

FÁTLAN VEGETÁCIÓTÍPUSOK AZONOSÍTÁSA LÉGI HIPERSPEKTRÁLIS TÁVÉRZÉKELÉSI MÓDSZERREL

BURAI Péter¹, LÉNÁRT Csaba¹, VALKÓ Orsolya², BEKŐ László¹, SZABÓ Zsuzsanna³,
DEÁK Balázs²

¹ Károly Róbert Főiskola, Távérzékelési és Vidékfejlesztési Kutatóintézet
3200 Gyöngyös Mátrai út 36. email: pburai@karolyrobert.hu, lenart.dr@gmail.com, lbeko@karolyrobert.hu

² MTA-DE Biodiverzitás Kutatócsoport
4032 Debrecen, Egyetem tér 1. email: debalazs@gmail.com, valkoorsi@gmail.com

³ Debreceni Egyetem, Természetföldrajzi és Geoinformatikai Tanszék
4032 Debrecen, Egyetem tér 1. email: zs.szabozsuzsa@gmail.com

Kulcsszavak: vegetációtérképezés, Maximum Likelihood Classifier (MLC), Random Forest (RF), Support Vector Machine (SVM), szikes gyepek, szikes mocsár, AISA Eagle II

Összefoglalás: Munkánk során egy szikes táj vegetációtípusainak osztályozását végeztük el, légi hiperspektrális adatok felhasználásával. A munka célja a hiperspektrális adatok alkalmazhatóságának vizsgálata volt a komplex társulásoknál, eltérő képosztályozási módszerek alkalmazásával. Vizsgálatunkban hagyományos osztályozó eljárások (Maximum Likelihood Classifier – MLC, Random Forest – RF és Support Vector Machine – SVM) eredményességét teszteltük 10 és 30 pixeles tanítóterületek felhasználásával. A mozaikolt hiperspektrális felvételen a zajsűrés és az információnyerés céljából MNF transzformációt alkalmaztunk. A légi hiperspektrális felvétel AISA EAGLE II szenzorral készült 1m terepi felbontásban. Társulástani besorolás és felszínborítás alapján összesen 20 vegetációosztályt alakítottunk ki. Az osztályokat további négy főbb élőhelykategóriába soroltuk: sztyeppék, nyílt szikes gyepek, szikes rétek, szikes és nem szikes mocsarak. Az SVM és az RF osztályozó eljárások, a pixelek számától függetlenül, majdnem minden vegetációosztálynál megbízhatóan működtek, nagy osztályozási pontosságot adtak. Az MLC bár nagy mintaszámnál nagy pontosságú osztályozást eredményezett, kis mintaszámnál számos osztály esetében alacsony megbízhatósággal működött. Az eredmények alapján elmondható, hogy a komplex fátlan táji környezetben a vegetáció osztályozásra az SVM megfelelő osztályozó lehet, mivel nagyobb pontosságot nyújt, mint az RF és az MLC. Az SVM bizonyult a legkevésbé érzékenynek a tanító területek méretére, így alkalmas lehet azokban az esetekben, amikor néhány osztálynál az elérhető pixelek száma korlátozottan áll rendelkezésre.

Bevezetés

A hagyományos terepi felmérések mellett napjainkban egyre elterjedtebb módszer az egyes távérzékelési technikák alkalmazása az élőhely- és vegetációtérképezésben (BORRE et al. 2011). A távérzékelés előnye, hogy alkalmazásával nagy kiterjedésű területekről lehet gyorsan, jó tematikai pontosságú adatot szolgáltatni, akár olyan területekről is (mint például az árterek vagy meredek lejtők), amelyek terepi megközelítése nehézségekbe ütközhet (HARRIS et al. 2015, MÜCKE et al 2013). A céltól és az anyagi lehetőségektől függően számos adatforrás áll rendelkezésre: műhold felvételek, lézerszkennelt adatok, hiperspektrális felvételek és hagyományos légifotók. A légifotók mellett térképezési célokra leggyakrabban a kereskedelemben könnyen hozzáférhető műholdfelvételeket alkalmazzák. Ezek terepi felbontása mára már meghaladja a 0,5 métert, azonban a faj szintű elemzésekhez szükséges spektrális információt csak korlátozott mértékben szolgáltatnak. A légi távérzékelés esetében az alacsonyabb repülési magasságnak és az érzékeny szenzoroknak köszönhetően nagy terepi és radiometriai felbontású felvételek készíthetők nagy területekről is, ezért a hiperspektrális technika számos esetben részletesebb információt szolgáltat a környezet monitorozására (THENKABAIL 2011, ADAM et al. 2010). Az elmúlt évtizedben a hiperspektrális távérzékelés és képelemzés a távérzékelés egyik leggyorsabban fejlődő területévé vált, ahol a nagy terepi felbontás mellett akár több száz spektrális csatornát tartalmazó felvételek készítésére is van lehetőség. Egy-egy felvétel nagy geometria felbontásban (0,5-1 m) akár több száz csatornát

tartalmazó folyamatos spektrumot tartalmaz, szemben a műholdak multispektrális adatainak többnyire 4-8 csatornájával. A felvételek anyagi vagy biofizikai tulajdonságok meghatározására is alkalmasak lehetnek. Ennek köszönhetően a hiperspektrális felvételek jól alkalmazhatóak a domináns vagy szubdomináns faj alapú részletes vegetációosztályozásra (HUANG és ASNER 2009, MIRIK et al. 2013).

