

GÉPI TANULÁSI MÓDSZEREK AZ ASZÁLY ÉS BELVÍZ MONITORING ÉS ELŐREJELZÉS FEJLESZTÉSÉBEN

BLANKA-VÉGI VIKTÓRIA – TOBAK ZALÁN – KAJÁRI BALÁZS – SIPOS GYÖRGY
– BARTA KÁROLY – KOVÁCS FERENC – BOUDEWIJN VAN LEEUWEN

MACHINE LEARNING METHODS TO IMPROVE DROUGHT AND INLAND
WATER MONITORING AND FORECASTING

Abstract

As climate change is expected to lead to more extreme hydrological events, monitoring and forecasting these events is of key importance for understanding the processes and planning prevention activities. In our research, we tested machine learning algorithms integrating satellite and field data as well as map information, with XGBoost (eXtrem Gradient Boosting) providing the best results. The accuracy of the model developed for inland water forecasting is 86%, which allows the operational use of the data provided by the model in protection and planning. The algorithm developed for soil moisture estimation and the observed Sentinel-1 S1SSM values show good agreement, especially in areas with less heterogeneous land use (e.g. fields and pastures). Our results suggest that integrated machine learning methods can be an effective tool for predicting and monitoring inland water and soil moisture, contributing to improved water management and effective conservation.

Keywords: hydrological extremes, soil moisture, inland water, machine learning, Sentinel-1, XGBoost

Bevezetés

A hidrológiai szélsőségek, mint például az aszály, a belvíz vagy az árvíz, komoly kihívást jelentenek a mezőgazdaság, vízgazdálkodás, és a természeti területek kezelése és fenntartása számára. Éppen ezért a talaj vízháztartásának tér- és időbeli dinamikáját értékelő részletes információk és a szélsőséges éghajlati események előrejelzése kiemelt jelentőséggel bírnak az érintett területeken (KUTI, L. et al. 2006; LI, Q. Q. et al. 2007; ROBINSON, D. A. et al. 2008; VEREECKEN, H. et al. 2018). Ezen szélsőséges hidrológiai események hatásainak értékelésére számos módszer létezik, beleértve a meteorológiai és hidrológiai adatok elemzését, a növényzet állapotának felmérését, valamint a műholdas vagy légi távérzékelési adatok feldolgozását. A hidrológiai szélsőségek kialakulásának monitorozása, előrejelzése és a vízkészletekre gyakorolt hatásuk mennyiségi értékelése azonban még jelenleg is számos kihívást tartogat. A vízgazdálkodás tervezését és irányítását hatékonyan segítheti, ha az aszály, a belvíz, vagy az árvíz kialakulását jelző mutatók változását követni és számszerűsíteni lehet. Ezt azonban jelentősen megnehezíti a talajnedvesség nagy tér-időbeli változékonysága (KOSTER, R. D. et al.

2004; LABORCZI, A. et al. 2020), ezért jelenleg nem állnak rendelkezésre részletes és térben és időben folytonos információk a talaj hidrológiai állapotáról.

A probléma egyik lehetséges megoldása a multispektrális, a passzív és aktív mikrohullámú (radar), valamint a termikus távérzékelési adatok alkalmazása. Felhasználásukat azonban nehezíti, hogy mindegyik megfigyelési elvnek megvannak az előnyei és hátrányai. A mikrohullámú adatok térbeli felbontása kisebb, azonban időjárástól független észlelést tesznek lehetővé. az optikai műholdfelvételek nagyobb térbeli részletességgel jelenítik meg a földfelszín jellegzetességeit, viszont sajátos problémájuk, hogy felhős időben nem állnak rendelkezésre értékelhető adatok. Ezért a vízgazdálkodásban és a mezőgazdaságban történő operatív alkalmazásukat javítani kell.

A gépi tanulási módszerek alkalmazása fejlesztési lehetőséget nyújthat a térben és időben gyorsan változó, nehezen monitorozható és előrejelezhető környezeti problémák nagy adathalmazokon (big data) alapuló vizsgálatában, ezért a földtudományi alkalmazásokban is egyre nagyobb térnyerése figyelhető meg (LECCUN, Y. et al. 1990; GIULIA C. et al. 2023; YICHEN, L. et al. 2022; SANCHEZ, S. et al. 2022).

