

A SZEGMENTÁLÁS SZEREPE AZ ŰRFELVÉTELEK TEMATIKUS OSZTÁLYOZÁSÁBAN

THE ROLE OF SEGMENTATION IN THE THEMATIC CLASSIFICATION OF SATELLITE IMAGES

Fekete István¹, Dezső Balázs¹, László István^{1,2}, Ócsai Katalin^{1,2}

¹Eötvös Loránd Tudományegyetem, Informatikai Kar

²Földmérési és Távérzékelési Intézet, Távérzékelési Központ

Összefoglaló

A *távérzékelés* széleskörű mezőgazdasági alkalmazásaiban alapvető fontosságú a felszínborítási kategóriák azonosítása az *űrfelvételeken*. Ez egy *tematikus osztályozás* elvégzését, és annak eredményeként egy tematikus térkép előállítását jelenti a vizsgált területről. Korábbi munkáinkban a távérzékeléssel kapott adatok tematikus osztályozásának újszerű, *szegmensalapú* megoldását dolgoztuk ki. A műholdfelvételek elemzése során jobb eredményeket érhetünk el ezzel a megközelítéssel, mint az általánosan alkalmazott képpontenkénti osztályozással. A módszer kihasználja a felszínborítás szomszédos képpontjai között gyakran fennálló hasonlóságot. Az egymás melletti hasonló képpontokból szegmenseket képezünk, majd az osztályozást végig a szegmenseken végezzük a különálló képpontok helyett. A szegmens általában „magával viszi” egy területnek azokat a pontjait is, amelyeket önálló képpontként esetleg – tévesen – a környezetüktől eltérő felszínborítási kategóriába sorolnánk intenzitásértékük alapján. Az eljárást olyan klaszterező és osztályozó algoritmussal egészítettük ki, amelyek a szegmenseken dolgoznak, egyedi képpontok helyett. Mivel a szegmensalapú osztályozás kedvező tapasztalatokat eredményezett, két újabb szegmentáló eljárást vezettünk be és vizsgáltunk. A három szegmentálás egymástól eltérő elméleti háttér alapján működik, eltérő eredményeket hoz létre, de a szegmentálást követő osztályozás eredménye nagy pontossággal megegyezik a három esetben.

Kulcsszavak

távérzékelés, űrfelvételek, tematikus osztályozás, szegmentálás

Abstract

In the widespread agricultural applications of *remote sensing* the identification of land cover categories in *satellite images* is essential. This consists of a *thematic classification* and as its result, the creation of a thematic map of the target area. During our previous works we have elaborated and implemented a novel, *segment-based* solution of classification. In the evaluation of satellite images, better results can be achieved with this approach than with the commonly used pixel-based classification. This method is able to utilize the similarity between neighboring pixels of land cover. Similar neighboring pixels are grouped into segments, and the classification is carried out on segments instead of individual pixels. A segment usually “takes along” those points of an area that would be erroneously classified as another land cover category than their neighborhood in case of pixel-based classification, using only intensities. The method was appended with a clustering and classifying algorithm that work on segments instead of individual pixels. As segment-based classification yielded favorable results, we have introduced and examined two further segmentation methods. Although the theoretical background of segmentation methods is different, and their result is not identical, the results of classification following the segmentation yields match with high accuracy in the three cases.

Keywords

remote sensing, satellite images, thematic classification, segmentation

1. Bevezetés

A *távérzékelés* szerepe a mezőgazdasággal kapcsolatos felmérések, megfigyelések és ellenőrzések elvégzése során folyamatosan növekszik. Az utóbbi években a távérzékelés Magyarországon egyre több monitorozási tevékenységet támogat. Ide sorolható többek között a növényterképezés és hozam-előrejelzés, az árvíz-, belvív- és aszály-monitoring, a területalapú mezőgazdasági támogatásokhoz kötődő alkalmazások, valamint a parlagfű-felmérés és -mentés. A tevékenységek csaknem mindegyikének része egy tematikus osztályozás elvégzése, és annak eredményeként egy tematikus térkép előállítása a területről.

A tematikus osztályozás alapvető feladatára a hazai gyakorlatban újszerű megoldást adtunk a szegmensalapú megközelítés alkalmazásával (László et al., 2004). A szegmensalapú osztályozás már kezdeti változatában is eredményesen használta fel a képpontok szomszédságából adódó hasonlósági összefüggést. Később a szegmentáló algoritmus javítása mellett az osztályozás minden lépését következetesen szegmensalapúvá tettük (László et al., 2007). Ebben a cikkben két további szegmentáló eljárás bevezetéséről számolunk be.