A Pannon biogeográfiai régió szikes élőhelyei kiváló lehetőséget nyújtanak a távérzékelt adatok felhasználásában rejlő lehetőségek tesztelésére, mivel nagy térbeli komplexitással bírnak és kis léptéken is számos strukturálisan és spektrálisan is hasonló élőhely fordul elő bennük (DEÁK et al. 2014a, ALEXANDER et al. 2016, BURAI et al. 2015, ZLINSZKY et al. 2014). A szikes élőhelyeket általában már kis léptéken is számos vegetációtípus együttes előfordulása jellemzi, melyben a foltok mérete igen változatos lehet (a pár négyzetmétertől a több hektárig) (DEÁK et al. 2014a, KELEMEN et al. 2013). Az ilyen komplex élőhelyekben a terepi élőhely térképezés esetenként igen bonyolult és időigényes feladat, a foltszám meghaladhatja az akár 500 folt/km²-t is (HÖDÖR I. szóbeli közlése). Szikes élőhelyeken az élőhelyek előfordulásának térbeli mintázatát elsősorban a talaj sótartalma és a vízellátottság határozza meg (TÓTH és KERTÉSZ 1996, DEÁK et al. 2014a, 2015a, VALKÓ et al. 2014). Az egyes élőhely típusokba tartozó növénytársulások sok hasonlóságot mutatnak egymással megjelenésük, biomasszájuk, szerkezetük és környezeti feltételeik tekintetében, ami miatt a távérzékelt adatok osztályozása gyakran kihívást jelent (ALEXANDER et al. 2015). További nehézséget jelenthet még, hogy egyes társulások csak kis foltokban, és egyes esetekben elszórtan vannak jelen a tájban, így a távérzékelt adatok osztályozásához szükséges mennyiségű terepi adat gyűjtése problémás lehet.

Célunk hiperspektrális adatok alkalmazhatóságának tesztelése volt komplex szikes tájban. Teszteltük, hogy az eredeti sávokból származtatott NDVI értékek alapján milyen pontossággal különböztethetőek meg az egyes növényzeti osztályok. Megvizsgáltuk továbbá három széles körben alkalmazott osztályozási eljárás (Maximum Likelihood Classifier – MLC, Random Forest – RF és Support Vector Machine – SVM) hatékonyságát MNF transzformált sávokon, különböző méretű tanítóterületek felhasználásával.

Anyag és módszer

A mintaterület leírása

Mintaterületnek a Hortobágyi Nemzeti Park területén található Pentezug-pusztát (N 47°34' E 21°06') választottuk. A terület éghajlata mérsékelt kontinentális, az átlagos évi középhőmérséklet 9,5 °C, az évi csapadékmennyiség 550 mm. A csapadék évek közötti eloszlására jelentős fluktuációk jellemzőek (LUKÁCS et al. 2015). A 23,49 ha-os területen előfordulnak a térség szikes tájaira jellemző élőhelytípusok: sztyeppék, nyílt szikes gyepek, szikes rétek, szikes- és nem szikes mocsarak (DEÁK et al. 2015b, KELEMEN et al. 2015, MOLNÁR et al. 2008). Az egyes vegetáció osztályokba tartozó növénytársulások leírása a Vegetációosztályok fejezetben található meg.

Légi adatgyűjtés

A hiperspektrális adatfelvételezés AISA EAGLE II szenzorral készült, 128 folyamatos spektrális csatornában (395,71–996,40nm), 4,4-4,8nm közötti spektrális és 1m terepi felbontásban. A navigációs adatokat OxTS 3003 típusú GNSS/INS rendszer gyűjtötte. A felvételezésre jó időjárási körülmények között, 2013. július 7-én, 9:11 és 9:53 között került sor.

Légi adatok feldolgozása

A mintaterületet lefedő 4 hiperspektrális sáv radiometriai és geometriai korrekcióját CaliGeoPro programmal végeztük. A radiometriai korrekcióhoz a kamera kalibrációs adatokat alkalmaztunk. A geometriai korrekciónál a belső tájékozási adatok mellett a GNSS/IMU navigációs adatait és LiDAR adatokból interpolált terepmodellt alkalmaztunk, így a pixel közeli pontosság is elérhető. Az atmoszférikus korrekcióhoz és a sávok mozaikolására ENVI/IDL 5.0 (Exelis, Inc., Boulder, CO, USA) programot alkalmaztunk. A további feldolgozáshoz a mozaikból kivágott 2500×3500m-es adatkockát használtuk (1. ábra).



1. ábra. A mintaterület elhelyezkedése (forrás: Google Earth; 2012 október).
Figure 1. Location of the study site (source: Google Earth; October 2012).

Terepi mintavételezés

Minden, a mintavételi területre jellemző vegetáció-osztályból referencia adatokat gyűjtöttünk a repülést követő egy héten belül. Tekintettel arra, hogy a vizsgált szikes élőhelyek igen mozaikosak (növényborítottság, foltok mérete és elhelyezkedése), a terepi felvételezés előtt egy előzetes terepszemlélt is tartottunk, annak érdekében, hogy optimalizálhassuk a felméréseket. Az előzetes terepi felmérés során feljegyeztük a tipikus vegetáció-osztályokat, megbecsültük az átlagos foltméretüket és a teljes mintaterületből való részesedésüket. A légi felvételezést követő terepi felmérés során a már korábban listázott vegetáció-osztályokból differenciális GPS segítségével összesen 98 homogén foltot mértünk fel. A foltokban felmértük a növényzet összborítását, a domináns (>50%) és szubdomináns (10-50%) fajok listáját és borítását, a vegetáció magasságát és a csupasz talajfelszín borítását. A felmért foltok növényzetét BORHIDI et al. (2012) alapján növénytársulásokba soroltuk.

Vegetációosztályok

Munkánk során kizárólag a fátlan élőhelyek osztályozására koncentráltunk, melyek a mintaterület több mint 99,5 %-át borították. Összesen 17 osztályt különítettünk el társulástani

alapon (BORHIDI et al. 2012). Az emberi tevékenységnek fokozottan kitett területeken illetve a növényzetmentes felszíneken további három osztályt különítettünk el felszínborítás alapján: ISZA – iszapos felszínek, KASZ – közvetlenül a repülés előtt lekaszált gyepek és SZAN – szántóföld). A társulások az alábbi fő élőhely kategóriákba sorolhatóak: sztyeppék, nyílt szikes gyepek, szikes rétek, szikes és nem szikes mocsarak. A vegetáció osztályokat négybetűs rövidítésekkel jelöltük; a vegetációosztályonkénti pixelszámot az alábbiakban a rövidítést követően zárójelben adtuk meg.

