

Talajvízkutak vízminőségének értékelése vízminőségi indexek, mesterséges intelligencia és adatvizualizáció segítségével egy alföldi település példáján

BALLA Dániel¹, TARI Levente², HAJDU András¹, KISS Emőke², ZICHAR Marianna¹, MESTER Tamás²

¹ Debreceni Egyetem, Informatikai Kar, Adattudomány és Vizualizáció Tanszék

² Debreceni Egyetem, Természettudományi és Technológiai Kar, Tájvédelmi és Környezetföldrajzi Tanszék

E-mail: balla.daniel@inf.unideb.hu

[DOI: 10.30921/GK.77.2025.2.2](https://doi.org/10.30921/GK.77.2025.2.2)

Absztrakt

Jelen tanulmányban egy alföldi településen, Bárádon, 34 ásott talajvízkút 2022-es mintavétele alapján értékeltük a talajvíz minőségét. A vízminőség állapotának meghatározására három vízminőségi mutatót alkalmaztunk (Súlyozott Vízminőség Index, WQI; Szennyezettségi Index, Cd; Kanadai Környezetvédelmi Tanács Vízminőség Indexe, CCME-WQI), továbbá térinformatikai (GIS), adatvizualizációs rendszereket és mesterséges intelligenciát (MI) vontunk be a kutatásba. A talajvíz minőségének értékelése során 8 vízkémiai paramétert használtunk fel (pH, EC, NH_4^+ , NO_2^- , NO_3^- , PO_4^{3-} , KIO_3 , Na^+). Interpolált térképek alapján megállapítottuk, hogy magas a szervesetlen nitrogénformák és szervesanyag koncentrációk értéke, mely azt indikálja, hogy a területen felhalmozódott szennyezőanyagok jelen vannak, amelyet mindhárom vízminőségi mutató eltérő mértékben és területi konfigurációban igazolt. A geoadatbázis interaktív megjelenítését Tableau Public felületen tettük elérhetővé, amely hatékonyan segíti a térbeli mintázatok azonosítását. A talajvízminőség előrejelzésére előrecsatolt neurális hálót (Feed-Forward Neural Network, FFNN) alkalmaztunk, amely a WQI és Cd mutatók esetében magas prediktív teljesítményt mutatott (trainbr algoritmus: $\text{RMSE}_{\text{WQI}}=0,164$, $\text{RMSE}_{\text{Cd}}=0,089$; $R^2_{\text{WQI}}=0,978$, $R^2_{\text{Cd}}=0,994$), míg a CCME-WQI alacsonyabb pontossággal bizonyult becsülhetőnek. Eredményeink rámutatnak, hogy a bayesi szabályozás és az aktivációs függvények optimalizálása javíthatja a modell teljesítményét, ugyanakkor a kis mintaszám és egyes paraméterek határérték-túllépése korlátozza az általánosíthatóságot. A jövőbeli kutatások során a mintaszám növelése, idősoros adatok bevonása és a tanító- valamint tesztalmozok irányított kijelölése jelentős mértékben hozzájárulhat a térbeli becslések megbízhatóságának növeléséhez.

Abstract

In our study, we assessed the groundwater quality in a lowland municipality in Báránd, using 34 dug groundwater wells sampled in 2022. Water quality was evaluated using three water quality indices (Water Quality Index (WQI), Contamination degree (Cd), Canadian Council of Ministers of the Environment Water Quality Index (CCME-WQI)), geographic information systems (GIS), data visualization systems and artificial intelligence (AI). Eight water chemistry parameters (pH, EC, NH_4^+ , NO_2^- , NO_3^- , PO_4^{3-} , KIO_3 , Na^+) were used to assess groundwater quality. Based on interpolated maps, we found that inorganic nitrogen forms and organic matter concentrations are high, indicating that accumulated pollutants are present in the area, as confirmed by all three water quality indicators to varying degrees and spatial configurations. Interactive visualisation and cloud-based sharing of the geodatabase data created was made freely available using Tableau Public, where it should be emphasised that data visualisation is an efficient tool for post-processing spatial monitoring data, as it can visualise information in intuitive visual format and explore spatial patterns and relationships. We also attempted to predict groundwater quality by creating a Feed-Forward Neural Network (FFNN), which estimated the water quality status of three water quality indicators based on water chemistry parameters. The most accurate predictions for the WQI and Cd indices were obtained by the Bayesian algorithm (trainbr), which achieved the smallest root mean square error ($\text{RMSE}_{\text{WQI}} = 0.164$, $\text{RMSE}_{\text{Cd}} = 0.089$) and the highest coefficient of determination ($R^2_{\text{WQI}} = 0.978$, $R^2_{\text{Cd}} = 0.994$). For the CCME-WQI indicator, the accuracy of the models was lower, suggesting that this index is more difficult to predict. Our results indicate that Bayesian regulation and optimization of activation functions can improve model performance, but small sample sizes and specific parameters exceeding their limits restrict generalizability. In future research, increasing the sample size, incorporating time series data, and guided selection of training and test sets could significantly improve the reliability of spatial estimations.

1. Bevezetés

A felszíni és felszín alatti vizek minőségének romlása aktuális jelenség, amely súlyos környezeti és egészségügyi problémákat eredményez. Ez nemcsak hazánkban, hanem a fejlődő és fejlett országokban egyaránt érzékelhető, ahol az urbanizáció és az ipari tevékenység jelentős nyomást gyakorol a vízkészletekre és azok minőségére (Kerényi és McIntosh 2020). Az elmúlt 20 évben nemzetközi esettanulmányok igazolták, hogy az ipari és mezőgazdasági tevékenység mellett az egyik legjelentősebb szennyezőforrás a kommunális szennyvíz, amelynek kezelése és tisztítása még mindig megoldatlan jellemzően a rurális térségekben (Keraita et al. 2003; Rutkowski et al. 2007; Aulakh et al. 2009; Tytla 2019; Livia et al. 2020; Bano et al. 2022). A települési szennyvíz okozta vízminőség romlás folyamatos monitorozása mellett, kiemelten fontos feladat a szennyezések feltérképezése, vízminőségi mutatók és modern térinformatikai döntéstámogató rendszerek felhasználásával (Zolfaghary et al. 2021).

A vízminőség tudományos alapokon nyugvó értékelését a Horton (1965) által bevezetett vízminőségi index tette lehetővé, amelyet az elmúlt közel hatvan év alatt számos alkalommal módosítottak (Brown-index (Water Quality Index, WQI (Brown et al. 1972)), Oregon index (Oregon Water Quality Index, OWQI (Dunnette 1979; Cude 2001)), Canadian Council of Ministers of the Environment Water Quality Index (CCME-WQI, (Lumb et al. 2006)) vagy további paraméterek bevonásával és aggregálásával újabb mutatókat hoztak létre (Liou index (Liou et al. 2004), Smith's index (Smith 1990), Overall Index of Pollution (Sargaonkar és Deshpande 2003), Equity Index (Luh et al. 2013)). A leggyakrabban használt 21 vízminőségi index összehasonlító vizsgálatáról Uddin et al. (2021) nyújtottak részletes áttekintést felhívva a figyelmet a vízminőségi indexek kiválasztása során a paraméterek számára, faktorok súlyára, illetve azok bizonytalanságaira. Számos nemzetközi tanulmány jutott arra a következtetésre, hogy a vízminőségi indexek legfontosabb feladata a nagyszámú bemeneti paraméterek adatminimalizálása révén biztosítani a vízminőség állapotára vonatkozó információk előállítását és értelmezését (Simsek és Gunduz 2007; Şener et al. 2017; Jha et al. 2020; Dandge és Patil 2021). Az indexértékek alapján előállított vízminőségi információk felhő alapú webGIS döntéstámogató rendszerekbe integrálva és interaktív adatvizualizációs eszközökkel támogatva további segítséget nyújtanak a döntéshozóknak a vízminőségi változások nyomon követéséhez, ezáltal a gyors és akár azonnali vízgazdálkodási intézkedések meghozatalához (Saravani et al. 2024). Ezen technológiák alkalmazása különösen fontossá vált olyan területeken, ahol a vízszennyezés hatásai komoly fenyegetést jelentenek az ivóvízellátásra és a mezőgazdasági termelésre (Habeeb et al. 2019).

