

# Neurális hálózatok alkalmazása hazai vízminőségi vizsgálatok során

Csábrági Anita<sup>1</sup>, Molnár Sándor<sup>1</sup>, Tanos Péter<sup>1</sup>, Kovács József<sup>2</sup>, Szabó István<sup>1</sup>, Molnár Márk<sup>3</sup>

<sup>1</sup> Szent István Egyetem, Mechanika és Géptani Intézet, Gödöllő

<sup>2</sup> Eötvös Loránd Tudományegyetem, Általános és Alkalmazott Földtani Tanszék, Budapest

<sup>3</sup> Szent István Egyetem, Közgazdaságtudományi, Jogi és Módszertani Intézet, Gödöllő

## Bevezetés

Az utóbbi évszázadban a növekvő ipari és mezőgazdasági tevékenység, az urbanizáció hatása következtében természetes vizeink jelentős szennyeződéseknak, antropogén terheléseknek (emberi tevékenység által okozott hatások) vannak kitéve, melyeknek során vizeink fizikailag leírható ökológiai állapota (pl. átlátszóság (turbiditás), zavarosság, fényklíma, áramlási sebesség, hőmérséklet stb.) az eredetétől eltér, drasztikusan megváltozik. Ezek a mesterséges, külső hatások, folyamatok általában pontforrás eredetűek vagy diffúz szennyeződések. Első típusra az ipari tevékenységből származó nehézfém-szennyeződések (pl. tiszai cianid-szennyezés, [1]), a nagyobb városok kommunális szennyvízbevezetése, olajvezeték meghibásodása miatti talajvízszennyezés nyújtanak példát. Az utóbbi esetre példa a nitrogén és foszforvegyületek beáramlása a műtrágyák használata során, szabálytalan hulladéklerakókból talajvízbe mosódó mérgek, mint például mikroműanyagok (5 mm-

nél kisebb, a természetbe kerülő műanyagdarabok) beáramlása a vízbe [2]. Ez utóbbi szennyeződés nagy veszélyforrás, megelőzni szakszerű hulladékkezeléssel, a műanyagok minél nagyobb százalékanak újrahasznosításával lehetséges. Ezen kívül antropogén terhelésnek tekinthető még a természetes vizek „túlhasználata”, mely a vizek kiszáradásához vezethet, a vízerőművek, duzzasztók alkalmazása, mely jelentősen megváltoztatja a folyók vízhozamát [3], illetve az atomerőművek hőszennyezése.

Ezen antropogén hatások megfigyelése és ellenőrzése szempontjából nagyon fontos a monitoring rendszerek (ellenőrző-megfigyelő rendszer) megfelelő kiépítése. A monitoring rendszerek egyik fő célja a víz szennyezettségének ellenőrzése és ezáltal a víz minőségének megőrzése úgy, hogy mind térben, mind időben megfelelő mérési adatokat nyújtsanak, és mindezt a lehető legnagyobb költséghatékonysággal tegyék. Ezeknek a feladatoknak a támogatására született meg az Európai Unióban a Víz Keretirány-

