



Ivan MRNČO¹
Peter BLŠTAK²
Peter HUDEC³
Tomáš GIBALA⁴
Eva MICHAELI⁵

PODPORARozvoja urbanizovaných území pomocou využitia simulačných metód matematického hydraulického modelu a data miningu pri prevádzke stokovej siete

Abstract:

The paper deals with the applications of the modern computational methods for solving complex water management tasks of the collection system operation and run off capabilities in urban areas through the sewer network. Optimization of the collection system operation are important background input data for the subsequent development of the urbanized areas. As the basic functionality of advanced technologies it is possible to classify the complex problem solving: merging of several previously separate systems – mathematical hydraulic model, GIS, SCADA (supervisory control and data acquisition), CIS (customer information system) etc. These are often treated separately or by the modern GIS system. Relatively new element to predicting the behaviour of the collection system for input events, such as rainfalls and the production of wastewaters, is data mining. Data mining is technology for extracting knowledge (information data knowledge) from large amount of data. Expansion of this technology is related to the rapid development of the information technologies and the huge increase in the volume of data in all spheres of our life. One of the possibilities of using the knowledge technologies is an assessment of the hydraulic behaviour of the collecting system for selected conditions. Operational and supervisory control of the network is only possible if there are sufficient data of the possible behaviour of the network for the foreseeable future events – pre-

- 1 **Ing. Ivan Mrnčo, PhD.** – ITKON, spol. s r. o., Dohnányho 2, 917 02 Trnava, e-mail: ivan.mrnco@itkon.sk
- 2 **Ing. Peter Blštak** – ITKON, spol. s r. o., Dohnányho 2, 917 02 Trnava, e-mail: blstak@itkon.sk
- 3 **Ing. Peter Hudec** – ITKON, spol. s r. o., Dohnányho 2, 917 02 Trnava, e-mail: peter.hudec@itkon.sk
- 4 **Ing. Tomáš Gibala, PhD.** – DHI SLOVAKIA s.r.o., Hattalova 12, 831 03 Bratislava, e-mail: t.gibala@dhi.sk
- 5 **Prof. RNDr. Eva Michaeli, PhD.** – Katedra geografie a regionálneho rozvoja FHPV PU v Prešove, Ul. 17. novembra 1, 081 16 Prešov, e-mail: eva.michaeli@unipo.sk



precipitation and provided elements on the network that can be controlled – control devices, and the retention tanks. Expanding the role of modeling for the operational management of the network at the same time – hydroinformatics tool can also be used to quantify such phenomena as the possible flooding of the surface water from street drains, or assessment of the volume of water extract to the recipient via reliever chamber.

With knowledge of these data is their subsequent use quite diverse – the need to protect the population, the development of an urbanized area, as well as the need for integrated protection of the recipient.

Key words:

Operation of sewage system, GIS, SCADA, CIS, mathematical modeling, hydroinformatics, data mining, development of urban areas.

ÚVOD

Využitie znalostných technológií na podporu riadenia a prevádzky stokovej siete umožňuje nielen optimalizáciu prevádzky stokovej siete, poprípade odstránenie problematických úsekov, ale slúži aj na stanovenie kapacity stokovej siete. Práve kapacita stokovej siete je údaj, ktorý predstavuje percentuálne využitie stokovej siete, resp. informuje o zvyšnej kapacite, ktorá úzko súvisí s rozvojom urbanizovaných území. V úzkej spolupráci s mestami a obcami sa stanovujú výhľadové plochy a následne sa vypočítajú produkcie odpadových vôd. Pomocou skalibrovaného matematického hydraulického modelu sa vykonávajú simulácie nových projektovaných urbanizovaných plôch a vykoná sa hydraulický prepočet kapacity siete (množstvo odpadových vôd v stokovej sieti, rýchlosť prúdenia, kapacita kanalizačných potrubí). Z výsledkových dát sa vyhodnotí súčasný stav a v prípade nedostačujúcej kapacity stokovej siete sa navrhnu opatrenia, ktoré nepriaznivý stav odstránia.