A mesterséges intelligencia (MI) és a GIS technológiák integrációja szintén jelentős előrelépést eredményezett a vízminőségi adatokat tároló geoadatbázisok feldolgozásában, térbeli megjelenítésében és elemzésében is (Taşan 2022). Az olyan gépi tanuló modellek, mint a véletlen erdő (random forest, RF), a mesterséges neurális hálózat (artificial neural network,

ANN) vagy a support vector machine (SVM) rendkívül hatékonyak bizonyultak a vízminőségi adatok előrejelzésében, mivel képesek nagy mennyiségű, heterogén adat kezelésére, térbeli mintázatok detektálására (Mustafa et al. 2021).

Kutatásunk aktualitását jelzi, hogy a települési környezetben a szennyvíz okozta vízminőség romlásáról és elszennyeződéséről születtek hazai publikációk (Prohászka et al. 2022; Vadas és Ferenczi 2023; Kirschner et al. 2024), azonban modern térinformatikai-adatvizualizációs eszközök segítségével és MI bevonásával végzett monitoring adatokon alapuló vízminőség vizsgálatok még nem kerültek a hazai kutatások középpontjába.


A fentiek alapján a kutatás legfontosabb célja megállapítani azt, hogy egy alföldi településen, Bárándon, a szennyvízcsatornahálózat kiépítését követő nyolcadik évben a talajvízkészlet még mindig szennyezett-e, illetve azt, hogy ez az állapot milyen mértékben tükröződik a különböző vízminőségi mutatókban. Ennek alapján az alábbi célokat tűztük ki:

1. Geoadatbázis építés ésott talajvízkutak felhasználásával a mintavételi és mérési adatok alapján.
2. A talajvíz minőségének becslése és teljesítményértékelése neurális háló létrehozásával és betanításával 8 vízkémiai paraméterek alapján.
3. A település talajvízminőségének térképezése, interaktív adatvizualizációja és felhő alapú megosztása három vízminőségi mutató alkalmazásával.

2. Anyag és módszer

2.1. Mintaterület bemutatása

Báránd jellegzetes alföldi középfalu, amely az Alföld keleti részén a Nagy-Sárréten helyezkedik el (1. ábra). A település szennyvízkibocsátása meghaladja a 2000 lakosegyenértéket (LE) ezért az Európai Unió vonatkozó irányelvei (2000/60/EC 2000) kötelezővé tették a csatornahálózat kiépítését. Ennek megfelelően, a csatornarendszert 2014-ben építették ki az Új Magyarország Fejlesztési Terv Környezet és Energia Operatív Programjának támogatásával. Korábbi kutatásaink igazolták, hogy a több évtizede zajló szennyvízkiáramlás hatására a település talajvízkészlete erősen elszennyeződött, amely a vízminőségi mutatókban is tükröződik (Mester et al. 2017, 2020; Balla et al. 2022, 2023a). Kimutattuk továbbá, hogy a talajvíz áramlási iránya alapvetően meghatározza a talajvíz szennyezettségének térbeli alakulását ezért azok a településrészek a legszennyezettebbek, amelyek felé a többi településrész felől a talajvíz áramlik. A szennyvízcsatornahálózat kiépítését követő monitoring időszakban a településen szignifikánsan javult a talajvíz minősége, azonban a szennyezettség a mai napig jelentős mértékű, ezért rendszeres, évenkénti mintavétellel megfigyeljük a talajvízkutakat a tisztulási folyamatok nyomon követése céljából (Balla et al. 2024).



1. ábra A monitoring kutak elhelyezkedése (A), valamint a mintaterület domborzati (B) és talajvíz viszonyai (C) 2022-ben.

2.2. Mintavétel és laboratóriumi feldolgozás

A vizsgálatba 34 ásott talajvízkutat vontunk be. A kutakból 2022 nyarán végzett mintavétel során a talajvízkutak felső 1 méteres vízrétegét mintáztuk meg. A talajvíz minőségének értékelését három vízminőségi mutató alkalmazásával végeztük el, mely során 8 fontos vízkémiai paramétert használtunk fel (pH , EC , NH_4^+ , NO_2^- , NO_3^- , PO_4^{3-} , KOI_{ps} , Na^+). A paraméterek kiválasztása során a háztartási szennyvizek legjellemzőbb szennyezőit vettük figyelembe. A minták pH és EC értékei WTW 315i mérőműszerrel, a begyűjtött vízminták NH_4^+ , NO_2^- , NO_3^- , PO_4^{3-} tartalmát MSZ ISO 7150-1:1992, MSZ 448-18:2009 és az MSZ 1484-13:2009 alapján spektrofotométerrel határoztuk meg (HS ISO 7150-1 1992; HS 448-18 2009; HS 1484-13 2009). A KOI_{ps} értékét Kálium-permanganáttal, a Na^+ értékét PerkinElmer 3110 AAS műszerrel mértük.

2.3. Alkalmazott vízminőségi indexek

Súlyozott Vízminőség Index (WQI) és Vízminőség Állapot (WQS)

Mivel a különböző paraméterek fontossága függ az adott víz felhasználásától, ezért Brown et al. (1972) súlyozott számtani index használatát javasolták, melynek kiszámolása a következő lépésekből áll [1-4]:

$$WQI = \sum Q_n W_n / \sum W_n \quad (1)$$

ahol Q_n az n . vízminőségi paraméter minőségi besorolása, W_n az n . vízminőségi paraméter egységnyi súlya, WQI a súlyozott vízminőségi index értéke. A Q_n értékét az alábbi egyenlet alapján számítjuk ki:

$$Q_n = 100 \left[\frac{(V_n - V_i)}{(V_s - V_i)} \right] \quad (2)$$

ahol V_n az n -edik paraméter tényleges értéke, V_i az adott paraméter ideális értéke [$V_i=0$, kivéve: pH ($V_i=7$)], a V_s az n . vízminőségi paraméter szabványos megengedett határértéke. Az egységnyi súly (W_n) a következő képlettel számolhatjuk ki:

$$W_n = k / V_s \quad (3)$$

ahol k az arányosság állandója, amelyet a következő egyenlet alapján számolhatjuk ki:

$$k = [1 / \sum 1 / V_s = 1, 2, \dots, n] \quad (4)$$

A WQI értékek alapján meghatározott vízminőségi kategóriákat a Táblázat 1. tartalmazza.

Táblázat 1. A WQI értékek és minősítésük (Brown et al. 1972).

WQI érték	Vízminőségi állapot
0-25	Kiváló vízminőség
26-50	Jó vízminőség
51-75	Rossz vízminőség
76-100	Nagyon rossz vízminőség
100<	Bármilyen használatra alkalmatlan

Szennyezettségi Index (Cd)

Az index a talajvízre káros paraméterek együttes hatását tükrözi, oly módon, hogy minden határérték feletti paramétert figyelembe vesz. Az index ebből következően a szennyező faktorok összegének tekinthető. A szennyezettség fokának megállapítása során minden vízminta esetében el kell végezni a számításokat. A számítások a következő egyenletek alapján végezhetők el [5-6] (Backman et al. 1998):

$$C_{fi} = \frac{C_{Ai}}{C_{Ni}} - 1 \quad (5)$$

$$Cd = \sum_{i=1}^n C_{fi} \quad (6)$$

ahol C_{fi} a szennyezettségi faktor i -edik komponensre; C_{Ai} az i -edik komponens analitikai értéke; C_{Ni} az i -edik komponens szennyezettségi határértéke, Cd a szennyezettségi index értéke. A Cd értékek alapján meghatározott szennyezettségi kategóriákat a Táblázat 2. tartalmazza.

