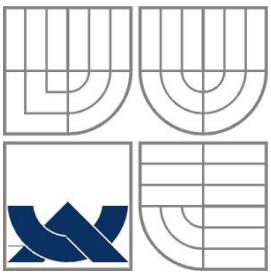

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

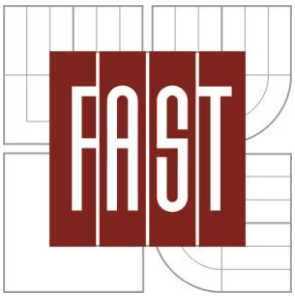

FAKULTA STAVEBNÍ
ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

FACULTY OF CIVIL ENGINEERING
INSTITUTE OF LANDSCAPE WATER MANAGEMENT

STŘEDNĚDOBÉ PŘEDPOVĚDI PRŮTOKŮ VODY V MĚRNÉM PROFILU TOKU

MIDDLE-TERM WATER STREAMFLOW FORECASTS IN GAUGE STATION

DISERTAČNÍ PRÁCE
DISSERTATION THESIS

AUTOR PRÁCE
AUTHOR
ING. JIŘÍ SÁZEL

VEDOUCÍ PRÁCE
SUPERVISOR
PROF. ING. MILOŠ STARÝ, CSC.

BRNO 2014

Abstrakt

Práce se zabývá vytvořením předpovědního modelu pro vydávání střednědobých předpovědí povrchových toků. Vytvořený model vytváří předpověď na základě nalezení nejvíce podobného historického případu. Účelnost modelu je demonstrována pro řízení jedné izolované nádrže v profilu Oslavany na řece Oslava.

Thesis is aimed on creation of prediction model for releasing medium-term water stream flow forecasts. Created model create forecasts based on principal of finding most similar historical case. Usefulness of forecasting model is demonstrated for operation of one isolated reservoir in gauge profile Oslavany on river Oslava.

Klíčová slova

Střednědobé předpovědi průtoků, průtok, předpověď, předpovědní model, přítok, vodní nádrž

Medium-term water streamflow forecasts, forecasts, flow, forecasting model, inflow, reservoir

Bibliografická citace VŠKP

SÁZEL, Jiří. *STŘEDNĚDOBÉ PŘEDPOVĚDI PRŮTOKŮ VODY V MĚRNÉM PROFILU TOKU: disertační práce.* Brno, 2014. 100 s. Vysoké učení technické v Brně. Fakulta stavební. Ústav vodní hospodářství krajiny. Vedoucí disertační práce prof. Ing. Miloš Starý, CSc.

Prohlášení:

Prohlašuji, že jsem disertační práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje.

V Brně dne ……..

…….
podpis autora

Poděkování

Rád bych poděkoval panu prof. Ing. Miloši Starému, CSc. za rady při řešení disertační práce

Brno Jiří Sázel

Obsah

1 Úvod 1

2 Předpovědi odtokových procesů povodí a práce zabývající se řešenou tématikou 3

2.1 Proces-driven metody 4

2.1.1 Pokles zbytkového odtoku 4

2.1.2 Srážko odtokové procesy 5

2.2 Data-driven metody 5

2.2.1 Regresní modely 6

2.2.2 Modely časových řad 7

2.2.3 Umělé neuronové sítě 8

2.2.4 Fuzzy logika 8

2.2.5 Metoda nejbližší polohy 9

2.2.6 Kanonická kolmační analýza 9

2.2.7 Teorie chaosu 9

3 Cíl disertační práce 11

4 Východiska řešení a zjednodušující předpoklady 12

5 Kritéria hodnocení dosažené přesnosti předpovědi 13

6 Zvolené metody řešení 16

6.1 Úprava a zobrazení vstupních dat 16

6.1.1 Zobrazení dat 16

6.1.2 Normalizace (standardizace) členů průtokových řad 16

6.1.3 Oprava vychýlení vstupních dat 18

6.2 Popis principu předpovědní metody 20

6.2.1 Rozšíření modelu podobnosti o využití předpovědní srážkových a teplotních dat 24

6.2.2 Další způsoby možného řešení 25

6.3 Definování oblasti, na kterou se koncentruje vývoj a aplikace modelů podobnosti 32

6.4 Parametry modelu podobnosti 32

6.4.1 Vlivy podobnosti průtokových, srážkových a teplotních řad 32

6.4.2 Počet nejvíce podobných historických případů 33

6.4.3 Váhy porovnávané oblasti 34

6.5 Metody volby parametrů principu odchylek 36

6.5.1 Přehled zobrazení přesnosti předpovědi pro různé kombinace parametru modelu podobnosti sloužících k subjektivnímu nalezení parametrů podobnosti a kalibračních vzorů 39

6.5.2 Metoda volby parametru PST 44
6.5.3 Metoda volby parametru NPHP 46
6.5.4 Metoda volby parametru W 47
6.5.5 Oprava vychýlení extrémů vstupních dat 47
6.6 Vývojové prostředí modelu podobnosti 50
7 Aplikace 51
7.1 Předpovědní profily 51
7.2 Kalibrační vzory 60
7.2.1 Volba parametru PST 61
7.2.2 Volba parametru NPHP 61
7.2.3 Volba parametru W 63
7.2.4 Dunaj 64
7.2.5 Rýn 66
7.2.6 Umpqua 69
7.2.7 Morava 72
7.2.8 Jihlava 76
7.2.9 Oslava 78
7.3 Předpověď modelem podobnosti 81
7.4 Ukázka aplikace poznatků práce pro simulaci provozu jedné izolované nádrže pomocí softwaru SOMVS 83
7.4.1 Simulace řízení nádrže pomocí software SOMVS 83
7.4.2 Parametry nádrže, parametry simulace a schéma předpovědi 84
7.4.3 Výsledky aplikace 88
8 Shrnutí výsledků 92
9 Závěr 94
10 Náměty pro další rozvoj 97
11 Literatura 99
12 Seznam Příloh 104
12.1 Korelační analýza předpovědních profilů 104
12.2 Zobrazení volby parametrů modelu podobnosti v jednotlivých profilech 107
12.2.1 Dunaj 107
12.2.2 Rýn 107
12.2.3 Umpqua 107
12.2.4 Morava 107

12.2.5 Jihlava 107
12.2.6 Oslava 107

1 Úvod

Vodní hospodářství se rozvijí v měnícím se světě s ekonomickými, ekologickými, technologickými, kulturními a jinými změnami, jejichž důsledky lze v souhrnu jen obtížně předvídat. Z toho vyplývá nutnost pochopit základní posuny v tomto světě a řešit vodohospodářské problémy v podmínkách nových paradigmat, tj. nových základních postojů jednotlivců i společnosti (Patera, 1996).

V posledních desetiletích můžeme sledovat vedle přirozené variability hydrologických procesů novou skutečnost. Hydrologické režimy jsou ovlivňovány lidskými aktivitami, a to jak přímými zásahy v povodí (např. výstavbou nádrží, odběry a převody vody, urbanizací povodí, využíváním půdy apod.), tak nadměrnou produkcí skleníkových plynů, majících za následek změny v klimatickém a hydrologickém systému Země (Nacházel, 1997).

Vodohospodářská opatření, která by eliminovala nepříznivě ovlivněné hydrologické řešení, jsou časově náročná. Úkolem vodohospodářské bilance je proto zachycovat nejen současný stav, ale provádět také realistické odhady budoucích vodohospodářských nároků a kapacit vodních zdrojů, a to jak z hlediska kvantitativního, tak kvalitativního. Odhad složek vodohospodářské bilance je úloha složitá už za předpokladu stálého prostředí. Dále se komplikuje při jeho změnách, ať vyvolaných přímými lidskými zásahy či změnou klimatických veličin.

Klimatické změny, jejich dopady na různé oblasti lidské činnosti a příprava zmírňujících a adaptačních opatření se stávají důležitým předmětem celosvětové politiky, a tedy i politiky v České republice. Vodní hospodářství je podle výsledků výzkumu jednou z nejvíce zranitelných oblastí, a proto by mu měla být věnována prvořadá pozornost (Vizina, Horáček, 2009).

Výzkumný ústav vodohospodářský T. G. Masaryka, v. v. i., se problematice klimatických změn dlouhodobě věnuje. S tím, jak jsou postupně zdokonalovány scénáře klimatické změny, založené na výsledcích modelování globální cirkulace atmosféry, jsou zpracovávány odpovídající modelová řešení hydrologické bilance a odhady změn hydrologického režimu. V návaznosti jsou řešeny dopady na vodní zdroje a vodní hospodářství, zejména na zásobování vodou.

Podle studie (Kašpárek, Peláková, Boersema, 2005) je pokles průměrné dlouhodobé odtokové výšky základním důsledkem klimatické změny pro vodní režim v ČR. Celkový odtok klesne do roku 2050 v případě optimistického scénáře EC1L na úroveň 80–94 % a v případě pesimistického scénáře EC2H na úroveň 57–86 % vůči nezměněnému klimatu. Sezónní chod celkového odtoku je klimatickou změnou také ovlivněn. V průběhu jarních, letních a podzimních měsíců bude celkový odtok v roce 2050 ve většině povodí o 10–20 % (EC1L), resp. o 30–40 % (EC2H) menší než ve 20. století. V zimních měsících bude naopak odtok větší, což je způsobeno zejména zvýšením teploty, které povede k častějšímu tání sněhu už v průběhu zimy a k většímu podílu dešťových srážek na úkor sněhových. Lze očekávat , že minima odtoku klesnou v některém měsíci pod polovinu původní hodnoty ve všech zkoumaných povodích. Účinek klimatické změny na minimální průtoky je tedy velmi významný a indikuje ohrožení zásobní funkce vodních zdrojů, které nemají dostatečnou akumulaci pro překrytí období sucha.

Obecně výsledky výzkumu dopadů možné změny klimatu na hydrologii a vodní zdroje v České republice prokazují, že vliv klimatické změny se daleko citelněji promítá do hospodaření s vodou v nádržích, než do samotných hydrologických procesů. V důsledku nepříznivého ovlivnění

hydrologických podmínek při daném zásobním objemu nádrže se ve většině případů pro různé klimatické scénáře snižuje nalepšený odtok o desítky procent. Rozptyl výsledků je však značný, neboť jsou závislé nejen na použitém klimatickém scénáři, hydrologickém modelu a simulačním postupu, ale i na místních podmínkách. Formulovat jednoznačný závěr je proto obtížné.

Výzkumy zabývající se zásobou vody v říční síti a hospodaření s vodou v nádržích byly v České republice intenzivně řešeny v 70-tých až 80-tých letech 20. století. Od 90-tých let (po změně politických poměrů) došlo k výraznému poklesu produkce v zemědělství a v průmyslu a to vedlo k zvětšování nadbytku zadržované vody. Od této doby se odborná veřejnost v České republice převážně zabývala kvalitou vod a později povodněmi, respektive protipovodňovou ochranou.

Vydatnost a časové rozložení vodních zdrojů ovlivňuje oběh vody. Ten může být v blízké budoucnosti pozměněn působením očekávaných klimatických změn. Změna hydrologického cyklu může v různých oblastech světa vyvolat nové vodohospodářské problémy, které nebylo dříve nutné řešit. V některých oblastech světa může nově docházet k častějšímu výskytu extrémních povodní a naopak v jiných částech světa se může prohloubit problém výskytu extrémně málovodých období. Právě sem patří i střední Evropa a Česká republika. Očekává se pokles Q_a na hodnoty 0,8Q_a až 0,6Q_a (Kašpárek a kolektiv, 2003). Vydatnost vodních zdrojů tak nemusí být schopna pokrýt potřeby uživatelů vody. Pokles průtoků také způsobí zvýšení koncentrace znečištění v tocích.

Jednou z možností, jak řešit předpokládaný nedostatek vody, je výstavba vodních nádrží. Ve směrném vodohospodářském plánu ČSR z roku 1988 byl naposledy aktualizován seznam výhledových údolních vodních nádrží. Obsahuje 464 plánovaných nádrží, z toho 210 územně hájených. Zbytek je pouze evidovaný, územně nehájený. Územní hájení je respektováno dodnes.

Trend výstavby nových údolních nádrží je však spíše klesající. U nás se výstavba nových údolních nádrží zastavila. Další možnost jak předejít nebo úplně zabránit vzniku výše popsaných problémům je v přehodnocení velikosti zásobních a ochranných objemů stávajících nádrží.

V návaznosti na klimatické změny a jejich vliv na vydatnost vodních zdrojů roste v současné době potřeba zapojení progresivních metod řízení provozu zásobní funkce nádrže. Při řízení izolované nádrže vystačíme vzhledem k počtu řízených veličin a ke složitosti dané problematiky s běžným dispečerským řízením, i když i to má významné omezení. Při řízení průtoků v rámci vodohospodářských soustav je problém nepoměrně složitější. Snahou do budoucna je současné způsoby řízení doplnit o optimalizované operativní řízení založené na adaptivním principu. Takovýto model řízení však vyžaduje odhad budoucích průměrných přítoků vody do nádrže ve formě řad průměrných měsíčních průtoků na jeden a více kroků dopředu. Spolehlivé předpovědi průtoků v požadované přesnosti nejsou k dispozici. Předložená disertační práce je zaměřena na možnosti řešení daného problému.

2 Předpovědi odtokových procesů povodí a práce zabývající se řešenou tématikou

Předpověď je vědecky opodstatněné určení hydrologických prvků nebo jevů na určitou dobu dopředu. Předpovědní model je možno zapsat obecným modelem.

$$\bar{X}_{t+\Delta t} = \Phi(\bar{X}_t, \bar{Y}_t, \bar{\omega}_t), \qquad (1)$$

kde X je předpovídaná (zkoumaná) veličina; Y jsou další vstupy, které vyžaduje předpověď; ω jsou další vstupy, nahrazující veličiny, s kterými předpovědní model nedisponuje; t je okamžik vytváření předpovědi; Δt je délka předpovědi. Veličina $X_{t+\Delta t}$ je prediktant a veličiny X_t, Y_t, ω_t jsou prediktory. Φ je operátor jehož tvar závisí na použití předpovědního modelu.

Čím je interval Δt delší, tím obtížnější je vytvořit přesnou předpověď. To samé platí i pro případ vytváření předpovědi na více kroků Δt dopředu, viz Obr. 1.

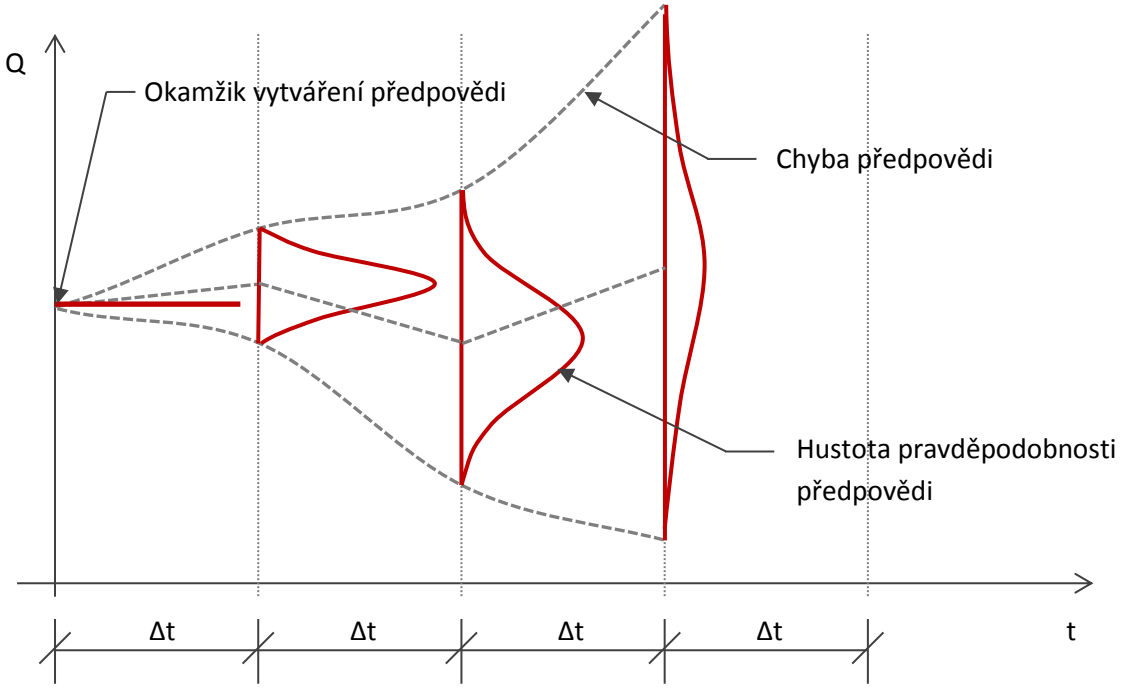

Obr. 1 – Přesnost předpovědi s délkou/opakování vydávané předpovědi

Předpověď průtoku vody je možno rozdělit na

- Termínované – například hodnota průtoku v určitém čase
- Netermínované - například hodnota průtoku v blízkém nespecifikovaném čase

Podle doby předstihu předpovědi jde předpověď dělit na

- Dlouhodobou – od půlročních průměrů, přes roční průměry až po několikaleté průměry
- Střednědobou – od týdenního průměru, přes měsíční průměry až po půlroční průměry
- Krátkodobou – od dnů po týdenní průměry
- Operativní – doba chodu vody systémem

Podle charakteru vstupních informací předpovědního modelu

- Hydrometrické – předpověď průtoku je vytvářena na základě průtoků pozorovaných před okamžikem předpovědi
- Hydrometeorologické – předpověď je vytvářena na základě časové extrapolace srážkoodtokového procesu probíhající v povodí.

Dalším dělením je podle způsobů vytváření předpovědi na

- Process-driven modely - metoda respektuje dílčí fáze, které tvoří odtok vody z povodí, ve smyslu teorie systému. Na základě určitého porozumění procesů odehrávajících se v povodí matematicky aproximují vnitřní fyzikální mechanismy, které řídí odtokový proces.
- Data driven modely - matematicky popisují pouze závislost mezi vstupem a výstupem, bez jakéhokoliv porozumění vnitřních fyzikálních mechanismů povodí a přistupují k problému zkoumáním závislostí mezi členy časových řad.

Rozdělení je vhodné vnímat pouze rámcově, protože některé modely odtokových procesů lze zařadit někde mezi předchozí zmíněné skupiny. Process-driven modelů je velká škála a jde je rozdělit do následujících skupin:

- Rozdělení dle prostorového uspořádání vstupů a hydrologických charakteristik
  - Celistvé modely – předpokládají, že všechny vstupy a další hydrologické charakteristiky jsou v prostoru povodí rozloženy homogenně a mění se pouze v čase.
  - Distribuované modely – zohledňuje prostorovou proměnlivost hydrologických či jiných charakteristik, tudíž je blíže skutečné reprezentaci přírodních podmínek a procesů. Parametry se pokládají konstantní na určitém elementárním území.
  - Semidistribuované modely – některé charakteristiky jsou homogenní pro celé povodí a ostatní jsou prostorově rozložené
- Rozdělení dle hloubky a komplikovanosti vazeb simulovaného procesu
  - Modely typu „black box“ – vztah mezi veličinami jsou dány empirickým odvozením
  - Koncepční modely – respektují základní fyzikální zákony v zjednodušené (koncepční) formě. Některé komplikované vazby jsou nahrazeny empirickými vztahy
  - Fyzikální modely – pracují s přesně fyzikálně definovanými vztahy

2.1 Proces-driven metody

Process-driven metody se obecně dělí do dvou hlavních oblastí: Modely srážkoodtokových procesů a modely poklesu zbytkového odtoku – doslova přeloženo z anglického „low flow recession process“ – v češtině známé také jako výtokové křivky. Kdy první zmíněný model je řízený různými procesy ovlivňující odtok, z nichž nejvýznamnější je srážka. Naopak druhý model se zaměřuje procesy, popisující množství průtoku na základě odtoku spodní vody a dalších zpožděných zdrojů a proto se používají většinou na vytváření předpovědi po období dešťů nebo po povodňovém období.

2.1.1 Pokles zbytkového odtoku

Proces se může být dobrým předpovědním nástrojem v málovodém období. Jako zdroj pro zbytkový odtok jsou vsaky z podzemních vod a další zpožděné zdroje. Pokles průtoku může být vyjádřen

pomocí křivky poklesu. Odhad hodnot křivky poklesu je možné udělat několika způsoby. Jeden byl vytvořen autorem Mishra (2003) použitím nelineárního algoritmu odtokové zásoby povodí.

2.1.2 Srážko odtokové procesy

Srážko-odtokové modely, se skládají z kombinace fyzikálně podložených rovnic a empirických rovnic. Za fyzikálně řízený proces můžeme považovat transformaci srážky a proudění vody v toku. Většinou se typický koncepční srážko-odtokový model skládá ze dvou částí a to transformace srážky a simulace proudění vody v toku; jinak řečeno popisující hydrologickou a hydraulickou transformaci.

Jakmile začaly být koncepční srážko-odtokové modely často používány pro operativní a krátkodobé předpovědi, objevují se také pokusy o jejich aplikaci pro střednědobé a dlouhodobé předpovědi. První aplikaci, srážko odtokového modelu s časovým krokem jeden měsíc, použil Pitman v roce 1973 v jižní Africe. Pro použití srážko-odtokového modelu pro střednědobou nebo dlouhodobou předpověď, je nezbytné změnit časový krok vstupu a výstupu což způsobí i změnu ve struktuře modelu. Například v tradičním Xinanjiang modelu (zhao and Liu 1995), je odtok rozložen do tří komponentů: Okamžitý odtok, povrchový odtok, podzemní odtok. Při použití modelu pro vytvoření střednědobé předpovědi průtoku jsou použity pouze dvě z těchto složek.

Pokud aplikujeme koncepční srážko odtokové modely na střednědobé a dlouhodobé předpovědi průtoků, jsou informace o počasí rozhodujícím předpokladem. V některých aplikacích jako je „ensemble streamflow prediction“ (ESP) (Day 1985), se jako vstupní informace pro vytvoření předpovědi, používá srážka a teplota, které se vyskytla v předchozích letech. Nejprve je model říze pomocí pozorovaných srážek a teplot až do chvíle předpovědi, kdy je vytvořen počáteční stav v povodí. Následně se vytvoří soubor předpovědí, založených na srážce a teplotě, které se vyskytly v předchozích rocích při stejném počátečním stavu. Za současného zlepšování přesnosti středně a dlouhodobých předpovědí počasí, se setkáváme s jejich aplikací při předpovědi průtoku. Například European Flood Forecasting Systém (EFFS) vytvořený spoluprací několika evropských zemí, používá upravený střednědobý soubor předpovědi srážek z European Center for Medium Range Weathwr Forecasting (ECMWF) jako vstup pro vodní bilanci a srážko odtokových procesů stejně, jako pro vytvoření předpovědi na jeden až deset dní dopředu (De Roo 2003). Tucci (2003) použil General Circulation Model (GCM) na získání stejných předpovědí srážek a ty použil jako vstup pro předpověď průtoku na pět měsíců dopředu.

Jedna z důležitých otázek při vytváření střednědobých a dlouhodobých předpovědí je jak upravit předpovídané atmosférické proměnné (převážně srážky), aby byly použitelné pro srážko odtokové modely. Werner a kolektiv (2005) porovnal dva soubory předpovědi pomocí Ensemble Streamflow Prediction (ESP) součásti National Weather Service River Forecast System (NWSRFS), kde jeden výpočet byl na základě historických pozorování teploty a srážky a druhý výpočet by na základě čtrnácti denní předpovědi srážek a teploty. Jejich studie ukázala, že použití předpovědi dálavo obecně lepší výsledky než použití historických dat, ale byli zde simulace, kdy předpověď počasí negativně ovlivnila výsledky předpovědi průtoku.

2.2 Data-driven metody

Oproti proces-driven metodám, které jsou různě složité, mají data-driven modely určité výhody. Jsou lehko aplikovatelné na různé situace, protože modelování a předpovídání je vesměs pro každý případ podobné. Navíc analýza struktury a parametrů data-driven modelu, může často poskytnout užitečné

informace ohledně dynamiky předpovídaného problému. Na jednu stranu jsme díky moderním technologiím schopni získat množství potřebných dat, ale na druhou stranu fyzikální vztahy mezi průtokem a příslušnou oblastí jsou stále neznámé. Z toho důvodu obdržely data-driven modely v posledních desetiletí více pozornosti.

2.2.1 Regresní modely

Regresní analýza, zahrnující jednoduchou regresi a vícenásobnou regresi je jedna z nejstarších a taky nejvíce používaných metod v předpovídání průtoku. Má výhodu, že poměrně jednoduchá a může být lehko realizovatelná. Dřívější regresní metody používaly grafické postupy. Následně byly představeny statistické metody jako princip složek, vícenásobná regrese a neparametrická regrese. Je možné najít určité variace regresních modelů použité pro předpověď průtoku jako je „linear perturbatioun model“ (LPM), „index variable method“ a „storage-accounting method“. Například v osmdesátých letech minulého století Water Master Plan Project ve spolupráci s Cairo University a MIT vytvořily model vícenásobnou postupnou regresní model pro předpověď průměrného měsíčního průtoku pro nádrž Aswan (Curry and Bras, 1980; Water Master Plan Project, 1983). British Columbia Hydro používá vícenásobnou lineární regresi, která zahrnuje sněhovou pokrývku, srážky a teplotu pro určení množství sezónního přítoku (Fast, 1990). Regresní metody se dnes stále používají v mnoha případech. Například předpověď potenciálního odtoku ze sněhové pokrývky ze dvou povodí v jihovýchodní Albertě, předpověď v Kanadě je v současné době založena na regresních modelech (Mahabir et al., 2003). Huo a kol. (2001) předpovídaly přítok do nádrže Sanmen Gorge na Žluté řece v nepovodňovém období pomocí regresních modelů, které využívaly předchozí srážky a průtoky.

Odhadované proměnné, používané při regresní analýze, obyčejně obsahují lokální vlivy (jakou jsou průtoky v horních stanicích povodí, srážky a teploty, sněhová pokrývka) a nějaké geofyzikální údaje (jako povrchová teplota, teplota povrchu moře a atmosferický cirkulační index). Nejvíce důležité rozhodnutí před aplikací regresních modelů jsou:

- které vlivy mají dostatečný dopad na hodnotu průtoku
- jaký časový krok vybraných vlivů má největší vliv na předpovídaný průtok
- jak velký je vliv časového zpoždění u jednotlivých proměnných

Na krátkodobou předpověď mají vliv lokální faktory, zatím co na dlouhodobou předpověď mají vliv spíše geofyzikální vlivy. Vztah mezi předpovědí průtoku a teplotou mořského povrchu stejně, jako vliv ENSO oscilace, byly usilovně zkoumány v posledních dvaceti letech. Například Piechota a kolektiv (1999) zjistil významný vliv mezi El Nino a průtokem v severozápadním Pacifiku a díky tomuto vztahu navrhl protáhnout předpovídanou periodu z 1 až 3 měsíců na 3 až 7 měsíců. Hamlet and Lettenmaier (1999) zahrnuli Pacific Decadal Oscillation (PDO) a ENSO klimatické signály do metody extended streamflow prediction pro vytvoření dlouhodobé předpovědi. Whitaker et al. (2001) zaznamenal významnou závislost mezi přirozenou změnou ročního průtoku v Ganze a ENSO indexem a navrhnul statistický model zahrnující tento vliv, a krokem na jeden rok dopředu. Dále Cai and Wang (1996) zjistil významný vliv mezi průměrným ročním průtokem přítoků Žluté řeky a prostorovým rozmístěním povrchové teploty. Tomasino a kol. (2004) spojil informaci o solární aktivitě a atmosférického cirkulačního indexu pro vytvoření sezónních předpovědí průtoku.

Ve většině aplikací předpovědi průtoku, je využita lineární regrese. Za účelem větší flexibility, jsou používány nelineární regresní modely. Jeden z často používaných regresních modelů je stromová regrese (anglicky theshold regresion), v které jsou data rozděleny podle podmínek „buď a nebo“.

Výhoda stromové regrese je že se jedná o neparametrickou nelineární metodu s velmi jednoduchým výkladem výsledků. V současné době byly tyto modely použity pro předpověď srážko odtokového procesu autory (e.g., Solomatine and Dulal, 2003; Solomatine and Xue, 2004).

2.2.2 Modely časových řad

Analýza časových řad má významnou roli v hydrologickém výzkumu. Je používána pro vytváření umělých průtokových řad, předpověď hydrologických veličin, detekci trendu a pro nahrazení chybějících dat. Velmi zhruba jde rozdělit modely do dvou kategorií podle počtu časových řad vstupujících do předpovědi: Modely jedné proměnné a modely zahrnující vnější proměnné.

Nejvíce populární model jedné proměnné je model ARMA (Autoregresive moving average) a jeho odvozeniny jako jsou ARMA, AR, ARIMA (Autoregresive integrated moving average), SARIMA (sesonal ARIMA), PARMA (periodic ARMA), TAR (threshold AR) a ARFIMA (fractionaly integratred ARMA). Model AR může být použit pro modelování ročního průtoku. Protože modely ARMA jsou vytvořeny na základě podmínky, že časová řada je stacionární. Nicméně v případě měsíčních průtoků je časová řada sezónní, a proto nelze model ARMA aplikovat v tomto případě. Z toho důvodu jsou utvořeny modely SARIMA, deseasonalised ARMA, PARMA. Tyto modely se dají použít pro předpověď měsíčního nebo čtvrtletního průtoku (např. McKerchar and Delleur, 1974; Thmoposon a kol., 1985; Noakes a kol., 1985; Yurekli a kol., 2005), a v některých případech i denního průtoku (např. Kang a kol., 1993;Abrahart and See, 2000). Bender and Simonovic (1994) předložily že, modely SARIMA se zdají být více vhodné pro modelování přítoků z povodí s menší plochou a větší variabilitou zatímco deseasonalized ARMA můžou poskytovat lepší výsledky na větších povodích s menší variabilitou a větší vzájemnou závislost jednotlivých prvků. V posledních letech si získal pozornost proces dlouhodobé paměti předpověď pro předpověď průtoku. Stochastický proces s dlouhodobou pamětí může být popsaný modelem ARFIMA (autoregressive fractionally integrated moving average). Montanari a kol. (2000) použil model ARFIMA pro simulaci měsíčního průtoku na Nilu v Aswanu.

Jestli nám do řešení vstupují vnější proměnné, můžeme použít model ARMAX nebo modely „transfer function noise“ (TFN). Thompstone et al. (1985) porovnal modely deseasonalized ARMA, PAR, TFN a koncepční model a zjistil, že nejlepší výsledky vytváří TFN model. Awadallah & Rousselle (2000) použili teplotu mořského povrchu jako vnější proměnou na vytvoření modelu TFN pro předpověď letního odtoku na řece Nil. Obecně jde říct, že jestli do modelu TFN vstupuje více informací, může poskytovat lepší výsledky než ARIMA modely. Speciálním typem TFN modelů je intervenční model, který je schopný modelovat „rozruch“ některých vnějších faktorů. Kuo and Sun (1993) vytvořily intervenční model, který zvažuje ovlivnění hurikánem, jako desetidenní průměrnou předpověď průtoku na řece Danshui v Tchaj-wanu.

Výše zmíněné modely jsou ve velké míře lineární. Protože procesy řídící průtok, speciálně denní průtok, jsou obecně akceptovány jako nelineární, některé nelineární modely jsou aplikovány na předpověď. Jeden z užívaných nelineárních modelů časových řad je threshold autoregressive (TAR) model (Tong a Lim, 1980). Astatkie a kol. (1997) představily nested threshold autoregressive (NeTAR) model na předpověď denního průtoku. Ve skutečnosti se dá PARMA a PAR model považovat za speciální typ TAR modelu, který využívá sezónu jako prahovou hodnotu namísto použití pozorované veličiny.

2.2.3 Umělé neuronové sítě

Umělé neuronové sítě (ANN) je data-driven metoda s flexibilní matematickou strukturou, která je schopna rozpoznat složité nelineární vztahy mezi vstupem a výstupem, bez porozumění procesu samotného. Jedno z prvních použití neuronových sítí bylo Kang et al. (1993), který použil ANN a autoregressive moving average modely pro předpověď denního a hodinového průtoku. Nejen v této studii, ale i v dalších následujících, bylo zjištěno, že ANN je srovnatelná nebo vhodnější metoda pro předpověď průtoku než tradiční statistické metody nebo koncepční modely (např., Raman and Sunilkumar 1995; Dibike and Solomatine, 2001; Tokar and Markus 2000; Birikundavyi et al., 2002).

Nejvíce populární typ neuronových sítí je multi-layer perception (MPL) síť optimalizovaná algoritmem zpětné propagace. Je to zároveň nejvíce populární neuronová sít pro předpověď průtoku. Markus (1997) vytvořil předpovědi průměrného měsíčního průtoku na několika tocích a porovnal s ostatními modely. Zaeland a kol. (1999) použily MPL ANN na modelování průtoku na jeden až čtyři týdny dopředu. Sajikumar a Thandaveswara (1999) představily použití dočasného (temporal) algoritmu zpětné propagace na modelování měsíčního srážko odtokového procesu. Birikundavyi a kol. (2002) zjistily, že ANN model vytvořený na předpověď denního průtoku 7 dní dopředu, podává lepší výsledky, než koncepční srážko odtokový model na 5 dní dopředu.

Některé další typy neuronových sítí byly použity pro předpověď průtoku, ale s menší četností. Chang and Chen (2001) aplikovaly counter-propagation fuzzy-neural network, na předpověď průtoku na jednu hodinu dopředu. Ballini a kol. (2001) použil neuro-fuzzy síť na modelování měsíčního průtoku. Moradkhani a kol. (2004) prozkoumaly aplikovatelnost Self Organizing Radial Basis (SORB) fiction na předpověď denního průtoku na jeden den dopředu. Pro zachycení nelinearity průtoku modular neural network (MNN), hybrid neural networks, a threshold (tak zvané range-depend) neural network můžou být použity (například Zhang and Govindaraju, 2000; Hu a kol., 2001). Zhang and Govindaraju (2000) prozkoumaly reprezentativnost MNN pro předpověď měsíčního průtoku na středně velkých povodích. Hu a kol. (2001) aplikovali range-depend ANN, které mohou být považovány za speciální případ MNN, na předpověď ročního a denního průtoku.

Běžně řešený problém při aplikaci ANN je malé množství souboru dat potřebné pro natrénování sítě, které následně snižuje schopnost její předpovědi. Na vyřešení tohoto problému je možné generovat umělé průtokové řady a potom je použít jako trénovací data.

2.2.4 Fuzzy logika

Od doby kdy Zadeh (1965) publikoval teorii fuzzy množin jako vylepšení klasické teorie množin, fuzzy logika byla aplikována v mnoha oblastech, kde vztahy mezi proměnou a výsledkem nejsou zcela jasné. Ve fuzzy logice se proměnná hodnotí jako jazykový výraz. Například „malý průtok“, „střední průtok“, „velký průtok“ se stávají proměnnými. Fuzzy logika je v oblasti modelování použitelná pro operativní (např., Han et al., 2002; Nayak a kol., 2005) i pro dlouhodobé předpovědi. (např., Zhu a kol., 1994; Mahabir a kol., 2003). Pomocí fuzzy logiky Mahabir a kol. (2003) vytvořil expertní fuzzy model pro předpověď letních odtoků, který dosáhl větší přesnosti předpovědi v oblasti malých a průměrných hodnot odtoků než regresní modely.

Stejně jako neuronové sítě, můžou být fuzzy modely kombinované s koncepčními modely nebo jinými data-driven modely. Mizumura (1995) představil, že kombinace koncepčního modelu nádrže a fuzzy logiky, poskytuje uspokojivé výsledky v předpovědi při odtoku ze sněhové zásoby.

2.2.5 Metoda nejbližší polohy

Metoda nejbližší polohy (angl. nearest neighbor method) (NNM) je lokální aproximace, která řeší složitý problém, rozdělením do velkého počtu podmnožin, kdy každá z nich se skládá z vícerozměrných bodů, které mají podobné stavové vzory a potom lokálně aproximuje tyto body pomocí neparametrického nebo parametrického modelu. NNM pochází z teorie rozpoznání vzoru. Z důvodu její schopnosti dobře aproximovat nelineární dynamiku, je používána mnoha vědci jako standardní metoda pro předpověď časové řady s chaotickým chováním (např., Farmer a Sidorowich, 1987; Sugihara a May,1990). První kdo aplikoval NNM na srážko odtokový proces byl Karlsson (1985), a potom Yakowitz a Karlsson (1987) a následně další buď pro případy jedné proměnné, nebo více proměnných. Yakowitz a Karlsson (1987) porovnaly vypovídací schopnost NNM s ARMAX a Sacramento modelem pro vytváření jednodenní předpovědí a shledali, že NNM a ARMAX modely vytvářejí značně lepší předpovědi než Sacramento model.

Další metoda podobná NNM, nelineární množina příslušnosti (angl. nonlinear set membership) (NSM), představená Novara and Milanese (2001), je aplikovaná na víceproměnné denní předpověď průtoku autory Milanese and Novara (2004).

2.2.6 Kanonická kolmační analýza

Kanonická korelační analýza (angl. Canonical correlation analysis) (CCA) je způsob jak měřit lineární vztah mezi dvěma vícerozměrnými proměnnými. Může to být definováno jako problém nalezení dvou množin bázových vektorů, jeden pro x a druhý pro y, takže korelace mezi projekcí proměných na jejich bázové vektory jsou vzájemně maximalizovány. CCA je upřednostňována v oblasti klimatologie a meterologie pro vytváření statistické předpovědi teploty a srážky. Uvo and Graham (1998) sestavily CCA model pro předpověď sezóního průtoku, jednu sezónu dopředu, na dvanácti místech na severovýchodu Jižní Ameriky z Pacifického a Atlantského SST.

2.2.7 Teorie chaosu

Teorie chaosu je zařazena do oblasti nelineární dynamiky, které je částí dynamických systémů. Obecně se dynamické systémy dělí na stochastické, v kterých se systém vyvíjí na základě náhodného procesu nebo deterministické, v kterých je budoucí stav přesně definován na základě minulosti pomocí nějakých pravidel nebo matematických vzorců. Teorie chaosu je často nazývána deterministický chaos, a může vzniknout pokud jsou řídící rovnice nelineární. Jak už bylo naznačeno dřív, teorie chaosu se liší od předešlých metod tím, že i když jsou vztahy vytvářeny deterministickými rovnicemi, výsledky mají chaotický charakter. Při použití teorie chaosu, kde modelovaný problém není popsán fyzikálními procesy, je při vytváření modelu nutné rekonstruovat fázový prostor, přesněji najít jeho dimenzi.

První studie, aplikující teorii chaosu v hydrologii, se zaměřovali na prověření, zda hydrologické procesy vykazují chaotické chování. Jayawardena and Lai, (1994) prokázaly denní srážky a denní průtok vykazují chaotické chování, a i přesto, že jejich předpověď měla malou vypovídací schopnost, tak překonala klasický stochastický model ARMA. Další studie předpovídající denní průtok, byly vytvořeny autory (Porporato and Ridolfi, 1997, 1997). Důkaz chaotického chování v předpovědi průměrného měsíčního průtoku, uskutečnil Sivakumar a kol. (2001, 2002) na řece Göta River ve Švýcarsku, kdy pozorovali nízkou korelační dimenzi, a extrémně vysokou predikční schopnost. Stejného výsledku docílil autor v roce 2002, kdy využil lokální aproximační metodu pro předpověď průměrného měsíčního na řece Coaracy Nunes/Araguari v jižní Brazílii. Ve stejném roku porovnal na řece Chao Phraya River v Thajsku, neuronové síte MPL a rekonstrukci fázového prostoru (PSR) pro

předpověď průtoku na jeden den a na sedm dní dopředu. Obě metody dávaly reprezentativní předpověď, ale rekonstrukce fázového prostoru byla poznatelně lepší. PSR byla správně předpovědět jak extrémní výkyvy, ale i jemné fluktuace ve změně průtoku. Wang a kol. (2005) zkoumal velikost nelinearity na čtyřech řekách při rozdílných intervalech předpovědi; jmenovitě Žlutá řeka v Číně, Rhine River v Evropě, Řeka Umpqua a Ocmulgee ve Spojených Státech. Výsledky ukázaly, že čím je časový interval kratší, tím větší je nelinearita. Všechny roční průtokové řady jsou lineární, zatímco všechny denní průtoky jsou nelineární. Po odstranění sezónního vlivu na měsíční a čtvrtletní časové řady nejde rozhodnout zda je nelinearita v řadě obsažena. Kasım KOÇAK (2007) modeloval průměrný měsíční průtok na přítoku do nádrže Yamula, kdy shledal dobrou shodu mezi modelovaným a pozorovaným průtokem.

Na základě skutečností uvedených v kapitole 2 lze konstatovat, že důraz na rozvoj řízení provozu zásobní funkce nádrže (vodohospodářské soustavy) má své opodstatnění. Podstatnou složku jejich dalšího rozvoje představuje schopnost vytvářet střednědobé předpovědi průměrných měsíčních průtoku na několik měsíců dopředu, který tvoří nezbytný vstup při operativním řízení odtoku vodní nádrže nebo vodohospodářské soustavy.

Vytváření střednědobých předpovědí průtoků je zatíženo značnou neurčitostí a je zatíženo značnou nejistotou, zatím nebyly vyvinuty modely, které by výrazně zlepšily jejich přesnost.

Výzkum zaměřený na střednědobé předpovědi průtoku může na jednu stranu poskytnout podklady pro optimalizaci řízení nádrže nebo vodohospodářské soustavy a na druhou stranu analýzou a předpovědí odtokových procesů je možné dojít k lepšímu porozumění jevu a k zlepšení schopnosti jeho předpovědi.

3 Cíl disertační práce

Cílem disertační práce je vytvoření předpovědního modelu k vytváření průměrných měsíčních průtoků povrchových toků, které budou využity pro řízení zásobní funkce vodní nádrže nebo vodohospodářské soustavy.

V rámci vytvoření předpovědního modelu je zájmem zvolit vhodný předpovědní princip, vstupy předpovědního principu, zvolit parametry kalibrace předpovědního modelu a testovat předpovědní model na různých předpovědních profilech. Zájmem je také aplikovat vytvořený model pro řízení vodní nádrže vodohospodářské soustavy a zhodnotit jakým způsobem zvyšuje efektivitu hospodaření při zásobení vodou. Předpokládaným výstupem disertační práce je také prohloubení pochopení odtokových procesů povodí a možnostech jejich předpovědi. To může sloužit ke zvýšení efektivity řízení zásobní funkce vodní nádrže nebo vodohospodářské soustavy ať už s využitím metod použitých v této práci nebo při použití jakýchkoliv jiných metod.

Obr. 2 - Schéma oblasti výzkumu

4 Východiska řešení a zjednodušující předpoklady

Z možných délek časových kroků střednědobých předpovědí průměrných průtoků byl zvolen měsíční krok. Vytvoření dobré předpovědi týdenních průměrů je otázkou zlepšení předpovědi počasí, které tvoří vstup koncepčním modelům odtokových procesů povodí. Pro koncepční odtokové modely není obtížné určit přesnou průměrnou týdenní předpověď, pokud disponují týdenní předpovědí počasí. Naopak odhad půlročních průměrů, neumožňuje příliš operativní rozhodování při řízení zásobní funkce nádrže, které by mohlo zvýšit efektivitu jejího hospodaření.

Výzkum je zaměřen na deterministickou předpověď průtoku. S ohledem na rozsah zpracování úloh operativního řízení zásobní funkce vodohospodářské soustavy je to v současnosti jediný vhodný vstup pro softwary řídící vodní nádrž (nebo soustavy vodních nádrží).

Výzkumu je zaměřen na vývoj modelu, který se přizpůsobuje sezónnosti zkoumaného jevu, tj. například umí nastavit parametry pro každý měsíc zvlášť. Předmětem práce je vyvinout model více orientovaný na specifickou aplikaci střednědobých předpovědí průměrných měsíčních průtoků, než pro obecnou aplikaci pro různé jevy. Obecná aplikace modelu však není vyloučena.

5 Kritéria hodnocení dosažené přesnosti předpovědi

V práci jsou používána dvě kritéria k hodnocení přesnosti souboru předpovězených dat. Prvním je *koeficient determinace* podle Strichlera, který je označován zkratkou KD,

$$KD = R^2 = 1 - \frac{\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right)^2}{\sum_{i=1}^{n}(Y_i - \bar{Y})^2}, \qquad (2)$$

kde: Y_i – značí realizaci zkoumaného jevu, která má být předpovězena (měřené realizace), $\hat{Y}_i$ – předpověď realizace, n – počet všech předpovědí, $\bar{Y}_i$ – aritmetický průměr všech měřených realizací. Hodnota koeficientu determinace leží při použití pro kalibraci modelu v intervalu

$$KD \in \langle 0{,}1 \rangle \qquad (3)$$

hodnota R = 1 znamená, že předpověď zcela odpovídá měřeným datům. Čím je koeficient determinace nižší, tím je předpověď méně přesná. Pokud je KD = 0 znamená to, že přednost předpovědi odpovídá přesnosti předpovědi aritmetickým průměrem (nejjednodušší předpovědní model). Koeficient determinace může nabývat i záporných hodnot, což představuje, že přesnost předpovědi je nižší než přesnost předpovědi aritmetickým průměrem. Hodnoty koeficientu determinace nižší než nula lze dosáhnout při použití validačního modelu.

Druhé kritérium používané k hodnocení předpovědi je zobrazení závislosti $\hat{Y} = f(Y)$ v *kontrolním kvadrantu*. Na y-nové ose jsou zobrazeny předpovězené realizace zkoumaného jevu a na X-ové ose realizace, které mají být předpovězeny, viz Obr. 3. Pokud body grafu leží na *srovnávací přímce* (přímka pod úhlem 45 stupňů), znamená to, že předpovězené body jsou přesně odhadnuty. Čím více se body vzdalují od přímky, tím méně je předpověď přesná. Přesnost předpovědi je hodnocena subjektivně.

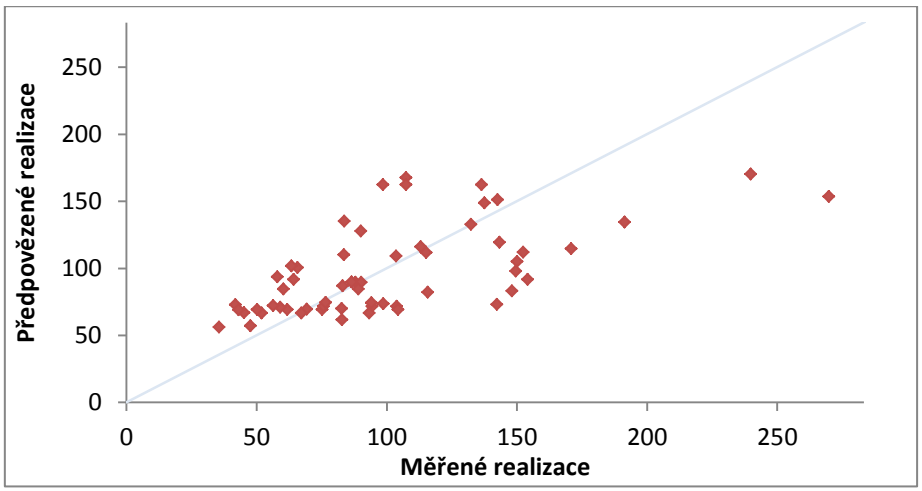

Obr. 3 - Příklad zobrazení kontrolního kvadrantu

V rámci práce byly používány i další kritéria jako koeficient korelace, absolutní koeficient determinace (KD, který má druhé mocniny nahrazeny absolutní hodnotou) atd. Avšak pro hodnocení přesnosti předpovědi a jako optimalizační kritéria se nejvíce osvědčili první dvě zmíněná kritéria.

Koeficient determinace je používán k hodnocení přesnosti předpovědi a jako kritérium optimalizace. Zobrazení kontrolního kvadrantu je používáno k hodnocení přesnosti předpovědi.

Koeficient determinace umožňuje jednoduše porovnávat přesnost různých výsledků předpovědi. Například porovnat dvě hodnoty KD je mnohem jednodušší než porovnat zobrazení dvou kontrolních kvadrantů. Protože výsledkem KD je číslo, jde tato statistika použít jako kritérium optimalizačního modelu. Na druhou stranu skutečnost, že celá interpretace výsledků předpovědi je shrnuta pouze do jednoho čísla, představuje značné zjednodušení, které vede mnohdy k mylné interpretaci. Tato mylná interpretace je zvláště významná u tak nejednoznačného jevu, jakou jsou předpovědi průtoku s měsíčním krokem. Jsou pozorovány následující jevy:

1. Velká citlivost k jednotlivým hodnotám – na Obr. 4 je vlevo zobrazen případ, kdy se nepodařilo předpovědět jednu vysokou hodnotu průtoku, zatímco ostatní realizace průtoků se podařilo předpovědět mnohem lépe. Hodnota koeficientu determinace je v případě levého obrázku 0,097, což by podle definice KD znamenalo, že předpověď je velmi nepřesná. Ve skutečnosti je předpověď velmi dobrá, protože pokud odstraníme nevyšší hodnotu průtoku, vyjde KD = 0,603. Jedna hodnota může výrazně ovlivnit celkovou interpretaci výsledků pomocí KD.
2. Hodnoty KD nejsou reprezentativní, ale jsou porovnatelné – jak už je naznačeno v předchozí odrážce, skutečnost, že i velmi nízká hodnota KD nemusí indikovat nepřesnou předpověď, dělá z hodnoty KD nereprezentativní číslo v porovnání s jeho definicí. Na druhou stranu pokud hodnota KD má sloužit k porovnání dvou předpovědních způsobů pro jeden předpovědní případ, může poskytnout reprezentativní výsledky. Například pokud rozdílné předpovědní způsoby usilují o vyšší hodnotu KD při kalibraci, většinou obtížně předpovídají extrémní hodnotu průtoku, jejíž předpovědní hodnota se při různých hodnotách parametrů obou předpovědních způsobů příliš nemění. Jakékoliv změny v poloze tohoto extrémního průtoku by vyvolali změny pro hodnotu KD na prvním desetinném místě. Změny, které se odehrávají pro průtoky v oblasti běžného výskytu, se projevují v hodnotě KD na druhém a třetím místě pro oba porovnávané předpovědní způsoby, což vlastně umožňuje jejich porovnání, které může být objektivní.
3. Oprava vychýlení dat pomáhá pouze částečně – skutečnosti popsané v předchozích dvou odstavcích jsou také ovlivněny skutečností, že nejvíce četné výskyty průtoků jsou v nízkých hodnotách průtoku a vysoké hodnoty průtoku se vyskytují zřídka. Jinak řečeno hustota pravděpodobnosti realizací průtoku v jednotlivých měsících je nakloněna k nízkým hodnotám průtoku; což je patrné z obrázků výskytů všech realizací průtoků zobrazených v kapitole 7.1. Šikmá hustota pravděpodobnosti také ovlivňuje efektivitu použití filtrace dat k omezení mylné interpretace výsledků ovlivněných extrémní průtoky. Na Obr. 5 vlevo jde vidět dohromady tři extrémní hodnoty, které mohou ovlivňovat interpretaci výsledků pomocí KD. V případě levého obrázku má na celkovou hodnotu KD největší vliv nejvíce extrémní bod. Body v modrém rámečku mají na hodnotu KD minimální vliv. Avšak pokud extrémní hodnotu odstraníme, stávají se dominantními hodnotami určující výsledné KD další extrémy, což je vidět na Obr. 5 vpravo. Většinou je nutné odebrat velké množství extrémů, než přestane být výše popisovaný jev patrný, což ve výsledku ovlivňuje vazby mezi hodnotami průtoku natolik, že intepretace výsledků značně být nejednoznačná.

