

Využití neuronových sítí při řízení hydroenergetické nádrže

Ing. Tomáš Kozel

Annotation:

Paper describes models based on neural networks and their application for hydropower management of large open water reservoir as replacement of current programme. Models were constructed and tested on different powers of water turbine.

Keywords:

Neural network, hydropower management, mean monthly flow.

Anotace:

Příspěvek popisuje modely vycházející z neuronových sítí a jejich aplikaci v oblasti hydroenergetiky. Hlavním účelem konstrukce výše zmíněných modelů je možnost náhrady již stávajícího optimalizačního programu. Modely byly testovány na rozdílných výkonech vodních turbín.

Klíčová slova:

Neuronové sítě, hydroenergetika, průměrný měsíční průtok.

ÚVOD

Z důvodu klesající tendence průtoků ve vodních tocích, která je způsobena změnou klimatu, je potřeba hledat efektivnější způsoby řízení vodních nádrží v oblasti hydroenergetiky. Další motivací je důraz kladený na využívání obnovitelných zdrojů, mezi které vodní elektrárny patří. V současné době universita vlastní optimalizační program, který pomocí numerické optimalizace dokáže nalézt optimální způsob řízení hydroenergetické nádrže. Program umožňuje zlepšení řízení vodní nádrže tak, aby bylo vyrobeno požadované, resp. vyšší množství elektrické energie. Jeho nevýhodou je poměrně velká spotřeba strojového času. Z výše zmíněného důvodu bylo přikročeno ke tvorbě modelů vycházejících z neuronových sítí, které by dokázaly s určitou ztrátou přesnosti nahradit optimalizační model. Modely byly sestavovány pro požadované výkony turbíny 200 a 300 kW. Byly testovány dvě různá období délky řízení a to 1 (model PM1) a 2 (model PM2) roky. Nádrž byla řízena s měsíčním krokem, a proto veškerá data průtoků jsou průměrné měsíční průtoky.

CÍL

Cílem práce bylo ověřit možnost nahrazení stávajícího optimalizačního programu modely vycházejícími z neuronových sítí.

POUŽITÉ METODY

Pro řešení úlohy byla vybrána perceptronová neuronová síť dvouvrstvá. První vrstva obsahuje 20 skrytých neuronů a používá sigmoidu jako transformační funkci. Druhá skrytá vrstva obsahuje jeden

skrytý neuron a používá lineární transformační funkci. Pro tvorbu a trénink neuronových sítí byl zvolen toolbox programu Matlab R2010a.

Pro každý předepsaný výkon turbíny a délku řady předpovězených průtoků byla ze vstupně-výstupních dat optimalizačního programu natrénována jedna neuronová síť. Síť se liší pouze v počtu vstupů. Pro trénování modelů typu PM1 bylo použito jen prvních devět let. Data pro poslední rok se dala stranou, aby bylo možné provést na nich validaci. U modelu typu PM2 se pro proces učení použila data jen z prvních osmi let. Zbylá data byla dána stranou pro validaci. Data pro učení byla pro oba modely rozdělena náhodně, na trénovací a validační, v poměru 90:10. Pro proces trénování všech neuronových sítí byla použita metoda zpětného šíření.

Model přijme předpovězené průtoky dle varianty a objem vody v nádrži na konci měsíce. Na základě výše zmíněných vstupů přiřadí výstup. V algoritmu je omezující podmínka, která omezuje maximální průtok na turbínu na hodnotu 1,5 m³/s. Hodnoty odpovídají maximální hltnosti turbíny. Pokud je hodnota vyšší, je automaticky přesána výše zmíněnou hodnotou. Dále je dle rovnice (1) dopočítán objem vody v nádrži. Objem je rovněž omezen podmínkou na hodnotu 3,9404979 m³/s, která odpovídá hladině pro max. zásobní objem. U modelu PM2 došlo k vyčerpání celého zásobního prostoru nádrže, a proto oba modely obsahují skript, který zabrání modelu vypouštět záporné objemy. Výše zmíněný skript je aktivován pokud W_i je menší než nula. Následně skript provede výpočet, na jehož základě upraví průtok na turbínu tak, aby se objem vody v nádrži nedostal do záporných čísel.

$$V_i = V_{i-1} - O_{i-1} + Q_{i-1} - Q_{tur_{i-1}} \quad (1)$$

V... objem vody v nádrži [m³/s]

O... odtok pro odběratele [m³/s]

Q... reálný přítok [m³/s]

Qtur... průtok na turbínu [m³/s]

$$W_i = V_{i-1} - O_{i-1} + 0.5 * Q_{p_{i-1}} - Q_{tur_{i-1}} \quad (2)$$

W... předpokládaný objem vody v nádrži [m³/s]

