

EÖTVÖS LORÁND TUDOMÁNYEGYETEM
TERMÉSZETTUDOMÁNYI KAR

Multispektrális képfeldolgozás, nyílt forráskódú alkalmazások segítségével

SZAKDOLGOZAT
TÉRKÉPÉSZ MESTERSZAK

Készítette:

Sipos Kristóf

Témavezető:

Dr. Jung András

habilitált egyetemi docens

ELTE Térképtudományi és Geoinformatikai Intézet



Budapest, 2022

Tartalom

Bevezetés.....	3
Sentinel-2	5
Orfeo ToolBox	7
OpenCV	9
Shark programkönyvtár.....	9
LibSVM.....	10
Az osztályozás folyamata az OTB-ben	11
Bayes féle osztályozás.....	12
K-legközelebbi szomszéd (K-means neighbors, KNN)	12
LibSVM.....	13
Döntési fa (Decision tree, DT)	14
Boosting (Erősítő/gyorsító eljárás).....	15
Véletlen erdő (Random forest, RF)	16
A Random Forests legnagyobb előnyei:	17
Shark.....	18
Az eredmények kiértékelése, pontosság-mérés	19
Pontosság becslés - Accuracy assesement.....	19
Zavar mátrix (Confusion mátrix)	19
Cohen féle kappa együttható	20
A felügyelt osztályozások összehasonlítása	21
Konklúzió	41
Irodalomjegyzék.....	42
Ábrajegyzék	43
Köszönetnyilvánítás	44

Bevezetés

A térinformatikában és a térképészeti gyakorlatban jelentősek a kiforrott, megbízható nyílt hozzáférésű szoftver-eszközrendszerek, amelyekkel kutatásokban, vizsgálatokban eredményesen felhasználhatók. Dolgozatom célja az eredetileg a Francia Űrügynökség, a CNES által kifejlesztett Orfeo Tool Box (OTB) rendszer bemutatását tűztem ki ezen belül a multispektrális képelemzésre helyeztem a hangsúlyt. E fő célkitűzésen belül is az ellenőrzött osztályozás, melyet egy egyszerű feladaton és adatmintán keresztül szeretnék szemléltetni. Igyekszem bemutatni az OTB által nyújtott lehetőségeket, melyeket úrfelvételek és más spektrális adatok osztályozásában nyújt, kiemelve a program erősségeit, és legfőbb sajátosságait.

Mivel tanulmányaimnak nem képezi tárgyát a mesterséges intelligencia mély ismerete, ezért nem rendelkezem átfogó háttértudással az alakfelismerési és döntésméleti háttérrel illetően, valamint a bemutatott szoftverek kialakításáról szóló szakcikkekben megfogalmazott eljárások kritikai elemzésének képességével, ám ezen kérdések részletezése nyilvánvalóan messze meg is haladná egy térképész mesterdiploma kereteit. Ezért az OTB programcsomag technikai üzembe állítására koncentrálhattam, valamint egy példán keresztül funkciói végrehajtását mutatom be.

Ilyen mennyiségű és nehezen értelmezhető tartalmi háttér mellett meg kellett elégednem az eszközrendszer használatának gyakorlati megismerésével és e dolgozatban történő átfogó bemutatásával, és be kellett látnom, hogy nem lehetséges a dolgozat keretein belül egy tematikus végeredmény optimalizálását kitűzni.

Az eszközrendszereket igyekeztem átfogóan bemutatni. A kitűzött demonstrációs példám során kapott eredményeket értelmeztem, és amely részleteket relevánsnak tartottam, azokat be is mutatom ebben a dolgozatban. A feldolgozás során elvégzett lépéseket szükség szerint, szelektíven igyekeztem bemutatni.

A munka során felmerült kísérletezések, akadályok elhárítása, valamint a paramétervizsgálatok egyrészt a munka elkerülhetetlen velejárói, másrészt szétfordultak volna a tárgyalás és kifejtés így is meglehetősen nehezen követhető logikai szerkezetét, így ezekre nem tértem ki.

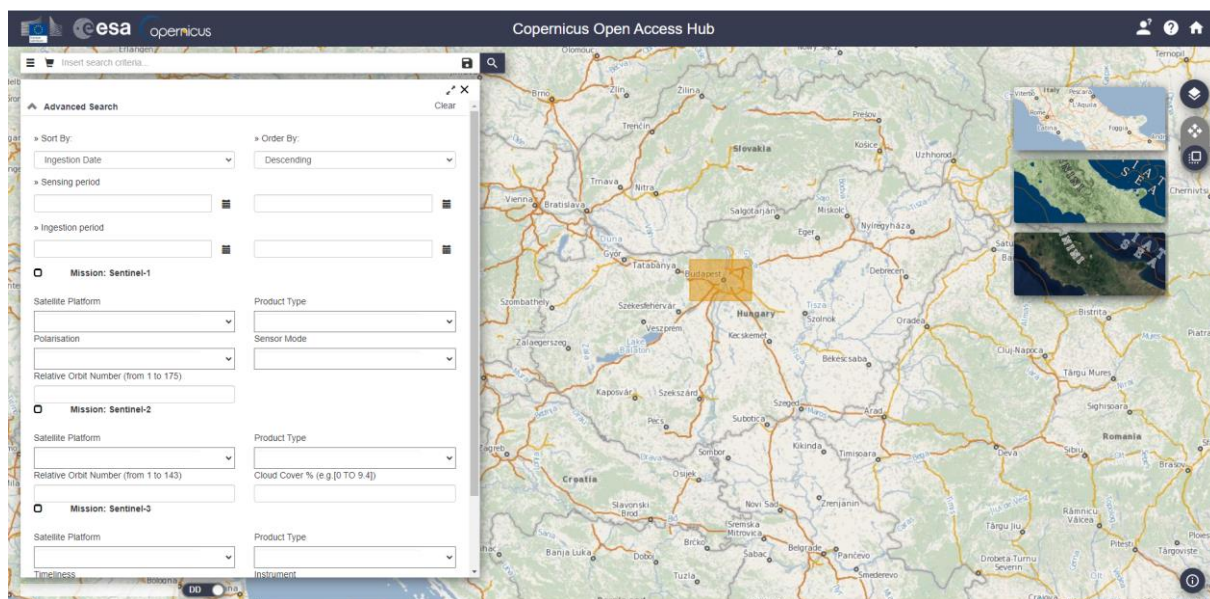
A fejezetek a feldolgozás logikájának felelnek meg, azt követik.