Táblázat 2. A Cd értékek és minősítésük (Backman et al. 1998).

Cd érték	Szennyezettség foka
<1	Alacsony
1-2	Közepes
2-3	Szennyezett
>3	Erősen szennyezett

Kanadai Környezetvédelmi Tanács Vízminőség Indexe (CCME-WQI)

A Kanadai Környezetvédelmi Tanács (Canadian Council of Ministers of the Environment) által 2001-ben kialakított vízminősítési rendszer három faktor kombinációján alapszik [7-13] (Lumb et al. 2006):

F1: A paraméterek száma, melyek átléplik a szennyezettségi határértéket (Scope):

$$F1 = \left(\frac{\text{határérték feletti paraméterek száma}}{\text{összes paraméter száma}} \right) \times 100 \quad (7)$$

F2: A gyakoriság, mellyel a határértékek nem teljesülnek (Frequency).

$$F2 = \left(\frac{\text{határérték feletti mérések száma}}{\text{összes mérés száma}} \right) \times 100 \quad (8)$$

F3 (amplitúdó) A határérték átlépés mértéke: Azt az összeget jelöli, amennyivel az egyes paraméterek értékei átléplik a vonatkozó határértéket. Ezt három lépésben számítjuk ki:

A határértéktől való eltérés azon esetek számát jelöli, amikor az egyes koncentrációk átléplik (vagy nem érik el) az adott határértéket:

$$\text{határértéktől való eltérés}_i = \left(\frac{\text{Határérték feletti koncentráció}_i}{\text{Határérték}_i} \right) - 1 \quad (9)$$

Azon esetek együttes összege, amikor az egyes koncentrációk nem felelnek meg a határértékeknek. Kiszámítása: Az egyes minták paramétereinek határértéktől való eltérésének az összege, osztva a vizsgálatok teljes számával (amelyek, ha teljesítik a határértéket és amelyek nem). E paraméter, a határértéktől való eltérések normalizált összege (*nse*):

$$nse = \frac{\sum_{i=1}^n \text{határértéktől való eltérés}_i}{\text{vizsgálatok teljes száma}} \quad (10)$$

Az F3-at ezután egy aszimptotikus függvény alapján számítjuk ki, amely a határértéktől való eltérések normalizált összegét (*nse*) skálázza egy 0 és 100 közötti tartományban.

$$F3 = \frac{nse}{0,01nse + 0,01} \quad (11)$$

Miután mindhárom faktor értékét kiszámoltuk a CCME-WQI-t a következő képlet alapján számolhatjuk ki:

Az 1.732-es osztó a kapott értékeket 0 és 100 közötti tartományba normalizálja, ahol 0 a „legrosszabb” vízminőséget és 100 a „legjobb” vízminőséget jelenti.

$$\sqrt{100^2 + 100^2 + 100^2} = \sqrt{30000} = 173,2 \quad (12)$$

$$CCME\ WQI = 100 - \left(\frac{\sqrt{F1^2 + F2^2 + F3^2}}{1,732} \right) \quad (13)$$

A skála alapján történő kategorizált csoportokat a Táblázat 3. tartalmazza.

Táblázat 3. A CCME-WQI értékek és minősítések (Lumb et al. 2006).

CCME-WQI érték	Vízminőségi állapot
95-100	Kiváló
80-94	Jó
60-79	Megfelelő
45-59	Szennyezett
0-44	Erősen szennyezett


2.4. Neurális hálózat alkalmazása a vízminőségi mutatók teljesítményének becslésére

A vízminőségi mutatók teljesítményének értékeléséhez előrecsatolt neurális hálózatot hoztunk létre (Feed-Forward Neural Network, FFNN). Az FFNN gráfmodell egy ellenőrzött tanítást megvalósító előrecsatolt neurális hálózat, amely három réteget tartalmaz: egy bemeneti (pH , EC , NH_4^+ , NO_2^- , NO_3^- , PO_4^{3-} , KOI_{ps} , Na^+), egy rejtett és egy kimenő réteget (vízminőségi állapot a WQI és CCME-WQI index alapján, szennyezettség foka a Cd index alapján). Az előrecsatolt hálózat azt jelenti, hogy a jel balról jobbra áramlik, azaz egy adott rétegbeli neuron bemenete a tőle balra lévő rétegbeli neuron kimenete lesz, vagyis a hálózat gráfelméleti reprezentációja nem tartalmaz hurkot (Csábrági et al. 2019; Alrowais et al. 2023) (2.ábra).

A modellek tanításakor az első szakaszban a transzferfüggvényként alkalmazott függvények paraméterei önszerveződő módon állítottak be, majd a második szakaszban már ellenőrzött tanítást megvalósítva, iterációs eljárással (ismétlések száma =20) határoztuk meg a rejtett rétegben lévő neuronok, illetve a rejtett és a kimeneti réteg közötti súlytényezőket, torzításokat.

A neurális hálózatok alkalmazásakor a mintahalmazt véletlenszerűen három részhalmazzá bontottuk fel, mivel a modellek teljesítménye és általánosító képessége alapvetően függ ezen halmazok meghatározásától és a mintahalmaz nagyságától. A mintahalmaz 70 %-át tanításra (darabszám=24), 15 %-át (darabszám=4) validációra, 15 %-át (darabszám=4) pedig tesztelésre használtuk. A tanító halmaz a modell paramétereinek illesztésére szolgál, míg a validációs halmaz a modell- és hyperparaméter választást támogatja, hogy elkerüljük a túlillesztést. A teszt halmazt pedig torzítatlan általánosító becslésre használjuk (Csábrági et al. 2019).

A neurális hálózatok kialakítását és tanítását, valamint a modellek teljesítményértékelését MATLAB R2020a környezetben implementáltuk előrecsatolt architektúrájú, ellenőrzött tanítást megvalósító Deep Learning Toolbox felhasználásával (The MathWorks Inc).



2.ábra. Az előrecsatolt (feed-forward) neurális háló felépítése.

Az alkalmazott vízminőségi modellek teljesítményének értékeléséhez két statisztikai mutatót használtunk fel, melyek az átlagos négyzetes hiba négyzetgyöke ($RMSE$) és a determinációs együttható (R^2). Az egyes statisztikai mutatók képletei a következők [14-15]:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (v_i - y_i)^2} \quad (14)$$


$$R^2 = \frac{[\sum_{i=1}^N (v_i - \bar{v})(y_i - \bar{y})]^2}{\sum_{i=1}^N (v_i - \bar{v})^2 \sum_{i=1}^N (y_i - \bar{y})^2} \quad (15)$$

ahol N a bemenő minták elemszáma; v_i és y_i az i -edik mért és a becsült kimeneti adatok, a $\bar{v}$ és $\bar{y}$ ezen mért adatok átlagát fejezi ki (Csábrági et al. 2019b).

2.5. Térképezés és adatvizualizáció

A település vízminőségi állapotának feltérképezését és felhő alapú adatvizualizációját három munkafolyamat alapján valósítottuk meg (3. ábra). Az adatgyűjtés során a bevett vízminták laboratóriumi mérését és a vízminőségi indexek meghatározását végeztük el egy saját fejlesztésű webGIS eszköz alkalmazásával (Balla et al. 2023b). A vízkémiai paraméterek és vízminőségi státuszok térbeli ábrázolása érdekében krigeléses interpolációs eljárással izovonalas térképeket készítettünk Surfer 12 szoftverkörnyezetben (Golden Software, LLC 2012).

A létrehozott geoadatbázis interaktív adatvizualizációját a Tableau szoftver grafikus felületén végeztük el. Az adatelőkészítés fázisában csatlakoztattuk a geoadatbázist és definiáltuk a dimenziókat és a mérőszámokat. A második fázisban megterveztük az adatbázist bemutató nézeteket (diagramok, táblázatok, fatérkép-diagramok, ponttérképek), interaktív szűrőket és irányítópultokat. Az utolsó fázisban pedig az elkészült irányítópultok összefűzésével történetet (story) hoztunk létre, amelyet a Tableau Cloud segítségével tettünk szabadon elérhetővé (Tableau Public, 2024).




