



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Alba Regia Műszaki Kar

Geoinformatikai/Mérnöki/
Természettudományi és Szoftvertchnológiai Intézet

SZAKDOLGOZAT

Különböző felbontású műholdas felvételek osztályozási pontosságának vizsgálata

OE-AMK

Hallgató neve: Bánáti Benedek

2022

Hallgató törzskönyvi száma: T000557/FI12904/A-G



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Alba Regia Műszaki Kar

Geoinformatikai/Mérnöki/
Természettudományi és Szoftvertchnológiai Intézet

HALLGATÓI NYILATKOZAT

Alulírott hallgató kijelentem, hogy a szakdolgozat/diplomamunka saját munkám eredménye, a felhasznált szakirodalmat és eszközöket azonosíthatóan közöltem. Az elkészült szakdolgozat/diplomamunkában található eredményeket az egyetem és a feladatot kiíró intézmény saját céljára térítés nélkül felhasználhatja, a titkosításra vonatkozó esetleges megkötések mellett.

Kelt: 2022.12.21

.....
hallgató aláírása



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Óbudai Egyetem
Alba Regia Műszaki Kar
Geoinformatikai Intézet

SZAKDOLGOZAT FELADATLAP

Hallgató neve: Bánáti Benedek
Szakdolgozat száma: SZD22011414094118
Törzskönyvi száma: T000557/FI12904/A-G

Neptun kódja: XXXXXXXXXX

Szak: földmérő és földrendező mérnök
Specializáció: Geoinformatika specializáció

A dolgozat címe: Különböző felbontású műholdas felvételek osztályozási pontosságának vizsgálata

A dolgozat címe angolul: Accuracy assessment of satellite image classification

A feladat részletezése:

1. A szakirodalom alapján foglalja össze:
 - a) a jelenleg elérhető műholdas felvételek tulajdonságait
 - b) valamint a digitális képosztályozás módszereit!
2. Egy kiválasztott mintaterületen végezze el a Sentinel 2 felvétel osztályozását különböző módszerekkel.
 - a) input adatok, osztályozandó kategóriák bemutatása
 - b) alkalmazott osztályozási eljárások jellemzése
 - c) eredmények bemutatása
3. Végezze el a pontosság vizsgálatot!
4. Foglalja össze a pontosság vizsgálat eredményeit, vonja le a következtetéseket!

Intézményi konzulens neve: Verőné Dr. Wojtaszek Malgorzata Mária

A kiadott téma elévülési határideje: 2024. 12. 15.

Beadási határidő: 2022. 12. 15.

A szakdolgozat: Nem titkos.

Kiadva: Székesfehérvár, 2022. 10. 12.



P.H

[Handwritten signature]

Intézetigazgató

A dolgozatot beadásra alkalmasnak találom: 2022. 12. 15.

[Handwritten signature]

belső konzulens

külső konzulens

Tartalomjegyzék

1.	Bevezetés.....	5
2.	Műholdas felvételek jellemzői	6
2.1	Térbeli felbontás.....	6
2.2	Spektrális felbontás	8
2.3	Radiometriai felbontás	10
2.4	Időbeli felbontás.....	10
3.	A digitális képosztályozás módszerei.....	11
4.	Osztályozási módszerek összehasonlítása	14
4.1	Ellenőrzött osztályozás.....	14
4.1.1	Minimum distance	14
4.1.2	Maximum-likelihood	15
4.2	Automatikus osztályozás.....	16
4.2.1	Klaszter:.....	16
4.2.2	ISODATA	17
4.3	Szegmens alapú osztályozás.....	17
5.	A kiválasztott terület jellemzése.....	19
6.	Sentinel és IDRISI.....	21
7	. Osztályozási módszerek alkalmazása a kijelölt területen.....	23
7.1	Szegmentálás és tanulóterületek.....	23
7.2	Minimum Distance osztályozás	25
7.3	Maximum Likelihood.....	27
7.4	Isodata	28
7.5	Klaszter.....	29
7.5.1	Broad Klaszter.....	29
7.5.2	Fine Klaszter.....	30
8.	Pontosságvizsgálat.....	31
8.1	Minimum distance hibamátrix	33
8.2	Maximum Likelihood hibamátrix.....	33
9.	Rövid tartalmi összefoglaló.....	39
10.	Angol nyelvű összefoglaló	40
11.	Irodalomjegyzék.....	41

1. Bevezetés

A regionális földhasználat és földborítás térképek elkészítéséhez a mai napig szükség van katasztrófamegfigyeléshez, tájtervezés, a terület alkalmasságának elemzésénél, erőforrás gazdálkodásnál és ökológiai tanulmányok esetén. A képosztályozás egyfolyta pixelérték kategorizálás, melynek segítségével értékes információkat nyerhetünk ki a nagyfelbontású műholdfelvételekből. A képosztályozás a földfelszín különböző spektrális jellemzőit használja fel. A pontosság értékelése minden osztályozási projekt lényeges szegmense a távérzékelésben. Ez az összehasonlítását jelenti egy besorolt képnek egy másik, pontosnak tekintett adatforrással esetleg alapadattal. A pontosság ellenőrzése azért fontos, mert a távérzékelés adatokat sok esetben használják feltérképezésre, valamint környezeti modellek bővítésére, amelyeket irányítási, továbbá döntéshozatali célokra használnak. Erre a folyamatra a gyorsuló éghajlatváltozás- és az energiaforrások, valamint környezetünk kihasználása- miatt nagy szükség van. A távérzékelés olyan adatnyerési eljárás amely során a földfelszíni objektumok egyes tulajdonságairól úgy juthatunk adatokhoz, hogy nem kerülünk közvetlen kapcsolatba a vizsgált tárggyal. Az adatnyerés elektromágneses energia közvetítésével következik be. A távérzékelésnek két lépése van. Az egyik az objektumról az elektromágneses hullámok által közvetített adatok valamilyen távolságból történő érzékelése, a másik pedig az észlelt, valamint rögzített adatok feldolgozása, értelmezése. A különféle hullámhosszú elektromágneses energia az atmoszférán keresztül terjed természetes, esetleg mesterséges forrásokból. A földfelszínre jutva kölcsönhatásba kerül a felszínen elhelyezkedő objektumokkal. Az ennek következtében módosult energia útja a felvevő berendezésig vezet az atmoszférán keresztül. Itt az energiamennyiség mérése, rögzítése valamint a földi vevőállomásra való továbbítása következik be. A távérzékeléshez a Kopernikusz program műholdjai kínálnak információs szolgáltatásokat. A Kopernikusz az Európai Unió Föld-megfigyelési programja. Műholdjai folyamatosan megfigyelik a Földet és helyszíni adatokon alapuló információs szolgáltatásokat kínál az európai polgárok érdekében. A program irányítása az Európai Bizottság feladata. Óriási mennyiségű széleskörű, a műholdak által nyert, továbbá a szárazföldi, légi, és tengeri mérőrendszerekből származó adat kerül fogyasztásra olyan adatok biztosítására, amik támogatásával a vállalkozások, hatóságok, továbbá egyéb nemzetközi szervezetek javítani tudják az európai lakosok életminőségét. Ezek az információs szolgáltatások szabadon és nyíltan hozzáférhetők a felhasználók számára. [1] A misszió információt szolgáltat a mezőgazdaságnak, erdőgazdálkodásnak és az élelmiszerbiztonságnak is. A műholdak figyelemmel követik a felszínborítás változását, monitorozzák a Föld erdőit és tavait, továbbá a tengerparti vizek szennyeződését, árvizek elöntéseit. Képesek feltérképezni a természeti katasztrófák okozta károkat: vulkáni tevékenységeket, földmozgásokat. A program így nagymértékben hozzájárul a klímaváltozás és a veszélyhelyzet-kezeléshez szükséges adatok előállításához. Összesen hét fajta műhold vizsgálja bolygónkat a Kopernikusz által. Ezek a Sentinel nevet kapták. Kiemelendő a Sentinel-2 mivel ezek szolgáltatják a


nagy felbontású optikai felvételeket a szárazföld-monitoring szolgáltatásokhoz. Ez biztosít felvételeket belvízi utakról, tengerparti övezetekről, de ami a legfontosab, a vegetációról. Szenzorai 13 különböző sávban képesek felvételeket rögzíteni. Méréseim során ennek a műholdnak a felvételeivel fogok dolgozni mivel a kiválasztott terület szárazföldi. Szakdolgozatomban szülővárosom, Zalaegerszeg műholdas felvételeit felhasználva különböző, pixel és szegmens alapú osztályozási módszereket fogok összehasonlítani. Az összehasonlítás következtével számos szempont alapján kiértékelem az egyes módszereket hatékonyságukat elemezve. Az algoritmusokat úgynevezett hibamátrix táblázatban fogom ábrázolni, ahol leolvasható lesz majd az osztályozás pontossága.

