

SZEGEDI TUDOMÁNYEGYETEM
Természettudományi és Informatikai Kar
Földtudományok Doktori Iskola

**Gépi tanulásos osztályozó eljárások vizsgálata felszínborítás/területhasználat
térképezés szempontjából**

PhD értekezés

GUDMANN ANDRÁS VIKTOR

Témavezető: Dr. Mucsi László

Szeged, 2023

Tartalomjegyzék

1. Bevezetés és célkitűzések.....	3
2. Irodalmi áttekintés	9
2.1. Felszínborítás és a területhasználat fogalma, jelentősége.....	9
2.2. A távérzékelés szerepe a felszínborítás és területhasználat osztályozásban.....	10
2.3. A gépi tanulás és algoritmusai a képfeldolgozásban	11
2.4. Felszínborítás és területhasználat osztályozási módszerek a távérzékelésben, hazai és nemzetközi példákon keresztül	23
3. Felhasznált adatok.....	27
3.1. Coordination of information on the environment (CORINE) Land Cover (CLC)	27
3.2. Landsat felvételek	31
3.3. Sentinel felvételek.....	34
3.4. Shuttle Radar Topography Mission (SRTM).....	37
3.5. Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) Global Digital Elevation Model (GDEM)	38
4. Mintaterületek	38
5. Módszerek és eredmények.....	43
5.1. Osztályozási módszertan koncepciójának kialakítása	43
5.1.1. Algoritmusok kalibrációja.....	44
5.1.2. Algoritmusok adaptálása python programozási környezetbe	48
5.2. Az osztályozáshoz felhasználható, bemenő adatok vizsgálata	50
5.2.1. Spektrális információk és derivátumaik hatékonyságának vizsgálata az osztályozás szempontjából	51
5.2.1.1. Spektrális sávok hatékonyságának vizsgálata	52
5.2.1.2. Spektrális indexek, mint kiegészítő adatok vizsgálata	59
5.2.1.3. Adattranszformációk, mint kiegészítő adatok vizsgálata	63
5.2.2. A képelem környezetéből kinyerhető adatok vizsgálata	67
5.2.2.1 Tájmetriai indexek, mint kiegészítő adatok vizsgálata.....	67

5.2.2.2. Textúra adatokból származó információk, mint kiegészítő adatok vizsgálata.....	70
5.2.3. Temporális adatok osztályozásra gyakorolt hatásának vizsgálata	78
5.2.4. A multispektrális műholdfelvételektől független adatok hatásának vizsgálata az osztályozásra	86
5.3. Gépi tanuláson alapuló algoritmusok összehasonlítása a felszínborítás/területhasználat osztályozásban	89
6. Összefoglalás és értékelés	99
7. Irodalomjegyzék	104
8. Köszönetnyilvánítás.....	116
9. Summary	117
10. Mellékletek	120

1. Bevezetés és célkitűzések

A földfelszín egyedülálló erőforrás, amely azt a teret határolja, amiben a gazdasági tevékenységek és a környezeti folyamatok zajlanak, továbbá a környezeti erőforrások és a gazdasági javak fellelhetők. A földfelszín használatának módja határozza meg az élelem-, anyag- és energiaellátást. Azonban a Föld és erőforrásai végesek, így egyre nehezebben szolgálják ki a növekvő emberi szükségleteket (élelmiszer, víz, lakhely, szolgáltatások). Emiatt a földfelszín használata gyakran változik, amit a városi területek és az infrastruktúra bővülése jellemez, valamint a mezőgazdasági területek térhódítása a gyepek, szavannák és erdők rovására. Ezek a területhasználati változások a felszínborításra is kihatnak, és annak mélyreható átalakulását, pl. a természeti erőforrások, a természetes ökoszisztémák kiterjedésének csökkenését, a talajok funkcióinak romlását, és a termékenység hanyatlását. eredményezik (UNSD, 2013).

A felszín két elsődleges aspektusa, a felszínborítás és a területhasználat különálló, de összefüggő fogalom. Mindkettő kulcsfontosságú információforrás a földrajzi, társadalmi, és gazdasági folyamatok megértésében. A felszínborítási és területhasználati térképek, a belőlük levezetett térbeli információk és statisztikák fontosak a természeti erőforrásokkal és a környezettel (mezőgazdaság, agráripár, erdőgazdálkodás, ásványok, víz, halászat stb.), emberi erőforrásokkal (pl. oktatás, egészségügyi szolgáltatások és infrastruktúra), természeti katasztrófák és katonai konfliktusok megelőzésével és enyhítésével, a bűnmegelőzéssel és bioüzemanyag-gyártással kapcsolatos szakpolitika kialakításához és tervezéséhez (UNSD, 2013).

A felszínborítási és területhasználati térképek és a belőlük levezetett információk széleskörű felhasználása miatt fontos a tartalmilag pontos térképek gyors előállításához szükséges módszertan fejlesztése. A tematikus térképkészítés módszertani fejlesztése, már a légifelvételezés korai alkalmazása óta a távérzékelés tudományának elsődleges feladata. A Föld műholdas megfigyelése, a szisztematikus visszatérésekkel és a nagy területekre kiterjedő lefedettséggel, megnyitotta az utat a műholdképek automatikus és szisztematikus elemzésének lehetősége előtt, és ezáltal a különböző műholdképekből automatikusan előállítható tematikus térképek készítésére (Inglada, 2016). A műholdas szenzorok folyamatos bővülésének, fejlődésének köszönhetően, napjainkra az egyre jobb geometriai, spektrális és időbeli felbontású távérzékelési adatok, valamint a széleskörű, multi- és interdiszciplináris módszertan biztos alapot szolgáltat a legkülönbözőbb térképezési feladatokhoz. A műholdas távérzékeléssel olyan naprakész, nagy területeket lefedő, a terepi felvételezésnél jóval olcsóbban előállítható felvételek állnak rendelkezésünkre, amelyek kellő alapot biztosíthatnak a földrajzi vizsgálatokhoz, így a felszínborítás és területhasználat térképezéséhez is.

A közepes felbontású távérzékelés (pl. Landsat TM, ETM+, OLI, Sentinel MSI) adatok alapján térinformatikai módszerek felhasználásával készített felszínborítási és területhasználati térképek még olyan régiókban is új eredményeket nyújthatnak, ahol a meglévő digitális térképi adatbázisok megújítása és frissítése nem jelent problémát. Azonban a fejlődő régiókban a távérzékelés által szolgáltatott adatok és módszerek nélkül nem lehetséges a felszínborítás és a területhasználat térképezése, ezáltal a társadalmi és környezeti folyamatok és kölcsönhatások hatékony monitoringja és vizsgálata sem. Emellett a műholdas távérzékelés már az 1970-es évektől biztosít megfelelő térbeli, spektrális és időbeli felbontású digitális felvételeket, amelyek így hosszú időskálán rendelkezésre állnak, és felhasználhatók a naprakész információk szolgáltatása mellett, a folyamatok nyomon követésére, illetve a változások idősoros elemzésére is (Wulder et al., 2022).

A felszínborítás és a területhasználat műholdfelvételek alapján történő térképezése számos technikai, módszertani kihívást hordoz magában, ezért az új algoritmusok és az új szenzorok adta lehetőségekkel a képfeldolgozási módszerek is folyamatosan fejlődnek. Az utóbbi évtizedben a képfeldolgozási módszerek bővülésével a térinformatikai szakemberek a rendelkezésre álló téradatokból további új térbeli információkat nyerhettek ki. Azonban a felszínborítás távérzékeléses térképezéséhez képest a területhasználati térképek előállításához szükséges módszertan kevésbé kutatott téma. Emiatt a kutatásom alapvető célja ***a felszínborítás és területhasználat nagy pontosságú osztályozáshoz szükséges módszertan koncepciójának kialakítása.***

A kutatásaim során ezt a célkitűzést két különböző irányból vizsgáltam meg. Egyrészt az ***osztályozáshoz felhasználható, jelenleg legelterjedtebb képosztályozó eljárások kiválasztása és alkalmazása irányából***, másrészt ***az osztályozáshoz felhasználható adatok kiválasztása szempontjából***. A 2010-es évek áttörést hoztak a műholdas távérzékelésben felhasználható adatforrások terén, nagyrészt az Európai Űrügynökség (European Space Agency – ESA) által felügyelt Sentinel programnak köszönhetően. A megnövekedett számú közepes térbeli felbontású multispektrális optikai és mikrohullámú földmegfigyelő műholdakkal (Landsat-8, Landsat-9, Sentinel-1A, Sentinel-1B, Sentinel-2A, Sentinel-2B) a felhasználók számára rendkívül sokféle, eltérő térbeli, spektrális, időbeli és radiometrikus felbontással rendelkező adat áll rendelkezésre a Föld felszínéről. Továbbá, az új elsődleges adatforrásokból több, új, eddig nem használt derivátumok kerültek meghatározásra. A rendelkezésre álló adatok és derivátumaik számának növekedésével az egyes térképkészítési feladatokhoz felhasznált optimális adatok kiválasztásának kérdése is egyre inkább előtérbe került. Ennek egyik oka, hogy az adatok együttes használata komoly kapacitásbeli kihívásokat jelent, a másik komoly ok, hogy az osztályozáshoz használt gépi tanulást alkalmazó algoritmusok hatékonysága nincs

egyértelműen kapcsolatban a felhasznált adatok számával és felbontásaikkal (térbeli, spektrális, radiometrikus, időbeli). Ezek az algoritmusok a felhasznált adatok információ mennyiségét értékelik és azokat, amelyek markáns információtöbblettel nem rendelkeznek, hátrébb sorolják a betanításnál vagy akár el is hagyják őket. Ezek alapján az adatbázis építése során, a bemenő adatok halmazának optimális meghatározásához kapcsolódóan az alábbi célokat jelöltem ki:

- (1) A felszínborítási osztályok és a spektrális reflektancia között közvetlen kapcsolat áll fenn, amely geoinformatikai és távérzékeléses módszerekkel jól mérhető és az egyes kategóriák jól elkülöníthetők. Azonban ez a kapcsolat a területhasználat esetén, annak összetettsége miatt már nem olyan egyértelmű (Anderson et al., 1976). ***Ezért dolgozatomban célul tűztem ki, a spektrális reflektancia és a területhasználati kategóriák közötti kapcsolat statisztikai vizsgálatát. A kutatásom során arra a kérdésre kerestem a választ, hogy a reflektancia értékek és a területhasználati kategóriák között létezik-e olyan erős összefüggés, amely lehetővé teszi, hogy a műholdfelvételek alapján ezeket az osztályokat megfelelő pontossággal lehatárolhassuk.***
- (2) A távérzékelte adatok osztályozása során legtöbbször használt az elsődleges adatforrást kiegészítő bemenő adatok, a műholdképek spektrális sávjából levezetett indexek és adattranszformációk (Ayala-Izurietta et al., 2017; Fragoso-Campón et al., 2018). Ezen derivátumok mindegyikére igaz, hogy az elsődleges, többnyire a spektrális sávok felhasználásával, matematikai úton hozhatók létre. Ennek köszönhetően a kiszámításuk általában gyorsan kivitelezhető, így könnyen alkalmazhatók az egyes elemzésekben. Ezért az osztályozások során legtöbbször ezeket a metrikákat használják a spektrális sávok kiegészítéséhez. Azonban ezen derivátumok hatása az osztályozásra nem teljesen egyértelmű, több ellentmondásos eredmény is született már a témában (Kobayashi et al., 2020; Li et al., 2011). ***Ezért célul tűztem ki, hogy megvizsgáljam, hogy a spektrális indexek és az adattranszformációk felhasználásával a területhasználat osztályozás teljesítménye (pontossági értékek, futtatási idők) növelhető-e.***
- (3) A távérzékelte adatok osztályozása során, ritkábban használt az elsődleges adatforrást kiegészítő bemenő adat, a műholdképek képelemei környezetéből kinyert információ. Ilyen információk lehetnek a pixel környezetét jellemző textúra adatok vagy az adott területen található tájat leíró metrikák, tájmetriai mutatók (Mezősi és Fejes, 2004). Ezek az előállításukból eredően a spektrális értékekből nem vezethetők le, ezért új dimenzióval rendelkező, többlet információt tartalmaznak, ami alkalmas lehet a különböző osztályozások, így a felszínborítás és területhasználat

osztályozások pontosságának növelésére. Ezen adatoknak a felszínborítással való kapcsolatával és az osztályozásban történő felhasználásával már több kutatás foglalkozott (Fichera et al., 2012; Li et al., 2011; Szilassi et al., 2017). Azonban a sok osztályt tartalmazó területhasználat osztályozásokban a tájmetriai és textúra paraméterek felhasználásának hatása még nem teljesen ismert. ***Ezért célul tűztem ki, hogy megvizsgáljam, a képelem környezetéből kinyerhető adatok alkalmazak-e a területhasználat osztályozás pontosságának növelésére.***

- (4) Az utóbbi évtizedben, a távérzékelésben megjelenő új, egyre jobb térbeli, spektrális és időbeli felbontással rendelkező adatforrások nem csak a különböző adatfúziós osztályozási eljárások előtt nyitották meg az utat, hanem a kedvezőbb időbeli felbontásoknak köszönhetően a multitemporális vizsgálatoknak is. Ennek köszönhetően lehetőség nyílik nem csupán a kisebb időablakos idősoros elemzések elvégzésére, hanem folyamatos megfigyelőrendszerek kialakítására is. Emellett, a képosztályozásba is fontos szerepet kapnak az éven belüli felvételek, amelyek az időbeli különbségekből származó eltérés miatt jelentős többletinformációval rendelkeznek. Az információtöbblet miatt a több időpontban készült képek együttes használata a képosztályozásokban már régóta alkalmazott technika (Costăchioiu és Datcu, 2010; Fragoso-Campón et al., 2018; Bui és Mucsi, 2021). Azonban a nagyszámú osztályt tartalmazó, területhasználat osztályozásokban az optimális felvételek száma, és a köztük lévő időtávolság nagysága még nem meghatározott. ***Ezért célul tűztem ki, egy kiválasztott műhold, eltérő időpontban készült felvételeinek különböző kombinációkban történő felhasználásának vizsgálatát, a felvételek és köztük lévő optimális időablak meghatározását.***
- (5) A közelmúltban a műholdas távérzékelésben történt fejlesztéseknek köszönhetően a különböző típusú adatok (optikai-, radarfelvételek, magassági adatok) és tulajdonságaikból (térbeli, spektrális, időbeli felbontás) olyan információhalmaz jön létre, amellyel a képosztályozások nagy pontossággal kivitelezhetők. Az ilyen adatkombinációt felhasználó kutatások száma az új adatforrások megjelenésével jelentősen megnőtt (Balzter et al., 2015; Garg et al., 2021; Li et al., 2011; T. Zhou et al., 2018). Azonban a sok kategóriát tartalmazó (pl. CORINE), területhasználat osztályozásokban az ideális adatkombinációk még nem egyértelműen meghatározottak. ***Ezért célul tűztem ki, hogy vizsgáljam a spektrális sávok és a független elsődleges adatforrások kettős kombinációkban történő felhasználásának hatását a felszínborítás és területhasználat osztályozás pontosságára vonatkozóan.***

Az osztályozó eljárásokkal kapcsolatban az alábbi kérdésekre kerestem a választ:

- (6) A távérzékeléses képelemzés az adatok minőségi javulásának és a különböző informatikai módszerek fejlődésének köszönhetően egy folyamatosan fejlődő tudományág, amihez már számos alkalmazást fejlesztettek ki. A jól ismert statisztikai megközelítések mellett több módszer a gépi tanulás területéről származó technikákon alapul (Waske et al., 2009). Ennek két fő oka közül az egyik, hogy 2014 óta több, nagyobb térbeli, spektrális és időbeli felbontású földmegfigyelési platformot hoztak létre, amelyek különböző hullámhossz-tartományokon működnek, a láthatótól a mikrohullámúig. Ezeknek a rendszereknek köszönhetően a távérzékelés minden eddiginél részletesebb információkat szolgáltat a földfelszínről és annak környezeti állapotáról. Ezek osztályozása igen bonyolult és összetett, amit a régebbi, jól ismert osztályozók (pl: ISODATA, *Maximum-likelihood*, *k*-legközelebbi szomszéd) csak korlátozottan képesek megoldani (Richards, 2005). Másrészt, az utóbbi évtizedben a mesterséges intelligencia tudományához tartozó gépi tanulás (*machine learning*) és mély tanulás (*deep learning*) osztályozó eljárások (tartóvektor-gép – *support vector machine*, döntési fa – *decision tree*, véletlen erdő – *random forest*, gradiens-növelő gépek – *gradient-boosting machines*, mély neurális hálók – *deep neural networks*) és alkalmazási módszereik száma dinamikusan növekedett, ami napjainkban is folytatódik. A gépi tanulási algoritmusok egyik leggyakoribb alkalmazási módja a távérzékelésben az irányított osztályozás, amely talán a legszélesebb körben alkalmazott képosztályozási módszer (Waske et al., 2009). Mindegyik gépi tanulási algoritmusnak megvannak a maga előnyei és hátrányai, így a különböző osztályozási szituációkban különböző hatékonysággal alkalmazhatók. Napjainkra, a különböző adatforrások száma miatt, a lehetséges osztályozási szituációk (adatfúziók, derivátumok, tanítóadatok, másodlagos adatok, jellemző kinyerés stb.) száma szinte korlátlan, így a legjobb algoritmus meghatározása csak adott korlátok között lehetséges. ***Ennek figyelembevételével célul tűztem ki, a szakirodalomban jelenleg leggyakrabban használt, többsztályos gépi tanulási algoritmusok és egy hagyományos osztályozó algoritmus összevetését a felszínborítás és területhasználat térképezésében. További célom volt meghatározni közülük, azt az algoritmust, amivel a CORINE Land Cover adatbázis 3. hierarchia szintű nomenklatúrájával a legnagyobb pontosságú felszínborítási/területhasználati térképek készíthetők el.***

- (7) Napjainkra az egyes osztályozási algoritmusok alkalmazásával előállított felszínborítási/területhasználati térképek pontossága mellett az algoritmusok teljesítménye is egy kritikus szempont az eredmények értékelése során. Az algoritmusok teljesítménye több tényezőtől felépülő összetett mutató, amely magába foglalja a különböző adathalmazokon (tanító, teszt, validáló) számított pontossági értékeken túl a tanítási hiba mértékét, a becslések megbízhatóságát, a modellépítési időt és az ezzel szorosan összefüggő paraméterbecslési időt, és az ismeretlen adatokon történő becslési időt. Az algoritmusok teljesítményének fontossága megnövekedett az utóbbi években a rendelkezésre álló adatok számának növekedése, az osztályozandó terület nagysága és a minél gyorsabb információk biztosításának követelménye miatt. Emiatt megnövekedtek a teljesítményelvárások, mind a sebesség (pl.: nagy adatkockák, operatív megfigyelő rendszerek és közel valós idejű alkalmazások esetében), mind a pontosság és a megbízhatóság terén is. ***Az említett elvárások növekedése miatt a pontosságok összehasonlításán túl, célul tűztem ki az egyes algoritmusok és az általuk generált modellek teljesítményének vizsgálatát, a modellek és az azok létrehozását leíró adatok és az eredményül kapott térképek elemzését.***
- (8) A távérzékelte adatokra épülő térképezési feladatoknál már a kezdeti idők óta felmerülő követelmény az adott módszer alkalmazhatósága nagyobb területen vagy adathalmazon (Anderson et al., 1976). Azóta erre a kérdésre már több válasz is született különböző módszerek formájában, amikkel számos regionális, nemzeti, kontinentális vagy akár globális lefedettségű térképet állítottak elő. Az ilyen, nagyobb területeket bemutató térképek szükségesek a különböző léptékű folyamatok, mint például a klímaváltozások okainak és következményeinek megértéséhez, és az ezekhez társuló tudományos tevékenységekhez. Az ilyen jellegű kutatások sokszor használt adatai a felszínborítási és területhasználati térképek, így az ezek előállítását célzó módszereknél is felmerülő kérdés a módszer kiterjesztésének, skálázhatóságának lehetősége és mértéke. A rendelkezésre álló nagy mennyiségű, egyre jobb felbontási tulajdonságokkal rendelkező felvételező rendszereknek köszönhetően, az adatsűrűség növekedése feldolgozási problémaként jelenik meg. ***A kiterjeszetheység és az adatsűrűség növekedése által generált kihívás miatt célom volt az algoritmusok skálázhatóságának vizsgálata, azaz a bemenő adatok számának és/vagy az osztályozni kívánt terület nagyságának növekedésével járó pontosságváltozás elemzése.***

2. Irodalmi áttekintés

2.1. Felszínborítás és a területhasználat fogalma, jelentősége

A Föld szárazföldi felszínének elemzése során a felszínborításról és a területhasználatról gyűjtött információk meghatározó jelentőségűek lokális, nemzeti és nemzetközi szinten egyaránt (Wulder et al., 2018). Ezt a két fogalmat sokszor használják szinonimaként, bár jelentésükben fontos eltérések vannak. Általános megfogalmazás szerint, a felszínborítás a Föld felszínének biofizikai lefedettségére utal, ezáltal térbeli információt nyújt a földfelszín, a domborzat, a klíma és a talaj kapcsolatáról (FAO, 1997). A felszínborítási térkép osztályain a felszínen lévő természetes vagy mesterséges objektumokat értjük, mint például erdők, vizek, mesterséges felszínek. A felszínborítási kategóriák meghatározása elég egyértelműnek tűnhet, de (Comber et al., 2005) rámutattak arra, hogy a kategóriák definícióiban lehetnek különbségek a földrajzi adottságok közötti eltérések miatt. Ilyen lehet pl. az erdők fogalmában, egy európai lombhullató erdő és egy dél-amerikai őserdő között.

A területhasználat a felszínborításnál összetettebb fogalom, mivel a területhasználat egy adott terület társadalmi-gazdasági hasznosítását mutatja meg (FAO, 1997). Az adott területen élő emberek tevékenységeinek hatására kialakuló egyedi területeket/objektumokat jelentik. Ilyenek lehetnek egyes városi övezetek: ipari, kereskedelmi, logisztikai, rekreációs, lakó vagy különböző mezőgazdasági művelésék: szántó, gyümölcsös, szőlős, legelő vagy más egyéb tevékenység miatt kialakuló területek: meddőhányók, építési területek. A területhasználat fogalmából adódik, hogy minden társadalmi, gazdasági, politikai komplexnél eltérő kategóriák, és a megegyező nevű kategóriák lehatárolásánál is különbségek lehetnek (pl.: nyugat-európai belváros és indiai belváros, észak-amerikai ipari terület és ázsiai ipari terület stb.). A területhasználat, specifikus kategóriáinak köszönhetően, széleskörű betekintést nyújt az emberi tevékenység környeztet módosító tevékenységébe, továbbá a társadalom és környezete közötti kapcsolatába és kölcsönhatásaiba.

Ezeknek a kölcsönhatásoknak és az emberi tevékenységnek az eredménye a területhasználat változása, amely a legtöbb esetben magával hozza a felszínborítás megváltozását is (Turner et al., 1995). A felszínborítás és a területhasználat változásai különböző lokális és globális folyamatokra fejtik ki hatásukat, mint például a szén körforgása, a hidrológiai körforgás és a biodiverzitás csökkenése stb. (Foley et al., 2005). A felszínborítás és a területhasználat változások folyamatos gyorsulásával, amit főleg a városok terjeszkedése, a gazdasági növekedés, és az implicit-explicit módon növekvő emberi szükségletek okoznak, a felszínborítás és területhasználat térképezése és a változások nyomon követése kulcsfontosságú eszközzé vált a környezetvédelmet és a fenntartható fejlődést célzó tervezési munkákban. Emellett ezen adatbázisok több tudományos kutatásban is alapinformációnak számítanak, mint

például a mezőgazdaságban (Bezdan et al., 2019; Pérez-Hoyos et al., 2020), a hidrológiában (Liaqat et al., 2021; Tobak et al., 2019), az ökológiában (Csikós és Szilassi, 2021b) és a változásvizsgálatokban (Szilassi, 2017). A széleskörű felhasználási lehetőségeik miatt a megbízható, pontos felszínborítási és területhasználati térképek előállításuk egy alapvető feladat a távérzékelésben (Townshend, 1992).

2.2. A távérzékelés szerepe a felszínborítás és területhasználat osztályozásban

A felszínborítási térképek készítése volt a mozgatórugója a térbeli adatok gyűjtésével, feldolgozásával és értelmezésével foglalkozó földrajzi információs rendszerek létrehozásának az 1960-as évek elején (Tomlinson, 1967), amiből a 2000-es évek elejére a geoinformatika tudománya (GI Science) fejlődött ki. A távérzékelési technológia fejlődése révén a felszínborítási és területhasználati térképek előállításához szükséges elsődleges térbeli adatok, elsősorban a Landsat program globális lefedést biztosító, közepes felbontású műholdfelvételei az 1980-as évek közepétől rendelkezésre állnak (Townshend et al., 1991).

A felszínt borító anyagok által visszavert energiát mérik a műholdak szenzorjai, így a felszínborításra jellemző reflektancia értékek számíthatók. A területhasználat és a reflektancia értékek közötti kapcsolat azonban már nem ennyire egyértelmű. Ennek oka a már említett definícióból és a területi különbségekből ered, ami miatt a területhasználati kategóriák száma sokkal nagyobb, mint a felszínborítási kategóriáké. Az osztályok magas száma miatt a kategóriák nevezéktani értelemben, tartalmilag hasonlóak (így szétválaszthatóságuk alacsony), ami tovább nehezíti az osztályozást. Továbbá a területhasználati kategóriák lehatárolása sok esetben nem egyértelmű, távérzékelési szempontból egymást nem kizáró csoportok. Emiatt a pixelek spektrális információi sok esetben nem nyújtanak elegendő alapot az osztályozások nagy pontosságú elvégzéséhez (Bruzzone et al., 1997; Rodriguez-Galiano és Chica-Olmo, 2012; Wilkinson, 2005).

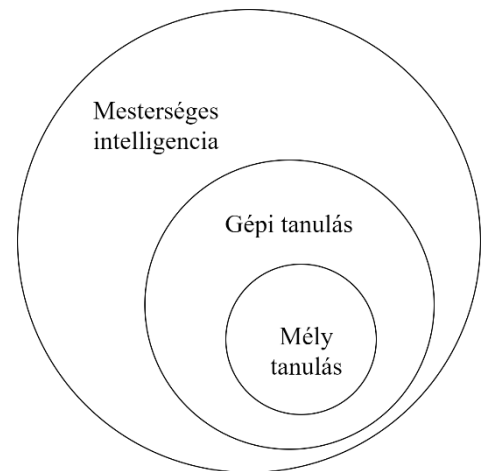
A pontosság javítása érdekében új adatokat kell bevonni az osztályozásba, ami csökkentheti az osztályozás teljesítményét (előkészítési, futtatási idő növekedése). Ezért annak érdekében, hogy megtaláljuk a megfelelő egyensúlyt az osztályozás pontossága és teljesítménye között, a megfelelő változók kiválasztása kulcsfontosságú kérdés lett, így a kutatások egyik fő témájává is vált. A távérzékelésben az osztályozás és az ahhoz felhasznált adatok és változók kiválasztása alapvetően adatvezérelt: függ a célterületre rendelkezésre álló különböző adatok típusától, az egyes típusú adatokból rendelkezésre álló felvételek számától, és ezen adatok tulajdonságaitól (térbeli és spektrális felbontás). Ezek alapján tudjuk meghatározni az osztályozásba bevonható lehetséges adat variációkat, mint a különböző szenzorok felvételeit együttesen alkalmazva (Garg et al., 2021; T. Zhou et al., 2018), több, különböző időpontban, azonos szenzorral készült képeket kombinálva (Bui és Mucsi, 2021;

Fragoso-Campón et al., 2018; Gudmann és Mucsi, 2019), vagy az eredeti képből új jellemzőket (indexek, textúrák, transzformációk) kinyerve (Gudmann et al., 2019, 2020; Gudmann és Mucsi, 2019; Pflugmacher et al., 2019; T. Zhou et al., 2018).

Napjainkra egyre több, ingyenesen elérhető közepes felbontású távérzékelt adatforrás áll rendelkezésünkre a felszínborítás/területhasználat térképezéséhez, melyek tulajdonságai (térbeli, spektrális, időbeli felbontás, közel 50 évet lefedő archívum) egyre kedvezőbb alapot biztosítanak a nagy pontosságú osztályozásokhoz, változáselemzésekhez. Azonban az egyre jobb tulajdonságú szenzorok és a belőlük kinyert változókból előállított adathalmazok dimenziója hatalmas kihívást jelent a feldolgozás szempontjából. Ezen adathalmazok felhasználása a felszínborítás/területhasználat osztályozásban a hagyományos, többnyire lineáris (pixel, szubpixel alapú) osztályozó eljárásokkal nem hoznak kellően pontos és megbízható eredményeket. Erre a kihívásokkal teli feladat megoldására használhatók fel a gépi tanulás (*machine learning*) osztályozó algoritmusai. A különböző algoritmusokat, mint például a döntési fákat (*decision tree*), véletlen erdőket (*random forest*), tartó-vektor gépeket (*support vector machine*), mesterséges neurális hálókat (*artificial neural networks*) vagy gradiens-növelő gépeket (*gradient boosting machines*) tesztelhetjük és összehasonlíthatjuk.

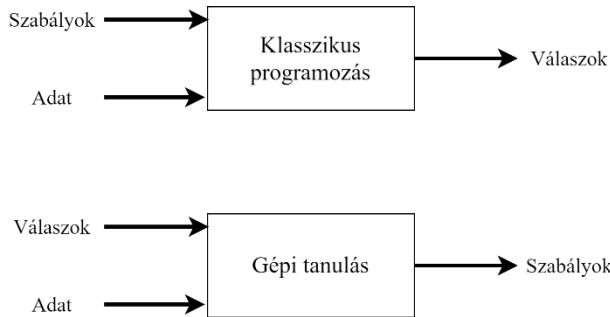
2.3. A gépi tanulás és algoritmusai a képfeldolgozásban

A gépi tanulás a mesterséges intelligencia (*artificial intelligence*) tudományágának része, aminek olyan módszerek előállítása a célja, amelyek az adatokból tanulás által ismétlődően optimalizálják saját teljesítményüket (1. ábra) (Waske et al., 2009). A mesterséges intelligencia kutatása az 1950-es kezdődött, azt a kérdést kutatva, hogy tud-e a számítógép gondolatot létrehozni? A kérdés megválaszolása érdekében, Alain Turing, a fogalmi viták helyett létrehozott egy később róla elnevezett elméleti gyakorlatot (TURING, 1950), és innentől számíthatjuk a mesterséges intelligencia tudományát (Haugeland, 1989). Az általános megfogalmazása szerint a mesterséges intelligencia: erőfeszítések arra, hogy automatizáljuk azon intellektuális feladatokat, amiket alapvetően emberek végeznek el (Chollet, 2017).



1. ábra Mesterséges intelligencia, gépi tanulás, és mély tanulás, (Chollet, 2017) alapján.

A gépi tanulás az 1990-es években kezdett el fejlődni és gyorsan a legnépszerűbb része lett a mesterséges intelligencia tudományának (Chollet, 2017). A gépi tanulás ahelyett, hogy szabályok sorozatát alakítaná ki, amelyek nagyban függenek az adott minta adatsortól, egy olyan modellt próbál felépíteni, ami képes felismerni az adathalmazban lévő mintázatokat. Ezek



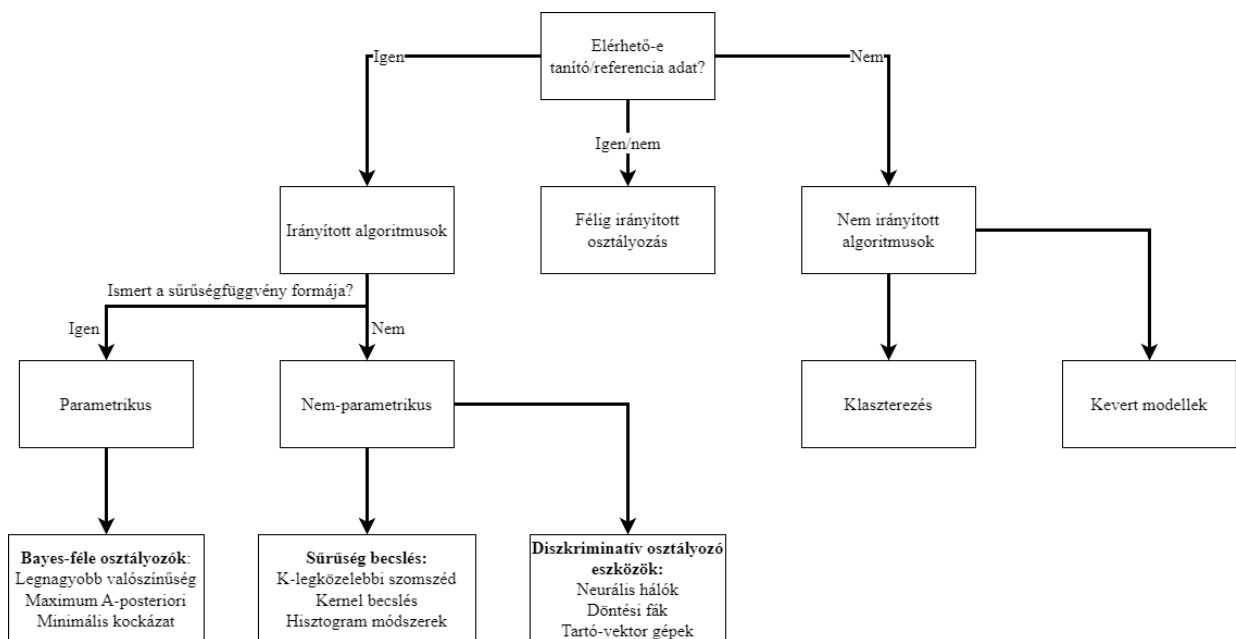
a minták kisebb mértékben függenek az adathalmaztól, és más adatsoron is sikeresen lehet alkalmazni őket. A gépi tanulás a következő kérdésre keresi a választ: képes a gép megtanulni önmagától, hogyan kell egy feladatot megoldani? Azaz ahelyett, hogy manuálisan határoznánk meg szabályokat, a

2. ábra Hagyományos programozás és a gépi tanulás paradigmája (Chollet, 2017) alapján.

gép képes-e az adatok alapján saját szabályokat létrehozni? A gépi tanulás

során a felhasználó a bemenő és a várt adatokat adja meg, amelyek alapján az algoritmus formulákat alkot (2. ábra). Emiatt a gépi-tanulós rendszerek nem külsőleg vannak programozva, hanem betanítva vannak.


A gépi tanuláshoz több közös metszete (módszerek, algoritmusok) van a statisztikával és az adatbányászattal, de mindegyik tudomány különbözik a másiktól, főleg céljaik miatt. A statisztika egy rendszert próbál megérteni az arról rendelkezésre álló adatok alapján, míg az adatbányászat célja a meglévő, hatalmas mennyiségű (petabyte, exabyte ...) adatokból minél hatékonyabb módon információk kinyerése. Ezekkel ellentétben a gépi tanulás szabályokat, összefüggéseket keres egy adott, kisebb nagyságú adathalmazban, a feladatok automatizálása céljából (Karimi, 2014).



3. ábra Algoritmusok besorolása (Waske et al., 2009) alapján.

A távérzékelésben a gépi tanulást többféle feladatra használhatjuk, úgymint az osztályozás, a regresszió, a klaszterezés (csoportosítás), a tulajdonság kinyerés, a dimenziócsökkentés és a sűrűség becslés (Waske et al., 2009). A bemenő adatok alapján háromféle csoportba sorolhatjuk a gépi tanulás módszereit: irányított algoritmusok (amelyeknél egyes eseteket ismerünk, van előzetes tudásunk az adatról, és azok fel vannak címkézve), irányítatlan algoritmusok (nincs előzetes tudásunk) és félig automatikus algoritmusok (a betanítás nem csak az ismert esetek alapján történik). A távérzékelésben a gépi tanulási algoritmusokat legtöbbször irányított osztályozáshoz alkalmazzák (Waske et al., 2009). Az irányított, gépi tanulást alkalmazó osztályozó algoritmusok közül főleg a nem-parametrikus algoritmusokat szokták használni a szakemberek, melyek megfelelően alkalmazhatók a kiegyensúlyozatlan és nem normális eloszlású adathalmazokon is (3. ábra). Ezen algoritmusok közül azokat mutatom be részletesen a következő fejezetekben, amelyeket a kutatásomban felhasználtam, mint a tartó-vektor gép, a mesterséges neurális háló, a döntési fa, a véletlen erdő és a hisztogram-alapú gradiens-növelő fa.

A tartó-vektor gép (*Support Vector Machine – SVM*) egy alapvetően bináris osztályozó eljárás, amely a Vepnik-Chervonenkis dimenzióelméleten és a minimális strukturális kockázati



4. ábra A tartó-vektor gép két lehetséges döntési határa (Tan et al., 2006) alapján.

A módszer egyedi jellege, hogy a döntési határt a tanuló esetek egy részhalmazának segítségével reprezentálja, amelyeket tartó-vektoroknak (*support vector*) nevezünk (4. ábra) (Tan et al., 2006). A nagy margóval rendelkező döntési határoknak általában jobb az általánosítási hibájuk, mint a kis margóval rendelkezőknek. Intuitívan, ha a margó kicsi, akkor a döntési határ bármilyen kis perturbációjának elég jelentős hatása lehet az osztályozásra. A kis margóval rendelkező döntési határokat létrehozó osztályozók ezért hajlamosabbak a modell túlillesztésre és korábban nem látott eseteken gyakran rosszul általánosítanak (Tan et al., 2006).

A tartó-vektor gép betanulási fázisában, bináris osztályozási probléma esetén egy egyenes egyenletének w és b paramétereit keressük (5. ábra):

$$w * x + b = 0$$

Ezeket a paramétereket úgy kell megválasztanunk, hogy az alábbi két feltétel teljesüljön:

$$w * x + b \geq 1, \text{ ha } y = 1$$

$$w * x + b \leq -1, \text{ ha } y = -1$$

Ezek a feltételek fogalmazzák meg, hogy az összes tanulóesetnek, amik a négyzet osztályba tartoznak ($y=1$), a hipersík felső margóján ($w * x + b = 1$) vagy felette kell lenniük. Míg, a kör kategóriába tartozó összes tanulóesetnek ($y=-1$) a hipersík alsó margóján ($w * x + b = -1$) vagy alatta kell lennie. Ezen feltételek mellett teljesülnie kell annak az elvnek is, hogy a döntési határ margója a lehető legnagyobb legyen. Ezt úgy lehet elérni, hogy minimalizáljuk az alábbi célfüggvényt:


$$f(w) = \frac{\|w\|^2}{2}$$

Ezt az elvet figyelembe véve egy lineáris tartó-vektor gép tanulási feladatát így összegezhethetjük:


$$\min_w \frac{\|w\|^2}{2}$$

ahol teljesül: $y_i(w * x_i + b) \geq 1, i = 1, 2, \dots, N$

Ez a konvex optimalizálási probléma a legegyszerűbben a Lagrange-szorító módszerrel oldható meg (Tan et al., 2006). Abban az esetben, ha nem találunk megfelelő hipersíkot az adathalmaz felosztására (nem szeparálható eset), azaz nem megoldható az optimalizáló probléma, bevezethetünk egy új paramétert. A nem megfelelő hipersík okozta hibák elkerülése érdekében az algoritmus felépítése során paraméterként állíthatjuk be az elfogadható hibát ($cost - C$). Ezzel a paraméterrel befolyásolható, hogy a döntési határon túlra is eshet ellentétes



5. ábra A tartó-vektor gép döntési határainak és margóinak egyenletei (Tan et al., 2006).



6. ábra Az adattér átvétele magasabb dimenziójú térbe (Bodon és Buza, 2014).

kategóriájú pont, és az milyen távolságra lehet a döntési határtól (minél nagyobb a távolság, annál nagyobb a hiba) (Bodon és Buza, 2014). A tartó-vektor gépeknek két fő típusa van, a lineáris és a nem-lineáris tartó-vektor gépek. A lineáris tartó-vektor gépeknél a döntési határ mindig egy egyenes (két dimenziónál), sík (három dimenziónál), vagy egy hipersík (több mint 3 dimenziónál). A nem-

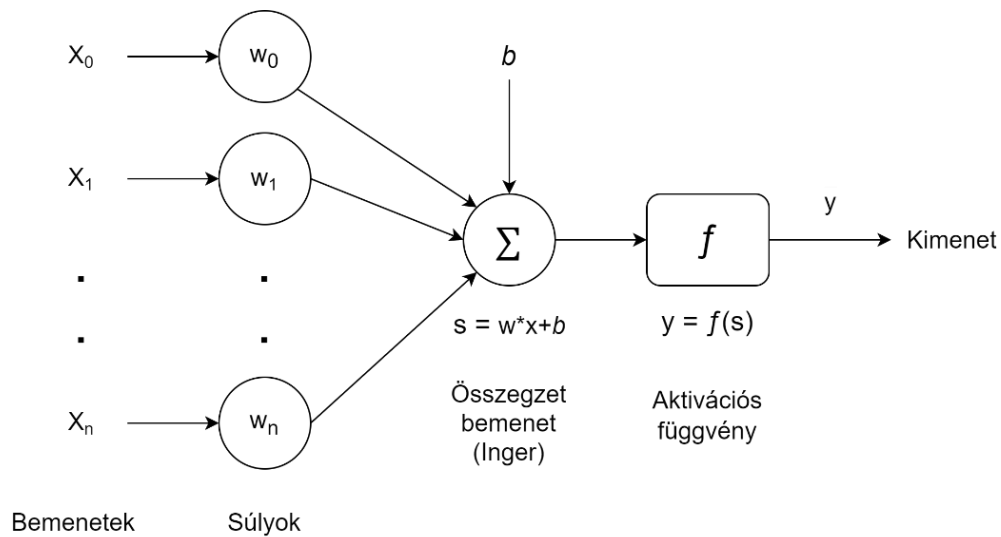
lineáris tartó-vektor gépeknél az eredeti adattér lineárisan nem szeparálható, így transzformálás segítségével olyan adattér hozható létre, ahol az esetek már elkülöníthetőek (6. ábra). A transzformáció után az adatrre egy olyan lineáris hipersík illeszthető, amely az eredeti bemeneti térben nem lineáris. A nem-lineáris tartó-vektor gépek alkalmazásának megkönnyítése érdekében, a transzformálást beleépíthetjük az eredeti pontokon értelmezett távolság függvénybe (kernelbe) (Bodon és Buza, 2014). Ezt az eljárást kernel trükknek is hívják, aminek köszönhetően a számítások az eredeti térben végezhetőek el, így az algoritmus számítási igénye sokkal kisebb lesz, míg a dimenzió-problémával kapcsolatos kérdéseket elkerülhetjük (Tan et al., 2006). A kernel trükkhöz köthetően, a nem-lineáris tartó-vektor gépek költség paramétere mellett, másik alapvető paraméter a magasabb dimenziószámú térbe vetítést helyettesítő kernel (Bodon és Buza, 2014). A gyakorlati tapasztalatok alapján, a nem-lineáris tartó-vektor gépekkel magasabb pontosság érhető el, azonban nagy esetszámú adathalmazok (> 10 000) esetén az adattranszformációk miatt a teljesítményük visszaesik, így ezekben az esetekben a lineáris változat alkalmazása ajánlott. A tartó-vektor gépek nagyon jól működnek sokdimenziós adatokkal, elkerülik a dimenzió problémát, ezért alkalmasak adatbányászati célokra is (Tan et al., 2006). A távérzékelésben a bináris osztályozási problémák száma csekély, így a tartó-vektor gépek felhasználása nem az alapvető bináris elválasztással történik, hanem többsztályos megoldásokkal. Ezek közül a leggyakrabban használt megoldások az egy az egy ellen szabály (*one-against-one*), amely minden egyes páronkénti osztály-kombinációt különválaszt, és az egy az összes ellen szabály (*one-against-all*), amely az egyes osztályok többiekhez képesti elkülönítésén alapul. A tartó-vektor gépek sokdimenziós adatokon nyújtott megfelelő teljesítménye miatt, főleg kis méretű hiperspektrális, multitemporális felvételeken és többforrású adathalmazokon alkalmazzák (Waske et al., 2009).

A mesterséges neurális hálók alapvető ötlete ugyanazon a felvetésen alapul mint a többi, biológiai rendszert utánzó módszernek: A biológiai rendszerek az évmilliók fejlődésének köszönhetően rendkívül hatékonyan és kifinomultan működnek, így megfigyelésükkel és mesterséges úton történő létrehozásukkal hasonlóan hatékony szisztémákat tudunk létrehozni (Altrichter et al., 2006). Azonban a többi biológiai rendszerhez képest az emberi agy egy fölöttébb összetett, nemlineáris és párhuzamosan működő információ feldolgozó egység, különféle számítási kapacitásokkal (mintázat felismerés, érzékelés, érzékelt adatok feldolgozása, motorikus funkciók irányítása) (Haykin, 2009). Ennek a komplex rendszernek vizsgálataiból indult ki a mesterséges neurális hálók létrehozásának ötlete az 1940-es években.

A első kutatások az agyban lévő idegrendszer felépítésének és számítási modelljének meghatározására irányultak (McCulloch és Pitts, 1943). Ezek alapján hoztak létre egy olyan számítási modellt, ami az emberi agyhoz hasonlóan működik. A számítási modell az emberi

agy idegsejtjeinek és hálózatának szerkezetét utánozza, ami neuronokból, dentrinekből és axonokból áll. A mesterséges neurális hálók ezt a szerkezetet lemásolva, az emberi idegrendszer struktúrájának és működésének analógiájára kiépített számítási mechanizmusok. Ebből kifolyólag nem értelmezni próbálnak egy jelenséget (és törvényszerűségeket megállapítani), hanem a bemenő adatok alapján matematikai úton próbálják azt újra előállítani, azaz fekete dobozként működnek. Emiatt működésükhöz csak adatokra van szükségük, további ismeret a jelenségről és annak felépítéséről és működési mechanizmusáról nem szükséges (Altrichter et al., 2006).


