

*Van Leeuwen Boudewijn – Tobak Zalán – Szatmári József<sup>1</sup>*

## BELVÍZ OSZTÁLYOZÁS HAGYOMÁNYOS MÓDSZERREL ÉS MESTERSÉGES NEURÁLIS HÁLÓVAL

### BEVEZETÉS

Magyarország, különösen pedig az Alföld váltakozva szenved aszályos periódusoktól és elöntésektől. A legutóbbi csapadékos időszak 2009 ősztől 2010/2011 teléig tartott, amikor nagy területek kerültek belvízelöntés alá. A legnagyobb kiterjedése a mezőgazdasági területek 11%-át tette ki. A belvív leggyakrabban tél végén jelentkezik, a csapadékviszonyok és a hóolvadás miatt. Emellett azonban az év bármely időszakában megjelenő elöntés komoly mezőgazdasági károkat okoz. A belvíznek számos definíciója létezik, melyek közül egy általánosabb megközelítés szerint: "A belvív lokális mélyedésekben megjelenő időszakos vízborítás, amelyet a lefolyás hiányából következő vízfelesleg, az elégtelen párolgás, valamint a talaj alacsony vízelvezetési képességének kombinációja vagy a feláramló talajvíz okoz" (Van Leeuwen 2012). A jelenséget előidéző tényezők között természetes, relatíve állandó – mint amilyenek a talaj és a domborzat –, dinamikusán változó – mint például a csapadék és a hőmérséklet – és antropogén – mint a területhasználat – is előfordul. Ezek az egymással kapcsolódó faktorok komplex rendszert alkotnak. Az egyes tényezők hatása nehezen mérhető. A belvív előfordulásának meghatározásával számos kutatás foglalkozott. Jelen tanulmányunkban a hagyományos, pixel alapú osztályozásokat egy neurális hálózatokon alapuló új klasszifikációs eljárással hasonlítjuk össze, melyben a mesterséges neurális hálózat (ANN) és a földrajzi információs rendszer (GIS) egy keretrendszerben integrálódik (Van Leeuwen et al. 2010). Az ANN különböző típusú bemeneti adatok sokaságát képes kezelni, ami a tradicionális osztályozásokkal nem lehetséges. Az eredmények összehasonlíthatósága érdekében minden osztályozásnál ugyanazon 3 sávós, színes-infravörös (CIR) légifelvételt használtuk fel, amelyet kisformátumú digitális kamerával (Tobak et al. 2008) készítettünk a Szeged melletti, belvízzel veszélyeztetett mintaterületről.

### MÓDSZEREK

A komplex belvív probléma elemzéséhez fontos megérteni annak tér- és időbeli kiterjedését. Ezt két módon tehetjük meg: (1) a legfontosabb, kiválasztott tényezők hatásának becslésével, illetve (2) a tér- és időbeli eloszlás terepi vagy távérzékelésen alapuló térképezésével.

#### *Veszélyeztetettség térképezése*

Számos kutatás próbálta azonosítani a belvízképződés előidéző tényezőket, majd azokat regressziós függvények vagy egyéb lineáris statisztikai módszerek segítségével összefogni (Bozán et al. 2009, Pálfi 2003, Körösparti et al. 2009). Ezekben az esetekben a létrehozott formula súlyozott faktorai alapján került kiszámításra egy terület belvízzel szembeni veszélyeztetettsége. Az egyes tényezők súlyozása a legtöbbször ismert elöntések regresszió analíziséből vagy szakértői becslésekből származott. Lineáris regressziós függvények alkalmazásakor ez problémákat okoz. A faktorok közötti komplex funkcionális kapcsolatok ugyanakkor térben és időben is változhatnak.