2. Műholdas felvételek jellemzői

A felvételező rendszereket három alapvető kategória: a térbeli, a spektrális és az időbeli tulajdonságaik szerint jellemezhetjük. Az egyes kategóriák paraméterei meghatározott technikai és gazdaságossági összefüggésben állnak egymással; a felvételező rendszerek fejlődése mellett sem lehet függetlenül kezelni őket. [2]

2.1 Térbeli felbontás


A térbeli felbontás leírja a geometriai kapcsolatot a digitális felvétel pixeljei és az általuk ábrázolt területegységek között. A digitális kép egy kétdimenziós pixeltömb. Minden pixelnek van egy intenzitás értéke melyet egy digitális szám jelöl és egy pozícióértéke (melyik oszlop hányadik sora).[3]



1. ábra Térbeli felbontás

A teljes felvétel által lefedett területdarab nagyságát a területi lefedés jelenti. Permanens felvételezés esetekor a haladási iránnyal megegyezően bármekkora távolságot bejárhatunk, ebben az irányban a felvételezésnek nincsenek határai. Egy feldolgozási egységnek vehető jellemzően a pászta szélességével egyenlő hosszúságú képdarab. Ezt szokás képeretnek is nevezni. A területi lefedés jellemző módon 16km x 16 km (szuperfelbontású felvételek) továbbá 2500km x 2500km (kisfelbontású felvételek) között mozog. A térbeli felbontás azt a legkisebb megkülönböztethető felületet írja le a Föld felszínén, amely egy pixelnek felel meg. Ezt hívják Instantaneous Field of View azaz IFOV-nak. A rögzítés során tulajdonképpen szabályos rácstra osztjuk a felületet, ahol a rácselemek az alapfelületi blokkoknak felelnek meg. Az alkalmazásban úgy szükséges

kiválasztani a rögzítési típust, hogy a pixelméret megegyezzen a mérni kívánt objektum méretével. Figyelembe szükséges azonban venni, hogy a pixelméretnél kisebb objektumok sok esetben észrevehetők a légi felvételeken (kellően nagy kontraszttal), hiszen ezek kisugárzása is hozzáad az egyes pixelek által összegyűjtött sugárzási értékhez. A pixelméret a gyakorlatunkban megjelenő felvételeknél nagyjából $0,5\text{m} \times 0,5\text{m}$, ezen kívül $1\text{km} \times 1\text{km}$ közé esik, a leggyakrabban megjelenő úgynevezett nagyfelbontású felvételek esetében $10\text{m} \times 10\text{m}$, továbbá $30\text{m} \times 30\text{m}$ körüli. A passzív szenzorok térbeli attribútumai elsődlegesen az IFOV-tól függenek.




2. ábra Passzív szenzorok térbeli attribútumai

Az IFOV – ot (A) definiálhatjuk úgy mint a szög amely az általa érzékelhető minimális területet zárja be. A (B) a pixel mérete a mérési távolságtól (C) függ, ez a repülési magasság. Ezek kapcsolatából egy egyenlet írható fel amely IFOV (α), térbeli felbontás(d) és repülési magasság-ból (h) áll.

$$\alpha = d/h$$

A pixel rendelkezik egy számmal amely azt jelzi átlagosan mennyi energiát nyelt el, esetleg vert vissza különféle felületekről abból a területről amelyet az adott pixel reprezentál. A térbeli felbontás egyik problémája a legkisebb objektumok (melyek még érzékelhetőek a szenzorral) kevert pixelei. (mixed pixels). A pixel homogenitása érdekének megfelelően az objektumméretének meg szükséges egyeznie a felbontással, esetleg nagyobbak lennie. A pixel rendelkezik egy számmal amely azt jelzi átlagosan mennyi energiát nyelt el, esetleg vert vissza különféle felületekről abból a területről amelyet az adott pixel reprezentál. A térbeli felbontás egyik problémája a legkisebb objektumok (melyek még érzékelhetőek a szenzorral) kevert pixelei. (mixed pixels). A pixel homogenitása érdekének megfelelően az objektumméretének meg szükséges egyeznie a felbontással, esetleg nagyobbak lennie.




3.ábra valóság és digitális kép felbontása

Minél kisebb a kép felbontása a pixelek annál jobban elmosódnak.

2.2 Spektrális felbontás

A spektrális felbontás determinálja a digitális felvétel pixelértékei, ezen kívül a felvételezett területről érkező, hullámsávtól függő sugárzási értékek közti kapcsolatot. A spektrális felbontás determinálja a rögzített sávok számát, az elektromágneses spektrumban elfoglalt helyét, ezen kívül szélességét. Ezekből a paraméterekből a teljes lefedett sávtartomány leolvasható. Két (azonos hullámsáv-tartományt lefedő) felvételtípus közül azt tekintjük nagyobb spektrális felbontásúnak, amelyik több részre osztja ugyanazt a hullámsáv-tartományt.[2] Egy adott alkalmazáshoz a rögzítés típusának kiválasztásakor lényeges, hogy spektrálisan alkalmas legyen a megfigyelt fizikai jelenség részleteinek rögzítésére. Az érzékelő a bemenő energiát számokká alakítja (intenzitásérték, sávérték). A radiometriai felbontás a kvantifikáció finomságát fejezi ki: több energiaszint magasabb radiometriai felbontást jelent. A megkülönböztethető energiaszintek számát két szempont determinálja. Egyrészt korlátozzák a technikai lehetőségeket, példának okáért az érzékelő anyagát, valamint szerkezetét, ezen kívül a hozzá tartozó analóg/digitális átalakító érzékenységét. Másrészt érdemes az energiaszintek számát a zajszint-érzékenység alatt tartani, hogy a sávértékek eltéréseit ne véletlenszerű zaj determinálja, hanem a Föld felszínét elhagyó sugárzás jelentős különbségei legyenek. Ez a paraméter 7-8 bittől 10-12 ig terjed. A leggyakrabban használt nagyfelbontású multispektrális szenzoroknál jellemző a 7-8 bites felbontás, amely 128, valamint 256 intenzitás szintnek felel meg.




4. ábra Az elektromágneses spektrum

[https://commons.wikimedia.org/wiki/File:EM_spectrum_hu.svg] (Philip Ronan, Gringer, 2013)

Az elektromágneses spektrum a rövidebb hullámhosszoktól (gamma sugár, röntgen) a hosszabbakig terjed (mikrohullám, rádióhullám). A spektrum számos területe használható távérzékeléshez. A passzív távérzékelés a látható tartományoktól az infravörös részekig terjed a spektrumon. A spektrum nem minden része felel meg a távérzékeléshez. A legfontosabb kritérium a spektrum tartományainak hogy benne kell lenniük az atmoszferikus ablakban.

A digitális területi fényképek jellemzően az elektromágneses spektrum látható részében (VIS) készülnek, ezen kívül néha az infravörös (NIR) tartományban kamerától függően. Az ábra bemutatja a különféle színekben a sávokat. Jól látható rajta, hogy a közeli infrared tartományban operáló szenzorok lehetővé teszik a talajborítás jobb megkülönböztetését különösen a növényzet vegetációja esetekor.



5. ábra Hullámhossz visszaverődés különböző felszínborításokon

2.3 Radiometriai felbontás

A radiometriai felbontás a kvantálás finomságát jelzi: a nagyobb energiaszint nagyobb radiometriai felbontást jelent. A megkülönböztethető energiaszintek számát két szempont determinálja. Egyrészt, korlátozzák a technikai lehetőségek, pl. a szenzor anyaga, felépítése, valamint a hozzá kapcsolt analóg/digitális-átalakító érzékenysége. Másrészt, az energiaszintek számát érdemes a zajszintérzékenység alatt tartani, hogy a sávértékek eltérését ne a véletlen zaj determinálja, hanem érdemi, szignifikáns különbséget jelentsen a földfelszín elhagyó sugárzásban. Ez a paraméter kevésbé változékony: 7-8 bittől 10-12 bitig terjed. A legelterjedtebben használt nagyfelbontású multispektrális szenzoroknál jellemző a 7-8 bites felbontás, amely 128, valamint 256 intenzitás szintnek felel meg. A nagyobb radiometriai felbontáshoz (10-12 bit: 1024-4096 szint) térbeli felbontásban a skála két vége tartozik, vagyis a kislebontású, valamint a szuperfelbontású felvételek csoportja.

2.4 Időbeli felbontás

Az időbeli felbontás azokat a felvételezéshez, valamint az adattovábbításhoz, előfeldolgozáshoz kapcsolódó jellemzőket jelentik, amelyeknél az idő dimenziója játszik szerepet. A visszatérési idő adja meg, hogy a rendszer milyen gyakran tud ugyanarról a területről felvételt készíteni. Ez a miliőben lejátszódó mechanizmusok monitorozása vonatkozásában lehet fontos. Az eltérő mechanizmusok igen eltérő igényt támasztanak ezzel a jellemzővel szemben: egy árvíznél gyakorlatilag óráról órára szükséges követni

az előntést, az aszály monitorozásánál 2-3 naponta szükséges egy-egy űrfelvétel, míg növényterképezési alkalmazásoknál évente (a vegetációs időszakon belül) összesen 4-5 felvétel is elég a megfelelő pontossághoz. A visszatérési idő definíciójánál megkülönböztetjük az alábbi két esetet: A célterületnél a felvételezés geometriája is megegyezik az egymást követő felvételeknél. A terület a felvételnek ugyanazon a részén, a műhold földre vonatkozó merőleges vetületéhez mérten ugyanannyival eltolva található. A geometria nem egyezik meg: az egymás utáni felvételeken eltérő pozícióban, eltérő felvételezési geometriával látszik a terület. A visszatérési idő csökkenthető azáltal, ha az egész érzékelőt el lehet fordítani a repülési irányra merőlegesen esetleg azzal párhuzamosan, így az egyszerre felvételezett pászta helyzete változhat a műhold merőleges vetületéhez viszonyítva. A kisfelbontású holdak akár naponta több felvételt is készítenek ugyanarról a területről (nem feltétlenül ugyanazzal a geometriával), a nagyfelbontású holdak tipikus visszatérési értéke 16-24 nap. Szuperfelbontású felvételeknél szükség szerint programozással a visszatérési idő akár pár nap is lehet, de gazdaságossági korlátokat is figyelembe véve egy területről évente jellemző módon nem készül egynél több felvétel. Az időkritikus alkalmazásoknál releváns a felvételezett adatokhoz való hozzáférés ideje, vagyis hogy a felvételkészítéstől mennyi idő telik el, amíg az adatok a felhasználóhoz jutnak. A leggyorsabb mód, ha a felhasználó azonnal letölti a műholdról a vett adatokat rádiókapcsolaton keresztül. A jelenleg üzemelő műholdak többségénél viszont az a jellemző, hogy a vett adat egy-két behatárolt földi vevőállomás valamelyikére kerül, ahonnan a rendszerkorrekció elvégzése után továbbítják a felhasználóhoz, amely a továbbítás módjától függően 1-2 napot (hálózati átvitel), esetleg 3-5 napot (postai továbbítás) vesz igénybe. Az egyéb tulajdonságok közül itt csupán az árat említjük meg, amelynek megítélésénél nem pusztán egyszerűen egy adott nagyságú területre vonatkoztatott egységárat szükséges figyelembe venni, hanem azt is, hogy a feldolgozás eredményeként várható haszon hogy viszonyul a befektetett pénzösszeghez

