidět, že se nedá určit počet neuronů ve skryté vrstvě, který by byl pro síť nejlepší.

U profilu Židlochovice, který leží na řece Svratce, byl výzkum prováděn na datech z období 1. 1. 2008 – 31. 12. 2019. Bohužel data nejsou spojitá, v měření jsou dva větší výpadky v letech 2011 a 2015. Opět byla nejprve provedena standardizace dat a následovalo rozdělení na trénovací, testovací a validační část.

Jak vyplývá z kapitol 5.2.3-5.2.6, pro profil Židlochovice se nepodařilo vytvořit neuronové sítě, které by byly schopné podávat akceptovatelné výsledky. V kapitole 6.3.1 bylo poukázáno na některé faktory, které mohly způsobit neúspěch. V současnosti se nedá říct, že by dosažené výsledky, respektive vazby mezi koncentrací plavenin a průtokem v přírodě ovlivňovat pouze jeden faktor. Jedná se o kombinaci změny plaveninového režimu díky vodohospodářským dílům nad měrným profilem, tvaru povodí a způsobu využití aktivního povrchu povodí. Fakt, že se v diplomové práci nepodařilo nalézt akceptovatelné výsledky neznámá, že to není

možné. Výsledky poukazují na komplexnější problém vyžadující zaměření přímo na profil v Židlochovicích.

Celkově studie nabízí několik možností, kam ji posouvat dál. I s ohledem na další školní projekty by bylo vhodné pokračovat na výzkumu na profilu Židlochovice. Zaměřit se pouze na tento profil s podrobnější analýzou erozních smyvů a vegetačního pokryvu v povodí. Případně využít srážkoměrné stanice nejen z těžiště povodí, ale i z částí nad a pod těžištěm a pomocí koeficientů korelace zjistit výraznější závislost mezi srážkami a koncentrací plavenin.

Další práce na profilu Podhradí by mohly být zaměřeny na vytvoření modelů, které budou předpovídat koncentrace plavenin z průtoků. V této práci byl použit vstup koncentrací plavenin z předchozího dne a někdy tento vstup sítě výrazně ovlivňoval.

Na úplný závěr můžeme konstatovat, že studie přinesla několik nových poznatků o chování povodí, ale příroda je tak složitý a matematicky nepopsatelný systém, že bude stále co nového objevovat.

