



SZENT ISTVÁN  
EGYETEM

Folyóvizek oldottoxigén-koncentrációjának  
becslése neurális hálózatokkal

Doktori (PhD) értekezés tézisei  
Csábrági Anita

Gödöllő  
2019

**A doktori iskola  
megnevezése:**

Műszaki Tudományi Doktori Iskola

**tudományága:**

Agrárműszaki tudományok

**vezetője:**

Prof. Dr. Farkas István  
egyetemi tanár, DSc  
SZIE, Gépészmérnöki Kar

**Témavezető:**

Dr. Molnár Sándor  
egyetemi tanár, DSc  
SZIE, Gépészmérnöki Kar,  
Mechanikai és Géptani Intézet

**Társ-témavezető:**

Dr. habil. Kovács József  
egyetemi docens  
ELTE, Természettudományi Kar,  
Általános és Alkalmazott Földtani Tanszék

.....  
Iskolavezető jóváhagyása

.....  
Témavezetők jóváhagyása

## TARTALOMJEGYZÉK

JELÖLÉSJEGYZÉK .....	4
1. BEVEZETÉS, CÉLKITŰZÉSEK .....	5
<b>1.1. A téma időszerűsége és jelentősége .....</b>	<b>5</b>
<b>1.2. Célkitűzések .....</b>	<b>5</b>
2. ANYAG ÉS MÓDSZER .....	7
<b>2.1. Homogén csoportok meghatározása a Dunán és a Tiszán.....</b>	<b>7</b>
<b>2.2. A vizsgálatok logikai lépései .....</b>	<b>8</b>
3. EREDMÉNYEK.....	11
<b>3.1. Időbeli előrejelzés a Dunán.....</b>	<b>11</b>
3.1.1. A vizsgált kombinációk modelleredményei .....	11
3.1.2. Antropogén hatások befolyása a becslésekre .....	11
<b>3.2. Térbeli előrejelzés a Tiszán.....</b>	<b>12</b>
3.2.1. A vizsgált konfigurációk modelleredményei.....	12
3.2.2. A leghatékonyabb modell kiválasztása .....	15
3.2.3. A tanítóhalmaz leghatékonyabb adatstruktúrája a Tiszán .....	18
3.2.4. A folyó térbeli szakaszainak jellemzése.....	18
<b>3.3. Térbeli előrejelzés a Dunán .....</b>	<b>19</b>
3.3.1. A vizsgált konfigurációk modelleredményei.....	19
3.3.2. A tanítóhalmaz leghatékonyabb adatstruktúrája a Dunán .....	20
4. ÚJ TUDOMÁNYOS EREDMÉNYEK.....	22
5. KÖVETKEZTETÉSEK ÉS JAVASLATOK.....	24
6. ÖSSZEFOGLALÁS .....	25
7. AZ ÉRTEKEZÉS TÉMAKÖRÉHEZ KAPCSOLÓDÓ KIEMELT PUBLIKÁCIÓK .....	26

## JELÖLÉSJEGYZÉK

### Jelölések:

CCDA	Combined cluster and discriminant analysis, kombinált klaszter- és diszkriminancia-analízis	[-]
DO	Dissolved oxygen, oldott oxigén	[mg L <sup>-1</sup> ]
EC	elektromos vezetőképesség	[μScm <sup>-1</sup> ]
GRNN	Generalized regression neural network, általánosított regressziós neurális hálózat	[-]
MLPNN	Multilayer perceptron neural network, többrétegű perceptron neurális hálózat	[-]
MLR	Multivariate linear regression, többváltozós lineáris regresszió	[-]
MSE	Mean square error, átlagos négyzetes hiba	[-]
Q	vízhozam	[m <sup>3</sup> s <sup>-1</sup> ]
R <sup>2</sup>	Determinációs együttható	[-]
RBFNN	Radial basis function neural network, Radiális bázis függvényes neurális hálózat	[-]
RMSE	Root mean square error, az átlagos négyzetes hiba gyöke	[-]
T <sub>w</sub>	víz hőmérséklete	[°C]

## 1. BEVEZETÉS, CÉLKITŰZÉSEK

Ebben a fejezetben a téma jelentőségét fogalmazom meg, illetve a munkám célkitűzéseit mutatom be.

### 1.1. A téma időszerűsége és jelentősége

Az utóbbi évszázadban a növekvő ipari és mezőgazdasági tevékenység, az urbanizáció következtében természetes vizeink jelentős szennyeződéseknek, antropogén terheléseknek vannak kitéve, melyeknek során vizeink fizikailag leírható ökológiai állapota (pld. turbiditás, fényklíma, áramlási sebesség, hőmérséklet stb.) drasztikusan megváltozik. Ezen antropogén hatások megfigyelése és ellenőrzése szempontjából nagyon fontos és elengedhetetlen az adott rendszer vízminőségi változóinak ismerete, melyet a monitoring hálózatok adatai biztosítanak. A monitoring hálózat optimális működése több szempontból (pld. költséghatékonyság) vizsgálható, vagy adott esetben javítható, ha bizonyos, nehezen vagy költségesen mérhető paramétereket, más egyéb könnyen mérhető paraméterekkel becsüljük, melynek egy adekvát eszköze a mesterséges intelligencia, vagy a mesterséges neurális hálózatok nyújtotta módszerek.

Az elmúlt évtizedekben ugrásszerűen megnőtt a mesterséges neurális hálózatok alkalmazása a vízminőségi változók becslésére mind a tavakban, mind a folyókban egyaránt a neurális hálózatok előnyei miatt. A neurális hálózat alkalmazásakor csak a bemenő adatokra van szükség mindenféle előfeltétel nélkül, illetve ezek a modellek képesek a bemenő és a kimenő adatok közötti komplex kapcsolatot feltérképezni, majd a tapasztalatokat felhasználva megfelelő módon általánosítani.

A legtöbb neurális hálózatokkal való alkalmazás a természetes vizek oxigén-háztartására jellemző kémiai paramétereket vizsgálják, és ezen belül is leggyakrabban az oldottoxigén-koncentrációját (DO) becsüli, mivel ez az egyik legfontosabb vízminőségi paraméter az élővizekben, és ez az egyik meghatározó mutatója a felszíni vizek ökológiai egyensúlyának.

A DO-szintet becsülő neurális hálózatok alkalmazásának egyre nagyobb elterjedése ösztönözte azon törekvésemet, hogy hazai környezetre, Magyarország két legnagyobb folyójára is adaptáljam ezen modelleket úgy, hogy a kapott eredmények, összefüggések más folyók esetében is felhasználhatóak legyenek.

### 1.2. Célkitűzések

Értékezésem célja, hogy a becslési eljárásokat megvalósító neurális modelleknek minél hatékonyabb alkalmazásának lehetőségeit mutassam be úgy, hogy példákat adjak arra, melyik modellt milyen módszerrel, milyen

beállítással érdemes alkalmazni folyóvizek oldottoxigén-koncentrációját becsülve. Ennek bemutatására Magyarország két legnagyobb és legfontosabb folyóját választottam ki mintaterületnek, hiszen legjobb tudomásom szerint ezen folyók magyarországi szakaszának oldottoxigén-koncentrációjának becslésével még nem foglalkoztak. A kutatás során háromféle mesterséges neurális hálózatot és a többváltozós lineáris regressziót alkalmaztam.

Célom kideríteni mindkét folyó vizsgálatánál, hogy melyik modell adja a leghatékonyabb becsléseket az oldottoxigén-koncentrációra vonatkozóan.

Az oldottoxigén-koncentrációra vonatkozó időbeli előrejelzésnél célom

- megvizsgálni az antropogén hatásoktól mentes, zavartalan és zavart mintavételi pontoknál a lineáris modellhez képest hány százalékos javulást tudok elérni a neurális hálózatokkal, illetve függ-e a becslés attól, hogy a folyó egy-egy állomását milyen hatások érik.

