

Az eleveniszapos szennyvíztisztítás biokémiai folyamatainak modellezése

Modeling of the Biochemical Processes of the Activated Sludge Wastewater Treatment Technology

Modelarea proceselor biochimice ale tehnologiei de epurare cu nămol activ

RÁDULY Botond¹, Ph.D, CROGNALÉ Silvia²,
Ph.D, SZILVESZTER Szabolcs¹, MÉSZÁROS Sándor¹, Ph.D

¹ Sapiientia Erdélyi Magyar Tudományegyetem, Műszaki és Társadalomtudományok Kar,
Csíkszereda, Szabadság tér 1. sz, tel: 0266317121, fax: 0266372099,
radulybotond@sapiientia.siculorum.ro, www.csik.sapiientia.ro

² Università degli Studi della Tuscia, DABAC, Via San Camillo de Lellis snc, Viterbo,
Italia, fax: 0039-0761357242, www.unitus.it

ABSTRACT

Modeling and simulation of the activated sludge wastewater treatment processes proved to be very useful in the design, upgrade, control, evaluation and optimisation of wastewater treatment plants. This paper introduces existing activated sludge models and discusses different modeling techniques that can be used for the above tasks. Besides the description of the „traditional” Activated Sludge Models (ASMs), the paper suggests that Artificial Neural Network (ANN) models can successfully be used for many modeling applications, outperforming the ASMs in some aspects. Advantages and disadvantages of ANN modeling are also discussed.

REZUMAT

Modelarea și simularea proceselor din tehnologia de epurare cu nămol activ a apelor uzate este de mare folos în proiectarea, re tehnologizarea, controlul și optimizarea stațiilor de epurare. Această lucrare descrie cele mai importante modele de nămol activ și discută diverse tehnici de modelare ce pot fi folosite pentru aplicațiile de mai sus. Pe lângă descrierea modelelor „tradiționale” ASM, lucrarea propune folosirea modelelor de rețele neurale artificiale (RNA) în anumite cazuri, acestea din urmă fiind mai performante din câteva aspecte decât modelele ASM. Avantajele și dezavantajele modelelor RNA sunt prezentate și ele.

ÖSSZEFOGLALÓ

Az eleveniszapos szennyvíztisztítás folyamatainak modellezése és szimulációja igen hasznosnak bizonyul a szennyvíztisztítók tervezésénél, korszerűsítésénél, vezérlésénél és optimalizálásánál. Ez a dolgozat bemutatja a fontosabb eleveniszap-modelleket és különböző modellezési eljárásokat tárgyal, amelyek a fenti feladatokra használhatóak. A már hagyományosnak számító ASM modellek leírásán túl a dolgozat rávilágít arra, hogy sok szimulációs feladatra a neuronháló-modellek is kiválóan alkalmasak, bizonyos tekintetben túlszárnyalva az ASM modelleket. A dolgozat tárgyalja a neuronháló modellek előnyeit és hátrányait is.

Kulcsszavak: modellezés, eleveniszap, szennyvíztisztítás, biokémiai folyamatok, neuronhálók

1. BEVEZETÉS

A modellezés és szimuláció nagymértékben képes hozzájárulni az eleveniszapos szennyvíztisztítók tervezéséhez és azok működésének a megértéséhez. A szennyvíztisztító jól megalkotott matematikai modellje, amely képes megjósolni, hogy a szennyvíztisztítónk miként fog viselkedni különböző működési körülmények között, egy kiválóan felhasználható eszköz a szennyvíztisztító-tervezésben, -elemzésben, vezérlésben és optimalizálásban.

Egy szennyvíztisztító-modell a szennyvíztisztítás biokémiai és fizikai folyamatait írja le matematikai egyenletekkel. Ideális esetben a biokémiai folyamatokon keresztül a szennyvíz szervesanyagtartalma végső soron széndioxidá, nitrogénné és egy szilárd frakcióvá alakul (beépül a mikroorganizmusok sejtjeibe). Ez utóbbi a víztől fizikai elválasztási módszerekkel (ülepítéssel) választható el. A fentiek értelmében egy eleveniszapos szennyvíztisztító modell legtöbbször két összekapcsolt modellből áll: az eleveniszap-modellből és az ülepítő-modellből.