O... odtok pro odběratele [m³/s]

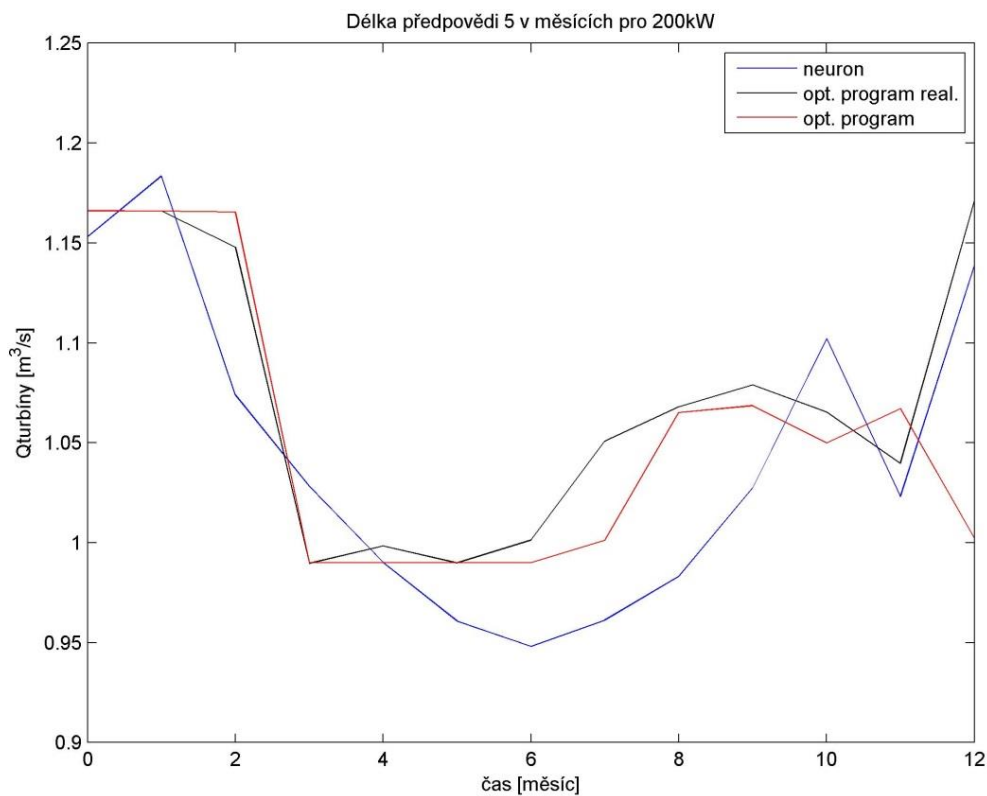
Qp... předpovězený přítok [m³/s]

Qtur... průtok na turbínu [m³/s]


VALIDACE

Do modelů, vycházejících z neuronových sítí, byly vloženy jako vstupy průtoky, které nebyly využity při procesu učení. Jako počáteční objem byl zvolen objem nádrže z konce posledního roku, který byl použit na proces učení. Následující objemy byly dopočítány dle bilanční rovnice (1). Výstupem z modelů byly průtoky na turbínu. Výsledky byly srovnány s výsledky optimalizačního programu, který měl k dispozici reálné průtoky a předpovězené průtoky. Výsledky byly dány do grafu a dále byly vyhodnoceny chyby, kterých se dopustil optimalizační program s předpovězenými průtoky a model vycházející z neuronových sítí. U vyhodnocení byla použita chyba absolutního rozdílu předpovězeného a reálného průtoku při optimalizovaném řízení na turbínu E_r .

