

Kirovne Rácz Réka,<sup>1</sup> Scholtz Emánuel<sup>2</sup>

# A mesterséges intelligencia és gépi tanulás algoritmusainak alkalmazása a hidrológiai katasztrófák elleni védekezésben

## Application of Artificial Intelligence and Machine Learning Algorithms in Protection Against Hydrological Disasters

### Absztrakt

Az elmúlt évtizedekben jelentősen megnőtt a katasztrófák száma, mind a természeti, mind az ember által előidézett katasztrófáké, hazai és nemzetközi viszonylatban is, ezért az előrejelző rendszerek fontossága felértékelődött. Az informatika és a számítástechnika, ezen belül a mesterséges intelligencia, gépi tanulás ugrásszerű fejlődésen ment keresztül az elmúlt időkben, így lehetővé téve, relatív kevés erőforrással is, nagyon pontos, magas általánosító képességgel rendelkező prediktív modellek megalkotását. A klímaváltozás miatt az időjárás egyre kiszámíthatatlanabbá válik, egyre gyakoribbak a szélsőséges időjárási jelenségek. Ez komoly nehézségek elé állítja az országokat, beleértve Magyarországot is. A hidrológiai katasztrófák hazánkban, a vízrajzi és a domborzati adottságokból adódóan, mindig jellemző katasztrófakockázatot jelentettek. Megemlíthetjük az elmúlt évtizedekből például a 2006-os dunai és tiszai árvizet, a 2013-as dunai árvizet, a 2024-es nagy dunai árhullámot, a 2025-ös áradást a Kaposon, a 2013-as zempléni, a 2020-as dél-zalai villámárvizet, a 2012-es, a 2022-es rendkívüli aszályokat, a 2021-es csapadékhiányt, a 2025-ös aszályos

<sup>1</sup> Egyetemi adjunktus, Nemzeti Közzolgálati Egyetem Rendészettudományi Kar Katasztrófavédelmi Intézet Katasztrófavédelmi Művelési Tanszék, e-mail: [kirovne.racz.reka@uni-nke.hu](mailto:kirovne.racz.reka@uni-nke.hu)

<sup>2</sup> Doktori hallgató, Nemzeti Közzolgálati Egyetem Rendészettudományi Doktori Iskola, e-mail: [scholtz.emanuel99@gmail.com](mailto:scholtz.emanuel99@gmail.com)

*időjárást, a 2013-as hókatasztrófát. 2024-ben az előrejelző rendszereknek sikerült időben érzékelni a veszélyt, a rendkívüli összefogásnak és a szakemberek fáradhatatlan munkájának köszönhetően sikerült hatékonyan védekezni az árvíz ellen. Tehát fontos az időbeni cselekvés, új, még pontosabb előrejelző, riasztó rendszerek és védelmi mechanizmusok kialakítása, a lakosság felkészítése. Ebben a cikkben összefoglaljuk a hazai és a nemzetközi kutatásokban használt algoritmusokat és a hazánkban működő előrejelző rendszereket.*

*Kulcsszavak: mesterséges intelligencia, gépi tanulás, katasztrófavédelem, árvíz, árvízvédelem, településlöntés, villámárvíz, belvíz, aszály, informatika, neurális hálók, support vector machine, decision tree, random forest, fuzzy logic*

## **Abstract**

*In the last decades, the number of disasters has increased significantly, both natural and man-made, at the national and international level. As a result, the importance of forecasting systems has greatly increased. Information technology and computer science, including artificial intelligence and machine learning, have undergone immense development in recent years, hence making it possible to create predictive models with very high accuracy and great generalisation capability, even having relatively few resources available. Due to climate change, the weather is becoming increasingly unpredictable, with extreme weather becoming more frequent. This is a serious challenge for countries, including Hungary. Unfortunately, hydrological disasters have become quite regular in our country. For example, we can mention the Danube and Tisza floods of 2006, the Danube flood of 2013, the major flood hazard situation on the Danube in 2024, the 2025 flood on the Kapos River, the 2013 Zemplén flash flood, the 2020 South Zala flash flood, the very severe droughts of 2012 and 2022, the moderately severe drought of 2021, the dry weather conditions of 2025, and the snow disaster of 2013. In 2024, forecasting systems successfully detected the danger in time, and thanks to extraordinary cooperation and the tireless work of experts, the country managed to defend effectively against the flood. Consequently, taking action in time is crucial, along with the development of new, even more accurate forecasting and warning systems, as well as defence mechanisms and population preparedness. In this article, I present the algorithms used in domestic and international research, as well as the forecasting systems operating in Hungary.*

*Keywords: artificial intelligence, machine learning, disaster management, flood, flood protection, urban flooding, flash flood, inland flooding, drought, information technology, neural networks, support vector machine, decision tree, random forest, fuzzy logic*

## **Bevezetés**

A mesterséges intelligencia (MI) már nem csupán az adatok alapján tanuló és fejlődő algoritmusok összessége. Egyre inkább képes az emberi megértés, tanulás és problémamegoldás szimulálására, valamint az emberi képességek bizonyos területeinek

leképezésére és hatékonyságának javítására.<sup>3</sup> Ezek a rendszerek meg tudják tanulni az adatokban rejlő mintázatokat, és olyan összefüggéseket is felismernek, amelyeket emberi szemmel csak nagyon nehezen vagy egyáltalán nem lehet észrevenni. Az ilyen rendszereket három kategóriába sorolhatjuk. Az első kategóriába a sekély mesterséges intelligenciával (*artificial narrow intelligence*) bíró rendszerek tartoznak, ezek létrehozása és működtetése olcsó és egy adott feladat témakörben remekül teljesítenek. A második kategóriába az általános célú mesterségesintelligencia-rendszerek (*artificial general intelligence*) tartoznak, megalkotásuk és működtetésük már jóval költségesebb, ilyen rendszereket általában a nagy cégek fejlesztnek. A harmadik kategória a mesterséges szuperintelligencia (*artificial superintelligence*), amely jelenleg még nem létezik, csupán elképzelés, és minden területen felülmúlná az emberi intelligenciát. A mesterségesintelligencia-algoritmusok nagy hátránya, hogy nehéz átlátni őket, sok esetben fekete dobozra hasonlítanak, ezért hibás működés esetén nehéz megtalálni a hiba konkrét okát. A mesterségesintelligencia-algoritmusok pontossága nem mindig tökéletes, ezért kritikus helyzetekben, ahol mások élete múlhat a helyes működésen, különös figyelmet igényelnek. Ilyenkor fontos a megfelelő kockázatkezelés alkalmazása, és a többforrású döntéstámogatás, hogy a rendszer megbízható legyen.<sup>4</sup>

Az árvíz-, belvív-, villámárvíz- és aszály-előrejelző rendszerek nagy része jelenleg fizikai, hidrológiai modelleket használ, de az elmúlt huszonöt évben több mint 1000 cikk íródott gépi tanulás és mesterséges intelligencia által támogatott árvíz-, belvív- és villámárvíz-megelőzésről, ezen katasztrófák okozta kár minimalizálásáról, esetleges helyreállítási munkálatokról.<sup>5</sup> Több mint 190 tudományos cikk készült gépi tanulás vagy mesterséges intelligencia által támogatott aszály-előrejelzésről, kárminimalizálásról. A kiadott cikkek mennyisége alapján nyilvánvaló, hogy ez jelenleg fontos kutatási terület.<sup>6</sup> A kutatások jelentős része Kínában, Indiában, Ausztráliában, Iránban, az Egyesült Királyságban és az Amerikai Egyesült Államokban történt. 2010-ig évente csak korlátozott számban jelentek meg publikációk. 2010 és 2015 között jelentősen megnőtt a kiadott cikkek száma. 2015 után a gépi tanulás és mesterséges intelligencia területén történt kutatások és fejlesztések felgyorsultak, ez részben a nagyobb teljesítményű, megfizethető videókártyák elterjedésének köszönhető, így évente már kifejezetten nagyszámú, akár több száz, tanulmány látott napvilágot.<sup>7</sup>

Az AGH University of Science and Technology kutatói, Julia Buszta, Katarzyna Wójcik, Krystian Kozioł és Kamil Maciuk, valamint a Federal University of Paraíba kutatója, Celso Augusto Guimarães Santos az elmúlt 60 év természeti katasztrófáinak előfordulási gyakoriságát térképezték fel, és előrejelzéseket készítettek a következő évekre. Ők is megállapították, hogy mind a szárazságok, földrengések, extrém hőmérsékletek, mind a földcsuszamlások, viharok, árvizek gyakoribbak. Szerintük Európa helyzete jobb Amerika vagy Kína helyzeténél, mivel Európában ritkábbak a természeti katasztrófák. Julia Buszta és társai szerint az elkövetkező időszakban a természeti katasztrófák előfordulásának

<sup>3</sup> Magyarország Mesterséges Intelligencia Stratégiája 2025–2030 2025.

<sup>4</sup> AYYADEVARA 2018.

<sup>5</sup> OpenAlex lekérdezés.

<sup>6</sup> BUSZTA et al. 2023.

<sup>7</sup> TAN et al. 2021; MOSAVI-OZTURK-CHAU 2018; LU-HUANG-WU 2023.

gyakorisága növekedni fog.<sup>8</sup> Ezért kulcsfontosságú, hogy a lehető legtöbb ember részt vegyen a katasztrófavédelmi feladatokban: legyen szó a katasztrófa megelőzéséről, felkészülésről, beavatkozásról, a károk kialakulása kockázatának minimalizálásáról, helyreállítási, újjáépítési munkálatokról. Kiemelték továbbá, hogy nagyon fontos, hogy ezeket a feladatokat minél többen saját felelősségüknek, kötelességüknek érezzék. Lényeges, hogy az előrejelző rendszerek által adott információkat gyorsan, hatékonyan, időben, pánikkeltés nélkül a lehető legtöbb emberhez könnyen el lehessen juttatni.