Vytvorenie hydroinformatického systému, ktorý by dokázal reálne a vecne zobrazovať skutočnú situáciu na vybranom prvku vodohospodárskej infraštruktúry bolo v minulosti neuskutočniteľnou predstavou. V posledných rokoch sa tento cieľ stal realitou najmä vďaka prudkému rozvoju výpočtovej techniky a softvérových aplikácií. Tento postup reprezentuje vytvorenie matematického modelu, ktorý je najpoužívanejším nástrojom hydroinformatiky. Pre vytvorenie matematického modelu stokovej siete je potrebné získať a overiť podkladové dáta o stokovej sieti. Informácie z GISu sú konzultované s prevádzkovateľom stokovej siete, prípadné nepresnosti je potrebné objasniť pomocou rekognoscácie stokovej siete. Tento súbor dát obsahuje pomerne veľké množstvo informácií (priemery potrubí, materiál potrubí, kóta dna šachty, kóta terénu šachty, čerpacie stanice, odľahčovacie komory...) a ich spracovanie vyžaduje vyčlenenie dostatočného časového priestoru na ich spracovanie a verifikáciu. Hydraulický model je potrebné skalibrovať na základe dát z mernej kampane vykonanej na stokovej sieti v dostatočne dlhom časovom intervale. Chýbajúce dáta, ktoré sa



počas mernej kampane nezaznamenali, resp. nevyskytli (napr. určitý zrážkový úhrn a následná odozva na stokovej sieti v podobe prietokov na merných profiloch), je možné pomocou data miningu dopočítať.

Data mining je proces netriviálnej extrakcie implicitných, vopred neznámych a potenciálne použiteľných informácií z rozsiahlych dát. Jedná sa teda o proces odhalovania skrytých závislostí v dátach a vyhľadávanie vzorov za účelom modelovania a predikcie. Vo všeobecnosti platí, že získanie relevantných informácií o vzťahoch veličín a závislostiach v systéme vedie k zefektívneniu činností, zníženiu nákladov, zvýšeniu bezpečnosti, resp. inému druhu profitu. Data mining tak umožňuje využiť plný potenciál informácií obsiahnutých v dostupných dátach.

Data mining využíva k získaniu znalostí historické dáta z príslušnej oblasti, nad ktorými sa aplikujú štatistické metódy ako napríklad korelačná, či regresná analýza. Takéto prístupy umožňujú veľmi efektívne odhaliť spoločné črty určitých prípadov, taktiež nájsť vzťahy vo forme implikácie, teda závislosti typu: „ak veličina A stúpa, tak veličina B klesá“. Čo je však oveľa podstatnejšie, tieto závislosti je možné použitím numerických predikčných metód kvantifikovať a odhadnúť tak aj veľkosť zmeny veličiny B, a to aj pre výrazne nelineárne systémy. Nevýhodou je obmedzenie kladené štatistikou, ktorým je nutnosť dostatočného počtu záznamov - teda dostatočného počtu nezávislých experimentálnych meraní.

Data mining spolupracuje s viacerými ďalšími súvisiacimi oblasťami, patria sem najmä matematická štatistika, matematické modelovanie, neurónové siete, umelá inteligencia, strojové učenie, databázové systémy a podobne.

MATEMATICKÝ MODEL

Základné členenie matematických modelov používaných vo vodnom hospodárstve je možné podľa:

- účelu a spôsobu aplikácie
- typu systému, ktorý má byť simulovaný
- miery komplexnosti
- hĺbky a komplikovanosti väzieb
- rozsahu časovej a priestorovej schematizácie

