

SZEGEDI TUDOMÁNYEGYETEM
Természettudományi és Informatikai Kar
Földtudományok Doktori Iskola
Természeti Földrajzi és Geoinformatikai Tanszék

**Mesterséges neurális hálózatok és
földrajzi információs rendszerek használata a
belvízosztályozásban**

Doktori (PhD) értekezés tézisei

van Leeuwen Boudewijn

Témavezetők:

Dr. Szatmári József
adjunktus

Prof. Dr. Mezősi Gábor
egyetemi tanár

Szeged, 2012

Bevezetés

Földrajzi helyzetének és klímájának következtében az Alföld az aszály és az áradások folytonos veszélyének van kitéve. A 2010-es esztendő az egyik legcsapadékosabb év volt Magyarországon, melyet valaha mértek. Az Alföldön, 2009 októbere és 2010 decembere között 1149 mm csapadék hullott, ami éves szinten 919 mm-t jelentett Szegeden a 489 mm-es többéves átlaghoz képest. Az extrém csapadékmennyiség kivételesen nagy belvívelöntéseket okozott. A vízzel borított területek maximális kiterjedésüket ebben a 15 hónapos időszakban 2010. december 9-én érték el 355.000 ha-ral, ami csak a mezőgazdasági szektorban több mint 500 millió eurós kárt okozott. A belvívelöntés, a következtében kialakuló károkkal együtt – mint amilyen például a talajdegradáció – a Kárpát-medencében az egyik leggyakoribb természeti katasztrófa. Belvív okozta károk megelőzése, illetve csökkentése érdekében fontos, hogy megértsük a kialakulásának okait és ismerjük az előfordulásait.

A disszertáció fő témáját adó hidrológiai jelenségre nem létezik hivatalos angol elnevezés. Az *inland excess water* kifejezés - amit a dolgozatban mindvégig használok - a magyar *belvív* szó fordítása. Habár a belvív jelenség tudományos vizsgálatára Magyarországon vetül a legnagyobb figyelem, annak előfordulása nem korlátozódik erre a földrajzi régióra. Megjelenik például Hollandiában, Indiában, Kínában, Németországban, Olaszországban, Oroszországban, Romániában és Szerbiában is. A szakirodalmakban fellelhető nagyszámú belvív definíció a kutatásokban résztvevő számos tudományterület hatását mutatja, melyek mindegyike – mint például a vízgazdálkodás, mezőgazdaság, ökológia, tájtervezés vagy

közgazdaságtan – saját szempontjai szerint közelít a problémához. A disszertációban használt saját általános definíció a következő:

A belvíz 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.

Különböző genetikai típusú belvizek különíthetők el: (1) A vertikális típus, melyet a feláramló talajvíz okoz; (2) a horizontális típus, amely az elégtelen lefolyás, párolgás és/vagy beszivárgás következtében a helyi mélyedésekben összegyűlő csapadékból és/vagy olvadékvízből jön létre; illetve (3) a folyók irányába más területekről érkező, az átemelő állomások elégtelen kapacitásának következtében azok előtt összegyülekező belvíz.

A belvíz több tényező egymásra hatása következtében alakul ki. Ezeket két csoportba sorolhatjuk: a statikus tényezők évtizedeken vagy még hosszabb időintervallumon át is stabilak maradnak, mint amilyen a relief és a talaj; a dinamikus tényezők azonban néhány órán vagy napon belül is változhatnak, mint például a meteorológiai viszonyok és a talajvízszint. A relief befolyásolja a lefolyást: olyan lokális mélyedéseket alakulhatnak ki, melyekben összegyűlik a víz. A talajtulajdonságok meghatározzák a beszivárgást és a tárolási kapacitást. A csapadék mennyisége – mint a belvíz forrása – a meteorológiai tényező része. Az egyéb meteorológiai összetevők – mint a hőmérséklet vagy a páratartalom – a párolgási sebességet befolyásolják. A magas talajvízszint nemcsak elöntéseket okozhat, de akadályozhatja a talajba szivárgást is. Gyakran antropogén tényezők gyakorolnak nagy hatást a belvízképződésre. Ez történhet a lefolyás akadályozásával (pl. épületek, utak, gátak által), a beszivárgás csökkentésével (pl. aszfaltozott felületeken) vagy ellenkezőleg, a víz

összegyülekezési esélyének csökkentésével (pl. csatornák és tározók építése által).

