

# Normalizált indexek alkalmazhatósága automatikus területi klasszifikációhoz Magyarországon Baranya megye példáján

Farkas Gábor

doktorandusz, Pécsi Tudományegyetem, Földtudományok Doktori Iskola, E-mail: randal73@gamma.ttk.pte.hu

## Absztrakt

*Az első multispektrális adatok megjelenése óta foglalkoztatja a kutatókat az ilyen adatok kiértékelése különböző módszerekkel. Igazán elterjedt módszer az automatikus, vagy felügyelt klasszifikáció, mely során különböző spektrális tartományokban készült képekből dimenziócsökkentő eljárásokkal osztályozott állományok készülnek. Egyik fontos célja a klasszifikációs eljárásoknak a felszínborítás térképezése, monitorozása. A tanulmány erre a célra mutat be részletesen egy teljesen automatizálható, költséghatékony megoldást. Bár a kutatáshoz használt, népszerűbbek közé tartozó négy normalizált index (NDVI, NDWI, NDBaI, NDBI) alkalmazhatósága Magyarország területén megkérdőjelezhető, a spektrálisan leginkább eltérő felszínborítási formákat (vízborítás, sűrű növényzet, kopár terület) az ezekkel készült klasszifikáció jól kirajzolja.*

**Kulcsszavak** Baranya, képfeldolgozás, klasszifikáció, klaszteranalízis, maximum likelihood classification, normalizált indexek

**DOI: 10.17799/2015.1.13**

## 1. Bevezetés

A távérzékelés tudományának manapság csupán apró szeglete a multispektrális szenzoroktól származó képek GIS rendszerek segítségével történő elemzése. Ezek a képek túlnyomó részben műholdakról származnak. Mika et al. (2011) szerint már az 1950-es évek óta foglalkoztatják a kutatókat a képi adatok feldolgozásában rejlő lehetőségek, míg az első multispektrális szenzor prototípusa 1962-ben született meg (Lein 2003). Az elmúlt 50 év alatt jelentős fejlődésen mentek keresztül mind a szenzorok, mind az elemzési eljárások. Mára fejlett algoritmusok, mint az MLC (maximum likelihood classification), vagy a MAP (maximum a posteriori) állnak a kutatók rendelkezésére, hogy ezeket a műholdképeket akár automatikusan, akár felügyelten kiértékeljék. Bár a távérzékelő műholdak egy részének – mint például a 4m-es felbontású IKONOS (Garrison et al. 2008) – adatai kereskedelmi forgalomban vannak, ingyenes minőségi adatokhoz sem bonyolult hozzájutni. Az Egyesült Államok adatpolitikájának köszönhetően például ingyenesen hozzáférhetünk az egyik legnagyobb műholdkép adatbázishoz, a Landsat archívumhoz (Wulder et al. 2012).

Az USGS (2015) közlése alapján az első Landsat műholdat, a Landsat 1-et 1972-ben állították pályára. Ez a műhold mindössze négy spektrális csatornán rögzített.

Jelenleg a Landsat 7 ETM+ (Enhanced Thematic Mapper +), és a Landsat 8 OLI (Operational Land Manager) szolgáltat folyamatosan frissülő képeket nyolc, illetve kilenc spektrális tartományban. Az 1972 óta felvett adatok napjainkban ingyenesen elérhetőek, általuk a földfelszínen végbemenő változások széles időintervallumon elemezhetőek. Ezeknek az elemzéseknek egyik célja a felszínborítás vizsgálata. Az ilyen típusú kutatások tárgya lehet egy egyszerű terület-, vagy földhasználati térkép előállítás, vagy akár egy specifikus faj terjedésének, térbeli eloszlásának vizsgálata.

A nyers műholdképek adattárolási megfontolásokból kvantált formában tartalmazzák az érzékelt információt. Minden műholdkép és szenzor esetében visszaszámolhatóak a rögzített értékek. A NASA (2011) által kiadott Landsat 7 kézikönyv szerint a kvantált értékek radiancia, és reflektancia értékekké számolhatóak vissza, melyek a szenzort érő sugárzás mennyiségét, valamint a visszavert energia arányát reprezentálják. Amíg általában a reflektancia értékek szolgálnak egy távérzékelési vizsgálat alapjául, más derivatív termékek is alkalmazhatóak hasonló célra. Tipikusan ilyen adatok a normalizált indexek. Ahogy Eredics (2007) is összefoglalja, ezek dimenzió nélküli mérőszámok. Az NDVI a növényzet klorofill tartalmával áll összefüggésben. Gyakori mérőszám még a Gao (1996) által bevezetett NDWI (normalizált ned-

vességindex), mely a növényzet nedvességtartalmával korrelál. Kevésbé ismert, ámbar igen hasznos normalizált index az NDBI, azaz a normalizált beépítettség index (Chen et al. 2006), valamint az NDBaI, vagyis a normalizált kopárság index (Zhao et al. 2005). Amíg az NDBI a beépített területekre érzékeny, az NDBaI a vegetációmentes, kopár területeket emeli ki.