Az oldottoxigén-koncentrációra vonatkozó térbeli előrejelzés és optimalizáció esetén célom

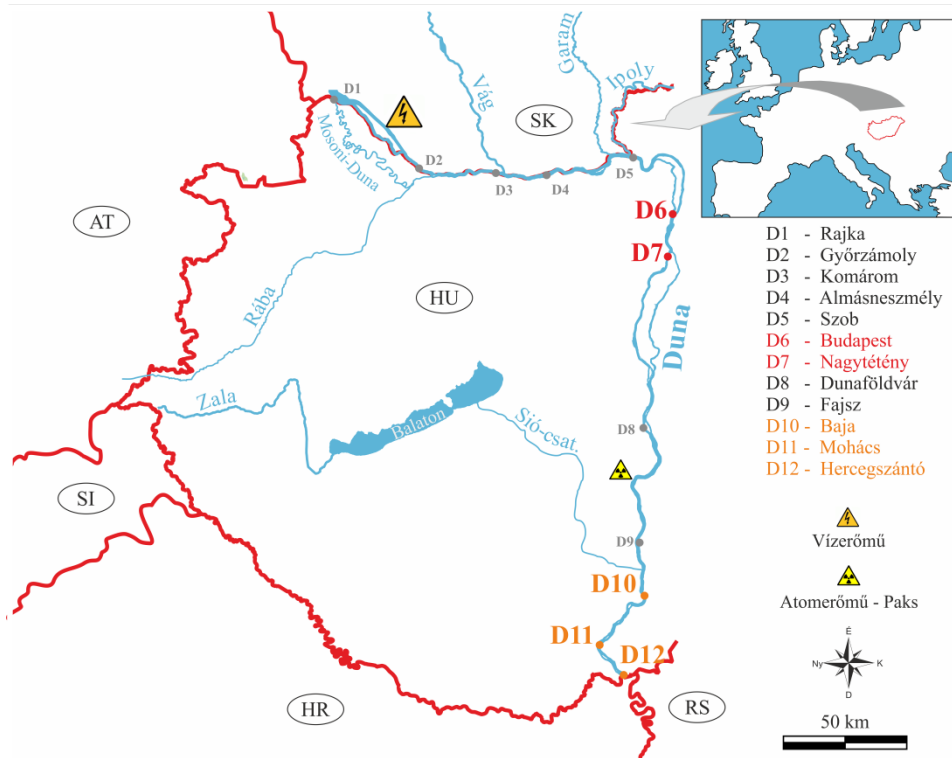
- a Tisza folyó összes magyarországi mintavételi pontjainak adatait feldolgozva a folyó egyes térbeli szakaszait külön-külön jellemezni aszerint, hogy mennyire hatékony becslést tudok adni az adott folyószakasz oldottoxigén-koncentrációjára a különböző modellekkel.
- mindkét folyó homogén csoportosításának eredményeit fölhasználva megvizsgálni, melyik adatstruktúra lesz a leghatékonyabb a becslés szempontjából.

## 2. ANYAG ÉS MÓDSZER

Ebben a fejezetben bemutatom a vizsgálandó folyórendszerek homogén csoportjait meghatározó eredményeket és a kutatási céljaim megvalósításához alkalmazott modelleket és azok konfigurációjait, illetve a vizsgálatok logikai lépéseit.

### 2.1. Homogén csoportok meghatározása a Dunán és a Tiszán

Társ-témavezetőm és kutatócsapata által elvégzett kombinált klaszter- és diszkriminancia-analízis (CCDA) vizsgálat szerint a Dunán lévő 12 mintavételi pont 9 homogén csoportba bontható, melyek közül 7 darab egytagú csoport (D1, D2, D3, D4, D5, D8, D9), egy darab kéttagú (D6 és D7) és egy darab háromtagú (D10, D11 és D12) (1. ábra).

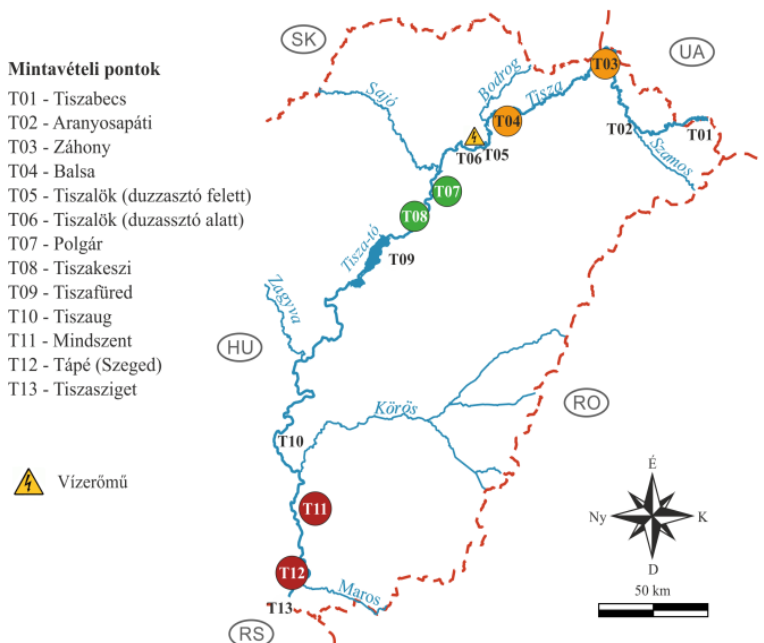


1. ábra CCDA által meghatározott homogén csoportok a Dunán

A Tisza homogén csoportokba való rendezés eredményét, melyet társ-témavezetőm és kutatócsapata CCDA módszerrel határozott meg, fölhasználtam vizsgálataim során. Eszerint a Tisza vizsgált 13 mintavételi pontja 10 homogén csoportba sorolható. Ezek között három olyan csoport volt megfigyelhető, amelyek két-két mintavételi pontot tartalmaztak (2. ábra), a többi csoport egyelemű. Vagyis a folyó felső szakaszán a T03-T04

## 2. Anyag és módszer

alkot homogén csoportot, a középső szakaszon a T07-T08, az alsó szakaszon pedig a T11-T12 állomások tartoznak homogén csoportba. Az azonos színnel jelölt állomások jelölik a homogén csoportba való tartozást.



2. ábra CCDA által meghatározott homogén csoportok a Tiszán

### 2.2. A vizsgálatok logikai lépései

Minden vizsgálatánál az adott folyó oldottoxigén-koncentrációját becsültem négy paraméter: a vízhozam ( $Q$ ,  $m^3s^{-1}$ ), a hőmérséklet ( $T_w$ ,  $^{\circ}C$ ), pH és az elektromos vezetőképesség ( $EC$ ,  $\mu S cm^{-1}$ ) segítségével, az alkalmazott időintervallum a 1998-2003 év közötti időszak volt.

Vizsgálataim három fő lépésre bonthatóak:

1. A dunai adatokra megvalósított oldottoxigén-koncentrációra vonatkozó időbeli előrejelzés
  - a) A célkitűzésemnek megfelelően azt vizsgáltam, hogy mennyire függ a becslés attól, hogy a mintavételi pontot érik-e antropogén hatások vagy nem. A lehetőség adott volt, hiszen a Duna magyarországi szakaszán két erőmű is található (1. ábra). Ennek a kérdéskörnek a vizsgálatához négy kombinációt hoztam létre, először Mohács ( $C_A$ ), Fajsz ( $C_B$ ) és Győrzámoly ( $C_C$ ) állomások adataira külön-külön, majd ezen három állomások mindegyikére ( $C_D$ ) becsültem a DO-koncentrációt. Négy modellt alkalmaztam: a többváltozós lineáris regressziót (MLR), a többretegű perceptront (MLPNN), a radiális bázisfüggvényes neurális hálózatot (RBFNN) és az általános regressziós neurális hálózatot



(GRNN), minden kombinációban a teszhalmaz elemei a 2003-as év adatai voltak.