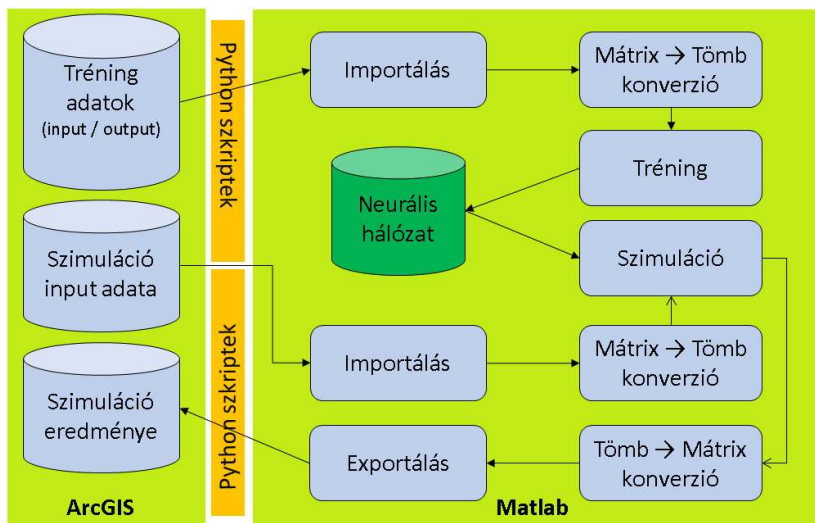
A belvíz okozta károk térben és időben egyaránt változatosak. Bizonyos években akár a mezőgazdasági területek 10%-a is víz alá kerül, míg máskor alig jelentkeznek károk. Néhány területet egyik évben elönt a víz, míg ugyanott egy másik évben komoly szárazság tapasztalható. Mindez megnehezíti a probléma megoldását. A belvíz térbeli mintázata is heterogén. A befolyásoló tényezők térbeli változatossága következtében egymás közelében találhatunk soha el nem öntött és gyakran víz alá kerülő területeket.

A komplex belvíz probléma elemzéséhez fontos megérteni annak térbeli és időbeli eloszlását. Ez két módon valósítható meg: (1) a térbeli és időbeli eloszlás terepi (*in situ*) vagy távérzékelt adatokon alapuló térképezésével; és (2) a kiválasztott, legfontosabb befolyásoló tényezők hatásainak becslésével, majd azok tapasztalati együtthatókkal történő súlyozásával. A legtöbb kutatás megpróbálta a fenti tényezők azonosítását és kombinálását regressziós függvények vagy egyéb lineáris statisztikai módszerek segítségével megoldani. Ezek a módszerek azonban nem képesek kezelni a tényezők közötti nem-lineáris és komplex funkcionális kapcsolatokat. Jelen kutatás egy ettől eltérő megközelítést mutat be: a belvízelöntések azonosítására és előrejelzésére a mesterséges neurális hálózatokat (ANN) a földrajzi információs rendszerekkel (GIS) kombinálja. Ennek a módszernek számos előnye van. Először is független az adatok statisztikai eloszlásától és nincs szükség az egyes tényezők súlyának definiálására. A neurális hálózatok lehetővé teszik a célcsoportok azonosítását minden egyes kapcsolódó adatforrás értelmezési tartományának (domain) megfelelően, így a távérzékelt és GIS adatok integrációja kényelmesen megoldható. Az

ANN képes továbbá a belső bizonytalanságok, a hiányos adatok, a helytelen mintavétel, a változók közötti többszörös kollinearitás, a tér- vagy időbeli autokorreláció és az egyedi változók inszignifikanciájának kezelésére. A felsoroltak a földrajzi elemzések során általánosan előfordulnak, a belvíz kutatásokban azonban – az elöntések fuzzy határai és az előidéző tényezők komplex belső kapcsolata miatt – különösen jelentősek.