3.ábra. A vízminőségi adatok feldolgozásának és publikálásának folyamata.

3. Eredmények és értékelésük

3.1. Vízkémiai paraméterek értékelése

A vízminőségi indexek kiszámításához szükséges vízkémiai paraméterekre vonatkozó szennyezettségi határértékek leíró statisztikáját és eloszlását a 4. táblázat és a 4. ábra tartalmazza. 2022-ben, nyolc évvel a szennyvízcsatorna hálózat kiépítését követően a vizsgált 8 paraméterből már csak 3 paraméter esetében (EC , NH_4^+ , NO_3^-) haladják meg az átlagértékek a vonatkozó határértéket. A vízminták elektromos vezetőképessége igen magas szórást mutat, a minimum értéke $1396 \mu S/cm$, míg a maximum értéke $11700 \mu S/cm$ volt. A vízminták emelkedett szervesanyag-tartalma ($KOI_{ps_max} = 5,11 mg/l$) jelzi, hogy az évtizedeken át zajló szennyvízkiáramlás következtében jelentős mennyiségű szerves anyag halmozódott fel a talajban és talajvízben. Az ammónium a szerves anyag lebomlását jelzi, ezáltal friss szennyezést indikál. A felső kvartilis értéke $0,77 mg/l$ volt, az alsó kvartilis értéke $0,38 mg/l$ mely még mindig szennyezettséget jelez. A nitrát esetében is jelentős különbségek mutatkoznak az egyes talajvízkutak értékei között. Az alsó és felső kvartilis értékei is meghaladják a szennyezettségi határértéket. Míg az alsó kvartilis csak $76,1 mg/l$ -el, addig a felső kvartilis értéke közel hét és félszerese volt ($377,27 mg/l$) a határértéknek.



4. ábra A vizsgált vízkémiai paraméterek eloszlása 2022-ben.


A vizsgált vízkémiai paraméterek térbeli alakulását a 2022-es évben az 5. ábra mutatja be. A szervesetlen nitrogénformák térbeli alakulása nagyfokú hasonlóságot mutat, azonban a határérték feletti koncentrációt mutató területek arányai eltérnek. A nitrít esetében a település jelentős részén határérték alatti koncentrációt mértünk, csupán a nyugati településrészen voltak emelkedett értékek. A nitrít koncentrációjának viszonylag

alacsony értékei (a település döntő részén <0,15 mg/l) azt jelzi, hogy a nitrifikáció folyamata végbe tud menni. Az ammónium koncentrációja a nitrithoz képest nagyobb területeken alakul határérték felett (0,50 mg/l), és bár a település északi, középső és déli részei a kevésbé szennyezettek, az antropogén a település ezen részein is kimutatható. Jellemzően csupán néhány kútban mértünk határértéket jelentősen meghaladó koncentrációt a település nyugati és keleti részein. A nitrát esetében rajzolódik ki a legkedvezőtlenebb kép, a település döntő részén határérték feletti koncentráció (>50 mg/l) a jellemző, csupán a belső területek és egy szűk északi sáv mutat alacsonyabb szennyezettséget. A település döntő részén 200 mg/l feletti koncentráció, míg kisebb, de jelentős területeken 400 mg/l feletti értékek jellemzőek.

Az elektromos vezetőképesség alakulása hasonló térbeli mintázatot mutat a szervesetlen szennyezők alakulásával, így a település északi és középső részein mutatható ki alacsonyabb érték, míg 3500 µS/cm feletti értékek a település nyugati és keleti részein mérhetőek.

Táblázat 4. A vízkémiai paraméterek leíró statisztikája.

Paraméter	Határérték	Átlag	Szórás	Min	Max	Alsó kvartilis	Felső kvartilis
pH	6,5-8,5	7,27	0,23	6,95	7,80	7,08	7,50
EC (µS/cm)	2500	3664,20	2081,5	1396	11700	2163,75	4623,75
NH ₄ ⁺ (mg/l)	0,50	0,64	0,50	0,10	2,47	0,38	0,77
NO ₂ ⁻ (mg/l)	0,50	0,20	0,30	0,00	1,24	0,04	0,25
NO ₃ ⁻ (mg/l)	50	296,1	329,90	9,64	1186,05	76,10	377,27
PO ₄ ³⁻ (mg/l)	0,50	0,20	0,200	0,03	0,89	0,10	0,32
KOI (mg/l)	4,50	2,20	0,8	0,99	5,11	1,71	2,58
Na ⁺ (mg/l)	200	153,50	77,10	21,70	295,77	94,90	205,26



5. ábra A vizsgálat vízkémiai paraméterek térbeli alakulása 2022-ben


A szervesanyag-tartalom kedvezően alakul, a település túlnyomó részén 3 mg/l érték alatti koncentráció jellemző. A foszfát-ion koncentrációja a település északi részein határérték alatt van, ugyanakkor egy nagyobb sávban továbbra is 0,5 mg/l felett alakul, ami szintén jól jelzi a korábbi szennyvíz kiáramlást, és egyéb lokális szennyezőforrások hatását. A pH érték a semleges, enyhén lúgos tartományban mozog 7 és 7,8 közötti tartományban. Magasabb pH érték a település északi részein jellemző. A nátrium tartalom a település több pontján is határérték felett alakul, mely természetes talajtani viszonyok mellett a kiáramló szennyvíz magas nátrium tartalmával magyarázható. Összességében megállapítható, hogy 8 évvel a csatornázást követően a település területének északi és középső területei mutatják a legalacsonyabb szennyezettséget, míg a déli és nyugati részek tekinthetők a legszennyezettebbnek a vizsgált vízkémiai paraméterek alapján.

3.2. A vízminőségi mutatók teljesítményértékelése mesterséges intelligencia felhasználásával

Az MI-modell célja, hogy a vízminőségi indexek becslését hiányos, vagy részben rendelkezésre álló adatok mellett, gyorsan és valós időben lehessen elvégezni, valamint jövőbeli előrejelzést is adjon. Ennek megfelelően előrecsatolt neurális háló (Feed-Forward Neural Network, FFNN) létrehozásával kísérletet tettünk a talajvízminőség térbeli előrejelzésére, a vízkémiai paraméterek alapján háromféle vízminőségi mutató állapotának becslésével. A modellek három rétegből épülnek fel: egy bemeneti réteg, amely tartalmazza a vizsgált vízkémiai paramétereket (pH , EC , NH_4^+ , NO_3^- , NO_2^- , PO_4^{3-} , KOI_{ps} , Na^+), egy rejtett réteg, és egy kimeneti réteg, ahol a vízminőségi mutatók előrejelzése történik.

A 6. ábra a valós (kék) és a modell által becsült (piros) értékek illeszkedését mutatja a tanító (bal) és teszt (jobb) halmazokon három vízminőségi mutatóra: (A) WQI, (B) Cd, (C) CCME-WQI. A tanító adatoknál mindhárom mutató esetében gyakorlatilag teljes az átfedés, ami nagyon alacsony reziduális hibára utal, ugyanakkor felveti a túlillesztés lehetőségét. Ugyan a rendkívül kis tesztkészletben (darabszám = 5) a WQI és Cd értékek vizuálisan pontos előrejelzést adnak, a CCME-WQI esetén pedig néhány pontnál kisebb alulbecsléssel prezentálnak. A kis tesztminta miatt a modell túlillesztésének veszélye jelentős, ezért nagyobb, független adatkészlettel szükséges a jövőben a validáció. A megbízható általánosíthatóság igazolásához ezért nagyobb, független validációs készlet és kvantitatív teljesítménymutatók (pl. RMSE, R^2) szükségesek a jövőben.

