



Soproni Egyetem
Erdőmérnöki Kar

VII. KARI TUDOMÁNYOS KONFERENCIA

konferencia kiadvány

2019. február 12.

A konferenciát és a konferenciakötet megjelenését az „EFOP-3.6.1-16-2016-00018 – A felsőoktatási rendszer K+F+I szerep-vállalásának növelése intelligens szakosodás által Sopronban és Szombathelyen” című projekt támogatta.

A kötet publikációit lektorálták: Bartha Dénes, Bidló András, Brolly Gábor, Czimber Kornél, Czupy Imre, Faragó Sándor, Frank Norbert, Pájet-Gálos Borbála, Gribovszki Zoltán, Heil Bálint, Hofmann Tamás, Horváth Adrienn, Horváth Tamás, Jánoska Ferenc, Kalicz Péter, Király Angéla, Király Gergely, Kovács Gábor, Lakatos Ferenc, László Richárd, Mátyás Csaba, Szakálosné Mátyás Katalin, Rétfalvi Tamás, Tuba Katalin, Veperdi Gábor, Vityi Andrea, Winkler Dániel

A kötet szakmai előkészítését az MTA VEAB Erdészettudományi Munkabizottsága támogatta.



Soproni Egyetem Kiadó 2019

ISBN978-963-334-322-7 (nyomtatott verzió)

978-963-334-323-4 (on-line verzió)

On-line verzió elérhetősége: http://emk.uni-sopron.hu/images/dekani_hivatal/Kiadvanyok/KariTudomanyosKonferencia/KariTudomanyosKonferencia2019.pdf

Szerkesztette: Király Gergely
Facskó Ferenc

Ajánlott hivatkozás:

KIRÁLY G. – FACSKÓ F. (szerk.) (2019): Soproni Egyetem Erdőmérnöki Kar VII. Kari Tudományos Konferencia. Soproni Egyetem Kiadó Sopron.

Tartalomjegyzék

Gribovszki Zoltán, Csáki Péter, Kalicz Péter, Zagyvainé Kiss Katalin: Erdő és víz – Kutatások az Erdőmérnöki Karon.....	5
Bende Attila, László Richárd: Erdei szalonka (<i>Scolopax rusticola</i> L.) színváltozatok és kurozomok Magyarországon.....	9
Polgár András, Kovács Zoltán, Elekné Fodor Veronika: Szántóföldi növénytermesztés környezeti életciklus elemzése	16
Rákóczi Attila: A zöldítés és a tájhasználat összefüggései Békés megyében.....	25
Tari Tamás, Sándor Gyula, Heffenträger Gábor, Náhlik András: A gímszarvas élőhelyhasználatának jellemzői a Soproni-hegyvidéken	30
Szalay László: The amazing world of Fibonacci sequence.....	37
Barton Iván, Czimber Kornél, Király Géza, Moskal L. Monika: Faállomány típusok térképezése Sentinel-2 ürfelvétel idősorozaton deep learning osztályozóval	41
Brolly Gábor, Primusz Péter, Bazsó Tamás, Király Géza: Több műszerállásból készített lézerszkennelések tájékozása erdőállományok felmérése során	48
Horváth Tamás, Gál János: Nelder kísérlet Magyarországon.....	54
Gálos Borbála, Csáki Péter, Gribovszki Zoltán, Kalicz Péter, Zagyvai Gergely, Tiborcz Viktor, Bartha Dénes, Hofmann Tamás, Visi Rajczi Eszter, Balázs Pál, Bidló András, Horváth Adrienn: Multidiszciplináris adatbázis és oktatási segédanyag fejlesztés komplex erdészeti klímahatás elemzések végzéséhez	58
Heilig Dávid, Heil Bálint, Kovács Gábor: A vízellátottság és a tápanyag-utánpótlás hatása egy midi rotációs nemesnyárültetvény növekedésére.	64
Horváth Attila László, Sudár Ferenc János, Szakálosné Mátyás Katalin: Folyamatgépesített fakitermelések vizsgálata	71
Kollár Tamás: Új adatok a magyarországi bükkösök faterméséről	76
Molnár Tamás, Birinyi Mátyás, Somogyi Zoltán, Király Géza: A 2017. áprilisi bükki hókarak felmérése és elemzése ürfelvételek alapján	81
Kiss Péter Áron, Rákosa Rita, Németh Zsolt István: Spektrumelőkészítési eljárások hatása biodegradált faanyag FT_IR spektrumainak értékelésében	88
Balázs Balázs, Tuba Katalin, Lakatos Ferenc: Kékülést okozó gombák és a szúbogarak kapcsolata.....	92
Bende Attila, László Richárd: Az erdei szalonka (<i>Scolopax rusticola</i> L.) színváltozatok előfordulása 2017-ben Magyarországon	96
Csáki Péter, Czimber Kornél, Király Géza, Kalicz Péter, Zagyvainé Kiss Katalin Anita, Gribovszki Zoltán: A CREMAP párolgástérkép leskálázása erdőállományok vízháztartásának vizsgálatához.....	102
Horváth Attila László, Horváth Béla, Szakálosné Mátyás Katalin: Harveszterek munkamínőségének vizsgálata	107
Kalicz Péter, Csáki Péter, Zagyvainé Kiss Katalin Anita, Gribovszki Zoltán: A lombkoronán áthulló csapadék mérésnek automatizálási lehetőségei.....	113
Komán Szabolcs, Németh Róbert, Fehér Sándor: <i>Paulownia</i> -fajok faanyagának tulajdonságai.....	117
Komán Szabolcs, Varga Dávid: Nyártermesztés Magyarországon	121
Major Tamás, Pintér Tamás: Mag- és sarjeredetű akác állományok választék-összetételének vizsgálata a SEFAG Erdészeti és Faipari Zrt. területén	126
Palkó Ákos, Winkler Dániel: Patakmenti égerligetek talajlakó faunájának (<i>Collembola</i>) vizsgálata a Soproni-hegységben	131
Papp Viktória: Ipari melléktermékek és faanyag keverék pelletek előállítása és energetikai értékelése.....	135