A kutatás célja olyan gépi tanuláson alapuló modellek kifejlesztése és tesztelése, amely a talajnedvesség és a belvíz vizsgálatára műholdas távérzékelt adatokat, valamint terepen mért és térképi adatokat integrál a folyamatok tér-időbeli változásainak becslésére egy olyan területen, amely aszályos és belvizes időszakokkal is érintett és fokozódó mértékben van kitéve a szélsőséges hidrológiai eseményeknek.

Mintaterület

A vizsgálatokat Dél-Alföldi mintaterületen végeztük, mivel az ország ezen területe a leginkább kitéve a hidrológiai szélsőségeknek, mint az aszály és a belvíz. Az éghajlatváltozás és a természetföldrajzi adottságok miatt a régió vízháztartása szélsőséges, a szélsőséges hidrológiai helyzetek tér- és időbeli előfordulása és mértéke is fokozódik, ami egyre gyakoribb és súlyosabb aszályos (pl. 2000, 2003, 2007, 2012, 2015, 2022) és belvizes (pl. 2000, 2006, 2010, 2011, 2013) helyzeteket eredményez. Ezek egymást követő években vagy akár ugyanabban az évben is előfordulhatnak.

A talajnedvesség vizsgálatok a Dél-Alföld Tisza vízgyűjtőhöz tartozó területét fedik le (1. ábra). Ez a terület jó lehetőséget kínál a vizsgálatokhoz, mivel tájtypus, talaj, földhasználat és a növényzet szempontjából is változatos. Emellett a terepi adatok szolgáltató Országos Vízügyi Főigazgatóság Operatív Vízhány Értékelő és Előrejelző Monitoring Rendszerének állomás sűrűsége a vizsgált területen a legnagyobb (40 állomás található a vizsgált területen) (FIALA, K. et al 2018).


A belvíz azonosítására kidolgozott módszer tesztelésére egy 1600 km²-es területet jelöltünk ki Mezőtúrtól EK-re. A terület a síksági karakter

ellenére igen változatos morfológiával rendelkezik pl. elhagyott folyómedrek találhatók itt, melyeket iszapos-agyagos üledékek töltenek ki. A rossz vízgazdálkodású talajok miatt gyakran aszályok és belvizek is sújtják a területet.

Módszerek

A talajnedvesség és a belvíz értékeléséhez műholdas, valamint dinamikus terepi adatokat, és statikus térképi információkat integráló gépi tanulási módszereket teszteltünk. A talajnedvesség vizsgálatához távérzékelt és terepi talajnedvesség adatokat, valamint talajnedvességre hatással lévő fontosabb környezeti paramétereket (talaj tulajdonságok, meteorológiai adatok és vegetáció) vizsgáltuk 2021–2023 közötti időszakra. A távérzékelt talajnedvesség a Sentinel-1 SSM1km 1km-es felbontású terméke volt, ami a talaj felső 5 cm-re szolgáltat adatot 2–4 naponként. A 10 cm mélységben mért terepi talajnedvesség és a meteorológiai adatok (napi csapadék, hőmérséklet és párolgás) az OVF monitoring rendszerének állomásairól származtak. A talaj tulajdonságok jellemzésére a 100 m felbontású HU-SoilHydroGrids adatait használtuk (a talaj maximális vízkapacitása (%) (THS), szabadföldi vízkapacitása (%) (FC), és holtvíz tartalma (%) (WP) hidraulikus vezetőképessége (KS) (SZABÓ, B. et al. 2024). A növénytakaró felszíni talajnedvességre gyakorolt hatásának értékeléséhez Sentinel-2 műhold adataiból származtatott havi NDVI adatokat használtunk.

A kutatás során négy gépi tanulási módszert vizsgáltunk a talajnedvesség becslésére: Multi Linear Regression (MLR), Support Vector machine Regression (SVR), eXtreme Gradient Boosting (XGBoost) és Deep Neural Network (DNN). A létrehozott adatbázisban a függő vál-



1. ábra A talajnedvesség és belvíz vizsgálatok mintaterülete
Figure 1 Study area of the soil moisture and inland excess water analyses

tozót és az alkalmazott 12 független változót a vizsgált 40 állomáshelyre hoztuk létre. A modellek tesztelése során a végleges adatkészletet betanítási (70%), tesztelési (20%) és validálási (10%) adatokra osztottuk.

