



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STAVEBNÍ

FACULTY OF CIVIL ENGINEERING

ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

INSTITUTE OF LANDSCAPE WATER MANAGEMENT

STOCHASTICKÉ ŘÍZENÍ ZÁSOBNÍ FUNKCE
NÁDRŽE

STOCHASTIC MANAGEMENT OF WATER RESERVOIR STORAGE FUNCTION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

David Pruch

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. TOMÁŠ KOZEL, Ph.D.

BRNO 2019



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STAVEBNÍ

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

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Student	David Pruch
Název	Stochastické řízení zásobní funkce nádrže
Vedoucí práce	Ing. Tomáš Kozel, Ph.D.
Datum zadání	30. 11. 2018
Datum odevzdání	24. 5. 2019

V Brně dne 30. 11. 2018

prof. Ing. Miloš Starý, CSc.
Vedoucí ústavu

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

PODKLADY A LITERATURA

- Starý, M.: Nádrže a vodohospodářské soustavy, skriptum. FAST VUT Brno, 2006.
- Starý, M.: Hydrologie, skriptum, FAST VUT Brno, 2005.
- Starý, M.: Nádrže a vodohospodářské soustavy, met. návody do cvičení 1. vyd. Brno: VUT, 1987
- Starý, M.: Nádrže a vodohospodářské soustavy, 1. vydání Brno: VUT, 1986 skriptum.
- Nacházel K., Starý M., Zezulák J.: Využití metod umělé inteligence ve vodním hospodářství, kniha, 320 stran, Academia, 2004, ISBN 80-200-0229-4.

ZÁSADY PRO VYPRACOVÁNÍ

Student si na vedoucím vybraném měrném profilu navrhne vodohospodářskou nádrže se zásobní funkcí, u které provede stochastické řízení pro vybrané kvantily. Následně vyhodnotí úspěšnost celého řízení.

STRUKTURA BAKALÁŘSKÉ PRÁCE

VŠKP vypracujte a rozčleňte podle dále uvedené struktury:

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

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

ABSTRAKT

Stochastické řízení zásobní funkce vodní nádrže pracuje s určitým počtem hodnot předpovězených průtoků s určitým pravděpodobnostním rozdělením. Pro požadavek stochastického řízení zásobní funkce nádrže byl sestaven stochastický předpovědní model fungující na principu metody LHS. Model pracuje s náhodnými procesy, mezi které patří průtok v daném měrném profilu. Stochastické řízení má výhodu naproti deterministickému řízení v eventualitě výběru řízení pro určitý pravděpodobnostní scénář. V práci jsou popsány velmi stručně některé deterministické metody, ale i některé stochastické metody. Dále je v práci popsán postup pro řízení zásobního funkce nádrže pomocí metody LHS. Navrhnutý model byl otestován na fiktivní nádrži. Na závěr byly vybrány nejlepší a nejhorší výsledky, které byly následně porovnány, a tak se mohlo tedy určit, které nastavení výpočtu byl ideální pro řízení.

KLÍČOVÁ SLOVA

Vodní nádrž, průměrný měsíční průtok, stochastická, předpověď, stochastické řízení, zásobní funkce.

ABSTRACT

The stochastic control of the reservoir storage function works with a certain number of control flow values with a certain probability distribution. For the requirement of stochastic control of the reservoir storage function, a stochastic prediction model based on the LHS method was compiled. The model works with random processes, which include flow in a specific measurement profile. Stochastic control has the advantage over deterministic control in the possibility of selecting a control for a particular probability scenario. Some deterministic methods as well as some stochastic methods are described very briefly. Furthermore, the thesis describes the procedure for the control of the reservoir storage function using the LHS method. The model was tested on a fictitious reservoir. In conclusion, the best and worst results were selected, which were then compared, so it could be determined which parameters of calculation was most ideal for driving.

KEYWORDS

Large open water reservoir, average monthly flow, stochastic forecasting, storage function.

BIBLIOGRAFICKÁ CITACE

David Pruch *Stochastické řízení zásobní funkce nádrže*. Brno, 2019. 46s. příl. Bakalářská práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Tomáš Kozel, Ph.D.

PROHLÁŠENÍ O SHODĚ LISTINNÉ A ELEKTRONICKÉ FORMY ZÁVĚREČNÉ PRÁCE

Prohlašuji, že elektronická forma odevzdané bakalářské práce s názvem *Stochastické řízení zásobní funkce nádrže* je shodná s odevzdanou listinnou formou.

V Brně dne 14. 5. 2019

David Pruch
autor práce

PROHLÁŠENÍ O PŮVODNOSTI ZÁVĚREČNÉ PRÁCE

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

V Brně dne 14. 5. 2019

David Pruch
autor práce

Poděkování:

Úvodem práce bych rád poděkoval školiteli Ing. Tomášovi Kozlovi, Ph. D. za cenné rady, náměty a připomínky, které mi dával v průběhu bakalářského studia a při psaní bakalářské práce. Dále chci poděkovat svým rodičům a mé rodině za podporu, velkou trpělivost a porozumění, které mi věnovali v průběhu celého studia a zejména při psaní bakalářské práce.

OBSAH

1	ÚVOD	2
2	CÍLE BAKALÁŘSKÉ PRÁCE	4
3	ROZDĚLENÍ METOD	5
3.1	Deterministické metody	6
3.1.1	Arima	6
3.1.2	Sarima	7
3.1.3	Lineární autoregresivní	8
3.1.4	Zonální model	8
3.2	Stochastické metody	10
3.2.1	Monte Carlo	10
3.2.1	Modifikovaný zonální	11
3.2.2	LHS (Metoda Latin Hypercube Sampling)	11
3.2.3	Markovovy řetězce	12
4	POUŽITÝ SOFTWARE	14
4.1	Program Matlab	14
4.2	Stochastický model	15
4.2.1	Způsob řízení nádrže	16
4.2.2	Čára pravděpodobnosti překročení ročních průtoků	17
4.2.1	Statistické charakteristiky	18
4.2.2	Box-Cox transformace	19
5	APLIKACE	20
5.1	Historická data	21
5.2	Kalibrace a validace řídicího modelu	22
6	VÝSLEDKY	23
6.1	Dosažené výsledky	23
6.1.1	Shrnutí celkových výsledků	31
7	ZÁVĚR	33
8	SEZNAM ZKRATEK A SYMBOLŮ	34
9	POUŽITÁ LITERATURA	36
10	SEZNAM OBRÁZKŮ	38
11	SEZNAM TABULEK	39

1 ÚVOD

Průměrný měsíční průtok (Q) v měrném profilu se dá považovat za stochastický náhodný proces (Swanidze 1961), u kterého se nedá s přesností určit jeho budoucí hodnoty. Je však možné do určité míry odhadnout pravděpodobnosti jejich dalšího výskytu. A proto předpovídat hodnoty deterministicky je značným zjednodušením. Předpověď pomocí deterministického procesu může obsahovat chybu a její využití pro řízení by mohlo vést k poruchám. K dané problematice je tedy potřeba přistupovat stochasticky a přinejmenším určit pásmo jejich možné přítomnosti s určitým pravděpodobnostním rozdělením. Pásmo s možností výskytu se s přibývajícím délkou předpovědi rozšiřuje. Předpovězená pásma výskytu budoucích přítoků se dají získat za pomoci předpovědních modelů, které vycházejí z historicky naměřených průtoků. V této práci řízení zásobní funkce nádrže využívá měsíční krok.

V současnosti je praxe taková, že při řízení zásobní funkce nádrže se používají hlavně dispečerské grafy a deterministické modely. Na akademické úrovni je úsilí o optimalizaci řízení s využitím deterministických popřípadě stochastických předpovědí. U využití deterministických předpovědí je pouze jeden výstup řídicí veličiny. Ovšem při využívání jenom jedné hodnoty a značnému zjednodušení dochází ke ztrátě přesnosti řízení (skutečnost se může lišit od předpovědi, kterou jsme předpokládali). Avšak stochastické řízení naproti deterministickému dovoluje pracovat s určitým rozptylem hodnot řízených odtoků. Při správné aplikaci vyhodnocení dochází k snížení nebezpečí selhání provozu zásobní funkce nádrže. Nesporným přínosem stochastického řízení je možnost výběru řízeného odtoku pro určitou pravděpodobnost překročení předem. Rozsah řízených odtoků skýtá určité eventuality výběru řízeného odtoku podle pravděpodobností překročení. S výše popsaného textu tedy vyplývá, že je lepší přejít z deterministického řízení na stochastické.

Problematika stochastického řízení zásobní funkce nádrže bude řešena v této práci nastíněna. Pro řízení izolované nádrže s jedním přítokem a jedním odtokem vody z nádrže budou použity stochastické předpovědi přítoků vody do nádrže. Při tomto způsobu řízení se může vycházet z metody Monte Carlo nebo z metody Latin hypercube sample LHS. Princip metody LHS je použit při vytváření předpovědí, které vycházejí z historicky naměřené průtokové řady. Stochastické řízení zásobní funkce nádrže je takové, u kterého v následujícím každém kroku při výpočtu, při plnění zásobního objemu nádrže bude probíhat výpočet možných

řízených budoucích odtoků z náhodně předpovězených přítoků. Jsou tedy hledány nejlepší kvantily pro vytváření předpovědi a následně provedeno řízení.

2 CÍLE BAKALÁŘSKÉ PRÁCE

Cíl práce spočívá v sestavení algoritmu předpovědního modelu s využitím metody LHS (Latin Hypercube Sampling) a jeho následné vyhodnocení. A pokusu o využití pro stochastické řízení zásobní funkce nádrže.

Práce je rozdělena do dvou částí. V první části jsou nastíněny deterministické a stochastické předpovědními modely.