Sztyeppék

CYPO (211) – A magasabb térszíneken található csernozjom talajon kialakult löszgyepek tartoznak ebbe az osztályba (TÓTH & HÜSE 2014). Domináns fűfajai a *Cynodon dactylon* és a *Festuca rupicola*, melyek zárt gyepeket alkotnak. Megtalálhatóak bennük a térség löszgyepeire jellemző kétszikű generalista fajai (*Centaurea pannonica*, *Galium verum*, *Hypericum perforatum*), de – valószínűleg egy korábbi túllegeltetés miatt – számos gyomfaj is előfordul bennük, mint az *Eryngium campestre*, *Ononis spinosa* és a *Carduus acanthoides*.

ACFE (141) és ARFE (96) – Cickafarkfüves (ACFE) és ürmös szikes puszták (ARFE). Közepesen sós szolonyec talajokon találhatóak, közös domináns fűfajuk a *Festuca pseudovina* (KELEMEN et al. 2015). Mindkét társulás átlagos növényzeti borítása 80% körüli volt. A cickafarkfüves gyepek fajösszetételükben átmenetet mutatnak a löszgyepek felé közös fajaik az *Achillea collina*, *Centaurea pannonica* és *Plantago lanceolata*, ugyanakkor számos sőtűró fajt is feljegyeztünk (*Podospermum canum* és *Inula britannica*). Az ürmös gyepek szubdomináns faja az *Artemisia santonica*, sőtűró fajai a *Bupleurum tenuissimum*, *Aster tripolium* és *Podospermum canum* voltak.

Nyílt szikes gyepek

CAMA (118), PHPA (142), ARTE (64) – Vakszik (CAMA) és szikénövényzet (PHPA). Mindhárom osztályra jellemző a nyílt talajfelszínek nagy aránya; a bárányparéjos osztály a különösen magas sótartalmú talajon alakult ki (ZLINSZKY et al. 2015). Mindhárom osztály igen fajszegény, a bárányparéjos domináns faja a *Camphorosma annua*, a szikér osztályban a *Pholiurus pannonicus* mellett még a *Plantago tenuiflora* volt a jellemző. Egyes helyeken a szikér állományok kilúgzása következtében az *Artemisia santonica* és a *Festuca pseudovina* borítása növekedett, ezeket az állományokat a kilúgzott szikes (ARTE) osztályba soroltuk be.

Szikes rétek

AGAL (531), AGBE (552), AGEL (402), GYOM (82) – Ecsetpázsitos, hernyópázsitos és tarackbúzás szikes rétek. Jellemzően hosszú fűvű társulások, melyekben a társulások névadó fajai dominálnak (*Agrostis stolonifera*, *Alopecurus pratensis*, *Beckmannia eruciformis* és *Elymus repens*, DEÁK & TÓTHMÉRÉSZ 2006, DEÁK et al. 2014b). A növényzet összborítása 65 és 90% között volt. Az ecsetpázsitos és tarackbúzás állományok a szárazabb termőhelyeken, a hernyópázsitos állományok a mélyebben fekvő, jobb vízellátottságú területeken voltak jelen. Az erősen gyomosodó (elsősorban *Cirsium arvense* által jellemzett) ecsetpázsitos és tarackbúzás állományokat a gyomos rét (GYOM) osztályba soroltuk.

CARE (253) – *Carex riparia* és *C. melanostachya* által alkotott fajszegény magassásosok. Állományaikat nagy növényzeti borítás jellemzi.

Szikes és nem szikes mocsarak

GLYM (229), TYPA (63), BOLB (179), SCHO (121), PHRA (297), TYSA (65) – A szikes és nem szikes mocsarak csoportjába számos egymástól jelentősen különböző megjelenésű társulás tartozik (DEÁK et al. 2015b). Általánosan jellemző rájuk, hogy a terület legmélyebb pontján található jó vízellátottságú területeken helyezkednek el, a domináns fajaik magas növésű higrofita egyszikűek és a növényzet összborítása 70% fölött van. Domináns fajaik a társulások névadó egyszikű fajai: *Glyceria maxima* (GLYM), *Typha angustifolia* (TYPA), *Bolboschoenus maritimus* (BOLB), *Schoenoplectus lacustris* subsp.

tabernaemontani (SCHO), és a *Phragmites communis* (PHRA). Az összes társulásra jellemző, hogy igen fajszegények, kevés számú higrofita faj található meg bennük. A tipikus megjelenésű gyékényesek mellett találtunk olyan állományokat, amelyek kiritkultak, a *Typha* borítása 40% alatti volt, ugyanakkor az alsó szintben a *Salvinia natans* borítása elérhette akár a 80%-ot is. Ezt a típust külön osztályoztuk TYSA néven.

Felszínborítás alapján három további osztályt hoztunk létre: ISZA (158) – iszapos felszínek, amelyek elsősorban a vizes élőhelyek szegélyében jelentek meg. SZAN (123) – tarlók, learatott gabonaföldek, amelyen a fennmaradt növényi részek mellett gyomfajok voltak jelen. A repülés előtti időszakban a területen található rétek egy részét lekaszálták, ezeket a kaszáló (KASZ; 351) osztályba soroltuk.