2. A tiszai adatokra megvalósított DO-koncentrációra vonatkozó térbeli előrejelzés
  - a) A tiszai vizsgálatokat három konfigurációban végeztem el, ahol az első konfiguráció (TC1) tulajdonképpen egy referenciamodell volt, amihez a többi konfiguráció eredményét hasonlítottam. A TC1 konfigurációban a Tisza folyó teljes adathalmazát véletlenszerűen választottam szét tanító és teszhalmazra, vagyis ebben az esetben a folyó teljes magyarországi szakaszára modelleztem a DO-koncentrációját.
  - b) A Tisza folyó magyarországi szakaszának nagyon heterogén volta miatt (jelentősen eltérőek a bemenő paraméterek ill. az oldott oxigén is) érdemes volt megvizsgálni a folyó egyes szakaszait, és ezekre jellemzéseket adni, ezért született meg a második konfiguráció (TC2). A TC2 konfigurációban a 13 mintavételi pontból 4 szomszédos állomás adatai kerültek a teszhalmazba, a maradék 9 mintavételi pont adatai alkották a tanítóhalmazt. Ebben az esetben térbeli előrejelzést valósítottam meg a folyó egy-egy szakaszának DO-koncentrációjára vonatkozóan. A konfiguráción belül négy beállítást hoztam létre (TC2-A, TC2-B, TC2-C és TC2-D); először a folyó felső négy mintavételi pontjára teszteltem (T01, T02, T03 és T04, ezt TC2-A-val jelöltem), majd az utolsó állomás adatait megtartva a következő három állomást hozzávéve a teszhalmazhoz kaptam a következő esetet (T04, T05, T06 és T07, ezt TC2-B-vel jelöltem). Ezután megint az utolsó mintavételi ponthoz hozzávettem a következő három mintavételi pontot, és megkaptam a harmadik esetet (T07, T08, T09 és T10, ezt TC2-C-nek neveztem el), és a negyedik esetben végül az utolsó négy mintavételi pont adatai alkották a teszhalmazt (T10, T11, T12 és T13, ez pedig legyen TC2-D).
  - c) A térbeli jellemzés mellett a becslés hatékonyságán is szerettem volna javítani a tanítóhalmaz adatstruktúrájának vizsgálatával a Tiszára kapott CCDA módszer eredményei alapján. Ez alapján jött létre a harmadik konfiguráció (TC3), melynek három beállítása volt (TC3-A, TC3-B és TC3-C), hiszen a folyón kételemű homogén csoportból három darab van (2. ábra). Minden egyes beállítás esetén vettem a két-két homogén mintavételi pontot, és a folyásirányban utánuk következő inhomogén állomást. Vagyis a folyó felső szakaszából három mintavételi pontot (T03, T04, T05, ez az „A” beállítás), a folyó középső szakaszából szintén három állomást (T07, T08, T09, ezt „B” beállításnak jelöltem), végül a folyó utolsó három magyarországi állomását (T11, T12 és T13, ez lesz a „C” beállítás) vizsgáltam. A kapott három állomásból kettő

## 2. Anyag és módszer

---

került a tanítóhalmazba, egy pedig a teszhalmazba. Ez minden beállításnál három-három esetet jelentett (TC3-A#1, TC3-A#2, stb.), így összesen kilenc esetet kellett megvizsgálnom. Ennél a konfigurációnál a térbeli előrejelzés mellett térbeli optimalizáció is megvalósult.

- d) Mindhárom tiszai konfigurációban három modellt alkalmaztam (MLR, RBFNN és GRNN), és igyekeztem megtartani a tanító- és teszhalmazra vonatkozó 2:1 arányt minden egyes konfigurációban.
3. A dunai adatokra megvalósított DO-koncentrációra vonatkozó térbeli előrejelzés
- a) Ebben az esetben szintén egy referenciamodellt ( $D_R$ ) hoztam létre, amelyben a folyó teljes adathalmazát véletlenszerűen osztottam szét 2:1 arányban tanító és teszhalmazra, tehát a folyó teljes magyarországi szakaszára modelleztem a DO-koncentrációját.
  - b) A referenciamodell mellé egy olyan konfigurációt is készítettem, ahol három állomás adatait vizsgáltam – D6, D7 és D8 (Budapest, Nagytétény és Dunaföldvár) - melynél két állomás homogén, a harmadik pedig velük szomszédos inhomogén állomás volt (1. ábra). Minden esetben a három állomásból kettő került a tanítóhalmazba, egy pedig a teszhalmazba. Először a D6 és a D8 állomások adatai ( $D_A$  eset), majd a D7 és a D8 állomások adatai ( $D_B$  eset) alkották a tanítóhalmazt, végül pedig a D6 és D7 mintavételi pontok adatai ( $D_C$  eset) voltak a tanítóhalmaz elemei. A cél itt is a tanítóhalmaz leghatékonyabb adatstruktúrájának meghatározása volt.
  - c) Mindkét konfigurációban három modellt alkalmaztam: MLR, RBFNN és GRNN modelleket.

### 3. EREDMÉNYEK

Ebben a fejezetben a célkitűzéseknek megfelelően a Duna és a Tisza folyó DO-koncentrációjára vonatkozó, lineáris és a neurális hálózatokkal kapott becsléseknek és azok kiértékeléseinek, összehasonlításainak bemutatására kerül sor.

#### 3.1. Időbeli előrejelzés a Dunán

##### 3.1.1. A vizsgált kombinációk modelleredményei

Mind a négy vizsgált kombinációnak (2.2 pont) a tesztalmazra vonatkozó modelleredményeiből kitűnik (1. táblázat), hogy a  $C_A$  kombinációban a tesztelő halmazon a GRNN modell teljesített a legjobban. Az egyes kombinációkra létrehozott modellek különbségei rámutattak, hogy a  $C_B$  és a  $C_D$  esetében az RBFNN modell szolgáltatta a legkisebb RMSE értéket (1. táblázat) a tesztalmazra vonatkoztatva. A  $C_C$  esetében pedig a GRNN modell adta a legjobb eredményt a tesztalmazra vonatkozó RMSE tekintetében. Mindegyik konfigurációnál elmondható, hogy a neurális hálózatokkal sokkal hatékonyabban lehet becsülni a DO paramétert, mint a lineáris modellel. A három neurális háló közül a két leghatékonyabb modell a GRNN és az RBFNN, melyek jobb eredményt szolgáltatnak, mint az MLPNN, amely szinte minden esetben alulmaradt a másik két modellel szemben. Egy másik előny még a GRNN és az RBFNN modellel kapcsolatban, hogy sokkal gyorsabb a futási idejük, szemben az MLPNN modell duplán iterált tanítási metódusával.

1. táblázat Modellteljesítmények a tesztalmazra vonatkozóan a vizsgált kombinációk esetén

Kombináció	Modell	MLR	MLPNN	RBFNN	GRNN
$C_A$	RMSE [ $\text{mg L}^{-1}$ ]	2,03	1,57	1,65	1,42
	$R^2$	0,4	0,57	0,59	0,72
$C_B$	RMSE [ $\text{mg L}^{-1}$ ]	1,94	1,72	1,62	1,74
	$R^2$	0,44	0,58	0,54	0,55
$C_C$	RMSE [ $\text{mg L}^{-1}$ ]	1,57	1,46	1,43	1,36
	$R^2$	0,5	0,59	0,47	0,6
$C_D$	RMSE [ $\text{mg L}^{-1}$ ]	1,98	1,7	1,63	1,7
	$R^2$	0,41	0,59	0,59	0,55

##### 3.1.2. Antropogén hatások befolyása a becslésekre

Ha mind a négy konfigurációnak a neurális hálózatokkal a tesztalmazra vonatkozó RMSE és  $R^2$  mutatóknak MLR-hez viszonyított értékeit összevetem (2. táblázat), akkor azt tapasztalom, hogy a neurális hálózatokkal az  $C_A$  konfigurációban, a zavartalan mintavételi pontban (Mohács) értem el a legszámottevőbb javulást – 30%-ot - a lineáris modellhez képest. A többi

### 3. Eredmények

konfigurációban is jelentősen hatékonyabbak a neurális hálózatok, de nincs olyan nagymértékű teljesítményjavulás, mint ahogyha csak a zavartalan pontot vizsgálnám. A zavart mintavételi pontok esetében a jelentkező antropogén hatás, zavarás megnehezíti a becslést. A D2 mintavételi pont esetében a közeli vízerőmű működtetése jelentősen manipulálja a vízhozamot, a D9 mintavételi pont esetében pedig a közeli atomerőmű hűtővíze befolyásolja a Duna hőháztartását és így hatással lehetnek a DO paraméterre. Mindezek megnehezítik a DO előrejelzését a D2 és D9 mintavételi pontokon. Ugyanakkor a  $C_D$  esetben egy összetett rendszert modelleztem, melyben egyszerre megtalálhatóak zavart és zavartalan mintavételi pontok, így érthető, hogy ebben rendszerben nehezebbé vált a DO előrejelzése, mint  $C_A$  esetében.  $C_D$  esetében az RMSE javulás, az MLR eredményéhez képest csak 14% ellentétben a  $C_A$  esetében tapasztalt 30%-kal (2. táblázat).