## Kutatási módszerek

A tanulmány módszertanának alapjául az irodalomkutatás szolgált, amely arra irányult, hogy milyen lehetőségeket kínál a mesterséges intelligencia és gépi tanulás a hidrológiai katasztrófák előrejelzésének fejlesztésében. Ennek érdekében figyelmünket a hazai és nemzetközi tudományos eredmények tanulmányozására, összehasonlítására és a hazai rendszerek bemutatására irányítottuk. A témánk szempontjából jelentős szakirodalom feltárásához több, egymást kiegészítő adatbázist használtunk, köztük az MTMT-t, a Google Scholar-t, a Scopus és Web of Science rendszereket, az IEEE Xplore és SpringerLink felületeket, a ScienceDirectet, ResearchGate-et, az OpenAlex bibliográfiai rendszerét, valamint a hazai szakmai folyóiratokat, például a *Hidrológiai Közlönyt*, a *Földrajzi Közleményeket*, a *HydroInform* kiadványait és a Nemzeti Köszolgáltatási Egyetem weboldalán elérhető folyóiratokat. Kereséseinket magyar és angol nyelven végeztük.

A kereső kulcsszavak összeállításakor szem előtt tartottuk mind a hidrológiai katasztrófák sajátos témaköreit, mind a mesterséges intelligencia területét. A keresések során a következő főbb kulcsszavakat használtuk a hidrológiára vonatkozóan: árvíz-előrejelzés (*flood prediction*), árvízmodellezés (*flood modelling*), villámárvíz-előrejelzés (*flash flood prediction*), településselöntés (*urban flood modelling*), belvíz-előrejelzés (*inland flood forecasting*), vízhozam-előrejelzés (*streamflow forecasting*), árhullámlefolys (*hydrograph forecasting*), csapadék-előrejelzés (*precipitation prediction*), aszály-előrejelzés (*drought prediction*), aszályindex (*drought index*), hidrológiai kockázatértékelés (*hydrological risk assessment*). A keresési tartományt nem korlátoztuk kizárólag a hidrológiai katasztrófák előrejelzésére, kiterjesztettük a fókusz a mesterséges intelligencia tágabb katasztrófavédelmi szerepének vizsgálatára is, olyan kulcsszavakkal, mint mesterséges intelligencia a katasztrófavédelemben (*artificial intelligence in disaster management*), gépi tanulás a katasztrófavédelemben (*machine learning in disaster management*), kockázatbecslés MI-vel (*AI-based risk assessment*), korai előrejelző rendszerek (*early warning systems*), veszélyazonosítás (*hazard identification*), extrém események előrejelzése (*extreme event prediction*). A mesterséges intelligencia és gépi tanulás módszertani oldalának tanulmányozásához technikai kulcsszavakat is alkalmaztunk: gépi tanulás (*machine learning*), mélytanulás (*deep learning*), neurális háló (*neural network*), konvolúciós neurális háló (*convolutional neural network, CNN*), rekurrens neurális háló (*recurrent neural network, RNN*), hosszú-rövid távú

<sup>8</sup> BUSZTA et al. 2023.

memóriaháló (*long short-term memory*, LSTM), döntési fa (*decision tree*), véletlen erdő (*random forest*), *gradient boosting*, extrém gradiensnövelés (XGBoost), kategorikus boosting (CatBoost), támasztóvektor-gép (*support vector machine*, SVM), többváltozós regresszió (*multiple linear regression*, MLR), autoregresszív és idősormodellek (AR, ARIMA), fuzzy logika (*fuzzy logic*), genetikus algoritmus (*genetic algorithm*, GA), részecskeraj-optimalizáció (*particle swarm optimisation*, PSO). Munkánkhoz átfogó szakirodalmi áttekintéseket (*literature review*, *systematic review*) is használtunk, hogy tágabb összefüggésben szemlélhessük a kutatási irányokat és a módszertani változásokat. Mivel nagy figyelmet szenteltünk a magyar nyelvű szakirodalom kutatásának, az MTMT-ben sok keresést végeztünk magyar kulcsszavakkal. Így átláthattuk a hazai kutatási irányokat, modellezési törekvéseket és intézményi gyakorlatokat, illetve a magyar eredményeket a nemzetközi kontextusban értékelhettük.

A kiválasztott publikációk többsége a 2016–2025 közötti időszakból származik, amikor az MI rohamléptekkel fejlődött. Főleg olyan kutatásokat kerestünk, amelyek a vízügyi katasztrófák – árvizek, belvizek, hirtelen áradások, települések elöntése, aszály – előrejelzésével vagy a kockázat felmérésével foglalkoznak. Ezek a tanulmányok MI-algoritmusokat alkalmaznak, vagy ötvözik a hagyományos vízrajzi modelleket és az MI-t. Azokra a publikációkra építettünk, amelyek tudományosan megalapozottak, részleteikben kidolgozottak és logikusak, átláthatóan ismertetik az adatokat és a módszereket, leírják a kutatás menetét, és konkrét, számokkal alátámasztott eredményeket mutatnak be (például RMSE, MAE,  $R^2$ , AUC, NSE). Figyelmen kívül hagytuk azokat a tanulmányokat, amelyek nem felelnek meg a tudományos követelményeknek vagy hiányos a módszertani leírásuk.

## A jelenlegi predikciós rendszerek hazánkban

Magyarországon a szélsőséges időjárási események mellett a leggyakrabban előforduló természeti katasztrófák az árvizek, villámárvizek és aszályok, ezért ezek előrejelzése rendkívül fontos, mivel így könnyebben megtehető a szükséges felkészülési intézkedések.

Az OVF (Országos Vízügyi Főigazgatóság) és az OVSZ (Országos Vízelző Szolgálat) működtet árvíz- és belvív-előrejelző rendszereket. Előrejelzési információikat nyíltan és ingyenesen elérhetővé teszik az interneten mindenki számára.<sup>9</sup>

A HungaroMet is működtet országos veszélyjelző rendszert, amely kiterjed nagy mennyiségű esőre, zivatarokra, extrém hidegre és melegre, hófúvásra, erős szélre, tartós ködre. Három előrejelzési fokozat van: sárga, narancssárga, piros. A sárga potenciális veszélyt jelent. A narancssárga komolyabb veszélyre figyelmeztet, amikor már veszélyt jelent az emberek testi épségére és anyagi károk is előfordulhatnak, a piros figyelmeztetést komoly veszély esetén, ritkán adják ki, amikor már emberek élete is veszélyben lehet, és nagyon komoly káresemények is előfordulhatnak.<sup>10</sup>

<sup>9</sup> Lásd az Országos Vízügyi Főigazgatóság weblapját: [www.vizugy.hu/](http://www.vizugy.hu/)

<sup>10</sup> HungaroMet vészjelző rendszer.

Az EFAS (European Flood Awareness System) egy árvíz-előrejelző rendszer, amely jelenleg használatban van Magyarországon is, nagyrészt hidrológiai modellekre támaszkodik, a CEMS (Copernicus Emergency Management Service) keretén belül működik, és akár tíznapos hidrológiai predikcióra is képes. Célja a felkészülés elősegítése, és főleg határokon átívelő folyókra koncentrálni.

Az Országos Vízügyi Főigazgatóság (OVF) működtet aszálymonitoring-rendszert, amely nyíltan és ingyenesen elérhető mindenki számára. Mérőállomás-hálózat segítségével gyűjtik a csapadék-, páratartalom-, talajnedvesség-, talajhőmérséklet-adatokat és a Global Forecast System (GFS), a European Centre for Medium-Range Weather Forecasts (ECMWF) modellek segítségével előrejelzéseket végeznek.<sup>11</sup>

Az Alsó-Tisza-vidéki Vízügyi Igazgatóság (ATIVIZIG) is foglalkozik árvíz-előrejelzéssel, kifejlesztettek egy LSTM-modellt, amely hétnapos predikcióra képes. A Pálfi-féle aszályindexet (PAI) a 80-as években fejlesztették ki, egyszerű mutató, amely a csapadék-hőmérséklet arányon alapul. Később ennek a továbbfejlesztéséből jött létre a Pálfi Drought Index (PaDI). A Hungarian Drought Indexet (HDI) 2015–2016-ban fejlesztették ki, amely napi időléptékű, kevés bemenetet igénylő, moduláris index, amely objektíven írja le a vízhiány mértékét, figyelembe véve a talajnedvességet és a meteorológiai viszonyokat. Az index kiszámítása három szinten történik, alapul véve, hogy van-e talajnedvesség-adat. Az első szint, a meteorológiai alapindex ( $HDI_0$ ), nem évszakfüggő, a napi középhőmérsékletet és csapadékmennyiséget használjuk fel, víztartalmat becsülünk a meglévő időszak adataiból. Átlagos időjárás esetén az érték 1 körül lesz, csapadékosabb, hűvösebb időjárás esetén 1 alatt, aszály esetén pedig 1 fölött. Második szint a párolgási hiányt és stressztényezőt is figyelembe vevő index ( $HDI_5$ ), amelynek az alapparaméterei megegyeznek a  $HDI_0$ -val, de a párolgási veszteség teljes mértékben realizálódik, 1,333 alatt nincs vízhiány, 1,333 és 1,5 között enyhe vízhiány, 1,5 és 2,5 között közepes vízhiány, 2 és 3 között erős vízhiány, 3 felett rendkívüli vízhiány van. A harmadik szint a talajnedvességgel súlyozott változat.<sup>12</sup>

A HungaroMet is foglalkozik aszálymonitoringgal, és ezek az információk az Agrometeorológiai menüpontban az Aszály információkra kattintva érhetőek el.<sup>13</sup> Az intézet a standardizált csapadékindexet (*standardised precipitation index*, SPI) használja, valamint több különböző műholdas szárazság- és vegetációs indexet, mint például a normalizált differenciált vegetációs indexet (*normalised difference vegetation index*, NDVI), a normalizált differenciált aszályindexet (*normalised difference drought index*, NDDI), a kibővített vegetációs indexet (*enhanced vegetation index*, EVI) és a vegetációs kondícióindexet (*vegetation condition index*, VCI).<sup>14</sup>

Az Alsó-Tisza-vidéki Vízügyi Igazgatóság szintén részt vesz az aszálymonitorozásban, mérőállomásokat üzemeltetnek, fontos szerepet játszottak a  $HDI_5$  index kifejlesztésében.<sup>15</sup>

Az elmúlt 20 évben Magyarországon fejlesztések voltak árvízvédelem terén: az árvízvédelmi töltésrendszereket korszerűsítették és kibővítették, és nagy hangsúlyt

<sup>11</sup> Lásd: <https://aszalymonitoring.vizugy.hu/> és <https://aszalymonitoring.vizugy.hu/index.php?view=info>

<sup>12</sup> FIALA et al. 2018; és <https://aszalymonitoring.vizugy.hu/index.php?view=info>

<sup>13</sup> Lásd: [www.met.hu/idojaras/agrometeorologia/aszalyinfo/index.php](http://www.met.hu/idojaras/agrometeorologia/aszalyinfo/index.php)

<sup>14</sup> KIRCSI et al. 2018.