Osztályozás NDVI értékek alapján

A normalizált vegetációs index (NDVI) az elmúlt évtizedekben az egyik leggyakrabban és szélesebben körben használt vegetációs index (AMBRUS et al. 2015, PARUELO et al. 1997; PETTORELLI et al. 2005). Az NDVI jól hasznosítható információt szolgáltat az egyes növényfajok eloszlásáról, vegetációs mintázatokról és a növények fiziológiai állapotáról (PETTORELLI 2013). Vizsgálatunkban adatfeltáró jelleggel az egyes növényzeti osztályok elkülönítéséhez keskenysávú NDVI értékeket használtunk, amelyeket a vörös (679nm) és az közeli-infravörös (800nm) sávok felhasználásával számoltunk ki (HURCOM és HARRISON, 1998). Az osztályozáshoz osztályonként 50 random módon kiválasztott pixelt használtunk fel. Az egyes osztályok NDVI értékei közötti különbségek teszteléséhez Mann-Whitney tesztet használtunk (SOKAL és ROHLF 1969). Az egyes osztályok NDVI értékeiből kiszámítottuk az „effect size”-ot, vagy effektust, ami két csoport közötti különbség nagyságát standardizált (azaz összehasonlítható) formában számszerűsíti (SZABÓ et al. 2012).

$$r = \frac{Z}{\sqrt{N}}$$

ahol Z a z-score érték és N a megfigyelések teljes száma.


Képosztályozás MNF transzformált sávok alapján

A hiperspektrális felvételek osztályozását az ENVI/IDL 5.0 (Exelis, Inc., Boulder, CO, USA) és az EnMap Box (RABE et al. 2013) szoftverkörnyezetben végeztük. Az osztályozás során három, vegetáció térképezésre gyakran használt, ellenőrzött osztályozási módszer (MLC, RF and SVM) alkalmasságát vizsgáltuk (MIRIK et al. 2013, HUANG és ASNER 2009, LAWRENCE et al. 2006). Az MLC osztályozásnál a valószínűsége nem határoztunk meg küszöbértéket. Az RF klasszifikációnál 100 döntési fát hoztunk létre Gini koefficiens használatával. Az SVM osztályozás Gaussian Radial Basis Function segítségével valósult meg, C = 100 és $\gamma = 0.11$ paraméterekkel, ötszörös keresztvalidáció mellett. Az osztályozást az első két MNF csatornától az első 15 csatornáig lefuttattuk és az osztályozás teljes pontosságát vizsgálva megállapítottuk, hogy a 9. csatorna után további pontosság javulás nem volt megfigyelhető. A továbbiakban az osztályozásra az első 9 MNF transzformált sávot használtuk. A képosztályozás során a pixel számok hatásának tesztelésére minden vegetációtípusból 10 és 30 pixelt választottunk ki. Nagyobb mintaszám alkalmazására nem volt lehetőség a korlátozott számban rendelkezésre álló terepi adatok miatt. A terepi minta és az ellenőrző adatállomány aránya 50-50% volt. A terepi mintákból a pixelek random módon lettek kiválasztva. Minden vizsgálatnál ugyanazt a validációs adatállományt alkalmaztuk. Az osztályozást elvégeztük mind a vegetáció-osztályokra (20 osztály), mind a tágabb kategóriát képviselő élőhely kategóriákra (4 kategória) is.

Eredmények és megvitatásuk

Osztályozás NDVI értékek alapján

Az NDVI értékek alkalmasak voltak a vizsgált vegetációs osztályok biomassza értékeinek detektálására. Eredményeink alapján megállapítható, hogy az egyes osztályok NDVI értékei egy jól kirajzolódó grádiensnek mutatnak, a gradiens értékei jól megfelelnek a szakirodalomban leírtaknak (KELEMEN et al. 2013, DEÁK et al. 2015b; 2. ábra). A gradiens elején az alacsony és kis növényzeti borítással – így alacsony biomasszával – jellemezhető osztályok találhatók (SZAN, CAMA, PHPA, ARTE és ISZA). A gradiens közepén a rövid és hosszúfüvű gyepek helyezkednek el (például az ACFE, ARFE, AGEL, AGAL). A gradiens végén a nagy biomasszával jellemezhető sásosok és mocsarak találhatók (TYSA, GLYM, TYPA, BOLB, SCHO, PHRA és CARE). Az NDVI értékek önmagukban azonban nem voltak alkalmasak az egyes osztályok elkülönítésére, mivel az azonos élőhely típusba tartozó osztályok hasonló struktúrával (fajösszetétel, összborítás, csupasz talajfelszín aránya és biomasszával) rendelkeznek. A Mann-Whitney teszt és az effect size elemzés eredményei alapján az NDVI értékek felhasználásával az osztályok elkülönítése csak a ACFE, TYSA, GYOM és GLYM osztályok esetében volt lehetséges (1. táblázat). A hasonló megjelenésű osztályok esetében az NDVI értékek nem tértek el szignifikánsan.



2. ábra. A vizsgált vegetációs osztályok NDVI értékei (50 random pixel értékei alapján).
 Figure 2. NDVI scores of the studied vegetation classes (50 pixels from each vegetation class).

Fátlan vegetációtípusok azonosítása légi hiperspektrális távérzékelési módszerrel