A legelső, gyakorlatban hasznosítható neurális hálózatok a többrétegű perceptron hálók (*multilayer perceptron network*) voltak, amik az 1950-es évek végén jelentek meg és az 1960-as évek végéig uralták a mesterséges neurális hálók tudományát. A többrétegű perceptron és neurális hálók fejlődését azonban visszavetette, hogy ezek a hálózatok még csak lineárisan szeparálható osztályozási feladatokat tudtak megoldani, így felhasználhatóságuk erősen korlátozott volt (Altrichter et al., 2006). A kutatásoknak az 1980-as években két különálló ötlet adott új lendületet. Az egyik John Hopfield munkája volt, a statisztikus mechanika felhasználhatósága a visszacsatolt (rekurrens) neurális háló terén. Ezáltal lehetővé vált különböző optimalizálási feladatok megoldása. A másik, a többrétegű perceptronok betanításánál használható hiba-visszaterjesztési algoritmus (*backpropagation*) kifejlesztése. Az eljárást először 1974-ben Paul Werbos írta le disszertációjában (Werbos, 1974), azonban először csak az 1980-as évek közepén alkalmazták és publikálták tudományos folyóiratban (Hagan Demuth, Howard B., Beale, Mark H., 1996). A hiba-visszaterjesztési algoritmusnak köszönhetően a többrétegű perceptron hálózatok képesek lettek nemlineáris problémák megoldására, ami megnyitotta az utat a széleskörű alkalmazásukra, amik új korszakot jelentett a neurális hálózatok fejlesztésében. Ennek új lendületet adtak a 2010-es évek elején elindult mélytanulós (*deep learning*) neurális hálók, amik akár több tíz vagy akár száz rejtett réteget is felhasználnak. Az ilyen hálók felhasználásával már az ember szintjéhez hasonlóan tudunk képosztályozást, beszédfelismerést, kézírás digitalizációt elvégezni, továbbá számos más területen is jelentős előrelépést értek el, mint a gépi fordítás, a szöveg-beszéd átalakítás, a digitális asszisztensek és az autonóm vezetés (Chollet, 2017).



7. ábra Memória nélküli neuron (perceptron) felépítése, (Altrichter et al., 2006) és (Haykin, 2009) alapján.

A mesterséges neurális hálók alapvetően három kulcsfontosságú tulajdonossággal rendelkeznek. (1) Általában nagyszámú, egyszerű, lokális feldolgozást végző számítási eszközökből (neuronokból) állnak, amik nagymértékben össze vannak kapcsolva. (2) Tanulási algoritmussal rendelkeznek, ami meghatározza az információfeldolgozás módját. (3) Képesek a betanított információt felhasználni az ezt lehetővé tévő előhívási algoritmussal. A neuronok egy több-bemenetű és egy-kimenetű eszközök, amelyek a bemenetekből valamilyen függvény alkalmazásával új értékeket hoznak létre. A neuronok közül a legelterjedtebb változat, a memória nélküli neuron (perceptron) (7. ábra). Ennél a neuronnál az x_i bemenetek w_i súlyokkal összegződnek és a b (bias – torzítás) értékkel együtt adják ki az összegzett bemenetet, vagy más néven ingert (s). Így kerülnek felhasználásra az aktivációs függvényben (f), ami megadja a kimenetet (y) (Altrichter et al., 2006). Ezek a neuronok önmagukban nem alkalmasak komplex feladatok kiszámítására, ezért szükséges őket (rejtett) rétegekbe összerendezve, párhuzamosan használni (8. ábra). A rétegekbe rendezett neuronok meghatározott topológiájú összekapcsolásával alakíthatunk ki neurális hálózatokat. A rejtett rétegek és a rétegekben lévő neuronok száma határozza meg a háló tanulási kapacitását.

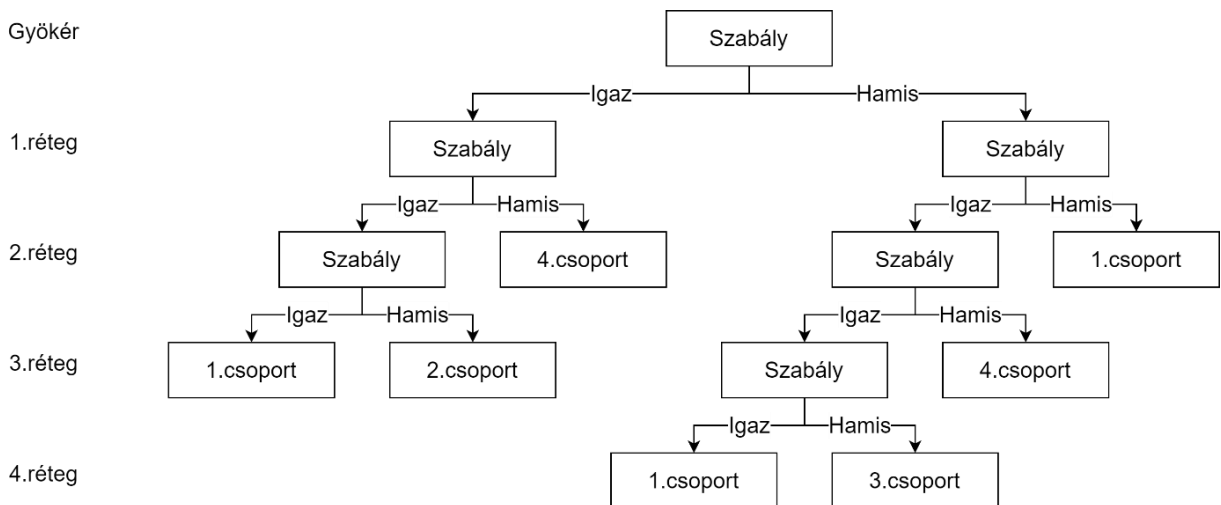
A neurális hálók működésében két fázist tudunk jól elkülöníteni. Az első a tanulási, amelynek során a neurális hálót alakítjuk ki a meglévő bemenő és kimenő adataink (bemenő és kimenő) segítségével. A tanulási fázisban iteratív módon a hálózatba beépítjük és eltároljuk az adatainkban lévő ismert és rejtett információkat. Eredményül egy betanított hálót kapunk, amivel képesek vagyunk új adatokat



8. ábra Egyszerű, egyrétegű neurális háló.

feldolgozni. A második fázis az előhívási fázis, melynek során új, ismeretlen adatokat dolgozunk fel a betanított hálónk segítségével, aminek a végén új eredményeket kapunk (Altrichter et al., 2006).

Az egyszerű elemekből történő felépülése, az aktivációs függvénynek és a hiba-visszaterjesztésnek köszönhető nem-linearitása és adaptivitása nagyban hozzájárult, hogy a mesterséges neurális hálók a távérzékelésben is hamar elterjedjenek. Több különböző neurális hálót alkalmazó módszert fejlesztettek ki az évek során, különböző feladatok megoldására, mint a minta felismerés, objektum azonosítás, képosztályozás (Chollet, 2017). A képosztályozásban főleg a többrétegű perceptron hálót alkalmazzák hiba-visszaterjesztési algoritmussal, valamint konvolúciós neurális hálót (*Convolutional Neural Network – CNN*). A neurális háló felépítésének köszönhetően minden adatforráshoz különböző súlyok alkalmazhatóak, ezért hasznosak a több adatforrásból épülő alkalmazásokban pl. a multitemporális (Zhu et al., 2021) és különböző szenzorokat felhasználó osztályozások (Ienco et al., 2019; Seydi et al., 2020). Emellett a neurális hálók alkalmazásával olyan osztályozási fogatókönyvekben is nagy pontosságot lehet elérni, ahol eddig nem sikerült elfogadható megoldást találni. Azonban az előnyei ellenére a teljesítménye nagyban függ a megfelelő számú és minőségű tanító adattól (Waske et al., 2009). A nagyszámú bemenő adat mellett, a betanítási fázis hardveres erőforrásigénye is jelentős, ami a mélytanulós neurális hálók megjelenésével még tovább nőtt. Azonban a betanítási fázis után a modell az új adatok becslésénél már nagyon gyors. Ezért a neurális hálók meghatározása (rejtett rétegek száma, neuronok száma, aktivációs függvény, optimalizációs módszer, kiesési ráta, tanulási ráta), a modellépítő paramétereinek optimalizálása, illetve a hálók célorientált beállítása mélyebb felhasználói ismereteket igényelnek.



9. ábra Egy döntési fa egyszerűsített szerkezete.

A döntési fa algoritmus alapötlete, hogy bonyolult összefüggéseket egyszerű döntések sorozatára vezeti vissza. Ezt az ötletet algoritmusként már 1977-ben megfogalmazta Swain és Hauska (Swain és Hauska, 1977). A döntési fa egy hierarchikus osztályozási módszer, ami egy fára hasonlít (gyökérből, ágakból, csomópontokból és levelekből áll) (9. ábra). A módszer az adatokat úgy osztályozza, hogy azokat rekurzívan egyre kisebb és homogénebb részekre bontja szét. A részekre bontás addig történik, amíg az összes pixel egy olyan csoportba nem kerül, ami teljesen elkülönül a többi osztálytól vagy az előre meghatározott feltételek nem teljesülnek (Jiang et al., 2010). Egy ismeretlen minta osztályozásakor a fa gyökérből kiindulva a csomópontokban feltett kérdésekre adott válaszoknak megfelelően addig lépked lefelé a fában, amíg egy levélbe nem ér. A döntési szabályok sorozatának eredményét a levél címkéje határozza meg (Bodon és Buza, 2014). Egyszerűségének köszönhetően a döntési fa a nyers adat értelmezésének, megjelenítésének, és az adatban rejlő minták és fontos információk kinyerésének egyik leghatékonyabb módja.

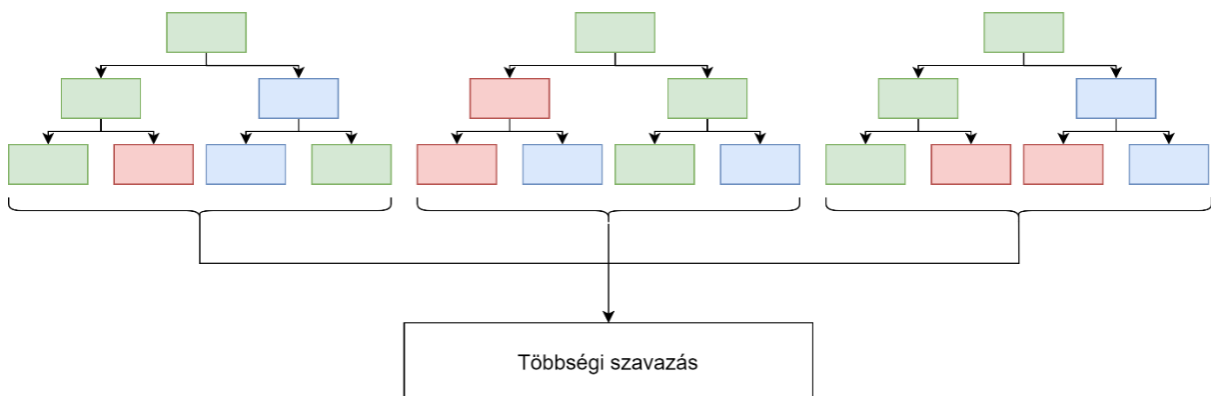
A döntési fa tartalmaz egy gyökér csúcsot, megadott számú belső csúcsot és leállítási csúcsokat. A gyökér és a belső csúcsokat egységesen nem-leállítási csúcsoknak nevezzük. A leállítási csúcsok maguk az osztályozás végső eredményeit mutatják. Az azonos szinten lévő csúcsokat, amelyek ugyanakkora távolságra helyezkednek el a gyökértől, együttesen rétegnek nevezzük (Swain és Hauska, 1977) (9. ábra). A nem-leállítási csúcsokban egy-egy attribútum értékének vizsgálata történik, a csúcsok közötti élek e vizsgálat eredményével (az adott attribútum megfelelő értékével) vannak felcímkézve, míg a leállítási csúcsok magát a döntést (vagyis a megfelelő osztályt reprezentáló attribútum értékét) tartalmazzák (Bényász, 2010). A döntési fa modell tanítási fázisa egy elválasztási eljárás. Első lépésben a teljes tanító adathalmaz áll rendelkezésünkre, ez lesz a gyökér, az első csúcs. Az adathalmaz szétválasztása során egy felhasználó által választott metrikával (pl. Gini index, entrópia) megkeressük azt az attribútumot, amellyel legjobban szeparálható az adathalmaz. Ezután a kiválasztott attribútum minden lehetséges értékével elágazást készítünk, és ezekkel osztjuk szét az adathalmazt. Amelyik értékkel optimális az elválasztás, az kerül a végleges modell csomópontjába/csúcsába. Ez a szétválasztási folyamat addig ismétlődik, amíg a modell el nem ér egy megállítási kritériumot vagy a végződésben lévő összes eset egy osztályba nem tartozik (Bodon és Buza, 2014). Megállítási kritériumok:

- Nincs több attribútum, ami alapján az elemeket tovább tudjuk osztani. Ekkor a csomópontokhoz tartozó osztály az lesz, amelyikhez a legtöbb tanítópont tartozik.
- Az adott mélység elért egy előre meghatározott korlátot. (modell nagyság)
- Nincs olyan vágás, ami javítani tudna az aktuális osztályozáson.
- A végződés elérte a minimális nagyságot. (minimális végződés nagyság)

Általában a gyökérhez közel az osztályozáshoz szükséges legfontosabb változók helyezkednek el, mivel segítségükkel lehet a legjobban szeparálni az adathalmazt. A kiválasztott fa struktúra és a bemeneti tulajdonságok határozzák meg a modell teljesítményt és a hatékonyságot (Swain és Hauska, 1977). A modell hatékonyságát javíthatjuk metszéssel, amely során eltávolítjuk (összevonjuk magasabb szintre) az összes olyan végződést, amely nem növeli az összpontosságot, ezáltal a döntési fa mérete csökkenthető, futási ideje, illetve a túltanítás mértéke is csökken. Az optimális döntési fa a lehető legkisebb méret mellett (legkevesebb réteggel rendelkezik), a lehető legnagyobb pontossággal rendelkezik és a tanító és tesztadaton is közel azonos teljesítményt nyújt.

A döntési fa előnyös tulajdonsága, hogy a gyökérből a leállítási csúcsokba vezető szabályok sorozatát összeolvasva könnyen értelmezhetjük az eredményeket. Ennek köszönhetően az osztályozás eredményei mindenki számára érthető módon reprezentálhatjuk. További előnye, hogy egyszerű működésének köszönhetően robusztusan viselkedik nagy adathalmazokon is, különböző adatelosztási jellemzők mellett is. A távérzékelt képi adatok jellemzői és a forrásadatok dimenziói különböző statisztikai eloszlással és skálákkal rendelkezhetnek, amelyek osztályozásánál a döntési fa jobb eredményeket ad, mint a hagyományos parametrikus osztályozók (Jiang et al., 2010). Azonban az új adatok és módszerek mellett a döntési fa már csak alaposztályozóként jelenik meg az együttes osztályozókban (*ensemble learners*). A további két eljárás is ezen az algoritmuson alapuló együttes osztályozó.

A véletlen erdő egy együttes osztályozási módszer, amelyet kimondottan a döntési fa osztályozókhoz terveztek és a 2010-es évek elején nőtt meg a népszerűsége. A véletlen erdő döntési fák olyan halmaza, amely a döntési fák által leadott előrejelzéseket kombinálja, egy többségi szavazási séma segítségével (Tan et al., 2006) (10. ábra). Az erdő általánosított hibája két paramétertől függ. Az egyik, hogy az egyes önálló osztályozók mennyire pontosak és a különböző osztályozók mennyire függetlenek egymástól, azaz az erdőben lévő egyes fák erejétől és a köztük lévő korrelációtól (Breiman, 2001).



10. ábra Véletlen erdő osztályozó algoritmus modellje.

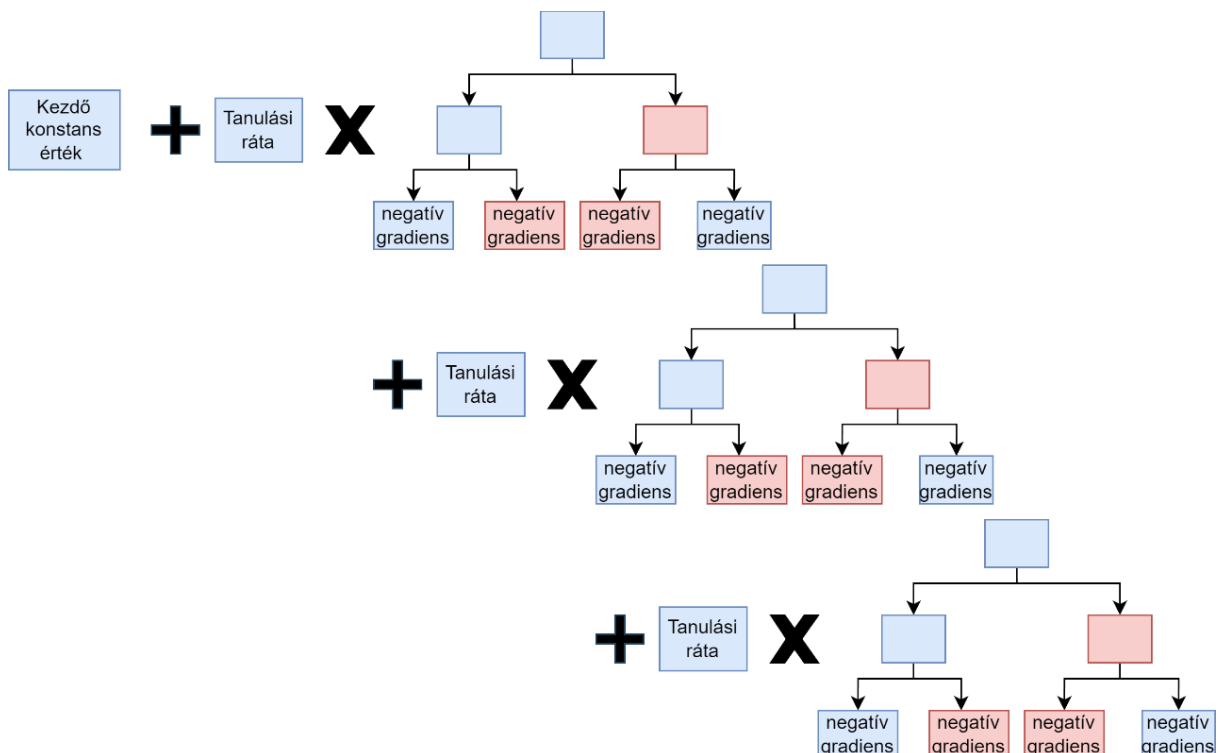
A modellépítő eljárás során az általánosított hiba csökkentése érdekében, a véletlenszerűség növelésével a fák közötti korreláció csökkenthető. Ennek egyik módja a 'zsákolás' (*bagging*) alkalmazása, amely során az eredeti tanulóhalmazból véletlenszerűen választott mintákat viszünk a modellépítő eljárásba (Breiman, 1996). A zsákolás ismétlődően egyenletes eloszlás szerint úgy mintavételez, hogy az egyes mintahalmazok ugyanolyan méretűek legyenek, de az egyes esetek többször is szerepelhetnek az adathalmazokban, míg mások nem kerülnek be a mintaadatok közé (Tan et al, 2011). A zsákolás használata mellett szól, hogy a véletlen attribútum kiválasztással együtt használva növeli a pontosságot és lehetővé teszi a teljes együttes osztályozó általánosított hibájának, pontosságának és korrelációjának folyamatos becslését. Ezeket a becsléseket zsákon kívüli becsléssel (*out of bag*) lehet kiszámítani, melynek lényege, hogy az egy zsákolás által kiválasztott részadathalmazon betanított modell pontosságát a tanító adathalmaz maradék esetein (amik nem kerültek a zsákba) futtatjuk le és vizsgáljuk meg annak pontosságát.

A modellépítő eljárás számára több paramétert kell megadni: (1) a „zsák” nagyságát (P), azaz, hogy a teljes adathalmazhoz képest mekkora méretű adathalmazt válasszon ki véletlenszerűen egy fa létrehozásához; (2) az erdő nagyságát (N), hogy mennyi fát hozzon létre az algoritmus, illetve, (3) mennyi attribútumot (M) használjon fel az eljárás az egyes fák létrehozásakor (Breiman, 2001). A modellépítő eljárás minden egyedi osztályozó esetében először zsákolással választ ki egy véletlenszerű adathalmazt az eredeti tanító adathalmazból. A véletlen tulajdonság kiválasztással előállítja a betanításhoz szükséges adathalmazt, amelyen végrehajtja a modell metszés nélküli betanítását. A P nagyságú véletlenszerűen kiválasztott adaton, M számú attribútum segítségével az N db létrehozott döntési fa mindegyike lead egy szavazatot és végeredménynek a leggyakoribbat döntést fogjuk kapni (Breiman, 2001). A modell teljesítményének (modellépítési idő, becslési idő) növelése érdekében, az eredeti koncepcióval szemben, korlátozhatjuk az egyes fák nagyságát különböző paraméterek segítségével: a fa maximális mélységének, a nem leállítási csúcsban lévő vágáshoz szükséges minimális esetek számának, a lehetséges leállítási csúcsok számának vagy a bennük lévő minimális esetszám meghatározásával. Ezen modellépítő paraméterek alkalmazásánál meg kell találni azokat az optimális beállításokat, amelyekkel a legkisebb pontosságvesztés mellett a legnagyobb teljesítmény növekedést érhetjük el.

A véletlen erdő előnye a döntési fához képest, hogy robusztusabb az adathalmazban lévő zajra és a túltanításra, képes kiegyensúlyozatlan és hiányos adathalmazokat is kezelni, miközben az osztályozási pontossága nem romlik (Pal, 2005). Ezenkívül a modellben lévő egyes fák a döntési szabályt minden egyes csomópontban a bemeneti adatoknak csak egy véletlenszerűen kiválasztott jellemző részhalmaza alapján határozzák meg. A jellemzők

számának csökkentésével minden egyes felosztásnál egyszerűsödik az egyes fák számítási komplexitása, amely a számítási kapacitás szempontjából előnyös módszert eredményez. Ez teszi lehetővé a véletlen erdő számára, hogy nagy dimenziós adathalmazokat kezeljen (Waske et al., 2009). Ezen tulajdonságainak köszönhetően a távérzékelt adatok képosztályozásában gyakori kiegyensúlyozatlan, zajos, nagy dimenziós adatokon is jó teljesítményt nyújt. Hátránya, hogy a modell építése több időt vesz igénybe, és nagyobb hardveres követelményeket támaszt. Valamint a modellbe már nem látunk bele közvetlenül, csak az összesített előrejelzéseket kapjuk meg eredményül, azaz már nem tekinthető „White-bokszt” modellnek.

A gradiens-növelő gép egy olyan együttes módszer, amely különböző gyenge alaptanulókat (döntési fákat és neurális hálókat) használ osztályozási vagy regressziós feladatok megoldásához (Friedman, 2001). A gradiens-növelő gép a modellt előrefelé lépcsőzetes módon építi fel, ami lehetővé teszi egy tetszőleges differenciálható veszteségfüggvény optimalizálását (Friedman, 2002). A gradiens-növelő fa a gradiens-növelő gép egy fajtája, ahol az alaptanuló egy döntési fa, legtöbb esetben egy regressziós fa, ezért is szokták sokszor gradiens-növelő regressziós fának nevezni (*Gradient Boosted Regression Tree*) (Olexó, 2018). A gradiens növelés során, iteratív módon olyan új modelleket tanítunk be, amelyek a korábbi modellek gyenge pontjainak kezelésére specializálódnak (Chollet, 2017).



11. ábra A gradiens-növelő gép felépítése, döntési fák alkalmazásával, mint alap tanulók.

A modellépítési fázisban, az adathalmazunk célváltozójából számított konstans értékhez (pl. átlag, medián) képest számított eltéréseket (negatív gradiens) határoz meg esetenként, valamilyen felhasználó által választott veszteségfüggvény segítségével (11. ábra). Ezen

eltérések becslésére, a magyarázó változók felhasználásával épít fel egy döntési fát, amelynek a mérete valamilyen mértékben korlátozott (általában a maximális mélysége). A célváltozó konstans értékével, a döntési fa szabályai által megadott esetek eltérési értékeivel és egy konstans tanulási értékkel (tanulási ráta) együtt kerülnek meghatározásra a köztes becült értékek. A becült értékekből számított eltérések felhasználásával épül fel a következő döntési fa és számíthatók ki az új becült értékek a már említett módon. A modellépítési fázis addig tart, amíg a felhasználó által megadott iterációk (döntési fák) számát el nem éri a modellépítés (Olexó, 2018). Az előbb bemutatott regressziós feladattól eltérően, az osztályozás során a modell az adathalmazunk célváltozójából nem konstans értéket határoz meg, hanem a célváltozó átlagos valószínűségét. Az átlagos valószínűséghez képest tudunk eltéréseket meghatározni esetenként, valamilyen felhasználó által választott veszteségfüggvény segítségével. A gradiens-növelő fa algoritmus a véletlen erdőhöz hasonló tulajdonságokkal rendelkezik ugyanazon alaptanulónak köszönhetően. Ilyen tulajdonság a jól skálázhatóság, robusztusság az adathalmazban lévő hiányokra és zajokra. Azonban a gradiens-növelő fa, a sztochasztikus gradiensnövelés módszerének köszönhetően a legtöbb esetben felülmúlja a véletlen erdő teljesítményét (pontosság, futási idő). Ezt jól mutatja, hogy 2014-ig a kaggle (<https://www.kaggle.com/>) versenyeken domináns véletlen erdőt a gradiens-növelő gépek, illetve azok extrém gradiens-növelő változataik (XGBoost) váltották le (Chollet, 2017). A mély tanulós mesterséges neurális hálók mellett, jelenleg ez a leggyakrabban használt módszer. Az általam alkalmazott hisztogram-alapú gradiens-növelő fa, a gradiens-növelő fa olyan változata, amely a bemenő adatokat egész szám alakú részekre bontja, amiken az algoritmus egész értékű adatstruktúrákat (hisztogramokat) tud használni. Ezzel a módszerrel az algoritmus nagyságrendekkel gyorsabb, mint a sima gradiens-növelő fa, főleg a tízezer mintánál nagyobb mintán alkalmazzuk.

2.4. Felszínborítás és területhasználat osztályozási módszerek a távérzékelésben, hazai és nemzetközi példákon keresztül

A felszínborítás és területhasználat térképezés a műholdas távérzékelés alapvető feladata már a tudomány kialakulása óta. A térképezési feladat automatizálásához szükséges képosztályozási módszerek keresése és fejlesztése a feladattal egyidős. Egyik kulcsproblémáját a felszínborítás és területhasználat fogalmából eredő regionális és értelmezésbeli eltérések okozzák, ami miatt a térképezéshez használt, egységes standardizált osztályozási rendszer kialakítása komoly kihívást jelent. Az első fontosabb ilyen, az Anderson által az Egyesült Államok Geológiai Szolgálatára (United States Geological Survey – USGS) számára létrehozott 4 hierarchikus szintből álló osztályozási rendszer (Anderson et al., 1976). Az egyes hierarchia szinteken lévő osztályokat, különböző felbontású távérzékelte adatok, és a belőlük levezethető

objektumok alapján különíti el. A hierarchiában lefelé haladva az egyes szintek előállításához 100-20 méter, 20-5 méter, 5-1 méter és 1 méter alatti térbeli felbontású adatokat szükségesek. A nomenklatúrában az első szinten lévő 9 osztály felszínborítási, míg a többi hierarchia szinten lévőek már területhasználati kategóriák. Ez adta az alapot az azóta megjelenő számos regionális és globális osztályozási rendszernek.

A globális osztályozási rendszerek közül az Egyesült Nemzetek Szervezetének Élelmezésügyi és Mezőgazdasági Szervezete (FAO) hozta létre az első 8 osztályos, széleskörű, standardizált a priori osztályozási rendszert, amely döntési szabályok kombinációjával határozza meg az egyes felszínborítási osztályokat. A rendszer kialakításának köszönhetően, méretaránytól független és a felhasználók igényeihez alkalmazkodik (Gregorio és Jansen, 2000). Ez az osztályozási rendszer is hozzájárult a későbbi GLC2000-es (Global Land Cover 2000) adatbázis létrehozásához, amiben több mint 30 kutató csoport együttesen vett részt és hozott létre egy globális lefedettségű felszínborítási térképet. Az adatbázis alapját egy 14 hónapos időszak (1999.11.01–2000.12.31) SPOT 4 műholdfelvételei szolgáltatták. Az adatbázis létrehozásakor a különböző csoportok eltérő osztályozási módszert alkalmaztak a helyi feltételeknek megfelelően (Bartholomé és Belward, 2005). Ehhez képest előrelépést hozott a Friedl és munkatársai által kidolgozott osztályozási módszer, amely a 2000 – 2001-es években készített MODIS műholdfelvételek képosztályozásával hozott létre globális felszínborítási térképet (Friedl et al., 2002). Egy 18 osztályt tartalmazó nomenklatúrát használtak fel képosztályozáshoz, amely elvégzéséhez egyváltozós döntési fa (C 4.5) és mesterséges neurális háló (ARTMAP) módszereket teszteltek. A rendszerben végül a döntési fa algoritmust implementálták, mivel a neurális háló nehezen tudta kezelni a hiányzó és zajos adatokat (főleg a felhőzet miatt) (Friedl et al., 2002). Szintén döntési fa osztályozó algoritmust alkalmaztak kínai kutatók a GlobeLand30 adatbázis létrehozásakor (Chen et al., 2014). A döntési fa osztályozót egy hierarchikus osztályozási szisztémában kombinálták egy objektum alapú módszerrel, a 10 felszínborítási kategória lehatárolásához. Az adatbázis létrehozásakor az egyes osztályokat egymás után nyerték ki a felvételekből és a már kinyert kategóriákat maszkolták a felvételekből. Az adatbázis alapját a 2000 és 2010 között készült Landsat műholdfelvételek adták és kiegészítő adatként a Huan Jing-1 (HJ-1) felvételeit is felhasználták (Chen et al., 2014).

Az első fontosabb regionális adatbázisokat az 1990-es években állították elő. Az Egyesült Államok Geológiai Szolgálatának által létrehozott Nemzeti Felszínborítási Adat 1992 (National Land Cover Data 92 – NLCD92) Landsat-5 műholdképek alapján készült. A projektben klaszterező irányítatlan osztályozást alkalmaztak a műholdfelvételeken, majd a kialakított pixelcsoportokat ortofotók segítségével azonosították be. Az osztályozás

eredményeképp létrehozott adatbázis 21 tematikus osztályt tartalmaz és az USA 48 államát fedi le (Vogelmann et al., 2001). A következő NLCD adatbázis módszertanán módosítottak és egy előre meghatározott 16 osztályos nomenklátúra alapján döntési fa osztályozó segítségével készítették el az adatbázisokat (Homer et al., 2007). Az európai osztályozási rendszerek és adatbázisok közül a CORINE Land Cover, 3 szintű és 44 osztályos osztályozási rendszerét (Büttner et al., 2000) és a nemzeti és EU szinten is alkalmazható EAGLE (EIONET Action Group on Land Monitoring) modellt (Arnold et al., 2013) kell megemlíteni. Az EAGLE modell a tájat olyan felszínborítás komponensek segítségével írja le, amelyek teljesskörűek és kölcsönösen kizárják egymást. Az Európai Környezetvédelmi Ügynökség (EEA) koordinációjával készült CORINE Land Cover (CLC) adatbázis kontinentális szintű felszínborítási térkép, amely az Európai Közösség területéről szolgáltat információt 1990 óta. Ezt az adatbázist a későbbiekben részletesen bemutatom. A meglévő CLC adatbázisok kiegészítése céljából az EEA öt nagyfelbontású (20 m térbeli felbontású) réteget (HRL) készített el Európa 39 országára. Ilyen rétegek az *imperviousness* (talajfedés mértéke), *forest* (lombkorona fedettség és erdő típus), *natural and semi-natural grasslands* (füves területek), *wetlands* (vizenyős területek), *water bodies* (állandó vízfelületek) stb.. A rétegek elkészítési módja a réteg típusától függően változott (NDVI vizsgálat, szegmentáció, fél-automatikus osztályozás) (Langanke, 2016b, 2016c, 2016a, 2017).

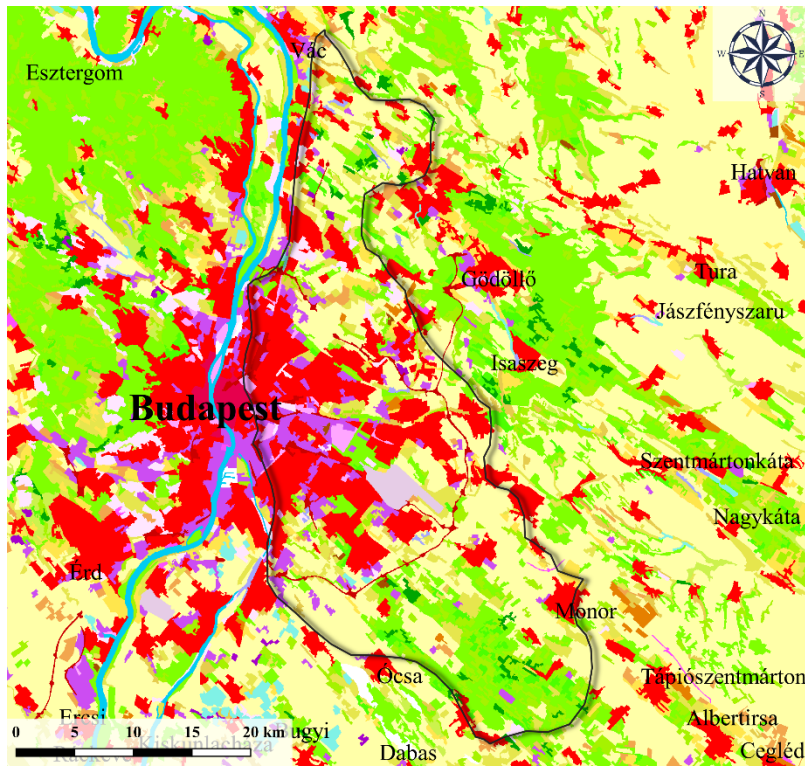
A CLC adatbázis előállítására és az eredeti adatbázis előállításából származó hátrányok leküzdésére már több automatikus vagy fél-automatikus osztályozási módszert alakítottak ki. Ezek a módszerek a CLC nomenklátúra egy részének vagy egészének felhasználásával lokális vagy kontinentális léptékű térképek előállítására irányultak. Esch és társai fél-automatikus és objektum orientált osztályozást felhasználva hoztak létre térképeket, és az osztályozás eredményeit vizuális interpretációval segítették (Esch et al., 2004). A vizsgálatban multispektrális műholdképek (Landsat-7) és a képekből szegmentálás útján előállított textúra rétegek szolgáltatták az osztályozás alapját. Ahol az osztályozás nem volt elég pontos vagy a pixelek osztályozatlanok maradtak, az osztályozás eredményeinek javítása érdekében vizuális interpretálást alkalmaztak. A kidolgozott módszer a nomenklátúra első szintjén 90%-os pontosságot eredményezett, viszont a 2. és 3. szinten akadályok adódtak a kategóriák elkülönítésében. Balzter és társai már véletlen erdő algoritmust alkalmazva, a CLC nomenklátúra 2. és 3. hierarchia szintjén lévő osztályok kombinálásával hoztak létre térképet (Balzter et al., 2015). Az osztályozáshoz Sentinel-1, SRTM adatokat és belőlük számított derivátumokat használtak fel. A módosított nomenklátúrával és az összes adat felhasználásával (Sentinel adatok, SRTM digitális magassági modell, lejtőszög, kiettség) 68,4%-os összpontosságot értek el. Szintén véletlen erdő osztályozó módszert használt Malinowski és

társai, kontinentális léptékű, CLC nomenklátúra alapú osztályozáshoz, amely optikai Sentinel-2-es felvételeken alapult (Malinowski et al., 2020). Az osztályozás során, a 2017-es évből származó multitemporális adatok és a belőlük kiszámított, összes 2 sávós index kombinációt felhasználva 13 osztályt határoztak le. Az eredmények alapján 86,1%-os összpontosságot értek el kontinentális szinten, azonban egyes osztályok csupán 50% alatti pontossági értéket értek el (ideiglenes hó, mocsári növényzet és lápok).

Magyarország területére (Kosztra et al., 2016) készített nagyfelbontású (20 m) CLC adatbázist hazai és európai felszínborítás és területhasználat adatok konverziójával. A CLC osztályok létrehozásához az EAGLE mátrixot használták, aminek segítségével meghatározták a CLC kategóriákat leíró felszínborítás, területhasználat és egyéb információkat. Ezt követően a hazai és európai felszínborítás és területhasználat adatokból lekérdezések segítségével hozták létre a nemzeti CLC osztályait. A teljes pontosságra 3. szinten 75,4%-ot, 1. szinten 88,7%-ot kaptak. Szintén Magyarország területére hozták létre a felszínborítást is leíró ökoszisztéma alaptérképet Tanács és társai (Tanács et al., 2019). Az alaptérképet 2015/16/17-es magyarországi és európai adatbázisok (MePAR, VINGIS, ESZIR-OEA stb.) együttes felhasználásával 20m-es térbeli felbontással készítették el. Az alaptérkép 3 szintes nomenklátúrája a MAES-, az EUNIS- és a magyar ÁNÉR-rendszer kategóriáira támaszkodva lett kialakítva. A létrehozott térkép átlagos pontossága az összevont kategóriák esetében 97,4%.

3. Felhasznált adatok

3.1. Coordination of information on the environment (CORINE) Land Cover (CLC)



Jelmagyarázat	
Összefüggő településszerkezet	Szőlők
Nem összefüggő településszerkezet	Gyümölcsösök, bogyósok
Ipari vagy kereskedelmi területek	Rét, legelő
Út- és vasúthálózat és csatlakozó területek	Komplex művelési szerkezet
Repülőterek	Elsődlegesen mezőgazdasági területek jelentős természetes növényzettel
Nyersanyag kitermelés	Lomblevelű erdők
Lerakóhelyek, meddőhányók	Tülevelű erdők
Építési munkahelyek	Vegyes erdők
Városi zöldterületek	Természetes gyepek, természetközeli rétek
Sport-, szabadidő- és tüdőterületek	Átmeneti erdős-cserjés területek
Nem öntözött szántóföldek	Szárazföldi mocsarak
Rizsföldek	Folyóvizek, vízi utak
	Állóvizek

12. ábra A Pesti hordalékkúp-síkság a CLC18-as adatbázis alapján

a kérdéses területek besorolásához. Az elkészült nemzeti felszínborítási térképeket integrálják az egységes európai adatbázisba. A legkisebb térképezési egysége 25 hektár, vonalas részekenél a minimális szélesség 100 méter. Az adatok felhasználhatósága és összevethetősége érdekében a térképeket egy egységes háromszintes nomenklatúra alapján készítik el. A nomenklatúrája első szinten 5, a második szinten 15, a harmadik szinten 44 darab osztályt tartalmaz (Mari és Mattányi, 2002) (1. táblázat). A CLC program keretében eddig 5 adatbázis készült el: 1990-es, 2000-es, 2006-os, 2012-es és 2018-as évekre. Az adatbázisok mindegyike ingyenesen elérhető a Copernicus Land Monitoring Service honlapjáról (<https://land.copernicus.eu/pan-european/corine-land-cover>). A kutatásom során az összes eddigi CLC adatbázist felhasználtam különböző módon (12. ábra).


A CLC programot az egységes környezeti politika kialakításának elősegítése érdekében indította el az Európai Közösség 1985-ben. A program célja, hogy adatokat állítson elő a Közösség tagországainak felszínborításáról, amit mindig az adott tagország erre szakosodott szerve állít elő, vizuális interpretációval. A módszer előnye, hogy az interpretálást végző szakemberek a kép több tulajdonságát is figyelembe tudják venni (szín, tónus, textúra, méret, alak) és több kiegészítő információforrást is igénybe vehetnek (nagyfelbontású

műholdképek, ortofotók, terepbejárás, helyszín leírások)

1. táblázat A CLC nomenklatúrája.


1. Mesterséges felszínek	1.1. Lakott területek	1.1.1 Összefüggő településszerkezet
		1.1.2 Nem összefüggő településszerkezet
	1.2. Ipari, kereskedelmi területek és közlekedési hálózatok	1.2.1 Ipari vagy kereskedelmi területek
		1.2.2 Út- és vasúthálózat és csatlakozó területek
		1.2.3 Kikötők
		1.2.4 Repülőterek
	1.3. Bányák, lerakóhelyek és építési munkahelyek	1.3.1 Nyersanyag kitermelés
		1.3.2 Lerakóhelyek, meddőhányók
		1.3.3 Építési munkahelyek
	1.4. Mesterséges, nem mezőgazdasági zöldterületek	1.4.1 Városi zöldterületek
		1.4.2 Sport-, szabadidő- és üdülőterületek
	2. Mezőgazdasági területek	2.1. Szántóföldek
2.1.2 Állandóan öntözött területek		
2.1.3 Rizsföldek		
2.2. Állandó növényi kultúrák		2.2.1 Szőlők
		2.2.2 Gyümölcsösök, bogyósok
		2.2.3 Olajfa ültetvények
2.3. Legelők		2.3.1 Rét, legelő
2.4. Vegyes mezőgazdasági területek		2.4.1 Egynyári kultúrák állandó kultúrákkal vegyesen
		2.4.2 Komplex művelési szerkezet
		2.4.3 Elsődlegesen mezőgazdasági területek jelentős természetes növényzettel
		2.4.4 Mezőgazdasági-erdészeti területek
3. Erdők és természetközeli területek		3.1. Erdők
	3.1.2 Tülevelű erdők	
	3.1.3 Vegyes erdők	
	3.2. Cserjés és/vagy lágyszárú növényzet	3.2.1 Természetes gyepek, természetközeli rétek
		3.2.2 Törpecserjés, cserjés területek, fenyérek
		3.2.3 Keménylevelű (szklerofil) növényzet
		3.2.4 Átmeneti erdős-cserjés területek
	3.3. Növényzet nélküli, vagy kevés növényzettel fedett nyílt területek	3.3.1 Homokos tengerpartok, dűnék, homok
		3.3.2 Csupasz sziklák
		3.3.3 Ritkás növényzet
		3.3.4 Leégett területek
		3.3.5 Gleccserek, örök hó
4. Vizenyős területek	4.1. Belső (szárazföldi) vizenyős területek	4.1.1 Szárazföldi mocsarak
		4.1.2 Tőzeglápok
	4.2. Tengerszemlélési vizenyős területek	4.2.1 Tengerszemlélési mocsarak
		4.2.2 Sóleparlók
		4.2.3 Ár-apály által érintett területek
5. Vízfelületek	5.1. Kontinentális vizek	5.1.1 Folyóvizek, vízi utak
		5.1.2 Állóvizek
	5.2. Tengeri vízfelületek	5.2.1 Tengerparti lagúnák
		5.2.2 Folyótorkolatok
		5.2.3 Tenger és óceán

Az adatbázis fontosságát és alkalmazhatóságát jól mutatja a széleskörű felhasználása, mint pl. a változás vizsgálatok (Cole et al., 2018; Feranec et al., 2010; Szilassi, 2017), 'urban sprawl' (Kovács et al., 2019; Steurer és Bayr, 2020), aszály és belvíz monitoring (Bezdan et al., 2019; Tobak et al., 2019; van Leeuwen et al., 2017), tájökológiai kutatások (Csikós és Szilassi, 2021a; Mander et al., 2018). A felsorolt előnyei mellett az adatbázisok több korláttal is rendelkeznek. Az előállítás módszere miatt az adatbázis pontossága nagyban függ az interpretáló szakmai tudásától, és így erősen szubjektív a végeredmény, illetve maga a folyamat is időigényes (éves lépték). A térképezési egység nagysága miatt az adatbázis a kisléptékű vizsgálatokban korlátozottan felhasználható, illetve felhasználásához előzetes pontosítás szükséges. Az előállítási módszer és a térképezési egység nagyban befolyásolja az adatbázisok tematikus pontosságát, ami $\geq 85\%$. A nomenklátúra nem csupán felszínborítási kategóriákat tartalmaz, hanem több területhasználati kategóriát is, mint pl. a 1.2.1-es osztály „*Ipari vagy kereskedelmi területek*”, 1.3.3-as osztály „*Építési munkahelyek*” vagy a 1.4.2-es osztály „*Sport-, szabadidő- és üdülő területek*”. Ezenkívül a nomenklátúra, főleg a minimális térképezési egység miatt, tartalmaz több olyan osztályt, amely más kategóriák elegyéből állnak, mint pl. 2.4.2-es osztály „*Komplex művelési szerkezet*”, 2.4.3-as osztály, „*Elsődlegesen mezőgazdasági területek, jelentős természetes formációkkal*” vagy a 3.1.3-as osztály, „*Vegyes erdők*”. Büttner pontossági vizsgálata a CLC2000-es adatbázison megmutatta, hogy az adott adatbázis $87,0\% \pm 0,7\%$ -os megbízhatósággal rendelkezik, így nem sokkal túllépve a garantált $>85\%$ tematikus pontosságot. A pontossági hibák meghatározásakor arra jutott, hogy az osztályozási hibák 78%-a a 3. hierarchia szinten lévő kategóriák között jelentkeztek (Büttner et al., 2016). Ezenfelül az ezen a szinten lévő kategóriák lehatárolási nehézségeit az osztályok közötti Jeffries-Matusita szeparabilitás értékek is jól mutatják. A Jeffries-Matusita (JM) távolság maximális távolságértéke 1414, ekkor a tanulók teljes mértékben elkülöníthetők az adott sávban, míg a minimuma 0, ekkor nem különíthetők el a tanulók (Dabboor et al., 2014). A JM távolságot mindkét általam használt CLC adatbázisra (CLC00, CLC18) kiszámítottam az adatbázisok alapját képező Landsat-7-es, és Sentinel-2-es műholdfelvételek felhasználásával. Az általam kiszámolt osztályok közötti minimális szeparabilitás értékek megmutatják, az adott sáv/ok felhasználásával legnehezebben elválasztható eseteket. Továbbá az átlagos szeparabilitás értékek megmutatják, hogy a legtöbb esetben milyen nehéz az elkülöníthetőség.