Druhá část práce se zabývá aplikací zvoleného modelu pro vybraný měrný profil. Předpovědní model pro řízení je naprogramován v programu Matlab.

3 ROZDĚLENÍ METOD

V současnosti se obyčejně v praxi v ČR nepoužívá stochastické řízení zásobní funkce nádrže. Zpravidla bývá zásobní funkce řízena pomocí dispečerských grafů. V budoucnu se očekává zvýšení tlaku na využívání vodních nádrží efektivněji, a proto jsou vyhledávány jiné možnosti jak řídit zásobní funkci nádrže bez použití dispečerských grafů, které formulují závislost objemů vody v nádrži na celkovém odtoku v průběhu roku, z důvodů předpokládané změny klimatu. Každé vodní dílo má tyto grafy jako součást manipulačního řádu. Jestliže dílčí díla spolupracují v daném systému, je vytvořen pro tuto soustavu manipulační řád.

V této kapitole se okrajově podíváme na deterministické metody, které by se daly eventuálně použít pro stejný typ úlohy řešené v bakalářské práci. Dále si přiblížíme některé stochastické metody.

V bakalářské práci byla aplikována metoda LHS respektive Latin Hypercube Sampling (dále jen LHS), která se řadí mezi stochastické a v dalším textu bude podrobněji popsána její konkrétní aplikace.

3.1 DETERMINISTICKÉ METODY

V současnosti jsou v praxi aplikovány při řízení zásobní funkce nádrže z velké části deterministické metody respektive modely. Výhoda deterministických modelů spočívá v pouze jednom výstupu (hodnota) řídicí veličiny, nicméně při využívání pouze jedné hodnoty dochází v důsledku silného zjednodušení problematiky ke ztrátě přesnosti řízení či nesprávnému vyhodnocení situace (předpověď by se mohla zřetelně odlišovat od skutečnosti, která byla předpokládána). [1]

3.1.1 Arima

U procesu Arima se zpočátku při identifikaci časové řady zaměřuje na prozkoumání jejího grafu. Často totiž lze na první pohled poznat, že se jedná o nestacionární řady, je zde přítomnost trendu anebo další problémy, kterými mohou být odchýlená pozorování, sezónnost apod. V tomto stádiu se jedná ale především o subjektivní zhodnocení. Avšak na základě těchto zhodnocení už je eventuelně možné případnou vhodnou transformací převést řadu na stacionární časovou řadu, nebo udělat jiné úpravy, kterými může být linearizme časové řady, resp. její stabilizace z hlediska rozptylu pomocí logaritmické transformace. Tuto transformaci je nicméně dobré provádět před vlastním diferencováním časové řady. Může se stát, že se diferencováním dají získat i záporné hodnoty.

Dalším krokem je posoudit výpočet odhadů ACF (autokorelací funkce) a PACF (parciální autokorelací funkce) prvotní časové řady. Na tomto základě se dá potvrdit, jestli je časovou řadu potřeba stacionarizovat (toto nastane v případě, když hodnoty výběrové ACF a PACF v prvním kroku zpoždění jsou velice blízké jedné a ostatní hodnoty výběrové ACF klesají pomalu).

Poté co byla provedena stacionarizace časové řady je snaha určit, který proces časovou řadu generuje. Využívají se výběrové procesy ACF a PACF pro identifikaci modelů AR (autoregresní proces) a MA (proces klouzavých součtů). Identifikace se opírá o princip podobnosti výběrové ACF a PACF s teoretickými ACF a PACF, na kterých je proces B-J (Box-Jenkins) založen. [2]

3.1.2 Sarima

Tab. 1. Tvary ACF a PACF procesů AR, MA a ARMA

Model	ACFE	PACF
AR(p)	exponenciální a/nebo exponenciálně sinusoidní pokles	$\phi_{kk} = 0$ pro $k > p$
MA(q)	$\rho_k = 0$ pro $k > p$	Omezená exponenciálním a/nebo exponenciálně sinusoidním poklesem
ARMA(p, q)	Od zpoždění ($q - p$) pro $q > p$ exponenciální nebo exponenciálně sinusoidní pokles	Od zpoždění ($p - q$) pro $p > q$ omezená exponenciálním nebo exponenciálně sinusoidní pokles

Je-li v časové řadě také přítomna sezónní složka, je nutné identifikovat model typu SARIMA. Principiálně se však jedná o totéž co v případě ARIMA.

V prvním kroku je zapotřebí časovou řadu stacionarizovat. Pokud je zapotřebí, tak proběhne linearizace řady pomocí logaritmické transformace. Následně se řada diferencuje, kde se musí dbát na to, že sezónní diference obsahuje i diferenci prostou. Stacionarizace, která proběhne pomocí sezónní diference, tak značí tvar výběrové ACF a PACF. Tyto funkce charakterizují vysoké hodnoty v nesezónních frekvencích.

V následující fázi výpočtu probíhá výpočet výběrové ACF a PACF pro stacionarizovanou časovou řadu, díky čemuž se poté určí typ sezónních modelů SAR (sezónní autoregresní proces), SMA (sezónní proces klouzavých průměrů) nebo SARMA (smíšené sezónní a nesezónní procesy). U sezónních frekvencí bývají tyto funkce statisticky významně odlišné od nuly, avšak tyto hodnoty nebývají až tak vysoké, aby umožňovali časovou řadu považovat za stacionární. Dále, když je určen model sezónní složky je zapotřebí spočítat výběrovou ACF a PACF tentokrát pro rezidua sezónního modelu. Potom se na tomto základě posoudí, zda je vhodné model doplnit o člen AR, MA nebo ARMA (autoregresivní proces klouzavých součtů).

Právě proto že ACF a PACF jsou náhodně vychýleny oproti teoretickým hodnotám, tak umožňují jen hrubý odhad typu procesu a řádu procesu, které probíhají v jednotlivých složkách. Praxe je taková, že se odzkouší více alternativních modelů a vyberou se z nich ty, které obsahují všechny parametry statisticky významné, a na tomto základě se dále vybere model, který skýtá nejlepší vysvětlení. [2]

3.1.3 Lineární autoregresivní

Lineární autoregresivní model, který funguje na principu, že předpovídá průměrné měsíční hodnoty průtoků podle lineární kombinace hodnot průměrných měsíčních předchozích průtoků (v hladině Z , tedy transformované hodnoty průtoků), náhodných čísel a autoregresních koeficientů. Pro určení autoregresních koeficientů byly využity Yule-Walkerovy rovnice. Po vyřešení těchto rovnic dostaneme koeficienty, které jsou transformovány spolu s průtoky na normované normální rozdělení, které tvoří dvojice, a s jejichž pomocí dle rovnice (1) dostáváme předpovídaný průtok. Během výpočtu použije model předem daný počet měsíců zpětně (2 - 11) a vypočte opakující se předpověď na předem požadovaný počet měsíců dopředu (1 - 12). Dané předpovědi jsou poté dále zpětně transformovány na rozdělení, odpovídající měsíci, pro který byla předpověď vypočtena. Jestliže je vyžádána předpověď delší než 1 měsíc, tak se předpověď posune o jeden krok (měsíc) dopředu a celý výpočet se opakuje. Z toho vyplývá, že pokud je požadována předpověď delší než 1 měsíc, dostávají se do modelu mimo data reálné řady také předpovědi poskytnuté modelem rovnice (1). [3]

Tvar základní rovnice lineárního autoregresivního modelu:

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

$Z_{i,j}$ až $Z_{i,j-k}$ značí předchozí hodnoty průměrných měsíčních průtoků transformované na hladinu Z

a_1, a_2 až a_k jsou regresní koeficienty

3.1.4 Zonální model

Jednou z výhod zonálních předpovědních modelů vůči klasickým předpovědním modelům spočívá v tom, že obsahují historická naměřená data, což jsou průměrné měsíční průtoky v daném měsíci, ve kterém předpověď probíhá, tak se rozdělí do zón výskytu. Průměrné měsíční průtoky historické řady se uspořádají v daném měsíci a na jeho konci je uvedena předpověď od nejmenší po největší podle měsíce s konečným měřeným průtokem a je rozdělena do předem připraveného počtu zón. Průměrné měsíční průtoky reálné průtokové řady, které se nacházejí v určité zóně a jejich následné procesy (délka bývá určena délkou předpovědi průtoků), které tvoří pracovní pásmo průtoků (zón). Další historické průběhy reálné průtokové řady už nebývají využity pro tvorbu předpovědi. Poté jsou ve vybrané zóně data oprostěna asymetrie, čímž z takto transformovaných dat dochází ke zkonstruování

trojúhelníkového rozdělení (přibližná hodnota hustoty pravděpodobnosti kvůli malému počtu realizací v některých zónách). Za předpovězený průtok se vybere modus předpovědi. Jednou s výhod zatřídění průtoků bývá, že jestliže se průtok, podle kterého je zatříděna předpověď do zóny a nachází se v zóně malých průtoků, daná předpověď bude obsahovat průtoky v určitém rozmezí, které jsou s tou danou konkrétní zónou spojeny historickou přítomností. [3]

3.2 STOCHASTICKÉ METODY

Stochastické metody pracují se specifickým rozptylem hodnot řídicích průtoků s daným předpovědním pravděpodobnostním rozdělením, a z toho důvodu dochází k výrazně lepší aproximaci skutečné problematiky řízení. Výhoda stochastického řízení je možnost výběru řízení pro určitou pravděpodobnost scénáře. Vějíř možností poskytuje výběr pravděpodobností. [1]

3.2.1 Monte Carlo

Algoritmy, které vycházejí z metody Monte Carlo mají jednu společnou charakteristiku a to výpočet, který vychází z mnohokrát opakovaných náhodných pokusů (odhad náhodné veličiny). Touto metodou lze řešit úlohy stochastické ale i deterministické.

