

Mucsi László

Műholdfelvételek feldolgozásának elmélete és gyakorlata

Olvasólecke

	<u>Feladat időtartama:</u> 90 perc	<u>Téma:</u> Műholdfelvételek osztályozás automatikus módszerrel
--	---------------------------------------	--

Űrfelvételek osztályozása

Automatikus (nem irányított) osztályozás

Jelen tananyag a Szegedi Tudományegyetemen
készült az Európai Unió támogatásával.

Projekt azonosító: EFOP-3.4.3-16-2016-00014

Űrfelvételek osztályozása

Automatikus (nem irányított) osztályozás

Tartalom

Bevezetés

1. *Automatikus osztályozás (Unsupervised training)*
 2. K-Means Klaszter Analízis vagy ISODATA klaszterezés
 3. A klaszterezés paraméterei
 4. Kezdő osztályközepek helyének meghatározása
 5. Döntéshozás - pixelek klaszterbe sorolása
 6. A klaszterezés eredménye
- Ellenőrző kérdések

Bevezetés

A műholdfelvételek osztályozásának az célja, hogy a folytonos spektrális információkat tartalmazó műholdfelvételtől diszkrét objektumokat tartalmazó tematikus térképet állítsunk elő. A műhold szenzora által, a lefedett területről gyűjtött spektrális adatokat tartalmazó űrfelvétel folytonos abban az értelemben, hogy a földrajzi térben szomszédos képelemek spektrális tulajdonságai hasonlítanak egymáshoz. Ez az állítás akkor is igaz, ha a felszínen diszkrét, határokkal élesen elválasztható objektumok, pl. mezőgazdasági táblák, városban épületek, útfelületek, stb. találhatóak és az űrfelvétel gridhálója nem pont a határvonalra illeszkedik. Ebben az esetben a határvonalra eső képelem a szomszédos területek pixelen belüli arányának megfelelően kapja meg a pixelértéket, amely vegyes felszínborítású terület egység spektrális szintézisének felel meg. Ezek a pixelek az ún. spektrálisan vegyes képelemek. Minél nagyobb egy digitális felvétel térbeli felbontása a felszíni homogén spektrális tulajdonságú objektumok méretéhez képest, annál kevesebb területet fednek le a spektrálisan vegyes képelemek.

Az osztályozás során elsősorban a felszín egyedi spektrális tulajdonságú objektumaihoz (endmember, szélsőpont) hasonló területeket keressük és vonjuk azokat egy osztályba.

A legtöbb műholdfelvételen (multi vagy hiperspektrális), a radiometrikus feldolgozás után, a pixelek reflektancia értékeket tartalmaznak sávonként. Így az n darab sáv egy n -dimenziós spektrális teret (adattér) feszít ki. A reflektancia értékek 0 és 1 közé esnek (vagy 0 és 100 %), vagyis a spektrális térben a műholdfelvétel összes pixele egy n -dimenziós, egységnyi oldalhosszúságú kockában helyezkedik el.

Ha a pixelértékek sávonkénti eloszlása normál eloszlást mutat, akkor a képelemek a spektrális térben egy n -dimenziós ellipszoid belsejében helyezkednek el, úgy, hogy az ellipszoid tengelyeinek metszéspontjában az átlagpixel (osztályközep) található, mely a leggyakrabban előforduló képelem. A középpontból kifelé haladva a gyakoriság csökken.

A változatos felszínborítás, vagy akár egy táblán belüli inhomogenitások miatt a pixelértékek sávonkénti eloszlása rendszerint nem normál eloszlású, így a pixelek a spektrális térben elszórtan, több kisebb-nagyobb csoportban helyezkednek el.

A spektrális tér az euklideszi tér tulajdonságaival rendelkezik. Kiszámolható két pixel távolsága, amely azt fejezi ki, hogy a két pixel által reprezentált terület spektrális tulajdonságai mennyire hasonlítanak egymáshoz. Minél kisebb a pixelek közötti távolság annál nagyobb a hasonlóság.