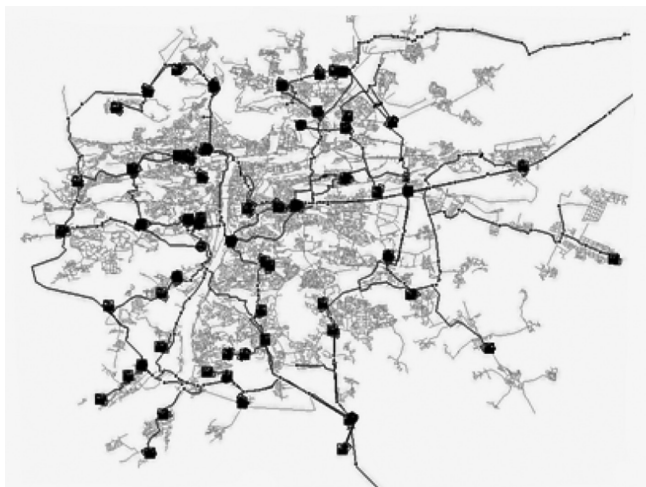
Samozrejme je členenie modelov podľa úrovne priestorovej schematizácie na 1D, 2D a 3D modely.

Použitie modelu zároveň predpokladá uskutočnenie niekoľkých krokov spočívajúcich najmä v dôkladnom a kontrolovanom zbere dát o systéme, ktorý chceme transformovať do formy matematického systému. Nasleduje výber vhodného softvérového nástroja, spracovanie a implementácia dát do vlastného modelu a najmä nevyhnutná kalibrácia a verifikácia vytvoreného systému. Podľa rozsahu schematizácie a účelu použitia sú pre vodohospodársku prax použiteľné dva základné typy modelov:

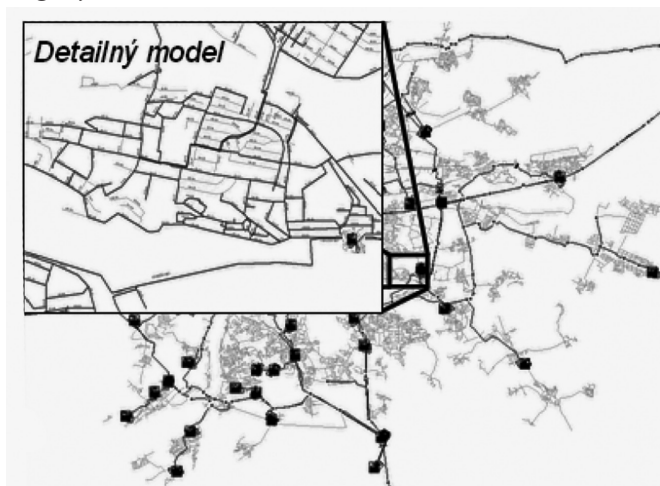
- koncepčný (strategický)
- detailný

Obr. č. 1: Úrovne matematických modelov

Strategický model



Strategický model



Strategické modely sa aplikujú ako nástroje na veľké vodohospodárske systémy s cieľom vytvorenia koncepcie, ako podkladu pre strategické rozhodovanie, či už o otázkach celkovej štruktúry systému, využívaní a spolupráci viacerých vodohospodárskych infraštruktúrnych prvkov až po optimalizačné úlohy v prevádzkovaní systému.



Naproti tomu detailné modely sú vzhľadom na oveľa menšiu mieru schematizácie využitelné na predikciu konkrétnych cieľov v oblasti systémov odvodnenia:

- obnova sietí
- detailné fungovanie systému odkanalizovania
- kapacita systému odvádzania vôd
- prieskumy kanalizačných sietí a balastné vody
- optimalizácia prevádzky čerpacích staníc
- výpočty hydraulických parametrov
- záplavové mapy
- posúdenie vplyvu kanalizačných systémov na režim kvality vody vo vodných tokoch
- posúdenie protipovodňových opatrení

Nie je potrebné zdôrazniť, že samozrejým trendom je vzájomné prepojenie strategických a detailných modelov s následnou implementáciou modelu do prostredia GIS-u a pri systémoch odvádzania vôd v urbanizovaných sídlach aj do prostredia dispečingu a ZIS-u [4].

