

Városi felszínborítás osztályozásának lehetőségei idősoros DESIS és PlanetScope műholdfelvételek fúziójából

SÓTI Márkó¹, MUCSI László¹

¹Szegedi Tudományegyetem, Léggör- és Téradata tudomány Tanszék

E-mail: sotimarko18@gmail.com

[DOI: 10.30921/GK.77.2025.1.2](https://doi.org/10.30921/GK.77.2025.1.2)

Absztrakt

A hiperspektrális távérzékelte adatok használata több új felszínborítás meghatározását teszi lehetővé városi környezetben, mint az általánosan elérhető multispektrális műholdfelvételek. A hiperspektrális műholdfelvételek hátránya a multispektrálissal szemben, hogy egyelőre jelentősen alacsonyabb térbeli felbontással rendelkeznek. A tanulmányban multispektrális PlanetScope és hiperspektrális DESIS műholdfelvételekből készült nagyfelbontású fúziós adattal különböző városi felszíneket határoztunk meg, Random Forest gépi tanulási módszerrel. Az adatokat egy budapesti mintaterületen, négy különböző időpontra készítettük el: 2022. június 24., augusztus 18., október 10., illetve 2023. február 15. A fő felszínborítási csoportok - mesterséges felület, növényzet és talaj - osztályozásával közel 90%-os összpontosságot értünk el. Továbbá az alcsoportokat is sikeresen, elfogadható pontossággal szétválasztottuk: fém, beton, aszfalt, cseréptető és lapostető felületekre. Az osztályozást külső vektoros adatforrás bevonásával, az OpenStreetMap épületpoligonjaival tovább javítottuk. Az idősoros osztályozott eredményekből meghatároztuk a mintaterület állandó és változó pixeleit a vizsgált időintervallumra.

Abstract

The use of hyperspectral remote sensing data allows for the identification of more detailed land cover types in urban environments than commonly available multispectral satellite imagery. A limitation of hyperspectral satellite imagery, compared to multispectral, is its currently lower spatial resolution. This study combines high-resolution fused data from multispectral PlanetScope and hyperspectral DESIS satellite imagery to identify diverse urban surfaces using Random Forest machine learning classifier. The data were prepared for a sample area in Budapest, captured at four different date: June 24, August 18, and October 10 of 2022, and February 15, 2023. Classification of main land cover groups—impervious surface, vegetation, and soil—achieved nearly 90% overall accuracy. Additionally, we successfully differentiated subcategories with acceptable accuracy, such as metal, concrete, asphalt, clay roof tiles, and flat roofs. The classification accuracy was further improved by incorporating external vector data, specifically OpenStreetMap building polygons. From the classified time-series data, we identified permanent and variable pixels within the sample area for the study period.

Kulcsszavak: PlanetScope, DESIS, pan-sharpening, osztályozás, városi felszínborítás

Keywords: PlanetScope, DESIS, pan-sharpening, classification, urban landcover

1. Bevezetés

2020-ban az ENSZ felmérései alapján a Föld lakóinak (7,8 md fő) több mint fele városi lakó volt, és becslései alapján 2070-re a városi lakók aránya 58%-ra fog emelkedni (United Nations Human Settlements Programme, 2022). Hazánkban a KSH 2024-es adatai szerint a városi lakók aránya 70,22%. A városi területek a Föld felszínének egy kis töredékét teszik ki, viszont


nagyban képesek befolyásolni a környezetük átalakulását és a lakosság életszínvonalát. Műhold alapú távérzékelés eszközeivel lehetőség nyílik nyomon követni a városi felszínborítás és a területhasználat változását. A városi felszínek spektrális és geometriai tulajdonságai jelentős kihatással bírnak a városok hőmérsékletére, ezért a városstervezés szempontjából szükséges ezen tényezők pontos ismerete. A városi felszínt a mesterséges és természetes anyagok változatosan építik fel. A mesterséges

felületek, mint pl. az épületek és útburkolat befolyásolják a mikroklimát, illetve akadályt képeznek a víz és csapadék természetes körforgásában. (Hayes és Sader 2001, Hargitai et al. 2006, Feranec et al. 2007, Afify 2011, Tobak et al. 2012, Ilsever & Ünsalan 2012, Falco et al. 2013, Hegazy és Kaloop 2015, Jenerowicz et al. 2019.)

Már számos kutatás készült a városi felszínborítás vizsgálatára, amely az 1980-as években terjedt el a Landsat program közepes felbontású műholdfelvételeivel, mikor a mesterséges felület, vegetáció és talajfelszín megkülönböztetésével kísérleteztek (Townshend et al. 1991). A városfelszín vizsgálat tanulmányokban egyre gyakoribb a képi elemek más adatforrással való kiegészítése, ilyenek például a digitális felszínmodellek (Al-Najjar et al. 2019). A városi felszínborítás vizsgálata hiperspektrális adatok használatával új lehetőségeket biztosít, akár az egyes alkategóriák megfelelő pontosságú szétválasztását is. Magyarországra már sikeresen alkalmaztak hiperspektrális felvételt városi területre. Az első tanulmány DAIS légi hiperspektrális adatokat használt fel Gyöngyös városi és elővárosi területének felszínborítás meghatározására, városökológia vizsgálathoz (Jung et al. 2005). A légi HS felvételezéssel szemben a hiperspektrális műholdfelvételek bár nagy spektrális felbontásúak és nagy területet fednek le (pl. 30*30 km²), önmagukban nem alkalmazhatók városi léptékben különböző mesterséges felületek osztályozására, mivel a térbeli felbontásuk túl kicsi (30 m). A pansharpening alkalmazásával, vagyis nagyfelbontású (3-5 m) multispektrális adattal való feljavítással már elérhető a megfelelő térbeli felbontás. A tanulmányban a multispektrális, 3 méteres PlanetScope felvételeit kombináltuk a hiperspektrális DESIS felvételekkel egy budapesti mintaterületen, amely adatok már alkalmazhatók a városi felszín részletes vizsgálatára. A kutatás fő célja, hogy egy olyan városi felszínfedettség osztályozási módszertant dolgozzunk ki a hiperspektrális adatok és gépi tanulási módszerek felhasználásával, mellyel később egész Budapest, illetve más magyarországi és európai városokra is alkalmazható legyen. A hiperspektrális adatok osztályozását a Random Forest gépi tanulási módszer segítségével végeztük, amely már más magyarországi DESIS adathoz kapcsolódó kutatásban kiemelkedő pontosságú eredményt ért el (Farmonov et al. 2023).