A műholdfelvételek képelemei helyhez kötöttek (földrajzi tér) és pixelértékeik fizikai mérések eredményeként jönnek létre. Nagyszámú pixel esetén (pl. Sentinel-2 műhold 1 csempéje 100*100 km-es területet fed le, 10 m-es felbontással $10^4 * 10^4 = 10^8$ db pixelt tartalmaz) a homogén pixelcsoportok lehatárolása a földrajzi térben vizuális interpretációval nem lehetséges, ezért szükséges a térbeli információt automatikus (nem irányított) vagy irányított osztályozási módszerekkel feldolgozni.

1. Automatikus osztályozás (*Unsupervised training*)

Az ún. *unsupervised classification*, **nem irányított osztályozás** csak minimális beavatkozást igényel a felhasználó részéről, de az osztályozás eredményét, az osztályokat megjelenítő térképet a felhasználónak kell értelmeznie, és az osztályoknak nevet adni, összevonni ha szükséges, stb.

A nem irányított osztályozást, **klaszterezésnek** (clustering) is nevezik, mert a módszer a spektrális térben lehatárolható pixelcsoportok kialakítására törekszik. Ezeket a **pixelcsoportokat, amelyek a statisztikai értelemben hasonló pixeleket tartalmazzák, klasztereknek hívják.** Az osztályozás után kialakuló csoportokat térképi műveletekkel, GIS funkciókkal összevonhatjuk, elemezhetjük, illetve felhasználhatjuk a supervised osztályozásban mint a tanulóterületek.

2. K-Means Klaszter Analízis és az ISODATA klaszterezés

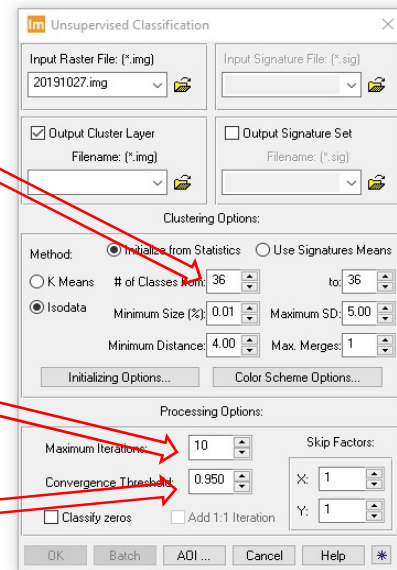
A K-Means és az ISODATA klaszterezési módszer a spektrális távolságot használja a csoportok elkülönítésekor, iteratív módon újraosztályozza a pixeleket, vagyis újraértelmezi a kritériumokat minden osztályra minden döntéshozás előtt, így a spektrális távolságon alapuló csoportok egyre finomodnak, egyre jobban reprezentálják az egymáshoz hasonló tulajdonságú képelemeket.

A K-Means osztályozás neve utal a klaszterek számára (k), mint induló paraméterre. Az ISODATA osztályozás neve az *Iterative Self-Organizing Data Analysis Technique* (Gonzalez és Tou, 1974) kifejezés rövidítése, jelentése: Ismétlődő önszervező adatelemző módszer. Ismétlődő (iteratív), mert a teljes klaszterezést megismétli, amíg az eredmény meg nem felel a követelményeknek, és létrehozza a tematikus raszterréteget, s újraszámítja annak statisztikáját. Mindkét eljárás önszervező, mert minimális felhasználói segédlet szükséges a klaszterek kijelöléséhez, a döntéshozás módszere mindkét esetben a legközelebbi szomszéd (*Nearest Neighbour*) vagy minimális távolságok (*Minimum Distance*) módszere. A két klaszterezés közötti nincs jelentős eltérés, inkább a különböző képfeldolgozó szoftverekben van különbség a parametrizálásban. Pl. az ERDAS 2020 Imagine szoftverben a K-Means klaszterezés során az induló k db klaszterközép elhelyezése átlósan vagy a főkomponens tengely mentén történik, míg a SNAP programban a K-Means klaszterezés első lépéseként a megadott számú klaszterközépet véletlenszerűen helyezi el a program. Az induló klaszterszám nem változik a klaszterezés végére. Az ISODATA klaszterezésnél (az ERDAS 2020 Imagine programban) a klaszterközépeket indulásként elhelyezhetjük az adatkocka átlóján vagy az első főkomponens tengely mentén és megadhatók olyan további paraméterek (küszöbértékek), melyek alapján bizonyos klaszterek eltűnhetnek, vagy két klaszterre osztoznak.