MOŽNOSTI VYUŽITIA HYDROINFORMATICKÝCH NÁSTROJOV

Na báze matematického modelu stokovej siete, resp. systému odvodnenia je možné postaviť množstvo aplikácií. Jednou zo základných podmienok je potreba kalibrácie a verifikácie modelu na základe porovnania meraných údajov a modelovaných údajov. Po dosiahnutí želanej miery zhody je možné pristúpiť k riešeniu jednotlivých otázok. Pri využití hydroinformatického systému je ale potrebné zdôrazniť, že simuláciu nie je možné realizovať presne – vždy ide o zjednodušenie, ktoré sa nevyhnutne prejavuje skreslením výsledkových parametrov. Preto je nevyhnutným krokom kalibrácia a verifikácia modelu siete, pre čo najlepšiu mieru podobnosti reálneho systému s modelovaným. Kľúčovým faktorom pre použitie modelu sa tak stáva „inžinierska“ znalosť prevádzkovateľa. Model samotný nie je schopný nahradiť ľudské zdroje a rozhodnutia pri riadení, ale slúži ako podporný rozhodovací nástroj.

V súčasnosti začíname častejšie pozorovať javy označované ako „bleskové povodne“, aj keď príľahavejší názov by bolo skôr extrémne prívalové dažde a ich dôsledky. V priebehu niekoľkých desiatok minút sa na malom území vyprší často aj mesačný zrážkový úhrn a tento jav dokáže vyprodukovať odtok aj na takých miestach, kde dovtedy historicky nebol vôbec pozorovaný. Pri urbanizovaných územiach sa často kanalizačným systémom môže rozšíriť aj na miesta kde nepršalo, a takto sa kanalizácia stáva zdrojom možného povodňového ohrozenia. Rovnako je možné, že pri takto zvýšenom prietoku cez odľahčovaciu komoru dôjde k takému navýšeniu prietoku v recipiente, že vyvolá povodeň.

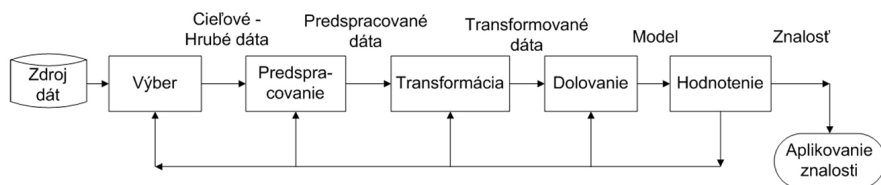
Predikcia takýchto udalostí je práve jedným z predmetov výskumu v rámci projektu KC ZATIPS – „Kompetenčné centrum znalostných technológií pre inovácie produkčných systémov v priemysle a službách“.

DATA MINING

Proces data miningu sa skladá z viacerých fáz. Tie však nie sú striktné definované; jednotlivé zdroje literatúry ich často uvádzajú mierne rozdielne. Jeden z možných pohľadov je znázornený na obr. č. 2.

Prvé tri bloky môžeme nazvať spoločným názvom ‚Výber a spracovanie dát‘. V prvej fáze sa teda jedná o selekciu relevantných atribútov z dostupných dátových zdrojov. Spracovanie pozostáva zo škálovania dát, odstraňovania záznamov s chýbajúcimi hodnotami, konverzie jednotiek, transformácie atribútov a podobne. Dáta je teda nutné očistiť od nežiaducich efektov (chýbajúce hodnoty, viacnásobné záznamy, poškodené dáta, a pod.), vykonať časovo – priestorovú synchronizáciu (prepočet na rovnaké časové intervaly, konverzie jednotiek, korekcie atribútov) a pripraviť ich tak na samotný proces trénovania modelu.

Obr. č. 2: Znázornenie fáz data miningového cyklu



Vo fáze dolovania (trénovania modelu) sa postupne prechádzajú trénovacie dáta, a hľadajú sa v nich relevantné vzťahy medzi vstupnými veličinami a cieľovou veličinou. Tieto vzťahy sa postupne integrujú do modelu, ktorý je schopný predikovať cieľovú veličinu na základe vstupných veličín.

Existuje veľké množstvo rozličných štruktúr a typov modelov. Medzi najpoužívanejšie patria umelé neurónové siete (dopredné, rekurentné, kononenové), rozličné stromové modely (rozhodovacie, regresné, či klasifikačné stromy), Bayesovské modely, Gaussovské procesy, či modely tvorené radiálnymi základnými funkciami. Taktiež je možné zvoliť rozdielne parametre modelu a tiež viaceré špeciálne metódy učenia modelu ako sú Boosting a Bagging. Po vytvorení modelu je nutné realizovať jeho hodnotenie (validáciu) k odhadnutiu presnosti modelu.