2. táblázat A vizsgált kombinációk RMSE és  $R^2$  értékeinek aránya az MLR modellhez viszonyítva

RMSE	MLR	MLPNN	RBFNN	GRNN	$R^2$	MLR	MLPNN	RBFNN	GRNN
$C_A$	100%	77%	81%	70%	$C_A$	100%	143%	148%	180%
$C_B$	100%	89%	84%	90%	$C_B$	100%	133%	123%	126%
$C_C$	100%	93%	91%	87%	$C_C$	100%	117%	94%	119%
$C_D$	100%	86%	82%	86%	$C_D$	100%	135%	143%	143%

A vizsgálatok eredményei azt mutatták, hogy mindhárom neurális háló, különösen a GRNN és az RBFNN hatékony eszközök folyóvizek oldotttoxigén-koncentrációjának becsléséhez még abban az esetben is, ha a folyót antropogén hatások érik, bár ebben az esetben a becslés hatékonysága csekélyebb mértékben javítható.

### 3.2. Térbeli előrejelzés a Tiszán

#### 3.2.1. A vizsgált konfigurációk modelledményei

A TC1 konfigurációban a Tisza folyó vizsgálatokor a teljes adathalmazból véletlenszerűen választottam ki a tanító és teszhalmazokat 2:1 arányban. A háromféle véletlenszerű kiválasztás - 800, 2000 és 1000 kezdőértékkel inicializálva - során létrejött TC1-A, TC1-B és TC1-C beállítások teszhalmazra vonatkozó eredményeit összehasonlítva (3. táblázat) látható, hogy a legjobb eredmény a TC1-B kombináció esetén GRNN modellel született. Így a TC1-B kombináció lesz a referenciamodell, és a kapott RMSE érték  $2,14 \text{ mg L}^{-1}$  lesz az a referenciaérték (3. táblázat), amihez a többi konfigurációban kapott eredményeket hasonlítom.

### 3. Eredmények

3. táblázat A TC1 konfiguráció eredményei a teszhalmazra vonatkozóan

Beállítások	Modell	MLR	GRNN	RBFNN
TC1-A	RMSE [mg L <sup>-1</sup> ]	2,40	2,33	2,38
	R <sup>2</sup>	0,35	0,39	0,39
TC1-B	RMSE [mg L <sup>-1</sup> ]	2,25	2,14	2,23
	R <sup>2</sup>	0,41	0,46	0,41
TC1-C	RMSE [mg L <sup>-1</sup> ]	2,35	2,31	2,26
	R <sup>2</sup>	0,40	0,42	0,44

A TC1 konfigurációban a teljes magyarországi folyószakaszra egyetlen becslést kaptam a létrehozott modellel, mely azt feltételezi, hogy a vizsgált teljes Tisza szakasz egységes tulajdonságokkal rendelkezik, így egyetlen modell leírhatja a folyó DO-koncentrációját. Azonban ez a feltevés nagy folyók hosszú szakaszaira nem teljesül. A fentiek szükségessé tették, hogy a vizsgált folyót térben irányítottan osszam szét tanító és teszhalmazra, ez indokolta a második illetve majd a harmadik konfiguráció bevezetését.

A TC2 konfigurációban szintén a teljes adathalmazt használtam föl a vizsgálathoz úgy, hogy mindig 9 ponttal tanítottam és négy szomszédos mintavételi ponttal teszteltem annak érdekében, hogy a folyó különböző szakaszaira is külön-külön modellt tudjak alkotni, négy beállítást alkalmaztam (2.2 pont).

A TC2-A beállításnál kaptam a legrosszabb teljesítményt mindhárom modellel (4. táblázat). A legjobb eredményt - 1,64 mg L<sup>-1</sup> RMSE - a GRNN modell szolgáltatja a TC2-C beállítás esetén. A TC2-A és a TC2-B esetben is a GRNN modell adta a legjobb eredményt RMSE tekintetében, a TC2-D beállítás esetében viszont a RBFNN modellel értem el a legjobb teljesítményt.

A TC2 konfiguráció beállításai pontosabb becslést adtak bizonyos szakaszokra, mint a referenciamodell. A folyó felső szakaszán rosszabb teljesítményű modellek készültek - TC2-A, TC2-B beállítások - a referenciamodellhez képest. A folyó alsóbb szakaszaira való előrejelzés esetében viszont TC2-C és TC2-D beállítások hatékonysága már felülmulta az referenciamodell eredményeit (összefoglaló ábra, 3. ábra). TC2-A esetén a teszhalmaz kimeneti tartományának terjedelme 1,9-28,5 mg L<sup>-1</sup>, a tanítóhalmaz kimeneti tartományának terjedelme viszont 3,6-14,2 mg L<sup>-1</sup>. Mivel a neurális hálózatok a tanítóhalmaz terjedelmén kívüli értékekre nem képesek megfelelő becslést adni, ezért a TC2-A beállítás esetében elért kedvezőtlen eredmény nem meglepő.

### 3. Eredmények

4. táblázat A TC2 konfiguráció eredményei a teszhalmazra vonatkozóan

Beállítás	Modell	MLR	GRNN	RBFNN
TC2-A	RMSE [mg L <sup>-1</sup> ]	4,75	4,73	4,74
	R <sup>2</sup>	0,07	0,06	0,08
TC2-B	RMSE [mg L <sup>-1</sup> ]	2,66	2,56	2,59
	R <sup>2</sup>	0,20	0,25	0,26
TC2-C	RMSE [mg L <sup>-1</sup> ]	1,65	1,64	1,75
	R <sup>2</sup>	0,67	0,66	0,50
TC2-D	RMSE [mg L <sup>-1</sup> ]	1,71	1,81	1,69
	R <sup>2</sup>	0,70	0,61	0,60

A TC2 konfiguráció szükségszerű volt a folyó térbeli jellemzéséhez, azonban ennek megvalósítása nem volt megfelelően hatékony a felsőbb szakaszok esetén. A becslés hatékonyságának növelése érdekében térbeli optimalizációt hajtottam végre, hiszen rendelkezésre álltak 2.1 pontban leírt eredmények, amelyet a TC3 konfigurációban használtam föl a 2.2 pont szerint.

A TC3 konfigurációban nem használtam föl a folyó teljes adathalmazát, hanem mindig csak három állomás adataival dolgoztam úgy, hogy két állomás egy homogén csoport elemei voltak, a harmadik állomás pedig a folyásirányban következő állomás volt. Ebből két mintavételi pont adatai szolgáltatták a tanítóhalmaz elemeit, a harmadik állomás adatai pedig a teszhalmaz elemei voltak.

Három esetet vizsgáltam (2.2 pont): a folyó felső szakaszából három mintavételi pontot (T03, T04, T05, ez az „A” beállítás, 5. táblázat), ekkor a T03 és a T04 állomások alkották a homogén csoportot, a T05 állomás pedig ettől a csoporttól eltérő tulajdonságú.

5. táblázat A TC3 konfiguráció „A” beállításának eredményei a teszhalmazra vonatkozóan

Albeállítás	Tanítóállomás + tesztállomás	Modell	MLR	GRNN	RBFNN
TC3-A#1	T3, T4 + T5	RMSE [mg L <sup>-1</sup> ]	3,93	3,70	3,58
		R <sup>2</sup>	0,65	0,42	0,34
TC3-A#2	T3, T5 + T4	RMSE [mg L <sup>-1</sup> ]	3,49	3,12	3,05
		R <sup>2</sup>	0,06	0,22	0,24
TC3-A#3	T4, T5 + T3	RMSE [mg L <sup>-1</sup> ]	3,35	2,93	2,97
		R <sup>2</sup>	0,06	0,24	0,22

A folyó középső szakaszából egy beállítással foglalkoztam (T07, T08, T09, ezt „B” beállításnak jelöltem, 6. táblázat), ebben az esetben a T07 és T08 állomások voltak homogének, és a T09 mintavételi pont volt más struktúrájú.

