

SZEGEDI TUDOMÁNYEGYETEM
Természettudományi és Informatikai Kar
Földtudományok Doktori Iskola
Légkör- és Téradattudomány Tanszék

Belvízelöntés monitoring és előrejelző rendszer kialakítása gépi tanulási algoritmusok felhasználásával

Doktori (PhD) értekezés

Kajári Balázs

Témavezetők:

Dr. habil. Van Leeuwen Boudewijn
vezető kutató

Dr. Tobak Zsolt
egyetemi adjunktus

**Szeged
2025**

Tartalomjegyzék

1.	BEVEZETÉS, PROBLÉMAFELVETÉS	1
2.	IRODALMI ÁTTEKINTÉS	6
2.1.	A belvíz kialakulását befolyásoló tényezők	6
2.2.	Belvíz kutatások - történeti tapasztalatok és tanulságok	9
2.2.1.	A belvízvizsgálatok hagyományos becslési eljárásai és megfigyelési adatbázisai - alapok a modern térképezéshez	10
2.2.2.	Belvíz-veszélyeztetettségi térképezés, veszélytérképek	13
2.2.3.	Térinformatikai és távérzékelési módszerek alkalmazása a belvízvizsgálatokban	20
3.	ANYAG ÉS MÓDSZER	29
3.1.	A vizsgálati terület bemutatása	29
3.2.	Adatbázisok	30
3.2.1.	Műhold adatok	31
3.2.2.	Dinamikus adatok	31
3.2.3.	Statikus adatok	32
3.3.	A módszertani fejlesztés során alkalmazott szoftverkörnyezetek	34
3.4.	A belvíz detektáláshoz felhasznált módszerek	35
3.4.1.	Normalized Difference Vegetation Index (NDVI)	36
3.4.2.	Normalized Difference Water Index (NDWI)	36
3.4.3.	Modified Normalized Difference Water Index (MNDWI)	37
3.4.4.	Maximum Likelihood (ML)	37
3.4.5.	Support Vector Machine (SVM)	38
3.4.6.	Random Forest (RF)	38
3.4.7.	Artificial Neural Network (ANN)	39
3.4.8.	Deep Neural Network (DNN)	40
3.4.9.	Convolutional Neural Network (CNN)	40
3.4.10.	XGBoost	41
3.4.11.	Explainable AI (xAI) és SHAP-alapú változó rangsorolás	41
3.4.12.	Variance Inflation Factor (VIF)	41
3.4.13.	Gray-Level Co-occurrence Matrix (GLCM)	42
3.4.14.	Radar Vegetation Index (RVI)	42
3.5.	Sentinel-2-es előfeldolgozás	43
3.6.	Sentinel-1-es előfeldolgozás	48
3.7.	Pontossági vizsgálat és teljesítménymutatók	49
3.8.	A műholdfelvételek fúziója	52
3.9.	A belvízgyakorisági térkép létrehozásának módszertana	52
3.10.	Az előrejelző modell kialakításának módszertana	54
3.10.1.	Dinamikus bemeneti adatok	54

3.10.2.	Statikus bemeneti adatok	55
3.11.	A belvízelöntések tartósságának becslési módszertana	57
4.	EREDMÉNYEK	59
4.1.	Az adatbázisok strukturálása és modellezési célú összehangolása	59
4.1.1.	A műhold adatok összevetése	59
4.1.2.	A műholdfelvételek előfeldolgozási környezete	60
4.1.3.	Dinamikus adatok felhasználhatóságának értékelése	61
4.1.4.	A statikus adatok eredményei/ felhasználhatóságának értékelése	61
4.2.	A belvízdetektálásra legalkalmasabb módszer kiválasztása Sentinel–2 műholdfelvételek alapján	66
4.3.	Belvízdetektálás eredményei a Sentinel–1 műholdfelvételek alapján	82
4.4.	A belvízgyakorisági térkép	87
4.5.	Előrejelző rendszer	90
4.6.	Tartósság becslés	95
4.7.	Diszkusszió	97
5.	KONKLÚZIÓ	100
6.	ÖSSZEFOGLALÓ	101
7.	SUMMARY	105
8.	KÖSZÖNETNYILVÁNÍTÁS	108
9.	IRODALOMJEGYZÉK	109
10.	MELLÉKLETEK	119

Rövidítések:

AD – Allocation Disagreement – eloszlási eltérés
ANN – Artificial Neural Network – Mesterséges Neurális Hálózat
CM – Confusion matrix – Összetévesztési mátrix
CNN – Convolutional Neural Network – Konvolúciós neurális hálózat
CONTRAST – Contrast – Kontraszt
CORR – Correlation – Korreláció
DENT – Difference Entropy – Különbség entrópia
DISS – Dissimilarity – Különbözőség
DNN – Deep Neural Network– Mély Neurális Hálózat
DT – Decision Trees – Döntési fák
DVAR – Difference Variance – Különbségvariancia
ENT – Entropy – Entrópia
ESA – European Space Agency – Európai Űrügynökség
EU SoilGrids – Európai talajtani raszteradatbázis
F1 – F1–score – Harmonikus átlag
FC – Field Capacity – szántóföldi vízkapacitás
FN – False Negative – Hamis negatív: nem vízként jelölt pixel, amely a referenciatérképen víz (kihagyott vízborítás)
FP – False Positive – Hamis pozitív: vízként jelölt pixel, amely a referenciatérképen nem víz (tévesen víznek azonosított terület)
GBDT – Gradient Boosting Decision Tree – gradiens boosting döntési fa
GEE – Google Earth Engine
GLCM – Gray–Level Co–occurrence Matrix – Textúraindex
HLS – Harmonized Landsat and Sentinel–2 – harmonizált Landsat– és Sentinel–2–adatkészlet
IDM – Inverse Difference Moment – Inverz különbségi momentum
IDW – Inverse Distance Weighting – Inverz távolság súlyozás
IEW – Inland Excess Water – Belvíz
IMCORR1 – Informational Measure of Correlation 1 – Információs korrelációs mérték 1
IMCORR2 – Informational Measure of Correlation 2 – Információs korrelációs mérték 2
INERTIA – Inertia – Tehetetlenség
IPCC – Intergovernmental Panel on Climate Change – Éghajlatváltozási Kormányközi Testület
 κ – Kappa–index – Cohen–féle Kappa index – Kappa index osztályozási pontosság
KS – Saturated Hydraulic Conductivity – Telített hidraulikus vezetőképesség
LIDAR – Light Detection and Ranging – Lézer alapú távérzékelés
LSTM – Long Short–Term Memory – Hosszú–rövid távú memória
MAXCORR – Maximum Correlation Coefficient – Maximális korrelációs együttható
ML– Maximum Likelihood – Legnagyobb valószínűség
MNDWI – Modified Normalized Difference Water Index – Módosított Víz Index


NDVI – Normalized Difference Vegetation Index – Vegetációs Index
NDWI – Normalized Difference Water Index – Víz Index
NIR – Near-infrared – Közeli infravörös spektrális sáv
OA – Overall Accuracy – Összesített pontosság
PA – Producer’s Accuracy – Előállítói pontosság
PET – Potential Evapotranspiration – Potenciális evapotranszpiráció
PROM – Cluster Prominence – Klaszter kiemelkedés
QADI index – Quantity and Allocation Disagreement Index – Mennyiségi és eloszlási eltérés index
QD – Quantity Disagreement – Mennyiségi eltérés
Recall – Felidézési arány
ReLU – Rectified Linear Unit – Egyenesített lineáris egység
RF – Random Forest – Véletlen erdő
RVI – Radar Vegetation Index – Radar Vegetációs Index
SAR – Synthetic Aperture Radar – Szintetikus apertúrájú radar
SAVG – Sum Average – Összegátlag
SCL – Scene Classification Layer – Műholdfelvétel osztályozási réteg
Sen2Cor – Sentinel-2 Correction – Sentinel-2 felvételek légköri zavarok korrekciós szoftvere
Sensitivity – Érzékenység
SENT – Sum Entropy – Szumma entrópia
SHADE – Cluster Shade – Klaszterárnyék
SHAP– Shapley Additive Explanations – Shapley-alapú additív magyarázatok
SVAR – Sum Variance – Összegzett variancia
SVM – Support Vector Machine – Tartóvektor-gép
SWIR – Short-Wave Infrared – rövidhullámú infravörös spektrális sáv
THS – Topsoil Hydraulic Saturation – telített víztartalom
TN – True Negative – Igaz negatív: nem vízként jelölt pixel, amely a referenciatérképen is nem víz (helyes száraz terület detektálás)
TP – True Positive – Igaz pozitív: vízként jelölt pixel, amely a referenciatérképen is víz (helyes vízdetektálás)
UA – User’s Accuracy – Felhasználói pontosság
VAR – Variance – Variancia
VH – Vertical transmit – Horizontal receive – Vertikális adás – Horizontális vétel
VIF – Variance Inflation Factor – változók közötti korreláció vizsgálata
VV – Vertical transmit – Vertical receive – Vertikális adás – Vertikális vétel
WP – Wilting Point – Hervadáspon
xAI – explainable AI – Magyarázható mesterséges intelligencia
XGBoost – Extreme Gradient Boosting – Extrém Gradiensnöveléses döntési fák

1. BEVEZETÉS, PROBLÉMAFELVETÉS

Magyarország síkvidéki mezőgazdasági területein a belvíz rendszeresen visszatérő, jelentős gazdasági károkat okozó természeti jelenség. A védekezés és a kármegelőzés érdekében az illetékes hatóságok évről évre jelentős erőforrásokat mozgósítanak. A Központi Statisztikai Hivatal [1] adatai szerint az ország művelésre alkalmas területének nagy része mezőgazdasági hasznosítású, amelyből megközelítőleg 1,8 millió hektár minősül belvízzel veszélyeztetettnek (Szlávik, 2016).

Az 1991–2002 közötti időszakban az időszakos belvízborítás éves átlaga Magyarországon mintegy 91 ezer hektár volt, ugyanakkor több évben is jelentős, nagy kiterjedésű elöntések alakultak ki (Pálfai, 2004). A legsúlyosabb elöntések 1999-ben és 2000-ben jelentkezték, amikor a belvízzel borított terület nagysága meghaladta az 500 ezer hektárt (Kozák, 2006; Pálfai, 2006; Somlyódy, 2011). A 2010-es év során például több mint 230 ezer hektár területet érintett a belvíz, ami becslések szerint több mint nyolcmilliárd forint kárt okozott [2]. Az Országos Vízügyi Főigazgatóság (OVF) adatai alapján 2013-ban szintén jelentős elöntések történtek, mintegy 155 ezer hektárt érintve. Ezt követően 2015 és 2016 is belvizes időszakként számított, egyenként közel 123–124 ezer hektáros érintettséggel, míg 2018-ban az elöntött területek nagysága elérte a 218 ezer hektárt (Bíró, 2017). A belvíz által okozott közvetlen termelési károk és a védekezés költségei az elmúlt két évtized során több mint 20 milliárd forintba tehetők [3].

Vízkárelhárítás, vízkárok és a védekezés költségei



1. ábra: Az árvíz és a belvíz okozta károk és védekezés költségei 2000-2022-ig [3]

A legfrissebb éghajlatváltozási előrejelzések szerint, a magas intenzitású csapadékesemények gyakorisága és súlyossága a jövőben várhatóan növekedni fog (Lee et al., 2023). A regionális klímamodellek szimulációi alapján a Kárpát-medencében az egyszerre lehulló csapadékmennyiség egyre nagyobb változékonyságot és szélsőséges jelleget mutat (Mezősi et al., 2013, 2017; Birinyi et al. 2023; Bezdan et al., 2024), ami közvetlenül hozzájárulhat a belvíz kialakulásának gyakoribbá és kiszámíthatatlanabbá válásához. Jó példát szolgáltat erre a 2000-es év, amikor belvizes és aszályos időszakok egyaránt előfordultak, szemléltetve az éghajlati szélsőségek térbeli és időbeli egyidejűségét (Pálfai, 2013).

A belvíz időszakos, kiterjedt megjelenése és visszahúzódása komplex hidrológiai folyamat, amelyet elsősorban a kialakító és megszüntető hatótényezők időbeli eltolódása határoz meg. A területi vízmérleg – azaz a beszivárgás, párolgás és lefolyás együttes viszonya – alapvetően befolyásolja a belvíz kialakulásának mértékét és időtartamát. A folyami és part menti árvizekkel szemben a belvíz a mentett oldalon lokálisan felgyülemelő, lefolyással nem rendelkező víztöbblet, amely hosszabb ideig is felszínen maradhat. A belvíz tartósságát számos természeti tényező – így például a meteorológiai viszonyok, a talajtípus, a talajvíz mélysége, a sekélyföldtani adottságok és a domborzat – mellett jelentős mértékben befolyásolják az emberi

tevékenységek is, mint például a belvízelvezető csatornahálózat kiépítettsége, a vízkormányzás és szivattyús rendszerek működése, az aktuális földhasználat, valamint az alkalmazott agrotechnikai beavatkozások (Kozák, 2003, 2005).

A belvíz mezőgazdasági kárai elsősorban a termés hozam csökkenésében, a termények minőségének romlásában, illetve különböző talajdegradációs folyamatok elindulásában nyilvánulnak meg, ugyanakkor a tenyészidőszak eltolódása/leszűkülése is közvetett gazdasági veszteségeket okozhat. Különösen fontos tényező a belvízelöntés éven belüli megjelenési ideje: a téli és kora tavaszi hónapokban a növények a nyugalmi állapotuk miatt jobban tolerálják a vízborítást, míg a vegetációs időszakban – különösen nyáron – már néhány napos vízborítás is súlyos károkat, akár a teljes állomány pusztulását eredményezheti (Petrasovits, 1959; Vajdai, 1975; 2. ábra).



2. ábra: A nyári időszakban megjelenő belvizek károkozása (Fotó: Túri N., Szentes-Veresháza, 2016)

A belvíz hosszabb távú hatásai a talaj állapotát is kedvezőtlenül befolyásolják: az elöntések következtében bekövetkező feliszapolódás, a tápanyagok kimosódása és a levegőtlené váló környezet a talajszerkezet degradációjához és a termékenység csökkenéséhez vezet (Barta et al., 2013; Bíró, 2017; Szilávik, 2016).

A belvízzel borított területek elöntéseinek lehatárolása sokáig főként terepi megfigyeléseken alapult. A vízügyi igazgatóságok rendszeresen dokumentálták az elöntéseket, és azokat térképeken is megjelenítették, amelyek hasznos információkkal szolgáltak a védekezés és tervezés számára (Van Leeuwen, 2012). Az elemzésekhez általában több éves vagy évtizedes megfigyelések alapján készített vízháztartási egyenleteket használtak fel (Pálfai, 1988).

Az 1990-es évektől kezdődően a belvízkutatásban egyre hangsúlyosabbá váltak az integrált megközelítések, amelyek az ökológiai és fenntarthatósági szempontokat is figyelembe vették. Egyes kutatások hidrológiai modellező eszközöket alkalmaztak a belvíz szimulációjára (Bíró, 2017; Van Leeuwen et al., 2016; Kozma, 2022). Ezek a módszerek ugyanakkor nagy mennyiségű, térben és időben pontos bemeneti adatot igényelnek, amelyek rendelkezésre állása sok esetben csak korlátozott területekre biztosított.

A modern technológiák, mint a térinformatikai rendszerek, a távérzékelési eljárások és a hidrológiai modellezés, jelentős mértékben hozzájárultak a belvíz térképezési módszertanának fejlődéséhez (Tobak et al., 2008; Balázs, 2010; Tsitsi et al., 2021; Birinyi et al. 2023, 2024; Cian et al., 2024; Bezdan et al., 2025). A pilóta nélküli légi járművek (UAV - Unmanned Aerial Vehicle), repülőgépes légi felvételezések, valamint a műholdak aktív és passzív szenzorai megfelelő térbeli és időbeli felbontású adatokat biztosítanak a belvizes területek vizsgálatához. A belvízképződést meghatározó tényezők és a tényleges elöntési előfordulások közötti kapcsolat feltárására többek között statisztikai módszereket, például multilineáris regressziós modellezést is alkalmaztak, különösen a belvíz-veszélyeztetettségi térképezés során (Thyll és Bíró, 1999; Bíró et al., 2000; Bozán et al., 2018; Pásztor et al., 2020).

A belvíz-veszélyeztetettségi térképezés célja a potenciális kockázati zónák azonosítása, vagyis annak becslése, hogy hol, milyen valószínűséggel alakulhat ki belvízi elöntés - akkor is,

ha adott időszakban tényleges elöntés nem következett be. E prediktív térképek készítése során a modellezés jellemzően a meteorológiai viszonyokat, a domborzatot, a talajtani adottságokat, a talajvíz mélységét, a sekélyföldtani viszonyokat, a vízelvezető rendszer állapotát, valamint a területhasználatot is figyelembe veszi (Bozán et al., 2021).

Ezzel szemben a belvízgyakorisági térképezés célja empirikus adatokon – jellemzően műholdas idősorokon, távérzékelte felvételeken és terepi felméréseken – alapulva feltárni, hogy egy adott időszakban valójában hol és milyen gyakorisággal fordult elő belvízi elöntés (Mucsi és Henits, 2011; Túri et al., 2022; Birinyi et al., 2024; Kajári és Van Leeuwen, 2024a). Az így előállított térképek a bekövetkezett elöntések tapasztalati alapú térbeli és időbeli mintázatát jelenítik meg, ezáltal alkalmasak a belvízi dinamika monitorozására, trendvizsgálatokra, valamint utólagos értékelésekre és elemzésekre.

Az elmúlt években a neurális hálózatok, különösen a mély neurális hálózatok – ezen belül kiemelten a konvolúciós neurális hálózatok (CNN) – egyre szélesebb körű alkalmazást nyertek a földtudományokban (Szatmári et al., 2011; Van Leeuwen, 2012; Simón Sánchez et al., 2022; Yichen et al., 2022; Giulia et al., 2023). Ezeket a módszereket mind gyakrabban alkalmazzák felszíni vízfelületek automatikus detektálására is, a hagyományosan legszélesebb körben használt spektrális indexek – például az Normalized Difference Vegetation Index (NDVI), az Normalized Difference Water Index (NDWI), és a Modified Normalized Difference Water Index (MNDWI) – mellett. Ugyanakkor a klasszikus gépi tanulási algoritmusok, mint a Maximum Likelihood (ML), a Random Forest (RF), és a Support Vector Machine (SVM) szintén széles körben alkalmazott eszközök maradtak a felszínborítási és vízborítottsági osztályozási feladatokban (Kaplan és Avdan, 2017; Jin et al., 2018; Miao et al., 2018; Varga et al., 2021).

A belvízi elöntések kiterjedése és tartóssága által okozott természeti, gazdasági és infrastrukturális károk, valamint a klímaváltozás következtében egyre gyakoribbá váló szélsőséges időjárási jelenségek – aszályok és belvizek váltakozása – rávilágítanak arra, hogy a vízviSSzatartás lehetőségeinek és a belvízkezelés új szemléletű megközelítésének tudományos vizsgálata továbbra is elengedhetetlen. Bár a belvizek Magyarországon elsősorban gazdasági károkozó jelenségként élnek a köztudatban, időszakos megjelenésük jelentős ökológiai és természetvédelmi értékkel is bír (Bartholy et al., 2011). A belvizes foltok ritka és veszélyeztetett növényfajok fontos élőhelyei lehetnek, és hozzájárulnak a biodiverzitás megőrzéséhez, a táji vízmegtartáshoz és a mikroklíma szabályozásához (Pál et al., 2006; Molnár és Lukács, 2014). Az elmúlt évek kutatásai megerősítették, hogy a klasszikus vízelvezetés–központú megközelítést fokozatosan felváltja a vízviSSzatartás és az ökológiai vízgazdálkodás iránti igény (Balogh, 2001; 2003; Szinay, 2009; Kozma et al., 2023; Kozák et al., 2024). A 2020-as években előtérbe került a vízviSSzatartás, az ökológiai vízpótlás és a természetes élőhelyek vízigényének figyelembevétele. Ennek egyik kulcsfontosságú programja a „*Vizet a tájba!*” kezdeményezés [4], amely az agroökológiai elvek mentén a csapadék– és felszíni vizek helyben tartását, a talaj vízmegtartó képességének javítását és a csatornahálózatok ökológiai célú hasznosítását ösztönzi. A kapcsolódó jogi és támogatási keretrendszert az Agro-ökológiai Program (AÖP) biztosítja, amely a Közös Agrárpolitika (KAP, [5]) Stratégiai Terv (2023–2027) részeként került bevezetésre [6]. E szemléletváltás új alapokra helyezi a belvizes élőhelyek kezelését, és lehetőséget kínál az ökológiai értékek megőrzésére is.

Egy innovatív belvíz–megfigyelési és monitorozási modell kialakítása új lehetőségeket teremthet arra, hogy a jelenleg elérhető, statikus pillanatképek helyett nagy területre kiterjedő, folyamatosan frissülő, dinamikus adatokon alapuló belvíz–gyakorisági térképezés és rövid távú előrejelző rendszer jöjjön létre. Ez a megközelítés nemcsak a védekezés hatékonyságát növelhetné, hanem célzottan kijelölhetné a vízviSSzatartásra legalkalmasabb területeket is, ezáltal hozzájárulva a mezőgazdasági termelékenység fenntartásához és a stratégiai vízgazdálkodási tervezéshez. A modell közvetlen támogatást nyújthatna a döntéshozók számára a védekezési prioritások meghatározásában, és megnyitná az utat a természetközeli vízgazdálkodási megoldások – így például a területhasználatot is figyelembe vevő ökológiai vízviSSzatartási stratégiák – szélesebb körű alkalmazása előtt.

Az értekezés célkitűzései

A belvíz összetett, interdiszciplináris hidrológiai jelenség, amelynek vizsgálata a természetföldrajzi és antropogén tényezők integrált értelmezését igényli. A kutatás célja olyan térinformatikai és távérzékelésen alapuló módszertani keret kidolgozása, amely alkalmas a belvízzel érintett területek pontos azonosítására, időbeli monitorozására, modellezésére és prediktív előrejelzésre. Különös figyelmet kap a Sentinel-1 (radaros) és Sentinel-2 (multispektrális) műholdfelvételek alkalmazhatósága, mivel ezek országos szinten is biztosítanak rendszeres és ingyenes adatelérést.

A kutatásom során az alábbi célokat határoztam meg, melyeket a továbbiakban részletesen is kifejték:

- (1) Az adatbázis- és modellépítés peremfeltételeinek meghatározása.
- (2) Műholdas távérzékelési alapú módszerek összehasonlítása, alkalmazhatóságának vizsgálata a belvízelöntések detektálhatósága szempontjából.
- (3) A multispektrális és a radaros műholdfelvételek kombinált alkalmazhatóságának vizsgálata.
- (4) A belvízelöntések kiterjedésének és időbeli tartósságának összefüggésvizsgálata.
- (5) Komplex értékelésen alapuló belvízelöntés tartóssági predikció módszertanának kidolgozása.

A kutatás alapvető célja egy olyan **alkalmazható és adaptálható módszertan kidolgozása**, amely egyrészt biztosítja a belvízdetektáláshoz szükséges adatok rendszerezését, másrészt lehetőséget nyújt hatékony prediktív modellek fejlesztésére **a síkvidéki területeken jelentkező belvízdetektálási problémák megoldására**, mindemellett figyelembe véve a fenntarthatóság és a gazdaságosság szempontjait. A fejlesztés során az alábbi kérdések megválaszolására töreksem:

A modell kidolgozása során elengedhetetlen (1) **a bemeneti peremfeltételek meghatározása, amelyek kijelölik az alkalmazható adatbázisok körét és a fejlesztés irányát**. Egy folyamatosan frissülő modell esetében kiemelten fontos, hogy az adatokhoz való hozzáférés hosszú távon is biztosított, lehetőleg térítésmentesen vagy alacsony költségen, ezáltal elősegítve a rendszer fenntarthatóságát. További lényeges kérdésként merül fel a modell területi léptékének meghatározása: lokális, belvízöblözeti, vármegyei, vízgyűjtői vagy országos szintű vizsgálatra is alkalmas legyen-e. A kutatásom során realizáltam, hogy célszerű az ország síkvidéki térségeit egységes lefedettséggel működő modell kialakítása. Ez a döntés ugyanakkor korlátozta a felhasználható adatforrásokat, főként a távérzékelési adatok tekintetében. Bár a drónos- és egyéb földközeli légi felvételek kiváló térbeli felbontást biztosítanak, alkalmazásuk költségigénye és frissítési nehézségei - különösen a műholdképek csempéivel összehasonlítva korlátozott területi lefedettségük miatt - erősen behatárolják gyakorlati használhatóságukat. Ezért a modell alapját elsősorban a műholdas adatok jelentik, amelyek széles körben hozzáférhetők, és megfelelő kompromisszumot kínálnak a felbontás, a lefedettség és a frissítési gyakoriság szempontjából. Ebben a kérdéskörben az alábbiakra keresem a választ:

1. Léteznek-e olyan költséghatékony multispektrális és radaros műholdfelvételek, amelyek megfelelő időbeli és térbeli felbontást biztosítanak Magyarország síkvidéki területein a belvízlehatárolás szempontjából?
2. A Sentinel-1 radar- és Sentinel-2 multispektrális felvételek térbeli felbontása elegendő-e a belvízelöntések pontos és megbízható lehatárolásához?
3. Integrálhatók-e a Sentinel-1 és Sentinel-2 műholdfelvételek hatékonyan a síkvidéki belvizek azonosítására és előrejelzésére szolgáló térinformatikai modellezési folyamatokba?

Módszertani megközelítések

A kutatás kezdeti szakaszában szakirodalmi adatok és előzetes elemzések révén vizsgálom meg, hogy (2) ***milyen távérzékelési alapú módszerek állnak rendelkezésre a belvizes területek lehatárolására.*** A célom az, hogy az elérhető eljárások közül azokat azonosítsam, amelyek a legszélesebb körben alkalmazottak, és amelyek kellő pontosságúak, illetve újrafelhasználhatóság szempontjából is megbízható alapot nyújthatnak a modellfejlesztéshez. A vizsgálatok középpontjában az alábbi kutatási kérdések álltak:

4. Nyújtanak-e a szabványosított távérzékelési alapú feldolgozási módszerek – például indexek, felügyelt osztályozási eljárások, hagyományos gépi tanulási algoritmusok vagy mélytanulási hálózatok – kellően nagy pontosságot a vízborítottság megbízható lehatárolásához?

5. Alkalmaznak-e bizonyos távérzékelési módszerek az idősoros elemzésekre, különösen a belvívelöntések gyakoriságának és dinamikájának vizsgálatában?

6. Képesek-e a mesterséges intelligencián alapuló módszerek (pl. konvolúciós neurális hálózatok) felülmúlni a hagyományos megközelítéseket a belvizek detektálásának pontosságában és megbízhatóságában?

Integráció és előrejelzések

A multispektrális felvételek visszatérési ideje, és a légköri zavarok által használhatatlan, vagy csak korlátozottan felhasználható felvételek miatt a napi szintű monitoring létrehozásához és (3) ***az adatok "sűrítése" érdekében a radaros műholdfelvételek egy alternatív megoldást jelenthetnek,*** mert függetlenek a fényviszonyoktól és a felhőborítottságtól. Ennek vizsgálatához a következő kutatási kérdést fogalmaztam meg:

7. Alkalmaznak-e a Sentinel-1 radaros műholdfelvételek önállóan a vízborítás pontos és megbízható lehatárolására?

Két különböző típusú – multispektrális és radaros – műholdfelvételekből lehatárolt vízfelületek eredményei alapján a következő kérdéseket tettem fel:

8. Lehetséges-e a multispektrális és radaros műholdfelvételek hatékony integrációja (fúziója) a belvizek lehatárolás céljára?

9. Növelhető-e a belvízi gyakorisági térképek pontossága a multispektrális és radaros adatok integrációjával?

A (4) napi szintű elöntés térképek alkalmazásával lehetőség nyílik az ***elöntések időbeli tartósságának vizsgálatára*** is. Ennek kapcsán a következő kérdés fogalmazódott meg:

10. Kimutatható-e statisztikailag is szignifikáns összefüggés a belvívelöntések kiterjedése és időbeli tartóssága között?


Végül, a mintaterületen végzett vizsgálatok során az elkészített napi vízlehatárolási modelleket kiegészítem különböző statikus (pl. domborzati, talajtani) és dinamikus (pl. meteorológiai) tényezőkkel, mely lehetővé teszi a (5) ***belvívelöntések predikcióját.*** Mindezt az alábbi kérdések megválaszolásával igazolom:

11. Javítja-e a belvívelöntésekre vonatkozó predikciók pontosságát a műholdfelvételek statikus (pl. domborzati, talajtani) és dinamikus (pl. meteorológiai) adatokkal való kiegészítése?

12. Játsszanak-e érdemi szerepet ezek a kiegészítő adatok a predikciós modellek megbízhatóságának és alkalmazhatóságának növelésében?

2. IRODALMI ÁTTEKINTÉS

A mai értelemben vett belvízről, mint hidrológiai jelenségről, a 19. század közepén megkezdett nagy folyószabályozási munkálatokat követően beszélhetünk. Ezt megelőzően a síkvidéki vízfolyások egykori árterein élő lakosság alkalmazkodott a folyók szeszélyes vízjárásához, kihasználták a táj ezen adottságait (3. ábra). A Tisza és mellékfolyóinak szabályozása elsősorban gazdasági célok mentén zajlott, mint például az árvízvédelem, a hajózhatóság javítása, a mezőgazdasági területek bővítése, valamint a vízenergia-hasznosítás (Dunka et al., 1996).



3. ábra: A történelmi Magyarország vízborította és árvízjárta területei az ármentesítő és lecsapoló munkálatok előtt, 1856, (Dunka et al, 1996)

“Most érkeztem a Sárrétről, s tele vagyok benyomásokkal. A Sárrét Bihar, Békés, sőt a jász és a kun vármegyéken terült el, s még ötven évvel ezelőtt az Ecsedi-láppal versengő nagy mocsárterület volt.” (Móricz Zsigmond, 1935)

Móricz sorai a táj eredeti, természetes állapotára utalnak, amely azóta a vízrendezési munkák következtében jelentős átalakuláson esett át. Ennek eredményeként a térség mára túlnyomórészt mezőgazdasági hasznosítású, antropogén módon befolyásolt tájjá alakult.

Az elmúlt több mint 150 évben a belvíz kialakulásának és megszűnésének vizsgálatát több irányból közelítették meg: egyes kutatások a természeti tényezőkre összpontosítottak (hidrológiai, hidraulikai, geomorfológiai, éghajlati hatások), míg mások a vízgazdálkodási, mezőgazdasági és veszélyeztetettségi szempontok alapján térképezték fel a jelenséget.

A fejezet célja, hogy bemutassa e vizsgálati irányok fejlődését, valamint rendszerezze azokat a tényezőket és módszereket, amelyek a belvízkutatás különböző szakaszaiban meghatározó szerepet játszottak. A hangsúly elsősorban a magyarországi sajátosságokon és eredményeken van, ugyanakkor a nemzetközi kutatási tapasztalatok is jelentős hatással voltak az hazai vizsgálatokra.

2.1. A belvíz kialakulását befolyásoló tényezők

A belvíz kialakulása számos természeti és antropogén tényező együttes hatásának eredménye, amelyek komplex és dinamikus rendszert alkotnak. A természeti tényezők két fő csoportra oszthatók: statikus és dinamikus tényezőkre.

A statikus tényezők időben nem, vagy csak nagyon kis mértékben változnak, például a (1) domborzati, (2) talajtani, (3) földtani adottságok, a (4) talajvízszint jellemzői, valamint az (5) antropogén és (6) területhasználati viszonyok. A dinamikus tényezők közé tartoznak például a

(7) hidrometeorológiai adatok, mint a csapadék, hőmérséklet, evapotranszpiráció és szélsőségek.

A belvíz kialakulásának és megszűnésének vizsgálata során ezen tényezők hatásait nehéz elkülöníteni egymástól, mivel azok kölcsönösen befolyásolják egymást. Ezért a belvíz kialakulásának és megszűnésének ok-okozati összefüggéseinek feltárása komplex szemléletmódot igényel, amely magában foglalja mind a természeti, mind az emberi hatások integrált elemzését (Kozák, 2006; Balázs, 2015; Bozán, 2021).

A statikus tényezők közül elsőként a domborzat szerepét emelem ki, amely alapvetően meghatározza a vízmozgásokat a síkvidéki térségekben. A síkvidéki területek, különösen az Alföld domborzati sajátosságai jelentősen meghatározzák a belvíz kialakulásának lehetőségét, mivel a csekély lejtés és a szinte lefolyástalan felszín akadályozza a természetes vízelvezetést (Bulla, 1954). Fontos azonban kiemelni a mikrodomborzati különbségek meglétét, amelyeknek „köszönhetően” a víz gyakran összegyülekezik a lefolyástalan mélyedésekben, eltemetett folyómedrekben és laposokban, főként, ha a talaj vízzel telített, és a beszivárgás minimális (Kienitz, 1974; Valipour, 2014). A természetes formák mellett az emberi beavatkozások által létrejött geomorfológiai elemek – például magasított utak töltései, vasútvonalak töltései, nem megfelelően kialakított és karbantartott csatornák – tovább nehezítik a víz elfolyását, mesterséges elöntéseket okozva (Kozák, 2003; Barta és Szatmári, 2010; Rakonczai et al., 2011; Benyhe, 2013).

A domborzati adottságok által meghatározott vízmozgások hatása a talajviszonyokon keresztül érvényesül tovább, hiszen a mikrodomborzati formákban felgyülemelő víz sorsa elsősorban a talaj vízáteresztő képességétől függ. Az Alföld agroökológiai adottságai általában kedvezőek, azonban a vízgazdálkodási szélsőségek – így a belvíz – gyakran problémát okoznak, különösen a szélsőséges időjárás és a talajok eltérő vízdinamikai viselkedése miatt (Várallyay, 2008). A belvíz kialakulásában a talaj vízbefogadó és vízáteresztő képessége kulcsszerepet játszik, amit elsősorban a pórusméret-eloszlás határoz meg. A tartós vízborítás strukturális degradációhoz vezet, amely rontja a talaj víz- és levegőgazdálkodását (Puskás et al., 2012; Gál és Farsang, 2013). A különböző talajtípusok belvízre való hajlama jelentősen eltér: míg a homoktalajoké alacsony, az agyagos és szikes talajoké kiemelkedően magas (Várallyay, 1980). A talajtömörödés – különösen mezőgazdasági gépek hatására – tovább fokozza a belvízre való érzékenységet. A csernozjom talajok esetében a gyakori elöntések hosszú távon szerkezeti károsodást is eredményezhetnek (Gál et al., 2015; 2017).

A talaj vízdinamikai tulajdonságai szoros kapcsolatban vannak az alatta elhelyezkedő földtani rétegekkel, amelyek rétegzettség és vízvezető képessége alapvetően befolyásolja a felszín alatti vízmozgásokat. Az Alföld földtani szempontból egy mély szerkezeti medence, amelyet vastag, főként neogén és negyedidőszaki üledéksorozat fed. A pleisztocén és holocén időszak során kialakult felszíni rétegek – különösen az ártéri finomszemcsés üledékek és a futóhomok - meghatározzák a vízháztartási viszonyokat. A rétegsorban váltakozó vízvezető (pl. homok, kavics) és vízzáró (agyag, márga) képződmények jelentős hatással vannak a beszivárgásra és a víz tározódására. A vízzáró rétegek jelenléte, különösen síkvidéki környezetben, elősegíti a felszíni víz felhalmozódását, ezáltal fokozva a belvíz kialakulásának esélyét. Az alapköveti szerkezet, a rétegzettség és a talajvízdinamika összjátéka meghatározó a belvíz térbeli eloszlásában és időbeli tartósságában (Fülöp, 1989).

Az altalaj szerkezeti és vízvezető jellemzői egyértelműen meghatározzák a talajvízszint helyzetét és ingadozását, amely szintén fontos tényező a belvízveszély kialakulásában. A talajvízszint és annak szezonális ingadozása alapvető szerepet játszik a belvíz kialakulásában, különösen Magyarország síkvidéki térségeiben. A talajvíz viselkedését a csapadék, az evapotranszpiráció, valamint a felszíni és felszín alatti vízáramlások együttesen szabályozzák, amelyek közvetlenül befolyásolják a talaj víztartó kapacitását és a felszíni vízborítottság mértékét (Rakonczai és Kovács, 2009; Túri et al., 2016; Barta et al., 2021).

A belvízképződés különböző típusainak rendszerezése segíti a belvízborítás kialakulási mechanizmusainak megértését és a vízgazdálkodási beavatkozások célzottabb megtervezését.

Rakonczi (2011) három fő típust különít el a víz eredete alapján: (1) az összegyülekezési típusú belvizek elsősorban a csapadék felszíni felhalmozódásából, (2) a feltörő-felszivárgó típusúak a talajvíz mozgásából, (3) míg az elvezetési problémákból származó belvizek, amelyek az elégtelen infrastruktúra következményeként alakulnak ki. E típusok gyakran együttesen is jelen vannak, a kialakulásukat a domborzat, a talaj, a talajvízszint és az emberi beavatkozások komplex interakciója befolyásolja.

E típusbesorolást egészíti ki Patay és Montvajszi (2011) morfológiai alapú megközelítése, amely a belvízfoltok térbeli formáit és geometriai mintázatait vizsgálta archív térképek alapján. A kutatók öt altípust különítettek el: barázda-, árok-, medence-, ikermedence- és fűzér-típusú belvizek, amelyek a felszínművelés, korábbi vízfolyások és talajviszonyok függvényében különböző hidrológiai viselkedést mutatnak. A belvíz típusa és megjelenési formája egyszerre függ genetikai, geomorfológiai és antropogén tényezőktől. A jelenség pontosabb értelmezése érdekében a genetikai (vízeredet szerinti) és a morfológiai (felszínalapú) osztályozások integrált alkalmazása javasolt.

Kozák (2006) szerint a magas talajvízszint – különösen felszínközeli állapot esetén – jelentősen növeli a belvízveszély kockázatát és időtartamát. A talajvíz ilyen viselkedése Rakonczi (2011) tipológiájához képest további három mechanizmuson keresztül járulhat hozzá a belvíz megjelenéséhez: (1) a magas talajvízszint csökkenti a csapadék beszivárgását, ami felszíni vízfelhalmozódást eredményez; (2) a finomszemcsés üledékeken a kapilláris emelkedés telítette teszi a felső talajrétegeket; (3) a földárja jelenség során nyomás alatt lévő talajvíz törhet a felszínre, tartós vízborítottságot okozva. Ezek a folyamatok síkvidéki térségekben, vízzáró talajok mellett válhatnak dominánssá.

A természetes rendszerek mellett a területhasználat módja is jelentős befolyással bír: az emberi tevékenységek gyakran fokozzák vagy módosítják a belvízre való hajlamot. A területhasználat az egyik legmeghatározóbb antropogén tényező a belvíz kialakulásában (Körösparti et al., 2022). A mezőgazdasági gépesítésből eredő talajtömörödés, a monokultúras gazdálkodás és a mezőgazdasági táblák mentén csökkenő vegetációborítottság jelentősen rontja a talaj vízbefogadó képességét. Emellett az alulméretezett és elhanyagolt vízelvezető rendszerek is fokozzák a vízvisszatartás problémáit.

A hosszú távú területhasználati változások – például az erdőirtás vagy a természetes élőhelyek mezőgazdasági célú átalakítása – tovább növelik a belvízre való hajlamot, míg az elhanyagolt csatornahálózatok karbantartási hiányosságai tartós vízborítottságot eredményezhetnek. A helytelen területhasználat tehát közvetlen és közvetett módon is hozzájárul a belvíz kialakulásához, amely megfelelő vízgazdálkodási és agrárökológiai intézkedésekkel mérsékelhető (Szilassi, 2015).

A földhasználat- és felszínborítás-változás (Land Use and Land Cover Change, LULC) önmagában is antropogén tényező, amelyet az emberi tevékenységek – különösen a mezőgazdaság, az infrastruktúra-fejlesztés és az urbanizáció – jelentős mértékben módosítják a felszíni és felszín alatti vízmozgásokat, ezáltal növelve a belvíz kialakulásának kockázatát. A 19. századi folyószabályozások és lecsapolási munkálatok (pl. Tisza-völgy) hosszú távon megváltoztatták a természetes vízelvezetési rendszereket, a gátak és csatornák több térségben a víz visszatartásához, pangásához vezettek (Rakonczi, 2011).

A mezőgazdasági géphasználat talajtömörödést (eketalp, tárcsatalp) idéz elő, amely csökkenti a vízbefogadó és -áteresztő képességet (Gál és Farsang, 2013), míg a monokultúras termesztés és a mélyen gyökerező növények hiánya rontja a talaj vízmegtartó kapacitását. A helytelen földhasználati gyakorlatok tovább fokozzák a felszíni vízgyülekezés mértékét (Kun et al., 2012). Urbanizált környezetben a burkolt felszínek aránya nő, a zöldterületek aránya csökken, miközben a csapadékvíz-elvezető rendszerek gyakran alulméretezettek, így a lokális elöntések gyakoribbá válnak (Barta és Szatmári, 2010; Kozák, 2011). Az egykori holtágak és vizes élőhelyek eltüntetése, valamint az erdőirtások is hozzájárulnak a vízháztartási egyensúly felborulásához.

Mivel az antropogén beavatkozások szinte minden más tényezőtípusra (talaj, domborzat, éghajlat, mikrodomborzat stb.) hatással vannak, a belvízprobléma csak integrált, ökoszisztéma-alapú területhasználati és vízgazdálkodási stratégiákkal kezelhető hatékonyan (Pinke, 2012; Szilassi, 2015).

Mindezekre a statikus rendszerekre a legközvetlenebb hatást az éghajlati és hidrometeorológiai tényezők gyakorolják, amelyek kiváltó szerepet játszanak a belvízi események megjelenésében. Magyarország a mérsékelt öv három éghajlati zónájának határán fekszik, ami jelentős regionális különbségeket eredményez a csapadék, hőmérséklet és egyéb meteorológiai jellemzők terén. Az ország nyugati részét az óceáni, a délkeleti a kontinentális, a délnyugati területeit a mediterrán, az északkeleti vidékeit hegyvidéki éghajlati hatások alakítják (Péczy, 1998). Ez az éghajlati sokféleség, különösen az átmeneti övezetekben, fokozott érzékenységet jelent a szélsőséges időjárási eseményekre – ideértve a belvizeket is –, melyek gyakorisága és intenzitása az éghajlatváltozással várhatóan tovább növekszik (Bartholy et al., 2011; Mezősi et al., 2013, 2017). A legfrissebb klímamodellek előrejelzései szerint a jövőben gyakoribbá válhatnak a szélsőséges időjárási események, különösen a rövid idő alatt lehulló nagy mennyiségű csapadék, amely jelentősen növeli az extrém belvízi elöntések kockázatát. Ennek következtében a belvízprobléma nem csupán az aktuális időjárási viszonyok függvénye, hanem egyre inkább a klímaváltozás által felerősített környezeti kockázattá válik, amely hosszú távon is kihívást jelent a vízgazdálkodás számára (Lee et al, 2023).

A belvíz kialakulásában a hidrometeorológiai tényezők trigger (kiváltó) szerepet játszanak, vagyis ezek a tényezők indítják el azokat a folyamatokat, amelyek a víz felszíni felhalmozódásához vezetnek (Orlóczi és Schlegel, 1967). Közvetlenül befolyásolják továbbá a vízháztartást és a talaj nedvességi állapotát, így a csapadék mennyisége, eloszlása és intenzitása a belvízképződés egyik legfontosabb mozgatórugója.

2.2. Belvíz kutatások - történeti tapasztalatok és tanulságok

Magyarországon a belvíz, mint hidrológiai jelenség, a 19. század óta jelentős problémát okoz, különösen az alföldi területeken. A belvízkutatás fejlődése szorosan összefügg az ország vízgazdálkodási történetével és a mezőgazdaság vízellátásának biztosításával.

A belvíz fogalmának értelmezése és a jelenség vizsgálata az elmúlt másfél évszázadban jelentős változáson ment keresztül, a korai helyszíni megfigyelésektől a komplex hidrológiai és távérzékelési alapú megközelítésekig. Ezt bizonyítja, hogy Pálfi (2001) több mint ötven különböző belvízdefiníciót gyűjtött össze, jelezve ezzel a jelenség összetettségét. Az eltérő értelmezéseket az alábbi megfogalmazással foglalta össze: *"a belvíz a sík vidékek időszakos, ám meglehetősen tartós és viszonylag nagy területre kiterjedő jelensége, egyedi víztípus"*. Lászlóffy (1982) minden olyan vizet belvízként kategorizál, amely egy töltésekkel védett területen csapadékból vagy talajvízből származik, és nincs természetes lefolyása. Rakonczai (2011) szerint a *"belvíz nem más, mint sík területen - többnyire a folyók mentesített árterületein kívül - keletkezett árvíz"*. Meglehet különböztetni műszaki szempontú definíciót is, ami szerint a *"belvíz esetén a területen összefüggő vízfoltok és elöntések alakulnak ki, a terepen lassú vízmozgás tapasztalható, és a vízállás emelkedése figyelhető meg a vízelvezető rendszerekben"* (Török, 1997). Biológiai értelemben a belvíz akkor alakul ki, *"ha a talaj termőrétegének húzágaiban több nedvesség található, mint amennyit a növényzet fejlődése megengedne"* (Salamon, 1942). Közgazdasági szempontból *"akkor van belvíz, ha a károkozás mértéke meghaladja a belvízzel nem érintett területeken realizálható többlettermés értékét, legyen az elöntés vagy a talaj telítettsége miatti termés kiesés"* (Rakonczai et al., 2011). A fogalom meghatározása folyamatosan változott a témát vizsgáló szakirodalomban, és még a mai napig nincs kikristályosodott definíciója.

A belvíz, amelyre a magyar kutatók az angol nyelvű szakirodalomban gyakran az *Inland Excess Water* (IEW) kifejezést használják, nem csupán Magyarországon ismert hidrológiai jelenség, hanem számos más országban is előfordul, bár eltérő megnevezésekkel és

értelmezésekkel illetik. Nemzetközi példákat említve Hollandiában és Chilében a *waterlogging* kifejezés terjedt el az olyan mélyfekvésű, lefolyástalan területeken kialakuló vízfelesleg leírására, ahol a túlzott vízterhelés oxigénhiányos (hypoxia) talajállapotot idéz elő a gyökérzónában, gyakran anélkül, hogy nyílt vízfelület jelenne meg (Wallender és Tanji, 2011; Jong és Homba, 2012; Morales-Olmedo et al., 2015, Yeung et al., 2018). Indiában és Bangladesben a *pounding water* és *waterlogging* kifejezéseket alkalmazzák a tartósan magas talajvízszint okozta elöntésekre, amelyek jelentős agrárkárokkal járnak (Asselman és Middelkoop, 1995; Akash et al., 2023). Kínában az *inundation* szó a mezőgazdasági földek hosszabb távú vízborítását és a városi területeken jelentkező elvezetési problémákat is magában foglalja (Jiayun et al., 2016). Németországban az *Überflutung* és a *Polderwasser* kifejezésekkel írják le a mezőgazdasági termelést veszélyeztető vagy gátló elöntéseket, míg az Egyesült Államokban a *flooded soils* megnevezés használatos főként a Mississippi deltavidékén előforduló, időszakos vízborításokra (Collaku és Harrison, 2002; Schmitt et al., 2022).

Ezek a nemzetközi példák rávilágítanak arra, hogy bár a terminológiai és fogalmi különbségek országonként változnak, a belvíz jelenségének alapvető sajátosságai – így a talaj telítettsége, vízborítás időtartama és agrárkárok – világszerte hasonlóak (Kuti et al., 2006; Titan et al., 2021).

A vízgazdálkodási szemléletváltások és a műszaki-informatikai fejlődés nyomán egyre pontosabb adatgyűjtés és modellezés vált lehetővé. A mai kutatásokban a műholdas távérzékelés, a gépi tanulás és azon belül a mélytanulás technikái új dimenziókat nyitnak a belvíz detektálásában, térképezésében és előrejelzésében (Tobak, 2008; Balázs, 2009; Bangira et al., 2021). A különböző módszertani irányok – a spektrális indexalapú megközelítések, a klasszikus statisztikai és modern algoritmikus modellek – összehangolása elengedhetetlen a belvízjelenségek megbízható feltárásához és kezeléséhez. A következő fejezetek e módszertani fejlődés legrelevánsabb elemeit mutatják be, amelyeket igyekeztem a saját kutatási metodikámba is beilleszteni.

2.2.1. A belvízvizsgálatok hagyományos becslési eljárásai és megfigyelési adatbázisai - alapok a modern térképezéshez

A 19. századi nagyszabású folyószabályozási és árvízvédelmi munkálatok alapozták meg az Alföld mezőgazdasági hasznosításának feltételeit, amelyekben a magyar vízmérnökök kiemelkedő szerepet játszottak (Thyll, 1994). A folyók árvízvédelmi töltések közé szorításával megszűnt a hegyvidékekről érkező áradások mocsarakba történő eloszlása, valamint a természetes mocsarak külső vízutánpótlása. Ezzel párhuzamosan megindult a síkvidékeken a csatornahálózatok kiépítése és a mocsarak teljes lecsapolása. A létrejött csatornarendszerek megalapozták a síkvidéki vízgyűjtő rendszerek és öblözetek kialakulását, valamint az első vízrendező és ármentesítő társulatok működését (Kienitz, 1972b).

A belvíz monitorozása és térképezése jelentős átalakuláson ment keresztül a különböző korok technológiai lehetőségeihez mérten. A belvíz ekkoriban még elsősorban káros vízformaként jelent meg a közgondolkodásban, amelyet mielőbb el kellett vezetni a területről. Ezt a szemléletet tükrözi az 1871. évi XXXIX. törvénycikk 23. §-a is, amely előírta, hogy az Ármentesítő társulatok kötelesek biztosítani a belvizek számára legalább olyan mértékű és biztonságos lefolyást, mint amilyen a szabályozás előtt fennállt:

“23. § Ármentesítő társulatok a belvizek által érdekelttel egyetértve, hatáskörükbe vonhatják az azok által borított területek mentesítését is; arról pedig minden esetben gondoskodni tartoznak, hogy a belvizeknek lefolyása munkálataik által ne akadályoztassék, és azok számára ugyanannyi és oly biztos lefolyást, a mennyi s a minő a szabályozás előtt volt, biztosítani kötelesek.” [7].

A korai vízmérnöki megközelítések elsősorban becslési eljárásokon alapultak. Például Bogdánfy (1906) táblázatos módszerekkel próbálta számszerűsíteni a vízelvezetés méretezési paramétereit, statikus megközelítést alkalmazva. A belvízöblözetek esetében ezek az eljárások

arra irányultak, hogy meghatározzák az adott víztömeg meghatározott időtartam alatti elvezetéséhez szükséges csatornák és műtárgyak méreteit. Az alkalmazott paraméterek többnyire kiemelkedő, rendkívüli eseményekhez kötődtek, és nem támaszkodtak egységes, standardizált adatgyűjtési metodikára. Ezek a statikus eljárások ugyanakkor az alapvető mezőgazdasági igényeket kielégítették, és jellemzően vízmérnöki tapasztalásokon alapultak (Trümmer, 1942; Bogárdi, 1944).

Az 1915, 1919, 1930 és 1940-es évek nagy belvizei rámutattak arra, hogy a mezőgazdaságnak egyre nagyobb szüksége van olyan vízrendezési megoldásokra, amelyek keretében a belvíz komplex hasznosítása megoldható. Erre szolgált például a melioráció, amelynek célja a földhasználatot korlátozó valamely természeti tényező hatásának tartós javítása, a káros, illetve a kedvezőtlen hatások lényeges és tartós mérséklése vagy megszüntetése (Kamarás, 1977; Thyll et al., 1983; Fehér et al., 1986; Vermes, 2001).

Babos (1957) munkája a Szeged környéki belvízrendszerek – így az algyői, gyálai és tápé-vesszősi rendszerek – fajlagos belvízhozamainak történeti elemzését adja 1881 és 1956 közötti események alapján. A tanulmány hangsúlyozza, hogy a belvizek kialakulását nem kizárólag a lehullott csapadék mennyisége, hanem annak évszakos eloszlása, a talaj víztelítettsége, a hótakaró vastagsága és a meteorológiai tényezők együttes hatása alakítja.

A 20. század folyamán, különösen a vízrajzi évkönyvek megjelenésével, pontosabb és rendszeresebben gyűjtött adatok váltak hozzáférhetővé. A vízügyi igazgatóságok által vezetett nyilvántartások már területi bontásban közölték a belvízzel elöntött területek nagyságát, az éves és szezonális csúcsértékeket, valamint az elöntések időtartamát. Az ilyen fajta adatgyűjtés egyik fő előnye, hogy az észlelés pillanatától kezdve azonnal megkezdhető, függetlenül az időjárási körülményektől. Ugyanakkor fontos figyelembe venni, hogy a terepi felméréseknek hátrányai is vannak. Például a belvízvédekezésben részt vevő szakemberek által készített elöntési térképek szubjektivitást hordozhatnak magukban, mivel az alkalmazott módszertan erősen függ az egyéni megítéléstől (Van Leeuwen, 2012). Emellett a nehezen megközelíthető belvízfoltok esetében a horizontális rálátásból adódó torzulások pontatlanságokat eredményezhetnek a térképeken. Bár a mérések továbbra is helyszíni felmérésekre és becslésekre épültek, már megfigyelhető volt a szervezett adatgyűjtés és archiválás. Javaslatokat tettek a természetes tározók vízviasszatartó szerepének kihasználására és a vízgyűjtők levezetési kapacitásának növelésére (Rakonczai et al., 2003).

Kienitz (1972a) tanulmányában átfogó képet nyújt a belvízrendezési kutatások hidrológiai fejlődéséről és a legjelentősebb kutatók hozzájárulásáról. A belvíz kialakulásának komplexitására először Gillyén (1910) hívta fel a figyelmet, aki hangsúlyozta, hogy nemcsak a csapadék, hanem a talajtani és egyéb hidrológiai tényezők is kulcsszerepet játszanak a belvíz kialakulásában. Ezt a szemléletet fejlesztette tovább Korbély (1915) és Kenessey (1930) az ún. összegyülekezési elméletek megalkotásával, amelyek már figyelembe vették a csapadék intenzitását, időtartamát és a vízgyűjtők morfológiai jellemzőit.

Az 1950-es és 1960-as évek vízgazdálkodási szemléletváltása jelentős előrelépést hozott a belvízi elöntések vizsgálatában, mivel új típusú adatforrásokat és mutatószámokat vezettek be a kutatásokba. A csapadékösszegek, a talajnedvesség és a talajvízszint rendszeres monitorozása mellett megjelent a vízmérleg szemlélet, amely a felszíni lefolyás, a beszivárgás és az elvezetés mennyiségi jellemzőit integrálta. Ebben az időszakban vezették be a lefolyási tényező alkalmazását, amely az éves csapadékhoz viszonyított tényleges lefolyás arányát kvantitatívan fejezte ki, hozzájárulva a vízháztartási viszonyok pontosabb értékeléséhez (Salamín, 1956).

Az újonnan bevezetett adatforrások és mutatószámok alkalmazása lehetővé tette a belvízi elöntések mezőgazdasági hatásainak célzott vizsgálatát is. 1966-tól kezdődően a Vízügyi Tudományos Kutató Intézetet (VITUKI) rendszeres adatgyűjtést végzett a belvíz és a mezőgazdasági terméseredmények közötti összefüggések feltárására, amelyeket Belvízi Mutató Szám (BMSZ) kódok (pl.: 1-9 helyértékek: A tábla helyét és a megfigyelés évét kódolással azonosító számok. 1 és 2 az évet, 3 és 4 a vízgyűjtőt, 5 és 6 a részvízgyűjtőt, 7, 8 és 9 a táblát jelöli) formájában rögzítettek. A kutatás célja a tavaszi belvizek okozta termés kiesés

előrejelzése volt, különböző talaj-, időjárási és agrotechnikai paraméterek alapján. Lineáris és log-lineáris regressziós modellek segítségével elemezték többek között a csapadék, a talajtípus, a fagyás mélysége, a csatornától való távolság és a művelési módok hatását. Az empirikus mutatók – például az agrotechnikai index – révén lehetővé vált a belvíz által okozott károk becslése, valamint a levezető rendszerek tervezésének megalapozása gazdasági szempontból is (Kienitz, 1972c).