A távérzékelés alapfogalmait ismertnek tételezzük fel. Az érdeklődőknek ajánlhatjuk a (Richards és Jia, 2005) alpművet, de a fent idézett két dolgozat is tartalmazza az alapvető fogalmak bevezetését.

2. A hagyományos pixelalapú osztályozás

A *tematikus osztályozás* feladata egy digitális tematikus térkép elkészítése az adott területről. A tematikus térkép képpontjai esetünkben a felszínborítás kategóriáinak, az ún. *osztályoknak* felelnek meg. A kategóriák elég változatosak lehetnek a különféle alkalmazásokban: nemcsak növényfajokat jelenthetnek, hanem mutathatják az aszály súlyosságát, vagy jelezhetik a különbséget a belvív által sújtott területek között.

A távérzékelésben ismert megfigyelés, hogy az ugyanazon felszínborítási kategóriát (pl. növényfajt) képviselő nagyszámú képpont egy vagy több normális eloszlással közelíthető az intenzitástérben. A hagyományos osztályozási feladat alapelveként a következő feltételezéssel élünk: minden tematikus kategória (pl. búza) leírható megfelelő normáeloszlású spektrális *alosztályok* kompozíciójaként. Az osztályozást végző bonyolult eljárás többnyire nem teljesen automatizált, az emberi szakértelem bevonására is szükség van.

Az osztályozás bemenő adata egy vagy több műholdfelvétel. Rendszerint, a célterület már ismert részeit leíró referenciaadatokat is felhasználjuk, két részre osztva: a tanulóterületeket az alosztályok paramétereinek meghatározására, a tesztadatokat pontosságvizsgálatra.

Ebben a cikkben a *növényterképezést* vesszük példának, amelyben a feladat a növényfajok meghatározása a mezőgazdasági területeken, körülbelül 25 m × 25 m-es térbeli felbontással. A különböző növények vegetációs időszaka és a fejlődésük menete az éven belül meglehetősen eltérhet egymástól, de egy adott időpontot tekintve a reflektanciájuk egybeeshet. Ezért a megfelelő osztályozáshoz több időpontban készült űrfelvételeket kell felhasználni. Az 1. ábra három időpontú űrfelvétel-sorozatot mutat ugyanarról a területről. A több-időpontú adatok osztályozásba való bevonásának legegyszerűbb módja az, ha a különböző időpontokban készült felvételeket egymásra rakva *többsávós képet* állítunk elő.

Az osztályozás a pontosságvizsgálattal együtt négy fő lépésből áll.

1.) A klaszterek az intenzitástér pontjainak a felszínborításokra jellemző „tömörödési”. A *klaszterezés* során az iterációnként változó klaszterterkép a képpontok klaszter-sorszámát tartalmazza. Az eljárás nem sorolja be a kis elemszámú klaszterek képpontjait, valamint azokat sem, amelyek minden klasztertől távol vannak. Az eljárás végén meghatározzuk a kapott klaszterek átlagvektorát és a kovarianciamátrixát (együtt: szignatúrát).

2.) A *tanulási fázis* célja, hogy a spektrális alosztályokhoz egyértelműen hozzárendeljük a felszínborítási kategóriák valamelyikét. Bemenete az eredeti kép, a tanuló referenciaadatok és a klaszterterkép. Kimenete az egyes felszíni borításokhoz tartozó alosztályok szignatúrái.

Először a kép pontjait újból hozzárendeljük a kialakult klaszterekhez. Ezzel egy új „klaszterterképet” hozunk létre. A besorolást maximum likelihood (ML) módszerrel végezzük, normális eloszlásokat feltételezve. Minden x képpontot abba az ω_k klaszterbe sorolunk, amelyre az (1) szerinti valószínűség maximális. Azokat a képpontokat, amelyek a χ^2 -próba szerint 99% eséllyel nem tartoznak klaszterbe, nem osztályozzuk.

$$p(x|\omega_k) = (2\pi)^{-N/2} |\Sigma_k|^{-1/2} e^{-(x-\mu_k)^T \Sigma_k^{-1} (x-\mu_k)/2} \quad (1)$$

Ezt követően a klaszterek és a referenciaterületek összefüggését vizsgáljuk. Minden egyes klaszterre meghatározzuk a képen hozzá tartozó pontok és az egyes referenciakategóriák közös területeit, összemetszésük mértékét. A klaszterekhez az „osztályozott”, „újraosztályozandó”, „vágandó”, illetve „elhagyandó” címkéket rendelünk egy összetett eljárásban.

