

TDK-dolgozat

Magyar Dávid

Hulladékdetektálás és változáselemzés folyóvizeken multispektrális műholdfelvételek alapján

EÖTVÖS LORÁND TUDOMÁNYEGYETEM

INFORMATIKAI KAR

PROGRAMOZÁSELMÉLET ÉS SZOFTVERTECHNOLÓGIAI TANSZÉK



Szerző:

Magyar Dávid

programtervező informatikus BSc

3. évfolyam

Témavezetők:

Cserép Máté

egyetemi tanársegéd

dr. Vincellér Zoltán

mesteroktató

Budapest, 2022

Tartalomjegyzék

1. Bevezetés	3
2. Szakirodalmi áttekintés és fogalmak	5
2.1. Legfontosabb fogalmak	5
2.1.1. Multispektrális műholdfelvételek	5
2.1.2. Indexek	7
2.1.3. Gépi tanulás	8
2.2. Szakirodalmi áttekintés	11
2.2.1. Műanyag index	11
2.2.2. Gumi- és műanyag hulladék detektálása <i>Random Forest</i> modell segítségével	14
2.2.3. Hullákdetektálás nagyfelbontású felvételeken neurális hálózatok segítségével	16
3. Módszertan	19
3.1. Tanító területek	19
3.2. Tanító címkék és döntési fák optimális száma	21
3.3. Hullákdetektálási módszerek	23
3.3.1. Hot-spotok detektálása	23
3.3.2. Vízfelszíni folyami torlaszok detektálása	24
3.3.3. A hullámtérben ismert helyen lerakott hulladék detektálása	26
4. Implementáció	29
4.1. Érdekesebb algoritmusok	34
4.1.1. Iteratív <i>Flood fill</i> algoritmus	34
4.1.2. Két különböző felvétel közös földrajzi koordinátákkal rendelkező metszetének meghatározása	35
5. Eredmények	38

5.1. Hot-spot detektálása	39
5.2. Vízfelszíni folyami torlaszok detektálása	39
5.3. A hullámtérben ismert helyen lerakott hulladék detektálása	39
6. Összefoglaló	44
Köszönetnyilvánítás	45
Irodalomjegyzék	46
Ábrajegyzék	49
Táblázatjegyzék	51
Algoritmusjegyzék	52
Forráskódjegyzék	53

1. fejezet

Bevezetés

Napjaink egyik legnagyobb környezetvédelmi problémája az illegális hulladék lerakatok számának növekedése az erdőkben, folyókon, folyópartokon, valamint egyéb félreeső helyeken. A folyóvizekbe kerülő hulladék ráadásul nem csak helyben okoz természetkárosítást, hanem a folyó lentebbi szakaszain is mind a vízben, mind a partra kimosódva. Vízerőműveknél, illetve gátaknál nagy kiterjedésű szemétszigetek is kialakulhatnak, melyek esetleges továbbhaladása további természeti károkat is okozhat a folyó mentén [1, 2, 3]. Ezért nagyon fontos, hogy a hulladékgyűjtő szervezetek képesek legyenek nyomon követni a potenciális veszélyforrásokat.

Az elmúlt egy évtizedben nagy fejlődésen mentek keresztül a közepes- és nagy felbontású, multispektrális szenzorokkal felszerelt földmegfigyelő műholdak. Havi, heti, vagy akár napi rendszerességgel is készülnek új felvételek ugyanazon területekről, ennél fogva változáselemzésre is kiválóan alkalmazhatók. A felvételek analizálása a multispektrális műholdfelvételek látható és nem látható tartományban készült sávjai, valamint az ezekből készült különféle indexek alapján történik, annak érdekében, hogy a hulladékkal fedett területek jobban elkülönüljenek a környezetüktől.

Dolgozatom témája különféle robusztus hulladékdetektálási módszerek tesztelése, fejlesztése, azon célból, hogy ezen lerakatok észlelését megkönnyítsem és felgyorsítsam, továbbá a hulladékgyűjtő akciókat egy automatikus monitoring rendszerrel elősegítsem. Eszközként a gépi tanulást választottam, mely napjaink széles körben alkalmazott, és a távérzékelésben is egyre inkább használatos technológiája.

A dolgozat második fejezete ismerteti a legfontosabb fogalmakat a témával kapcsolatban, illetve betekintést nyújt a szakirodalomban szereplő hulladékdetektálási próbálkozásokba. A harmadik fejezetben bemutatásra kerülnek az osztályozási modell tanításához

felhasznált területek, valamint a projekt során kifejlesztett detektálási módszerek. A módszertan megvalósításához szükséges prototípus alkalmazás részleteiről a negyedik fejezet ír. Az ötödik fejezetben szemléltetésre kerülnek az elért eredmények. Zárásképpen a tanulmány összefoglalóját és saját konklúziómat tartalmazza a hatodik fejezet.

2. fejezet

Szakirodalmi áttekintés és fogalmak

2.1. Legfontosabb fogalmak

2.1.1. Multispektrális műholdfelvételek

Az elmúlt évtizedekben mind maga a távérzékelés, mind a közepes- és nagy felbontású, multispektrális szenzorokkal felszerelt földmegfigyelő műholdak is nagy technológiai fejlődésen mentek keresztül. Ezen műszerek képesek a látható és nem látható tartományban is adatokat rögzíteni, ezáltal több információt biztosítanak a megfigyelt területről.

GeoTIFF

A műholdfelvételek általában *GeoTIFF* [4] típusú fájlokba kerülnek elmentésre. A *GeoTIFF* egy nyilvános metaadat-szabvány, amely lehetővé teszi a georeferencia-információk beágyazását egy *TIFF*-fájlba [5]. A lehetséges kiegészítő információk közé tartozik a térképi vetület, a koordinátarendszer, az ellipszoidok, a dátum és minden más, ami a fájl pontos térbeli referenciájának meghatározásához szükséges. A *GeoTIFF* formátum teljes mértékben megfelel a *TIFF* 6.0-nak, így a speciális metaadatok olvasására és értelmezésére képtelen szoftverek is képesek megnyitni a *GeoTIFF* formátumú fájlokat.

Kutatásom során a távérzékelő műholdak két fajtájával dolgoztam, melyek specifikációi alább olvashatóak.

Sentinel-2

Az Európai Unió Föld-megfigyelési programja, a Kopernikusz program [6]. Ennek Sentinel-2 küldetése [7] két azonos műholdból álló, azonos pályán keringő konstelláción

alapul. Mindkét műhold egy-egy innovatív, 13 spektrális sávot tartalmazó, nagy felbontású, széles sávú multispektrális képalkotó eszközt hordoz, melyek folyamatosan monitorozzák a földfelszín változását.

A Sentinel-2 nagy felbontású multispektrális műszere a francia SPOT-missziók [8] és az amerikai Landsat műholdak [9] jól bevált örökségén alapul. A multispektrális képalkotó a legfejlettebb a maga nemében - valójában ez az első olyan optikai földmegfigyelő műszer, amely három sávot tartalmaz a "vörös él" tartományban, amelyek kulcsfontosságú információkat szolgáltatnak a növényzet állapotáról. Két nagyméretű, látható közeli infravörös és rövidhullámú infravörös fókuszszíkot integrál, amelyek mindegyike 12 detektorral van felszerelve és 450 000 pixelt egyesít. A küldetés során esetlegesen meghibásodó pixelek redundáns pixelekkal helyettesíthetők. A kétféle detektor kiváló minőségű szűrőket használ a spektrális sávok tökéletes elkülönítése érdekében. A műszer optikai-mechanikai stabilitásának rendkívül magasnak kell lennie, ami szilícium-karbid kerámia használatát jelentette a három tükör és a fókuszszík, valamint maga a távcső szerkezete esetében. A 13 spektrális sáv, a látható tartománytól a közeli infravörösön át a rövidhullámú infravörösig (2.1 táblázat), 10 és 60 méter közötti térbeli felbontással, eddig nem látott szintre emeli a földfelszín megfigyelését [7].

