

# BELVÍZ MONITOROZÁSA SZEGMENTÁLÁSSAL, FELÜGYELT OSZTÁLYOZÁSSAL ÉS GÉPI TANULÁSSAL SENTINEL 2-ES MŰHOLDFELVÉTELEKEN

Kajári Balázs<sup>1,2</sup> – Körösparti János<sup>1</sup> – Kerezi György<sup>1</sup> – Túri Norbert<sup>1</sup> – Bozán Csaba<sup>1</sup> – Boudewijn van Leeuwen<sup>2</sup>

<sup>1</sup> Magyar Agrár- és Élettudományi Egyetem (MATE), Környezettudományi Intézet (KÖTI), Öntözési és Vízgazdálkodási Kutatóközpont ÖVKI), Szarvas

<sup>2</sup> Szegedi tudományegyetem, Geoinformatikai, Természet- és Környezetföldrajzi Tanszék, Szeged

## KIVONAT

Az általunk bemutatott modellek közül a konvolúciós neurális hálózat (Convolutional Neural Network (CNN)) modell bizonyult a leghatásosabbnak a vizsgált időpontokban lásd 1. táblázat. Ami lehetővé teszi a belvíz monitoring rendszer kialakítását minimális felhasználói beavatkozás mellett. Az index-el történő vízfelületek lehatárolása folyamatos felhasználói beavatkozást igényelnek, úgy, mint az irányított osztályozások. Az általunk vizsgált mintaterületen közel meggyőző eredményeket mutatott, így lehetőség nyílik a vizsgálatok kiterjesztéséhez mind területileg, mind időben. Remélhetőleg a kiválasztott modell alkalmas lesz lokális vagy regionális, illetve hosszú idő-soros elemzésekre a későbbiekben.

A Kárpát-medence egész évben sokféle, köztük extrém időjárási körülménynek van kitéve. Egyrészt a tél végi és a tavaszi, kora nyári intenzív csapadékok sekély elöntést okoznak a sík mélyfekvésű területeken. A klímaváltozási modellek megnövekedett intenzitású csapadék eseményeket jósolnak a Kárpát-medencében is, ami a jövőben növelheti a belvizek megjelenésének kockázatát. Az elöntések nagyon dinamikus természetűek lehetnek. A meteorológiai viszonyok (hőmérséklet, csapadék, szélsébség) függvényében amilyen gyorsan megjelenhetnek, olyan gyorsan el is tűnhetnek. Ezért fontos, hogy megfigyelésükhöz műholdképeket használjunk, beleértve a légköri zavarokat (felhőket) tartalmazókat is. Ebben a dolgozatban egy indexet egy osztályozási módszert, valamint egy fejlettebb mély tanulási módszert mutatunk be a belvíz detektálására, Sentinel-2 műholdfelvételeket felhasználva. A kutatás célja annak értékelése, hogy mely módszertan optimális a belvíz elöntések helyzetének és kiterjedésének monitorozására nagy területeken, kellően nagy tér- és időbeli felbontás mellett. A folyamatos monitorozás felhasználható a belvíz fejlődésének megértésére, az infrastruktúrára és a mezőgazdaságra jelentett kockázatok mérséklésére, valamint a többletvíz újrafelhasználási lehetőségeinek vizsgálatára az aszályos időszakokban.

**KULCSSZAVAK:** belvíz, osztályozás, gépi tanulás, Sentinel-2, szegmentálás, klasszifikáció, távérzékelés

## BEVEZETÉS

Magyarország termőterületének (7,3 millió hektár) jelentős része (5,3 millió ha) mezőgazdasági terület, amiből kb. 1,9 millió hektárt lehet potenciálisan belvízzel veszélyeztetni tekinteni (KSH, 2021; Pálfai, 2004). Általánosságban elmondható, hogy Magyarországon a csapadékosabb években a vízzel borított területek elérhetik az 50-100 ezer hektárt kiterjedést is. Kiemelt volt az 1999-es év, amikor több mint 500 ezer hektár terület lett elöntve. (Somlyódy, 2011).