A 20. század közepére a belvízprobléma egyre inkább a komplex vízgazdálkodási szemlélet részévé vált. Salamin (1955) munkássága révén jelent meg az a megközelítés, amely a belvizet nem pusztán vízrendezési problémaként, hanem a mezőgazdasági termelés és a vízháztartás egyensúlyi kérdéseként kezelte – előrevetítve a mai integrált vízgazdálkodási koncepciókat.

Példaként emelném ki Hartyányi (1959) kutatását, amely a Kondorosvölgyi minta-belvízgyűjtő területén végzett komplex vízháztartási vizsgálatokat mutatja be, ahol részletes hidrológiai, meteorológiai és talajtani méréseket végeztek. A kutatás kimutatta, hogy a legjelentősebb lefolyások hóolvadás idején, fagyott talajon keletkeznek, míg záporok esetén gyorsabb lefolyási ciklus figyelhető meg. Kiemelt szerepet kapott az „eketalp” réteg vizsgálata, amely a vizsgált területeken akadályozta a víz beszivárgását, ezáltal jelentősen befolyásolta a talaj vízháztartását. A tanulmány megerősítette, hogy a csapadékeloszlás és a talajnedvesség közötti összefüggések kulcsfontosságúak a belvízkezelés és a vízgazdálkodás tervezése szempontjából. Hartyányi munkája a korszakra jellemző innovatív mérési hálózat és adatfeldolgozási módszerek révén a későbbi vízgazdálkodási és vízrendezési rendszerek fejlesztéséhez is hozzájárult.

A komplex belvízértékelés alapjait Orlóczy és Schlegel (1967), valamint Forgó et al. (1967) munkái alapozták meg. Elemzéseik a védekezési tapasztalatokra és a csapadék, talajvíz és elöntések közötti összefüggések feltárására irányultak. Orlóczy és Schlegel (1967) a két meghatározó belvízi év – 1940 és 1966 – tapasztalatait vetették össze, hangsúlyozva, hogy a rendkívüli elöntések nem csupán a csapadékmennyiség, hanem a meteorológiai és hidogeológiai tényezők együttes hatásának következményei. Rámutattak arra, hogy bár a műszaki feltételek javultak, a védekezés hatékonyságát továbbra is korlátozták az adatgyűjtési és monitoring rendszerek hiányosságai.

Forgó et al. (1967) az Alsó-Tisza-vidéki Vízügyi Igazgatóság területén az 1966-os belvízvédekezés részletes elemzését készítették el. Vizsgálatuk kvantitatív módon mutatta be a belvízképződés meteorológiai előzményeit, beleértve a hóolvadás intenzitását, a lefolyási tényezőket és az elöntött területek nagyságát. A szivattyúzással elvezetett víz mennyisége meghaladta a 80 millió m³-t, és a védekezés hatékonyságát jelentősen növelte a mobil szivattyúk alkalmazása és a megfelelő előkészületek. A tanulmány gyakorlati ajánlásokat is megfogalmazott a csatornahálózat korszerűsítésére és az előrejelzési rendszerek fejlesztésére.

A hetvenes évektől kezdődően a belvízhez kapcsolódó adatgyűjtés egyre komplexebb hidrometeorológiai mutatók alkalmazásával bővült. Kiemelkedő jelentőségű Pálfai Imre munkássága, aki az 1970-80-as években számos tanulmányában foglalkozott a belvízképződés feltételeinek számszerűsítésével (Pálfai, 1979; 1981). Nevéhez fűződik a téli belvízindex kidolgozása, amely a csapadék, a maximális hóvastagság, a talajvízmélység és a talajfagy mélysége alapján integrált módon jellemzi a téli időszak belvízveszélyét. Az index a meteorológiai és talajhidrológiai tényezők együttes figyelembevételével tér- és időbeli összehasonlításokra, illetve előrejelzési célokra is alkalmas (Pálfai, 2004).

A rendszerhidrológiai modellek révén lehetőség nyílt olyan tűrési idők meghatározására is, amelyek a mezőgazdasági területek vízborítás-érzékenységet jellemzik. Ezek az értékek azt mutatják meg, hogy a különböző növénykultúrák milyen időtartamig képesek elviselni a vízborítást jelentős termés kiesés nélkül (Kamarás, 1977).

Kienitz (1972a) tanulmánya rávilágított arra, hogy a belvízrendezés hatékonyságának növelése csakis interdiszciplináris és integrált vízgazdálkodási megközelítéssel valósítható meg, amely a vízelvezetés mellett ökológiai és gazdasági szempontokat is figyelembe vesz.

A belvízrendszerek működésének hidraulikai és rendszerelméleti vizsgálatai már a klasszikus determinisztikus modellezés és rendszeranalízis keretei között is megjelentek. Kienitz (1970) modellje a síkvidéki vízgyűjtők belvízhullám-lefutását négyfázisú összegyülekezési folyamatként, kibernetikai rendszerként írta le. Az input–output alapú megközelítés figyelembe vette a belvízfoltok láncolatát, a csatornák visszaduzzasztó hatását és a rendszer önszabályozó működését. A modell alapján kialakított gépi számítási eljárás lehetővé tette a lefolyási folyamatok időbeli szimulációját, vízhozam- és elöntési idősorok formájában.

Domokos et al. (1978) tízéves adatsorok feldolgozása alapján statisztikai módszerekkel mutatták ki a belvízkárok és a hidrometeorológiai, vízgazdálkodási, valamint agrotechnikai tényezők közötti számszerű összefüggéseket a Mirhó–Gyolcsi kísérleti belvízöblözet területén. Az eredmények hozzájárultak a belvízképződési folyamatok ok-okozati viszonyainak pontosabb megértéséhez, és megalapozták a későbbi modellezési fejlesztéseket.

Kontur (1983) a belterületi felszíni vízmozgások determinisztikus modellezésére dolgozott ki eljárást, amely az egység-árhullámkép elméletén alapult. Modellje lineáris kaszkádként ábrázolta az összegyülekezési folyamatot, figyelembe véve a beszivárgási veszteségeket, az intercepciót és a talaj vízmegtartó képességét. A módszer kiemelten kezelte a csapadékesemények időbeli szerkezetének hidrológiai hatásait, és célja a tetőző vízhozam mellett a teljes lefolyási görbe valószínűségi leírása volt.

Vágás (1989) elméletében a belvízelvezető rendszerek működését nem-lineáris, állapotfüggetlen hidraulikai transzformációként értelmezi, ahol a szivattyúzási kapacitás határozza meg a vízelvezetés mértékét, nem pedig a tározott víztömeg. A szerző szerint a szivattyúk a belvíz elöntési időtartamát képesek csökkenteni, míg a kiterjedés a tározóterek kapacitásától függ. Modellje szakít a klasszikus lefolyásmodellezési szemlélettel, és úszószivattyú-működéshez hasonló rendszert feltételez, ahol a kifolyás a vízszinttől függetlenül állandó. Vágás (1989) hangsúlyozza a tározási igények statisztikai értékelésének jelentőségét a belvízrendszerek tervezésekor.

Pálfai (1989) módszere az elöntési és lefolyási adatok alapján becsüli a mértékadó fajlagos belvízhozamot, figyelembe véve a természetes és antropogén tényezők együttes hatását. Mindezek a kutatások közvetve hozzájárultak a belvízi indexek kialakításához és alkalmazásához a gyakorlatban (Balogh, 2009).

Összefoglalva a becslésen alapuló eljárások a belvízvizsgálatok kezdeti szakaszában voltak jellemzőek, amikor a vízmérnökök megfigyelések és térképi elemzések alapján határozták meg a belvízlevezetés lehetőségeit. A 20. század folyamán a statikus megközelítéseket fokozatosan felváltották a dinamikus hidrológiai modellek, amelyek már a csapadék, a vízgyűjtő jellemzői és a talajtani adottságok közötti összefüggéseket is vizsgálták (Várallyay, 2005, 2017). Domokos et al. (1978) kutatásai révén megjelentek azok a regressziós és empirikus modellek, amelyek a hidrometeorológiai és agrotechnikai tényezők együttes hatását is számszerűsíteni tudták, megalapozva ezzel a belvízkárok előrejelzésének lehetőségét. Ezek a fejlesztések jelentős lépést jelentettek az integrált vízgazdálkodási szemlélet felé, amely a becslési eljárások természetes továbbfejlődését eredményezték. A belvízkutatások fejlődésének következő meghatározó állomása a belvízveszélyeztetettség térképezése, amely már nemcsak a kialakulás hátterének, hanem a potenciális kockázati zónák azonosításának is fontos eszközévé vált. A következő fejezet ezt a szegmenst vizsgálja részletesebben.

2.2.2. Belvíz-veszélyeztetettségi térképezés, veszélytérképek

A belvíz-veszélyeztetettség térképezésének hazai történetét elsőként Pálfai (2004) dolgozta fel átfogóan, aki az 1950-es évektől a 21. század elejéig kronologikusan mutatta be a főbb intézményeket, szerzőket, módszereket és térképtípusokat. A feldolgozás kronologikus és tematikus rendben halad, kiemelve a legfontosabb módszertani és intézményi fejlesztéseket. A belvíz-veszélyeztetettségi térképezés önálló fejezetbe történő integrálását az a tudományos igény

indokolta, hogy a történetileg kialakult módszertani megközelítések érdemben támogatták a disszertációban bemutatott dinamikus modell kidolgozását.

Mosonyi (1954) az Országos Vízgazdálkodási Keretterszervezés kialakulását és alapelveit mutatta be, amely 1952-ben indult az Magyar Tudományos Akadémia (MTA) kezdeményezésére, és első változata 1953-ra készült el a Vízügyi Tervező Vállalat (VIZITERV) közreműködésével. A terv célja egy komplex, hasznosítás-orientált vízgazdálkodási koncepció megalkotása volt, amely különbséget tett az aktív és passzív vízgazdálkodási elemek között, és ezek egyensúlyát hangsúlyozta. Mosonyi előremutató szemlélete szerint a többletvizeket – köztük a belvizeket – nem csupán kezelendő problémának, hanem értékes erőforrásnak kell tekinteni. Ez a gondolat máig releváns, és a belvíz erőforrásként való kezelése szempontjából is irányadó.

Salamin (1966) tankönyvében úttörő módon mutatta be a vízrendezés és a mezőgazdaság szoros kapcsolatát, hangsúlyozva, hogy a belvízkezelés nem választható el a termelési, gazdasági és technikai feltételektől. A vízrendezési feladatokat a mezőgazdaság igényeihez igazítva, de annak megelőző feltételeként értelmezte, kiemelve a vízvisszatartás és vízelvezetés egyensúlyának fontosságát. Bevezette a „tűrési idő” fogalmát, amely segíti a vízborítottság gazdasági hatásainak becslését. Salamin munkája előremutató komplex szemléletet képviselt, amely ötvözte a vízgazdálkodási, agrotechnikai és regionális tervezési szempontokat, így alapot teremtett a belvíz-veszélyeztetettség térképezés későbbi irányvonalaihoz is.

Az 1970-es évek végén országos belvíz-veszélyeztetettség térképsorozat készült az Országos Műszaki Fejlesztési Bizottság (OMFB) Fehérje Program Iroda megbízásából, a 10%-os valószínűségű elöntések ábrázolására. A munkát a VITUKI irányította a vízügyi igazgatóságok bevonásával, és az 1966-1979 közötti időszakból választott mértékadó év, jellemzően 1977 alapján készült. Az 1:100 000 méretarányú térképek az akkori vízrendezési állapotokat figyelembe véve fontos mérföldkövet jelentettek a belvíz-veszélyeztetettség térképi megjelenítésében (Pálfai, 2003).

A VITUKI által készített elöntési térképsorozat és adatbázis felhasználásával az Országos Vízügyi Hivatal Vízgazdálkodási Intézete (ma: Országos Vízügyi Főigazgatóság, korábban OVH) – a Mezőgazdasági és Élelmezésügyi Minisztérium (MÉM) Növényvédelmi és Agrokémiai Főosztályának megbízásából részletes elemzéseket végzett a belvíz által érintett térségekről. Az eredmények szerint az elöntések túlnyomó többsége (79-82%) az Alföldön fordult elő, míg a Dunántúlon és az északi megyékben egyaránt 8-11% közötti arányt képviseltek. Az elemzések eredményeit megyetérképeken (1:150 000) és munkatérképeken (1:500 000) mutatták be, kiemelve a fejlesztendő területeket és ökológiai körzeteket is (Pálfai, 2003).

Az 1980-as évek elején az MTA agroökológiai felmérése során a belvíz-veszélyeztetettség vizsgálata is szerepet kapott. A 1970-1979 közötti belvizes térképi adatok alapján körzetenként kiszámították a belvízfoltok összes területét és arányát, majd három (közepesen, erősen és igen erősen) veszélyeztetettségű kategóriát állapítottak meg. Ez a besorolás megalapozta a termőföldhasználat és a vízgazdálkodás hosszú távú tervezését (Pálfai, 2003).

1979-1980 között az MTA TAKI (ma HUN-REN ATK - Hungarian Research Network-Magyar Kutatási Hálózat Agrártudományi Kutatóközpont) részletesen elemezte a belvízképződés talajtani tényezőit, különös tekintettel a talaj vízáteresztő és víztároló tulajdonságaira, valamint a talajvízszint mozgására (Várallyay et al., 1980). Ennek eredményeként készült el a „Belvízképződésre ható talajtani tényezők” térképsorozat, kezdetben négy megyére (Békés, Csongrád, Hajdú-Bihar és Szolnok), majd az Alföld többi síkvidéki térségére is. A térképeken belvíz-veszélyességi kategóriákat és azok mérséklésének lehetőségeit is ábrázolták. A hegy- és dombvidékeken a belvíz lokálisan fordult elő, itt a talajtani tényezők másodlagos jelentőségűek voltak. A vizsgálatot részletes területi kimutatások egészítették ki (Pálfai, 2003).

Nagy (1982) tanulmányában a belvíz kialakulásának természetföldrajzi és mezőgazdasági összefüggéseit elemezte. A vizsgálat során meghatározta a talajtípusok vízbefogadó képességét, és négyfokozatú belvízérzékenységi kategóriát dolgozott ki. Magyarország területét három belvíz-veszélyeztetettségű övezetbe sorolta, a genetikus talajtérkép és az átlagos talajvíztükör mélysége alapján. A szerző hangsúlyozta, hogy a védekezés nem minden területen gazdaságos,

ezért bizonyos térségekben művelésiág változtatást, például erdősítést javasolt a károk mérséklésére.

Az 1980-as évek elején, az új Országos Vízgazdálkodási Keretterv részeként, Pálfai (1981) egy új, tényleges elöntések gyakoriságán alapuló térképezési módszert dolgozott ki a belvívveszély területi különbségeinek jellemzésére. A módszert először Békés megyében, majd fokozatosan a Tisza-menti vízügyi igazgatóságok területén is alkalmazták. Az így létrejött belvízgyakorisági térképeket az OVH 1984-es keretterve foglalta össze országos léptékben. A térképek fontos szerepet kaptak a mezőgazdasági erőforrások értékelésében és a vízrendezési tervezésben.


Petrasovits és Szalai (1986) célja a magyarországi öntözésfejlesztési és vízrendezési tervek hosszú távú, valamint agroökológiai alapú megalapozása volt. Az általuk használt ökotípus-rendszer domborzati, hidrológiai, talajtani és agrometeorológiai tényezők alapján homogén egységekre osztotta fel az országot, így lehetővé vált a belvív-veszélyeztetett, valamint vízhiányos térségek elkülönítése és növénytípus szerinti értékelése. Kihangsúlyozták a síkvidéki területeken a felszíni és felszín alatti vízrendezés együttes szükségességét, valamint az adaptív földhasználati és vízhasználati stratégiák kialakítását, különös tekintettel a klímaváltozásra és talajromlásra. Gazdasági szempontból felhívták a figyelmet arra, hogy a meliorációs beavatkozások költségeit hosszú távon és közösen kellene viselnie az államnak és a termelőknek. Módszertani eredményeiket felhasználták Magyarország Nemzeti Atlaszának [8] ár- és belvízvédelmi térképeihez, valamint Pálfai többször is publikálta a térkép egyes részleteit (Pálfai, 1982; 1985).

Pálfai (1985) tanulmánya a síkvidéki belvízi lefolyásokat országos léptékben elemzi, és elsőként számszerűsíti azok éves átlagos értékét (14-101 mm között), megalkotva Magyarország első ilyen tematikájú térképét. A szerző statisztikai kapcsolatot mutat ki a lefolyás mértéke és olyan tényezők között, mint a talajvízszint mélysége és a csapadékeloszlás, kiemelve, hogy a magas talajvízszint jelentősen fokozza a belvív kialakulásának valószínűségét. A tanulmány új szemléletet vezet be, amely szerint a belvív nem csupán elvezetendő többletvíz, hanem potenciális vízkészlet is lehet. Ezzel előrevetíti a táji léptékű, integrált vízvi sszatartási megközelítések elterjedését.

Nováky (1988) tanulmányában egy új számítógépes modellezési rendszert mutat be, amely az éghajlati tényezők – különösen a csapadék és hőmérséklet – alapján számítja ki az évi fajlagos lefolyást és jeleníti meg izovonalas térképen. A modell homogén térszíni adottságokra épül, négyzethálós rácsokra bontva a teret, és elemi vízgyűjtő egységekhez rendelve az adatokat. A számítás empirikus összefüggéseken és a Budiko-féle párolgási modellen alapul (Keve és Nováky, 2010), lehetővé téve a lefolyási viszonyok térképi értékelését az éghajlati jellemzők alapján. Ez az eljárás fontos előrelépést jelentett a kvantitatív térképezés és a vízháztartási elemzések terén.

1986 és 1990 között az OVH megbízásából Pálfai vezetésével indult kutatás a belvízi veszélyeztetettség és a természeti tényezők kapcsolatának feltárására. A vizsgálat első szakaszában Pálfai (1987) új módszertant dolgozott ki a belvív-veszélyeztetettség objektív, kvantitatív értékelésére: az 1961-1980 közötti legnagyobb elöntések térképei alapján gyakorisági osztályokat definiált, majd többváltozós regresszióval azonosította a legfontosabb befolyásoló tényezőket. A vizsgálatok szerint a talajvízszint mélysége és a talajtani tulajdonságok jelentették a legmeghatározóbb tényezőket a belvív kialakulásában.

Pálfai (1994) későbbi tanulmánya egy országos kutatás módszertani alapjait ismerteti, amellyel az Alföld síkvidéki területeinek belvív-veszélyeztetettségét térképezte (4. ábra). Célja egy olyan egységes értékelési rendszer létrehozása volt, amely a domborzat, talajvízmélység, talajtípusok és éghajlati tényezők alapján objektíven jellemzi a belvízkockázatot. Ennek eredményeként készült el az 1:200 000 méretarányú, 40 lapból álló térképsorozat, amely négy kockázati kategóriát tartalmazott, valamint egy belvív-veszélyeztetettségi mutatót (BV) is bevezetett. A térképek nemcsak múltbeli állapotokat tükröztek, hanem tervezési és prognosztikai célokra is alkalmazhatók voltak.



4. ábra: Pálfi-féle belvíz-veszélyeztetettségi térkép (Pálfi, 2004)

Pálfi (2000) újabb tanulmánya a korábbi belvíz-veszélyeztetettségi térképsorozat alkalmazásközpontú továbbfejlesztését mutatta be, amely már az aszályérzékenység vizsgálatára is kiterjedt. A kutatás elemzi az 1931-2000 közötti belvívelöntések alakulását, és azonosítja a leginkább veszélyeztetett alföldi térségeket. Bevezetésre kerül a Pálfi-féle aszályossági index (PAI), amely a csapadék és hőmérséklet alapján kategorizálja az aszályérzékenységet. A két jelenség együttes térképezése lehetővé teszi a vízháztartási szempontból leginkább sérülékeny területek azonosítását, és hangsúlyozza a térinformatikai eszközök jelentőségét a jövőbeli vízgazdálkodási stratégiákban.


Thyll és Bíró (1999) térinformatikai alapú módszert dolgoztak ki a belvíz-veszélyeztetettség térképezésére a Bihari-sík egy 60 km²-es mintaterületén. A vizsgálat során különféle állandó környezeti tényezők – mint a talaj tározókapacitása, domborzati konvergencia, talajvízmélység, vízáteresztő képesség és földhasználat – kategorizált térképeit hozták létre, DDM50, talajtérképek és LANDSAT-felvételek felhasználásával. A raszteres átfedés és korrelációs elemzések alapján a legfontosabb tényező a talaj víztározó kapacitása volt, ezt követték a domborzati és hidrológiai jellemzők. Az így létrehozott veszélyeztetettségi térkép pontosabb és differenciáltabb képet nyújtott, mint a hagyományos statikus térképek, és hatékonyan támogatta a földhasználati tervezést, valamint a vízgazdálkodási és belvízmegelőzési döntések megalapozását.

Bozán (2021) doktori értekezése a belvízképződés komplex természeti és antropogén meghatározó tényezőit vizsgálta a Békés-Csanádi löszháton. Célja egy olyan módszertani keretrendszer kidolgozása volt, amely objektív, kvantitatív módon értékeli a belvív-veszélyeztetettséget, miközben támogatja a fenntartható területhasználati döntéseket. A dolgozat egyik központi eleme a Komplex Belvív-veszélyeztetettségi Mutató (KBM), amely hat fő hatótényezőt – domborzati, talajtani, földtani, hidrometeorológiai, talajvíz- és földhasználati jellemzőket – integrál, és ezeket súlyozott, geostatistikai módszerekkel dolgozza fel. A KBM módszertani alapjait a szerző korábbi, 2002-ben – a Halászati és Öntözési Kutatóintézet (ma MATE KÖTI ÖVKI) keretében – végzett kutatásaiban dolgozta ki, ahol a térség kedvezőtlen vízgazdálkodási állapotait vizsgálták térinformatikai eszközökkel. Ezt követően, Pálfi et al. (2004) vezetésével elkészült Csongrád megye belvív-veszélyeztetettségi térképe és a KBM első változata, amely már akkor is integrált megközelítést alkalmazott a veszélyeztetett területek lehatárolására. Bozán (2021) ezekre az alap kutatásokra és gyakorlati eredményekre építve fejlesztette tovább a KBM-et, mind térbeli kiterjedés, mind adatminőség szempontjából, létrehozva egy alkalmazásorientált, döntéstámogató modellt, amely illeszkedik a mai vízgazdálkodási és éghajlat-adaptációs stratégiákhoz.

Kozák (2006) szerint a belvízveszély meghatározása nem kizárólag statikus adottságokon, hanem az aktuális hidrometeorológiai állapotokon alapul, ezért a jelenséget dinamikus rendszerként szükséges értelmezni. A „pillanatnyi belvízveszély” fogalma az adott időpillanatban fennálló csapadékviszonyok, talajvízállás, talajnedvesség és egyéb vízháztartási tényezők együttes figyelembevételével határozza meg egy adott terület elöntési valószínűségét. Fontos különbséget tesz a belvíz-veszélyeztetettség, mint hosszú távon jellemző adottság, és a tényleges belvízveszély között, amely időben és térben jelentős ingadozásokat mutathat. A hidrometeorológiai események nem egyenletes térbeli lefutása miatt a tényleges elöntés mértéke gyakran kisebb, mint a veszélyeztetett területeké. Hangsúlyozza, hogy a belvízmodellezés hatékonysága növelhető, ha nem elméleti veszélyeztetettségi mutatókra, hanem valós elöntési kontúrookra épülő adatelemzésekre alapozzuk a térképezést. Ennek feltétele lenne egy országos, archivált elöntési adattár létrehozása, amely megbízható alapot nyújtana a gyakorisági térképek előállításához és a belvízveszély pontosabb értékeléséhez.


A több évtizedes belvízkutatási tapasztalatok ellenére továbbra is számos nyitott kérdés nehezíti a belvíz-veszélyeztetettségi térképezést és a kockázatértékelést – különösen a megfelelő minőségű és felbontású adatbázisok korlátozott rendelkezésre állása. Az elmúlt évtizedben ugyanakkor több hazai kutatás és térképezési kezdeményezés is született, amelyek célja a síkvidéki területek belvízre való érzékenységeinek térbeli jellemzése volt. A következőkben ezek közül kerülnek bemutatásra a legfontosabb, különböző módszertani megközelítéseket és gyakorlati alkalmazási lehetőségeket képviselő példák.

Pásztor et al. (2015) Szabolcs-Szatmár-Bereg megyére készítettek belvíz-veszélyeztetettségi térképet (5. ábra), több környezeti tényező - talaj, geológia, talajvíz, földhasználat és éghajlat - kvantitatív térbeli jellemzésére alapozva. A modellt többváltozós lineáris regresszióval állították fel, a maradék hibákat pedig geostatisztikai interpolációval (krigeléssel) javították. A kombinált módszertan előnye, hogy képes a különböző környezeti tényezők együttes hatásait is pontosan leképezni. Az eredmények jól alkalmazhatók a területrendezés, a mezőgazdasági vízgazdálkodás és a kockázatértékelés területén.




5. ábra: Szabolcs-Szatmár-Bereg megye belvíz-veszélyeztetettségi térképe, ahol a sötétebb kék árnyalatok a veszélyeztetett területek (Pásztor et al., 2015)

Balázs (2015) disszertációjában az alföldi belvíz-veszélyeztetettség térbeli és időbeli sajátosságait vizsgálta három mintaterületen: a Szolnok–Túri-síkon, a Rétközben és a Dél-Nyírségben. A kutatás célja a belvizek kialakulására ható természeti és antropogén tényezők feltárása, valamint a veszélyeztetettségi területek lehatárolása és összehasonlítása volt. A vizsgálatok hidrogeológiai, talajtani, meteorológiai és felszínborítási adatok integrálásával készültek, kiegészítve műholdas távérzékelési elemzésekkel (elsősorban Landsat-felvételek alapján). Az eredmények kimutatták, hogy a belvizek előfordulása elsősorban a talajvízszint és a csapadék kapcsolatától, a mikrodomborzati viszonyoktól és a felszínborítás típusától függ. A távérzékelési elemzések jól támogatták a belvízzel borított területek időbeli változásainak térképezését, és megerősítették a terepi megfigyelések eredményeit.




6. ábra: A Szolnoki-Túri-sík belvíz-veszélyeztetettségi térképe (Balázs, 2015)

A NAIK ÖVKI (ma: MATE KÖTI ÖVKI) 2019-es tanulmánya korszerű térinformatikai és geostatistikai módszerek segítségével készített nagyfelbontású belvíz-veszélyeztetettségi térképet Magyarország síkvidéki területeire. A kutatás hat fő tényezőcsoport (talajtan, domborzat, hidrometeorológia, talajvíz, földtan, földhasználat) több mint 50 változóját használta fel, és a Random Forest Krigelés (RF-K) eljárással prediktív modellt állított elő. Az eredményként létrejött Komplex Természeti-alapú Belvíz-veszélyeztetettségi Valószínűség (KTBV) térkép referenciaként szolgálhat jövőbeli forgatókönyv-alapú elemzésekhez (pl. klímaváltozás) (Bozán et al., 2019). A kutatás újdonsága az adatbányászati módszerek integrálása volt, amely új szintre emelte a belvíz-veszélyeztetettség tudományos értékelését (7. ábra).



7. ábra: Komplex Természeti-alapú Belvíz-veszélyeztetettség Valószínűség (KTBV) Jenks osztályozás alapján (Bozán et al., 2019)

Bozán et al. (2021) elkészítették a Magyarország síkvidéki területeinek belvízi veszélyeztetettségi térképét különböző stratégiai forgatókönyvek mentén (8. ábra). A referenciaállapotot a KTBV térkép jelenti. A vizsgálat olyan tényezőcsoportokat modellez, mint a belvízvédelmi rendszerek állapota, belvíztározók, szivattyúzási kapacitás, agrotechnikai beavatkozások (pl. talajlazítás, öntözés), hidrológiai feláramlás, valamint a klímaváltozás és a területhasználat változásának hatása. A forgatókönyveket térinformatikai elemzések és statisztikai szimulációk (90%-os előrejelzési intervallumok) segítségével értékelték. A térképezés célja a belvíz kialakulásához vezető természeti és emberi hatású tényezők térbeli kockázatának előrejelzése, amely alapot adhat a belvízvédkezési intézkedések és földhasználati döntések megalapozásához.



8. ábra: Árvízi kockázat-kezelés (AKK) Belvízi-veszélyeztetettség felülvizsgálata stratégiai forgatókönyvek (Bozán et al., 2021)

A belvíz-veszélyeztetettség térképezés az elmúlt évtizedekben elsősorban statikus megközelítésekre épült, amelyek historikus elöntési adatokra, talajtani és topográfiai jellemzőkre, valamint szakértői becslésekre támaszkodtak. Ezek a térképek fontos kiindulópontot jelentettek a földhasználati tervezéshez, a vízgazdálkodási stratégiákhoz és a mezőgazdasági kockázatok értékeléséhez. Ugyanakkor a klasszikus megközelítések jellemzően nem vették figyelembe az időbeli változékonyságot, valamint a dinamikus változó környezeti tényezőket.

A módszertani fejlődés – különösen a térinformatikai rendszerek, a távérzékelés és a gépi tanulás előretörése – új irányt mutat a belvívelöntések detektálásában. Módszertani szempontból a veszélyeztetettség térképezés során a belvíz kialakulását befolyásoló tényezők ok-okozati összefüggései alapján határozzák meg egy-egy térképi cella veszélyeztetettség valószínűségét, ahol a belvízgyakorisági (elöntési) értékek az adott cellára meghatározott befolyásoló tényezők értékeinek validálásához járulnak hozzá. Éppen ezért a belvívelöntések detektálása, illetve az abból levezetett elöntési maximumokból készített gyakorisági térképek jelentős mértékben hozzájárulnak a belvíz-veszélyeztetettség térképezés fejlődéséhez. Az egyre bővülő adatkészletek és a többváltozós modellezési technikák révén lehetőség nyílik arra, hogy a veszélyeztetettség térképezés ne csupán múltbeli állapotokat tükrözzön, hanem dinamikus, közel valós időben reagáljon az aktuális és előre jelzett környezeti állapotokra. Ennek eredményeként a belvíz-veszélyeztetettség térképezése fokozatosan az automatizálás és a predikció irányába fejlődik, amely hozzájárulhat a megelőzés és a beavatkozás hatékonyságának növeléséhez, valamint az adaptív vízgazdálkodás megalapozásához. Kutatásom módszertani felépítése szorosan épít erre a megközelítésre, hiszen célom egy olyan dinamikus "belvízveszélyeztetettség" modell létrehozása, amely a hagyományos térképezési módszertanokat az általam összeállított adatbázisokkal és deep learning alapú eljárásokkal ötvözve képes a belvízi kockázatok tér- és időbeli változásainak pontosabb, közel valós idejű előrejelzésére.

2.2.3. Térinformatikai és távérzékelési módszerek alkalmazása a belvízvizsgálatokban

A belvízborítások tér- és időbeli előfordulásának pontos nyomon követése hosszú időn keresztül jelentős kihívást jelentett a vízgazdálkodási és a földhasználati szempontokból. A XX. század második felétől megjelenő digitális térinformatikai rendszerek és a műholdas távérzékelés technológiai fejlődése alapvetően új megközelítéseket tett lehetővé. A hagyományos becslésen és terepi megfigyelésen alapuló eljárásokat fokozatosan felváltották az automatizált térképezési technikák, amelyek lehetővé teszik a nagy területű, időben is kiterjeszthető vizsgálatokat. A fejezet célja, hogy bemutassa a távérzékelésen és térinformatikán alapuló belvízdetektálási módszerek fejlődését, az ezekhez alkalmazott modellezési technikákat, valamint az optikai és radaros felvételek előnyeit a belvízkutatásban.

Bozán et al. (2018) három fő technikai megoldást azonosítottak a térképezés terén. Az első a közvetlen vagy direkt térképezés, amely terepi felmérések térinformatikai feldolgozásán alapul. Ebben az esetben csupán egy pillanatkép áll rendelkezésre a vizsgált terület aktuális állapotáról, miközben az események háttérére nem ad információt. A második megoldás a szintetikus térképezés, amely a függő és független tényezők közötti statisztikai összefüggésekre épül. Ez lehetővé teszi az ok-okozati viszonyok feltárását, ugyanakkor nagymértékben függ az adatbázisok minőségétől. A harmadik megközelítés az integrált hidrológiai modellezés, amely a hidrológiai változók és a belvívelöntések közti dinamikát írja le. Ez a módszer szolgáltatja a legtöbb információt az elöntések becsléséhez (Kozma, 2013; Van Leeuwen et al., 2013; Bozán et al., 2018).

Awange és Kyalo Kiema (2013) kiemelik, hogy a térinformatikai modellezés alapvető célja a különböző típusú térképi rétegek – például domborzat, talaj, földhasználat, hidrológiai és meteorológiai adatok – térbeli integrálása oly módon, hogy azokból egy új, szintetizált információkat hordozó térkép jöjjön létre. Ez az ún. overlay analysis révén valósul meg, amely

lehetővé teszi különböző adatrétegek logikai és matematikai összevetését. A modellezés nem pusztán vizualizációs eszköz, hanem analitikus és prediktív szerepet is betölt, különösen a környezeti kockázatok, például a belvízveszély térbeli előrejelzésében és értékelésében. A térbeli adatintegráció révén nemcsak a felszíni viszonyokat lehet pontosabban feltárni, hanem olyan rejtett összefüggések is azonosíthatók, amelyek alapvetően meghatározzák a kockázati szintek differenciálását.

A számítástechnikai eszközök térnyerése az 1960-70-es évektől jelentősen elősegítette a nagyméretű hidrológiai és modellezési feladatok nagy számítási kapacitást igénylő megvalósítását. A térinformatikai rendszerek (GIS) fejlődésével lehetővé vált integrált hidrológiai modellek – mint a MODFLOW (Restrepo et al., 1998), MIKE SHE, SWAT, HEC-HMS (Spanoudaki et al., 2009) – alkalmazása, illetve nyílt forráskódú platformok, például QGIS, SAGA GIS, valamint hazai fejlesztésű rendszerek (DIWA, DWSM) bevezetése (Koncsos et al., 2011; Szatmári, 2013). E modellek alkalmasak a belvíz tér- és időbeli viselkedésének szimulációjára, így hatékony eszközt jelentenek a belvízfolyamatok feltárásában és előrejelzésében.

Bíró (2017) kiemeli, hogy a fizikai alapú hidrológiai modellek – például a MIKE SHE vagy a MODFLOW – hatékony eszközt jelentenek a belvízhez kapcsolódó folyamatok elemzésében. Működtetésükhöz nagy térbeli és időbeli felbontású, megbízható bemeneti adatok szükségesek, amelyek országos vagy regionális szinten gyakran nem állnak rendelkezésre (Rakonczai et al., 2003; Kozák, 2009; Van Leeuwen, 2012).

Kozma (2013) hasonlóképpen vélekedett, szerinte a legnagyobb kihívást az jelenti, hogy a belvízképződést befolyásoló változók komplexitása nincs összhangban a rendelkezésre álló adatok részletességével és elérhetőségével. Van Leeuwen et al. (2016) az Orosháza-Székkutas térségben végzett kutatásukban a MIKE SHE fizikai alapú hidrológiai modellt alkalmazták a belvízborítások térbeli és időbeli előrejelzésére. A modell csapadék, párolgás, talaj- és talajvízparaméterek alapján szimulálta a belvízképződés folyamatait, objektív módon értékelve az előtések dinamikáját. A kalibrációhoz nagyfelbontású Light Detection and Ranging (LIDAR - lézer alapú távérzékelés) DDM, talajtérképek és RapidEye műholdképek szolgáltatottak részletes bemeneti adatokat. Eredményeik alátámasztották, hogy a fizikai alapú modellezés nagyobb pontosságot nyújthat, azonban érzékenyen reagál a bemeneti adatok minőségére és felbontására.

A belvízfelmérés módszertana az utóbbi évtizedekben jelentősen fejlődött, a hagyományos helyszíni megfigyeléseket egyre inkább felváltják a távérzékelési technikák, különösen az UAV-alapú, műholdas és légifotós adatgyűjtések. Rakonczai et al. (2001) vizsgálata két mintaterületen (Hortobágy-Berettyó és Hamvas-sárrét) hasonlította össze a terepi méréseket, műholdképeket (LANDSAT) és légifelvételeket, amelyeket a Földmérési és Távérzékelési Intézet (FÖMI – mai nevén Lechner Tudásközpont Nonprofit Kft.) szereztek be. Eredményeik szerint a légifotók részletesebb térbeli információt nyújtanak a kisebb belvízfoltok esetében, míg a műholdképek egységesebb, de durvább felbontású lefedettséget biztosítanak. A terepi megfigyelések időbeli kiterjedésük és szubjektivitásuk miatt kevésbé alkalmasak a pontos térképezésre. A vizsgálat igazolta, hogy a különböző adatok kombinált alkalmazása – különösen nagyfelbontású műholdképek és digitális domborzatmodellek bevonásával – javíthatja a belvíz detektálásának pontosságát. A GIS-alapú, időben kiterjedt térképezési megközelítés bizonyult a legmegbízhatóbbnak.

A légifotós távérzékelés kiemelkedően magas, akár centiméteres térbeli felbontást kínál, ami különösen előnyös a kis léptékű, gyorsan változó belvízi jelenségek detektálására. Előnyük a részletes felszíni információk gyors kinyerhetősége, ugyanakkor alkalmazásukat korlátozza a kis lefedhető terület, a repülési idő korlátozottsága, valamint az időjárási tényezőkre – csapadék, szél, fényviszonyok – való érzékenység (Rakonczai és Bódis, 2001; Rakonczai et al., 2003).

A műholdas távérzékelés egyik legnagyobb előnye a nagy területi lefedettség, amely lehetővé teszi több száz km²-es térségek egyidejű vizsgálatát. A multispektrális

műholdfelvételek különösen alkalmasak a felszíni vizek detektálására, míg a hiperspektrális adatok inkább speciális, precízebb kategorizálást igénylő vizsgálatokban kerülnek alkalmazásra. Ugyanakkor e módszerek használatát gyakran korlátozza a térbeli és időbeli felbontás, valamint a légköri zavarok, elsősorban a felhőborítottság. Ez utóbbi hátrányt küszöbölik ki a radaros, aktív távérzékelési eljárások, amelyek a mikrohullámú tartományban működve függetlenek a nappali megvilágítástól és a felhőzettől, így kedvezőtlen meteorológiai körülmények között is megbízhatóan alkalmazhatók. A túlnedvesedett, de nyílt vízborítással nem rendelkező területek azonosítása továbbra is technikai kihívást jelent, különösen multispektrális szenzorok esetén, miközben az eltérő pixelméretű műholdfelvételek korlátozhatják az előntések térbeli részletezettségű észlelését. A radaros adatok bevonása e problémák mérséklésében is jelentős szerepet játszhat (Bíró et al., 2000; Kovács, 2004; Mucsi és Henits, 2011; Szatmári és Van Leeuwen, 2013; Van Leeuwen et al., 2017, 2020; Balázs et al., 2018; Rawat et al., 2020; Mucsi és Bui, 2023; Birinyi et al. 2024).

A távérzékelésen alapuló vizsgálatok és kutatások jelentős része a széles körben alkalmazott spektrális indexeken (pl. NDVI, NDWI, MNDWI) alapuló eljárásokat használja, amelyek egyszerűségük ellenére hatékony eszközt jelentenek a belvízborítás kiterjedésének pontos és automatizált detektálásában. A legújabb kutatások – például a felszínborítottság változásának nyomon követése (Rouse et al., 1973; Liska et al., 2017, Varga et al., 2021), a mezőgazdasági állapotértékelés (Huang et al., 2020) vagy a vízborítottság térképezése (Kovács, 2004, Salvai et al., 2023) – jelentős módszertani előrelépést hoztak a belvízdetektálás területén.

Rouse et al. (1973) tanulmányukban az Earth Resources Technology Satellite-1 (ERTS-1) – a későbbi Landsat-1 – felvételei alapján vizsgálta a vegetációs rendszerek távérzékeléses megfigyelésének lehetőségeit az Észak-Amerikái Prérin. A kutatók multispektrális sávok kombinációjával különböző növényborítású felszínek azonosítására és időbeli változásaik detektálására fókuszáltak. A közeli infravörös és a vörös tartomány összehasonlításán alapuló spektrális indexek erős kapcsolatot mutattak a vegetációs biomasszával és fotoszintetikus aktivitással. A vizsgálat eredményeként született meg, és itt került elsőként publikálásra az NDVI index formula alapelve, amely később széles körben elterjedt, és robusztus, skálázható eszközt biztosított a növényzet térbeli és időbeli mintázatainak nyomon követésére. A kutatás úttörő szerepet játszott a műholdas távérzékelés mezőgazdasági és ökológiai alkalmazásaiban, különösen a nagy területű, időszakosan változó vegetációjú régiók monitorozásában. Az ERTS-1 platform és az alkalmazott módszertan megalapozta a fenntartható földhasználat- és erőforrásgazdálkodás későbbi fejlődését (Cooper és Ryan, 1975).

Persico et al. (2024) cikkükben a Sudd-mocsár (Afrika legnagyobb trópusi vizes élőhelye) hidrológiai és ökológiai változásait vizsgálták, különös tekintettel a klímaváltozás hatásaira. Több évtizednyi műholdas és éghajlati adatsor (NDVI, felszíni víz kiterjedése, vízszint, csapadék és hőmérséklet) alapján elemezték a térbeli és időbeli trendeket. Az NDVI alapú eredmények szerint a központi területeken a vegetáció kiterjedése csökkent, míg a peremrészekben növekedett. A felszíni vizek kiterjedése összességében nőtt: a tartós vízfelszín aránya kis mértékben (3%-kal), míg az időszakos előntések jelentősen (19%-kal). A felszíni vízszintek is lassú, de folyamatos emelkedést mutattak. A hőmérséklet trendszerűen nőtt (~0,7 °C), a csapadék pedig több délkeleti térségben szignifikánsan emelkedett. A kutatás rámutat, hogy a Sudd ökoszisztémáját és vízháztartását a klímaváltozás mellett az emberi hatások is erősen befolyásolják, ezért a fenntartható vízgazdálkodás és természetvédelem kulcsfontosságú a térség jövője szempontjából.

Kovács (2004) által írt tanulmány a Duna–Tisza közí vizes élőhelyeken végzett NDVI-alapú vegetációvizsgálatra fókuszál. A kutatás célja az volt, hogy műholdas távérzékelés (Landsat-felvételek) alapján kvantitatívan jellemezze a vízborítottság és a növényzet viszonyát, különösen a vegetációs periódus kezdeti és csúcspontján. A vizsgálat során az NDVI segítségével mérték a fotoszintetikusan aktív növényzet arányát, és annak változását különböző vízállású élőhelyeken. A tanulmány eredményei szerint az NDVI értékek jól tükrözik a vízborítottság mértékét és annak szezonális hatását a vegetációs aktivitásra. Az alacsonyabb

vízborítású területeken (pl. kiszáradó laposok, időszakos mocsarak) jellemzően magasabb NDVI értékek jelentkeztek a nyár folyamán, míg a tartósan víz alatt álló részekben a vegetáció fejlődése gátolt volt. Kiemeli az NDVI térképek hasznosságát a természetvédelmi és tájhasználati beavatkozások tervezésében, különös tekintettel a vizes élőhelyek állapotának monitorozására és az élőhely-rekonstrukciók hatékonyságának értékelésére.

Huang et al. (2020) áttekintést ad az NDVI-index alkalmazásáról mezőgazdasági aszályhelyzetek értékelésében és monitorozásában. A szerzők az NDVI használatának módszertani alapjait tekintik át, beleértve a vegetációs válaszdő és a meteorológiai tényezők kapcsolatát. Kiemelik az NDVI előnyeit, mint például az egyszerű számíthatóságot és a nagyléptékű alkalmazhatóságot, ugyanakkor rámutatnak a korlátaira is, például a telítődési effektusra vagy a felhőborítás problémáira. A cikk hangsúlyozza a vegetációs indexek integrálásának fontosságát egyéb indikátorokkal (pl. talajnedvesség, csapadék), különösen döntéstámogatási rendszerekben. A szerzők megállapítják, hogy az NDVI értelmezése erősen kontextusfüggő, és csak megfelelő kalibrációval és validációval alkalmazható megbízható módon aszályérzékeny területeken. A tanulmány továbbá javaslatokat tesz az NDVI-alapú monitoring fejlesztésére, többek között a különböző távérzékelési források kombinálásával és a tér-időbeli dinamikák figyelembevételével.

McFeeters (1996) az NDWI alkalmazását mutatja be a nyílt vízfelszínek pontosabb lehatárolására távérzékelte adatok alapján. Az NDWI-t úgy alakították ki, hogy a zöld és a közeli infravörös (NIR - Near-infrared) sávok eltérését felhasználva maximalizálja a vízfelszínek kiemelését, miközben csökkenti a talaj és növényzet jelenlétének hatását a képeken. A hagyományos NIR-alapú vagy sávhányados módszerekhez képest az NDWI jobban elhatárolja a víztesteket a szárazföldi fedettségtől. A szerző demonstrálja az NDWI működését Landsat MSS felvételeken, és javaslatot tesz annak alkalmazására a vízminőség, különösen a zavarosság (turbiditás) vizsgálatában is. Bár a szélessávú spektrális megközelítés korlátozott lehet a vízminőség egyes paramétereinek elkülönítésében, az NDWI így is értékes eszköz lehet a felszíni vízkészletek mennyiségi és minőségi értékelésére.

Sahoo et al. (2015) tanulmányukban Punjab állam (India) Sri Muktsar Sahib körzetében vizsgálta a belvíz előfordulását műholdfelvételek, domborzati adatok (DEM) és talajvízszint-mérések integrálásával. A kutatás fő célja a NDWI és a MNDWI vízindexek teljesítményének összehasonlítása volt, különösen olyan területeken, ahol a víz felszíni növényzettel vagy beépített környezettel keveredik. Az eredmények azt mutatták, hogy az NDWI gyakran negatív értékeket adott a víz–növényzet keveredés miatt, és hajlamos volt a beépített felszíneket vízként osztályozni, míg a MNDWI pozitív értékeket mutatott a víz esetében, és sokkal hatékonyabban különítette el a vízborítású területeket a beépített zónáktól. A MNDWI-vel végzett osztályozás 96,9%-os pontosságot és 0,89-es Kappa értéket ért el. A DEM és a talajvízszint összevetése rámutatott, hogy a belvíz kialakulása leginkább az alacsonyabb fekvésű, sekély talajvízszintű területeken, illetve a csatornák mentén a szivárgás következtében volt jelentős. A kutatás hangsúlyozza, hogy a MNDWI integrálása domborzati és hidrológiai adatokkal gyors és megbízható módszer a belvíz detektálására, amely támogatja a vízgazdálkodási beavatkozások megtervezését és a mezőgazdasági károk csökkentését.

Worden és de Beurs (2020) tanulmánya a Kaukázus térségében vizsgálta a felszíni vizek feltérképezhetőségének módszereit, Landsat 8 optikai műholdfelvételek felhasználásával, három ország (Grúzia, Örményország, Azerbajdzsán) száraz (július) és nedves (október) meteorológiai időszakában. Öt vízetektálási módszert – négy indexet (NDWI, MNDWI, AWEIsh, AWEInsh - Automated Water Extraction Index) és a Zou et al. (2017) által kidolgozott MNDWI–NDVI/EVI (Enhanced Vegetation Index) kombinált algoritmust – hasonlítottak össze, valamint értékelték az European Commission Joint Research Centre (ECJRC) globális felszíni vízterméket is. A 5744 Google Earth pont manuális osztályozásával végzett validáció alapján a logisztikus regresszióval és optimális valószínűségi küszöbvel (OPC - Optimal Probability Cut-off) kombinált MNDWI teljesített a legjobban, 93%-os átlagos pontossággal. Az ECJRC termék a nagyobb vízfelületek esetén megbízható, de az 5 hektárnál

kisebb víztestek jelentős részét kihagyja. A szerzők kiemelik, hogy a rugalmas, képspecifikus küszöbértékek jobban alkalmazkodnak a helyi környezeti viszonyokhoz, mint a fix értékek. A jövőbeni felszíni víztérképezés hatékonysága a finomabb felbontású és többforrású (optikai és aktív távérzékelési) adatok integrálásával növelhető.

Du et al., (2016) tanulmányának célja egy 10 méteres térbeli felbontású víztest-lehatárolási módszer kidolgozása Sentinel-2 műholdképeken MNDWI alkalmazásával. Az eredetileg 20 méteres SWIR sávot a szerzők spektrális fúzióval élesítették, hogy a teljes MNDWI-indexet 10 méteres felbontással generálhassák. A módszert három képegyesítési technika (IHS-Intensity-Hue-Saturation transzformáció, HPF-High-Pass Filter élesítés és Gram-Schmidt) alkalmazásával vizsgálták. A vizsgálati terület Velence (Olaszország) városának vizsgálatát foglalta magába, amely ideális mintaterületnek bizonyult a városi víztestek sokfélesége és a város komplex felszínborítása miatt. Az eredmények alapján a Gram-Schmidt-féle fúziós módszer nyújtotta a legjobb pontosságot, mind a víz-nem víz osztályozás, mind a határvonalak élessége szempontjából. A kutatás rámutatott arra is, hogy az élesített MNDWI jobban elkülöníti a víztesteket a sötét épített felszínű objektumoktól, mint az NDVI, így a javasolt módszer hasznos eszköz lehet a városi víztestek nagy felbontású térképezéséhez.

A távérzékelte adatok feldolgozásában az indexalapú módszerek mellett egy másik jelentős csoportot alkotnak a korszerű gépi tanuláson és mélytanuláson alapuló technikák, mint például a döntési fák (Decision Trees, DT), a gradiens boosting döntési fa (Gradient Boosting Decision Tree, GBDT), a ML, a RF és az SVM, valamint az mesterséges neurális hálózatok (Artificial Neural Network, ANN), és a konvolúciós neurális hálózatok (Convolutional Neural Network, CNN).

A döntési fa (DT) egy felügyelt gépi tanulási algoritmus, amely osztályozási és regressziós problémák megoldására egyaránt alkalmas. A módszer a bemeneti attribútumok alapján hierarchikus, elágazó döntési szabályokat alkot, melyeket egy fa struktúrában ábrázol. Minden belső csomópont egy változóra vonatkozó feltételt, míg a levelek az előrejelzett értéket vagy osztályt tartalmazzák. A De Ville (2013) által bemutatott áttekintés szerint a döntési fák egyik legfőbb erőssége az intuitív értelmezhetőség és a nemlineáris kapcsolatok feltárására való képesség, amely különösen előnyös az összetett, többváltozós rendszerek - például környezeti és hidrológiai folyamatok – modellezésében. A szerző részletesen ismerteti a legismertebb döntési fa algoritmusokat (pl. CART - Classification and Regression Trees, ID3 - Iterative Dichotomiser 3, C4.5), és kitér azok metszési stratégiáira, túlilleszkedésre való hajlamára, valamint a prediktív teljesítményükre. A döntési fákat gyakran használják alapmodellként más fejlettebb algoritmusokban is, így például a RF vagy a GBDT rendszerekben, ahol több fát kombinálva növelhető a modell robusztussága és predikciós pontossága. A tanulmány kiemeli, hogy a döntési fák alkalmazása a térinformatikai adatok feldolgozásában is elterjedt, mivel jól kezelik a heterogén bemeneteket, és könnyen integrálhatók térbeli elemzésekbe.

A GBDT egy felügyelt gépi tanulási technika, amely gyenge tanulók - leggyakrabban alacsony mélységű döntési fák - iteratív illesztésével épít fel egy nagy prediktív teljesítményű modellt. Minden új modell a korábbi iteráció hibáira koncentrál, és a veszteségfüggvény gradiensének irányába haladva javítja az előrejelzést. Ennek a módszer egyik fő előnye, hogy képes megbirkózni komplex, nemlineáris kapcsolatokkal, valamint jól kezeli a heterogén bemeneteket és a változók közötti interakciókat is. Chen és Guestrin (2016) fejlesztették ki az XGBoost rendszert, amely a gradiensnöveléses döntési fák (GBDT) módszerén alapul. A keretrendszer fő erőssége a számítási hatékonyság és a túlillesztés mérséklését szolgáló regularizáció, ami hozzájárult széleskörű alkalmazásához, többek között a térinformatikai és környezeti modellezés területén is.

Az ML osztályozás, amely a távérzékelés egyik legismertebb statisztikai alapú eljárása. A módszer a spektrális sávok közötti valószínűségi eloszlásokon alapul, és a pixeleket annak az osztálynak a javára sorolja be, amelyhez való tartozás valószínűsége maximális (Tso és Mather, 2009). Yilmaz et al., (2023) tanulmányukban a különféle vízindexek (NDWI, MNDWI) és osztályozási algoritmusok (RF, ML, K-means, Otsu) teljesítményének összehasonlítását

mutatták be a Sentinel-2 és Landsat-8 műholdképek alapján a törökországi Demirköprü-víztározó területén. A kutatás során több időpontból származó képeket dolgoztak fel, a vízfelszíneket különböző módszerekkel detektálták, és a kapott eredményeket manuálisan digitalizált referenciatérképek alapján értékelték. A Random Forest algoritmus nyújtotta a legjobb eredményeket, míg a ML közepes teljesítményt mutatott, különösen a kisebb víztestek esetében. Az indexek közül az AWEI bizonyult a legmegbízhatóbbnak a különböző osztályozási eljárásokkal kombinálva. A Sentinel-2 adatok a Landsat-8-hoz képest jobb térbeli felbontást (10 m kontra 30 m) és rövidebb visszatérési időt (5 nap kontra 16 nap) biztosítanak, ami különösen előnyös a kisebb, változékony vízfelületek pontos nyomon követéséhez. A szerzők ennek megfelelően a Sentinel-2 alkalmazását javasolják vízmegfigyelési célokra.

Az RF algoritmus egy döntési fákot használó együttes tanulási eljárás. Robusztus működése, kevés beállítandó paramétere és magas osztályozási pontossága miatt vált népszerűvé a távérzékelési gyakorlatban. Kifejezetten jól kezeli a nagy dimenziós adatokat, és hatékonyan alkalmazható automatikus belvízdetektálásra is (Ming et al., 2016; Jin et al., 2018). Wangchuk és Bolch (2020) kutatásuk célja gleccsertavak automatikus lehatárolása Sentinel-1 radar- és Sentinel-2 optikai műholdképek, valamint Random Forest osztályozó alkalmazásával, nyolc teszterületen. A kutatás során különböző bemeneti változók (pl. NDWI, domborzati és topográfiai jellemzők) felhasználásával több ezer 10×10 m-es pixel alapján tanították az RF modellt. Az osztályozás Sentinel-2 esetén ~95%-os, Sentinel-1 esetén ~85%-os pontosságot ért el; ugyanakkor a Sentinel-1 előnye a felhőfüggetlenség, míg a Sentinel-2 részletesebb spektrális információt és jobb körvonal-lehatárolást biztosít. Kihívást jelentett a kis tavak detektálása, az árnyékos területek és a jég-víz keveredés elkülönítése. A szerzők javasolják a multiszenzoros adatok kombinálását és a tér-időbeli változásokra érzékeny módszerek fejlesztését a globális gleccsertó-monitoring javítása érdekében.

Gudmann et al. (2019) kutatásukban a felszínborítási kategóriák automatikus osztályozásának lehetőségeit vizsgálták nagyfelbontású távérzékelési adatok felhasználásával a CORINE Land Cover (CLC) rendszerhez igazodva. A szerzők Sentinel-2 műholdképeken alapuló feldolgozási láncot dolgoztak ki, amelyhez gépi tanulási algoritmusokat (például Random Forestet) alkalmaztak. A kutatás fontos hozadéka, hogy az automatikus osztályozás eredményei már megközelítik a manuális térképezés pontosságát, miközben jelentős idő- és erőforrás-megtakarítást tesznek lehetővé. A tanulmány részletesen bemutatja a feldolgozási lépéseket, a kiválasztott bemeneti paramétereket és az osztályozási pontosságot. Eredményeik azt mutatják, hogy az automatikus módszerek a jövőben egyre inkább kiegészíthetők, sőt részben helyettesíthetők a hagyományos CLC-adatfrissítési gyakorlatot.

Az SVM algoritmust Cortes és Vapnik (1995) vezették be, akik a strukturális rizikó-minimalizálás elvén alapuló, hatékony osztályozási módszert dolgoztak ki. A lineáris elválasztás mellett bevezették a kernel-függvények alkalmazását is, amely lehetővé teszi a nemlineáris problémák magas dimenziós térben történő megoldását. Az SVM a kis mintaszámú, de nagy dimenziójú adathalmazok esetén is bizonyítottan jó általánosító képességgel rendelkezik, ezért napjainkban is az egyik legelterjedtebb gépi tanulási eljárás.