2. MECHANISZTIKUS SZENNYVÍZTISZTÍTÓMODELLEK

2.1. Eleveniszap-modellek

A mechanisztikus (elméleti) modellek az eleveniszapos szennyvíztisztításban résztvevő folyamatokat meghatározó fizikai és biokémiai egyenletekre alapulnak. E modellekben jellemzően a biokémiai folyamatok modellezésén van a hangsúly, valamint az ülepítő hidrodinamikájának leírásán. A szennyvíztisztító hidrodinamikája általában kevésbé részletesen van modellezve; ennek oka egyrészt az, hogy a reaktorok hidrodinamikája általában nem jól ismert, másrészt pedig a biokémiai folyamatok modellezésének egyszerűsítő feltételezései sokkal merészebbek, mint a hidrodinamika leírásában alkalmazottak. Egy gyakran használt megoldás a szennyvíztisztítónak néhány sorba kötött, tökéletesen kevert folytonos tankreaktorral (CSTR) történő leírása. Ily módon legalább a keveredés folyamata modellezve van.

A biokémiai folyamatok modellezése néhány fontos kinetikai egyenletre alapul, amelyek a mikroorganizmusok növekedését és leépülését, a szubsztrátum elhasználását, a szerves anyag hidrolízisét, stb. írják le. Az utóbbi néhány évtizedben több eleveniszap-modellt dolgoztak ki, amelyek más és más módon írták le a végbemenő biokémiai folyamatokat [1, 2, 3]. A jelenleg referenciának számító eleveniszap-modell az IWA (International Water Association) egy munkacsoportja által kifejlesztett ASM modelleszalád (ASM1, ASM2, ASM2d és ASM3) [4]. Ezek a modellek képesek leírni a karbonoxidációt, nitrifikálást és denitrifikálást, az ASM2d pedig a biológiai és kémiai foszforeltávolítás egyenleteit is tartalmazza. Az ASM modellek az ASM1 első megjelenése (1987) óta többször is frissültek, és az első változatokban azonosított problémákat nagyrészt orvosolták. Ezek a modellek KOI-alapúak, vagyis a kémiai oxigénigényt használják a szerves széntartalom kifejezésére; az ASM3-nak van egy teljes szerves szén (TOC) alapú változata is. Az ASM modelleket részletesen ismerteti a szakirodalom, a továbbiakban csak a legutóbbi, ASM3 modellben leírt folyamatokat tárgyaljuk [4].

Az ASM3 megszületésének fő oka a korábbi ASM1 hibáinak kiküszöbölése, valamint az eleveniszap-modellezésben az ASM1 publikálását követő időszakban elért fejlesztések alkalmazása volt [5]. Ez a modell 12 biokémiai folyamatot és 13 állapotváltozót tartalmaz, de nem foglalja magába a biológiai vagy kémiai foszforeltávolítás folyamatait. Ez utóbbiak azonban viszonylag könnyen beépíthetők a modellbe. Siegrist *et al.* (2002) kifejlesztettek egy egyszerű bio-P modult az ASM3 számára, amely egy svájci települési szennyvíztisztító esetében pontos szimulációs eredményeket szolgáltatott [6].