13. ábra A mintaterületekre kiszámolt minimális JM távolság átlaga, nomenklátúra szintenként, a CLC00-ás adatbázis és a Landsat-7 sávjai alapján.

A JM távolságok megmutatják, hogy az egyes spektrális sávok alapján a minimális elválaszthatóság igen alacsony, azaz egyes osztályok nem választhatóak el egymástól (13. ábra). Az összes adat felhasználásával az osztályok minimális elválaszthatósága javul, azonban így sem éri el a lehetséges maximum felét se. Az átlagos szeperabilitás értékek alapján az osztályok gyengén választhatóak el az egyes sávok alapján, azonban az összes sáv felhasználásával már elfogadhatóvá válik a szeperabilitás érték (14. ábra). A Sentinel-2-es adatok felhasználása a CLC18-as adatbázis elválaszthatóságának vizsgálatakor javulást mutatott. A minimális és átlagos szeperabilitás érték a hat mintaterület alapján 595, és 1219, ami kb. 100 és 200 pontos javulást jelent.



14. ábra A mintaterületekre kiszámolt átlagos JM távolság átlaga, nomenklátúra szintenként, a CLC00-ás adatbázis és a Landsat-7 sávjai alapján.

3.2. Landsat felvételek

A kutatásomhoz különböző, közepes felbontású multispektrális és mikrohullámú műholdkép forrásokat választottam ki. Ezek a műholdképek alapján történt a CLC adatbázisok létrehozása is, így megfelelő alapot biztosítottak a CLC nomenklatúrát felhasználó osztályozásaim elvégzéséhez. A műholdfelvételek két nagyobb programhoz tartoznak, az amerikai Landsat és az európai Sentinel földmegfigyelési programhoz.

A Landsat program 1970-ban indult az Egyesült Államok Geológiai Szolgálatának és az Amerikai Egyesült Államok Nemzeti Repülési és Űrhajózási Hivatalának (National Aeronautics and Space Administration – NASA) közös vállalkozásaként (Emery és Camps, 2017). A program célja a Föld felszínének megfigyelése és a természeti erőforrásainak kutatása, feltérképezése. A program indulása óta 9 műholdat építettek, amelyek közül az elsőt 1972-ben állították pályára, a legutolsót, a Landsat-9-est, pedig 2021. szeptember 27-én (Masek et al., 2020). Így ez a program szolgáltatja a világ leghosszabb ideje folyamatosan gyűjtött távérzékelési adatkollekcióját (U.S. Geological Survey, 2016). A Landsat programban lévő műholdak műszereinek tulajdonságait úgy alakították ki, hogy egymással összevethetőek legyenek (közel azonos spektrális tartományokat lefedő sávok, hasonló geometriai és radiometrikus tulajdonságok), ezáltal egy időben folytonos adatbázist hozzanak létre (Wulder et al., 2016). A műholdképek közepes térbeli (30, 60, 80 méter) és spektrális (4-11 sáv), valamint 16 napos időbeli felbontással rendelkeznek (U.S. Geological Survey, 2012). Emellett a műholdképek lefedik a Föld egész felszínét és szabadon elérhetőek minden felhasználó részére (Wulder et al., 2019). A Landsat programot, tulajdonságainak köszönhetően, széles körben használják: mezőgazdasági alkalmazásokban (Das et al., 2021; Di et al., 2021), erdészeti kutatásokban (Morin et al., 2021; Pelletier et al., 2021), vízgazdálkodásban (Baughman és Conaway, 2021; van Leeuwen et al., 2017), földhasználat és területhasználat térképezésben (Bui és Mucsi, 2021; Liska et al., 2017) és városi környezet megfigyelésében (Henits et al., 2017; Kovács et al., 2019).

A Landsat-7-es műhold a Landsat program hetedik műholdja, amelyet 1999. április 15-én lőttek ki a kaliforniai Vandenberg légibázisról. A Landsat-7-es műhold a sikertelenül felbocsátott Landsat-6-os műhold továbbfejlesztett szenzorját kapta meg, az Enhanced Thematic Mapper Plus-t (ETM+), amely az infravörös és látható fény tartományában összesen 8 sávban rögzít adatokat (U.S. Geological Survey, 2019a). A Landsat 8-as műhold a Landsat program nyolcadik műholdja, melyet 2013. február 11-én indítottak el egy Atlas 5-ös rakétával a kaliforniai Vandenberg légibázisról. A Landsat-8 műhold két sávmenti pásztázó (push-broom) felvételező rendszerrel lett felszerelve: Operational Land Imager (OLI) és a Thermal Infrared Sensor (TIRS). Az OLI szenzor a látható és infravörös fény tartományában összesen 9

sávban rögzít adatokat, és a folytonosság fenntartása érdekében, ezen sávok többségének spektrális kiosztása majdnem teljesen megegyezik a Landsat-7-es műhold ETM+ szenzorának kiosztásával. A TIRS szenzor 2 termális sávja a Landsat-7-es műhold termális sávjának 2 külön intervallumában érzékelnek és gyűjtenek adatokat (U.S. Geological Survey, 2019b). A spektrális sávok térbeli felbontása 30, a termális sáv/sávoké 60 vagy 100 és a pankromatikusé 15 méter (2. táblázat). A felvételezések időbeli felbontása 16 nap. A műholdak által készített standard kép 185 km ×180 km nagyságú területet fed le, amelyet a Worldwide Reference System-2-ben (WRS-2 referencia rendszer) kategorizálnak (233 pálya, 248 sor) (Mucsi, 2004). A Landsat-7-es műholdfelvételek alapján készítették el a CLC00-es adatbázis. Az adatbázis létrehozásához felhasznált, Magyarországra vonatkozó képek a 2000-es év három egymást követő hónapjából (június, július és augusztus) származnak. A műholdfelvételeket a CORINE adatbázis számára, az IMAGE 2000 projekt keretein belül dolgozták fel. A feldolgozás eredményeképp a felvételek geometrikus pontossága a multispektrális sávokban 25 méterre, a pankromatikus sávban 12,5 méterre javult (European Commission, 2005). A Landsat-8-as műholdfelvételek a CLC18-as előállítás során kisebb hangsúlyt kaptak. Az előállítási projekt során csupán a Sentinel-2-es adatok hiánypótlójaként használták azokon a területeken, ahol nem álltak rendelkezésre megfelelő minőségű Sentinel-2-es műholdképek. A képek felbontását a felhasználásuk előtt nem javították (Buttner és Kosztra, 2017).

2. táblázat A Landsat-7 ETM+ és Landsat-8 OLI és TIRS szenzorok sáv kiosztása és térbeli felbontása.

Sáv	Hullámhossz (µm)		Térbeli felbontás (m)	
	Landsat-7	Landsat-8	Landsat-7	Landsat-8
Ultrakék	-	0,43–0,45	-	30
Kék	0,45–0,515	0,45–0,51	30	30
Zöld	0,525–0,605	0,53–0,59	30	30
Vörös	0,63–0,69	0,64–0,67	30	30
Közeli infravörös	0,75–0,9	0,85–0,88	30	30
Közepes infravörös I,	1,55–1,75	1,57–1,65	30	30
Közepes infravörös II,	2,09–2,35	2,11–2,29	30	30
Pankromatikus	0,52–0,9	0,50–0,68	15	15
Cirrus	-	1,36–1,38	-	30
Termális infravörös I,	10,4–12,5	10,6–11,19	60	100
Termális infravörös I,		11,5–12,51		100

A Landsat felvételeket az Earth Resource Observation and Science (EROS) Center Processing Architecture (ESPA) online felületéről (<https://espa.cr.usgs.gov/>) töltöttem le 2.szintű feldolgozottsággal (a felvételek intenzitásértékei felszíni reflektancia és troposzféra felső hőmérséklet értékek) (3. táblázat). A Landsat-7 adatok 7 sávot (6 spektrális és 1 termális),

míg a Landsat-8 adatok 11 sávot (9 spektrális és 2 termális) tartalmaznak. A Landsat-8 felvételek cirrus és pankromatikus sávjait nem használtam fel, így összesen 9 spektrális sávot vontam be a vizsgálataimba. A L2A feldolgozottsági szintű műholdfelvételek spektrális sávjainak felszíni reflektancia értékei és termális sávjainak troposzféra felső hőmérséklet értékei -9999-től 20000-ig terjedő intervallumban vehetnek fel értékeket (a negatív értékek a háttér miatt lehetségesek) (U.S. Geological Survey, 2020). Az előfeldolgozást QGIS 3.16 és ERDAS Imagine 2020 szoftverkörnyezetben végeztem el. A könnyebb kezelhetőség érdekében az előfeldolgozás során a különálló fájlokban tárolt spektrális és termális sávokat egy fájlba egyesítettem. Az adatok valós tartományon kívüli (a 0 – 10 000-ig terjedő intervallumban nem beleeső) értékeit korrigáltam egy általam készített ERDAS modellel (a minimum-maximum értékekre változtattam a nem valós értékeket). A korrigált adatokból kötegelt művelettel kivágtam a hat mintaterületet.

3. táblázat A kutatáshoz felhasznált Landsat műholdfelvételek.

Műhold	Dátum	Pászta	Sor	Csempe által lefedett mintaterületek
Landsat-7	2000.05.16	187	27	Pesti hordalékkúp-síkság
	2000.08.20	187	27	
	2000.10.23	187	27	
	2000.04.21	188	27	Hevesi ártér
	2000.05.07	188	27	Tétényi-fennsík
	2000.06.08	188	27	
	2000.07.10	188	27	Gödöllői-dombság
	2000.08.11	188	27	
	2000.10.14	188	27	
	2000.04.28	189	27	Felső-örség
	2000.07.01	189	27	
	2000.08.18	189	27	Balatoni-riviéra
	2000.10.21	189	27	
	Landsat-8	2017.08.09	189	27
2017.08.11		187	27	Hevesi ártér
2017.08.18		188	27	Pesti hordalékkúp-síkság Tétényi-fennsík Gödöllői-dombság
2017.08.25		189	28	Balatoni-riviéra

3.3. Sentinel felvételek

A Sentinel program célja az előregedett földmegfigyelő műholdak (mint például az ERS program műholdjainak) lecserélése olyan következő generációs műholdakra, amik megfelelnek a modern kutatások kihívásainak. A programot az ESA koordinálja és hajtja végre, az ESA és az Európai Bizottság közös kezdeményezésének, a „Globális Környezetvédelmi és Biztonsági Megfigyelés” (GMES – Global Monitoring for Environment and Security) részeként. Ezt a kezdeményezést 2011-ben Copernicus névre keresztelték át, mint az Európai Unió és az Európai Űrügynökség közös földmegfigyelési programját. A program a műholdak generáció váltását úgy hajtja végre, hogy figyelembe veszi az adatok folytonosságát, és az új idők követelményeit. Az egyes küldetések mind más és más célt szolgálnak, melyek részei a Copernicus programnak, ennek megfelelően mindegyikhez más típusú mérőberendezést fejlesztenek ki. Jelenleg 6 küldetés zajlik a program keretein belül és további 6 van tervben (Jutz és Milagro-Pérez, 2020).

A Sentinel-1 küldetés célja a radar alapú földmegfigyelés. A küldetés részeként 2 műhold kering azonos pályán (jelenleg csak 1, a Sentinel-1B meghibásodása miatt), 180°-os eltéréssel, 693 km-es magasságban 98,18°-os inklinációjú közel napszikron pályán. Az egyes műholdak visszatérési ideje (időbeli felbontása) 12 nap, az azonos pályának köszönhetően az együttes visszatérési idejük 6 nap. Azonos képkészítő berendezéssel vannak ellátva, ami egy C-sávban (frekvencia: 5,405 GHz – hullámhossz: 5,5465763 cm) felvételező szintetikus apertúra radar (SAR). A műszer képes duális polarizációval is működni (HH-HV, VV-VH) (Jutz és Milagro-Pérez, 2018). Négyféle adatgyűjtési móddal rendelkezik: Stripmap (SM) – Sávterképező mód, Interferometric Wide Swath Mode (IW) – Szélessávú interferometrikus mód, Extra Wide Swath Mode (EW) – Extra szélessávú mód, Wave mode (WM) – Hullám mód. Ezek közül a szélessávú interferometrikus mód a fő leképezési mód a szárazföldek felett. A felvételezési módtól függően a felvételek térbeli felbontása 5 és 40 méter között váltokozhatnak. Az IW a TOPSAR (Terrain Observation with Progressive Scanning SAR) technika segítségével 3 alsávban képezi le a felszínt úgy, hogy változtatja az antenna nézési szögét. Ez a technika lehetővé teszi a széles sávon (250km) történő felmérést, közepes térbeli felbontással (5x20 méter). Az interferometriát biztosítja a kielégítő nagyságú átfedés a Dopplerspektrumban (azimuth tartományban) és a hullámszám-spektrumban (magassági tartományban). A Sentinel-1 megfigyelései forgatókönyv¹ alapján a szárazföldek fölött, amelyek nem poláris vagy jeges elhelyezkedésűek az IW mód duális VV-VH polarizációval felvételez. A Sentinel-1-es adatokat a CLC18-as adatbázis létrehozásához, az adatok

¹ <https://sentinel.esa.int/web/sentinel/missions/sentinel-1/observation-scenario> megtekintve: 2022.04.22
15:13

polarimetrikus leírónak éves statisztikáiból származó különböző kompozitok formájában használták fel.

A Sentinel-2 küldetés alapvető célja a Föld felszínének folyamatos megfigyelése, multispektrális optikai mérőberendezéssel. A program alapját a Sentinel-2 iker műholdak adják, amelyek egy multispektrális felvételező rendszerrel (Multi-Spectral Instrument – MSI: Multispektrális Műszer) szereltek fel. A program első műholdját (Sentinel-2A) 2015. június 23-án állították pályára, míg ikerműholdját (Sentinel-2B) 2017. március 7-én. A műholdak tervezett élettartama 7,25 év. A két műhold azonos, napszinkron pályán kering, 786 km-es magasságban, egymástól 180°-os eltéréssel. Az időbeli felbontásuk 10 nap, viszont az azonos pályának köszönhetően az együttes időbeli felbontásuk 5 napra csökkent ((SUHET) Sentinel User Handbook and Exploration Tools, 2015).

A multispektrális felvételező rendszer (MSI) úgy lett kialakítva, hogy az eddigi földmegfigyelési programok (Landsat, SPOT) spektrális sávjait is figyelembe vették, így biztosítja a SENTINEL-2 küldetés ezen programok folytonosságát. A műszer 13 spektrális sávja lefedi a Landsat-8 és a SPOT 6/7 műholdak sávjait (4. táblázat). A 8a sáv célja a közeli infravörös egy kisebb részének érzékelése, ezáltal a vízpára által okozott atmoszférikus zaj csökkentése. A kék hullámhossztartományban található 1. sávot a többi sáv pontos aeroszol korrekciójánál használják fel (ezt már korábbi küldetések során is használták). A cirrus felhők korrekciója érdekében került a sávok közé a SWIR (10-es) sáv, amely lehetővé teszi a cirrus felhők detektálását (a korrekció a látható és közeli infravörös sávokra alkalmazható). A szenzor radiometrikus felbontása 12bit (4095 érték). A műszer által készített egy felvétel 290x290km nagyságú ((SUHET) Sentinel User Handbook and Exploration Tools, 2015). A Sentinel-2-es adatokat a CLC18-as adatbázis létrehozásához, 2 hetes felhőmentes mozaikok formájában használták fel Magyarország területére az alábbi időpontokból: 2016-szeptember, 2017-április, 2017-július, 2017-szeptember.

4. táblázat A Sentinel-2A és 2B műholdak MSI szenzorjainak sávkiosztásai és felbontásuk.

Sentinel 2A/B MultiSpectral Instrument (MSI)			
Sáv száma	S2A Hullámhossz (nm)	S2B Hullámhossz (nm)	Felbontás (m)
1	442,7-469,7	442,2-487,2	60
2	492,4-590,4	492,1-590,1	10
3	559,8-604,8	559,0-605,0	10
4	664,6-702,6	664,9-703,9	10
5	704,1-723,1	703,8-723-8	20
6	740,5-758,5	739,1-757,1	20
7	782,8-810,8	779,7-807,7	20
8	832,8-977,8	832,9-965,9	10
8a	864,7-897,7	864,0-896,0	20
9	945,1-971,1	943,2-970,2	60
10	1373,5-1448,5	1376,9-1452,9	60
11	1613,7-1756,7	1610,4-1751,4	20
12	2202,4-2444,4	2185,7-2423,7	20

A Sentinel-1 felvételeket az NASA, Alaska Satellite Factory (ASF) online felületéről (<https://asf.alaska.edu/>) töltöttem le 1. szintű Ground Range Detected (GRD) terméként (5. táblázat). Az adatok 2 sávot (VV, VH polarizáció) tartalmaznak. Az előfeldolgozást Sentinel Application Platform (SNAP) szoftverkörnyezetben végeztem el. Az előfeldolgozás során az általánosan használt lépéseket végeztem el: pályafájl alkalmazás (apply orbit file), termális zaj eltávolítás (thermal noise removal), kalibrálás, domborzat-korrekción (range-Doppler terrain correction) (Filipponi, 2019). Ezen lépések után a 2 polarizáció (VV-VH) értékeit dB-re (sigma0 dB) alakítottam át. Az előfeldolgozott termékek 10 m felbontásúak lettek. Az adatokon foltzűrést (speckle filtering) nem alkalmaztam az adatvesztés elkerülése végett.

5. táblázat A kutatáshoz felhasznált Sentinel-1 műholdfelvételek.

Időpont	Pálya	Szelet sorszáma	Csempe által lefedett mintaterületek
2017.07.24	124	19	Felső-Őrség, Balatoni-riviéra
2017.07.25	51	18	Pesti hordalékkúp-síkság, Hevesi-ártér, Tétényi-fennsík, Gödöllői-dombság

A Sentinel-2 műholdképeket a Copernicus Open Access Hub online felületéről (<https://scihub.copernicus.eu/dhus/#/home>) töltöttem le L1C vagy L2A szintű feldolgozottsággal (a felvételek intenzitásértékei toposzféra-alja (Bottom-Of-Athmosphere) vagy teteje (Top-Of-Athmosphere) reflektancia értékek) (6. táblázat). A felvételek 11 sávot tartalmaznak, mivel a 10-es sáv nem kerül be a letölthető sávok közé ezen a feldolgozottsági szinten, és a térbeli felbontásuk 10, 20, és 60 méteres. A műholdfelvételek spektrális sávjainak értékei 0,0-tól 1,0-ig terjedő intervallumban vehetnek fel értékeket. Az előfeldolgozást QGIS

3.16, az ERDAS Imagine 2020 és a SNAP szoftverkörnyezetben végeztem el. Azokat a felvételeket melyek toposzéra alja reflektancia értékekkel rendelkeztek, atmoszféricusan korrigáltam. Az előfeldolgozás során a különálló fájlokban tárolt spektrális sávok mindegyikét 10 méteres felbontásra újramintavételeztem, majd a sávokat egyesítettem egy fájlba. A korrigált adatokból kötegelte művelettel kivágtam a hat mintaterületet.

6. táblázat A kutatáshoz felhasznált Sentinel-2 műholdfelvételek.

Időpont	Pálya	Csempe azonosítók	Csempe által lefedett mintaterületek
2017.01.01	122	33TWN, 33TXN	Felső-örség
2017.01.05	36	34TCT, 34TDT	Pesti hordalékkúp-síkság, Hevesi ártér, Tétényi-fennsík, Gödöllői-dombság
2017.03.29	79	33TXM, 33TYN, 34TCT	Pesti hordalékkúp-síkság, Balatoni-riviéra, Tétényi-fennsík, Gödöllői-dombság
2017.04.25	36	34TDT	Hevesi ártér
2017.05.15	36	34TDT	Hevesi ártér
2017.06.24	36	34TCT	Pesti hordalékkúp-síkság, Tétényi-fennsík, Gödöllői-dombság
2017.07.07	79	33TWN, 33TXN, 34TCT	Pesti hordalékkúp-síkság, Felső-örség, Tétényi-fennsík, Gödöllői-dombság
2017.07.17	79	33TXM, 33TYN	Balatoni-riviéra
2017.08.03	36	34TDT	Hevesi ártér
2017.08.08	36	34TCT	Pesti hordalékkúp-síkság, Tétényi-fennsík, Gödöllői-dombság
2017.10.02	36	34TCT, 34TDT	Pesti hordalékkúp-síkság, Hevesi ártér, Tétényi-fennsík, Gödöllői-dombság
2017.10.15	79	33TWN, 33TWM, 33TYN, 33TXN	Felső-örség, Balatoni-riviéra
2017.12.01	36	34TCT, 34TDT	Pesti hordalékkúp-síkság, Hevesi ártér, Tétényi-fennsík, Gödöllői-dombság
2017.12.19	79	33TWN, 33TWM, 33TYN, 33TXN	Felső-örség, Balatoni-riviéra

3.4. Shuttle Radar Topography Mission (SRTM)

Az SRTM az amerikai Nemzeti Térinformatikai Hírszerző Ügynökség (National Geospatial – Intelligence Agency) és a NASA közös projektje, amelynek célja magassági adatok gyűjtése a Föld minél nagyobb részéről egy űrsiklóra telepített radarberendezés segítségével. A hosszas előkészületek után a küldetés 2000. február 11-én kezdődött el és 2000. február 22-ig tartott. A 11 napos küldetést (2000. február 11.–február 22.) az Endeavour űrsikló hajtotta végre, amelynek inklinációja 57° volt, ezáltal a radar képes volt a Föld felszínének északi szélesség 60° és a déli szélesség 56° közötti felmérésére. Ezzel a bolygó szárazföldi területeinek 80 százalékát lefedte (Farr et al., 2007). A mérés eredményeképpen 10 TB nyers adat jött létre, amelynek feldolgozása 2 évet vett igénybe (Farr és Kobrick, 2000). Ezután az adatokat továbbították az USGS-nak, amely tárolja és biztosítja az ingyenes hozzáférést a saját EROS szerverén. A létrejött adatok 3 fokmásodperc felbontásúak (körülbelül 90 m, foktrapézonként 1201×1201 pixel) az egész felvételezett területre vonatkozóan (az USA

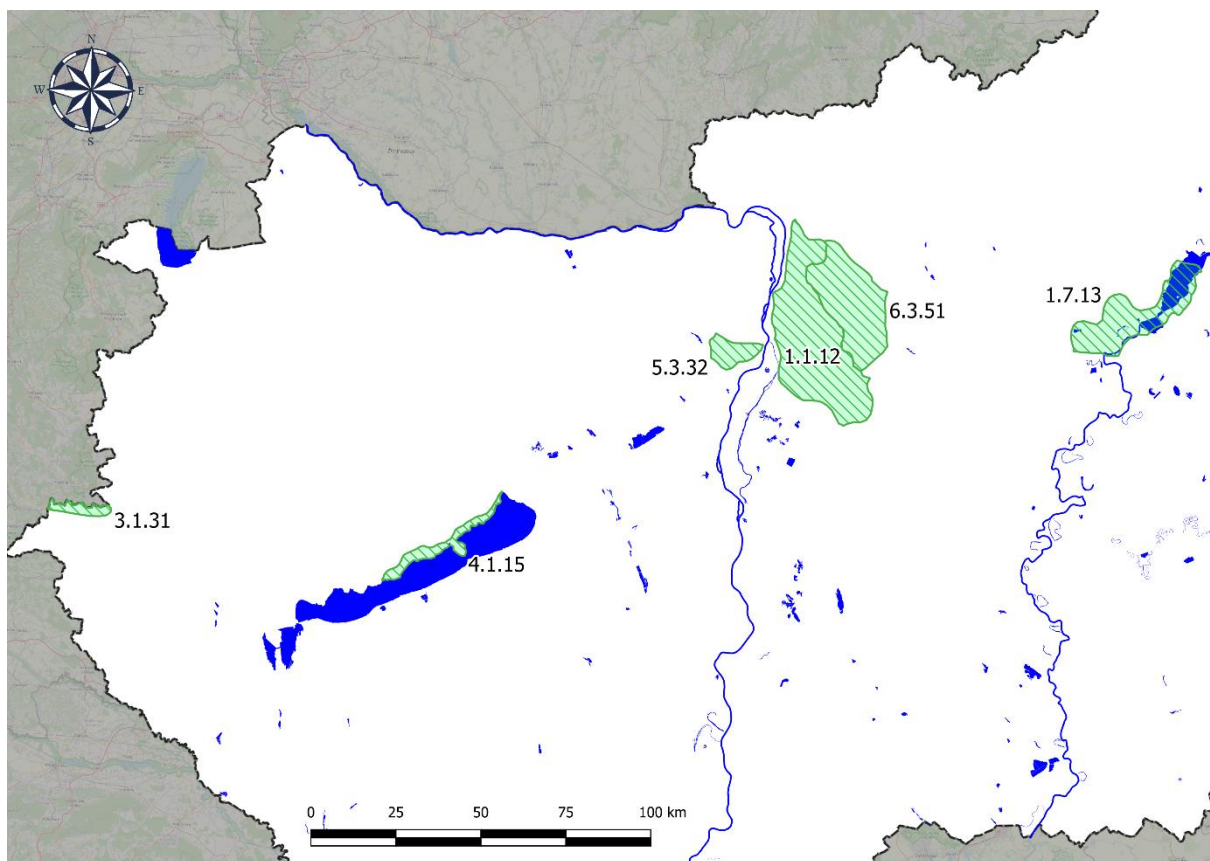
területére 1 fokmásodperces adatok is elérhetőek) (Farr et al., 2007). Az alapfelületük WGS84 ellipszoid. Az SRTM adatok a felszín magasságát adják meg, így ezek az adatok alkalmasak a szintkülönbségekkel rendelkező osztályok közötti szeparabilitás növelésére. Az SRTM adatokat az EarthExplorer adatbázisából töltöttem le (<https://earthexplorer.usgs.gov/>). A letöltött csempeket egyesítettem, majd a mintaterületek körvonalalaival, kivágatokat készítettem belőlük.

3.5. Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) Global Digital Elevation Model (GDEM)

Az ASTER szenzor a NASA és a japán gazdasági, kereskedelmi és ipari minisztérium (Ministry of Economy, Trade, and Industry – METI) közös projektje. A berendezést a Lockheed Martin által készített Terra műholdon helyezték el, négy másik műszerrel együtt. A műholdat 1999. decemberében állították pályára. A műszer három alrendszerrel (szenzorral) rendelkezik: (1) látható fény és közeli infravörös, (2) közepes infravörös, (3) termális infravörös (Yamaguchi et al., 1998). Mindegyik alrendszer más térbeli és spektrális felbontással rendelkezik. A globális digitális magassági modellt (GDEM) a látható fény és infravörös alrendszer által készített sztereó-képpárokból állították elő (Abrams et al., 2010). A GDEM a Föld északi 83° és déli 83° közötti területeket fedi le, ezáltal a szárazföldek 99%-ról szolgáltat információt (Abrams et al., 2020). Az adatbázis első verzióját 2009-ben adták ki, amelyet már 2 alkalommal frissítettek (2011-ben és 2019-ben). Az adatok a NASA Earthdata honlapjáról érhetőek el (<https://search.earthdata.nasa.gov/search/>), 1 fokmásodperces (kb. 30 méteres) térbeli felbontással. A letöltött csempeket egyesítettem, majd a mintaterületek körvonalalaival, kivágatokat készítettem belőlük.

4. Mintaterületek

Az osztályozások megfelelő összehasonlításához kulcsfontosságú lépés a mintaterületek kiválasztása. Ezt egyik, a disszertációm témájához illeszkedő, azt előkészítő vizsgálataim során igazoltam, amelyben Csongrád megyét jelöltem ki a vizsgálatom mintaterületének (Gudmann et al., 2019). A vizsgálatban egy általam kidolgozott, döntési fára épülő módszertan segítségével felszínborítási/területhasználati térképeket hoztam létre. Az eredményeim alapján megállapítottam, hogy a döntési fa algoritmus a mintaterületen domináns osztályt (Nem-öntözött szántóföldek, a mintaterület több mint 60%-át tette ki), magas pontossági értékekkel (>80%), míg a kis részarányú osztályokat jelentősen kisebb pontossággal (<60%) osztályozta. Emiatt az eltérés miatt az eredmények nem teljes mértékben adják vissza az algoritmus teljesítőképességét.



15. ábra A hat kiválasztott mintaterület.

A disszertációmban a mintaterületeket Magyarország kistájai közül választottam ki. A területek kijelölése során több olyan szempontra is külön figyelmet fordítottam, amelyek alapvetően befolyásolják az osztályozási eredményeket és az osztályozó algoritmusok összevetését. Az egyik ilyen, hogy a területek alapvetően eltérő felszínborítással és területhasználattal rendelkezzenek, azaz az egyes mintaterületeken különböző osztályok forduljanak elő és a legnagyobb részarányal rendelkező kategória is eltérő legyen. Ezáltal, a felszínborítási és területhasználati kategóriák közötti osztályozási különbségek megfigyelése is lehetséges. Továbbá, egy adott mintaterületen belül, egyik kategória részaránya se legyen 50%-nál nagyobb. Ennek köszönhetően kiküszöbölhetők a magas területi arányok miatti torzulások az osztályozási eredményekben. Az egyes kategóriák részarányát a CORINE Land Cover adatbázisok alapján határoztam meg minden kistájra vonatkozóan. A meghatározott értékek alapján készítettem el a leválogatást a korábban említett tényezők figyelembevételével és az eredményül kapott területek közül választottam ki a hat különböző karakterisztikájú kistájat. Ezek a következők lettek: Pesti hordalékkúp-síkság (kistáj azonosító: 1.1.12.), Hevesi-ártér (kistáj azonosító: 1.7.13.), Felső-Örség (kistáj azonosító: 3.1.31.), Balatoni-riviéra (kistáj azonosító: 4.1.15.), Tétényi-fennsík (kistáj azonosító: 5.3.32.) és Gödöllői-dombság (kistáj azonosító: 6.3.51.) (15. ábra). A mintaterületek leírása „Magyarország kistájainak katasztere” alapján történt (Becse et al., 2010).

A Pesti hordalékkúp-síkság Pest megyében és Budapest területén helyezkedik el. A kistáj 97.5 és 251 m közötti tengerszint fölötti magasságban helyezkedik el, 892 km² területen. Kelet felé lépcsőzetesen, magasabb teraszok irányába emelkedik. A felszín döntő többsége közepes magasságú, tagolt síkság. Mérsékelt meleg, száraz éghajlatú kistáj. A napsütéses órák száma 1910–1940 óra évente (nyáron 770–780, télen 180 óra). Az évi középhőmérséklet 10–10,2 °C, és az évi csapadékösszeg 520–580 mm. A táj jelentős részét települések és mezőgazdasági területek foglalják el. Területének kisebb része töredékes állományú nyílt homokpusztagyepkekből, homoki sztyeprétekből, homoki tölgyesekből és nyáras-borókásokból áll, mellettük jelentős az akác- és fenyőültetvények aránya. A 22 önálló településen kívül ide tartozik a főváros pesti oldalának döntő része is, így a kistáj területének 35%-a lakott terület. Az itt élő több mint egy millió ember 97.5%-a városlakó és a terület népsűrűsége extrém magas. A kistájon 23 CLC kategória található meg, amelyek közül 13 legalább 1%-os részarányal bír. A legnagyobb kiterjedésűek a 2.1.1. – „Nem öntözött szántóföldek”, 1.1.2. – „Nem összefüggő településszerkezet” és a 3.1.1. – „Lombhullató erdők” (A1. táblázat).

A Hevesi-ártér Heves és Jász-Nagykun-Szolnok megyében helyezkedik el. Területe 388 km². A kistáj legalacsonyabb pontja 85,4 méter és a legmagasabb 90,5 méter közötti tengerszint fölötti magasságú. Az egyhangú kistáj felszíni formáit a Tisza alakította ki oldalezó erózióval és erős feltöltő tevékenységével. Mérsékelt meleg-száraz éghajlatú terület, különösen a D-i részei. Az átlagos napsütéses órák száma egy évre 1920-1960 óra között változik (nyáron 760–770, télen 175–180 óra). Az évi középhőmérséklet 10,1–10,3 °C, mellette évi 510–540 mm az átlagos csapadékösszeg. A kistáj a Tisza egykori árterét foglalja magában, melynek ártéri és mentett oldali részének növényzete ma eltérő jellegeket mutat. A Tisza-tó gazdag hínár-, lápi és mocsári komplexekben és az erdőket jobbra jellegtelen fűzligetek alkotják. Az árvizek és az általuk jelentett állandó veszély miatt a kistájon mindössze 4 település található és a népességszáma nagyon alacsony, és ezzel együtt a népsűrűsége is. A kistájon 15 CLC kategóriák található, melyek több mint fele legalább 1%-os részarányal bír (8 db). A domináns osztály, ami a terület kb. felét kiteszi, a 2.1.1. – „Nem öntözött szántóföldek”. Emellett nagyobb részarányban van jelen az 5.1.2. – „Állóvizek”, a 3.1.1. – „Lombhullató erdők” és a 4.1.1. – „Szárzöldi mocsarak” (A1. táblázat).

A Felső-Őrség kistáj Vas megyében helyezkedik el, területe 63 km². A kistáj az Alpokalja közepesen tagolt (átlagos relatív relief 48 m/km²), teraszos, eróziós-deráziós dombsági területe, amely a Ny-i országhatár, a Rába és a Pinka-völgy torkolati szakasza között helyezkedik el. Átlagos tengerszint fölötti magassága 252 m. A mérsékelt hűvös-mérsékelt nedves éghajlati övezetbe tartozik. Az átlagos napsütéses órák száma évi 1820 óra körüli (nyáron 700–720, télen 180 óra). Az évi középhőmérséklet 9,2–9,4 °C, mellette évi 750 mm az

átlagos csapadékösszeg. Alacsony dombvidéki jellege ellenére vegetációja számos hegyvidéki vonással bír: bükkösök és gyertyános-kocsánytalan tölgyesek uralják a tájat. Továbbá a völgyek alján égerligetek és keményfás ligeterdők találhatóak és magas a telepített fenyves-monokultúrák aránya. A csekély méretű kistájon összesen 3 falu található, emiatt a népsűrűség és a lakosság nagyon alacsony a területen. A kis kiterjedésű kistájon a CLC kategóriák száma alacsony, csupán 9 fordul elő, melyek közül csak egy részaránya nem éri el az 1%-ot. A domináns kategória, amely a terület kb. felét kiteszi, a 2.1.1. – „Nem öntözött szántóföldek”. Emellett nagyobb részarányban van jelen az 5.1.2. – „Állóvizek”, a 3.1.1. – „Lombhullató erdők” és a 4.1.1. – „Szárzsföldi mocsarak” (A1. táblázat).

A Balatoni-riviéra Veszprém megyében helyezkedik el, területe 159 km². A különböző genetikájú és magasságú, többnyire D-i kitettségű síkok, völgyek és völgyközi hátságok mellett számos mikroforma fordul elő. Tengerszint feletti magassága 110 és 180 m között változik. Mérsékelt meleg-mérsékelt száraz éghajlatú kistáj. Az évi napsütéses órák száma kevéssel meghaladja a 2000 órát (nyáron 800–810, télen 190 óra). Az évi középhőmérséklete 10,2–10,5 °C, mellette évi átlagos csapadékösszeg 580–640 mm. A klímazonálisan többségében erdőssztyepp-övbe tartozó terület ma jellemzően fél-kultúrtáj (szép példa erre Tihany). Feltűnő a déli, szubmediterrán jellegű fajok magas aránya. Hagyományos gyümölcskultúrái: a szőlő, és a délvidéki fajok (füge, levendula), a hegyoldalakon erdőszedés figyelhető meg. Nagyon sűrű településhálózat jellemzi a kistájat, 100 km²-re több mint 10 település jut, ami viszonylag magas népsűrűséggel és közepes mennyiségű lakosságszámmal társul. A kistájon megtalálható CLC kategóriák száma 17, amelyek többsége (13) nagyobb mint 1% részarányal rendelkezik. A domináns kategória, mely a terület kb. felét kiteszi, a 2.1.1. – „Nem öntözött szántóföldek”. Emellett nagyobb arányban van jelen az 5.1.2. – „Állóvizek”, a 3.1.1. – „Lombhullató erdők” és a 4.1.1. – „Szárzsföldi mocsarak” (A1. táblázat).

A Tétényi-fennsík Pest megyében és Budapesten helyezkedik el, területe 108 km². Tagolatlan fennsíkok jellemzik, kopár, száraz, egész évben vízhiányos felszíne terméketlen, erdőgazdasági hasznosításra is alkalmatlan. Mérsékelt meleg-száraz éghajlatú kistáj, az évi napsütéses órák száma 1940 óra (nyáron 765, télen 175 óra). Az évi középhőmérséklet 10 °C, mellette az évi átlagos csapadékösszeg 550–580 mm. Jelentős részben beépített, illetve felszántott kistáj, a természetes vegetációval borított terület nem éri el a 20%-ot, és aránya jelenleg is csökken. A tölgyesek és a száraz gyepek kiterjedése jelentős. Igen technogén, urbanizált kistáj, területének kb. a fele beépített. A népsűrűsége többszöröse az országos átlagnak és a lakosságszáma is folyamatosan növekszik. A kistájon található 16 CLC kategória többsége (13) 1%-ot meghaladó részarányal rendelkezik. A domináns kategória, aminek területe folyamatosan növekszik, a 1.1.2. – „Nem összefüggő településszerkezet”. Emellett

nagyobb részarányban van jelen a 3.1.1. – „Lombhullató erdők” és a 1.4.2. – „Sport-, szabadidő- és üdülő területek” és a 2.3.1. – „Rét/legelő”. A területen jelentős városiasodás történt, ezért a mesterséges felszínek (1.1.2., 1.2.1., 1.4.2.) részarányának növekedésével a mezőgazdasági területek (2.1.1., 2.2.2., 2.3.1.) nagysága is jelentősen lecsökkent. (A1. táblázat).

A Gödöllői-dombság Pest megyében található, területe 510 km². A kistáj 138 és 344 m közötti tengerszint fölötti magasságon helyezkedik el, egy enyhén DK felé lejtő dombvidéken. Mérsékeltén hűvös-mérsékeltén száraz, illetve mérsékeltén-száraz éghajlatú, az évi napsütéses órák száma 1950 óra (nyáron 780–790, télen 190 óra). Az évi középhőmérséklet 9,5–10 °C, mellette az évi átlagos csapadékösszeg 540–580 mm. A dombság platóin jellemző a gyertyános-tölgyeshez hasonló, de bükkös elemekben és gyertyánban szegényebb mezei juharos tölgyes. Kisebb kiterjedésű, de fontos társulás a lösztölgyes. A kistáj teljes területére jellemzőek a nyílt és a zárt homoki gyepek. A nagyterületű kistáj majdnem teljes egészében a budapesti agglomerációhoz tartozik, rajta 16 településsel. Az átlagos településsűrűséghez nagy népsűrűség tartozik. A kistájon található 16 CLC kategória többsége (13) 1% feletti részarányal rendelkezik. A domináns kategória, ami egyre nagyobb részarányú, a 1.1.2. – „Nem összefüggő településszerkezet”. Emellett nagyobb részarányban van jelen a 3.1.1. – „Lombhullató erdők”, a 1.4.2. – „Sport-, szabadidő- és üdülő területek” és a 2.3.1. – „Rét/legelő”. A területen jelentős városiasodás történt, ami miatt a mesterséges felszínek (1.1.2., 1.2.1., 1.4.2.) részarányának növekedésével a mezőgazdasági területek (2.1.1., 2.2.2., 2.3.1.) nagysága jelentősen csökkent. (A1. táblázat).

5. Módszerek és eredmények

5.1. Osztályozási módszertan koncepciójának kialakítása

A kutatásom során kétféle környezetben dolgoztam, egy szoftveres és egy programozási környezetben. A módszerek kialakításánál fő szempont volt, hogy mindenki számára használható legyen a módszertan, ezért a felhasznált eszközök mindegyike ingyenesen elérhető és/vagy nyílt forráskódú.

A kutatásom első szakaszában a WEKA általános adatbányászati szoftvert (Eibe et al., 2016) használtam, amellyel egységesen elvégezhető az adatelőkészítés, tisztítás és osztályozás. A szoftver különböző haladó osztályozási, regressziós algoritmusokat is tartalmaz, illetve a szoftverben további algoritmusokat is adaptálhatunk kiegészítő csomagok telepítésével. A kutatásom második szakaszában a korábban kiválasztott vagy nem rendelkezésre álló algoritmusokat adaptáltam *python* programozási környezetbe, amivel az osztályozási folyamat nagy mértékben automatizálhatóvá vált. Mivel mindkét módszer általános osztályozási felhasználásra lett kifejlesztve, így az általam használni kívánt térinformatikai adatokat általánosan felhasználható formátumba kellett alakítani. Az átalakítás előtti adatharmonizációs és kiválasztási lépéseket QGIS szoftverrel végeztem el. A WEKA szoftverben főleg az algoritmusok kalibrációjára és a régebbi, hagyományos gépi tanulásos osztályozó eljárások vizsgálatára, míg a *python* környezetben a legújabb algoritmusok vizsgálatára összpontosítottam. Mindkét módszernél az algoritmusok teljesítményét a *maximum likelihood* osztályozás eredményeihez hasonlítottam, amit *ArcMap* szoftverben készítettem el.

A WEKA szoftver alkalmazásához szükséges módszertannál, az adatok előkészítése során a már elkészített kivágatokat egy raszteres fájlba egyesítettem. Az egyesített fájlokat több lépésben *python* scriptekkel transzformáltam *gdal* és *numpy* függvénykönyvtár segítségével (Contributors, n.d.; Harris et al., 2020). Első lépésben a raszteres adatállományomból ASCII (.asc) formátumú nyers szövegfájl másolatot készítettem, amely tartalmazza a raszteres adat pixeleinek x és y koordinátáit. Ezen koordináták szükségesek voltak az osztályozott értékek raszteres állománnyá történő visszaalakítása miatt. Második lépésben, az ASCII fájl koordinátáinak és a raszteres adatállomány sávonkénti értékeinek összefűzésével hoztam létre egy tagolt szövegfájlt (*csv*). A létrehozott fájl már alkalmas volt a szoftverbe történő beolvasásra. A szoftver beolvasó funkciója segítségével, kiválaszthatók az egyes változók adattípusai és kijelölhető a nominális (címkéket tartalmazó) változó. A szoftverben ezután véletlenszerűsítettem az adatokat és létrehoztam a betanításhoz szükséges tanító és teszt halmazokat. Ezeket a halmazokat használtam fel az osztályozáshoz és a modell létrehozásához, illetve a modell teljesítményének meghatározásához. Az osztályozással meghatározott

kategória értékeket, a koordinátákkal összefűzve tudtam újra raszteres formátumú adatot létrehozni.