A belvízzel, mint hidrológiai jelenséggel foglalkozó kutatások hazánkban nagy múltra tekintenek vissza. Pálfai (2001) közel ötven definícióját gyűjtötte össze, ezzel is rámutatva a jelenség bonyolultságára. Az eltérő értelmezéseket az alábbi megfogalmazással hozta közös nevezőre: "a belvíz a sík vidékek időszakos, de meglehetősen tartós és viszonylag nagy területre kiterjedő jelensége, sajátos vízfajtája." Más alacsonyabban fekvő országokban (Hollandia, Lengyelország, Németország) is ismert hasonló jelenség (amit punding water - pangó víznek, waterlogging – vizesedésnek neveznek (Kuti et al., 2006)), de messze a Kárpát-medencében okozza a legnagyobb kárt.

A belvízkutatás terén az elmúlt időszakban jelentős előre lépések történtek a távérzékelés és a térinformatika fejlődésével. A szintetikus térképi eljárások egyre kifinomultabbak lettek. Tamás (2000) megfogalmazta, hogy a térinformatikai modellezés lényege, hogy a különböző vizsgálatra kiválasztott térképi rétegeket úgy kombináljuk, hogy egy új szintézis térképi réteget

kapjunk, amely az eredeti térképi rétegek információi alapján, egy teljesen új információt szolgáltat a felhasználónak.

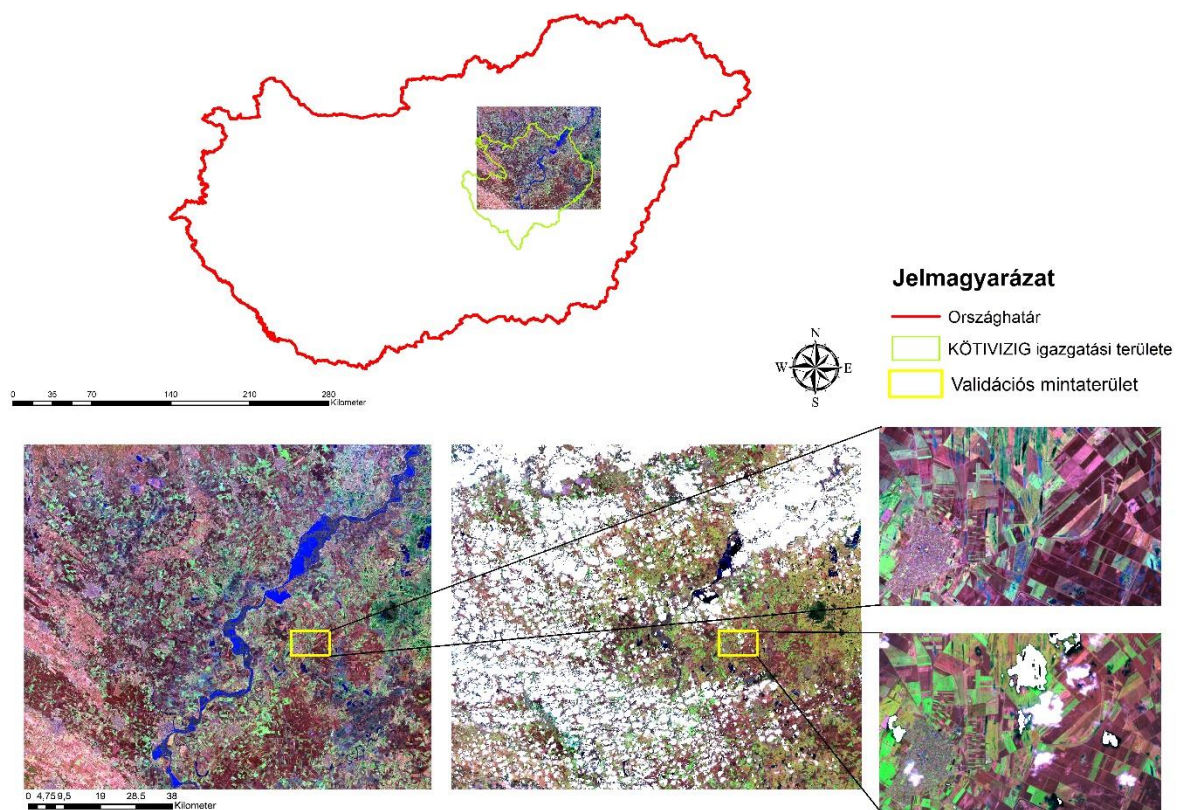
Van Leeuwen et al. (2020) szerint a belvíz térképezésére és monitorozására négy fő metodikát lehet meghatározni. Az alapvető/legkézenfekvőbb módszer a belvíz foltok vizuális megfigyelése. Magyarországon az első in situ belvíz térképek a 20. század közepéről származnak. Ez a megközelítés munkaigényes, és könnyen vezethet hibákhoz a félmérési és a megfigyelési módszertanok közötti különbségek miatt. A helyszíni megfigyelések alapján nem lehetséges a nyomon követés, mivel általában csak a belvizes időszak alatt megfigyelt maximális elöntést rajzolják fel a térképre többen és többféleképpen. A térképek pontosságát nagyban befolyásolják a felmérést végzők szubjektivitása. Pálfai (2003) az elsők között készített belvizet okozó tényezőkön alapuló veszélyeztetettségi térképezést. Eredményeként elkészült az ország első belvíz-veszélyeztetettségi térképe. Azóta számos országos, regionális és helyi változata jelent meg erre a módszerre alapozva (pl. Bozán et al. 2008; Pásztor et al., 2015; Bozán et al. 2018; Laborczi et al., 2020; Bozán et al. 2021 ). Más kutatócsoportok a belvíz modellezését hidrológiai modellező szoftver segítségével is végezték el (Kozma, 2013; Bíró, 2017; Kozma 2019). Ez a megközelítés nagy mennyiségű pontos bemeneti adatot igényel, amelyek gyakran csak kis területekre állnak rendelkezésre. A modellek alkalmazása így is rendkívül költségesek (a monitorig hálózat kiépítése és fenntartása). Ezen okok miatt a belvíz kiterjedésének terepi és/vagy távérzékeléses mérése, illetve a belvíz-veszélyeztetettség meghatározása országos viszonylatban továbbra is jelentős bizonytalansággal terheltnek lehet nevezni (Rakonczai et al., 2003; Kozák, 2009; van Leeuwen, 2012). A negyedik megközelítés az belvíz térképezésére és monitorozására távérzékelési adatokon és algoritmusokon alapul. Ezek a módszerek a kis (drónok), közepes (légi felvételek) és nagy (műholdfelvételek) területekről gyűjtött adatokat használják fel a belvíz elöntések kimutatására (Gálya et al. 2016; Balázs et al., 2018; Gulácsi és Kovács 2019). A távérzékelési adatokon jól ismert, szabványosított módszerek (indexek, osztályozások) alkalmazhatók, amelyek lehetővé teszik nagy területek egységes, jó térbeli felbontású felszínfedettségi térképének osztályozott elkészítését (Gudmann et al., 2019; Szabó et al. 2021).

