

Doktori (PhD) értekezés tézisei

ÁRTÉRI FORMAKINCS LIDAR ALAPÚ ELEMZÉSE

Short thesis for the degree of Doctor of Philosophy (PhD)

LIDAR BASED ANALYSIS OF FLUVIAL LANDFORMS

Dr. Csatariné Szabó Zsuzsanna

Témavezető: Prof. Dr. Szabó Szilárd



DEBRECENI EGYETEM
Földtudományok Doktori Iskola

Debrecen, 2022

1. Bevezetés

A folyók felszíninformáló munkájuknak köszönhetően változatos ártéri formakincset hoznak létre, melyek hazai folyóinkat is végig kísérik. Az ártéri formák – mint például a sarlólapos, övzátony, folyóhát, fok, elhagyott meder, ártéri lapály – sajátos geomorfológiájuk révén számos természeti folyamat meghatározójává válnak. Legtöbbször csak néhány tíz centiméteres magasságkülönbség jellemző rájuk, ami viszont alapvetően megszabja a víz lefolyási viszonyait. Az eltérő vízellátottság a növényzet szukcessziós pályáit is kijelöli, valamint meghatározza a területhasználati jellemzőket, a mezőgazdasági tevékenységet. A mikrodomborzati sajátságok alapvetően befolyásolják az üledékfelhalmozódási folyamatokat is.

Az árterekhez sokszínű élővilág kötődik, amely igen értékessé teszi őket mind ökológiai, mind természetvédelmi szempontból. Hazánkban számottevő részük védeltséget élvez – mind hazai (pl. nemzeti park), mind nemzetközi (pl. Ramsari Egyezmény) vonatkozásokban –, illetve ökológiai folyosóként fontos elemei a páneurópai és a Nemzetközi Ökológiai Hálózatnak. Emellett az árterek fontos színterei a mezőgazdasági tevékenységeknek, valamint kulcsfontosságú szerepük van az árvizek elleni védekezésben is. Mindebből következik, hogy megőrzésük, illetve ahol szükséges helyreállításuk kiemelten fontos területe a természetvédelmi, illetve vízügyi szakpolitikának. Ahhoz viszont, hogy felelős döntések születessenek szükséges alapszerkezetük kellő részletességű feltárása.

A jelenleg elérhető távérzékelési módszerek közül a légi lézerszkennelés nagy felbontásban és nagy pontossággal teszi lehetővé a vegetáció és a felszín 3D mérését. Az aktív szenzor alkalmas a növényzettel borított területeken is a talajfelszín felmérésére, lehetőséget adva egy részletgazdag digitális terepmodell előállítására. Ennek köszönhetően az utóbbi időben számos alkalmazási területen terjedt el a LiDAR felmérésekből származó adatok használata. Hazánkban például különböző projektek keretében folyóinkat és hullámterüket országos szinten felmérték az árvízvédekezési tevékenység alapdokumentumainak korszerűsítése, a töltésfejlesztések előkészítése érdekében. A kérdés az, hogy a felmérésekből származó LiDAR adatok – az árvízvédelmi célok mellett – milyen mértékben használhatók az ártéri formák térképezésére, ezáltal az árter alapszerkezetének mélyebb feltárására?

2. Célkitűzések

Doktori értekezésemben az alábbi négy területhez kapcsoltn a következő fő kérdésekre kerestem a választ:

Az ártér felszínformáinak hidromorfológiai megközelítésű elemzése

- Mi jellemzi a teljes mintaterület geomorfológiáját, felszínborítását, illetve hogyan alakul a rakamazi ártér vízborítása?
- A LiDAR pontfelhőben hogyan tükröződnek vissza a hidromorfológiai sajátosságok a sarlólapos és övzátony formaelemekben a rakamazi ártéren?
- Az eltérő területhasználat, illetve növényborítottság hogyan befolyásolja a DTM hibáit a két forma esetében?

Az ártér terepmodelljének előállítás LiDAR adatokból

- Milyen hatékonysággal alkalmazhatók a nyílt forráskódú zajsűrű eljárások az ártér LiDAR pontfelhőjének szűrésére?
- A CSF (*Cloth Simulation Filter*) algoritmus mely beállításai alkalmasak leginkább az ártéri környezet talajpontjainak leválogatására?
- Melyik interpolációs módszerrel és milyen felbontással hozható létre a legpontosabb terepmodell?

Az ártér formakincsének LiDAR alapú azonosítása

- A LiDAR DTM-en végzett vizuális interpretáció mennyire hatékony eszköze az ártéri formakincs lehatárolásának?
- Különválaszthatóak-e az ártéri formák pixel alapú, illetve objektum megközelítésű automatikus képosztályozással a LiDAR DTM és deriváltjai, valamint az NDVI réteg alapján?

A sarlólapos és övzátony formák nehézfém akkumulációs mintázatának vizsgálata

- Van-e szignifikáns különbség a sarlólapos és övzátony formaelemek nehézfém akkumulációjában?
- Alapvetően mely talajtulajdonságok befolyásolják a fémfelhalmozódást?
- Milyen trend figyelhető meg a fémek horizontális, valamint vertikális eloszlásában?

3. Anyag és Módszer

Mintaterületnek a Tokaji-kapu alatt található, Rakamaz-Tokaj-Tiszanagyfalu-Tiszaeszlár-Tiszaladány-Tiszatardos-Tiszalök települések közigazgatási határán belüli, tiszai árteret választottam. Az elemzések túlnyomó többsége azonban a legtermészetesebb ártérre, a rakamazi ártérre koncentrált. A TIVIZIG rendelkezésemre bocsátotta a mintaterületről az SH/2/6 projekt keretében készült adatokat, a LiDAR pontfelhőt – 4 pont/m² és ±15 cm pontosság, a LiDAR DTM-et, az ortofotót, és a hiperspektrális felvételt. A mintaterületen referencia méréseket Stonex S9 RTK GPS-sel, félkinematikus módszerrel végeztünk, ahol a vertikális és horizontális pontosság ±1 cm volt.

Az ártér felszínformáinak hidromorfológiai megközelítésű elemzése

A rendelkezésre álló LiDAR DTM és az ortofotó segítségével vizuálisan elkülönítettem, majd manuálisan vektorizáltam a teljes mintaterület geomorfológiai egységeit, illetve elkészítettem a rakamazi terület ártéri formáinak térképét. Vektorizáltam a teljes mintaterület felszínborítási kategóriáit is az ortofotó alapján, majd elemeztem az egyes geomorfológiai egységekre jellemző felszínborítási sajátosságokat. Vizsgáltam a vízborítási jellemzőket, melyhez az NDVI-t (*Normalized Difference Vegetation Index*) és NDWI-t (*Normalized Difference Water Index*) vontam be. Az előbbihez a hiperspektrális adatokat, utóbbihoz pedig Sentinel-2 alapadatokat használtam.

A sarlólapos és övzátony formák alakotani sajátosságait keresztaszvénnyel létrehozásával elemeztem. A növényesség elemzése céljából a LiDAR pontfelhő alapján megnéztem a két formára vonatkozóan az összes, illetve az egy m²-re jutó pontok számát a három növénymagassági (alacsony, közepes és magas) kategória alapján.

Megvizsgáltam a terepmodell magassága és a terepen mért RTK GPS magasságok közötti eltérést a két ártéri forma esetében, mely során az eltérő növényzet hatását is figyelembe vettem. A statisztikai elemzéseket a kétutas faktoriális ANOVA eljárással végeztem.

Az ártér terepmodelljének előállítását LiDAR adatokból

A georeferált LiDAR pontfelhő zajszűrése a szórás és az átlagot figyelembe vevő statisztikai kiugróérték szűrőkkel: a szomszédos

távolság alapú (*Neighborhood Distance-Based*) és a felszíni távolság alapú (*Surface Distance-Based Filter*) szűréssel történt.

A talajpontok meghatározása a Zhang et al. (2016) által fejlesztett, a felhasználó által könnyen beállítható CSF módszer segítségével történt a *CloudCompare 2.10.2* programban.

A terepmodell létrehozásához 3 féle interpolációs módszert, a *Linear*, *Natural Neighbor*, *Topo to Raster* használtam, eltérő bemeneti adatformátumban (*LAS dataset*, *LAS dataset single point with z*, *terrain dataset*, *terrain dataset with thinning*) tárolt pontokkal, 1 és 2 méteres felbontással. Összesen 180 db DTM-et hoztam létre.

A pontfelhő pontjainak száma és a modell pontosságok közötti korreláció mérésére Spearman-féle módszert (r) alkalmaztuk. Az egyutas (*one-way*) összehasonlításokra a Welch tesztet használtuk a Tukey HSD (*Honesty Significant Difference*) post hoc teszttel. A nominális változók közötti kölcsönhatások vizsgálata a robusztus kétutas faktoriális ANOVA-val (*Analysis of Variance*) történt.

Az ártér felszínformáinak automatikus azonosítása

További célom volt, hogy a LiDAR domborzatmodellét, az abból származtatott, valamint az azt kiegészítő adatokat használva elvégezzem a sarlólapos és övzátany formaelemek automatikus pixel alapú osztályozását. Ehhez SVM (*Support Vector Machine*) osztályozást végeztem a *Radial Basic Function* (RBF) *kernellel* a DTM, lejtőszög, a lejtőkitettség és az NDVI rétegeken, az eredményt pedig hibamátrixban ismertettem.

Ezután a sarlólapos és övzátany formák mellett a folyóhát és fok elemeket is bevonva *Random Forest* (RF) osztályozást végeztem. Ehhez a LiDAR DTM-et és 60 morfológiai réteget, illetve a rakamazi terület 4 formaelemét tartalmazó (összesen 265 db objektum) geomorfológiai térképet használtam, és egyrészt pixel alapon, másrészt objektum (szegmens) alapú megközelítésben hajtottuk végre. A morfometriai rétegeket a SAGA GIS 6.3.0 és a Whitebox GAT 3.4.0 szoftverkörnyezetben hoztam létre. A rövidítések teljes elnevezését a melléklet tartalmazza.

Az ellenőrzött RF osztályozás során 500 döntési fát alkalmaztunk, a *mtry* paraméterrel finomhangolást végeztünk, és a legjobb általános pontosság (OA) alapján választottunk modellt.

A túlillesztés (*overfitting*) elkerülése miatt az RFE (*Recursive Feature Elimination*) módszert alkalmazva csökkentettük a változók számát, valamint vizsgáltuk e módszer mennyire ad hasonló eredményt a kiválasztott változókra, ha megváltoztatjuk az input adatokat. Ehhez a lehetséges 5 000 pontból 11 db random mintavétel során 1 000-1 000 pontot vettünk ki és futtattuk újra az RFE algoritmust. A kapott eredményekből összesítettük, hogy melyik változó hányszor szerepelt a legfontosabb rangszámú helyezéseken. Így előállt a *stabilitási megbízhatósága* az RFE-alapú változószelekciónak.

A sarlólapos és övzátony formák nehézfém akkumulációs mintázata

A nehézfém akkumulációs vizsgálatokhoz 64 db mintavételi helyről a felső 25 cm-es rétegből vettünk talajmintát. A vertikális nehézfém-eloszlás vizsgálat céljából az említett mintavételi pontok közül 54 db ponton 5 cm-ként is vettünk mintákat, összesen 270 db-ot.

A pH-érték elektroanalitikai eljárással, a szervesanyag-tartalom Tyurin módszerrel, a szemcseméret-eloszlás a Köhn-pipettás módszerrel került meghatározásra. A következő nehézfémek koncentrációinak mérése történt: Mn, Cr, Cu, Ni, Pb, Zn, illetve az Al, Ca, Fe, K és Mg koncentrációját is meghatároztuk mikrohullámú plazma atomemissziós spektrométerrel.

A sarlólapos és övzátony formák fém-felhalmozódásának elemzésénél a kétmintás t-próba robusztus változatát (Yuen's teszt) alkalmaztuk. A nehézfémek vertikális eloszlását a robusztus kétutas faktoriális ANOVA eljárással vizsgáltuk. A talajtulajdonságok és a fémek közötti kapcsolatot korreláció vizsgálatokkal tártuk fel, az eredményt pedig korrelációs mátrix diagramon ábráztuk. A fémeknél dimenziócsökkenést alkalmaztunk standardizált főkomponens analízist a korrelációs mátrixot és a Varimax rotációt használva.