	SZAN	CAMA	PHPA	ARTE	ISZA	KASZ	ACFE	ARFE	AGEL	TYSA	AGBE	CYPO	AGAL	GYOM	GLYM	TYPA	BOLB	SCHO	PHRA	CARE
SZAN	0,00	-0,03	-0,19	-0,30	-0,86	-0,85	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
CAMA	-0,03	-0,00	-0,16	-0,26	-0,77	-0,76	-0,84	-0,86	-0,85	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
PHPA	-0,19	-0,16	-0,00	-0,13	-0,85	-0,82	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
ARTE	-0,30	-0,26	-0,13	0,00	-0,86	-0,84	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
ISZA	-0,86	-0,77	-0,85	-0,86	0,00	-0,03	-0,76	-0,84	-0,85	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
KASZ	0,85	-0,76	-0,82	-0,84	-0,03	0,00	-0,75	-0,82	-0,83	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
ACFE	-0,86	-0,84	-0,86	-0,86	-0,76	-0,75	0,00	-0,32	-0,36	-0,68	-0,84	-0,83	-0,85	0,85	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
ARFE	-0,86	-0,86	-0,86	-0,86	-0,84	-0,82	-0,32	0,00	-0,18	-0,61	-0,84	-0,83	-0,85	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
AGEL	-0,86	-0,85	-0,86	-0,86	-0,85	-0,83	-0,36	0,18	0,00	-0,31	-0,72	-0,70	-0,78	-0,82	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
TYSA	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,68	-0,61	-0,31	0,00	-0,84	-0,83	-0,85	-0,85	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
AGBE	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,84	-0,84	-0,72	-0,84	0,00	-0,12	-0,42	-0,65	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86
CYPO	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,83	-0,83	-0,70	-0,83	-0,12	0,00	-0,18	-0,55	-0,82	-0,86	-0,80	-0,86	-0,86	-0,86
AGAL	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,85	-0,85	-0,78	-0,85	-0,42	-0,18	0,00	-0,45	-0,78	-0,85	-0,76	-0,86	-0,86	-0,86
GYOM	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,85	-0,86	-0,82	-0,85	0,65	-0,55	-0,45	0,00	-0,44	-0,68	-0,50	-0,82	-0,86	-0,86
GLYM	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,82	-0,78	-0,44	0,00	-0,35	0,24	-0,61	-0,81	-0,86
TYPA	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,85	-0,68	-0,35	0,00	0,03	-0,30	-0,69	-0,81
BOLB	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,80	-0,76	-0,50	-0,24	-0,03	0,00	-0,13	-0,43	-0,57
SCHO	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,82	-0,61	-0,30	-0,13	0,00	-0,50	-0,69
PHRA	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,81	-0,69	-0,43	-0,50	0,00	-0,23
CARE	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,86	-0,81	-0,57	-0,69	-0,23	0,00

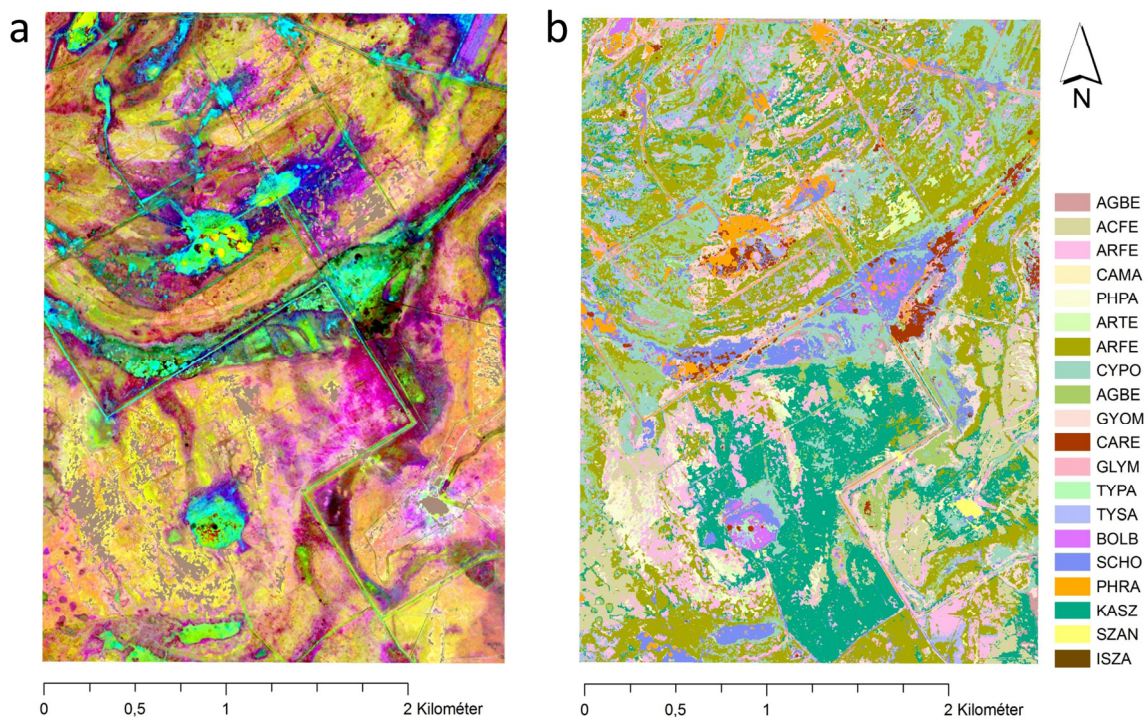
1. táblázat. Effect size és a Mann-Whitney teszt eredményei (N=50; vegetáció osztályonkénti NDVI értékek). A nem szignifikáns ($p>0,05$) eltéréseket félkövér betűtípussal jelöltük, a szürkével kiemelt cellák közepes ($r<-0,3$) vagy nagy ($r<-0,5$) effect size-ot jelölnek.

Table 1. Effect size and significance level of the Mann-Whitney tests (N=50; NDVI scores from each vegetation class). Numbers in boldface represent cases when classes were not significantly different ($p>0.05$). We marked cells with medium ($r<-0.3$) or large ($r<-0.5$) effect size with gray color.

Az MNF-transzformált sávok képosztályozása

A hiperspektrális felvételeknél a sávok autokorrelációja és a zajos csatornák miatt valamilyen információnyerési technológiát célszerű alkalmazni. A vegetáció-osztályozásnál a hiperspektrális felvételek alkalmazása során eredményesen alkalmazott robosztus módszer az MNF transzformáció (3a ábra). A hiperspektrális felvételeknél alkalmazott képosztályozásnál az MNF transzformált sávok alkalmazásával többnyire megbízhatóbb osztályozási eredmény érhető el, mint az eredeti csatornakészlet vagy más információnyerési technika (például PCA) alkalmazásával (BELLUCO et al. 2006, HESTIR et al. 2008).

