

SOPRONI EGYETEM
ERDŐMÉRNÖKI KAR
ROTH GYULA ERDÉSZETI ÉS VADGAZDÁLKODÁSI TUDOMÁNYOK DOKTORI ISKOLA
E3 ERDŐVAGYON-GAZDÁLKODÁS PROGRAM

DOKTORI (PHD) ÉRTEKEZÉS

FAÁLLOMÁNYOK FELMÉRÉSE ÉS MODELLEZÉSE TÁVÉRZÉKELESI ÉS GEOINFORMATIKAI MÓDSZEREKKEL

Készítette: Barton Iván
Témavezetők: Dr. Király Géza & Dr. Czimber Kornél

Sopron
2021

FAÁLLOMÁNYOK FELMÉRÉSE ÉS MODELLEZÉSE TÁVÉRZÉKELESI ÉS GEOINFORMATIKAI MÓDSZEREKKEL

Értekezés doktori (PhD) fokozat elnyerése érdekében
a Soproni Egyetem Roth Gyula Erdészeti és Vadgazdálkodási Tudományok Doktori Iskolája
E3 Erdővagyon-gazdálkodás programja keretében.

Írta:
Barton Iván

Témavezető: Dr. Király Géza

Elfogadásra javaslom (igen / nem)

(aláírás)

Témavezető: Dr. Czímber Kornél

Elfogadásra javaslom (igen / nem)

(aláírás)

A jelölt a doktori szigorlaton %-ot ért el,
Sopron,

.....
a Szigorlati Bizottság elnöke

Az értekezést bírálóként elfogadásra javaslom (igen /nem)

Első bíráló (Dr.) igen /nem

(aláírás)

Második bíráló (Dr.) igen /nem

(aláírás)

(Esetleg harmadik bíráló (Dr.) igen /nem

(aláírás)

A jelölt az értekezés nyilvános vitáján.....% - ot ért el

Sopron, 2021.

.....
a Bírálóbizottság elnöke

A doktori (PhD) oklevél minősítése.....

.....
Az EDHT elnöke

NYILATKOZAT

Alulírott **Barton Iván** (neptun kód: B5HALP) jelen nyilatkozat

aláírásával kijelentem, hogy a **Faállományok felmérése és modellezése távérzékelési és geoinformatikai módszerekkel** című PhD értekezésem **önálló munkám**, az értekezés készítése során betartottam a szerzői jogról szóló 1999. évi LXXVI. tv. szabályait, valamint a Roth Gyula Erdészeti és Vadgazdálkodási Tudományok Doktori Iskolája Doktori Iskola által előírt, a doktori értekezés készítésére vonatkozó szabályokat, különösen a hivatkozások és idézések tekintetében¹.

Kijelentem továbbá, hogy a dolgozat készítése során az önálló munka kitétel tekintetében a konzulenszt illetve a feladatot kiadó oktatót **nem tévesztettem meg**.

Jelen nyilatkozat aláírásával tudomásul veszem, hogy amennyiben bizonyítható, hogy a dolgozatot **nem magam készítettem**, vagy a dolgozattal kapcsolatban szerzői jogsértés ténye merül fel, a Soproni Egyetem **megtagadja a dolgozat befogadását**.

Az értekezés befogadásának megtagadása és a fegyelmi eljárás indítása nem érinti a szerzői jogsértés miatti egyéb (polgári jogi, szabálysértési jogi, büntetőjogi) jogkövetkezményeket.

Sopron, 2021.01.14.



doktorjelölt

¹ **1999. évi LXXVI. tv. 34. § (1)** A mű részletét - az átvevő mű jellege és célja által indokolt terjedelemben és az eredetihez híven - a forrás, valamint az ott megjelölt szerző megnevezésével bárki idézheti.

36. § (1) Nyilvánosan tartott előadások és más hasonló művek részletei, valamint politikai beszédek tájékoztatás céljára - a cél által indokolt terjedelemben - szabadon felhasználhatók. Ilyen felhasználás esetén a forrást - a szerző nevével együtt - fel kell tüntetni, hacsak ez lehetetlennek nem bizonyul.

Kivonat

Faállományok felmérése és modellezése távérzékelési és geoinformatikai módszerekkel

A tartamos és természetközeli erdőgazdálkodás alapfeltétele, hogy tisztában legyünk az erdőben található biomassza minél pontosabb mennyiségével és a faállományok minőségével. A szakmai és társadalmi elvárásoknak megfelelően a klasszikus vágásos kezelésű erdőkből átalakított vegyes korú faállományok leírása egyre komplexebb, a régi módszerekkel egyre nehezebben meghatározható. A faállományok szerkezetének és állapotának leírására alkalmazott módszerek jelenleg a magyar erdőgazdálkodásban hagyományos, pont szerű terepi mintavételezésen alapulnak. Modern technológiák segítségével lehetőség van ezeket a méréseket megbízhatóbban kiterjeszteni a teljes faállományra, így a korábbi modellekre és becslésre alapuló paramétereket pontosabb következtetésekkel lehetne felváltani. A doktori kutatásom során a faállományok különböző paramétereit határoztam meg nagy felbontású (10-20 m) optikai űrfelvételekre épülő munkafolyamatokkal, melyekkel modellezni lehetett a faállományok kiterjedést, típusát és változását. A fejlesztett munkafolyamatokat 3 esettanulmányon keresztül mutattam be. Az esettanulmányokban megvizsgáltam a magyarországi erdőállományokra eső kiértékelhető Sentinel-2 űrfelvételek elérhetőségét, idősor alapú lék térképezést hajtottam végre mintaterületeken és faállomány-típus térképet készítettem hegyvidéki erdőkre. A kiértékelhető felvételek vizsgálatához kialakított munkafolyamattal erdőrésztlet szintű adatbázist hoztam létre, ami alapján ki lehetett válogatni a további feldolgozásra alkalmas űrfelvételeket. A kiválogatott űrfelvételek részletesebb kidolgozásához további előfeldolgozó módszertant alkottam, aminek a felhőmaszk moduljával akár 74%-kal jobb felhasználói pontosságot lehetett elérni a kiértékelést zavaró felhők detektálásában faállományok felett, mint az egy időpont alapján működő megoldással. Az idősor alapú léktérképezésnél egyes mintaterületeken 10% alá sikerül csökkenteni a terület meghatározás hibáját. A munkám során olyan módszerek és távérzékelési adattípusok kerültek alkalmazásra, melyek újszerűek az erdészeti távérzékelés területén, ezzel bővítve a hazai erdőtérképezés tudásbázisát. A kialakított módszertan a bemutatott mintaterületekhez hasonló jellegű erdőkön megismételhetők és akár országos szintre kiterjeszthetők.

Kulcsszavak: erdészet, távérzékelés, Sentinel-2, radiometria korrekció, spektrális szétkeverés, Deep Learning

Abstract

Surveying and modelling forests with remote sensing and GIS methods

Proper knowledge about resources in forest management is fundamental to meet the expectations of professionals and society. The methods used to describe the structure and condition of forests are currently based on traditional, point-like field sampling in Hungarian forest management. With the help of technologies like remote sensing, it is possible to extend these measurements to the entire forest compartment with higher reliability. Three case studies are presented in this thesis where various forest parameters were estimated with remote sensing workflows based on high-resolution (10-20 m) Sentinel-2 optical satellite images. The created workflows are presenting methods for determining the availability of imagery for time series analysis, mapping treefall gaps on sub-pixel level, creating reliable multitemporal cloud mask over forests and classifying forest types with Deep Learning. The evaluation of the results showed high accuracy ($> 70\%$ Overall Accuracy) in every application. The methods and data types that have been used are novel in the field of forestry in Hungary. The developed methodology provides high scalability and reproducibility on temperate forests.

Keywords: forestry, remote sensing, Sentinel-2, radiometrical correction, spectral unmixing, Deep Learning

Tartalomjegyzék

1	Bevezetés.....	10
1.1	A téma aktualitása	10
1.2	A kutatás célkitűzései.....	12
1.3	A disszertáció felépítése	14
2	Irodalmi áttekintés.....	14
2.1	Erdők távérzékeléses felmérése.....	14
2.2	Műholdas földmegfigyelés fejlődése.....	18
2.3	Faállományok megjelenése nagy felbontású optikai távérzékelte űrfelvételeken.....	19
2.3.1	A szenzor által rögzített képet befolyásoló szerkezeti tényezők faállományokon	19
2.3.1.1	Levelek	20
2.3.1.2	Ágak	21
2.3.1.3	Fakorona	22
2.3.1.4	Faállomány	23
2.3.1.5	Erdőterület	24
2.3.2	Idősorok.....	25
2.3.2.1	Interannuális (éven belüli) idősor.....	25
2.4	Az esettanulmányokhoz kapcsolódó irodalmak áttekintése	27
2.4.1	Kiértékelhető Sentinel-2 űrfelvételek vizsgálata a magyarországi erdőállományokra..	27
2.4.2	Lécek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben	28
2.4.3	Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben ...	29
3	Anyagok	30
3.1	Mintaterületek	30
3.1.1	Börzsöny.....	30
3.1.1.1	Tölgyes mintaterület 1 (T1).....	31
3.1.1.2	Tölgyes mintaterület 2 (T2).....	32
3.1.1.3	Bükkös mintaterület (B)	33
3.2	Űrfelvételek.....	34
3.2.1	Sentinel-2.....	34
3.2.1.1	Felhasznált Sentinel-2 űrfelvételek	35
3.2.1.1.1	Kiértékelhető Sentinel-2 űrfelvételek vizsgálata a magyarországi erdőállományokra	35
3.2.1.1.2	Lécek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben	36
3.2.1.1.3	Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben	37
3.3	Referencia adatok	37
3.3.1	Lécek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben	37
3.3.2	Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben ...	38
4	A kutatás módszerei	38
4.1	Űrfelvételek előfeldolgozása.....	38
4.1.1	Atmoszférikus korrekció	39
4.1.1.1	Sentinel-2 (Sen2Cor).....	39
4.1.2	Felhőmaszkolás	40
4.1.2.1	Sen2Cor.....	40
4.1.2.2	Multitemporális felhőmaszk Sentinel-2 idősorhoz.....	40
4.1.2.2.1	Kálmán-szűrő alapú multitemporális felhőmaszk Sentinel-2 idősorhoz.....	41
4.1.3	Hiányzó adatok pótlása	43
4.1.4	Topográfiai normalizáció	44
4.1.4.1	Megvilágítottsági állapot (IC)	45
4.1.4.2	Sen2Cor topográfiai normalizáció (ATCOR3).....	45
4.1.4.3	Empirikus forgatás módszere	45

4.1.5	Szegmentálás	46
4.1.5.1	Képszegmentálás	46
4.2	Adatosztályozás.....	47
4.2.1	Spektrális szétkeverés.....	48
4.2.2	Gépi tanulási módszerek.....	49
4.2.2.1	K-means.....	49
4.2.2.2	Random forest	50
4.2.2.3	Deep Learning - Konvolúciós neurális hálózatok	50
5	Esettanulmányok	52
5.1	Kiértékelhető Sentinel-2 űrfelvételek vizsgálata a magyarországi erdőállományokra.....	52
5.1.1	Módszertan	52
5.1.1.1	A felhőmaszkok kiértékelésének módszertana.....	52
5.1.1.2	Az űrfelvétel elérhetőség adatbázis létrehozása	53
5.1.2	Eredmények és az eredmények értékelése.....	54
5.1.2.1	Az adatbázis és a térkép értékelése.....	54
5.1.2.2	A kiválasztott faállomány-típus főcsoportok értékelése.....	56
5.1.3	Következtetések.....	57
5.2	Lécek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben	57
5.2.1	Módszertan	57
5.2.1.1	Előfeldolgozottsági szint vizsgálata	58
5.2.1.2	Árnyék modellezés	58
5.2.1.3	Spektrális szétkeverés.....	58
5.2.1.4	Spektrális minták gyűjtése.....	59
5.2.1.5	Szétkevert képek mozaikolása.....	60
5.2.1.6	Szintetikus lécek modellezése	60
5.2.1.7	Terület kimutatás.....	61
5.2.1.7.1	Egyes felvételek kiértékelése	61
5.2.1.7.2	Idősor összeállítása.....	61
5.2.1.8	A spektrális minták vizsgálata.....	62
5.2.1.9	Érvényesítéshez használt referencia anyag készítése	62
5.2.2	Eredmények és az eredmények értékelése.....	62
5.2.2.1	Spektrális minták értékelése	62
5.2.2.2	A spektrális minták számának vizsgálata	65
5.2.2.3	Szintetikus lécek modellezése.....	65
5.2.2.4	Lécek területének kimutatása egyes felvételek sorozata alapján	66
5.2.2.4.1	Tölgyes mintaterület 1 (T1).....	66
5.2.2.4.2	Tölgyes mintaterület 2 (T2).....	67
5.2.2.4.3	Bükkös mintaterület (B)	68
5.2.2.5	Lécek területének kimutatása idősor alapján.....	69
5.2.2.5.1	Tölgyes mintaterület 1 (T1).....	69
5.2.2.5.2	Tölgyes mintaterület 2 (T2).....	71
5.2.2.5.3	Bükkös mintaterület (B)	72
5.2.2.6	A terület túlbecslés lehetséges oka	74
5.2.3	Következtetések.....	74
5.3	Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben	75
5.3.1	Módszertan	75
5.3.1.1	Idősor összeállítása	76
5.3.1.2	Képszegmentálás	76
5.3.1.3	Adatosztályozás	77
5.3.1.3.1	Erdőborítás	77
5.3.1.3.2	Faállomány-típus	77
5.3.1.4	Érvényesítés.....	78
5.3.2	Eredmények és az eredmények értékelése.....	79
5.3.2.1	Előfeldolgozás értékelése	79

5.3.2.2	Felhők detektálásának értékelése.....	79
5.3.2.3	Az előfeldolgozó lánc értékelése.....	80
5.3.2.4	Osztályozások eredményei	81
5.3.2.4.1	Erdőborítás osztályozás.....	81
5.3.2.4.2	Faállomány-típus osztályozás.....	83
5.3.3	Következtetések.....	85
6	Összefoglalás.....	86
7	A kutatások legfontosabb eredményeit összefoglaló tézisek	87
8	Megjegyzés.....	88
9	Köszönetnyilvánítás	88
10	Rövidítések.....	89
11	Ábra- és Táblázatjegyzék	90
12	Irodalomjegyzék.....	93

1 Bevezetés

1.1 A téma aktualitása

Az erdőgazdálkodás jelenlegi gyakorlatában a gazdálkodók az erdőtervezésnél felmért paraméterek, terepi bejárások alkalmával szerzett tapasztalatok és további mérések alapján kezelik az erdőket. Ez a hibrid módszer már közel két évszázada van használatban, ami homogén állomány szerkezet mellett vágásos üzemmódban kezelt erdőknél bizonyítottan jól működik [1]. A módszer megbízhatóságának hátterét a statisztikai mintavételezés [2] nyújtja, amelyen az erdőbecslés [3] alapul. Az erdő üzemtervi leírása egy közel objektív adathalmaz, melynek a pontosságát a mintavételes becslések [4] precizitása határozza meg. Az erdő leírása 10 éves ciklusokban készül el a Körzeti Erdőtervezéshez [5] kapcsolódva. A faállományokról pontosabb összképet csak a terepi látogatás során nyer a gazdálkodó, mivel az erdőleíró adatok elsősorban vertikálisan írják le az erdőt a különböző állományrészekben keresztül. A horizontális térbeli kiterjedés rögzítésére korlátozottak a lehetőségek az erdőleírásban [6], ezeket a körlap, elegyedés módja vagy a sűrűség mutatók képesek kifejezni. A GNSS (Global Navigation Satellite System) alapú területmérések [7] napi feladatává vált az erdőgazdálkodóknak a térinformációk beszerzéséhez [8]. A terepi bejárásnál pontszerűen gyűjtött adatoknál objektívebb adatokat szolgáltatnak a légi fotogrammetriai termékek térbeli adatok kinyeréséhez [9]. Az ortofotók használata széles körben elterjedt az erdőgazdálkodók körében [10]. Míg korábban az ortofotók elérhetősége igen korlátozott volt, mára a nem mérőkamerával felszerelt pilóta nélküli repülő járművek (Unmanned Aerial Vehicle, UAV) térhódításának [11], a fotogrammetria fejlődésének [12] és a jogszabályok módosításnak következtében [13] kis területekről is gyorsan információkat lehet szerezni rövid időn belül [14].

A hagyományos erdőleírás során gyűjtött adatok interpretálása a döntéshozatalhoz nem feltétlenül igényel részletesebb helyismereteket, amennyiben az adatgyűjtés reprezentatív mintaszámmal történt meg. Heterogén faállományok esetén 30-50%-kal több minta szükséges egyes erdőbecslési eljárásoknál [6] homogén faállományokhoz képest. Az erre fordított időtöbblet és a körzeti erdőtervezéssel járó adminisztrációs teher növekedése [15] az erdőleírás hatékonyságát csökkentette az utóbbi évtizedekben, aminek következtében az ország egyes területein rendszeressé vált az átmeneti erdőtervek alkalmazása [16]. Az elmúlt két évtizedben az agrár felsőoktatásban résztvevők száma csökkenést mutat, 2001 és 2019 között megfeleződött [17]. Ez részben a demográfiai változásokat követi [18], részben a szektor népszerűtlenségét mutatja az aktuális generációkban és tükrözi az agrárgazdaság szerkezeti átalakulásait [19], [20]. Az erdőgazdálkodás egyes szektorait már jelenleg is érinti a munkaerőhiány problémája [21], [22]. A körülmények alapján várható, hogy az erdészeti felsőfokú végzettséggel rendelkező szakemberekből is hiány lesz. Az ország erdőterülete mérsékelten, de továbbra is növekszik [23], [24]. A munkaerőhiány mellett a munkáltatókat a fiatalabb generációhoz tartozó munkavállalók gyakoribb munkahely váltása [25] is negatívan érintheti a jövőben. A magasabb fluktuáció következtében a korábbi, csak egyes személyekhez kötődő, hosszú idő alatt megszerzett helyismeretek nem feltétlenül adódnak át objektívan az utódnak, ami az erdőleírásnál a hatékonyság további visszaeséséhez vezethet. Ezeket a helyi szinten megjelenő problémákat az egyes feladatok automatizálásával [26] lehetne feloldani, aminek következtében kevesebb élőmunka befektetéssel hasonló teljesítményt lehet elérni.

Míg az emberi erőforrások menedzsmentje az erdészeti ágazat belső problémája lesz, mellette foglalkozni kell a kívülről érkező, gazdálkodást is érintő kritikákkal. Az utóbbi években egyre gyakrabban olvasható civil szervezetek kritikája az állami erdőgazdaságok tevékenységeiről [27], [28]. Ezek a kritikák ugyan lokális problémákra mutatnak rá, de a háttérükben egy olyan, egyre jobban bizonyított, [29] és a társadalom által fontosabbnak tartott nézetek állnak [30], melyeket a 21. században már nem lehet teljesen figyelmen kívül hagyni, mint például a klíma változását. A gazdálkodók részéről az átláthatóbb gazdálkodással és szélesebb köröket elérő kommunikációval lehetne a társadalom felé nyitni, melynek egy lehetséges formája interaktív térképek publikálása lehetne. Ezek már bizonyos

célokra használatban vannak, mint például a vadászattal érintett területek [31] vagy az erdőtervezés alatt álló területek [32] megjelölése, de elérésük még speciális ismereteket igényel.

A jelenlegi erdőleírás erdőrészt színtén történik, ami egy átlagosan 3.7 ha területű egységet jelöl az Országos Erdőállomány Adattárban (OEA). Az erdőrésztetek általában homogén termőhelyi paramétereket takaró területek, melyeket hegyvidéken többnyire természetes képződmények határolnak. Síkvidéken gyakran adminisztratív határok határozzák meg az erdőrésztetek alakját. A homogén termőhely és egységes faállomány kezelés miatt a rajta álló faállomány is egységesnek tekinthető a legtöbb esetben. Az egységes faállományokat modellezni lehet, részletes felméréseik alapján születtek meg a fatermési és erdőnevelési modellek [33]. Az erdők jövőjének tervezése, mely Magyarországon a Körzeti Erdőtervezés [5] keretében történik, ezeket a modelleket [6] alkalmazza. Ezek a modellek rendszerint hektárra fajlagosított értékeket tartalmaznak, így a modellek alapján kiszabott erdőnevelési beavatkozásoknál a faállományok pontos kiterjedésének az ismerete nagyon fontos. Az erdőrészteten belüli faállomány kiterjedése nem mindig azonos az erdőrésztet poligon méretével [34]. Az erdőrészteten belül a jelenleg alkalmazott erdőleíró rendszer is képes kezelni különböző állományrészteteket vertikálisan és horizontálisan. A horizontális kiterjedések tárolására csak nagyon általánosított formában van lehetőség, az Erdőrésztetleíró-Lap elegyedés módja című mezőjében [33], így a pontosabb térbeli elhelyezkedését nem tudja leírni önmagában. Kiegészítő geoinformatikai téradatokkal vagy helyismerettel rendelkező személyek képesek ilyen esetben az állomány jövőjének pontosabb tervezését elvégezni.

Magyarországon 2015-ben közel 60 000 hektár olyan erdőterület volt [35], ahol a korábbi vágásos erdőműveléssel kezelt erdők vegyeskorúvá alakítása van előírva az érvényes körzeti erdőtervekben. Az átalakító üzemmód a korábbi egykorú, vágásosan kezelt erdők többkorúvá alakítását jelenti, ami lehetőséget nyújt a szálaló üzemmód alkalmazására a jövőben. A szálaló üzemmód segítségével folyamatos erdőborítás mellett lehetséges az erdők párhuzamos használata és felújítása. Erdőtervezés szempontjából nagyobb kihívást jelentenek, így nyilvántartásukra fokozottabb figyelmet kell fordítani, mivel a hagyományos módszerekkel nagyon sűrű terepi mintavétel segítségével lehet csak pontosan felmérni a fakészletüket [36].

Az erdők funkciója folyamatosan változott a múltban [37], és az évszázadok óta művelésnek alá vetett faállományok részben elvesztették önszabályozó képességeiket [38], így az emberek kezében van az irányításuk. A felsorolt problémák arra mutatnak rá, hogy szükség van olyan objektív erdőleltárra lokális szinten, ami a mostaninál gyakoribb frissítéssel rendelkezik, több térbeli paramétert tartalmaz, ezzel támogatva az erdő fenntartható és jobban átlátható kezelését, amivel az erdő jövőjét alapozzuk meg hosszú távon.

A bruttó hazai termék (GDP) termeléséhez 3.6%-kal járult hozzá 2018-ban a mezőgazdaság, ami magában foglalja az erdő- és halgazdálkodást [19]. Habár ezt a mutatót nagy mértékben befolyásolják más ágazatok teljesítményei, annyit határozottan ki lehet jelteni, hogy az erdészeti szektor teljesítménye az ország természeti adottságaihoz képest elmarad hasonló adottságú országoktól [39]. Az erdő olyan erőforrás, melynek a hozamát pontosabban lehet becsülni, mint a mezőgazdasági kultúrákét, mivel kevésbé van kitéve az időjárás ingadozásának rövid távon, és jelentősen hosszabb életciklusa van a szántóföldi növényekhez képest. Hátránya, hogy sokkal hosszabb idő alatt realizálódik a nyeresége és az eltelt idő alatt a piaci igények megváltozhatnak. A súlyos természeti katasztrófák [40] hosszabb távú kiesést okozhatnak, mint mezőgazdasági termelés esetén. Az erdőt, mint erőforrást, nem szabad csak gazdasági szempontból vizsgálni. Az erdő eredeti funkciója az ökoszisztéma szolgáltatás [41], ami a legtöbb társadalom kialakulásában nagy szerepet játszott. Ennek értékét materiális javakban nehéz meghatározni [42], de más mutatókkal jobban kifejezhető. Ilyen mutató az erdő természetessége, melyet az erdő állományában lévő fafajok őshonossága és termőhely azonossága határoz meg. Ennek országos értéke 48.6% volt 2007-ben [43].

A Nemzeti Erdőstratégia [44] célkitűzései közé tartozik mind az erdők gazdasági értékének, mind az ökoszisztéma szolgáltató képességének növelése bizonyos mértékig hazánkban, habár a gazdasági érdekek és a természet védelme gyakran összeférhetetlen dolog [45]. Ehhez szükség lenne egy olyan nyilvántartásra, amely nem csak lokális szinten készül el, mint a Körzeti Erdőterv, hanem képes országos szinten szolgáltatni mind a gazdasági, mind a természetvédelem szempontjából fontos naprakész információkat a megfelelő irányelvek [5] betartásához. Egy ilyen rendszer csak magasan automatizált adatgyűjtési módszerek mellett lenne fenntartható. Egy lehetséges útja az ilyen típusú adatszerzésnek a távérzékelés [46]. Számos távérzékelésre épülő megfigyelő szolgáltatás született már, melyeket mezőgazdasági [47], [48] térképezésre vagy erdő monitoringra [49]–[52] építettek ki, de lokális szinten is érvényesített, gazdálkodásba integrálható, nagy felbontású operatív rendszer eddig kevés született. A Földmegfigyelési Információs Rendszer (FIR)[53], mely elsősorban adat infrastruktúrát szolgáltat majd az ország erdeinek pontosabb nyilvántartásához, valamint a Nemzeti Ökoszisztéma Szolgáltatások Térképezése és Értékelése (NÖSZTÉP) program [54] a hazai ökoszisztémák felméréséhez kiépítése 2017-ben kezdődött meg. Ezek a fejlesztések mutatják, hogy az igények egyre fokozódnak a térben és időben is részletesebb faállomány felmérésekre már a közigazgatás részéről is.

A faállományok szerkezetének és állapotának leírására alkalmazott módszerek jelenleg nem használják ki a modern technika adta lehetőségeket. A tartamos [55] és természetközeli erdőgazdálkodás [56] alapfeltétele, hogy tisztában legyünk az erdőben található biotomassza minél pontosabb mennyiségével és a faállományok minőségével [57]. A szakmai és társadalmi elvárásoknak megfelelően a klasszikus vágásos kezeléssel erdőkből átalakított vegyes korú faállományok leírása egyre komplexebb [58], a régi módszerekkel egyre nehezebben leírható [59]. Ennek érdekében olyan fejlesztésekre van szükség, amelyekkel minél pontosabb modellt tudunk alkotni az erdő múltjáról, jelenéről és jövőjéről.

1.2 A kutatás célkitűzései

A doktori kutatás célja olyan távérzékelésen alapuló munkafolyamatok fejlesztése volt, amelyeknek segítségével idő- és költséghatékonyan lehetséges különböző faállomány paraméterek meghatározása nagy felbontású optikai űrfelvételken.

A kutatás célkitűzéseinek részletesebb megfogalmazása:

- Bemutatni, hogy a nagy felbontású űrfelvételken látható faállományok milyen formában jelennek meg és ezeket milyen szerkezeti és környezeti tényezők befolyásolják.
- Megvizsgálni, hogy a Sentinel-2 műhold ingyenesen elérhető, nagy felbontású űrfelvételeiből lehetséges-e olyan idősorok összeállítása, amelyen a faállományok különböző paraméterei kiértékelhetők.
- A Sentinel-2 műhold különböző előfeldolgozott szintű termékeinek vizsgálata faállományokon.
- Elemzésre kész, konzisztens Sentinel-2 űrfelvétel-idősor előállításához automatizált feldolgozó lánc fejlesztése, ami kifejezetten a faállományok spektrális és időbeli jellegzetességeit veszi figyelembe a radiometriai korrekció során.
- Idősor alapú távérzékelési munkafolyamat fejlesztése, amivel a faállományokban létrehozott mesterséges és természetes lélek területe pontosan becsülhető szubpixel szinten.
- Faállomány-típusok térképezéséhez olyan távérzékelési munkafolyamat fejlesztése, amely a lehető legjobban figyelembe veszi az állományok spektrális-térbeli-időbeli jellegzetességeit.

A munka három esettanulmányból áll össze, melyek a fenti kitűzött célokra koncentrálnak:

1. Kiértékelhető Sentinel-2 űrfelvételek vizsgálata a magyarországi erdőállományokra: Az optikai földmegfigyelő műholdak felvételeit erdőterületekre csak felhő- és felhőárnyék mentes képeken lehetséges kiértékelni. Régióink felett magas az átlagos felhőborítottság (~70%), ezért kevés teljesen felhőmentes kép érhető el. Egy olyan adatbázist hoztam létre Sentinel-2A űrfelvételek alapján, amely erdőrészt szinten nyújt információt arról, hogy milyen időpontokban áll rendelkezésre kiértékelhető űrfelvétel. Az adatbázison végzett vizsgálatok alapján teljesebb képet kaptam az idősorok alkalmazhatóságáról és azoknak korlátairól.
2. Lékek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben: A Sentinel-2 műhold 10 m felbontású felvételeivel lehetőség nyílt arra, hogy olyan kisebb mértékű erdészeti beavatkozásokat is megfigyelhessünk, mint a mesterséges lékek. A kis méretű lékek területkimutatása szubpixeles megoldásokkal kiértékelhető. A magas időbeli felbontást kihasználva évente több térkép készíthető egy adott állapotról, azonban ilyenkor a felvételek rögzítési körülményei különböznek. A kutatás során olyan módszert alkalmaztam, amely képes kezelni a különböző felvételi körülményeket, így a létrehozott térképekből összeállított idősoron nagyobb pontossággal meg lehet határozni az erdővel és lékekkel borított állományrészek térbeli kiterjedését, mint egy időpont alapján. Az esettanulmány további célja volt, hogy a különböző előfeldolgozottsági szintű űrfelvétel idősorok alapján képet kapjak az eredményre gyakorolt hatásukra.
3. Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben: A faállomány felső lombkoronaszintjének fafajösszetételét az űrfelvétel idősorok spektrális, idő- és térbeli jellemzői alapján lehet meghatározni. Annak ellenére, hogy az idősor csak a korona felszínről szolgáltat információt, a faállomány-típusra következtetni lehet a detektált főfafaj alapján. A kutatás során egy űrfelvétel-idősor előfeldolgozási láncot fejlesztettem, amelynek segítségével az erdőborítást pontosabban lehet kiértékelni, mint az adatszolgáltató által nyújtott megoldással. Az előfeldolgozott képanyagon történt meg a faállomány-típusok kiértékelése a homogén erdőfoltokon, erdőrészt szint alatti felbontásban a Börzsöny hegységben. A kutatásban mély konvolúciós neurális hálózatokra épülő képosztályozási eljárások erdészeti alkalmazhatóságát vizsgáltam nagy felbontású űrfelvétel idősorokon, ami az idősor spektrális-térbeli-időbeli jellemzőit használta fel az egyes faállomány-típusoknak. Az elért osztályozási pontosságot egy Random Forest típusú osztályozó modell teljesítményével hasonlítottam össze, ami csak a spektrális-időbeli képjellemzőket használta fel. Az összehasonlítás célja az osztályozó modellek létrehozásához szükséges befektetett élő munkának vizsgálata volt.

Az esettanulmányok eredményei alapján a következő hipotéziseket állítottam fel:

1. Az egyes erdőrésztletekre sűrűbb idősor állítható össze, ha nem Sentinel-2 csempe (1000000 ha), hanem erdőrésztlet (átl. 3.7 ha) alapon történik a vizsgálat.
2. Topográfiai és atmoszférikus korrekción átesett Sentinel-2 űrfelvétel-idősor alapján jobban meghatározható és monitorozható a mesterséges lékek kiterjedése hegyvidéki faállományokban.
3. A Sentinel-2 űrfelvétel-idősor előfeldolgozási lánc fejlesztése faállományokra jellemző spektrális-időbeli-jellegzetességei alapján javítja a távérzékelési elemzés végső eredményét.
4. Az erdőterületek fölött a Sentinel-2 idősorban, Kálmán-szűrésen alapuló módszerrel jelentősen pontosabb felhőmaszkok hozhatók létre, mint a Sen2Cor szoftverben egy időpont alapján.
5. A faállományok megvilágítottságát is figyelembe véve olyan idősor alapú térkép hozható létre, ami szubpixeles felbontásban mutatja a lékek kiterjedését nagy pontossággal.
6. A faállomány-típusok térképezése nagy pontossággal lehetséges Sentinel-2 űrfelvétel-idősorokon olyan mély konvolúciós neurális hálózatokkal, melyek a spektrális-térbeli-időbeli jellegzetességeket használják fel.

1.3 A disszertáció felépítése

A disszertáció három önálló esettanulmányból áll össze, melyeknél átfedések vannak az alkalmazott mintaterületek, anyagok és módszerek között. A következő nagyobb egységekre osztottam a munkámat:

1. Az irodalmi áttekintés fejezetben az erdők távérzékeléses felmérésének alapjai, a műholdas földmegfigyelés leírása és az egyes esettanulmányok irodalmának részletes bemutatása olvasható.
2. Az anyagok fejezetben a mintaterületek, felhasznált űrfelvétel típusok és a kutatási eredmények érvényesítéséhez alkalmazott referencia adatok leírása található.
3. A módszertan fejezetben az egyes esettanulmányoknál alkalmazott képfeldolgozási munkafolyamatok elemeinek leírása van.
4. Az esettanulmányok fejezetben az egyes tanulmányok munkafolyamatainak leírása, ezeknek eredményei majd a levont következtetések találhatók.
5. Az összefoglalás fejezetben a fejlesztett módszerek együttes alkalmazásainak előnyeit mutatom be.

2 Irodalmi áttekintés

2.1 Erdők távérzékeléses felmérése


A távérzékelési és térinformatikai módszerek napjainkban egyre nagyobb teret nyernek a földfelszín vizsgálatában, a felszínen zajló folyamatok elemzésében [60]. A távérzékelés Bácsatyai és Márkus megfogalmazása alapján olyan információgyűjtési eljárás, melynek során általában az elektromágneses hullámok közvetítésével egységes adatrendszer kapunk, leggyakrabban a földfelszínről [46]. Az érzékelőműszerek a tárgyról visszavert vagy azok által kibocsátott (saját) sugárzást rögzítik. A távérzékelés fogalmába nem csak a speciális adatgyűjtést, de az adatok térinformatikai kiértékelését is beleértjük. Ma már számos feladat ellátásához szabadon elérhető távérzékelte adatok közül is válogathatunk. Ezek bizonyos esetekben kiválthatják a költséges vagy nehezen kivitelezhető földi méréseket, illetve kiegészíthetik a hagyományos módszerekkel előállított erdészeti adatbázisokat [60]. Távérzékeléssel az erdő különböző paramétereit lehet meghatározni. Légifotók az 1930-as évek óta használatban vannak az erdőtervezésben Magyarországon [9]. Lézerszkennelt adatokból az egyes fák törzs és korona paraméterei is kinyerhetők már nagy pontossággal [61]. Az erdőborítás és a faállományok egyéb paraméterei is meghatározhatók nagy felbontású légi vagy műholdas adatok alapján [62] és különböző monitoring alkalmazások is léteznek az erdő állapotának megfigyelésére [63].

A távérzékelés során a képalkotó szenzor egy modellt készít a környezetről. A távérzékelte modellben nem a valós környezet képződik le, hanem annak egy részleges és tökéletlen változata. Minden távérzékelési feladata végecélja, hogy a távérzékelte modell alapján következtethessünk a valós környezetre [64]. A felvételeken látható objektumok felismerése, tematikus azonosítása általában nem triviális, sőt leggyakrabban valószínűségi jellegű [46].

A távérzékeléssel készült felvételek legfontosabb jellemzői a térbeli felbontás, spektrális felbontás, időfelbontás és a radiometriai felbontás [46]. A felvételeket kategorizálni lehet a leképezett térbeli dimenziók alapján, valamint a szenzor helyzete alapján. Ezek a paraméterek határozzák meg, hogy milyen mély mintavételezésre képes az adott távérzékelő szenzor a valós környezetről.

A térbeli felbontás mutatja meg, hogy a felszínen mekkora oldalhosszúságú területet mintavételez egy képeleme (pixel) [65] a felvételnek. A térbeli felbontás alapján kis (> 500 m), közepes (500-30 m), nagy (30-5 m) és nagyon nagy (< 5 m) felbontású felvételeket különböztethetünk meg az űrfelvételeknél.

A spektrális felbontás (1. ábra) azt fejezi ki, hogy egy adatgyűjtő rendszer a spektrum hány és milyen szűk spektrális tartományában érzékeli az elektromágneses energiát [46]. A spektrális felbontás alapján pankromatikus (1 nagyon széles tartomány), multispektrális (2-40 széles tartomány) és hiperspektrális (40 > keskeny tartomány) kategóriákba sorolhatók a felvételek. A nagyon széles tartomány 200 nm-nél nagyobb sáv szélességet, a széles tartományú sávok 10-200 nm sáv szélességeket fednek le és a keskeny tartományú sávok 10 nm-nél keskenyebb részt fednek le az elektromágneses spektrumban.



1. ábra: Különböző multispektrális műholdas szenzorok spektrális mintavételi tartományai az atmoszférikus transzmisszió függvényében (Adatok forrása: <http://landsat.gsfc.nasa.gov/wp-content/uploads/2015/06/Landsat.v.Sentinel-2.png> (2020. 09. 10.))

Az időfelbontás, más néven időbázis az egymást követő felvételezések között eltelt idő. Különösen jelentős a gyorsan változó jelenségek vizsgálatában illetve általában a változások felderítésében (monitorozás)[46]. Geostacionárius vagy fix telepítésű szenzoroknál az adatok akár folyamatosan elérhetőek, míg a napszinkron pályán keringő műholdak óras- napos visszatérési idővel rendelkeznek. A légi felvételeknél évek is eltelhetnek két felmérés között egy adott területről.

A felvétel radiometriai felbontása a rögzített spektrális tartomány digitális mintavételezési mélységét jelöli, ami a beérkező elektromágneses sugárzás maximális és minimális értékei közötti intervallum fokozatok számát mutatja [46].

Jellemzően a képkalkító szenzorok 2 dimenzióban rögzítik az adatokat, melyek raszteres adatformátumban [46] tárolnak. Távmérések sorozatából álló távérzékelte adatok 3 dimenzióval rendelkeznek, melyeket többnyire vektoros adatformátumban tárolnak pontfelhőként. Az adatok feldolgozása során lehetséges a térbeli dimenziók emelése, mint például sztereó fotogrammetriánál. Gyakran a térbeli dimenziók mellé az időt szokták párosítani, így lehet értelmezni a 4 dimenziós adatokat [66].

A szenzor helyzete határozza meg, hogy milyen geometriai tulajdonságai lesznek a felvételnek. Légi vagy űr eszközre helyezett szenzorok többnyire függőleges tengelyű (nadír) felvételeken ábrázolják a föld felszínén lévő objektumokat, míg a statikus műszerekre jellemzően a nem függőleges tengelyű felvételeken (oblique).

Amennyiben a szenzor egy elektromágneses hullámok kibocsátására alkalmas adó-vevő egység, aktív távérzékelésről beszélünk (pl. lézeres letapogatás, radar szenzorok). Ha a szenzor csak vevő egységet tartalmaz, ami más sugárforrás által kibocsátott, az objektumok által visszavert jelet rögzíti, akkor passzív távérzékelésről beszélünk (pl. az optikai távérzékelés) [34]. A passzív távérzékelés esetén a sugárzás forrása a Nap és az érzékelt tartomány a látható fény (400 nm–700 nm), közeli infravörös (700

nm – 1000 nm), rövid hullámú infravörös (1400 nm – 2400 nm) és termális infravörös (10000 nm – 13000 nm) tartományokba esik általában (1. ábra).

A különböző távérzékelt adattípusok a faállományok különböző paramétereinek meghatározására alkalmasak. Teljes körű leírásra önmagában egyik típus sem alkalmas, de kombinációjukból pontos erdőleírást lehet kapni, ami terepi mintavételezések pont szerű kiterjedését képes a teljes területre kiterjeszteni. A faállományok esetében statikus és dinamikus paramétereket lehetséges meghatározni. Az erdőleírás jellemzően statikus paramétereket tartalmaz, mint a faállomány kiterjedése, magassága, erdőtípusa, amit a leírás időpontjában határoztak meg. Dinamikus paraméterként az állomány növedékét lehet értelmezni, de az egészségi állapot változása is ide sorolható. Távérzékelés segítségével a statikus paraméterek megfigyelését is célszerű több időpontú felvételek alapján elvégezni, ugyanis így a valószínűség alapú következtetéseket pontosítani lehet. A távérzékelt felvétel típusok erdészeti hasznosíthatóságáról mérsékelt övi erdőkben Tanács és mtsai. munkájában [60] található egy összefoglalás (1. táblázat).