Odhady veličiny θ , kterou hledáme, se získávají pomocí statistické cesty a obsahují tedy pravděpodobnostní charakter. Odhady $(\theta_1, \theta_2, \dots, \theta_n, \dots)$ tedy prohlásíme za hledanou hodnotu veličiny θ , které jsou získány zpracováním statistických experimentů, které byly obdrženy jakožto výsledek častokrát opakovaných náhodných pokusů. Je požadováno, aby v tomto konkrétním případě veličina (θ_n) , kde n udává počet pokusů, a která je takzvanou veličinou náhodnou, při $(n \rightarrow \infty)$ a přibližovala se k hledané hodnotě (θ) v pravděpodobnosti. Tím se rozumí vyhovit vztahu, aby pro libovolně malé $(\varepsilon > 0)$ platilo

$$\lim_{n \rightarrow \infty} P(|\theta_n - \theta| < \varepsilon) = 1 \quad (2)$$

Výběr odhadu (θ_n) je daný typem a specifikujícími zvláštnostmi řešené úlohy. Výsledek pak má pokaždé povahu statistického charakteru. Z již zmíněného vztahu tedy vyplývá, že můžeme dosáhnout potřebné přesnosti pomocí zvyšování počtu náhodných pokusů. Může se však stát, že příliš velký počet náhodných pokusů zapříčiní velkou časovou náročnost a proto je nutné hledat takové optimalizace, které dosáhnou dostatečné přesnosti i s rozumným počtem opakování.

Hledání diferenciálních rovnic, které by mohly odpovídat náhodným procesům, tak to se ukázalo jako nepraktické. Čím dál tím víc se začal protlačovat model, kdy se naopak hledá pravděpodobnostní model, který by byl spíše shodný s analytickým řešením. Díky rozvoji výpočetní techniky se ukazuje, že je tato metoda stále užitečnější. V rámci zmíněného přístupu se musí vždy sestavit takový pravděpodobnostní model, který má parametry, které

reprezentují řešení formulované úlohy. V praxi jsou zajímavé jenom ty pravděpodobnostní modely, jež připouštějí víceméně jednoduchou realizaci a jsou uskutečnitelné na současných počítačích a zároveň dovolují získávat odhady neznámých parametrů (výsledky s hodnotami daných úloh) s co možná nejmenší chybou (která se může měřit např. rozptylem).

Nemusíme ani znát explicitní matematický popis konkrétního zkoumaného systému. Protože je využíván pravděpodobnostní model, dá se systém považovat za „černou skříňku“. Tento faktor skýtá možnost využití metody Monte Carlo pro vyřešení úloh nejrozmanitějšího typu. [4]

3.2.1 Modifikovaný zonální

Pracovní oblast průtokových řad je rozdělena do zón stejně jako u zonálního modelu. Tento modifikovaný zonální model se odlišuje tím, že aplikuje lineární autoregresní model na předem vybranou zónu. Historicky naměřené průtoky budou převedeny na stupeň hladiny Z . Zóna je vytyčena pro pracovní měsíc pokaždé dle posledního naměřeného průtoku. Korelační matice, která je hlavním vstupem do Yule-Walkerových rovnic, které jsou počítány jenom z historicky měřených průtoků objevujících se v přiřazené zóně. Ke zbývajícím datům už model nemá při tvorbě korelační matice přístup. Po sestavení korelační matice se s použitím Yule-Walkerových rovnic vyčíslí regresní koeficienty. Následný postup při sestavování modelu je potom stejný jako v případě modelu lineárního autoregresního. [3]

3.2.2 LHS (Metoda Latin Hypercube Sampling)

Metoda byla poprvé popsána pány McKayem (1979) a Eglasem (1977). Následně byla rozvinuta Imanem (1981), který dohromady ve spolupráci se svými spolupracovníky zveřejnil zdrojový kód a návod k použití. Metoda LHS spočívá v principu rozdělení definičního oboru funkce hustoty pravděpodobnosti každé další základní náhodné veličiny X_i (průměrné měsíční průtoky) na N_{Sim} (počet intervalů u metody LHS) intervaly, které nemají společný prvek. Intervaly jsou voleny o identické pravděpodobnosti $1/N_{Sim}$. Praxe v současnosti nabývá reprezentativní parametr intervalu jakožto střed daného intervalu N_{Sim} na distribuční funkci a bere jej v potaz jako výchozí pro nabytí reprezentativní hodnoty veličiny s pomocí inverzní transformace distribuční funkce. Řeč je o stratifikační metodě, kde vrstva oboru hodnot kumulativní distribuční funkce náhodné veličiny bývá nahrazena jedinou hodnotou. Rozčlenění na intervaly zabezpečuje, že rozsah všech náhodných veličin je realizován

rovnoměrně vzhledem k distribuční funkci. Potom je zde uvedeným postupem docíleno, že ani jedna reálná hodnota není dopředu vyloučena. Všechny vrstvy se použijí jen jednou. Konečným krokem je vhodné seskupení vzorků pomocí celých náhodných permutací.

Tato metoda je často využívána u teorie kontinua, kde bylo prokázáno, že i při malém počtu opakování dokáže dosáhnout s nějakou určitou ztrátou přesnosti také dobrých výsledků jako při využití většího počtu opakování u metody Monte Carlo. [3]

3.2.3 Markovovy řetězce

Při posloupnosti náhodných diskrétních veličin X_0, X_1, X_2, \dots s hodnotami z vypočítané množiny stavů, která má obvykle tvar $\{1, 2, \dots\}$.

Indexována je diskrétním časem s hodnotami z množiny $N_0 = \{0, 1, 2, \dots\}$

Ze stanoviska okamžiku t rozlišujeme budoucnost ($>t$) a minulost ($<t$)

Jsou dány pravděpodobnosti počátečních stavů (=rozdělení náhodné veličiny X_0)

$$p_i(0) = p_{X_0}(i), \quad (3)$$

nebo stanovený počáteční stav k , to znamená

$$p_i(k) = \delta_{ik} = \begin{cases} 1 & \text{pro } i = k, \\ 0 & \text{pro } i \neq k, \end{cases} \quad (4)$$

přechod pravděpodobnosti ze stavu i do stavu j během jednoho kroku,

$$p_{ij} = P(X_{t+1} = j \mid X_t = i), \quad (5)$$

(nezávislé na čase t) pro více stavů jdou popsat maticí přechodu

$$P = \begin{pmatrix} p_{11} & \cdots & p_{1n} \\ \vdots & \ddots & \vdots \\ p_{n1} & \cdots & p_{nn} \end{pmatrix} \quad (6)$$

matice je stochastická (obsahuje jednotkové řádkové součty)

$$\forall i = 1, \dots, n : \sum_{j=1}^n p_{ij} = 1. \quad (7)$$

Homogenní = matice přechodu je nezávislá na čase

Řetězce = s diskrétními stavy a s diskrétním časem, pro spojitý čas tímto způsobem dostáváme Markovův proces.

Markovovy = pravděpodobnost budoucích stavů je de facto stanovena současným stavem, s tím, že se nehledí na stavy minulé.

$$P(X_{t+1} = j \mid X_t = i_t, X_{t-1} = i_{t-1}, \dots, X_0 = i_0) = P(X_{t+1} = j \mid X_t = i_t) = p_{i_t j}. \quad (8)$$

(stav obsahuje „dostatečnou informaci“ o předešlém průběhu)

To je podmíněná nezávislost budoucího a minulého stavu při daném současném stavu: pro $u < t < v$ a libovolné stavy $i; j; k$ [7]

$$P(X_u = i, X_v = k \mid X_t = j) = P[X_u = i \mid X_t = j] \cdot P(X_v = k \mid X_t = j). \quad (9)$$

4 POUŽITÝ SOFTWARE

Čtvrtá kapitola je rozdělena na dvě části. První část je věnována programu MATLAB, který byl během práce používán. Druhá část popisuje využití a aplikování metody LHS.


4.1 PROGRAM MATLAB

Program Matlab od společnosti MathWorks funguje na principu integrovaného prostředí. Lze použít pro výpočty, modelování, návrhy algoritmů, simulace, analýzu a presentaci dat, měření a zpracování signálů, návrhy řídicích a komunikačních systémů. První verze byla uvedena už v roce 1985.

Prostředí Matlabu se skládá ze dvou základních částí:

- MATLAB – slouží hlavně k výpočtům a k programování
- SIMULINK – slouží hlavně k simulaci a modelování

Program Matlab je možné použít na platformách Windows, UNIX/Linux a Macintosh. [6]



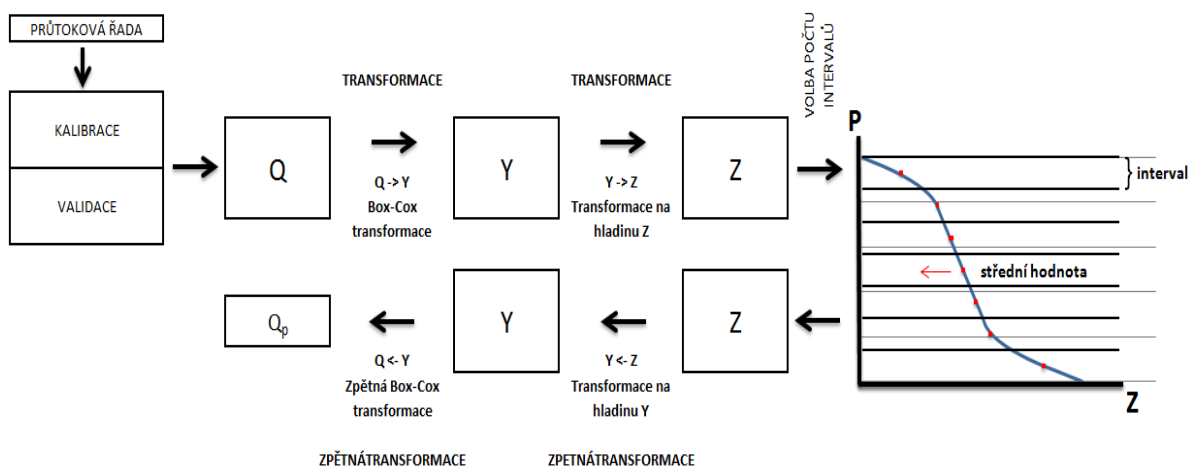
Obr. 1. Program Matlab

4.2 STOCHASTICKÝ MODEL

Pro určení průběhu řízení byl sestaven stochastický model (dále jen SM), který vychází z metody LHS, v prostředí programu Matlab.