Az általam felhasznált sávok között többnyire a 10 és 20 méteres felbontásúak szerepeltek, melyeken egy képpont rendre 100, illetve 400 m² nagyságú területet fed le. Ennélfogva csak nagyobb kiterjedésű szemétkerakatok, szemétkerakok azonosítására volt alkalmas.

PlanetScope

Az amerikai Planet Labs Inc.¹ vállalat PlanetScope műhold-konstellációja [10] egyedi kockaműhold-csoportok sokaságából tevődik össze. A több, mint 130 műholdból álló konstelláció naponta képes képet készíteni a Föld szinte teljes szárazföldi területéről. A felvételek készítésére használt műszer, mely az összes ilyen műholdon megtalálható, jelenleg négy sávban képes rögzíteni: *Kék*, *Zöld*, *Vörös*, *Közeli infravörös* (2.2 táblázat), ezek speciális esetekben kiegészülnek még egy *Vörös él* sávval is.

Ezen műszerek már kisebb területek azonosítására is alkalmasak voltak, mivel sávjaik 3 méter felbontásúak, azaz egy képpont 9 m² kiterjedésű terület adatait tartalmazza.

¹Planet Labs Inc. - <https://www.planet.com/>

Sáv	Felbontás	Hullámhossz közepe	Leírás	Angol rövidítés
B1	60 m	443 nm	Tengerparti aeroszol	Coastal aerosol
B2	10 m	490 nm	Kék	Blue
B3	10 m	560 nm	Zöld	Green
B4	10 m	665 nm	Vörös	Red
B5	20 m	705 nm	Vörös él	Vegetation red edge
B6	20 m	740 nm	Vörös él	Vegetation red edge
B7	20 m	783 nm	Vörös él	Vegetation red edge
B8	10 m	842 nm	Közeli infravörös	NIR
B8a	20 m	865 nm	Keskeny közeli infravörös	Narrow NIR
B9	60 m	940 nm	Vízpára	Water vapour
B10	60 m	1375 nm	Rövidhullámú infravörös	SWIR - Cirrus
B11	20 m	1610 nm	Rövidhullámú infravörös	SWIR 1
B12	20 m	2190 nm	Rövidhullámú infravörös	SWIR 2

2.1. táblázat. A Sentinel-2 sávjainak elnevezései és paraméterei [11, 12].

Sáv	Felbontás	Hullámhossz	Leírás	Angol rövidítés
B1	3 m	455 - 517 nm	Kék	Blue
B2	3 m	500 - 590 nm	Zöld	Green
B3	3 m	590 - 682 nm	Vörös	Red
B4	3 m	780 - 888 nm	Közeli infravörös	NIR

2.2. táblázat. A PlanetScope sávjainak elnevezései és paraméterei [13].

2.1.2. Indexek

A műhold felvételek sávjaiból különböző index értékek számíthatók. Mindegyik más-más típusú területek jellemzőit emeli ki. Az általam használt talán legfontosabb ilyen mutató a *Plastic Index* volt (2.3 táblázat) [14], mely a műanyagot tartalmazó területek esetében magasabb értékkel rendelkezik. Ezt az adottságát használtam ki a változáselemzés során. A végső eljárásokban nem alkalmaztam a 2.4-es táblázatban szereplő indexeket, mivel azok csak Sentinel-2 műholdak által mért adatokból számíthatók, a PlanetScope műholdak nem rendelkeznek az ezekhez szükséges sávokkal.

$$\begin{aligned}
 \text{Plastic Index (PI)} &= \frac{NIR}{NIR + Red} \\
 \text{Normalized Difference Water Index (NDWI)} &= \frac{Green - NIR}{Green + NIR} \\
 \text{Normalized Difference Vegetation Index (NDVI)} &= \frac{NIR - Red}{NIR + Red} \\
 \text{Reversed Normalized Difference Vegetation Index (RNDVI)} &= \frac{Red - NIR}{Red + NIR} \\
 \text{Simple Ratio (SR)} &= \frac{NIR}{Red}
 \end{aligned}$$

2.3. táblázat. A végül felhasznált indexek kiszámítási módjai [14].

$$\begin{aligned} \text{Water Ratio Index (WRI)} &= \frac{\text{Green} + \text{Red}}{\text{NIR} + \text{SWIR} 2} \\ \text{Modified Normalization Difference Water Index (MNDWI)} &= \frac{\text{Green} - \text{SWIR} 2}{\text{Red} + \text{SWIR} 2} \\ \text{Normalized Difference Moisture Index (NDMI)} &= \frac{\text{Green} - \text{SWIR} 1}{\text{Green} + \text{SWIR} 1} \end{aligned}$$

2.4. táblázat. Az egyéb kipróbált indexek kiszámítási módjai [14].

2.1.3. Gépi tanulás


A gépi tanulás (*Machine learning* - *ML*) olyan számítógépes algoritmusokat foglal magába, amelyek tapasztalatok és adatok felhasználásával automatikusan fejlődni tudnak. A mesterséges intelligencia (*Artificial intelligence* - *AI*) egy részhalmazának tekinthető. Ezek az algoritmusok mintaadatok, úgynevezett tanító adatok alapján építenek egy modellt, mellyel képesek előrejelzéseket vagy döntéseket hozni anélkül, hogy erre kimondottan programozták volna őket. A gépi tanulási algoritmusokat számos olyan alkalmazásban használják, ahol nehéz vagy kivitelezhetetlen hagyományos algoritmusokat fejleszteni a szükséges feladatok elvégzésére [15].

Két nagyobb ismert csoportja:

- **Felügyelt tanulás:** A számítógépnek bemeneti példákat és ezek kívánt kimenetét mutatják meg, és a cél egy olyan általános szabály megtanulása, amely a bemeneteket a kimenetekhez rendeli. Egy adathalmaz matematikai modelljét építik fel, amely tartalmazza mind a bemeneteket, mind a kívánt kimeneteket [16]. A felügyelt tanulási algoritmusok típusai közé tartozik az aktív tanulás, az osztályozás és a regresszió [17]. Néhány ismert algoritmus: *Support-vector machine (SVM)*, *Naive Bayes*, *Random Forest*.
- **Felügyelet nélküli tanulás:** Ezek az algoritmusok olyan tesztadatokból tanulnak, amelyeket nem jelöltek, osztályoztak vagy kategorizáltak korábban. Egy olyan adathalmazt vesz alapul, amely csak bemeneteket tartalmaz. A feladata az, hogy ebben struktúrát találjon, mint például az adatpontok csoportosítása vagy klaszterezése. A felügyelet nélküli tanulási algoritmusok közös vonásokat azonosítanak az adatokban, és az ilyen közös vonások jelenléte vagy hiánya alapján reagálnak minden egyes új adat esetén. Néhány ismert algoritmus: *k-means*, *ISODATA*.

Döntési fa

A döntési fa az egyike a prediktív modellezési megközelítéseknek, amit a gépi tanulásban használnak. Az osztályozási modell egy elemmel kapcsolatos megfigyelésektől az elem célértékére vonatkozó következtetésekig jut el. A megfigyelések a fa ágaiban, a célértékek pedig a fa leveleiben helyezkednek el. Az olyan fa modelleket, ahol a célváltozó értékei egy diszkrét halmazból kerülnek ki, osztályozási fának nevezzük. Ilyen fákban a levelek osztálycímkéket jelentenek, az ágak pedig olyan jellemzők elágazásai, amik az osztálycímkékhez vezetnek (2.1 ábra).



2.1. ábra. Egy betanított döntési fa, és a felhasznált tanító adathalmaz.
Az egyes adatpontok osztályait az adatpontok alakja jelöli [18].

