

MOŽNOSTI POUŽITÍ UMĚLÉ INTELIGENCE PRO ŘÍZENÍ PROCESŮ ÚPRAVY PITNÉ VODY

Ing. Klára Štrausová, Ph.D.

W&ET Team, České Budějovice, klara.strausova@wet-team.cz

S vývojem a rozmachem moderních informačních technologií se i v oblasti úpravy pitné vody začínají objevovat nové postupy a možnosti optimalizace a řízení. Oblast umělé inteligence je velice rozsáhlá a možnosti využití rychle rostou.

Umělá inteligence je označením pro moderní technologie jako jsou umělé neuronové sítě (UNS), fuzzy logika, genetické algoritmy či jejich kombinace. Možnosti uplatnění a podmínky použití se liší nejen dle použitého prostředku, procesu, ale samozřejmě i dle lokality.

Výzkum v oblasti úpravy pitné vody a jejího provozování se setkává stále s větším ohlasem a úspěšné aplikace jsou již dnes známy z nejrůznějších zemí světa. Česká republika není výjimkou. Nacházel a kol. již v roce 1999 využili teorii fuzzy logiky pro řízení manipulací s vodou ve vodárenské nádrži Římov [1], druhým úspěšným výzkumem u nás byla aplikace UNS pro optimalizaci dávek koagulantu na úpravně vody Plav v téže lokalitě [2]. Výsledky tohoto výzkumu jsou krátce shrnuty na konci článku a v rozsáhlejší formě budou publikovány v odborném tisku.

UMĚLÉ NEURONOVÉ SÍTĚ

Největší předností UNS pro modelování a řízení procesů je zejména jejich schopnost řešit nelineární problémy učení z dostupných dat, tj. detekovat z nich určitý vzor. UNS nepotřebují přesné matematické formulace daného problému (procesu), ale mohou obsahovat dostupné teoretické a empirické znalosti procesních postupů.

Pro předpovědní systémy je nejvhodnější učení sítě z předkládaných dat, tj. učit sít' správně odhadnout výstupy modelu podle zadaných vstupů nebo vzorů změnou váhových spojení mezi neurony. Snaha tohoto učení je učit sít' tak, aby co nejlépe modelovala výstupní hodnoty pro každý předložený soubor vstupů nebo vzor, vytvořením odpovídajících spojení mezi neurony. Chyba mezi simulovanými a měřenými veličinami je minimalizována změnami vah mezi jednotlivými neurony vzhledem k pravidlu učení. Nejpoužívanějším algoritmem minimalizace chyby v procesním modelování je pravidlo *back-propagation* (zpětné šíření chyby).

UNS je možné použít tam, kde selhávají klasické výpočetní modely. Ale použití UNS má i svá omezení. Aby neuronová sít' měla možnost získat vzory rozhodování a porozuměla danému procesu, je nutné mít k dispozici rozsáhlou reprezentativní databázi historických dat. Z tohoto poznatku také vyplývá, že UNS jsou vhodné pro stávající technologické linky, nikoliv pro linky v krátké době po rekonstrukci, kdy jsou procesy úpravy pozměněny a tím i kvalita vody, kterou produkují a není dostatek nových provozních dat.

U nás nebyly UNS poměrně dlouhou dobu známé, první zmínku přinesl Dolejš na konferenci ve Zlíne v roce 2001 [3]. V oblasti úpravy vody je využití UNS nejrozsáhlejší v oblasti optimalizace dávek koagulantů [5-12] a v určování množství dezinfekčního činidla v síti [13-20], dále v procesu filtrace [9], určování tlaku v membránách při ultra/nanofiltraci [21-23], predikci tvorby bromičnanů při ozonizaci

[24], THM [25] pomocí nich lze například předpovídat poruchy potrubí [26], množství organismů [27,28] nebo potřebu pitné vody [9]. Tento výčet neobsahuje všechny dostupné aplikace UNS a ani není možné rozvést v tomto článku všechny uvedené příklady, proto stručně popíší jen některé z nich.