V prvním kroku je provedena transformace z reálných hodnot (hladina Q) na hladinu Y (normální rozdělení) pomocí Box-Coxovi transformace (která bude později podrobněji popsána), kdy je výše zmíněnou transformací odstraněna asymetrie z reálné řady. Po provedení transformace předpokládáme normální rozdělení na hladině Y . Dále za pomoci klasických transformačních vztahů (10 a 11) proběhne transformace z hladiny Y na hladinu Z normované normální rozdělení $N(0,1)$. Takto transformovaná řada se dá považovat za část normovaného normálového rozdělení, a proto můžeme pro sestavení čáry překročení využít normované normální rozdělení. Program Matlab je schopen čáru překročení normovaného normálního rozdělení sestavit.

Takto zkonstruovanou čára je rozdělena na předem daný počet intervalů a jsou z ní odečteny střední hodnoty intervalů hodnot transformovaného průtoku. Takto odečtené průtoky jsou převedeny zpětnými transformacemi na hladinu Q .



Obr. 2. Schéma modelu

Transformační vztahy:


$$Y_{i,j} = x_j + s_j \cdot Z_{i,j} \quad (10)$$

$$Z_{i-1,j} = \frac{Y_{i-1,j} - x_{j-1}}{s_{j-1}} \quad (11)$$

kde $Y_{i,j}$ je transformovaný průměrný měsíční průtok na rozdělání bez asymetrie, $Z_{i,j}$ je předpovězený průměrný měsíční průtok, který je transformován, x_j je průměr hodnot v předpovězeném měsíci, s_j je směrodatná odchylka předpovídaného měsíce, j je pořadí měsíce a i je číslo předpovědi

4.2.1 Způsob řízení nádrže

Řízením nádrže se rozumí řízení izolované vodní nádrže se zásobní funkcí s jedním přítokem a s jedním řízeným odtokem, kdy nádrž nalezňuje průtok vody v profilu pod nádrží. Pro zjednodušení úlohy jsou zanedbané ztráty spojené s provozem nádrže a nejistoty vstupních dat.



Obr. 3. Schéma nádrže

Pro zvolenou délku předpovědí (počet předpovězených měsíců) je provedena simulace řízení, kdy přítoky vody do nádrže jsou nahrazeny jejich předpověďmi, které byly získány pomocí SM. Protože model SM poskytuje vějíř možných přítoků, je z hodnot poskytnutých SM tedy sestavena empirická čára překročení (kap. 4.2.2), ze které je pro vybraný kvantil odečtena hodnota přítoku. Řízení je vždy po celou dobu simulace prováděno pro zvolený kvantil pravděpodobnosti překročení přítoků. V průběhu řízení se jednotlivých krocích vypočítává

hodnota zásobního objemu pomocí rovnice nádrže (12). Takovouto simulací nám vznikne vektor řízených odtoků. Pokud ve vektoru odtoků vznikají během řízení poruchy, tak je celková porucha rozpočítána mezi všechny členy vektoru řízených odtoků. Z takto upraveného vektoru pro řízení je pro vlastní řízení použit pouze první člen. Výše uvedená korekce by měla zajistit zmírnění průběhu poruchy.

$$Q^\tau - O^\tau = \frac{V^\tau - V^{\tau-1}}{\Delta t} \quad (12)$$

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

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

4.2.2 Čára pravděpodobnosti překročení ročních průtoků


Máme-li k dispozici dostatečně dlouhou řadu průměrných ročních průtoků, tak následně lze sestavit čáru překročení ročních průtoků.

Nejprve řadíme hodnoty průtoků sestupně a k jednotlivým průtokům určíme pravděpodobnost dle Čegodajeva (13), pravděpodobnosti jsou uváděny v %. [8]

Rovnice dle Čegodajeva:

$$\text{Čegodajev: } P = \frac{m-0.3}{n+0.4} \times 100 \quad (13)$$

P značí pravděpodobnost, m celkový počet roků a n celkový počet měsíců



Obr. 4. Distribuční funkce $F(x)$ a funkce pravděpodobnosti překročení $P(x)$ [9]

4.2.1 Statistické charakteristiky

Střední hodnota, μ_x [m^3s^{-1}] – je hodnota prvního obecného momentu ($k=1$) a která se nazývá střední hodnotou. Střední hodnota je řazena k tzv. charakteristikám polohy, její hodnota je charakterizována jako x-ová souřadnice těžiště hustoty pravděpodobnosti.

$$\mu_x = \mu(x) = \mu[x] = m_1[x] = \int_a^b x f(x) dx \quad (14)$$

Disperze, $D(x)$ [m^6s^{-2}] – základní momentová míra variability, hodnota druhého centrálního momentu ($k=2$) je nazývána disperze nebo také rozptyl.

$$D_x = D(x) = D[x] = M_2(x) = m_2(x - \mu_x) = \int_a^b (x - \mu_k)^2 f(x) dx \quad (15)$$

Směrodatná odchylka, $\sigma(x)$ [m^3s^{-2}] – odmocnina z rozptylu, je využívána hlavně pro popis souborů.

$$\sigma_x = \sigma(x) = \sigma[x] = \sqrt{D_x} \quad (16)$$

Koeficient variace, $C_v(x)$ [-] – jedná se o bezrozměrnou charakteristiku vyjádřenou procentuálně. Je formulován jako podíl směrodatné odchylky a střední hodnoty.

$$C_{v,x} = \frac{\sigma_{vx}}{\mu_x} \quad (17)$$

Koeficient asymetrie, $C_s(x)$ [-] – je charakterizována jako rozdělení náhodné veličiny, která popisuje jeho nesymetrii.

$$C_{s,x} = \frac{M_3(x)}{\sigma^3(x)} \quad (18)$$

Koeficient excese, $E(x)$ [-] – je rozsah koncentrace dat kolem jisté hodnoty nebo skupiny hodnot ve srovnání s určitým definovaným rozdělením veličiny.

$$E_x = \frac{M_4(x)}{\sigma^4(x)} - 3 \quad (19)$$

4.2.2 Box-Cox transformace

Ve statistice se nejdnou setkáváme s daty, která nejsou řízena normálním rozdělením, ale pro využití testových statistik v lineárním modelu jej vyžadujeme. A také převedením dat na normální rozdělení může dojít k eliminaci jejich nesymetrie (šikmost). Je tedy hledána taková transformace, která náhodný vektor Y z jiného rozdělení než normálního převede na vektor $bcY \sim N(X\beta, \sigma^2 I_n)$. Je evidentní, že není možné libovolný vektor transformovat na vektor shodný normálnímu rozdělení, je však možnost najít transformaci, která se normálnímu rozdělení bude co nejvíce blížit. Podle Pengfei (nebo více podrobně v Box-Cox) mají přijatelné transformace tvar

$$y(\lambda) = \begin{cases} \frac{y^\lambda - 1}{\lambda} & \text{pro } \lambda \neq 0, \\ \log y & \text{pro } \lambda = 0. \end{cases} \quad (20)$$

Tato transformace transformuje ale pouze kladné hodnoty vektoru Y , jinak přestává mít smysl. Aproto byla modifikována na verzi pro všechna reálná čísla

$$y(\lambda) = \begin{cases} \frac{(y+\lambda_2)^{\lambda_1} - 1}{\lambda_1} & \text{pro } \lambda_1 \neq 0, \\ \log(y + \lambda_2) & \text{pro } \lambda_1 = 0, \end{cases} \quad (21)$$

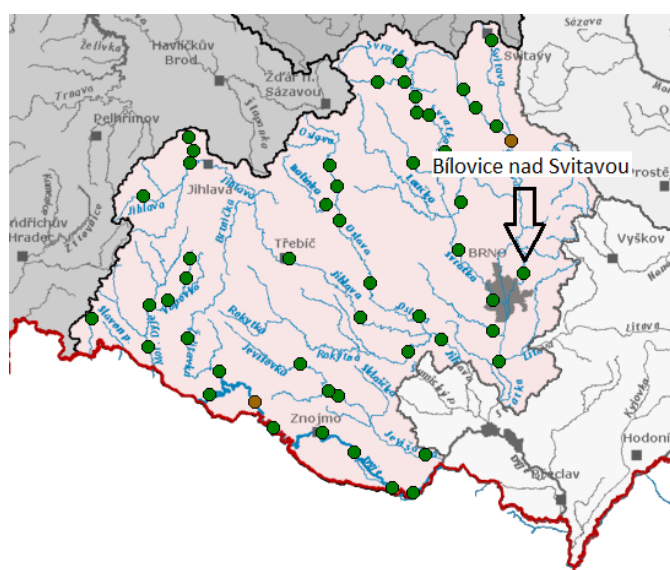
přesněji pro $Y > \lambda_2$. Takže přijatelnou volbou λ_2 pro libovolné Y . Při volbě parametrů je konkrétní postup λ_1 a λ_2 založen na metodě maximální věrohodnosti. [14]

5 APLIKACE

Stochastické řízení bylo použito na imaginární vodní nádrž situovanou do oblasti Bílovice nad Svitavou v horní části povodí. Zvolený profil byl určen kvůli dostupnosti dat, která se dala použít a dlouhé řady reálných průměrných měsíčních průtoků. Nádrž byla navržena tak, aby v průběhu řízení vznikaly dostatečně dlouhé a hluboké poruchy. Takto zvolený postup byl aplikován proto, aby se daná metoda použitá na řízení zásobní funkce nádrže mohla rozsáhleji projevit. Zásobní objem byl určen na hodnotu $52\,600\,000\text{ m}^3$ a řídicí odtok vody z nádrže O_p na konstantní hodnotu $4\text{ m}^3/\text{s}$.