3. A digitális képosztályozás módszerei

A távérzékelés alkalmával a vizsgált tárgyról visszavert, esetleg általa kibocsátott energiát többféle módon lehet érzékelni, továbbá rögzíteni. A 0,38 - 0,9 m közötti fotográfikus, továbbá elektronikus képfelvevő rendszerekkel is készíthetők felvételek. A 0,9 m-nél nagyobb hullámhosszakra a fényképezési filmek nem érzékenyek, emiatt az adatrögzítés elektronikus eszközökkel következik be. Fényképezéskor a visszavert elektromágneses energiát egy előre behatárolt hullámhossz tartományra érzékenyített filmre rögzítjük. Az érkező energia a film fényérzékeny rétegén kémiai reakciót vált ki. Ennek eredményét, a képet fotólaboratóriumi eljárások során jelenítik meg. A kép tónusát, esetleg színskáláját, a részletgazdagságát, a kép minőségét az érzékenyített réteg jellemzői, továbbá a használt előhívási technológia együttesen határozzák meg. A fényképezési eljárás rapid,

megbízható, tárgyilagos információgyűjtési módszer, relatíve egyszerű, továbbá olcsó. További előnye jelentős térbeli felbontása. Ezeket a digitális képeket számos módon lehet osztályozni.

A távérzékelte digitális képek feldolgozásának célkitűzése, hogy a többsávos, különféle időpontban, ezen kívül különféle felvevőrendszerekkel készített felvételek alapján a földfelszínt térképezzük, a felszínborítási csoportok minél több ismervét, minél megbízhatóbban becsüljük. A felszínborítási csoportok, továbbá a jellemzők minden feladatban mások. Gyakran a teendő megoldása alkalmával változtatni, összevonni, kiejteni vagyunk kénytelenek őket. A kiértékeléssel szemben támasztott esszenciális követelmények a geometriai-, továbbá tematikus pontosság, a konzisztens, tárgyilagos, valamint megismételhető képosztályozás. Összehasonlítva a vizuális értelmezéssel (interpretáció), a digitális képfeldolgozásról a következők mondhatók el: az interpretációnál geometriai összefüggések, alakok, textúrák felismerése effektív, amíg a digitális képelemzés a tónusok elkülönítésében, az objektivitásban, megbízhatóságban, feldolgozási sebességben, több adatforrás együttes kiértékelésében múlja felül az analóg módszert. Gyakran a két módszert együttesen alkalmazzák, ezen kívül a feldolgozás alkalmával a felhasználó szakembereket is bevonják a munkába.

A kép osztályozása előtt különböző lényegkiemelő, információ sűrítő, vizuális interpretációt segítő, az osztályozás pontosságát növelő eljárást lehet alkalmazni. Ilyen például a filterek alkalmazása amely simíthatja, élesítheti a képeket a „képi zaj” csökkentése és a képi információ fokozása érdekében.

Leggyakoribb osztályozási módszerek:

- A legközelebbi középpontú osztályozás (minimum distance módszer)
- Box osztályozási módszer,
- Maximum likelihood módszer,
- Bayes módszer
- Spektrális adatosztályozás (klaszterezés)

Boksz, azaz paralelepiped módszernél a koordináta tengelyekkel párhuzamos oldalú téglalapok írják le a célkategóriákat. Ez a művelet a következő logaritmuson alapul:

$$L_{ak} \leq x_k \leq H_{ak}$$

ahol az L_{ak} – az „a” osztályra jellemző érték minimuma a k sávban, H_{ak} – az „a” osztályra jellemző érték maximuma a k sávban, x – vizsgált pixel intenzitási értéke „k” sávban. A tanulóterületek átlag értéke és az átlagtól való eltérés határozza meg az osztályra jellemző intenzitás tartományát, valamint a box méretét.

Maximum-likelihood módszer során figyelembe veszi az adott pixelek intenzitásainak gyakoriságát valamint a valószínűség-eloszlását és oda sorolja az adott pixelt amely osztályban ilyen érték gyakrabban fordul elő. Ez a módszer a hibák valószínűségének szempontjából optimális mégis fent állhat a lehetőség hibák elkövetésére. A tévesen beütemezett pixel a gyakorlati alkalmazásban veszteséget hoz a felhasználónak. Ha azt szeretnénk, hogy az osztályozási hibából létrejött veszteség a legminimálisabb legyen

akkor a Bayes-döntést kell alkalmaznunk. Altalában célszerű a maximum-likelihood eljárás után a Bayes osztályozást alkalmazni.

3.1 Spektrális adatosztályozás (klaszterezés)

A felvétel osztályozásakor a kép pixeleit, az intenzitási érték alapján tematikus kategóriákba soroljuk. Az egyes tematikus osztályok pixelei az intenzitástérben csoportosulnak, ezen kívül elkülöníthetők egymástól. Ezeket az adatcsoportokat klasztereknek nevezzük. A természetben gyakran előforduló, hogy egy tematikus osztályon belül is több adatcsoportosulás lép fel. Ennek oka, hogy adott kategória (pl. búzával fedett tábla) különbözőképpen veri vissza az elektromágneses energiát, hiszen a növény fejlődése a búza fajtájától, a talaj állapotától (talajtípus, az erózió fokozata) a megelőző esőktől, a vetés időpontjától, satöbbi függ. Így egy tematikus kategória több homogén, spektrálisan hasonló csoportra (klaszterre) bontható. Egy tematikus osztály több spektrális adatosztályból áll, de inverz eset is előfordulhat, amikor ugyanaz a spektrális osztály több tematikus osztályban is megjelenik. Mivel az ide eső felszínborítások spektrálisan nem különböznek, így osztályozási hibákat okoznak. Gyakorlatban nagyon nem gyakori az evidens megfeleltetés, amikor egy spektrális adatosztály egy tematikus osztálynak felel meg. Ennek értelmében a tematikus osztály, ezen kívül spektrális osztály között a következő három viszony állhat fenn:

- egy spektrális adatosztály egy tematikus osztálynak felel meg,
- több spektrális adatosztály egy tematikus osztályt épít fel,
- egy spektrális adatosztály több tematikus osztályban is előfordul
- A képszegmentáció alkalmával a képet egymással összefüggő, homogén, a szomszédoktól elkülönülő területekre osztjuk fel. A multispektrális felvételek

használata esetében a homogenitás kritériumokat egyszerre több sávon alkalmazzák. A szegmensek mérete a processzus elején a behatárolt hasonlósági kritérium küszöbértékétől függ. A szegmensek homogenitása kisebb küszöbérték meghatározásával érhető el. Nagyobb küszöbérték esetében a szegmensekre nagyobb méretű heterogenitás jellemző. Az osztályozáshoz szükséges tanulóterületek definiálása szegmentált képen történik. A továbbiakban a kijelölt szegmensekről, mint tanulóterületekről numerikus adatok gyűjtése következik a tematikus csoportok spektrális jellemzőinek meghatározása céljából. Ezek után a szegmenseken különleges, esetleg pixel alapú osztályozási eljárásokkal végrehajtjuk az osztályozást.

- Ezzel az eljárással növelhető az osztályozás pontossága (a pixel alapú osztályozással összehasonlítva), eredményeként azon felül a térképen – a szegmensek határvonalainak megőrzése mellett - az osztályok közti átmenet egyenletesebb lesz.

4. Osztályozási módszerek összehasonlítása

A fent leírt módszerek közül kiválasztottam 4 olyan módszert amelyek bemutatják az ellenőrzött és automatikus osztályozást, valamint a szegmentálást. Az osztályozási módszereket két szempont szerint is csoportosíthatjuk. Így megkülönböztetünk pixel-alapú és szegmens alapú osztályozást, valamint ellenőrzött és nem ellenőrzött osztályozást.