Mivel ezek az indexek azon eltérő karakterisztikáit emelik ki a felszínnek, melyek alkalmasak lehetnek egy általános felszínborítottságot ábrázoló állomány elkészítéséhez akár teljesen automatikus eszközökkel is, ez a tanulmány hipotézise. A hipotézist erősíti, hogy Chen et al. (2006) már sikeresen alkalmazott egy hasonló módszert Kína területén belül, ahol az indexek jó elszeparálhatóságából adódóan határértékek segítségével sikerült hét felszínborítási típust (kopár terület, víz, halastó, félig kopár terület, beépített terület, erdő, termőföld) nagy pontossággal leválogatni.

A tanulmány célja egy teljesen automatizálható módszer pontosságának a vizsgálata, mely spektrális indexeket használ az automatikus osztályozáshoz. Így, amennyiben bizonyítást nyer a módszer alkalmassága, azt költséghatékony módon lehet alkalmazni, mivel az emberi munkaerő költsége csak egyszéri.

## 2. Módszerek

### 2.1. Kiinduló adatok

Elsőként pontos referenciaadatokra volt szükség, mely a pontosságvizsgálatot megalapozza. Kritériuma volt a referenciaként szolgáló állománynak, hogy ingyenes legyen, mivel a tanulmánynak nem volt költségvetése. Így a választás a FÖMI által kiadott CLC50 (Corine Land Cover) állományra esett, amely Magyarország 2000-es felszínhasznosítási viszonyait ábrázolja nagy méretarányban (1:50 000). Ahogy Büttner et al. (2009) összefoglalja az adatokhoz kiadott jelentésben, a CLC50 felbontása a kötelező CLC100-as adatoknak vonalas elemekre a duplája, míg a területi felbontása több mint ötszöröse. A helyzeti pontosságot 20m alattinak adja meg, a tematikus megbízhatóságot pedig 90% felettinek. Ezen technikai paraméterek alapján a CLC50 vektoros állomány megbízható referenciaként szolgálhat a kutatáshoz.

Az elemzés második kiinduló állománya az osztályozandó műholdkép. Erre a célra az ingyenesen elérhető Landsat 7 állományra esett a választás. A CLC50 állomány a 2000-es állapotot örökíti meg, továbbá Chen et al. (2006) is ETM+ szenzorból származó adatokkal végzett sikeres osztályozást, így megfelelőnek tűntek a 2000-es Landsat 7 felvételek. Megfigyelhető a CLC50 állományban Baranya megyén belül a kopár (növényzetrel nem borított) területek majdnem teljes hiánya, viszont ez egy meghatározó kategória az elemzésben. Ennek a problémának orvosolására a tanulmány októberi felvételekre támaszkodik (2000. október 14.), amikor már

az utolsó őszi aratások is javarészt megtörténtek. Így a CLC50 helyes klasszifikációjával a referencia is helyes lesz, valamint az osztályozó algoritmus is elég mintához jut a helyes klasszifikáció elvégzéséhez. Természetesen azokon a területeken, ahol a betakarítás még nem történt meg az előbb említett időpontban, a pontossági elemzés hibás lesz, azonban a mintaterület nagysága révén ez a hibaszázalék elhanyagolható.

### 2.2. A CLC50 állomány újraosztályozása

Kezdő lépésként a referenciaadatot, azaz a CLC50 vektoros állományt az októberi viszonyoknak megfelelően kellett újraosztályozni. Fontos megemlíteni, hogy a Corine Land Cover projekt célja egy konzisztens európai felszínborítási téradatbázis létrehozása melyben terület-használati elemek is fontos szerepet kapnak (Feranec et al. 2007), míg a kutatás célja csak a felszínborítás automatikus osztályozása. A két termék eltér, méghozzá idő dimenzióban. A területhasználat független a szezonális változásoktól, míg a felszínborítás függ a felvétel időpontjától. A két termék közös nevezőre hozásának kézenfekvő módszere a területhasználati állomány újraosztályozása az elméleti szezonális viszonyoknak megfelelően.

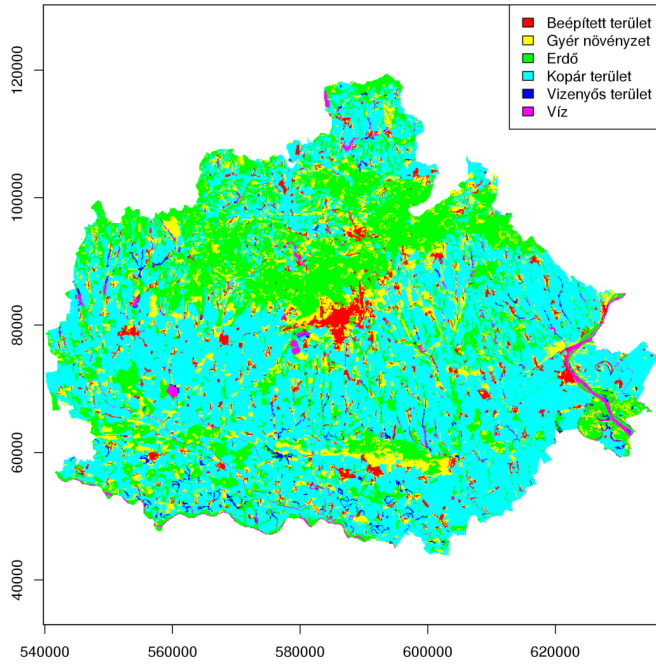
A FÖMI (2009) által kiadott CLC50 nomenklatúrából nem csupán az osztályelemek olvashatók ki, hanem azok rövid leírása és az osztályok kritériumrendszere is. Az újraosztályozást így az egyes osztályok és alosztályok értelmezésével el lehet végezni (1. táblázat). Minden csoport és alcsoport a legmeghatározóbb területhasználati forma alapján került besorolásra. Azok a mezőgazdasági területek szakadtak ketté, ahol a szántóföldek a kopár területekhez lettek sorolva, míg a szőlők, és a természetes növényzettel borított területek a gyér növényzethez. Az erdők és a vizenyős területek nem szezonális felhasználási formák, így újraosztályozásuk egyértelmű volt, míg a vízzel borított területekhez a természetes vizek mellett besorolásra kerültek a folyékony hulladéktároló telepek.