Obr. 5. Celková situace území




Legenda:

● Měřicí stanice

Obr. 6. Měrný profil Bílovice nad Svitavou

5.1 HISTORICKÁ DATA


Pro uspořádání a následnou validaci byla využita řada dlouhá 90 let průměrných měsíčních průtoků (1921 až 2010). Reálná řada je zobrazena na obrázku 7, kde osa x značí posloupnost měsíců a řada y průtoky. Řada byla vytvořena pomocí měření v reálném měrném profilu Bílovice nad Svitavou, který je situován na řece Svitavě. Nahoře nad profilem nejsou umístěné žádné velké nádrže, které by mohly výrazně ovlivňovat přirozený proces řady. Řada byla rozdělena na dvě části. Počátečních 75 let bylo využito pro kalibraci předpovědního modelu a posledních 15 let bylo využito pro validaci modelu. V každém měsíci mají průtoky jiné pravděpodobnostní rozdělení a z tohoto důvodu bylo přikročeno k jejich transformaci na jednotné rozdělení.



Obr. 7. Reálná průtoková řada

5.2 KALIBRACE A VALIDACE ŘÍDÍCÍHO MODELU

Následující kapitola se věnuje kalibraci a validaci modelu. Kalibrační fáze byla zvolena mezi lety 1921 – 1995 a validační fáze mezi 1996 – 2010. Validační období bylo zvoleno se zřetelem na zvýšenou přítomnost malovodých období, která jsou problematické zejména z hlediska řízení zásobní funkce nádrže.



Obr. 8. Reálná průtoková řada od roku 1996 do 2010

6 VÝSLEDKY

V následující kapitole jsou popsány a shrnuty výsledky, kterých bylo dosaženo. Pro různá nastavení modelu SM byly získány různé výsledky. Kdy se měnil počet intervalů, do kterých byla rozdělena empirická čára překročení. Použité počty intervalů byly 5, 10, 15, 20, 25, 30 a 35. Celkový počet předpovědí závisí na počtu použitých intervalů. Dále byl testován vliv délky předpovědi od 1 do 12 vytvořené modelem SM, která byla použita pro každý krok řízení. Dále byla provedena simulace řízení pro různé hodnoty kvantilů předpovědí od 0.1 po 0.9. Úspěšnost předpovědi byla vyhodnocována na simulaci provozu nádrže. Úspěšnost provozu nádrže je dána vyhodnocovacím kritériem E_r což charakterizuje sumu rozdílu řídicího odtoku od řízeného odtoku umocněný druhou mocninou (22).

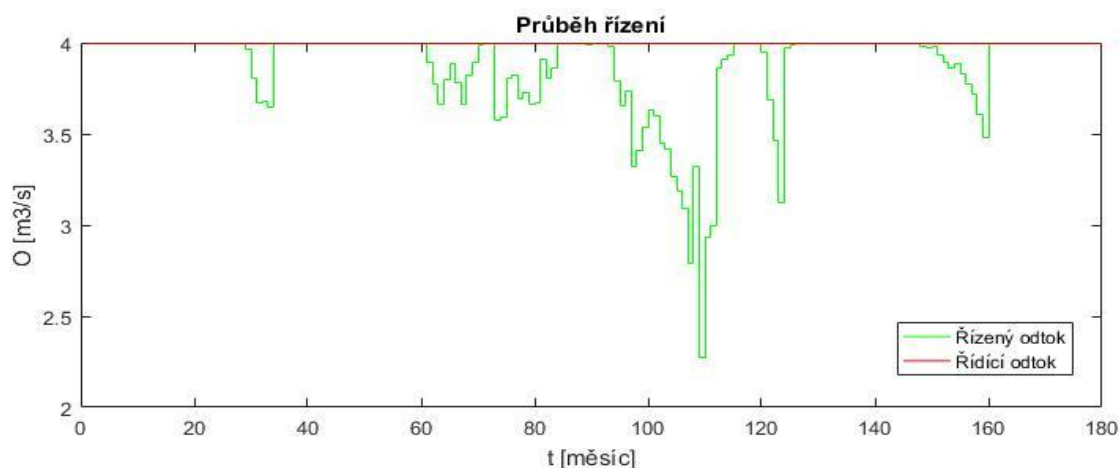
$$E_r = \sum(O_p - O)^2. \quad (22)$$

6.1 DOSAŽENÉ VÝSLEDKY


Tato podkapitola znázorňuje dosažené výsledky řízení nádrže pomocí předpovědního modelu. Tabulky nereprezentují všechny dosažené výsledky pro daný počet intervalů. Byly vybrány nejlepší (zelená barva) a nejhorší (červená barva) výsledky. Tabulky kromě nejlepších a nejhorších výsledků také obsahují výsledky vybraných ostatních nastavení, tak aby byla nastíněna představa, jak se promítají různé délky předpovědi a výběr kvantilů do kvality výstupů. V tabulkách je uvedeno vyhodnocovací kritérium E_r . Jeho hodnota charakterizuje úspěšnost dané předpovědi. Aby byla předpověď co nejlepší, tak musí být E_r co nejnižší.

Tab. 2. Výsledná tabulka předpovědi pro interval 5

INTERVAL		KVANTIL								
5		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
DÉLKA PŘEDPOVĚDI	1	25.3707	25.3707	25.3707	25.4666	26.8199	29.3921	26.6853	26.6853	28.3034
	3	25.3707	25.3707	25.3707	25.3707	25.5551	24.885	24.1795	23.7897	24.3331
	6	25.3707	25.3707	25.3707	25.3707	23.9598	21.8855	21.5195	18.2931	17.5408
	10	25.3707	25.3707	25.3707	25.3707	24.0118	21.7170	18.7626	17.1680	14.7750
	11	25.3707	25.3707	25.3707	25.3707	24.0189	21.7981	18.8121	16.9111	14.9518
	12	25.3707	25.3707	25.3707	25.3707	24.0247	21.7990	18.8020	16.7411	15.4734



Obr. 9. Výsledný graf předpovědi při intervalu 5, kvantilu 0.9 a délce předpovědi 1




Obr. 10. Výsledný graf předpovědi při intervalu 5, kvantilu 0.6 a délce předpovědi 1


Pro řízení s intervalem 5 bylo dosaženo nejlepšího výsledku předpovědi pro kvantil 0.9 a délkou předpovědi 10 a naopak nejhoršího pro kvantil 0.6 s délkou předpovědi 1.

Tab. 3. Výsledná tabulka předpovědi pro interval 10

INTERVAL		KVANTIL								
10		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
DÉLKA PŘEDPOVĚDI	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.5444	27.3793	28.3115	30.6849
	3	25.3707	25.3707	25.3707	25.3707	25.3707	25.0586	24.8422	21.6203	22.1531
	6	25.3707	25.3707	25.3707	25.3707	25.3707	25.0494	24.2020	19.9255	16.8231
	8	25.3707	25.3707	25.3707	25.3707	25.3707	25.0513	24.2265	19.1050	15.5263
	9	25.3707	25.3707	25.3707	25.3707	25.3707	25.0523	24.2347	18.6308	15.5705
	12	25.3707	25.3707	25.3707	25.3707	25.3707	25.0549	24.2637	18.4315	16.5669



Obr. 11. Výsledný graf předpovědi při intervalu 10, kvantilu 0.9 a délce předpovědi 8




Obr. 12. Výsledný graf předpovědi při intervalu 10, kvantilu 0.9 a délce předpovědi 1

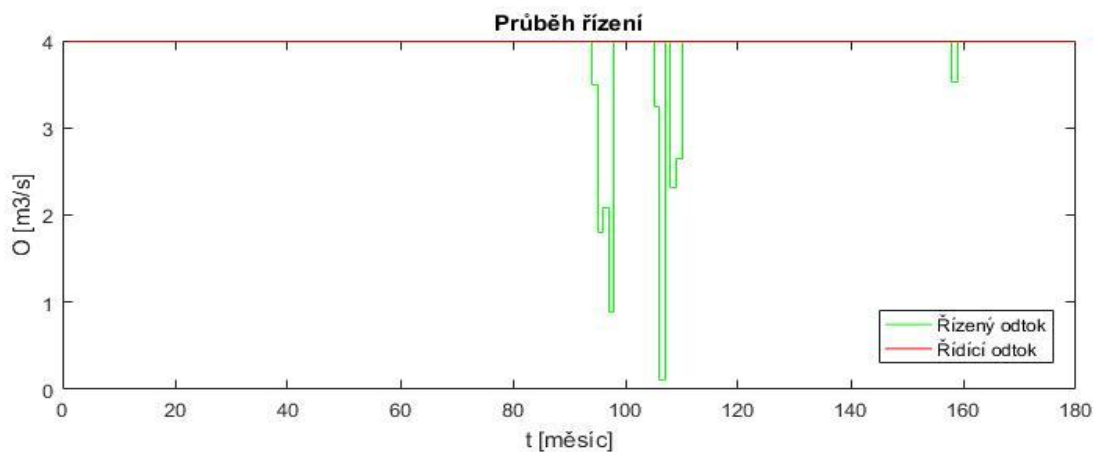
Pro řízení s intervalem 10 bylo dosaženo nejlepšího výsledku předpovědi pro kvantil 0.9 a délkou předpovědi 8 a naopak nejhoršího pro kvantil 0.9 s délkou předpovědi 1.