A rejtett rétegben alkalmazott neuronok száma befolyásolta a modellek teljesítményét (Táblázat 5). A WQI RMSE értékei a neuronok számának növelésével kis mértékben változtak, 0,164 és 0,185 között mozognak. Az RMSE érték csökkenését tapasztaltuk 17 neuron alkalmazásával ($RMSE_{17 \text{ neuron}} = 0,164$), míg magasabb neuronszám esetében kis mértékben ugyan, de magasabb értékeket mutattak ($RMSE_{19 \text{ neuron}} = 0,175$, $RMSE_{21 \text{ neuron}} = 0,184$, $RMSE_{25 \text{ neuron}} = 0,185$). Ebből arra következtet-



6. ábra A valós és becsült értékek összevetése a tanító és teszt adathalmaz esetében: (A) WQI, (B) Cd, (C) CCME-WQI.

hetünk, hogy ebben a modellben a neuronok száma nem befolyásolta drasztikusan a hibát, azonban 17 neuron alkalmazásával a legpontosabb az eredmény. Az R^2 értékek 0,972 és 0,978 között mozognak, és 17 neuron esetében itt is a legjobb az illeszkedés (0,978), ami magas prediktív képességet jelez.

A Cd mutató RMSE értékei 0,089 és 0,114 között változnak, a legkisebb hiba 19 neuron alkalmazásával érhető el ($RMSE_{19 \text{ neuron}} = 0,089$). Az R^2 értékek 0,990 és 0,994 között változnak, ami azt jelenti, hogy a modell ebben az esetben is nagyon jó prediktív képességgel bír, és optimális választás lehet a Cd index becslésére.

A CCME-WQI RMSE értékei (0,272 és 0,352) jóval nagyobbak, mint az előző két mutató értékei, ami magasabb hibaszintre utal. A legalacsonyabb RMSE érték 10 neuron alkalmazásával érhető el (0,272), és az R^2 értékek 0,771 és 0,863 között változnak, így ez a mutató kevésbé pontosabban becsülhető, továbbá a neuronok számának növelése ebben a konfigurációban nem eredményezett szignifikáns javulást.

Megvizsgáltuk, hogy a különböző tanító algoritmusok (trainlm-Levenberg-Marquardt, trainscg- Scaled Conjugate Gradient; trainbr-Bayesian Regularization) hogyan befolyásolják a modellek teljesítményét (Táblázat 6). A tanító algoritmusok célja a hálózat súlyainak beállítása úgy, hogy a hálózat a bemeneti adatok alapján minél pontosabb kimeneti értékeket adjon. A tanító algoritmusok végzik a hálózat „tanulását”, vagyis az optimalizálást, amely során a hálózat súlyai a bemeneti és kimeneti adatok közötti kapcsolatot alakítják ki. A legjobb eredményt a bayesi szabályozáson alapuló trainbr algoritmus ad-

Táblázat 5. A vízminőségi modellek rejtett rétegében alkalmazott neuronok számának hatása a vizsgált statisztikai mutatókra.

Vízminőségi mutató	Statisztikai mutató	Neuronok száma				
		10	17	19	21	25
WQI	RMSE	0,184	0,164	0,175	0,184	0,185
	R ²	0,972	0,978	0,974	0,972	0,972
Cd	RMSE	0,096	0,093	0,089	0,114	0,097
	R ²	0,993	0,994	0,994	0,990	0,993
CCME-WQI	RMSE	0,272	0,315	0,352	0,324	0,336
	R ²	0,863	0,817	0,771	0,806	0,791

ta, különösen a WQI és Cd mutatók esetében, ahol a legkisebb RMSE ($RMSE_{trainbr_WQI} = 0,164$, $RMSE_{trainbr_Cd} = 0,089$) és legmagasabb R² értéket tapasztaltuk ($R^2_{WQI} = 0,978$, $R^2_{Cd} = 0,994$). Ez az algoritmus rendkívül hatékony a túllillesztés elkerülésében és a prediktív modellek stabilizálásában (Zhang 2018).

A hálózatban használt aktivációs függvények szintén hatással voltak a modellek teljesítményére (Táblázat 7). Az aktivációs függvények alapvetően azt határozzák meg, hogy egy adott neuron mennyire aktiválódik a bemeneti jelekre. Abban segítenek, hogy a hálózat nemlineáris viselkedést mutasson, ami lehetővé teszi, hogy a neurális hálózat bonyolultabb mintázatok felismerésére és modellezésére is képes legyen. A WQI esetében a „tansig” aktivációs függvény alkalmazásával értük el a legjobb eredményt ($RMSE_{tansig} = 0,164$, $R^2_{tansig} = 0,978$), míg a „radbas” aktivációs függvény általánosságban jobb eredményeket nyújt a Cd és a CCME-WQI mutatók esetében ($RMSE_{radbas_Cd} = 0,085$, $R^2_{radbas_Cd} = 0,995$, $RMSE_{radbas_CCME-WQI} = 0,260$, $R^2_{radbas_CCME-WQI} = 0,875$). A „tribas” függvény mindhárom mutató tekintetében a leggyengébb teljesítményt eredményezte.

A létrehozott neurális háló tekintetében kiemelendő, hogy a neuronok számának optimalizálása, a megfelelő tanító algoritmusok és aktivációs függvények megválasztása alapvető fontosságú a prediktív modellek hatékonyságának maximalizálása érdekében. Tanulmányunk vonatkozásában kijelenthető, hogy különböző vízminőségi mutatókra alkalmazott tanító algoritmusok és aktivációs függvények eltérő hálózati struktúrák esetén bizonyultak a legjobbnak.

Táblázat 6. A vízminőségi modellekben alkalmazott tanító algoritmusok hatása a vizsgált statisztikai mutatókra.

Vízminőségi mutató	Statisztikai mutató	trainlm	trainscg	trainbr
WQI	RMSE	0,305	0,317	0,164
	R ²	0,922	0,916	0,978
Cd	RMSE	0,391	0,334	0,089
	R ²	0,887	0,917	0,994
CCME-WQI	RMSE	0,311	0,309	0,272
	R ²	0,821	0,824	0,863

Táblázat 7. A rejtett réteg aktivációs függvényének hatása a vizsgált statisztikai mutatókra a vízminőségi modellekben.


Vízminőségi mutató	Statisztikai mutató	radbas	tribas	tansig
WQI	RMSE	0,181	0,313	0,164
	R ²	0,973	0,918	0,978
Cd	RMSE	0,085	0,213	0,089
	R ²	0,995	0,966	0,994
CCME-WQI	RMSE	0,260	0,326	0,272
	R ²	0,875	0,804	0,863


3.3. A talajvíz minőségének térbeli alakulása különböző indexek alkalmazásával

Mindhárom alkalmazott vízminőségi index esetében a vízminőség állapotának leírására ugyanazokat a vízkémiai paramétereket használtuk fel az indexértékek kiszámításához és a vízminőségi állapot/szennyezettség fokának meghatározásához. A talajvízkutak minősítését és az egyes vízminősítési kategóriákhoz tartozó kutak számát a 7. ábra szemlélteti. A Súlyozott Vízminőségi Index (WQI) szerint a talajvízkutak 26,47%-a a legrosszabb (*Nagyon rossz vízminőség, Bármilyen használatra alkalmatlan*) kategóriákba kerültek. A talajvízkutak további 41,18%-a esetében gyenge vízminőséget (*Rossz vízminőség*) állapítottunk meg. A vízminőség állapota csupán a minták 29,41%-a esetében volt elfogadható (*Jó vízminőség*), és egyetlen kút esetében volt kiváló.

