

STOCHASTICKÉ ŘÍZENÍ ZÁSOBNÍ FUNKCE NÁDRŽE S POMOCÍ NEURONOVÝCH SÍTÍ

Tomáš Kozel

Abstract

Described models are used random forecasting period of flow line with different length. The length is shorter than 1 year. Forecasting period of flow line is transformed to line of managing discharges with same length as forecast. Adaptive managing is used only first value of line of discharges. Stochastic management is worked with dispersion of controlling discharge value. Main advantage stochastic management is fun of possibilities. In article is described construction and evaluation of adaptive stochastic model base on neural network (NS). The NS model is used neural network as replacement of classic optimization algorithm. If model is given pattern matrix of management, matrix is given by model base on classic optimization algorithm, and forecast, controlling discharge value is computed by model for chosen probability of controlling discharge value. Model was tested and validated on made up large open water reservoir. Results were evaluated and were compared with model base on traditional algorithms. Evaluation was done for 100% forecast (forecasted values are real values). The management of the large open water reservoir with storage function was logically. The main advantage of NS model is computing speed. Classical optimization model is needed much more time for same calculation as NS model, therefore classic model were needed using clusters for stochastic calculation.

Anotace:

Příspěvek popisuje konstrukci modelu vycházejícího z neuronových sítí pro stochastické řízení zásobní funkce nádrže a srovnání modelu s tradičními metodami optimalizace řízení (genetické algoritmy).

Klíčová slova: stochastický, zásobní funkce, průměrný měsíční průtok, neuronová síť

Anotation:

Development of model base on neural network for stochastic management of storage function open water large reservoir is described in article. Evaluation between model using neural network and classic methods for managemnet of storage function is included.

Keywords: stochastic, storage function, average monthly flow, neural network

1. Úvod

V současné době jsou v praxi používány při řízení zásobní funkce nádrže převážně deterministické modely. Výhodou použití deterministický modelů je pouze jeden výstup (hodnota) řídicí veličiny, avšak při používání pouze jedné hodnoty dochází díky silnému zjednodušení problematiky, ke ztrátě přesnosti řízení či mylnému vyhodnocení situace (předpověď se může výrazněji odlišovat od skutečnosti, která byla předpokládána). Oproti tomu stochastické řízení pracuje s určitým rozptylem hodnot řídicích průtoků s daným pravděpodobnostním rozdělením, a proto dochází k výrazně lepší aproximaci skutečné problematiky řízení. Výhodou stochastického řízení je výběr možnosti řízení pro danou pravděpodobnost scénáře. Výběr pravděpodobností nám poskytne větší možnosti.

Pro stochastické řízení můžeme při adaptivním způsobu řízení využít metodu Monte Carlo. Její využití v oblasti vodohospodářského řešení nádrží naráží na omezení z hlediska výpočetní techniky (velké nároky na strojový čas). Pro vyhodnocení opakovaných náhodných stavů je zapotřebí minimálně 300 opakování výpočtu. Adaptivní řízení s použitím metody Monte Carlo a využitím tradičních algoritmů pro optimalizaci (kritériem optimalizace budeme v textu chápat odchylku mezi nelepším a řízeným odtokem, která bude minimalizována), je vhodnou volbou pro stochastické řízení. Avšak výpočetní doba pro běžné počítače je neúnosná. Velké požadavky na výpočetní techniku jsou způsobeny především optimalizací, která je použita v každém časovém kroku, ve kterém opakovaně korigujeme řízení (vychází z principu adaptivity). Optimalizace využívá tradiční algoritmy. Cestou ke snížení časových nároků optimalizace a zmírnění požadavků adaptivity je nahrazení optimalizačních modulů metodami umělé inteligence. Pro sestavení a práci s modelem byl použit program Matlab 2010.

2. Model

Model vycházející z neuronových sítí (NS model) je schopen výrazného urychlení výpočtu při určité ztrátě přesnosti. NS model obsahuje jednu dvouvrstvou perceptronovou síť. První skrytá vrstva obsahuje 15 skrytých neuronů a transformační funkcí je sigmoida. Druhá skrytá vrstva obsahuje počet skrytých neuronů, který je roven počtu průměrných měsíčních přítoků vody do nádrže a má lineární transformační funkci. Neuronová síť je určena na matici vzorů získané pomocí tradiční metody optimalizace (genetické algoritmy). Pro natrénování sítě byla použita metoda zpětného šíření. Pro řízení byly zvoleny dva typy modelů.

Model typu SW


Vstupem do modelu SW je objem vody v nádrži na počátku řešení a předpovězené přítoky vody do nádrže. Výstupem je jeden řízený odtok pro danou kombinaci vstupů.



Obr. 1 Schéma modelu SW

Model typu SU

Vstupem do modelu SU je objem vody v nádrži na počátku řešení a předpovězené přítoky vody do nádrže. Výstupem je řada řízených odtoků vody z nádrže. S uvedenou řadou lze dále pracovat a upravit hodnotu prvního členu řady, který bude použit pro řízení.