Pixel alapú osztályozás

Az osztályozás alapja a felvétel minden egyes pixelének, valamint annak területéről visszaverődő sugárzás intenzitáson alapuló véges számú osztályba történő számítógépes eljárások általi besorolása meghatározott algoritmusokkal. A besorolás történhet ellenőrzött

módon (supervised), amikor a felhasználó által előre meghatározott tematikus kategóriákba történik a besorolás, valamint történhet kevésbé ellenőrzött módon (unsupervised), amikor az egymástól kellően eltérő sugárzás intenzitások egy-egy új csoportot alkotnak. A szükséges eltérés megadása, továbbra is a felhasználó feladata.

A dolgozat további részeihez szükséges felvételek a Sentinel-2 műholdakról származnak. A felvételek regisztrációt követően ingyenesen letölthetők az Európai Űrügynökség honlapjáról.



1.ábra A Sentinel-2 felvételek letöltésére szolgáló honlap kezelőfelülete

Sentinel-2

A Sentinel-2-es műholdakat az Európai Űrügynökség (ESA) a Kopernikusz program keretében (Sentinel-2A 2015 június 23.-án és Sentinel-2B 2017 március 7.-én) lőtte fel. A két műhold közös napszinkron pályán egymástól 180 fokos szögben eltolva, átlagosan 786 km magasan. A pályájuk dőlése $98,62^\circ$, visszatérési idejük 10 nap/ műhold, ami 2 hold estén 5 napra csökken. Letapogatás sávjuk 290 km. A műholdak által vizsgált terület az északi szélesség $82,8^\circ$ és déli szélesség 56° fok közötti szárazföldeket és part közeli vizeket fedi le 20 km-es távolságig. Emellett minden 100 négyzetkilométernél nagyobb szigetet, az Európai Unió tagországaikhoz tartozó szigetet, valamint a Földközi tengert és a beltengereket foglalja magába.

Céljuk a földfelszín borításának, valamint annak változásainak észlelése úgy, mint a levél területi index (Leaf Area Index, LAI), a levél klorofil tartalom (Leaf Chlorophyll Content, LCC), vagy a növény fedettség (Leaf Cover, LC). Ezekkel az indexekkel képet kaphatunk a növényzet állapotáról és a vízkörforgásról, ezzel segítve a területrendezést, erdő- és vízgazdálkodást, valamint a mezőgazdaságot.

Fontos szerepe van a katasztrófavédelemben is, mind az előrejelzésben, mind a kárbecslésben. Gyakori visszatérési idejének (5 nap) és nagy térbeli felbontásának köszönhetően alkalmas városi környezetben a katasztrófák (pl.: földrengés, árvíz) előtti és utáni állapotok felmérésére, segélyek megszervezésére és célba juttatására.

Az elkészült műholdképek fontos határvédelmi célokat is ellátnak, ezzel csökkentve az illegális bávándorlásokat a szárazföldön és a tengeren, valamint a hajótörést szenvedett migránsok megtalálására és megmentésére is alkalmas lehet. Az Uniós határ védelme mellett használható az országok közti határokon átívelő bűnözés nyomon követésére és a biztonság növelésére is. A felvételeket felhasználhatják a klímaváltozás okainak és annak hatásainak megfigyelésére, mivel gyakori visszatérési ideje miatt jó eséllyel készíthetünk felhőmentes felvételeket még a sűrű felhőzettel rendelkező trópusi éghajlati területekről is, ezzel nyomon követhető az esőerdők állapotát és az erdőirtásokat.

A Jegyes-tengeri hajózási útvonalak megfigyelésével, a leszakadó jéghegyek nyomon követésével éppúgy, mint a partmenti területeken a zátonyok és homokpadok monitorizálásával, valamint a partok melletti globális vízemelkedés nyomon követésével a felvételek fontos segítséget nyújtanak a tengeri kereskedelemnek is.

A Sentinel-2 műholdak fel vannak szerelve egy-egy MultiSpectral Instrument (MSI) szenzorral. Ez egy push-broom elven működő szenzor, ami haladása során passzívan gyűjti a visszavert sugárzási adatokat. Tervezésekor fontos szempont volt a nagy térbeli és spektrális felbontás,

valamint az, hogy az elkészült felvételek kompatibilisek legyenek a SPOT és LANDSAT műholdak felvételeivel, ezzel biztosítva a Kopernikusz program folytonosságát. Ennek eléréséhez a helyi átvonulási időt 10:30-ban határozták meg, ami majdnem azonos a SPOT 5 -ével és közel áll a LANDSAT-hoz is.