Adatok és módszerek

A belvíz előfordulások neurális hálózatokkal történő hatékony osztályozásához olyan keretrendszert kellett létrehozni, amelyet az *ArcGIS* földrajzi információs rendszer, a *Matlab* matematikai modellező szoftver és a *Python* nyílt forrású programnyelv épít fel (1. ábra).



1. ábra. ANN – GIS keretrendszer az ArcGIS és Matlab munkafolyamatokkal

A keretrendszer úgy alkottam meg, hogy a bemenő, köztes és kimenő adatokat egyaránt rugalmasan kezelje ArcGIS-ben és Matlab-ban. Ily módon hatékonyan hozhatunk létre adatállományokat, tesztelhetünk különböző hálózati beállításokat, futtathatunk tréning és szimulációs lépéseket, illetve értékelhetjük és vizualizálhatjuk a tréning és szimulációs eredményeket. Minden egyes lépés a GIS programból indítható, így nincs szükség közvetlen felhasználói beavatkozásra az ANN rendszerben.

A keretrendszer fejlesztése és tesztje egy Szegedhez közeli 20 km²-es terület adatai alapján történt. A mintaterület kiválasztásában két fő tényező játszott szerepet: (1) a terület talajai extrém mechanikai tulajdonságokkal jellemezhetők. A rossz áteresztőképesség (permeabilitás) a nagyrészt sík felszínen nagy kiterjedésű, lefolyástalan lokális mélyedésekkel párosul, aminek eredményeként a belvíz összegyülekezésének valószínűsége igen nagy. (2) A Természeti Földrajzi és Geoinformatikai Tanszék hosszú idő óta végez itt belvízkutatásokat, aminek eredményeképpen nagy mennyiségű adat és ismeret áll rendelkezésre a területről. A mintaterület emellett közel fekszik a szegedi repülőtérhez, ami a légi adatgyűjtés kiinduló állomása volt. Mivel a belvíz időben nagyon változékony jelenség, a kutatások szempontjából fontos a megfelelő idejű adatfelvételezés.

A keretrendszerben 5 különböző input adatforrást használtunk: (1) színes-infravörös (CIR) légifelvételek, melyeket a tanszéki fejlesztésű – DuncanTech MS3100 digitális kamerára épülő – légi adatgyűjtő rendszerünk szolgáltatott; (2) 1 méter térbeli felbontású. LIDAR alapú digitális domborzatmodell; (3) 1:25 000 méretarányú talaj adatbázis; (4) a területen megtalálható antropogén objektumok (csatornák, utak, épületek és olajkutak) adatbázisa; és (3) kézi GPS eszközzel gyűjtött terepi referencia

mérések adatai a belvízelöntésekről. Egyéb – a belvízképződést befolyásoló – input adatok különféle okok miatt nem kerültek a rendszerbe. Először is a talajminták az egész területen rossz permeabilitást mutattak, amihez az egyéb talajtulajdonságok minimális eltérése is társult. Ennek megfelelően a talaj az egész területen homogénnek tekinthető. A földtani tényezők szintén homogénnek tekinthetők a mintaterületen. A talajvízszintet, csapadékot és páratartalmat mérő állomás órás felbontásban számos paraméterrel szolgált. Ezek a talajvíz, csapadék és párolgás adatok vízfelesleget mutattak a belvizes időszakokban. A vegetáció a területen nem homogén eloszlású, a rendszerben mégsem került bele külön input réteggént, ugyanis azt a színes-infravörös felvételek már reprezentálják.

Eredmények és következtetések


1. A disszertáció a belvíz jelenség első részletes elméleti leírása angol nyelven. Ez egy fontos lépés a probléma magyar nyelvterületeken túlnyúló tudatosításának folyamatában. Számos határos országban is előfordul, de azt ott – pl. Szerbiában és Romániában – a folyóvízi áradásokhoz hasonlóan kezelik, és nem fordítanak speciális figyelmet a mögötte zajló fizikai folyamatokra.
2. A regionális vízügyi igazgatóság által készített helyszíni felmérések neurális hálózatokkal végzett osztályozásban történő alkalmazhatóságának értékelése során megtörtént azok statisztikai összevetése a LIDAR alapú domborzatmodellből származtatott lokális mélyedésekkel. Az alap feltételezés szerint az elöntések előfordulási száma és a depressziók mélysége között pozitív kapcsolat van. A két adathalmaz között ilyen azonban nem volt kimutatható. Azaz

megállapítható, hogy a vízügyi terepi megfigyelési térképek nem használhatók a keretrendszerben alapadatként.