1. táblázat: távérzékelte felvétel típusok erdészeti hasznosíthatóságának csoportosítása adattípus szerint Tanács és mtsai. [60] munkájából


Távérzékelte adattípus	Felhasználás
Kis és közepes térbeli felbontású felvételek	- erdő – nem erdő térképezés - erdőterület változások követése (terjeszkedés, erdőirtás) - fenyők, lombos fafajok, fiatalos térképezése - erdőfelújítások nyomon követése (lékek, bontóvágás, végvágás) - erdőkárok térképezése (tűzkár, szélöntés, száradás) - vegetációs index időbeli változásának vizsgálata (éven belül, évek között)
Nagyon nagy térbeli felbontású légi és űrfelvételek	- faj meghatározás vagy fajcsoport meghatározás (több időpont segít) - elegyarány számítás - zárodás számítása - törzszám és lombkorona térképezés idős/gyérített/tűlevelű állományban - törzszám és lombkorona méret alapján fatérfogat becslés - sztereó felvételekből lombkorona felületmodell kinyerés, famagasság mérés
Hiperspektrális felvételek	- faj meghatározás (vörös él, indexek, közeli infravörös sávok) - elegyarány meghatározás - biomassza mennyiség becslése - egészségi állapot térképezése (vízhiány detektálása, kártevők és kórokozók kártétele, tüzesetek – károsítás jellege, mértéke) - biofizikai paraméterek becslése (klorofill-tartalom, növényi színanyagok, cellulóz, lignin stb.)
Légi lézeres letapogatás (3D adat)	- felvételekből pontos famagasság számítás domborzat modell előállításával - szinteztettség becslése a köztes visszaverődésekből - magasság és teljes jelalakos letapogatás adatai alapján fatérfogat becslés - idős állományoknál látszanak a törzsről visszaverődő pontok is (egyefa térképezés) - lokális maximum vagy inverz vízgyűjtő eljárással törzszám és korona térképezés - törzszám és lombkorona méret alapján fatérfogat becslés
Földi fotogrammetria és lézeres letapogatás (3D adat)	- faj (törzs spektrális és texturális jellemzőiből) - zárodás (hagyományos és hemiszférikus zenitfelvételek osztályozása) - mellmagassági átmérő (törzsfelismerés) - körlevegő (szögszámlálás) - törzsalak, ágtszta törzsmagasság - famagasság (állomány széléről készült felvételek) - fatérfogat (átmérő, magasság, faj szerint)

2.2 Műholdas földmegfigyelés fejlődése

A földmegfigyelés (angolul Earth Observation) alatt a Föld világűrbeli való megfigyelését értjük különböző szenzorokkal. Az első kísérlet a Földbolygó megfigyelésére a világűrbeli a 2. világháború során fejlesztett V-2 rakétákra szerelt kamerákkal történt az 1940-es évek végén az Amerikai Egyesült Államokban [67]. A műhold platformra szerelt szenzorok [68], [69] története 1960-ban kezdődött a TIROS kísérleti meteorológiai műholdakkal, melyekkel bizonyították az ilyen felvételezési mód létjogosultságát [70]. 1963-ban a Mercury űrprogram űrhajósai által készített fényképek már geológiai térképezésre alkalmas minőséget nyújtottak. Az első digitális képeket rögzítő és Föld felé irányított, stabilizált meteorológiai műhold a Nimbus-program keretében került pályára 1964-ben. Az űrhajósok által készített nagy felbontású fényképek és a globális lefedettséget biztosító Nimbus program adta a lendületet az első földmegfigyelő műholdprogram elindításához 1972-ben [71]. A létrehozott Landsat program célja már a földfelszínen történő folyamatok térképezése volt, így a fedélzetén lévő szenzorok olyan spektrális tartományokban érzékeltek, melyek a vegetáció aktivitás megfigyelését is lehetővé tették kezdetben 60 méteres felbontásban 18 napos visszatérési idővel és 6 bites radiometriai felbontással [46].

Az idő előrehaladásával és a technológia fejlődésével mind a térbeli, időbeli és radiometriai felbontás terén jelentős fejlődés történt az elmúlt évtizedekben. A földmegfigyelő műholdak időbeli felbontását elsősorban a program célja és költségvetése befolyásolja, a fejlődést a technológia kevésbé korlátozta. A kezdeti 6 bites [72] radiometriai felbontás már 12 bitnél jár [73]. A térbeli felbontás terén 1999-ben történt korszakváltás, amikor pályára állították az IKONOS-2 műholdat, amely már 1 m felbontásban szolgáltatott felvételeket kereskedelmi forgalomban [74]. A jelenleg kereskedelmi forgalomban elérhető legnagyobb felbontás 0.3 m, melyet a WorldView-4 műhold szolgáltat [75]. A felbontások együttes növelése egyetlen szenzor esetén még mindig nem lehetséges. Ennek feloldására műhold konstellációkat alkalmaznak, ahol több azonos típusú, egymástól eltolt fázisban keringő szenzor alkot rendszert. A 21. század első évtizedében jelentek meg a piko műholdak CubeSat néven, melyekben már távérzékelésre alkalmas szenzorokat tudtak elhelyezni költséghatékonyan [76]. Az Egyesült Államokban létrehozott Planet Labs Inc. (San Francisco, Kalifornia, Egyesült Államok) nyitott újabb fejezetet a földmegfigyelés történelmében, mikor 2013-ban pályára állította 28 darab CubeSat-ból álló Flock-1 konstellációját, melyek 3-5 méteres felbontásban nyújtanak felvételeket globálisan, 10 napnál gyakoribb visszatéréssel [77]. A cég 2019-ben már több mint 140 db CubeSat műholdat magába foglaló flottával rendelkezik, amiknek visszatérési ideje már órákban határozható meg.

A földi erőforrás kutatásra fejlesztett programok (2. ábra) műholdjai jellemzően napszinkron pályán keringenek, így mindig azonos időpontban látogatnak vissza ugyanazokra a területekre. A hasonló felvételi geometria megkönnyíti a képanyag idősoros kiértékelést. A legújabb kereskedelmi célú műholdak a felhasználók igényeihez igazodva rendszeresen módosítják pályájukat, így azonos területekről rendszerint eltérő felvételi geometriával készítik felvételeiket [78]. A CubeSat konstellációk a még gyakoribb visszatérési idő eléréséhez a Napszinkron pálya mellett a Nemzetközi Űrállomás (ISS) pályáját is igénybe veszik [79].



2. ábra: A földmegfigyelő műholdak fejlődése (Adatok forrása: <https://earth.esa.int/web/eoportal/satellite-missions/> (2020. 09. 10.))

2.3 Faállományok megjelenése nagy felbontású optikai távérzékelte űrfelvételeken

A faállományok egymástól és más felszínborításoktól való spektrális elkülönülése a szenzoron rögzített spektrum tartományok kialakításának, radiometriai-térbeli felbontásának és a felvételi körülményeknek a függvénye. A nagy felbontású optikai földmegfigyelő műholdak jellemzően a látható (visible spectrum, VIS), közeli infravörös (near infrared, NIR) és a közép infravörös (short wave infrared, SWIR) tartományokban rögzítik felvételeiket. Nagy felbontású űrfelvételeken a faállományok koronaszerkezetének térbeli jellegzetességei is megjelennek, melyek a faállomány korának és típusának lehetnek leírói. Passzív optikai távérzékelésnél a megvilágítás forrása a Nap, amelynek a megfigyelt objektumhoz viszonyított pozíciója (magassági és azimuth szög) nagy mértékben meghatározza a szenzoron rögzített képet. A felvételeken megjelenő faállomány képét több tényező befolyásolja, melyek közül a legmeghatározóbb a fafajok lombjának anyaga. Mellette a fakorona szerkezeti felépítése, állomány szerkezete és az egyes faegyedek vegetációs aktivitása játszik fontos szerepet a felvételen megjelenő képen. Ezek a tényezők együttesen befolyásolják a beérkező napsugárzás visszaverődését [46], aminek képét az űrszenzor rögzíti.

A kutatás során vizsgált űrfelvételek felbontása nem alkalmas arra, hogy egyes fa szinten vizsgáljam a faállományokat, de az esettanulmányokban alkalmazott munkafolyamatok megértéséhez - geometriai szempontból - szükség van a szenzoron rögzített kép kialakulásának részletes ismeretére.

2.3.1 A szenzor által rögzített képet befolyásoló szerkezeti tényezők faállományokon

A távérzékelés során a szenzor az objektumok radianciáját rögzíti. A radiancia a szenzor egységnyi felületére érkező sugárzási teljesítmény, aminek SI mértékegysége $[W m^{-2} sr^{-1} nm^{-1}]$. A radiancia a vizsgált objektum reflektanciájából származik, ami az objektumra érkező $(E [W m^{-2}])$ és az onnan kilépő fény $(M [W m^{-2}])$ energiájának arányát jellemzi [80].

Az űrfelvételeken megjelenő felszínborítás formák a különböző frekvencia tartományokban spektrálisan elkülönülnek egymástól különböző anyagszerkezetük és felület típusuk miatt a vegetációs időszakban [81]. Az erdőborítás, mint felszínforma magas lombkorona záródás mellett ($> 80\%$) a falevél anyagával jellemezhető nagy felbontású optikai űrfelvételeken, ami egy fotoszintetikusan aktív felület. A fák ágait takaró kéreg ebben az időszakban és ilyen felbontás mellett elhanyagolható részt tesz ki a rögzített

spektrumban a közel függőleges tengellyel készül felvételeken a legtöbb hazai fafaj esetén. Az erdők jól elkülönülnek a fotoszintetikusán kevésbé aktív felszínborítástól, mint a vízfelszín vagy a beépített területek. Más fotoszintetikusán aktív formákkal már enyhe spektrális átfedéseket mutatnak, ahol a klorofil mennyisége, sejt szerkezet és a tárolt víz mennyisége a levélfelülethez hasonló mértékű [82].

A különböző fafajok spektrális jellemzői bizonyos mértékben elkülönülnek egymástól. Az elkülönülés okai az alábbi szintekre bonthatók:


- Levelek;
- Ágszerkezet;
- Fakorona;
- Faállomány;
- Erdőterület.

A legalacsonyabb szintnek a fa levelét tekintem, ami már vizsgálható nagyon nagy felbontású távérzékelte, roncsolásmentes felvételeken. Ezen a szinten lehetséges a levél lemezéről olyan spektrális mintavételt készíteni, amit csak minimális mértékben módosítanak a geometriai jelenségek. A magasabb szinteken megjelenő mért reflektancia értékek a levek pontos pozíciójának és méretének ismeretében modellezhető 3 dimenziós fizikai modelleken. Ezeket radiative transfer modellnek [83] nevezik, melyek segítenek megérteni, hogy hogyan alakul ki a szenzoron rögzített kép adott körülményeknél. Egyes fafajokhoz elérhető ilyen modell [84], azonban a jellemző hazai fafajokra még nem készültek el. A modellek segítségével a kialakító tényezőire bontható a szenzoron mért reflektancia. A megjelenő képet az összes tényező közül fák esetén, a Bidirectional Reflectance-Distribution Function (BRDF) jelenség befolyásolja a legjobban geometriai szempontból. Az BRDF az anizotróp felületeken [85] megfigyelhető jelenség, ami a beérkező fény energiájától, beesési szögétől és a megfigyelés betekintési szögétől függ [86], [87].

Egyes fafajok esetén, mint például az összetett levelű *Fraxinus* nemzetség fajtái, már levél szinten is igen komplex 3 dimenziós szerkezetet alkotnak a térben. A nagy felbontású optikai űrfelvételeken az idős fák koronáit már képes egy darab pixel mintavételezni a képen. Az ilyen, pixelen megjelenő reflektancia érték a felületen látható egyes levelek árnyalt és megvilágított részeinek nem lineáris kombinációjából jön létre. A fa csúcsa és a szenzor pályája közötti több száz kilométeres szakaszon többek között az atmoszféra található, ami további zajok forrása a rögzített jelekben [88].

2.3.1.1 Levelek


A levelekben végbemenő fotoszintézis során a beérkező napfény (sugárforrás) összetétele és mennyisége megváltozik, így a fafajok leveleinek eltérő sejt struktúrája is [89] befolyásolja a szenzoron rögzített reflektanciát [34]. A fotoszintézis hatása mellett a levél felületen lévő viasz vastagsága, szőrössége tovább befolyásolja a rögzített értékeket [64]. A lombos és tűlevelű fafajok között már ilyen szinten nagymértékű elkülönülés tapasztalható. Levél szintű spektrometriai információkat csak közvetlen méréssel lehet kinyerni terepi vagy labor spektrométerekkel [90]. A leveleket nem célszerű 2 dimenziós objektumnak tekinteni, mert a legtöbb esetben található rajtuk valamiféle görbület, és a levél lemezek sem feltétlenül párhuzamosak a talajjal. Ezek a tényezők labormérések során kiküszöbölhetők, de környezeti távérzékelésnél már komolyan befolyásolják a megjelenő képet. A BRDF hatás miatt a teljesen megegyező levelek, különböző szögekben elforgatva teljesen más képet mutatnak passzív távérzékeléssel készült felvételeken. A bemutatott példában (3. ábra) csupán 1 tengely körül forgatva sem lineáris a kapcsolat a forgatás szöge és a megjelenő árnyalt/megvilágított területek között a komplex 3 dimenziós felület miatt.



3. ábra: Egy falevél 0° , 45° és 90° -kal elforgatott képe azonos megvilágítási és felvételi betekintési szögek mellett

2.3.1.2 Ágak

A levelek az ágakhoz csatlakoznak, ahol szórطان, átellenesen vagy keresztben átellenesen helyezkednek el [91]. Az egyes fajokra jellemző, hogy a levelek, ágak milyen szögtartományokban csatlakoznak egymáshoz, mely segít a terepi határozásukban, továbbá egyedivé teszi őket távérzékelés szempontjából is. Ha ág szinten vizsgáljuk, mint sugárzás visszaverő objektumot, akkor a levélállás függvényében nem az ágon elhelyezkedő összes levél felületét látjuk egyszerre. A látható részen is különböző szögekben állnak a levelek, így az egyes levelek felületén az egy pontból megfigyelt refelktancia nem homogén. A bemutatott példában (4. ábra) látható, hogy különböző pozícióban lévő, azonos objektumok mennyire eltérő képeket adnak vissza függőleges tengelyű megfigyelésnél. Nagyon nagy felbontású légifotókon (<5 cm), melyeket jellemzően alacsonyan repülő UAV-k készítenek, már önálló objektumként jelennek meg az ágak. Alacsonyabb felbontású felvételeken egy vagy több pixelben keveredik az ágakról visszavert fény jele, ami a nagy felbontású űrfelvételekre is érvényes.




4. ábra: Egy gally 0° , 45° és 90° -kal elforgatott képe azonos megvilágítási és felvételi betekintési szögek mellett


2.3.1.3 Fakorona

Az ágak alkotják a faegyed koronaszerkezetét, ami oldalról tekintve lapostól a kihegyesedő formáig vesz fel különböző alakzatokat. Az ágak különböző hosszúságúak, átmérőjűek. Fentről tekintve zártfogazott-osztott profilok között változik az egyes fafajok koronavetületének alakja. Az űrfelvételeken jellemzően ilyen vetületben láthatók, ám az alacsonyabb térbeli felbontás miatt az alak közvetlenül nem kivehető, de vannak erre utaló jellegzetességek, melyek csak állomány szinten vizsgálva válnak láthatóvá. A fák koronája nagy felbontású űrfelvételeken már önálló pixeleken jelenhet meg, amelyen a spektrális keveredés [92] eredménye látható.

Az egyes fák koronáinak fentről látható felületét egyszerű geometriai alakzatokkal (gömb, kúp, ellipszoid) lehetséges közelíteni (5. ábra). A fakoronáknak ezt a geometriai tulajdonságát a gyakran alkalmazzák légi lézeres letapogatásos (Airborne Laser Scanning, ALS) felméréseknél egyes fák pozíciójának és koronaméreteinek meghatározására [93]. A nagy felbontású optikai űrfelvételeknél ez a tulajdonság egészen máshogy érvényesül. Míg az alacsonyabb szerkezeti szinteken is már megfigyelhető volt, hogy a leveleken, ágakon a BRDF érvényesül, ezek eltörpülnek a burkolófelületen megjelenő árnyalódás mértékéhez képest. Egy gömb alakzattal közelítve a korona felületét jól látható, hogy a megvilágítás és a megfigyelési szög függvényében milyen mértékben árnyalódik a korona (6. ábra). A fa koronáját nem lehet Lambert-féle felületnek tekinteni, ha nagy felbontású űrfelvételen vizsgáljuk a faállományokat [94].




5. ábra: Stilizált lombkorona szerkezet ráillesztett gömbfelülettel (A) és egy valós fa lézerszkennelt képe rá illesztett burkoló felület kontúrral (B)




6. ábra: Gömb nem Lambert-féle felülettel megvilágítva egy irányból (A) és egy fakorona képe vetületével kiemelve hamis színes légifotón (B) alacsony Nap állás mellett készítve

2.3.1.4 Faállomány

A faállomány koronaszintjét az egyes fák koronái és a közbefoglalt kisebb-nagyobb lécek alkotják. A koronaszint felülete ritkán lapos, a koronák burkoló felülete egy mintázatot alkot. Ezek a mintázatok mesterségesen ültetett erdőknél a térben szabályosan jelennek meg (7. ábra), míg kevésbé mesterséges állományokban a szabálytalanabb térszerkezet a jellemző. Az egyes koronákon megjelenő árnyalódás és az alacsony Nap állás következtében a szomszédos fákra vetített árnyékok jellegzetes textúrát adnak a faállományok képének az űrfelvételeken. A műholdas szenzor geometriai felbontása határozza meg, hogy mekkora területegységeket mintavételez a kép rögzítése során. A mintavételezési hálózat pozíciója a faállományon bizonyos határokon belül mozog földmegfigyelő műholdak esetén [95]. Egy faállományról két különböző időpontban igen nehéz tökéletesen összehasonlítható felvételt készíteni, még ha a változó környezeti változóktól (Nap állása, vegetáció aktivitás, időjárás) eltekintünk (8. ábra). Még azonos időpontban, kissé eltérő felvételi geometriával készült felvételeknél sem lehetséges a tökéletes pixel szintű regisztráció, ezért a képek kiértékelésénél ezt a jelenséget figyelembe kell venni. Közepes felbontású űrfelvételeken ez nem okoz problémát, mert a nagyobb felületről gyűjtött reflektancia átlagolódik a szenzoron, ezzel kisimítva a kiugró értékeket, így az idősoros összehasonlító elemzéseket kevésbé befolyásolja.




7. ábra: Stilizált faállomány, nem Lambert-féle felületű gömbbel közelített fakoronákkal



8. ábra: Egy faállomány modell reflektanciájának mintavételezése egymáshoz képest fél fázissal eltolt, azonos méretű rácshálóval

Minél idősebb egy faállomány, annál több térbeli mintázat figyelhető meg az alacsonyabb törzsszám mellett a nagyobb méretű egyes fákon. Fiatal, záródott állományokban a magasabb törzsszám miatt magasabb a NIR és SWIR reflektancia, ami faállomány szerkezet átalakulása után csökken a törzsszámmal együtt [96]. A különböző faállomány-típusokban ritka, hogy teljesen szabályos hálózatban helyezkednek el a fák. A fényt folytatott verseny következtében, amit mesterséges és természetes bolygatások támogatnak [97] a faállomány szerkezete átalakul és a faállomány típusra jellemző mintázatot vesz fel (9. ábra). Erre a mintázatra következtetni lehet az űrfelvételen látott képből, hasonlóan, mint a településszerkezeteknél [98]. Ez a térbeli mintázat, amit a koronák árnyalt részei és a vetített árnyékai képeznek további információt ad a faállományok kiértékeléséhez.




9. ábra: Két különböző szerkezetű faállomány modell

2.3.1.5 Erdőterület


Az erdőterületet faállományok borítják, amelyek lehetnek sík, domb és hegyvidéki területeken. Sík erdőterületek esetén az előző bekezdésben leírt spektrális és térbeli jellegzetességeket adják vissza a faállományok. A szenzoron megjelent képet a továbbiakban az atmoszféra állapota befolyásolhatja jelentősen, egyéb geometriai eredetű hatások nem torzítják azt a föld felszínén.

Domb és hegyvidéki területeken a faállományok általában nem sík területeken helyezkednek el. A szenzoron megjelent képen a faegyedek megjelenését a korábbi bekezdésekben leírt tényezőkön felül itt az befolyásolja jelentősen, hogy a fatövek nem egy szintben helyezkednek el. A faegyedek továbbra is „egyenesen” állnak, mert a fentről jövő fény irányába növekednek, de a koronák burkolófelületének más részei is láthatóvá válnak azzal, hogy függőleges irányban vannak elmozdítva egymás mellett (10. ábra).



10. ábra: Azonos tőszámú stilizált faállományok képe sík területen (A) és egy meredek területen (B) azonos betekintési és megvilágítási szögből.

Az, hogy a koronák felületének melyik része, milyen mértékben járul hozzá a szenzor által rögzített képhez az erdőterület domborzata és a megvilágítási viszonyok határozzák meg. Feltételezni lehet, hogy a domborzaton megjelenő természetes árnyalódás mértéke közel lineáris kapcsolatban van a faállományok felületén megjelenő árnyalódással (11. ábra). A domborzaton megjelenő árnyalódást, a felület és megvilágítás függvényében modellezni lehet. Ezeknek az árnyalásoknak és az árnyékok kialakulásának fizikai alapjai Minnaert munkájában olvasható részletesen [99]. Egy digitális domborzatmodell és a Nap pozíciójának ismeretében kiszámítható a megvilágítottsági állapot (Illumination Condition, IC) [100]. Ezen felül a vetített árnyékok mértéke is megnő hegyvidéki területeken, aminek a faállományon belüli pontos modellezése igen nehézkes, mert levél szintű koronamodellek szükségesek hozzá. Helyette a faállomány magasságot is tartalmazó felületmodellel készült vetített árnyékmodellt lehet kombinálni a megvilágítottsági állapot modelljével olyan módon, hogy a vetített árnyék helyén a megvilágítottsági értékek minimumával helyettesítjük. Ezzel a lépéssel közelíteni lehet a valós állapotot. A kombinált megvilágítottsági modell alapján korrigálni lehet a képen látható reflektancia értékeket [101] vagy kategorizálni lehet a faállományokat annak függvényében, hogy milyen mértékű árnyalás torzítja az adott időpontban a vizsgált erdőterületet.




11. ábra: Egy hegyvidéki erdőterület képe ősszel Sentinel-2 felvételen (A) és a terület domborzatmodelljére készített megvilágítási modell (B) az űrfelvétel időpontjához tartozó Nap állás paraméterekkel.

2.3.2 Idősorok

2.3.2.1 Interannuális (éven belüli) idősor

Az erdők, mint élő felszínborítás forma az év során különböző fejlődési fázisokban látható, melynek kialakulása a termoperiódushoz kapcsolódik [102]. A különböző fajok éven belüli fejlődési fázisait így elsősorban a genetikai adottságai határozzák meg, melyet az aktuális év időjárása tud befolyásolni. A vegetációs időszakban szabad szemmel jól látható fenológiai jelenségek következnek be, amely a rügypattanás kezdetétől a lombhullás végéig tart a lombos fajoknál [103]. A téli időszakban nyugalmi fázisokban vannak a lombos fajok, mely során szabad szemmel látható fejlődést nem produkálnak. A fakorona különböző részein, eltérő időpontban történhetnek az egyes fenológiai fázisok. Tülevelű, örökzöld fajokon a fenológiai ciklus kevésbé látványos. Az új tülevelek megjelenésének időpontja alapján lehet a vegetációs időszakának a kezdetét meghatározni [104]. Az erdők fenológiája távérzékeléssel jól megfigyelhető [105], az egyes szakaszok elkülönítését pontosabban el lehet végezni multispektrális felvételek idősorai alapján (12. ábra), mint terepi megfigyeléssel. A fenológiai fázisok megfigyelésében elsősorban közepes felbontású űrfelvételeket alkalmaznak, magasabb időbeli felbontásuk miatt [106], [107]. Nagy felbontású, konzisztens idősorok ritkán érhetők el a mérsékelt övben, többnyire modellezéssel kiegészítve hozhatók létre [108].

Az előző bekezdésben felsorolt szerkezeti különbségek statikusan is megfigyelhetők az űrfelvételeken, ám sok esetben hasonlóságot mutatnak a különböző fafajok tulajdonságai. Az időbeli változás, amely során a fafajok különböző fenológiai fázisban jelennek meg az optikai távérzékelte felvételeken, további különbségeket képez a fafajok között. A spektrális jellemzők változása levelek szintjén megy végbe. Ezen felül nagy felbontású űrfelvételeken megjelenő térbeli jellegzetességek is változnak a korona lomb mennyisége és a nap állásának szögei alapján. Több egymás után készült felvétel, azaz idősor alkalmazásával kihasználható a távérzékelési folyamatban a fenológiai változás. Ilyen alkalmazása lehetne a faállomány-típus vagy fafaj térképek készítése [109], de az aktuális év növedékének meghatározásában is segíthet [110]. A szakirodalomban a több időpontú (multi temporális) vizsgálatok egyre jobban elterjedtek erdők vizsgálatánál [111], melyekkel pontosabb térképeket lehet készíteni.



12. ábra: Egy hazai lombos faállomány éven belüli NDVI vegetációs index idősora és a hozzá tartozó fenológiai állapota (Adatok forrása: MOD13Q1 v6 termék a <https://earthengine.google.com/-on> keresztül)

A sűrű idősorok bizonyítottan jól alkalmazhatók osztályozási problémák megoldására a faállományok vizsgálatánál, melyekben akár több ezer megfigyelést (hipertemporális) alkalmaznak több év űrfelvételei alapján [112]. Az ilyen idősorokban hatalmas redundancia van, így azonos információk ismétlődnek benne. Földmegfigyelési adatoknál, különösen Magyarország régiójában a nyár közepén érhető el a legtöbb felhőmentes felvétel, így egy éves idősor összeállításánál nagyobb súllyal szerepelnek közeli időpontból származó felvételek, melyek hasonló körülményeket rögzítettek ahelyett, hogy folyamatos sűrűséggel mintavételeznék az időt. A modern gépi tanulási módszerekkel [113] kiértékelt adatokban az adat belső kereszt- és autó korrelációjának [114] a negatív hatása kiküszöbölhető közvetlen adatredukciós lépések nélkül. Nagyon sűrű idősorok alkalmazása esetén, habár negatív hatással nincs a létrehozott térkép pontosságára, de egy bizonyos számú megfigyelés után az elért pontosság kulminál képosztályozásnál [115]. A ma működő Földmegfigyelő műhold programok, mint a Sentinel-2 már képes olyan sűrűségű idősorokat rögzíteni, ami az optimálisnál több megfigyelést tartalmaz egyes célfeladatok végrehajtásához [116].

2.4 Az esettanulmányokhoz kapcsolódó irodalmak áttekintése

2.4.1 Kiértékelhető Sentinel-2 űrfelvételek vizsgálata a magyarországi erdőállományokra

Az ingyenesen elérhető, földmegfigyelő műholdprogramok ma már havonta több felvételt szolgáltatnak nagy felbontásban [73], [117]. Ez lehetővé teszi azt, hogy természeti erőforrásainkat folyamatosan nyilvántartsuk űrfelvételek segítségével. Az űrfelvétel-sorozatokból a faállományok típusa [109], záródása [118], [119] és egészségi állapotának [49], [120] változása nyomon követhető, magas szinten automatizált távérzékelési módszerekkel [121]. Az optikai földmegfigyelő műholdak felvételeit erdőterületekre csak felhő- és felhőárnyék mentes képeken lehetséges kiértékelni. Régióink felett magas (~70%) az átlagos felhőborítottság [122], ezért kevés teljesen felhőmentes kép érhető el. Habár a felhasználók számára elérhető űrfelvételek rendelkeznek egy globális felhőborítás értékkel [123], ami alapján ki lehetne szűrni a kiértékelhető időpontokat, ezek a számok nem adnak részletes térbeli kiterjedést. A felhő- és felhőárnyékok detektálása a távérzékeléssel egyidős probléma [124]. Az erdőborítás fölött megjelenő pára keletkezése és fizikai tulajdonságai nagyban különböznek a felhőkétől, azonban az űrfelvételeken hasonló karaktert mutatnak, így ezekkel együtt vizsgálható. A felhők detektálásának pontossága nagymértékben függ a szenzor tulajdonságaitól [125], de a felszínborítás típusa is szerepet játszik a megbízhatóságában [126]. A szenzorok radiometriai felbontásának növekedésével és a felhőborításra érzékenyebb sávok alkalmazásával ma már pontosabb felhőmaszkok készíthetők [127], így nagyobb biztonsággal lehet meghatározni a kiértékelhető pixeleket a képeken [128]. Ugyanakkor, a felvételek geometriai felbontásának növekedése tovább nehezíti a felhők pontos detektálását [129]. A felhőmaszkoló módszerek fejlesztése a mai napig aktívan kutatott terület. Egy új optikai szenzor elméleti visszatérési ideje alapján már jóval a felbocsájtása előtt meg lehet tervezni az alkalmazási területeit [130]. Ilyen lehet az, hogy alkalmas-e közel valós idejű monitoring feladatokra, vagy csak éves leltárak elkészítésére. Globális földmegfigyelő programoknál a műholdak pályáiból kifolyólag nem egyenletes a felvételek eloszlása [131]. A Sentinel-2 műhold felvételeinek sűrűségét több alkalmazásban is követni lehet [131], [132], de ezek a felhőborítottságról nem adnak részletes információt, így lokális felhasználású távérzékelési termékek tervezéséhez csak korlátozottan alkalmasak. Korábban a Landsat műholdak archívumát vizsgálták a felhőborítás szempontjából, kifejezetten operatív távérzékelési szolgáltatások fejlesztéséhez [133]. Az ilyen típusú vizsgálatokat geostatistikai elemzésekkel lehet végrehajtani a felhőmaszkokon teljesen automatizált módon. Az elemzést nem a számításuk komplexitása bonyolítja, hanem az adatok nagy mennyisége, melyek ma már szuper számítógépes (High Performance Computing, HPC) környezetben is elvégezhetők.

A magasabb tengerszint feletti magasságokban átlagosan magasabb a felhőborítás, mint az alacsonyabb régiókban. A pára megjelenése szűk völgyekben gyakori jelenség, valamint folyamatos topográfiai árnyalásban lévő területek is találhatók. Az ilyen területek élőhelyeket is jeleznek bizonyos faállomány-típusok számára, így ezeknek valószínűleg kisebb pontossággal lehet meghatározni a paramétereit távérzékeléssel.

A különböző távérzékelési, erdészeti felhasználásra készült termékeknek egyedi adatigényük van. Egészségi állapot trend megállapításhoz évente egy teljesen felhőmentes felvétel elegendő [120], ami a fenológiai maximum tartományból származik. Közel valós idejű monitoring feladatokhoz éven belüli, nagyon sűrű idősor szükséges [134], mint a valószínűség alapú szubpixeles koronaborítás vizsgálatoknál. Faállomány-típusok pontosabb meghatározásához több időpont ($2 <$) felhasználására van szükség, amelyeknek meghatározott fenológiai fázisban kell készülniük [116]. Ezeknek a követelményeknek az ismeretében lokálisan (erdőrészlet szinten) meg lehet határozni, hogy milyen időbeli felbontásban és megbízhatósággal lesznek elérhetők az ilyen termékek.

2.4.2 Lékek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben

Az egykorú erdő vegyes korú állománnyá átalakítása [135] során mesterséges léknyitással [136] indukálnak megfelelő életkörülményeket az újulat számára. Ezt a kezelési módot jellemzően őshonos lombhullató fafajok domb- és hegyvidéki állományaiban alkalmazzák Magyarországon, ahol az állomány már reprodukciós korban van. Ilyen egykorú állományokban a fák magassága és átmérője szűk határok között mozog. A mesterséges lékek létrehozásánál általában kb. egy, a famagasságnak megfelelő átmérőjű területen kitermelik a faegyedeket. Az irodalomban ezt a módszert gyakran csoportos száalásnak nevezik [137]. A faegyedek eltávolítása léket képez a lombkorona rétegben. Ennek a műveletnek az a célja, hogy az erdőt csak a nyitott lék területén belül újítsa fel, lehetőleg a szomszédos fák szaporítóanyagával természetes úton [138]. Ha nem áll rendelkezésre szaporítóanyag helyben, akkor mesterséges alávetéssel vagy csemete ültetéssel pótolható a hiányzó újulat. A mesterséges lékek elve a természetes erdődinamikán alapul, a léket természetes bolygatások hozzák létre [139], mint egy jégtörés vagy az idős, álló holtfák összeomlása. A különböző faállomány-típusok különböző lék kezelést igényelnek erdőművelési tulajdonságaiknak megfelelően. Általában a csemetéknek sok napfényre van szükségük a növekedéshez [140]. A lombkorona alatt csak diffúz megvilágítás áll rendelkezésre [141]. A lombkorona rétegben lévő lék lehetővé teszi a közvetlen napfényt a csemeték számára, ami gyorsabb növekedést okoz [142], [143].

Ezzel az erdőkezelési módszerrel lehetőség nyílik a vegyes korú faállományok létrehozására az erdőrészleten belül, amivel biztosítani lehet a folyamatos erdőborítást [144] nagyobb területű tarvágások nélkül. Ily módon a lékek jelentős szerepet játszanak az ökoszisztémában a biológiai sokféleség kialakításában, a tápanyagkörforgás befolyásolásával, valamint a faállomány többkorúságának megőrzésében [145]. A mesterséges lékeket az erdőgazdálkodás során több fázisba ütemezve nyitják meg [146]. Mivel a lombhullató természetes erdők növekedése a hegyvidéki területeken viszonylag lassú, a lékek nyitásának ütemezését az ökológiai és gazdasági tényezők befolyásolják. Ahhoz, hogy az ütemezés optimális legyen, pontosan ismerni kell a faállomány dendrometriai paramétereit [147] és a faállomány horizontális kiterjedését. A fenntartható erdőgazdálkodáshoz [148] szükség van arra, hogy a gazdálkodó tudatában legyen a kezelt természeti erőforrásokkal, mint a faállománnyal és lékekkel borított területek kiterjedésével. A mintavételes erdőbecslési módszerek, mint például a körlap mérés vagy a fatermési táblák használata esetén a faállomány pontos területe szükséges az erdő fatömegének becsléséhez [149], amelyek a leggyakrabban használt módszerek az erdőleírásnál.

Magyarországon az erdőgazdálkodók a 19. század óta részletes térképeket készítettek az erdőkről erdőrészlet szinten [150]. Ezek a térképek azonban erdőrészlet alatti szinten nem ábrázolják az erdő pontos borítását, különösen a lékek kiterjedését. Kevés olyan terület van, ahol ezeknek a pontos mérete részletesen ismert [60], [151]. A lékek felméréséről összefoglaló mű [145] is készült, amelyben összegyűjtötték a leggyakrabban alkalmazott módszereket lékek felméréséhez. Az összefoglaló mű szerint két fontos paraméter határozza meg a lékeket: a koruk és a kiterjedésük. Mivel a lékek egy élő ökoszisztémában vannak, ezért a méretük folyamatosan változik az idő során. Az egyes fák koronavetület mérete igen dinamikus tud lenni. A lék körül folyamatosan változik a korona borítás, így monitorozása szükséges, hogy elegendő fény mennyiség jut-e a lékbe. A pontos méretét a kerülete mentén álló faegyedek koronavetülete alapján lehet meghatározni geodéziai módszerekkel. A gyakorlatban egyszerűbb mérési módszereket alkalmaznak, ahol a lék alakját egy egyszerű geometriai formával közelítik. Ebben az esetben elegendő a lék átmérőit meghatározni.

Geodéziai módszerekkel csak kutatási céllal mérnek fel lékeket, a távérzékelt légi felvételek alkalmazása elterjedtebb. Ortofotókat [152] és borított felszínmodelleket [153], [154] gyakran alkalmaznak ilyen célokra. Ezeken az adatforrásokon nagy pontossággal lehet térképezni a lékeket, de az adatgyűjtés és kiértékelés magas költsége megnehezíti a folyamatos használatát monitoring tevékenységhez. Űrfelvételek alapján is térképezhetők a lékek. Garbarino és mtsai. [118] nagyon nagy felbontású Kompsat-2 felvételen térképezett Bosznia-Hercegovinai mintaterületen automatikus osztályozási módszer és vizuális interpretáció segítségével. Egy másik tanulmányban [119] a

WorldView-2 műhold sztereó képpárján értékelték ki a lécek borítását egy ukrán bükkös erdőben. Negron-Juarez és mtsai. [155] Landsat felvételeken vizsgálták közép-Amazóniában a lék térképezés lehetőségeit spektrális szétkeverés módszerével.

2.4.3 Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben


A faállomány-típus egy faállomány jellemző az erdőleírásban. Ez egy mesterségesen létrehozott osztályozási rendszer, amit a faállomány elegyaránya alapján állítottak fel. A faállomány-típusokat egy főfajjal lehet jellemezni, ami az adott faállományban a legmagasabb elegyaránnal rendelkezik és a koronája a felső lomboronasztban helyezkedik el. Magyarországon 8 fő faállomány-típus csoportot ír le az erdőtörvény [5], melyek további altípusokra oszlanak előre meghatározott elegyarány számok alapján.

Mesterséges faültetvényekben - ahol ugyanaz a fajfaj található az egész erdőrészletben és rendszeres erdőművelési tevékenységeket végeznek, hogy monokultúráként tartsák - a faállomány-típus kevésbé fontos paraméter. Ellenben a faállomány aktuális kiterjedése, amit a koronavetületével lehet jellemezni nagyon fontos paramétere a faállománynak. Természetes és természetyszerű faállományokban mind a faállomány kiterjedésének, mind a faállomány-típus meghatározásának nagyobb jelentősége van. Az ilyen erdőkben jellemzően természetes úton történik a fejűjtés, így az erdőgazdálkodónak kevesebb ráhatása van a későbbi faállomány összetételére. Tisztításokkal, gyérítésekkel lehet szabályozni a fajfaj összetételét, azonban ezeknek a tervezéséhez szükség van az aktuális faállomány-típus információkra, hogy megfelelően lehessen szabályozni az állományt. Nagy felbontású optikai távérzékeléssel csak magasan záródott faállományok paraméterei határozhatók meg, így elsősorban a sűrűség és vékony rudas [156] állapotától kezdve lehetséges a faállomány-típus meghatározása ilyen adatok alapján. Ebben az életfázisában az erdő terepi mintavételezéshez többnyire nehezen megközelíthető. Gyorsan növekvő fajfajok esetén 6-8 éves kortól, míg lassú növekedésű fajfajok esetén 20-30 éves kortól lehetséges a hazai faállományok távérzékeléses vizsgálata nagy felbontású űrfelvételeken.

A faállomány-típus különböző típusú távérzékelte adatokon meghatározható [109]. Mérsékelt övi erdők vizsgálatára a nagy felbontású optikai multispektrális [116] és hiperspektrális [157] szenzorok képei alkalmasak költséghatékony módon. Ezek a szenzorok csupán a legfelső koronaszint felületének a reflektanciáját rögzítik, amelyből összefüggéseket lehet felállítani a faállomány típusára. A faállomány-típusok térképezése spektrális, spektrális-időbeli és textúra jellemzők alapján végezhető el hatékonyan. A távérzékelés első alkalmazásai a spektrális elkülönülést alkalmazták faállomány-típusok térképezésére [158]. Több tanulmány alkalmazta már a spektrális-időbeli jellemzőket faállomány-típus térképezésre, és egyértelműen a több időpontú vizsgálat módszerét mutatták hatékonyabbnak [112]. A térbeli képjellemzők közül a textúra jellemzők alkalmazására is voltak már példák űrfelvételek esetén, melyek a használata mellett szólnak [159]. A nagy felbontású űrfelvételeken alkalmazott faállomány-típus térképezési technológiák fejlődésének történetét Turlej foglalta össze munkájában [116]. Az összefoglalás alapján az alkalmazott módszerek 70-95% összesített pontosságokat értek el. Összehasonlítható tanulmányok Wisconsin államban születtek 1988 és 2018 között, melyek alapján követni lehet a távérzékelési technológia és a távérzékelte adatok minőségének fejlődését. A pontossági mutatók telítődést ábrázolnak, így az utóbbi időben a pontosságok javulása kisebb mértékű. Ez arra utalhat, hogy a szenzoron rögzített információ korlátozza ma már a további fejlődést, nem az alkalmazott kiértékelési módszerek.

A különböző faállomány-típusok ismétlődő mintázatokat alkotnak az űrfelvétel idősorokban térbeli-időbeli és spektrális síkokon (13. ábra), melyeknek a felismerése gépi tanulási módszerekkel automatizálható. A gépi tanuláson alapuló osztályozáshoz képjellemzőket kell a modellbe táplálni. Ezek lehetnek a gyakran alkalmazott spektrális jellemzők [160], térbeli jellegzetességet kiemelő jellemzők [161], [162] és az ezeknek az időbeli változását mutató jellemzők [112]. A megfelelő jellemzők kiválasztására hagyományos esetben csak útmutatások léteznek, a legtöbbször terület- és esetfüggő az alkalmazásuk hagyományos gépi tanulási módszereknél. A nagyon mély neurális hálózatok képesek a

betáplált jellemzők közül a megfelelő elemek kiválasztására [163], [164], ezért széles körben alkalmazzák általános képfeldolgozási célokra [165].



13. ábra: Az űrfelvétel-idősor spektrális (A), spektrális-időbeli (B) jellemzői és a kivont textúra (C) a Magas kőris (*Fraxinus excelsior* L.) és Bükk (*Fagus sylvatica* L.) példájával (Adatok forrása: Sentinel-2 L2A termék a <https://scihub.copernicus.eu/>-n keresztül elérve 2019.01.30.)