A belvíz vizsgálatok során a tesztelt gépi tanulási módszerekkel belvíz elöntés gyakorisági térképek és előrejelzési módszerek fejlesztését céloztuk meg. A vizsgálatok során a Convolutional Neural Network (CNN), az eXtrem Gradient Boosting (XGBoost) és a Deep Neural Network (DNN) módszereket alkalmaztuk (KAJÁRI, B. et al. 2023, 2024). Ezekhez a vizsgálatokhoz a távérzékelte adatforrásokat Sentinel-1 radar és Sentinel-2 multispektrális képek szolgáltatták. A földfelszíni adatok a talajnedvesség vizsgálathoz hasonlóan magukban foglaltak meteorológiai, felszínborítás és talaj tulajdonságokat, valamint topográfiai adatokat. Műholdas adatok közül a kutatáshoz a Sentinel-1 interferometrikus Wide-Swath (IW) üzemmódban készült, 5×20 m térbeli felbontású Ground Range Detected (GRD) termékét, valamint Sentinel-2A és Sentinel-2B 13 spektrális sávot lefedő (láthatótól a közeli infravörös tartományokon át a rövidhullámú infravörösig) Level 2A terméket használtunk. Az OMSZ állomáshálózatán mért napi meteorológiai paraméterek (csapadék (mm), globálsugárzás (J/m^2), relatív nedvességtartalom (%), átlag, minimum és maximum hőmérséklet ($^{\circ}C$), valamint 10 m magasságban mért szélesség (m/s) és a számított potenciális evapotranspiráció mellett, a felszínborítást a 20×20 m felbontású NÖSZTÉP adatokkal, a talaj tulajdonságokat a 250 m felbontású European Soil Hydraulic Database (EU-SoilHydroGrids) adataival jellemeztük. A domborzatra vonatkozó információkat az 5 méteres térbeli felbontású országos digitális domborzatmodellből származtattuk. Az OpenStreetMap térképi objektumait a legközelebbi úttól, csatornától vagy településtől való távolság számításához használtuk fel. Az előállított elöntés térképek térbeli felbontása 10×10 m.

Eredmények

A felszíni talajnedvesség tér- és időbeli változékonysága

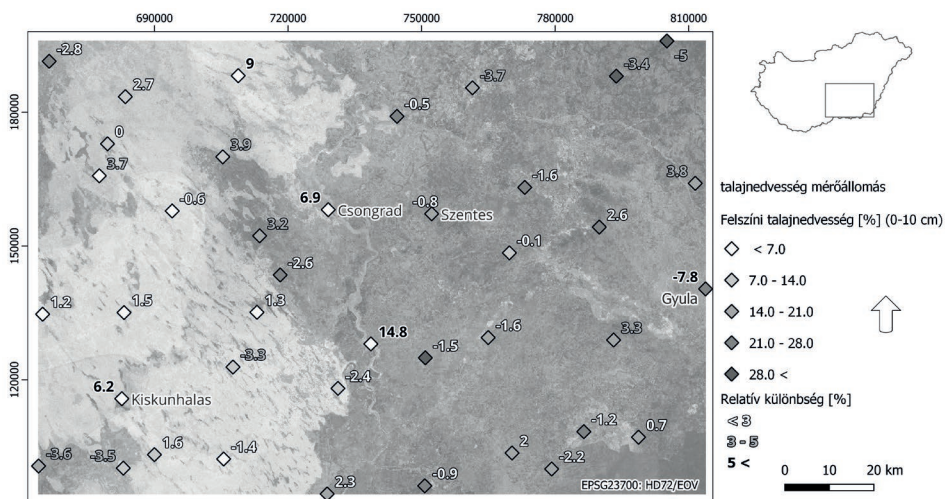
Az eredmények azt mutatják, hogy a talajnedvesség becslésére alkalmazott négy módszer szignifikánsan eltérő kapcsolatot muta-

tott a becslőt és a mért talajnedvesség-értékek között. Az eredmények közös jellemzője, hogy magasabb talajnedvesség értékek esetén gyengébb a korreláció, mint az alacsonyabb értékek esetében. Az MLR módszer szolgáltatta a legalacsonyabb korrelációs együtthatót (0,59), míg a legerősebb összefüggést (0,92) az XGBoost módszer adta. Így a részletes értékeléseket az XGBoost modellel végeztük.