3. A nyers LIDAR adatok és a digitális légifelvételek – a neurális hálózat osztályozásban input adatként használható – egységes formátummá konvertálásához képfeldolgozó munkafolyamatot dolgoztam ki.
4. Egy kiválasztott belvízfolt különböző GPS eszközökkel került terepi felmérésre. A különböző eszközökkel végzett mérések között csak kis eltérés (1,8 %) adódott, amit a GPS technikák pontosságbeli különbsége okozott, mértéke azonban nem haladja meg az adatgyűjtési módszer okozta pontatlanságot. Következtetésként tehát megállapítható, hogy az egyedi belvízfoltok felméréséhez a legegyszerűbb (legolcsóbb) GPS eszköz is elegendő pontosságot biztosít.
5. Első alkalommal került bemutatásra és sikeres kivitelezésre a belvíz elöntések – neurális hálózatok és földrajzi információs rendszerek kombinálásával történő – azonosítása és lehetőségek szerinti előrejelzése.
6. Első alkalommal készült GIS-ANN keretrendszer az ArcGIS (GIS), a Matlab (modellező szoftver) és a Python (programnyelv) teljes integrálásával, ami lehetővé teszi, hogy az ANN szoftverrel kapcsolatos minden művelet futtatható legyen a GIS programból.
7. A mesterséges neurális hálózatok és azok betanítási algoritmusainak természetéből adódóan a módszer számításgényes. Emellett a belvízelemzés számos nagy felbontású adatréteget használ. A nagy adathalmaz és a bonyolult számítások együttesen időben elnyúló tréning folyamatot és memóriakezelési problémákat eredményeznek. Ezek megoldására olyan adatcsökkentő algoritmus került kifejlesztésre, amely úgy redukálja a bemenő adatok mennyiségét, hogy a neurális

hálózatba beolvasott mátrixba konvertálásakor csak minden n -edik pixelt használja fel. Az adatsökkentés pozitív hatással volt a betanítás minőségére is. A bemenő minták számának csökkentésével a hálózati *túltanulás* is elkerülhető volt.

8. Az ANN – GIS keretrendszer számításigényes megoldás. A lehetséges teljesítményfokozás meghatározása kísérletekkel történt. A hálózat betanításához szükséges idő és a tréning adatok mennyisége között exponenciális kapcsolat került kimutatásra. Hasonló exponenciális kapcsolat volt megfigyelhető a tréning időtartama és a számítógép memóriájába írt adatok mennyisége között (2. ábra). Ezen megfigyelések alapján került kidolgozásra az ún. Data reduction factor, illetve felhasználásra a Matlab Memory reduction funkciója.




2. ábra. A tréning során 50 iterációhoz szükséges idő és az adatsökkentési tényező (balra), illetve a betanítási idő és a memória redukciós faktor közötti kapcsolat (jobbra) (standard, elemző számítógép Intel Core 2, 2.6 GHz processzor, 2 Gb RAM)

9. A különböző input rétegek hatásának vizsgálatára négy szimuláció használtam. Ezek mindegyike a bementi rétegek különböző halmazával,

de minden esetben azonos neurális hálózat beállításokkal történt. Az input rétegek az 1. táblázatban, az eredmények a 3. ábrán láthatók.

1. táblázat. A tréning és a szimuláció bementi adatai a tanulóterületen

Leírás			
1	Lokális mélyedések	6	Épületektől mért távolság
2	Talajtulajdonságok (agrotopo)	7	CIR légifelvétel (1. sáv)
3	Csatornáktól mért távolság	8	CIR légifelvétel (2. sáv)
4	Utaktól mért távolság	9	CIR légifelvétel (3. sáv)
5	Olajkutaktól mért távolság		



3. ábra. Az input rétegek értékelése. Minden egyes eredmény azonos méretarányban azonos területet fed le

2. táblázat. Az input rétegek, a tréning réteg és a szimuláció közötti térbeli korreláció