3 Anyagok


3.1 Mintaterületek

3.1.1 Börzsöny

A Börzsöny hegység az Északi-középhegységben található (14. ábra). Kiterjedése megközelítőleg 600 km², ahol a tengerszint feletti magasság (TSZFM) 150 és 938 m között mozog. A magasabb (500–938 m TSZFM) részein meredek, sziklás lejtők és mély völgyek található az északi oldalakon, amik kevésbé meredek lejtőkben folytatódnak a déli oldalakon (300–500 m TSZFM) [166]. Az alapkőzet jellemzően andezit a miocén kori vulkanikus tevékenységek következtében [166]. Több megjelenése található a lösznek és Lajta mészkőnek a hegység peremterületein [167].

Az átlagos évi középhőmérséklet 8 °C. Januárban 3.5 °C és 18 °C júliusban. Az éves csapadék 550-900 mm közé esik. Az éves átlagos felhőborítás 60-70% között mozog [122]. Megközelítőleg 445 km² erdőborítás található, amivel az ország egyik legnagyobb egybefüggő erdőtömbjét alkotja, aminek biodiverzitása igen magas [168]. Többek között élőhelyet nyújtott olyan ritka fajoknak, mint a kerecsen sólyom (*Falco cherrug*) [169] és a hiúz (*Lynx lynx*) [170].

A hegység lábánál elterülő települések körül a gyümölcsök termesztése volt a jellemző. A 21. századra ezek a területek szántóföldként lettek tovább hasznosítva vagy művelés nélkül maradtak. A lakosság gyorsan növvő többcélú faállományokat telepített ezekre a területekre a 19. század óta. Jellemzően akácosokat (*Robinia pseudoacacia* L.), melyeket gyorsan el tudtak érni.



14. ábra: A Börzsöny elhelyezkedése Magyarországon az alkalmazott mintaterületek megjelölésével és a területet fedő Sentinel-2 képcsempék lábnymaival

A klímazonális erdőtársulások máig megfigyelhetők a hegységben a különböző magasságokban az elmúlt évszázadok kizsákmányoló erdőhasználatának ellenére. Az alacsonyabb hegyeken és dombokon száraz tölgyesek (*Quercus cerris* L., *Quercus pubescens* Willd.) vannak jelen. A nedvesebb területeken a gyertyános-tölgyes állományok a meghatározó erdőtársulások (*Quercus petraea* (Matt.) Liebl., *Carpinus betulus* L.). Egyes helyeken a gyertyán konszociációk is jelen vannak. A legmagasabb régióban a bükkösök (*Fagus sylvatica* L.) találhatók [171]. A tűlevelű fafajok aránya a hegységen belül 1.5% alatt van. Ezek az állományok mesterségesen telepített kéttűs fenyők (*Pinus* spp.) és lucfenyves (*Picea abies* L.) állományok, melyek részaránya folyamatosan csökken. A különböző klímazonális társulásokban több egyéb fafaj is jelen van, mint elegyfaj vagy ritkábban konszociációt alkotva. A hegység edényes flórájának részletes leírása Nagy munkájában olvasható [167].


Az erdők koreloszlása a Börzsönyben egyenetlen, aminek következtében az erdők hozama sem kiegyensúlyozott [172]. Ez az állapot több okra vezethető vissza. A 20. században történt nagy területű erdőtelepítések a korábbi legelőterületeken ideiglenes eltolódást okoznak a korosztályok eloszlásában [173]. Ennél komolyabb problémát jelent a korábbi évszázadok nem tartamos gazdálkodása [151], amely hatalmas területű egykorú erdőtömböket hagyott maga után, gyakran sarjerdőket. Ezek a hatalmas méretű erdőtömbök ma már idős állományok vagy már felújítás alatt álló területek. Az ilyen területek az elmúlt évtizedekben többször is ki voltak téve abiotikus károsodásnak [40], [172]. A hegység egy részén a folyamatos erdőborítás elvei alapján történik az erdőgazdálkodás. A nagy kiterjedésű vágások helyett kisebb kiterjedésű lécek segítségével történik a véghasználat, így térben és időben elnyújtható az erdő felújulása [174]. Ezzel a hozam hosszú idő alatt kiegyenlíthető lesz a jövőben, és vegyes korú állományok jönnek létre, azonban nagyon precíz erdőtervezést igényel a kivitelezése. A vegyes korú állományok ezen felül jobb élőhelyet biztosítanak az állat- és növényvilágnak. Az erdőgazdálkodást az Ipoly Erdő Zrt. (Balassagyarmat, Magyarország) és a Duna-Ipoly Nemzeti Park (Budapest, Magyarország) végzi a hegységben. A települések közelében a magánerdőgazdálkodás a jellemző.

A léktérképezés esettanulmányához három különböző típusú állomány lett kijelölve a hegység klímazonális és extrazonális társulásaiból. Az egyik területet bükkös erdő borítja, míg a másik kétfőn a kocsánytalan tölgy a jellemző. A faállomány-típusok térképezése a teljes hegységre készült el.

3.1.1.1 Tölgyes mintaterület 1 (T1)

A vizsgált mintaterület (15. ábra) Kismaros község közelébe (É 47.84533°; K 18.9771°) esik. A teljes területe 28.4 ha. A domborzata változatos: különböző kitettségű oldalak, egy kis hegygerinc és völgy

alkotja. Az átlagos TSZFM 160 m. A kocsánytalan tölgy és a gyertyán fafajok jellemzők a területre, valamint bükkös részek is találhatók kisebb arányban. A folyamatosan jelen lévő árnyalás miatt a völgy mélyebb részét kizártuk a vizsgálatból. Ezen a részen olyan alacsony a megvilágítottság egész évben, hogy nem különíthető el egy űrfelvételen a természetes eredetű lék és a domborzati árnyalás. Az állományok átlagos kora 80 év, átlagmagasságuk 25 m. Az első mesterséges lékeket 2007-ben vágták a területen, majd 2015-2016 telén további lékeket nyitottak. A lékek aljában sűrű vegetáció található. A fiatal facsemetéken kívül a fekete szeder (*Rubus fruticosus L.*), nadragulya, sások (*Atropa belladonna L.*), harasztok és egyéb fűfélék vannak jelen. A kerek alakú lékek átlagos átmérője 20-25 m között van. A legtöbb lék közepén egy magfa áll. Az egyedül álló magfa feladata, hogy makkal bevesse a léket. Az irodalomban lékként azon részét definiálja az állománynak, ahol a fák átlagos magassága nem éri el a 2 métert, így szigorúan véve a magfa nem képezi a lék részét. Ilyen esetekben a lék nem kerek, hanem gyűrű formájú lenne. Mivel a vizsgálatok nagy felbontású űrfelvételek segítségével történtek, az egyes magfák detektálása korlátozva volt a térszíni felbontás miatt. Minden egyes léket egy kompakt objektumként értelmeztünk, hogy a detektálásuk módszertanát egyszerűsíteni lehessen. A korona záródása a lékeken kívül magas, ami jellemző a hasonló faállományokra. A magas záródás ellenére apró záródás hiányok találhatók a lékeken felül, melyeknek eredete természetes. Egyes fák koronája kisebb, amit a faegyed egészségi állapota, koronaszintben elfoglalt pozíciója vagy az elérhető tápanyagok befolyásolnak. A mesterséges lékeken kívül természetes eredetű nagyobb lékek is jelen vannak a meredekebb oldalakon, ahol a gyökér alatti erózió következtében a fák maguktól dőltek ki. Ezekben a lékekben fekvő holtfa-ként hasznosulnak a kidőlt faegyedek, ami növeli a biodiverzitás értékét. A mintaterület változatos domborzati formáinak és megvilágítottsági állapotának köszönhetően ez a kisebb méretű terület is alkalmas módszerfejlesztésre nagy felbontású űrfelvételeken a lékek kimutatásához.




15. ábra: A Tölgyes mintaterület 1 képe egy 2015-ben készült 20 cm felbontású ortofotón

3.1.1.2 Tölgyes mintaterület 2 (T2)

A másik tölgyes mintaterület (16. ábra) Kóspallag település közelében található a hegység közepén (É 47.88656°; K 18.94261°). Gyertyános tölgyes erdőállomány található itt is hasonlóan a T1 mintaterülethez. Az átlagos TSZFM 370 m és területe 8.88 ha. A terület domborzata homogén, enyhén nyugati kitettségű. Ennek következtében sokkal kevésbé van a koronafelület kitéve a domborzati árnyalódásnak a T1 mintaterülethez képest. A faállomány átlagos magassága 25 m. A 2000-es évek elején kezdték meg a mesterséges lékek kialakítását a területen. 2015 és 2016 között nem történt változás a lékek kiterjedésében. A lékek alakja és mérete hasonló a T1 mintaterületen találhatóéhoz. Mivel a lékek kora meghaladja a 10 évet, a környező fák koronája elkezdte benőni a lékeket. Ennek következtében az eredeti lékek mérete csökkent, így egyes helyeken még nagyon nagy felbontású távérzékelte felvételeken is bizonytalan a beazonosításuk. A korona záródását a lékeken kívül 100%-nak


tekintjük. Erre a mintaterületre több nagyon nagy felbontású távérzékelte anyag is elérhető, így az érvényesítéshez jobban modellezhető a környezet.



16. ábra: A Tölgyes mintaterület 2 képe egy 2015-ben készült 20 cm felbontású ortofotón

3.1.1.3 Bükkös mintaterület (B)

A 38.2 ha kiterjedésű bükkös mintaterület (17. ábra) a hegység magasabb régiójában fekszik (É 47.93216°; K 18.94378°). Az átlagos TSZFM 750 m. A faállományban a bükk fafaj dominál. További fafajok találhatók elegyként, mint a kocsánytalan tölgy, magas kőris (*Fraxinus excelsior* L.) vagy a hegyi juhar (*Acer pseudoplatanus* L.). A terület kitettsége délnyugati, a terep lejtése igen meredek, 20°. A homogén domborzatot a mintaterületen a heterogén vertikális erdőszerkezet kompenzálja a komplexitásában. A területet több természetes bolygatás érintette az 1990-es évektől kezdve. A bolygatások során keletkezett természetes lékek mellé nyitott mesterséges lékek az egykorú állományt több korúvá alakították az utóbbi évtizedekben. Több tanulmány foglalkozott a bolygatások modellezésével a hegységben, melyeknek ez a mintaterület is része volt. A területet 1996, 2001, 2004 és 2014-ben jégtörések érintették és 1999, 2000-ben széldöntések. Az utóbbi jégtörés során elsősorban részleges koronatoréseket szenvedtek annak következtében, hogy a korábbi bolygatások már megtizedelték az instabilabb idős faegyedeket. A bükk erős megújuló tulajdonságainak köszönhetően a lékekben több újulat található, mint a tölgyes mintaterületeken. A csemetéken és a fiatal korú fákon kívül egyéb lágyszárúak is jelen vannak. A faállomány átlagos magassága 26 m. A lékekben található újulat magassága koruk függvényében változik, de a főállománytól minden esetben jelentősen elkülönülnek. A lékek alakja a bükkösben különbözik a tölgyesekben tapasztaltakból. Az átmérőjük sokkal nagyobb (30-40 m) és az alakjuk kevésbé kompakt. A szomszédos lékek gyakran egymásba nyílnak, így nagyobb és szabálytalanabb alakú újulati foltokat hoznak létre.




17. ábra: A Bükkös mintaterület képe egy 2015-ben készült 20 cm felbontású ortofoton

3.2 Űrfelvételek

3.2.1 Sentinel-2

A Copernicus földmegfigyelő program [175] keretében pályára állított Sentinel-2 (S-2) műholdpár ingyenesen szolgáltat nagy térbeli és időbeli felbontásban képanyagot a Földről 2015 óta. A műholdakat az Európai Űrügynökség (ESA) üzemelteti. A Sentinel-2A (S-2A) műholdat 2015-ben, a Sentinel-2B (S-2B) műholdat pedig 2017-ben állították pályára. A két műhold teljesen azonos, fedélzetükön az MSI (MultiSpectral Instrument) szenzor található meg, ami a spektrum 13 tartományában rögzít képeket (18. ábra). Négy sávja 10 méteres (kék (B2), zöld(B3), vörös(B4), közeli infravörös(B8)), hat sávja 20 méteres (vörös él (B5, B6, B7), keskeny közeli infravörös (B8A), rövid hullámú infravörös (B11, B12)) és három sávja 60 méteres (aeroszol (B1), vízpára(B9), cirrus (B10)) felbontással működik [73]. A szenzor radiometriai felbontása 12 bit. A műholdpár visszatérési ideje azonos betekintési szögű felvételek készítéséhez 5 nap. Az egyes pászták átfedéseinek és a 290 km széles lábnyomnak köszönhetően gyakoribb megfigyelések is elérhetők. A magas visszatérési időnek köszönhetően sűrű idősorok alkotására is alkalmas egy vegetációs időszakon belül, havi egy közel felhőmentes megfigyelés elérhető vele kis területekre.



18. ábra: A Sentinel-2 fedélzetén található MSI szenzor spektrális felbontása (Adatok forrása: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/overview> 2020.10.9)

Az S-2 műholdak felvételei a ma már népes távérzékeléssel foglalkozó közösség számára készültek, így a kezdetektől fogva Creative Commons CC BY-SA 3.0 IGO Open Access licensz [176] alapján ingyenesen elérhetők a felvételei. Az Open Access licensz megkönnyíti a kutatás és alkalmazás közötti technológia transfert, így folyamatosan üzemelő szolgáltatások alapját tudja képezni. Eddigi erdészeti alkalmazásai kiterjednek az erdő- és felszínborítás [177], erdőkár [178], faállomány-típus és fajfaj térképezésre [116], faállomány szerkezet komplexitás meghatározására [179]. A statikus térképezés mellett erdészeti monitorig alkalmazásai is vannak [51], [180], melyek a magasabb térbeli és időbeli felbontásának köszönhetően hatékonyabban tudják kimutatni a változásokat, mint a korábbi Landsat alapú rendszerek.


Az S-2 űrfelvételek a többi Sentinel műhold adataival egyetemben több csatornán keresztül érhetők el. A Copernicus Open Access Hub-on (<https://scihub.copernicus.eu/>, 2019.12.30.) érhetők el a felvételek a felhasználók számára közvetlenül az adatszolgáltatótól. Felhő alapú adatfeldolgozó szolgáltatásokban is elérhető közvetlenül az adat, mint a DIAS (Data and Information Access Services) [181] vagy a kifejezetten erdészeti térképezésre fejlesztett Forestry Thematic Exploitation Platform (Forestry TEP) [182], melyek az ESA támogatásával jöttek létre. Az S-2 felvételek L1C szintű georeferált, atmoszféra tetején mért reflektancia termékként érhetők el 100x100 km méretű csempékre darabolva UTM vetületben. Az adatszolgáltató több megoldást nyújt az L2A típusú felvételek előállításához [183].

A műholdprogramot hosszú távra tervezték, ezért további elemekkel fog bővülni a jövőben (Sentinel-2C, Sentinel-2D), melyek a jelenleg pályán lévő műholdakat fogják váltani üzemidejük lejártával [184].

3.2.1.1 Felhasznált Sentinel-2 űrfelvételek

3.2.1.1.1 Kiértékelhető Sentinel-2 űrfelvételek vizsgálata a magyarországi erdőállományokra

Az esettanulmányban a Sentinel-2A 2015 júniusa és 2017 szeptembere között készült Magyarországot lefedő 22 csempére eső (19. ábra) felvételeit értékeltem ki. Ezek 4 különböző műhold pályáról (R122, R036, R079, R136) kerültek rögzítésre különböző szenzor-betekintési szögekből. A feldolgozás a bécsi Earth Observation Data Centre for Water Resources Monitoring GmbH (EODC GmbH, Ausztria) infrastruktúráján történt [185]. Az EODC GmbH űrfelvétel adatközpontot üzemeltet, amelyben megtalálható a Copernicus-program keretében felbocsájtott összes Sentinel műhold felvétele, napi frissítéssel. Az elérhető felvételek metaadatai az online eomEX adatbázisból kérdezhetők le (<https://eomex.eodc.eu/>, 2019.12.30.). Az ország legkeletibb részére eső 34UFU és 34TFT csempék nem voltak elérhetők minden időpontban az adatközpontban, így ezeknek a kiértékelése nem történt meg.



19. ábra: A Magyarországot fedő Sentinel-2 műholdpászták képcsempéi azonosító jelükkel jelölve (Adatok forrása: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/acquisition-plans> (2020. 09. 15.))

3.2.1.1.2 Lékek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben

A lékek detektálása egy 11 felvételtől álló idősorban történt meg, melyekből két felvétel 2015-ből és 9 felvétel 2016-ból származott. A felvételek a mintaterületek fölött nem minden esetben teljesen felhőmentesek, így a kiértékelt felvételek száma változó. Az R036 és R039 műholdpászták 33UCU csempéi kerültek felhasználásra a kutatás során. A különböző pásztákban rögzített felvételeknél közel 180 fok különbség van a szenzor betekintési irány szögén. A betekintés azimuth szöge közel megegyezik a szenzor detektor elrendezésének köszönhetően. A különböző betekintési szöggel rendelkező felvételek reflektancia értékeinek közvetlen összehasonlítása az idősorban a BRDF hatás miatt zajjal terhelt, így ennek megfelelően kell kiértékelni. A lékek képét a betekintési szögek különbsége minimálisan befolyásolja, mivel 25 m átlagos faállomány magasság mellett 786 km magasságból tekintve szubpixeles mértékű a lék szegélyén kitakart területek. Az L1C típusú felvételek a Copernicus Open Access Hub-ról származnak. A Sentinel-2A (S-2A) első felvételeit 4 nappal felbocsájtása után készítette 2015. június 29-én, de operatív fázisba csak 2016. szeptember 9-én lépett. Az idősor első 6 időpontja (2. táblázat) az operatív fázis előtt lett rögzítve, így geometriai hibák elfordulhatnak rajta.

A felület megvilágítási modelljének modellezéséhez a S-2A felvételek metaadatai lettek felhasználva, amelyek 5x5 km felbontásban találhatók meg a csempékben.

2. táblázat: Az esettanulmányban felhasznált Sentinel-2 képcempék fontosabb paramétereiről

Műhold pászta azonosító	Év	Hónap	Nap	Nap azimuth (°)	Nap magasság (°)
R079	2015	8	7	156.43	56.68
R036	2015	10	3	165.49	37.17
R079	2016	3	24	161.83	42.31
R079	2016	7	22	154.09	60.17
R036	2016	8	28	157.52	49.64
R079	2016	8	31	161.92	49.22
R036	2016	9	7	159.99	46.28
R079	2016	9	10	164.19	45.74
R036	2016	9	27	164.46	39.09
R079	2016	9	30	168.16	38.37
R079	2016	10	10	169.69	34.67

3.2.1.1.3 Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben

A faállomány-típusok térképezéséhez 2017.04.10. és 2017.10.27. között készült felvételek választottam ki a 34UCU Sentinel-2 cempéből az R036 és R079-es műholdpásztákból. Az L1C típusú felvételek a Copernicus Open Access Hub-ról származnak. Az elérhető összes felvétel letöltésre került és a kutatás során fejlesztett automatikus előfeldolgozó rendszer segítségével lettek kiválogatva. A cempékből készített kivágatok földrajzi befoglalói: (É 47.7610°; K 18.7452°; É 48.0840°; K 19.1198°). Az alkalmazott kiértékelési módszernek köszönhetően a különböző műholdpásztákból rögzített felvételek radiometriai különbsége nem okozott problémát a feldolgozásban.

3.3 Referencia adatok

A fejlesztett térképezési módszereknél a modellek paraméterezéséhez, tanításához és pontossági vizsgálatukhoz terepi adatokra volt szükség. Több esetben elegendő volt nagyon nagy felbontású légi vagy űr távérzékelte adatok bevonása, ám más esetekben közvetlen terepi mérésekre volt szükség a téradatok és faállomány attribútumok meghatározásához.

3.3.1 Lékek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben

A mesterséges lékek detektálásához szubpixeles felbontásban több típusú referencia anyagra volt szükség, mint a többi adatvezérelt módszernél a magasabb térbeli felbontás érdekében. A Börzsöny hegységről 2015-ben készült 0.2 m terepi felbontású légifotók alkották az alapját a referencia anyagoknak. A felvételek a Vexcel UltraCamX (Vexcel Imaging GmbH, Graz, Ausztria) kamerával készültek. A felvételek javított külső tájékozása rendelkezésre állt, melyekhez további GNSS illesztőpontokat mértem geodéziai pontossággal Leica 1200 GPS (Leica Geosystems AG, Heerbrugg, Svájc) rendszerrel. A légifotókból a Trimble Inpho® 7 szoftverrel (Trimble Inc, Sunnyvale, USA) előállított ortofotót és digitális borított felszín modellt (Digital Surface Models, DSM) használtam fel. A felületmodell a szoftver Match-T moduljával készült 0.5 m és 2.0 m felbontásban. Az ortofotó az elkészített 2.0 m felbontású DSM modellre készült el, ezzel kiküszöbölve a perspektív torzulásokat a létrejött faállományok területén. A 2015 előtt nyitott mesterséges lékek ezen a képanyagon jól beazonosíthatók voltak. A lékek azonosítása félig automatizáltan történt meg a 0.5 m felbontású DSM-en a terepmodell alapján. A normalizált magasságok 5 m küszöbértékkel elvágván kaptam meg a feltételezett lékeket, majd a hibák vizuális interpretáció segítségével az ortofotó alapján lettek javítva. A fotogrammetriai úton készült DSM a kisebb méretű lékeket nem tartalmazta, ugyanis az ilyen területeken nem lehetséges a képegyeztetés az alacsony textúra miatt [186], így interpolált felület fedt

ezeket a helyeket. A T1 mintaterületre 2016-ból egy másik forrásból (<https://geoshop.hu/>, 2019.12.30.) elérhető volt 1.0 m terepi felbontással egy frissebb ortofotó, amelyen a 2015-2016 telén nyitott lékeket is meg lehetett határozni. 2016 őszén GNSS méréseket készítettem a T1 mintaterületen a Trimble Juno SB (Trimble Inc, Sunnyvale, USA) terepi adatgyűjtővel a lécek pontosabb beazonosításához a légifelvételeken.

A T2 mintaterületen elérhető volt egy 2016 nyarán készült 0.1 m terepi felbontású légifotó anyag és a fényképezéssel párhuzamosan rögzített ALS-ből származó felületmodellek. Az ALS átlagos felbontása 27 pont/m² volt. Az ALS-ből készült DSM-en nagyon pontosan meg lehetett határozni a lécek pozícióját és kiterjedését. Ennél a repülésnél a LEICA ALS-70HP lézerszenzor és a LEICA RCD 30 RGBN 60 MP kamera (Leica Geosystems AG, Heerbrugg, Svájc) szenzorok rögzítették a faállományt. Az ALS-ből készült felületmodell a referencia lécek meghatározásán túl alkalmas volt a megvilágítás függvényében történő spektrum modellezésre a T1 területen.

A B mintaterületen 2015 és 2016 között nem történt jelentősebb változás a faállomány kiterjedésében, így ott nem volt szükség további adatforrás bevonására a 2015-ös ortofotó mellett.

3.3.2 Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben

Az erdőborítás térképezéshez nagyon nagy felbontású űrfelvételeket alkalmaztam a tanítótérületek kijelölésénél a Bing térkép szolgáltatótól (<https://www.bing.com/maps>, 2019.12.30.). Az erdőborítás térképezéshez összesen 4217 erdő, 2553 nem erdő tanítótérület jelöltem ki. A faállomány-típus minták kijelölése az OEA adatai és terepi bejárások alapján történt. Az űrfelvétel idősből összeállított időkompozit vizuális támaszt adott a tanítótérületek elhelyezéséhez. A tanítótérületek kijelölésének feltétele volt, hogy legalább 6x6 pixel méretű (60x60 m) kiterjedése legyen és már záródott lombkoronával rendelkezzenek. A faállomány-típusok osztályozásához összesen 1148 tanítótérületet jelöltem ki a 2017-es képanyaghoz.

A faállomány borítás térkép pontossági vizsgálatához 5022 pontot jelöltem ki szabályos hálózatban 438 méteres rács távolsággal. A cél 5000 pont érvényesítése volt szabályos hálózatban. A referencia pontok típusának meghatározása nagyon nagy felbontású űrfelvételek és ortofotó alapján történt meg. A faállomány-típusok modelljéhez szabálytalan hálózatban lettek ellenőrző pontok kijelölve 2018-2019 telén Szokolya, Nógrád, Kóspallag és Kismaros települések közelében. Itt az egyes pontokban körlap szerinti elegyarány lett számolva a felső koronaszintben elhelyezkedő faegyedekből. Ezen kívül az OEA alapján választottunk ki a tanító területektől független helyeken 100%-os elegyarányú erdőrésztleteket. A gyűjtött információk segítségével 1415 ponton került ellenőrzése a faállomány-típus térkép.

A terepi információk gyűjtésénél a helyszín dokumentálása földrajzi pozícióval ellátott fényképekkel és jegyzetekkel történt. A fényképek készítésének pozíciója lett felhasználva a pontok pozíciójának meghatározásánál, melyeknek 10 méteren belüli pontossága elegendő volt az űrfelvételek felbontásához.

4 A kutatás módszerei

Ebben a fejezetben az esettanulmányokban alkalmazott távérzékelési munkafolyamatok építőelemeinek leírása található. A máshonnan átvett módszereknek rövid leírása, míg a saját fejlesztésű módszerek részletesen dokumentálva olvashatók. Az építőelemek leírásának a sorrendje a távérzékelési kiértékelési folyamat logikáját követi.

4.1 Űrfelvételek előfeldolgozása

A bemutatott esettanulmányok többsége űrfelvétel idősorok elemzésével foglalkozik. Az űrfelvételeket a szolgáltatóktól olyan feldolgozottsági szinten érkeznek a felhasználókhoz, melyek már alkalmasak az elemzésre (Level 1 és Level 2) [187], de ezek ritkán alkalmasak idősorok kiértékelésére. Az

esettanulmányokban alkalmazott űrfelvételek geometriai szempontból már Level 1 szinten is megfelelő minőségű geometriai korrekcióval rendelkeznek (S-2 10 m felbontású sávjai: 3 m (3σ) hiba [188] Landsat-8 30 m felbontású sávjai: 38 m (2σ) hiba [189]). Az idősorok kiértékeléséhez Level 3 típusú (Analysis ready data, ARD) [190] vagy más néven konzisztens idősorokra van szükség. Ez alatt olyan űrfelvételek sorozatát értjük, melyek a vizsgált terület felett:

- Magas időbeli felbontású;
- Az atmoszféra alján értelmezett reflektancia-értékeket tartalmazza;
- A vizsgálat szempontjából elfogadható mértékű geometriai hibákat tartalmaz;
- Csak olyan mértékben tartalmaz atmoszférikus zajokat, felhőket, felhőárnyékokat, melyek a vizsgálat eredményét nem befolyásolják;
- Mentess a domborzaton megjelenő természetes árnyalásoktól.

Az ilyen módon előkészített idősor alkalmas automatizált képosztályozó módszerek futtatására, ami nagy kiterjedésű erdőterületek leltározásánál nélkülözhetetlen. A konzisztens idősor létrehozása egy komplex folyamaton keresztül valósul meg, ahol a folyamat egyes lépései egymásra épülnek. A felvételek beszerzése, szűrése majd a felhő és felhőárnyék maszkok létrehozása történik meg először. Az adathiányos területek pótlása után a felvételek topográfiai normalizációja történik, így készül el a már elemzésre alkalmas idősor. Az előfeldolgozás egyes lépései az atmoszférikus korrekción kívül egy saját fejlesztésű képfeldolgozó keretrendszerben történtek.

4.1.1 Atmoszférikus korrekció

A felszínről visszaverődő reflektancia jelét az atmoszféra nagy mértékben befolyásolja. Ez a „zavarás” a légköri részecskék típusától és jellemzőitől függ. A gáz molekulákon áthaladó sugárzás (N_2 , O_2 , O_3 , H_2O , CO_2 , ...) a Rayleigh-szórás alapján torzul. A Rayleigh-szórás akkor lép fel, ha a sugárzás hullámhosszánál sokkal kisebb méretű részecskéken halad át [191]. Az atmoszférikus korrekció idősorok kiértékelésénél nélkülözhetetlen lépés, amely eltávolítja vagy csökkenti az atmoszférában történt jel szóródást [192].

4.1.1.1 Sentinel-2 (Sen2Cor)

Az S-2 adatok atmoszférikus korrekciója a Sen2Cor szoftverben [126] történt. A Sen2Cor szoftver egyes S-2 L1C típusú georeferált TOA termékek L2A típusúvá transzformálását végzi el. A korrekcióhoz szükséges metaadatok, mint a szenzor és Nap pozíciók és szenzor erősítési (gain) és munkapont (bias) tényezők az L1C típusú termékekben megtalálhatók. Az atmoszférikus korrekció végrehajtásához először a fényerő hőmérséklet (brightness temperature) kerül kiszámításra, ami alapján a szaturált és hiányos pixeleket lehet kiszűrni. Az atmoszféra tetején mért reflektancia (Top Of Atmosphere, TOA) számítása a szenzor által az adott sávon rögzített pixel érték és a sávhoz tartozó erősítési tényező szorzatából áll elő, melyhez még hozzá kell adni a sávhoz tartozó munkapont értéket (1).

$$L_{\lambda} = gain_{\lambda} \cdot DN_{\lambda} + bias_{\lambda} \quad (1)$$

L_{λ} : Az atmoszféra tetején mért reflektancia érték a λ sávon

DN_{λ} : A λ sávon rögzített pixel érték

$gain_{\lambda}$: A λ sávhoz tartozó erősítési tényező

$bias_{\lambda}$: A λ sávhoz tartozó munkapont

Az atmoszféra alján mért felszíni reflektancia (Bottom Of Atmosphere, BOA) számítása a TOA reflektancia módosításával történik meg. Az atmoszférikus korrekció a légnyomás, vízpára, ózon réteg vastagság és geometriai tényezők figyelembevételével történik. Ezekre a tényezőkre a légköri aeroszol optikai vastagsága (Aerosol Optical Thicknesses, AOT) alapján lehet következtetni [193]. Az AOT számítása a Dark Dense Vegetation (DDV) [194] módszerrel történik a Sen2Cor rendszerben. Az AOT számítás a felvételen látható sötét objektumok alacsony reflektanciájára fektetett hipotézisen alapul. Ezek a sötét objektumok jobban ki vannak téve az atmoszféra módosító hatásának, így a TOA

reflektancián nagyobb dinamikával írják le az atmoszféra állapotát. A DDV módszer a vegetációval borított területeket tekinti ilyen sötét objektumoknak [195]. Az AOT-t egy a SWIR és látható tartomány között felállított lineáris regresszió segítségével számítja a módszer, a klorofill abszorpció és víz abszorpció kapcsolata alapján. A TOA reflektancia alapján megfelelő sötét objektumokat keres a program, melyek felett létrehozza az aeroszol modellt az atmoszféra modell alapján [192]. Amennyiben az AOT számításához nem áll rendelkezésre sötét objektum, egy konstans AOT értékkel végzi el a korrekciót. A Sen2Cor az AOT segítségével készült korrekción kívül egyéb korrekciók elvégzésére is alkalmas, mint a topográfiai normalizáció, empirikus BRDF korrekció. A szoftver által korrigált felvételek földfelszín kiértékelésére alkalmasak elsősorban, a víztesteken megjelenő egyéb hatásokat nem korrigálja. A Sen2Cor atmoszférikus korrekciója a szoftverbe épített ATCOR3 modulban valósul meg [126], [196]. A kutatásoknál a Sen2Cor 2.3.1. verzióját használtam fel.

4.1.2 Felhőmaszkolás

A felhők és a felhőárnyékok szűrése az egyik legfontosabb eleme az előfeldolgozásnak. A távérzékelés munkahipotézise, hogy a hasonló objektumok hasonló reflektancia jellemzőkkel rendelkeznek ideális esetben. Ez a hipotézis teszi lehetővé a gépi tanulási módszerek alkalmazását is automatikus képosztályozáshoz nagy területeken. Amennyiben a földfelszínen található objektumot vastag felhőréteg (cumulus-típusok) borítja, nem értelmezhető a felvételen az objektum. Ha vékony felhőréteg borítja (cirrus-típusok), az atmoszférára érzékeny hullámhosszokon zajos formában jelenik meg a spektrális reflektanciája, de alakjellemezői még értelmezhetők. A vastag felhők árnyékot vetítenek a felszínre, ami alacsonyabb dinamikát eredményez az objektumokon, ezért nem kiértékelhetők.

4.1.2.1 Sen2Cor

A Sen2Cor futtatása során létrejön egy automatikus felszínosztályozás réteg, amely 12 tematikus kategóriával rendelkezik. Ezek a kategóriák különböző felhő, hó, víz, vegetáció és talaj felszínborításokat jelentenek [126]. A felhőmaszk létrehozása a szoftverben több lépésben történik. Az algoritmus külön választja a magas szintű, ún. cirrus-típusú felhők és az egyéb felhőnemek osztályozását. Az egyéb felhőnemeknél 3 típusú felhőt különböztet meg: alacsony, közepes és magas valószínűséggel detektált felhők. A felhőosztályozás egy küszöbértékes szakértői osztályozó modell és egy betanított self-organizing map neurális hálózat kombinációjával történik [197]. A szakértői osztályozó modell spektrális indexeket, mint a normalizált differenciált vegetációs index (NDVI) [198] és normalizált hó index valamint az egyes sávokon előre meghatározott küszöbértékeket alkalmaz. A felhőárnyékok osztályozásánál a vetített árnyékok elméleti pozíciója segíti az algoritmust, amelyet a nap pozíciójából és a lehetséges felhő magasságból számít ki. Az osztályozás pixel alapon történik. Az MSI szenzor [73] nem rendelkezik olyan sávval, ami a termális infravörös tartományban (10400-12500 nm) érzékelne. Ezért nem tudja kihasználni azt a jelenséget, hogy a felhők felszíni hőmérséklete különbözik a talajközeli felszín hőmérsékletétől. Ennek következtében kevesebb változó áll rendelkezésre a felhők osztályozásánál, mint a hasonló földmegfigyelő műholdprogramoknál. A Sen2Cor készítői által végzett érvényesítés alapján a létrehozott automatikus felszínosztályozás $73 \pm 11\%$ összesített pontosságot képes elérni globális mintaterületeket tartalmazó érvényesítés során [126].

4.1.2.2 Multitemporális felhőmaszk Sentinel-2 idősorhoz

A Sen2Cor [126] által létrehozott felhő és felhőárnyék maszk egyetlen időpont alapján készül. A felvételek előzetes szűrésére alkalmas ez a maszk. A vastagabb felhőket jól azonosítja, de a kerületükön található kevert pixeleket és a vékony felhőrétegeket már csak kisebb hatékonysággal tudja azonosítani. A felhőárnyékok térképezése geometriai úton történik a szoftverben. Ennek a következménye, hogy ha a felhő mennyiségét alábecsülte a szoftver, a hozzá tartozó árnyékot is alábecsüli. A Sen2Cor által készített felhőmaszkon kívül más módszerek is születtek már az S-2 képeihez. Az eredetileg Landsat űrfelvételekhez fejlesztett Fmask algoritmus [127] is alkalmazható, azonban a termális sáv hiánya miatt kevésbé hatékony az eredeti módszer. Az Fmask-nak született egy módosított változata kifejezetten az S-2 képeihez, ami a termális sáv helyett a két közeli infra tartományban érzékelő sáv különböző

betekintési szöge alapján határozza meg a felhőket [125]. Egy másik megoldás döntési fákat alkalmazott a felhők detektálására bayesi statisztikával kiegészítve [199]. Ezekben a megoldásokban a közös, hogy egyetlen felvétel alapján történik a felhők osztályozása, amivel a vastag felhők jól, a vékony felhőrétegek kevésbé hatékonyan detektálhatók. A Multi-sensor Atmospheric Correction and Cloud Screening (MACCS) alkalmaz multitemporális felvételeket a felhők detektálásra [200]. A szenzor kék tartományában rögzített sávjait hasonlítja össze a felhő detektáláshoz egy referencia időpont alapján. A felhő észlelése egy dinamikus küszöbérték alapján történik, ami a két időpont közötti idő különbségnek a függvénye. Hazai kutatóműhelyben is készültek megoldások úrfelvételek felhő szűrésére, melyek egy logikai modell alapján a szenzor által rögzített sávok különbségei és arányainak küszöbértékes szűrésével hoz létre maszkokat [201], aminek elméleti alapja alkalmazható lenne multitemporális felhő szűrésekre.

A felsorolt módszerek mindegyike alkalmas a felhők és árnyékaik detektálására szárazföldek fölött, azonban ezek általános felhasználási célra készültek. Az erdőgazdálkodást támogató tematikus térképek lokális szinten készülnek, melyek rendszerint néhány ezer hektárt foglalnak magukba. A lokális szintű tematikus erdőterképek előállításához olyan felhőszűrő módszerre van szükség, amely nagyon magas (90% >) felhasználói pontosságra képes erdőterületek fölött, akár más felszínborítási kategóriák fölötti pontosság rovására is. Ezt a szempontot figyelembe véve fejlesztettem ki a több időpontot figyelembe vevő felhő és felhőárnyék szűrő módszertant.

4.1.2.2.1 Kálmán-szűrő alapú multitemporális felhőmaszk Sentinel-2 idősorhoz

A vastag felhők egyértelműen meghatározhatók a látható kék tartományban az egyes felvételeken. Az idősorban kiugró megfigyelést mutat a magas reflektanciájuk. Ez a feltevés erdőterületek felett igaz, ahol a vegetációs időszak során minimális reflektancia-változás van. A mérsékelt övi erdőkben - melyek Magyarországon találhatók - csak katasztrófa események (pl.: hirtelen lombvesztés, széldöntés) okozhatnak kivételeket a feltevés alól, melyek szerencsére kis mértékben érintik az erdőterületeket. A vékony felhők is kiugrást okoznak az egyes felvételeken pozitív irányban, azonban a kiugrás mértéke az átlátszóságuk miatt alacsonyabb. A felhők felszíne nem egyenletes, így a bennük lévő aeroszol réteg vastagsága is szinte pixelenként változik. Ennek következtében nehéz egyetlen küszöbértéket találni a detektálásukra. A pontos detektálásuk csak idősorban lehetséges.

A felhők által vetített árnyékok detektálása is idősorral végezhető el hatékonyabban, ha nem geometriai úton határozzuk meg az egyes felvételeken. A különböző vegetáció típusoknak a közeli infravörös tartományban igen magas a reflektanciája, így, ha egy időpontban árnyék vetődik rá, hirtelen nagymértékben megváltozik. A változás iránya ellentétes a felhők által okozott kitéréssel. A kék tartománnyal szemben a közeli infravörös tartomány az erdők felett komolyabb dinamikával rendelkezik a vegetációs időszakban. A változás dinamikája összefüggésben van a Nap állásával, ugyanis a besugárzás szöge határozza meg a felszínre jutó energia mennyiségét. A topográfiai árnyalással érintett területre eső vetített árnyékok képfeldolgozási módszerrel nem különíthetők el, így az ilyen területeknek a vizsgálatát ki kell zárni.

A leírt feltevések alapján pixel alapon elvégezhető a felhők és a vetített árnyékok meghatározása az idősorban. A pixel alapú vizsgálatnak az előnye, hogy megtartja a magasabb térbeli felbontását a maszk, de a kimenet gyakran tartalmaz elkülönülő hibás észleléseket. Ezek a hibás észlelések utófeldolgozással csökkenthetők.

Az idősorban a kiugró értékek detektálása a Kálmán-szűrővel történt [202]. A Kálmán-szűrő a dinamikus rendszerek állapotának optimális becslését végzi el zajjal terhelt megfigyelések alapján. Az egyes időpontokban a négyzetes hibát minimalizálva éri el az optimális becslést. A rendszer változói és az időpontok között korrelációt feltételez a modell. Nagyon gyakran alkalmazott módszer adatasszimilációnál, GNSS navigációnál és a robotikában, de a földmegfigyelésben is számos alkalmazása volt már. A felhők detektálása esetén az egyes sávok idősorát egy lineáris rendszernek tekintjük, ahol minden egyes időponthoz tartozik egy állapotérték (reflektancia). A Kálmán-szűrő állapot-vektorának meghatározásához (2) szükség van az állapotváltozás modellre (F_k), a mérési

modellre (H_k), a folyamat zaj kovarianciájára (Q_k), mérési zajra (R_k), kontroll-input modellre (B_k), azonban ezek az esetünkben konstansnak tekinthetők. Így az egyenlet egyszerűsített formája:

$$x_k = F_k \cdot x_{k-1} + W_k \quad (2)$$

x_k : A rendszer állapotvektora k időpontban

F_k : Az állapotváltozás modell alapján meghatározott érték $k-1$ időpontban

W_k : A folyamat zaja k időpontban

Az állapot-vektor tartalmazza a rendszer pozíció és sebesség komponenseit (3). A rendszer egy új állapotának k időpontban van egy gyorsulása, aminek az értéke az egyes időpontokban normális eloszlást mutat a 0 átlag körül. Amikor a lineáris rendszerben nagyobb változás történik, a gyorsulás értéke 0-tól távoli extrém értékeket vesz fel. Az ilyen kilengés az állapot-vektor ($\hat{x}_k$) sebesség komponensében ($\dot{x}$) válik láthatóvá.

$$\hat{x}_k = \begin{bmatrix} \text{pozíció} \\ \text{sebesség} \end{bmatrix} \quad (3)$$


$\hat{x}_k$: A rendszer állapotának optimális becslése k időpontban

A felhők detektálása a sebesség komponens változása alapján történt (20. ábra), amennyiben elértek egy bizonyos küszöbértéket. Az idősor kék sávjában történt kisebb mértékű változás vékony felhőréteget, a nagymértékű változás vastag felhőréteget mutat a feltételezésünk szerint. A mérési zajt empirikusan becsültem meg a modellhez. A felhők és felhőárnyékok szűrését képpárokon végeztem el. Egy teljesen felhőmentes referencia képpel állítottam párba az egyes vizsgált képeket. A referenciaképet vizuális vizsgálattal választottam ki a vegetációs időszak közepéről, hogy minimalizáljam a különbségeket. A Kálmán-szűrőhöz a referencia képet egymás után kétszer helyeztem el, majd az aktuálisan vizsgált felvételt is beillesztettem. Az első lépésben, amikor a referencia értéken fut a szűrő, a kezdeti állapotot találja meg, majd a második lépésben ér az aktuális képhez. Amennyiben a változás értéke -1-nél kisebb volt, akkor vastag felhőréteget jelzett. A vékony felhőréteg detektálása egy 6x6 pixel méretű ablak alapján történt, ami 60x60 métert takar, hasonlóan az S-2 B1 sávjához. A sebesség komponensek szórását vizsgáltam az ablakban, és ha ez meghaladta a 70-es küszöbértéket, akkor felhőnek osztályoztam a teljes ablakot. A küszöbértékek empirikus módon lettek meghatározva a képanyagnál a transzformált képek hisztogramjai alapján. A vastag felhőrétegnek osztályozott pixelek közül azokat állítottam vissza nem felhő értékre, amelynek 2-nél kevesebb, azonos osztályba tartozó szomszédja volt.