Kilenc MNF transzformált sáv alkalmazása esetén 30 random pixellel mind a három képosztályozó eszköz nagy pontosságot nyújtott (SVM: 81,72%; RF: 79,14%; MLC: 80,78%) (2. táblázat). Alacsonyabb pixel számok esetében azonban már csak az SVM és az RF osztályozók adtak megfelelő pontosságú eredményt. Ez az MLC becsült kovariancia mátrix instabilitásának tudható be. 10 véletlenszerűen kiválasztott pixel esetében az SVM 79,57%-os, az RF 76,55%-os teljes pontosságot mutatott, míg az MLC osztályozó pontossága számottevően csökkent (52,76%) (2. táblázat). 30 tanító pixel alkalmazása esetén mindhárom módszer nagy pontossággal osztályozott a legtöbb nagy biomasszával jellemezhető osztály esetében mint az AGEL, AGAL, AGBE, CARE, GLYM, TYSA valamint a spektrálisan jelentősen eltérő osztályoknál, mint a KASZ, SZAN és ISZA (2. táblázat). A CAMA és PHPH osztályozásának alacsony hatékonyságát az osztályokra jellemző nagy arányú nyílt talajfelszín okozhatta. A CYPA, ARFE, GYOM és TYPA osztályoknál az eltérő osztályozási eljárások eltérő pontosságot eredményeztek. A rosszul osztályozott pixelek általában egy olyan vegetációs osztályba kerültek, amelyek a cél osztállyal azonos élőhely típusba tartoztak. Az osztályozás eredményeként kapott térképek jól tükrözik a szikes tájak mozaikosságát, alkalmasak a kis léptékű mintázatok megjelenítésére (3b ábra). Az élőhely típusok esetén az osztályozás pontossága az alkalmazott osztályozótól függetlenül magas volt (SVM 98,70%; RF 95,77%; MLC 95,77%).



3. ábra. A mintaterületet ábrázoló MNF transzformált kép hamis színes megjelenítésben (a) és az osztályonként 30 tréning pixel és SVM alkalmazásával készült vegetáció térkép (b).

Figure 3. False colour picture of the MNF transformed image (a) and the vegetation map of the study site using SVM classification with 30 random training samples per class (b).

Osztályok	PA (%) 10 tréning pixel			PA (%) 30 tréning pixel		
	SVM	RF	MLC	SVM	RF	MLC
CYPO	82,00	52,00	22,00	84,00	48,00	26,00
ACFE	56,00	70,00	70,00	50,00	52,00	50,00
ARFE	90,00	37,50	52,50	95,00	70,00	42,50
CAMA	54,00	52,00	48,00	54,00	56,00	62,00
PHPA	24,00	10,00	36,00	26,00	30,00	42,00
ARTE	56,67	83,33	60,00	63,33	93,33	80,00
AGEL	94,00	92,00	3,00	95,00	91,00	93,00
AGAL	95,00	93,00	86,00	99,00	96,00	100,00
AGBE	99,00	100,00	94,00	99,00	91,00	87,00
GYOM	57,50	65,00	30,00	57,50	62,50	80,00
CARE	89,00	97,00	81,00	97,00	94,00	100,00
GLYM	90,00	94,00	30,00	100,00	98,00	98,00
TYPA	24,00	16,00	0,00	8,00	4,00	28,00
TYSA	100,00	100,00	0,00	100,00	100,00	100,00
BOLB	44,00	40,00	26,00	42,00	46,00	66,00
SCHO	47,50	42,50	60,00	72,50	80,00	87,50
PHRA	70,00	58,00	44,00	68,00	64,00	80,00
KASZ	100,00	100,00	85,00	100,00	100,00	100,00
SZAN	100,00	92,00	100,00	100,00	100,00	90,00
ISZA	100,00	100,00	0,00	100,00	100,00	100,00
OA(%)	79,57	76,55	52,76	81,72	79,14	80,78

2. táblázat. Osztályozás pontossága (PA; *Production Accuracy*) osztályonként és a teljes pontosság (OA; *Overall Accuracy*) a három alkalmazott osztályozó esetében 9 MNF transzformált sáv és 10 és 30 tréning pixel felhasználása esetén.

Table 2. Production accuracy (PA) of the classes and Overall Accuracy (OA) with respect to three classifiers using 9 MNF-transformed bands and random training samples (10 and 30 pixels).

A tesztelt osztályozók alkalmazhatósága komplex tájakban

Azokban az esetekben, amikor nincs szükség egy társulástani pontosságú térkép előállítására érdemes az osztályok aggregációja által létrehozott tágabb kategóriákat (esetünkben élőhely típusok) alkalmazni, mivel ez esetben bár az osztályozás kisebb információtartalmú térképek előállítását teszi lehetővé, de az osztályozás megbízhatósága jelentősen nő.

Optimális esetben a távérzékelési adatok osztályozásához nagy mennyiségű földi tanító és validáló adatra van szükség. Sok esetben azonban a megfelelő mennyiségű adat gyűjtése nehézségekbe ütközhet. Ennek az okai az alábbiak lehetnek: (1) komplex tájakban az adatgyűjtésre rendelkezésre álló anyagi forrás és idő limitált a korlátozott kapacitás miatt nem lehet minden osztályból elegendő mintát gyűjteni; (2) egyes vegetációs osztályok csak kis foltokban vannak jelen a kutatási területen; (3) egyes foltok terepen nehezen megközelíthető helyen vannak. Fentiek miatt különösen fontos, hogy ilyen esetekben azt az osztályozót válasszuk, amely a rendelkezésre álló anyagból a legnagyobb pontosságú osztályozást tudja produkálni. Eredményeink alapján elmondható, hogy komplex tájakban a vegetáció osztályozásra az SVM módszer a legalkalmasabb, mivel a legpontosabb osztályozást e módszerrel tudtuk elérni. Mindemellett az alkalmazott *machine learning* algoritmusok (SVM és RF) egyaránt jó osztályozási eredményt adtak abban az esetben is ha a tréning adatok korlátozott számban voltak elérhetők. A hiperspektrális felvételek osztályozására azok a robosztus módszerek a legalkalmasabbak, amelyek nem érzékenyek a tanító terület méretére

így jól alkalmazhatóak olyan területeken is, ahol egyes osztályok esetében korlátozott számban állnak rendelkezésre referenciaterületek.

