

Bevezetés

A belvízi elöntések Magyarország síkvidéki térségeiben – különösen az Alföldön – a 19. század óta visszatérő hidrológiai problémát jelentenek, amelyek jelentős gazdasági, társadalmi és környezeti hatással bírnak. A mezőgazdasági területek mintegy 1,8 millió hektárja számít belvíz által veszélyeztetettnek, és az elmúlt évtizedekben több ízben is (1999, 2000, 2010, 2013, 2015, 2016, 2018) több százezer hektárnyi elöntés fordult elő (Pálfai, 2004; Kozák, 2006; Bíró, 2017). A szélsőséges időjárási események gyakoribbá válása – különösen az intenzív csapadék és a hirtelen hóolvasás – tovább növeli a belvízi kockázatot és az operatív monitoring iránti igényt (Mezősi et al., 2017; Bezdan et al., 2024).

A belvíz kialakulását komplex természeti és antropogén tényezők együttes hatása szabályozza: a domborzat, a talajtani viszonyok, a talajvízmélység és a csatornahálózat állapota egyaránt befolyásolja az elöntések térbeli mintázatát és időtartamát (Kozák, 2005). Míg a belvíz gazdasági károkat okoz, időszakos megjelenése ökológiai és természetvédelmi szempontból is értékes, mivel hozzájárul a biodiverzitás és a táji vízmegtartás fenntartásához (Pál et al., 2006; Molnár és Lukács, 2014).

A belvíz hagyományos megfigyelése sokáig terepi méréseken és statikus veszélyeztetettségi térképeken alapult, amelyek korlátozott tér- és időbeli felbontásuk miatt nem voltak alkalmasak a dinamikus változások részletes feltárására. A modern távérzékelési és térinformatikai módszerek – különösen a Sentinel-1 radaros és Sentinel-2 multispektrális műholdfelvételek – új lehetőségeket kínálnak a felszíni vízborítás pontos és rendszeres monitorozására (Van Leeuwen, 2012; Birinyi et al., 2023).

Az elmúlt években egyre szélesebb körben alkalmazták a vízfelületek detektálására különböző spektrális indexeket (NDVI–Normalized Difference Vegetation Index, NDWI–Normalized Difference Water Index, MNDWI–Modified Normalized Difference Water Index), felügyelt osztályozási módszereket (ML–Maximum Likelihood, RF–Random Forest, SVM–Support Vector Machine) és gépi tanulási modelleket, ugyanakkor ezek érzékenyek a küszöbértékekre és a légköri feltételekre, ezért új, automatizálható megoldások iránt nőtt az igény (Chen et al., 2018; Miao et al., 2018). A legújabb kutatások szerint a mélytanulási technikák, különösen a konvolúciós neurális hálózatok (CNN–Convolutional Neural Network), alkalmasak a vízborítás nagy pontosságú és általánosítható detektálására (Szatmári et al., 2011; Simón Sánchez et al., 2022).

A kutatás célja egy komplex belvízmonitoring és előrejelző módszertan kidolgozása, amely a Sentinel-1 radaros és Sentinel-2 multispektrális műholdfelvételek integrált feldolgozásán alapul. A módszertan középpontjában a belvízfoltok pontos térbeli és időbeli lehatárolása, valamint a gyakorisági térképek előállítás és elemzése áll. E folyamatokhoz kapcsolódva olyan predikciós modell került kifejlesztésre, amely a statikus (domborzati, talajtani, földhasználati) és dinamikus (meteorológiai) tényezők integrálásával képes rövid távú (1–2 hetes) előrejelzésekre, valamint a belvíz tartósságának becslésére.

A módszertan célja, hogy hozzájáruljon a fenntartható vízgazdálkodás, a vízvisszatartási stratégiák és a döntéstámogató rendszerek fejlesztéséhez, ezáltal erősítve a klímaadaptációs törekvések tudományos alapjait a síkvidéki területeken.