Huang et al. (2002) tanulmányukban az SVM alkalmazhatóságát vizsgálták a földfelszín-borítás osztályozásában, különös tekintettel a távérzékelési multispektrális adatokra. A kutatók a Maryland állambeli Chesapeake Bay térségéből származó Landsat TM képeket használták fel, és összehasonlították az SVM teljesítményét a hagyományos osztályozási módszerekkel, mint például a döntési fákkal és a neurális hálókkal. Az eredmények szerint az SVM robusztusabb osztályozási teljesítményt nyújtott, különösen akkor, amikor kevés tanító adat állt rendelkezésre. Az SVM nem igényel előzetes feltételezést az adatok eloszlásáról, és jól kezeli a nemlineáris döntési határokat is. A tanulmány kiemeli, hogy az SVM különösen előnyös heterogén tájhasználatú területeken, és a megfelelő kernelválasztás (pl. lineáris, polinomiális vagy radiális bázisfüggvény – RBF - Radial Basis Function) kritikus a modell teljesítménye szempontjából.

John és Varghese (2022) kutatásának célja az SVM és az ML osztályozók összehasonlítása Sentinel-2 műholdképeken végzett felszínborítási osztályozásban, India középső részén, Maharashtra állambeli Nagpur körzetében. A kutatás során öt felszínborítási kategóriát különítettek el: bozótos terület, erdő, vízfelület, mezőgazdasági terület és beépített terület. A Sentinel-2 képeken végzett előfeldolgozást követően a szerzők mindkét módszert alkalmazták, majd a pontosságot összehasonlító mutatókkal (overall accuracy, Kappa-statisztika) értékelték. Az SVM módszer 89,13%-os pontosságot és 0,84-es Kappa-statisztikát, míg az ML módszer 83,76%-os pontosságot és 0,77-es Kappa-értéket ért el. Az SVM jobban kezelte a spektrálisan átfedő osztályokat (pl. bozótos és erdő), míg az ML érzékeny volt a normális eloszlásokra vonatkozó feltételezések sérülésére. A tanulmány javasolja az SVM alkalmazását a Sentinel-2 adatokkal végzett földhasználati térképezésben, különösen heterogén tájakon.

Mucsi és Henits (2011) kutatásukban a belvízzel elöntött területek térképezését végezték el közepes felbontású Landsat ETM+ műholdfelvételek felhasználásával, szubpixel-alapú osztályozás révén. A vizsgálat mintaterülete a Dél-Alföldön, Székkutas településtől délkeletre található, mintegy 86 km²-es területen, amely mezőgazdasági hasznosítású és természetvédelmi övezeteket is magába foglal. A kutatók a Lineáris Spektrális Szétválasztás (LSMA- Linear Spectral Mixture Analysis) módszerét alkalmazták, amely lehetővé tette, hogy egy pixel spektrális jele alapján megbecsüljék három felszínborítási típus (víz, növényzet, talaj) részarányát. A módszer előnye, hogy a kevert pixelek esetén is képes megbízhatóan azonosítani a részben vízborított területeket, amelyek a hagyományos osztályozással gyakran rejtve maradnak. Az LSMA alapján készült belvízelöntési térképek jól tükrözik a heterogén elöntési mintázatokat, és megbízhatóbb kvantitatív információt szolgáltatnak a vízborítás kiterjedéséről, mint a pixel-alapú megközelítések. A pixelszintű osztályozási eljárások ezt a folyamatot tovább pontosítják, különösen heterogén felszínborítottságú síkvidéki térségekben.

Csendes és Mucsi (2016) tanulmányának célja a belvízzel borított felszínek nagy felbontású hiperspektrális légi felvételeken történő azonosítása a Szeged melletti Tápai-rét mikrotérségében, amely gyakori elöntéseiről ismert. A kutatás során AISA (Airborne Imaging Spectrometer for Applications) szenzorral gyűjtött hiperspektrális adatokat és nagyfelbontású LIDAR domborzatmodellt használtak. A felszínborítás osztályozása Spectral Angle Mapping (SAM) módszerrel történt, 85%-os pontosságot és 0,8-as Kappa indexet eredményezve. A leggyengébb szétválaszthatóság a nedves talajok és sekély vízfelszínek között mutatkozott, míg a vegetáció jól elkülöníthető volt. A LIDAR adatok alapján a víztestek a legalacsonyabban fekvő területekre koncentráálódtak, igazolva a vízborítás és a mikrodomborzat kapcsolatát. A kombinált távérzékelési módszer megbízhatóan azonosította a belvíz által veszélyeztetett területeket, különösen a környezeti szempontból érzékeny olaj- és gázkitermelő létesítmények térségében.

Balázs et al., (2018) tanulmányuknak célja a felszíni víz és vízhez kötődő felszínborítási típusok feltérképezése Landsat 7 ETM+ műholdfelvételek alapján a Rétköz területén, a 2000. márciusi árvíz idején. A kutatók a spektrális reflektanciaadatokból képzett NDVI, NDWI és MNDWI vegetáció- és vízindexeket kombinálták főkomponens-analízissel (Principal Component Analysis - PCA), hogy a spektrális varianciák alapján elkülönítsék a vízborított és nem borított felszíneket. A képzési mintákra épülő irányított osztályozást RF és SVM algoritmusokkal végezték el. Eredményeik szerint az eredeti sávok használata 93–94%-os általános pontosságot (OA) eredményezett, míg az egyes vízindexek többsége 60–70%-os OA-val teljesített. A MNDWI index kiemelkedően pontosnak bizonyult (98% OA), de a legjobb eredményeket a PCA-val transzformált sávok adták, ahol a pontosság elérte a 99–100%-ot. A PCA tehát növelte az osztályozás megbízhatóságát, különösen a víztestek és telített talajok elkülönítésében. A kutatás végkövetkeztetése, hogy a PCA-alapú megközelítés hatékonyabb a vízzel kapcsolatos felszínek feltérképezésében, mint az önálló spektrális indexek, és megbízható eszközt jelent a vízgazdálkodási döntéstámogatásban.

Az aktív (radar) és passzív (optikai) műholdas adatok integrálása megfelelő tér- és időbeli felbontással biztosít lehetőséget a belvízi területek dinamikus monitorozására. Gálya et al.

(2016) tanulmányának célja a belvízérzékenység térképezése Sentinel-1A radaros műholdfelvételek alapján, 2015. január és december közötti időszakra, havi bontásban készült 12 felvétel felhasználásával. Az egyes időpontokra készített vízborítottsági térképekből a szerzők belvíz gyakorisági térképet állítottak elő, amely alapján belvízérzékenységi kategóriákat hoztak létre. Az eredmények összevetése a CORINE felszínborítási adatokkal azt mutatta, hogy a többletvízborítottság leginkább gyepterületeket érintett. A térképek értékeléséhez használt - Közép-Tisza-vidéki Vízügyi Igazgatóság (KÖTIVIZIG) - hidrológiai adatok alapján megválasztott küszöbértékek nem minden esetben tükrözték pontosan az elöntések térbeli kiterjedését, így az azonosítás korlátokba ütközött. A szerzők javaslata szerint, a módszer fejlesztése érdekében érdemes lenne Sentinel-1 és Landsat-8 adatok együttes, integrált kiértékelését megvalósítani, amely pontosabb eredményeket biztosíthatna más területeken és eltérő időszakokban is.

Gulácsi és Kovács (2019) tanulmányukban a vizes élőhelyek és vízborítottság időbeli nyomon követésére dolgoztak ki egy módszert Sentinel-1 C-SAR (Synthetic Aperture Radar) radaros műholdfelvételek alapján, havi léptékben, közepes térbeli felbontással. A feldolgozást a Google Earth Engine (GEE) felhőalapú platformon végezték, amely lehetővé tette a műholdképek gyors, automatizált és ismételt feldolgozását, nagy időfelbontás mellett. A módszer lényege a VV polarizációjú visszaszórási értékek küszöbértékes osztályozása volt, amely időjárástól független, felhőborítottság esetén is megbízható detektálást biztosított. A radaros eredményeket Sentinel-2 MSI és Landsat 8 OLI optikai műholdfelvételek MNDWI indexe alapján validálták, amely során magas és közepes korrelációt kaptak, igazolva a radaros eljárás megbízhatóságát. A vizsgálat rámutatott a szenzorérzékenységet befolyásoló tényezők – például a szélesebbesség, a vegetáció és az emelkedő/süllyedő pályákból adódó különbségek – hatására, amelyek egyes időszakokban (pl. 2016. január–február, 2017. április) rontották a képminőséget. Bár a radarjelek szemcsés zajának csökkentésére törekedtek, továbbra is előfordultak tévesen víznek osztályozott pixelek. A szerzők szerint a módszer továbbfejleszthető nagyobb térbeli felbontású adatok vagy drónfelvételek integrálásával, és így alkalmas lehet belvízmonitoring célú vizsgálataokra is. Eredményeik azt mutatják, hogy a nyílt forráskódú, felhőalapú feldolgozás hatékony eszközt biztosíthat a nagyléptékű, nagy időfelbontású vízborítottsági monitoring feladatok számára.

Birinyi et al., (2024) kutatásában a Sentinel-1A radaros felvételek alkalmazhatóságát vizsgálta belvízdetektálásra egy alföldi mintaterületen. A vízfelületek lehatárolására az Edge Otsu módszert alkalmazták, amely éldetektálás és küszöbérték-meghatározás kombinációjával választja szét a víz és nem víz kategóriákat reprezentáló pixeleket. A validáció során Sentinel-2 NDWI alapján jelölték ki 500 állandó vízpontot, valamint a belvízgyakorisági térképből származó 500 belvízre hajlamos és 500 nem hajlamos pontot használtak fel. Az időbeli változásokat a NASA SMAP talajnedvesség-anomáliáival és a Sentinel-1 adatokból számított SurfMI indexszel vetették össze. Az eredmények szerint a vízfelületek detektálási pontossága jellemzően 80% felett, míg a nem víz kategória közel 100% volt. A belvíztalálatok időbeli mintázata jól korrelált a talajnedvesség-adatokkal, bár aszályos időszakokban fals pozitív előfordulások jelentkeztek. A módszer ígéretesnek bizonyult, de operatív alkalmazása előtt szükséges a meteorológiai és talajnedvesség-adatok integrálása

A belvízborítás detektálásában új távlatokat nyitott a mélytanulási módszerek alkalmazása, különösen az ANN és a CNN hálózatok, amelyek az elmúlt években a Föld-megfigyelés területén is egyre szélesebb körben terjedtek el (Van Leeuwen et al., 2012). A Van Leeuwen et al. (2008) által fejlesztett módszertani keretrendszer célja, az ANN és a GIS integrálása volt a belvízborítások pontos azonosítása érdekében. A Tápai-rét mintaterületen végzett kutatás során LIDAR-adatok, színes infravörös felvételek és terepi mérések szolgáltattak bemeneti forrásként. Az ANN-alapú osztályozás jobb teljesítményt nyújtott, mint a hagyományos statisztikai eljárások, különösen nemlineáris összefüggések esetén. Az eredmények alátámasztják az ANN-GIS integráció potenciálját a belvízmonitoringban, bár további fejlesztések szükségesek az általánosíthatóság javítása érdekében.

Szatmári et al. (2011) különböző forrásokból – távérzékelés, terepi felmérés, meteorológiai és talajtani adatok – származó információkat integráltak a belvízmegjelenés előrejelzésére. A modellezéshez mesterséges neurális hálózatokat alkalmaztak, amelyek lehetővé tették a belvíz kialakulásának valószínűségi térképezését. A módszer újdonságát a nemlineáris összefüggések felismerése és a térbeli előrejelzés pontosságának javítása jelentette. Eredményeik alapján a neurális hálók hatékony eszközt jelenthetnek a belvízmonitoring új generációs megközelítéseiben.

Van Leeuwen et al. (2013) tanulmányukban három osztályozási módszer – ML, Spektrális keverési analízis (Spectral Mixture Analysis - SMA) és az ANN – teljesítményét hasonlították össze RapidEye műholdképek alapján. Az ANN módszer bizonyult a legpontosabbnak, míg az SMA jelentősen alulmaradt a vízosztályok tévesztése miatt. Az eredmények alátámasztják, hogy a neurális hálózatokon alapuló félautomatikus osztályozások hatékonyan alkalmazhatók nagy kiterjedésű síkvidéki belvízterületek feltérképezésére. A kutatás rámutatott a távérzékelési technikák gyakorlati alkalmazhatóságára a belvízmonitoringban.

A CNN módszerek napjaink egyik legígéretesebb eszközei a belvízdetektálásban, mivel képesek a műholdképek többsávós adatstruktúrájának térbeli és spektrális értelmezésére, valamint a felszínborítási mintázatok komplexitásának automatikus felismerésére (Zhu et al., 2017). E hálózatok különösen jól kezelik a belvizes területekre jellemző inhomogén, széttöredezett felszíni jelenségeket, amit korábbi kutatások (Kajári et al., 2022b) is megerősítettek a Sentinel-2 adatokra épülő elemzések során. Előnyük az automatikus textúrafelismerés és a nagy osztályozási pontosság, azonban alkalmazásuk jelentős számítási kapacitást és jól tanított, reprezentatív adathalmazt igényel, különösen nagy felbontású multispektrális képek esetén.

A fentiekben ismertetett módszerek összehasonlító elemzése lehetőséget kínál annak meghatározására, hogy adott térbeli és időbeli felbontás mellett mely eljárások nyújtják a legnagyobb pontosságot és alkalmazhatóságot a belvíz detektálásában – különös tekintettel a felhős és derült műholdképi környezetekre.

A 2.2-es fejezetben bemutatott belvízkutatás több mint másfél évszázados fejlődése rendkívül gazdag tudományos és gyakorlati tapasztalatokat eredményezett, amelyek szerves módon beépültek a disszertációban bemutatott kutatási koncepciókba és módszertani megközelítésekbe. A 19. század végi vízmérnökök által alkalmazott becsléses eljárások és táblázatos értelmezések, majd a 20. század közepén megjelenő dinamikus hidrológiai modellek és regressziós elemzések jelentős inspirációt nyújtottak a prediktív szemléletű belvízmodellezéshez. A térképezési gyakorlat fejlődése – különösen Pálfi Imre, Mosonyi Emil és Várallyay György munkái nyomán – rávilágított, hogy a belvízjelenségek komplex módon, többféle természeti és antropogén tényező együttes hatásaként értelmezhetők. A domborzat, a talajtani viszonyok, a vízháztartás és a földhasználat együttes figyelembevétele mára elengedhetlenné vált a kockázati besorolás és a vízgazdálkodási beavatkozások megalapozásához (Mosonyi, 1954; Pálfi, 2004, 2013; Várallyay, 2005, 2017).

A disszertációban bemutatott modell erre az örökségre épít, miközben korszerű gépi tanulási és távérzékelési módszereket alkalmaz Sentinel-1 és Sentinel-2 műholdképek, valamint a belvíz kialakulásában szerepet játszó környezeti és emberi tényezők együttes feldolgozásával. A cél nemcsak a pillanatnyi előtérsek nagy pontosságú detektálása, hanem a belvíz előfordulásának megbízható előrejelzése is.

3. ANYAG ÉS MÓDSZER


A kutatás célkitűzéseinek megvalósítása érdekében olyan módszertani keretet dolgoztam ki, amely alkalmas a belvízzel borított területek nagy pontosságú és automatizált lehatárolására, a vízborítás gyakoriságának kvantitatív jellemzésére, valamint a belvízhelyzet előrejelzésére. A vizsgálatok alapját a Sentinel–1 radaros és Sentinel–2 multispektrális műholdfelvételek képezték, amelyek integrált felhasználása – statikus (domborzati, talajtani, földhasználati, antropogén) és dinamikus (hidrometeorológiai) adatokkal kiegészítve - lehetővé tette a vízborítások térbeli és időbeli térképezését, valamint előrejelzését. A módszertani fejlesztések különböző léptékű és célú elemzések során valósultak meg, amelyek bemutatását egységes szerkezetben, az egymásra épülő kutatási lépések logikáját követve ismertetem. Különös hangsúlyt helyezek az alkalmazott adatforrások, előfeldolgozási lépések, modellezési eljárások és értékelési módszerek részletes bemutatására.

3.1. A vizsgálati terület bemutatása

A kutatás több lépcsőben zajlott, eltérő kiterjedésű mintaterületeken, amelyek a módszertani fejlesztés és a végső modellezés különböző fázisait támogatták. Az első vizsgálatok a Sentinel–2 műholdképek teljes, 34TDT jelű csempéjére (13. ábra) terjedt ki, amely pontosan 10 000 km² kiterjedésű területet fedett le. Ez a lépés metodikai szempontból nélkülözhetetlen volt, mivel lehetőséget biztosított a vízlehatárolási módszerek és feldolgozási paraméterek nagy területre vonatkozó tesztelésére és értékelésére, megalapozva ezzel a későbbi fejlesztési irányokat. Ezt követően egy 82,3 km²-es részterületen (15. ábra) történt a feldolgozási eljárások finomítása és validálása. A végleges, 1600 km²-es fő mintaterület (9. ábra) szolgált a belvízmonitoring és predikciós elemzések alapjául, amelyekre a dolgozat 4.4. fejezettől kezdődő eredményrész-fejezetei épülnek.

A fő mintaterület Magyarország legnagyobb nagytáján, az Alföldön található, és két középtájat ölel fel: a Közép-Tisza-vidéket és a Berettyó–Körös vidéket. A 1600 km²-es (40 × 40 km) terület öt különböző kistájat érint. Északnyugati része a Tiszafüredi–Kunhegyesi-síkra nyúlik, míg az északkeleti területek a Nagy-Sárrétre esik. A középső keleti rész a Déványai-síkon terül el, a délkeleti területrészt a Körösmenti-síkhöz tartozik. A mintaterület legnagyobb hányada a Szolnoki–Túri-síkon fekszik.

A terület egykor a Tisza folyó által szabdalta vidék volt, mely igen változatos morfológiával rendelkezik. Éghajlata mérsékelt meleg-száraz, az éves átlagos csapadék mennyisége 450–550 mm között alakul. Elsősorban szárazságtűrő, hosszú tenyészidejű és magas hőigényű növényfajták termesztésére alkalmas, ahol kiemelt szerepe lenne a vízvisszatartásnak és az öntözésnek. Felszíne tökéletes síkság, azonban mikrodomborzati viszonyait tekintve már tökéletlen sík, ezért a gyakori aszályok mellett belvizek is sújtják a mélyebben fekvő területrészeket, ahol a jellemző öntéstalajok magas agyagtartalmuk következtében gyenge víznyelő és vízáteresztő képességgel bírnak, kedvezve ezzel a belvíz kialakulásának és tartósságának. A talajvíz mélysége változó, annak ellenére, hogy sűrű csatornahálózat húzódik a vidéken; általában 2–4 m az évszakos ingadozás mellett, de a déli részekben 4–6 m közötti is lehet. A belvizes foltok a mélyfekvésű mezőgazdasági területekre, rétekre és legelőkre szorultak vissza. E mozaikos, természetközeli élőhelyek jelentős része Natura 2000 természetmegőrzési terület, ahol kiemelten fontos a természetvédelmi érdekek érvényesítése és a tájfenntartás (Csorba, 2021).



9. ábra: A vizsgálati terület

Az öt vizsgált alföldi kistáj – a Tiszafüredi–Kunhegyesi-sík, a Nagy-Sárrét, a Dévaványai-sík, a Körösmenti-sík és a Szolnoki–Túri-sík – természetföldrajzi karaktere egy rendkívül egységes, ugyanakkor mikrodomborzati szinten változatos síkvidéki táj képét rajzolja ki. A domborzati viszonyok, az üledéktani felépítés, a talajtani adottságok és a klimatikus paraméterek mindegyik terület esetében az alacsony csapadék, a gyenge lefolyás és a belvizek kockázatának kombinációját mutatják. A belvizek jelenléte ugyanakkor nemcsak mezőgazdasági kihívást, hanem ökológiai lehetőséget is jelent, hiszen a természetközeli élőhelyek megőrzésében kiemelt szerepet játszhatnak. A vizsgált tájak természeti adottságai komplex víz- és tájgazdálkodási stratégiák kialakítására adnak lehetőséget, ahol a víz visszatartás, az öntözés és a biodiverzitás megőrzése egyensúlyban tartható. E sajátosságok miatt a térség kiválóan alkalmas mintaterületként a belvízdetektálási és előrejelzési módszerek fejlesztésére és tesztelésére.

3.2. Adatbázisok

Az általam létrehozott modell alapját távérzékeléses adatgyűjtési eljárásokon alapuló adatok képezik, ezért kiemelt figyelmet fordítottam a szabadon hozzáférhető műholdfelvételek áttekintésére és összehasonlító értékelésére. A választott adatsorok ismertetése során külön hangsúlyt kap a döntés indoklása, különösen abból a szempontból, hogy az adott műholdrendszer milyen pontossággal képes azonosítani és lehatárolni a nyílt vízfelületeket, valamint az időszakosan megjelenő, ideiglenes víztesteket – beleértve a belvizes területeket is.

A statikus és dinamikus adatbázisok térbeli és időbeli felbontását, tematikus tartalmát, valamint a belvízdetektálásban és -predikcióban betöltött szerepét külön ismertettem, ugyanis az adatok jellege és minősége alapvetően meghatározza a modell teljesítményét és alkalmazhatóságát, ezért az adatbázis-választás indoklása módszertani szempontból is hangsúlyos.

3.2.1. Műhold adatok

A kutatás célkitűzései alapján a műholdas távérzékelési adatok kiválasztásánál elsődleges szempont volt az általuk biztosított megfelelő, nagy területi lefedettség és a belvízfeltok megbízható detektálásához elegendő térbeli felbontás. A vizsgált víztestek mérete a néhány száz négyzetméteres lokális elöntésektől a több hektáros összefüggő belvízterületekig terjedt, ezért a centiméteres (1–2 cm) felbontású, de csak kis kiterjedésű területeket lefedő – például drónos vagy légi – felvételek alkalmazása nem bizonyult indokoltnak. Az ilyen felvételek felhasználhatóságát tovább korlátozza, hogy országos léptékben történő, rendszeres és költséghatékony adatgyűjtésre nem alkalmasak, és még a nagyobb, 50 hektár feletti vízborítások térképezése esetén is jelentős technikai és logisztikai korlátokba ütköznének. Mindezek alapján a kis területi lefedettségű, túlzottan nagy felbontású adatok a jelen kutatásból kizárásra kerültek, a műholdas távérzékelés pedig optimális kompromisszumot nyújtott a térbeli felbontás és a nagy kiterjedésű, rendszeres monitorozás lehetősége között.

A belvízmonitoring szempontjából megfelelő egyensúlyt a néhány méteres vagy tízméteres felbontású multispektrális műholdfelvételek biztosítják. A hazánkat rendszeresen lefedő releváns szenzorok közé tartozik a *Sentinel-2*, *Landsat-8*, *MODIS* és a *PlanetScope*, valamint a Sentinel-1 műholdrendszer táblázatát az 1. melléklet tartalmazza. A műholdfelvételek kiválasztásánál további fontos szempont a rövid visszatérési idő, amely alapfeltétele egy operatív, kvázi-folyamatos megfigyelési rendszer kialakításának.

A műholdas multispektrális adatok használatának korlátját a felhőborítottság és az abból fakadó légköri zavarok jelentik, különösen a belvizes időszakokban (késő ősztől kora tavaszig). E problémák mérséklésére a radaros távérzékelés kínál hatékony megoldást, amely időjárási és napszakfüggetlen adatszolgáltatást tesz lehetővé. A *Sentinel-1* műholdcsalád napjainkban is az egyetlen olyan, nagy területi lefedettséget biztosító és megfelelő térbeli felbontású szintetikus apertúrájú radar (SAR) adatforrás, amely az Európai Űrügynökség (ESA) rendszerén keresztül szabadon hozzáférhető. A Sentinel-1 adatok kiválóan kiegészítik a multispektrális felvételeket, elősegítve a visszatérési idő csökkentését és a detektálás időbeli sűrítését. Ugyanakkor a kutatás időszakában a Sentinel-1 Level-1C (vagy magasabb feldolgozottsági szintű) adatok még nem álltak rendelkezésre, ami a feldolgozásban és az automatizált előfeldolgozási lépésekben bizonyos korlátokat jelentett.

A műholdfelvételek kiválasztására vonatkozó döntések – a térbeli felbontás, a visszatérési idő és az időjárásfüggetlen adatszolgáltatás szempontjainak mérlegelésével – alapvetően meghatározták a kutatás módszertani keretét. A Sentinel-2 multispektrális és a Sentinel-1 radaros adatok kombinációja biztosította azt a kompromisszumot, amely lehetővé tette a belvízi állapotok pontos térbeli és időbeli detektálását. E megfontolások eredményei és a műholdas adatok felhasználásának gyakorlati tapasztalatai az „Eredmények” fejezetben kerülnek részletes ismertetésre. A módszertani döntések szoros kapcsolatban állnak a dinamikus belvízdetektálási és prediktív modell kialakításával, amely a kutatás egyik legfőbb innovációját képviseli.

3.2.2. Dinamikus adatok

A kutatás során felhasznált hidrometeorológiai adatok az Országos Meteorológiai Szolgálat (OMSZ) napi felbontású, országos lefedettségű adatbázisából [9] származnak, amely részletes időjárási paramétereket biztosít az egyes meteorológiai állomásokra vetítve (Bihari et al., 2018). Az adatok földrajzi lekérdezése során minden állomáshoz hozzárendelésre került annak egyedi azonosítója, földrajzi koordinátái, valamint az alábbi napi időléptékű meteorológiai változók:

- csapadékmennyiség (mm),
- globálisugárzás (J/m^2),
- relatív páratartalom (%),
- napi minimum- és maximumhőmérséklet ($^{\circ}C$),
- 10 méteres magasságban mért átlagos szélsebesség (m/s).

A felsorolt paraméterekre alapozva Python script [10] segítségével számítottam ki a potenciális evapotranspirációt (PET) a Penman–Monteith-formula alkalmazásával (Ponce, 1989; Vremec et al. 2024):

$$ET_0 = \frac{0,408 \Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34 u_2)} \quad (1)$$

ahol:

ET_0 : referencia evapotranspiráció (mm/day)

Δ : telített vízgőznyomás görbülete hőmérséklet függvényében (kPa K⁻¹)

R_n : nettó sugárzás (MJ m⁻² day⁻¹)

G : talajhő-fluxus (MJ m⁻² day⁻¹, általában elhanyagolható)

T : napi átlaghőmérséklet (°C) vagy Kelvin (külön jelölve)

u_2 : légsebesség 2 m magasságban (m s⁻¹)

δe : vízgőznyomás deficit (kPa) – a telített és a tényleges vízgőznyomás különbsége

γ : pszichrometrikus állandó (~0,066 kPa K⁻¹)

Az így előállított napi PET-idősorok a vízháztartási egyensúly szempontjából meghatározó szerepet töltenek be, különösen az előtött területek visszahúzóási dinamikájának modellezésében. Míg a csapadék a belvízképződés elsődleges kiváltó tényezője, addig az evapotranspiráció és a légmozgás – mint a víztöbblet csökkenésének gyorsító hatásai a napszivattyú jelenségnek köszönhetően (Matta et al., 2022) – a víztestek tartósságát, illetve visszahúzóási idejét befolyásolják.

A fenti változók tehát időben változó, ún. dinamikus bemeneti tényezőként kerültek integrálásra a prediktív modellbe, a belvíz megjelenésének, eltűnésének és időbeli tartósságának előrejelzése céljából.

3.2.3. Statikus adatok

Domborzat

A domborzati tényező vizsgálatához digitális domborzatmodellt (DDM) használtam fel, amely az 1:10 000 méretarányú topográfiai térképek szintvonalrajzain alapul, amelyeket sztereofotogrammetriai kiértékeléssel pontosítottak [11]. Az alaptérképek 1979–2000 közötti felmérésekből származnak, míg a jelentősebb domborzatváltozásokat – például autópálya-építések vagy külszíni bányák megjelenését – 2000, 2005 és 2015 során végzett országos fotogrammetriai frissítésekkel aktualizálták. Az adatállomány az Egységes Országos Vetületi rendszerben (EOV) áll rendelkezésre. A modell öt méteres térbeli felbontása lehetővé teszi a felszíni vízmozgások és belvízgyülekezési helyek részletes vizsgálatát. A lefolyástalan mélyedések azonosításán túl a domborzati derivátumok – mint a lejtőszög, profilgörbület és síkgörbület – fontos geomorfológiai indikátorokként szolgálnak. A profilgörbület a felszín domborúságát vagy homorúságát a maximális lejtés irányában jellemzi, míg a síkgörbület a vízszintes XY síkban határozza meg a konvexitási vagy konkávitási viszonyokat. E paraméterek kombinációja elősegíti azoknak a mikrorelief-elemeknek a feltárását, ahol a víz összegyülekezésének, és így a belvízképződésnek fokozott kockázata áll fenn.

Területhasználat

Magyarország 20 x 20 méteres térbeli felbontású Nemzeti ökoszisztéma szolgáltatás-térképezés és értékelés (NÖSZTÉP, [12]; Vári et al., 2022) adatbázist használtam a földhasználat/fedettség meghatározásához. A 2020-as térkép országos szinten mutatja ökoszisztémáink tényleges eloszlását, kiterjedését és gyakoriságát. Ennek segítségével határoztam meg, hogy mely földhasználati kategóriák veszélyeztetettek az belvízzel szemben.

Antropogén hatásokat tükröző/szintetizáló adatok

A földhasználati adatok mellett a bemeneti adatbázis tartalmazta a legközelebbi antropogén infrastruktúrák – úthálózat, csatornák és települések – távolsága alapján készített térinformatikai rétegeket is. Ezeket az adatokat az OpenStreetMap (OSM; [13]) nyílt forráskódú adatbázisából nyertem ki, majd a kivonatolt objektumok alapján távolságtérképeket generáltam. A kapott raszteres állományok 10×10 méteres térbeli felbontással készültek, a távolságtérképeket méterben fejeztem ki. Az ilyen típusú, ún. távolságalapú (proximity) rétegek szerepe azért kiemelkedő, mert az emberi tevékenységek – különösen az infrastruktúra-hálózat sűrűsége és elérhetősége – közvetett módon befolyásolhatják a belvíz kialakulását és tartósságát. Például a burkolt utak vízelvezető képessége, a csatornák közelsége, illetve a települési környezet vízmozgásra gyakorolt hatása jelentős tényező lehet a felszíni vízviisszatartás vagy -elvezetés szempontjából. A modellezés során ezen antropogén tényezők bevonása elősegíti a belvíz előfordulásának valószínűségi becslését, különösen a mezőgazdaságilag hasznosított, de emberi hatásnak kitett területeken.

Talajtan

A talajtani bemeneti adatokat az Európai Talajhidraulikai Adatbázisból (EU SoilGrids; [14]) nyertem ki, amelyet Tóth et al. (2017) által alkalmazott pedotranszfer-függvények segítségével állítottak elő. Az adatbázis 250 méteres rácshálózaton szolgáltat információt, hét különböző talajmélységre vonatkozóan (0, 5, 15, 30, 60, 100 és 200 cm). A raszteres rétegek tartalmazzák a talaj textúrájára, kémiai összetételére és fizikai tulajdonságaira vonatkozó paramétereket: agyag-, iszap- és homoktartalom (tömeg %), szerves szén koncentráció (g kg^{-1}), térfogattömeg (kg m^{-3}), valamint a pH érték vízben mérve.


A talaj vízgazdálkodási tulajdonságai és a belvíz kialakulása közötti összefüggések vizsgálatához négy alapvető hidraulikai paraméter került felhasználásra: a telített víztartalom (THS), a szántóföldi vízkapacitás (FC), a hervadáspon (WP) és a telített hidraulikus vezetőképesség (KS). A telített víztartalom a talaj maximális vízraktározó képességét jelzi, amikor a pórusok teljes mértékben vízzel telítettek, és további beszivárgás már nem lehetséges. A szántóföldi vízkapacitás azt a nedvességtartalmat mutatja, amelyet a talaj a gravitációs vízvesztés után is képes viisszatartani, és amely a növények számára még felvehető. A hervadáspon a talaj azon nedvességi szintjét jelenti, amely alatt a növények vízfelvétele már nem biztosított, mivel a talajrészecskékhez kötött víz erőbben kötődik, mint amit a gyökérnyomás képes leküzdeni. A telített hidraulikus vezetőképesség a víz talajon belüli mozgásának sebességét jellemzi telített állapotban, és alapvetően meghatározza a beszivárgás, valamint a víz oldalirányú és függőleges elvezetésének mértékét. E paraméterek együttesen írják le a talaj víztároló és vízelvezető tulajdonságait, így közvetlen hatást gyakorolnak a belvízérzékenység térbeli változékonyságára.

A vizsgálatban nem alkalmazott tényezők

Bár a belvíz kialakulását számos környezeti tényező befolyásolja, jelen kutatás során a modellfejlesztésbe a talajvízszint és a földtani háttér közvetlen bevonását nem tartottam indokoltnak. A talajvízviszonyok tekintetében elővizsgálatot végeztem a vizsgált mintaterület kistájleírásaira és az OVF archív adatbázisára [15] támaszkodva. Az interpolált térkép alapján a talajvíztükör mélysége jellemzően 2–4 méter között változik (10. ábra). E mélységtartományban a talajvíz szintje csupán korlátozott hatást gyakorol a felszínközeli vízmozgásokra, különösen az időszakos, gyors lefolyású belvízi elöntések esetében. A vizsgálati időszak kijelölését az indokolta, hogy 2021 tavaszán az átlagosnál nagyobb kiterjedésű belvízelöntés alakult ki Magyarországon, amelynek legnagyobb kiterjedése a mintaterületen 2021 februárjában volt. Ekkor a talajvízszint a vizsgált térségben továbbra is a 2–4 méteres mélységtartományban helyezkedett el, így a felszíni vízborítás kialakulása döntően a csapadékeseményekhez és a felszín közeli vízforgalmi folyamatokhoz kapcsolódott, nem pedig a talajvízszint közvetlen emelkedéséhez.

Ugyanakkor fontos megemlíteni, hogy a belvíz kialakulásának vizsgálatában több korábbi kutatás hangsúlyozta a talajvíz szerepét, különösen akkor, ha az a felszín közelébe emelkedik. Pálfai (2001, 2004) szintetizáló munkáiban részletesen tárgyalta a magas talajvízállás jelentőségét, elsősorban a hosszabb idejű vízborítás és a földárja jelensége kapcsán. Hasonló megközelítést alkalmazott Rakonczi felhívta a figyelmet a kapilláris vízmozgásokra és a felszínközeli vízzáró rétegek szerepére a belvizes állapotok kialakulásában (Rakonczi et al., 2001). Az említett kutatások elsősorban olyan térségekre vonatkoznak, ahol a talajvíz szintje magasabb fekvésű, intenzívebben befolyásolja a felszíni vízháztartást.

Ezzel szemben a jelen kutatás mintaterületén a talajvíz nincs közvetlen, effektív kapcsolatban a felszínnel, így a felszíni vízborítás kialakulása döntően nem a talajvízszint emelkedésének, hanem a csapadékból származó vízfeleslegnek/víz többletnek a következménye. A felszín alatti vízmozgások lassabb időléptéke és a vertikális hidrológiai rétegek elkülönülése miatt a talajvízszintre vonatkozó adatok bevonása várhatóan nem növelte volna érdemben a predikciós pontosságot, miközben a modell komplexitását és az adatfeldolgozási igényt indokolatlanul növelte volna.



10. ábra: A talajvíztükör mélysége (m) a vizsgálati területen 2021.02.23-án

A földtani tényezők közvetlen figyelembevételétől a jelen kutatásban eltekintettem, mivel az Alföld, de főként a mintaterület geológiai felépítése viszonylag homogén, döntően vastag üledékes rétegekből áll. Emiatt a belvizek kialakulása és a vízháztartási különbségek meghatározása elsősorban nem a mélyebb földtani szerkezethez, hanem a felszínközeli talajrétegek vízvezető és víztároló tulajdonságaihoz köthető. Ezek a paraméterek – mint például a telített víztartalom, a szántóföldi vízkapacitás vagy a hidraulikus vezetőképesség – már közvetetten beépültek a modellbe a talajtani változók révén. Mindez biztosítja, hogy a földtani háttér hatása a modellben a belvízképződés szempontjából releváns formában jelenjen meg.

3.3. A módszertani fejlesztés során alkalmazott szoftverkörnyezetek

A kutatás során a módszertani keret kialakítása több szoftveres és programozási környezet alkalmazását igényelte, a vizsgálat célkitűzéseire és az adatok jellegére igazodva. A kezdeti szakaszban az ArcGIS Desktop szoftverben végeztem a Sentinel-2 műholdfelvételek indexalapú elemzését és a hagyományos gépi tanulású osztályozási eljárások (pl. ML, RF, SVM) tesztelését. A CNN modellek fejlesztése érdekében áttértem az ArcGIS Pro deep learning moduljára [16], majd a modellt ArcPy [17] és egyéb Python-alapú könyvtárak (pl. PyTorch; [18]) felhasználásával exportáltam, ami biztosította a feldolgozás rugalmasságát és az idősoros elemzések automatizálhatóságát, továbbá csökkentette a térinformatikai szoftverkörnyezethez való kötöttséget. A nagy léptékű

adatlekérdezéseket és előfeldolgozásokat a GEE felhőplatformon végeztem, majd az eredményeket fájl-alapú kimenetként (pl. GeoTIFF) visszacsatoltam a Jupyter Notebook-alapú elemzési és modellezési környezetbe. A további feldolgozási lépések – így a gyakorisági térképek generálása, a Sentinel–1 radaradatok feldolgozása, valamint a dinamikus és statikus adatok integrációja – már Jupyter Notebookban történtek, egységes, reprodukálható munkafolyamatban.

Az ArcGIS Pro az ArcGIS Desktop továbbfejlesztett, modern változata, amely közvetlen támogatást biztosít a gépi tanulás és a deep learning alapú térbeli elemzésekhez, többek között konvolúciós neurális hálózatok (CNN) és U-Net architektúrák alkalmazásához. A szoftver integrálható PyTorch [18], TensorFlow (Abadi et al., 2015; [19]) és Keras [20] keretrendszerekkel, támogatja a párhuzamos feldolgozást és a felhőalapú adattárolással való együttműködést. E tulajdonságai alkalmassá teszik nagyméretű, időben dinamikus adathalmazok automatizált feldolgozására és belvízdetektálási modellek hatékony futtatására.

A Jupyter Notebook nyílt forráskódú, interaktív fejlesztőkörnyezet, amely elsősorban Python, de más nyelvek (pl. R, Julia) támogatását is biztosítja. Lehetővé teszi forráskód, dokumentáció (Markdown), matematikai képletek (LaTeX) és interaktív ábrák egyidejű szerkesztését és futtatását. A notebook-alapú fejlesztés előnye a lépésenkénti futtatás, az eredmények azonnali vizualizációja és a reprodukálható kutatási folyamatok biztosítása. A Python-ökoszisztémával (pl. NumPy, scikit-learn, PyTorch [18] / TensorFlow [19]) szorosan integrálható, így komplex térinformatikai és idősoros műveletek végrehajtására is alkalmas.

A GEE felhőalapú térinformatikai és távérzékelési platform, amely nagy térbeli és időbeli felbontású geoadatok (pl. Landsat, Sentinel) közvetlen, skálázható feldolgozását teszi lehetővé böngésző- vagy API (Application Programming Interface) -alapon (JavaScript, Python). A párhuzamos feldolgozást és a felhőben futó analitikát kihasználva a GEE különösen alkalmas regionális és országos léptékű vizsgálatokra. Az eredmények interaktív térképeken és grafikonokon megjeleníthetők, a kimenetek standard formátumokban (pl. GeoTIFF) exportálhatók, és beépíthetők a helyi Jupyter-alapú feldolgozási láncba. A GEE kutatási és oktatási célra díjmentesen hozzáférhető; a kereskedelmi felhasználás külön megállapodást/licencet igényel.

3.4. A belvíz detektáláshoz felhasznált módszerek

A távérzékelési technológiák fejlődése az elmúlt évtizedekben jelentős előrelépést tett lehetővé a földhasználati mintázatok és a környezeti változások kvantitatív vizsgálatában, különösen a multispektrális műholdfelvételek térnyerésének köszönhetően. A Sentinel–2 műholdrendszer különösen alkalmas a felszínborítás részletes és nagy pontosságú elemzésére, köszönhetően a széles spektrális lefedettségének és a 10–60 méter közötti térbeli felbontásának. A leggyakrabban alkalmazott spektrális indexek (pl. NDVI, NDWI, MNDWI) mellett az elmúlt években több mint harminc nemzetközileg elismert mutató került kifejlesztésre, amelyek célzottan alkalmasak a vegetációs aktivitás, a talajnedvességi viszonyok, valamint a felszíni víztestek azonosítására és monitorozására (Bijeesh és Narasimhamurthy, 2020).

A belvizes területek detektálásához három, a szakirodalomban széles körben alkalmazott spektrális indexet használtam: az NDVI-t, az NDWI-t (McFeeters, 1996) és az MNDWI-t (Xu, 2005). Ezek a mutatók a zöld (B3), vörös (B4), közeli infravörös (B8) és rövidhullámú infravörös (B11) sávok reflektanciaértékein alapulnak, amelyek a Sentinel–2 műholdképeken, illetve bármely más multispektrális szenzor megfelelő spektrális sávjain is megtalálhatók. Az indexekből előre definiált küszöbértékek mentén bináris (víz/nem-víz) osztályokat állítottam elő, amelyek gyors és hatékony eszközt biztosítanak a belvízzel borított területek azonosításához.

Azonban a távérzékelési adatok elemzésében nemcsak az indexek játszanak kulcsszerepet, hanem a felügyelt gépi tanulási módszerek is nélkülözhetetlenek a pontos és hatékony osztályozás és azonosítás érdekében. E fejezetben részletesen ismertetem a választott gépi tanulási technikákat, beleértve a SVM, a RF, a ML, illetve az ANN, a CNN és a DNN algoritmusokat (Varga et al., 2021).

A kiválasztott módszerek által azonosított vízfelületek pontos lehatárolása kulcsfontosságú lesz a kutatási célok megvalósításában, és lehetővé teszi a jövőbeli kutatási irányok meghatározását.

3.4.1. Normalized Difference Vegetation Index (NDVI)

Az NDVI a távérzékelésben leggyakrabban alkalmazott spektrális mutató, amely a felszín tényleges állapotát jellemzi a vörös (Red, Band 4) és közeli infravörös (NIR, Band 8) sávok reflektanciaértékei alapján. A számításhoz felszíni reflektancia értékeket használtam, mivel ezek korrigáltak az atmoszferikus hatásokra, és így pontosabban tükrözik a különböző felszínborítási típusok (víz, talaj, növényzet) spektrális viszonyait. Bár az NDVI-t elsősorban a vegetáció klorofiltartalmának és fotoszintetikus aktivitásának jellemzésére fejlesztették ki, a vízborítás az alacsony vagy negatív NDVI-értékek révén jól elkülöníthető a növényzettel borított területektől:

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (2)$$

A módszer alapjai Rouse et al. (1973) munkájára vezethetők vissza, akik a vegetációs rendszerek szezonális változásainak kvantitatív vizsgálatára alkalmazták először ezt az indexet. Az NDVI értékei -1 és $+1$ között mozognak: a negatív és nulla közeli értékek általában vízfelszínnekhez, kopár felszínnekhez vagy urbanizált területekhez köthetők, míg a pozitív, $0,3-0,8$ közötti tartomány jellemző a különböző intenzitású vegetációs borítottságra. Az NDVI tehát közvetetten, de jól értelmezhető módon utal a biomassza mennyiségére és a növényi borítás tér- és időbeli változásaira (Kriegler et al., 1969).

A vízfelületek detektálásában az NDVI elsősorban kizáró módszerként alkalmazható, mivel az alacsony vagy negatív értékek gyakran vízborítást jeleznek, mert a (mély) víz reflektanciája a Red sávban magasabb, mint a NIR sávban. Ugyanakkor a vegetációval részben fedett vagy sekély belvízfoltok esetében az index érzékenysége csökken, mivel a reflektancia-értékek eltolódhatnak a növényzet irányába. A víztestek megbízható azonosításához ezért küszöbérték meghatározása szükséges, amely az adott spektrális felbontás, szenzor típus és évszak függvényében változhat (Wen et al., 2021). Hazai példák is alátámasztják, hogy az NDVI alkalmazása jól használható a szárazodási és belvizes folyamatok térképezésére (Kovács, 2004), különösen, ha az eredményeket egyéb indexekkel (pl. NDWI) vagy radaros adatokkal kombinálják a pontosság növelése érdekében. McFeeters (1996) hangsúlyozza, hogy a víz–növényzet határ diffúz jellege miatt az egyes spektrális indexek (pl. NDVI, NDWI) egymással, illetve más távérzékelési forrásokkal – például radaros felvételekkel – való összevetése és kombinációja kulcsfontosságú a felszíni vízborítás pontos feltárásában

3.4.2. Normalized Difference Water Index (NDWI)

A Normalized Difference Water Index (NDWI) McFeeters (1996) tanulmánya alapján került bevezetésre a felszíni víztestek megbízható detektálása érdekében, elsősorban multispektrális távérzékelte képeken. Az NDWI a zöld (Green, Band 3) és a közeli infravörös (NIR, Band 8) sávok reflektanciáján alapul, és a következő képlettel számítható:

$$NDWI = \frac{Green - NIR}{Green + NIR} \quad (3)$$

A módszer elvi alapja, hogy a vízfelszínnek erősen elnyelik a közeli infravörös sugárzást, míg a zöld tartományban jellemzően magasabb a reflektanciájuk. Ennek következtében a vízzel borított pixelek pozitív NDWI értéket vesznek fel, míg a növényzet és a száraz felszín általában nulla közeli vagy negatív értékeket mutat.

Az NDWI egyik legfőbb előnye az egyszerűség és a számítási hatékonyság mellett, hogy nagy kontrasztot képes létrehozni a nyílt víztestek és a szárazföldi borítások között, különösen homogén táji viszonyok esetén. Az index jól alkalmazható természetes tavak, folyók, csatornák, illetve belvízfoltok detektálására, amennyiben a vegetációs és épített környezet interferenciája minimális. Ugyanakkor városi környezetben vagy sűrű növényzet mellett előfordulhat, hogy árnyékos vagy nedves felszínek is pozitív értéket vesznek fel, így tévesen vízként jelennek meg a térképeken.

A küszöbérték kiválasztása kritikus szerepet játszik az NDWI-t alkalmazó bináris osztályozásban. McFeeters eredeti javaslata szerint a víz–nem víz elkülönítésére az $NDWI = 0$ küszöbérték szolgálhat alapértelmezésként, azonban a gyakorlatban a lokális viszonyokhoz igazított, histogram-alapú küszöbmeghatározás pontosabb eredményekhez vezethet. A vízfelületek detektálása során az NDWI-index nagy előnye, hogy kevés előfeldolgozást igényel, így gyors és megbízható megoldást kínál elsősorban Sentinel–2 és Landsat műholdképeken.

3.4.3. Modified Normalized Difference Water Index (MNDWI)

Az Modified Normalized Difference Water Index (MNDWI) a víztestek távérzékeléssel történő lehatárolásának egyik legelterjedtebb és leghatékonyabb indexe, különösen városi környezetben és mezőgazdasági területeken (Balázs et al., 2018). Xu (2006) eredeti javaslata alapján az MNDWI az NDWI (McFeeters, 1996) módosított változata, amely a közeli infravörös (NIR) sáv helyett a rövidhullámú infravörös (SWIR) sávot alkalmazza, a következő képlettel:

$$MNDWI = \frac{Green - SWIR}{Green + SWIR} \quad (4)$$

A módosítás célja a beépített területek és a vegetációs borítás spektrális „zajának” hatékonyabb kiszűrése. A SWIR tartományban magasabb reflektancia jellemzi ezeket a felszíneket, míg a vízfelületek erősen elnyelik ezt a tartományt, így az MNDWI pozitív értékei megbízhatóan jelölik a nyílt vízfelszíneket, míg a többi felszín negatív értékeket vesz fel.

A Sentinel–2 műhold esetében a zöld (Band 3) és a SWIR (Band 11) sávok alkalmazásával 20 méteres térbeli felbontású MNDWI index számítható. Azonban Du et al. (2016) tanulmányukban rámutattak, hogy a Sentinel–2 10 méteres sávjainak (pl. Band 3) és a 20 méteres SWIR sáv együttes használata adatvesztést eredményezhet. Ennek kiküszöbölésére pan-sharpening technikát alkalmaztak, amely lehetővé tette a SWIR sáv 10 méteresre való „átméretezését” (upscaling), és így nagyobb részletességű, megbízhatóbb MNDWI előállítását. Eredményeik szerint a 10 méteres MNDWI nemcsak pontosabban határolja le a kisebb víztesteket, hanem jobban elhatárolja a vízfelszíneket a beépített környezettől is.

3.4.4. Maximum Likelihood (ML)

A Maximum Likelihood (ML) osztályozás az egyik legszélesebb körben alkalmazott, statisztikai alapú felügyelt osztályozási módszer a távérzékelési képfeldolgozásban (Richards and Jia, 2006; Tso és Mather, 2009; Van Leeuwen et al., 2013; Sisodia et al., 2014; John és Varghese, 2022). Alapfeltevése, hogy az egyes osztályok (pl. víz, növényzet, talaj) spektrális jellemzői multivariáns normáeloszlással modellezhetők. A módszer a Bayes-féle döntési szabályt alkalmazza, amely a pixelhez tartozó osztályt azon valószínűségek alapján választja ki, amely szerint az adott pixel a különböző osztályokhoz tartozhat. Ez a valószínűségi megközelítés lehetővé teszi, hogy az osztályozás figyelembe vegye nemcsak az osztályok középértékeit (spektrális jellegzetességeit), hanem azok szóródását és irányát is – azaz a kovariancia mátrixot is beépíti a döntési szabályba. Az eljárás a Bayes-tételen alapul, amely a pixel ω jellemzővektorának és az i osztályhoz tartozásának feltételes valószínűségét a következőképpen írja le (Strahler, 1980; Ahmad és Quegan, 2012):

$$P(i | \omega) = \frac{[P(\omega | i) \cdot P(i)]}{P(\omega)} \quad (5)$$

ahol:

$P(i | \omega)$: a pixel i osztályhoz tartozásának feltételes valószínűsége

$P(\omega | i)$: likelihood függvény (a jellemzővektor valószínűsége i osztály esetén)

$P(i)$: az i osztály a priori valószínűsége

$P(\omega)$: a jellemzővektor (ω) előfordulásának valószínűsége

Az ML osztályozás fő előnye a magas pontosság és a statisztikai megalapozottság, különösen homogén spektrális tulajdonságú felszínborítási típusok esetében. A módszer alkalmas többosztályos problémák kezelésére, és viszonylag kevés előfeldolgozást igényel.

Hátrányai közé tartozik a magas számítási igény, amely a felhasznált spektrális sávok számával négyzetesen növekszik, valamint az a feltételezés, hogy a minták eloszlása normáeloszlást követ – ami számos esetben nem teljesül. Ez különösen problémás heterogén városi környezetekben, vegyes növényzettel borított felszíneken vagy részben vízzel fedett zónákban, ahol a spektrális eloszlás aszimmetrikus vagy összetett lehet.

Mindezek ellenére az ML osztályozás megbízható és széles körben alkalmazható módszer a vízborítottság lehatárolására, amennyiben megfelelő mennyiségű és minőségű tanítóadat áll rendelkezésre (Otukei és Blaschke, 2010).

3.4.5. Support Vector Machine (SVM)

A Support Vector Machine (SVM) osztályozó egy hatékony nemparaméteres gépi tanulási eljárás, amelyet elsősorban bináris osztályozási problémákra fejlesztettek ki, de megfelelő stratégiák alkalmazásával többosztályos feladatokra is alkalmazható (Cortes és Vapnik 1995). Elméleti alapját a strukturális kockázatminimalizálás (Structural Risk Minimization, SRM) elve képezi, amely célul tűzi ki az általánosítási hiba minimalizálását oly módon, hogy a tanulási mintákhoz képest maximális elválasztási tartományt (margin) határoz meg az osztályokat elválasztó hipersík (separating hyperplane) mentén. A lineárisan szeparálható esetben az SVM a tanulási minták közül kizárólag azokat használja fel a modell meghatározásához, amelyek az elválasztó sík közelében helyezkednek el – ezek az ún. támogatási vektorok (support vectors). Az optimális elválasztó síkot úgy határozza meg, hogy az maximalizálja a két osztályhoz tartozó legközelebbi minták (margin) közti távolságot. Ez a megközelítés hatékonyabbá és robusztusabbá teszi az osztályozást más statisztikai módszerekkel szemben. Amennyiben az osztályok nem lineárisan elválaszthatók a bemeneti térben, az SVM kerneltrükköt alkalmaz: a bemeneti adatokat egy magasabb dimenziós térbe transzformálja, ahol azok már lineárisan elválaszthatók. E transzformációt egy kernel függvény segítségével végzi el, amely lehet például polinomiális vagy radiális bázisfüggvény (RBF). A kernel típusának és paramétereinek megválasztása jelentős hatással van a modell teljesítményére, különösen kis számú változó esetén. Az SVM különösen alkalmas nagy dimenziójú adathalmazok (pl. hiperspektrális képek) osztályozására, ahol más módszerek – például döntési fák vagy neurális hálók – hajlamosak az alul- vagy túltanulásra. Ugyanakkor az SVM hátránya, hogy nagyobb számítási kapacitást és jól megválasztott paraméter beállításokat igényel. Többosztályos feladatokra az ún. „egy-az-összes ellen” vagy „egy-az-egy ellen” stratégiák alkalmazásával válik használhatóvá (Huang et al., 2020, John és Varghese, 2022).

Ez a megközelítés a távérzékelési adatok, különösen a földhasználati és belvíz osztályozások során különösen hasznosnak bizonyul, mivel az SVM képes megbízható osztályhatárokat meghatározni még kis mintaszám esetén is. Ezáltal a belvízdetektálás és más felszínborítási kategóriák megbízható automatikus lehatárolásához is kiváló alapot biztosít (Richards és Jia, 2006).

3.4.6. Random Forest (RF)

A Random Forest (RF) egy együttes (ensemble) tanulási módszeren alapuló nem-paraméteres klasszifikációs algoritmus, amelyet széles körben alkalmaznak felszínborítás osztályozási feladatokban, különösen nagy spektrális hasonlóságot mutató kategóriák elkülönítésére (Ming et al., 2016; Balázs et al., 2018; Mahdavi et al., 2018; Bozán et al., 2019; Yilmaz et al., 2023). Működési elve azon alapul, hogy egy adott tanulókészletből véletlenszerű mintavételezéssel több döntési fát hoz létre, majd ezek többségi szavazása alapján határozza meg az adott pixel osztályát. A döntési fák kialakítása során minden osztásnál a bemeneti

jellemzők egy véletlenszerűen kiválasztott részhalmazából választja ki a legjobb szeparáló jellemzőt, így biztosítva a modellek diverzitását és az túltanulás elkerülését (Breiman, 2001, 2003).

Az RF különösen előnyös távérzékelte adatok feldolgozásánál, mivel képes nagy dimenziójú adathalmazokat kezelni, robusztus a „zajjal” szemben (azaz a hibás, véletlenszerű vagy irreleváns értékek nem befolyásolják jelentősen a teljesítményét), és nem érzékeny az adatok eloszlására. További előnye, hogy nem igényel normáeloszlást vagy egyenlő szórású csoportokat, ellentétben sok klasszikus paraméteres módszerrel, mint például a Maximum Likelihood (Ming et al., 2016).

A modell teljesítményét alapvetően két paraméter befolyásolja: a döntésfák száma és az egyes elágazásokhoz használt jellemzők száma. E paraméterek optimalizálása kulcsfontosságú a modell teljesítményének maximalizálásában. Ming et al. (2016) genetikai algoritmus segítségével optimalizálták az RF paramétereit, és megállapították, hogy az így konfigurált modell jelentősen felülmúlta a hagyományos RF-et és az SVM-et is osztályozási pontosság tekintetében.