Az ASM3 a szennyvízben lévő összetevőket 13 kategóriára osztja, ezek a modell állapotváltozói:

- S_{ALK} - a szennyvíz alkalinitása [$\text{mól HCO}_3/\text{m}^3$]
- S_I - inert oldott szerves anyag [$\text{g KOI}/\text{m}^3$]
- S_S - biológiailag könnyen bomló szerves szubsztrátum [$\text{g KOI}/\text{m}^3$]
- S_{N2} - di-nitrogén [$\text{g N}/\text{m}^3$]
- S_{NH4} - ammónium- és ammónia-nitrogén [$\text{g N}/\text{m}^3$]
- S_{NOX} - nitrát- és nitrit-nitrogén [$\text{g N}/\text{m}^3$]
- S_{O2} - oldott oxigén [$\text{g KOI}/\text{m}^3$]
- X_{SS} - össz-lebegőanyag tartalom [g/m^3]
- X_A - nitrifikáló organizmusok [$\text{g KOI}/\text{m}^3$]
- X_H - heterotróf organizmusok [$\text{g KOI}/\text{m}^3$]
- X_I - inert oldatlan szerves anyag [$\text{g KOI}/\text{m}^3$]
- X_S - biológiailag nehezen bomló szubsztrátum [$\text{g KOI}/\text{m}^3$]
- X_{STO} - a heterotrófok által tárolt szerves anyag [$\text{g KOI}/\text{m}^3$]

Az ASM3 12 biokémiai folyamatot modellez. Az 1. ábra vázlatos módon ábrázolja az állapotváltozók-nak az átalakulási folyamatokkal való kapcsolatát. A biokémiai átalakulási folyamatok kinetikai egyenletei részletesen a [4]-ben vannak leírva, a továbbiakban csupán felsorolásuk következik:

- a szerves anyag hidrolízise biológiailag könnyen bontható oldott szubsztrátummá
- az oldott szubsztrátum tárolása a heterotrófokban anoxikus és aerob körülmények között
- a heterotróf organizmusok növekedése aerob és anoxikus körülmények között
- a heterotróf organizmusok leépülése aerob és anoxikus körülmények között
- autotrófok aerob növekedése

- autotrófok aerob és anaerob leépülése
- a szervesanyag-tároló termékek aerob és anaerob leépülése



1. ábra

A KOI útja az ASM3-ban (Henze et al., 2000 után).

A heterotróf biomasszában van egy sejten belüli tároló frakciója is. Az endogén respiráció aerob és anoxikus körülményekre is modellezve van, a mikroorganizmusok és a tároló frakció esetében is.

2.2. Ülepítőmodellek

Az ülepítő modellezése nélkül nem lehetne bezárni egy eleveniszap-recirkulációt alkalmazó szennyvíztisztító anyagmérlegét. Az ülepítőmodellek üledési függvényeken alapulnak, amelyek a részecskék üledési sebességét hivatottak megadni, általában a lebegőanyag-koncentráció függvényében. A legnépszerűbbek a réteg-megközeztésen alapuló egyszerű 1-D modellek (csak függőleges mozgást írnak le), ezek közül is leggyakrabban az ún. „Takács modell”-t alkalmazzák [7]. Ezek a modellek kielégítő részletességgel írják le az üledés és iszapsűrűsödés folyamatait, miközben számításigényük alacsony marad. Az 1-D modellek megfelelőek az eleveniszap-modellek anyagmérlegének bezárására és valamelyes mértékben modellezik az iszap átmosódását is a bioreaktorból az ülepítőbe. A biokémiai folyamatok egyenleteit általában nem tartalmazzák az ülepítőmodellek, mert az ülepítőben lejárló átalakulási folyamatok kevésbé fontosak [8].

A gyakorlatban az ülepítőmodellek számítógépes kódolása a réteg-megközeztés segítségével valósul meg. Az ülepítőt több vízszintes rétegre osztjuk (leginkább 10 rétegre) és az anyagmérleg differenciálegyenletét minden rétegben megoldjuk. Az iszap valamelyik közbenső rétegben fog belépni, a legfelső réteg koncentrációja az elfolyónak felel meg, a legalsó réteg pedig a recirkulált iszap koncentrációját adja meg.