Adatok és módszerek

A kutatás során egy komplex, távérzékelési és gépi tanulási alapú módszertani keretet alakítottam ki, amely a Sentinel-1 és a Sentinel-2 műholdfelvételek integrált feldolgozásán alapul. A cél a belvízfoltok megbízható detektálása, gyakorisági mintázataik feltárása és rövid távú (1–2 hetes) előrejelzése síkvidéki környezetben. Az optikai (Sentinel-2) adatokon indexalapú vízlehatárolást végeztem (NDWI, MNDWI, NDVI), majd klasszikus felügyelt gépi tanulási módszereket (ML, RF, SVM) és neurális hálózatokat (ANN, CNN) használtam a pontosság növelésére. A radaros (Sentinel-1) feldolgozásban a VV/VH polarizációk mellett RVI és GLCM textúra-mutatók kerültek számításra.

A modellezésben két bemeneti csoportot különítettem el: dinamikus (hidrometeorológiai) tényezőket – így különösen a csapadékot, hőmérsékletet, szélesebséget és a potenciális evapotranszpirációt (PET), továbbá a korábbi vízborítási állapotokat ($t-1$, $t-7$, $t-14$) –, valamint statikus (környezeti) tényezőket, ideértve a domborzati derivátumokat, a talajtani és földhasználati jellemzőket, illetve az antropogén hatásokat leíró rétegeket használtam fel a predikciós modell felépítéséhez.

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 terjedtek ki, amely 10 000 km² területet fedett le. Ez a metodikai tesztfázis lehetőséget biztosított a vízlehatárolási eljárások és feldolgozási paraméterek nagy területre vonatkozó összehasonlítására és optimalizálására, megalapozva a későbbi fejlesztési irányokat. Ezt követően

egy 82,3 km²-es részterületen történt a feldolgozási folyamatok finomítása, a paraméterek validálása és a modell tanításához szükséges adatbázisok egységesítése.

A végleges, 1600 km²-es fő mintaterület szolgált a belvízmonitoring, a gyakorisági elemzések és a predikciós modellek alapjául. A vizsgálati térség az Alföld két középtáját – a Közép-Tisza-vidéket és a Berettyó–Körös vidéket – foglalja magába, és öt kistájat érint: a Tiszafüredi–Kunhegyesi-síkot, a Nagy-Sárrétet, a Dévaványai-síkot, a Körösmenti-síkot és a Szolnoki-Türi-síkot. A térség síkvidéki jellegéből, agyagos üledékeiből és időszakosan vízzel borított mélyfekvésű területeiből adódóan ideális környezetet biztosított a belvízdetektálási és előrejelzési módszerek fejlesztéséhez és validálásához (Csorba, 2021).

A Sentinel–2 multispektrális műholdfelvételek 10–20 m térbeli felbontásban és ötnapos ismétlési idővel biztosítanak optikai információt a látható, közeli és rövidhullámú infravörös tartományban. Az elemzéshez a 13 sáv közül tízet használtam, a 20 m-es sávokat 10 m-re resample-elve az egységes feldolgozás érdekében. A felhő- és árnyékmaskolást az ESA Scene Classification Layer (SCL) alapján végeztem, a mesterséges felszíneket a NÖSZTÉP adatbázis, az állandó víztesteket manuális digitalizáció segítségével zártam ki. A vízlehatárolást indexalapú (NDWI, MNDWI, NDVI), gépi tanulási (ML, RF, SVM) és mélytanulási (ANN, CNN) módszerekkel végeztem.


A Sentinel–1 radaros adatok bevonása lehetővé tette a felhőborítottságtól független vízdetektálást és a Sentinel–2 adatok időbeli sűrítését. A vizsgálat során a C-sávú VV és VH polarizációs felvételeket használtam, valamint az ezekből származtatott Radar Vegetation Index (RVI) és Gray-Level Co-occurrence Matrix (GLCM) textúraindexeket, összesen 18 mutató előállításával. Az előfeldolgozás magában foglalta a hőzaj-eltávolítást, a radiometriai kalibrációt, a domborzati torzítás korrekcióját, valamint a Refined Lee speckle-szűrőt, amely javította a textúraelemzés megbízhatóságát. A feldolgozást a Google Earth Engine (GEE) környezetében végeztem, míg az adatintegrációt és a CNN-modellek előkészítését Jupyter Notebook és ArcPy környezetben hajtottam végre. A Sentinel–1 adatok felhasználása a felszíni visszaverődésből származtatott információk segítettek hozzá a vízfelületek térbeli lehatárolásához.