Az XGBoost modellel készített 100 méteres felbontású, térben folytonos becslőt felszíni talajnedvességet (SSM = surface soil moisture) összehasonlítottuk egy kiválasztott nyári teszt-nap (2023. július 13.) földi mérőállomásokon 10 cm mélységben mért napi átlagos talajnedvesség (SM = soil moisture) értékeivel (2. ábra). A legtöbb állomáson a modellezett és a megfigyelt SM-értékek nagyfokú hasonlóságot mutatnak. Az állomások többségénél (24 állomás) a modellezett és a megfigyelt SM-érték közötti különbség 3%-nál kisebb volt, és csak 5 állomáson fordult elő 5%-nál nagyobb eltérés. Az 5 állomásból 4 esetben az állomás 100×100 méteres pixelhatár közelébe esett, és a szomszédos pixel modellezett értéke közel volt a terepen megfigyelt adatokhoz. Emellett a legtöbb esetben az állomások különböző növénytakarók határára helyezkednek el, ahol a pixel növényzete nem feltétlenül volt jellemző a mérési pontra.

Megvizsgáltuk az S1SSM műholdas termékből származó értékek és a modellel előállított folytonos becslés értékek közötti különbséget is. A terület nagy részén (45,5%) jó egyezést mutatott (10% alatti különbség) a megfigyelt és a modellezett érték. Jelentősebb (20% feletti) különbség a vizsgált terület 27,1%-án volt kimutatható. Ezek főként a terület nyugati részén és a folyók mentén helyezkedtek el. A különbségek egyik lehetséges magyarázata lehet, hogy a heterogénebb területhasználat egyes pixeleket eredményez az 1 km-es térbeli felbontású S1SSM-adatokban, amelynek pixelei így heterogén talajnedvességű területeket fednek le. További magyarázat lehet a korábban BAUER-MARSCHALLINGER, B. et al. (2019), BAZZI, H. et al. (2024), vagy SCHMIDT, T. et al. (2024) által is azonosított jelenség, hogy a műholdas talajnedvesség termékek pontossága függ a talaj és területhasználat típusától. A legnagyobb pontatlanságokat az erdők esetében azonosították.

Vizsgáltuk a független változók szerepének fontosságát és hatását a modellezési eredményekre. Ez alapján a modell kimenetét a talajparaméterek és a hőmérséklettel kapcsolatos



2. ábra A 100 méteres felbontású, térben folytonos modellezett és a terepi állomásokon mérési napjaink átlagos talajnedvesség összehasonlításának eredménye (a színek a talajnedvesség értékét, a feliratok a modellezett és a mért talajnedvesség relatív különbségét jelzik).

Figure 2 Comparison of the measured ground-based soil moisture and the 100-meter resolution continuous prediction (colours indicate the soil moisture value, captions indicate the relative difference between modelled and measured soil moisture)

adatok (az előző 7 nap átlaghőmérséklete és párolgása) kiemelkedő mértékben befolyásolják.

A belvizek előjelzése

A kidolgozott algoritmusok háromféle eredményt szolgáltatnak. Először is, megmutatják az elöntések gyakoriságát, ami alapján megállapítható a terület belvizek-veszélyeztetettsége. Másodsorban, információval szolgáltatnak a tesztelt gépi tanulási modellek alkalmazhatóságáról a belvizek borítottság feltérképezésére. Végül pedig az előrejelző algoritmus segítségével több napos előrejelzés adtak a várható elöntések térbeli helyzetére vonatkozóan.

Kutatásaink alapján (KAJÁRI, B. et al. 2023) a belvizek előjelzési térképek előállításához a CNN módszer adja a legjobb eredményt. A CNN-modell tovább előnye, hogy robusztus és újra felhasználható más időintervallumot érintő adatokon, ami az idősoros vizsgálatoknál fontos tényező (3. ábra).