Belgiu és Dragut (2016) áttekintő tanulmányukban kiemelik, hogy az RF különösen jól alkalmazható földhasználati és felszínborítási térképezési feladatokban, mivel képes hatékonyan kezelni a távérzékelési adatok spektrális komplexitását. Immitzer et al. (2012) Sentinel-2 adatokra alapozott erdőborítás osztályozási vizsgálatukban szintén sikeresen alkalmazták az RF-et, és kiemelték annak megbízhatóságát heterogén vegetációs mintázatok elkülönítésében.

3.4.7. Artificial Neural Network (ANN)

Az Artificial Neural Network (ANN) egy biológiai idegrendszer működését utánzó számítási modell, amely különösen hatékony nemlineáris mintázatok felismerésére és prediktív feladatok elvégzésére (Van Leeuwen, 2012). A Rosenblatt (1958) által bevezetett perceptron modell tette le a modern neurális hálózatok alapjait, amely azóta számos fejlesztésen ment keresztül. Az ANN struktúrája több rétegből áll – bemeneti, rejtett és kimeneti rétegből –, ahol az egyes neurális egységek között súlyozott kapcsolatok valósítják meg az információ feldolgozását. A tanítási folyamat során a hálózat súlyai jellemzően a hiba visszaterjesztésével (backpropagation) módosulnak a kimeneti érték és a várt eredmény közötti különbség minimalizálása érdekében, bár bizonyos architektúrák vagy speciális feladatok esetén más optimalizálási eljárások is alkalmazhatók (Van Leeuwen, 2012; 2013).

Az ANN előnye a rugalmasság és a nemlineáris összefüggések felismerésének képessége, amely különösen hasznos a távérzékelésben, ahol a felszínborítás osztályozása gyakran komplex, többváltozós döntési problémát jelent. Jiang et al. (2018) kimutatták, hogy az ANN kiemelkedő teljesítményt nyújt a különböző felszínborítási kategóriák (víz, vegetáció, beépített terület stb.) elkülönítésében, különösen akkor, ha a bemeneti változók között spektrális indexek is szerepelnek.

A hálózat teljesítménye függ a rétegek számától, a neurális egységek számától, az aktivációs függvény típusától és a tanulási rátától. Ezek optimalizálása kulcsfontosságú a túltanulás elkerüléséhez és a generalizációs képesség biztosításához. Devi és Chib (2019) kifejezetten felhívja a figyelmet arra, hogy megfelelő adatelőkészítés és normalizálás mellett az ANN képes megbízható térképezési eredményeket nyújtani, különösen heterogén felszínű térségekben.

Abraham (2002) tanulmánya szintén megerősíti, hogy az ANN módszertan nagy potenciállal bír a geoinformatikában, különösen a kép osztályozási problémákban, ahol a sokdimenziós bemeneti adatok (pl. multispektrális sávok) és a nemlineáris osztályhatárok kezelése kiemelt jelentőséggel bír.

3.4.8. Deep Neural Network (DNN)

A DNN, azaz mély mesterséges neurális hálózat olyan, több rejtett rétegből álló architektúra, amely képes összetett, nemlineáris összefüggések megtanulására nagy dimenziójú adathalmazokból. A DNN a klasszikus ANN továbbfejlesztett formája, amelyben a bemenet és a kimenet között több, egymásra épülő rejtett réteg található. E rétegek fokozatosan egyre absztraktabb reprezentációkat hoznak létre a bemeneti adatokból, ezáltal javítva a modell predikciós és osztályozási teljesítményét (Hinton et al., 2012, Bravó-López et al, 2022).

A mély tanulási modell különösen akkor előnyös, ha a bemeneti adatok között bonyolult, nemlineáris kapcsolatok húzódnak meg, amelyeket hagyományos regressziós vagy sekély tanuló algoritmusok nem képesek megbízhatóan feltárni. A DNN különösen jól teljesít időbeli és tematikus trendek detektálásában, amit távérzékelte vagy meteorológiai idősort tartalmazó predikciós feladatoknál – így például a belvíz előrejelzésénél – ki lehet használni (Goodfellow et al., 2016).

A modell előnye, hogy képes tanulni a bemeneti jellemzők közötti magas szintű korrelációkat, így például a csapadék, a talajnedvesség, a hőmérséklet és a felszínborítás együttes hatását a belvíz megjelenésére. Azonban hátránya, hogy a modell betanítása nagy adat- és számításigényű, valamint könnyen túlilleszthet, ha nem megfelelően történik a szabályozás.

A disszertációban alkalmazott DNN modell célja az volt, hogy időbeli meteorológiai adatok (pl. csapadék, evapotranszpiráció), valamint statikus felszíni jellemzők (pl. talaj, domborzat, földhasználat) alapján néhány napos előrejelzést adjon a belvizes elöntések előfordulásáról, támogatva ezzel a korai beavatkozásokat és a döntéshozatalt.

3.4.9. Convolutional Neural Network (CNN)

A CNN koncepciója és gyakorlati áttörése Krizhevsky, Sutskever és Hinton (2012) munkájához köthető, akik az ImageNet adatbázison elért kiemelkedő osztályozási eredményeikkel megalapozták a mai mélytanulás-alapú képfeldolgozási módszerek elterjedését.

A CNN-ek olyan mesterséges neurális hálózatok, amelyek a bemeneti adatok térbeli vagy időbeli struktúráját kihasználva képesek hatékony mintafelismerésre. E hálózatok egyik fő sajátossága, hogy az ANN-ekre jellemző, teljesen összekapcsolt rétegek helyett a jellemzők kinyerésére konvolúciós (szűrőalapú) műveleteket alkalmaznak, amelyek lehetővé teszik a lokális mintázatok felismerését az egész képterületen (LeCun, 1990). Minden konvolúciós réteg egy adott számú szűrőt tanul meg, amelyek térbeli jellemzőket (pl. élek, textúrák) detektálnak, és a jellemzőtérben egyre absztraktabb reprezentációkat alakítanak ki (LeCun et al., 2015).

A hálózat tipikus rétegei három fő szakaszból állnak: a konvolúciós szakaszban a bemeneti adatokat a szűrők segítségével lineárisan transzformálják; ezt követi egy nemlineáris aktiváció (általában ReLU – Rectified Linear Unit), amely a bemeneti értékeket nulla és pozitív tartományra korlátozza azzal, hogy a negatív értékeket nullává alakítja, míg a pozitív értékeket változatlanul hagyja. A ReLU aktiváció után általában egy pooling réteg következik, amely a kimeneti tér redukcióját végzi, és hozzájárul az invariancia kialakításához a kis elmozdulásokkal szemben. A pooling réteg mechanizmusai – mint például a max pooling vagy az átlag pooling – lehetővé teszik, hogy a hálózat ne csak a jellemzők meglétét, hanem azok stabil előfordulását is felismerje, függetlenül azok pontos helyzetétől (Goodfellow et al., 2016).

A CNN-ek különösen előnyösek a nagyfelbontású képek feldolgozásában, mivel képesek a képi adatok térbeli szerkezetét és lokális mintázatait közvetlenül kihasználni. A konvolúciós rétegekben alkalmazott súlymegosztás és lokális kapcsolatok révén a hálózat hatékonyabban kezeli a paramétereket, mint a teljesen összekapcsolt (fully connected) architektúrák, ezáltal csökkenti a túlillesztés kockázatát és javítja az általánosító képességet (Ronneberger et al., 2015; Zhu et al., 2017; Mahdianpari et al., 2018; Alzubaidi et al., 2021; Corbane et al., 2021; James et al., 2021).

Pritt és Chern (2017) tanulmányukban gyakorlati példát is bemutattak, amelyben CNN-eket alkalmaztak nagyfelbontású, multispektrális műholdképek automatikus osztályozására. Az általuk

fejlesztett rendszer alkalmas volt különböző felszínborítási kategóriák azonosítására, és 83% átlagos osztályozási pontosságot ért el, egyes kategóriák esetében pedig 95% feletti teljesítményt - jól demonstrálva a CNN-ek magas adaptív képességét a földmegfigyelési feladatokban.

Kutatásomban a CNN modellt a Sentinel-1 és Sentinel-2 adatok feldolgozásánál az adatokat a teljes állomány 80%-ának felhasználásával tanításhoz, míg 20%-ának felhasználásával validációhoz osztottam fel. A modell teljesítményének értékelésére több mutatót (F1, OA, κ) alkalmaztam, amelyek a módszertani fejezet további részében kerülnek részletes ismertetésre.

3.4.10. XGBoost

Az XGBoost (Extreme Gradient Boosting) egy hatékony gradiensnöveléses keretrendszer, amely döntési fák összevont tanításával képes komplex prediktív feladatok megoldására. A módszer lényege, hogy egymást követő tanítási körökben újabb gyenge tanulókat (jellemzően döntési fákat) illeszt az előző körök hibáinak korrigálására, ezzel fokozatosan javítva az összmodell teljesítményét (Chen és Guestrin, 2016). Az XGBoost különösen alkalmas strukturált adatok osztályozására vagy regressziójára, mivel jól kezeli a heterogén típusú változókat, robusztus a hiányzó értékekkel szemben, és beépített regularizációs mechanizmusokat kínál a túlillesztés elkerülésére. Előnyei közé tartozik a kiemelkedő számítási hatékonyság, a párhuzamosíthatóság, valamint a modell belső interpretálhatósága is, mivel a predikciók mögötti döntési logika nyomon követhető (Chen és Guestrin, 2016; Li et al., 2023).

Az XGBoost különösen hasznosnak bizonyult abban, hogy a prediktív jellemzők közötti nemlineáris összefüggéseket gyorsan és hatékonyan modellezze, lehetővé téve a térbeli generalizációt és a változófontossági sorrendek elemzését. A döntési fák stabilitása és interpretálhatósága miatt jól kiegészítette a predikciós rendszer más komponenseit (Dong et al., 2023).

3.4.11. Explainable AI (xAI) és SHAP-alapú változó rangsorolás


A gépi tanulási és mélytanulási modellek egyik kihívása, hogy döntéseik gyakran „fekete dobozként” értelmezhetők, azaz a predikciók mögötti folyamatok nehezen követhetők. E probléma kezelésére szolgálnak a magyarázható mesterséges intelligencia (explainable AI – xAI) módszerei, amelyek célja a modellek átláthatóságának növelése és az előrejelzések interpretálhatóságának biztosítása. Az xAI-keretrendszer különböző algoritmusokat foglal magában, amelyek lehetővé teszik az egyes változók szerepének feltárását, valamint annak azonosítását, hogy mely tényezők járultak hozzá leginkább vagy legkevésbé a modell döntéseéhez. Az egyik legszélesebb körben alkalmazott xAI-technika a SHAP (Shapley Additive Explanations), amely a játékelméletben kidolgozott Shapley-értékeken alapul (Lundberg és Su-In, 2017). A módszer minden bemeneti változóhoz hozzárendel egy marginális hozzájárulási értéket, amely megmutatja, mennyiben javítja vagy rontja az adott változó a modell előrejelzését az összes lehetséges változókombináció figyelembevételével. A SHAP előnye, hogy egységes és összehasonlítható keretet biztosít a jellemzők fontosságának értékelésére, és mind lineáris, mind nemlineáris modellek esetében alkalmazható. A SHAP-alapú magyarázó módszerek ezért különösen alkalmasak a komplex környezeti modellek értelmezésére és a változók fontosságának kvantitatív vizsgálatára (Al-Najjar et al., 2023, Wang et al., 2023).

3.4.12. Variance Inflation Factor (VIF)

A bemeneti változók közötti erős korreláció kimutatására a VIF (Variance Inflation Factor) mutatót alkalmazzák. A VIF egy adott jellemző és a többi független változó közötti kapcsolat erősségét méri, így alkalmas a multikollinearitás azonosítására. Magas VIF érték arra utal, hogy az adott változó erősen korrelál más jellemzőkkel, és ezért redundáns információt hordoz a modell számára. Általánosan elfogadott küszöbérték, hogy 10 feletti VIF esetén a változó eltávolítása indokolt, míg 4 alatti érték esetében a korreláció alacsonynak tekinthető. A VIF alkalmazása lehetővé teszi a predikciós modellek stabilitásának növelését, mivel kiszűri a túlzott együttjárást mutató bemeneti változókat (O'Brien et al., 2007).

3.4.13. Gray-Level Co-occurrence Matrix (GLCM)

A Gray-Level Co-occurrence Matrix (GLCM) egy statisztikai módszer a képi textúra kvantitatív leírására, amelyet először Haralick et al., (1973) ismertettek. Lényege, hogy a pixelintenzitások térbeli eloszlását elemzi az adott távolságra és irányra vonatkozó szűrkeszint-párok előfordulási gyakorisága alapján. A számítás során a vizsgált kép intenzitásértékeit először kvantálják, majd a kiválasztott irányokban (pl. 0°, 45°, 90°, 135°) és távolságokban előforduló pixelérték-párokat számlálják, és a kapott mátrixból különböző statisztikai jellemzők – például kontraszt, homogenitás, energia vagy entrópia – számíthatók (Haralick et al.; 1973; Connors et al., 1984; Kupidura, 2019, Mall et al., 2019). A GLCM a digitális képfeldolgozás egyik alapvető eszközévé vált a felszínborítás szerkezetének és heterogenitásának jellemzésében, és széles körben alkalmazzák távérzékelési feladatokban, különösen a textúra-alapú osztályozások során (11. ábra, Allagwail et al., 2019, Mullissa et al., 2021).



11. ábra: A GLCM pixelértékeinek számítási módja (Allagwail et al. 2019)

A kutatásomban a GLCM-indexek a Sentinel-1 radaradatok textúraelemzésére szolgáltak, különösen a vízborítottság és a vegetációs struktúra elkülönítésében, mivel a radarhullámok visszaverődése érzékeny a felszín érdességére és szerkezetére.

3.4.14. Radar Vegetation Index (RVI)

A Radar Vegetation Index (RVI) egy radaralapú vegetációs mutató, amely a növényzet és a talaj közötti visszaverődési különbségeket méri a különböző polarizációs csatornák felhasználásával. A Sentinel-2 adatokon alkalmazott NDVI radaros megfelelőjeként is értelmezhető, mivel a vegetációborítottság és a felszíni nedvességi állapotok jellemzésére szolgál, függetlenül a megvilágítási és felhőborítottsági viszonyoktól. Az RVI számítása a Sentinel-1 adatok alapján az alábbi képlettel történt (Szigarski et al., 2016; Nasirzadehdizaji et al., 2019):

$$RVI = \frac{4 \times VH}{VV + VH} \quad (6)$$

ahol VH a vertikális adás–horizontális vétel polarizációjú, míg VV a vertikális adás–vertikális vétel polarizációjú radar-visszaverődési értéket jelöli. Az RVI értéke 0 és 1 között változik, ahol a magasabb értékek nagyobb vegetációs borítottságot jeleznek.

Az RVI a Sentinel-1 adatokból került előállításra, és kiegészítő bemeneti jellemzőként szolgált a belvízborítottság detektálásához. Segítségével javítható volt a vegetációval részben fedett vízfoltok azonosítása, különösen a nyári időszakokban, amikor a növényzet erőteljesen befolyásolja a radarjelet.

3.5. Sentinel–2-es előfeldolgozás

A Sentinel–2 műholdcsalád multispektrális képalkotó rendszerei hazánkban ötnapos ismétlődő időszakokkal biztosítanak nagy térbeli felbontású optikai információkat a látható fény, a közeli infravörös és a rövidhullámú infravörös tartományokban. A 13 rendelkezésre álló spektrális sáv közül 10-et használtam fel az elemzés során, a 10 és 20 méteres térbeli felbontású sávokra koncentrálva. A spektrális homogenitás és az eltérő felvételek mozaikolásából eredő zavaró hatások elkerülése érdekében minden vizsgálati időponthoz egyetlen, teljes csempét (34TDT) tartalmazó műholdfelvételt dolgoztam fel.

A kutatás egyik módszertani sajátossága, hogy az adatok felhőalapú környezettől függetlenül, saját gépre letöltve és ott tárolva kerültek feldolgozásra. Ez a megközelítés a hosszadalmas és tárhelyigényes adatbázis-építés ellenére lehetőséget biztosított a független, internetkapcsolattól mentes munkavégzésre, különösen a modellezési fázis során. Az így kialakított helyi adatbázis kiépítése tehát a platformfüggetlen, automatizálható munkamenet fontos pillére volt. A módszertani összevetést – a helyi (offline) és felhőalapú (online) megközelítések előnyeinek és korlátainak értékelését – a 3.6-os fejezetben fejtettem ki.

A vizsgálatba csak azok a Sentinel–2 multispektrális felvételek kerültek be, amelyek felhőborítottsága nem haladta meg a 80%-ot. A gyakorlatban azonban érdemben csak az ennél lényegesen kisebb felhőborítottságú képek voltak alkalmasak a feldolgozásra, mivel a felhő- és árnyékmazsolás a vizsgálandó terület kiterjedése miatt jelentős adatvesztést eredményezett volna, így az ilyen felvételek felhasználása az elemzés szempontjából kevésbé lett volna célszerű. A feldolgozási folyamat első lépéseként a 20 méteres térbeli felbontású sávokat, úgy, mint a közeli infravörös (SWIR) sávok, a vörös-él (Red-Edge) sávok és a növényzet vörös-él (Vegetation-RE) sáv (2. melléklet), valamint a felhőhatás kiszűrésére az Európai Űrügynökség (ESA) által biztosított Scene Classification Layer (SCL) fedvényt a jobb részletesség és egységes feldolgozás érdekében 10 méteres felbontásra mintáztam át (resampling). A resampling során a 20 m-es cellaméretű rasztert egy új, 10 m-es cellákból álló rácsra alakítjuk át, azaz “felméretezzük” (upsampling). A folyamat során kiválasztott interpolációs módszer (nearest neighbour- legközelebbi szomszéd) segítségével számítottam ki az új cellaértékeket az eredeti raszterértékek alapján. Az átalakított raszterfejlécben rögzítjük az új felbontást, a vetületet és az eredeti adatforrást. Fontos azonban megjegyezni, hogy az interpoláció nem teremt valódi részletgazdagságot, csak a meglévő értékeket újramintázza finomabb felbontásra.


A Sentinel–2 Level–2A termékekhez tartozó SCL a Sen2Cor feldolgozási lánc részeként készül, és automatikusan osztályozza a képek minden egyes pixelét előre meghatározott felszínborítási típusok szerint (pl. felhő, felhőárnyék, víz, hó/jég stb.) (Louis et al., 2021). Az osztályozás többparaméteres algoritmus alapján történik, amely figyelembe veszi a spektrális jellemzőket, topográfiai adatokat, valamint meteorológiai tényezőket is. Bár az egyes osztályok megbízhatósága környezeti feltételektől függően változhat, az SCL réteg hatékony támogatást nyújt a nem releváns képrészletek – például a felhővel vagy felhőárnyékkal borított területek – kiszűréséhez. Vizsgálataimban az SCL réteg 3., 8., 9. és 10. osztályait (felhőárnyék, közepes és magas valószínűségű felhő, valamint a fátyolfelhő) kizártam az elemzésből (12. ábra).

Label	Classification
0	NO_DATA
1	SATURATED_OR_DEFECTIVE
2	DARK_AREA_PIXELS
3	CLOUD_SHADOWS
4	VEGETATION
5	NOT_VEGETATED
6	WATER
7	UNCLASSIFIED
8	CLOUD_MEDIUM_PROBABILITY
9	CLOUD_HIGH_PROBABILITY
10	THIN_CIRRUS
11	SNOW

12. ábra: A Sentinel–2-es műholdfelvételekhez az ESA által generált SCL osztályozás (Louis et al., 2021)

A kutatás kezdeti szakaszában a vizsgálati célterületek kijelölésekor elvi és gyakorlati szempontokat egyaránt figyelembe vettem. Elvi megfontolás alapján az elemzéseket a településeken kívüli, mezőgazdaságilag hasznosított területekre korlátoztam, mivel az ideiglenes vízborítás elsősorban ezeken a területeken fordul elő, és ott okoz számottevő gazdasági károkat. Már a kezdetektől alapvető előfeldolgozási lépésként érvényesült a felhő- és árnyékmazskolás. A kutatás előrehaladtával indokolttá vált a spektrálisan inhomogén, mesterséges felszínek (pl. burkolt területek, települések), valamint az állandó víztestek kizárása is, elsősorban a detektálási pontosság javítása érdekében. A végleges mazskolási lépések fokozatosan kerültek beépítésre a feldolgozási láncba, módszertani jelentőségüket és hatásukat a fejezet további része részletesen tárgyalja. A mazskoláshoz a mesterséges felszínek kiszűrését a NÖSZTÉP felszínborítási adatbázis [12], míg az állandó víztestek elkülönítését manuális digitalizáció biztosította.


A kutatómunka első fázisában a Sentinel–2 műholdfelvételek felhőborítottságának vizsgálatát az ArcGIS desktop szoftverkörnyezetben kezdtem meg. A belvízmonitoring rendszer fejlesztéséhez elengedhetetlen annak megértése, hogy a légköri zavarok – elsősorban a felhők és felhőárnyékok – milyen mértékben befolyásolják az időszakos víztestek megbízható lehatárolását. Ennek feltárására két időpontot választottam ki összehasonlító célból: egy teljesen felhőmentes felvételt (2021.02.23.) és egy felhőkkel, valamint felhőárnyékokkal erősen terhelt képet (2021.03.20.). A vizsgálati mintaterület a Sentinel–2 34TDT csempe teljes területére kiterjed, amely 10 000 km² nagyságú (13. ábra).



13. ábra: Sentinel–2 hamis színű kompozit (B8, B4, B3), amely bemutatja a vizsgálati területet mindkét időpontban (2021.02.23 (bal), 2021.03.20 (jobb)), és annak magyarországi elhelyezkedését a Sentinel–2 felvételezési grid hálójában (34TDT; Kajári és Van Leeuwen, 2021)

A műholdfelvételek előfeldolgozását, valamint az indexalapú és hagyományos gépi tanulós osztályozásokat az ArcGIS Model Builder vizuális modellező környezetében hajtottam végre. A feldolgozási lánc első lépésében a 20 m térbeli felbontású sávokat 10 m-es pixelméretre mintáztam át (resampling), majd ezt követően elvégeztem a felhő- és mesterséges felszínek maszkolását, az indexek számítását, valamint a 10 sávból álló multispektrális kompozit előállítását. Az így előkészített adatok képezték az alapot a többsztályos osztályozásokhoz (ML, RF, SVM). A modell egy adott időpontra vonatkozó feldolgozás esetén teljesen automatikusan futott, ugyanakkor idősoros vizsgálatoknál „félíg automatizált” jelleggel működött, mivel minden egyes időponthoz manuálisan kellett megadni a bemeneti paramétereket.

A kutatás során többféle osztályozási eljárást alkalmaztam (indexalapú küszöbérték-meghatározás, hagyományos gépi tanulós módszerek, valamint mélytanulás-alapú modellek), amelyek részletes ismertetése a korábbi fejezetben (lásd 3.4. fejezet) található. Az egyes módszerekkel előállított térképi eredmények megbízhatóságának vizsgálatához az ArcGIS – különösen a Spatial Analyst és Image Analyst modulokkal kiegészítve – többféle pontosságértékelési eljárást kínál. A legelterjedtebben használt eszközök közé tartozik az Accuracy Assessment Points tool, amely véletlenszerűen generált mintapontokon alapul. Az így létrehozott pontok segítségével elvégezhető a pontosságértékelés, amelynek során minden osztályra meghatározott számú mintapontot helyeztem el az osztályozott rétegen, majd a pontokhoz tartozó tényleges felszínborítási kategóriákat vizuális ellenőrzéssel határoztam meg a hamis színezésű műholdfelvételen. A pontosságot a mintapontok osztályozott értékeinek és a referenciaadatokként szolgáló vizuálisan meghatározott kategóriáknak a statisztikai egyezésvizsgálatával becsültem. Egy másik széles körben alkalmazott módszer a Confusion Matrix (CM – összevetési mátrix), amely a tényleges és a prediktált osztályok összehasonlítását végzi pixelalapon. A főatlón elhelyezkedő elemek a helyesen osztályozott eseteket, míg az attól eltérő cellák a hibákat jelzik. A kutatás korai szakaszában az *assessment point* módszert használtam az osztályozott térképek értékelésére (14. ábra).




14. ábra A Sentinel–2-es előfeldolgozott műholdképek feldolgozási módusa (Kajári és Van Leeuwen, 2021)

A kutatás következő fázisában a korábbi vizsgálatot kibővítettem egy újabb Sentinel–2 műholdcsempe feldolgozásával, amely 2021. március 7-i felvételen alapult, és egy kisebb, mintegy 82,3 km² kiterjedésű mintaterületre koncentrált (15. ábra).



15. ábra: A 82,3 km²-es vizsgálati terület Kajári et al. (2022a) alapján

Az eddig alkalmazott módszerek – így az indexalapú (NDVI, NDWI, MNDWI) és hagyományos gépi tanulású eljárások (ML, RF, SVM) – mellett a vízfelületek lehatárolására új módszereket is bevontam: az ANN és a CNN hálókat, melyeknek a feldolgozási munkafolyamatát a 16. ábra mutatja be.




16. ábra: Az ANN, és a CNN modell feldolgozási folyamata Kajári et al. (2022a) alapján

Az újrafelhasználhatóság és a hatékonyság érdekében a feldolgozási folyamatokat Python nyelven automatizáltam, valamint korszerű szoftverkörnyezetben – többek között az ArcGIS Pro-ban – valósítottam meg. Ez a megközelítés jelentősen növelte a rugalmasságot, és lehetővé tette az egyes feldolgozási lépések egységes és reprodukálható végrehajtását.

Az első vizsgálati munkafolyamathoz képest több lényeges változtatás történt. Az indexalapú lehatárolás során a kisebb mintaterület adottságaihoz igazodva új küszöbértékeket határoztam meg. A hagyományos gépi tanulású módszerek közül az ML osztályozást továbbra is az ArcGIS Pro szoftver eszköztárával végeztem el, míg az SVM, RF, ANN és CNN modellek futtatása Python nyelven írt saját fejlesztésű scriptek segítségével történt.

A gépi tanulásos modellek (RF, SVM) betanítását a scikit-learn Python-könyvtár segítségével végeztem, a bemeneti adatokat 80/20%-os arányban osztottam fel tanító és validációs halmazra. Az értékek standardizálását (átlag kivonása, egységnyi szórásra skálázás) követően a hiperparamétereket gridsearch eljárással és 10-szeres keresztvalidálással optimalizáltam.

A CNN esetében további fejlesztésként a modell struktúráját az ArcGIS Pro deep learning moduljában [16] hoztam létre, majd az ArcPy könyvtár segítségével készült Python script biztosította a folyamat teljes automatizációját és az eredmények előállítását (17. ábra).



17. ábra: A Sentinel-2 műholdképek előfeldolgozásának és osztályozásának neurális hálózatokkal kibővített folyamatábrája Kajári et al. (2022b) nyomán


Az eredmények validálását a mintaterület manuális digitalizálásával előállított, referencia jellegű vízborítási térkép alapozta meg. Ezt a referenciaként szolgáló réteget a Sentinel–2 műholdfelvételek hamis színezésű vizuális interpretációja alapján készítettem el, a tényleges vízborítás térbeli kiterjedését figyelembe véve. Bár a manuális lehatárolás vizuális értékelésen alapul, a távérzékelési gyakorlatban ez széles körben alkalmazott és tudományosan elfogadott validációs eljárás, különösen nagy kiterjedésű területek esetében, ahol a terepi ellenőrzés nem kivitelezhető. A modell pontosságát pixelalapú CM segítségével értékeltem, amely lehetővé tette a helyes találati arány (TP), valamint a tévesen osztályozott pixelek arányának pontos meghatározását. Ez a módszer objektív és reprodukálható módon támogatta az alkalmazott osztályozási eljárások összehasonlítását és a prediktív modell teljesítményének számszerű értékelését (Rahman et al., 2010).

3.6. Sentinel–1-es előfeldolgozás

A Sentinel–2 optikai műholdfelvételek alkalmazhatóságát jelentősen korlátozhatja a felhőborítottság, amely különösen a belvizes időszakokban nehezíti meg a felszíni vízborítás megbízható detektálását. E probléma kiküszöbölésére a vizsgálat aktív radaros Sentinel–1 adatok (VV és VH polarizáció) bevonásával, valamint az ezekből számított kiegészítő változókkal egészült ki, úgymint a RVI és a GLCM alapú textúra indexek. A vizsgálat idején a Sentinel–1 konstellációt a Sentinel–1A és Sentinel–1B műholdak alkották, azonban 2022 óta a B egység meghibásodása miatt a rendszer egy ideig kizárólag a Sentinel–1A adataira támaszkodott, ami a frissítési ciklus megnyúlásával járt. A helyzet 2025-ben javult, amikor a Sentinel–1C műhold pályára állításával ismét két aktív egység biztosítja a C-sávú radaradatok folyamatos elérhetőségét. A Sentinel–1 műholdak C-sávú radarrendszere többféle polarizációs üzemmódban képes adatokat rögzíteni. Jelen vizsgálatban a VV (vertikális adás – vertikális vétel) és a VH (vertikális adás – horizontális vétel) polarizációs csatornák adatait használtam fel. A VV polarizáció elsősorban a felszíni visszaverődést és a nyílt vízfelületek radarválaszát jellemzi, míg a VH polarizáció érzékenyebb a felszíni szerkezetek és a vegetáció által okozott depolarizációra. A két csatorna együttes alkalmazása lehetővé teszi a vízfelületek és a részben növényzettel fedett területek pontosabb megkülönböztetését, különösen heterogén felszínborítási viszonyok között (Mermoz et al., 2021, Ku et al. 2024). A radaros információk nem csupán a légköri zavaroktól független vízdetektálást tették lehetővé, hanem jelentősen javították a Sentinel–2 adatokkal önállóan elérhető 4–5 napos időbeli felbontást, amely így integrált megközelítéssel akár 1–2 napos időablakra is szűkíthetővé vált.

A Sentinel–2 felvételek előfeldolgozása offline módon történt, amely bár időigényes és jelentős tárhelyigénnyel rendelkezett, ugyanakkor biztosította a platformfüggetlen, internetkapcsolattól független és automatizálható munkavégzést. Ezzel szemben a Sentinel–1 adatok feldolgozását a GEE felhőalapú környezetében végeztem, amely gyorsabb és erőforrástakarékosabb megoldást nyújtott, viszont nagyobb mértékben kötött a platformhoz és az internetkapcsolathoz. A két megközelítés így eltérő előnyökkel és korlátokkal rendelkezik, amelyeket a dolgozatban módszertani szempontból összevettem.

A Sentinel–1-es lépések (18. ábra) magukban foglalták a hőzaj-eltávolítást, a radiometriai kalibrációt és a domborzati torzítás korrekcióját. A hőzaj-eltávolítás célja az érzékelő által generált, nem a felszínről visszaverődő, zavaró háttérjelek kiszűrése, amelyek torzíthatják a valódi visszaverődési értékeket. A radiometriai kalibráció révén a radar-visszaverődés mért értékei fizikailag értelmezhető egységekké (backscatter-koefficiensek) alakíthatók, biztosítva az adatok időben és térben történő összehasonlíthatóságát. A domborzati torzítás korrekciója (Terrain Correction) a lejtők és domborzati egyenetlenségek által okozott geometriai és intenzitásbeli eltéréseket küszöböli ki, amely különösen síkvidéki belvízvizsgálatok esetén teszi pontosabbá a felszíni visszaverődés térképezését (Kajári et al., 2023).



18.ábra: A Sentinel–1-es adatok feldolgozási modellje (Kajári et al., 2023)

Az előfeldolgozás során a Refined Lee speckle-szűrőt is alkalmaztam, mivel a kísérleti tapasztalatok alapján a radaros felvételeken megjelenő foltszerű zaj (speckle noise) kedvezőtlenül befolyásolta a GLCM textúraindexek megbízható kiszámítását. Ez különösen lényeges volt a mélytanulási modellek, elsősorban a CNN betanítási fázisában, ahol a zaj jelenléte félreosztályozási hibákhoz vezethetett. A GLCM indexeket külön-külön számítottam ki a VV és VH sávokra; mindkét polarizációhoz 18 különböző textúramutatót generáltam (3. melléklet).

A terepkorrigált radarértékeket ezt követően logaritmikus skálázással ($10 \cdot \log_{10}(x)$) decibel (dB) értékekké alakítottam át, amely a radaros visszaverődési intenzitás szabványos megjelenítési formája. Az így előkészített adatokat Jupyter Notebook környezetben, az ArcPy könyvtár [17] segítségével dolgoztam fel.

Összességében megállapítható, hogy a Sentinel–1 radaros adatok előfeldolgozása során alkalmazott lépések – ideértve a hőzaj-eltávolítást, a radiometriai kalibrációt, a domborzati torzítás korrekcióját, a speckle-zaj szűrését, valamint a GLCM textúraindexek és az RVI előállítását a jellemzők előállításának (feature generation) folyamatába illeszkedett, és megalapozta a belvizes területek texturális és spektrális jellemzőinek megbízható leképezését. Az így előkészített Sentinel–1 adatokból – a Sentinel–2 multispektrális felvételekhez hasonlóan – egy CNN-alapú vízfelület-detektálás bemeneti adatbázist hoztam létre, ahol a modellek betanításához az adatokat két részre osztottam: a teljes állomány 80%-át a tanításhoz, 20%-át pedig a validációhoz használtam fel.

3.7. Pontossági vizsgálat és teljesítménymutatók

A pontossági vizsgálat célja az osztályozási eredmények megbízhatóságának és prediktív értékének számszerű értékelése a referenciaadatokhoz viszonyítva. A távérzékelési alapú vízborítottság lehatárolás során a térképi kimenetek önmagukban nem elegendőek a módszerek minőségének megítélésére, ezért szükséges az eredmények objektív, kvantitatív összehasonlítása.

A kutatás korai szakaszában az Accuracy Assessment Points módszert alkalmaztam, amely véletlenszerűen generált mintapontok vizuális ellenőrzésén alapult. Ez a megközelítés gyors és áttekinthető képet adott az osztályozások pontosságáról, és megalapozta a későbbi, részletesebb pontossági vizsgálatokat.

A későbbiekben a pontossági vizsgálatok alapját a confusion mátrix (CM) képezte, amely a modell által becsült és a referenciaadatok szerinti osztályok (víz / nem víz) közötti egyezéseket és eltéréseket mutatja be. A leggyakrabban használt mutatók közé tartozik az összesített

pontosság (OA), a Kappa-index (κ), az F1-score, valamint a producer's (PA) és user's accuracy (UA), és a QADI-index, amelyek külön-külön is rávilágítanak az osztályozás erősségeire és gyengeségeire.

A kutatásban a pontossági vizsgálat célja nemcsak az egyes módszerek teljesítményének leírása volt, hanem azok összehasonlítása is, különös tekintettel a különböző megközelítések (indexalapú, gépi tanulós és mélytanulós modellek) vízborítottsági térképekre gyakorolt hatására.

A mátrix négy alapvető kategóriát tartalmaz:

- True Positive (TP): vízként jelölt pixel, amely a referenciatérképen is víz (helyes vízdetektálás).
- True Negative (TN): nem vízként jelölt pixel, amely a referenciatérképen is nem víz (helyes száraz terület detektálás).
- False Positive (FP): vízként jelölt pixel, amely a referenciatérképen nem víz (tévesen víznek azonosított terület).
- False Negative (FN): nem vízként jelölt pixel, amely a referenciatérképen víz (kihagyott vízborítás).

Ezek a kategóriák lehetővé teszik a hibák típus szerinti elkülönítését. Például a belvízdetektálásban az FN értékek a kihagyott vízfoltokat, míg az FP értékek a tévesen víznek azonosított területeket mutatják. A TP és TN értékek együttesen adják meg a helyesen osztályozott pixelek számát.

A disszertációban a CM minden vizsgált osztályozási módszer esetében elkészült, lehetővé téve a hibák típus szerinti azonosítását és a modellek teljesítményének részletes összehasonlítását.

A confusion mátrixból többféle teljesítménymutató számítható, amelyek eltérő szempontok alapján értékelik az osztályozás minőségét:

Overall Accuracy (OA): a helyesen osztályozott pixelek aránya a teljes mintához viszonyítva

$$OA = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (7)$$

Ez a legegyszerűbb és leggyakrabban használt mutató, azonban kiegyensúlyozatlan osztályeloszlás esetén (pl. 95,9% nem víz) torzíthat, ezért további mérőszámokkal együtt alkalmazandó.

Producer's Accuracy (PA): az adott referenciaosztályon belüli helyes besorolások aránya (érzékenység a vízosztályra)

$$PA = \frac{TP}{TP + FN} \quad (8)$$

User's Accuracy (UA): a térképen vízként megjelölt pixelek közül a valóban vízborításúak aránya (precízió felhasználói szemszögből)

$$UA = \frac{TP}{TP + FP} \quad (9)$$

Sensitivity / Recall: a ténylegesen vízzel borított területek felismerési aránya, megegyezik a PA képletével, de a statisztikai teljesítményértékelés kontextusában külön kiemelve használatos

$$Sensitivity (Recall) = \frac{TP}{TP + FN} \quad (10)$$

Precision: a modell vízként azonosított pixeleinek megbízhatóságát méri, és az UA-val azonos képletben alapul, eltérő értelmezésben

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

F1-score: a precízió és az érzékenység harmonikus átlaga, különösen hasznos kiegyensúlyozatlan osztályeloszlás esetén

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (12)$$

Kappa-index (κ): a tényleges és a véletlenszerű egyezés különbségét méri, korrigálva a torzított osztályeloszlás hatását

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (13)$$

ahol P_o a megfigyelt, P_e pedig a véletlen egyezés valószínűsége. Magas TN arány esetén a Kappa-érték informatívabb, mint az OA, mivel kiegyensúlyozottabb képet ad a valódi osztályozási teljesítményről

$$P_o = \frac{TP + TN}{TP + FP + FN + TN} \quad (14)$$

$$P_e = \frac{(TP + FN) \cdot (TP + FP) + (FP + TN) \cdot (FN + TN)}{(TP + FP + FN + TN)^2} \quad (15)$$

A Kappa-index értéke -1 és 1 között változik, ahol a 0 a véletlen osztályozással egyenértékű, az 1 a tökéletes egyezést, a negatív értékek pedig a véletlennél rosszabb teljesítményt jelzik.

A vizsgálatban a TN nagyon magas aránya miatt ($\sim 95,9\%$) a véletlen egyezés valószínűsége (P_e) is viszonylag magas, ezért a Kappa-index jobban képes korrigálni a magas Overall Accuracy-ból adódó, látszólag kiemelkedő eredményeket. Ezáltal kiegyensúlyozottabb képet ad a vízborítás detektálásának tényleges pontosságáról, különösen olyan esetekben, amikor az osztályok eloszlása erősen kiegyensúlyozatlan.

A hagyományos teljesítménymutatók (pl. Overall Accuracy, F1-score, Kappa) mellett tesztelési céllal egy további értékelési indexet, a Quantity and Allocation Disagreement Indexet (QADI) is felhasználtam, amely részletesebb képet ad a prediktív osztályozások hibaszervezetéről.

A QADI (Quantity and Allocation Disagreement Index) a prediktív osztályozások és a referenciaadatok közötti eltérések részletes elemzésére szolgál. Az index két hibakomponenst különít el:

- mennyiségi eltérés (quantity disagreement), amely a víz/nem víz arányainak becslési hibáját méri, és
- allokációs eltérés (allocation disagreement), amely a térbeli elhelyezkedés különbségét jelzi azonos osztálymennyiség esetén (Feizizadeh et al., 2022).

A QADI számítása a confusion mátrixból történik:


$$QADI = QD + AD \quad (16)$$

ahol a QD (Quantity Disagreement) és az AD (Allocation Disagreement) a mennyiségi és az elhelyezkedési eltérések mértékét fejezi ki. Az index 0 és 1 közötti értéket vehet fel; 0 esetén teljes, 1 esetén maximális eltérésről beszélünk.

A QADI különösen hasznos olyan vizsgálatokban, ahol a térbeli mintázat éppoly fontos, mint a mennyiségi arány (pl. belvízfoltok esetében). A jelen kutatásban az index a különböző modellek (indexek, hagyományos gépi tanulás, ANN, CNN) vízborítási térképeinek összehasonlítását tette pontosabbá, megmutatva, hogy a pontatlanság inkább a vízborítottság mennyiségéből vagy térbeli lokalizációjából ered-e.

3.8. A műholdfelvételek fúziója

A belvízfoltok detektálása és időbeli nyomon követése érdekében elengedhetetlen a műholdfelvételek kvázi-folyamatos elemzése, ezért kétféle adatforrást használtam a kutatásomban. Az együttes alkalmazása jelentősen javította az időbeli lefedettséget, ugyanakkor a műholdas megfigyelések természetéből adódóan időszakosan hiányos értékek is jelentkezhettek. A Sentinel-2 esetében a hiányosságok elsősorban a felhőborítottság, a felhőárnyékok és a települési felszínek maszkolása miatt jelentkezhettek, míg a Sentinel-1 radaradatoknál a csempehatárok mentén fellépő, 1–2 pixeles feldolgozási hibák okoztak lokális zavarokat. A hiányzó értékek pótlására egy idősoros interpolációs eljárást alkalmaztam, amely a hiányzó pixelek értékét az időben legközelebbi az azt megelőző vagy követő, maximum 4 napon belül rendelkezésre álló előntési adatok alapján töltöttem ki (19. ábra).




19. ábra: Az időbeli interpoláció sematikus ábrája Kajári et al. (2024a) nyomán

Amennyiben ezen időintervallumon belül nem állt rendelkezésre érvényes megfigyelés, az érintett pixel „nem víz” (0) értéket kapott. Ez a módszer lehetővé tette a hiányzó adat értékek automatikus felszámolását, amely a prediktív modellezési folyamat zavartalan lefuttatásához elengedhetetlen volt.

3.9. A belvízgyakorisági térkép létrehozásának módszertana

A vízborítottság időbeli változásának vizsgálatához Sentinel-1 és Sentinel-2 műholdfelvételeken alapuló napi felbontású bináris víz/nem víz térképek előállítása történt meg, a 2020.06.03 - 2021.06.02. közötti időszakra. Az adatok előfeldolgozása, a mélytanulási modellek alkalmazása, valamint az idősoros térképek integrációja az alábbi lépések szerint zajlott (20. ábra).



20. ábra: A Sentinel–1-es és Sentinel–2-es felvételek feldolgozási folyamata (Kajári és Van Leeuwen, 2024a)

A Sentinel–1 radaradatok (VV és VH polarizáció) feldolgozása a GEE felhőalapú környezetében történt, a 3.6. fejezetben részletezett előfeldolgozási lépések alkalmazásával. Az előkészített adatokból 17 sávós kompozit rétegek készültek, amelyek tartalmazták az eredeti visszaverődési értékeket (VV, VH), az RVI-t, valamint a GLCM-alapú textúraindexeket (2 x 7 sáv).

A Sentinel–2 multispektrális felvételek előfeldolgozását az ArcGIS Pro ArcPy moduljával végeztem [17]. A feldolgozásba kizárólag alacsony felhőborítottságú képeket vontam be, mivel a felhő- és árnyékmaszkolás a nagy kiterjedésű mintaterület esetén jelentős adatvesztést eredményezhetett volna. A maszkolás után 10 sávós multispektrális kompozitok készültek. Mind a Sentinel–1, mind a Sentinel–2 esetében a mintaterületre kivágott adatok 10 méteres térbeli felbontásban kerültek mentésre, biztosítva a szenzorok közötti kompatibilitást a további feldolgozási lépések során.

Mélytanulási modellek és vízdetektálás

Az előfeldolgozott felvételeken CNN alapú vízdetektálási modelleket futtattam. A modellek bináris víz/nem víz osztályozási eredményeket szolgáltatottak, amelyeknél a víz jelenlétét 1-es, a száraz felszínt 0-ás érték jelölte, míg a -1 érték az adathiányt reprezentálta. Az adathiányos

pixelek kezelésére időbeli transzformációt alkalmaztam (3.8. fejezet), hogy a későbbi tér-időbeli elemzésekhez folytonos idősor álljon rendelkezésre.

Térképek összeillesztése és interpoláció

A 2020. június 3. és 2021. június 2. közötti vizsgálati időszakban az egyes napok három kategóriába sorolhatók:

- csak Sentinel–1 adat állt rendelkezésre (151 nap),
- csak Sentinel–2 adat állt rendelkezésre (32 nap),
- mindkét műholdról rendelkezésre állt adat (31 nap).

Az azonos napon elérhető Sentinel–1 és Sentinel–2 alapú előntés térképeket fűzionáltam, ahol csak azokon a pixelek lettek vízként detektálva, ahol mindkét szenzor vízfedettséget jelzett. Az így kapott idősor adathiányos pixeljeit időbeli interpolációval pótoltam: ha az adott napon nem volt elérhető adat, akkor az azt megelőző vagy követő legfeljebb 4 napon belüli elérhető értékeket használtam a kitöltéshez (Kajári et al., 2024a). Ennél hosszabb időbeli távolság esetén a hiányzó értékek „nem víz” (0) besorolást kaptak. Az eljárás eredményeként egy napi felbontású, 364 napot lefedő bináris vízfedettségi térképsorozat jött létre, amely megbízható alapot biztosított a belvíz gyakorisági és tartóssági vizsgálatokhoz, valamint a prediktív modellezéshez.

3.10. Az előrejelző modell kialakításának módszertana

A kutatás további szakaszában a pillanatnyi belvízállapotok azonosítása mellett azok előrejelzésére (predikciójára) is törekedtem (Kajári et al., 2024a). A korábbi előrejelzési megközelítések jellemzően fizikai alapú, részletes bemeneti adatokat igénylő hidrológiai modelleken alapultak, melyek elsősorban lokális léptékben alkalmazhatók. Ezzel szemben jelen vizsgálat újszerűsége abban rejlik, hogy gépi tanulási módszereket – adatvezérelt algoritmusokat – alkalmaz a belvízborítás valószínűségi előrejelzésére.

Az előrejelzéshez két algoritmust használtam: a DNN neurális hálózatot és az XGBoost modellt. A DNN képes a bemeneti változók – meteorológiai, talajtani, domborzati, földhasználati és távérzékelési jellemzők – közötti komplex, nemlineáris kapcsolatok feltárására.

A modellbemenetek a gyakorisági térképezésnél ismertetett, egy teljes éves távérzékelési idősor (2020. június 1. – 2021. május 31.) adataira épültek, amelyet statikus (talajtérkép, felszínborítás, domborzat) és dinamikus (napi csapadék, hőmérséklet, vegetációs indexek) változókkal egészítettem ki.

Elemzésem alapját a Sentinel–1 radar- és a Sentinel–2 multispektrális műholdfelvételek alapján előállított napi szintű vízborítottsági előntés térképek képezték, amelyeket dinamikus és statikus környezeti adatokkal kombináltam. A vízfelszínnek lehatárolását a két különböző műholdtípushoz illesztett CNN alapuló, eltérő modellek alkalmazásával végeztem.


A predikciós modell célja az időszakos előntések előrejelzése, amely a korábban detektált vízborítások tér- és időbeli gyakoriságán, valamint meteorológiai, felszínborítási, talajtani, domborzati és antropogén tényezőkön alapul.

3.10.1. Dinamikus bemeneti adatok

A dinamikus adatkészlet két fő komponensből állt: a műholdképekből származtatott vízborítottsági térképekből és a napi meteorológiai adatokból. A meteorológiai adatok az OMSZ adatházisából [9] származtak, amelyek állomásonként tartalmazták az állomásazonosítót, földrajzi koordinátákat, napi csapadékösszeget (mm), globálsugárzást (J/m^2), relatív páratartalmat (%), a napi minimum és maximum hőmérsékletet ($^{\circ}C$), valamint az átlagos szélesebséget (m/s) 10 méteres magasságban.

Ezen paraméterek alapján számítottam ki a potenciális evapotranszpiráció (PET) értékét a Penman-módszer alkalmazásával, a pyet Python-csomag segítségével [10]. A Penman-módszer a nettó sugárzásból és a tömegáramlásból származó párolgási komponensek súlyozásával becsli a párolgási veszteséget (Ponce, 1989; Vremec et al., 2024).

A vizsgálati terület (21. ábra) köré 40 km-es pufferzónát hoztam létre, amelyben összesen kilenc meteorológiai állomás közül 7 állomás adatai álltak rendelkezésre (21/C. ábra). Ez szükséges volt a térben folytonos meteorológiai térképek interpolációjához, mivel az eredeti területen csak három állomás helyezkedett el (21/A. ábra), ami nem bizonyult elegendőnek. Az interpolációhoz az inverz távolság súlyozás (IDW) módszerét alkalmaztam. Az így előállított napi hőmérséklet-, csapadék-, PET- és szélsőérték-térképek 10×10 méteres térbeli felbontásban készültek.



21. ábra: A vizsgálati terület a meteorológiai állomásokkal és a validációs pontokkal Kajári et al. (2024a) alapján

3.10.2. Statikus bemeneti adatok

A statikus tényezők négy fő csoportba sorolhatók: antropogén hatások, területhasználat, talajtani jellemzők, valamint a domborzatból származtatott morfológiai paraméterek.

1. Antropogén tényezők:

Az emberi tevékenységek térbeli hatásait három fő réteg jellemezte: a településektől, utaktól és csatornáktól való távolságtérképek. Ezeket az OSM nyílt adatbázisából nyertem ki [13], majd Euklideszi távolság alapján készült térképekké alakítottam, 10×10 méteres felbontással.

2. Felszínborítás:

A földhasználati és élőhelytérképet a NÖSZTÉP ökoszisztéma-alaptérkép 20×20 méteres felbontású változatából származtattam [12], amely az ország teljes területére egységes földhasználati besorolást biztosít. Az adatok alapján azonosítottam a belvízre leginkább érzékeny földhasználati típusokat.


3. Talajtani jellemzők:

A talaj vízgazdálkodási tulajdonságainak vizsgálatához az EU SoilGrids adatbázist használtam [14], amely 250 méteres rácshálón biztosít pedotranszfer-függvényeken alapuló fizikai és kémiai talajjellemzőket. A modellben a korábban ismertetett, vízháztartást befolyásoló paraméterek (pl. telített víztartalom, vízkapacitás, hidraulikus vezetőképesség) szerepeltek, amelyeket 0–30 cm és 30–60 cm mélységi sávokban átlagoltam, majd 10 × 10 m felbontású raszteres térképekké alakítottam.

4. Domborzati jellemzők:

A lejtés, valamint a profil- és síkgörbület értékeit az országos, 5 m felbontású digitális domborzatmodell alapján számítottam. A profilgörbület a meredekségi tengely menti, míg a síkgörbület az XY sík menti vízszintes görbületet írja le. Ezek a morfológiai jellemzők közvetlenül befolyásolják az elöntések térbeli előfordulását.

A következő ábra (22. ábra) bemutatja az előfeldolgozási és előrejelző modell munkafolyamatát.



22. ábra: Előfeldolgozási és modellezési munkafolyamat Kajári et al. (2024a) nyomán

A vizsgálati időszakban a Sentinel-1 és Sentinel-2 műholdfelvételek rendelkezésre állása térben és időben eltérő volt. A Sentinel-1 adatbázis 241 felvételt tartalmazott, amelyek közül

60 nem fedte le legalább 40%-ban a mintaterületet, ezért kizárásra került. A Sentinel–2 esetében a feldolgozásba csak a felhőborítottsági küszöböt teljesítő felvételek kerültek be, így a hasznos képek száma jelentősen csökkent. A két műholdrendszer párhuzamos adatainak előfordulása korlátozott volt, ami indokolta a különböző szenzorokból származó idősorok kombinálását és interpolációs módszerek alkalmazását (lásd 3.9. fejezet).

A Sentinel–1 és Sentinel–2 műholdfelvételek osztályozása CNN modellek alkalmazásával történt. A Sentinel–1 esetében a feldolgozás Kajári et al. (2022b) által részletesen ismertett algoritmus alapján zajlott. A modell bemeneti változói az eredeti VV és VH polarizációjú radar sávok, az RVI, valamint a GLCM alapú textúra jellemzők voltak. A Sentinel–2 adatok esetében a modell tíz bemeneti változót használt, amelyek a látható, a közeli infravörös (NIR) és rövidhullámú infravörös (SWIR) sávokból álltak (Kajári és Van Leeuwen, 2023).

Az osztályozás eredményeként minden feldolgozott műholdfelvétélből bináris vízborítottsági térkép készült, ahol a pixelek értékei három kategóriát jelöltek:

- 1 – víz jelenléte,
- 0 – víz hiánya,
- Nincs adat – a modell nem tudta egyértelműen eldönteni a vízborítottságot.

A predikciós modell felépítéséhez szükséges mintákat először két fő csoportra bontottam: vízborítást tartalmazó, illetve vízmentes területekre. Mindkét csoportból 3000 mintát választottam ki véletlenszerűen, amelyek együttesen biztosították a kiegyensúlyozott adatkészletet. Az így létrehozott mintahalmazokat 70–30%-os arányban osztottam fel tanító- (4200) és tesztmintákra (1800). A felosztás után a víz- és nem víz kategóriák mintái mind a tanító-, mind a tesztalomban egyesítésre kerültek.

A feldolgozás során a tanító- és tesztmintákat függő (víz előfordulása) és független (környezeti, meteorológiai és statikus) változókra bontottam. A NÖSZTÉP földhasználati adatbázis [12] kategóriális változóit bináris formában (one-hot-encoding) kódoltam át, ami 56 új jellemzőt eredményezett, mindegyik egy-egy földhasználati típust képviselt. Végül valamennyi bemeneti változót standardizáltam a scikit-learn könyvtár StandardScaler függvényével (Pedregosa et al., 2011), ezzel biztosítva a modellezéshez szükséges homogén skálát. A bemeneti változók Víz (világoskék), Meteorológiai (lila) és Statikus (világos narancssárga) táblázatát az 4. melléklet tartalmazza.

3.11. A belvizek tartósságának becslési módszertana


A belvízi elöntések értékelését a gyakorisági térképezés (lásd 3.9. fejezet) módszertanára építve bővítettem ki, amelynek során az időbeli tartósság és a vízmélység becslése is hangsúlyos szerepet kapott. A korábbi megközelítés elsősorban az elöntések előfordulásának gyakoriságát vizsgálta, azonban a hidrológiai folyamatok megértéséhez elengedhetetlen volt az események időbeli lefutásának elemzése is. Ennek érdekében a módszertant úgy alakítottam át, hogy az egyidejűleg értékelje a belvízborítás fennmaradásának időtartamát, a felszíni vízborítás térbeli kiterjedését és a becsült vízmélységet.

A feldolgozás alapját a Sentinel–2 és Sentinel–1 adatokra épülő osztályozási és textúraelemzési eljárások képezték, amelyeket kiegészítettem egy 5×5 méteres felbontású digitális domborzatmodellel (DDM) [11]. A domborzati modell szerepe kettős volt: egyrészt lehetővé tette a vízgyűjtők és mélyfekvésű mikrodomborzati egységek azonosítását, másrészt alapot nyújtott a vízborítás mélységének és térfogatának közelítő becsléséhez. A multispektrális adatok segítségével az elöntött felszínek optikai jellemzői, míg a radaros adatokból származó visszaverődési értékek révén a felszíni érdesség és víztartalom különbségei váltak kimutathatóvá, így az egyes vízfoltok térbeli és időbeli változásai pontosabban meghatározhatók voltak.

A feldolgozási lépések általános áttekintését a 20. ábra mutatja, míg a 23. ábra az elöntés tartósságának becslésére szolgáló folyamatot részletezi. Az egyes elöntési eseményekhez a

gyakorisági térképből származtatott információk alapján rendelttem hozzá a felszíni kiterjedést, a víztérfogat-becslést és a vízborítás átlagos mélységét. Ezek a paraméterek lehetővé tették, hogy ne csak az elöntés előfordulásának valószínűségét, hanem annak időbeli stabilitását és hidrológiai jelentőségét is számszerűsítsem.

A tartóssági elemzés során az egymást követő időpontokhoz tartozó, napi felbontású elöntés-térképeket vettem össze, hogy meghatározzam, egy adott területrészen hány napon keresztül maradt vízborítás alatt. Az így kapott idősorok lehetővé tették a belvízfoltok kialakulásának, fennmaradásának és visszahúzódásának részletes nyomon követését. Ez a megközelítés nemcsak az események gyakoriságát, hanem azok időtartamát és dinamikus változását is feltárja, így pontosabb képet ad a belvízi elöntések tér-időbeli viselkedéséről. A módszer különösen alkalmas a visszatérő belvízes gócpontok azonosítására, valamint a vízvisszatartási potenciál és az elöntésre való érzékenység becslésére.