### 3. Eredmények

6. táblázat A TC3 konfiguráció „B” beállításának eredményei a tesztalmazra vonatkozóan

Albeállítás	Tanítóállomás + tesztállomás	Modell	MLR	GRNN	RBFNN
TC3-B#1	T7, T8 + T9	RMSE [mg L <sup>-1</sup> ]	1,25	1,17	1,23
		R <sup>2</sup>	0,76	0,78	0,74
TC3-B#2	T7, T9 + T8	RMSE [mg L <sup>-1</sup> ]	1,01	0,84	0,90
		R <sup>2</sup>	0,78	0,84	0,83
TC3-B#3	T8, T9 + T7	RMSE [mg L <sup>-1</sup> ]	1,00	0,84	0,89
		R <sup>2</sup>	0,77	0,84	0,82

Végül a folyó utolsó három magyarországi állomását (T11, T12 és T13, ez lesz a „C” beállítás, 7. táblázat) vizsgáltam, ahol a T13 mintavételi pont volt más struktúrájú a T11 és T12 állomások által alkotott homogén csoporttal szemben.

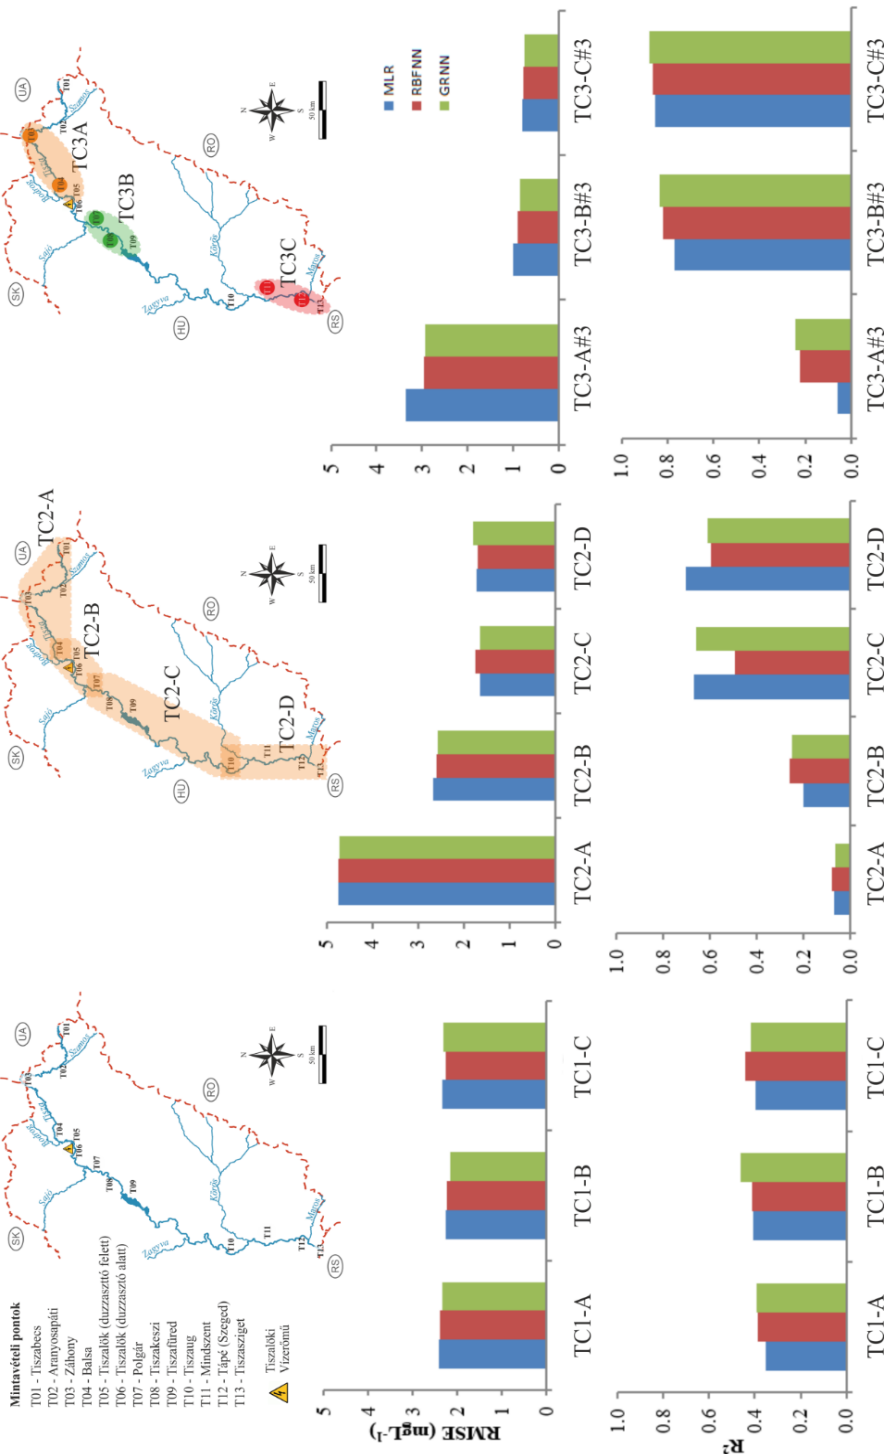
7. táblázat A TC3 konfiguráció „C” beállításának eredményei a tesztalmazra vonatkozóan

Albeállítás	Tanítóállomás + tesztállomás	Modell	MLR	GRNN	RBFNN
TC3-C#1	T11, T12 + T13	RMSE [mg L <sup>-1</sup> ]	0,87	0,77	0,86
		R <sup>2</sup>	0,83	0,86	0,82
TC3-C#2	T11, T13 + T12	RMSE [mg L <sup>-1</sup> ]	0,95	0,75	0,76
		R <sup>2</sup>	0,81	0,89	0,88
TC3-C#3	T12, T13 + T11	RMSE [mg L <sup>-1</sup> ]	0,80	0,74	0,77
		R <sup>2</sup>	0,85	0,88	0,86

#### 3.2.2. A leghatékonyabb modell kiválasztása

Mindhárom vizsgált konfiguráció beépített térképeit és eredményeit egy összefoglaló ábrán mutatom be (3. ábra), amely a tesztalmazra vonatkozó RMSE és R<sup>2</sup> értékét jeleníti meg. A TC3 konfiguráció esetén mivel mind a három beállításon belül a harmadik albeállításnál - TC3-A#3, TC3-B#3 és TC3-C#3 - értem el a legjobb eredményt (5. táblázat), ezért ezen albeállítások elért eredményei kerültek az összefoglaló ábrára (3. ábra). A TC3-A#3, a TC3-B#3 és a TC3-C#3 albeállításnál a GRNN modell szolgáltatta a leghatékonyabb becslést mindkét statisztikai mutató vonatkozásában.

### 3. Eredmények



3. ábra Tiszai konfigurációk beépített térképei és eredményei

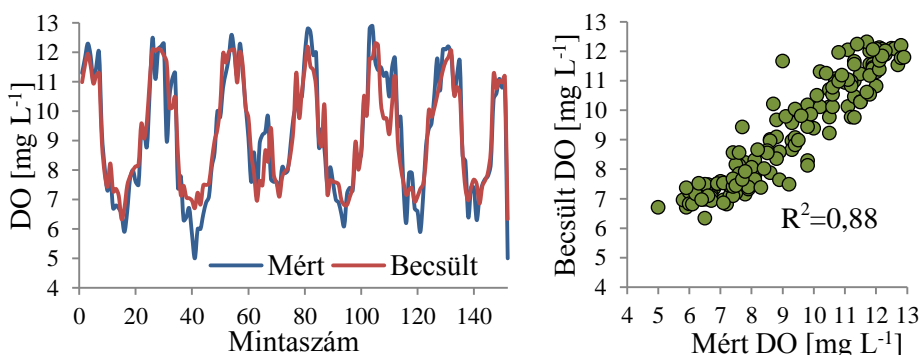
a) TC1 konfiguráció      b) TC2 konfiguráció      c) TC3 konfiguráció



### 3. Eredmények

A TC3 konfigurációban három különböző beállítást vizsgáltam (TC3-A, TC3-B és TC3-C), melyeken belül 3-3 albeállítás volt elkülöníthető. A TC3-A beállítással kapott RMSE értékek kisebbek voltak, mint  $4 \text{ mg L}^{-1}$ , amely kedvezőbb a TC2-A eredményéhez képest, de ez még mindig 37%-kal elmarad a referenciaértéktől. Ez magyarázható azzal is, hogy a T05-ös állomás a Tiszalöki duzzasztómű hatása (antropogén hatás) miatt nagyon elkülönül a másik két ponttól. A másik két beállítással kapott eredmények már (TC3-B és TC3-C) jóval túlszárnyalják a referenciaértéket, vagyis az alsóbb szakaszokra a TC2 konfiguráció mellett a TC3 konfiguráció esetében is hatékonyabb a becslés (3. ábra).