Az osztályozás döntéshozó módszere a **minimális spektrális távolságok módszere.** Az osztályozás meghatározott számú klaszter átlagértékének (klaszterközépének) a megadásával kezdődik (beleértve akár a már létező parametrikus tanulóterületek alapján számított osztályközépeket is), és ez ismétlődik, úgy hogy a klaszterközépek folyamatosan módosulnak egy új pixel osztályba sorolása után.

3. A klaszterezés paramétere

- k a klaszterek maximális száma. Minden klaszter a későbbi osztályt fogja meghatározni, így a klaszterek száma megadja az osztályok maximális számát is. Minden ISODATA osztályozási folyamat k klaszterközép meghatározásával kezdődik. Kevés pixelt tartalmazó klaszterek megszűnhetnek, ezért kevesebb, mint k klaszter marad.
- M - az iterációk maximális száma.
- T - konvergencia küszöb, amely megadja, hogy a pixelek hány százaléka maradhat változatlan két egymást követő iteráció eredményét összehasonlítva.



Ábra 1. Klaszterezés paramétere

4. Kezdő osztályközepek helyének meghatározása

Az algoritmus az első iterációban először a k klaszter átlagértékét helyét határozza meg a spektrális térben. Minden egyes iteráció után, az új klaszterközepeket határoz meg az aktuális klaszterbeli pixelek szerint (átlagszámítással). Ezeket a klaszterközepeket használja a következő iterációban a klaszterek meghatározásához. Ez a folyamat addig folytatódik, amíg az iterációk eredménye között nagyon kicsi különbség nincs (Swain, 1973).


A spektrális térben a kezdő klaszterközepek helyét megválaszthatjuk a következőképpen:

- a, véletlenszerűen
- b, átlósan (*diagonal axis*) az adatkockában
- c, főkomponens tengely mentén (PCA)

Az átlósan elhelyezett kezdő klaszterközepek a spektrális térben egy vektor mentén helyezkednek el, mely két végpontjának spektrális térbeli koordinátái az n -dimenziós térben:

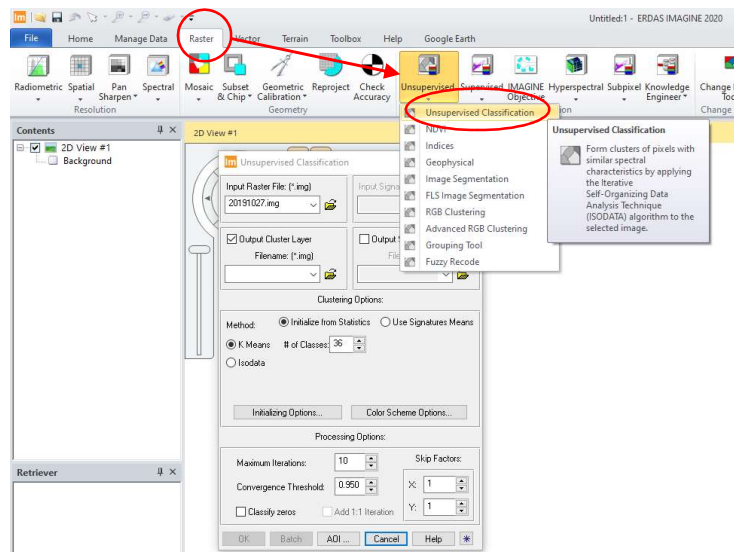
$$(\mu_1 - s_1, \mu_2 - s_2, \dots, \mu_n - s_n), \text{ ill. } (\mu_1 + s_1, \mu_2 + s_2, \dots, \mu_n + s_n).$$

Kétdimenzióban a kezdő klaszterközepek az $A(\mu_1 - s_1, \mu_2 - s_2)$ és $B(\mu_1 + s_1, \mu_2 + s_2)$ pontok között helyezkednek el.



