

Sentinel-1 és Sentinel-2 felvételek belvív-veszélyeztetettségi idősoros elemzése konvolúciós neurális hálózatokkal

KAJÁRI Balázs – Boudewijn van LEEUWEN

DOI: [10.30921/GK.76.2024.1.2](https://doi.org/10.30921/GK.76.2024.1.2)

Absztrakt: Napjainkban a klímaváltozás következtében egyre szélsőségesebb időjárásra lehet majd számítani, ami egyre gyakrabban megjelenő és egyre nagyobb területekre kiterjedő belvívelöntéseket idézhet elő. A belvív természeténél fogva igen összetett jelenség, ami a preventív védekezés megkezdését és a belvízzel veszélyeztetett területek lehatárolását jelentősen megnehezíti. Megoldást jelenthet, ha nagy területekre és megfelelő térbeli felbontással rendelkező, az Európai Űrügynökség (ESA) által elérhető Sentinel műholdcsalád aktív és passzív műholdjainak a felvételeire támaszkodva „közel folyamatos” monitoringrendszert alakítanánk ki. A vízfelületek lehatárolását konvolúciós neurális hálózatok (CNN – Convolutional Neural Network) alkalmazásával végeztük el, majd az adathiányos területeket és napokat időbeli interpolációval kiegészítve elkészítettük az egész évet felölelő belvívgyakorisági térképet. Az 1600 km²-es mintaterületen, 17,80 km² állandó vízfelületet, 5,64 km² magas, 3,70 km² közepes és 7,79 km² alacsony elöntési gyakoriságú területet határoltunk le.

Abstract: Presently, climate change is expected to cause extreme weather more often, which may result in increasingly frequent and widespread inundations. Shallow floods, also defined as inland excess water, are complex phenomena, which makes it very difficult to initiate preventive action and to identify areas at risk. It is therefore important to develop a "near-continuous" monitoring system based on images from the Sentinel constellation of active and passive satellites, available from the European Space Agency (ESA), covering large areas and with sufficient spatial resolution. We used convolutional neural networks (CNNs - Convolutional Neural Networks) to delineate water surfaces, which were temporally interpolated to create a frequency map over the whole year by filling temporal and spatial gaps in the time series. In the 1600 km² study area, we delineated 17,80 km² of permanent water surface, and 5,64 km² of highly, 3,70 km² of moderately and 7,79 km² of land slightly vulnerable to inland excess water.

Kulcsszavak: belvív, Sentinel-1, Sentinel-2, mélytanulás, konvolúciós neurális hálózat

Keywords: inland excess water, Sentinel-1, Sentinel-2, Deep Learning, CNN

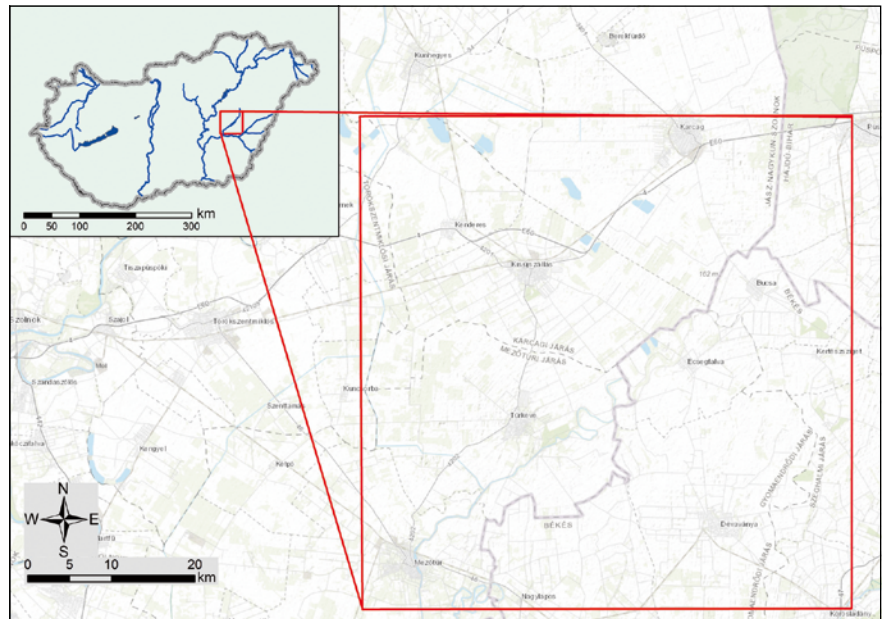
Bevezetés

A Kárpát-medence hidrometeorológiai viszonyait a földrajzi adottságok és a klímaváltozás következtében egyre szélsőségesebb időjárási jelenségek befolyásolhatják. A klímaváltozási előrejelzések helyenként a csapadék intenzitásának növekedését mutatják, ami növelheti a belvizek kockázatát (Mezősi et al. 2017). Kiemelt fontosságú a belvív napi szintű térképezése, monitoringrendszerének kialakítása, valamint a rövidtávú előrejelzése, annak érdekében, hogy a megfelelő védekezés időbeni elkezdésével csökkenteni lehessen a belvív által okozott károk nagyságát. A XX. század közepén megjelentek az első tanulmányok a belvív vizsgálatával kapcsolatban, az első térképek terepi felmérések alapján készültek (van Leeuwen et al. 2020). Műszaki, mérnöki oldalról tekintve, a belvív kialakulását és annak lefolyását

különböző hidrológiai modellek (Bíró 2017, Kozma et al. 2022) alapján lehet vizsgálni. A hivatkozott szerzők rávilágítottak arra a tényre, hogy az ilyen modellek futtatásához sok bemeneti (nagy felbontású) paraméter összegyűjtése szükséges, amelyek vagy nem állnak adatbázisszinten rendelkezésre, vagy nagyon költséges az adatgyűjtéshez szükséges felméréseket elvégezni. Alkalmazhatóságuk csak korlátozott léptékben – vízgyűjtő területen, belvívöblözetekben, pilotterületeken – lehet eredményes. Különböző országos léptékű tanulmányok készültek a sík területek belvív-veszélyeztetettségéről, amit elsőként Pálfi (2003) készített el statikus és dinamikus tényezők alapján, melynek azóta újabb változatai (Pásztor et al. 2015, Bozán et al. 2019, Laborczy et al. 2020) és stratégiai forгатókönyvei jelentek meg (Bozán et al. 2021). A belvív térképezését és monitorozását célzó legújabb kutatások mára távérzékelési