<sup>15</sup> KOZÁK et al. 2022.

fektettek a karbantartásukra, új védművek és szabályozó műtárgyak épültek, fejlesztették a monitorozó és előrejelző rendszereket. Az elmúlt öt évben figyelmet kapott a modern, korszerű, innovatív vízgazdálkodás.<sup>16</sup>

2025-ben rengeteg fontos intézkedés történt az aszályvédelem területén: létrejött az Aszályvédelmi Operatív Törzs, elindult a Vízet a tájba program, amelynek célja a korábban levezetett, feleslegesnek vélt víz helyben tartása. A gazdák online csatlakozhatnak az önkéntes elárasztási kezdeményezéshez.<sup>17</sup>

Dr. Liptay Zoltán Árpád a Nemzeti Közzolgálati Egyetem Víz tudományi Karának kutatója körszimmetrikus és elliptikus bázisfüggvény-hálózatokat alkalmazott 1–6 napos vízszint-előrejelzésre a Dunán, a Tiszán és a Rábán. (A körszimmetrikus és elliptikus bázisfüggvény-hálózatok olyan előrecsatolt neurális hálózatok, amelyek egyetlen rejtett réteggel rendelkeznek, aktivációs függvényük pedig a bázisfüggvény, mint például a Gauss, és nem a ReLU vagy a tanh.) Munkája során felhasználta az OVSZ OPADAT 2010 és 2023 közötti idősoros vízállásadatait. A hálózatokban különféle bázisfüggvényeket, távolságmétrikákat és optimalizálókat hasonlított össze. A Matérn kovariancia, multikvadratikus és multikvadratikus-biharmonikus függvények többnyire jobb RMSE-t adtak a Gaussnál, míg a csapadék hozzáadása csak csekély javulást hozott. A kutató az előrejelzések pontosságát *root mean square error* segítségével értékelte, és összehasonlította klasszikus OVSZ-modellekkel és mesterségesintelligencia-modellekkel is. A Dunán és a Rábán a klasszikus modellek voltak pontosabbak, míg a Tiszán az elliptikus bázisfüggvény-hálózat ért el jobb eredményt.<sup>18</sup>

Blanka-Végi Viktória, Tobak Zsolt, Kajári Balázs, Sipos György, Barta Károly, Kovács Ferenc, akik a Szegedi Tudományegyetem Geoinformatikai, Természet- és Környezetföldrajzi Tanszék kutatói és Boudewijn van Leeuwen, aki a Víz tudományi és Vízbiztonsági Nemzeti Laboratórium munkatársa a Dél-Alföldön *deep neural network* (DNN), *multi linear regression* (MLR), *extrem gradient boosting* (XGBoost) és *support vector machine regression* (SVR) segítségével, Sentinel-1 radarinformációk és Sentinel-2 multispektrális képek, az Országos Vízügyi Főigazgatóság Operatív Vízhány Értékelő és Előrejelző Monitoring Rendszerének 40 állomásáról származó adatok, és a HU-SoilHydroGrids rendszerből származó adatok felhasználásával talajnedvességet próbáltak előrejelezni. Felhasználtak távérzékelt és terepi talajnedvesség-adatokat, meteorológiai adatokat is, mint például párolgás, napi csapadékmennyiség és hőmérséklet, de még a talaj maximális vízkapacitás-adatait és szabadföldi vízkapacitás-adatokat is. A legjobb eredményt az XGBoost érte el 0,92-es korrelációs együtthatóval. A belvízvizsgálatot Mezőtúrtól északkeletre végezték egy megközelítőleg 1600 km<sup>2</sup>-es területen a Sentinel-1 és Sentinel-2 adatokból, valamint meteorológiai adatok alapján állítottak elő elöntési térképeket, ahol a belvízborítottság feltérképezésére a *convolutional neural network* (CNN) adta a legjobb eredményt.<sup>19</sup>

Szabó János Adolf, a HYDROinformatikai Kutató, Rendszerfejlesztő és Tanácsadó Bt. kutatója, szakértője, Lucza Zoltán és Szabó-Márku Melinda, a Felső-Tisza-vidéki Vízügyi Igazgatóság szakértői munkájuk során bemutatták a numerikus meteorológiai

<sup>16</sup> Magyarország 2021. évi árvíz kockázat-kezelési terve 2022; HEGEDŰS 2020.

<sup>17</sup> Vízet a tájba. Lásd: [www.ovf.hu/jobboldali-sav-tartalmaj/vizetatajba/vizet-a-tajba](http://www.ovf.hu/jobboldali-sav-tartalmaj/vizetatajba/vizet-a-tajba)

<sup>18</sup> LIPTAY 2024.

<sup>19</sup> BLANKA-VÉGI et al. 2024.

modellek hibalehetőségeit és korlátait, szerintük ezeket lehetne javítani mesterséges intelligenciával. A cikk nem egy, már meglévő, konkrét rendszert mutat be, hanem az előrejelzés pontosításának lehetőségeit ismerteti. A numerikus modell pontosságának növeléséhez szükség van SAL-ellenőrzésre, amely három tényező alapján vizsgálja az előre jelzett csapadékmezők hibáit: amplitúdó, lokáció és struktúra. A kutatók úgy gondolják, hogy a numerikus modellek előrejelzéseit óránként össze kellene vetni a radarok és földi mérőállomások által jelzett értékekkel, és a gépi tanulási algoritmust az így kapott SAL-értékekkel kellene tanítani. Az algoritmus képes lenne felismerni a numerikus előrejelzések hibamintázatait, és geometrikus transzformációk segítségével tudná korrigálni ezeket.<sup>20</sup>

## Mesterséges intelligencia és gépi tanulás az árvízvédelemben nemzetközi szinten

Az árvíz rendszeresen előforduló természeti katasztrófa, a világ sok országát érinti, emberéleteket követelhet és felbecsülhetetlen károkat hagy maga után.

Ling Tan a Nanjing University of Information Science and Technology kutatója, Ji Guo a Nanjing University of Information Science and Technology kutatója, Selvarajah Mohanarajah a University of North Carolina at Pembroke kutatója és professzora, Kun Zhou a Nanjing University of Information Science & Technology kutatója 2020-ban készítettek átfogó tanulmányt, amelyben bemutatják az eddig világszerte elért eredményeket a mesterséges intelligencia és gépi tanulás katasztrófavédelmi felhasználásában. Szerintük a mesterséges intelligenciát és gépi tanulást főleg előrejelzésre használják jelenleg, de folynak kutatások olyan rendszerek előállítására, amelyek a védekezést és a kárelhárítást segítik. A meglévő megoldásokat két csoportba oszthatjuk: egyszerű megoldások, ezek főleg egy algoritmust használnak, illetve hibrid megoldások, amelyek több módszert, algoritmust használnak a jobb eredmények eléréséhez. Árvíz-előrejelzéshez használatosak az *artificial neural network* (ANN), *support vector machine* (SVM), *decision tree* (DT), *random forest* (RF) algoritmusok. Szintén léteznek más statisztikán alapuló összetett, haladó, modern algoritmusok, mint: *fuzzy logic* (fuzzy logika), *genetic algorithm* (genetikus algoritmus), *particle swarm optimisation* (raj alapú optimalizáció).<sup>21</sup>

A mesterséges neurális hálózat (*artificial neural network*, ANN) olyan népszerű digitális rendszer, amely a kognitív folyamatokat utánozza abban, hogy komplex mintázatokat modellez, előrejelzéseket hoz létre, illetve megfelelő reakciókat ad külső ingerekre. Fő egysége a neuron, amelynek van bemenete, kimenete, nem lineáris aktivációs függvénye, és a neuron bemeneteihez súlyok tartoznak. A mesterséges neurális hálók három típusú réteggel rendelkeznek: bemeneti, kimeneti és rejtett. Általában sok rejtett réteg van. A tanítás során *backpropagation*, vagyis hiba-visszatérjesztés segítségével próbáljuk elérni, hogy a súlyok a megfelelő értékeket vegyék

<sup>20</sup> SZABÓ – LUCZA – SZABÓ-MÁRKU 2024.

<sup>21</sup> TAN et al. 2021.

fel, ezáltal a háló általánosító képessége a lehető legnagyobb legyen, ami pontosabb predikciókat tesz lehetővé.<sup>22</sup>

A *support vector machine* (SVM), vagyis támasztóvektorgép, egy könnyen használható, felügyelt, relatív egyszerű gépi tanulási modellt, amely rugalmasan alkalmazható akár regressziós, akár klasszifikációs feladatokra is. Az algoritmus célja olyan hipersík megtalálása, amely maximalizálja a margót az osztályok között, a legjobban elkülöníti az osztályokat. Abban az esetben, ha a meglévő adatok nem lineárisan szeparálhatóak, akkor a kernel trükk segítségével olyan transzformációt hajtunk végre, amely egy magasabb dimenzióba képezi le az adatokat, ahol már könnyen szétválaszthatóvá válnak.<sup>23</sup>

A döntési fa (*decision tree*, DT) egy felügyelt gépi tanulási algoritmus, amelyet osztályozásra és regresszióra használnak. A cél egy olyan modell létrehozása, amely megjósolja egy célváltozó értékét az adatjellemzőkből kikövetkeztetett egyszerű döntési szabályok megtanulásával. Jól használható regressziós és klasszifikációs feladatokhoz is, kezeli a folytonos és a kategorikus adatokat is. Hátránya, hogy gyakran túlillesztés (*overfitting*) léphet fel, bár ez a jelenség elkerülhető a fa mélységének korlátozásával vagy regularizáció alkalmazásával.<sup>24</sup>

