

SZEGEDI TUDOMÁNYEGYETEM
Természettudományi és Informatikai Kar
Földtudományok Doktori Iskola

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

PhD értekezés tézisei

GUDMANN ANDRÁS VIKTOR

Témavezető:
Dr. Mucsi László

Szeged, 2023

1. Bevezetés és célkitűzések

A földfelszín egyedülálló erőforrás, amely azt a teret határolja, amiben a gazdasági tevékenységek és a környezeti folyamatok zajlanak, és a környezeti erőforrások és a gazdasági javak fellelhetőek. Ez az erőforrás egyre nagyobb nyomás alatt áll, hogy kiszolgálják a növekvő emberi szükségleteket (élelmiszer, víz, lakhely, szolgáltatások), és emiatt sokszor történik rajta területhasználati változások. Ezek a változások a felszínborításra is kihatnak és annak átalakulását eredményezheti (UNSD, 2013). A felszínborítás és a területhasználat a földfelszín két alapvető aspektusa, amelyek kulcsfontosságú információforrások a földrajzi, társadalmi, és gazdasági folyamatok megértésében. Emiatt fontos az ezeket bemutató pontos térképek gyors előállításához szükséges módszertan. A műholdas távérzékelés a műholdak és szenzorok fejlődésének köszönhetően, egyre jobb felbontással rendelkező távérzékelési adatok felhasználásával és széleskörű, interdiszciplináris módszertanával lehetőséget ad a legkülönbözőbb térképezési feladatok megoldására. A felszínborítás és a területhasználat műholdfelvételek alapján történő térképezése számos technikai, módszertani kihívást hordoz magában. Ezen kihívások leküzdésére a távérzékeléssel foglalkozó szakemberek már több módszertant alakítottak ki, így lehetővé téve a felszínborítási térképek nagy pontosságú előállítását. Azonban a területhasználat térképek előállításához szükséges módszertan kevésbé kutatott téma a felszínborításhoz képest, aminek térképezése így még nem megoldott.

Emiatt a dolgozatom alapvető célja a felszínborítás és területhasználat nagy pontosságú osztályozáshoz szükséges módszertan koncepciójának kialakítása. 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 megnövekedett számú közepes felbontású 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. Így az osztályozáshoz felhasznált adatok vizsgálatával kapcsolatban az alábbi célokat jelöltem ki:

- (1) Dolgozatomban 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 pontosan lehatárolhassuk.
- (2) A távérzékelte adatok osztályozása során legtöbbször használt az elsődleges adatforrást kiegészítő bemenő adatok, a műholdképek spektrális sávjából levezetett indexek és adattszformációk. 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 a spektrális indexek és az adattszformációk 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. Ezeknek az adatoknak a felszínborítással való kapcsolatával és az osztályozásban történő felhasználásával már számos 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 alkalmasak-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. A képosztályozásba is fontos szerepet kapnak az éven belüli felvételek, amelyek az időbeli különbségekből származó eltérés miatt jelentős többletinformációval rendelkeznek. 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 hardveres fejlesztéseknek köszönhetően olyan információhalmaz jön létre, amellyel a képosztályozások nagy pontossággal kivitelezhetők. Azonban a nagyszámú kategóriát tartalmazó, területhasználat osztályozásokban az ideális elsődleges adatforrásokból képzett kombinációk még nem egyértelműen meghatározottak. Ezért célul tűztem ki meghatározott elsődleges adatforrások kettős kombinációkban történő felhasználásának hatását a felszínborítás és területhasználat osztályozásának pontosságára.

Az utóbbi évtizedben a mesterséges intelligencia tudományához tartozó gépi tanulás (*machine learning*) és mély tanulás (*deep learning*) osztályozó eljárások (tartó-vektor gép, döntési fa, véletlen, gradiens növelő gépek, mély neurális hálók) és alkalmazási módszereik száma dinamikusan növekedett, ami napjainkban is folytatódik. A távérzékelésben ezen algoritmusok egyik leggyakoribb alkalmazási módja az irányított osztályozás.

- (6) 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, többosztályos gépi tanulásos osztályozó algoritmusok és egy hagyományos osztályozó algoritmus összevetését a felszínborítás és területhasználat térképezésében. További célom volt meghatározni közülük, azt az algoritmust, amivel a CLC adatbázis 3. hierarchia szintű nomenklatúrájával a legnagyobb pontosságú felszínborítási/területhasználati térképek készíthetők el.