adatokon alapulnak (Tobak et al. 2008, Balázs 2010, Tsitsi et al. 2021). Ezek a pilóta nélküli járművek, légi felvételezések és a műholdak aktív és passzív adatai megfelelő térbeli és időbeli felbontást szolgáltatnak a vizsgálatokhoz. A belvív lehatárolására különböző módszerek (indexek, osztályozások, tradicionális gépi tanulás, mély neurális hálózatok) állnak rendelkezésre. A neurális hálózatok az utóbbi években, főleg a mély neurális hálózatok, ezeken belül a LeCun és munkatársai (1990) által megalkotott konvolúciós neurális hálózat (CNN), egyre nagyobb térnyerése figyelhető meg a földtudományi alkalmazásokban (LeCun et al. 1990, Giulia et al. 2023, Yichen et al. 2022, Sánchez et al. 2022). Korábbi vizsgálataink során nyolc módszert alkalmaztunk a belvív detektálására, amelyek közül a CNN bizonyult a legpontosabbnak a vizsgált Sentinel-2-es, nagy felbontású, multispektrális műholdképeken

(Kajári–Van Leeuwen 2021). A Sentinel-2-es optikai műholdfelvételek sajátos problémája, hogy felhős időben nem állnak rendelkezésre értékelhető adatok. Jelen kutatásunkban erre a problémára kerestünk megoldást a Sentinel-2-es felvételeket kiegészítve a Sentinel-1-es radarképek Radar Vegetation Index (RVI) és Gray Level Co-Occurrence Matrix (GLCM) (Allagwail et al. 2019, Haralick et al. 1973, Connors et al. 1984) osztályozott adataival. Ezzel a módszerrel megfelelő mennyiségű és minőségű bemeneti adatot hoztunk létre, amelyek lehetővé tették a vízfelületek egy éven keresztül (2020. 06. 01. – 2021. 05. 31.) folyamatos lehatárolását.

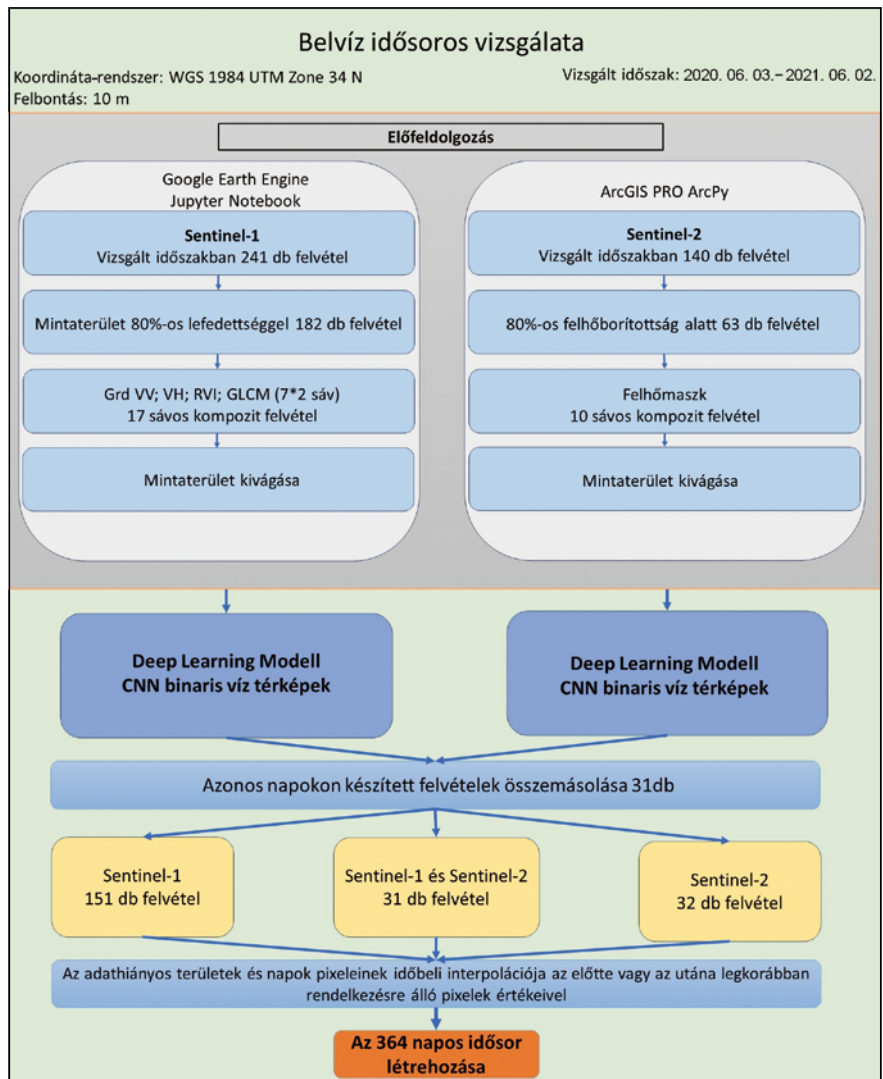


1. ábra. A vizsgálati terület

Adatok és módszer

A 1600 km²-es (40 km × 40 km) mintaterület az Alföld közepén helyezkedik el a Szolnok-Túri-sík a Nagy-Sárrét, a Dévaványai-sík, Tiszafüred-Kunhegyesi-sík és a Körösmenti-sík területén. A felszíne egyenletes sík, egykor a Tisza által szabdalta terület volt, amely ma igen változatos morfológiával rendelkezik. Éghajlata mérsékelt meleg, száraz, az évi átlagos csapadék 450-550 mm között oszlik el. A tájrészek elhagyott folyómedreinek, holtágainak mélyedéseit iszapos-agyagos üledékek és lösziszap tölti ki. A rossz vízgazdálkodású talajok miatt a gyakori aszályok mellett belvizek is sújtják a területet (Dövényi et al. 2010) (1. ábra).