A kutatásunk célja egy index alapú Modified Normalized Difference Water Index (MNDWI), egy osztályozó algoritmus (Maximum Likelihood, ML), és egy konvolúciós neurális hálózat (Convolutional Neural Network, CNN) összehasonlítása a belvíz kiterjedésének és pontosságának a meghatározására egy felhős és egy nem felhős multispektrális műholdkép (Sentinel 2) alapján.

## **ANYAG ÉS MÓDSZER**

A mintaterület kiválasztása a Komplex Természeti-alapú Belvíz-veszélyeztetettségi térkép (Bozán et al., 2021) alapján Magyarország egyik legveszélyeztetettebb területére kíván fókuszálni (1. ábra). A talajtípusok magas agyagtartalma, a sok egykori eltemetett folyómeder a lefolyástalan területek teszik a belvíz elöntések által leginkább veszélyeztetetté a területet. Csapadék szempontjából az évi 500-550 mm-es mennyiség nem kiemelkedő a területen, de az éven belüli eloszlása a tél végi és a kora tavaszi időszakban jelentős (akár az évi csapadékmennyiség 30-50%-a is lehullhat) ami a talajok rossz beszivárgási tényezőjének köszönhetően a belvíz megjelenik/megjelenhet. Ez a terület a Sentinel-2-es műholdnak a T34TDT cempéje, amely többnyire a KÖTIVIZIG igazgatási területén helyezkedik el. A Sentinel-2 műhold adatai a Sentinel-2A és Sentinel-2B műholdak azonos műszereivel készülnek. Az adatokat tizenkét

spektrális sávban gyűjtik a láthatótól a rövidhullámú infravörösig. Az adatokat a vizsgált területről átlagosan 3 napos időközönként gyűjtik. Összehasonlításunkban a felhő mentes műholdkép 2021.02.23-án, míg a felhővel borított műholdkép pedig 2021.03.20-án készült.