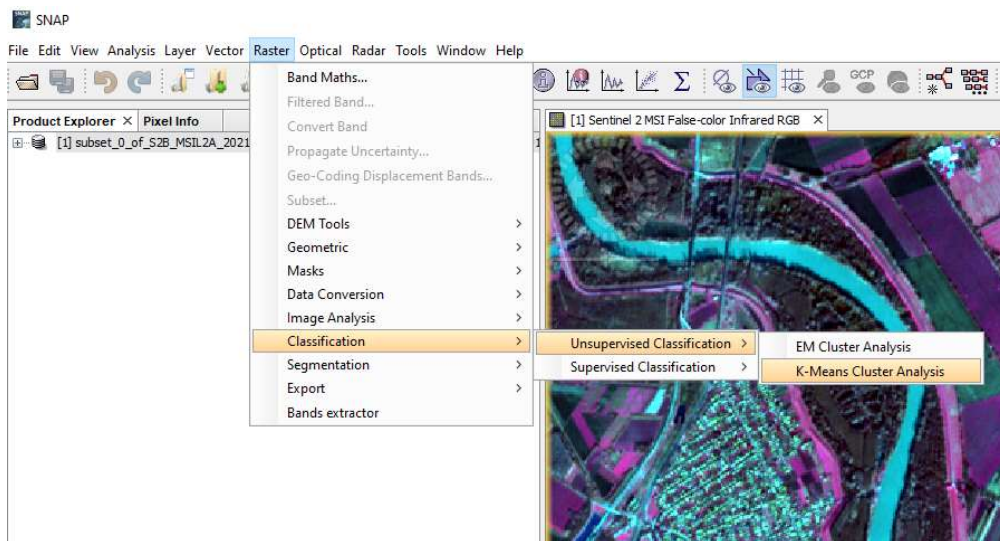
Ábra 2. Induló klaszterközepek elhelyezkedése a spektrális térben

ERDAS 2020-ban válasszuk a **Raster** főmenüből az **Unsupervised** gördülő menüt és abban kattintsunk az **Unsupervised** parancsra.



Ábra 3. Nem irányított osztályozás indítása ERDAS 2020 programban

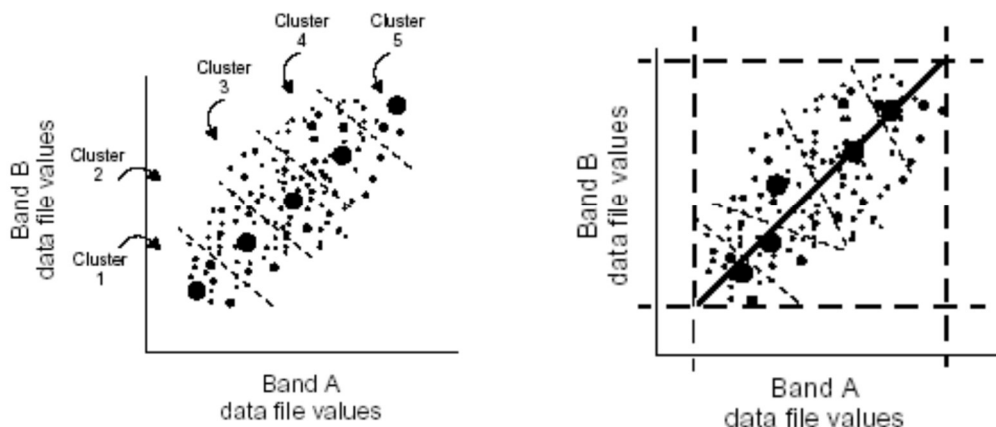
A SNAP programban a **Raster** főmenüben válasszuk a **Classification** almenüt és azon belül az **Unsupervised Classification** opciót. A két automatikus klaszterezés közül válasszuk a **K-Means Cluster Analysis** eljárást.



Ábra 4. Nem irányított osztályozás indítása SNAP (v8.0) programban

5. Döntéshozás - pixelek klaszterbe sorolása

A pixeleket egyenként soroljuk valamelyik klaszterbe a bal-felső sarokban lévő pixellel kezdve, majd soronként sorra kerül minden pixel. A pixel és a klaszterközepek térbeli távolságait kiszámítja az algoritmus és a pixelt ahhoz a klaszterhez rendeli, mely közepéhez a pixel legközelebb van a spektrális térben. A klaszterezés eredménye egy tematikus raszterréteg és/vagy egy tanulóterület file. Az első iteráció eredménye hasonló a következő képhez.