Osztály	Kat.	CLC50 kód
Beépített terület	1	1100 – 1300, 1420 – 2000, 12110 – 13000, 1331, 2113
Gyér növényzet	2	1410 – 1420, 2200 – 2430, 2432, 2433, 2435, 3240 – 3300, 22110 – 25000
Erdő	3	3100 – 3240
Kopár terület	4	1310 – 1321, 2100 – 2200, 3300 – 4000, 2431
Vizenyős terület	5	4000 – 5000
Víz	6	5000 – 10000, 50000 – 60000, 1322

#### 1. táblázat. CLC50 októberi újraosztályozása

A hat vizsgálandó osztály kialakítása, és a vektoros állomány újraosztályozása után az utolsó lépés raszterre alakítani a poligonokat. Mivel a Landsat 7 felvételek tér-

beli felbontása 30 m, az átalakított referencia állomány (1. ábra) felbontása is erre az értékre esett.



1. ábra. CLC50 állomány újraosztályozva, raszterre konvertálva

### 2.3. A spektrális indexek létrehozása

Az indexek előállításához először a Landsat műholdképek átalakítására volt szükség. Az elemzést megkönnyítette, hogy a felvételek felhőborítottsága 0%. A műholdképek digitális számokból állnak, azaz az információt kvantált formában tartalmazzák, egy bájtra transzformálva. Ebből a radiancia értékeket elő lehet állítani GRASS 7 segítségével. A művelet az i.landsat.toar modullal végezhető el, mely a GRASS Development Team (2016) által kiadott kézikönyv szerint először radiancia értéket számol (1. egyenlet), majd azokat átszámolja reflektancia értékekké (2. egyenlet). A modulnak szüksége van az adott felvétel összes sávjára és a felvétel metaadataira, mely a felvételekkel egy archívumba van csomagolva.

$$L_{\lambda} = Gain \times QCAL + Bias$$

$$\text{ahol } Gain = \frac{LMAX_{\lambda} - LMIN_{\lambda}}{QCALMAX - QCALMIN}$$

$$\text{és } Bias = LMIN_{\lambda} - Gain \times QCALMIN \quad (1)$$

A NASA (2011) Landsat 7 kézikönyvéből kiolvasható, hogy az  $LMAX_{\lambda}$  és az  $LMIN_{\lambda}$  értékek sávfüggő kalibrációs konstansok, a  $QCALMAX$  255, azaz a kvantálás felső értéke, a  $QCALMIN$  a kvantálás alsó értéke, mely az előfeldolgozást végző szoftvertől függően 0 vagy 1-es értéket vesz fel, a  $QCAL$  pedig az adott raszter kvantált értéke (digitális száma). Végül az  $L_{\lambda}$  a radiancia érték  $W/m^2 \times sr \times \mu m$ -ben.

$$\rho_p = \frac{L_{\lambda}}{ESUN_{\lambda} \times \sin \alpha_s / (\pi \times d^2)} \quad (2)$$

A GRASS kézikönyve szerint az  $ESUN_{\lambda}$  a Napból érkező sugárzás közepes értéke, az  $\alpha_s$  a Nap magassági szöge, míg a  $d$  érték a közepes Naptávolság csillagászati egységben kifejezve a felvétel időpontjában. A  $\rho_p$  egy mértékegység nélküli planetáris reflektancia érték, mely a visszaverődő sugárzás arányát mutatja meg a beérkező sugárzashoz képest. Ez a képlet eltér a Landsat 7 kézikönyvben olvashatótól (3. egyenlet), azonban mivel  $\theta_s$ , azaz a Nap zenitszöge komplementere a Nap magassági szögének, könnyedén belátható, hogy  $\sin \alpha_s = \cos \theta_s$ .

$$\rho_p = \frac{\pi \times L_{\lambda} \times d^2}{ESUN_{\lambda} \times \cos \theta_s} \quad (3)$$

Miután a GRASS kiszámolta a reflektancia értékeket, a négy különböző normalizált index kiszámítása következett. Chen et al. (2006) alapján az NDVI (4. egyenlet) és az NDWI (5. egyenlet) mutatók reflektancia értékből számolandóak, míg az NDBI (6. egyenlet) és az NDBaI (7. egyenlet) kvantált értékekből, azaz digitális számokból.

$$NDVI = \frac{\rho_{B4} - \rho_{B3}}{\rho_{B4} + \rho_{B3}} \quad (4)$$

A  $\rho_{B3}$  a hármassáv, azaz a vörös spektrális tartomány reflektancia értékét jelöli, míg a  $\rho_{B4}$  a négyessáv, azaz a közeli infravörös tartomány reflektanciáját. Az NDVI mutató főként a növényzet és a felszíni vizek elkülönítésére alkalmas.