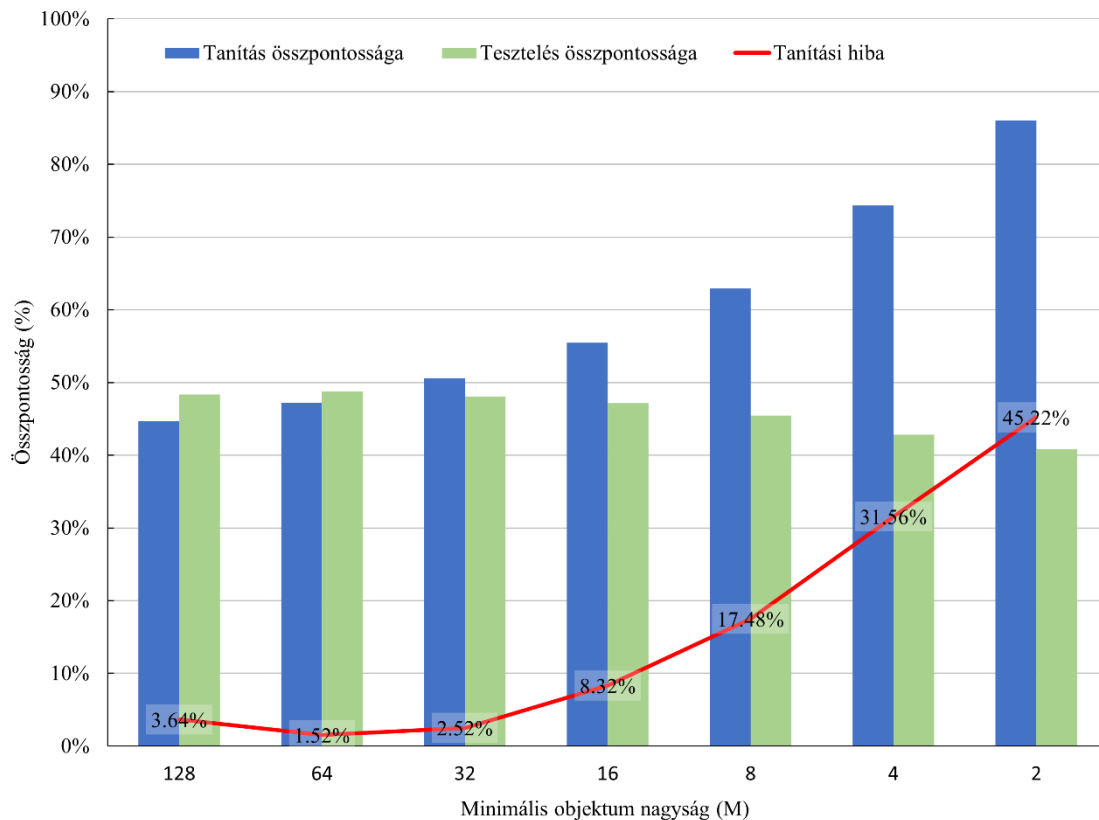
A *python* programkörnyezetben történő osztályozáshoz és az ahhoz szükséges módszertanhoz is az első lépésben a már elkészített kivágatokat egy raszteres fájlba egyesítettem. A tanító és validáló adatok létrehozásakor a QGIS véletlen pont generálás funkcióját használtam. A CLC adatsorok bizonytalanságának csökkentése érdekében, azokon a poligonokon belül hoztam létre validáló pontokat véletlenszerűen, amelyek az elmúlt 30 évben nem változtak (kivéve azon osztályok esetén, amelyek ideiglenes kategóriák, pl. „Építési területek”). A nem változó poligonok kiválasztásához az összes CLC-adatbázist (CLC90, CLC00, CLC06, CLC12 és CLC18) elmetszettem egymással, és kiválasztottam az azonos CLC-kóddal rendelkező poligonokat. Ezzel a módszerrel a validáló pontok megbízhatósága 97% fölé kerül, így megfelelő alapot biztosítanak az összehasonlításokhoz (Gudmann és Mucsi, 2022). A tanító pontokat a változó poligonokon belül hoztam létre, véletlenszerűen elhelyezve. A létrehozott tanító és validáló pontok attribútum táblájába beleírtam az x és y koordinátákat, mező kalkulátor segítségével. A pontokat ezután a *point sampling tool* nevű modul segítségével mentettem ki tagolt szövegfájlba. Hasonlóan az előző módszerhez, a fájlokat több lépésben *gdal* és *numpy* függvénykönyvtár felhasználásával *python* scriptekkel alakítottam át. A raszteres adatállományomból ASCII formátumú nyers szövegfájl másolatot készítettem, majd az ASCII fájl koordinátáinak és a raszteres adatállomány sávonkénti értékeinek összefűzésével hoztam létre egy tagolt szövegfájlt (csv). Az osztályozáshoz elkészített script az adatok automatikus beolvasását, tisztítását és osztályozását végzi el. Az osztályozás során automatizálva történik a paraméterbecslés, a modellépítés, a becslés és az adatok visszaalakítása raszteres formátummá. Továbbá a *python* környezetben lehetőség van olyan mérőszámok kiszámítására, ami a WEKA szoftverben nem lehetséges. A kutatásomban ilyen volt a permutációs fontosság érték, ami megmutatja egy adott változó fontosságát a változókészletben. A script a gépi tanulási osztályozásokhoz leggyakrabban használt *python* könyvtárakat használja, ezek a GDAL, a NumPy, a Pandas, a Scikit-learn, és a Tensorflow (Abadi et al., 2015; Contributors, n.d.; Harris et al., 2020; Pedregosa et al., 2011).

5.2.1. Algoritmusok kalibrációja

Az algoritmusok kalibrációja során, a modellépítési paraméterek hatásait vizsgáltam, azzal a céllal, hogy olyan paraméterhálót tudjak meghatározni, amelyen belül a legjobb teljesítményt nyújtó modellek építhetők fel. Emellett, a kalibráció során meghatároztam azt a tanítóterület nagyságot, a teljes adathalmazhoz viszonyítva, ami szükséges az osztályozás megfelelő elvégzéséhez az egyes osztályozók esetén. Ezáltal meghatározható, hogy az egyes algoritmusok megfelelő működéséhez mekkora mennyiségű referencia információ szükséges,

így kijelölve, hogy azok milyen valós esetekben hasznosíthatók. Az algoritmusok kalibrációja során a WEKA szoftvert használtam fel a 2000-es évből származó adatokon. A Jeffries-Matusita szeparabilitás értékekből kiderült, hogy az egyes spektrális sávok biztosan nem elegendők, hogy az egyes kategóriákat megfelelően elválasszassuk egymástól (13. és 14. ábra). Ezért, a kalibráció során a Landsat-7-es műholdképek összes sávját felhasználtam, mint magyarázó változók, így összesen 7 magyarázó változó volt a tanítóadathalmazon belül. A paraméterháló meghatározásához a tanító és teszt adathalmaz aránya 33-66% volt, az adott mintaterület teljes adathalmazán belül. A paraméter hálók vizsgálatánál a döntési fa, a véletlen erdő, a tartó-vektor gép és a mesterséges neurális háló paramétereit elemeztem. A háló meghatározásánál, minden mintaterület esetén a tanító és teszt adathalmazon mért kappa statisztikát és összpontosságot, továbbá a kettő közötti, úgynevezett tanítási hibát, és a modellépítési időt vizsgáltam.

A döntési fa algoritmusnál, a WEKA-ba adaptált J48-as döntési fát használtam. A J48-as döntési fa az Interactive Dichotomize 3 (ID3)-as családba tartozó C4.5-ös típusú algoritmus kiterjesztése és a szeparabilitás meghatározásához az entrópia értékét alkalmazza. Az algoritmus a fa létrehozásakor az entrópiacsökkentés elvét alkalmazza, a nyereségarány mutató (*gain-ratio*) alkalmazásával. Ennek köszönhetően a lehető legkisebb modell jön létre a modellépítés során (Bhargava et al., 2013). A modellépítés során utómetszést (*post pruning*) is alkalmaztam, hogy tovább csökkentsem a modell nagyságát. A modellalkotó eljárásához két paramétert kell megadni, a minimális objektum nagyságot (M): ennél az értéknél kisebb elemszámú végződést nem alakíthat ki az algoritmus, illetve a konfidencia faktort (C): ami az utómetszésnél, mint határérték jelenik meg (a megadott konfidencia értéknél kisebb végzések lesznek „lemetszve”). A paraméterek tesztelése a paraméter értékek változtatásával történt ($\pm 10\%$). Az eredmények alapján az objektumnagyság alapvetően befolyásolja a betanítás és a tesztelés pontosságát. Minél kisebb az objektumnagyság annál nagyobb a betanítás pontossága, és kisebb a tesztelés pontossága, azaz túltanítás lép föl (16. ábra). Ebből következtethetünk, hogy a nagyobb minimális objektum nagysággal, általánosabb szabályrendszert hoz létre az algoritmus. Az eredmények alapján a legkisebb tanítási hiba a 16 és 512 közötti minimális objektum nagysággal érhető el. Ez a tanító adathalmaz nagyságához képest 0,0006% és 1,5% közötti tartományt jelent. A másik paraméter, a konfidencia faktor változtatása kis hatással van a modell pontosságára (1% alatti pontosság különbség), azonban a modell méretét is befolyásolja. Ezzel a modell becslési ideje nagy mértékben csökkent és így javult a modell teljesítménye. Az eredmények alapján a konfidencia faktor 0,15 és 0,05 között eredményez teljesítmény javulást.



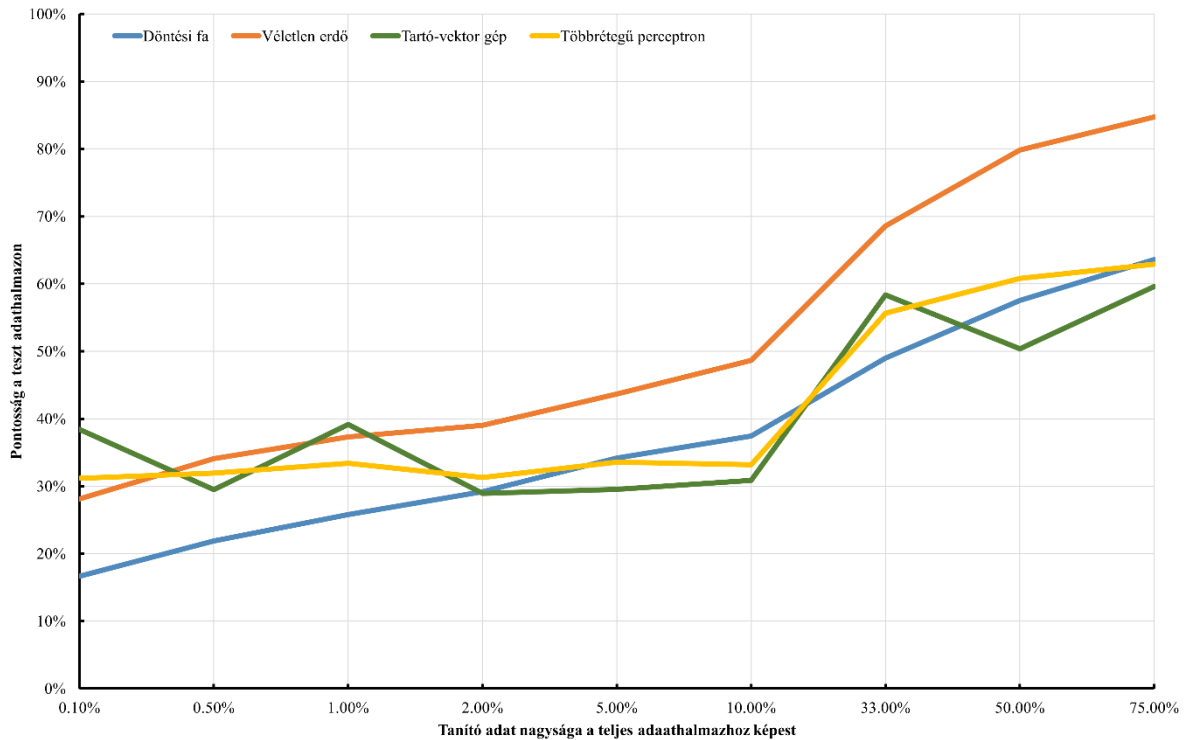
16. ábra A 1.1.12-es mintaterületen mért összpontosságok a minimális objektumnagyság függvényében.

A véletlen erdő algoritmusnál, a WEKA-ba adaptált J48-as döntési fán alapuló algoritmust használtam. Ennél az algoritmusnál a döntési fát nem korlátozzuk (nincs megadva minimális objektumnagyság és gallyazást sem alkalmazunk). A modellben lévő döntési fákat gallyazás nélkül használjuk fel, így bár az egyes modellek túltanítottak lehetnek, a modellben lévő torzítás kisebb lesz. A paraméterháló meghatározásánál a modellépítő attribútumok száma (F - Features), a létrehozott fák száma (I - Iterations), a zsák nagyság (S - Size) paraméterek változtatása történt, próbálgatás útján ($\pm 10\%$). Az eredmények alapján a zsák nagyságának csökkentésével a tanítási hiba csökkenthető (60%-ról 30%-ra, átlagosan 7,389%), míg a teszt adaton mért pontosság növelhető (átlagosan 6,572%). Az iterációk számának növelésével (100-ról 300-ra) a tanítási hiba átlagosan 6,952%-ot csökkent, azonban a teszt adaton mért pontosság nem javult ugyanilyen mértékben, csupán 0,341%-ot átlagosan. A változók számának növelése kis mértékben volt hatással a tanítási hibára és a pontosságra ($< 0,5\%$). Azonban 50%-fölé történő növelésével az összes változóhoz képest már rontja a modell teljesítményét. Az eredmények alapján, az ideális paraméter kombinációkat csak együttesen lehet alkalmazni, mivel a 3 paraméter egymást is befolyásolja, illetve fontos a bemenő attribútumok „minősége” (adattartalma). Az vizsgálatok alapján meghatároztam, hogy a legjobb modellekhez a bemenő attribútumok értéke az összes attribútumhoz képest 25-45%-os. Továbbá, a zsák nagysága 30%, míg az iterációk száma 100 és 300 db között mozoghat.

A tartó-vektor gép esetén nem a WEKA-ban adaptált nem-lineáris algoritmust, hanem a külön könyvtárként telepített LIBLINEAR lineáris SVM-t használtam (Fan et al., 2008). Ennek oka, hogy a nem-lineáris SVM-ek csak kis tanító adathalmazon (<10 000 esetszám) alkalmazhatók megfelelő teljesítménnyel, azonban a távérzékelt adatok, és az ezekből generált tanító adathalmazok ennél jóval nagyobbak. Az ilyen nagy adathalmazokon, megfelelő teljesítménnyel csak az SVM-k közül csak a lineáris változatok alkalmazhatók, viszont csak kisebb pontossági értékek érhetőek el velük, mint a nem-lineáris változataikkal. A lineáris SVM-nél a két vizsgálendő paraméter a költség (C - cost) és az elterelő súly (B – bias) volt, valamint a modellépítésnél mindig alkalmaztam normalizálást a tanító adatokon, ellenkező esetben értékelhetetlen modelleket kaptam (50% alatti összpontosság). Az eredmények alapján a modell teljesítményére a költség paraméter volt a legnagyobb hatással, ami viszonylag magas érték mellett eredményezte a legjobb modelleket. A súly értéke kis variációs lehetőséget nyújtott, a 4 vagy annál nagyobb értékek már nagy mértékben rontották a pontosságot (teszt adaton csak 60,49% összpontosság). A legjobb összpontossággal és legkisebb tanítási hibával rendelkező modelleket 40 és 80 közötti költség érték és 1 vagy 2 súllyal értem el.

A neurális hálók közül a WEKA-ba a többrétegű perceptron van adaptálva, amely alkalmazza a hiba-visszaterjesztést. A többrétegű perceptron az egyik leggyakrabban alkalmazott neurális háló. Az algoritmus modellépítő paraméterei a tanulási ráta (learning rate - L), momentum (M), a rejtett rétegek száma (H) és a tanítási idő (T). A WEKA-ban integrált modellnél, több más paraméter mellett, nem szabályozhatjuk a neuronok számát, a neuronok aktivációs függvényét és az optimalizációs stratégiát sem. A tanító adathalmazon normalizálást alkalmaztam a modellépítés előtt. A paraméterek tesztelése során a paraméterek egyformán fontosnak bizonyultak a modell végleges teljesítménye szempontjából. A legjobb modelleket 2 és 6 közötti rejtett réteg számmal, 0,05 és 0,25 közötti tanulási rátával, 0,1 és 0,2 között momentummal és 7 és 12 perc közötti tanítási idővel állítottam elő.

Az egyes algoritmusok paraméter hálójának meghatározása mellett, vizsgáltam, hogy mekkora tanítóadathalmazon érik el a megfelelő teljesítményt. Az adathalmaz nagyságát a teljes osztályozni kívánt halmazhoz képest relatívan határoztam meg. A vizsgálatot minden algoritmus esetén a két legnagyobb területű kistájon (1.1.1.2., 6.3.5.1.) végeztem el. Az algoritmusokat a paraméterháló meghatározásánál a legjobb pontosságot nyújtó paraméter beállításokkal építettem fel. Az eredmények alapján a döntési fa és a véletlen erdő pontossága hasonlóan változott, míg a tartó-vektor gép és többrétegű perceptron pontossága egyedi módon volt változékony a tanító adat nagyságának függvényében (17. ábra).

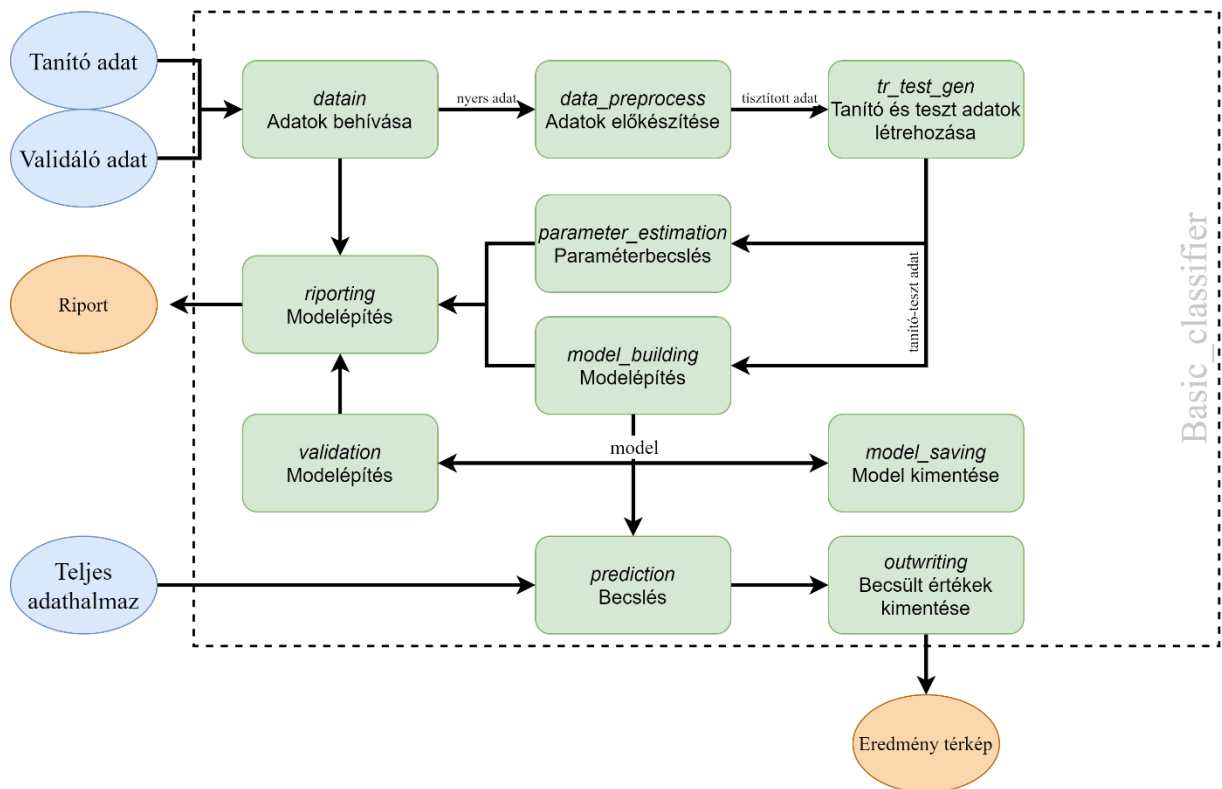


17. ábra Az egyes modellek összpontosság változása a tanító adathalmaz nagyságának függvényében.

A döntési fa és a véletlen erdő pontossága a tanító adat növelésével fokozatosan javult. A véletlen erdővel már a teljes adathalmaz nagyságához viszonyított 33%-os tanítóadat nagyságnál elfogadható minőségű modellt lehet alkotni. A tartó-vektor gép és többrétegű perceptron pontossága 10% alatti tanító adat esetén változékony volt, azonban 10% fölött egyértelmű pontosság javulást eredményezett a tanító adat nagyságának növelése. Mindegyik algoritmus esetén megállapítható, hogy a 33%-os tanító adat méret alatt a pontosság javulás mértéke nő, 33% fölött a javulás mértéke csökken. Emiatt, a további elemzésekben a tanító adathalmaz nagyságát 33% vagy attól kis mértékben eltérő ($\pm 5\%$) nagyságban rögzítettem a teljes adathalmazhoz képest.

5.1.2. Algoritmusok adaptálása python programozási környezetbe

Az algoritmusok kalibrációja során több problémával szembesültem. Egyik ilyen probléma volt a WEKA szoftverben történő paraméterbecslés, ami a szoftverben csak manuálisan volt kivitelezhető és emiatt nagy időráfordítással járt. További nehézséget okozott, hogy az algoritmusok meghatározott paramétereit tudtam csak módosítani, így nem tudtam teljes mértékben szabályozni az algoritmusok modellépítő eljárását és így a végleges modell pontosságát sem. Ezeknek a problémáknak a feloldására hoztam létre egy *python* szkriptet, több függvénykönyvtár (GDAL, NumPy, Pandas, Scikit-learn, Tensorflow) felhasználásával (18. ábra).



18. ábra Az osztályozáshoz elkészített *python* script felépítése.

A script a tanító és validáló adatokat tartalmazó tagolt szövegfájl beolvasásával és az osztályozó algoritmus kiválasztásával kezdődik. A beolvasott adatokból a hibás esetek (végtelen értékűek) értékeit nullára változtatom. Továbbá a lebegőspontos értékeket felszorzással egész számokká alakítottam. Ennek köszönhetően az összes változó értéke egy dimenzióba került, így az értékek abszolút különbségét felhasználó algoritmusok nagyobb pontosságot érhetnek el. Ezenkívül az egész számos alak memória felhasználás szempontjából is kedvezőbb. Ha az algoritmus számára szükséges volt a magyarázó változókon normalizálást, akkor a cél változón átkódolást végeztem el. Az adatok előkészítése után a tanító adathalmazt felosztottam 2 részre, az egyik halmazzal a paraméterpróbát végeztem el, míg a másik halmazon történt a betanítás, így a kapott pontossági értékek a különböző adatokon mérve jobban mutatják a modell pontosságát. A paraméterpróba során véletlenszerűsített paraméterkeresési módszert alkalmaztam, amely ugyan nem teszti le az összes lehetséges paraméter kombinációt, de kis időráfordítással a optimális paramétereket adja meg. A paraméterbecslés ezenkívül jól mutatja, melyik algoritmus mennyire robusztus, illetve felhasználóbarát. A véletlen erdőnél a különböző paraméterkombinációkkal tanított modellek közül a teszt adaton mért legalacsonyabb és legmagasabb pontosságok között átlagosan csupán 2,1% különbség volt, addig a gradiens-növelő fánál már 6,01%, míg a neurális hálónál 27,75%. Ezek alapján a véletlen erdő algoritmust legkönnyebb parametrizálni, míg a neurális hálót a legnehezebb.

A kapott paraméterek felhasználásával készült el a végleges modell, amely alkalmazásával történt a validálás és a becslés. A script egy osztályozott térképet és egy riport fájlt készít el a legfontosabb teljesítményt leíró adatokkal. A leíró adatok között több összpontossági érték is szerepel a lehető legrészletesebb és megbízhatóbb eredmények elérése miatt.

5.2. Az osztályozáshoz felhasználható, bemenő adatok vizsgálata

Az osztályozások során egyre nagyobb hangsúlyt kap a megfelelő bemenő változók kiválasztása és/vagy létrehozása. Az egyre növekvő adathalmazok, amelyek következtében minden változónak (dimenzióknak) sokkal nagyobb hatása van az osztályozó modell teljesítményére. Ezért a változók kiválasztásánál már nem csak a változó információtartalmát és ezzel együtt a pontosságra kifejtett hatását kell vizsgálnunk, hanem hatását a modell teljesítményére a pontossággal összefüggésben. Vagyis az adott változó információtartalma elég nagy-e ahhoz képest, hogy mennyivel növeli a modell futási idejét.

A területhasználat osztályozásban is kulcsfontosságú a megfelelő változók kiválasztása, mivel a távérzékelte adatok osztályozási folyamata alapvetően adatorientált, így a kezdeti kutatási koncepciókat sokszor a rendelkezésre álló adatok alapján kell kialakítanunk, vagy a meglévőt módosítanunk. A legtöbb esetben az osztályozáshoz egy időpontból áll rendelkezésre számunkra felvétel az adott területről a térképezés elvégzéséhez. Azonban egy adott felvétel sokszor nem hordoz akkora információmennyiséget, ami a területhasználati kategóriák elkülönítéséhez szükséges, főleg, ha az alkalmazott nomenklatúra nagyszámú kategóriát tartalmaz. Ilyen esetben szükségünk lehet olyan adatokra, amelyek az eredeti felvételtől levezetve többletinformációt hordoznak és ezáltal növelik a térképezésünk pontosságát. A másik lehetőség, hogy többféle adatforrásból származó felvételekkel biztosítjuk a megfelelő információmennyiséget az osztályozáshoz. Ilyen adatfúziós eljárásnál azonban nagy hangsúlyt kell fektetnünk az adatok harmonizációjára. Ha több időpontból áll rendelkezésünkre felvétel az adott területről, akkor az információ többlet a felvételek közötti időkülönbségből adódik, amennyiben a felszint borító anyag reflektancia tulajdonsága változik ezen idő alatt. Ebben az esetben arra kell figyelmet fordítanunk, hogy mekkora időkülönbség szükséges a felvételek között ahhoz, hogy a különböző felvételek már eltérő információt hordozzanak. A disszertációmban ezeket a lehetőségeket vizsgálom meg a gépi tanulós osztályozó eljárások alkalmazásával.

Az eredmények kiértékelésnél négy többsztályos osztályozási feladatoknál használt mutatószámot számítottam ki és hasonlítottam össze: az összpontosságot, a felhasználói pontosságot, a készítői pontosságot és az F-számot (7. táblázat) (Congalton és Green, 2008). Az összpontosság a legalapvetőbb mutatószám, amely megmutatja, hogy térképünk hány

százalékát osztályoztuk megfelelően. Az osztályozás során az elvárt összpontosság legalább 80%. A felhasználói és készítői pontossági adatok osztályszintű betekintést nyújtanak az eredményeinkbe. A felhasználói pontosság azt mutatja meg, hogy adott osztályba besorolt pixelek közül mennyi a jól osztályozott pixel. Azaz, hogy az osztályozó modell adott kategóriára adott becslései mennyire megbízhatóak. A készítői pontosság pedig azt mutatja meg, hogy az adott kategória az eredmény térképen milyen gyakran adja vissza a referencia térképet, vagyis az eredmény térkép milyen valószínűséggel adja vissza az adott kategóriát a terepen (milyen jól tükrözi a valóságot). Az F-számot (vagy F1-számot), alapvetően bináris osztályozási eredmények kiértékeléséhez alakították ki, azonban többsztályos esetekben is használható. A mutatót a felhasználói és a készítői pontosság harmonikus átlagaként számolhatjuk ki, amely így egy kompozit számként tudja az adott osztály pontosságát jellemezni. Az eredmények bemutatásánál a bemutatott mérőszámokat vettem össze, amelyeket a validáló pontok alapján számítottam ki.

7. táblázat A bemenő adatok kiértékeléséhez használt statisztikai mutatószámok (Congalton és Green, 2008) alapján.

Mérőszám	Kiszámítási mód
Összpontosság (Overall accuracy)	$\frac{A \text{ térképen jól osztályozott pixelek összege}}{A \text{ térkép pixeleinek összege}}$
Felhasználói pontosság (User's accuracy)	$\frac{A \text{ térképen } y \text{ kategóriába jól osztályozott pixelek összege}}{A \text{ térképen } y \text{ kategóriába osztályozott pixelek összege}}$
Készítői pontosság (Producer's accuracy)	$\frac{A \text{ térképen } y \text{ kategóriába jól osztályozott pixelek összege}}{A \text{ referencia térkép } y \text{ kategóriába tartozó pixeleinek összege}}$
F-szám (F-score)	$\frac{2 * a \text{ térképen } y \text{ kategóriába jól osztályozott pixelek összege}}{2 * a \text{ térképen } y \text{ kategóriába jól osztályozott pixelek összege} + a \text{ térképen } y \text{ kategóriába osztályozott pixelek összege} + a \text{ referencia térkép } y \text{ kategóriába tartozó pixeleinek összege}}$


5.2.1. Spektrális információk és derivátumaik hatékonyságának vizsgálata az osztályozás szempontjából

A felszínborítás osztályozásánál a leggyakrabban felhasznált adatforrások a multispektrális műholdfelvételek. Azonban a területhasználati kategóriák száma, átmeneti jellege és nem diszkrét meghatározása miatt a felvételek spektrális értékei önmagukban nem minden esetben elegendők az osztályozás megfelelő pontossággal való elvégzéséhez. Ezért szükségünk lehet különböző kiegészítő adatokra, amiket az eredeti adatokból származtathatunk. Ilyenek lehetnek a spektrális indexek vagy a transzformációk. A felvételek spektrális sávjainak

vizsgálatán túl, a multispektrális műholdképekből különböző típusú származtatott adatokat számítottam ki. Célul tűztem ki, hogy megvizsgáljam, ezen adatok felhasználásával hogyan változik az osztályozások pontossága és a modellek teljesítménye. Az egyes adatok hatásának vizsgálatához a CLC adatbázisokhoz használt műholdképek alapján végzett osztályozás pontosságát vettem alapul. Ezekkel az értékekkel vettem össze az egyes derivátumok és a műholdképek kombinációi alapján létrehozott modellek teljesítményét.

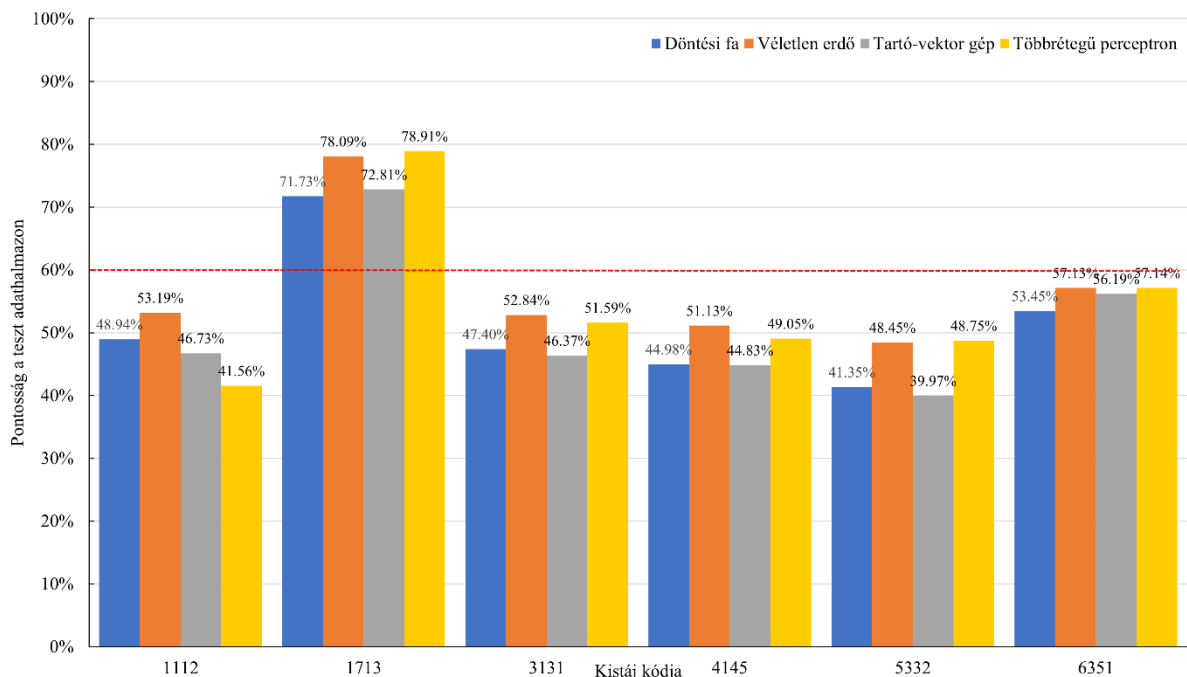
5.2.1.1. Spektrális sávok hatékonyságának vizsgálata

A műholdfelvételek spektrális sávjai különféle információkat tartalmaznak egy adott területen fekvő objektumokról. A területhasználati kategóriák közvetlenül nem érzékelhető tulajdonságaik miatt, a spektrális sávok önmagukban gyakran nem elegendők az összes területhasználat jellegű kategóriák közvetlen osztályozására. Ez a jelenség jól kimutatható az egyes osztályok szeparabilitás értékei alapján, amely megmutatja, hogy mennyire különíthetők el az egyes kategóriák a spektrális térben. Az általam, a CLC00 adatbázis és az ehhez felhasznált Landsat-7 (L7) felvételek (A4. táblázat) felhasználásával a mintaterületekre kiszámított Jeffries-Matusita távolságokon (13. ábra) jól látszik, hogy az egyes sávok alapján a kategóriák minimális távolság értéke (azaz a legkevésbé elkülöníthető osztály értéke) a 0-hoz közelít (0 = nem szeparálható eset). Még az összes sáv együttese használata esetén is a minimális távolság érték a lehetséges maximum (1414) felét se éri el (14. ábra). A CLC18-as adatbázis alapján a Sentinel-2 felvételek 1-1 sáv reflektancia értékeiből számolt osztályok szerinti JM távolságok minimumai is nagyobbak, mint a L7 felvételekből az összes sáv alkalmazásával kapott JM távolság érték (19. ábra).



19. ábra A Pesti hordalékkúp-síkságra kiszámolt JM távolságok, osztályonként, a CLC18-ás adatbázis és a Sentinel-2 sávjai alapján.


Valamint az átlagos elválaszthatóság értékei is magasabbak, de ezek az értékek a legtöbb esetben így sem érik el a maximális érték felét. Azonban a minden sáv alapján számított szepearabilitás értékek, amelyek majdnem minden osztály esetén 1000 fölötti értékek, már igen magas elkülöníthetőségre utalnak. A szepearabilitás értékek alapján levont következtetést altámasztják a pontossági értékek, amiket a L7-es spektrális sávok felhasználásával készített modellek adtak (20. ábra). Ezek alapján a 6 mintaterület közül 5 esetében egyik osztályozó algoritmus se tudott elégségesnek mondható eredményt adni (60% alatti pontosság) a spektrális sávok alapján. Csupán 1 mintaterületnél volt különbség, azonban ott mindegyik osztályozó közepes pontosságot ért el (70–80% között).



20. ábra A különböző algoritmusok által az egyes mintaterületek tesz adathalmazán mért pontossági értékek a Landsat 7-es spektrális sávok alapján.

Az eredmények konfúziós mátrixai alapján vizsgálni tudjuk az osztályszintű hibákat is. A legjobban urbanizált 1112-es (Pesti hordalékkúp-síkság) mintaterületen a konfúziós mátrixok alapján a területen lévő 24 kategóriából 18-at egyik modell sem jelzett. A többi 6 között pedig nagyfokú átosztályozás tapasztalható, főleg a 2.1.1.-es „Nem öntözött szántóföldek” kategóriánál, amely a 2.3.1.-es „Rét, legelő”, a 2.4.2-es „Komplex művelési szerkezet” és a 3.2.4-es „Átmeneti erdős-cserjés területek” kategóriákkal keveredett. Az 1713-as (Hevesi-ártér) mintaterületen a 15 CLC szerint létező kategóriából csak 5 osztály jelent meg a modellfuttatás után az eredménytérképen. Az 5 osztályozott kategória azonban csak kis mértékben osztályozódott át egymás között. Az erdős 3131-es (Felső-Őrség) mintaterületen a 9 kategóriából 4 nem jelent meg a becsült térképen. Az átosztályozások a 3. hierarchia szinten belül jelentkeztek, ahol a 3.1.1-es „Lomblevelű erdők”, a 3.1.2-es „Tűlevelű erdők”, a 3.1.3-as

„Vegyes erdők” és a 3.2.4-es „Átmeneti erdős-cserjés területek” keveredtek különböző mértékben. A 4145-ös (Balatoni-riviéra) mintaterületen a lehetséges 14 lehetséges osztályból 9 megtalálható a becslt térképeken. Ebből a 9 osztályból 2 kategória helyesen osztályozódott: a 2.2.1 „Szőlők” és a 3.1.1 „Lomblevelű erdők”, a többi kategória közepes mértékben.



21. ábra A különböző modellekkel készített osztályozások átlagos F-száma kategóriánként Landsat-7-es sávok alapján.


A legtöbb átosztályozás az 1.1.2-es „Nem összefüggő településszerkezet” és a 1.4.1-es „Városi zöldterületek” között volt. Az 5332-es (Tétényi-fennsík) kistájon csupán 5 kategória nem jelent meg az eredmény térképen a lehetséges 15-ből. A legjobban lehatárolt az 1.1.2-es és a 3.1.1-es kategóriák voltak, míg a legrosszabbul a 3.2.1-es „Természetes gyepek,

természetközeli rétek”, és az 1.3.3-as „*Építési munkahelyek*”. A legnagyobb átosztályozás a már említett 1.1.2-es és az 1.3.3-as kategóriák, illetve az 1.1.2-es és az 1.4.2-es kategóriák között volt. Az utolsó, fővároshoz közel lévő, 6351-es (Gödöllői-dombság) mintaterületen a lehetséges 18 osztályból csupán 3 kategória került lehatárolásra: 1.1.2, 2.1.1, 3.1.1. Az nem osztályozott kategóriák pixelei főleg a 2.1.1-es és a 3.1.1-es kategóriákban lettek besorolva, azonban ez a 3 osztály egymással csak kismértékben keveredett. Az eredmények alapján megállapítható, hogy a legtöbb mintaterületen sok kategória nem került osztályozásra a L7-es spektrális sávok alapján, de a konfúziós mátrixok alapján, az átosztályozások nagy része főosztályon belül történt. Ezek alapján arra a következtetésre jutottam, hogy a spektrális sávok az alapvető felszínborítási kategória (I. hierarchia szint) elkülönítésére még alkalmasak, azonban az inkább területhasználati kategóriák között (II–III. hierarchia szint) már nem alkalmasak az elhatároláshoz.

A mintaterületeken mért F-számok átlaga alapján a legtöbb kategória értéke az alkalmazott modellek esetében közel azonos (21. ábra). A Landsat-7-es spektrális sávjai alapján legjobban elhatárolható kategóriák az 1.1.1-es „*Összefüggő településszerkezet*”, az 1.2.1-es „*Ipari vagy kereskedelmi területek*” és az 1.2.4-es „*Repülőterek*”. Azonban a három osztály közül az 1.1.1-es és az 1.2.4-es is csak egy mintaterületen fordul elő (Pesti hordalékkúp-síkság). A mindegyik mintaterületen jelen lévő 7 osztályból a legjobban osztályozott kategória a 2.3.1-es „*Rét, legelő*”, míg a második az 1.1.2-es „*Nem összefüggő településszerkezet*”. A legnehezebben elkülöníthető kategóriák közé sorolható az 1.3.1-es „*Városi zöldterületek*”, az 1.3.2-es „*Lerakóhelyek, meddőhányók*”, a 3.2.1-es „*Természetes gyep, természetközeli rétek*” és a 4.1.1-es „*Szárazföldi mocsarak*” osztályok. A hat mintaterületen előforduló kategóriák közül a legrosszabb F-számmal a 2.4.3-as „*Elsődlegesen mezőgazdasági területek jelentős természetes növényzettel*” kategória rendelkezik.

A 2018-as adatok esetén a Landsat-8 (L8) és a Sentinel-2-es felvételek spektrális értékei alapján készített osztályozásoknál több szempontot is vizsgálhattam. A spektrális sávok felszínborítást és területhasználatot jellemző képessége mellett elemeztem a térbeli felbontásból és a felvételező rendszerek sávkiosztásából eredő hatásokat is, az osztályozások pontosságára nézve. Az eredmények azt mutatták, hogy az L8-as és az S2-es adatok alapján mindhárom felhasznált algoritmus és mindegyik mintaterület esetén az elégségesnek mondható 60% feletti összpontosságot kaptam. Az L8 spektrális értékei alapján az osztályozások validációs halmazon mért átlagos pontossága a véletlen erdő esetében 69,06%, a gradiens-növelő fa esetében 69,38% és a többrétegű perceptron esetében 67,9% volt. Az S2-es értékekkel történő osztályozás esetében 70% fölötti átlagos pontosság értékek adódtak a validációs halmazokon mérve:

75,09%–75,71%–70,67%. Összeségében az S2-es adatok alapján magasabb összpontosságokat érhetünk el, azonban ezek az értékek is csak közepesnek mondhatóak (<80%).




22. ábra Az S2 és az L8 spektrális sávjainak permutációs fontossági értékei.

A véletlen erdő osztályozásokból származó permutációs fontossági értékek (22. ábra) azt mutatták, hogy az L8-as értékek közül az algoritmus számára a legfontosabbak a közepes infravörös I., a zöld és a vörös sávok voltak. Az S2-es spektrális sávok közül a legfontosabbak az ultrakék és a közepes infravörös I. és II. voltak. Az L8-as hullámhossz tartományai között nem szereplő 5–10-ig terjedő S2 sávok közül a 10-es sáv magas fontossági értékkel rendelkezik (0,23), míg a többi közepes vagy gyenge értékkel (0,06–0,12). Az L8 TIRS sávjaira, amik nincsenek az S2 sávok között, közepes fontossági értékek jellemzők (0,13–0,15). A fontossági értékek és az S2 adatok alapján készített osztályozások kis mértékben a spektrális sávok közötti különbségek, nagyobb mértékben a jobb térbeli felbontás miatt eredményeznek magasabb pontossági értékeket. Mivel így kisebb a keveredés egy adott pixelen belül, ezért több tiszta pixel kerül az osztályozásba. Azonban a változók fontossági értékei alapján az alapvetően nagyobb területet jellemző változók (eredeti térbeli felbontásuk nagyobb, az átmintavételezés miatt több pixelt csoportosítanak) lettek a legfontosabbak, ami utal a térbeliség szerepére is.

A különböző adatokon (L8, S2) betanított modellek átlagos F-száma is az előző állítást támasztja alá (23. ábra). A mintaterületeken lévő 25 CLC kategóriából 20-nál javulást okozott az S2-es adatok felhasználása az L8-as adatok helyett. Az F-szám változás -22,35% és +35,53% közötti intervallumban mozgott, átlagosan +8,12%. A három legnagyobb javulást az F-számban a 3.1.3-as „Vegyes erdők” (+35,53%), a 1.4.1-es „Városi zöldterületek” (+27,66%) és a 2.4.3-as „Elsődlegesen mezőgazdasági területek jelentős természetes növényzettel” (+27,61%)

kategóriáknál figyelhető meg. Ugyanakkor a három legnagyobb visszaesés az F-számban a 1.3.1-es „Nyersanyag kitermelés” (-22,35%), az 1.2.4-es „Repülőterek” (-16,89%) és a 2.2.1-es „Szőlők” (-12,81%) osztályoknál történt.

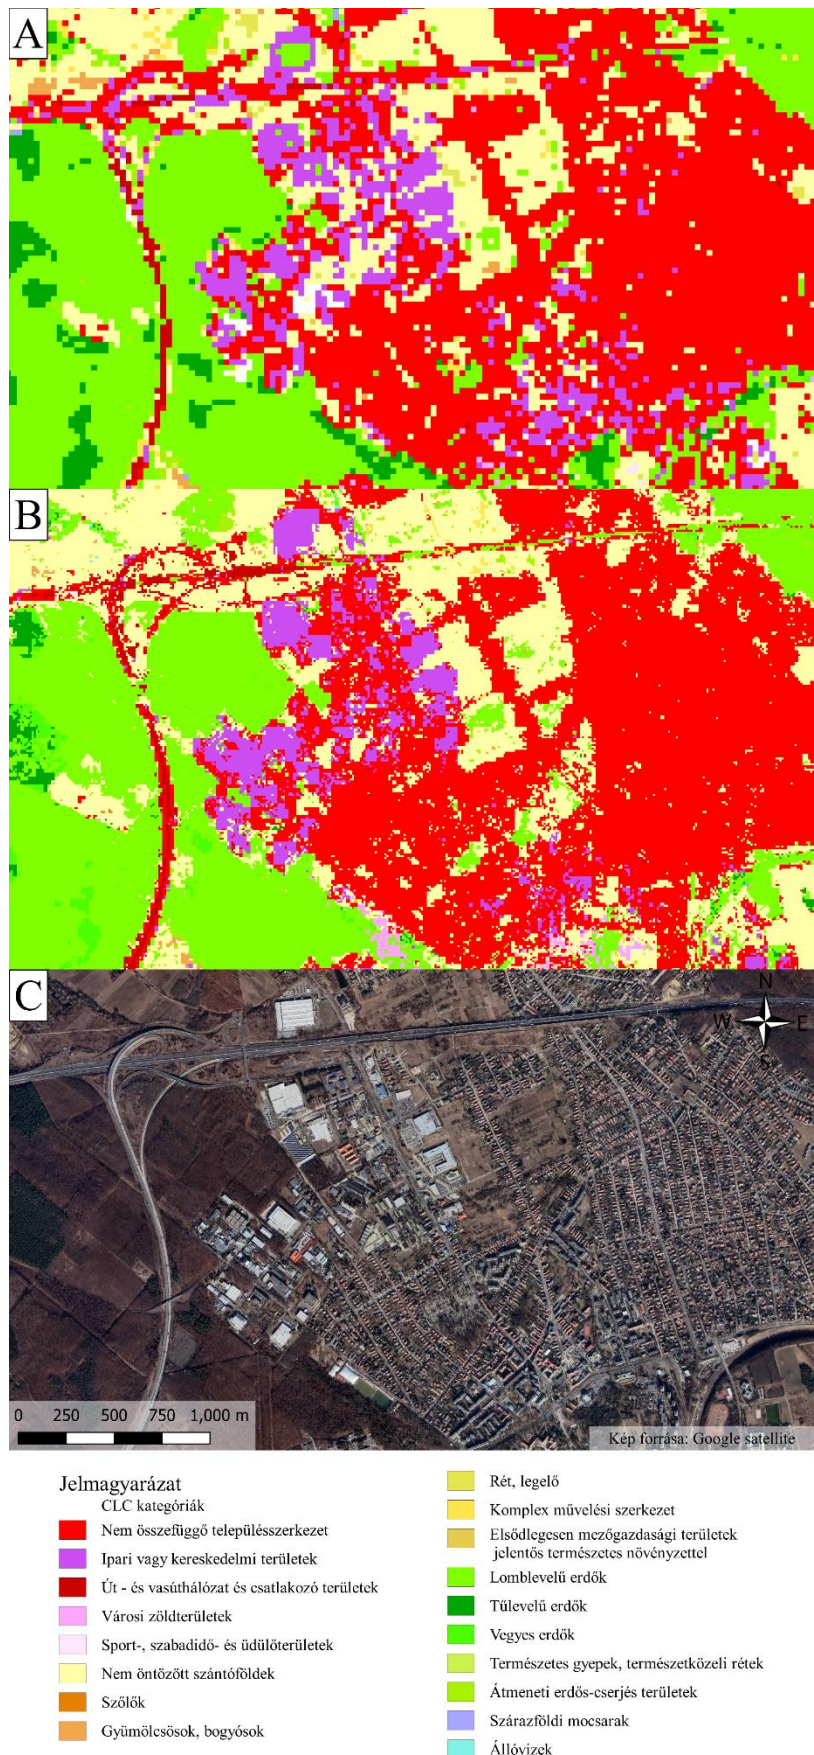


23. ábra A különböző műholdképeken betanított modellekkel készített osztályozások átlagos F-száma kategóriánként.