Modelování procesu koagulace

O dávkce koagulantu rozhoduje procesní schéma úpravní a kvalita surové vody. Tradiční metody určování dávky koagulantu spoléhají především na praktické znalosti provozních techniků. Dávku koagulantu je třeba dodržovat v úzkém rozmezí nejen z ekonomického, ale i provozního hlediska. Proto je potřeba stanovit optimální dávku tak, aby došlo k dokonalé agregaci částic za minimálního přebytku koagulantu. Nejběžněji používaným provozním testem na zjištění potřebné dávky koagulantu je sklenicový pokus. UNS mají schopnost nejen rychlé odezvy na změnu kvality surové vody, ale splňují i požadavky určení ekonomicky vhodných dávek koagulantu.

V člancích zabývajících se tvorbou modelů pro proces koagulace jsou nejčastěji uváděnými parametry, ovlivňujícími dávku koagulantu: zákal, vodivost, pH, teplota, průtok, A254, DOC, aj. Vždy je nutné přihlédnout k charakteristice surové vody a především volit parametry, které jsou sledovány z dlouhodobého hlediska a s maximální četností.

V loňském roce byla uveřejněna zajímavá studie autorů Mälzera a Strugholze [12]. Jejich výzkum byl prováděn na úpravě vody v Obermaubachu v Německu, kde pro optimalizaci dávek nepoužili jen výstupní hodnotu zákalu na odtoku ze sedimentace, ale pro výpočet dávky koagulantu vložili do systému optimalizace ještě prvek pro stanovení nákladů spojených s danou dávkou. Tímto zásahem by se v daném období zvýšila průměrná hodnota zákalu po sedimentaci z 1,46 NTU na 1,59 NTU. S přihlédnutím k úsporám v dávkách koagulantu, likvidaci kalu, ale (z důvodu vyššího zákalu) zkrácením filtračních cyklů, byly úspory vyčísleny na cca 15% (=18.000 €/rok).

Modelování procesu dezinfekce

Dávky dezinfekčního činidla jsou závislé na minimálním množství zbytkového dezinfekčního činidla na výstupu z úpravní vody nebo v určitém bodu systému. V minulosti byly nejčastěji používané různé matematické vzorce, které jsou však náročné na přípravu modelu. Mezi nové metody pro zjišťování koncentrace chloru v určitém bodu systému, založené na použití historických dat, patří právě UNS. Tyto prostředky jsou výhodným nástrojem pro modelování, kdy není potřeba znalost jednotlivých reakcí, pouze vstupních veličin ovlivňujících množství dezinfekčního činidla, resp. úbytek chloru. Provozovatel distribuční sítě tak může vhodně regulovat zbytkovou koncentraci chloru pro hygienické zabezpečení vody a množství chloru pro pitnou vodu, která bude příjemná pro konzumaci.

Modely UNS pro proces dezinfekce mohou být sestaveny např. pro návrh dávek dezinfekčního činidla na základě zbytkové koncentrace aktivní složky v různých místech distribučního systému. Mezi nejvýznamnější publikace v oblasti dezinfekce patří metodika pro tvorbu UNS pro stanovení zbytkové koncentrace chloru ve vodojemech nebo v distribuční síti sestavenou kolektivem Sérodes, Rodriguez, Ponton s názvem Chlorcast© [18].

Klíčovými parametry pro tvorbu modelu jsou: dávka chloru, zbytková koncentrace chloru, teplota a průtok. Průtok poskytuje vyjádření o době zdržení, která je hlavním faktorem při úbytku chloru, teplota ovlivňuje kinetiku úbytku chloru. Zajímavým

poznatkem pro model dezinfekce je fakt, že v modelu není obsažen žádný parametr popisující kvalitu vody. Předpokládá se totiž, že informace o změně kvality vody je zahrnuta do parametrů spojených s vývojem koncentrace chloru.