4. Kutatási eredmények

1. tézis

A LiDAR DTM alapján elkészítettem a teljes mintaterület átfogó és a rakamazi ártér nagy részletességű geomorfológiai térképét, és megállapítottam, hogy az ártér hidromorfológiai célú vizsgálata nem képzelhető el modern távérzékelési eljárások használata nélkül.

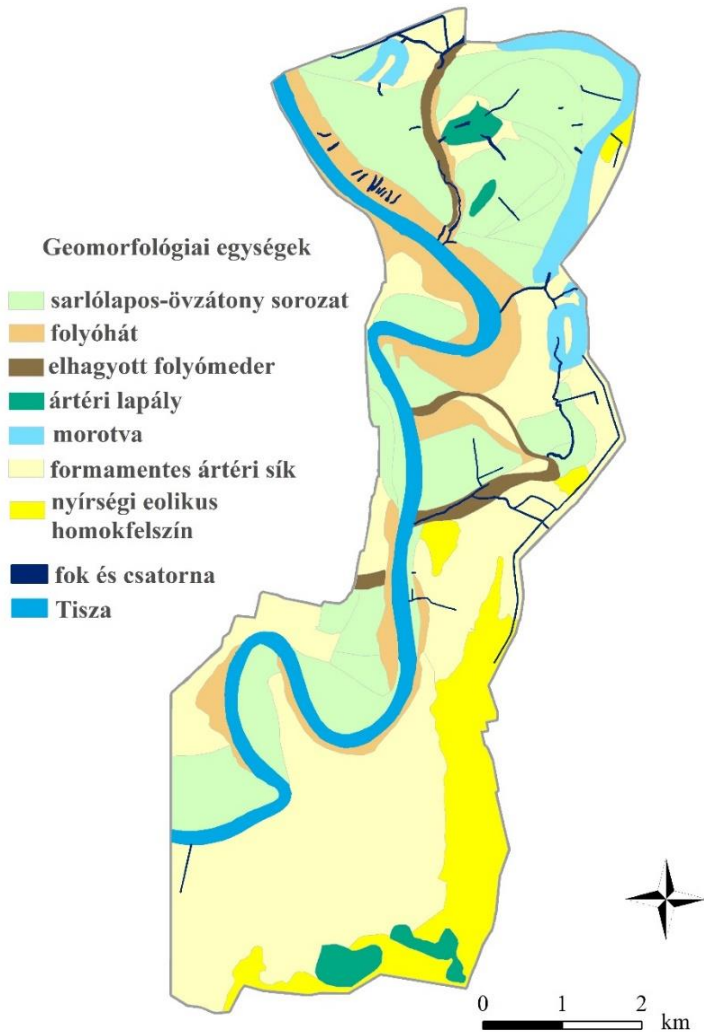
A mintaterületről rendelkezésekre bocsátott árvízvédelmi célú felmérésből származó adatok, bár nem jelen kutatáshoz voltak

optimalizálva, nagy lehetőséget jelentettek az ártér felszínformáinak hidromorfológiai megközelítésű elemzésében. A mintaterület LIDAR alapú terepmodellje korábban nem látott részletességgel engedett betekinteni az ártér geomorfológiai jellemzőibe. A LiDAR DTM vizuális interpretációjával olyan formák azonosítására is lehetőség nyílt, amelyek a terepi viszonyok között nem megközelíthetők és formahatáraik nem láthatók (pl. a sűrű, egyes esetekben áthatolhatatlan növényzet és/vagy víz borítja). Illetve azon formák, amelyek kis méretüknél fogva (pl. fokok, keskenyebb sarlólaposok és övzátonyok) nem detektálhatók korábbi, gyengébb felbontású felvételeken.

A LIDAR DTM segítségével a teljes mintaterületen 9 db geomorfológiai egységet határoltam le (1. ábra), melyek közül a második legnagyobb területi aránnyal – a formamentes ártéri sík után – a sarlólapos-övzátony formaegyüttes rendelkezett (30%). E formaelemek az északi ártérrészen, a Tisza és a Nagy-Morotva között a legjellemzőbbek.

A rakamazi ártérre elkészített geomorfológiai térkép alapján összesen 105 db övzátont, 127 db sarlólapost azonosítottam. Mindkét formátípusra jellemző, hogy füves területek, amelyeket gyakran fák és bokrok tarkítanak, illetve a sarlólaposok sok esetben sűrűbb növényzettel rendelkeznek és vízborított, vizenyős térszínnek is találhatók rajtuk (az azonosított 127 db forma közül 10 esetben volt vizes folt felszínükön). A rakamazi ártér formakincsét 20 db részben természetes, részben mesterséges fok, 2 db folyóhát (melyből az egyik aktív, a másik inaktív forma), 2 db ártéri lapály, 1 db elhagyott meder, 1 db morotva is színesítette (2. ábra). Az 1:10 000 magyar topográfiai térképen e formák közül csak a nagyobb, illetve vízzel borítottak voltak feltüntetve.


A LiDAR felvétellel egyidőben készített ortofotó nagy segítséget jelentett a felszínborítási kategóriák elkülönítésében. A térbeli elemzésekkel lehetőség nyílt a geomorfológiai egységek és a felszínborítási kategóriák összefüggéseinek vizsgálatára. A formákra változatos élőhelytípusok jellemzők, melyek mozaikos elhelyezkedésükkel még tovább emelik az ártéri élővilág sokszínűségét. A morotva, az elhagyott meder, az ártéri lapályok, illetve egyes sarlólaposok vizes élőhelyek, néhány esetben nyílt víztükrökkel, mocsaras, lápos részekkel, melyek jelentős ökológiai és természetvédelmi értéket képviselnek.



1. ábra: A teljes mintaterület geomorfológiai egységeinek térképe

A LiDAR pontfelhő vegetációs pontjainak vizsgálata további információkkal szolgált a növényzet sűrűségéről és magasságáról. A sarlólaposnál mind az alacsony, mind a közepes vegetációs pontok száma az övezetok pontsűrűségét meghaladó volt. A hiperspektrális felvétel csatornáiból készített NDVI réteg lehetőséget nyújtott a vízzel

fedett területrészek detektálására. A sarlólaposoknál azokon a részeken, ahol az $NDVI < -0,3$ volt, alacsonyabb talajpontsűrűség volt tapasztalható, $2,68 \text{ pont/m}^2$, míg azokon a részeken, ahol az $NDVI > -0,3$ értéket vett fel, ott magasabb, $3,77 \text{ pont/m}^2$, jelezve ezáltal a vízfelület meglétét.



2. ábra: A rakamazi ártér geomorfológiai formái

A Sentinel-2-es felvételek jó lehetőséget adtak a meder-ártér oldalirányú kapcsolatrendszerének vizsgálatára, a vízfelület-változás nyomon követésével. A Sentinel-2-es műholdak észlelési adatait használva, azt tapasztaltam, hogy egy kisebb árhullám (2 nap) következtében, akár 3-4 hét elteltével a rakamazi ártér 1/3-án visszamaradhat a víz. Ez nem csak a mélyebb fekvésű formákat, hanem például az övzátonyokat is érintette, amelyek szintén 1/3-a volt vízborítás alatt, 3 héttel az árhullám levonulása után.

Mindent összevetve nem vitatható, hogy a LiDAR alapú DTM nagyon jó lehetőséget kínál az ártér geomorfológiai jellemzőinek térképezésére, és elősegíti a hidromorfológiai sajátságok mélyebb megismerését. Azt azonban meg kell említeni, hogy a sűrű vegetáció, illetve a vízfelület megléte rontja a kapott terepmodell pontosságát. A terepfelmérés alapján az övzátányok relatív magassága $0,25 \pm 0,10$ m, a sarlólaposok relatív mélysége pedig $0,24 \pm 0,12$ m volt. A DTM csak azoknál a formáknál tükrözi vissza pontosan a sarlólapos és övzátány formaelemekre jellemző konvex és konkáv alakot, ahol kaszálással hasznosítják a területet. (Kivéve a sarlólaposok esetében a zombékoló sások jelenléte, 20-30 cm-es kiemelkedések, illetve a legeltetett állatok nyomai, 10-15 cm-es mélyedések.) Az elemzések szerint a DTM és a felmért terület adatai között átlagosan $0,15 \pm 0,12$ m különbség van, ami egy sarlólapos átlagos mélységének vagy egy övzátány magasságának kb. 60%-a. A megvizsgált növényborítottsági kategóriák (letisztított, füves, nádas és sásos, sűrű nádas és sásos, ligetes fás, füves területek szénabálákkal) tekintetében a faktoriális ANOVA modell alapján statisztikailag szignifikáns különbségek voltak tapasztalhatók a két ártéri forma között. A laposoknál a sűrű, alacsony és közepes vegetáció, illetve a vízfelület megléte van hatással geomorfológiai értelemben a pontfelhő és a LiDAR DTM sajátosságaira, esetükben 10,2% a m²-kénti hiányzó talajpontok száma. A zátányok esetében pedig azok a mélyebben fekvő formák, amelyek sűrű nádassal fedettek, vannak leginkább kitéve az osztályozási tévedéseknek, amelyek rontják a terepmodell pontosságát. Összességében elmondható, hogy a fent említettek a formák vizuális interpretációval történő azonosíthatóságát jelentősen nem zavarják, viszont a forma jellemzők vizsgálatánál már befolyással vannak, illetve nehezítik a szoftveres osztályozást.

2. tézis

Megterveztem és teszteltem a LiDAR alapú terepmodell előállításának munkafolyamatát, keresve a zajsztűrés és a talajpontosztályozás optimális paramétereit, valamint a megfelelő interpolációs eljárást és felbontást, amelyekkel a legpontosabb modell állítható elő a vizsgált ártéri környezetre.

A LiDAR pontfelhő zajsztűrésére, a talajpontok osztályozására jó lehetőséget nyújtottak a nyílt forráskódú szoftverkörnyezetbe

beágyazott eljárások. A statisztikai alapú zajszűrők alkalmazása hatásos eszköz volt a kiugró pontok eltávolítására. Elmondható, hogy minden típusú előzetes zajszűrés lényegesen pontosabb eredményeket hozott a feldolgozás során, mint amit az eredeti adatbázis alkalmazásánál tapasztalhattunk (1. táblázat). A pontok száma közepesen korrelált a pontossággal ($r=-0,65$, $p<0,05$), a kevesebb pontot tartalmazó modellek közelebb álltak a referencia pontok értékeihez. Az alacsonyabb pontok száma nem jelentette azonban azt, hogy a legkevesebb pontot tartalmazó modell volt a legpontosabb, mivel a legkevesebb pontot a felszíni távolság alapú szűrő eljárásnál kaptuk, viszont a szomszédos távolság alapú eljárás adta a legjobb bemeneti modellt a talajpontok osztályozásához.

1. táblázat: A talajpontosztályozás pontossága a zajszűrők és az eltérő CSF beállítások esetében


Zajszűrés módszere	CSF beállítás (CS; Thd)	Pontok száma	Pontosság (m)	
			átlag	szórás
d	2; 1	6 943 468	-0,152	0,18
d	2; 0,2	5 199 607	-0,125	0,14
d	2; 0,5	6 375 149	-0,142	0,15
d	5; 1	6 875 994	-0,151	0,18
d	5; 0,2	3 720 552	-0,095	0,17
d	5; 0,5	5 905 299	-0,134	0,15
n	2; 1	8 050 253	-0,145	0,17
n	2; 0,2	5 958 207	-0,119	0,14
n	2; 0,5	7 395 394	-0,136	0,15
n	5; 1	7 971 242	-0,144	0,17
n	5; 0,2	4 246 638	-0,088	0,17
n	5; 0,5	6 842 756	-0,132	0,15
o	2; 1	8 293 970	-0,150	0,19
o	2; 0,2	6 999 426	-0,153	0,17
o	2; 0,5	7 837 259	-0,147	0,17
o	5; 1	8 287 750	-0,149	0,19
o	5; 0,2	6 729 067	-0,158	0,17
o	5; 0,5	7 781 547	-0,146	0,17

(o: eredeti pontfelhő; d: felszíni távolság alapú szűrés izolált pontok kizárásával; n: szomszédos távolság alapú szűrés; CS: szövet felbontás; Thd: osztályozási küszöbérték; félkövérrel kiemelve a legpontosabb modell)

A CSF talajpontosztályozó módszernek két fontos beállítható paramétere van. Az egyik a szövet felbontása, a másik a küszöbérték. A szövetfelbontás a pontsűrűséggel van kapcsolatban, amely a mintaterület esetében 4 pont/m^2 volt, ráadásul a többszörös visszaverődés miatt akár a 10 pont/m^2 -t is elérhette. Ennek megfelelően a finomabb szövetfelbontás használata indokoltabb lett volna, ugyanis az algoritmust fejlesztő ajánlása a ponttávolság egyharmada. A 2 és 5 m-es beállítás közötti átlagos különbség szerint viszont az 5 m-es szövetfelbontás 0,012 m-rel jobbnak bizonyult a szomszédos távolság alapú szűrő eljárásnál. A másik beállítható CSF paraméter az osztályozási küszöbérték, ahol a fejlesztő által javasolt beállítás 0,5 volt, a mi esetünkben azonban a kisebb, 0,2-es küszöbérték használata bizonyult pontosabbnak. Ebben az ártéri környezetben így a szomszédos távolság alapú szűrő használatát javaslom.