Az eredmény térképeken is jól látható a két kép felbontásából eredő osztályszintű pontosságnövekedés (24. ábra). A nagyobb térbeli felbontásnak köszönhetően a tisztább

spektrális értékekből homogénebb foltok alakulnak ki, illetve az alapvetően heterogén, városi környezetben is egyértelműbben lehatárolható pixelcsoportok jelennek meg (pl.: ipari létesítmények, csarnokok teteje). Azonban meg kell jegyezni, hogy a városi területeken lévő elszórt pixelek, illetve kisebb homogén pixelcsoportok a CLC minimális térképezési nagysága miatt nem minden esetben eredményeznek pontosságnövekedést a statisztikában.

A Landsat-7 műholdképek spektrális sávjai alapján betanított modellek átlagosan 45,91%-os (min. 39,97%, max. 78,91%) összpontossági értékkel rendelkeztek, így kijelenthető, hogy ezen információk alapján a területhasználati osztályozást az elvárt pontossággal nem lehet elvégezni. A Landsat-8 és a Sentinel-2 adatok alapján




24. ábra Landsat-8 spektrális sávok (A), Sentinel-2 spektrális sávok (B) felhasználásával betanított HGBC modellek eredménytérképei, illetve a valós helyzet (C).

létrehozott modellek 68,78%-os (min. 67,90%, max. 69,38%) és 73,67%-os (min. 70,22%, max. 75,71%) átlagos összpontossággal rendelkeztek, így ezen információk alapján közepes eredménnyel lehet területhasználati osztályozást elvégezni. Ezen eredményeim alapján megállapítható, hogy a spektrális sávok önmagukban nem hordoznak elegendő információt a felszínborítási/területhasználati kategóriák megfelelő lehatárolásához. Továbbá a nagyobb térbeli felbontású Sentinel-2-es műholdfelvételek használatával az osztályozások pontosságát növelni tudtam (+4,89%-kal). (1. cél)

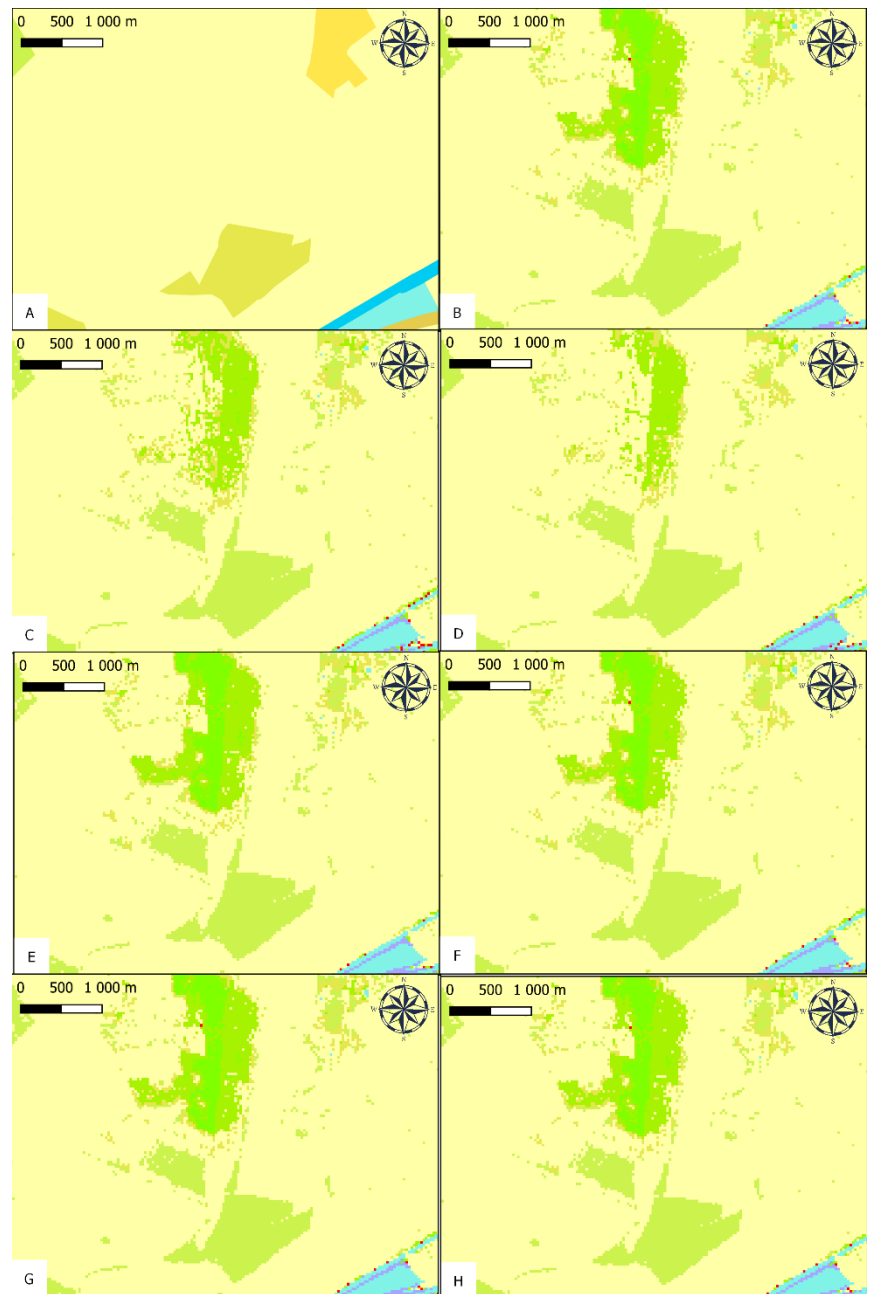
5.1.1.2. Spektrális indexek, mint kiegészítő adatok vizsgálata

Az osztályozásokban leggyakrabban használt kiegészítő bemenő adatok, a műholdképekből számított különböző spektrális indexek (Costăchioiu és Datcu, 2010; Thakkar et al., 2014). Ezen indexek hatása az osztályozás pontosságára nem teljesen egyértelmű. A kutatásomban különböző vegetációs, égési és nedvességi indexeket (NDVI, SAVI, MSAVI, EVI, NBR, NBR2, NDMI) számítottam ki a CLC00-as alapját adó L7-es műholdfelvételek alapján (A2. táblázat, A3. táblázat). Ezen mutatószámok mindegyike több sáv felhasználásával hoz létre új értékeket, ezért az új értékek segítik a felhasználót a felvételek interpretálásában, másrészt mint adattömörítő eljárás is funkcionálnak. Az indexek közül nem mindegyik hordoz információt a felszínborításról vagy a területhasználatról (égési, nedvességi indexek). Ezek azért kerültek a kutatásomba, hogy megvizsgáljam a vegetációs indexek hatása az osztályozásra egyedi jelenség (pl. információ többlet miatt) vagy minden indexre érvényes.












25. ábra Különböző spektrális indexek hatása az osztályozások összpontosságára.

Az egyes indexeket a spektrális sávokkal együtt felhasználva készítettem osztályozásokat. Az indexek különböző kombinációit nem vizsgáltam, mivel az indexek önálló hatását akartam elsőnek megvizsgálni. A mintaterületeken mért indexek eredményeit az egyes algoritmusok szintjén átlagoltam, illetve a modellek átlagait is átlagoltam, hogy átfogó képet kapjak az indexek hatásáról. Az eredmények alapján (25. ábra) a hagyományos vegetációs indexek, mint az NDVI, SAVI, MSAVI, EVI az osztályozás összpontosságát nem, vagy csak kis mértékben növelik (<2%). Továbbá megállapítható, hogy a döntési fa és az azokból felépülő véletlen erdő osztályozónál egyik index sem okozott pontosság növekedést. Azonban a többretegű perceptronnál a 7 indexből 4 is tudott javulást okozni (MSAVI, NBR, NDVI, SAVI). Ezt a képet árnyalja, hogy a 4 indexből a második legnagyobb pontosságbeli javulást nem egy vegetációs



CLC00

	Nem összefüggő településszerkezet
	Nem öntözött szántóföldek
	Rét, legelő
	Lomblevelű erdők
	Természetes gyepek, természetközeli rétek
	Átmeneti erdős-cserjés területek
	Szárazföldi mocsarak
	Folyóvizek, vízi utak
	Állóvizek

26. ábra MLP és különböző spektrális indexek felhasználásával készített térképek:

- A – Az eredeti CLC00 térkép,
- B – A spektrális sávok alapján készült térkép,
- C – A spektrális sávok és az EVI index alapján készült térkép,
- D – A spektrális sávok és az MSAVI index alapján készült térkép,
- E – A spektrális sávok és az NBR index alapján készült térkép,
- F – A spektrális sávok és az NBR2 index alapján készült térkép,
- G – A spektrális sávok és az NDMI index alapján készült térkép,
- H – A spektrális sávok és az NDVI index alapján készült térkép

index, hanem a NIR és SWIR sávokból számítható normalizált égési index (Normalized Burn Ratio - NBR) eredményezte. A tartó-vektor gép esetében a 7-ből 1 index okozott javulást a pontosságban, míg a többi valamilyen mértékben rontotta az eredményeket. Az átlagos pontosság változások mértékét figyelembe véve 3 index egyértelműen rontja (EVI, NBR2, NDMI), 3 index nem egyértelműen rontja (MSAVI, NBR, SAVI), míg egy index minimális szinten javítja a pontosságot (NDVI). Az egyes indexek felhasználásával készült eredménytérképeken is a pontossági adatokból kiolvasható eredmények láthatóak (26. ábra). A térképek nagyban hasonlítanak egymáshoz, az eredeti CLC adatbázishoz képest ugyanazokban a részletekben eltérnek, mint a spektrális sávok alapján készült térkép. Azonban az adott térkép előállításához használt indextől függően az eltérés mértéke változó. A CLC adatbázisban nem jelzett 2 db folt mindegyik térképen jelen van, viszont az indextől függően az alakja, kiterjedése és besorolása eltérő. A legnagyobb eltérés az EVI-t és MSAVI-t használó térképeknél látható, míg a többi térképen csak kisebb, pixel szintűek az eltérések a spektrális sávok alapján készült térképhez képest.

Az L7-es műholdképekből kiszámított indexek eredményei alapján, a következő lépésként olyan indexek felhasználását tűztem ki célul az osztályozásban, amik kiszámításához már nem elegendők a műholdfelvétel sávjai. Ezzel azt vizsgáltam, hogy az új információk önmagukban, legyenek azok bármilyen típusúak, képesek-e javítani az egyes modellek pontosságát. A Sentinel-2-es adatok alapján általam kiszámított ilyen indexek a fraction of Absorbed Photosynthetically Active Radiation (faPAR) index és a Fraction of Vegetation Cover (FVC) (A4. táblázat). A faPAR index az egyik legelterjedtebb és leghatékonyabb műholdképből számított index (Weiss és Baret, 2011), amelynek a kiszámításához szükséges ismernünk a fotoszintetikusan aktív sugárzási értékeket (Photosynthetically Active Radiation – PAR, az elektromágneses spektrum 400 és 700 nm közötti tartománya), továbbá a sugárzáshoz köthető egyéb adatokat (Nap helyzete, azimuth szög, légköri viszonyok). A faPAR értékét az alábbi képlettel kaphatjuk meg (Weiss és Baret, 2011):

$$fAPAR_T(\theta_s, \varphi_s) = (1-f) * fAPAR_{BS}(\theta_s, \varphi_s) + f * fAPAR_{WS}$$

ahol θ_s a napsugarak beesési szöge a nadírhoz képest,

φ_s az azimuth szög,

$fAPAR_{BS}$ a faPAR sötét égbolton (black-sky),

$fAPAR_{WS}$ a faPAR fehér égbolton (white-sky),

f pedig a szóródás direkt frakciója.

A gyakorlatban több módszer áll rendelkezésre a fAPAR index kiszámításhoz. A SNAP szoftver algoritmus a S2 műhold felvételezési adatainak és spektrális sávjainak felhasználásával egy adott sugárzási-transzfer modell és egy neurális háló felhasználásával számítja ki a fAPAR értékeket (Weiss et al., 2020). Ugyanezzel a módszerrel számítható ki a levélfelület indexből (LAI) és más lombkoronaszerkezeti változóból a növényborítottság aránya (FVC), amely a fAPAR-ral ellentétben nem függ olyan változótól, mint a megvilágítás geometriája. Emiatt nagyon jól hasznosítható a klasszikus vegetációs indexek helyettesítésére a zöld növényzet megfigyelése során (Weiss et al., 2020).

Az eredmények alapján a FaPAR és az FVC index, mint az S2 sávok kiegészítő adatok nem okoztak szignifikáns összpontosságbeli különbséget (8. táblázat). Azonban az F-számok vizsgálata azt mutatta, hogy javítani tudták az kategóriák többségének lehatárolását. A 25 kategóriából 19-nél a FaPAR és 16 esetében az FVC felhasználásával növekedett az F-szám. Mindkét index esetében a legnagyobb növekedés az 2.2.1-es „Szőlők” (FaPAR: +22,15%,

FVC: +22,62%), míg a legnagyobb romlás a 3.1.3-as „Vegyes erdők” kategóriánál történt (FaPAR: -27,59%, FVC: -26,31%). Az F-számok alapján kijelenthető, hogy az indexek használatával a kis részarányú kategóriák lehatárolását tudjuk javítani, pár nagy részarányú (pl. 2.1.1. „Nem öntözött szántóföldek”) rovására. Ennek a kettős hatásnak köszönhetően az összpontosságban nem tapasztalható lényegi változást, de osztály szinten igen.

8. táblázat A FaPAR és FVC indexek felhasználásával elkészített eredmények átlagának mutatószámai.


	Sentinel-2	Sentinel-2 + FaPAR	Sentinel-2 + FVC
Összpontosság	73,67%	73,66%	73,48%
F-szám			
111	39,45%	58,99%	54,36%
112	71,59%	71,18%	71,04%
121	52,70%	52,92%	53,71%
122	39,95%	40,53%	39,85%
124	52,16%	61,00%	64,69%
131	10,39%	24,23%	27,75%
132	39,59%	53,77%	58,46%
133	15,49%	32,99%	15,25%
141	43,98%	46,00%	47,65%
142	45,97%	46,90%	46,76%
211	82,24%	81,53%	80,75%
213	70,73%	73,09%	72,25%
221	33,17%	55,31%	55,79%
222	42,71%	48,29%	46,57%
231	55,65%	55,87%	56,78%
242	33,31%	32,80%	31,85%
243	48,14%	47,19%	47,30%
311	71,19%	71,98%	74,66%
312	63,60%	65,34%	64,07%
313	42,70%	15,11%	16,40%
321	18,09%	32,30%	17,21%
324	49,89%	49,90%	49,41%
411	61,96%	63,51%	64,74%
511	82,53%	83,17%	84,59%
512	84,30%	81,59%	85,98%

Az eredményeim alapján a hagyományos spektrális indexek (NDVI, SAVI, MSAVI, EVI, NBR, NBR2, NDMI) és spektrális sávokon felépített modellek összpontosságaiknak átlagai alapján csak az NDVI növelte az osztályozások pontosságát (+0,06%). A többi index rontotta az osztályozások pontosságát -0,14% és -2,54% közötti mértékben. Ezek alapján megállapítottam, hogy a kiválasztott indexek nem hordoznak olyan többlet információt a spektrális sávokhoz képest, ami jelentős mértékben javítaná a gépi tanulós osztályozó modellek pontosságát a felszínborítás és területhasználat térképezésben. Az összetett vegetációs indexek (FaPAR, FVC) átlagosan -0,01%-kal és -0,19%-kal változtatták az összpontosságot, azonban kategória szinten tudták javítani a modellek pontosságát, a 25 kategóriából 16-19 osztály F-szám értékét növelték. (2. cél)

5.1.1.3. Adattranszformációk, mint kiegészítő adatok vizsgálata


A spektrális sávokból matematikai úton és más a kép készítéséhez kapcsolódó információk segítségével előállítható indexek mellett, az adattranszformációk szerepét is vizsgáltam. Két transzformációt választottam ki a vizsgálatomhoz: a főkomponens analízist és a Tasseled Cap transzformációt. A főkomponens analízis (Principal Component Analysis – PCA) az egyik legrégebben alkalmazott dimenziócsökkentő, adattömörítő eljárás. Lényege, hogy csökkentjük a nagyszámú összefüggő változót tartalmazó adattömb dimenzióját úgy, hogy közben megőrizzük az adathalmaz információ tartalmát. A dimenziócsökkentést úgy éri el, hogy transzformálja az adattömböt egy új változó készletre, amiben a változók nem korreálnak, függetlenek egymástól és az első néhány változó megőrzi az eredeti változókban lévő információ tartalom nagy részét (Jolliffe, 1986). A főkomponens analízis első két-három sávja tartalmazza az eredeti sávok információ tartalmának majdnem teljes részét (~90%). A PCA segítségével könnyen megtalálhatók az adatokat legjobban jellemző mintázatok és információcsökkentés nélkül képes tömöríteni az adathalmazt. Továbbá az adatokban lévő zajt is képes jelentősen csökkenteni (Tan et al., 2006). A PCA egy általánosan használt eljárás, míg a Tasseled Cap transzformáció a direkt multispektrális műholdfelvételekhez fejlesztették. „A Tasseled Cap-transzformáció (Kauth és Thomas, 1976) matematikailag a spektrális téren történő elforgatásként és eltolásként értelmezhető. Segítségével a műholdfelvételek úgy alakíthatók át, hogy a dimenziószám csökkenése mellett a felszín térképezés szempontjából lényeges részletek emelkednek ki.” (Mucsi, 2004). A transzformáció eredményeképp a létrejövő spektrális térben a talaj pixelei egy egyenest, ellipszist vagy ellipszoidot formálnak, ez a talajvonala. A vegetáció képpontjai pedig a talajvonala merőlegesen helyezkednek el, és minél fejlettebb a növényzet, annál messzebb található a talajvonala tengelyétől (Mucsi, 2004). A talajvonallal induló növények pályái a fenológiai fázisban egy bojtos sapkához hasonlítanak

a vörös és a NIR sávok által kifejlesztett spektrális síkon, ezért az adattranszformáció a Tasseled Cap nevet kapta. A módszer létrehozása során három adatstruktúrát határoztak meg: a fényességet (Brightness), amely a talajfelszínek és a magas albedójú felszínek reflektancia tulajdonságaival áll kapcsolatban. A zöld index (Greenness) növényzettel kapcsolatos információkat nyújt és a vegetáció előfordulását jelzi. A nedvesség (Wetness) vizet és talajt, valamint a vegetáció nedvességét jelzi. A vizsgálataimban az összes mintaterületre nézve, a kiegészítő adatként az L7-ből kiszámított PCA első három sávját és a Tasseled Cap transzformáció 6 sávját használtam fel az L7 spektrális sávokkal kombinálva (A4. táblázat).




27. ábra Tasseled Cap és PCA sávok hatása az osztályozás összpontosságára.

Az eredmények alapján nehéz egyértelmű, általános megállapításokat tenni a transzformációkról (27. ábra). A Tasseled Cap a négy osztályozó algoritmus közül háromnál nem okozott jelentős pontosságbeli változást, csupán a tartó-vektor gépnél történt jelentősebb, negatív irányú változás (>6%). A PCA-nak nagyobb hatása volt a modellek pontosságára, mint a Tasseled Cap transzformációnak. Ennél a változónál is a tartó-vektor gép esetében változott a legnagyobb mértékben a pontosság, azonban itt pozitív irányba (>4%). A tartó-vektor gépen kívül a többrétegű perceptronnál is pontosságnövekedést okozott a PCA értékek bevonása az osztályozásba. Ugyanakkor a döntési fa és a véletlen erdő esetén egyik transzformáció sem okozott jelentős pontosságbeli változást. Az elkészült térképek vizuális kiértékelése azt mutatta, hogy a Tasseled Cap és a PCA értékek közötti pontosságbeli különbség az SVM osztályozónál nem látható (28. ábra).



28. ábra SVM osztályozó és különböző transzformációk felhasználásával készült térképek:
 A – Eredeti CLC térkép,
 B – Spektrális sávok felhasználásával készült térkép,
 C – Spektrális sávok és Tasseled Cap transzformáció felhasználásával készült térkép,
 D – Spektrális sávok és PCA sávok felhasználásával készült térkép.

Mindkét adat külön-külön történő bevonásával az eredménytérképen lévő osztályok száma lecsökkent és egy homogénebb, de pontatlanabb térkép jött létre. A térképeken a 3 legnagyobb részarányú osztály jelent csak meg: az 1.1.2-es „Nem összefüggő településszerkezet”, a 2.1.1-es „Nem öntözött szántóföldek” és a 3.1.1-es „Lomblevelű erdők”. A transzformációk hatása mellett az is jól látható az osztályozott képeken, ahogy az L8 és S2 összevetésnél is kiemeltem, a részletesebb pixel szintű osztályozás a 25 ha minimális térképi egységgel dolgozó CLC adatbázissal összevetve pontosságcsökkenést eredményez. A településeken lévő szerkezet utcák, terek és parkok vagy a repülőtér kifutópályája mind megjelennek a pixel szintű osztályozásban, azonban ez hibaként jelenik meg a statisztikában.



29. ábra SVM modell által a teszt adaton becsült értékek konfúziós mátrixa a 6351-es kistájon (Gödöllői-dombság).

Az SVM esetén a legnagyobb javulás a Gödöllői-dombságon volt tapasztalható. A mintaterületre elkészített konfúziós mátrix vizsgálatából kiderül, hogy a spektrális sávok alapján készült modell a lehetséges 18-ból, 13-at nem osztályozott jól, míg a spektrális és PCA értékeken alapuló modell csak 11-et (29. ábra). A PCA adatok bevonása javulást eredményezett

a 1.1.2-es „Nem összefüggő településszerkezet”, a 3.1.2-es „Tűlevelű erdők” és az 5.1.2-es „Folyóvizek, vízi utak” kategóriáinak lehatárolásában.

Az eredmények alapján a kipróbált két adattranszformációs eljárás a Tasseled Cap és PCA nem okoztak egyértelmű javulást az osztályozó modellek pontosságában. A Tasseled Cap értékek egyik algoritmus esetén sem hoztak jelentős pontosságnövekedést, míg a PCA értékek az algoritmusok felénél okoztak javulást, amelyek közül a tartó-vektor gép esetén volt jelentős a javulás. **Az eredmények alapján arra a következtetésre jutottam, hogy a Tasseled Cap transzformáció átlagosan -1,45%-os, míg a PCA transzformáció +1,11%-os változást okoz az összpontosságban. Azonban az algoritmusok többségénél (3-ból, 4-nél) a változás 1%-nál kisebb volt, így ezen adatokat csak egyedi esetekben érdemes kiegészítő adatként alkalmazni. (2. cél)**

5.2.2. A képelem környezetéből kinyerhető adatok vizsgálata

Mivel a spektrális indexek és a különböző transzformációk sem hordoztak magukban olyat plusz információt, ami egyértelműen javította volna a különböző osztályozó algoritmusok pontosságát, így olyan mérőszámokat kezdtem vizsgálni, amik nem a pixel saját értékén alapulnak. Ilyenek a pixelek térbeli környezetét valamilyen módon leíró adatok, mint például a különböző kernel módszerek vagy a foltokon/szegmenseken alapuló tájmetriai indexek. Ezek az indexek az emberi logikát követve olyan információkat szolgáltathatnak, amik a pixelek szomszédsági viszonyából adódóan döntő jelentőségűek lehetnek egyes esetekben. A lombhullató erdő és a városi zöldterületek kategóriák mind jelentős arányú lombhullató fát tartalmaznak folt szinten, viszont a városi zöldterületek körül mesterséges felszínek pixelei találhatóak valamilyen távolságon belül. Ugyanilyen logikát követve nehezen elkülöníthető egy sportpálya, amely a „Sport-, szabadidő- és üdülőterületek” kategóriába tartozik a „Rét, legelő” kategóriától. Egy repülőtér kifutópályája sem különbözik az „Út - és vasúthálózat és csatlakozó területek” kategóriától csak az kifutópályát körbevevő komplexum határozza meg a repülőtér jellegét. Ezek alapján a kutatásomban arra kerestem a választ, hogy ezek a pixel környezetét valamilyen módon számszerűsítő metrikák képesek-e a gépi tanuláson alapuló osztályozó algoritmusok pontosságát növelni.

5.2.2.1 Tájmetriai indexek, mint kiegészítő adatok vizsgálata

A kutatásom első része a tájmetriai mérőszámok vizsgálatára irányul, aminek eredményét különálló cikkben is publikáltam (Gudmann et al., 2020). A vizsgálatomhoz a már említett mintaterületek tájszerkezeti heterogenitása miatt a Gödöllői-dombság és homogenitása miatt pedig a Marosszög kistájakat választottam ki. A Gödöllői-dombságon a CLC18-as adatbázis alapján 3 nagyobb osztály (1.1.2 „Nem összefüggő településszerkezet”, 2.1.1 „Nem öntözött szántóföldek”, 3.1.1 „Lomblevelű erdők”) teszi ki a terület nagy részét,

amelyek jelentősen szétagolják a kistájat. Ennek köszönhetően a területen 349 poligon található, amelyek átlagos mérete 142 hektár. A Marosszögön egy dominás osztály (2.1.1 „*Nem öntözött szántóföldek*”) teszi ki a terület nagy részét (74,55%), amely így egy homogén tájszerkezetet alkot. Ez abból is látható, hogy a területen lévő 166 poligon átlagos mérete 352 hektár. Az osztályozáshoz Landsat-8-as és Sentinel-2-es műholdfelvételeket választottam ki a 2018-as év 3–3 időpontjából és a CLC18-as adatbázist használtam fel referenciaként. A tájmetriai mérőszámok kiszámításához szegmensekre volt szükségem, így a műholdfelvételekből készített kompozit képekből éldetektálás segítségével szegmenseket állítottam elő. A szegmentálás során több különböző minimális nagysággal (1–5–10–25 hektár) is készítettem szegmentált képeket, hogy megvizsgáljam, melyik szegmens méret az optimális az osztályozás szempontjából. Ezen szegmentált képek alapján számítottam ki 4, a tájökológiában gyakran használt indexet, mint az Átlagos Folt Méret (Mean Patch Size – MPS), Élhossz (Total Edge – TE), Átlagos Alak Index (Mean Shape Index – MSI), Fraktáldimenzió (Mean Fractal Dimension). Ezek a metrikák egy teljes tájat képesek leírni, a táj jellemzőinek tulajdonságaival és elrendezésével, a táj fragmentáltságával és a foltok alakjával. Sajátos tulajdonságaik miatt a metrikákat széles körben használják indikátorként olyan területeken, mint a biológiai sokféleség, a vízminőség, a földtakaró változása, a tájökológia és a várostervezés (Csikós és Szilassi, 2020; Kumar et al., 2018; Szabo et al., 2012). Az általam kiválasztott metrikák a tájszerkezet folytonosságát, a foltok alakjának összetettségét és a foltok külső peremének szabálytalanságait reprezentálják. A multitemporális műholdképek sávjait és a kiszámított tájmetriai indexeket együttesen használtam fel az osztályozás során. Az osztályozáshoz *python* programkörnyezetben implementált véletlen erdő osztályozót alkalmaztam. A modell tanításához véletlenszerűen kiválasztott pontokat generáltam, osztályonként 4000 db-ot, míg a többi adatot a teszteléshez használtam fel.

Az eredmények alapján a tájmetriai mérőszámok képesek az osztályozás pontosságát növelni mind a heterogén mind, a homogén tájszerkezetű mintaterület esetében. A heterogénebb szerkezettel rendelkező Gödöllői-dombságon az osztályok eloszlása egyenletesebb, így a táj szerkezete és a kategóriák eloszlása miatt kisebb összpontossági értéket eredményezett a spektrális sávokon alapuló osztályozás (66,81%). Mivel a spektrális sávokon alapuló osztályozás viszonylag alacsony pontosságot eredményezett, a tájmetriai mérőszámok itt magasabb pontosságnövekedést okoztak. Alkalmazásuk esetén a számításuk alapjául szolgáló szegmensek méretétől függően 4,61–5,85% közötti pontosságnövekedést eredményeztek (9. táblázat). Továbbá ezen a mintaterületen a mérőszámok együttes alkalmazása 2,82 és 6,82% közötti javulást okozott. A legjobb összpontossági eredményt az összes adat (spektrális sávok, szegmensek és tájmetriai indexek) együttes alkalmazása hozta

(+9,33% a spektrális sávon alapuló eredményhez képest, 73,62%). A szegmensek minimális méretének vizsgálata alapján ezen a mintaterületen a legjobb pontossági értéket a 25 hektáros minimális nagyságú szegmens réteggel érhető el.

9. táblázat Összpontosság növekedés a különböző adatkombinációkkal és minimális szegmens nagyságokkal (Gudmann et al., 2020).

Adat/Minimális szegmens méret	Marosszög				Gödöllői-dombság			
	1 ha	5 ha	10 ha	25 ha	1 ha	5 ha	10 ha	25 ha
Spektrális sávok	87,02%	87,02%	87,02%	87,02%	66,81%	66,81%	66,81%	66,81%
Spektrális sávok és szegmensek	+1,48%	+1,53%	+3,14%	+1,15%	+4,10%	+4,21%	+3,98%	+4,11%
Spektrális sávok és tájmetriai indexek	+0,59%	+1,51%	+2,65%	+2,38%	+2,82%	+3,55%	+4,96%	+6,82%
Spektrális sávok és szegmensek és MSI	+3,28%	+2,01%	+1,89%	+1,92%	+4,65%	+4,87%	+5,16%	+5,82%
Spektrális sávok és szegmensek és MPS	+3,35%	+2,00%	+3,70%	+1,71%	+4,97%	+5,06%	+5,10%	+5,65%
Spektrális sávok és szegmensek és TE	+3,39%	+1,91%	+3,80%	+1,88%	+4,87%	+5,10%	+5,12%	+5,65%
Spektrális sávok és szegmensek és MFRAC	+1,64%	+1,87%	+1,94%	+1,84%	+4,61%	+5,11%	+5,04%	+5,85%
Összes adat (spektrális sávok, szegmensek és tájmetriai indexek)	+1,82%	+2,73%	+4,37%	+2,96%	+6,28%	+6,76%	+7,88%	+9,33%

A homogénebb szerkezetű Marosszög esetében az osztályozás a spektrális sávok alapján magas pontossági értéket eredményezett (87,02%). Ez a pontossági eredmény csak részben következik a terület szerkezetéből, nagyrészt a területhasználati kategóriák kis száma és a domináns osztály területen belüli nagy arányának köszönhető. Ezen a mintaterületen a magasabb összpontossághoz képest kisebb mértékű javulást eredményezett a tájmetriai mérőszámok alkalmazása. A tájmetriai mérőszámok 1,64 és 3,8% közötti pontosság növekedést okoztak a minimális szegmens mérettől függően. Az együttes felhasználásuk esetében a javulás ennél kisebb mértékű, 0,58% és 2,38% közötti volt. A legmagasabb összpontossági eredményt itt is az összes adat (spektrális sávok, szegmensek és tájmetriai indexek) együttes alkalmazása hozta (4,37%-os növekedést, 89,65%-os összpontosságot). A szegmensek minimális méretének vizsgálata alapján ezen a mintaterületen a legjobb pontossági érték a 10 hektáros minimális nagyságú foltmérettel érhető el.

Az eredményeim alapján jelentős pontosságbeli javulás érhető el, ha az osztályozást a pixel környezetét tájmetriai mérőszámokkal leíró adatokkal bővítjük (min.: 0,52%, max.: 6,82%). Ezért a kutatásomban további, a pixel környezetét leíró adatokat vontam be és ezek hatását vizsgáltam az osztályozás pontosságára. (3. cél)

5.2.2.2. Textúra adatokból származó információk, mint kiegészítő adatok vizsgálata


A másik, általam vizsgált, a pixelek környezetét leíró adat a textúra volt. A textúrára (szerkezetre) vonatkozó adatok ugyanúgy segíthetnek az egyes osztályok pontosabb lehatárolásában, mint a tájmetriai mérőszámok. A textúra a pixel szomszédságának olyan tulajdonsága, ami kis területekre vonatkozó térbeli eltérésekre utal, és így képes növelni a felszínborítás és területhasználat osztályozás pontosságát. A textúrainformáció kinyerésére gyakran használt módszer Haralick által kifejlesztett szürke-szintű együttállási mátrix (*gray-level co-occurrence matrix* – GLCM) segítségével végzett statisztikai számítások és adattranszformáció (Haralick et al., 1973). A módszer több pixel egyesítését használja fel ahhoz, hogy információt nyújtson a pixelek közötti, valamint bármelyik pixel és a kép közötti térbeli kapcsolatáról. Az Irons és Petersen által bemutatottak szerint az adatok átlaga, varianciája (*variance*), ferdesége (*skewness*) és csúcossága (*kurtosis*) számítható ki ezzel a módszerrel (Irons és Petersen, 1981). Egyszerűségük és hatékonyságuk miatt számos korábbi tanulmányban használták már a GLCM-et és derivátumait (Feng et al., 2015; Lei et al., 2020; Mishra et al., 2019; Paneque-Gálvez et al., 2013; H. Zhou et al., 2021). A számításához két paraméter megfelelő kiválasztása szükséges: a számítási egyenlet és a számítási ablak.

A textúra kiszámításához többféle egyenlet alkalmazható, mint például a variancia, a ferdeség, a csúcosság vagy az átlagos euklideszi távolság (*Mean Euclidian Distance*) (Irons és Petersen, 1981). Anys és He (Anys és He, 1995) szerint, akik az első, másod- és harmadrendű textúrametrikák szisztematikus összehasonlítását végezték el, sorrendben a variancia, a csúcosság és az entrópia a leghasznosabb textúrametrikák. Ők az első rendű metrikákat ajánlották azok alacsony számítási költsége miatt, bár a vizsgálatuk szerint a legmagasabb pontosságot a harmadrendű metrikák biztosítják. Arra a következtetésre jutottak, hogy egynél több elsőrendű metrika együttes használata nem javítja a földhasználati osztályozás pontosságát az egyedüli használathoz képest.

A kiválasztott egyenlet kiszámításához meg kell határozni az ablakban (kernelben) lévő pixelek számát, ami páratlan számpárok szorzatával írható le, például 3×3 vagy 5×5 és a kép megfigyelésére használható. A kernel mérete határozza meg a képből kinyerhető információ mennyiségét is (Marceau et al., 1990). Ha az ablakméret túl kicsi, akkor a műholdképekből kinyert térbeli információ nem elegendő a különböző földhasználati osztályok megkülönböztetéséhez. Ha túl nagy, az információ durva lesz, és a földhasználati osztályok

átfedhetik egymást, ami térbeli hibákat okozhat és hamis információt szolgáltathat (Anys et al., 1994). A gyakorlati tapasztalatok azt mutatják, hogy a textúrametrika kombinált használata különböző kernelméretekkel növeli a pontosságot.

A textúra adatok felhasználásánál figyelembe kell vennünk a képünk térbeli felbontását és azt a tény is, hogy a mozgó ablak sok esetben csak nagy méret mellett okoz megfelelő



30. ábra A különböző textúra számítási módszerekkel és ablak méretekkel készült modellek átlagos pontosság különbsége a spektrális sávokon tanított modellekhez képest.

javulást (pl. 61×61). A vizsgálatom első lépéseként a Landsat-7-es felvételeken teszteltem le 4 különböző textúra számítási módszert (Variancia, Ferdeség, Csúcsosság, Átlagos Euklideszi távolság), 4 különböző ablakmérettel (3×3, 5×5, 11×11, 17×17) (A3. táblázat, A4. táblázat).

Az eredmények alapján a legtöbb metrika kernel mérettől függetlenül javítja a különböző modellek pontosságát (30. ábra). Az algoritmusoknál együttesen a legnagyobb javulást a két legegyszerűbben kiszámítható metrika: a variancia és az átlagos euklideszi távolság eredményezte. Azonban ezeknél az ablakok mérete jelentős hatást gyakorolt a

pontosság növekedésére. A legnagyobb javulást a 17×17-es kernel okozta mindkét metrika esetében (átlagosan +10,83% a variancia és +8,38% az átlagos euklideszi távolság esetén), illetve a különböző ablakmérettel kiszámított metrikák együttes alkalmazása (variancia +11,11%, átlagos euklideszi távolság +8,37%). Arra a megállapításra jutottam, minél bonyolultabb a metrika kiszámításához szükséges egyenlet, annál kisebb javulást okozott a pontosságban. A legbonyolultabb metrika, a csúcosság, több esetben rontotta is a pontosságot.

10. táblázat A textúra adatok felhasználásával készült eredmények átlagos F-szám változása a spektrális sávok felhasználásával készült eredményekhez képest.

CLC kategória \ Felhasznált adatok	Spektrális sávok + Variancia (összes)	Spektrális sávok + Variancia 17x17	Spektrális sávok + Átlagos Euklideszi Távolság (összes)	Spektrális sávok + Átlagos Euklideszi Távolság 17x17
1.1.1 Összefüggő településszerkezet	-6,63%	+5,74%	+3,63%	+3,42%
1.1.2 Nem összefüggő településszerkezet	+20,93%	+16,30%	+17,57%	+14,70%
1.2.1 Ipari vagy kereskedelmi területek	+13,42%	-11,26%	-2,68%	-6,27%
1.2.2 Út - és vasúthálózat és csatlakozó területek	+0,88%	+15,56%	+33,26%	+33,16%
1.2.4 Repülőterek	+17,46%	+14,58%	+10,34%	+10,15%
1.3.1 Nyersanyag kitermelés	+0,00%	+0,00%	+0,00%	+0,00%
1.3.2 Lerakóhelyek. meddőhányók	+0,00%	+0,00%	+0,00%	+0,00%
1.3.3 Építési munkahelyek	-14,68%	-4,87%	+7,22%	+2,93%
1.4.1 Városi zöldterületek	+34,89%	+28,30%	+14,35%	+7,35%
1.4.2 Sport-, szabadidő- és üdülőterületek	-10,31%	+4,49%	-9,67%	-10,43%
2.1.1 Nem öntözött szántóföldek	+34,37%	+29,70%	+24,32%	+24,14%
2.2.1 Szőlők	+23,47%	+21,21%	+25,10%	+21,70%
2.2.2 Gyümölcsösök. bogyósok	+7,03%	-1,15%	+8,91%	+6,28%
2.3.1 Rét. legelő	+25,87%	+7,39%	+19,02%	+16,75%
2.4.2 Komplex művelési szerkezet	+15,85%	+9,11%	+9,93%	+8,15%
2.4.3 Elsődlegesen mezőgazdasági területek jelentős természetes növényzettel	+19,88%	+16,22%	+14,99%	+11,26%
3.1.1 Lomblevelű erdők	+17,63%	+8,03%	+12,91%	+11,06%
3.1.2 Tülevelű erdők	+3,09%	-1,13%	+5,30%	+4,60%
3.1.3 Vegyes erdők	+16,30%	-5,92%	+7,86%	+2,03%
3.2.1 Természetes gyepek. természetközeli rétek	+25,22%	+17,56%	+17,25%	+14,18%
3.2.4 Átmeneti erdős-cserjés területek	+16,48%	+8,88%	+4,97%	+2,60%
4.1.1 Szárazföldi mocsarak	+20,47%	+9,32%	+17,12%	+17,10%
5.1.1 Folyóvizek. vízi utak	-10,69%	-16,34%	-12,22%	-12,81%
5.1.2 Állóvizek	+14,32%	+5,83%	-0,90%	+2,30%

A legmagasabb összpontossággal rendelkező eredmények átlagos F-szám változás vizsgálatával osztályszinten is jól látható a textúra adatok pontosságjavító hatása (10. táblázat). A 24 kategóriából 13-nál mindegyik textúra adat és további 5-nél a textúra adatok többsége (négyből három esetben) növelte az F-szám értékét. A variancia adatok mindegyikének felhasználásakor, az F-szám változás -14,68% és 34,89% közötti tartományban mozgott, és a


25 kategóriából 18 esetében növekedés volt a pontosságban (átlagosan +18,2%-os javulás). A variancia adatok 17-es kernel mérettel elkészített változatainak felhasználásakor az F-szám különbség hasonló tartományban mozgott (-16,34% és 29,7% között). A 25 kategóriából 16 esetén volt növekedés (ezen osztályoknál átlagosan +13,63%-os volt a javulás). Az átlagos euklideszi távolság adatok mindegyikének felhasználásakor is hasonlóan széles tartományban mozogtak az F-szám változás értékei: -12,22% és 33,26% között, ahol a 25 kategóriából 18 esetén volt növekedés a pontosságban (átlagosan +14,1%-os volt a javulás). Ezekhez az eredményekhez képest, csupán az átlagos euklideszi távolság 17-es kernel mérettel elkészített változatainak felhasználásakor változott egy kicsivel tágabb értéktartomány mellett (-12,81% és +33,16%), a 25 kategóriából 19 esetén volt növekedés a pontosságban (átlagosan +11,25%-os volt a javulás).

Az eredmények alapján a variancia textúra adatok felhasználásával értem el a legnagyobb átlagos pontosság javulást mind összpontosság, mind osztály szinten. Emiatt a továbbiakban ennek a metrikának a felhasználásával folytattam a vizsgálataimat.

A későbbi elemzésekben a 2018-as adatokon az S2 adatokból variancia textúra adatot vizsgáltam különböző, az eddigiektől részben eltérő kernel mérettel (11×11, 17×17, 23×23) kiszámítva (A4. táblázat). Az eredmények alapján minden algoritmus és tanuló terület esetén, a 2000-es adatoknál tapasztaltakhoz hasonlóan jelentős pontosság növekedést értem el a textúra adatok bevonásával (11. táblázat). A kernel méret növelésével együtt a pontosság javulása is növekszik, így a legjelentősebb összpontosság javulást a legnagyobb 23×23-as kernellel kiszámított variancia értékek adták (+10,49%). Azonban a variancia értékek együttes alkalmazása még ennél is magasabb összpontosság javulást eredményezett (+11,94%).

11. táblázat A variancia textúra adatok felhasználásával készült eredmények átlagos összpontosság és F-szám változása a Sentinel-2-es spektrális sávok felhasználásával készült eredményekhez képest.