1. ábra. A két időpontban (2021.02.23, 2021.03.20) vizsgált False Composit (B11, B8, B2) Sentinel 2-es műholdkép, valamint az azon belül kijelölt validációs terület

A metódusok alkalmazása előtt a műholdfelvételeken egy előfeldolgozási munkafolyamatot hajtottunk végre. A megfelelő felbontásba alakítottuk át az összes spektrális tartományt. Így az elkészített kompozit kép 10 m-es térbeli felbontással bír. Továbbá az Európai Űrügynökség (ESA) által elkészített SCL (Scene Classification) osztályozott képet is felhasználtuk, ami a legköri zavarok azonosítását szolgálja. Az osztályozott térkép segítségével kimaszkoltuk a felhővel és felhő árnyékkal borított területeket (3, 8, 9, 10, osztály lásd 2. ábra). Megjegyzendő, hogy ez a SCL osztályozott kép nem tökéletes az ESA becslései alapján 70-75 %-os pontossággal bír.

### 1. módszer

Vizsgálatunkban a spektrális indexek közül a módosított víz indexet (MNDWI) használtuk fel, amely az indexek sokasága közül véleményünk szerint a legjobb a vízfelületek beazonosítására. Az index képlete a következő:  $MNDWI = \frac{Green - MIR}{Green + MIR}$ , ahol a zöld (Green - Band 3), és a közeli infravörös (MIR - Middle Infrared - Band 11) különbségének és az összegének a hányadosából képezzük (Xu, 2006).

### 2. módszer

Az osztályozási modell a ML egy irányított osztályozás (Kruse et al., 1993), ahol a validációs mintaterületen különböző felszínborítottsági területeket (víz, szántó, vetés és azok árnyaltabb változatait, valamint a településeket) azonosítunk be a pontos osztályozás érdekében. Ezt követően az elkészült térképből készítünk egy bináris térképet, ahol két osztályban a víz és nem víz területek kerültek megjelenítésre.

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

2. ábra. SCL (Scene Classification) felhőmaszk osztályozás (forrás: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-2-msi/level-2a/algorithm>)

### 3. módszer


A CNN modellnek (LeCun et al., 1990) készítettünk egy tanulófelületet, de itt már csak a be-tanításhoz a víz pixelek kerültek manuálisan digitalizálásra.

Az indexnél az irányított osztályozásnál és a neurális hálónál - a küszöbértéket, a tanuló területet, és a víz pixelek bedigitalizálását - az első időpontban 2021.02.23. került meghatározásra/digitalizálásra az egységes összehasonlítás érdekében.

A vizsgálat célja, hogy megtaláljuk azt a legjobb módszert, ami a belvíz monitoring szempont-jából a legjobb eredményt adja, de nem csak felhő mentes, hanem légköri zavarokkal (felhő, felhő árnyék) terhelt felvételeken is. Mivel gyakran a belvizes időszakok rossz időjárási körülmények között nagyrészt felhős időszakokban alakulnak ki.

### EREDMÉNYEK

Első lépésként manuálisan elkészítettük az előfeldolgozott 10x10 m felbontású hamis színezetű (Band 11, Band 8, Band 2), kompozit képeken a 66 km<sup>2</sup>-es kiterjedésű validációs területre vonatkozó vízfelületet digitalizálását. A 3. ábrán látható a két időpontban digitalizált összes vízfelület. A februári időpontban (2021.02.23) a 66 km<sup>2</sup>-es mintaterületen a vízelöntés 2,26 km<sup>2</sup>-t tett ki, ami a terület 3,42 %-a. A márciusi időpontban (2021.03.20) a vízfelületek kiterjedése csökkent, valamint a felhő maszknak köszönhetően a vizsgálati terület lecsökkent 62km<sup>2</sup>-re és a vízzel borított terület 0,48 km<sup>2</sup>, ami a terület 0,78 %-át tette ki.