## 8 SEZNAM VYUŽITÉ LITERATURY

- [1] FRANČŮ, Eva a Milan GERŠL. *Vzorkování plavenin v menších tocích* [online]. , 3 [cit. 2021-01-06]. Dostupné z: [http://www.geology.cz/vav-dyje/Data/Data3/Metodika%20vzorkovani%20SPM\\_CGS.pdf](http://www.geology.cz/vav-dyje/Data/Data3/Metodika%20vzorkovani%20SPM_CGS.pdf)
- [2] ZACHOVAL, Zbyněk. *Splaveniny ve vodních tocích: Modul 1*. Brno: VUT FAST, 2016.
- [3] STARÝ, Miloš. *HYDROLOGIE Modul 02*. Brno: VUT FAST, 2005.
- [4] Dominika Hudíková *Vazba průtoků a sedimentů ve vybraném vodoměrném profilu povodí řeky Dyje*. Brno, 2019. 52 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce doc. Ing. Daniel Marton, Ph.D.
- [5] KOZEL, Tomáš a Miloš STARÝ. „*Vazba průtoků a sedimentů ve vybraném vodoměrném profilu povodí řeky Dyje*“: Report – shrnutí výsledků za MO5 [online]. VUT FAST, 2019 [cit. 2021-01-06]. VUT FAST.
- [6] MELESSE, A. M., S. AHMAD, M. E. MCCLAIN, X. WANG a Y. H. LIM. Suspended sediment load prediction of river systems: An artificial neural network approach. *Agricultural Water Management* [online]. 2011, 26. 1. 2011, **2011**, 1-12 [cit. 2021-01-06]. Dostupné z: [www.elsevier.com/locate/agwat](http://www.elsevier.com/locate/agwat)
- [7] KHAN, Mohd Yawar Ali, Fuqiang TIAN, Faisal HASAN a GovindJoseph CHAKRAPANI. Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. *International Journal of Sediment Research* [online]. 2019, **2019**, 1-13 [cit. 2021-01-06]. Dostupné z: [www.elsevier.com/locate/ijsrc](http://www.elsevier.com/locate/ijsrc)
- [8] Neuronové síť. *TriloByte* [online]. [cit. 2021-01-06]. Dostupné z: [https://www.trilobyte.cz/downloadfree/qcemanual/neural\\_net.pdf](https://www.trilobyte.cz/downloadfree/qcemanual/neural_net.pdf)
- [9] KAČER, Petr. *VÍCEVRSTVÁ NEURONOVÁ SÍŤ*. VUT FEKT, 2013. Bakalářská. VUT FEKT. Vedoucí práce Doc. Ing. VÁCLAV JIRSÍK, CSc.
- [10] DURČÁK, Pavel. Neuronové síť a princip jejich fungování. In: *NaPočítači.cz* [online]. Verlag Dashöfer, nakladatelství, 2017 [cit. 2021-01-06]. Dostupné z: <https://www.napocitaci.cz/33/neuronove-site-a-princip-jejich-fungovani-uniqueidgOkE4NvrWuNY54vrLeM670eFNQh552VdDDulZX7UDBY/>
- [11] Neuronové síť. In: *ČVUT FEL CourseWare Wiki* [online]. [cit. 2021-01-06]. Dostupné z: [https://cw.fel.cvut.cz/old/\\_media/courses/a6m33dvz/dvz2017-05-nnet.pdf](https://cw.fel.cvut.cz/old/_media/courses/a6m33dvz/dvz2017-05-nnet.pdf)
- [12] Neuronové síť. In: *Mendelova univerzita v Brně* [online]. [cit. 2021-01-06]. Dostupné z: [https://is.mendelu.cz/eknihovna/opory/zobraz\\_cast.pl?cast=21471](https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=21471)
- [13] VOLNÁ, Eva. *Neuronové síť 1. 2. vyd.* Ostravská univerzita v Ostravě: Ostravská univerzita v Ostravě, 2008.
- [14] *Koncept umělé neuronové síť* [online]. Institut biostatistiky a analýz Lékařské fakulty Masarykovy univerzity [cit. 2021-01-06]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-intelligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--koncept-umele-neuronove-site>
- [15] *Standardizace dat* [online]. Institut biostatistiky a analýz Lékařské fakulty Masarykovy univerzity [cit. 2021-01-06]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--vicerozmerne-metody-pro-analyzu-dat--vicerozmerna-rozdeleni-pravdepodobnosti--transformace-dat--standardizace-dat>

- [16] ZOUHAROVÁ, Silvie. *Hodnocení prediktivní schopnosti klasifikačních systémů hospitalizačních případů*. Přírodovědecká fakulta MU, 2016. Bakalářská. MU. Vedoucí práce RNDR. TOMÁŠ PAVLÍK, PH.D.
- [17] Evidenční list hlásného profilu č.358. In: *Český hydrometeorologický ústav* [online]. [cit. 2021-01-06]. Dostupné z:  
[https://hydro.chmi.cz/hpps/hpps\\_prfbk\\_detail.php?seq=2505251](https://hydro.chmi.cz/hpps/hpps_prfbk_detail.php?seq=2505251)
- [18] *Mapy.cz* [online]. [cit. 2021-01-06]. Dostupné z:  
<https://mapy.cz/zakladni?x=15.7618469&y=48.9166606&z=13&l=0&source=coor&id=15.6908163%2C48.9033249>
- [19] *DIBAVOD: Struktura DIBAVOD* [online]. VÚV TGM, 2020 [cit. 2021-01-06]. Dostupné z: <https://www.dibavod.cz/index.php?id=27>
- [20] *Evidenční list hlásného profilu č.383* [online]. Český hydrometeorologický ústav, 2020 [cit. 2021-01-06]. Dostupné z:  
[https://hydro.chmi.cz/hpps/hpps\\_prfbk\\_detail.php?seq=307151](https://hydro.chmi.cz/hpps/hpps_prfbk_detail.php?seq=307151)