Az interpolációs eljárásoknál a leggyengébb (*3.a ábra*) és legjobb modellt (*3.b ábra*) összevetve, a közöttük lévő legnagyobb különbség $-1,71 \text{ m}$ volt (*3.c ábra*). Az eltérések leginkább a sűrűbb vegetációval borított területekre koncentráálódtak. Az interpolációk esetében két következtetést vontam le: a mediánokat figyelembe véve a Natural Neighbor (NA) módszer adta a legpontosabb modellt; a különbségek tartományát tekintve pedig a Topo to Raster (TT) és a terrain dataset-ek a természetes szomszéd interpolációval (TD, TH) biztosították a legjobb DTM-eket. Ezen eredményekre támaszkodva javaslatom az, hogy amennyiben az ESRI ArcGIS szoftver rendelkezésre áll, megfontolandó a TT, TD és TH módszerek alkalmazása, mivel azok kevéssel teljesítettek az NA interpolációk alatt, és értékeik tekintetében szűkebb skálán mozogtak, így a potenciális hiba kisebb is lehet.

A felbontást tekintve, a durvább, 2 m-es felbontás átlagosan 0,009-0,012 m-rel volt közelebb a referencia pontokban mért magassághoz, mint a finomabb 1 m-es. Azt azonban szem előtt kell tartani az ártér kisebb méretű, keskenyebb formáinak (pl. fokok, keskenyebb sarlólapos és övzátony formák) azonosításánál, hogy csak azok a formák azonosíthatók, amelyek azonos, vagy nagyobb mérettel rendelkeznek, mint a DTM pixelek felbontása; így az elemzések során az 1 méteres felbontást használtam. Javasolom ennek mérlegelését más ártereken is.



(o|2|0.2|LI: o: eredeti pontfelhő; első szám: szövet felbontás (2); második szám: osztályozási küszöbérték (0,2); LI: Linear interpoláció;
 n|5|0.2|NA: n: szomszédos távolság alapú szűrés; első szám: szövet felbontás (5); második szám: osztályozási küszöbérték (0,2); NA: Natural Neighbor interpoláció)

3. ábra: A medián alapján sorberendezett legrosszabb (a), illetve legjobb (b) terepmodellek és a közöttük lévő különbségek (c) vizuális megjelenítése

3. tézis

A sarlólapos és övzátóny formaelemek pixel alapú SVM osztályozása során megállapítottam, hogy a DTM, az NDVI, a lejtőkíttetés és a lejtőszög változókat használva 71%-os osztályozási pontosság érhető el.

A sarlólapos és övzátóny formaelemek pixel alapú SVM osztályozása során a LiDAR DTM és az abból származtatott lejtőszög és lejtőkíttetés, valamint az NDVI rétegeket bevonva, különböző kombinációkat vizsgálva 71%-os a teljes pontosságot (OA) értem el (2. táblázat). Ebben az esetben az övzátónyok átlagos osztályozási hibája (PA) 26%, míg a sarlólaposoké 30% volt.

2. táblázat: A táji és növényzeti változók hibamátrixa

Vizsgálatba bevont változók	OA (%)	Övzátány Sarlólapos	
		PA (%)	
DTM	66	79	54
Lejtőkitettség	52	23	82
Lejtőszög	54	38	69
NDVI	44	14	90
DTM+NDVI	69	73	65
DTM+lejtőkitettség	68	75	60
DTM+lejtőszög	68	74	63
DTM+NDVI+lejtőszög	71	73	67
DTM+NDVI+lejtőkitettség	69	72	67
DTM+lejtőkitettség+lejtőszög	68	73	62
NDVI+lejtőkitettség+lejtőszög	59	50	67
NDVI+lejtőkitettség+lejtőszög+DTM	71	74	70

Az övzátányok esetében a DTM réteg egyedül való használata eredményezte a legpontosabb osztályozást, 79%-ot. A sarlólapos esetében pedig a másik 3 változó – az NDVI, a lejtőszög és lejtőkitettség – hozott magasabb osztályozási pontosságot. A legkevesbé pontos modell az NDVI változó esetén volt, ahol a pixelek csaknem teljes egészében a sarlólaposként kerültek besorolásba, ami a övzátány esetén csak 14%-os pontosságot okozott, tehát így ennek az eredménye nem elfogadható.

4. tézis

Az ártéri formakincs automatikus azonosítása során kimutattam, hogy morfometriai változókat használva pixel alapon 81%-os, míg az objektum alapú megközelítéssel 95%-os osztályozási pontosság érhető el Random Forest osztályozóval.

Az RF osztályozást RFE változó szelekciós módszerrel kiegészítve végeztük, ami segített azonosítani a legfontosabb változókat (megőrizve a modell magas teljesítményét és csökkentve a túlillesztés kockázatát), amelyben az alábbi sorrend született:

- (1) A pixel alapú osztályozásnál az OA maximuma 20 változónál volt, a következő sorrendben:

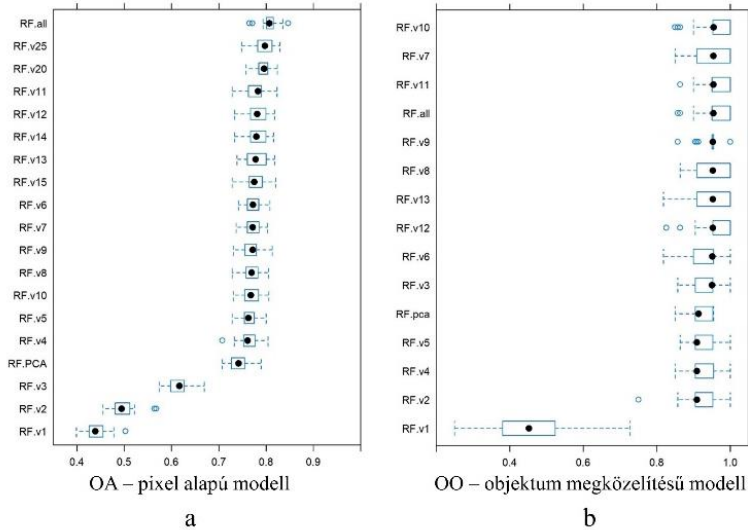
GenSurf>DTM>EIRel>FlodO>TPI>MRVBF1>DevME3>DifME3>ValDpth>RidgLvl>ConvISR>ElevP3>MxEMg>DifME2>ElevP2>DevME2>MRRTF1>VRM>MRRTF2>SedTI.

- (2) Az objektum megközelítésű osztályozás során az OA 13 változónál érte el a maximumát, a következő sorrendben:

MRVBF1>MorfFeat>MS_TPI2>ConvISR>DifME1>DevME1>FlodO>ConvI>MS_TPI1>EIRel> LocCurv>DTM >GenSurf.

Az 5000 pixelből és 265 formából 11 véletlenszerűen kiválasztott adathalmazzal végzett stabilitás-megbízhatósági elemzésünk azt mutatta, hogy az objektumorientált és a pixel alapú megközelítés különböző változókkal járul hozzá a legmagasabb teljes pontossághoz. A pixel alapú megközelítésnél a legnagyobb teljes pontosságot a 11 és a 20 változó adta, a teljes pontosság 78,5% és 81,1% érték között változott, amelyben a GenSurf került az első helyre 8 esetben, az EIRel a második helyre szintén 8 esetben, és a harmadik helyre a DTM 7 esetben a 11 ismétlésből. Az objektum alapú megközelítésnél a változók optimális száma 10 és 60 közötti tartományban változott, közel azonos 95,2% és 95,7% teljes pontosság mellett. A legfontosabb változónak a MRVBF1 bizonyult, amely, mind a 11 ismétlésben az első ranghelyen végzett, a második helyen a MorfFeat végzet szintén 11 esetben, a harmadik pedig a ConvISR volt 5 esetben. Összességében a legfontosabb geomorfometriai mutatók a pixel alapú megközelítésnél a GenSurf, EIRel, DTM, FlodO és TPI voltak, az objektumorientált megközelítésnél pedig az MRVBF1, MorfFeat, ConvISR, MS_TPI2 és DevME1.

A pixel alapú RF módszernél mind a 61 változót bevonva az osztályozásba a teljes pontosság 80,7%-os volt, az RFE szerint az optimális 20 változó 79,5%-os teljes pontosságot eredményezett. Négy morfometriai mutatót tartalmazó modell, a GenSurf, az EIRel, a DTM és a FlodO csak 4,6%-kal volt rosszabb az előrejelzésben, mint amikor 61 változót használtunk (*4a ábra*). Az objektumorientált osztályozásokban a legjobb teljes pontosság a 10 változó modelljéhez tartozott (95,4%) (*4b ábra*). Az RFE változókiválasztás szerinti optimális 13 változó csak a hetedik legjobb modell volt a listában.




4. ábra: A különböző változóhalmazok osztályozási pontossága (OA) 10-szeres keresztvalidálással és 3-szoros ismétlés mellett (azaz 30 modell); (a) pixel alapú megközelítés, (b) objektum alapú megközelítés

5. tézis

Kimutattam, hogy a sarlólapos és övzátony formák nehézfém akkumulációs mintázatában szignifikáns különbségek vannak. A feltárt nehézfém-felhalmozódási mintázatok összefüggései más ártereken is segítséget nyújtanak a magas nehézfémtartalmú hotspot területek azonosításában.

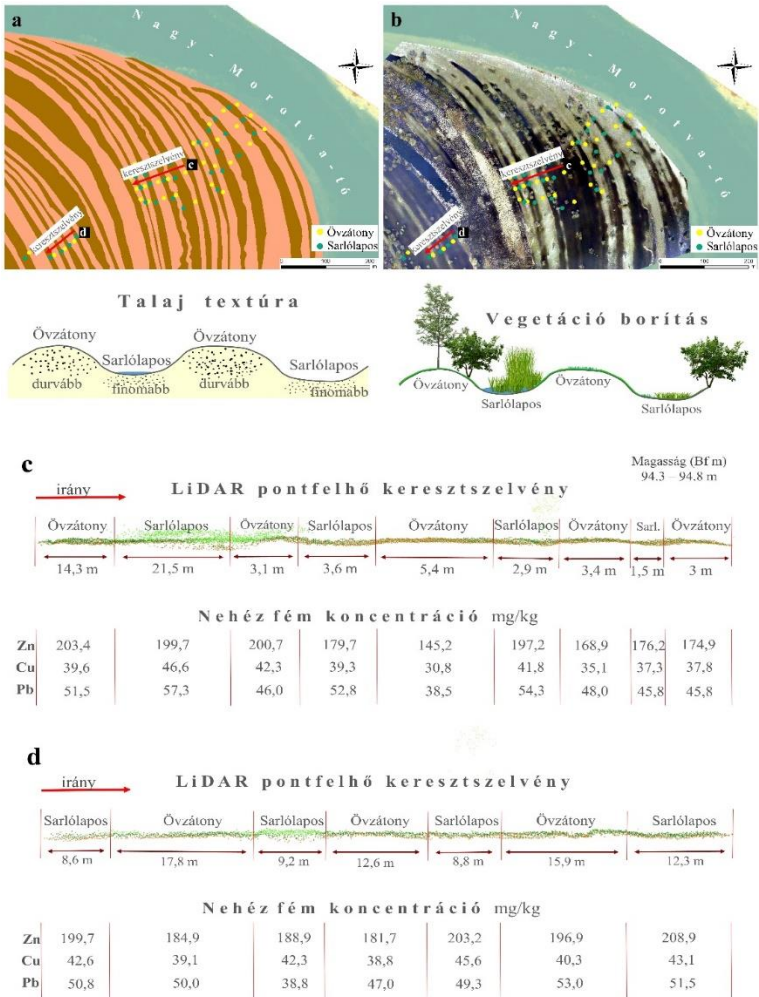
A geomorfológiai alapú nehézfém elemzés során megállapítottam, hogy a sarlólapos és övzátony formák fontos befolyásoló tényezői az árter horizontális fémmintázatának: szignifikáns különbségeket ($p < 0,05$) tártunk fel a Fe, K, Mg, Mn, Cr, Cu, Ni, Pb és Zn tekintetében a két forma között (5. és 6. ábra). Mindez egyrészt a talajtulajdonságokból is adódott, a sarlólapos magasabb szervesanyag-tartalma ($4,9 \pm 1,3\%$, míg a zátonyok esetében $4,2 \pm 1\%$), illetve a finomabb szemcsemérete (az agyagtartalom $36,9 \pm 3,2\%$, a homok pedig $10,6 \pm 2,2\%$, szemben az övzátonyok $33,4 \pm 5,6\%$ agyag- és $17,6 \pm 7,9\%$ homoktartalmával) kedvezőbb feltételeket teremtett a fémek megkötődésének. A GLM alapján a makro- és mikroelemekre