2. Mintaterület

A közel 25 km² nagyságú mintaterület Budapesten helyezkedik el, a IX., XI. és XXI. kerületekben (1. ábra). A mintaterület kiválasztásának fő szempontja, hogy a lehető legtöbb féle városi felszínborítás megjelenjen egy kisebb kivágaton, a sűrű belvárosi lakóépületektől kezdve (Ferencváros) a kis sűrűségű fás lakóövezetig (Erzsébetváros), illetve ipari övezetek és zöldterületek is szerepeljenek a mintában. A választott területen számos nagyterjedésű mesterséges felület is megtalálható, amely megfelelő, homogén pixeleket tartalmaz a szélsőpontok kijelöléséhez, mint például a Groupama aréna és az MVM Dome fémtetője.



1. ábra A budapesti mintaterület elhelyezkedése a 2022. június 22-i PlanetScope-DESIS fúzió felvételén (R:821 nm, G:665 nm, B:561 nm)

3. Adatok

A vizsgálat alapját a PlanetScope és a DESIS műholdfelvételek, illetve az abból pansharpening-el készült fúziós adatok szolgáltatták. A PlanetScope műholdkonstelláció több mint 200 cubesat egységből áll, melyek napi szintű adatot szolgáltatnak. A tanulmányban felhasznált PlanetScope multispektrális adatok térbeli felbontása 3 méter, a spektrális felbontása 431 nm – 885 nm-ig terjed, 8 sávban (Dos Reis et al. 2020, Sadeh et al. 2021, Jin et al. 2021, Planet Team 2024). A cikkben felhasznált PlanetScope adatok Farmonov et al. (2023) kutatási projektjéből származnak. A DESIS hiperspektrális szenzor a Német Repülési Központ (DLR) és a Teledyne Brown Engineering vállalat közös fejlesztése, mely 2018 óta üzemel. A szenzor a Nemzetközi Űrállomás MUSES platformján helyezkedik el, ahol 2 havonta ismétlődően 7-10 napos időablakokban készít nadír felvételeket magyarországi városokról. A felvételek kutatási céllal igényelhetők. A szenzor 235 sávban felvételez 400 – 1000 nm tartományban, 2,55 nm sáv szélességgel. A térbeli felbontása 30 méter. (Peschel et al. 2018, Heiden et al. 2019, Krutz et al. 2019.) A tanulmányban felhasznált DESIS adatok Mucsi László kutatási projektjéből származnak. A raszteres adatok 2022. június 22, 2022. augusztus 18, 2022. október 10 és 2023. február 15 időpontokban készültek. A letöltött és felhasznált adatok atmoszféricusan korrigált L2A adatok. A tanulmányban emellett OpenStreetMap vektoros épület réteget használtunk fel.

4. Módszerek

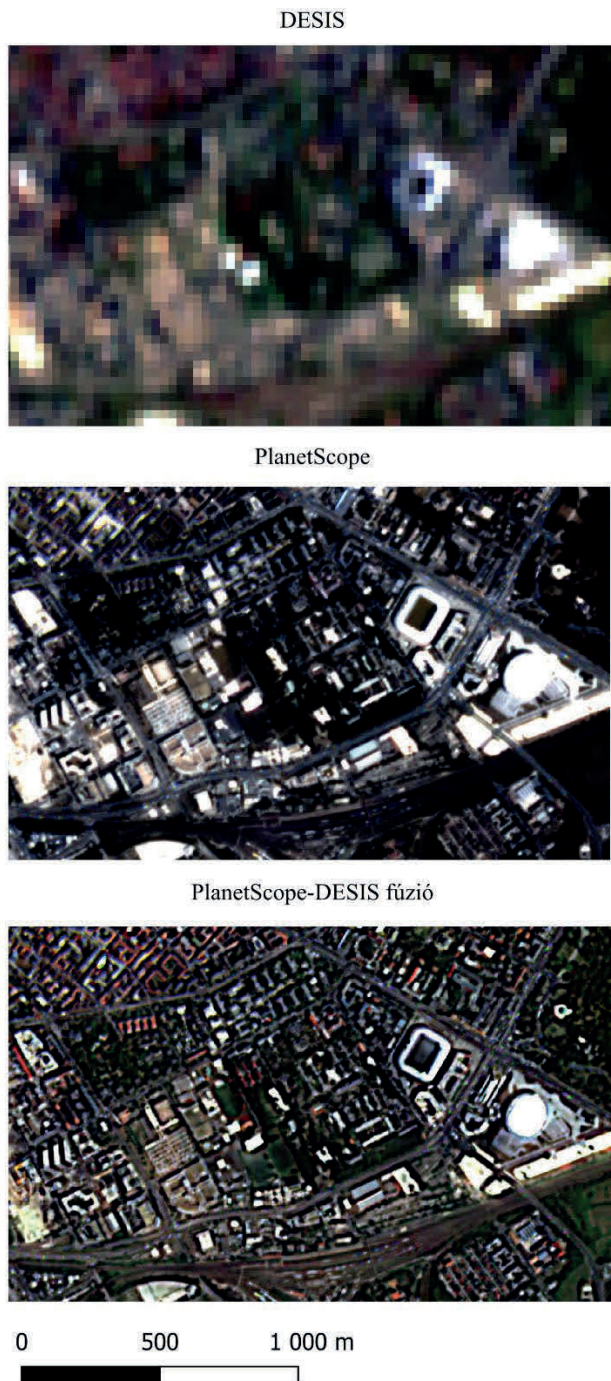
Az adatok feldolgozása az ERDAS Imagine 2020 és a QGIS program EnMap-Box bővítményével készült. Az EnMap-Box egy ingyenesen elérhető, főleg hiperspektrális adatok feldolgozására készített bővítmény, amely a DESIS adatokra is