2.3. A modellek bonyolultsága okozta problémák

A bonyolultság problémája abból a hitből adódik, hogy minél részletesebb egy modell, annál pontosabban leírja a valóságot. Ezért a modellek kifejlesztésekor elsődleges szempont, hogy minél több ismeretet sűrítünk beléjük, a modellezett folyamat lehető legjobb leírása érdekében. A modellek az idők során egyre bonyolultabbak lettek, túl sok paramétert tartalmaznak és ezért igen nehezen kalibrálhatóak. Innen jön a *túlparametrizáltság* fogalma [9].

A túl bonyolult modellek másik hátránya, hogy igen magas a számításigényük. A szennyvíztisztítómodelleknek a folyamatok igen széles skáláját kell leírniuk, és a leírt folyamatok időskálája is igencsak eltérő (pl. másodperces az oxigénbeoldódás és évszakos a hőmérsékletváltozás esetén). Ez egy matematikailag merev differenciálegyenlet-rendszert eredményez, amelyet numerikus módszerekkel nehézkes megoldani. A helyzetet tovább rontja, hogy a szennyvíztisztító-modell vezérlőköréi kizárják a merev integráló szolverek használatát, így még lassabb szimulációkhoz vezetnek [10].

3. EMPIRIKUS SZENNYVÍZTISZTÍTÓMODELLEK

A mechanisztikus modellekkel ellentétben az empirikus modellek nem használnak a leírandó folyamatokkal kapcsolatos előzetes ismereteket, hanem egyszerűen a bemeneti és kimeneti változók (általában mért adatok) közötti összefüggések azonosításán alapulnak. Az empirikus modellek a gyökerénél ragadják meg a mechanisztikus modellek két nagy problémáját, a modell-komplexitást és az alacsony szimulációs sebességet. Az „empirikusok” szerint a modellezendő folyamatok végtelenül bonyolultak, ezért nem is lehetne őket pontosan modellezni, a folyamat részletes leírása tehát nem lényeges, elegendő ha pontos a modell bemeneti/kimeneti válasza (jóslási képessége). A szimulációs sebesség terén pedig sokszoros előnyük van az empirikus modelleknek, hiszen a differenciálegyenletek helyett egyszerű algebrai egyenletekből állnak, ezek megoldása nem erőforrásigényes.

3.1. Mesterséges neuronhálók

Az empirikus modellezési módszerek közül a mesterséges neuronhálók (MNH) a legelterjedtebbek a szennyvíztisztítómodellezésben [11, 12, 13]. Egy MNH-modell egy csoport párhuzamosan összekapcsolt egyszerű számítási egységből áll, amelyeket neuronoknak neveznek. Egy ilyen modell két tekintetben hasonlít az agyhoz: (1) az ismereteket egy tanulási folyamaton keresztül sajátítja el és (2) a tudást a neuronok közti kapcsolatok súlyaiban tárolja [14]. A tanulási folyamatban a kapcsolatok súlya állítódik be oly módon, hogy a MNH egy adott bemenetre a kívánt választ adja [15]. Egy jól betanított MNH általánosítani tud a tanításhoz használt példákból.

3.2 Milyen MNH alkalmas az eleveniszapos szennyvíztisztítás modellezésére?

Az eleveniszapos szennyvíztisztítási folyamatok MNH-modellezésének van néhány specifikus vonzata, amelyekről nem esik szó a MNH - amúgy igen részletes - szakirodalmában. Mivel a MNH-s szennyvíztisztítómodellezés egy meglehetősen ismeretlen terület, egy kísérletsorozatot végeztünk, amelyben a különböző MNH-specifikus paramétereknek az eleveniszap-változók jóslására kifejtett hatását mértük fel.