23. ábra: Az elöntés tartósságának és becslésének feldolgozási folyamata Kajári et al. (2024b) alapján

A teljes módszertani folyamat átfogóan integrálja a multispektrális és radaros adatokat, valamint a domborzati tényezőket, ezáltal lehetőséget biztosít a vízborítási tartósság és mélység térbeli és időbeli mintázatainak részletes feltárására. Az így előállított tartóssági térképek hozzájárulnak a belvízi elöntések hidrológiai karakterizálásához, és alapot képeznek a prediktív modellezéshez, különösen a belvízveszély előrejelzésének és az érintett területek kockázati besorolásának finomításához.

4. EREDMÉNYEK

A kutatás központi célja egy olyan módszertani keret kidolgozása volt, amely a felszíni vízborítottságának időszakos megjelenését nagy pontossággal, idősorosan megbízható módon és minimális felhasználói beavatkozás mellett képes detektálni, jellemezni, előrejelezni és tartósságát becsülni. Ennek érdekében a vizsgálat 6 fő lépésre tagolható: (1) az adatbázisok strukturálása és modellezési célú összehangolása (2) Sentinel–2 multispektrális műholdfelvételek előfeldolgozása és a legalkalmasabb vízdetektálási módszer kiválasztása; (3) Sentinel–1 radaradatok integrálása a monitoring rendszerbe; (4) az optikai és radaros adatforrások fúziója, gyakorisági térképek előállítása; (5) prediktív modellek fejlesztése; (6) a belvizes állapotok időbeli tartósságának becslése.

4.1. Az adatbázisok strukturálása és modellezési célú összehangolása

A predikciós modell felépítéséhez elengedhetetlen volt a különböző adatbázisok megfelelő strukturálása, előfeldolgozása és egységes keretbe illesztése. A műholdfelvételek alkalmazhatóságának vizsgálata során figyelembe vettem azok térbeli felbontását, visszatérési idejét, valamint azt is, hogy az adatfeldolgozás online (felhőalapú) vagy offline környezetben történt. A módszertani keret kidolgozásánál kiemelt szempont volt az adatforrásokból származó eltérő formátumok és felbontások harmonizálása. Ennek érdekében valamennyi bemeneti adat – beleértve a dinamikus (időben változó) és a statikus (időben állandó) rétegeket is – 10 méteres térbeli felbontású raszteres struktúrába került konvertálásra. Ez az egységesítés tette lehetővé, hogy a predikciós modell számára konzisztens és összevethető bemeneti adathalmaz álljon rendelkezésre. Az alábbi alfejezetek részletesen bemutatják az egyes adatbázisok előállításának, transzformációjának és a modellbe történő integrálásának főbb lépéseit.

4.1.1. A műhold adatok összevetése

A belvíz detektálásához alkalmazható műholdas adatforrások közötti választás során kulcsfontosságú szempont volt a térbeli és időbeli felbontás, a spektrális információgazdagság, valamint az adatok elérhetősége. Ezen peremfeltételek alapos vizsgálata elengedhetetlen volt annak érdekében, hogy a kiválasztott szenzorok alkalmasak legyenek a kisebb kiterjedésű ideiglenes vízfoltok megbízható lehatárolására, illetve a jelenség időbeli dinamikájának követésére. A fejezet célja, hogy bemutassa az egyes multispektrális műholdrendszerek előnyeit és korlátait a belvízmonitoring szempontjából, valamint megalapozza a Sentinel–2 és Sentinel–1 szenzorok integrált alkalmazása melletti döntést.

A belvíz detektálására alkalmazott multispektrális műholdfelvételek közül a *Sentinel–2* nagy térbeli felbontása (10 m), relatíve rövid, 5 napos visszatérési ideje, valamint a rendelkezésre álló spektrális sávok – különösen a közeli infravörös (NIR) és a rövidhullámú infravörös (SWIR) sávok – lehetővé teszik a víztestek, talaj és a vegetációs borítás megbízható elkülönítését.

A *Landsat-8* előnye az évtizedekre visszanyúló archív adatbázis, amely hosszú távú elemzésekhez nélkülözhetetlen, ugyanakkor a 16 napos visszatérési ideje miatt kevésbé alkalmas a belvíz gyors változásainak nyomon követésére, jóllehet a 15-30 méteres térbeli felbontás még megfelelő a közepes léptékű vizsgálatokhoz.

A *MODIS* érzékelő alacsony (250-1000 m) térbeli felbontása miatt nem alkalmas kisebb léptékű elöntések lehatárolására, ugyanakkor rendkívül rövid – napi többszöri – visszatérési ideje és globális lefedettsége lehetővé teszi a nagyobb kiterjedésű, régiós szintű belvizes területek gyors áttekintését.

A *PlanetScope* felvételek kiemelkedő térbeli felbontással (~3–5 m) és napi felvételi ciklussal rendelkeznek, így technikailag kiválóan alkalmasak lennének a belvizes területek nagy gyakoriságú, részletes monitorozására. Ugyanakkor a kereskedelmi adatpolitika, illetve az

ingyenes hozzáférés korlátozott volta jelentős akadályt jelent a rendszeres, országos léptékű alkalmazásokban. További korlátozó tényező, hogy spektrális sávszámuk mindössze négy csatornára – a látható (kék, zöld, vörös) és a közeli infravörös (NIR) tartományra – korlátozódik, amely lényegesen kevesebb lehetőséget kínál a különböző felszínborítási típusok elkülönítésére és indexek alkalmazására. Ezzel szemben a Sentinel–2 műholdrendszer 13 spektrális sávja – köztük a vörös él (Red Edge) és rövidhullámú infravörös (SWIR) sávok – jóval szélesebb spektrális információtartalmat biztosítanak, amelyek lehetővé teszik a víz–talaj–vegetáció elkülönítés pontosabb és sokoldalúbb indexalapú megközelítését (Sahoo et al., 2015).

A peremfeltételek részletes elemzése alapján a Sentinel–2 multispektrális műholdfelvételek bizonyultak a legalkalmasabb adatforrásnak a belvízlehatárolási feladatokhoz (Xu, 2006; Sahoo et al., 2015; Du et al., 2016; Kajári és Van Leeuwen, 2023). A Sentinel–2 műholdrendszer nagy térbeli felbontása (10 m), ötnapos visszatérési ideje és nyílt hozzáférhetősége ideális feltételeket teremt a kis- és közepes kiterjedésű belvízfoltok megbízható detektálásához. Ugyanakkor a multispektrális optikai felvételek használhatóságát jelentősen korlátozza a felhőborítottság és a felhőárnyék jelenléte, különösen a belvizes időszakokban, amikor ezen légköri jelenségek gyakorisága fokozott. E korlátozó tényezők nemcsak a saját kutatási tapasztalataim, hanem számos szakirodalmi forrás említése szerint is meghatározó jelentőségűek (Immitzer et al., 2012; Slagter et al., 2020; Wangchuk és Bolch, 2020; Parajuli et al., 2022; Simón Sánchez et al., 2022; Yilmaz et al., 2023).

További kihívást jelent, hogy a Sentinel–2 önálló alkalmazása, az ötnapos visszatérési idő ellenére, nem elegendő a gyors lefolyású vagy rövid ideig fennálló belvízi események megfelelő időbeli felbontású követésére. E hiányosság kezelése érdekében a kutatás során radaros Sentinel–1 adatok integrálása vált indokolttá. A Sentinel–1 által szolgáltatott SAR felvételek egyik legfőbb előnye, hogy működésük nem függ sem a napszaktól, sem a légköri viszonyoktól, így állandó és kiszámítható adatgyűjtési lehetőséget biztosítanak. A Sentinel–1 térbeli felbontása (alapértelmezésben $4\text{--}5\text{ m} \times 20\text{ m}$), illetve VV és VH átméretezéssel harmonizálható a Sentinel–2 10 m-es multispektrális felbontásához. Ez a harmonizáció teszi lehetővé, hogy a két adatforrás integrált alkalmazása mind a detektálás pontosságát, mind az időbeli frissülést javítsa – akár 2–3 napos időablakra szűkítve a monitorozást.

Összességében a Sentinel–1 és Sentinel–2 műholdak együttes alkalmazása komplex, időben sűrű és spektrálisan gazdag megfigyelési lehetőséget kínál a kutatásomban bemutatott vizsgálatokhoz. A Sentinel–1 biztosítja a légköri zavaroktól független adatgyűjtést és a rövid távú változások észlelését, míg a Sentinel–2 a felszínborítás részletes spektrális jellemzésére nyújt megbízható alapot kedvező optikai körülmények mellett. A két adatforrás szabadon hozzáférhető, strukturált és egységes formában való elérhetősége az ESA Copernicus program keretében nemcsak költséghatékony, hanem a különféle feldolgozási és modellezési eljárások számára is könnyen integrálható és jól összehangolható adatstruktúrát biztosít. E kombinált alkalmazás lehetőséget teremt a belvizes területek megbízható, automatizált és kvázi valós idejű detektálására.


4.1.2. A műholdfelvételek előfeldolgozási környezete

Az alkalmazott műholdfelvételek előfeldolgozása során módszertani szempontból jelentős különbséget jelentett a Sentinel–1 és Sentinel–2 adatok feldolgozási környezete. Míg a Sentinel–1 radaros adatok esetében a Google Earth Engine (GEE) felhőalapú platformot alkalmaztam, addig a Sentinel–2 multispektrális felvételek feldolgozása offline, lokális környezetben történt. A GEE előnye elsősorban a nagy mennyiségű időszakos adat gyors és közvetlen elérésében, valamint az előfeldolgozási lépések – mint például a hőzaj-eltávolítás, radiometriai kalibráció, domborzati torzítás korrekció – automatizált futtatásában rejlik. Ez különösen akkor előnyös, ha nagy területi és időbeli lefedettségű radaradatokat szükséges egységesen kezelni. Ezzel szemben a Sentinel–2 felvételek offline feldolgozása részletesebb

kontrollt biztosított a maszkolási lépések (pl. felhő, árnyék, városi felszínborítás kiszűrése), valamint a sávok átmintázása és spektrális indexek számítása során. Ugyanakkor az offline megközelítés idő- és erőforrás-igényesebb, különösen nagyobb adatmennyiség esetén, továbbá korlátozottabban skálázható. Az eltérő feldolgozási stratégiák gyakorlati tapasztalatai hozzájárultak a kutatás során kialakított módszertani keret finomhangolásához. A Sentinel-1 esetében alkalmazott felhőalapú modell kedvezőbbnek bizonyult a gyorsaság, automatizálhatóság és nagyobb területi lefedettség szempontjából, míg a Sentinel-2 adatok offline feldolgozása lehetővé tette a részletes belvízdetektálási paraméterek precíz beállítását és ellenőrzését. A kétféle feldolgozási mód összevetése megerősítette, hogy a különböző adatforrásokhoz és célkitűzésekhez illeszkedő előfeldolgozási eljárások rugalmas kombinálása elengedhetetlen egy megbízható és adaptív belvízmonitoring-rendszer felépítéséhez.

4.1.3. Dinamikus adatok felhasználhatóságának értékelése

A dinamikus meteorológiai változók adatait az OMSZ archív állományából töltöttem le napi bontásban [9], azonban a potenciális evapotranszspiráció (PET) értékek nem szerepeltek az elérhető adatbázisban. Ennek pótlására egy saját fejlesztésű Python-szkriptet alkalmaztam [10], amely a bemeneti adatokat (hőmérséklet, szélesebbesség, páratartalom, sugárzási jellemzők) CSV formátumból beolvasva különböző, összesen 28 féle számítási eljárás alapján képes meghatározni a PET napi értékeit. A rendelkezésre álló meteorológiai inputok és a szakirodalmi ajánlások alapján a Penman–Monteith eljárás eredményeit használtam fel, mivel ez a módszer bizonyult a legmegbízhatóbbnak az adott adatkör mellett, és széles körű elfogadottságot élvez a tudományos gyakorlatban is. A számítás során a szkript a pyet könyvtár validált PET-modelljeire, valamint a pandas és numpy csomagokra épült, melyek elősegítették az idősorok hatékony feldolgozását és matematikai kezelését. Az így előállított napi PET-értékeket a prediktív modellezés meteorológiai bemeneti adatainak részeként használtam fel (24. ábra).




24. ábra: A potenciális evapotranszspiráció időszora a meteorológiai állomások napi adatai alapján

4.1.4. A statikus adatok eredményei/ felhasználhatóságának értékelése

A statikus prediktorváltozók, mint a domborzati, talajtani, földhasználati és antropogén tényezők, a belvízelöntés-térképezés és predikció szempontjából állandó jellemzőként befolyásolják a modellek teljesítményét. A különböző gépi tanulási algoritmusok esetében a statikus bemeneti adatok relatív fontosságát külön-külön vizsgáltam, különös figyelemmel az XGBoost és a DNN modellek érzékenységi eredményeire.


A belvíz kialakulásának egyik legmeghatározóbb statikus tényezője a domborzat, amely közvetlenül befolyásolja a víz összegyülekezés lehetséges helyeit. A domborzat hatását nemcsak a relatív magasság, hanem a felszín morfológiai jellemzőit is jól tükrözik. A DDM

alapján [11] három domborzati derivátum – lejtőszög, profilgörbület és síkgörbület – került kiszámításra. A görbületi jellemzők értelmezését korábban a módszertani fejezetben ismertettem; jelen fejezetben ezek térbeli mintázatait és belvízérzékenységi összefüggéseit vizsgáltam. Az eredmények szerint a negatív (homorú) profilgörbületi és síkgörbületi értékek mentén koncentrálnak leginkább az elöntési események, ami alátámasztja, hogy a mikrodomborzat döntően befolyásolja a víz visszatartását és lefolyását a vizsgált területen (25. ábra).



25. ábra A domborzatmodellből származtatott profil- és síkgörbület


Az antropogén tényezők értékelésének első lépéseként a területhasználati kategóriákat vontam be a vizsgálatba, amelyeket a NÖSZTÉP adatbázisából nyertem ki [12]. A területhasználati térkép lehetőséget adott a mezőgazdasági, természetközeli és mesterséges felszínek elkülönítésére, ezáltal a belvíz kialakulását befolyásoló felszínborítási viszonyok térbeli mintázatainak feltárására (26. ábra). A térképhez tartozó nomenklátúra a 5. mellékletben található.



26. ábra: A területhasználati térkép


Az antropogén hatások további vizsgálatához három olyan tényezőt vontam be a statikus prediktorváltozók közé, amelyek az emberi beavatkozások és az infrastruktúra jelenlétének közvetett hatásait reprezentálták. A településszerkezet, a közlekedési hálózat és a csatornahálózat közelsége alapvetően meghatározza a felszíni vízmozgás lehetőségeit, illetve a vízelvezetés és vízvisszatartás térbeli mintázatait. Ezeket a hatásokat euklideszi távolságtérképek segítségével kvantifikáltam, amelyek részletesen a következőkben kerülnek bemutatásra.

A településszerkezet hatását az épített területek térbeli elhelyezkedését figyelembe vevő távolságtérképpel reprezentáltam (27. ábra). Az OSM adataiból származó településkontúrok alapján euklideszi távolságtérkép készült 10×10 m felbontásban, amely lehetővé tette az urbanizált felszínek közelségének kvantitatív jellemzését a belvíz kialakulása szempontjából.




27. ábra: A településektől való távolság (m)

A közlekedési infrastruktúra szerepét a főbb úthálózati elemekből készített távolságtérkép segítségével vizsgáltam (28. ábra). Az utak közelsége elsősorban a vízelvezetés akadályozásán, illetve a talajfedettség változtatásán keresztül befolyásolhatja a belvíz előfordulását.



28. ábra: Az utaktól való távolság (m)


A csatornahálózat közelségét ábrázoló távolságtérkép (29. ábra) a vízelvezetési lehetőségek térbeli mintázatát jelenítette meg. Ez az információ különösen fontos a belvíz kockázatának értékelése szempontjából, hiszen a csatornák jelenléte és távolsága közvetlenül meghatározza a vízborítás fennmaradásának időtartamát.



29. ábra: A csatornáktól való távolság (m)

A talajtani tényezők a belvíz kialakulásának egyik meghatározó komponensét képezték, ezért a European Soil Hydraulic Database adataira támaszkodva három fő jellemzőt integráltam a modellbe: Telített víztartalom (THS), Mezőgazdasági vízkapacitás és hervadásponthoz közeli víztartalom (FC) Telített hidraulikus vezetőképesség (KS).

Az adatbázis a változókat hét különböző mélységben (0, 5, 15, 30, 60, 100 és 200 cm) tartalmazta. A talajmélységi rétegek közül a 0–30 cm-es és a 30–60 cm-es tartomány átlagolásával két különálló térképet állítottam elő mindhárom talajtani jellemzőre. Így összesen hat talajtani prediktorváltozó került a modellezésbe, valamennyi 10 × 10 méteres térbeli felbontásban (30. ábra).



30. ábra: A belvízmodellezéshez felhasznált talajtani tényezők (THS, FC, KS) térképi megjelenítése két talajmélységi rétegben

Ezek az adatok lehetővé tették a felszínközeli víztároló képesség és a vízáteresztő tulajdonságok térbeli különbségeinek figyelembevételét, ami különösen lényeges a belvíz tartósságának és intenzitásának modellezésében.

4.2. A belvízdetektálásra legalkalmasabb módszer kiválasztása Sentinel–2 műholdfelvételek alapján

A Sentinel–2 műholdfelvételek alapján különböző vízlehatárolási eljárásokat vizsgáltam eltérő időpontokban és változó légköri viszonyok mellett. Az összehasonlítás célja az volt, hogy feltárjam, az egyes módszerek mennyire érzékenyek a spektrális és atmoszférikus zavarokra (például a felhőborítottságra, az árnyékhataásra vagy a napszögfüggésre), illetve mennyiben alkalmasak dinamikus, napi szintű, automatizálható térképi termékek előállítására újrakalibrálás nélkül. A kiválasztott eljárásokat a modellépítés szempontjából is értékeltem, különös tekintettel az osztályozási pontosság és a gyakorlati alkalmazhatóság együttes biztosítására.

A feldolgozási lépések során kiemelt cél volt a műholdas idősorok időbeli dinamikájának vizsgálata, a belvizes területek tér-időbeli változásainak nyomon követése, valamint az előrejelzések megalapozása. A munkafolyamatokat több platformon (ArcGIS Desktop, ArcGIS Pro, Jupyter Notebook, Google Earth Engine) keresztül valósítottam meg, biztosítva ezzel a modell térinformatikai szoftverektől való függetlenségét és széleskörű adaptálhatóságát.


A vizsgálathoz szükséges nyers Sentinel–2 műholdképeket a Földmegfigyelési Információs Rendszer (eFöld) űrtávérzékelési portáljáról szereztem be [23], amely egyetemi vagy ügyfélkapus hozzáféréssel díjmentesen elérhető.

Az index-térképek előállításához a műholdképek B3, B4, B8 és B11 sávjaiból számítottam ki a belvíz-detektáláshoz szükséges vegetációs és vízindexeket. A meghatározott küszöbértékek

alapján a számított NDVI, NDWI (McFeeters, 1996) és MNDWI (Xu, 2005) értékeket víz és nem-víz osztályokra soroltam.

A klasszikus gépi tanulási osztályozási eljárások (pl. ML, RF, SVM) alkalmazása során kilenc különböző felszínfedettség kategóriát (település; világos víz; sötét víz; száraz szántó; nedves szántó; világos vetés; sötét vetés; rét, legelő; erdő) különítettem el, ahol átlagosan 5700 tanítópixel/kategória alapján lettek az osztályok lehatárolva. Az algoritmusok részletes működését a módszertani fejezet ismerteti, jelen fejezetben az elért pontossági mutatók alapján végzett összehasonlítás eredményei kerülnek bemutatásra.

Az indexalapú és a gépi tanulási osztályozások összevetését az egységesített bináris víz/nem víz térképek tették lehetővé. Az így előállított kimenetek alkalmasak voltak a kétféle megközelítés vizuális és empirikus összehasonlítására, amelyet a 31. ábra szemléltet.



31. ábra: Az indexalapú és osztályozó algoritmusok összehasonlítása a belvíz detektálásában, két vizsgált időpontban (2021.02.23. és 2021.03.20., Kajári és Van Leeuwen, 2021)

A bináris (víz/nem víz) osztályozási térképek vizuális kiértékelése alapján megállapítható, hogy az indexalapú módszerek (NDVI, NDWI, MNDWI) hajlamosak a vízfelületek térbeli kiterjedésének túlbecslésére a gépi tanulási algoritmusokhoz (ML, RF, SVM) képest. Ez a különbség mind a felhőmentes (2021.02.23.), mind pedig a maszkolt, felhő- és árnyékhattal terhelt (2021.03.20.) időpontokban megfigyelhető volt.

Az indexalapú vízetektálást minden vizsgálati időpontra egyedileg meghatározott, empirikusan beállított küszöbértékek alapján végeztem el. A 2021.02.23-i felvétel esetében az

alkalmazott határértékek: $NDVI < -0,10$; $NDWI > -0,20$; $MNDWI > -0,25$. A küszöbértékek megbízhatóságát célzott validációs pontok segítségével ellenőriztem. A vízosztály reprezentálására véletlenszerűen kijelölt 100 mintapontból mindössze 1–2 eset nem igazolódott vissza, míg a többi felszínborítási típushoz rendelt 350 mintapontból csupán 3–4 pont esett tévesen a víz kategóriába.

Ezen eredmények alapján az indexalapú módszerekkel elért felhasználói pontosság (UA) megközelítette a 98%-ot, ugyanakkor a vízborítások túldetektálása miatt a túlosztályozás problémája továbbra is fennáll, különösen spektrálisan bizonytalan vagy árnyékolt területeken.

A többsztályos osztályozási eredmények (ML, RF, SVM) kiértékelését kategóriánként 50–50 véletlenszerűen kijelölt mintapont alapján végeztem el. A pontosságbecslés során minden algoritmus esetében a teljes, 9 kategóriás osztályozási mátrix alapján számítottam ki a legfontosabb statisztikai mutatókat, többek között az UA és a Kappa-indexet.

Az ML algoritmus mutatta a legalacsonyabb teljesítményt, amely feltehetően a viszonylag kis mintaméretből (5700 tanulópixel/osztály) és a kategóriákon belüli magas szórásból adódott (UA: 0,30–0,64; κ : 0,21–0,60). A RF osztályozóval 200–400 döntési fa alkalmazása mellett mérsékelt pontosságot sikerült elérni (UA: 0,68–0,72; κ : 0,64–0,69), azonban a futási idő számottevően megnőtt. A legjobb eredményeket az SVM algoritmus szolgáltatta, különösen az SVM_500 konfiguráció, amely korlátozott mintaszámmal (500) dolgozva némileg pontosabb eredményeket és hatékonyabb futást biztosított. Az SVM így a vizsgált terület felszínborítási kategóriáinak osztályozására a legalkalmasabb módszernek bizonyult (1. táblázat).

1. táblázat: A gépi tanulós módszerek pontosságbecslése

Pontosságbecslés	Település	Világos víz	Sötét víz	Száraz szántó	Nedves szántó	Világos vetés	Sötét vetés	Rét, legelő	Erdő	U_Accuracy	Kappa
Felhőmentes műholdkép 2021.02.23.											
ML_P_Accuracy	0,96	0,78	0,02	0,04	0,52	0,12	0,22	0,04	0,02	0,30	0,21
RF_200_P_Accuracy	0,86	0,68	0,48	0,48	0,52	0,52	0,72	0,70	0,94	0,68	0,64
RF_300_P_Accuracy	0,86	0,68	0,46	0,46	0,54	0,52	0,72	0,70	0,94	0,68	0,64
RF_400_P_Accuracy	0,84	0,68	0,46	0,46	0,52	0,54	0,72	0,70	0,94	0,68	0,64
SVM_0_P_Accuracy	0,82	0,68	0,54	0,30	0,56	0,56	0,82	0,94	0,92	0,72	0,68
SVM_500_P_Accuracy	0,88	0,66	0,38	0,42	0,56	0,66	0,74	0,72	0,92	0,69	0,65
Felhős műholdkép SCL maszkkal 2021.03.20.											
ML_P_Accuracy	0,92	0,72	0,50	0,34	0,52	0,28	0,64	0,80	0,90	0,64	0,60
RF_200_P_Accuracy	0,84	0,86	0,84	0,32	0,72	0,34	0,96	0,62	0,94	0,72	0,68
RF_300_P_Accuracy	0,78	0,84	0,88	0,38	0,72	0,26	0,96	0,68	0,92	0,72	0,69
RF_400_P_Accuracy	0,84	0,94	0,76	0,30	0,72	0,30	0,90	0,72	0,94	0,72	0,69
SVM_0_P_Accuracy	0,82	0,88	0,72	0,24	0,36	0,36	0,86	0,78	0,98	0,72	0,69
SVM_500_P_Accuracy	0,80	0,88	0,72	0,38	0,48	0,48	0,86	0,80	0,96	0,74	0,71

Az osztályozott műholdfelvételek kiértékelése során a vízfelszínekhez tartozó kategóriák – különösen a világos víz osztály – következetesen magas felhasználói pontosságot (UA) mutattak, míg más felszínborítási osztályok esetében jelentős szórás volt megfigyelhető.

A felhasználói pontosság értékei az egyes kategóriák esetében széles tartományban (0,04–0,90) mozogtak, ami egyrészt a tanító minták egyenetlen eloszlására, másrészt a vizsgálati terület nagy kiterjedéséből fakadó spektrális heterogenitásra vezethető vissza. A felszíni

osztályok vizuálisan homogén megjelenése nem mindig tükrözte azok valós spektrális viselkedését, ami az osztályozási hibák egyik forrása lehetett. Ez különösen szembetűnő volt a települési és mesterséges felszínek esetében, ahol a pixelalapú inhomogenitás fokozottan jelen van.


A víz/nem víz típusú osztályok elkülönítése során mind az indexalapú, mind a gépi tanuláson alapuló osztályozási módszerek megbízhatóan működtek nagy kiterjedésű mintaterületen (10000 km²). Az indexek egyik legfőbb korlátja azonban az, hogy a küszöbértékek időpontként változnak, és meghatározásuk empirikus, manuális beavatkozást igényel. Ez a szubjektivitás nemcsak a módszertani konzisztenciát csökkenti, hanem akadályozza az automatizált feldolgozási láncok megvalósítását is, különösen, ha cél a napi frissítésű, dinamikus térképek előállítása.

A spektrális viszonyok időbeli változásai, valamint a felhőborítottságból, párásságból vagy árnyékhatságból eredő légköri zavarok tovább nehezítik a küszöbértékek pontos meghatározását. Bár az ESA által biztosított SCL segíthet a problémás pixelek kiszűrésében, de az általuk elkészített réteg nem tökéletes, így fennáll annak az esélye, hogy például egy vízfelületet részben felhőárnyék borít, amit az algoritmusok tévesen osztályozhatnak.

A gépi tanulási módszerek eredményessége nagymértékben függ a kategóriák belső homogenitásától. A nagy kiterjedésű mintaterületeken a spektrális inhomogenitás növekedése miatt az osztályozó algoritmusok teljesítménye romolhat, ami indokoltá teszi az osztályhatárok finomhangolását és a tanítóadatok kiterjesztését. Eredményeim alapján megállapítható, hogy bár a klasszikus osztályozási módszerek technikailag alkalmasak nagy területek elemzésére, a kapott térképi eredmények pontosságának megítélése csak részletes, pixel-alapú validációval és CM alapú teljesítményértékeléssel lehetséges, függetlenül az alkalmazott módszer típusától.

Összességében tehát a nagy kiterjedésű vízborítási osztályozás elvégezhető mind az indexalapú, mind a felügyelt gépi tanulási módszerekkel, azonban a pontosság és automatizálhatóság közötti egyensúly eléréséhez további fejlesztések, validációs eljárások és módszertani finomítások szükségesek.

A módszertani fejlesztések értékelése érdekében a kutatás egy kisebb, 82,3 km²-es mintaterületen folytatódott, amely lehetőséget adott az eljárások célzott továbbfejlesztésére. A vizsgálat során az indexalapú (NDVI, NDWI, MNDWI), a hagyományos gépi tanulási (ML, RF, SVM) és a mélytanulási (ANN, CNN) módszereket egyaránt alkalmaztam, az adatfeldolgozás egységesítése és automatizálása érdekében pedig a teljes folyamatot Python környezetben valósítottam meg. A feldolgozás menete az előzőekben ismertetett lépésekhez igazodott, ugyanakkor a kisebb léptékű vizsgálat lehetőséget biztosított a hiperparaméterek részletesebb optimalizálására és a pontosságértékelés finomítására. Ez utóbbit pixelalapú confusion matrix segítségével végeztem el, amelyhez manuálisan digitalizált validációs réteget készítettem, az állandó víztestek (pl. halastavak, horgásztavak, fürdők) célzott kizárásával (32. ábra). Az állandó vízfelületek és a 2021. 03. 20-i felvételen az SCL réteg alapján maszkolt felhő- és árnyékterületek a validációs térképeken (34. ábra) fehér színnel, *no data* kategóriában jelennek meg. Ezek külön jelölése a vizualizált térképeken – a nagy számú részlet miatt – nem került feltüntetésre, azonban a leírásban egyértelműen értelmezhetők.



32. ábra: A 82.3 km²-es vizsgálati terület Sentinel-2 hamisszínes kompozitjai állandó víztestekkel és felhőmaszkolással három időpontban: 2021. február 23. (A), 2021. március 7. (B), 2021. március 20. (C) Kajári et al. (2022b) alapján

Az indexalapú osztályozásokhoz a vizsgált terület sajátosságaihoz igazított, a 2021. február 23-i felvétel alapján meghatározott küszöbértékeket alkalmaztam ($NDVI < 0,17$; $NDWI > -0,31$; $MNDWI > -0,36$). Ezek az értékek eltértek a nagyobb mintaterületen használt korábbi beállításoktól, ugyanakkor minden időpontra egységes alapot biztosítottak, ami lehetővé tette az eredmények összehasonlíthatóságát.

Ezt követően hagyományos gépi tanulási eljárásokat alkalmaztam – ML, RF és SVM – tematikus térképek készítéséhez, kilenc osztály elkülönítésével. A vízosztály mellett más felszínborítási osztályokat is létrehoztam, amelyek némelyike "sötét" és "világos" változatban is megjelent, a felhőárnyékokhoz igazodva. A tematikus térképeket bináris víztérképekké alakítottam a további összehasonlítás céljából.


Az ML osztályozást az ArcGIS Pro szoftverrel hajtottam végre, az alapértelmezett paraméterek alkalmazásával. Az osztályozás során minden kategóriát azonos kezdő valószínűséggel kezeltem, vagyis nem adtam egyik osztálynak sem nagyobb súlyt a többinél. A visszautasítási hányadot nullára állítottam, így minden pixel valamelyik osztályba besorolásra került. Az RF modellnél a legjobb eredményt 200 döntési fa és 20-as maximális mélység adta. Az SVM osztályozásnál Radial Basis Function kernelt használtam.

Ezt követően mesterséges neurális hálózatokat is alkalmaztam a sekély víztestek azonosítására két megközelítést teszteltem. Az első egy teljesen kapcsolt neurális hálózat volt, amelyet ugyanazzal a tanítóadathalmazzal tanítottam, mint az ML, RF és SVM modelleket. Ez a hálózat három sűrű réteget tartalmazott (16, 12 és 9 neuronnal), és az első két réteg után 20%-os dropout réteget alkalmaztam az overfitting csökkentése érdekében. Az aktivációs függvényként ReLU-t használtam az első két rétegben, míg a kimeneti rétegben softmax függvényt alkalmaztam. Az Adam optimalizálót 0,004-es tanulási rátával alkalmaztam. A hálózatot 32-es batch size mellett, 30 epoch alatt tanítottam, a hiperparamétereket szintén gridsearch segítségével optimalizáltam. Az eredeti 9 osztályos kimenetet bináris víztérképpé alakítottam.

Az ANN, és CNN modellek betanítását a 2021.02.23-as műholdfelvételen készítettem el. Bemeneti adatként csak a vízfelületeket reprezentáló pixelek kerültek lehatárolásra (33. ábra). Az iteratív elemzés során meghatározásra kerültek az optimális hiperparaméterek. Az ANN egy

háromrétegű teljesen kapcsolt hálózat volt (16, 12, 9 neuronnal), dropout-tal, ReLU és softmax aktivációkkal, míg a CNN esetében a végső paraméterek a következők: 126*64-es csempeméretnél (chip size), 50%-os átfedettséggel (overlap), 8 kötegeléssel (batch size), 20 futtatási körben (Max Epochs) és a túltanulást elkerülve 20%-os validációs érték mellett került meghatározásra. A modellt az ResNet50 hálózati (backbone) modellel képeztük, ahol csak a teljesen összekapcsolt réteg súlyait igazítottam ki. Az ismétlődő folyamatok érdekében az egész munkafolyamat áthelyeztem Python környezetbe, ahol térinformatikai szoftverektől való semlegességet, valamint a felhasználói oldalról történő hibalehetőségek kizárását értem el. Továbbá az automatizált eljárással rengeteg időt spóroltam meg.


A ResNet50 architektúrájú modellel az U-Net előre betanított változata. Ahol az elnevezésben az 50-es szám a rétegek számát jelöli. Minél nagyobb ez a szám annál több képzendő paramétert jelent, és ezáltal nagyobb erőforrás szükséges a modell tanításához. Esetemben az architektúra megfelelően skálázható, rugalmas és robusztus, mélyebb háló -úgy mint, a ResNet101 vagy a ResNet152- csak a számítási időt növelte. A modell képzése során a paramétereket (számokat 0;1) kell beállítani, úgy, hogy az adott bemeneti értékekre az elvárt kimeneti értéket kapjuk. A feladat matematikai értelemben egy függvény illesztési feladat, és csak a teljesen összekapcsolt réteg súlyait igazítottam ki.



33. ábra: A CNN modell betanításához előállított tanítóadatok az eredeti Sentinel-2 színes kompozit alapján (jobb felső sarokban) és a digitalizált állandó víztest-poligonokkal (bal oldalon) Kajári et al. (2022b) alapján


A CNN modellt az így előállított tanítóadatok alapján képeztem, majd minden vizsgált időpontra alkalmaztam, és bináris víztérképeket generáltam. A tanítás és az osztályozás folyamata az ArcGIS Pro deep learning modulban [16] zajlott, amely lehetővé teszi több ismert Python-könyvtár (PyTorch, [18]; TensorFlow, [19]; Keras, [20]; fastai, [21], Howard és Gugger, 2020) mélytanulási funkcióinak felhasználását (Paszke et al.; 2019). A tanításhoz 4794 darab 32×32 pixeles kivágatot készítettem, 16 pixeles átfedéssel. Nem alkalmaztam adatnövelést. A címkék két osztályba tartoztak: víz és nem víz. Az U-Net hálózatot PyTorch [18] implementációval tanítottam meg, ResNet50 háttérhálóval. Csak a teljesen kapcsolt kimeneti rétegek súlyait tanítottam újra. A modell 23 epoch után érte el az optimális teljesítményt.

A klasszifikációk pontosságát egy független, manuálisan digitalizált validációs adathalmazzal értékeltem, amely nem tartalmazott átfedést a tanító minták adataival (34. ábra). Összesen 82.3 km² vízfelületet digitalizáltam mind a három időpontra. A referenciapoligonokat pixelekre bontottam a modellek térbeli felbontásának megfelelően, és minden módszerre és időpontra hibamátrixokat készítettem. A pontosság értékelésére az alábbi mutatókat alkalmaztam: összpontosság, felhasználói és előállítói pontosság, valamint Kappa-index és QADI.



34. ábra: Manuálisan digitalizált validációs vízfelületek a három vizsgálati időpont műholdfelvételein (2021.02.23. – bal felső; 2021.03.07. – bal alsó; 2021.03.20. – jobb alsó) Kajári et al. (2022b) alapján

Az első időpont (2021.02.23.) eredményeit bemutató térképen (35. ábra) az első sorban az indexalapú módszerek láthatók, amelyek küszöbértékekkel határolták le a vízfelületeket. Az NDVI esetében vegyes eredmények adódtak, mivel a küszöbértékeket az első időpontra optimalizált indexértékek alapján határoztam meg. Jól kirajzolódik, hogy a mélyebb vízfoltok helyesen elkülönültek (TP), ugyanakkor a sekélyebb vízfoltok nem minden esetben kerültek megfelelően lehatárolásra, így a FN (világoskék) pixelek száma közel azonos a helyesen azonosított vízpixelekével. Az NDWI osztályozás hasonló mintázatot mutatott, mint az NDVI: a helyesen osztályozott víz és nem-víz pixelek aránya közel azonos volt a két módszernél. Ugyanakkor az NDWI érzékenyebbnek bizonyult az épített környezetre, ezért a csupasz talajfelszínek gyakran tévesen vízfelületként jelentek meg. Az indexalapú eljárások közül a legjobb teljesítményt az MNDWI adta, különösen az első időpontban, mivel a helyesen azonosított pixelek száma jóval meghaladta a hibásan kihagyott vízfoltokét, vagyis a sekélyebb vízborítások pontosabban körvonalazódtak.




35. ábra: A különböző osztályozási módszerek eredményei 2021.02.23-án (Kajári et al., 2022b)

Az ábra második sorában a hagyományos gépi tanulási modellek eredményei szerepelnek. Az ML osztályozás jó egyezést mutatott a validációs adatokkal, bár több kisebb vízfelület hiányzott, ami arra utal, hogy a sekély előtések nem minden esetben kerültek megfelelően lehatárolásra. Az RF módszer a vízfoltokat összességében jól érzékelt, ugyanakkor a vizsgálati terület északi részén némi túl-osztályozás (overclassification) jelentkezett. Az SVM teljesítménye hasonló volt az RF-hez: a hipersík alapú klasszifikáció összességében megbízható eredményt adott, bár a belvíz foltok közelében megjelentek téves pozitív értékek is.


A harmadik sorban a mélytanulási modellek eredményei láthatók. Az ANN hálózatot ugyanazzal a mintahalmazzal tanítottam, mint a hagyományos gépi tanulási modelleket. Ez a megközelítés összességében kevés téves osztályozást eredményezett, az épített környezetben is megbízhatóbb volt, mint az indexalapú módszerek. A CNN modell első időpontbeli eredményei azt mutatták, hogy a víztestek többsége helyesen került osztályozásra, azonban számos sekély előtés kimaradt a detektálásból, ami magasabb FN értékekhez vezetett.

A második időpont (2021.03.07.) eredményeit bemutató térképen (36. ábra) az indexalapú módszerek közül továbbra is az MNDWI teljesített a legjobban, míg az NDVI és az NDWI osztályozásoknál az épített környezet (utak, épületek) továbbra is gyakran tévesen jelent meg vízfelületként (FP). A hagyományos gépi tanulási modellek közül az ML eredményei kiegyensúlyozottak maradtak, az RF módszer pedig az első időponthoz képest meglepően jó teljesítményt nyújtott: a vízfelületek lehatárolása pontosabb lett, és a tévesen osztályozott pixelek (FN és FP) aránya jelentősen csökkent, szinte teljesen eltűnt. Ezzel szemben az SVM instabillá vált, és az NDVI-hoz és NDWI-hez hasonlóan az épített környezet jelentős részét tévesen vízfelületként osztályozta. A mélytanulási modellek eredményei hasonlóan jók voltak, mint az első időpontban: a legtöbb vízfelületet helyesen detektálták, és a téves osztályozások száma alacsony maradt.




36. ábra: A különböző osztályozási módszerek eredményei 2021.03.07-án (Kajári et al., 2022b)

A harmadik időpont (2021.03.20.) felvétele jelentős légköri zavarokat tartalmazott (felhők, felhőárnyékok), ezért fontos volt megvizsgálni, hogyan reagálnak a modellek a felhőmaszkolásra és az atmoszférikus hatásokra. Az indexalapú módszerek teljesítménye gyengébbnek bizonyult az első két időponthoz képest, különösen az NDWI esetében, ahol a hibásan víznek azonosított felszínek egyre szétszórtabban jelentek meg, főként a felhőmaszk környezetében és a csupasz talajfelszíneken (37. ábra). A hagyományos gépi tanulási modellek közül az ML alig mutatott érzékenységet, ugyanakkor az RF és az SVM osztályozások teljesen instabillá váltak, és számos téves vízosztályozás jelent meg a vizsgálati területen. A mélytanulási modellek közül a CNN egyáltalán nem volt érzékeny a légköri zavarokra, míg az ANN csak minimális érzékenységet mutatott, így mindkettő stabilabb eredményt nyújtott a problémás felvételeken.




37. ábra: A különböző osztályozási módszerek eredményei 2021.03.20-án (Kajári et al., 2022b)

Az NDVI érzékenységet az alacsony pixelértékekre jól mutatja, hogy a vizsgálati terület északnyugati részén a volt kunmadarasi repülőtér kifutópályáját tévesen vízfelületként azonosította (38/A. ábra). Hasonló hibák jelentkeztek más lineáris létesítményeknél (utak) és a beépített területeken is (38/B. ábra). A küszöbérték növelésével ugyan több belvízfolt is bevonható lett volna, azonban ezzel párhuzamosan megnőtt a tévesen vízként osztályozott pixelek száma, ahogy az az első időpontnál is látható. Emellett a felhőmaszk közvetlen környezetében is megjelentek hibás vízosztályozások, ami szintén rámutat az index légköri zavarokra való érzékenységre (38/C. ábra).



38. ábra: Az NDVI modell osztályozási hibáinak példái különböző időpontokban. A: a repülőtér kifutópályája (2021.02.23., méretarány 1:6000); B: szétszóró épületek és utak. A fehér területek a maszkolt állandó víztesteket jelölik (2021.03.07., méretarány 1:6000); C: a felhő- és árnyékmáskhoz kapcsolódó hibák (2021.03.20., méretarány 1:6000) (Kajári et al., 2022b)


Az első időpont esetében az NDWI osztályozás eredményei nagyon hasonlóak voltak az NDVI alapján kapott értékekhez (35. ábra). A helyesen osztályozott víz- és szárazföldi pixelek aránya szinte megegyezett a két módszernél. Ugyanakkor az NDWI módszer érzékenyebbnek bizonyult az épített környezetre, mivel a csupasz talajfelszínek hamis pozitívként jelentek meg. Bár ezek még szórványosan fordultak elő, a vízfoltok és lineáris objektumok közelében jól érzékelhetők voltak (39/A. ábra). A második időpontban a helyesen lehatárolt vízpixekek számának növekedése mellett nagyszámú hibásan víznek minősített pixel is megjelent: több beépített terület került tévesen vízfelületként azonosításra (39/B. ábra). A harmadik időpontban, amelyet erőteljes légköri zavarok jellemeztek, a módszer extrém túlbecslést eredményezett: a vízfelületek túlzott kiterjesztése különösen a csupasz talajfelszíneken és a felhőmaszk környezetében volt megfigyelhető (39/C. ábra).



39. ábra: Az NDWI modell osztályozási hibáinak példái különböző időpontokban. A: szétszóró épületek és utak (2021.02.23., méretarány 1:6000); B: utak menti csupasz talajfelszínek (2021.03.07., méretarány 1:6000); C: jelentős hibák a felhő- és árnyékmásk környezetében (2021.03.20., méretarány 1:6000) (Kajári et al., 2022b)


Az indexalapú módszerek közül a MNDWI bizonyult a legeredményesebbnek, különösen az első időpont esetében. Az első felvételen a helyesen azonosított vízfelületek száma jóval meghaladta a téves negatívokét, ami arra utal, hogy a sekélyebb vízfelületek lehatárolása

pontosabban történt (35. ábra). A vízként tévesen osztályozott pixelek száma csökkent, ugyanakkor a repülőtér kifutópályája továbbra is hamis pozitívként jelent meg a kimeneti képeken. Az északi területen egy nagyobb hibásan osztályozott folt is látható (40/A. ábra), amelynek oka lehet a referencia térkép hibája vagy a küszöbérték nem teljesen megfelelő megválasztása. Emellett kisebb mértékű túlbecslés is megfigyelhető a vízfelületek közvetlen környezetében, amely szintén ezekkel az okokkal magyarázható (40/B. ábra). A második időpontban a helyesen azonosított pixelek aránya továbbra is magas, a téves negatívok száma pedig alacsony maradt, ami megerősíti a választott küszöbérték pontosságát. A kifutópályán megjelenő hibás osztályozások száma csökkent, és az elszórtan tévesen víznek minősített foltok ritkán fordultak elő. A harmadik felvételen az eredmények tovább javultak: csupán kevés téves negatív volt megfigyelhető, amelyek azonban más helyeken, például a felhőmaszk közelében jelentek meg (40/C. ábra).




40. ábra: Az MNDWI modell osztályozási hibáinak példái különböző időpontokban. A: hiba a referenciatérképen (2021.02.23., méretarány 1:6000); B: sekély vízfelület (2021.03.07., méretarány 1:6000); C: hibák a felhő- és árnyékmaszok közelében (2021.03.20., méretarány 1:6000) (Kajári et al., 2022b)

Az első időpont osztályozása során az ML jó egyezést mutatott a validációs adatokkal (35. ábra). Ugyanakkor számos vízfelület hiányosan került detektálásra, feltehetően azért, mert a sekély belvízfoltok lehatárolása nem volt teljesen pontos. Téves pozitív besorolások csak az északi területeken jelentek meg (41/A. ábra). A második időpontban még több vízfolt került helyesen azonosításra, miközben néhány északi irányú lineáris vízfolt kimaradt, amelyek valószínűleg nem szerepeltek a referenciakészletben. Téves negatív eredmények a felszáradó belvízfoltok környezetében fordultak elő (41/B. ábra). A harmadik felvétel esetében a modell szintén jó egyezést mutatott a vízfoltokkal, azonban a mélyebb elöntések körül megjelenő sekély vízfelületeket nem sikerült kellő pontossággal érzékelnie. Az indexalapú módszerekkel ellentétben az ML osztályozás nem minősítette tévesen víznek a felhők környezetében található területeket (41/C. ábra). Az első időpont alapján összeállított tanító adathalmaznak köszönhetően a modell mindhárom időpontban következetesen jó teljesítményt nyújtott, és – az indexekkel ellentétben – egyáltalán nem bizonyult érzékenynek az épített környezetre.




41. ábra: Az ML modell osztályozási hibáinak példái különböző időpontokban. A: kihagyás a referencia térképen (2021.02.23., méretarány 1:6000); B: sekély vízfelületek (2021.03.07., méretarány 1:6000); C: felhő- és árnyékmazsk, valamint sekély vízfelületek (2021.03.20., méretarány 1:6000) (Kajári et al., 2022b)

Az első két időpontban az RF módszer jól érzékelt a vízfoltokat, ugyanakkor az utolsó felvétel esetében rendkívül erős túlbecslés (overclassification) jelentkezett. Az első időpontban a modell érzékenysége magas volt, így szinte minden vízfelületet sikeresen detektált (42/A. ábra). A második időpontban az RF kifejezetten jó teljesítményt mutatott, alig fordult elő téves pozitív besorolás. Ugyanakkor számottevő téves negatív eredmények is megfigyelhetők, főként a sekély belvízfoltok esetében, amelyek lehatárolása a tanítás során nem volt teljesen pontos (36. ábra). A harmadik időpontban a modell teljesítménye jelentősen romlott: számos téves pozitív besorolás fordult elő, különösen a sekély belvízfoltokkal spektrálisan hasonló felszíneken, például földutakon, csupasz talajokon vagy aszfaltozott felületeken (42/B. ábra). Ezek a területek a víztestekhez közeli alacsony reflexiós értékeik miatt rendszeresen víznek minősültek, ami a tanítóadatok heterogenitására, valamint a felhőárnyékos területek részleges maszkolására vezethető vissza. A téves pozitív besorolások mértéke és térbeli kiterjedése is megnőtt, ami az RF módszer időbeli instabilitását jelezte a csökkenő vízborítású időszakokban (42/C. ábra).




42. ábra: Az RF modell osztályozási hibáinak példái különböző időpontokban. A: viszonylag kisebb kihagyások (2021.02.23., méretarány 1:6000); B: szélsőséges túlbecslés (2021.03.20., méretarány 1:6000); C: szélsőséges túlbecslés a felhő- és árnyékmazsk környezetében (2021.03.20., méretarány 1:6000) (Kajári et al., 2022b)

Az SVM modell teljesítménye hasonlóan alakult, mint a RF esetében. Az első időpontban a hipersík-alapú osztályozás még viszonylag jó eredményt adott: a vízhez tartozó pixelek jól elkülönültek, és a téves pozitív előfordulások is többnyire a belvizes foltok közvetlen közelében jelentek meg (43/A. ábra). A második és harmadik időpontban azonban az osztályok közelsége megnehezítette a vízfelszínek pontos lehatárolását, ami nagyszámú téves pozitív besorolást eredményezett. A harmadik időpontban az RF modellhez hasonlóan az épített területek (43/B. ábra), valamint szinte a teljes úthálózat tévesen vízfelületként került osztályozásra (43/C. ábra).



43. ábra: Az SVM modell osztályozási hibáinak példái különböző időpontokban. A: viszonylag kisebb kihagyások/tévesztések (2021.02.23., méretarány 1:6000); B: szélsőséges túlbecslés (2021.03.20., méretarány 1:6000); C: szélsőséges túlbecslés (2021.03.20., méretarány 1:6000) (Kajári et al., 2022b)


Az ANN hálózat stabil és megbízható teljesítményt mutatott, viszonylag kevés tévesen azonosított vízfelülettel, és a beépített területeken sem jelentkezett olyan mértékű hibás besorolás, mint a többi módszernél (35. ábra). Az első időpontban a belvízfoltok többségét helyesen detektálta, és a hamis negatív arány az egyik legalacsonyabb volt a modellek között. Ennek ellenére előfordult néhány téves negatív besorolás, főként sekély vízborítások közelében (44/A. ábra). A második időpontban szintén kis számú hamis negatív jelent meg, miközben a vízpixelex nagy részét pontosan azonosította. Bár a modell teljesítménye továbbra is kedvező volt, a vizsgálati terület északi részén néhány hibás osztályozás előfordult (44/B. ábra). A harmadik időpontban a vízfoltok felismerése továbbra is megfelelő maradt, ugyanakkor az atmoszférikus zavarások (fátyolfelhők, felhőárnyékok) hatására a kép középső részén kisebb foltokban vízként jelentek meg olyan területek, amelyek valójában felhőhöz vagy árnyékhoz tartoztak (44/C. ábra).



44. ábra: Az ANN modell osztályozási hibáinak példái különböző időpontokban. A: viszonylag kisebb kihagyások (2021.02.23., méretarány 1:6000); B: némi túlbecslés (2021.03.20., méretarány 1:6000); C: légköri zavarok miatti túlbecslések (2021.03.20., méretarány 1:6000) (Kajári et al., 2022b)

A CNN modell első időpontra vonatkozó eredményei azt mutatják, hogy a víztestek nagy része helyesen került osztályozásra, ugyanakkor számos belvízfolt kimaradt, ami magas számú hibásan kihagyott (FN) pixelt eredményezett (35-37. ábra). A sekély vízfelületek lehatárolása – más modellekhez hasonlóan – továbbra is nehézséget okozott, bár a hibásan vízként azonosított pixelek száma az északi területeken korlátozott maradt (45/A. ábra). Ezenfelül a modell – az ANN és az ML eredményeihez hasonlóan – nem mutat érzékenységet a beépített területekre. A második időpontban a belvízfoltok jól detektálhatók voltak, ugyanakkor a sekély vizek a foltok határain hiányoztak az osztályozási eredményekből. Az ANN modellhez hasonlóan a vizsgálati terület északi részén egy nagyobb folt tévesen vízfelületként jelent meg (45/B. ábra). A harmadik időpontban az egyes belvízfoltok szinte teljes egészében helyesen kerültek azonosításra, csupán a határaikon fordultak elő kisebb kihagyások. A modell

robusztusnak bizonyult a légköri zavarokkal szemben: a felhők és árnyékok hatására csak minimális anomáliák jelentek meg a foltok szélein (45/C. ábra).



45. ábra: A CNN modell osztályozási hibáinak példái különböző időpontokban. A: vízfelületek kihagyásai, 2021.02.23. (méterarány 1:6000); B: kisebb túlbecslés, 2021.03.07. (méterarány 1:6000); C: kisebb túlbecslés és részleges kihagyások, 2021.03.20. (méterarány 1:6000) (Kajári et al., 2022b)

A módszerek összehasonlítása során több pontossági mutatót alkalmaztam annak érdekében, hogy kiválasszam a legmegfelelőbb osztályozási eljárást. Az OA tekintetében azt tapasztaltam, hogy az aszimmetrikus osztályeloszlásból (a nem víz pixelek magas aránya) adódóan minden módszer 90% feletti teljesítményt ért el szinte minden esetben. Emiatt kiegészítésként olyan további mutatókat is bevontam, mint a széles körben alkalmazott Kappa-index (κ) és a QADI-index (QADI), amelyek kevésbé érzékenyek az osztályeloszlás aszimmetriájára (Feizizadeh et al., 2022), valamint a Szenszitivitás (S) és a Precizitás (P) mutatók (Maksimović et al., 2019, 2–4. táblázat).

Az 2. táblázat az első időpontra vonatkozóan mutatja be a nyolc különböző módszer statisztikai eredményeit. Az indexalapú eljárások közül a MNDWI teljesített a legjobban (κ : 0,67; S: 0,71; P: 0,68). A másik két index (NDVI, NDWI) ennél gyengébben szerepelt, körülbelül 0,2-es eltéréssel, kivéve a QADI értéket, ahol a MNDWI 0,03-mal jobb eredményt adott.

2. táblázat: A módszerek statisztikai összehasonlítása az első időpontra (2021.02.23.) vonatkozóan Kajári et al. (2022b) alapján

Mutató	NDVI	NDWI	MNDWI	ML	RF	SVM	ANN	CNN
TN	90,4%	89,42%	91,36%	92,94%	89,4%	90,88%	91,09%	93,38%
FP	3,14%	4,12%	2,18%	0,6%	4,14%	2,66%	2,45%	0,16%
FN	3,4%	2,97%	1,88%	3,46%	1,47%	1,88%	1,64%	3,75%
TP	3,07%	3,49%	4,58%	3,01%	4,99%	4,59%	4,82%	2,72%
OA	0,93	0,93	0,96	0,96	0,94	0,95	0,96	0,96
Sensitivity	0,47	0,54	0,71	0,47	0,77	0,71	0,75	0,42
Precision	0,49	0,46	0,68	0,83	0,55	0,63	0,66	0,94
Kappa	0,45	0,46	0,67	0,58	0,61	0,64	0,68	0,56
QADI	0,063	0,060	0,038	0,031	0,040	0,038	0,034	0,036

A küszöbérték-alapú osztályozás eredményei alapján megfigyelhető, hogy az NDVI és az NDWI érzékenyebbnak bizonyult a beépített területekre (lineáris létesítmények, épületek), ami a tévesen vízként azonosított pixelek magasabb arányában (%) mutatkozott meg (NDVI: 3,14%; NDWI: 4,12%), szemben az MNDWI alacsonyabb értékével (2,18%). A hagyományos gépi tanulási modellek (ML, RF, SVM) közül a SVM teljesített a legjobban a Kappa-index alapján (κ : 0,64), de a másik két modell értékei sem maradtak el jelentősen (ML: κ = 0,58; RF: κ = 0,61). Ugyanakkor a QADI mutató szempontjából az ML modell bizonyult jobbnak (QADI: 0,031), mivel nagyságrendekkel kevesebb hibásan osztályozott vízpixelt tartalmazott (FP: 0,6%). Az ANN esetében a Kappa-index volt a legmagasabb az összes modell közül (κ : 0,68). Ezen az időpontra az ANN minden mutatója (a precizitás kivételével) a legjobb értéket adta. A CNN modell átlagosan szerepelt, ugyanakkor a precizitási mutatója kiemelkedően magas volt (P: 0,94).

Az első időponthoz képest a második időpont mutatói változatos eredményeket mutattak (3. táblázat). Néhány modell, például az SVM, a jelek szerint túlilleszkedett az első időpontra vonatkozó tanító adatokra. Az indexek közül az NDVI és az MNDWI eredményei javulást mutattak.