Köszönetnyilvánítás

Jelen kutatás a “TÁMOP-4.2.2.D-15/1/ KONV-2015-0010” projekt keretében zajlott. Deák Balázst az OTKA PD 115627 pályázat támogatta. Köszönjük Belényesi Mártának, Centeri Csabának, és Molnár Dánielnek a bírálattal során nyújtott hasznos tanácsait és észrevételeit.

Irodalom

- ADAM, E., MUTANGA, O., RUGEGE, D. 2010: Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: A review. *Wetlands Ecology Management* 18: 281–296.
- ALEXANDER, C., DEÁK, B., KANIA, A., MÜCKE, W., HEILMEIER, H. 2015: Classification of vegetation in an open landscape using full-waveform airborne laser scanner data. *International Journal of Applied Earth Observations and Geoinformation* 41: 76–87.
- ALEXANDER, C., DEÁK, B., HEILMEIER, H. 2016: Micro-topography driven vegetation patterns in open mosaic landscapes. *Ecological Indicators* 60: 906–920.
- AMBRUS, A., BURAI, P., LÉNÁRT, CS., ENYEDI, P., KOVÁCS, Z. 2015: Estimating biomass of winter wheat using narrowband vegetation indices for precision agriculture. *Journal of Central European Green Innovation* 3: 13–22.
- BELLUCO, E., CAMUFFO, M., FERRARI, S., MODENESE, L., SILVESTRI, S., MARANI, A., MARANI, M. 2006: Mapping salt-marsh vegetation by multispectral and hyperspectral remote sensing. *Remote Sensing of Environment* 105: 54–67.
- BORHIDI A., KEVEY B., LENDVAI G. 2012: *Plant Communities of Hungary*. Akadémiai Kiadó, Budapest.
- BORRE, J.V., PAELINCKX, D., MÜCHER, C.A., KOOISTRA, L., HAEST, B., BLUST, G.D., SCHMIDT, A.M. 2011: Integrating remote sensing in Natura 2000 habitat monitoring: Prospects on the way forward. *Journal for Nature Conservation* 19: 116–125.
- BURAI, P., DEÁK, B., VALKÓ, O., TOMOR, T. 2015: Classification of herbaceous vegetation using airborne hyperspectral imagery. *Remote Sensing* 7: 2046–2066.
- DEÁK B., TÓTHMÉRÉSZ B. 2006: Kaszálás hatása a növényzetre a Nyírölapos (Hortobágy) három növénytársulásában. In: Molnár E. (szerk.) *Kutatás, oktatás értékettermés. A 80 éves Précsényi István köszöntése*. MTA Ökológiai és Botanikai Kutatóintézet, Vácrátót, pp. 169–180.
- DEÁK, B., VALKÓ, O., ALEXANDER, C., MÜCKE, W., KANIA, A., TAMÁS, J., HEILMEIER, H. 2014a: Fine-scale vertical position as an indicator of vegetation in alkali grasslands - case study based on remotely sensed data. *Flora* 209: 693–697.
- DEÁK, B., VALKÓ, O., TÖRÖK, P., TÓTHMÉRÉSZ, B. 2014b: Solonetz meadow vegetation (*Beckmannion eruciformis*) in East-Hungary – an alliance driven by moisture and salinity. *Tuexenia* 34:187–203.
- DEÁK, B., VALKÓ, O., TÖRÖK, P., KELEMEN, A., MIGLÉCZ, T., SZABÓ, SZ., SZABÓ, G., TÓTHMÉRÉSZ, B. 2015a: Micro-topographic heterogeneity increases plant diversity in old stages of restored grasslands. *Basic and Applied Ecology* 16: 291–299.
- DEÁK, B., VALKÓ, O., TÖRÖK, P., KELEMEN, A., TÓTH, K., MIGLÉCZ, T., TÓTHMÉRÉSZ, B. 2015b: Reed cut, habitat diversity and productivity in wetlands. *Ecological Complexity* 22: 121–125.
- HARRIS, A., CHARNOCK, R., LUCAS, R.M. 2015: Hyperspectral remote sensing of peatland floristic gradients. *Remote Sensing of Environment* 162: 99–111.
- HESTIR, E., KHANNA, S., ANDREW, M.E., SANTOS, M.J., VIERS, J.H., GREENBERG, J.A., RAJAPAKSE, S.S., USTIN, S.L. 2008: Identification of invasive vegetation using hyperspectral remote sensing in the California delta ecosystem. *Remote Sensing of Environment* 112: 4034–4047.
- HUANG, C., ASNER, G.P. 2009: Applications of remote sensing to alien invasive plant studies. *Sensors* 9: 4869–4889.
- HURCOM, S.J.; HARRISON, A. R. 1998: The NDVI and spectral decomposition for semi-arid vegetation abundance estimation. *International Journal of Remote Sensing* 19: 3109–3126.
- KELEMEN, A., TÖRÖK, P., VALKÓ, O., MIGLÉCZ, T., TÓTHMÉRÉSZ, B. 2013: Mechanisms shaping plant biomass and species richness: plant strategies and litter effect in alkali and loess grasslands. *Journal of Vegetation Science* 24: 1195–1203.
- KELEMEN, A., TÖRÖK, P., VALKÓ, O., DEÁK, B., TÓTH, K., TÓTHMÉRÉSZ, B. 2015: Both facilitation and limiting similarity shape the species coexistence in dry alkali grasslands. *Ecological Complexity* 21: 34–38.
- LAWRENCE, R., WOOD, S., SHELEY, R. 2006: Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (randomForest). *Remote Sensing of Environment* 100: 356–362.