A Sentinel műholdak MSI szenzorának spektrális sávjai

Sávok	Sentinel-2A		Sentinel-2B		Térbeli felbontás(m)
	Hullámhossz közepe (nm)	Sávszélesség	Hullámhossz közepe (nm)	Sávszélesség	
1 - Tengerparti aeroszol	442,7	21	442,3	21	60
2 - Kék	492,4	66	492,1	66	10
3 - Zöld	559,8	36	559,0	36	10
4 - Vörös	664,6	31	665,0	31	10
5 - Vörös él	704,1	15	703,8	16	20
6 - Vörös él	740,5	15	739,1	15	20
7 - Vörös él	782,8	20	779,7	20	20
8 - Közele infra	832,8	106	833,0	106	10
8a - Vörös él	864,7	21	864,0	22	20
9 - Vízpára	945,1	20	943,2	21	60
10 - Közepes infra (Cirrus felhők)	1373,3	31	1376,9	30	60
11 - Közepes infra	1613,7	91	1610,4	94	20
12 - Közepes infra	2202,4	175	2185,7	185	20

A Sentinel-2 által készített felvételek mindegyike UTM vetületben georeferált, 100 x 100 km²-es területet fed le és az összes spektrális sávot tartalmazza. A „Level 1C” kóddal rendelkező fájlok az légkör tetejéről (Top-Of-Atmosphere, TOA) visszavert sugárzási adatokat tartalmazzák, míg a „Level 2A” a felszínről (Bottom-Of-Atmosphere, BOA) visszavert adatokat.

A továbbiakban bemutatom azokat a szoftvereket és programkönyvtárakat, amelyeket felhasználtam a dolgozat során

Orfeo ToolBox

Az Orfeo ToolBox (OTB) egy nyílt forráskódú szoftver távérzékeléshez. Nagy felbontású optikai, multispektrális és radarképeket képes feldolgozni terabájtos léptékben, alkalmazások széles skáláján. Fejlesztője a CNES, a francia kormányzati űrügynökség (Centre national d'études spatiales) a CS-vel (Communication Systèmes) együttműködve. Működése az ITK-n, vagyis az Insight Toolkit-en alapul, mely 2006. június 30-án debütált. Az OTB összes algoritmusa elérhető QGIS-ből, Pythonból, parancssorból, C++-ból vagy az OTB standalone verziójából is, amit Monteverdinek hívnak. Az OTB Windows, Linux és Mac rendszeren is futtatható.

Az OTB raszteres és vektoros állományok olvasásához és írásához is a GDAL-ra támaszkodik. A GDAL az illesztőprogramok igen nagy paneljét kínálja a képfájlok metaadatainak eléréséhez.

Az OTB a metaadatokat az „otbImageMetadata” nevű speciális szótárban tárolja.

Az alábbi táblázaban szerepelnek azon szenzorok és raszterek, amelyeknek képes olvasni a fejlécét. A listában nem szereplő szenzorok továbbra is használhatók az OTB-vel, de a metaadatok nem lesznek elérhetők.

CosmoSkyMed	HDF5 / TIFF
Formosat	DIMAP / TIFF
Ikonos	TIFF
Pleiades	JPEG2000 / TIFF / DIMAP
QuickBird	TIFF
Radarsat 2	TIFF
Sentinel 1	TIFF
Spot 5	DIMAP / TIFF
Spot 6/7	DIMAP / JPEG2000 / TIFF
TerraSarX	COS
WorldView 2	TIFF

Az OTB egy megfeleltetési táblázatot használ egy adott fájlkiterjesztés GDAL-illesztőprogramhoz való kapcsolásához. Ez azt jelenti, hogy a táblázatban nem szereplő formátumok nem szerkeszthetők, még akkor sem, ha az illesztőprogram létezik a GDAL-ban.

Az OTB-ben elérhető formátumok a raszterek írásához:

- GTiff (.tif / .tiff)
- ENVI (.hdr)
- HFA (.img)
- NITF (.ntf)
- PNG (.png)
- JPEG (.jpg / .jpeg)
- PCIDSK (.pix)
- ISIS2 (.lbl / .pds)
- JP2OpenJPEG / JP2KAK / JP2ECW (.j2k / .jp2 / .jpx)

Az OTB képes olvasni az OGR által támogatott összes vektorformátumot, de az írási folyamat már bonyolultabb. A jelenleg a teljes mértékben támogatott formátumok az alábbiak:

- ESRI Shapefile (.shp)
- MapInfo File (.tab)
- Geographical Markup Language (.gml)
- GPS Exchange Format (.gpx)
- SQLite (.sqlite)
- Keyhole Markup Language (.kml)
- GeoPackage (.gpkg)

Sok OTB alkalmazás magassági modellt használ bemenetként, általában az „-elev.dem” paraméterrel. Ez a paraméter elfogad minden, a GDAL által támogatott raszterfájlt vagy az ilyen fájlokat tartalmazó könyvtárat. Ebben az esetben a bemeneti könyvtár összes raszterét a GDAL fogja megnyitni. Ügyelni kell arra, hogy a DEM mappa csak DEM fájlokat tartalmazzon. Ugyanez vonatkozik a „-elev.geoid” paraméterű geoidra is. Az alapértelmezett magasságot általában a „-elev.default” paraméterrel állíthatjuk be.

Az OTB az osztályozás során az OpenCV, LibSVM illetve a Shark programkönyvtárak algoritmusait használja fel.

OpenCV

Az OpenCV (Open Source Computer Vision Library) egy nyílt forráskódú programkönyvtár, amely több száz számítógépes algoritmust tartalmaz. Az algoritmusokat az úgynevezett OpenCV 2.x API-t írja le, amely lényegében egy C++ API.