3. táblázat. A módszerek statisztikai összehasonlítása a második időpontra (2021.03.07.) vonatkozóan Kajári et al. (2022b) alapján

Mutató	NDVI	NDWI	MNDWI	ML	RF	SVM	ANN	CNN
TN	95,89%	93,51%	96,06%	96,5%	96,64%	81,13%	95,71%	96,63%
FP	0,9%	3,29%	0,73%	0,3%	0,15%	15,66%	1,08%	0,16%
FN	0,85%	1,08%	1,03%	1,8%	1,53%	0,53%	0,95%	1,56%
TP	2,36%	2,13%	2,18%	1,4%	1,68%	2,68%	2,26%	1,65%
OA	0,98	0,96	0,98	0,98	0,98	0,84	0,98	0,98
Sensitivity	0,74	0,66	0,68	0,44	0,52	0,83	0,71	0,51
Precision	0,72	0,39	0,75	0,83	0,92	0,15	0,68	0,91
Kappa	0,72	0,47	0,70	0,56	0,66	0,21	0,68	0,65
QADI	0,023	0,031	0,015	0,016	0,014	0,152	0,019	0,014

Az NDWI eredményei a második időpontban hasonlóak voltak az első felvételhez. Az ML kissé gyengébben teljesített, míg az RF valamivel jobban (pl. ML: $\kappa = 0,56$; RF: $\kappa = 0,66$). Az ANN összehasonlítható eredményeket adott, kevesebb hibásan besorolt víz és nem víz pixel mellett (FN: 0,95%; FP: 1,08%), így a QADI mutatója javult (QADI = 0,019). Ezen az időponton a CNN modell az első dátumhoz képest jobban szerepelt: Kappa értéke közepesnek mondható ($\kappa = 0,65$), ugyanakkor a precizitás értéke továbbra is 0.90 felett maradt (P = 0,91). Ez a modell stabilitását mutatta a többi eredményhez képest, kivéve az RF-et, amelynek precizitása valamivel magasabb volt (P = 0,92).

A 4. táblázat a harmadik időpont statisztikai eredményeit mutatja be. Ezen a felvételen atmoszférikus zavarok (felhő, felhőárnyék) jelentkeztek, amelyeket az előfeldolgozás során az SCL réteg felhasználásával igyekeztem a lehető legjobban maszkolni. Az adott képet szándékosan vontam be a vizsgálatba, mert kíváncsi voltam arra, hogy az alkalmazott módszerek miként birkóznak meg az alacsonyabb minőségű felvételekkel, illetve hogyan viselkednek, ha a feldolgozás során csak a standard felhőmaszk áll rendelkezésre.

Az indexek közül az NDWI szerepelt a leggyengébben (pl. K = 0,33). Az NDVI és az MNDWI mutatói szinte minden mérőszám tekintetében rosszabbak voltak a második időponthoz képest, ráadásul téves pozitív pixelek is megjelentek a felhőmaszk környezetében. A hagyományos modellek közül az ML teljesítménye ugyan kissé tovább romlott a második időponthoz képest, de eredményei még így is elfogadhatónak bizonyultak ($\kappa = 0,5$; P = 0,83; S = 0,37; QADI = 0,013). Ezzel szemben az RF és SVM modell eredményei lényegesen rosszabbak lettek, mivel nem voltak képesek kezelni az atmoszférikus zavarokat, amelyek a tanítóhalmazban nem szerepeltek.

Ugyanakkor az ANN modell csak enyhén, míg a CNN modell szinte teljesen érzéketlennek bizonyult a megmaradt felhőhatásokkal szemben, bár mindkét modell teljesítménye kissé gyengébb lett a második időpont eredményeihez képest.

4. táblázat. A módszerek statisztikai összehasonlítása a harmadik (2021.03.20.) időpontra vonatkozóan Kajári et al. (2022b) alapján

Mutató	NDVI	NDWI	MNDWI	ML	RF	SVM	ANN	CNN
TN	95,91%	91,84%	96,79%	97,55%	73,74%	84,57%	96,59%	97,54%
FP	1,81%	5,89%	0,93%	0,18%	23,99%	13,16%	1,14%	0,18%
FN	0,32%	0,54%	0,88%	1,43%	0,49%	0,56%	0,99%	1,15%
TP	1,96%	1,73%	1,4%	0,84%	1,79%	1,72%	1,29%	1,12%
OA	0,98	0,94	0,98	0,98	0,76	0,86	0,98	0,99
Sensitivity	0,86	0,76	0,61	0,37	0,79	0,75	0,57	0,49
Precision	0,52	0,23	0,60	0,83	0,07	0,12	0,53	0,86
Kappa	0,64	0,33	0,60	0,50	0,09	0,17	0,54	0,62
QADI	0,016	0,055	0,018	0,013	0,235	0,127	0,020	0,010

A 5. táblázat az egyes módszerek összesített eredményeit mutatja, amelyeket az egyes felvételi időpontokra számított pontossági mutatók átlagolásával kaptam. Az indexek közül az MNDWI bizonyult a legjobbnak ($\kappa = 0,66$; $P = 0,68$; $QADI = 0,023$). A hagyományos gépi tanulási modellek közül az ML érte el a legmagasabb értékeket ($\kappa = 0,55$; $P = 0,83$; $QADI = 0,020$), míg a neurális hálózatok esetében a CNN mutatta a legjobb teljesítményt ($\kappa = 0,61$; $P = 0,90$; $QADI = 0,020$).

5. táblázat. A pontossági értékelés összesített eredményei Kajári et al. (2022b) alapján

Mutató	NDVI	NDWI	MNDWI	ML	RF	SVM	ANN	CNN
OA average	0,97	0,94	0,97	0,97	0,89	0,89	0,97	0,98
Kappa average	0,60	0,42	0,66	0,55	0,45	0,34	0,63	0,61
Precision average	0,58	0,36	0,68	0,83	0,51	0,30	0,62	0,90
QADI average	0,032	0,049	0,023	0,02	0,096	0,105	0,024	0,020

A modellek időbeli viselkedésének és megbízhatóságának átfogó értékelése érdekében a három vizsgált időpont (2021.02.23.; 2021.03.07. és 2021.03.20.) eredményeit egységes referenciarétegen alapuló validációval hasonlítottam össze. Az elemzés célja annak feltárása volt, hogy a különböző osztályozási megközelítések milyen arányban képesek rekonstruálni a ténylegesen megfigyelt vízfelületeket, illetve hogyan változik e teljesítmény a hidrológiai viszonyok időbeli változásával.

A pontossági mutatók értelmezéséhez szükséges, hogy a helyesen azonosított vízpixelek (TP) arányát az összes, a validációs adathalmazban szereplő tényleges vízpixelszámhoz viszonyítsuk. A validációs poligonokból generált referencia-raszter alapján a vízpixelek száma az egyes időpontokban a következő volt:

- 2021.02.23.: 27 449 pixel
- 2021.03.07.: 31 402 pixel
- 2021.03.20.: 23 964 pixel

A mintaterület teljes kiterjedéséhez viszonyítva ezek a vízfelületek rendre 3,1%, 3,6% és 2,7% lefedettséget képviseltek. A modellek által helyesen detektált vízpixelek (TP) aránya az összes referencia vízpixelhez viszonyítva a vizsgált időpontokban átlagosan 43–78% (Sensitivity) között változott, ami jól szemlélteti az egyes módszerek érzékenységbeli különbségeit.

A CNN modell szenzitivitása (0,42–0,51) közepes értéket mutatott, ami azt jelzi, hogy a modell mérsékelten érzékeny a tényleges vízfelületek detektálására, ugyanakkor a precizitás (0,86–0,94) kiemelkedően magas maradt. Ez arra utal, hogy a CNN hajlamos az alul-, nem pedig a túlbecslésre, így kevesebb hamis pozitív (FP) vízdetektálást eredményezett, mint a többi modell. A kiegyensúlyozott teljesítmény a CNN időbeli stabilitását és általánosíthatóságát támasztja alá a belvízmonitoring alkalmazásokban.

Az első időpontban a CNN modell a validációs vízpixelek kb. 59%-át ismerte fel helyesen, míg az ANN és az SVM 63–70% közötti pontosságot ért el. A második időpontban mindkét

neurális hálózat teljesítménye javult (ANN: 74%, CNN: 68%), ami az adatok jobb spektrális és térbeli felbontásának és a csapadékesemény utáni homogénebb vízborításnak köszönhető. A harmadik időpontban, amikor atmoszférikus zavarok is jelen voltak, a helyesen azonosított vízpixelek aránya mérséklődött (ANN: 57%, CNN: 52%), ugyanakkor a CNN stabilitása továbbra is megfigyelhető volt a többi módszerhez képest.


Az eredmények alapján egyértelmű, hogy a Sentinel-2 műholdképekre épülő belvízmonitoring során a CNN modell bizonyult a legalkalmasabb módszernek. Pontossági mutatói stabilak maradtak mind a három vizsgált időpontban, még a felhőkkel és árnyékokkal terhelt képek esetében is. A CNN előnye nemcsak a megbízható osztályozásban rejlik, hanem az automatizálhatóságban is: a modellt egyszer kell betanítani, és ezt követően képes általánosan alkalmazható eredményeket produkálni. Ezzel szemben az indexalapú módszereknél a küszöbértékek minden egyes időpontra és területre történő újrameghatározása szükséges, a hagyományos gépi tanulási eljárásoknál pedig a különböző spektrális viszonyok miatt szintén új osztályozásokat kell készíteni. Mindezek alapján a CNN módszer kínálja a legstabilabb és legjobban automatizálható megoldást a belvíz előrejelző és monitoring rendszerek jövőbeni fejlesztéséhez.

4.3. Belvízdetektálás eredményei a Sentinel-1 műholdfelvételek alapján

A kutatás következő fázisában a Sentinel-1-es felvételekre fektettem a hangsúlyt, hogy az ideiglenes vízfelületek miként és milyen módon lehet detektálni. Az adatgyűjtés a 2020.11.22. és 2021.04.09. közötti időszakra terjedt ki. A Sentinel-2 optikai felvételekkel való összehasonlíthatóság érdekében az összes adatot 10 méteres térbeli felbontásra mintáztam át. Három olyan időpontot választottam ki, amikor mindkét műholdrendszer felvétele elérhető volt (2021.02.23., 2021.03.07., 2021.03.20.), és ezekhez validációs célból manuálisan digitalizált belvizes fedvények is rendelkezésre álltak.

A végleges, 17 sávból álló bemeneti adatstruktúrát a Sentinel-1 radaros felvételek VV- és VH-polarizált sávjaiból, az RVI, valamint a GLCM textúraanalízis során kiválasztott (2×7) jellemzőkből állítottam össze (ASM, CONTRAST, CORR, VAR, IDM, SAVG, ENT). Az adatok összefoglalását a 3. melléklet tartalmazza. A GLCM-sávok kiválasztását empirikus módon végeztem: a rendelkezésre álló textúramutatókat egyenként bevonva vizsgáltam, hogy azok miként befolyásolják a CNN modell teljesítményét. Azokat a sávokat, illetve azok kombinációját tartottam meg (kék színnel kijelölve), amelyek javították az F1-mutatót; a részletes modell-metrikákat a 6. melléklet tartalmazza. A különböző sávkombinációk mellett a háttérhálózat több változatát (ResNet101, ResNet152 stb.) is teszteltem, azonban ezek alkalmazása nem eredményezett érdemi pontosságjavulást, kizárólag a számítási idő jelentős növekedését.

A modell betanításához szükséges tanító adathalmazt az első időpontra (2021.02.23) vonatkozó Sentinel-2 multispektrális felvétel alapján állítottam össze, amelyen vizuális interpretációval határoztam meg a belvízfoltok poligonjait. Ezek a referenciaadatok szolgáltak a Sentinel-1 felvételek osztályozásának alapjául. A Sentinel-1 adatok feldolgozási folyamatát a 46. ábra szemlélteti.




46. ábra: A Sentinel–1-es adatok feldolgozási modellje (Kajári et al., 2023)

Az összehasonlítás alapjául szolgáló három időpont eredményeit Sentinel–1 és Sentinel–2 felvételek CNN-alapú osztályozásainak páronkénti összevetésével értékeltém, amelynek pontossági mutatóit a 6. táblázat szemlélteti. Az első időpont esetében (47. ábra) a Sentinel–1 felvételen jól látható, hogy a mintaterület két csempe határán helyezkedik el. Ennek következtében a csempe szélein található pixeleket a modell hamisan vízfelületként (FP) azonosította. Emellett a detektáló algoritmusok több tényleges vízfelületet sem ismertek fel, ami a helyesen azonosított pixelek (TP) számának csökkenését és a tévesen kihagyott vízfelületek (FN) arányának növekedését eredményezte. Ezzel szemben a Sentinel–2 optikai felvételen alkalmazott CNN-modell pontosabb eredményt adott (κ : S1 = 0,36; S2 = 0,57; F1-score: S1 = 0,39; S2 = 0,58).


6. táblázat: A Sentinel–1-es és Sentinel–2-es felvételek pontossági összehasonlítása (Kajári et al., 2023)

Dátum	Overall Accuracy		Sensitivity / Recall		Precision		Kappa		F1-score	
	S–1	S–2	S–1	S–2	S–1	S–2	S–1	S–2	S–1	S–2
2021.02.23	0,94	0,96	0,27	0,42	0,70	0,95	0,36	0,57	0,39	0,58
2021.03.07	0,96	0,98	0,41	0,52	0,41	0,91	0,39	0,65	0,41	0,66
2021.03.20	0,93	0,99	0,30	0,50	0,11	0,88	0,14	0,63	0,17	0,63




47. ábra: A 2021.02.23-án lehatárolt vízfelületek összehasonlítása a Sentinel–1 és Sentinel–2 felvételen (Kajári et al., 2023)

A második időpontra vonatkozó elemzés során (48. ábra) a validációs mutatók alapján a vízfelületek helyes detektálása (TP) közel azonosnak bizonyult a két műhold esetében. Ugyanakkor a Sentinel–1 felvételen jól látható, hogy a mintaterület két csempe határán helyezkedik el. Ezen a területen a hibásan vízfelületként azonosított (FP) pixelek száma lényegesen magasabb, és markánsan kirajzolódik az ÉNY–DK irányú csempehatár. Ettől a problémától eltekintve a Sentinel–1 eredményei az első időponthoz képest javulást mutattak: a Kappa értéke 0,39, az F1-score pedig 0,41 volt, míg a Sentinel–2 esetében ezek a mutatók 0,65, illetve 0,66 értéket értek el.



48. ábra: A 2021.03.07-án lehatárolt vízfelületek összehasonlítása a Sentinel–1 és Sentinel–2 felvételen (Kajári et al., 2023)

A harmadik időpontra eső Sentinel–2 felvételen a vízfelületek lehatárolását a felhőborítás is nehezítette (49. ábra). Az optikai adatok előfeldolgozása során a felhők és árnyékok maszkolására az ESA által biztosított SCL réteget alkalmaztam, amelyben a 3., 8., 9., 10. és 11. osztályok kerültek kiszűrésre. Ennek ellenére a Sentinel–1 felvételtől jobb eredményt vártam, azonban az adatfelvétel feltehetően közvetlenül az esőzést követően történt, így a modell nagyszámú pixelt tévesen vízfelületként (FP) azonosított. Emiatt a pontossági mutatók rendkívül gyengének bizonyultak: a Sentinel–1 esetében a Kappa érték 0,14, az F1-score 0,17, míg a Sentinel–2 esetében ezek lényegesen magasabbak voltak (κ : 0,63; F1: 0,63).



49. ábra A 2021.03.20-án lehatárolt vízfelületek összehasonlítása a Sentinel–1 és Sentinel–2 felvételen (Kajári et al., 2023)


A CNN modellt mind a Sentinel–1, mind a Sentinel–2 adatok feldolgozása során eredményesen alkalmaztam a felszíni vízfoltok osztályozására. Tapasztalataim szerint a Sentinel–1 térképeken gyakran megjelent tévesen vízként azonosított foltok (FP), ugyanakkor a tényleges vízfoltokat sok esetben kisebb kiterjedésben jelezte (FN), mint a referencia réteg alapján. A Sentinel–2 felvételek pontosabb eredményeket adtak, de belvizes időszakokban a felhőborítottság miatt csak korlátozottan álltak rendelkezésre, ezért a Sentinel–1 adatok bevonása továbbra is elengedhetetlen.

Az idősoros elemzések szempontjából a Sentinel–2 felvételek Sentinel–1 adatokkal történő kiegészítése jelentősen növelte az időbeli lefedettséget és a vizsgálatok megbízhatóságát. A Sentinel–1 esetében az adatgyűjtés a 2020. november 22. és 2021. április 9. közötti időszakra terjedt ki, amely során összesen 69 darab radaros felvételt dolgoztam fel. Ezzel szemben ugyanebben az időszakban mindössze 9 darab Sentinel–2 optikai felvétel volt felhasználható, elsősorban a felhőborítottsági korlátok miatt. Az Sentinel–1-es adatok integrálása tehát közel nyolcszorosára növelte az időbeli felbontást, ami lehetővé tette a belvízi elöntések kialakulásának és lefolyásának részletesebb követését. A tapasztalatok alapján a jövőbeli kutatásokban kiemelten fontos a Sentinel–1 és Sentinel–2 adatok együttes alkalmazása, mivel ez biztosítja a gyakorisági térképek nagyobb időbeli sűrűségű és megbízható előállítását.

4.4. A belvízgyakorisági térkép

A kutatás egyik kiemelt célja az volt, hogy olyan időben sűrű, térben egységes vízborítottsági adatbázist hozzak létre, amely megbízható alapot szolgáltat a belvízi elöntések dinamikájának elemzésére. Ennek érdekében a Sentinel–1 és Sentinel–2 műholdfelvételek alapján bináris víz/nem víz térképek generálása történt mélytanulási (CNN) modellek alkalmazásával, majd az eltérő időpontokban és érzékelőkkel készült adatok fúziója révén egy napi felbontású idősor összeállítása vált lehetővé. Az adatfeldolgozási lépések szorosan kapcsolódtak az előző fejezetben ismertetett előfeldolgozási és osztályozási folyamatokhoz, azonban a jelen fejezetben már a vízlehatárolás eredményének integrálása, a Sentinel-adatok időbeli lefedettségének kiterjesztése, valamint az interpolációs eljárások bemutatása kerül előtérbe.


Az F1-mutató alapján a Sentinel–1 adatokra épülő modell jobb teljesítményt nyújtott ($F1 = 0,84$), mint a Sentinel–2 alapú modell ($F1 = 0,71$). Ez arra utal, hogy a radaros felvételek a felhőborítottságtól független működésük révén hatékonyabban támogatták a vízfelületek osztályozását. A predikciós térképek közül a 2021. február 23-i eredményt választottam ki, amelyhez az adott dátumra vonatkozó Sentinel–2 hamis színes kompozit felvételt használtam validációs alapként. A teljes vizsgálati terület nagyságára tekintettel egy, mintegy 160 km^2 kiterjedésű mintaterületet jelöltem ki (50. ábra), ahol a vízfelületeket manuális digitalizálással határoltam le. A referencia poligonokat a modellek felbontásával megegyező ($10 \times 10 \text{ m}$) pixelekre alakítottam át, majd ezek alapján állítottam össze a hibamatrixot (50. ábra). Az előrejelzés általános pontossága $0,97$ volt, amelyet a kiegyensúlyozatlan osztályeloszlás magyaráz. A $0,64$ -es Kappa érték ezzel szemben realisabb képet ad a modell teljesítményéről.



50. ábra: Validáció a mintaterületen (Kajári et al., 2024b)

Az adott időpontra (2020.07.05.) vonatkozó térképi eredmények (51. ábra) összehasonlítása alapján megállapítható, hogy az állandó víztestek (sötétkék szín) mindkét műholdfelvételen hasonlóan jelennek meg. A Sentinel–1 radaradatai érzékenyebbeknek bizonyultak a sekélyebb vízborítások, illetve a nedves, kopár talajfelszínek kimutatására (világoskék szín). Ezzel szemben a Sentinel–2 optikai felvételek esetében jobban detektálhatók voltak a gyér


növényzettel fedett vízfelületek (zöld szín), ami feltehetően a növényzettel részben borított rizskazetták víztestjeinek pontosabb azonosíthatóságával magyarázható.



51. ábra: A Sentinel–1-es és Sentinel–2-es felvételek vízlehatárolásának összehasonlítása (Kajári et al., 2024b)

Megjegyzendő, hogy az SCL réteg nem tökéletes osztályozása miatt a felhő- és árnyékmászkolás mellett helyenként hibásan vízfelszínként azonosított pixelek is megjelentek. A Sentinel–1 felvételeken továbbá a csempehatárok mentén is előfordultak hasonló torzulások. Mivel a műholdfelvételek ilyen típusú érzékenysége lokálisan téves vízazonosítást eredményezhet, a többletvíz kimutatásának elkerülése érdekében az azonos időpontban készült felvételek metszetét használtam fel a további elemzésekben.

A 364 napra elkészített bináris térképekből számított gyakorisági értékek eredményeit a vízpixekek előfordulását bemutató térkép szemlélteti (52. ábra). A Sentinel–1 és Sentinel–2 műholdfelvételek fúziója révén a vizsgált egyéves időszakban összesen 214 napon álltak rendelkezésemre értékelhető adatok. A CNN modellek futtatását követően az adathiányos pixeleket időbeli interpolációval pótoltam, azaz a hiányzó értékeket a megelőző vagy a következő időpont felvételei alapján töltöttem ki. Ennek eredményeként sikerült előállítanom a teljes vizsgálati évet lefedő belvízgyakorisági térképet. A térképen egyértelműen elkülönülnek az állandó víztestek az időszakosan vízborítással érintett területektől. A gyakorisági értékek megfelelő osztályozásával lehetőség nyílik olyan területek azonosítására is, amelyek különböző mértékben hajlamosak a belvíz kialakulására. A vízborítás előfordulásának relatív gyakorisága alapján hoztam létre az osztályokat. Az empirikus vizsgálat során a kategóriák határértékeit úgy állapítottam meg, hogy azok illeszkedjenek a térképen megjelenő eloszláshoz, és egyben jól értelmezhetően különítsék el a gyenge, közepes, erős és állandó vízborítást. A táblázat a kategóriákhoz tartozó pixelek számát, területét és arányát mutatja, míg a térkép a belvíz gyakorisági mintázatát szemlélteti (7. táblázat).



52. ábra: A vizsgált időszakra elkészített gyakorisági térkép a teljes vizsgálati területen (1600km²) (Kajári et al., 2024b)


Az eredménytérképen állandó víztestként egyértelműen azonosíthatók a nagyobb tavak, halastavak, nyílt vízfelszínnel rendelkező csatornák (pl. Nagykunsági öntöző főcsatorna), továbbá a holtágak (pl. Peresi-Holt-Körös) és folyószakaszok (pl. Hortobágy-Berettyó).

Az egész vizsgálati területen (1600 km²) a kisebb foltok, amelyek „állandó vízfelületként” kerültek osztályozásra (sötét kék) az év döntő részében folyamatos vízborítás jellemezte őket ezen területek kiterjedése 17.80 km². A magas elöntési gyakoriságú területek (piros) 5.64 km²-rel (84–146 nap) és a közepes gyakoriságú foltok (narancssárga) 3.70 km²-rel (legfeljebb 84 nap) járulnak hozzá, az elöntésekhez. Az alacsony elöntési gyakoriságú zónák (sárga) további 7.79 km²-t tesznek ki, ahol a vízborítás legfeljebb 66 napig tartott. Összességében az állandó és ideiglenes vízborítás együttesen mindössze a mintaterület 1.46%-át érintette, jellemzően a mélyebb részekhez, illetve a magas kockázatú zónák környezetéhez kapcsolódva.

7. táblázat: Az állandó vizek és a belvízzel veszélyeztetett területek megoszlása az 1600 km² vizsgálati területen (Kajári et al., 2024b)

Gyakoriság (%)	Pixel	km ²	Terület (%)	Nap
0–13%	15650691	1565,07	97,82	0–48
13–18%	77934	7,79	0,49	48–66
18–23%	37001	3,70	0,23	66–84
23–40%	56365	5,64	0,35	84–146
40–100%	178009	17,80	1,11	146–365

Az 53. ábra két konkrét példát mutat be magas elöntési gyakoriságú területekre. A felső térképen jól kivehetők a vízborítás alatt álló rizsföldek szabályos alakzatai (53/A. ábra), míg a másik példa az egykori, feltöltődött folyómederben kialakuló vízfelhalmozódás mutatja be (53/B. ábra). Az „állandó vízfelületként” osztályozásra került területek az év döntő részében folyamatos vízborítás jellemezte. A magas elöntési gyakoriságú területek és a közepes gyakoriságú foltok főként a rizskazettákban és vízenyős réteken sekélyebb térszínein helyezkednek el. Az alacsony elöntési gyakoriságú zónák az elöntött területek peremein találhatóak.



53. ábra: Az elöntési gyakorisági térkép eredményei két kiválasztott mintaterületen A: vizenyős rét-legelő, B: rizskazetták (Kajári et al., 2024b)

4.5. Előrejelző rendszer

A fejlesztett belvizeleltetések előrejelző modell alapját a különböző adatforrások – dinamikus tényezők - úgy, mint a hidrometeorológiai adatok, és statikus adatok - talajtani, domborzati és földhasználati tényezők, valamint a Sentinel-1 és Sentinel-2 alapú elöntési adatok – képezték. Ezeket az adatokat időben és térben egységesítettem, majd a megfelelő előfeldolgozási lépéseket követően szolgáltattam bemenetként a DNN és XGBoost modellekhez. A tanítás és validálás során az adathalmazt 80–20% arányban osztottam fel, és a modellek teljesítményét többféle pontossági mutató (pl. Kappa, Sensitivity, Precision, F1-score) alapján értékeltem.

A jövőbeli időpontra történő előrejelzést az XGBoost modell segítségével végeztem el, mivel bár pontosságban csak kis mértékben haladta meg a DNN-t, számítási hatékonyságban lényegesen jobb eredményt nyújtott. A modell tanításához a 2021. február 23-i Sentinel-2 műholdkép bináris vízosztályozása alapján 250 validációs pontot választottam ki véletlenszerűen (21. ábra), amelyek 50%-a víz, 50%-a pedig nem víz pixelre esett. Minden mintaponthoz és időponthoz a különböző adathalmazokból jellemzőket nyertem ki, amely összesen 91250 mintát eredményezett. Azokat a mintákat, amelyeknél egy vagy több jellemzőre hiányzó adat szerepelt, töröltem, valamint kizárásra kerültek azok a területek is, amelyeket a gyakorisági térkép a teljes vizsgálati időszakban (365 nap) mindig vízként vagy mindig szárazként jelölt. A végső mintaszám 50 315 lett. A bemeneti adathalmazok táblázatát a 4. melléklet tartalmazza.

Az xAI-elemzés (lásd a 3.4.11. fejezetben részletezett SHAP-módszertan) rávilágított arra, hogy a prediktorváltozók közül csak néhány játszott meghatározó szerepet a belvíz előrejelzésében. Az alacsony fontossági értékkel rendelkező tényezők eltávolításra kerültek, így a modell a leginkább releváns változókra épült.

A megmaradt 17 bemeneti jellemző mindegyikére folytonos raszteres térképeket készítettem (8. táblázat). A statikus változók térképei időben állandóak, így ezeket csak egyszer kellett előállítani. A környező vizek térképét a t_1 időpontra, vagyis az előrejelzés napját megelőző napra hoztam létre. A

víztörténeti térképeket idősoros állományként kezeltem (lásd 3.8. fejezet). A t_0 időpontra történő előrejelzéshez a t_{-1} és t_{-7} közötti („egy héttel korábbi”), valamint a t_{-8} és t_{-15} közötti („két héttel korábbi”) víztérképeket használtam fel. Hasonló módon a csapadék-, evapotranszpiráció- és széltérképeket is elkészítettem az előrejelzés napját megelőző egy, illetve két hétre. Az adatokat összefűztem, majd 250×250 pixeles csempékre bontottam a számítási terhelés csökkentése érdekében. Az egyes csempéket ugyanazzal a skálázó eljárással normalizáltam, mint a tanítóadatokat, majd betápláltam a modellbe. Az előrejelzés eredményeit végül visszavetítettem a bemeneti adatok eredeti geometriájára, így állítva elő a végső előrejelzési térképet.


8. táblázat: A T_0 időpontra vonatkozó előrejelzés bemeneti változói Kajári et al. (2024a) alapján

Bemeneti adatok	$T_{-8...-15}$	$T_{-1...-7}$	T_{-1}	T_0
Statikus tényezők (6)		x		Előrejelzés
Vízfelület (1)			x	
Víz előzmények (2)	x	x		
Meteorológiai adatok (8)	x	x		

Az előrejelzés folyamata megegyezik a predikció eljárásával, azonban iteratív módon történik. Például az adott t_5 napon várható vízborítás előrejelzéséhez a t_0 , t_1 , t_2 stb. napokra vonatkozó predikciókat egymást követően kell elvégezni, minden lépésben felhasználva az előző nap(ok) előrejelzési eredményeit.

Az előrejelző modell közvetett kiindulópontját a 4.4. fejezetben részletesen bemutatott előtési gyakorisági térkép képezte, amely a CNN-alapú vízlehatárolások időbeli összesítésével jött létre, és a vízborítások tér- és időbeli mintázatait integrálja. E térképből származtattam azokat az időbeli változókat (pl. WATER, IEWSUMweek1, IEWSUMweek2), amelyek a korábbi előtések előfordulását és gyakoriságát jellemzik, és a predikciós modell 17 bemeneti jellemzője között szerepeltek. Így a korábbi vízborítások információi közvetetten beépültek az előrejelzési folyamatba, erősítve a modell időbeli összefüggéseinek felismerését.

A bemeneti változók közötti korrelációt a VIF mutatóval ellenőriztem. Ennek alapján a PETSUMweek1 és a FC_0_30 változókat kizártam, mivel VIF értékük meghaladta a 10-et (O'Brien et al., 2007). Az összes többi változó VIF értéke négy alatt maradt. A SHAP-elemzés további szűrőként szolgált, amelynek eredményeként elhagytam azokat a jellemzőket, amelyek csak csekély mértékben járultak hozzá a tanítás eredményéhez (54. ábra). A változók fontossági sorrendje egyértelműen jelezte, hogy mindkét modell esetében a környező vízborítás (WATER), valamint az egy és két héttel korábbi előtések gyakorisága (IEWSUMweek1 és IEWSUMweek2) bizonyult meghatározónak. A végső modellek 17 bemeneti változóval kerültek betanításra.



54. ábra: A bemeneti változók SHAP-értékek szerinti fontossági sorrendje a DNN (jobbra) és az XGBoost (balra) modell esetében (Kajári et al., 2024a)

Részletesebben kiértékelve a bemeneti változók közül a legerősebb magyarázó tényező a WATER, vagyis az előző napi vízborítottság volt, amely különösen a DNN modellben bizonyult meghatározónak. Ez jól szemlélteti, hogy a belvíz kialakulása erősen autokorrelált jelenség: ha egy területet az előző napon víz borított, nagy valószínűséggel a következő időpontban is elöntött maradt. Az XGBoost modell esetében ugyanakkor az IEWSUMweek1 mutatkozott a legfontosabb prediktornak, amely a rövid távú (7 napos) elöntési előzményeket integrálja. Ez a tényező különösen jól ragadja meg az időjárási viszonyok és a talajnedvesség együttes hatását, így megbízható indikátorává vált a belvíz fennmaradásának. Az IEWSUMweek2, vagyis a két héten belüli elöntési gyakoriság szerepe némileg gyengébb, de még mindig számottevő volt. Ez azt jelezte, hogy a hosszabb idejű, 8–14 napos vízborítottsági mintázatok is hozzájárulhatnak a predikcióhoz, különösen akkor, ha a rövid távú meteorológiai hatások mérséklődnek.

A meteorológiai tényezők közül a PET (napi potenciális evapotranszpiráció) közepes jelentőséggel bírt: magas értékei a vízborítás gyorsabb csökkenéséhez járultak hozzá, míg alacsony PET esetén a felszíni vízborítás tartósabban fennmaradt. A csapadék (Precipitation) ugyanakkor meglepően alacsony súlyt kapott a modellekben, ami arra utal, hogy az elöntések kialakulása nem közvetlenül a napi csapadékösszegekkel, hanem inkább a hosszabb távú vízháztartási folyamatokkal függ össze. Ezt a megállapítást a vizsgált egyéves időszak eredményei is alátámasztják: a nyári hónapok magas csapadékösszegei ellenére nem alakult ki elöntés, mivel a magas hőmérséklet, a nagy potenciális evapotranszpiráció és a növényállomány vízfelhasználása megakadályozta a víz felszíni felhalmozódását. Ősszel és télen, amikor a csapadék mennyisége mérséklődött, ugyanakkor a növények aktivitása is csökkent és az evapotranszpiráció lelassult, a víz sokkal tartósabban a felszínen maradt. Ez jól mutatja, hogy a csapadék önmagában nem tekinthető domináns tényezőnek, hanem hatása a hőmérsékleti és vegetációs viszonyokkal, valamint a párolgási és beszivárgási folyamatokkal összefüggésben értelmezhető (55. ábra). Ez az összefüggés jól tükrözi a SHAP-analízis eredményeit, amelyek szerint a csapadék súlya alacsony, hatása azonban a szezonális vízháztartási folyamatokkal összefüggésben közvetetten érvényesül. A szélesebbesség (Wind) és annak kumulatív mutatói (WindAVGweek1–2) csupán marginális szerepet játszottak, de hozzájárultak a párolgási veszteségekhez. Hasonlóan a kumulatív evapotranszpirációs mutatók (PETSUMtweek1–2) is kisebb, de érzékelhető mértékben befolyásolták az elöntések tartósságát, jelezve, hogy a modellek a tartós meteorológiai hatásokat is figyelembe vették.



55. ábra: Az időszakos belvívelöntések és a csapadék alakulása a vizsgálati időszakban egy 64 ha-os mintaterületen (Kajári et al., 2024a)

A statikus környezeti változók szerepe összességében mérsékelt maradt, de bizonyos mintázatok mégis megfigyelhetők voltak. A csatornához való közelség (Channel_dist) befolyásolta az elöntések fennmaradását: a vízvezető infrastruktúrához közel eső területeken gyakrabban jelentek meg rövid életű vízborítások, amelyek a csatornához közelsége miatt gyorsabban levezethetők voltak. Az utakhoz és településekhez való távolság (Road_dist, City_dist) szerepe szintén kismértékű volt, ugyanakkor utalhat arra, hogy az antropogén létesítmények – például a burkolt felszínek vagy a tömörödött talaj – növelhetik a felszíni elöntések kialakulásának valószínűségét. Az XGBoost modell eredményeiben a City_dist némileg hangsúlyosabban jelent meg, ami jelezheti, hogy a települési környezet közelsége érzékenyebb tényező lehet a belvíz előrejelzésében.

A talajtani és domborzati változók szerepe a modellekben összességében háttérbe szorult. Ennek egyik oka, hogy ezek a tényezők térben viszonylag állandók, így a rövid távú, dinamikus előrejelzésekben kisebb befolyást gyakorolnak az eredményekre. A telített hidraulikus vezetőképesség (KS_0_30) gyenge prediktornak bizonyult, ami arra utal, hogy a talaj vízáteresztő képessége csak közvetett módon hat a belvíz kialakulására, míg az elöntések megjelenését elsősorban a felszíni folyamatok és meteorológiai tényezők határozzák meg. A mikrodomborzati jellemzők, mint a profile és a plan görbület, szintén marginális jelentőséggel bírtak, ami a vizsgált síkvidéki területek alacsony reliefjével magyarázható. Ugyanakkor lokális szinten a mikrodomborzat sajátosságai – például kisebb mélyedések vagy feltöltődött medrek – anomáliákat okozhatnak, amelyek elősegíthetik a víz lokális felhalmozódását, így helyi léptékben mégis releváns tényezővé válhatnak.

Összességében megállapítható, hogy a korábbi vízborítottsági adatok (WATER, IEWSUM) dominálták az előrejelzéseket, míg a meteorológiai változók – különösen a PET, a csapadék és a szél – másodlagos szerepet töltek be. A statikus és talajtani tényezők elsősorban kiegészítő információként járultak hozzá a modellek működéséhez, erősítve a predikciók stabilitását, de önálló magyarázó erejük csekély maradt.

Az XGBoost modell mind pontosság, mind számítási teljesítmény tekintetében felülmúlta a DNN-t. Ennek megfelelően a vizsgálati terület egy 9 napos elöntési időszakának (2021. február 15–23.) előrejelzésére az XGBoost modellt alkalmaztam (56. ábra). A február 15-i előrejelzés alapját a műholdfelvételekből származtatott vízborítottsági idősor képezte, míg a további napokra vonatkozó predikciók minden esetben az előző nap(ok) modell-eredményeire épültek.

A DNN tanítását 0,001-es tanulási rátával és 0,0001-es decay értékkel optimalizáltam. A legjobb eredményt 10-es batch méret és 100 epoch mellett értem el. Az osztályozás pontossága 0,84, Kappa értéke 0,68, az F1-mutató pedig 0,84 volt (9. táblázat). Az XGBoost modellt 0,02-es tanulási rátával, 350 döntési fával, hat maximális mélységgel, minimális három levél-súllyal és nulla gamma értékkel futtattam. Ez kissé jobb eredményt adott, mint a DNN: az összpontosság 0,852 volt. A Kappa (0,703) és az F1 (0,854) mutatók szintén kedvezőbbek lettek. Az XGBoost további előnye, hogy a mélytanulási modellhez képest körülbelül ötször gyorsabban fut (18 másodperc a 102 másodperccel szemben).

9. táblázat: A DNN és az XGBoost modell tanításának pontosság-elemzése 1800 független tesztmintán (Kajári et al. (2024a) alapján)

Teljesítménymutató	DNN	XGBoost
Overall Accuracy	0,84	0,85
Kappa	0,68	0,70
Sensitivity	0,86	0,87
Precision	0,83	0,84
F1-score	0,84	0,85

Az előrejelzések összevetése referenciaként külön-külön előállított, CNN-alapú vízborítottsági térképekkel történt. A vízborítottsági osztályozások statisztikai értékelésére kiszámítottam az összpontosságot (2021.02.15.: 0,97; 2021.02.23.: 0,98), a Kappa értéket (2021.02.15.: 0,55; 2021.02.23.: 0,69), valamint az F1-mutatót (2021.02.15.: 0,56; 2021.02.23.: 0,71). A teljes, 1600 km² kiterjedésű vizsgálati területre összeállított confusion mátrixot a 10. és a 11. táblázat mutatja be.

10. táblázat: A vízborítottság pontosságának értékelése az előrejelzési térképek alapján a 2021.02.15. napon Kajári et al. (2024a) alapján

Pixel	Water	No Water	Total	Overall
Víz	1,66%	1,61%	3,27%	Accuracy: 0,97 Precision: 0,51 Kappa: 0,55 F1-score: 0,56
Nem víz	0,97%	95,75%	96,73%	
Total	2,63%	97,37%	100%	


11. táblázat: A vízborítottság pontosságának értékelése az előrejelzési térképek alapján a 2021.02.15. napon Kajári et al. (2024a) alapján

Pixel	Water	No Water	Total	Overall
Víz	2,91%	0,01%	2,92%	Accuracy: 0,98 Precision: 1,00 Kappa: 0,69 F1-score: 0,71
Nem víz	2,42%	94,66%	97,08%	
Total	5,33%	94,67%	100%	

A 56. ábra a referencia- és az előrejelzett vízborítottság közötti különbséget mutatja be egy kiválasztott területen, 2021. február 15. és 23. időpontokra. Az ábra jól szemlélteti a víz időszakos felhalmozódását a lefolyástalan mélyedésekben, amelyek jellemzően egykori folyómedrekben gyűltek össze. A predikciós térképek validálásához a műholdfelvételekből előállított vízborítottsági térképeket használtam fel. A hibakép (error map) a két modell által előállított térképek közötti eltéréseket ábrázolja, ami hasznos eszköz a predikciós modellek működésének, teljesítményének és hibáinak értelmezéséhez. A referenciaadatok azok a vízborítottsági térképek, amelyekhez az előrejelzéseket hasonlítottam.

A helyesen detektált vízfelületek (TP, zöld) mellett a tévesen vízként azonosított foltok (FP, narancs) főként a nagyobb víztestek szélein jelentek meg, ahol a modellek a sekély, időszakosan kiszáradó részeket és a telített talajfelszíneket is vízként értelmezték. Ezek, különösen jól láthatók a 2021. február 15-i térképen, főként a nagyobb vízfoltok szélein, ahol a modellek a sekély, időszakosan kiszáradó vízfelszíneket és a telített talajokat is vízként jelölték. Ez arra utal, hogy a modell érzékeny a nedves talajfelszínekre. A FN (piros) pixelek azok az esetek, amikor a modell nem azonosított vízborítottságot, pedig jelen volt. Ezek jellemzően kis kiterjedésű vagy keskeny vízfoltok, amelyek valószínűleg nem szerepeltek a tanító adatkészletben, vagy méretük túl kicsi volt a műholdfelvételek térbeli felbontásához képest.

A 2021. február 23-i hibakép már pontosabb előrejelzést mutat. Ezen a napon a nagyobb vízborítások szegélyeinél jelentkező túlbecslés már nem fordult elő, ugyanakkor több kisebb, keskeny vízfoltot a modell nem azonosított. Összességében a két modell jól detektálta az időszakos belvízfoltokat, amit az F1-mutatók is jeleznek (Sentinel-1: 0,56 és Sentinel-2: 0,71).



56. ábra: Referencia- és előrejelzett vízborítottsági térképek közötti különbségek vizsgálata a mintaterület egy részletén (Kajári et al., 2024a)

4.6. Tartósság becslés

A belvízi elöntések vizsgálatában nemcsak a területi kiterjedés, hanem azok időtartama és mélysége is meghatározó szerepet játszik. Míg a gyakorisági térképezés a jelenség előfordulási mintázataira világít rá (lásd 4.4. fejezet), addig a tartósság és a vízmélység elemzése lehetővé teszi a károsodási kockázatok pontosabb értelmezését. Ez a megközelítés különösen fontos a mezőgazdasági hatások feltárásában, mivel a vízborítás időbeni fennmaradása és a talajfelszínen felhalmozódó víztérfogat közvetlenül összefügg a termés kiesés mértékével és a művelési lehetőségek korlátozottságával.

A belvízi elöntések nemcsak kiterjedésük, hanem időtartamuk (tartósságuk) révén is jelentős hatást gyakorolnak a mezőgazdasági termelésre és a gazdálkodási döntésekre. Az elöntés időtartama kulcsfontosságú tényező a növényi károk mértékének meghatározásában, hiszen a tartós vízborítás oxigénhiányos állapotot idéz elő a talajban, ami gátolja a gyökérlégzést és visszafordíthatatlan károsodást okozhat a kultúrnövényekben. A belvizek jellemzően a mélyfekvésű, rossz vízgazdálkodású területeken jelennek meg elsőként, ahol a víz hosszabb ideig stagnál. Már néhány napos vízborítás is súlyos termés kieséshez vezethet, különösen a vegetációs időszak érzékeny fázisaiban (Barta et al., 2013). Ugyanakkor kivételes esetekben az 1–2 napos elöntés akár kedvező hatással is lehet a termés hozamra, például, ha a növények már fejlett fenológiai állapotban vannak, és


a későbbi aszályos periódusokban a talajban megőrzött vízkészlet hozzájárulhat a termés stabilizálásához. Emellett az elöntések jelentősen megnehezítik a szántóföldi munkák időzítését is, mivel az átnedvesedett, vízzel telített talajon a munkagépek nem tudnak közlekedni, így a vetés vagy akár az aratás is több nappal, szélsőséges esetben hetekkel eltolódhat.

A tartósság vizsgálata azonban nem csupán a termés kiesés és a gazdasági károk számszerűsítésében játszik szerepet, hanem vízgazdálkodási szempontból is fontos következtetésekkel szolgál. Az elmúlt évtizedekben a belvizek kezelése elsősorban a gyors elvezetésre irányult, azonban a klímaváltozás hatására szemléletváltás figyelhető meg.

Az ideiglenes vízborítások megítélésében egyfajta „párfordulás” következett be: míg korábban kizárólag káros jelenségeként értékelték, ma egyre inkább felértékelődik a helyben tartott vizek ökológiai és gazdasági szerepe. A tartós, sekély elöntések hozzájárulhatnak a talaj vízkészletének pótlásához, javíthatják a mikroklimatikus viszonyokat, és mérsékelhetik az aszályok hatásait.

E szemléletváltás nyomán indultak el olyan kezdeményezések, mint a „Vízvisszatartás” vagy a „Vizet a tájba!” program, amelyek célja a belvizek hasznosítása ahelyett, hogy azonnali káros tényezőként kezelnék azokat. A tartósság vizsgálata tehát nemcsak a veszteségek becslésében, hanem a fenntartható vízgazdálkodásban is kulcsszerepet játszhat, hiszen segít azonosítani azokat a területeket, ahol az ideiglenes vízmegtartás kifejezetten előnyös lehet mind a mezőgazdaság, mind a környezeti alkalmazkodás szempontjából.

Vizsgálatom célja annak meghatározása volt, hogy a kiválasztott, mintegy 30 hektáros mezőgazdasági területen a vizsgált éves időszakban hány napon keresztül, mekkora kiterjedésben és milyen vízmélységgel jelentkezett a vízborítás (57. ábra). Az elemzés a vízborítási gyakoriság térbeli és időbeli mintázatainak értékelésén alapult, amely lehetővé tette a víz tartósságának valószínűségi becslését. A részletes módszertani lépéseket a 3.11. fejezet, illetve a 23. ábra szemlélteti.



57. ábra: A tartósság vizsgálata az általam kiválasztott mezőgazdasági táblán (Kajári et al., 2024c)

A gyakorisági térképen a vízborítás előfordulási arányait elemeztem, amelyek azt mutatják, hogy az adott év során hány napon jelent meg víz ugyanazon a felszíni helyen (12. táblázat). A vizsgált 30 hektáros mezőgazdasági területen a legnagyobb kiterjedés idején a belvízfolt elérte a 3,08 hektárt ($\approx 10\%$), amely 58 napon keresztül állt vízborítás alatt (sárga színnel jelölve). Az elöntés időbeli lefolyása során a belvízborítás területe fokozatosan csökkent: közepes gyakoriság esetén 1,72 hektár (narancssárga), míg a legmagasabb gyakorisági értékekhez tartozó terület 0,98 hektár (piros) volt, amely a számítások szerint 116 napon keresztül maradt vízzel fedett.

12. táblázat: A belvíz elöntött területek tartóssága (Kajári et al., 2024c)

Tartóssági kategória	Terület (ha)	Tartósság (nap)
Alacsony	3,08	58
Közepes	1,72	68
Magas	0,98	116

A felszíni víztérfogat-becslés alapján a belvíz mennyisége 1984 m³-re tehető, amely átlagosan 6,4 cm-es vízmélységnek felelt meg a vizsgált folton. Ez az érték jól szemlélteti, hogy a tartós, sekély vízborítás még kisebb kiterjedés mellett is jelentős ökológiai és gazdasági hatást gyakorolhat a mezőgazdasági területekre.

4.7. Diszkusszió

A kutatás során többféle módszertani megközelítést alkalmaztam a belvízdetektálás és előrejelzés vizsgálatára. hogy megtaláljam a leghatékonyabb módszert a Sentinel-2 műholdképek alapján történő belvíz-osztályozásra, minimális felhasználói beavatkozással. Szakirodalmi feldolgozás alapján próbáltam megkeresni a legrelevánsabb nyílt vízfelület detektálására használatos optikai műholdfelvételek feldolgozásán alapuló eljárásokat. A Sentinel-2 műholdképeken végzett indexalapú, gépi tanulós és mélytanulós osztályozásokat, amit Sentinel-1 radaros felvételek textúra alapú kiértékelésével egészítettem ki, majd idősoros elemzéseket és predikciós modelleket építettem. Az alábbiakban a legfontosabb eredményeket foglalom össze, kiegészítve a vonatkozó ábrákra és táblázatokra történő hivatkozással.

Az indexalapú módszerek (NDVI, NDWI, MNDWI) értékelését a három időpontra (2021.02.23; 2021.03.07; 2021.03.20) elvégzett vizsgálatok eredményei alapján végeztem. A kisebb mintaterületre (82,3 km²) szűkített, confusion matrix alapú validáció szerint a három index közül a MNDWI teljesített a legjobban (2-4 táblázat; 35–45. ábra): az első időpontban $\kappa = 0,67$, $S = 0,71$, $P = 0,68$, az összesített (átlagolt) mutatók pedig $\kappa = 0,66$, $P = 0,68$, $QADI = 0,023$ értéket mutattak. Az NDVI és NDWI gyengébben szerepelt, különösen a mesterséges felszínek és a felhő-/árnyéknak közelében (átlag: NDVI $\kappa = 0,60$; $P = 0,58$; $QADI = 0,032$; NDWI $\kappa = 0,42$; $P = 0,36$; $QADI = 0,049$).

A hagyományos gépi tanulás (ML, RF, SVM) összesített eredményei szerint az ML adta a legkiegyensúlyozottabb teljesítményt a klasszikus eljárások között ($\kappa = 0,55$; $P = 0,83$; $QADI = 0,020$). Az RF közepes értékeket mutatott ($\kappa = 0,45$; $P = 0,51$; $QADI = 0,096$), míg az SVM szerepelt a leggyengébben ($\kappa = 0,34$; $P = 0,30$; $QADI = 0,105$). A QADI mutató alapján az ML modell téves vízbesorolása kedvezőbb volt, és nagyságrendileg megegyezett a CNN által elért pontossági szinttel. A neurális hálózatok közül az ANN átlagos Kappa-értéke volt a legmagasabb ($\kappa = 0,63$; $P = 0,62$; $QADI = 0,024$), míg a CNN bizonyult a legpontosabbnak és legstabilabbnak ($OA = 0,98$; $\kappa = 0,61$; $P = 0,90$; $QADI = 0,020$). Az első időpontban a CNN $P = 0,94$ értéket ért el, és a három időpont átlagában is megőrizte magas precizitását; a felhős/árnyékos harmadik időpontban is csak minimális határanomáliák jelentkeztek (35–45. ábra). Ez alátámasztja, hogy a CNN robusztusabban és megbízhatóbban detektálja a belvizes foltokat, mint az indexalapú vagy a klasszikus gépi tanulási módszerek, amelyeknél minden időpontra új küszöbérték-meghatározásra vagy újratanításra van szükség.

A Sentinel-1 felvételek alapján végzett vizsgálatok célja a belvízfoltok detektálhatóságának értékelése volt a 2020.11.22–2021.04.09 közötti időszakban. A feldolgozás során minden adatot 10 méteres térbeli felbontásra mintáztam át, és három időpontot választottam ki (2021.02.23., 2021.03.07., 2021.03.20.),

amelyekhez Sentinel-2 felvételek és manuálisan digitalizált referenciaadatok is rendelkezésre álltak. A bemeneti adatstruktúra a VV és VH polarizált sávokból, a Radar Vegetation Indexből (RVI), valamint a Gray-Level Co-occurrence Matrix (GLCM) textúraanalízisből kiválasztott mutatókból állt össze (ASM, CONTRAST, CORR, VAR, IDM, SAVG, ENT).

Az első időpontban (2021.02.23.) a Sentinel-1 eredményei ($\kappa = 0,36$; $F1 = 0,39$) gyengébbnek bizonyultak a Sentinel-2 optikai adatokhoz képest ($\kappa = 0,57$; $F1 = 0,58$), főként a csempehatárokhoz kapcsolódó hibás osztályozások miatt. A második időpontban (2021.03.07.) a pontosság némileg javult (S1: $\kappa = 0,39$; $F1 = 0,41$; S2: $\kappa = 0,65$; $F1 = 0,66$), bár továbbra is előfordultak álpozitív vízosztályozások a csempehatár mentén. A harmadik időpont (2021.03.20.) esetében a Sentinel-1 modell teljesítménye jelentősen visszaesett ($\kappa = 0,14$; $F1 = 0,17$), mivel a felvétel közvetlenül csapadékeseményt követően készült, ami nagyszámú hibás vízdetektálást eredményezett. Ezzel szemben a Sentinel-2 ekkor is kedvezőbb mutatókat szolgáltatott ($\kappa = 0,63$; $F1 = 0,63$), annak ellenére, hogy a felhőborítás előfeldolgozást igényelt.

Az eredmények alapján a Sentinel-1 adatok önállóan is alkalmasnak bizonyultak a belvízterületek detektálására, ugyanakkor legnagyobb erősségük abban rejlik, hogy kiegészítik az optikai felvételek időablak közötti hiányosságokat. A radaros idősorok integrálása különösen a felhőborítás idején biztosít stabil megfigyelési lehetőséget, ezáltal növelve a belvízmonitoring rendszer megbízhatóságát.

A Sentinel-1 és Sentinel-2 adatok együttes alkalmazása kimutathatóan növelte a belvízlehatárolás napi vizsgálatát a mintaterületen. Míg az optikai felvételeken CNN hálózattal előállított víztérképek önmagukban is jó eredményeket adtak tiszta légköri viszonyok mellett, a radaros felvételekből származtatott adatok (VV, VH, RVI, GLCM textúraindexek) bevonása javította a kvázi folyamatos megfigyelést. A fúziós modell különösen a felhőborítással terhelt időpontban mutatott előnyt, amikor az optikai adatok korlátozott információtartalma miatt a belvízfeltoltok egy része csak radaradatok segítségével volt kimutatható. Az integrált megközelítés összességében stabilabb eredményeket biztosított, így a fúziós módszer megbízhatóbb alapot nyújt a jövőbeni operatív belvízmonitoring és előrejelző rendszerek számára.

A DNN és az XGBoost modellek azonos, 24 bemeneti paraméter felhasználásával közel azonos pontosságot értek el, azonban az XGBoost tanítása és predikciója lényegesen gyorsabb volt, ezért a rövid távú előrejelzésekhez ezt a modellt alkalmaztam. Az XGBoost egy-két héttel előre is képes vízfelületeket prognosztizálni, ami összhangban áll Li et al. (2023) szójatermés-előrejelző, valamint Dong et al. (2023) csapadék-predikciós modelljeivel. Bár a modell a múltbeli előntési állapotokat ($T_{-1} \dots -7$ és $T_{-8} \dots -14$) is figyelembe veszi, nem képes explicit módon kezelni az időbeli függőségek dinamikáját, ezért hosszabb távon korlátozottabb predikciós teljesítményt nyújt. Ezzel szemben a long short-term memory (LSTM) hálózatok (van Houdt et al., 2020) képesek az idősoros mintázatok tanulására, így ígéretes alternatívát jelenthetnek a belvízelőntések jövőbeli vizsgálatában.

Az előntési térképek előállításában a CNN modellek bizonyultak a legeredményesebbnek, amelyek robusztusságuk révén különböző időpontokra is megbízhatóan alkalmazhatók. Ez külön előnyt jelent a hagyományos módszerekkel szemben, ahol minden időpontra új küszöbértékeket (indexalapú módszerek) vagy új osztályokat (SVM, RF, ML) kell meghatározni. A tanítás során modelljeim 0,84-es F1 értéket értek el.

Az előntési gyakorisági térkép az adott terület érzékenységeinek jellemzésére is használható, hasonlóan a korábbi kutatásokban publikált belvízveszély-térképekhez (Pálfi et al., 1994; 2004; Pásztor et al., 2015; Bozán et al., 2019; Laborezi et al., 2020). Módszerem előnye a statikus veszélyeztetettségi térképekkel szemben az, hogy az előntési gyakorisági térkép dinamikusan frissíthető, amint új adatok válnak elérhetővé.

A vízborítás tartósságának és mennyiségének meghatározása nagymértékben függ a domborzatmodell pontosságától és felbontásától, különösen abban az esetben, ha síkvidéki területek mikrodomborzati mélyedéseiben összegyülekező vízfoltokat vizsgálunk, ahol a néhány centiméteres különbségek meghatározása a cél.

A kutatás illeszkedik ahhoz a szemléletváltáshoz, amely a klímaváltozás hatására egyre inkább a víz gyors elvezetése helyett az ökológiai vízvisszatartás irányába mozdítja el a hazai vízrendezési gyakorlatot. E paradigmaváltás középpontjában a természetes vízdinamikához való alkalmazkodás, a táji léptékű

vízmegetartás és a belvíz, mint potenciális erőforrás újraértelmezése áll. A kutatás eredményei ezt az irányt támogatják, hozzájárulva nemcsak a vízkárok mérsékléséhez, hanem a fenntartható területhasználat és az ökológiai állapot megőrzését szolgáló vízgazdálkodási döntések megalapozásához is.