$$NDWI = \frac{\rho_{B4} - \rho_{B5}}{\rho_{B4} + \rho_{B5}} \quad (5)$$

A  $\rho_{B5}$  a közepes infravörös tartomány, azaz az ötös sáv reflektancia értékeit jelöli. Gao (1996) alapján ez a mérőszám a vegetáció nedvességtartalmával korrelál, így alkalmas lehet a sűrű növényzet, a gyér növényzet, és a mocsári növényzet elkülönítésére.

$$NDBI = \frac{DN_{B5} - DN_{B4}}{DN_{B5} + DN_{B4}} \quad (6)$$

A  $DN_{B4}$  és a  $DN_{B5}$  a négyes és ötös sávok kvantált értékeit jelölik. Chen et al. (2006) szerint ez az index a beépített területekre érzékeny.

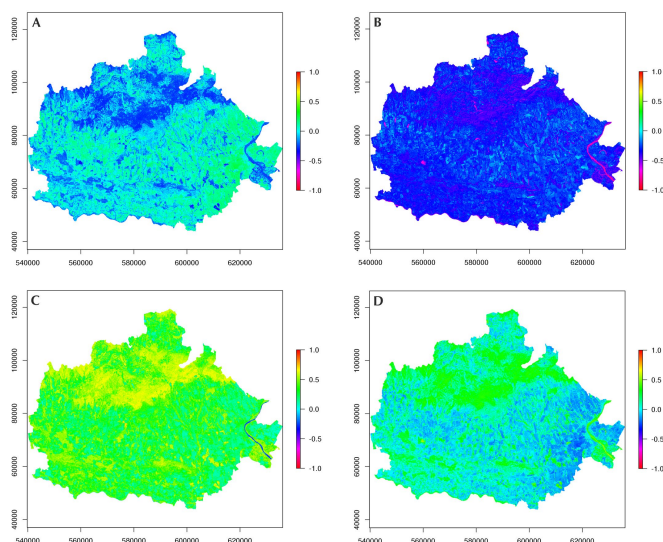
$$NDBaI = \frac{DN_{B5} - DN_{B6}}{DN_{B5} + DN_{B6}} \quad (7)$$

A  $DN_{B6}$  a hatos sáv, azaz a termális infravörös tartomány kvantált értékeit jelöli. Zhao et al. (2005) vezette be ezt az indexet a kopár területek automatikus leválogatására, és azok további alosztályokba való besorolására.

Az elkészült indexeken (2. ábra) jól elkülönülnek a legmeghatározóbb felszínborítási típusok, mint a Duna vonala, vagy a Mecsek erdővel borított területe.

Az alaptérképek klaszifikációjának van felügyelt és automatikus módja. A felügyelt módszer során a felhasználó mintaterületeket jelöl ki, melyek az adott terület-használati kategóriát reprezentálják. Ez a lépés is auto-





2. ábra. Spektrális indexek A: NDBI, B: NDBaI, C: NDVI, D: NDWI

matizálható klaszteranalízis segítségével. Erre a GRASS i.cluster modulja szolgál, mely a forráskód alapján K-közép módszerrel dolgozik. A K-közép módszer egy iteratív klaszterezési eljárás, mely Ding et al. (2004) szerint a lokális minimum felé konvergál (8. egyenlet). A lokális minimum minden egyes klaszternél a klaszter közepe és a hozzá tartozó pontok közötti távolságnégyzetek összege (négyzetes hiba).

$$J_K = \sum_{k=1}^K \sum_{i \in C_k} (x_i - m_k)^2 \quad (8)$$

A felügyelt klasszifikáció első lépéséhez hasonlóan, a klaszterezési eljárás is mintavételezésen alapszik. A kutatáshoz a mintaterületen minden 9 km<sup>2</sup>-re egy minta jutott, ezért is volt fontos, hogy minden elkülönítendő típushoz elegendő referenciaterület tartozzon. A K-közép módszer kötelező paramétere még az osztályok száma, mely az 1. táblázatnak megfelelően 6 volt.

A következő lépés az automatikus osztályozásban a mintaterület rasztereinek osztályozása az indexek alapján. A klaszteranalízis végeredménye egy spektrális lenyomat minden csoportra, mely tartalmazza az indexek csoportspecifikus átlagait és kovariancia mátrixait. A spektrális lenyomatok alapján a GRASS i.maxlik modulja képes minden rasztert megfelelő osztályba sorolni. Ez a modul az MLC módszert használja, mely Ahmad et al. (2012) alapján a Bayes statisztika módszereivel vizsgálja minden raszterre azt a valószínűséget, hogy egy bizonyos osztályba tartozik (9. egyenlet). Kiválasztja azt az osztályt, ahová az adott raszter legnagyobb valószínűséggel sorolható, majd besorolja. Opcionális kimenetként készít egy raszteres állományt, melyben az értékek a helyes osztályba sorolás valószínűségét reprezentálják. Ezt a valószínűséget az algoritmus  $\chi^2$  próbával állapítja meg.