A véletlen erdő (*random forest*), rövidítése RF, közepesen összetett, megbízható, rugalmas klasszifikációs és regressziós modellt. Több, egymástól független döntési fát hoz létre, és úgy jut el a végeredményhez, hogy regresszió esetén ezek eredményeit átlagolja, vagy, klasszifikáció esetén, kiválasztja a legtöbb szavazatot kapott eredményt. Változatos adatok esetében is stabil teljesítménnyel rendelkezik, jóval kevésbé hajlamos a túlillesztésre mint a döntési fa.<sup>25</sup>

A *fuzzy logic*, vagyis fuzzy logika a klasszikus igaz-hamis, (1)-(0)-án alapuló logikai rendszer továbbfejlesztése, kibővítése, nem tekinthető gépi tanulási modellnek, ennek ellenére valamilyen szinten az emberi gondolkodásmódot utánozza. Míg a klasszikus logikában csak 0 vagy 1 értéket vehetünk fel, a fuzzy logika lehetővé teszi, hogy a 0 és 1 között lévő tört számokat is felvegyük.<sup>26</sup>

A *genetic algorithm* (GA), vagyis genetikai algoritmus a természetből inspirálódott, modern, heurisztikus optimalizációs eljárás. Központi eleme a „gén” vagy „kromoszóma”, amelyeken a következő műveleteket: szelekciót, keresztezést és mutációt addig végezzük, amíg a leállási feltétel nem teljesül. Jól teljesít olyan feladatoknál, ahol a keresési tér extrémén nagy, igaz, hogy nem garantált a legjobb megoldás megtalálása, mivel hajlamos beragadni helyi minimumpontba, de gyakran képes rövid időn belül az optimálshoz közeli megoldást találni.<sup>27</sup>

A *particle swarm optimisation*, azaz raj alapú optimalizáció egy természetből, madárrajok repüléséből, halrajok úszásából inspirálódott, haladó, evolúciós, kevés hiperparaméterrel rendelkező heurisztikus algoritmus, nem gépi tanulási modell, amely jól használható folytonos optimalizálási feladatoknál. Madárrajok esetén nincsen kijelölt vezér, ennek ellenére eljutnak a céljukhoz. Az algoritmus alapeleme az egyed

<sup>22</sup> AYYADEVARA 2018.

<sup>23</sup> AYYADEVARA 2018.

<sup>24</sup> AYYADEVARA 2018.

<sup>25</sup> AYYADEVARA 2018.

<sup>26</sup> AYYADEVARA 2018.

<sup>27</sup> AYYADEVARA 2018.

vagy részecske, amelynek van egy optimuma, a rajnak is van optimuma. Az egyedek a saját és a raj optimumát figyelembe véve mozognak.<sup>28</sup>

Amir Mosavi és Pinar Ozturk a Norvég Műszaki és Tudományos Egyetem (Norwegian University of Science and Technology) Számítástudományi Tanszék (Department of Computer Science) kutatói, gépi tanulási szakértők, Kwok-wing Chau a Hong Kongi Politechnikai Egyetem (Hong Kong Polytechnic University) kutatója, akik által 2018-ban publikált tudományos cikk szerint mind a rövid távú, mind a hosszú távú előrejelző modelleknek fontos szerepük van az árvízjárok megelőzésében. A modellek lehetnek egyszerűek (*single model*), vagy összetettek (*hybrid model*). A leggyakrabban használt árvíz-előrejelző modell az ANN. Az összetett modellek általában több modell segítségével végeznek predikciókat. Az összetett modellek jóval elterjedtebbek, mint az egyszerűek. Használatosak a következő modellek és algoritmusok, módszerek: *autoregressive moving average* (ARMA), *multiple linear regression*, *autoregressive integrated moving average* (ARIMA), *quantile regression techniques* (QRT), amelyek célja az árvízgyakoriság előrejelzése (*flood frequency analysis*, FFA). Az ARMA, ARIMA, QRT nem gépi tanulási modellek, de jól használhatók előrejelzésekhez.<sup>29</sup>

A lineáris regresszió a legegyszerűbb gépi tanulási modell, statisztikai módszeren alapul, gyorsan tanítható, kevés erőforrást igényel. Akkor használható jól, ha a bemeneti és a kimeneti adatok között egyszerű lineáris összefüggés van, a valóságban a felhasználása gyakran limitált, mivel a valóságban a bemenet és a kimenet között nem egyszerű lineáris kapcsolat van.<sup>30</sup>

A *multiple linear regression* már több valóságos helyzetben használható, mint az egyszerű lineáris regresszió, mivel itt a függő változót nem csupán egyetlen tényező, hanem már több független változó magyarázza együttesen. Ez a modell már jóval több kimenetet befolyásoló tényezőt figyelembe tud venni, mint az egyszerű lineáris regresszió, és sok esetben pontosabb predikciókra képes. Akkor ütközhetünk problémába, ha a független változók erősen korrelálnak egymással, vagy bizonyos független változók nem szignifikánsak statisztikailag, ilyen esetekben gyengül a modell általánosító képessége.<sup>31</sup>

Az *adaptive neuro-fuzzy inference systemmel* (ANFIS) Mosavi és társai rövid távú árvíz-előrejelzést végeztek, ez az összetett hibrid rendszer ötvözi a fuzzy logika előnyeit a neurális hálók magas fokú rugalmasságával, ezáltal adaptív előrejelző rendszert hozván létre. A neurális háló komponens tanulás útján optimalizálja a meglévő fuzzy szabályokat, így pontos predikciókat tud végezni.<sup>32</sup>

Alexander Pyayt, az oroszországi Siemens LLC alkalmazottja, Ilya Mokhov, az oroszországi Siemens LLC alkalmazottja, Bernhard Lang, a németországi Siemens AG alkalmazottja, Valeria V. Krzhizhanovskaya, az Amszterdami Egyetem (Universiteit van Amsterdam) kutatója, Robert J. Meijer, a Holland Alkalmazott Tudományos Kutatások Szervezet (Nederlandse Organisatie voor Toegepast Natuurwetenschappelijk Onderzoek) kutatója, munkájuk során töltéseknél mért szenzoradatok alapján próbálnak

<sup>28</sup> AYYADEVARA 2018.

<sup>29</sup> MOSAVI–OZTURK–CHAU 2018.

<sup>30</sup> AYYADEVARA 2018.

<sup>31</sup> AYYADEVARA 2018.

<sup>32</sup> MOSAVI–OZTURK–CHAU 2018.

előrejelzéseket végezni. Ilyen adatok a pórusvíznyomás (*pore water pressure*), maghőmérséklet (*core temperature*), dőlésszög (*inclination*), elmozdulások (*displacements*), vízállás (*water level*). Ők *neural cloudsot* (NC) használtak anomáliadetekcióra, amely egy kombinált algoritmus, két fő elemmel. Első eleme az *advanced K-means* (AKM), ez a könnyen használható klaszterező algoritmus, amely meghatározza, hogy milyen értékek számítanak hétköznapiaknak, normálisnak, és melyek nem. A második eleme a *radial basis function* (RBF) hálózat, amely a meglévő klaszterek középpontjai köré Gauss-görbéket húz, így egy új mérésről könnyedén meg lehet mondani, hogy normális érték-e, vagy anomáliának számít.<sup>33</sup>

A *K-means* egy felügyelet nélküli tanuló modell, célja az adatok klaszterezése (csoportosítása) úgy, hogy a hasonló elemek egy klaszterbe kerüljenek. A modell működtetéséhez előre meg kell adni a *k* paraméter értékét, vagyis hogy hány klaszterbe szeretnénk csoportosítani az adatokat; bár ez a valóságban gyakran okozhat nehézségeket, az algoritmus sok esetben kimondottan jól működik. Szintén negatívum, hogy olykor megtörténik, hogy beragad egy lokális minimumba, és nem találja meg a globális optimumot. Az algoritmus célja, hogy egy adott klaszteren belül lévő elemek egymáshoz minél közelebb legyenek, úgy, hogy a különböző klaszterek középpontjai pedig egymástól a lehető legtávolabb legyenek. Az algoritmus működése iteratív. Első lépésben általában véletlenszerűen kiválasztunk *k* darab középpontot. Ezután minden adatot a legközelebbi klaszterközépponthez rendelünk, aztán a középpontokat újra-számítjuk a klaszterhez tartozó pontok átlagolásával, innen ered az algoritmus neve is. Ezeket a lépéseket addig ismételjük, amíg a klaszterek stabilizálódnak, vagyis már nem változik a pontok besorolása, vagy el nem érünk egy előre megadott iterációs számot.<sup>34</sup>

*Advanced K-means* (AKM): a *K-means* továbbfejlesztett változata, ahol a klaszterek száma nincs előre rögzítve bemeneti paraméterként, a felhasználó ad meg egy minimális és maximális értéket, és az algoritmus megpróbál az adatokra jól illeszkedő klasztereket találni. Ez úgy valósul meg, hogy választanak egy kezdő klaszterszámot és lefuttatják a hagyományos *K-means* algoritmust. Ezt követően az eljárás iteratív módon módosítja a klaszterközéppontok számát és elhelyezkedését. Új középpontot hoz létre, ha bizonyos adatok túl nagy távolságra esnek a legközelebbi centroidtól, törli azokat a klasztereket, amelyek túl kevés adatpontot tartalmaznak, és összevonja azokat a klasztereket, amelyek középpontjai egy előre megadott távolságkülönbélnél közelebb kerülnek egymáshoz. Minden ilyen lépés után ismét lefuttatják a *K-means* lépéseit az aktuális középpontokra, egészen addig, amíg a klaszterszám és a centroidok helyzete nem stabilizálódik, vagy amíg el nem érnek egy maximális iterációs számot. Ez a módszer részben automatizálja a klaszterek számának megválasztását, ugyanakkor az eredmény erősen függ a minimális és maximális klaszterszámtól, a minimális klasztermérettől, valamint a távolságra és összevonásra vonatkozó küszöbértékektől. Az AKM hátrányai közé tartozik, hogy euklideszi távolságra és nagyjából gömb alakú klaszterekre épít, érzékeny az adatok skálázására és a kezdeti középpontválasztásra,

<sup>33</sup> PYAYT et al. 2011.

<sup>34</sup> AYYADEVARA 2018.