Az eredmények azt mutatják, hogy a CNN és az XGBoost modellek kombinációja ígéretes megközelítés a belvíz rövid távú előrejelzésében. A módszertan gyakorlati haszna abban rejlik, hogy hozzájárulhat a gazdasági károk mérsékléséhez, valamint a védekezés és területhasználat tervezéséhez. A pontosság azonban tovább javítható a Sentinel-1 GLCM sávok optimalizálásával, a hiperparaméterek finomításával, a felhőmaszkok pontosításával, valamint új adatok bevonásával (pl. HLS - Harmonized Landsat and Sentinel-2, PlanetScope, talajvízszint, részletes földhasználati adatok). A mikrodomborzati viszonyok pontosabb megragadásához elengedhetetlen a nagyobb felbontású domborzatmodell.

A vizsgálatok egy mérsékelt belvízi eseményekkel jellemezhető egyéves időszak alapján készültek, de a hosszabb idősorok feldolgozása (száraz és csapadékos évek vizsgálatával) a jövőben robusztusabb és általánosíthatóbb előrejelzéseket tehet lehetővé.

5. KONKLÚZIÓ

A kutatás fő célja egy olyan alkalmazható és adaptálható módszertan kidolgozása volt, amely alkalmas a belvízfoltok megbízható detektálására és előrejelzésére, különösen az alacsony lejtésű, vízgyűjtő-szinten zártabb síkvidéki területek hidrometeorológiai és talajtani sajátosságai között. A vizsgálatok eredményei alapján a kitűzött célok túlnyomó része megvalósult, ugyanakkor bizonyos komponensek esetében további fejlesztések indokoltak a módszertan operatív alkalmazhatóságának erősítése érdekében.

Elsőként a bemeneti adatok körének meghatározása volt szükséges. A kutatás kimutatta, hogy a költséghatékonyan hozzáférhető Sentinel-1 radar- és Sentinel-2 multispektrális felvételek biztosítják a belvízlehatárolás szempontjából a megfelelő térbeli (10 m) és időbeli felbontást. Ez a felbontás a vizsgált mintaterületen elegendőnek bizonyult a belvízelöntések pontos azonosítására és monitorozására, bár a kisebb mikrodomborzati mélyedések vízborításának detektálása továbbra is korlátozott. A vizsgálatok alapján tehát a 10 méteres terepi felbontás a belvízmonitoringban alkalmazható, de a domborzati modell felbontásának növelése hozzájárulhat a jövőbeni finomabb elemzésekhez.

A módszertani megközelítések értékelése során az indexalapú technikák, a hagyományos gépi tanulási eljárások és a mélytanulások modellek teljesítményét hasonlítottam össze. Az indexalapú módszerek (NDVI, NDWI, MNDWI) előnye az egyszerűség és a gyors feldolgozhatóság, azonban hátrányuk, hogy minden időpontra külön küszöbérték meghatározása szükséges, ami növeli a felhasználói beavatkozás igényét. A hagyományos gépi tanulási modellek (ML, RF, SVM) már nagyobb rugalmasságot biztosítottak, ugyanakkor érzékenyek bizonyultak az eltérő spektrális viszonyokra. Ezzel szemben a mélytanuláson alapuló módszerek, különösen a konvolúciós neurális hálózat, konzisztens és robusztus eredményeket biztosítottak, és kevésbé voltak érzékenyek a légköri zavarokra vagy a mesterséges felszínek jelenlétére. Az értékelés alapján a CNN bizonyult a legalkalmasabbnak a belvízdetektálásra, mivel a modell egyszeri betanítást követően általánosan alkalmazható maradt, szemben az indexekkel és a hagyományos gépi tanulási modellekkel.

A Sentinel-1 és Sentinel-2 műholdfelvételek integrációja egyértelműen növelte a módszertan hatékonyságát. Míg az optikai adatok tiszta légköri viszonyok mellett biztosítottak nagy pontosságú osztályozást, addig a radaradatok lehetővé tették a vizsgálatok folytatását felhős időszakokban is. A két adatforrás fúziója stabilabb és folyamatosabb idősort eredményezett, különösen a belvízi események kialakulásának és megszűnésének nyomon követésében. Ez igazolta, hogy a multispektrális és radaros adatok együttes alkalmazása megbízhatóbb alapot nyújt a gyakorisági térképek és a tartóssági vizsgálatok számára, mint bármelyik adatforrás önállóan.

A predikciós modellek értékelése során a DNN és az XGBoost eredményeit hasonlítottam össze. Bár a két modell pontossága közel azonosnak bizonyult, az XGBoost kiemelkedett számítási hatékonyságával és stabil teljesítményével, ezért a rövid távú előrejelzésekhez alkalmazása indokoltnak bizonyult. A szakirodalom ugyanakkor rámutat arra, hogy a hosszabb távú predikciókhoz olyan idősoros modellek, mint például az LSTM, ígéretes alternatívát jelenthetnek, mivel képesek integrálni a korábbi állapotok időbeli összefüggéseit (pl.: Ulloa et al., 2022; Yao et al., 2023).

A vizsgálatok alapján az XGBoost modell bizonyult a leghatékonyabbnak a rövid távú előrejelzésekben, 1–2 hétre előre is képes vízborítottságot prognosztizálni. Ez az eredmény új lehetőségeket kínál a belvíz megelőzés és a kárenyhítés szempontjából, és közvetve hozzájárulhat a víz fenntartható mezőgazdasági hasznosításához (pl. kiegészítő öntözés, vízvisszatartás), valamint a vízgazdálkodás fejlesztéséhez (pl. víztározás, talajvíz-utánpótlás, vizes élőhelyek helyreállítása).

Összességében a kutatás igazolta, hogy a Sentinel-1 és Sentinel-2 adatok integrált feldolgozása, a CNN-alapú osztályozás, valamint az XGBoost-alapú predikciós modell olyan komplex módszertani keretet alkot, amely alkalmas a belvízi események detektálására és rövid távú előrejelzésére. A célkitűzések megvalósultak: sikerült azonosítani a költséghatékony és fenntartható adatforrásokat, kidolgozni a legalkalmasabb módszereket a belvízdetektálásra, és létrehozni egy prediktív modellt, amely rövid távon képes a belvízi események előrejelzésére. A további kutatásoknak ugyanakkor ki kell terjedniük a hosszabb idősorok feldolgozására, a bemeneti adatkör bővítésére (pl. talajvíz, domborzati viszonyok, mezőgazdasági gyakorlat), valamint a módszerek operatív alkalmazásának lehetőségeire a hazai vízgazdálkodásban.

6. ÖSSZEFOGLALÓ

A kutatás elsődleges célja egy olyan alkalmazható és adaptálható módszertan kidolgozása volt, amely szabadon elérhető műholdfelvételekre és korszerű gépi tanulási algoritmusokra alapozva alkalmas a belvízelöntések monitorozására és előrejelzésére. A vizsgálatok célja kettős volt: egyrészt egy átfogó keretrendszer kialakítása az adat-előfeldolgozás és -elemzés számára, másrészt olyan operatív modellek létrehozása, amelyek képesek támogatni a vízgazdálkodást és a fenntartható területhasználatot a magyarországi síkvidékeken.

A kutatás során több alapvető kérdésre kerestem választ. Elsőként azt vizsgáltam, hogy a költséghatékony multispektrális (Sentinel-2) és radar (Sentinel-1) műholdfelvételek elegendő időbeli és térbeli felbontást nyújtanak-e a belvizek megbízható lehatárolásához. Az eredmények alapján mindkét adatkészlet alkalmas: a Sentinel-2 képek tiszta légköri körülmények között pontosabb osztályozást nyújtottak, míg a Sentinel-1 radaradatok felhős időszakokban bizonyultak nélkülözhetetlen kiegészítő forrásnak, jelentősen növelve a monitoring rendszer időbeli felbontását.

Második lépésben különböző módszertani megközelítések teljesítményét értékeltem a belvizek lehatárolására és nyomon követésére. Az indexalapú módszerek (NDVI, NDWI, MNDWI), a felügyelt osztályozások (ML, RF, SVM) és a mélytanulási modellek (ANN, CNN) összehasonlítása alapján a MNDWI index teljesített legjobban az indexek között, ugyanakkor összességében a mélytanulási modellek, különösen a CNN mutatták a legnagyobb robusztusságot és pontosságot. A CNN stabil Kappa- és pontossági mutatókat ért el, felülmúlva az indexalapú és a hagyományos gépi tanulási eljárásokat. További előnye, hogy a modell betanítása után automatikusan, több időpontra is egységesen alkalmazható.

Harmadik lépésként a Sentinel-1 radaradatok önálló osztályozási potenciálját vizsgáltam. A VV, VH, RVI és GLCM textúraalapú jellemzők bevonásával CNN modelleket tanítottam. Bár teljesítményük kissé elmaradt a Sentinel-2 eredményeitől, a radar adatok kulcsszerepet játszottak az időbeli hiányok kitöltésében, valamint az elöntések felhős időszakok alatti detektálásában. A Sentinel-1 és Sentinel-2 adatok együttes felhasználása tovább javította az eredmények konzisztenciáját, különösen a kedvezőtlen légköri viszonyok idején.

Negyedik lépésként az elöntések kiterjedésének és időbeli tartósságának kapcsolatát elemeztem. A CNN osztályozással előállított és időben interpolált napi víztérképek lehetővé tették a gyakorisági térképek előállítását. Ezek a térképek elkülönítették az állandó víztesteket az ideiglenes elöntésektől, és kimutatták a magas előfordulási gyakoriságú belvízterületeket, dinamikus alternatívát nyújtva a hagyományos statikus veszélyeztetettség térképekhez képest.

Ötödik lépésként előrejelző modelleket alkalmaztam (DNN és XGBoost). A 24 statikus és dinamikus prediktorváltozóra épülő modellek közül a két módszer hasonló pontosságot nyújtott, ugyanakkor az XGBoost számítási hatékonysága jobb volt, így operatív alkalmazásra alkalmasabbnak bizonyult. Ezzel az eljárással a vízborítottság 1–2 hétre előre jelezhető, ami jelentős hozzájárulás lehet a korai előrejelző rendszerekhez és a kárenyhítéshez.

Hatodik lépésként a kutatás eredményeit vízgazdálkodási és ökológiai szempontból is értékeltem. Az eredmények rávilágítottak arra, hogy a vízborítás tartósságának és dinamikájának vizsgálata nemcsak a károk számszerűsítésére alkalmas, hanem a vízgazdálkodási döntések megalapozásában is kulcsszerepet játszhat. A kidolgozott módszertan lehetőséget teremt olyan elemzésekre, amelyek elősegítik a belvizek helyben tartásának optimalizálását, a vízvisszatartó beavatkozások tervezését és a területi vízmegtartó kapacitás feltérképezését. Vízgazdálkodási szempontból mindez hozzájárulhat a klímaváltozásból fakadó szélsőséges vízhiányok helyzetek – aszály és belvíz – együttes kezeléséhez, a mezőgazdasági termelés biztonságának növeléséhez, valamint az öntözési és vízkormányzási stratégiák hatékonyabb kialakításához. Ökológiai nézőpontból az ideiglenes vizek tartósságának ismerete segítheti a vizes élőhelyek védelmét, a biodiverzitás fenntartását, a talajvíz-utánpótlás biztosítását és a táji mikroklíma szabályozását. A vizsgálat tehát hozzájárul ahhoz a szemléletváltáshoz, amely a belvizeket nem kizárólag problémaként, hanem potenciális erőforrásként kezeli, és új irányokat nyit a fenntartható vízgazdálkodási stratégiák kialakításában.

A kutatás fő következtetései a következőkben foglalhatók össze:

- A Sentinel–1 radaros és Sentinel–2 multispektrális felvételek hatékony és egymást kiegészítő alapot jelentenek a belvízmonitoringhoz.
- A CNN-alapú modellek jelentik a legpontosabb, legrobusztusabb és leginkább automatizálható megoldást a vízfelszínnek lehatárolására.
- Az optikai és radaros adatok egyesítése javítja az időbeli lefedettséget és a megbízhatóságot változó légköri viszonyok mellett.
- A napi osztályozásokból származtatott gyakorisági térképek dinamikus és frissíthető eszközt biztosítanak a veszélyeztetett területek azonosítására.
- Az XGBoost modell bizonyult a leghatékonyabbnak a rövid távú belvízelőfordulások előrejelzésében.

A vízborítás tartósságának becslése nemcsak a károk számszerűsítését teszi lehetővé, hanem kulcsfontosságú a vízgazdálkodási döntések megalapozásában is. Az alkalmazott módszertan támogatja a vízviSSzatartási beavatkozások és a belvizek helyben tartásának tervezését, valamint a területi vízmegtartó kapacitás feltérképezését, ezáltal hozzájárul a klímaadaptációhoz és a fenntartható tájhasználatához.

A jövőbeli fejlesztések irányai közé tartozik a multispektrális és radaradatok harmonizálása, a hosszabb idősorok (pl. Harmonized Landsat–Sentinel) és nagyobb felbontású kereskedelmi adatok (pl. PlanetScope) bevonása, valamint a prediktor adatbázis bővítése talajvíz-, öntözési és agrárgazdálkodási információkkal a modellek pontosságának növelése érdekében.

Összegzésként elmondható, hogy a szabadon elérhető műholdadatok és a fejlett gépi tanulási modellek kombinációja stabil alapot nyújt egy operatív belvízmonitoring és előrejelző rendszerhez. A módszertan döntéstámogató eszközként szolgálhat a vízügyi igazgatóságok és önkormányzatok számára, valamint lehetőséget teremt a gazdálkodók számára a belvízi károk nyomon követésére és az aszály–belvíz kockázatbecslés integrálására. A modell egy térinformatikai előrejelző felület alapjául is szolgálhat, amely valós idejű tájékoztatást nyújt a belvízveszélyes időszakokról és területekről, ezzel hozzájárulva a klímaadaptív tájhasználat és a fenntartható vízgazdálkodás hazai megvalósításához.

A kutatási kérdésekre adott rövid válaszok:

1. kérdés: Léteznek-e olyan költséghatékony multispektrális és radaros műholdfelvételek, amelyek megfelelő időbeli és térbeli felbontást biztosítanak Magyarország síkvidéki területein a belvízlehatárolás szempontjából?

Igen. Az összehasonlító elemzések alapján a szabadon elérhető multispektrális műholdfelvételek közül a Sentinel–2 biztosítja a legnagyobb térbeli felbontást (10 m) és a legszélesebb spektrális lefedettséget (13 sáv) a vizsgált adatkészletekhez (MODIS, Landsat, PlanetScope) képest. Radaros felvételek közül pedig kizárólag a Sentinel–1 áll térítésmentesen rendelkezésre, amely C-sávú radarrendszere révén független a fényviszonyoktól és a felhőborítottságtól, így a belvízdetektálásban nélkülözhetetlen adatforrást jelent.

2. kérdés: A Sentinel–1 és Sentinel–2 multispektrális felvételek térbeli felbontása elegendő-e a belvízelöntések pontos és megbízható lehatárolásához?

Igen. A Sentinel–2 optikai adatok 10 m-es felbontása elegendő a belvízfoltok pontos lehatárolására ($\kappa = 0,62$; $F1 = 0,62$). A Sentinel–1 radaros felvételek átlagos pontossága ($\kappa = 0,30$; $F1 = 0,32$) önmagukban korlátozott, de kiegészítő adatforrásként javítják a térbeli és időbeli lefedettséget, különösen felhős időszakokban.

3. kérdés: Integrálhatók-e a Sentinel–1 és Sentinel–2 műholdfelvételek hatékonyan a síkvidéki belvizek azonosítására és előrejelzésére szolgáló térinformatikai modellezési folyamatokba?

A Sentinel–1 és Sentinel–2 műholdfelvételek 10 m-es térbeli felbontásra történő harmonizálása lehetővé tette a radaros és optikai adatok integrációját, ami közel napi szintű elöntés-térképek

előállítását tette lehetővé. A fúziós feldolgozás növelte a megfigyelések időbeli sűrűségét és javította a belvízdetektálás megbízhatóságát.

4. kérdés: Nyújtanak-e a szabványosított távérzékelési módszerek kellően nagy pontosságot a vízborítottság megbízható lehatárolásához?

Részben. A szabványosított távérzékelési indexek (NDWI, MNDWI, NDVI) önállóan nem biztosítanak kellően nagy pontosságot a belvízlehatároláshoz, mivel érzékenyek a küszöbértékek és a légköri viszonyok változásaira. A MNDWI módszer adta a legjobb eredményt ($\kappa = 0,66$; $P = 0,68$; QADI = 0,023).

A felügyelt gépi tanulási módszerek (ML, RF, SVM) pontossága javult az indexalapú eljárásokhoz képest; közülük az SVM modell bizonyult a legstabilabbnak ($\kappa = 0,69$), de teljesítménye erősen függött a tanítóterületek homogenitásától és a légköri feltételektől.

A mélytanulós (CNN) modell ezzel szemben konzisztensen magas pontosságot ért el ($\kappa = 0,61$; $P = 0,90$; QADI = 0,020), stabil működést mutatott felhős körülmények között is, és jól illeszthető volt az automatizált feldolgozási láncba.

5. kérdés: Alkalmasak-e bizonyos távérzékelési módszerek az idősoros elemzésekre, különösen a belvízelöntések gyakoriságának és dinamikájának vizsgálatában?

Igen, de eltérő mértékben. Az indexalapú módszerek (NDVI, NDWI, MNDWI) idősoros alkalmazása korlátozott, mivel minden időpontra külön küszöbérték beállítása szükséges, ami csökkenti az automatizálhatóságot és a módszertani konzisztenciát. A hagyományos gépi tanulós modellek (ML, RF, SVM) javították a pontosságot, azonban minden új időpontra újratanítást igényelnek, és érzékenyek a légköri viszonyokra.

A mélytanulós modellek – különösen a CNN – ezzel szemben megbízhatóbbnak bizonyultak az időbeli variabilitás kezelésében.

6. kérdés: Képesek-e a mesterséges intelligencián alapuló módszerek felülmúlni a hagyományos megközelítéseket a belvizek detektálásának pontosságában és megbízhatóságában?

Igen. A mesterséges intelligencián alapuló módszerek, különösen a CNN modell, felülmúlták az indexalapú és hagyományos gépi tanulási eljárásokat. A CNN stabil teljesítményt nyújtott változó légköri viszonyok mellett is ($\kappa = 0,61$; $P = 0,90$; QADI = 0,020), és automatizálható feldolgozási folyamatba illeszthető, így a legmegbízhatóbb módszernek bizonyult.

7. kérdés: Alkalmasak-e a Sentinel–1 radaros műholdfelvételek önállóan a vízborítás pontos és megbízható lehatárolására?

Igen, de korlátozott pontossággal. A Sentinel–1 radaros felvételek önállóan is alkalmasak a vízborítás detektálására, de érzékenyek a felszín érdességére, a növényzetre és a speckle-zajra. A radaros feldolgozás átlagos pontossága ($\kappa = 0,30$; $F1 = 0,32$) alacsonyabb az optikai modellnél, ugyanakkor a Sentinel–1 adatok felhős időszakokban pótolhatatlan kiegészítő információt biztosítanak.

8. kérdés: Lehetséges-e a multispektrális és radaros műholdfelvételek hatékony integrációja (fúziója) a belvízlehatárolás céljára?

Igen. A multispektrális és radaros adatok integrációja jelentősen javította a belvízlehatárolás térbeli és időbeli lefedettségét. A 10 m-es térbeli harmonizálás és az idősorok egyesítése 63 napról 214 napra növelte a megfigyelési időablakot, ezáltal lehetővé téve a kvázi folyamatos előntés monitoringot. A fúziós feldolgozás különösen a felhős időszakokban eredményezett pontosabb és stabilabb vízlehatárolást.

9. kérdés: Növelhető-e a belvízi gyakorisági térképek pontossága a multispektrális és radaros adatok integrációjával?

Igen. A multispektrális és radaros adatok integrálása növelte a belvízi gyakorisági térképek pontosságát és részletességét.

Az éves idősor alapján készült térképek pontosan elkülönítették az állandó, közepes és ideiglenes elöntéseket, és javították a mikrodomborzati mélyedések felismerhetőségét.

A dinamikus, időben frissíthető gyakorisági térképek így lényegesen pontosabb képet adnak a belvízveszélyeztetettségéről, mint a hagyományos, statikus veszélytérképek, és alkalmasak az operatív kockázatbecslés és döntéstámogatás alapjául.

10. kérdés: Kimutatható-e statisztikailag is jelentős összefüggés a belvízelöntések kiterjedése és időbeli tartóssága között?

Igen. A vizsgálatok statisztikailag is kimutatták a belvízelöntések kiterjedése és időbeli tartóssága közötti pozitív összefüggést. A nagyobb elöntések jellemzően hosszabb ideig maradtak fenn, míg a kisebb, izolált foltok gyorsabban visszahúzódtak. A kapcsolat különösen markáns volt a mélyfekvésű területeken, a rizstermesztéshez kapcsolódó kazettákban és a lefolyástalan mikrodomborzati mélyedésekben.

11. kérdés: Javítja-e a belvízelöntésekre vonatkozó predikciók pontosságát a műholdfelvételek statikus (pl. domborzati, talajtani) és dinamikus (pl. meteorológiai) adatokkal való kiegészítése?

Igen. A predikciók pontosságát jelentősen növelte a műholdfelvételek statikus (domborzat, talajtani, földhasználati, antropogén) és dinamikus (meteorológiai) adatokkal való kiegészítése.

Az XGBoost modell rövid távon (1–2 hét) megbízható előrejelzést adott, míg a SHAP-elemzés szerint a legnagyobb hatású tényezők a korábbi vízborítottsági jellemzők voltak (WATER, IEWSUM).

12. kérdés: Kialakítható-e egy olyan operatív, gépi tanuláson alapuló előrejelző rendszer, amely alkalmas a síkvidéki belvízelöntések rövid távú modellezésére és térképi megjelenítésére?

Igen. A kutatás során sikerült létrehozni egy gépi tanuláson alapuló, moduláris előrejelző rendszert, amely alkalmas a síkvidéki belvízelöntések rövid távú modellezésére és térképi megjelenítésére.

A Sentinel–1 és Sentinel–2 adatok integrált feldolgozásán alapuló rendszer 1–2 hetes előrejelzési horizonton működik, automatizálható és döntéstámogató eszközként alkalmazható az operatív vízgazdálkodási gyakorlatban.

7. SUMMARY

The primary objective of this research was to develop an applicable and adaptable methodology for monitoring and predicting inland excess water (IEW) using freely available satellite data and advanced machine learning algorithms. The study aimed to provide both a comprehensive framework for data preprocessing and analysis, as well as operational models capable of supporting water management and sustainable land use in the lowland areas of Hungary.

Several fundamental questions were addressed during the research. First, it was examined whether cost-effective multispectral (Sentinel-2) and radar (Sentinel-1) satellite images provide adequate temporal and spatial resolution for reliable delineation of IEW. The results confirmed that both datasets are suitable: Sentinel-2 offers more accurate classification under clear atmospheric conditions, while Sentinel-1 provides essential complementary information during cloudy periods, significantly increasing the temporal density of the monitoring system.

Second, the performance of different methodological approaches for delineating and monitoring IEW was evaluated. Index-based methods (NDVI, NDWI, MNDWI), supervised classification techniques (ML, RF, SVM), and deep learning models (ANN, CNN) were compared. Among the indices, MNDWI performed best, but overall, deep learning models, particularly the convolutional neural network (CNN), proved to be the most robust and accurate. The CNN achieved stable Kappa and precision values, outperforming both index-based and traditional machine learning methods. Furthermore, the model requires training only once and can then be applied consistently across multiple dates.

Third, the potential of Sentinel-1 radar data for independent classification was explored. CNN models were trained using VV, VH, RVI and GLCM texture-based features. Although performance was slightly lower compared to Sentinel-2, radar data played a key role in filling temporal gaps and detecting inundations under cloudy conditions. The fusion of Sentinel-1 and Sentinel-2 data further improved the consistency of results, particularly when atmospheric disturbances reduced the reliability of the optical imagery.

Fourth, the relationship between the extent and temporal persistence of inundations was analyzed. Daily water maps, produced through CNN classification and temporally interpolated, enabled the derivation of frequency maps. These maps separated permanent water bodies from temporary inundations and identified areas with high recurrence of IEW, thereby providing a dynamic alternative to traditional static hazard maps.

Fifth, predictive modelling was carried out using DNN and XGBoost. Based on 24 static and dynamic predictor variables, both models achieved similar accuracy, but XGBoost outperformed DNN in terms of computational efficiency, making it more suitable for operational applications. With this approach, water presence could be predicted one to two weeks in advance, which represents a valuable contribution to early warning systems and damage mitigation.

Sixthly, the research results were evaluated from both hydrological management and ecological perspectives. The findings highlighted that the assessment of surface water persistence and dynamics is not only suitable for quantifying damages but also plays a key role in supporting water management decisions. The developed methodology enables analyses that facilitate the optimization of local water retention, the planning of water-retaining interventions, and the mapping of territorial water-holding capacity. From a water management perspective, these results may contribute to the integrated management of extreme hydrological conditions arising from climate change—such as droughts and inland excess water—enhancing the security of agricultural production and supporting the development of more efficient irrigation and water regulation strategies. From an ecological viewpoint, understanding the persistence of temporary waters can support the protection of wetlands, the maintenance of biodiversity, the replenishment of groundwater, and the regulation of the microclimate at the landscape scale. Thus, this study contributes to a paradigm shift in which inland excess water is regarded not merely as a problem but as a potential resource, opening new directions for the development of sustainable water management strategies.

The main conclusions of this research can be summarized as follows:

- Sentinel–1 and Sentinel–2 images provide an effective and complementary basis for IEW monitoring.
- CNN-based models offer the most accurate, robust and automatable solution for delineating water bodies.
- Fusion of optical and radar data improves temporal coverage and reliability under variable atmospheric conditions.
- Frequency maps derived from daily classifications provide a dynamic and updatable tool for identifying vulnerable areas.
- The XGBoost model proved to be the most efficient for short-term prediction of IEW occurrence.

Estimating the persistence of surface water is not only suitable for quantifying damage but also plays a key role in supporting water management decisions. The applied methodology contributes to the planning of water-retention interventions, the optimization of local water storage, and the mapping of regional water-holding capacity, thereby promoting climate adaptation and sustainable land use.

Future developments should focus on harmonizing multispectral and radar datasets, incorporating longer time series (e.g., Harmonized Landsat–Sentinel products) and higher-resolution commercial data (e.g., PlanetScope) to detect local-scale anomalies more effectively. Expanding the predictor database with groundwater, irrigation, and agricultural management information can further enhance the accuracy of predictions.

In summary, the combination of freely available satellite data and advanced machine learning models provides a solid foundation for developing an operational inland excess water monitoring and forecasting system. The methodology serves as a decision-support tool for water management authorities and municipalities, and enables farmers to monitor and assess inland-water-related damages. Furthermore, it can form the basis of an online geoinformatics-based prediction platform that provides near-real-time information on flood-prone periods and areas. The model could also be integrated into broader water management frameworks—such as combined drought–inland-water risk assessment—and incorporated into agricultural risk mitigation and land-use planning processes. Through these avenues, the research outcomes hold both scientific and operational significance for implementing climate-adaptive land use and sustainable water management in Hungary.

Research questions and concise answers

1. Are freely available multispectral (Sentinel–2) and radar (Sentinel–1) satellite images suitable for inland excess water mapping?

Yes. The Sentinel–2 multispectral (10 m) and Sentinel–1 radar datasets provide an effective and complementary basis for lowland IEW mapping. Sentinel–2 ensures high spatial and spectral resolution under clear conditions, while Sentinel–1 enables observation through cloud cover, ensuring continuity of monitoring.

2. Are Sentinel–2 images sufficient for accurately delineating temporary water surfaces?

Yes. The 10 m spatial resolution of Sentinel–2 proved adequate for delineating IEW ($\kappa = 0.62$; $F1 = 0.62$). Sentinel–1 radar imagery achieved moderate accuracy ($\kappa = 0.30$; $F1 = 0.32$), but complemented optical data effectively during cloudy periods.

3. Can Sentinel–1 and Sentinel–2 imagery be effectively integrated for inland excess water detection and forecasting?

Yes. Harmonizing both datasets to 10 m spatial resolution allowed their integration and significantly reduced the observation gaps. The fusion approach enabled near-daily mapping of inundation extent, improving the temporal density and reliability of monitoring.

4. Do standardized remote-sensing indices provide sufficient accuracy for reliable water delineation?

Partially. Standard indices (NDWI, MNDWI, NDVI) were sensitive to threshold and atmospheric variations. The MNDWI performed best ($\kappa = 0.66$; $P = 0.68$; QADI = 0.023). Supervised machine learning models (ML, RF, SVM) achieved higher accuracy, with SVM showing the most stable results ($\kappa = 0.69$). The CNN model, however, provided consistently high accuracy ($\kappa = 0.61$; $P = 0.90$; QADI = 0.020) and was well suited for automated processing.

5. Are the applied methods suitable for multi-temporal monitoring?

Yes, with varying effectiveness. Index-based methods (NDWI, MNDWI) required recalibration for each date, limiting temporal comparability. Machine learning models (RF, SVM) improved spatial accuracy but lacked temporal stability. Deep learning models (CNN, ANN) enabled continuous monitoring of a 214-day time series, capturing the spatial-temporal dynamics of IEW.

6. Do artificial intelligence-based models outperform conventional methods?

Yes. The CNN model outperformed both index-based and traditional machine learning approaches, achieving stable accuracy under varying atmospheric conditions ($\kappa = 0.61$; $P = 0.90$; QADI = 0.020). Its robustness and automatable workflow make it the most reliable technique for operational IEW detection.

7. Are Sentinel-1 radar images alone suitable for reliable delineation of water-covered areas?

Yes, but with limited accuracy. Radar data proved suitable for detecting water surfaces but were sensitive to surface roughness, vegetation, and speckle noise. The average accuracy ($\kappa = 0.30$; F1 = 0.32) was lower than that of optical or fused datasets, yet radar information remained essential during cloudy periods.

8. Does the integration of Sentinel-1 and Sentinel-2 datasets improve IEW detection?

Yes. The integration of multispectral and radar imagery increased both spatial and temporal coverage. Harmonization to 10 m resolution and combining the time series extended the monitoring window from 63 to 214 days, enabling near-continuous observation of inundation dynamics.

9. Do fused datasets enhance the accuracy of inland excess water frequency maps?

Yes. Fusion of optical and radar data improved the accuracy and detail of frequency maps. The 214-day series allowed differentiation between permanent, medium, and temporary inundations, producing a more dynamic representation of flood vulnerability than static maps.

10. Is there a measurable relationship between inundation extent and duration?

Yes. Statistical analysis revealed a significant positive correlation between inundation area and persistence. Larger inundations lasted longer, while smaller ones receded faster. The relationship was strongest in low-lying areas, rice-field basins, and closed micro-depressions.

11. Does integrating static and dynamic variables improve prediction accuracy?

Yes. Combining static (topographic, soil, land use, anthropogenic) and dynamic (meteorological) variables significantly enhanced model accuracy. The XGBoost model produced reliable short-term (1–2 weeks) predictions, with SHAP analysis identifying previous water coverage (WATER, IEWSUM) as the most influential predictors.

12. Can a machine learning-based operational prediction system be developed for lowland inland excess water monitoring?

Yes. A modular prediction system was developed, integrating Sentinel-1 and Sentinel-2 data for short-term (1–2 week) IEW forecasting and spatial visualization. The system is automatable, effective for operational applications, and serves as a decision-support tool for water management and local planning.

8. KÖSZÖNETNYILVÁNÍTÁS

Köszönetemet fejezem ki témavezetőimnek, Dr. habil. Van Leeuwen Boudewijn vezető kutatónak és Dr. Tobak Zalán egyetemi adjunktusnak, akik szakmai útmutatásaikkal támogatták és segítették doktori értekezésem elkészítését. Különösen nagyra értékelem, hogy nemcsak szakmai, hanem emberi támogatásukkal is folyamatosan fenntartották motivációm. Hálás vagyok a rám fordított időért, energiáért és a kérdéseimre adott mindig segítőkész válaszaikért.

Köszönettel tartozom az SZTE egykori Geoinformatikai, Természet- és Környezetföldrajzi Tanszék munkatársainak és oktatóimnak, akik szakmai kérdésekben nyújtott tanácsaikkal és az eredmények értékelésében adott segítségükkel hozzájárultak a dolgozat elkészítéséhez. Köszönöm továbbá a tanszék infrastrukturális eszközeinek használatát is.

Hálásan köszönöm a Magyar Agrár- és Élettudományi Egyetem (MATE) Környezettudományi Intézet (KÖTI) Öntözési és Vízgazdálkodási Kutatóközpont (ÖVKI) munkatársainak szakmai támogatását, akikhez mindig bizalommal fordulhattam, és akik sok terhet levéve a vállamról nagyban segítettek a dolgozat határidőre történő elkészültét.

A kutatást a MATE KÖTI ÖVKI „18K020007 – Mezőgazdasági vízgazdálkodás fejlesztését (öntözéses gazdálkodás, belvízgazdálkodás, földhasználat racionalizálás) célzó kutatások” című témája, valamint „A Kulturális és Innovációs Minisztérium ÚNKP-23-3 kódszámú Új Nemzeti Kiválóság Programja – a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával” támogatta.

Külön köszönet illeti Dr. Bozán Csabát és Dr. Túri Norbertet, akik építő észrevételeikkel, kritikáikkal és szakmai tanácsaikkal jelentős mértékben hozzájárultak a dolgozat tudományos színvonalához. Köszönöm továbbá, hogy lehetőséget biztosítottak az ÖVKI eszközeinek és infrastruktúrájának használatára a doktori tanulmányaim során.

Végül, de nem utolsósorban szeretném szívből megköszönni családomnak – gyermekeimnek, Lilinek és Bazsának, valamint páromnak, Kócsi Zsuzsannának – a végtelen türelmüket és szeretetüket, amellyel támogatták munkámat. Köszönöm Édesanyámnak és testvéreimnek, Gábornak és Barbarának a rendületlen biztatást és segítséget, amely sok erőt adott a kitartáshoz

9. IRODALOMJEGYZÉK

- Abadi M., Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G.S., Davis A., Dean J., Devin M. 2015. TensorFlow: Large-scale machine learning on heterogeneous systems. Elérhető online: <https://arxiv.org/pdf/1603.04467.pdf>, p. 19. (hozzáférés dátuma:2025.08.23.)
- Abraham T.H. 2002. (Physio)logical circuits: The intellectual origins of the McCulloch–Pitts neural networks. *J. Hist. Behav. Sci.*, 38: 3–25. <https://doi.org/10.1002/jhbs.1094>
- Ahmad A., Quegan S. 2012. Analysis of Maximum Likelihood classification on multispectral data. *Applied Mathematical Sciences*, 6(129), 6425–6436.
- Allagwail S., Gedik O.S., Rahebi J. 2019. Face Recognition with Symmetrical Face Training Samples Based on Local Binary Patterns and the Gabor Filter. *Symmetry*. 11(2): p. 22. <https://doi.org/10.3390/sym11020157>
- Al-Najjar H. A. H., Pradhan B., Beydoun G., Sarkar R., Park H.-J., Alamri A. (2023). A novel method using explainable artificial intelligence (XAI)-based Shapley Additive Explanations for spatial landslide prediction using time-series SAR dataset. *Gondwana Research*, 123, 107–124. <https://doi.org/10.1016/j.gr.2022.08.004>
- Alzubaidi A., Laith J. Z., Amjad J. H., Ayad A., Ye D., Omran A., Santamaria J., Mohammed A.F., Muthana A., Laith F. 2021. Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions, *Journal of Big Data* 8(1). p. 74. <https://doi.org/10.1186/s40537-021-00444-8>
- Asselman N.E.M., Middelkoop H. 1995. Floodplain sedimentation: Quantities, patterns and processes. 20(6): 481–499. <https://doi.org/10.1002/esp.3290200602>
- Awange J. L., Kyalo Kiema J. B. 2013. Environmental Science and Engineering, Environmental Geoinformatics, Image Interpretation and Analysis, Chapter 10, 145–155. <https://doi.org/10.1007/978-3-642-34085-7>
- Balázs B. 2010. Belvizes területek felmérése geoinformatikai módszerekkel, *Geoinformatika és domborzatmodellezés: A HunDEM 2009 és a GeoInfo 2009 konferencia és kerekasztal válogatott tanulmányai*, Miskolc, Hungary, Hegedűs, A., 1–10.
- Balázs B. 2015. Belvív-veszélyeztetettség vizsgálata alföldi mintaterületeken. Doktori disszertáció, Debreceni Egyetem, Debrecen, Hungary, p. 157. <https://dea.lib.unideb.hu/bitstreams/910e6a63-f4d9-48f4-96c1-3a489aff66b2/download> (hozzáférés dátuma:2025.08.23.)
- Balázs B., Bíró T., Dyke G., Singh S.K., Szabó Sz. 2018. Extracting water-related features using reflectance data and principal component analysis of Landsat images, *Hydrological Sciences Journal*, 63(2): 269–284. <https://doi.org/10.1080/02626667.2018.1425802>
- Balogh E. 2009. Szakirodalmi áttekintés a hazai belvizekről, *Hidrológiai Közlöny*, 89(4): 53–55.
- Balogh P. 2001. Az ártéri tájgazdálkodás koncepciója. *Földrajzi közlemények*, 125(3–4): 249–270.
- Balogh P. 2003. Javaslat A Közép-Tiszaí Árterek És Hullámterek Használatára. Tisza-völgyi tájváltozások Kisújszállás. p.11
- Bangira T., Iannini L., Menenti M., Van Niekerk A., Vekerdy Z. 2021. Flood extent mapping in the Caprivi floodplain using sentinel-1 time series. *IEEE Journal of selected topics in applied earth observations and remote sensing*, 14: 5667–5683. <https://doi.org/10.1109/JSTARS.2021.3083517>
- Barta K., Bata T., Benyhe B., Miograd B., Viktor D., Dragan D., Farsang A., Gál N., Henits L., Juhász L., Kiss T., Kovács F., Mezősi G., Mucsi L., Mészáros M., Đorđe O., Dragoslav P., Rakonczai J., Stevan S., Sipos Gy., Sümeghy B., Szatmári J., Szilassi P., Tobak Z., Miloš Ž., Van Leeuwen B. 2013. Belvív. In: Mezősi, G. (szerk.), *Tájváltozás a Kárpát-medencében* (pp. 57–97).
- Barta K., Szatmári, J. 2010. Antropogén hatások a belvív-képződésben. Esettanulmány az M5 autópálya szatymazi szakaszának talajvízáramlásban betöltött szerepéről. *Hidrológiai Közlöny*, 90(2), 23–25.
- Barta K., Szatmári J., Van Leeuwen B., Blanka V., Kovács F., Ladányi Z., Mezősi G., Rakonczai, J. 2021. A felszínközeli vízkészletek monitoringjának lehetőségei a szélsőséges vízháztartási helyzetek (aszály, belvív) értékelésének szolgálatában / Possibilities of monitoring near-surface water resources for the purpose of the assessment of extreme water management, *Léggör: az országos meteorológiai intézet szakmai tájékoztatója* 66:4 pp. 4–12.
- Bartholy J., Pongrácz R., Pieczka I., Torma. Cs. 2011. Dynamical downscaling of projected 21st century climate for the Carpathian Basin, *Climate change – Research and technology for adaptation and mitigation*, Croatia, Blanco J.; Rijeka, Croatia, 3–22. ISBN 978-953-307-621-8.
- Belgiu M., Drăguț L. 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* 114: 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Benyhe B. 2013. Agrogén hatásra kialakuló felszínformák és folyamatok vizsgálata eltérő geomorfológiai adottságú területeken. PhD disszertáció, Szegedi Tudományegyetem, p. 120. https://doktori.bibl.u-szeged.hu/id/eprint/1699/1/benyhe_balazs_disszertacio.pdf (hozzáférés dátuma:2025.08.23.)
- Bezdan A., Bezdan J., Marković M., Mirčetić D., Baumgertel A., Salvai A., Blagojević B. 2025. An objective methodology for waterlogging risk assessment based on the entropy weighting method and machine learning. *Catena*, 249, 108618. <https://doi.org/10.1016/j.catena.2024.108618>

- Bezdan J., Bezdan A., Blagojević B., Antić S., Greksa A., Milić D., Lipovac A. 2024. Impact of climate change on extreme rainfall events and pluvial flooding risk in the Vojvodina region (North Serbia). *Atmosphere*, 15(4), 488. <https://doi.org/10.3390/atmos15040488>
- Bihari Z., Babolcsai Gy., Bartholy J., Ferenczi Z., Gerhátné Kerényi J., Haszpra L., Homokiné Ujváry K., Kovács T., Lakatos M., Németh Á., Pongrácz R., Putsay M., Szabó P., Szépszó G. V. 2018. Éghajlat. In Magyarország nemzeti atlasza: természeti környezet. In: Kocsis, K.; (főszerk.) Magyar Tudományos Akadémia, Csillagászati és Földtudományi Kutatóközpont, Földrajztudományi Intézet, Budapest, Hungary, pp. 58-69, ISBN 978-963-9545-56-4
- Bijeesh T. V., Narasimhamurthy K. N. (2020). Surface water detection and delineation using remote sensing images: A review of methods and algorithms. *Sustainable Water Resources Management*, 6(4), 68. <https://doi.org/10.1007/s40899-020-00425-4>
- Birinyi E., Lakatos B. O., Belényesi M., Kristóf D., Hetesi Zs., Mrekva L., Mikus G. 2023. Contribution of data-driven methods to risk reduction and climate change adaptation in Hungary and beyond. *Időjárás*, 127(4), 421–446. <https://doi.org/10.28974/idojaras.2023.4.1>
- Birinyi E., Kristóf D., Kern A. 2024. Possibilities of radar-based inland excess water mapping in Google Earth Engine during the single-satellite Sentinel-1 era for a study area in Hungary. In *IGARSS 2024 – IEEE International Geoscience and Remote Sensing Symposium Proceedings* (pp. 1–5). IEEE. <https://doi.org/10.1109/IGARSS53475.2024.10640894>
- Bíró T., Thyll Sz., Tamás J., Lénárt Cs. 2000. Térinformatikai módszerek alkalmazása a belvív-veszélyeztetettség térképezésében. In: Magyar Hidrológiai Társaság XVIII. Országos Vándorgyűlése (pp. 754–759). Veszprém: Magyar Hidrológiai Társaság.
- Bíró T. 2017. Amikor sok víz van a területen – belvív. Magyar tudomány: a Magyar Tudományos Akadémia Értesítője. 178: 1216-1227. <https://doi.org/10.1556/2065.178.2017.10.5>
- Bogárdi J. 1944. A lefolyási tényező és a levezetendő belvízmennyiség. *Vízügyi Közlemények*, 1944. évi kötet. Budapest, pp. 6-62.
- Bogdánfy Ö. 1906. A természetes vízfolyások Hidraulikája, II. kötet Frankiin-Társulat, Budapest, p. 285.
- Bozán Cs., Takács K., Körösparti J., Laborczy A., Túri N., Pásztor L. 2018. Integrated spatial assessment of inland excess water hazard on the Great Hungarian Plain. *Land Degrad Dev.* 29: 4373-4386. <https://doi.org/10.1002/ldr.3187>
- Bozán Cs., Körösparti J., Túri N., Kerezsi Gy., Kajári B. 2019. AKK Belvízi veszélyeztetettség felülvizsgálata, Készült VIZITERV Environ Kft. megbízásából, 83 p + térkép mellékletek.
- Bozán Cs., Körösparti J., Túri N., Kerezsi Gy., Kajári B. 2021. AKK Belvízi veszélyeztetettség felülvizsgálata Stratégiai forgatókönyvek, Készült VIZITERV Environ Kft. megbízásából, Tudományos, 144 p.
- Bravó-López E., Del Castillo T.F., Sellers C., Delgado-García J. 2022. Landslide Susceptibility Mapping of Landslides with Artificial Neural Networks: Multi-Approach Analysis of Backpropagation Algorithm Applying the Neuralnet Package in Cuenca, Ecuador. *Remote. Sensing*, 14: 3495. <https://doi.org/10.3390/rs14143495>
- Breiman L. 2001. Random Forests. *Machine Learning*, 45: 5–32, <https://doi.org/10.1023/A:1010933404324>
- Breiman L. 2003. Statistical Challenges in Astronomy. *Random Forests: Finding Quasars*, 10.1007/b97240 (Chapter 16), 243–254. https://doi.org/10.1007/0-387-21529-8_16
- Bulla B. 1954. Általános természeti földrajz. II. kötet. A földfelszín formáinak ismerete (Geomorfológia.) Tankönyvkiadó. Budapest. p 325.
- Chen T., Guestrin C. 2016. Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785-794. <https://doi.org/10.1145/2939672.2939785>
- Cian F., Delgado Blasco J. M., Ivanescu C. 2024. Improving rapid flood impact assessment: An enhanced multi-sensor approach including a new flood mapping method based on Sentinel-2 data. *Journal of Environmental Management*, 369, 122326. <https://doi.org/10.1016/j.jenvman.2024.122326>
- Connors R.W., Trivedi M.M., Harlow C.A. 1984. Segmentation of a high-resolution urban scene using texture operators, *Computer Vision, Graphics, and Image Processing*, Volume 25 (3): 273-310, [https://doi.org/10.1016/0734-189X\(84\)90197-X](https://doi.org/10.1016/0734-189X(84)90197-X)
- Cooper S., Ryan P. T. 1975. Data collection system: Earth Resources Technology Satellite-1 (No. LC-74-600160), p. 127.
- Corbane C., Syrris V., Sabo F. 2021. Convolutional neural networks for global human settlements mapping from Sentinel-2 satellite imagery. *Neural Comput és Applic*, 33: 6697–6720. <https://doi.org/10.1007/s00521-020-05449-7>
- Cortes, C., Vapnik, V. 1995. Support-Vector Networks. *Machine Learning*, 20: 273-297. <http://dx.doi.org/10.1007/BF00994018>
- Csendes B., Mucsi L. 2016. Inland excess water mapping using hyperspectral imagery. *Geographica Pannonica*, 20(4): 191-196. <https://doi.org/10.5937/GeoPan1604191C>
- Csorba P. 2021. Magyarország kistájai, Meridián Táj- és Környezetföldrajzi Alapítvány, Debrecen, Hungary, ISBN 978-963-89712-4-1, pp. 12-150.
- De Ville B. 2013. Decision trees. *Wiley Interdisciplinary Reviews: Computational Statistics*, 5(6): 448-455. <https://doi.org/10.1002/wics.1278>
- den Besten N., Steele-Dunne S., Jeu R., van der Zaag P. 2021. Towards Monitoring Waterlogging with Remote Sensing for Sustainable Irrigated Agriculture. *Remote Sensing*, 13(15): 2929, <https://doi.org/10.3390/rs13152929>
- Devi M. S., Chib S. 2019. Classification of Satellite Images Using Perceptron Neural Network, *International Journal of Computational Intelligence Research*, Volume 15(1): 1-10. ISSN 0973-1873
- Domokos M., Fehér F., Kárpátné Radó D. 1978. Belvízkár-összefüggések. *Vízügyi Közlemények*, 60(3): 401-426.

- Dong J., Zeng W., Wu L., Huang J., Gaiser T., Srivastava A.K. 2023. Enhancing short-term forecasting of daily precipitation using numerical weather prediction bias correcting with XGBoost in different regions of China. *Engineering Applications of Artificial Intelligence*, 117: 105579. <https://doi.org/10.1016/j.engappai.2022.105579>
- Dövényi Z., Ambrózy P., Juhász Á., Marosi S., Mezősi G., Michalkó G., Somogyi S., Szalai Z., Tiner T. 2010. Magyarország kistájainak katasztere. Földrajztudományi Kutatóintézet, Budapest, pp. 23-289.
- Drusch M., Del Bello U., Carlier S., Colin O., Fernandez V., Gascon F., Meygret A. 2012. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sens. Environ.*, 120: 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Du Y., Zhang Y., Ling F., Wang Q., Li W., Li X. 2016. Water bodies' mapping from Sentinel-2 imagery with Modified Normalized Difference Water Index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sens.* 8: 354–373. <https://doi.org/10.3390/rs8040354>
- Dunka S., Fejér L., Vágás I. 1996. A veritékes honfoglalás. A Tisza-szabályozás története. MKVM, Budapest, 12p.
- Fehér F., Horváth J., Ondruss L. 1986. Területi vízrendezés. Műszaki Könyvkiadó, Budapest, p. 312.
- Feizizadeh B., Darabi S., Blaschke T., Lakes T. 2022. QADI as a New Method and Alternative to Kappa for Accuracy Assessment of Remote Sensing-Based Image Classification. *Sensors*, Basel, Switzerland. 22. <https://doi.org/10.3390/s22124506>
- Fiala K., Kiss T. 2004. Mederváltozások és következményeik vizsgálata az Alsó-Tiszán. In Gábor B., Gábor D., János R. (Eds.), II. Magyar Földrajzi Konferencia Kiadványa. Szeged, pp. 443-451.
- Forgó L. 1967. Az 1966. évi téli-tavaszi belvízvédkezés az Alsótiszavidéki Vízügyi Igazgatóság működési területén, *Hidrológiai Közlöny*, 47(1): 24-40.
- Frantz D., Haß E., Uhl A., Stoffels J., Hill J. 2018. Improvement of the Fmask algorithm for Sentinel-2 images: Separating clouds from bright surfaces based on parallax effects, *Remote Sensing of Environment*, 215: 471-481, <https://doi.org/10.1016/j.rse.2018.04.046>
- Fukao T., Barrera-Figueroa B.E., Juntawong P., Peña-Castro J.M. 2019. Submergence and Waterlogging Stress in Plants: A Review Highlighting Research Opportunities and Understudied Aspects, *Frontiers in Plant Science*, 10, p. 24. <https://doi.org/10.3389/fpls.2019.00340>
- Fülöp J. 1989. Bevezetés Magyarország geológiájába. Akadémiai Kiadó.
- Gál N., Farsang A. 2013. Weather Extremities and Soil Processes: Impact of Excess Water on Soil Structure in the Southern Great Hungarian Plain. In: Loczy D., Ed., *Geomorphological Impacts of Extreme Weather*, Springer, Berlin, 313-325. https://doi.org/10.1007/978-94-007-6301-2_20
- Gál N., M. Tóth T., Földes T., Farsang A. 2015. Modellezett vízelöntés talajszerkezetre gyakorolt hatásának komputertomográfiás vizsgálata. *Agrokémia és Talajtan*, 64(1): 13-27.
- Gál N., M. Tóth T., Raucsik B., Földes T., Farsang A. 2017. Effects of inland excess water on bulk density and clay mineralogy of a chernozem soil using xrt and xrd techniques, *Carpathian Journal of Earth and Environmental Sciences*, 12(1): 189-196.
- Gálya B., Riczu P., Blaskó L., Tamás J. 2016. Belvíz érzékenység vizsgálata radar adatok alapján. In *Theory Meets Practice in GIS*; Balázs B., Ed.; University of Debrecen, Debrecen, Hungary. pp. 161-168.
- Gillyén J. 1910. Hidrológiai tanulmányok. *Vízügyi Közlemények*, XXVII.füzet. Budapest, pp. 1-20.
- Giulia C., De Fioravante P., Dichicco P., Congedo L., Marchetti M., Munafò M. 2023. Land Cover Mapping with Convolutional Neural Networks Using Sentinel-2 Images: Case Study of Rome. *Land*, 12(4): 879. <https://doi.org/10.3390/land12040879>
- Goodfellow I., Bengio Y., Courville A. 2016 *Deep Learning*. The MIT Press, 800 p, Elérhető online: <http://www.deeplearningbook.org> (hozzáférés dátuma:2025.08.23.)
- Gorelick N., Hancher M., Dixon M., Ilyushchenko S., Thau D., Moore R. 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sens. Environ.*, 202: 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Graham N. D., Refsgaard A. 2001. MIKE SHE: A distributed, physically based modelling system for surface water/groundwater interactions. *Modflow 2001 and Other Modeling Odysseys-Conference Proceedings*, Colorado, pp. 321–327.
- Graupe D. 2013. *Principles of Artificial Neural Networks*, 3rd ed., World Scientific Publishing Company, University of Illinois, Chicago, USA. p 384, <https://doi.org/10.1142/8868>
- Gudmann A., Mucsi L., Henits L. 2019. A CORINE felszínborítási térkép automatikus előállításának lehetősége döntéshozatali segítségével. *Geodézia és Kartográfia* 71(2): 9-13.
- Gulácsi A., Kovács F. 2019. Radaralapú vizesélőhely-monitoring Sentinel-1 adatokkal. *Hidrológiai Közlöny*, 99: 38-47.
- Hagolle O., Huc M., Desjardins C., Auer S., Richter R. 2017. MAJA's ATBD, p. 40. <https://doi.org/10.5281/zenodo.1209633>
- Hanqiu Xu. 2006. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery, *International Journal of Remote Sensing*, 27(14): 3025-3033, <https://doi.org/10.1080/01431160600589179>
- Haralick R.M., Shanmugam K., Dinstein I.H. 1973. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, 6: 610-621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Hartányi L. 1959. Vízháztartási vizsgálatok a Kondorosvölgyi minta belvízgyűjtő területén. *Hidrológiai Közlöny*, 1959/5. Budapest, pp. 326-339.