A felhőárnyékok esetében is hasonló módszert alkalmaztam (21. ábra) a 10 méteres felbontású közeli infravörös sáv idősorán. A topográfiai árnyalással borított területek kizárása a megvilágítottsági állapot (5)[100] alapján történt, melyet a nap állása és a domborzatmodell segítségével számítottunk ki az egyes időpontokban. Empirikusan a 0.5 érték feletti területeket tekintettem megvilágítottoknak, így az annál alacsonyabb megvilágítottságú területeken a későbbi topográfiai normalizáció végzett korrekciót. A Kálmán-szűrő állapotvektorának sebességváltozásához az infravörös tartomány nagy dinamikája miatt nem lehetett egyetlen határértéket meghatározni, ezért egy lineáris függvény készült empirikusan a Nap-magasság szögének függvényében. A függvény meredekségét -0.5-nél, és tengelymetszését 125-nél határoztam meg az egyes képekről vett minták alapján. A sebesség-változás képeket a kapott küszöbértékkel osztályozva kaptam meg a vetített felhőárnyékokat. A vastag felhő osztályozásnál alkalmazott szomszédsági vizsgálattal itt is ki lettek szűrve az önálló megjelenések. A folyamat végén egy 2-pixel széles pufferezóna került a felhőárnyéknak osztályozott területek köré, hogy a kevert pixelek se kerüljenek bele a végső elemzésbe. A három különböző típusú maszk egyesítésével kaptam meg az egyes képekhez a pontos felhő- és felhőárnyék maszkot.



20. ábra: Felhőmaszk készítésének munkafolyamata



21. ábra: Felhő árnyék maszk készítésének munkafolyamata

A felhő és felhőárnyék maszkoláshoz készített módszertan pontosságának meghatározása hibamátrix segítségével történt. Az egyes képeken vizuális interpretációval a kék, zöld és vörös sávokból készült RGB kompozit alapján a felhőket és felhőárnyékokat vektorizáltam. Az egyes időpontokból származó hibamátrixok felhasználói pontossága lett összehasonlítva a saját fejlesztésű és a Sen2Cor által generált maszkokkal.

A felhőmaszk fejlesztéséhez Martirosyan Kálmán-szűrő implementációját vettem alapul (<https://github.com/hmartiro/kalman-cpp>, 2019.12.30).

4.1.3 Hiányzó adatok pótlása

A felhők és felhőárnyékok maszkolása után adathiányos területek keletkeznek az egyes képeken. Gépi tanulási módszereknél az osztályozó modelleket n dimenziójú adattal tanítják ($n > 0$; $n \in \mathbb{Z}$). Az n dimenzió egy ürfelvétel idősoránál a felvételek számának és a szenzor kiválasztott sávjainak a szorzata. Amennyiben az idősorban adathiányos területek vannak, akkor n -nél kevesebb érvényes dimenzió található csak meg. Ebben az esetben a tanított modell és az osztályozni kívánt objektum dimenziói nem egyeznek meg. Ha a hiányzó értékek helyén „nincs adat” értékek maradnak, az n dimenzióra tanított modell ezekhez képest számolja az euklideszi távolságokat, ami kevésbé megbízható osztályozáshoz vezethet. Két lehetséges mód van a jelenség feloldására: (1.) Az osztályozó modell dimenzióinak módosítása vagy (2.) az idősor „kifoltozása”. Egy vegetációs időszakon belüli ürfelvétel idősoránál, ahol azt feltételezzük, hogy csak fenológiai változás következik be az erdőben, a második lehetőség alkalmazása jár kevesebb számítási költséggel.

A foltozás szekvenciálisan történt meg az egyes időpontokban, sorban haladva az egyes pixeleken. Habár az egyes spektrális sávok között magas korreláció van erdők esetén, a módszer egymástól

függetlenül kezeli őket. A hiányzó pixelek pótlása a legközelebbi érvényes pixelek alapján történt meg (22. ábra). A szekvenciális haladás miatt az előző időpontban már olyan kép szerepel, amelyen már nem található adathiányos terület. Ideális esetben - ha havonta egy közel felhőmentes felvétel elérhető, - a felvétel rögzítési körülményei között maximum 10° nap magasság vagy azimuth szög eltérés lehet, ami a megjelenő domborzati árnyalás szempontjából még vizuálisan elfogadható különbséget eredményez. Így az aktuálisan vizsgált képen az érvényes pixeleket párosítani lehetett a korábbi reflektancia értékével. A reflektancia párokra lineáris regressziót lehetett állítani, aminek a meredeksége határozta meg a változás mértékét a két időpont között (4). Sűrű idősor esetén - amikor havonta 1-2 felvétel van - a mozgó árnyékok sem jelentenek nagyobb problémát az ilyen típusú modellezésnél. A reflektancia párok 40x40 pixel méretű ablakban kerülnek kigyűjtésre. A kiválasztott ablak mérettel folszerű felhőborítás mellett már nagy valószínűséggel lehetséges érvényes pixel párok mintavételezése a környezetből. A pixelpárok szűrése a megvilágítottsági állapotuk és a reflektancia értékük alapján történik. Azok a reflektancia-értékek kerülnek begyűjtésre, melyeknek az előző időpontban 5%-nál nem volt nagyobb az eltérése. A megvilágítottsági állapot esetén 20%-os eltérést határoztam meg.


$$R_{i(x,y)} = S_{i-1(x,y)} \cdot a_{(x,y)} + b_{(x,y)} \quad (4)$$

$R_{i(x,y)}$: Egy sáv modellezett reflektancia értéke az aktuális időpontban

$S_{i-1(x,y)}$: Egy sáv reflektancia értéke az előző időpontban

$a_{(x,y)}$: A környezetből vett reflektancia párokra állított lineáris regresszió meredeksége

$b_{(x,y)}$: A környezetből vett reflektancia párokra állított lineáris regresszió tengelymetszése



22. ábra: A hiányzó pixelek pótlásának munkafolyamata

4.1.4 Topográfiai normalizáció

A szakirodalomban a képen megjelenő domborzati árnyalás kiküszöbölésére jellemzően topográfiai normalizációt alkalmaznak [101]. A korrekció során az árnyalt és megvilágított részek spektrális értékei a domborzaton elfoglalt viszonyai (kitettség, lejtés) alapján kiegyenlítődnek, aminek korrekciójára többféle eljárás létezik [203]. Minden modell digitális domborzat modellt igényel a domborzati viszonyok számításához. A leggyakrabban alkalmazott modellek csak domborzat függő, domborzat-hullámhossz függő [100] vagy domborzat-reflektancia függő [204] képleteket alkalmaznak.

A fejezetben a Sentinel-2 MSI szenzor felvételeihez az esettanulmányokban alkalmazott topográfiai korrekciós módszereket mutatom be, melyeket a Börzsöny hegységről készült felvételeknél alkalmaztam.

4.1.4.1 Megvilágítottsági állapot (IC)

A domborzaton megjelenő árnyalódás, a felület és megvilágítás függvénye. Minnaert művében [99] olvasható ennek a hétköznapi jelenségnek a fizikai alapja, ami alapján modellezni lehet. Egy digitális domborzatmodell és a Nap pozíciójának ismeretében kiszámítható a megvilágítottsági állapot (Illumination Condition, IC)(5) [100]:

$$IC = \cos(Z) \cdot \cos(S) + \sin(Z) \cdot \sin(S) \cdot \cos(\varphi_Z - \varphi_S) \quad (5)$$

IC: Megvilágítottsági állapot

Z: Nap zenit szöge

S: Felületelem lejtőszöge

φ_Z : Nap azimuth szöge

φ_S : Felületelem kitettségének a szöge

Az IC egy [-1;1] tartományban mozgó relatív értéket ad a felületelem megvilágítottsági állapotára, ami alapján becsülni lehet az azonos képelemre eső ürfelvétel reflektanciáját befolyásoló domborzati tényezőket.

4.1.4.2 Sen2Cor topográfiai normalizáció (ATCOR3)

A Sen2Cor féle topográfiai normalizáció a szoftverbe épített ATCOR3 modulban valósul meg [126], [196]. Az ATCOR3-ban lévő topográfiai normalizációs eljárás egy részben empirikus módszer [205]. Az alkalmazott képlet (6) becsült paraméterekkel (G komponens) csökkenti a túlkorrigálás hatását, amit a diffúz fény tényezőjének figyelmen kívül hagyása okoz az egyszerűbb módszereknél, mint a C és koszinusz eljárások. A módszer Lambert-féle felületet feltételez a területre, paraméterezése nagy mértékben felszínborítás függő. A szoftver zárt működése miatt korlátozottan módosíthatók a beállított értékek. Ha az előre megadott paraméterek nem illeszkednek az alkalmazott területre túl vagy alul korrigálás léphet fel.

$$\rho_H = \rho_L \cdot \left(\frac{\cos \beta}{\cos \beta_T} \right)^b = \rho_L G \quad (6)$$

ρ_H : Normalizált reflektancia

ρ_L : Lambert féle reflektancia

β : Megvilágítottsági állapot (IC) (5)

β_T : Módosított Nap zenit szög

b: Vegetáció borítás mértékétől és hullámhossztól függő változó

G: Korrekciós faktor

4.1.4.3 Empirikus forgatás módszere

A topográfiai normalizációt az empirikus forgatás modelljével (7) végeztem el [100]. A gyakrabban alkalmazott C és koszinusz topográfiai normalizációs eljárások során gyakori hiba, hogy a modell túlkorrigálja a reflektanciát az alacsony megvilágítású területeken, különösen a spektrum látható tartományában. A hiba oka, hogy ezek a módszerek figyelmen kívül hagyják a diffúz sugárzást. Az empirikus forgatás modellje ezt küszöböli ki adatvezérelt módon azzal, hogy megszünteti a megvilágítottság függését a reflektanciától. A módszer előnye, hogy nem feltételez Lambert-féle felületet, azonban felszínborítás-függő a paraméterezése. Az egyes spektrális sávokhoz tartozó paramétereket az adott felszínborításból vett mintákon kell meghatározni. Az egyes sávok és a megvilágítottsági érték között lineáris regressziót kell felállítani, melyben csak érvényes, nem árnyalt

pixelek lehetnek. Az erdőterületekre készítettem el a modell paraméterezését, melyhez a mintaterületen található erdőrésztetek területéről gyűjtöttem ki a reflektancia-értékeket. Az árnyalt területeket ki kellett zárni a vizsgálatból, ezért felületi árnyalódásként lettek figyelembe véve azok a területek, melyeken a megvilágítottsági állapot 0 érték alatt volt. A vetített árnyékok szűréséhez sugárkövetéses [206] módszerrel készült maszk.

$$R_{i(x,y)} = S_{i(x,y)} - a_i \cdot (IC_{(x,y)} - IC_h) \quad (7)$$

$R_{i(x,y)}$: Normalizált reflektancia az i sáv egy pixelén

$S_{i(x,y)}$: Eredeti reflektancia az i sáv egy pixelén

a_i : Lineáris regresszió meredeksége az adott sávon

$IC_{(x,y)}$: Megvilágítottsági állapot a felületen

IC_h : A vízszintes felület megvilágítottsági állapota, mely egyenlő a Nap állás zenit szögének cosinusával

A normalizáció után a 0-nál kisebb és 1-nél nagyobb értékek 0 vagy 1 értékkel lettek felülírva. A topográfiai normalizáció az idősor minden egyes képén megtörtént.

4.1.5 Szegmentálás

A szegmentálás során a kép pixeleinek homogén egységekbe sorolása történik. Az előfeldolgozott nyers vagy a már tematikus tartalommal bíró képek információ tartalmának átláthatóbb kezelésére alkalmas eljárás a szegmentáció. Képfeldolgozásban jellemzően a kép térbeli objektumainak kiterjedésének azonosítására alkalmazzák a képszegmentáló módszereket. A szegmentálás ebben az esetben X-Y síkon zajlik és a képsíkon elhelyezett magpontokból kiindulva épülnek fel a szegmensek régiónöveléssel. Idősorok kiértékeléshez az előkészítés történhet időbeli szegmentációval, ahol a pixel értékének zajos idősorát illeszti matematikailag jól megfogalmazható szakaszokra a módszer [97]. Ebben az esetben az idősoron a sávok irányában, pixelszinten történik a szegmentálás, térbeli kiterjesztés nélkül (nincs régiónövelés) és a szegmensek egy-egy időszakot fednek le az idősorból.

4.1.5.1 Képszegmentálás

A szegmentálás a képen homogén részeket épít fel a pixelekből, melyeket később objektumként lehet kezelni. Az objektumból a benne elhelyezkedő pixelek spektrális jellemzőin kívül statisztikai és geometriai jellemzőket lehet levezetni, amelyek az objektumok osztályozásánál használhatók fel.

A homogén objektumok létrehozása az általam alkalmazott multi-resolution képszegmentáló (MRS) [207] eljárásban lokálisan történik. Ha az objektumok létrehozása globálisan történne, az a felügyelet nélküli adatosztályozáshoz hasonló eredményt adna. Az MRS lentől-felfelé (Bottom-up) stratégia alapján hozza létre a szegmenseket. Kezdetben a szegmens csak 1 pixel kiterjedésű, majd iteratívan növeli az objektum területét, amíg el nem ér egy bizonyos küszöbértéket. A kezdőpontok kijelölésének pseudo random eloszlást kell követnie a megismételhetőség miatt.

A szegmens homogenitásának mértékére lehet küszöbértéket felállítani, melyet az intenzitás értékek szórása alapján lehet meghatározni. Czímber leírása alapján többsávós kép esetén a sávok szórásának súlyozott átlagát kell képezni a homogenitás meghatározásához [208]. Célszerű a szórást egy alakjellemzővel is kiegészíteni, hogy ne képződjene szabdalt alakzatok. Erre a célra a szegmens kerületének és területének viszonyát kifejező alakszám alkalmas. Egy szegmens h homogenitása a következőképpen írható fel (8):

$$h = (1 - a) \frac{\sum_{i=1}^b w_i \sigma_i}{\sum_{i=1}^b w_i} + a \frac{l}{\sqrt{n}} \quad (8)$$

a: az alakjellelmező sulya

b: a kép sávjainak száma

σ_i : A szegmens pixeleinek a szórása az i sávon

w_i : Az i sávhoz tartozó suly együttható

l: A szegmens kerülete

n: A szegmens pixelszáma

A szegmensek összevonása lokális környezetben történik olyan módon, hogy az összevonás utáni homogenitás változás minimális legyen. A szegmentálás iterációi akkor érnek véget, amikor a kijelölt homogenitás küszöbérték alatt már nem lehetséges további szegmensek összevonása. A szegmensek összevonása akkor ér véget, amikor már nem található két olyan egymás melletti szegmens, ahol a homogenitás változása egy előre megadott értéknél kisebb. Kezdetben az objektumok homogenitás értéke magas, amikor méretük csupán néhány pixel. Az összevonás során ezt az értéket csökkenteni kell, amit a szegment területével való súlyozás segít. Az így súlyozott értéket össze lehet hasonlítani a kiválasztott csatolandó szegmenssel. Az összevont szegmens homogenitásának (h_m) változása (Δh) a következő módon számítható két szegmens esetén (h_1, h_2) (9):

$$\Delta h = h_m n_m - h_1 n_1 - h_2 n_2 \quad (9)$$

h: szegmens homogenitása

n: szegmens pixelszáma

Az MRS szegmentálást a Czimmer által leírt algoritmus [208] általam továbbfejlesztett változatával végeztem el, ami Baatz és Schäpe [207] leírásán alapul.

4.2 Adatosztályozás

Az adatosztályozás a statisztikának egy területe, ami kategorizálja az adathalmaz egyes elemeit. A statisztika alapú adatosztályozásnak központi jelentősége van a mesterséges intelligencia (Artificial Intelligence, AI) és a számítógépes látás szempontjából, és messzemenő alkalmazásai vannak a mérnöki, tudományos, orvostudományi és üzleti célokra. Különösen az elmúlt fél évszázad során elért eredmények a mintázat felismerés terén lehetővé teszik a számítógépek hatékonyabb interakcióját az emberekkel [209].

Az adatosztályozás célja, hogy a kép minden egyes elemét tematikus kategóriák valamelyikéhez soroljuk. Ez a folyamat az adatokban lévő, ismétlődő mintázatok alapján történik. Ha egy képrészlet több tematikus kategóriát tartalmaz, az egyes osztályok pixelei azokon a sávokon, melyek érzékenyek az adott felszínborítási osztályra, az intenzitástérben jellegzetesen csoportosulva helyezkednek el [210]. Multispektrális felvételek esetén több sávon is megjelenhet ez a csoportosulás. Ha az egyes osztályok spektrális profilját tekintjük, ami a sávokból vett intenzitás értékeket tartalmazza, ezek különböző lefutással rendelkezhetnek. Az intenzitás értékeken felül további képjellemzők is bevonhatók, melyekkel növelni lehet az képek információ tartalmát képobjektum szinten [211]. Ezek a jellemzők alkotnak ismétlődő mintázatokat a távérzékelte képeken.

Az adatok osztályozása történhet felügyelt és felügyelet nélküli módon. Felügyelt osztályozás esetén az osztályozó modell tanítása a tematikus kategóriák mintáiból kigyűjtött adatok felhasználásával történik. A kategóriák mintaterületeinek kijelölése történhet terepi bejárás alapján, vizuális interpretációval vagy korábbi információk felhasználásával. A mintaterületek egyik részét az osztályozó tanítására használjuk, a másik részét pedig tesztelés céljából elkülönítjük [210]. Felügyelet nélküli osztályozásnál az intenzitástérben csoportosuló, feltételezhetően az egyes tematikus kategóriákhoz tartozó adatsortok elkülönítése történik meg. Az adatsortokat klasztereknek nevezzük. A nem felügyelt osztályozást

szokás klaszterezésnek is nevezni. A felügyelt osztályozásnál tehát a tematikus kategóriák meghatározása után osztályozzuk a képet, míg a nem felügyelt osztályozásnál a klaszterezés után az egyes klasztereket feleltetjük meg a tematikus kategóriák valamelyikének [210].

Az adatosztályozás távérzékelte adatokon korábban kizárólag vizuális interpretációval történt. Vizuális interpretációnak nevezzük azt a képfeldolgozási módszert, amikor a kiértékelést végző személy a felvételekről műszer közbeiktatásával, döntéseket hoz (osztályokba sorol), a döntéseiben háttérismereteit, szaktudását is felhasználja. A döntések szubjektív hibákkal terhelték [46]. A mesterséges intelligencia kutatásnak köszönhetően ma már nagyon elterjedtek a digitális módszerek [121], melyek hatékonyabbak nagy területek kiértékelésére.

4.2.1 Spektrális szétkeverés

Spektrális szétkeveréssel a szenzor által a pixelen rögzített spektrumot lehet szétbontani az őt alkotó elkülönülő spektrumokra [92]. A pixelt alkotó spektrumok részarányából következtetni lehet a felszínborítás típusok pixelen belüli előfordulásának arányára. A módszert a rugalmas osztályozók kategóriájába sorolják, ugyanis a pixelt több osztályhoz is hozzárendelheti [212]. A pixelen belül rögzített spektrum összetételére a felszínborítások tiszta spektrumainak ismeretében lehet következtetni, így a felügyelt osztályozás kategóriájába tartozik. Nagy felbontású űrfelvételeken, mint az S-2, a 10 méteres pixelein többnyire kevert spektrum található az erdőkben. Ennek a jelenségnek köszönhető, hogy a szigorú osztályozó módszerek, melyek egy pixelhez csak egy kategóriát rendelnek, pontatlan eredményeket adhatnak lokális szintű térképezésnél. Jellemzően hiperspektrális felvételek kiértékelésére alkalmazzák a módszert, ahol magas dimenziós számú képeket bontanak szét (osztályoznak) alacsonyabb számú osztályokra [213].

A multitemporális, spektrális keverést több esetben alkalmazták már felszínborítás kiértékelésére [214], [215]. Ebben az esetben az idősor képeit egymáshoz regisztrálják, majd az összeillesztett, magasabb dimenziós számú felvételen történik a szétkeverés. Több felszínborítási kategóriához készült multitemporális spektrális adatbank, aminek segítségével hatékonyan el lehet végezni a térképezést [216]. A hiperspektrális felvételeken túl a multispektrális Landsat TM adatai szintén alkalmasak a változás észlelésére spektrális szétkeveréssel [217].

A spektrális szétkeverés történhet lineáris és nem lineáris módszerekkel. Lineáris esetben a felszínborításokat homogénnek feltételezzük és a pixel alatti területfoglalásukkal lehet jellemezni az egyes kategóriákat. Nemlineáris esetben a modell figyelembe veszi, hogy a felszínborítás típusok bizonyos méretarány alatt nem tekinthetők homogénnek, így a rajtuk megjelenő spektrum is több anyagról, felület típusról érkezik. A különböző felszínborítások különböző energiával sugározzák a szenzor felé a fényt, így a nem lineáris modellek ezt is figyelembe tudják venni. A gépi tanulási módszerek fejlődésével a nem lineáris szétkeverés alkalmazásai is egyre növekednek [218].

Lineáris módszer esetén a modell azt feltételezi, hogy a mintaspektrumok keverékéből és a maradék hibából áll össze a kevert pixel spektruma (10). A modell n darab egyenletből álló össze, ahol n a távérzékelte felvétel sávjainak a száma. Az ismeretlenek az egyenletekben a mintaspektrumok hányadosai. Fontos, hogy kevesebb ismeretlen legyen, mint az egyenletek száma, ezért a sávszámot meghaladó osztály számok alkalmazása nem ajánlott.

$$R_k = \sum_i^n a_i \cdot E_{i,k} + \varepsilon_k \quad RMSE = \sqrt{\frac{(\sum_k^m \varepsilon_k^2)}{m}} \quad (10)$$

R_k : Reflektancia érték k sáv egy pixelén

$E_{k,i}$: Az i minta spektrum reflektancia értéke k sávon

a_i : Az i minta spektrum részaránya a pixelen

ε_k : Zaj értéke a k sávon

RMSE: ε_k négyzetes hibája

n : Mintaspektrumok száma

m : A sávok száma a diszkrét spektrumban

Az esettanulmányban alkalmazott lineáris spektrális szétkeverés a legkisebb négyzetek módszerével történt. A teljesen kényszerített megoldás során a pixelben előforduló spektrumok arányának összege maximum 1 lehet és nem lehet negatív. Ezt az algoritmus a nem negatív legkisebb négyzetek módszerével (NNLS) éri el, iteratív módon. Az algoritmus megtalálható több nyílt forráskódú szoftverben [219], [220].

4.2.2 Gépi tanulási módszerek

A gépi tanulás (Machine Learning, ML) a mesterséges intelligencia egy típusa, ami az adatosztályozás területén belül a számítógép képes tanulni és a tanult modell alapján mintákat felismerni és kategorizálni [221]. A gépi tanulás olyan algoritmusokra épül, amelyek a bemeneti tanító adatok alapján statisztikai analízist végeznek a tesztelt adatokon. A modern gépi tanulási módszerek kutatásnak kezdete egybe esett az első digitális elektronikus számítógépek megjelenésével az 1950-es években [165]. A 1990-es években kapott egy újabb és nagyobb lendületet a terület kutatása, amikor a korábbi mély szakmai ismeretet igénylő klasszikus módszerek mellett megjelentek az adatokhoz legjobban megfelelő modellt kereső (data-driven) módszerek, melyek nem feltétlenül igényelnek átfogó tudást az osztályozásához az operátortól. A 2010-es évek elején újabb mérföldkőhöz érkezett a tudomány, amikor a Deep Learning-módszer már megvalósíthatóvá vált, és a gépi tanulás széles körben elterjedt a szolgáltatásokban és szoftveres alkalmazásokban, mint például a digitális tartalmak szűrése, osztályozása. A 21. század egyik legkeresettebb szakmája lett az adattudós [222], aki munkája során a gépi tanulás eszközeit alkalmazza a osztályozási problémák megoldására.

4.2.2.1 K-means

A nem felügyelt osztályozási módszerek közül az egyik leggyakrabban alkalmazott eljárás a K-means (K-közép) klaszterezés, melyet több, mint 50 éve alkalmaznak különböző feladatokra [223]. A klaszterezés célja az adatokban lévő természetes csoportosulások kimutatása. A Webster (<https://www.merriam-webster.com/>, 2019.12.31.) definíciója szerint a klaszter analízis egy „statisztikai osztályozási módszer a populáció egyes elemeinek osztályokba sorolásához, több jellemző alapján történő kvantitatív összehasonlítással”. Az egyes adatok osztályba sorolása hasonlósági mutatók alapján történik, ami távérzékelte reflektancia termékeknél gyakran az intenzitás térben mért euklideszi távolság a pixelérték és az osztály átlaga közötti távolság. Az adatokban lévő zaj a klaszterek definiálását nehezíti. A végleges osztályozás iteratív folyamat során alakul ki. Az ideális klaszter kompakt alakú és teljesen elkülönül más osztályoktól. A valós környezetről alkotott képeken a klaszterek között gyakran magas átfedés tapasztalható. Az klasztereket az osztályközépen kívül a sűrűségükkel és alakjukkal is lehet jellemezni. Az ember vizuális interpretáció során nagyon jól el tudja különíteni a klasztereket 3 dimenziós mélységig, de a távérzékelte adatoknál előforduló nagyon magas dimenziószámok estén már a klaszterezéssel hatékonyabb osztályozást lehet végezni[223], [224].

A klaszterezésnél a kezdeti osztályok számának, méretének és elhelyezkedésének nagyon nagy jelentősége van. Az esettanulmányokban centroid alapú K-means modellt alkalmaztam, ahol a kezdeti osztályok az intenzitás tér k darabszámú egyenlő rész középpontjába esett.

4.2.2.2 Random forest

A Random Forest (RF) típusú osztályozó a felügyelt módszerek közé tartozik, melyet először 1995-ben dolgoztak ki az AT&T Bell Labs-nél [225]. Az RF modell döntési fák kombinációjából áll, melyek a tanító adatok és azoknak egyes dimenzióinak véletlenszerű mintavételezése alapján állt fel [226]. Az egyes döntési fák eredményei alapján készül el a bejövő adat osztályozása. A döntési fának a száma fontos paraméter lehet távérzékelt adatok osztályozásánál.


A döntési fák tanításához a megfelelő jellemzőket kell kivonni a tanító adatokból, amihez számos megoldás létezik. Az esettanulmányokban alkalmazott módszer [113] véletlenszerűen választott képjellemzők és ezek kombinációit használja fel a tanítás során. Az alkalmazott eljárásban úgynevezett Bagging módszerrel [227] történt mesterséges adatkiterjesztés a tanító adatokon, hogy az információ tartalom megtartása mellett növelje az adathalmaz változatosságát. A döntési fák tanításához használt képjellemzők a Gini Index [228] alapján kerülnek kiválasztásra. Ez a mutató az egyes képjellemzők tisztaságát tudja kimutatni, ami az információ tartalmára utal. Az egymással szorosan korreláló képjellemzők ebben a lépésben kikerülnek az osztályozó modellből, hogy a jobb elkülönülést mutató jellemző alapján történjen meg az osztályozás. Az egyes döntési fák a tanítás során különböző képjellemzőkből és azoknak a kombinációiból épülhetnek fel, így az egyes fák különböző jellegzetességeket képesek kiemelni az osztályozáshoz. A tanított döntési fák úgynevezett „nyesése” nem szükséges, melyet hagyományos esetben alkalmazni szoktak. A „nyesés” során a döntési fa egyes ágait az osztályozó figyelmen kívül hagyja, ezzel az adatban lévő zajra illesztés lehetőségét csökkentené, amit a RF módszer a véletlen szelekcióval és a mesterséges adatkiterjesztéssel helyettesít. Több döntési fa bevezetésével tovább növelhető az osztályozás stabilitása a képelemen. Bizonyos számú döntési fa fellett a hiba értéke 0-hoz konvergál, így több fa bevezetése csak a számítási igényt növeli, a pontosságot nem [229].

Az esettanulmányokban a Ranger [113] implementációját használtam az RF osztályozónak C++ interfészen keresztül. Az esettanulmányokban a modellek paraméterezése azonos volt. A döntési fák száma 1000-re lett állítva, a többi paramétere a programban kiadott alapértékeken maradt.

4.2.2.3 Deep Learning - Konvolúciós neurális hálózatok

A mesterséges neurális hálózatok (neural networks) az idegrendszerrel rendelkező élőlényekben található érzékelő és jeltovábbító idegsejtek működése és kapcsolódásai alapján inspirált rendszerek. Az élő szervezetben az érzékelt inger, idegsejtek kapcsolódásain keresztül jut el a felismerésig. A tanulás során befogadott információk az idegsejtek új kapcsolatai alapján rögzülnek a központi idegrendszerben [230]. A mesterséges neurális hálózatok esetén az idegsejtek funkcióját a mesterséges jelfeldolgozó egységek végzik, melyeket a korai alkalmazásaiban perceptronnak neveztek [231]. Ezek az egységek különböző bemeneteket kapnak, akár közvetlenül az adatból vagy a hálózatban hozzá kapcsolt neuronoktól, melyeket előre megadott funkciók alapján transzformálnak és egy darab kimenetet generálnak. Kezdetben bináris kimenetek képzésére alkalmas algoritmusokat használtak a bemenő adatok súlyozásával, melyek küszöbértékek alapján hozták létre kimenetüket. Idővel megjelentek a rugalmas (fuzzy) döntéshozatalra [232] is képes neuronok a hálózatokban. A neuronok hálózatot alkotnak, ahol a kapcsolatok nem lineárisak. A hálózatot rétegekre lehet bontani. A hálózatban a bemenetek és a kimenetek külön réteget alkotnak. A két réteg között elhelyezkedő rétegeket rejtett rétegeknek nevezik. Kezdetben - az 1960-as években - sekély hálózatokat alkalmaztak, melyekben csak néhány réteg volt [233]. A mélyebb hálózatokat is ezekben az időkben kezdték el tervezni, azonban a számítástechnika még nem volt olyan szinten, hogy alkalmazni lehetett volna őket, így csak az 1980-as évek végén jelentek meg az első mélyebb hálózatok, ahol már több rejtett réteg is jelen volt.

A Deep Learning alatt olyan neurális hálózatot értünk, melyben legalább két rejtett réteg található (23. ábra). A tanító adatok részletes jellemzőit a hálózat önmagának ismeri fel tanítása során, így nem szükséges különösebb meta információkkal ellátni a tanító adathalmazt. Ez különbözteti meg a hagyományosabb gépi tanulási módszerektől, ahol nagyon részletes háttér tudást igényeltek a különböző osztályozási módszerek [231].



23. ábra: Deep Learning típusú mély mesterséges neurális hálózat 4 rejtett réteggel

A nagyon mély neurális hálózatok előnye a hagyományos osztályozó módszerekkel szemben, hogy nincs szükség a képjellemzők mesterséges kiemelésére és a nem releváns információt tartalmazó jellemzők eltávolítására az osztályozó modell tanítása előtt. A modellben a bemenő képjellemzők a bemeneti rétegbe csatlakoznak, amit rejtett neuron rétegek követnek, majd egy kimeneti réteg, ahol minden rétegben minden egyes neuron össze van kötve egymással. A tanítás során ezeknek a kapcsolatoknak az erősségét állítja be a modell a betáplált tanító adatok alapján iteratíván egy optimalizáló funkció segítségével, visszacsatolásokon keresztül.

A konvolúciós neurális hálózatok (convolutional neural networks, CNN) a leggyakrabban alkalmazott mély neurális hálózat modellek az általános képfeldolgozásban. A távérzékelésben 2014 óta alkalmazzák [231]. Ezzel a módszerrel a képen megjelenő alacsony és magas szintű jellegzetességek, valamint a rögzített spektrum alapján történik az osztályozás. A konvolúciós (ablakos) szűrők sorozatai által kivont képjellegzetességek az objektumok fontosabb alak jellemzőit képesek megtanulni, így a pixelek topológiáját is figyelembe tudják venni, ami textúrákat alkothat.

A CNN hálózatoknak általában három fő építő eleme van: a konvolúciós, az összegző (Pooling) és a teljesen összekapcsolt (Fully connected) rétegek [234]. A különböző architektúrák többnyire ezekből az alkalmazásnak megfelelő méretű rétegekből épülnek fel. Ayrey és Hayes munkája alapján a leggyakrabban előforduló rétegtípusok a CNN modellekben [235]:

- **Konvolúciós réteg:** Olyan rétegek, melyeken konvolúciós szűrők sorozata halad végig az adatokon, melyeknek térbeli vagy időbeli kapcsolata van. Az konvolúciós szűrő ablakának értékei szolgálnak súlyozásra a neuronokban, melyek kezdetben véletlenszerű értékkel vannak inicializálva, majd a tanulás folyamata során nyerik el végleges értékeiket. Az képi jellemzők kiemelésére alkalmas szűrők, melyek a tanulás során jellemzőn az irányok kimutatására alkalmas formákat vesznek fel.
- **Dropout réteg:** A konvolúciós rétegeket követően találhatók meg a dropout rétegek. A rétegben véletlenszerűen távolítanak el kapcsolatokat a hálózathoz, hasonlóan a Random Forest osztályozóhoz [236], hogy a modell túlillesztését a zajos adatokra meggátolják a tanítás során.
- **Batch normalization:** A konvolúciós rétegekből származó adatok standardizálása történik ebben a rétegben. A modell túlillesztését segít elkerülni, a réteg kimenetének kovarianciájának eloszlásához transzformálja a következő réteg bementi adatainak az eloszlását [237].
- **Pooling rétegek:** Térbeli összegző rétegek, melyekbe a kép lefelé történő mintavételezése történik. Elsősorban az adat dimenzióinak csökkentésére és az információ kondenzálására szolgálnak. A Maximum Pooling (max-pooling) a leggyakoribb típusa, ami a konvolúciós ablakban szereplő legmagasabb értéket rögzíti.

- **Fully connected réteg:** Ez a rétegtípus a CNN hálózat legvégső rétegeiben található. Mérete általában $1 \times 1 \times n$ pixel, ahol n a tanító adatban lévő osztályok száma. Ahogy a neve is utal rá, az előtte lévő rétegből minden egyes neuronnal kapcsolatban áll. Itt történik meg a végső osztályozás a megadott osztályozó funkcióval [238].

Az esettanulmányokban az osztályozáshoz a Tensorflow 1.4. (Google, Mountain View, CA) keretrendszert használtam a CNN modellek tanításához és osztályozásához Python és C++ interfészen keresztül.

5 Esettanulmányok


Az alábbi fejezetben az egyes esettanulmányokat mutatom be. A részletes munkafolyamat leírásokat melyek a bemutatott anyagokból és módszerekből épülnek föl az eredmények és ezeknek megvitatása, következtetései követik.

5.1 Kiértékelhető Sentinel-2 űrfelvételek vizsgálata a magyarországi erdőállományokra

Az esettanulmány célja a Sentinel-2 műholdprogram egy műholdja (S-2A) által készített képanyag kiértékelhetőségének vizsgálata volt a magyarországi erdőállományokra. Az OEA poligonok a Sen2Cor által létrehozott felhőmaszkok alapján végeztem a vizsgálatot, és az eredményeket egy adatbázisba foglaltam.

5.1.1 Módszertan

A kiértékelhető területek meghatározása felhőmaszkok alapján történt az OEA erdőrézlet poligonjai által fedett területeken (24. ábra). A kiértékelt erdőrézlet poligonok adatai később egy adatbázisba kerültek, amiből kimutatásokat lehetett készíteni.



24. ábra: Az erdőállomány kiértékelésének munkafolyamata

5.1.1.1 A felhőmaszkok kiértékelésének módszertana

A pontosabb felhő- és felhőárnyék maszkok az űrfelvételek atmoszférikus korrekciója után készül el. Az űrfelvételek ilyen típusú előfeldolgozását a Sen2Cor 2.3.1. szoftverrel végeztem el. Az L1C feldolgozottsági szintű, légkör tetején mért reflektancia (TOA) értékekkel rendelkező S-2A felvételekből L2A típusú, a légkör alján mért (BOA) reflektancia termékeket készítettem 20 méteres felbontással. A feldolgozás során létrejött automatikus felszínosztályozás tartalmazta a felhő, hó, víz, vegetáció és nyers talaj felszínborításokat. Ezt a réteget használtam fel a minden egyes felvételnél.

A felhőmaszkok kiértékeléséhez saját programot fejlesztettem, amely képes volt a HPC környezetben kiértékelni a felszínosztályozás térképeket. Ehhez szükség volt a képek beolvasására a memóriába, a vektoros erdőrésztlet poligonok raszterizálására és a létrehozott raszteres régióra képstatisztikák számítására. Az egyes részletekhez tartozó kép-régióban a program lekérdezte a felszínosztályozás hisztogramját. Amennyiben a hisztogramban 0-nál nagyobb gyakorisággal szerepelt egy olyan felszínborítási osztály, ami nem vegetáció vagy talajfelszín, akkor azt nem kiértékelhető részletnek jelöltem meg. A szigorú feltétel oka a kevert pixelekből ered, amelyek egyszerre több felszínborítást takarnak. Ha egy jól osztályozott, nem kívánt felszínborítás kategóriába tartozó pixel jelen van a régióban, akkor feltételezhetően a környezetében kevert pixelek is találhatók. Ennek a jelenségnek az oka arra vezethető vissza, hogy az űrfelvételen szabályos rácshálóban képződnek le az objektumok, míg a valóságban nem szabályos a kiterjedésük. Így elkerülhetetlen a különböző objektumok reflektanciájának keveredése a felhasznált terepi felbontásokon. Amennyiben az adott felvétel használhatónak lett megítélve az erdőrésztletre, akkor az űrfelvételhez tartozó adattáblába ez rögzítésre került. Az űrfelvétel azonosító adatai és kiválasztott metaadatai egy külön adattáblába kerültek.

5.1.1.2 Az űrfelvétel elérhetőség adatbázis létrehozása

Az erdőrésztletekhez tartozó érvényes felvétel-azonosítókat és a felvételek részletes adatait egy adatbázisba rendeztem (25. ábra, 26. ábra). Az erdőrésztletekhez a faállományok adatait is csatoltam, így a vizsgálatokba ezeket az attribútumokat be lehetett vonni. A kiértékelő programban lehetőség van szűréseket megadni időre, területre, egyéb attribútumra. Az esettanulmányhoz a TopoXmap (TopoLynx Kft., Kőszeg) térinformatikai szoftvert használtam az adatbázis kezelésére.



25. ábra: Az egyes erdőrésztletekhez tartozó felhőmentes dátumokat tartalmazó adatbázis modell



26. ábra: Az egyes erdőrésztletekhez tartozó összesítő adatbázis modell


Az adatbázis bemutatása három példán keresztül történik az eredmények fejezetben. Létrehoztam egy olyan térképet, amely megmutatja az összes kiértékelhető felvétel számát erdőrészekként 2015 júniusa és 2017 októbere között. A második példa 6 darab, Nagymaros község határban található, szomszédos erdőrészekre mutatja meg az elérhető felvételek eloszlását a vegetációs időszakban (Day Of Year (DOY): 70-300). A harmadik példában az OEA faállomány-típusra vonatkozó attribútumai alapján csoportokat hoztam létre, majd csoportonként, havi bontásban ábrázolom a kiértékelhető képeken található erdőrészek számának összegét. A következő faállomány-típus csoportok lettek kiértékelve: bükkös, akácos, gyertyános-tölgyes és erdeifenyves. Ezek a csoportok vagy különböző vertikális elterjedésűek, vagy különböző levélszerkezettel rendelkeznek. A különbségek alapján és az elérhető felvételek száma alapján következtetni lehet arra, hogy az adott régiókban milyen sűrűséggel érhetők el kiértékelhető felvételek.