kalibrálva van. Az egyes időpontokra készült csempéket mozaikolással egyesítettük. A feldolgozás során a felvételek maximalizált pixelértéke (10000) megfelel az 1 (vagy 100%) BoA reflektancia értéknek, mellyel kiszűrhetők a nem valós reflektancia értékű felszínek. Az ilyen kiugró értékek származhatnak például becsillanó fémfelületekről.

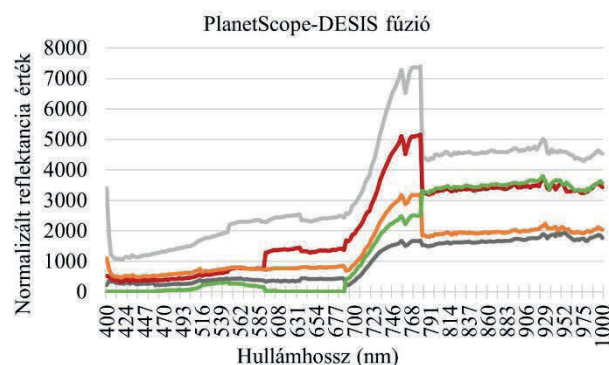


Az azonos időpontokban készített és közel megegyező spektrumtartományban felvételezett PlanetScope és DESIS műholdképek lehetővé tették a pansharpening használatát, vagyis a hiperspektrális felvételek feljavítását a nagyfelbontású

multispektrális adatokkal. A pansharpeningnek (HPF Resolution Merge) köszönhetően a fúziós adatok megkapták a PlanetScope 3 méteres térbeli felbontását, megtartva a DESIS 235 sávós, részletes spektrumadatait, ami lehetővé teszi a felszínborítási vizsgálatot sűrűn beépített városi környezetben is. A pansharpening jelentős, tízszeres felbontásjavítást eredményezett, százszoros adatmennyiség növekedés mellett (2. ábra).


A pansharpening velejárója a spektrális adatorzulás is, amely abban jelentkezik, hogy a fúziós felvétel pixeleiben olyan felületek jellegzetessége is megfigyelhető a spektrumgörbén, amely a pixelben lévő felszíncsoportra nem jellemző (3. ábra).



2. ábra Kivágat a DESIS, PlanetScope és a fúziós műholdfelvételtől



3. ábra A PlanetScope és a fúziós műholdfelvételtől készített egyes felszínminták spektrumai, illetve a mintavételezési pontjai



4. ábra. Egy nem homogén, de magas fémfelület arányú DESIS pixel spektrális tulajdonságai a különböző időpontban

Erre példa a fém spektrumgörbén jelentkező, klorofila jellemző vörös-él tartományban lévő megugrás, mivel az eredeti 30 méteres felbontású DESIS pixel tartalmazott vegetációt is. Emellett más felületek jelenléte is nagy kihatással van a nem homogén DESIS pixelek spektrumadataira, melyek aránya évszakosan változik, ezért az ugyanabból a pontból vett spektrumadatok is meglehetősen változékonyak a különböző időpontokban (4. ábra).

A mintaterület, főként a sűrű belvárosi részen árnyékkal terhelt. Mivel az árnyék és a vízfelület reflektanciája hasonlóan alacsony, számos tanulmányban a víz és árnyék egy osztályként szerepel. Jelen esetben a vízfelületet nem osztályoztuk, ezért a megfelelő szétválaszthatóság miatt vízmaszk alkalmazása volt szükséges. A vízmaszkot az ERDAS területnövelő eljárással határoztuk meg.

Az osztályozás betanítása szélsőpontok alapján történt. A szélsőpont olyan homogén pixel, amely teljes egészében az adott felszínborítási típust tartalmazza. Az osztályozás során négy főcsoportot különböztettünk meg: mesterséges felületet, növényzetet, talajfelszínt és árnyékot. A főcsoportokon belül további alcsoportokat is meghatároztunk, például a mesterséges felületen belül a fém, beton, aszfalt, cseréptető és lapostető (panelházak teteje). A növényzeten belül megkülönböztetendő az alacsony vegetáció (fű, gyepek) és a lombos fa, továbbá a téli időszakban a száraz vegetáció. A szélsőpontokat külön az egyes felvételek időpontjaira, a műholdfelvételek beazonosított, homogén pixeleiről gyűjtöttük ki. A spektrumkönyvtár alcsoportok szerint készítettük el, az egyes alcsoportokra 5-10 mintavételezést végeztünk. A mintavételezések száma aszerint változott, hogy a mintaterületen mennyire eltérők az alcsoporton belüli felszínek spektrumai. Például a cseréptető borítás spektrumgörbéi nagyobb eltérést mutattak, így abból 10 db mintavételre volt szükség. Ezzel szemben a fémborítások között nem volt jelentős eltérés, ezért 5 db minta is elegendő volt. Az egyes alcsoportokra gyűjtött spektrumminták átlagából készült el az osztályozások során alkalmazott szélsőpont. A spektrumkönyvtár tartalmazza a mintavételek fő és alcsoport szerinti azonosítóját, illetve a mintavételezések helyének x és y koordinátáit.