Příklady na obrázcích Obr. 4 a Obr. 5 jsou zvoleny takové, aby bylo jednoduché vysvětlit principy popsané výše. Případy řešené v rámci vývoje, kalibrace nebo validace modelu jsou mnohem více komplikované.

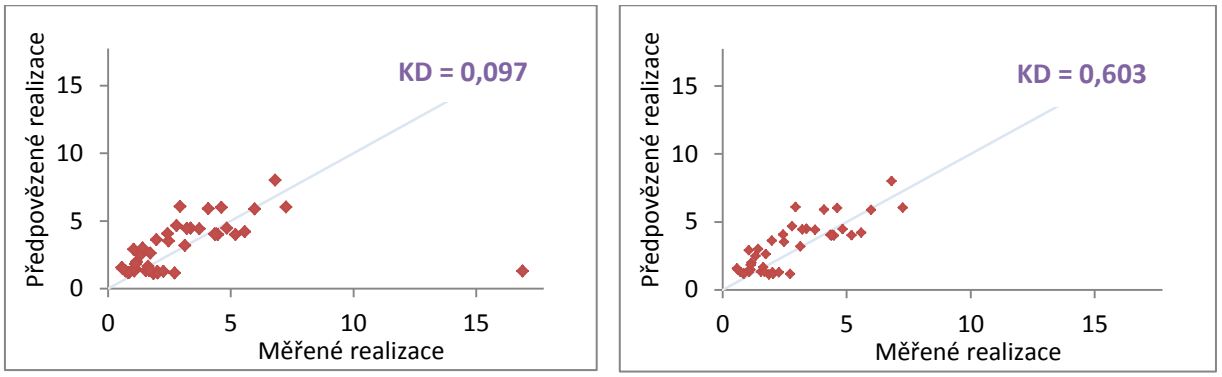

Obr. 4 – Vliv extrémů na hodnotu koeficientu determinace

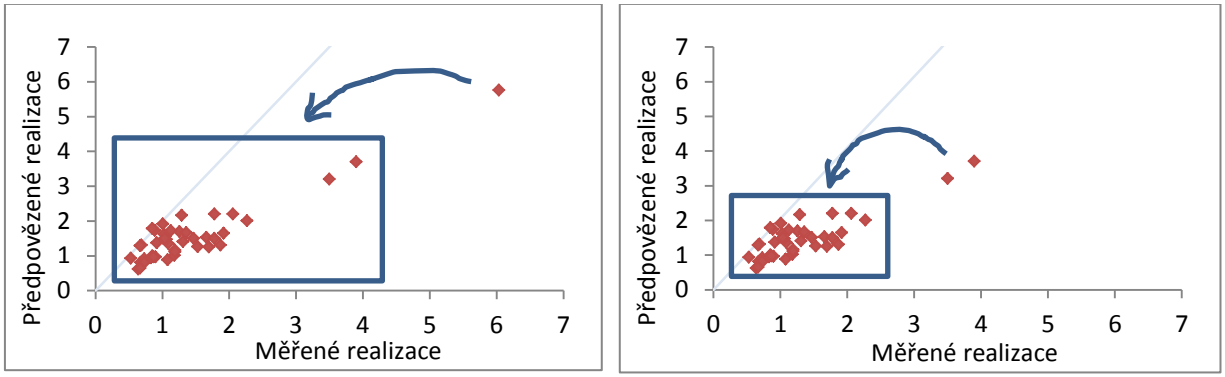

Obr. 5 – Vliv opravy vychýlení extrému na hodnotu KD

Zobrazení kontrolních kvadrantů umožňuje odstranit mylnou interpretaci přesnosti předpovědi pomocí KD popsanou výše. Protože je přesnost předpovědi hodnocena subjektivně, může být velmi náročné vhodně zkoumat velké množství zkoumaných souborů předpovědí a vzájemně je porovnávat, viz například Obr. 22, nebo může docházet k subjektivnímu zkreslení výsledků.

Koeficient determinace je používán jako orientační kritérium hodnocení přesnosti. Jednotlivé poznatky popsané v práci se více opírají o hodnocení přesnosti předpovědi pomocí zobrazení kontrolních kvadrantů, než pomocí KD.

Použití KD a zobrazení kontrolního kvadrantu k hodnocení přesnosti předpovědi může ovlivňovat volbu parametrů předpovědního modelu nebo interpretaci poznatků. Přesnost předpovědi validačního souboru je hodnocena KD nebo kontrolního kvadrantu. I když v rámci práce může být rozhodnuto nad určitou volbou parametrů předpovědního modelu, která vytváří dobrou přesnost předpovědi na validačním souboru, nemusí to zaručovat, že takováto předpověď bude vhodná také pro provoz zásobní funkce nádrže. Je předpokládáno, že při aplikaci předpovědního modelu pro provoz zásobní funkce nádrže, se bude použití předpovědního modelu zakládat na poznatcích popsaných v práci, než na nastavení modelu, který pro validační soubor vytvářel nejvyšší KD. KD a zobrazení kontrolního kvadrantu představují určité zastoupení aplikace, pro kterou má být předpověď použita. Aplikace předpovědi pro provoz nádrže je však otázkou dalšího výzkumu, kterým se práce nezabývá. V kapitole 7.4 je uvedena pouze jedna ukázka aplikace na předpovědním profilu Oslavany na řece Oslava.

6 Zvolené metody řešení

Kapitola popisuje zvolený předpovědní způsob, definuje oblast, na kterou se koncentruje jeho vývoj a aplikace a popisuje způsob kalibrace zvoleného modelu.

6.1 Úprava a zobrazení vstupních dat

6.1.1 Zobrazení dat

Průběh průměrných měsíčních hodnot časových řad je možno znázornit sloupcovým nebo bodovým grafem. Hodnoty bodového grafu leží na koncích každého měsíce grafu sloupcového. Zobrazení pomocí bodového grafu je používáno v rámci práce, viz Obr. 6.

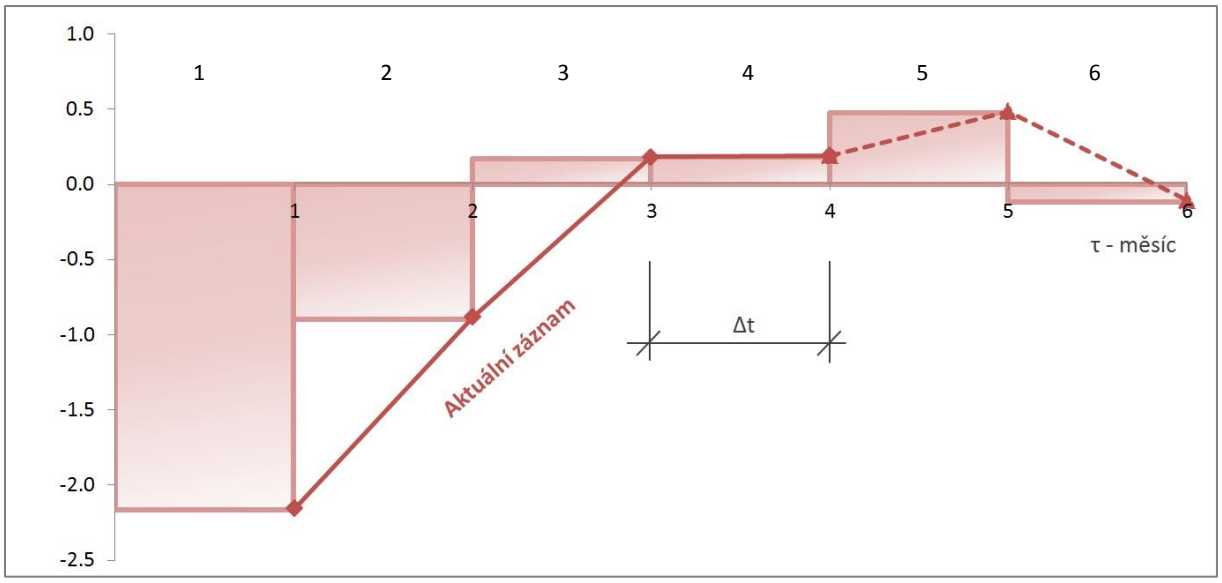

Obr. 6 - Zobrazení sloupcového a bodového zobrazení časové řady vstupních dat

6.1.2 Normalizace (standardizace) členů průtokových řad

Modely podobnosti pracují s normalizovanou časovou řadou. Při vytváření normalizované časové řady je nejprve logaritmováním odstraněna asymetrie. Touto operací se stanou realizace bodů časové v jednotlivých měsících popsatelné normálním rozdělením N ($\mu_{Y,m}$, $\sigma_{Y,m}$). Dále je logaritmovaná časová řada normována na rozdělení N (0,1). Provedené operace, které vychází ze vztahů

$$Q_{t,m} - reálná\ časová\ řada, \qquad (4)$$

$$Y_{t,m} = \log\left(\frac{Q_{t,m} - a_m}{b_m - Q_{t,m}}\right), \qquad (5)$$

$$Z_{t,m} = \frac{Y_{t,m} - \mu_{Y,m}}{\sigma_{Y,m}}, \qquad (6)$$

odstraní rozdíl v asymetriích, aritmetických průměrech a směrodatných odchylkách průměrných měsíčních průtoků mezi jednotlivými měsíci. Ve vzorcích t značí libovolný bod časové řady; m měsíc, kterému libovolný časový bod náleží; a, b parametry logaritmické transformace.

Parametry a, b jsou hledány mřížkovou optimalizační metodou pro měsíce leden až prosinec. Mřížka všech možných realizací parametru a, b je procházena, dokud není nalezen koeficient šikmosti rovný

nebo menší hodnotě 0,0001. Pokud vstupní časová řada obsahuje nulové hodnoty, jsou přepsány na hodnotu 0,01, aby mohla být data logaritmována, což byla potřeba například u průměrných srážkových úhrnů řeky Umpqua, které jsou v letních měsících nulové.

Rozdíl mezi časovými řadami reálných dat a logaritmicko normálně transformovaných je patrný z Obr. 7 a Obr. 8. Pro přepočet transformovaných dat zpět do reálných průtoků je použit inverzní postup

$$Y_{t,m} = Z_{t,m} \cdot \sigma_{Y,m} + \mu_{Y,m}, \quad (7)$$

$$Q_{t,m} = \frac{10^{Y_{t,m} * b_m + a_m}}{10^{Y_{t,m}+1}}, \quad (8)$$

Měsíc	1	2	3	4	5	6	7	8	9	10	11	12
Průměr	59	74	113	104	67	54	53	39	32	32	43	56
Sm. odch	31	49	47	52	36	36	66	36	21	25	24	32

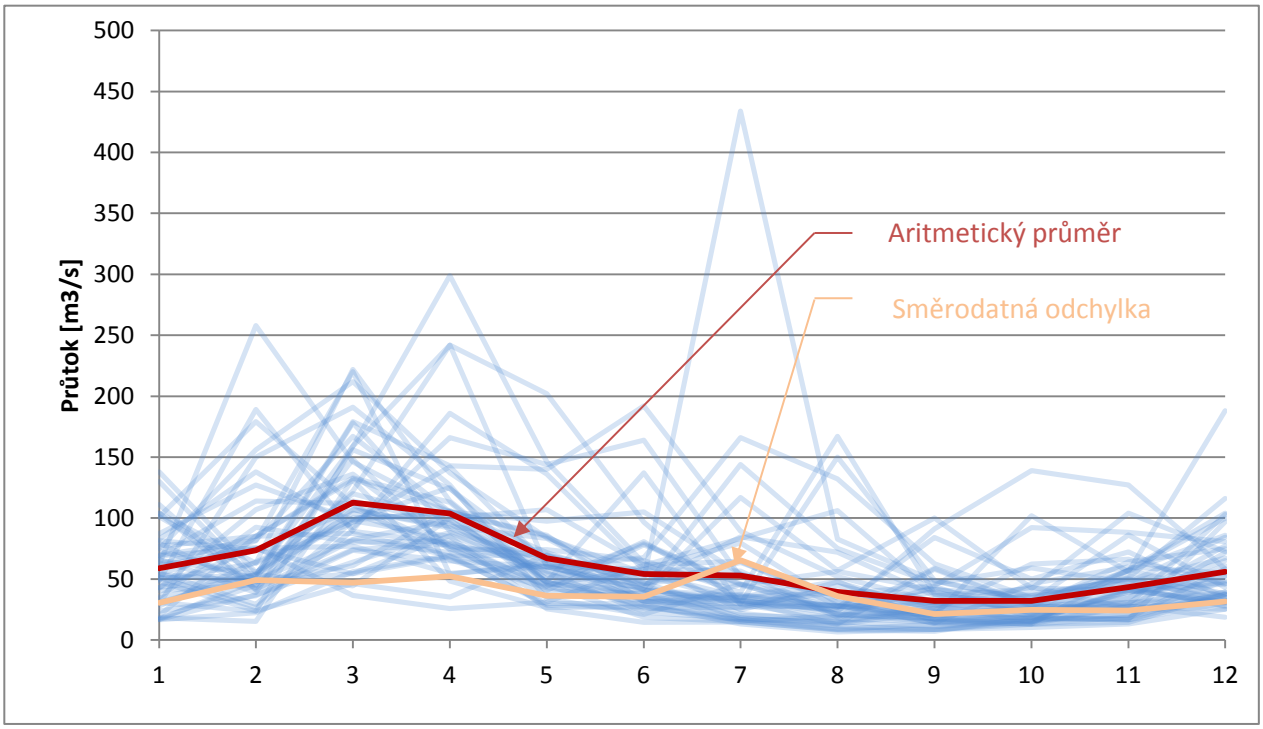

Obr. 7 - Realizace všech měření v profilu Strážnice na řece Morava v reálných průtocích

Měsíc	1	2	3	4	5	6	7	8	9	10	11	12
Průměr	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
Sm. odch	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0

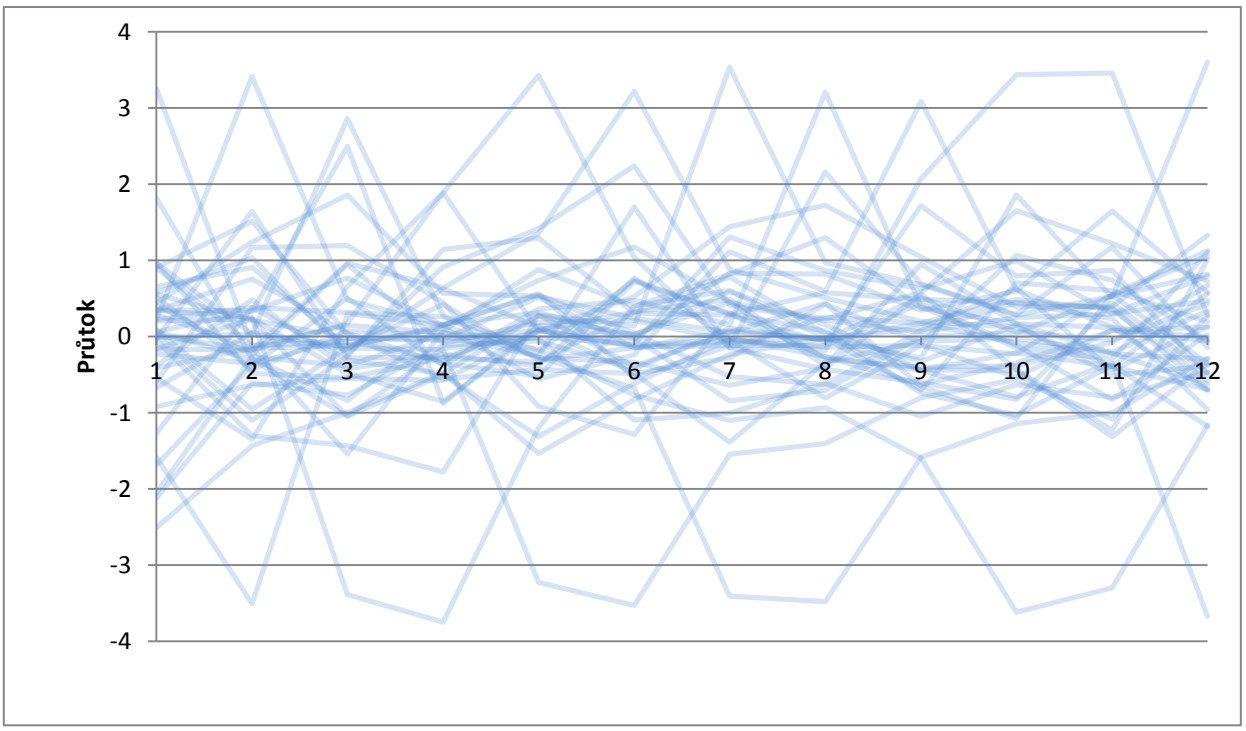

Obr. 8 - Realizace všech měření v profilu Strážnice na řece Morava po normalizaci

V průběhu vyvíjení modelu podobnosti bylo testováno, zda bude vhodnější pracovat s normalizovanými daty nebo s reálnými daty. Předpovědi vytvořené použitím normalizovaných dat a reálných dat byly srovnatelné a s ohledem na přesnost vytvářené předpovědi, nebyl nalezen žádný důvod k privilegování reálných nebo log-normálních vstupních dat. Pro rozšíření modelu podobnosti o využití časových řad srážek a teplot (viz kap 6.2.2) byla zvolena taková konstrukce modelu podobnosti, která vyžadovala, aby všechny členy vstupní časové řady byly normalizovány.

6.1.3 Oprava vychýlení vstupních dat

Pro účely kalibrace modelu a hledání kalibračních vzorů byla data opravena o vychýlení od extrémů. Oprava vychýlení extrémů umožnilo rozkrýt nejednoznačný interpretaci výsledků pro volbu optimálních parametrů modelu podobnosti prováděných v průběhu subjektivní kalibrace, viz 0. Například interpretace výsledků může být zkreslena jedním maximálním extrémem, který jde vidět na Obr. 7 v sedmém měsíci. Pro rozhodnutí nad volbou parametrů modelu v průběhu subjektivní kalibrace jsou však využívány opravené i neopravené datové soubory. Dosažené přesnosti předpovědi jsou získány pro oba datové soubory, následně jsou navzájem porovnány a na jehož základě je rozhodnuto o vhodné volbě parametrů modelu.

V rámci práce jsou odstraňovány pouze maximální extrémy průtokových řad. Vynechaný extrém je nahrazen aritmetickým průměrem všech realizací pro příslušný měsíc. Odstranění extrémů bylo aplikováno pouze u menších povodí, jmenovitě profilů na řekách Morava, Jihlava, Oslava, které jsou více náchylné na výkyv měřených veličin (průtok, srážka, teplota). Odstranění maximálních extrémů je uvedeno v Tab. 1 a Tab. 2. Číslo uvedené v tabulce určuje, kolik extrémů bylo odstraněno. Pokud je v tabulce uvedeno číslo větší jak jedna, znamená to, že jsou odstraněny dva nebo více největších extrémů. Extrémy jsou vynechávány ve dvou stupních, malé a větší ubrání extrémů. Vznikají tak dva datové soubory s ubranými daty.

Vynechání extrémů vedlo v některých případech ke zlepšení interpretace výsledků kalibrace. Naopak vynechání příliš velkého množství extrémů vedlo k větší nejednoznačnosti výsledků kalibrace, protože dochází k příliš velkému zásahu do vzájemných vazeb v povodí, viz kapitola 1. Konkrétní velikost jednotlivých ubrání je vidět Tab. 1 a Tab. 2.

Tab. 1 - Evidence malého vynechání extrémních průtoků

Měsíc	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**
Morava	1	1	0	1	1	0	1	0	0	1	1	1
Jihlava	1	1	1	1	1	1	2	1	4	1	4	1
Oslava	1	1	2	1	1	2	2	1	2	1	1	1

Tab. 2 - Evidence velkého vynechání extrémních průtoků

Měsíc	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**
Morava	2	1	0	3	4	3	3	3	3	3	1	1
Jihlava	3	6	5	5	4	3	4	4	4	4	4	3
Oslava	4	4	3	3	4	2	3	3	2	5	2	1

V rámci práce jsou vynechávány extrémy pouze průtokových řad, i když model využívá srážkovou nebo teplotní časovou řadu k vytváření předpovědi. To znamená, že i když je v jednom měsíci nalezen extrémní průtok, je změněn na aritmetický průměr pouze průtok a ne srážková nebo teplotní data v tom samém měsíci, viz Tab. 3. K tomuto postupu vedla úvaha, že je zde prokazatelný vliv extrémního průtoku na nejednoznačnost interpretace výsledků kalibrace, avšak zde není tak jednoznačný vliv jedné extrémní hodnoty srážky nebo teploty na extrémní hodnotu průtoku v dalším časovém kroku. Skutečnost popsaná v předchozí větě je o to více patrná u malých povodí (Morava, Jihlava, Oslava), u kterých je oprava vychýlení uplatněno. U malých povodí jsou velmi malé korelační vazby mezi průtoky a srážkami spadlé v tom samém měsíci nebo v předchozím oproti například Dunaji, kde je jasně prokazatelné, že srážka spadlá na povodí v jednom měsíci má přímý vliv na průtok v dalším měsíci.

Tab. 3 - Příklad vynechání extrému pro extrémní případ na Moravě v roce 1997

Rok	Měsíc	Původní data			Opravená data		
		Průtok	Srážka	Teplota	Průtok	Srážka	Teplota
1997	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	5	69,8	92,3	286,7	69,8	92,3	286,7
	6	50,4	84,6	289,9	50,4	84,6	289,9
	7	434,0	307,9	289,6	**53,0**	307,9	289,6
	8	82,8	45,8	291,3	82,8	45,8	291,3
	9	48,3	38,2	286,0	48,3	38,2	286,0
	⋮	⋮	⋮	⋮	⋮	⋮	⋮

Realizace všech dostupných dat k jednotlivým profilům uvedené v přílohách 12.2 až 12.2.6 jsou uvedeny bez opravy vychýlení dat. Další zobrazení v přílohách 12.2 až 12.2.6 mohou být zjištěny z dat opravených o vychýlení. Pokud tomu tak je, je uvedeno v nadpise měsíce, kolik extrémů bylo odstraněno.

Jak konkrétně se projevuje oprava vychýlení dat na výsledky kalibrace, je podrobněji popsáno v kapitole 6.5.5.

6.2 Popis principu předpovědní metody

Aktuální záznam je měření pozorované před okamžikem vydávání předpovědi a *historické záznamy* jsou množinou měření pozorovaných v minulosti ve stejné oblasti, jako je aktuální záznam. Všechny body ležící před okamžikem vydávání předpovědi patří do tzv. *porovnávané množiny* (včetně okamžiku vydávání předpovědi). Body ležící za okamžikem vydávání předpovědi patří do *předpovídané množiny*, viz Obr. 11

Většina současných modelů pro vytváření střednědobých předpovědi vytváří předpověď na základě rozboru historicky naměřených záznamů v povodí. Rozbor historicky naměřených záznamů bývá podkladem k nastavení parametrů výpočetního aparátu modelu. Pokud model disponuje zvolenými parametry, je schopný vypočítat předpověď na základě zadání vstupů modelu. S určitým zjednodušením jde prohlásit, že historicky naměřené záznamy obsahují stěžejní informaci pro získání předpovědi. Na počátku volby metody pro vytváření střednědobých předpovědí byl záměr vytvořit předpověď přímo z podobných historických záznamů, bez mnohdy velmi složitých matematických aparátů používaných modelů.

Je předpokládáno, že po nalezení historicky podobného záznamu, bude předpověď aktuálního záznamu vytvořena z průběhu historického záznamu v oblasti předpovídané množiny.

V počátku vývoje principu předpovědi byl záměr hledat historicky podobné případy na základě podobnosti průběhu časových řad v porovnávané množině; jinak řečeno o podobnosti historického případu rozhodovat na základě *grafické podobnosti*. Například na Obr. 9 je zobrazen příklad podobného historického průběhu a na Obr. 10 příklad málo podobného historického průběhu. Grafická podobnost byla hledána subjektivně na základě prohlížení a porovnávání průběhu historického a aktuálního záznamu v porovnávané množině. Zájmem bylo získat zkušenosti o nalezení podobného historického případu, které by bylo možné následně matematicky formulovat a předpověď automatizovat.

Princip rozpoznání podobnosti byl vyvíjen s pomocí průtokových časových řad, avšak následně byly vyvinuté principy použity i na rozpoznání podobnosti srážkových a teplotních časových řad.

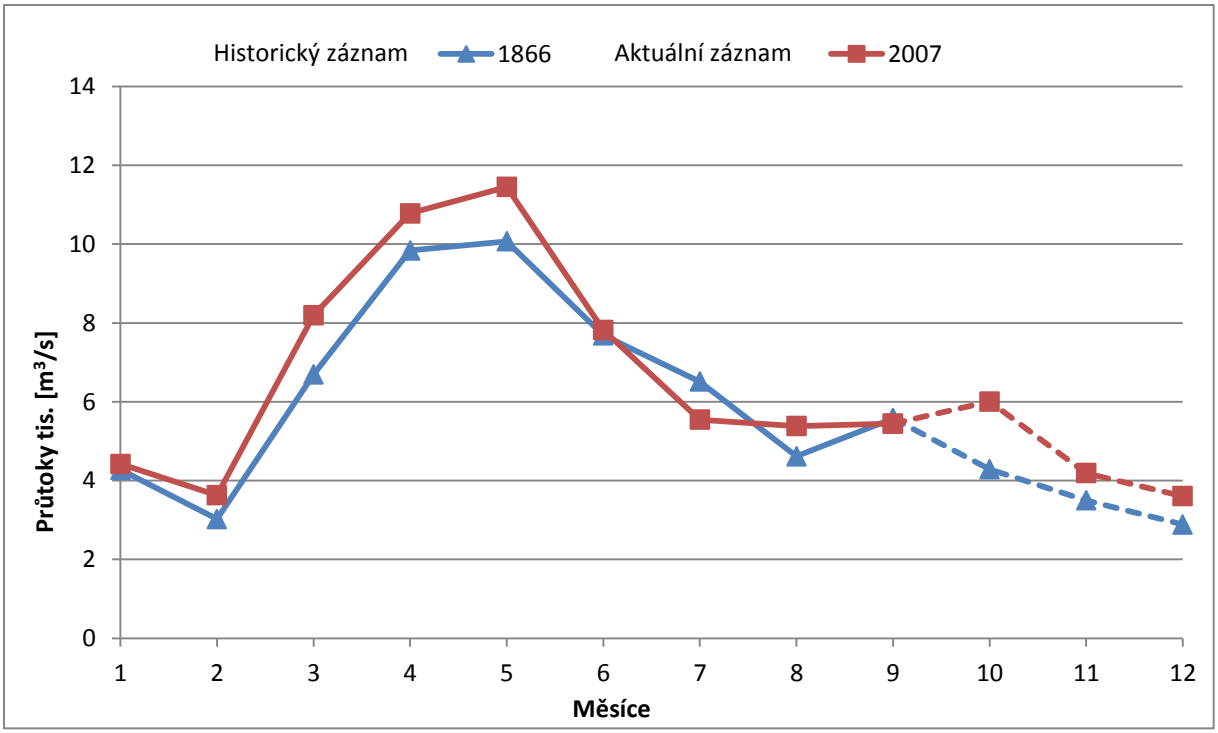

Obr. 9 – Podobný historický případ

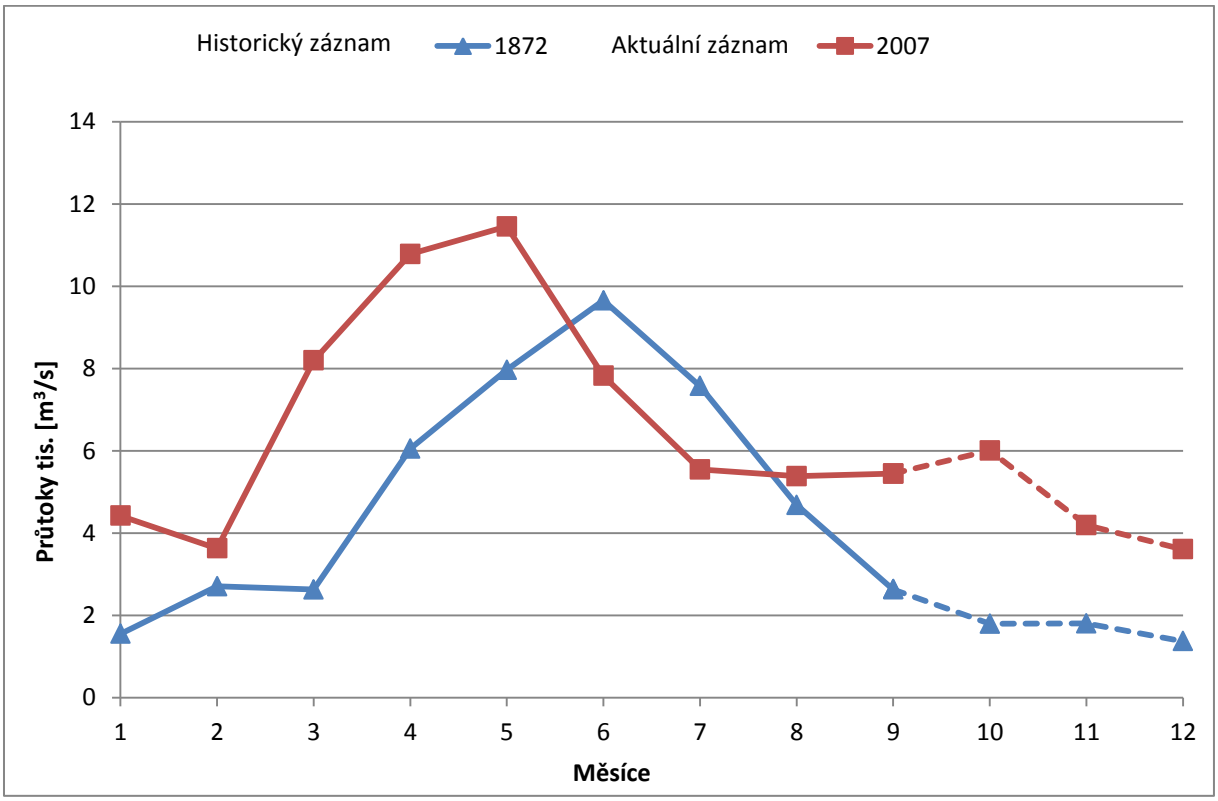

Obr. 10 – Málo podobný historický případ

Na základě zkušeností, získaných při subjektivním hodnocení podobnosti historického a aktuálního záznamu, je stanoven princip rozpoznání podobnosti podle polohy bodů historického a aktuálního záznamu, viz Obr. 11 nazvaný *princip odchylek*. Ve většině případů se jeví vhodnější vytvořit předpověď průměrem několika vybraných nejvíce podobných historických záznamů, protože předpověď s pomocí pouze jedné nejvíce podobné historické řady je příliš náhodná. Vliv bodů ležících

v porovnávané oblasti na rozhodnutí o podobnosti historického a aktuálního záznamu je ohodnocen váhami. Význam vah klesá s rostoucí vzdáleností bodu do okamžiku předpovědi. Předpověď principem odchylek je matematicky formulována v rovnicích (9) až (19).

V průběhu subjektivního hodnocení podobnosti historického a aktuálního záznamu byly stanoveny i další principy rozpoznání podobnosti. *Princip trendu* a princip *zonálního pravděpodobnostního modelu* je matematicky formulován v kapitole 6.2.2. Principy předpovědi dvou uvedených způsobů nejsou prozkoumány tak podrobně jako princip odchylek a proto se práce koncentruje na předpověď principem odchylek. Na druhou stranu je předpokládáno, že princip trendu a princip zonálního pravděpodobnostního modelu mají potenciál k vytváření střednědobých předpovědí a v rámci budoucího výzkumu je stojí za to je rozvíjet.

Protože předpovědní princip odchylek modeluje historickou podobnost, je v práci nazýván *modelem podobnosti.*

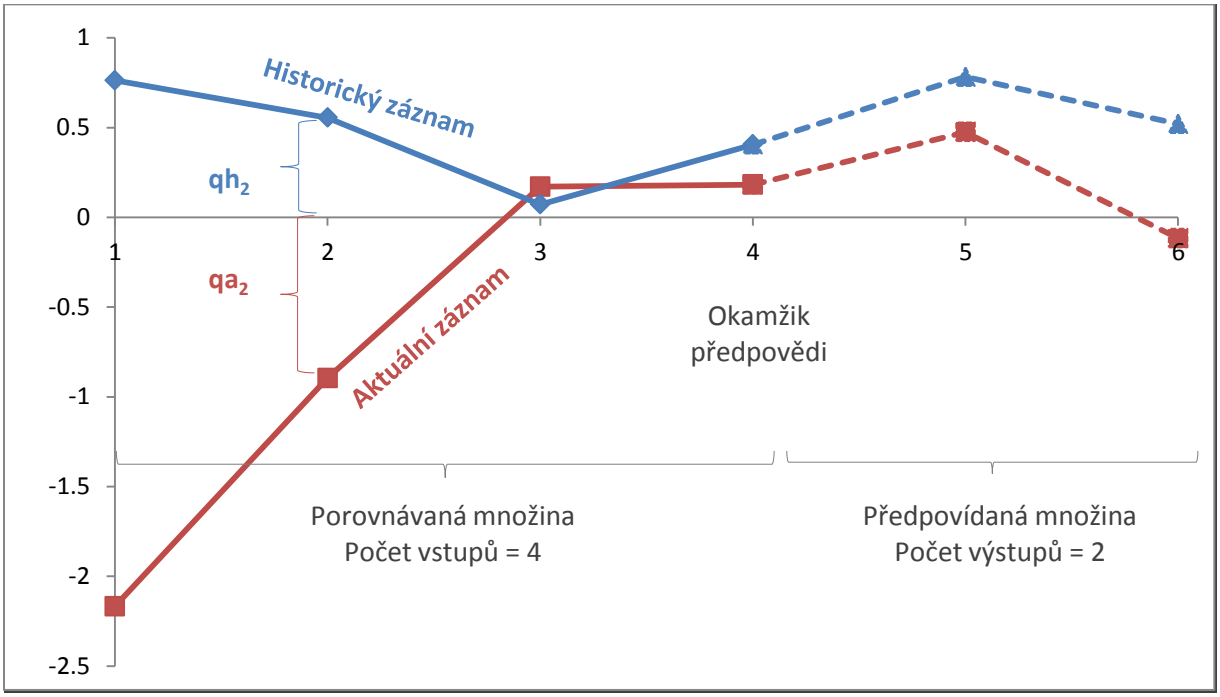

Obr. 11 - Schéma předpovědi modelem odchylek

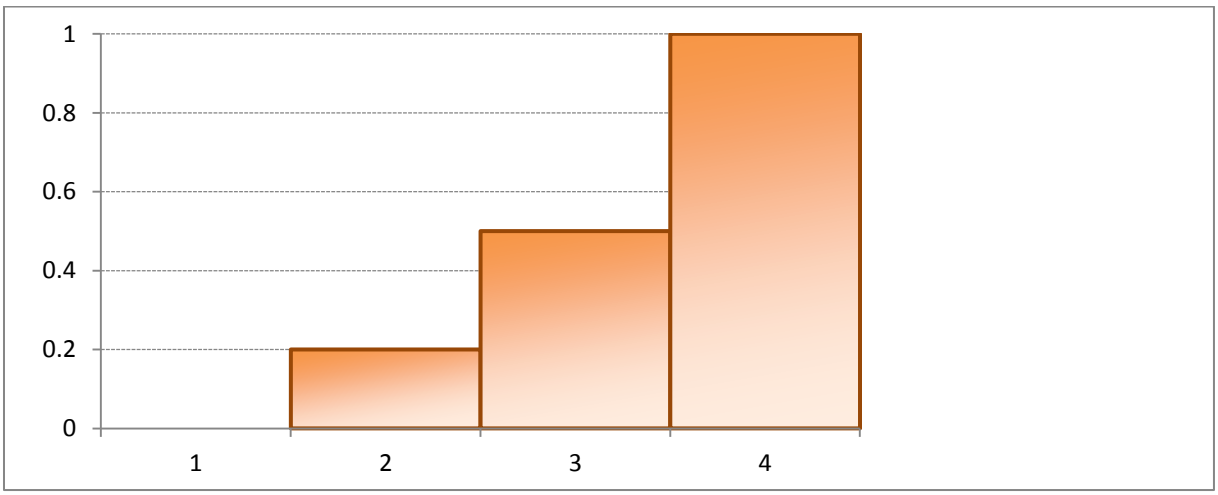

Obr. 12 - Schéma vah modelu odchylek

Matematická formulace předpovědi **principem odchylek** je následovná. Nechť je aktuální záznam dán vektorem

$$\boldsymbol{QA} = (qa_1, qa_2, \dots, qa_i, \dots qa_n) \quad \textbf{(9)}$$

kde n = počet vstupních měsíců (tj. počet bodů časové řady náležící do porovnávané množiny). Historické záznamy tvoří matici

$$\boldsymbol{QH} = \begin{pmatrix} qh_{1,1} & qh_{1,2} & \cdots & qh_{1,i} & \cdots & qh_{1,n+v} \\ \vdots & \vdots & & \vdots & & \vdots \\ qh_{j,1} & qh_{j,2} & \cdots & qh_{j,i} & \cdots & qh_{j,n+v} \\ \vdots & \vdots & & \vdots & & \vdots \\ qh_{m,1} & qh_{m,2} & \cdots & qh_{m,i} & \cdots & qh_{m,n+v} \end{pmatrix} \quad \textbf{(10)}$$

kde n = počet vstupních měsíců, v = počet výstupních měsíců (počet výstupních měsíců určuje množství bodů náležící do předpovídané množiny), m = počet historických záznamů. Nechť je dán vektor vah

$$\boldsymbol{W} = (w_1, w_2, \dots, w_i, \dots w_n) \quad \textbf{(11)}$$

kde n = počet vstupních měsíců, $w_i \in < 0, 1 >$. Váha v bodě vydávané předpovědi má vždy hodnotu rovnou jedné. Další hodnoty vah se zmenšují se vzdáleností od okamžiku vydávání předpovědi, viz Obr. 12. Potom vzájemná podobnost aktuální a historické časové řady při vydávání předpovědi za použití modelu odchylek bude vyhodnocena podle kritéria

$$Podobobnost_j = s_j = \sum_{i=1}^{n} (qa_i - qh_i)^2 \cdot w_i \quad \textbf{(12)}$$

pro j = 1,2,…m. Čím je podobnost s_j menší, tím je aktuální a historický záznam více podobný. Kritérium podobnosti s_j je tedy postupně vypočítáno pro všechny historické záznamy a příslušné hodnoty jsou zaznamenány do vektoru podobnosti S

$$\boldsymbol{S} = \left(s_1, s_2, \dots, s_j, \dots s_m\right)^T, \quad \textbf{(13)}$$

kde m = počet historických záznamů. Z vektoru podobnosti je následně vybráno několik nejmenších hodnot $s_{min,1}$, $s_{min,2}$,…, $s_{min,u}$, a jejich příslušných pozic v matici historických záznamů r_1, r_2,…, r_u. Odpovídající hodnoty $s_{min,i}$ a r_i tvoří matici $\boldsymbol{\Pi}$ tvoří dvouřádkovou matici PI

$$\boldsymbol{\Pi} = \begin{pmatrix} s_{min,1} & s_{min,2} & \cdots & s_{min,i} & \cdots & s_{min,u} \\ r_1 & r_2 & \cdots & r_i & \cdots & r_u \end{pmatrix} \quad \textbf{(14)}$$

Kde platí

$$s_{min,1} < s_{min,2} < \cdots < s_{min,i} < \cdots < s_{min,u} \quad \textbf{(15)}$$

kde s_{min} – minimální hodnota kritéria podobnosti, r_i – poloha minima v matici historických záznamů, u – počet vybraných nejvíce podobných historických záznamů. Podle hodnoty r_i pro i = 1, 2, … , u, je postupně vložen příslušný řádek z matice historických záznamů do matice vybraných řádků

$$\boldsymbol{QV} = \begin{pmatrix} qv_{1,1} & \cdots & qv_{1,i} & \cdots & qv_{1,n+v} \\ \vdots & & \vdots & & \vdots \\ qv_{j,1} & \cdots & qv_{j,i} & \cdots & qv_{j,n+v} \\ \vdots & & \vdots & & \vdots \\ qv_{u,1} & \cdots & qv_{u,i} & \cdots & qv_{u,n+v} \end{pmatrix}, \quad \textbf{(16)}$$

kde n = počet vstupních měsíců, v = počet výstupních měsíců.

V nejjednodušším případě je možno považovat za předpovězené průtoky prvky prvního řádku matice QV, tedy $qv_{1,i}, kde: i = n+1, n+2, \dots, n+v$, kdy z matice historických záznamů je podle zvoleného kritéria podobnosti nejvíce podobný aktuálnímu záznamu.

Numerické experimenty prokázaly, že předpověď s využitím pouze prvního řádku matice QV je většinou velmi náhodná. Proto je možné vytvořit předpověď aktuálního záznamu průměrem mezi odpovídajícími prvky matice vybraných řádků. Průměrování je provedeno pouze v předpovídané oblasti a jejím výsledkem je vektor

$$\boldsymbol{QP} = (qp_1, qp_2, \dots, qp_i, \dots qp_v), \quad \textbf{(17)}$$

kde pro jednotlivé prvky vektoru platí

$$qp_i = \frac{\sum_{j=1}^{u} qv_{j,i}}{u}, \quad \textbf{(18)}$$

$pro\ i = n+1, n+2, \dots n+v.$

6.2.1 Rozšíření modelu podobnosti o využití předpovědní srážkových a teplotních dat

Ve své nejjednodušší formě vytváří model podobnosti předpověď pomocí podobnosti časových řad průtoku. V předpovědních profilech na území České republiky vycházelo hodnocení přesnosti předpovědi vytvořené hledáním podobností pouze průtokových řad stejně nebo hůř jako odhad budoucích přítoků aritmetickým průměrem předchozích měření (KD kolem nuly). S předpokladem zlepšení předpovědi modelem podobnosti byl model rozšířen o možnost hledat nejvíce podobný historický případ na základě podobnosti průtokové, srážkové a teplotní časové řady.

Postup popsaný v předchozí kapitole je rozšířen o nalezení podobnosti pro všechny tři časové řady.

$$\begin{aligned} Podobobnost_j = s_j \\ = v_p \cdot \sum_{i=1}^{n} (qa_i - qh_i)^2 \cdot w_i + v_s \cdot \sum_{i=1}^{n} (sa_i - sh_i)^2 \cdot w_i + v_t \\ \cdot \sum_{i=1}^{n} (ta_i - th_i)^2 \cdot w_i \end{aligned} \quad \textbf{(19)}$$

Kde: qa_i, qh_i – aktuální a historický záznam průtoku; sa_i ,sh_i – aktuální a historický záznam srážek; ta_i, th_i – aktuální a historický záznam teplot; v_p, v_s, $v_t \in < 0, 1 >$ – vliv průtokové, srážkové, teplotní časové řady na podobnost.

Následný postup pro vytvoření předpovědi je stejný, jako je popsáno ve vztazích (13) až (18).

Pro vytvoření předpovědi jde využití jednotlivých časových řad kombinovat. Například předpověď může být vytvořena na základě podobnosti průtokové a teplotní řady nebo jenom pouze na základě

podobnosti srážkových řad atd. Model však vždy musí mít k dispozici průtokovou řadu, z které stanovuje samotnou hodnotu předpovídaného průtoku. I když jde zapojení různých datových řad kombinovat, zabývá se práce využitím všech třech časových řad, tj. průtokové, srážkové a teplotní.

Pro rozšíření modelu podobnosti byly zvoleny srážkové řady na základě předpokladu, že velikost srážky má významný podíl na velikost průtoku v předpovědním profilu. Teplotní řady byly zavedeny s předpokladem, že v jarních obdobích určuje právě teplota velikost odtoku vody z povodí. Oba předpoklady byly aplikací modelu potvrzeny a podrobnosti jde nalézt v kapitole 1.

Zavedení srážek a teplot vedlo k významnému zlepšení přesnosti předpovědi. Příklady velikosti zlepšení předpovědi jsou v Tab. 4. Pro každý předpovědní profil je v tabulce uvedena v řádku „průměr“ průměrná hodnota KD, vypočtená ze všech měsíců. Ve sloupci „P“ je předpověď vytvořená pouze porovnáváním podobností průtokových řad, „PS“ předpověď vytvořená podobností průtokových a srážkových řad, „PST“ průtokových, srážkových a teplotních řad. V řádku zlepšení je potom rozdíl mezi hodnotami KD v jednotlivých sloupcích „P“, „PS“, „PST“.

Tab. 4 - Příklady zlepšení předpovědi na základě zavedení předpovědi s využitím srážkových a teplotních řad

	Danube			**Rhein**			**Umpqua**		
	PST	PS	P	PST	PS	P	PST	PS	P
Průměr	0.724	0.704	0.477	0.514	0.483	0.336	0.331	0.307	0.240
Zlepšení		0.020	0.227		0.032	0.147		0.024	0.067

	Morava			**Jihlava**			**Oslava**		
	PST	PS	P	PST	PS	P	PST	PS	P
Průměr	0.283	0.240	0.115	0.325	0.240	0.160	0.309	0.247	0.174
Zlepšení		0.044	0.125		0.085	0.080		0.062	0.073

Z tabulky je zřejmé, že čím větší je řeka, tím více se zlepší předpověď, pokud je využívána podobnost srážkových řad. Naopak v porovnání s velkými povodími způsobí u malých povodí stejné zlepšení využití teploty jako využití srážek.

Rozšíření umožnilo dosažení přesnějších odhadů budoucích průtoků, ale také poskytnulo nový vhled do problematiky vytváření středně dobé předpovědi. Například v některých případech je nejvíce podobný historický případ nalezen pouze pomocí podobnosti klimatických scénářů (srážka, teplota), bez jakéhokoliv ohledu na podobnost průtoků v porovnávané oblasti, více v kapitole 1.

6.2.2 Další způsoby možného řešení

Kapitola představuje další principy vytváření předpovědi, které byly v rámci práce zkoumány. Princip předpovědi níže uvedených dvou způsobů je sice vytvořen, avšak jejich aplikace pro vytváření střednědobých předpovědí není příliš široce zpracována. Na druhou stranu je předpokládáno, že tyto předpovědní modely mají potenciál k vytváření střednědobých předpovědí a v rámci budoucího výzkumu je stojí za to je rozvíjet.

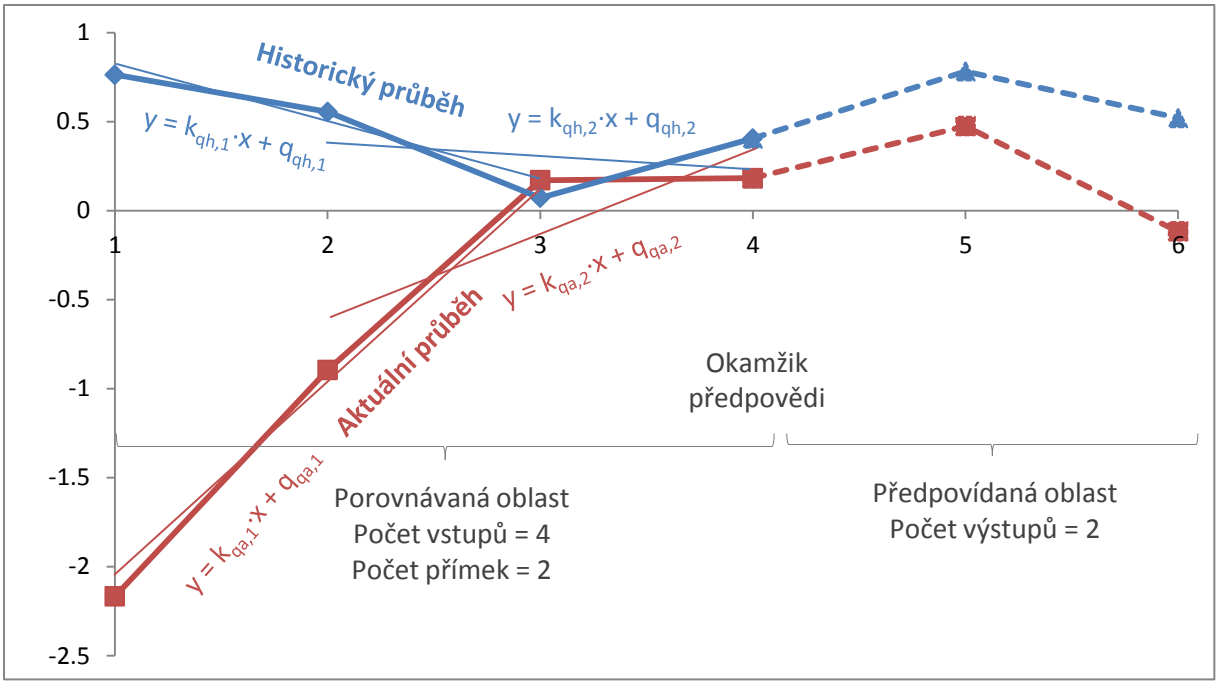

Obr. 13 - Schéma předpovědi modelem trendu

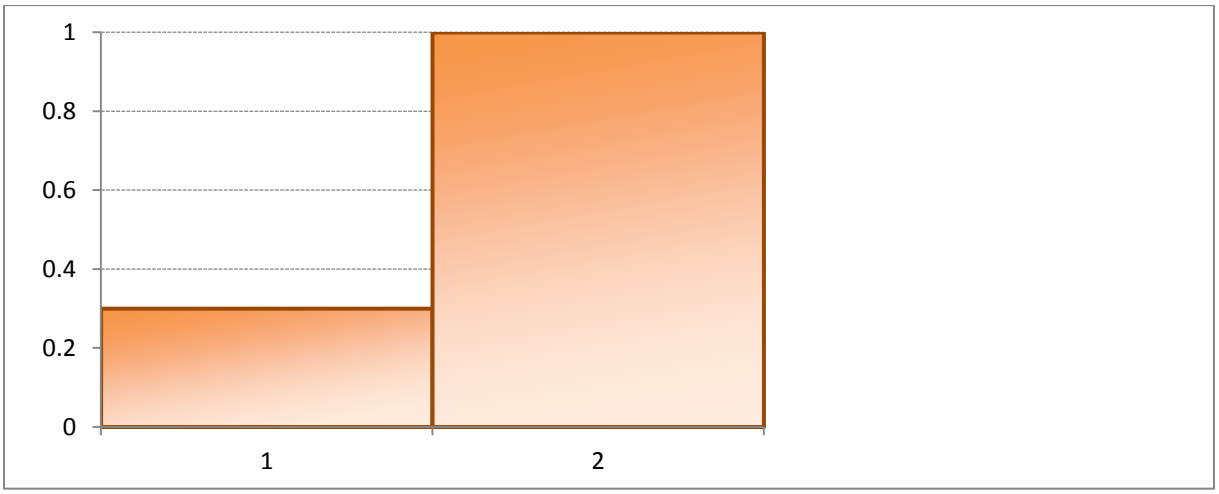

Obr. 14 - Schéma vah modelu trendu

Předpověď **principem trendu** má obdobný postup jako předpověď pomocí principu odchylek, liší se pouze ve způsobu rozpoznání podobnosti a výpočtu předpovědi. Vektor aktuálního záznamu a matice historických záznamů jsou definovány stejně jako ve vztazích (9) a (10). Vektor vah je dán

$$\boldsymbol{W} = (w_1, w_2, \dots, w_i, \dots w_{pp}), \qquad \textbf{(20)}$$

kde: pp – počet přímek, kterými je prokládaná historická a předpovídaná řada, viz Obr. 13, $w_i \in < 0, 1 >$, viz Obr. 14. Aktuální a historický záznam jsou v porovnávané množině proloženy několika přímkami metodou nejmenších čtverců. Přímky jsou určeny ze třech bodů časové řady klouzavým průměrem pro každou posloupnost třech bodů, viz Obr. 13. Vzájemná podobnost aktuální a historické časové řady při vydávání předpovědi bude za použití modelu trendu vyhodnocena podle kritéria

$$Podobobnost = s = \sum_{i=1}^{pp} (k_{qa,i} - k_{qh,i})^2 \cdot w_i, \quad \textbf{(21)}$$

kde: pp – počet přímek, $k_{qa,i}$ a $k_{qh,i}$ dvojce klouzavých směrnic odpovídajících si přímek proložených aktuálním záznamem a historických záznamem. Další postup předpovědi je stejný jako ve vztazích (13) až (16). Oproti modelu odchylek může model trendu nalézt podobné průběhy časových řad na různých úrovních (vertikálně posunuté). Takto podobný historický záznam je nezbytné přiblížit aktuálnímu. Proto jsou jednotlivé body výsledného vektoru

$$\boldsymbol{QP} = (qp_1, qp_2, \dots, qp_i, \dots qp_v), \quad \textbf{(22)}$$

určeny podle následujícího postupu. Nejprve je vypočítán průměr sloupců matice vybraných řádků a je zapsán do vektoru

$$\boldsymbol{QPV} = (qph_1, qph_2, \dots, qph_i, \dots qph_{n+v}) \quad \textbf{(23)}$$

kde pro jednotlivé prvky vektoru platí

$$qpv_i = \frac{\sum_{j=1}^{u} qv_{j,i}}{u}, \quad \textbf{(24)}$$

$pro\ i = 1, 2, \dots, n + v$. Přiblížení průměru matice vybraných řádků k aktuálnímu záznamu je realizováno vypočtením střední hodnoty v porovnávané oblasti pro oba vektory pomocí vztahů

$$\overline{qpv}_w = \frac{\sum_{i=1}^{n} qpv_i}{n}, \quad \textbf{(25)}$$

$pro\ i = 1, 2, \dots, n$. Průměr je určen také pro vektor aktuálního záznamu

$$\overline{qa}_w = \frac{\sum_{i=1}^{n} qa_i}{n}, \quad \textbf{(26)}$$

$pro\ i = 1, 2, \dots, n$. Jednotlivé body výsledného vektoru QP jsou potom určeny vztahem

$$qp_i = qpv_i + (\overline{qa}_w - \overline{qpv}_w), \quad \textbf{(27)}$$

$pro\ i = n + 1, n + 2, \dots n + v$.

