

POUŽITÍ NEURONOVÝCH SÍTÍ PRO MODELOVÁNÍ A ŘÍZENÍ PROCESU KOAGULACE NA ÚV PÍSEK

**prof. Ing. Alexander Grünwald¹⁾, CSc., Dr. Ing. Pavel Fošumpaur²⁾,
Ing. Klára Štrausová¹⁾, Ing. Kateřina Slavičková, Ph.D., Ing. Marek Slaviček, Ph.D.,
Ing. Bohumil Šťastný, Ph.D.**

¹⁾ Fsv ČVUT, katedra zdravotního a ekologického inženýrství

Thákurova 7, 166 29 Praha 6, grunwald@fsv.cvut.cz, klara.strausova@fsv.cvut.cz

²⁾ Fsv ČVUT, katedra hydrotechniky

Thákurova 7, 166 29 Praha 6, fosump@fsv.cvut.cz

Technologie umělých neuronových sítí (UNS) jsou prostředky umělé inteligence, které simulují procesy řešení problémů lidského mozku. Jejich předností je schopnost řešit jednotlivé úlohy bez potřeby přesné matematické formulace nebo znalostí algoritmu. V současné době se UNS používají v mnoha inženýrských oblastech, např. k rozpoznávání obrazců, řízení složitých zařízení v dynamicky se měnících podmínkách a predikce [1,2,3,4].

Proces úpravy vody je nelineární systém, běžnými fyzikálními rovnicemi těžko popsitelný. Důvodem pro použití UNS i v oblasti úpravy vody je právě jejich shodnost učení se z předkládaných vzorů a následná aplikace získaných poznatků na nová data. UNS se používají pro modelování dávky koagulantu [5,6,7,8,9,10], optimalizaci procesu desinfekce [11,12,13,14] nebo predikci poruch potrubí [15].


Výzkum použití neuronových sítí pro proces koagulace byl prováděn na datech z úpravny vody Písek, která je součástí Jihočeské vodárenské soustavy.

Modelování procesu koagulace

Použití NS pro určení dávky koagulantu bylo již v minulosti vyzkoušeno Gagnonem et al. na ÚV Ste-Foy v Quebecu v Kanadě [3], Joo et al. Na ÚV Chungju, Korea [5], Valentin et al. aplikovali NS na ÚV Viry-Chatillon [8], Baxter, Stanley a Zhang vytvořili podobný model pro ÚV Rossdale v Edmontnu [16]. Jednotlivé výzkumy se liší nejen topologií sítě, ale druhem aktivačních funkce nebo vstupními veličinami.

V současnosti je jednou z nejpoužívanějších provozních metod určování dávky koagulantu na úpravárnách vody sklenicová zkouška. Jednou z jejích nevýhod je například delší doba odezvy při změně provozních podmínek. Umělé neuronové sítě poskytují nejen okamžitou reakci v závislosti na kvalitě surové vody, ale splňují i požadavky určení ekonomicky přesných dávek koagulantu.

Pro modelování pomocí UNS byl využit tzv. interní model řízení (IMC), jehož základní filozofii odvodili García a Morari [17] (obr. 1). Princip řízení podle IMC spočívá v odvození dvou nezávislých matematických modelů, z nichž první slouží pro simulaci chování řízeného systému (procesní model) a druhý představuje samostatný model řídicího systému. Součástí soustavy je i filtr, sloužící jako preprocesor vstupních dat. Jednotlivé modely pro řídicí systém IMC byly sestaveny v programu Matlab s učícím algoritmem Backpropagation.




Obr. 1. Schéma modelu řídicího systému na bázi IMC

Datovým souborem systému byla data z ÚV Písek shromažďovaná v průběhu celého roku 2003. Vzorky byly odebírány v pracovních dnech, ostatní měření (průtok, teplota,..) zaznamenávaly přístroje s denním krokem. Původní počet dat byl redukován s ohledem na neúplnost některých měření a tím nedostatečné množství vstupních hodnot.

Simulační model

Pro návrh systému je klíčová volba vstupních veličin, které mají významný vliv na sledovaný proces. Jako vstupy byly po dohodě s provozovatelem Jihočeské vodárenské soustavy použity následující parametry surové vody; průtok, teplota vody, dávka koagulantu, $CHSK_{Mn}$, $KNK_{4,5}$ a hodnota $CHSK_{Mn}$ přitékající na filtr [18,19]. Řídicí veličinou je hodnota dávky koagulantu, protože představuje hlavní zásah do systému. $CHSK_{Mn}$ na odtoku z čířiče vystupuje jako řízená veličina, jejíž hodnota udává míru vlivu procesu koagulace-flokulace-sedimentace. Schéma procesního modelu koagulace je na obr. 2.