Random Forest

Kutatásom során a *Random Forest* osztályozó algoritmust alkalmaztam. A felhasználónak a tanításhoz meg kell adnia a modell fáinak számát, ezzel valamennyire a véletlenszerűség mértékét tudja szabályozni. Valamely implementációk lehetőséget adnak a fák méretének szabályozására is (például a fa maximális magassága vagy a fa egyes csúcsainak maximális mérete), mellyel az algoritmus futási idejét lehet korlátozni [18, 19]. A megkapott tanító adatok alapján a modell számos döntési fát hoz létre, ezek alkotják majd az erdőt. Ismeretlen bemeneti adat esetén a modell kimenete a legtöbb fa által kiválasztott osztály (1. algoritmus és 2.2 ábra).


1. Algoritmus A *Random Forest* algoritmus predikciós eljárásának pszeudokódja, amely egy korábban betanított modellt (*forest*) használ az X felvétel osztályozására.

Forrás: [18]

```

1: for all  $x \in X$  do
2:    $predictions := \text{EmptyDictionary}()$ 
3:   for all  $tree \in forest.Trees()$  do
4:      $n := tree.Root()$ 
5:     while not  $n.IsLeaf()$  do
6:        $n := n.ChildBasedOnSplitFor(x)$  ▷ a következő csúcs lekérdezése
7:     end while
8:      $p := n.Prediction()$  ▷ az elért levélhez tartozó célérték-predikció tárolása
9:      $predictions[p] := predictions[p] + 1$ 
10:  end for
11:   $x.AssignToMajorityElementOf(predictions)$ 
12: end for
13: return  $\text{PointAssignment}()$ 

```




2.2. ábra. *Random Forest* döntéshozatal.

Forrás: <https://dinhhanhthi.com/>

Keresztvalidáció

A betanított modellek pontosságának meghatározásához széles körben alkalmazott technika a keresztvalidáció (*cross-validation*). Az alapötlet az, hogy a tanító adatainkat valamilyen arányban bontsuk két részre. Az első részt használjuk egy modell tanítására, a másodikat pedig ezen modell predikciós hibájának meghatározására [20].

A általam ellenőrzött modellek pontosságát k -szoros keresztvalidációval határoztam meg (k -folds cross-validation). Itt az adatokat véletlenszerűen k darab, egymást nem átfedő és kölcsönösen kizáró részre osztjuk fel, amelyek megközelítőleg azonos méretűek. A k részmintából egyet tartunk meg validációs adatként a modell teszteléséhez, a fennmaradó $k - 1$ részmintát pedig tanító adatként használjuk. A folyamatot ezután k -szor megismétljük, és minden k részmintát pontosan egyszer használunk validálási adatként (2.3 ábra). A k eredményt ezután átlagolni lehet, hogy a pontosságot megkapjuk [21].



2.3. ábra. Keresztvalidáció.

Forrás: <https://scikit-learn.org/>

2.2. Szakirodalmi áttekintés

2.2.1. Műanyag index

Az óceán felszínén úszó műanyag szemét globális szinten jelentős problémát jelent. Themistocleous és tsai. [14] azt vizsgálták, hogy a Sentinel-2 műholdfelvételek felhasználhatók-e a tenger felszínén úszó műanyag szemét azonosítására, nyomon követésére. Ennek érdekében egy kísérleti tanulmányt végeztek. Egy $3 \text{ m} \times 10 \text{ m}$ -es felületű, műanyag vizes palackokból álló céltárgyat hoztak létre (2.4 ábra), amelyet ezt követő-

en a ciprusi Limassol egy kikötőjének² közelében helyezték el a tengerben (2.5 ábra). Egy pilóta nélküli légi járművet (*Unmanned aerial vehicle* - UAV) is használtak, melynek segítségével multispektrális légi felvételeket készítettek a vizsgált területről a Sentinel-2 műhold [7] áthaladásával egy időben. A víz és a vízbe helyezett műanyag szemét spektrális szignatúráját egy SVC HR1024 spektroradiométerrel [22] rögzítették. A vizsgálat megállapította, hogy a műanyag szemét legkönnyebben a *Közel infravörös (NIR)* hullámhosszon volt kimutatható. A műholdképek feldolgozásakor általában használt indexek közül (2.3, 2.4 táblázatok) hetet vizsgáltak azon célból, hogy képesek-e azonosítani a vízben lévő műanyag szemetet. Továbbá a szerzők két új indexet is kipróbáltak: a műanyag indexet (*Plastic Index* - PI) és a fordított normalizált differenciált vegetációs indexet (*Reversed Normalized Difference Vegetation Index* - RNDVI) (2.6 ábra). Az újonnan kifejlesztett műanyag index (PI) képes volt a vízfelszínen úszó műanyag tárgyak azonosítására, és a leghatékonyabb mutató volt a tenger felszínén úszó műanyag szemét azonosításában [14].




2.4. ábra. A műanyag palackokból elkészített céltárgy.

Forrás: [14]

²A limassoli kikötő - <https://goo.gl/maps/6enjwDfJ2XJXRcBq7>



2.5. ábra. A céltárgy tengerre bocsátása.
Forrás: [14]




2.6. ábra. A céltárgy detektálása.

Sentinel-2 műholdkép az indexekkel feldolgozva. A szárazföldet narancssárga szín, a vizet kék, a műanyagot pedig sárga ábrázolja. A sárga körön belüli sárga négyzet a műanyag céltárgy a műholdas áthaladás során. A műanyaghoz tartozó indexértékek az egyes indexek esetében zárójelben szerepelnek. Forrás: [14]


2.2.2. Gumi- és műanyag hulladék detektálása *Random Forest* modell segítségével

Az Európa-szerte szigorodó hulladékszabályozás eredményeként a hulladékkal kapcsolatos bűncselekményekről szóló bejelentések száma napról napra emelkedik. A jelentős mennyiségű gumiabroncs- és műanyagkészletek az emberi és környezeti egészséget egyaránt veszélyeztetik, vízszennyezéshez és állatok megbetegedéséhez vezethetnek, potenciális veszélyforrások tüzek kialakulásához. Az illegális lerakatok azonosításának hagyományos módszerei általában fáradságos helyszíni felmérésekkel járnak, amelyek nem alkalmasak a problémák országos szintű megoldására. A hulladékok kezelését célzó távérzékeléses vizsgálatok eddig kevésbé kerültek felfedezésre a gumiabroncsok és a műanyagok spektrálisan változó és összetett jellege, valamint más földtakarókhhoz, például a vízhez és az árnyékhoz való hasonlóságuk miatt. Ezért Page és tsai. tanulmányának [23] átfogó célja az volt, hogy egy pontos osztályozási módszert dolgozzanak ki mind a gumiabroncs-, mind a műanyag hulladék detektálására, hogy életképes platformot biztosítsanak a megismételhető, költséghatékony és nagyszabású nyomon követéshez. Kidolgoztak egy olyan kibővített földtakaró osztályozást, amely kombinálja a Kopernikusz Sentinel-2 [7] optikai felvételek tematikus indexeit és a Kopernikusz Sentinel-1 [24] mikrohullámú adatait. Két *Random Forest* osztályozási algoritmust használtak, melyeket specifikusan a gumi- és műanyag hulladék detektálására tanítottak be Skóciában készült felvételek alapján (2.7, 2.8 ábrák) [23].



2.7. ábra. A tanító terület Skóciában.


Forrás: [23]



(a) Sentinel-2 RGB felvétel



(b) Osztályozott felvétel, ami mutatja a gumi- és műanyag hulladékok is



(c) Google Earth felvétel

2.8. ábra. Példa Skóciában történt detektálásra.