Polgár András: A környezetközpontú irányítás gyakorlatának helyzetértékelése Sopron városában	141
Polgár András, Elekné Fodor Veronika: Környezeti vonatkozású helyi sajtóinformációk vizsgálata Sopronban	149
Rákosa Rita, Vargovics Máté, Németh Zsolt István: FT-IR-ATR spektrometria alkalmazhatósága gomba tenyészetek fajspecifikus megkülönböztetésére.....	156
Stofa Krisztián, Virág Szabolcsné, Gálos Borbála: A kitettség napi hőmérséklet menetre gyakorolt hatásának számszerűsítése a Harkai kúpon	161
Szalay Dóra: RED II. – A generációk találkozása	164
Szóke Előd, Csáki Péter, Kalicz Péter, Zagyvainé Kiss Katalin Anita, Gribovszki Zoltán: Vízpótlási rendszerek hatásai egy somogyi erdőtömbön belül a vízfolyás menti zónák vízforgalmára	169
Vágvölgyi Andrea, Kovács Gábor: Energetikai faültetvények értékelő pontrendszere..	174
Visiné Rajczi Eszter, Albert Levente, Hofmann Tamás: Tobozok antioxidáns polifenol tartalmának felmérése.....	178
Zagyvainé Kiss Katalin Anita, Csáki Péter, Kalicz Péter, Szóke Előd, Gribovszki Zoltán: Agrárerdészeti rendszerek hidrológiai jellemzői	182

FAÁLLOMÁNY-TÍPUSOK TÉRKÉPEZÉSE SENTINEL-2 ŪRFELVÉTEL IDŐSOROZATON DEEP LEARNING OSZTÁLYOZÓVAL

BARTON IVÁN¹ – CZIMBER KORNÉL¹ – KIRÁLY GÉZA¹ – MOSKAL L. MONIKA²

¹Soproni Egyetem, Erdőmérnöki Kar, Geomatikai, Erdőfeltárási és Vízgazdálkodási Intézet

²Precision Forestry Cooperative, School of Environment and Forest Sciences,

University of Washington, Seattle (WA), USA

ivan.barton@gastudent.nyme.hu

Az egyes erdőtervezési körzetek erdőleírását Magyarországon 10 éves ciklusokban újítják meg. Ez alatt a hosszú idő alatt mesterséges és természetes eredetű változások következhetnek be az állományokban. Habár a faállományok lassú növekedéséhez meghatározott 10 éves ciklusok a gazdálkodás szempontjából még megfelelőek a legtöbb esetben, viszont a XXI. század felgyorsult információ-áramlásának már nem felel meg.

A faállomány-típus az erdőállomány egy jellemzője, ami az ott található fafajok elegyarányát fejezi ki. Jellemzően egy főfafaj köré csoportosulnak a kialakított faállomány-típus kategóriák. Optikai ūrfelvételek kiértékelésével az erdők koronaszerkezetének fontos paramétereit lehet meghatározni, többek között a faállomány felső lombkoronaszintjének fafajösszetételét. Annak ellenére, hogy csak korlátozott mértékben szolgáltatnak információt az ūrfelvételek a faállományokról, az erdőleírás egyes paramétereit évről évre aktualizálhatók vele. A technológia fejlődésének köszönhetően az ūrfelvétel idősorozatok spektrális, idő- és térbeli jellemzői is könnyen vizsgálhatók az erdőállományokon. Munkánk során a Börzsöny hegységre készítettünk el egy faállomány-típus térképet.