Obr. 2. Struktura neuronové sítě – procesní model

Řídicí model

Struktura řídicího systému je podobná s modelem simulačním. Řízenou veličinou již není hodnota $CHSK_{Mn}$ na výtoku z čířiče, ale dávka koagulantu $Fe_2(SO_4)_3$. Vstupy systému pak jsou ukazatele surové vody; průtok, teplota vody, $CHSK_{Mn}$, $KNK_{4,5}$ a hodnota $CHSK_{Mn}$ přitékající na filtr a výstupem dávka koagulantu.


Řídicí systém dávkování

Simulační a řídicí model tvoří spojený systém pro navržení optimální dávky koagulantu. Tyto dva modely vzájemně porovnávají vstupní a výstupní veličiny, tj. navrženou dávku. Důležitou součástí řídicího modelu je kontrola dávky CHSK_{Mn} na výstupu z čířiče, která musí splňovat vyhláškou dané mezní hodnoty 3 mg.l^{-1} .

Výsledky řešení


Aplikace neuronových sítí se dělí na dva stupně. Nejprve je nutné provést kalibraci neuronové sítě tak, aby se modelované výstupy co nejvíce shodovali s měřenými hodnotami. Pokud vykazuje kalibrace dostatečnou shodu, můžeme přistoupit k simulaci dat na testovací množině. Celkový počet dat vhodných pro modelování byl 182. Soubor byl rozdělen na 80 %, kalibrovacích dat, 20% bylo použito jako data testovací a zbylých 10 % pro ověření produkčního souboru dat. Aby nedošlo k neobsažení extrémních případů v kalibrovací množině, byla data do tohoto souboru vybrána náhodně tak, aby pokrývala celý rok 2003.

Simulační neuronový model byl zvolen s pěti vstupními parametry (Q , t , $\text{Fe}_2(\text{SO}_4)_3$, $\text{KNK}_{4,5}$, $\text{CHSK}_{\text{Mn IN}}$) a jedním výstupním $\text{CHSK}_{\text{Mn OUT}}$. Pro aproximaci tohoto nelineárního vztahu byla použita třívrstvá neuronová síť s 15 neurony ve skryté vrstvě. V následujících grafech budou uvedeny výsledky modelování pro spojenou jednotku čířiče I+II.




Obr. 3. Kalibrace - Simulace CHSK na přítoku na filtr pomocí simulačního neuronového modelu pro čířič I+II

Schopnost neuronové sítě modelovat výstupní parametr dle vstupních podmínek se ověřuje simulací na testovací množině dat. Grafické vyhodnocení ověřování je uvedeno v grafu na obr. 4.




Obr. 4. Predikce CHSK na přítoku na filtr pomocí simulačního neuronového modelu pro čířič I+II

Dalším krokem při tvorbě neuronového modelu byla kalibrace a ověření řídicího modelu dávky koagulantu. Simulační neuronový model odhadne výstupní hodnotu $CHSK_{Mn}$ na přítoku na filtr, řídicí model určí pomocí neuronové sítě potřebnou dávku koagulantu (obr. 5,6). Datový soubor byl shodně se simulačním modelem rozdělen na trénování, testovací a produkční soubor.



Obr. 5. Kalibrace - Simulace dávky koagulantu pomocí simulačního neuronového modelu pro čířič I+II



Obr. 6. Predikce dávky koagulantu pomocí simulačního neuronového modelu pro čistič I+II

Z grafů pro kalibraci i verifikaci vyplývá velmi dobrá shoda při kalibraci a trénování. To je způsobeno principem učení neuronových sítí, což je hledání co nejmenší odchylky a vzájemných vazeb mezi veličinami. Pro statistické posouzení řídicího systému byla použita střední chyba odhadu (RMSE), která dosahovala v oblasti testovacích dat hodnot $0,546 \text{ mg.l}^{-1}$ pro simulační model a $1,293 \text{ l.hod}^{-1}$ pro řídicí model.

Závěr

Předmětem výzkumu bylo sestavení a ověření modelu neuronových sítí pro řízení dávky koagulantu na ÚV Písek. Jelikož je proces úpravy vody nelineární systém obsahující množství na sobě závislých i nezávislých reakcí, je obtížné jej jednoduše formulovat. Proto se v posledních letech rozšířila metoda použití umělých neuronových sítí, které jsou pro takto formulované problémy vhodným prostředkem řešení. Důležitým faktorem pro úspěšnost je i vhodná volba dat, pomocí kterých se neuronová síť „učí“.

Model pro určování dávky koagulantu je kalibrován i pro zhoršené vstupní podmínky, tak aby výstupní hodnota CHSK_{Mn} na odtoku z úpravny vody byla vždy pod mezní hodnotou udávanou vyhláškou 252/2004 Sb, tj. 3 mg.l^{-1} . Tento model by měl sloužit obsluze úpravny vody jako nástroj pro rychlý odhad dávky koagulantu, kdy se hodnoty určených dávek koagulantu budou pohybovat v rozmezí $9,0$ až $20 \text{ mg.l}^{-1} \text{ Fe}_2(\text{SO}_4)_3$.