Forrás: [23]

2.2.3. Hulladékdetektálás nagyfelbontású felvételeken neurális hálózatok segítségével

Az elmúlt években a mély tanulás (*deep learning* [25]) egyik fontos sikere és alkalmazása a képfeldolgozás területén volt. A mély tanulással kapcsolatos kutatások kimutatták, hogy ezek az architektúrák, különösen a konvolúciós neuronhálók (*Convolutional neural network* - *CNN* [26]), képesek emberi szintű képességekkel megoldásokat tanulni bizonyos vizuális feladatokra. Ezeket a technikákat különösen a távérzékelési képelemzési feladatokban alkalmazták, beleértve a képeken történő objektum-detektálást, a képfúziót, a képfelvételt, a jelenetosztályozást, a szegmentálást, az objektumalapú képelemzést, a földhasználat és a földtakaró osztályozását (*Land Use and Land Cover* - *LULC* [27]). Youme és tsai. tanulmányukban [28] egy automatikus megoldást mutatnak be az eldugott hulladéklerakók felderítésére pilóta nélküli légi járművek (*UAV*) képeinek felhasználásával a nyugat-afrikai Szenegál Saint Louis³ területén (2.9, 2.10 ábrák). Ez kihívást jelentő feladat, tekintettel az UAV-felvételek nagyon nagy térbeli felbontására (néhány centiméteres nagyságrendű) és rendkívül nagy részletességére, ami megfelelő automatikus elemzési módszereket igényel. Az általuk javasolt módszer a következőkkel kezdődik:

1. A képet négy régióra szegmentálják, amelyek bemeneti képként használhatók.
2. A bemeneti képek méretének csökkentése 300x300x3-ra a *CNN* bejegyzésekhez.
3. A kép címkézése az érdekeltségi területek meghatározásával.

Ezután *Single shot detectort* (*SSD* [29]) használnak a rendkívül egyedi jellemzők meghatározásához ezekben az adatkészletekben. Az eredmények azt mutatják, hogy a modell jól felismeri az érintett területeket, de nehézségekbe ütközik néhány olyan területen, ahol nincsenek egyértelmű alapigazságok (2.11 ábra) [28].

³Saint Louis, Szenegál - <https://goo.gl/maps/mWqm9X23HxRDzYDA7>



2.9. ábra. Saint-Louis (Szenegál) térképe, a kutatás helyszíne.
Forrás: [28]



(a) A kutatók egyetemi területén lerakott hulladék homokos háttérrel.



(b) A folyó mentén található szemét sötétebb háttérrel.

2.10. ábra. Tanító adatok gyűjtése.
Forrás: [28]



(a) A folyó menti terület 1.



(b) A folyó menti terület 2.



(c) A folyó menti terület 3.



(d) Az egyetem területe.

2.11. ábra. A detektálás néhány eredménye.
Forrás: [28]

3. fejezet

Módszertan

3.1. Tanító területek

Tanító területként a pusztazámori hulladéklerakó¹ (3.1 ábra), illetve a kiskörei vízerőmű² (3.2 ábra) területei szolgáltak. Ezeken a helyeken a műholdfelvételeken szabad szemmel is látható, nagymennyiségű hulladékkal fedett területek találhatók. A hulladéklerakóról Sentinel-2 [7], míg a vízerőműről pedig PlanetScope műholdak [10] által készített felvételek álltak rendelkezésemre, melyek különböző időpontokban készültek.

Kettő különböző módszert alkalmaztam a tanítások során. Az egyikben csak Sentinel-2 által készített felvételeket, és az ezeken elérhető sávokból számítható összes indexet használtam fel (2.3, 2.4 táblázat). A másik verzióban csak azokat a sávokat, és az ezekből számítható indexeket vettem, melyek mind a PlanetScope és Sentinel-2 felvételeken is elérhetőek (2.3 táblázat). Ennek oka az volt, hogy a végső megoldást be szerettem volna ágyazni a saját keretprogramomba (4. fejezet), mely képes Sentinel-2, illetve PlanetScope felvételek egységes feldolgozására.

Az általam betanított végső modell a *Kék, Zöld, Vörös, Közeli infravörös* sávokat, és az ezekből számítható *PI, NDWI, NDVI, RNDVI, SR* indexeket használta az osztályozási feladatok elvégzéséhez. Öt célosztályt alkalmaztam: hulladék, víz, szántóföld, mező/erdő, épület. A majdnem 200 ezer tanító adatomon keresztvalidációt (*cross-validation*) is végeztem, mely közel 96%-os pontosságot mutatott [20, 21].

¹Pusztazámori hulladéklerakó - <https://goo.gl/maps/1MNGxfXEikePNbrB8>

²Kiskörei vízerőmű - <https://goo.gl/maps/qEphzqyAXa1mU5vD7>



3.1. ábra. Pusztazámori hulladéklerakó.
Forrás: Google Earth



3.2. ábra. Kiskörei vízerőmű.
Forrás: Google Earth

3.2. Tanító címkék és döntési fák optimális száma

A *Random Forest* osztályozási modell tanításakor mindig felmerülő kérdés, hogy hány döntési fával hozzuk létre az erdőt. A *scikit-learn RandomForestClassifier* osztálya [30] egy alapértelmezett 100-as darabszámmal dolgozik. A kutatás során megvizsgáltam, hogy a fák és tanító címkék számának változtatásával mennyire pontos eredmények születnek, melyeket keresztvalidációval határoztam meg.

A tanító adataim egy részhalmazán kipróbáltam melyik tanító címke kombinációkkal lehet magasabb pontosságot elérni. A következő oldalon látható eredmények kb. 55 ezer képpont adatai alapján kerültek meghatározásra (3.3 ábra). Az "ALL" címke az összes elérhető sávra és az ezekből számítható indexekre vonatkozik, melyek a Sentinel-2 és PlanetScope felvételeken egyaránt elérhetőek (2.3 táblázat). A 48 kipróbált kombinációból ezen az adathalmazon a *Kék*, *Zöld*, *Vörös*, *Közeli infravörös* együttes felhasználása adta a legjobb eredményt. A legpontosabb kilenc kombináció került vizuális szemléltetésre, ezek nagyon hasonlóan teljesítettek. A végső eljárásban az összes sávot és indexet felhasználtam, mivel akadtak olyan felvételek, melyeken ez a kombináció jobb eredményt mutatott.


A diagramokon látható első két oszlop rendre azt mutatja meg, hogy 1 és 100 fa között 1-es léptékkal, 100 és 1000 fa között 50-es léptékkal mekkora volt a legnagyobb pontosság. Az utolsó kettő pedig szemlélteti a 100 és 1000 darab fa használata során kapott eredményeket. Ezekből az adatokból látszik, hogy az alapértelmezett 100 döntési fa az tényleg egy jó választás, mely még gyors és pontos feldolgozást eredményez. Az alábbi táblázatok szemléltetik a tanítási és osztályozási időket (3.1, 3.2 táblázatok).

Fák száma	Tanítási idő
100	6.76 sec
1000	68 sec

3.1. táblázat. *Random Forest* tanítási idő.
Felhasznált tanító adatok száma: ~190 ezer.

Kép mérete	Fák száma	Osztályozási idő
$164 \times 312 = 51168$	100	0.137 sec
	1000	1.167 sec
$1194 \times 801 = 956394$	100	3.017 sec
	1000	28.951 sec

3.2. táblázat. *Random Forest* osztályozási idő.



3.3. ábra. Tanító címkék.