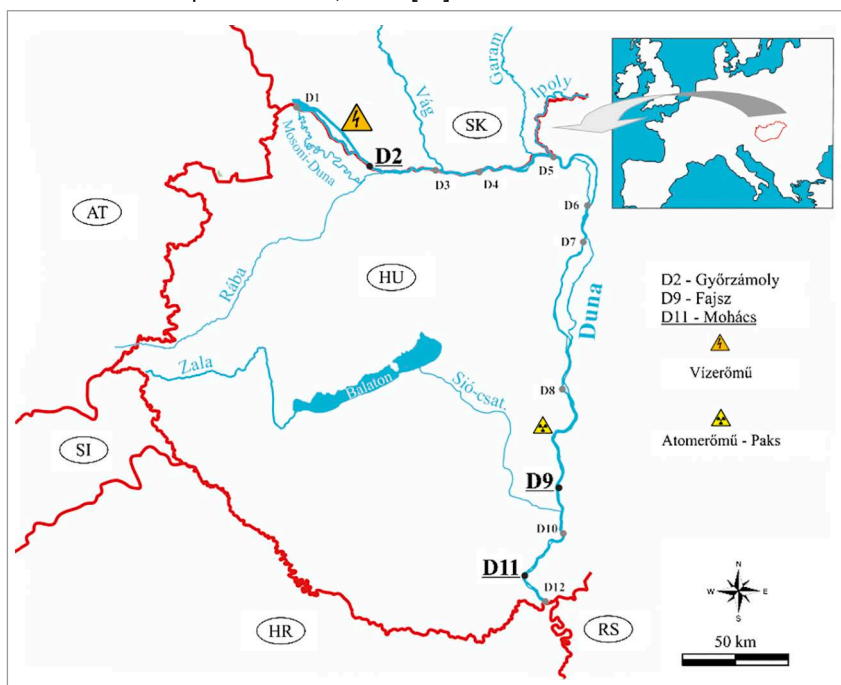
elv (VKI, 2000/60/EC), amely jelenleg is megszabja a vízminőség-védelem célkitűzéseit és előírásait Európában. A monitoring rendszerek létrehozásának és üzemeltetésének alapja a megfelelő mintázási stratégia kiválasztása, amely során I) meg kell határozni a mért paramétereket; II) a megfelelő mérési pontokat (térbeliség); III) a mintavétel gyakoriságát (időbeliség) a megfelelő reprezentativitás érdekében [4]. Ugyanakkor a rendszeres, jól működő, megfelelő mintavételi stratégiát alkalmazó mérési, monitoring-rendszer nem elég, szükség van az adathalmaz megfelelő szintű feldolgozására, adatelemzésre. Ha a folyamatosan mért vízminőségi adatokból előrejelzéseket, illetve a paraméterek között bizonyos összefüggéseket szeretnénk kinyerni, akkor becsléseket célszerű végezni, amely a vízminőséggel foglalkozó szakemberek számára hatékony segítség a döntéstámogató rendszerek működéséhez.

Az utóbbi évtizedekben ugrásszerűen megnőtt a mesterséges neurális hálózatok alkalmazása a vízminőségi változók becslésére mind a tavakban, mind a folyókban egyaránt a neurális hálózatok előnyei miatt, hiszen nagy mennyiségű mérési adat feldolgozására képes, jó általánosítóképességgel rendelkező nemlineáris modellek [5].

A legtöbb neurális hálózatokkal való alkalmazás a természetes vizek oldottoxigén-koncentrációját (DO) becslői, mivel ez az egyik legfontosabb vízminőségi paraméter az élővizekben, és ez az egyik meghatározó mutatója a felszíni vizek ökológiai egyensúlyának.

A rengeteg, neurális hálózatokkal vízminőségi paramétert becsülő kutatás közül néhányat sikeresen alkalmaztak abban az esetben is, amikor egy tó oldottoxigén-koncentrációját becsülték szennyezett [6], illetve erősen szennyezett, eutróf (sok tápanyagot tartalmazó) tavakban [7]. Az DO paraméteren kívül még másik három paramétert – klorofill-a, összes foszfor és Secchi-átlátszóság – is becsültek eutróf tavakban [8,9], mivel ezen paraméterek alapján számítják ki tavakban a Carlson-féle eutróf indexet. Van példa szennyezett folyók vizsgálatára

1. ábra Mintavételi pontok a Dunán, forrás: [13]



is: erősen szennyezett, hipoxiás (oxigénhiányos) kínai folyó (Wen-Riu Tang) nyolc mintavételi pontján mért adatok segítségével a folyó DO-szintjét becsülték [10] négyféle modellel. Szintén szennyezett folyót (Karon, Irán) vizsgáltak sikeresen háromféle modellel, 8 bemenő paraméterrel 17 év adata alapján háromféle kimenetet – kémiai oxigénigény, biológiai oxigénigény és DO – becsülve [11]. A törökországi, szennyezett Melen folyó biológiai oxigénigényét becsülték 11 állomás adataiból többbrétegű perceptront használva [12]. Nem találtunk viszont olyan vizsgálatot, amely vízerőmű, duzzasztó vagy atomerőmű közelében lévő mintavételi pont DO-szintjét vizsgálta volna neurális hálózatokkal.