Az OpenCV moduláris felépítésű, ami azt jelenti, hogy a csomag több megosztott vagy statikus könyvtárat tartalmaz. A következő modulok érhetőek el:

core: egy kompakt modul, amely a többi modul által használt alapvető funkciókat és adatstruktúrákat határozza meg.

imgproc: egy képfeldolgozó modul, amely magában foglalja a lineáris és nemlineáris képszűrést, a geometriai képtranszformációkat, szintér-konverziót, hisztogramokat.

video: egy videó elemző modul, amely mozgásbecslést, háttérkivonást és objektumkövető algoritmusokat tartalmaz.

calib3d: alapvető többnézetű geometriai algoritmusok, mono- és sztereó kamerás kalibráció, objektumpozíció-becslés, sztereó megfelelési algoritmusok és 3D rekonstrukciós elemek.

features2d: kiemelkedő értékek érzékelő, leírói és a leírók illesztői.

objdetect: objektumok és előre meghatározott osztályok példányainak észlelése.

highgui: interfész videórögzítéshez, kép- és videó kodekekhez.

gpu: GPU-gyorsított algoritmusok különböző OpenCV modulokból.

Shark programkönyvtár

A SHARK egy gyors, moduláris, funkciókban gazdag nyílt forráskódú C++ gépi tanulási könyvtár. Módszereket biztosít a lineáris és nemlineáris optimalizáláshoz, a kernel alapú tanulási algoritmusokhoz, a neurális hálózatokhoz és számos egyéb gépi tanulási technikához.

A Shark kompatibilis a Windows, Solaris, MacOS X és Linux operációsrendszerekkel.

Fejlesztői: Christian Igel, Verena Heidrich-Meisner, és Tobias Glasmachers

A Shark jelenleg az alábbi funkciókat támogatja:

- Felügyelt tanulás
 - Lineáris diszkriminancia analízis (LDA), Fisher–LDA
 - Lineáris regresszió
 - Vektorgépek (SVM-ek) egyosztályos, bináris és valódi többkategóriás osztályozáshoz
 - mesterséges neurális hálózatok
 - Radiális bázisfüggvény hálózatok
 - Regularizációs hálózatok
 - Iteratív legközelebbi szomszéd osztályozás és regresszió
 - Döntési fák és véletlenszerű erdők
- Felügyelet nélküli tanulás
 - Főegyüttható elemzés
 - Korlátozott Boltzmann gépek
 - Hierarchikus klaszterezés
 - Hatékony távolságfüggő clusterezéshez használt adatstruktúrák
- Evolúciós algoritmusok
- Egycélú optimalizáció
- Több célú optimalizáció
- Alapvető lineáris algebra és optimalizálási algoritmusok

LibSVM

A LibSVM (A támogató vektor gépek-könyvtára, A Library for Support Vector Machines)

A LibSVM egy beépíthető nyílt forráskódú programkönyvtár, ami SVM-et kínál a felhasználó számára. Fejlesztői Chih-Chung Chang és Chih-Jen Lin a Tajvani egyetemről.

Különböző SVM létrehozása

Hatékony többsztályos osztályozás

Kereszthivatkozások a model kiválasztásához

Valószínűségbecslések

Különböző kernelek

Súlyozott SVM-ek

Grafikus interfész az SVM osztályozáshoz és regresszióhoz

Alapvetően használható C++ és Java nyelvekkel

Továbbá Python, R, MATLAB, LISP, Haskell, PHP, C# .NET kiterjesztései is elérhetőek

Az osztályozás folyamata az OTB-ben

Elsőként a ComputeImagesStatistics parancs segítségével kiszámítjuk a felvételek sávjainak minimum, maximum, átlag és szórás értékeit. Az eredményt egy „*.xml” fájlba menthetjük el és innen használhatjuk fel a későbbi lépések során.

Ellenőrzött osztályozás esetén ezután meg kell határozni a felhasználni kívánt tanulóterületeket. Ez egy vektoros „*.shp” formátumú fájl kell, hogy legyen, aminek geometriája lehet pont, vonal vagy felület:

pont esetén a legközelebbi pixel kerül kiválasztásra

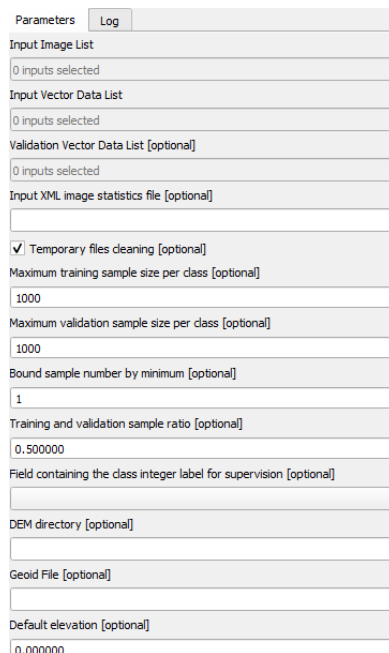
vonal esetén, azok a pixelek, amiket elmetsz a vonal

felület esetén azok a pixelek, amiknek a középpontja a felületen belül találhatóak

Attribútum táblájának tartalmaznia kell egy olyan oszlopot, ami alkalmas a tanulóterületek kódolására. Ennek az oszlopnak a típusa lehet szöveg vagy számérték azonban ha szám, azoknak egész számoknak kell lenniük.

Ezután következik a betanítás, amihez a TrainImagesClassifier parancsot kell futtatni.

A sikeres lefutáshoz kötelező megadni az osztályozandó felvételt. a tanulóterületeket tartalmazó vektoros állományt, valamint ki kell jelölni, hogy melyik oszlop tartalmazza az osztályozáshoz szükséges kódolást.