eltérő eredményeket kaptunk: a makroelem-koncentrációt a szervesanyag határozta meg, míg a mikroelemeknél az agyagtartalom és a formák voltak jelentős magyarázó változók. Másrészt pedig az erózió és a kilúgzás következményeként is magasabb lehet a sarlólaposok fémkoncentrációja. Az övzátanyok pozitív, magasabban fekvő formák, amelyek a magasabb homokfrakciónak köszönhetően jobb beszívargási kapacitással rendelkeznek, így a beszívargó víz és a felszíni lefolyás is kimoshatja a finomabb szemcséket – amelyek megkötik a fémeket – és ezáltal csökkentik az övzátanyok nehézfém-koncentrációját, egyúttal pedig növelik a szomszédos sarlólaposok fém mennyiségét (6. ábra). Harmadrészt a sarlólaposok sűrűbb növényzete is csökkenti a víz áramlási sebességét és fokozza a lerakódást.



(Ö: övzátany – szürke, S: sarlólapos – narancssárga; whiskers: $1,5 \times$ interkvartilis tartomány, •: kiugró értékek; box: alsó kvartilis, medián, felső kvartilis; notch: a medián 95%-os konfidencia intervaluma)

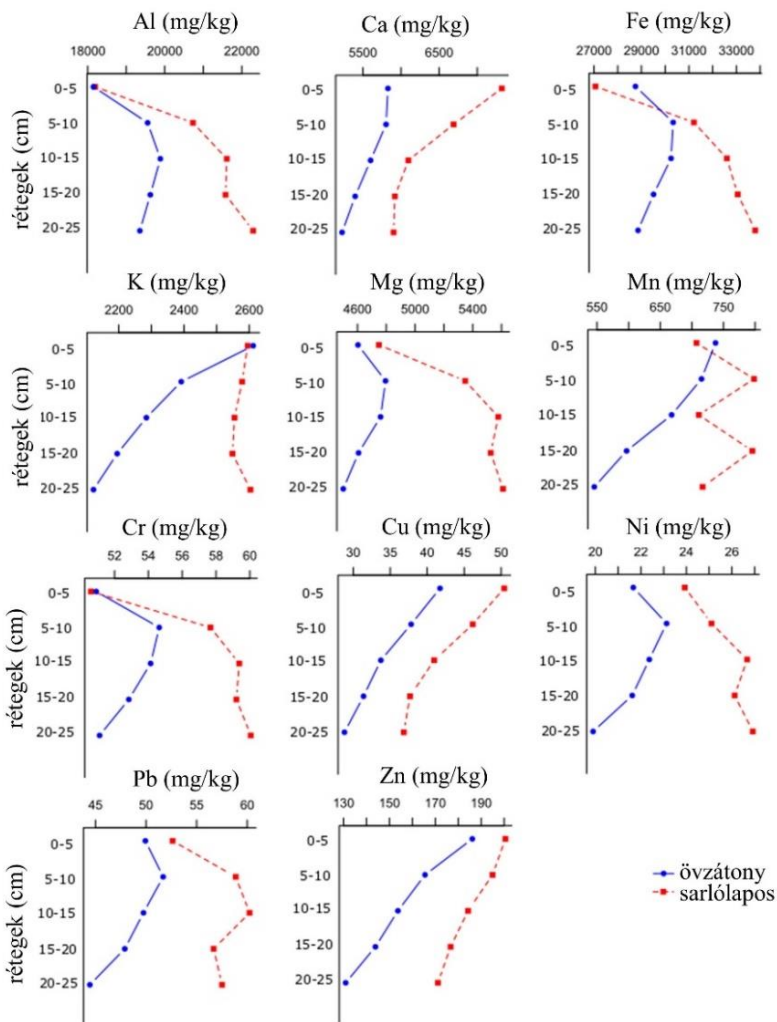
5. ábra: A két ártéri forma fémakkumulációs (mg/kg) különbségei



(a) A LIDAR DTM alapján vektorizált sarlólapos és övzátóny formaelemek; (b) a sarlólapos és övzátóny rendszerek drónos felvételen a 2017-es áradás és hóolvadás után; (c, d); a sarlólapos és övzátóny formaelemek keresztmetsvényei (magasságtorzítás: 2) a LiDAR pontfelhőben, illetve a nehézfémek koncentrációit. A talajmintavételi pontok és a keresztmetsvények mintavételi helyei az (a) és (b) ábrán feltüntetésre kerültek. Illetve a két forma általános vegetációs és textúra jellemzőiket az (a) és (b) ábrák alatti rajzok illusztrálják.

6. ábra: Sarlólapos és övzátóny sorozatok nehézfém akkumulációs mintázata

A vertikális eloszlás is szignifikánsan eltért formánként: minden rétegben magasabb volt a fémkoncentráció (kivéve Ni) a sarlólaposokban. Míg az Al-, Fe-, Mg- és Cr-koncentráció fokozatosan emelkedett, addig a mélyebb rétegekben az összes többi fém csökkenő tendenciát mutatott (7. ábra).



7. ábra: A nehézfémek vertikális eloszlásának ábrája

A sarlólaposoknál a Pb nehézfém nagyobb mennyiségben az 5-10 cm-es rétegben volt azonosítható. Ez azt jelentette, hogy a mintaterületen a 2000-es évtől (amikor is a nehézfémekkel szennyezett árhullám vonult le a Tiszán) körülbelül 5-10 cm vastagságú üledék halmozódott fel. Az akkumuláció oka viszont, nem csak a folyóvízzel érkező lebegtetett üledék kiülepedése volt, hanem a magasabban fekvő, övzátony formák eróziója, a finom szemcsék kimosódása, illetve a szerves anyagok felhalmozódása is szerepet játszott benne.

Melléklet – az RFE változó szelekció eredménye alapján a legfontosabb morfológiai rétegek rövidítésjegyzéke és beállításai

Morfometriai változó	Rövidítés	Beállítás
Flood Order	FlodO	-
Elevation Relative To Min and Max	ElRel	-
Deviation from Mean Elevation	DevME1	Search Neighborhood Size: 8
	DevME2	Search Neighborhood Size: 16
	DevME3	Search Neighborhood Size: 32
Difference from Mean Elevation	DifME1	Search Neighborhood Size: 8
	DifME2	Search Neighborhood Size: 16
	DifME3	Search Neighborhood Size: 32
<i>Maximum Elevation Deviation (Multiscale) Magnitude</i>	MxEMg	Maximum Neighborhood Radius (cell): 1498
Elevation Percentile	*ElevP1	Search Neighborhood Size: 8
	ElevP2	Search Neighborhood Size: 16
	ElevP3	Search Neighborhood Size: 32
Sediment Transport Index	SedTI	-
Convergence Index	ConvI	Alapértelmezett
Convergence Index (Search Radius)	ConvISR	Alapértelmezett
<i>Upslope and downslope curvature</i>		
Local Curvature	LocCurv	Alapértelmezett
<i>Multiresolution Index of Valley Bottom Flatness</i>		
Multiresolution Index of Valley Bottom Flatness	MRVBF1	Alapértelmezett
	*MRVBF2	Initial threshold for slope: 8
Multiresolution Ridge Top Flatness Index	MRRTF1	Alapértelmezett
	MRRTF2	Initial threshold for slope: 8
Topographic Position Index	TPI	Alapértelmezett
Multi-Scale Topographic Position Index	MS-TPI1	Alapértelmezett
	MS-TPI2	Min Scale: 8 Max Scale: 8
Generalized Surface	GenSurf	Alapértelmezett
<i>Valley Depth</i>	Valdpth	
Valley Depth	RidgLvl	Alapértelmezett
Ridge Level		
Morphometric features	MorfFeat	Alapértelmezett
Vector Ruggedness Measure	VRM	Alapértelmezett

*Ezekkel a beállításokkal nem voltak a legfontosabb változók között



Nyilvántartási szám: DEENK/79/2022.PL
Tárgy: PhD Publikációs Lista

Jelölt: Csatáriné Szabó Zsuzsanna
Doktori Iskola: Földtudományok Doktori Iskola
MTMT azonosító: 10050415

A PhD értekezés alapjául szolgáló közlemények

Idegen nyelvű tudományos közlemények külföldi folyóiratban (4)

1. **Szabó, Z.**, Tóth, C. A., Holb, I., Szabó, S.: Aerial Laser Scanning Data as a Source of Terrain Modeling in a Fluvial Environment: Biasing Factors of Terrain Height Accuracy. *Sensors*. 20 (7), 1-18, 2020. ISSN: 1424-8220.
DOI: <http://dx.doi.org/10.3390/s20072063>
IF: 3.576
2. **Szabó, Z.**, Buró, B., Szabó, J., Tóth, C. A., Baranyai, E., Herman, P., Prokisch, J., Tomor, T., Szabó, S.: Geomorphology as a Driver of Heavy Metal Accumulation Patterns in a Floodplain. *Water*. 12 (2), 1-16, 2020. EISSN: 2073-4441.
DOI: <http://dx.doi.org/10.3390/w12020563>
IF: 3.103
3. **Szabó, Z.**, Mikita, T., Négyesi, G., Varga, O. G., Burai, P., Takács-Szilágyi, L., Szabó, S.: Uncertainty and Overfitting in Fluvial Landform Classification Using Laser Scanned Data and Machine Learning: A Comparison of Pixel and Object-Based Approaches. *Remote Sens*. 12 (21), 1-29, 2020. ISSN: 2072-4292.
DOI: <https://doi.org/10.3390/rs12213652>
IF: 4.848
4. **Szabó, Z.**, Tóth, C. A., Tomor, T., Szabó, S.: Airborne LiDAR point cloud in mapping of fluvial forms: a case study of a Hungarian floodplain. *GISci. Remote Sens*. 54 (6), 862-880, 2017. ISSN: 1548-1603.
DOI: <http://dx.doi.org/10.1080/15481603.2017.1339987>
IF: 2.852

Magyar nyelvű konferencia közlemények (3)

5. **Szabó, Z.**, Szabó, J., Tomor, T., Baranyai, E., Prokisch, J., Szabó, S.: Övzátónyok és sárlalaposok nehézfém mintázatának vizsgálata rakamazi mintaterületen.
In: Az elmélet és a gyakorlat találkozása a térinformatikában X.. Szerk.: Molnár Vanda Éva, Debreceni Egyetemi Kiadó, Debrecen, 295-300, 2019. ISBN: 9789633180549





6. **Szabó, Z., Szabó, S.:** A rakamazi ártér vízborítottság rövid távú változásának nyomon követése Sentinel-2 felvételek alapján.
In: Az elmélet és a gyakorlat találkozása a térinformatikában IX. : Theory meets practice in GIS. Szerk.: Molnár Vanda Éva, Debrecen Egyetemi Kiadó, Debrecen, 333-339, 2018. ISBN: 9789633187234
7. **Szabó, Z., Szabó, S., Szabó, J., Tomor, T., Hunyadi, G.:** Felszínfejlődési szakaszok és formák vizsgálata LiDAR felmérés alapján a Tisza hullámterén.
In: Az elmélet és a gyakorlat találkozása a térinformatikában VI.: Térinformatikai konferencia és szakkiallítás. Szerk.: Boda Judit, Debreceni Egyetemi Kiadó, Debrecen, 387-394, 2015. ISBN: 9789633184882