Kutatásunk célja megvizsgálni, hogy az antropogén hatások, terhelések megnehezítik-e a dunai állomások oldtoxicigén-koncentrációját becslését. Ehhez a vizsgálatához a dunai mintavételi pontokon időbeli előrejelzést kívánunk megvalósítani, amely alapján meg tudjuk majd határozni, hogy zavar-talan, illetve antropogén hatásoknak, terheléseknek kitett mintavételi pontokon mekkora hatékonyságnövekedés lehet elérni a kétféle neurális hálózattal a többváltozós lineáris regresszióval (MLR) szemben.

## Anyag és módszer

### A vizsgált terület

A Duna Magyarország leghosszabb folyója, mely a németországi Fekete-erdőben ered, és 10 országot érintve gazdagon szerteágazó torkolattal ömlik a Fekete-tengerbe. Vízgyűjtőterülete 817.000 km<sup>2</sup>, a folyó magyarországi szakasza 417 km hosszú, ahol az átlagos vízhozam 2 000 m<sup>3</sup>/s. A Duna bizonyos szakaszai UNESCO védelem alatt állnak (Duna-delta bioszféra Rezervátum, 1991, Budapest, Duna partok, 1987), mind gazdasági értelemben, mind vízellátási szempontból, és mint szállítási útvonal miatt is fontos folyó, jelentős gazdasági tényező, amely vízminőségének megőrzése kulcskérdés.

A magyar-szlovák határnál épült a Bős-nagymarosi vízlépcsőrendszer, amely nagymértékben megváltoztatta a folyó ezen szakaszát. Ennek eredményeképpen a főmeder vízhozamának 80 százalékát elterelték a szlovák oldalra, és csak mintegy 400 m<sup>3</sup>/s vízhozamú szakasz hagyta meg a magyar területen. A folyó 1806 folyamkilométerénél (fkm) éri el a főmedret [3]. Még egy további említésre méltó létesítmény is befolyásolja a Duna vizét, ez pedig a MVM Paksi Atomerőmű (1 525-1 526 fkm), melynek hűtővíze a Dunába folyik, ezáltal pedig növeli a folyó hőmérsékletét, ami csökkentheti a folyó oxigénbeoldhatóságát. A folyó magyarországi sza-

1. táblázat Mohács, Fajsz és Győrzámoly adatainak alapstatisztikája a teljes vizsgált időintervallumra (1998-2003)

Állomás	Mintaszám	Paraméter	Max.	Min.	Átlag	Relatív szórás	r
D11	154	Q	5400	910	2363,19	0,41	-0,16
		T <sub>w</sub>	25,9	0,2	12,84	0,58	-0,29
		pH	8,75	7,8	8,24	0,03	0,33
		EC	530	272	377,62	0,16	0,25
		DO	17,7	6,8	11,04	0,16	1
D9	151	Q	5310	920	2346,74	0,40	-0,08
		T <sub>w</sub>	25,2	0,2	12,49	0,60	-0,34
		pH	8,85	7,75	8,26	0,03	0,25
		EC	525	256	371,30	0,15	0,27
		DO	15,5	7	11,20	0,14	1
D2	156	Q	5130	618	1940,58	0,40	0,16
		T <sub>w</sub>	22,8	0	11,59	0,56	-0,58
		pH	8,9	7,02	8,13	0,03	0,08
		EC	560	294	370,56	0,13	0,42
		DO	14,03	5,76	9,82	0,16	1