- (7) Az adatok egyre gyorsabb előállítására miatt, a térképek pontossága mellett az algoritmusok teljesítménye is egy kritikus szemponttá vált az eredmények kiértékelése során. Ezért célul tűztem ki, hogy 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) Az algoritmusok teljesítménye mellett fontos szempont az adott módszer alkalmazhatósága nagyobb területen vagy adathalmazon. A rendelkezésre álló nagy mennyiségű, egyre jobb felbontási tulajdonságokkal rendelkező felvételező rendszereknek köszönhetően, az adatsűrűség növekedése feldolgozási problémaként jelenik meg. A kiterjeszhetőség 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. Felhasznált adatok és módszerek

A kutatásomhoz különböző távérzékelt adatokat, azok derivátumait és a CORINE Land Cover (CLC) adatbázisait használtam fel a 2000-es és 2018-as évre vonatkozóan. A CLC programot az egységes környezeti politika kialakításának elősegítése érdekében indította el az Európai Közösség 1985-ben. Az adatbázisok legkisebb térképezési egysége 25 hektár, vonalas részeken a minimális szélesség 100 méter. A CLC-ék egy egységes, háromszintes nomenklátúra alapján készítik el, amely első szinten 5, a második szinten 15, a harmadik szinten 44 darab osztályt tartalmaz. A CLC program keretében eddig 5 adatbázis készült el: 1990-es, 2000-es, 2006-os, 2012-es és 2018-as évekre. A kutatásom során ezeket az adatbázisokat használtam fel különböző módon. A 2000-es és 2018-as adatokat és azok 3. hierarchia szintjén lévő osztályait, mint tanító és referencia adat használtam fel az osztályozások során. Az összes CLC adatbázis alapján validáló pontokat jelöltem ki azokon a területeken belül, ahol nem változott a területhasználat.

Az általam kiválasztott elsődleges adatforrások a Landsat-7 (L7), Landsat-8 (L8), Sentinel-1 (S1), Sentinel-2 (S2) közepes felbontású multispektrális és mikrohullámú műholdképek, illetve SRTM és ASTER-GDEM magassági adatok voltak. A felhasznált műholdképek alapján történt a CLC adatbázisok létrehozása is, így megfelelő alapot biztosítottak a CLC nomenklatúrát felhasználó osztályozásaim elvégzéséhez. A Landsat felvételek közel azonos tulajdonságokkal rendelkeznek a műholdprogram alapvető kialakítása miatt. Az L7 ETM+ szenzorja 8 spektrális, és egy termális sávban készít képeket. Az L8 OLI szenzorja a látható és infravörös fény tartományában összesen 9 sávban, TIRS szenzorja 2 termális sávban rögzít adatokat. A spektrális sávok térbeli felbontása 30, a termális sáv/oké 60 (L7) vagy 100 (L8) és a pankromatikusé 15 méter. A felvételezések időbeli felbontása 16 nap és egy készített standard kép 185 km × 180 km nagyságú területet fed le. A Sentinel program keretein belül különböző tulajdonságú műholdak kerületek felbocsátásra. Az S1 műholdak radar alapú földmegfigyelést végeznek. Az egyes műholdak visszatérési ideje (időbeli felbontása) 12 nap, az azonos pályának köszönhetően az együttes visszatérési idejük 6 nap. A felvételező rendszerük egy C-sávban működő szintetikus apertúra radar (SAR). A műholdak fő leképezési módja a szárazföldek felett a szélessávú interferometrikus mód. Ezzel a móddal a nem poláris vagy jeges elhelyezkedésűek szárazföldek felett duális VV-VH polarizációval felvételez, 250 km sávban, 5x20 méteres térbeli felbontással. Az S2 műholdak multispektrális optikai mérőberendezéssel felvételezik a Föld felszínét. Az időbeli felbontásuk 10 nap, viszont az azonos pályának köszönhetően az együttes időbeli felbontásuk csak 5 nap. A műholdakon lévő MSI szenzor 13 spektrális sávban képeket felvételezni. A műszer által készített egy felvétel 290x290km nagyságú, és spektrális sávtól függően 10, 20, vagy 60 méteres térbeli felbontással rendelkezik. Az SRTM magassági információk alapját az Endeavour űrsiklóra telepített radarberendezés használatával, 2000.02.11-22 között gyűjtött adatok szolgáltatták. A magassági adatok a Föld északi szélesség 60° és a déli szélesség 56° közötti területekre érhetőek el. Az adatok globálisan kb. 90 éteres térbeli felbontással rendelkeznek. Az ASTER-GDEM az ASTER szenzor adatai által készített domborzat modell. Az ASTER szenzor a Terra műholdra telepítették. A műszer három alrendszere