---

<sup>1</sup>Van Leeuwen Boudewijn, Tobak Zalán, Szatmári József Szegedi Tudományegyetem, Természeti Földrajzi és Geoinformatikai Tanszék

6722 Szeged, Egyetem u. 2-6.

E-mail: leeuwen@geo.u-szeged.hu; tobak@geo.u-szeged.hu; szatmari@geo.u-szeged.hu

*Terepi mérések*


A belvíz természetéből adódóan a terepi (*in situ*) mérések csak kis területen végezhetőek el. Az adatgyűjtés időigényes és az egyes előtések fuzzy határai miatt hibákkal terhelt. A távérzékelés módszereit felhasználva nagy területek lefedhetőek, azt követően azonban néhány irányított osztályozási eljárás szükséges a felvételek generalizálásához és kiértékeléséhez. Kutatásunkban távérzékelte felvételek alapján egy nagyobb terület belvíz foltjait két különböző tradicionális klasszifikációs módszerrel határoltuk le. Az elsőben – a Minimum Distance módszerrel – az adott pixel és az osztályközepek minimális (spektrális térbeli) Euklidészi- és Mahalanobis-távolságát határoztuk meg. Minél kisebb a távolság, annál nagyobb az objektumok hasonlósága. Az átlagolt osztályközepek minden kategóriára a tréningadatokból származnak. Az ismeretlen pixelek a legközelebbi osztály címkéjét kapják meg (Tso & Mather, 2009). A minimális távolságok módszere matematikailag egyszerű, nem számításgépes, de vannak korlátai. A legfontosabb, hogy érzéketlen az osztályon belüli variancia fokára (Lillesand et al. 2004). Egy pixel – a kis távolság alapján – olyan osztályba is bekerülhet, amelynek nagyon kicsi a varianciája, miközben valójában egy távolabbi, de nagyobb varianciával rendelkező osztályhoz tartozik.

A másik osztályozási eljárás a Maximum Likelihood módszer, amely statisztikailag meghatározza, hogy egy képelem mekkora valószínűséggel tartozik az egyes osztályokba, majd a legnagyobb valószínűség alapján címkézi fel a pixelt (Tso & Mather, 2009). Az eljárás az adatok többváltozós normál (Gauss) eloszlását feltételezi, aminek a műholdas szenzorok spektrális érzékenységének eloszlása általában megfelel (Lillesand et al. 2004). Más típusú adatok kezelése azonban gondot okozhat.

Mindkét osztályozási módszerrel problémák jelentkeznek azonban, ha az osztályokat magasabb szinteken összevonjuk. Ha egy területet például erdők borít, a valóságban az lombhullató és tűlevelű fákat egyaránt tartalmazhat. Ezek az osztályok a spektrális térben több (különálló?) részt fednek le. Ebben az esetben a magasabb szintű *erdő* osztály nem mutat normál eloszlást (Atkinson & Tatnall 1997).

A kombinált ANN-GIS megközelítésben sem a fent említett súlyozási problémák, sem a normál eloszlás feltétele nem jelentkeznek. A súlyozás a neurális hálózat betanításának természetes része (Van Leeuwen 2010). Így nincs gond a non-linearitással és a szubjektív emberi beavatkozással sem. Emellett az ANN-ek függetlenek az adatok statisztikai eloszlásától és a különböző bemeneti faktorok – ismeretlen – belső kapcsolataitól (Zhou 1999). Olyan esetekben is alkalmazható, amikor a vizsgált jelenség (probléma) rosszul definiált vagy nem teljesen érthető (Thirumalaiah & Deo 1998). Képesek továbbá kezelni az adatok bizonytalanságát és hiányosságait, a hibás mintavételezést, a változók közötti kolinearitást, térbeli és időbeli autokorrelációt, illetve az egyedi változók inszignifikanciáját. Ezek a problémák általánosan jelentkeznek a belvíz kutatásokban az előtési határok fuzzy természetéből és a belvíz kialakulását előidéző tényezők komplex belső kapcsolatrendszeréből adódóan.