Výpočet podobnosti principem trendu s využitím průtokových, srážkových a teplotních časových řad je následovný

$$\begin{aligned} Podobobnost = s \\ = v_p \cdot \sum_{i=1}^{pp} \left(k_{qa,i} - k_{qh,i}\right)^2 \cdot w_i + v_s \cdot \sum_{i=1}^{pp} (k_{sa,i} - k_{sh,i})^2 \cdot w_i + v_t \\ \cdot \sum_{i=1}^{pp} (k_{ta,i} - k_{th,i})^2 \cdot w_i, \end{aligned} \quad \textbf{(28)}$$

Kde: $k_{qa,i}$, $k_{qh,i}$, $k_{sa,i}$, $k_{sh,i}$, $k_{ta,i}$, $k_{th,i}$,– jsou dvojce klouzavých směrnic odpovídajících si přímek proložených aktuálním záznamem a historických záznamem průtokovýchm srážkových a teplotních časových řad; v_p, v_s, $v_t \in < 0, 1 >$ – vliv průtokové, srážkové, teplotní časové řady na podobnost.

Zonální pravděpodobností model

Oblast všech realizací historických záznamů je rozdělena na několik *intervalů výskytu*. Průměrné měsíční průtoky jsou v každém měsíci rozděleny na šest oblastí a zájmem rozdělení je vystihnout jednotlivé oblasti četnosti výskytu průměrného měsíčního průtoku. Ukázka rozdělení na intervaly výskytu pro řeku Moravu je na Obr. 15.

Všechny data historických záznamů, které padnou do jednoho z intervalů výskytu, představují *předpovědní svazek*. Ukázka předpovědního svazku je na Obr. 16. Všechny realizace historických záznamů ležících v předpovědním svazku v předpovídané množině jsou proloženy trojúhelníkovou hustotou pravděpodobnosti. Poloha vrcholu trojúhelníkové hustoty pravděpodobnosti představuje modus, tj. polohu realizace s největší četnosti výskytu.

Předpověď aktuálního záznamu, představuje průběh modu od okamžiku vytváření předpovědi, podle toho, do jakého intervalu výskytu padne poslední měřená hodnota aktuálního záznamu. Pokud hodnota modu padne nad aritmetický průměr anebo pod jednu třetinu vzdálenosti mezi minimem a aritmetickým průměrem je navrácena zpět do těchto limitů.

Matematický zápis má následující podobu. Nechť je aktuální záznam dán vektorem

$$\boldsymbol{QA} = qa \qquad \textbf{(29)}$$

o jedné hodnotě, představující pozorovaný průtok v okamžiku vytváření předpovědi. Historické záznamy tvoří matici

$$\boldsymbol{QH} = \begin{pmatrix} qh_{1,1} & qh_{1,2} & \cdots & qh_{1,i} & \cdots & qh_{1,v} \\ \vdots & \vdots & & \vdots & & \vdots \\ qh_{j,1} & qh_{j,2} & \cdots & qh_{j,i} & \cdots & qh_{j,v} \\ \vdots & \vdots & & \vdots & & \vdots \\ qh_{m,1} & qh_{m,2} & \cdots & qh_{m,i} & \cdots & qh_{m,v} \end{pmatrix} \qquad \textbf{(30)}$$

kde v = délka porovnávané množiny, m = počet historických záznamů. První sloupec matice historických záznamů je okamžik vytváření předpovědi. Nechť je dán vektor intervalů výskytu

$$\boldsymbol{W} = (w_1, w_2, \ldots, w_i, \ldots w_d) \qquad \textbf{(31)}$$

kde d = počet mezí intervalů výskytu, který rozděluje množinu všech realizací historických záznamů v okamžik vytváření předpovědi (první sloupec QH) na několik intervalů. Z matice historických záznamů je vybrána matice předpovědního svazku QS. Matice předpovědního svazku obsahuje takové řádky matice QH, jejichž hodnoty v prvním sloupci náleží do stejného intervalu matice W jako hodnota aktuálního záznamu.

$$\boldsymbol{QS} = \begin{pmatrix} qs_{1,1} & qh_{1,2} & \cdots & qh_{1,i} & \cdots & qh_{1,v} \\ \vdots & \vdots & & \vdots & & \vdots \\ qh_{j,1} & qh_{j,2} & \cdots & qh_{j,i} & \cdots & qh_{j,v} \\ \vdots & \vdots & & \vdots & & \vdots \\ qh_{n,1} & qh_{n,2} & \cdots & qh_{n,i} & \cdots & qh_{n,v} \end{pmatrix} \quad \textbf{(32)}$$

kde n = množství vybraných řádků. Vektor MAX, MIN a QS (s pruhem) představuje výběr maximální, minimální a výpočet průměrné hodnoty z každého sloupce matice QS

$$\boldsymbol{MAX} = (max_1, max_2, \dots, max_i, \dots max_v) \quad \textbf{(33)}$$

$$\boldsymbol{MIN} = (min_1, min_2, \dots, min_i, \dots min_v) \quad \textbf{(34)}$$

$$\overline{\boldsymbol{QS}} = (\overline{qs}_1, \overline{qs}_2, \dots, \overline{qs}_i, \dots \overline{qs}_v) \quad \textbf{(35)}$$

kde v = délka porovnávané množiny. Jednotlivé hodnoty výsledný vektor předpovědi

$$\boldsymbol{QP} = (qp_1, qp_2, \dots, qp_i, \dots qp_v), \quad \textbf{(36)}$$

jsou vypočteny následovně

$$qp_i = min_i + \frac{max_i - min_i}{2} + \left(\overline{qs}_i - min_i + \frac{max_i - min_i}{2}\right) * 3. \quad \textbf{(37)}$$

Rovnice (37) představuje výpočet polohy modu pro jednotlivé body ležící v předpovídané množině. Pokud jakákoliv hodnota QP leží mimo intervaly určené maticí

$$\mathbf{LIM} = \begin{pmatrix} lim_{h,1} & lim_{h,2} & \cdots & lim_{h,i} & \cdots & lim_{h,v} \\ lim_{d,1} & lim_{d,2} & \cdots & lim_{d,i} & \cdots & lim_{d,v} \end{pmatrix} \quad \textbf{(38)}$$

kde

$$lim_{h,i} = \overline{qs}_i \quad \textbf{(39)}$$

$$lim_{d,i} = min_i + \frac{max_i - min_i}{3} \quad \textbf{(40)}$$

je navrácena mezi tyto limity.

V případě tohoto principu předpovědi neprobíhalo testování na srážkových a teplotních průtokových řadách. Tento princip pracuje pouze s průtokovou časovou řadou.

V případě dostupnosti více dat v předpovědním profilu je vhodné zvolit jiné než trojúhelníkové rozdělení.

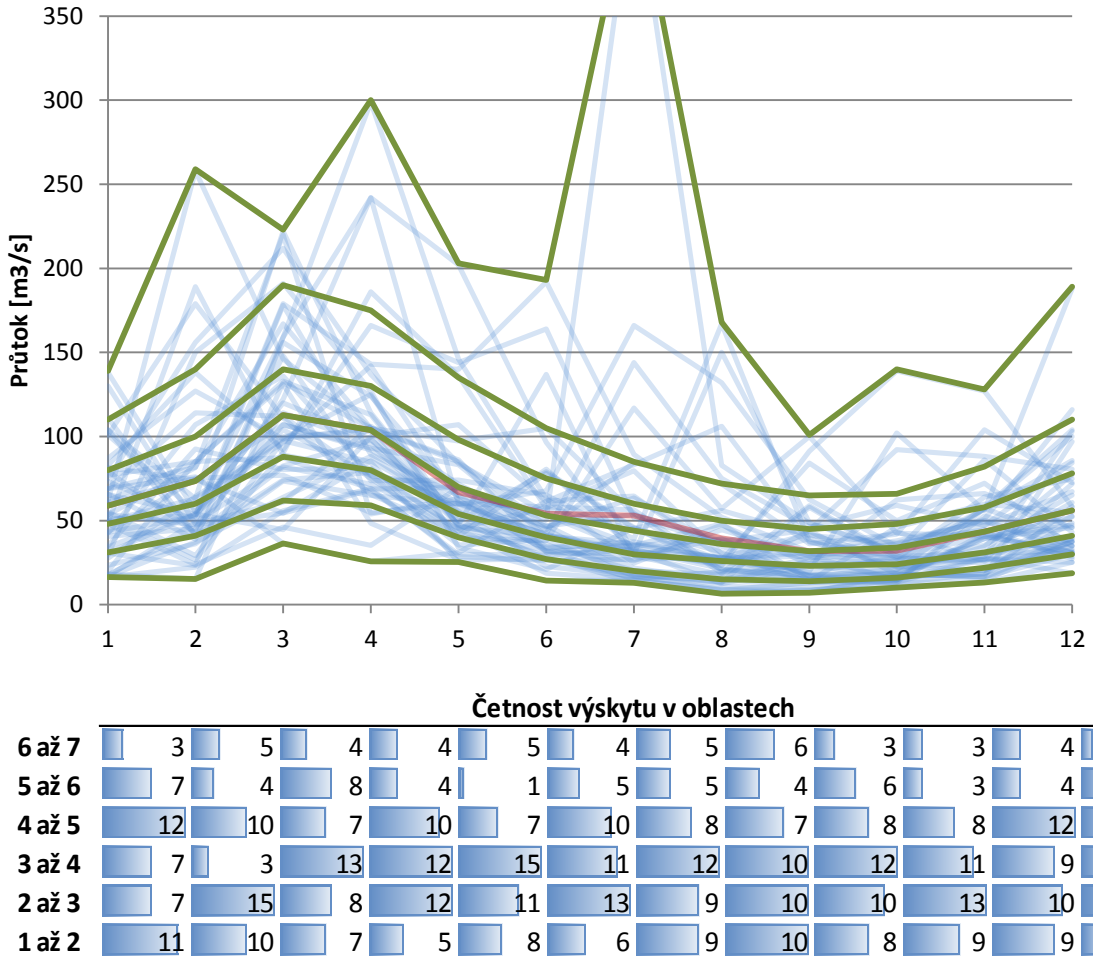

Obr. 15 – Oblasti rozdělení všech realizací u řeky Morava

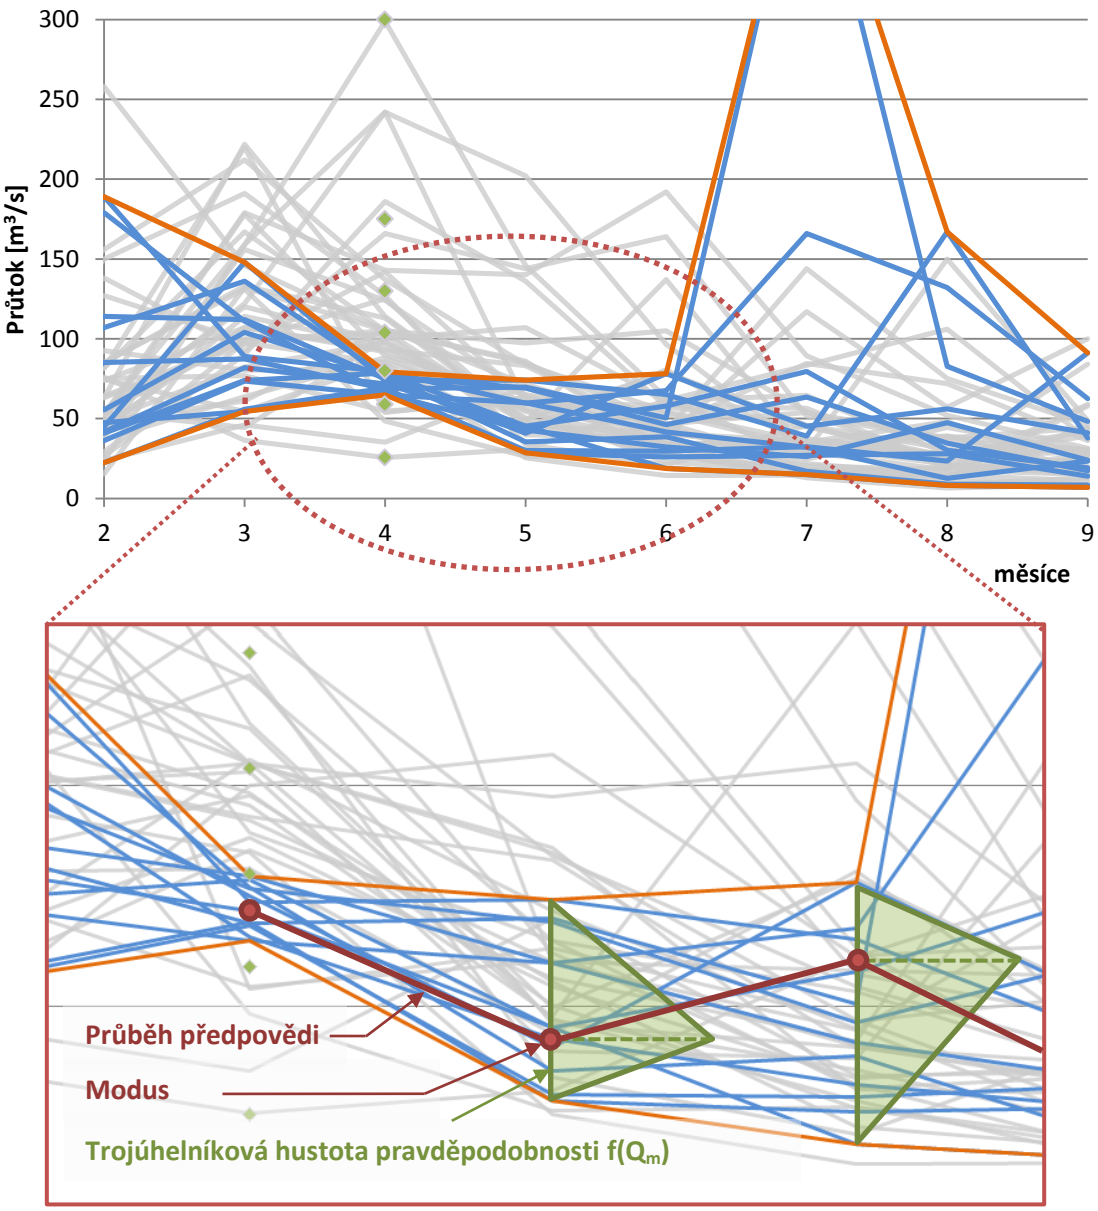

Obr. 16 – Ukázka předpovědního svazku, řeka Morava, měsíc duben

6.3 Definování oblasti, na kterou se koncentruje vývoj a aplikace modelů podobnosti

Obecné vysvětlení předpovědních principů v předchozích kapitolách umožňuje velkou spoustu různých způsobů jak využít model podobnosti pro vytvoření střednědobé předpovědi. Jde využít princip odchylek, trendu nebo zonálního pravděpodobnostního modelu, jde předpovídat na jeden nebo více bodů dopředu nebo jde využít pro předpověď různé časové řady atd. Způsoby využití modelu podobnosti pro vytvoření předpovědi byly v průběhu výzkumu postupně rozvíjeny. Komplexní zpracování všech způsobů však představuje velký objem práce a proto jsou další kapitoly práce omezeny pouze na ty způsoby, které jsou v současnosti komplexně zpracovány. Ostatní způsoby představují otevřené větve vývoje modelu podobnosti. Omezení jsou následující:

Je využíván pouze princip odchylek. I když byla větší časová dotace v průběhu výzkumu věnována vývoji principu trendu, není v současnosti jeho vývoj v oblasti kalibrace tak komplexně zpracován jako je tomu u principu odchylek. Modelování principem trendu zůstává otevřenou větví výzkumu, která může být v budoucnu rozpracována. Pokud bude v dalších kapitolách zmíněn model podobnosti, myslím se tím model podobnosti, který využívá princip odchylek.

Předpověď je vytvářena na jeden krok dopředu. Podobně jako v předchozím odstavci není zpracování předpovědi na více časových kroků tak komplexní, i když mu byla věnována značná pozornost. Další skutečnost, která vedla k omezení pouze na jeden krok je, že u většiny měsíců profilů Umpqua, Morava, Jihlava, Oslava nebylo dosaženo příliš přesné předpovědi na dva a více měsíců dopředu. Je předpokládáno, že ve většině případů předpovědních profilů s malým povodím je vhodnější předpovídat druhý a další předpovědní krok pomocí statisticky pravděpodobné hodnoty, tj. aritmetický průměr nebo modus. Předpověď pomocí modelu podobnosti na více měsíců dopředu je další otevřenou větví výzkumu.

Je zkoumáno vytváření předpovědi s využitím všech třech časových řad, tj. průtoková, srážková, teplotní. Výsledky předpovědi vytvářené na základě průtokové řady, kombinací průtokové a teplotní řady atd. jsou z výsledků sice pozorovatelné, ale v práci nejsou komentované.

Délka porovnávaného období není delší než 8 měsíců. V rámci většiny numerických experimentů způsobilo dlouhé porovnávané období horší výsledky KD a navíc protahovalo délku kalibrace modelu podobnosti. Na druhou stranu je však také možné hledat nejvíce podobný případ na základě porovnání průběhu celého roku (celých roků) a tato možnost představuje také možnost budoucího zkoumání.

6.4 Parametry modelu podobnosti

Předpoklad většiny předpovědních modelů je jejich univerzální použitelnost. Stejně tak i model podobnosti může být nastavením svých parametrů adjustován pro příslušný profil. Záměrem takovéto adjustace (respektive kalibrace) je zvýšení přesnosti výsledné předpovědi. Tato kapitola podrobněji popíše zvolené parametry principu odchylek, které se zjišťují při kalibraci. Další kapitola se věnuje způsobům nalezení parametrů.

6.4.1 Vlivy podobnosti průtokových, srážkových a teplotních řad

$$\boldsymbol{V_{pst}} = (v_p, v_s, v_t) \qquad \textbf{(41)}$$

$$v_p \in \langle 0,1\rangle, v_s \in \langle 0,1\rangle, v_t \in \langle 0,1\rangle, \quad (42)$$

$$v_p = 1 - v_s \quad (43)$$

Pro parametr je používána zkratka *vliv PST* nebo pouze *PST*. Parametr jde zapsat jako matice V_{pst}, která se skládá ze třech prvků (vlivů) v_p – vliv průtoku, v_s – vliv srážek, v_t – vliv teplot. Ty nabývají hodnot od nuly do jedné a určují jak velký vliv na určení nejvíce podobného historického případu má podobnost průtokových, srážkových nebo teplotních průtokových, viz vztahy v kapitole 6.2.2. Pokud je jeden z dílčích vlivů rovný nule, znamená to, že příslušná časová řada nemá vliv na rozeznání nejvíce podobného historického případu. Aby se zmenšilo množství kombinací mezi jednotlivými parametry (a tím i náročnost jejich nalezení v průběhu kalibrace) je mezi parametrem v_p a v_s předepsán vztah (43). Možné kombinace trojce parametrů jde nalézt na Obr. 17, kde jsou zobrazeny dosažené hodnoty koeficientu determinace na základě změn parametru PST. Pokud je v_p rovný jedné nemá podobnost srážkových řad na určení nejvíce podobného historického případu žádný vliv. Pokud se vliv v_p zvětšuje a dosáhne v_p = 0,5 má podobnost srážkových a teplotních řad stejný vliv na určení nejvíce podobného historického případu. Pokud je v_p = 0 rozhoduje o nejvíce podobném historickém případu pouze podobnost srážkových řad. Pro každou kombinaci v_p a v_s je zkoumán vliv teplot, které pro rozpoznání nejvíce podobného historického případu nemají buď vůbec žádný vliv v_t = 0 nebo mají stejný význam jako pouze průtok nebo pouze srážka, v_t = 1.

v_p		1	0.9	0.8	0.7	0.6	0.5	0.4	0.3	0.2	0.1	0
v_s		0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
v_t	0	0.190	0.209	0.253	0.217	0.212	0.266	0.240	0.250	0.153	0.111	0.040
	0.1	0.226	0.277	0.265	0.280	0.272	0.362	0.300	0.298	0.295	0.139	0.053
	0.2	0.194	0.223	0.298	0.299	0.260	0.259	0.305	0.238	0.282	0.239	0.079
	0.3	0.158	0.202	0.261	0.299	0.272	0.288	0.273	0.223	0.208	0.195	0.122
	0.4	0.141	0.161	0.226	0.270	0.311	0.293	0.255	0.235	0.193	0.183	0.145
	0.5	0.134	0.157	0.188	0.261	0.264	0.294	0.223	0.202	0.212	0.156	0.154
	0.6	0.119	0.118	0.164	0.209	0.236	0.229	0.208	0.190	0.219	0.138	0.137
	0.7	0.103	0.159	0.145	0.188	0.254	0.241	0.183	0.165	0.177	0.124	0.137
	0.8	0.087	0.130	0.153	0.228	0.233	0.213	0.176	0.157	0.146	0.124	0.168
	0.9	0.080	0.087	0.145	0.182	0.233	0.204	0.175	0.175	0.154	0.162	0.147
	1	0.073	0.097	0.134	0.204	0.200	0.227	0.169	0.157	0.149	0.137	0.136

Obr. 17 - Ukázka možných kombinací parametru PST

6.4.2 Počet nejvíce podobných historických případů

Parametr určuje kolik je hledáno nejvíce podobných historických případů na základě podobnosti průtokových, srážkových nebo teplotních časových řad z kterých je průměrováním určena předpověď (18). Zkratka pro tento parametr je *NPHP.* Jeho hodnoty mohou se pohybovat do 1 do celkového počtu případů, které je určeno délkou dat. Na základě numerických experimentů je pracováno s parametrem v rozmezí od 1 do 20. Vyšší hodnoty NPHP než 20 nezlepšují přesnost dosažené předpovědi a dělají náročnější proces kalibrace.

6.4.3 Váhy porovnávané oblasti

Název parametru je v rámci práce uváděn ve zkrácené podobě jako *váhy* anebo je uváděn pod symbolem *W*. Parametr určuje význam jednotlivých bodů (měsíců) v porovnávané oblasti na jejich vliv o rozhodnutí o nejvíce podobném historickém případu, viz kap 6.2.2. Parametr představuje vektor

$$\boldsymbol{W} = (w_1, w_2, \dots, w_i, \dots w_n) \qquad \textbf{(44)}$$

kde n = počet vstupních měsíců, $w_i \in < 0, 1 >$. Váha v bodě vydávané předpovědi má vždy hodnotu rovnou jedné. Další hodnoty vah se zmenšují (anebo jsou rovny) se vzdáleností od okamžiku vydávání předpovědi. Krok, s kterým váhy klesají, byl na základě numerických pokusů zvolen 0,05. Jemnější krok totiž velmi prodloužil délku výpočtu v průběhu kalibrace a změna výsledků KD byla dostatečně zřetelná s krokem 0,05. V rámci práce nabývá hodnota počet vstupních měsíců, $n \in < 1, 8 >$. V rámci numerických experimentů byla zkoušena i vyšší horní limit n, ale podobně jako u předchozích parametrů, nebyla tato oblast parametru využívána a protahovala délku výpočtu kalibrace. Dohromady je v rámci práce zvoleno 208 různých průběhů vah zvolených na základě empirické zkušenosti. Značka například W (8) nebo W (71) udává jeden z konkrétních průběhů nazývaných *verze vah*. Váhy se dají zobrazit, jako sloupcový graf viz Obr. 12 a Obr. 14, nebo jako bodový spojnicový viz Obr. 18 – na tomto obrázku jsou vidět čtyři různé příklady, jak mohou různé realizace vah vypadat. Na x-ové ose grafu je porovnávaná oblast. Číslo 8 představuje okamžik předpovědi. Na y-ové ose je velikost váhy.

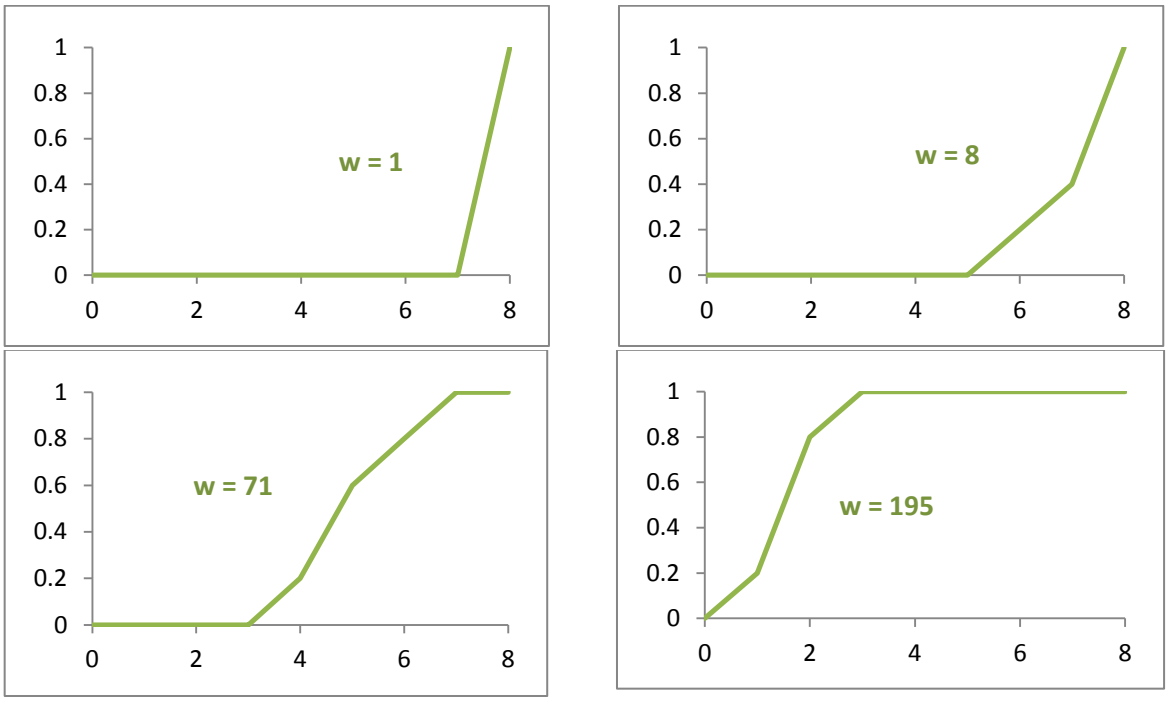

Obr. 18 - Příklady různých vah, které může princip podobnosti využívat

Pro nastavení modelu by bylo možné zvolit i více parametrů, avšak výše vybrané tři parametry nejvíce ovlivňovali výslednou přednost předpovědi a také o ostatních parametrech bylo zjištěno, že mohou být nastaveny na konstantní hodnotu.

Výše popsané parametry mohou být voleny (nebo hledány v rámci kalibrace) stejné pro všechny roční měsíce.

$$\boldsymbol{V_{pst}} = (v_p, v_s, v_t) \quad \textbf{(45)}$$

$$NPRH \quad \textbf{(46)}$$

$$\boldsymbol{W} = (w_1, w_2, \dots, w_i, \dots w_n) \quad \textbf{(47)}$$

a nebo hledány pro každý měsíc zvlášť:

$$\boldsymbol{V}_{PST} = \begin{pmatrix} v_p^1, & v_s^1, & v_t^1 \\ \vdots & \vdots & \vdots \\ v_p^M, & v_p^M, & v_p^M \\ \vdots & \vdots & \vdots \\ v_p^{12}, & v_p^{12}, & v_p^{12} \end{pmatrix} \quad \textbf{(48)}$$

$$NPRP = (nphp^1, \quad \cdots \quad nphp^M, \quad \cdots \quad nphp^{12}) \quad \textbf{(49)}$$

$$\boldsymbol{W} = \begin{pmatrix} w_1^1, & w_2^1, & \cdots & w_i^1, & \cdots & w_n^1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_1^M, & w_2^M, & \cdots & w_i^M, & \cdots & w_n^M, \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_1^{12}, & w_2^{12}, & \cdots & w_i^{12}, & \cdots & w_n^{12}, \end{pmatrix} \quad \textbf{(50)}$$

Kde M ϵ < 1, 12 > a představuje značku měsíce. Práce se věnuje převážně nalezení parametrů pro každý měsíc zvlášť.

6.5 Metody volby parametrů principu odchylek

Model podobnosti může být přizpůsoben k aplikaci na různých profilech pomocí parametrů popsaných v přechozí kapitole. Tato kapitola se zabývá postupy k optimální volbě parametrů modelu podobnosti.

Běžný (frekventovaný) postup kalibrace předpovědního modelu bývá nalezení parametrů s pomocí numerického *optimalizačního modelu*. Data k dispozici jsou rozdělena na *kalibrační* a *validační soubor*. Kalibrační soubor slouží k hledání parametrů modelu a validační soubor k ověření přesnosti předpovědi na jiných datech než na kterých byly určeny parametry modelu. V průběhu procesu hledání parametrů modelu poskytuje kalibrační soubor zadání a zároveň řešení předpovědní úlohy. S využitím optimalizačního modelu jsou potom hledány takové parametry modelu, které přiblíží předpovědi co nejblíže řešení. Kombinace všech parametrů modelu vytváří *mřížku nastavení modelu*, která je většinou velmi rozsáhlá. Optimalizační metoda prochází mřížku možných nastavení modelu a pomoci kritéria k hodnocení vytvářené přesnosti předpovědi hledá nejvhodnější nastavení modelu. Optimalizační metody mohou být Monte Carlo, Mřížková metoda, Gradientní metoda, Genetická optimalizace atd. Po nalezení parametrů předpovědního modelu může být hodnocena jejich volba na základě předpovědi vytvořené z validačního souboru.

Parametry modelu mohou být voleny také *subjektivní optimalizací*, díky které jde, na základě znalosti vazeb mezi předpovědním modelem a zkoumaným jevem, odhadnou volbu parametrů modelu. Použití subjektivní volby parametrů připadá v úvahu u modelů, jejichž parametry nevytváří velké množství kombinací a představa, jak ovlivní změna parametrů vytvářenou předpověď, není příliš obtížná. Dalších způsobů jak získat parametry modelu je velké spousta (analytické řešení atd.), avšak v textu níže bude zvažováno použití optimalizační metody a subjektivní volby.

Model podobnosti (v případě principu odchylek) umožnuje

$$počet\ PST \times počet\ NPHP \times počet\ W = 121 \times 20 \times 208 = 503\ 360$$

možných kombinací nastavení parametrů modelu v každém měsíci. Pro všechny měsíce je to

$$503\ 360 \times 12 = 6\ 040\ 320$$

kombinací. S ohledem na množství možných kombinací parametrů modelu podobnosti se jeví vhodné použití optimalizačního modelu k nalezení vhodné volby parametrů.

Hledání optimálního nastavení parametrů modelu je v případě zkoumaného jevu (zkoumaným jevem jsou předpovědi průměrných měsíčních průtoků) velmi obtížné. Ve většině zkoumaných případů v rámci práce byla při změně libovolného parametru o jednu jednotku výrazně vyšší náhodná změna hodnotícího kritéria, než předpokládané zlepšení hodnotícího kritéria. Jinými slovy, pokud je změněn parametr o jednu jednotku, je předpokládáno určité zlepšení/zhoršení/změna koeficientu determinace. Náhodná odchylka KD při změně parametru o jednu jednotku je však několikrát větší. Například na Obr. 19 jde vidět změnu hodnotícího kritéria na základě změny parametru NPHR. V intervalu NPHR = 1 do NPHR = 9 je výrazně větší náhodná odchylka než odhadované zlepšení (změna/vývoj) hodnotícího kritéria. V intervalu od NPHR = 9 do NPHR = 17 jde vidět plynulou změnu (zlepšení/zhoršení) KD změnou parametru NPHR. V uvedeném příkladu by optimalizační metoda našla jako nejlepší volbu parametru NPHR = 8 (a na druhém místě NPHP = 4). Na základě subjektivní optimalizace jde zhodnotit a rozhodnout, že nejvhodnější volba parametru je NPHR = 12. Případy při

hledání optimálnější volby parametrů bývají většinou mnohem složitější, než je spíše demonstrativní příklad na Obr. 19. Další příklad neurčitosti je uveden v poznámce pod čarou na straně 40.

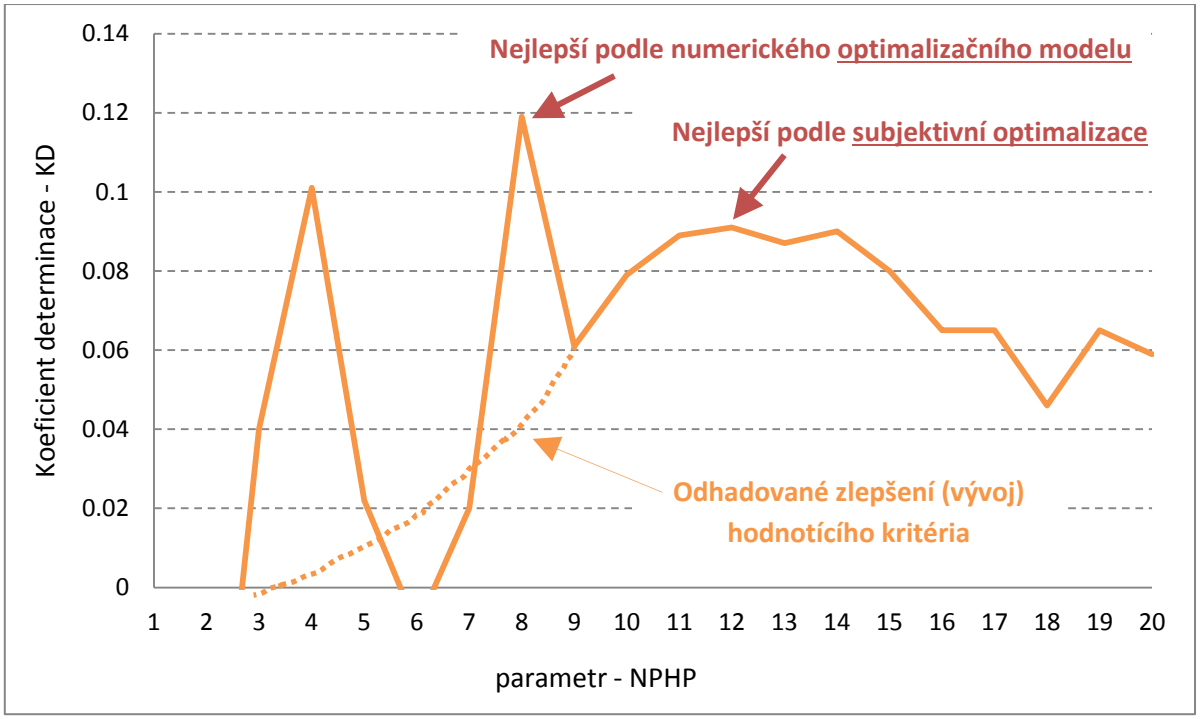

Obr. 19 - Příklad neurčitosti zkoumaného jevu

Výše popsané skutečnosti dělají použití optimalizační metody pro nalezení optimální volby parametrů modelu podobnosti neužitečné, protože ve převážné většině případů volí lokální maxima. Vhodnější volbu parametrů je dosáhnout na základě subjektivního rozhodnutí (navíc rozhodnutí nad optimální volbou parametrů mnohdy záleží na mnohem více kritériích než pouze na KD, což je jediné kritérium pro optimalizační modely). Použití subjektivního rozhodnutí pro volbu parametrů modelu podobnosti představuje zobrazení[1] a prohlédnutí přibližně 6 milionů dosažených přesností pro mřížku parametrů modelu což představuje časově velmi náročný úkol. Časová náročnost nalezení vhodných parametrů modelu podobnosti by potom komplikovala jeho aplikaci/nastavení v dalších profilech nejen pro autora modelu podobnosti.

Parametry modelu podobnosti jsou oproti jiným předpovědním modelům velmi dobře představitelné vzhledem ke zkoumanému jevu. Například skutečnost, že pro vytvoření předpovědi v jarních měsících má vliv změna parametru týkající se teploty, je mnohem lépe představitelná, než jak se projeví na výsledku změna jedné synapse neuronové sítě. Tato skutečnost umožnila nalezení vztahů mezi optimálním nastavením parametrů modelu a *charakterem předpovědního profilu* (tím jsou myšleny statistiky jako průměr a směrodatná odchylka všech měření v jednotlivých měsících, délka záznamů měření, vlivy na odtok vody z povodí, korelační analýza atd.) nazvané *kalibrační vzory*. Jedná se o empirická pravidla, které umožňují volbu parametrů modelu podobnosti na základě charakteru profilu, čímž je možné vynechání zdlouhavého procesu zobrazování a prohlížení mřížky všech možných kombinací parametrů modelu podobnosti. Kalibrační vzory jsou však nalezeny tímto

[1] Zobrazení výsledků představuje vypočtení koeficientu determinace (nebo jiného kritéria hodnocení přesnosti) pro každou kombinaci parametrů modelu podobnosti a jejich zobrazení například do grafu, který je uveden na Obr. 19 nebo do zobrazení popisovaných v kapitolách 6.5.1 až 6.5.4.

zdlouhavým procesem nalezeny, tj. prohlédnutím výsledků všech možných kombinací parametrů a subjektivním rozhodnutím nad volbou parametrů.

Kalibrační vzory mohou být při kalibraci modelu podobnosti zužitkovány následovně. Je k dispozici *kalibrační a validační soubor dat.* Kalibrační soubor slouží k hledání parametrů modelu a validační soubor k ověření přesnosti předpovědi na jiných datech než na kterých byly určeny parametry modelu. Kalibrace modelu může být provedena následujícími způsoby:

1. Na základě charakteru předpovědního profilu a kalibračních vzorů jsou subjektivně zvoleny parametry modelu podobnosti a přesnost předpovědi nastaveného modelu hodnocena validačním souborem. Kalibrační soubor dat není potřeba využívat.
2. Použitím kalibračního souboru zobrazit dosažené přesnosti předpovědi v jednotlivých bodech zvolené mřížky, přihlédnout ke kalibračním vzorům a charakteru předpovědního profilu, subjektivně zvolit nastavení parametrů modelu a přesnost předpovědi nastaveného modelu hodnocena validačním souborem.
3. Použitím kalibračního souboru zobrazit dosažené přesnosti předpovědi v jednotlivých bodech zvolené mřížky a detailně je prohlédnout, subjektivně zvolit nastavení parametrů modelu a přesnost předpovědi nastaveného modelu hodnocena validačním souborem. Kalibrační vzory nejsou využity.

S přibývajícími čísly způsobů kalibrace se zvyšuje pracnost kalibrace a také nároky na zkušenosti řešitele v použití modelu podobnosti. Ideální bylo použití prvního způsobu kalibrace. Protože byli kalibrační vzory vyvíjeny pouze na šesti profilech je současná komplexnost kalibračních vzorů nízká. Ve stádiu současného poznání je předpokládáno, že pro kalibrování modelu podobnosti na novém předpovědním profilu bude nejvíce využívaný druhý způsob. Pokud bude druhý způsob nedostatečný je nutné procházet mřížku řešení detailně jak je popsáno u třetího způsobu.

V případě komplexního poznání a popisu kalibračních vzorů nebudou muset modely podobnosti využívat kalibrační soubor k nastavení parametrů modelu, což může být určitá výhoda modelů podobnosti oproti ostatním modelům vhodných pro střednědobé předpovědi průtoku.

Hledání kalibračních vzorů umožňuje nejen zjednodušit kalibraci modelu podobnosti, ale také porozumět předpovídanému jevu a jeho vazbami k jeho předpovědi vytvářené modelem podobnosti. Protože jsou výsledky předpovědi v rámci práce hodnoceny koeficientem determinace a zobrazením kontrolního kvadrantu, směřuje převážné poznání k dosažení vysokého KD a nebo takového zobrazení kontrolního kvadrantu, které jsou díky subjektivnímu hodnocení považovány za dobré. Aplikace modelu podobnosti pro provoz nádrže však může otevřít nové nároky na vytvářené předpovědi. Na jejich pokrytí velmi pravděpodobně poslouží doposud poznané skutečnosti o vazbách mezi předpovídaným jevem a modelem podobnosti shrnutých v kalibračních vzorech.

V rámci práce bylo zkoušeno použití mřížkové optimalizační metody a genetické optimalizační metody. U obou metod byl použit KD jako kritérium k hodnocení předpovědi. Mřížková optimalizační metoda nacházela náhodně lokální maxima. V případě genetické optimalizace nedosáhl při nízkých počtech generací a počtů jedinců (tyto dva parametry představují, jak dlouho se genetická metoda zabývá hledáním optimálního nastavení parametrů) model tak vysokých KD jako u metody subjektivní volby. Naopak čím vyšší byly počty generací a počty jedinců tím nižší KD bylo dosaženo (díky nalezení lokálního extrému).

Kalibrační vzory předepisují určitý dobře pochopitelný systém volby parametrů modelu podobnosti a u většiny předpovědních profilů se zvolené parametry plynule mění z měsíce na měsíc na základě charakteru profilu. Naopak volba parametrů modelu podobnosti optimalizační metodou je velmi náhodná a rozpoznání systému volby parametrů velmi sporadické. I přesto může být mít předpověď s volbou parametrů pomocí optimalizační metody lepší KD než předpověď na základě subjektivní volby parametrů. I přesto je v rámci práce považováno za významnější volit parametry modelu na základě určitého systému, který se váže k předpovídanému jevu, volit parametry zcela náhodně s pomocí optimalizačního modelu.

Míra náhodnosti nalezení parametrů pomocí optimalizační metody se však mění s velikostí povodí nad předpovídaným profilem (a tím i velikostí řeky). V případě Dunaje by určení parametru vliv PST optimalizační metodou byla zcela stejné jako na základě subjektivní volby s využitím kalibračního vzoru. Ale u zbytku profilů zkoumaných v rámci práce by byla volba parametrů optimalizačním modelem určena spíše náhodná, než aby volba parametrů pro jednotlivé měsíce vytvářela určitý systém.

6.5.1 Přehled zobrazení přesnosti předpovědi pro různé kombinace parametru modelu podobnosti sloužících k subjektivnímu nalezení parametrů podobnosti a kalibračních vzorů

Parametry a kalibrační vzory jsou hledány na základě zobrazení přesností předpovědi (pomocí KD nebo kontrolního kvadrantu) pro různé kombinace parametrů. Používají se čtyři zobrazení, které jsou podrobně popsána na Obr. 20 až Obr. 24. Jejich zjednodušené názvy jsou

1. Mapa PST
2. kontrolní kvadranty PST
3. Nej váhy PST
4. KD verzí vah PST

U těchto jednotlivých zobrazení jsou parametry PST, NPHP, W zvoleny programem buď na základě nejvyššího koeficientu determinace dosaženého v mřížce příslušných parametrů (nazýváno *automatická volba*), nebo jsou zvoleny subjektivně na základě zobrazení dosažené hodnoty přesnosti pro rozsah hodnot parametru (nazýváno *subjektivní volba*). Pro hodnocení přesnosti předpovědi je používán v případě automatické volby pouze KD a pro subjektivní hodnocení je použit KD a zobrazení kontrolního kvadrantu (viz kapitola 1.).

Subjektivní volba parametrů modelu vyžaduje prohlédnutí dosažených přesností předpovědi všech možných kombinací parametrů modelu, což představuje v jednom profilu přibližně 6 milionů kombinací (jak je popsáno na začátku kap. 0). Proces prohlédnutí je zjednodušen na jeho počátku tak, že je prohlíženo zobrazení přesnosti předpovědi pouze jednoho parametru a další dva jsou voleny automaticky. Řešitel si tím může vytvořit přehled nad oblastí předběžné optimální volby jednoho z parametrů. Následně není pro řešitele tolik obtížné hledat optimální volbu parametrů ve zobrazení mřížky dosažených výsledků u dvou parametrů zároveň (s tím že třetí parametr je volen automaticky) a následně ve zobrazení mřížky tří parametrů zároveň. Jednotlivá zobrazení jsou popsána níže na Obr. 20 až Obr. 24.

V Tab. 5 je pro jednotlivá zobrazení shrnuto jaké parametry jsou voleny automaticky a u kterých jsou dosažené přesnosti předpovědi zobrazeny a prohlíženy. Z tabulky je zřejmé, že množství prohlížených

výsledků se zvedá s řádky v tabulce a u posledního zobrazení jsou prohlíženy všechny přesnosti předpovědi mřížky parametrů modelu podobnosti. Tabulka napovídá také o postupu volby parametrů, při kterém je nejprve volen parametr PST, potom NPHP a nakonec W. Volba jednoho parametru ovlivňuje volbu dalších parametrů, a je možné na základě volby NPHP nebo W změnit volbu předchozích parametrů. Pokud by v tabulce byl uveden řádek nula u kterého by byly voleny všechny parametry automaticky jednalo by se o mřížkovou optimalizační metodu nalezení parametrů.

Tab. 5 - Souhrn parametrů a způsob jejich nalezení a zobrazení

Číslo řádku		PST	NPHP	W
1	Mapa PST	m	a/m	a/m
2	Kontr. Kv. PST	m	m	a
3	Nej váhy PST	m	m	a
4	KD verzí vah PST	m	m	m

Pokud je parametr zvolen automaticky je používaná značka *PST-a nebo NPHP-a nebo W-a* pokud je parametr zvolen subjektivně je používána značka *PST-m nebo NPHP-m nebo W-m* (zkratka „a“ jako automaticky nalezeno, zkratka „m“ jako mřížka výsledků).

Kalibrační vzory jsou hledány u profilů popsaných v kapitole 7.1. K jejich nalezení je používán kalibrační soubor dat.

		1	0.9	0.8	0.7	0.6	0.5	0.4	0.3	0.2	0.1	0
		0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
Červen	0	0.183	0.248	0.393	0.476	0.526	0.601	0.644	0.677	0.715	0.703	0.669
	0.1	0.183	0.268	0.424	0.497	0.572	0.636	0.659	0.695	0.724	0.704	0.679
	0.2	0.218	0.298	0.416	0.527	0.583	0.633	0.666	0.699	0.716	0.716	0.670
	0.3	0.190	0.312	0.436	0.512	0.588	0.618	0.659	0.707	0.710	0.712	0.677
	0.4	0.209	0.309	0.433	0.537	0.590	0.632	0.667	0.697	0.699	0.724	0.688
	0.5	0.212	0.330	0.460	0.529	0.583	0.627	0.660	0.687	0.692	0.704	0.668
	0.6	0.240	0.326	0.436	0.525	0.594	0.630	0.648	0.674	0.702	0.692	0.663
	0.7	0.229	0.327	0.431	0.514	0.570	0.631	0.665	0.685	0.700	0.679	0.664
	0.8	0.211	0.354	0.426	0.504	0.568	0.623	0.655	0.664	0.676	0.707	0.680
	0.9	0.197	0.328	0.441	0.519	0.558	0.620	0.674	0.657	0.669	0.729	0.695
	1	0.229	0.313	0.421	0.474	0.553	0.617	0.656	0.655	0.675	0.681	0.704

Obr. 20 - Příklad zobrazení KD pro všechny hodnoty parametru PST [2]

[2] Na Obr. 20 jde pozorovat další z příkladů obtížného rozpoznání optimální volby parametrů modelu podobnosti. Podle koeficientu determinace je optimální volba parametru PST na $v_p = 0,9$; $v_s = 0,1$; $v_t = 0,9$. Okolní kombinace nejlepšího PST nedosahují tak vysokého KD. V oblasti podobnosti průtokových řad bez vlivu teploty mapy PST se vyskytuje shluk kombinací parametru PST s vyšším KD, které navíc plynule narůstají a klesají. Proto jde považovat vysoké KD pro kombinaci $v_p = 0,9$; $v_s = 0,1$; $v_t = 0,9$ pouze za náhodu a subjektivně zvolená optimální volba parametru by ležela někde v oblasti podobnosti průtokových řad bez vlivu teploty. Podstatné však je, že volba parametru pro kombinaci $v_p = 0,9$; $v_s = 0,1$; $v_t = 0,9$ by značně zkreslovala poznání vazeb mezi modelem podobnosti a zkoumaným jevem, protože by udávala, že je v tomto měsíci podstatný vliv

Na Obr. 20 je uveden příklad zobrazení KD pro všechny hodnoty parametru PST, které bude v práci nazýváno *mapa PST*. Výplň tabulky jsou hodnoty koeficientu determinace pro jednotlivé hodnoty parametru PST (jak již bylo přiblíženo v kap. 6.4.1). Čím více je barva fialová, tím vyšší je koeficient determinace. Takováto mapa je určena pro každý měsíc zvlášť. Popis měsíce na obrázku vlevo představuje okamžik předpovědi a hodnota KD v tabulce je předpověď na jeden měsíc dopředu. Takže v případě Obr. 20 představují KD přesnost předpovědi na měsíc červenec. Nejlepší volba parametru je podle výše uvedené mapy PST $v_p = 0{,}9$; $v_s = 0{,}1$; $v_t = 0{,}9$. Parametry NPHP a W mohou být zvoleny automaticky pro každý bod mapy PST, nebo mohou mít jednu zvolenou hodnotu pro všechny body mapy PST. V druhém případě je hodnota vždy uvedena v levém horním rohu, jak je ukázáno na Obr. 21. Oranžová je pro parametr NPHP a zelená pro parametr W.