	Előnyök	Hátrányok
Automatikus osztályozás	-nem kell ismernünk az osztályozott régiót -Az emberi hibalehetőség minimalizálása -Spektrálisan választ el területeket, úgy ahogy az emberi szem nem lenne képes	-A spektrálisan létrejött csoportok nem biztos, hogy tükrözik a keresett eredményeket -A felhasználónak csekély beavatkozási lehetősége van
Ellenőrzött osztályozás	-A felhasználó teljes irányítást kap -A felhasználó javításokat végezhet a képeken	-A tanulóterületek kiválasztása időigényes -Nincs rá lehetőség, hogy azokat a területeket is észleljük amik nincsenek benne a tanulóterületekben

4.1 Ellenőrzött osztályozás

Az ellenőrzött osztályozás, azaz a supervised classification során különböző külső adatokból ismernünk kell a képen található olyan területeket amelyeknél biztosra vehetjük, hogy a kijelölt osztályt képviseli. Ezeket hívjuk tanuló területeknek, melyek minden egyes képkocájához hozzárendelhető egy n dimenziós szűrkeségi érték vektor (n az ugyanarra a pixelre eső (spektrális vagy SAR) csatornák száma):

$$SZ = (sz_1, sz_2, \dots, sz_n)^T$$

Ha a feladat során nagy csatornaszámmal rendelkezne az osztályozási művelet, akkor úgy a vektor dimenzióját csökkentve a feldolgozás számítási igényét is egyaránt csökkenti. Ezt úgy éri el, hogy a megegyező pixelekhez hozzárendelt szűrkeségi értékvektor elemekből kivonás, osztás, lineáris kombinációk segítségével komplex vektorelemeket képeznek. A továbbiak szempontjából azonban a dimenzió csökkentésén kívül nincs elvi jelentősége annak hogy sz elemei eredeti mérésekből vagy azok kombinációiból származnak. [4]

4.1.1 Minimum distance

A minimum distance alapelve, hogy az adott pixel értékének legkisebb távolságra megkeresi az osztálynak átlag intenzitását. Ennél a módszernél minden ismeretlen

pozícióju pixelt a legközelebbi középpontú osztályhoz sorolunk. Minimum distance osztályozási módszernél leginkább az euklideszi vagy a Manhattan-távolság számítását alkalmazzuk.

$$d(x, y) = \sum_{k=1}^n |x_k - y_k|$$

$$d_1(x, y) = \sqrt{\sum_{k=1}^n (x_k - y_k)^2}$$

ahol $d(x, y)$ - Manhattan-távolság, $d_1(x, y)$ - euklideszi távolság, x_k pixel intenzitása a „k” sávban, y_k - átlag értéke „k” sávban. Az algoritmussal egyszerűen jó osztályozási pontosságot érhetünk el.

4.1.2 Maximum-likelihood


„Legnagyobb előfordulási gyakoriság” osztályozás az adott osztályhoz tartozó pixelek intenzitásának gyakoriságát, valószínűségeloszlását veszi figyelembe. Az adott pixeleket abba az osztályba sorolja be ahol a legnagyobb a valószínűsége, hogy ilyen pixel előfordulna. Egy x pixel pozícióját egy n -dimenziós intenzitástérben az X vektor határozza meg, ilyenkor az előfordulási valószínűsége egy k adatkategóriában a következő formula szerint határozható meg:

$$p(\omega_k | \vec{x}) = P(\vec{x} | \omega_k) p(\omega_k) / p(\vec{x})$$

A döntés szabálynak megfelelően X intenzitásvektor ahhoz a k osztályhoz kerül, amelyikhez a legnagyobb valószínűséggel tartozik, vagyis minden l -re teljesül a következő egyenlőtlenség.

$$p(\vec{x} | \omega_k) p(\omega_k) \geq p(\vec{x} | \omega_l) p(\omega_l)$$

A legnagyobb előfordulási valószínűség elvét alkalmazó módszer a normális eloszláson alapul. Azért az osztályra jellemző spektrális tulajdonságok hisztogramját Gauss eloszlás kell, hogy jellemezze. Ennek a módszernek előnye, hogy az osztályozásnál az ún. „priori” súlyozás is figyelembe vehető. A súlyozás értéke az egyes kategóriák által fedett terület és a vizsgált terület nagysága alapján becsülhető. Bár igaz, hogy ez az osztályozási módszer - a hibák valószínűsége szempontjából - optimális, itt is követhetünk el hibát. A téves besorolás oka, hogy bizonyos intenzitási értékek mindkét vizsgált osztályban megtalálhatók, azonban más az előfordulási gyakoriságuk. Így, ha a C intenzitású pixel hovatarozásáról kellene dönten, akkor a maximum-likelihood elvét követve az 1. osztályba sorolnánk be, ahol az adott értéknek nagyobb az előfordulási gyakorisága. Így minden C értékű pixel esetében, amely valójában a 2. osztályhoz tartozik, a módszer hibázik. A döntéshatár a D értéknél van. A téves osztályozások számát a satírozott terület adja.



6. ábra A téves osztályozások számát a satírozott területek adják [CSORNAI G. - DALIA O., 1991.: Távérzékelés. – Kézirat. EFE Földmérési és Földrendezési Kar, Székesfehérvár]

A távérzékelési adatok jellegéből, ezen kívül a Földfelszín összetettségéből és az osztályozó eljárások nem tökéletes voltából adódóan az osztályozás pontossága igen eltérő lehet, megfelelő besorolás mellett mellé osztályozások fordulnak elő. Minden tévesen besorolt pixel a gyakorlati alkalmazásban veszteséget jelenthet a felhasználó részére. Ha az a célkitűzés, hogy az osztályozási hibából származó veszteség a lehető legkisebb legyen, abban az esetben eljutunk a Bayes döntéshez.

4.2 Automatikus osztályozás

Az automatikus, illetve felügyelet nélküli osztályozás az, amikor az eredmények a kép szoftveres elemzésén alapulnak anélkül, hogy a felhasználó mintakategóriákat adna meg.[4] A számítógép osztályokba csoportosítja az egymáshoz kapcsolódó pixeleket. Ezt a folyamatot a felhasználó az általa megadott paraméterekkel tudja „kontrollálni” azonban nem befolyásolja az osztályozási folyamatot. A felhasználónak ismernie kell a kiválasztott területet, tudnia kell annak jellemzőit mert rossz paraméterek megadásával az automatikus osztályozás hibás számítást eredményezhet.

4.2.1 Klaszter:

Klaszterezés során az algoritmus az összes pixelt számításba veszi elemzéskor. Az osztályozás végrehajtása előtt ismeretlen számunkra a tematikus kategóriák jellemzői, az eljárás során azonban olyan statisztikai algoritmusokat használunk melyek spektrális adatosztályokra (klaszterekre) bontják a képet. A klaszterezés célja a képi intenzitás olyan csoportosítása, aminek eredményeként az egymáshoz hasonló adatok egy csoportba (klaszterekbe) kerülnek, az egyes csoportok pedig elegendően különböznek egymástól. A gyakorlatban használt klaszterező eljárások (szakirodalom szerint több mint száz) lényegében a klaszter középpontját keresik meg és a pixeleket a legközelebbi klaszter-középponthez (K-mean) sorolják, általában az euklideszi távolság alapján. Az itt alkalmazott algoritmusok közös tulajdonsága azok iteratív jellege az adatcsoportok meghatározásában. Az eredmény több lépésben (iterációban) a célfüggvénnyel (pl. a

klaszter középponttól vett távolságok négyzetösszegének minimuma) kapcsolatos szélső értékek egyre pontosabb és pontosabb teljesítése mellett alakul ki. Ha a számítás n -dimenziós intenzitástérben megy végbe, akkor megadhatjuk a létrehozandó klaszterek maximális számát, de megadhatunk az intenzitástérben egy távolságot, amelynek túllépése esetén egy újabb klaszter jön létre. Klaszterezés során az iteráció maximális számának megadása további lehetséges megoldásokhoz vezet. A folyamat alatt lehetőség van az egyes iterációk eredményeit leíró statisztikai paraméterek ellenőrzésére, ami utalhat a számítások folytatására vagy megszakítására.

4.2.2 ISODATA

A képfeldolgozásban legjobban az ISODATA (Interactive Self-Organizing Data Analysis) módszer terjedt el. Ez magyarul ismétlődő önszervező adatelemző módszer. „Az ismétlődő, iteratív nevet azért kapta mert a teljes klasszifikációt megismétli, amíg az eredmény nem felel meg a követelményeknek, és létrehozza a tematikus raszterteréteget, s újraszámítja annak statisztikáját.” [5] Az ISODATA klaszterezési módszer a spektrális távolságot felhasználva osztályozza a pixeleket iteratív módon, a kritériumokat minden osztályra újraértelmezve. Ezáltal sokkal finomabb spektrális távolságon alapuló csoportokat kaphatunk. Az eljárás célja a felvétel adathalmazában olyan csoportok megtalálása, melyek elemei egymáshoz közel vannak, aminek értelmében a pixelek klaszterátlagtól való távolsága négyzetösszegének minimális értékére törekszik. Az eljárás a klaszter középpontjainak felkeresését, azok iteratív javítását valósítja meg. Az ISODATA klaszterezésnek 3 paramétere van ahol az N a klaszterek maximális száma, T a konvergencia küszöb és M az iterációk maximális száma. A konvergencia küszöb adja meg, maximálisan pixelek hány százaléka maradhat változatlan az iterációk között.[5]

4.3 Szegmens alapú osztályozás

A felvevőrendszerek fejlődése mellett a szenzorok felbontásai is fejlődnek. Ez a feldolgozandó adatok mennyiségének növekedésével és a minőség javulásával jár. A szuper nagyfelbontású felvételek esetekor csökken a képpontok nagysága az ábrázolt objektumokhoz nézve, ezáltal nagyon különböző intenzitású pixelek is előfordulhatnak a tematikus kategóriákon belül (pl. utakon lévő forgalmi felfestések, kultivált termőföldeken belüli növényelváltozások). „A pixel-alapú osztályozási eljárás egy ismeretlen hovatartozású képpont intenzitását önmagában vizsgálja, figyelmen kívül hagyva a pixel környezetét, vagyis a homogén területekre (pl. út, épület, mezőgazdasági tábla) eső szomszédos képpontok egymáshoz való viszonyát, térbeli kapcsolatát.” [2] Ebből tehát megállapítható a pontonkénti osztályozás tipikus tévedése, hogy az adott pixeleket a környezetéből kiemelve oda sorolja ahová önmagában nézve legjobban illeszkedik. Ennél jobb eljárás az amikor a pixelt szomszédjaival együtt vizsgálva csoportosítunk ilyen nagy felbontású műholdas felvételeknél. Tehát az osztályozáshoz szükséges a felvétel tartalmát régiókra osztani amelyek szomszédos és összetartozó képpontokból tevődnek össze és alkalmazkodnak a valós világ elemeihez. Ezek a

területek homogénnek mondhatóak, hiszen pixeleik ugyanahoz a tematikus kategóriához (pl. vegetáció mentes talaj) tartoznak. A szegmensek nagyságát a felhasználó állíthatja a hasonlósági küszöbérték módosításával. A szegmentálás egyre inkább elterjedt megoldás a képfeldolgozásban, hiszen sokkal megbízhatóbb eredményeket érhetünk el vele. „A szegmentálás eredménye döntően befolyásolja az osztályozás pontosságát, hiszen az osztályozás alapját a szegmensekre (objektumokra) számított jellemzők (spektrális, geometriai, térbeli, stb.) képezik.” [2]