Anyag

A Copernicus földmegfigyelő program keretében pályára állított Sentinel-2 (S2) műholdpár ingyenesen szolgáltat nagy térbeli és időbeli felbontásban képanyagot a Földről 2015 óta. A műholdak fedélzetén az MSI szenzor található meg (DRUSCH *et al.* 2012), amely a spektrum 13 tartományában rögzíti a felszínről visszaverődő sugárzást a látható és az infravörös tartomány között (443–2190 nm) 12 bit/pixel radiometriai felbontásban. A szenzor 10 és 20 méteres felbontású sávjai elsősorban a felszínborítás és vegetáció térképezésére és elemzésre alkalmas tartományokban érzékelnek, a 60 méteres felbontású sávjai az atmoszféra állapotának rögzítésére alkalmas tartományokban rögzítik a képeket. Ennek megfelelően a kutatásban csak a 10 és 20 méteres terepi felbontású sávok kerültek alkalmazásra. A szenzor 290 km széles pásztában rögzíti a felvételeket. A műholdak együttes visszatérési ideje 5 nap, azonban az átfedő pályák miatt ez egyes helyeken gyakoribb. Magyarország elhelyezkedéséből kifolyólag egész évben közepes szintű a felhőborítás (60-70%) (WILSON - JETZ 2016), így az elkészült felvételeknek csak egy kis része értékelhető ki, és ezek időbeli eloszlása sem mindig optimális a vegetáció vizsgálatához (BARTON *et al.* 2018). A felvételeken még felhőmentes időben is megjelenhetnek egyéb atmoszférikus jelenségek, ezért atmoszférikus korrekció nélkül az egyes képek radiometriai tulajdonságai nem feltétlenül konzisztensek egy felvételen belül.

A faállomány-típusok térképezéséhez a Börzsöny hegységet és környezetét választottuk ki. A mintaterületet a 34UCU jelölésű S-2 csempe fedi, így a 2017. április 10. és 2017. október 27. között készült felvételek kerültek beszerzésre és feldolgozásra a R036 és R079-es műholdpásztákból. A tengerszint feletti magasság 100-900 méter között változik a mintaterületen. Az itt található természetes klímazonális erdőtársulásokban valamint a mesterséges telepítésű erdőkben összesen 87 leírt faállomány-típus található meg az Országos Erdőállomány Adattár (OEA) alapján. Ezeknek a térbeli és koreloszlása nem egyenletes minden fő-típusnál, de lehetőséget nyújt a gyakrabban előforduló faállomány-típus csoportok térképezésére.


A munka során a terület 20 méteres horizontális felbontású digitális domborzatmodelljét, valamint az erdőrészt poligonokat használtuk fel az űrfelvétel sorozat előfeldolgozásához. Az összes segédanyag az űrfelvételekkel megegyező UTM 34N vetületbe lett transzformálva.

Módszertan

Az űrfelvételeken megjelenő felszínborítások a különböző frekvencia tartományokban elkülönülnek egymástól különböző anyagszerkezetük és felülettípusuk miatt (XIAN *et al.* 2009). Spektrális elkülönülésük a szenzoron rögzített spektrum-tartományok kialakításának, radiometriai-térbeli felbontásának és a felvételi körülményeknek a függvénye. Az erdőborítás, mint felszínforma magas lombkorona záródás mellett a falevél anyagával jellemezhető, ami fotoszintetikusán aktív felület. Az erdők jól elkülönülnek a fotoszintetikusán kevésbé aktív felszínborítástól, mint a víz vagy a beépített területek. Más fotoszintetikusán aktív formákkal már enyhe spektrális átfedéseket mutatnak, ahol a klorofil mennyisége, a sejszerkezet és a tárolt víz mennyisége a levélfelülethez hasonló mértékű (XIE *et al.* 2008). A különböző fafajok spektrális jellemzői bizonyos mértékben elkülönülnek egymástól. Az elkülönülést tovább lehet javítani idősorozat alkalmazásával. Ebben az esetben a különböző felszínborítási formák, elsősorban a fotoszintetikusán aktív felületek a vegetációs időszak különböző időpontjaiban, különböző spektrális tulajdonságokkal bírnak. Magasabb térbeli felbontás mellett térbeli jellegzetességek is rögzülnek a képeken (HEROLD *et al.* 2003). Az olyan térbeli képjellemzők, mint az alak és méret faállományok esetén nehezen értelmezhető az S-2 felvételein. A 10 méteres felbontású sávokon az egyes faállományok koronaszerkezeteire utaló árnyék mintázatok jelennek meg. Ez spektrálisan tekintve szórásaként, míg a térben textúráként jelenik meg a faállomány területén belül. A faállomány-típusok térképezése a bemutatott spektrális, spektrális-időbeli és textúra jellemzők alapján végezhető el hatékonyan (1. ábra). A távérzékelés első alkalmazásai a spektrális elkülönülést alkalmazták faállomány-típusok térképezésére (BRYANT *et al.* 1980). Több tanulmány alkalmazta már a spektrális-időbeli jellemzőket faállomány-típus térképezésre, és egyértelműen a több időpontú vizsgálat módszerét mutatták hatékonyabbnak (PASQUARELLA *et al.* 2018). A térbeli képjellemzők közül a textúra jellemzők alkalmazására is voltak már példák űrfelvételek esetén, melyek a használata mellett szólnak (MOSKAL - JAKUBAUSKAS 2001).