Mindhárom konfiguráció eredményét megvizsgálva a TC3 konfiguráción belül a C beállításnál (7. táblázat) értem el a modellekkel a legeslegjobb eredményeket, ezen belül a GRNN modell a TC3-C#3 albeállítás esetén eredményezte a legpontosabb becslést, hiszen a számított RMSE érték  $0,74 \text{ mg L}^{-1}$  volt, ez pedig 65%-os teljesítményjavulást jelent a referenciaértékhez képest. Ekkor a T11 (Mindszent) állomás adatai alkották a tesztalmozást (4. ábra).



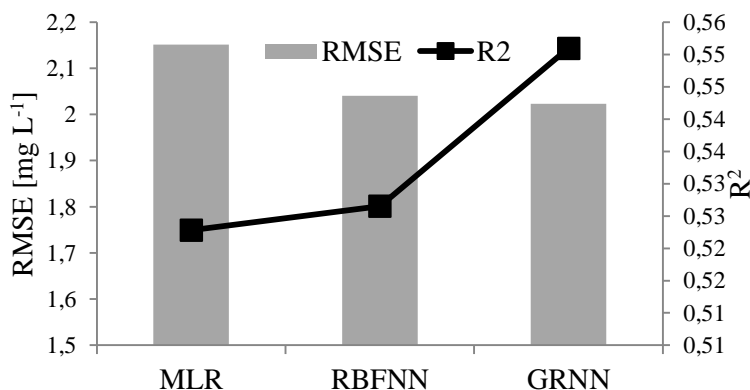
a) vonaldiagram

b) pontfelhő diagram

4. ábra TC3-C#3 albeállítás mért ill. becslt DO-szintjének diagramjai

Az alkalmazott modellek hatékonyságát megvizsgálva a három konfiguráció összes RMSE és  $R^2$  eredményét átlagolva azt az eredményt kaptam, hogy a neurális hálózatok hatékonyabb eszköznek bizonyultak, mint a többváltozós lineáris regresszió módszere (5. ábra). A neurális hálózatok közül a GRNN volt a leghatékonyabb modell a tiszai konfigurációk eredményei alapján.

### 3. Eredmények



5. ábra A vizsgált konfigurációkban kapott RMSE és R<sup>2</sup> értékek átlagai

#### 3.2.3. A tanítóhalmaz leghatékonyabb adatstruktúrája a Tiszán

A TC3 konfiguráció „A”, „B”, és „C” beállításainak eredményei rámutattak arra, hogy azok az albeállítások adják a legrosszabb teljesítményt, amikor kizárólag a homogén csoport mintavételi pontjai szerepelnek a tanítóhalmazban, és az inhomogén mintavételi pont szerepel a teszhalmazban (5. táblázat; TC3-A#1, TC3-B#1, TC3-C#1). Vagyis a modellek hatékonysága növelhető azzal, ha a tanítóhalmaz tartalmazza a homogén csoport egyik mintavételi pontját és az inhomogén mintavételi pontot, így a tanítóhalmaz tartalmazza mind a homogén, mind az inhomogén mintavételi pont adatainak struktúráit, ezzel elősegítve a hatékonyabb becslést. Ekkor a tanítóhalmaz „kevert struktúrájú”, így az ilyen eseteket „kevert struktúrának” neveztem el.

Az eredmények rámutattak arra, hogy a csökkenő mintaszám ellenére a tanító és a teszhalmaz tudatos/irányított kijelölésével, illetve térbeli optimalizációval jelentősen javítható a modellek hatékonysága.

#### 3.2.4. A folyó térbeli szakaszainak jellemzése

A TC2 és a TC3 konfiguráció eredményeit összevetve a referenciamodellel azt kaptam, hogy a folyó felső szakaszán rosszabb teljesítményű modellek készültek (TC2-A, TC2-B és a TC3-A beállítások), ez pedig rámutat arra, hogy a felsőbb folyószakasz jelentősebb változékonysága megnehezíti a becslést.

Ugyanakkor a TC2-C és TC2-D illetve a TC3-B és TC3-C beállítások hatékonysága, amelyek a folyó alsóbb szakaszaira adtak előrejelzést, már felülmúlták az referenciamodell eredményeit (3. ábra).

Összességében a TC2 és a TC3 konfiguráció eredményei is megerősítették, hogy a folyó alvízi szakaszain könnyebb a DO becslése, amely visszavezethető arra, hogy az áramlási sebesség lassulásával a vízminőségi

paraméterek változékonysága is csökken, így egy könnyebben becsülhető rendszer keletkezik. Ennek eredményeképpen a legpontosabb becslést is a folyó alsó szakaszán értem el (TC3-C#3, 4. ábra) kevert struktúra alkalmazásával.

### 3.3. Térbeli előrejelzés a Dunán

#### 3.3.1. A vizsgált konfigurációk modelleredményei

A Duna folyó DO-koncentrációját becsültem négy bemenő paraméterrel és két konfigurációban a tanító- és tesztalmaz kiválasztásának különböző módszere szerint. Az első konfigurációban a Duna folyó vizsgálatok a teljes adathalmazból véletlenszerűen választottam ki a tanító és tesztalmazokat 2:1 arányban. Ebben az esetben a folyó teljes magyarországi szakaszára adtam becslést az oldotoxigén-koncentrációjára vonatkoztatva. A véletlenszerű kiválasztás (2000 kezdőértékkel inicializálva) során létrejött  $D_R$  beállítás tesztalmazra vonatkozó eredményeit a 8. táblázat tartalmazza.

8. táblázat A dunai konfigurációk eredményei a tesztalmazra vonatkozóan

Beállítások	Tanítóhalmaz + Tesztalmaz	Modell	MLR	GRNN	RBFNN
$D_R$	2/3 + 1/3	RMSE [ $\text{mg L}^{-1}$ ]	1,39	1,22	1,27
		$R^2$	0,33	0,50	0,45
$D_A$	D6, D8 + D7	RMSE [ $\text{mg L}^{-1}$ ]	1,27	0,93	1,08
		$R^2$	0,48	0,69	0,59
$D_B$	D7, D8 + D6	RMSE [ $\text{mg L}^{-1}$ ]	1,41	0,96	1,01
		$R^2$	0,37	0,66	0,65
$D_C$	D6, D7 + D8	RMSE [ $\text{mg L}^{-1}$ ]	1,89	1,79	1,75
		$R^2$	0,32	0,39	0,41

Az eredmények rámutattak arra, hogy a többváltozós lineáris regressziós modellnél jóval pontosabb becslést adtak az neurális hálózatokkal való becslések, melyek közül a GRNN modellel értem el a leghatékonyabb becslést, tehát a GRNN modellel a tesztalmazra kapott RMSE érték ( $1,22 \text{ mg L}^{-1}$ ) lesz a referenciaérték.