Vo fáze hodnotenia kvality modelu sa využívajú rozličné číselné charakteristiky. V prípade numerických spojitých veličín, sa často používajú štatistické číselné charakteristiky ako napríklad: stredná kvadratická chyba, stredná absolútna chyba, relatívna absolútna chyba, relatívna chyba, relatívna kvadratická chyba, či Pearsonov korelačný koeficient.

Po vyčíslení sledovaných charakteristík modelu stanovenou metódou validácie dochádza k rozhodovaniu. To spočíva v tom, či sa s dosiahnutou kvalitou modelu uspokojíme a je teda dostatočná pre danú aplikáciu, alebo sa vrátíme k niektorému



z predchádzajúcich krokov ako sú predspracovanie, či trénovanie a pokúsime sa zmenou štruktúry modelu, resp. zmenou trénovacieho algoritmu dosiahnuť model s lepšími vlastnosťami.

APLIKÁCIE DATA MININGU

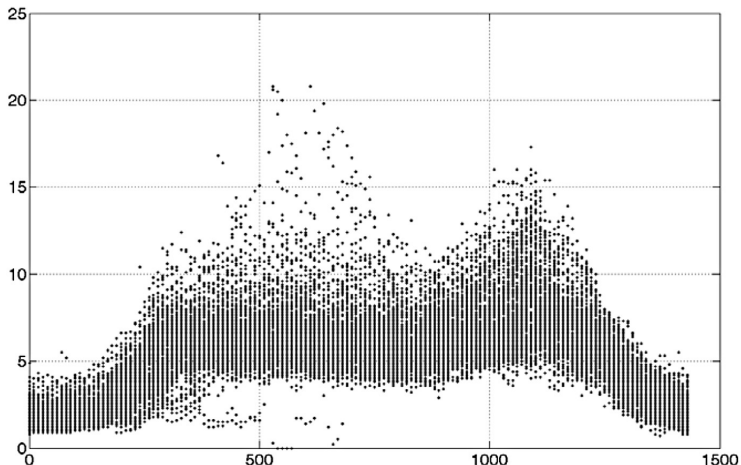
Techniky data miningu je možné aplikovať v rozličných doménach a odvetviach. Jedinými obmedzeniami sú dostupnosť dostatočného množstva dát (rádovo tisícky záznamov) a existencia vzoru, či vzťahu (závislosti) obsiahnutého v dátach. Veľmi známe sú aplikácie vo viacerých oblastiach: marketing (analýza nákupného košíka), časticová fyzika (identifikácia elementárnych častíc), ekológia (modelovanie vplyvu koncentrácie CO₂ na teplotu) a informatika (detekcia vírusov, spamové filtre). Techniky data miningu však boli úspešne aplikované aj vo viacerých ďalších odvetviach – na prvý pohľad menej intuitívnych, ako sú: ekonomika a bankovníctvo (vyhľadávanie podozrivých bankových transakcií), biológia (mapovanie ľudského genómu), astronómia (klasifikácia hviezdnych objektov), medicína a zdravotníctvo (identifikovanie spoločných príznakov chorôb, varovné systémy pred pandémiou), či chémia (modelovanie veličín v chemických reakciách). Existujú však aj data miningové aplikácie v oblasti hydrologie a meteorológie, napríklad experimenty realizované v rámci projektu ADMIRE [1] [2]. Prvý spomedzi scenárov – ORAVA je zameraný na predikciu výšky hladiny a teploty vody na rieke Orava za účelom varovania pred prílivovou vlnou, či upchatím koryta rieky. Využívajú sa pri tom aj dáta z meteorologického modelu Aladin, predpovedajúceho zrážkovú činnosť. Ďalší scenár – RADAR bol zameraný na meteorologickú predpoveď zrážok na základe radarových matíc odrazivosti. Scenár SVP sa zameriaval na modelovanie topenia horského snehu a jeho vplyv na výšku riečnych tokov.

