



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Alba Regia Műszaki Kar
Geoinformatikai Intézet

SZAKDOLGOZAT

A Soproni-hegyvidék erdőállományának elemzése hiper- és multispektrális felvételek alapján

OE-AMK

2022

Hallgató neve: Szalai Áron

Hallgató törzskönyvi száma: T000538/FI12904/A-G



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Óbudai Egyetem
Alba Regia Műszaki Kar
Geoinformatikai Intézet

SZAKDOLGOZAT FELADATLAP

Hallgató neve: Szalai Áron

Szakedolgozat száma: SZD22011414079793

Törzskönyvi száma: T000538/FI12904/A-G

Neptun kódja: XXXXXXXXXX

Szak: földmérő és földrendező mérnök

Specializáció: Geoinformatika specializáció

Földrendező specializáció

A dolgozat címe: A Soproni-hegyvidék erdőállományának elemzése hiper- és multispektrális felvételek alapján

A dolgozat címe angolul: Analysis of the forest of the Sopron Mountains based on hyper- and multispectral images

A feladat részletezése:

1. A szakirodalom alapján a távérzékelés szerepének összefoglalása az erdőállomány monitoringban.
2. A mintaterület részletes bemutatása. A felhasznált adatok jellemzése.
3. A felhasznált képelemzési módszerek bemutatása.
4. Az eredmények kiértékelése.
5. Az alkalmazott osztályozási eljárások összehasonlítása, következtetések levonása.

Intézményi konzulens neve: Verőné Dr. Wojtaszek Malgorzata Mária

Külső konzulens neve: Dr. Király Géza

Munkahelye: Győr-Moson-Sopron Megyei Kormányhivatal Ingatlan-nyilvántartási Osztály

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

Beadási határidő: 2022. 12. 15.

A szakedolgozat: Nem titkos.

Kiadva: Székesfehérvár, 2022. 10. 12.

P.H

Intézetigazgató

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

Verőné Wojtaszek M.
belső konzulens

Király Géza
külső konzulens



ÓBUDAI EGYETEM
ÓBUDA UNIVERSITY

Alba Regia Műszaki Kar
Geoinformatikai Intézet

HALLGATÓI NYILATKOZAT

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

Kelt: Sopron, 2022. december 15.

.....
hallgató aláírása

Tartalomjegyzék

1.	Bevezetés.....	1
2.	Irodalmi Áttekintés.....	2
2.1	A Soproni-hegyvidék és erdőállományának jellemzői.....	2
2.1.1	A Soproni-hegyvidék geológiai viszonyai.....	2
2.1.2	A Soproni-hegyvidék éghajlati jellemzői.....	3
2.1.3	A Soproni-hegyvidék vízrajza.....	4
2.1.4	A Soproni-hegyvidék talajtani viszonyai.....	5
2.1.5	A Soproni-hegyvidék erdőállományának jellemzői.....	6
2.2	A távérzékelésről általában, távérzékelési módszerek alkalmazása az erdészeti gyakorlatban.....	8
2.2.1	A távérzékelés története.....	8
2.2.2	A távérzékelés felhasználási területei, általánostól az erdészetiig.....	9
2.2.3	A távérzékelés során használt szenzorok típusai.....	12
2.2.4	A passzív optikai felvételek előfeldolgozása során alkalmazandó korrekciók	15
3.	Anyag és módszer.....	17
3.1	A hiperspektrális felvételek alkalmazási területeinek bemutatása.....	17
3.2	A Soproni-hegyvidékről készült hiperspektrális felvétel és ortofotó jellemzői	20
3.3	A hiperspektrális felvételek feldolgozása az ENVI szoftver felhasználásával.	20
3.3.1	A távérzékelte felvételek transzformálása.....	21
3.3.2	A képosztályozási eljárások.....	24
3.3.3	Az NDVI index és alkalmazási területe.....	26
3.3.4	Tanuló területek létrehozása.....	28

4.	Eredmények.....	33
4.1	A felügyelt osztályozási módok eredményei.....	34
4.2	A nem felügyelt osztályozás módok az ISODATA és a K-mean osztályozó eredménye	38
4.3	Az osztályozási módszerek összehasonlítása.....	39
4.4	A mintaterület NDVI értékeinek összehasonlítása a 2021- és 2022-es évre vonatkozóan	40
5.	Következtetések.....	41
6.	Összefoglaló.....	42
7.	Summary.....	43
8.	Köszönetnyilvánítás.....	44
9.	Irodalomjegyzék.....	45
10.	Ábrajegyzék.....	47

1. BEVEZETÉS

Eredeti végzettségem erdőmérnök, ezért olyan témát kerestem melyben kamatoztathatom korábbi tanulmányaim során szerzett ismereteimet. Az egyetemi tanulmányaim időszakom alatt a távérzékelés tárgyköre került érdeklődésem középpontjába. A távérzékelés tudományának fontos és régóta kutatott területe a felszín borító növényzet detektálása, a növényzeti kategóriák elkülönítése, a mennyiségi és minőségi változások nyomon követése. Ezek a törekvések magától értetődően az erdészeti kutatásban szintén nagyon korán megjelentek.

Az erdőtervezés és gazdálkodás szempontjából elengedhetetlen annak ismerete, hogy milyen faállománytípusból és fafajokból épül fel egy adott erdőállomány. Nagy területek terepi felvételezése rettentő idő- és munkaigényes feladat. A távérzékelés segítséget nyújthat faállományok, egyes fafajok mennyiségi és minőségi jellemzőinek meghatározásában. Azokban az országokban, ahol nagy területű egybefüggő erdők találhatók, már régóta használják a gyakorlatban is ezeket a módszereket. Dolgozatom alapját képezi az általam oly kedvelt Soproni-hegyvidék erdőállományáról 2021-ben készült hiperspektrális felvétel, melyet a Soproni Egyetem bocsátott rendelkezésemre. A hiperspektrális felvételek kitűnően alkalmasak faállománytípusok és fafajok elkülönítésére, míg a címben szintén említett multispektrális felvételek ingyenesen hozzáférhetőek bárki számára nagy idő- és térbeli felbontásban. Így ez utóbbiak a változások detektálására használhatók fel. A változások nem csak antropogén jellegűek lehetnek, a klímaváltozásra is visszavezethetők. A klímaváltozás során a magyar erdőket leginkább az évi középhőmérséklet emelkedése és a csapadék eloszlásának kedvezőtlen változása fenyegeti leginkább. Ezen káros hatások is könnyűszerrel kimutathatók a multispektrális felvételekből elkészített vegetációs indexek segítségével.

A hegyvidék erdőállományának elemzésében az egyes fafajok elkülönítésére, és a klímaváltozás faállományokra gyakorolt negatív hatásának kimutatására helyezem a hangsúlyt. A feladat elvégzése során célul tűztem ki, hogy megvizsgáljam a hiperspektrális felvételek alkalmazhatóságát a fafajosztályozás területén, ennek során felügyelt és nem felügyelt pixel alapú osztályozási módokat használtam. Továbbá a vizsgálati területemre NDVI (normalizált vegetációs index) értékeket is számítsak multispektrális felvételek alapján.

2. IRODALMI ÁTTEKINTÉS

A következőkben áttekintést nyújtok a Soproni-hegyvidék erdőállományáról, a távérzékelés tudományáról külön kiemelve ennek erdészeti felhasználását a hiper- és multispektrális felvételek feldolgozásának ismertetésén keresztül.

2.1 A Soproni-hegyvidék és erdőállományának jellemzői

A hegyvidék helyzetét és természetföldrajzi viszonyait ismertetném először, mely nagyban befolyásolja a rajta kialakított erdőállományt. A Soproni-hegység a Kőszegi-hegységgel egyetemben az Alpok-hegységrendszerének északkeleti a Kárpát-medencébe benyúló vonulata. Nagysága észak-déli irányban 13 km, míg nyugat-keleti irányban 17 km, területe körülbelül 185 km². Nyugatról a Sieggrabenbach-völgye, a Szikrai-nyereg és a Marzer Bach-völgye határolja. Észak-nyugati irányban a Vulka-medencével találkozik, míg északon a Klettenbach, az Ödenmühlbach és a Soproni-medence szab határt a hegység kiterjedésének. A Soproni-medencéhez csatlakozik az Ikva-sík, mely egyben az északkeleti határ. Keleti irányból már nehezebb megszabni, hol ér véget a Soproni-hegység. A határ a Harkai-kúptól keletre Harka település érintésével a Haschendorf-Neckenmarkt-Lackendorf-Lackenbach községek kijelölt vonal, mely a Kabold-Fülesi-dombvidék északi részéhez csatlakozik. Majd ezután a Weppersdorftól északra a Fuchsriegel déli részén ér vissza Sieggrabenbach-völgyébe (Szmorad, 2011).

2.1.1 A Soproni-hegyvidék geológiai viszonyai

A hegység magját főként kristályos, metamorf kőzetek építik fel, melyek túlnyomórészt a földtörténeti ókorban keletkeztek. Legtöbbjük savanyú kémhatású (csillámpala, durva gneisz, fillit, kvarcit). A miocén kor közepéig (helvét emelet) volt szárazulat a kristályos tönk, ekkor indult süllyedésnek a nyugati rész. Kialakult egy tektonikus árok, melybe édesvízi széntelepes rétegek és efölé rétegződött folyóvízi eredetű kavicsos üledékek rakódtak le. A 18. század közepétől két évszázadon keresztül bányászták a szenet a telepekből. A helvét emelet vége felé, a tortónai emeletben végbement tengerelőöntés során a megsüllyedt területek kerültek víz alá. A hegység lábainál agyagrétegek, míg Fertőrákos környékén lajtmészakó rétegek ülepedtek le. A Károly-magaslat meredek, keleti oldala feltételezhetően az egykori tengerpart pusztuló partja lehetett. A pliocénig víz borította az alacsony részeket, de üledék lerakódás a továbbiakban csak a várostól távol zajlott. A Pannon-tenger vízszintjének csökkenésével és az Alpok

nyúlványának emelkedésével komolyabb denudációs folyamatok indultak meg, melynek folyamányaként a hegység elnyerte mai formáját.

Két fő csoportra oszthatjuk a kőzeteket: a metamorf és az üledékes. Az előbbieket a Soproni Kristályospala Formációcsoportba sorolhatók be, mely üledékes és granitoid kőzetek polimetamorfózisával létrejött gneiszek, csillámpalák és különleges szerkezetű kőzettestek (disztén kvarcit, leukofillit) takarós összetételű összlete. Ezek közül kiemelhetjük a csillámpalát, mely a Soproni-hegység leggyakoribb kőzete. Általában üledékes kőzetek változó mértékű regionális metamorfózisával jön létre. A miocén korban zajló kéregmozgások során a kristályos kőzetek feldarabolódtak, és a megsüllyedt területeken üledékek rakódtak le. A hegység nyugati felén az üledékes kőzetek a legjellemzőbbek. Ezek leginkább kavicsos, konglomerátumos és márgás szerkezetűek.

2.1.2 A Soproni-hegyvidék éghajlati jellemzői

A Soproni-hegység jellegéből fakadóan a hőmérsékleti gradiens szabja meg a hőmérsékleti viszonyokat, melynek nagysága kb. $-0,9\text{ °C}/200\text{ m}$ a terepviszonyoktól függően. A leghidegebb területek a hegyvidék völgyeiben lelhetők fel. Az átlaghőmérséklet kb. $10,5\text{ °C}$ a hegylábi területeken, míg a hegytetőkön $9,0$ és $9,5\text{ °C}$ között alakul. A magasabb térszíneken található (300-400 m) völgyekben $8,5\text{ °C}$ – $9,0\text{ °C}$ -os érték a jellemző. Ez alapján több hőmérsékleti régióra oszthatjuk fel a hegységet. Az első az enyhe, gyakran széles Soproni-medence, a második a szélvédett völgyek (pl. Brenneri-völgy), itt a legnagyobb a hőingás, a harmadik a hegység Mucktól Harkáig tartó enyhébb, egyenletesebb hőmérséklet-járású keleti területe, és végül a negyedik Brennerbányától nyugatra elterülő leghűvösebb, legkiegyenlítettebb rész. A mért adatok szerint Sopron éves átlaghőmérséklete 2 °C -kal melegebb, mint a Hidegvíz-völgyé. Ne feledkezzünk meg a klímaváltozásról sem, az elmúlt évtizedekben a hőmérséklet emelkedő tendenciát mutat az év minden hónapjában.

A Kisalföldhöz képest a Soproni-hegyvidék komoly csapadéktöbblettel rendelkezik. A csapadéktöbbletnek két komponense van, egy orografikus (magassággal növekvő) és egy kelet-nyugat irányú. Az átlagos csapadékösszeg a hegylábi 200 m-es tengerszint feletti magasságon $628,4\text{ mm}$, míg az 500 m-es tengerszint feletti magasságú területeken $797,1\text{ mm}$. A Soproni-hegység területén a magasságból származó csapadéktöbblet értéke 42 mm/év , míg az országos átlag mindössze $30\text{--}35\text{ mm/év}$. A mért adatok alapján elmondható, hogy keleti irányban a

hegyvidéktől távolodva először drasztikusan (8-9 mm/km/év) végül kisebb (1-2 mm/km/év) mértékben csökken a csapadék mennyisége. Az elmúlt másfél évtizedben a csapadék mennyisége enyhén növekvő tendenciát mutat a Soproni-hegységben, és az éven belüli eloszlás is változott.