Modelování množství a prvků ve vodě

Rizika spojená s výskytem prvků *Cryptosporidium* a *Giardia* jsou známá po celém světě a pokud by bylo možné jejich koncentrace předvídat, byl by to velký krok kupředu v ochraně spotřebitelů. Stanovení kryptosporidií i giardií jsou zdlouhavá, nákladná a složitá. Proto se vědci snaží identifikovat zástupné indikátory, které by byly schopny předpovědět či odhalit nebezpečnou přítomnost patogenů pro případy, kdy není přímé stanovení možné provést. Protože snahy o nalezení vhodné matematické formulace nebyly úspěšné, pokusil se tým Neelakantana a kol. [28] o vytvoření modelu pomocí UNS. Největší překážkou byl nedostatečný počet dat. K dispozici byl datový soubor obsahující 72 dnů měření z období více než jednoho roku. Pro modelování kryptosporidií byly zvoleny následující parametry neuronové sítě: alkalita, pH, zákal, nerozpuštěné látky, srážky, průtok, celkový počet koliformních bakterií, fekální koliformy, *E. coli* a *Clostridium perfringens*. Model giardií obsahoval 14 parametrů. Navzdory poměrně malému počtu dat bylo možné učinit závěr, že UNS jsou vhodné pro stanovení prvků, kdy pro kryptosporidie predikoval model lepší výsledky než pro giardie. To může být způsobeno převládajícími zdroji a transportem oocyst.

Z předchozích ukávek aplikace UNS je patrné, že je možné dosáhnout jak optimalizace jednotlivých procesů z pohledu kvality vody, minimalizace nebezpečí plynoucích z nežádoucích látek či organismů, tak mohou vést i ke snížení provozních nákladů úpraven.

FUZZY LOGIKA

Fuzzy logika je podobor odvozený od teorie fuzzy množin. Hlavním přínosem tohoto oboru je možnost matematického vyjádření rozhodovacích postupů. Kromě numerických informací jsou ve výrocih obsaženy i lidské zkušenosti. Logické výroky se ohodnotí stupněm příslušnosti v intervalu od 0 do 1 včetně krajních hodnot a ne jako v binárním vyjádření pouze jako 1 (pravdivé) či 0 (nepravdivé). Díky těmto vlastnostem je možné vyjádřit pojmy jako „trochu“, „hodně“ apod.

Jak je uvedeno v úvodu, aplikací u nás se zabýval Nacházel a kol. Použitým regulátorem v tomto případě byl regulátor využívající klasickou strukturu Mamdaniho typu, tj. soustavy složených podmíněných řídicích pravidel. Tato pravidla je možné si představit jako věty popisující aktuální stav řízeného objektu a na tento stav reagující rozhodnutí o zásahu. Autoři uvádí při modelovém rozhodování i možnost zlepšení hodnot $CHSK_{Mn}$ v surové vodě, kdy díky optimalizaci způsobu vypouštění vody z nádrže za přívalových přítoků je možné vhodnou manipulací s horizontem odtoku zabránit zhoršení jakosti vody v nádrži.

MODELOVÁNÍ PROCESU KOAGULACE NA ÚV PLAV

Na konferenci Voda Zlín 2007 byly prezentovány výsledky z použití UNS na úpravně vody Písek. Na tyto výsledky jsem navázala dalším výzkumem krátce prezentovaným v následující části.

Pro řízení pomocí umělých neuronových sítí byl využit tzv. interní model řízení (Internal Model Control - IMC). Datovým souborem systému byla data z ÚV Plav shromažďovaná v letech 2002 – 2006. Modely pro určení dávky koagulantu na ÚV Plav byly vytvořeny celkem dva. První model (IMC I) řeší závislost hodnoty $CHSK_{Mn}$ na


odtoku z usazovací nádrže, druhý (IMC II) je zaměřen na zbytkovou koncentraci železa na výstupu z usazovací nádrže.

System řízení dávek koagulantu – IMC I


Pro řízení procesu koagulace byl použit systém IMC I s použitím dvou neuronových sítí. Modelovou veličinou, která udává míru vlivu procesu, byla zvolena hodnota $CHSK_{Mn}$ na odtoku z usazovací nádrže. V případě, že je tato hodnota vysoká, nebyla použita vhodná dávka koagulantu nebo systém procesu koagulace-flokulace-sedimentace nefunguje správně. Vysoké množství organických látek ovlivňuje i tvorbu vedlejších produktů dezinfekce, proto je snaha o jejich minimalizaci. Grafický výstup optimalizovaných dávek koagulantu systému řízení IMC I je na obr. 1.