The image shows a screenshot of the 'TrainImagesClassifier' parameters dialog box in the OTB software. The dialog has a 'Parameters' tab and a 'Log' button. It contains several input fields and checkboxes for configuring the training process. The parameters are as follows:

Parameter	Value
Input Image List	0 inputs selected
Input Vector Data List	0 inputs selected
Validation Vector Data List [optional]	0 inputs selected
Input XML image statistics file [optional]	
<input checked="" type="checkbox"/> Temporary files cleaning [optional]	
Maximum training sample size per class [optional]	1000
Maximum validation sample size per class [optional]	1000
Bound sample number by minimum [optional]	1
Training and validation sample ratio [optional]	0.500000
Field containing the class integer label for supervision [optional]	
DEM directory [optional]	
Geoid File [optional]	
Default elevation [optional]	0.000000

2. ábra Az OTB számára megadandókötelező paraméterek

Továbbá ki kell választanunk, hogy melyik osztályozási folyamatot alkalmazza a betanítás során. Ezek a következők lehetnek:

Bayes féle osztályzás

Ez az osztályozási modell Bayes-tételén alapszik, amely meghatározza annak valószínűségét, hogy egy esemény egy másik eseményből származik, feltéve, hogy ez a két esemény egymással összefügg.

$$P(A|B) = \frac{P(B|A)*P(A)}{P(B)}, \text{ ha } P(B) \neq 0$$

Valamint az OTB használt Naív-Bayes osztályozó feltételezi, hogy az egyes osztályok jellegvektorai normális eloszlásúak és egymástól feltételesen függetlenek. Azaz, hogy egy osztály egyik jellemzőjének megléte bizonyos változó(k) rögzítése mellett függetlenek más jellemzők meglététől. A Bayes-osztályozó előnye, hogy viszonylag kevés tanuló adatra van szüksége valamint az OTB-ben nem szükséges további paraméterek megadása. Az algoritmus a betanítási adatok felhasználásával minden osztályhoz megbecsüli az átlagvektorokat és a kovariancia mátrixokat, majd ezeket használja fel az előrejelzéshez.

K-legközelebbi szomszéd (K-means neighbors, KNN)

Az algoritmus megjegyzi az összes betanítási mintát, majd ezt követően megkeresi az osztályozandó pixelhez intenzitásához legközelebbi k darab értéket és kiválasztja a távolsággal súlyozott összegekből leggyakoribbat.

A „Number of Neighbors” paraméterrel adhatjuk meg a vizsgált szomszédok számát

LibSVM

Az első SVM-t Boser et al (1992.); Cortes and Vapnik (1995.) írta le. Működési elve, hogy az osztályozandó adatok között megkeresi a lehető legszélesebb pufferű hipersíkot egy magasabb dimenzióban. Az OTB ehhez az alábbi kerneleket kínálja fel lehetőségként:

Lineáris (nincs leképezés, leggyorsabb módszer)

Gauss-féle radiális bázisfüggvény (Radial base Function, RBF; az euklidészi távolságon alapuló leképezés)

Polinominális (polinominális leképezése a vektoroknak)

Szigmoid (tangens-hiperbolikus leképezése a vektoroknak)

Általánosságban az RBF a legjobb választás, mivel képes kezelni a lineáris és nem lineáris mintázatokat is. Keerthi és Lin (2003.) leírta, hogyan lehet a lineáris kernel paraméterét megadni az RBF változóival. Lin és Lin (2003.) bebizonyította, hogy szigmoid kernel úgy viselkedik, mint az RBF bizonyos paraméterek esetében. Valamint a polinominális kernelnél kevesebb hiperparaméterrel dolgozik, ami csökkenti a számítási nehézségeket. Ezért a továbbiakban csak az RBF kernelt ismertetem.

A változók megadása

Mivel az SVM-ek jellemzően megengedő margókat (soft margin) használnak, azaz megengedik, hogy a puffer zónán belül is legyenek pontok, így nagyobb határsáv jelölhető ki, amivel az előrejelzés bizonyossága javítható. Ezeket a határokon belüli pontokat különböző büntetőpontokkal illetjük. Az OTB megkülönböztet:

„C”, „Nu” és „egy osztályos” paraméterezéseket. Ahol C a betanítási hibák és a margó szélességének függvénye. Nu egy felülről zárt, alulról nyitott 0;1 intervallum, ahol a magasabb értékek kevésbé megengedő margót eredményeznek. Ezt nehezebb meghatározni és lassabb lefutást eredményezhet. Egy osztályos SVM esetén a tanuló adatok mindannyian egy csoportból származnak és ezt határoljuk el a tér többi részétől.

Egyéb paraméterek: gamma, mint a kernel együttthatója

a Paraméter optimalizáló (Parameters optimization) és a valószínűség becslő (Probability estimation) jelölőnégyzet

a véletlen tagok száma (random seed), amik kereszthivatkozásokat hoznak létre a tanulóadatok között ezzel javítva pontosságot és a paraméterbeállításokat, de lassítják a folyamatot).

Döntési fa (Decision tree, DT)

Ez egy bináris fa, ahol kezdetben az összes intenzitás vektor egy csoportot alkot, amit gyökérnek (root) hívunk. Ezt a gyökeret osztjuk fel egy-egy vizsgálati szempont szerint. A vizsgálatnak mindig két gyermeke lesz. Azokat a gyermekeket, amiket tovább osztunk csomópontoknak (node) nevezzük, azokat a gyermekeket pedig, amiket nem osztunk tovább leveleknek (leaf) hívjuk.

Osztályozás során az összes tanuló adat a gyökér felosztására szolgál, majd ezt követően a többi pixel intenzitásait teszteljük, hogy mely csomópontban lévő intenzitásértékek részhalmazának felelnek meg. Ebből következik, hogy minden csomópontban egy változó indexet (variable index) és egy döntési szabályt (decision rule) tárolunk. Ezt a párt splitnek nevezzük. Az osztályozás jellemzően abbamarad, ha:

A megépített faág mélysége (depth) elérte a megadott maximális értéket.