közül a GDEM-et a látható fény és infravörös alrendszer által készített sztereó-képpárokából állítottak elő. A GDEM a Föld északi 83° és déli 83° közötti területeket fedi le, ezáltal a szárazföldek 99%-ról szolgáltat információt. A GDEM térbeli felbontása kb. 30 méter. Az adatbázis első verzióját 2009-ben adták ki, amelyet már 2 alkalommal frissítettek (2011-ben és 2019-ben).

A multispektrális műholdképekből különböző derivátumokat számoltam ki. A 2000 évből származó L7 képekből NDVI, SAVI, MSAVI, EVI, NBR, NBR2, NDMI spektrális indexeket, PCA és Tasseled Cap transzformációkat és textúra értékeket (Variansia, Ferdeség, Kurtózis, Átlagos Euklideszi Távolság) különböző kernel mérettel (3×3, 5×5, 11×11, 17×17). A 2018-ban készített S2 felvételekből FaPAR és FVC spektrális indexeket és variancia textúra értékeket eltérő kernel mérettel (11×11, 17×17, 23×23). Az osztályozások elvégzéséhez két módszert alakítottam ki. A kutatásom első szakaszában a WEKA általános adatbányászati szoftvert használtam. A kutatásom második szakaszában az első szakaszban kiválasztott vagy nem rendelkezésre álló algoritmusokat adaptáltam python programozási környezetbe, amivel az osztályozási folyamat nagy mértékben automatizálhatóvá vált. Mindkét módszer esetében az adatok előkészítését (adatharmonizáció és kiválasztás) lépéseket QGIS és ERDAS Imagine szoftverekkel végeztem el. A térinformatikai adatokat általánosan felhasználható formátumba kellett alakítani az osztályozások elvégzéséhez majd vissza térinformatikai adatokká. Ehhez a feladathoz *python* sripteket készítettem 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. A WEKA szoftverrel a 2000-es adatokat dolgoztam fel (Landsat-7, SRTM) és azok derivátumait, míg *python* környezetben a 2018-as adatokkal (Landsat-8, Sentinel-1, Sentinel-2) és azok derivátumaikkal dolgoztam. Az osztályozásokat 6 különböző típusú kistájra végeztem el: Pesti hordalékkúp-síkság, Hevesi-ártér, Felső-Örség, Balatoni-riviéra, Tétényi-fennsík és Gödöllői-dombság. Az eredményeimet a mintaterületeken mért különböző osztályozó algoritmusok által adott metrikák segítségével mutatom be.

3. Eredmények és következtetések

- (1) A CLC2000 és CLC2018 adatbázisok előállításához használt L7 (2000.08.11 és 08.18-ai) és S2 (2017.07.07 és 2017.07.17-ei) műholdképek alapján Jeffries-Matusita (JM) szeeparabilitás értékeket számítottam ki az adott CLC poligonokra. Az JM értékek alapján az L7 spektrális sávjai által a CLC kategóriák elválaszthatósága igen alacsony. Az S2 felvételek spektrális sávjai alapján azonban az egyes kategóriák jól elválaszthatók egymástól. Ezt részben alátámasztja az osztályozások eredményei. Az L7 spektrális sávok és CLC2000-es adatok alapján készített osztályozásoknál rossz pontossági értékeket kaptam. A 6 mintaterület közül 5 esetében az osztályozó algoritmusok 60% alatti összpontosságot adtak, és csak egy esetében 70% fölötti eredményt. Az S2 sávok és CLC2018-as adatok alapján a mintaterületekre készített osztályozásoknál közepes pontosságot adtak az algoritmusok, átlagosan 73,82%-ot.
- (2) A spektrális sávok önmagukban nem voltak elegendők az osztályozási feladat magas pontossággal való megoldásához, ezért különböző derivátumokat használtam (spektrális indexek és adattranszformációk), mint további bemenő adat az osztályozások pontosságának növeléséhez. Ilyen spektrális indexek voltak az NDVI, SAVI, MSAVI, EVI, NDMI, FaPAR, FVC. Az L7-es spektrális sávok és a hagyományos spektrális indexek (az NDVI, SAVI, MSAVI, EVI, NDMI) alapján készített osztályozások eredményei alapján, ezen indexek nem növelik az osztályozások pontosságát. A nem hagyományos derivátumok (FaPAR, FVC) és az S2 spektrális sávok kombinációjával kapott eredmények alapján ezen indexek képesek egyes kategóriák pontosságát növelni. A kutatásomban a spektrális indexek mellett a Tasseled Cap és PCA adattranszformációkat használtam fel, amelyeket az L7-es adatokból számítottam ki. Ezek az adatok az L7-es spektrális sávokkal kombinálva nem javították az osztályozások pontosságát általánosságban, azonban az SVM osztályozónál a PCA sávok képesek voltak pontosságnövekedést okozni (+4,78%).