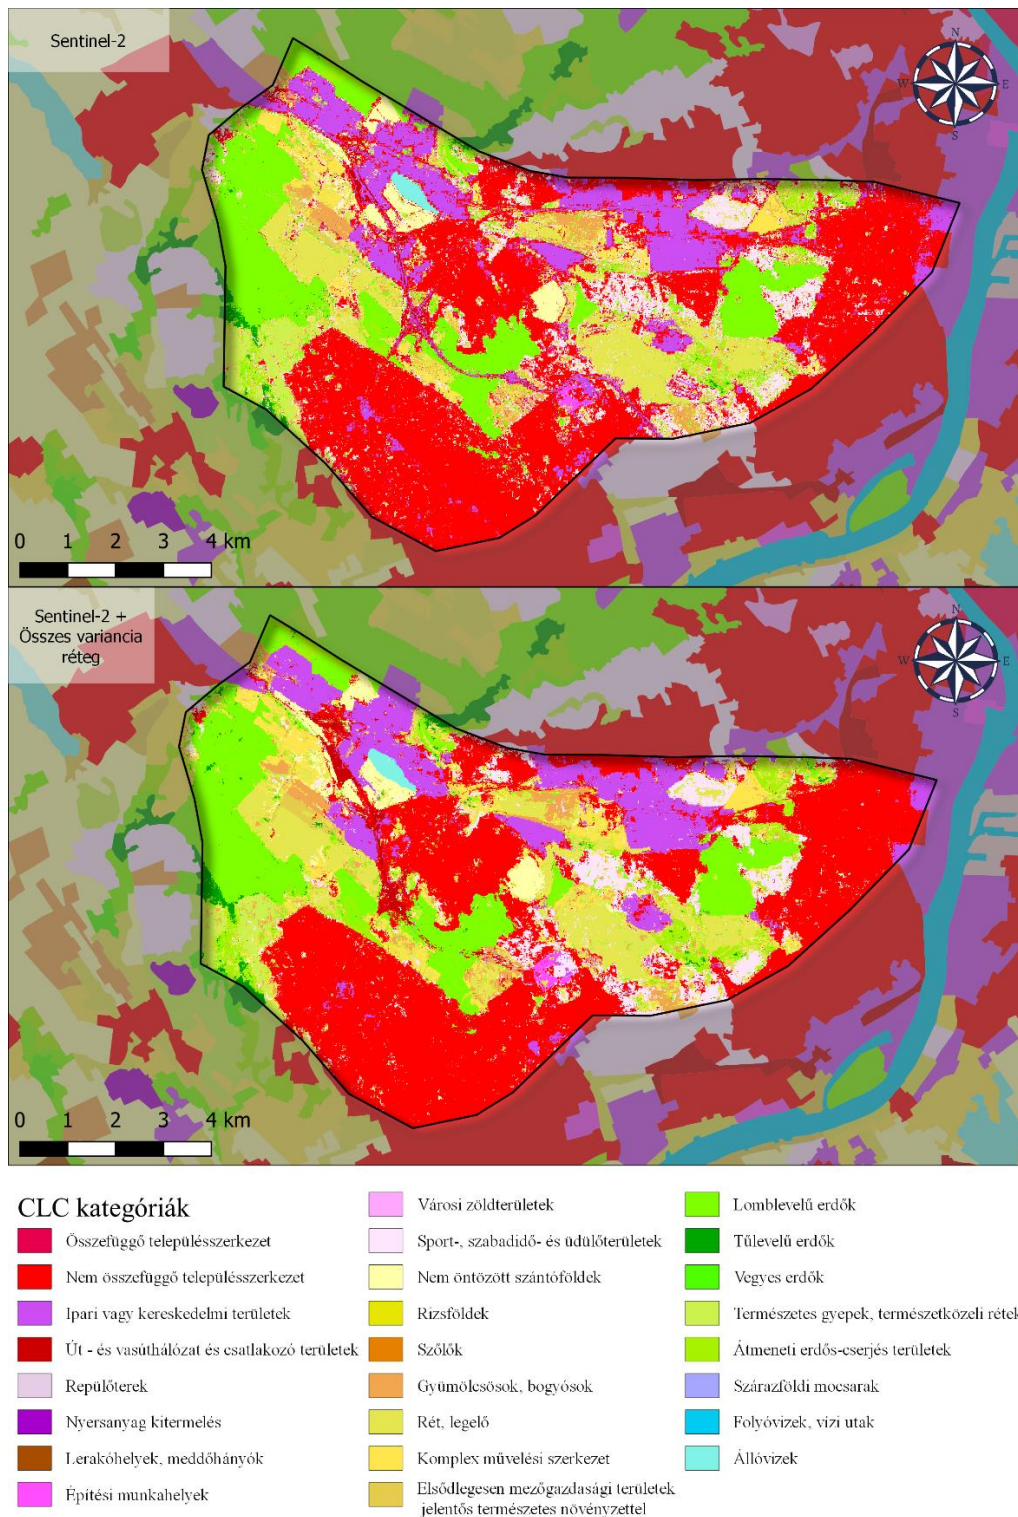
	Sentinel-2	Sentinel-2 + variancia 11x11	Sentinel-2 + variancia 17x17	Sentinel-2 + variancia 23x23	Sentinel-2 + variancia összes
Összpontosság	73,67%	+3,39%	+8,04%	+10,49%	+11,94%
F-szám					
1.1.1 Összefüggő településszerkezet	39,45%	+15,67%	+34,09%	+43,42%	+40,36%
1.1.2 Nem összefüggő településszerkezet	71,59%	+6,20%	+11,52%	+13,86%	+15,89%
1.2.1 Ipari vagy kereskedelmi területek	52,70%	+10,37%	+20,77%	+26,26%	+29,11%
1.2.2 Út - és vasúthálózat és csatlakozó területek	39,95%	+14,26%	+25,04%	+30,08%	+34,40%
1.2.4 Repülőterek	52,16%	+22,46%	+30,19%	+33,53%	+35,88%
1.3.1 Nyersanyag kitermelés	10,39%	+25,37%	+39,78%	+41,09%	+42,93%
1.3.2 Lerakóhelyek. meddőhányók	39,59%	+14,06%	+29,37%	+35,94%	+38,78%
1.3.3 Építési munkahelyek	15,49%	+34,32%	+43,86%	+47,30%	+51,63%
1.4.1 Városi zöldterületek	43,98%	+9,15%	+24,06%	+29,06%	+33,81%
1.4.2 Sport-, szabadidő- és üdülőterületek	45,97%	+11,70%	+22,37%	+26,67%	+29,86%
2.1.1 Nem öntözött szántóföldek	82,24%	+1,86%	+5,87%	+7,46%	+8,94%
2.1.3 Rizsföldek	70,73%	+10,74%	+14,76%	+17,85%	+17,84%
2.2.1 Szőlők	33,17%	+22,36%	+33,11%	+36,17%	+39,12%
2.2.2 Gyümölcsösök. bogyósok	42,71%	+16,46%	+27,47%	+31,37%	+35,24%
2.3.1 Rét. legelő	55,65%	+5,24%	+13,21%	+17,72%	+19,38%
2.4.2 Komplex művelési szerkezet	33,31%	+8,39%	+18,04%	+23,23%	+26,50%
2.4.3 Elsődlegesen mezőgazdasági területek jelentős természetes növényzettel	48,14%	+8,38%	+17,75%	+23,87%	+27,20%
3.1.1 Lomblevelű erdők	71,19%	+3,41%	+6,20%	+10,71%	+10,53%
3.1.2 Tülevelű erdők	63,60%	+4,54%	+12,93%	+15,49%	+19,69%
3.1.3 Vegyes erdők	42,70%	+8,23%	+18,01%	+20,82%	+23,48%
3.2.1 Természetes gyepek. természetközeli rétek	18,09%	+20,55%	+47,69%	+51,76%	+54,47%
3.2.4 Átmeneti erdős-cserjés területek	49,89%	+6,82%	+14,16%	+18,56%	+21,05%
4.1.1 Szárazföldi mocsarak	61,96%	+4,83%	+13,53%	+17,83%	+18,68%
5.1.1 Folyóvizek. vízi utak	82,53%	+1,16%	+4,88%	+8,46%	+7,80%
5.1.2 Állóvizek	84,30%	+2,97%	+8,41%	+9,39%	+9,23%



31. ábra A Sentinel-2-es sávok és 23×23-as kernellel elkészített variancia rétegek átlagos permutációs fontosság értékei.

A változók permutációs értékeinek vizsgálatánál jól látható, hogy milyen fontos szerepet töltenek be a modellépítés során (31. ábra). A variancia rétegek többsége közepes vagy magas fontossági értékkel rendelkezik. Bár az 5 legfontosabb réteg között csak 1 variancia szerepel, azonban a 10 legfontosabb között már 6. Ezzel szemben az 5 legkevésbé fontos réteg között nincs egy variancia sáv sem és a 10 legkevésbé fontos között is csak 2 szerepel. A S2-es sávok önálló futtatása során megfigyelt

legfontosabb sávok, mint az ultrakék, a közepes infravörös 1. és 2., valamint a vízpára itt is magas értékeket vettek fel (0,7–0,81 között). A legfontosabb sávok között is megtalálhatók a variancia rétegek (közepes infravörös 1. és 2.), de több sávnál is előfordul, hogy spektrális szinten kis mértékben voltak fontosak, variancia sávként viszont magas értéket vettek fel (kék, vörös, közeli infravörös).



32. ábra A különböző kernel méretekkel készített variancia rétegek együttes felhasználásával betanított mesterséges neurális háló modell eredménytérképe a Tétényi-fennsík mintaterületre, 2018-as évre vonatkozóan.

A felhasznált variancia adatok mindegyike az összes osztály esetén növelte az F-számot, azonban a javulás mértéke osztályonként eltérő volt. A kizárólag az S2 spektrális reflektancia adatain alapuló osztályozás során kapott legalacsonyabb F-számmal rendelkező kategóriáknál figyelhető meg (1.3.1-es „Nyersanyag kitermelés”, 1.3.3-mas „Építési munkahelyek”, 3.2.1-es „Természetes gyepek, természetközeli rétek”). Azonban még az alapvetően jól lehatárolható,

80% fölötti F-számmal rendelkező kategóriáknál is határozott növekedés volt tapasztalható. A variancia textúra adatok együttes felhasználásával, a 25 osztályból 16-nál 20%-nál többel növekedett az F-szám és a 25-ből csupán egy osztálynak volt 70% alatti F-szám értéke: a 1.3.1-es „Nyersanyag kitermelés” kategóriának. A variancia adatok együttes használatával készített térképet vizsgálva jól látható, hogy a térképen nagy, egybefüggő, az eredeti CLC réteghez nagyban hasonlító foltok jöttek létre a csak az S2-es adatokból levezett térképhez képest (32. ábra). Emellett az elszórt kis pixelcsoportok száma is jelentősen kisebb, mint a csupán S2-es adatokból osztályozott térképen. Azonban a vonalas objektumok (utak, vasút) a textúra adatok felhasználásával készült térképen sokkal kevésbé vehetők ki, mint az S2-es eredménytérképen. **Ezek alapján arra a megállapításra jutottam, hogy a variancia textúra adat kernel mérettől függetlenül hasznos információforrás az egy időpontot használó osztályozásnál, de nagyobb és különböző kernel méretek együttes alkalmazása nyújtja a legnagyobb pontosságbeli javulást az eredményekben.**


Mivel a tájmetriai mérőszámok és a textúra adatok felhasználása is egyértelműen javította az osztályozások pontosságát, ezért érdemesnek találtam, hogy ezeket az adatokat nagy területen történő osztályozásra is felhasználjam. Ennek a vizsgálatnak az eredményeit publikáltam „*Pixel and object-based land cover mapping and change detection from 1986 to 2020 for Hungary using histogram-based gradient boosting classification tree classifier*” címen a *Geographica Pannonica* folyóiratban (Gudmann és Mucsi, 2022). A vizsgálat során egész Magyarország területére készítettem el felszínborítási/területhasználati térképeket a CLC nomenklatúra alapján, Landsat műholdfelvételek alapján, 4 időpontra vonatkozóan (1986, 2003, 2015, 2020). Az elkészült térképek alapján megvizsgáltam az időpontok közti változásokat, hogy beazonosítsam a fő változási dinamikákat Magyarország területén. **A vizsgálat eredményei alapján a spektrális sávok, tájmetriai metrikák és textúra adatok felhasználásával megfelelő pontossággal voltam képes területhasználati térképeket előállítani (85,99%–87,33%) országos szinten.** Az egyes osztályok felhasználói pontossága, ami az osztályok megbízhatóságát mutatja, minden időpontban a lehetséges 27-ből 15 osztály esetében 90% fölötti volt. Az elkészült változásvizsgálat segítségével kimutattam a Magyarországon domináns változási folyamatokat, mint a városiasodást és az erdősítést. Emellett a pixelszintű eredményeknek köszönhetően részletesebb képet kaphatunk a lokális változásokról is.

A térbeli adatok felhasználásával készült modellek eredményei alapján, a variancia, a ferdeség, a kurtózis, az átlagos euklideszi távolság adatok a Landsat-7-es felvételekből különböző kernel mérettel kiszámítva, átlagosan 7,83%, 6,32%, 3,52% és 6,42%-os pontosságnövekedést okoztak. Továbbá a Sentinel-2-es felvételekből különböző

kernel mérettel kiszámított variancia adatok átlagosan 3,39% és 11,95% közötti növekedést okoztak az osztályozások összpontosságában. Így megállapítható, hogy a textúra adatok megfelelőnek bizonyultak az osztályozások pontosságának növelése szempontjából. Ezen adatok nemcsak kistáj szinten, hanem országos szinten is alkalmazhatók a megfelelő pontosság elérésében. (3. cél)

5.2.3. Temporális adatok osztályozásra gyakorolt hatásának vizsgálata

A hosszútávú változásvizsgálatok készítésekor a korábbi időpontokból általában kevés adat és adatforrás érhető el, ezért sokszor egy évből csak egy felvétel (és az abból származtatható adat) áll rendelkezésünkre. Azonban napjainkra több egymástól független adatforrás is létezik, amelyek önmagukban is nagyon fontos információforrások, köszönhetően térbeli, spektrális és időbeli felbontásuknak. Időbeli felbontásuk nagyságrendekkel jobb, mint az előző generációs megoldásoknak, így az időjárási körülmények ellenére egy adott területről sokkal több elemzésre alkalmas felvételt biztosítanak. Emiatt az egy időpontban készült felvételek és a belőlük származtatott adatokon kívül megvizsgáltam a multitemporális adatok felhasználhatóságát is.

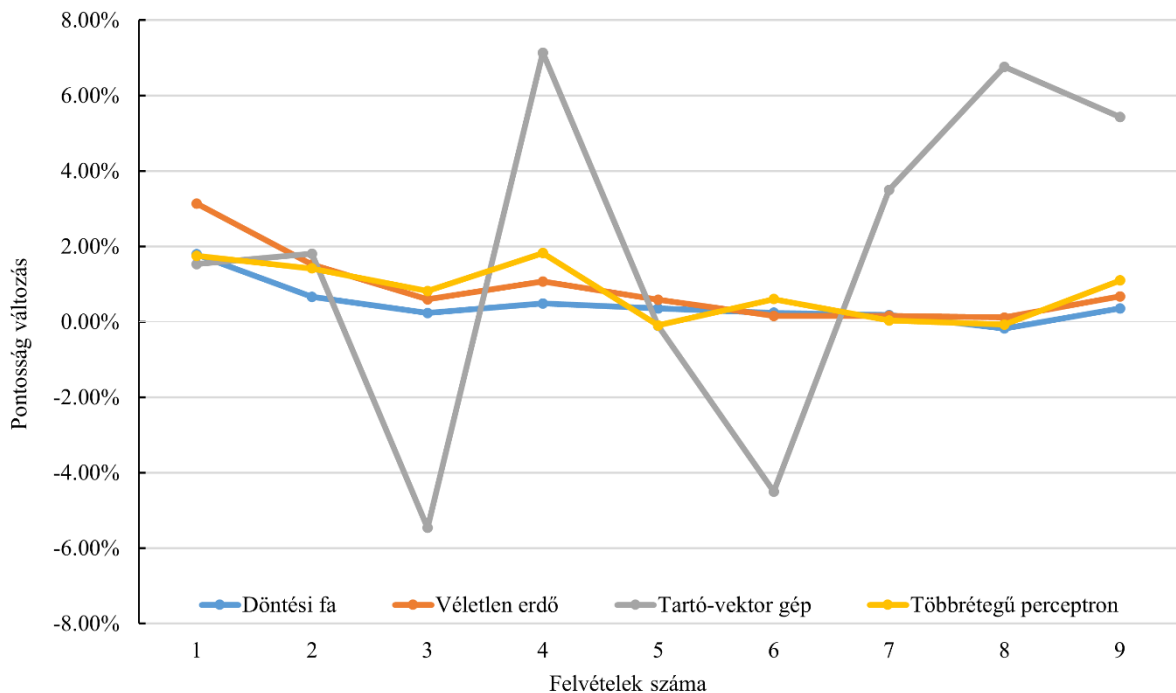


33. ábra Mezőgazdasági CLC kategóriák éven belüli medián értékei Sentinel-2 8a-as sáv értékei alapján.

Ezek több szempontból is hasznos információkat hordoznak: egyrészt a felszínborítást és területhasználatot alkotó elemek éven belüli változásából eredő spektrális különbségeket (pl. a vegetáció éven belüli fenológiai fázisaiból eredő eltérések, mezőgazdasági tevékenységből eredő változások, mint a vetés, a szántás vagy az aratás); másrészt, a spektrális sávok


intenzitásának éven belüli változékonyságából eredő különbségeket (33.ábra). Ezek az információk az eddigi kutatások szerint is hasznosnak bizonyultak a különböző osztályozási feladatokban (Griffiths et al., 2013; Henits et al., 2016; Pflugmacher et al., 2019; Phan et al., 2020).

A jelenlegi kutatásomban arra kerestem a választ, hogy ezen adatok az osztály szintű pontossági értékeket (készítői és felhasználói pontosság) milyen mértékben képesek módosítani. Továbbá megvizsgáltam, hogy hány darab különböző időpontban készült kép, milyen időközzel érheti el a legnagyobb teljesítménybeli növekedést az egyes modelleknél.



34. ábra A mintaterületeken mért összpontosság átlagának változása a felhasznált felvételek számának függvényében az eggyel kevesebb kép alapján készült modell pontosságához képest.

A kutatásomban a multitemporális adatok vizsgálatát a 2000-es adatokon kezdtem el. A kezdő időpont a CLC adatbázisok alapját nyújtó augusztusi L7-es felvételek voltak (A4. táblázat). Ezeket bővítettem egyre több új képpel, amelyek más-más időpontban készültek. Az új időpontok bevonásánál az éven belüli távolabbiaktól haladtam az egyre közelebbi időpontok felé, mivel a kezdő időponthoz közel a felvételek spektrális értékei között nagymértékű a korreláció, ezért ezek kisebb információmennyiséget hordoznak. Ebből adódik, hogy az osztályozásra gyakorolt potenciális hatásuk is alacsonyabb. A távolabbi időpontban készült felvételeket a kezdő időponthoz képest mindkét irányba bővítettem, így az augusztusi kezdő dátumot elsőnek egy tavaszi legtávolabbi időpontban, majd egy őszi legtávolabbi időpontban készült felvétellel bővítettem. A tavaszi kezdő dátumtól az őszi dátumig haladva minden képet egymás után hozzáadtam az osztályozáshoz.



35. ábra A mintaterületeken mért összpontosságok átlagának változása a felhasznált felvételek számának függvényében az egy kép alapján készült modell pontosságához képest.

Az eredmények alapján a 4-ből 3 osztályozó algoritmus (döntési fa, véletlen erdő, többrétegű perceptron) ugyanúgy reagált a multitemporális adatokból származó

többletinformációra, míg a tartó-vektor gép ettől kicsit eltérően (34. ábra, 35. ábra). A két szélső időpont bevonása minden algoritmus esetén növelte a pontosságot 1,53 és 4,66% közötti értékekkel. A legnagyobb javulást a véletlen erdő algoritmusnál okozta, ahol egy további felvétel felhasználása 3,14%-os javulást, míg a harmadik felvétel további 1,52%-os javulást eredményezett (35. ábra). A pontosság növekedése az ötödik hozzáadott felvételig tartott, azonban újabb időpontok bevonása már egyre kisebb mértékű javulást okozott. További képek felhasználása már csak kis mértékben gyakorol hatást a pontosságra, mivel az osztályozásba bevont képek közti korreláció miatt az információ kinyerése bonyolultabb, ugyanis ugyanazt az információmennyiséget nagyobb dimenziójú adathalmazból kell kivonni.


12. táblázat A 2000-es évre vonatkozóan, több időpontban készült Landsat-7-es felvételek kombinációival betanított modellek eredményeinek átlagos F-számai.

CLC kód	1 nyári felvétel	1 nyári, 1 tavaszi felvétel	1 nyári, 1 tavaszi, 1 őszi	1 nyári, 2 tavaszi, 1 őszi	1 nyári, 3 tavaszi, 1 őszi	2 nyári, 3 tavaszi, 1 őszi	3 nyári, 3 tavaszi, 1 őszi	3 nyári, 3 tavaszi, 2 őszi
111	72,99%	75,54%	77,57%	77,76%	78,83%	78,53%	78,12%	80,20%
112	13,90%	15,51%	16,80%	17,89%	17,55%	18,21%	16,93%	16,93%
121	6,24%	4,60%	5,87%	6,14%	6,21%	7,60%	7,29%	7,29%
122	8,92%	8,69%	12,75%	16,27%	11,48%	11,86%	12,20%	12,20%
124	63,87%	72,67%	73,72%	72,53%	75,17%	73,80%	72,81%	72,81%
131	22,45%	39,73%	39,56%	49,47%	49,57%	48,73%	45,97%	45,97%
132	6,51%	13,19%	15,72%	18,09%	21,21%	26,39%	20,35%	20,35%
133	20,30%	22,44%	23,70%	24,60%	24,69%	25,03%	25,47%	25,47%
141	6,74%	9,19%	9,16%	12,32%	9,62%	12,00%	10,11%	10,11%
142	13,10%	15,52%	15,48%	19,04%	18,88%	18,96%	18,66%	18,66%
211	8,73%	12,31%	13,31%	13,98%	14,05%	13,71%	14,54%	14,54%
221	6,43%	8,59%	14,09%	14,87%	18,32%	16,00%	15,15%	15,15%
222	14,49%	13,05%	14,08%	14,53%	14,98%	15,42%	15,32%	15,32%
231	5,30%	4,03%	5,43%	5,57%	6,88%	7,57%	6,15%	6,15%
242	3,14%	4,97%	5,20%	4,84%	7,07%	5,80%	6,18%	6,18%
243	3,34%	4,73%	5,07%	5,21%	5,57%	5,71%	5,73%	5,73%
311	5,93%	6,19%	9,29%	10,38%	10,79%	11,20%	9,25%	9,25%
312	4,20%	5,90%	6,89%	7,16%	7,93%	7,75%	10,59%	10,59%
313	7,78%	11,29%	12,39%	14,56%	14,91%	16,03%	12,74%	12,74%
321	3,79%	5,23%	6,01%	5,75%	6,78%	7,53%	7,41%	7,41%
324	1,01%	1,78%	2,37%	4,77%	2,77%	4,87%	4,71%	4,71%
411	4,62%	8,23%	8,40%	8,49%	9,58%	9,77%	10,28%	10,28%
512	3,95%	5,40%	3,07%	5,55%	5,56%	7,90%	8,13%	8,13%


Ugyanezt az eredményt kaptam, amikor az osztályonkénti átlagos F-szám értékeket vizsgáltam meg (12. táblázat). Az F-számok a két szélső időpont (1 tavaszi, 1 őszi) bevonására a legtöbb kategóriánál (a 25-ből 21-nél) jelentős pontosságnövekedést eredményeztek

(átlagosan 1,92%-kal). A legjelentősebb javulást az 1.3.1-es „Nyersanyag kitermelés” kategóriánál tapasztaltam. A további tavaszi időpontok bevonása az osztályozásba ugyan kisebb mértékben, mint a szélső időpontok esetében, de tovább növeli a kategóriák F-szám értékeit (átlagosan 0,92%-kal). Ugyanakkor a további nyári időpontok már a legtöbb esetben csökkenést okoznak (25-ből 16 esetben) és csak kevés alkalommal javulást. Emiatt a visszaesések miatt az átlagos F-szám változás elhanyagolható lett (-0,09%). További egy őszi időpont felhasználása csak az 1.1.1-es „Összefüggő településszerkezet” -nél okozott változást, ahol +2,07% -kal nőtt az F-szám. Ezek alapján kijelenthető, hogy az éven belül legtávolabb lévő két dátumok bevonása hozza a legnagyobb pontosságbeli növekedést az osztályozásban, míg a további dátumok sokkal kisebb javulást eredményeznek. Osztályszinten is az éven belül legtávolabb lévő dátumok okozzák a legnagyobb javulást, míg a tavaszi időpontok kisebb javulást még nyújtanak. Viszont a nyári és az őszi időpontok már nem okoznak jelentős változást a pontosságban.

A 2018-as adatokon az eddigi eredményeket figyelembe véve az S2-es adatok mellett kétféle adathalmaz hatását vizsgáltam meg (A4. táblázat, 38. ábra). Az egyik esetben egy-egy tavaszi, nyári és őszi felvételt használtam fel, míg a másikban egy tágabb időintervallumban a meglévő 3 időponthoz még három felvételt adtam hozzá, így nagyjából 2-3 havonta lett egy felvétel az évből (Jan.–Márc.–Jún.–Aug.–Okt.–Dec.). Az eredmények alapján a 2 plusz időpont bevonása átlagosan +14,82%-os összpontosságbeli növekedést okozott az egy időpontos eredményekhez képest, míg az 6 időpontos futtatás átlagosan +18,84%-ot. A legnagyobb pontosságnövekedés a mesterséges neurális modellnél volt kimutatható, ahol a 3 időpont alapján +15,81%, míg az 6 időpont alapján +22,25% volt a növekedés. Azonban az osztályszintű eredmények ennél összetettebb képet mutatnak (36. ábra), mivel a 3 időpontos eredmények esetén az összes osztály F-szám jelentősen javult, jelentős, átlagosan +30,89%-kal. A legnagyobb növekedés a 3.2.1-es „Természetes gyepek, természetközeli rétek” (+61,74%) és a 1.3.3-as „Építési munkahelyek” (+54,66%) kategóriáknál történt. A 6 időpont adatainak felhasználásával kapott eredményeknél az osztályok mindegyikénél egy kivétellel javulás történt. Azonban ezek közül csak 7 kategóriánál kaptam nagyobb F-szám értéket (főleg a mesterséges felszínnek főosztályba tartozóknál), mint a 3 időpontos futtatásnál (azaz, ahol további javulás történt) (36. ábra). A többi 17 osztálynál nem történt további pontosságnövekedés, sőt, valamilyen mértékben csökkent az adott osztályok F-szám értéke. Ezek alapján a további 3 időpont felhasználásakor figyelembe kell venni, hogy a jelentős összpontosság növekedés ellenére csak bizonyos, mesterséges felszínnek főosztályba tartozó kategóriák pontossága növekedett érdemben, a többi osztály pontossága valamilyen szinten csökkent a 3 időpontos futtatáshoz képest.



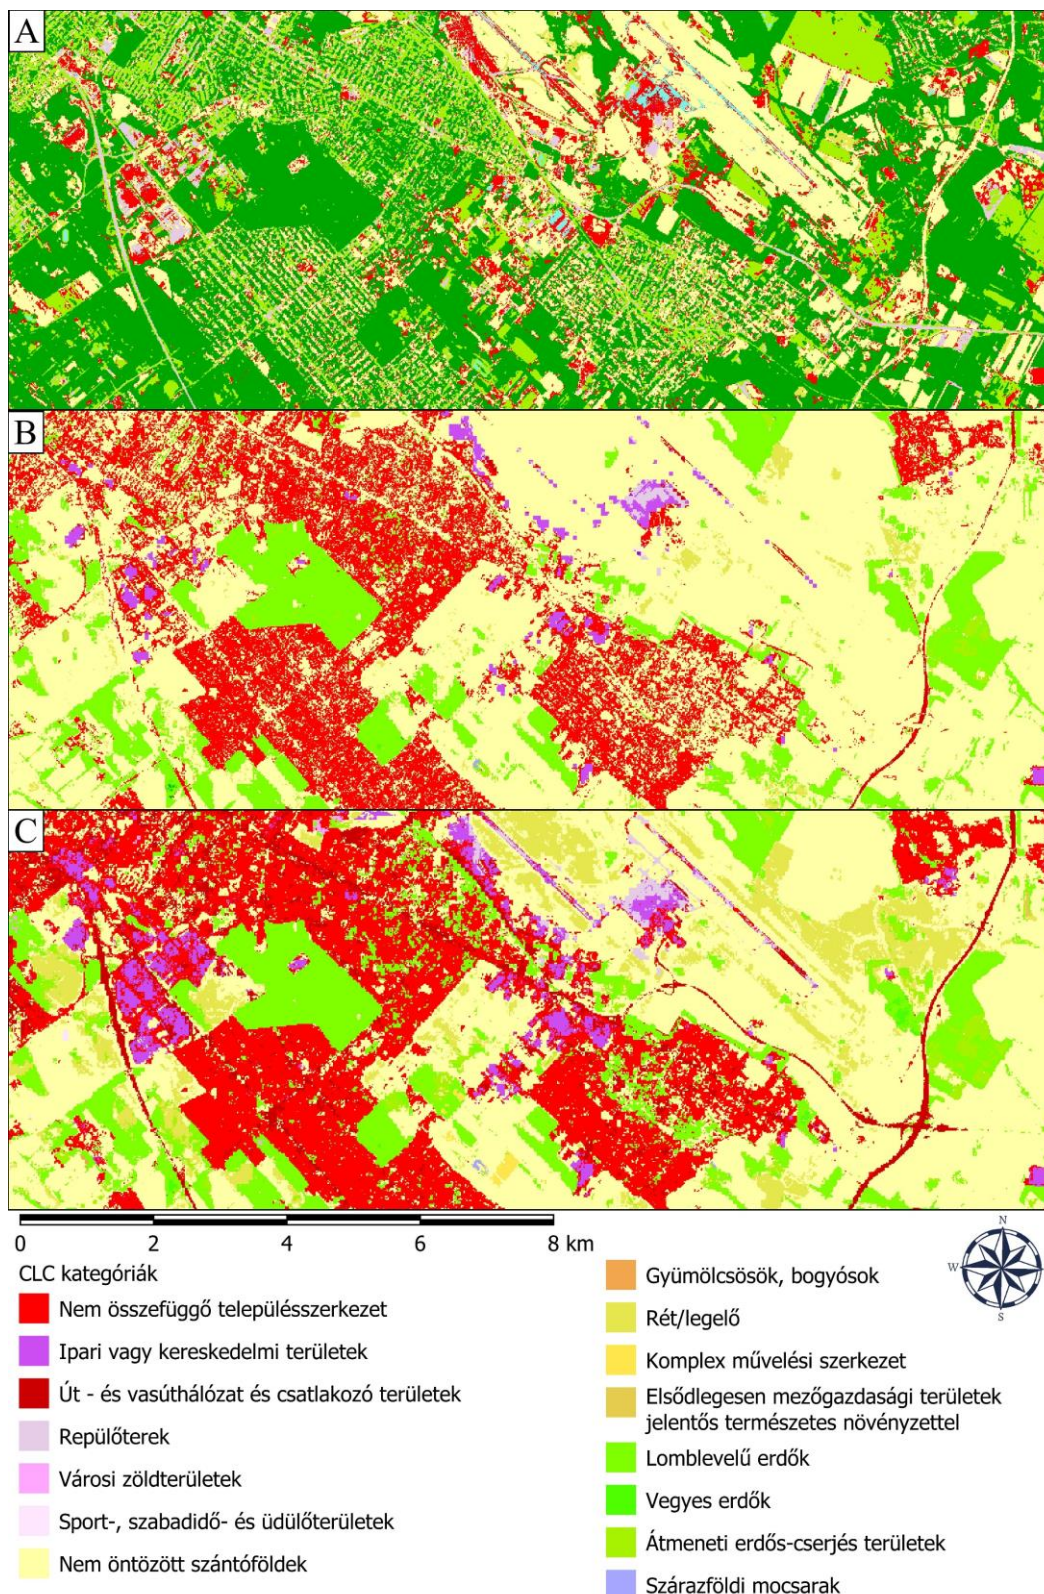
36. ábra A 2018-as, multitemporális adatok bevonásával készült modellek által kapott eredmények átlagos F-szám értékei.



37. ábra A hat, különböző időpontban készített műholdkép felhasználásával készített véletlen erdő modell átlagos permutációs fontosság értékei.

A permutációs fontosság értékek alapján a legfontosabb sávok ugyanazok, mint az egy időpont felhasználásánál: Ultrakék, Vízpara, Közepes infravörös 1. és 2. (37. ábra). A különböző időpontok közül is ezek a sávok kerültek a legfontosabb változók közé. A legfontosabb 5 változó között 2-2 januári és október változó van, míg a többi egy május-júniusi időpont. Kiemelendő, hogy a kezdő időpontnak választott augusztusi kép egyetlen egy változója sem szerepel a legfontosabb 10 változó között és a legfontosabb 20 között is csak 2 ilyen változó van. A permutációs fontosság értékek magnitúdója alapján az is látható, hogy az egy időponthoz képest, a változók egy mértékkel kisebb értékeket vesznek fel. Ebből arra

következhethetünk, hogy a változók megnövekedett száma miatt, az egyes időpontok, és a hozzájuk tartozó változók alapvetően kisebb szerepet játszanak a modellépítés során, mint az egy időpontos futtatás során.



38. ábra Véletlen erdő osztályozóval készített területhasználati térképek a Liszt Ferenc Nemzetközi Repülőtér környékéről:

A – 1 időpont alapján,

B – 3 időpont alapján,

C – 6 időpont alapján.

A Landsat-7-es temporális adatok felhasználásával készített eredmények alapján ezen információk -5,46% és +7,14% közötti pontosságváltozást okoztak (átlagosan +0,99%). A Sentinel-2-es temporális adatok felhasználásával betanított modellek 12,92% és 22,25% közötti pontosságnövekedést mutattak. Ezen eredmények alapján a temporális adatok felhasználásával jelentős javulást lehet elérni az osztályozás pontosságában. Eredményeim alapján az időpontok időablakának kiválasztásánál, a 2018-as évre a legjobb eredményt 3 hónapos időablakok esetén 6 műholdkép alapján kaptam (minden osztályozó algoritmus 90% feletti átlagos pontossági értéket adott vissza). (4. cél)

5.2.4. A multispektrális műholdfelvételektől független adatok hatásának vizsgálata az osztályozásra

Az optikai szenzorok adatai mellett felhasználhatunk olyan adatokat is, amelyek más módon írják le az adott biofizikai vagy társadalmi-gazdasági jelenségeket. Ilyenek lehetnek a mikrohullámú radar adatok, amelyek az objektumok megadott hullámhosszokon mért spektrális intenzitásértékei helyett egy impulzus visszavert energiamennyiségét és annak tulajdonságait mérik. Ezen adatok alapján lehet következtetni egy adott objektum magasságára, érdekességére, összetételére vagy alakjára. További független adat lehet, amit már sok kutatásban felhasználtak, mint kiegészítő adat, a különböző domborzat vagy felület modellekből származtatott magassági adatok (Balzter et al., 2015; Phan et al., 2020). Ezek az adatok bővebb információt adnak az adott terület domborzati viszonyairól, azonban figyelembe kell vennünk, hogy nagy mértékű geokorrelációval rendelkeznek, tehát a felhasználásukkal készített modellek nem teljesen generalizált szabályokat alkotnak, hanem megjelennek bennük az adott terület sajátosságai. A vizsgálatomban kétféle magassági adatot használtam fel mint kiegészítő adat, az SRTM-et, az L7-es spektrális sávokkal együtt a 2000-es évre vonatkozóan, illetve az ASTER-GDEM-ből kinyerhető magassági adatokat az S2-es spektrális sávokkal a 2018-as évre. Továbbá Sentinel-1 (S1) radar adatok VV és VH sávjait is vizsgáltam egy időpontból (2017.07.24–25.) az S2-es adatok kiegészítéseként a 2018-as évre.

A 2000-es adatok eredményei alapján az STRM adatok felhasználása a spektrális adatok mellett a mintaterületek többségénél minden osztályozó esetén növeli a pontosságot. A legnagyobb mértékű átlagos javulást a többrétegű perceptron osztályozónál okozta: +3,57%-kal, míg a legkisebb javulás a döntési fa esetén volt mérhető +0,49%-kal. A véletlen erdő és a tartó-vektor gép esetében a pontosság növekedése 3,11% és 2,23% volt. A lehetséges 25 kategóriából a véletlen erdő osztályozó esetén 19-nél történt javulás az F-szám értékében, míg a többrétegű perceptron esetében 13, a döntési fánál 10, a tartó-vektor gépnél 6 kategóriánál (13. táblázat).

13. táblázat A spektrális sávok és az SRTM adatok felhasználásával készült modellek eredményeinek átlagolt F-szám értékei kategóriánként.

CLC osztályok	Spektrális sávok (átlag)	Spektrális sávok + SRTM Döntési fa	Spektrális sávok + SRTM Véletlen erdő	Spektrális sávok + SRTM Tartó-vektor gép	Spektrális sávok + SRTM Többretegű perceptron
111	62,19%	3,5%	6,4%	4,0%	-3,9%
112	30,50%	0,2%	1,2%	-1,0%	0,4%
121	53,54%	0,8%	5,0%	-0,6%	5,2%
122	19,20%	-7,5%	3,6%	-1,5%	2,1%
124	34,92%	-0,3%	2,3%	2,3%	-1,0%
131	0,00%	0,0%	0,0%	0,0%	0,0%
132	0,00%	0,0%	0,0%	0,0%	0,0%
133	37,90%	-1,3%	2,2%	-2,4%	0,9%
141	5,07%	1,5%	2,6%	-2,2%	0,2%
142	32,27%	-0,5%	1,4%	-4,3%	1,0%
211	11,69%	-0,7%	1,3%	-7,8%	2,0%
221	3,67%	2,6%	2,6%	-3,7%	-1,0%
222	32,46%	0,6%	1,9%	-1,3%	1,0%
231	33,88%	1,4%	2,8%	-1,1%	2,5%
242	16,28%	-1,1%	0,9%	-1,1%	0,2%
243	4,34%	0,9%	1,0%	-2,3%	0,9%
311	7,36%	-1,3%	0,6%	0,7%	-0,2%
312	20,89%	1,6%	1,5%	-3,9%	0,5%
313	15,98%	-0,7%	-0,2%	0,6%	-0,3%
321	0,00%	0,0%	0,0%	0,0%	0,0%
324	10,50%	-1,7%	0,3%	1,4%	0,6%
411	0,00%	0,0%	0,0%	0,0%	0,0%
511	17,00%	-0,8%	1,1%	-0,5%	-0,5%
512	6,21%	3,0%	0,8%	1,5%	-0,8%

A legnagyobb javulásokat az 1.1.1-es „Összefüggő településszerkezet” és az 1.2.1-es „Ipari vagy kereskedelmi területek” kategóriák eredményezték, ahol a mesterséges létesítmények magassága teszi lehetővé a pontosabb lehatárolást. A legnagyobb F-szám csökkenést a 2.1.1-es „Nem öntözött szántóföldek” és a 1.2.2-es „Út - és vasúthálózat és csatlakozó területek” nyújtották. Azonban meg kell jegyezni, hogy sem a legnagyobb növekedést, sem a legnagyobb csökkenést mutató osztályoknál nem egyértelműek az eredmények, mivel az algoritmusok felénél eltérő, kisebb fokú különbségek voltak tapasztalhatók.

Az ASTER-GDEM adatok bevonása esetén hasonló eredményeket kaptam, mint az SRTM adatok felhasználásánál (14. táblázat). Az összpontoság az S2-es spektrális adatokon történő osztályozáshoz képest elhanyagolható mértékben változott, azonban osztályszinten szignifikáns javulást eredményezett a magassági adat felhasználása. Az előzetes várakozásoknak megfelelően nagymértékű F-szám növekedés tapasztalható az olyan

osztályoknál, amik rendelkeznek magassági tényezővel (a felületmodellekben az osztály objektumainak magassága hozzáadódik a felszín magasságához, elkülöníthetők a szomszédos alacsonyabb felszínborításoktól). Ilyen osztályok a mesterséges felszínek legtöbb kategóriája (1-es főosztály), a „szőlők” (2.2.1) és „gyümölcsös, bogyósok” (2.2.2, illetve az erdők (3.1.1, 3.1.2) és a 3.2.1-es „Természetes gyepek, természetközeli rétek” (az utóbbi kategóriánál a magassági tényező az elhelyezkedésből adódik, mivel főleg magasabb térszíneken fordulnak elő). Ezzel szemben jelentősebb F-szám csökkenést csupán pár esetben tapasztalhatunk: 2.1.3 „Rizsföldek”, 2.4.3 „Elsődleges mezőgazdasági területek jelentős természetes növényzettel” és a 3.1.3-as „Vegyes erdők” kategóriáknál. Ennek köszönhetően az F-szám változás átlagos értéke +7,29%.

A Sentinel-1-es adatok bevonása az osztályozásba nem hozott egyértelmű összpontosság javulást (14. táblázat). Azonban az ASTER-GDEM-hez hasonlóan, osztályszinten már látható különbségeket eredményezett. Az ASTER-GDEM-nél a már említett

mesterséges felszínek, szőlők, gyümölcsösök, bogyósok és erdő kategóriáknál kimutatott F-szám érték növekedés jelentkezik, azonban kisebb magnitúdóval. Emellett több osztályt is érintett az F-szám értékek csökkenése ezért az átlagos F-szám növekedés mértéke elmarad az ASTER-GDEM-nél tapasztaltaktól, csak 3,35%. Az ASTER-GDEM és az S1-es adatok

14. táblázat Az ASTER-GDEM és a Sentinel-1 adatok felhasználásával készült eredmények átlagos összpontosság és F-szám változása a Sentinel-2-es spektrális sávok felhasználásával készült eredményekhez képest.

	Sentinel-2	Sentinel-2 + ASTER-GDEM	Sentinel-2 + Sentinel-1
Összpontosság	73,67%	+0,07%	-0,26%
F-szám			
111	39,45%	+17,55%	+22,58%
112	71,59%	-0,03%	-0,57%
121	52,70%	+3,75%	+0,16%
122	39,95%	+3,46%	+2,28%
124	52,16%	+18,83%	+16,81%
131	10,39%	+44,81%	+18,77%
132	39,59%	+22,10%	+12,01%
133	15,49%	+21,75%	+19,62%
141	43,98%	-2,83%	+0,18%
142	45,97%	+3,42%	-0,15%
211	82,24%	-2,95%	-2,20%
213	70,73%	-9,23%	-0,46%
221	33,17%	+24,61%	+18,41%
222	42,71%	+6,85%	+0,95%
231	55,65%	+0,46%	-1,25%
242	33,31%	-0,15%	-1,44%
243	48,14%	-8,74%	-2,59%
311	71,19%	+0,72%	+2,59%
312	63,60%	+3,86%	+0,90%
313	42,70%	-5,64%	+0,43%
321	18,09%	+36,37%	-18,09%
324	49,89%	-2,85%	-1,07%
411	61,96%	+3,79%	-2,42%
511	82,53%	-0,41%	-2,43%
512	84,30%	+2,77%	+0,77%

permutációs fontossági értékei eltérő eredményt mutatnak, mint az összpontosság és osztályonkénti F-szám értékek. Az ASTER magassági adat, mint változó volt a legkevésbé fontos változó a modellépítés során, addig az S1 két változója közepes fontossági értékkel rendelkeztek. Az S1-es adatok esetében ugyanakkor meg kell jegyezni, hogy az előfeldolgozás során többféle zajszűrési eljárást is lehet alkalmazni, amelyekkel eltérő eredményt kaphatunk. Ezeket a módszereket ebben a kutatásban nem vizsgáltam.

A különböző független adatok (magassági, radar) felhasználása az osztályozásban eltérő eredményeket nyújtott. Míg az SRTM bevonása a Landsat-7-es adatokkal együtt összpontosság növekedést okozott, átlagosan 2,35%-ot, azonban osztályszinten csak kisebb különbségeket eredményezett. Az ASTER-GDEM és a Sentinel-1-es adatok az S2 adatokkal kombinálva nem okoztak jelentősebb összpontosságbeli változást, átlagosan +0,07%-ot és -0,26%-ot. Azonban osztályszinten a pontosság növekedett, főleg a jelentős magassági tulajdonsággal rendelkező kategóriák esetében. (5. cél)

5.3. Gépi tanuláson alapuló algoritmusok összehasonlítása a felszínborítás/területhasználat osztályozásban


A gépi tanulásban kompromisszumot kell kötni aközött, hogy az algoritmus mennyire jól illeszkedjen az adatokhoz, illetve, hogy az algoritmus mennyire lehet bonyolult. Napjainkra a felhasználóknak sokféle algoritmus sokféle verziója áll rendelkezésére a feladataik elvégzéshez. Ezeket az osztályozási algoritmusokat a múltban már többször összehasonlították, azonban a legjobb pontossággal rendelkező algoritmus kiválasztása egyértelműen nem lehetséges (Du et al., 2020; Jozdani et al., 2019; Leeuwen van et al., 2020; Shao és Lunetta, 2012), mivel a különböző osztályozások eltérő nyers adatokat és előfeldolgozási módszereket használnak. Így a betanításkor használt adatokban lévő osztályok száma és eloszlása (kiegyensúlyozott/kiegyensúlyozatlan), a hiányzó vagy hibás értékek, valamint a betanítási adatok mérete (mintanagyság és változók) meghatározzák azt az algoritmust, amely a legnagyobb pontossággal rendelkezik egy adott adatkészleten. Kutatásom során több különböző osztályozó algoritmust teszteltem, mint például a döntési fát, a tartó-vektor gépet, a véletlen erdőt, a többrétegű perceptront, a teljesen kapcsolt mély neurális hálót vagy a gradiens-növelő fát. Összehasonlításuknál az ugyanazon az adathalmazon tanított és kiértékelt eredményeket használtam fel. A kiértékelésnél az összpontosság, a modell építési idő, a tanító adat nagysága, az F-szám, a felhasználói és készítői pontosság és az átlagos valószínűségi mutatókat vizsgáltam. Az összehasonlítás alapját a spektrális sávokon kapott eredmények adják, de ezen kívül azokat az adatkombinációkat is megvizsgáltam, amelyekkel a spektrális sávoknál jobb eredményeket kaptam.