Az osztályozás főcsoport és alcsoport szerint is elkészült a PlanetScope és a fúziós műholdfelvételekre is, mind a négy vizsgált időpontra. Az osztályozás a Random Forest (RF) gépi tanulási módszerrel készült. Az RF paraméterezése 100 fa. Az osztályozás javításához OpenStreetMap (OSM) épület adatokat vontunk be. Ezt három módon vizsgáltuk:

Az 1. módszer: vektoros adatoktól függetlenül futott az osztályozás, így az épületpoligonok nem befolyásolták az eredményt.

A 2. módszer: az épület poligonokba tartozó pixelek kizárólag fém, cseréptető, lapostető, illetve árnyék osztályba tartozhatnak. A módszer előnye, hogy az épületpoligonok pixelei nem tartozhatnak például aszfalt és beton csoportba, illetve más főcsoportba, ezzel kizárva, hogy a lapostető borítása aszfaltként szerepeljen az eredményekben.

A 3. módszer: esetén ugyan ez a szabály vonatkozik az épületpoligonon belüli pixelekre, viszont ezek a csoportok nem szerepelhetnek a poligonon kívül. A módszer az előzővel szemben nem engedi meg, hogy például a valójában aszfalt pixelek hibásan lapostetőként szerepelhessenek.

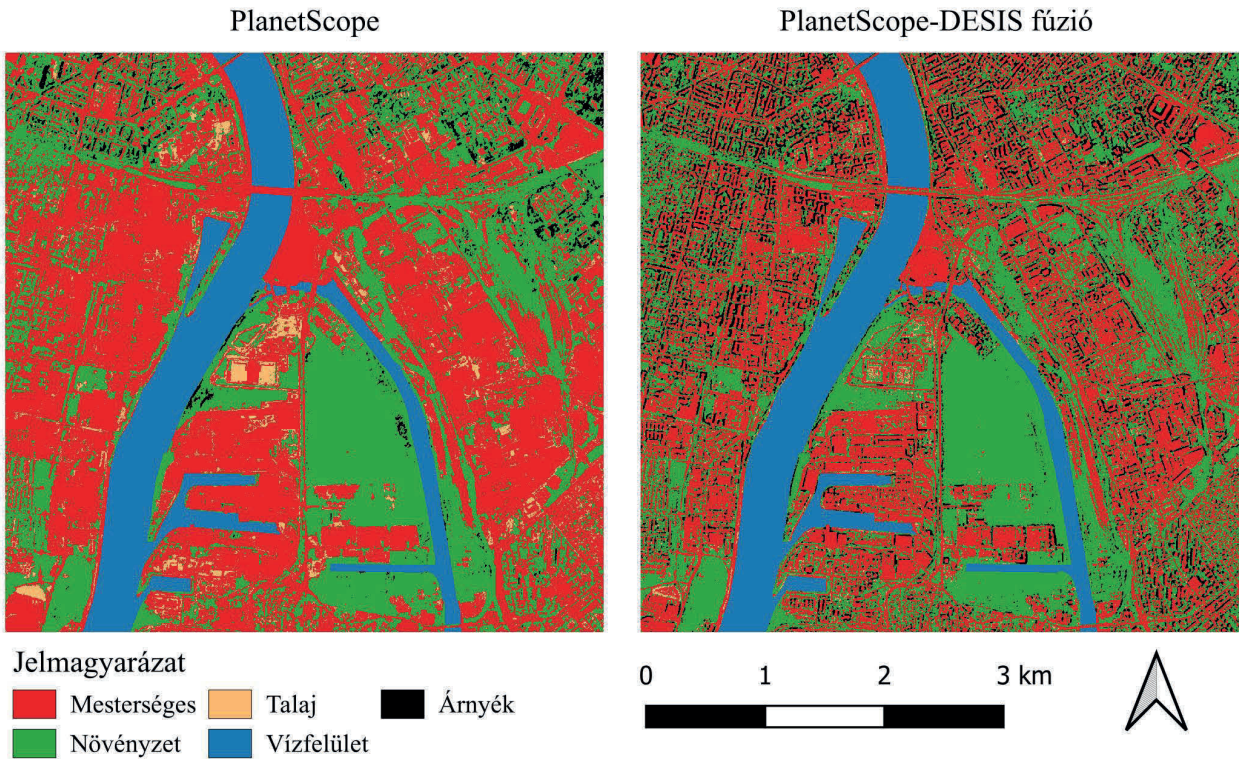
A 2. és 3. módszer alkalmazása főként arra irányult, hogy az aszfalt-cseréptető-lapostető alcsoportok keveredését csökkentjük az osztályozott eredményen, amely jelentős pontosságbeli problémát okozott. Az OSM épületpoligonok bevonása akár hibát is eredményezhet, mivel az adatbázisban szereplő poligonok nem feltétlenül a vizsgált időpontban létező valós épületet határoznak, lehet azóta elbontott vagy megváltozott alaprajzú épület. Mivel az OSM közösségi fejlesztésű alkalmazás, így a teljesség sem biztosított minden esetben.

A validáció a vízmaszkolt mintaterületen 250 véletlenszerűen generált ponttal történt, amelyek referenciáját a Google Earth nagy pontosságú felvételei biztosították. A validáció során meghatároztuk a tematikus térképek össz pontosságát (overall accuracy), illetve az egyes csoportok készítői pontosságát (producer's accuracy) és felhasználói pontosságát (user's accuracy), és az abból számított F-értéket is.