- (3) A spektrális indexek 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 eredményeim alapján jelentős pontosságbeli javulás érhető el, ha az osztályozást a pixel környezetét tájmetriai mérőszámokkal leíró adatokkal bővítjük (minimum +0,52%, maximum +6,82%). A spektrális sávok és térbeli adatok felhasználásával készült modellek eredményei alapján, a variancia, ferdeség, kurtózis, 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. 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.
- (4) A spektrális sávok derivátumai mellett vizsgáltam az L7 és S2 temporális adatok hatékonyságát és az optimális időablak nagyságát. Az eredményeimmel igazoltam, hogy a temporális adatok jelentősen képesek növelni minden osztály pontosságát és az összpontosságot is (L7 esetén átlagosan +0,99%-kal, S2 esetén 12,92% és 22,25% között). Továbbá az eredményeim 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) A kutatásomban a derivátumok és temporális adatok mellett vizsgáltam a lehetséges egyéb elsődleges adatok hatását is, mint az SRTM, ASTER-GDEM magassági adatokat és a Sentinel-1 radar adatokat. Az SRTM magassági adatok a L7-es adatokkal kombinálva kis mértékben növelték az egyes osztályozások eredményét (átlagosan 2,35%-kal). Az ASTER-GDEM adatok a S2-es adatokkal kombinálva összpontosságban nem, de osztályszinten okoztak kisebb mértékű javulást. A S1 és S2-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 alapján 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. Változó átlagos összpontossági értékei 66,88% és 92,46% között mozogtak. Azonban a kutatásomban, összességében az osztályozó algoritmus érte el a legmagasabb pontossági értéket a három osztályozó közül (Hevesi ártér, Sentinel-2 6 időpontban készült felvétele alapján: 96,71%).

Összeségében megállapítható, hogy a CLC 3. hierarchia szintjén lévő főleg területhasználati kategóriák nagy pontosságú lehatárolása a temporális adatok felhasználásával adja a legideálisabb 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.

Summary

In my Ph.D. thesis, I have created a classification methodology and with that I 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). I examined the relationship of the spectral bands and satellite images. The results show that the algorithms, based on Landsat-7 spectral bands gave low accuracy (below 60% overall accuracy (OVRA)). The classifications based on Sentinel-2 bands achieve moderate accuracy (mean OVRA 73,82%). 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. The tested spectral indices and transformations, combined with spectral values caused no significant increase in accuracy. I also examined the effect of the information extracted from the environment of each pixel, like landscape metrics and texture data. 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%). I also tested the effects of the temporal data of Landsat-7 and Sentinel-2. The results show that temporal data can significantly increase the accuracy of all classes and the OVRA (Landsat-7: -5,46%–7,14%, Sentinel-2: 12,92%–22,25%). 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 an increase (+2,35% on average), while the ASTER-GDEM data combined with Sentinel-2 data caused a smaller improvement in accuracy (+0,06% OVRA). The combination of Sentinel-1 and Sentinel-2 data did not cause an overall improvement in the classification. In addition to examining the input data, I compared the advanced classification algorithms (random forest, histogram-based gradient-boosting decision tree, artificial neural network) based on their performance. Based on the results, the histogram-based gradient-boosting decision tree proved to be the most suitable for classifying land cover/land use (average accuracy values: between 69,38% and 93,34%).

Overall, it can be concluded that the use of temporal data provides the most ideal result for the high-precision delineation of land use/land cover categories of CLC. 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. All the mentioned latest algorithms were suitable for this task, but the most suitable was the histogram-based gradient boosting decision tree.