5.1.2 Eredmények és az eredmények értékelése

5.1.2.1 Az adatbázis és a térkép értékelése


Az adatbázis készítéséhez összesen 2888 darab L1C típusú S-2A felvételt dolgoztam fel. Az előfeldolgozás és a kiértékelése 6950 processzor órát vett igénybe az EODC GmbH által nyújtott klaszterszámítógépen, ami 3 nap alatt futott le.

Az országos erdőállományra készített összegzett térkép (27. ábra) jól mutatja, hogy az ország közepén van átfedés két műholdpálya között, így ott több kiértékelhető felvétel található. Az ország nyugati felében magasabb lehet a felhőborítás, ugyanis kevesebb kiértékelhető felvétel készült, mint keleten. A középhegységekben a magasabb régiókban ugyancsak kevesebb kiértékelhető felvételt találtam. Ennek az oka a topográfiai árnyalásból származó árnyékok. Ezeket a képrészeket alacsony szindinamikájuk miatt felhőárnyéknak osztályozza a Sen2Cor felhődetektáló algoritmus. Gyakran előfordul, hogy az osztályozó algoritmus összekeveri a víz-árnyék, valamint a felhő-hó kategóriákat. Az erdők kiértékelhetőségének szempontjából ezek kevésbé lényegesek. Az ártéri erdőknél az alkalmazott módszerrel nem lehetett megbízható adatokat kinyerni az erdőreszlet határán belül, akár részben megjelenő víz borította pixelek miatt. Azokon a területeken, ahol jellemzően keskeny mezővédő erdősávok vannak, az alkalmazott módszer nem adott értékelhető eredményt a szigorú vizsgálati kritériumok miatt. A térképről leolvasható, hogy a felhasznált képanyagon, ami csak egy műhold adatait tartalmazta, nem biztosított havonta elérhető megfigyelést erdőrészekként országos szinten.



27. ábra: Az egyes erdőrészekre elérhető összes kiértékelhető megfigyelések száma 2015-2017 között


A kiválasztott egyes részleteknél megfigyelhető (28. ábra) az, hogy kis területen is milyen változatos tud lenni a kiértékelhető felvételek eloszlása a vegetációs időszakon belül. A kiválasztott területen 10 napnál gyakrabban készülnek felvételek, ugyanis két műholdpásztja átfedésébe esik, de a felhőborítás miatt csak ritkábban vannak érvényes megfigyelések. Egyes időszakokban, mint júniusban és szeptemberben sűrűbben fordulnak elő felhőmentes megfigyelések.




28. ábra: Nagymaros községhatárban kiválasztott 6 db szomszédos erdőrészeletről elérhető felhő- és felhőárnyék mentes felvétel eloszlása 2015-2017 között a vegetációs időszakokban

5.1.2.2 A kiválasztott faállomány-típus főcsoportok értékelése

A faállománytípus-csoportokba sorolt részletek gyakorisági eloszlása további érdekes jellemzőket mutat meg. A kiválasztott bükk, akác, gyertyános-tölgyes és erdei fenyő állományok előfordulási területei jellemzően elkülönülnek, habár előfordulnak azonos területeken is (29. ábra). A csoportok területfoglalása is különböző, azonban a karakterük leolvasható a hisztogramokról. A négy kiválasztott csoportnál azonos, hogy a nyár közepére és végére esik a legtöbb kiértékelhető felvétel (30. ábra). Szeptemberben még igen sok kiértékelhető felvétel van, ami októbertől kezdve nagymértékben lecsökken. Az év elején igen kevés kiértékelhető erdőrészlet tartozik a kategóriákhoz. Ezt az okozhatja, hogy a lombmentes állományokat a vegetációs időszakon kívül az alacsony dinamika és a megjelenő törzsárnyékok miatt gyakran a felhőárnyék kategóriájába sorolja az osztályozó algoritmus. Kivételt a fenyők jelentik, mert a télen is fent maradó lombjuk miatt továbbra is vegetációnak osztályozza az algoritmus ezeket a területeket. A tavaszi lombfakadás időszakából igen kevés felvétel értékelhető ki, ami korlátozza a valódi, teljes vegetációs időszakot átfogó interannuális idősorok létrehozását.



29. ábra: A kialakított faállomány-típus csoportok elhelyezkedése az országban



30. ábra: A kiértékelhető erdőrészletek darabszámainak gyakorisági eloszlása (bükk, akác, gyertyános-tölgyes és erdeifenyő) az egyes hónapokban a 2015-2017 közötti időszakból

5.1.3 Következtetések


A létrehozott módszertannal egy hosszútávon alkalmazható eljárást hoztam létre, aminek rendszeres alkalmazásával folyamatosan bővíteni lehet az idősor elérhetőség adatbázisát. Ez megkönnyíti az űrfelvételek alapján történő idősoros faállomány-típus térképezést, a fahasználatok térbeli lehatárolását és a vegetáció-aktivitás monitorozását a kutatásokban. Az automatikus feldolgozás során azok az erdőrésztetek nem értékelhetők ki, amelyeknek alakja elnyúlt és átmérőjük nem éri el a 20-30 métert. Az ilyen erdőrésztetek elérhetőségének a vizsgálata a közeli környezete alapján végezhető el. Azokon a területeken, ahol jellemzően mezőgazdasági területek közé beszúrt keskeny résztetek találhatók (pl. alföldek), ott nincs lehetőség az erdőtömb más részletét alapul venni, így alkalmazási lehetősége igen korlátozott. A folyamatosan domborzati árnyalás alatt álló területek sem értékelhetők ki a felvételek alacsony szín dinamikája miatt. A módszertan részben víz borította területek kiértékelésére korlátozottan alkalmazható a Sen2Cor alapú felhőmaszk korlátjai miatt. A kiválasztott mintákon megfigyelhető, hogy nyáron van a legtöbb kiértékelhető felvétel, míg a lombfakadás időpontjában viszonylag kevés érhető el. A már pályán lévő S-2B műholddal kiegészülve, 2018-tól kezdve még sűrűbb idősorok állnak rendelkezésre, amelyek segítségével pontosabb faállomány-paramétereket tudunk majd meghatározni távérzékeléssel. A Sen2Cor felhőmaszkjai a tapasztalatok alapján nem megbízhatóak teljesen automatizált lokális szintű űrfelvétel kiértékelésen alapuló térképezéshez. A jelenlegi módszertana a vizsgálatoknak nagyobb léptékű, például erdőtervezési körzet szintű kiértékeléshez nyújt megbízható információkat. Lokális szintű információk kinyeréséhez erdőrésztet szinten multitemporális felhőmaszk alkalmazásával lehetne alkalmas.

5.2 Lécek detektálása Sentinel-2 űrfelvételeken a Börzsöny hegységben

Az esettanulmány célja a lécek területkimutatása és térképezése volt Sentinel-2 űrfelvételek idősorán. Három különböző előfeldolgozottsági szinten vizsgáltam a Sentinel-2 felvételek alkalmazhatóságát erre a célra. A különböző adattípusok vizsgálata azon a feltételezésen alapult, hogy az előfeldolgozás nagy befolyással lehet a kimutatott területek méretére. A tölgyes mintaterületeken összesen 9, a bükkös mintaterületen 6 felvételt értékeltem ki, amelyet a felhőborítottság befolyásolt.

5.2.1 Módszertan

A lécek detektálásához egy komplex munkafolyamatot fejlesztettem (31. ábra), amely az árnyékok modellezéséből, spektrális szétkeverésből és az osztályozás utáni összehasonlításból és terület kiértékelésből áll. Szintetikus lék modellezés segítségével lehetett a kiértékeléshez szükséges küszöbértékeket meghatározni.



31. ábra: A lécek detektálásának munkafolyamata

5.2.1.1 Előfeldolgozottsági szint vizsgálata

A kutatás másik célja, a lécek területének kimutatása mellett az S-2 felvételek előfeldolgozottsági szintjeinek a vizsgálata volt. Az atmoszférikus korrekción átesett felvételeken vizuális vizsgálat alapján eltérő mértékű lék volt látható, mint az atmoszféra tetején rögzített reflektancia terméken. A domborzati korrekció tovább befolyásolta a lécek megjelenését a képeken. Ezeknek a hatásoknak a vizsgálatához mind a három adattípuson elvégeztem a kiértékelést: atmoszféra tetején mért reflektancia (L1C), felszíni reflektancia (L2A) és a topográfiai korrekción átesett felszíni reflektancia (L2ADEM).

5.2.1.2 Árnyék modellezés

Nagyobb méretarányú térképezésnél a gyakran alkalmazott topográfiai normalizációs módszerek [34], [101] megfelelnek, de helyi szintű térképezésnél nagy felbontású űrfelvételeken bizonytalan lehet a pontosságuk, például a pontatlan domborzatmodell vagy a nem megfelelő paraméterezésük miatt. Ebből kifolyólag, nagyon kis méretarányú térképezésnél nem lehet teljes mértékben a normalizációs eljárás eredményére támaszkodni.

A különböző megvilágítottsági állapottal rendelkező felületeket elkülönítettem a vizsgált területen és a megvilágítottsági szintjüknek megfelelően kezeltem a továbbiakban. Az árnyékok modellezése a 2 m felbontású DSM-en történt. Az árnyalás modellezése az IC módszerrel történt, ami az ember számára is elfogadható árnyalási modellt ad. Míg a vetített árnyékok számítása [206] egy globális funkció, amely a teljes képet igényli a számításhoz, az árnyalás modellezése fokális 3x3 pixel méretű ablakkal készült el, az űrfelvétel metaadataiban található Nap pozíciók alapján. Az ablak mérete 6x6 métert fedett le a területen. Ez a felbontás túl finom az S-2 10 m-es mintavételezéséhez, így az árnyék modellt 10, 20 és 50 m felbontásra mintavételeztem tovább, átlag értékes módszerrel. Az árnyalás minden egyes felbontásra elkészült az IC módszerrel.

A különböző megvilágítottsági állapotok elkülönítése az árnyékmodellen K-means klaszterezéssel [223] történt. Az 50 m-es felbontású megvilágítási modell három klaszterre lett szétbontva minden egyes felvételnél. Az osztályok számának meghatározása empirikusan történt, hogy lefedje a következő kategóriákat:

- Megvilágított;
- Részben megvilágított;
- Árnyalt.

A kategóriák határait nem lehet élesen definiálni. A kategóriák mértéke változik minden egyes időpontban a domborzat és a Nap pozíciójának függvényében. A tematikus megvilágítás térkép a 10 m felbontású megvilágítás modell alapján készült el. Az egyes pixelek a legközelebbi klaszter középponthoz lettek rendelve. A klaszterezés azért az 50 m felbontású modellen történt, mert az már simítva tartalmazza a megvilágítás értékeit, ami az osztályozás túlillesztését segít kizárni a zajosabb klaszterek elkerülésével.

5.2.1.3 Spektrális szétkeverés

A faállományok átlagos magassága 25 méter körül van a vizsgált mintaterületeken. A lécek átmérője megközelítőleg 20 méter. A műhold áthaladásának az ideje a terület fölött délelőtt (9:50 GMT) van. Ilyenkor a síkon vagy északi kitettségben lévő lécekben vetített árnyék látható az alacsonyabb Nap állás miatt. A környező fák által vetett árnyék jelentős reflektancia csökkenést okoz elsősorban a NIR tartományban a rögzített képen. Az arány alapú vegetációs indexek [239] ezt a különbséget képesek elsimítani, amennyiben a reflektancia csökkenés közel lineárisan történik minden érintett sávon. Ebből kifolyólag a lécek árnyék alapú kimutatására az arány alapú vegetációs indexek kevésbé alkalmasak.

A délies kitettségben lévő léceknek ellentét az arány alapú vegetációs indexek (32. ábra). Itt több közvetlen napfény jut a lék alá, ahol a gazdag aljnövényzet és az újulat reflektanciájának keveréke rögzül a képeken.


Ebben az esetben a lék NIR reflektanciája jelentősen magasabb, mint a környező faállományé. Ez a jelenség elsősorban bükkös erdőtípusokban következik be, ahol – a jégtörések miatt – jellemzően nagyobb méretű lékek vannak.

Ezek alapján tölgyes típusú erdőkre a következő spektrális minták meghatározása történt:

- Erdő minta;
- Árnyalt lék minta.

Bükkös típusú erdőkben a következő spektrális minták meghatározása történt:

- Erdő minta;
- Árnyalt lék minta;
- Megvilágított lék minta.



32. ábra: Mesterséges lékekkel szabdalts azonos paraméterű stilizált faállományok különböző lejtésű és kitettségű erdőterületeken azonos megvilágítási és betekintési szögek mellett, melyek a létrehozott minta kategóriákat támasztják alá.

5.2.1.4 Spektrális minták gyűjtése

A spektrális szétkeverés az egyes S-2 felvételeken történt meg. A szétkeveréshez szükséges spektrális minták az aktuális képről lettek gyűjtve előre meghatározott pozíciókból. A gyűjtési pozíciók és a típusaik meghatározása vizuális interpretációval történt. A pozíciók gyűjtés a 2016. augusztus 28-án (DOY: 260) készült teljesen felhőmentes felvétel alapján történt. A gyűjtött, feltételezhetően a minta típusának tiszta spektrumát tartalmazó pixel földrajzi pozícióját rögzítettem. Az S-2 felvételen az alkalmazott sávokon a különböző lombos faállomány-típusok nem mutatnak jelentős eltérést, ezért a záródott erdőt mutató minták különböző típusokat fednek. A mintavételezés kiterjedt a teljes Börzsöny hegység területére.

Az egyes képeknél az alkalmazható pozíciók a Sen2Cor feldolgozásból származó felhőmaszk segítségével lettek meghatározva. A felhőmaszkon kívül további szűrés történt a kék sáv (B2) alapján, a LandTrendr szoftverhez hasonlóan. Kennedy és mtsai. a Landsat TM kék sávját alkalmazta a további szűréshez [120], aminek a tartománya átfed az S-2 B1 tartományával. Egy fix küszöbérték alapján történt a további szűrés 1000-es pixelérték felett (reflektancia > 0.1), ami az erdők fölött hisztogram vizsgálata alapján lett meghatározva.

A spektrális minta az egyes borítás típusoknál mind a három megvilágítási állapothoz meghatározásra került. A mintavételi pozíciók megvilágítás szerinti osztályozása az 50 m felbontású modell klaszterei alapján történt. A mintapozíciókon lévő pixelek átlaga adta a spektrális mintát, amit a szétkeverésnél

alkalmaztam. Az egyes kategóriák szórása alapján lehetett következtetni az osztályok számának helyességére.

5.2.1.5 Szétkevert képek mozaikolása

A spektrális szétkeverés az egyes megvilágítási kategóriáknál külön-külön történt meg, így hat szétkevert kép tartozott egy S-2 felvételhez: minden megvilágítási kategóriához két szétkevert kép. A bükkös típusú mintaterületen a három borítás típus úgy lett összevonva két fő típusba, hogy összevethető lehessen a tölgyes típusokkal.

Az egyes megvilágítási kategóriákhoz tartozó erdő és lék előfordulás valószínűség értékek a 20 m felbontású megvilágítási modell alapján egy képbe mozaikoltam. Ennek a 3 sávos képnek a következő tartalma volt:

- Sáv 1: Erdő előfordulás valószínűsége;
- Sáv 2: Lék előfordulás valószínűsége;
- Sáv 3: Megvilágítási kategória.


Az első és második sávok összege az eredmény képen mindig 1.0-t kell kiadjon az alkalmazott spektrális szétkeverő eljárásnak köszönhetően. A terület kimutatások az első sávban tárolt előfordulási valószínűségek alapján lettek kiszámítva.

5.2.1.6 Szintetikus lékek modellezése

A lék előfordulási valószínűség képen meg kellett határozni egy küszöbértéket, ami felett valóban léknek lehet feltételezni a pixel spektrumát, nem csak a koronafelületen megjelenő árnyalások keverékének. Ez a küszöbérték minden egyes időponthoz szintetikus lék modellezés segítségével készült el, ahol az ismert spektrális minták alapján egy felszínmodellre lettek „visszakeverve” a pixelek (33. ábra).

Az ALS alapú felszínmodellen meg kellett határoznom a lékek pontos kiterjedését. Ehhez egy DSM készült az OPALS szoftver DSM moduljával [240]. A modell 0.5 m felbontással jött létre a területről készült ALS felvételből. A DSM-en jól megfigyelhetők voltak a lékeknek a peremei a koronaszinten az alkalmazott interpolációs módszernek köszönhetően. A területre elkészítettem a digitális domborzat modellt (DTM), ami a minimum pontokból lett interpolálva. A felszín és a domborzat modell különbségeként a normalizált felszínmodellt kaptam meg (nDSM), amelyen létrehoztam a lék és erdő térképet vertikális küszöbértékes (2.0 m) szűréssel.

Összesen 6 darab lék került digitalizálásra, melyek mind a részben megvilágított kategóriába estek a megvilágítási modelleken. A lékek közül háromban magfa volt, így ezeknek a hatását is lehetett vizsgálni. A felület árnyalását a Nap pozíció adatai alapján modelleztem a felületen. A nagyon nagy felbontású DSM modellen láthatósági vizsgálat segítségével számítottam ki a vetített árnyék modellt, amin így a koronafelszín egyenetlenségei mellett a lékben lévő vetített árnyékok is megjelentek. Az adott képhez gyűjtött spektrális mintákból hoztam létre a szintetikus S-2 felvételt a tematikus lék és erdő térkép alapján, 0.5 m felbontásban. A kép tartalmazta a fiatal, megvilágított erdő mintákat a lék alján, vetített árnyék mintát a lék alján és az idős erdő mintáját a koronaszinten. Ez a kép lett 10 m felbontásra mintavételezve átlagolással, mind a négy felhasznált sávra. Ebből a lineáris keveréssel készült modellen újra végrehajtottam a spektrális szétkeverést azonos mintákkal, ami a létrehozásához lett felhasználva. A digitalizált léken belül elhelyezkedő pixelek lék aránya a szétkevert eredményben megadta a küszöbértéket, amin felül lékes árnyalásnak, nem koronafelületen megjelenő árnyalásnak lehet figyelembe venni. A kiválasztott 6 lékből manuálisan lettek meghatározva azok a pixel pozíciók, amelyből a maximum lékarány küszöbértéke meghatározásra került. A modellezés az L2ADEM típusú mintákkal történt.



33. ábra: Az egyes űrfelvételekhez tartozó szűrési küszöbértékek meghatározásának munkafolyamata

A modellezés a küszöbérték meghatározásán túl alkalmas volt arra is, hogy a referencia lék területhez képest a modellen mekkora területet lehet kimutatni. Ebből következtetni lehet később korrekciós együtthatókra a területkimutatásnál.

5.2.1.7 Terület kimutatás

5.2.1.7.1 Egyes felvételek kiértékelése

Minden egyes megvilágítási állapot alapján mozaikolt kép tartalmazta a lék valószínűség értékét, amit a pixelen belüli területfoglalásával tekintek egyenlőnek. Mivel az erdőben nem csak a lékekben vannak árnyalt részek, szűrni kell egy bizonyos küszöbérték felett a lékek megjelenését a szétkevert eredményen. A szűrés a szintetikus lékek modellezése során került meghatározásra minden egyes időponthoz. Ha a pixelen számolt lék valószínűség alacsonyabb volt, mint a küszöbérték, akkor 0 értékkel szerepelt a továbbiakban. Ha magasabb volt, mint a küszöbérték, akkor a korábbi értéke maradt a továbbiakban. A lék előfordulási valószínűségéből lehetett a területet kimutatni, melyen 100-zal megszorozva m²-ben kaptam meg a lék feltételezett területfoglalását. Az egyes időpontokban a mintaterületen becsült lékterület az egyes pixelekből származó lékterületek összegeként lett meghatározva.

5.2.1.7.2 Idősor összeállítás

A szétkevert eredmények idősor alapú kiértékelése két módszerrel történt meg. Az első esetben az egyes időpontokhoz tartozó összegzett területek leíró statisztikái (átlag, szórás) kerültek összevetésre a referencia terület mérettel. Ez a módszer az erdőgazdálkodáshoz szükséges területkimutatást megadja, de a lékek, mint objektumoknak a térbeli kiterjedését nem adja vissza tematikusan. A lékek pontos számának definiálása a legtöbb esetben objektíven nem lehetséges, mert nem minden lék különíthető el egymástól egyértelműen. A térbeli pontosság vizsgálatához a digitalizált referencia lékekből egy 10 m felbontású, az S-2 felvételekhez regisztrált lék részarány réteget hoztam létre. Ezzel a réteggel korreláltatni lehetett az idősor alapú kimutatás eredményét.

Az idősor alapú kiértékeléshez egy 10 m méretű rácshálót hoztam létre Egységes Országos Vetületben (EOV), amelyhez minden egyes időpontban hozzárendeltem az aktuális lék előfordulás valószínűségét. A rácsháló pontjaihoz a legközelebbi pixel értéke lett hozzárendelve. A szétkevert eredmények Universal Transverse Mercator (UTM) vetületben voltak, ezért 7 paraméteres koordináta transzformációt hajtottam végre rajtuk EOV vetületre [241]. Az egyes időpontok lék valószínűségi értékei [0;1] tartományban helyezkedtek el. Ezeket az értékeket összegeztem a rácsháló pontjaiban, majd a megfigyelések számával elosztottam. A vegetációs időszakon belül, ahonnan a felvételek származtak, azt feltételeztem, hogy nem történt nagyobb változás az erdőborításban. A normalizált értékek a rácspontokban a lék előfordulásának fuzzy valószínűségét mutatják.

Az idősor alapú kimutatás előnye, hogy a koronaszinten megjelenő, év közben mozgó árnyalt területek könnyen kiszűrhetők, melyek biztosan nem mesterséges lékeket fednek. A fuzzy valószínűséghez is meg kellett határozni egy küszöbértéket, melyet empirikusan végeztem el. Ezzel a szűréssel a lékek vizualizációját lehetett segíteni. A későbbi területkimutatásoknál a szűretlen értékek szerepelnek. A különböző évekből származó fuzzy valószínűségek különbségével lékterület változás térképet tudtam létrehozni.

5.2.1.8 A spektrális minták vizsgálata

A spektrális minták létrehozásához alkalmazott mintákat manuálisan választottam ki. A szükséges minták száma a kiválasztás alatt ismeretlen volt, ezért túl lett méretezve a számuk. A módszer jövőbeli alkalmazásához szükséges az optimális mintaszám meghatározása, ami már garantálni tudja, hogy azonos körülmények között gyűjtött mintavételi pozícióknál azonos eredményt lehet elérni a spektrális szétkeverésénél.

A vizsgálat során a spektrális minták számát 100%-ról 10%-os lépésekben 10%-ra csökkentettem, majd 10%-tól 0%-ig 1%-os lépésekben csökkentettem. A mintaszám csökkentéséhez véletlenszerűen kiválasztott elemeket távolítottam el az adatsorból. Az eltávolítás előtt a minták sorrendje véletlenszerűen meg lett változtatva. A véletlen számok generálása a C++ STL könyvtárának segítségével történt (<https://en.cppreference.com/w/cpp/numeric/random/rand>, 2019.12.31.). Amikor a mintaszám 0%-ra lett csökkentve, akkor összesen 1 db spektrális mintát használt fel minden egyes osztályból. A csökkentett mintaszámú spektrális mintákból számítottam ki az egyes osztályokhoz alkalmazott spektrumokat átlagolással. A spektrális szétkeverés ezekkel a spektrális mintákkal készült el. Minden egyes lépés a mintaszám csökkentésben kétszáz iterációban történt meg, mind a három adattípuson (L1C, L2A, L2ADEM). Az iterációkból származó területek átlaga került számításba a vizsgálatnál. A terület kimutatás konstans 0.7-es küszöbértékkel történt a lék előfordulás képeken. A T1 mintaterületen végeztem el a vizsgálatot.

5.2.1.9 Érvényesítéshez használt referencia anyag készítése


A referencia réteg a lékekhez légifotók és felületmodellek alapján készült. A sztereó légifotó párokon könnyebben meg lehetett határozni a lékek kiterjedését, mint az elkészített ortofotókon. A referencia poligonok nem tartalmazták a lék közepén álló önálló magfákat. A poligonok töréspontjai megközelítőleg 0.5 méterenként helyezkedtek el. A T1 mintaterületen GNSS mérések segítségével tudtam meghatározni a mesterséges lékek pozícióját. A B1 mintaterületen az interpretáció után rács alapú ellenőrzést végeztem.

5.2.2 Eredmények és az eredmények értékelése


5.2.2.1 Spektrális minták értékelése

A spektrális minták vizuális vizsgálata nyomán jutottam arra döntésre, hogy megvilágítottsági állapot alapján további csoportokra kell osztanom őket, mert jelentősebb elkülönülés csak a NIR sávban tapasztalható. A látható tartományba eső sávokon az erdő és lék minták elkülönülése minimális.

A létrehozott spektrális minta osztályok szórása (34. ábra) és átlaga (35. ábra) mutatta meg a mintavételezés pontosságát. Ahol a szórás értéke 1000-nél magasabb volt a NIR sávban, ott megbízhatatlan eredményt adott a mintavételezés. Egy felhőmentes felvételtől mintavételezett erdő és lék mintákon a NIR értékek szórása 0-1000 között volt, ami a felvétel dinamikáját figyelembe véve (reflektancia tartomány: 0.25-0.45) még elfogadható tartományba esett. Az S-2 felvételek kék sávján (B2) alkalmazott küszöbértékes szűrést követően minden tesztelt adattípuson csökkent a szórás értéke. A legalacsonyabb szórást az L1C típusú adatokon tapasztaltam 166 átlagos értékkel, míg az L2A termékeken 210 és az L2ADEM típusú terméken 251 volt.



34. ábra: Erdő minták szórása a különböző megvilágítottsági kategóriákban és kategorizálás nélkül, 2016.08.29-én készült L2A típusú felvétel alapján



35. ábra: Lék és erdő spektrumok reflektancia átlagai a 3 megvilágítási osztályban

A mintavételezés a Börzsöny hegység majdnem teljes területére kiterjedt, így különböző tengerszint feletti magasságokból származtak a minták (3. táblázat). Akár 800 m szintkülönbség is lehetett azonos osztályba tartozó mintavételi pozíciók között. Ilyen nagy különbségeknél feltételezhetően különbözik az atmoszféra állapota, ami magyarázatot ad különböző adattípusoknál tapasztalt szórásra. Az egyes felvételekhez gyűjtött érvényes mintavételi pozíciók statisztikája a

4. táblázatban látható.

3. táblázat: Az egyes spektrális osztályokhoz gyűjtött mintavételezési pontok száma.

Minta típusa	Minták száma
Idős bükkös	1632
Árnyalt bükkös lék	563
Bükkös újulat	2961
Idős tölgyes	6694
Árnyalt tölgyes lék	2809

4. táblázat: Az egyes felvételeken a felhőmentes mintavételi pozíciók aránya

Felvétel dátuma	Felhasználható mintavételi pontok aránya
2015.08.07	98%
2015.10.03	88%
2016.03.24	59%
2016.07.22	63%
2016.08.28	98%
2016.08.31	100%
2016.09.07	100%
2016.09.10	100%
2016.09.27	71%
2016.09.30	100%
2016.10.10	96%


A legalacsonyabb szórást a minták esetén az L2ADEM adattípusnál vártam. Az alkalmazott domborzatmodell (SRTM 90) vagy az ATCOR3-ban található topográfiai normalizációs módszer [205] túlkorrigálta a reflektancia értékeket a nem megfelelő paraméterezése miatt, így az L2ADEM adattípusnál magasabb szórás értékek keletkeztek, mint az L2A-nál. A mintaterületeken a különböző sávok reflektancia értékeit korreláltattam egymással a különböző adattípusokon (5. táblázat). Az eredményeken megfigyelhető, hogy milyen mértékben befolyásolja a korrekciós módszer az atmoszféra tetején mért reflektanciát. Az atmoszférikus korrekció nagyon nagy mértékben befolyásolta a kék tartományt (B2), míg a topográfiai normalizáció ezt a tartományt nem érintette erősen. A radiometriai korrekció a NIR tartományban (B8) nem végzett erős változtatásokat. A bükkös mintaterületen a fiatal és idős faállomány spektrális profilja a topográfiai normalizáció hatására konvergál, míg anélkül vizuálisan jól elkülönültek. Az erdő és árnyalt lék spektrális minták között az elkülönülés megmaradt mindkét erdőtípus esetén a topográfiai normalizációnál.

5. táblázat: A felhasznált Sentinel-2 sávok korrelációja a különböző adattípusokon

R				R			
B2	L2ADEM	L2A	L1C	B4	L2ADEM	L2A	L1C
L2ADEM	1	0.91	0.32	L2ADEM	1	0.97	0.78
L2A	0.91	1	0.31	L2A	0.97	1	0.78
L1C	0.32	0.31	1	L1C	0.78	0.78	1
R				R			
B3	L2ADEM	L2A	L1C	B8	L2ADEM	L2A	L1C
L2ADEM	1	0.85	0.58	L2ADEM	1	0.88	0.86
L2A	0.85	1	0.6	L2A	0.88	1	0.95
L1C	0.58	0.6	1	L1C	0.86	0.95	1

5.2.2.2 A spektrális minták számának vizsgálata


Az optimális mintavételi pozíciók számának meghatározásánál arra az eredményre jutottam, hogy a kijelölt mintavételi helyek 10%-a elegendő lenne a térképezés végrehajtására hasonló pontossággal (36. ábra). Az optimális mintaszám így 100-200 pozícióra csökkenthető az alkalmazott több ezer helyett, amennyiben azonos minőségben kerülnek a pozíciók kijelölésre.



36. ábra: Területkimutatás a különböző mértékben mintavételezett spektrális minták alapján


5.2.2.3 Szintetikus lélek modellezése

A spektrális modellezés során a kiválasztott 6 lék felületmodellje alapján készült el a modell. Mind a 11 elérhető felvétel körülményeihez elkészítettem a küszöbértéket a leírt módszer alapján (37. ábra). A kevert pixelben megjelenő lék részaránya egy határozott mintázatot mutat a nem teljes idősor ellenére is. Az értékek hasonló mozgást mutatnak, mint a Nap állásának magassági szöge. Ez a szög nagymértékben befolyásolta a létrehozott megvilágítási és árnyék modellt, így a hatása az eredményben is megfigyelhető: a Nap magassági szögének és a minimum lék részarányának korrelációja -0.98. Ez alapján arra lehet következtetni, hogy alacsonyabb Nap állás esetén a koronaszinten megjelenő árnyék már olyan szinten tud keveredni a lék alján megfigyelhető árnyékokkal, hogy csak alacsony megbízhatósággal lehet elkülöníteni őket a meghatározott küszöbértékkel. Ez bizonyítja a dinamikus küszöbérték alkalmazásának szükségességét, ahol minden egyes időpontban más értékek alapján történik a területek kiértékelése.



37. ábra: Minimum lék részarányok az egyes időpontokban a megvilágítási kategóriákhoz

A kiválasztott pixeleken, melyeket a lékeket reprezentálták a modelleken, a terület túlbecslése mérhető volt. Mivel a felhasznált S-2 sávok felbontása 10 m-es, az ennél finomabb oldalakkal rendelkező, kis méretű lékeknél mindenképpen spektrális keveredés történik. A spektrális keveredés miatt torzul a kimutatott lék geometriája. A vizsgálat azt mutatta ki, hogy magas Nap állás mellett (június-augusztus), megfelelő méretű lékeknél nem történik jelentős fölé- vagy alá- becslés a szintetikus modellen (38. ábra). Mivel a valódi felvételt több tényező befolyásolja, mint amit a modellbe foglaltam, ott nagyobb torzítás várható.



38. ábra: A terület túlbecslés arányai az egyes időpontokban a különböző megvilágítási kategóriákban

5.2.2.4 Lékek területének kimutatása egyes felvételek sorozata alapján

5.2.2.4.1 Tölgyes mintaterület 1 (T1)

A légifotók alapján a 2015-ös évre 1.79 ha lékterületet mutattam ki. A 2016-os légifotók alapján 3.29 ha lék területet mértem, melyen újonnan nyitott lékek találhatók. A változás mértéke 1.5 ha volt. Több lékben is előfordul magfa, melyek kis kiterjedésük miatt korlátozottan lettek figyelembe véve az űrfelvételek esetében.

A kiértékelés során a völgyben található, folyamatosan árnyalt terület nem került kiértékelésre. Az ehhez hasonló adottságokkal rendelkező mély völgyekben elhelyezkedő lékek kiértékelésére az S-2 képanyaga és az alkalmazott módszer nem alkalmas. A vizsgált terület kiterjedése 26.3 ha volt. 2015-ből kettő, 2016-ból hét képet tudtam kiértékelni a felhőborítás miatt. Az első módszerrel, ami az egyes képek alapján kimutatott területek statisztikáját veszi figyelembe, a következő területeket mutattam ki (6. táblázat):

6. táblázat: Terület kimutatás a Tölgyes 1 mintaterületen

	Év	L2ADEM	L2A	L1C	Referencia
Átlag (ha)	2015	3.39	6.58	7.10	1.79
	2016	5.04	8.32	7.85	3.29
Szórás (ha)	2015	2.08	0.64	1.97	
	2016	1.18	1.12	0.63	
Lék/Teljes terület arány	2015	12.92%	25.05%	27.03%	6.80%
	2016	19.20%	31.67%	29.89%	12.52%
Változás 2016–2015	ha	1.65	1.74	0.75	1.50
	%	6.28%	6.62%	2.86%	5.71%

A referencia területhez legjobban megközelítő eredményt az L2ADEM adattípus, azaz az atmoszférikus korrekción és topográfiai normalizáción átesett reflektancia értékek adták. Az L2A típus közel kétszeres mennyiségű léket mutatott ki, de ezt konzisztensen végezte az idősorban, alacsony szórással. A változást 2015 és 2016 között sokkal pontosabban lehetett kimutatni, mint a teljes területet az egyes időpontokban. Az S-2 felvételei alapján a változást 0.15 ha pontossággal mutatta ki az alkalmazott módszertan.

A felvételek közül több az operatív fázis előtt készült, így georeferálásból származó hibák terhelhetik a kimutatott területeket. A különböző műhold pásztákból származó felvételek térképei között jelentősebb különbség nem volt. A detektált lékek mennyiségét a felvételek körülményei (időpont, vegetáció fenológiai fázisa, Nap állás) sokkal nagyobb mértékben befolyásolják, mint az esetleges geometriai hibák.

A különböző időpontoknál a különböző adattípusból készült lék valószínűség térképeket korreláltattam egymással. A korrelációs együtthatók azt mutatják (7. táblázat), hogy az L2A és L1C térképek között igen magas az együttmozgás (R : 0.98-1.0). Ebből az a következtetés vonható le, hogy az L1C adattípuson is hasonló mennyiségű lék lenne kimutatható, mint az L2A-n, csak a meghatározott küszöbértéket az L1C adattípusra is meg lehetne határozni. Az eredmények alapján a topográfiai normalizáció nem lineáris változást okoz a sávokban, így a nagyobb kontrasztnak köszönhetően jobban elkülönülnek a lékek az erdőtől.

7. táblázat: Korrelációk a szűrés nélküli lék valószínűség raszterek között a különböző adattípusok esetén az egyes időpontokban a Tölgyes 1 mintaterületen

Dátum	R		
	L2ADEM-L2A	L2ADEM-L1C	L2A-L1C
2015.08.07	0.84	0.82	0.99
2015.10.03	0.58	0.59	1.00
2016.03.24	0.86	0.86	0.98
2016.08.28	0.83	0.82	1.00
2016.08.31	0.84	0.84	1.00
2016.09.07	0.81	0.81	1.00
2016.09.10	0.82	0.82	1.00
2016.09.27	0.73	0.78	0.98
2016.09.30	0.75	0.75	1.00

5.2.2.4.2 Tölgyes mintaterület 2 (T2)

A légifotók és a felületmodellek alapján 1.24 ha lékterületet mutattam ki a T2 mintaterületen. A mintaterület egy erdőtömb közepén feküdt, ezért a szélein nem volt zavaró tényező. 2015-ből kettő, 2016-ból hét felvételt értékeltem ki a területre. A két év alatt nem történt jelentős változás a lékek kiterjedésében, így a két évet együtt lehetett kiértékelni (8. táblázat). Az L2ADEM adattípuson megközelítőleg azonos mértékben lehetett kimutatni a lékek területét, mint a referencia adatokon. A közel azonos átlaghoz egy viszonylag magas szórás érték tartozik, míg a többi adattípuson a szórás alacsonyabb. A 2016-os képeken nagyobb a túlbecslés mértéke, feltételezhetően a több késői vegetációs fázisból származó felvétel miatt.

8. táblázat: Terület kimutatás a Tölgyes 2 mintaterületen

	Év	L2ADEM	L2A	L1C	Referencia
Átlag (ha)	2015	1.30	0.76	1.00	1.24
	2016	1.53	1.05	0.78	1.24
Szórás (ha)	2015	0.21	0.05	0.10	
	2016	0.30	0.28	0.17	
Lék/Teljes terület arány	2015	14.58%	8.54%	11.29%	13.98%
	2016	17.23%	11.77%	8.83%	13.98%
Változás 2016–2015	ha	0.23	0.29	−0.22	
	%	2.64%	3.24%	−2.46%	

A terület domborzata közel sík, de a topográfiai normalizációnak a kontraszt képző hatása itt is megfigyelhető. A lék valószínűség térképek korrelációja (9. táblázat) hasonló tendenciát mutat, mint a másik tölgyes mintaterületnél. A kevesebb domborzati korrekciónak köszönhetően az L2A és L2ADEM adattípusok között kisebb különbség figyelhető meg.

9. táblázat: Korrelációk a szűrés nélküli lék valószínűség raszterek között a különböző adattípusok esetén az egyes időpontokban a Tölgyes 2 mintaterületen

Dátum	R		
	L2ADEM-L2A	L2ADEM-L1C	L2A-L1C
2015.08.07	0.92	0.92	1.00
2015.10.03	0.78	0.77	1.00
2016.07.22	0.90	0.88	0.98
2016.08.28	0.87	0.86	1.00
2016.08.31	0.88	0.88	1.00
2016.09.07	0.86	0.86	1.00
2016.09.10	0.86	0.86	1.00
2016.09.30	0.82	0.82	1.00
2016.10.10	0.78	0.77	1.00

5.2.2.4.3 Bükkös mintaterület (B)

A légifotók és a felületmodellek alapján 14.11 ha lékterületet lehetett elkülöníteni, ami a többi mintaterülettől abban különbözik, hogy itt több helyen jóval magasabb a lékekben lévő faállomány magassága. A lékek széle a bükk faegyedek koronáinak konvex befoglalóinál lett meghatározva. 2015-ből kettő, 2016-ból négy felvételt értékeltem ki. Ez a mintaterület magasabban fekszik, mint a tölgyesek, így a felhőborítás is magasabb volt.

A spektrális minták vizsgálata kimutatta, hogy a topográfiai normalizáció csökkenti a spektrális távolságot a fiatal és idős erdő között. Ez a jelenség befolyásolja a kimutatott lék területet ilyen erdőknél, így ebben az esetben az L2A típusú adat mutatta a legközelebbi értéket a referenciához.

A 2015-ös felvételeken még jól látható a 2014-es jégtörés hatása. A jégtörés részleges koronatoréseket okozott ezen a területen, ami további egyenletlenséget okozott a fakorona burkoló felületében. Ebből kifolyólag több önárnyalás volt ezeken a felvételeken megfigyelhető, mint a későbbiekben. Egy év alatt 22.36%-kal csökken a kimutatott lékterület és a szórások értéke is megfeleződött (10. táblázat). Ez a jelenség a bükk fafaj jó regenerációs képességével magyarázható. Közepes felbontású űrfelvételeken is kimutatható volt ugyanez a jelenség a Börzsönyben [242].

10. táblázat: Terület kimutatás a Bükkös mintaterületen

	Év	L2ADEM	L2A	L1C	Referencia
Átlag (ha)	2015	26.04	22.01	22.74	14.11
	2016	21.27	14.69	14.61	14.11
Szórás (ha)	2015	2.07	1.34	1.57	
	2016	1.51	0.73	0.91	
Lék/Teljes terület arány	2015	79.47%	67.18%	69.41%	43.06%
	2016	64.91%	44.82%	44.58%	43.06%
Változás 2016–2015	ha	–4.77	–7.33	–8.14	
	%	–14.56%	–22.36%	–24.83%	

Az adattípusok korrelációja igen alacsony (11. táblázat), ami a különböző korrekciós eljárások nem lineáris változtató hatására utalnak. Csúpan az L2A és az L1C adattípusok között figyelhető meg nagyobb mértékű együtt mozgás.