A vizsgálat alapját az ESA Sentinel-1-es és Sentinel-2-es műhold felvételei szolgáltatják. A Sentinel-1 két műholdból álló konstelláció, amely napszinkronpályán kering (98,18° pályainklinációjú). A műholdak azonos műszerekkel ellátva radarfelvételeket készítenek a Föld felszínéről. A Sentinel-1B 2021 decemberében bekövetkezett leállása óta csak a Sentinel-1A adatai állnak rendelkezésre. A műhold napszaktól, időjárásitól és légköri viszonyoktól függetlenül készíti felvételeket, Magyarország esetében körülbelül háromnapos visszatérési idővel. Képkalkáló műszere egy C sávú, 5,405 GHz-es központi frekvenciájú szintetikus apertúrájú radar.



2. ábra. A Sentinel-1-es és Sentinel-2-es felvételek feldolgozási folyamata

A műszer a radarjeleket vízszintes-függőleges (HV – Horizontal-Vertical) és függőleges-horizontális (VH – Vertical-Horizontal) polarizációs üzemmódban képes küldeni és fogadni. Ehhez a tanulmányhoz a Sentinel-1 Ground Range Detected (GRD) adatait használtuk fel interferometrikus Wide-Swath (IW) üzemmódban, 5 × 20 méteres térbeli felbontással, amelyeket 10 × 10 méteresre átalakítva töltöttünk le az egységes feldolgozás érdekében.

A Sentinel-2A és Sentinel-2B multispektrális képalkotó műholdak, optikai adatokat szolgáltatnak közel ötnaponta ismétlődő periódussal. A felvételek 13 spektrális sávból állnak, amelyek a látható tartománytól a közeli infravörösön át a rövidhullámú infravörösig terjedő spektrumot fedik le. A térbeli felbontást tekintve 10, 20 és 60 méteres felbontású adatokat szolgáltatnak. A különböző műholdadatok előfeldolgozásának, valamint az egy éves vizsgálati időszak (2020. 06. 03. – 2021. 06. 02.) elemzésének folyamatát a 2. ábra mutatja be.

A Sentinel-1-es felvételek összegyűjtése és feldolgozása a Google Earth Engine (GEE) használatával történt. A GEE egy felhő alapú platform, ami a térbeli adathalmazok tudományos elemzéséhez és vizualizálásához nyújt segítséget. A műholdképeket egy nyilvános adatarchívumban tárolja, és lehetőséget nyújt a nagy adathalmazok elemzésére. A vizsgálati időszakban összesen 241 darab felvétel található, amely érinti a mintaterületünket. Ezekből a felvételekből kiszűrésre kerültek azok, melyek nem fedték le legalább a terület 80%-át. Így összesen 182 darab felvétel került feldolgozásra.

A felvételek egy előfeldolgozási folyamaton estek át, ahol a hőzaj eltávolítása és radiometriai kalibrálása, valamint a domborzati korrekció segítségével a végleges terepkorrigált értékekkel rendelkező 10 × 10 méteres felbontású felvételeket alakítottunk ki (Van Leeuwen et al. 2020).

Korábbi kísérletek azt mutatták, hogy a radarképekben lévő foltos zajok (speckle-noise) felerősödése gyakran megzavarta a GLCM-textúrák kinyerését és a CNN sokszor tévesen

belvíznek osztályozta azokat, ezért alkalmaztuk a RefineLee szűrőt (Mullissa et al. 2021). A leválogatott adatok letöltését Jupyter Notebookban ArcPy használatával végeztük el.

A letöltött VV (Vertical-Vertical) és VH (Vertical-Horizontal) sávok mellett, a belőlük képzett RVI és a GLCM számunkra hasznos textúráiból 17 sávot kompozit felvételeket hoztunk létre.

Az RVI a vegetáció növekedési szintjének megfigyelésére szolgáló módszer az idősoros adatelemzésben, amelyet az optikai képfeldolgozási vizsgálatokban használt NDVI (Normalized Difference Vegetation Index) módszer alternatívájaként használtuk. Az RVI egy normalizált index, amelynek határértékei ideális esetben nulla és egy között változhatnak. Sima, növényzet nélküli felület esetén közel 0 az érték, amely a növényzet magasságának/kiterjedésének növekedésével arányosan növekszik. A mi megközelítésünkben, az alacsony értékek várhatóan növényzet nélküli területeket reprezentálnak. Az RVI számításához a következő képletet használtuk fel (Szigarski et al. 2016, Nasirzadehdizaji et al. 2019):

$$RVI = (4 \times VH) / (VV+VH)$$

A szürkességi együttváltozási mátrix (GLCM) módszerét először Haralick és társai mutatták be (1973). Ez egy olyan matematikai módszer, amelyet a digitális képfeldolgozásban használnak a kép textúrájának elemzésére (Kupidura 2019, Allagwail et al. 2019). A szürkeárnyaltos képen a pixelértékek párijainak egy bizonyos távolságban és szögben való előfordulási gyakoriságát mutatja. A szürkességi szintek együttváltozási mátrixa az azonos felületek (esetünkben a vízfelületek) szabályosabb térbeli elrendeződését, textúráját jelenti. A vizsgálat során felhasznált sávok (VV és VH) eredményeként 2 × 18 darab sáv keletkezett. A Google Earth Engine glcmTexture funkcióját használtuk, ahol a Haralick által javasolt 14 GLCM-számítást (Haralick et al. 1973), valamint a Connors által javasolt további 4 számítást (Connors et al. 1984) végeztük el. A 18 sávból egy előszűrés alapján azok a sávok lettek felhasználva, melyek textúratulajdonságai a legjobb eredményeket adták (lásd 1. táblázat zöld színnek jelölt 7 sáv) a modell betanítása során. Az elkészített 17 sávot kompozit felvételek a mintaterületre aktualizálva kivágásra kerültek.