A betanítási minták száma a csomópontban kisebb, mint a megadott küszöb

A csomópontban lévő összes minta ugyanabba az osztályba tartozik

A legjobbnak talált felosztás nem ad észrevehető javulást a véletlenszerű választáshoz képest. Az eredmények kereszthivatkozással jól ellenőrizhetőek. Szükség esetén metszhető (split) is, ezzel elkerülve a túlillesztési hibákat. A változók között a fent említett kilépési feltételeket lehet beállítani.

Boosting (Erősítő/gyorsító eljárás)

Működésének alapja, hogy rengeteg olyan egyszerű osztályzást (pl.: DT) futtat le, amik gépigénye minimális. Ezek eredményit összedolgozva kapjuk meg az osztályokat. Ezeket az eljárásokat például a Friedman, J. H., Hastie, T. and Tibshirani, R. Additive Logistic Regression: a Statistical View of Boosting. Technical Report, Dept. of Statistics*, Stanford University, 1998-ben találjuk.

Az OTB-ben elérhető fajtái:

- Discrete Adaboost:
- Real AdaBoost
- LogitBoost
- Gentle AdaBoost

Ezek felépítésükben és leírásukban nagyon hasonlítanak egymásra. Kezdetben minden mintához súlyt rendelünk, erre indítunk egy egyszerű osztályozót. majd kiszámítjuk a pontosságát és a hibáját. Ezután megemeljük a súlyát a hibás mintáknak, majd a súlyokat normalizáljuk és újra lefuttatjuk. Ezt ismételjük N-1 alkalommal. A végső osztályzás az egyes egyszerű osztályozók súlyaiból adódik (pl.: A diszkrét adaboost ezen súlyok lineáris kombinációját használja).

A paraméterek között, a számítási idő csökkentésére is van lehetőség a pontosság megtartásával („influence trimming technique”) Ilyenkor az algoritmus előre haladtával egyre több minta kerül helyre ezért ezek egyre kisebb súlyt kapnak az ezt következő lefutások során. Ennek következtében kevesebb ráhatásuk van a következő iterációkra. Ezt a folyamatot a „weight_trim_rate” paraméter vezérli. Az OTB-ben ez egy 0 és 1 közötti szám. Ha egy minta súlya kevesebb vagy egyenlő mint az 1-„weight_trim_rate”, akkor nem vesz részt a következő iterációkban. További paraméter az egyszerű osztályozók száma („weak count”), ami az egymást követő iterációk számát határozza meg, valamint az egyes osztályozók maximális mélysége („max depth tree”).

Véletlen erdő (Random forest, RF)

Leírása Leo Breiman és Adele Cutler nevéhez fűződik. A részletes leírás megtalálható a honlapjukon: <https://www.stat.berkeley.edu/users/breiman/RandomForests>

Működésének alapja, hogy több száz különböző döntési fa eredményeiből adja meg a végső következtetést. Minden egyes pixelhez a legtöbb fa által javasolt osztály értéke kerül hozzárendelésre.

Ha az esetek száma a tanuló területen N , akkor az algoritmus, is N , véletlenszerű esetet választ ki az eredeti adatokból visszatevéssel. Ez a minta lesz a döntési fa oktatókészlete, tananyaga. A minták kiválasztása tehát visszatevéssel történik, azaz az egyes minták többször is előfordulhatnak, mások pedig hiányozhatnak.

Ha M osztályunk van, akkor egy $m \ll M$ számot adunk meg úgy, hogy mindezen csomóponton m változót véletlenszerűen választunk ki az M -ből, és az m -paraméterrel elért legjobb felosztást használjuk fel a csomóponton. Az m értéke állandó marad a teljes lefutás során, így minden csomóponttal egy új részhalmaz jön létre, aminek mérete állandó minden csomóponton és minden döntési fán. Ez az m tanítási paraméter jellemzően az összes változó négyzetgyökével egyezik meg.

Minden fát a lehető legnagyobb mértékben hagyunk növekedni, nincs metszés.

Véletlenszerű fáknál nincs szükség semmilyen pontosságbecslési eljárásra, például keresztellenőrzésre. A hiba belső becslése a képzés során történik. Amikor az éppen aktuális fát a betanítási halmaz mintáival és a cserékkel szerkesztjük, néhány érték kimarad, ezek az ún. oob (out-of-bag) adatok. Az oob adatok mérete körülbelül $N/3$. Az osztályozási hiba becslése ezen oob-adatok felhasználásával történik.

Minden döntési fa felépítése után az algoritmus lefuttatja az összes adatot a fán, és minden esetpárhoz kiszámítja a közelségeket. Ha két eset ugyanazt a terminális csomópontot foglalja el, akkor a közelségük eggyel nő. A futtatás végén az algoritmus a közelségeket a fák számával való osztással normalizálja. A közelítéseket a hiányzó adatok pótlására, a kiugró értékek megkeresésére használja.