Magyar nyelvű absztrakt kiadványok (2)

8. **Szabó, Z., Szabó, S., Tomor, T.:** Előzetes eredmények a hullámterí formaelemek LiDAR alapú meghatározásáról.
In: Az elmélet és a gyakorlat találkozása a térinformatikában VII. : Térinformatikai Konferencia és Szakkiallítás. Szerk.: Balázs Boglárka, Debreceni Egyetemi Kiadó, Debrecen, 455, 2016. ISBN: 9789633185704
9. **Szabó, Z.:** Fluviális felszínformák osztályozása LiDAR felhasználásával rakamazi mintaterületen.
In: Absztraktkötet : Magyar Földrajzi Napok 2016 : VIII. Magyar Földrajzi Konferencia : XVI. Geográfus Doktoranduszok Országos Konferenciája : Oktatás-módszertani és Földrajztanári Konferencia. Szerk.: Pajtókné Tari Ilona, Tóth Antal, Magyar Földrajzi Társaság, Budapest, 145-146, 2016. ISBN: 9786158030717

További közlemények

Magyar nyelvű könyvrészletek (3)

10. **Szabó, Z., Balla, D. Z.:** Nekézseny túraútvonal hálózatának kialakítása az ökoturizmus elősegítése érdekében.
In: Földrajzi Tanulmányok 2018. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 377-379, 2018. ISBN: 9789635088973
11. Balla, D. Z., **Szabó, Z., Molnár, D.:** Tanösvények webes geovizualizációja az Upponyi-hegység területén.
In: Földrajzi Tanulmányok 2018. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 373-375, 2018. ISBN: 9789635088973





12. **Szabó, Z.:** Az "energianád" (*Miscanthussinensis 'Giganteus'*) biomassza célú termesztésének főbb jellemvonásai.
In: Vidéki erőforrások hasznosítása. A KRF Természeti Erőforrás-gazdálkodási és Vidékfejlesztési Kara hallgatóinak kutatási eredményei. Szerk.: Koncz Gábor, Károly Róbert Kutató-Oktató Közhasznú Non-profit Kft., Gyöngyös, 59-70, 2011. ISBN: 9789639941212

Magyar nyelvű tudományos közlemények hazai folyóiratban (2)

13. Burai, P., Lénárt, C., Valkó, O., Bekő, L., **Szabó, Z.**, Deák, B.: Fátlan vegetációtípusok azonosítása légi hiperspektrális távérzékelési módszerekkel.
Tájékol. Lapok. 14 (1), 1-12, 2016. ISSN: 1589-4673.
14. **Szabó, Z.:** Belvízcsatorna-rekonstrukciós munkálatok hatásainak térinformatikai elemzése síkvidéki mintaterületen.
Agrárinformatika. 1 (3), 40-47, 2010. ISSN: 2061-862X.
DOI: <http://dx.doi.org/10.17700/jai.2010.1.3.27>

Idegen nyelvű tudományos közlemények külföldi folyóiratban (3)

15. Varga, O. G., Kovács, Z., Bekő, L., Burai, P., **Szabó, Z.**, Holb, I., Ninsawat, S., Szabó, S.:
Validation of Visually Interpreted Corine Land Cover Classes with Spectral Values of Satellite Images and Machine Learning.
Remote Sens. 13 (5), 1-24, 2021. EISSN: 2072-4292.
DOI: <http://dx.doi.org/10.3390/rs13050857>
IF: 4.848 (2020)
16. Varga, O. G., Pontius, R. G., **Szabó, Z.**, Szabó, S.: Effects of Category Aggregation on Land Change Simulation Based on Corine Land Cover Data.
Remote Sens. 12, 1-16, 2020. EISSN: 2072-4292.
DOI: <http://dx.doi.org/10.3390/rs12081314>
IF: 4.848
17. **Szabó, Z.**, Schlosser, A. D., Túri, Z., Szabó, S.: A review of climatic and vegetation surveys in urban environment with laser scanning: A literature-based analysis.
Geogr. Pannon. 23 (4), 411-421, 2019. ISSN: 0354-8724.
DOI: <http://dx.doi.org/10.5937/gp23-24675>

Magyar nyelvű konferencia közlemények (1)

18. **Szabó, Z.:** Térinformatikai vizsgálatok a vidéki természeti erőforrások védelme érdekében.
In: Agricultural Informatics 2010 Conference Proceedings. Ed.: by Alexander B. Sideridis, Miklós Herdon, László Várallyai, Hungarian Association of Agricultural Informatics (HAAI), Debrecen, 229-234, 2010. ISBN: 9789638736642





Magyar nyelvű absztrakt kiadványok (3)

19. **Szabó, Z.**, Szabó, J., Tomor, T., Baranyai, E., Prokisch, J., Szabó, S.: Az ártér geomorfológiájának szerepe a nehézfémek mintázatában Sajó menti mintaterületen.
In: Az elmélet és a gyakorlat találkozása a térinformatikában X.. Szerk.: Molnár Vanda Éva, Debreceni Egyetemi Kiadó, Debrecen, 293-294, 2019. ISBN: 9789633180549
20. **Szabó, Z.**, Balla, D. Z.: Nekézseny túraútvonal hálózatának kialakítása az ökoturizmus elősegítése érdekében.
In: IX. Magyar Földrajzi Konferencia előadásainak és posztereinek összefoglalói. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 175, 2018. ISBN: 9789635088966
21. Balla, D. Z., **Szabó, Z.**, Molnár, D.: Tanösvények webes geovizualizációja az Upponyi-hegység területén.
In: IX. Magyar Földrajzi Konferencia előadásainak és posztereinek összefoglalói. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 174, 2018. ISBN: 9789635088966

A közlő folyóiratok összesített impakt faktora: 24,075

A közlő folyóiratok összesített impakt faktora (az értekezés alapjául szolgáló közleményekre): 14,379

A DEENK a Jelölt által az iDEa Tudóstérbe feltöltött adatok bibliográfiai és tudományometriai ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján elvégezte.

Debrecen, 2022.02.09.



1. Introduction

Rivers, through erosion and accumulation processes generate various landforms in their floodplains, which accompany the Hungarian rivers as well. The fluvial landforms – for example: swale, point bar, levee, crevasse channel, backswamp – through their specific geomorphology determine many natural processes. In most cases, they are characterized by only a few decimeters of height differences, which basically determines the flow conditions of the water. The different water level defines the ecological succession paths of the vegetation, furthermore the characteristics of the land use and farming. The micro-topographic properties also fundamentally influence sediment accumulation processes.

Floodplains characterized by very diverse wildlife, which makes them highly valuable from both an ecological and nature conservation point of view. In Hungary, a considerable part of them is protected – a framework of domestic (e.g. national park) and international (e.g. Ramsar Convention) agreement –, and as an ecological corridor they are important elements of the pan-European and International Ecological Network. In addition, floodplains are important for agriculture and play a key role in flood protection. It follows that their conservation and, where necessary, restoration is an important area of nature and water policy. However, in order responsible decisions to be made, it is necessary to explore and comprehend their structure in more details.

Among the currently available remote sensing methods, aerial laser scanning allows 3D measurements of vegetation and surface with high resolution and accuracy. The active sensor is also suitable for surveying the surface in vegetated areas, enabling the generation of a detailed digital terrain model. As a result, the use of LiDAR data has recently become widespread in several applications. In Hungary, for example our rivers and floodplains were surveyed in the framework of various projects in order to modernize the basic documents of flood protection and to prepare embankment developments. The question is the LIDAR data from those surveys how usable for other purposes than flood protection e.g. floodplain mapping, fluvial landform identification.

2. Aims of the research

In my doctoral dissertation, I sought answers to the following main questions related to the next four areas:

Hydromorphological analysis of floodplain forms

- What characterizes the geomorphology and surface cover of the whole study area, and how does the water cover of the Rakamaz floodplain change?
- In the Rakamaz floodplain, how does the hydromorphological properties reflect in the swale and point bar forms in the LiDAR point cloud?
- How do the different land use and land cover affect the DTM errors in the two forms?

Generation of the DTM of floodplain from the LiDAR data

- How effective can be the open-source noise filtering methods to filter the LiDAR point cloud in the floodplain?
- Which settings of the CSF (Cloth Simulation Filter) algorithm are most suitable for classifying the ground points of the floodplain environment?
- Which interpolation method and resolution can be used to create the most accurate terrain model?

LiDAR-based identification of the floodplain forms

- How effective is the visual interpretation on LiDAR DTM in delimiting the floodplain forms?
- Can floodplain forms be distinguished by pixel-based and object-oriented automatic image classification based on LiDAR DTM and its derivatives and the NDVI layer?

Investigation of the heavy metal accumulation pattern of the swale and point bar forms

- Is there a significant difference in the accumulation of heavy metal in the swales and point bars?
- Basically, which soil properties affect metal accumulation?
- What is the trend of the horizontal and the vertical distribution of metals?

3. Materials and methods

For the study area a Tisza floodplain was chosen within the administrative boundaries of Rakamaz-Tokaj-Tiszanagyfalu-Tiszaeszlár-Tiszaladány-Tiszatardos-Tiszalök settlements. However, most of the analysis focused on the most natural floodplain part, the floodplain of Rakamaz. The Trans Tisza Water Directorate provided data to me from the study area, which was gathered in the framework of SH/2/6 project. There were LiDAR point cloud – 4 points/m² and ±15 cm accuracy, LiDAR DTM, orthophoto, hyperspectral imaging. Reference measurements in the study area were performed with Stonex S9 RTK GPS, a semi-kinematic method with a vertical and horizontal accuracy of ±1 cm.

Hydromorphological analysis of floodplain forms

Using the LiDAR DTM and the orthophoto, I visually separated and then vectorized the geomorphological units of the whole study area and prepared a detailed floodplain forms map of the Rakamaz area. I also vectorized the land cover categories of the whole study area based on the orthophoto, and then analysed the characteristic of land cover properties of each geomorphological unit. I examined the water cover characteristics, for which I included NDVI (*Normalized Difference Vegetation Index*) and NDWI (*Normalized Difference Water Index*). I used hyperspectral data for the former and Sentinel-2 data for the latter one.

The morphological properties of the swales and point bars were analysed by creating cross sections. For the analysis of plant density, I looked at the total number and the number of points per m² for the two forms based on the LiDAR point cloud, respectively. It was examined the difference between the height of the terrain model and the RTK GPS heights measured in the field in the case of the two floodplain forms. I also took into account the effect of the different vegetation, where the statistical analysis was performed using two-way factorial ANOVA.

Generation of the DTM of the floodplain from the LiDAR data

The noise filtering of the georeferenced LiDAR point cloud was performed with statistical outliers filters taking into account the standard deviation and the mean distance: Neighbourhood Distance-Based and Surface Distance-Based Filters. The CSF algorithm

developed by Zhang et al. (2016) was applied to identify the ground points in CloudCompare 2.10.2.

To generate the terrain model, I used 3 types of interpolation methods: Linear, Natural Neighbour, Topo to Raster, with points stored in different input data formats (LAS dataset, LAS dataset single point with z, terrain dataset, terrain dataset with thinning). The resolution of 1 and 2 m was tested. A total of 180 DTMs were created.

Spearman's method (r) was used to measure the correlation between the number of points in the point cloud and the model accuracies. For the one-way comparisons, the Welch test was used with the Tukey HSD (*Honesty Significant Difference*) post hoc test. Interactions between nominal variables were examined using a robust two-way factorial ANOVA (*Analysis of Variance*).

Automatic identification of floodplain forms

Further goal was to perform automatic pixel-based classification of the swale and point bar elements using the LiDAR and supplementary data. For this, SVM (*Support Vector Machine*) classification with the *Radial Basic Function* (RBF) kernel was performed on the DTM, slope, aspect, and NDVI layers, and reported the result in an error matrix.