1. táblázat. A GLCM-sávok és a CNN-modellben felhasznált (zöld) sávok listája (Haralick et al. 1973, Connors et al. 1984)

	GLCM sávok
CONTRAST:	Kontraszt
SAVG:	Összegátlag
DVAR:	Differencia variancia
DISS:	Különbség
INERTIA:	Tehetetlenség
SHADE:	Klaszterárnyék
PROM:	Klaszterkiemelkedés
ASM:	Második szögmomentum: az ismétlődő párok számát méri.
CORR:	Korreláció; a pixelpárok közötti korrelációt méri.
VAR:	Variancia: a szürkességi szintek eloszlásának szóródását méri.
IDM:	Inverse Difference Moment: a homogenitást méri.
SVAR:	Összegzett variancia
SENT:	Szumma entrópia
ENT:	Entrópia: a szürkességi eloszlás véletlenszerűségét méri.
DENT:	Különbség entrópia
IMCORR1:	A korreláció információs mértéke. 1
IMCORR2:	A korreláció információs mértéke. 2
MAXCORR:	Max Corr. Coefficient (nem számított)

A Sentinel-2A és Sentinel-2B műholdak felvételeit ArcGIS Pro ArcPy környezetben használtuk fel a vizsgálataink során. A vizsgált időszakra 140 darab műholdfelvétel volt elérhető az ESA adatbázisában. A vizsgált műholdfelvételekből a 80%-nál nagyobb felhőborítottsággal rendelkező felvételek kizárásra kerültek, így 63 darab felvétellel kezdtük meg az előfeldolgozást. Az adatok tizenhárom spektrális tartományából, tíz sávja került feldolgozásra. Az egységes felbontás elérése érdekében, a 20×20 m-es felbontású spektrális sávok úgy, mint az 5, 6, 7, 8A, 11, 12 sávok 10×10 m-es felbontásúra lettek átméretezve. A légköri zavarok (felhők, felhőárnyékok) maszkolását az ESA által elkészített SCL (Scene Classification) alapján végeztük el. A 11 osztályból a felhőként és felhőárnyékként azonosított osztályok által lehatárolt területek kerültek (3, 8, 9, 10 osztályok) eltávolításra. Mindezek után a mintaterület került kivágásra az előkészített kompozit felvételekből.

A vizsgálatunkhoz használt CNN-modell egy olyan speciális neurális hálózat, amely többdimenziós felépítésű adatok feldolgozására alkalmas. Ilyen adatok lehetnek például az idősoros adatok, amelyeket úgy lehet elképzelni, mint ami egy egydimenziós rács, mely rendszeres időközönként veszi fel a mintákat, és a képek, melyekre kétdimenziós rácsként kell tekinteni. Az elnevezés azt jelzi, hogy a modell egy matematikai lineáris műveletet, konvolúciót alkalmaz. A konvolúciós hálókat egyszerű neurális hálózatok, melyek legalább az egyik rétegükben konvolúciót alkalmaznak az általános mátrixszorzás helyett (Alzubaidi et al. 2021). A különböző CNN-architektúrák közül mi a Ronneberger et al. (2015) által kifejlesztett U-Net architektúrát használtuk. A modell betanítását a 2021. 02. 23-as műholdfelvételen végeztük el, amikor elegendő vízzel előtöltött pixel állt rendelkezésre. Bemeneti adatként csak a vízfelületeket reprezentáló pixeleket határoztuk le. Az iteratív elemzés során meghatározásra kerültek az optimális hiperparaméterek mind a két típusú műholdfelvételen. A Sentinel-1-es 17 sávos kompozit felvételeken a végső

paraméterek a következőképpen alakultak: U-Net pixelosztályozást alkalmazva 128×128 -as csempeméretet (chip size) használva, azok 50%-os átfedtségével (overlap), 8 kötegeléssel (batch size) és 50 futtatási körben (Max Epochs) a túltanulást elkerülve 20%-os validációs értékek kerültek meghatározásra.

A Sentinel-2-es 10 sávos kompozit felvételeken szintén az U-Net pixelosztályozást alkalmaztuk: 128×128 -es csempeméretnél (chip size), 50%-os átfedtséggel (overlap), 8 kötegeléssel (batch size) 30 futtatási körben (Max Epochs) a túltanulást elkerülve 20%-os validációs érték mellett került meghatározásra.

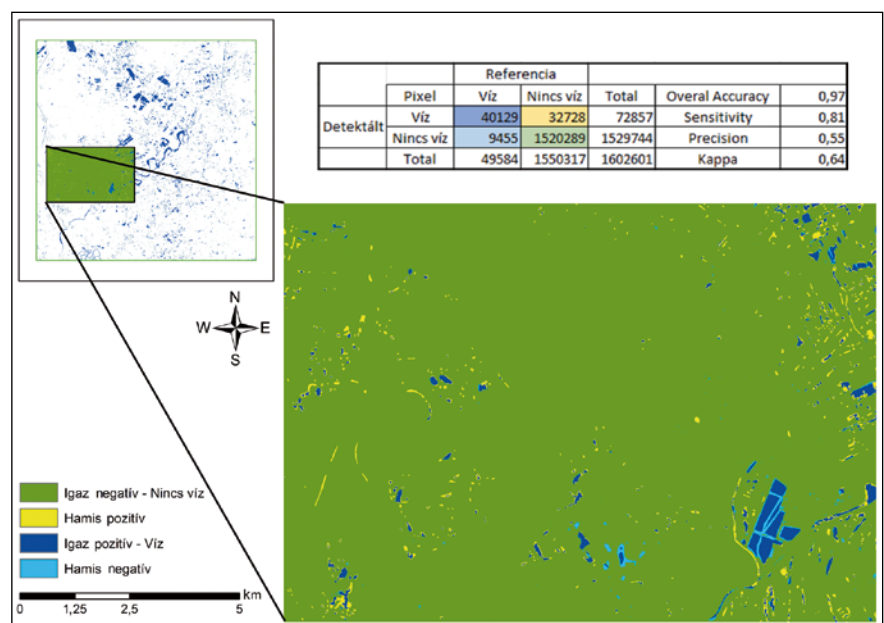
A futtatás a ResNet34 architektúrájú modellel történt, ahol a 34-es szám a rétegek számát jelöli. Minél nagyobb ez a szám, az annál több létrehozandó paramétert jelent, amely előrevetíti, hogy nagyobb erőforrás szükséges a modell tanításához. Esetünkben az architektúra megfelelően skálázható volt, a rugalmas és robusztus, mélyebb háló – úgy mint, a ResNet50 vagy a ResNet101 – csak a számítási időt növelte. A modell képzése során a paramétereket (bináris számrendszer 0; 1) kellett beállítani, úgy, hogy az adott bemeneti értékekre az elvárt kimeneti értéket kapjuk. A feladat matematikai értelemben egy függvényillesztési feladat, amellyel csak a teljesen összekapcsolt réteg