	A	B	C	D	Train	1	2	3	4	5	6	7	8	9
A	1	0,91	0,83	0,83	0,76	-0,79	0,07	-0,3	0,14	0,13	0,06	0,23	0,02	0,04
B	0,91	1	0,91	0,91	0,83	-0,73	0,06	-0,44	0,11	0,14	0,03	0,22	0,02	0,04
C	0,83	0,91	1	0,99	0,92 ^b	-0,66	0,09	-0,4	0,18	0,17	0,11	0,19	0,02	0,03
D	0,83	0,91	0,99	1	0,92 ^c	-0,66	0,09	-0,4	0,18	0,17	0,11	0,19	0,02	0,03
Train	0,76	0,83	0,92	0,92	1	-0,59	0,08	-0,37	0,16	0,16	0,09	0,18	0,02	0,03
1	-0,79	-0,73	-0,66	-0,66	-0,59 ^a	1	-0,05	0,19	-0,1	-0,06	-0,05	-0,12	-0,09	-0,12
2	0,07	0,06	0,09	0,09	0,08 ^d	-0,05	1	0,28	0,46	0,33	0,34	0,03	-0,06	-0,06
3	-0,3	-0,44	-0,4	-0,4	-0,37	0,19	0,28	1	0,27	0,07	0,31	-0,23	0,01	-0,02
4	0,14	0,11	0,18	0,18	0,16	-0,1	0,46	0,27	1	0,14	0,71	0,03	-0,07	-0,05
5	0,13	0,14	0,17	0,17	0,16	-0,06	0,33	0,07	0,14	1	-0,03	0,05	-0,01	-0,04
6	0,06	0,03	0,11	0,11	0,09	-0,05	0,34	0,31	0,71	-0,03	1	0,04	-0,11	-0,05
7	0,23	0,22	0,19	0,19	0,18	-0,12	0,03	-0,23	0,03	0,05	0,04	1	-0,13	0,26
8	0,02	0,02	0,02	0,02	0,02	-0,09	-0,06	0,01	-0,07	-0,01	-0,11	-0,13	1	0,63
9	0,04	0,04	0,03	0,03	0,03	-0,12	-0,06	-0,02	-0,05	-0,04	-0,05	0,26	0,63	1

A szimuláció csak a tréning területéről származó adatokon lett lefuttatva, így az eredmény összehasonlítható a terepi felméréssel. Az első szimuláció (A) csak a CIR felvételeken és a lokális depressziókon alapult. A második (B) már figyelembe vette a csatornáktól mért távolságot is, míg a harmadik (C) 8 bemenő réteggel dolgozott, egyedül a talaj paraméterek kerültek kizárásra. Az utolsó szimuláció (D) mind a 9 réteget felhasználta. A input rétegek és az eredmények között mutatkozó térbeli korreláció a különböző rétegek jelentőségét mutatja a szimulációban (3. táblázat). Az első szimuláció eredményén világosan látszanak a terület lokális mélyedései (3A ábra), melyek korrelációja a terepi vagy tréning adatokkal $-0,59$ (2. táblázat – a). A korreláció azért negatív mert az osztályozott lokális mélyedések a *nincs mélyedés-től nagy mélyedés-ig* és a belvíz osztályok pedig *nincs belvíz-től a van belvíz-ig* terjednek. A relatív magas korrelációs érték azt mutatja, hogy az domborzatnak jelentős hatása van a belvízképződésre. Általánosságban megállapítható, hogy minél több réteget használ a szimuláció, annál jobb az eredmény. A legjobb eredmények a C és D szimulációnál láthatók, melyek egyedül a talaj réteg használatában különböznek. Ez utóbbi réteg kis mértékben csökkent a térbeli korrelációt (2. táblázat – b, c). A mintaterület talajának korlátozott befolyása a szimulációra a terepi felmérés adatai és a talajtérkép közötti alacsony térbeli korrelációban ($0,08$) is megmutatkozik (2. táblázat –d).

10. A általános pontosság (overall accuracy) és a Cohen-féle Kappa értékekből levonható az az általános következtetés, hogy minél több réteget használunk a tréning és a szimulációs lépésben, annál jobb minőségű lesz a szimuláció (3. táblázat). Ez alól a talaj réteg jelent

kivételt melynek használata negatív hatással van a pontosságra (ld. 9. pont).