Obr. 2 Schéma modelu SU


Vlastní řízení

Modelu vycházející z NS s natrénovanou NS je dána matice předpovězených přítoků vody do nádrže a počáteční objem vody v nádrži. Následně proběhne simulace řízení pro všech n předpovězených přítokových řad. První člen řady řídicích odtoků vody (u model typu SU) jsou poskládány do matice výstupů, ze které je sestavena empirická čára překročení řízených odtoků. Z uvedené čáry je odečtena hodnota odtoku vody z nádrže pro zvolenou pravděpodobnost. Následně je hodnota odtoku průměrována s předchozími hodnotami řízeného odtoku pro zvolenou pravděpodobnost. V dalším kroku je spočtena nová hodnota objemu vody v nádrži dle bilanční rovnice nádrže (1), pokud není dostatek vody na udržení vypočteného odtoku vody z nádrže je vypuštěn maximální možný odtok a objem vody na konci kroku je roven nule.

$$V_{i+1} = V_i - O_i + Q_{ri} \quad (1)$$

Kde O_i [m^3/s] je vypočtený odtok vody pro zvolenou pravděpodobnost, O_{ri} [m^3/s] je reálný přítok vody do nádrže, V_i [m^3/s] je objem vody v nádrži na počátku řešeného kroku a V_{i+1} [m^3/s] na konci řešeného kroku.

Krok=měsíc



Obr. 3 Schéma modelu stochastického řízení pro jeden časový krok


Opravné řízení

Při použití průměrování s předchozími kroky řízení může model provést opětovné řízení pro $i-1$ krok. První sloupec matice předpovězených průtoků je nahrazen odpovídající hodnotou reálné průtokové řady a hodnota počátečního objemu je nastavena na hodnotu $Vi-2$. Model znovu provede řízení pro všechny předpovědi, sestaví empirickou čáru překročení řízených odtoků a odečte odtok vody z nádrže pro požadovanou pravděpodobnost. Poté je hodnota odtoku zprůměrována s předchozími kroky řízení a dle rovnice (1) je vypočten opravný počáteční objem vody pro krok i .

Pokud je opravný řízený odtok menší, než původní, je počáteční objem pro i -tý krok zmenšen o rozdíl mezi řízeným odtokem a opravným řízeným odtokem. Když je opravný řízený odtok vyšší, počáteční objem vody pro i -tý se nemění. Tento postup je možno aplikovat i na předchozí kroky řízení, avšak doba potřebná pro výpočet je přímo úměrná počtu opravných řízení.


3. Aplikace modelu

Model byl aplikován na fiktivní nádrž na řece Svitavě (měrný profil Bílovice nad Svitavou). Nádrž byla navržena tak, aby došlo k výrazným poruchám během trénovacího období (délka 15 let). Nádrž byla řízena adaptivně s časovým krokem jeden měsíc. Řídicí odtok byl nastaven na hodnotu $4.25 \text{ m}^3/\text{s}$ a maximální objem vody v nádrži byl stanoven na $19.76 \text{ m}^3/\text{s}$. Maximální objem vody v nádrži a řídicí odtok byly zvoleny tak, aby docházelo v testovacím období k výrazným poruchám (nedodávce vody). Model provedl řízení s pravděpodobnostmi odtoku 99, 95, 5, 5, 0.01 pro délky předpovědi 1 až 12 měsíců. Předpovědi průměrných měsíčních přítoků byly získány ze zonálního lineárního autoregresivního rekurentního modelu.



Obr. 4 Profil Bílovice nad Svitavou [5]

Níže uvedené obrázky grafů mají totožné osy, kdy je na svislé ose vždy řízený odtok vody z nádrže pro vybranou pravděpodobnost odtoku vody z nádrže a na vodorovné ose je čas v měsících, protože nádrž je řízena s měsíčním krokem. V legendě číslo uvedené v závorce značí uvažovanou pravděpodobnost řízeného odtoku vody z nádrže.




Obr. 5 Ukázka řízení NS modelu

4. Vyhodnocení výsledků aplikace modelu

Hlavním kritériem úspěšnosti řízení byla druhá mocnina chyby mezi výstupy z modelů používající předpovězené přítoky a řízením, které bylo získáno z klasického modelu za použití 100 % předpovědi (reálná průtoková řada).