A faállomány-típusok kiértékeléséhez konzisztens idősorozatra van szükség, ahol minden egyes időpontban teljesen felhőmentesek a felvételek és radiometriájuk kiegyenlített. Ennek megfelelően a felvételeken először az atmoszférikus korrekciót hajtották végre a SEN2COR 2.5.5 szoftver (MAIN-KNORN *et al.* 2017) segítségével, melynek során felszínen mérhető értékekké lett transzformálva az atmoszféra tetején mért reflektancia. A korrekció során felhőmaszkok is készültek a felvételre. Ez alapján csak azok a felvételek kerültek további feldolgozásra, ahol 10%-nál alacsonyabb volt az erdőrészt poligonok feletti felhő- és felhőárnyék borítás. Az egy időpont alapján készült felhőmaszkok a vékony felhőrétegeket és a párat nem tudják nagy pontossággal kimutatni, mivel ezeknek magas az átlátszósága (HAGOLLE *et al.* 2015). Egy idősorozat-alapú felhő és felhőárnyék maszkoló módszert fejlesztettünk, amely egy felhőmentes referencia kép alapján a Kálmán-szűrő (MEINHOLD - SINGPURWALLA 1983) segítségével hatékonyabban ki tudta mutatni a vastag és vékony felhőrétegeket, valamint a felhők által vetített árnyékokat. Lineáris regresszió segítségével a vizsgált időpontban hiányzó reflektancia érték korábbi értéke alapján modelleztük az aktuális reflektanciát a felhők okozta adathiányos területeken. A változatos domborzat miatt még magas napállás mellett is nagymértékű a topográfiai, valamint a vetített árnyékok megjelenése. Az empirikus forgatás módszerét (TAN *et al.* 2013) alkalmaztuk a topográfiai normalizációnál. A konzisztens idősorozatot homogén részekre bontottuk képszegmentálással

(CZIMBER 2009). Ennek elsődleges célja a térbeli képjellemzők kivonásához szükséges területek létrehozása. Másodlagos célja az idősorozatban szereplő felvételek geometriai hibáinak kiküszöbölése, ami az alkalmazott térbeli felbontás mellett maximum 1 pixel. A szegmentálásnál alkalmazott küszöbértékhez 10, az alakparaméterhez 0,9 értéket választottunk.



1. ábra: Az űrfelvétel idősorozat spektrális (A), spektrális-időbeli (B) jellemzői és a kivont textúra (C) a Magas kőrös (*Fraxinus excelsior*) és Bükk (*Fagus sylvatica*) példájával.