3.3. Hulladékdetektálási módszerek

A szakirodalomban kevés hasonló projekttel találkoztam, ennél fogva saját felvetésekre volt szükség a probléma megoldásához. A Tiszai PET Kupa³ hulladékgyűjtő szervezet munkatársaival folyamatos konzultáció zajlott a témával kapcsolatban. Ők is tettek javaslatokat a probléma megközelítéséhez. Kutatásom során három különböző módszer megalkotására és tesztelésére került sor:


1. Hot-spotok, azaz illegális hulladéklerakók azonosítása közepes vagy nagy felbontású műholdfelvételeken a Tisza felsőbb (ukrajnai, romániai) részein, amelyekből áradáskor jelentős mennyiségű hulladék kerül a folyóba (3.3.1 alfejezet).
2. Vízfelszíni folyami torlaszok azonosítása közepes vagy nagy felbontású műholdfelvételeken, amelyek a folyó ismert helyszínein (például vízerőműveknél) tudnak kialakulni (3.3.2 alfejezet).
3. A hullámtérben ismert helyen lerakott, elsősorban műanyag hulladék detektálása nagyfelbontású műholdfelvételeken (3.3.3 alfejezet).

3.3.1. Hot-spotok detektálása

A cél az volt, hogy a folyó mentén elhelyezkedő nagyobb hulladékos területek kiterjedésének változását képesek legyünk megfigyelni. A közvetlenül a folyó partján fekvő ilyen területek ugyanis nagy veszélyforrásnak számítanak áradások idején. Ilyen esetekben a folyó elhagyja a medrét, majd mikor visszahúzódik, magával sodorja a hulladékot, és azt egy másik, nem kívánt helyen rakja le. Ilyen Tisza menti hot-spotok főként Ukrajnában, illetve Romániában találhatók. A magyar hulladékgyűjtő szervezeteknek már van tapasztalata azzal kapcsolatban, hogy mely hot-spotok esetén a Tisza mely részére kell kivonulniuk egy áradás bekövetkezte után. Amennyiben az általam készített osztályozás azt mutatja, hogy az áradást megelőző felvételen a hot-spot kiterjedése jelentős, akkor a helyszínre való kivonulás indokolt.

Az ehhez használt modell tanításában nagy szerepet játszott a pusztazámori hulladéklerakó, hiszen ehhez a területhez nagyon hasonló tulajdonságúak detektálása volt a cél. A klasszifikáláson kívül nem alkalmaztam más eljárást (3.4 ábra).

³PET Kupa - https://petkupa.hu/hu_HU/



(a) Osztályozás előtt, Forrás:
<https://scihub.copernicus.eu/>


(b) Osztályozás után

3.4. ábra. A pusztazámori tanító terület osztályozása.


3.3.2. Vízfelszíni folyami torlaszok detektálása

Vízfelszíni folyami torlaszok elsősorban vízerőműveknél, illetve gátnál tudnak kialakulni. Egy ilyen torlasz kiterjedése elérhet akár több ezer négyzetmétert is. Ezek detektálásában nagy segítséget jelentettek a kiskörei vízerőműről készült felvételek, mivel ott gyakran nagy területű szemétsziget akad el.

A kívánt eredmény eléréséhez az osztályozáson kívül még morfológiai transzformációkra is szükség volt (3.5 ábra). A klasszifikált felvételtől készítettem egy bináris képet: a hulladék és víz osztályokat egy csoportba vettem, minden mást pedig lehagytam a képről. Az eredményen végrehajtottam egy morfológiai nyitást annak érdekében, hogy a zajokat (kisebb területek melyek a folyótól távolabb esnek) eltávolítsam. Majd ezt követte egy dilatáció, hogy a megmaradt területek körvonalát kiszélesítsem. Ezekhez egy 5×5 -ös mátrixot használtam kernelként. Így a végeredményen főként már csak a folyó és a rajta lebegő szemétsziget maradt (3.6 ábra).



3.5. ábra. Morfológiai transzformációk.
Forrás: <https://docs.opencv.org/>



3.6. ábra. A kiskörei vízerőmű szeméttorlaszának detektálása.
Az osztályozás előtti kép forrása: <https://www.planet.com/>

3.3.3. A hullámtérben ismert helyen lerakott hulladék detektálása

Ennél a módszernél nem volt célszerű osztályozási modellt alkalmazni. Ennek oka, hogy a hullámtérben lerakott műanyag hulladék nagyon kis kiterjedésű, nem rendelkezik a tanító területeken szereplő szemét tulajdonságaival. Itt nem összefüggő szennyezett területekről beszélünk, hanem elszórt, esetleg más anyagokkal keveredett (pl. uszadékfa, jég) hulladékról (3.7, 3.8 ábrák).

Ezért egy másik megközelítést kellett alkalmaznom. Itt csak a *Plastic Index* [14] értékeit figyeltem, azt a tulajdonságát kihasználva, hogy a hulladékkal fedett területek *PI* értéke magasabb, mint más területeké. De ez még önmagában kevésnek bizonyult, így a végső kiértékeléshez két felvételre van szükségünk, méghozzá ugyanazon területről más időpillanatban készült felvételekre. A feldolgozás algoritmus a következő:

1. Meghatározzuk a két kép földrajzi metszetét (4.1.2 alfejezet), ennek mérete legyen $n \times m$.
2. Számoljuk ki mindkét kimetszett képre a műanyag indexet, ezeket tároljuk rendre A és B mátrixokban.
3. Legyen $D = A - B$ különbség mátrix (ld. 3.9 ábra) és legyen $m = \text{median}(D)$, amelyet küszöbértéknek (*threshold*) fogunk választani az algoritmus következő lépésében.
4. Legyen X is egy $n \times m$ méretű mátrix. Ekkor $\forall i \in [1, n] \forall j \in [1, m]$:

$$X_{i,j} := \begin{cases} D_{i,j} - m & D_{i,j} > m \\ 0 & D_{i,j} \leq m \end{cases}$$

5. Hasonlóan legyen Y is egy $n \times m$ méretű mátrix. Ekkor $\forall i \in [1, n] \forall j \in [1, m]$:

$$Y_{i,j} := \begin{cases} 0 & D_{i,j} > m \\ m - D_{i,j} & D_{i,j} \leq m \end{cases}$$


Így X mátrixban a korábban készült felvételhez tartozó magas *PI* értékek szerepelnek, míg az Y mátrixban a később készült képhez tartozó magasak. Amikor az elsőn magasabb, az azt jelenti, hogy korábban ott feltehetőleg valamilyen műanyag hulladék volt, ami eltávolításra került. Mikor a másodikon magasabb, akkor pedig időben később került oda valamilyen hulladék (3.10 ábra).



3.7. ábra. Hulladékgyűjtési akció.
Forrás: PET Kupa



3.8. ábra. Tiszai jeges ár 2017 februárjában.
Forrás: [3]



3.9. ábra. A *Plastic Index* különbsége tiszaszalkai felvételeken, 2019 március.
A műholdfelvételek forrása: <https://www.planet.com/>



3.10. ábra. A különbség eltérése a középértéktől hulladékgyűjtés során - Tiszaszalka, 2019 március.
A háttérben látható műholdfelvétel forrása: <https://www.planet.com/>

4. fejezet


Implementáció

A módszertan megvalósításához szükséges prototípus alkalmazást *Python (3.8)* nyelven készítettem el. Elsősorban azért, mert képfeldolgozásban széles körben alkalmazott, számtalan hasznos szoftverkönyvtár érhető el hozzá.

MVC (Model-View-Controller) architektúrát (4.1 ábra) alkalmaztam az implementáció során (4.6 osztálydiagram). Az osztályozási modelleim megalkotásához a *scikit-learn RandomForestClassifier* osztályát [30] használtam.


Az alkalmazásban lehetőség nyílik a műholdfelvételek feldolgozására a 3. fejezetben tárgyalt módszerek segítségével. A folyamatok befejezése után a felhasználó képes az eredmények böngészésére, megjelenítésére (4.2, 4.3 ábrák). Opcionálisan statisztika készíthető a hulladékkal fedett területek kiterjedésének becsléséről, ahol külön kategóriákba vannak szedve az osztályozott, illetve a hőterképen látható területek (4.4 ábra). Ha a felhasználó nincs megelégedve az általam betanított osztályozási modellel, akkor tud sajátot készíteni egy interaktív vizuális felület segítségével (4.5 ábra).