5. A kiválasztott terület jellemzése

A dolgozatomhoz szükséges feladatokhoz szülővárosomat, Zalaegerszeget és környező területét választottam. A város a zalai-dombság északi részén található. Ez Zala megye székhelye a 18. század óta. Az erdők a harmadát teszik ki a 117000 hektárnyi területnek, így ez Magyarország erdőkben leggazdagabb megyéje. Ez a megyeszékhely környezetében is érzékelhető, a műholdas felvételekről, valamint a Copernicus Land Cover tematikus térképéről jól megfigyelhető, hogy a város körül ölelik az erdős területek. Zala megye erősen tagolt domborzattal rendelkezik, emiatt sűrű a vízhálózata. A vidék aktuális felszínét a negyedidőszaki tektonikus mozgások és a pleisztocén-kori éghajlati változások alakították ki. A folyók hordaléka több száz méter vastagon befedte a Pannon-tenger üledéket. Az eljegesedések, glaciálisok közötti felmelegedett időszakokban, interglaciálisokban a folyók nagyobb vízhozamuk révén bevágódtak a korábban, feltöltött síkságokba és völgyi teraszokat alakítva ki. [8] Zala megye területe a Pannonicum flóratartomány Saladiense flórajárásába tartozik. Növényzete az Illiricum flóratartomány valamint a Praenoricum flóravídek hatásait is mutatja. A domborzati tagoltság, a sokféle talaj igen változatos növénytakarót eredményez. [8] Magyarország nyugati részén található, ezáltal közel fekszik a tengerekhez. Ebből adódik, hogy hazánkban itt az óceáni hatás érvényesül. Mérsékelt meleg, nedves nyarakat enyhe telek követik. Zalaegerszeg és környéke csapadékban gazdagnak mondható. Az évi átlag 745 mm, emiatt a vízellátottság pozitív, nincs időszakos vízhiány a környéken. Ez kedvez a növényzetnek is, ritka a nyári szárazság és friss növényzet boriítja környezetét még

6. Sentinel és IDRISI

Mint azt már korábban említettem, az osztályozási módszerek összehasonlítására a Sentinel-2 műhold felvételeit fogom használni. Ez a műhold nagy felbontású, multispektrális szenzorokkal van felszerelve. A két műholdpár egymással 180-os szöget zárnak be és napszinkron pályán keringenek. A műholdak élettartama egy 7 éves ciklusra elegendő, azonban ez az energiaellátásnak köszönhetően akár 12 év. A felvételek egy 290 km szélességű sávban, a déli szélesség 56 és az északi szélesség 84 között készülnek. Szenzoraikat a francia Airbus Defence and Space tervezte és építette. Ezek a szenzorok a push-broom technológián alapulnak. A képi információt soronként gyűjtik a haladási pályájuk sávjában és így készülnek az újabb és újabb sorok miközben a műhold halad előre. Ezek a szenzorok a látható fény, a közeli infravörös és a közepes infravörös tartományokban készít képeket. Radiometrikus felbontásuk 12-bit, képesek 4096 szürkeségi érték tárolására. A nagyfelbontású űrfelvételeket a Földmegfigyelési Információs Rendszer honlapjáról szereztem be. Ezen a weboldalon megtalálhatóak a Kopernikusz program műholdjai által készített képek a bolygó egész területéről. A vegetációt figyelembe véve nyár eleji illetve tavasz végi felvételek között kellett keresnem. Sajnos a nyár eleji felvételeken, amik a vegetáció megfigyeléséhez a legalkalmasabbak lennének, túl nagy volt a területek felhő borítottsága. Azért, hogy a felvételeken a legpontosabb méréseket tudjam elvégezni inkább egy korábbi, május eleji Sentinel-2-es űrfelvételt választottam. Ezt tif formátumban tudtam letölteni a weboldalról. Ezek a formátumok tartalmazzák a különböző hullámhosszon rögzített sávokat. Munkám során az IDRISI SELVA szoftvert használtam, ami számos lehetőséget nyújt távérzékeléssel kapcsolatos munkákhoz. A szoftvert a Clark University fejlesztette ki és a mai napra az egyik legismertebb raszter alapú GIS és képfeldolgozó rendszer oktatási körökben. Első verziója 1987-re tehető, már több mint 20 éve dolgoznak rajta. Ennek köszönhetően sikerült egy precíz és effektív geo-analitikus elemző eszközt létrehozni. Segít a döntéshozatalban, a bizonytalanságok kezelésében valamint a képelemzésben. Elvégezhetőek benne a pixel és szegmens alapú osztályozások is, valamint ezeknek ellenőrzése hibamátrixal. A program képes raszteres és vektoros adatokat is kezelni. A műholdas képek a következő sávokat tartalmazzák:

Sentinel sávok	Sentinel-2A		Sentinel-2B		Térbeli felbontás(m)
	Hullámhossz közepe (nm)	Sávszélesség(nm)	Hullámhossz közepe (nm)	Sávszélesség(nm)	
Sáv 1 (Tengerparti aeroszol)	442.7	20	442.3	20	60
Sáv 2 (kék)	492.7	65	492.3	65	10
Sáv 3 (zöld)	559.8	35	558.9	35	10
Sáv 4 (Vörös)	664.6	30	664.9	31	10
Sáv 5 (Vörös él)	704.1	14	703.8	15	20
Sáv 6 (Vörös él)	740.5	14	739.1	13	20
Sáv 7 (Vörös él)	782.8	19	779.7	19	20
Sáv 8 (Közeli infravörös)	832.8	105	832.9	104	10
Sáv 8a (Keskeny közeli infravörös)	864.7	21	864.	21	20
Sáv 9 (Vízpára)	945.1	19	943.2	20	60
Sáv 10 (Közepes infravörös)	1373.5	29	1376.9	29	60
Sáv 11 (Közepes infravörös)	1613.7	90	1610.4	94	20
Sáv 12 (Közepes infravörös)	2202.4	174	2185.7	184	20

[7]

Konvertálás után megkaphatóak a műholdas felvétel sávjai IDRISI-ben. Ezekből a felvételekből kivágotot készíték, valamint hamisszínes színekompozitot.




A jobb oldali képen látható ahogy a zöld színt leváltja a vörös, valamint a szántók kékes színt kapnak. Ezt hívjuk hamisszínes eljárásnak a távérzékelésben. Ezzel az eljárással előhozhatók vagy felnagyíthatók azok a tulajdonságok is amik szabad szemmel alig láthatók. A hamis színskombináció egy multispektrális képértelmezés, amely a szabványos vizuális RGB sáv tartományt (piros, zöld és kék) használja. Hamis színskombinációt különböző kombinációkkal is el tudunk érni. Az itt szereplő mérésekhez a zöld, vörös és közeli infravörös sávokat használtam.

7 . Osztályozási módszerek alkalmazása a kijelölt területen

Ahhoz, hogy a kivágaton lévő pixeleket ellenőrzött osztályozással tudjuk csoportosítani, először is szegmentálnunk kell a területet. Ez a kivágat régiókra osztását jelenti. A szegmensek a pixelek csoportjainak intenzitás értékeit csoportosítják. Az algoritmus felismeri, ha egy pixelhalmaz azonos értékekkel rendelkezik. A szegmensek homogenitásukban enyhén variálódhatnak, azonban általánosságban kijelenthető, hogy egy szegmens, ha megfelelő méretben jön létre, akkor homogén lesz.

7.1 Szegmentálás és tanulóterületek

Szegmentálásánál ügyelni kell a létrejött szegmensek méretére. Az elaprózódó szegmensekkel sokkal időigényesebb elvégezni a számításokat, valamint a tanuló területek nem lesznek igazán hatékonyak. Ezzel ellentétben, ha túl nagy darabkák jönnek létre, nem lesz elég a szegmensek homogenitása. A homogenitási értéket fontos figyelembe venni a későbbiekben, amikor a tanulóterületeket választjuk ki, mivel ezek pontatlan számításokhoz vezethetnek.




A bal oldali képkivágaton látható hogy a szegmentálás során létrejött régiók tükrözik a valós világ objektumait, valamint megfelelnek a homogenitási feltételeknek. Az egyes

részekben láthatóak földutak melyeknek eltérőek az intenzitás értékei, a szegmentálás azonban figyelembe vette a környező pixelek intenzitás értékeit és egy osztályba sorolta azokat.