3.) Az *osztályozási fázisban* a megcímkézett klaszterekhez pontokat kategóriákba soroljuk. Elsőként az újraosztályozandó klaszterek pontjait ML-döntéssel besoroljuk az osztályozott vagy a vágandó klaszterekbe, a klaszterbe nem illő pontok elhagyásával. Majd statisztikai becsléssel meghatározzuk a vágandó klaszterekben előforduló releváns növényekhez tartozó referenciapixel szignatúráit – normális eloszlásokat feltételezve –, és a klaszterhez tartozó pontokat besoroljuk ML-módszerrel ezekbe az „alklaszterekbe”. Az osztályozott klaszterek pixeljeit pedig hozzárendeljük az egyetlen releváns növény osztályához.

A kialakult képen a pixelek nagy részét ilyen módon osztályba soroltuk. A kezdeti klaszterbe sorolásnál elhagyott pixelek, az elhagyandó klaszterek pixeljei, és az újraosztályozásnál elhagyott pixelek nem ismert kategóriába esnek, tehát ezek a pontok nem lettek osztályozva.

4.) Végül, a negyedik lépésben *pontosságvizsgálatot* hajtunk végre, a referenciaadatokból a teszterületet felhasználva. Magas hibaarány esetén újra végrehajtjuk valamelyik korábbi lépést korrigált paraméter-beállítással. (Részletesebben lásd: (Nádor et al., 1997).)

Megjegyezzük, hogy ez a „pontonkénti” osztályozási módszer teljesen figyelmen kívül hagyja a homogén területekre (pl. ugyanabba a mezőgazdasági parcellába) eső szomszédos képpontok azonosságát vagy hasonlóságát, mivel csak a képpontok intenzitását használja fel, környezeti információ nélkül. A pontonkénti klaszterezés és az osztályozás eredményét bemutató ábra található a már idézett (László et al., 2007) dolgozatban.

3. A szegmensalapú osztályozás módszere

A hagyományos pixelalapú *pontonkénti osztályozás* gyakori tévedése az, hogy egy, a környezet átlagától eltérő képpontot nem oda sorol be, mint ahová a szomszédjaival együtt valójában tartozik, hanem abba az osztályba, ahová önmagában nézve a legvalószínűbben

elhelyezhető. A környezeti hovatartozásban rejlő információ kinyerése céljából tértünk át a *szegmensalapú osztályozásra*: először végrehajtottunk egy szegmentáló eljárást, majd az osztályozás további lépéseit a szegmensekre alkalmazzuk. Ilyen módon a szegmensek „végigvonulnak” a teljes klaszterezésen és osztályozáson: magukat a szegmenseket fogjuk klaszterezni és osztályba sorolni.

Az, hogy a szegmenseket soroljuk osztályba, segít megőrizni a felvételen tapasztalható homogenitásokat, ami erős természeti adottság. Ez a hatásos elv azonban nem elég finom megközelítés a határpontok hovatartozásának eldöntésére, illetve a minden felvételen szükségszerűen előforduló heterogén területek esetén. Ezért az osztályozó eljárást egy pontonkénti felülvizsgálat zárja.

4. A képszegmentálás megvalósított módszerei

A *szegmens* spektrálisan hasonló, szomszédos képpontok egybefüggő halmaza. A szegmentálás eredményeként egy tematikus térképet, ún. szegmenstérképet kapunk, amely minden egyes képpontra megadja az őt tartalmazó szegmens sorszámát. Olyan szomszédos képpontok kerülnek egy szegmensbe, amelyek – bizonyos hasonlósági kritériumok alapján – feltehetően ugyanahhoz a felszínborításhoz tartoznak.

Számos szegmentáló eljárás leírása található a szakirodalomban. A szegmentálás ismert monográfiája (Schoenmakers, 1995) a nagyszámú módszer ismertetése mellett segít az önálló kísérletezéshez szükséges egységes szemlélet kialakításában is. Eddigi munkánk során három szegmentáló eljárást implementáltunk és vizsgáltunk nagyobb adatmennyiségen. Mindhárom eljárást röviden ismertetjük alább, és működésük eredményét a vizsgált mintaterületre a 2. ábrán adjuk meg.