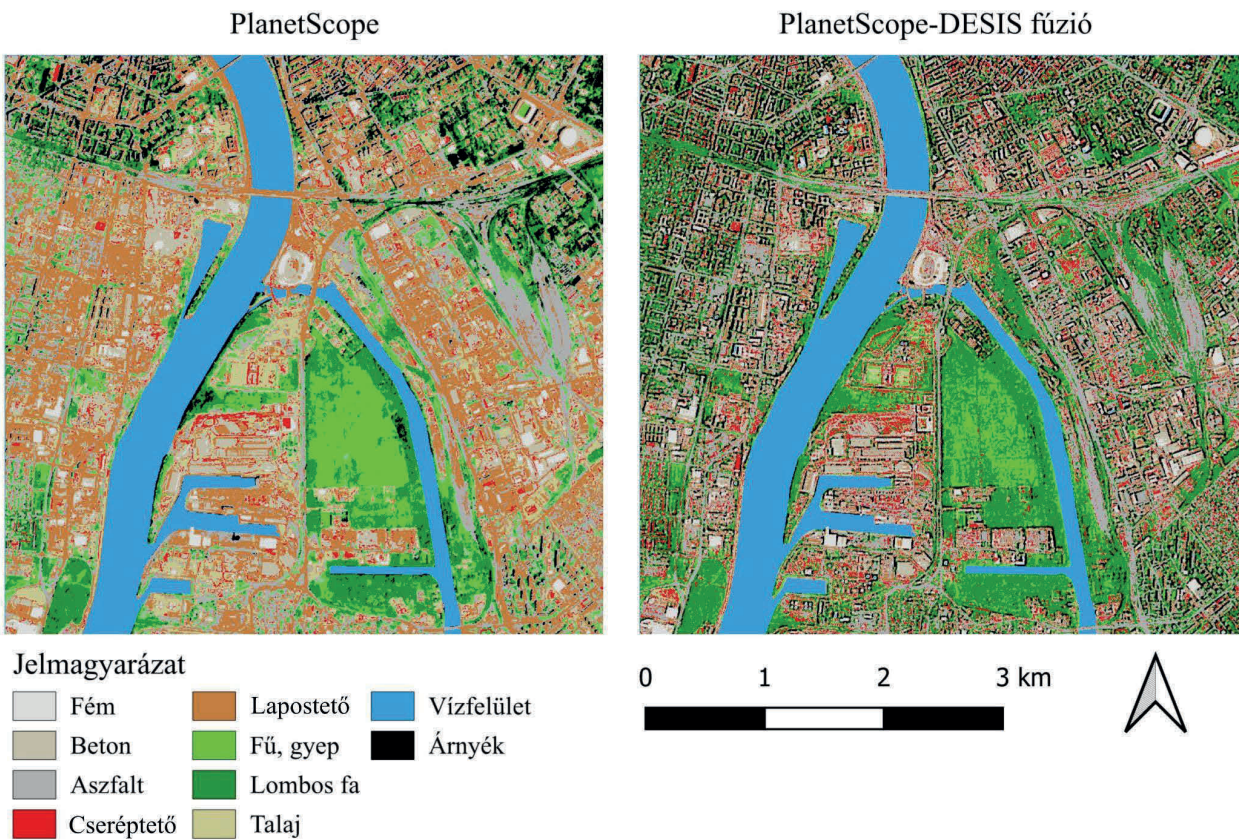
5. Eredmények

A főcsoport szerinti osztályozásokból kiderült, hogy a PlanetScope-DESIS fúziós felvétel jobb osztályozási eredményre ad lehetőséget, mint a PlanetScope önmagában. A június 24-i felvételeken a RF módszerrel futtatott osztályozás a PS a multispektrális felvételre 73% össz pontosságot ért el, a hiperspektrális fúziós adaton 87%-ot. Az osztályozások között jelentős eltérés a főcsoportok határvonalai mentén jelentkezik, ahol a hiperspektrális fúzió esetében éles határok jelennek meg, a multispektrális esetében összefüggő, nagy kiterjedésű foltok (5. ábra).

A fúziós felvételek közül az augusztusi időpontra készült a főcsoport szerinti osztályozásból a legjobb eredmény, ahol az RF 86,4% össz pontosságot eredményezett. Az alcsoportok szerinti



5. ábra. A PlanetScope és a fúziós műholdfelvétel főcsoport szerinti osztályozása RF módszerrel a június 24-i felvételeken



6. ábra. A PlanetScope és a fúziós műholdfelvétel alcsoport szerinti osztályozása RF módszerrel a június 24-i felvételeken

osztályozás esetében is jelentős a fúziós felvétel használatának előnye, amely összpontossága 75%, a multispektrálisé csupán 34%. A PlanetScope adatról történő osztályozás gyengesége leginkább az aszfalt - cseréptető - lapostető borítás szétválasztásának teljes hiányán alapszik, illetve az árnyék és vegetáció hibás megkülönböztetésén (6. ábra). A lapostető borítás felhasználói pontosság mutatószáma 28,6%, amely alapján a térképen jelölt lapostetők töredéke felel meg a valóságnak. A fúziós adat esetében ez 47,4%.



7. ábra. Az alcsoport szerint osztályozások az OSM épületréteg bevonásától függően. A: az 1. módszer szerint az osztályozás külső adatforrás nélkül futott. B: a 2. módszer szerint az osztályozás során az épületpoligonokba eső pixelek csak fém, cseréptető, lapostető és árnyék értéket kaphattak. C: a 3. módszer esetében az épületek a 2. módszer szerint lettek osztályozva, viszont az épület poligonon kívüli pixelek nem kaphattak fém, tetőcserép és lapostető értéket. Jelmagyarázat: 6. ábra