A jobb oldali képkivágaton Zalaegerszeg belvárosáról készült szegmentálást figyelhetjük meg. A város utcái a műholdas felvételen ültetett fasorokkal tarkítottak. Ugyan a városképek szegmentálása segíthet az egyes telkek beépítettségét megítélni, az itt felhasznált műholdas felvételek felbontása nem megfelelő erre. Itt, ezeken a felvételeken, a kiválasztott szegmentálással szegényebb a területek homogenitás szintje és a régiók formája is csak nehezen követi le a valós világban található objektumokat. Ezt a szegmensek méretének csökkentésével tudnánk kis mértékben kiküszöbölni, viszont ha ezt a módszert választjuk akkor a környező mezőgazdasági területek lesznek túlaprózódva.

Miután a területet szegmentáltuk úgynevezett tanuló, avagy tréning területek kell kiválasztanunk. Érdemes minél több és minél homogénebb szegmenseket kiválasztani, ugyanis a későbbi algoritmusok ezeket veszik majd mintának. Az úgy nevezett segmentation training során a szegmensek azonosítójához (segment id) hozzárendelünk egy osztály azonosítót (class id).




Miután a tanulóterületek kiválasztása megtörtént már elvégezhetőek az ellenőrzött osztályozási módszerek.


7.2 Minimum Distance osztályozás

A legkisebb távolság algoritmus nagy előnye, hogy gyorsan végzi el a folyamatot és sok időt spórol meg a felhasználónak. Ugyanakkor, ennek az eljárásnak van egy hátránya is ami pedig nem más mint a pontatlansága. Előfordulnak ugyanis félreosztályozott pixelek, mivel az algoritmus hajlamos a hibázásra amikor az összes pixel osztályozva van, néha még a legrövidebb távolság is nagyon messze lesz.

Minimum Distance Osztályozás




Az osztályozás során a minimum distance algoritmus hibája érzékelhető. A tanuló területek többszöri újraválasztása sem oldotta meg a problémát, mégpedig a lombhullató erdők és a mezőgazdasági vegetáció 3 régiók félreosztályozását. A kivágoton számos olyan terület került mezőgazdasági vegetáció 3 csoportba amely a való életben lombhullató erdő lenne. Ennek oka, hogy a intenzitás értékük nem nagyban tér el egymásétól, és szabad szemmel is könnyen összekeverhetőek a régiók.




Ezen a grafikon láthatjuk az egyes osztályok előfordulását. Leolvasható, hogy a leggyakrabban előforduló osztály a mezőgazdasági vegetáció 3.


A térképen találhatóak olyan területek ahol a vegetáció még nem igazan erős, valószínűleg frissen bevetett mezőgazdasági területek lehetnek. Az ilyen területeket lehetséges hibaforrások hiszen megtalálhatóak bennük olyan pixelek amelyek a vegetációs és vegetáció mentes talajokban találhatóak meg. Az ilyen területeket a hamisszínes ábrázoláson lilás, halvány vörös színben találhatjuk meg.



7.3 Maximum Likelihood




Az előző módszerhez képest most a lomblevelű erdők kerültek fölénybe. Ez az algoritmus azt vizsgálja, hogy egy adott pixel milyen valószínűséggel tartozik egy adott tartományba.




A grafikonról leolvasható, hogy a leggyakrabban előforduló osztály a fűves területek.

7.4 Isodata



Ennél az eljárásnál már nem „felügyeljük” az algoritmust. Ezáltal, a tökéletes eredmény eléréséhez finomhangolnunk kell az eljárás paramétereit. Az ISODATA eljárás klaszterekkel dolgozik, ezek számát mi állíthatjuk. A fenti képen 11 klasztert állítottam be, mivel az ellenőrzött osztályozás során is ennyi csoportot határoztam meg. Az iterációk számát is szabályozhatjuk, a képen az iterációk száma 60. Maximális mérete az egyes klasztereknek 100. Az isodata eljárás más osztálycsoportokat hoz létre, mint amelyeket mi a szegmentálás után meghatároztunk. Ennek az az oka, hogy az eljárás algoritmusában más osztályokat tart „logikusabbnak”.





Az ISODATA az ún. iteratív önszerveződő adatelemzési technikát (algoritmust) alkalmazza egy n-dimenziós képi anyagnak a megadott értéknek jó számú klaszterre történő felosztására. Az ISODATA a megadott paraméter támogatásával a centroidok (középértékek) számának inicializálásával kezdi, majd minden egyes képpontot ahhoz a klaszterhez rendel, amelynek centroidja a legközelebb van, frissíti a klasztercentroidokat, majd felosztja, ezen kívül összevonja a klasztereket, amikor a felosztási, ezen kívül összevonási kritériumok érvényesek.

Az ISODATA az euklideszi távolságot alkalmazza a pixelek, valamint a klasztercentroidák közti távolságok kiszámításához.

7.5 Klaszter


Klaszterezés esetében nem tudjuk pontosan azokat az osztályozási csoportokat megkapni mint a pixel alapú algoritmusokkal. Kezdetben egy küszöbértékkel szegmentálják az átalakított képet texturált és nem texturált régiókra. Ezután texturált és nem texturált régiókra bontja a szegmentált képmaszk segítségével. Ezeket egymástól függetlenül csoportosítja. A klaszterezés során beállíthatjuk az úgy nevezett „grey levels”, azaz szürkeségi értékeket. Ezután meghatározhatjuk a klaszterezés módszerét. A széles és finom általánosítási szintek eltérő döntési szabályokat használnak a csúcsok gyakorisági histogramjának kiértékelésekor. A „széleskörű” klaszterezésben egy csúcsnak nagyobb frekvenciát kell tartalmaznia, mint az összes nem átlós szomszédja. A finom osztályozás lehetővé teszi, hogy a csúcs magasabb frekvenciájú, nem átlós szomszédban legyen.

7.5.1 Broad Klaszter



A klaszterezés során a legtöbb terület az egyes osztályba került.

7.5.2 Fine Klaszter




Az IDRISI szoftverben a klaszterelemzés hisztogramcsúcs-technikáját használja. Ez egyenértékű az egydimenziós hisztogram csúcsainak keresésével, ahol a csúcsot olyan értéként határozzuk meg, amely nagyobb gyakorisággal fordul elő, mint a kétoldali szomszédai. A csúcsok azonosítása után az összes lehetséges értéket a legközelebbi csúcshoz rendeljük, és az osztályok közötti felosztás a csúcsok közötti középpontokba esik. Itt egy egy-hét dimenziós hisztogramot használnak a csúcsok megtalálására. A csúcs tehát egy olyan osztály, amelynek gyakorisága magasabb, mint az összes kardinális szomszédja. Az átlós szomszédok a sávok közötti korreláció miatt kimaradnak. A széles körű osztályozásban egy osztálynak magasabb frekvenciát

kell tartalmaznia, mint az összes nem diagonális szomszédjának. A finom osztályozásban ez a követelmény enyhül, megengedve, hogy egy nem diagonális szomszédnak magasabb legyen a frekvenciája. Ez olyan valódi csúcsokat tesz lehetővé, amelyek egyébként kimaradnának, mert egy közeli, nagyobb erősségű csúcs eltakarja a csúcsok közötti szokásos mélyedést. A CLUSTER nem alkalmazza az eredeti képek hisztogramját a csúcsok meghatározásához. Ehelyett minden egyes bemeneti képet adott számú szürkeárnyalatra nyújt, mielőtt kiszámítja a hisztogramjukat. Ez a processzus az alábbiakban ismertetett három szakaszból áll. Elsőnek az egyes bemeneti képek hisztogramját az eredeti bemeneti kép digitális számainak végigjárásával kapjuk meg. Ebből a hisztogramból az egyes szürkességi szintek numerikus kumulatív arányát úgy találjuk meg, hogy az egyes szürkességi szintek frekvenciáját az alacsony frekvenciától a magas frekvenciákig összeadjuk. Ezt követően a megadott telítettségi százaléknak megfelelő módon határozzuk meg a határpontokat. Ha példának okáért egy képet 5 százalékkal szeretnénk telíteni minden egyes farkában, az 5 százalékos, valamint 95 százalékos kumulatív arányú határpontokat a hisztogramból származó kumulatív arányok ellenőrzésével határozzuk meg. Az egyes bemeneti képek hisztogramjának származtatásához a bemeneti képek szürke szintjeit lineárisan 256 szintre nyújtjuk, 0, továbbá 255 között. Ez lehetővé teszi a CLUSTER részére, hogy a három adattípus - byte, egész szám, esetleg valós - bármelyikét kezelje ebben az adattartományban.