4.1. Szekvenciális csatolás módszere

Az általunk használt szegmentáló eljárás a (Kettig és Landgrebe, 1976) által leírt módszer többször javított változata (lásd: (László et al. 2004, 2007)).

A szegmentáló algoritmus első lépésben 2×2 -es *cellákra* osztja a képet, majd minden celláról eldönti, hogy homogénnek tekinthető-e vagy sem. Egy cella *homogén*, ha minden sávban igaz a következő (2) egyenlőtlenség (ahol n a cella pixelszáma, esetünkben $n = 4$). A feltétel azt fejezi ki, hogy a szórás minden sávban egy adott határon alul marad az intenzitások átlagához képest. Az inhomogén cellák pixeljeit nem soroljuk szegmensekbe, míg a homogén cellák bevonásával egy területnövelő algoritmust hajtunk végre.

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{(n-1)\bar{x}^2} \leq C_H \quad (2)$$

A kép bal felső sarkából indulva, kifinomult *szekvenciális sorrendű csatolási eljárást* alkalmazva, megpróbáljuk a homogén cellákat – akár áthidaló cellák segítségével – az előzőleg kialakult szegmensek valamelyikéhez (a legközelebbihez) csatolni. Ha egyik összevonás sem lehetséges, akkor a cella egy új szegmens kezdetét jelenti.

Az összevonás lehetőségét minden esetben a szegmensekhez tartozó spektrális intenzitások várható értéke és szórása által meghatározott ANOVA-kritériumok segítségével döntjük el.

Legyen x egy m elemű és y egy n elemű minta, és jelölje z a kettő összevonásával kapott eloszlást. Minden sávban számítsuk ki a (3) és (4) szerinti mennyiségeket.

$$A_x = \sum_{i=1}^m (x_i - \bar{x})^2 \quad A_y = \sum_{i=1}^n (y_i - \bar{y})^2 \quad A = A_x + A_y \quad (3)$$

$$B_x = \sum_{i=1}^m (x_i - \bar{z})^2 \quad B_y = \sum_{i=1}^n (y_i - \bar{z})^2 \quad B = B_x + B_y \quad (4)$$

A szegmensösszevonást egy adott sáv szerint engedélyezzük, ha a következő (5) egyenlőtlenségek teljesülnek meghatározott C_1 és C_2 értékekre. Két szegmens akkor vonható össze, ha az egyenlőtlenségek minden sávra teljesülnek.

$$(A/B)^{(m+n)/2} \geq C_1 \quad \left(\frac{(A_x/m)^{m-1} (A_y/n)^{n-1}}{(A/(m+n))^{m+n-2}} \right)^{1/2} \geq C_2 \quad (5)$$

Jól hangolt döntési eljárás eredményeként olyan *szegmenstérképet* kapunk, amelyen az egybefüggő részek várhatóan ugyanahhoz a felszínborításhoz tartoznak. Egy felszínborításhoz viszont több szegmens is tartozhat, egymástól távol, vagy akár egymás mellett is. Az eljárás futási ideje $O(n)$, azaz a kép méretében lineáris.

4.2. Legjobb összevonás alapú szegmentálás

A legjobb összevonás alapú szegmentálást a (Schoenmakers, 1995) monográfia 5. fejezete alapján alakítottuk ki. Ez alapvetően egy mohó algoritmus, amelynek kezdőállapotában az egyes pixelek önálló szegmenseket alkotnak, és minden lépésben újabb optimális összevonást alkalmazva állít elő egy szegmenstérképet.

Ez az iteratív algoritmus minden lépésben egy hasonlósági kritérium szerint a legközelebbi, szomszédos szegmenseket vonja össze. Leállási feltétele vagy a megfelelő szegmens-szám elérése, vagy az, hogy a hasonlósági kritérium már minden szomszédos szegmens-páron meghalad egy adott küszöbértéket.

Az általunk megvalósított eljárásban a *hasonlósági kritérium* olyan távolságfüggvényeken alapul, amelyek a két szegmens intenzitásának a várhatóérték-vektorából és kovarianciamátrixából meghatározhatók. Ilyen távolságfüggvények például a divergencia, a Bhattacharya-, a Jeffries-Matusita-, vagy az átlagos négyzetes távolság. Választásunkkal két szegmens egyesítése esetén az új átlagvektor és kovarianciamátrix könnyen számolható.