- Hasan I., Liu W., Xu C. 2023. Monitoring and Analyzing the Seasonal Wetland Inundation Dynamics in the Everglades from 2002 to 2021 Using Google Earth Engine. *Geographies*, 3: 161-177. <https://doi.org/10.3390/geographies3010010>
- Hinton G., Deng L., Yu D., Dahl G. E., Mohamed A. R., Jaitly N., Senior A., Vanhoucke V., Nguyen P., Sainath T. N., Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6), 82–97. <https://doi.org/10.1109/MSP.2012.2205597>
- Hird J.N., DeLancey E.R., McDermid G.J., Kariyeva J. 2017. Google Earth Engine, Open-Access Satellite Data, and Machine Learning in Support of Large-Area Probabilistic Wetland Mapping. *Remote Sens.*, 9: 1315. <https://doi.org/10.3390/rs9121315>
- Houk E.E., Frasier M., Schuck E.C. 2006. The agricultural impacts of irrigation induced waterlogging and soil salinity in the Arkansas Basin. *Agricultural Water Management*, 85: 175-183. <https://doi.org/10.1016/j.agwat.2006.04.007>
- Howard J., Gugger S. Fastai 2020. A layered API for Deep Learning. *Information*, 11(2): 108. <https://doi.org/10.3390/info11020108>
- Huang C., Davis L.S., Townshend J.R.G. 2002. An assessment of support vector machines for land cover classification, *International Journal of Remote Sensing* 23(4): 725-749, <https://doi.org/10.1080/01431160110040323>
- Huang S., Tang L., Hupy J.P., Wang Y., Shao G. 2020. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32: 1-6. <https://doi.org/10.1007/s11676-020-01155-1>
- James T., Schillaci C., Lipani A. 2021. Convolutional neural networks for water segmentation using sentinel-2 red, green, blue (RGB) composites and derived spectral indices, *International Journal of Remote Sensing*, pp. 5338-5365. <https://doi.org/10.1080/01431161.2021.1913298>
- Jiang W., He G., Long T., Ni Y., Liu H., Peng Y., Lv K., Wang G. 2018. Multilayer Perceptron Neural Network for Surface Water Extraction in Landsat 8 OLI Satellite Images. *Remote Sensing*, 10: 755. <https://doi.org/10.3390/rs10050755>
- Jin Y., Liu X., Chen Y., Liang X. 2018. Land-cover mapping using Random Forest classification and incorporating NDVI time-series and texture: a case study of central Shandong, *International Journal of Remote Sensing* 39(23): 8703-8723. <https://doi.org/10.1080/01431161.2018.1490976>
- John S., Varghese A.O. 2022. Analysis of support vector machine and maximum likelihood classifiers in land cover classification using Sentinel-2 images. *Proc.Indian Natl. Sci. Acad.* 88: 213-227. <https://doi.org/10.1007/s43538-022-00078-1>
- Jong P., Hobma F. 2012. Rights and responsibilities in Dutch land-use planning aimed at flood protection and prevention of waterlogging, In 6th International Conference of the International Academic Association on Planning, Law and Property Rights, School of the Built Environment, University of Ulster, Belfast, UK, 7-10 February, p. 16.
- Kajári B., Van Leeuwen B. 2021. Belvíz detektálása felhővel borított multispektrális műholdképeken In: Molnár, Vanda Éva (szerk.) *Az elmélet és a gyakorlat találkozása a térinformatikában XII.: Theory meets practice in GIS Debrecen*, Magyarország: Debreceni Egyetemi Kiadó 360 p., 137-145.
- Kajári B., Bozán Cs., Van Leeuwen B. 2022a. Belvíz idősoros elemzése konvolúciós neurális hálózattal Sentinel-2-es műholdfelvételeken In: Abriha-Molnár, Vanda Éva (szerk.) *Az elmélet és a gyakorlat találkozása a térinformatikában XIII.* Debrecen, Magyarország: Debreceni Egyetemi Kiadó, 177-183.
- Kajári B., Bozán Cs., Van Leeuwen B. 2022b. Monitoring of Inland Excess Water Inundations Using Machine Learning Algorithms. *Land*, 12: 36. <https://doi.org/10.3390/land12010036>
- Kajári B., Bozán Cs., Van Leeuwen B. 2023. Belvívelöntés detektálása Sentinel-1-es műhold felvételeken GLCM textúrák és konvolúciós neurális hálózat segítségével. *Az elmélet és a gyakorlat találkozása a térinformatikában XIV.: Theory meets practice in GIS Debrecen*, Debrecen, Magyarország, In: Abriha-Molnár V. É. (szerk.), Debreceni Egyetemi Kiadó, 93-101.
- Kajári B., Tobak Z., Túri N., Bozán Cs., Van Leeuwen B. 2024a. Prediction of Inland Excess Water Inundations Using Machine Learning Algorithms. *Water*, 16(9): 1267. <https://doi.org/10.3390/w16091267>
- Kajári B., Van Leeuwen B. 2024b. Sentinel-1 és Sentinel-2 felvételek belvízveszélyeztetettségi idősoros elemzése konvolúciós neurális hálózatokkal. *GEODÉZIA ÉS KARTOGRAFIA* (0016-7118), 76(1), 10-16.
- Kajári B., Túri N., Körösparti J., Bozán Cs., Van Leeuwen B. 2024c. Belvíz tartósság elemzése Sentinel műholdfelvételeken konvolúciós neurális hálózatokkal előállított belvív-gyakorisági térkép alapján. In: Somlyódy B., Váradi J., Dobó K., Göncz B., Lénárt L., Sütő L., Bíró T., Darabos P., Kassai Zs., Engloner A., Szalma E., Baranya S., Kozák P. (szerk.) *A Magyar Hidrológiai Társaság által rendezett XLI. Országos Vándorgyűlés dolgozatai.* Magyar Hidrológiai Társaság, Szolnok. pp. 1–9.
- Kamarás M. 1977. A meliorálásra szoruló területek kárjelenségei, in Szabó János (szerk.): *A melioráció kézikönyve*, Mezőgazdasági Kiadó, Budapest, pp 45-61.
- Kenessey B. 1930. Lefolyási tényezők és retenciók. *Hidrológiai tanulmány.* *Vízügyi Közlemények*, 12: 55-76.
- Keve G., Nováky B. 2010. Klímaváltozás hatásának vizsgálata a Bácsbokodi-Kígyós csatorna vízgyűjtőjén Budyko modell alkalmazásával. *A Magyar Hidrológiai Társaság XXVIII. Országos Vándorgyűlése* (Sopron, 2010. július 7-9.), p. 18.
- Kienitz G. 1970. A belvízszállás-leképezés gyakorlati felhasználásának kérdései. *Vízügyi Közlemények*, 52(4): 457-473.
- Kienitz G. 1972a. A belvízrendezés hidrológiai alapjai kutatásának kritikai fejlődéstörténete, *VITUKI*, Budapest, p. 66.
- Kienitz G. 1972b. A mirhó-gyolcsi kísérleti belvízöblözlet és a belvízkutatás eredményei. *VITUKI Tanulmányok és Kutatási Eredmények*, 30. Budapest.
- Kienitz G. 1972c. A terméseredmények és a vízrendezés kapcsolata *Vízügyi Közlemények* 54: 144-149.

- Kienitz G. 1974. A síkvidéki, befolyásolt összegyűlekezési folyamat hidrológiai modellje. A modell leírása. VITUKI Tanulmányok és kutatási eredmények, Budapest. 42/A szám,
- Koncsos L. (szerk.) 2011. Jövőképtől a vízkészlet kockázatig, Budapesti Műszaki és Gazdaságtudományi Egyetem, Vízi Közmű és Környezetmérnöki Tanszék, Budapest, ISBN 978-963-313-060-5, p. 268.
- Kontur I. 1983. Belterületen keletkező felszíni víz számítása. Vízügyi Közlemények, 65(3): 399-417
- Korbély J. 1915. Az árvizekről. Vízügyi Közlemények, 1915. évi 1. és 2. füzet. Budapest, pp. 1-34.
- Kovács F. 2004. Környezeti változások értékelése a Duna-Tisza közén, különös tekintettel a szárazodás problémájára. In A magyar földrajz kurrens eredményei: II. Magyar Földrajzi Konferencia / Táj, tér, tervezés: Geográfus Doktoranduszok VIII. Országos Konferenciája. pp. 1046-1072.
- Kozák P. 2003. Az alföldi belvizek elvezetése. Hidrológiai Közöny. 83(1): 51–61.
- Kozák P. 2005. The general characteristics of excess surface waters in the Lower Tisza Region, Hungary: Bibliogr.: 83. p. In: Acta Universitatis Szegediensis: acta geographica, (38). pp. 75-83.
- Kozák P. 2006. A Belvízjárás Összefüggései az Alföld Délkeleti Részén, Különös Tekintettel a Vízkárelhárítás Európai Igényeire Ph.D. Disszertáció, Szegedi Tudományegyetem, Szeged, Hungary, p. 86., <https://doktori.bibl.u-szeged.hu/id/eprint/1679/3/Disszert%C3%A1ci%C3%B3.pdf> (hozzáférés dátuma:2025.08.23.).
- Kozák P. 2009. Belvízi kockázat térképezés végrehajtásának eddigi tapasztalatai. MHT 27. Országos Vándorgyűlés, Baja, ISBN 978-963-8172-23-5, p. 8.
- Kozák P. 2011. Belvízi jelenségek az Alsó-tiszai vízgyűjtőkön az 1955–2010 közötti időszakban. Nagyalföld Alapítvány Kötetek, 7, 227–236.
- Kozák P., Magyar K., Fiala K. 2024.: Vízet a tájba... In: Somlyódy B., Váradi J., Dobó K., Göncz B., Lénárt L., Sütheő L., Bíró T., Darabos P., Kassai Zs., Engloner A., Szalma E., Baranya S., Kozák P. (szerk.): A Magyar Hidrológiai Társaság által rendezett XLI. Országos Vándorgyűlés dolgozatai. Magyar Hidrológiai Társaság, Szolnok, pp. 1–17.
- Kozma Zs. 2013. Belvízi szélsőségek kockázatalapú értékelésének és modellezési módszertanának fejlesztése. Doktori értekezés (PhD), Budapesti Műszaki és Gazdaságtudományi Egyetem, Budapest, p. 160. <http://hdl.handle.net/10890/5576> (hozzáférés dátuma:2025.08.23.)
- Kozma Zs., Jolánkai Z., Kardos M. K., Muzelák B., Koncsos L. 2022. “Adaptive Water Management-land Use Practice for Improving Ecosystem Services – a Hungarian Modelling Case Study”, Periodica Polytechnica Civil Engineering, 66(1): 256–268, <https://doi.org/10.3311/PPci.18369>
- Kozma Zs., Decsi B., Ács T., Kardos M. K., Hidy D., Árvai M., Kalicz P., Kern Z., Pinke Z. 2023. Supposed effects of wetland restoration on hydrological conditions and the provisioning ecosystem services—A model-based case study at a Hungarian lowland catchment. Sustainability, 15(15), 11700. <https://doi.org/10.3390/su151511700>
- Körösparti J., Kajári B., Kerecsi Gy., Túri N., Pásztor L., Bozán Cs. 2022. A területhasználat racionalizálásának hatása Magyarország síkvidéki területeinek belváz-veszélyeztetettségére, JOURNAL OF CENTRAL EUROPEAN GREEN INNOVATION, 10 (Suppl). pp. 21-37. ISSN 2064-3004
- Kriegler F., Malila W., Nalepka R., Richardson W. 1969. Preprocessing transformations and their effect on multispectral recognition. Proceedings of the 6th International Symposium on Remote Sensing of Environment, Ann Arbor, MI: University of Michigan, 97-131.
- Krizhevsky A., Sutskever I., Hinton G. E. 2012. ImageNet classification with deep convolutional neural networks. In Pereira F., Burges C. J. C., Bottou L., Weinberger K. Q. (Eds.), Advances in Neural Information Processing Systems (Vol. 25). Curran Associates, Inc. <https://doi.org/10.1145/3065386>
- Ku M., Jiang H., Jia K., Dai X., Xu J., Li D., Wang C., Qin B. 2024. Cropland Inundation Mapping in Rugged Terrain Using Sentinel-1 and Google Earth Imagery: A Case Study of 2022 Flood Event in Fujian Provinces. Agronomy, 14: 138. <https://doi.org/10.3390/agronomy14010138>
- Kun Á., Barta K., Katona O. 2012. Az M43-as autópálya által indukált 2010–11-es belváz talajtani hatásai. A VI. Magyar Földrajzi Konferencia, a MERIEXWA nyitókonferencia és a Geográfus Doktoranduszok Országos Konferenciájának Tanulmánykötete, 483-494.
- Kupidura P. 2019. The Comparison of Different Methods of Texture Analysis for Their Efficacy for Land Use Classification in Satellite Imagery, Remote Sensing 11(10). <https://doi.org/10.3390/rs11101233>
- Kuti L., Kerék B., Vatai J. 2006. Problem and prognosis of excess water inundation based on agrogeological factors. Carpth. J. of Earth and Environmental Sciences, 1(1): 5-18.
- Laborczy A., Bozán Cs., Körösparti J., Szatmári G., Kajári B., Túri N., Kerecsi G., Pásztor L. 2020. Application of hybrid prediction methods in spatial assessment of inland excess water hazard. ISPRS International Journal of Geo-Information, 9(4): 268. <https://doi.org/10.3390/ijgi9040268>
- Lászlóffy W. 1982. A Tisza: vízi munkálatok és vízgazdálkodás a tiszai vízrendszerben. Budapest, Akadémiai Kiadó Zrínyi. 609.p.
- LeCun Y., Boser B., Denker S. J., Henderson D., Howard E.R., Hubbard W., Jackel D. L. 1990. Handwritten Digit Recognition with a Back-Propagation Network, In D. Touretzky (Ed.), Advances in Neural Information Processing Systems (NIPS 1989), Denver, CO (Vol. 2). Morgan Kaufmann, pp. 396-403.
- LeCun Y., Bengio Y., Hinton G. 2015. Deep learning. Nature, 521: 436-444. <https://doi.org/10.1038/nature14539>
- Lee H., Calvin K., Dasgupta D., Krinner G., Mukherji A., Thorne P., Trisos C., Romero J., Aldunce P., Barrett K., Blanco G. 2023. Climate change 2023: synthesis report. Contribution of working groups I, II and III to the sixth assessment

- report of the intergovernmental panel on climate change. Geneva, Switzerland, pp. 35-115. <https://doi.org/10.59327/IPCC/AR6-9789291691647>
- Li Y., Zeng H., Zhang M., Wu B., Zhao Y., Yao X., Cheng T., Qin X., Wu F. 2023. A county-level soybean yield prediction framework coupled with XGBoost and multidimensional feature engineering. *International Journal of Applied Earth Observation and Geoinformation*, 118, 103269. <https://doi.org/10.1016/j.jag.2023.103269>
- Liska Cs. M., Mucsi L., Henits L. 2017. Hosszútávú felszínborítás-változások vizsgálata Csongrád megyében idősoros adatok felhasználásával, Random Forest módszerrel. *Földrajzi Közlemények*, 141(1): 71-83.
- Louis J., Devignot O., Pessiot L. 2021. L2A Product Definition Document. Ref. S2-PDGS-MPC-L2A-PDD-V14.9. European Space Agency. Elérhető online: <https://step.esa.int/thirdparties/sen2cor/2.10.0/docs/S2-PDGS-MPC-L2A-PDD-V14.9-v4.9.pdf>, p. 39. (hozzáférés dátuma:2025.06.20.)
- Lundberg M., Su-In L. 2017. A unified approach to interpreting model predictions. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, California, USA, 4768-4777, <https://doi.org/10.48550/arXiv.1705.07874>
- Mahdavi S., Salehi B., Granger J., Amani M., Brisco B., Huang W. 2018. Remote sensing for wetland classification: A comprehensive review. *GISci. Remote Sens.* 55: 623-658. <https://doi.org/10.1080/15481603.2017.1419602>
- Mahdianpari M., Rezaee M., Zhang Y., Salehi B. 2018. Wetland Classification Using Deep Convolutional Neural Network, *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, pp. 9249-9252, <https://doi.org/10.1109/IGARSS.2018.8517919>
- Maksimović V., Lekic P., Petrovic M., Jakšić B., Spalevic P. 2019. Experimental analysis of wavelet decomposition on edge detection. *Proceedings of the Estonian Academy of Sciences*, 68: 284. <https://doi.org/10.3176/proc.2019.3.06>
- Mall P. K., Singh P. K., Yadav D. 2019. "GLCM Based Feature Extraction and Medical X-RAY Image Classification using Machine Learning Techniques," 2019 IEEE Conference on Information and Communication Technology, Allahabad, India, pp. 1-6, <https://doi.org/10.1109/CICT48419.2019.9066263>
- Matta E., Amadori M., Free G., Giardino C., Bresciani M. 2022. A Satellite-Based Tool for Mapping Evaporation in Inland Water Bodies: Formulation, Application, and Operational Aspects. *Remote Sensing*, 14(11): 2636. <https://doi.org/10.3390/rs14112636>
- McFeeters S. K., 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features, *International Journal of Remote Sensing*, 17(7): 1425-1432, <https://doi.org/10.1080/01431169608948714>
- Mermoz S., Le Toan T., Bouvet A. 2021. Sentinel-1 for observing forests in the tropics – SOFT final report (Version 2.0, SOFT_FR_202104_v2.0). European Space Agency, p. 38.
- Mezősi G., Meyer B.C., Loibl W., Aubrecht C., Csorba P., Bata T. 2013. Assessment of regional climate change impacts on Hungarian landscapes. *Reg. Environ. Chang.* 13: 797-811. <https://doi.org/10.1007/s10113-012-0326-1>
- Mezősi G., Bata T., Blanka V., Ladányi Z. 2017. A Klímaváltozás hatása a környezeti veszélyekre az Alföldön'. *Földrajzi Közlemények* 141(1): 60-70
- Ming D., Zhou T., Wang M., Tan T. 2016. Land cover classification using random forest with genetic algorithm-based parameter optimization. *J. Appl. Remote Sens.* 10(3): p. 16. <https://doi.org/10.1117/1.JRS.10.035021>
- Molnár V. A., Lukács B. 2014. Belvizes szántók. Átok vagy áldás?. *Élet és Tudomány*. 69: 454-456.
- Morales-Olmedo M., Ortiz M., Sellés G. 2015. Effects of transient soil waterlogging and its importance for rootstock selection. *Chilean Journal of Agricultural Research*, 75(Suppl. 1). pp. 45-56 <https://doi.org/10.4067/S0718-58392015000300006>
- Mosonyi E. 1954. Országos Vízgazdálkodási Keretters. A Magyar Tudományos Akadémia Műszaki Tudományok Osztályának Közleményei, XIV (4): 393-423.
- Mucsi L., Henits L. 2011. Belvízelöntési térképek készítése közepes felbontású űrfelvételek szubpixel alapú osztályozásával. *Földrajzi Közlemények*, 135(4): 365-378.
- Mucsi L., Bui D. H. 2023. Evaluating the performance of multi-temporal synthetic-aperture radar imagery in land-cover mapping using a forward stepwise selection approach. *Remote Sensing Applications: Society and Environment*, 30, 100975. <https://doi.org/10.1016/j.rsase.2023.100975>
- Mullissa A., Vollrath A., Odongo-Braun C., Slagter B., Balling J., Gou Y., Gorelick N., Reiche J. 2021. Sentinel-1 SAR Backscatter Analysis Ready Data Preparation in Google Earth Engine, *Remote Sens.* 13, 1954. <https://doi.org/10.3390/rs13101954>
- Nasirzadehdizaji R., Balik Sanli F., Abdikan S., Cakir Z., Sekertekin A., Ustuner M. 2019. Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. *Applied Sciences*. 9(4): 655. <https://doi.org/10.3390/app9040655>
- Nováky B. 1988. A műszaki-hidrológiai jellemzők térképi bemutatásának módszertani kérdései. *Hidrológiai Közlöny*, 68(4): 193-207.
- O'Brien R. M. 2007. A caution regarding rules of thumb for variance inflation factors. *Quality és Quantity: International Journal of Methodology*, 41(5): 673-690. <https://doi.org/10.1007/s11135-006-9018-6>
- Orlóczi I., Schlegel O. 1967. Jelentősebb belvízvédkezéseink összehasonlító értékelése. Oroszlány I. 1963. Vízgazdálkodás a mezőgazdaságban, Mezőgazdasági Kiadó, Budapest, pp 109-128
- Otukei J. R., Blaschke T. 2010. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12(1), S27-S31. <https://doi.org/10.1016/j.jag.2009.11.002>

- Pálfa I. 1979. Csongrád megye vízrendezésének fejlesztése. Hidrológiai Közlöny. 12: 561-565.
- Pálfa I. 1981. Síkvidéki területek vízrendezésének értékelése. Összefoglaló az 1981. évi kerettervi vizsgálatokról. Kézirat, Szeged: Országos Vízügyi Hivatal.
- Pálfa I. 1982. A belvízi veszélyeztetettség területi mutatója. In: Magyar Hidrológiai Társaság III. Országos Vándorgyűlése, I. kötet, pp. 385–390.
- Pálfa I. 1985. A síkvidéki vízrendezés időszéri kérdései. Vízügyi Közlemények, 67(3), 257–268.
- Pálfa I. 1987. A belvíz-veszélyeztetettség mértékének meghatározása. Hidrológiai Tájékoztató, 1987. október. pp. 13-15.
- Pálfa I. 1988. A mértékadó belvízhozam számítási módszerei. VMGT 165. VGI, Budapest, pp. 17-25.
- Pálfa I. 1989. A belvízi veszélyeztetettség és a természeti tényezők kapcsolata. In: Magyar Hidrológiai Társaság VIII. Országos Vándorgyűlése, V. kötet. Nyíregyháza: Magyar Hidrológiai Társaság. pp 1-28.
- Pálfa I. 1994. Az Alföld belvíz-veszélyeztetettségi térképe, Vízügyi közlemények, 76(3): 278-290.
- Pálfa I. 2000. Az Alföld belvízi veszélyeztetettsége és aszályossága. In: A víz szerepe és jelentősége az Alföldön (pp. 85–96). Békéscsaba: Nagyalföld Alapítvány.
- Pálfa I. 2001. A belvíz definíciói. Vízügyi Közlemények, 83(3): 376-392.
- Pálfa I. 2003. Magyarország belvíz-veszélyeztetettségi térképe. Vízügyi Közlemények, 85: 510-524.
- Pálfa I. 2004. Belvizek és aszályok Magyarországon: hidrológiai tanulmányok. Budapest, Közlekedési dokumentációs Kft., 492 p., ISBN 963 552 382 3
- Pálfa I. 2013. Vízháztartási szélsőségek a Kárpát-medencében. Hidrológiai Közlöny, 93(2): 9-12.
- Parajuli J., Fernandez-Beltran R., Kang J., Pla F. 2022. Attentional Dense Convolutional Neural Network for Water Body Extraction From Sentinel-2 Images, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15: 6804-6816. <https://doi.org/10.1109/JSTARS.2022.3198497>
- Paszke A., Gross S., Massa F., Lerer A., Bradbury J., Chanan G., Killeen T., Lin Z., Gimelshein N., Antiga L., Desmaison A., Köpf A., Yang E., DeVito Z., Raison M., Tejani A., Chilamkurthy S., Steiner B., Fang L., Bai J., Chintala S. 2019. PyTorch: An Imperative Style, High-Performance Deep Learning Library. Cornell University, Elérhető online: <https://arxiv.org/pdf/1912.01703v1.pdf>, p.12. (hozzáférés dátuma:2025.08.23.)
- Pásztor L., Körösparti J., Bozán Cs., Laborci A., Takács K. 2015. Spatial Risk Assessment of Hydrological Extremities: Inland Excess Water Hazard, Szabolcs-Szatmár-Bereg County, Hungary, Journal of Maps, 11(4): 636–44. <https://doi.org/10.1080/17445647.2014.954647>
- Pásztor L., Laborci A., Bozán Cs., Körösparti J., Szatmári G., Kajári B., Túri N., Kerezsi Gy. 2020. Application of Hybrid Prediction Methods in Spatial Assessment of Inland Excess Water Hazard. ISPRS Int. J. Geo-Inf. 9: 268. <https://doi.org/10.3390/ijgi9040268>
- Patay I., Montvajszi M. 2011. Belvíztestek matematikai modellezése. Hidrológiai Közlöny, 91: 45–49.
- Pécze Gy. 1998. Éghajlat, Nemzeti Tankönyvkiadó, Budapest, pp 258-282.
- Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V. 2011. Scikit-learn: Machine Learning in Python. J. Mach. Learn. Res., 12: 2825–2830. <https://doi.org/10.48550/arXiv.1201.0490>
- Persico G., Seyoum W.M., Peterson E.W. 2024. Interrelationships Between NDVI, Surface Water, and Regional Hydro-Climatic Variables in the Sudd Wetland. Wetlands 44: 92. <https://doi.org/10.1007/s13157-024-01851-2>
- Petravits I. 1959. A növények víztűrőképességéről. Hidrológiai Közlöny, 39. évf. 4. pp. 285-288.
- Petravits I., Szalai Gy. 1986. A mezőgazdasági vízgazdálkodás hosszú távú fejlesztését megalapozó előrejelzés. Vízügyi Közlemények, 68(4): 462-477.
- Pinke Z. 2012. Aszály-, belvízkárok és az árvízvédelmi ökoszisztéma szolgáltatás értékelésének szerepe a belvizes területek vizes élőhelyé alakításában. TÁJÖKÖLÖGIAI LAPOK JOURNAL OF LANDSCAPE ECOLOGY, 10(2): 271-286.
- Ponce V.M. 1989. Engineering Hydrology: Principles and Practices, Prentice Hall: Englewood Cliffs, NJ, USA, Volume 640, Elérhető online: http://ponce.sdsu.edu/330textbook_hydrology_chapters.html (hozzáférés dátuma:2025.08.23.).
- Pritt M., Chern G. 2017. Satellite Image Classification with Deep Learning," 2017 IEEE Applied Imagery Pattern Recognition Workshop (AIPR), pp. 1-7, <https://doi.org/10.1109/AIPR.2017.8457969>
- Puskás I., Gal N., Farsang A. 2012. Impact of weather extremities (excess water, drought) caused by climate change on soils in Hungarian Great Plain (SE Hungary). Review of Climate Change Research Program at the University of Szeged. 73-88.
- Rahman S., Rahman S. H., Ullah M. W. 2010. Assessment of water-logging extent using RS and GIS techniques and its possible remedial measures at the Kopotaksho Basin area, Bangladesh. In H. Calado; A. Gil (Eds.), Geographic technologies applied to marine spatial planning and integrated coastal zone management, pp. 112–119. ISBN 978-972-8612-64-1
- Rakonczai J., Bódis K. 2001. A geoinformatika alkalmazása a környezeti változások kvantitatív értékelése. Magyar Földrajzi Konferencia kiadványa, p. 18.
- Rakonczai J., Mucsi L., Szatmári J., Kovács F., Csátó Sz. 2001. A belvizes területek elhatárolásának módszertani lehetőségei. A földrajz eredményei az új évezred küszöbén. A Magyar Földrajzi Konferencia Tudományos Közleményei (CD), Szeged, p. 14.
- Rakonczai J., Csátó Sz., Mucsi L., Kovács F., Szatmári J. 2003. Az 1999. és 2000. évi alföldi belvíz-elöntések kiértékelésének gyakorlati tapasztalatai. Vízügyi Közlemények, 85(4. különszám): 317-336.

- Rakonczai J., Kovács F. 2009. Környezeti változások komplex értékelése az Alföldön földrajzi, geoinformatikai és távérzékelési módszerekkel. Munkabeszámoló. OTKA, p. 10p.
- Rakonczai J., Farsang A., Mezösi G., Gál N. 2011. A belvízképződés elméleti háttere. Földrajzi közlemények, 135(4): 339-349.
- Rawat K. S., Singh S. K., Ray R. L., Szabó Sz. (2020). Parameterization of the Modified Water Cloud Model (MWC) using Normalized Difference Vegetation Index (NDVI) for winter wheat crop: a case study from Punjab, India. *Geocarto International*. 37. 1-14. <https://doi.org/10.1080/10106049.2020.1783579>
- Restrepo J.I., Montoya A.M., Obeysekera J. 1998. A wetland simulation module for the Modflow groundwater model. *Groundwater*, 36(5): 764–770, <https://doi.org/10.1111/j.1745-6584.1998.tb02193.x>
- Richards J., Jia X. 2006. Remote sensing digital image analysis, 4th ed., Heidelberg, springer, Germany, 359-388. <https://doi.org/10.1007/3-540-29711-1>
- Ronneberger O., Fischer P., Brox T. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab N., Hornegger J., Wells W., Frangi A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015, Lecture Notes in Computer Science, vol 9351. Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28, p. 8.
- Rosenblatt F. 1958. "The perceptron, a probabilistic model for information storage and organization in the brain," *Psych. Rev.*, 65: 386–408.
- Rouse J.W., Haas R.H., Schell J.A., Deering D.W. 1973. Monitoring Vegetation Systems in the Great Plains with ERTS (Earth Resources Technology Satellite). *Proceedings of 3rd Earth Resources Technology Satellite Symposium, Greenbelt*, 10-14 december, SP-351, 309-317.
- Sahoo S., Setia R., Sahoo S., Prasad A., Pateriya B. 2015. Evaluation of NDWI and MNDWI for assessment of waterlogging by integrating digital elevation model and groundwater level. *Geocarto International* 30(1): 49–69. <https://doi.org/10.1080/10106049.2014.965757>
- Salamin P. 1942. Tanulmány a hazai belvízrendezésről. *Hidrológiai Közlöny*, 22. évf. 1-6. szám, pp. 76-122
- Salamin P. 1955. A belvízrendezés tervezési vezérfonala. Kézirat, Budapest.
- Salamin P. 1956. A belvízrendszerek tervezésének néhány kérdése. *Hidrológiai Közlöny*, 36. évf., 5. szám, pp. 342-350.
- Salamin P. 1966. Vízrendezések I. Síkvidéki vízrendezés. Tankönyvkiadó, Budapest, pp. 147-150
- Salvai A., Santrač N., Stajić M., Antić S., Zemunac R., Benka P., Bezdan A., Vranešević M. 2023. Mapping of inland excess water using geographical information system and high-resolution satellite images: A case study of Srem, Serbia. *Ecol. Chem. Eng. S*, 30(3), 343–355. <https://doi.org/10.2478/eces-2023-0037>
- Sheykhoum M., Mahdianpari M., Ghanbari H., Mohammadimanesh F., Ghamisi P., Homayouni S. 2020. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 6308-6325. <https://doi.org/10.1109/JSTARS.2020.3026724>
- Simón Sánchez A-M., González-Piqueras J., de la Ossa L., Calera A. 2022. Convolutional Neural Networks for Agricultural Land Use Classification from Sentinel-2 Image Time Series. *Remote Sensing*, 14(21):5373. p. 23. <https://doi.org/10.3390/rs14215373>
- Sisodia P. S., Tiwari V., Kumar A. 2014. Analysis of Supervised Maximum Likelihood Classification for remote sensing image, *International Conference on Recent Advances and Innovations in Engineering (ICRAIE-2014)*, pp. 1-4, <https://doi.org/10.1109/ICRAIE.2014.6909319>
- Slagter B., Tsendbazar N-E., Vollrath A., Reiche J. 2020. Mapping wetland characteristics using temporally dense Sentinel-1 and Sentinel-2 data: A case study in the St. Lucia wetlands, South Africa, *International Journal of Applied Earth Observation and Geoinformation*, Volume 86, 102009, ISSN 1569-8432, p. 11. <https://doi.org/10.1016/j.jag.2019.102009>
- Somlyódy L. 2011. Magyarország vízgazdálkodása: helyzetkép és stratégiai feladatok. Budapest: Magyar Tudományos Akadémia, Köztisztületi Stratégiai Programok, p. 345.
- Spanoudaki K., Stamou A. I., Nanou-Giannarou A. 2009. Development and verification of a 3-D integrated surface water-groundwater model. *Hydrology*, 375(3-4): 410–427. <https://doi.org/10.1016/j.jhydrol.2009.06.041>
- Strahler A.H. 1980. The Use of Prior Probabilities in Maximum Likelihood Classification of Remotely Sensed Data. *Remote Sensing of Environment*, 10, 135–163. [https://doi.org/10.1016/0034-4257\(80\)90011-5](https://doi.org/10.1016/0034-4257(80)90011-5)
- Szatmári J., Tobak Z., Van Leeuwen B., Dolleschall J. 2011. A belvízelöntések térképezését megalapozó adatgyűjtés és a belvízképződés modellezése neurális hálózattal. *Földrajzi Közlemények*, 135(4): 351-364.
- Szatmári J. 2013. Modellek a geoinformatikában. Szegedi Tudományegyetem, Debreceni Egyetem, Pécsi Tudományegyetem. TÁMOP-4.1.2.A/1-11/1 MSc Tananyagfejlesztés. 48p.
- Szatmári J., Van Leeuwen, B. 2013. Inland Excess Water - Belvív - Suvišne Unutrašnje Vode, Szegedi Tudományegyetem: Szeged, Hungary, Újvidéki Egyetem: Újvidék, Srbija, p. 154.
- Szigarski C., Jagdhuber T., Baur M., Thiel C., Parrens M., Wigneron J-P., Piles M., Entekhabi D. 2018. Analysis of the Radar Vegetation Index and Potential Improvements. *Remote Sensing*, 10(11): 1776. <https://doi.org/10.3390/rs10111776>
- Szilassi P. 2015. Területrendezési tervek, mint a belvív elleni védekezés eszközei magyarországon. *4D Tájépítészeti és Kertművészeti Folyóirat*, 48-61.

- Szinay M. 2009. Belvízreform tanulmány. In: Vélemények az Országos Vízügytőlgazdálkodási Terv 2009. augusztus 31-én közzétett kéziratából. http://www2.vizeink.hu/files/vizeink.hu_0525_belvizreform_tanulmany_szina_ymiklos.pdf, p. 24. (hozzáférés dátuma:2025.08.23.).
- Thyll Sz., Fehér F., Madarassy L. 1983. Mezőgazdasági talajcsövezés. Mezőgazdasági Kiadó, Budapest, p. 321.
- Thyll Sz. 1994. Síkvidéki vízrendezés, (In: Vermes (szerk.) Vízgazdálkodás Mezőgazdasági Szaktudás Kiadó. Budapest, pp. 197-241.
- Thyll Sz., Bíró T. 1999. A belvív-veszélyeztetettség térképezése. Vízügyi Közlemények, 81(4): 709-717.
- Tobak Z., Szatmári J., Van Leeuwen B. 2008. Small Format Aerial Photography-Remote Sensing Data Acquisition for Environmental Analysis, Journal of Env. Geogr, 3(4): 21–26. <https://doi.org/10.14232/jengeo-2008-43861>
- Tóth B., Weynants M., Pásztor L., Hengl T. 2017. 3D soil hydraulic database of Europe at 250 m resolution. Hydrological Processes, 31: 2662–2666. <https://doi.org/10.1002/hyp.11203>
- Török I. Gy. 1997. „Eszmetörések” a belvív fogalmának korszerűbb értelmezése és a belvízvédekezés gazdaságossága tárgyában. MHT. XV. Országos Vándorgyűlés, Kaposvár, pp. 554-557.
- Trümmér Á. 1942. Belvízrendezésünk fontosabb feladatai. Mezőgazdasági Közlöny, 2., Budapest,
- Tsitsi B., Iannini L., Menenti M., Van Niekerk A., Vekerdy Z. 2021. Flood Extent Mapping in the Caprivi Floodplain Using Sentinel-1 Time Series, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 14: 5667–83. <https://doi.org/10.1109/JSTARS.2021.3083517>
- Tso B., Mather P. 2009. Classification Methods for Remotely Sensed Data, Second Edition, CRC Press, 376 p. <https://doi.org/10.1201/9781420090741>
- Túri N., Körösparti J., Bozán Cs., Kun Á., András G. 2016. Talajvízszintek hosszú idősoros észlelési eredményeinek elemzése Magyarország síkvidéki területein. In Szabó, A. K., Erdeiné Késmárki-Gally Sz., Ölvedi-Vázsonyi M., Várallyay É. (Szerk.), Kutatói utánpótlást elősegítő program I. szakmai konferenciája: Publikációk (pp. 100-105). Nemzeti Agrárkutatási és Innovációs Központ (NAIK), Gödöllő, Magyarország.
- Túri N., Körösparti J., Kajári B., Kerezi G., Zain M., Rakonczai J., Bozán Cs. 2022. Spatial assessment of the inland excess water presence on subsurface drained areas in the Körös Interfluve (Hungary), Agrokémia és Talajtan, 71(1): 23-42. doi: <https://doi.org/10.1556/0088.2022.00126>
- Ulloa N. I., Yun S-H., Chiang S-H., Furuta R. 2022. Sentinel-1 spatiotemporal simulation using Convolutional LSTM for flood mapping. Remote Sensing, 14(2), 246. <https://doi.org/10.3390/rs14020246>
- Vajdai I. 1975. A tavaszi időszakos káros vízbőség néhány közvetlen hatása szántóföldi növénytermesztésben, Kandidátusi értekezés, Gödöllő. 195p.
- Valipour M. 2014. Drainage, waterlogging, and salinity, Archives of Agronomy and Soil Science, 60(12): 1625-1640, <https://doi.org/10.1080/03650340.2014.905676>
- van Houdt G., Mosquera C., Nápoles G. 2020. A review on the long short-term memory model. Artif Intell Rev, 53: 5929–5955. <https://doi.org/10.1007/s10462-020-09838-1>
- Van Leeuwen B., Tobak Z., Szatmári J. 2008. Development Of An Integrated ANN-GIS Framework For Inland Excess Water Monitoring. Journal of Environmental Geography, 1(3-4): 1-6. <https://doi.org/10.14232/jengeo-2008-43858>
- Van Leeuwen B. 2012. Mesterséges neurális hálózatok és földrajzi információs rendszerek használata a belvízosztályozásban. Doktori (PhD.) értekezés, Szegedi Tudományegyetem, Szeged. 111p. https://doktori.bibl.u-szeged.hu/id/eprint/1520/3/ThesesHU_BvL.pdf (hozzáférés dátuma:2025.08.25.).
- Van Leeuwen B., Henits L., Mészáros M., Tobak Z., Szatmári J., Pavić D., Savić S., Dolinaj D. 2013. Classification methods for inland excess water modeling. Journal of Environmental Geography, 6(1-2): 1-8. <https://doi.org/10.2478/v10326-012-0001-5>
- Van Leeuwen B., Právetz T., Liptay Z., Tobak Z. 2016. Physically based hydrological modelling of inland excess water. Carpathian journal of earth and environmental sciences. 11: 497-510.
- Van Leeuwen B., Tobak Z., Kovács F., Sipos Gy. 2017. Towards a continuous inland excess water flood monitoring system based on remote sensing data. Journal of Environmental Geography, 10(3-4): 9-15. <https://doi.org/10.1515/jengeo-2017-0008>
- Van Leeuwen B., Tobak Z., Kovács F. 2020. Sentinel-1 and-2 Based near Real Time Inland Excess Water Mapping for Optimized Water Management, Sustainability 12(7). p21 <https://doi.org/10.3390/su12072854>
- Várallyay Gy., Szűcs L., Rajkai K., Zilahy P., Murányi, A. 1980. Magyarországi talajok vízgazdálkodási tulajdonságainak kategóriarendszere és 1:100 000 méretarányú térképe. Agrokémia és Talajtan, 29(1-2): 77–112.
- Várallyay Gy. 2005. Magyarország talajainak vízraktározó képessége. Agrokémia és Talajtan, 54(1-2), 5-24.
- Várallyay Gy. 2008. talajdegradációs folyamatok és szélsőséges talaj-vízháztartási helyzetek, mint környezeti problémák a kárpát-medencében. a fenntartható fejlődés és a megújuló természeti erőforrások környezetvédelmi összefüggései a kárpát-medencében, 17., Pécs. 17-26.
- Várallyay Gy. 2017. A szélsőséges vízháztartási helyzetek (árvíz, belvív – aszály) talajtani okai és következményei. In Kubovics, I., Póka T., Weidinger T. (Szerk.), A talajtakaró geonómiája: A pedoszféra mint a Föld sajátos fázishatára (pp. 41–61). ELTE TTK Meteorológiai Tanszék.
- Varga O. G., Kovács Z., Bekő L., Burai P., Csátáriné Szabó Zs., Holb I., Ninsawat S., Szabó Sz. 2021. Validation of visually interpreted Corine Land Cover classes with spectral values of satellite images and machine learning. Remote Sensing, 13(5), 857. <https://doi.org/10.3390/rs13050857>

- Vári Á., Tanács E., Tormáné Kovács E., Kalóczkai Á., Arany I., Czúcz B., Bereczki K., Belényesi M., Csákvári E., Kiss M. 2022. National Ecosystem Services Assessment in Hungary: Framework, Process and Conceptual Questions. Sustainability, 14: 12847. <https://doi.org/10.3390/su141912847>
- Vermes L. (szerk.) 2001. Vízgazdálkodás mezőgazdasági, kertész-, tájépítész- és erdőmérnök hallgatók részére. Mezőgazdasági Szaktudás Kiadó, Budapest. Vízügyi Közlemények, 49(1): 51-71.
- Vremec M., Collenteur R. A., Birk S. 2024. PyEt v1.3.1: a Python package for the estimation of potential evapotranspiration, Geosci. Model Dev., 17: 7083-7103, <https://doi.org/10.5194/gmd-17-7083-2024>.
- Wallender W.W., Tanji K.K. 2011. Agricultural Salinity Assessment and Management, American Society of Civil Engineers (ASCE): Reston, Virginia. 825 – 853, <https://doi.org/10.1061/9780784411698>
- Wang M., Li Y., Yuan H., Zhou S., Wang Y., Ikram R.M.A., Li J. 2023. An XGBoost-SHAP approach to quantifying morphological impact on urban flooding susceptibility. Ecological Indicators, 156, p. 111137. <https://doi.org/10.1016/j.ecolind.2023.111137>
- Wen Z., Zhang C., Shao G., Wu S., Atkinson P.M. 2021. Ensembles of multiple spectral water indices for improving surface water classification, International Journal of Applied Earth Observation and Geoinformation, 96. 102278. 13, pp. <https://doi.org/10.1016/j.jag.2020.102278>.
- Worden J., de Beurs K. M. 2020. Surface water detection in the Caucasus. International Journal of Applied Earth Observation and Geoinformation, 91, 102159. <https://doi.org/10.1016/j.jag.2020.102159>
- Xu H. 2005. A study on information extraction of water body with the modified normalized difference water index (MNDWI). Int. J. Remote Sens., 5: 589–595, <http://doi.org/10.11834/jrs.20050586>
- Xu H.Q. 2006. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. Int. J. Remote Sens., 27: 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Yao J., Cai Z., Qian Z., Yang B. 2023. A novel approach based on TCN–LSTM network for predicting waterlogging depth with waterlogging monitoring station. PLOS ONE, 18(10), e0286821. <https://doi.org/10.1371/journal.pone.0286821>
- Yeung E., van Veen H., Vashisht D., Sobral Paiva A. L., Hummel M., Rankenberg T., Steffens B., Steffen-Heins A., Sauter M., de Vries M., Schuurink R. C., Bazin J., Bailey-Serres J., Voesenek L. A. C. J., Sasidharan R. 2018. A stress recovery signaling network for enhanced flooding tolerance in Arabidopsis thaliana. Proceedings of the National Academy of Sciences of the United States of America, 115(26), E6085–E6094. <https://doi.org/10.1073/pnas.1803841115>
- Yichen L., James T., Schillaci C., Lipani A. 2022. Snow Detection in Alpine Regions with Convolutional Neural Networks: Discriminating Snow from Cold Clouds and Water Body, GIScience and Remote Sensing 59(1): 1321–43. <https://doi.org/10.1080/15481603.2022.2112391>
- Yilmaz O.S., Gulgen F., Balik Sanli F. 2023. The Performance Analysis of Different Water Indices and Algorithms Using Sentinel-2 and Landsat-8 Images in Determining Water Surface: Demirkopru Dam Case Study. Arab J Sci Eng., 48: 7883-7903. <https://doi.org/10.1007/s13369-022-07583-x>
- Zou Z., Dong J., Menarguez M.A., Xiao X., Qin Y., Doughty R.B., Hooker K.V., David Hambright K. 2017. Continued decrease of open surface water body area in Oklahoma during 1984–2015. Science of the Total Environment 595: 451-460. <https://doi.org/10.1016/j.scitotenv.2017.03.259>

Internetes hivatkozások:

1. Központi Statisztikai Hivatal (KSH) 2025. https://www.ksh.hu/stadat_files/mez/hu/mez0008.html (06.05.2025.)
2. Vízügy.hu 2011 <https://www.vizugy.hu/print.php?webdokumentumid=280> (06.09.2025.)
3. Központi Statisztikai Hivatal (KSH) 2024 https://www.ksh.hu/stadat_files/kor/hu/kor0040.html (03.10.2025.)
4. OVF: <https://www.ovf.hu/jobboldali-sav-tartalmi/vizetatajba/vizet-a-tajba>
5. KAP, 2025: <https://kap.gov.hu/agrookologiaiprogramAOP>
6. AM rendelet: <https://net.jogtar.hu/jogszabaly?docid=a2400017.am>
7. 1871. évi XXXIX. törvénycikk: <https://net.jogtar.hu/ezer-ev-torveny?docid=87100039.TV&searchUrl=/ezer-ev-torvenyei/%3Fpagenum%3D28>
8. MTA Magyarország Nemzeti Atlasza: <https://nemzeti-atlasz.hu/1989/MNA1989.html>
9. OMSZ adattár: https://odp.met.hu/climate/observations_hungary/daily/historical/
10. Pet számítás: <https://github.com/pyet-org/PyEt>
11. Lechner Tudásközpont DDM: <https://lechnerkozpont.hu/oldal/domborzatmodell>
12. Lechner Tudásközpont NÖSZTÉP: <https://lechnerkozpont.hu/oldal/noszttep>
13. OSM: <https://www.openstreetmap.org/#map=8/47.184/19.509>
14. Eu SoilGrids: <https://esdac.jrc.ec.europa.eu/content/3d-soil-hydraulic-database-europe-1-km-and-250-m-resolution>
15. OVF adatbázis: data.vizugy.hu
16. ArcGIS Pro deep learning modul: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/deep-learning-in-arcgis-pro.htm>
17. ArcPy: <https://pro.arcgis.com/en/pro-app/3.4/arcpy/get-started/arcpy-modules.htm>
18. PyTorch: <https://pytorch.org/>
19. TensorFlow: <https://www.tensorflow.org/>
20. Keras: <https://github.com/keras-team/keras>
21. fastai: <https://www.fast.ai/>
22. Copernicus-Sentinel-2: <https://sentinewiki.copernicus.eu/web/s2-mission>
23. Földmegfigyelési Információs Rendszer (eFöld): <https://fir.gov.hu/>

10. MELLÉKLETEK

1. Melléklet: A távérzékelési műholdak (optikai és radaros) összehasonlítása

Tulajdonság	Sentinel-2	Landsat 8	MODIS	Planet Scope	Sentinel-1
Üzemeltető	Európai Űrügynökség (ESA)	NASA, USGS	NASA (Terra, Aqua)	Planet Labs	Európai Űrügynökség (ESA)
Felbocsátás éve	2015 (Sentinel-2A) 2017 (Sentinel-2B) 2024 (Sentinel2-C)	2013	1999 (Terra), 2002 (Aqua)	2014-től folyamatos	2014 (S1A), 2016 (S1B)
Visszatérési idő	5 nap (két műholddal)	16 nap	Naponta kétszer (globális lefedettség)	Napi szinten	6 nap (két műholddal)
Térbeli felbontás	10–60 m	15–100 m	250–1000 m	~3–5 m	5–20 m
Spektrális sávok száma	13 sáv	11 sáv	36 sáv	4 sáv	VV, VH (opcionálisan HH, HV)
Fő spektrális sávok	Látható (kék, zöld, vörös), NIR, SWIR, vörös szegély	Látható, NIR, SWIR, TIR, pankromatikus	Látható, NIR, SWIR, TIR	Kék, zöld, vörös, NIR	Felszíni víz, talajnedvesség, elöntések, felszínváltozások
Tervezett élettartam	7+ év	5+ év	6 év (Terra, Aqua), de folyamatosan működik	Folyamatos	Felhő- és napszaktól független adatgyűjtés
Specialitások	Nagy térbeli felbontás és gyors visszatérési idő, ideális részletes vegetációs és felszíni vizsgálatokhoz	Hosszú távú archívum (1970-es évek óta), termikus adatok is elérhetők	Alacsony felbontás, de naponta friss globális lefedettség	Magas térbeli felbontás, napi adatok, gyors monitoring lehetőség	Magas zajszint, előfeldolgozási igény (speckle-szűrés, kalibrálás)

2. Melléklet: A Sentinel-2A és 2B műholdfelvételek sávonkénti felbontása és spektrális információi [22]

Band number	S2A Equivalent wavelength (nm)	S2A Bandwidth (nm)	S2B Equivalent wavelength (nm)	S2B Bandwidth (nm)	Radiance sensibility range $L_{min} < L_{ref} < L_{max}$ ($W \cdot m^{-2} \cdot sr^{-1} \cdot \mu m^{-1}$)	SNR (@ L_{ref})	Spatial resolution (m)
B1: Coastal Aerosol	442.7	20	442.2	20	15.97 < 129.11 < 587.87	129	60
B2: Blue	492.7	64	492.3	65	11.70 < 128.00 < 615.48	154	10
B3: Green	559.8	35	558.9	36	6.49 < 128.00 < 559.01	168	10
B4: Red	664.6	30	664.9	31	3.31 < 108.00 < 484.13	142	10
B5: Red-Edge	704.1	14	703.8	14	2.61 < 66.00 < 424.89	117	20
B6: Red-Edge	740.5	14	739.1	14	2.06 < 63.83 < 412.92	89	20
B7: Red-Edge	782.8	20	779.7	20	1.67 < 66.70 < 387.08	105	20
B8: NIR	832.9	118	832.9	115	9.52 < 129.48 < 567.06	174	10
B8a: Vegetation RE	864.7	20	864.0	21	0.95 < 52.39 < 307.80	72	20
B9: Water Vapor	945.1	20	943.2	20	0.79 < 48.09 < 232.91	75	60
B10: SWIR Cirrus	1373.5	31	1376.9	30	0.02 < 6.02 < 74.16	35	60
B11: SWIR	1613.7	91	1610.4	93	0.40 < 64.00 < 69.78	100	20
B12: SWIR	2202.4	175	2185.7	181	0.10 < 1.70 < 24.60	100	20

3. Melléklet: A Sentinel–1-es felvételekből előállított GLCM sávok Haralick et al. nyomán (1973), illetve a CNN modellben felhasznált sávok (kék) listája

GLCM sávok	Magyar jelentés – leírás
	Második szögmomentum: az ismétlődő párok számát méri.
CONTRAST	Kontraszt; a kép helyi kontrasztját méri.
CORR	Korreláció; a pixelpárok közötti korrelációt méri.
VAR	Variancia; a szürkeségi szintek eloszlásának szóródását méri.
IDM	Inverse Difference Moment: a homogenitást méri.
SAVG	Összegátlag
SVAR	Összegzett variancia
SENT	Summa entrópia
ENT	Entrópia: A szürkeségi eloszlás véletlenszerűségét méri.
DVAR	Differencia variancia
DENT	Különbség entrópia
IMCORR1	A korreláció információs mértéke. 1
IMCORR2	A korreláció információs mértéke. 2
MAXCORR	Max Corr. Coefficient. (nem számított)
DISS	Különbség
INERTIA	Tehetlenség
SHADE	Klaszterárnyék
PROM	Klaszter kiemelkedés

4. Melléklet: A bemeneti változók Víz (világoskék), Meteorológiai (lila) és Statikus (világos narancssárga) csoportokba sorolva

Változó neve	Leírás	Minimum érték	Maximum érték	Átlag érték
WATER	Víz pixelek száma a műholdas víztérképeken a központi pixel 50 m-es környezetében (9x9 kernel) t_1 időpontra	0,00	69*	16,62
IEWSUMweek1	A napok száma, amikor víz észlelhető a pixelben t_1 és t_7 között	0,00	7,00	1,92
IEWSUMweek2	A napok száma, amikor víz észlelhető a pixelben t_8 és t_{15} között	0,00	7,00	1,90
Precipitation	Napi csapadék (mm) t_0 időpontban	0,00	95,46	1,80
PET	Napi potenciális evapotranszpiráció (mm) t_0 időpontban	0,00	8,16	2,58
Wind	Napi átlagos szélesség (m/s) t_0 időpontban	0,00	7,30	2,30
PreSUMweek1	Csapadék összege t_0 és t_6 között	0,00	151,64	12,90
PreSUMweek2	Csapadék összege t_7 és t_{14} között	0,00	151,64	18,05
PETSUMweek1	Evapotranszpiráció összege t_0 és t_6 között	0,59	47,45	18,05
PETSUMweek2	Evapotranszpiráció összege t_7 és t_{14} között	0,59	47,45	18,05
WindAVGweek1	Átlagos szélesség t_0 és t_6 között	0,11	4,89	2,22
WindAVGweek2	Átlagos szélesség t_7 és t_{14} között	0,11	4,89	2,22
Road_dist	Távolság a legközelebbi út osztály pixelétől (m)	0,00	1564,16	281,5
City_dist	Távolság a legközelebbi települési osztály pixelétől (m)	0,00	8489,08	3344,08

Channel_dist	Távolság a legközelebbi csatorna osztály pixelétől (m)	0,00	1697,29	285,67
Profil	Profilgörbület (m)	-0,04	0,21	0,00
Plan	Síkgörbület (m)	-0,25	0,13	0,00
Slope	Lejtőszög fokban (ez a változó eltávolításra került)**	0,00	0,11	5,22
FC_0_30	Mezőgazdasági vízkapacitás 0-30 cm mélységben (cm ³ /cm ³)	32,50	40,25	36,26
FC_30_60	Mezőgazdasági vízkapacitás 30-60 cm mélységben (cm ³ /cm ³)	30,50	39,50	34,89
KS_0_30	Telített hidraulikus vezetőképesség 0–30 cm mélységben (cm/nap ⁻¹)	1361,5	4964,75	2895,95
KS_30_60	Telített hidraulikus vezetőképesség 30–60 cm mélységben (cm/nap ⁻¹)	468,00	5015,50	3774,94
THS_0_30	Telített víztartalom 0–30 cm mélységben (cm ³ /cm ³)	47,75	51,75	49,39
THS_30_60	Telített víztartalom 30–60 cm mélységben (cm ³ /cm ³)	45,50	49,50	47,27
LU	Földhasználati osztályok	Három legjellemzőbb osztály: 2100 – Szántó, 3400 – Zárt gyeptömörödött talajon, 6100 – Nyílt víz.		

Megjegyzés: A statisztikák a tanító adatkészlet mintáin alapulnak. *A 9×9 pixeles ablakon belül a pixelek maximális száma 69 volt a 81 helyett, mivel a gyakorisági térkép alapján az állandó víz kategória nem került be a tanító adatok közé. **A lejtésváltozót kizártam, mivel a minták mindössze 17%-ánál volt a lejtés nagyobb 0 foknál, és csak 3%-ánál haladta meg az 1 fokot.

5. Melléklet: Az ökoszisztéma alaptérkép nómenklatúrája

Ökoszisztéma alaptérkép nómenklatúra

 1 110 : Alacsony épület	 3 400 : Zárt gyepek kötött talajon vagy domb és hegyvidéken	 4 304 : Ártéren kívüli füzesek
 1 120 : Magas épület		 4 305 : Ártéren kívüli, többletvízhatás alatti nyárasok
 1 210 : Szilárd burkolatú utak	 3 500 : Máshová nem besorolható lágyszárú növényzet	 4 306 : Nyíresek
 1 220 : Földutak	 4 101 : Bükkösök	 4 307 : Többletvízhatással érintett cseresek
 1 230 : Vasutak	 4 102 : Gyertyános kocsánytalan tölgyesek	 4 308 : Egyéb, többletvízhatással érintett őshonos dominanciájú erdők
 1 310 : Egyéb burkolt vagy burkolatlan mesterséges felületek	 4 103 : Cseresek	 4 309 : Egyéb, többletvízhatással érintett elegyes lomberdők
 1 410 : Zöldfelületek mesterséges környezetben fákkal	 4 104 : Molyhos tölgyesek	 4 401 : Túlevelűek dominálta ültetvények
 1 420 : Zöldfelület mesterséges környezetben fák nélkül	 4 105 : Ny-Dunántúl erdeifenyvesei	 4 402 : Akác dominálta ültetvények
 2 100 : Szántóföldek	 4 106 : Ny-Dunántúl erdeifenyő-elegyes lomberei	 4 403 : Nemesnyár- és fűz dominálta ültetvények
 2 210 : Szőlők	 4 107 : Hazai nyárasok	 4 404 : Egyéb idegenhonos lombos fajok dominálta erdők
 2 220 : Gyümölcsösök, bogysók és egyéb ültetvények	 4 108 : Hegy- és dombvidéki pionír erdők	 4 501 : Pusztavágás
 2 230 : Energiaültetvények	 4 109 : Gyertyános kocsányos tölgyesek	 4 502 : Folyamatban lévő felújítás
 2 310 : Komplex művelési szerkezet épületekkel	 4 110 : Elegyetlen és kőriselegyes kocsányos tölgyesek	 4 600 : Máshová nem besorolható fás szárú növényzet
 2 320 : Komplex művelési szerkezet épületek nélkül	 4 111 : Egyéb, többletvízhatástól független őshonos dominanciájú erdők	 5 110 : Vízben álló mocsári/lápi növényzet
 3 110 : Nyílt homokpuszta gyepek	 4 112 : Egyéb elegyes lomberdők	 5 120 : Időszakos vízhatás alatt álló gyepek valamint láp- és mocsárrétek
 3 120 : Zárt gyepek homokon	 4 201 : Puhafás ártéri erdők	 5 200 : Láp- és mocsárerdők
 3 200 : Szikes és szikesedésre hajlamos gyepek	 4 202 : Keményfás ártéri erdők	 6 100 : Állóvizek
 3 310 : Sziklakibúvásokkal tarkított mészkedvelő gyepek	 4 301 : Elegyetlen és kőriselegyes kocsányos tölgyesek TVHA	 6 200 : Vízfolyások
 3 320 : Sziklakibúvásokkal tarkított egyéb gyepek	 4 302 : Égeresek	
	 4 303 : Többletvízhatás alatti gyertyános kocsányos tölgyesek	

6. Melléklet: A Sentinel–1 adatokon futtatott CNN modell teljesítménymutatói

GLCM sávok	F1-score (teljesítménymutatók)	Resnet
ASM:	0,39	50
CONTRAST:	0,84	50
CORR:	0,79	50
VAR:	0,68	50
IDM:	0,69	50
SAVG:	0,80	50
SVAR:	0,72	50
SENT:	0,71	50
ENT:	0,26	50
DVAR:	0,81	50
DENT:	0,76	50
IMCORR1:	0,60	50
IMCORR2:	0,28	50
MAXCORR:	0,71	50
DISS:	0,82	50
INERTIA:	0,82	50
SHADE:	0,84	50
PROM:	0,81	50
Sentinel–1 VV, VH sávokkal kombinált Contrast sáv különböző Resnet hálóval készült teljesítménymutatói		
CONTRAST:	0,70	34
CONTRAST:	0,79	50
CONTRAST:	0,69	101
Sentinel–1 VV, VH, és RVI sávokkal kombinált GLCM sávok kombinációjának teljesítménymutatói		
Contrast + ASM:	0,44	50
Contrast + CORR:	0,32	50
Contrast + VAR:	0,70	34
Contrast + VAR:	0,79	50
7 kiválasztott GLCM sáv	0,83	34
7 kiválasztott GLCM sáv	0,84	50
7 kiválasztott GLCM sáv	0,83	101