System řízení dávek koagulantu – IMC II

Model IMC II je založen na odhadu dávky koagulantu v závislosti na zbytkové koncentraci železa na odtoku z usazovací nádrže. Podstata fungování modelu vychází z typického průběhu funkce závislosti zbytkové hodnoty Fe na dávce koagulantu. Příliš nízká dávka koagulantu neumožní dokonalé vytvoření vloček. Jejich malá velikost způsobí poruchy v sedimentaci a vločky jsou bez usazení odplavovány na filtr. Vysoké hodnoty koagulantu naopak způsobí přebytek tohoto činidla. Minimální zbytková hodnota Fe odpovídá optimální dávce koagulantu (obr. 2).



Obr.1 System řízení IMC I – graf optimalizované dávky koagulantu



Obr. 2 Systém řízení IMC II – graf optimalizované dávky koagulantu

SHRNUTÍ

Uvedený přehled literatury o prostředcích umělé inteligence není samozřejmě výčet všech existujících zdrojů. Na předložených příkladech je však možné vidět, že umělé neuronové sítě nebo fuzzy logika mají velký potenciál v oblastech, kde klasické matematické modely selhávají. Touto nadějnou oblastí je i technologie úpravy a zásobování pitnou vodou.

Poděkování

Príspevek vznikl za podpory projektu MZe 1G 46036 a VZ MSM 6840770002 na dřívějším pracovišti autorky (katedra zdravotního a ekologického inženýrství, FSv ČVUT Praha).

LITERATURA

- [1.] Nacházel K., Patera A., Hejzlar J.: Možnost využití metodických postupů teorie fuzzy množin a fuzzy logiky pro řízení manipulací s vodou v nádržích z vodárenského hlediska, *Pitná voda* 1999, pp. 41-48, W&ET Team, Č. Budějovice 1999.
- [2.] Štrausová K.: Řízení procesu koagulace a dezinfekce pomocí umělých neuronových sítí. Doktorská disertační práce, FSv ČVUT 2008.
- [3.] Dolejš P.: Využití technologického auditu pro optimalizaci provozu úpraven vody a manažerské rozhodování. Sborník V. mezinárodní konference Voda Zlín 2001, s. 77-84. VaK Zlín, Zlín 2001.
- [4.] Zhang. Q., Stanley. S.: Real-time water treatment process control with artificial neural networks. *Journal of Environmental Engineering* 125 (2), pp. 153-160, Elsevier Science 1999.
- [5.] Valentin N., Denoeux T., Fotoohi F.: A 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>>
- [6.] Gagnon C., Grandjean B.P.A., Thibault J.: Modeling of Coagulant Dosage in a Water Treatment Plant. *Artificial Intelligence in Engineering* 11, pp. 401-404, Elsevier Science 1997.