## 9 SEZNAM OBRÁZKŮ

Obrázek 1: rozdělení částic v toku [2].....	3
Obrázek 2: porovnání výsledků dosažených aproximací v programu Excel [5].....	4
Obrázek 3: porovnání výsledků regresních modelů a umělé inteligence [4]. ....	5
Obrázek 4: plochy povodí a polohy měrných stanic [6].....	6
Obrázek 5: výsledky simulace pro architekturu se všemi vstupy. Grafy a, b, c jsou pro denní data; c, d, e pro týdenní data [6]. ....	7
Obrázek 6: výsledky ukazatelů úspěšnosti [6]. ....	7
Obrázek 7: standardizované hodnoty průtoků a denních koncentrací plavenin na řece Ramganga [7]. ....	8
Obrázek 8: výstupy trénování, testování a validace pro síť T1 z programu MATLAB [7]. ....	9
Obrázek 9: základní tvar vícevrstvé neuronové sítě [10]. ....	10
Obrázek 10: model neuronu [12].....	11
Obrázek 11: graf sigmoidy [13]. ....	12
Obrázek 12: topologie NS [14].....	12
Obrázek 13: grafické zobrazení střední hodnoty [3]. ....	14
Obrázek 14: koeficient asymetrie [3]. ....	15
Obrázek 15: grafické znázornění koeficientu korelace [3].....	16
Obrázek 16: poloha měrného profilu v Podhradí nad Dyjí [18].....	18
Obrázek 17: import dat pro vytvoření NS v programu MATLAB.....	19
Obrázek 18: schéma vytvořené NS se třemi vstupy a pěti neurony ve skryté vrstvě.....	20
Obrázek 19: schéma stupů a počtu neuronů ve skryté vrstvě NS1.....	21
Obrázek 20: trénování NS. ....	22
Obrázek 21: výsledky simulace denní koncentrace plavenin pro testovací data NS1.....	22
Obrázek 22: výsledky simulace denní koncentrace plavenin pro validační data NS1. ....	23
Obrázek 23: schéma vstupů a počtu neuronů ve skryté vrstvě NS2.....	24
Obrázek 24: výsledky simulace denní koncentrace plavenin pro testovací data NS2.....	24
Obrázek 25: výsledky simulace denní koncentrace plavenin pro validační data NS2. ....	25
Obrázek 26: schéma vstupů a počtu neuronů ve skryté vrstvě NS3.....	26
Obrázek 27: povodí Dyje po profil Podhradí nad Dyjí. ....	26
Obrázek 28: vzdálenost těžiště zkoumané oblasti od srážkoměrné stanice ve Slavonicích [18]. .....	27
Obrázek 29: výsledky simulace denní koncentrace plavenin pro testovací data NS3.....	27
Obrázek 30: výsledky simulace denní koncentrace plavenin pro validační data NS3. ....	28