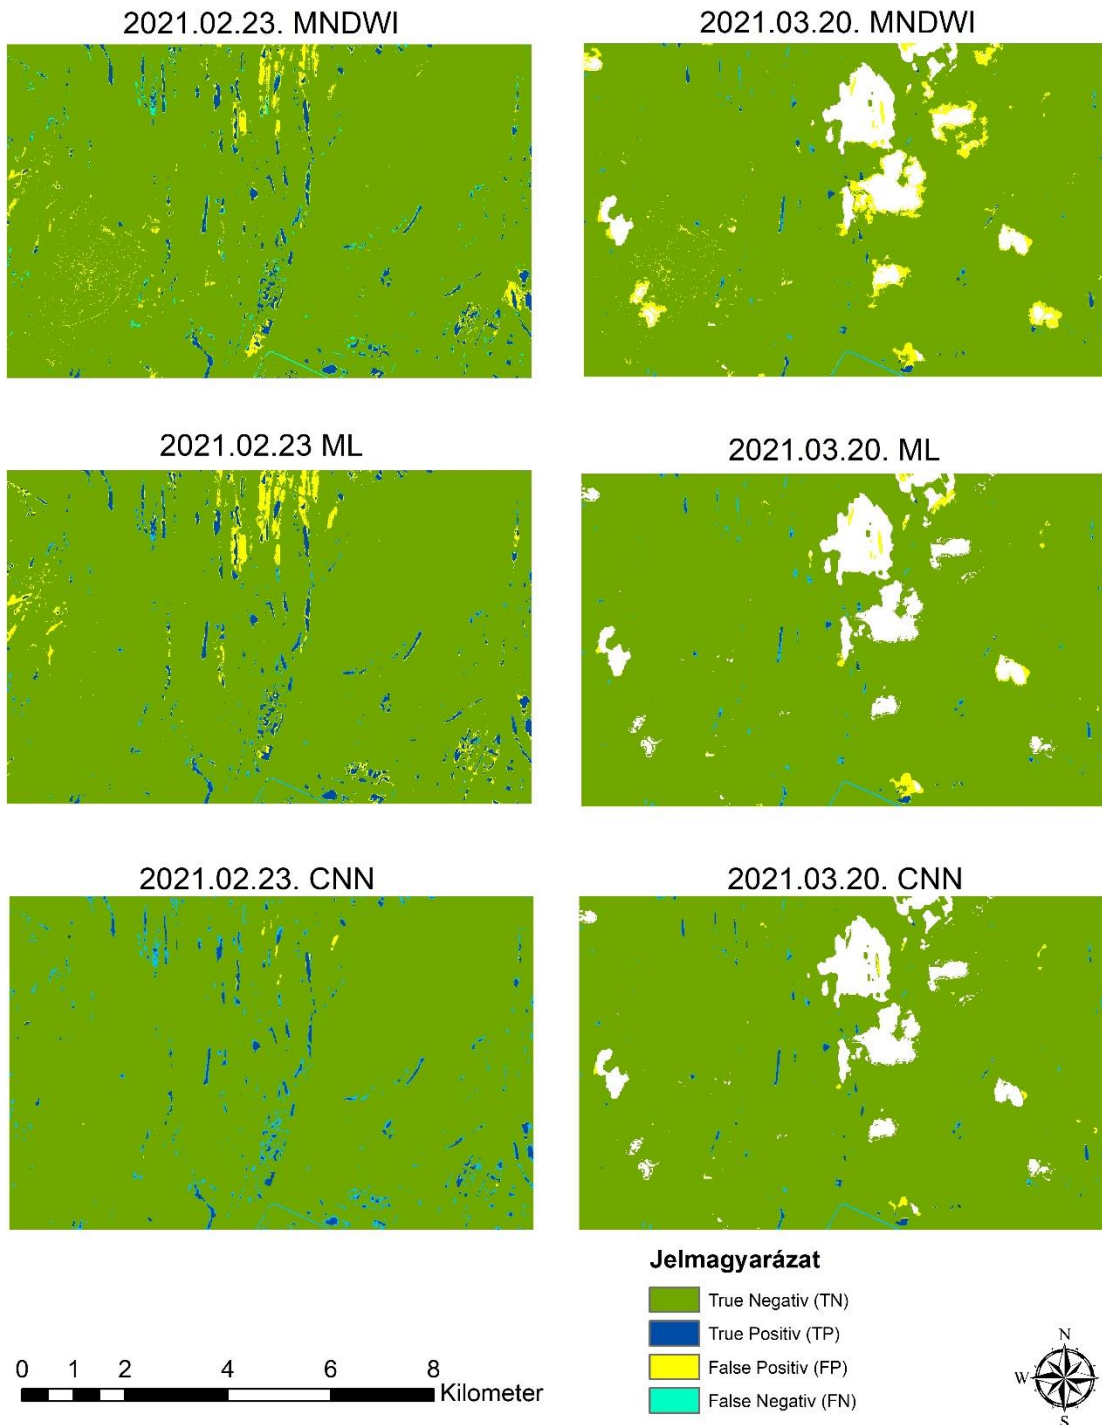


3. ábra. A validációs területeken elhelyezkedő vízfelületek

Az index számításánál empirikus módszer alapján meghatároztuk a küszöbértéket a vízfelületek lehatárolására. A ML irányított osztályozás során a víz, szántó, vetés és település felszínborítottsági területek (átlagosan 2000 pixel/kategória) alapján lett betanítva a modell, amit szintén a hamis színezetű kompozit képen határoltuk le, majd egy bináris víz és nem víz osztályozott térképet készítettünk. A CNN modellnél egy, a validációs területtől távolabbi helyen szintén manuálisan létrehozott poligonokat tartalmazó térkép alapján tanítottunk be modellt és hoztuk létre a végső eredmény térképeket. Az indexnél az irányított osztályozásnál és a konvolúciós neurális hálónál az első időpont (2021.02.23.) volt a mérvadó az összehasonlítás érdekében. A validációs térképekkel összekombinált modelleket a 4. ábrán láthatjuk. A térképek elemzéséhez az alábbi színek és kategóriák tartoznak:

- TN (True Negatív – sötétzöld) - azok a területek, ahol a validációs térképen és a modell által létrehozott térképen nem azonosítottunk vizet;
- TP (True Pozitív – sötétkék) - ahol a validáció alapján vizet azonosítottunk és a modell is vizet talált;