A Backman et al. (1998) által, a szennyezettség fokának értékelésére kidolgozott Szennyezettségi Index (Cd) szerint a vizsgált talajvízkutak 50%-a az erőteljes szennyezettséget jelző (*Szennyezett, Erősen szennyezett*) kategóriákba került. Továbbá a talajvízkutak 29,41%-a közepesen szennyezettnek tekinthető, és csupán a kutak 20,58%-ában alacsony a szennyezettség foka (*Alacsony szennyezettség*). A Kanadai Környezetvédelmi Tanács Vízminőség Indexe (CCME-WQI), amely a hagyományos WQI továbbfejlesztett változata, a talajvízkutak 41,17%-át szennyezettnek értékelte (*Szennyezett, Erősen szennyezett*), míg a már megfelelő vízminőséget jelző (*Megfelelő, Jó vízminőség*) kategóriák aránya 58,83%.

Mivel nagyszámú minta állt rendelkezésünkre, elkészítettük a vízminőség és a szennyezés mértékének interpolált eloszlástérképeit (8. ábra). A WQI index szerint a vízminőségi állapot a település északi és középső részein általában „Jó” és

**7. ábra.** A vízminőségi kategóriák százalékos megoszlása.



8.ábra. A vízminőségi indexek térbeli alakulása a mintaterületen.

„Kiváló” minőséggel jellemezhető. Ezek a területrészek általában kisebb kiterjedésűek, de jelentősen jobb minőséget mutatnak, mint a település déli és nyugati részei, ahol a vízminőség „Nagyon rossz” vagy „Bármilyen használatra alkalmatlan” kategóriába esik.

Ezzel szemben a Cd index, amely a szennyezettség fokát prezentálja, azt mutatja, hogy a középső és déli településrészek a legnagyobb szennyezettség mértéke. Az északi területeken ebben az esetben is alacsony fokú szennyezettséget találhatunk hasonlóan a WQI index szerinti vízminőségi kategóriákhoz. A település középső részén azonban a szennyezettség foka néhány helyen magas, míg a vízminőség itt is több helyen jó minőségi állapotot jelez, amely rávilágít, hogy a különböző vízminőségi indexek együttes alkalmazása pontosabbá teheti az értékelést.

A CCME-WQI index a településen északi-déli irányú markáns területrésze megfelelő vízminőségi állapotot rajzol ki. Az északi részek itt hasonló képet mutatnak, de a jó minőségű területek száma és kiterjedése kisebb, mint az előző két index esetében. Az északi részekben azonban mindhárom térkép hasonló állapotot mutat, ami utalhat arra, hogy ez a terület valóban jobb vízminőséggel rendelkezik, alacsonyabb szennyezettségi szintekkel. A területi különbség egyik oka elsősorban a WQI eltérő súlyozásából adódik, melynek következtében az indexek érzékenyebben reagálnak egyes vízkémiai paraméterek (pl.: ammónium- és foszfátértékek) változására, mint a Cd. A másik tényező, hogy a WQI kevésbé érzékeny a nitrát értékek változásaira, amelyek nagyobb súlyt kapnak a Cd-ben. További befolyásoló tényező, hogy a Cd nem veszi figyelembe a határérték alatti paramétereket, még akkor sem, ha azok nagyon közel vannak ahhoz (Mester et al. 2020; Balla et al. 2023).

3.4. Térbeli adatok interaktív adatvizualizációja

A 2022-es év mérési és számítási eredményeit felhasználva interaktív vizualizációk formájában szemléltettük a talajvízminőség térbeli alakulását. A csatlakoztatott adatforrás alapján öt irányítópultot (dashboard) és tizennyolc nézetet (view) hoztuk létre, amelyek az alábbiak:

1. Mintaterület irányítópult: A mintaterület elhelyezkedését bemutató ponttérkép egy Google alaptérkép felületén. A monitoring kutakra rámutatva az előugró buborék súgó (tooltip) a monitoring kutak azonosítóját és a koordinátáit jeleníti meg. A nézethez a mintaterületet ábrázoló talajvízszint és domborzati viszonyokat ábrázoló eloszlástérképeket is hozzákapsoltuk.
2. Adatforrás irányítópult: A csatlakoztatott geodatabase attribútum adatait jeleníti meg táblázatos formában.
3. Paraméterek és határértékek a mért talajvízkutakban irányítópult: A vízkémiai paraméterek oszlopdiagramokon történő ábrázolása talajvíz kutanként referenciavonallal ellátva, amelyek az egyes vízkémiai paraméterek szennyezettségi határát jelölik.
4. A vízminőség állapotát és a szennyezettség fokát bemutató irányítópultok: Az irányítópult öt különböző nézet szimultán megjelenítésére alkalmas:
 - a. A talajvízkutak vízminőségi állapotát bemutató ponttérkép,
 - b. összesítő táblázat a vízminőségi/szennyezettségi kategóriák számáról,
 - c. fánk diagram a kategóriák %-os eloszlásáról,
 - d. fatérkép a kategóriák arányairól,
 - e. oszlopdiagram, amely bemutatja az egyes kutak indexértékeit.
5. Térbeli eloszlás irányítópult: A vízkémiai paraméterek és a vízminőségi indexek eloszlástérképeit mutatja be.

Vízminőségi monitoring adatok értékelése Báránodon



9.ábra. A vizualizált geodatabase összefoglaló nézete a WQI index alapján.

A stilizálás minden esetben az adott vízminőségi állapot/szennyezettségi fok térképi színekódjával történt. A térbeli mintázatok felfedezésére kiválasztás alapú interaktív szűrőket (filter) és kiemeléseket (highlight) definiáltunk. A műveletek elvégzése a nézetek automatikus frissítését eredményezik, amelyek dupla kattintással visszaállíthatók az eredeti nézetre. Mivel az adatvizualizáció nem csak az adatok grafikus megjelenítését jelenti, lehetőséget kívántunk biztosítani a felhasználóknak az adatok narratív formában történő bemutatásra és szabadon elérhetőségére, ezért az interaktív irányítópultok felhasználásával egy story-t hoztunk létre, amelyet megosztottuk a Tableau felhő alapú platformján (Tableau Public, 2024) (9. ábra).

4. Összefoglalás

Tanulmányunkban egy alföldi településen, Bárádon, 34 ásott talajvízkút bevonásával értékeltük a talajvíz minőségét a 2022-es év mintavétele alapján. A vízminőség állapotát három vízminőségi mutató (Súlyozott Vízminőség Index (WQI), Szennyezettségi Index (Cd), Kanadai Környezetvédelmi Tanács Vízminőség Indexe (CCME-WQI)) segítségével, továbbá térinformatikai (GIS), adatvizualizációs rendszerek és mesterséges intelligencia (MI) felhasználásával értékeltük. A talajvíz minőségének értékelése során 8 vízkémiai paramétert használtunk fel (pH, EC, NH_4^+ , NO_2^- , NO_3^- , PO_4^{3-} , KOI_{ps} , Na^+). Interpolált térképek alapján megállapítottuk, hogy magas a szervesetlen nitrogénformák és szervesanyag-koncentrációk értéke, mely azt indikálja, hogy a területen felhalmozódott szennyezőanyagok jelen vannak, amelyet mindhárom vízminőségi mutató eltérő mértékben és területi konfigurációban igazolt. A létrehozott geoadatbázis adatainak interaktív vizualizációja és felhő alapú megosztását Tableau Public segítségével tettünk szabadon elérhetővé. Ezzel kapcsolatban kiemelendő, hogy az adatvizualizáció különösen praktikus eszköz a térbeli monitoring adatok utófeldolgozására, mivel alkalmas az információk intuitív, vizuális formában történő megjelenítésére és a térbeli mintázatok és összefüggések felfedezésére. Előrecsatolt neurális háló (Feed-Forward Neural Network, FFNN) létrehozásával továbbá kísérletet tettünk a talajvízminőség térbeli előrejelzésére, a vízkémiai paraméterek alapján háromféle vízminőségi mutató állapotának becslésével. Az előrecsatolt neurális hálózattal, ha megfelelően reprezentatív adatbázison történik a tanítás, képes implicit módon megtanulni az összefüggéseket. Ez lehetővé teszi, hogy akár néhány paraméter alapján is megbízható előrejelzést adjon. Emellett egy előrejelző modell – meteorológiai és hidrológiai adatokkal kiegészítve – időbeli prognózt is szolgáltat, míg a determinisztikus képletek csupán a mérés pillanatára érvényesek. Így a gépi tanulás hozzáadott értéke a gyorsaság, a hiányos adatok melletti robusztus működés és a jövőbeni trendek becslésének lehetősége. Az eredmények azt mutatták, hogy az alkalmazott tanító algoritmusok és aktivációs függvények eltérő hálózati struktúrák esetén bizonyultak a legjobbnak. A WQI és Cd mutatók legpontosabb előrejelzését a bayesi szabályozáson alapuló algoritmus (trainbr) adta, amely a legkisebb átlagos