A modellek értékelését standard pontossági mutatók alapján végeztem: Overall Accuracy (OA), Kappa-index (κ), Precision (P), Sensitivity (S), F1-score és QADI (Quantity Allocation Disagreement Index). A validáció során manuálisan digitalizált vízpoligonokat használtam referenciaként, valamint a

modellek térbeli felbontásával egységesített pixel-alapú pontosságvizsgálatokat végeztem.

A Sentinel–1 és Sentinel–2 műholdfelvételek integrálása lehetővé tette a belvízfoltok kvázi-folyamatos, napi szintű nyomon követését a 2020.06.03–2021.06.02. közötti időszakban. Az előfeldolgozott adatokból CNN-alapú bináris víz/nem víz térképek készültek, ahol a víz jelenlétét 1, a száraz felszínt 0, az adathiányt –1 érték jelölte. A két adatforrás együttes alkalmazása jelentősen növelte az időbeli lefedettséget: 151 napon Sentinel–1, 32 napon Sentinel–2, míg 31 napon mindkét szenzor biztosított adatot. Az azonos napokra eső térképeket pixelszintű fúzióval egyesítettem, ahol víznek csak azokat a pixeleket tekintettem, amelyeket mindkét adatforrás előntőtként azonosított. A felhőborítottság és a radaros csempehatárok okozta hiányos értékek pótlására idősoros interpolációt alkalmaztam, legfeljebb 4 napos időablakon belül. Amennyiben ez időn belül sem állt rendelkezésre érvényes megfigyelés, az adott pixel „nem víz” értéket kapott. A módszer biztosította a folytonos idősor előállítását, amelyből a 364 napot lefedő vízborítottsági térképsorozat létrejött. Ez az integrált adatbázis képezte alapját a belvíz gyakorisági és tartóssági térképek, valamint a prediktív modellek előállításának.

A belvíz-előrejelzés céljából egy adatvezérelt predikciós modellt alakítottam ki, amely a Sentinel–1 és Sentinel–2 adatokból származó vízborítottsági térképeket statikus (talajtani, domborzati, földhasználati, antropogén) és dinamikus (meteorológiai) tényezőkkel kibővítettem (1. ábra). A modell két algoritmusra épült: a Deep Neural Network (DNN) és az Extreme Gradient Boosting (XGBoost) módszerekre, amelyek a vízborítás térbeli és időbeli valószínűségének becslését végezték. Az eredeti 24 inputparaméter közül az xAI elemzés alapján 17 bizonyult meghatározónak. A predikciók a vízborítás valószínűségi értékein alapultak, amelyek 1–2 hetes előrejelzést biztosították a belvízveszélyes területek azonosítását.



1. ábra: Előfeldolgozási és modellezési munkafolyamata Kajári et al., 2024 nyomán

A belvízelöntések tartósságának becslése a gyakorisági térképezés módszertanára épült, kiegészítve a vízborítás fennmaradásának időtartamával és a becsült vízmélységgel. Az elemzés gyakorisági térkép, valamint egy 5 m felbontású digitális domborzatmodell bevonásán alapult, amely a

mikrodomborzati mélyedések és vízgyűjtő egységek azonosítását is lehetővé tette. A domborzati és radaros paraméterek kombinációja a vízborítás térfogatának és tartósságának becslését szolgálta. Az előntések időtartamát a napi felbontású vízfedettségi térképek egymást követő összevetésével határoztam meg, így azonosíthatóvá vált, hogy egy adott terület hány napon keresztül maradt víz alatt. Az így előállított tartóssági térképek a belvízfoltok kialakulásának, fennmaradásának és visszahúzódásának dinamikáját jellemzik, hozzájárulva a hidrológiai folyamatok pontosabb értelmezéséhez, valamint a vízviszataratási potenciál és a kockázati besorolás finomításához.


Eredmények és következtetések

A vizsgálatok alapján a Sentinel-1 és Sentinel-2 adatok egyaránt alkalmasak a síkvidéki belvízelöntések detektálására, azonban eltérő erősségekkel és korlátokkal rendelkeznek. A Sentinel-2 optikai felvételek tiszta légköri körülmények között pontosabb osztályozást eredményeztek, míg a Sentinel-1 adatok előnye az időbeli folytonosságban és a felhőborítás alatti megfigyelhetőségben rejlik. A két adatforrás harmonizálása és együttes feldolgozása jelentősen növelte a térbeli és időbeli lefedettséget, így lehetővé tette a kvázi folyamatos előntés-monitoringot a teljes vizsgálati időszakban.