kaszán 12 mintavételi pont van (1. ábra). Ezek közül Mohácsot (D11, 1451,7 fkm) választottuk ki, mint „zavartalan” reprezentatív állomást, mivel ezt a mintavételi helyet nem befolyásolja egyetlen egy természetes (pl. mellékfolyó), illetve más, antropogén hatás (pl. vízerőmű) sem. A további két vizsgált mintavételi hely, Győrzámoly (D2, 1806,2 fkm) és Fajsz (D9, 1507,6 fkm), melyek azonban „zavart” mintavételi pontoknak vehetőek, hiszen D2 az első mintavételi pont azután, hogy a Bős-nagymarosi vízlépcsőrendszer alvizi csatornája újra kapcsolódik a Duna főmedrével, míg a D9-es mintavételi pont a Paksi Atomerőmű után az első mintavételi pont.

### Mintahalmaz

A dunai vizsgálatához négy bemenő paramétert választottunk az DO-szint becslésére: vízhozamot (Q, m<sup>3</sup>s<sup>-1</sup>), hőmérsékletet (T<sub>w</sub>, °C), pH értéket és az elektromos vezetőképességet (EC, μScm<sup>-1</sup>), melyek könnyen mérhető alapparaméterek. Az adatokat standardizáltuk a neurális háló használata előtt. Mindhárom állomás vizsgálatánál a tanítóhalmaz az 1998-2002 időintervallumba eső adatok voltak, a 2003. évi adatok alkotják a tesztalmez elemeit, tehát időbeli előrejelzést adtunk mindhárom esetben [14].

Mindhárom mintavételi pontnál a bemenő paraméterek és a kimenet mért adatainak leíró statisztikái (1. táblázat) rámutatnak arra, hogy a relatív szórás alapján a legváltozékonyabb paraméterek a vízhozam és a hőmérséklet, a legstabilabb paraméter viszont a pH. Az is látható, hogy Mohács és Fajsz mintavételi pontok adatai között kis különbség van, míg Győrzámoly állomás adatai nagyon eltérnek az előző állomások adataitól. Mindez nem meglepő, hiszen Győrzámoly és Mohács között több mint 298 fkm

van. A különbséget jól mutatja a vízhozam átlagértéke, mely Győrzámolynál majdnem 20%-kal, míg az átlaghőmérséklet közel tíz százalékkal kevesebb, mint Mohácsnál.

### Alkalmazott modellek, kiértékelésük

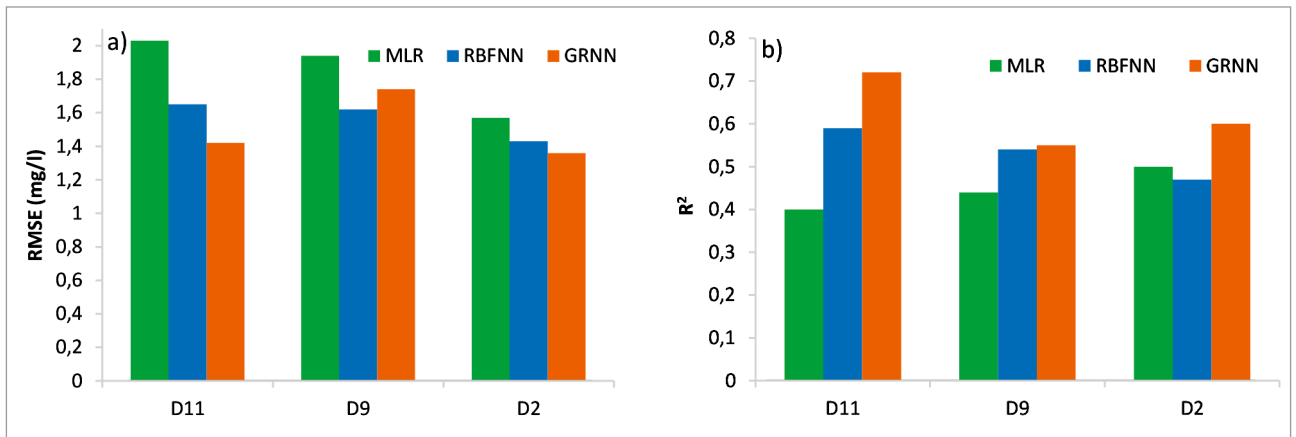
Referenciamodellünk, a többváltozós lineáris regresszió (MLR) alkalmazása lehetővé teszi, hogy lineáris kapcsolatot állítsunk föl a függő és a többi független változó között egy lineáris modellt fölépítve [15].