4	1	0.9	0.8
	0	0.1	0.2
0	0.183	0.248	0.393
0.1	0.183	0.268	0.424
0.2	0.218	0.298	0.416

110	1	0.9	0.8
	0	0.1	0.2
0	0.183	0.248	0.393
0.1	0.183	0.268	0.424
0.2	0.218	0.298	0.416

4	1	0.9	0.8
110	0	0.1	0.2
0	0.183	0.248	0.393
0.1	0.183	0.268	0.424
0.2	0.218	0.298	0.416

Obr. 21 - Příklad zobrazení pokud jsou hodnoty v mapě PST určeny pro pevnou hodnotu NPHP nebo W

Dalším používaným zobrazením mřížky parametrů je zobrazení kontrolních kvadrantů pro všechny hodnoty parametru PST. Příklad je uveden na Obr. 22 a v rámci práce bude toto zobrazení pojmenováno kontrolní kvadranty PST. Jedná se o to samé zobrazení jako v předchozím případě s rozdílem, že hodnoty KD v mřížce parametru PST doplněny o kontrolní kvadranty předpovědí a skutečně nastalých hodnot.

teploty na vytvoření předpovědi. I v tomto příkladu (podobně jako v příkladu zmíněném výše v textu) platí, že je výrazně demonstrativní a většina případů při běžném hledání optimální volby parametrů je mnohem více komplikovaná.

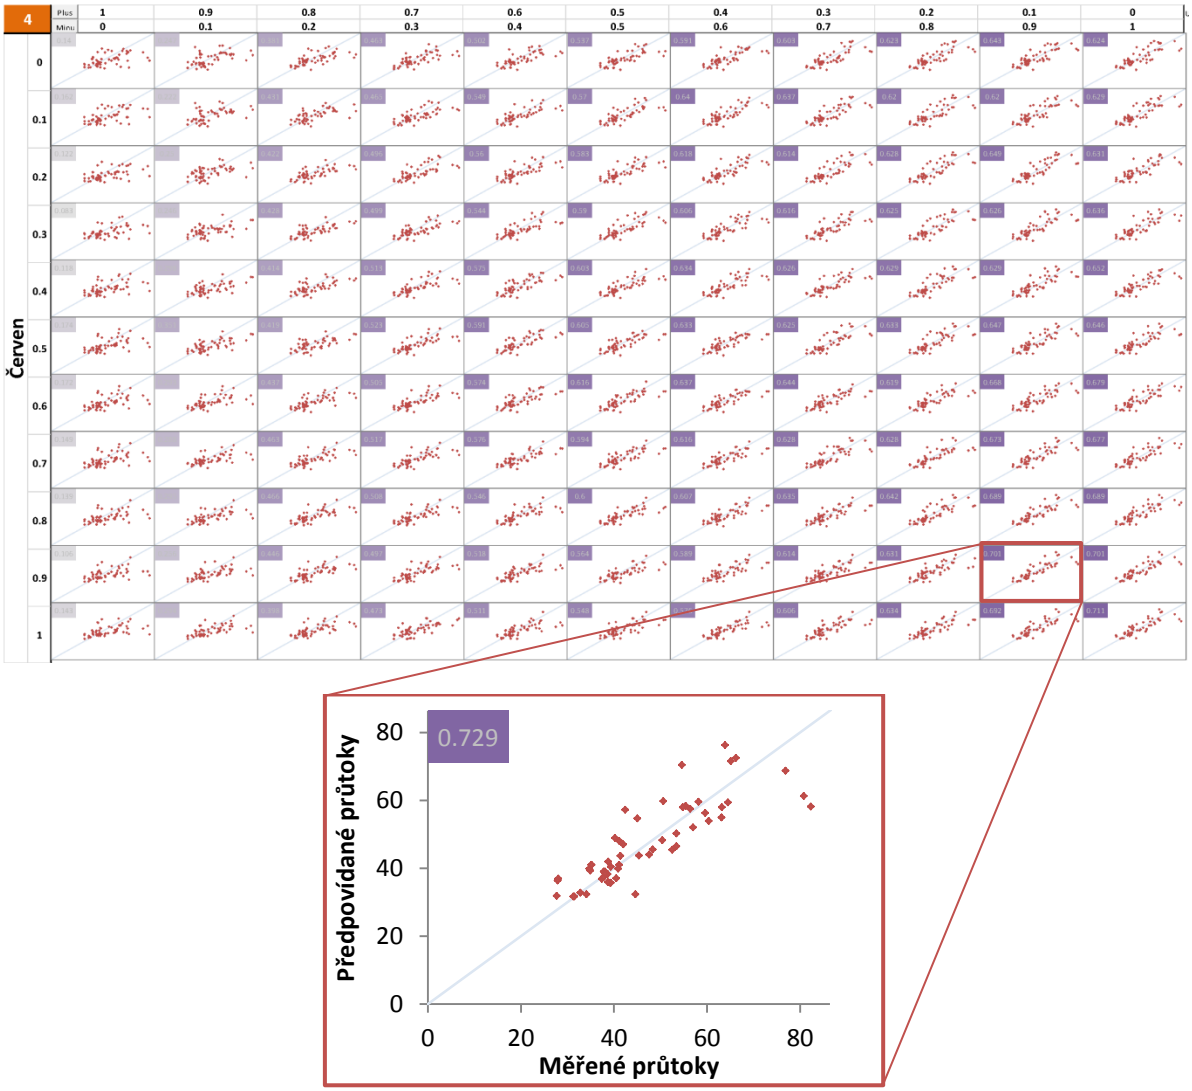

Obr. 22 - Příklad zobrazení kontrolních kvadrantů pro všechny hodnoty parametru PST

Dalším používaným zobrazením mřížky parametrů je zobrazení nejlepších verzí vah pro všechny hodnoty parametru PST. Příklad je uveden na Obr. 23 a v rámci práce bude pojmenováno *nejlepší váhy PST*. Jedná se o to samé zobrazení jako v předchozích případech s rozdílem, že hodnoty KD v mřížce parametru PST jsou doplněny o výběr třech nejlepších verzí vah. Verze vah jsou vybrány na základě koeficientu determinace. Hodnota KD ve fialovém rámečku přísluší nejlepší verzi vah, hodnoty KD pro další dvě verze vah nejsou zobrazeny (obvykle však bývají velmi podobné nejlepší verzi vah). Čím menší je koeficient determinace pro příslušnou verzi vah, více průhlednější je její zobrazení v grafu. Čísla třech nejlepších verzí jsou zobrazena v pravém dolním rohu. Tři váhy jsou voleny proto, aby byla možnost odhalit náhodnou chybu. Ta je rozpoznatelná, pokud by některá z třech vybraných verzí vah ležela zcela jinde než ostatní verze vah. K ověření, zda došlo k náhodné chybě, slouží také porovnání vybraných verzí vah pro okolní parametry PST (a další způsoby popsané níže). Parametry PST a NPHR jsou pro zobrazení stanoveny na konkrétní hodnotu. Z Obr. 23 je tedy patrné, že pro $v_p = 0,9$; $v_s = 0,1$; $v_t = 0,9$, NPHR = 4 a w = 110 je dosažena hodnota KD 0,729.

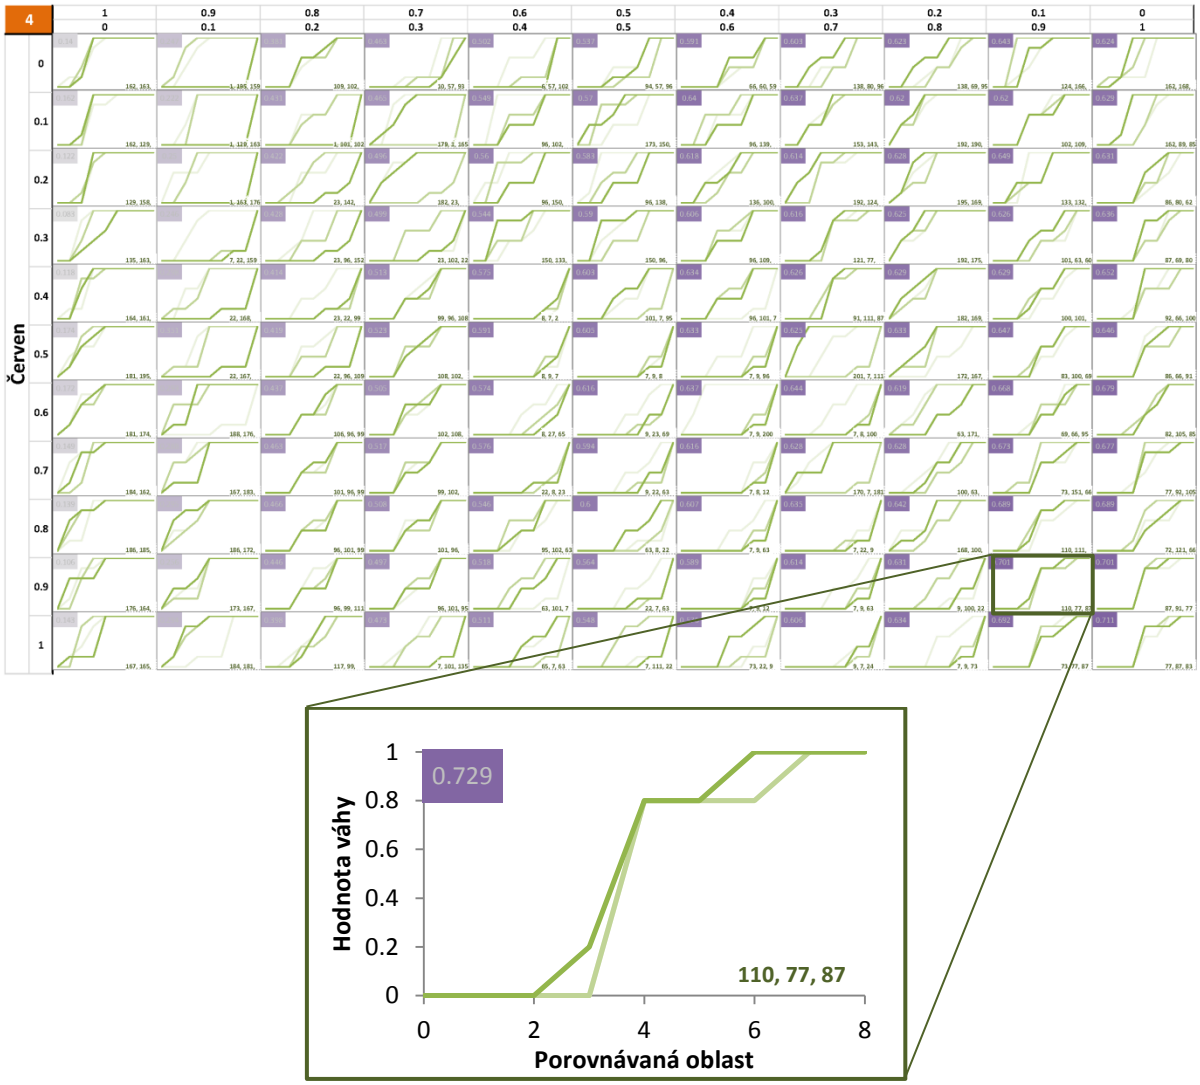

Obr. 23 - Příklad zobrazení nejlepších verzí vah pro všechny hodnoty parametru PST

Dalším používaným zobrazením mřížky parametrů je zobrazení hodnoty dosaženého KD na základě verze vah pro všechny hodnoty parametru PST viz Obr. 24. V rámci práce bude pojmenováno toto zobrazení *KD verzí vah PST*. Na grafu pro každou realizaci parametru PST je na x-ové ose verze vah a na y-ové dosažený koeficient determinace. Podobně jako v předchozím případě, záměrem tohoto zobrazení je odhalení náhodné chyby, která nemusí být patrná z výběru tří nejlepších verzí vah.
V některých případech se stává, že nejlepší koeficient KD je dosažen například u w = 70 a zároveň w = 100. I když jsou hodnoty KD podobné (nebo srovnatelné s ohledem na náhodnou chybu) můžou být u předchozího zobrazení vybrány verze vah pouze okolo 70 (respektive pouze okolo 100). Díky tomuto zobrazení může být volba optimální verze vah přehodnocena.

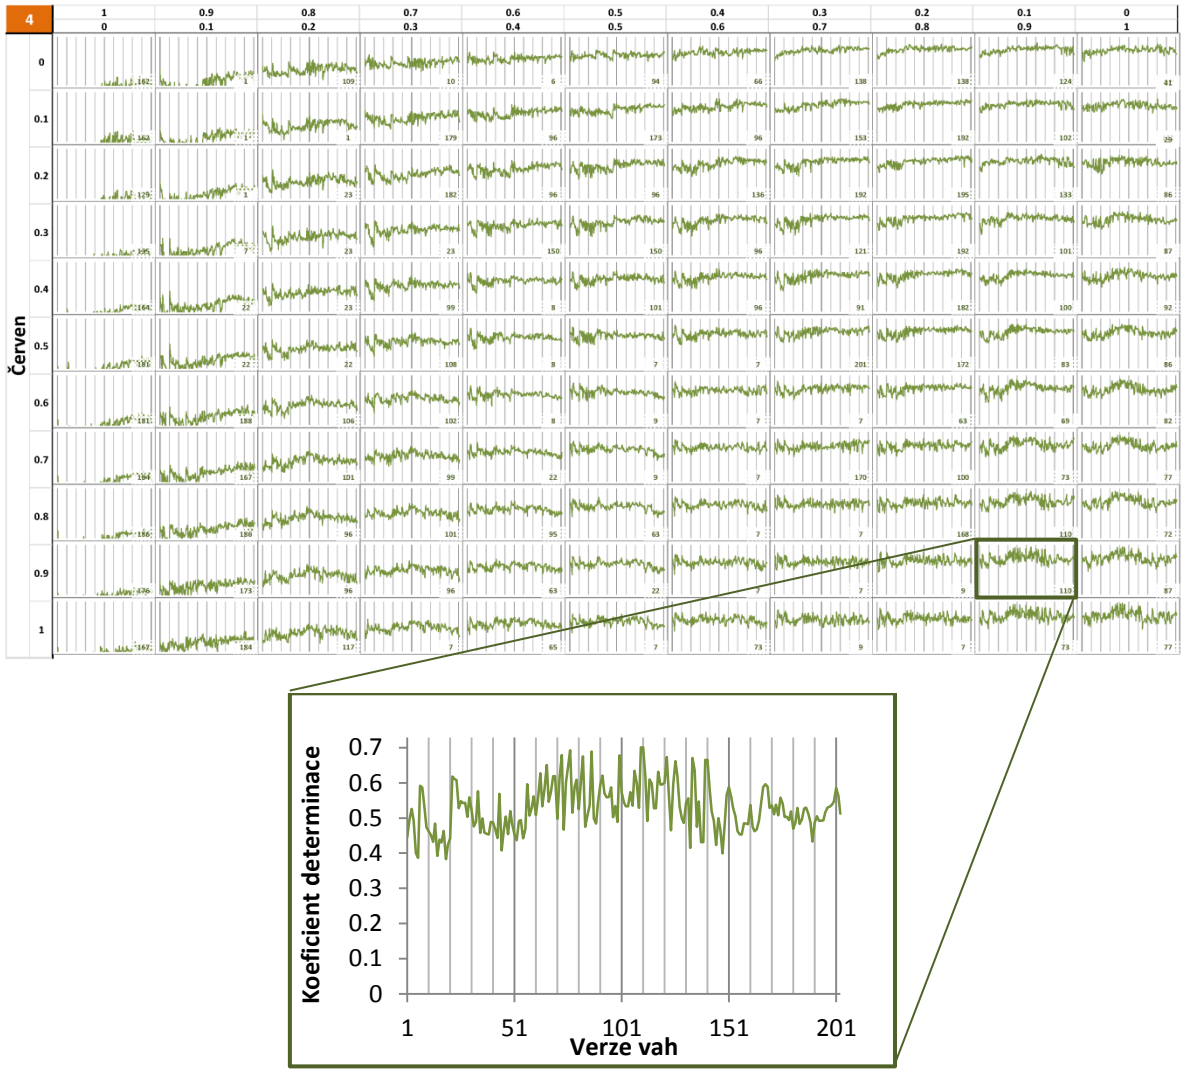

Obr. 24 - Příklad zobrazení KD(W) pro všechny hodnoty parametru PST

6.5.2 Metoda volby parametru PST

Cílem je vhodně stanovit hodnotu parametru PST pro profil, na kterém bude předpověď aplikována. Předpoklad je, že není známý žádný jiný parametr.

Pro volbu parametru PST je využíváno zobrazení Mapa PST (PST-m, NPHP-m, W-a). V průběhu postupu zjištění parametru PST je měněn parametr NPHP a je pozorován vývoj změny „polohy“ nejlepších hodnot KD na mapě PST. Společně se změnou polohy KD v měsíci, na který je předpověď vytvářena, je pozorován vývoj polohy nejlepších hodnot KD také v okolních měsících a je hodnoceno, jak změny vzájemně korelují. Na vývoj parametru má vliv také charakter zvoleného profilu. V případě Dunaje se poloha nejlepších KD se změnou NPHP nemění skoro vůbec. Naopak u Jihlavy nebo Oslavy se poloha nejlepších KD objeví na jiném místě mapy PST při každé změně NPHP (více v kapitole 7.1).

Při sledování změny polohy nejlepších hodnot KD je vhodné předběžně odhadnout při jakém parametru NPHP dosahuje KD své maximum. K tomu může sloužit zobrazení KD(NPHP) kde jsou voleny parametry PST a W automaticky. Příklad zobrazení KD(NPHR) je uveden na Obr. 25, kde ve sloupcích jsou měsíce a řádcích jsou hodnoty parametru NPHP. Poloze nejlepších KD v mapě PST při předběžně odhadnuté poloze parametru NPHP jde přisoudit větší význam oproti nejlepším polohám KD při jiných NPHP.

NPHP \ Měsíce	1	2	3	4	5	6	7	8	9	10	11	12
1	-0.224	0.213	0.060	-0.095	0.387	0.721	0.659	0.164	-0.033	-0.001	0.078	0.117
2	0.130	0.285	0.261	0.175	0.385	0.713	0.624	0.290	-0.090	0.127	0.120	0.154
3	0.150	0.285	0.206	0.216	0.404	0.680	0.664	0.257	0.023	0.087	0.191	0.173
4	0.094	0.351	0.238	0.292	0.380	0.677	0.611	0.258	0.063	0.071	0.168	0.235
5	0.086	0.315	0.226	0.257	0.415	0.681	0.642	0.269	0.044	0.062	0.215	0.267
6	0.125	0.281	0.255	0.298	0.394	0.700	0.640	0.267	-0.010	0.036	0.257	0.283
7	0.159	0.259	0.239	0.301	0.358	0.709	0.612	0.249	0.013	0.016	0.251	0.300
8	0.128	0.289	0.232	0.281	0.346	0.724	0.611	0.253	0.119	0.015	0.260	0.294
9	0.136	0.270	0.217	0.280	0.354	0.710	0.597	0.251	0.061	0.007	0.294	0.298
10	0.175	0.293	0.199	0.281	0.345	0.704	0.590	0.222	0.079	0.016	0.280	0.284
11	0.187	0.277	0.191	0.267	0.343	0.711	0.591	0.199	0.089	0.014	0.262	0.268
12	0.175	0.301	0.214	0.270	0.338	0.708	0.577	0.203	0.091	-0.002	0.251	0.282
13	0.199	0.275	0.232	0.267	0.334	0.708	0.575	0.185	0.057	0.010	0.244	0.279
14	0.175	0.270	0.204	0.262	0.335	0.708	0.576	0.166	0.086	0.028	0.235	0.282
15	0.171	0.256	0.215	0.257	0.318	0.688	0.568	0.171	0.069	0.011	0.232	0.292
16	0.167	0.260	0.208	0.248	0.314	0.671	0.555	0.159	0.065	-0.004	0.246	0.278
17	0.159	0.263	0.205	0.246	0.322	0.657	0.560	0.159	0.065	-0.005	0.233	0.274
18	0.165	0.264	0.188	0.234	0.319	0.639	0.562	0.160	0.046	-0.003	0.221	0.282
19	0.151	0.253	0.184	0.221	0.322	0.630	0.563	0.152	0.065	-0.009	0.209	0.266
20	0.140	0.246	0.177	0.217	0.324	0.615	0.581	0.159	0.059	0.005	0.209	0.259

Obr. 25 - Závislost KD(NPHR)

Na základě výše popsaného postupu je potom možné zvolit nejvhodnější parametry PST. S ohledem na následnou volbu parametrů NPHP a W není vhodné zvolit parametry bodově – tj. prohlásit nejlepší volba je jedna konkrétní kombinace v_p, v_s, v_t. S bodově určenou polohou nejlepšího vlivu PST by hledání dalších parametrů bylo velmi nejednoznačné (a tím i obtížnější). Zvláště v případě menších povodí (Umpqua, Morava, Jihlava, Oslava) by při bodové hodnotě PST byla výrazně větší náhodná chyba průběhu dosažené přesnosti předpovědi pro spektrum hodnot určitého parametru, jak bylo demonstrováno na Obr. 19. Proto bylo zvoleno vybrat oblast na mapě PST, v které je předpokládaný výskyt nejlepších PST. Oblast s předpokládaným výskytem nejlepších PST označená červeným rámečkem na obr. 26 bude dále v práci pojmenována *ohrada.* Například, jednotlivé hodnoty Obr. 25 mohu být určeny pro jednotnou volbu parametru PST nebo mohou být vybrány z ohrady podle KD nebo jiného kritéria. Druhá možnost poskytne lepší přehled o vývoji velkosti KD se změnou NPHP a potom vhodnější volbu parametru NPHP. Pokud je parametr PST vybírán z ohrady je volen na základě KD nebo jiných kritérií (což například může být volba PST pro předchozí NPHP respektive W). Dá se tedy říci, že parametr PST je volen částečně automaticky z ohrady. Ohrada může být umístěna na výšku, kdy obsahuje 24 bodů mřížky PST nebo na šířku kdy obsahuje 25 bodů mřížky PST (mřížka má celkově 121 bodů). Ohrada má obdélníkový tvar avšak v některých případech by byl více vhodný trojúhelníkový, který se však v práci nepoužívá. Zavedení ohrady je pouze jedna z metod jak nalézt parametry modelu a kalibrační vzory. Další možné způsoby již nejsou v práci popsány.

Ohrada se používá pouze pro hledání dalších parametrů (tj. parametrů, které jsou voleny na základě volby parametru PST). Konkrétní volba parametru PST pro vytvoření předpovědi je zobrazena na mapě PST červeným rámečkem, viz obr. 26.

Volba ohrad a konkrétních hodnot parametru PST pro jednotlivé profily jde nalézt v přílohách 12.2 až 12.2.6.

		1	0.9	0.8	0.7	0.6	0.5	0.4	0.3	0.2	0.1	0
		0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
Červen	0	0.183	0.248	0.393	0.476	0.526	0.601	0.644	0.677	0.715	0.703	0.669
	0.1	0.183	0.268	0.424	0.497	0.572	0.636	0.659	0.695	0.724	0.704	0.679
	0.2	0.218	0.298	0.416	0.527	0.583	0.633	0.666	0.699	0.716	0.716	0.670
	0.3	0.190	0.312	0.436	0.512	0.588	0.618	0.659	0.707	0.710	0.712	0.677
	0.4	0.209	0.309	0.441	0.537	0.590	0.632	0.667	0.697	0.699	0.724	0.688
	0.5	0.212	0.330	0.460	0.529	0.583	0.627	0.660	0.687	0.692	0.704	0.668
	0.6	0.240	0.326	0.436	0.525	0.594	0.630	0.648	0.674	0.702	0.692	0.663
	0.7	0.229	0.327	0.431	0.514	0.570	0.631	0.665	0.685	0.700	0.679	0.664
	0.8	0.211	0.354	0.426	0.504	0.568	0.623	0.655	0.664	0.676	0.707	0.680
	0.9	0.197	0.328	0.441	0.519	0.558	0.620	0.674	0.657	0.669	0.729	0.695
	1	0.229	0.313	0.421	0.474	0.553	0.617	0.656	0.655	0.675	0.681	0.704

obr. 26 - příklad zobrazení KD pro všechny hodnoty parametru PST

6.5.3 Metoda volby parametru NPHP

Cílem je vhodně stanovit hodnotu parametru s předpokladem, že je odhadnuta poloha parametru PST pomocí ohrady. Prostup je následující:

Pro jednotlivé hodnoty parametru NPHP jsou se zobrazení kontrolní kvadranty-PST vybrány grafy kontrolních kvadrantů ležící uvnitř ohrady podle nejlepšího KD nebo podle subjektivní volby. Vybrané grafy kontrolních kvadrantů jsou seřazeny pod sebe podle NPHP jak jde vidět v přílohách 12.2 až 12.2.6. Toto zobrazení je nazýváno *vývoj kontrolních kvadrantů*[3]. Pozorováním vývoje kontrolních kvadrantů je rozhodnuto o volbě parametru NPHP.

Hodnota parametru NPHR ovlivňuje, jaký mají kontrolní kvadranty *tvar.* Pří nízkých NPHP mají kontrolní kvadranty tvar kruhu okolo srovnávací přímky při vysokých NPHP mají naopak tvar vodorovné přímky, která se velmi přibližuje přímce představující aritmetický průměr. Vypočtený koeficient determinace může mít stejnou hodnotu pro tvar kruhu i vodorovné přímky. Subjektivním zhodnocením je však možné rozhodnout jestli je více vhodné zvolit tvar kruhu nebo vodorovné přímky na základě pozorování vývoje kontrolního kvadrantu. Volba parametru NPHP na základě pozorování vývoje kontrolního kvadrantu se lépe osvědčila než na základě zobrazení KD(NPHP) na Obr. 25. Více o vztahu parametru NPHP a tvaru kontrolního kvadrantu v kapitole 7.1.

Na Obr. 27 jde vidět příklad obecného vysvětlení v předchozím odstavci. V prvním grafu jde vidět, že kontrolní kvadranty mají tvar kruhu v posledním naopak tvar vodorovné přímky. Při NPHP = 16 dosahuje koeficient determinace nejlepší hodnotu, ale z pozorování změny tvaru kontrolního

[3] I když je zobrazení kontrolního kvadrantu PST podobným zobrazením jako mapa PST, je v něm mnohem více informací, které může být obtížné pro řešitele pojmout. Proto je považováno za vhodnější vytvořit zobrazení vývoj kontrolního kvadrantu a do zobrazení kontrolního kvadrantu PST využívat pro doplňující informace.

kvadrantu mezi NPHP = 1 a 16 by šlo usoudit, že nejlepší volba parametru NPHP může ležet někde uprostřed.

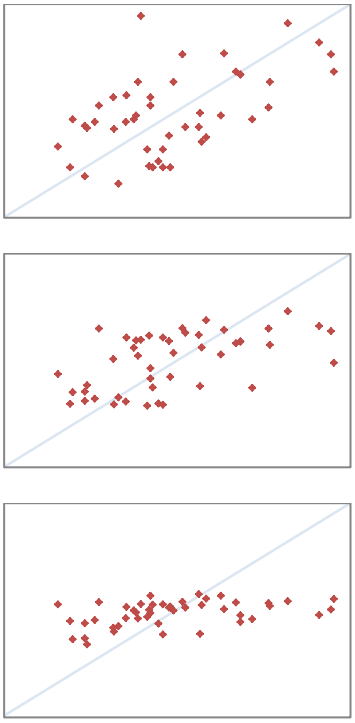

NPHP = 1
KD = 0,135

NPHP = 8
KD = 0,143

NPHP = 16
KD = 0,170

Obr. 27 - Příklad vývoje kontrolního kvadrantu pro rozdílné hodnoty parametru NPHP

Konkrétní volba parametrů jde vidět v přílohách 12.2 až 12.2.6.

6.5.4 Metoda volby parametru W

Cílem je vhodně stanovit hodnotu parametru s předpokladem, že je odhadnuta poloha parametru PST pomocí ohrady a jsou odhadnuty NPHP. Prostup je následující:

Pro jednotlivé hodnoty parametru NPHP jsou se zobrazení nej váhy PST vybrány grafy nejlepších třech vah ležící uvnitř ohrady podle nejlepšího KD nebo podle subjektivního rozhodnutí. Vybrané grafy vah jsou seřazeny pod sebe podle NPHP jak jde vidět v přílohách 12.2 až 12.2.6. Vytváření zobrazení je nazýváno *vývoj vah.* Pozorováním vývoje vah a taky s přihlédnutím k zobrazení KD verzí vah PST je rozhodnuto o volbě parametru W.

6.5.5 Oprava vychýlení extrémů vstupních dat

Pro optimální volbu parametrů modelu podobnosti má významný vliv i využití opravy vychýlení dat od extrémních průtoků. Jak jsou data opravena o vychýlení je popsáno v kapitole 6.1.3, tato kapitola se zabývá, jak jde výsledky na základě opravení dat o vychýlení použít pro volbu optimálních parametrů.

Princip této metody spočívá v porovnání zobrazení mřížky dosažených výsledků na základě použití opravených a neopravených dat a díky tomu k rozhodnutí nad vhodnou volbou parametrů. Díky použití opravených dat je v některých případech jasnější optimální volba parametrů modelu podobnosti, jak jde vidět na Obr. 28. V některých případech jde díky porovnání výsledků dat opravených o vychýlení a původních dat lépe rozpoznat kalibrační vzor.

Na Obr. 28 je zobrazeno porovnání výsledků z pomocí dat opravených o vychýlení a původních dat na řece Jihlavě, okamžik vytváření předpovědi je měsíc květen, v měsíci červnu je odstraněn jeden nejvyšší průtok. Jsou zde zobrazeny čtyři mapy PST, pro hodnoty NPHP = 1, 2, 3, 4. Parametr W je volen automaticky. Optimální volba parametru PST (respektive umístění ohrady) je v levém horním rohu. V případě původních dat jde vidět, že nejvyšší hodnoty KD padnou do ohrady až při NPHP = 4. V případě opravených dat padnou pro všechny hodnoty NPHP nejvyšší hodnoty KD do ohrady. Popsaná skutečnost vypovídá, že při zkoumání volby vhodné volby parametru PST práce s původními daty vyvolá určité dilema kde o oblasti optimální volby parametru PST. Rozhodnutí nad optimální volbou parametru PST (nebo respektive jeho oblastí/ohradou) je díky použití dat opravených o odchýlení snažší.

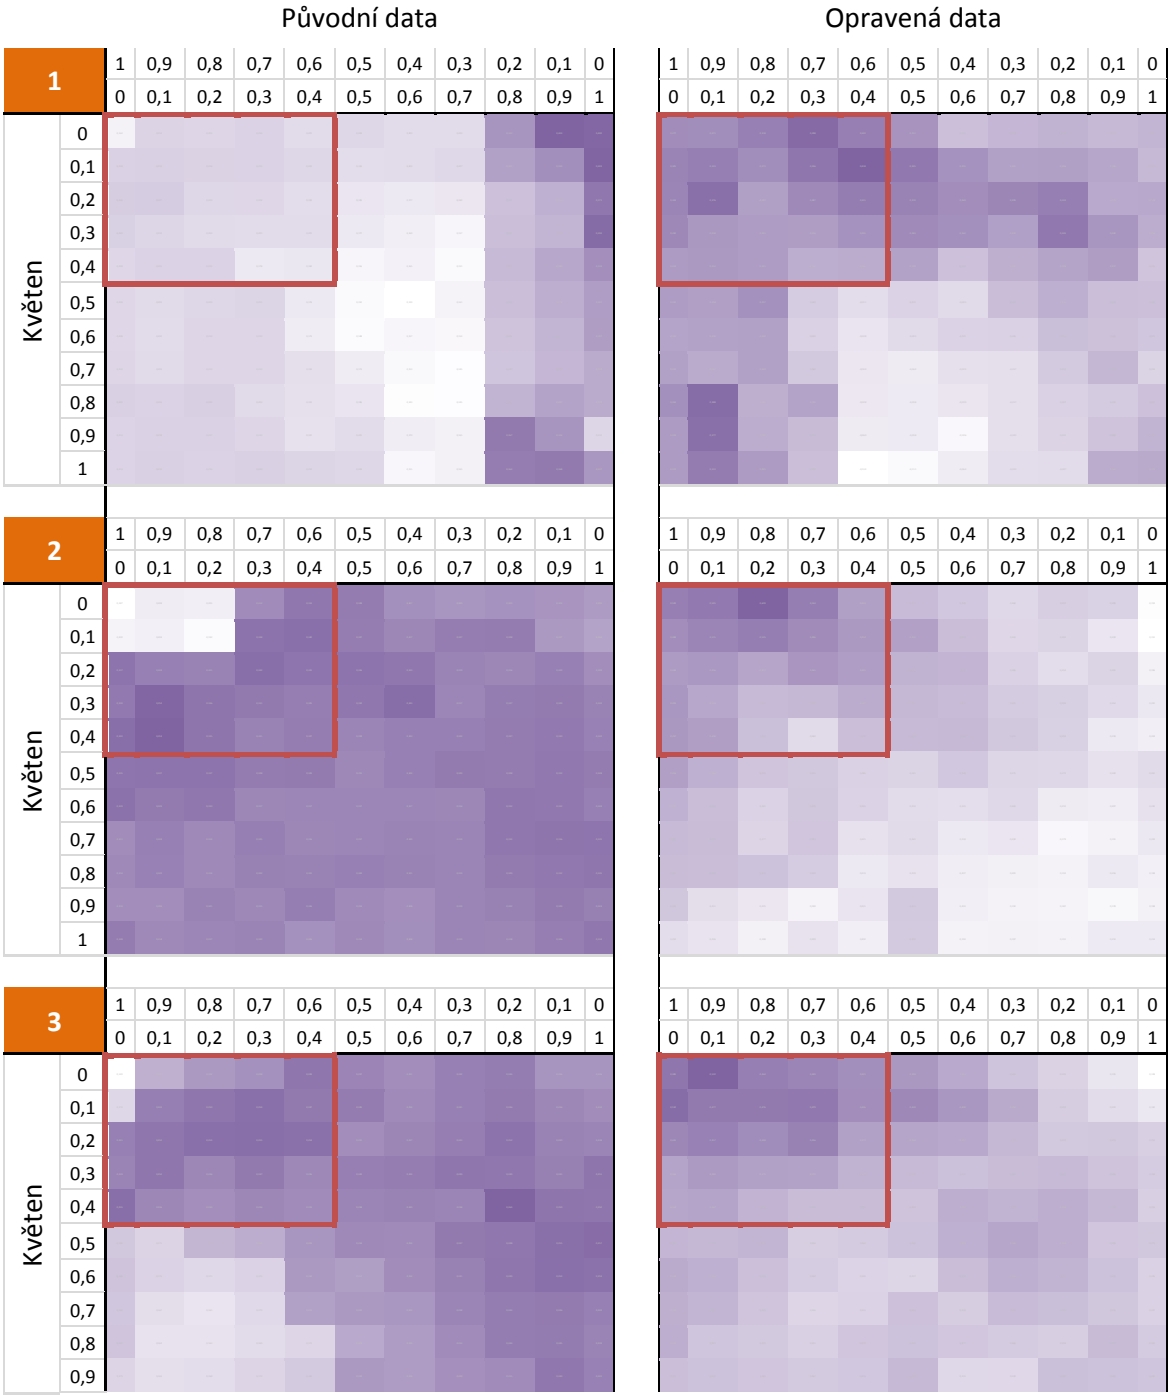

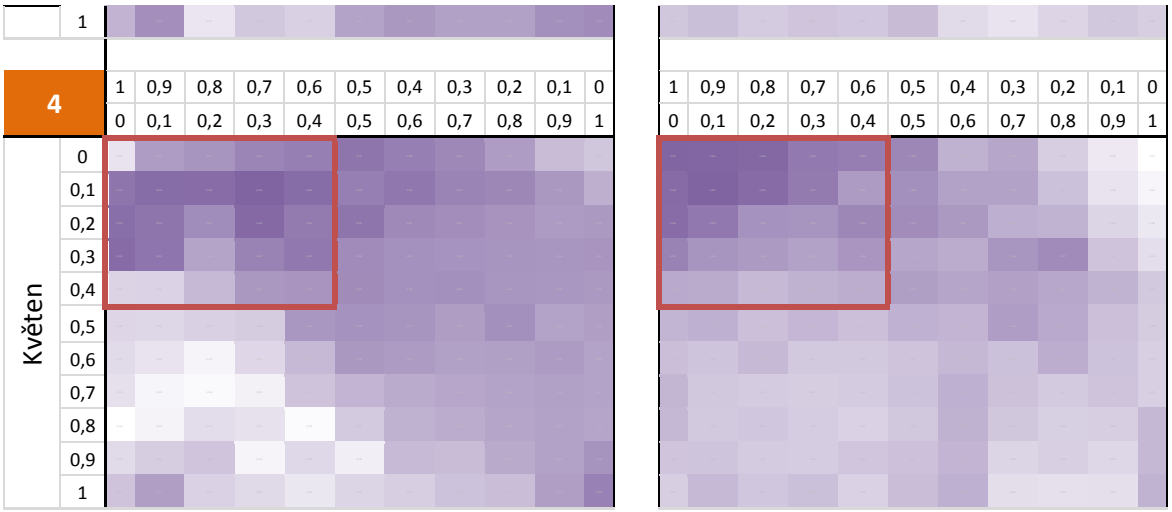

Obr. 28 - Příklad vývoje dosažených výsledků KD na mapě PST pro rozdílné NPHP

Výše v textu byly popsány pouze nejvíce používané metody k nalezení parametrů modelu podobnosti a nalezení kalibračních vzorů. V průběhu výzkumu bylo používáno více metod.

6.6 Vývojové prostředí modelu podobnosti

Na počátcích výzkumu byly modely podobnosti vyvíjeny s využitím programu Microsoft Excel. Při nárůstu množství mechanicky opakovaných procesů začal být využíván programovací jazyk Visaul Basic for Application (VBA), který je součástí programu Microsoft Excel. Při využití VBA se uživatelské prostředí Excelu se stalo nástrojem k zobrazení výsledků a výpočetní operace byli zpracovány VBA. VBA je interpretovaný programovací jazyk (kompiluje se za chodu programu). To umožňuje měnit zdrojový kód programu přímo za jeho chodu, což může být výhodné ve fázi vývoje programu. Avšak významná nevýhoda interpretovaných programovacích jazyků je pomalé zpracování náročných výpočetní operací. V průběhu vývoje modelu podobnosti narostlo množství výpočetních operací při výpočtu přednosti předpovědi pro mřížku parametrů, který by v případě použití VBA trvalo pro jeden profil v řádu několika měsíců. Z toho důvodu začal být pro kalibraci modelu podobnosti používán programovací jazyk FORTRAN. Navíc programovací jazyk FORTRAN umožnil distribuovat výpočty na více jader procesoru počítače a tím plného využití výpočetního potenciálu PC. Celková doba kalibrace trvá do deseti minut a nejnáročnější případy maximálně půl hodiny.

V současné podobně využívá model podobnosti program Excel jako uživatelské prostředí k zadání vstupních informací popřípadě nastavení modelu a k zobrazení výsledků kalibrace modelu podobnosti. Jazyk VBA je používán drobným operacím v uživatelském prostředí jakou jsem například úpravy vstupních dat modelu podobnosti, dále k vytvoření vstupních dat k zadání kalibrace a importování výsledků kalibrace do uživatelského rozhraní Excel. FORTRAN je využíván pro výpočet kalibrace modelu podobnosti.

7 Aplikace

Kapitola popisuje aplikaci modelu podobnosti. V první části popsány předpovědní profily na kterých je předpověď prováděna. Následně jsou popsány kalibrační vzory, což je soubor pravidel ke kalibraci modelu podobnosti získaných pomocí metod popsaných v kapitole 0, aplikací modelu podobnosti na kalibrační soubor dat. V kapitole 7.3 je ukázána předpověď kalibrovanými modely podobnosti na validačních souborech dat všech předpovědních profilů. V kapitole 7.4 je ukázka zužitkování poznatků získaných v průběhu výzkumu pro řízení jedné izolované vodní nádrže umístěné v profilu Oslavany na řece Oslavě.

7.1 Předpovědní profily

Volba a aplikace předpovědního způsobu je testována na šesti profilech, které jsou představeny v rámci této kapitoly. Pro každý profil je představena zeměpisná poloha, odtokové poměry, základní statistiky a další charakteristiky. Předpovědní profily jsou vzájemně porovnány a jsou nastíněny důvody jejich volby. V kapitole je také přiblížena volba rozdělení datových souborů a kalibrační a validační soubor. Aplikace zvoleného předpovědního způsobu na předpovědních profilech je popsána v kapitole 1.

Tab. 6 - Základní statistiky řek a předpovědních profilů

Řeka	Profil	Stát	Délka dat [4]	Délka toku [5]	Sběrná plocha	Průměrný průtok
			[roky]	[Km]	[Km^2]	[m^3/s]
Dunaj	Ceatal	Rumunsko	88	2 860	817 000	6 500
Rýn	Lobith	Nizozemí	76	1 233	170 000	2 000
Umpqua	Elkton	USA	59	179	12 018	208
Morava	Strážnice	ČR	47	151	9 145	60
Jihlava	Ptáčov	ČR	42	91	963	5,5
Oslava	Oslavany	ČR	48	97	861	3,5

Dunaj je druhou nejdelší řekou v Evropě a nejdůležitější řekou v centrální a jihovýchodní Evropy. Pramení v Černém lese v jihozápadním Německu, z kterého se ubírá převážně východním směrem. Po přibližně 2 860 kilometrech se vlévá do Černého moře. Díky geologickým a geografickým podmínkám jde povodí Dunaje rozdělit do třech hlavních oblastí: horní, střední, spodní Dunaj. Řeka má složitý vodní režim, ve kterém jsou výrazné tři fáze. Na jaře je nejvyšší vodní stav, v létě a na podzim dochází k nárazovým povodním a na konci podzimu a v zimě je vodní stav nejnižší. Hladina začíná stoupat v únoru až dubnu a na horním a středním toku se udržuje vysoká do května, zatímco na dolním až do června. Celý vzestup hladiny se skládá ze dvou vln. První je způsobena táním sněhu v rovinách a druhá smíšená dešti a táním sněhu na horách. Nerovnoměrnost tání sněhu a srážek v různých částech povodí způsobují prudké kolísání hladiny. Když povodňové vlny z hlavních přítoků (Dráva, Tisa, Sáva) přijdou ve stejný čas, vytvoří se na Dunaji mohutná vlna, která může způsobit povodně. Ve druhé polovině léta hladina klesá, což je však přerušováno náhlými vzestupy při deštích. V říjnu a v listopadu deště způsobují podzimní povodně. V případě, že je teplá zima, může setrvat

[4] Délka dat je pro všechny tři datové soubory, tj. pro průtokovou, srážkovou a teplotní řadu
[5] Jedná se o délku toku od pramene po předpovědní profil

vysoký vodní stav a vzestupy hladiny mohou být způsobeny také ledovými zátarasy, což může vést až k vylití řeky z břehů a zatopení pobřežní roviny. Když je zima studená tak má řeka nejnižší vodní stav. Předpovědi jsou vytvářeny pro uzávěrkový profil povodí Ceatal.

Rýn je největší hydrologický systém v západní Evropě. Od pramene ve východním Švýcarsku teče řeka severozápadním směrem přes Německo a Švýcarsko a 1320 Km se vlévá do severního moře. Povodí Rýnu s rozlohou 185 000 Km^2 se skládá ze čtyř hlavních dílčích povodí: alpská oblast ve Švýcarsku, hornaté nebo nížinné povodí přítoků Neckar, Main (Německo), Moselle (Německo a Francie). Odtokové poměry na území Německa jsou popsatelné převážně dvěma procesy. V průběhu málovodého období v létě je převážná většina odtoku vytvářena v Alpské oblasti díky tání sněhu a ledu. Přítoky z Francie a Německa nepřispívají příliš k tomuto odtoku. Převážná většina srážek spadlá na mimo alpskou oblast se z povodí vypaří. Situace se změní v zimním období kdy převážná většina srážek spadlá do alpského regionu je ukládána ve sněhové a ledové pokrývce zatímco v ostatních povodích se mění na odtok. Předpovědi jsou vytvářeny v měrné stanici Lobith, která se nalézá na spodním toku Rýnu v Nizozemí (blízko Německých hranic).

Umpqua je řekou s jedním z nejdelších přímořských povodí v Oregonu (severozápadní USA). Řeka pramení ve dvou větvích, teče na západ a vlévá se do Pacifického Oceánu. Povodí řeky Umpqua je charakteristické mírným přímořským klimatem se slabými a vlhkými zimami a naopak suchými a teplými léty. V zimním období spadá na povodí nejvíce srážek a je i největší průtok. V průběhu jara se zmenšuje množství spadlých srážek. V letním období dosahují spadlé srážky minima. Podobně i průtok postupně klesá s přibývajícím létem a dochází k vyprazdňování vody akumulované v povodí v průběhu zimního období. Spadlé srážky a následně i průtok se postupně zvedá na počátku zimního období. Teploty v povodí neklesnou v zimním období pod nula stupňů celsia a maximální teploty jsou dosaženy v průběhu letního období zároveň se srážkovým minimem. Předpovědní profil leží blízko města Elkton, stát Oregon.

Morava je nejvýznamnější řekou na území Moravy. Pramení pod kralickým sněžníkem v pohoří Jeseníků. Převážně západním směrem protéká přes území Moravy a po 353 Km se řeka stává levostranným přítokem Dunaje. 284 Km z její délky leží na území České Republiky. Největší průtoky jsou dosaženy v průběhu jarních měsíců (březen a duben) díky tání sněhové pokrývky akumulované v horských oblastech v průběhu zimy. Od jara až do září velikost průměrného průtoku postupně klesá díky prázdnění zásob vody v povodí. Nejvíce průměrných srážek spadne na povodí v průběhu letního období. Průměrné měsíční teploty dosahují maxima v průběhu letního období a v zimě klesají pod nulu. Předpovědní profil Strážnice leží na hranicích mezi Českou republikou a Rakouskem, před soutokem Moravy a Dyje.

Řeka Jihlava a Oslava leží na území Moravy. Jejich povodí jsou přilehlá. Řeka Oslava se vlévá do Jihlavy, která se následně stává levostranným přítokem řeky Dyje, která se vlévá do Moravy a následně Dunaje. Odtokové poměry ovlivňují stejné skutečnosti, jaké byly popsány u Moravy s rozdílem, že povodí jsou mnohem menší a nejde zde pozorovat taková setrvačnost jako u Moravy. Předpovědní profil na řece Oslavě leží v obci Oslavany a na Jihlavě v obci Ptáčov u Třebíče před vzdutím vody od přehrady Dalešice.