A Sentinel-2 multispektrális felvételek alkalmazása igazolta, hogy az optikai adatok 10 m-es térbeli és ötnapos időbeli felbontása megfelelő a belvízfoltok térbeli lehatárolásához és dinamikájuk elemzéséhez. Az indexalapú módszerek közül az MNDWI bizonyult a legpontosabbnak ($\kappa = 0,66$; $P = 0,68$; $QADI = 0,023$), ugyanakkor a küszöbértékek érzékenysége miatt korlátozott automatizálhatóságot mutatott. A gépi tanulós modellek (ML, RF, SVM) növelték az osztályozás pontosságát, közülük az SVM érte el a legstabilabb eredményt ($\kappa = 0,69$). A legjobb teljesítményt azonban a mélytanulós (CNN) modellek konzisztensen magas pontosságot értek el egyrészt a tanítás során ($F1 = 0,84$), valamint a modellezés folyamán ($\kappa = 0,61$; $P = 0,90$; $QADI = 0,020$). A modell stabil teljesítményt nyújtott változó légköri viszonyok mellett is.

A Sentinel-1 adatok feldolgozása során a VV és VH polarizációs sávok, az RVI és a GLCM textúraindexek együttes alkalmazása javította az osztályozási teljesítményt. A radaros modellek ugyanakkor érzékenyek voltak a felszín érdességére, a növényzet szerkezetére és a speckle-zajra. A pontosság jellemzően elmaradt az optikai adatokétól (átlagosan $\kappa = 0,30$; $F1 = 0,32$), de a radaros felvételek pótolhatatlan információt nyújtottak a felhőborításos időszakokban.

A Sentinel-1 és Sentinel-2 adatok integrált feldolgozása 63 napról 214 napra növelte a megfigyelési időablakot. Az integrált modell különösen a felhővel terhelt időpontokban bizonyult hatékonyabbnak, mivel a radaros adatok kiegészítették az optikai felvételek hiányzó információtartalmát. Az adatintegráció eredményeként stabilabb és részletesebb előntési térképek készültek, amelyek megbízható alapot biztosítottak az idősoros elemzésekhez és a gyakorisági térképek előállításához (2. ábra).




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

A térkép pontosan elkülönítette az állandó, közepes és ideiglenes elöntéseket, és kimutatták a magas gyakoriságú területeket, amelyek döntően a mikrodomborzati mélyedésekhez, rizszakettákhoz és vizenyős rétekhez kapcsolódtak. A gyakorisági térkép dinamikus frissíthetősége révén pontosabb és aktuálisabb képet adott a belvízveszélyeztetettségéről, mint a korábbi statikus veszélytérképek.

A belvíz-előrejelzéshez fejlesztett predikciós modellek közül a Deep Neural Network (DNN) és az Extreme Gradient Boosting (XGBoost) algoritmusokat használtam, amelyek a 24 bemeneti paraméterből az xAI-elemzés (SHAP) alapján kiválasztott 17 releváns változót vették figyelembe. A két modell hasonló pontosságot ért el (F1: 0,85 és 0,84), azonban az XGBoost számítási hatékonysága lényegesen jobb volt (18 másodperc a 102

másodperccel szemben), ezért rövid távú, 1–2 hetes előrejelzésekhez alkalmazhatóbbnak bizonyult. A DNN tanítását 0,001-es tanulási rátával, 0,0001-es decay értékkel, 10-es batch-mérettel és 100 epoch mellett optimalizáltam ($F1 = 0,84$; $\kappa = 0,68$), míg az XGBoost-modell 0,02-es tanulási rátával, 350 döntési fával és hat maximális mélységgel futott, némileg jobb teljesítménnyel ($F1 = 0,854$; $\kappa = 0,703$). Az interpretálhatóságot biztosító SHAP-elemzés kimutatta, hogy a predikciókat elsősorban a korábbi vízborítottsági jellemzők (WATER, IEWSUM) határozták meg, míg a dinamikus meteorológiai tényezők (pl. csapadék, PET) másodlagos szerepet játszottak. A statikus változók – különösen a domborzat és a talajtani jellemzők – a lokális érzékenységek leírásában bizonyultak meghatározónak. Az összehasonlító értékelés során a CNN-alapú vízdetektálás 0,84-es $F1$ -értéket ért el, míg a Sentinel-1 és Sentinel-2 modellek pontossága rendre 0,56 és 0,71 volt. Összességében a CNN-osztályozás és az XGBoost-alapú előrejelzés integrálása olyan robusztus és automatizálható módszertani keretet eredményezett, amely képes a belvízi események megbízható detektálására, 1–2 hetes előrejelzésére, és döntéstámogató rendszerként is alkalmazható a hazai vízgazdálkodási gyakorlatban.