Jelen kutatásban egy kétrétegű, back propagation betanítású, feed-forward ANN-GIS keretrendszert hoztunk létre. A hálózat 3 bemeneti neuront, 20 rejtett rétegben található neuront és 1 kimeneti neuront tartalmazott.



1.ábra Az osztályozás bemeneti adatai

A bemeneti adatok minden osztályozónál 9 mozaikolt CIR felvételből álltak. A neurális hálózat osztályozó esetében a mozaikokat 3 különálló sávra kellett szétbontani (1. ábra). A hagyományos eljárások közvetlenül be tudták olvasni a 3 sávos képeket. A mintaterületen terepi felméréssel belvízelöntéseket térképeztünk fel, amit felhasználva a pixelek két típusával tanítottuk be az osztályozót: a vízzel borított képelemekkel és az „egyéb” pixelekkkel. Az „egyéb” kategória vegyes osztálynak számított, melyben több területborítás is megjelent, mint a száraz talaj, a különböző vegetációk, utak és átmedvesedett talajok. A vizsgálódás középpontjában egy nagy kiterjedésű belvízfolt állt. A terület ÉNy-i sarkában a gát és erdők találhatóak. Szabályos úthálózat és velük párhuzamosan futó csatornák keresztezik a területet K-Ny és É-D irányban. A déli részen egy nagy állattenyésztő farm helyezkedik el. A többi részeken relatív homogén, mezőgazdasági területek vannak.

## EREDMÉNYEK


Először Minimum Distance klasszifikáció került lefuttatásra. Ennek teljes pontossága (Overall Accuracy) 67% lett, azonban jól láthatóan sok pixel helytelenül került a belvíz osztályba (36%). A képen a fehér szín a vízzel borított területeket, a fekete az el nem öntött részeket ábrázolja (2. ábra).

Másodjára a hagyományos Maximum Likelihood osztályozó algoritmust futtattuk le (3. ábra). Ennek eredménye nagy hasonlóságot mutatott a Minimum Distance klasszifikációhoz. A teljes pontosság ez esetben 69% lett, de ugyanúgy sok képelem tévesen a belvíz osztályba került (37%).




2.ábra A Minimum Distance osztályozás eredménye

A vizsgált területen mindkét algoritmus sok magasabb pixelt hibásan a belvíz kategóriába helyezett. Sokszor a fás területeket is belvíz előntésként értelmezték. Nyilvánvalóan az *el nem öntött* kategória tanulói túl heterogén mintából származtak ahhoz, hogy jobb eredményt szolgáltatassanak.



3. ábra A Maximum Likelihood osztályozás eredménye

A mesterséges neurális hálózat osztályozó eredménye a 4. ábrán látható. A teljes pontosság 74% lett, azonban a referencia belvíz pixelek 36%-a még itt is hibásan lett osztályozva. Bár vizuálisan megállapítható, hogy az ANN klasszifikáció jobb minőségű eredményt adott, ez statisztikailag nem teljesen egyértelmű (1. táblázat). A helytelenül osztályozott képelemek főként a nagy belvíz folttól keletre találhatók. Ezen a területen a átnedvesedett talajokat találhatunk.



4. ábra A mesterséges neurális hálózattal végzett osztályozás eredménye

A különböző módszerekkel végrehajtott osztályozások eredményeinek statisztikai összehasonlítására 300, véletlenszerűen kijelölt pontból álló független mintát használtunk fel, melynek 50% belvízzel borított, 50%-a pedig száraz területre került. Az eredmények az 1. táblázatban láthatók.