- FP (False Pozitív - sárga) – ahol a validációs térképen nem azonosítottunk vizet, de a modell vizet talált;
- FN (False Negatív – világoskék) – ahol a validációs térképen vizet találtunk, de azt a modell nem találta meg.





4. ábra. A modellek és a validációs térképek kombinációjának eredményei

A térképek eredményeit - abszolút pixel értékek, pontosság, érzékenység, kappa értékei - egy négyzetes mátrix segítségével számítottuk ki, amit az 1. táblázat mutat be.

A Cohen-Kappa értékek azt mutatják, hogy statisztikailag két eredmény (esetünkben a validációs térkép és a modellek eredmény térképei között) közötti megegyezést (vagyis egyetértést) számítja ki. Jól látható, hogy míg az első időpontban mind a 3 modell jól teljesített (MNDWI = 0,59; ML = 0,51; CNN = 0,55), addig a „zajos hatásnak” köszönhetően a második időpontban az MNDWI és ML modell a felhők kimaszkolása mellett is rosszul teljesített

(MNDWI = 0,18; ML = 0,30). A CNN modell bizonyult a legjobbnak (CNN = 0,54). Második helyen az irányított osztályozás végzett, és a leggyengébb eredményeket az általunk választott index adta. Összességében elmondható, hogy ha a két időpont Cohen-Kappa értékeinek az átlagát vizsgáljuk (1. táblázat utolsó sora), akkor a CNN modell „jó egyetértést” mutat, míg a másik két modell csak „alacsony egyetértést” tanúsít.