A MNH-tesztek során vizsgált paraméterek: a tanítási algoritmus típusa, a MNH-architektúra, a tanítási adatok mintavételezési frekvenciája és a tanítási adatsor összetétele. Több száz MNH mérettetett meg, az elbírálás a jóslási képesség, a szimulációs sebesség és a tanításhoz szükséges idő figyelembevételével történt. Minden esetben statikus *feedforward-backpropagation* neuronhálókat tanítottunk be az alábbi szennyvízparaméterek jóslására:

- ötnapos biokémiai oxigénigény (BOD₅)
- összes nitrogén (TN)
- összes Kjeldahl nitrogén (TKN)
- oldott ammónium (SNH₄)
- össz-lebegőanyagtartalom (X_{SS})
- kémiai oxigénigény (COD)

A neuronhálók megalkotására, tanítására, validálására, tesztelésére és alkalmazására a Matlab 7.3 (The Mathworks, Inc.) Neural Network eszköztárát használtuk. A nevezett eszköztár összes tanítási algoritmusából a konjugált gradiens algoritmusok teljesítettek a legjobban a tesztjeink során.

Mivel jó minőségű (magas mintavételezési frekvenciájú, hiánytalan) bemenő és kimenő szennyvíztisztítóadatokat igen nehéz találni, az IWA/COST teljesítményvizsgáló szimulációs szennyvíztisztítójának (benchmark simulation plant - BSM1) bemenő és kimenő adatait használtuk fel a tanításhoz [16]. A BSM1 ötreaktoros elrendezésű, az első két reaktor anoxikus és tökéletesen kevert (egyenként 1000 m³), az utolsó három pedig levegőztetett (egyenként 1333 m³). A legutolsó reaktorban az oxigénszintet egy PI-kontroller tartja 2 mg/l értéken. A BSM1 nem tartalmaz előülepitőt, a meghatározás szerint a reaktorokba bemenő szennyvíz a mechanikus tisztításon már túlesett. A szekunder ülepitő 6000 m³ térfogatú és 1500 m² felületű, az iszap betáplálása az ülepitő aljától számított 2.2 m magasságban történik. A BSM1 összes specifikációját igen hosszas lenne itt felsorolni, de megtalálhatóak a szakirodalomban [16]. A hosszútávú szimulációkra a BSM1 bemenő adatait egy szennyvízösszetétel-generáló modullal (influent disturbance generator) hoztuk létre [17].

A tesztjeink során legjobban teljesítő MNH adatai az 1. táblázatban láthatóak.

1. Táblázat A legjobban teljesítő neuronháló specifikációi


MNH típusa	Statikus, <i>feedforward, backpropagation</i>
Tanítási algoritmus	Konjugált gradiens Polak-Ribiere frissítéssel
Kezdeti súlyok	Random Gauss-eloszlás
Leállási kritérium	Kereszt-validálás
Neuronok száma	145 / 35 / 25 / 6
Neuronok típusa	Tan-szig / Tan-szig / Tan-szig / Lineáris
Vándorló ablak mérete	20 óra
Adatelőkészítés	Zéro-alapú normalizálás [-1,+1]
Tanítás/validálás	6 / 1 (minden 7. adatot validálásra használ)
MNH optimalizálás	Regularizáció, PPR = 0.85

3.3 Eleveniszap-specifikus problémák

MNH-kísérleteink eredményeiből három fontosabb részletet emelünk ki. Ezek a bemeneti adatok összevöire, a tanítási adathalmaz hosszára és a MNH-architektúrára vonatkoznak.

a) *A bemeneti adatok összetétele:* eredményeink azt mutatják, hogy a szennyvízparaméterek pontos jóslása csak a múltbéli bemeneti adatok felhasználásával lehetséges. Ez a gyakorlatban egy ún. vándorló ablakkal történik, amely a felhasznált múltbéli adatok számát (a $T-n \dots T$ időpillanatokból) határozza meg a kimenő adatok minden T jóslási pillanatára (2. ábra). Ily módon a MNH információhoz jut az eleveniszap „történelmét” illetően és a rendszer aktuális állapotát veheti figyelembe. Eleveniszapos rendszereknél ez igen fontos, mert pl. a mikroorganizmus-koncentráció egy adott pillanatban nagyban függ a múltbéli paraméterektől. A szükséges mozgó ablak méretét az eleveniszap populációdinamikája határozza meg.