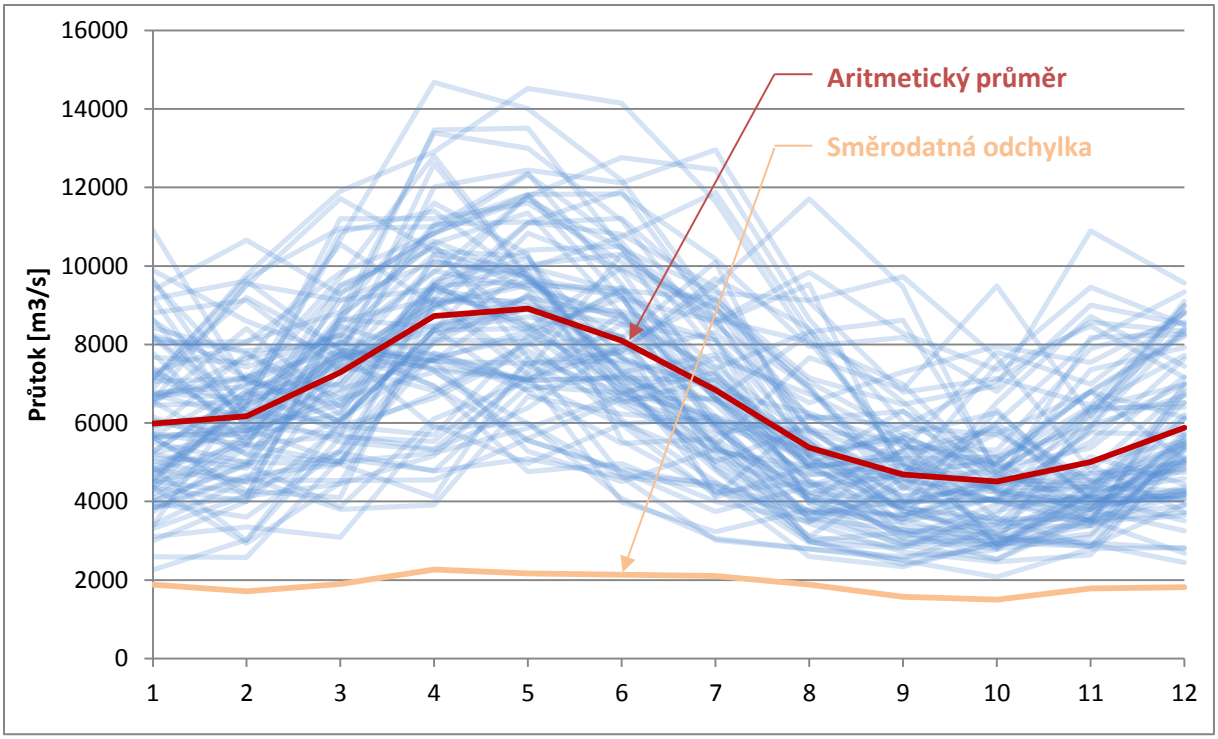

Obr. 29 – Zobrazení všech realizací průtokové řady v profilu Ceatal povodí Dunaje

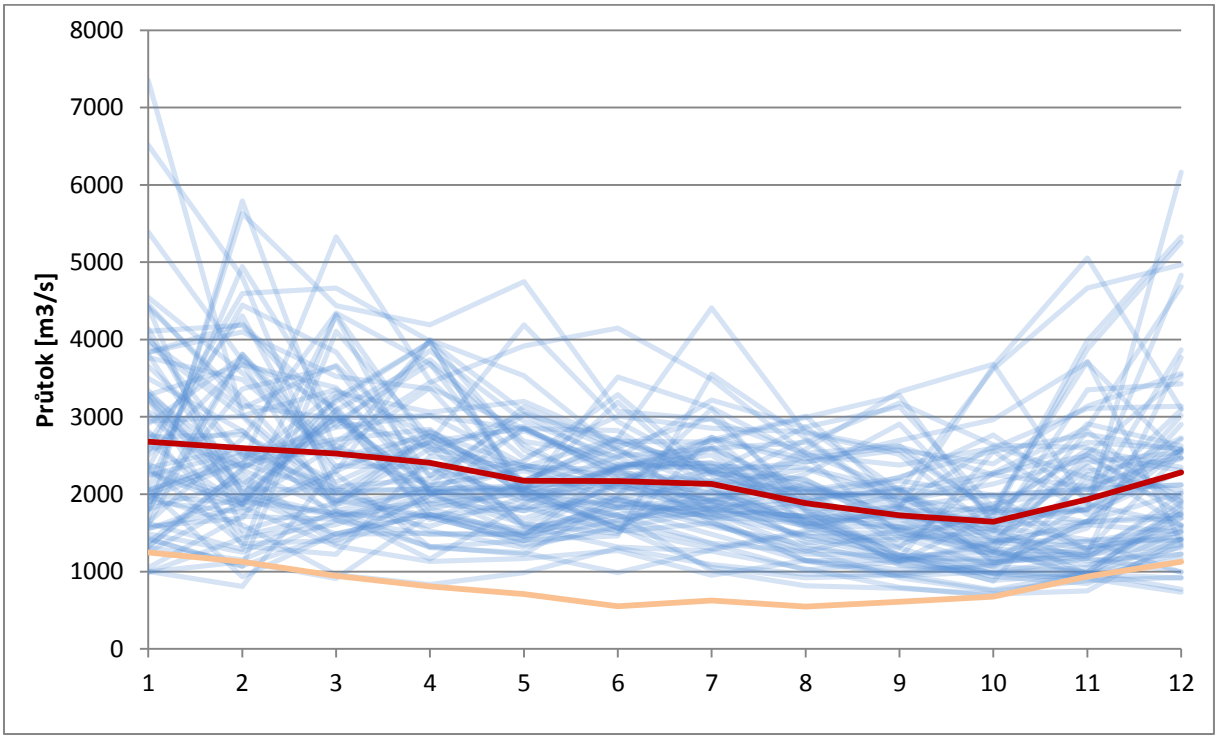

Obr. 30 - Zobrazení všech realizací průtokové řady v profilu Lobith povodí Rýnu

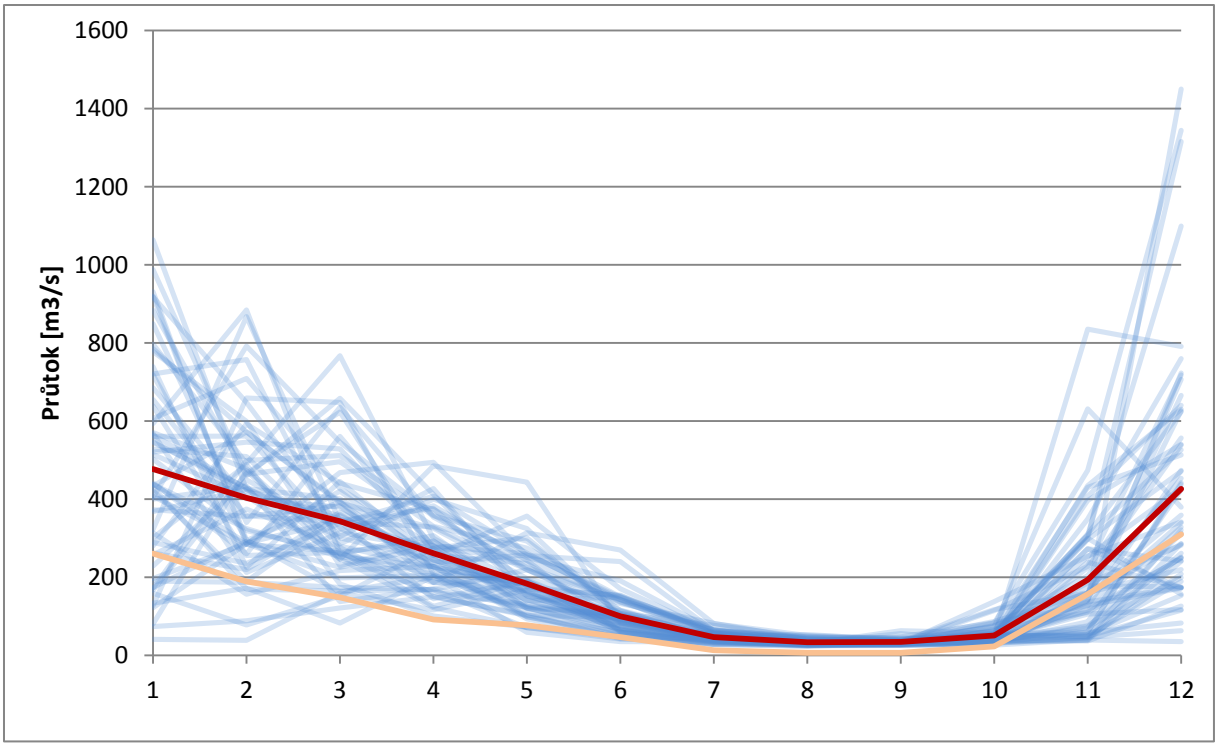

Obr. 31 - Zobrazení všech realizací průtokové řady v profilu Elkton povodí Umpqua

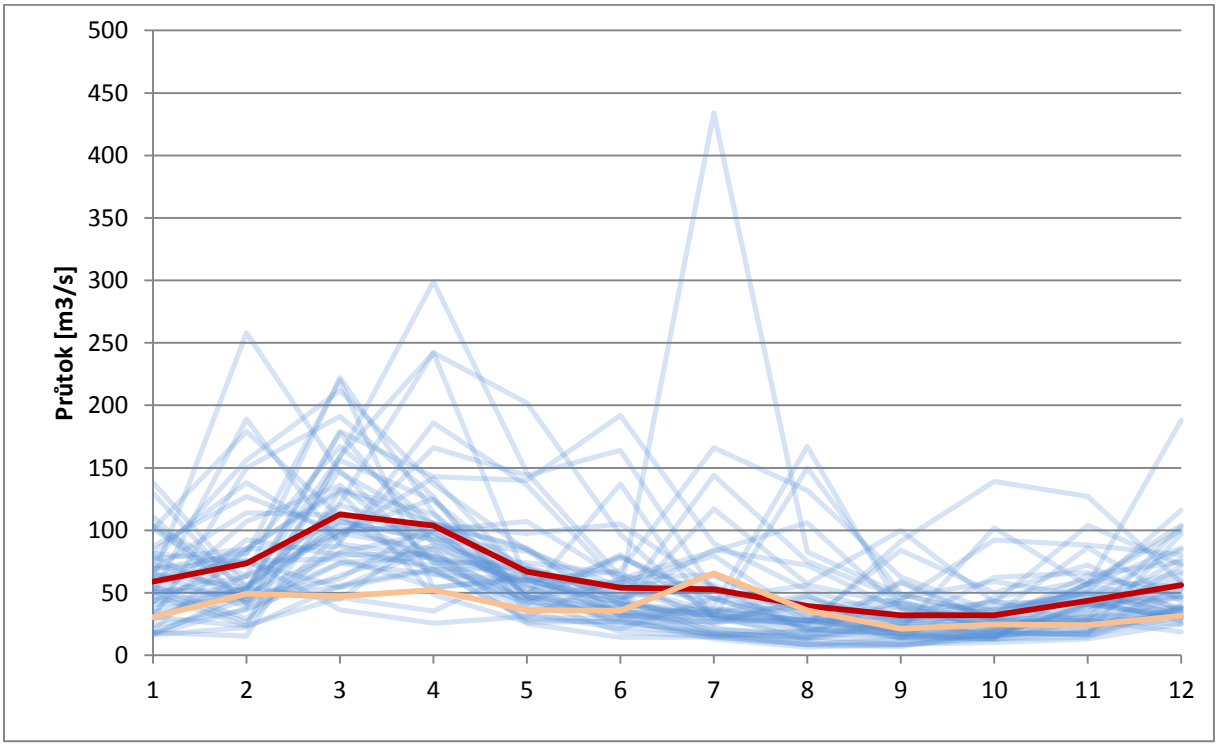

Obr. 32 - Zobrazení všech realizací průtokové řady v profilu Strážnice povodí Moravy

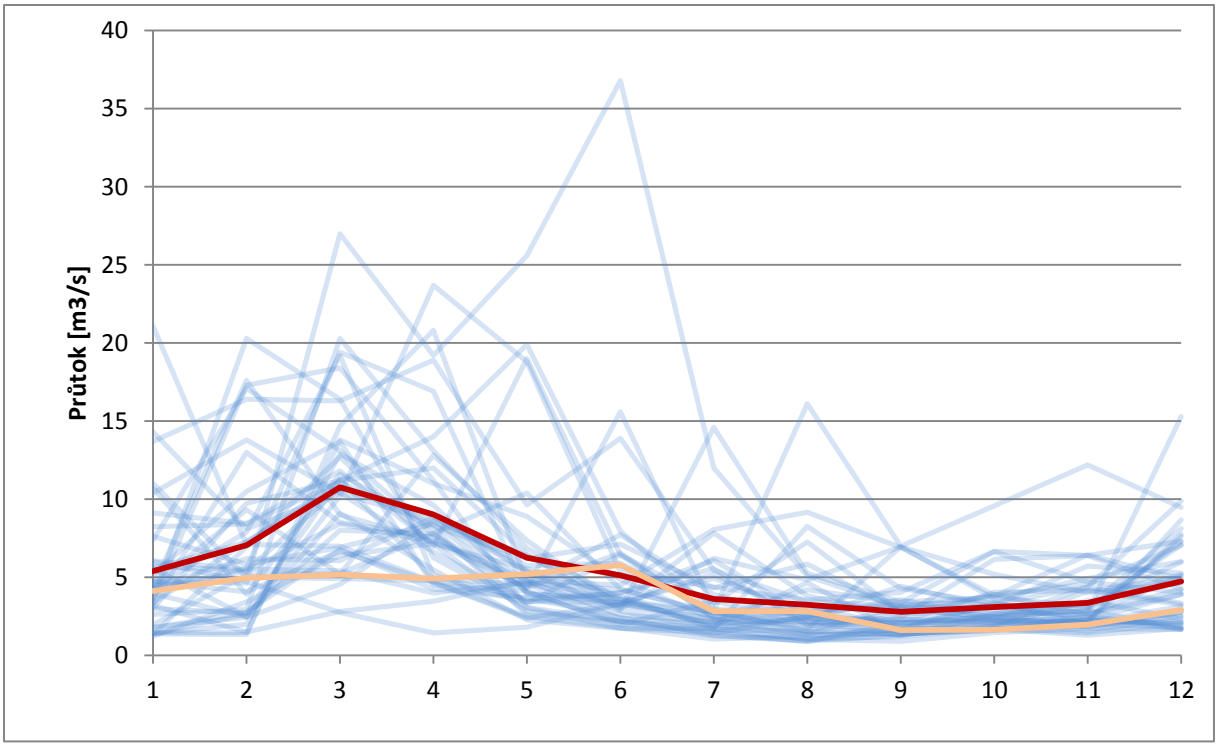

Obr. 33 - Zobrazení všech realizací průtokové řady v profilu Ptáčov povodí Jihlavy

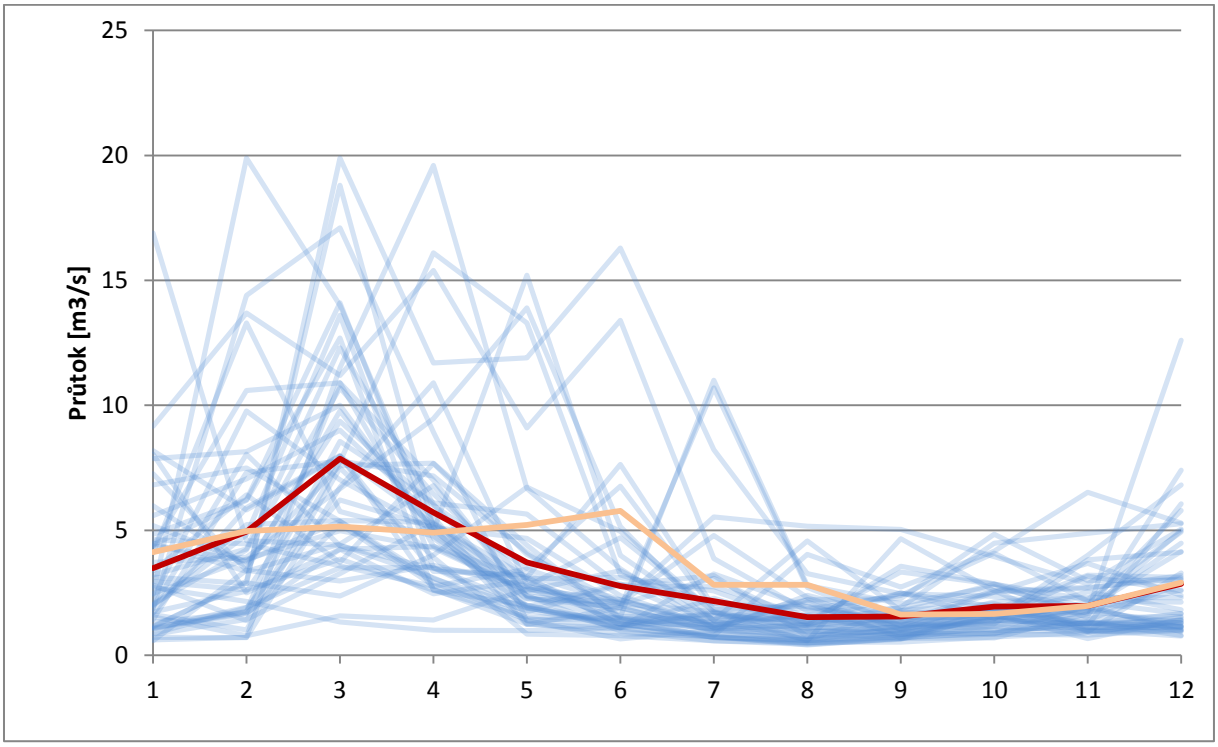

Obr. 34 - Zobrazení všech realizací průtokové řady v profilu Oslavany povodí Oslava

Obr. 35 - Povodí Dunaje

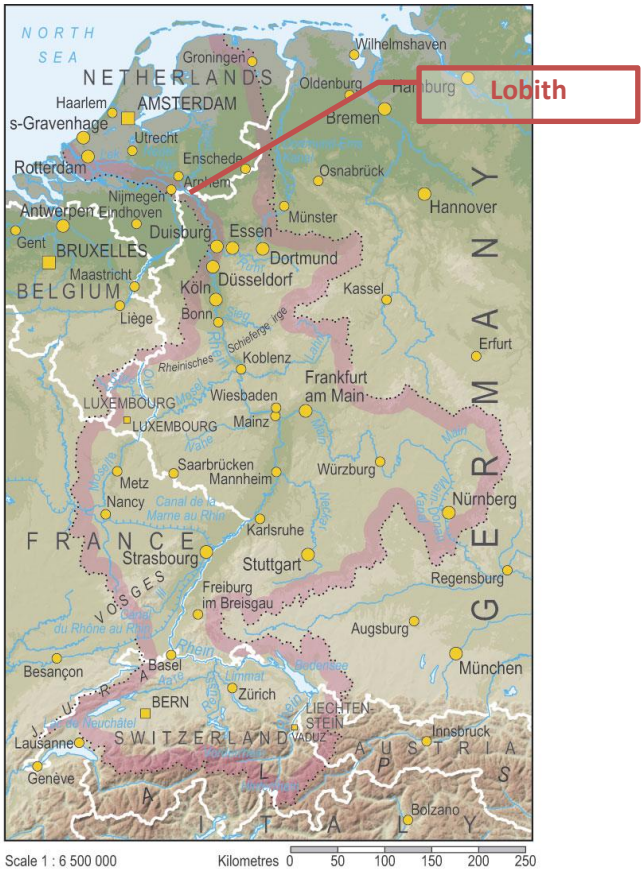

Obr. 36 - Povodí Rýna

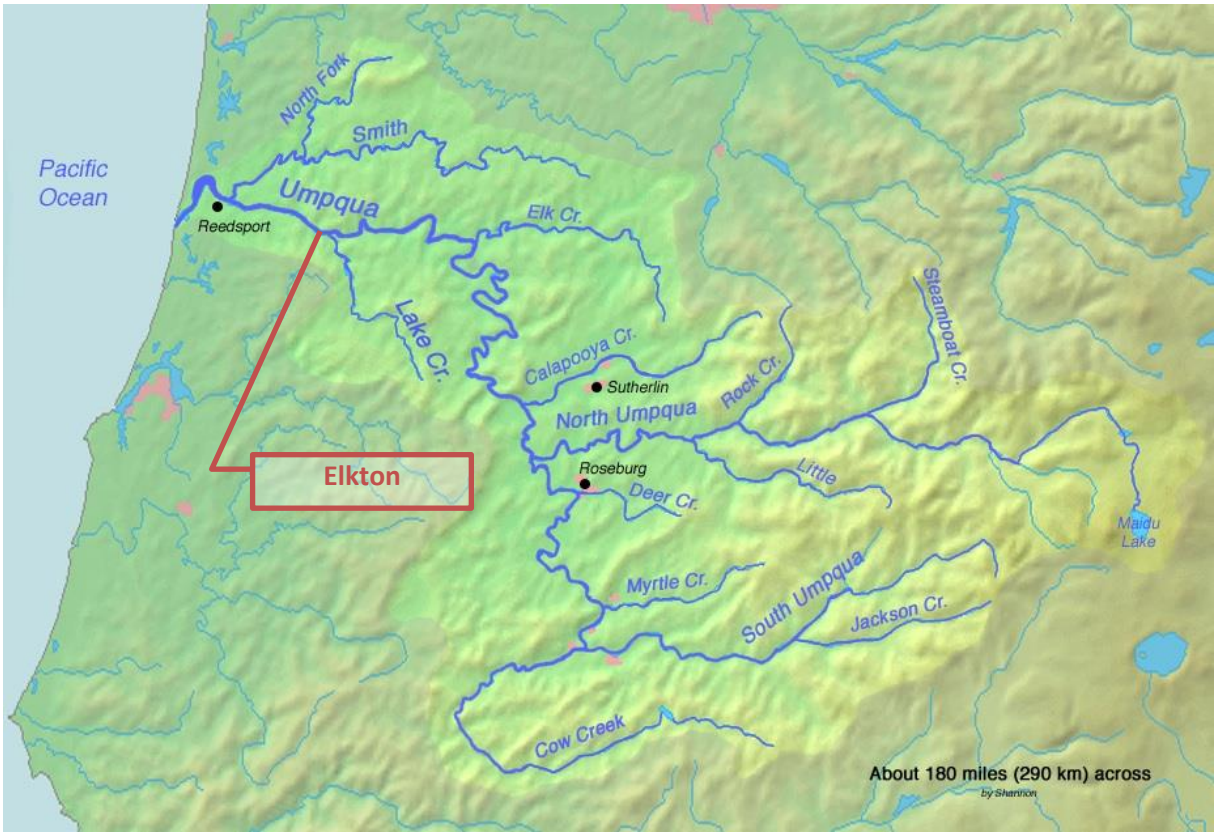

Obr. 37 - Povodí řeky Umpqua

Obr. 38 - Povodí řeky Moravy na území České republiky

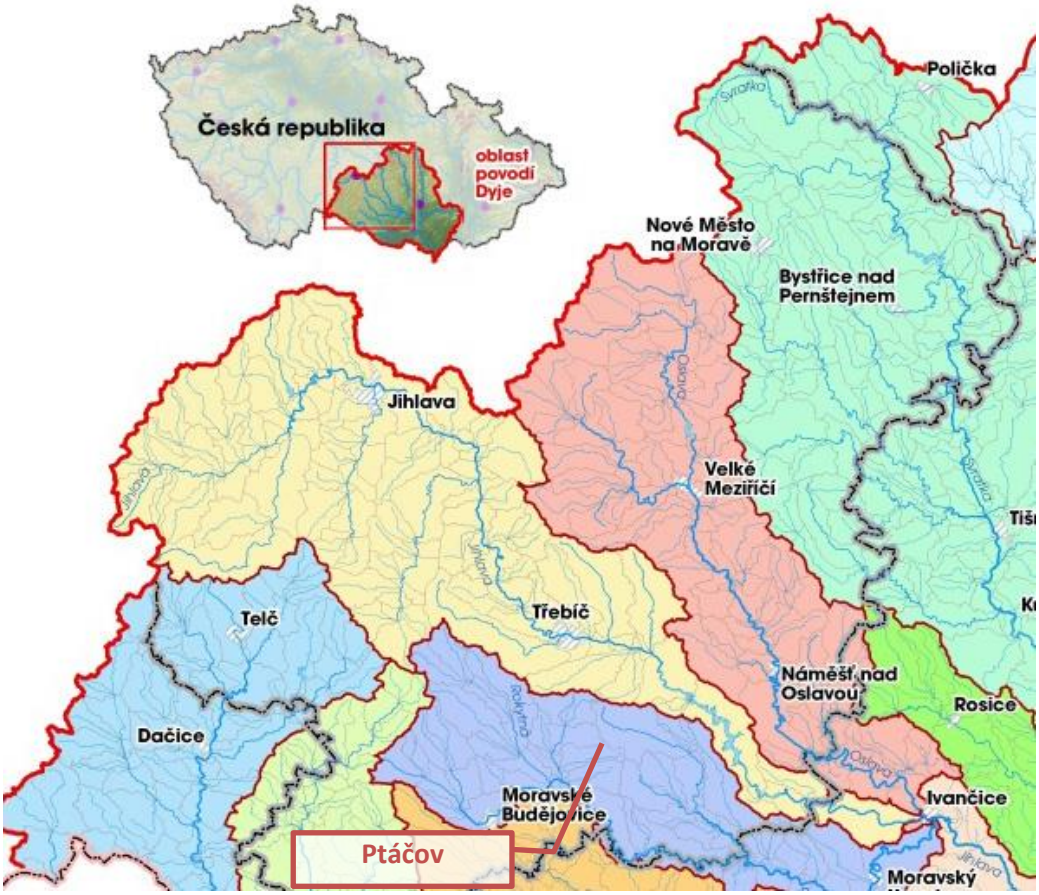

Obr. 39 - Povodí řek Jihlava a Oslava

Předpovědní modely využívají k vytvoření předpovědi také srážková a teplotní data v profilu nad povodím. Zobrazení všech realizací měření a základní statistiky srážkových a teplotních řad jde nalézt v přílohách 12.2 až 12.2.6.

Profily byly zvolené tak, aby bylo možné vyvíjený model testovat na různě velkých povodích, různých odtokových poměrech a na území České republiky (kde je předpokládaná aplikace) i mimo něj. Dunaj i Rýn představují velké řeky s velkou setrvačností, jejíž odtokové poměry jsou ovlivněny spoustou faktorů. Řeka Umpqua je jedinou řeknou, jejíž odtokové poměry nejsou ovlivněny evropskými klimatickými poměry. Oproti evropským jsou klimatické procesy západního pobřeží USA pravidelnější a jednodušší (například jednoznačně odlišené období sucha a dostatku vody nebo průměrná teplota neklesá pod nulu). Tři profily na území České republiky představují značně menší povodí než předchozí tři. Tyto profily byly také vybrány s ohledem na předpokládanou aplikaci modelu na území České republiky. Profily Morava, Jihlava a Oslava jsou oproti předchozím zatíženy významněji neurčitostí zkoumaného jevu. Oproti velkým povodím (Dunaj a Rýn) se zde nevyskytují kombinace významných vlivů tvořící výsledných odtok z povodí jako například skládání odtoku z dílčích povodí na základě rozdílných srážek.

Z předchozího odstavce je patrné, že profily Dunaj, Rýn, Umpqua a profily na území ČR jsou od sebe odlišné určitými specifiky. Vývoj a aplikace modelu na profilech s rozdílným charakterem vedlo k širšímu porozumění vztahů mezi používaným modelem a zkoumaným jevem. Na druhou stranu zkoumaný je jev velmi neurčitý a poznatky získávané při aplikaci byli většinou velmi nejednoznačné a díky rozdílnosti profilů nebylo možné odhadované poznatky kvantitativně ověřit. Výjimku ke

skutečnosti popsané v předchozí větě tvořilo testování v profilech na řekách Jihlava a Oslava. Jejich povodí leží vedle sebe a jsou si velmi podobné. Získané poznatky se pro oba profily shodovali a umožnili aspoň částečně kvantitativní zhodnocení (jak je podrobněji popsáno v kapitole 1). Na druhou stranu vývoj a aplikace předpovědi na větším počtu profilů by byla časově velmi náročná; jak je patrné z kapitoly naměřené kalibraci modelu 0)

Volbu profilů ovlivňovala i dostupnost dat. Pro profily Dunaje a Rýnu byly průtokové řady získány od organizace Global Runoff Data Centre (GRDC) in Germany (http://grdc.bafg.de/). Průtokové řady k řece Umpqua jsou dostupné na webu United States Geological Survey (USGS) http://water.usgs.gov/waterwatch. Srážkové a teplotní data pro povodí řek Dunaj, Rýn a Umpqua byly získány z webu National Climatic Data Center (NCDC). Průtokové, srážkové a teplotní data na území české republiky byly poskytnuty Českým hydrometeorologickým ústavem.

Předpovědní způsob byl vyvíjen i na dalších profilech jako Dyje – Podhraní nad Dyjí, Mississippi – St. Louis, Yukon – Pilot Station, Skryje – Skryje a další.

V práci jsou využívány průtokové srážkové a teplotní časové řady. Míra vzájemných vazeb jednotlivých bodů časové řady je hodnocena autokorelační funkcí. Autokorelační funkce popisuje, jestli mají jednotlivé body časové řady nějakou informaci o poloze bodů v dalším časovém kroku. V příloze 12.1 jsou uvedeny tři autokorelační posuny pro každou časovou řadu – ACF(1), ACF(2), ACF(3). Vzájemné vztahy jednotlivých časových řad jsou hodnoceny koeficientem korelace. Ten může vypovídat například, jestli má srážka spadlá na povodí vliv na velikost v tom samém měsíci anebo dalším. V příloze 12.1 jsou uvedeny korelační vazby mezi průtokovými, srážkovými a teplotními řadami ve stejném měsíci, jedním a dvěma předchozích měsíců – CF(0), CF(1), CF(2).

U všech profilů jde vidět, že autokorelační funkce průtokových řad nabývá nejvyšších hodnot v letních měsících, při kterých dochází k prázdnění povodí. U českých řek nabývá autokorelační funkce vyšších hodnot na konci podzimu. Srážkové řady nemají žádnou vnitřní strukturu tj. hodnota v dalším kroku časové řady nijak nezáleží na předchozí. To samé by šlo tvrdit i o teplotní časové řadě, kde však tvoří výjimku řeka Rýn. Velmi významná je korelace mezi srážkou a průtokem. U Dunaje jde vidět, že největší korelace mezi srážkou a průtokem je pro předchozí měsíc. To znamená, že průměrná srážka spadlá na plochu povodí se projeví na průtoku až další měsíc (doba dokoku povodí je více jak jeden měsíc). V případě Rýnu ovlivňuje odtok z povodí srážka, která spadne ten samý měsíc nebo předchozí měsíc. V případě všech dalších profilů má na odtok převážný vliv pouze srážka, která spadla ten samý měsíc. V případě Dunaje a Rýna má srážka vliv na odtok víceméně stejný v průběhu celého roku, u řeky Umpqua se jedná převážně o zimní období (kdy je na řece srážkový extrém) a u řek na území České republiky je to letní období (kdy dochází také ke srážkovému extrému). Až na řeku Dunaj jde nalézt korelaci mezi odtokem vody z povodí a teplotou v tom samém měsíci v zimních obdobích.

Data každého profilu jsou rozdělena na kalibrační a validační soubor. Validační soubor představuje přibližně 20% dat od konce měření. Kalibrační soubor je 80% zbytku dat. Kalibrační soubor je používán pro kalibraci předpovědního modelu a nalezení kalibračních vzorů, viz 7.1. Validační soubor pro vytváření předpovědi kalibrovaným modelem viz 7.3, ale taky pro ukázku aplikace řízení vodní nádrže použitím předpovědního modelu, viz 7.4. Předpovědní model vytváří předpověď na základě nalezení nejvíce podobného historického případu. V průběhu validace předpovědního modelu jsou nejvíce podobné historické případy hledány v kalibračním souboru dat. Důvody pro volbu velikosti kalibračního/validačního souboru jsou následující:

- V rámci práce je kladen velký důraz na popsání vztahů mezi předpovědním modelem a odtokovými procesy povodí, které jsou nazvány kalibračními vzory. Poznatky popsané v kalibračních vzorech vycházejí z kalibračního souboru dat.
- Předpovědní model vytváří předpověď na základě nalezení nejvíce podobného historického případu a z toho důvodu je vhodné mít historický soubor dat co nejvíce obsáhlý, tj. co největší kalibrační soubor dat.
- I když je zkoumaný jev zatížen značnou náhodností a výsledky může být velmi obtížné interpretovat (ať už se jedná o výsledky kalibrace nebo validace) představuje 20% procentní validační soubor dostatečně reprezentativní vzorek i u profilů s nejkratší časovou řadou zatížené náhodností nejvíce jako je třeba profil Oslavany na řece Oslava.

Předpovědní profily jsou v rámci práce rozlišovány předpovědní profily s *velkým povodí* a *malým povodím* nad předpovědním profilem. Hlavním kritériem tohoto rozlišení je doba dotoku vody povodím, kdy v povodích Dunaje a Rýnu je to více jak jeden měsíc (tyto povodí jsou považována za velká) a v povodích Umpqua, Morava, Jihlava a Oslava je to méně jak jeden měsíc; respektive je to přibližně kolem jednoho týdne (tyto povodí jsou považována jako velká). Jedním z důvodů, proč je toto rozdělení významné, je skutečnost, že u toků s velkým povodím má na odtoku vody z povodí vliv srážka spadlá v předchozím měsíci.

Všechna specifika popisovaná výše pro jednotlivé profily jsou v práci nahrazena jedním zástupným termínem *charakter předpovědního profilu.* Pokud bude níže v práci uveden název řeky, bude tím myšlen předpovědní profil zmíněný výše.

7.2 Kalibrační vzory

Způsob jak volit jednotlivé parametry modelu podobnosti je v kapitole popsán nejprve obecně a následně je uvedena konkrétní volba parametrů v jednotlivých profilech. Soupis obecného popisu volby parametrů představuje kalibrační vzory. Volba parametrů je vysvětlována v pořadí PST, NPHP, W. Stejně tak i volba parametrů na jednotlivých profilech v pořadí Dunaj, Rýn, Umpqua, Morava, Jihlava a Oslava. Při vysvětlování jednotlivých poznatků podle pořadí popsaných v předchozích dvou větách je předpokládáno, že čtenář je již seznámený s fakty popsanými výše.

Interpretace zobrazení mřížky popsaných v kapitole 0 je se zmenšujícím se povodím více nejednoznačná. Proto jsou profily seřazeny sestupně podle velikosti povodí nad profilem, aby byla volba parametrů nejprve vysvětlena na jednoznačnějších (jednodušších) případech.

Díky velikosti povodí řek Dunaj a Rýn je volba parametrů modelu jednotná pro všechny měsíce, v kterých může být předpověď vytvářena; tj. nastavení modelu je velmi jednoduché. Předpovědní profil na řece Umpqua má oproti všem ostatním profilům nejvíce jednoznačné odtokové poměry. Nastavení parametrů už v tomto případě není jednotné (jak u Dunaje nebo Rýna), ale jejich nalezení bylo v tomto profilu nejvíce zřetelné. Odtokové poměry profilů na území České republiky jsou mnohem složitější než u řeky Umpqua. Čím menší profil na území České republiky tím více obtížnější bylo nalezení kalibračních vzorů a volba parametrů. Například u profilu Oslava by bylo velmi obtížné zvolit parametry modelu, pokud by nebyla prozkoumána vazba charakteru profilu a volby parametrů u jiných profilů.

Rozpoznat kalibrační vzory bývá nejednoduší u parametru PST. Značně obtížnější bývá volba parametrů NPHP a W. O volbě parametrů u konkrétních předpovědních profilů je rozhodnuto na

základě zobrazení v přílohách 12.2 až 12.2.6 (jejichž vytváření je popsáno kapitolách 0.) a v textu kapitoly jsou shrnuty pouze výsledné volby parametrů. U některých profilů jdou parametry modelu nastavit několika způsoby. Na základě použitých hodnotících kritérií (KD a zobrazení kontrolního kvadrantu) je obtížné stanovit, která z voleb je nejvhodnější. Na obrázcích kapitoly a také v přílohách 12.2 až 12.2.6 je uvedena pouze jedna volba nastavení modelu a možné variace jsou popsány v textu kapitoly. U většiny nastavení parametrů modelu je popsána jejich vazba na charakter profilu. Vazba nastavení parametrů na charakter profilu však není rozpoznána pro všechny nastavení modelu. V takových případech je pouze uvedeno, jak vychází nejvhodnější nastavení modelu. Je předpokladem, že odpovídající vysvětlení je předmětem budoucího výzkumu.

7.2.1 Volba parametru PST

Parametr PST je volen na základě procesu, který dominantně ovlivňuje odtok vody z povodí. Jednak může mít na výtok vody z povodí dominantní vliv srážka (například v období srážkových extrémů), nebo jej ovlivňovat teplota (třeba v průběhu léta nebo zimy) anebo je odtok vody z povodí utvářen prázdněním akumulované vody v předchozích měsících. Parametr PST je tedy volen pouze na základě charakteristiky odtokových poměrů z povodí. Pro volbu PST platí následující doporučení:

1. Podobnost srážek – parametr PST je volen do oblasti podobnosti srážek v případech kdy srážky spadlé na povodí v okamžik vytváření předpovědi nebo i v bodech před okamžikem předpovědi (u větších povodí, jako je Dunaj a Rýn) tvoří převážnou složku průměrného měsíčního odtoku vody z povodí. Volba parametru PST do oblasti podobnosti srážek je vhodná u povodí s kratší dobou dotoku (tj. přibližně do jednoho týdne, ne další jak jeden měsíc). U těchto povodí povrchový odtok spadlé srážky významně ovlivňuje výsledný odtok vody z povodí. U velkých povodí jako je Rýn a Dunaj má srážka vliv, ale ne dominantní.
2. Podobnost průtoků – parametr PST je volen do oblasti podobnosti průtoků pokud
   2.1. povodí vyprazdňuje zásoby vody akumulované v průběhu zimního období. Toto nastavení modelu je vhodné u povodí s kratší dobou dotoku v průběhu jarních měsíců.
   2.2. na počátku zimního období (měsíce září, říjen, listopad) u profilů na území České republiky je optimální volba parametru PST v oblasti podobnosti průtokových řad.
3. Podobnost teplot
   3.1. pokud jsou teplá léta bez významného ovlivnění odtoku srážkou, je vhodné zvýšit vliv podobnosti teploty na rozhodnutí o nejvíce podobném historickém případu. Tento případ se vyskytuje pouze na řece Umpqua.
   3.2. U profilů na území Evropy je vhodné zvýšit vliv teploty v jarních měsících (jmenovitě březen a duben) z důvodů tání sněhové pokrývky.
   3.3. U profilů na území Evropy je vhodné zvýšit vliv teploty na počátku zimního období (jmenovitě říjen a listopad).

7.2.2 Volba parametru NPHP

Parametr NPHP je volen na základě volby parametru PST a charakteru profilu. Parametr NPHP může být volen také na základě průběhu směrodatné odchylky (nebo aritmetického průměru) průtokové časové řady, vypočtené pro jednotlivé měsíce ze všech historických záznamů. Pro volbu NPHP platí následující doporučení:

1. Pokud je parametr PST zvolen v oblasti podobnosti srážek, je volba parametru doporučena NPHP v rozmezí 6 až 15. Čím větší mají spadlé srážky vliv na výsledný odtok vody z povodí, tím vyšší je vhodné parametr NPHP volit.
2. Pokud je parametr PST zvolen v oblasti podobnosti průtoků, je volba parametru NPHP doporučena v rozmezí 2 až 4.
3. V měsících září, říjen, listopad v profilech Morava, Jihlava, Oslava jsou voleny NPHP v rozmezí 2 až 4.
4. U profilů s velmi malou dobou dotoku, u kterých představují po většinu roku srážky dominantní proces určující odtok vody z povodí, tj. Jihlava a Oslava, jsou voleny nízké hodnoty NPHP v jarních měsících v kterých je parametr PST nastaven na podobnost srážek.

Zvyšování parametru NPHP má podstatný vliv na změnu vzhledů kontrolních kvadrantů. Pří nízkých NPHP mají kontrolní kvadranty tvar kruhu okolo srovnávací přímky při vysokých NPHP mají naopak tvar vodorovné přímky, která se velmi přibližuje přímce představující aritmetický průměr. Pokud parametr NPHP nabývá hodnot 1 až 3 může model správně předpovědět vyšší hodnoty průtoku (extrémní průtoky)[6]. Naopak se modelu při nízkých NPHP nedaří předpovědět průtoky, které nastávají s větší četností. Čím více je zvyšován parametr NPHP, tím více se daří předpovědět průtoky, které nastávají s větší četností, avšak tím více klesá možnost modelu předpovědět vysoké průtoky. S dalším zvedáním NPHP klesá schopnost modelu předpovědět nízké průtoky a následně se body kontrolního kvadrantu přiblíží přímce představující aritmetický průměr, viz Obr. 27.

Protože přesnost modelu byla hodnocena pouze KD a zobrazením kontrolních kvadrantů je velmi obtížné rozhodnout nad volbou pouze jedné optimální hodnoty parametru NPHP. Nízká nebo vysoká hodnota má své pro i proti. Pro budoucí aplikaci modelu pro řízení vodní nádrže by bylo vhodné vyzkoušet vydávat jednu předpovědi pro nízkou hodnotu NPHP a druhou pro vysokou NPHP a testovat jejich výhody a nevýhody pro provoz nádrže.

Pokud je parametr PST volen do oblasti srážek, je vytvářená předpověď dosti náhodná. Je to pravděpodobně spjaté ze skutečností, že hodnota průměrné měsíční srážky, která v povodí nastane, je značně náhodný proces. Pokud jsou voleny vyšší hodnoty NPHP (tj. 6 až 15), dojde k většímu průměrování vytvořených předpovědí (které jsou spíše náhodné, pokud je PST na podobnosti srážek) díky kterému vycházejí lepší hodnoty KD a také tvaru kontrolních kvadrantů. Pokud model v jarních obdobích (kdy dochází k výtoku zásob vody z povodí) vytváří předpovědi porovnáváním průtokových řad je volena pouze malá hodnota NPHP (tj. od 2 do 4). Průtokové řady jsou při výtoku vody z povodí velmi setrvačné a mohou si být velmi podobné. Proto není potřeba předpověď průměrovat vysokým NPHP, ale spíše najít pouze pár nejvíce podobných případů. Volba parametru váhy doplňuje principy popsané výše a jeho volba bude vysvětlena v kapitole 7.2.3. Skutečnosti popsané výše v tomto odstavci se mohou měnit pro velmi malé povodí jako je Jihlava a Oslava, kde vychází malé hodnoty NPHP pro PST v oblasti podobnosti srážek, více viz vysvětlení v kapitole 7.2.8 a 7.2.9. Avšak protože jsou povodí Jihlava a Oslava zatíženy obrovskou neurčitostí, není možné rozlišit, jestli ke spekulacím vede náhoda a je nutné poznatky ověřit na více profilech.

[6] Pokud je přesnost modelu hodnocena koeficientem determinace, mají extrémní hodnoty velmi podstatný vliv na hodnotu koeficientu determinace. Například pokud model správně předpoví jednu vysokou hodnotu průtoku, vyjde koeficient determinace velmi dobře, i když jsou průtoky s větší frekvencí výskytu předpovězeny nepřesně.

S principy vysvětlenými v předchozím odstavci úzce souvisí také hodnota směrodatné odchylky (aritmetického průměru) průtokové časové řady. Pokud je odtok z povodí určován srážkou spadlou na povodí, je i směrodatná odchylka průtokové řady větší. Naopak pokud je odtok vody z povodí určován výtokem prázdněním akumulované vody v zimním období, je i směrodatná odchylka průtokové řady menší. Proto může být parametr NPHP volen také na základě průběhu směrodatné odchylky (nebo aritmetického průměru) průtokové časové řady, vypočtené pro jednotlivé měsíce ze všech historických záznamů.

S ohledem na principy volby parametru NPHP popsané v předchozích odstavcích je pravděpodobnější, že volba parametru NPHP závisí pouze na směrodatné odchylce. Avšak u profilů s velmi malým povodím tj. (Morava, Jihlava a Oslava) se vyskytují takové extrémní průtoky, které v kombinaci s krátkou časovou řadou způsobují, že směrodatné odchylka neposkytuje reprezentativní hodnoty. U všech zkoumaných profilů jde pozorovat, že s růstem směrodatné odchylky se zvětšuje i aritmetický průměr (a taky naopak). Proto může být parametr NPHP volen také na základě aritmetického průměru.

Parametr NPHP jde volit na základě volby PST a směrodatné odchylky. Mohou nastat případy, kdy volba PST a směrodatná odchylka indikují tutéž volbu NPHP (například v případě hledání parametru u profilu na řece Umpqua). Nebo mohou nastat případy, kdy volba PST a směrodatná odchylka indikují rozdílnou volbu NPHP (což se stává na území České republiky díky složitějším odtokovým poměrům). V těchto případech je parametr NPHP volen prioritně na základě volby parametru PST a následného pozorování vývoje kontrolních kvadrantů. K průběhu směrodatných odchylek může být přihlédnuto, anebo mohou být zcela vypuštěny. Volba parametru NPHP na základě směrodatné odchylky je vhodná k rozpoznání průběhu (tvaru) hodnot parametru v sekvenci jednotlivých měsíců. Nevypoví však o tom jak vysoké mají být voleny hodnoty parametru NPHP (pokud by byli kalibrační vzory odvozovány z více profilů, bylo by to pravděpodobně možné). Proto je nezbytné pro kalibraci modelu v předpovědním nejprve vytvořit pozorování vývoje kontrolních kvadrantů a při volbě parametrů přihlédnout k průběhu směrodatné odchylky. Závislost parametru NPHP na směrodatné odchylce byla jasně rozpoznána na profilu Umpqua na základě určení parametru na základě PST a následného pozorování vývoje kontrolních kvadrantů. U profilů Morava, Jihlava a Oslava byl tento poznatek pouze využíván k potvrzení průběhu (tvaru) parametru NPHP v jednotlivých měsících.

7.2.3 Volba parametru W

Parametr je volen na základě volby parametru PST, NPHP a charakteru profilu podle následujících doporučení:

1. Pokud je PST zvolen v oblasti podobnosti srážek a je zvolena vyšší hodnota NPHP je voleno velmi krátké porovnávané období. Verze vah je většinou přibližně 3 anebo taková, která nevyužívá více jak dva body v porovnávané oblasti.
2. Pokud je PST zvolen v oblasti podobnosti průtoků a je zvolena nižší hodnota NPHP je voleno delší porovnávané období. Číslo verze vah se liší podle profilu, ale porovnávané období může obsahovat dva až šest bodů.
3. V měsících září, říjen, listopad v profilech Morava, Jihlava, Oslava je voleno velmi krátké porovnávané období, ve všech případech je volena verze vah 3.
4. U profilů s velmi malou dobou dotoku, u kterých představují po většinu roku srážky dominantní proces určující odtok vody z povodí, tj. Jihlava a Oslava, mají v jarních měsících zvoleny PST v

oblasti podobnosti srážek a nízké hodnoty NPHP využívají krátké porovnávané období (tj. verze vah je u nich nastavena na 3). Jak bylo popsáno výše, není zcela jasné, jestli je toto pravidlo vzniklo na základě náhody a je potřeba ověřit větším testováním.

Ve většině případů se zvýšením parametru NPHP zkracuje porovnávané období (zmenšuje se verze vah). Pokud model podobnosti vytváří předpověď při nízkém NPHP využívá delší porovnávané období. Čím větší je parametr NPHP, tím kratší porovnávané období model využívá. Pokud je parametr NPHP okolo 8 a výše je ve většině případů využívána verze vah 1 až 3.

Při nízkém NPHP model usiluje o „přesné trefení“ předpovídané hodnoty. Zvyšováním parametru NPHP jsou předpovědi vytvářeny více náhodně a model vytváří předpověď na základě toho, kam může hodnota utéct.

7.2.4 Dunaj

Dunaj je řekou s největším povodím a body průtokové časové řady významnou vzájemnou setrvačnost. Odtok vody z povodí je sice složen ze spousty faktorů odehrávajících se v povodí, avšak při měsíčním časovém kroku v kombinaci s tak rozsáhlým povodím se rozdílné vlivy na odtok vody z povodí v uzávěrkovém profilu neprojevují a průtoková časová řada je velmi setrvačná. Proto předpovědi vytvářené v tomto profilu dosahují nevyššího KD (ať už modelem podobnosti nebo jakýmkoliv jiným). Jedná se o jediný ze zkoumaných profilů, kde průměrná měsíční srážka spadlá na plochu povodí určitém měsíci, má prokazatelný významný vliv na velikost odtoku v dalším měsíci.

Průběh aritmetického průměru průtokové řady přes jednotlivé měsíce je velmi plynulý. Průběh směrodatné odchylky průtokové řady přes jednotlivé měsíce se mění pouze velmi málo a je téměř konstantní. Všechny procesy ovlivňující odtok v povodí nad zkoumaným profilem se projevují v uzávěrkovém profilu plynule a pravidelně.

Volba parametrů PST je zobrazena na Obr. 40. PST je volen jednotně pro všechny měsíce. Parametr PST je stanoven tak, že na vytvoření nejlepší předpovědi má stejný význam porovnání podobnosti srážkových i průtokových časových řad. Podobnost teplotních řad na vytvoření dobré předpovědi má vliv pouze v březnu (respektive při předpovědi na měsíc duben, protože březen je okamžikem vytváření předpovědi).

Na Obr. 41 jde vidět podklad k rozvaze o volbě parametru NPHP pro profil Dunaj. Světle oranžově je zobrazeno rozmezí, v kterém by mohlo být vhodné zvolit parametr NPHP. Tmavě oranžově je vybrána hodnota parametru NPHP, které se zdá nejvíce vhodná. Červená linka představuje finální volbu parametru pro model podobnosti, která je podobně jako parametr PST stejná pro všechny měsíce a to NPHP = 4. V případě parametru NPHP jde pozorovat určitou vazbu na charakter profilu, tj. závislost na směrodatné odchylce (nebo aritmetickém průměru). Náhodná změna parametru je stejně velká jako možné změny parametru díky vazbě na směrodatnou odchylku a proto nejde rozhodnout o závislosti parametru NPHP na směrodatné odchylce. S ohledem také na skutečnost, že parametr PST je volen jednotně, je zvolena i jednotná volba parametru NPHP.

Parametr W byl také zvolen jednotný pro všechny měsíce a to W = 3. Díky velké setrvačnosti nevyužívá model příliš dlouhé porovnávané období.

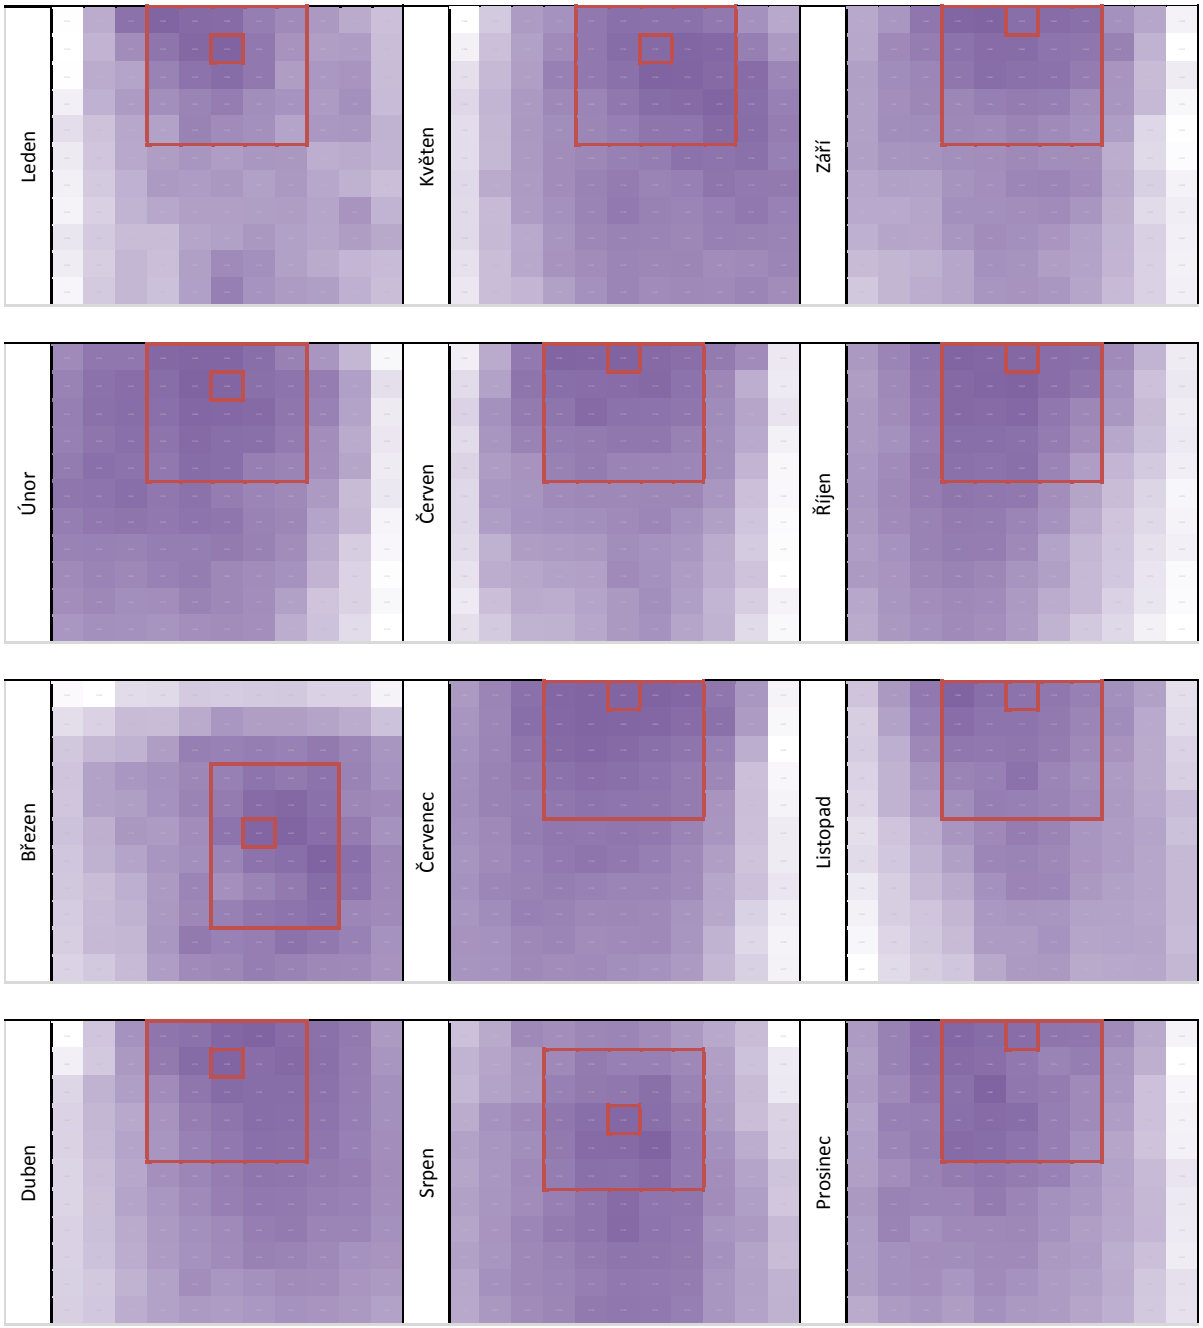

Obr. 40 – Volba parametru PST v profilu Dunaj

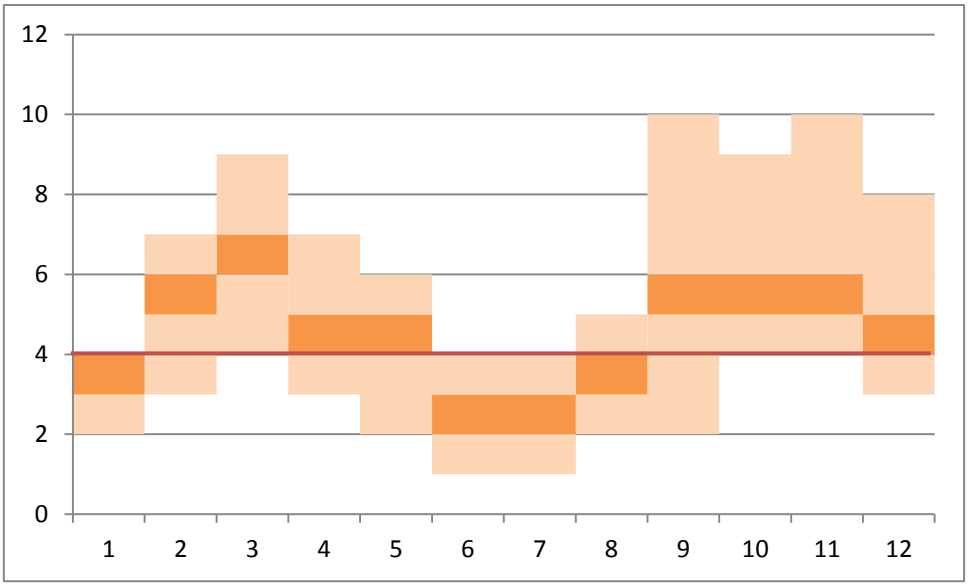

Obr. 41 - Volba parametru NPHP v profilu Dunaj

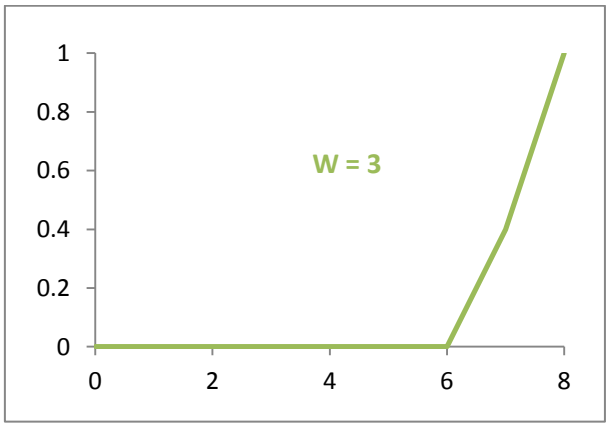

Obr. 42 - Volba parametru W v profilu Dunaj

7.2.5 Rýn

Rýn je řeknou s čtvrtinovou velikostí povodí oproti Dunaji. I přes to jsou průtokové časové řady velmi setrvačné. Volba parametrů v tomto profilu sice není jednotná pro všechny měsíce jako tomu je u Dunaje, ale k jednotné volbě má velmi blízko.