2.1.3 A Soproni-hegyvidék vízrajza

A Soproni-hegység vízháztartása nagyon kedvezőnek számít az országban. A lefolyási tényező a nagymennyiségű csapadéknak köszönhetően 20-25%. Ebből következően a hegyvidéken több forrás is található, a vízfolyások esetében viszont csak patakokról beszélhetünk. Északon folyik a 14,8 km hosszú Rák-patak (régebbi nevén Bánfalvi-patak), melynek vízgyűjtő területe 36,8 km², délen a Kecske-patak, amely 12,8 km hosszú, és 45,2 km² nagyságú vízgyűjtő területtel rendelkezik, ennek fele az osztrák oldalon található. A Kecske- és a Rák-patak is az Ikva vízrendszeréhez tartozik. Kultúrtörténeti érdekesség, hogy korábban a Rák-patakon 11 vízimalom üzemelt. Működésüket tekintve felülcsapott vízimalmok voltak. Ezek közül a tulajdonosa után Kárpáti-malomnak nevezett üzemel jelenleg is.

Két kisebb említést érdemlő mesterségesen felduzzasztott tó található a Soproni-hegyvidéken. Ezek közül a nagyobb a Görbehalom határában elhelyezkedő Fehér úti tó, a kisebb a Tacsi-árokban fellelhető Szalamandra-tó. Brennbergbánya környékén bányaművelés során keletkezett tavacsákak találhatók, a „Madisz”-tó és a Hermesi-tó.

A hegységben talajvíz csak a völgylejtőkön és talpakon fordul elő kisebb mértékben. Viszont az agyagos talajoknak köszönhetően a felszín közelében kialakuló vízzáró rétegek miatt, időszakosan a felszín közelében megjelenő talajvízzel is találkozhatunk. Hasadékvízként rétegvíz is megjelenhet. A vízzáró mélyebb rétegek vízszegények. Korábban már említettem, hogy több forrás is található a Soproni-hegységben. Ezek közül felsorolok néhány különlegesebbet: Deák-kút, Pedagógus-forrás és Fehér Dániel forrás (Hárs, 2019.).

2.1.4 A Soproni-hegyvidék talajtani viszonyai

A talajok létrejöttét az alapkőzet, a domborzat, a klimatikus jellemzők és az ezek eredményeként létrejött növényzet szabja meg. A Soproni-hegységben a talajok kialakulásához kedvező körülmények uralkodnak. Ennek köszönhetően főként barna erdőtalajokkal találkozhatunk. A nevében is benne van, hogy létrejöttéhez erdőre van szükség. A főtípus négy altípusát találjuk meg a hegyvidéken.

Az agyagbemosódásos barna erdőtalajok a teljes terület majd egyharmadán fordulnak elő (33,2%). Esetükben a humuszosodás, a kilúgzás, az agyagosodás folyamatait az agyagos öszszetevő vándorlása és közepes szintű savanyodás követi. Leggyakrabban löszön és egyéb üledékeken képződnek. Tipikus háromszintes talajok, jól felismerhető a szintekre tagozódás. A legtermékenyebb talajtípusok, melyek az erdők részére az ökológiai optimumot jelentik. Az agyagbemosódásos barna erdőtalajokon megtalálható erdőtársulások a gyertyános tölgyesek és bükkösök.

A hegységben legnagyobb részarányban (56%) a podzolos barna erdőtalajok fordulnak elő. A barna erdőtalajokra jellemző talajképző folyamatokon kívül a podzolosodás, az agyagásványok szétesése is felfedezhető, és a savanyodás is erősebb, mint az előző talajtípusnál. Alapkőzetük a hegyvidéken főként a bázisokban szegény gneisz, fillit, csillámpala és a nyugati területeken különböző üledékek. A podzolos barna erdőtalajokon a hegységben főként savanyú kocsánytalan tölgyesek, bükkösök tenyésznek, de luc-, erdei- és vörösfenyőt is fellehetünk rajtuk. A fekete áfonya, csarab és a fehér perjeszittyó, mint savanyúságot kedvelő növények, már messziről valószínűsítik ezen talajokat. Termőképességük az előzőekből fakadóan sajnos csak közepes.

A savanyú, nem podzolos barna erdőtalajok is nagy arányban (6,5 %) képviseltetik magukat. Ez a legsavanyúbb talajtípus, ahol az erőteljes savanyodás az acid mull típusú humuszosodáshoz, a kilúgzáshoz, illetve az agyagosodáshoz párosul. Alapkőzete elsősorban csillámpala, gneisz és leukofillit. A savanyúságot kedvelő növények szintén előszeretettel tenyésznek rajt. Nem a legkedvezőbb talajtípus az erdő számára. Főként acidofil tölgyesek, kocsánytalan tölgyesek fordulnak elő a savanyú, nem podzolos barna erdőtalajokon. A luc-, az erdei fenyő és a pionírok is kedvelik, és humid klímában a bükk is felbukkan rajt. A Soproni-hegyvidéken előforduló kevésbé jellemző talajokat csak felsorolás szinten említem: pszeudoglejes barna er-

dőtalaj, típusos réti talaj, réti erdőtalaj, lejtőhordalék talajok, öntéstalajok, lejtőhordalék és öntés erdőtalajok (Bidló, Gálos, & Kiss, 2019.).

2.1.5 A Soproni-hegyvidék erdőállományának jellemzői

Az egyes szerzők és az üzemterv adataiból szépen látszanak a jó két évszázad év alatt végbe ment változások. A jelentősen leromlott, agyon sarjztatott erdőket az erdőgazdálkodónak sikerült, olyan szálerdökké alakítani, melyek a termőhely szerinti potenciális fatermőképességgel bírnak. Ez a folyamat a számok nyelvén a következő, a szálerdő – sarjerdő arány az 1787-es 10:90-esről 1973-ra 75:25-re módosult. Ettől kezdve is évről évre tovább növekszik a mag eredetű szálerdők aránya, csak lassabb ütemben. A vágásforduló hossza több, mint 5-szörösére nőtt két évszázad alatt. Ezek mind egy irányba mutató pozitív változások, melyek az erdők általános állapotának minőségi javulását jelentik. Az egyes fafajokat szemlélve a különböző trendek figyelhetők meg.

A jövedelmezőség miatt a '900-as évek elejétől a fenyőket részesítették előnyben, ezért ezek aránya 1925-ig folyamatosan növekedett a lombosokhoz képest, majd több, mint 50 évig stagnál 50% környékén (1. táblázat). Aztán 1983-tól csökkenni kezdett a fenyők térfoglalása, mely a lucosok arányának csökkenéséből fakad. A '900-as évek második felében kiderült, hogy a hegyvidék klimatikus viszonyai nem megfelelőek ahhoz, hogy a lucfenyő stabil állományokat tudjon létrehozni. Már 1945 és 1950 között is feljegyeztek csekélyebb mértékű lucpusztulást. De a '80-as évek közepétől a '90-es évek végéig tartó időszakban öltött igazán drasztikus mértéket, mely során a hegyvidék lucfenyő állományának 2/3-a 550 ha-on elpusztult. Bár csekélyebb volumenben, de sajnos jelenleg is tart a megmaradt lucosok pusztulása. A vörös- és a feketefenyő térfoglalása az 50-es évektől napjainkig nézve viszonylag stabil.

A lombosok között a gyertyán és a nyír visszaszorulása szintén az állomány szerkezet javító intézkedéseknek tudható be. A tölgy aránya viszonylag stabil és az utóbbi évtizedekben növekvő tendenciát mutat, és jelenleg a legnagyobb a térfoglalása a hegyvidéken. A bükk előfordulása szintén növekedett a kezdetekhez képest, napjainkra pedig a tölgy után a legjelentősebb fafaj a hegyvidéken. Ez annak is betudható, hogy a lucosokat főként bükkösökre cserélték le (Köveskuti, 2019.).

A jelen erdőgazdálkodásának legnagyobb kihívása a klímaváltozás, mely változás sebessége a természetes folyamatokét jóval meghaladja, tehát a gazdálkodásnak kell erre elsősorban rea-

gálni. Emellett a szigorodó természetvédelmi korlátozások és az erdészeti kutatások eredményei előre vetítik a természet közeli és a folyamatos erőborítást biztosító üzemmódok egyre nagyobb térnyerését, ami városi erdőről lévén szó, egybeesik a lakosság igényeivel is.

1. táblázat A Soproni-hegység erdeinek eredet (szál-sarj) és fajaj szerinti megoszlásának változása (az adott évre vonatkozó erdőállomány-leírások és aktuális üzemtervi adatok alapján (Köveskúti, 2019.))

Időpont	1787	1837	1869	1875	1895	1925	1953	1963	1973	1983	1993	2003	2014
Forrás	Sárközy András	Oderszky János	Robert Micklitz - Friedrich Hollan	Slatinszky Adolf - Pausinger József	első üzemtervi reví- zió	üzemterv	üzemterv	üzemterv	üzemterv	üzemterv	üzemterv	üzemterv	üzemterv
Szálerdő (%)	10	8	5	10	34	68	71	73	75	75	75	75	75
Sarjerdő (%)	90	92	95	90	66	32	29	27	25	25	25	25	25
Vágásforduló	20	20	20-30	40	40-60	60-80	82	79	83	93	93	95	108
Fafajok													
Tölgyek		30			24	26	26	27	29	31	32	33	33
Bükk		8			8	5	6	6	6	8	11	17	22
Gyertyán		30			27	14	11	12	9	6	6	6	6
Egyéb kl		1			1	2	2	-	1	1	1	3	3
Nyír		28			21	2	3	4	3	3	3	3	2
Éger		1			1	1	1	1	1	1	1	1	1
Lucfenyő		1			11	30	26	26	27	26	21	12	9
Jegenyefenyő		-			-	1	1	1	1	1	1	1	1
Vörösfenyő		-			3	6	9	8	7	8	9	10	11
Erdeifenyő		1			3	10	13	13	14	13	13	12	10
Feketeftenyő		-			1	3	2	2	2	2	2	2	2
Lomb		98	95	90	82	50	49	50	49	50	55	63	68
Fenyő		2	5	10	18	50	51	50	51	50	45	37	32

2.2 A távérzékelésről általában, távérzékelési módszerek alkalmazása az erdészeti gyakorlatban

Nem tévedünk nagyot, ha kijelentjük a távérzékelési és térinformatikai módszereknek a jövőben még a mainál is nagyobb szerepe lesz az erdészeti kutatásban és gyakorlatban. A rendelkezésre álló adatok mennyisége nő és minősége (felbontása) folyamatosan javul. A távérzékelés során közvetlen fizikai kontaktus nélkül szerzünk információt a megfigyelés tárgyáról. Összehasonlítva az *in situ* eljárásokkal ezen módszerek sokkal nagyobb területről egyidejűleg bocsátanak rendelkezésünkre adatokat. Egyes területek korábbi állapotáról kizárólag távérzékelte felvételek alapján tájékozódhatunk. Bizonyos földmegfigyelő műholdak esetében a felvételek akár negyven évre visszamenőleg előkereshetők, ha légi fényképre gondolunk, ez az időintervallum akár száz évre is kiterjeszthető. Viszont a távérzékelési módszerekkel a földfelszínről szerzett információ csak részleges, ezért egyéb adatokkal kombináltan célszerű elemezni. A földrajzi információs rendszerek (FIR, GIS) kitűnően alkalmasak a különböző forrásokból eredő adatok összevont elemzésére. Összességében kijelenthető, hogy a távérzékelési eszközök és eljárások segítségével új horizontok nyíltak a környezet monitoringban.

2.2.1 A távérzékelés története

A távérzékelés alaptézise az elektromágneses energia és az anyag kölcsönhatásának vizsgálatán alapul. Ezen gondolatok 1947-ből Krinov orosz tudóstól származnak. A távérzékelés előzményeinek felkutatásához viszont sokkal korábbra kell az időben visszamenni. Már az 1800-as évek közepe táján megindult a ballonról történő fényképezés. A Császári és Királyi Hadserg katonái (közismertebb nevén k. u. k. Armee) az első világháború során légi fényképeket használtak az ellenséges vonalak felderítéséhez (Bakó, 2014.). Az akkori háború helyzet okozta nyomás tehát nagyot lendített a távérzékelés tudományának szekerén. Említést érdemel még, hogy a XX. század folyamán kísérleti rakétákról is történt fényképezés.

A távérzékelés kifejezést viszont csak az első műholdak megjelenésétől használják. Az első űrfelvételt 1959-ben az Explorer-6 amerikai műhold készítette a Földről. Az első erőforráskutató műholdat, az ERTS-1-et (később Landsat 1) 1972-ben lőtték fel. A '80-as évekig kizárólag a Szovjetunió és az USA műholdjai keringtek az űrben, ettől kezdve azonban mind több és több ország lőtt fel katonai és polgári műholdakat. Végül megjelentek az állami műhold-

programok mellett a magán műholdprogramok, melyek tovább gyorsították a fejlődést. Jelenleg a Landsat-sorozat 9 műholdnál tart, míg a SPOT már 7 tagot számlál.