Then, next to the swales and point bars, levees and crevasse channels were also included to the identification, and Random Forest classification was performed. For this, we used LiDAR DTM and its derivatives – 60 morphological layers – and the map of the 4 morphological elements of the Rakamaz area (265 objects in total), and we performed it on the one hand on a pixel based and on the other hand in an object (segment) based approach. The morphometric layers were created in the SAGA GIS 6.3.0 and Whitebox GAT 3.4.0 software environments. The full names of the abbreviations of derived morphometric layers are given in the Appendix.

The classification was performed using the Random Forest (RF) algorithm with 500 decision trees, and the *mtry* parameter, which was fine-tuned, and the model was chosen based on the best overall accuracy (*OA*).

To avoid overfitting, we reduced the number of variables using the RFE (*Recursive Feature Elimination*) method, examining how similar the results for the chosen variables were if the input data is changed.

We had set 11 different random samples with 1000 pixels from the 5000 training pixels and using the RFE. From the results obtained, we summed up which variable was included in the top rankings. This is how the stability reliability of RFE-based variable selection was achieved.

Heavy metal accumulation pattern of the swales and point bars

For analysing the heavy metal accumulation, soil samples were taken from the top 25 cm layer from 64 sampling sites. In addition, we also conducted vertical sampling from the top 25 cm at 5 cm intervals, the total number of these samples was 270.

The pH value was determined by electrometric method, the organic matter content by the Tyurin method, and the particle size distribution by the Köhn pipette method. Concentrations of the following heavy metals were measured: Mn, Cr, Cu, Ni, Pb, Zn, and the concentrations of Al, Ca, Fe, K and Mg were also determined by a microwave plasma atomic emission spectrometer.

A robust version of the two-sample t-test (Yuen's test) was used to analyse the metal accumulation of the swale and point bar forms. The vertical distribution of heavy metals was examined by robust two-way factorial ANOVA. The relationship between soil properties and metals was revealed by a correlation analysis, and the result was visualized as a correlation plot. We applied dimension reduction to the metals studied; a standardized *Principal Component Analysis* (PCA) was performed using the correlation matrix and Varimax rotation.

4. Scientific results

Thesis Statement 1.

Based on the LiDAR DTM, I prepared a comprehensive geomorphological map of the entire study area and a detailed one of the floodplain of Rakamaz, and found that the hydromorphological study of the floodplain is not conceivable without the use of modern remote sensing methods.

The data provided to me from the study area afforded a great opportunity for the hydromorphological analysis of the forms of the floodplain; despite it was originated from a flood protection survey, therefore not optimized for this specific research. The LIDAR-based

terrain model of the study area provided insight of the geomorphological features of the floodplain in unprecedented details. Visual interpretation of LiDAR DTM also made it possible to identify forms that are inaccessible under field surveys and their boundaries are not visible (e.g. covered by dense, in some cases impenetrable vegetation and/or water). And forms that, due to their small size (e.g., crevasse channels, narrower swales and bars), cannot be detected on earlier, lower-resolution images.

With the help of LIDAR DTM 9 geomorphological units were delineated in the whole study area (*Figure 1*). The largest area ratio was formless floodplain, followed by the swale and point bar system as the second, with 30% coverage. These elements are most characteristic in the northern part of the floodplain, between the Tisza River and the Nagy-Morotva-Lake.

Based on the geomorphological map prepared for the floodplain of Rakamaz, it was identified a total of 105 point bars and 127 swales. Both types of forms are characterized by grassy areas, often interspersed with trees and bushes, and in many cases the swales have denser vegetation and water-covered or wet areas (10 of the 127 forms identified had water cover on their surface). Additionally, there were 20 crevasse channels (natural and man-made ones), 2 levees (one active and one inactive), 2 backswamps, 1 paleo channel, 1 oxbow (*Figure 2*). On the 1:10 000 Hungarian topographic map, only the larger ones and those covered with water were delineated among them.

The orthophoto taken simultaneously with the LiDAR data, was a great help in distinguishing the land cover categories. Spatial analysis provided an opportunity to examine the relationships between geomorphological units and land cover categories. The forms are characterized by a variety of habitat types, which, with their mosaic location, further enhance the diversity of floodplain wildlife. The oxbow, the abandoned riverbed, the backswamps and some of the swales were wetlands, marshy areas, in some cases with an open water surface, which represented a significant ecological and nature conservation value.

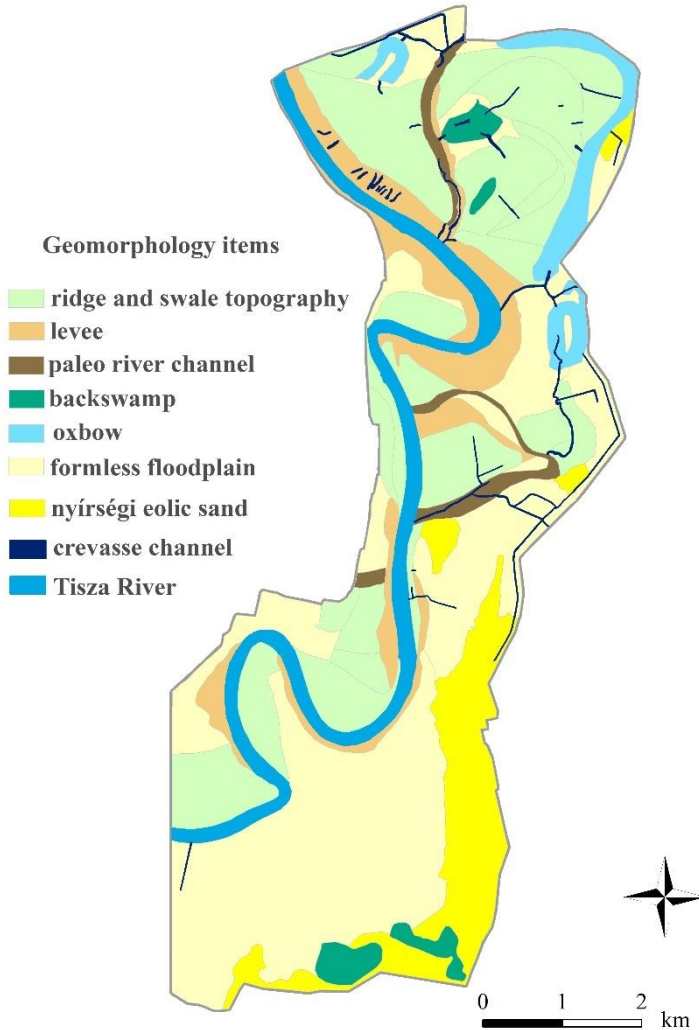


Figure 1. The geomorphological units of the whole study area

Analysing of the vegetation points of the LiDAR point cloud provided additional information on vegetation density and height. The number of both, low and medium vegetation points in the swales exceeded the point density of the point bars. The NDVI layer prepared from the hyperspectral data provided an opportunity to detect areas

covered by water. In that parts where the NDVI<-0.3 was lower ground point density, 2.68 points/m², while in that parts where the NDVI was>-0.3 it was higher, 3.77 points/m². This indicated the presence of a water surface, which absorbs laser beams.

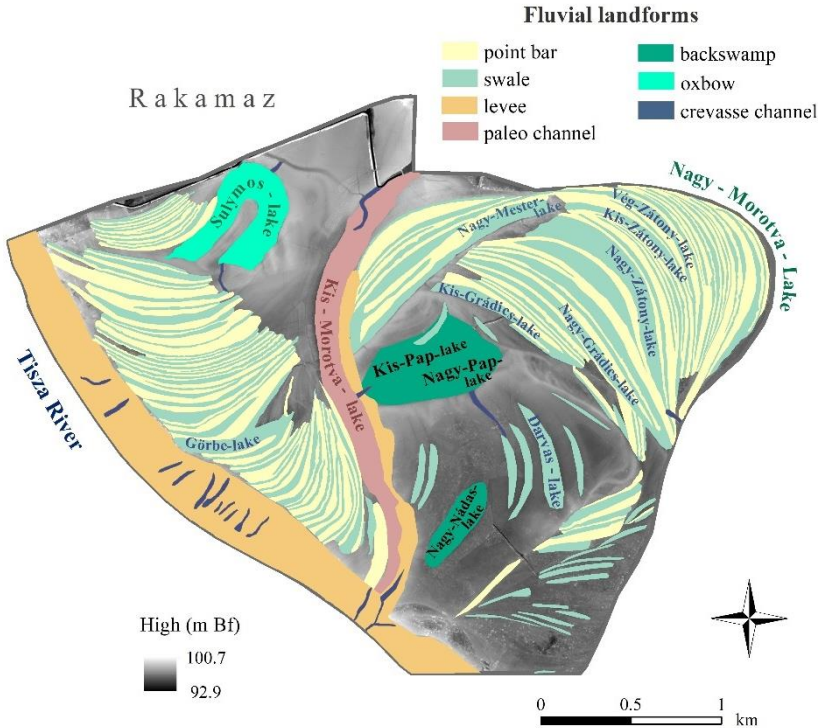


Figure 2. The fluvial forms of the floodplain of Rakamaz

Sentinel-2 data provided a good opportunity to examine the lateral relationship between the riverbed (Tisza River) and the floodplain by monitoring water surface change. Using the data from the Sentinel-2 satellites, I found that due to a minor flood wave (2 days), even after 3-4 weeks, water may remain on 1/3 of the Rakamaz floodplain. This was true not only the deeper forms, but also some of the point bars, which were also 1/3 under water cover 3 weeks after the flood.

All things considered, it is undeniable that LiDAR-based DTM offers a very good opportunity to map the geomorphological features of the floodplain and contributes to a deeper understanding of the

hydromorphological features. However, it should be mentioned that the presence of dense vegetation and water surface impairs the accuracy of the obtained terrain model. Based on the field survey, the relative height of the point bars was 0.25 ± 0.10 m, and the relative depth of the swales was 0.24 ± 0.12 m. The DTM accurately reflects the convex and concave shape typical of swale and point bars only where the area was mowed. (Except in some case of swales due to for the presence of tussocky, 20-30 cm protrusions, and trail of grazed animals, 10-15 cm depressions.) It was determined that the average error (i.e. the difference between the DTM and the surveyed height) was 0.15 ± 0.12 m, which was about the 60% of the relative floodplain form heights. There were statistically significant differences between the two floodplain forms based on the factorial ANOVA model for the examined vegetation categories (clear areas with short grass, reed and sedge, dense reed and sedge, woods, short (mowed) grass with haystack). In the case of swales, the presence of dense low and medium vegetation and water surface had a geomorphological effect on the characteristics of the point cloud and LiDAR DTM, in their case the number of missing ground points per m^2 was 10.2%. In the case of point bars, deeper forms that are covered with dense reeds were most exposed to classification errors that decreased the accuracy of the terrain model. Overall, the above mentioned does not significantly influence the visual interpretation of the landforms, but they do influence when examining the characteristics of the fluvial forms or complicate the automatic classification.

Thesis Statement 2.

I planned and tested the workflow for the generation of the LiDAR-based terrain model, looking for the optimal parameters of noise filtering and ground point classification, as well as the appropriate interpolation procedure and resolution to produce the most accurate model for the studied fluvial environment.

The algorithms embedded in open-source software environment provided a good opportunity to filter the noise of the LiDAR point cloud and to classify the ground points. The use of statistically based noise filters was an effective tool to remove outliers. Noise removal was an important step, and both methods resulted in better models than the

original point cloud without noise filtering (*Table 1*). The number of points had a moderate correlation with the mean accuracies ($r = -0.65$, $p < 0.05$), indicating that less points provided better alignment with the field measurements. However, the less points did not mean that the model with the fewest points was the most accurate, as the lowest point numbers were obtained with the surface distance-based filtering method, whereas the neighbourhood distance-based approach gave the best input model for classifying ground points.