A belvízi elöntések tartósságának vizsgálata a gyakorisági térképezés eredményeire épült, kiegészítve a vízborítás időtartamának és becsült vízmélységének elemzésével. A feldolgozás alapját a Sentinel-1 radaros és Sentinel-2 multispektrális adatok integrált idősorai, valamint egy 5 m felbontású digitális domborzatmodell képezték, amelyek együttesen lehetővé tették a mikrodomborzati mélyedések és a vízgyűjtő egységek pontos azonosítását. Az éves adatsor alapján meghatároztam, hogy a mintaterületen (3. ábra) az elöntés legnagyobb kiterjedése 3,08 ha volt, 58 napon keresztül fennmaradó vízborítással.



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

A közepes tartósságú elöntések 1,72 ha területet érintettek (68 nap), míg a legmagasabb tartóssági kategóriába sorolt vízfoltok 0,98 ha kiterjedésben 116 napon át maradtak meg. A felszíni víztérfogat-bebecslés alapján a belvíz mennyisége 1984 m³, ami átlagosan 6,4 cm-es vízmélységnek felelt meg. Az eredmények alátámasztják, hogy a kisebb kiterjedésű, de tartósan víz alatt álló területek jelentős szerepet játszanak a belvizek hidrológiai viselkedésében, és alapvető információt szolgáltatnak a mezőgazdasági károk és a vízvisszatartási potenciál térbeli értékeléséhez.

A kutatás kimutatta, hogy a vízborítás kiterjedése és időbeli tartóssága között szignifikáns, pozitív kapcsolat áll fenn, ami különösen a mélyfekvésű és lefolyástalan területeken jelentős.

A dolgozatban felállított célkitűzésekhez kapcsolódó kutatási kérdésekre az alábbi válaszok adhatók:

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

Megmutattam, hogy 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. A radaros rendszerek közül a Sentinel-1 C-sávú radarműhold nyújt térítésmentesen elérhető adatokat, amelyek a fényviszonyoktól és a felhőborítottságtól függetlenül teszik lehetővé a felszíni vízborítás detektálását, így a síkvidéki belvizek vizsgálatában nélkülözhetetlen adatforrást jelentenek.

2. Biztosítható-e a belvízelöntések megbízható lehatárolása 10 méteres terepi felbontás mellett?

Bebizonyítottam, hogy a Sentinel-2 optikai adatok 10 méteres térbeli felbontása elegendő a belvízfoltok pontos lehatárolására ($\kappa = 0,62$; $F1 = 0,62$). A Sentinel-1 radaros felvételek önállóan alacsonyabb pontosságot értek el ($\kappa = 0,30$; $F1 = 0,32$), ugyanakkor kiegészítő adatforrásként javították a térbeli és időbeli lefedettséget, különösen a felhős időszakok megfigyelése során.

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

Igazoltam, hogy a Sentinel-1 és Sentinel-2 műholdfelvételek 10 méteres térbeli felbontásra történő harmonizálása lehetővé tette a radaros és optikai adatok integrálását, ami közel napi szintű elöntés-térképek előállítását tette lehetővé. A fúziós feldolgozás növelte a megfigyelések időbeli sűrűségét, és javította a belvízdetektálás megbízhatóságát.

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

Eredményeim szerint 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 modellek (ML, RF,

SVM) javították az osztályozás pontosságát, közülük az SVM modell bizonyult a legstabilabbnak ($\kappa = 0,69$), de teljesítményük erősen függött a tanítótérületek homogenitásától és az aktuális légköri feltételektől. A mélytanulások (CNN) modell ezzel szemben konzisztensen magas pontosságot ért el ($\kappa = 0,61$; $P = 0,90$; QADI = 0,020), felhős körülmények között is stabilan működött, és jól illeszthető volt az automatizált feldolgozási láncba.