Az algoritmus működése során valójában egy olyan *gráfot* módosít folyamatosan, amelynek csúcsai az egyes szegmensek (kezdetben a pixelek), élei pedig a szomszédos szegmenseknek megfelelő csúcsokat kötik össze, a hasonlóságuknak megfelelő értékkel súlyozva. Az implementáció hatékonyságát fejlett adatstruktúrákkal – éllistas gráf-reprezentációval, bináris kupaccal, unió-holvan adatszerkezettel – biztosítottuk. Az algoritmus futásideje legrosszabb esetben $O(n^2)$, átlagos esetben azonban $O(n \log(n))$ időt kapunk.

4.3. Gráf alapú szegmentálás

A gráf alapú szegmentálást a (Felzenszwalb és Huttenlocher, 2004) cikk alapján implementáltuk. Az előző algoritmushoz hasonlóan kezdetben itt is minden pixel külön szegmensbe esik, és a szegmensek összevonásával jön létre az eredménykép.

Az algoritmus a kiinduló felvételt (az előző eljáráshoz hasonlóan) egy rácsgráfnak fogja fel, melyben a pixelek megfeleltethetőek a csúcsoknak, és két csúcsot akkor köt össze él, ha szomszédos pixeleket reprezentálnak. Az élekhez rendelt súlyt ezúttal is az összekötött pixelek távolsága. Egy szegmens mindig megfeleltethető egy összefüggő részgráfnak. Míg a szekvenciális csatolás módszerénél a szegmens homogenitását adtuk meg számszerűen, addig itt egy S szegmens változékonyságát, *heterogenitását* jellemezzük egy gráfelméleti fogalommal, a szegmens *minimális feszítőfájában* a maximális élnek a súlyával, amit $het(S)$ -sel jelölünk. A szomszédos S_1 és S_2 szegmensek összevonhatók, ha az újonnan kialakuló szegmens nem növeli meg nagymértékben a két szegmens heterogenitását:

$$\min\{het(S_i) + k / |S_i|, het(S_j) + k / |S_j|\} > het(S_i \cup S_j) \quad (6)$$

Az összevonási feltétel értelmezéséhez figyelembe kell venni, hogy az egyenlőtlenség jobb oldalán álló mennyiség, a két szegmenst összekötő legrövidebb él súlya nagyobb, mint a két szegmens feszítőfájának maximális élsúlya, azonban azok korrigált értékénél már jó esetben kisebb. A korrekciót egy alkalmas k küszöb és szegmens-elemszám hányadosának hozzáadása jelenti, ami a kis elemszámú szegmensek esetére biztosít reális értékeket.

Az algoritmus kezdetben minden pixelt külön szegmensbe sorol, majd az élek súlyának növekvő sorrendjében megvizsgálja, hogy az él két végpontján lévő szegmensek összevonhatók-e. Az eljárás sorban minden élt megvizsgál. Az implementáció során ki lehet használni azt a – rendezettségéből adódó – tény, hogy ha egy élen összevonhatunk két szegmenst, akkor az lesz az új szegmensben a minimális feszítőfa maximális éle, így magát a fát nem kell meghatározni. Az algoritmusban alkalmazhatjuk az unió-holvan adatszerkezetet, így a teljes futási időt a rendezés határozza meg, ami $O(n \log(n))$ hatékonyságot eredményez.

Érdekes összehasonlítani a legjobb összevonás alapú szegmentálást ezzel a módszerrel. Míg az előbbiben mindig optimális összevonást használunk, addig itt a lehetséges összevonásokat fogadjuk el, vagy vetjük el a belső heterogenitás és a hasonlóság függvényében. Míg a legjobb összevonás alapú módszerben esetlegesen nem is vizsgálunk nagyon intenzíven változó területeket a képen – így ezen területeken minden pixel külön szegmensbe esik –, addig a gráf alapú módszerben ezeket a területeket is mindenképpen vizsgáljuk, és ezeken területeken a szegmensek kialakulása adaptívan reagál az erősebb intenzitás változásra.