A Random Forests legnagyobb előnyei:

- Kimagasló pontosságú a jelenlegi algoritmusok között. (A véletlenszerű erdők nem tudnak túlilleszkedni (overfit).)
- Hatékonyan fut nagy adatbázisokon, emellett nincs limitálva a döntési fák maximális száma.
- Nagy adathalmazok esetén a fő memóriaigény csak magának az adatnak, és három, az adatokkal azonos méretű egész szám tömbnek a tárolásából származik.
- Több ezer bemeneti változót képes kezelni változó törlése nélkül.
- Becsléseket ad arra vonatkozóan, hogy mely változók fontosak az osztályozásban.
- Az erdőépítés előrehaladtával belső, elfogulatlan becslést generál az általánosítási hibáról.
- Hatékony módszerrel rendelkezik a hiányzó adatok becslésére, és megőrzi a pontosságot, még akkor is, ha az adatok nagy része hiányzik.
- Vannak módszerei az osztálypopuláció kiegyensúlyozatlan adatkészleteiből származó hibák kiegyenlítésére.
- A generált erdők elmenthetők későbbi felhasználásra más adatokon.
- Prototípusokat számítanak ki, amelyek információt adnak a változók és az osztályozás közötti kapcsolatáról.
- Kiszámítja az esetpárok közötti közelségeket, amelyek használhatóak a kiugró értékek lokalizálásához.
- A fentiek képességei kiterjeszthetők a címkézetlen adatokra is, ami felügyelet nélküli klaszterezéshez, az adatszerkezet megértéséhez és a kiugró értékek észleléséhez vezet.
- Kísérleti módszert kínál a változó kölcsönhatások kimutatására.

Az OTB-ben megadható paraméterei, a döntési fánál használt paramétereken felül:

OpenCV

- Az egyes fák megengedett legnagyobb mélysége (Maximum depth of the tree) Az optimális érték kiszámolása például kereszthivatkozásokkal ellenőrizhetőek.
- Ha az egy csoportba sorolt minták darabszáma (Minimum number of samples in each node) nem éri el az itt megadott paramétert nem lesz elmetszve a fa, azaz nem alkothatnak önálló csoportot.
- Ez a paraméter összehasonlítja az egyes csomópontok értékeit és a tanulóterületekből származó csoportok értékeit. Amennyiben a különbségük abszolút értéke nem haladja

meg a Termination Criteria for regression tree paraméter értékét a csoport nem lesz felosztva

- A Cluster possible values of a categorical variable into $K \leq \text{cat clusters}$ to find a suboptimal split változóval a lehetséges osztályok számát határozhatjuk meg. Ezáltal szuboptimális osztályok jöhetnek létre de jelentős processor idő megspórolható(mivel a számítások az osztályok számával exponenciálisan nőnek).
- A minták véletlenszerűen kiválasztott részhalmazának mérete az egyes csomópontokon (Size of the randomly selected subset of features at each tree node): Ez az egyes fa csomópontokon véletlenszerűen kiválasztott jellemzők részhalmazának mérete, amelyet a legjobb felosztás(ok) megtalálásához használ az algoritmus. Ha az értéke 0, akkor a mérete a funkciók teljes számának négyzetgyökére lesz beállítva.
- A fák maximális száma az erdőben (Maximum number of trees in the forest): A fák maximális száma az erdőben. Általában minél több fa van, annál jobb a pontosság. Zonban a fák számának növelésével a pontosság javulása csökken A fák számának növelése lineárisan növeli az lefutási időt.
- Elegendő pontosság, OOB hiba (Sufficient accuracy (OOB error))

Shark

- A Maximum number of trees in the forest paraméter meghatározza hányszor fusson le az algoritmus. A nagyobb érték pontosabb osztályozást eredményez, de növeli a lefutási időt is.
- Min size of the node for a split paraméter ugyan úgy viselkedik mint az OpenCV darabszáma Minimum number of samples in each node paramétere
- A Number of features tested at each node meghatározza, hogy a betanítás után rendelkezésre álló minták hányada vegyen részt az egyes fák felosztásában.
- Az Out of bound ratio meghatározza, hogy a tanulóterületek hány százaléka ne vegyen részt az osztályozásban.

Az eredmények kiértékelése, pontosságmérés

Ebben a fejezetben az elkészült osztályozás eredményének kiértékelését fogom bemutatni

A kiértékelés első lépése az elkészült osztályozás minőségének megállapítása.

Pontosság becslés - Accuracy assesement

A pontosság becslése véletlenszerűen kiválasztott referencia pixelek és az osztályzások eredményeként kapott tematikus raszterréteg összehasonlítását jelenti. Ez az összehasonlítás történhet:

véletlenszerű módon: semmilyen szabályt nem használva,

stratégiai véletlenszerű módon: a referencia pixelek a tematikus osztályok területi arányának megfelelően oszlanak el véletlenszerűen az osztályokban,

kiegyenlített véletlenszerű módon: a referencia pixelek a tematikus osztályokban egyenlő számban oszlanak el véletlenszerűen.

A pontosság mérésének eredménye vagy egy $c \times c$ méretű zavar mátrixban jelenik meg, ahol c az osztályok száma. Vagy a pontosság százalékos statisztikája a hibamátrix alapján.

Zavar mátrix (Confusion mátrix)

Mivel tanulóterület pixelei nem mindig homogének, ezért szükséges egy táblázat, ami százalékosan vagy számszerűen megmutatja, hogy a tanuló terület pixelei hogyan osztályozódtak. Ezt a táblázatot Zavar mátrixnak hívják (Confusion mátrix), de hívják még hibamátrixnak (Error Matrix) is, valamint nem felügyelt eljárások esetén illeszkedési mátrixnak (Matching Matrix).

	POSITIVE (1)	NEGATIVE (0)
POSITIVE (1)	TP	FN
NEGATIVE (0)	FP	TN

3. ábra A zavar mátrix leegyszerűsített modellje

Ahol az oszlopok a tanulóterület egyes attribútum címkéinek felelnek meg, míg a sorok az osztályozás utáni címkéjüket mutatják. Az egyes rövidítések a következők (T=True, F= false
P= Positive, N= negative)

Ebből következik, hogy a mátrix főátlójában lévő értékek mutatják meg azokat az eseteket, amikor az osztályozás helytálló volt

Az OTB az alábbi lehetőségeket kínálja és automatikusan számolja.