Povodí Rýnu podobně jako povodí Dunaje významně tlumí rozkolísanost počasí nad povodím. Oproti Dunaji je však po většinu roku skoro stejný aritmetický průměr průtokové řady, ale směrodatná odchylka větší v zimních měsících.

Volba parametrů PST je zobrazena na Obr. 43. Až na měsíc únor je předpověď tvořena určitou kombinací mezi podobností srážkových a průtokových řad. Teplota má vliv na vytvoření předpovědi v měsíci únor, březen a listopad. Podobně jako u Dunaje je výsledný odtok z povodí složen ze spousty faktorů (složité odtokové poměry). Protože povodí není tak velké jako Dunaj, projevují se tyto různé složky odtoku z povodí na volbu parametrů PST tak, že není zcela jednotná pro všechny měsíce. Na druhou stranu povodí Rýna není až tak malé, aby bylo možné u něj zvolit parametry PST pouze na základě nalezení závislosti k odtokovým poměrům. Proto u tohoto profilu není zkoumáno, jaká je vazba parametrů PST na odtokové poměry v povodí, pouze je akceptováno, že u některých měsíců

ohrady PST prostě takto vycházejí. U většiny měsíců vychází volba PST na polovinu vlivu srážky a průtoku (podobně jako u Dunaje).

Podobně jako u Dunaje, balancuje volba parametru NPHP mezi jednotnou volbou pro všechny měsíce a nalezení závislosti na směrodatné odchylce (respektive na aritmetickém průměru). Oproti Dunaji byla v tomto případě zvolena závislost na směrodatné odchylce. Na Obr. 44 jde vidět volba parametru PST pro jednotlivé měsíce. Červenou tečkovanou čarou je v obrázku vyznačen aritmetický průměr, oranžovou směrodatná odchylka. Hodnoty směrodatné odchylky a aritmetického průměru jsou v grafu vyznačeny pro měsíc, na který je předpověď vydávána, tj. pokud je v grafu vyznačena volba NPHP = 4 v měsíci leden ovlivňuje tento parametr předpověď na měsíc únor. Hodnota směrodatné odchylky a aritmetického průměru ve sloupci jedna je hodnota vypočtená v měsíci únoru. Změna parametru NPHP v různých měsících je velmi malá a je velmi pravděpodobné, že zavilost NPHP na směrodatné odchylce je náhodou.

Parametr W je zvolen pro měsíce duben až listopad W = 3, v měsících prosinec až březen je zvolen W = 10. Podobně jako u parametru PST nebyla vazba na charakter profilu popřípadě na další parametry zkoumána.

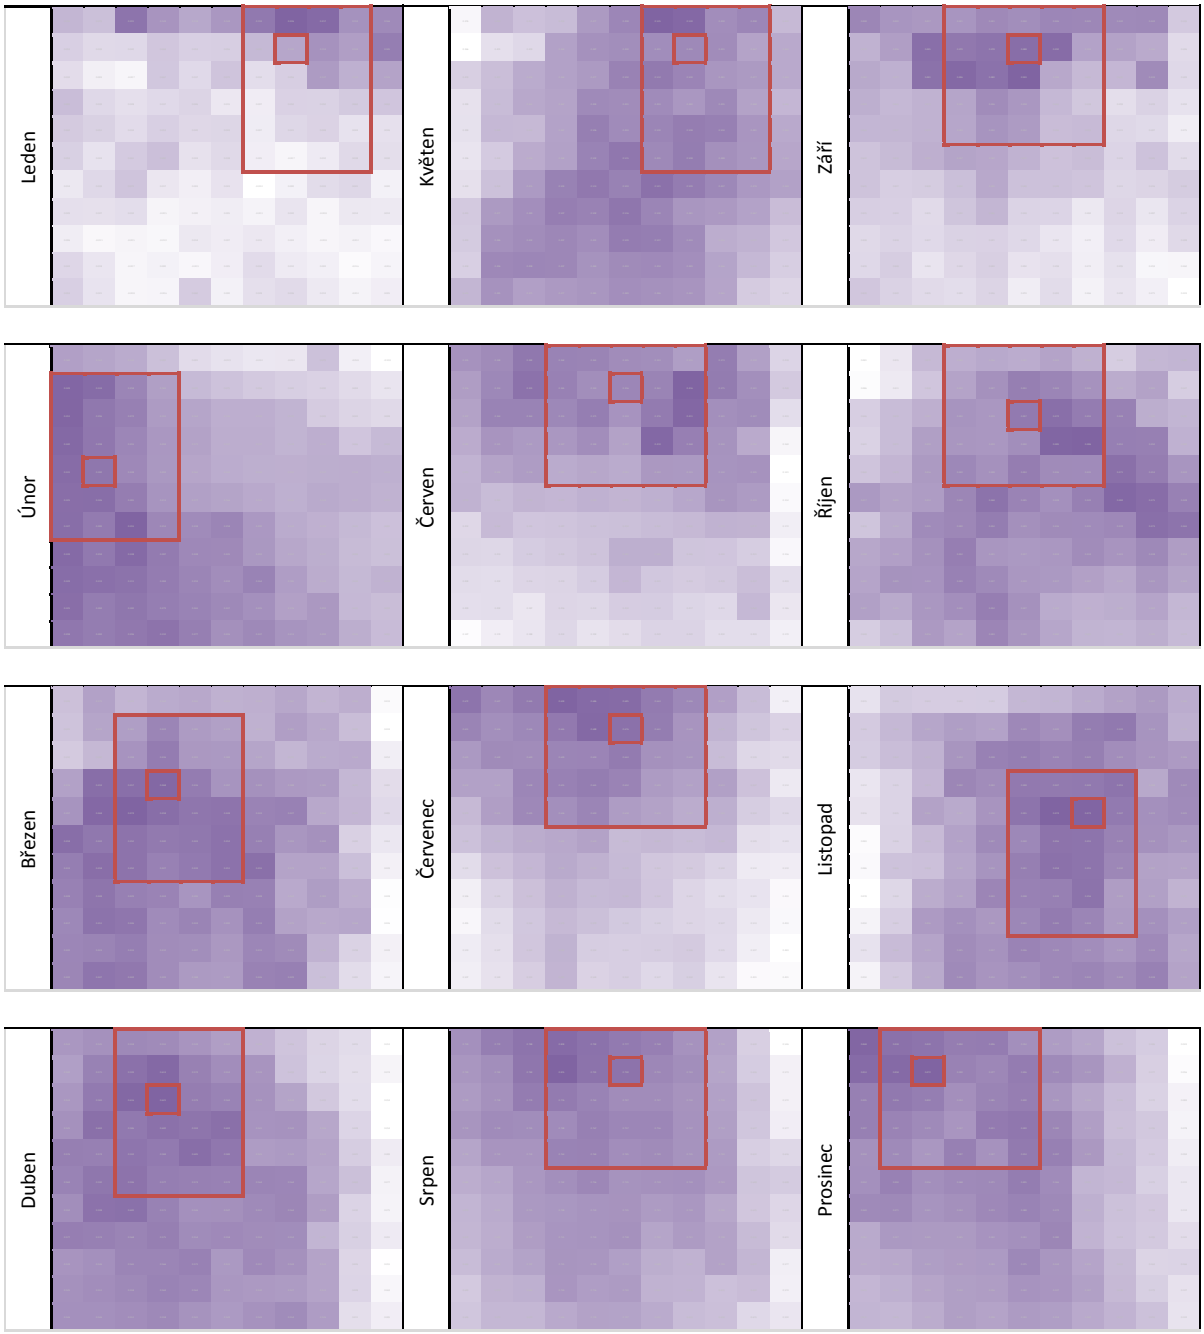

Obr. 43 - Volba parametru PST v profilu Rýn

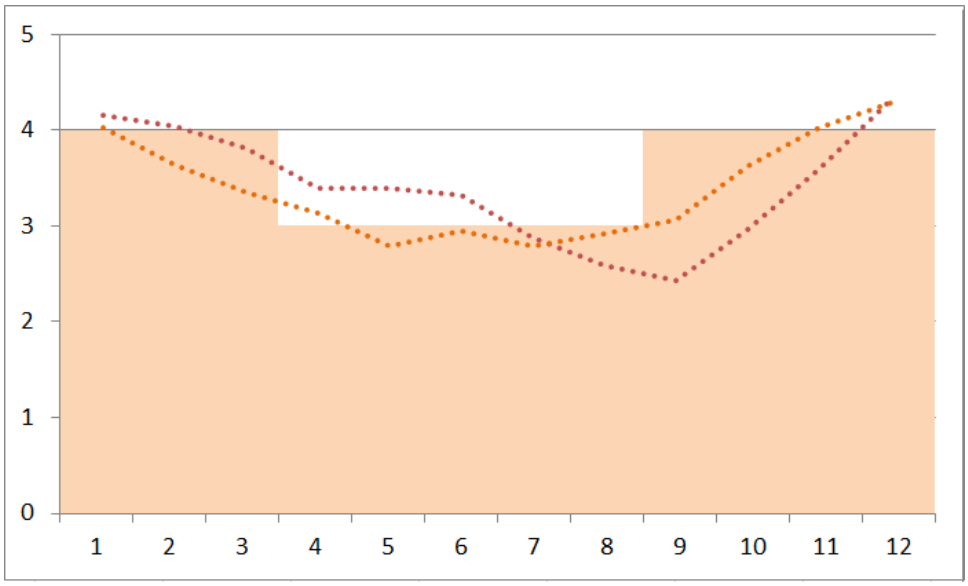

Obr. 44 - Volba parametru NPHP v profilu Rýn

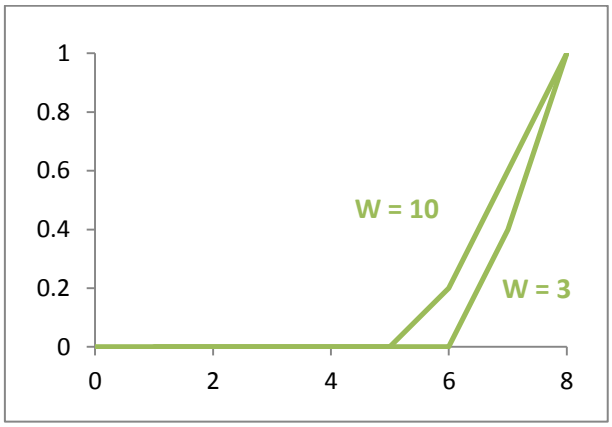

Obr. 45 - Volba parametru W v profilu Rýn

7.2.6 Umpqua

Umpqua je řeknou s nejjednoznačnějšími odtokovými poměry. Odtok z povodí je v různých fázích ročního období určován vždy pouze jedním dominantním procesem odehrávajícím se v povodí, tj. například, že jsou v zimním období deště, které jsou naprosto dominantní proces ovlivňující průtok v závěrovém profilu. Díky této skutečnosti je nalezení kalibračních vzorů značně jednodušší oproti profilům Morava, Jihlava, Oslava.

V zimním období nastává v povodí srážkové maximum, které způsobuje zvýšený odtok z povodí (a také rozkolísanost odtoku). S přibývajícím létem dochází ke snižování výskytu srážek, které v průběhu července a srpna dosáhnou svého minima (v těchto dvou měsících je dokonce několik výskytů nulových srážkových úhrnů). Čím více klesá intenzita srážek, tím více je odtok z povodí utvářen prázdněním zásob akumulovaných v průběhu zimy. Odtok z povodí dosáhne svého minima v měsících srpen a září. Od měsíce září dochází ke zvyšování srážek a povodí je znovu naplňováno. Průměrná teplota v povodí neklesá pod nulu. Teplotní maximum je červnu a srpnu zároveň s průtokovým a srážkovým minimem. Zobrazení všech realizací historických měření jsou v příloze 12.2.3.

Parametr PST je volen na základě toho, co ovlivňuje odtokové poměry v povodí, viz Obr. 46. Protože v zimním období určuje odtok vody z povodí množství spadlých srážek, je parametr PST zvolen oblasti

podobnosti srážek (tj. že o nalezení nejvíce podobného historického případu rozhoduje podobnost srážkových řad). V průběhu března dochází k přechodu mezi podobnosti srážek a průtoků. Od dubna až do srpna je předpověď vytvořena na základě podobnosti průtokových řad. Od září začíná určovat velikost odtoku z povodí srážka, a proto je parametr PST volen v oblasti podobnosti srážek. Teplota má na vytvoření předpovědi význam od ledna do až do července. V zimním období určuje teplota pravděpodobně akumulaci nebo uvolnění srážek ve sněhové pokrývce. Pouze řeka Umpqua využívá k vytvoření předpovědi podobnost teplotních řad v letních měsících, v průběhu kterých ovlivňuje množství odtoku vody z povodí velikost výparu.

Parametr NPHP je volen na základě volby parametru PST a průběhu směrodatné odchylky (aritmetického průměru). Protože je v zimním období velikost odtoku určována srážkou, dochází k odhadu průtoku velmi chaoticky (tvar kontrolního kvadrantu je většinou kruh). K přesnějším odhadům průtoků dochází až při vyšších NPHP (až jsou předpovědi více průměrovány). S tím jak klesá vliv srážky na vytvoření předpovědi, klesá i velikost NPHP a v letním období stačí zprůměrovat pouze dvě podobné historické řady. S narůstajícími srážkami od měsíce září narůstá požadavek na zvýšení NPHP.

Parametr W je volen s ohledem na volbu předchozích parametrů a taky charakteru předpovědního profilu. Pokud je v zimním období vytvářena předpověď na základě podobnosti srážek, je potom volena vysoká hodnota NPHP. Oproti letnímu období dochází k určitému generování více předpovědí, které jsou potom zprůměrovány. Z toho důvodu je parametr W volen tak, že porovnávané období je velmi krátké. S přibývajícím létem dochází k postupnému protahování porovnávané oblasti a v měsících červen až srpen využívá model až pět bodů s porovnávané oblasti. Změna nastává až v měsíci září, kdy se hodnota vah vrací k nízkým hodnotám W. Za úvahu stojí skutečnost, jestli by návrat ke kratšímu porovnávanému období neměl být více plynulý, jako volba ostatních parametrů. U předpovědí, které jsou vytvářeny v měsíci září a říjen, hraje hlavní význam, jestli nastane období dešťů. Z perspektivy modelu podobnosti je příchod srážky v měsíci, na který je předpověď vytvářena, zcela náhodná skutečnost. I když model při vytváření kalibračních vzorů disponuje s hodnotami, které má předpovědět, není v jeho možnostech vytvořit v těchto měsících lepší předpověď než KD = cca 0. Jedinou možností modelu jak odhadnout správnou hodnotu je co nejvíce průměrovat k čemuž využívá velmi krátké porovnávané období.

Pouze řeka Umpqua má tak jednoznačnou závislost mezi volbou parametrů modelu podobnosti a charakterem profilu. U dalších profilů (Morava, Jihlava a Oslava) jsou odtokové poměry složitější. K rozpoznání kalibračních vzorů u dalších profilů značně přispělo rozpoznání kalibračních vzorů na řece Umpqua.

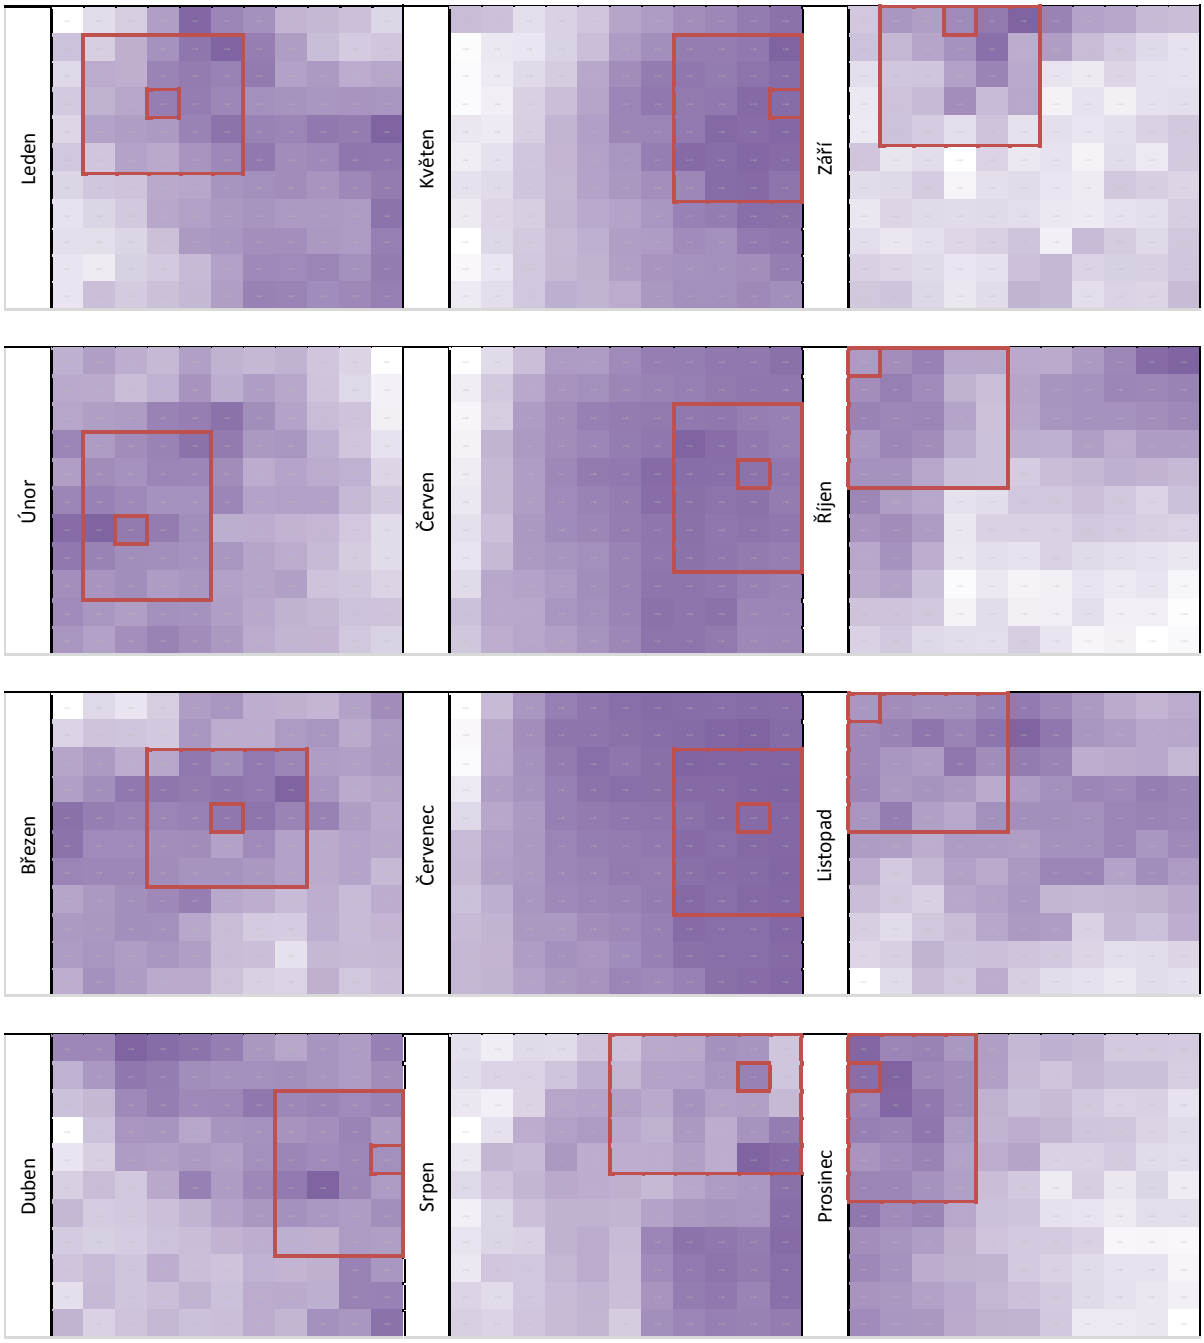

Obr. 46 - Volba parametru PST v profilu Umpqua

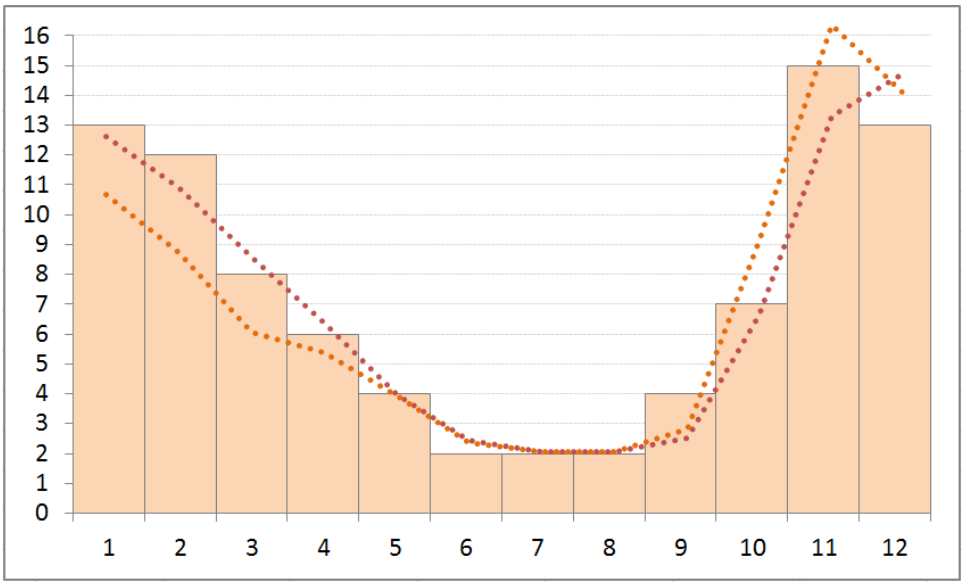

Obr. 47 - Volba parametru NPHP v profilu Umpqua

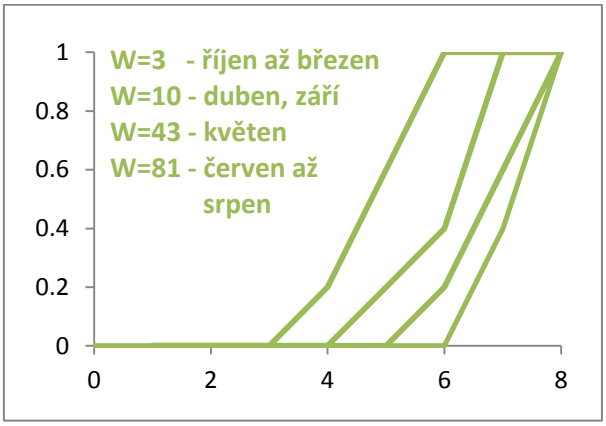

Obr. 48 - Volba parametru W v profilu Umpqua

7.2.7 Morava

Předpovědní profil na řece Morava je povodím s největší plochou na území České republiky. Jednoznačnost odtokových poměrů a určení kalibračních vzorů je mnohem jednodušší oproti profilům Jihlava a Oslava, avšak značně komplikovanější oproti řece Umpqua. Všechny řeky ležící na území České republiky mají velmi podobné odtokové poměry a také nastavení parametrů modelu.

Průtokové maximum, které nastává na řece Morava v měsících březen a duben, je způsobeno táním sněhové pokrývky akumulované ze srážek spadlých na povodí v průběhu zimního období. V průběhu měsíců květen až září dochází k prázdnění zásob vody v povodí akumulovaných v průběhu zimního období. Aritmetický průměr průtoku v průběhu těchto měsíců klesá. Od měsíce září začíná průměrný průtok stoupat a zásoby vody v povodí se začínají znovu akumulovat. Srážkové maximum je v průběhu letního období od měsíce květen do měsíce srpen. Průměrná teplota klesá v průběhu zimy pod nulu stupňů celsia a teplotní maximum je dosaženo v červenci. Realizace všech historických měření jsou zobrazeny v příloze 12.2.4.

Oproti doposud uvedeným profilům je v případě profilu Morava (a také dalších profilů na území ČR) výrazně kratší doba dotoku vody v povodí. Proto může na výsledný odtok v povodí mít dominantní vliv srážka, která spadla na povodí v okamžik vytváření předpovědi, popřípadě v měsíci před

okamžikem předpovědi. Tato skutečnost významně ubírá na setrvačnosti průtokovým řadám a tím pádem i na jejich předpověditelnosti. Přístup k nastavení modelu podobnosti u profilů na území České republiky se oproti výše zmíněným profilům mění tak, že u většiny měsíců je předpověď vytvářena porovnáváním klimatických scénářů (respektive porovnáváním srážek) a pouze v některých měsících předpovídáno pomocí podobnosti průtokových řad. Další skutečnost odlišná oproti doposud uvedeným profilům je, že v případě profilu Morava (a také v dalších profilů na území ČR) pozorované výsledky indikují, že parametry modelu podobnosti jdou nastavit dvojím způsobem. I když v případě tohoto profilu bylo zvoleno jedno z nastavení, nejde v rámci používaných kritérií k hodnocení přesnosti předpovědi (KD a zobrazení kontrolního kvadrantu) zcela jasně vyloučit nebo potvrdit, které z nastavení je nejvhodnější.

V měsících duben až srpen jde nastavit parametr PST buď do oblasti vlivu srážek nebo průtoků. Volbu podobnosti srážek ovlivňuje skutečnost, že ve zmíněných měsících dochází ke srážkovému extrému a navíc odtok v takto malém povodí může být velmi významně určen spadlou srážkou. Naopak k volbě podobnosti průtokových řad vede fakt, že povodí vyprazdňuje akumulované zásoby vody po zimním období a odtok jde dobře modelovat podobností průtokových řad. Na základě volby parametru PST závisí potom i volba parametrů NPHP a W. Pokud je parametr PST volen v oblasti srážek je NPHP vysoký a W nízký, pokud je PST volen v oblasti průtoků je NPHP nízký a W vysoký.

V případě volby parametru PST je v průběhu měsíců prosinec až březen předpověď vytvářena na základě podobnosti srážkových časových řad. V měsících duben až červen dochází k prázdnění zásob vody akumulovaných v povodí a proto je parametr volen v oblasti podobnosti průtokových řad. Od května začíná také zároveň srážkové maximum, které trvá až do srpna. Velikost srážek má podstatný vliv na odtok vody z povodí, avšak v průběhu dubna a až června představuje výtok vody z povodí podstatnější složku odtoku (a tím pádem i předpovědi). V měsících červenec a srpen pořád dochází k prázdnění povodí, ale srážka spadlá na povodí začne tvořit podstatnější složku odtoku vody z povodí a proto PST parametr zvolen v oblasti podobnosti srážek. V průběhu měsíců duben až srpen by bylo možné zvolit parametry v oblasti podobnosti srážek nebo i průtoků protože výsledný odtok je tvořen výtokem akumulované vody z povodí a zároveň srážkovým extrémem. To, v kterých měsících převažuje jeden z procesů, je subjektivní volba řešitele a není nikde stanoveno, že je to ta nejoptimálnější; respektive nejlepší nastavení pro aplikaci modelu na provoz nádrže. Podobně jako v předchozích měsících by šlo v září zvolit PST na podobnost srážek nebo průtoků, ale parametr jde zvolit i doprostřed mapy PST, protože mezi měsícem srpen a říjen přechází parametr PST od podobností srážek k podobnosti průtokových řad. V měsících říjen a listopad je vytvářena nejvhodnější předpověď na základě podobnosti průtokových řad. Teplota má vliv na předpověď v měsíci březnu, říjnu i listopadu. I když je zvýšený vliv teploty i měsících květen a červen je velmi pravděpodobné, že se jedná o náhodu.

V měsících prosinec až březen je parametr PST v oblasti podobnosti srážek a z toho důvodu je voleno vyšší NPHP a to mezi 5 až 7. Parametr NPHP není tak vysoký jako v zimních měsících u řeky Umpqua nebo v měsících červenec a srpen u řeky Morava. I když v měsících prosinec až březen u Moravy dominuje odtoku z povodí srážka, není to jediný a určující složka odtoku z povodí jako je tomu u profilu Umpqua v zimě a u Moravy v létě, která by způsobovala významnou rozkolísanost v předpovědích, a která je potřeba průměrovat vyšším NPHP. V měsících duben až červen je zvoleno NPHP mezi tři a čtyři, protože je PST v oblasti podobnosti průtokových řad. Parametr NPHP by šel zvolit i 2, ale oproti profilu Umpqua jsou odhady průtoků mnohem více náhodné a proto je vhodnější

pomocí většího průměrování zmenšit nepřesné odhady průtoku. V měsících červenec a srpen je zvolen parametr NPHP = 10, protože má určující vliv na odtok vody z povodí srážka. V měsících srpen až listopad je volen NPHP = 3 protože PST je v oblasti podobnosti srážek.

Parametr NPHP jde zvolit na základě předchozí volby parametru PST nebo na základě směrodatné odchylky (nebo aritmetického průměru). Tyto dvě kritéria se u profilu Umpqua dobře doplnila, tj. že ke stejné volbě parametrů NPHP jde dojít na základě parametru PST nebo směrodatné odchylky. V případě profilů na území České republiky si díky složitějším odtokovým poměrům tyto kritéria mohou odporovat. V tom případě je dávána přednost volbě NPHP na základě volby parametru PST. V profilu Morava jde vidět, že parametr NPHP opisuje aritmetický průměr, až na měsíce červenec a srpen kdy nad volbou parametru NPHP převládne volba parametru PST. Opis volby parametru NPHP aritmetickým průměrem není již tak přesný jako u profilu Umpqua. Je způsobeno skutečností, že interpretace zobrazení mřížky výsledků již není tak jednoznačná jako u Umpqua a proto je rozhodnuto volit parametry NPHP robustněji, tj. stejné pro určité oblasti než plynule proměnné pro každý měsíc. Navíc u řeky Umpqua byli na základě zobrazení kontrolního kvadrantu zvoleny parametry NPHP a následně bylo shledáno, že přesně kopírují aritmetický průměr respektive směrodatnou odchylku. U řeky Morava je tento poznatek již využíván, a pokud není zcela jisté na základě zobrazení kontrolních kvadrantů jakou hodnotu NPHP zvolit je přihlédnuto k průběhu aritmetického průměru. Směrodatná odchylka je u profilu Morava již významně zatížena chybou od extrémních průtoků, a proto je vhodnější porovnávat volbu parametru NPHP k aritmetickému průměru.

Parametr W je volen s ohledem na volbu předchozích parametrů. V měsících prosinec až březen a červenec a srpen je volena nízká verze vah respektive porovnávané období. V období duben až červen je voleno delší porovnávané období. V měsících září až listopad je voleno krátké porovnávané období, což je opak oproti výtokové větvi z povodí, kde je voleno delší porovnávané období.

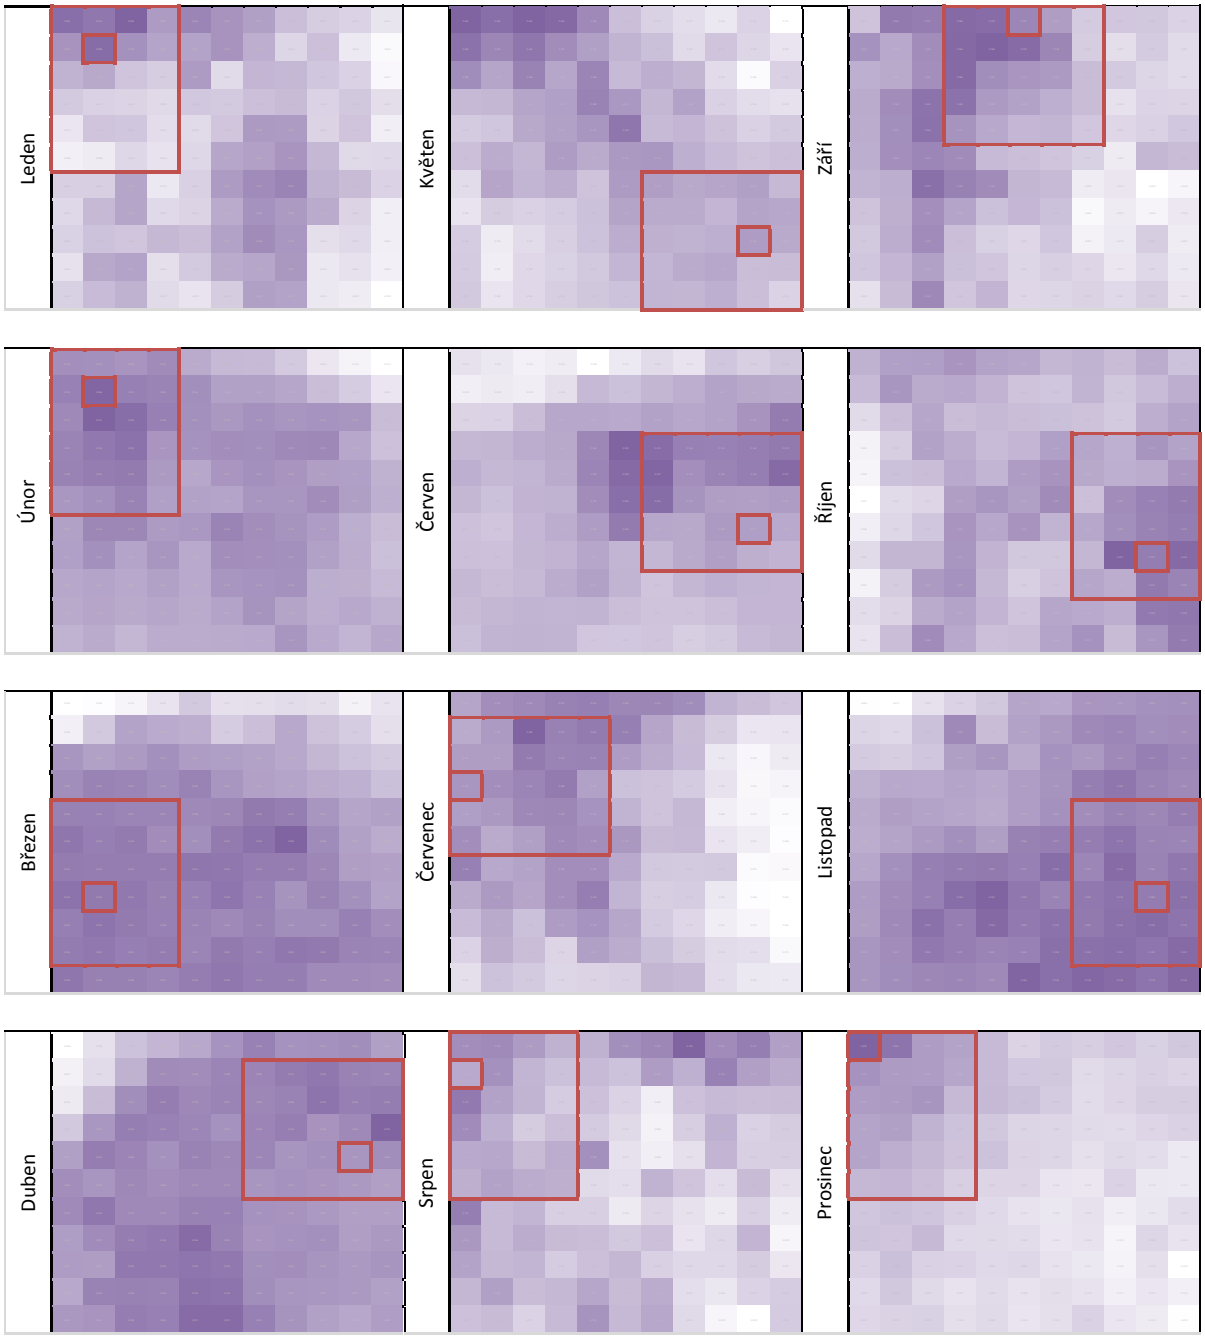

Obr. 49 - Volba parametru PST v profilu Morava

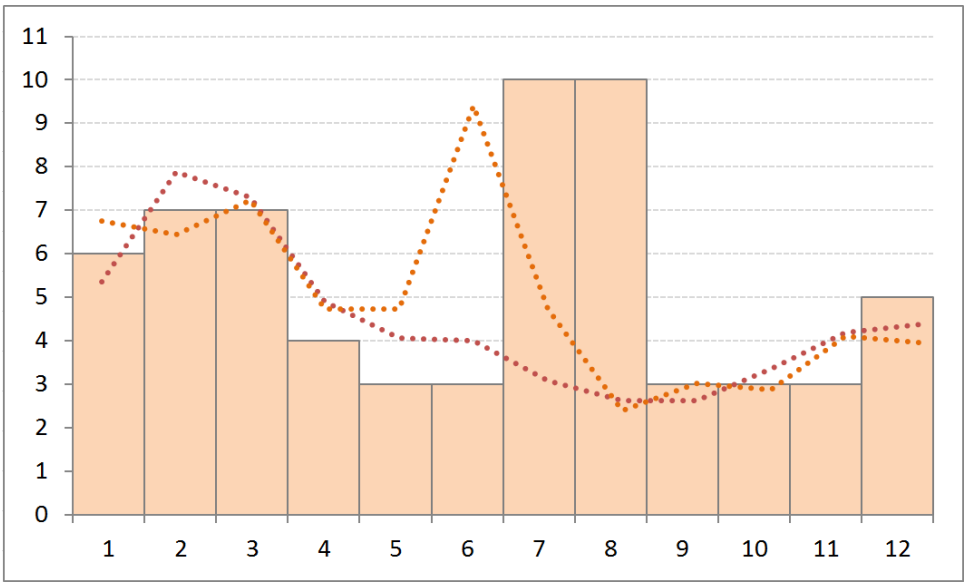

Obr. 50 - Volba parametru NPHP v profilu Morava

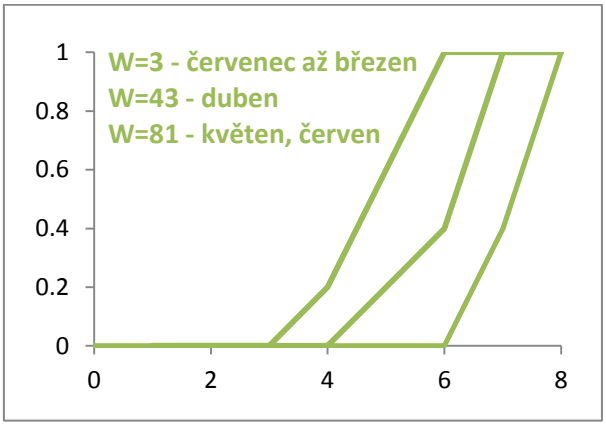

Obr. 51 - Volba parametru W v profilu Morava

7.2.8 Jihlava

Jihlava je profilem s druhým největším povodím ze zkoumaných profilů na území České republiky. Procesy ovlivňující výtok vody z povodí jsou velmi podobné procesům u řeky Moravy. Identifikace kalibračních vzorů je obtížnější jak u Moravy, ale není tak obtížná jako u Oslavy.

Oproti Moravě je u profilu Jihlava volen v měsících březen až červen parametr PST do oblasti podobnosti srážek. Vliv výtoku vody z povodí představuje u tohoto profilu významnou složku odtoku, avšak lepší výsledky předpovědí vycházeli v případě, pokud jsou porovnávané srážkové případy. U měsíce června vycházeli nejvyšší koeficienty determinace spíše v oblasti podobnosti průtoků. Protože se však v případě června jedná pouze o jeden měsíc v sekvenci jarních měsíců s vlivem PST na srážkách, byl červenec parametr PST volen také do oblasti podobnosti srážek. Oproti Moravě dochází na konci léta k přechodu parametru PST k podobnosti průtokových řad již v měsíci srpnu a v září již leží PST v oblasti podobnosti průtoků.

Parametr NPHP je volen podobně jako u řeky Morava. Oproti Moravě jde vidět, že parametr NPHP již skoro vůbec nekopíruje průběh směrodatné odchylky. Směrodatná odchylka je tak zatížena chybou, že je vhodnější kopírovat průběh aritmetického průběhu. Další odlišnost volby parametru NPHP oproti profilu Morava je jeho nízká volba v měsících březen až červen. U profilů Umpqua a Morava

vycházeli dobré předpovědi pro volbu vysoké hodnoty parametru NPHP v případech, kdy je podobnost PST v oblasti srážek (jinak řečeno nejednoznačnost srážek je průměrována vysokým NPHP). V případě profilu Jihlava (a také Oslava) vycházejí nejvíce přesné předpovědi v jarních měsících (březen až červen), pokud je parametr NPHP nízký a parametr PST v oblasti srážek. Díky významné nejednoznačnosti interpretace výsledků je obtížné rozhodnout, jestli se jedná o náhodu nebo o jedno z dalších pravidel volby parametrů modelu, které je v rozporu s doposud rozpoznanými procesy. Rozhodnutí je otázkou ověření na více profilech s podobnými odtokovými profily.

Skutečnost vysvětlená v předchozím odstavci ovlivňuje i volbu parametru W. V měsících březen až červen vychází volba W velmi nízká. Protože nastavení parametru PST a NPHP směřuje k využívání nízké verze vah ve všech dalších měsících, je parametr W nastaven na hodnotu W = 3 pro všechny měsíce.

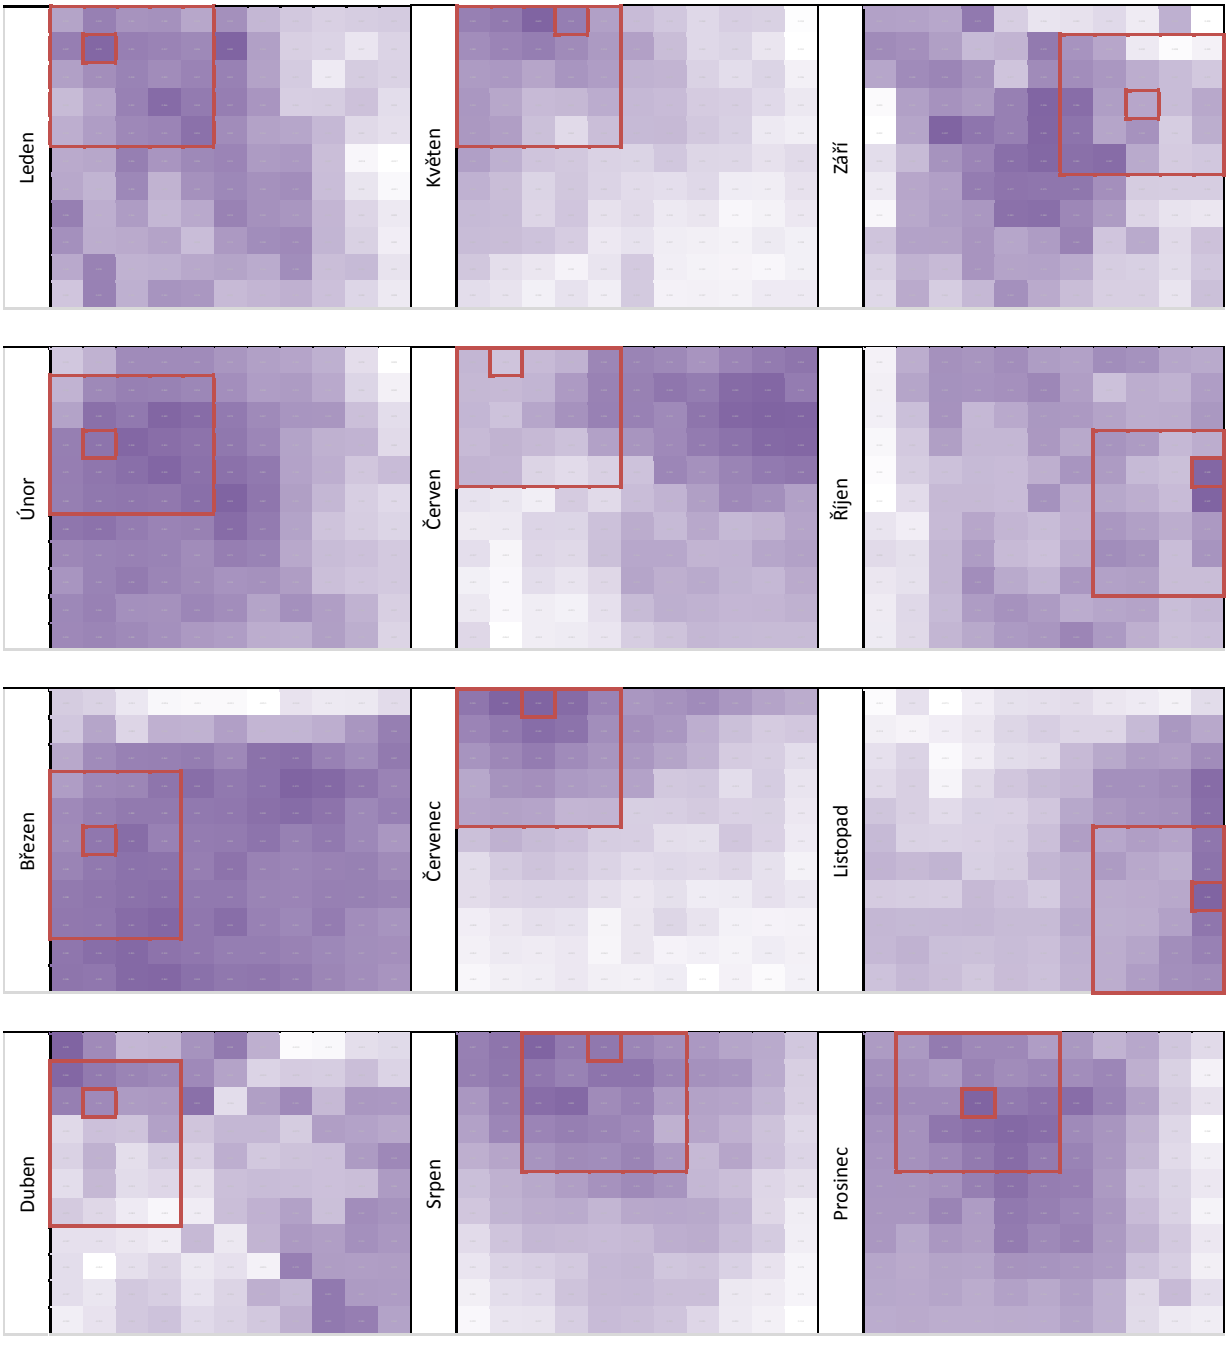

Obr. 52 - Volba parametru PST v profilu Jihlava

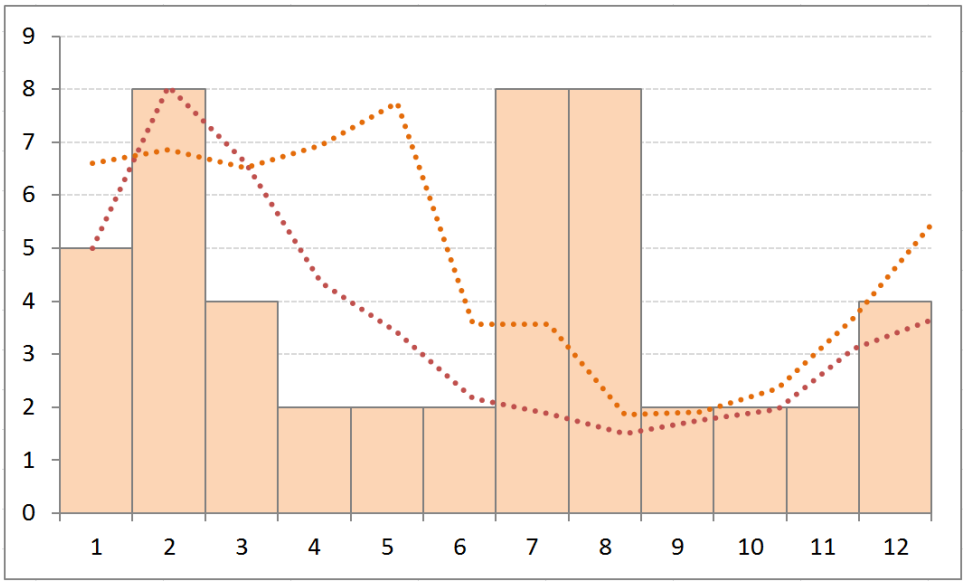

Obr. 53 - Volba parametru NPHP v profilu Jihlava

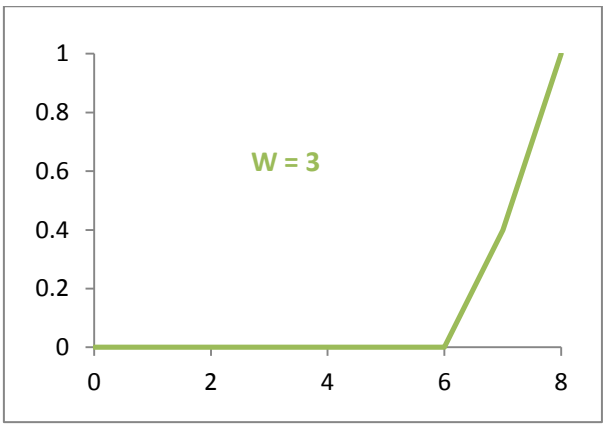

Obr. 54 - Volba parametru W v profilu Jihlava

7.2.9 Oslava

Oslava je profil s nejmenší plochou povodí ze všech zkoumaných profilů. Odtokové poměry jsou podobné jako u Moravy a Jihlavy. Identifikace kalibračních vzorů je oproti ostatním profilům nejvíce obtížná, a pokud by nebyly identifikované kalibrační vzory u Moravy a Jihlavy nebylo by možné zvolené kalibrační vzory u Oslavy identifikovat.