A tesztelt XGBoost és DNN modellek közül előrejelzés készítésére az XGBoost modell bizonyult alkalmasabbnak. Ez a modell valamivel jobb pontossággal és sokkal nagyobb hatékonysággal rendelkezett, mivel a betanítás és a modellfuttatás az XGBoost-tal lényegesen

gyorsabb volt. Következésképpen ezt a modellt alkalmaztuk a belvizek előjelzésére egy 9 napos elöntési időszak alatt, 2021. február 15–23. között. A február 15-ére vonatkozó vízborítást műholdas adatokból CNN módszerrel számítottuk. A következő napok előrejelzéséhez mindig az előző napok modell adatait használtuk. Az előrejelzési eredmények validálására műholdképek alapján készült vízborítási térképeket használtunk (KAJÁRI et al. 2024). A modell működésének jobb megértésére és a hibák lehetséges forrásainak azonosítására az eltéréseket mutató hibaterkép készült. A téves pozitív eredmények általában a nagyobb vízfoltok szélénél, valamint a sekély, időszakosan kiszáradó vízfelületek és telített talaj esetén jelentek meg, ami a modell nedves talajokra való érzékenységére utal. Téves negatív eredmény a kicsi, keskeny elöntés foltoknál volt jellemző, ami a térbeli felbontás (10 m) korlátaival magyarázható.


Összefoglalás

A műholdas és terepi adatokat, valamint térképi információkat integráló gépi tanulási módszerek komoly lehetőséget rejtenek magukban mind a belvizek, mind a talajnedvesség monitorozása és előrejelzése tekintetében. A tesztelt

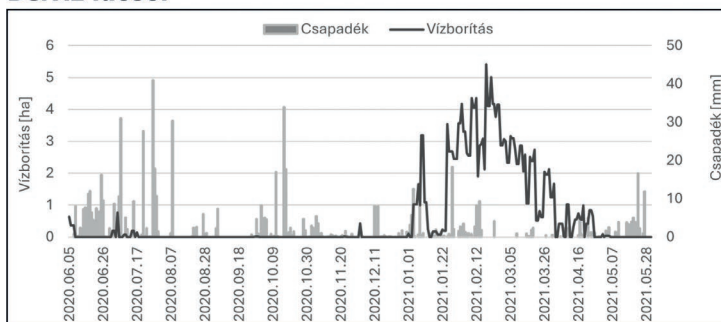
Belvíz gyakorisági térkép



Belvíz előrejelzés



Belvíz idősor



3. ábra a) Belvízi elöntés gyakorisága és b) előrejelzett elöntések, valamint a c) belvízborítás kiterjedése és az időszak csapadék mennyisége a 2020. júniusától 2021. májusáig egy kiválasztott területen (KAJÁRI, B. et al. 2024 alapján)

Figure 3 a) Inland excess water inundation frequency and b) predicted inundations, and c) Inland excess water coverage and precipitation amount between June 2020 and May 2021 in a selected area (based on KAJÁRI, B. et al. 2024)

algoritmusok közül a belvíz előrejelzésére, és a talajnedvesség monitorozásra is az XGBoost algoritmus adta a legjobb eredményt. Mindkét XGBoost algoritmuson alapuló modell megfelelő eredményt szolgáltatott. A belvíz előrejelzésére kidolgozott modell pontossága 86%, így a modell által szolgáltatott adatok felhasználhatók a belvíz elleni védekezéssel kapcsolatos

operatív intézkedésekhez, valamint az elöntések megelőzését célzó tevékenységek tervezéséhez. A talajnedvesség becslésére kifejlesztett algoritmus és a megfigyelt Sentinel-1 S1SSM értékek jó egyezést mutatnak (kevesebb mint 10% eltérés) a kevésbé heterogén, jellemzően mezőgazdasági művelés alatt álló területeken (pl. szántóföldek, szőlőültetvények, legelők). A talajnedvesség

becslésére tehát mind a kifejlesztett algoritmus, mind az SSISSM-adatok jól használhatók.