$$\forall i. P(M_i|\omega) > P(M_j|\omega) \rightarrow x \in M_i \wedge j = i$$

$$\text{ahol } i \in \{2 \dots |M|\}, j = 1$$

$$P(M_i|\omega) = \frac{P(\omega|M_i) \times P(M_i)}{P(\omega)}$$

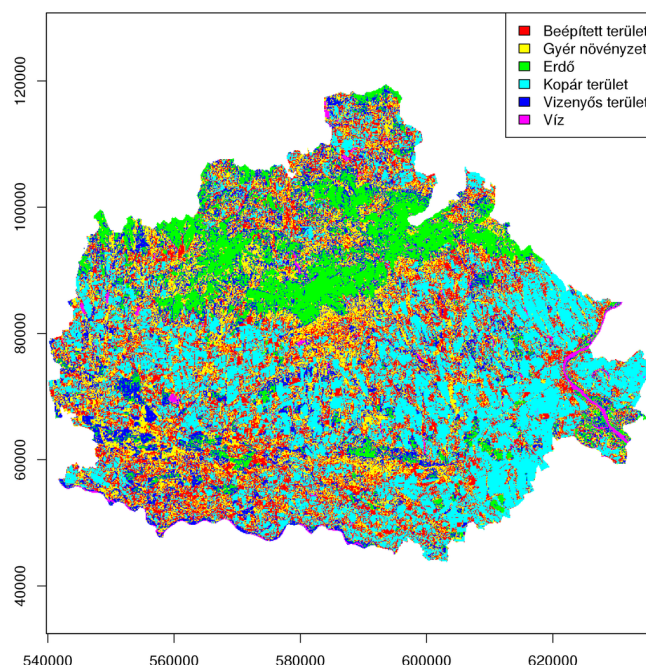
$$\text{ahol } P(\omega) = \sum_{i=1}^{|M|} P(\omega|M_i) \times P(M_i) \quad (9)$$

Az M az osztályok halmazát jelöli, az x egy adott rasztert, míg az  $\omega$  az adott raszter jellemvektorát a különböző indexeken felvett értékei alapján.

## 3. Eredmények

### 3.1. Pontosságvizsgálat

Az elkészült klasszifikáció az összehasonlíthatóság érdekében újraosztályozásra szorult. Az eredmény (3. ábra) pontossága egy Kappa vizsgálat (Cohen 1960) során számolt százalékos, és  $\kappa$  értékekkel jellemezhető (GRASS-ban r.kappa modul). Congalton (1991) szerint a kiértékelt raszter valódi pontosságát csak közelíteni lehet, a referenciákat tartalmazó minta nagyságától függően alulról, vagy felülről. Különlegessége az ebben a kutatásban szereplő vizsgálatnak, hogy a valódi pontosságot felülről közelíti meg, így referenciaként az egész vizsgálati területre generált és újraosztályozott CLC50 állományt használja.



3. ábra. Az automatikus klasszifikáció eredménye

Bár már a térképen is látszik, hogy az eredmény nem csupán zajos, de a kategóriák többségében pontatlan. Ezt a Kappa Indexel történt pontosságvizsgálat eredménye

(2. táblázat) is alátámasztja. A teljes területnek csupán 50,62%-át sikerült helyes osztályba sorolni.

Osztály	Com.	Om.	$\kappa$
Beépített terület	91,79%	60,95%	0,04
Gyér növényzet	70,06%	49%	0,21
Erdő	8,5%	55,16%	0,88
Kopár terület	2,82%	45,35%	0,94
Vizenyős terület	98,73%	80,17%	0
Víz	21,75%	39,36%	0,78
<b>Összesen</b>			<b>0,35</b>

## 2. táblázat. A pontosságvizsgálat eredménye.

A Com. oszlop a kategóriák Commission error százalékos értékét tartalmazza, mely a referenciaosztályon kívül eső extra raszterek arányát jelöli. Az Om. oszlop az Omission error szintén százalékos értékét mutatja, mely a referenciaosztályból hiányzó raszterek arányát adja meg (Congalton 1991). Ez a két fajta hiba nagyszerű kiegészítő információkat ad az egyes osztályok hibáinak természetéről. A  $\kappa$  érték a teljes pontosságot fejezi ki, mely 0-tól 1-ig terjedhet. Landis és Koch (1977) szerint 0,61-es értéktől megfelelőnek, míg 0,81-es értéktől majdnem tökéletesnek tekinthető a klasszifikáció.

Bár a kopár területek, az erdők, és a vizek magas  $\kappa$  mutatóval rendelkeznek, a hiányzó raszterek aránya igen magas. A jelenség adódhat a CLC50 állomány generalizált természetéből (Büttner et al. (2009) alapján maximum 10%-ban), azonban jelen esetben inkább valószínűsíthető az indexek alkalmatlanságából adódó pontatlanság, de nem zárható ki a CLC50 hibás újraosztályozásából származó pontatlanság sem.

## 3.2. A hiba természetének vizsgálata

### 3.2.1. Újraosztályozásból származó hiba

Az indexek alkalmatlanságának bizonyítására a tanulmány a meghatározó lépéseket vizsgálta, ezek közül is azokat, melyek egyszerűen meghatározhatóak. Ilyen az újraosztályozásból származó hiba, valamint a hibás

klasszterezés. Az újraosztályozásból származó hiba kizárása érdekében érdemes a hibás rasztereket (3. táblázat) jobban szemügyre venni.