Table 1. Accuracies as reflected in the noise reduction and CSF parameters

Filtering method	CSF parameters (CS; Thd)	Point number	Accuracy (<i>m</i>)	
			mean	+ - sd
d	2; 1	6 943 468	-0,152	0,18
d	2; 0,2	5 199 607	-0,125	0,14
d	2; 0,5	6 375 149	-0,142	0,15
d	5; 1	6 875 994	-0,151	0,18
d	5; 0,2	3 720 552	-0,095	0,17
d	5; 0,5	5 905 299	-0,134	0,15
n	2; 1	8 050 253	-0,145	0,17
n	2; 0,2	5 958 207	-0,119	0,14
n	2; 0,5	7 395 394	-0,136	0,15
n	5; 1	7 971 242	-0,144	0,17
n	5; 0,2	4 246 638	-0,088	0,17
n	5; 0,5	6 842 756	-0,132	0,15
o	2; 1	8 293 970	-0,150	0,19
o	2; 0,2	6 999 426	-0,153	0,17
o	2; 0,5	7 837 259	-0,147	0,17
o	5; 1	8 287 750	-0,149	0,19
o	5; 0,2	6 729 067	-0,158	0,17
o	5; 0,5	7 781 547	-0,146	0,17


(*o*: original LAS dataset; *d*: distance-based filter with island detection; *n*: neighbourhood-based filter; *CS*: cloth size; *Thd*: threshold; *SD*: standard deviation)

The cloth simulation filter has two important parameters. The first parameter is cloth size, which is in accordance with the point cloud density. The point density was 4 points/m²; furthermore, calculating with multiple echoes, it can even reach 10 points/m². Accordingly, a

finer cloth size would have been reasonable, the recommendation of the developer is one-third of the point spacing, but according to the mean difference between the two settings, the 5 m cloth was 0.012 m better than the neighbourhood-related filter. The second CSF parameter is the threshold, whereas a value of 0.5 was suggested by the developer, but this was not the best setting in our case. A smaller value of 0.2 resulted in more accurate models with all interpolation methods. Thus, in this fluvial environment, I recommend the use a resolution of 5 m and a threshold value of 0.2 among the parameters of the CSF.

In the case of the interpolation methods subtracting the worst from the best model, the largest difference in modelled height was -1.71 m (*Figure 3*). The noise is mainly concentrated in the area with higher density of vegetation. In the case of interpolations, we have drawn two conclusions: the natural neighbour (NA) method provided the most accurate model considering the medians; regarding the range of the differences, the topo to raster (TT) and terrain dataset approaches with natural neighbour interpolations (TD, TH) provided the best DTMs. Based on these results, I suggest that the use of TT, TD, and TH interpolation should be considered if ESRI ArcGIS software is available, because they showed medians only with slightly lower differences than the best NA, but their ranges were narrower. This can be an advantage as the potential error is smaller.

In terms of resolution, the coarser 2 m resolution was on average 0.009-0.012 m closer to the height measured at the reference points than the finer 1 m. However, in identifying smaller, narrower forms of floodplain (e.g. crevasse channel, narrower swale or point bar), it should be noted that only forms that are the same or larger in size than the resolution of the DTM pixels can be identified; thus, I used a resolution of 1 meter during the analysis. I suggest considering this fact in other floodplains as well.



(a) $o|2|0.2|LI$: o : original database; first number: cloth size parameter (2); second number: threshold parameter (0.2); LI : linear interpolation; (b) $n|5|0.2|NA$: n : neighborhood-based noise filter; first number: cloth size parameter (5); second number: threshold parameter (0.2); NA : natural neighbor interpolation. (c) The difference between $o|2|0.2|LI$ and $n|5|0.2|NA$ terrain models

Figure 3. The best and the worst models according to the range of medians and the differences between them

Thesis Statement 3.

In the case of the pixel-based SVM classification of the swales and point bars, I found that 71% classification accuracy can be achieved using the DTM, NDVI, slope and aspect variables.

The maps of the floodplain forms resulting from the pixel-based SVM classification had an OA 71% (Table 1). According to the error matrix, the most favourable solution was when we took all variables into account; the average error was 26% for point bars and 30% for swales.

Table 2. Error matrix of the landscape variables

Variables	OA (%)	Point bar PA (%)	Swale PA (%)
DTM	66	79	54
Aspect	52	23	82
Slope	54	38	69
NDVI	44	14	90
DTM+NDVI	69	73	65
DTM+Aspect	68	75	60
DTM+Slope	68	74	63
DTM+NDVI+Slope	71	73	67
DTM+NDVI+Aspect	69	72	67
DTM+Aspect+Slope	68	73	62
NDVI+Aspect+Slope	59	50	67
NDVI+Aspect+Slope+DTM	71	74	70

Using the DTM alone resulted in the most accurate classification for point bars, 79%. Classification of NDVI, slope and aspect performed best for swales. The least accurate were the case of NDVI pixels were the model classified almost homogeneously to swales, resulted merely 14% PA for point bars, which was not acceptable.

Thesis Statement 4.

In the case of the pixel-based classification 81% and in the object-based approach 95% accuracy can be achieved by the Random Forest classifier using morphometric variables.

RFE variable selection method was performed together with RF classification. It helped to identify the most important variables (preserving the high performance of the model and reducing the risk of overfitting), in which the ranks were the following:

- (1) Pixel-based (PB) approach: maximum OA had been reached with 20 variables:
 GenSurf>DTM>ElRel>FlodO>TPI>MRVBF1>DevME3>DifME3>ValDpth>RidgLvl>ConvISR>ElevP3>MxEMg>DifME2>ElevP2>DevME2>MRRTF1>VRM>MRRTF2>SedTI.

- (2) Object oriented (OO) approach: maximum OA had been reached with 13 variables:

MRVBF1>MorfFeat>MS_TPI2>ConvISR>DifME1>DevME1
>FlodO>ConvI>MS_TPI1>ElRel> LocCurv>DTM >GenSurf.

The stability analysis with 11 randomly selected data sets out of 5,000 pixels and 265 forms showed that different variables contribute to the highest overall accuracy, in case of the object-oriented and pixel-based approaches. The PB-approach showed that the number of optimal variables (i.e., ensuring the largest OA) varied between 11 and 20, and the OAs varied between 78.5% and 81.1%. GenSurf was the first in the rank order in eight cases out of the 11 repetitions, ElRel was the second in eight cases, DTM was the third in seven cases. In the OO-approach the optimal number of variables varied between 10 and 60, with almost the same OAs between 95.2% and 95.7%. The most important variable was MRVBF1, which was the first in the rank order in 11 cases of the 11 repetitions. The second in the list was MorfFeat in 11 cases, the third was ConvISR in 5 cases. Overall, the most important geomorphometric variables for the pixel-based approach were GenSurf, ElRel, DTM, FlodO, and TPI, and for the object-oriented approach MRVBF1, MorfFeat, ConvISR, MS_TPI2, and DevME1.

For the pixel-based RF method, including all 61 variables in the classification, the overall accuracy was 80.7%, and according to RFE, the optimal 20 variables resulted in an overall accuracy of 79.5%. The model with four geomorphometric indices – GenSurf, ElRel, DTM and FlodO –, was only 4.6% worse in the prediction than when 61 variables were used (*Figure 4a*). In the object-oriented classifications, the best overall accuracy was for the model of the 10 variables (95.4%) (*Figure 4b*). The optimal 13 variables according to RFE variable selection were only the seventh best model in the list.




Figure 4. Classification accuracies of different variable sets


(Using a 10-fold cross-validation with 3 repetitions (i.e., 30 models); (a) PB: pixel-based approach; (b) OO: object-oriented approach)

Thesis Statement 5.

I have shown that there were significant differences in the heavy metal accumulation pattern of the swale and point bar forms. The correlations of the revealed heavy metal accumulation patterns in other floodplains also can help to identify hotspot areas with high heavy metal content.

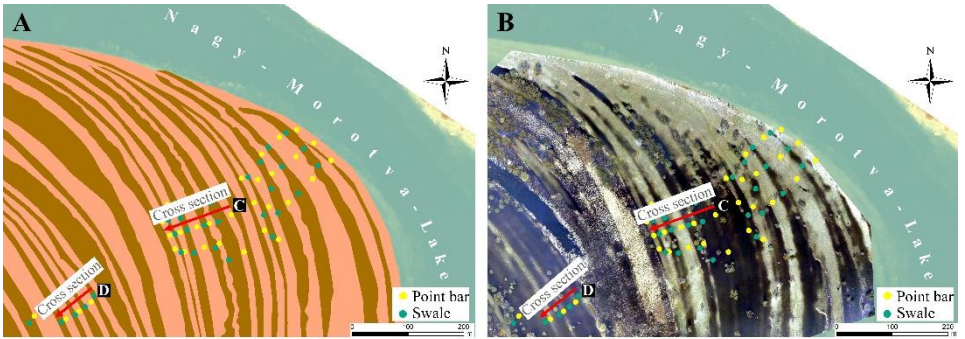
The geomorphology-based analysis of heavy metals revealed that the swale and point bar forms are important factors influencing the horizontal metal pattern of the floodplain: significant differences ($p < 0.05$) were found in Fe, K, Mg, Mn, Cr, Cu, Ni, Pb and in terms of Zn, between the two forms (*Figures 5 and 6*). This was due to the higher organic matter content ($4.9 \pm 1.3\%$, while in the case of point bars it was $4.2 \pm 1\%$) and the finer particle size of swales (clay content $36.9 \pm 3.2\%$ and $10.6 \pm 2.2\%$ of sand, compared to $33.4 \pm 5.6\%$ of clay and $17.6 \pm 7.9\%$ of sand in the point bars), which provided more favourable conditions for binding of metals. Based on the GLM, we obtained different results for the macro- and microelements: the concentration of the macro-elements was determined by the organic matter, while in case of the microelements the clay content and the forms were significant

explanatory variables. On the other hand, the metal concentration in the swales may be also higher as a result of erosion and leaching. Point bars are positive, higher-lying forms that have a better infiltration capacity due to the higher sand fraction, so infiltration water and surface runoff can wash out the finer particles - which bind metals - and thus reduce the heavy metal concentration in the point bars and rise the amount of metal in adjacent swales (*Figure 6*). Third, the denser vegetation of the swales also reduces the flow rate of water and increases deposition.




(PB: point bar—grey, S: swale—orange; whiskers: $1.5 \times$ interquartile range, •: outliers; box: lower quartile, median, upper quartile; notch: 95% confidence interval of the median)


Figure 5. The accumulation differences between the two landforms



C



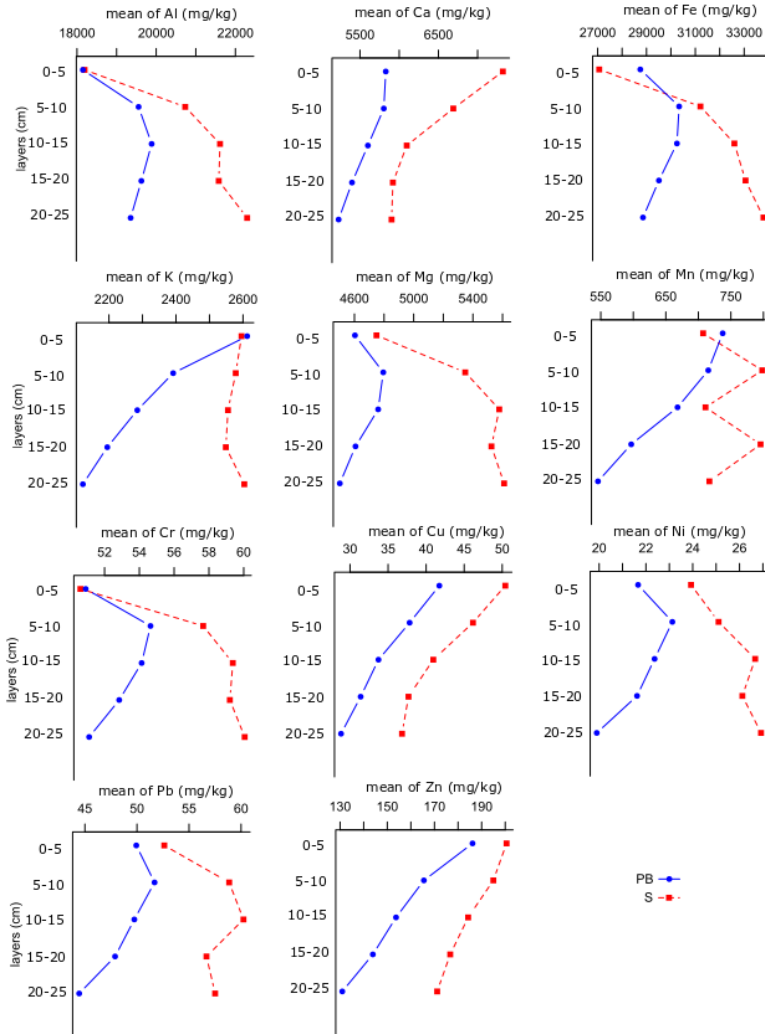
D



(A) The digitized fluvial forms in a LiDAR-based digital terrain model; (B) point bar-swale series in an aerial image during flood; (C, D) cross sections of point bars and swales in a LiDAR point cloud (z exaggeration: 2) and their metal concentrations. When point bars have denser vegetation and they are in lower position their metal concentrations were higher, as it reflected in case of C in the first two point bars

Figure 6. Point bar and swale topography, and their heavy metal accumulation pattern

The vertical distribution also differed significantly from form to form: all layers had higher metal concentrations (except Ni) in the swales. While Al, Fe, Mg, and Cr concentrations gradually increased, all other metals in the deeper layers showed a decreasing trend (Figure 7).