A forráskódok elérhetőek a kari GitLab szerveren, a következő címen:
<https://gitlab.inf.elte.hu/lechner/summer-lab-2021/project-5>




4.1. ábra. *MVC* architektúra.


Forrás: <https://openclassrooms.com/>




4.2. ábra. Oszályozott képek megjelenítése.




4.3. ábra. Hőterkép (*Heatmap*) képek megjelenítése.



4.4. ábra. Statisztika a hulladékkal fedett területek kiterjedésének becsléséről.



4.5. ábra. *Random Forest* modell tanító felület.



4.6. ábra. Az alkalmazás osztálydiagramja.

4.1. Érdekesebb algoritmusok

4.1.1. Iteratív *Flood fill* algoritmus

Az egybefüggő hulladékkal fedett területek meghatározásához szükségem volt egy olyan algoritmusra, amelyik hatékonyan működik nagyobb méretű felvételekkel is. Ehhez a jól ismert *Flood fill* algoritmust választottam [31]. Először próbálkoztam rekurzív módszerrel, de hamar kiderült, hogy gyorsan meghaladja a maximális rekurzív mélységet a legtöbb felvétel esetében. Ezért az algoritmus iteratív változatát alkalmaztam (4.1, 4.2 forráskódok) [32].

```

1 @staticmethod
2 def _is_search_value(matrix: np.ndarray, row: int, col: int,
3     search_value: List[int]) -> bool:
4     if not Model._valid_row(matrix.shape, row):
5         return False
6
7     if not Model._valid_col(matrix.shape, col):
8         return False
9
10    if matrix[row, col] in search_value:
11        return True
12    else:
13        return False

```

4.1. forráskód. Segédfüggvény a keresett érték validálására.

```

1 @staticmethod
2 def _iterative_flood_fill(matrix: np.ndarray, row: int, col: int,
3     search_value: List[int]) -> Union[List[
4         Tuple[int, int]], None]:
5     if not Model._valid_row(matrix.shape, row):
6         return
7
8     if not Model._valid_col(matrix.shape, col):
9         return
10
11    if matrix[row, col] not in search_value:
12        return
13
14    q = list() # init empty queue (FIFO)

```

```
14     matrix[row, col] = -1 # mark as visited
15     q.append([row, col]) # add to queue
16     region = list()
17
18     while len(q) > 0:
19         [cur_row, cur_col] = q[0]
20         region.append(tuple(q[0]))
21
22         del q[0]
23
24         if Model._is_search_value(matrix, cur_row - 1, cur_col,
25                                   search_value):
26             matrix[cur_row - 1, cur_col] = -1
27             q.append([cur_row - 1, cur_col])
28
29         if Model._is_search_value(matrix, cur_row + 1, cur_col,
30                                   search_value):
31             matrix[cur_row + 1, cur_col] = -1
32             q.append([cur_row + 1, cur_col])
33
34         if Model._is_search_value(matrix, cur_row, cur_col - 1,
35                                   search_value):
36             matrix[cur_row, cur_col - 1] = -1
37             q.append([cur_row, cur_col - 1])
38
39         if Model._is_search_value(matrix, cur_row, cur_col + 1,
40                                   search_value):
41             matrix[cur_row, cur_col + 1] = -1
42             q.append([cur_row, cur_col + 1])
43
44     return region
```

4.2. forráskód. Iteratív *Flood fill* algoritmus.

4.1.2. Két különböző felvétel közös földrajzi koordinátákkal rendelkező metszetének meghatározása

A hullámtérben ismert helyen lerakott hulladék detektálásakor egy érdekes problémába ütköztem. Ennél a módszernél szükségünk van a két felvétel *Plastic Index* [14] különbségének meghatározására. Ez minden esetben a képeket reprezentáló mátrixok egymásból

való kivonásával történik. Viszont, ha két különböző méretű felvételt szeretnénk feldolgozni, vagy ezek nem teljes mértékben fedik egymást, akkor szükségünk lesz a két kép földrajzi koordináták szerinti metszetére. Ezen probléma egy megoldását szemlélteti az alábbi kódrészlet (4.3).

```

1 @staticmethod
2 def _get_empty_intersection_matrix_and_start_coords(
3     input_path_1: str, input_path_2: str) -> Union[Tuple[np.
4         ndarray, Tuple], Tuple[None, None]]:
5     coords_1 = Model._calculate_coords_for_pixels(input_path_1)
6     coords_2 = Model._calculate_coords_for_pixels(input_path_2)
7
8     if (coords_1 is not None) and (coords_2 is not None):
9         img_1_size = coords_1.shape[0] * coords_1.shape[1]
10        img_2_size = coords_2.shape[0] * coords_2.shape[1]
11
12        larger_img = coords_1 if img_1_size >= img_2_size else
13            coords_2
14        smaller_img = coords_1 if img_1_size < img_2_size else
15            coords_2
16
17        selector = np.in1d(larger_img.flatten(), smaller_img.
18            flatten())
19        intersection = list(compress(range(len(selector)), selector
20            ))
21
22        new_rows, new_cols = 0, 0
23
24        if intersection:
25            larger_rows, larger_cols = np.unravel_index(
26                intersection, larger_img.shape)
27            larger_start_index = (larger_rows[0], larger_cols[0])
28
29            start_coord = larger_img[larger_start_index]
30
31            smaller_start_index = np.where(smaller_img ==
32                start_coord)
33            smaller_start_index = smaller_start_index[0][0],
34                smaller_start_index[1][0]

```

```
28     i, j = larger_start_index
29     k, l = smaller_start_index
30
31     while i < larger_img.shape[0] and k < smaller_img.shape
32         [0]:
33         new_rows += 1
34         i += 1
35         k += 1
36
37     while j < larger_img.shape[1] and l < smaller_img.shape
38         [1]:
39         new_cols += 1
40         j += 1
41         l += 1
42
43     intersection_matrix = np.ndarray(
44         shape=(new_rows, new_cols),
45         dtype="float64",
46     )
47
48     coords_information = (start_coord, larger_start_index,
49         smaller_start_index)
50
51     return intersection_matrix, coords_information
52
53 return None, None
```

4.3. forráskód. A metszet mátrix meghatározása.

5. fejezet

Eredmények

Ebben a fejezetben bemutatásra kerül a kifejlesztett módszerek néhány eredménye. Amelyiknél lehetett, ott több mintaterület kerül szemléltetésre. Az ősszel és télen készült felvételek osztályozása nem ad jó eredményeket, ennek oka, hogy a rossz időjárási körülmények miatt nem készült olyan felvétel, ami érdemben alkalmazható lett volna tanításra. Az alább látható eredmények tavaszi, illetve nyári felvételek feldolgozása során keletkeztek.

Az osztályozott képeken a legfontosabb szín a piros, mivel ez jelöli a modell szerint hulladékkal fedett területeket (5.1 táblázat). A hőtérképeken pedig a szemetes területek egy részhalmaza látható. Ezeken a színek azokat a valószínűségeket jelentik, hogy a modell mennyire volt biztos a döntésében (5.2 táblázat).

Osztály	Szín
hulladék	piros 
víz	kék 
erdő/mező	zöld 
épület	szürke 
szántóföld	barna 

5.1. táblázat. Osztályok és színezésük.

Valószínűség	Szín
90% - 100%	piros 
80% - 90%	sárga 
70% - 80%	zöld 

5.2. táblázat. Hőtérkép valószínűségei és színezésük.