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

Igazoltam, hogy az alkalmazott módszerek idősoros elemzésre eltérő mértékben alkalmasak. Az indexalapú eljárások (NDVI, NDWI, MNDWI) minden időpontra külön küszöbérték-beállítást igényelnek, ami korlátozza az automatizálhatóságot és a módszertani konzisztenciát. A hagyományos gépi tanulások modellek (ML, RF, SVM) növelték ugyan a pontosságot, de minden új időpontra újratanítást igényeltek, és érzékenyek maradtak a légköri viszonyokra. A mélytanulások modellek – különösen a CNN – ezzel szemben megbízhatóbbnak bizonyultak az időbeli variabilitás kezelésében, és lehetőséget biztosítottak a folyamatos belvíz-monitoring megvalósítására.

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

Megmutattam, hogy 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), átlagosan magasabb precizitást ($P = 0,90$) és kiegyensúlyozottabb eredményeket biztosított, különösen felhővel terhelt felvételek esetén. A módszer automatizálható feldolgozási folyamatba illeszthető, és a legmegbízhatóbb megoldásnak bizonyult a síkvidéki belvízdetektálásban.

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

Bebizonyítottam, hogy a Sentinel-1 radaros felvételek önállóan is alkalmasak a vízborítás detektálására, ugyanakkor korlátozott pontossággal. A radaros mérések érzékenyek a felszín érdességére, a növényzet szerkezetére és a szórási zajra (speckle noise). A radaros feldolgozás átlagos pontossága ($\kappa = 0,30$; $F1 = 0,32$) alacsonyabb az optikai modellekénél,

ugyanakkor a Sentinel–1 adatok felhős időszakokban pótolhatatlan kiegészítő információt biztosítanak.

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

Megmutattam, hogy a multispektrális és radaros adatok integrációja jelentősen javította a belvízlehatárolás térbeli és időbeli lefedettségét. A 10 méteres 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. Növelhető-e a belvízi gyakorisági térképek pontossága a multispektrális és radaros adatok integrációjával?

Eredményeim szerint 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 előntéseket, valamint javították a mikrodomborzati mélyedések felismerhetőségét. A dinamikus, időben frissíthető gyakorisági térképek lényegesen pontosabb képet adnak a belvízveszélyeztetettségéről, mint a hagyományos statikus veszélytérképek, és alkalmasak az operatív kockázatbecslés és döntéstámogatás alapjául.

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

Bizonyítottam, hogy a belvízelöntések kiterjedése és időbeli tartóssága között statisztikailag szignifikáns, pozitív összefüggés áll fenn. 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, valamint a lefolyástalan mikrodomborzati mélyedésekben.

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

Bebizonyítottam, hogy a belvíz-előrejelzések pontosságát jelentősen növeli a műholdfelvételek statikus (domborzati, talajtani, földhasználati, antropogén) és dinamikus (meteorológiai) adatokkal való kiegészítése. Az XGBoost modell rövid távon (1–2 hét) megbízható előrejelzést adott, amelyet az xAI (SHAP) elemzés is alátámasztott: a predikciókat elsősorban a korábbi vízborítottsági jellemzők (WATER, IEWSUM) határozták meg, míg a

dinamikus meteorológiai tényezők (pl. potenciális evapotranszspiráció, csapadék) másodlagos szerepet játszottak. A statikus környezeti tényezők – különösen a talaj és a domborzat – kiegészítő információt nyújtottak, főként a lokális mikrodomborzati anomáliák azonosításában. E tényezők együttes figyelembevétele magas predikciós pontosságot eredményezett ($F1 = 0,84$).

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

Bebizonyítottam, hogy a kutatás során létrehozott gépi tanuláson alapuló, moduláris előrejelző rendszer alkalmas a síkvidéki belvízelőntések 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.

Az értekezés témakörében megjelent, a doktori fokozat megszerzéséhez felhasznált saját publikációk

Kajári, B.; Bozán, C.; Van Leeuwen, B.; 2023, Monitoring of Inland Excess Water Inundations Using Machine Learning Algorithms. Land, 12, 36. <https://doi.org/10.3390/land12010036>

Kajári, B.; Tobak, Z.; Túri, N.; Bozán, C.; Van Leeuwen, B.; 2024, Prediction of Inland Excess Water Inundations Using Machine Learning Algorithms. Water, 16, 1267. <https://doi.org/10.3390/w16091267>

Kajári, B.; Van Leeuwen, B.; 2024, Sentinel-1 és Sentinel-2 felvételek belvívveszélyeztetettségi idősoros elemzése konvolúciós neurális hálózatokkal. Geodézia és kartográfia, 76 (1). Pp. 10-16. Issn 0016-7118

Az értekezéshez kapcsolódó további saját publikációk

Kajári, B.; Túri, N.; Körösparti, J.; Bozán, Cs.; Van Leeuwen, B.; 2024. Belvíz tartósság elemzése Sentinel műholdfelvételeken konvolúciós neurális hálózatokkal előállított belvíz-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.