Srovnání modelů typu SU a SW

Prvním krokem bylo srovnání mezi modely typu SW a SU. Výsledky modelu SU bez opravného řízení se ukázaly jako nedostatečné, model nedokázal uřídit hlavní poruchu, a proto bylo přistoupeno k zavedení opravného řízení. Při použití opravného řízení pro dva předchozí řízené odtoky se výsledky velmi zlepšily. Model poskytoval nejlepší výsledky při délce předpovědi 6 měsíců. Výsledky modelu SW byly i bez opravného řízení velmi dobré avšak jen do délky předpovědi 4 měsíce při použití delší předpovědi se velmi rychle zhoršovala kvalita řízení. Při použití opravného řízení byly výsledky i pro předpovědi delší než deset měsíců použitelné. Nejlepší výsledky model typu SU poskytoval při použití opravného řízení pro jeden krok zpětně a délku předpovědi 8 měsíců. Obecně lze říci, že výsledky u obou typů modelů byly při použití opravného řízení lepší, avšak výsledky modelu typu SU byly lepší než u modelu SW. Z výše uvedeného důvodu byl do druhé fáze vyhodnocení zařazen pouze model typu SU.




Obr. 6. Srovnání modelu SU a SW pro délku předpovědi 6 (SU8 = 8 měsíců) měsíců pro pravděpodobnost 0.95


Vyhodnocení modelu typu SU

V dalším kroku byly výstupy NS modelu porovnávány s výstupy stochastického tradičního optimalizačního modelu (genetické algoritmy). Oba modely měly stejná data na straně vstupů a uvažovaly stejný počet kroků řízení zpětně. Z Obr. 7. vyplývá, že NS model při řízení dosáhl celkově menší nedodávky než Stochastický klasický model. Během řízeného období vytvářel umělé poruchy, avšak průběh řízení je velmi dobrý i při srovnání s klasickým modelem (100 % předpověď). Oproti tomu klasický model vytvořil mělké umělé poruchy, ale celková nedodávka byla vyšší.

Pro různé pravděpodobnosti odtoku vody z nádrže bylo dosaženo různého počtu a délek poruch. Obecně platilo, že nejmenší chyby bylo dosahováno NS modelem při pravděpodobnosti 90 % a při délce předpovědi 8 měsíců. Velký vliv na průběh řízení měl i celkový počet předpovědí, kdy NS model dával velmi dobré výsledky od počtu 500 průtokových řad. Při použití nižšího počtu docházelo k silnému nárůstu chyby.



Obr. 7. Srovnání NS modelu SU a stochastického klasického modelu



Obr. 8. Srovnání NS modelu SU a deterministického klasického modelu (100 % předpověď)

3. Závěr

Z výše uvedeného textu vyplývá, že výsledné řízení je závislé na požadované pravděpodobnosti, s níž by se měli přítoky vyskytnout, a s nimi i požadovaný odtok vody z nádrže. Nelze opomenout, že výsledné řízení je závislé na celkovém počtu i délce předpovědí a počtu kroků uvažovaných při řízení zpětně. Při vyšším počtu předpovědí dochází ke zlepšení řízení. Skutečností je, že stochastický model vycházející z neuronových sítí je výrazně rychlejší než klasický optimalizační model. Srovnání stochastického řízení mezi oběma modely vyžadovalo velké množství strojového času a výpočty na clusterech. Srovnatelný výpočet (150 měsíců, délka předpovědi 8 a počet předpovědí 1000, 21 pravděpodobností) trval NS modelu 2 hodiny na běžném stolním PC, klasický model i přes paralelní výpočty v clusterech potřeboval 7 dní. NS model dokázal provést řízení logicky. Výsledky ukazují, že lze nahradit optimalizační modul při řízení zásobní funkce nádrže NS modelem a dosáhnout velmi dobrých výsledků při výrazném zkrácení výpočetního času.

Poděkování

Článek vznikl za přispění FAST-J-16-3104 "ŘÍZENÍ ZÁSOBNÍ FUNKCE NÁDRŽE PŘI UVAŽOVÁNÍ NEJISTOT HYDROLOGICKÝCH VSTUPECH S POUŽITÍM METOD UMĚLÉ INTELIGENCE S PODPOROU PŘEDPOVĚDNÍCH MODELŮ.

Literatura

- [1] JURA, P.: Základy fuzzy logiky pro řízení a modelování. In: IEEE Transactions on Systems, Man and Cybernetics, Vol. 23, No. 3, FEI VUT, Brno 1998, 92 s.
- [2] MATLAB + Fuzzy Logic Toolbox, The Language of Technical Computing, The Math Works, 1984-2007.
- [3] NACHÁZEL, K., STARÝ, M., ZEŽULÁK, J.: Využití metod umělé inteligence ve vodním hospodářství, Academia, nakladatelství Akademie věd České republiky, Praha 2004, ISBN 80-200-02229-4.
- [4] NACHÁZEL, K., FOŠUMPAUR, P.: Teorie možnosti v hydrologii a vodním hospodářství. Journal of Hydrology and Hydromechanics. 2010, roč. 58, č. 2, s. 73-97. ISSN 0042-790X. DOI: 10.2478/v10098-010-0008-y.
- [5] www.chmi.cz
- [6] 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.

Kontakt:

Tomáš Kozel, Ing.

VUT v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny, Žižkova 17, 602 00 Brno

koz.el.t@fce.vut.cz