MODELOVANIE PRODUKCIE ODPADOVÝCH VÔD

Celkovo data mining s rozdielnymi typmi modelov, trénovacích algoritmov a validačných techník, dokáže pokryť veľmi širokú oblasť problémov. Presvedčili sme sa o tom aj v prípade výrazne stochastického procesu – produkcie odpadových vôd. Produkciu odpadových vôd nie je možné úplne exaktne predpovedať, avšak využitím historických dát je možné ju štatisticky odhadnúť, za použitia vhodných regresných modelov.

Príklad produkcie odpadových vôd vo vybranej lokalite v priebehu dňa je znázornený na obr. č. 3, kde na osi x je čas v minútach; os y predstavuje produkciu odpadových vôd v litroch za sekundu. Každý bod v grafe reprezentuje jedno meranie.

Obr. č. 3: Produkcia odpadových vôd počas dňa



Tabuľka 1: Porovnanie kvality najlepších natrénovaných modelov spotreby vody

Model a parametre	Korelačný koeficient	Stredná absolútna chyba	Stredná kvadratická odchýlka
MLP* Regressor -N 2	0.7613	1.2485	1.6889
MLP* Regressor -N 10	0.7746	1.2224	1.6475
MLP* Regressor -N 20	0.7746	1.2226	1.6476
RBF** Regressor -N 2	0.7520	1.2799	1.7171
RBF** Regressor -N 10	0.7753	1.2211	1.6451
RBF** Regressor -N 20	0.7755	1.2204	1.6445
IsotonicRegression	0.5918	1.5328	2.0997
K-najbližších susedov K=5	0.7749	1.2211	1.6464

V tabuľke 1 sú zhrnuté výsledky najlepších natrénovaných modelov meranej produkcie odpadových vôd. Vidíme, že s narastajúcim parametrom N (N počet elementárnych regresných funkcií) narastá kvalita modelov. Avšak, pre N vyššie ako 10 sa už kvalita ustáľuje – saturuje.

*MLP – multi layer perceptron – viacvrstvomá neurónová sieť tvorená perceptronmi

**RBF – radial basis function – model tvorený radiálnymi základnými funkciami

V porovnaní modelov si môžeme všimnúť, že viaceré modely dosahujú približne rovnakú výkonnosť (MLP Regressor -N 20, RBF Regressor -N 20, K-najbližších susedov K=5). Signalizuje to stav, kedy sme pre danú dátovú množinu dosiahli maximálnu presnosť, alebo sme veľmi blízko pri nej. Z dosiahnutých výsledkov vi-



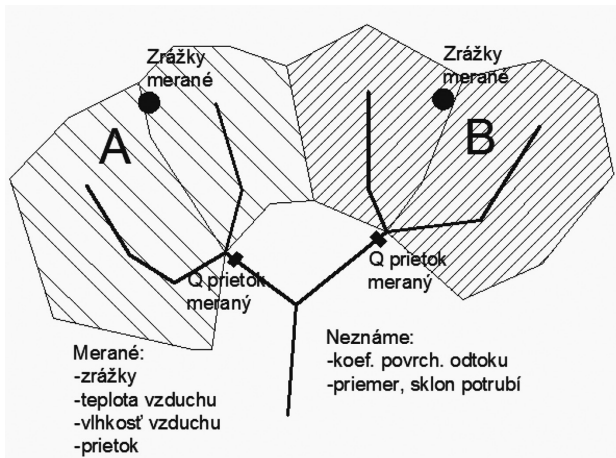
dieť, že najlepšie modely dosahujú strednú absolútnu chybu okolo 1,22 litra za sekundu. Avšak, ak sa pozorne pozrieme na graf produkcie odpadových vôd od času, uvidíme, že spotreba sa pohybuje vo výrazne širokých intervaloch, preto môžeme dosiahnutie strednej absolútnej chyby na úroveň 1,22 pokladať za úspešné.