A modellbe bevont független változók számának növelésével valószínűleg a becslés jósága nem romlik, így azt hihetnénk, hogy a legjobb modellt minél több független változó bevonásával kapjuk meg. Ezzel szemben az optimális modell létrehozásához meg kell határozunk azon független változók minimális körét, melyek még érdemi hatással vannak a függő változóra, ezeket tekintjük szignifikáns változóknak. A szignifikáns változók listáját minden eredménynél megadjuk.

Becsléseinket a referenciamodellen kívül kétféle neurális hálózattal is elvégeztük, melyek MATLAB környezetében implementálódtak, mindkettő előrecsatolt architektúrájú, ellenőrzött tanítást megvalósító modellek.

A radiális bázisfüggvényes neurális hálózatoknak (RBFNN) három rétege van: egy bemeneti, egy rejtett és egy kimenő réteg [16]. A modellek tanításakor az első szakaszban a transzferfüggvényként alkalmazott Gauss-függvények paraméterei önszerveződő módon állítódhatnak be, majd a második szakaszban már ellenőrzött tanítást megvalósítva, iterációs eljárással lesznek meghatározva a rejtett rétegben lévő neuronok, illetve a rejtett és a kimeneti réteg közötti súlytényezők, torzítások [5].

Az általános regressziós neurális hálózatoknak (GRNN) négy rétege van: egy be-



2. ábra Mindhárom állomás esetén a tesztalmazra vonatkozó a) RMSE és b)  $R^2$  értékek

meneti réteg, egy mintaréteg, egy összegző réteg és egy kimeneti réteg [17]. A modell tréningezéséhez nincs szükség iterációs eljárásra, hiszen a mintarétegben a neuronok számát rögzítették, így a bemeneti adatok csak egyszerűen áramolnak végig a rendszeren, és ezután már meg is kapjuk a modell végeredményét [5].

Mindkét modell futtatásához egyetlen paramétert kell megadni a szigma-faktort ( $\sigma$ ), ezt a paramétert, illetve a radiális bázisfüggvényes neurális hálózatoknak a rejtett rétegben lévő neuronok számát minden eredménynél közöljük.

Mindhárom modell teljesítményének kiértékeléséhez két statisztikai mutatót alkalmaztunk, melyek az átlagos négyzetes hiba négyzetgyöke (RMSE) és a determinációs együttható ( $R^2$ ) [14].

## Eredmények

Mohács (D11) adataival való vizsgálat során (2. ábra) az első, mind a négy bemenő paramétert alkalmazó MLR modell alapján két bemenő paraméter a vízhozam és a vezetőképesség kizárható, mert ezek a paraméterek 5%-os szinten nem voltak szignifikánsak. Ezen paraméterek nélkül, a második MLR modell és a magyarázó paraméterek is már szignifikánsak voltak. Az RBFNN háló a legjobb becslést a tesztalmazra vonatkozóan 0,26-os szigma-faktornál érte el, ekkor a rejtett rétegben lévő neuronok száma 18 volt. A GRNN modell alkalmazásánál a 0,3-as szigma-faktor értéknél kaptuk a legjobb becslést a tesztelő halmazra vonatkozóan. Mindhárom modellt összehasonlítva a GRNN modell nyújtotta a legjobb becslést a tesztalmazra vonatkozó RMSE értékek alapján.