Az első osztályozási módszerben, ahol WEKA szoftverkörnyezetben meglévő algoritmusokat tudtam felhasználni, az alábbi négy, már viszonylag széles körben ismert algoritmust vettem össze: döntési fa, véletlen erdő, tartó-vektor gép, többrétegű perceptron. Ezek a kiválasztott, egyszerűbb algoritmusok közepes vagy jó eredményeket értek el különböző osztályozási forgatókönyvekben. Az összpontosság tekintetében a legmagasabb értékeket a véletlen erdő osztályozóval kaptam, amely az L7-es spektrális sávok alapján a mintaterületeken átlagosan 67,96%-os eredményt adott (legalacsonyabb 62,84% – Tétényi-fennsík, legmagasabb 81,87% – Hevesi-ártér). A második, harmadik, negyedik helyen sorrendben a többrétegű perceptron, a döntési fa, a tartó-vektor gép algoritmusok állnak, közel azonos értékekkel. A többrétegű perceptron a spektrális sávok alapján átlagosan 50,3%-os eredményt adott (legalacsonyabb 37,42% – Pesti hordalékkúp-síkság, legmagasabb 69,98% – Hevesi-ártér). A döntési fa átlagosan 49,8%-os összpontosságot ért el úgy, hogy a legalacsonyabb eredményt (39,95%) a Tétényi-fennsík, míg a legmagasabbat (69,97%) a Hevesi-ártér mintaterületen nyújtotta. A legalacsonyabb összpontosságot a tartó-vektor gép adta, amely átlagosan 47,7%-ot ért el. A legalacsonyabb értékét, 37,38%-ot a Tétényi-fennsík, míg a legmagasabb értékét 69,97%-ot a Hevesi-ártér mintaterületen adta. Az L7-es spektrális sávokhoz további információk hozzáadásakor, ezek az osztályozók a legmagasabb összpontosság értékeiket a variancia textúra adatok bevonásával érték el (osztályozónként a többi adatkombinációhoz képest). A legmagasabb összpontosságot, 81,88%-ot szintén a véletlen erdő érte az összes variancia sáv felhasználásával (minimum 78,75% - Pesti hordalékkúp-síkság, maximum 89,14% – Hevesi-ártér). Hasonlóan az összes variancia sáv bevonásával érte el a legmagasabb összpontosságot a tartó-vektor gép: átlagosan 57,49%-kal (minimum 51,91% – Tétényi-fennsík, maximum 71,07% - Hevesi-ártér). A döntési fa esetén a variancia adatok 11×11-es kernel mérettel készített értékeivel értem el a legmagasabb összpontosságot: 67,02% (minimum 51,26% – Pesti hordalékkúp-síkság, maximum 81,8% – Hevesi-ártér). A többrétegű perceptron a variancia adatok 17×17-es kernel mérettel nyújtotta a legmagasabb összpontosságot: 67,02% (minimum 36,2% – Pesti hordalékkúp-síkság, maximum 73,94% – Hevesi-ártér). Az algoritmusok eredményeinek összpontossága és a tanító adathalmaz nagysága között nincs egyértelmű kapcsolat. Több esetben a legkisebb összpontosságot a legnagyobb mintaterületen (Pesti hordalékkúp-síkság) kaptam, illetve itt minden osztályozónál átlag alatti összpontosságot mértem. Azonban az is kimutatható, hogy a második leggyakrabban alacsony összpontossági értékeket nyújtó mintaterület (Tétényi-fennsík) inkább a kisebb területűek közé tartozik, mint a nagyobbak közé (15. ábra). A két kistáj osztályszintű eloszlása nagyban hasonlít, ugyanis mindkét esetben magas a mesterséges felszínek és a mezőgazdasági területek aránya (A1. táblázat). Továbbá a Hevesi-ártér, amely esetében a legtöbbször kaptam a legmagasabb

összpontosságot, a harmadik legnagyobb területű mintaterület, a kategóriák szerinti eloszlása pedig viszonylag homogén, 1 domináns kategóriával (2.1.1. „Nem-öntözött szárazföldek”). Ezek alapján az algoritmusok teljesítményét a mintaterület nagysága csak kisebb mértékben befolyásolja, viszont a területen lévő osztályok eloszlása sokkal meghatározóbb.

A spektrális sávok alapján a véletlen erdő osztályozó adta a legmagasabb átlagos F-szám értékeket (23. ábra) a legtöbb kategória esetében (24-ből 16 esetben). A további 8 osztálynál 3 esetben a tartó-vektor gép, míg 1 esetben a többrétegű perceptron adta legmagasabb F-számot (4 esetben mindegyik osztályozónál az F-szám 0 volt). Azonban az F-szám alapján egyik kategória sem éri el a 70-es értéket, így az osztályszintű eredmények alacsonynak vagy közepesnek mondhatók. Ezért az osztályok részletesebb vizsgálatát (készítői, felhasználói pontosság, átlagos valószínűség) nem végeztem el. Az algoritmusok modellépítési idejét tekintve a leggyorsabb a döntési fa modell volt, amely a teljes adathalmaz 33%-án tanítva 35,58 másodperc futott le. Míg a második leggyorsabb a véletlen erdő modell 53,43 másodperccel, a harmadik, többrétegű perceptron 235,28 másodperccel és a leglassabb a tartó-vektor gép 1293,14 (21,55 perc) másodperccel teljesített. Az eredmények alapján a véletlen erdő osztályozó algoritmus hozta a legjobb pontossági eredményeket, amik közepes és jónak mondható tartományban mozogtak, míg a modellezési ideje gyors volt. A másik három algoritmus egymáshoz viszonyítva hasonló pontossági eredményeket adott, viszont ezek az adott feladatot rossz vagy alig közepes hatékonysággal oldották meg. Ezek alapján döntöttem úgy, hogy a második osztályozási módszernél a véletlen erdő algoritmust is implementálom.

A második osztályozási módszerben, a *python* programozási környezetben három, napjainkban igen gyakran használt algoritmust implementáltam: a már említett véletlen erdőt, a mély tanulós mesterséges neurális hálót és a gradiens-növelő fát. A pontossági értékek elemzéséhez a *maximum likelihood*, hagyományos osztályozót is alkalmaztam, aminek az eredményeit alapértékként használtam. A *python* programozási környezetnek köszönhetően az algoritmusok modellépítő paramétereit automatikusan, véletlen keresési eljárással optimalizáltam. Ezzel a módszerrel az S2 spektrális sávokon felépített modellek összpontosságait megvizsgálva megállapítható, hogy a *maximum likelihood* nem volt képes megfelelően megoldani az osztályozási problémát, mivel összpontossága minden mintaterületen 60% alatt maradt (minimum 32,91%, maximum 56,71%) (39. ábra).



39. ábra Különböző osztályozó algoritmusok teljesítménye a Sentinel-2-es spektrális sávok alapján, különböző mintaterületeken mérve.

A többi osztályozó algoritmus viszonylag hasonló pontossági eredményeket adott a különböző mintaterületeken. Mindhárom osztályozó a legnagyobb területű Pesti hordalékkúp-síkságon érte el a legalacsonyabb összpontosságot. Ezen a mintaterületen az algoritmusok között csupán 2,66%-os különbség volt mérhető. A legmagasabb pontosságot a gradiens-növelő fa érte 65,25%-kal míg a legalacsonyabbat a mesterséges neurális háló 62,59%-kal, és a véletlen erdő 64,2%-ot nyújtott. Az első osztályozási eredményekhez hasonlóan itt is a Hevesi-ártér mintaterületen adták a legmagasabb pontossági értékeket az algoritmusok, ugyanis mindhárom osztályozó összpontossága 80% felett volt. A legmagasabb értéket itt is a gradiens-növelő fa

érte el 86,67%-kal, míg a véletlen erdő nem sokkal alacsonyabb 86,2%-ot. A legalacsonyabb pontosságot (84,07%) itt is a mesterséges neurális háló adta. A többi mintaterületen 70% és 80% közötti összpontosságbeli eredményeket adtak az algoritmusok. A hat mintaterületből összesen öt esetben a gradiens-növelő fa bizonyult a legpontosabb modellnek, míg egy esetben a véletlen erdő. A többi adatkombinációt megvizsgálva a legmagasabb pontossági értékeket a monotemporális adatok esetén a variancia sávok mindegyikének felhasználásával, illetve a multitemporális felvételek együttes alkalmazásánál kaptam. A legmagasabb összpontosságot (94,5%) a véletlen erdő esetében a 3 időpontban készült Sentinel-2-es felvételek felhasználása nyújtotta a Hevesi-ártéren. Ugyanezen a mintaterületen, a 6 időpontban készült Sentinel-2-es felvételek alapján a legmagasabb összpontosságot (96,71%) a mesterséges neurális hálónál kaptam, ami egyben a legmagasabb érték is az összes eredmény közül. A gradiens-növelő fa is ugyanezen a mintaterületen érte a legmagasabb pontosságot (96,29%), az összes variancia sáv felhasználásával. Az adatkombinációnként vizsgált átlagos összpontosságok esetén is a spektrális sávoknál bemutatott eredményekhez hasonlókat kaptam (15. táblázat). Minden esetben a gradiens-növelő fa rendelkezett a legmagasabb átlagos összpontossággal, míg a véletlen erdő és a mesterséges neurális háló közel azonos eredményeket adtak. Valamint a *maximum likelihood* osztályozó semmilyen adatkombinációval sem volt képes megfelelően elvégezni az osztályozási feladatot.

15. táblázat Különböző osztályozó algoritmusok átlagos összpontossága a különböző adatkombinációk alapján.

	ML	RF	GBM	ANN
Landsat-8	41,78%	69,06%	69,38%	67,90%
Sentinel-2	42,22%	75,09%	75,71%	70,22%
Sentinel-2 + textúra 11x11 var	31,59%	76,81%	78,55%	75,83%
Sentinel-2 + textúra 17x17 var	35,60%	80,43%	85,54%	79,18%
Sentinel-2 + textúra 23x23 var	36,93%	82,61%	87,68%	82,19%
Sentinel-2 + összes textúra var	2,33%	83,09%	89,66%	84,11%
Sentinel-2 + FaPAR	41,32%	72,72%	76,91%	71,36%
Sentinel-2 + FVC	41,93%	72,13%	76,82%	71,49%
Sentinel-2 + ASTER-GDEM	45,74%	75,38%	78,96%	66,88%
Sentinel-2 + Sentinel-1	45,35%	73,36%	78,23%	68,65%
Sentinel-2 + 2 időpont	50,31%	88,02%	91,43%	86,02%
Sentinel-2 + 5 időpont	20,06%	91,74%	93,34%	92,46%


Az osztályszintű eredmények kiértékeléséhez, a Sentinel-2-es adatokon és a legmagasabb átlagos összpontossággal bíró adatkombináción kapott eredményeket vizsgáltam meg (S2 + 5 időpont) (16. táblázat). Az S2-es sávok alapján a legtöbb kategóriára közepes átlagos F-szám értékeket kaptam, mindhárom algoritmus esetén.

16. táblázat Átlagos F-szám értékek kategóriánként a Sentinel-2-es spektrális sávok alapján, az egyes osztályozó algoritmusok alapján.

CLC kód	Sentinel-2			Sentinel-2 + 5 időpont		
	RF	HGBC	ANN	RF	HGBC	ANN
111	51,51%	66,84%	0,00%	94,99%	97,15%	76,34%
112	73,92%	74,53%	66,32%	93,42%	94,43%	92,49%
121	54,01%	58,89%	45,21%	76,77%	88,08%	77,83%
122	46,46%	49,71%	23,66%	84,13%	88,91%	77,44%
124	54,40%	60,85%	41,24%	95,65%	99,11%	94,52%
131	10,06%	10,94%	10,18%	73,17%	86,38%	74,07%
132	50,42%	55,53%	12,82%	86,69%	95,16%	86,92%
133	0,00%	46,48%	0,00%	83,73%	48,05%	89,69%
141	52,81%	60,17%	18,96%	84,61%	93,65%	83,05%
142	47,38%	52,83%	37,68%	85,99%	92,67%	87,04%
211	83,47%	83,77%	79,49%	96,15%	96,30%	96,53%
213	70,15%	75,31%	66,74%	88,50%	94,55%	94,66%
221	59,05%	40,45%	0,00%	96,10%	48,97%	95,51%
222	44,37%	54,93%	28,84%	87,47%	92,37%	90,93%
231	63,65%	51,37%	51,94%	85,74%	87,71%	88,86%
242	43,21%	32,15%	24,57%	81,13%	59,72%	80,16%
243	52,40%	54,06%	37,96%	81,08%	88,39%	82,82%
311	64,42%	77,76%	71,41%	73,49%	91,36%	92,24%
312	67,33%	71,55%	51,93%	91,41%	95,42%	88,15%
313	55,14%	40,91%	32,05%	86,46%	92,75%	85,96%
321	0,00%	54,27%	0,00%	89,31%	62,04%	88,83%
324	53,63%	52,94%	43,11%	76,51%	79,39%	80,91%
411	64,68%	66,04%	55,15%	88,06%	91,57%	87,44%
511	85,29%	86,28%	76,02%	92,31%	88,09%	90,73%
512	85,74%	86,76%	80,41%	94,70%	96,05%	93,76%
ÁTLAG	53,34%	58,61%	38,23%	86,70%	85,93%	87,07%

Ezért az F-számok átlagai is alacsonyak vagy közepesek voltak: a mesterséges neurális hálónál 38,23%, a véletlen erdőnél 53,34% és a gradiens-növelő fánál 58,61%. A 25 osztályból 20 esetében a gradiens-növelő fa adta a legmagasabb átlagos F-szám értéket, de ebből az esetek felénél kevesebb mint 5%-kal volt magasabb, mint a második legmagasabb érték, tehát ezen osztályok könnyebben is lehatárolhatók voltak. A többi 5 osztálynál a véletlen erdő úgy adta a

legmagasabb átlagos F-szám értéket, hogy csak egy esetben volt kisebb a különbség 5%-nál a második legmagasabb értékhez képest. A legmagasabb F-szám értékeket a nagy részarányal bíró, vagy könnyen lehatárolható kategóriák produkálták, mint a 1.1.2-es „Nem összefüggő településszerkezet”, a 2.1.1-es „Nem öntözött szántóföldek”, a 3.1.1-es „Lomblevelű erdők”, az 5.1.1-es „Folyóvizek, vízi utak” és az 5.1.2-es „Állóvizek”. Azonban a legjobb eredményeket adó adatkombináció esetén ez az állítás már nem igaz. Bár az említett osztályok F-szám értékei itt is magasak, több osztály is legalább ilyen értékkel rendelkezik. Ilyenek voltak az 1.2.4-es „Repülőterek”, az 1.3.2-es „Lerakóhelyek, meddőhányók” és a 3.1.2-es „Tülevelű erdők” kategóriák. A magas F-szám értékeknek köszönhetően az átlagos pontosságok is jelentősen megnövekedtek és az eddig legalacsonyabb átlagértékkel bíró mesterséges neurális háló érte el a legmagasabb pontosságot (87,07%). Ugyanakkor az eddig legjobban teljesítő gradiens-növelő fa érte el a legalacsonyabb értéket 85,93%-ot, míg a véletlen erdő 86,7%-ot. Az átlagos F-szám értékek ellenére a 25 kategóriából továbbra is a gradiens-növelő fa érte el a legtöbb esetben (15) a legmagasabb értéket. A további 10 kategóriából 6-nál a mesterséges neurális háló, míg 4 esetben a véletlen erdő adta a legjobb eredményt.

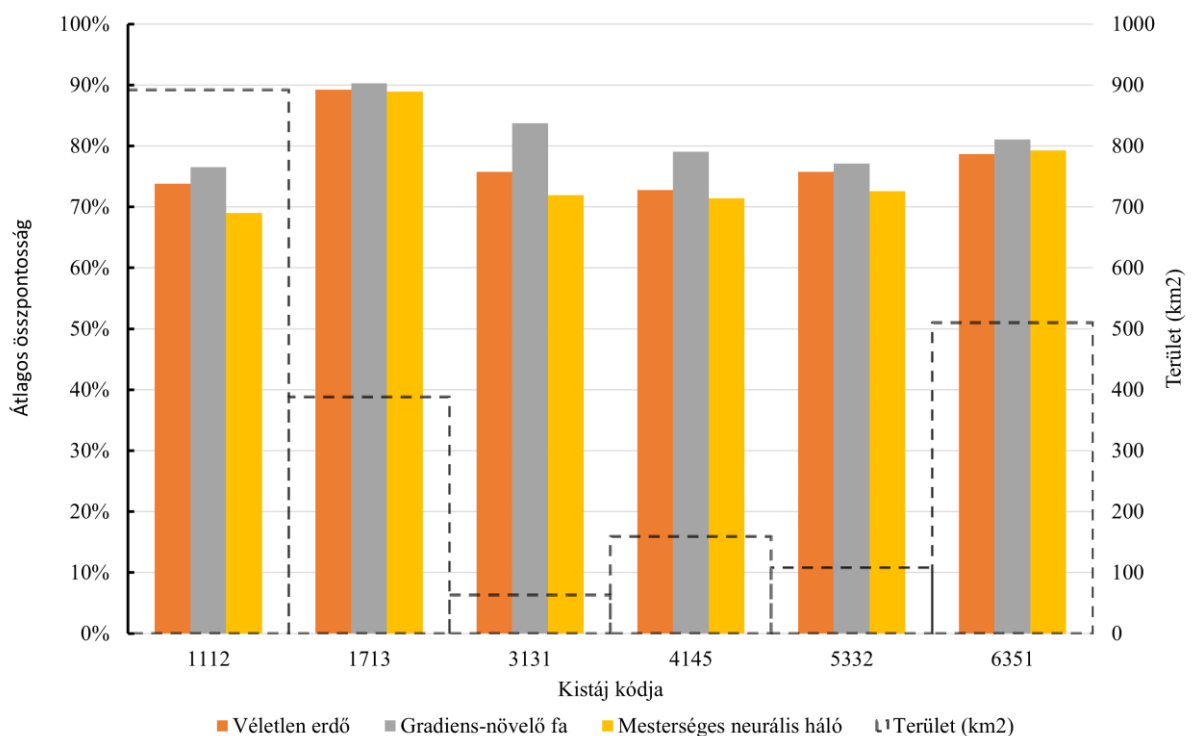


40. ábra A Sentinel-2-es spektrális adatokon betanított egyes modellek által adott átlagos valószínűségi értékek kategóriánként.

Az F-számtól részben eltérő eredményeket láthatunk az egyes modellek által osztályonként adott átlagos valószínűségi értékek alapján (40. ábra). Ezek az értékek azt mutatják meg, hogy az egyes modellek adott osztályba milyen átlagos valószínűségi érték mellett sorolták be a pixeleket (mekkora a valószínűsége a modell szerint, hogy az adott pixel a becsült osztályba tartozik). Ezek alapján további következtetéseket vontam le arról, hogy milyen pontosan tudott az adott algoritmus egy kategóriát lehatárolni. Míg az F-számhoz hasonlóan a legmagasabb átlagos valószínűségi értékkel a gradiens-növelő fa rendelkezik (64,84%), addig az eddigiektől eltérően a mesterséges neurális háló adja a második legmagasabb (58,66%) és a véletlen erdő a legalacsonyabb átlagos valószínűségi értéket (49,57%). Jól látható, hogy a legtöbb osztálynál a gradiens-növelő fa nyújtja a legnagyobb valószínűségű becsléseket (25-ből 21 esetben). A többi 4 esetben a mesterséges neurális háló adja a magasabb átlagos valószínűségű becsléseket. Viszont a véletlen erdő ezen a mutató alapján rosszul teljesít, ugyanis a legtöbb kategória esetén ez az osztályozó adja a legkisebb valószínűségű becsléseket. Az F-számtól eltérően, ennél a mutatónál a területi részarány kisebb hangsúlyt kap, míg a változók által adott térben történő szeparabilitás és az algoritmus hatékonysága nagyobb. Ezt jól mutatja, hogy az olyan alapvetően felszínborítási osztályok, mint az 5.1.1-es „Folyóvizek, vízi utak” és az 5.1.2-es „Állóvizek” a gradiens-növelő fa és a mesterséges neurális háló esetében is 85% feletti átlagos valószínűséggel lehatárolhatók. A már említett nagy területi részarányal rendelkező osztályok közepes (60 és 80% közötti) átlagos valószínűséggel rendelkeznek. **Eredményeim alapján a gradiens-növelő fával értem el a legjobb osztályozási eredményt az 5 időpontban készített adatok felhasználásával, átlagosan 93,34%-os összpontosságot. Emellett a véletlen erdő és a mesterséges neurális háló is ugyanezen adatok felhasználásával eredményezték a legmagasabb átlagos pontosságot, 91,74% és 92,46%. (6. cél)**

Az algoritmusok teljesítményének értékeléséhez a már említett pontossági értékek mellett megvizsgáltam az algoritmusok modellezési folyamatát (modellépítő és architektúrális paraméterek, paraméterek súlya, modellezési idők). A paraméterbecslés eredményeként a véletlen erdő osztályozónál többféle optimális paraméterkombinációt is kaptam. Azonban az eredmények alapján arra a következtetésre jutottam, hogy a paraméterek hatása alacsony, a legjobb és a legrosszabb paraméterkombinációk pontossága között is csupán 1–5%-os eltérés volt tapasztalható (tanító adattól és mintaterülettől függően). A gradiens-növelő fa esetén a modellépítő paraméterek hatása egy nagyságrenddel nagyobb volt, a legjobb és a legrosszabb paraméterek között 4–20% közötti eltérések is lehettek, adathalmaztól és mintaterülettől függően. A véletlen erdőtől eltérően a gradiens-növelő fa paramétereinél kisebb fluktuáció volt az ideális paraméterek között, a leggyakoribb kombinációnál a tanítási ráta 0,01, az iterációk

maximális száma 3000, a maximális mélység 8 volt. A mesterséges neurális hálónál volt a legnagyobb a hatása a paramétereknek, mivel itt nemcsak modellépítő, hanem architektúrális paramétereket is optimalizálni kell. Emiatt a legjobb és legrosszabb paraméterek között 20–40% közötti eltérés is tapasztalható volt (tanító adattól és mintaterülettől függően). A paraméterek számosságának ellenére, meglepő módon az algoritmusnál is viszonylag alacsony fluktuáció mutatkozott az ideális paraméterkombinációk között, így meghatározhattam a leggyakrabban alkalmazott paramétereket. A rétegek száma 5, a neuronok száma 512, az aktivációs függvény ReLU, a tanulási ráta 0,00001, az epochok száma 500, a batch méret 64 lett. A spektrális sávok felhasználásával a különböző mintaterületeken mért modellépítési idők alapján a leggyorsabbnak a gradiens-növelő fa algoritmus bizonyult, átlagosan 6381 másodperc alatt épült fel (minimum 3657 másodperc, maximum 15923 másodperc, ~4,42óra), míg a másodiknak a véletlen erdő átlagosan valamivel több mint kétszeres idővel: 14581 másodperc ~4,05 óra (minimum 745 másodperc, maximum 40306 másodperc ~11,19 óra). A leglassabban a mesterséges neurális háló modell épült fel, átlagosan 79578 másodperc ~22,1 óra (min.: 4171 másodperc, max.: 123978 másodperc ~34,43 óra). A modellépítési időt és a paraméterek hatását figyelembe véve, a mesterséges neurális hálót a legnehezebb, míg a gradiens-növelő fát közepesen nehéz és a véletlen erdőt a legkönnyebb optimalizálni. **Az eredményeim alapján közepes súlyú modellépítő paraméterekkel, a legrövidebb modellépítési (átlagosan 6381 másodperc) és paraméterbecslési idővel és legmagasabb átlagos pontossággal rendelkező, így egyben legjobb teljesítményű algoritmus a gradiens-növelő fa. (7. cél)**



41. ábra Az osztályozók átlagos pontossági értékeik mintaterületenként.

A három osztályozó algoritmus skálázhatóságának vizsgálatához az egyes munkaterületeken mért, 2018-as adatok alapján készített modellek átlagos pontossági értékeit vizsgáltam meg (41. ábra). Az eredmények hasonlóak a 2000-es adatok alapján levont következtetésekhez. A legkisebb átlagos pontossági értékeket mindhárom algoritmus esetén a legnagyobb területű Pesti hordalékkúp-síkságon mértem (véletlen erdő 73,82%, gradiens-növelő fa 76,50%, mesterséges neurális háló 68,99%). A legmagasabb átlagos pontosságot mindhárom algoritmus esetén a harmadik legnagyobb területű Hevesi-ártéren kaptam (véletlen erdő 89,23%, gradiens-növelő fa 90,27%, mesterséges neurális háló 88,90%). A többi négy mintaterületen közel azonos pontossági értékeket kaptam. Ezen eredményeim alapján az algoritmusok összpontossága és a tanító adathalmaz nagysága között nincs egyértelmű kapcsolat. Az algoritmusok magas pontossági értékeket adtak a második és harmadik legmagasabb területű Gödöllői-dombság és Hevesi-ártér kistájon. A kis területű mintaterületeken mértem az alacsonyabb pontosságokat, főleg a mesterséges neurális háló esetén. **A 2000-es és 2018-as adatok felhasználásával készített modellek mintaterületeken mért pontosságai alapján az algoritmusok mindegyike jól skálázható nagyobb területekre, de a kisebb mintaterületeken alacsony pontosságot kaptam. (8. cél)**

Az eredmények alapján a három vizsgált algoritmus mindegyike képes megoldani az adott osztályozási feladatot, szemben a hagyományos osztályozási eljárással. Megállapítottam, hogy a véletlen erdő igen felhasználóbarát, mivel egy gyorsan felépülő modell és könnyen optimalizálhatók a modellépítő paraméterei. Ez az osztályozó a spektrális sávok alapján közepes hatékonysággal képes az adott osztályozási feladatot megoldani úgy, hogy a modell által adott becslések a legalacsonyabb átlagos valószínűséggel rendelkeznek. Továbbá bemutattam, hogy a különböző adatkombinációk felhasználásával jelentősen növelhető a pontossága is, de kisebb mértékben, mint a másik két algoritmusnál. A gradiens-növelő fa modellépítési ideje kétszerese a véletlen erdőnek, de a paramétereinek optimalizálása ugyanúgy egyszerűnek tekinthető. Az algoritmus a spektrális sávok alapján közepes hatékonysággal képes az osztályozási feladatot megoldani és a modell által adott becslések is átlagos valószínűséggel rendelkeznek. Azonban a különböző adatkombinációkkal jelentősen növelhető a pontossága. Továbbá az is kiemelendő, hogy a három vizsgált osztályozó közül ez az eljárás adja a legmagasabb átlagos összpontossági értékeket. Emellett osztály szinten is ez az algoritmus adja a legmagasabb F-szám értékeket a különböző adathalmazokon. A mesterséges neurális háló szignifikánsan hosszabb idő alatt felépülő modell, ezért az optimalizálási folyamata is sokkal tovább tart. Ugyanakkor az architektúrális és modellépítő paraméterek számossága miatt ennél az algoritmusnál a legfontosabb a paraméterek optimalizálása. A spektrális sávok alapján ez adta a legalacsonyabb átlagos összpontosságot, de a modell által adott becslések valószínűségei nem maradtak el jelentősen ettől. További adatok bevonása a legjelentősebb pontosság növekedést okozta, ami mind összpontosságban mind osztályszinten megmutatkozott.

Ezen eredmények alapján a CLC nomenklátúra szerint történő felszínborítási/területhasználati térkép előállítására, az általam vizsgált módszerek közül a legalkalmasabb algoritmus a gradiens-növelő fa.

6. Összefoglalás és értékelés

A távérzékelés egyik alapvető és legrégebbi feladata a felszínborítás és területhasználat térképezése, mivel a Föld ezen két aspektusa kulcsfontosságú információforrás a földrajzi, társadalmi, és gazdasági folyamatok megértésében. Az egyre nagyobb emberi szükségletek miatt a felszínborítást és területhasználatot befolyásoló tényezők változása felgyorsult, ezáltal felgyorsítva azok változását is. Ezért a megbízható, naprakész térképek és azokból kinyerhető statisztikák előállítása és megléte kulcsfontosságú a szakpolitika kialakítása és tervezése szempontjából. A Föld ezen aspektusainak térképezése definícióikból eredően számos technikai és módszertani kihívást hordoz magában. Azonban a műholdas távérzékelte adatok legújabb generációjának köszönhetően nagy mennyiségű, egyre jobb térbeli, spektrális, időbeli felbontással rendelkező adat érhető el a szakértők számára. Emellett az utóbbi évtizedben a mesterséges intelligencia tudományához tartozó gépi tanulás (*machine learning*) és mély tanulás (*deep learning*) osztályozó módszerek fejlődésével minden eddiginél szélesebb eszköztár áll rendelkezésre a feladat megoldására.

Dolgozatomban a CORINE Land Cover nomenklatúrája alapján állítottam elő felszínborítási/területhasználati térképeket különböző adatok és osztályozó algoritmusok alapján a 2000-es és 2018-as évre vonatkozóan. A kutatásom során a különböző régebbi és újabb műholdfelvételek (Landsat-7, Landsat-8, Sentinel-1, Sentinel-2), és a belőlük levezethető metrikák, illetve további független források (SRTM, ASTER-GDEM) által nyújtott adatok alapján vizsgáltam meg, hogyan érhetjük el a legmagasabb pontosságot bizonyos körülmények (különböző osztályozó algoritmusok, mintaterületek, adatkombinációk) között.

A kutatásom során sikerrel alakítottam ki egy olyan osztályozási módszertant, ami véletlenszerűen kiválasztott, viszonylag kis mennyiségű tanító adat alapján képes megfelelően elvégezni az osztályozási feladatot. Az osztályozások elvégzéséhez szoftveres (WEKA) és programozási (*python*) környezetben is sikerrel alakítottam ki elő- és utódolgozási *workflow*-t, amivel a térinformatikai adatokat nyers adattá, majd az osztályozások végén újra térinformatikai adattá tudtam alakítani. A WEKA szoftveres környezetben sikerrel tudtam négy osztályozó algoritmust felhasználni az osztályozások elvégzésére: a döntési fát, a véletlen erdőt, a tartó-vektor gépet és a többrétegű perceptront. Mivel a legújabb algoritmusok közül a szoftverben több nem állt rendelkezésre, így ezeket *python* programozási környezetbe kellett implementálnom. Az osztályozás elvégzéséhez sikerrel implementáltam három osztályozó algoritmust (véletlen erdő, gradiens-növelő fa, mesterséges neurális háló) *python* programozási környezetbe, aminek köszönhetően az osztályozás folyamatát is automatizálhattam (adattisztítás, tanító-teszt adat generálás, paraméterbecslés, modellezés, becslés, eredmények átalakítása), illetve kiszámíthattam különböző egyéb mutatószámokat, mint a permutációs fontosság értéket, vagy a pixelek legmagasabb valószínűség értékét.

(1) A módszertan kidolgozása után a nyári időpontban készült felvételek spektrális sávjainak kapcsolatát vizsgáltam a CLC nomenklatúra 3. hierarchia szintjén lévő kategóriákkal, az egyes osztályok szeperabilitás értéke, illetve az osztályozások eredménye alapján. A Jeffries-Matusita szeperabilitás értékekből azt állapítottam meg a Landsat-7-es műholdkép spektrális sávjai által (amelyek 30 vagy 60 méteres térbeli felbontással rendelkeznek) a CLC kategóriák elválaszthatósága igen alacsony, és még a spektrális sávok együttes alkalmazása mellett se válnak az egyes kategóriák jól elhatárolhatóvá. Ezt támasztották alá az osztályozások eredményei is, amelyeknél a 6 mintaterület közül csak 5 esetben adtak az osztályozó algoritmusok 60% alatti összpontosságot és 1 esetben 70% fölötti eredményt. Ezzel szemben a Sentinel-2-es felvételek spektrális sávjai alapján (amelyek 10, 20 vagy 60 méteres térbeli felbontással rendelkeznek) az egyes kategóriák jól elválaszthatók egymástól. Azonban az osztályozási eredmények ezt csak részben igazolták, mivel az egyes osztályozó algoritmusok csak közepes pontosságot (átlagosan 73,82%-os összpontosságot) voltak képesek elérni ezekkel a sávokkal. A temporális adatok osztályozásban felhasznált eredményeinek vizsgálatából azonban kiderült, hogy több időpontban készült multispektrális felvételek alapján az osztályozások kiváló összpontossággal végezhetőek el. Ezek alapján a spektrális sávok képesek megfelelően jellemezni az adott felszínborítási/területhasználati kategóriákat. Ezért kijelenthető, hogy a spektrális sávok és a CLC 3. hierarchia szintjén lévő, főleg területhasználati kategóriák között kimutatható kapcsolat van, de az osztályozások nagy pontosságú elvégéséhez több időpontban készült kép információi szükségesek.

(2) Mivel a spektrális sávok önmagukban nem elegendőek az osztályozási feladat megoldásához, ezért különböző derivátumokat használtam, mint további bemenő adat az osztályozások pontosságának növeléséhez. Ilyen derivátumok voltak a spektrális indexek, mint az NDVI, SAVI, MSAVI, EVI, NDMI, FaPAR, FVC. Az osztályozás eredményei alapján a hagyományos spektrális indexek (az NDVI, SAVI, MSAVI, EVI, NDMI), amelyek csak a spektrális sávok kombinációiból számíthatóak ki, nem növelik az osztályozások pontosságát. Azonban a nem hagyományos derivátumok (FaPAR, FVC), amelyek komplex számítások és további adatok ismeretében számíthatók ki (például sugárzási transzfer modell által), osztály szinten képesek egyes kategóriák pontosságát növelni. A spektrális indexek mellett a spektrális sávokból kiszámítható adattranszformációkat is teszteltem kiegészítő adatként. A kutatásomban a Tasseled Cap és PCA adattranszformációkat használtam fel. A hagyományos spektrális indexekhez hasonlóan, ezek se javították az osztályozások pontosságát általánosságban, azonban az SVM osztályozónál a PCA sávok képesek voltak pontosságnövekedést okozni (+4,78%).

(3) A spektrális sávokból levezethető újabb adatok mellett, megvizsgáltam az egyes pixelek környezetéből kinyerhető információk hatását is az egyes osztályozó algoritmusoknál. Ilyen információk voltak a tájmetriai indexek, mint az átlagos folt méret, élhossz, átlagos alak index, fraktáldimenzió vagy a kernel számításokból kinyerhető variancia, a ferdeség, a kurtózis vagy az átlagos euklideszi távolság. Az eredményeimmel bizonyítottam, hogy mind a tájmetriai indexek, mind a textúra adatok fontos információforrások, amelyek képesek általánosan növelni az osztályozások pontosságát osztályszinten és összességében is. Továbbá ezeknek a kombinációi további pontosságnövekedést okoznak az osztályozásokban. Emellett ezek lényegesen eltérő méretű területeken egyaránt megfelelő pontossággal alkalmazhatók.

(4) Az egyre jobb időbeli felbontásnak köszönhetően egyre több lehetőségünk adódik temporális adatokat (egy műhold más időpontban készült képeit) bevonni az osztályozásba. A kutatásomban a 2000-es évre Landsat-7-es és a 2018-as évre vonatkozóan Sentinel-2-es felvételek több időpontban készült képeiből kialakított adatkombinációkat vizsgáltam meg. Az eredményeimmel igazoltam, hogy a temporális adatok jelentősen képesek növelni minden osztály pontosságát és az összpontosságot is. A legjobb eredmény elérése érdekében az egyes felvételek közötti időablakot lehetőség szerint tágan kell tartani, hogy az egyes időpontok közötti korreláció minél kisebb legyen, és ezzel az információtartalmuk minél nagyobb. Ezek alapján a 2018-as évre a legjobb eredményt 3 hónapos időablakok esetén 6 műholdkép alapján kaptam, minden osztályozó algoritmus 90% feletti átlagos pontossági értéket adott vissza.

(5) Az egy időpontból származó multispektrális műholdképeinket bizonyos esetekben nem szükséges különböző derivátumokkal vagy temporális adatokkal kiegészítenünk, ha van olyan elsődleges adatforrásunk, ami képes elegendő plusz információt szolgáltatni az osztályozás megfelelő elvégzéséhez. Kutatásomban az SRTM, ASTER-GDEM magassági adatokat és a Sentinel-1 radar adatokat sikeresen kombináltam a multispektrális sávokkal és a hatásukat mutattam be az osztályozás eredményeire. Az SRTM magassági adatok a Landsat-7-es adatokkal kombinálva kis mértékben növelték az egyes osztályozások eredményét (átlagosan 2,35%-kal), míg az ASTER-GDEM adatok a Sentinel-2-es adatokkal kombinálva főleg osztályszinten okoztak kisebb mértékű javulást. A Sentinel-1 és Sentinel-2-es képek kombinálása nem okozott általános javulást az osztályozásban, de osztály szinten több esetben pontosságnövekedést eredményezett. Osztályszintű javulást mindhárom adatkombináció esetében a magassági tulajdonsággal rendelkező kategóriák (mesterséges felszínek, erdők, gyümölcsösök, bogyósok) esetében mutattam ki.

(6-8) A bemenő adatok vizsgálatán túl, kutatásomban külön összevettem a legújabb osztályozási algoritmusokat, teljesítményük alapján. Az összevetés során az egyes algoritmusok alkalmazhatóságát, pontosságát és skálázhatóságát értékeltem a felszínborítás és

területhasználat térképezésben. A három alkalmazott algoritmus (véletlen erdő, gradiens-növelő fa, mesterséges neurális háló) közül a legkönnyebben alkalmazható eljárás a véletlen erdő, amely a három eljárás közül a leggyorsabban felépülő modell. Az alacsony számú modellépítő paraméterei csak kis hatással vannak a modell összpontosságára, így kis felhasználói tudás mellett is jó eredményt képes adni. Ez a modell a kis és nagy mintaterületeken is hasonló idő alatt épül fel, jól skálázható különböző nagyságú adathalmazok között, miközben pontosságából nem veszít. Azonban az átlagos pontossága a többi osztályozóhoz képest közepes csak közepesnek mondható, a különböző adathalmazokon 69,06% és 91,74% között mozgott. A gradiens-növelő fa (hisztogram alapú gradiens-növelő döntési fa) a véletlen erdőhöz hasonlóan könnyen alkalmazható eljárás, kevés modellépítő paraméterrel rendelkezik, bár ezen paraméterek hatása jelentősebb, mint a véletlen erdőnél. Modellépítési ideje kb. a duplája a véletlen erdőjének, de így is igen rövidnek tekinthető. A modell a hisztogram alapnak köszönhetően jól skálázható, kis és nagy területen is megfelelő eredményt képes adni. Bár az egy időpontban készült felvétel alapján a véletlen erdőhöz közeli pontosságot adott, a különböző adatkombinációk jelentősen növelték pontosságát, így ez az algoritmus adta a legmagasabb átlagos pontossági értékeket (69,38% és 93,34% között). A mesterséges neurális háló a legnehezebben alkalmazható algoritmus a három vizsgált osztályozó közül, mivel nemcsak modellépítő paramétereit, hanem architektúráis paramétereit is optimalizálni kell. Ezen paraméterek optimalizálása igen bonyolult feladat, mivel egyrészt időigényes egy-egy modell felépítése, másrészt az egyes paramétereknek igen nagy hatása van a modell teljesítményére. A modell nehezen skálázható, modellépítési ideje exponenciálisan nő a mintaterület (és így a tanító adat) nagyságával. Pontossági értékeit tekintve az algoritmus a legalacsonyabb pontossági értékeket adat több adatkombinációt tekintve, de a legjobban reagált a további adatok bevonására, mint a textúra és a temporális adatok alkalmazására. Az átlagos összpontossági értékei 66,88% és 92,46% között mozogtak. Azonban a kutatásomban összeségében az osztályozó algoritmus érte el a legmagasabb pontossági értéket a három osztályozó közül (Hevesi ártér, Sentinel-2 6 időpontban készült felvétele alapján: 96,71%). A kutatásom alapján a véletlen erdő és a gradiens-növelő fa alkalmasak általános célú felhasználásra, akár monitoring rendszerekben is, mivel könnyen alkalmazhatóak különböző nagyságú és minőségű adathalmazokon, illetve rövid idő alatt képesek az osztályozást megfelelő pontossággal elvégezni. A mesterséges neurális háló speciális osztályozási feladatok elvégzésénél alkalmazható, mivel igen nagy pontosságú eredményeket tud adni, azonban teljesítménye erősen függ a felhasználó tudásától és az adathalmaz tulajdonságaitól. Eredményeim alapján a gradiens-növelő fa algoritmus bizonyult a legalkalmasabbnak a CLC

3. hierarchia szintjén lévő felszínborítási/területhasználati kategóriák osztályozására, közepes felbontású távérékelt adatok alapján.

Összeségében megállapítható, hogy a CLC 3. hierarchia szintjén lévő főleg területhasználati kategóriák nagy pontosságú lehatárolása a temporális adatok felhasználásával adja a legpontosabb eredményt. Azonban ezen felvételek hiányában a közepes felbontású távérékelt adatból kinyert térbeli adatok a spektrális sávokkal kombinálva is megfelelő alapot biztosítanak a legújabb osztályozási algoritmusok számára. Ezen osztályozások nagy pontosságú elvégzéséhez mindegyik algoritmus alkalmas volt, de a hisztogram alapú gradiens-növelő döntési fa bizonyult a legpontosabbnak.

7. Irodalomjegyzék

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., ... Zheng, X. (2015). *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*.
- Abrams, M., Bailey, B., Tsu, H., Hato, M. (2010). The ASTER Global DEM. *Photogramm Eng*, 76(4), 344–348.
- Abrams, M., Crippen, R., Fujisada, H. (2020). ASTER Global Digital Elevation Model (GDEM) and ASTER Global Water Body Dataset (ASTWBD). *Remote Sensing*, 12(7).
- Altrichter, M., Horváth, G., Pataki, B., Strausz, G., Takács, G., Valyon, J. (2006). *Neurális hálózatok*. Panem Kft.
- Anderson, J. R., Hardy, E. E., Roach, J. T., Witmer, R. E. (1976). A land use and land cover classification system for use with remote sensor data. In *Professional Paper*.
- Anys, H., Abdou, B., He, D. C., Morin, D. (1994). Texture analysis for the mapping of urban areas using airborne MEIS-II images, in proceedings of the first international airborne remote sensing conference and exhibition. *Strasbourg, France*, 3, 231–245.
- Anys, H., He, D.-C. (1995). Evaluation of textural and multipolarization radar features for crop classification. *IEEE Transactions on Geoscience and Remote Sensing*, 33(5), 1170–1181.
- Arnold, S., Kosztra, B., Banko, G., Smith, G., Hazeu, G., Bock, M., Sanz, N. V. (2013). *The EAGLE concept - A vision of a future European Land Monitoring Framework*.
- Ayala-Izurieta, J., Marquez, C. O., Garcia, V., Recalde, C., Rodríguez-Llerena, M., Damián Carrión, D. (2017). *Land Cover Classification in an Ecuadorian Mountain Geosystem Using a Random Forest Classifier, Spectral Vegetation Indices, and Ancillary Geographic Data*.
- Balzter, H., Cole, B., Thiel, C., Schullius, C. (2015). Mapping CORINE land cover from Sentinel-1A SAR and SRTM digital elevation model data using random forests. *Remote Sensing*, 7, 14876–14898.
- Bartholomé, E., Belward, A. S. (2005). GLC2000: a new approach to global land cover mapping from Earth observation data. *International Journal of Remote Sensing*, 26(9), 1959–1977.
- Baughman, C. A., Conaway, J. S. (2021). Comparison of Historical Water Temperature Measurements with Landsat Analysis Ready Data Provisional Surface Temperature Estimates for the Yukon River in Alaska. *Remote Sensing*, 13(12).
- Becse, A., Mezősi, G., László, Á., Juhász, Á., Marosi, S., Somogyi, S., Szilárd, J., Ambrózy, P., Konkolyiné, B. Z., Király, G., Molnár, Z., Bölöni, J., Csiky, J., Vojtkó, A., Rajkai, K.,

- Tóth, G., Tiner, T., Dövényi, Z., Michalkó, G., Keresztesi, Z. (2010). *Magyarország kistájainak katasztere* (Z. Dövényi (ed.); 2., átd. é). MTA Földrajztudományi Kutatóintézet.
- Bényász, M. (2010). *Klasszifikáció az adatbányászatban* [Eötvös Loránd Tudományegyetem].
- Bezdan, A., Vranešević, M., Blagojević, B., Pejić, B., Bezdan, J., Milić, D., Tica, N., Zekić, V. (2019). Mezőgazdasági aszálykockázatbecslés a Vajdaságban. In Z. Ladányi & V. Blanka (Eds.), *Aszály és belvíz monitoring és menedzsment, valamint a kapcsolódó kockázatok a Dél-Alföldön és a Vajdaságban* (pp. 48–62). Szegedi Tudományegyetem, Természeti Földrajzi és Geoinformatikai Tanszék.
- Bhargava, N., Sharma, G., Bhargava, R., Mathuria, M. (2013). Decision Tree Analysis on J48 Algorithm for Data Mining. *International Journal of Advanced Research in Computer Science and Software Engineering*, 3(6).
- Bodon, F., Buza, K. (2014). *Adatbányászat*.
- Boser, B. E., Guyon, I. M., Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual Workshop on Computational Learning Theory - COLT '92*, 5, 144–152.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32.
- Bruzzone, L., Conese, C., Maselli, F., Roli, F., others. (1997). Multisource classification of complex rural areas by statistical and neural-network approaches. *Photogrammetric Engineering and Remote Sensing*, 63(5), 523–532.
- Bui, D. H., Mucsi, L. (2021). From Land Cover Map to Land Use Map: A Combined Pixel-Based and Object-Based Approach Using Multi-Temporal Landsat Data, a Random Forest Classifier, and Decision Rules. *Remote Sensing*, 13(9), 1–24.
- Buttner, G., Kosztra, B. (2017). *CLC2018 Technical Guidelines*.
- Büttner, G., Kosztra, B., Maucha, G. (2016). Accuracy assessment of CLC data. In *European Landscape Dynamics: CORINE Land Cover Data* (pp. 41–54).
- Büttner, G., Steenmans, C., Bossard, M., Feranec, J., Kolár, J. (2000). Land Cover --- Land Use Mapping within the European Corine Programme. In M. F. Buchroithner (Ed.), *Remote Sensing for Environmental Data in Albania: A Strategy for Integrated Management* (pp. 89–100). Springer Netherlands.
- Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., He, C., Han, G., Peng, S., Lu, M., Zhang, W., Tong, X., Mills, J. (2014). Global land cover mapping at 30 m resolution: A POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103.
- Chollet, F. (2017). *Deep Learning with Python* (1st ed.). Manning Publications Co.
- Cole, B., Smith, G., Balzter, H. (2018). Acceleration and fragmentation of CORINE land cover

- changes in the United Kingdom from 2006–2012 detected by Copernicus IMAGE2012 satellite data. *International Journal of Applied Earth Observation and Geoinformation*, 73, 107–122.
- Comber, A., Fisher, P., Wadsworth, R. (2005). What is Land Cover? *Environment and Planning B: Planning and Design*, 32(2), 199–209.
- Congalton, R. G., Green, K. (2008). *Assessing the Accuracy of Remotely Sensed Data* (2nd ed.). CRC Press.
- Contributors, G. (n.d.). *GDAL/OGR Geospatial Data Abstraction Library*.
- Cortes, C., Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.
- Costăchioiu, T., Datcu, M. (2010). Land cover dynamics classification using multi-temporal spectral indices from satellite image time series. *2010 8th International Conference on Communications, COMM 2010*, 157–160.
- Csikós, N., Szilassi, P. (2020). Impact of Energy Landscapes on the Abundance of Eurasian Skylark (*Alauda arvensis*), an Example from North Germany. *Sustainability*, 12, 664.
- Csikós, N., Szilassi, P. (2021a). Investigation the relation between the recent land cover and the eurasian skylark (*alauda arvensis*) population changes in european scale. *Carpathian Journal of Earth and Environmental Sciences*, 16, 361–372.
- Csikós, N., Szilassi, P. (2021b). Modelling the Impacts of Habitat Changes on the Population Density of Eurasian Skylark (*Alauda arvensis*) Based on Its Landscape Preferences. *Land*, 10(3).
- Dabboor, M., Howell, S., Shokr, M., Yackel, J. (2014). The Jeffries–Matusita distance for the case of complex Wishart distribution as a separability criterion for fully polarimetric SAR data. *International Journal of Remote Sensing*, 35(19), 6859–6873. <https://doi.org/10.1080/01431161.2014.960614>
- Das, P., Mudi, S., Behera, M. D., Barik, S. K., Mishra, D. R., Roy, P. S. (2021). Automated Mapping for Long-Term Analysis of Shifting Cultivation in Northeast India. *Remote Sensing*, 13(6).
- Di, Y., Zhang, G., You, N., Yang, T., Zhang, Q., Liu, R., Doughty, R. B., Zhang, Y. (2021). Mapping Croplands in the Granary of the Tibetan Plateau Using All Available Landsat Imagery, A Phenology-Based Approach, and Google Earth Engine. *Remote Sensing*, 13(12).
- Du, P., Bai, X., Tan, K., Xue, Z., Samat, A., Xia, J., Li, E., Su, H., Liu, W. (2020). Advances of Four Machine Learning Methods for Spatial Data Handling: a Review. *Journal of Geovisualization and Spatial Analysis*, 4(1), 13.
- Eibe, F., Mark, A. H., Ian, H. W. (2016). *The WEKA Workbench, Online Appendix for “Data*

- Mining: Practical Machine Learning Tools and Techniques*” (Fourth). Morgan Kaufmann.
- Emery, W., Camps, A. (2017). *Introduction to Satellite Remote Sensing* (W. Emery & A. Camps (eds.)). Elsevier.
- Esch, T., Roth, A., Strunz, G. (2004). *Object-oriented approach towards a semi-automated classification of urban areas*.
- European Commission, J.-I. (2005). *IMAGE2000 and CLC2000 Products and Methods* (M. V. N. de Lima (ed.)). European Commission.
- Fan, R.-E., Chang, K.-W., Hsieh, C.-J., Wang, X.-R., Lin, C.-J. (2008). LIBLINEAR: A library for large linear classification. *Journal of Machine Learning Research*, 9(Aug), 1871–1874.
- FAO. (1997). *AFRICOVER: land cover classification*.
- Farr, T. G., Kobrick, M. (2000). Shuttle radar topography mission produces a wealth of data. *Eos*, 81(48), 583–585.
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., Alsdorf, D. E. (2007). The shuttle radar topography mission. *Reviews of Geophysics*, 45(2).
- Feng, Q., Liu, J., Gong, J. (2015). UAV Remote Sensing for Urban Vegetation Mapping Using Random Forest and Texture Analysis. *Remote Sensing*, 7(1), 1074–1094.
- Feranec, J., Jaffrain, G., Soukup, T., Hazeu, G. (2010). Determining changes and flows in European landscapes 1990–2000 using CORINE land cover data. *Applied Geography*, 30(1), 19–35.
- Fichera, C., Modica, G., Pollino, M. (2012). Land Cover classification and change-detection analysis using multi-temporal remote sensed imagery and landscape metrics. *European Journal of Remote Sensing*, 45, 1–18.
- Filipponi, F. (2019). *Sentinel-1 GRD Preprocessing Workflow*. 11.
- Foley, J. A., DeFries, R., Asner, G. P., Barford, C., Bonan, G., Carpenter, S. R., Chapin, F. S., Coe, M. T., Daily, G. C., Gibbs, H. K., Helkowski, J. H., Holloway, T., Howard, E. A., Kucharik, C. J., Monfreda, C., Patz, J. A., Prentice, I. C., Ramankutty, N., Snyder, P. K. (2005). Global Consequences of Land Use. *Science*, 309(5734), 570–574.
- Fragoso-Campón, L., Quirós, E., Mora, J., Gutiérrez, J. A., Durán-Barroso, P. (2018). Accuracy Enhancement for Land Cover Classification Using LiDAR and Multitemporal Sentinel 2 Images in a Forested Watershed. *Proceedings*, 2(20), 1280.
- Friedl, M. A., McIver, D. K., Hodges, J. C. F., Zhang, X. Y., Muchoney, D., Strahler, A. H., Woodcock, C. E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F., Schaaf, C.