8. Pontosságvizsgálat

Miután elvégeztük egy műholdas felvétel osztályozását felmerülhet bennünk a kérdés, hogy a számítás mennyire lehet pontos. Létfontosságú, hogy ismerjük egy osztályozási módszer pontosságát, hiszen szeretnénk, hogy akik majd a térképünket használják megbízzanak benne. Ha egy osztályozás közel tökéletesre sikerül, azt elmondhatjuk a felhasználónak, hogy a lehető legtöbbet kihozhatta a térképből. Kötelességünk arról is tájékoztatni ha esetleg a számítások nem lettek megbízhatóak. Az ellenőrzés alapelve, hogy összehasonlítsuk a becsléseket a valósággal, valamint a kettő közötti különbséget számszerűsítsük. A távérzékelésen alapuló talajborítási osztályozással összefüggésben a „becslések” az egyes pixelekhez leképezett osztályok, a „valóság” pedig az egyes pixeleknek megfelelő területek tényleges földborítása. Először is nekünk kell a „valóságra” vonatkozó adatokat megkeresnünk, mivel a „becsléseket” már elvégezte nekünk az algoritmus. A valóságra vonatkozó adatokat általában ground-truth, azaz valós világ adatoknak nevezik, és jellemzően a talajborítás georeferált terepi megfigyeléséből állnak. Ez gyakran használt technika, hogy fizikailag bemegyünk a vizsgált területre egy GPS-szel és egy kamerával, és georeferált fényképeket készítünk, amelyek viszont lehetővé teszik a talajborítás vizuális meghatározását minden egyes fotóról. Mivel az emberek vizuálisan nagy pontossággal képesek megkülönböztetni a különböző típusú talajtakarókat, az ilyen adatok ésszerűen tekinthetők a „valóságnak”. Sok esetben

azonban az „alap igazság” kifejezés felülmúlja az ilyen jellegű információk pontosságát. Lehet, hogy az emberek jól tudják megkülönböztetni a „sivatagot” és az „erdőt” egy fotón, de egyértelműen kevésbé tudnak különbséget tenni a „nagy sűrűségű erdő” és a „közepes sűrűségű erdő” között. Különösen akkor, ha a két osztály közötti különbség a borítás százalékos arányán alapul (például a közepes és a nagy sűrűségű erdők közötti különbség az lehet, hogy a fák a felszín több vagy kevesebb mint 50%-át borítják), a terepi megfigyelések nem mindig vezetnek tökéletes eredményhez. Ezért sok távérzékelési tudós előnyben részesíti a „validációs adatok” kifejezést, ami arra utal, hogy ezek az adatok alkalmasak a távérzékelésen alapuló osztályozásokkal való összehasonlításra, ugyanakkor elismerik annak lehetőségét, hogy nem felelnek meg tökéletesen az „igazságnak”. A valós és elfogulatlan pontosságvizsgálathoz néhány szabályt be kell tartanunk. A validációs adatoknak le kell fedniük az egész térképen található összes osztályt. Az általunk kiválasztott és bedigitalizált területek számának közel azonosnak kell lennie például a szegmentálás után kiválasztott tanuló területek számával. Ez arra is hasznos módszer, ha a felhasználó meg szeretné tudni, hogy mely osztályok vannak jobban feltérképezve, mint mások. Minél több az érvényesítési adat, annál pontosabb lesz a vizsgálat. Azonban az érvényesítési adatok létrehozása gyakran időbe és pénzbe telhet, emiatt célszerű az „elég” adat beszerzése. A pontosságvizsgálat megkezdéséhez először is be kell digitalizálni néhány területet amelyekkel később a kiválasztott osztályozási módszerek eredményeit hasonlítjuk össze. A területek kiválasztása során ügyeltem az egyes szegmensek homogenitására, valamint arra, hogy a minél több helyről gyűjtsek mintaterületeket. Ezeket a területeket az IDRISI vektor állományban menti el, viszont a hibamátrixok számításához raszter állomány szükséges. A program lehetőséget kínál a vektorból raszterre konvertálásban.



Ha elvégeztük a területek digitalizálást, olyan adatokat kaptunk melyekben megbízhatunk és a későbbiekben referenciának vehetjük őket. A számítás során az értékeket egy táblázatban összegezzük, melyet hibamátrixnak nevezünk. Az ezáltal szolgáltatott információval megválaszolhatjuk, hogy mennyire volt pontos az adott osztályozás.

8.1 Minimum distance hibamátrix

		Referencia adat											Sor összes	P	U
		1	2	3	4	5	6	7	8	9	10	11			
Osztályozott adat	1	2524	0	0	0	0	0	0	0	0	0	0	2524	100%	100%
	2	0	2271	249	0	0	0	0	8	0	0	0	2528	100%	90%
	3	0	0	11	0	0	0	72	67	0	479	0	629	0%	2%
	4	0	0	0	5840	19	0	56	0	0	0	438	6353	100%	92%
	5	0	0	0	26	1701	0	1574	0	0	0	280	3581	99%	48%
	6	0	0	0	0	0	817	376	0	0	0	0	1193	100%	68%
	7	0	0	0	0	0	0	1931	0	0	0	7	1938	45%	100%
	8	0	0	132	0	0	0	21	418	0	415	0	986	17%	42%
	9	0	0	0	0	0	0	163	1	2290	0	0	2454	100%	93%
	10	0	0	1928	0	0	0	25	1968	0	223	0	4144	20%	5%
	11	0	0	0	0	0	0	114	0	0	0	3373	3487	82%	97%
Oszl		2524	2271	2320	5866	1720	817	4332	2462	2290	1117	4098	29817		
													Átfogó pontosság	72%	

A hibamátrix egyes sorai és oszlopai az adott osztályban található pixelek számát mutatják be. Leolvasható a táblázatról hogy az egyes osztályba, amely a mezőgazdasági vegetáció 1 nem került más képpont. A mezőgazdasági vegetáció 2 osztályból viszont került a mezőgazdasági vegetáció 3 osztályba is. A legnagyobb eltérések is ezeknél az osztályoknál vannak. Az átfogó pontosság végül 72%.


8.2 Maximum Likelihood hibamátrix

		Referencia adat											Sor összes	P	U
		1	2	3	4	5	6	7	8	9	10	11			
Osztályozott adat	1	2524	0	0	0	0	0	0	0	0	0	0	2524	100%	100%
	2	0	2271	185	0	0	0	0	0	4	0	0	2460	100%	92%
	3	0	0	0	0	0	0	25	5	0	399	0	429	0%	0%
	4	0	0	0	5860	48	0	68	0	0	0	12	5988	100%	98%
	5	0	0	0	26	1205	0	998	0	0	0	72	2281	70%	53%
	6	0	0	0	0	0	817	20	0	0	0	0	837	100%	98%
	7	0	0	0	0	0	0	2925	0	0	0	13	2938	68%	100%
	8	0	0	678	0	0	0	21	2234	0	158	0	3070	91%	73%
	9	0	0	0	0	0	0	163	1	2290	4	0	2383	100%	96%
	10	0	0	1457	0	0	0	25	218	0	509	0	2229	46%	23%
	11	0	0	0	0	0	0	163	0	0	47	4001	4678	98%	86%
Oszlop összes		2524	2271	2320	5866	1720	817	4332	2462	2290	1117	4098	29817		
													Átfogó pontosság	83%	


Az itt kapott értékek már 11 százalékkal jobbak mint a minimum distance osztályozásnál, az átlagos pontosság 83%

8.3 ISODATA és Klaszterezés kiértékelés

Az ISODATA és Klaszter algoritmusok nem ellenőrzött osztályozási módszerek így saját csoportokat hoznak létre. Ahhoz, hogy ezeket az eredményeket kiértékelhessük újra kell osztályoznunk az algoritmusok által létrejött eredményeket. Erre az Idrisi szoftver RECLASS parancsa alkalmas. Ennek folyamán az automatikusan létrehozott osztályokat az általunk meghatározott osztályokba küldjük.




A térképen látható, hogy a mezőgazdasági vegetációk 2 csoportját és a fűves területeket egy osztályba sorolta. Ennek oka a hasonló intenzitásértékük. Nézzük meg, hogy a klaszterezés algoritmus során milyen eredményt kapunk.



A klaszter eljárás következtével a mezőgazdasági vegetáció 2 osztályba sorolta be a terület nagy részét. Ez szintén azért történt mert a füves területek, mezőgazdasági vegetáció, lombhullató erdők intenzitás értékei hasonlóak. Az eredményekből így azt a következtetést vonhatjuk le, hogy az automatikus osztályozás során ekkora területre, ilyen széles intenzitásértékekkel nem elég 11 osztályt létrehozni.

ISODATA osztályozás





Egy újabb automatikus isodata osztályozás során a klaszterek maximális számát 16-ra állítottam. A térképen látható, hogy így már jobban elkülönülnek a hasonlóan tekinthető osztályok is. A módosított eljárás következtében a új osztályok is létrejöttek amik viszont nem azonosulnak az előző részben általunk kijelölt tanulóterületek csoportjaival. A hibamátrix számításakor a mintaterületek osztályának száma megegyezik az ellenőrzött osztályozás során létrejött csoportok számával. Ez az ellenőrzött osztályozás alkalmával nem jelentett nehézséget, hiszen a mi általunk

definiált osztályokkal számított az algoritmus. Ahhoz, hogy ez a két szám most is megegyezzen hozzá kell finomítanunk az isodata eljárás során létrejött klaszterekhez a régi csoportokhoz. Mivel több klaszter jött létre mint mi azt szeretnénk, szükséges az egyes klasztereket újraosztályozni és kettő vagy esetleg több osztályt egybeolvasztani. Ehhez elemeznünk kell az osztályozott képet és az eredeti hamisszínes térképkivágatot. Elemzés után látható, hogy az ISODATA eljárás milyen osztályokat hozott létre:


- 1 gyenge vegetáció
- 2 mezőgazdasági vegetáció 1
- 3 gyenge vegetáció 2
- 4 víz
- 5 barázdált vegetáció
- 6 mezőgazdasági vegetáció 2
- 7 vegetáció mentes talaj 1 / város
- 8 erdő 1
- 9 erdő 2
- 10 vegetáció mentes talaj 2
- 11 mezőgazdasági vegetáció 3
- 12 gyenge vegetáció
- 13 vegetáció mentes talaj 2
- 14 füves terület
- 15 gyenge vegetáció 3
- 16 erdő 3


Látható, hogy az egyes osztályozási csoportokat még több részre osztotta. A város egy osztályba került néhány vegetáció mentes talajjal így a 7. klasztert nem a vegetáció mentes talajok közé fogom újraosztályozni.