A hibás raszterek vizsgálatához a referenciaállomány és a végeredmény közötti különbségből indultam ki. A különbségeket a hiba típusa szerint csoportosítottam, ahol az első szám a helyes csoport azonosítószámát (1. táblázat) mutatja, a második pedig azt az osztályt, amibe a klasszterezés besorolta. Ezeket a csoportokat az eredeti CLC50 állomány alapján alosztályokra bontottam, és megvizsgáltam az alosztályokon belüli hibás raszterek arányát az összes hibás raszterhez (hibaarány), az alcsoportba tartozó összes raszterhez (osztályarány), és a teljes mintaterülethez (teljes arány) képest.

Az eredményből kiolvasható, hogy a legnagyobb hibákat okozó alosztályok osztályaránya az újraosztályozásban nem utal hibára. A klasszifikációban a legnagyobb hibát a 2111-es alosztály okozta, melyek a FÖMI (2009) által kiadott nomenklatúra alapján nagytáblás szántóföldeket jelöl. Az alosztály 35,25%-át rossz osztályba sorolta, tehát az újraosztályozás megváltoztatása rontana a klasszifikáció pontosságán. A hibát súlyosbítja, hogy a hibás besorolás többsége beépített terület lett, ami két dolgra is utal. Egyrészt az indexek alkalmatlanok lehetnek néhány felszínborítási kategória határozott elválasztására a környezetüktől (pl. kisebb szőlők). Másrészt a kiinduló adatok felbontása túl nagy ahhoz, hogy kisebb mesterséges elemeket (pl. utak) pontosan lehatároljon, ugyanakkor nem elég nagy ahhoz, hogy ezek az elemek ne torzítsák el a végeredményt (4. ábra). Az alosztály 10,41%-a gyér növényzetként került besorolásra, ami olyan területeket is jelölhet, ahol 2000. október 14-én még nem történt meg a betakarítás.

A táblázat azt is megmutatja, hogy vannak olyan alosztályok, melyek átsorolása javíthat az újraosztályozás pontosságán. A 3115-ös alosztály, azaz a lombos erdő ültetvények nagyobb része rossz osztályba került. Itt az átsorolás nem indokolt, mivel a hibát könnyen okozhatja egy fiatal telepítés, ahol a lombkorona nem összefüggő,

Hiba	CLC osztály	n	Hibaarány	Osztályarány	Teljes arány
4 — 1	2111	521 962	21,48%	24,84%	10,61%
	2112	214 127	8,81%	4,35%	4,35%
	Egyéb	5 817	0,24%	38,32%	0,12%
3 — 5	3115	198 987	8,19%	52,72%	4,04%
	3111	147 120	6,05%	22,19%	2,99%
	Egyéb	120 598	4,96%		2,45%
4 — 2	2111	218 821	9%	10,41%	4,45%
	2112	118 944	4,9%	21,29%	2,42%
	Egyéb	7 593	0,31%		0,15%
3 — 2	3115	81 918	3,37%	21,7%	1,66%
	3211	33 217	1,37%	61,87%	0,68%
	Egyéb	92 071	3,79%		1,87%
Egyéb		901 545	37,1%		18,32%
<b>Összesen</b>		<b>2 429 839</b>	<b>100%</b>		<b>49,38%</b>

## 3. táblázat. Hibák részletes bontásban.



4. ábra. Az 56-os, és 57-es utak hibás klaszterezése Mohács és Lánycsók között. A két sávos (kb. 6 m széles) utak spektrális torzításának hatására 900 m<sup>2</sup>-es területek kerültek beépített terület kategóriába. Forrás: Google Maps 2016.

valamint összefüggő aljnövényzet sem alakult ki. Besorolási hibára utal azonban a 3211-es alosztály, ami természetes gyept jelöl fák és cserjék nélkül. Itt valóban az újraosztályozás tévedett, azonban ennek javítása a végeredményben szignifikáns változást nem hozna.

Összességképpen megállapítható, hogy az újraosztályozás nem hibátlan, viszont helytálló. A hibák javítása minimális javulást hozna az automatikus klaszifikáció pontosságában, a hiba nagy része viszont megmaradna. Így az újraosztályozás, mint fő hibaforrás zárható.

### 3.2.2. Klaszterezésből származó hiba

Egy másik könnyen ellenőrizhető, illetve számszerűsíthető hibaforrás a klaszteranalízis, mely a spektrális lenyomatokat hozza létre. A klaszterezés helyességének ellenőrzéséhez szükség van az indexek átlagaira (4. táblázat), valamint kovariancia mátrixaira a referenciaállomány csoportjaira lebontva. Így a klaszteranalízis kivonhatóvá válik a klasszifikációból, és a két eredmény összehasonlítható lesz. Az eredmények közötti különbség mutatja meg a klaszterezés hibáját, de a két eredmény kapa mutatóinak összehasonlításából is lehet következtetni a klaszteranalízis pontosságára.


A kovariancia mátrixok kiszámolására a GRASS-on belül az r.covar modul szolgál. A manuálisan létrehozott spektrális lenyomattal készített klasszifikáció jobbnak bizonyult, mint az automatikus. Itt már a terület 67,56%-át sikerült helyesen besorolni, azonban a részletes kapa elemzés (5. táblázat) érdemi változást nem mutat.