A bemutatott modellek jó teljesítménye ellenére mindkét esetben azonosíthatók korlátozó tényezők a bemeneti adatokkal (az alkalmazott terepi és műholdas adatok, valamint egyéb térképi adatok tér- és időbeli felbontása, pontossága), az előfeldolgozással és a modellezéssel kapcsolatban is.

A talajnedvesség esetében a heterogénebb földhasználati típusokkal (pl. erdők, települések) és/vagy talajtípusokkal (homokos talajok) rendelkező területeken mind a modell, mind a műholdadat alapú SSISSM termék már kisebb megbízhatóságú. Emellett a bemutatott modell térbeli kiterjesztésének lehetősége további vizsgálatokat és fejlesztéseket igényel. A jövőbeli elemzések középpontjában az eltérő környezeti jellemzőkkel rendelkező területek és további adatforrások bevonásának tesztelése, valamint a szezonálisan változó meteorológiai és vegetációs adatok modell eredmények pontosságára gyakorolt hatásának értelmezése áll.

A belvízi elöntés előrejelzés eredményére jelentős hatása van a CNN-modellen alapuló osztályozási térképek pontosságának, mivel ezek képezik az előrejelzések alapját. Ezeknek a térképeknek a pontossága ugyan magasnak bizonyult, de erősen függ a rendelkezésre álló Sentinel-1 és/vagy Sentinel-2 adatoktól. A hiányzó műholdas adatok növelik az időbeli interpoláció szükségességét, ami az előrejelzés pontosságának csökkenését eredményezhetik. A módszer előnye a statikus belvíz veszélyeztettségi térképekkel szemben, hogy az előrejelzés alapját képező belvíz elöntési gyakorisági térképeket dinamikusan frissíti, amikor új adatok állnak rendelkezésre.

Köszönetnyilvánítás

A kutatást a Víztudományi és Vízbiztonsági Nemzeti Labor (RRF-2.3.1-21-2022-00008) projekt támogatta.

BLANKA-VÉGI VIKTÓRIA
SZTE Geoinformatikai, Természet- és Környezetföldrajzi Tanszék, Szeged
Víztudományi és Vízbiztonsági Nemzeti Laboratórium, Budapest
blankav@geo.u-szeged.hu

TOBAK ZALÁN
SZTE Geoinformatikai, Természet- és Környezetföldrajzi Tanszék, Szeged
Víztudományi és Vízbiztonsági Nemzeti Laboratórium, Budapest
tobak@geo.u-szeged.hu

KAJÁRI BALÁZS
SZTE Geoinformatikai, Természet- és Környezetföldrajzi Tanszék, Szeged
Magyar Agrár- és Élettudományi Egyetem, Környezettudományi Intézet, Öntözési és Vízgazdálkodási Kutatóközpont, Szarvas
kajari.balazs@ovki.naik.hu

SIPOS GYÖRGY
SZTE Geoinformatikai, Természet- és Környezetföldrajzi Tanszék, Szeged
Víztudományi és Vízbiztonsági Nemzeti Laboratórium, Budapest
gysipos@geo.u-szeged.hu

BARTA KÁROLY
SZTE Geoinformatikai, Természet- és Környezetföldrajzi Tanszék, Szeged
Víztudományi és Vízbiztonsági Nemzeti Laboratórium, Budapest
barta@geo.u-szeged.hu

KOVÁCS FERENC
SZTE Geoinformatikai, Természet- és Környezetföldrajzi Tanszék, Szeged
kovacsf@geo.u-szeged.hu

BOUDEWIJN VAN LEEUWEN
Víztudományi és Vízbiztonsági Nemzeti Laboratórium, Budapest
Bay Zoltán Alkalmazott Kutatási Közhasznú Nonprofit Kft. Biotechnológiai Divízió, Szeged
leeuwen@geo.u-szeged.hu

IRODALOM

- BAUER-MARSHALLINGER, B.–FREEMAN, V.–CAO, S.–PAULIK, C.–SCHAUFLER S.–STACHL, T.–MODANESI, S.–MASSARI, C.–CIABATTA, L.–BROCCA, L.–WAGNER, W. 2019: Toward Global Soil Moisture Monitoring With Sentinel-1: Harnessing Assets and Overcoming Obstacles. – IEEE Transactions on Geoscience and Remote Sensing 57. 1. pp. 520–539. <https://doi.org/10.1109/TGRS.2018.2858004>