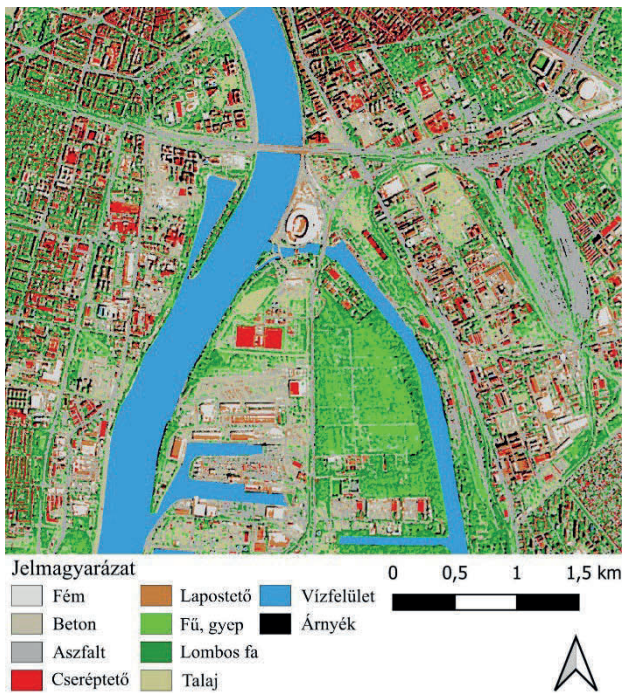
A fúziós adatok osztályozásánál is jellemző, hogy a mesterséges felületen belüli alcsoportok, főként az aszfalt, cseréptető és lapostető esetében nem megfelelő pontosságú az osztályozások eredménye. Gyakori probléma, hogy a hasonló reflektancia miatt a lapostető megjelenik az aszfalt helyén, illetve az aszfalt a cseréptetővel borított épületek és a panelházak tetején. Ezek megfelelő szétválasztására az OSM épületpoligonok bevonása hozott javulást a fúziós adatok osztályozása során (7. ábra). Az épületpoligonok jelenléte minden esetben növelte az osztályozás összpontosságát, a bevonásával járó hibalehetőségek ellenére. (1. táblázat) A legmagasabb, 88,8% összpontosságú eredmény az augusztusi időpontra készült (8. ábra).

Az épületpoligonok bevonásával sikerült jelentősen csökkenteni a mesterséges felületeken belüli félreosztályozásokat (2. táblázat). Kiemelendő a lapostető csoport, mely így 20-30%-kal magasabb pontosságú eredményt ért el. Emellett lényeges javulás látható az aszfalt és cseréptető esetében is, melyeknél 10-15%-os pontosságnövekedés érhető el. A mesterséges felületek között a beton szétválasztása viszont nem elegendő pontosságú. A vegetáció esetében az OSM poligonok bevonása nem javít az osztályozások pontosságán. A talaj csoport bizonytalan eredményeire jelentős hatással van a mintaterület elhelyezkedése, mivel a városi területen kevés nyílt talajfelszín található. Emiatt a talajfelszín osztályozások eredményei is kevés mintán alapszanak. Egyedül az augusztusi, rendkívül aszályos időszakban volt jelentősebb talajfelszín érzékelhető, illetve építkezések területén.

A fúziós felvételekből készített, négy időpont főcsoport szerint osztályozott tematikus térképeit összevetve vizsgáltuk abból a szempontból, hogy a június – február közötti időszakban milyen arányban változott a vizsgált pixel értéke. Az azonos osztályba tartozó területeket aszerint határoztuk meg, hogy a négy időpontból legalább 3 esetben ugyanolyan osztályban volt az adott pixel, így kizárva az esetleges egyszeri félreosztályozást, illetve a műholdképekből eredő adathiányokat. E módszer szerint a vízfelület nélküli mintaterület 42%-a állandó mesterséges felület, 28%-a állandó növényborítottságú. Emellett

Táblázat 1. A különböző időpontokra alkalmazott osztályozási módszerekkel elért összpontosság

Időpont	Osztályozási módszer	Összpontosság
2022. június 24.	1	75,2%
	2	74,0%
	3	78,4%
2022. augusztus 18.	1	82,8%
	2	88,8%
	3	80,4%
2022. október 10.	1	70,0%
	2	74,8%
	3	76,0%
2023. február 15.	1	70,4%
	2	73,9%
	3	72,3%



8. ábra. Az augusztus 18-i fúziós felvételre készített alcsoport szerinti osztályozás RF, illetve OSM épületrétegek a 2. módon ismertetett bevonásával

mindössze csak 0,4% volt állandó talajfelszín. Az árnyékborítottság esetében 6,3%, amely a sűrű, belvárosi házak között jellemző. Ebből következik, hogy a mintaterület változó osztályokba tartozó pixeleinek az aránya 23% (9. ábra).

Fontos kiemelni, hogy a változó osztályokba tartozó pixelek csak a reflektanciát adó, időben változó felszínborítások következtében jelennek meg. A változó felszínborítású felületekre számos variáció van, köztük a legjelentősebb a növényzet - mesterséges felület - növényzet váltakozása, mely a változó területek 34%-át érinti. Erre jó példa a Ferencváros pályaudvar területe, ahol a 2022-es év szélsőséges időjárásának (nyári súlyos aszály) következtében a területen nyár elején még a vegetáció (gyomnövények) az uralkodó felszínborítás, majd az

Táblázat 2. A négy időpontra készített alcsoport szerinti osztályozások pontosságbeli mutatóinak átlaga, illetve a kizárólag a februári képen osztályozott száraz vegetáció. Az 1. módszer szerint az osztályozás külső adatforrás nélkül futott. A 2. módszer szerint az osztályozás során az épületpoligonokba eső pixelek csak fém, cseréptető, lapostető és árnyék értéket kaphattak. A 3. módszer esetében az épületek a 2. módszer szerint lettek osztályozva, viszont az épület poligonon kívüli pixelek nem kaphattak fém, tetőcserép és lapostető értéket