Fajsz (D9) mintavételi pontot önmagában vizsgálva is két MLR modell készült. Az első a négy bemenő paraméter közül a vízhozam és a vezetőképesség paramétereit zárta ki, mert ezek a modellben nem voltak szignifi-

kánsak. A második MLR modell e paraméterek nélkül készült, az így kapott modell minden paramétere szignifikáns volt. Az RBFNN modell teljesítménye 0,12 szigma-faktor mellett volt a legjobb, ebben az esetben a rejtett réteg neuron száma 49 volt. Végül a GRNN modell 0,3 szigma-faktor esetében volt a leghatékonyabb. A három különböző modell közül ebben az esetben a RBFNN modell szolgáltatta a legjobb eredményt (2. ábra).

Győrzámoly (D2) mintavételi pont adataival való becslés esetén szintén két MLR modell kellett alkalmazni. Az első MLR modell ebben az esetben a pH és az vezetőképesség paramétert zárta ki, így a második MLR modell e paraméterek nélkül készült. Az RBFNN modellt alkalmazva azt tapasztaltuk, hogy 0,28 szigma-faktor esetében adja a leghatékonyabb becslést, mely esetben a rejtett rétegben lévő neuronok száma 36 volt. A GRNN modell 0,5 szigma-faktornál volt a leghatékonyabb. A három modell közül a GRNN módszerrel készült modell bizonyult a leghatékonyabbnak (2. ábra).

A következőkben mindhárom állomás vizsgálata esetén a GRNN és az RBFNN modellel a tesztalmazra (2003-as év) kapott statisztikai mutatókat hasonlítjuk össze az MLR-hez viszonyítva (2. táblázat). A GRNN modell a tesztelő fázisban a becslést jellemző RMSE értékét a lineáris modellhez képest Mohács állomás vizsgálata esetén 30%-kal javította, míg Fajsz vizsgálata esetén csak 10%, Győrzámoly esetén pedig 13%-os az elért hatékonyságjavulás. Ha az RBFNN modellel kapott eredményeket nézzük, akkor az RMSE érték a tesztelő szakaszban 19%-kal javult az MLR-hez képest Mohács adataival való becsléskor, ugyanez az érték Fajsz esetén 16%, Győrzámoly esetén pedig csak 9%.

Ha a determinációs együtthatókat vesszük figyelembe, akkor szintén azt látjuk, hogy Mohács vizsgálata esetén a legjelentősebb, 80%-os hatékonyságjavulást értünk

el a GRNN-nel a lineáris modellhez képest, míg Fajsz esetén 26%, Győrzámoly esetén pedig 19%-kal javult a becslés. Az RBFNN modellel kapott  $R^2$  értékeket megvizsgálva látható, hogy Mohácsnál a legnagyobb, 48%-os javulást értünk el, míg Fajsz esetén ez csak 23%, Győrzámoly esetében viszont 6%-os visszaesés tapasztalható az MLR modellel kapott eredményekhez képest.

## Következtetések

Ha mind a három mintavételi ponttal történt vizsgálatoknak a neurális hálózatokkal a tesztalmazra vonatkozó RMSE és  $R^2$  mutatóknak MLR-hez viszonyított értékeit összevetjük (2. táblázat), akkor azt tapasztaljuk, hogy a neurális hálókkal a zavartalan mintavételi pontban (Mohács) értük el a legszámottevőbb javulást a lineáris modellhez képest. A többi állomás vizsgálata esetén is jelentősen hatékonyabbak a neurális hálók, de nincs olyan nagymértékű teljesítményjavulás, mint hogyha csak a zavartalan pontot vizsgálnánk. A zavart mintavételi pontok esetében a jelentkező antropogén hatás, zavarás megnehezíti a becslést. Győrzámoly vizsgálata esetében a közeli vízerőmű működtetése jelentősen manipulálja a vízhozamot [3,18], amely a teljes ökológiai rendszerre befolyást gyakorol [19], így a DO paraméterre is. Másrészt a Fajsz állomás vizsgálata esetében a közeli atomerőmű hűtővíze – lokálisan ugyan – de befolyásolja a Duna hőháztartását és így hatással lehet az oldottóxi-gén-koncentrációra is [20]. Mindezek megnehezítik a DO előrejelzését Győrzámoly és Fajsz mintavételi pontokon. Természetesen nemcsak antropogén hatások, hanem természetes hatások (pld. mellékfolyók beáramlása) is megváltoztathatják egy folyó ökológiai állapotát egy adott mintavételi pontban, amit szintén fontos figyelembe venni különböző modellek alkalmazásánál.