A beépített területek és az erdők osztályozása pontosabb lett, azonban az eddig kiváló pontossággal lehatá-

Osztály	Com.	Om.	$\kappa$
Beépített terület	77,65%	47,45%	0,19
Gyér növényzet	69,3%	49,38%	0,22
Erdő	16,85%	27,38%	0,77
Kopár terület	6,19%	29,27%	0,86
Vizenyős terület	95,79%	80,41%	0,03
Víz	40,53%	36,33%	0,59
<b>Összesen</b>			<b>0,53</b>

5. táblázat. A klaszterezés nélküli klasszifikáció kapa elemzésének eredménye.

rolt kopár területek, és jó pontossággal rendelkező vizek veszítettek pontosságukból. A hiba oka csak részlegesen keresendő a klaszterezésben, mivel a K-közép algoritmus sajátosságai is okozhatták. Az algoritmus egymástól jól elválasztható, normál eloszlású csoportokat próbál kialakítani (5. ábra), így a kialakított csoportok szórása, varianciája hasonló, a többi jellemző statisztikai mutatója eltérő, periodikus változást mutat.



5. ábra. Csoportok eloszlása automatikus klasszifikáció esetén az NDBI indexen.


Az indexek a referencia csoportokra kiszámolt statisztikai mutatóiból (4. táblázat) jól látszik azonban, hogy az indexek nem ezeket a tulajdonságokat mutatják. Bár a szórásuk többnyire alacsony, az átlagaik, és a határérté-

Kat.	NDBI				NDBaI				NDVI				NDWI			
	m	$\sigma$	1%	99%	m	$\sigma$	1%	99%	m	$\sigma$	1%	99%	m	$\sigma$	1%	99%
1	-0,04	0,07	-0,21	0,12	-0,31	0,06	-0,48	-0,17	0,35	0,1	0,12	0,56	0,1	0,08	-0,09	0,28
2	-0,07	0,08	-0,26	0,12	-0,31	0,06	-0,47	-0,18	0,44	0,09	0,18	0,64	0,13	0,09	-0,09	0,34
3	-0,18	0,08	-0,3	0,07	-0,39	0,07	-0,55	-0,22	0,53	0,08	0,25	0,66	0,25	0,09	-0,04	0,39
4	0,06	0,09	-0,22	0,2	-0,27	0,07	-0,42	-0,2	0,25	0,12	0,09	0,6	-0,02	0,1	-0,19	0,29
5	-0,06	0,08	-0,24	0,12	-0,34	0,06	-0,56	-0,2	0,42	0,09	0,17	0,6	0,12	0,09	-0,09	0,33
6	-0,16	0,1	-0,35	0,11	-0,57	0,18	-0,8	-0,2	0,14	0,24	-0,29	0,55	0,28	0,16	-0,08	0,58

4. táblázat. Az indexek néhány releváns statisztikai mutatója a referenciaállomány csoportjaira kiszámolva.




keik nem különülnek el annyira, hogy a klaszteranalízis megtalálhassa a várt csoportokat. Így a klaszterezés sem hordoz meghatározó mennyiségű hibát.



**6. ábra.** NDVI és NDWI indexek eloszlásfüggvényei a referenciacsoporthoz tartozó területeken.

A hiba forrása így már elég nagy valószínűséggel az indexek alkalmatlansága, azonban érdemes lehet feltárni, pontosan miért alkalmatlanok ezek a normalizált indexek Magyarország területén. A mutatók eloszlása a referenciacsoporthoz tartozó területeken (6., 7. ábra) érdekes összefüggésekre világít rá.



**7. ábra.** NDBI és NDBaI indexek eloszlásfüggvényei a referenciacsoporthoz tartozó területeken.

Az NDVI emeli ki leginkább a célcsoportok spektrális eltéréseit. Az NDWI legfőbb alkalmazási területe a növényzet nedvességtartalmának a kimutatása. Az erdők és a gyér növényzet elkülönítésére maradéktalanul alkalmas, azonban az erdők és a vizek, valamint a gyér növényzet és a vizenyős területek nehezen választhatók szét ezzel a mutatóval. Váratlan előnye azonban, hogy a kopár területekre is igen érzékeny.

Az NDBaI jól kiemeli a kopár területeket. Azonban Chen et al. (2006) megállapítása, miszerint a 0-nál nagyobb NDBaI értékek a kopár területekkel erősen korrelálnak, Magyarországon megdőlni látszik. Baranya megyében szinte az egész terület 0 alatti értéket vesz fel, és a kopár területek -0,6-os érték alatt szeparálhatóak el. Ennek fő oka lehet a Kína délkeleti részét jellemző vörös- és sárgaföldek eltérő reflektanciája a kontinentális éghajlat jellemző talajaitól közepes, és termális infravörös tartományban.

Az NDBI mutató hozta a leggyengébb eredményt. A mutatónak a beépített területek és a természetes területek

eltérő reflektanciájára kellene érzékenynek lennie, ezzel szemben a kopár területekre érzékeny. Ennek okai egyelőre ismeretlenek, feltárásuk további kutatómunkát igényel. Az okok között szerepelhetnek a kínai és magyar területek közötti beépítettség mennyiségi, és minőségi különbségei, a besugárzás eltérő mértéke, valamint a vidéki városok hőszennyeztségének kisebb mértékéből adódó UHI (Urban Heat Island) jelenség részleges hiánya. Fontos megemlíteni, hogy a vizeket, és az erdőket jól elválasztja a többi csoporttól, ami a többi mutatóval együtt, négy dimenzióban javítja azok elszeparálhatóságát.