A 3. ábrán a vándorló ablak hatását láthatjuk a MNH-k jóslási képességére. Világosan látszik, hogy amint nő a felhasznált múltbéli adatok száma, a jóslás is egyre pontosabbá válik. Ugyanakkor a különböző paraméterek jóslása között jelentős eltérések mutatkoznak. A BOD_5 és a X_{SS} pl. pontosan jósolható már néhány múltbéli adat figyelembevételével is, míg a COD és TN kielégítő pontosságú jóslása nagyméretű vándorló ablakot igényel.



2. ábra

Múltbéli bemeneti értékek felhasználása a jósláshoz egy vándorló ablak segítségével.

Az elfolyó X_{SS} és BOD_5 könnyű jósolhatósága arra enged következtetni, hogy ezen változók koncentrációját meghatározó folyamatok egyszerűbbek mint az eleveniszapban lejátszódó többi folyamat, így a MNH könnyebben azonosítja a bemeneti/kimeneti összefüggéseket. Valóban, az elfolyó X_{SS} koncentráció főként az ülepedési folyamatoktól függ és csak kisebb mértékben befolyásolják a biokémiai folyamatok. Ugyanez érvényes a BOD_5 -re is, hisz kevés paramétertől függ, leginkább a biomassza- és oxigénkoncentráció határozza meg. A nitrogéntartalmú összetevőkért és a kémiai oxigénigényért felelős reakciók bonyolultabbak és hosszabb időt igényelnek, ezért ezen változók jóslása nehezebb feladat.



3. ábra

Jóslási pontosság a vándorló ablak méretének függvényében

b) *A tanítási adathalmaz hossza:* mivel az eleveniszap biokémiai folyamatainak jó része igen lassú dinamikájú (pl. a bakteriális növekedés), a tanításra használt adatok több hónapot is le kell fedjenek. Ha a hőmérséklet hatását is modellezni szeretnénk, akkor legalább egy fél évre kiterjedő adatsorral kell tanítani, hiszen ennyi idő szükséges a szennyvíz átlaghőmérsékletének a legkisebbtől a legnagyobbra való emelkedéséhez (január-július). Jó tanítás csak reprezentatív tanítási adatokkal érhető el. Ha mesterségesen generált adatokkal tanítunk, akkor a hőmérsékleti jel frekvenciájának megduplázásával az éves hőmérsékletváltozást besűrítjük egy fél évbe. Ez tapasztalatunk szerint pontosabb jósláshoz vezet.

c) *A MNH architektúrája:* a múltbéli bemenetek vándorló ablakának a használata a bemeneti neuronok számának növekedését vonja maga után. Ebből kifolyólag a jó predikciós képességekkel rendelkező MNH-ink mind igen nagyméretűek, akár 200-nál is több neuronból állnak. Eredményeink (2. táblázat) azt mutatják, hogy a háló architektúrájának csak moderált szerepe van a jóslás pontosságára (kivéve természetesen ha túl kevés neuront használunk). A két rejtett rétegbe szervezett neuronhálók valamivel jobban jósolnak mint az azonos számú neuront tartalmazó egyrétegűek, de ami ennél fontosabb, hogy rövidebb idő alatt tanulnak. Nagy komplexitású neuronhálók esetén akár 40-50%-al rövidebb tanítási idők is elérhetőek kétrétegű MNH alkalmazásával. Ugyanakkor azt is kell

látni, hogy a tanításhoz szükséges idő egyre hosszabb lesz a neuronok számának növekedésével, míg a jóslási pontosság csak kismértékben javul. Ezért a túlságosan nagyméretű MNH-k használata nem ajánlott, és inkább kétrétegű hálót érdemes használni a tanítási idő minimalizálásának érdekében.