11. táblázat: Korrelációk a szűrés nélküli lék valószínűség raszterek között a különböző adattípusok esetén az egyes időpontokban a Bükkös mintaterületen



Dátum	R		
	L2ADEM-L2A	L2ADEM-L1C	L2A-L1C
2015.08.07	-0.16	-0.11	0.83
2015.10.03	0.27	0.25	0.97
2016.08.28	-0.17	-0.22	0.96
2016.09.07	-0.24	-0.26	0.97
2016.09.10	-0.04	-0.26	0.77
2016.09.30	-0.27	-0.38	0.88

5.2.2.5 Lékek területének kimutatása idősor alapján

Az egyes felvételek leíró statisztikáit felhasználó módszer minden esetben túlbecsülte a kimutatott lék területek méretét. Az a módszer nem használta fel az időbeli adatokat a kiértékelés során, így csúpan sejteni lehet, hogy a hibák miből származtak. A rácsháló alapú idősor kiértékeléssel pontosabb eredményt lehet elérni. A lék előfordulás értékét fuzzy valószínűségnek tekintve olyan térképet hoztam létre, ami részletes információt nyújt a lékek térbeli kiterjedéséről. Az idősor alapú kiértékelés csak azon az adattípuson történt meg, amelyik a legjobb eredményt mutatta a korábbi módszernél.

5.2.2.5.1 Tölgyes mintaterület 1 (T1)

A kiértékelésnél csak az L2ADEM adattípust dolgoztam fel. A terület kimutatás hasonló eredményeket ábrázolt, mint az előző módszernél (12. táblázat). Az egyes felvételeknél meghatározott küszöbértékekkel szűrt térképekből állítottam össze az eredményt, ezért a térképen látható végeredményen nem kellett további szűrést alkalmazni (39. ábra). A térbeli korreláció az eredményként kapott térkép és a referencia lékekből alkotott térkép között a 2015-ös évre 0.63, a 2016-os évre 0.65 értéket mutatott. Az eredmény térképre fektetve a referencia poligonokat az figyelhető meg, hogy kevés helyen van hamis lék detektálás. Elsősorban a detektált lékek mérete különbözik, nem a pozíciójuk. Ennek az oka az lehet, hogy a referencia digitalizálása során a fakorona konvex befoglalóját tekintettem a határának, míg ezeken a szélső ágakon lazább a lombszerkezet. A lazább lombszerkezetben több önárnyalás történhet, ami belekeveredik a lék árnyalt részével együtt a rögzített pixelbe.



39. ábra: A lékek idősor alapú fuzzy valószínűség térképe a 2015-ös (A) és 2016-os (B) állapotokról a referencia lék kontúrok megjelölésével


Az összesített fuzzy valószínűség térképen egy empirikusan meghatározott 0.25 valószínűségi küszöbérték fölött vettem figyelembe a léket. Ez a küszöbérték az alkalmazott felvételek időpontjaitól függ, amennyiben több késői vagy nagyon korai felvétel van a sorozatban, akkor magasabb értéket kell választani. A túl magas küszöbérték azokat a lékeket, melyeknek például 1 pixelnél keskenyebb, hosszúkás alakja van, kiszűrheti az eredményből. A legkisebb detektálható lék mérete nem sokkal kevesebb, mint 1 pixel (10x10 m), de kompakt alakjának kell lennie.

12. táblázat: Idősor alapú lék területkimutatás a Tölgyes 1 mintaterületen

	L2ADEM	Referencia	Referencia + 2 m puffer
Terület 2015 (ha)	3.33	1.76	3.18
Terület 2016 (ha)	5.19	3.26	5.32
Terület 2015 + 2016 (ha)	5.39	3.26	5.32

5.2.2.5.2 Tölgyes mintaterület 2 (T2)

A kiértékelésnél csak az L2ADEM adattípust dolgoztam fel. Összesen 1.72 ha lékterületet mutattam ki ezzel a módszerrel a két év kombinációjából (13. táblázat). A térképen (40. ábra) nem volt szükség globális küszöbérték meghatározására a fuzzy valószínűség értékekhez, mivel a közel sík fekvés és az állomány szerkezete miatt még kevesebb árnyalás volt tapasztalható. A korreláció a referencia léktérképpel 0.72-es értéket mutatott.




40. ábra: A lékek idősor alapú fuzzy valószínűség térképe a 2015-2016-os összesített állapotokról a referencia lék kontúrok megjelölésével

13. táblázat: Idősor alapú lék területkimutatás a Tölgyes 2 mintaterületen

	L2ADEM	Referencia	Referencia + 2 m puffer
Terület 2015 (ha)	1.43	1.24	1.67
Terület 2016 (ha)	1.81	1.24	1.67
Terület 2015 + 2016 (ha)	1.72	1.24	1.67

5.2.2.5.3 Bükkös mintaterület (B)

A kiértékelésnél csak az L2A adattípust dolgoztam fel (14. táblázat). Az egyszerű területkimutatás során elfogadható mennyiségű területet adott a 2016-os felvételekre. A tölgyes mintaterületeken tapasztalt túlbecslés a lékek szegélyénél itt is jelen van (41. ábra), és a lékek nagyobb méretei jelentősebben befolyásolják az eredményeket. A 2015-ös eredmény térképen a lékek mellett alacsony valószínűséggel jól megfigyelhetők a jégtörés okozta károk. A 2016-os eredmény térkép már sokkal jobban illeszkedik a referencia lékekhez, ennek ellenére a korreláció értéke a referencia térképhez viszonyítva csak 0.21. Ez jelentősen alacsonyabb, mint a tölgyesek esetén tapasztalt 0.63 (T1) és 0.72 (T2) értékek.



41. ábra: A lécek idősor alapú fuzzy valószínűség térképe a 2016-os állapotokról (A) és 2015-2016 történt regeneráció térképe a területen


A 2015 és 2016 közötti regeneráció a két év közötti változás térképen figyelhető meg. A referencia lécek környékén nem történt változás, míg a részleges koronatorést szenvedett állományrészekben nagyon nagy mértékű regeneráció történt.

14. táblázat: Idősor alapú lék területkimutatás a Bükkös mintaterületen

	L2ADEM	Referencia
Terület 2015 (ha)	23.03	14.11
Terület 2016 (ha)	15.49	14.11
Terület 2015 - 2016 (ha)	7.54	

5.2.2.6 A terület túlbecslés lehetséges oka

A lékvalószínűség térképeken látható volt, hogy a legtöbb hiba a referencia lécek kerületén látható, különösen a délkeleti oldalukon. Ezek a pixeleken a lécek terület foglaltságának jóval 100% alatt kellene lennie, míg a térképen gyakran 100% körüli érték szerepel. Ez a hiba abból az árnyalásból származhat, ami a fakorona Naptól eltekintő (árnyékos) oldalán jelenik meg. Ez nem a talajszintre vetített árnyék, de a szenzor ezt is hasonlóan rögzíti a kevert pixelben. Ez a hatás modellezhető egy felületmodellen a IC típusú megvilágítás modellezéssel. Ha egy félgömbnek tekintem a lombos fák korona felszínének burkolófelületét, akkor létrejön ez az árnyékhatás. Egy légifotón, ami hasonló napszakban lett rögzítve, mint az S-2 felvétel, ugyanúgy megjelenik. Az árnyalt koronarész egy közel 2 m szélességű szegélyt alkot a referencia lék körül (42. ábra, 6. ábra). Ez alapján feltételezni lehet, hogy a délelőtti készült űrfelvételeken minden esetben ilyen típusú túlbecslésnek jelen kell lennie idős tölgyes és bükkös állományokon. A feltételezés alapján meg lehet határozni egy túlbecslési együtthatót szabályos, kerek léceket feltételezve. Az együtthatóval szorozva a területkimutatásokat a valódihoz nagyon közel álló területeket lehet kapni (12. táblázat, 13. táblázat).



42. ábra: Egy lék nagyon nagy felbontású felületmodellje digitalizált lék és árnyalt részekkel (A) és ugyan annak a lécknek a képe egy hamis infraszínes ortofotón a lék körvonalával (B)

5.2.3 Következtetések

Az esettanulmányban létrehozott bonyolult munkafolyamat során az erdőgazdálkodást segítő tematikus térinformációkat hoztam létre, amelyeknek a pontossága ismert. A vizsgálatból kiderült, hogy az űrfelvétel előfeldolgozottság típusok nagy mértékben befolyásolják az elért eredményt. Tölgyes erdőkben, ahol a lécek mérete kisebb és a léken kívüli állomány záródása magasabb, ott az L2ADEM, topográfiai normalizáción átesett felszíni reflektancia termékek mutatták a legpontosabb eredményt. A bükkös területen, ahol nagyméretű lécek vannak, gazdagabb, idősebb újulattal és az idős faegyedek

koronája fragmentáltabb, ott az L2A típusú felszíni reflektancia érték adta a legjobb eredményt. A spektrális szétkeveréshez szükséges tanító minták létrehozásához legalább 100 mintavételezési pont szükséges, hogy megbízható pontossággal lehessen létrehozni a minta spektrumot. Az alkalmazott felületmodellnek pontosnak kell lennie, amin a megvilágítási típusokat modellezem. Ezeknek az elérése ma már nem jelent problémát, mert országos szinten elérhető fotogrammetriai úton készült magassági adatok állnak rendelkezésre az országra 5-10 éves frissítéssel [243]. Hosszabb idősor alkalmazásánál, amelyben túlsúlyban vannak a magas Nap állás mellett készült felvételek, még pontosabb eredményt lehetne elérni. A vizsgálat az S-2 műholdprogram korai szakaszában készült, így akkor még nem álltak rendelkezésre a műholdpár sűrűbb adatai. Az űrfelvételek kiértékelhetőségére készített vizsgálat azt mutatta ki, hogy erdőrézlet szinten elérhető a havi egy megfigyelés, így ennek a módszernek az alkalmazása nagy területeken lehetséges a jövőben.

A szabályos, kerek alakú lékek detektálása magas Nap állás mellett nagy pontossággal elvégezhető. A kicsi, nem kompakt alakú lékek detektálása nehezebb. Ezekhez 5 m terepi felbontású űrfelvételek lennének alkalmasak, amelyek ugyan léteznek, de elérésük egy hazai erdőgazdálkodó számára nagy anyagi megterhelést jelentene. Például a Börzsöny hegységet és szűk környezetét lefedő 5 m felbontású 10 időpontos nyers idősor közel 21 millió forintba kerülne egy évre a 2019-es árak alapján (<http://www.landinfo.com/satellite-imagery-pricing.html>, 2019.12.31.).

A lékek területének abszolút kiterjedését csak túlbecsléssel tudta a módszer megállapítani, míg a változások kiterjedését nagyon pontosan megállapította. Az egyes felvételeken megállapított lékterület a közvetlen alkalmazást részterületek számítására nem javasolom, de az idősből fuzzy valószínűségek segítségével előállított terület kimutatás már pontosabb képet adhat a gazdálkodónak az erdő állapotáról. A változás térképek alapján követni lehet a lékek méretét, így pontosan ütemezni lehet a szükséges beavatkozásokat, ha több fényre van szükség a lékekben.


Nagyon nagy felbontású távérzékelési adatokon pontosabban meg lehet határozni a lékek kiterjedését, de ezek az anyagok csak ritkán elérhetők. A bemutatott módszerrel éves szinten elkészíthetők ezek a térképek, amelyeken a koronazáródás nyomon követhető.

5.3 Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben

Az esettanulmány elsődleges célja a faállomány-típusok térképezése volt a Börzsöny hegységben és szűk környezetében. A megvalósítás során a Sentinel-2 idősor előfeldolgozó láncának fejlesztésére is megtörtént, amivel a hegyvidéki erdőterületekre jellemző zajokat szűrni lehetett. Erre a fejlesztésre azért volt szükség, mert a nyíltan elérhető előfeldolgozó alkalmazások nem voltak alkalmasak az elvárt pontosságú konzisztens idősort létrehozni. A faállományok kiértékeléséhez CNN típusú osztályozó modelleket alkalmaztam. Összehasonlításuként elvégeztem a kiértékelést RF osztályozó modellekkel, hogy képet kapjak az eredmények és a befektetett emberi munka összefüggéséről. Az előfeldolgozási lánc fejlesztésének eredményességét is a faállományok kiértékelésének bevonásával végeztem el.

5.3.1 Módszertan

A faállomány-típusok térképezése egy komplex munkafolyamaton keresztül valósult meg (43. ábra). A munkafolyamat része volt a felvételek beszerzése, előfeldolgozása. A faállomány-típusok osztályozása felügyelt osztályozási módszerekkel történt. Az esettanulmányban a spektrális-időbeli-térbeli képjellegzetességek alapján tanított CNN típusú és spektrális-időbeli képjellegzetességek alapján tanított RF osztályozó modellek teljesítményét hasonlítottam össze összesített pontosság és befektetett munka szempontjából.



43. ábra: A faállomány-típus térképezés részletes munkafolyamat ábrája

5.3.1.1 Idősor összeállítás

A letöltött S-2 felvételekből egy konzisztens idősort állítottam össze. A letöltött felvételek először atmoszférikus korrekción estek át a Sen2Cor szoftverrel, ami során létrejött automatikus felszín osztályozás réteget és felhőmaszkot felhasználtam további szűrésekre. A Sen2Cor felhőmaszkjai alapján 1%-os felhőelfordulás alapján lettek szűrve a letöltött felvételek az OEA erdőmaszkja alapján a vizsgált területre. Mivel a Sen2Cor felhőmaszkjának megbízhatósága nem megfelelő, a saját fejlesztésű Kálmán-szűrő alapú multitemporális maszkolást alkalmaztam a további szűrésekhez.

A pontosabb felhőborítás információk ismeretében a felhők helyén pótoltam a hiányzó felszíni reflektancia értékeket lineáris modellezéssel. A már csak érvényes felszíni reflektancia értékeket tartalmazó képeken topográfiai normalizációt végeztem az empirikus forgatás módszerével. Az empirikus forgatás módszeréhez a regressziót az erdőrézlet poligonokból vett mintákkal és a 20 m felbontású digitális domborzatmodellből származtatott IC értékek alapján hoztam létre.

Az előfeldolgozási lépésekkel előállt egy konzisztens idősor egy vegetációs időszakra, amelyen vizsgálni lehetett a faállományok-típusát spektrális-térbeli és időbeli jellegzetességek alapján.

5.3.1.2 Képszegmentálás

Az előkészített konzisztens idősorton képszegmentálást végeztem MRS eljárással. A szegmentálás során az összes sávot felhasználtam az idősortból. A szegmentálással olyan képjelölőket kaptam, amelyek megőrizték a faállomány-típusok térbeli kiterjedését egy bizonyos küszöbértéken alul. Ezzel lehetővé vált a faállományok erdőrézlet szint alatti egységre bontása. A szegmensek több felszínborítás típust fedhetnek le [164], melyek nem feltétlenül faállományokat takarnak. Az ilyen alacsony szintű objektum kimutatása nagy felbontású űrfelvételen szubpixeles eljárásokkal lenne csak lehetséges.


A homogenitás paraméter 10 és az alak paraméter 0.9-re lett beállítva a kísérletezés során. Ezekkel a paraméterekkel olyan kompakt szegmensek jöttek létre, melyek alkalmasak voltak a CNN típusú osztályozáshoz.

5.3.1.3 Adatosztályozás

5.3.1.3.1 Erdőborítás

A faállomány-típusok kiértékeléséhez szükség van egy pontos faállomány borítás térképre. Az erdőrészlet poligonok erre a célra nem alkalmasak, ugyanis találhatók erdőtervvel nem rendelkező faállományok és alacsony korona záródású területek a poligonokon belül. Ennek a térképezésére transfer learning módszert alkalmaztam, ahol a CNN hálózat előre tanított kategóriákat tartalmaz. A hálózat kimeneti osztályozó rétege után kerül egy további réteg, ami a már meglévő osztályok paramétereit módosítja az új tanító anyagnak megfelelően. A faállomány borítás térképezéshez az INCEPTION V3 modellt [244] tanítottam újra (44. ábra). Erdő és nem erdő kategóriák lettek létrehozva a tanító anyagban. Az újra tanítás 150 000 iterációval történt meg. A szabálytalan alakú, homogén képrészek 299x299 pixel méretűre lettek skálázva, hogy megfeleljenek az INCEPTION V3 bemeneti rétegének méretének. A szabálytalan alak körüli terület a homogén képrész spektrális átlagaival lett feltöltve a sávokban. Az INCEPTION V3 modell 3 sávos képeket képes feldolgozni, így az idősor magasabb dimenziószámát csökkenteni kellett. Az idősor 3 eltérő időpontjából választott látható kék (B2) tartományban rögzített sáv kompozitját használtam fel erre a célra. Ennek oka, hogy az erdő felszínborítás ebben a spektrum-tartományban nem mutat különösebb változást a vegetációs időszak alatt, más fotoszintetikusan aktív felületekhez képest.

Az osztályozás után azokat a szegmenseket tekintetem erdőnek, melyeknél az osztályozás 50%-nál magasabb fuzzy valószínűséggel jelzett erdőborítást. Az RF modell a szegmensek sávonkénti spektrális átlagaival tanítottam, majd osztályoztam.



44. ábra: Az INCEPTION V3 modell felépítése Szegedy és mtsai. [244] leírása alapján

5.3.1.3.2 Faállomány-típus

A faállomány-típusok osztályozása is egy CNN modell segítségével történt, ami ebben az esetben egyedi felépítéssel rendelkezett (45. ábra). A hálózat 8 neuron rétegből áll, ahol az első 5 rétegben történik meg a térbeli jellemzők kivonása konvolúciós szűrőkkel, amit 3 további teljesen összekapcsolt neuron réteg követ. Minden egyes réteget egy batch normalization [237] funkció követ, ami a modell túlillesztését segít elkerülni. A hálózat regularizálása L2 funkcióval [245] történt. A tanítás optimalizálásához az Adaptive Moment Estimation (Adam) [246] módszert alkalmaztam. A hálózat bemenetei 6x6 pixel méretű, 80 sávos képkivágatok voltak. A szabálytalan alakú homogén képrészek a 6x6 pixel méretre lettek újra mintavételezve. A ki nem töltött részekre véletlenszerűen választott észak-dél irányú mintákat (1x1, 1x2, 1x3 pixel) illeszttem be, hogy az árnyalásból származó textúra részben megmaradjon. A szegmensek szélénél levágott képek olyan szabálytalan alakjellemzőket okozhatnak, amelyek félrevezethetik a CNN modell tanítást. A véletlenszerűen, a szegmens belsejéből mintavételezett textúrák feltételezhetően csökkentik ennek a lehetőségét. A modell tanítása 943 836 iteráción keresztül tartott.

Nem egyenlő a különböző faállomány-típusoknak az eloszlása a vizsgált területen (15. táblázat), így feltételezhetően a tanítóanyag sem lesz megfelelő. Az egyenlőtlen mintaszámú tanítóanyag túlillesztést

okozhat az osztályozás során, mert esetleg nem az osztályra jellemző mintázatra, hanem zajra illeszti a modellt. A túlillesztés ellen mesterséges adatkiterjesztést alkalmaztam. A 6x6 pixel méretű ablak a mintavételi pozíció körül 8 irányba lett elmozgatva, így növelve a minták variációit. A mintaszámok kiegyenlítése az alacsonyabb számú csoportokba véletlenszerű ismétléssel történt meg. A mintaszám növelése lehetővé tette, hogy a tanítás során alkalmazott 48 elemű mini-batch [237] minden osztályból tartalmazzon egy elemet.

45. ábra: A faállomány-típus osztályozáshoz alkalmazott CNN modell felépítése

Faállomány-típusok elnevezése a jellemző fafaj alapján	Jellemző faj a típusban	Az egyes típusok területfoglalása a vizsgált területen az OEA alapján
Mezei juhar	<i>Acer campestre</i>	1.2%
Mézgás éger	<i>Alnus glutinosa</i>	1.2%
Gyertyán	<i>Carpinus betulus</i>	4.4%
Bükk	<i>Fagus sylvatica</i>	18.0%
Magaskőris	<i>Fraxinus excelsior</i>	1.3%
Virágoskőris	<i>Fraxinus ornus</i>	0.6%
Fenyők	<i>Pinus spp. & Picea spp.</i>	2.9%
Cser	<i>Quercus cerris</i>	18.8%
Tölgyek	<i>Quercus petraea & Q. robur</i>	38.7%
Vöröstölgy	<i>Quercus rubra</i>	0.3%
Akác	<i>Robinia pseudoacacia</i>	12.5%
Hárs	<i>Tilia spp.</i>	0.3%

5.3.1.4 Érvényesítés

A felhőmaszkok vizsgálata kézzel digitalizált felhő poligonok segítségével történt. A digitalizálást S-2 RGB (B4, B3, B2) kompoziton végeztem. A digitalizálás során a különböző felhőtípusok és pára nem lettek elkülönítve, csupán a felhőárnyék kategória került más osztályba. A vizsgálatot a Sen2Cor által

készített maszkokon is elvégeztem. A hiba mátrix felhasználói pontosságát vettem figyelembe a kiértékelésnél.


A fejlesztett előfeldolgozó módszertan vizsgálatát a faállomány-típus osztályozás pontosságával végeztem. Két RF modell, ami az összes letöltött felvétel közül a Sen2Cor felhőmaszk alapján 50% alatti felhőborítást tartalmazó L2A idősoron (33 felvétel) és a saját fejlesztésű előfeldolgozási lánc által kiválasztott felvételekből összeállított L2A típusú idősoron lett tanítva azonos mintavételi pozíciókkal a tanító területekhez. Egy harmadik RF modell az előkészített konzisztens idősoron lett tanítva.

Az erdőborítás térképezés pontosságát összesen 5022 szegmensbe eső ponton vizsgáltam. A faállomány-típusok osztályozásának pontossági vizsgálatához egy a tanító adatoktól független adatsort hoztam létre. Az érvényesítésre összesen 1279 szegmenst választottam ki, ami a tanító adathalmazzal (1148 szegmens) összehasonlítható mértékű.

5.3.2 Eredmények és az eredmények értékelése

5.3.2.1 Előfeldolgozás értékelése

Összesen 73 db L1C típusú S-2 képen végeztem el az atmoszférikus korrekciót a Sen2Cor-ral. Az előzetes felhőmaszkon 1.5%-os megengedett felhőborítási küszöbértéknek csak 9 felvétel felelt meg. Az éves felhőborítás a mintaterület fölött 70% [122]. Ez alapján a statisztika alapján a felvételek közel 30%-a használható lenne, míg a tanulmányban csak 11%-a lett felhasználva. A konzisztens idősor 8 felvételt tartalmazott, ami összesen 80 sávot foglalt magába. A kiválasztott felvételek időbeli eloszlása nem egyenletes (46. ábra).




46. ábra: Az 50%-nál kevesebb felhőborítottsággal rendelkező Sentinel-2 felvételek listája a felhasznált felvételek megjelölésével

5.3.2.2 Felhők detektálásának értékelése

A felhő és felhőárnyék maszkoknak az átlagos felhasználói pontossága 86% volt a Kálmán-szűrő alapú multitemporális módszerrel, míg a Sen2Cor maszkjai csak 12%-os felhasználói pontosságot értek el. A multitemporális módszerrel a vékony felhőrétegeket és a párát nagyobb pontossággal lehetett detektálni, ezért lett hatalmas különbség a két módszer pontosságában (47. ábra). A fejlesztett módszer hátrányai erdőterületeken nem jelentkeznek, míg más felszínborítási formákon, ahol évközben nagy erősségű

változások vannak kevésbé alkalmazható. Az idősorban az előzetes szűrés alapján 9 felvétel került be, ám a saját fejlesztésű felhőmaszkkal további 1 felvétel kikerült (DOY: 238) magas felhőborítása miatt.



A B
47. ábra: Két felhő és árnyékaik egy Sentinel-2 RGB kompozitképen (A) és a legyártott felhő és felhő árnyék maszkok (B)

5.3.2.3 Az előfeldolgozó lánc értékelése

A faállomány-típus osztályozás összesített pontossága 84.5% ($\kappa=0.82$) volt a RF modellel a maszkolás, képpótlás és topográfiai normalizáció nélküli L2A idősorban, ami ugyan azokat a felvételeket tartalmazta, mint a konzisztens idősor. Összehasonlításképp, a konzisztens idősorban az RF modell 84.7% ($\kappa=0.83$) összesített pontosságot ért el, ami nem tekinthető jelentős különbségnek. Az RF modell az osztályozás

során számos lépésben generált véletlen számokat alkalmaz. Több iterációval elvégezve az osztályozást, ilyen alacsony különbség mellett kiegyenlítődhét a pontosság értéke a két adattípus között. Az alacsony különbség oka a már amúgy is alacsony felhőborítás értékben kereshető, ami előzetes szűrésen esett át. A hasonló pontosság oka abban is kereshető, hogy a tesztelésre alkalmazott megvilágítási állapot közepesnél magasabb volt, így a topográfiai normalizáció hatása itt kevésbé érvényesült. Az átlagos IC értéke, alacsony Nap állás mellett (DOY: 290) 0.53 ($\sigma=0.14$; $\gamma=-0.55$), ahol IC <0 érték alatt lenne teljesen árnyalt a terület. A közeli időpontok miatt a rövid idősorban magas a redundancia. Hasonló jellegű tanulmányok kimutatták [111], [116], hogy egyes fajok esetén már két felvétel is elegendő lehet jelentős osztályozási pontosság javuláshoz.

Az előfeldolgozás minőségének vizsgálatához a másik, 33 felvételtől álló idősort vizsgáltam, ami részleges felhőborítást tartalmazott a Sen2Cor maszkjai alapján. Az osztályozás összesített pontossága 79.9%-ra ($\kappa=0.76$) csökkent ezen az idősoron, ami megközelítőleg 5% teljesítmény csökkenést okoz a részletes előfeldolgozáson átesett eredményhez képest.

Az alkalmazott képszegmentálás átlagosan 36 pixel (0.36 ha; $\sigma=26.0$) méretű szegmenseket eredményezett. Alul és felül szegmentálás is megfigyelhető az erdőfoltokon, ahol nem éles a faállomány-típusok elvállása. Ahol a határ éles, mint a lombos-nem lombos állományoknál, ott a szegmensek határa is megfelelő helyen fut. A szegmentálás segítségével a nagymértékben fragmentálódott koronaszerkezetű erdők is generalizálhatók, melyek pixel alapú megoldásoknál csak további lépések bevonásával lennének kiértékelhetők.


5.3.2.4 Osztályozások eredményei

5.3.2.4.1 Erdőborítás osztályozás

Az Inception V3 modell újra tanítását 4217 erdő és 2553 nem erdő mintával végeztem el. A térképezés eredménye 46.6% erdőborítást mutatott a vizsgált területen (48. ábra). A térképezés pontossága 95.4% ($\kappa=0.91$) lett a transfer learning technológiával (16. táblázat). Az összehasonlításához alkalmazott RF modell ugyan azon a tanító és tesztelő adatsoron 91.4%-os ($\kappa=0.83$) összesített pontosságot ért el. Az RF modell csak a spektrális átlagokat használta fel a szegmenseknél, így részletesebb texturális információja nem volt az osztályozáshoz. Ennek köszönhetően a vegyes vegetáció és épített borítást tartalmazó szegmenseknél félreosztályozások voltak megfigyelhetők. Hasonlóan a gyümölcsös ültetvények szabályos szerkezetét se tudta kezelni, és ezeket is rendszeresen erdő borításnak osztályozta, míg a CNN modell képes volt ezeket a térbeli jellegzetességeket kihasználni.

16. táblázat: Az INCEPTION V3 alapú modellel készült erdőborítás osztályozás hibamátrixa

	Erdő	Nem erdő	Összesen	Előállítói pontosság
Erdő	2597	105	2702	96.11%
Nem erdő	125	2195	2320	94.61%
Összesen	2722	2300	5022	
Felhasználói pontosság	95.41%	95.43%		



48. ábra: A Börzsöny erdőborítás térképe 2017-es Sentinel-2 úrfelvétel-idősor alapján

5.3.2.4.2 Faállomány-típus osztályozás

A faállomány-típus osztályozásához a CNN modellt 1148 mintavételi pozíció alapján tanítottam. Ezek a pozíciók estek át mesterséges adatkiterjesztésen és osztály mintaszám kiegyenlítésen, ami után 31500 minta állt rendelkezésre. A tanító adat kiegészítése után minden osztály legalább 2400 elemből állt. A CNN modell érvényesítése során 88.2%-os összesített pontosságot ($\kappa=0.87$) ért el a konzisztens idősoron (17. táblázat). Az RF modell a konzisztens idősoron 84.7%-os eredményt ($\kappa=0.83$) produkált. Ez a teljesítmény különbség összhangban van az irodalomban olvasott értékekkel [163], [164]. Csak az idősebb erdők hordoznak az S-2 felvételeken olyan szintű texturális jellemzőket [249], amelyek lényegesen befolyásolni tudnák az osztályozás pontosságát.

17. táblázat: A CNN modellel készült Faállomány-típus osztályozás normalizált hibamátrixa

	Akác	Bükk	Fenyők	Magas kőris	Gyertyán	Tölgyek	Hárs	Virágos kőris	Cser	Mézőgás éger	Vörös tölgy	Egyéb	Mezei juhar
Akác	88.3%	0.6%	0.0%	0.0%	0.6%	4.3%	0.0%	0.0%	0.6%	4.9%	0.0%	0.6%	0.0%
Bükk	0.0%	89.4%	0.0%	0.5%	2.6%	2.1%	1.1%	0.0%	1.1%	0.0%	0.5%	2.6%	0.0%
Fenyők	0.0%	0.0%	94.5%	0.0%	0.9%	0.9%	0.0%	0.0%	0.0%	0.0%	0.0%	3.6%	0.0%
Magas kőris	0.0%	3.4%	0.0%	96.6%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
Gyertyán	0.0%	3.9%	0.0%	0.0%	78.9%	6.6%	2.6%	2.6%	3.9%	0.0%	0.0%	1.3%	0.0%
Tölgyek	0.0%	1.0%	0.0%	0.0%	3.0%	89.9%	0.0%	1.0%	3.0%	1.0%	0.0%	1.0%	0.0%
Hárs	0.0%	6.9%	0.0%	0.0%	20.7%	3.4%	65.5%	0.0%	3.4%	0.0%	0.0%	0.0%	0.0%
Virágos kőris	0.0%	0.0%	0.0%	0.0%	2.2%	0.0%	0.0%	95.7%	0.0%	2.2%	0.0%	0.0%	0.0%
Cser	0.0%	0.0%	0.0%	0.0%	2.6%	4.8%	0.0%	0.9%	89.0%	0.4%	0.4%	1.8%	0.0%
Mézőgás éger	1.0%	0.0%	0.0%	0.0%	5.1%	4.1%	0.0%	0.0%	8.2%	76.5%	1.0%	4.1%	0.0%
Vörös tölgy	0.0%	0.0%	0.0%	0.0%	5.3%	0.0%	2.6%	0.0%	2.6%	0.0%	89.5%	0.0%	0.0%
Egyéb	0.0%	6.9%	0.0%	0.0%	0.0%	3.4%	0.0%	0.0%	0.0%	0.0%	0.0%	89.7%	0.0%
Mezei juhar	0.0%	0.0%	0.0%	0.0%	6.7%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	93.3%


Az eredmény térképek (49. ábra) mindkét esetben kis mértékű túlillesztést mutatnak a gyertyános faállomány-típusokon, jellemzően a fiatal korú erdőkben, ahol a későbbi főfafaj elegyaránya még nem domináns. Ezt a feltevést az bizonyítja, hogy a gyertyános típusnak osztályozott erdőrészeket átlagos életkora 41 év volt a vizsgálat idején.

Az osztályozott szegmensek átlagos tengerszint feletti magasságából készített függőleges hisztogramon az egyes típusok folyamatos eloszlást mutatnak. A hisztogramon (50. ábra) látható az extrazonális és a klímazonális elterjedéseknek az aránya. A különböző kitettségekben gazdag területen a bükkösök 300 m alatti régiókban is előfordulnak, az alacsony megvilágítottaságú részekben. Az akácok és fenyves állományok 200-300 m magasságban, míg a magasakörtes állományok szinte kizárólag a magasabb részekben, a hegygerincek környékén fordulnak elő.


Az érvényesítés során a mézőgás éger és az akác néhány százalékos keresztbe osztályozást mutatott, ami a térképen szétszóródva jelent meg. A két főfafajnak különböző korona szerkezete és élőhelye van, így a hiba forrását a gyökerekön élő *Rhizobium* baktériumok [250] okozhatják. A nitrogén megkötés következtében hasonló temporális profilt mutatnak ezek a fafajok, mivel lombjuk még kora ősszel is zöld és nitrogén dús [251], így keveredik az osztályozásuk kismértékben.

A kor kevésbé befolyásolja közép és időskorú faállományoknál az osztályozást. A reflektancia időbeli változása nagyobb elkülönülést tud okozni [111] a faállományok között, mint ami egy időponton tapasztalható.

Az egyéb kategóriába azok a szegmensek kerültek, melyeket nem lehetett egyértelműen interpretálni, mint a nagy kiterjedésű lékeket, amelyekben magasabb volt az árnyékolás, mint a korona borítása. A második leggyakoribb eset az erdőszegélyek által vetített árnyékokat tartalmazó szegmensek ide sorolása volt.



49. ábra: A Börzsöny faállomány-típus térképe 2017-es Sentinel-2 űrfelvétel-idősor alapján



50. ábra: A faállomány-típusok vertikális eloszlása a Börzsönyben az osztályozott Sentinel-2 felvétel alapján

5.3.3 Következtetések

A faállomány-típusok osztályozására alkotott módszertan hasonló pontosságú térképezésre volt alkalmas, mint amit más tanulmányok szerzői elértek. A 88%-os összesített pontosság az S-2 térbeli és időbeli kép jellegzetességeinek felhasználásával volt lehetséges szenzor fúzió nélkül egy vegetációs időszak képanyagával. Összesen 12, a mintaterületen értékelhető mennyiségben előforduló faállomány-típust térképeztem. A műholdpár megfelelő mennyiségben szolgáltat közel felhőmentes felvételeket, amelyeket a létrehozott módszertannal konzisztens idősorra lehet alakítani.

Az elvégzett vizsgálatok alapján az űrfelvételek részletes előfeldolgozása 5%-os pontosság javulást okoz a tematikus faállomány-típus térképen. Az előfeldolgozó rendszerhez létrehozott multitemporális felvételeken alapuló felhő és felhőárnyék detektáló módszer 74%-kal pontosabb felhasználói pontossággal rendelkezik erdőterületek fölött, mint a Sen2Cor megoldása.

A gépi tanuláson alapuló osztályozó módszereknél az S-2 térbeli kép jellemzőinek felhasználása közel 5% teljesítmény javulást mutatott. Ezt mély konvolúciós neurális hálózat alapú osztályozókkal lehetett a legkönnyebben elérni. A RandomForest osztályozó modellek is képesek hasonló pontosságot elérni, de ebben az esetben az osztályozást végző operátornak jelentősen több időmunkát kell befektetnie azzal, hogy a megfelelő jellemzőket kiválassza, amelyek az adott területre és alkalmazáshoz megfelelnek. Ezek lehetnek spektrális indexek vagy másodrendű textúra mutatók, melyek segítségével hasonló eredményeket lehet elérni.

Az osztályozáshoz alkalmazott tanító adatok minőségének sokkal nagyobb hatása van az eredményre, mint az alkalmazott előfeldolgozási és az osztályozó módszereknek. A bizonytalan forrásokból származó adatok iteratív tisztítása és kiegészítése teszi lehetővé a pontosabb végeredményt. A kialakított osztályok száma a képanyag tulajdonságaitól és az elérhető tanító adat mennyiségétől függ. Az osztályok kialakítását szubjektíven végeztem el, így a modell más területeken történő alkalmazása korlátokba ütközhet. A tapasztalatok alapján az S-2 idősorán megfelelő mennyiségű jellemző áll rendelkezésre, így a területi elérhetőség tud korlátozó tényező lenni. Amennyiben kevés tanító terület áll rendelkezésre egy-egy faállomány-típusból, mesterséges adatkiterjesztéssel sikeresen ki lehet küszöbölni az

osztályozó modell túlillesztését. Az esettanulmányban a terület 1.0%-án lett tanító terület kijelölve, míg az érvényesítés a 0.9%-án készült el.

A kialakított faállomány-típus osztályok nem fedik le teljes mértékben az erdészeti igazgatásban alkalmazott csoportokat. Ennek elsődleges oka, hogy az igazgatásban alkalmazott csoportok jellemzően faanyag felhasználás alapján kerültek osztályokba, a fafajok spektrális reflektanciáját figyelmen kívül hagyva. Ennek ellenére a kialakított osztályok megfeleltethetők bizonyos mértékig a létező kategóriáknak.

Az osztályozott térkép szigorú osztályozással készült, így csak a legvalószínűbb osztály van a szegmenshez hozzárendelve. Abban az esetben, ha több fafaj is található a felső lombkoronaszintben, közel egyenlő elegyarányal (például: cseres-tölgyes), az erdőrésztelen belül bizonytalan lehet az eredmény. Az elegyarány alapján történő rugalmas osztályozás az alkalmazott tanító adattal nem volt lehetséges. Mesterséges adatkiterjesztéssel tovább lehet finomítani a kialakított osztályokat, akár kevert osztályok létrehozásával. A szenzor radiometriai és spektrális felbontása jelenleg korlátot szab ennek a fejlesztési lehetőségnek.

Az erdőtervben előírt erdőgazdálkodási beavatkozások az erdőterületek közel 10%-át érintik évente. Az évente előállítható faállomány-típus térképekkel az erdők elegyarány változása nyomon követhető, mely elsősorban a fiatal sűrűségekben végzett erdőnevelési munkákat vagy gyérítéseket követően fontos információkkal látják el a gazdálkodót. A fejlesztett módszertan alkalmas az erdőrésztelen belüli alacsonyabb területi egységek elkülönítésére.

6 Összefoglalás

Doktori kutatásom során a faállományok különböző paramétereit határoztam meg optikai űrfelvételekből, melyekkel modellezni lehet az állományok kiértékelhetőségét, kiterjedést és faállomány-típusát. A létrehozott módszerek nagy területekre kiterjeszthetők, de mindegyiknek megvan a felhasználási korlátja. Az esettanulmányokban létrehozott osztályozó modellek közvetlenül nem adaptálhatók más területekre, paraméterezésük eset függő. Ennek ellenére a kutatás eredményei továbblépést jelentenek a teljesen automatizált, felügyelet nélküli módszerek felé, melyek megkönnyítene az erdőgazdálkodás hétköznapijait.

A bemutatott esettanulmányokban idősor alapú vizsgálatot végeztem, melynek segítségével az egyes felvételeken kevésbé egyértelmű információk valószínűségét lehetett megállapítani, vagy a faállományok időbeli változása közben nyújtott jellemzőit lehetett kihasználni. A felhasznált S-2 felvételek már olyan térbeli és radiometriai felbontással rendelkeznek, amelyen a faállományok legfelső koronaszintjén megjelenő árnyalások nem simulnak el, mint a korábbi hasonló célú Landsat műholdprogram felvételein. Ennek köszönhetően a hazai viszonylatban a közepes magasságú és koronaméretű faállományok olyan részletesen jelennek meg a felvételeken, hogy a faállomány szerkezetre következtetni lehet a felvételek alapján, amit korábban csak nagyon időigényes terepi vagy költséges légi felmérésekkel lehetett elvégezni.

A koronafelületben lévő lékek detektálásához fejlesztett módszert olyan közép- és időskorú állományokban lehet alkalmazni, ahol a lékeken kívül magas a koronaszint záródása. A faállomány-típusok detektálása fiatal erdőkön is alkalmazható, amennyiben már záródott a koronaszint, és nem a talajon lévő egyéb növényzet jele rögzül az űrfelvételen.

A mély konvolúciós neurális hálózat alapú osztályozó módszerek néhány százalékos javulást mutatnak a korábban alkalmazott más gépi tanulási modellekhez képest. Amennyiben terület alapú erdészeti szolgáltatás igénybeviteléhez készül terv, mint az ápolások, tisztítások vagy gyérítések, akkor a csupán néhány százalékkal pontosabb térkép is pontosabb előzetes költségkalkulációt tesz lehetővé. Az ilyen modellek tanítása és futtatása jelentősen több számítási időt vesz igénybe, mint a hagyományos modellek. A megnövekedett számítási igényt ma már egy asztali munkaállomás is ki tudja elégíteni, de

emellett számos felhő alapú megoldás létezik. A mély konvolúciós neurális hálózat alapú osztályozáshoz a modell architektúrájának tervezésén kívül kevesebb szakértői munka elegendő, így a keretrendszerek felhasználó felületének javításával idővel a hétköznapi használatba is bekerülhetnek.

A magassági adatok bevonása a legtöbb esetben nélkülözhetetlen. A fotogrammetriai nagyon nagy felbontású felszínmodellek ma már alacsony költséggel elérhetők. Mivel az optikai űrfelvétel és a légifotó is csak a koronafelszínt rögzíti, amiből a magassági információkat ki lehet nyerni, nincs feltétlenül szükség pontosabb légi lézeres letapogatáson alapuló magassági információkra a teljes vizsgált területre. Egyes esetekben, mint például a lékdetektáláshoz szükséges hibaszűrési küszöbértékek meghatározásához, nagyon részletes felszínmodellre van szükség, amit csak alacsony repülési magasságú UAV-vel vagy légi lézeres letapogatás adataiból lehet előállítani. Az űrfelvételek geometriai korrekciójánál és topográfiai normalizációjánál is alkalmazhatók lennének ezek a frissebb, pontosabb magassági modellek.

A bemutatott esettanulmányok teljes reprodukálásához még nem áll rendelkezésre kereskedelmi forgalomban kapható megoldás, így alkalmazása más területeken korlátokba ütközik. A technológiai előrehaladásával ez változni fog. A doktori kutatásom ideje alatt több olyan platform született, melyek segítségével a jövőben sokkal könnyebben megismételhetővé válnak a bemutatott módszerek [182], [252].