## Összefoglalás

Kétféle neurális hálózatot és a többváltozós lineáris regressziót, mint referenciamodell alkalmaztuk a Duna egyik legfontosabb vízminőségi jellemzőjének, az oldott oxigén koncentrációjának becslésére. A kutatás során három mintavételi pont – Mohács, Fajsz és Győrzámoly – 1998-2003 között mért adataival vizsgáltunk külön-külön, időbeli előrejelzést megvalósítva. A kapott eredményekből kitűnik, hogy mindkét neurális háló, különösen a GRNN és az RBFNN hatékony eszközök folyóvizek oldott oxigén-koncentrációjának becsléséhez. Azt is megállapítottuk, hogy a természetes és antropogén hatásoktól „zavartalan” mintavételi ponton, Mohácson sokkal nagyobb hatékonyságjavulás – 30% – érhető el a neurális hálózatokkal a lineáris modellel szemben, mint a másik két állomásnál, ahol antropogén hatások, terhelések nehezítik a becslést.

Kulcsszavak: antropogén hatások, General Regression Neural Network, oldott oxigén-koncentráció, Radial Basic Function Neural Network

## Summary

*In this paper two types of neural networks and as a reference a multivariate linear regression model is applied to estimate one of the most important parameters, the dissolved oxygen content of the river Danube. During the research data from three sampling locations – Mohács, Fajsz and Győrzámoly – was used for analysis separately for temporal forecasts. Results show that both neural networks (GRNN and RBFNN) are efficient tools for dissolved oxygen forecasts. It was learnt furthermore that in undisturbed sampling points free from natural and anthropogenic impacts (e.g. Mohács) the gain in efficiency was significantly larger (30%) with neural networks than with the linear model unlike in other stations where anthropogenic disturbances and loads made estimation more difficult.*

*Keywords: anthropogenic impacts, dissolved oxygen demand, General Regression Neural Network, Radial Basic Function Neural Network*

Lektorálta: Prof. Dr. Füst Antal

## Köszönetnyilvánítás

Kutatómunkánkat a FIEK\_16\_1\_2016\_0008 azonosítási számú projekt támogatta.

2. táblázat A teszthalmazra vonatkozó RMSE és R<sup>2</sup> értékek aránya az MLR modellhez képest

RMSE	MLR	RBFNN	GRNN	R <sup>2</sup>	MLR	RBFNN	GRNN
D11	100%	81%	70%	D11	100%	148%	180%
D9	100%	84%	90%	D9	100%	123%	126%
D2	100%	91%	87%	D2	100%	94%	119%