súlyait igazítottuk ki. Az előkészített Sentinel-1-es és Sentinel-2-es adatokon a CNN-modelleket futtatva három osztályt (-1 = adathiány, 0 = nincs víz és 1 = víz) tartalmazó térképeket készítettünk el.

Adathiányos (-1 -es értékű) területek adódtak mind a két féle típusú műholdfelvétel vizsgálata során. A Sentinel-1-es felvételeken a csempéhatárokon alakultak ki 1-2 pixelből álló adathiányos sorok, míg a Sentinel-2-es felvételeken a felhőfelhőárnyék maszkolásának köszönhetően alakultak ki az adathiányos területek. A -1 értékkel rendelkező területek felszámolását a modell futtatása érdekében úgy oldottuk meg, hogy a hiányzó pixelértéket az előtte, vagy utána legközelebbi dátumon rendelkezésre álló adatok időbeli interpolációjával töltöttük fel. Maximálisan 4 napnyi távolságra néztük a rendelkezésre álló adatokat, ha nem találtunk értékeket, akkor 0 értékkel (nem víz) töltöttük ki a hiányzó pixeleket.

Természetesen adódtak olyan napok, ahol mind a két műholdnak voltak felvételei (összesen 31 nap), melyek összemáskolását el kellett végezni. Végül az eredménytérképre a közös vízfelületként detektált területek kerültek.

Mindezek után elkészültek az egy évet lefedő, napi bontású, bináris térképeink, melyeken a vízfelületek lehatárolását és vizsgálatát el tudtuk végezni.