PB: point bar—blue; S: swale—red)

Figure 7. Interaction plot of the vertical distribution of metals

In the case of swales, Pb heavy metal was identifiable in larger amounts in the 5–10 cm layer. This meant that sediment of about 5–10 cm thickness had accumulated in the study area since 2000 (when the heavy metal-contaminated flood wave receded on the Tisza). However, the reason for the accumulation was not only the sedimentation of the suspended sediment from the flooded water, but also the erosion of the higher-lying, point bars forms, the leaching of fine particles, and the accumulation of organic matter.

Appendix – a list of abbreviations and settings for the most important morphometric layers based on the results of RFE variable selection

Morphometric variables	Abbreviation	Settings
Flood Order	FlodO	-
Elevation Relative To Min and Max	EIRel	-
Deviation from Mean Elevation	DevME1	Search Neighborhood Size: 8
	DevME2	Search Neighborhood Size: 16
	DevME3	Search Neighborhood Size: 32
Difference from Mean Elevation	DifME1	Search Neighborhood Size: 8
	DifME2	Search Neighborhood Size: 16
	DifME3	Search Neighborhood Size: 32
<i>Maximum Elevation Deviation (Multiscale) Magnitude</i>	MxEMg	Maximum Neighborhood Radius (cell): 1498
Elevation Percentile	*ElevP1	Search Neighborhood Size: 8
	ElevP2	Search Neighborhood Size: 16
	ElevP3	Search Neighborhood Size: 32
Sediment Transport Index	SedTI	-
Convergence Index	ConvI	Defaults
Convergence Index (Search Radius)	ConvISR	Defaults
<i>Upslope and downslope curvature</i>		
Local Curvature	LocCurv	Defaults
<i>Multiresolution Index of Valley Bottom Flatness</i>		
Multiresolution Index of Valley Bottom Flatness	MRVBF1	Defaults
	*MRVBF2	Initial threshold for slope: 8
Multiresolution Ridge Top Flatness Index	MRRTF1	Defaults
	MRRTF2	Initial threshold for slope: 8
Topographic Position Index	TPI	Defaults
Multi-Scale Topographic Position Index	MS-TPI1	Defaults
	MS-TPI2	Min Scale: 8 Max Scale: 8
Generalized Surface	GenSurf	Defaults
<i>Valley Depth</i>	Valdpth	
Valley Depth	RidgLvl	Defaults
Ridge Level		
Morphometric features	MorfFeat	Defaults
Vector Ruggedness Measure	VRM	Defaults

*These settings were not among the most important variables



Registry number: DEENK/79/2022.PL
Subject: PhD Publication List

Candidate: Zsuzsanna Szabó Csatáriné
Doctoral School: Doctoral School of Earth Sciences
MTMT ID: 10050415

List of publications related to the dissertation

Foreign language scientific articles in international journals (4)

1. **Szabó, Z.**, Tóth, C. A., Holb, I., Szabó, S.: Aerial Laser Scanning Data as a Source of Terrain Modeling in a Fluvial Environment: Biasing Factors of Terrain Height Accuracy. *Sensors*. 20 (7), 1-18, 2020. ISSN: 1424-8220.
DOI: <http://dx.doi.org/10.3390/s20072063>
IF: 3.576
2. **Szabó, Z.**, Buró, B., Szabó, J., Tóth, C. A., Baranyai, E., Herman, P., Prokisch, J., Tomor, T., Szabó, S.: Geomorphology as a Driver of Heavy Metal Accumulation Patterns in a Floodplain. *Water*. 12 (2), 1-16, 2020. EISSN: 2073-4441.
DOI: <http://dx.doi.org/10.3390/w12020563>
IF: 3.103
3. **Szabó, Z.**, Mikita, T., Négyesi, G., Varga, O. G., Burai, P., Takács-Szilágyi, L., Szabó, S.: Uncertainty and Overfitting in Fluvial Landform Classification Using Laser Scanned Data and Machine Learning: A Comparison of Pixel and Object-Based Approaches. *Remote Sens*. 12 (21), 1-29, 2020. ISSN: 2072-4292.
DOI: <https://doi.org/10.3390/rs12213652>
IF: 4.848
4. **Szabó, Z.**, Tóth, C. A., Tomor, T., Szabó, S.: Airborne LiDAR point cloud in mapping of fluvial forms: a case study of a Hungarian floodplain. *GISci. Remote Sens*. 54 (6), 862-880, 2017. ISSN: 1548-1603.
DOI: <http://dx.doi.org/10.1080/15481603.2017.1339987>
IF: 2.852

Hungarian conference proceedings (3)

5. **Szabó, Z.**, Szabó, J., Tomor, T., Baranyai, E., Prokisch, J., Szabó, S.: Övzátónyok és sárlapások nehézfém mintázatának vizsgálata rakamazi mintaterületen.
In: Az elmélet és a gyakorlat találkozása a térinformatikában X.. Szerk.: Molnár Vanda Éva, Debreceni Egyetemi Kiadó, Debrecen, 295-300, 2019. ISBN: 9789633180549





6. **Szabó, Z.**, Szabó, S.: A rakamazi ártér vízborítottság rövid távú változásának nyomon követése Sentinel-2 felvételek alapján.
In: Az elmélet és a gyakorlat találkozása a térinformatikában IX. : Theory meets practice in GIS. Szerk.: Molnár Vanda Éva, Debrecen Egyetemi Kiadó, Debrecen, 333-339, 2018. ISBN: 9789633187234
7. **Szabó, Z.**, Szabó, S., Szabó, J., Tomor, T., Hunyadi, G.: Felszínfejlődési szakaszok és formák vizsgálata LiDAR felmérés alapján a Tisza hullámterén.
In: Az elmélet és a gyakorlat találkozása a térinformatikában VI.: Térinformatikai konferencia és szakkiallítás. Szerk.: Boda Judit, Debreceni Egyetemi Kiadó, Debrecen, 387-394, 2015. ISBN: 9789633184882

Hungarian abstracts (2)

8. **Szabó, Z.**, Szabó, S., Tomor, T.: Előzetes eredmények a hullámterí formaelemek LiDAR alapú meghatározásáról.
In: Az elmélet és a gyakorlat találkozása a térinformatikában VII. : Térinformatikai Konferencia és Szakkiallítás. Szerk.: Balázs Boglárka, Debreceni Egyetemi Kiadó, Debrecen, 455, 2016. ISBN: 9789633185704
9. **Szabó, Z.**: Fluviális felszínformák osztályozása LiDAR felhasználásával rakamazi mintaterületen.
In: Absztraktkötet : Magyar Földrajzi Napok 2016 : VIII. Magyar Földrajzi Konferencia : XVI. Geográfus Doktoranduszok Országos Konferenciája : Oktatás-módszertani és Földrajztanári Konferencia. Szerk.: Pajtókné Tari Ilona, Tóth Antal, Magyar Földrajzi Társaság, Budapest, 145-146, 2016. ISBN: 9786158030717

List of other publications

Hungarian book chapters (3)

10. **Szabó, Z.**, Balla, D. Z.: Nekézsény túraútvonal hálózatának kialakítása az ökoturizmus elősegítése érdekében.
In: Földrajzi Tanulmányok 2018. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 377-379, 2018. ISBN: 9789635086973
11. Balla, D. Z., **Szabó, Z.**, Molnár, D.: Tanösvények webes geovizualizációja az Upponyi-hegység területén.
In: Földrajzi Tanulmányok 2018. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 373-375, 2018. ISBN: 9789635086973





12. **Szabó, Z.:** Az "energianád" (*Miscanthussinensis 'Giganteus'*) biomassza célú termesztésének főbb jellemvonásai.
In: Vidéki erőforrások hasznosítása. A KRF Természeti Erőforrás-gazdálkodási és Vidékfejlesztési Kara hallgatóinak kutatási eredményei. Szerk.: Koncz Gábor, Károly Róbert Kutató-Oktató Közhasznú Non-profit Kft., Gyöngyös, 59-70, 2011. ISBN: 9789639941212

Hungarian scientific articles in Hungarian journals (2)

13. Burai, P., Lénárt, C., Valkó, O., Bekő, L., **Szabó, Z.**, Deák, B.: Fátlan vegetációtípusok azonosítása légi hiperspektrális távérzékelési módszerekkel.
Tájékol. Lapok. 14 (1), 1-12, 2016. ISSN: 1589-4673.
14. **Szabó, Z.:** Belvízcsatorna-rekonstrukciós munkálatok hatásainak térinformatikai elemzése síkvidéki mintaterületen.
Agrárinformatika. 1 (3), 40-47, 2010. ISSN: 2061-862X.
DOI: <http://dx.doi.org/10.17700/jai.2010.1.3.27>

Foreign language scientific articles in international journals (3)

15. Varga, O. G., Kovács, Z., Bekő, L., Burai, P., **Szabó, Z.**, Holb, I., Ninsawat, S., Szabó, S.:
Validation of Visually Interpreted Corine Land Cover Classes with Spectral Values of Satellite Images and Machine Learning.
Remote Sens. 13 (5), 1-24, 2021. EISSN: 2072-4292.
DOI: <http://dx.doi.org/10.3390/rs13050857>
IF: 4.848 (2020)
16. Varga, O. G., Pontius, R. G., **Szabó, Z.**, Szabó, S.: Effects of Category Aggregation on Land Change Simulation Based on Corine Land Cover Data.
Remote Sens. 12, 1-16, 2020. EISSN: 2072-4292.
DOI: <http://dx.doi.org/10.3390/rs12081314>
IF: 4.848
17. **Szabó, Z.**, Schlosser, A. D., Túri, Z., Szabó, S.: A review of climatic and vegetation surveys in urban environment with laser scanning: A literature-based analysis.
Geogr. Pannon. 23 (4), 411-421, 2019. ISSN: 0354-8724.
DOI: <http://dx.doi.org/10.5937/gp23-24675>

Hungarian conference proceedings (1)

18. **Szabó, Z.:** Térinformatikai vizsgálatok a vidéki természeti erőforrások védelme érdekében.
In: Agricultural Informatics 2010 Conference Proceedings. Ed.: by Alexander B. Sideridis, Miklós Herdon, László Váralyai, Hungarian Association of Agricultural Informatics (HAAI), Debrecen, 229-234, 2010. ISBN: 9789638736642





Hungarian abstracts (3)

19. **Szabó, Z.**, Szabó, J., Tomor, T., Baranyai, E., Prokisch, J., Szabó, S.: Az ártér geomorfológiájának szerepe a nehézfémek mintázatában Sajó menti mintaterületen.
In: Az elmélet és a gyakorlat találkozása a térinformatikában X.. Szerk.: Molnár Vanda Éva, Debreceni Egyetemi Kiadó, Debrecen, 293-294, 2019. ISBN: 9789633180549
20. **Szabó, Z.**, Balla, D. Z.: Nekézseny túraútvonal hálózatának kialakítása az ökoturizmus elősegítése érdekében.
In: IX. Magyar Földrajzi Konferencia előadásainak és posztereinek összefoglalói. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 175, 2018. ISBN: 9789635088966
21. Balla, D. Z., **Szabó, Z.**, Molnár, D.: Tanösvények webes geovizualizációja az Upponyi-hegység területén.
In: IX. Magyar Földrajzi Konferencia előadásainak és posztereinek összefoglalói. Szerk.: Fazekas István, Kiss Emőke, Lázár István, MTA DTB Földtudományi Szakbizottság, Debrecen, 174, 2018. ISBN: 9789635088966

Total IF of journals (all publications): 24,075

Total IF of journals (publications related to the dissertation): 14,379

The Candidate's publication data submitted to the iDEa Tudóstér have been validated by DEENK on the basis of the Journal Citation Report (Impact Factor) database.

09 February, 2022