Ábra 5. Klaszterek az 1. iteráció után és klaszterek a következő iteráció után (Az induló klaszterközepek elmozdultak a sűrűbb adatcsomók közepe felé)

A második iteráció során minden klaszter átlagértékét újraszámítja az algoritmus és pixeleket hozzárendeli a legközelebbi klaszterközéphez. Mindegyik iteráció után megtörténik az adott és az előző iteráció eredményének összehasonlítása. Amennyiben az azonos klaszterbe sorolt pixelek aránya meghaladja az előre definiált küszöbértéket (konvergencia küszöböt), akkor az algoritmus befejeződik. Ha nem, akkor az eljárás folytatódik addig, amíg a konvergencia küszöböt el nem érjük.

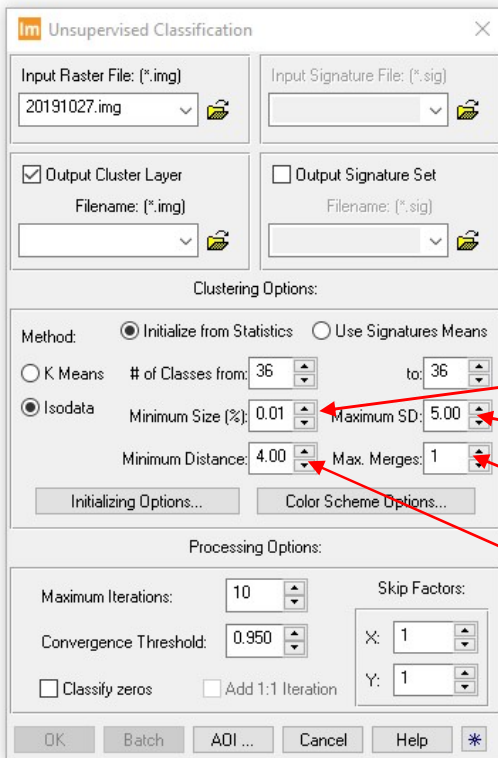
Lehetséges, hogy a változatlan pixelek százalékos aránya sohasem éri el ezt a küszöbértéket, ezért az iterációk számának (M) rögzítésével megakadályozható, hogy a program a végtelenségig fusson.

<i>K Means vagy ISODATA klaszterezés</i>	
<i>előnyök</i>	<i>hátrányok</i>
Iteratív	A klaszterezés sokszor ismételtető ezért időigényes művelet.
Ez az algoritmus nagyon alkalmas az egynemű adatokat tartalmazó spektrális klaszterek megtalálására. Nincs jelentősége, hogy a kezdő klaszterközepek hol helyezkednek el, ha elég sok iteráció engedélyezett	Nem veszi figyelembe a pixel térbeli homogenitást.
A kimenő tematikus raszterréteg hasonló a tanulóterületek alapján, a minimális távolságok módszerét alkalmazó osztályozás eredményéhez. Ezt a tematikus raszterréteget elemezhetjük és kezelhetjük a tanulóterületek szerint mielőtt az aktuális klasszifikációt végrehajtanánk.	

6. A klaszterezés eredménye

A klaszterezés eredménye egy klaszterkép. Minden pixel értéke egy pozitív egész szám lesz. Az egész szám lesz az adott klaszter kódja (n az n-edik klaszteré). Spektrális térben egymáshoz közel lévő (hasonló) pixelekből álló klaszter elemei a földrajzi térben bárhol elhelyezkedhetnek. A K-Means klaszterező eljárást akkor érdemes használni, ha pontosan ismerjük a lehetséges klaszterek számát, hiszen az K-Means eljárásban nem csökken a klaszterek száma.

Az ISODATA eljárásban különböző parametrizálással változhat a klaszterek száma.