Osztályozási módszer	Index/csoport	Fém	Beton	Aszfalt	Cseréptető	Lapostető	Fű, gyepek	Lombos fa	Száraz vegetáció	Talaj	Árnyék
1	Producer A.	82,55%	44,65%	65,90%	70,83%	49,81%	88,17%	95,23%	90,00%	77,94%	91,43%
	User A.	67,86%	61,80%	73,52%	60,01%	41,23%	86,82%	81,12%	96,43%	61,71%	94,98%
	F-score	71,80%	51,37%	69,30%	58,51%	44,95%	87,46%	86,70%	93,10%	66,28%	93,03%
	Overall A.	74,60%									
2	Producer A.	81,65%	62,35%	85,46%	56,58%	62,65%	81,79%	92,26%	91,38%	73,60%	84,85%
	User A.	82,74%	53,90%	72,03%	88,73%	70,16%	85,63%	75,45%	94,64%	58,94%	93,55%
	F-score	80,50%	56,56%	77,74%	67,79%	65,06%	83,61%	82,29%	92,98%	64,24%	88,43%
	Overall A.	77,86%									
3	Producer A.	93,29%	53,64%	76,87%	64,94%	87,48%	74,15%	92,86%	85,45%	48,87%	80,27%
	User A.	73,25%	59,95%	85,64%	64,19%	64,21%	85,80%	66,87%	83,93%	71,71%	92,80%
	F-score	81,10%	56,31%	80,97%	62,67%	73,13%	79,50%	77,48%	84,68%	57,11%	85,56%
	Overall A.	76,78%									

őszi-téli időszakban már a mesterséges felületek lettek meghatározók. A téli csapadékos időjárásnak köszönhetően a területen ismét nagyobb súllyal találtunk növényzettel borított felszíneket.

6. Következtetések

A tanulmány eredményeiből megállapítható, hogy a közepes térbeli felbontású hiperspektrális DESIS adatokra megfelelő felbontásbeli javítás érhető el a PlanetScope adataival történő pansharpening fúzióval, amely lehetővé teszi a városi felszínek hatékonyabb vizsgálatát. A városi környezetben a főcsoport (mesterséges felület, növényzet, talajfelszín, illetve árnyék) szerinti osztályozásánál a fúziós adattal 80-90% összpontosság érhető el. A fúziós adat használatával így 10-15%-kal magasabb összpontosság érhető el 3 méteres térbeli felbontásnál, mint a PlanetScope adattal. A kérdés viszont felmerül, hogy ekkora pontosságnövekedésért megéri-e a fúziós adatok előállítás, aminek rendkívül magas a számítás és tárhely igénye. Az alcsoport szerinti osztályozásnál viszont egyértelmű, hogy hiperspektrális adat szükséges a megfelelő szétválasztáshoz, mivel a multispektrális felvételt nem lehet megfelelő pontossággal osztályozni. A fúziós adatról történő alcsoport szerinti osztályozás minőségét az OSM épület rétegekkel tovább lehet növelni, mellyel 70-80% összpontosság érhető el, évszaktól és árnyékborítottságtól függően. A legjobb összpontosságú eredmény így 88,8%, amely az augusztusi időpontra készült. Az OSM épületréteg megoldást nyújt a mesterséges alcsoportokon belüli félreosztályozások mérsékléséhez, főként az aszfalt, cseréptető és lapostető esetében. A beton felszín megfelelő szétválasztása viszont még nem megfelelő ezen módszerek alkalmazásával sem.

Az idősoros vizsgálatokból megállapítottuk, hogy a mintaterület 77%-a állandó, 23%-a változó felszínborítottságú a vizsgált főcsoportok tekintetében. A legjelentősebb állandó felszínborítottság a mesterséges felület, mely 42%-ot tesz ki a mintaterületből. Emellett jelentős még az állandó növényzet, ami a 28%. Az állandóan árnyékborított felszínek aránya 6,3%, ami a belvárosi házak között jelentkezik, így a felvételeken ezekről a



9. ábra. Az állandó és a változó osztályokba tartozó pixelek a négy időpontra készült osztályozott tematikus térképek alapján

pixelekről nem kapunk felszínborítottsági információt. A változó értékű pixelek között a vegetáció – mesterséges felület jelentős, ami az út menti lombhullató fákból adódik (mintaterület 4,5%-a), a vegetáció – mesterséges felület - vegetáció váltakozása (8%), mely az elhagyatottabb, gyommal borított területeken jelentkeznek.

A hiperspektrális műholdfelvételek városi környezetben való alkalmazása továbbra is kihívást jelent. A pontosságnöveléshez érdemes lehet más, pl. vektoros adatforrásokat is alkalmazni. Emellett nagyfelbontású digitális felszínmodell alkalmazásával is segítheti az eltérő magasságú épületek és az útburkolatok megkülönböztetését. Továbbá várható, hogy a szélesebb spektrális tartományú műholdfelvételek jobb szétválaszthatóságot eredményezhetnek, emellett újabb mesterséges felszínborítás kategóriába tartozó alcsoportok is megkülönböztethetővé válnak.

Köszönetnyilvánítás

A kutatást „Az egészséges és beteg haszonnövények spektrális ujjlenyomatainak meghatározása és térbeli nagyadat-elemzése fuzionált multitemporális hiperspektrális műholdas és terepi távérzékelési adatok és mélytanulási módszerek felhasználásával” c. NKFIH-Advanced 149686 azonosítójú projekt támogatta.

Irodalomjegyzék

Afify, H. A., 2011. Evaluation of change detection techniques for monitoring land-cover changes: A case study in new Burg El-Arab area. *Alexandria Engineering Journal*, 50(2), 187–195. DOI: <https://doi.org/10.1016/j.aej.2011.06.001>

Dos Reis, A.A. – Werner, J.P.S. – Silva, B.C. – Figueiredo, G.K.D.A. – Antunes, J.F.G. – Esquerdo, J.C.D.M. – Coutinho, A.C. – Lamparelli, R.A.C. – Rocha, J.V. – Magalhães, P.S.G., 2020. Monitoring Pasture Aboveground Biomass and Canopy Height in an Integrated Crop–Livestock System Using Textural Information from PlanetScope Imagery. *Remote Sens.* 2020, 12, 2534. <https://doi.org/10.3390/rs12162534>