- Kajári B.; Bozán Cs.; Van Leeuwen B.; 2023. Belvízelőntés detektálása Sentinel-1-es műholdfelvételeken GLCM textúrák és konvolúciós neurális hálózat segítségével. In: Abriha-Molnár V. É. (szerk.) Az elmélet és gyakorlat találkozása a térinformatikában XIV.: Theory meets practice in GIS. Debreceni Egyetemi Kiadó, Debrecen. pp. 93–101.
- Kajári B.; Körösparti J.; Kerecsi Gy.; Túri N.; Bozán Cs.; Van Leeuwen B.; 2022. Belvíz monitorozása szegmentálással, felügyelt osztályozással és gépi tanulással Sentinel-2-es műholdfelvételeken. In: Szilávik L.; Kaszás G. (szerk.) A Magyar Hidrológiai Társaság XXXIX. Országos Vándorgyűlés dolgozatai. Magyar Hidrológiai Társaság, Budapest. pp. 19–26.
- Kajári B.; Bozán Cs.; Van Leeuwen B.; 2022. Belvíz idősoros elemzése konvolúciós neurális hálózattal Sentinel-2-es műholdfelvételeken. In: Abriha-Molnár V. É. (szerk.) Az elmélet és gyakorlat találkozása a térinformatikában XIII. Debreceni Egyetemi Kiadó, Debrecen. pp. 177–183.
- Kajári B.; Van Leeuwen B.; 2021. Belvíz detektálása felhővel borított multispektrális műholdképeken. In: Molnár V. É. (szerk.) Az elmélet és a gyakorlat találkozása a térinformatikában XII.: Theory meets practice in GIS. Debreceni Egyetemi Kiadó, Debrecen. pp. 137–145.

Summary

The occurrence of inland excess water (IEW) poses a serious challenge for agriculture and water management in the Hungarian Great Plain. Climate change, land-use intensification, and the low-lying topography increase the risk and persistence of inundations. Remote sensing and machine learning provide new opportunities for monitoring and predicting these processes more accurately than traditional approaches. This research aimed to develop a methodology that integrates Sentinel-1 radar and Sentinel-2 multispectral imagery with advanced machine learning and deep learning algorithms in order to monitor and predict IEW.

The results demonstrated that both Sentinel-1 and Sentinel-2 data are suitable for IEW detection, but with different advantages. Sentinel-2 imagery produced more accurate classifications under clear atmospheric conditions, whereas Sentinel-1 radar data ensured continuous monitoring under cloudy weather. Among the spectral indices, the Modified Normalized Difference Water Index (MNDWI) performed best, although the sensitivity of threshold values limited the robustness of index-based approaches. Supervised machine

learning algorithms such as ML, RF, and SVM provided acceptable results, however their performance was inconsistent in the presence of atmospheric disturbances.

Deep learning models, especially the Convolutional Neural Network (CNN), yielded the most accurate and consistent classifications. CNN achieved stable Kappa and precision values, while requiring minimal user intervention. Radar-based CNN models performed slightly worse than optical-based ones, but played a crucial role in filling temporal gaps caused by cloud cover. The fusion of Sentinel-1 and Sentinel-2 further improved temporal coverage and reliability, highlighting the benefits of combined data usage.

Daily inundation maps generated by CNN classification enabled the derivation of water frequency maps, which provide a dynamic and updateable alternative to traditional static hazard maps. These maps clearly distinguished between permanent and temporary water bodies and revealed areas with recurrent inundations. For predictive modelling, both Deep Neural Network (DNN) and XGBoost were tested. While their accuracy was comparable, XGBoost proved computationally more efficient, making it more suitable for operational applications.