Volba PST, NPHP a W vychází stejně jako u profilu Jihlava. Rozdíl oproti Jihlavě je, že v měsících duben a květen je jasně pozorovatelná možná volba nastavení modelu podobnosti také do oblasti podobnosti průtokových řad a tomu odpovídající volba parametrů NPHP a W. U Jihlavy je dvojí nastavení modelu v jarních měsících obtížně identifikovatelné. Protože je jev zatížen značnou neurčitostí a vhodnost nastavení je hodnocena pouze koeficientem determinace a zobrazením kontrolních kvadrantů, není možné rozhodnout které z nastavení je vhodnější. Zobrazeno je pouze nastavení v oblasti podobnosti srážek.

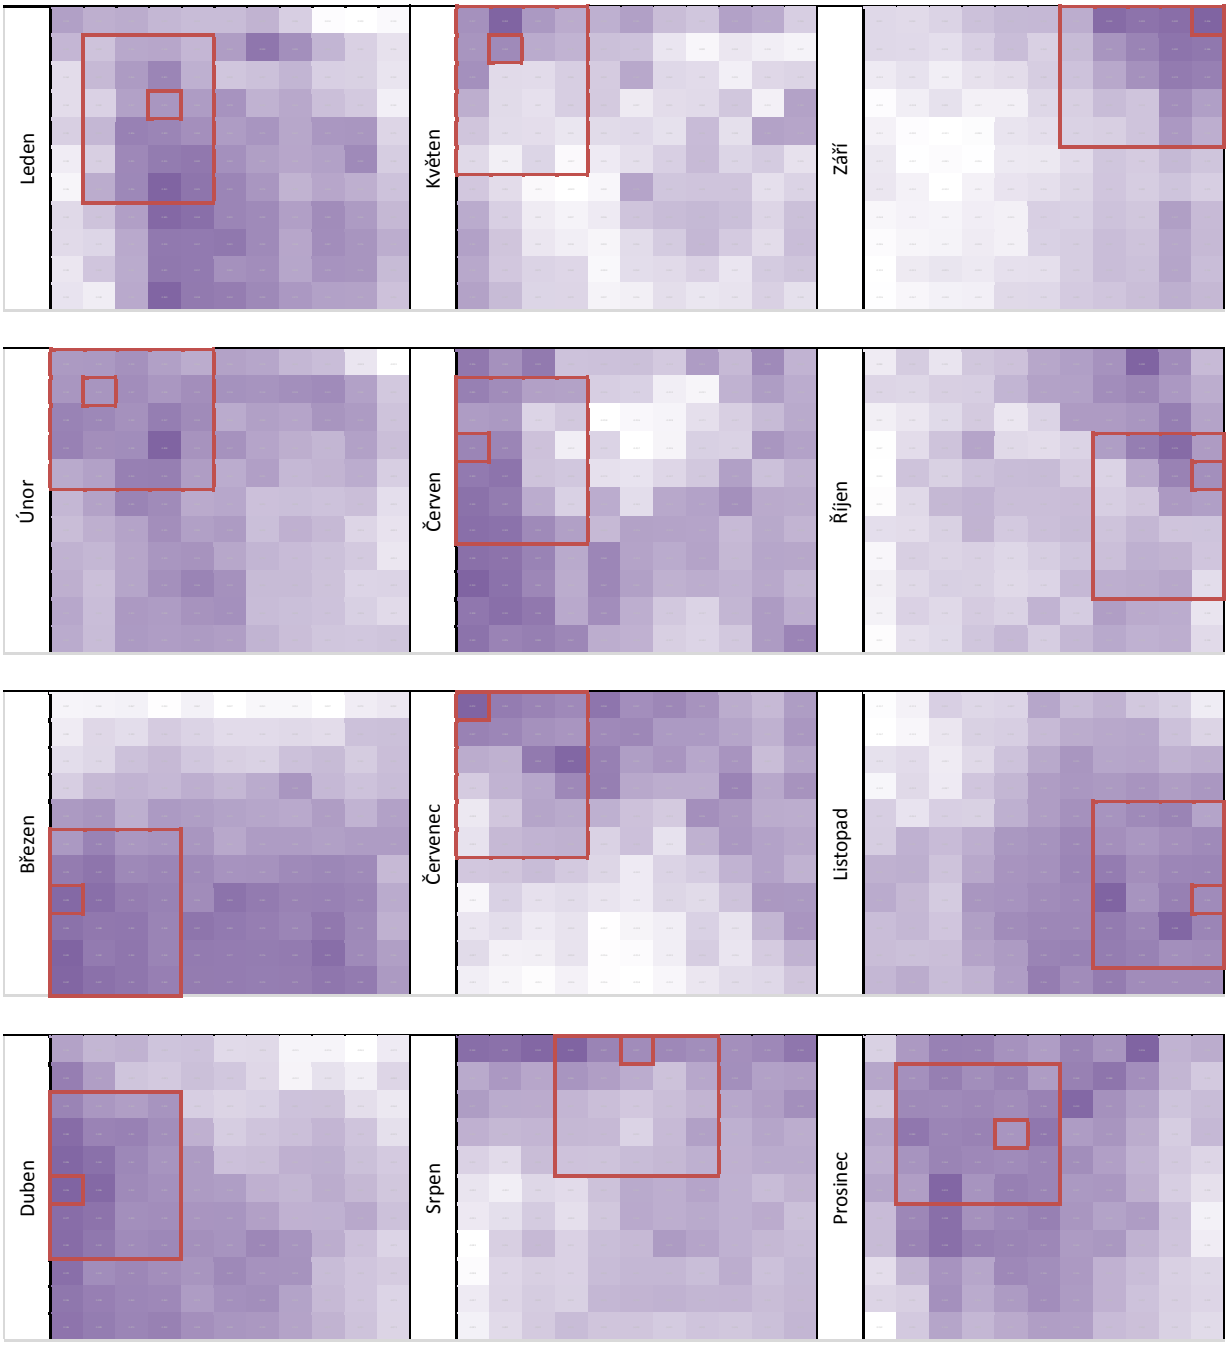

Obr. 55 - Volba parametru PST v profilu Oslava

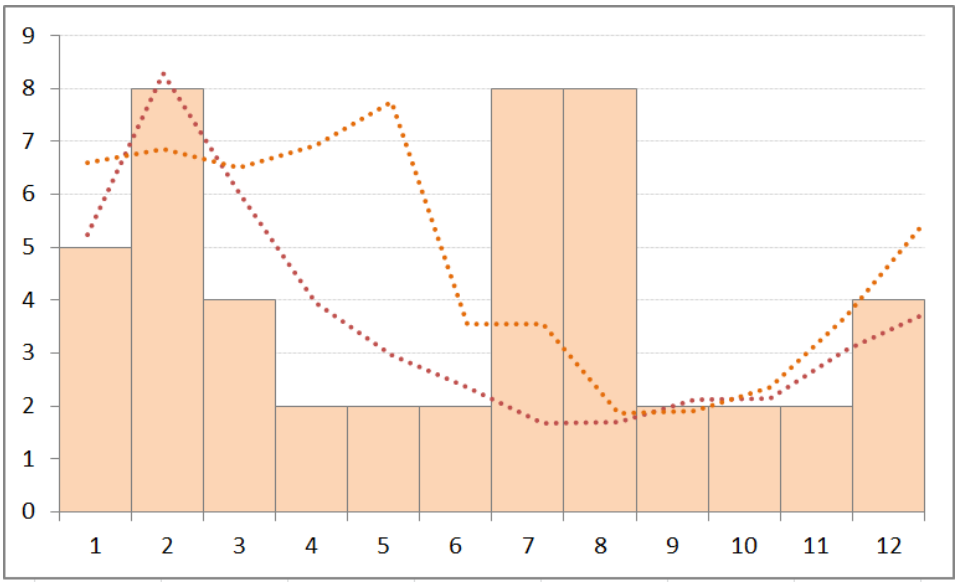

Obr. 56 - Volba parametru NPHP v profilu Oslava

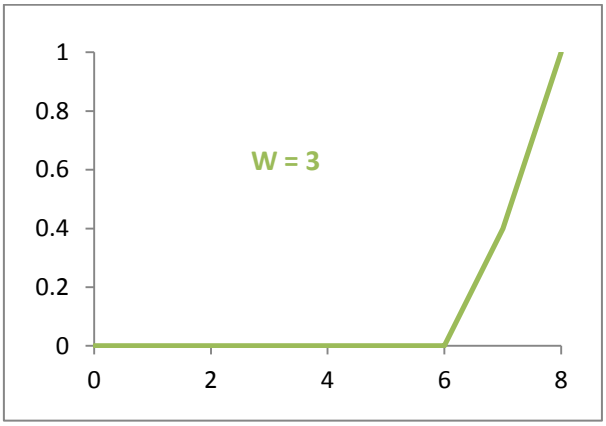

Obr. 57 - Volba parametru W v profilu Oslava

7.3 Předpověď modelem podobnosti

Kapitola se zabývá hodnocením předpovědi modelem podobnosti na validačním souboru dat zkoumaných předpovědních profilů na jeden krok dopředu.

Parametry modelu kalibrace jsou voleny podle kalibračních vzorů uvedených v předchozí kapitole 7.1. Předpověď je prováděna na validačním souboru dat, který představuje přibližně 22 % naposled měřených dat z celkového souboru dat, které jsou k dispozici k jednotlivým profilům (více o volbě validačního souboru v kapitole 7.1). Výsledky jsou shrnuty v Tab. 7 a na Obr. 58. Předpověď je prováděna na jeden krok dopředu. Měsíc uvedený v Tab. 7 a na Obr. 58 představuje okamžik vydávání předpovědi a hodnota koeficientu determinace a zobrazení kontrolního kvadrantu pro příslušný měsíc je předpověď na měsíc příští.

Je vidět, že dosažené přesnosti předpovědi se velmi liší podle velikosti povodí nad předpovědním profilem a složitosti odtokových poměrů v povodí. Dosažené přesnosti předpovědi pro jednotlivé profily odpovídají skutečnostem popsaným podrobně v kapitole 7.1.

Z Tab. 7 je patrné, že u profilů na řekách Dunaj, Rýn, Umpqua jsou hodnoty KD (které hodnotí přesnost předpovědi) větší jak nula. U profilů Morava, Jihlava a Oslava je dosažená přesnost předpovědi hodnocená KD velmi blízko nule a u těchto profilů je nutné zvážit, zda je vhodnější nahradit předpovědi statistickou předpovědí (pomocí aritmetického průměru nebo modu). Na druhou stranu interpretace výsledků koeficientem determinace může být velmi zkreslující (jak je popsáno v kapitole 5) a zobrazení kontrolního kvadrantu obtížně vyhodnotitelné a vzájemně porovnatelné. Hodnotit vytvářenou předpověď je vhodnější přímo její aplikací pro řízení vodní nádrže, jak je ukázáno v další kapitole 7.4.

Tab. 7 – Výsledky předpovědi modelem podobnosti hodnocené KD

Profil	Měsíc												Prům. KD
	1	2	3	4	5	6	7	8	9	10	11	12	
Dunaj	0.276	0.429	0.548	0.665	0.643	0.822	0.835	0.671	0.559	0.605	0.649	0.433	**0.595**
Rýn	0.324	0.203	0.449	0.463	0.470	0.293	0.686	0.813	0.526	0.307	0.152	0.501	**0.432**
Umpqua	-0.008	0.342	0.172	-0.[illegible]	0.713	0.680	0.675	0.321	-0.833	-0.005	0.467	0.106	**0.201**
Morava	-0.257	0.165	0.295	0.506	-1.468	0.065	0.199	0.053	0.227	0.436	-0.123	-0.409	**-0.026**
Jihlava	-0.055	0.482	0.296	-0.573	-0.271	-0.386	0.029	-0.399	-0.316	0.143	0.592	0.301	**-0.013**
Oslava	0.117	-0.131	0.162	0.020	-0.460	0.072	-0.020	0.092	0.543	0.244	0.528	0.320	**0.124**

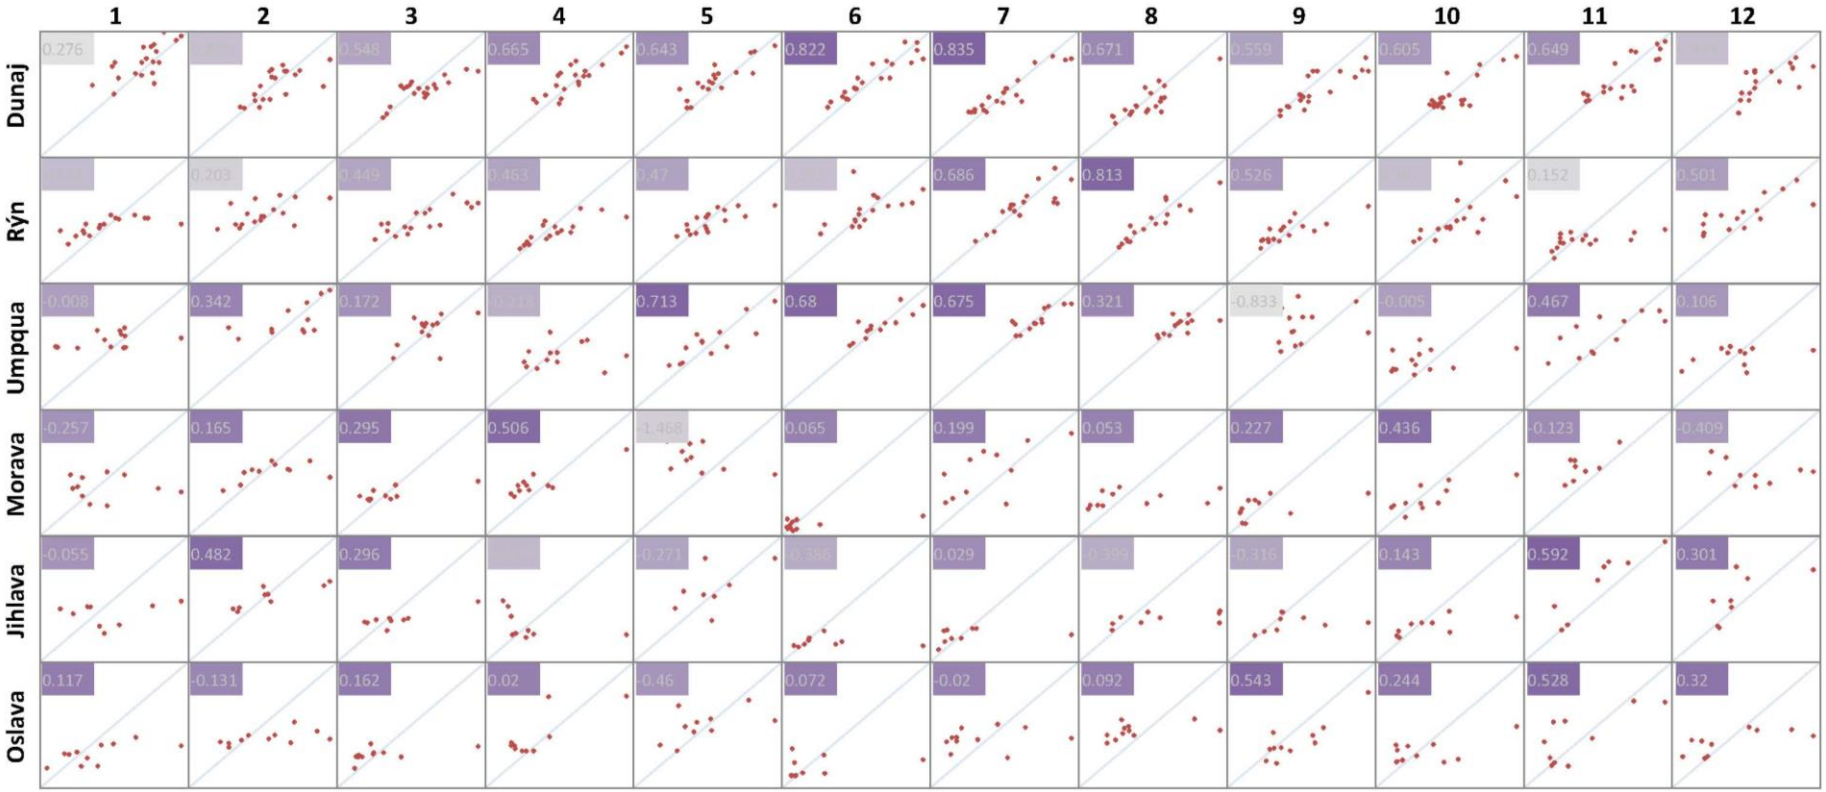

Obr. 58 – Výsledky předpovědi modelem podobnosti hodnocené kontrolními kvadranty

7.4 Ukázka aplikace poznatků práce pro simulaci provozu jedné izolované nádrže pomocí softwaru SOMVS

Kapitola se věnuje ukázce aplikace poznatků získaných v rámci práce pro řízení fiktivní nádrže umístěné v profilu Oslavany na řece Oslava pomocí softwaru SOMVS na validačním souboru dat v profilu Oslavany na řece Oslava.

Software SOMVS (simulační a optimalizační model vodohospodářské soustavy) (Menšík & Starý, 2012) umožňuje automatizovaně sestavit optimalizační a simulační model systému zásobení vodou a řešit na něm úlohy optimálního řízení a optimálního rozvoje; více v disertační práci (Menšík, 2012). V případě ukázky aplikace v této kapitole je řešena úloha optimálního řízení pomocí adaptivního simulačního modelu s optimalizací řízení.

Zájmem je ukázat, jak mohou být využity poznatky ohledně vytváření průměrných měsíčních předpovědí popsané v práci pro zvýšení efektivity provozu nádrže a zhodnotit zda jsou vhodnější než doposud používané způsoby. Zvolené schéma předpovědi (popsané níže) je porovnáváno s řízením na nalepšený odtok, předpovědí aritmetickým průměrem a modem.

Pro ukázku je zvolen profil Oslavany na řece Oslava, který má ze všech profilů zkoumaných v práci, nejméně jednoznačné odtokové poměry. Je předpoklad, že pokud se prokáže účelnost použití předpovědi na tomto profilu, u povodí s jasnějšími odtokovými poměry, bude použití předpovědi také účelné.

Komplexní aplikace na široké spektrum různých profilů/nádrží by byla pro prokázání účelnosti předpovědi vhodnější než pouze ukázka na jednom profilu. Program SOMVS byl vytvářen paralelně s vytvářením střednědobých předpovědí, kterými se zabývá tato práce. Komplexní aplikace bude jednak časově náročná, ale bude také apelovat na rozvoj způsobů předpovědi, ale také rozvoje jejich zpracování programem SOMVS. Proto je komplexní aplikace otázkou budoucího výzkumu. Pokud se prokáže účelnost použití předpovědi v této ukázce, je předpokládáno, že díky budoucímu rozvoji bude účelnost použití předpovědi pro řízení nádrže vyšší.

7.4.1 Simulace řízení nádrže pomocí software SOMVS

Kapitola se věnuje popisu podoby použití software SOMVS pro simulaci řízení jedné izolované vodní nádrže. Definice systému a obecný popis řešení optimálního řízení jde nalézt v disertační práci (Menšík, 2012).

Jako lokální a globální kriteriální funkce jsou použity rovnice

$$\pi_{lok} = \sum_{\tau=1}^{N} (O_{p,n} - O_{s,n})^2 \qquad (51)$$

$$\pi = \sum_{T=2}^{L} (O_{p,l} - O_{s,l})^2 \qquad (52)$$

Kde:

O_p	Součet nalepšeného odtoku z nádrže a odběru z nádrže
O_s	Skutečný odtok vody z nádrže (představuje pokrytí hodnoty O_p)
τ = 1, 2, … n, … N	N – počet kroků vytvářené předpovědi, tj. počet prvků množiny předpovídaných bodů
T = 2, 3, … t, … L	L – počet kroků, v kterých je prováděna simulace provozu nádrže

Celkové řešení je prováděno v L krocích adaptivního způsobu řízení globálního modelu. Globální kroky jsou měsíce. V každém kroku globálního modelu je hledán optimální plán vypouštění vody z nádrže, tj. hledáno minimální $\pi_{lok,T}$. Rozdíl mezi plánem a skutečně nastalým stavem je hodnocen globální kriteriální funkcí. Na začátku řešení musí být stanoveno počáteční množství vody v nádrži. Řešení úlohy může mít následující podobu.

Na počátku řešení je plná nádrž. V prvním kroku globálního modelu T=1 je na základě předpovědi vytvořené v délce N, hledána pomocí optimalizačního modelu minimální hodnota kriteriální funkce $\pi_{lok,T=1}$. Parametry optimalizačního modelu (hodnoty, které může optimalizační model měnit, aby dosáhl minimálního π) je množství odtoku vody z nádrže v intervalu vydávaných předpovědí. Například pokud je první krok globálního modelu leden a délka vydávání předpovědi je 4, hledá optimalizační model množství vody vypouštěné v únoru, březnu, dubnu a květnu tak, aby bylo $\pi_{lok,T=1}$ minimální. Po nalezení hodnot odtoků s minimální hodnotou $\pi_{lok,T=1}$ se globální model přesouvá do dalšího kroku T = 2 (druhý měsíc řešení) a podle nastaveného odtoku z předchozího kroku řídí odtok z nádrže. Množství vody skutečně dodané do nádrže se však může lišit oproti odhadům vydaných v předchozím kroku. Na základě rozdílu mezi skutečně dodaným množství vody O_s pro T = 2 je podle rovnice (52) vypočteno globální $\pi_{T=2}$ a je upraveno množství vody v nádrži. Tj. například pokud byla předpověď vydaná pro T=2 nepřesná a skutečný přítok v kroku T = 2 je vyšší než O_p tak, je zásobováno spotřebiště bez toho aniž by se prázdnila nádrž; přebytečná voda je vypouštěna do toku a hodnota π narůstá, protože nádrž není efektivně využita. Po vypočtení globální kriteriální funkce $\pi_{T=2}$ a upravení objemu vody v nádrži je na základě vydané předpovědi a množství vody v nádrži hledá lokální optimalizační model měněním velikosti odtoků v předpovídaném intervalu minimální hodnotu $\pi_{lok,T=2}$. Po jeho nalezení se globální model přesouvá do dalšího kroku T = 3, kde určí globální hodnotu $\pi_{T=3}$ podle skutečně dodaného množství vody do nádrže a následně je upraveno množství vody v nádrži. Obdobný postup je opakován pro všechny L a jeho výsledkem je hodnota globální funkce π.

7.4.2 Parametry nádrže, parametry simulace a schéma předpovědi

V řešení je použita fiktivní nádrž v profilu Oslavany řeky Oslavy. Tato fiktivní nádrž má stejné parametry jako nádrž Mostiště ležící na horním toku řeky Oslavy. Nádrž Mostiště je tedy „přesunuta“ z horního toku do uzávěrkového profilu řeky Oslavy. Předpovědní profil Oslavany je umístěn na přítoku do vodní nádrže.

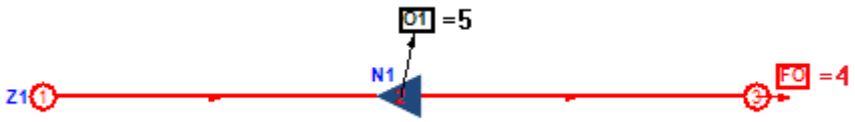

Obr. 59 – Schéma

$Q_{2,3}$	Odtok z nádrže
$Q_{2,5}$	Odběr nádrže
$Q_{1,2}$	Přítok do nádrže
$Q_{3,4}$	Odtok ze soustavy (nalepšený otok)
V_2	Nádrž
V_{max} =	10384000 m^3
V_{min} =	1045000 m^3

$V_{poč}$ =	10384000	m^3
$O_p = (Q_{2,5} + Q_{3,4})$	4,0	m^3/s

Řešení je prováděno ve 120 adaptivních krocích. Jeden krok představuje jeden měsíc. Délka adaptivního řešení vychází z délky validačního souboru, který je jedenáct let. Řešení probíhá v prvních deseti letech. Nádrž je na počátku řešení plná.

Pro řešení je vytvořena hypotetická situace, v rámci které je zvolena hodnota odtoku O_p vyšší než by byla pravděpodobně volena u nádrže s uvedenými parametry a průměrným ročním přítokem 3,5 m^3/s. Zájem je vytvoření napjaté hydrologické situace k zřetelnějšímu rozpoznání výhodnosti předpovědi. Vodní nádrže jsou navrženy tak, aby při jejich provozu byl výskyt možných poruch naprosto minimální. V průběhu návrhu vodní nádrže (ale i provozu již realizované nádrže) je výskyt možné poruchy předpokládán v řádu desítek let. Validační soubor v případě profilu Oslavany na řece Oslava je dlouhý jedenáct let. V případě volby nižší (běžné) hodnoty O_p by účelnost použití předpovědi pro řízení vodní nádrže nebyla zcela patrná. Při nízkém O_p by rozdíly mezi hodnotícím kritériem provozu nádrže π byli minimální.

Pro předpověď je zvoleno následující schéma:

- Předpověď je vytvářena na 7 kroků dopředu od okamžiku vytváření předpovědi
- Hodnoty předpovědi v krocích 2 až 7 od okamžiku vytváření předpovědi jsou vytvořeny modem (tj. hodnotou nejvyšší četnosti výskytu jevu) pro příslušné měsíce
- V okamžicích vytváření předpovědi duben až prosinec je první krok předpovědi vytvořen modelem podobnosti s parametry uvedenými v kapitole 7.2.9.
- Jakékoliv předpovědi pro měsíce únor až duben (buď první krok předpovědi, nebo jakýkoliv jiný) je vytvořen aritmetickým průměrem pro příslušný měsíc.

Například pokud je předpověď vytvářena v měsíci únoru, je předpověď na měsíc březen a duben aritmetický průměr a na všechny další kroky předpovědi je to hodnota modu, viz Obr. 60. Pokud je předpověď vytvářena v měsíci dubnu, je předpověď na měsíc květen vytvořena Modelem podobnosti a na všechny další kroky předpovědi jsou vytvořeny modem, viz Obr. 61.

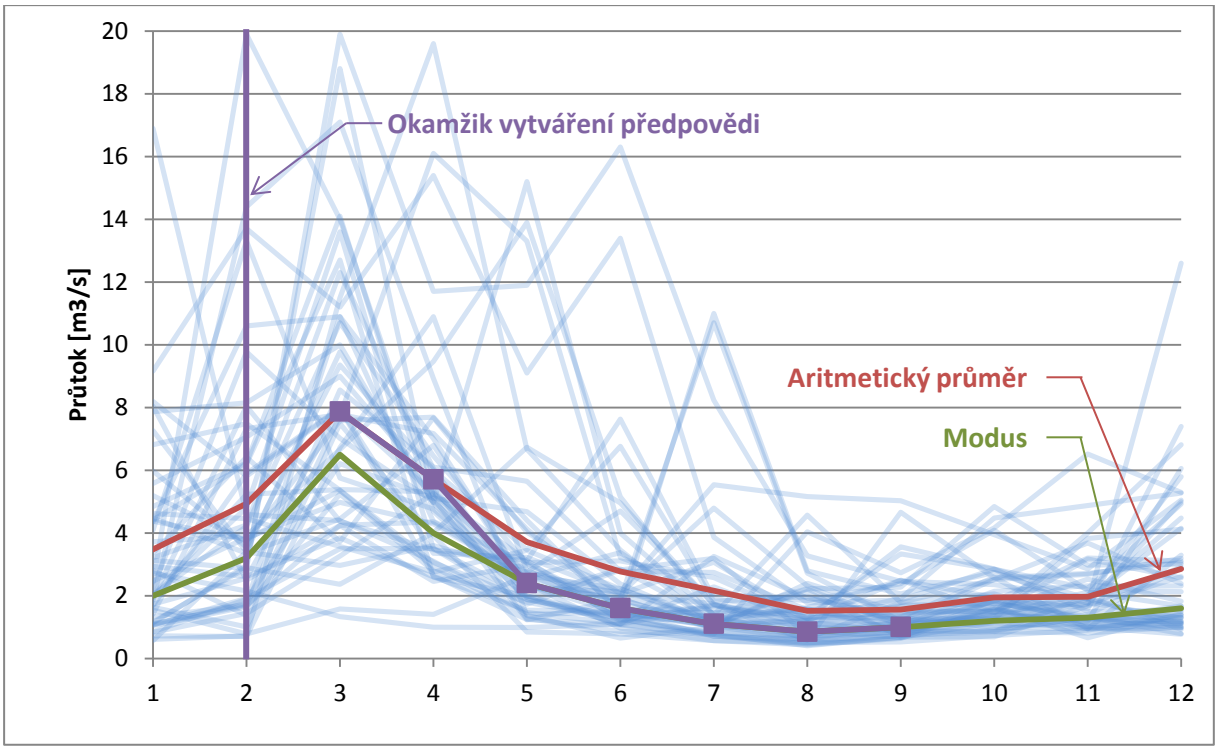

Obr. 60 – Předpověď vytvářena v měsíci únoru

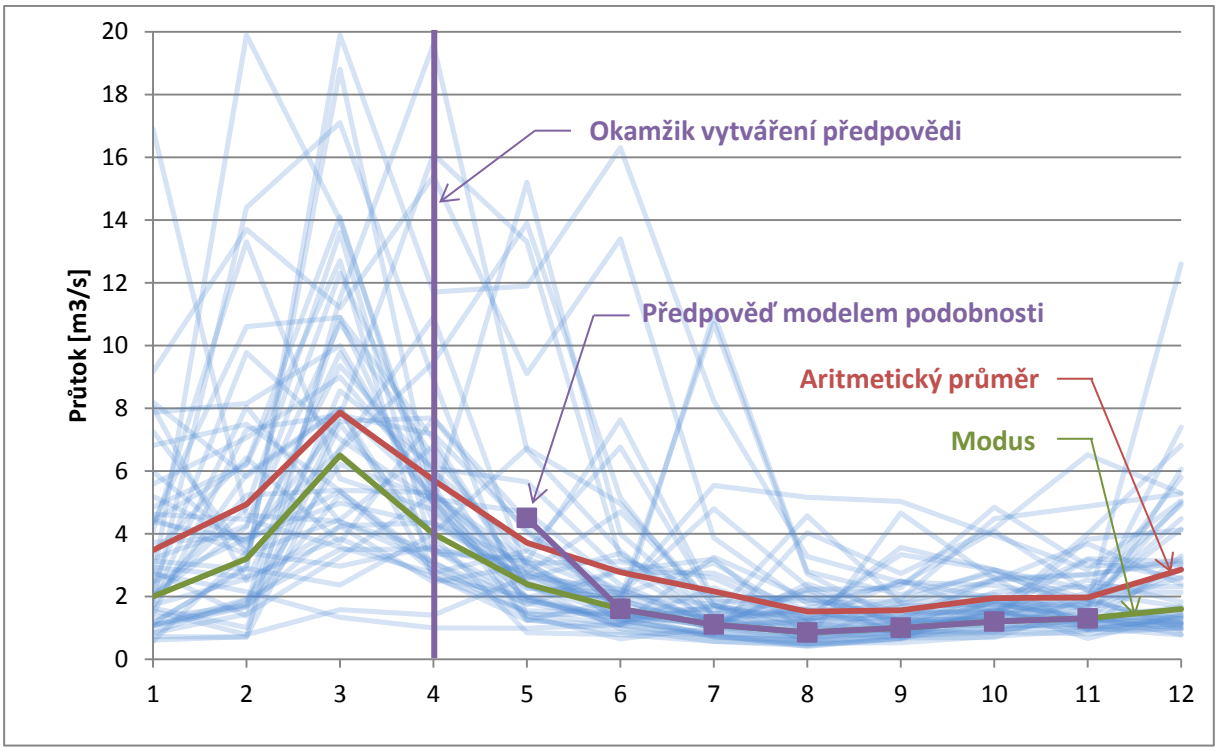

Obr. 61 - Předpověď vytvářena v měsíci dubnu

Průběh hodnot modu pro jednotlivé měsíce je patrný z Obr. 60 nebo Obr. 61. Modus představuje hodnotou průtoku, která se vyskytuje v průtocích sledovaných v příslušném měsíci s největší četností. Jedná se o místo kde má hustota pravděpodobnosti maximální hodnotu (neformálně řečeno svůj vrchol). Modus je určen subjektivním odhadem na základě pozorování několika histogramů četnosti, tj. že množina všech realizací průtoku v příslušném měsíci je rozdělena pomocí pravidelných intervalů. Je zvoleno několik délek těchto intervalů a tím vzniká několik histogramů. Na základě

pozorování těchto histogramů je subjektivně rozhodnuto o poloze modu pro příslušný měsíc. Zvolení pouze jedné optimální délky intervalu a vytvoření jednoho histogramu četnosti neumožňuje jednoznačné rozpoznání oblasti s největší četností výskytu.

S využitím předpovědi skutečně nastalých hodnot průtoku, se efektivita provozu nádrže měřená hodnotou π nezlepšuje, pokud je využito více jak 7 kroků od okamžiku vytváření předpovědi, viz Obr. 62. Proto je délka vydávané předpovědi 7 kroků dopředu od okamžiku vytváření předpovědi.

Z Obr. 62 je patrný také progresivní nárůst hodnoty π se zkracujícím se intervalem délky předpovědi. Přesně opačný vývoj jde vidět na obrázku Obr. 63, kde je zachycena efektivita hospodaření nádrže pro různé délky předpovědi aritmetickým průměrem. Porovnáním grafů jde pozorovat, že hodnota π je téměř stejná pro délku předpovědi 1, ale o sto jednotek π rozdílná, pokud je délka předpovědi 7 a více. Předpověď pomocí skutečně nastalých hodnot je nejlepší předpovědní model (žádný model nemůže dosáhnout lepšího π); předpověď pomocí aritmetického průměru je jeden z nejjednodušších předpovědních modelů. Z porovnání grafů je patrné, že krátká délka předpovědi má neblahý dopad na efektivitu hospodaření nádrže a pokud je délka rovna 1, je vlastně jedno, jestli je použit nejlepší nebo nejhorší předpovědní model. Naopak pokud je délka předpovědi čtyři, dosahuje nejlepší i nejhorší model skoro svého maxima (v závislosti na změně délky předpovědi). V případě řízení nádrže v profilu Oslavany na řece Oslava je vhodné použít délku předpovědi alespoň 4.

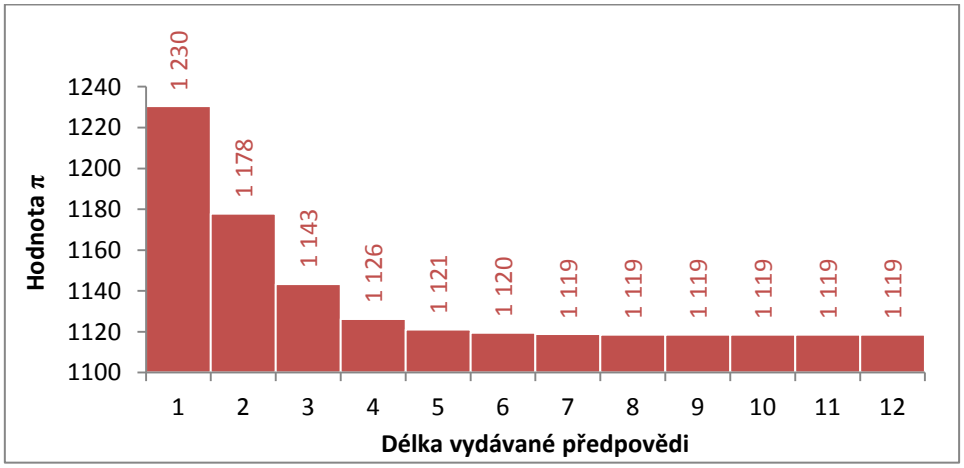

Obr. 62 – Efektivita hospodaření nádrže pro různé délky předpovědi pomocí reálných hodnot průtoků

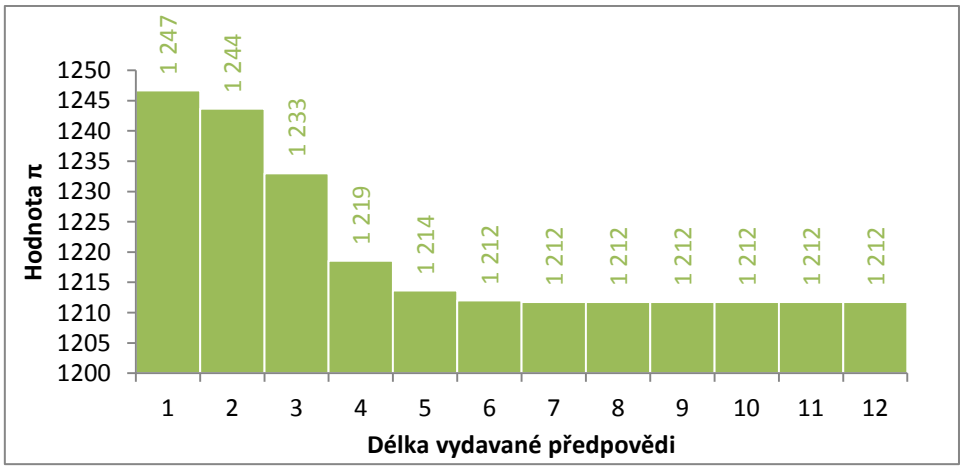

Obr. 63 - Efektivita hospodaření nádrže pro různé délky předpovědi aritmetickým průměrem

Pro body vzdálené dva a více kroků od okamžiku předpovědi je velmi obtížné dosažení lepší přesnosti předpovědi než předpověď statisticky pravděpodobnou hodnotou (jako je třeba aritmetický průměr nebo modus) – toto je zvlášť patrné u profilů ležících na území České republiky. Z toho důvodu jsou předpovědi v krocích 2 až 7 od okamžiku vytváření předpovědi nahrazeny modem nebo aritmetickým průměrem. Modus je volen v měsících květen až leden, kde histogram četnosti indikuje polohu nejvíce pravděpodobného výskytu průtoku v oblasti modu. Naopak aritmetický průměr je zvolen v měsících únor až duben, kde histogram četnosti indikuje nejvíce pravděpodobné hodnoty průtoku kolem aritmetického průměru.

Pro předpověď prvního kroku před okamžikem předpovědi na měsíce květen až leden je použit model podobnosti. V měsících únor až duben jsou odtokové procesy v povodí tak náhodné, že použití modelu podobnosti nepřispívá k efektivnějšímu hospodaření nádrže. Tudíž je vhodnější prohlásit, že předpověď na jeden krok dopředu v únoru až dubnu není přesná a nahradit je aritmetickým průměrem.

7.4.3 Výsledky aplikace

Tab. 8 ukazuje shrnutí efektivity hospodaření nádrže s využitím nejjednoduššího způsobu řízení nádrže (na prvním řádku) a různých způsobů předpovědí pro řízení nádrže (na dalších řádcích).

Tab. 8 – Shrnutí efektivity hospodaření nádrže

Č.	Model	π	Rozdíl k prvnímu řádku	Rozdíl k předchozímu řádku
1	Řízení na plánovaný odtok	1230		
2	Předpověď aritmetickým průměrem	1214	16	16
3	Předpověď pomocí modu	1211	19	3
4	Předpověď pomocí modus a aritmetického průměru	1206	24	5
5	Předpověď s využitím modelu podobnosti	1198	32	8
6	Předpověď s využitím reálných dat	1118	112	80

1. Řízení na plánovaný odtok je nejjednodušší způsob řízení vodní nádrže a je například používán pro simulaci provozu nádrže při návrhu velikosti zásobního objemu. Z nádrže je vypouštěna hodnota O_p pokud je dostatek vody v nádrži. Pokud v nádrži není dostatek akumulované vody je hodnota nalepšeného odtoku O_p pokryta pouze částečně a to z množství vody, které do nádrže přitéká. Zbytek představuje poruchu v dodávce vody, která se měří zvýšením hodnoty π. Pokud se množství přítoku do nádrže zvýší nad hodnotu O_p je nádrž znovu plněna a hodnota π neroste.
2. V případě metody předpovědi aritmetickým průměrem jsou všechny hodnoty v předpovídané množině dat tvořeny aritmetickým průměrem pro příslušný měsíc.
3. V případě metody předpovědi modem jsou všechny hodnoty v předpovídané množině dat tvořeny modem pro příslušný měsíc.
4. V případě předpovědi pomocí modu a aritmetického průměru jsou předpovědi v měsících květen až leden tvořeny modem a v případě měsíců únor až duben tvořeny aritmetickým průměrem.
5. Předpověď s využitím modelu podobnosti je vytvořena podle popisu v předchozí kapitole 7.4.2. Jedná se o stejnou předpověď jako v předchozím případě, která je doplněna o předpověď v první kroku modelem podobnosti.

6. Předpověď, kde jsou pro všechny hodnoty v předpovídané množině dat poskytnuty skutečně měřené hodnoty průtoku. Žádná předpověď nemůže dosáhnout lepší efektivity hospodaření než s využitím skutečně měřených průtoků.

Na Obr. 64 je zachycen chronologický průběh hodnoty π a objemů vodní nádrže všech kroků adaptivního řízení pro předpověď s využitím reálných průtoků a předpovědi s využitím modelu podobnosti. Z obrázku Obr. 64 jde vyčíst například následující informace: v druhém roku řízení zásobního funkce vodní nádrže končí v adaptivním kroku 14 období s vysokými průtoky, přítok do nádrže klesá pod O_p a nádrž musí začít hospodařit se svým objemem aby pokryla potřebu spotřebiště. Pokud je vodní nádrž řízena s využitím předpovědi pomocí reálně nastalých průtoků, je nastaven takový odběr vody z nádrže, aby bylo kritérium π konstantní v průběhu celého období kdy přítok do nádrže je nižší než odběr (tj. adaptivní kroky druhého 16 až 23). Zásobní objem nádrže se vyprazdňuje plynule až do konce kalendářního roku. Při řízení nádrže s využitím modelu podobnosti dochází na počátku období, kdy je přítok do nádrže nižší než odběr (tj. adaptivní kroky druhého 16 až 23) k většímu vypouštění objemu vody nádrže než u řízení s využitím reálných dat. K většímu vypouštění vede optimistická předpověď na konci léta. Větší vypouštění objemu vodní nádrže způsobí skutečnost, že na konci léta je nádrž prázdná a hodnota π narůstá významněji, než u řízení s využitím reálných dat.

Zobrazení na Obr. 64 je pouze ukázkou možné interpretace průběhu π pro všechny kroky adaptivního řešení pro jeden předpovědní model. Detailní rozbor tohoto zobrazení pro různé předpovědní metody může sloužit k dalšímu vývoji vytváření vhodné předpovědi pro řízení nádrže, což není předmětem této kapitoly. Pokud je zájmem získat celkové hodnocení vhodnosti předpovědního modelu pro řízení vodní nádrže ve zvoleném adaptivním období, postačí zobrazení uvedené na Obr. 65. Na grafech je zobrazen součet hodnot π pro jednotlivé měsíce za celé adaptivní období pro různé způsoby předpovědi. V každém grafu je zobrazen průběh hodnot π pro příslušný způsob předpovědi a také řízení s využitím reálných dat. Zobrazení hodnot π pro řízení s využitím reálných dat slouží jako referenční zobrazení pro porovnání průběhu π mezi ostatním způsoby předpovědi.

Z Tab. 8 je zřejmé, že jakákoliv použitá metoda předpovědi je vhodnější než řízení na plánovaný odtok.

Využití předpovědi aritmetickým průměrem pro řízení nádrže poskytuje srovnatelné výsledky jako při použití modu. Rozdíl v hodnotě π mezi použitím předpovědi aritmetickým průměrem a modem jde považovat za velmi malý (jedná se o 3 jednotky π). Oproti předpovědi pomocí aritmetického průměru dosahuje předpověď pomocí modu nižší hodnoty π v průběhu letních a podzimních měsíců. Z Obr. 65 je patrné, že i když řízení nádrže využívající předpověď pomocí aritmetického průměru může dosahovat vyšší π v průběhu léta a podzimu, veškerá ztráta oproti řízení využívající předpověď modem je dorovnána na počátku zimního období, kdy model modu nemá oproti modelu aritmetického průměru zcela prázdnou nádrž. S ohledem na víceleté řízení vodní nádrže hodnocené kritériem π je dosaženo stejné efektivity při použití předpovědi aritmetickým průměrem i modem. Kombinace metod předpovědi pomocí aritmetického průměru a modu poskytuje více efektivní hospodaření s nádrží, tj. π = 1206.

Nejefektivnější hospodaření zajišťuje předpověď s využitím modelu podobnosti, který dosahuje hodnoty π = 1198. V porovnání s ryze statistickou předpovědí pomocí aritmetického průměru a modu

na řádku 4. jde vidět, že doplnění tohoto modelu o předpovědi modelem podobnosti na jeden krok dopředu, zvyšuje efektivitu hospodaře nádrže a použití modelu podobnosti má své opodstatnění.

Rozdíl zlepšení mezi ryze statistickým modelem modus a ar. průměru a modelem využívající model podobnosti je 8 (rozdíl k řízení na nalepšený odtok je 36). I když se rozdíl mezi modely může zdát nízký, interval předpovědi modelem podobnosti krátký a použití modelu podobnosti omezeno v jarních měsících, je nutno podotknout, že předpovídaný profil Oslavany na řece Oslava má nejvíce nejednoznačné odtokové poměry ze všech profilů použitých v práci a vytváření předpovědi v tomto profilu je nejvíce komplikované. Je předpokládáno, že na všech dalších profilech s jednoznačnějšími odtokovými poměry bude předpověď modelem podobnosti způsobovat efektivnější hospodaření nádrže (vyšší rozdíl v π oproti statistickým modelům nebo řízení na plánovaný odtok) a bude využívat delší předpovědní interval (ne pouze předpovědi na jeden krok dopředu), bez vynechání použití modelu podobnosti v některých měsících.

Ověření výše popsaného předpokladu je otázkou dalšího výzkumu zaměřeného na aplikaci poznatků této práce pro řízení provozu nádrže nebo systému nádrží. Je předpokladem, že výzkum aplikace poznatků této práce pro řízení provozu nádrže bude časově velmi náročným a komplexním úkolem. Z toho důvodu nabízí tato práce pouze jednu omezenou ukázku, která však prokazuje, že předpovědi zvyšují efektivitu řízení provozu vodní nádrže. Předpokladem je, že pro budoucí výzkum aplikace modelu podobnosti pro řízení nádrže budou stěžejním podkladem poznatky popsané v rámci kalibračních vzorů, viz kapitola 7.1.

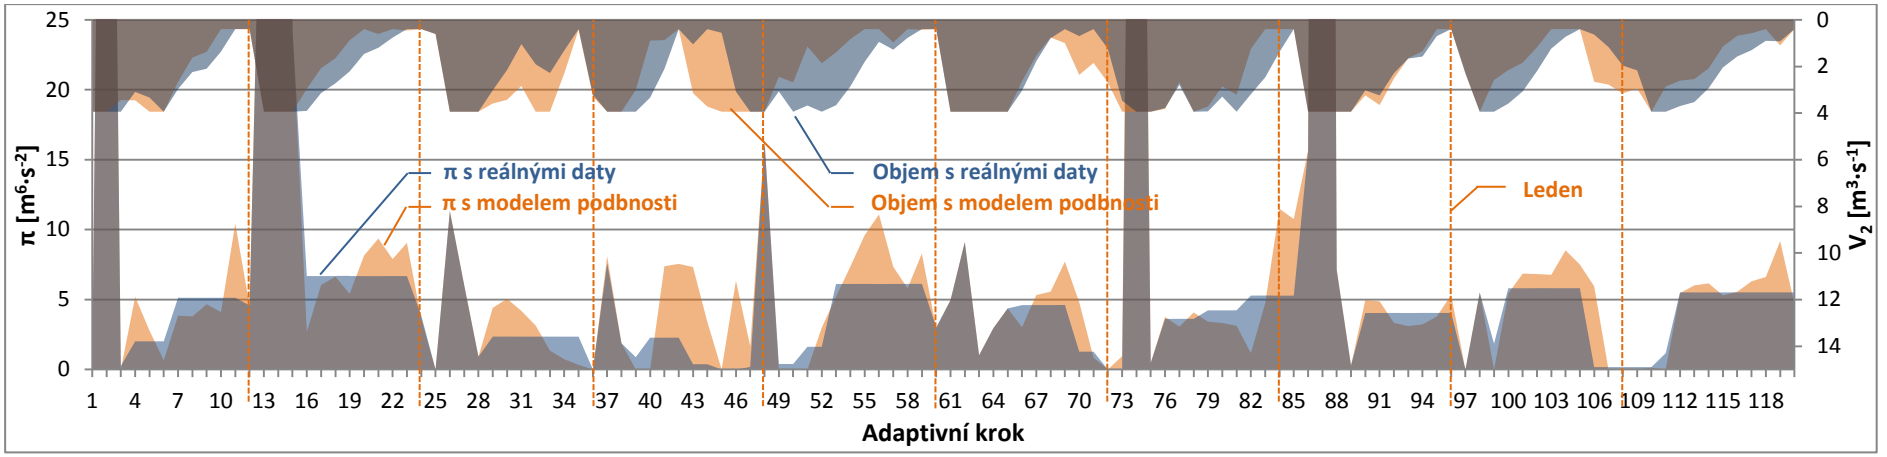

Obr. 64 - Průběh hodnot πa plnění vodní nádrže pro jednotlivé adaptivní kroky s předpovědí využívající reálných dat a modelu podobnosti

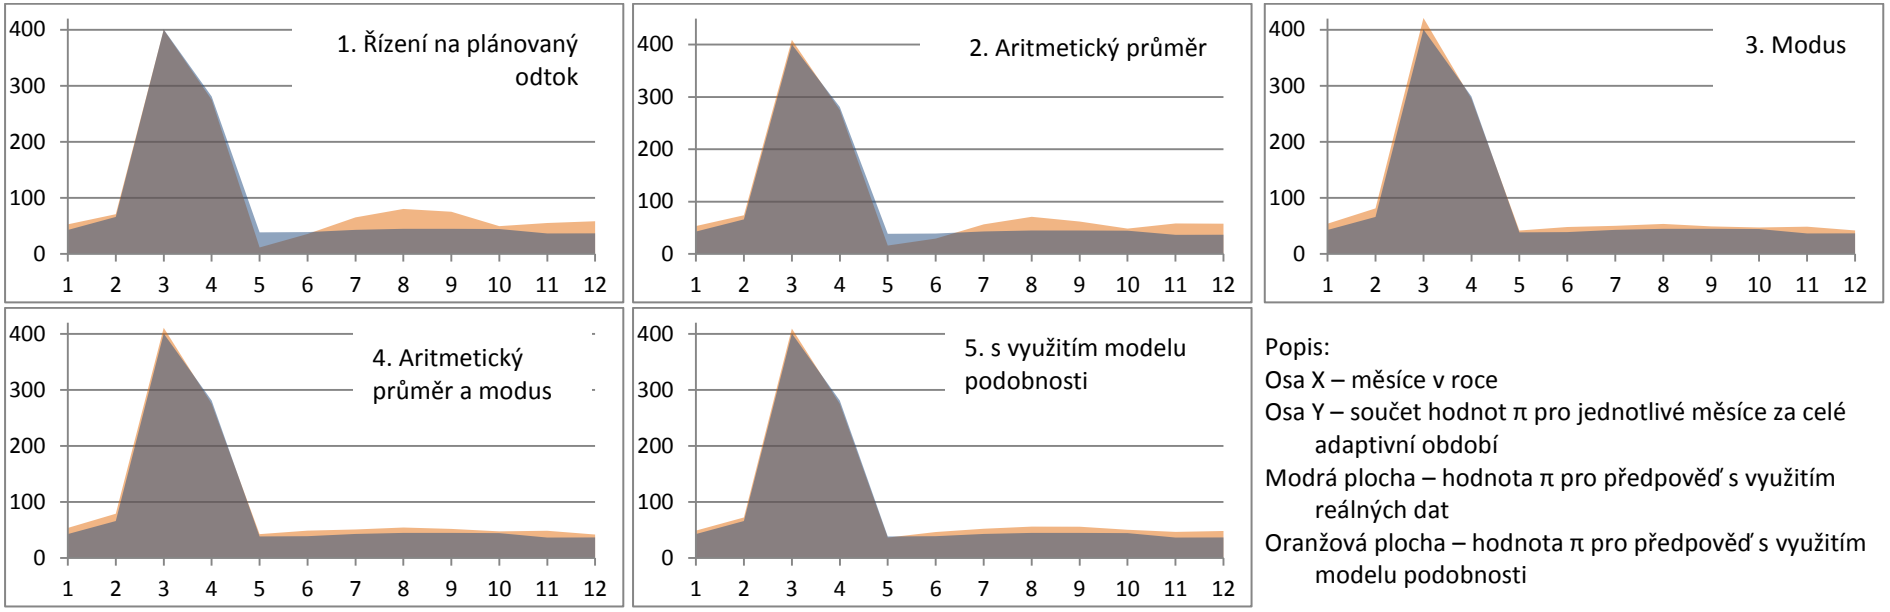

Popis:
Osa X – měsíce v roce
Osa Y – součet hodnot π pro jednotlivé měsíce za celé adaptivní období
Modrá plocha – hodnota π pro předpověď s využitím reálných dat
Oranžová plocha – hodnota π pro předpověď s využitím modelu podobnosti

Obr. 65 - Součet hodnot π pro jednotlivé měsíce za celé adaptivní období pro různé způsoby předpovědi

8 Shrnutí výsledků

Kalibrační vzory popisují vztahy mezi předpovědním modelem podobnosti a předpovídaným jevem. Jednak že umožňují lepší porozumění odtokových poměrů povodí pro vytváření střednědobých předpovědí, ale také umožnují jednodušší kalibraci modelu podobnosti.