így nagy dimenziószám vagy zajos, átfedő klaszterek esetén előfordulhat, hogy lokális minimumba ragad, és nem találja meg a globális optimumot.<sup>35</sup>

A települési csapadékvíz által okozott elöntések sok ország számára rendszeres és jelentős problémát okoznak, ami évente felbecsülhetetlenül nagy károkat tud okozni. William Sayers, az Exeteri Egyetem (University of Exeter) kutatója és a HR Wallingford kutatóintézetnél is dolgozik, Dragan Savić és Zoran Kapelan, az Exeteri Egyetem (University of Exeter) kutatói és Richard Kellagher, a HR Wallingford kutatóintézet munkatársa által végzett kutatás célja a beavatkozás hatékonysága és a ráfordítandó összeg közötti egyensúly megtalálása volt. Ők egy ADAPT (A Drainage Analysis and Planning Tool) rendszert egészítettek ki multiobjektív genetikussal, konkrétan *nondominated sorting genetic algorithm II* (NSGA II) és neurális hálóval (*neural network*).<sup>36</sup>

A multiobjektív genetikussal (MOGA) egy gyűjtőfogalom, amelybe beletartozik az összes olyan genetikussal, amely többcélú optimalizációra használható. A hagyományos genetikussal esetén a cél a legjobb megoldás megtalálása, többcélú optimalizáció esetén ilyen nem létezik, a többcélú optimalizáció esetén kompromisszumos megoldásokat tartalmazó halmaz megtalálására törekszünk, vagyis a Pareto-frontot akarjuk közelíteni. A *nondominated sorting genetic algorithm II* vagyis nemdomináns genetikussal az egyik legelterjedtebb, könnyen használható, gyors, többcélú optimalizációra alkalmazható genetikussal, amely nemdomináns rendezési stratégiát használ, és kimondottan jól tudja kezelni az egymással ellentétes célfüggvényeket is.<sup>37</sup>

A Google által fejlesztett Google's Flood Hub jól működő árvíz-előrejelző rendszer, amely bárki számára térítésmentesen elérhető, és 2018-tól kezdték használni. A rendszert négy komponens alkotja: adatvalidálás, szakaszos előrejelzés, árvízmodellelés és riasztáselosztás. Két alrendszer gépi tanulásra támaszkodik. A szakaszos előrejelzéshez hosszú rövid távú memória (LSTM) hálózatokat és lineáris modelleket alkalmaznak. Az árvízi elöntést a küszöbérték- és a sokaságmodellekkel számítják ki, ahol az előbbi az árvíz kiterjedését, az utóbbi pedig az árvíz kiterjedését és mélységét is kiszámítja. Az itt elsőként bemutatott sokaságmodell gépi tanuláson alapul. A küszöbértékű modell a Google hagyományos komponense. A rendszer betáplálja a mérőállomásokról, műholdakról kapott adatokat az MI-modellekbe, így végez predikciókat. Jelenleg csak folyami árvizek előrejelzésére képes, de a jövőben elképzelhető, hogy a működést kiterjesztik villámárvizekre is. A történeti adatokon végzett értékelés során minden modell kellően jól működik az operatív használathoz. Az LSTM jobban teljesített, mint a lineáris modell, míg a küszöbértékű és a sokaságmodellek hasonló teljesítménymutatókat értek el az árvíz kiterjedésének modellezésében. A rendszer akár hét nappal előre prediktálni tudja, hogy egy adott folyó ki fog-e lépni a medréből. Ez nagy segítséget jelent, mivel a helyes predikciók segítségével a katasztrófavédelmi szakemberek időben meg tudják hozni a szükséges lépéseket a károk minimalizálása érdekében. Az elmúlt években a projekt rengeteget fejlődött, sok ország csatlakozott

<sup>35</sup> AYYADEVARA 2018; PYAYT et al. 2011; LANG et al. 2008.

<sup>36</sup> SAYERS et al. 2014.

<sup>37</sup> DEB et al. 2002.

hozzá. A rendszerrel kapcsolatos tervek a lefedettség kiterjesztését, valamint a modellezési képességek és pontosság javítását célozzák.<sup>38</sup>

Az árvizek aránytalanul nagy hatást gyakorolnak a fejlődő és fejletlen országokra, ahol gyakran hiányoznak a sűrű vízhozammérő hálózatok. A világ vízgyűjtőinek csak néhány százalékát mérik, és a vízfolyásmérők nem egyenletesen oszlanak el a világon. Szoros kapcsolat van a nemzeti bruttó hazai termék és az adott országban nyilvánosan elérhető összes vízhozam-megfigyelési adat között, ami azt jelenti, hogy a kiváló minőségű előrejelzések különösen nagy kihívást jelentenek azokon a területeken, amelyek a leginkább ki vannak téve az árvizek pusztító hatásainak. A Flood Hub kutatói kimutatták, hogy a mesterségesintelligencia-alapú előrejelzés megbízhatóan jelzi a szélsőséges folyami eseményeket a nem mért vízgyűjtőkön, akár ötnapos előzetes idővel is, ami hasonló vagy jobb, mint a jelenlegi legmodernebb globális modellező rendszer, a Copernicus Vészhelyzet-kezelési Szolgálat Globális Árvízudatossági Rendszere (GloFAS) azonnali előrejelzéseinek (nulladik napos előzetes idő) megbízhatósága. A Flood Hub kutatói rávilágítanak, hogy égető szükség van a hidrológiai adatok elérhetőségének növelésére a megbízható árvízi figyelmeztetésekhez való globális hozzáférés további javítása érdekében.<sup>39</sup>

## A mesterséges intelligencia és a gépi tanulás a villámárvíz elleni védekezésben nemzetközi szinten

A hirtelen lezúduló csapadék komoly problémákat okozhat, sok ember életét és vagyonát veszélyezteti a hegyvidékeken és dombvidékeken, hiszen villámárvíz kialakulásához vezethet. Az ilyen események előrejelzése nehéz, mivel rendkívül pontos modellekre van szükség, mert a villámárvíz gyorsan alakul ki, és relatív kisebb területre koncentráldik, pár km-es pontosságú predikció gyakran nem elég.

Ghazi Al-Rawas, Mohammad Reza Nikoo, Malik Al-Wardy és Talal Etri a Sultan Qaboos University kutatói összefoglaló jellegű, 2024-ben publikált cikkükben bemutatják, hogy Iránban SVM, ANN, RNN, CNN és *nearest neighbor classification* (NNC) algoritmusokat, Jordániában ANN, a Fülöp-szigeteken regressziós algoritmusokat, Kínában LSTM, Egyiptomban *light gradient boosting machine* (LightGBM), CatBoost, XGBoost, *multilayer perceptron* (MLP), *logistic regression* (LR) rendszereket használtak villámárvíz-predikcióra.<sup>40</sup>

Az LR, vagyis logisztikus regresszió egyszerű, gyors gépi tanulási modell, amely jól használható kategorikus adatokon. Az algoritmus eredménye gyakran csak két értéket vehet fel: igazat vagy hamisat. Jól használható eldöntendő feladatoknál, például lesz árvíz vagy nem, beteg az illető vagy nem.<sup>41</sup>

<sup>38</sup> NEVO et al. 2022.

<sup>39</sup> NEARING et al. 2024.

<sup>40</sup> AL-RAWAS et al. 2024.

<sup>41</sup> AYYADEVARA 2018.

RNN, azaz rekurrens neurális hálózat egy speciális verziója a mesterséges neurális hálóknak, rendelkezik, úgymond, beépített memóriával, amely jól kezeli az időben összefüggő, szekvenciális adatokat, ahol kulcsfontosságú a sorrend.<sup>42</sup>

Az RNN-modellek általában jól megtanulják az időbeli mintázatokat, egyszer-egyszer előjön a *vanishing gradient* vagy az *exploding gradient* probléma. Elhaló gradiens (*vanishing gradient*) akkor fordulhat elő, amikor a fontos információval már túl régen találkozott a modell, ilyenkor hajlamos ezt elfelejteni, mivel a tanulás során a régi információ gradiense egyre kisebb lesz, így a súlyfrissítés is egyre kisebb lesz, a régi információ hatása lassan eltűnik, a modell már nem fog emlékezni erre az információra. A robbanó gradiens (*exploding gradient*) probléma akkor fordul elő, amikor bizonyos súlyok túl nagyra nőnek, a modell tanulása instabillá válik, mivel a modell már nem tud konvergálni a helyes súlyok felé azért, mert a frissítések túl nagyok.<sup>43</sup>

Long short-term memory (LSTM), magyarul hosszú rövid távú memória egy komplex modell, amely már kiküszöböli az eltűnő és robbanó gradiens problémát, képes hosszú adatsorozatok esetén is emlékezni a lényeges információkra. Az LSTM működésének legfontosabb eleme a cellamemória: akár egy futószalag, amelyen az információk sok ideig tudnak utazni anélkül, hogy minden lépésnél megváltoznának. Rendelkezik bemeneti kapuval (*input gate*), kimeneti kapuval (*output gate*) és elfelejtő kapuval (*forget gate*). A fontos információk a cellamemóriában maradnak, a felesleges, kis relevanciával bíró információk pedig elfelejtődnek a felejtő kapun keresztül.<sup>44</sup>

A *bagging* és *boosting* a gépi tanulásban alkalmazott együttes (*ensemble*) tanulási módszerek. Az *ensemble* megközelítés lényege, hogy egyetlen modell helyett modellek csoportját tanítjuk és egyesítjük. A *bagging* és a *boosting* a két legismertebb ilyen technika. A *bagging* (*bootstrap* aggregálás) Leo Breiman statisztikus által 1996-ban bevezetett módszer, amely több változatban létrehozott tanuló modell átlagolásával vagy szavazásával javítja az előrejelzést.<sup>45</sup>

A *bagging* során az eredeti adathalmazból számos *bootstrap* újramintavétellel készült részhalmazt hozunk létre: minden egyes részhalmaz az eredeti mintából véletlenszerűen, visszatevéses mintavételezéssel generálódik, így egy-egy elem többször is szerepelhet vagy kimaradhat egy adott részhalmazból. Minden egyes ilyen *bootstrap* halmazhoz betanítunk egy-egy alapmodellt (úgynevezett alaptanulót, például döntési fát vagy más klasszifikátort), majd az így kapott több modell aggregált előrejelzését adjuk eredményül. Klasszifikáció esetén az egyes modellek osztályba sorolási szavazatait többségi szavazással egyesítjük, regressziónál pedig az átlagukat vesszük. A *bagging* fő hatásmechanizmusa a predikciós modell varianciájának csökkentése azáltal, hogy több, egymástól függetlenül betanított modell átlagát vesszük. Különösen instabil, nagy varianciájú alaptanulók esetén (mint például a döntési fák) hoz jelentős javulást, mivel kiegyenlíti az adatkészlet kis változásaira érzékeny modellek fluktuációit.<sup>46</sup>

<sup>42</sup> AYYADEVARA 2018.