A tézishez felhasznált saját publikációk

Gudmann, A.; Mucsi, L.; Henits, L. A CORINE felszínborítási térkép automatikus előállításának lehetősége döntésifa-osztályozó segítségével, *Geodézia és Kartográfia*, 71: 2 pp. 9-13., 5 p. (2019),

DOI: 10.30921/GK.71.2019.2.2 Scopus: 85084584871

Gudmann, A.; Csikós, N.; Szilassi, P.; Mucsi, L. Improvement in Satellite Image-Based Land Cover Classification with Landscape Metrics, *Remote Sensing* 12: 21 Paper: 3580, 18 p. (2020), D1-Q1 (Earth and Planetary Sciences (miscellaneous))

DOI: 10.3390/rs12213580 Scopus: 85094919206

Gudmann, A.; Mucsi, L. 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* 26: 3 pp. 165-175., 11 p. (2022),

DOI: 10.5937/gp26-37720 Scopus: 85141340582

Gudmann, A.; Mucsi, L. Döntési fa és véletlen erdő osztályozási módszerekkel készített felszínborítási térképek pontosságának összehasonlító elemzése, In: Molnár, Vanda Éva (szerk.) *Az elmélet és a gyakorlat találkozása a térinformatikában X.: Theory meets practice in GIS* Debrecen, Magyarország: Debreceni Egyetemi Kiadó (2019) 428 p. pp. 91-100., 10 p.

A tézishez kapcsolódó saját publikációk

Gudmann, A. Mesterséges intelligencia alapú osztályozó eljárások alkalmazása nagytájszintű területhasználat változás térképezésére In: Béla, Bálint; Vass, Viktória; Vass, Zóra (szerk.) *Móra Akadémia szakkollégiumi tanulmánykötet: A Móra Ferenc Szakkollégium Évkönyve*, Szeged, Magyarország: Szegedi Tudományegyetem Móra Ferenc Szakkollégium (2022) 269 p. pp. 239-253., 15 p.

Társszerzői nyilatkozatok

Társszerzői nyilatkozat

Alulírott dr. Mucsi László nyilatkozom, hogy az alábbi publikációkban a doktorjelölt szerepe meghatározó fontosságú, nem használtam fel tudományos fokozat megszerzésekor, és ezt a jövőben sem teszem:

- „Döntési fa és véletlen erdő osztályozási módszerekkel készített felszínborítási térképek pontosságának összehasonlító elemzése” (Az elmélet és a gyakorlat találkozása a térinformatikában X.: Theory meets practice in GIS Debrecen, Magyarország: Debreceni Egyetemi Kiadó (2019) 428 p. pp. 91-100., 10 p.)
- „A CORINE felszínborítási térkép automatikus előállításának lehetősége döntésfá-osztályozó segítségével” (Geodézia és kartográfia 71: 2 pp. 9-13., 5 p. (2019))
- „Improvement in Satellite Image-Based Land Cover Classification with Landscape Metrics” (Remote Sensing 12: 21 Paper: 3580, 18 p. (2020))
- „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 26: 3 pp. 165-175., 11 p. (2022))

Szeged, 2023. 02.20.



dr. Mucsi László

Társszerzői nyilatkozat

Alulírott dr. Szilassi Péter nyilatkozom, hogy a „Improvement in Satellite Image-Based Land Cover Classification with Landscape Metrics” (Remote sensing 12: 21 Paper: 3580, 18 p. (2020)) publikációban a doktorjelölt szerepe meghatározó fontosságú, nem használtam fel tudományos fokozat megszerzésekor, és ezt a jövőben sem teszem.

Szeged, 2023. 02.20.



dr. Szilassi Péter

Társszerzői nyilatkozat

Alulírott dr. Csikós Nándor nyilatkozom, hogy a „Improvement in Satellite Image-Based Land Cover Classification with Landscape Metrics” (Remote sensing 12: 21 Paper: 3580, 18 p. (2020)) publikációjában a doktorjelölt szerepe meghatározó fontosságú, nem használtam fel tudományos fokozat megszerzésekor, és ezt a jövőben sem teszem.

Szeged, 2023.02.19


.....
dr. Csikós Nándor

Társszerzői nyilatkozat

Alulírott dr. Henits László nyilatkozom, hogy „A CORINE felszínborítási térkép automatikus előállításának lehetősége döntésifa-osztályozó segítségével” (Geodézia és kartográfia 71: 2 pp. 9-13., 5 p. (2019)) publikációjában a doktorjelölt szerepe meghatározó fontosságú, nem használtam fel tudományos fokozat megszerzésekor, és ezt a jövőben sem teszem.

Szeged, 2023.02.23.


.....
Dr. Henits László