Použití umělých neuronových sítí při procesu koagulace na ÚV Písek poskytlo dostatek povzbudivých výsledků. Na základě těchto poznatků bychom chtěli pokračovat v ověření na datech z dalších sledovaných období a rozšířit aplikaci UNS i na proces desinfekce.

Poděkování

Příspěvek vznikl za podpory projektu Mze 1G 46036 a VZ MSM 6840770002.

LITERATURA

- [1.] Maier H., Morgan N., Chow C.: Use of Artificial Neural Networks for Predicting Optimal Alumn Doses and Treated Water Quality Parametres, *Environmental Modelling & Software*, 2003, vol.19, p. 484-494.
- [2.] Joo S., Choi D., Park H.: The Effects of Data Preprocessing in the Determination of Coagulant Dosing Rate, *Water Research*, 2000, vol. 34, no. 13, p. 3295-3202.
- [3.] Baxter C., Stanley S., Zhang Q., Smith D.: Developing Artificial Neural Network Models of water treatment processes: a guide for utilities, *Journal of Environmental Engineering and Science*, 2002, vol. 1, p. 201-211.
- [4.] Kvasnička V., Beňušková L., Pospíchal J., Farkaš I., Tiňo P., Král' A.: *Úvod do teórie neurónových sietí*, Bratislava 1997.
- [5.] Demuth H., Beale m.: *Neural Network Toolbox User's Guide*, MathWorks, Inc. 2003.
- [6.] Kuba M.: *Neuronové sítě*, Masarykova universita 1995.
- [7.] Chen Z. et al.: Evaluation of Al₃₀ Polynuclear Species in Polyaminum Solutions as Coagulant for Water Treatment, *Chemosphere* 2006.
- [8.] Valentin N., Denoeux T., Fotoohi F.: *An Hybrid Neural Network Based System for Optimization of Coagulant Dosing in a Water Treatment Plant*. [online] <<http://www.hds.utc.fr/~tdenoeux/congres/icnn99.pdf>>.
- [9.] Deeloping of a Full-scale Artificial Neural Network Model for the Removal of Natural Organic Matter by Enhanced Coagulation, *J Water SRT- Aqua*, 1999, vol. 48, no. 4, p. 129-136.
- [10.] Gagnon C., Grandjean B.P.A., Thibault J.: Modelling of Coagulant Dosage in a Water Treatment Plant, *Artificial Intelligence in Engineering* Vol. 11, p. 401-404.
- [11.] Haas Ch.: Neural Networks Provide Superior Description of Giardia Lamblia Inactivation by Free Chlorine, *Water Research*, vol. 38, p. 3449-3457.
- [12.] Serodes J., Rodriguez M., Ponton A.: Chlorcast©: a methodology for developing decision-making tools for chlorine disinfection control, *Environmental Modelling & Software*, 2001, vol. 16, p. 53-62.
- [13.] Rodriguez M., Serodes J.: Neural network-based modelling of the adequate chlorine dosage for drinking water disinfection, *Canadian Journal of Civil Engineering*, 1996, vol. 23, p. 621-631.
- [14.] Rodrigez M., Serodes J.: Assessing empirical linear and non-linear modelling of residual chlorine in unrbn drinking water systems, *Environmental Modelling & Software*, 1999, vol. 14, p. 93-102.
- [15.] Ahn J., Lee S., Lee G., Koo J.: Predicting Water Pipe Breaks Using Neural Network, *Water Science and Technology: Water Supply*, 2005, vol. 5, no. 3, p. 159-172.
- [16.] Baxter C., Stanley S., Zhang Q., Shariff R., Tupas R., Stark H.: Drinking water quality and treatment: the use of artificial neural networks, *Canadian Journal of Civil Engineering*, 2001, vol. 28, no. 1, p. 26-35.
- [17.] Garcia G.E., Morari M.: Internal model control: 1. A unifying reviw and somne new results., *Ind. Eng. Chem. Process Des. Devel.* 21, 1982, 308-323.
- [18.] Grünwald A., Fošumpaur P., Šťastný B., Slavičková K., Slaviček M., Štrausová K., Čiháková I.: *Inovace procesu úpravy vody a zabezpečení vysoké kvality pitné vody v distribučních systémech* [Výzkumná zpráva], Fakulta stavební ČVUT, katedra zdravotního a ekologického inženýrství,, 2004, 1G46036.
- [19.] Grünwald A., Fošumpaur P., Šťastný B., Slavičková K., Slaviček M., Štrausová K., Vlčková K., Veselá R., Čiháková I.: *Inovace procesu úpravy vody a zabezpečení vysoké kvality pitné vody v distribučních systémech* [Výzkumná zpráva], Fakulta stavební ČVUT, katedra zdravotního a ekologického inženýrství, 2005, 1G46036