<sup>43</sup> AYYADEVARA 2018.

<sup>44</sup> AYYADEVARA 2018.

<sup>45</sup> BREIMAN 1996.

<sup>46</sup> BREIMAN 1996.

Ezzel szemben a *bagging* nem feltétlenül csökkenti a torzítást: az egyes modellek átlagolása a rendszeres hibákat nem szünteti meg, viszont az *overfitting* (túlillesztés) kockázatát csökkenti a variancia mérséklésével. A *bagging* egyszerűsége és hatékonysága miatt hamar népszerű lett; tipikus alkalmazása a *random forest* algoritmus, amely a *bagging* elvét valósítja meg döntési fák esetén, kiegészítve a változók véletlenszerű kiválasztásával minden fa építésekor. A *random forest* így sok, különböző *bootstrap* mintán tanult döntési fa együttesével ér el magas pontosságot és stabilitást. Ebben a kontextusban fontos kiemelni, hogy a *random forest* nem egyenlő a döntési fával: míg a döntési fa egyetlen faalapú modell, addig a *random forest* a *bagging* egy speciális formája, amely sok mély döntési fát tanít különböző *bootstrap* mintákon, és minden egyes *split* során csak egy véletlenül kiválasztott jellemző részalmból engedi meghatározni a legjobb osztást. Ez a kétlépcsős véletlenítés – az adatminták és a jellemzők szintjén – jelentősen növeli a modell robusztusságát és általánosító képességét, így a *random forest* működése és célja alapvetően eltér egyetlen döntési fa viselkedésétől.<sup>47</sup>

A *boosting* olyan együttes tanulási módszer, amely szekvenciálisan kapcsol össze több gyenge tanulót annak érdekében, hogy egy erős, nagy pontosságú modellt állítson elő. A *boosting* során az egyes almodelleket egymás után tanítjuk be úgy, hogy minden új modell az előző modell által elkövetett hibákra koncentrál. Ezt tipikusan azzal érik el, hogy a tanulóalgoritmus figyelmét az előző körökben rosszul klasszifikált példákra irányítják – például súlyokat rendelnek az adatokhoz, amelyeket minden iteráció után növelnek a helytelenül besorolt példák esetén.<sup>48</sup>

Kezdetben egy almodell tanul az eredeti adatokon, majd minden további modell az addig rosszul prediktált mintákat nagyobb súllyal veszi figyelembe. Végül az összes almodell előrejelzését egyesítjük, általában súlyozott szavazással vagy összegzéssel, ahol a jobb teljesítményű modellek nagyobb súlyt kapnak a végső döntésben. Ennek eredményeképp a *boosting* iteratív módon csökkenti a modell torzítását: a korábban alulbecsült mintákra fókuszálva egyre pontosabbá teszi a kompozit modellt. A *boosting* elvi alapját Robert Schapire 1990-ben rakta le a gyenge tanulók megerősítésének elméletével, gyakorlati áttörést pedig Freund és Schapire AdaBoost algoritmusával hozott 1996-ban. Az AdaBoost (*adaptive boosting*) volt az első, széles körben alkalmazott *boosting* algoritmus, és máig az egyik legnépszerűbb, mivel viszonylag egyszerű és sokféle gyenge tanulóval jól működik. Az AdaBoost minden iterációban újrasúlyozza a tanító adatpontokat: növeli a rosszul osztályozott példák súlyát, így a következő gyenge modell már ezekre helyez nagyobb hangsúlyt.<sup>49</sup>

Az idők során számos *boosting* variáns született. Jelentős fejlesztés volt Jerome Friedman munkája, aki bevezette a *gradiens boosting* módszert, általánosítva a *boostingot* tetszőleges veszteségfüggvény gradiense mentén történő iteratív javításra – ezzel nemcsak osztályozási, hanem regressziós problémákra is hatékony *boosting* algoritmust adott.<sup>50</sup>

<sup>47</sup> JANSEN 2021.

<sup>48</sup> SCHAPIRE 1990; FREUND 1995.

<sup>49</sup> FREUND–SCHAPIRE 1996.

<sup>50</sup> FRIEDMAN 2001.

A gradiens alapú *boosting* keretrendszer számos modern megvalósítás alapja; ilyen például a széles körben használt XGBoost algoritmus is. Ugyanakkor a *boosting* hajlamos lehet a túlillesztésre, ha túl sok iterációt használunk, vagy ha jelentős zaj van az adatokban. Empirikus vizsgálatok kimutatták, hogy míg zajmentes adatokon a *boosting* gyakran pontosabb, addig zajos adatkörnyezetben a *bagging* stabilabbnak bizonyul. A *boosting* modell ugyanis felerősítheti a zajt vagy a kimeneti változóban lévő véletlenszerű hibákat azzal, hogy megpróbál minden apró hibát kijavítani, ami túlillesztéshez vezethet. Ezzel szemben a *bagging*, mivel átlagolással dolgozik, jóval robusztusabb a zajjal szemben, és ritkábban fordul elő, hogy teljesítménye zaj hatására jelentősen romlik.<sup>51</sup>

*Categorical boosting* (CatBoost), azaz kategorikus boosting algoritmus egy relatív új, 2017-ben megalkotott, rugalmas *gradiens boosting* algoritmus, amely nagyon hatékonyan tudja kezelni a nagy mennyiségű kategorikus bemeneti adatot. Képes számokká alakítani a kategorikus adatokat *one-hot encoding* felhasználása nélkül.<sup>52</sup>

Mohamed Wahba, aki az Egyiptom–Japán Tudományos és Technológiai Egyetem (Egypt-Japan University of Science and Technology, E-JUST) Környezetmérnöki Tanszékének (Environmental Engineering Department) kutatója, Mustafa El-Rawy, aki a Miniai Egyetem (Minia University) Építőmérnöki Karán (Civil Engineering Department, Faculty of Engineering) a Vizsgádzalkodási Mérnöki tanszék professzora és kutató, Nassir Al-Arifi, aki a Szaúd-Arábiai Király Szaúd Egyetem (King Saud University) Geológiai és Geofizikai Tanszékének (Department of Geology and Geophysics) kutatója, Mahmoud M. Mansour, aki az Egyiptomi Menoufia Egyetem (Menoufia University) Mérnöki Kar Építőmérnöki Tanszékének (Department of Civil Engineering, Faculty of Engineering) kutatója, akik által végzett tudományos munka során, amelynek célja új módszerek kifejlesztése volt, amivel Japánban földcsuszamlások és villámárvizek kockázatát lehet becsülni, LASSO Regression modell segítségével generáltak *landslide hazard map* (LHM), *flood hazard map* (FHM), *composite hazard map* (CHM) eredményeket. A kapott eredményeket *receiver operating characteristic* (ROC) és *area under the curve* (AUC) segítségével mérték. Az LHM és a FHM 99% fölötti ROC- és AUC-értéket értek el.<sup>53</sup>

Khaula Alkaabi, az Egyesült Arab Emírségek Egyetem (United Arab Emirates University), Uzma Sarfraz, a Government College University Lahore és Saif Al Darmaki, az Egyesült Arab Emírségek Nemzeti Meteorológiai Központjának (National Center of Meteorology) kutatói közösen végzett munkájuk során az Egyesült Arab Emírségek területén prediktálták a villámárvíz valószínűségét egy hibrid mélytanulási keretrendszerrel, amely integrálja a CNNs-t, RNNs-t és a *neural ordinary differential equations* (Neural ODEs) megoldásait, amelyek  $R^2 = 0,98$ ,  $RMSE = 2,87 \times 10^6$ ,  $MAE = 1,13 \times 10^6$ ,  $PBIAS = -8,38$  értékeket értek el.<sup>54</sup>

A következőkben összefoglaló táblázatban (1. táblázat) mutatjuk be a különböző országokban alkalmazott mesterségesintelligencia-alapú villámárvíz-előrejelző modelleket, valamint azok teljesítményét.

<sup>51</sup> KOTSIANTIS–KANELLOPOULOS 2012; OPITZ–MACLIN 1999.

<sup>52</sup> JANSEN 2021.

<sup>53</sup> WAHBA et al. 2023.

<sup>54</sup> ALKAABI – SARFRAZ – AL DARMAKI 2025.

1. táblázat: Villámárvíz-előrejelző modellek összehasonlítása

Modell	Modell célja, felhasználása	Elért eredmények
Least Absolute Shrinkage and Selection Operator (LASSO) regresszió	Villámárvíz előrejelzése	AUC (area under the curve): 99,36% Átlagos abszolút hiba (MAE): 0,208
DeepLabv3 (konvolúciós neurális hálózat, CNN)	Villámárvíz detektálása	Szegmentálási pontosság: 87%
Neurális differenciálegyenlet (Neural ODE)	Villámárvíz detektálása	Átlagos abszolút hiba (MAE): $1,85 \times 10^6$ Root mean square error (RMSE): $3,41 \times 10^6$ $R^2$ : 0,97 Nash–Sutcliffe-hatékonyság (NSE): 0,97 Percent bias (PBIAS): -25,48%
Konvolúciós neurális hálózat (CNN) + Rekurrens neurális hálózat (RNN)	Villámárvíz előrejelzése	Átlagos abszolút hiba (MAE): $1,66 \times 10^6$ Root mean square error (RMSE): $3,74 \times 10^6$ $R^2$ : 0,96 Nash–Sutcliffe-hatékonyság (NSE): 0,96 Percent bias (PBIAS): -13,73%
Konvolúciós neurális hálózat (CNN) + Rekurrens neurális hálózat (RNN) + neurális differenciálegyenlet (Neural ODE)	Villámárvíz előrejelzése	Átlagos abszolút hiba (MAE): $1,13 \times 10^6$ Root mean square error (RMSE): $2,87 \times 10^6$ $R^2$ : 0,98 Nash–Sutcliffe-hatékonyság (NSE): 0,98 Percent bias (PBIAS): -8,38%
U-net alapú detektálás	Veszélyértékelés és erőforrás-allokáció támogatása	F1-pontszám: 0,92

Forrás: WAHBA et al. 2023; ALKAABI – SARFRAZ – AL DARMAKI 2025; ZHOU 2025

## A mesterséges intelligencia és a gépi tanulás az aszály elleni védekezésben nemzetközi szinten

Az aszály mint hidrológiai katasztrófa jóval lassabban alakul ki, mint az árvíz, de jelentősen tovább is tart, és nagyobb területeket érint. Fontos, hogy minden országnak legyen modern, pontos aszálymonitorozó és -előrejelző rendszere, és létezzenek akciótervek arra nézve, hogyan lehet elkerülni az aszályt, vagy legalább a hatását csökkenteni. Az aszályok előrejelzése kulcsfontosságú a gazdasági stabilitás érdekében. Az időben előrejelzett aszályra sokkal könnyebb felkészülni, és megtenni a szükséges intézkedéseket.