	2021.02.23			2021.03.20		
	MNDWI	ML	CNN	MNDWI	ML	CNN
True Negatív (TN)	623814	621099	637612	597797	612189	615134
False Positiv (FP)	14586	17301	788	18727	4335	1390
False Negatív (FN)	6309	5577	13484	2349	3168	2514
True Positiv (TP)	16251	16983	9076	2471	1652	2306
Teljes pontosság	0,97	0,97	0,98	0,97	0,99	0,99
Érzékenység	0,72	0,75	0,40	0,51	0,34	0,48
Pontosság	0,53	0,50	0,92	0,12	0,28	0,62
Cohen-Kappa	0,59	0,51	0,55	0,18	0,30	0,54
Cohen-Kappa átlag	0,39	0,40	0,54			

*1. táblázat. A validációs térképek és az eredmény térképek kombinációjából számított értékek*

A vizsgálatunk kimutatja, ha egy automatizálni kívánt modellt szeretnénk kialakítani, ahol a manuális beavatkozásokat minimálisra szeretnénk csökkenteni akkor a CNN modell alkalmazása indokolt. Az indexek-nél a probléma, hogy minden alkalommal egy új küszöbérték meghatározásával lehetne csak jó vagy jobb eredményt elérni, de itt a felhasználó szubjektív döntésén sok minden múlhat. Az irányított osztályozásnál a felszínborítottság folyamatosan változik főleg a vegetációs időszakot tekintve, így ott is folyamatos korrigálásra lenne szükség. A konvolucios neurális hálónál a modell felépítésénél csak a vízfelületek adják a bemeneti adatokat, amit csak egyszer kell elkészíteni, így képes folyamatosan közel azonos minőségű és pontosságú eredményt elérni.

**KÖVETKEZTETÉSEK**

Az eredményeink tükrében elmondható, hogy a legpontosabb modellnek a CNN adódott. A modell használata lehetővé teszi, hogy a Sentinel-2 relatív gyors (3-4 nap) visszatérési idejét kihasználva minél több felvétel felhasználható legyen a belvíz evolúciós vizsgálatára. Irodalmi közlések alapján elmondható, hogy a kutatók nem mindig használják fel azokat a felvételeket, ahol felhőborítottság van. A pontosság csökkenése miatt, amit a felhők és azok árnyékai okoznak, limitálják a folyamatos megfigyelést. Kijelenthetjük továbbá, hogy módszerünkkel elég nagy pontossággal modellezhető a belvizes területek kiterjedése és tartóssága, valamint a vizsgálat kiterjeszhető akár egy egész műholdfelvételtre, vagy annál nagyobb területre. A hosszú idősoros elemzések és később monitoring rendszer kialakítását alapozhatja meg.

**KÖSZÖNETNYILVÁNÍTÁS**

A kutatást a MATE ÖVKI „A mezőgazdasági vízgazdálkodás fejlesztését (öntözéses gazdálkodás, belvízgazdálkodás, földhasználat racionalizálás) célzó kutatások” c. programja, a MATE Kutatói Utánpótlást Elősegítő Programja, valamint a WATERatRISK projekt (HUSRB/1602/11/0057) támogatta.