A második konfigurációban a CCDA módszerrel meghatározott dunai homogén csoportok (1. ábra) közül csak egy kételemű homogén csoportot tudtam alkalmazni arra vonatkozóan, hogy a tanítóhalmaz leghatékonyabb adatstruktúráját meghatározzam, amihez két homogén és egy folyásirányban utánuk következő, szomszédos inhomogén állomásokra volt szükség. Ez a csoport a D6 (Budapest) és D7 (Nagytétény) állomások által alkotott homogén csoport volt, és a folyásirányban utánuk következő pont D8 (Dunaföldvár), ami már inhomogénnek tekinthető (2.1 pont). Így tehát egy beállítást vizsgáltam a D6, D7 és D8 állomások adataival úgy, hogy két

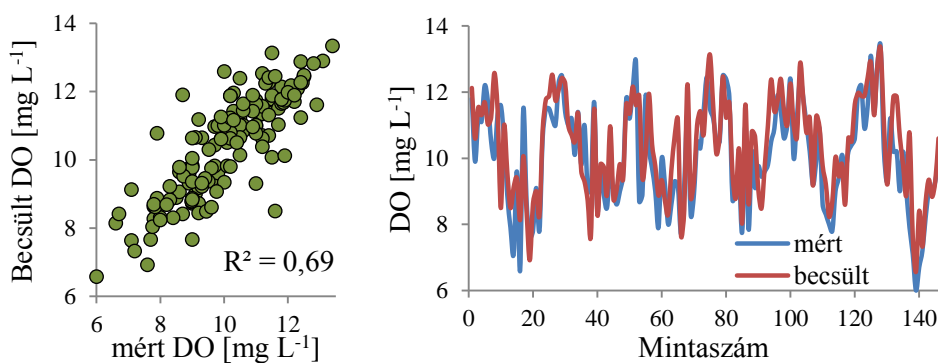
### 3. Eredmények

állomás adatai alkották a tanítóhalmazt és a harmadik mintavételi pont adatai voltak a teszhalmaz elemei, hogy biztosítva legyen a 2:1 arány a tanító- és a teszhalmazra vonatkozóan. Vagyis háromféle albeállítást kellett vizsgálnom, első esetben a D<sub>6</sub> és D<sub>8</sub> (D<sub>A</sub> beállítás), a második esetben D<sub>7</sub> és D<sub>8</sub> (D<sub>B</sub> beállítás) mintavételi pontok voltak a tanítóhalmaz elemei, végül pedig a D<sub>6</sub> és a D<sub>7</sub> állomások (D<sub>C</sub> beállítás) adatai kerültek a tanítóhalmazba.

Mindhárom albeállításnál megvizsgáltam, hogy melyik modellel kaptam a legkisebb RMSE értéket a teszhalmazra vonatkozóan, vagyis melyik modell volt a leghatékonyabb. Eszerint a D<sub>A</sub> beállítás esetén a GRNN modellel kapott 0,93 mg L<sup>-1</sup> RMSE érték volt a legkisebb a másik két modellel kapott értéknél. A D<sub>B</sub> beállítás esetén is a GRNN szolgáltatta a leghatékonyabb becslést (0,96 mg L<sup>-1</sup>), viszont a D<sub>C</sub> esetén az RBFNN modellel kaptam a legkisebb RMSE értéket (1,75 mg L<sup>-1</sup>) a teszhalmazra vonatkozóan. Tehát mindhárom beállítás esetén a két neurális hálózattal hatékonyabb becslést sikerült elérnem, mint az MLR modellel.

#### 3.3.2. A tanítóhalmaz leghatékonyabb adatstruktúrája a Dunán

A második konfiguráció eredményei alapján látható (8. táblázat), hogy a három albeállítás közül a legrosszabb eredményt a D<sub>C</sub> albeállítás adta, és bár a három modell közül itt az RBFNN modell volt a leghatékonyabb, a teszhalmazra vonatkozó RMSE érték 88% illetve 82%-kal rosszabb, mint a D<sub>A</sub> illetve a D<sub>B</sub> albeállítás legjobb RMSE értékei. A 3.2.3 pont szerint a D<sub>A</sub> és a D<sub>B</sub> albeállításoknál a tanítóhalmaz „kevert struktúrájú”, hiszen egy homogén és egy inhomogén állomás adatai alkotják a tanítóhalmazt. A D<sub>A</sub> és a D<sub>B</sub> albeállításokkal kapott becslések a teszhalmazra vonatkoztatott statisztikai mutatók alapján közel hasonló értékeket mutatnak, de a D<sub>A</sub> albeállítás és azon belül a GRNN modell adta a leghatékonyabb becslést (6. ábra), ahol Nagytétény állomás adatai voltak a teszhalmaz elemei.



a) pontfelhő diagram

b) vonaldiagram

6. ábra D<sub>A</sub> mért ill. becslött oldottoxigén-koncentrációjának diagramjai

### 3. Eredmények

---

A  $D_A$  és  $D_B$  beállításoknál kapott legjobb RMSE értékek a referenciaértékhez viszonyítva 31 és 27 százalékos javulást jelentenek, tehát ennyivel hatékonyabbak a referenciamodellnél, viszont a  $D_C$  albeállításnál majdnem 43%-os teljesítménycsökkenés figyelhető meg a referenciamodellhez képest.

Mivel a mintaszám a második konfigurációban az első konfiguráció mintaszámának kevesebb, mint negyede, ezért a  $D_A$  és  $D_B$  albeállításoknál elért hatékonyságnövekedés számottevő, hiszen a mintaszámot jelentősen csökkentve (térbeli homogenitást fölhasználva) sokkal hatékonyabb becsléseket kaptam. Ugyanakkor megjegyezendő, hogy térbeli optimalizáció esetén nem mindegy, hogy hogyan csoportosítjuk egy folyó homogén és inhomogén mintavételi pontjait a tanító- és a tesztalmezba, mert esetleg kevésbé hatékony eredmény is születhet.

## 4. ÚJ TUDOMÁNYOS EREDMÉNYEK

Kutatómunkám során folyóvizek oldottoxigén-koncentrációjának becslésén keresztül a neurális hálózatok különböző alkalmazásának bemutatásával foglalkoztam. Az eredményeim tézisekbe foglalt következtetéseit az alábbiakban foglalom össze:

### *1. Antropogén hatások befolyása a becslésre*

A Duna folyó adataival időbeli előrejelzést valósítottam meg a folyó oldottoxigén-koncentrációjára vonatkozóan MLR, MLPNN, GRNN és RBFNN modellek segítségével. Az így kapott eredményekkel igazoltam, hogy az MLR modell szolgáltatta referencia-becsléshez képest a zavartalan mintavételi ponton (Mohácson) nagyobb (30%-os) javulás érhető el hatékonyság terén a neurális hálózatokkal, míg a másik két zavart mintavételi pont (Fajsz és Győrzámoly) esetén csekélyebb (13-18%) javulás volt megfigyelhető. A modellek hatékonyságát a tesztalmazra számított RMSE értékekkel mértem. Megállapítottam, hogy az antropogén hatások által zavart mintavételi pontok adataival nehezebb a lineáris modellhez képest hatékonyabb becslést adni a neurális hálózatokkal.

### *2. Neurális hálózatok tanítóhalmazának leghatékonyabb adatstruktúrája*

A Tisza és a Duna folyók adataival térbeli előrejelzést, illetve térbeli optimalizációt valósítottam meg a folyók oldottoxigén-koncentrációjára vonatkozóan MLR, GRNN és RBFNN modellek segítségével úgy, hogy a folyók homogén csoportjait figyelembe véve adtam meg a tanító és a tesztalmazokat. Ez a Tisza esetében három, a Duna esetében pedig egy példát jelentett. Az így kapott eredményekkel igazoltam, hogy akkor hatékonyabb a becslés a tesztalmazra vonatkozó RMSE érték alapján, ha a tanítóhalmaz „kevert struktúrájú”, vagyis egyszerre tartalmazza a kételemű homogén csoport egyik mintavételi pontját és az inhomogén mintavételi pontot. Mind a négy példában az inhomogén állomás a kételemű homogén csoporttal folyásirányban szomszédos mintavételi pont volt.

### *3. Tisza folyó térbeli szakaszainak becslhetősége*

A Tisza folyó oldottoxigén-koncentrációjára vonatkozó térbeli előrejelzést és optimalizációt megvalósítva igazoltam, hogy a folyó magyarországi szakaszain az oldottoxigén-koncentráció eltérő pontossággal becslhető. A változékonyabb, nagyobb áramlási sebességgel jellemezhető felső folyószakaszon a becslések pontatlanabbak (pl.: Balsa, Záhony, Tiszalök-duzzasztó felett), mint az alsóbb szakaszokon (pl. Mindszent, Tápé, Tiszasziget). Mindez rámutatott arra, hogy adott esetben a vizsgált folyó

szakaszjellegét (felső-, közép- és alsó-) is figyelembe kell venni a becslések során.

#### *4. A leghatékonyabb modell kiválasztása oldottoxigén-tartalom becslésére*

Vizsgálataimmal igazoltam, hogy a neurális hálózatok – főleg a GRNN és az RBFNN – hatékonyabb modellek a tesztalmazra vonatkozó RMSE értékek alapján folyóvizek oldottoxigén-koncentrációjának becslésére a többváltozós lineáris regressziónál. A neurális hálózatok és a többváltozós lineáris modellek közötti teljesítménykülönbség a Duna vizsgálatainak esetében volt nagyobb mértékű.