A szenzorok és az adatátviteli technikák fejlődése, az adattároló kapacitás bővülése egyaránt elősegítették az egyre nagyobb információ tartalmú felvételek készítését. A térbeli felbontás ennek köszönhetően 80 m-ről (Landsat MSS) 34 cm-re (Geoeye-2 pankromatikus sáv) nőtt. Mindeközben főként a légi távérzékelésben (AVIRIS, DAIS, AISA...) előtérbe került a hiperspektrális technika is, mely több mint 20, nagyon keskeny sávban (2-10 nm) végzi a felvételezést. De az űrtávérzékelésben is találhatunk rá példát. Ezen felvételek feldolgozásához szükségesek a kiegészítő adatokat szolgáltató nem képalkotó eszközök, a kézi radiométerek. Viszont egyelőre még a technika határt szab a lehetőségeinknek, tekintettel a feldolgozandó adatmennyiségre és a feldolgozás időigényére. El kell döntenünk, hogy mire szeretnénk a felvételeket felhasználni, és ennek tükrében mire van szükségünk. Mert a felvételek térbeli és spektrális felbontása nagyon különböző lehet, ebből következően a méretük és a feldolgozási időigény is nagyon változó.

Az űrtávérzékeléssel párhuzamos fejlődésen ment keresztül a légi távérzékelés is. A repülési idő flexibilis megválasztása lehetővé teszi a terepi mintavételezéssel való kombinálásra. A vegetáció-térképezési célokra az '50-es években főként a színes infravörös légifelvételeket használták. Jelenleg a légi hiper-, és multispektrális, valamint az aktív radar és lidar eszközöket egyaránt alkalmazzák a vegetáció- és erdőtérképezésben.

Nem mehetünk el szó nélkül az informatika nagyléptékű fejlődése mellett sem, mely lehetővé tette a digitális felvételek és előfeldolgozási-elemzési módszerek széleskörű elterjedését. A nagy térbeli felbontás miatt pixel alapú feldolgozási módszerek mellett megjelentek az objektum alapúak. Új szoftverek és ezekbe beépített új elemző algoritmusok jelentek meg.

2.2.2 A távérzékelés felhasználási területei, általánostól az erdészetiig

A távérzékelés legfontosabb területe napjainkban a természeti erőforrások kutatása, mely az ezekkel való hatékonyabb gazdálkodást hivatott elősegíteni. A természeti erőforrások klasszikus felosztása szerint nem megújuló (fosszilis) és megújuló (pl.: napsugárzás) erőforrásokról beszélhetünk. A megújulón belül kiemelhető a vízkészlet, talajkészlet (földértékelés, talajtérképezés) és a kialakult növényzet, mint biomassa (vegetációtérképezés és állapotbecslés) felmérésének fontossága. A klímaváltozás következtében az egyre fokozódó a szélsőséges jelen-

ségek (vihar, aszály, szökőár) és hatásaik elemzése szintén elsődleges feladat. Az ember és tevékenységének (ipar, bányászat, agrárium) környezetre gyakorolt hatása korunk legnagyobb problémája, ennek felmérése és ez alapján az ésszerű terület- és földhasználat tervezése kulcskérdés. Az említettek időbeni változásának monitorozása lehetővé teszi a modellezés segítségével a jövőbeni folyamatok előrejelzését.

A távérzékelés történetének magyar erdészeti fejezete már több, mint 150 éve íródik. Már 1854-ben említette tanárának Újsághy Zsigmond erdőmérnök-hallgató a fényképekre alapuló térképezés elvét. Aztán az első magyar erdőtörvény az 1879. évi XXXI. törvénycikk előírta az üzemterv szerinti erdőgazdálkodást, amihez elengedhetetlen volt az erdők felmérése, térképezése és a területük számítása. A térképek a készítési mód és a külalak szempontjából változatlanok maradtak a II. világháborúig. Az 1896-os Ezredéves Kiállításon bemutatásra került jó néhány erdészeti térkép. Az 1900-as párizsi nemzetközi kiállításon Csiby Lőrinc térképei számos díjat nyertek. Az első magyar nyelven megjelent fotogrammetriai mű Jankó Sándor munkáját dicséri, melyet 1917-ben Pozsonyban adtak ki. Az 1930-ban megjelent „Fotogrammetria az erdőgazdaság szolgálatában”-t Sébor János jegyzi.

Az 1948-as ideiglenes erdőrendezési utasítás alapján az ideiglenes üzemtervekhez 1:75 000-es méretarányú átnézeti térképvázlatot és terület-kimutatásokat kellett mellékelni. Ez hagyományos módszerekkel nagyon időigényes lett volna, ezért az ERTI erdőrendezési osztályának akkori vezetője, Bezzegh László egy fotogrammetriai módszer kidolgozásába kezdett a honvéd térképészek Wild A5-ös autográfjának segítségével. Viszont csak 1951-ig folytatták a munkát. Az Erdészeti Földméréstani Tanszéken Sébor János vezetésével elsősorban földi fotogrammetriával foglalkoztak 1952-1956 között. Az erdőrendezés 1959/60-tól kezdett ismét fotogrammetriával dolgozni, a munkához egy Zeiss Stereotopot és Zeiss C5 típusú sztereoplániráfot használtak. Az előző üzemtervezés 1:10 000-es térképeit egészítették ki. Az Erdészeti és Faipari Egyetem munkatársai Teszárs Géza adjunktus vezetésével 1960-ban elkészítették a Soproni-hegység első erdészeti légifényképezését, mely erdészeti szempontból országosan szintén az első volt. A 60-as évektől az erdőrendezési gyakorlatban folyamatosan nőtt a léfényképezett területek nagysága. Legjobban az 1:10 000-es fekete-fehér képanyag vált be.

Főként Czimmer Kornélnak köszönhetően az EFE Földmérési és Távérzékelési Tanszékén 1996-ban elkészült a STEREO program, melynek segítségével lehetővé vált a digitális sztereófotogrammetriai kiértékelés. Majd 1997-ben létrejött az IMAGE digitális képfeldolgozó

program, mely magában foglalta az ortofotó-előállítását. Az ortorektifikáció megvalósításával pedig bevonult a történelembe, mint az első ilyen magyar fejlesztésű program. „A Fertő-Hanság NP és a Szigetközi TK földrajzi információs rendszerének (GIS) kifejlesztése” című projekt az ortofotóhoz kapcsolódó kutatásokat segítette elő, mely során az EFE FTT munkatársai kiváló minőségű ortofotó-mozaikokat készítettek 1:30 000-es infraszínes légifényképek felhasználásával Győr-Moson-Sopron megye védett területeiről.

Az erdőrendezési gyakorlatban 2000-ben vezette be az akkori Állami Erdészeti Szolgálat a digitális térképezést. Ennek ellenére az egyes űrfelvételekben rejlő potenciált még mindig nem használják ki kellően. Bár az utóbbi években voltak biztató példák, az erdőrendezési gyakorlat nemzetközi trendjeitől jelentősen le vannak maradva.

Ha nemzetközi kitekintésben vizsgáljuk meg a távérzékelés erdészeti szerepét, megállapíthatjuk, hogy ott van a legfontosabb szerepe, ahol az erdészeti szakmának nincsenek komoly gyökerei. Azon jelentős erdőterülettel rendelkező országokban, ahol nincs erdészeti szakigazgatás, jelentősége elengedhetetlen. Erre példának hozhatók fel a trópusi esőerdők övében elhelyezkedő egyes afrikai országok. Ennek hazánk pont az ellentettje, mert jelentős múltú az erdészeti szakigazgatás, így a távérzékelésnek csak kiegészítő szerep jut a terepi felvételezés mellett. A '90-es évektől jelentek meg a globális erdészeti erőforrás-felmérések (pl.: Global Forest Resources Assessment – FRA 2000), melyek a távérzékelés segítségével valósíthatók meg.

A kifelbontású űrszenzoroknak a globális változások monitorozásában nagy szerepük van. Az Európai Erdészeti Intézet (European Forest Institute, EFI) a NOAA (National Oceanic and Atmospheric Administration, Egyesült Államok) műholdakra felszerelt AVHRR (Advanced Very High Resolution Radiometer) szenzorok által készített felvételek és az erdőnyilvántartási adatok felhasználásával készítette el Európa erdőterképét 2000/2001-ben. A Corine Land Cover felszínborítási adatbázis alapján erdő típusokat különítettek el: tűlevelű erdő, lomblevelű erdő, vegyes erdő, egyéb fával borított terület.


A természetes folyamatok (különös tekintettel a katasztrófákra) és az emberi tevékenység hatásainak, és magának az erdőállapotának felmérésére létrehozott monitoring rendszerekben a távérzékelés fontossága elengedhetetlen, és egyúttal lehetővé teszi a hosszú távú folyamatok

modellezését is. Hazai berkekben legjelentősebb erdészeti monitoring rendszerek a következők, az Erdővédelmi Hálózat (EVH) és a Folyónövedék megfigyelési hálózat (FNM).

A különböző felbontású felvételeket eltérő célokra lehet felhasználni az erdőtérképezésben. A kis és közepes felbontású felvételek felhasználási területei a következők: a felszínborítás meghatározása (erdő-nem erdő), erdő típusok elkülönítése, károk térképezése, vegetációs index monitorozása és felújítások nyomon követése. A nagy felbontású légi és űrfelvételek alkalmasak fafaj meghatározásra, faállomány jellemzők (záródás, törzsszám, elegyarány) és a faállomány szerkezeti paraméterek (famagasság, lombkorona méret) meghatározására, és ezek alapján a fatérfogat becsülhető. A hiperspektrális felvételek felhasználási területei a fafaj és elegyarány meghatározás, egészségi állapot térképezés és a levelek kémiai anyag tartalmának vizsgálata. A légi lézeres letapogatás szintén alkalmas a famagasság, törzsszám, lombkorona méret meghatározására és a fatérfogat becsülésére (teljes jelalakos letapogatás). Ha lézeres letapogatást még földi fotogrammetriával is kiegészítjük szinte az összes faállomány jellemző (fafaj) és szerkezeti paraméter mérhető (mellmagassági átmérő, körlapösszeg, magasság) és becsülhető (fatérfogat).

2.2.3 A távérzékelés során használt szenzorok típusai

Jelenleg a gyakorlatban használt érzékelők különféle fizikai mennyiség mérésére használhatók. Az 1. ábra szemlélteti a távérzékelés folyamatát.



1. ábra A távérzékelési adatgyűjtés folyamata (Belényesi, és mtsai., 2013)

A folyamat szereplői: adóegység, sugárforrás; vizsgált objektum; hordozóeszköz (platform); érzékelő (sensor). Az érzékelőket működési elvük alapján aktív- és passzív szenzorokra csoportosíthatjuk. A passzív szenzorok legfőbb jellemzője, hogy nem bírnak saját sugárforrással. A természetes fényt (elektromágneses sugárzás) érzékelik, ez lehet a visszavert napfény vagy a tárgy részéről kibocsátott sugárzás. Jó példa rá a fényképezőgép, a multispektrális és termális szkennerek. Az aktív érzékelők bírnak saját sugárforrással. A szenzor az általa kibocsátott sugárzás visszavert részét érzékeli. Ebbe a csoportba sorolhatók a radarok, melyek a mikrohullámú, és a lidarok, amelyek pedig az ultraibolya, látható és az infravörös sávban érzékelnek. Ezek alapján a hullámhossztartomány szerint is csoportosíthatjuk a szenzorokat. Az optikai tartományban a passzív kamerák nagy része, míg a mikrohullámú tartományban a radarok és a mikrohullámú radiométerek érzékelnek.

A hullámhossztartományok száma és szélessége szerint három fő csoportba soroljuk az érzékelőket. A pankromatikus szenzor egy széles sávban állít elő felvételeket (pl. teljes látható tar-

tomány). A geometriai felbontásuk kitűnő. A multispektrális szenzorok az optikai tartományban érzékelnek aránylag széles sávban. A sávok elhelyezése idomul a megfigyelésre alkalmas légköri ablakokhoz és azokhoz a hullámhossz-tartományokhoz, melyek a megfigyelendő objektumok spektrális jellemzői alapján a leginformatívabbak. Az erőforrás-kutató műholdak többsége ilyen szenzorokat hordoz. Korábban főként a szélessávú (broadband) szenzorok voltak használatban, melyek több 10 nm-es sávokon dolgoznak. Ma már a keskeny sávú (narrow band) érzékelők is elterjedtek, melyek a szűkebb hullámhossz-tartományokhoz rendelhető tulajdonságokat (pl. vörösel, „Red Edge”) vizsgálatát teszik lehetővé. A mai érzékelők nagy hányada a szűkebb és tágabb sávok egyszerre történő felvételezését valósítja meg. A hiperspektrális szenzorok húsznál több (250-300 is lehet), nagyon keskeny (2-10 nm) sávban érzékelnek. A nagy spektrális felbontás mellett a geometriai felbontás is kitűnő, ezért a hatalmas adattömeg feldolgozási igénye következtében aránylag kis területek felvételezését teszi lehetővé. A képek összes pixel reflektanciája sok szűk, egymással szomszédos hullám-hossztartományú értékkel írható le, amely folyamatos reflektancia görbét ad. Repülőre szerelhető változataik: AISA, DAIS. Űrszenzor pedig a Hyperion. Az érzékelők legtöbbször paraméterezhetők, a fixált hullámhossz-tartományok és a geometriai felbontás a felmérés tárgyához igazítható.