Je zrejmé, že produkcia odpadových vôd je závislá okrem hodín dňa aj od rôznych iných ukazovateľov, napríklad od aktuálnej teploty. Preto pridaním ďalšej vstupnej veličiny – teploty vzduchu, môžeme presnosť modelu výrazne zvýšiť. Momentálne však nemáme k dispozícii dáta o teplote, preto zatiaľ tento experiment nemôžeme vykonať.

MOŽNOSTI VYUŽITIA DATA MININGU

Modelovanie produkcie odpadových vôd je len jedným spomedzi mnohých vodárenských problémov, v ktorých môže data mining poskytnúť nové netradičné a efektívne riešenia. Najzaujímavejším spôsobom aplikácie data miningu pre prevádzku stokovej siete je stanovenie zrážkoodtokových procesov a určenie množstva odpadových vôd v kanalizácii v závislosti od počasia. Predikcia množstva odpadových vôd v kanalizačnej sieti je postavená na vstupných dátach, ktoré predstavujú množstvo zrážok, teplotu vzduchu, vlhkosť vzduchu. Ďalším vstupným atribútom je už spomenutá produkcia odpadových vôd. Pre daný experiment je potrebné zbierať pomerne veľké množstvo historických dát. Zrážkomery a prietokomery, resp. hladinometry je potrebné osadiť na vytipovaných merných bodoch po dobu aspoň dvoch rokov. Samozrejme väčší súbor dátových vstupov zvyšuje presnosť tejto metódy. Týmto prístupom je možné pomocou metódy data miningu predpovedať odozvu správanie sa kanalizačného systému na meteorologické dáta.

Obr. č. 4: Experiment pre techniku data miningu





Keďže data mining vyžaduje dáta vo forme záznamov, a jednotlivé fyzikálne veličiny sú väčšinou merané a zaznamenané s rozdielnymi periódami, alebo dokonca nerovnomerne; je preto nutné dáta prevzorkovať. Je totiž podstatné, aby sme v pravidelných časových okamžikoch vedeli hodnoty všetkých sledovaných veličín. Na tento účel je možné použiť techniku bikvadratickej interpolácie, na základe ktorej sa určujú hodnoty veličín v čase medzi viacerými meranými hodnotami. Taktiež je možné aplikovanie kľzavého priemeru, či kvadratickej regresie namiesto bikvadratickej interpolácie.

Na takto upravených dátach je teda možné zamerať sa na jednu spomedzi vyššie položených úloh, a použitím relatívne jednoduchých dátových transformácií pristúpiť až k fáze trénovania modelu špecializovaného na zvolený typ úlohy. Momentálne pracujeme na definovaní konkrétnych úloh a určení príslušnej dátovej transformácie. V budúcnosti plánujeme natrénovat' viaceré modely na riešenie predložených úloh a porovnať ich s výsledkami fyzikálnych modelov.

ZÁVER

Znalostné technológie predstavujú moderné možnosti ako napomôcť prevádzkovateľovi pri bežných operatívnych úlohách, ale aj pri riešení otázok spojených so správou a údržbou siete z pohľadu asset managementu. Spojením a využitím spomenutých metód vzniká veľmi účinný nástroj na podporu rozhodovania – či už sa riešia úlohy spojené napr. s plánovaním bežnej údržby siete, alebo jej obnovy, tak aj po náročnejšie aplikácie typu riadenie odtoku alebo riešenie krízových udalostí a napojenie nových urbanizovaných území.

Účinné prevádzkovanie stokovej siete je možné po identifikovaní a pochopení fungovania celého systému. A práve pre tento účel sa črtá využitie prepojenia hydraulických (fyzikálnych) výpočtových modelov kanalizácie na model DM (tvorený technikou data miningu), kedy model DM môže namiesto historických dát použiť dáta z hydraulického modelu a naopak hydraulický model môže byť verifikovaný pomocou DM modelu.

Všetky tieto úlohy majú mnohé spoločné črty a vyžadujú takmer identické zlúčenie a predspracovanie dát. Následne na zlúčených a upravených dátach je možné riešiť aj viaceré ďalšie úlohy.