*1.táblázat Az osztályozások pontossága*

	Helyesen osztályozott belvíz	Helyesen osztályozott száraz terület	Összes belvíz	Összes száraz terület	Teljes pontosság
MD	119	83	186	114	67 %
ML	135	72	213	87	69 %
ANN	93	128	115	185	74 %

Összességében megállítható, hogy három távérzékelte bemeneti adatréteg esetében a hagyományos és az ANN osztályozások eredményei meglehetősen hasonló. Korábbi kutatások (Van Leeuwen 2012) rámutattak, hogy a klasszifikáció eredménye további bemenő információk hozzáadásával – mint amilyenek a helyi mélyedések, az antropogént objektumoktól mért távolság, a talajtípus – javítható. Ily módon 90% feletti pontosság érhető el. A távérzékelte adatrétegek és a velük nem kompatibilis adattípusok együttes használata ANN osztályozóval lehetséges, a hagyományos módszerekkel azonban nem megoldható.

#### **KÖVETKEZTETÉSEK**

A belvízfoltok azonosítására hagyományos a ANN osztályozási módszereket alkalmaztunk. Amennyiben csak három távérzékelte adatréteg kerül felhasználásra, az osztályozók közötti statisztikai különbség kicsi, bár vizuálisan érzékelhető az ANN megoldás jobb eredménye. Az ANN osztályozás valójában további, nem távérzékelte input rétegek, mint a felszín a relatív magassága vagy a talajtípus, bevonásával javítja jelentősen az eredményeket. Ezeket a neurális hálózatok képesek kezelni, a tradicionális osztályozók azonban csak az azonos numerikus adattípusok együttes használatát támogatják. Problémát jelent továbbá kevert osztályok kezelése, ugyanis a hagyományos módszerek az input adatok normál eloszlását feltételezik.

#### **FELHASZNÁLT IRODALOM**

- ATKINSON P.M. & TATNALL A.R.L., 1997, Introduction neural networks in remote sensing. International Journal of Remote Sensing 18, p. 699–709.
- BOZÁN Cs, KÖRÖSPARTI J., PÁSZTOR L., KUTI L., KOZÁK P., PÁLFAI I., 2009, GIS-based Mapping of excess water inundation hazard in Csongrád county (Hungary), Proceedings of the International Symposia on Risk Factors for Environment and Food Safety & Natural Resources and Sustainable Development, Faculty of Environmental Protection, November 6-7 Oradea 2009, pp. 678 – 684.
- VAN LEEUWEN B., TOBAK Z., SZATMÁRI J., BARTA K., 2010, Új módszerek alkalmazása a belvizek keletkezésének vizsgálatában és monitorozásában. In: Lóki J., Demeter G. (eds.) Az elmélet és gyakorlat találkozása a térinformatikában I, Debrecen, 121-130.
- VAN LEEUWEN B., 2012, Artificial neural networks and geographic information systems for inland excess water classification, PhD Dissertation, Szeged, 111 p.
- LILLESAND T.M., KIEFER R.W., CHIPMAN J.W., 2004, Remote Sensing and Image Interpretation, Wiley, 784 p.

- KÖRÖSPARTI J., BOZÁN CS., PÁSZTOR L., KOZÁK P., KUTI L., PÁLFAI I., 2009, GIS alapú belvíz-veszélyeztetettség térképezés a Dél-Alföldön, Magyar Hidrológiai Társaság, XXVII Országos vándorgyűlés, Baja, 1-3 július 2009
- PÁLFAI I., 2003, Magyarország belvíz-veszélyeztetettség térképe, Vízügyi közlemények 85, 3, pp. 510-524.
- TOBAK Z., SZATMÁRI J., VAN LEEUWEN B., 2008, Small format aerial photography – remote sensing data acquisition for environmental analysis, Journal of Env. Geogr I, 3-4, pp. 21-26.
- TSO B. & MATHER P., 2009, Classification Methods for Remotely Sensed Data, Second Edition, CRC Press, 376 p.
- THIRUMALAI K. & DEO M.C., 1998, Real-time flood forecasting using neural networks, Computer-Aided Civil and Infrastructure Engineering 13, pp. 101-111.
- ZHOU W., 1999, Verification of the nonparametric characteristics of backpropagation neural networks for image classification, IEEE Transactions on geoscience and remote sensing, Vol. 37, No. 2, pp. 771-779.