U předpovědních profilů s velkým povodím jako je Dunaj nebo Rýn je volba parametrů modelu podobnosti zcela jednotná pro všechny měsíce v roce. Nejlepší předpověď je dosažena pokud má podobnost srážkové a průtokové řady stejný vliv na rozpoznání nejvíce podobného případu. Vliv podobnosti teplotních případů na nalezení nejvíce podobného historického případu je nepatrný. Parametr NPHP je volen jednotně pro všechny měsíce a pro vytvoření přesné předpovědi stačí relativně nízký počet historicky nejvíce podobných případů (NPHP=4), což indikuje, že procesy v povodí jsou relativně setrvačné. Délka porovnávaného období většinou nepřesahuje délku více jak dvou měsíců (tj. okamžik vytváření předpovědi a jeden krok méně).

Předpovědní profil na řece Umpqua má nejvíce jednoznačné odtokové poměry. Odtok z povodí je v různých fázích ročního období určován vždy pouze jedním dominantním procesem odehrávajícím se v povodí, tj. například v zimním období představují intenzivní deště dominantní proces ovlivňující průtok v závěrovém profilu. Oproti profilům Dunaj a Rýn se volba parametrů mění v každém měsíci (není jednotná pro všechny měsíce). Oproti profilům Morava, Jihlava, Oslava je volba optimálních parametrů mnohem více jednoznačná.

V průběhu zimního období nastává období dešťů, které dominantně určuje odtok vody z povodí. Nejlepší předpovědi jde dosáhnout, pokud je nalezen nejvíce podobný historický případ na základě podobnosti klimatického scénáře (podobnost srážek a teplot); volba parametru NPHP je velmi vysoká (více jak 10, kvůli skutečnosti, že procesy v povodí velmi náhodné); a porovnávané období je velmi krátké (což, podobně jako u předchozího parametru NPHP, ovlivňuje velká náhodnost procesů v povodí). V průběhu jara začínají ustávat srážky v povodí a v letním období nastává období srážkového minima (v některých letech i s nulovými měsíčními úhrny). Dominantním procesem utvářející odtok vody z povodí je prázdnění akumulovaných zásob v povodí. Oproti velmi náhodným odtokovým procesům v zimním období jsou odtokové procesy na jaře a v létě velmi setrvačné. Nejlepší předpovědi lze dosáhnout, pokud je nalezen nejvíce podobný historický případ na základě podobnosti průtokových řad a teplotních řad; volba parametru NPHP je velmi nízká (v létě až NPHP = 2); porovnávané období je velmi dlouhé (až 5 měsíců). Protože je odtok vody z povodí tvořen výtokem akumulované vody je vhodné nalézt nejvíce podobný historický případ porovnáním průtokových řad. Podobnost teplotních řad má pouze u profilu Umpqua význam i v létě. Odtokové procesy na jaře a létě jsou velmi setrvačné a velmi málo ovlivněny náhodností a proto jde jednoduše najít podobný historický případ a stačí, pokud je předpověď vytvořena průměrováním pouze malého množství nejvíce podobných případů. Nejvíce podobné historické případy je však vhodné hledat na dlouhém porovnávaném období. V průběhu podzimu končí srážkové minimum a dominantním procesem utvářejícím odtok vody z povodí se znovu stávají srážky. Povodí se znovu plní vodou.

Předpovědní profily na území ČR Morava, Jihlava a Oslava mají velmi podobné odtokové poměry a také nastavení parametrů modelu. U všech třech předpovědních profilů jde v průběhu zimního období nejlepší předpovědi dosáhnout porovnáním klimatických scénářů (srážka a teplota). Tomu odpovídá i vysoká volba NPHP a krátké porovnávané období, protože procesy v povodí jsou velmi

náhodné. V průběhu jara a léta se začínají prázdnit zásoby vody akumulované v povodí v průběhu zimního období. V průběhu léta se vyskytuje srážkový extrém. U všech třech předpovědních profilů představuje prázdnění zásob povodí (na jaře a létě) a srážkový extrém (v průběhu zimy) dva významné procesy, které utvářejí odtok vody z povodí. Parametry modelu jde nastavit dvěma způsoby, a to, že nejvíce přesnou předpověď jde vytvořit

- porovnáním srážkových časových řad, průměrováním vysokou hodnotou NPHP a krátkým porovnávaným obdobím. Nebo
- porovnáním průtokových časových řad, nalezením pouze několika NPHP s využitím delšího porovnávaného období.

S ohledem kritéria hodnocení přesnosti použité v rámci práce (KD a zobrazení kontrolního kvadrantu) je velmi obtížné rozhodnout, která z možností volby nastavení parametru je nejlepší. Nicméně je v případě předpovědního profilu Morava pravděpodobnější, že významnějším procesem pro vytvoření přesné předpovědi je setrvačnost odtokových poměrů. Naopak u profilů na řekách Jihlava a Oslava je doba dotoku vody povodím již natolik krátká oproti Moravě, že je pravděpodobnější, že významnějším procesem pro vytvoření přesné předpovědi je srážka dopadlá na povodí.

V průběhu podzimu pro profily území ČR dosažení nejvyšší přesnosti předpovědi možné hledáním nejvíce podobné časové řady na základě podobnosti průtokových řad s velmi krátkým porovnávaným obdobím. Nalezení podobných historických případů není příliš obtížné (tj. že procesy v povodí jsou setrvačné) a proto je volba NPHP nízká.

Poznatky shromážděné v průběhu vývoje a aplikace modelu podobnosti jsou využity v ukázce řízení zásobní funkce vodní nádrže na profilu Oslavany na řece Oslavě. Řízení nádrže probíhá na validačním souboru dat v délce 10 let a 120 adaptivních krocích. Pro vytváření předpovědi je zvolené takové předpovědní schéma, které vytváří předpověď na jeden krok dopředu pomocí modelu podobnosti a na více kroků dopředu pomocí modu (v případě jara, léta a podzimu) a pomocí aritmetického průměru (v průběhu zimy). Zvolené předpovědní schéma vykazuje lepší efektivitu řízení zásobní funkce nádrže než řízení s pomocí řízení na plánovaný odtok nebo nejjednodušších předpovědních modelů jakým je předpověď pomocí aritmetického průměru nebo modu.

9 Závěr

V rámci práce byl vytvořen předpovědní model k vytváření střednědobých předpovědí průtoků povrchových toků nazvaný model podobnosti.

Vytvoření předpovědi modelem podobnosti vzniká na základě porovnávání aktuálního záznamu a historických záznamů, která je hodnocena podle polohy bodů historického a aktuálního záznamu. Následně je vybrán jeden nebo více nejvíce podobných historických záznamů, ze kterých je vypočítán aritmetický průměr. Průběh tohoto průměru v oblasti předpovídaných bodů je předpověď modelem podobnosti. Model podobnosti pracuje s časovou řadou s měsíčními průměry a vytváří bodovou předpověď. Umožňuje vytvářet předpovědi na základě porovnání průtokových časových řad (které jsou nezbytným vstupem řešení), ale také časových řad průměrných srážek a teplot v povodí nad předpovídaným profilem. S ohledem široké spektrum různých způsobů aplikace modelu podobnosti se práce koncentruje na vytváření předpovědi s využitím průtokové, srážkové a teplotní časové řady na jeden krok dopředu od okamžiku předpovědi. Parametry modelu podobnosti jsou hledány subjektivně na základě zobrazení mřížky výsledků předpovědi pro kombinace parametrů modelu. Aplikace modelu podobnosti je provedena na šesti předpovědních profilech. V rámci kalibrace modelů na předpovědních profilech je vytvořen soubor pravidel nazvaný kalibrační vzory, který popisuje nastavení parametrů modelu podobnosti pro profily s různým charakterem odtokových poměrů povodí. Přínosem kalibračních vzorů není pouze možnost jednodušší kalibrace modelu podobnosti pro další předpovědní profily, ale i pochopení vazeb mezi zkoumaným jevem a předpovědním modelem. Možné využití modelu podobnosti je demonstrováno v ukázce řízení provozu jedné izolované nádrže programem SOMVS v profilu Oslavany a řece Oslava. Na základě poznatků získaných v průběhu výzkumu je zvoleno takové předpovědní schéma, které umožňuje nádrži hospodařit efektivněji, než jak by hospodařila s využitím nejjednodušších předpovědních modelů.

Vytvořený předpovědní model představuje jednu z dalších alternativ k vytváření střednědobých předpovědí. Výhodou vytvořeného modelu je oproti jiným předpovědním modelům, že je vyvinut právě pro specifikou aplikaci pro vytváření střednědobých předpovědí. Tj. například, že model má zvolen takový předpovědní princip, který je vhodný pro hledání historické podobnosti; model má zvolen takový druh a množství parametrů, které mohou ovlivnit výslednou přesnost předpovědi; model má parametry, které jsou dobře představitelné vůči zkoumanému jevu - dobře představitelné parametry vůči zkoumanému jevu umožňují použití subjektivní kalibrace (subjektivní volby parametrů modelu), která eliminuje velmi náhodnou volbu parametru vznikající při použití optimalizačních modelů pro hledání parametrů modelu. Oproti tomu modely vytvořené pro obecnou aplikaci (jako třeba neuronové sítě) nebo modely vytvořené pro podobnou aplikaci (jako třeba koncepční modely odtokových procesů v povodí pro operační předpověď) mohou mít na úkor obecnosti nebo jiného předmětu jejich původní aplikace, určité nevýhody pro aplikaci k vytváření středně dobých předpovědí. Tj. například kalibrace neuronových sítí je docílena pomocí optimalizačních modelů, které mají pro zkoumaný jev významnou tendenci hledat lokální minima. Dále například obtížná interpretace vlivu změny jedné synapse neuronové sítě vůči zkoumanému jevu dělá subjektivní kalibraci obtížně použitelnou.

Úspěšně splněný cíl práce, týkající se vytvoření předpovědního modelu, není její jediný přínos. Podrobný popis vazeb zkoumaného jevu a zvoleného předpovědního modelu, představuje jednak nezbytnou složku k výzkumu širší aplikace modelů podobnosti pro efektivní řízení vodních nádrží nebo vodohospodářských soustav, ale také významný příspěvek k porozumění odtokových procesů povodí s měsíčním časovým krokem a schopností jejich předpovědi. Největší množství poznatků ohledně vazeb zkoumaného jevu a předpovědního modelu je shrnuto v rámci kalibračních vzorů. Z kalibračních vzorů jde pro jednotlivé zvolené předpovědní profily vyčíst například, jak moc mohou být dominantní klimatické vlivy na celkový odtok vody z povodí a tím i vytvářenou předpověď; v jakých ročních obdobích je vhodné vytvářet předpověď založenou na setrvačnosti jednotlivých bodů průtokové řady; jestli a kdy má vliv na odtokové poměry průměrná teplota v povodí; kolik bodů po sobě průtokové časové řady může obsahovat vzájemnou vazbu bez ohledu na to, jakou délku této vazby indikuje autokorelační funkce; v kterém ročním období je vhodné předpovídat pomocí aritmetického průměru nebo modu a v kterých ročních obdobích se naopak vyplácí vytvářet předpověď. Jak je přiblíženo v předchozím odstavci, nezbytnou podmínkou pro vytvoření kalibračních vzorů a prohloubení poznání odtokových procesů povodí s měsíčním časovým krokem a jejich předpovědi je, že parametry modelu podobnosti jsou dobře představitelné vůči zkoumanému jevu.

Poznatky shromážděné v průběhu vývoje a aplikace modelu podobnosti jsou využity v ukázce řízení vodní nádrže na profilu Oslavany na řece Oslavě. Řízení nádrže probíhá na validačním souboru dat v délce 10 let a 120 adaptivních krocích. Zvolené předpovědní schéma využívající předpovědi modelem podobnosti, vykazuje lepší efektivitu provozu nádrže než nádrž řízení s pomocí nejjednodušších předpovědních modelů (řízení na plánovaný odtok, předpověď pomocí aritmetického průměru nebo modu). Ve zvoleném profilu jsou oproti všem dalším profilům zkoumaných v rámci práce odtokové poměry nejvíce zatíženy náhodností, tj. vytvořit přesnou předpověď je nejvíce obtížné. Je předpoklad, že u profilů s odtokovými poměry zatíženými menší náhodností než je profil Oslavany na řece Oslava, bude efektivita řízení nádrže s využitím poznatků získaných při vývoji a aplikaci modelu podobnosti vyšší.

Schopnost modelu podobnosti zvýšit efektivitu řízení vodní nádrže v profilu Oslavany je nepochybně pozitivním závěrem. Na druhou stranu komplexní ověření vhodnosti modelu podobnosti pro řízení vodní nádrže nebo soustavy vodních nádrží je záležitost budoucí aplikace poznatků shrnutých v této práci. Pro hodnocení přesnosti předpovědi je v práci používán KD (spíš jako kritérium pro vytvoření přehledu nebo předběžných závěrů) a zobrazení kontrolního kvadrantu (jako kritérium pro vyvození závěrů nebo potvrzení předběžných závěrů). I když může předpověď modelem podobnosti vytvářet takovou předpověď, která může být hodnocena KD nebo pozorováním kontrolního kvadrantu jako přesná, ve výsledku je mnohem více významná taková předpověď, která způsobí efektivnější provoz nádrže. Software SOMVS byl vyvíjen paralelně s výzkumem shrnutým v této práci a možnost testovat předpověď pro řízení provozu nádrže se otevřela až na konci tohoto výzkumu. V průběhu vývoje předpovědi modelem podobnosti bylo možné předpověď hodnotit pouze KD a zobrazením kontrolního kvadrantu. S ohledem na paralelní provádění výzkumu předpovědi průtoků a řízení nádrže je v práci uvedena pouze ukázka aplikace modelu podobnosti na jednom případu než komplexní výzkum. Komplexní ověření vhodnosti modelu podobnosti pro řízení vodní nádrže nebo soustavy vodních nádrží je s ohledem na pracnost celého procesu (který může apelovat na rozvoj jednak modelu podobnosti, ale také softwaru SOMVS) ponechána pro budoucí výzkum. Na druhou stranu je předpokládáno, že budoucí aplikace modelu podobnosti pro rozdílné případy řízení odtoku vody z vodní nádrže nebo vodohospodářské soustavy, musí vycházet z vazeb předpovědního modelu

a zkoumaného jevu, na které se výzkum primárně koncentruje. Je předpokládáno, že určitá nevýhoda v zastoupení finální aplikace KD a zobrazením kontrolního kvadrantu, bude překonána komplexností prozkoumání vazeb předpovědního modelu a zkoumaného jevu a i kdyby byla po celou dobu výzkumu střednědobých předpovědí k dispozici software pro řízení vodních nádrží jakým je třeba SOMVS, bylo by detailní prozkoumání vazeb mezi zkoumaným jevem a předpovědním modelem stěžejním kritériem pro úspěšné řízení nádrže na základě předpovědi jejich přítoků.

Protože v průběhu vývoje předpovědního modelu nebylo dosaženo příliš přesné předpovědi na dva a více měsíců dopředu (zvlášť u profilů s malým povodím, tj. profilů Umpqua, Morava, Jihlava, Oslava) koncertoval se výzkum na předpověď na jeden krok dopředu s předpokladem, že je vhodnější nahradit předpověď pro druhý a další předpovědní krok pomocí statisticky pravděpodobné hodnoty, tj. aritmetický průměr nebo modus. Na druhou stranu, jak je ukázáno v kapitole 7.4.2 předpověď o délce jednoho kroku není pro efektivitu řízení vodní nádrže příliš vhodná a proto se může zdát volba koncentrace na jeden předpovědní krok ne příliš vhodná. Avšak v kapitole 7.4.3 je ukázáno, že pokud je předpověď pomocí statisticky pravděpodobných hodnot, tj. aritmetický průměr nebo modu, doplněna v prvním kroku předpovědí modelem podobnosti je dosažena vyšší efektivita řízení nádrže (a jedná o aplikaci na nejvíce obtížném případu). Vytváření předpovědí na více než jeden kroku dopředu je otázkou budoucího rozvoje (hlavně v oblasti architektury předpovědního principu a jeho parametrů) a je předpokladem, že zvýší efektivitu hospodaření vody v nádrži.

Hlavní přínosy pro zkoumanou oblast jsou ve stručném shrnutí následující:

- Vyvinutý předpovědní model specificky orientovaný pro vytváření střednědobých předpovědí průtoků povrchových toků
- Rozvoj porozumění odtokových procesů povodí s měsíčním časovým krokem a rozvoj schopnosti jejich předpovědi
- Zvýšení efektivity řízení vodní nádrže při využití poznatků získaných v rámci provedeného výzkumu

10 Náměty pro další rozvoj

Díky tomu, že je možné testovat použití vytvořeného modelu na provoz nádrže pomocí softwaru SOMVS, měl by veškerý budoucí rozvoj modelu podobnosti (popřípadě i dalších předpovědních principů) být vyvíjen tak, aby ve výsledku zefektivňoval provoz vodní nádrže bez ohledu na to, jaký bude předpověď vykazovat přesnost hodnocenou pomocí KD nebo zobrazení kontrolního kvadrantu.

Model podobnosti by měl být použit pro více případů řízení vodní nádrže nebo vodohospodářské soustavy. Další aplikační případy pro řízení nádrže by měli být zvoleny tak, aby umožnili možnost testovat použití modelu podobnosti na širokém spektru různých případů a umožnit tak vývoj modelu podobnosti k aplikaci na řízení nádrže zcela obecným směrem použití.

Společně s vývojem modelu podobnosti je potřeba paralelně vyvíjet i software SOMVS. Například model podobnosti ve své současné podobě vydává bodové předpovědi, což je jediná forma předpovědi, kterou může software SOMVS zpracovat. Jak je však z poznatků popsaných v této práci patrné představuje jedna bodová předpověď budoucího stavu velké zjednodušení interpretace budoucí předpovědi. Například v kapitole 7.1 je popsáno, že odtokové procesy v některých předpovědních profilech určuje několik procesů v povodí zároveň a každý z těchto procesů může náhodně převážit a určit výsledný odtok. Například v případě profilů na území ČR vytéká v průběhu jara akumulovaná voda z povodí a tento jev je velmi jednoduché předpovídat pomocí hledání podobných průtokových časových řad. Ve stejném ročním období nastává srážkový extrém, který v případě kdy zaprší, významně zvedne výsledný odtok vody z povodí. Avšak nastavení parametrů modelu podobnosti pro úspěšnou předpověď na základě podobnosti průtokových řad je zcela rozdílné než nastavení parametrů modelu podobnosti pro vhodnou předpověď v případě kdy odtok z povodí ovlivní srážky spadlé na povodí. Jeden z námětů budoucího rozvoje je vydávat dvě předpovědi s dvojím nastavením parametrů, které budou indikovat dva možné případy, které mohou v povodí nastat. Otázkou vývoje pro software SOMVS je potom jak „dvojí“ předpověď zpracovat.

Pro vytvoření předpovědi modelem podobnosti na více kroků dopředu je potřeba jednak zvážit předpovědní princip, ale také parametry modelu a jejich kalibraci. Například předpověď s využitím principu trendu by mohla skýtat určitou perspektivu pro vytvoření dlouhodobějších perspektiv. Na druhou stranu je předpokladem, že předpověď na více kroků dopředu se opře poznatky popsané v tomto výzkumu a nastavení parametrů modelu podobnosti může být pouhou drobnou modifikací parametrů pro první předpovědní krok.

Prohloubení poznání částečně prozkoumaných předpovědních principů zmíněných v kapitole 6.2.2 může být také předmětem budoucího rozvoje. S tím souvisí i rozvoj architektury všech předpovědních principů popsaných v práci. Například princip předpovědi zonálním pravděpodobnostním modelem má pouze jeden předpovědní parametr čímž je vymezení jednotlivých oblastí intervalů výskytu, tj. jejich množství a s tím související intervaly jejich rozsahu. Tento parametr určuje podobu předpovědi podle toho, do jaké oblasti po výšce všech možných realizací padne aktuální záznam. Princip odchylek umožňuje oproti principu zonálního pravděpodobnostního modelu adjustaci předpovědi vyšším množství parametrů. Avšak ani architektura principu odchylek ani jeho parametry nijak nezohledňují při vytvoření předpovědi skutečnost, jestli padne aktuální záznam do oblasti minim, maxim nebo do oblasti nejvíce četného výskytu, což může být pro zvýšení přesnosti důležitá informace.

Protože je zkoumaný jev velmi náhodný, je vliv parametru NPHP velmi významný. V případech kde je náhodnost jevu vyšší (třeba kdy dominantní vliv na odtok vody z povodí mají srážky) se vyplácí zvyšovat parametr, protože ze statistického hlediska vychází přesnější předpověď. To, jak moc velkou náhodností je zkoumaný jev zatížen, ovlivňuje i volbu parametrů PST a W. Například pokud je jev velmi náhodný, mění se poloha s každou jinou změnou parametru NPHP nebo W velmi významně v rámci mapy PST. S ohledem na velkou náhodnou chybu zkoumaného jevu, je nalezení parametrů modelu podobnosti v průběhu kalibrace modelu obtížný proces. V rámci práce je používáno množství různých metod jak proces nejednoznačné kalibrace ulehčit. I přes množství ulehčujících metod, je na konci procesu kalibrace vybrána jedna volba parametru z celého spektra, v které se optimální parametr pohybuje. Změna architektury modelu podobnosti byl mohla spočívat v tom, že se zvyšující se hodnotou parametru NHPH by ostatní dva parametry PST a W byly náhodně volny v určité spektru kolem optimální volby parametr a tím by kopírovali skutečnost, že rozptyl volby optimálního parametru pro profily s velkou náhodností je skutečně velký.

11 Literatura

Abrahart, R.J., See, L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. Hydrological Processes, 14, 2157-2172.

Astatkie, T, Watts, D G, Watt, W E. Nested threshold autoregressive (NeTAR) models. International Journal of Forecasting, 1997, 13(1), 105-116.

B Sivakumar and A.W Jayawardena, An investigation of the presence of low-dimensional chaotic behavior in the sediment transport phenomenon, *Hydrol. Sci. J.* **47** (3) (2002), pp. 405–416.

Ballini, R.; Soares, S.; Andrade, M.G., 2001. Multi-step-ahead monthly streamflow forecasting by a neurofuzzy network model. Proceedings of the Joint 9th IFSA World Congress and 20th NAFIPS International Conference, Vol. 2, Vancouver, Canada, 992-997.

Birikundavyi S, Labib R, Trung HT, Rousselle J., 2002. Performance of neural networks in daily streamflow forecasting. J. Hydrol. Eng., 7 (5), 392-398.

C. Barbălată and L. Leuştean, *Average monthly liquid flow forecasting using neural network*

Cai Y., Wang D.M., 1996. Correlation analysis between the land surface temperature field and the variation of the runoff within a year. Plateau Meteorology, 15(4), 472-477. (in Chinese)

Curry, K., Bras R.L., 1980. Multi-variate seasonal time series forecast with application to adaptive control. Technical Report 253, Ralph M. Parsons Laboratory, Department of Civil Engineering, Cambridge, MA:MIT.

Day G.N., 1985. Extended steramflow forecasting using NWSRFS. J. Water Resour. Plan. Manage, 111(2), 157-170.

De Roo APJ, Bartholmes J, Bates PD, Beven K et al., 2003. Development of a European Flood Forecasting System. Journal of River Basin Management, 1(1), 49-59.

Dibike Y.B., Solomatine D.P., 2001. River Flow Forecasting Using Artificial Neural Networks, Journal of Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere, 26(1), 1-8.

Farmer, D.J., Sidorowich, J.J., 1987. Predicting chaotic time series. Phys. Rev. Lett. 59, 845–848.

Fast, B., 1990. Analysis of seasonal inflow volume forevasts produced using regression equations. Operations Control Department, British Columbia Hydro. Canada.

Hamlet, A.F., Lettenmaier, D.P., 1999. Columbia River streamflow forecasting based on ENSO and PDO climate signals. J. Water Resour. Plan. Manage., 125(6), 333-341.

Han, D., I. D. Cluckie, D. Karbassioun, J. Lawry And B., 2002. Krauskopf. River Flow Modelling Using Fuzzy Decision Trees. Water Resources Management 16, 431–445.

HIPEL, K. W. *Time series analysis in perspective*. 1985. *Water Resour. Bull*. 21, 609–623.

Hu, T.S., Lam, K.C., Ng, S.T., 2001. River flow time series prediction with a range-dependent neural network. Hydrol. Sci. J., 46(5), 729-745.

Huo, S.Q., Rao S.Q., Xue J.G., 2001. Inflow forecast for the Sanmen Gorge reservoir of the Yellow River during non-flooding period. People's Yellow River, 23(12), 14-16 (in Chinese) .

Chang F.J., Chen Y.C., 2001. A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction. J. Hydrol., 245, 153-164.

Jayawardena, A.W., Lai, F., 1994. Analysis and prediction of chaos in rainfall and stream flow time series. J. Hydrol. 153, 23–52.

Kang, K. W., Kim, J. H., Park, C. Y., Ham, K. J., 1993. Evaluation of hydrological forecasting system based on neural network model. In: Proc., 25th Congress of Int. Assoc. for Hydr. Res., IAHR, Delft, The Netherlands, 257–264.

Kang, K. W., Kim, J. H., Park, C. Y., Ham, K. J., 1993. Evaluation of hydrological forecasting system based on neural network model. In: Proc., 25th Congress of Int. Assoc. for Hydr. Res., IAHR, Delft, The

Karlsson, M.S., 1985. Nearest neighbor regression estimators in rainfall-runoff forecasting. Ph.D thesis, University of Arizona.

Kasım KOÇAK, Aydın BALI, Bilal BEKTAŞOĞLU, 2007 Flow prediction of monthly flows by using chaotic approach, INTERNATIONAL CONGRESS ON RIVER BASIN MANAGEMENT, str. 553 – 559.

Kašpárek, L., Peláková, M., & Boersema, M. (2005). *Odhad objemu nádrží potřebného pro kompenzaci poklesu odtoku vlivem klimatické změny.* VÚV Praha, Praha.

Koçak, K., 2000: "Nonlinear time series prediction of O3 concentration in Istanbul". Atmospheric Environment, 34, 1267-1271.

Koçak, K., Şaylan, L., and Eitzinger, J., 2004: "Nonlinear Prediction of Near-surface Temperature via Univariate and Multivariate Time Series Embedding". Ecological Modelling, 173(1), pp:1-7.

M. Erol KESKİN, Emine Dilek TAYLAN, A. Gökhan YILMAZ, *Flow prediction model with fuzzy logic approaches: dim stream*

M. Shahjahan Mondal and Saleh A. Wasimi, *long-range prediction of flows in the ganges for water resources and agricultural management in bangladesh*

Mahabir, C., Hicks, F. E., Robinson Fayek. A., 2003. Application of fuzzy logic to forecast seasonal runoff. Hydrol. Process., 17, 3749–3762.

Mahabir, C., Hicks, F. E., Robinson Fayek. A., 2003. Application of fuzzy logic to forecast seasonal runoff. Hydrol. Process., 17, 3749–3762.

Markus, M., 1997. Application of neural networks in streamflow forecasting. Ph.D dissertation, Department of Civil Engineering, Colorado State University, Fort Collins, Colorado

McKerchar, A.I., Delleur, J.W., 1974. Application of seasonal parametric linear stochastic models to monthly flow data. Water Resources Research, 10, 246-255.

Menšík, P. (2012). *Automatizace řešení zásobní funkce vodohospodářské soustavy.* Brno: Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního.

Menšík, P., & Starý, M. (2012). SOMVS - Simulační a optimalizační model vodohospodaříské soustavy. Dostupné z: http://uvhk.fce.vutbr.cz/software.php.

Milanese, M., Novara, C., 2004. Nonlinear Set Membership prediction of river flow. Systems & Control Letters, 53, 31–39.

Mishra, A., Hata, T., Abdelhadi, A. W., Tada, A., Tanakamaru1, H., 2003. Recession flow analysis of the BlueNile River. Hydrol. Process., 17, 2825–2835.

Mizumura, K., 1995. Application of fuzzy theory to snowmelt-runoff. In: Kundzewicz, Z.W.(Ed.), New uncertainty concepts in hydrology and water resources, Cambridge University Press, New York.

Montanari, A., Rosso, R., Taqqu, M. S., 2000. A seasonal fractional ARIMA model applied to the Nile River monthly at Aswan. Water Resources Research, 36:1249-1259.

Nayak, P. C., Sudheer, K. P., Ramasastri, K. S., 2005. Fuzzy computing based rainfall–runoff model for real time flood forecasting. Hydrol. Process., 19, 955–968.

Netherlands, 257–264. Raman, H., Sunilkumar, N., 1995. Multivariate modeling of water resources time series using artificial neural network. Hydrol. Sci. J., 40(2), 145–163.

Noakes, D.J., McLeod, A.I., Hipel, K.W., 1985. Forecasting monthly riverflow time series. International Journal of Forecasting, 1, 179-190.

Novara, C., Milanese, M., 2001. Set Membership prediction of nonlinear time series. In: Proceedings of the 40th IEEE Conference on Decision and Control, Orlando, U.S., 2131–2136.

Piechota, T.C., Dracup, J.A., 1999. Long-Range Streamflow Forecasting Using El–Nino Southern Oscillation Indicators, J. Hydrol. Eng., 4(2), 144-151

Pitman, W. V., 1973. A mathematical model for generating river flows from meteorological data in South Africa. Report no. 2/73, Hydrological Research Unit, University of the Witwatersrand, Johannesburg, South Africa.

Porporato, A., Ridolfi, L., 1996. Clues to the existence of deterministi chaos in river flow. Int. J. Mod. Phys. B 10, 1821–1862.

Porporato, A., Ridolfi, L., 1997. Nonlinear analysis of river flow time sequences. Water Resour. Res. 33 (6), 1353–1367.

Sivakumar B. Comment on “Estimation of missing streamflow data using principles of chaos theory” by Elshorbagy et al. J Hydrol 2002c, submitted for publication.

Solomatine, D.P., Dulal., K.N., 2003. Model trees as an alternative to neural networks in rainfall–runou modelling. Hydrological Sciences Journal, 48(3), 399–411.

Solomatine, D.P., Xue, Y., 2004. M5 model trees compared to neural networks: application to flood forecastingin the upper reach of the Huai River in China. Journal of Hydrological Engineering, 9(6), 491-501.

Sugihara, G., May, R.M., 1990. Nonlinear forecasting as a way of distinguishing chaos from measurement error in time series. Nature, 344, 734–741.

Thompstone, R.M., Hipel, K.W., Mcleod, A.I., 1985. Forecasting quarter-monthly riverflow. Water Resources Bulletin, 21(5), 731-741. Kuo I.T., Sun Y.H., 1993. An intervention model for average 10 day streamflow forecast and synthesis, Journal of Hydrology, 151(1), 35-56.

Tokar, A. S., Markus, M., 2000. Precipitation-runoff modeling using artificial neural network and conceptual models. J. Hydrological Eng., 5(2), 156–161.

Tomasino, M., Zanchettin D., Traverso, P., 2004. Long-range forecasts of River Po discharges based on predictable solar activity and a fuzzy neural network model. Hydro. Sci. J., 49(4), 673-684.

Tong, H., Lim, K. S., 1980. Threshold autoregression, limit cycles and cyclical data. Journal of the Royal Statistical Society (Series B), 42(3), 245-292.

Tucci, C.E.M., Clarke, R.T., Collischonn, W., da Silva Dias, P.L., de Oliveira. G.S., 2003. Long-term flow forecasts based on climate and hydrological modeling: Uruguay River basin. Water Resour. Res., 39(7), SWC3-1-11.

Uvo, C.B., Graham, N.E., 1998. Seasonal runoff forecast for northern South America: A statistical model. Water Resour. Res., 34(12), 3515-3524.

Water Master Plan Project, 1983. Multi-lead forecasting of the River Nile streamflows. Technical Report 21 (UNDP/EGY/81/031), Ministry of Irrigation, Cairo, Egypt.

Wen Wang, J.K. Vrijlingb, Pieter H.A.J.M. Van Gelder, Jun Ma, 2005 Testing for nonlinearity of streamflow processes at different timescales, science direkt, journal of hydrology

Wen Wang, Stochasticity, Nonlinearity and Forecasting of Streamflow Processes, Editor: IOS Press, 2006, ISBN 1586036211, 9781586036218, 210s

Yakowitz, S., Karlsson, M., 1987. Neareast neighbour methods for time series with application to rainfall-runoff prediction. In: J.B. MacNeil and G.J. Umphrey (eds.), Stochastic Hydrology, D. Reidel, Dordrecht, 149-160.

Yurekli K., Kurung A., Ozturk F., 2005. Testing the Residuals of an ARIMA Model on the Cekerek Stream Watershed in Turkey. Turkish J. Eng. Env. Sci., 29, 61-74.

ZADEH, L. A. *Fuzzy sets*. 1965. *Information Control* 8(3), 338–353.

Zadeh, L.A., 1965. Fuzzy sets, Inform. Control Systems. 8, 338–353.

Zhang, B., Govindaraju, R.S., 2000. Prediction of watershed runoff using Bayesian concepts and modular neural networks. Water Res. Res., 36(3), 753-762.

Zhao, R. J., Liu X. R., 1995. The Xinanjiang model. In: Singh, V.P. (ed.) Computer Models of Watershed Hydrology. Water Resources Publications, 215-232.

Internetové stránky:

http://www.businessdictionary.com/definition/Box-Jenkins-B-J-models.html
http://en.wikipedia.org/wiki/Exponential_smoothing
http://en.wikipedia.org/wiki/Markov_model
http://en.wikipedia.org/wiki/Random_walk
http://cs.wikipedia.org/wiki/Teorie_chaosu
http://cs.wikipedia.org/wiki/Fázový_prostor
http://en.wikipedia.org/wiki/Phase_space
http://en.wikipedia.org/wiki/Topology
http://en.wikipedia.org/wiki/Takens%27_theorem
http://www.scholarpedia.org/article/Attractor_reconstruction
http://en.wikipedia.org/wiki/Mutual_information
http://en.wikipedia.org/wiki/Information_theory
http://balrog.wku.edu/~amaral/docs/chaospaper/node9.html
http://www.statsoft.com/textbook
http://www.nwrfc.noaa.gov/nwrfc/papers/esp_review/esp_review.html

12 Přílohy

12.1 Korelační analýza předpovědních profilů

V tabulkách je šest předpovědních profilů podrobně popsaných v kapitole XXX. Pro každý měsíc v roce jsou v tabulce vypočteny autokorelační funkce jednotlivých časových řad pro tři posuny ACF(1), ACF(2), ACF(3). Dále jsou v tabulce vypočteny korelační koeficienty mezi průtokovou řadou a srážkovou nebo teplotní. Koeficient určuje, jak ovlivňuje velikost průtoku srážka nebo teplota v tom samém měsíci CF(0), v tom předchozím CF(1), před dvěma měsíci CF(2).

			1	2	3	4	5	6	7	8	9	10	11	12	
Danube	Průtok	ACF(1)	0.692	0.658	0.574	0.676	0.808	0.783	0.793	0.731	0.774	0.643	0.657	0.777	**0.714**
		ACF(2)	0.539	0.420	0.329	0.369	0.533	0.466	0.552	0.552	0.544	0.427	0.347	0.570	**0.471**
		ACF(3)	0.369	0.240	0.273	0.297	0.276	0.310	0.300	0.368	0.432	0.199	0.300	0.352	**0.310**
	Srážka	ACF(1)	0.116	0.181	0.185	0.105	-0.077	0.031	0.143	0.214	0.107	0.157	0.097	0.339	**0.133**
		ACF(2)	-0.015	0.009	0.059	0.116	-0.070	0.015	0.144	0.087	-0.103	-0.109	0.082	-0.011	**0.017**
		ACF(3)	-0.021	0.006	0.049	-0.084	-0.036	0.066	0.082	0.128	-0.169	0.094	-0.064	-0.003	**0.004**
	Teplota	ACF(1)	0.283	0.329	0.390	0.183	0.151	0.283	0.326	0.437	0.198	0.182	0.093	0.007	**0.239**
		ACF(2)	0.051	0.063	0.239	0.266	0.102	0.175	0.259	0.228	0.237	0.019	0.143	-0.047	**0.144**
		ACF(3)	0.049	-0.124	0.188	0.161	0.034	0.229	0.296	0.334	0.066	-0.051	0.066	0.199	**0.120**
	Pr/Sr	CF(0)	0.109	0.116	0.342	0.148	0.122	0.272	0.328	0.285	0.127	0.236	0.214	0.354	**0.221**
		CF(1)	0.700	0.383	0.624	0.530	0.492	0.515	0.640	0.775	0.656	0.641	0.760	0.604	**0.610**
		CF(2)	0.459	0.481	0.377	0.351	0.466	0.441	0.458	0.405	0.590	0.415	0.447	0.518	**0.451**
	Pr/t	CF(0)	0.041	0.096	-0.014	-0.190	-0.190	-0.244	-0.305	-0.439	-0.209	-0.107	-0.027	-0.084	**-0.139**
		CF(1)	-0.027	-0.039	0.028	-0.076	0.092	-0.138	-0.207	-0.367	0.027	0.009	-0.116	-0.056	**-0.072**
		CF(2)	0.008	-0.050	0.073	-0.074	0.045	0.014	-0.160	-0.366	0.145	-0.021	-0.046	-0.209	**-0.053**

Rhein	Průtok	ACF(1)	0.399	0.342	0.338	0.563	0.647	0.670	0.586	0.738	0.799	0.610	0.682	0.592	**0.580**
		ACF(2)	0.135	0.410	0.107	0.261	0.397	0.448	0.341	0.518	0.473	0.520	0.381	0.369	**0.363**
		ACF(3)	0.188	0.244	0.228	0.138	0.304	0.464	0.248	0.469	0.397	0.197	0.419	0.163	**0.288**
	Srážka	ACF(1)	0.186	0.111	-0.026	0.087	-0.063	0.062	0.141	0.140	0.207	-0.072	0.074	0.106	**0.079**
		ACF(2)	-0.019	0.080	0.044	0.146	0.084	-0.020	0.131	0.062	0.265	0.092	0.039	0.041	**0.079**
		ACF(3)	-0.106	0.110	0.045	0.119	0.148	-0.080	0.220	0.032	-0.115	0.012	-0.095	0.061	**0.029**
	Teplota	ACF(1)	0.403	0.438	0.458	0.418	0.366	0.592	0.471	0.599	0.588	0.510	0.359	0.187	**0.449**
		ACF(2)	0.155	0.326	0.299	0.415	0.342	0.273	0.537	0.354	0.402	0.415	0.399	0.302	**0.352**
		ACF(3)	0.163	0.102	0.452	0.271	0.210	0.334	0.467	0.474	0.316	0.418	0.401	0.375	**0.332**
	Pr/Sr	CF(0)	0.640	0.761	0.583	0.549	0.332	0.325	0.595	0.515	0.484	0.492	0.555	0.532	**0.530**
		CF(1)	0.671	0.344	0.466	0.632	0.632	0.564	0.615	0.750	0.761	0.616	0.586	0.591	**0.602**
		CF(2)	0.192	0.265	0.134	0.291	0.311	0.349	0.254	0.310	0.512	0.450	0.316	0.337	**0.310**
	Pr/t	CF(0)	0.390	0.345	-0.144	-0.072	0.093	-0.019	-0.418	-0.314	-0.275	-0.180	0.136	0.174	**-0.024**

	CF(1)	-0.033	0.226	-0.048	-0.035	-0.088	0.250	-0.095	-0.130	-0.130	-0.035	0.129	-0.116	**-0.009**
	CF(2)	-0.216	0.275	0.192	-0.039	-0.102	0.106	-0.099	-0.114	-0.041	-0.049	0.089	-0.058	**-0.005**
Umpqa	**Průtok**	ACF(1)	0.520	0.260	0.345	0.418	0.546	0.583	0.774	0.803	0.468	0.116	0.243	0.473	**0.462**
		ACF(2)	0.219	0.318	0.267	0.223	0.282	0.418	0.514	0.684	0.385	0.117	0.066	0.208	**0.308**
		ACF(3)	-0.130	0.214	0.151	0.090	0.262	0.368	0.501	0.360	0.226	0.087	-0.109	-0.131	**0.157**
	Srážka	ACF(1)	0.330	-0.017	0.276	0.008	0.146	-0.047	0.057	0.156	0.012	0.057	0.020	0.206	**0.100**
		ACF(2)	0.094	-0.010	-0.141	-0.057	0.197	0.203	-0.097	-0.222	-0.211	-0.002	0.099	-0.002	**-0.012**
		ACF(3)	-0.035	0.139	-0.181	-0.081	0.192	-0.181	0.118	-0.022	-0.033	-0.250	-0.183	-0.023	**-0.045**
	Teplota	ACF(1)	0.348	0.180	0.204	0.247	0.184	0.243	0.145	0.315	-0.065	0.149	0.001	0.119	**0.172**
		ACF(2)	-0.124	-0.027	0.246	-0.007	0.316	0.215	0.056	0.358	0.035	0.103	0.169	0.205	**0.129**
		ACF(3)	0.209	0.078	0.069	0.077	0.124	0.235	0.153	0.067	-0.094	-0.088	0.120	0.229	**0.098**
	Pr/Sr	CF(0)	0.878	0.816	0.790	0.629	0.672	0.371	0.145	0.423	0.514	0.822	0.871	0.861	**0.649**
		CF(1)	0.592	0.305	0.445	0.382	0.382	0.361	0.399	0.126	0.332	0.172	0.299	0.463	**0.355**
		CF(2)	0.265	0.181	0.164	0.231	0.339	0.200	0.084	0.162	0.032	0.012	0.254	0.225	**0.179**
	Pr/t	CF(0)	0.195	0.146	-0.146	-0.268	-0.275	-0.458	-0.257	-0.299	-0.367	-0.276	0.025	0.309	**-0.139**
		CF(1)	-0.055	-0.188	0.057	-0.186	-0.002	-0.312	-0.101	-0.143	0.022	-0.013	0.001	0.200	**-0.060**
		CF(2)	-0.232	-0.093	-0.287	-0.079	-0.168	-0.243	-0.091	-0.064	0.100	-0.023	-0.065	0.063	**-0.098**
Morava	**Průtok**	ACF(1)	0.242	0.181	0.208	0.314	0.405	0.560	0.268	0.510	0.335	0.325	0.564	0.270	**0.348**
		ACF(2)	0.128	0.207	-0.045	-0.071	0.138	0.312	0.128	0.121	0.428	0.153	0.352	0.184	**0.170**
		ACF(3)	0.388	-0.063	0.036	-0.062	-0.028	0.134	0.048	0.231	0.063	0.355	0.297	0.233	**0.136**
	Srážka	ACF(1)	0.122	-0.056	0.172	-0.129	0.152	-0.122	-0.006	-0.031	-0.176	0.150	-0.177	-0.159	**-0.022**
		ACF(2)	-0.221	-0.140	0.126	0.132	-0.152	-0.011	0.007	0.093	-0.061	-0.236	-0.136	0.052	**-0.046**
		ACF(3)	0.172	-0.185	0.222	-0.213	-0.164	-0.110	0.022	0.180	-0.124	-0.027	0.101	-0.147	**-0.023**
	Teplota	ACF(1)	0.438	0.320	0.428	-0.073	0.259	0.351	0.264	0.319	-0.032	0.035	0.095	-0.194	**0.184**
		ACF(2)	-0.064	0.292	0.446	0.112	0.054	0.212	0.304	0.246	0.372	-0.268	-0.023	-0.169	**0.126**
		ACF(3)	-0.010	-0.076	0.328	0.132	0.058	0.079	0.187	0.450	0.084	-0.022	0.037	0.133	**0.115**
	Pr/Sr	CF(0)	0.461	0.238	0.579	0.250	0.612	0.495	0.546	0.639	0.657	0.590	0.554	0.390	**0.501**
		CF(1)	0.447	0.158	0.385	0.305	0.498	0.603	0.367	0.492	0.311	0.198	0.317	0.142	**0.352**
		CF(2)	-0.144	0.368	0.237	0.271	-0.100	0.227	0.041	0.121	0.351	0.120	0.167	0.050	**0.142**
	Pr/t	CF(0)	0.318	0.596	0.062	0.055	-0.359	-0.254	-0.286	-0.302	-0.367	-0.184	0.354	0.427	**0.005**
		CF(1)	0.064	0.056	0.171	0.130	-0.196	-0.108	-0.138	-0.223	-0.241	0.283	0.079	-0.226	**-0.029**
		CF(2)	-0.112	0.149	0.119	0.245	0.193	-0.079	0.120	-0.386	-0.118	0.056	-0.241	-0.120	**-0.015**
Jihlava	**Průtok**	ACF(1)	0.457	0.268	0.245	0.529	0.582	0.650	0.460	0.304	0.637	0.641	0.840	0.375	**0.499**
		ACF(2)	0.119	0.193	-0.063	-0.030	0.347	0.423	0.375	0.117	0.345	0.633	0.596	0.291	**0.279**
		ACF(3)	0.175	0.219	-0.109	-0.066	-0.124	0.462	0.304	0.116	0.068	0.204	0.626	0.306	**0.182**
	Sráž ka	ACF(1)	0.198	-0.129	0.126	-0.147	-0.044	0.123	0.015	0.028	-0.176	-0.184	-0.004	-0.013	**-0.017**

		ACF(2)	-0.194	-0.203	0.015	0.069	-0.209	-0.063	-0.016	0.233	-0.127	0.188	0.066	0.038	**-0.017**
		ACF(3)	0.073	-0.281	0.256	-0.275	-0.101	-0.054	0.119	0.054	-0.048	0.218	0.184	-0.162	**-0.002**
	Teplota	ACF(1)	0.367	0.226	0.419	-0.109	0.241	0.283	0.086	0.350	0.018	-0.075	-0.054	-0.315	**0.120**
		ACF(2)	-0.148	0.272	0.365	0.135	0.039	0.200	0.231	0.038	0.257	-0.224	-0.099	-0.288	**0.065**
		ACF(3)	-0.168	-0.097	0.305	0.088	0.144	0.073	0.089	0.413	0.038	-0.025	0.071	0.111	**0.087**
	Pr/Sr	CF(0)	0.611	0.207	0.405	0.134	0.778	0.408	0.738	0.760	0.421	0.592	0.377	0.707	**0.511**
		CF(1)	0.537	0.341	0.448	0.272	0.210	0.528	0.288	0.394	0.572	0.205	0.522	0.297	**0.385**
		CF(2)	0.040	0.332	0.231	0.348	-0.055	0.189	0.259	0.279	0.308	0.603	0.254	0.247	**0.253**
	Pr/t	CF(0)	0.155	0.466	-0.264	-0.069	-0.288	-0.104	-0.278	-0.052	-0.209	0.114	0.263	0.451	**0.015**
		CF(1)	0.219	0.009	0.184	0.085	-0.138	-0.293	-0.165	-0.123	-0.175	0.443	0.275	-0.320	**0.000**
		CF(2)	-0.220	0.122	-0.142	0.205	0.181	0.091	-0.213	-0.363	0.079	0.064	-0.058	-0.257	**-0.043**

Oslava	**Průtok**	ACF(1)	0.448	0.236	0.334	0.384	0.579	0.585	0.331	0.490	0.476	0.661	0.554	0.395	**0.456**
		ACF(2)	0.269	0.087	-0.081	0.034	0.149	0.449	0.150	0.267	0.260	0.520	0.389	0.271	**0.230**
		ACF(3)	0.278	0.025	-0.171	-0.071	-0.119	0.301	0.175	0.335	0.221	0.307	0.314	0.332	**0.161**
	Srážka	ACF(1)	0.065	0.036	0.154	-0.219	-0.030	0.028	0.077	-0.046	-0.341	-0.152	-0.027	-0.098	**-0.046**
		ACF(2)	-0.062	-0.339	0.007	0.029	-0.138	-0.077	0.004	0.107	-0.168	-0.038	0.072	0.071	**-0.044**
		ACF(3)	0.195	-0.208	0.115	-0.173	-0.126	0.043	-0.190	0.230	0.009	0.175	0.063	-0.059	**0.006**
	Teplota	ACF(1)	0.393	0.285	0.430	-0.045	0.257	0.380	0.230	0.303	0.004	0.001	0.018	-0.169	**0.174**
		ACF(2)	-0.083	0.301	0.398	0.147	0.083	0.206	0.267	0.223	0.368	-0.298	0.026	-0.209	**0.119**
		ACF(3)	-0.037	-0.096	0.331	0.131	0.078	0.127	0.202	0.467	0.066	0.031	0.115	0.173	**0.132**
	Pr/Sr	CF(0)	0.525	0.186	0.593	0.259	0.792	0.434	0.717	0.616	0.414	0.403	0.401	0.615	**0.496**
		CF(1)	0.451	0.386	0.376	0.344	0.189	0.536	0.382	0.471	0.301	0.167	0.439	0.265	**0.359**
		CF(2)	0.097	0.300	0.323	0.193	-0.040	0.124	0.226	0.268	0.224	0.381	0.304	0.233	**0.219**
	Pr/t	CF(0)	0.158	0.402	-0.104	-0.008	-0.264	-0.209	-0.182	-0.308	-0.123	0.152	0.123	0.375	**0.001**
		CF(1)	0.200	-0.004	0.153	0.260	-0.158	-0.325	-0.131	-0.112	-0.009	0.392	0.035	-0.165	**0.011**
		CF(2)	-0.067	0.036	-0.117	0.131	0.178	0.010	-0.135	-0.455	0.216	0.050	-0.246	-0.185	**-0.049**

12.2 Zobrazení volby parametrů modelu podobnosti v jednotlivých profilech

Tato příloha obsahuje zobrazení charakteru profilu, mapy PST, zobrazení vývoj kontrolních kvadrantů a vývoje vah pro jednotlivé předpovědní profily. Tyto zobrazení byly podkladem pro volbu parametrů modelu podobnosti. S ohledem na obsáhlost těchto příloh, jsou přílohy v elektronické podobě.

12.2.1 Dunaj

12.2.2 Rýn

12.2.3 Umpqua

12.2.4 Morava

12.2.5 Jihlava

12.2.6 Oslava