négyzetes hibát ($\text{RMSE}_{\text{WQI}} = 0,164$ $\text{RMSE}_{\text{Cd}} = 0,089$) és a legmagasabb determinációs együtthatót ($R^2_{\text{WQI}} = 0,978$ $R^2_{\text{Cd}} = 0,994$) érte el. A CCME-WQI mutató esetében a modellek pontossága alacsonyabb volt ($\text{RMSE} = 0,272$, $R^2 = 0,863$), ami arra utal, hogy ezt a mutatót nehezebben becsülhető. A bayesi szabályozás alkalmazása előnyösebb lehet, mivel képes mérsékelni a túlillesztésből eredő torzításokat. Az aktivációs függvények és neuronok optimalizálása szintén kritikus szerepet játszik a modell teljesítményének javításában. Azonban a kutatásban felhasznált EC, NH_4^+ , NO_3^- paraméterek átlagértékeinek határérték túllépése torzíthatja a neurális háló tanulását miközben a többi vízkémiai paraméter súlya alulmarad. Ennek következtében a felépített modellek teljesítménye jelenleg korlátozott megbízhatósággal értékelhető. Korlátként kiemelendő a rendelkezésre álló minták alacsony elemszáma, amely indokoltá teszi a modellek validációjának folytatását a következő években gyűjtött adatok bevonásával. A modell megbízhatóságának növelése érdekében célszerű nagyobb mennyiségű tanító adat alkalmazása, illetve a teljesítmény ellenőrzése olyan adatokon, amelyek ugyanazon mintavételi helyről, de eltérő időpontban, vagy más, hasonló környezeti adottságokkal rendelkező területről származnak. A jövőbeli kutatások során az idősoros adatok bevonása, a mintaszám növelése, valamint a tanító- és tesztadatok irányított kijelölése és térbeli optimalizációja együttesen jelentős mértékben hozzájárulhat a térbeli becslések pontosságának javításához.

Köszönetnyilvánítás

Megvalósult a DE Tudományos Kutatási Alap (DETKA) Áthidaló Pályázat támogatásával.

Irodalomjegyzék

- 2000/60/EC. 2000. *Directive 2000/60/EC of the European Parliament and of the Council establishing a framework for Community action in the field of water policy*. OJ L327, 22.12.2000.
- Alrowais, R. – Abdeldaiem, M. M. – Li, R. – Maklad, M. A. – Helmi, A. M. –Nasef B. M. – Said. N. 2023. Groundwater Quality Assessment for Drinking and Irrigation Purposes at Al-Jouf Area in KSA Using Artificial Neural Network, GIS, and Multivariate Statistical Techniques. *Water* 15(16), 2982. doi:10.3390/w15162982.
- Aulakh, M. S. – Khurana, M. P. S. – Singh, D. 2009. Water Pollution Related to Agricultural, Industrial, and Urban Activities, and its Effects on the Food Chain: Case Studies from Punjab. *Journal of New Seeds* 10(2), 112–37. doi:10.1080/15228860902929620.
- Backman, B. – Bodiš, D. – Lahermo, P. – Rapant, S. – Tarvainen, T. 1998. Application of a groundwater contamination index in Finland and Slovakia. *Environmental geology* 36, 55–64. doi: https://doi.org/10.1007/s002540050320
- Balla, D. – Kiss, E. – Zichar, M. – Mester, T. 2023a. Evaluation of Groundwater Quality in the Rural Environment Using Geostatistical Analysis and WebGIS Methods in a Hungarian Settlement, Báránd. *Environmental Science and Pollution Research*. doi:10.1007/s11356-023-28627-1.