Falco, N. – Mura, M. D. – Bovolo, F. – Benediktsson, J. A., – Bruzzone, L., 2013. Change Detection in VHR Images Based on Morphological Attribute Profiles. *IEEE Geoscience and Remote Sensing Letters*, 10(3), 636–640. DOI: <https://doi.org/10.1109/LGRS.2012.2222340>

Farmonov, N. – Amankulova, K. – Szatmári, J. – Urinov, J. – Narmanov, Z. – Nosirov, J. – Mucsi, L., 2023. Combining PlanetScope and Sentinel-2 images with environmental data for improved wheat yield estimation. *International Journal of Digital Earth*, 16(1), 847–867. DOI: <https://doi.org/10.1080/17538947.2023.2186505>

Farmonov, N. – Amankulova, K. – Szatmári, J. – Sharifi, A. – Abbasi-Moghadam, D. – Mirhoseini Nejad, S. M. – Mucsi, L., 2023. Crop type classification by desis hyperspectral imagery and machine learning algorithms. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 1576–1588, DOI: <https://doi.org/10.1109/JSTARS.2023.3239756>

Feranec, J. – Hazeu, G. – Jaffrain, G. – Cebecauer, T., 2007. Cartographic Aspects of Land Cover Change Detection (Overland Underestimation in the I&CORINE Land Cover 2000 Project). *The Cartographic Journal*, 44(1), 44–54. DOI: <https://doi.org/10.1179/000870407X173869>

Hayes, D. J. – Sader, S. A., 2001. Comparison of Change-Detection Techniques for Monitoring Tropical Forest Clearing and Vegetation Regrowth in a Time Series. *Photogrammetric Engineering and Remote Sensing*, 67(9), 1067–1075.

Hegazy, I.R. – Kaloop, M.R., 2015. Monitoring Urban Growth and Land Use Change Detection with GIS and Remote Sensing Techniques in Daqahlia Governorate Egypt. *International Journal of Sustainable Built Environment*, 4, 117–124. DOI: <https://doi.org/10.1016/j.ijsbe.2015.02.005>

Heiden, U. – Bachmann, M. – Alonso, K. – Carmona, E. – Cerra, D. – Dietrich, D. – Langheinrich, M. – Los Reyes, R. – Mueller, R. – Pinnel, N. – Ziel, V. 2019. DESIS imaging spectrometer data access and synergistic use with other ISS earth observing instruments. In: *Proc. Conference: Workshop on International Cooperation in Spaceborne Imaging Spectroscopy*, German Aerospace Center (DLR), Frascati, Italy, 2019, Art. no. 24.

Ilsever, M., – Ünsalan, C., 2012. *Two-Dimensional Change Detection Methods*. Springer London. DOI: <https://doi.org/10.1007/978-1-4471-4255-3>

Jenerowicz, A. – Kaczynski, R. – Siok, K. – Palkiewicz, K., 2019. Change detection of urban area based on multisensor imagery. In: *Proceedings of SPIE - The International Society for Optical Engineering*, 11157. DOI: <https://doi.org/10.1117/12.2533379>

Jin, Y. – Guo, J. – Ye, H. – Zhao, J. – Huang, W. – Cui, B., 2021. Extraction of Arecanut planting distribution based on the feature space optimization of PlanetScope imagery, *Agriculture*, 11(4): 371. DOI: <https://doi.org/10.3390/agriculture11040371>

Jung, A. – Kardeván, P. – Tökei, L., 2005. Detection of urban effect on vegetation in a less built-up Hungarian city by hyperspectral

remote sensing. *Physics and Chemistry of the Earth*, 30(1-3), 255-259. DOI: <https://doi.org/10.1016/j.pce.2004.08.041>

Krutz, D. – Müller, R. – Knodt, U. – Günther, B. – Walter, I. – Sebastian, I. – Säuberlich, T. – Reulke, R. – Carmona, E. – Eckardt, A., 2019. The Instrument Design of the DLR Earth Sensing Imaging Spectrometer (DEGIS). *Sensors*, 19, 1622. DOI: <https://doi.org/10.3390/s19071622>

Planet Team, 2024. Planet Application Program Interface: In Space for Life on Earth. San Francisco, CA. <https://api.planet.com>

Peschel, T. – Beier, M. – Damm, C. – Hartung, J. – Jende, R. – Müller, S. – Rohde, M. – Gebhardt, A. – Risse, S. – Walter, I. – Sebastian, I. – Krutz, D., 2018. Integration and testing of an imaging spectrometer for Earth observation. In: *Proceedings Volume 11180, International Conference on Space Optics – ICSSO 2018*, pp. 267–273. DOI: <https://doi.org/10.1117/12.2535943>

Sadeh, Y. – Zhu, . – Dunkerley, D. – Walker, J. P. – Zhang, J. – Rozenstein, O. – Manivasagam, V. S. –Chenu K., 2021. Fusion

of Sentinel-2 and PlanetScope time-series data into daily 3 m surface reflectance and wheat LAI monitoring, *International Journal of Applied Earth Observation and Geoinformation*, Volume 96, 2021, DOI: <https://doi.org/10.1016/j.jag.2020.102260>

Tobak Z. – Csendes B. – Henits L. – Van Leeuwen B. – Szatmári J. – Mucsi L., 2012. *Városi felszín spektrális tulajdonságainak vizsgálata légifelvételek alapján*. Szeged, SZTE TTIK Természeti Földrajzi és Geoinformatikai Tanszék, 1059 p., pp. 1088-1097.

United Nations, Department of Economic and Social Affairs, Population Division, 2019. *World Population Prospects 2019: Highlights (ST/ESA/SER.A/423)*.

United Nations Human Settlements Programme, 2022. *World Cities Report 2022*, United Nations, DOI: <https://doi.org/10.18356/9789210028592>



FlintSign
Powered by
InfoCert

**Minősített elektronikus aláírás
MFTTT tagoknak
29.750 Forint
1 év, korlátlan aláírás**