- LUKÁCS, B.A., TÖRÖK, P., KELEMEN, A., VÁRBÍRÓ, G., RADÓCZ, SZ., MIGLÉCZ, T., TÓTHMÉRÉSZ, B., VALKÓ, O. 2015: Rainfall fluctuations and vegetation patterns in alkali grasslands – Self-organizing maps in vegetation analysis. *Tuexenia* 35: 381–397.
- MIRIK, M., ANSLEY, R.J., STEDDOM, K., JONES, D.C., RUSH, C.M., MICHELS, G.J. ELLIOTT, N.C. 2013: Remote distinction of a noxious weed (musk thistle: *Carduus nutans*) using airborne hyperspectral imagery and the Support Vector Machine Classifier. *Remote Sensing* 5: 612–630.
- MOLNÁR, Z.; BÖLÖNI, J., BIRÓ, M., HORVÁTH, F. 2008: Distribution of the Hungarian (semi-)natural habitats I. Marshes and grasslands. *Acta Botanica Hungarica* 50: 59–105.
- MÜCKE, W., DEÁK, B., SCHROIFF, A., HOLLAUS, M., PFEIFER, N. 2013: Estimation of dead wood using small footprint airborne laser scanning data. *Canadian Journal of Remote Sensing* 39: 32–40.
- PARUELO, J. M., EPSTEIN, H. E., LAUENROTH, W. K., BURKE, I. C. 1997: ANPP estimates from NDVI for the central grassland region of the United States. *Ecology* 78: 953–958.
- PETTORELLI, N., VIK, J. O., MYSTERUD, A., GAILLARD, J. M., TUCKER, C. J., STENSETH, N. C. 2005: Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution* 20: 503–510.
- PETTORELLI, N. 2013: *The Normalised Difference Vegetation Index*; Oxford University Press, Oxford.
- RABE, A., JAKIMOW, B., HELD, M., VAN DER LINDEN, S., HOSTERT, P. 2014: EnMAP-Box, Version 2.0. (<http://www.enmap.org>).
- SOKAL, R.R., ROHLF, F.J. 1987: *Introduction to Biostatistics*. W.H. Freeman and Company, 2nd edition, New York. p. 368.
- SZABÓ, SZ., SZILASSI, P., CSORBA, P. 2012: Tools for landscape ecological planning– Scale, and aggregation sensitivity of the contagion type landscape metric indices. *Carpathian Journal of Earth and Environmental Sciences* 7: 127–136.
- THENKABAIL, P.S. 2011: *Hyperspectral Remote Sensing of Vegetation*. Taylor & Francis, New York. p. 782.
- TÓTH, K., HÜSE, B. 2014: Soil seed banks in loess grasslands and their role in grassland recovery. *Applied Ecology and Environmental Research* 12: 537–547.
- TÓTH, T., KERTÉSZ, M. 1996: Application of soil–vegetation correlation to optimal resolution mapping of solonchak rangeland. *Arid Soil Research and Rehabilitation* 10: 1–12.
- VALKÓ, O., TÓTHMÉRÉSZ, B., KELEMEN, A., SIMON, E., MIGLÉCZ, T., LUKÁCS, B., TÖRÖK, P. 2014: Environmental factors driving vegetation and seed bank diversity in alkali grasslands. *Agriculture, Ecosystems & Environment* 182: 80–87.
- ZLINSZKY, A., DEÁK, B., KANIA, A., SCHROIFF, A., PFEIFER, N. 2015: Mapping Natura 2000 habitat conservation status in a pannonic salt steppe with airborne laser scanning. *Remote Sensing* 7: 2991–3019.
- ZLINSZKY, A., SCHROIFF, A., KANIA, A., DEÁK, B., MÜCKE, W., VÁRI, Á., SZÉKELY, B., PFEIFER, N. 2014: Categorizing grassland vegetation with full-waveform airborne laser scanning: a feasibility study for detecting Natura 2000 habitat types. *Remote Sensing* 6: 8056–8087.

VEGETATION MAPPING IN AN ALKALI LANDSCAPE - APPLICATION OF AIRBORNE HYPERSPECTRAL DATA

P. BURAI¹, CS. LÉNÁRT¹, O. VALKÓ², L. BEKŐ¹, ZS. SZABÓ³, B. DEÁK²

¹ Karoly Robert College, Research Institute of Remote Sensing and Rural Development, Mátrai út 36, H-3200 Gyöngyös, email: pburai@karolyrobert.hu, lenart.dr@gmail.com, lbeko@karolyrobert.hu

² MTA-DE Biodiversity and Ecosystem Services Research Group
Egyetem tér 1, Debrecen H-4032, Hungary email: debalazs@gmail.com, valkoorsi@gmail.com

³ University of Debrecen, Department of Physical Geography and Geoinformatics
Egyetem tér 1. Debrecen H-4032, email: zs.szabozsuzsa@gmail.com

Keywords: vegetation mapping, Maximum Likelihood Classifier (MLC), Random Forest (RF), Support Vector Machine (SVM), alkali grassland, alkali meadow, alkali marsh

Summary: We mapped the vegetation of an alkali landscape using airborne hyperspectral data. The aim of our study was to test the applicability of hyperspectral data in mapping of these complex habitats. We tested the performance of three frequently applied classifiers (Maximum Likelihood Classifier – MLC, Random Forest – RF and Support Vector Machine – SVM) using 10 and 30 training pixels and MNF transformed bands. For data collection we used an AISA EAGLE II sensor, which produced 1 m ground pixel size. Based on the coenological categories, land cover types and the experiences of the preliminary field survey we assigned the training polygons to 20 classes. Classes were aggregated to four main habitat types: steppes, open alkali swards, alkali

meadows and alkali and non-alkali marshes. We found that the SVM and the RF classifiers provided a high overall accuracy for most of the classes independently from the number of training pixels. Even though the MLC classifier provided a high overall accuracy when using 30 training pixels, its efficiency was low when using 10 training pixels. Overall accuracies increased considerably in case of all classifiers when using aggregated habitat types. Based on our results, in complex, open habitats the SVM is the most effective classifier, it provided the highest accuracy. Furthermore it was the less sensitive for the low number of training pixels, thus can be effective in those cases when the number of training pixels is low for some classes.