7 A kutatások legfontosabb eredményeit összefoglaló tézisek

1. A Magyarországot fedő 2015 és 2017 készült Sentinel-2 felvételek felhőborítottságának pixel szintű vizsgálata alapján megállapítható, hogy nagyon sűrű interannuális idősor (havonta több megfigyelés) csak erdőrészlet szinten állítható össze. Minél nagyobb a vizsgált terület mérete, annál nehezebb teljesen felhőmentes vagy nagyon alacsony felhőborítású idősort összeállítani.
2. A különböző előfeldolgozáson átesett Sentinel-2 űrfelvételek közül az atmoszférikus korrekción és topográfiai normalizáción átesett adattípus a legmegfelelőbb hegyvidéki faállományokban található lékek területének vizsgálatára és monitorozására. Az atmoszférikus és topográfiai korrekció során a reflektancia nem lineáris transzformációja olyan irányba javítja a kontraszt viszonyokat, hogy a korona felszín és az árnyalt lékek között nő a spektrális távolság. A megnövekedett különbségnek köszönhetően megnő az a tartomány a spektrális szétkeveréssel kapott lék valószínűségeken, ahol a lék és korona osztályok közötti küszöbérték elhelyezhető, így pontosabb területkimutatások készíthetők.
3. A Sentinel-2 űrfelvétel-idősor előfeldolgozásához több szabad felhasználású alkalmazás érhető el, melyek általános felszínborítás térképezéshez nyújtanak megfelelő alapot. A kifejezetten faállományok kiértékeléséhez továbbfejlesztett előfeldolgozási lánc segítségével 5%-os pontosság javulást lehetett elérni faállomány-típusok osztályozása esetén. A fejlesztés magába foglalta a felhőmaszkok létrehozását idősor alapon, topográfiai normalizációt és az adathiányos területek pótlását adatvezérelt módon. Az adatvezérelt megoldásoknak köszönhetően más területek feldolgozásához is könnyen adaptálható a feldolgozási lánc.
4. A Kálmán-szűrésen alapuló multitemporális felhőmaszk a vizsgált képanyagon 74%-kal jobb felhasználói pontosságot mutatott, mint a Sen2Cor szoftverben készült maszk. A fejlesztett módszer azon a jelenségen alapul, hogy a vegetációs időszakban a magas lombkorona záródású faállományok látható kék tartományban rögzített reflektanciája igen stabil, így a kisebb mértékű kiugrások is már atmoszférikus zajt mutatnak.
5. A Sentinel-2 űrfelvétel-idősor egyes felvételein spektrális szétkeverés segítségével előállítható pixelenként a lék-korona részarány. A lék és korona elkülönítése az idősorban azon a feltételezésen alapszik, hogy a lékeken tapasztalható reflektancia vagy jelentősen alacsonyabb,

vagy jelentősen magasabb a fekvésük és méretük függvényében, mint a koronafelszín reflektanciája. Az idősorban található lék részarányokból levezethető egy valószínűségi érték, ami megmutatja, hogy milyen mértékben tekinthető léknek az adott pixel területe. A domborzat megvilágítottsági állapotát figyelembe véve ki lehet küszöbölni a topográfiai normalizáció okozta hibákat azzal, hogy több megvilágítási kategóriára bontjuk a vizsgált területet, majd a kategóriák tematikus eredményeit a folyamat végén egyesítjük.

6. A faállomány-típusok térképezése lehetséges olyan mély konvolúciós neurális hálózatokkal, melyek a Sentinel-2 ürfelvétel-idősor spektrális-térbeli-időbeli jellegzetességeit használják fel. A vizsgált mintaterületen 88%-os összesített pontosságot ért el az osztályozó 12 típuson. Más gépi tanulási módszerekkel összehasonlítva a mély konvolúciós neurális hálózat típusú osztályozóval kevesebb befektetett előmunkával lehet hasonló vagy jobb eredményeket elérni faállomány-típusok térképezésénél.

8 Megjegyzés

A disszertáció a 2019.12.31-ig megjelent irodalmakat és kutatásokat dolgozta fel, a benne szereplő hivatkozások a tudomány akkori álláspontjára hivatkoznak. A disszertáció szövegének szerkesztése Microsoft® Word for Office 365 (Microsoft Corporation, Redmond, Egyesült Államok) programban történt 2019 és 2021 között. A hivatkozások kezelése a Mendeley Desktop V1.19.14 (Mendeley Ltd., London, Egyesült Királyság) és a Word-be épülő Mendeley Cite-O-Matic modullal történt. A hivatkozások formája az Institute for Electrical and Electronics Engineers (IEEE) szabványt követi (<https://iee-dataport.org/sites/default/files/analysis/27/IEEE%20Citation%20Guidelines.pdf>, 2021. 01. 10.).

9 Köszönetnyilvánítás

Szeretném megköszönni Dr. Király Gézának és Dr. Czímber Kornélnak a téma kutatása alatt nyújtott segítséget. Köszönetet mondok a Földmérési és Távérzékelési Tanszék aktív és nyugdíjas munkatársainak, diploma tervezőinek és Andrési Réka évfolyamtársamnak, hogy olyan ösztönző környezetet alakítottak ki, amely segítette tudományos munkámat.

Köszönetet mondok a Soproni Egyetem Kutatási és Külügyi Rektorhelyettesi Iroda munkatársainak, különösen Sándor Mártának és az Erdőmérnöki Kar Erasmus koordinátorának Dr. Gálos Borbálának az Erasmus+ és Campus Mundi ösztöndíjak adminisztrálásával végzett munkájukért. A mobilitási ösztöndíjak segítségével jutottam el olyan kutató műhelyekbe, amelyek nagy hatása volt a munkámra.

A doktori képzésem során több, az Európai Űrügynökség (ESA) által szervezett ingyenes kurzuson és konferencián vettem részt. Az ott szerzett tapasztalatok felhasználásával készültek az esettanulmányok munkafolyamatai. Ezúton szeretnék köszönetet mondani az ESA SEOM (Scientific Exploitation of Operational Missions) programjának, amely a rendezvényeket koordinálta és támogatta.

Az esettanulmányok megvalósításában több személy és intézmény is segítette munkámat:

Kiértékelhető Sentinel-2 ürfelvételek vizsgálata a magyarországi erdőállományokra: Köszönetet nyilvánítok az EODC GmbH-nak, különösen Dr. Christian Brieke-nek és a TU Wien Geodéziai és Geoinformatikai Intézetének, hogy biztosították a kutatáshoz szükséges adatokat és infrastruktúrát, valamint a NÉBIH Erdészeti Igazgatóságának a rendelkezésre bocsájtott friss országos erdőállomány adatokért.

Lékek detektálása Sentinel-2 ürfelvételeken a Börzsöny hegységben: Köszönetet mondok az Ipoly Erdő Zrt-nek a rendelkezésre bocsájtott légi felvételekért és faállomány adatokért, valamint a TU Wien Geodéziai és Geoinformatikai Intézetének a módszertan fejlesztésében nyújtott segítségért kiemelve

Dr. Markus Hollaus-t és Prof. Dr. Norbert Pfeifer-t. A kutatásból megjelent publikációt az Austrian Research Promotion Agency 854053 S2-HQ, “EODC High Quality Sentinel-2 Services” projektje és az EFOP-3.6.2-16-2017-00018 projekt támogatta.

Faállomány-típusok térképezése Sentinel-2 űrfelvételeken a Börzsöny hegységben: A kutatás az Emberi Erőforrások Minisztériuma ÚNKP-18-3-IV kódszámú Új Nemzeti Kiválóság Programjának támogatásával készült. Köszönetet mondok a KIFÜ NIIF Programjának a HPC infrastruktúra szolgáltatásáért, melyen a számítások készültek és a University of Washington-on működő Precision Forestry Cooperative-nek (PFC) a kutatásban nyújtott segítségért, külön kiemelve Prof. Dr. Monika L. Moskal-t és Megan O'Shea-t. Külön köszönetet mondok Prof. Dr. Volker Radeloff-nak és Dr. Konrad Turlej-nek, hogy megosztották velem kutatási eredményeiket a témában.

A kutatás támogatásához a következő ösztöndíjak járultak hozzá:

Nemzeti Tehetség Program 2016, szerződésszám: NTP-NFTÖ-16_0687

Campus Mundi mobilitási ösztöndíj 2017, szerződésszám: 16/1/KA103/022832

Campus Mundi mobilitási ösztöndíj 2018, szerződésszám: CM-SMP-KA107/281741/2018

Új Nemzeti Kiválóság Program 2018, pályázati azonosító: ÚNKP-18-3-IV-SOE-18

10 Rövidítések

AI	Artificial Intelligence
ALS	Airborne Laser Scanning
AOT	Aerosol Optical Thicknesses
ARD	Analysis ready data
B	Bükkös mintaterület
B1	MSI szenzor aeroszoloakra érzékeny sávja (60 m)
B10	MSI szenzor cirrus felhőkre érzékeny sávja (60 m)
B11	MSI szenzor rövid hullámú infravörös (I.) tartományban érzékelő sávja (20 m)
B12	MSI szenzor rövid hullámú infravörös (II.) tartományban érzékelő sávja (20 m)
B2	MSI szenzor kék tartományban érzékelő sávja (10 m)
B3	MSI szenzor zöld tartományban érzékelő sávja (10 m)
B4	MSI szenzor vörös tartományban érzékelő sávja (10 m)
B5	MSI szenzor vörös él (I.) tartományban érzékelő sávja (20 m)
B6	MSI szenzor vörös él (II.) tartományban érzékelő sávja (20 m)
B7	MSI szenzor vörös él (III.) tartományban érzékelő sávja (20 m)
B8	MSI szenzor közeli infravörös tartományban érzékelő sávja (10 m)
B8A	MSI szenzor keskeny közeli infravörös tartományban érzékelő sávja (20 m)
B9	MSI szenzor vízpárára érzékeny sávja (60 m)
BOA	Bottom of Atmosphere
BRDF	Bidirectional Reflectance-Distribution Function
CNN	Convolutional Neural Networks
DDM	digitális domborzat modell
DDV	Dark Dense Vegetation
DIAS	Data and Information Access Services
DOY	Day of Year
DSM	Digital Surface Models
É	észak
EF	erdeifenyő

EODC	Earth Observation Data Centre for Water Resources Monitoring
EOV	Egységes Országos Vetület
ESA	Európai Űrügynökség
FIR	Földmegfigyelési Információs Rendszer
Forestry TEP	Forestry Thematic Exploitation Platform
GDP	bruttó hazai termék
GMT	Greenwich Mean Time
GNSS	Global Navigation Satellite System
GY-T	gyertyános-tölgyes
HPC	High Performance Computing
IC	Illumination Condition
IEEE	Institute for Electrical and Electronics Engineers
ISS	Nemzetközi Űrállomás
K	kelet
L1C	georeferált, atmoszféra tetején mért reflektancia termék
L2A	georeferált, felszíni reflektancia termék
L2ADEM	georeferált és topográfiai normalizáción átesett felszíni reflektancia termék
MACCS	Multi-sensor Atmospheric Correction and Cloud Screening
ML	Machine Learning
MRS	Multi-Resolution Képszegmentáló
MSI	MultiSpectral Instrument
nDSM	normalizált felületmodell
NDVI	Normalizált Differenciált Vegetációs Index
NIR	közeli infravörös spektrum
NNLS	nem negatív legkisebb négyzetek módszere
NÖSZTÉP	Nemzeti Ökosisztéma Szolgáltatások Térképezése és Értékelése
OEA	Országos Erdőállomány Adattár
R	korrelációs együttható
RF	Random Forest
S-2	Sentinel-2
S-2A	Sentinel-2A
S-2B	Sentinel-2B
SWIR	közép infravörös spektrum
T1	Tölgyes mintaterület 1
T2	Tölgyes mintaterület 2
TOA	Top of Atmosphere
TSZFM	tengerszint feletti magasság
UAV	Unmanned Aerial Vehicle
UTM	Universal Transverse Mercator
VIS	látható spektrum

11 Ábra- és Táblázatjegyzék

1. ábra: Különböző multispektrális műholdas szenzorok spektrális mintavételi tartományai az atmoszférikus transzmisszió függvényében (Adatok forrása: http://landsat.gsfc.nasa.gov/wp-content/uploads/2015/06/Landsat.v.Sentinel-2.png (2020. 09. 10.))	15
--	----

2. ábra: A földmegfigyelő műholdak fejlődése (Adatok forrása: https://earth.esa.int/web/eoportal/satellite-missions/ (2020. 09. 10.)).....	19
3. ábra: Egy falevél 0°, 45° és 90°-kal elforgatott képe azonos megvilágítási és felvételi betekintési szögek mellett.....	21
4. ábra: Egy gally 0°, 45° és 90°-kal elforgatott képe azonos megvilágítási és felvételi betekintési szögek mellett.....	21
5. ábra: Stilizált lombkorona szerkezet ráillesztett gömbfelülettel (A) és egy valós fa lézerszkennelt képe rá illesztett burkoló felület kontúrral (B).....	22
6. ábra: Gömb nem Lambert-féle felülettel megvilágítva egy irányból (A) és egy fakorona képe vetületével kiemelve hamis színes légifotón (B) alacsony Nap állás mellett készítve.....	22
7. ábra: Stilizált faállomány, nem Lambert-féle felületű gömbbel közelített fakoronákkal.....	23
8. ábra: Egy faállomány modell reflektanciájának mintavételezése egymáshoz képest fél fázissal eltolt, azonos méretű rácshálósával.....	23
9. ábra: Két különböző szerkezetű faállomány modell.....	24
10. ábra: Azonos tőszámú stilizált faállományok képe sík területen (A) és egy meredek területen (B) azonos betekintési és megvilágítási szögből.	24
11. ábra: Egy hegyvidéki erdőterület képe ősszel Sentinel-2 felvételen (A) és a terület domborzatmodelljére készített megvilágítási modell (B) az űrfelvétel időpontjához tartozó Nap állás paraméterekkel.	25
12. ábra: Egy hazai lombos faállomány éven belüli NDVI vegetációs index idősora és a hozzá tartozó fenológiai állapota (Adatok forrása: MOD13Q1 v6 termék a https://earthengine.google.com/-on keresztül)	26
13. ábra: Az űrfelvétel-idősor spektrális (A), spektrális-időbeli (B) jellemzői és a kivont textúra (C) a Magas körös (<i>Fraxinus excelsior</i> L.) és Bükk (<i>Fagus sylvatica</i> L.) példájával (Adatok forrása: Sentinel-2 L2A termék a https://scihub.copernicus.eu/ -n keresztül elérve 2019.01.30.)	30
14. ábra: A Börzsöny elhelyezkedése Magyarországon az alkalmazott mintaterületek megjelölésével és a területet fedő Sentinel-2 képcsempék lábnyomaival	31
15. ábra: A Tölgyes mintaterület 1 képe egy 2015-ben készült 20 cm felbontású ortofotón	32
16. ábra: A Tölgyes mintaterület 2 képe egy 2015-ben készült 20 cm felbontású ortofotón	33
17. ábra: A Bükkös mintaterület képe egy 2015-ben készült 20 cm felbontású ortofotón.....	34
18. ábra: A Sentinel-2 fedélzetén található MSI szenzor spektrális felbontása (Adatok forrása: https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/overview 2020.10.9)	34
19. ábra: A Magyarországot fedő Sentinel-2 műholdpátszák képcsempéi azonosító jelükkel jelölve (Adatok forrása: https://sentinel.esa.int/web/sentinel/missions/sentinel-2/acquisition-plans (2020. 09. 15.))	36
20. ábra: Felhőmaszk készítésének munkafolyamata.....	43
21. ábra: Felhő árnyék maszk készítésének munkafolyamata.....	43
22. ábra: A hiányzó pixelek pótlásának munkafolyamata.....	44
23. ábra: Deep Learning típusú mély mesterséges neurális hálózat 4 rejtett réteggel.....	51
24. ábra: Az erdőállomány kiértékelésének munkafolyamata.....	52
25. ábra: Az egyes erdőrészekhez tartozó felhőmentes dátumokat tartalmazó adatbázis modell	53
26. ábra: Az egyes erdőrészekhez tartozó összesítő adatbázis modell	53
27. ábra: Az egyes erdőrészekre elérhető összes kiértékelhető megfigyelések száma 2015-2017 között	55
28. ábra: Nagymaros községhatárban kiválasztott 6 db szomszédos erdőrészeletről elérhető felhő- és felhőárnyék mentes felvétel eloszlása 2015-2017 között a vegetációs időszakokban	55
29. ábra: A kialakított faállomány-típus csoportok elhelyezkedése az országban	56
30. ábra: A kiértékelhető erdőrészek darabszámainak gyakorisági eloszlása (bükk, akác, gyertyános-tölgyes és erdeifenyő) az egyes hónapokban a 2015-2017 közötti időszakból	56
31. ábra: A lécek detektálásának munkafolyamata	57

32. ábra: Mesterséges lékekkel szabdalts azonos paraméterű stilizált faállományok különböző lejtésű és kitettségű erdőterületeken azonos megvilágítási és betekintési szögek mellett, melyek a létrehozott minta kategóriákat támasztják alá.	59
33. ábra: Az egyes űrfelvételekhez tartozó szűrési küszöbértékek meghatározásának munkafolyamata	61
34. ábra: Erdő minták szórása a különböző megvilágítottsági kategóriákban és kategorizálás nélkül, 2016.08.29-én készült L2A típusú felvétel alapján	63
35. ábra: Lék és erdő spektrumok reflektancia átlagai a 3 megvilágítási osztályban.....	63
36. ábra: Területkimutatás a különböző mértékben mintavételezett spektrális minták alapján	65
37. ábra: Minimum lék részarányok az egyes időpontokban a megvilágítási kategóriákhoz.....	65
38. ábra: A terület túlbecslés arányai az egyes időpontokban a különböző megvilágítási kategóriákban	66
39. ábra: A lékek idősor alapú fuzzy valószínűség térképe a 2015-ös (A) és 2016-os (B) állapotokról a referencia lék kontúrok megjelölésével.....	70
40. ábra: A lékek idősor alapú fuzzy valószínűség térképe a 2015-2016-os összesített állapotokról a referencia lék kontúrok megjelölésével.....	71
41. ábra: A lékek idősor alapú fuzzy valószínűség térképe a 2016-os állapotokról (A) és 2015-2016 történt regeneráció térképe a területen	73
42. ábra: Egy lék nagyon nagy felbontású felületmodellje digitalizált lék és árnyalt részekkel (A) és ugyan annak a léknek a képe egy hamis infraszínes ortofotón a lék körvonalával (B).....	74
43. ábra: A faállomány-típus térképezés részletes munkafolyamat ábrája.....	76
44. ábra: Az INCEPTION V3 modell felépítése Szegedy és mtsai. [244] leírása alapján	77
45. ábra: A faállomány-típus osztályozáshoz alkalmazott CNN modell felépítése.....	78
46. ábra: Az 50%-nál kevesebb felhőborítottsággal rendelkező Sentinel-2 felvételek listája a felhasznált felvételek megjelölésével	79
47. ábra: Két felhő és árnyékaik egy Sentinel-2 RGB kompozitképen (A) és a legyártott felhő és felhő árnyék maszkok (B).....	80
48. ábra: A Börzsöny erdőborítás térképe 2017-es Sentinel-2 űrfelvétel-idősor alapján.....	82
49. ábra: A Börzsöny faállomány-típus térképe 2017-es Sentinel-2 űrfelvétel-idősor alapján.....	84
50. ábra: A faállomány-típusok vertikális eloszlása a Börzsönyben az osztályozott Sentinel-2 felvétel alapján	85

1. táblázat: távérzékelt felvétel típusok erdészeti hasznosíthatóságának csoportosítása adattípus szerint Tanács és mtsai. [60] munkájából	17
2. táblázat: Az esettanulmányban felhasznált Sentinel-2 képcempék fontosabb paraméterei	37
3. táblázat: Az egyes spektrális osztályokhoz gyűjtött mintavételezési pontok száma.	63
4. táblázat: Az egyes felvételeken a felhőmentes mintavételi pozíciók aránya.....	64
5. táblázat: A felhasznált Sentinel-2 sávok korrelációja a különböző adattípusokon.....	64
6. táblázat: Terület kimutatás a Tölgyes 1 mintaterületen.....	66
7. táblázat: Korrelációk a szűrés nélküli lék valószínűség raszterek között a különböző adattípusok esetén az egyes időpontokban a Tölgyes 1 mintaterületen.....	67
8. táblázat: Terület kimutatás a Tölgyes 2 mintaterületen.....	68
9. táblázat: Korrelációk a szűrés nélküli lék valószínűség raszterek között a különböző adattípusok esetén az egyes időpontokban a Tölgyes 2 mintaterületen.....	68
10. táblázat: Terület kimutatás a Bükkös mintaterületen	69
11. táblázat: Korrelációk a szűrés nélküli lék valószínűség raszterek között a különböző adattípusok esetén az egyes időpontokban a Bükkös mintaterületen	69
12. táblázat: Idősor alapú lék területkimutatás a Tölgyes 1 mintaterületen	71
13. táblázat: Idősor alapú lék területkimutatás a Tölgyes 2 mintaterületen	72
14. táblázat: Idősor alapú lék területkimutatás a Bükkös mintaterületen	74

15. táblázat: A modell tanításához kialakított faállomány-típusok	78
16. táblázat: Az INCEPTION V3 alapú modellel készült erdőborítás osztályozás hibamátrixa.....	81
17. táblázat: A CNN modellel készült Faállomány-típus osztályozás normalizált hibamátrixa	83

12 Irodalomjegyzék

- [1] G. Soltz and L. Fekete, *Az erdőbecsléstan kézikönyve*, 1st ed. Selmezbánya: Joerges Á. Özv. És Fia, 1882.
- [2] J. Podani, *Introduction to the exploration of multivariate data*, 1st ed. Leiden: Backhuys Publishers, 2000.
- [3] Z. Fekete, *Erdőbecsléstan*. Budapest: Budapest Nyomda, 1951.
- [4] R. Oderwald, "The Relascope Idea: Relative Measurements in Forestry," *For. Sci.*, vol. 32, no. 1, pp. 35–36, 1986, doi: 10.1093/forestscience/32.1.35.
- [5] Földművelésügyi Minisztérium, 61/2017. (XII. 21.) FM rendelet. <http://www.kozlonyok.hu/nkonline/MKPDF/hiteles/MK17220.pdf>, 2017. (2019.12.30.)
- [6] MÉM Erdőrendezési Szolgálat, *Útmutató az erdőállomány-gazdálkodási tervek (erdőtervek) készítéséhez*. Budapest: MÉM Erdészeti és Faipari Hivatal, 1986.
- [7] L. Bácsatyai and A. Gyimóthy, "GPS technika erdővel fedett területeken," *Geomatikai közlemények*, vol. V., pp. 303–308, 2003.
- [8] B. Koren, "GNSS eszközök pontosságának összehasonlítása," *Erdészeti Lapok*, vol. CLIV, no. 9, pp. 278–281, 2019.
- [9] G. Fodor, "A légi fotogrammetria térhódítása s várható jelentősége az erdőrendezési munkálatok szempontjából," *Erdészeti Lapok*, vol. 74, no. 1, pp. 41–62, 1935.
- [10] Z. Pataki, "Drónok használata az erdészeti távérzékelésben I.," *Erdészeti Lapok*, vol. CL, no. 6, pp. 168–169, 2015.
- [11] F. Remondino, L. Barazzetti, F. Nex, M. Scaioni, and D. Sarazzi, "UAV photogrammetry for mapping and 3D modeling – current status and future perspectives," *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. XXXVIII-1/, no. 1, pp. 25–31, 2012, doi: 10.5194/isprsarchives-xxxviii-1-c22-25-2011.
- [12] H. Hirschmüller, "Stereo processing by semiglobal matching and mutual information," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 30, no. 2, pp. 328–341, 2008, doi: 10.1109/TPAMI.2007.1166.
- [13] Vidékfejlesztési Minisztérium, 2012. évi XLVI. törvény a földmérési és térképészeti tevékenységről. Hungary: <https://net.jogtar.hu/jogszabaly?docid=a1200046.tv>, 2012.
- [14] R. Farkas, G. Király, and K. Szabó, "Erdők felülnézetben," *Erdészeti Lapok*, vol. CLIV, no. 4, pp. 113–115, 2019.
- [15] Miniszterelnökség, "Tájékoztató a KÖFOP-1.0.0-VEKOP-15 „Az adminisztratív terhek csökkentése” című konstrukció keretén belül a EKEIDR egységes irat- és folyamatkezelő rendszer területi közigazgatásra történő kiterjesztése” című kiemelt projektről.” Miniszterelnökség, Budapest, p. 3, 2016.
- [16] M. Möcsényi, "FAGOSZ észrevétel az erdőről, az erdő védelméről és az erdőgazdálkodásról szóló 2009. évi XXXVII. törvény és egyéb kapcsolódó törvények módosításáról szóló előterjesztéshez.” FAGOSZ, Budapest, p. 91, 2016.
- [17] Oktatási Hivatal, "Elmúlt évek statisztikái (2001/Á-2019/Á)," Budapest, 2019.
- [18] Központi Statisztikai Hivatal, "2011. ÉVI NÉPSZÁMLÁLÁS – 4. Demográfiai adatok," Budapest, 2013.
- [19] Központi Statisztikai Hivatal, "A mezőgazdaság szerepe a nemzetgazdaságban, 2018," Budapest, 2018.
- [20] G. Gutman and V. Radeloff, *Land-cover and land-use changes in Eastern Europe after the collapse of the Soviet Union in 1991*. Springer, 2016.
- [21] E. Schiberna, "Az erdőgazdálkodás helyzete." Nemzeti Agrárgazdasági Kamara, Budapest, p. 14, 2019.
- [22] Oxygen Hírgyűnökség, "Az erdészeti ágazatban is nagy a munkaerőhiány, nehezen találni fakitermelőt," Dec-2017. [Online]. Available: <http://erdo-mezo.hu/2017/12/01/az-erdeszeti-agazatban-is-nagy-a-munkaerohiany-nehezen-talalni-fakitermelot/>. (2019.12.30.)
- [23] Agrárminisztérium Sajtóiroda, "Növelte az erdőtelepítésre adható támogatás mértékét az Agrárminisztérium," 2019. [Online]. Available: <https://magyarmezogazdasag.hu/2019/10/11/novelte-az-erdotelepitesre-adhato-tamogatas-mertekeket-agrarminiszterium>. (2019.12.30.)
- [24] L. Nagy, "Elindult az Agrárminisztérium Országfásítási Programja," *Erdészeti Lapok*, vol. CLIV, no. 11, pp. 357–357, 2019.
- [25] K. K. Myers and K. Sadaghiani, "Millennials in the workplace: A communication perspective on millennials' organizational relationships and performance," *J. Bus. Psychol.*, vol. 25, no. 2, pp. 225–238,

- 2010, doi: 10.1007/s10869-010-9172-7.
- [26] O. Ringdahl, "Automation in forestry : development of unmanned forwarders," Institutionen för datavetenskap, UmeåUniversitet, 2011.
- [27] C. Molnár, "A 180 éves, kivágott bükkös csak az erdőgazdálkodás általános válságára világít rá," *index.hu*, 2019. [Online]. Available: https://index.hu/techtud/2019/05/15/a_180_eves_kivagott_bukkos_csak_az_erdogazdalkodas_altalanos_valsagara_vilagit_ra/. (2019.12.30.)
- [28] WWF Magyarország Alapítvány, "Megmenekült a Csarna-völgy!," *wwf.hu*, 2018. [Online]. Available: <https://wwf.hu/hireink/erdok/megmenekult-a-csarna-volgy/>. (2019.12.30.)
- [29] C. Mátyás, "Forecasts needed for retreating forests," *Nature*, vol. 464, no. 7293. Nature Publishing Group, p. 1271, 2010, doi: 10.1038/4641271a.
- [30] G. Thunberg, *No one is too small to make a difference by Greta Thunberg*, 1st ed. London: Penguin Books, 2019.
- [31] Mecsekerdő Zrt., "Erdőlátogatási korlátozások a téli társas vadászatok idején 2019/20," 2019. [Online]. Available: https://www.mecsekerdo.hu/erdolatogatasi-korlatozasok?fbclid=IwAR2CUUIei9Pnf2j367LmSh56xuW--IB-WjMmeWWM3sZ0W_jqn_Dx34R6iI8. (2019.12.30.)
- [32] Nemzeti Élelmiszerlánc-biztonsági Hivatal Erdészeti Igazgatóság, "Erdőtérkép," 2019. [Online]. Available: <https://erdoterkep.nebih.gov.hu/>. (2019.12.30.)
- [33] A. Bondor, *Erdőrendezés*, Bondor, An. Budapest: Mezőgazdasági Kiadó, Budapest, 1986.
- [34] G. Király, "A távérzékelés erdészeti alkalmazása," Soproni Egyetem, 2007.
- [35] Nemzeti Élelmiszerlánc-biztonsági Hivatal Erdészeti Igazgatóság, "Erdővagyon és Erdőgazdálkodás Magyarországon," *NÉBIH*, 2015. .
- [36] P. Csépanyi, "Örökerdő-gazdálkodás ökonomiai sajátosságai bükkösökben és cseresekben a Pilisi Parkerdő Zrt-nél," Soproni Egyetem, 2017.
- [37] R. Pilli and A. Pase, "Forest functions and space: a geohistorical perspective of European forests," *iForest-Biogeosciences For.*, vol. 11, no. 1, p. 79, 2018.
- [38] J. J. Zhu and F. Q. Li, "Forest degradation/decline: Research and practice," *Ying yong sheng tai xue bao= J. Appl. Ecol.*, vol. 18, no. 7, pp. 1601–1609, 2007.
- [39] M. Kovalčík, "Profitability and competitiveness of forestry in European countries," *J. For. Sci.*, vol. 57, no. 9, pp. 369–376, 2011, doi: 10.17221/138/2010-jfs.
- [40] P. Csépanyi, E. Magassy, C. Kontor, C. Szabó, and S. Szentpéteri, "A 2014. decemberi jégkár okai és következményei a Pilisi Parkerdő Zrt. által kezelt erdőállományokra," *ERDÉSZETTUDOMÁNYI KÖZLEMÉNYEK*, vol. 7, no. 1, pp. 25–41, 2017.
- [41] I. J. Bateman, G. M. Mace, C. Fezzi, G. Atkinson, and R. K. Turner, "Economic analysis for ecosystem service assessments," in *Valuing Ecosystem Services: Methodological Issues and Case Studies*, Edward Elgar Publishing, 2014, pp. 23–77.
- [42] S. F. Tóth, G. J. Ettl, N. Könnnyű, S. S. Rabotyagov, L. W. Rogers, and J. M. Comnick, "ECOSEL: Multi-objective optimization to sell forest ecosystem services," *For. Policy Econ.*, vol. 35, no. 2, pp. 73–82, Oct. 2013, doi: 10.1016/j.forpol.2013.06.011.
- [43] D. Bartha *et al.*, *A magyarországi erdők természetessége*. Budapest: WWF Magyarország, 2007.
- [44] Földművelésügyi Minisztérium Erdészeti és Vadgazdálkodási Főosztály, "Nemzeti ErdőStartégia 2016-2030." Földművelésügyi Minisztérium, Budapest, p. 63, 2016.
- [45] B. Sohngen, R. Mendelsohn, and R. Sedjo, "Forest Management, Conservation, and Global Timber Markets," *Am. J. Agric. Econ.*, vol. 81, no. 1, pp. 1–13, 1999, doi: 10.2307/1244446.
- [46] L. Bácsatyai and I. Márkus, *Fotogrammetria és távérzékelés*. Soproni Egyetem, 2010.
- [47] G. Csornai *et al.*, "Cropmon : Hungarian Crop Production Forecast By Remote Sensing," *Area*, vol. 36, no. 8, pp. 25–30, 2007.
- [48] G. Vsevolod, S. Mazai, and S. Yakovlev, "OneSoil - Make reliable agricultural decisions with AI," 2018. [Online]. Available: <https://onesoil.ai/en/>. (2019.12.30.)
- [49] Z. Somogyi, A. Koltay, T. Molnár, and N. Móricz, "Forest health monitoring system in Hungary based on MODIS products," in *Az elmélet és a gyakorlat találkozása a térinformatikában IX. : theory meets practice in GIS : Debreceni Egyetem, IX. Térinformatika Konferencia és Szakkiállítás*, 2018, pp. 325–330, doi: 978-963-318-723-4.
- [50] M. C. Hansen *et al.*, "High-Resolution Global Maps of 21st-Century Forest Cover Change," *Science (80-.)*, vol. 342, no. 6160, pp. 850–853, Nov. 2013, doi: 10.1126/science.1244693.
- [51] W. Mücke, "AlpMon - Satellite Earth Observation to highlight hot spots of damaged forest areas.," 2019. [Online]. Available: <https://www.joanneum.at/digital/referenzprojekte/alpmon/>. (2019.12.30.)
- [52] S. P. Norman, W. W. Hargrove, J. P. Spruce, W. M. Christie, and S. W. Schroeder, "Highlights of Satellite-Based Forest Using the ForWarn System Change Recognition and Tracking," *Gen. Tech. Rep.*

- SRS-180, vol. 180, pp. 1–30, 2013.
- [53] Kormányzati Informatikai Fejlesztési Ügynökség, “Földmegfigyelési Információs Rendszer (FIR) földmegfigyelési adatinfrastruktúra és szolgáltatások kialakítása,” 2017. [Online]. Available: https://kifu.gov.hu/kofof_fir. (2019.12.30.)
- [54] E. Tanács, M. Kiss, Á. Vári, and D. Kristóf, “Az ökoszisztéma-állapot térképezés keretmunkaterve,” Budapest, 2018.
- [55] R. S. Troup, “Dauerwald,” *For. An Int. J. For. Res.*, vol. 1, no. 1, pp. 78–81, 1927.
- [56] Pro Silva, *Pro Silva Principles*. ProSilva Europe Association, 2012.
- [57] I. Czirok, *A szálalásról és szálalóvágásról*, 2nd ed. Budapest: Állami Erdészeti Szolgálat, 1999.
- [58] L. Kolozs and G. Veperdi, “Élőfakészlet- és növedékmeghatározás a szálaló, illetve átalakító üzemmódú erdőkben egyváltozós fatérfogatófüggvény alkalmazásával,” *ERDÉSZETTUDOMÁNYI KÖZLEMÉNYEK*, vol. 2, no. 1, pp. 21–34, 2012.
- [59] G. Veperdi, “Mintakörös élőfakészlet-meghatározás a szálaló, illetve átalakító üzemmódú erdőkben egyváltozós fatérfogatófüggvény alkalmazásával,” in *Múlt és jövő II. Tarvágásból szálalásba*, C. Bakó, Ed. Sopron: Lővér Print Nyomdaipari Kft., 2010, pp. 50–70.
- [60] E. Tanács *et al.*, “Távérzékelte adattípusok felhasználásának lehetőségei az erdőállapot-értékelésben,” in *Erdőállapot-értékelés középhegyiségi erdeinkben Budapest*, T. Standovár, M. Bán, and P. Kézdy, Eds. Budapest: Duna-Ipoly Nemzeti Park Igazgatóság, 2017, pp. 37–107.
- [61] X. Liang *et al.*, “International benchmarking of terrestrial laser scanning approaches for forest inventories,” *ISPRS J. Photogramm. Remote Sens.*, vol. 144, pp. 137–179, Oct. 2018, doi: 10.1016/j.isprsjprs.2018.06.021.
- [62] M. Wulder, “Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters,” *Prog. Phys. Geogr. Earth Environ.*, vol. 22, no. 4, pp. 449–476, Dec. 1998, doi: 10.1177/030913339802200402.
- [63] W. B. Cohen *et al.*, “How Similar Are Forest Disturbance Maps Derived from Different Landsat Time Series Algorithms?,” *Forests*, vol. 8, no. 4, p. 98, 2017, doi: 10.3390/f8040098.
- [64] D. Kristóf, “Távérzékelési módszerek a környezetgazdálkodásban,” Szent István Egyetem, 2005.
- [65] R. A. Kirsch, L. Cahn, C. Ray, and G. H. Urban, “Experiments in processing pictorial information with a digital computer,” in *Papers and discussions presented at the December 9-13, 1957, eastern joint computer conference: Computers with deadlines to meet on XX - IRE-ACM-AIEE '57 (Eastern)*, 1958, pp. 221–229, doi: 10.1145/1457720.1457763.
- [66] J. Muñoz-Gómez, J. Bartrina-Rapesta, I. Blanes, L. Jiménez-Rodríguez, F. Aulí-Llinàs, and J. Serra-Sagristà, “4D remote sensing image coding with JPEG2000,” in *Satellite Data Compression, Communications, and Processing VI*, 2010, vol. 7810, p. 78100X, doi: 10.1117/12.860545.
- [67] J. Eggert and T. E. Stimson, “Erdaufnahmen aus der V-2-rakete/der riesenreflektor auf mt. Palomar/neues zählrohr für röntgenstrahlen,” *Phys. J.*, vol. 3, no. 8, pp. 277–279, 1947, doi: 10.1002/phbl.19470030809.
- [68] J. A. Van Allen, “Scientific Uses of Earth Satellites,” *Phys. Today*, vol. 10, no. 8, p. 30, 1957, doi: 10.1063/1.3060464.
- [69] R. Bernstein, “Digital Image Processing of Earth Observation Sensor Data,” *IBM J. Res. Dev.*, vol. 20, no. 1, pp. 40–57, 1976, doi: 10.1147/rd.201.0040.
- [70] G. D. Anderson, “The first weather satellite picture,” *Weather*, vol. 65, no. 4, p. 87, 2010.
- [71] M. A. Mulders, “Remote Sensing from Space in the 0.3 - 3.0 μm Zone,” in *Developments in Soil Science*, M. A. Mulders, Ed. Elsevier, 1987, pp. 464–468.
- [72] D. L. Helder, S. Karki, R. Bhatt, E. Micijevic, D. Aaron, and B. Jasinski, “Radiometric calibration of the Landsat MSS sensor series,” *IEEE Trans. Geosci. Remote Sens.*, vol. 50, no. 6, pp. 2380–2399, 2012, doi: 10.1109/TGRS.2011.2171351.
- [73] M. Drusch *et al.*, “Sentinel-2: ESA’s Optical High-Resolution Mission for GMES Operational Services,” *Remote Sens. Environ.*, vol. 120, pp. 25–36, May 2012, doi: 10.1016/j.rse.2011.11.026.
- [74] ESA, “Ikonos-2,” 2015. [Online]. Available: <https://earth.esa.int/eogateway/missions/ikonos-2>. (2019.12.30.)
- [75] Satellite Imaging Corporation, “WorldView-4,” 2016. [Online]. Available: <https://www.satimagingcorp.com/satellite-sensors/geoeye-2/><https://www.satimagingcorp.com/satellite-sensors/geoeye-2/>. (2019.12.30.)
- [76] W. A. Shiroma *et al.*, “CubeSats: A bright future for nanosatellites,” *Cent. Eur. J. Eng.*, vol. 1, no. 1, pp. 9–15, 2011, doi: 10.2478/s13531-011-0007-8.
- [77] C. R. Boshuizen, J. Mason, P. Klupar, and S. Spanhake, “Results from the Planet Labs Flock Constellation,” in *28th Annual AIAA/USU Conference on Small Satellites*, 2014, pp. SSC14-I–1.
- [78] C. S. R. Neigh, J. G. Masek, and J. E. Nickeson, “High-resolution satellite data open for government research,” *Eos (Washington. DC)*, vol. 94, no. 13, pp. 121–123, 2013, doi: 10.1002/2013EO130002.