2. Táblázat: a hálóarchitektúra hatása a MNH teljesítményére

Rejtett neuronok száma		Tanítási idő (s)	Átlagolt R^2
1. réteg	2. réteg		
20	-	161	0.972
25	-	198	0.973
35	-	272	0.973
14	6	150	0.973
15	10	171	0.973
20	15	215	0.975

3.4. MNH-modellek szimulációs sebessége

A legjobb neuronhálónk (lásd 1. táblázat) szimulációs sebessége kb. 0.8 év/sec egy 1.8 GHz órajelű processzoron tesztelve, míg a tanítás 5 percet vett igénybe. Ez önmagában kb. 1000-szer gyorsabb szimulációt eredményez, mintha mechanisztikus modellt használnánk. Ha beleszámítjuk a tanítási adatok generálásához, valamint az utólagos adatfeldolgozáshoz szükséges időt is, akkor a 20 éves MNH-szimuláció majdnem 13 percet vett igénybe. Ez kb. 32-szer kevesebb, mint ugyanazt a szimulációt mechanisztikus modellel lefuttatni (kb. 7 óra). A mechanisztikus szennyvíztisztító-modell több mint 80 differenciálegyenletét megoldani processzorizzasztó feladat, ezzel szemben a MNH-matematika meglehetősen egyszerű, és ez meg is látszik a szimulációs sebességen. Olyan alkalmazások esetén, ahol a szimulációs sebesség fontos és a MNH jóslási pontossága kielégítő, a MNH-modell jobb választás a mechanisztikus modellel [12].


3.5. MNH-modellek jóslási pontossága

Egy jól megépített MNH jóslási pontossága sok modellezési feladathoz kielégítő lehet. A 3. táblázat 20 éves szimuláción vizsgált átlagos jóslási pontosságokat tartalmaz, a jósolt változókra külön-külön számolva. A korrelációs együttható a mechanisztikus modell szimulációs eredményeihez van viszonyítva. Az adatok a legjobban teljesítő neuronhálókra vonatkoznak (jellemzőit lásd az 1. táblázatban)

3. Táblázat: MNH-predikció jósági mutatói

Jósolt változó	BOD ₅	X _{SS}	COD	S _{NH4}	TKN	TN
R^2	0.990	0.990	0.978	0.975	0.975	0.958
Átlagos relatív hiba (%)	1.27	1.35	1.62	2.59	2.52	2.97

A 4. ábra a két modellezési megközelítéssel kapott szimulációs eredmények egy részletét mutatja. Megfigyelhető, hogy a MNH nagyon jól teljesít a kimenő COD és BOD₅ jóslásában, és valamivel rosszabbul a TN és az S_{NH4} esetén. A modellek helyesen leírják a napi koncentrációingadozásokat, lásd pl. a száraz napok egyes ammóniumcsúcsait. A 6493. napon egy eső hatása látható: a szennyvíztisztító nem tud megbírkózni a csúshozamokkal, és mindkét modell képes ezt leírni. A MNH-modell az eső alatti koncentrációcsúcsokat kissé alábecsüli.



4. ábra

szennyvízparaméterek jóslása mechanisztikus ASM3-alapú és MNH modellel

4. KÖVETKEZTETÉSEK

Míg az eleveniszapos szennyvíztisztítók mechanisztikus modellezése már jól bejáratottnak mondható, és jól működő komplett modell-leírásokat találunk a szakirodalomban, addig igen keveset tudunk az empirikus modellezés alkalmazhatóságáról ezen a téren. Eredményeink azt mutatják, hogy a mesterséges neuronhálók alkalmasak a szennyvíztisztítók bemeneti/kimeneti összefüggéseinek azonosítására. A statikus *backpropagation* neuronhálók igen jól teljesítettek, még ha a modellezett rendszer komplexitása kiemelkedően magas is volt. Rámutattunk, hogy a bemeneti adatok összetétele van a legnagyobb hatással a jóslási pontosságra, míg a hálóarchitektúra csak kismértékben befolyásolja azt. Ez egyben azt is jelenti, hogy előre meghatározott architektúra és tanítási beállítások használhatóak különböző szennyvíztisztító-berendezések modellezésére. Ezáltal a MNH-modellezés területén kevésbé járatosak számára is elérhetővé válik ezen modellek használata. Az így származtatott MNH-modellek elég jók ahhoz, hogy sok modellezési alkalmazásban kiváltsák a mechanisztikus modelleket, jelentősen felgyorsítva ezáltal a szimulációkat.