## 4. Összegzés

A Chen et al. (2006) által alkalmazott indexek vegyesen alkalmazhatóak Magyarországon automatikus klasszifikációra. A K-közép és MLC algoritmusok jó pontossággal határolják le a kopár területeket és a vizeket, valamint közepes pontossággal az erdőket. A többi vizsgálati csoportra azonban nem eléggé érzékenyek. A beépített területek, a gyér növényzet, valamint a vizenyős területek mind a négy indexen összemosódnak, spektrális tulajdonságaik túlságosan hasonlóak. Az NDVI képes leginkább elválasztani a célcsoportokat, viszont pontos lehatárolásra egy mutató, az algoritmusok szemszögéből egy dimenzió nem elegendő. Az NDWI, és az NDBaI nem a várt módon, de hasznosnak bizonyulnak a kopár területek, a vizek, és az erdők elválasztásában. Az NDBI hozta a legrosszabb eredményt, ennek a mutatónak volt a legkevésbé hasznos az elemzés során.

Bár a vizsgált indexek automatikus klasszifikációra részlegesen alkalmasak, azaz néhány felszínborítási elemet nagy pontossággal képesek lehatárolni, önállóan nem alkalmazhatóak. Egy teljesen automatizálható és pontos módszer kidolgozásához az itt megírt módszer implementálható, azonban más jellegű, lokalizált, Magyarország viszonyait jól visszaadó mutatókra is szükség van.

## Köszönetnyilvánítás

Szeretnék köszönetet mondani Dr. Szabó Szilárdnak, amiért meglátásaival nem csak tartalmilag, de formailag is sokat sikerült javítani a dolgozaton, valamint Dr. Mucsi Lászlónak, amiért véleményével további perspektívákat adott a kutatásnak. Mindkettejük munkáját nagyra értékelem.

## Irodalomjegyzék

- Ahmad, A. és Quegan, S. (2012). Analysis of maximum likelihood classification on multispectral data. *Applied Mathematical Sciences*, 6(129), 6425–6436.
- Büttner, G., Maucha, G., Bíró, M., és Petrik, O. (2009). Nagyfelbontású nemzeti felszínborítási adatbázis. Földmérési és Távérzékelési Intézet, Környezetvédelmi Távérzékelési Osztály, Budapest. 9 p.
- Chen, X.-L., Zhao, H.-M., Li, P.-X., és Yin, Z.-Y. (2006). Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes. *Remote Sensing of Environment*, 104, 133–146.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37–46.
- Congalton, R. G. (1991). A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, 37, 35–46.
- Ding, C. és He, X. (2004). K-means clustering via principal component analysis. *Proceedings of the Twenty-first International Conference on Machine Learning, ICML '04*, New York, NY, USA. 29–.
- Eredics, A. (2007). Vegetációs Indexméter (NDVI) Tervezése és Fejlesztése. Nyugat-Magyarországi Egyetem Erdőmérnöki Kar Geomatikai, Erdőfeltárási és Vízgazdálkodási Intézet Földmérési és Távérzékelési Tanszék, Sopron. 3–5.
- Feranec, J., Hazeu, G., Christensen, S., és Jaffrain, G. (2007). Corine land cover change detection in Europe (case studies of the Netherlands and Slovakia). *Land Use Policy*, 24, 234–247.
- FÖMI (2009). Az 1:50.000 léptékű országos CORINE Felszínborítási (Land Cover) Projekt nomenklatúrája. Földmérési és Távérzékelési Intézet, Környezetvédelmi Távérzékelési Osztály, Budapest. 20 p.
- Gao, B.-C. (1996). NDWI – A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. *Remote Sensing of Environment*, 58, 257–266.
- Garrison, T. G., Houston, S. D., Golden, C., Inomata, T., Nelson, Z., és Munson, J. (2008). Evaluating the use of IKONOS satellite imagery in lowland Maya settlement archaeology. *Journal of Archaeological Science*, 35, 2770–2777.
- GRASS Development Team (2016). Geographic Resources Analysis Support System (GRASS GIS) Software, Version 7.0. Open Source Geospatial Foundation.
- Landis, J. R., és Koch, G. G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159–174.
- Lein, J. K. (2003). OhioView: A Case Study in Progress. *Journal of Space Communications*, 1(3), 29 p.
- Mika, J., Utasi, Z., Bíró, C., és Kónya, E. P. (2011). Műholdakról távérzékelte adatok feldolgozása és hasznosítása. EKF Matematikai és Informatikai Intézet, Eger. 19–20.
- NASA (2011). Landsat 7 Science Data Users Handbook. Landsat Project Science Office at NASA's Goddard Space Flight Center, Greenbelt. 186 p.
- USGS (2015). Landsat missions: Imaging the earth since 1972. [http://landsat.usgs.gov/about\\_mission\\_history.php](http://landsat.usgs.gov/about_mission_history.php). Letöltve: 2016. Január 8.
- Wulder, M. A., Masek, J. G., Cohen, W. B., Loveland, T. R., és Woodcock, C. E. (2012). Opening the archive: How free data has enabled the science and monitoring promise of Landsat. *Remote Sensing of Environment*, 122, 2–10.
- Zhao, H. és Chen, X. (2005). Use of normalized difference bareness index in quickly mapping bare areas from TM/ETM+. *Geoscience and Remote Sensing Symposium, 2005. IGARSS '05. Proceedings. 2005 IEEE International*, 3, 1666–1668.