Minimális klaszterméret (az összes pixel arányában)

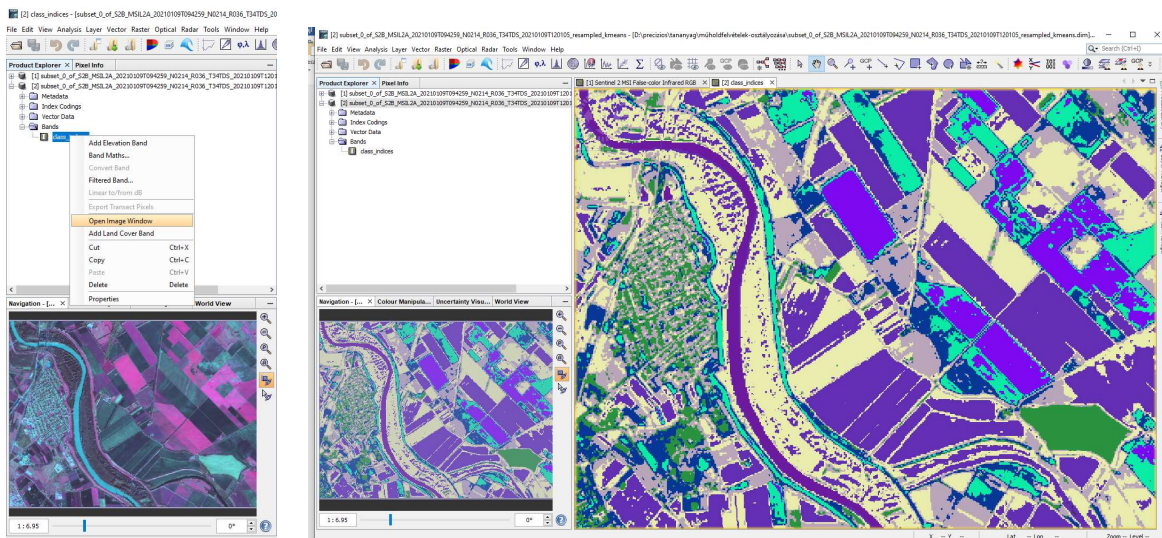
A klaszteren belüli pixel értékeinek maximális szórása (nagyobb szórású klaszter kettéválí két klaszterre)

A klaszterösszevonások maximuma iterációnként

A klaszterközepek minimális távolsága (közelebb lévő klaszterek összevonódnak)

Az eredmény klaszterterkép mindig egy egyrétegű állomány, melyet szürkeárnyaltos vagy hamis színes tematikus réteggént tudunk megjeleníteni.

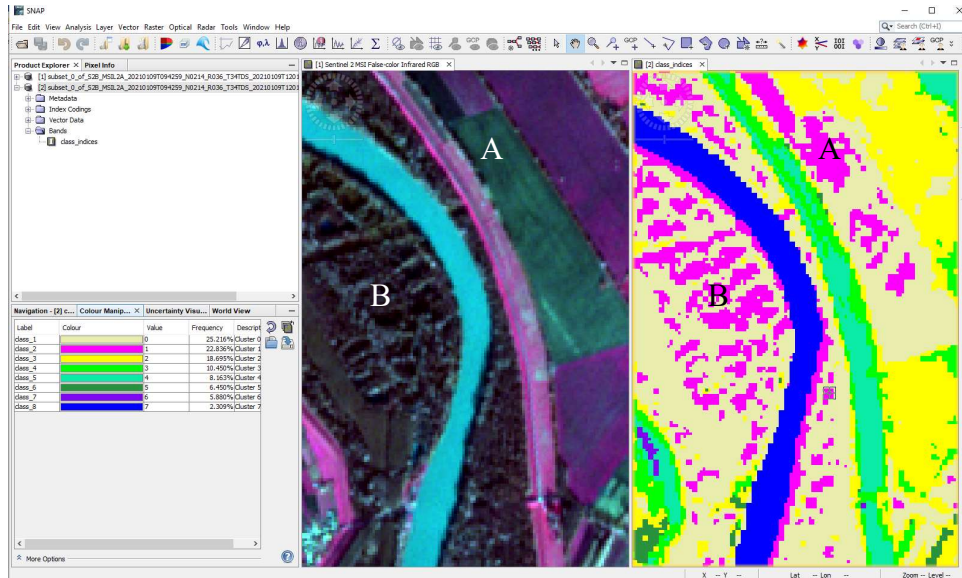
A SNAP programban a klaszterezés eredményét megnyithatjuk az **Open Product** ikonra kattintva. Nyissuk le a betöltött kép melletti – gombra kattintva a kép állományait és a **Bands** könyvtárban válasszuk az egyetlen réteget (*class_indices*).