Az űrfelvétel idősorozatban megjelenő spektrális és térbeli képjellemzők mintázatokat alkotnak, amelyek ismétlődnek. Ezek a mintázatok a magas dimenziószám és a nem túl határozott térbeli képjellemzők miatt vizuálisan nehezen interpretálhatók, ezért a gépi tanulási módszerek alkalmazása hatékonyabb. Az erdőborítás térképezés és az ezen belüli faállomány-típusok térképezés Deep learning típusú osztályozó módszerrel történt. A Deep learning olyan gépi tanulási módszerek összefoglaló neve, melyek mély mesterséges neurális hálózatok segítségével oldanak meg osztályozási vagy regressziós problémákat (ZHU *et al.* 2017). Jellemzően adat vezérelt, felügyelt típusú osztályozók készítésére alkalmazzák nagyon széles körben. A távérzékelésben 2014 óta alkalmaznak ilyen technológiát a felvételek kiértékelésére. A nagyon mély neurális hálózatok előnye a hagyományos osztályozó módszerekkel szemben, hogy nincs szükség a képjellemzők mesterséges kiemelésére és a nem releváns információt tartalmazó jellemzők eltávolítására az osztályozó modell tanítása előtt. A modellben a bemenő képjellemzők a bemeneti rétegbe csatlakoznak, amit rejtett neuron rétegek követnek, majd egy kimeneti réteg, ahol minden rétegben, minden egyes neuron össze van kötve egymással. A tanítás során ezeknek a kapcsolatoknak az erősségét állítja be a modell a betáplált tanító adatok alapján iteratíván egy optimalizáló funkció segítségével, visszacsatolásokon keresztül. A képfeldolgozásban az egyik leggyakrabban alkalmazott hálózat típus a konvolúciós neurális hálózat (CNN). A CNN esetén a bemeneti rétegbe képcempéket kell táplálni, amelyből konvolúciós szűrők segítségével vonja ki hierarchikusan a térbeli információkat a hálózat rétegeiben, amely a jelenlegi alkalmazása esetén a képtextúrára korlátozódik. A kivont térbeli jellemzőkön keresztül a spektrális információk is számításba kerülnek a kapcsolatok erősségének kialakításánál. A hálózat végén, a koncentrált információkat leggyakrabban softmax függvényvel osztályozzák a kimeneti rétegben. Jellemzően nagyon nagy felbontású távérzékelte felvételeken alkalmazzák objektum detektálásra, azonban nagyfelbontású űrfelvétel idősorozatokon felszínborítási kategóriák térképezésére is vannak példák (SHUNPING *et al.* 2018).

A faállomány-típusok kiértékeléséhez szükség van egy pontos faállomány borítás térképre. Az erdőrészlet poligonok erre a célra nem alkalmasak, ugyanis található erdőtervvel nem rendelkező faállományok és alacsony korona záródású területek a poligonokon belül. Ennek a térképezésére *transfer learning* módszert alkalmaztunk, ahol a CNN hálózat bizonyos kategóriákra előre meg van tanítva. A hálózat kimeneti osztályozó rétege után kerül

egy további réteg, ami a már meglévő osztályok paramétereit módosítja az új tanító anyagnak megfelelően. A faállomány borítás térképezéshez az INCEPTION V3 modellt (SZEGEDY *et al.* 2016) tanítottuk újra. Erdő és nem erdő kategóriák lettek létrehozva a tanító anyagban. Az újra tanítás 150 000 iterációval történt meg. A szabálytalan alakú, homogén képrészek a hálózat bementi rétegének megfelelően 299x299 pixel méretűre lettek skálázva. A szabálytalan alak körüli terület a homogén képrész spektrális átlagaival lett feltöltve a sávokban. Az INCEPTION V3 modell 3 sávos képeket képes feldolgozni, így az idősorozat magasabb dimenziószámát csökkenteni kellett. Az idősorozat 3 eltérő időpontjából választott látható kék tartományban rögzített sáv kompozitját használtuk fel erre a célra. Ennek oka, hogy az erdő felszínborítás ebben a spektrum-tartományban nem mutat különösebb változást a vegetációs időszak alatt, más fotoszintetikusan aktív felületekhez képest.

A faállomány-típusok osztályozása is egy CNN modell segítségével történt, ami ebben az esetben egyedi felépítéssel rendelkezett. A hálózat 8 neuron rétegből áll, ahol az első 5 rétegben történik meg a térbeli jellemzők kivonása konvolúciós szűrőkkel, amit további 3 teljesen összekapcsolt neuron réteg követ. Minden egyes réteget egy *batch normalization* (IOFFE - SZEGEDY 2015) funkció követ, ami a modell túlillesztését segít elkerülni. A hálózat regularizálása L2 funkcióval történt. A tanítás optimalizálásához az *Adaptive Moment Estimation* (ADAM) (KINGMA - BA, 2014) módszert alkalmaztuk. A hálózat bemenete 6x6 pixel méretű, 80 sávos képcempék voltak. A szabálytalan alakú homogén képrészek a 6x6 pixel méretre lettek újra minta vételezve. A ki nem töltött részekre véletlenszerűen választott É-D irányú mintákat illesztettünk be. A modell tanítása 943 836 iteráción keresztül tartott. Az osztályozáshoz kialakított faállomány-típus csoportok: akác, bükk, fenyők, magas kőris, gyertyán, tölgyek, hársak, virágos kőris, cser, mézgás éger, vöröstölgy, mezei juhar, valamint az egyéb kategória. Az egyéb kategória azoknak a képrészeknek szánt gyűjtő osztály, melyek az erdőborítás osztályozás során hibásan faállománynak lettek megjelölve. Az egyes kategóriákba több hasonló fafajt vontunk össze alacsony területfoglalásuk miatt.