A hordozó eszköz alapján is csoportosíthatjuk a szenzorokat. Feladatuk az érzékelők megfelelő helyre juttatása a megfelelő érzékelés szempontjából. A kézi szenzorok egy-két méteren készítik a képeket. Ilyen nem képalkotó műszerek (FieldSpec, HandySpec). A légi szenzorokat hordozhat kisebb magasságban sárkányrepülő, nagyobb magasságban repülőgép (pl. hiperspektrális érzékelők). Az űrszenzorokat a műholdak cipelik. Előnyük, hogy nagy területekről állandó adatszolgáltatást biztosítanak (pl. Hyperion).

A geometriai felbontás alapján kis-, közepes-, és nagyfelbontású felvételeket készíthetünk. Kis felbontású a 100 m-nél nagyobb pixel méretű felvétel, míg nagy felbontású a 1 m-nél kisebb pixel méret esetén. Általában elmondható, hogy a nagyobb hullámhossz-tartományban rosszabb a képek geometriai felbontása, mert az energiával a hullámhossz fordítottan arányos, emiatt nagyobb területről gyűjti be a minimálisan érzékelhető energiamennyiséget. Hála a detektor-technológia fejlődésének a felbontás nagysága minden tekintetben folyamatosan növekszik.

A szenzorok által gyűjtött információ is lehet geometriai és spektrális. A geometriai információ a tárgyak helye, felülete, alakja. A földi pixelméret egy fontos jellemző, mely megmondja a képi pixel valós, terepi kiterjedését. A spektrális információ az objektumról érkező sugárzás nagysága.

Erdészeti szempontból kiemelt fontosságúak a passzív optikai- és lézeres letapogató szenzorok (LIDAR).

2.2.4 A passzív optikai felvételek előfeldolgozása során alkalmazandó korrekciók

A felvételezés során tapasztalt fizikai körülmények és az észlelés, a képek rögzítésének jellemzői következtében a felvételeken lévő értékekből közvetlenül nem határozhatjuk meg a megfigyelt objektumok tulajdonságait, mert radiometriai és geometriai torzulásokkal terheltek. Ennek kiküszöbölésére különböző korrekciókat alkalmazunk. Az abszolút korrekció esetében a fizikai viszonyok pontos ismerete és jelentős számú bemeneti paraméter ismerete szükséges, segítségével ismert pontossággal korrigálhatók a torzító hatások. Az abszolút korrekció során a felvétel létrejöttének időpontjában a felszínen észlelt reflektancia értékekkel korrigáljuk a felvétel DN (Digital Number) értékeit.

A relatív korrekciók a képek pixel értékein alapulnak, ismert, vagyis állandó reflektancia jellemzőkkel rendelkező területhez viszonyítjuk adatainkat. Jelentősen kevesebb bemeneti paraméter ismerete szükséges, mert statisztikai jelzőszámokat és közelítéseket használ a torzítások korrekciójára.

A hibrid módszer a kétfajta technika vegyítéséből származik, így mindkét módszer előnyeivel rendelkeznek. A fizikai módszer pontosságát szinte eléri, és jelentősen kevesebb bemeneti paraméter ismerete szükséges.

A felvételeken tárolt radiometria érték sok természetes és mesterséges hatásnak köszönhetően nem egyezik meg a felszínről kiinduló sugárzásmennyiséggel, tehát a képek nyers pixelértékei nem vethetők össze közvetlenül egymással. Idősoros felvételek vizsgálatánál nagy jelentősége van ennek. Az abszolút radiometria korrekció során először a radianciát számítjuk. A képek készítésekor, a digitalizálásnál az analóg jelből meghatározott időközönként mintát vételezve kódolt számértékekkel (DN) írjuk le nagyságát. A DN értékek legtöbbször a radianciával arányos értékeket jelölnek. Tehát a DN értékekből visszafejthető a spektrális radiancia, így kiküszöbölhetjük a szenzoröregedés okozta hatásokat. Ezután még ki kell számítanunk a légkörön

kívül mért látszólagos reflektanciát, ezzel kiküszöbölhető a Föld-Nap távolságokból, napállás-szögekből és a Nap sugárzási teljesítményéből eredő globális hatás.

A légköri hatások fizikai modellezésén nyugvó korrekciója régóta igen jelentősen kutatott téma, melyben nagy eredményeket mutatnak fel. A kutatók nagyszámú légköri sugárzástranszfer-kódot hoztak létre a légkör és a sugárzás kölcsönhatásainak interakciójának bemutatására. A modellekhez jelentős számú bemeneti paraméter ismerete szükséges: szenzortulajdonságok, felvételi geometria, Nap pozíciója, légköri körülmények és földfelszíni reflektancia. Mivel a régebbi felvételek esetén ezek nem mindig állnak rendelkezésre, ezért jelentős számú hibrid és relatív korrekciós módszert hoztak létre. Lehetőség van még standard légköri modellek, légkörprofilok használatára, melyek számítása hosszú távú méréseken alapul, ezért pont a legváltozékonyabb és legnagyobb hatást gyakorló összetevőket korrigálására alkalmatlanok.

A relatív radiometriai korrekciók közé sorolhatjuk a topográfiai hatások korrekcióját, mely főként a jelentős domborzattal bíró területeken jelentkezik.

A felvételek geometriai torzulásának korrekciója szintén nagy jelentőséggel bír a távérzékelésben. A térbeliség, amely a felvételen lévő adott pixel képmátrixbeli (pixelsorok (i), pixeloszlopok (j)) és a terepen ennek megfelelő felszíndarab (x,y) koordinátái, igen jelentős szerepet játszanak az előfeldolgozásban. Az azonos területről különböző időpontban készült felvételek és egyéb adatok közötti kapcsolatot jelentik. Ezért a geometriai korrekciók elengedhetetlenek az elemzések során. Jelenleg a szolgáltatók az alapvető hibákat korrigálják. Nekünk az a feladatunk, hogy a további korrekciókat megtegyük. Nagyon fontos, hogy a vizsgálni kívánt felvételek és más adatbázisok részére egy közös referencia koordinátarendszert hozzunk létre. Ez a referencia koordinátarendszer legtöbbször valamely földrajzi koordináta-rendszer (Belényesi, és mtsai., 2013). A hiperspektrális felvételek felhasználási területeinek részletesebb bemutatását a 3.1-es fejezet részben fogom bemutatni.

3. ANYAG ÉS MÓDSZER

A távérzékelési módszerekkel készített egyes felvételek a szenzorok típusától függően más-más alkalmazási területek igényeit elégítik ki. Ha ebből indulunk ki, először érdemes átgondolni, milyen típusú információra lenne szükségünk, majd megkeresni ehhez a megfelelő technikát.

3.1 A hiperspektrális felvételek alkalmazási területeinek bemutatása

A dolgozatom célja a hiperspektrális felvételek elemzése, ezért a témához kapcsolódó kutatási eredmények ebben a fejezetben kerülnek ismertetésre. A hiperspektrális felvételek erdészeti felhasználásának sokrétűségét az irodalomban fellelhető gyakorlati példákon keresztül fogom megvilágítani. A hiperspektrális felvételek legfontosabb jellemzői a nagy spektrális és geometriai felbontás, amelyek alkalmassá teszik az erdőállományok minőségi és mennyiségi mutatóinak detektálására. Az első magyarországi képalkotó spektrométeres repülés alkalmával készült hiperspektrális felvételek feldolgozása során Hargitai elsődleges célja az erdőtípusok elkülönítése volt (Hargitai, 2006). A szerző véleménye szerint az akkori multispektrális felvételek alapján az erdőtípusok mélyebb elkülönítésének automatizálása nem volt lehetséges, ezért fordult a hiperspektrális felvételek irányába.

A hiperspektrális felvételeket fafajok elkülönítésre is használhatjuk. Főként nagy területek esetében megkönnyítheti a fafajok elterjedésének térképezését. Kitűnő példa erre Kanada. A Gulf-szigetek Nemzeti Park területén T. G. Jones és munkatársai hiperspektrális (AISA) és LiDAR adatok alapján 11 fafaj térképezését végezték el (Jones, Coops, & Sharma, 2010.). A LiDAR adatok a szakirodalomban gyakran felbukkannak a hiperspektrális felvételek mellett, mert segítségével nagyobb pontosság érhető el az osztályozás során. A nemzeti park területén végzett felmérés során négy különböző módszer pontosságát hasonlították össze. Az osztályozási technika minden esetben az SVM (támasztó vektoros eljárás, a későbbiek során ismertem) volt. Az első módszer csak a hiperspektrális adatokra hagyatkozott, a második kiegészült magassági adatokkal, míg a harmadik a négy lombkoronaszintbe való besorolással, a negyedik módszer esetén pedig csak két lombkorona szintet különböztettek meg. Az fafaj osztályozás pontossága csak a spektrális adatokkal 60% és 90% közé esett általában, de voltak 90% feletti értékek. Ez utóbbiak természetesen egyes fenyő fajknál fordultak elő. A szerzők a kö-

vetkező következtetésekre jutottak, nem minden fafaj esetében nyújtanak nagyobb pontosságot a szerkezeti információk, de általánosságban elmondható, hogy a térbeli és magassági adatok nagyobb pontosságot eredményeznek, mint a csak spektrális adatok alapján végzett osztályozás. T. G. Jones és munkatársai fontosnak tartották még kiemelni, hogy a hiperspektrális/LiDAR adatok beszerzése és feldolgozása feleannyiba kerül, mint a légi felvételeken alapuló hagyományos erdőleltár. Bár tegyük hozzá mindkettő más-más információkat szolgáltat az erőről. Így a hiperspektrális/LiDAR adatok feldolgozásával nyert információk jól kiegészíthetik a hagyományos erdőleltár adatállományát.

Nagyon hasonló következtetésre jutottak M. Dalponte és munkatársai a Pó síkságon található „*Bosco della Fontana*” rezervátum komplex szerkezetű erdőállományának vizsgálata során (Dalponte, Bruzzone, & Gianelle, 2008). Szintén hiperspektrális és LiDAR adatokat használtak a kiértékeléshez. Annyi különbség adódott a mintaterületen kívül, hogy a több osztályozási módszert is összehasonlítottak. Az eloszlásmentes SVM osztályozó bizonyult a leghatékonyabbnak a parametrikus kovariancia analízissel kombinált Gauss-féle maximális valószínűséggel és a k-legközelebbi szomszéddal szemben. A domináns fafajok (*Carpinus betulus*, *Juglans regia*, *Platanus hybrida*, *Quercus rubra*) esetében elérhető volt a 85-90%-os pontosság. Viszont a főként elegyben megtalálható fajoknál akár 50%-nál is alacsonyabb volt a pontosság, a LiDAR adatok a legtöbb esetben javítottak a pontossági értékeken. A LiDAR adatok bevonása az elemzésekbe nagyban megkönnyíti a hasonló spektrális jellemzőkkel bíró, de különböző magasságú fajok elkülönítését. Összességében kijelenthető, hogy a hiperspektrális és a LiDAR adatok együttes alkalmazása csökkenti a számítási időt és a növeli az általánosítás lehetőségét, tehát csökkenti a költségeket. A példák jól mutatják, ha egy kanadai és olasz kutató csoport is ugyanarra az eredményre jutott két teljesen különböző mintaterületen, a módszer alkalmazhatósága bizonyított.

Még egy finn példát citálnék a hiperspektrális és LiDAR együttes alkalmazásának témakörébe Európa északi Finnország déli boreális zónájából (Mäyrä, és mtsai., 2021.). Általánosságban kijelenthető, hogy az erdészeti célból végzett távérzékelési felvételezések főként az erdők gazdasági szerepe szempontjából fontos paramétereket és fajokat célozzák meg. Így az alacsonyabb gazdasági értékű, de ökológiailag nagy szereppel bíró fajok háttérbe szorulnak. J. Mäyrä és munkatársai ezen fajok detektálását célozták meg a már sokat emlegetett hiperspektrális és LiDAR adatok kombinálásával, kiegészítve még földi referencia adatokkal. Az osztá-

lyozáshoz az SVM mellett alkalmazták még a 3D-CNN (3 dimenziós konvolúciós neuron háló), a véletlen erdő, a gradiens növelő és a mesterséges neurális háló (ANN) osztályozó módszereket. A norvég luc, erdei fenyő, nyír fajok és a rezgő nyár detektálása volt a cél. Az osztályozók közül a 3D-CNN eljárás teljesített a legjobban. A 4 m-es felbontású felvételek esetében a rezgő nyár osztályozásának F1-próba értéke 0,91, az összes fajnál 0,86, míg az összesített pontosság 87% volt, a 10 m-es felbontású felvételeknél az F1-próba értéke az összes fajnál 0,83, és az összesített pontosság 85%. Az SVM és az ANN osztályozók F1-próba értékei a vizsgált fafajokra vonatkozóan 0,8 feletti, és az összesített pontosság értéke mindkét eljárásnál szintén 80% feletti, de alacsonyabbak a 3D-CNN eljárás pontosságánál. Megállapítható, hogy a 3D-CNN osztályozó hatékonyabb volt a tűlevelű fajok és a rezgő nyár elkülönítésében a referencia modelleknél. Az előző publikációkhoz képest egy új eredmény, hogy van egy osztályozó, ami hatékonyabb, mint az SVM.