5. Szegmensalapú klaszterezés

A klaszterezés feladatára az Isodata eljárást úgy módosítottuk, hogy alkalmas legyen szegmensek besorolására. Az Isodata klaszterezés általános váza a következő lépésekből áll:

- 1. lépés** Válasszunk véletlen módon kezdő klaszter-középpontokat.
- 2. lépés** Soroljuk be a szegmenseket euklideszi távolság alapján a legközelebbi klaszter-középponthez, felső határt szabva a minimális távolságra.
- 3. lépés** Töröljük az adott küszöbértéknél kisebb elemszámú klasztereket.
- 4. lépés** Vonjuk össze a hasonló intenzitás-eloszlású klasztereket, a Bhattacharyya-távolságot használva hasonlóság megállapítására.
- 5. lépés** Osszuk fel a nagy klasztereket. (Opcionális lépés.)
- 6. lépés** Ha a leállási feltétel nem teljesül, akkor az aktuális klaszterek alapján új középpontokat alkotva folytassuk a 2. lépéstől.

Az algoritmus lépései során nagy szabadságunk van az alkalmazott módszerek, távolságfüggvények és paraméterek megválasztásában. Meghatározott számú lépés végrehajtása után áll le. Ehelyett az is lehetne a leállási feltétel, hogy két iteráció között a klaszter-középpontok elmozdulása megadott norma szerint kicsi.

Az algoritmus által meghatározott, a spektrális térben vett *normális eloszlásokat* tekintjük a klaszterezés eredményének, amit az eloszlások várhatóérték-vektora és kovariancia-mátrixa (együtt szignatúra) jellemez. (Vö. 2. fejezet, osztályozó algoritmus 1. pontja.) A *szignatúrák* kialakításában nem vesznek részt a felvétel bizonyos pixeljei: egyrészt a nem szegmentált pontok, másrészt a minden klasztertől távol eső szegmensek pontjai. A szegmensalapú klaszterezés eredményét a bemutatott mintaterületre, rendre a három szegmentálás esetén, a 3. ábra szemlélteti. (Az eljárás a klasztereket a szegmensek adataiból alakítja ki, így előáll a szegmenseknek a klaszterekhez történő besorolása is, ezt az eredményt azonban nem tartjuk meg, hanem a következő lépésben újból előállítjuk.)

6. A kép szegmenseinek tematikus osztályozása

A szegmensalapú eljárásnál is az a célunk, hogy meghatározzuk a felszínborítási kategóriákhoz tartozó eloszlásokat. Ahogy említettük, egy tematikus kategóriát több eloszlás is felépíthet, ezért beszélünk spektrális alosztályokról.

Elsőként a kép szegmenseit újból hozzárendeljük a kialakult klaszterekhez a tapasztalati eloszlásuk alapján, szintén a maximum likelihood módszerrel. Így egy új klaszterterkép jön létre. Az ML-döntésnél a szegmens pixeljein vett valószínűségek logaritmikus átlagát, a χ^2 -döntésnél pedig a pixeleken vett χ^2 -értékek átlagát használjuk.


Majd elkészítjük a *referenciaterületek* és a *klaszterterkép metszetét*. Az egyes klaszterekhez ugyanolyan eljárással rendelünk címkét, mint a pontonkénti esetben (2. fejezet, 2. pont). Egy klaszter itt is „elhagyandó”, „osztályozott”, „újraosztályozandó”, illetve „vágandó” lehet. A klaszterek címkétől függő feldolgozása formálisan megegyezik a pontonkénti esettel.

Így kialakult a kép *elsődleges osztályozása*, amelynek az eredménye, hogy csaknem az összes szegmenst besoroltuk valamelyik felszínborítási kategóriához. Előfordul, hogy egy szegmens oda nem illő pontot is „bevisz” egy kategóriába, valamint a kép pontjainak cellákra osztása nem ad elég finom eljárást a határpontok kezelésére. Ezért az elsődleges osztályozást pontonkénti 99%-os χ^2 -próbával felülvizsgáljuk, vágandó klasztereknél a próbát az alklaszterekre is alkalmazva.

Végül a *pontonkénti javítás* következik: a szegmentálás, a klaszterezés és az osztályozás felülvizsgálata során kiesett képpontokat ML-módszerrel besoroljuk egy osztályozott vagy vágandó klaszterbe (illetve ezek egyik alklaszterébe), ezeken keresztül pedig egy tematikus kategóriába. Azonban erre a besorolásra is alkalmazunk egy 99%-os χ^2 -próbát.


Ezzel minden, az eljárás végén besorolt képpont megalapozottan került valamely tematikus kategóriába. A pontosságvizsgálatot a referenciaadatokból a teszterület felhasználásával hajtjuk végre, a pixelenkénti esethez hasonlóan.