Ali Mokhtar, a Kairói Egyetem Mezőgazdasági Mérnöki Tanszék (Cairo University Faculty of Agriculture) kutatója, akinek publikációs területei a vízgazdálkodás, a mesterséges intelligencia és az éghajlatváltozás, és társai Kínában CNN, LSTM és XGB algoritmusokkal végeztek aszály-előrejelzést, felhasználva az 1980 és 2019 között gyűjtött meteorológiai adatokat. A predikciókhoz felhasználták a csapadékmennyiségi és hőmérsékletátlagot, minimum- és maximumhőmérséklet-, szélsőséges- és páratartalom-adatokat.<sup>55</sup>

Jelenleg nincs általános, világszerte használható aszályindex. Mhamd Saifaldeen Oyounalsoud, Abdullah Gokhan Yilmaz, Mohamed Abdallah és Abdulrahman Abdeljaber kutatásuk során, amelynek célja az aszály-előrejelzés volt Ausztráliában, DT, *generalised linear model* (GLM), SVM, ANN és RF modellek segítségével új aszályindexeket fejlesztettek ki, amelyek jobban teljesítettek a meglévő indexeknél.<sup>56</sup>

Kavina Dayal a School of Agriculture and Environmental Science intézmény kutatója, amely a University of Southern Queensland része, Ravinesh Deo a University of Southern Queensland School of Agricultural, Computational & Environmental Sciences kutatója és Armando A. az Apan University of Southern Queensland School of Civil Engineering and Surveying kutatója, munkájuk során a SPEI-t (*standardised precipitation-evapotranspiration index*) prediktálták ANN segítségével, és ezáltal végeztek aszály-előrejelzést Ausztrália két különböző éghajlati régiójában, egy mérsékelt területen és egy füves pusztai részen. A modell bemenetei idősoros meteorológiai adatok voltak, mint csapadékmennyiség, minimum és maximum hőmérséklet. A modell jól teljesített, az  $R^2$  megközelítően 0,99 volt.<sup>57</sup>

Tadele Melese, a Bahir Dar Egyetem (Bahir Dar University) Természeti Erőforrás Menedzsment Tanszékének (Department of Natural Resource Management) kutatója és társai több gépi tanulási modellt is kipróbáltak aszály-előrejelzés céljából Etiópiában, és arra a következtetésre jutottak, hogy az együttes tanulási modellek (*ensemble learning models*) kimondottan jól teljesítenek ebben a helyzetben. A *random forest* teljesítménye volt a legjobb, 71,18%-os pontosságot és 0,9 AUC-t értek el. Kutatásuk arra is rávilágított, hogy kulcsfontosságú az adatok kiegyensúlyozottsága, ezért hibrid mintavételezést alkalmaztak, amely ötvözi a manuális újra-mintavételezést és a *synthetic minority oversampling technique* (SMOTE) technikát. Munkájuk során, a túllilleszkedés elkerülése érdekében, *grid search*-öt és keresztvalidációt használtak.<sup>58</sup>

A következőkben összefoglaló táblázatban (2. táblázat) mutatjuk be a különböző országokban alkalmazott mesterségesintelligencia-alapú aszály- és aszályindex-előrejelző modelleket, valamint azok teljesítményét.

<sup>55</sup> MOKHTAR et al. 2021.

<sup>56</sup> OYOUNALSOUND et al. 2024.

<sup>57</sup> DAYAL-DEO-APAN 2017.

<sup>58</sup> MELESE et al. 2025.

2. táblázat: Aszály-előrejelző modellek összehasonlítása

Modell	Modell célja	Elért eredmények
Extreme gradient boosting (XGB)	SPEI aszályindex előrejelzése éghajlati változókból	SPEI-3: Átlagos abszolút hiba (MAE): 0,26–0,35 Négyzetes átlag hiba (RMSE): 0,09–0,17 Nash–Sutcliffe-hatékonyság (NSE): 0,84 SPEI-6: Négyzetes átlag hiba (MSE): 0,16 Korrelációs együttható (R): 0,95
Random forest (RF)	SPEI aszályindex előrejelzése éghajlati változókból	SPEI-3: Átlagos abszolút hiba (MAE): 0,36 Nash–Sutcliffe-hatékonyság (NSE): 0,86  SPEI-6: Négyzetes átlag hiba (MSE): 0,11 Korrelációs együttható (R): 0,95
Konvolúciós neurális háló (CNN)	SPEI előrejelzése különböző időskálákon	SPEI-3: Négyzetes átlag hiba (MSE): 0,29 Korrelációs együttható (R): 0,82 SPEI-6: Négyzetes átlag hiba (MSE): 0,36 Átlagos abszolút hiba (MAE): 0,49 Korrelációs együttható (R): 0,77
Long short-term memory (LSTM)	SPEI előrejelzése	SPEI-3: Négyzetes átlag hiba (MSE): 0,37 Átlagos abszolút hiba (MAE): 0,56 Korrelációs együttható (R): 0,78 SPEI-6: Négyzetes átlag hiba (MSE): 0,46 Korrelációs együttható (R): 0,77
Mesterséges neurális háló (ANN)	SPEI havi előrejelzése	Determinációs együttható (R <sup>2</sup> ): 0,9839 Nash–Sutcliffe-hatékonyság (NSE): 0,9838 Négyzetes átlagos hiba gyöke (RMSE): 0,1338 Átlagos abszolút hiba (MAE): 0,0882
Gradiens boosting	PDSI – Palmer-féle aszály-súlyossági index osztályozása	Pontosság: 0,61 AUC (area under the curve): 0,8982 F1-pontszám: 0,60
Támogató vektorgépek (SVM)	PDSI – Palmer-féle aszály-súlyossági index osztályozása	Pontosság: 0,67 AUC (area under the curve): 0,8681 F1-pontszám: 0,66
Random forest (RF)	PDSI – Palmer-féle aszály-súlyossági index osztályozása	Pontosság: 0,72 AUC (area under the curve): 0,9000 F1-pontszám: 0,71
Döntési fa (decision tree, DT)	PDSI – Palmer-féle aszály-súlyossági index osztályozása	Pontosság: 0,56 AUC (area under the curve): 0,55 F1-pontszám: 0,7456

Forrás: MOKHTAR et al. 2021; OYOUNALSOUND et al. 2024; DAYAL–DEO–APAN 2017; MELESE et al. 2025

## Összefoglalás

Láthatjuk, hogy az elmúlt húsz év alatt a mesterséges intelligencia felhasználása nagyon elterjedt lett a különböző hidrológiai katasztrófák előrejelzésében, sok esetben pontosabb predikciókat ér el, mint a régi fizikai modellek. Hidrológiai katasztrófák predikciójánál leggyakrabban artificial neural network (ANN), convolutional neural network (CNN), decision tree (DT), random forest (RF), support vector machine (SVM), extreme gradient boost (XGBoost), long short-term memory (LSTM) eszközöket használnak. A fentebb leírtak alapján azt is kijelenthetjük, hogy csak mesterséges-intelligencia-alapú módszerek használata árvíz-, belvív-, villámárvíz-, településelőntés-, aszály-előrejelzéshez a legtöbb esetben nem lesz elegendő. A tudomány jelen állása szerint a régebbi klasszikus hidrológiai módszerek kombinálása több géptanulás- és mesterségesintelligencia-moddal hozza a legjobb eredményt. Hazánk rendelkezik jól működő árvíz- és aszály-előrejelző rendszerrel, de jelenleg a mesterséges intelligencia és a gépi tanulás alkalmazása még nem jellemző a hidrológiai katasztrófák predikciós rendszereiben, viszont több egyetem és intézmény, mint a Nemzeti Közszolgálati Egyetem, Szegedi Tudományegyetem, Felső-Tisza-vidéki Vízügyi Igazgatóság, is folytat kutatást ebben a témakörben.