Tab. 4. Výsledná tabulka předpovědi pro interval 15

INTERVAL		KVANTIL								
15		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
DÉLKA PŘEDPOVĚDI	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.5075	29.6441	31.1645	39.0902
	3	25.3707	25.3707	25.3707	25.3707	25.3707	25.8167	25.8740	28.2844	31.5447
	6	25.3707	25.3707	25.3707	25.3707	25.3707	25.6088	24.5391	26.5749	25.3603
	8	25.3707	25.3707	25.3707	25.3707	25.3707	25.5780	24.2459	26.5742	24.0517
	9	25.3707	25.3707	25.3707	25.3707	25.3707	25.5620	24.1841	25.2788	24.0827
	12	25.3707	25.3707	25.3707	25.3707	25.3707	25.5315	24.2025	25.8007	24.8564



Obr. 13. Výsledný graf předpovědi při intervalu 15, kvantilu 0.9 a délce předpovědi 8

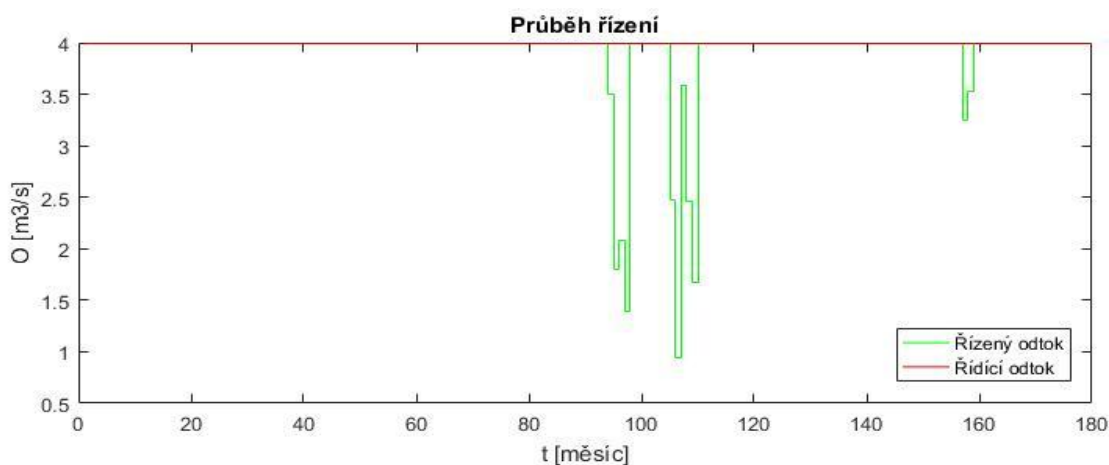


Obr. 14. Výsledný graf předpovědi při intervalu 15, kvantilu 0.9 a délce předpovědi 1


Pro řízení s intervalem 15 bylo dosaženo nejlepšího výsledku předpovědi pro kvantil 0.9 a délkou předpovědi 8 a naopak nejhoršího pro kvantil 0.9 s délkou předpovědi 1.

Tab. 5. Výsledná tabulka předpovědi pro interval 20

INTERVAL		KVANTIL								
20		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
DĚLKA PŘEDPOVĚDI	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.7296	26.1883	29.6012	36.0116
	3	25.3707	25.3707	25.3707	25.3707	25.3707	25.5639	25.0106	25.6344	31.3461
	7	25.3707	25.3707	25.3707	25.3707	25.3707	25.4882	23.5624	21.3240	25.8556
	8	25.3707	25.3707	25.3707	25.3707	25.3707	25.4833	23.5292	21.4033	26.7242
	10	25.3707	25.3707	25.3707	25.3707	25.3707	25.4769	23.5493	22.2878	30.1891
	12	25.3707	25.3707	25.3707	25.3707	25.3707	25.4731	23.5621	22.5618	31.1208



Obr. 15. Výsledný graf předpovědi při intervalu 20, kvantilu 0.9 a délce předpovědi 7

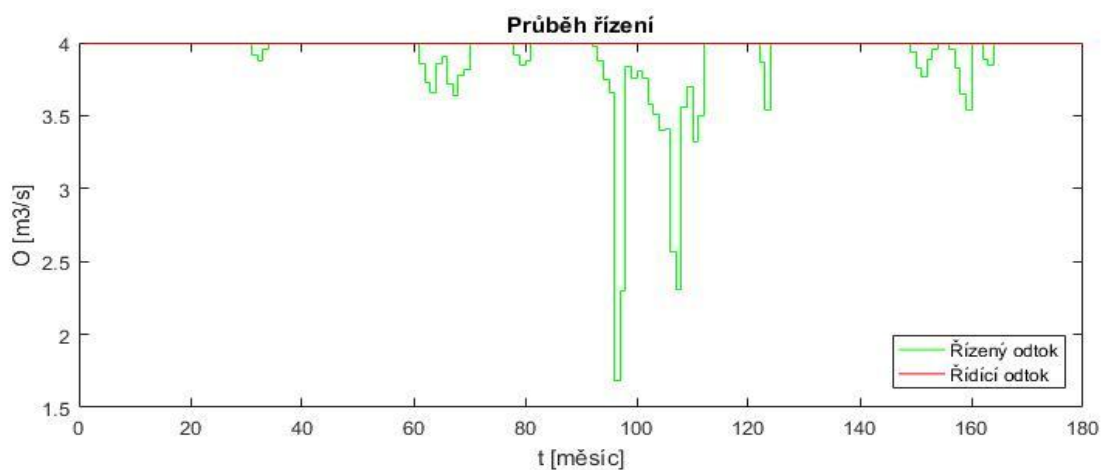


Obr. 16. Výsledný graf předpovědi při intervalu 20, kvantilu 0.9 a délce předpovědi 1

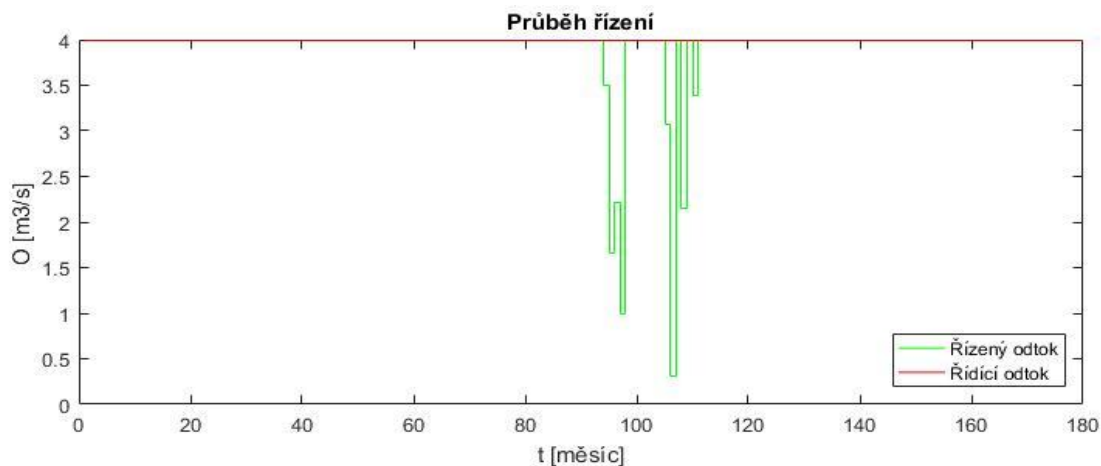
Pro řízení s intervalem 20 bylo dosaženo nejlepšího výsledku předpovědi pro kvantil 0.9 a délkou předpovědi 7 a naopak nejhoršího pro kvantil 0.9 s délkou předpovědi 1.

Tab. 6. Výsledná tabulka předpovědi pro interval 25

INTERVAL		KVANTIL								
25		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
DĚLKA PŘEDPOVĚDI	1	25.3707	25.3707	25.3707	25.3707	25.3707	26.0292	27.5095	36.1997	28.4078
	3	25.3707	25.3707	25.3707	25.3707	25.3707	25.9518	25.3605	27.5399	24.8239
	6	25.3707	25.3707	25.3707	25.3707	25.3707	25.3353	23.9069	27.3236	19.5619
	8	25.3707	25.3707	25.3707	25.3707	25.3707	25.3304	23.9322	25.8970	17.0812
	9	25.3707	25.3707	25.3707	25.3707	25.3707	25.3291	23.9409	25.0720	17.2639
	12	25.3707	25.3707	25.3707	25.3707	25.3707	25.3270	23.9591	24.9269	18.7973



Obr. 17. Výsledný graf předpovědi při intervalu 25, kvantilu 0.9 a délce předpovědi 8




Obr. 18. Výsledný graf předpovědi při intervalu 25, kvantilu 0.8 a délce předpovědi 1


Pro řízení s intervalem 25 bylo dosaženo nejlepšího výsledku předpovědi pro kvantil 0.9 a délkou předpovědi 8 a naopak nejhoršího pro kvantil 0.8 s délkou předpovědi 1.