## 5. KÖVETKEZTETÉSEK ÉS JAVASLATOK

A dunai vizsgálat időbeli előrejelzést megvalósító eredményeiből azt a tapasztalatot vontam le, hogy nagyon fontos megvizsgálni azt, milyen hatások érik a folyót az adott mintavételi pontban. Úgy tűnik ugyanis, hogy antropogén hatásoknak kitett, nem zavartalan állomás adataival való vizsgálat esetén nehezebb pontosabb becslést adni a lineáris és a neurális hálózatokkal is, ellenben csak zavartalan állomás adataival pontosabb, megbízhatóbb becslések születnek.

Folyóvizek oldottoxigén-koncentrációjának becslésével foglalkozó tudományos közlések áttanulmányozása során megállapítottam, hogy szinte alig van olyan tudományos munka, ahol a folyók mintavételi pontjait figyelembe véve osztották volna föl az adathalmazt tanító- és tesztalmazra, vagyis térbeli előrejelzés valósult volna meg. Kutatómunkámban a tiszai és a dunai vizsgálat során is adok példát térbeli előrejelzésre.

A tiszai vizsgálatnál az összes mintavételi pont adataival modelleztem az első két konfigurációban, majd arra a következtetésre jutottam, hogy érdemes a folyó mintavételi pontjainak a struktúráját is megvizsgálni a harmadik konfigurációban. Ekkor ugyanis a kevesebb mintából álló, optimalizált bemenő adathalmaz vizsgálatával hatékonyabb becsléseket kaptam ellentétben az első két konfigurációval. Tehát a csökkenő mintaszám ellenére a tanító- és a tesztalmaz irányított kijelölésével jelentősen javítható a modellek hatékonysága, ami nem mond ellen a statisztikai konzisztenciának, mivel a Tisza magyarországi szakasza nem tekinthető azonos struktúrájúnak.

A leghatékonyabb becslést a Tisza folyó alsó szakaszára kaptam a térbeli optimalizációval és a tanítóhalmazban „kevert struktúrát” alkalmazva, vagyis a két homogén állomás közül az egyik és a folyásirányban szomszédos inhomogén állomás alkották a tanítóhalmaz elemeit. A tanítóhalmaz leghatékonyabb adatstruktúrára vonatkozó megállapítást a Tiszán három a Dunán pedig egy példán mutattam be, és mind a négy példában a kételemű homogén csoporton kívül a folyásirányban szomszédos állomás volt az inhomogén mintavételi pont. További vizsgálataim során indokolt lehet megvizsgálni, hogy a kevert struktúra alkalmazása akkor is hatékonyabb, ha az inhomogén állomás nem a szomszédos mintavételi pontja a két-, vagy többelemű homogén csoportnak.

A kutatómunka további folytatása során célszerű lehet további neurális hálózatokkal, mint például tartó vektor géppel, illetve hibrid modellekkel is például adaptív neuro-fuzzy következtető rendszerrel becsülni folyóvizek oldottoxigén-koncentrációját.



## 6. ÖSSZEFOGLALÁS

Az emberiség utóbbi másfél évszázadának ipari tevékenysége miatt jelentős változás ment végbe a természetes vizek vízminőségében, ezért a felszíni vizek minőségét legjobban leíró paraméterek közül az oldottoxigén-koncentrációjának a becslése nagyon fontos feladat. Kutatómunkám célja bemutatni a neurális modellek minél hatékonyabb alkalmazásának lehetőségeit ezen paraméter becslésére két nagy folyóvizünk, a Duna és a Tisza adatait felhasználva.

A kutatási témakörhöz kapcsolódó szakirodalom tanulmányozása során bemutattam a neurális hálózatok előnyeit, hátrányait, különböző fajtáit, illetve meghatároztam azokat a könnyen mérhető paramétereket, melyek legjobban befolyásolják a folyóvizek oldottoxigén-koncentrációját.

A dunai mintavételi pontokból hármat választottam ki aszerint, hogy a folyót érik-e antropogén hatások vagy nem, így Mohács, mint „zavartalan” referenciaállomás, Győrzámoly és Fajsz, mint két ún. „zavart” állomás jelenik meg. A három állomást külön-külön illetve mind a hármat egyben is vizsgáltam időbeli előrejelzést megvalósítva négyféle modellel (MLPNN, GRNN, RBFNN és MLR). Jelentős javulást, 30 százalékos Mohács adataival értem el a GRNN modellel az MLR-rel szemben, a másik két zavart állomásnál nehezebb hatékonyabb becslést adni a lineáris modellhez képest.

A tiszai állomás összes mintavételi pontjának adatait háromféle módszerrel osztottam szét tanító- illetve tesztalakra, így az első konfigurációban egy referenciamodellrel valósítottam meg véletlen kiválasztással, a másodikban térbeli előrejelzést adtam mintavételi pontok térbeli elhelyezkedése szerinti kiválasztással. A harmadik konfigurációban (térbeli optimalizáció) csak három állomás adatait vizsgáltam egyszerre. Mindhárom konfigurációban 2:1 arányban osztottam szét az adatokat a tanító- és a tesztalakra között az összehasonlítás végett, és három modellt (GRNN, RBFNN, MLR) alkalmaztam. A kapott eredményekből megállapítható, hogy a Tisza magyarországi felső szakasza nehezebben becsülhető, ahogy a folyásirányban egyre lejjebb haladunk úgy növekszik a modellek hatékonysága. A tiszai és a dunai térbeli optimalizációt megvalósító konfigurációkban kapott eredményekkel igazoltam, hogy ha a tanítóhalmaz „kevert struktúrájú”, vagyis tartalmazza az egyik homogén állomás és az inhomogén állomás adatait, akkor hatékonyabb a becslés. Térbeli optimalizációval 65%-os javulást értem el a Tisza alsó szakaszán a referenciamodellhez képest úgy, hogy a tanítóhalmaz „kevert struktúrájú” volt. Megállapítottam, hogy a neurális hálózatok - főleg a GRNN és a RBFNN modellek - hatékonyabb eszközök folyóvizek oldottoxigén-tartalmának becslésére a lineáris modellel szemben.

## 7. AZ ÉRTEKEZÉS TÉMAKÖRÉHEZ KAPCSOLÓDÓ KIEMELT PUBLIKÁCIÓK

*Lektorált folyóiratcikk világnyelven*

1. **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. (ISSN: 0925-8574)
2. Molnár S., Molnár M., **Csábrági A.** (2014): Progress towards emission targets through the development of climate change policies and measures in Hungary. *Időjárás - Quarterly Journal of the Hungarian Meteorological Service*, Vol. 118 (4), pp. 293-305.
3. **Csábrági A.**, Molnár S., Tanos P., Kovács J. (2015): Forecasting of dissolved oxygen in the river Danube using neural networks. *Hungarian Agricultural Engineering*, Vol. 27, pp. 38-41.
4. Borbás E., Kovács J., Hatvani I.G., **Csábrági A.**, Molnár S. (2014): Water chemistry analysis in the sediment of the Baradla cave using geomathematical methods: Aggtelek, NE Hungary. *Mechanical Engineering Letters*, Vol. 11, pp. 32-43.
5. Molnár S., Somogyi F., **Csábrági A.** (2011): Comprehensive assessment of future energy needs and the role of alternative energy source. *Hungarian Agricultural Engineering*, Vol. 23, pp. 117-119.
6. Molnár S., Molnár M., **Csábrági A.** (2011): Impact assessment of mitigation strategies in the Hungarian agriculture. *Journal of Agricultural Informatics*, Vol. 2, pp. 10-17. (ISSN 2061-862X)

*Lektorált cikk magyar nyelven*

1. Molnár S., **Csábrági A.** (2010): Externális költségek vizsgálata az erőművi kibocsátások terén EcoSense modellel. *Acta Agraria Kaposváriensis*, 14(3), 69-77. o.
2. **Csábrági A.**, Molnár S., Tanos P., Kovács J. (2019): Neurális hálózatok alkalmazása ökológiai rendszerek vizsgálatában. *Mezőgazdasági Technika*, LX. évf. 3. sz., 2-5. o.
3. **Csábrági A.**, Molnár S., Tanos P., Kovács J. (2019): Neurális hálózatok alkalmazása hazai vízminőségi vizsgálatok során. *Mezőgazdasági Technika* (megjelenés alatt)