## Felhasznált irodalom

- AL-RAWAS, Ghazi et al. (2024): A Critical Review of Emerging Technologies for Flash Flood Prediction: Examining Artificial Intelligence, Machine Learning, Internet of Things, Cloud Computing, and Robotics Techniques. *Water*, 16(14). Online: <https://doi.org/10.3390/w16142069>
- ALKAABI, Khaula – SARFRAZ, Uzma – AL DARMAKI, Saif (2025): A Deep Learning Framework for Flash-Flood-Runoff Prediction: Integrating CNN-RNN with Neural Ordinary Differential Equations (ODEs). *Water*, 17(9), 1283. Online: <https://doi.org/10.3390/w17091283>
- AYYADEVARA, V. Kishore (2018): *Pro Machine Learning Algorithms: A Hands-On Approach to Implementing Algorithms in Python and R*. New York: Apress. Online: <https://doi.org/10.1007/978-1-4842-3564-5>
- BLANKA-VÉGI Viktória et al. (2024): Gépi tanulási módszerek az aszály és belvív monitoring és előrejelzés fejlesztésében. *Földrajzi Közlemények*, 148(2), 175–181. Online: [www.foldrajzitasasag.hu/downloads/reviews/2024/FK\\_2024\\_02\\_175\\_181\\_Blanka\\_etal.pdf](http://www.foldrajzitasasag.hu/downloads/reviews/2024/FK_2024_02_175_181_Blanka_etal.pdf)
- BREIMAN, Leo (1996): Bagging Predictors. *Machine Learning*, 24, 123–140. Online: <https://doi.org/10.1007/BF00058655>
- BUSZTA, Júlia et al. (2023): Historical Analysis and Prediction of the Magnitude and Scale of Natural Disasters Globally. *Resources*, 12(9), 106. Online: <https://doi.org/10.3390/resources1209106>
- Copernicus Emergency Management Service. Online: <https://emergency.copernicus.eu/>
- DAYAL, Kavina – DEO, Ravinesh – APAN, Armando A. (2017): Drought Modelling Based on Artificial Intelligence and Neural Network Algorithms: A Case Study in

- Queensland, Australia. In LEAL FILHO, Walter (szerk.): *Climate Change Adaptation in Pacific Countries*. Cham: Springer, 177–198. Online: [https://doi.org/10.1007/978-3-319-50094-2\\_11](https://doi.org/10.1007/978-3-319-50094-2_11)
- DEB, Kalyanmoy et al. (2002): A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182–197. Online: <https://doi.org/10.1109/4235.996017>
- European Flood Awareness System. Online: <https://european-flood.emergency.copernicus.eu/en>
- FIALA Károly et al. (2018): Operatív aszály- és vízhiánykezelő monitoring rendszer. *Hidrológiai Közlöny*, 98(3), 14–24. Online: [https://real.mtak.hu/156046/1/Fiala\\_et\\_al2018HidrologiaiKozlony.pdf](https://real.mtak.hu/156046/1/Fiala_et_al2018HidrologiaiKozlony.pdf)
- FREUND, Yoav (1995): Boosting a Weak Learning Algorithm by Majority. *Information and Computation*, 121(2), 256–285. Online: <https://doi.org/10.1006/inco.1995.1136>
- FREUND, Yoav – SCHAPIRE, Robert Elias (1996): Experiments with a New Boosting Algorithm. *Machine Learning: Proceedings of the Thirteenth International Conference*, 1996. Online: <https://cseweb.ucsd.edu/~yfreund/papers/boostingexperiments.pdf>
- FRIEDMAN, Jerome Harold (2001): Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29(5), 1189–1232. Online: <https://doi.org/10.1214/aos/1013203451>
- HEGEDŰS Gergely (2020): Újabb mérföldkőhöz érkezett Magyarország árvízvédelme. *Magyar Építők*, 2020. szeptember 24. Online: <https://magyarepitok.hu/vizgazdalkodas/2020/09/ujabb-merfoldkoho-erkezett-magyarorszag-arvizvedelme>
- JANSEN, Stefan (2021): *Machine Learning for Algorithmic Trading*. Birmingham: Packt.
- KIRCSI Andrea et al. (2018): *Drought Monitoring in Hungary*. Interreg – OMSZ. Online: [https://drmkc.jrc.ec.europa.eu/portals/0/Innovation/SupportSystem/12\\_Hungary/Documents/thursday/Andrea\\_Kircsi\\_final\\_Hungary20181108.pdf](https://drmkc.jrc.ec.europa.eu/portals/0/Innovation/SupportSystem/12_Hungary/Documents/thursday/Andrea_Kircsi_final_Hungary20181108.pdf)
- KOTSIANTIS, Sotiris – KANELLOPOULOS, Dimitris (2012): Combining Bagging, Boosting and Random Subspace Ensembles for Regression Problems. *International Journal of Innovative Computing, Information and Control*, 8(6), 3953–3961. Online: [www.ijcic.org/ijcic-11-02046.pdf](http://www.ijcic.org/ijcic-11-02046.pdf)
- KOZÁK Péter et al. (2022): Az aszály monitoring hálózat és az aszálykezelés gyakorlata a 2022. évi aszály tükrében. *Vízügyi Közlemények*, 104(3), 113–130. Online: [https://library.hungaricana.hu/en/view/VizugyiKozlomenyek\\_2022/?pg=458](https://library.hungaricana.hu/en/view/VizugyiKozlomenyek_2022/?pg=458)
- LANG, Bernhard et al. (2008): Neural Clouds for Monitoring of Complex Systems. *Optical Memory and Neural Networks*, 17(3), 183–192. Online: <https://doi.org/10.3103/S1060992X08030016>
- LIPTAY Zoltán Árpád (2024): Hidrológiai előrejelzés körszimmetrikus bázisfüggvény hálózatokkal. *Hidrológiai Közlöny*, 98(3), 1–33. Online: [www.hidrologia.hu/vandorgyules/41/word/0606\\_liptay\\_zoltan\\_arpad.pdf](http://www.hidrologia.hu/vandorgyules/41/word/0606_liptay_zoltan_arpad.pdf)
- LU, Shuang – HUANG, Jianyun – WU, Jing (2023): Knowledge Domain and Development Trend of Urban Flood Vulnerability Research: A Bibliometric Analysis. *Water*, 15(10). Online: <https://doi.org/10.3390/w15101865>
- Magyarország 2021. évi árvízkezelési terve* (2022). Online: [https://vizeink.hu/wp-content/uploads/2022/10/akk/Arvizkockazat-kezelesi\\_terv.pdf](https://vizeink.hu/wp-content/uploads/2022/10/akk/Arvizkockazat-kezelesi_terv.pdf)

- Magyarország Mesterséges Intelligencia Stratégiája (2025–2030)* (2025). Online: <https://cdn.kormany.hu/uploads/document/c/c0/c0d/c0dfdbd37cfa520ae37361a168d244c85e7295af.pdf>
- MELESE, Tadele et al. (2025): Machine Learning-based Drought Prediction Using Palmer Drought Severity Index and TerraClimate Data in Ethiopia. *PLoS One*, 2025. június 18. Online: <https://doi.org/10.1371/journal.pone.0326174>
- MOKHTAR, Ali et al. (2021): Estimation of SPEI Meteorological Drought Using Machine Learning Algorithms. *IEEE Access*, 9, 65503–65523. Online: <https://doi.org/10.1109/ACCESS.2021.3074305>
- MOSAVI, Amir – OZTURK, Pinar – CHAU, Kwok-wing (2018): Flood Prediction Using Machine Learning Models: Literature Review. *Water*, 10(11). Online: <https://doi.org/10.3390/w10111536>
- NEARING, Grey et al. (2024): Global Prediction of Extreme Floods in Ungauged Watersheds. *Nature*, 627, 559–563. Online: <https://doi.org/10.1038/s41586-024-07145-1>
- NEVO, Sella et al. (2022): Flood Forecasting with Machine Learning Models in an Operational Framework. *Hydrology and Earth System Sciences*, 26(15), 4013–4032. Online: <https://doi.org/10.5194/hess-26-4013-2022>
- OpenAlex lekérdezés – flood prediction. Online: [https://explore.openalex.org/works?page=1&filter=title\\_and\\_abstract.search:flood+prediction,type:types/article,primary\\_topic.id:t11490](https://explore.openalex.org/works?page=1&filter=title_and_abstract.search:flood+prediction,type:types/article,primary_topic.id:t11490)
- OpenAlex lekérdezés – 2000–2025, drought prediction. Online: [https://explore.openalex.org/works?page=1&filter=publication\\_year:2000-2025,title\\_and\\_abstract.search:drought+prediction,primary\\_topic.id:t11490,type:types/article&view=api,report,list](https://explore.openalex.org/works?page=1&filter=publication_year:2000-2025,title_and_abstract.search:drought+prediction,primary_topic.id:t11490,type:types/article&view=api,report,list)
- OPITZ, David – MACLIN, Richard (1999): Popular Ensemble Methods: An Empirical Study. *Journal of Artificial Intelligence Research*, 11, 169–198. Online: <https://doi.org/10.1613/jair.614>
- OYOUNALSOUD, Mhamd Saifaldeen et al. (2024): Drought Prediction Using Artificial Intelligence Models Based on Climate Data and Soil Moisture. *Scientific Reports*, 14. Online: <https://doi.org/10.1038/s41598-024-70406-6>
- PYAYT, Alexander et al. (2011): Machine Learning Methods for Environmental Monitoring and Flood Protection. *World Academy of Science, Engineering and Technology*, 54, 118–123. Online: [www.researchgate.net/publication/254762064](http://www.researchgate.net/publication/254762064)
- SAYERS, William et al. (2014): Artificial Intelligence Techniques for Flood Risk Management in Urban Environments. *Procedia Engineering*, 70, 1505–1512. Online: <https://doi.org/10.1016/j.proeng.2014.02.165>
- SCHAPIRE, Robert Elias (1990): The Strength of Weak Learnability. *Machine Learning*, 5, 197–227. Online: <https://doi.org/10.1023/A:1022648800760>
- SZABÓ János Adolf – LUCZA Zoltán – SZABÓ-MÁRKU Melinda (2024): Mesterséges Intelligencia (MI) alkalmazásának lehetőségei az árvízi előrejelzések pontosításában. In DOBÓ Kristóf et al. (szerk.): *A Magyar Hidrológiai Társaság által rendezett XLI. Országos Vándorgyűlés dolgozatai*. Budapest: Magyar Hidrológiai Társaság. Online: [https://hidrologia.hu/vandorgyules/41/word/0607\\_lucza\\_zoltan.pdf](https://hidrologia.hu/vandorgyules/41/word/0607_lucza_zoltan.pdf)

- TAN, Ling et al. (2021): Can We Detect Trends in Natural Disaster Management with Artificial Intelligence? A Review of Modeling Practices. *Natural Hazards*, 107, 2389–2417. Online: <https://doi.org/10.1007/s11069-020-04429-3>
- Vizet a tájba. Online: [www.ovf.hu/jobboldali-sav-tartalmai/vizetatajba/vizet-a-tajba](http://www.ovf.hu/jobboldali-sav-tartalmai/vizetatajba/vizet-a-tajba)
- WAHBA, Mohamed et al. (2023): A Novel Estimation of the Composite Hazard of Landslides and Flash Floods Utilizing an Artificial Intelligence Approach. *Water*, 15(23). Online: <https://doi.org/10.3390/w15234138>
- ZHOU, Shuyan (2025): Application of AI in Urban Flash Flood Risk Assessment: From Real-time Warning to Resilience Planning. *Applied and Computational Engineering*, 150(1), 9–14. Online: <https://doi.org/10.54254/2755-2721/2025.22398>