Na rozdiel od tradičných postupov modelovania procesov dynamiky prúdenia vody na základe fyzikálnych rovníc môže byť modelovanie pomocou metód DM efektívnejšie tam, kde vystupujú neznáme premenné, ktoré významne ovplyvňujú fyzikálne správanie. Takýmito neznámymi premennými sú väčšinou údaje o aktuálnej produkcii odpadových vôd, neznáme profily potrubí v stokových sieťach ako aj neznáme kóty dna šácht. Na rozdiel od výpočtového hydraulického modelu sú výsledky k dispozícii okamžite bez nároku na výpočtový čas a bez nároku na znalosti v oblasti modelovania a špeciálnych softvérových zručností.



LITERATÚRA:

- Hluchý L., Habala O., Viet D. Tran, Peter Krammer, Branislav Simo: *Using ADMIRE framework and language for data mining and integration in environmental application scenarios*. FSKD 2011: 2437-2441.
- Viet D. Tran, Ladislav Hluchý, Ondrej Habala, Branislav Simo, Peter Krammer: *ADMIRE platform for distributed data integration and mining*. FSKD 2011: 2663-2666.
- Mrnčo I., Poláček M., Blštak P., Hudec P., Gibala T., Brtko P.: *Odvádzanie odpadových vôd ako zdroj povodňového znečistenia*: Konferencia Odpadové vody 2012, NOI Bratislava, ISBN: 978-80-970896-2-7.
- Mrnčo I., Blštak P., Poláček M.: *Štruktúra dát v systémoch hydroinformatiky a ich vzájomné prepojenie*. Konferencia Inovatívne informačno-komunikačné technológie vo vodnom hospodárstve. ISBN: 978-80-89535-14-9.
- STN 75 6261 *Dažďové nádrže*. Bratislava: 1992.
- Urcikán, P., Rusnák, D., Stanko, Š.: *Stanovenie bilančných veličín na posudzovanie činnosti odľahčovacích komôr*. Vodohospodársky spravodajca 5/2001.
- EN 752 (August 1992): *Entwässerungssysteme außerhalb von Gebäuden (Deutsche Fassung*. Deutsches Institut für Normung, e.V., Berlin.

Poznámka

„Tento príspevok vznikol vďaka podpore v rámci operačného programu Výskum a vývoj, pre projekt: Kompetenčné centrum znalostných technológií pre inovácie produkčných systémov v priemysle a službách, kód ITMS: 26220220155, spolufinancovaný zo zdrojov Európskeho fondu regionálneho rozvoja.“

SUMMARY

THE USE OF THE KNOWLEDGE TECHNOLOGIES TO SUPPORT MANAGEMENT AND OPERATION OF COLLECTION SYSTEM AS A BASIS FOR THE DEVELOPMENT OF THE URBAN AREAS.

Aim of the study was to identify possible background data for the development of the urban areas in field of the collection systems. In present there are existing more knowledge technologies as mathematical hydraulic model, GIS, SCADA, CIS etc. These systems can work separately or can exchange data each other. Hydraulic evaluation of the collection system is based on the data from operation of the collection system. Input data are used for creating mathematical model. Next step is to collect calibration data from measurement campaign (rainfalls, flow in the collection pipes, water level in the collection pipes). Based on these data the mathematical hydraulic model is calibrated and is representing real behaviour on the collection system – hydraulic evaluation of the system. Another possibilities how to predicted behaviour



of the collection system is to collect huge amount of the input data and used them for data mining. Data mining is process of detecting hidden dependencies on the data and search for the patterns to modelling prediction of the data. Data mining makes possible to exploit the full potential of the information contained in the evaluated data. This technology uses knowledge of historical data from the area for applying statistical methods such as correlation and regression analysis. Efficient operation of the collection system can be identified only by the understanding of the functionality of the whole system. Use of the connections between mathematical hydraulic models and data mining models can bring better understanding of collection system behaviour. Data mining model can instead of historical model to use data from the hydraulic model and mathematical model can be verified using the data mining model. By joining and using of aforementioned methods involve a very effective tool to support decision – to solve challenges related to the planning of routine maintenance or its renewal, as well as the more demanding applications like managing runoff or responding to crisis events or connection of new urban areas to the existing collection system.