Az előzőekben említetteken kívül a hiperspektrális felvételeket használják az invazív fajok terjedésének térképezésére is. Yuki Hamada és munkatársai *Tamarix* fajok terjedésének vizsgálatára nagy térbeli (0,5 m) és spektrális (4 nm) felbontású, vagyis hiperspektrális felvételeket használt (Hamada, Stow, Coulter, Jafolla, & Hendricks, 2007.). Többféle osztályozási eljárást is teszteltek. A mintaterület a dél-kaliforniai folyóparti élőhelyeket foglalta magában, mivel az inváziós növény fajok megjelenésének veszélye a mediterrán ökoszisztémákat jobban érinti. Az objektum alapú értékelés azt mutatta, hogy a hierarchikus klaszterezés által kiválasztott négy optimális spektrális sáv a leghatékonyabb osztályozási megközelítés.

A fafaj osztályozáson és egy adott faj elterjedési területének térképezésén túl a hiperspektrális felvételek erdőszerkezeti paraméterek vizsgálatára is kitűnően alkalmasak, ezt M. A. Cho és munkatársai az olaszországi Majella Nemzeti Park területén fekvő bükkös erdőállományról készült felvételek elemzése során mutatták be (Cho, Skidmore, & Sobhan, 2009.). A bükkös állományok lombkoronája általában zárt, ezért a távérzékelési módszerekkel mindig kihívást jelentett az ilyen állományok tanulmányozása. A vizsgált paraméterek az átlagos mellmagassági átmérő, az átlag magasság és a záródás volt. Az elemzéshez felhasznált eljárások a legkisebb négyzetek módszere (PLS) és a különböző vegetációs indexek (NDVI, standard VI, új VI). A PLS módszer enyhén jobban teljesített, mint a lineáris regresszióval számolt VI-k, de itt is elég nagy volt az előrejelzés hibája (27,6% átlagos mellmagassági átmérő, 35,8% átlag magasság, 48,3% záródás esetében). Ezek a magas hiba értékek az állomány heterogenitásá-

nak voltak köszönhetőek. Megállapítható, hogy a legkisebb hibával becsülhető paraméter az átlagos mellmagassági átmérő volt.

3.2 A Soproni-hegyvidékről készült hiperspektrális felvétel és ortofotó jellemzői


Az EnviroSens Hungary Kft. a Soproni-hegyvidékről a Soproni Egyetem megbízásából 2021-ben készítette egy repülőre szerelt hiperspektrális kamerával (érzékelő leírása: Kestrel10, Lumo - Recorder v2020-558) azt a légi felvételt, melyet további adatfeldolgozásra megkaptam az egyetem Geomatikai és Kultúrmérnöki Intézetétől. A felvétel 169 sávból áll, és terepi felbontása 1 m-es. Emellett a repülés során készült RGB színsávós légifénykép is, az ebből készült ortofotó szintén rendelkezésre állt. Ennek terepi felbontása 15 cm. A passzív optikai felvételek előfeldolgozása során elvégzendő korrekciókat a felvételt készítő cég elvégezte. A feldolgozás további lépéseinek elvégzése már az én feladatomat képezte. A hiperspektrális felvételek nagyszámú sávjának adatai általában összefüggnek egymással (Kertész, 2014). Ezért van szükség a képtranzformációs eljárásokra, mert segítségükkel informatívabbá tehetőek a felvételek. Az általam kiválasztott tranzformációs eljárás az MNF (minimum noise fraction), a 3.3.1-es fejezetben taglalom az egyes tranzformációs eljárásokat. Az osztályozást a tranzformált felvételen végeztem el, melynek célja az egyes fafajok meghatározása.

3.3 A hiperspektrális felvételek feldolgozása az ENVI szoftver felhasználásával


Az általam használt képelemző szoftver az ENVI 4.7-es verziója, mely szoftver licencével a Soproni Egyetem Geomatikai és Kultúrmérnöki Intézete rendelkezik. Segítségével szinte minden típusú adat feldolgozható: multispektrális, hiperspektrális, termikus, LiDAR és SAR. Programozási ismereteket nem igénylő, könnyen tanulható GIS-szoftver. A hiperspektrális felvételek feldolgozásához szükséges eszköztárral rendelkezik.

3.3.1 A távérzékelte felvételek transzformálása

Jellemzően az osztályozás során nem fogom a hiperspektrális felvétel összes sávját használni. A nagy adatmennyiség és a hibás csatornák miatt különböző képjavító eljárásokat alkalmazhatunk. Ezek az ENVI-ben, mint beépített transzformáló modulok állnak rendelkezésre. Ezek segítségével végezhetünk zajszűrést, információ kiemelést, kontrasztfokozást stb. A 2. ábrán láthatjuk a még transzformáció nélküli felvételt, a 3. ábrán pedig az adott spektrális sávok hisztogramjait.




2. ábra A hiperspektrális felvétel RGB-színsávós képe




3. ábra A hiperspektrális felvétel adott spektrális sávjainak hisztogramja

A PCA (Principal Component Analysis) egy olyan lineáris transzformáció, mely új képsávokba rendezi a többsávós kép varianciáját, ezzel a művelettel információ kiemelést végez. Az eredeti sávok korrelálatlan lineáris kombinációiból kerülnek ki az új képsávok. A főkomponens analízis új ortogonális tengelyeket hoz létre, amelyek origója az adatátlagnál található, a tengelyeket el is forgatja úgy, hogy az adatok varianciája maximalizálódjon. Első lépésben a felvétel kovariancia- vagy korrelációs mátrixának számítása történik. Majd a létrejött mátrix saját vektorainak számítása következik. Aztán a sávátlagok kivonásra kerülnek a bemeneti képadatokból, ennek következtében a kimeneti képben, olyan origo eltolódás jön létre, hogy annak spektrum átlaga minden sávban 0 lesz. Végül a Richards féle megközelítést alkalmazva, de egy másik képlet felhasználásával történik az átlaggal korrigált képadatok vetítése a sajátvektor-mátrix transzponáltjára.


Az egy másik zajszűréshez gyakran használt transzformáció az MNF (minimum noise fraction). Segítségével meghatározható a képadatok eredeti kiterjedése, az adatoktól elkülöníthető a zaj és csökkenthető a további feldolgozás számítási igénye. A jelenlegi formájában módosított MNF-et Green és munkatársai fejlesztették ki 1988-ban. Ez egy lineáris transzformáció, mely két főkomponens analízisből áll. Az első a zajkovariancia-mátrix főkomponenseinek segítségével dekorrelálja és átskálázza a felvételen található zajt (zajfehérítés), a transzformált képen a zajnak egységnyi varianciája van, és a sávok között nincs korreláció. A második forgatás az eredeti felvétel főkomponenseit használja, miután azon már megtörtént az első főkomponens analízis. Abból kifolyólag, hogy később spektrális feldolgozás következik, az adatok eredeti kiterjedését a végső sajátértékek és a kapcsolódó képek elemzésével határozzuk meg. Két részre osztjuk az adatteret: egy nagy sajátértékekhez és összetartozó sajátképekhez kapcsolódó részre, és egy közel egységnyi sajátértékeket és zajdominált képeket tartalmazó részre. Csak a koherens részeket vizsgálva jobbak lesznek a spektrális feldolgozási eredmények, mert a zaj elkülönül az adatoktól (L3HARRIS, 2022). Az MNF transzformáció eredményét a 4., 5. és a 6. ábra szemlélteti.



4. ábra A felvétel 2. sávjának képe az MNF transzformáció után



5. ábra A felvétel 20. sávjának képe az MNF transzformáció után



6. ábra A felvétel 40. sávjának képe az MNF transzformáció után

3.3.2 A képosztályozási eljárások

A kép osztályozás lényege, hogy a felvétel pixeleinek összetartozó képpont-együtteseit elkülönítsük vagy az előre meghatározott célkategóriákba soroljuk őket. A pixel-alapú osztályozás magában foglalja a képponton alapuló eljárásokat, statisztikus és szintaktikus műveleteket. A pixel értékek (intenzitás értékek) elemzésekor a vizsgált tulajdonság a pixel érték (vektor), ezek többsávós felvételek esetén az egyes spektrális alkotórészek vektorát, míg az eltérő időpontban készült képek esetében a geometriai értelemben összeillő adatok vektorát jelenti. Multispektrális osztályozást a többsávós felvételeknél, míg a különböző időpontokban rögzített képeknél multitemporális osztályozást használunk. Textúra elemzésnek hívjuk, ha a pixel értékek térbeli mintázatát vizsgáljuk.

A pixel intenzitások vizsgálatára korlátozódnak a szokványos osztályozási eljárások. Ezen belül két csoportba sorolhatjuk az osztályozókat: automatikus vagy nem felügyelt (unsupervised classification) és felügyelt (supervised classification). A két eljárás közötti legfontosabb különbség az osztályozáshoz szükséges tanuló területek előállításában keresendő. A nem felügyelt osztályozási módszereknél nincsenek előre ismert spektrális tulajdonságokkal rendelkező minták, hanem statisztikai algoritmusok segítségével történik a spektrális adatosztályok előállítása. Az osztályozás eredményeképpen jönnek létre azok a csoportok, melyekbe a felvétel pixelei intenzitás értékeik alapján besorolásra kerülnek. Az általánosan elterjedt osztályozó eljárások a klaszter középpontot (K-mean) keresik, majd az euklideszi távolság számításával pixeleket a legközelebbi klaszter középponthez párosítják. Az algoritmusok közös jellemzője, hogy iteratív módon végzik az adatsortok meghatározását. A célfüggvényhez tartozó szélsőértékek egyre pontosabb és pontosabb meghatározása során több lépésben történik az eredmény számítása. Számítás előtt megadhatjuk a létrejövő osztályok számát, vagy egy maximális távolságot, melynek túllépése egy újabb osztály létrejöttét eredményezi. Vagy még az iterációk számát is maximálhatjuk (Verőné Wojtaszek, 2015.).

Egy szintén jól ismert és gyakran használt nem felügyelt osztályozási mód az ISODATA. Az osztályozás során először kiszámítja az egyenletesen elosztott osztályközéppontokat az adat-
térben, majd a pixeleket a minimum távolság eljárás felhasználásával iteratív módon klaszterezi. Minden iteráció során az átlagokat is újraszámolja, és újraosztályozza a pixeleket az új átlagok alapján. A folyamat abbamarad, ha az iterációk maximális számát elérjük, vagy az ite-

ráció során osztályt váltó pixelek százalékos aránya kisebb lesz, mint a változási küszöbérték. Azt meg kell adni, hogy hány osztályt szeretnénk látni az osztályozás végén.

A felügyelt osztályozási módokból jóval több áll rendelkezésre. Itt a tanuló területek létrehozására kell nagyon ügyelni, mert ha a tanuló területek tévesen lesznek kijelölve, az osztályozás eredménye is helytelen lesz, amiből nem megfelelő következtetések vonhatók le.

A nagyszámú osztályozási mód közül néhányat emelnék ki. A Maximum Likelihood (maximális valószínűség) osztályozó feltételezi, hogy normális eloszlásúak az egyes sávokban az egyes osztályok, és annak a valószínűségét számítja, hogy egy adott képpont egy adott osztályba sorolható. Az egyes képpontok abba az osztályba kerülnek, amelynek a valószínűsége a legnagyobb (vagyis maximális).


A Minimum Distance (minimális távolság) osztályozó is az egyszerűbb elven működő osztályozók közé tartozik. Az osztályonkénti átlagos ROI-k és az egyes ismeretlen pixelek euklideszi távolságát számolja ki. A legközelebbi osztályba kerülnek besorolásra a pixelek.

A Mahalanobis Distance (mahalanobisz távolság) egy irányérzékeny távolságosztályozó, minden egyes osztályra statisztikákat számít. Nagyon hasonló a maximális valószínűség osztályozóhoz, de gyorsabb módszer annak a feltételezésnek köszönhetően, hogy minden osztály kovarianciája egyenlő. A pixeleket a legközelebbi tanulóterülethez sorolja be.