A CNN modellek tanításához tanító adatra van szükség, ami tartalmazza a kialakított osztályok jellemzőit. Ha a tanító adatok tartalmaznak minden mintázatot és jellegzetességet, ami az adott kategóriában megjelenik és a kijelölt kategóriák nem fednek át túlságosan egymással spektrálisan, akkor tökéletes lesz az osztályozó modell és az elkészített térkép. A tanító anyaghoz alkalmazott tanító területek pontos kijelölése, különösen természetes környezetben, nehezen kivitelezhető. Az egyes faállomány-típusok terület foglalása nem egyenlő, így a belőlük vehető minták eloszlása sem. Ezt mesterséges adatkiterjesztéssel lehet kiküszöbölni: a minta spektrális átlaga körül normál eloszlást hozunk létre, majd ezekből az értékekből véletlenszerűen választottuk ki az új mintaátlagot. Az új mintaátlag alapján történt meg az eredeti minta módosítása, és ezt a kellő mértékben megismételve kiegyenlített mintaszámot kaptunk az egyes osztályokban.

Az erdőborítás térképezéshez nagyfelbontású légi felvételeket alkalmaztunk a tanítóterületek kijelölésénél. A faállomány-típus minták kijelölése az OEA és terepi bejárások alapján történt. Az űrfelvétel idősorozatból összeállított időkompozit vizuális támaszt adott a tanítóterületek elhelyezéséhez. A tanítóterületek kijelölésének feltétele volt, hogy legalább 6×6 pixel² méretű (60×60 m²) kiterjedése legyen és már záródott lombkoronával rendelkezzenek. Az alkalmazott softmax osztályozó a CNN modellekben rugalmas osztályozásra képes, így lehetőség lenne a típusok keveredésének kimutatására, amiből az elegyarányra lehetne következtetni. A terület méretéhez viszonyított kevés számú tanító adat miatt a modell túlillesztésének magas a kockázata, így az elegyarány becslés ezzel a módszerrel nem végezhető el megbízhatóan.

A CNN modellek pontossági vizsgálata hibamátrixok segítségével történt meg. A faállomány borítás térkép vizsgálatához 5022 pontot jelöltünk ki szabályos hálózatban 438 méteres rácstávolsággal. A referencia pontok típusának meghatározása nagyon nagy felbontású

űrfelvételek és ortofotó alapján történt meg. A faállomány-típusok modelljéhez szabálytalan hálózatban lettek ellenőrző pontok kijelölve. Itt az egyes pontokban körlap szerinti elegyarány lett számolva a felső koronaszintben elhelyezkedő faegyedekből. Ezen kívül az OEA alapján választottunk ki a tanító területektől független helyeken 100%-os elegyarányú erdő-részleteket. Összesen 1415 homogén képrészletet ellenőriztünk az így gyűjtött referencia adatok alapján.

Az űrfelvételek előfeldolgozása és osztályozása a KIFÜ NIIF programjának keretében Miskolcra és Debrecenbe telepített szuperszámítógépeken történt. A Deep learning modell tanítása a TENSORFLOW 1.4 keretrendszerben (ABADI *et al.* 2016) készült.

Eredmények


Összesen 73 darab űrfelvétel került beszerzésre. Az előfeldolgozás után 8 darab felvételt értékeltünk ki, ami megfelelt a szigorú felhőborítás kritériumoknak. Az éves átlagos felhőborítás alapján várt 30%-os felhasználhatóság csupán 11% lett 2017-ben. A kiértékelt felvételek időbeli eloszlása nem egyenletes, a nyár közepén csoportosulnak.

A faállomány borítás térképezéshez összesen 4217 erdő, 2553 nem erdő tanítóterület lett kijelölve. Az osztályozás eredményeként a terület 46,6%-át faállományok borítják, míg 53,4%-át egyéb felszínborítás típus. A térképezés pontosságának meghatározásához kijelölt ellenőrző pontokon az összesített pontosság 95,4% ($\kappa = 0,908$) (1. táblázat).

1. táblázat: A faállomány borítás térképezés pontossági vizsgálatának eredménye

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

A faállomány-típusok osztályozásához összesen 1148 tanítóterületet jelöltünk ki. A tanított modell pontossága az ellenőrzés során 88,2% ($\kappa=0.866$) pontosságot ért el (2. ábra). A modellek alapján készült térkép (3. ábra) vizuálisan is elfogadható eredményt adott, a faállomány-típusok a jellemző domborzati és klíma viszonyoknak megfelelően jelentek meg.