A szegmensalapú osztályozás eredményét a bemutatott mintaterületre, rendre a három szegmentálás esetén, a 4. ábra szemlélteti.



(a) 2003. 05. 06. (b) 2003. 06. 30. (c) 2003. 08. 11.

1. ábra. A mintaterületről készült űrfelvétel-idősor




(1) Szekvenciális csatolás (2) Legjobb összevonás (3) Gráfalapú

2. ábra. A háromféle szegmentálás eredménye



(1) Szekvenciális csatolás (2) Legjobb összevonás (3) Gráfalapú

3. ábra. A klaszterezés eredménye a háromféle szegmentálás után



(1) Szekvenciális csatolás (2) Legjobb összevonás (3) Gráfalapú

4. ábra. Az osztályozás eredménye a háromféle szegmentálás után

7. Eredmények

Röviden összefoglaljuk eddigi eredményeinket (László et al., 2004, 2007). Létrehoztunk egy *teljesen szegmensalapú osztályozó eljárást*, amelynek részeként eddig egy stabil szegmentáló eljárás működött. Ezt az algoritmust annyira megjavítottuk, hogy a kialakuló eredmény alig függ a cellák szekvenciális feldolgozási sorrendjétől. A paraméterezése viszont nem egyszerű, a 2-3 %-os *pontosság-növekedés* elérése sok kísérletezést kívánt. A javulást az is elősegíti, hogy az eljárás erőssége a parcellák belső pontjainak helyes besorolása, és ez többet javít a pontosságon, mint amennyit a határpontok bizonytalanabb kezelése ront. Az eljárás minden fázisában lehetőség van a nem illeszkedő pontok kezelésére. A teljes eljárás *futási ideje csökkent*, jórész annak köszönhetően, hogy a klaszterezendő objektumok száma nagyságrendekkel kevesebb, mivel a pixeleket szegmensek váltották fel.

A cikkben bemutatott szegmentáló algoritmusok megfelelő paraméterezésével 91-95% osztályozási eredményt értünk el, ami meghaladja az általunk készített pontonkénti osztályozás eredményét. A vizsgálat során azt tapasztaltuk, hogy a különböző szegmentálási módszerek érdemben nem különböznek az osztályozás találati arányában, azonban eltérnek abban, hogy mennyire érzékenyek az eljárás működését vezérlő *paraméterek* változtatására. Tapasztalatunk szerint a legjobb összevonás alapú és a gráf alapú szegmentálás optimális paramétereinek a megkeresése lényegesen egyszerűbb, mint a szekvenciális csatolás módszer esetében. Ezen túl a legjobb összevonás alapú módszernél érdemes olyan távolságot választani, ami a szegmens méretek növekedésével egyre szigorúbb feltételt határoz meg, ezáltal elkerülhető a nagyméretű, több felszínborítást is fedő szegmensek kialakulása.

Irodalomjegyzék

- [1] Felzenszwalb P. F., Daniel P. Huttenlocher D. P. (2004) Efficient Graph-Based Image Segmentation. *International Journal of Computer Vision*, Vol. 59, Number 2, 167–181.
- [2] Kettig R. L., Landgrebe D. A. (1976) Classification of Multispectral Image Data by Extraction and Classification of Homogeneous Object. *IEEE Transactions on Geoscience Electronics*, 14(1), 19–26.
- [3] László I., Pröhle T., Fekete I., Csornai G. (2004) A method for classifying satellite images using segments. *Annales Univ. Sci. Budapest., Sectio Computatorica*, 23, 163–178.
- [4] László I., Dezső B., Fekete I. Pröhle T. (2007) A Fully Segment-Based Method for Classification of Satellite Images In: *Proc. of the 10th Symposium on Programming Languages and Software Tools*, Dobogókő, Hungary, 14-16 June 2007, 152–166.
- [5] Nádor G., Csornai G., Kocsis A. (1997) Methods of accuracy assessment of thematic vegetation mapping by remote sensing. In: *7th Seminar on Earth and Meteorological Observations by Satellites*, Budapest (in Hungarian)
- [6] Richards, J. A., Jia, X. (2006) *Remote Sensing, Digital Image Analysis — An Introduction. Fourth Edition*. Springer-Verlag.
- [7] Schoenmakers, R. (1995) *Integrated methodology for segmentation of large optical satellite images in land applications of remote sensing*. Joint Research Centre, European Commission.