Az összetettebb osztályozók közé tartozik a spektrális szögtérképező (SAM, Spectral Angle Mapper), mely egy fizikai alapokon nyugvó spektrális osztályozó, egy n -D szög segítségével végzi el a pixelek és a tanuló területek megfeleltetését. A SAM két spektrum között számítja a szöget, és ROI-ként kezeli őket egy adott térben, melynek a sávok számával megegyező a dimenzióinak száma. Az eljárás hibája, hogy kalibrált reflexiós adatok vizsgálatánál kevésbé érzékeny a megvilágítás és az albedó hatásaira. A spektrális szögtérképező a tanuló területek átlagos ROI-a és az egyes pixel ROI-k közötti szöget hasonlítja össze az n -D térben. Minél kisebb a szög, annál közelebb van a pixel a referenciaspektrumhoz. Így a legkisebb szöggel bíró osztályba kerülnek a pixelek.

Az erdőállományokról készült hiperspektrális felvételek feldolgozásához egyik leggyakrabban használt osztályozási mód az SVM (Support Vector Machine). Magyarul támasztó vektoros eljárásnak nevezzük. Az SVM a komplex és zajos felvételek osztályozásánál hoz jó eredményeket. Az osztályok szétválasztásához egy döntési felületet használ, amely maximalizálja az

osztályok közötti különbségeket. A felületet hipersíknak nevezik, és az ehhez legközelebb eső adatpontok alkotják a támasztó vektorokat (L3HARRIS, 2022). A klaszter-kereső eljárás döntési elvét a 7. ábra szemlélteti.



7. ábra Az iteratív klaszter-kereső eljárás lépései (Csornai & Dalia, 1991.)

3.3.3 Az NDVI index és alkalmazási területe

Az NDVI (Normalized Difference Vegetation Index), vagyis normalizált vegetációs index, az egyik legelterjedtebb vegetációs index. Segítségével a fotoszintetikus aktivitáson keresztül detektálható a felszín növényzettel való borítottsága, mert minél zöldebb a felszín, annál magasabb a fotoszintetikus aktivitás. A növényzetről a közeli infravörös (NIR) és a látható vörös (Red) sávban mért visszaverődés különbségének és összegének hányadosa adja ki az index értékét. Ennek számításához mérni kell a közeli infravörös és a látható vörös tartományban a visszavert intenzitásokat (Belényesi, és mtsai., 2013).

$$NDVI = \frac{Q_{NIR} - Q_R}{Q_{NIR} + Q_R}$$

A normalizálásnak köszönhetően -1 és +1 közötti értéket kapunk végeredményként. A 0-t közelítő érték mutatja a növényzet teljes hiányát. Az NDVI egy összesített képet közöl a növényzet életképességéről. Felvételtől függően egy 0,5 körüli értékre löhetjük be azt az értéket, aminél nagyobb szám esetén zöld növényzet borítja a felszínt.

A felszínborítás típusának meghatározása mellett, növényzet esetén annak egészségi állapotára is következtethetünk az index értékéből. Minél magasabb az NDVI értéke, annál nagyobb a fotoszintetikus aktivitás, tehát annál vitálisabb a növényzet. Ezért döntöttem úgy, hogy a mintaterületem index-alapú elemzéséhez az NDVI-t fogom felhasználni, mely segítségével képet kaphatok az erdő állapotáról.

A 2022-es esztendő még a korábbi évekhez képest is nagyon száraznak számít, főleg ha a nyár végéig tartó időszakot nézzük. Az erdő lombzatát figyelve már augusztusban szeptemberi látkép fogadott minket. Egyes fák lombzata szabályosan bebarnult és teljesen elszáradt. A szokatlan időjárási körülmények arra ösztönöztek engem, hogy madártávlatból is megfigyeljem ezt a szomorú látványt. Ekkor készült az Ágfalvi-gerinc bejárása során a 15-ös ábrán látható felvétel. Jól látható, hogy a fák egy részén a levélzet már elszíneződött, míg egyes fák-ról le is hullott. Ezért arra gondoltam, hogy teszek egy egyszerű összehasonlítást az NDVI index segítségével a tavalyi évhez képest.


Először is regisztráltam a „Copernicus” weboldalán. Itt bárki számára ingyenesen hozzáférhetővé teszik a Sentinel-2 műhold által készített felvételeket, lehetőségünk van a felvétel készítési idejének és a vizsgálni kívánt területnek a kiválasztására is. A Sentinel-2 által készített felvételek közül a L2A típusúra volt szükségem a NDVI számításhoz. Felhőmentes felvételeket kerestem, a vizsgálatához szükséges időszakot elemezve találtam két ilyen felvételt, néhány nap eltéréssel. A tavalyi felvétel 2021. június 16-án míg az idei felvétel 2022. június 19-én készült. A látható spektrum vörös tartományát a 4-es sáv, a közeli infravöröst a 8-as sáv tartalmazza. Az NDVI index számításához és a raszter műveletekhez a QGIS nevű programot használtam, mely egy nyílt forráskódú széleskörű felhasználásra alkalmas térinformatikai szoftver. Mivel nyílt forráskódú, ezért otthon is tudtam vele dolgozni, ellentétben az ENVI-vel, amit csak Soproni Egyetemen használhattam. A 2021-es és 2022-es felvételek 4-es és 8-as sávját tartalmazó raszterekből kivágtam a mintaterületemnek megfelelő részt, és ezekre elvégeztem a NDVI számítást a raszter kalkulátorral. Végül a raszter statisztika segítségével kiszámítottam a felvételek NDVI értékeinek statisztikai mutatóit.



8. ábra Az Ágfalvi-gerinc erdőállománya augusztus 20-án (készítette: Dr. Király Géza)

3.3.4 Tanuló területek létrehozása

A tanuló területek elkészítéséhez szintén a QGIS szoftvert használtam. A minta területemet a Hideg-vízülvölgyi Erdőrezervátumban található 8 erdőrészlet alkotja, mely magában foglalja a tanuló és tesztterületeket egyaránt. A hideg-vízülvölgyi erdőrészletekről elmondható, hogy a legkevésbé zavarásnak kitett területek a hegyvidéken. A kommunista időkben a lakosság elől teljesen el voltak zárva ezek a részek, sőt az erdészeti munkák végrehajtása is sokszor nehézségbe ütközött. A jelenlegi helyzetben pedig a várostól való távolsága és az autós forgalom korlátozottsága tartja távol a turista tömegeket. A faállomány szempontjából hasonló folyamatok zajlottak le, mint az egész hegyvidéken. A több hullámban zajló fenyőpusztulás hatására a luc viasszaszorult a területen, és már csak elegyben a hűvös északi oldalakon és a völgyekben található meg. A luc helyét részben a bükk vette át. De jellemzően elég változatos a terület az elegyarány szempontjából, és köszönhetően a védettségnek főként idősebb állományokat találunk itt. Így kitűnően alkalmas teszt területnek fafaj osztályozási kísérletekhez (Mollayné Madas, Molnár, & Tamás, 2011.).



9. ábra A mintaterületem elhelyezkedése 1:10 000-es topográfiai térképen (Lechner Tudásközpont, 2020.)

A tanuló területek létrehozásához mindenképpen szükség volt terepi felvételezésre is. A Hídegvíz-völgyi Erdőrezervátumon belül a 186/C és D erdőrészteket (9. ábra) választottam, mert mindkét részletben megtalálható jelentős elegyaránnyal az általam vizsgálni kívánt fafajok: bükk, kocsánytalan tölgy, vörösfenyő és lucfenyő. A 186/C erdőrésztlet állományának képét a 10. ábra mutatja be. Még egy indok, hogy a rezervátumot választottam, itt rendelkezésre álltak mérőállomással kitűzött hálópontok, amiket úgymond alappontként használhattam fel méréseim során. A pontossági követelmények lehetővé tették számomra, hogy nagy pontosságú geodéziai műszerek használata nélkül is el tudjam végezni a méréseket.

A terepen való tájékozódáshoz és a mintapontok azonosításához a QField applikációt használtam. A 9-es ábrán látható topotérkép-, erdőrésztlet határok réteghez hozzáadtam a hálópontok réteget, mely az állandósított, mérőállomással bemért felvételi hálópontokat tartalmazta. Ezt a projekt fájl elmentve, és a QField-ben okostelefonon megjelenítve kitűnően lehetett az erdőben tájékozódni.

A műszer, amellyel dolgoztam a TruPulse 360B. Az erdészeti kutatásokban és gyakorlatban előszeretettel alkalmazott eszköz. A műszer rendelkezik egy lézeres távolságmérővel, melyet

prizmával és anélkül is használhatunk (Laser Technology, 2007). Prizmára általában a cserjeszinttel rendelkező állományokban van szükség, ellenkező esetben egyszerűen a fák törzsét célozzuk meg a lézerrel a mérés során. A szögméréshez a TruePulse a legújabb elektronikus iránytű technológiát használja. A belső áramkörök lehetővé teszik a föld mágneses mezejének három tengely irányában történő megfigyelését, ezzel biztosítva a lehető legjobb azimutális pontosságot. Emellett a kalibrálás egyszerűen, akár terepen elvégezhető.




10. ábra A 186C erdőrészlet képe

A méréseket a 186/C és D erdőrészlet határán végeztem a 19_07-es és a 17_06-os hálóponton felállva. Első lépésben az állásponttól egy másik ismert koordinátájú hálópontra végeztem mágneses azimut és távolság mérést, és számítottam az irányszögeket. A számított irányszög és az azimut eltérését az egyes fákra mért azimutokhoz hozzáadva kaptam az irányszögeket az adott állásponton, ebből és a mért távolságok segítségével már számítható volt az egyes fák koordinátái. Ezenkívül mértem az egyes fák átmérőjét, ameddig volt figuránsom, ezután már csak becsültem, és természetesen meghatároztam a fafajt. Összesen 82 faegyedet vettem fel, főként bükk, kocsánytalan tölgy, vörös és lucfenyő alkotta az állományt.

2. táblázat Részlet a terepi mérések jegyzőkönyvéből kiegészítve a kiszámított EOY koordinátákkal

	állásp.	irányz. pont	fafaj	táv(m)	mág. azimut(°)	eltér.(°)	δ(°)	D(cm)	Y	X
	19_07	20_07		50,0	149,6	5,4	155,0		454 844,261	261 294,678
1	20_07					5,4			454 865,392	261 249,363
2	19_07		B	3,9	307,9	5,4	313,3	60,3	454 841,423	261 297,353
3	19_07		LF	8,0	48,6	5,4	54,0	69,9	454 850,733	261 299,380
4	19_07		B	8,3	9,9	5,4	15,3	56,9	454 846,451	261 302,684
5	19_07		LF	13,8	30,6	5,4	36,0	76,7	454 852,373	261 305,843
6	19_07		B	17,3	45,0	5,4	50,4	53,6	454 857,591	261 305,706
7	19_07		LF	24,6	39,5	5,4	44,9	46,8	454 861,626	261 312,103
8	19_07		KTT	25,1	53,1	5,4	58,5	39,8	454 865,663	261 307,793
9	19_07		B	27,8	64,6	5,4	70,0	58,3	454 870,385	261 304,186
10	19_07		HJ	30,5	80,4	5,4	85,8	35,7	454 874,679	261 296,912

Az EOY koordináták kiszámítása után térképen megjelenítettem a fák helyzetét jelölő pontokat. Az ismert fafajú vizuálisan elkülöníthető fakoronák körbe rajzolásával tanuló területeket hoztam létre a QGIS-ban (11. ábra), a fájlok típusa shape. Ezeket alakítottam az ENVI szoftverben ROI fájlokká, melyek már közvetlenül felhasználhatók voltak az osztályozáshoz.



11. ábra A tanuló területek ábrázolása

4. EREDMÉNYEK

Ebben a fejezetben az osztályozás és az index-alapú elemzés az eredmények bemutatásához. A korábbiakban taglaltam a tanulóterületek létrehozásának folyamatát. Említettem azt is, hogy a hiperspektrális felvételen kívül rendelkezésemre állt a felvételezett területről egy ortofotó. Ez utóbbinak a felbontása lehetővé tette, hogy elkülöníthessem az egyes fakoronákat. Így az EOv koordináták segítségével meghatározott egyes fakoronák körberajzolását az ortofotón hajtottam végre. Az ortofotó EOv míg a hiperspektrális felvétel vetületi rendszere az UTM. A hiperspektrális felvételt EOv vetületi rendszerbe transzformáltam, de az automatikus korrekciók miatt előjöttek a lent leírt problémák. A két felvételt aprólékosan összehasonlítottam, és ekkor vettem észre, hogy geometriájuk sajnos a vetületi rendszerek különbözőségéből fakadónál jóval nagyobb mértékben tér el egymástól. Sajnos az eltérés teljesen szabálytalan volt, ebből arra lehetett következtetni, hogy az ortofotó megfelelő georeferálása megtörtént, a hiperspektrális felvételé viszont nem. Így nem volt arra sem lehetőségem, hogy a két felvételt egyeztetsem, és a hibákkal terheltten kellett tovább dolgoznom. Az alábbiakban ismertetem, hogy ez milyen mértékben mutatkozott meg az eredményekben.