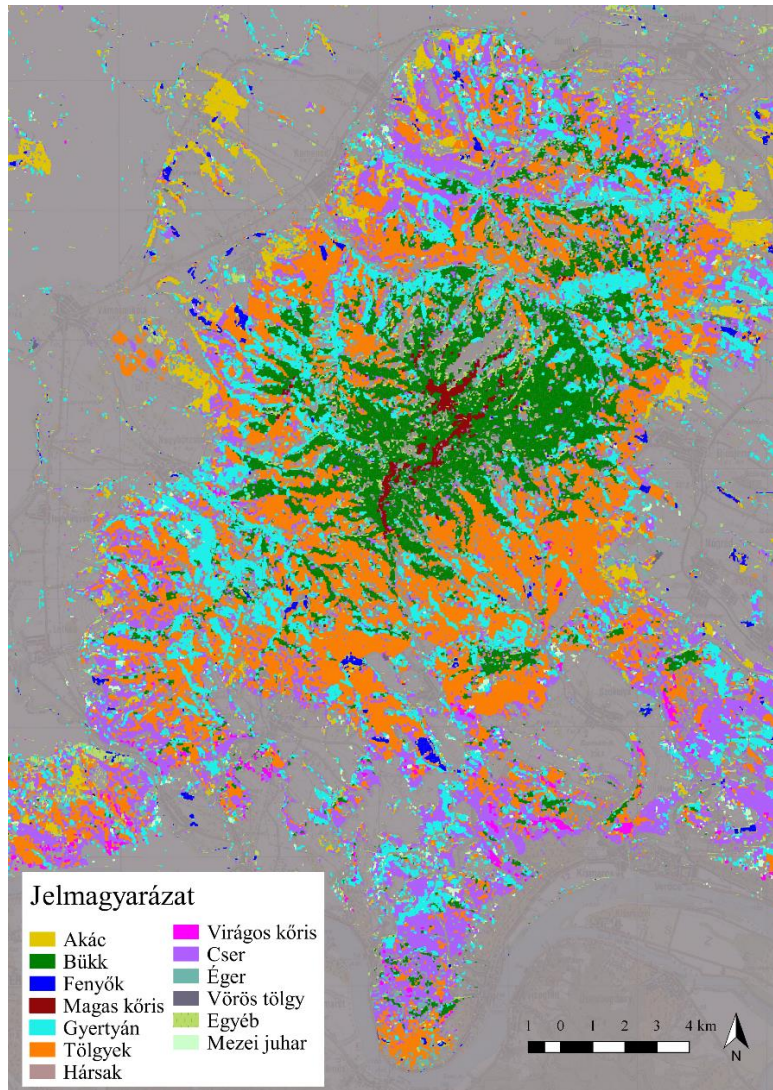


2. ábra: A Faállomány-típus térkép pontossági vizsgálatához készült hibamátrix a bevonási pontosság mértéke alapján színezve (A) és az egyes osztályoknál elért pontosságok (B)

Összefoglalás

A Deep learning alkalmazása a távérzékelésben olyan mértékű javulást hozott a térképek pontosságában (KUSSUL *et al.* 2017), ami mindenképpen a további alkalmazása mellett szól. Általánosságban igaz erre a technológiára, hogy kevesebb szakértői munkát igényel az osztályozó modell felépítése, mint a korábban használt gépi tanulási módszereknél. Ez úgy értelmezhető, hogy azonos befektetett munkával jobb eredmények, pontosabb térképek hozhatók létre mint korábban. A modellek tanítása nagyon számításigényes feladat, aminek végrehajtása csak elosztott rendszereken hatékony. A létrehozott térképek erdő-részlet szint alatt

szolgáltatnak információkat, de az alkalmazott technológia miatt nem lehetséges az űrfelvételek eredeti felbontását megtartani. Ennek előnye, hogy viszonylag alacsony koronazáródású területeken (lékek környezete, erőteljes bontások) is képes meghatározni a faállomány-típusát, hátránya az alacsonyabb geometriai pontosság.



3. ábra: A 2017-es állapotot mutató faállomány-típus térkép

Az évente elkészíthető térképek a faállományok típusáról és kiterjedéséről olyan információkat adnak át, melyek korábban csak lokális szinten voltak ismertek hasonló felbontásban. A magasabb szinteken is elérhető faállomány-típus térképek segítségével az állományok pontosabb szabályozása tervezhető meg, melyek előrehaladása évről évre ellenőrizhető, és a friss információk alapján módosítható lenne.

Köszönetnyilvánítás: A kutatás az ÚNKP-18-3-IV kódszámú pályázat támogatásával készült. Köszönetet mondunk a KIFÜ NIIF Programjának a HPC szolgáltatásáért, a Precision Forestry Cooperative-nek (PFC) és az Ipoly Erdő Zrt-nek a kutatásban nyújtott segítségért.

Irodalomjegyzék

ABADI, M. - BARHAM, P. - CHEN, J. - CHEN, Z. - DAVIS, A.-DEAN, J. - ... - KUDLUR, M. (2016): Tensorflow: a system for large-scale machine learning. Savannah, GA, USA, USENIX, pp. 265-283.