- [7.] Baxter C.W., Stanley S.J., Zhang Q.: Developing of a Full-scale Artificial Neural Network Model for the Removal of Natural Organic Matter by Enhanced Coagulation. *J Water SRT- Aqua* 48, No. 4, pp. 129-136, IWSA 1999.
- [8.] Joo S., Choi D., Park H.: The Effects of Data Preprocessing in the Determination of Coagulant Dosing Rate. *Water Research* Vol. 34, No. 13, pp. 3295-3202, Pergamon 2000.
- [9.] Maier H., Morgan N., Chow C.: Use of Artificial Neural Networks for Predicting Optimal Alum Doses and Treated Water Quality Parameters. *Environmental Modeling & Software* 19, pp. 484-494, Elsevier Science 2003.
- [10.] Bloch G., Denoeux T.: Neural networks for process control and optimization: Two industrial applications. *ISA Transactions* 42, pp. 39-51, ISA - The Instrumentation 2003.
- [11.] Chen Z. et al.: Evaluation of Al₃₀ Polynuclear Species in Polyaminum Solutions as Coagulant for Water Treatment. *Chemosphere* 64, pp. 912-918, Elsevier Science 2006.
- [12.] Mälzer H.-J., Strugholtz S.: Artificial neural networks for cost optimization of coagulation, sedimentation and filtration in drinking water treatment. *Water Science & Technology: Water Supply* 8.4, pp. 383-388, IWA Publishing 2008.
- [13.] 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* 28, Suppl. 1, pp.26-35, NRC Canada 2001.
- [14.] 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* 1, pp. 201-211, NRC Canada 2002.
- [15.] Rodriguez M., Serodes J.: Neural network-based modeling of the adequate chlorine dosage for drinking water disinfection. *Canadian Journal of Civil Engineering* 23, pp. 621-631, Canada 1996.
- [16.] Serodes J., Rodriguez M.: Predicting residual chlorine evolution in storage tanks within distribution systems: application of neural network approach. *J Water SRT- Aqua* 45, No. 2, pp. 57-66, IWSA 1996.
- [17.] Rodrigez M., Serodes J.: Assessing empirical linear and non-linear modeling of residual chlorine in urban drinking water systems. *Environmental Modeling & Software* 14, pp. 93-102, Elsevier Science 1999.
- [18.] Serodes J., Rodriguez M., Ponton A.: Chlorcast©: a methodology for developing decision-making tools for chlorine disinfection control. *Environmental Modeling & Software* 16, pp. 53-62, Elsevier Science 2001.
- [19.] Bowden G.J., Nixon J.B., Dandy G.C, Maier H.R., Holmes M.: Forecasting chlorine residuals in a water distribution system using a general regression neural network. *Mathematical and Computer Modeling*, Vol. 44, pp.469-484, Elsevier Science 2006.
- [20.] Gibbs M.S., Morgan N., Maier H.R., Dandy G.C., Nixon J.B., Holmes M.: Investigation into the relationship between chlorine decay and water distribution parameters using data driven methods. *Mathematical and Computer Modeling*, Vol. 44, pp. 485-498, Elsevier Science 2006.
- [21.] Delgrange N., Cabassud C., Cabassud M., Durand- Bourlier L., Lainé J.M.: Neural networks for prediction of ultrafiltration transmembrane pressure – application to drinking water production, *Journal of Membrane Science* 150, pp. 111-123, Elsevier Science 1998.
- [22.] Shetty G.R., Malki H., Chellam S.: Predicting contaminant removal during municipal drinking water nanofiltration using artificial neural networks. *Journal of Membrane Science* 212, pp. 99-112, Elsevier Science 2003.
- [23.] Shetty G.R., Chellam S.: Predicting membrane fouling during municipal drinking water nanofiltration using artificial neural networks. *Journal of Membrane Science* 217, pp. 69-86, Elsevier Science 2003.
- [24.] Legube B., Parinet B., Gelinet K., Berne F., Croue J.-P.: Modeling of bromated formation by ozonation of surface waters in drinking water treatment. *Water Research* 38, pp. 3185-2195, Elsevier Science 2004.
- [25.] Milot J., Rodriguez M.J., Sérodes J.B.: Contribution of Neural Networks for Modeling Trihalomethanes Occurrence in Drinkinf Water. *Journal of Water Resources Planning and Management*, Vol.128, No. 5, pp. 370-376, ASCE 2002.
- [26.] Ahn J., Lee S., Lee G., Koo J.: Predicting Water Pipe Breaks Using Neural Network. *Water Science and Technology: Water Supply*, Vol. 5, No. 3, pp. 159-172, IWA Publishing 2005.
- [27.] Haas Ch.: Neural Networks Provide Superior Description of Giardia Lamblia Inactivation by Free Chlorine. *Water Research* Vol. 38, pp. 3449-3457, Elsevier Science 2004.
- [28.] Neelakantan T.R., Lingureddy S., Brion G.M.: Effectiveness of Different Artificial Neural Network Training Algorithms in Predicting Protozoa Risk in Surface Waters. *Journal of Environmental Engineering*, Vol. 128, No. 6, pp. 533-542, ASCE 2002.