## Irodalomjegyzék

- [1] Soldán, P., Pavonič, M., Bouček, J., Kokeš, J. (2001): Baia Mare Accident – Brief Ecotoxicological Report of Czech Experts. *Ecotoxicology and Environmental Safety*, Vol. 49, pp. 255-261. DOI:10.1006/eesa.2001.2070
- [2] Lechner, A., Keckeis, H., Lumesberger-Loisl, F., Zens, B., Krusch, R., Tritthart, M., Glas, M., Schludermann, E. (2014): The Danube so colourful: A potpourri of plastic litter outnumbers fish larvae in Europe's second largest river. *Environmental Pollution*, Vol. 188, pp. 177-181.
- [3] Kovács, J., Márkus, L., Szalai, J., Kovács, I.SZ. (2015): Detection and evaluation of changes induced by the diversion of River Danube in the territorial appearance of latent effects governing shallow-groundwater fluctuations. *Journal of Hydrology*, Vol. 520, pp. 314-325.
- [4] Füst, A., Geiger, J. (2010): Monitoring-tervezés és -értékelés geostatistikai módszerekkel I. Szakértői véleményen alapuló, „igazol” mintázás geostatistikai támogatása. *Földtani Közönlöny*, 140(3), 303-312. o.
- [5] Haykin S. (1999): *Neural Networks: A Comprehensive Foundation*. 2nd ed. Prentice-Hall. Upper Saddle River, New Jersey
- [6] Akkoyunlu, A., Altun, H., Cigizoglu, H.K. (2011): Depth-integrated estimation of dissolved oxygen in a lake. *Journal of Environmental Engineering*, Vol. 137, pp. 961-967.
- [7] Ranković, V., Radulović, J., Radojević, I., Ostojčić, A., Čomić, L. (2010): Neural network modelling of dissolved oxygen in the Gruza reservoir, Serbia. *Ecological Modelling*, Vol. 221, pp. 1239-1244.
- [8] Chen, W.B., Liu, W.C. (2015): Water quality modeling in reservoirs using multivariate linear regression and two neural network models. Hindawi Publishing Corporation. DOI:10.1155/2015/521721
- [9] Kuo, J., Hsieh, M., Lung, W., She, N. (2007): Using artificial neural network for reservoir eutrophication prediction. *Ecological Modelling*, Vol. 200, pp. 171-177.
- [10] Ji, X., Shang, X., Dahlgren, R.A., Zhang, M. (2017): Prediction of dissolved oxygen concentration in hypoxic river systems using support vector machine: a case study of Wen-Rui Tang River, China. *Environmental Science and Pollution Research International*, Vol. 24(19), pp. 16062-16076.
- [11] Emamgholizadeh, S., Kashi, H., Marofpoor, I., Zalaghi, E. (2014): Prediction of water quality parameters of Karoon River (Iran) by artificial intelligence-based models. *Int. Journal of Environmental Science and Technology*, Vol. 11, pp. 645-656.
- [12] Dogan, E., Sengorur, B., Koklu, R. (2009): Modeling biochemical oxygen demand of the Melen River in Turkey using an artificial neural network technique. *Journal of Environmental Management*, Vol. 90, pp. 1229-1235.
- [13] Csábrági A., Molnár S., Tanos P., Kovács J., (2017): Application of artificial neural networks to the forecasting of dissolved oxygen content in the Hungarian section of the river Danube. *Ecological Engineering*, Vol. 100, pp. 63-72.
- [14] Csábrági A., Molnár S., Tanos P., Kovács J. (2019): Neurális hálózatok alkalmazása ökológiai rendszerek vizsgálatában. *Mezőgazdasági Technika*, LX. évf. 3. sz., 2-5. o.
- [15] Draper N.R., Smith H. (1981): *Applied regression analysis*. Wiley, New York
- [16] Poggio, T., Girosi, F. (1990): Regularization algorithms for learning that are equivalent to multilayer networks. *Science*, Vol. 247 (4945), pp. 978-982.
- [17] Specht, D. F. (1991) A general regression neural network, *IEEE Transactions on Neural Networks*, Vol. 2, pp. 568-576.
- [18] Klaver, G., van Os, B., Negrel, P., Petlet-Giraud, E. (2007): Influence of hydropower dams on the composition of the suspended and riverbank sediments in the Danube. *Environmental Pollution*, Vol. 148, pp. 718-728.
- [19] Onderka, M., Pekárová, P. (2008): Retrieval of suspended particulate matter concentrations in the Danube River from Landsat ETM data. *Science of the Total Environment*, Vol. 397(1-3), pp. 238-243.
- [20] Turnpenny, A.W.H., Coughlan, J., Ng, B., Crews, P., Bamber, R.N., Rowles, P. (2010): *Cooling Water Options for the New Generation of Nuclear Power Stations in the UK*. Env. Agency, Bristol.
- [21] [https://www.gov.uk/government/uploads/system/uploads/attachment\\_data/file/291077/scho0610bsot-e-e.pdf](https://www.gov.uk/government/uploads/system/uploads/attachment_data/file/291077/scho0610bsot-e-e.pdf) (megtekintve: 2016.12.03.).