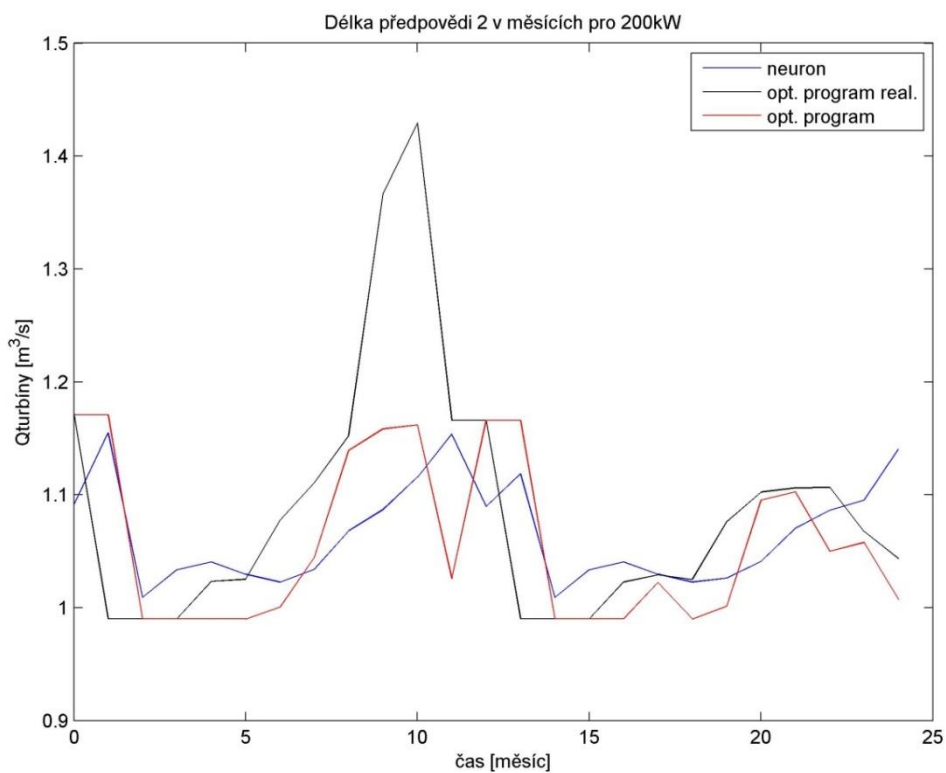
Na obrázcích jsou zobrazeny modrou barvou výstupy z jednotlivých modelů vycházejících z neuronových sítí. Černou barvou jsou zobrazeny výsledky z optimalizačního programu pro reálnou řadu. Červenou barvou jsou výsledky optimalizačního modelu pro předpovězené průtoky. Na ose x jsou jednotlivé měsíce a na ose y jsou zobrazeny průměrné měsíční průtoky na turbínu v m^3/s .




Obr. 1. Výstupy z modelu PM 1



Obr. 2. Výstupy z modelu PM 1



Obr. 3. Výstupy z modelu PM 2



Obr. 4. Výstupy z modelu PM 2

ZÁVĚR

Po vyhodnocení výstupů bylo zjištěno, že modely vycházející z neuronových sítí dokáží nahradit optimalizační program. Model PM1 dokázal nahradit optimalizační program pro testované výkony, avšak výstupy modelu PM1 dokázaly pro 300 kW dokonce i překonat výstupy poskytnuté optimalizačním programem. Stejná situace nastala i u modelu PM2, jehož výstupy dokázaly překonat výstupy optimalizačního programu pro 300 kW. Pro výkon turbíny 200 kW nedokázaly modely, vycházející z neuronových sítí, překonat výsledky, poskytnuté optimalizačním programem. Ukázalo se, že při delším období řízení nádrže, výše zmíněné modely poskytují menší chybu u výkonu 200 kW, než u období kratšího.

Application of neural network for hydropower management of large open water reservoir

Ing. Tomáš Kozel

Nowadays, flows in rivers has decreasing tendency, which is caused by climate change, therefore it is important to looked for a better management of water reservoir in a course of hydropower control. One way how to control reservoir is using models based on neural networks. In this case researchers have own software, which is able to find the optimal way, how to control reservoir in course of hydropower energy using numerical optimization method. Disadvantage of this software is relatively big computing time consumption. This software allows improving reservoir management, in order to produce the required or bigger amount of the electric energy. The goal of this work is replacement above mentioned software by neural network. For training of neural networks the data from this optimization software were used. The models, which comes out from neural networks were controlled the turbine flow in time period one respectively two years. The Neural networks were tested for different maximal turbine flow, in order to verify how to will the networks work in different situations. For solution was used one month time step. The models with neurons worked with the predictions of average monthly inflow with time length 1 to 12 month. A predictions of mean monthly flows was created using the forecasting software, which was developed and is owned by VUT university. One neural network was trained by input-output data set generated by optimization software. The values of every specific power of turbine and given length of mean monthly flow predictions were used as a training data. Training of networks was done only on the one part of data, other part of data set were used for validation. The results of the models based on neural networks for validation data were compared with the results of optimization software. Both final results were evaluated in the end. It was shown that models based on neural networks, could replace and in many cases overcome the results of the optimization program. Big advantage of these models is a speed of calculations. The solution were made using programme Matlab and it's Neural Toolbox.

Ing. Tomáš Kozel

Kontakt: kozel.t@fce.vutbr.cz

**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
FAKULTA STAVEBNÍ**

Adresa:

Veveří 331/95

602 00 Brno

Česká republika

Tel.: +420 541 141 111 Fax: +420 549 245 147

Email: info@fce.vutbr.cz