- BARTON I. – KIRÁLY G. – CZIMBER K. (2018): Sentinel-2A úrfelvétel-idősorozat sűrűség vizsgálata az országos erdőállományra. Kari Tudományos Konferencia, Sopron, pp. 123-127.
- BRYANT, E. – DODGE, J. – ARTHUR, G. – WARREN, S. D. (1980): Landsat for practical forest type mapping: a test case. *Photogrammetric Engineering and Remote Sensing*, 46(12), pp. 1575-1584.
- CZIMBER K. (2009): Új, általános célú képosztályozó kifejlesztése nagyfelbontású, textúrával rendelkező digitális képek feldolgozására, *Geomatikai Közlemények*, Vol XII: pp. 249–258.
- DRUSCH, M. – DEL BELLO, U. – CARLIER, S. – COLIN, O. – FERNANDEZ, V. – GASCON, F. – ... – MEYGRET, A. (2012): Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote sensing of Environment*, Vol. 120: pp. 25-36.
- HAGOLLE, O. – HUC, M. – VILLA PASCUAL, D. – DEDIEU, G. (2015): A multi-temporal and multi-spectral method to estimate aerosol optical thickness over land, for the atmospheric correction of FormoSat-2, LandSat, VENUS and Sentinel-2 images. *Remote Sensing*, Vol. 7(3): pp. 2668-2691.
- HEROLD, M. – LIU, X. – CLARKE, K. C. (2003): Spatial metrics and image texture for mapping urban land use. *Photogrammetric Engineering & Remote Sensing*, Vol. 69(9): pp. 991-1001.
- IOFFE, S. – SZEGEDY, C. (2015): Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*.
- KINGMA, D. P. – BA, J. (2014): Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, pp. 1-15.
- KUSSUL, N. – LAVRENIUK, M. – SKAKUN, S. – SHELESTOV, A. (2017): Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, Vol. 14(5): pp. 778-782.
- MAIN-KNORN, M. – PFLUG, B. – LOUIS, J. – DEBAECKER, V. – MÜLLER-WILM, U. – GASCON, F. (2017): Sen2Cor for Sentinel-2. Warsaw, Poland, Society of Photo-Optical Instrumentation Engineers (SPIE), pp. 10427-10427.
- MEINHOLD, R. J. – SINGPURWALLA, N. D. (1983): Understanding the Kalman filter. *The American Statistician*, Vol: 37(2): pp. 123-127.
- MOSKAL, L.M. – JAKUBAUSKAS, M. E. (2001): Discriminating forest stand age classes using 2nd order image texture in the Central Plateau of Yellowstone National Park. Denver, CO, p. 9p.
- PASQUARELLA, V. J. – HOLDEN, C. E. – WOODCOCK, C. E. (2018): Improved mapping of forest type using spectral-temporal Landsat features. *Remote Sensing of Environment*, Vol. 210: pp. 193-207.
- SHUNPING, J. – ZHANG, C. – XU, A. – SHI, Y. – DUAN, Y. (2018): 3D convolutional neural networks for crop classification with multi-temporal remote sensing images. *Remote Sensing*, Vol: 10(1): p. 75.
- SZEGEDY, C. – VANHOUCHE, V. – IOFFE, S. – SHLENS, J. – WOJNA, Z. (2016): Rethinking the inception architecture for computer vision., *IEEE*, pp. 2818-2826.
- TAN, B. – MASEK, J. G. – WOLFE, R. – GAO, F. – HUANG, C. – VERMOTE, E. F. – ... – EDERER, G. (2013): Improved forest change detection with terrain illumination corrected Landsat images. *Remote Sensing of Environment*, Vol: 136: pp. 469-483.
- WILSON, A. M. – JETZ, W. (2016): Remotely sensed high-resolution global cloud dynamics for predicting ecosystem and biodiversity distributions. *PLoS biology*, Vol: 14(3), p. e1002415.
- XIAN, G. – HOMER, C. – FRY, J. (2009): Updating the 2001 National Land Cover Database land cover classification to 2006 by using Landsat imagery change detection methods. *Remote Sensing of Environment*, Vol: 113: pp. 1133–1147.
- XIE, Y. – SHA, Z. – YU, M. (2008): Remote sensing imagery in vegetation mapping: a review. *Journal of plant ecology*, Vol: 1(1): pp. 9-23.
- ZHU, X. X. – TUIA, D. – MOU, L. – XIA, G. S. – ZHANG, L. – XU, F. – FRAUNDORFER, F. (2017): Deep learning in remote sensing: a review. *IEEE Geoscience and remote sensing magazine*, pp. 8-36.