Tab. 7. Výsledná tabulka předpovědi pro interval 30

INTERVAL		KVANTIL								
30		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
DĚLKA PŘEDPOVĚDI	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.1803	27.7069	38.3778	38.5523
	3	25.3707	25.3707	25.3707	25.3707	25.2994	24.4663	25.7007	28.0757	26.7820
	6	25.3707	25.3707	25.3707	25.3707	25.3649	23.3079	23.5572	24.3796	17.7294
	8	25.3707	25.3707	25.3707	25.3707	25.3707	23.3605	23.4286	22.1490	14.8638
	9	25.3707	25.3707	25.3707	25.3707	25.3707	23.3776	23.3790	21.4763	14.3442
	12	25.3707	25.3707	25.3707	25.3707	25.3707	23.4120	23.3835	22.9751	16.1605



Obr. 19. Výsledný graf předpovědi při intervalu 30, kvantilu 0.9 a délce předpovědi 9




Obr. 20. Výsledný graf předpovědi při intervalu 30, kvantilu 0.9 a délce předpovědi 1

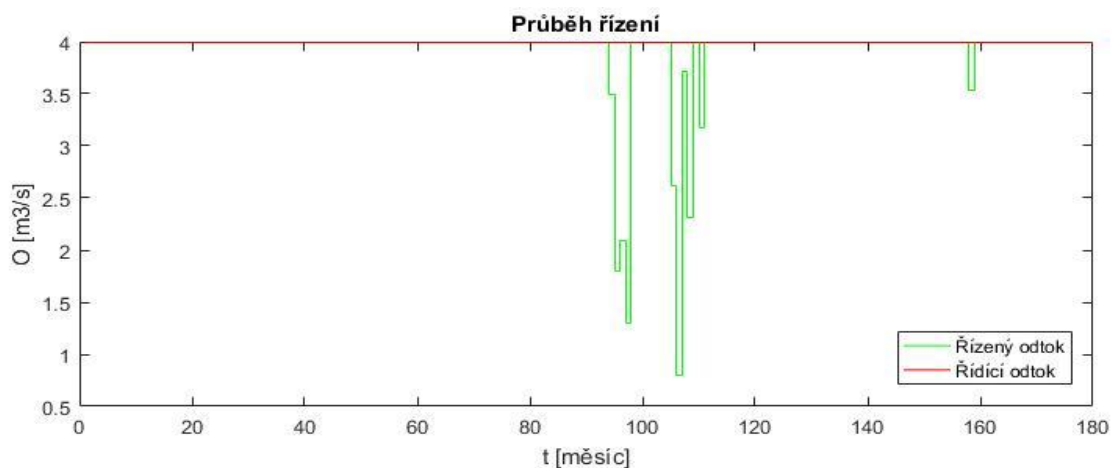
Pro řízení s intervalem 30 bylo dosaženo nejlepšího výsledku předpovědi pro kvantil 0.9 a délkou předpovědi 9 a naopak nejhoršího pro kvantil 0.9 s délkou předpovědi 1.

Tab. 8. Výsledná tabulka předpovědi pro interval 35

INTERVAL		KVANTIL								
35		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
DÉLKA PŘEDPOVĚDI	1	25.3707	25.3707	25.3707	25.3707	25.4033	26.6178	28.7790	26.6111	32.0926
	3	25.3707	25.3707	25.3707	25.3707	25.3707	25.6801	25.0872	24.2487	25.6932
	6	25.3707	25.3707	25.3707	25.3707	25.3707	24.4131	22.2039	22.2552	18.5438
	9	25.3707	25.3707	25.3707	25.3707	25.3707	24.4296	22.0799	19.4275	17.9676
	11	25.3707	25.3707	25.3707	25.3707	25.3707	24.4412	22.0533	19.7406	17.5282
	12	25.3707	25.3707	25.3707	25.3707	25.3707	24.4455	22.0449	19.8793	17.4148



Obr. 21. Výsledný graf předpovědi při intervalu 35, kvantilu 0.9 a délce předpovědi 12



Obr. 22. Výsledný graf předpovědi při intervalu 35, kvantilu 0.9 a délce předpovědi 1


Pro řízení s intervalem 35 bylo dosaženo nejlepšího výsledku předpovědi pro kvantil 0.9 a délkou předpovědi 12 a naopak nejhoršího pro kvantil 0.9 s délkou předpovědi 1.

6.1.1 Shrnutí celkových výsledků

Tato kapitola rekapituluje všechny nejlepší a nejhorší výsledky, kterých bylo dosaženo pomocí předpovědního modelu. Jak lze vidět v tabulce níže tak nejlepšího řízení bylo vždy dosaženo pro kvantil 0.9 s vyšší délkou předpovědi 9. Naopak nejhorších výsledků bylo dosaženo vždy s délkou předpovědi 1 a pro různé hodnoty kvantilu. Pro nastavení s počtem intervalů 5 je nejhorší výsledek pro kvantil 0.6. A pro nastavení s počtem intervalů 25 je nejhorší výsledek pro kvantil 0.8. Úplně nejlepšího výsledku (žlutá barva) bylo dosaženo pro nastavení s počtem intervalů 30 a pro kvantil 0.9. Naproti tomu celkově nejhoršího výsledku (fialová barva) bylo dosaženo při nastavení s počtem intervalů 15 a s délkou předpovědi 1 pro kvantilu 0.9. U kvantilů 0.1 až 0.3 jsou výsledky vždy stejné a začínají se lišit až od kvantilu 0.4. Ve všech případech s kratší délkou předpovědi se hodnoty zvyšují a naopak s narůstající délkou předpovědi hodnoty klesají. Dále jsou uvedeny dva grafy a to pro nejlepší předpověď a pro nejhorší předpověď. Jak lze vidět tak rozdíl mezi řízeným a řídicím odtokem je v prvním grafu zřetelně menší než u druhého případu.

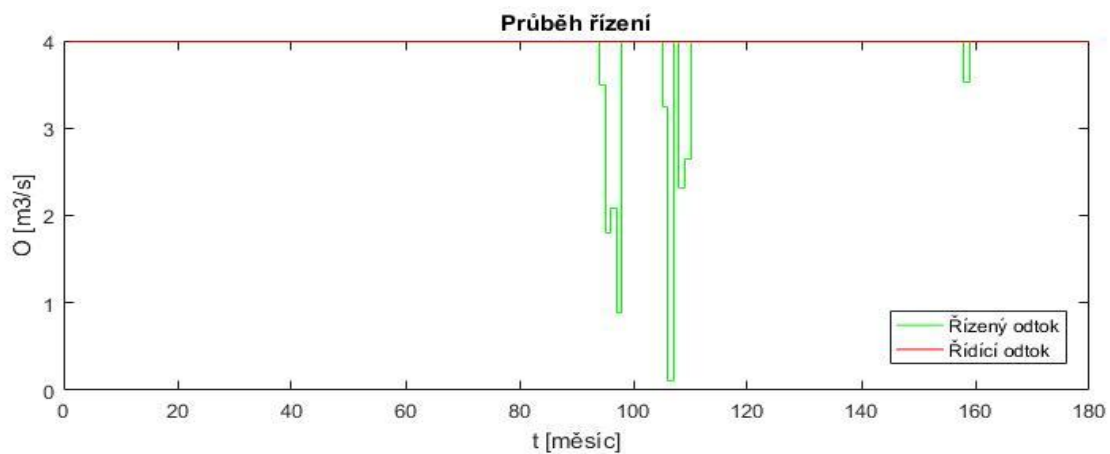
Tab. 9. Celková výsledná tabulka

INTERVAL	DÉLKA PŘEDPOVĚDI	KVANTIL								
		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
5	1	25.3707	25.3707	25.3707	25.4666	26.8199	29.3921	26.6853	26.6853	28.3034
	10	25.3707	25.3707	25.3707	25.3707	24.0118	21.7170	18.7626	17.1680	14.7750
10	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.5444	27.3793	28.3115	30.6849
	8	25.3707	25.3707	25.3707	25.3707	25.3707	25.0513	24.2265	19.1050	15.5263
15	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.5075	29.6441	31.1645	39.0902
	8	25.3707	25.3707	25.3707	25.3707	25.3707	25.5780	24.2459	26.5742	24.0517
20	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.7296	26.1883	29.6012	36.0116
	7	25.3707	25.3707	25.3707	25.3707	25.3707	25.4882	23.5624	21.3240	25.8556
25	1	25.3707	25.3707	25.3707	25.3707	25.3707	26.0292	27.5095	36.1997	28.4078
	8	25.3707	25.3707	25.3707	25.3707	25.3707	25.3304	23.9322	25.8970	17.0812
30	1	25.3707	25.3707	25.3707	25.3707	25.3707	25.1803	27.7069	38.3778	38.5523
	9	25.3707	25.3707	25.3707	25.3707	25.3707	23.3776	23.3790	21.4763	14.3442
35	1	25.3707	25.3707	25.3707	25.3707	25.4033	26.6178	28.7790	26.6111	32.0926
	12	25.3707	25.3707	25.3707	25.3707	25.3707	24.4455	22.0449	19.8793	17.4148



Obr. 23. Výsledný graf pro nejlepší předpověď

Absolutně nejlepší předpovědi bylo dosaženo v šestém kroku výpočtu s délkou intervalu 30, při kvantilu 0.9 a s délkou předpovědi 9.



Obr. 24. Výsledný graf pro nejlhorší předpověď

Nejlhorší předpovědi bylo dosaženo ve třetím kroku s délkou intervalu 15 při kvantilu 0.9 s délkou předpovědi 1.