- [79] Planet Inc., "Planet Labs Specifications: Spacecraft Operations & Ground Systems." Planet Inc., San Francisco, p. 15, 2015.
- [80] G. Schaepman-Strub, M. E. Schaepman, T. H. Painter, S. Dangel, and J. V. Martonchik, "Reflectance quantities in optical remote sensing-definitions and case studies," *Remote Sens. Environ.*, vol. 103, no. 1, pp. 27–42, 2006, doi: 10.1016/j.rse.2006.03.002.
- [81] G. Xian, C. Homer, and J. Fry, "Updating the 2001 National Land Cover Database land cover classification to 2006 by using Landsat imagery change detection methods," *Remote Sens. Environ.*, vol. 113, no. 6, pp. 1133–1147, Jun. 2009, doi: 10.1016/j.rse.2009.02.004.
- [82] Y. Xie, Z. Sha, and M. Yu, "Remote sensing imagery in vegetation mapping: a review," *J. Plant Ecol.*, vol. 1, no. 1, pp. 9–23, 2008, doi: 10.1093/jpe/rtn005.
- [83] J. P. Gastellu-Etchegorry, E. Martin, and F. Gascon, "DART: A 3D model for simulating satellite images and studying surface radiation budget," *Int. J. Remote Sens.*, vol. 25, no. 1, pp. 73–96, 2004, doi: 10.1080/0143116031000115166.
- [84] R. Janoutová, L. Homolová, Z. Malenovský, J. Hanuš, N. Lauret, and J. P. Gastellu-Etchegorry, "Influence of 3D spruce tree representation on accuracy of airborne and satellite forest reflectance simulated in DART," *Forests*, vol. 10, no. 3, p. 292, 2019, doi: 10.3390/f10030292.
- [85] F. Gao, Y. Shuai, T. He, C. B. Schaaf, J. G. Masek, and Z. Wang, "Influence of angular effects and adjustment on medium resolution sensors for crop monitoring," in *2013 2nd International Conference on Agro-Geoinformatics: Information for Sustainable Agriculture, Agro-Geoinformatics 2013*, 2013, pp. 296–301, doi: 10.1109/Argo-Geoinformatics.2013.6621925.
- [86] F. E. Nicodemus, "Directional reflectance and emissivity of an opaque surface," *Appl. Opt.*, vol. 4, no. 7, pp. 767–775, 1965.
- [87] W. Wanner *et al.*, "Global retrieval of bidirectional reflectance and albedo over land from EOS MODIS and MISR data: Theory and algorithm," *J. Geophys. Res. Atmos.*, vol. 102, no. 14, pp. 17143–17161, 1997, doi: 10.1029/96jd03295.
- [88] S. Liang, H. Fang, and M. Chen, "Atmospheric correction of Landsat ETM+ land surface imagery-Part I: Methods," *IEEE Trans. Geosci. Remote Sens.*, vol. 39, no. 11, pp. 2490–2498, 2001, doi: 10.1109/36.964986.
- [89] M. R. Slaton, E. R. Hunt, and W. K. Smith, "Estimating near-infrared leaf reflectance from leaf structural characteristics," *Am. J. Bot.*, vol. 88, no. 2, pp. 278–284, 2001, doi: 10.2307/2657019.
- [90] B. Ribeiro da Luz, "Attenuated total reflectance spectroscopy of plant leaves: A tool for ecological and botanical studies," *New Phytol.*, vol. 172, no. 2, pp. 305–318, 2006, doi: 10.1111/j.1469-8137.2006.01823.x.
- [91] L. Gencsi, "Erdészeti növénytan I," *Budapest, Mezőgazdasági Kiadó*, 1980.
- [92] N. Keshava and J. F. Mustard, "Spectral unmixing," *IEEE Signal Process. Mag.*, vol. 19, no. 1, pp. 44–57, 2002.
- [93] L. Eysn *et al.*, "A Benchmark of Lidar-Based Single Tree Detection Methods Using Heterogeneous Forest Data from the Alpine Space," *Forests*, vol. 6, no. 12, pp. 1721–1747, May 2015, doi: 10.3390/f6051721.
- [94] J. A. Smith, T. L. Lin, K. J. Ranson, and others, "The Lambertian assumption and Landsat data," *Photogramm. Eng. Remote Sensing*, vol. 46, no. 9, pp. 1183–1189, 1980.
- [95] T. L. Trémas, C. Déchoz, S. Lacherade, J. Nosavan, and B. Petrucci, "Sentinel-2: presentation of the CAL/VAL commissioning phase," in *Image and Signal Processing for Remote Sensing XXI*, 2015, vol. 9643, p. 964309, doi: 10.1117/12.2194847.
- [96] S. Ustin, *Remote sensing for natural resources management and environmental monitoring: manual of remote sensing*, 1st ed. Hoboken: John Wiley & Sons, 2004.
- [97] R. E. Kennedy, W. B. Cohen, and T. A. Schroeder, "Trajectory-based change detection for automated characterization of forest disturbance dynamics," *Remote Sens. Environ.*, vol. 110, no. 3, pp. 370–386, 2007, doi: 10.1016/j.rse.2007.03.010.
- [98] C. P. Qiu, M. Schmitt, P. Ghamisi, and X. X. Zhu, "Effect of the Training Set Configuration on SENTINEL-2-BASED Urban Local Climate Zone Classification," *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. XLII-2, no. 2, pp. 931–936, May 2018, doi: 10.5194/isprs-archives-XLII-2-931-2018.
- [99] M. Minnaert, *Light and Color in the Outdoors*, vol. 17. Springer Science & Business Media, 1995.
- [100] B. Tan *et al.*, "Improved forest change detection with terrain illumination corrected Landsat images," *Remote Sens. Environ.*, vol. 136, pp. 469–483, Sep. 2013, doi: 10.1016/j.rse.2013.05.013.
- [101] R. Richter, T. Kellenberger, and H. Kaufmann, "Comparison of topographic correction methods," *Remote Sens.*, vol. 1, no. 3, pp. 184–196, 2009, doi: 10.3390/rs1030184.
- [102] C. Mátyás, *Erdészeti ökológia*, 1st ed. Budapest: Mezőgazda Kiadó, 1996.
- [103] K. Hrotkó, *Gyümölcsfaiskola*, 1st ed. Budapest: Mezőgazda Kiadó, 1995.

- [104] U. Š. Vilhar *et al.*, “Chapter 9 - Tree Phenology,” in *Developments in Environmental Science*, vol. 12, Elsevier, 2013, pp. 169–182.
- [105] J. J. Walker, K. M. De Beurs, R. H. Wynne, and F. Gao, “Evaluation of Landsat and MODIS data fusion products for analysis of dryland forest phenology,” *Remote Sens. Environ.*, vol. 117, pp. 381–393, 2012, doi: 10.1016/j.rse.2011.10.014.
- [106] A. Kern, H. Marjanović, and Z. Barcza, “Evaluation of the quality of NDVI3g dataset against collection 6 MODIS NDVI in Central Europe between 2000 and 2013,” *Remote Sens.*, vol. 8, no. 11, p. 955, 2016, doi: 10.3390/rs8110955.
- [107] X. Zhang *et al.*, “Monitoring vegetation phenology using MODIS,” *Remote Sens. Environ.*, vol. 84, no. 3, pp. 471–475, 2003, doi: 10.1016/S0034-4257(02)00135-9.
- [108] M. Baumann, M. Ozdogan, A. D. Richardson, and V. C. Radeloff, “Phenology from Landsat when data is scarce: Using MODIS and Dynamic Time-Warping to combine multi-year Landsat imagery to derive annual phenology curves,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 54, pp. 72–83, Feb. 2017, doi: 10.1016/j.jag.2016.09.005.
- [109] F. E. Fassnacht *et al.*, “Review of studies on tree species classification from remotely sensed data,” *Remote Sens. Environ.*, vol. 186, pp. 64–87, Dec. 2016, doi: 10.1016/j.rse.2016.08.013.
- [110] C. J. Tucker and P. J. Sellers, “Satellite remote sensing of primary production,” *Int. J. Remote Sens.*, vol. 7, no. 11, pp. 1395–1416, 1986, doi: 10.1080/01431168608948944.
- [111] E. Grabska, P. Hostert, D. Pflugmacher, and K. Ostapowicz, “Forest Stand Species Mapping Using the Sentinel-2 Time Series,” *Remote Sens.*, vol. 11, no. 10, p. 1197, May 2019, doi: 10.3390/rs11101197.
- [112] V. J. Pasquarella, C. E. Holden, and C. E. Woodcock, “Improved mapping of forest type using spectral-temporal Landsat features,” *Remote Sens. Environ.*, vol. 210, pp. 193–207, Jun. 2018, doi: 10.1016/j.rse.2018.02.064.
- [113] M. N. Wright and A. Ziegler, “ranger: A Fast Implementation of Random Forests for High Dimensional Data in C++ and R,” *arXiv Prepr. arXiv1508.04409*, Aug. 2015, doi: 10.18637/jss.v077.i01.
- [114] D. Bacciu, “Unsupervised feature selection for sensor time-series in pervasive computing applications,” *Neural Comput. Appl.*, vol. 27, no. 5, pp. 1077–1091, 2016, doi: 10.1007/s00521-015-1924-x.
- [115] X. Zhu, C. Vondrick, D. Ramanan, and C. C. Fowlkes, “Do we need more training data or better models for object detection?,” in *BMVC 2012 - Electronic Proceedings of the British Machine Vision Conference 2012*, 2012, vol. 3, p. 5, doi: 10.5244/C.26.80.
- [116] K. I. Turlej, “Mapping Forest Types and Tree Species in Temperate Forests with Satellite Data from Landsat, Sentinel-2, and MODIS,” The University of Wisconsin-Madison, 2018.
- [117] M. A. Wulder and N. C. Coops, “Satellites: Make Earth observations open access.,” *Nature*, vol. 513, no. 7516, pp. 30–31, 2014, doi: 10.1038/513030a.
- [118] M. Garbarino *et al.*, “Gap disturbances and regeneration patterns in a Bosnian old-growth forest: A multispectral remote sensing and ground-based approach,” *Ann. For. Sci.*, vol. 69, no. 5, pp. 617–625, 2012, doi: 10.1007/s13595-011-0177-9.
- [119] M. L. Hobi, C. Ginzler, B. Commarmot, and H. Bugmann, “Gap pattern of the largest primeval beech forest of Europe revealed by remote sensing,” *Ecosphere*, vol. 6, no. 5, pp. 1–15, 2015, doi: 10.1890/ES14-00390.1.
- [120] R. E. Kennedy, Z. Yang, and W. B. Cohen, “Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr - Temporal segmentation algorithms,” *Remote Sens. Environ.*, vol. 114, no. 12, pp. 2897–2910, 2010, doi: 10.1016/j.rse.2010.07.008.
- [121] D. Phiri and J. Morgenroth, “Developments in Landsat Land Cover Classification Methods: A Review,” *Remote Sens.*, vol. 9, no. 9, p. 967, Sep. 2017, doi: 10.3390/rs9090967.
- [122] A. M. Wilson and W. Jetz, “Remotely Sensed High-Resolution Global Cloud Dynamics for Predicting Ecosystem and Biodiversity Distributions,” *PLOS Biol.*, vol. 14, no. 3, p. e1002415, Mar. 2016, doi: 10.1371/journal.pbio.1002415.
- [123] R. Coluzzi, V. Imbrenda, M. Lanfredi, and T. Simoniello, “A first assessment of the Sentinel-2 Level 1-C cloud mask product to support informed surface analyses,” *Remote Sens. Environ.*, vol. 217, pp. 426–443, Nov. 2018, doi: 10.1016/j.rse.2018.08.009.
- [124] E. C. Barrett and C. K. Grant, “Comparisons of cloud cover evaluated from Landsat imagery and meteorological stations across the British Isles,” London, 1976.
- [125] D. Frantz, E. Haß, A. Uhl, J. Stoffels, and J. Hill, “Improvement of the Fmask algorithm for Sentinel-2 images: Separating clouds from bright surfaces based on parallax effects,” *Remote Sens. Environ.*, vol. 215, pp. 471–481, Sep. 2018, doi: 10.1016/j.rse.2018.04.046.
- [126] M. Main-Knorn, B. Pflug, J. Louis, V. Debaecker, U. Müller-Wilm, and F. Gascon, “Sen2Cor for Sentinel-2,” in *Image and Signal Processing for Remote Sensing XXIII*, 2017, vol. 10427, p. 1042704.
- [127] Z. Zhu, S. Wang, and C. E. Woodcock, “Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images,” *Remote Sens. Environ.*,

- vol. 159, pp. 269–277, Mar. 2015, doi: 10.1016/j.rse.2014.12.014.
- [128] D. C. Reuter *et al.*, “The thermal infrared sensor (tirs) on landsat 8: Design overview and pre-launch characterization,” *Remote Sens.*, vol. 7, no. 1, pp. 1135–1153, 2015, doi: 10.3390/rs70101135.
- [129] S. W. Cooley, L. C. Smith, L. Stepan, and J. Mascaro, “Tracking dynamic northern surface water changes with high-frequency planet CubeSat imagery,” *Remote Sens.*, vol. 9, no. 12, p. 1306, 2017, doi: 10.3390/rs9121306.
- [130] J. L. Barker *et al.*, “MODIS Level 1 Geolocation, Characterization and Calibration Algorithm Theoretical Basis Document Version 1,” Washington, D.C., 1994.
- [131] M. Sudmanns, D. Tiede, H. Augustin, and S. Lang, “Assessing global Sentinel-2 coverage dynamics and data availability for operational Earth observation (EO) applications using the EO-Compass,” *Int. J. Digit. Earth*, vol. 13, no. 7, pp. 768–784, Jul. 2020, doi: 10.1080/17538947.2019.1572799.
- [132] EODC Earth Observation Data Centre and for W. R. M. GmbH, “Sentinel-2 coverage map,” 2019. [Online]. Available: <https://eomex.eodc.eu/cm.> (2019.12.30.)
- [133] C. Kontoes and J. Stakenborg, “Availability of cloud-free landsat images for operational projects. The analysis of cloud-cover figures over the countries of the european community,” *Int. J. Remote Sens.*, vol. 11, no. 9, pp. 1599–1608, 1990, doi: 10.1080/01431169008955117.
- [134] J. Verbesselt, R. Hyndman, G. Newnham, and D. Culvenor, “Detecting trend and seasonal changes in satellite image time series,” *Remote Sens. Environ.*, vol. 114, no. 1, pp. 106–115, 2010, doi: 10.1016/j.rse.2009.08.014.
- [135] J. P. Schütz, “Opportunities and strategies of transforming regular forests to irregular forests,” *For. Ecol. Manage.*, vol. 151, no. 1–3, pp. 87–94, 2001, doi: 10.1016/S0378-1127(00)00699-X.
- [136] N. V. L. Brokaw, “The Definition of Treefall Gap and Its Effect on Measures of Forest Dynamics,” *Biotropica*, vol. 14, no. 2, p. 158, 1982, doi: 10.2307/2387750.
- [137] R. F. Wittwer, S. Anderson, and D. W. Marcouiller, “Even and Uneven-Aged Forest Management,” 2009. [Online]. Available: https://courseweb.hopkinsschools.org/pluginfile.php/87569/mod_resource/content/2/Even and Uneven Aged Forest Management Fact Sheet and Reading.pdf. (2019.12.30.)
- [138] R. J. Petit, C. Bodénès, A. Ducousso, G. Roussel, and A. Kremer, “Hybridization as a mechanism of invasion in oaks,” *New Phytologist*, vol. 161, no. 1. Wiley Online Library, pp. 151–164, 2004, doi: 10.1046/j.1469-8137.2003.00944.x.
- [139] R. J. Schaetzl, S. F. Burns, D. L. Johnson, and T. W. Small, “Tree uprooting: review of impacts on forest ecology,” *Vegetatio*, vol. 79, no. 3, pp. 165–176, 1988, doi: 10.1007/BF00044908.
- [140] M. D. Swaine and T. C. Whitmore, “On the definition of ecological species groups in tropical rain forests,” *Vegetatio*, vol. 75, no. 1–2, pp. 81–86, 1988, doi: 10.1007/BF00044629.
- [141] F. Tinya, S. Márialigeti, I. Király, B. Németh, and P. Ódor, “The effect of light conditions on herbs, bryophytes and seedlings of temperate mixed forests in Őrség, Western Hungary,” *Plant Ecol.*, vol. 204, no. 1, pp. 69–81, 2009, doi: 10.1007/s11258-008-9566-z.
- [142] P. G. Jarvis, “The Adaptability to Light Intensity of Seedlings of *Quercus Petraea* (Matt.) Liebl.,” *J. Ecol.*, vol. 52, no. 3, p. 545, 1964, doi: 10.2307/2257848.
- [143] N. T. Welander and B. Ottosson, “The influence of shading on growth and morphology in seedlings of *Quercus robur* L. and *Fagus sylvatica* L.,” *For. Ecol. Manage.*, vol. 107, no. 1–3, pp. 117–126, 1998, doi: 10.1016/S0378-1127(97)00326-5.
- [144] A. Pommerening and S. T. Murphy, “A review of the history, definitions and methods of continuous cover forestry with special attention to afforestation and restocking,” *Forestry*, vol. 77, no. 1. Oxford University Press, pp. 27–44, 2004, doi: 10.1093/forestry/77.1.27.
- [145] S. A. Schliemann and J. G. Bockheim, “Methods for studying treefall gaps: A review,” *For. Ecol. Manage.*, vol. 261, no. 7, pp. 1143–1151, 2011, doi: 10.1016/j.foreco.2011.01.011.
- [146] B. Varga *et al.*, *A folyamatos erdőborítás fenntartása melletti erdőgazdálkodás alapjai*, vol. 1. Sopron, 2013.
- [147] M. Prodan, *Forest Biometrics*, 1st ed. Amsterdam, The Netherlands: Elsevier, 1968.
- [148] V. Dieterich, *Forstliche Betriebswirtschaftslehre*, vol. 3. P. Parey, 1948.
- [149] W. Bitterlich, “Die Winkelzählprobe - Ein optisches Meßverfahren zur raschen Aufnahme besonders gearteter Probestflächen für die Bestimmung der Kreisflächen pro Hektar an stehenden Waldbeständen,” *Forstwissenschaftliches Cent.*, vol. 71, no. 7–8, pp. 215–225, 1952, doi: 10.1007/BF01821439.
- [150] G. Szabó, “Föld- és Területrendezés 14, Erdőrendezés, Erdőtervezés, Erdőtérképezés,” *Székesfehérvár: Nyugat-Magyarországi Egyetem Geoinformatikai Kar*, 2010. .
- [151] B. Kovács, K. Kelemen, J. Ruff, and T. Standovár, “Experience of large-scale conversion from even-aged to continuous cover forestry by gap-cutting in the Királyret Forest Directorate,” *Bull. For. Sci.*, vol. 3, no. 1, pp. 55–70, 2013.
- [152] K. Kenderes, B. Mihók, and T. Standovár, “Thirty years of gap dynamics in a central European beech

- forest reserve,” *Forestry*, vol. 81, no. 1, pp. 111–123, 2008, doi: 10.1093/forestry/cpn001.
- [153] S. Koukoulas and G. A. Blackburn, “Quantifying the spatial properties of forest canopy gaps using LiDAR imagery and GIS,” *Int. J. Remote Sens.*, vol. 25, no. 15, pp. 3049–3072, 2004, doi: 10.1080/01431160310001657786.
- [154] K. Zielewska-Büttner, P. Adler, M. Ehmann, and V. Braunisch, “Automated Detection of Forest Gaps in Spruce Dominated Stands Using Canopy Height Models Derived from Stereo Aerial Imagery,” *Remote Sens.*, vol. 9, no. 5, p. 471, May 2017, doi: 10.3390/rs9050471.
- [155] R. I. Negrón-Juárez *et al.*, “Detection of subpixel treefall gaps with Landsat imagery in Central Amazon forests,” *Remote Sens. Environ.*, vol. 115, no. 12, pp. 3322–3328, 2011, doi: 10.1016/j.rse.2011.07.015.
- [156] I. Danszky, *Erdőművelés I.* Budapest: Mezőgazdasági Kiadó, 1972.
- [157] M. Deák *et al.*, “Heterogeneous forest classification by creating mixed vegetation classes using EO-1 Hyperion,” *Int. J. Remote Sens.*, vol. 38, no. 18, pp. 5215–5231, Sep. 2017, doi: 10.1080/01431161.2017.1325529.
- [158] E. Bryant, A. G. Dodge Jr, S. D. Warren, and others, “Landsat for practical forest type mapping: a test case,” *Photogramm. Eng. Remote Sensing*, vol. 46, no. 12, pp. 1575–1584, 1980.
- [159] M. Jakubauskas, L. Moskal, M. Houts, and K. Price, “Forest Characterization in the Central Plateau of Yellowstone National Park Using Multispectral High Resolution Digital Photography,” *UW Natl. Park. Serv. Res. Stn. Annu. Reports*, vol. 25, no. 1, pp. 119–122, 2001, doi: 10.13001/uwnpsrc.2001.3473.
- [160] M. Wessel, M. Brandmeier, and D. Tiede, “Evaluation of Different Machine Learning Algorithms for Scalable Classification of Tree Types and Tree Species Based on Sentinel-2 Data,” *Remote Sens.*, vol. 10, no. 9, p. 1419, Sep. 2018, doi: 10.3390/rs10091419.
- [161] S. Kollár, Z. Vekerdy, and B. Markus, “The role of geostatistical measures in the classification of riparian vegetation-case study about a Hungarian floodplain,” in *Modellierung und Simulation von Ökosystemen: Workshop Kőlpinsee 2012*, 2013, pp. 227–236.
- [162] T. Gao, J. Zhu, X. Zheng, G. Shang, L. Huang, and S. Wu, “Mapping Spatial Distribution of Larch Plantations from Multi-Seasonal Landsat-8 OLI Imagery and Multi-Scale Textures Using Random Forests,” *Remote Sens.*, vol. 7, no. 2, pp. 1702–1720, Feb. 2015, doi: 10.3390/rs70201702.
- [163] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, “Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data,” *IEEE Geosci. Remote Sens. Lett.*, vol. 14, no. 5, pp. 778–782, May 2017, doi: 10.1109/LGRS.2017.2681128.
- [164] S. Ji, C. Zhang, A. Xu, Y. Shi, and Y. Duan, “3D Convolutional Neural Networks for Crop Classification with Multi-Temporal Remote Sensing Images,” *Remote Sens.*, vol. 10, no. 2, p. 75, Jan. 2018, doi: 10.3390/rs10010075.
- [165] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*, 1st ed. Cambridge: MIT press, 2016.
- [166] R. Aszalós, I. Somodi, K. Kenderes, J. Ruff, B. Czúcz, and T. Standovár, “Accurate prediction of ice disturbance in European deciduous forests with generalized linear models: a comparison of field-based and airborne-based approaches,” *Eur. J. For. Res.*, vol. 131, no. 6, pp. 1905–1915, 2012.
- [167] J. Nagy, *A Börzsöny hegység edényes flórája*. Duna-Ipoly Nemzeti Park Igazgatóság, 2007.
- [168] T. Standovár *et al.*, “A novel forest state assessment methodology to support conservation and forest management planning,” *Community Ecol.*, vol. 17, no. 2, pp. 167–177, 2016.
- [169] D. Tapfer, “Kiemelten védett ragadozómadarak a Börzsöny-hegységben az utóbbi másfél évtizedben (1958–1973),” *Folia Hist. Musei Matraensis*, no. 2, p. 119.124, 1974.
- [170] G. Gadó, “Let Me Play the Lynx, Too!,” 2019. [Online]. Available: https://www.youtube.com/watch?v=Q8amaDkd_wM. (2019.12.30.)
- [171] L. Gálhidy, B. Czúcz, and F. Torre, “Zonal forest types, climatic variables and effect of changes for Hungary,” *Lesn. casopis--Forestry J.*, vol. 52, no. 1–2, pp. 99–105, 2006.
- [172] K. Kenderes, R. Aszalós, J. Ruff, Z. Barton, and T. Standovár, “Effects of topography and tree stand characteristics on susceptibility of forests to natural disturbances (ice and wind) in the Börzsöny Mountains (Hungary),” *Community Ecol.*, vol. 8, no. 2, pp. 209–220, 2007.
- [173] R. Solymos, “Afforestation programmes in Hungary—a story of success,” in *EFI Proc*, 2000, vol. 35, pp. 167–174.
- [174] P. Csépanyi and A. Csór, “Economic Assessment of European Beech and Turkey Oak Stands with Close-to-Nature Forest Management,” *Acta Silv. Lignaria Hungarica*, vol. 13, no. 1, pp. 9–24, 2017.
- [175] J. Aschbacher and M. P. Milagro-Pérez, “The European Earth monitoring (GMES) programme: Status and perspectives,” *Remote Sens. Environ.*, vol. 120, pp. 3–8, May 2012, doi: 10.1016/j.rse.2011.08.028.
- [176] Creative Commons, “Attribution-NonCommercial-ShareAlike 3.0 IGO (CC BY-NC-SA 3.0 IGO),” 2019. [Online]. Available: <https://creativecommons.org/licenses/by-nc-sa/3.0/igo/>. (2019.12.30.)
- [177] G. Büttner, B. Kostztra, T. Soukup, A. Sousa, and T. Langanke, “CLC2018 Technical Guidelines,” *Eur. Environ. Agency Copenhagen, Denmark*, vol. 25, no. 3436, pp. 0–60, 2017.
- [178] B. Hawryło Paweł and Bednarz, P. Weżyk, and M. Szostak, “Estimating defoliation of Scots pine stands

- using machine learning methods and vegetation indices of Sentinel-2,” *Eur. J. Remote Sens.*, vol. 51, no. 1, pp. 194–204, 2018.
- [179] P. J. Morley, D. N. M. Donoghue, J. C. Chen, and A. S. Jump, “Quantifying structural diversity to better estimate change at mountain forest margins,” *Remote Sens. Environ.*, vol. 223, pp. 291–306, 2019, doi: 10.1016/j.rse.2019.01.027.
- [180] V. M. Mantas, E. Baltazar, A. Pereira, C. Aas, and N. Lewyckyj, “Global forest disturbance data: operational monitoring and dissemination,” *AGU Fall Meeting Abstracts*. 2018.
- [181] European Commision, “The DIAS: User-friendly Access to Copernicus Data and Information,” 2018. [Online]. Available: https://www.copernicus.eu/sites/default/files/Copernicus_DIAS_Factsheet_June2018.pdf. (2019.12.30.)
- [182] T. Häme *et al.*, “Forestry-TEP responds to user needs for sentinel data value adding in cloud,” in *Conference on Big Data from Space, BiDS'2017*, 2017, pp. 239–242, doi: 10.2760/383579.
- [183] V. S. Martins, C. C. F. Barbosa, L. A. S. de Carvalho, D. S. F. Jorge, F. de L. Lobo, and E. M. L. de Moraes Novo, “Assessment of atmospheric correction methods for sentinel-2 MSI images applied to Amazon floodplain lakes,” *Remote Sens.*, vol. 9, no. 4, p. 322, 2017, doi: 10.3390/rs9040322.
- [184] AIRBUS Deffence & Space, “ESA selects Airbus Defence and Space for two new Sentinel-2 satellites.” Airbus Deffence & Space, p. 2, 2016.
- [185] W. Mücke, W. Wagner, C. Briese, and M. Aspetsberger, “Cooperative Research, Development and Operation of Earth Observation Services in the Framework of Copernicus,” *Agit J.*, vol. 2, pp. 38–45, 2016.
- [186] E. P. Baltsavias, “A comparison between photogrammetry and laser scanning,” *ISPRS J. Photogramm. Remote Sens.*, vol. 54, no. 2–3, pp. 83–94, 1999, doi: 10.1016/S0924-2716(99)00014-3.
- [187] NASA Earth Data, “Data Processing Levels,” 2019. [Online]. Available: <https://earthdata.nasa.gov/collaborate/open-data-services-and-software/data-information-policy/data-levels>. (2019.12.30.)
- [188] A. Meygret *et al.*, “SENTINEL-2 image quality and level 1 processing,” in *Earth Observing Systems XIV*, 2009, vol. 7452, p. 74520D, doi: 10.1117/12.826184.
- [189] M. Claverie *et al.*, “The Harmonized Landsat and Sentinel-2 surface reflectance data set,” *Remote Sens. Environ.*, vol. 219, pp. 145–161, 2018, doi: 10.1016/j.rse.2018.09.002.
- [190] A. V. Egorov, D. P. Roy, H. K. Zhang, M. C. Hansen, and A. Kommareddy, “Demonstration of percent tree cover mapping using Landsat Analysis Ready Data (ARD) and sensitivity with respect to Landsat ARD processing level,” *Remote Sens.*, vol. 10, no. 2, p. 209, 2018, doi: 10.3390/rs10020209.
- [191] G. Horváth, “Fény szóródás a természetben,” *Természet Világa*, vol. 117, no. 6, pp. 250–254, 1986.
- [192] G. Schmidt, C. Jenkerson, J. Masek, E. Vermote, and F. Gao, “Landsat Ecosystem Disturbance Adaptive Processing System (LEDAPS) Algorithm Description,” *Open-file Rep. 2013-1057*, no. December, pp. 1–27, 2013.
- [193] J. G. Masek *et al.*, “A landsat surface reflectance dataset for North America, 1990-2000,” *IEEE Geosci. Remote Sens. Lett.*, vol. 3, no. 1, pp. 68–72, 2006, doi: 10.1109/LGRS.2005.857030.
- [194] Y. J. Kaufman and C. Sendra, “Algorithm for automatic atmospheric corrections to visible and near-ir satellite imagery,” *Int. J. Remote Sens.*, vol. 9, no. 8, pp. 1357–1381, 1988, doi: 10.1080/01431168808954942.
- [195] L. De Keukelaere *et al.*, “Atmospheric correction of Landsat-8/OLI and Sentinel-2/MSI data using iCOR algorithm: validation for coastal and inland waters,” *Eur. J. Remote Sens.*, vol. 51, no. 1, pp. 525–542, 2018, doi: 10.1080/22797254.2018.1457937.
- [196] R. Richter and R. Sensing, “Atmospheric and Topographic Correction : Model ATCOR3,” *Aerospace*, vol. 3, no. November, pp. 1–71, 2001.
- [197] R. Richter, J. Louis, and B. Berthelot, “Sentinel-2 MSI – Level 2A Products Algorithm Theoretical Basis Document,” *European Space Agency, (Special Publication) ESA SP*, vol. 49, no. 0. pp. 1–72, 2012.
- [198] S. Hasegawa, “Metabolism of limonoids. Limonin d-ring lactone hydrolase activity in pseudomonas,” *J. Agric. Food Chem.*, vol. 24, no. 1, pp. 24–26, 1976, doi: 10.1021/jf60203a024.
- [199] A. Hollstein, K. Segl, L. Guanter, M. Brell, and M. Enesco, “Ready-to-Use Methods for the Detection of Clouds, Cirrus, Snow, Shadow, Water and Clear Sky Pixels in Sentinel-2 MSI Images,” *Remote Sens.*, vol. 8, no. 8, p. 666, Aug. 2016, doi: 10.3390/rs8080666.
- [200] O. Hagolle, M. Huc, D. V. Pascual, and G. Dedieu, “A multi-temporal method for cloud detection, applied to FORMOSAT-2, VENμS, LANDSAT and SENTINEL-2 images,” *Remote Sens. Environ.*, vol. 114, no. 8, pp. 1747–1755, Aug. 2010, doi: 10.1016/j.rse.2010.03.002.
- [201] C. Ferencz, G. Tarcsa, and J. Lichtenberger, “Correction of atmospheric effects of satellite remote sensing data (Landsat mss-noaa avhrr) for surface canopy investigations,” *Int. J. Remote Sens.*, vol. 14, no. 18, pp. 3417–3431, 1993, doi: 10.1080/01431169308904455.
- [202] R. J. Meinhold and N. D. Singpurwalla, “Understanding the Kalman filter,” *Am. Stat.*, vol. 37, no. 2, pp.

- 123–127, 1983.
- [203] D. Riaño, E. Chuvieco, J. Salas, and I. Aguado, “Assessment of different topographic corrections in Landsat-TM data for mapping vegetation types (2003),” *IEEE Trans. Geosci. Remote Sens.*, vol. 41, no. 5, pp. 1056–1061, 2003.
 - [204] J. D. Colby, “Topographic normalization in rugged terrain,” *Photogrammetric Engineering & Remote Sensing*, vol. 57, no. 5, pp. 531–537, 1991.
 - [205] V. Balthazar, V. Vanacker, and E. F. Lambin, “Evaluation and parameterization of ATCOR3 topographic correction method for forest cover mapping in mountain areas,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 18, no. 1, pp. 436–450, 2012, doi: 10.1016/j.jag.2012.03.010.
 - [206] A. S. Glassner, *An introduction to ray tracing*, 1st ed. London: Academic Press Ltd., 1989.
 - [207] M. Baatz and A. Schäpe, “Multi resolution Segmentation: an optimum approach for high quality multi scale image segmentation,” in *Beiträge zum AGIT-Symposium. Salzburg, Heidelberg, 2000*, 2000, pp. 12–23.
 - [208] K. Czímber, “Új, általános célú képosztályozó kifejlesztése nagyfelbontású, textúrával rendelkező digitális képek feldolgozására,” *Geomatikai Közlemények*, vol. XII., pp. 249–258, 2009.
 - [209] C. H. Chen, *Handbook of pattern recognition and computer vision*, 4th ed. World Scientific, 2009.
 - [210] K. Czímber, “Geoinformatika.” Soproni Egyetem, Sopron, p. 113, 1997.
 - [211] T. Blaschke, “Object based image analysis for remote sensing,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 65, no. 1, Elsevier, pp. 2–16, 2010, doi: 10.1016/j.isprsjprs.2009.06.004.
 - [212] Y. Liu, H. H. Zhang, and Y. Wu, “Hard or soft classification? large-margin unified machines,” *J. Am. Stat. Assoc.*, vol. 106, no. 493, pp. 166–177, 2011, doi: 10.1198/jasa.2011.tm10319.
 - [213] J. M. Bioucas-Dias *et al.*, “Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, no. 2, IEEE, pp. 354–379, 2012, doi: 10.1109/JSTARS.2012.2194696.
 - [214] Z. Mitraka, N. Chrysoulakis, G. Doxani, F. Del Frate, and M. Berger, “Urban surface temperature time series estimation at the local scale by spatial-spectral unmixing of satellite observations,” *Remote Sens.*, vol. 7, no. 4, pp. 4139–4156, 2015, doi: 10.3390/rs70404139.
 - [215] G. Doxani, Z. Mitraka, F. Gascon, P. Goryl, and B. R. Bojkov, “A spectral unmixing model for the integration of multi-sensor imagery: A tool to generate consistent time series data,” *Remote Sens.*, vol. 7, no. 10, pp. 14000–14018, 2015, doi: 10.3390/rs71014000.
 - [216] K. L. Dudley, P. E. Dennison, K. L. Roth, D. A. Roberts, and A. R. Coates, “A multi-temporal spectral library approach for mapping vegetation species across spatial and temporal phenological gradients,” *Remote Sens. Environ.*, vol. 167, pp. 121–134, 2015, doi: 10.1016/j.rse.2015.05.004.
 - [217] D. Dutta, A. Rahman, and A. Kundu, “Growth of Dehradun city: An application of linear spectral unmixing (LSU) technique using multi-temporal landsat satellite data sets,” *Remote Sens. Appl. Soc. Environ.*, vol. 1, pp. 98–111, 2015, doi: 10.1016/j.rsase.2015.07.001.
 - [218] J. Yu, D. Chen, Y. Lin, and S. Ye, “Comparison of linear and nonlinear spectral unmixing approaches: a case study with multispectral TM imagery,” *Int. J. Remote Sens.*, vol. 38, no. 3, pp. 773–795, 2017, doi: 10.1080/01431161.2016.1271475.
 - [219] N. Fomferra and C. Brockmann, “BEAM - The Envisat MERIS and AATSR toolbox,” in *European Space Agency, (Special Publication) ESA SP*, 2005, vol. 597, no. 597, pp. 301–303.
 - [220] M. Zuhlke *et al.*, “SNAP (Sentinel Application Platform) and the ESA Sentinel 3 Toolbox,” in *Sentinel-3 for Science Workshop, Proceedings of a workshop held 2-5 June, 2015 in Venice, Italy*, vol. 12, 2015, p. 21.
 - [221] R. S. Michalski, *Machine learning*, 1st ed., vol. 45, no. 13. Springer, 2017.
 - [222] T. H. Davenport and D. J. Patil, “Data scientist: The sexiest job of the 21st century,” *Harv. Bus. Rev.*, vol. 90, no. 10, p. 5, Oct. 2012.
 - [223] A. K. Jain, “Data clustering: 50 years beyond K-means,” *Pattern Recognit. Lett.*, vol. 31, no. 8, pp. 651–666, 2010, doi: 10.1016/j.patrec.2009.09.011.
 - [224] P.-N. Tan, M. Steinbach, and V. Kumar, *Introduction to Data Mining, (First Edition)*. USA: Addison-Wesley Longman Publishing Co., Inc., 2005.
 - [225] T. K. Ho, “Random decision forests,” in *Proceedings of the International Conference on Document Analysis and Recognition, ICDAR*, 1995, vol. 1, pp. 278–282, doi: 10.1109/ICDAR.1995.598994.
 - [226] L. Breiman, “Random forests,” *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
 - [227] L. Breiman, “Bagging predictors,” *Mach. Learn.*, vol. 24, no. 2, pp. 123–140, 1996, doi: 10.1007/bf00058655.
 - [228] R. I. Lerman and S. Yitzhaki, “A note on the calculation and interpretation of the Gini index,” *Econ. Lett.*, vol. 15, no. 3–4, pp. 363–368, 1984.
 - [229] M. Pal, “Random forest classifier for remote sensing classification,” *Int. J. Remote Sens.*, vol. 26, no. 1,

- pp. 217–222, 2005.
- [230] R. J. Zatorre, R. D. Fields, and H. Johansen-Berg, “Plasticity in gray and white: Neuroimaging changes in brain structure during learning,” *Nature Neuroscience*, vol. 15, no. 4. Nature Publishing Group, pp. 528–536, 2012, doi: 10.1038/nn.3045.
 - [231] X. X. Zhu *et al.*, “Deep learning in remote sensing: A comprehensive review and list of resources,” *IEEE Geosci. Remote Sens. Mag.*, vol. 5, no. 4, pp. 8–36, 2017.
 - [232] L. A. Zadeh, “Fuzzy logic, neural networks, and soft computing,” *Commun. ACM*, vol. 37, no. 3, pp. 77–84, Mar. 1994, doi: 10.1145/175247.175255.
 - [233] R. E. Howard, L. D. Jackel, and H. P. Graf, “Electronic Neural Networks,” *AT&T Tech. J.*, vol. 67, no. 1, pp. 58–64, 1988, doi: 10.1002/j.1538-7305.1988.tb00233.x.
 - [234] J. Sun, Y. Li, H. Lu, T. Kamiya, and S. Serikawa, “Deep Learning for Visual Segmentation: A Review,” in *Proceedings - 2020 IEEE 44th Annual Computers, Software, and Applications Conference, COMPSAC 2020*, 2020, vol. 187, pp. 1256–1260, doi: 10.1109/COMPSAC48688.2020.00-84.
 - [235] E. Ayrey and D. J. Hayes, “The use of three-dimensional convolutional neural networks to interpret LiDAR for forest inventory,” *Remote Sens.*, vol. 10, no. 4, p. 649, 2018, doi: 10.3390/rs10040649.
 - [236] M. Belgiu and L. Drăgu, “Random forest in remote sensing: A review of applications and future directions,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 114. Elsevier, pp. 24–31, 2016, doi: 10.1016/j.isprsjprs.2016.01.011.
 - [237] S. Ioffe and C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” *arXiv Prepr. arXiv1502.03167*, Feb. 2015.
 - [238] A. Karpathy, G. Toderici, S. Shetty, T. Leung, R. Sukthankar, and L. Fei-Fei, “Large-scale video classification with convolutional neural networks,” in *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, 2014, pp. 1725–1732.
 - [239] A. Bannari, D. Morin, F. Bonn, and A. R. Huete, “A review of vegetation indices,” *Remote Sens. Rev.*, vol. 13, no. 1–2, pp. 95–120, 1995, doi: 10.1080/02757259509532298.
 - [240] M. Hollaus, G. Mandlbürger, N. Pfeifer, and W. Mücke, “Land Cover Dependent Derivation of Digital Surface Models From,” in *IAPRS, Vol. XXXVIII, Part 3A – Saint-Mandé, France, September 1-3, 2010*, 2010, vol. XXXVIII, pp. 221–226.
 - [241] L. Bácsatyai, *Magyarországi vetületek*, 1st ed. Budapest: Szaktudás Kiadó Ház, Budapest, 2006.
 - [242] T. Molnár *et al.*, “Egy бүккi hőtörés távérzékeli elemzése MODIS és Sentinel-2 ürfelvételek alapján,” *Geomatikai Közlemények*, vol. XXII., no. 1, pp. 53–65, 2019.
 - [243] G. Király, C. Balla, I. Barton, G. Mészáros, B. Petrányi, and K. Szabó, “Borított felszínmodellek erdészeti felhasználása,” in *Soproni Egyetem Erdőmérnöki Kar VI. Kari Tudományos Konferencia*, 2018, pp. 118–122.
 - [244] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2818–2826.
 - [245] A. Y. Ng, “Feature selection, L 1 vs. L 2 regularization, and rotational invariance,” in *ICML '04: Proceedings of the twenty-first international conference on Machine learning*, 2004, p. 78, doi: 10.1145/1015330.1015435.
 - [246] D. P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization,” *arXiv Prepr. arXiv1412.6980*, Dec. 2014.
 - [247] R. M. Haralick, “Statistical and structural approaches to texture,” *Proc. IEEE*, vol. 67, no. 5, pp. 786–804, 1979.
 - [248] J. R. Landis and G. G. Koch, “The measurement of observer agreement for categorical data,” *Biometrics*, vol. 33, pp. 159–174, 1977, doi: 10.2307/2529310.
 - [249] S. E. Franklin, M. A. Wulder, and G. R. Gerylo, “Texture analysis of IKONOS panchromatic data for Douglas-fir forest age class separability in British Columbia,” *Int. J. Remote Sens.*, vol. 22, no. 13, pp. 2627–2632, Jan. 2001, doi: 10.1080/01431160120769.
 - [250] P. van Rhijn and J. Vanderleyden, “The Rhizobium-plant symbiosis,” *Microbiol. Rev.*, vol. 59, no. 1, pp. 124–42, Mar. 1995.
 - [251] L. Gencsi and R. Vancsura, *Dendrológia*, 1st ed. Budapest: Mezőgazda Kiadó, 1992.
 - [252] N. Gorelick, M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, and R. Moore, “Google Earth Engine: Planetary-scale geospatial analysis for everyone,” *Remote Sens. Environ.*, vol. 202, pp. 18–27, 2017, doi: 10.1016/j.rse.2017.06.031.