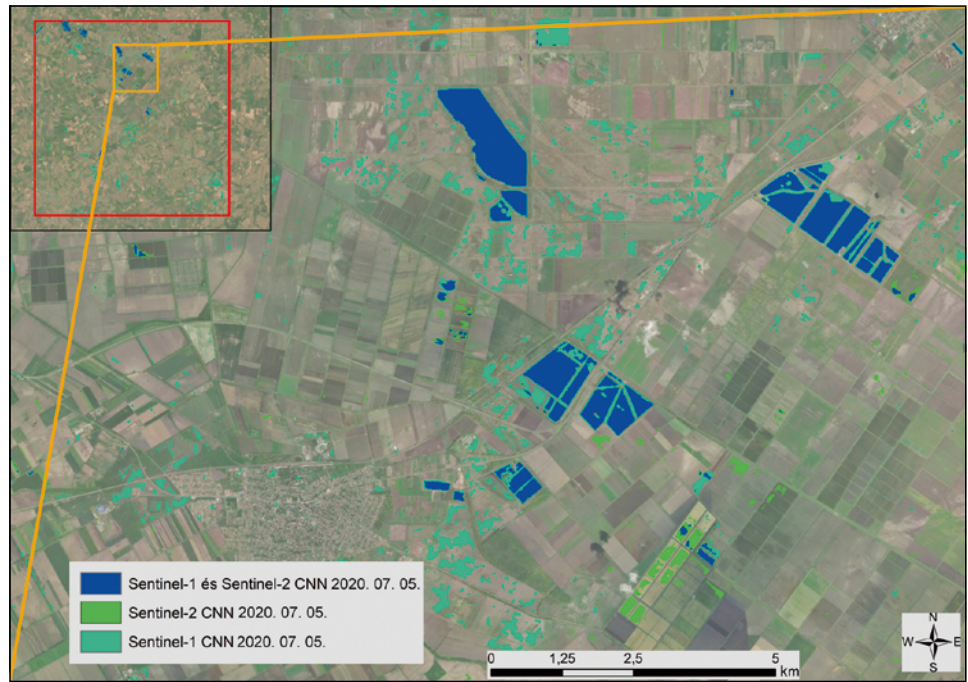
3. ábra. Validáció a mintaterületen

Eredmények

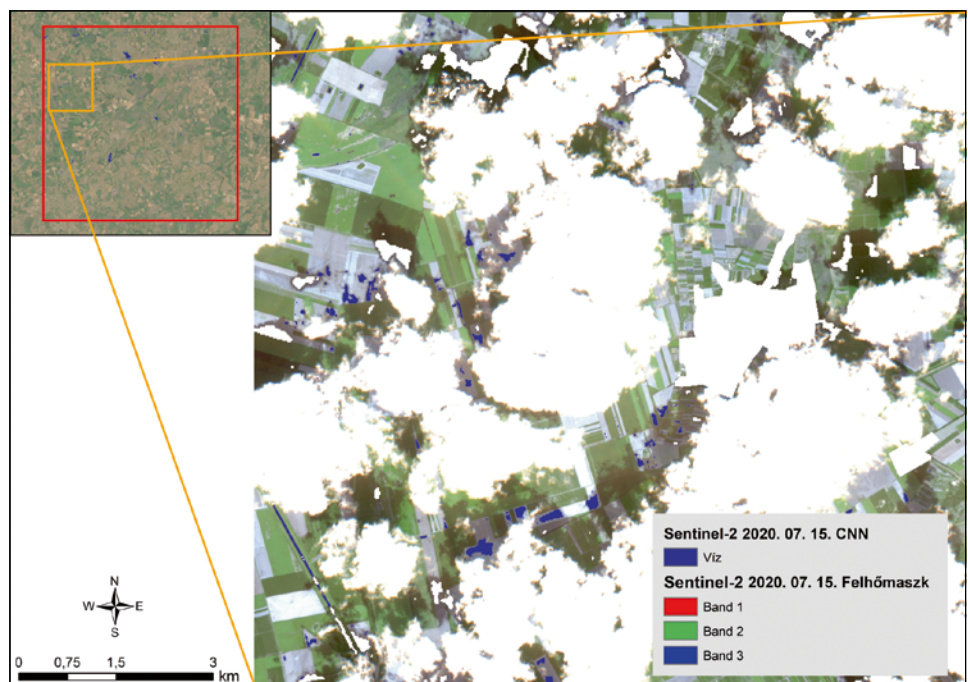
A Sentinel-1 és Sentinel-2 modellek képzésénél az adatokat két részre osztottuk, 80%-ot használtunk a betanításhoz, míg 20%-ot a validáláshoz. A pontosságot az F1 metrika segítségével validáltuk, amely a pontosság és a visszahívás harmonikus átlaga. Ennek eredményeként a Sentinel-1-alapú modell F1-értéke 0,84, a Sentinel-2 modellé pedig 0,71 volt. Az elkészült predikciós térképek közül a 2021. 02. 23-ai térképet és az ugyanehhez a dátumhoz tartozó Sentinel-2-es hamis színezetű kompozit felvételt használtuk fel a validáláshoz. A mintaterület nagysága miatt, egy, az egész területre jellemző ~160 km²-es területet határoltunk le (4. ábra). A felvételen manuálisan digitalizáltuk a vízfelületeket. A referenciapoligonokat a modell eredményeivel megegyező felbontású pixelekre (10 × 10 m) konvertáltuk és készítettük el a hibamátrixot (3. ábra). Az előrejelzés általános pontossága 0,97 volt. Ez a nagyon magas eredmény a kiegyensúlyozatlan osztályoknak köszönhető. A 0,64-es kappá érték jobb pontossági mérőszámot mutat.

Az azonos időpontban készített térkép (4. ábra) alapján megállapítható, hogy az állandó vízfelületek (sötétkék) megegyeznek a két műholdkép esetében. A Sentinel-1-es felvételen a radaradatok a sekélyebb vízelöntéseket és a sötétebb, átnedvesedett kopár talajfelszínt érzékeli jobban (világoskék szín). A Sentinel-2-es felvételen viszont az enyhén növényborítással bíró vízfelületek (zöld szín) azonosíthatók jobban, valószínűleg itt a növényzettel borított rizskazetták víztesteinek beazonosítására érzékenyebb az elkészült térkép.

Továbbá megjegyzendő, hogy a nem tökéletesen osztályozott SCL-képnek köszönhetően a felhő- és felhőárnyékmászkolás mellett elvétve hibásan



4. ábra. A Sentinel-1-es és Sentinel-2-es felvételek vízlehatárolásának összehasonlítása



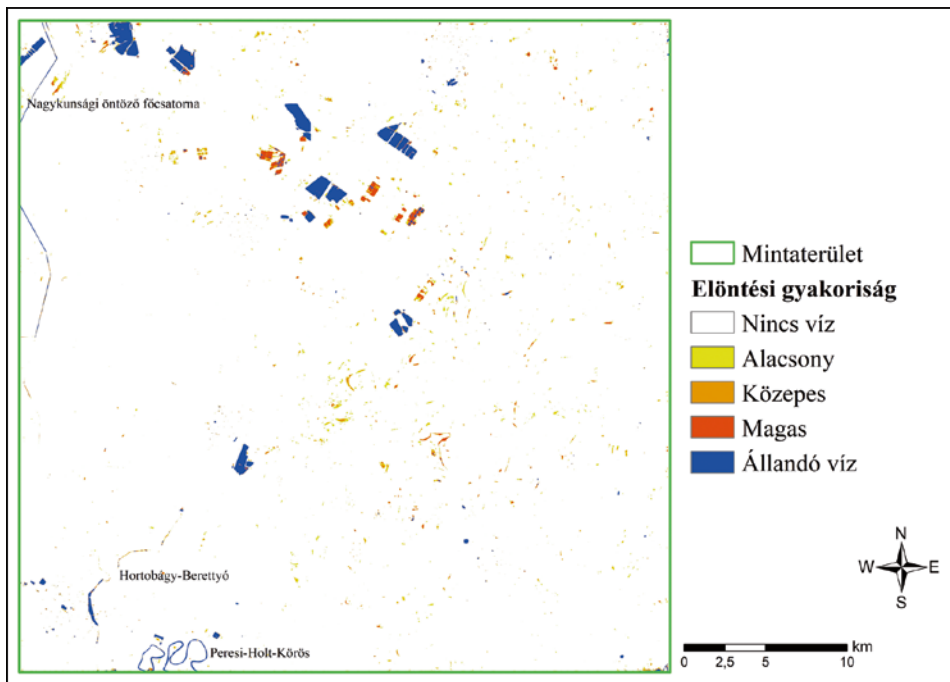
5. ábra. Felhőárnyékban tévesen detektált vízfelület a Sentinel-2-es felvételen

vízfelületként detektált pixeleket találhatunk (5. ábra). A Sentinel-1-es felvételeken a csempehatárok is hasonló hibákkal terheltek. A műholdfelvételek ilyen típusú „érzékenysége” miatt, hogy a „hibásan” vízfelületként azonosított pixelek a közös dátummal rendelkező felvételeken ne okozzanak víztöbbletet, a felvételek metszetét készítettük el.

A 364 napra elkészített bináris térképek gyakorisági értékeit ábrázoló

térkép a vízpixelek előfordulását a 6. ábra mutatja be, amelyen jól elkülöníthetők az állandó vízfelületek az ideiglenesen vízzel borított területektől. A gyakorisági értékek jól meghatározott osztályozása után, különböző fokozatokban ki lehet jelölni azokat a területeket, amelyek a belvíz előfordulására hajlamosak.