The analysis of predictor variables confirmed that previous water occurrence and surrounding pixels with water dominated the models, while meteorological factors (precipitation, potential evapotranspiration) played a secondary role, and static environmental and soil parameters contributed only marginally. This underlines the strong temporal autocorrelation of IEW processes.

Overall, this research demonstrated that the integration of freely available satellite data and advanced machine learning algorithms offers a powerful framework for IEW monitoring and prediction. The proposed methodology can serve as a foundation for operational systems that support sustainable water management, agricultural damage mitigation, and climate adaptation strategies in lowland regions.

Társszerzői nyilatkozat

Jelölt neve: Kajári Balázs

Doktori iskola: SZTE TTIK, Földtudományok Doktori Iskola

Közlemény címe: *Monitoring of Inland Excess Water Inundations Using Machine Learning Algorithms*

Szerzők: Kajári Balázs, Bozán Csaba, Van Leeuwen Boudewijn

Megjelenés helye, ideje: LAND (BASEL) 12: 1 Paper: 36, 22 p. (2023)


DOI: <https://doi.org/10.3390/land12010036>

MTMT azonosító: 10071869

Alulírott társszerzők kijelentjük, hogy a fenti közleményben szereplő eredmények elérésében a jelölt szerepe meghatározó fontosságú. A jelölt által a Szegedi Tudományegyetemre benyújtott tézisekben és az értekezésben szereplő, valamint a közösen publikált eredmények eddig nem szerepeltek más PhD értekezés tudományos eredményei között. Tudomásul vesszük, hogy az értekezés eredményei a jövőben nem használhatók fel más tudományos fokozat megszerzésére indított eljárás során.

Dr. Bozán Csaba

Dr. Van Leeuwen Boudewijn



Kelt: Szeged, 2025. augusztus. 19.

Társszerzői nyilatkozat

Jelölt neve: Kajári Balázs

Doktori iskola: SZTE TTIK, Földtudományok Doktori Iskola

Közlemény címe: *Sentinel-1 és Sentinel-2 felvételek belvíz-veszélyeztetettségi idősoros elemzése konvolúciós neurális hálózatokkal*

Szerzők: Kajári Balázs, Van Leeuwen Boudewijn


Megjelenés helye, ideje: GEODÉZIA ÉS KARTOGRÁFIA 76: 1 pp. 10-16., 7 p. (2024)

DOI: <https://doi.org/10.30921/GK.76.2024.1.2>

MTMT azonosító: 10071869

Alulírott társszerző kijelentem, hogy a fenti közleményben szereplő eredmények elérésében a jelölt szerepe meghatározó fontosságú. A jelölt által a Szegedi Tudományegyetemre benyújtott tézisekben és az értekezésben szereplő, valamint a közösen publikált eredmények eddig nem szerepeltek más PhD értekezés tudományos eredményei között. Tudomásul vesse, hogy az értekezés eredményei a jövőben nem használhatók fel más tudományos fokozat megszerzésére indított eljárás során.

Van Leeuwen Boudewijn



Kelt: Szeged, 2025. augusztus. 19.

Társszerzői nyilatkozat

Jelölt neve: Kajári Balázs

Doktori iskola: SZTE TTIK, Földtudományok Doktori Iskola

Közlemény címe: *Prediction of Inland Excess Water Inundations Using Machine Learning Algorithms*

Szerzők: Kajári Balázs, Tobak Zalán, Túri Norbert, Bozán Csaba, Van Leeuwen Boudewijn

Megjelenés helye, ideje: WATER (2073-4441): 16 9 Paper 1267. 21 p. (2024)

DOI: <https://doi.org/10.3390/w16091267>

MTMT azonosító: 10071869

Alulírott társszerzők kijelentjük, hogy a fenti közleményben szereplő eredmények elérésében a jelölt szerepe meghatározó fontosságú. A jelölt által a Szegedi Tudományegyetemre benyújtott tézisekben és az értekezésben szereplő, valamint a közösen publikált eredmények eddig nem szerepeltek más PhD értekezés tudományos eredményei között. Tudomásul vesszük, hogy az értekezés eredményei a jövőben nem használhatók fel más tudományos fokozat megszerzésére indított eljárás során.

Dr. Tobak Zalán

Dr. Túri Norbert

Dr. Bozán Csaba

Dr. Van Leeuwen Boudewijn

.....
.....
.....
.....

Kelt: Szeged, 2025. augusztus. 19.