IRODALMI HIVATKOZÁSOK

- [1] W.W. Eckenfelder, "Industrial Water Pollution Control". McGraw-Hill, New York, **1966**
- [2] G.v.R. Marais and G.A Ekama. The Activated Sludge Process: Part 1 - Steady State Behaviour, *Water SA*, **1976**, 2, 163-200.
- [3] A.C. Van Haandel, G.A. Ekama and G.v.R. Marais: The Activated Sludge Process: Part 3 - Single Sludge Denitrification, *Water Research*, **1981**, 15, 1135-1152.
- [4] M. Henze, W. Gujer, T. Mino, M.C.M. van Loosdrecht: "Activated Sludge Models ASM1, ASM2, ASM2d, and ASM3". IWA Scientific and Technical Report n. 9. IWA Publishing, London, UK, **2000**.
- [5] W. Gujer, M. Henze, T. Mino and M.C.M. van Loosdrecht: Activated sludge model No. 3. *Water Science and Technology*, **1999**, 39(1), 183-193.
- [6] H. Siegrist, L. Rieger, G. Koch, M. Kühni and W. Gujer, The EAWAG Bio-P module for activated sludge model No. 3. *Water Science and Technology* **2002**, 45 (6), 61-76
- [7] I. Takács, G.G. Patry and D. Nolasco: A dynamic model of the clarification thickening process. *Water Research*, **1991**, 25(10), 1263-1271.
- [8] G.A. Ekama, J.L. Barnard, F.W. Gunthert, P. Krebs, J.A. McCorquodale, D.S. Parker and E.J. Wahlberg: "Secondary settling tanks: theory, modelling and operation". IAWQ Scientific and Technical Report no.6, London, **1997**
- [9] P.Harremoës and H. Madsen: Fiction and reality in the modelling world – balance between simplicity and complexity, calibration and identifiability, verification and falsification; *Water Science and Technology*, **1999**, 39(9), 1-8.
- [10] U. Jeppsson, "On the verifiability of activated sludge system dynamics." Teknisk Licentiat Thesis, KF Sigma, Lund, Sweden, **1993**
- [11] M.M. Hamed, M.G. Khalafallah and E.A. Hassanien: Prediction of wastewater treatment plant performance using artificial neural network. *Environmental Modelling and Software*, **2004**, 19(10), 919-928.
- [12] B. Ráduly, K. V. Gernaey, A. G. Capodaglio, P. S. Mikkelsen, M. Henze, Artificial neural networks for rapid WWTP performance evaluation: Methodology and case study. *Environmental Modelling & Software*, **2007**, v.22 n.8, p.1208-1216
- [13] K.P.Oliveira-Esquerre, M. Mori and R.E. Bruns: Simulation of an industrial wastewater treatment plant using artificial neural networks and principal component analysis. *Brazilian Journal of Chemical Engineering*, **2002**, 19(4), 365-370.
- [14] S. Haykin, "Neural Networks." Macmillan College Publishing Company, Inc, New York, **1994**
- [15] E. Loke: "Artificial neural networks in urban storm drainage". PhD thesis, Dept. of Environmental Science and Engineering, Technical University of Denmark, Lyngby, Denmark, **1999**
- [16] J.B. Copp (ed.). "The COST Simulation Benchmark — Description and Simulator Manual". ISBN 92-894-1658-0, Office for Official Publications of the European Communities, Luxembourg, **2002**.
- [17] K.V. Gernaey, C. Rosen and U. Jeppsson: WWTP dynamic disturbance modelling – an essential module for long-term benchmarking development. *Water Science & Technology*, **2006**, Vol 53, No 4-5 pp 225–234