Ábra 6. Egyrétegű klaszterterkép megnyitása és megjelenítése a SNAP View ablakban

Ha kevesebb klaszterközeget adunk meg induló paraméterként, mint ahány klaszter valójában létezik, akkor egy eredmény klaszter több valós klasztert is tartalmazhat. Ebben az esetben már nem tudjuk tovább bontani azt a klasztert, ami több valós klasztert tartalmaz, hiszen a tematikus rétegben ugyanaz a pixelérték (kód) jelenik meg a valós klaszterek területén.

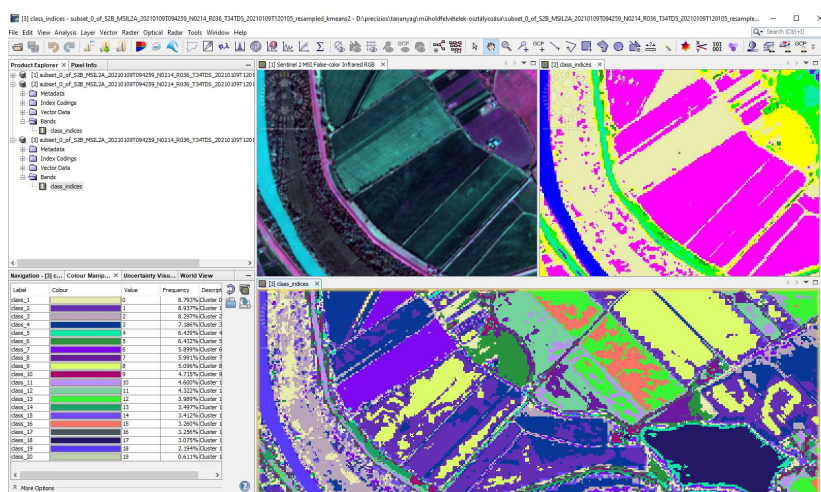
Az alábbi képen látható, hogy a mentett oldali terület (A –nyílt talajfelszín) ugyanabba klaszterbe tartozik, mint az ártéri erdő terület (B)



Ábra 7 Hamis színes 843 (RGB) műholdfelvétel kompozíció és a 7 klasztert tartalmazó klaszterkép

Ha a valós klaszterszámnál több induló klasztert adunk meg, akkor az eredményklaszterek nem reprezentálják teljességükben a valós osztályokat. Több eredményklaszter összevonásával (átkódolás) kaphatjuk meg a valós klasztert.

Az alábbi ábrán egy 7, ill. 20 induló klaszteres osztályozás eredményét láthatjuk. A 7 klaszteres osztályozásban még homogén táblán belül a 20 klaszteres osztályozás eredményeként több klaszter is megjelenik.



Ábra 8 Egy 7, ill. 20 induló klaszteres osztályozás eredményei SNAP programban megjelenítve

Ellenőrző kérdések:

1. Mi a különbség a K-Means és az ISODATA klaszterező eljárás között?
2. Mi jelent a konvergencia küszöb és mit szabályoz?
3. Milyen módszerekkel határozhatjuk meg az induló klaszterközepek helyét a spektrális térben?
4. Milyen paraméterekkel szabályozhatjuk a klaszterezés eredményét?
5. Mi történik akkor, ha két klaszterközép nagyon közel van egymáshoz?
6. Lehet-e nagyobb a klaszterek száma az eredménytérképen, mint az induló klaszterszám?
7. Mi az előnye az ISODATA klaszterezésnek?
8. Mi a hátránya az ISODATA klaszterezésnek?
9. Mi az eljárás, ha egy eredményklaszter több valós klasztert is lefed a spektrális térben?
10. Mi az eljárás, ha több eredményklaszter egy valós klasztert fed le a spektrális térben?

Forrás:

- https://hexagongeospatial.fluidtopics.net/r/uOKHREQkd_XR9iPo9Y_Ijw/6AblsqhovZCI4DnLAbSzsw
- SNAP Unsupervised Classification – Online Help

Jelen tananyag a Szegedi
Tudományegyetemen
készült az Európai Unió
támogatásával.
Projekt azonosító: EFOP-
3.4.3-16-2016-00014

SZÉCHENYI 2020



MAGYARORSZÁG
KORMÁNYA

Európai Unió
Európai Szociális
Alap



BEFEKTETÉS A JÖVŐBE