## Felhasznált irodalom

- Balázs, B., Bíró, T., Dyke, G., Singh, S.K., Szabó, S. (2018): Extracting water-related features using reflectance data and principal component analysis of Landsat images. *Hydrol. Sci. J. J. Des Sci. Hidrol.* 63, 269-284.
- Bíró, T. (2017): Amikor sok víz van a területen – belvív. *Magyar tudomány: [a Magyar Tudományos Akadémia Értesítője]*. 178. 1216-1227. 10.1556/2065.178.2017.10.5.
- Bozán, Cs, Körösparti, J, Pásztor, L, Kuti, L, Pálfai, I (2008): Mapping of excess water hazard in the region of South Hungarian Great Plain, Slovenian National Committee for the IHP UNESCO. 1 p.
- Bozán, C., Takács, K., Körösparti, J., Laborczi, A., Túri, N., Pásztor, L. (2018): Integrated spatial assessment of inland excess water hazard on the Great Hungarian Plain. *Land Degradation and Development* 29: 4373-4386, doi:10.1002/ldr.3187.
- Bozán Cs., Körösparti J., Túri N., Kerecsi Gy., Kajári B., Pásztor L. (2021): AKK Belvízi veszélyeztetettség felülvizsgálata Stratégiai foratókönyvek , 144 p.
- Gálya B., Riczu P., Blaskó L., Tamás J. (2016): Belvív érzékenység vizsgálata radar adatok alapján. In *Theory Meets Practice in GIS*; Balázs, B., Ed.; University of Debrecen, Debrecen, Hungary. pp. 161-168.
- Gudmann A., Mucsi L., Henits L. (2019): A CORINE felszínborítási térkép automatikus előállításának lehetősége döntésifa-osztályozó segítségével. *Geodézia és Kartográfia* 71(2), pp. 9-13.
- Gulácsi, A., Kovács, F. (2019): Radar alapú vizes élőhely-monitoring Sentinel-1 adatokkal. *Hidrologiai Közöny* 99, 38-47.
- 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, DOI: 10.1080/01431160600589179
- Kozák P. (2009): Belvízi kockázat térképezés végrehajtásának eddigi tapasztalatai. *MHT 27. Országos Vándorgyűlés, Baja*, ISBN 978-963-8172-23-5.
- Kozma Z. (2019): A síkvidéki hidrológia és a belvív vizsgálata folyamat alapú modellezéssel: Kihívások és lehetőségek. *Hidrológiai Közöny* 99, 28–39.
- Kozma Zs. (2013): Belvízi szélsőségek kockázatalapú értékelésének és modellezési módszertanának fejlesztése. *Doktori értekezés (PhD)*, Budapesti Műszaki és Gazdaságtudományi Egyetem, Budapest.
- 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.
- KSH (2021) [https://www.ksh.hu/stadat\\_files/mez/hu/mez0008.html](https://www.ksh.hu/stadat_files/mez/hu/mez0008.html)
- Kruse, F., Lefko, A.B., Boardman, J., Heidebrecht, K.B., Shapiro, A.T., Barloon, P.J., Goetz, A. (1993): The spectral image processing system (SIPS)-interactive visualization and analysis of imaging spectrometer data. *Remote Sens. Environ.* 44, 145-163.
- 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. pp. 396-403.
- Laborczi, A., Bozán, Cs., Körösparti, J., Szatmári, G., Kajári, B., Túri, N., Kerecsi, Gy., Pásztor, L. (2020): Application of Hybrid Prediction Methods in Spatial Assessment of Inland Excess Water Hazard *ISPRS INTERNATIONAL JOURNAL OF GEO-INFORMATION*: 4 Paper: 268. 9p.
- Pálfai I. (2001): A belvív definíciói. *Vízügyi Közlemények* 83 (3): 376-392.
- Pálfai I. (2004): Belvizek és aszályok Magyarországon: hidrológiai tanulmányok. Budapest, Közlekedési dokumentációs Kft., 99 p.
- Pálfai I. (2003): Magyarország belvív-veszélyeztetettségi térképe. *Vízügyi Közlemények* 85, 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, 636-644, doi:10.1080/17445647.2014.954647.
- Rakonczi J., Csató Sz., Mucsi L., Kovács F., Szatmári J. (2003): Az 1999. és 2000. évi alföldi belvív-elöntések kiértékelésének gyakorlati tapasztalatai. *Vízügyi Közlemények*, 85. évf. 4. különszám. 317-336.
- Somlyódy, L. (2011): Magyarország vízgazdálkodása: helyzetkép és stratégiai feladatok. Budapest: Magyar Tudományos Akadémia, Köztisztviselési Stratégiai Programok.
- Szabó, L., Abriha, D., Phinzi, K., Szabo, Sz. (2021): Urban vegetation classification with high-resolution PlanetScope and SkySat multispectral imagery. *Landscape & Environment*. 15. 66-75. 10.21120/LE/15/1/9.
- Tamás, J. (2000): *Térinformatika I.* Debreceni Egyetem, ATC-MTK. Debrecen.
- Van Leeuwen, B. (2012): Mesterséges neurális hálózatok és földrajzi információs rendszerek használata a belvív-osztályozásban. *Doktori (PhD.) értekezés*, Szegedi Tudományegyetem, Szeged.
- 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 Paper: 2854, 21 p.