Az eredménytérképen állandó vízfelületként a nagyobb tavak, halastavak nyílt vízfelszínnel rendelkező



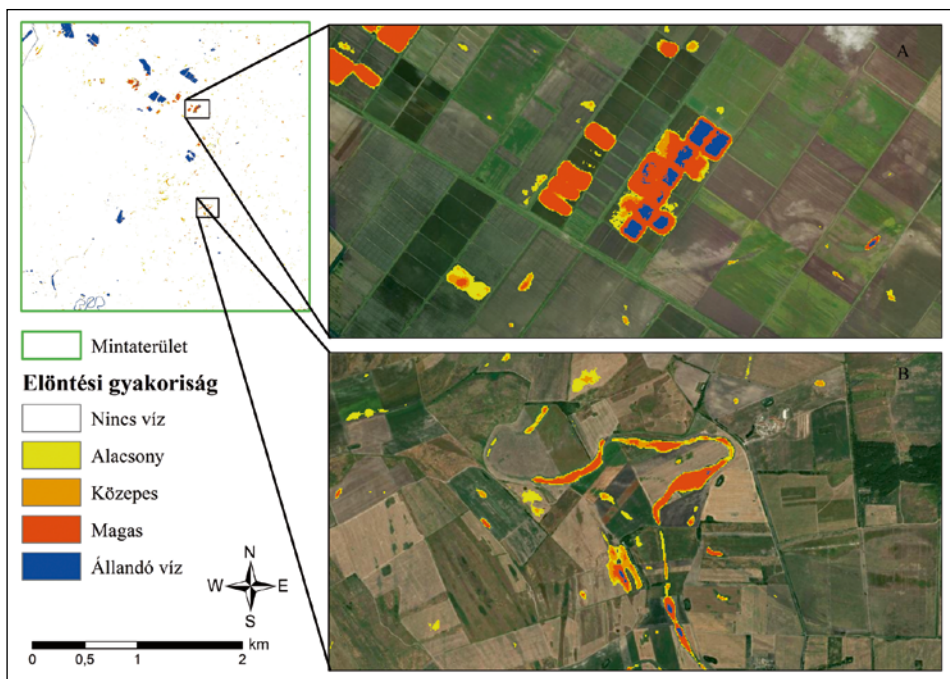
6. ábra. Az elöntésgyakorisági térkép alapján lehatárolt vízfelületek

84–146 napra tehető, melynek területi kiterjedése 5,64 km². Az összterülethez viszonyítva a kiterjedése minimálisnak tekinthető (0,35%). A narancssárga színnel jelölt területek a közepes elöntési gyakoriságú területeknek számítanak, amelyek többnyire a rizskazettákat (7. a) ábra) és az erősen veszélyeztetett területek melletti területeket (vizenyős rét-legelő) (7. b) ábra) jelöli ki. Területi kiterjedése 3,70 km², és a vízborítással feltételezett napok száma maximálisan 84 napra tehető. A sárga szín az alacsony elöntési gyakoriságú területeket határolja le 2,70 km² kiterjedéssel. A vízzel borított napok maximális száma 66. Az eredmények tükrében a mintaterülethez arányosítva a vízfelületek mind az állandó vízborítású, mind az ideiglenes vízborítással rendelkező területek az összterület 1,07%-át teszik ki (2. táblázat).

Következtetések

A Sentinel-1 és Sentinel-2 felvételek fúziója által, a kitűzött egy éves időtartamot vizsgáló elemzésünk során 214 napra álltak rendelkezésünkre a felvételek. A CNN-modellek futtatását követően az adathiányos pixeleket feltöltöttük az előtte vagy utána rendelkezésre álló adatok időbeli interpolációjával, így elkészítve az egész évet felölelő belvízgyakoriság-térképet.

A modellek finomításával, úgy, mint a Sentinel-1-es GLCM-sávok redukálásával, vagy bővítésével, a hiperparaméterek módosításával, valamint a Sentinel-2-es felvételek felhőmaszkjának pontosításával az eredmények tovább javíthatók. A kijelölt területek rámutatnak azokra a helyekre, amelyek veszélyeztetettek lehetnek a belvízelöntések megjelenése szempontjából. Ez egyrészt a döntéshozók számára adhat segítséget az operatív védekezés feladatainak prioritizálásában, másrészt a területhasználat átstrukturálását, optimalizálását teheti lehetővé.



7. ábra. A közepes elöntési gyakoriságú területek a) rizskazetták, b) vizenyős rét-legelő

csatornák (pl. a Nagykunsági öntöző főcsatorna), holtágak (pl.: Peresi-Holt-Körös) és folyók (pl. Hortobágy-Berettyó) azonosíthatók be. Az

állandó vizek területi kiterjedése 17,80 km². A piros szín a magas elöntési gyakoriságú területeket jelöli. A vízpixelek előfordulása az év folyamán

2. táblázat. Az állandó vizek és a belvizzel veszélyeztetett területek megoszlása

Gyakoriság %	Pixel	km ²	Terület %	Nap
0-13%	15 650 691	1565,07	97,82	0-48
13-18%	77 934	7,79	0,49	48-66
18-23%	37 001	3,70	0,23	66-84
23-40%	56 365	5,64	0,35	84-146
40-100%	178 009	17,80	1,11	146-365

Köszönetnyilvánítás

A kutatást a Magyar Agrár- és Élettudományi (MATE) Egyetem Környezettudományi Intézet (KÖTI) Öntözési és Vízgazdálkodási Kutatóközpont (ÖVKI) 18K020007 Mezőgazdasági vízgazdálkodás fejlesztését (öntözéses gazdálkodás, belvígazdálkodás, földhasználat racionalizálás) célzó kutatások c. téma támogatta.

A tanulmány a Kulturális és Innovációs Minisztérium ÚNKP-23-3 kódszámú, a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott, Új Nemzeti Kiválóság Programjának a szakmai támogatásával készült.