Balra látható az újraosztályozott eredmény intenzitásértékei, alatta pedig az általam elkészített színpalettával leképzett tematikus térkép. A mezőgazdasági vegetációk szépen elkülönültek egymástól. Néhány félreosztályozási hiba azonban így is létrejött, mivel a gyenge vegetációs területek homogenitása nagyon hasonló akár a város fákkal beborított utcáinak homogenitására, akár az utakéra. Ennek következményeként a térkép jelentős része ebbe a gyenge vegetációs osztályba került. A városban az épületek teteje és a fák lombkoronái olyan értékkel vegyülnek egymáshoz, ahogy a gyenge vegetációs területeken a föld és a frissen elültetett növényzet. Ennek következtében a város nagy része ilyen gyenge vegetációs osztályba került.





Az újraosztályozás után, kijelöltem új tanulóterületeket hiszen nem sikerült teljesen azonos osztályokat létrehozni. A képen láthatóak az új mintaterületek. Ezekkel fogjuk összehasonlítani az isodata algoritmus eredményét hibamátrixban.

		Referencia adat											Sor összes	P	U
		1	2	3	4	5	6	7	8	9	10	11			
Oszályozott adat	1	4331	0	169	0	0	0	0	4	0	715	0	5046	99%	86%
	2	0	2398	12	0	0	0	138	48	125	1	84	3586	59%	67%
	3	65	1333	1168	0	0	0	119	945	1	972	101	5202	42%	22%
	4	0	0	0	4647	1113	0	491	0	0	0	0	6251	93%	74%
	5	0	0	0	245	7493	0	136	0	0	0	0	7874	87%	95%
	6	0	0	0	0	0	1199	1102	0	0	0	0	2301	100%	52%
	7	0	0	0	12	45	0	3868	0	0	0	0	3993	40%	97%
	8	0	0	144	0	0	0	1042	5362	0	0	136	6684	84%	80%
	9	0	339	80	0	0	0	52	13	623	60	4	1171	73%	53%
	10	0	1	10	0	0	0	18	2	96	2161	0	2288	55%	94%
	11	0	0	83	0	61	0	2742	0	6	13	923	3801	74%	24%
	Oszlop	4396	4071	2775	5023	8634	1199	9708	6370	851	3922	1248	48197		
Átfogó pontosság													71%		

A hibamátrixról leolvasható, hogy az átfogó pontosság 71%. Ha megnézzük látható hogy vannak olyan részek amelyeket az isodata osztályozás víznek tekintett, pedig az igazából a város osztályába tartozna.

9. Összegzés

A manapság legismertebb osztályozási módszereket elvégezve arra a következtetésre juthatunk, hogy az ellenőrzött osztályozás, azt a negatívumot leszámítva, hogy időigényes a tanulóterületek kiválasztása miatt, mégis pontosabb és hatékonyabb osztályozást végez. A nem ellenőrzött, automatikus osztályozás során a felhasználó hamar eredményekhez juthat ám ezeket a későbbiekben még finomítani kell, hogy egy átlátható tematikus térképet tudjon készíteni. Méréseim során a maximum likelihood osztályozási módszer bizonyosult a leghatékonyabbnak, mivel ennek 83% az átfogó pontossága. Kijelenthető, hogy a vizsgált terület tulajdonságaitól is függ melyik metódus válik be a felhasználónak leginkább. Az itt láthatott térképkivágat sok szabálytalan területből tevődött össze. Kisebb kivágatokon, ahol a valós világ objektumai egyszerűbb alakzatokat jelentenek, az automatikus osztályozás sokkal hatékonyabb tud lenni.

10. Rövid tartalmi összefoglaló

A távérzékelés fontos szegmense a képosztályozás. Ez a művelet egy adott műholdas felvétel pixeleinek elemzését és csoportosítását jelenti. A képosztályozás segíti a szervezést és a tervezési folyamatokat. Hasznosítható a mezőgazdálkodástól kezdve a várostervezésen át egészen a katasztrófavédelemig. Emiatt szükséges ezeket a képosztályozási módszerek folyamatosan vizsgálni, ellőnirzni és összehasonlítani, hogy kiértékelhessük azok hatéktívását. A műholdas felvételeknek 4 tulajdonsága van, ez a térbeli felbontás, spektrális felbontás, radiometriai felbontás és időbeli felbontás. Mind a távérzékelés, mind a digitális képosztályozás során ezeket a tulajdonságokat felhasználjuk hiszen tudnunk kell az egyes területek, pixelek méretét valamint intenzitás értékeit. A digitális képosztályozást ellenőrzött és az automatikus osztályozásra lehet bontani. A két metódus közötti legszembetűnőbb különbség az a tanulóterületek használata. Ugyanis az ellenőrzött osztályozáshoz szükségünk van előre kiválasztott tréning, azaz tanulóterületekre, melyeket a későbbi algoritmus mintának vehet. Ezeket a tanulóterületek úgy kell megválasztanunk, hogy azok a lehető legpontosabb példát szolgáltatassák az ellenőrzött eljárásoknak. Ügyelnünk kell a területek homogenitására, azaz a pixelek közel azonos intenzitásértékére egy területen belül. Az automatikus osztályozás ezzel ellentétben nem igényel ilyen mintaterületek, az algoritmusok a paraméterek beállítása után automatikusan elvégzik a számításokat. Az ellenőrzött osztályozásból kiemeltem a minimum distance, azaz a legkisebb távolság, valamint a maximum likelihood algoritmusokat. Az automatikus osztályozás csoportjába tartozó isodata és klaszter algoritmusok kerültek bemutatásra. A dolgozatban Zalaegerszeg és annak környező területéről készült műholdas felvételeket használtam fel. Az osztályozási módszerek alkalmazása után digitalizálás segítségével kiértékeltem az algoritmusok pontosságát. A digitalizálás során kiválasztottam azokat a megbízható területeket ahol a homogenitási értékek a legjobbak az egyes osztályokon belül. Az így kapott eredményeken jól látszik, hogy mindegyik osztályozási módszernek megvannak a maga

előnyei és hátrányai is. Mérlegelnünk kell, hogy melyiket válasszuk meg az egyes munkákhoz. Nagyban befolyásolja a módszerek hatékonyságát az osztályozandó területen elhelyezkedő objektumok tulajdonságai.

11. Angol nyelvű összefoglaló

Image classification is an important segment of remote sensing. It is the process of analysing and grouping pixels from a given satellite image. Classification aids organisation and planning processes. It has applications ranging from agriculture to urban planning and disaster management. For this reason, it is necessary to continuously test, develop and compare these image classification methods in order to evaluate their effectiveness. Satellite imagery has 4 properties: spatial resolution, spectral resolution, radiometric resolution and temporal resolution. In both remote sensing and digital image classification, we use these properties because we need to know the size and intensity values of each pixels. There are two categories of classification. These two groups are supervised and automatic classification. The most striking difference between the two methods is the use of learning areas. For the controlled classification, we need pre-selected training, i.e. learning areas, which can be used as a sample by the subsequent algorithm. These learning domains must be chosen in such a way that they provide the most accurate possible example of the controlled procedures. We need to take care of the homogeneity of the areas, i.e. the pixels within an area should have nearly the same intensity value. Automatic classification, on the contrary, does not require such sample areas, the algorithms perform the calculations automatically after setting the parameters. I have highlighted the minimum distance, i.e. the smallest distance, and the maximum likelihood algorithms from the verified classification. Isodata and klaszter algorithms belonging to the group of automatic classification are presented. In the thesis I used satellite images of Zalaegerszeg and its surrounding area. After applying the classification methods, I evaluated the accuracy of the algorithms by means of digitization. During the digitization I selected the reliable areas where the homogeneity values are the best within each class. The results obtained clearly show that each classification method has its own advantages and disadvantages. We need to consider which one to choose for each job. The effectiveness of the methods is greatly influenced by the properties of the objects in the area to be classified.

11. Irodalomjegyzék

- [1] <https://www.copernicus.eu/hu/kopernikusz-program> (Copernicus)
- [2] http://tamop412.elte.hu/tananyagok/taverzekelt/lecke3_lap1.html (ELTE - PPKE informatika tananyagfejlesztési projekt (TÁMOP-4.1.2.A/1-11/1-2011-0052))
- [3] https://people.inf.elte.hu/fekete/taverzekeles/eloadasok_2017/jegyzet-tfe-20170618.pdf (László István, Csornai Gábor, Dr. Fekete István, Giachetta Roberto- Távérzékelte felvételek elemzése)
- [4] http://www.agt.bme.hu/tutor_h/terinfor/t34c.htm (BME AGT - Távérzékelés III)
- [5] <http://www.geo.u-szeged.hu/~laci/ab-Geoinfo-tananyag/ch07s03.html> (Szegedi Tudomány Egyetem, Geoinformatikai, Természet- és Környezetföldrajzi Tanszék - Űrfelvételek feldolgozása – osztályozás)
- [5] <https://mapasyst.extension.org/whats-the-difference-between-a-supervised-and-unsupervised-image-classification/> (MAPASYST)
- [6] <https://oszkdk.oszk.hu/storage/00/01/70/50/dd/1/Wojtaszek.pdf> (Verőné Dr. Wojtaszek Malgorzata - Objektum-alapú képelemzés)
- [8] <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument> (Sentinel sávok)
- [9] https://gocsejmuzeum.hu/sites/default/files/csatolmanyok/statikus/zalai_muzeum_22_x1_bw.tomoritett.pdf (Dr. Németh József: A megye földrajza; Történelmi-társadalmi viszonyok. In Molnár Máté (szerk): Zala. Budapest: Kossuth. 1984 ISBN 963 09 2477)
- [11] <https://lms.irsel.eu/~akovacs/docs/M2.tar> Data Acquisition, Sensors and Platforms (passive sensing) Irsel
- [12] CSORNAI G. - DALIA O., 1991.: Távérzékelés. – Kézirat. EFE Földmérési és Földrendezési Kar, Székesfehérvár