5.1. Hot-spot detektálása

Ennél a módszernél csak egy osztályozásból állt a folyamat. Az 5.1-es ábrán látható a Depónia Hulladékkezelő Központ¹ területének osztályozása. Míg az 5.2-es ábrán a PET Kupa² szervezet munkatársai által megjelölt egyik terület, a romániai Kányaházi tó³ található, amit potenciális veszélyforrásként kezelnek hot-spotok kialakulása szempontjából. Mindegyik osztályozás viszonylag pontosnak mondható.

5.2. Vízfelszíni folyami torlaszok detektálása

Ez a módszer adta a leglátványosabb eredményeket. Az osztályozott képeken szereplő hulladékkal borított területek (piros) jól elkülönülnek környezetüktől (5.3, 5.4 ábrák). A folyó partján látható piros foltok, melyek nem érintkeznek vízzel (kék), eliminálását megfontoltam, azonban arra a következtetésre jutottam, hogy mégis rajtahagyom őket a végső képeken. Ennek oka az volt, hogy előfordultak olyan esetek, mikor a szemétsziget osztályozása során nem vízzel érintkezett, hanem egyéb más osztályokkal. Ebben az esetben a tényleges hulladék is eltávolításra került volna.

5.3. A hullámtérben ismert helyen lerakott hulladék detektálása

Ez a módszer adta a legkevésbé látványos eredményeket, hiszen itt nagyon kis kiterjedésű hulladékkal fedett területekről beszélünk. Az eredmény képeken fehér ellipszisekben szereplő fehér képpontok a nagyon magas PI [14] értékkel rendelkezők, melyekből láthatóan csak néhány darab van (5.5 ábra). Ezen pixelek mérete növelésre került, hogy jobb vizuális élményt nyújtsanak, ennél kisebb területet fednek le a valóságban. A PET Kupa hulladékgyűjtő szervezettel való egyeztetés során arra a következtetésre jutottunk, hogy ezek akár valós adatok is lehetnek, mivel az első felvétel az közvetlenül egy hulladékgyűjtő akció előtt, míg a második közvetlenül utána készült. Más felvételeken viszont nem sikerült biztos eredményeket elérni.


¹Depónia Hulladékkezelő Központ - <https://goo.gl/maps/v5vhPBkppjJRAfTuG6>

²PET Kupa - https://petkupa.hu/hu_HU/


³Kányaházi tó - <https://goo.gl/maps/TZN3eiPZYaCZgZju6>



(a) Folyamat előtt, Forrás:
<https://scihub.copernicus.eu/>



(b) Folyamat után




(c) Heatmap


5.1. ábra. Depónia Hulladékkezelő Központ, Magyarország - 2019.06.27.



(a) Folyamat előtt, Forrás: <https://www.planet.com/>




(b) Folyamat után




(c) Heatmap

5.2. ábra. Kányaházi tó, Románia - 2020.09.16.



5.3. ábra. Kiskörei vízerőmű, Magyarország - 2019.07.02.



5.4. ábra. Kiskörei vízerőmű, Magyarország - 2020.07.23.



(a) Hulladékgyűjtés előtt magas

(b) Hulladékgyűjtés után magas

5.5. ábra. A hullámtérben ismert helyen lerakott hulladék detektálása eredmény.
A különbség eltérése a középértéktől - Tiszaszalka, 2019 március. A háttérben látható
műholdfelvétel forrása: <https://www.planet.com/>

6. fejezet

Összefoglaló

A kutatás célja olyan hulladékdetektálási módszerek tesztelése és fejlesztése volt, melyek a gyakorlatban is használhatóak, és a hulladékgyűjtő szervezetek munkáját megkönnyítik. Az ehhez elkészített megoldás kompatibilis bármilyen legalább négy sávval rendelkező műholdfelvétellel, melynek kötelezően tartalmaznia kell a *Kék, Zöld, Vörös, Közeli infravörös* sávokat.

A betanított *Random Forest* osztályozási modell főként tavasszal és nyáron készült felvételekkel működik jól, melynek oka, hogy télen és ősszel az időjárási körülmények nem megfelelőek, ilyenkor általában túl felhős képek készülnek, így azokat nem lehetett a tanításban alkalmazni.

A legjobb eredményeket a vízfelszíni folyami torlaszok detektálásával lehetett elérni. Itt az osztályozott képeken jól láthatóan elkülönül a vízfelszínen lebegő szemétsziget a környezetétől. A legkevésbé látványos eredményeket pedig a hullámtérben ismert helyen lerakott hulladékok észlelése produkálta.

Továbbfejlesztési lehetőségnek a modell nagyon nagy mennyiségű adat felhasználásával való továbbtanítását látom. Valamint a felvételek feldolgozását lehetne párhuzamos módon is folytatni, mely a feldolgozási idő csökkenését eredményezhetné. A hullámtérben ismert helyen lerakott hulladékok detektálásának pontossága még javítható lenne, ez az irány további kutatást igényel.

Összegzésként elmondhatjuk, hogy a bemutatott módszerek akár a gyakorlatban is alkalmazhatóak egy olyan végfelhasználót feltételezve, aki a legjobb tudása szerint megítéli a kapott eredményeket, azokat körültekintően használja fel.

Köszönetnyilvánítás

A kutatási munka az ELTE Informatikai Kar¹ és az InforNess Training Kft.² pénzügyi, valamint a Lechner Tudásközpont³ és a Tiszai PET Kupa⁴ hulladékgyűjtő szervezet szakmai támogatásával valósult meg. A PlanetScope műholdfelvételek a Planet Labs Inc. *Education and Research Program*-ja keretében kerültek a kutatáshoz biztosításra [33].

¹ELTE Informatikai Kar - <https://inf.elte.hu/>

²InforNess Training Kft. - <https://www.inforness.hu/>

³Lechner Tudásközpont - <https://lechnerkozpont.hu/>

⁴PET Kupa - https://petkupa.hu/hu_HU/

Irodalomjegyzék

- [1] Katona Gábor. “A Tisza folyó hulladékszennyezése”. *Műszaki Katonai Közlöny* 29.4 (2019), 65–80. old.
- [2] PET Kupa. *PET PALACK ÁRADAT*. https://petkupa.hu/hu_HU/pet-palack-aradat. Hozzáférve: 2022-05-09.
- [3] *A legsúlyosabb képek a tiszai jeges árról*. <https://index.hu/belfold/2017/02/17/a-legsulyosabb-kepek-a-tiszai-jeges-arrol/>. Hozzáférve: 2022-05-09. 2017.
- [4] Sk. Sazid Mahammad és R. Ramakrishnan. *GeoTIFF - A standard image file format for GIS applications*. <https://www.geospatialworld.net/article/geotiff-a-standard-image-file-format-for-gis-applications/>. Hozzáférve: 2022-05-05. 2009.
- [5] James D. Murray és William VanRyper. “Encyclopedia of graphics file formats”. *TIFF*. Bonn és Sebastapol, CA: O’Reilly & Associates, 1996, 880–908. old.
- [6] ESA. *Europe’s Copernicus programme*. https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Europe_s_Copernicus_programme. Hozzáférve: 2022-05-05. 2014.
- [7] Earth Online. European Space Agency. *Sentinel-2*. <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>. Hozzáférve: 2022-05-05.
- [8] Earth Online. European Space Agency. *Spot*. <https://earth.esa.int/eogateway/missions/spot>. Hozzáférve: 2022-05-05.
- [9] Earth Online. European Space Agency. *Landsat*. <https://earth.esa.int/eogateway/missions/landsat>. Hozzáférve: 2022-05-05.
- [10] Earth Online. European Space Agency. *PlanetScope*. <https://earth.esa.int/eogateway/missions/planetscope>. Hozzáférve: 2022-05-05.