3. táblázat. A 4 szimuláció Cohen-féle Kappa értéke és teljes pontossága

	A (4 réteg)	B (5 réteg)	C (8 réteg)	D (9 réteg)
Cohen's Kappa (κ)	0,76	0,81	0,86	0,83
Általános pontosság	0,88	0,91	0,93	0,91

11. Megtörtént az ANN osztályozás eredményeinek összehasonlítása a hagyományos minimum distance (MD) és maximum likelihood (ML) klasszifikációkkal (4. táblázat). Az ANN – GIS keretrendszer teljesítményben felülmúlja a hagyományos osztályozásokat, már 3 réteg felhasználása esetében is.

4. táblázat. A különböző típusú osztályozások pontossága (overall accuracy)

	Overall accuracy
MD 2 osztállyal	67 %
ML 2 osztállyal	69 %
ML összevont nem-víz osztállyal	70 %
ANN 2 osztállyal (3 réteg)	74 %
ANN 2 osztállyal (8 réteg)	93 %

12. A maximum likelihood osztályozás és a csak 3 távérzékelte CIR réteget felhasználó ANN szimuláció eredménye meglehetősen hasonló (4. táblázat). Ez a pontosság tovább növelhető, ha olyan extra információkat adunk az osztályozáshoz, mint a lokális mélyedések, az antropogén objektumoktól mért távolság és a talajtípus. Ezek az extra input rétegek azonban csak az ANN megközelítést alkalmazva

használhatók, mivel azok nem kompatibilisek a távérzékelt rétegekkel, és így nem alkalmasak a maximum likelihood klasszifikáció pontosságának növelésére.

A tézishez kapcsolódó saját publikációk

Van Leeuwen B., Mezősi G., Tobak Z., Szatmári J., Barta K., 2012, Identification of inland excess water floodings using an artificial neural network, Carpathian Journal of Earth and Environmental sciences. (In review).

Van Leeuwen B., Tobak Z., Szatmári J., 2008, Development of an integrated ANN - GIS framework for inland excess water monitoring, Journal of Env. Geogr. I, 3-4, pp. 1-6.

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. pp. 121-130.

van Leeuwen B., Tobak Z., Szatmári J., Mucsi L., Fiala K., Mezősi G., 2009, Small format aerial photography: a cost effective approach for visible, near infrared and thermal digital imaging, In: Car A, Griesebner G, Strobl J (Eds.), Geospatial crossroads, Heidelberg: Herbert Wichmann Verlag, pp. 200-209.

Szatmári J., Szíjj N., Mucsi L., Tobak Z., van Leeuwen B., Lévai Cs., Dolleschall J., 2012, Comparing LIDAR DTM with DEM-5 of Hungary, In: Geiger J., Pál Molnár E., Malvic T. (Eds.), New horizons in Central European geomathematics, geostatistics and geoinformatics, Institute of Geosciences, University of Szeged, pp. 151-158.

Szatmári J., Szíjj N., Mucsi L., Tobak Z., van Leeuwen B., Lévai Cs., Dolleschall J., 2011., A belvízelöntések térképezését és a belvízképződés modellezését megalapozó térbeli adatgyűjtés, In: Lóki J. (Ed.), Az elmélet és gyakorlat találkozása a térinformatikában II., Debrecen. pp. 27-35.

Szatmári J., Tobak Z., van Leeuwen B., Dolleschall J., 2011, A belvízelöntések térképezését megalapozó adatgyűjtés és a belvízképződés modellezése neurális hálózattal, Földrajzi Közlemények 135, 4, pp. 351–363.

Tobak Z., Szatmári J., van Leeuwen B., 2008b, Small format aerial photography – remote sensing data acquisition for environmental analysis, Journal of Env. Geogr I, 3-4, pp. 21-26.

Unger J., Gál T., Rakonczai J., Mucsi L., Szatmári J., Tobak Z., van Leeuwen B., Fiala K., 2010, Modeling of the urban heat island pattern based on the relationship between surface and air temperatures, Időjárás 114, 4, pp. 287-302.