- BAZZI, H. – BAGHDADI, N. – NINO, P. – NAPOLI, R. – NAJEM, S. – ZRIBI, M. – VAUDOUR, E. 2024: Retrieving Soil Moisture from Sentinel-1: Limitations over Certain Crops and Sensitivity to the First Soil Thin Layer. – *Water* 16. 40. <https://doi.org/10.3390/w16010040>
- FIALA K. – BARTA K. – BENYHE B. – FEHÉRVÁRY I. – LÁBDY J. – SIPOS GY. – GYÖRFFY L. 2018: Operatív aszály- és vízhiánykezelő monitoring rendszer. – *Hidrológiai Közlöny* 98. 3. pp. 14–24.
- 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 <https://doi.org/10.3390/land12040879>
- 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>
- KOSTER, R. D. – DIRMEYER, P. A. – GUO, Z. – BONAN, G. – CHAN, E. – COX, P. – YAMADA, T. 2004: Regions of strong coupling between soil moisture and precipitation. – *Science* 305. 5687. pp. 1138–1140. <https://doi.org/10.1126/science.1100217>
- KUTI, L. – KERÉK, B. – VATAI, J. 2006: Problem and prognosis of excess water inundation based on agrogeological factors. – *Carpath. J. Earth Environ. Sci.* 1. pp. 5–18.
- LABORCZI, A. – BOZÁN, C. – KÖRÖSPARTI, J. – SZATMÁRI, G. – KAJÁRI, B. – TÚRI, N. – KERESZI, 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. <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.
- LI, Q. Q. – CHEN, Y. H. – LIU, M. Y. – ZHOU, X. B. – DONG, B. D. – YU, S. L. 2007: Effect of Irrigation to Winter Wheat on the Soil Moisture, Evapotranspiration, and Water Use Efficiency of Summer Maize in North China. – *Transactions of the ASABE*. 50. 6. pp. 2073–2080. <https://doi.org/10.13031/2013.24109>
- ROBINSON, D. A. – CAMPBELL, C. S. – HOPMANS, J. W. – HORNBUCKLE, B. K. – JONES, S. B. – KNIGHT, R. – OGDEN, F. – SELKER, J. – WENDROTH, O. 2008: Soil Moisture Measurement for Ecological and Hydrological Watershed-Scale Observatories: A Review. – *Vadose Zone Journal* 7. pp. 358–389. <https://doi.org/389.10.2136/vzj2007.0143>
- 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. <https://doi.org/10.3390/rs14215373>
- SCHMIDT, T. – SCHRÖN, M. – LI, Z. – FRANCKE, T. – ZACHARIAS, S. – HILDEBRANDT A. – PENG, J. 2024: Comprehensive quality assessment of satellite- and model-based soil moisture products against the COSMOS network in Germany. – *Remote Sensing of Environment*, 301. 113930. <https://doi.org/10.1016/j.rse.2023.113930>
- SZABÓ, B. – MÉSZÁROS, J. – LABORCZI, A. – TAKÁCS, K. – SZATMÁRI, G. – BAKACSI, ZS. – MAKÓ, A. – PÁSZTOR, L. 2024: From EU-SoilHydroGrids to HU-SoilHydroGrids: A Leap Forward in Soil Hydraulic Mapping. – *Science of Total Environment* 921.171258. <https://doi.org/10.1016/j.scitotenv.2024.171258>
- VERECKEN, H. – HUISMAN, J. A. – PACHEPSKY, Y. – MONTZKA, C. – VAN DER KRUK, J. – BOGENA, H. – WEIHERMÜLLER, L. – HERBST, M. – MARTINEZ, G. – VANDERBORGH, J. 2014: On the spatio-temporal dynamics of soil moisture at the field scale. – *Journal of Hydrology*. 516. pp. 76–96, <https://doi.org/10.1016/j.jhydrol.2013.11.061>
- 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. pp. 1321–1343. <https://doi.org/10.1080/15481603.2022.2112391>