- [11] Earth Online. European Space Agency. *Sentinel-2 MultiSpectral Instrument (MSI) Overview*. <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>. Hozzáférve: 2022-05-05.
- [12] GISGeography. *Sentinel 2 Bands and Combinations*. <https://gisgeography.com/sentinel-2-bands-combinations/>. Hozzáférve: 2022-05-05.
- [13] Planet. *PLANET IMAGERY PRODUCT SPECIFICATIONS*. Hozzáférve: 2022-05-05. 2019. URL: <https://assets.planet.com/docs/combined-imagery-product-spec-final-may-2019.pdf>.
- [14] Kyriacos Themistocleous és tsai. “Investigating Detection of Floating Plastic Litter from Space Using Sentinel-2 Imagery”. *Remote Sensing* 12.16 (2020). ISSN: 2072-4292. URL: <https://www.mdpi.com/2072-4292/12/16/2648>.
- [15] Tom M. Mitchell. *Machine Learning*. New York: McGraw-Hill, 1997. ISBN: 978-0-07-042807-2.
- [16] Stuart J. Russell és Peter Norvig. *Artificial Intelligence: A Modern Approach*. London: Pearson Education, 2016.
- [17] E. Alpaydin. *Introduction to Machine Learning, third edition*. Adaptive Computation and Machine Learning series. MIT Press, 2014. ISBN: 9780262325752. URL: <https://books.google.hu/books?id=7f5bBAAQBAJ>.
- [18] Tarczali Tamás. “Drónnal rögzített légifelvételek klaszterező algoritmusainak elemzése”. Dipl. Eötvös Loránd Tudományegyetem, 2021.
- [19] Gérard Biau és Erwan Scornet. “A Random Forest Guided Tour”. *TEST* 25 (2015. nov.). DOI: 10.1007/s11749-016-0481-7.
- [20] M. Stone. “Cross-Validatory Choice and Assessment of Statistical Predictions”. *Journal of the Royal Statistical Society: Series B (Methodological)* 36.2 (1974), 111–133. old. URL: <https://rss.onlinelibrary.wiley.com/doi/abs/10.1111/j.2517-6161.1974.tb00994.x>.
- [21] scikit learn. *Cross-validation: evaluating estimator performance*. https://scikit-learn.org/stable/modules/cross_validation.html. Hozzáférve: 2022-05-07.
- [22] Field Spectroscopy Facility. *SVC HR-1024i Field Spectroradiometer*. https://fsf.nerc.ac.uk/instruments/svc_hr-1024i.shtml. Hozzáférve: 2022-05-05.

- [23] Robert Page és tsai. “Identification of Tyre and Plastic Waste from Combined Copernicus Sentinel-1 and -2 Data”. *Remote Sensing* 12.17 (2020). ISSN: 2072-4292. URL: <https://www.mdpi.com/2072-4292/12/17/2824>.
- [24] Earth Online. European Space Agency. *Sentinel-1*. <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1>. Hozzáférve: 2022-05-05.
- [25] Yann LeCun, Yoshua Bengio és Geoffrey Hinton. “Deep learning”. *Nature* 521.7553 (2015), 436–444. old. ISSN: 1476-4687. URL: <https://doi.org/10.1038/nature14539>.
- [26] M.V. Valueva és tsai. “Application of the residue number system to reduce hardware costs of the convolutional neural network implementation”. *Mathematics and Computers in Simulation* 177 (2020), 232–243. old. ISSN: 0378-4754. URL: <https://www.sciencedirect.com/science/article/pii/S0378475420301580>.
- [27] SEDAC. *Land Use and Land Cover (LULC)*. <https://sedac.ciesin.columbia.edu/data/collection/lulc>. Hozzáférve: 2022-05-05.
- [28] Ousmane Youme és tsai. “Deep Learning and Remote Sensing: Detection of Dumping Waste Using UAV”. *Procedia Computer Science* 185 (2021). Big Data, IoT, and AI for a Smarter Future, 361–369. old. ISSN: 1877-0509. URL: <https://www.sciencedirect.com/science/article/pii/S1877050921011224>.
- [29] Sik-Ho Tsang. *SSD — Single Shot Detector (Object Detection)*. <https://towardsdatascience.com/review-ssd-single-shot-detector-object-detection-851a94607d11>. Hozzáférve: 2022-05-05. 2018.
- [30] scikit learn. *sklearn.ensemble.RandomForestClassifier*. <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>. Hozzáférve: 2022-05-07.
- [31] Alvy Ray Smith. “Tint Fill”. *SIGGRAPH Comput. Graph.* 13.2 (1979), 276–283. ISSN: 0097-8930. URL: <https://doi.org/10.1145/965103.807456>.
- [32] Goran Trlin. *Flood fill algorithm in Python*. <https://playandlearntocode.com/article/flood-fill-algorithm-in-python>. Hozzáférve: 2022-05-07.
- [33] Planet Team. *Planet Application Program Interface: In Space for Life on Earth*. <https://api.planet.com/>. San Francisco, CA. 2017.

Ábrák jegyzéke

2.1. Egy betanított döntési fa, és a felhasznált tanító adathalmaz.	9
2.2. <i>Random Forest</i> döntéshozatal.	10
2.3. Keresztvalidáció.	11
2.4. A műanyag palackokból elkészített céltárgy.	12
2.5. A céltárgy tengerre bocsátása.	13
2.6. A céltárgy detektálása.	13
2.7. A tanító terület Skóciában.	14
2.8. Példa Skóciában történt detektálásra.	15
2.9. Saint-Louis (Szenegál) térképe, a kutatás helyszíne.	17
2.10. Tanító adatok gyűjtése.	17
2.11. A detektálás néhány eredménye.	18
3.1. Pusztazámori hulladéklerakó.	20
3.2. Kiskörei vízerőmű.	20
3.3. Tanító címkék.	22
3.4. A pusztazámori tanító terület osztályozása.	24
3.5. Morfológiai transzformációk.	25
3.6. A kiskörei vízerőmű szeméttorlaszának detektálása.	25
3.7. Hulladékgyűjtési akció.	27
3.8. Tiszai jeges ár 2017 februárjában.	27
3.9. A <i>Plastic Index</i> különbsége tiszaszalkai felvételeken, 2019 március. . . .	28
3.10. A különbség eltérése a középértéktől hulladékgyűjtés során - Tiszaszalka, 2019 március.	28
4.1. <i>MVC</i> architektúra.	29
4.2. Osztályozott képek megjelenítése.	30
4.3. Hőtérkép (<i>Heatmap</i>) képek megjelenítése.	31
4.4. Statisztika a hulladékkal fedett területek kiterjedésének becsléséről. . . .	32

4.5. <i>Random Forest</i> modell tanító felület.	32
4.6. Az alkalmazás osztálydiagramja.	33
5.1. Hot-spot detektálás eredmény 1	40
5.2. Hot-spot detektálás eredmény 2	41
5.3. Vízfelszíni folyami torlaszok detektálása eredmény 1	42
5.4. Vízfelszíni folyami torlaszok detektálása eredmény 2	42
5.5. A hullámtérben ismert helyen lerakott hulladék detektálása eredmény. . .	43

Táblázatok jegyzéke

2.1. Sentinel-2 sávok	7
2.2. PlanetScope sávok	7
2.3. Felhasznált indexek kiszámítása	7
2.4. Egyéb indexek kiszámítása	8
3.1. <i>Random Forest</i> tanítási idő.	21
3.2. <i>Random Forest</i> osztályozási idő.	21
5.1. Osztályok és színezésük.	38
5.2. Hőterkép valószínűségei és színezésük.	38

Algoritmusjegyzék

1. A *Random Forest* algoritmus predikciós eljárásának pszeudokódja, amely egy korábban betanított modellt (*forest*) használ az X felvétel osztályozására. 10

Forráskódjegyzék

4.1. Segédfüggvény a keresett érték validálására.	34
4.2. Iteratív <i>Flood fill</i> algoritmus.	34
4.3. A metszet mátrix meghatározása.	36