3. táblázat Az egyes faegyedek száma a tanító- és referencia területek esetében


db	tanító terület	referencia terület	össze- sen	osztály színe
B	7	16	23	kék
KTT	6	11	17	zöld
LF	8	17	25	piros
VF	5	9	14	sárga
összesen	26	53	79	

A 3. táblázat mutatja, hogy a méréseimből 79 faegyedet tudtam felhasználni, illetve kevesebbet, mivel lucfenyőt csak 5-öt sikerült bemérnem, így egy korábbi hallgatók által felvett törzstérképből kellett átvennem adatokat (Bazsó, 2007.). Ebből is látszik, hogy érdemes többet mérni a minimálisnál, mert mindig vannak olyan faegyedek, amelyekről az adatok feldolgozása során derül ki, hogy nem használhatók fel a további vizsgálatokhoz. A tanító területek alapján történt az ENVI-ben a tényleges osztályozás, melyet a mintaterületnek választott 8 részleten és a transzformált felvétel (MNF) első 30 sávján végeztem el. Az osztályozás helyességét a referencia területek segítségével ellenőriztem le. A referencia terület pixeleinek vizsgálatát a

QGIS-ban végeztem el. A tanító/referencia terület arány 90/10-től akár 10/90-ig is terjedhet, és a szakirodalomban sem egységes. Én az 1/3 tanító/referencia terület arány mellett foglaltam állást. Akkor következzen az osztályozók eredményeinek bemutatása. Először a felügyelt osztályozási módokkal fogom kezdeni az egyszerűbbtől a bonyolult fele haladva, majd végül a nem felügyelt osztályozási módok eredményét mutatom be.

4.1 A felügyelt osztályozási módok eredményei

A minimális távolság eljárás az egyszerűbb osztályozási módok közé tartozik, ami nem azt jelenti, hogy ne lenne jó módszer. A fafajok közül a legpontosabban a bükköt (80.9%) és a vörös fenyőt (80.5%) ismerte fel a módszer (4. táblázat). Jellemző volt a legtöbb esetben, hogy ahol a bükköt jó pontossággal osztályozta, ott a kocsánytalan tölgy kevésbé szerepel jól. Ez a trend itt is érvényesül, mivel a tölgy osztályozási pontossága csak 59.2%. A lucfenyőnél pedig egyéb problémák léphettek fel, amelyekre a későbbiek során ki fogok térni, mert mindössze 6.0% az osztályozás pontossága. A táblázatban a félre osztályozások eredményei is összehasonlításra kerültek. A lucfenyőt figyelmen kívül hagyva a kocsánytalan tölgy esetében volt a legnagyobb, itt a referencia pixelek 31.7%-a került bükk-ként meghatározásra. Az osztályozás képét a 12. ábra mutatja be. Az ábra rövidítései: B (bükk), KTT (kocsánytalan tölgy), LF (lucfenyő), vörösfenyő (VF).




12. ábra A Minimum Distance osztályozás eredménye

4. táblázat A Minimum Distance osztályozás pontossága

	pixel besorolása	B	KTT	LF	VF
B referencia	pixel szám	440	83	6	15
	oszt. pont. (%)	80,9	15,3	1,1	2,8
KTT referencia	pixel szám	97	181	11	17
	oszt. pont. (%)	31,7	59,2	3,6	5,6
LF referencia	pixel szám	104	58	33	355
	oszt. pont. (%)	18,9	10,5	6,0	64,5
VF referencia	pixel szám	24	4	4	132
	oszt. pont. (%)	14,6	2,4	2,4	80,5

A mahalanobisz távolság osztályozó más eredményeket hozott, mint az előző módszer. A legnagyobb osztályozási pontosság a vörösfenyőé 78,7%-kal (5. táblázat). A bükk 67,8%-a és a kocsánytalan tölgy 64,4%-a elég közel van egymáshoz, mint ahogy a félre osztályozás is majd 30% a másik faj javára. Itt a lucfenyő osztályozási pontossága már 35,3%, de ez még mindig nem elégséges, és az összes többi faj javára jelentős a félre osztályozás. Az osztályozás képét 13. ábra mutatja be.




13. ábra A Mahalanobis Distance osztályozás eredménye

5. táblázat A Mahalanobis Distance osztályozás pontossága

	pixel besorolása	B	KTT	LF	VF
B referencia	pixel szám	369	151	14	10
	oszt. pont. (%)	67,8	27,8	2,6	1,8
KTT referencia	pixel szám	80	197	6	23
	oszt. pont. (%)	26,1	64,4	2,0	7,5
LF referencia	pixel szám	83	175	194	98
	oszt. pont. (%)	15,1	31,8	35,3	17,8
VF referencia	pixel szám	21	13	1	129
	oszt. pont. (%)	12,8	7,9	0,6	78,7

A maximális valószínűség osztályozó esetében először fordul elő, hogy a bükk osztályozásának pontossága mindössze 39,0%, a kocsánytalan tölgyként való félre osztályozás is magasabb 44,3% (6. táblázat). Ebből következik, hogy a kocsánytalan tölgy azonosítása kellő pontosságú, 78,1%, a félre osztályozás csekélyebb jóval, mint a büknél. A lucfenyő osztályozás pontossága is feltűnően jó, 75,6%. De vizuálisan összehasonlítva az előző módszerek képével valószínűleg szinte minden pixelt lucfenyőnek osztályozott, ami a másik három osztályba nem volt besorolható. Az előzőekhez képest a vörös fenyő osztályozási pontossága is alacsony, 48,2% és a nagy téves osztályozás a lucfenyő javára. Az osztályozás képét a 14. ábra mutatja be.




14. ábra A Maximum Likelihood osztályozás eredménye

6. táblázat AMaximum Likelihood osztályozás pontossága

	pixel besorolása	B	KTT	LF	VF
B referencia	pixel szám	212	241	91	0
	oszt. pont. (%)	39,0	44,3	16,7	0,0
KTT referencia	pixel szám	31	239	24	12
	oszt. pont. (%)	10,1	78,1	7,8	3,9
LF referencia	pixel szám	29	103	416	2
	oszt. pont. (%)	5,3	18,7	75,6	0,4
VF referencia	pixel szám	10	28	47	79
	oszt. pont. (%)	6,1	17,1	28,7	48,2

Az SVM osztályozónál hasonló eredményeket kapunk, mint a minimális és a mahalanobisz távolság osztályozó esetében (7. táblázat). Itt a tölgy javára billen a mérleg a 71,6%-os osztályozási pontossággal, félre osztályozás a bükk javára 23,2%. A bükk azonosításának pontossága mindössze 60,3%, félre osztályozás a tölgy javára 36,2%. A lucfenyő osztályozási pontossága mindössze 44,7%. A vörösfenyő átlagosan jónak mondható a 72,0%-os osztályozási pontossággal. Az osztályozás képét a 15. ábra mutatja be.




15. ábra Az SVM osztályozás eredménye

7. táblázat Az SVM osztályozás pontossága

	pixel besorolása	B	KTT	LF	VF
B referencia	pixel szám	328	197	16	3
	oszt. pont. (%)	60,3	36,2	2,9	0,6
KTT referencia	pixel szám	71	219	13	3
	oszt. pont. (%)	23,2	71,6	4,2	1,0
LF referencia	pixel szám	69	150	246	85
	oszt. pont. (%)	12,5	27,3	44,7	15,5
VF referencia	pixel szám	17	21	8	118
	oszt. pont. (%)	10,4	12,8	4,9	72,0

4.2 A nem felügyelt osztályozás módok az ISODATA és a K-mean osztályozó eredménye



16. ábra Az ISODATA és a K-mean osztályozó eredménye

A nem felügyelt osztályozási módoknál az ENVI a színeket véletlenszerűen választotta ki. Az ISODATA módszerrel 8 osztályba történt a besorolás, a 8. az osztályozatlan pixelek, de mivel itt nem adtam küszöbértéket, ilyenek nem voltak. A K-mean osztályozónál 9 osztályba történt a besorolás, és a 9. az osztályozatlan pixel, ami az előzőekhez hasonlóan itt sem volt. Ha megvizsgáljuk a klaszterek méretét, az egyes osztályok nem térnek el jelentősen egymástól. Kivéve a 6-os (rózsaszín) és az 5-ös (halvány kék) klasztert, a 6-os klaszter az K-mean osztályozónál foglal el nagyobb területet, mint az ISODATA esetében, míg az 5-ösnél ez pont fordítva van (16. ábra).

4.3 Az osztályozási módszerek összehasonlítása

Az egyes osztályozási módszerek összevetése esetén a felügyelt módszereket tudtam egymással összehasonlítani. A hiperspektrális felvétel MNF transzformációját a mintaterületre végeztem le, amely nyolc erdőrészletet foglal magában, melyet érint a Hidegvíz-völgy Erdőrezervátum területe. Az osztályozást is erre a nyolc erdőrészletre végeztem el.

Az osztályozási módszerek pontossága elmarad az elvárhatótól. A leglátványosabb a lucfenyő esetében, melynél szinte értékelhetetlenek az eredmények. Korábban már említettem, hogy a hiperspektrális felvétel georeferálása nem volt megfelelő, az ortofotóhoz képest teljesen szabálytalan és a vetületi rendszerek közti különbséget jóval meghaladó eltéréseket tapasztaltam. Ez sajnos a két felvétel egymáshoz való illesztését is megakadályozta. A tanuló területek kijelölése az ortofotón történt, mert itt volt lehetőségem az egyes faegyedek elkülönítésére a jobb geometriai felbontásnak köszönhetően. A hiperspektrális felvétel 1 m-es geometriai felbontása ezt nem tette lehetővé. A néhol méteres eltérések a két felvétel között, vezettek oda, hogy hiába jelöltem a ki nagy körül tekintéssel a tanulóterületeket, így is kerültek be más fafajok pixelai is az adott fafajhoz tartozó tanuló területbe. Emiatt a lucfenyő esetében, amely szálankénti elegyben volt jelen a mintaterületen, a félre osztályozás nemcsak a vörösfenyő, hanem még a lombos fafajok javára is előfordult, az említett okokból kifolyólag. Készítettem talaj és árnyék tanuló területeket is az osztályozás pontosságának javításához, de sajnos ezek az előbb említett okokból kifolyólag inkább csak rontottak a helyzeten. Ezért végül alkalmazásuktól eltekintettem.

A fentiek hatására döntöttem úgy, hogy az osztályozási módszerek pontosságának kiértékelésekor a lucfenyő nélkül is kiszámoltam az átlagokat, és ezeket használtam fel az összehasonlításhoz (8. táblázat). A Maximum Likelihood osztályozó teljesít így a legrosszabbul, 55,1%-os pontosságával, ez lucfenyővel együtt számolva feljavul 60,2%. Egyedül ez a módszer osztályozza a lucfenyőt 50% feletti, 75,6%-os pontossággal. A legjobban a Minimum Distance osztályozó teljesít az összes fafaj osztályozási pontosságának átlagát tekintve 73,5%-kal, és a fafajonkénti legjobb osztályozási pontosságot is ő tudja, a bükk 80,9%-os osztályozási pontosságával. A vörösfenyőt szintén ez a módszer azonosította a legnagyobb 80,5%-os pontossággal. A Mahalanobis Distance teljes pontossága 70,3%, míg az SVM osztályozó kissé elmaradva ettől mindössze 67,9%. A kocsánytalan tölgyet a legnagyobb pontossággal a Maximum

Likelihood osztályozó ismerte fel 78,1%-os pontossággal, míg utána 71,6%-kal következik az SVM osztályozó. A vörösfenyő esetében nem meglepő módon a legrosszabbul a Maximum Likelihood osztályozó teljesít, 48,2%-kal, az összes többi módszernél 70% feletti az osztályozás pontossága.

8. táblázat Az egyes osztályozási módszerek összehasonlítása

pontosság (%)	SVM	Min. Dis.	Mah. Dis.	Max. Lik.	átlag
B	60,3	80,9	67,8	39,0	62,0
KTT	71,6	59,2	64,4	78,1	68,3
LF	44,7	6,0	35,3	75,6	40,4
VF	72,0	80,5	78,7	48,2	69,8
átlag	62,1	56,6	61,5	60,2	60,1
LF nélkül	67,9	73,5	70,3	55,1	66,7

4.4 A mintaterület NDVI értékeinek összehasonlítása a 2021- és 2022-es évre vonatkozóan

Az eltérés meglepően nagy. Az előző év NDVI értékeinek minimuma több, mint kétszerese, a maximuma majd másfélszerese a jelenlegi évnek, az átlagról nem is beszélve (9. táblázat). A 2022-es év NDVI értékeinek szórása több, mint kétszerese a 2021-es évnek, de ez sem jelent jót. Ebből arra következtethetünk, hogy az egyes fafajoknak, sőt még fajon belül az egyes egyedeknek is nagyon eltérő az alkalmazkodásuk az extrém körülményekhez. Megfelelő körülmények esetén a szórás jóval kisebb. Az index értékeiből sajnos nagyon jól látszik, hogy az erdők egészségére is jelentős hatással van az extrém szárazság, és ellenálló képességüknek vanna határai. Csak remélni tudjuk, hogy következő év csapadékosabb lesz.