- Balla, D. – Kiss, E. – Zichar, M. – Mester, T. 2023b. Vízminőségi monitoringadatok feldolgozása és publikálása WebGIS-támogatással. *Geodézia és Kartográfia*. 75(6), 4-9. doi:10.30921/GK.75.2023.6.1.
- Balla, D. – Kiss, E. – Zichar, M. – Mester, T. 2024. Ásott talajvízkutak vízminőségének tér- és időbeli változásainak értékelése egy alföldi településen a CCME WQI vízminőségi mutató alkalmazásával. *Tájékológiai Lapok* 22(1), 3–24. doi:10.56617/tl.4964.
- Balla, D. – Zichar, M. – Kiss, E. – Szabó, Gy. – Mester, T. 2022. Possibilities for Assessment and Geovisualization of Spatial and Temporal Water Quality Data Using a WebGIS Application. *ISPRS International Journal of Geo-Information* 11(2), 108. doi: 10.3390/ijgi11020108.
- Bano, H. – Rather, R.A. – Malik, S. – Bhat, M. A. – Khan, A. H. – Américo-Pinheiro, J. H. P. – Mir, I. A. 2022. Effect of Seasonal Variation on Pollution Load of Water of Hokersar Wetland: a Case Study of Queen Wetland of Kashmir, J&K, India. *Water Air Soil Pollut* 233, 518. doi:10.1007/s11270-022-05988-w.
- Brown, R. M. – McClelland, N. I. – Deininger, R. A. – O'Connor, M. F. 1972. A Water Quality Index – Crashing the Psychological Barrier. In: Thomas, W.A. (eds) *Indicators of Environmental Quality. Environmental Science Research, vol 1*. Springer, Boston, MA. doi:10.1007/978-1-4684-2856-8_15.
- Cude, C. G. 2001. Oregon water quality index a tool for evaluating water quality management effectiveness. *JAWRA Journal of the American Water Resources Association* 37(1), 125–37. doi: 10.1111/j.1752-1688.2001.tb05480.x
- Csábrági, A. – Molnár, S. – Tanos, P. – Kovács, J. – Szabó, I. – Molnár, M. 2019. Neurális hálózatok alkalmazása hazai vízminőségi vizsgálatok során. *Mezőgazdasági Technika* 60:2–5.
- Dandge, K. P. – S. S. Patil. 2021. Spatial Distribution of Ground Water Quality Index Using Remote Sensing and GIS Techniques. *Applied Water Science* 12(1):7. doi:10.1007/s13201-021-01546-7.
- Dunnette, D. A. 1979. A geographically variable water quality index used in Oregon. *Journal (Water Pollution Control Federation)* 51(1), 53–61.
- Habeeb, R. – Gupta, Y. – Chinwan, H. – Barker, E. 2019. Assessing Demographic and Water Sensitivities Arising Due to Urban Water Insecurity in Haldwani, Uttarakhand (India): A GIS-Based Spatial Analysis. *Journal of Geovisualization and Spatial Analysis* 3(2):8. doi:10.1007/s41651-019-0031-4.
- Horton, R. K. 1965. An Index Number System for Rating Water Quality. *Journal of the Water Pollution Control Federation*, 37, 300-306.
- HS 448-18. 2009. Hungarian Standard Water Quality. Part 18: Drinking Water Analysis. Determination of Orthophosphate and Total Phosphorus Using Spectrophotometric Method. Hungarian Standards Institution (MSZT): Budapest, Hungary, 2009.
- HS 1484-13. 2009. Hungarian Standard Water Quality. Part 12: Determination of Nitrate and Nitrite. Content by Spectrophotometric Method. Hungarian Standards Institution (MSZT): Budapest, Hungary, 2009.
- HS ISO 7150-1. 1992. Hungarian Standard Water quality. Determination of ammonium. Part 1: Manual spectrophotometric method. Hungarian Standards Institution (MSZT): Budapest, Hungary, 1992.
- Jha, M. K. – Shekhar, A. – Jenifer, M. A. 2020. Assessing groundwater quality for drinking water supply using hybrid fuzzy-GIS-based water quality index. *Water Research* 179:115867. doi:10.1016/j.watres.2020.115867.
- Keraita, B. – Drechsel, P. – Amoah, P. 2003. Influence of Urban Wastewater on Stream Water Quality and Agriculture in and around Kumasi, Ghana. *Environment and Urbanization* 15(2):171–78. doi:10.1177/095624780301500207.
- Kerényi, A. – McIntosh, R. W. 2020. Sustainable Development in Changing Complex Earth Systems. *Sustainable Development Goals Series*, Berlin/Heidelberg, Germany: Springer, 2020. doi:10.1007/978-3-030-21645-0.
- Kirschner, A. K. – Schachner-Groehs, I. – Kavka, G. – Hoedl, E. – Kovacs, A. – Farnleitner, A. H. 2024. Long-Term Impact of Basin-Wide Wastewater Management on Faecal Pollution Levels along the Entire Danube River. *Environmental Science and Pollution Research* 31(33):45697–710. doi:10.1007/s11356-024-34190-0.
- Liou, S. M. – Lo, S. L. – Wang, S. H. 2004. A Generalized Water Quality Index for Taiwan. *Environmental Monitoring and Assessment* 96(1):35–52. doi:10.1023/B:EMAS.0000031715.83752.a1.
- Livia, S. – María, M. S. – Marco, B. – Marco, R. 2020. Assessment of Wastewater Reuse Potential for Irrigation in Rural Semi-Arid Areas: The Case Study of Punitaqui, Chile. *Clean Technologies and Environmental Policy* 22(6):1325–38. doi:10.1007/s10098-020-01874-3.
- Luh, J. – Baum, R. – Bartram, J. 2013. Equity in water and sanitation: Developing an index to measure progressive realization of the human right. *International Journal of Hygiene and Environmental Health* 216(6):662–71. doi:10.1016/j.ijheh.2012.12.007.
- Lumb, A. – Halliwell, D. – Sharma, T. 2006. Application of CCME Water Quality Index to Monitor Water Quality: A Case Study of the Mackenzie River Basin, Canada. *Environmental Monitoring and Assessment* 113(1):411–29. doi:10.1007/s10661-005-9092-6.
- Mester, T. – Balla, D. – Szabó, Gy. 2020. Assessment of Groundwater Quality Changes in the Rural Environment of the Hungarian Great Plain Based on Selected Water Quality Indicators. *Water, Air, & Soil Pollution* 231(11):536. doi:10.1007/s11270-020-04910-6.
- Mester, T. – Szabó, G. – Bessenyei, É. – Karancsi, G. – Barkóczi, N. – Balla, D. 2017. The Effects of Uninsulated Sewage Tanks on Groundwater. A Case Study in an Eastern Hungarian Settlement. *Journal of Water and Land Development* 33(1):123–29. doi:10.1515/jwld-2017-0027.
- Mustafa, H. M. – Mustapha, A. – Hayder, G. – Salisu, A. 2021. *Applications of IoT and artificial intelligence in water quality monitoring and prediction: A review*. 6th International Conference on Inventive Computation Technologies (ICICT), Coimbatore, India, 2021, pp. 968-975. doi: 10.1109/ICICT50816.2021.9358675IEEE.
- Prohászka V, J. – Tormán Kovács, E. – Grósz, J. – Waltner, I. 2022. Az ásott kutak vízminősége két ökofaluban: Visnyeséplakon és

Gyűrűfű. Tájékológiai Lapok 20(2):41–58.
doi:10.56617/tl.3449.

Rutkowski, T. – Raschid-Sally, L. – Buechler, S. 2007. Wastewater irrigation in the developing world—Two case studies from the Kathmandu Valley in Nepal. *Agricultural Water Management* 88(1):83–91. doi:10.1016/j.agwat.2006.08.012.

Saravani, M. J. – Saadatpour, M. – Shahvaran, A. R. 2024. A web GIS based integrated water resources assessment tool for Javeh Reservoir. *Expert Systems with Applications* 252:124198. doi:10.1016/j.eswa.2024.124198.

Sargaonkar, A. – Deshpande, V. 2003. Development of an Overall Index of Pollution for Surface Water Based on a General Classification Scheme in Indian Context. *Environmental Monitoring and Assessment* 89(1):43–67. doi:10.1023/A:1025886025137.

Şener, Ş. – Şener, E. – Davraz, A. 2017. Evaluation of water quality using water quality index (WQI) method and GIS in Aksu River (SW-Turkey). *Science of The Total Environment* 584–585:131–44. doi:10.1016/j.scitotenv.2017.01.102.

Simsek, C. – Gunduz, O. 2007. IWQ Index: A GIS-Integrated Technique to Assess Irrigation Water Quality. *Environmental Monitoring and Assessment* 128(1):277–300. doi:10.1007/s10661-006-9312-8.

Smith, D. G. 1990. A better water quality indexing system for rivers and streams. *Water Research* 24(10):1237–44. doi:10.1016/0043-1354(90)90047-A.

Golden Software, LLC. 2012. Surfer® (verzió 12.0) [Számítógépes szoftver]. Golden Software, LLC. Link: <https://www.goldensoftware.com/products/surfer>. (Utolsó elérés: 2025. szeptember 3.)

Tableau Public. 2025. Vízminőségi monitoring adatok értékelése Bárádon. Link: https://public.tableau.com/app/profile/d.niel.balla/viz/Brnd_

Water_Quality_2022_magyar/BrndWaterQuality?publish=yes, (Utolsó elérés: 2025. szeptember 3.)

Taşan, S. 2022. Estimation of Groundwater Quality Using an Integration of Water Quality Index, Artificial Intelligence Methods and GIS: Case Study, Central Mediterranean Region of Turkey. *Applied Water Science* 13(1):15. doi:10.1007/s13201-022-01810-4.

The MathWorks, Inc. 2024. MATLAB and Simulink [Számítógépes szoftver]. The MathWorks, Inc. Link: <https://www.mathworks.com>. (Utolsó elérés: 2025. szeptember 3.)

Tytła, M. 2019. Assessment of Heavy Metal Pollution and Potential Ecological Risk in Sewage Sludge from Municipal Wastewater Treatment Plant Located in the Most Industrialized Region in Poland—Case Study. *International Journal of Environmental Research and Public Health* 16(13):2430. doi:10.3390/ijerph16132430.

Uddin, M. G. – Nash, S. – Olbert, A. I. 2021. A Review of Water Quality Index Models and Their Use for Assessing Surface Water Quality. *Ecological Indicators* 122:107218. doi:10.1016/j.ecolind.2020.107218.

Vadas, A. – Ferenczi, L. 2023. Small urban waters and environmental pressure before industrialization: The case of Hungary. *Journal of Historical Geography* 82:98–109. doi:10.1016/j.jhg.2023.09.008.

Zhang, Z. 2018. *Artificial Neural Network*. In Zhang, Z. (szerk.): *Multivariate Time Series Analysis in Climate and Environmental Research*. Springer, Cham, pp. 1–35. doi: 10.1007/978-3-319-67340-0_1.

Zolfaghary, P. – Zakerinia, M. – Kazemi, H. 2021. A model for the use of urban treated wastewater in agriculture using multiple criteria decision making (MCDM) and geographic information system (GIS). *Agricultural Water Management* 243:106490. doi:10.1016/j.agwat.2020.106490.



e-Szignó
Földmérőknek!

e-szigno.hu/foldmeroknek