- (2002). Global land cover mapping from MODIS: algorithms and early results. *Remote Sensing of Environment*, 83(1), 287–302.
- Friedman, J. (2001). Greedy Function Approximation: A Gradient Boosting Machine. *Annals of Statistics*, 29, 1189–1232.
- Friedman, J. (2002). Stochastic Gradient Boosting. *Computational Statistics & Data Analysis*, 38, 367–378.
- Garg, R., Kumar, A., Prateek, M., Pandey, K., Kumar, S. (2021). Land cover classification of spaceborne multifrequency SAR and optical multispectral data using machine learning. *Advances in Space Research*.
- Gregorio, A. Di, Jansen, L. J. M. (2000). *Land Cover Classification System (LCCS): Classification Concepts and User Manual*.
- Griffiths, P., van der Linden, S., Kuemmerle, T., Hostert, P. (2013). A Pixel-Based Landsat Compositing Algorithm for Large Area Land Cover Mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(5), 2088–2101.
- Gudmann, A., Csikós, N., Szilassi, P., Mucsi, L. (2020). Improvement in Satellite Image-Based Land Cover Classification with Landscape Metrics. *Remote Sensing*, 12(21), 3580.
- Gudmann, A., Mucsi, L. (2022). Pixel and object-based land cover mapping and change detection from 1986 to 2020 for Hungary using histogram-based gradient boosting classification tree classifier. *Geographica Pannonica*.
- Gudmann, A., Mucsi, L. (2019). Döntési fa és véletlen erdő osztályozási módszerekkel készített felszínborítási térképek pontosságának összehasonlító elemzése. In V. É. Molnár (Ed.), *Az elmélet és a gyakorlat találkozása a térinformatikában X.: Theory meets practice in GIS*. (pp. 91–100).
- Gudmann, A., Mucsi, L., Henits, L. (2019). A CORINE felszínborítási térkép automatikus előállításának lehetősége döntési fa-osztályozó segítségével. *Geodézia És Kartográfia*, 71(2).
- Hagan Demuth, Howard B., Beale, Mark H., M. T. (1996). *Neural network design*. PWS Pub.
- Haralick, R., Shanmugam, K., Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Trans Syst Man Cybern, SMC-3*, 610–621.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., del Río, J. F., Wiebe, M., Peterson, P., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357–362.
- Haugeland, J. (1989). *Artificial Intelligence: The Very Idea*. The MIT Press.
- Haykin, S. S. (2009). *Neural Networks and Learning Machines* (Issue 10. k.). Prentice Hall.

- Henits, L., Jürgens, C., Mucsi, L. (2016). Seasonal multitemporal land-cover classification and change detection analysis of Bochum, Germany, using multitemporal Landsat TM data. *International Journal of Remote Sensing*, 37(15), 3439–3454.
- Henits, L., Mucsi, L., Liska, C. M. (2017). Monitoring the changes in impervious surface ratio and urban heat island intensity between 1987 and 2011 in Szeged, Hungary. *Environmental Monitoring and Assessment*, 189.
- Homer, C., Dewitz, J., Fry, J., Coan, M., Larson, C. R., Mckerrow, A., VanDriel, J., Wickham, J. (2007). Completion of the 2001 National Land Cover Database for the Conterminous United States. *Photogrammetric Engineering and Remote Sensing*, 73.
- Inco, D., Interdonato, R., Gaetano, R., Ho Tong Minh, D. (2019). Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 11–22.
- Inglada, J. (2016). Land Cover Mapping from Optical Images. In N. Baghdadi & M. Zribi (Eds.), *Land Surface Remote Sensing in Agriculture and Forest* (pp. 81–111). Elsevier.
- Irons, J. R., Petersen, G. W. (1981). Texture transforms of remote sensing data. *Remote Sensing of Environment*, 11, 359–370.
- Jiang, L., Wang, W., Yang, X., Xie, N., Cheng, Y. (2010). *Classification Methods of Remote Sensing Image Based on Decision Tree Technologies*.
- Jolliffe, I. (1986). *Principal Component Analysis* (1st ed.). Springer-Verlag.
- Jozdani, S. E., Johnson, B. A., Chen, D. (2019). Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification. *Remote Sensing*, 11(14).
- Jutz, S., Milagro-Pérez, M. (2020). Copernicus: the European Earth Observation programme. *Revista de Teledetección*.
- Jutz, S., Milagro-Pérez, M. P. (2018). 1.06 - Copernicus Program. In S. Liang (Ed.), *Comprehensive Remote Sensing* (pp. 150–191). Elsevier.
- Karimi, H. A. (2014). *Big Data: Techniques and Technologies in Geoinformatics* (H. A. Karimi (ed.); 1st ed.). CRC Press.
- Kauth, R. J., Thomas, G. S. (1976). The Tasseled Cap, A graphic description of the spectral-temporal development of agricultural crops as seen by LANDSAT. *LARS Symposia*.
- Kobayashi, N., Tani, H., Wang, X., Sonobe, R. (2020). Crop classification using spectral indices derived from Sentinel-2A imagery. *Journal of Information and Telecommunication*, 4(1), 67–90.
- Kosztra, B., Lehoczki, R., Pataki, R., Henits, L., Petrik, O., Gunawan, M., Gaál, Z. (2016).

- Európai CLC előállítására nemzeti adatokból EAGLE módszer alapján. *Fény-Tér-Kép*.
- Kovács, Z., Farkas, Z. J., Egedy, T., Kondor, A. C., Szabó, B., Lennert, J., Baka, D., Kohán, B. (2019). Urban sprawl and land conversion in post-socialist cities: The case of metropolitan Budapest. *Cities*, 92, 71–81.
- Kumar, M., Denis, D., Singh, S., Szabo, S., Suryavanshi, S. (2018). Landscape metrics for assessment of land cover change and fragmentation of a heterogeneous watershed. *Remote Sensing Applications: Society and Environment*, 10.
- Langanke, T. (2016a). *Copernicus Land Monitoring Service – High Resolution Layer Grassland: Product Specifications Document*.
- Langanke, T. (2016b). *Copernicus Land Monitoring Service – High Resolution Layer Imperviousness: Product Specifications Document*. 39.
- Langanke, T. (2016c). *Copernicus Land Monitoring Service – High Resolution Layer Water and Wetness: Product Specifications Document*.
- Langanke, T. (2017). *Copernicus Land Monitoring Service – High Resolution Layer Forest: Product Specifications Document*. 38.
- Leeuwen van, B., Tobak, Z., Kovács, F. (2020). Machine Learning Techniques for Land Use/Land Cover Classification of Medium Resolution Optical Satellite Imagery Focusing on Temporary Inundated Areas. *Journal of Environmental Geography*, 13(1–2).
- Lei, T. C., Wan, S., Wu, S.-C., Wang, H.-P. (2020). A New Approach of Ensemble Learning Technique to Resolve the Uncertainties of Paddy Area through Image Classification. *Remote Sensing*, 12(21).
- Li, G., Lu, D., Moran, E., Hetrick, S. (2011). Land-cover classification in a moist tropical region of Brazil with Landsat TM imagery. *International Journal of Remote Sensing*, 32(23), 8207–8230.
- Liaqat, M. U., Mohamed, M. M., Chowdhury, R., Elmahdy, S. I., Khan, Q., Ansari, R. (2021). Impact of land use/land cover changes on groundwater resources in Al Ain region of the United Arab Emirates using remote sensing and GIS techniques. *Groundwater for Sustainable Development*, 14, 100587.
- Liska, C. M., Mucsi, L., Henits, L. (2017). Hosszútávú felszínborítás-változások vizsgálata Csongrád megyében idősoros adatok felhasználásával, Random Forest módszerrel. *Földrajzi Közlemények*, 141(1), 71–83.
- Malinowski, R., Lewiński, S., Rybicki, M., Gromny, E., Jenerowicz, M., Krupiński, M., Nowakowski, A., Wojtkowski, C., Krupiński, M., Krätzschmar, E., Schauer, P. (2020). Automated Production of a Land Cover/Use Map of Europe Based on Sentinel-2 Imagery. *Remote Sensing*, 12(21), 3523.

- Mander, Ü., Kull, A., Uuemaa, E., Mõisja, K., Külvik, M., Kikas, T., Raet, J., Tournebize, J., Sepp, K. (2018). Green and brown infrastructures support a landscape-level implementation of ecological engineering. *Ecological Engineering*, 120, 23–35.
- Marceau, D. J., Howarth, P. J., Dubois, J. M., Gratton, D. J. (1990). Evaluation Of The Grey-level Co-occurrence Matrix Method For Land-cover Classification Using Spot Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4), 513–519.
- Mari, L., Mattányi, Z. (2002). Egységes európai felszínborítási adatbázis a CORINE Land Cover program (A uniform european land cover database the CORINE Land Cover program). *Földrajzi Közlemények*, 76 (50), 31–38.
- Masek, J. G., Wulder, M. A., Markham, B., McCorkel, J., Crawford, C. J., Storey, J., Jenstrom, D. T. (2020). Landsat 9: Empowering open science and applications through continuity. *Remote Sensing of Environment*, 248, 111968.
- McCulloch, W. S., Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.
- Mezősi, G., Fejes, C. (2004). A tájak ökológiai feltjainak kvantitatív elemzése. *A Magyar Földrajz Kurrens Eredményei: II. Magyar Földrajzi Konferencia / Táj, Tér, Tervezés : Geográfus Doktoranduszok VIII. Országos Konferenciája*, 1–11.
- Mishra, V. N., Prasad, R., Rai, P. K., Vishwakarma, A. K., Arora, A. (2019). Performance evaluation of textural features in improving land use/land cover classification accuracy of heterogeneous landscape using multi-sensor remote sensing data. *Earth Science Informatics*, 12(1), 71–86.
- Morin, N., Masse, A., Sannier, C., Siklar, M., Kiesslich, N., Sayadyan, H., Fauqueur, L., Seewald, M. (2021). Development and Application of Earth Observation Based Machine Learning Methods for Characterizing Forest and Land Cover Change in Dilijan National Park of Armenia between 1991 and 2019. *Remote Sensing*, 13(15).
- Mucsi, L. (2004). *Műholdas távérzékelés*. Libellus kiadó, Szeged, ISBN 963-214-903-3, p. 237.
- Olexó, T. (2018). *Az adatbányászat hibrid modelljei* [Eötvös Loránd Tudományegyetem].
- Paneque-Gálvez, J., Mas, J.-F., Moré, G., Cristóbal, J., Orta-Martínez, M., Luz, A. C., Guèze, M., Macía, M. J., Reyes-García, V. (2013). Enhanced land use/cover classification of heterogeneous tropical landscapes using support vector machines and textural homogeneity. *International Journal of Applied Earth Observation and Geoinformation*, 23, 372–383.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python.

Journal of Machine Learning Research, 12, 2825–2830.

- Pelletier, F., Eskelson, B. N. I., Monleon, V. J., Tseng, Y.-C. (2021). Using Landsat Imagery to Assess Burn Severity of National Forest Inventory Plots. *Remote Sensing*, 13(10).
- Pérez-Hoyos, A., Udías, A., Rembold, F. (2020). Integrating multiple land cover maps through a multi-criteria analysis to improve agricultural monitoring in Africa. *International Journal of Applied Earth Observation and Geoinformation*, 88, 102064.
- Pflugmacher, D., Rabe, A., Peters, M., Hostert, P. (2019). Mapping pan-European land cover using Landsat spectral-temporal metrics and the European LUCAS survey. *Remote Sensing of Environment*, 221, 583–595.
- Phan, T. N., Kuch, V., Lehnert, L. W. (2020). Land Cover Classification using Google Earth Engine and Random Forest Classifier—The Role of Image Composition. *Remote Sensing*, 12(15).
- Richards, J. A. (2005). Analysis of remotely sensed data: the formative decades and the future. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 422–432.
- Rodriguez-Galiano, V., Chica-Olmo, M. (2012). Land cover change analysis of a Mediterranean area in Spain using different sources of data: Multi-seasonal Landsat images, land surface temperature, digital terrain models and texture. *Applied Geography*, 35(1), 208–218.
- Seydi, S. T., Hasanlou, M., Amani, M. (2020). A New End-to-End Multi-Dimensional CNN Framework for Land Cover/Land Use Change Detection in Multi-Source Remote Sensing Datasets. *Remote Sensing*, 12(12).
- Shao, Y., Lunetta, R. S. (2012). Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70, 78–87.
- Steurer, M., Bayr, C. (2020). Measuring urban sprawl using land use data. *Land Use Policy*, 97, 104799.
- Swain, P. H., Hauska, H. (1977). The decision tree classifier: Design and potential. *IEEE Transactions on Geoscience Electronics*, 15(3), 142–147.
- Szabo, S., Csorba, P., Szilassi, P. (2012). Tools for landscape ecological planning - scale, and aggregation sensitivity of the contagion type landscape metric indices. *Carpathian Journal of Earth and Environmental Sciences*, 7, 127–136. h
- Szilassi, P. (2017). Magyarországi kistájak felszínborítás változékonysága és felszínborítás mozaikosságuk változása. *Tájökológiai Lapok*, 15(2), 131–138.
- Szilassi, P., Bata, T., Szabo, S., Czúcz, B., Molnár, Z., Mezősi, G. (2017). The link between landscape pattern and vegetation naturalness on a regional scale. *Ecological Indicators*,

81, 252–259.

- Sentinel User Handbook and Exploration Tools. (2015). *Sentinel-2 User Handbook*. European Space Agency (ESA).
- Tan, P.-N., Steinbach, M., Kumar, V. (2006). *Introduction to Data Mining*. Pearson Addison-Wesley.
- Tanács, E., Belenyési, M., Lehoczki, R., Pataki, R., Petrik, O., Standovár, T., Pásztor, L., Laborczi, A., Szatmári, G., Molnár, Z., Bede-Fazekas, Á., Fodor, L., Zsembergy, Z. (2019). *Országos, nagyfelbontású ökoszisztéma- alaptérkép: módszertan, validáció és felhasználási lehetőségek*. 25, 34–58.
- Thakkar, A., Desai, V., Patel, A., Madhukar, P. (2014). Land Use/Land Cover Classification of Remote Sensing Data and their Derived Products in a Heterogeneous Landscape of a Khan-Kali Watershed, Gujarat. *Asian Journal of Geo-Informatics*, 14, 1–12.
- Tobak, Z., Leeuwen van, B., Kovács, F., Szatmári, J. (2019). Belvíz előntések nagy pontosságú térképezése és monitorozása. In Z. Ladányi & V. Blanka (Eds.), *Aszály és belvíz monitoring és menedzsment, valamint a kapcsolódó kockázatok a Dél-Alföldön és a Vajdaságban* (pp. 13–23). Szegei Tudományegyetem, Természeti Földrajzi és Geoinformatikai Tanszék.
- Tomlinson, R. F. (1967). *An Introduction to the Geo-information System of the Canada Land Inventory*. (Department) of Forestry and Rural Development.
- Townshend, J. (1992). Land cover. *International Journal of Remote Sensing*, 13(6–7), 1319–1328.
- Townshend, J., Justice, C., Li, W., Gurney, C., McManus, J. (1991). Global land cover classification by remote sensing: present capabilities and future possibilities. *Remote Sensing of Environment*, 35(2), 243–255.
- Turing, A. M. (1950). I.—Computing machinery and intelligence. *Mind*, LIX(236), 433–460.
- Turner, B. L., Skole, D., Sanderson, S., Fischer, G., Fresco, L., Leemans, R. (1995). *Land-use and land-cover change. Science/Research plan*. (Issue 35). IGBP.
- U.S. Geological Survey. (2019a). Landsat 7 (L7) Data Users Handbook. In *USGS Landsat User Services* (2.0, Vol. 7, Issue November). Department of the Interior U.S. Geological Survey.
- U.S. Geological Survey. (2019b). Landsat 8 Data Users Handbook. In *Nasa* (5th ed., Vol. 8, Issue November). Department of the Interior U.S. Geological Survey.
- U.S. Geological Survey. (2020). Landsat 8 Collection 1 (C1) Land Surface Reflectance Code (LaSRC) Product Guide. In *Lsds-1368* (3rd ed., Vol. 1, Issue 3).
- U.S. Geological Survey. (2012). Landsat: A global land-imaging mission. In *Fact Sheet*.
- U.S. Geological Survey. (2016). Landsat—Earth observation satellites. In *Fact Sheet* (Ver 1.2).

- UNSD. (2013). Basic Set of Environment Statistics of the FDES 2013. *44th Session of the United Nations Statistical Commission*.
- van Leeuwen, B., Tobak, Z., Kovács, F., Sipos, G. (2017). Towards a continuous inland excess water flood monitoring system based on remote sensing data. *Journal of Environmental Geography*, 10(3–4), 9–15.
- Vogelmann, J. E., Howard, S. M., Yang, L., Larson, C. R., Wylie, B. K., Van Driel, J. N. (2001). Completion of the 1990s National Land Cover Data set for the conterminous United States from Landsat Thematic Mapper data and ancillary data sources. *Photogrammetric Engineering and Remote Sensing*, 67(6), 650–662.
- Waske, B., Fauvel, M., Benediktsson, J. A., Chanussot, J. (2009). Machine Learning Techniques in Remote Sensing Data Analysis. In *Kernel Methods for Remote Sensing Data Analysis* (pp. 1–24). John Wiley & Sons, Ltd.
- Weiss, M., Baret, F. (2011). fAPAR (fraction of Absorbed Photosynthetically Active Radiation) estimates at various scale. *34th International Symposium on Remote Sensing and Environment (ISRSE)*, 1–4.
- Weiss, M., Baret, F., Jay, S. (2020). *S2ToolBox Level 2 products LAI, FAPAR, FCOVER*. EMMAH-CAPTE, INRAe Avignon.
- Werbos, P. J. (1974). *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Harvard University.
- Wilkinson, G. G. (2005). Results and implications of a study of fifteen years of satellite image classification experiments. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 433–440.
- Wulder, M. A., Coops, N. C., Roy, D. P., White, J. C., Hermosilla, T. (2018). Land cover 2.0. *International Journal of Remote Sensing*, 39(12), 4254–4284.
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., Allen, R. G., Anderson, M. C., Belward, A. S., Cohen, W. B., Dwyer, J., Erb, A., Gao, F., Griffiths, P., Helder, D., Hermosilla, T., Hipple, J. D., Hostert, P., Hughes, M. J., ... Zhu, Z. (2019). Current status of Landsat program, science, and applications. *Remote Sensing of Environment*, 225, 127–147.
- Wulder, M. A., Roy, D. P., Radeloff, V. C., Loveland, T. R., Anderson, M. C., Johnson, D. M., Healey, S., Zhu, Z., Scambos, T. A., Pahlevan, N., Hansen, M., Gorelick, N., Crawford, C. J., Masek, J. G., Hermosilla, T., White, J. C., Belward, A. S., Schaaf, C., Woodcock, C. E., ... Cook, B. D. (2022). Fifty years of Landsat science and impacts. *Remote Sensing of Environment*, 280, 113195.
- Wulder, M. A., White, J. C., Loveland, T. R., Woodcock, C. E., Belward, A. S., Cohen, W. B.,

- Fosnight, E. A., Shaw, J., Masek, J. G., Roy, D. P. (2016). The global Landsat archive: Status, consolidation, and direction. *Remote Sensing of Environment*, 185, 271–283.
- Yamaguchi, Y., Kahle, A. B., Tsu, H., Kawakami, T., Pniel, M. (1998). Overview of advanced spaceborne thermal emission and reflection radiometer (ASTER). *IEEE Transactions on Geoscience and Remote Sensing*, 36(4), 1062–1071. <https://doi.org/10.1109/36.700991>
- Zhou, H., Fu, L., Sharma, R. P., Lei, Y., Guo, J. (2021). A Hybrid Approach of Combining Random Forest with Texture Analysis and VDVI for Desert Vegetation Mapping Based on UAV RGB Data. *Remote Sensing*, 13(10).
- Zhou, T., Li, Z., Pan, J. (2018). Multi-Feature Classification of Multi-Sensor Satellite Imagery Based on Dual-Polarimetric Sentinel-1A, Landsat-8 OLI, and Hyperion Images for Urban Land-Cover Classification. *Sensors*, 18(2), 373.
- Zhu, Y., Geiß, C., So, E., Jin, Y. (2021). Multitemporal Relearning With Convolutional LSTM Models for Land Use Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 3251–3265.

8. Köszönetnyilvánítás

Szeretném megköszönni témavezetőmnek, **Dr. Mucsi Lászlónak**, hogy egyetemi tanulmányaim és doktori képzésem során végig segítette szakmai és tudományos fejlődésemet. A témavezetése alatt örömmel végeztem el a feladataim, illetve fejezhettem be a tanulmányaim. Az iránymutatásai mellett olyan tudásanyagot sikerült elsajátítanom, ami egész karrierem során biztos alapot ad és erre támaszkodva tovább mélyíthetem azt.

Szeretném megköszönni egykori témavezetőmnek, **Dr. Henits Lászlónak**, hogy az országos diákköri konferenciára felkészülés során végig segítette kutatásomat szakmai iránymutatásával és szaktudásával. A témavezetése alatt felbecsülhetetlen ismeretekre tettem szert, amik ösztönöztek a doktori tanulmányaim elkezdéséhez. Továbbá szeretném megköszönni a doktori dolgozattal kapcsolatos segítségét, észrevételeit és tanácsait.

Szeretném megköszönni egykori PhD-s szobatársamnak, **Dr. Csikós Nándornak**, akihez mindig fordulhattam a doktori képzés során előforduló szakmai és egyéb kérdésekkel. Illetve, külön köszönet neki, és többi doktorandusz hallgatótársaimnak, akiknek köszönhetően kellemes, vidám és inspiráló környezetben végezhettem doktori tanulmányaimat és kutatásomat.

Köszönettel és hálával tartozom Anyukámnak, Testvéreimnek és Rokonaimnak, hogy céljaim elérésében mindig támogattak.

Köszönöm páromnak, Makra Tímeának, aki a mindennapokban jelentett nélkülözhetetlen támaszt és segítséget a PhD tanulmányaim és kutatásom során.

9. Summary

One of the fundamental and oldest tasks of remote sensing is the mapping of land use and land cover (LULC), as these two aspects of land are key sources of information for understanding geographical, social, and economic processes. The production and availability of reliable, up to date LULC maps and the statistics that can be derived from them play a vital role to the creation of environmental policies for sustainable development and planning. However, the mapping of these aspects of the earth, by definition, presents a number of technical and methodological challenges.

In my Ph.D. thesis, I have produced land cover/land use maps based on CORINE Land Cover nomenclature using different input data and classifier algorithms for the years 2000 and 2018. I used various older and newer satellite imagery, data derived from them, as well as other independent sources to investigate how to achieve the highest accuracy under certain conditions (different classification algorithms, study areas, data combinations).

In my research, I have successfully developed a classification methodology that can perform the classification task correctly on a randomly selected, relatively small set of training data. To perform the classifications in both software (WEKA) and programming (python) environments, I successfully developed a pre- and post-processing workflow to transform the spatial data into raw and then back into spatial data at the end of the classifications. In the WEKA software environment, I was able to successfully use four classification algorithms to perform the classifications: decision tree, random forest, support–vector machine, multilayer perceptron. Furthermore, I successfully implemented to python programming environment three advanced classification algorithms: random forest (RF), histogram-based gradient boosting classification tree (HBGBCT), artificial neural network (ANN). With these two methodologies, I performed the classifications on the different datasets.

(1) I examined the relationship of the spectral bands of the summer-time Landsat-7 (L7), and Sentinel-2 (S2) satellite images with the categories at 3rd level of the CLC nomenclature. Based on the Jeffries-Matusita (JM) separability values of the L7 satellite image spectral bands the separability values of the CLC categories were very low, but the S2 images showed a good separability value between the different categories. The L7 JM values were confirmed by the results of the classifications, which based on the spectral bands of satellite images and level-3 CLC categories. The results show that the algorithms, based on L7 spectral bands gave below 60% overall accuracy (OVRA) on 5 of the 6 study areas and only on 1 case above 70%. The classifications based on S2 bands achieve moderate accuracy (mean OVRA 73,82%), despite the JM values. Therefore, it can be stated that there is a detectable relationship between spectral

bands and categories at the 3rd level of the CLC hierarchy, but information from single date is not enough to perform the classifications with high accuracy.

(2) Since spectral bands alone were not sufficient to solve the classification task, I tried to improve the classification accuracy with different derivatives as additional input data. Such derivatives were spectral indices, such as NDVI, SAVI, MSAVI, EVI, NDMI, FaPAR, FVC and transformations, like Tasseled Cap and PCA. The classification results, based on L7 and traditional spectral indices (NDVI, SAVI, MSAVI, EVI, NDMI), show that only NDVI can improve the accuracy of the classification with 0,06%. The other indices decreased the accuracy with by between -0,15% and -2,54%. However, non-traditional classifiers (FaPAR, FVC) with S2 spectral bands increased the accuracy of some categories at class level. Similar to traditional spectral indices, transformations didn't improve the OVRA of the classifications, but for the SVM classifier, PCA bands were able to cause significant increase in accuracy (+4,78% OVRA).

(3) I also examined the effect of the information extracted from the environment of each pixel. Such information were the landscape metrics such as mean patch size (MPS), total edge (TE), mean shape index (MSI), and fractal dimension (MFRACT) or the variance, skewness, kurtosis and average Euclidean distance that can be extracted from kernel calculations. The results suggest that both the landscape metrics and the texture data are important sources of information that can generally improve the accuracy of classifications (landscape metrics between 0,52%–6,82%, texture information between 3,39%–11,95%). Furthermore, combinations of these data, cause further increases in accuracy of classifications and these can be applied appropriately to small and large areas.

(4) Thanks to the increasing temporal resolution of the satellite images, there are more and more opportunities to include temporal data in the classification. I examined data combinations formed with images from Landsat-7 for the year 2000 and Sentinel-2 for the year 2018, taken at multiple date. The results show that temporal data can significantly increase the accuracy of all classes and the OVRA (L7: -5,46%–7,14%, S2: 12,92%–22,25%). Based on the best results, the time window between each image should be kept as wide as possible to minimize the correlation between images and thus maximize the amount of information they contain. For the year 2018, the best results were obtained with a 3-month time window: based on 6 satellite images, all classification algorithms returned OVRA above 90%. The examination of the results from the temporal data used in the classification shows the spectral bands can adequately characterise the given land cover/land use categories.

(5) Beside the spectral band's derivatives and the temporal data I tested different primary data sources like SRTM, ASTER-GDEM elevation and Sentinel-1 radar data. The

SRTM combined with Landsat-7 data caused a small increase in the results of each classification (+2,35% on average), while the ASTER-GDEM data combined with Sentinel-2 data caused a smaller improvement, mainly at the class level (+0,06% OVRA). The combination of Sentinel-1 and Sentinel-2 data did not cause an overall improvement in the classification but did cause an improvement at class level. Class-level improvements were observed for all three data combinations for the categories with elevation attributes (artificial surfaces, forests, orchards, berries).

(6-8) In addition to examining the input data, I compared the advanced classification algorithms based on their performance. In this comparison, I observed the applicability, accuracy, and scalability of each algorithm. Among the three algorithms (RF, HBGBCT, ANN), the RF is the easiest to apply and the fastest model to build among the three algorithms. In addition, it builds models with small time difference on small and large sample sizes, can be scaled well between data sets of different sizes, while not losing accuracy. However, its average accuracy compared to the other classifiers is only moderate, ranging from 69,06% to 91,74% on different data sets. The HBGBCT is similar algorithm to the RF, with few model-building parameters, although the effect of these parameters is more significant than in the RF. Model building times were low and the model scales well and can give good results over small and large areas. The accuracies of this algorithm based on single date spectral values were like the RF. However, the different data combinations increased its accuracy significantly, thus it had the highest average accuracy values: between 69,38% and 93,34%. The ANN is the most difficult algorithm to apply, as we need to optimize its model building and architectural parameters, which have a very large impact on the performance of the model. The model is difficult to scale because the model building time increases exponentially with the size of the training data. The algorithm was most responsive on the inclusion of certain data, such as texture and temporal data, but with other data combination it gave the lowest accuracies. The average accuracy values ranged from 66,88% to 92,46%. Based on these results, the HBGBCT algorithm proved to be the most suitable for classifying land cover/land use categories at the 3rd level of the CLC hierarchy, based on medium resolution remotely sensed data.

Overall, it can be concluded that the use of temporal data provides the most ideal result for the high-precision delineation of categories at the 3rd level of CLC hierarchy. However, in its absence, spatial data extracted from medium resolution remote sensing data, combined with spectral data, can provide a suitable basis for the latest classification algorithms to perform classifications with high accuracy. From the mentioned latest algorithm were suitable for this task, but the most suitable was the histogram-based gradient boosting decision tree.

10. Mellékletek

A1. táblázat A mintaterületeken a CLC osztályok arányai.

CLC-kód	Pesti hordalékkúp-síkság		Hevesi-ártér		Felső-Őrség		Balatoni-Riviéra		Tétényifennsík		Gödöllői-dombság	
	CLC 00	CLC 18	CLC 00	CLC 18	CLC 00	CLC 18	CLC 00	CLC 18	CLC 00	CLC 18	CLC 00	CLC 18
111	0,02 %	0,02%	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %
112	21,9 5%	23,53 %	1,93 %	2,09 %	1,84 %	1,87 %	4,68 %	4,71 %	28,0 9%	33,8 1%	8,85 %	10,3 9%
121	4,70 %	6,11%	0,16 %	0,22 %	0,00 %	0,00 %	0,51 %	1,01 %	7,12 %	11,7 7%	0,76 %	1,33 %
122	0,99 %	2,01%	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	1,53 %	1,70 %	0,00 %	0,38 %
124	1,45 %	1,45%	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %
131	0,29 %	0,18%	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %
132	0,27 %	0,16%	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %
133	0,13 %	0,09%	0,00 %	0,00 %	0,00 %	0,00 %	0,23 %	0,00 %	2,85 %	0,34 %	0,31 %	0,09 %
141	1,09 %	1,11%	0,00 %	0,00 %	0,00 %	0,00 %	0,36 %	0,30 %	0,00 %	0,00 %	0,14 %	0,14 %
142	1,43 %	1,71%	0,49 %	0,61 %	0,00 %	0,00 %	16,7 7%	19,0 5%	8,25 %	9,91 %	0,20 %	0,35 %
211	37,9 8%	31,55 %	50,7 7%	47,0 9%	13,4 7%	13,5 8%	3,86 %	2,76 %	4,93 %	2,58 %	39,1 4%	35,7 5%
213	0,00 %	0,00%	0,56 %	0,60 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %
221	0,60 %	0,46%	0,00 %	0,00 %	0,00 %	0,00 %	25,0 3%	19,6 0%	0,00 %	0,00 %	0,17 %	0,11 %
222	0,90 %	0,50%	0,07 %	0,13 %	0,00 %	0,00 %	0,00 %	0,00 %	10,4 9%	3,37 %	0,99 %	0,75 %
231	4,67 %	6,26%	3,35 %	4,66 %	2,71 %	2,61 %	6,34 %	6,13 %	10,8 2%	8,22 %	2,39 %	2,43 %
242	1,97 %	2,10%	0,69 %	0,35 %	0,25 %	0,25 %	0,80 %	3,77 %	5,36 %	6,67 %	3,53 %	3,28 %
243	1,72 %	1,49%	0,36 %	0,46 %	1,29 %	1,21 %	5,13 %	4,62 %	0,79 %	0,79 %	2,41 %	2,52 %
311	11,3 4%	10,96 %	9,70 %	10,5 8%	17,8 0%	16,1 0%	20,5 3%	20,9 8%	13,8 4%	12,8 7%	31,6 0%	29,6 4%
312	1,60 %	1,26%	0,00 %	0,00 %	26,7 2%	23,7 4%	1,25 %	0,87 %	0,81 %	0,62 %	2,67 %	2,30 %
313	2,54 %	2,09%	0,00 %	0,00 %	30,5 7%	35,6 3%	1,92 %	2,11 %	0,00 %	0,05 %	2,92 %	2,78 %
321	0,00 %	0,00%	5,84 %	6,18 %	0,00 %	0,00 %	0,69 %	0,40 %	2,79 %	2,31 %	0,61 %	0,45 %
324	3,76 %	6,39%	2,31 %	2,55 %	5,34 %	5,01 %	4,38 %	6,17 %	1,92 %	4,64 %	2,77 %	6,77 %
411	0,45 %	0,36%	6,45 %	7,01 %	0,00 %	0,00 %	6,28 %	6,27 %	0,00 %	0,00 %	0,21 %	0,21 %
511	0,02 %	0,02%	2,30 %	2,35 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %	0,00 %
512	0,12 %	0,17%	15,0 1%	15,1 1%	0,00 %	0,00 %	1,24 %	1,24 %	0,43 %	0,36 %	0,32 %	0,32 %

A2. táblázat A Landsat-7-es felvételekből kiszámított spektrális indexek képletei.

Index	Egyenlet	Megjegyzés
Normalizált Differenciált Vegetációs Index (Normalized Difference Vegetation Index - NDVI)	$NDVI = \frac{IR - R}{IR + R}$	ahol IR a pixel értéke a közeli infravörös tartományban, és R a pixel értéke a vörös tartományban
Talajhoz Igazított Vegetációs Index (Soil-Adjusted Vegetation Index - SAVI)	$SAVI = (1 + L) \frac{N - R}{N + R + L}$	ahol N a pixel értéke a közeli infravörös tartományban, az R a pixel értéke a vörös tartományban, és L pedig a talaj-kiegyenlítő faktor
Módosított Talajhoz Igazított Vegetációs Index (Modified Soil- Adjusted Vegetation Index - MSAVI)	$SAVI = (1 + L) \frac{N - R}{N + R + L}$	ahol N a pixel értéke a közeli infravörös tartományban, az R a pixel értéke a vörös tartományban, és L pedig a talaj-kiegyenlítő faktor
	$L = 1 - \frac{2 * s * (NIR - R) * (NIR - s * R)}{(NIR + R)}$	ahol NIR a pixel értéke a közeli infravörös tartományban, a R a pixel értéke a vörös tartományban, és s az első talaj paraméter (a vörös és közeli-infravörös spektrális térben)
Továbbfejlesztett Vegetációs Index (Enhanced Vegetation Index - EVI)	$EVI = G \frac{p_{NIR} - p_R}{p_{NIR} + C_{1*} * p_R - C_2 * p_B + L}$	ahol G a növekedési faktor, a p a pixel felszíni reflektancia értéke, a NIR a pixel értéke a közeli infravörös tartományban, a R a pixel értéke a vörös tartományban, a B a pixel értéke a kék tartományban, C1 és C2 az aeroszol ellenállás koefficiensek, és L a lombkorona háttérét kiegyenlítő állandó
Normalizált Égési Arány (Normalized Burn Ratio - NBR)	$NBR = \frac{(NIR - SWIRII.)}{(NIR + SWIRII.)}$	ahol a NIR a pixel értéke a közeli infravörös tartományban, és a SWIRII. a pixel értéke a

		rövidhullámú infravörös tartományban
Normalizált Égési Arány 2 (Normalized Burn Ratio 2 – NBR2)	$NBR2 = \frac{(SWIRI. - SWIRII.)}{(SWIRI. + SWIRII.)}$	ahol a SWIRI. a pixel értéke a rövidhullámú infravörös tartományban, és a SWIRII. a pixel értéke a rövidhullámú infravörös tartományban
Normalizált Differenciált Nedvesség Index (Normalized Difference Moisture Index - NDMI)	$NDMI = \frac{(NIR - SWIRI.)}{(NIR + SWIRI.)}$	ahol a NIR a pixel értéke a közeli infravörös tartományban, és a SWIRI. a pixel értéke a rövidhullámú infravörös tartományban

A3. táblázat A textúra számításokhoz használt képletek.

Variancia	$\frac{\sum(x_{i,j} - M)^2}{n - 1}$ $M = \frac{\sum x_{ij}}{n}$	ahol $x_{i,j}$ a pixel értéke, M az ablak átlaga, és n az ablakban lévő pixelek száma
Ferdeség	$\frac{ \sum(x_{ij} - M)^3 }{(n - 1)(V)^{\frac{3}{2}}}$	ahol $x_{i,j}$ a pixel értéke, M az ablak átlaga, V a variancia, és n az ablakban lévő pixelek száma
Csúcsosság	$\frac{\sum(x_{ij} - M)^4}{(n - 1)(V)^2}$	ahol $x_{i,j}$ a pixel értéke, M az ablak átlaga, V a variancia, és n az ablakban lévő pixelek száma
Átlagos euklideszi távolság	$\frac{\sum [\sum_{\lambda} (x_{c\lambda} - x_{i\lambda})^2]^{\frac{1}{2}}}{n - 1}$	ahol $x_{ij\lambda}$ az i,j pixel λ sávjának értéke, $x_{c\lambda}$ a kernel középponti pixel λ sávjának értéke, és n az ablakban lévő pixelek száma

A4. táblázat Felhasznált adatok és belőlük kiszámított derivátumok, vastagon szedve azon időpontok, amik a CLC adatbázisok alapjául szolgáltak.

Műhold	Dátum	Kiszámított derivátumok	Csempe által lefedett mintaterületek
Landsat-7	2000.05.16		Pesti hordalékkúp-síkság Hevesi ártér Tétényi-fennsík Gödöllői-dombság
	2000.08.20	NDVI, SAVI, MSAVI, EVI, NBR, NBR2, NDMI, PCA, Tasseled Cap, Variancia (3×3, 5×5, 11×11, 17×17), Ferdeség (3×3, 5×5, 11×11, 17×17), Csúcsosság (3×3, 5×5, 11×11, 17×17), Átlagos Euklidészi Távolság (3×3, 5×5, 11×11, 17×17)	
	2000.10.23		
	2000.04.21		
	2000.05.07		
	2000.06.08		
	2000.07.10		
	2000.08.11		
	2000.10.14		
	2000.04.28		
	2000.07.01		
	2000.08.18	NDVI, SAVI, MSAVI, EVI, NBR, NBR2, NDMI, PCA, Tasseled Cap, Variancia (3×3, 5×5, 11×11, 17×17), Ferdeség (3×3, 5×5, 11×11, 17×17), Csúcsosság (3×3, 5×5, 11×11, 17×17), Átlagos Euklidészi Távolság (3×3, 5×5, 11×11, 17×17)	
	2000.10.21		
	Landsat-8	2017.08.09	
2017.08.11			Hevesi ártér
2017.08.18			Pesti hordalékkúp-síkság, Tétényi-fennsík, Gödöllői-dombság
2017.08.25			Balatoni-riviéra
Sentinel-1	2017.07.24		Felső-Örség, Balatoni-riviéra
	2017.07.25		Pesti hordalékkúp-síkság, Hevesi-ártér, Tétényi-fennsík, Gödöllői-dombság
Sentinel-2	2017.01.01		Felső-örség
	2017.01.05		Pesti hordalékkúp-síkság, Hevesi ártér, Tétényi-fennsík, Gödöllői-dombság
	2017.03.29		Pesti hordalékkúp-síkság, Balatoni-riviéra, Tétényi-fennsík, Gödöllői-dombság
	2017.04.25		Hevesi ártér

	2017.05.15		Hevesi ártér
	2017.06.24		Pesti hordalékkúp-síkság, Tétényi-fennsík, Gödöllői-dombság
	2017.07.07	FaPAR, FVC, Variancia (11×11, 17×17, 23×23)	Pesti hordalékkúp-síkság, Felső-órség, Tétényi-fennsík, Gödöllői-dombság
	2017.07.17	FaPAR, FVC, Variancia (11×11, 17×17, 23×23)	Balatoni-riviéra
	2017.08.03	FaPAR, FVC, Variancia (11×11, 17×17, 23×23)	Hevesi-ártér
	2017.08.08	FaPAR, FVC, Variancia (11×11, 17×17, 23×23)	Pesti hordalékkúp-síkság, Tétényi-fennsík, Gödöllői-dombság
	2017.10.02		Pesti hordalékkúp-síkság, Hevesi ártér, Tétényi-fennsík, Gödöllői-dombság
	2017.10.15		Felső-órség, Balatoni-riviéra
	2017.12.01		Pesti hordalékkúp-síkság, Hevesi ártér, Tétényi-fennsík, Gödöllői-dombság
	2017.12.19		Felső-órség, Balatoni-riviéra