Obrázek 31: trojice použitých srážkoměrných stanic okolo těžišť povodí [18].....	29
Obrázek 32: schéma vstupů a počtu neuronů ve skryté vrstvě NS4.....	29
Obrázek 33: výsledky simulace denní koncentrace plavenin pro testovací data NS4.....	30
Obrázek 34: výsledky simulace denní koncentrace plavenin pro validační data NS4. ....	30
Obrázek 35: schéma vstupů a počtu neuronů ve skryté vrstvě v NS5.....	31
Obrázek 36: výsledky simulace denní koncentrace plavenin pro testovací data NS5.....	32
Obrázek 37: hlásný profil Židlochovice. ....	33
Obrázek 38: schéma vstupů a počtu neuronů ve skryté vrstvě v NS1.....	34
Obrázek 39: výsledky simulace denní koncentrace plavenin pro testovací data NS1 ze Židlochovic.....	35
Obrázek 40: výsledky simulace denní koncentrace plavenin pro validační data NS1 ze Židlochovic.....	35
Obrázek 41: povodí Svatky po profil Židlochovice. ....	36
Obrázek 42: vzdálenost těžišť povodí od obce Kuřim [18]. ....	37
Obrázek 43: schéma vstupů a počtu neuronů ve skryté vrstvě v NS2.....	37
Obrázek 44: výsledky simulace denní koncentrace plavenin pro testovací data NS2 ze Židlochovic.....	38
Obrázek 45: výsledky simulace denní koncentrace plavenin pro validační data NS2 ze Židlochovic.....	38
Obrázek 46: trojice využitých stanic [18].....	39
Obrázek 47: schéma vstupů a počtu neuronů ve skryté vrstvě v NS3.....	39
Obrázek 48: výsledky simulace denní koncentrace plavenin pro testovací data NS3 ze Židlochovic.....	40
Obrázek 49: výsledky simulace denní koncentrace plavenin pro validační data NS3 ze Židlochovic.....	40
Obrázek 50: schéma vstupů a počtu neuronů ve skryté vrstvě v NS4.....	41
Obrázek 51: vstupy pro validaci NS1.....	42
Obrázek 52: výsledky simulace denní koncentrace plavenin pro testovací data NS2 s osmi neurony ve skryté vrstvě.....	43
Obrázek 53: výsledky simulace denní koncentrace plavenin pro testovací data NS3 se šesti neurony ve skryté vrstvě.....	44
Obrázek 54: výsledky simulace denní koncentrace plavenin pro validační data NS3 se šesti neurony ve skryté vrstvě.....	45
Obrázek 55: výsledky simulace denní koncentrace plavenin pro validační data NS3 se šesti neurony ve skryté vrstvě – znázorněn vstup srážek (H).....	45

Obrázek 56: výsledky simulace denní koncentrace plavenin pro testovací data NS4 s pěti a sedmi neurony ve skryté vrstvě. ....	46
Obrázek 57: výsledky simulace denní koncentrace plavenin pro validační data NS4 s pěti a sedmi neurony ve skryté vrstvě. ....	46
Obrázek 58: výsledky simulace denní koncentrace plavenin pro testovací data NS5 s deseti neurony ve skryté vrstvě. ....	47
Obrázek 59: výsledky simulace denní koncentrace plavenin pro validační data NS5 s deseti neurony ve skryté vrstvě. ....	47
Obrázek 60: výsledky simulace denní koncentrace plavenin pro testovací data NS1 s osmi neurony ve skryté vrstvě. ....	48
Obrázek 61: výsledky simulace denní koncentrace plavenin pro testovací data NS2 s osmi neurony ve skryté vrstvě. ....	49
Obrázek 62: výsledky simulace denní koncentrace plavenin pro validační data NS2 s osmi neurony ve skryté vrstvě. ....	49
Obrázek 63: napravo povodí Svatky po profil Židlochovice, nalevo povodí Dyje po profil Podhradí. ....	50

## 10 SEZNAM TABULEK

Tabulka 1: vstupy použité do NS pro profil Podhradí.....	20
Tabulka 2: NS vytvořené pro profil Podhradí. ....	21
Tabulka 3: výsledky hodnotících koeficientů NS1 pro testovací a validační data.....	23
Tabulka 4: výsledky hodnotících koeficientů NS2 pro testovací a validační data.....	25
Tabulka 5: výsledky hodnotících koeficientů NS3 pro testovací a validační data.....	28
Tabulka 6: výsledky hodnotících koeficientů NS4 pro testovací a validační data.....	30
Tabulka 7: výsledky hodnotících koeficientů NS5 pro testovací a validační data.....	31
Tabulka 8: vstupy použité v NS pro profil Židlochovice. ....	34
Tabulka 9: NS vytvořené pro profil Židlochovice.....	34
Tabulka 10: výsledky hodnotících koeficientů NS1 pro testovací a validační data.....	36
Tabulka 11: výsledky hodnotících koeficientů NS2 pro testovací a validační data.....	37
Tabulka 12: výsledky hodnotících koeficientů NS3 pro testovací a validační data.....	39
Tabulka 13: výsledky statistických charakteristik profilu Podhradí nad Dyjí. ....	42
Tabulka 14: výsledky statistických charakteristik profilu Židlochovice.....	48
Tabulka 15: hodnoty nejlepších sítí z profilu Podhradí s uvedením množství neuronů ve skryté vrstvě. ....	51
Tabulka 16: výsledky hodnotících koeficientů nejlepších NS. ....	52