9. táblázat A mintaterület NDVI értékeinek összehasonlítása két időpontban

NDVI értékek	minimális érték	maximális érték	átlag	szórás
2021.06.16	0,801	0,943	0,909	0,021
2022.06.19	0,380	0,664	0,545	0,044

5. KÖVETKEZTETÉSEK

A távérzékelés és ennek erdészeti alkalmazása számomra nagyon kedves terület. A munka elkészítése során tovább mélyíthettem ismereteimet ebben a témában, amely nagy megelégedésemre szolgált. Sajnos az eredmények kissé elmaradtak a várakozásaimtól, gondolok itt főképp az osztályozási pontosságokra. Valószínűleg tapasztalatlanságom okán is követhettem el olyan hibákat, melyek az elvártnál alacsonyabb értékekhez vezettek.

Az eredmény részben kitaglott okokon kívül említenék ki még egyet. A bükk és a tölgy vizuális alapú elkülönítése sem mindig zökkenő mentes. Ebben nagy segítségünkre lehet a felvételek közeli infravörös sávja. Ezért általában a légifelvételeket az RGB-n kívül még kiegészítik ezzel az egy sávval. Viszont az általam használt ortofotóról ez a sáv hiányzott. Így jobb híján a geoshop oldaláról töltöttem le a területről 2012-ben készült 40 cm-es felbontású ortofotót, mely már tartalmazta a közeli infrát. Persze a két felvételt az időbeli távolság és a különböző geometria miatt csak korlátozottan tudtam összehasonlítani.

A szakirodalomból ezenkívül több dolgot emelnék ki, ami a későbbiek során fontos lehet. Számos cikkben megemlítették, hogy a hiperspektrális felvételek LIDAR adatokkal való kombinálása nagyban javíthatja az osztályozás pontosságát. Általában a legnagyobb pontosságot az SVM osztályozóval érték el, egy esetet kivéve, amikor a 3D konvolúciós neuron háló megelőzte. A terepen felvett fák mennyiségének növelésével, és olyan állományok kiválasztásával, melyekben az egyes faegyedek jobban elkülönülnek, javítható a tanuló területek kijelölésének pontossága. A későbbiek során mindenképpen szeretnék ezzel a témával foglalkozni, és az itt tapasztaltakat beépíteni a feldolgozás folyamatába. Öröömre szolgált a Soproni-hegyvidék erdeinek más aspektusból történő mélyebb megismerése.

6. ÖSSZEFOGLALÓ

Munkám fő célja a Soproni-hegyvidék erdőállományának elemzése a hiper- és multispektrális felvételek alapján. A Soproni-hegyvidékről 2021-ben készült hiperspektrális felvételt használtam fel a vizsgálathoz, melynek feldolgozása és az osztályozás az ENVI szoftverben történt. A különböző raszter műveletekhez és a tanuló területek kijelöléséhez a QGIS szoftvert hívtam segítségül. Első lépésben a hiperspektrális felvétel zajsűrését hajtottam végre az MNF transzformáció által. Mintaterületem a Hidegvíz-völgy Erdőrezervátum területén található 8 erdő-részlet volt. Az általam választott osztályozandó fafajok a következők voltak: bükk, kocsánytalan tölgy, luc- és vörösfenyő. A 186/C és D részletben a terepen bemértem a TruePulse360 műszerrel a tanuló- és teszt területek faegyedeit. A mért mágneses azimut és távolság értékek, és a számított irányszögek segítségével határoztam meg a fák EOY koordinátáit. Majd a fák pontos helyét térképen megjelenítve rajzoltam körbe az egyes fakoronákat egy nagy geometriai felbontású ortofotón, melyből a tanuló területek poligonjait hoztam létre QGIS-ben. Ezek alapján történt az ENVI-ben a mintaterület osztályozása a transzformált felvétel első 30 sávjában. A felügyelt osztályozók közül a Minimum Distance, a Mahalanobis Distance, a Maximum Likelihood és a SVM módszert, míg a nem felügyelt osztályozók közül a K-mean és az ISODATA eljárást használtam. A lucfenyő osztályozás pontosságát nélkül értékeltém az eredményeket, mert ez nagyon kilógott lefele az átlagtól. A legjobb összesített pontosságot a 3 fajra a Minimum Distance osztályozó adta, 73,5%-ot. A fafajok közötti legjobb osztályozási pontosságot is neki köszönhetjük a bükk 80,9%-os felismerésével. A legrosszabb összesített pontosságot a Maximum Likelihood osztályozó adta, 55,1%-ot. Az osztályozás pontosságának alacsony volta a hiperspektrális felvétel és az ortofotó közti geometriai különbségekből fakad. A mintaterületre a Sentinel-2 L2A típusú felvételeit felhasználva NDVI értékeket is számoltam a 2021-es és 2022-es év júliusának azonos időszakára. Az ideai csapadékszegény időjárás következtében jelentősen lecsökkent a fotoszintetikus aktivitás, amit az index értékei jól alátámasztottak, már-már rémisztő mértékben. A munka elvégzése során értékes tapasztalatokkal gazdagodtam.

7. SUMMARY

The main objective of my work is to analyse the forest cover of the Sopron Hills based on hyper- and multispectral imagery. I used hyperspectral imagery of the Sopron Hills in 2021, processed and classified in ENVI software. For the different raster operations and the selection of the study areas I used the QGIS software. In the first step, I performed noise filtering of the hyperspectral image by MNF transform. My sample area was 8 forest fragments located in the Coldwater Valley Forest Reserve. The tree species I chose to sub-divide were beech, sessile oak, spruce and larch. In transects 186/C and D, I surveyed the study and test plots in the field using the TruePulse360 instrument. I used the measured magnetic azimuth and distance values, and calculated bearing angles to determine the EOVS coordinates of the trees. I then plotted the exact location of the trees on a map and circled each tree line on a high geo-spatial resolution orthophoto, from which I created polygons of the study areas in QGIS. These were used in ENVI to classify the sample area in the first 30 bands of the transformed image. Among the supervised classifiers, I used the Minimum Distance, Mahalanobis Distance, Maximum Likelihood and SVM methods, while among the unsupervised classifiers, I used the K-mean and ISODATA methods. I evaluated the results without the accuracy of the spruce classification, because it was very far off the mean. Minimum Distance classifier gave the best overall accuracy for the 3 tree species, 73.5%. It also gave the best classification accuracy between tree species with 80.9% detection of beech. The worst overall accuracy was obtained with the Maximum Likelihood classifier, 55.1%. The low classification accuracy is due to the geometric differences between the hyperspectral image and the orthophoto. NDVI values were also calculated for the sample area using Sentinel-2 L2A imagery for the same period in July 2021 and July 2022. This year's spate of poor weather has resulted in a significant decrease in photosynthetic activity, which was well supported by the index values, almost to an alarming degree. The work has provided me with valuable experience.

8. KÖSZÖNETNYILVÁNÍTÁS

Szeretném megköszönni a segítséget két konzulensemnek: Verőné Dr. Wojtaszek Małgorzatának és Dr. Király Gézának, továbbá Gallai Bencének, ki mindig rendelkezésemre állt, Dr. Bazsó Tamásnak, Hegedüs Dánielnek, de legfőképp a feleségemnek és a családomnak.

9. IRODALOMJEGYZÉK

- Bakó, G. (2014.). Légi fényképezés a gazdálkodásban és a közszolgáltatásban. *E-Government Tanulmányok XL*. Budapest: E-Government Alapítvány a Közigazgatás Modernizációjáért.
- Bazsó, T. (2007.). *A Hidegvíz-völgy Erdőrezervátum kutatási eredményeinek térinformatikai feldolgozása*. Budapest.
- Belényesi, M., Burai, P., Czimber, K., Király, G., Kristóf, D., & Tanács, E. (2013). *Távérzékelési adatok és módszerek erdőtérképezési célú felhasználása, megvalósíthatósági tanulmány*. (D. Kristóf, Szerk.) Budapest: An Augur Kft.
- Bidló, A., Gálos, B., & Kiss, M. (2019.). A tájvédelmi körzet természetföldrajzi viszonyai. In L. Kárpáti (Szerk.), *Soproni Tájvédelmi Körzet, Monografikus tanulmányok a Soproni-hegység természeti és kulturális értékeiről* (old.: 39-58). Budapest: Szaktudás Kiadó Ház.
- Cho, M. A., Skidmore, A. K., & Sobhan, I. (2009.). Mapping beech (*Fagus sylvatica*) forest structure with airborne hyperspectral imagery. *International Journal of Applied Earth Observation and Geoinformation*, 11, 201-211.
- Csornai, G., & Dalia, O. (1991.). *Távérzékelés jegyzet*.
- Dalponte, M., Bruzzone, L., & Gianelle, D. (2008). Fusion of Hyperspectral and LiDAR Remote Sensing Data for Classification of Complex Forest Areas. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5), 1416-1427.
- Hamada, Y., Stow, A. D., Coulter, L. L., Jafolla, J. C., & Hendricks, L. W. (2007.). Detecting Tamarisk species (*Tamarix* spp.) in riparian habitats of Southern California using high spatial hyperspectral imagery. *Remote Sensing of Environment*, 109, 237-248.
- Hargitai, H. (2006). *A hiperspektrális képfeldolgozás módszerei és az első magyarországi képkalkító spektrométeres repülés adatainak elemzése, Doktori (PhD) értekezés*. Budapest.

- Hárs, O. (2019.). A hegység forrásai. In L. Kárpáti (Szerk.), *Soproni Tájvédelmi Körzet, Monografikus tanulmányok a Soproni-hegység természeti és kulturális értékeiről* (old.: 59-64). Budapest: Szaktudás Kiadó Ház.
- Jones, T. G., Coops, N. C., & Sharma, T. (2010.). Assessing the utility of airborne hyperspectral and LiDAR data for species distribution mapping in the coastal Pacific Northwest, Canada. *Remote Sensing of Environment*, 114, 2841-2852.
- Kertész, P. (2014). *Bükkös állapotának felmérése hiperspektrális felmérés alapján, Diplomamunka*. Sopron.
- Köveskúti, Z. (2019.). Az erdőgazdálkodás napjainkban (1945-től...). In L. Kárpáti (Szerk.), *Soproni Tájvédelmi Körzet, Monografikus tanulmányok a Soproni-hegység természeti és kulturális értékeiről* (old.: 315-321). Budapest: Szaktudás Kiadó Ház.
- L3HARRIS. (2022). (L3Harris Geospatial Solutions, Inc.) Forrás: https://www.l3harrisgeospatial.com/docs/using_envi_Home.html
- Laser Technology, I. (2007. september 15.). TruPulse™ 360/360B User's Manual. USA.
- Lechner Tudásközpont. (2020.). <https://lechnerkozpont.hu/>. Forrás: <https://geoshop.hu/>.
- Mäyrä, J., Keski-Saari, S., Kivinen, S., Tanhuanpää, T., Hurskainen, P., Kullberg, P., . . . Vihervaara, P. (2021.). Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks. *Remote Sensing of Environment*, 256, 1-16.
- Mollayné Madas, G., Molnár, Á., & Tamás, J. (2011.). *A Soproni-hegység erdőállományainak története*. Sopron: TAEG Tanulmányi Erdőgazdaság Zrt.
- Richards, J. A. (1999.). *Remote Sensing Digital Image Analysis: An Introduction*. Springer-Verlag.
- Szomorad, F. (2011). A Soproni-hegység erdeinek történeti, növényföldrajzi és ökológiai vizsgálata. (D. Bartha, Szerk.) *TILIA*, XVI.
- Verőné Wojtaszek, M. (2015.). Objektum alapú képelemzés.

10. ÁBRAJEGYZÉK

1. ábra A távérzékelési adatgyűjtés folyamata (Belényesi, és mtsai., 2013).....	13
2. ábra A hiperspektárlis felvétel RGB-színsávós képe.....	21
3. ábra A hiperspektárlis felvétel adott spektrális sávjainak hisztogramja.....	21
4. ábra A felvétel 2. sávjának képe az MNF transzformáció után.....	23
5. ábra A felvétel 20. sávjának képe az MNF transzformáció után.....	23
6. ábra A felvétel 40. sávjának képe az MNF transzformáció után.....	23
7. ábra Az iteratív klaszter-kereső eljárás lépései (Csornai & Dalia, 1991.).....	26
8. ábra Az Ágfalvi-gerinc erdőállománya augusztus 20-án (készítette: Dr. Király Géza)	28
9. ábra A mintaterületem elhelyezkedése 1:10 000-es topográfiai térképen (Lechner Tudás- központ, 2020.).....	29
10. ábra A 186C erdőrészlet képe.....	30
11. ábra A tanuló területek ábrázolása.....	32
12. ábra A Minimum Distance osztályozás eredménye.....	34
13. ábra A Mahalanobis Distance osztályozás eredménye.....	35
14. ábra A Maximum Likelihood osztályozás eredménye.....	36
15. ábra Az SVM osztályozás eredménye.....	37
16. ábra Az ISODATA és a K-mean osztályozó eredménye.....	38