Irodalom

- Allagwail, S. – Osman S. G. – Javad R. 2019. *Face Recognition with Symmetrical Face Training Samples Based on Local Binary Patterns and the Gabor Filter*, Symmetry 11(2). DOI: [10.3390/sym11020157](https://doi.org/10.3390/sym11020157)
- Alzubaidi, A. – Laith, J. Z. – Amjad, J. H. – Ayad, A. – Ye, D. – Omran, A. – Santamaría, 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). DOI: [10.1186/s40537-021-00444-8](https://doi.org/10.1186/s40537-021-00444-8)
- Balázs, B. 2010. *Belvizes Területek Felmérése Geoinformatikai Módszerekkel*, pp. 1–10 In Hegedűs, A. (szerk.): Geoinformatika és domborzatmodellelés: A HunDEM 2009 és a GeoInfo 2009 konferencia és kerekasztal válogatott tanulmányai, Miskolc.
- 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. DOI: [10.1109/JSTARS.2021.3083517](https://doi.org/10.1109/JSTARS.2021.3083517)
- Bíró, T. 2017. Amikor sok víz van a területen – Belvív. *Magyar Tudomány* 178(10):1216–27. DOI: [10.1556/2065.178.2017.10.5](https://doi.org/10.1556/2065.178.2017.10.5)
- Bozán, C. – Körösparti, J. – Túri, N. – Kerecsi, Gy. – Kajári, B. 2019. *AKK Belvízi veszélyzettség felülvizsgálata*, Készült VIZITERV Environ Kft. megbízásából, p. 83 + térképmellékletek.
- Bozán, C. – Körösparti, J. – Túri, N. – Kerecsi, Gy. – Kajári, B. 2021. *AKK Belvízi veszélyzettség felülvizsgálata Stratégiai forgatókönyvek*, Készült VIZITERV Environ Kft. megbízásából, p. 144
- Giulia, C. – De Fioravante, P. – Dichicco, P. – Congedo, L. – Marchetti, M. – Munafo, M. 2023. *Land Cover Mapping with Convolutional Neural Networks Using Sentinel-2 Images: Case Study of Rome*, Land 12(4). DOI: [10.3390/land12040879](https://doi.org/10.3390/land12040879)
- Conners, 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, DOI: [10.1016/0734-189X\(84\)90197-X](https://doi.org/10.1016/0734-189X(84)90197-X)
- Dövényi, Z. – Ambrózy, P. – Juhász, Á. – Marosi, S. – Mezősi, G. – Michalkó, G. – Somogyi, S. – Szalai, Z. – Tiner, T. 2010. *Magyarország kistájainak katasztere (Inventory of Microregions in Hungary)*, Földrajztudományi Kutatóintézet, Budapest.
- Haralick, R. M. – Shanmugam, K. – Dinstein, I. H. 1973. *Textural features for image classification*. *IEEE Transactions on systems, man, and cybernetics*, (6), pp. 610–621. DOI: [10.1109/TSMC.1973.4309314](https://doi.org/10.1109/TSMC.1973.4309314)
- Kajári, B. – Van Leeuwen, B. 2021. *Belvív 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 p. 360, pp. 137–145., p. 9.
- Kajári, B. – Bozán, C. – Van Leeuwen, B. 2023. *Belvívelöntés detektálása Sentinel-1-es műhold felvételeken GLCM textúrák és konvolúciós neurális hálózat segítségével*, pp. 93–101. In Az elmélet és gyakorlat találkozása a térinformatikában XIV.
- Kozma, Z. – 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):256–68. DOI: [10.3311/PPci.18369](https://doi.org/10.3311/PPci.18369)
- 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). DOI: [10.3390/rs11101233](https://doi.org/10.3390/rs11101233)
- Laborczi, A. – Bozán, C. – 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). DOI: [10.3390/ijgi9040268](https://doi.org/10.3390/ijgi9040268)
- 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.
- 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. DOI: [10.1080/15481603.2022.2112391](https://doi.org/10.1080/15481603.2022.2112391)
- Mezősi, G. – Bata, T. – Blanka, V. – Ladányi, Z. 2017. *A klímaváltozás hatása a környezeti veszélyekre az Alföldön*. Földrajzi Közlemények 141(1):60–70
- 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. DOI: [10.3390/rs13101954](https://doi.org/10.3390/rs13101954)
- Nasirzadehdizaji, R. – Balik, S. 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. 2019; 9(4):655. DOI: [10.3390/app9040655](https://doi.org/10.3390/app9040655)
- Pálfi, I. 2003. *Magyarország belvív-veszélyzettségi térképe*, Vízügyi Közlemények 85(3):510–524
- Pásztor, L. – Körösparti, J. – Bozán, C. – Laborczi, 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. DOI: [10.1080/17445647.2014.954647](https://doi.org/10.1080/17445647.2014.954647)
- Ronneberger, O. – Fischer, P. – Brox, T. 2015. *U-Net: Convolutional Networks for Biomedical Image Segmentation*, pp. 234–41. In Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). Vol. 9351. Springer Verlag DOI: [10.1007/978-3-319-24574-4_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Sánchez, S. – Martín, A. – 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). DOI: [10.3390/rs14215373](https://doi.org/10.3390/rs14215373)
- 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. DOI: [10.3390/rs10111776](https://doi.org/10.3390/rs10111776)
- 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. DOI: [10.14232/jengeo-2008-43861](https://doi.org/10.14232/jengeo-2008-43861)
- 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 (Switzerland) 12(7). DOI: [10.3390/su12072854](https://doi.org/10.3390/su12072854)



Kajári Balázs
doktorandusz,
tudományos
segédmunkatárs

Szegedi Tudományegyetem
Geoinformatikai, Természet- és Környezetföldrajzi Tanszék,
Magyar Agrár- és Élettudományi Egyetem Környezettudományi Intézet
Öntözési és Vízgazdálkodási Kutatóközpont, Szarvas
kajari.balazs@uni-mate.hu



Boudewijn van Leeuwen
egyetemi
adjunktus

Szegedi Tudományegyetem
Geoinformatikai, Természet- és Környezetföldrajzi Tanszék