7 ZÁVĚR

Cíl bakalářské práce spočíval v ověření, zda by se dalo využít stochastického řízení zásobní funkce nádrže a naprogramovat předpovědní model pro reálné využití. SM byl vytvořen v prostředí Matlab a byl navržen tak aby vytvářel stochastickou předpověď. Následně se simuloval průběh řízeného odtoku. Toto se podařilo splnit a SM otestovat na fiktivní nádrži se známými přítoky. Výsledky, kterých bylo dosaženo podrobně shrnuje šestá kapitola. Nacházejí se zde grafy pro různé nastavení s různými počty intervalů a tabulky znázorňující kritérium E_r , které bylo rozhodující pro úspěšnost daného řídicího odtoku pro konkrétní kvantil, délku předpovědi a nastavení s délkou intervalu. Nejlepšího výsledku bylo dosaženo až pro nastavení s počtem intervalů 30, s délkou řízení 9 a kvantilem 0.9. Nejvyšší kvantil odpovídá vysokým pravděpodobnostem překročení průtoků (malovodé období). Tato malovodá období jsou důležitá z pohledu zásobní funkce nádrže, protože v těchto období hrozí vznik poruch. Naopak nejhoršího výsledku bylo dosaženo pro nastavení s počtem intervalů 15, délkou řízení 1 a s kvantilem 0.9. Výsledky pro všechny intervaly a délkami řízení s nižšími kvantily byly stejné, protože nízký kvantil značí vysoké povodňové průtoky, které nás z pohledu řízení nádrže nezajímají, protože nemůže nastat nedostatek vody. Na základě dosažených výsledků se jeví stochastické řízení zásobní funkce nádrže je velice dobrou metodou. V budoucnu můžeme očekávat, že s příchodem neurčitých přítoků do nádrže důležitost stochastického řízení ještě vzroste. Trend klimatu je takový, že se mohou rapidně změnit přítoky do nádrží a současné metody pomocí, kterých jsou nádrže řízeny nemusí být schopny na tuto změnu zareagovat. Oproti tomu stochastické řízení je schopno zařadit vysokou rozmanitost budoucích přítoků.

8 SEZNAM ZKRATEK A SYMBOLŮ

$Q...$	Průtok
LHS...	Latin hypercube sample
ACF...	Autokorelační funkce
PACF...	Parciální autokorelační funkce
AR...	Autoregresivní proces
MA...	Proces klouzavých součtů
B-J...	Box-Jenkins
ARMA...	Autoregresivní proces klouzavých součtů
SAR...	Sezónní autoregresivní proces
SMA...	Sezónní proces klouzavých průměrů
SARMA...	Smíšené sezónní a nesezónní procesy
$a_1, a_2, a_3 \dots a_k \dots$	Regresní koeficienty
$Z_{i,j} \dots Z_{i,j-k} \dots$	Předchozí hodnoty průměrných měsíčních průtoků transformované na hladinu Z
$N_{sim} \dots$	Počet intervalů u metody LHS
$X_i \dots$	Průměrné měsíční průtoky
$X_0, X_1, X_2 \dots$	Náhodné diskrétní veličiny
$t \dots$	Čas
$Y_{i,j} \dots$	Transformovaný měsíční průtok na rozdělání bez asymetrie
$Z_{i,j} \dots$	Předpovězený průměrný průtok
$x_i \dots$	Průměr hodnot v předpovězeném měsíci
$s_j \dots$	Směrodatná odchylka předvídaného měsíce
$j \dots$	Pořadí měsíce
$i \dots$	Číslo předpovědi
$\Delta t \dots$	Časový krok
$P \dots$	Pravděpodobnost
$m \dots$	Celkový počet roků
$n \dots$	Celkový počet měsíců
$\mu_x \dots$	Střední hodnota
$D(x) \dots$	Disperze
$\sigma(x) \dots$	Směrodatná odchylka
$C_v(x) \dots$	Koeficient variace
$C_s(x) \dots$	Koeficient asymetrie

$E(x)...$	Koeficient excese
$O_p...$	Řízený odtok
$O...$	Řídící odtok

9 POUŽITÁ LITERATURA

- [1] Kozel, T. a Starý, M. Stochastické řízení zásobní funkce nádrže s použitím evolučních algoritmů. *Vodohospodářské technicko-ekonomické informace*, 2017, roč. 59, č. 3, str. 12–15. ISSN 0322-8916.
- [2] Zatloukal, R. *Analýza a předpověď časových řad pomocí statistických metod se zaměřením na metodu Box-Jenkins*. Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2008. 51 s. Vedoucí diplomové práce RNDr. Libor Žák Ph.D.
- [3] Kozel, Tomáš. *Stochastické řízení zásobní funkce nádrže s pomocí metod umělé inteligence*. Brno, 2017. 131 s. Disertační práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Školitel prof. Ing. Miloš Starý, CSc.
- [4] Kupčík, Jakub. *Statistická metoda Monte Carlo*. Zlín, 2009. Diplomová práce. Univerzita Tomáše Bati ve Zlíně, Fakulta aplikované informatiky. Vedoucí práce Ing. Bronislav Chramcov Ph.D.
- [5] Menšík, P., Starý, M., Marton, D.: Water Management Software for Controlling the Water Supply Function of Many Reservoirs in a Watershed. *Water resources*, 2015, roč. 42, č. 1, s. 133-145. ISSN: 0097- 8078.
- [6] Heczko, Michal. *Výukový a zkušební program pro předmět PPAŘ*. Zlín, 2006. Bakalářská práce. Univerzita Tomáše Bati ve Zlíně, Fakulta aplikované informatiky. Vedoucí práce Ing. Karel Průtka.
- [7] <http://cmp.felk.cvut.cz/~navara/stat/>
- [8] Hudec, Martin., *Vodohospodářské řešení zásobního objemu vybrané vodní nádrže*. Brno, 2016. 51 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.
- [9] Starý, M. *Hydrologie: Modul 1. studijní opory*. VUT FAST v Brně, 2005.
- [10] Starý, M. *Hydrologie: Modul 2*. Brno, 2005.
- [11] <http://www.pmo.cz/portal/sap/cz/index.htm>
- [12] <https://mapy.cz>

- [13] <https://www.google.cz/imghp?hl=cs>
- [14] Kalibán, František. *Analýza finančních časových řad na základě hlaviček ekonomických zpráv*. Praha, 2011. Bakalářská práce. Univerzita Karlova v Praze, Matematicko-fyzikální fakulta.
- [15] Iman, R. L., Davenport, J. M., and Zeigler, D. K. 'Latin Hypercube Sampling (A Program User's Guide)': Technical Report SAND79-1473, Sandia Laboratories, Albuquerque (1980).
- [16] McKay, M.D., Beckman, R.J., Conover, W.J. (May 1979). "A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code". *Technometrics* (JSTOR Abstract). American Statistical Association. 21 (2): 239–245. doi:10.2307/1268522. ISSN 0040-1706.
- [17] Eglajs, V., Audze P.: "New approach to the design of multifactor experiments". *Problems of Dynamics and Strengths*. 35 (in Russian). Riga: Zinatne Publishing House: 104–107, (1977).

10 SEZNAM OBRÁZKŮ

Obr. 1. <i>Program Matlab</i>	14
Obr. 2. <i>Schéma modelu</i>	15
Obr. 3. <i>Schéma nádrže</i>	16
Obr. 4. <i>Distribuční funkce $F(x)$ a funkce pravděpodobnosti překročení $P(x)$ [9]</i>	17
Obr. 5. <i>Celková situace území</i>	20
Obr. 6. <i>Měrný profil Bílovice nad Svitavou</i>	20
Obr. 7. <i>Reálná průtoková řada</i>	21
Obr. 8. <i>Reálná průtoková řada od roku 1996 do 2010</i>	22
Obr. 9. <i>Výsledný graf předpovědi při intervalu 5, kvantilu 0.9 a délce předpovědi 1</i>	24
Obr. 10. <i>Výsledný graf předpovědi při intervalu 5, kvantilu 0.6 a délce předpovědi 1</i>	24
Obr. 11. <i>Výsledný graf předpovědi při intervalu 10, kvantilu 0.9 a délce předpovědi 8</i>	25
Obr. 12. <i>Výsledný graf předpovědi při intervalu 10, kvantilu 0.9 a délce předpovědi 1</i>	25
Obr. 13. <i>Výsledný graf předpovědi při intervalu 15, kvantilu 0.9 a délce předpovědi 8</i>	26
Obr. 14. <i>Výsledný graf předpovědi při intervalu 15, kvantilu 0.9 a délce předpovědi 1</i>	26
Obr. 15. <i>Výsledný graf předpovědi při intervalu 20, kvantilu 0.9 a délce předpovědi 7</i>	27
Obr. 16. <i>Výsledný graf předpovědi při intervalu 20, kvantilu 0.9 a délce předpovědi 1</i>	27
Obr. 17. <i>Výsledný graf předpovědi při intervalu 25, kvantilu 0.9 a délce předpovědi 8</i>	28
Obr. 18. <i>Výsledný graf předpovědi při intervalu 25, kvantilu 0.8 a délce předpovědi 1</i>	28
Obr. 19. <i>Výsledný graf předpovědi při intervalu 30, kvantilu 0.9 a délce předpovědi 9</i>	29
Obr. 20. <i>Výsledný graf předpovědi při intervalu 30, kvantilu 0.9 a délce předpovědi 1</i>	29
Obr. 21. <i>Výsledný graf předpovědi při intervalu 35, kvantilu 0.9 a délce předpovědi 12</i>	30
Obr. 22. <i>Výsledný graf předpovědi při intervalu 35, kvantilu 0.9 a délce předpovědi 1</i>	30
Obr. 23. <i>Výsledný graf pro nejlepší předpověď'</i>	32
Obr. 24. <i>Výsledný graf pro nejlhorší předpověď'</i>	32

11 SEZNAM TABULEK

Tab. 1. <i>Tvary ACF a PACF procesů AR, MA a ARMA</i>	7
Tab. 2. <i>Výsledná tabulka předpovědi pro interval 5</i>	24
Tab. 3. <i>Výsledná tabulka předpovědi pro interval 10</i>	25
Tab. 4. <i>Výsledná tabulka předpovědi pro interval 15</i>	26
Tab. 5. <i>Výsledná tabulka předpovědi pro interval 20</i>	27
Tab. 6. <i>Výsledná tabulka předpovědi pro interval 25</i>	28
Tab. 7. <i>Výsledná tabulka předpovědi pro interval 30</i>	29
Tab. 8. <i>Výsledná tabulka předpovědi pro interval 35</i>	30
Tab. 9. <i>Celková výsledná tabulka</i>	31