- Szórás(Precision) vagy Positive Predicted Value (PPV) , ahol $PPV = \frac{TP}{TP+FP}$
- Recall érték vagy Sensitivity, ami $= \frac{TP}{TP+FN}$
- Accuracy ami $= \frac{TP+TN}{TP+TN+FP+FN}$
- balanced accuracy ami $= \frac{\frac{TP}{TP+FN} + \frac{TN}{TN+FP}}{2}$
- F1-score minden osztályra, ami a precision és Sensitivity harmónikus középértéke.

Cohen féle kappa együttható

Olyan statisztikai együttható, ami megmutatja egy mérés megbízhatóságát, illetve több mérés esetén azok összehasonlítására szolgál. Figyelembe véve a megegyezések százalékos előfordulását, valamint azok véletlenszerű bekövetkezésének lehetőségét is.

Legmagasabb értéke 1 lehet a teljes megegyezés esetén, ha a mérések között nincs nagyobb egyetértés, mint amit a véletlen indokolna akkor értéke 0. Előfordulhat negatív értékek is, ha az egyes mérések eredményei ellent mondanak egymással.


A köztes értékek felosztására az alábbiak szerint történik

- 0,01-0,2 csekély egyezés
- 0,21-0,4 megfelelő egyezés
- 0,41-0,6 közepes egyezés
- 0,61-0,8 jelentős egyezés
- 0,81- 1 kiváló egyezés

A felügyelt osztályozások összehasonlítása

Ahhoz, hogy részletesebben meg tudjam vizsgálni az OTB nyújtotta lehetőségeket letöltöttem egy műholdfelvételt Budapest környékéről.

Első lépésként, a gyorsabb feldolgozás érdekében a felvételtől kivágtam egy területet, ami Budapest szűkebb környezetét mutatja, valamint az egyes sávokat bemutató felvételeket a QGIS Build Virtual Raster segítségével egy „tif” fájlba lementettem. Ezek az állományok a „vagott_3sav10m.tif” illetve a „vagott_4sav10m.tif” nevet kapták.



4. ábra A Sentinel-2 S2B_MSIL2A_20220328T095029_N0400_R079_T34TCT_20220328T125103 kódú felvétele

Ezután létrehoztam a tanulóterületeket, ami egy felület típusú .shp állomány, aminek attribútum táblájában az alábbi kategóriákat különítettem el:

- vízfelület (1)
- épületek (2)
- utak (3)
- beépített terület (4)
- magas vegetáció (5)
- alacsony vegetáció (6)
- növényzet (7)
- fedetlen talaj (8)

Ahol a (4) -es kategória alatt a (2) -es és (3) -as kategória összevonását, a (7) -es kategória alatt a (5) -es és (6) -as kategória összevonását értem.

Az osztályozás megkezdése előtt megvizsgáltam a tanulóterületek homogenitását. Ehhez az egyik osztályozót háromszor lefuttattam rendre a tanulóterületek pixeleinek 33%, 50% és 66%-ára. Az eredményeket az alábbi táblázatban foglaltam össze:

Bayes-féle osztályozás																							
Sentinel-2 (2,3,4-es sáv)								Sentinel-2 (2,3,4 -es sáv)								Sentinel-2 (2,3,4 -es sáv)							
1	2	3	5	6	8			1	2	3	5	6	8			1	2	3	5	6	8		
1	568	0	0	0	4	0		1	860	1	0	0	6	0		1	1129	0	0	0	15	0	
2	0	403	79	38	6	46		2	0	572	138	67	8	82		2	0	653	186	175	10	122	
3	0	137	420	5	1	9		3	0	196	651	7	2	11		3	0	225	884	14	2	19	
5	0	14	0	556	0	2		5	0	25	0	836	1	5		5	0	21	2	1109	1	11	
6	6	20	3	0	543	0		6	6	30	0	0	831	0		6	10	43	3	0	1088	0	
8	0	23	0	4	0	545		8	0	22	0	13	0	832		8	0	28	0	30	0	1086	

Pontosságbecslés											
Ellenőrző	pixelek	aránya	Ellenőrző	pixelek	aránya	Ellenőrző	pixelek	aránya			
33%			50%			66%					
Precisio	Recall	F-score	Precision	Recall	F-score	Precision	Recall	F-score	n		
1	99%	99%	99%	1	99%	99%	1	99%	99%		
2	68%	70%	69%	2	68%	66%	67%	2	67%	57%	62%
3	84%	73%	78%	3	83%	75%	79%	3	82%	77%	80%
5	92%	97%	95%	5	91%	96%	93%	5	84%	97%	90%
6	98%	95%	96%	6	98%	96%	97%	6	97%	95%	96%
8	91%	95%	93%	8	89%	96%	93%	8	88%	95%	91%
Kappa index		86%	Kappa index		86%	Kappa index		84%			

Homogenitás vizsgálat a tanuló terület pixeleinek 33% (bal oldal) 50%(középső) és 66%-ával (jobb oldal) Figyelembe véve az eredményeket a további vizsgálatokat az osztályozások a tanuló területek szerinti önellenőrzését a rendelkezésre álló pixelek felével fogom végezni.

Az osztályozást a Sentinel-2 által elérhető legnagyobb térbeli felbontású képein (10m) végeztem el. Először a hagyományos, a látható fény tartományán belüli felvételen, majd ezután egy multispektrális (4 sáv) felvételen.

A pontosság javítható amennyiben az eddigi hat kategória helyett négyet használunk, összevonva az eddigi épületek és utak rétegeket egy új beépített terület (4) valamint az eddig megkülönböztetett alacsony és magas vegetációt egységesen növényzet (7) réteggé.

Az egyes osztályozások kontingencia mátrixait és pontosságbecslését az alábbi táblázatban foglaltam össze:

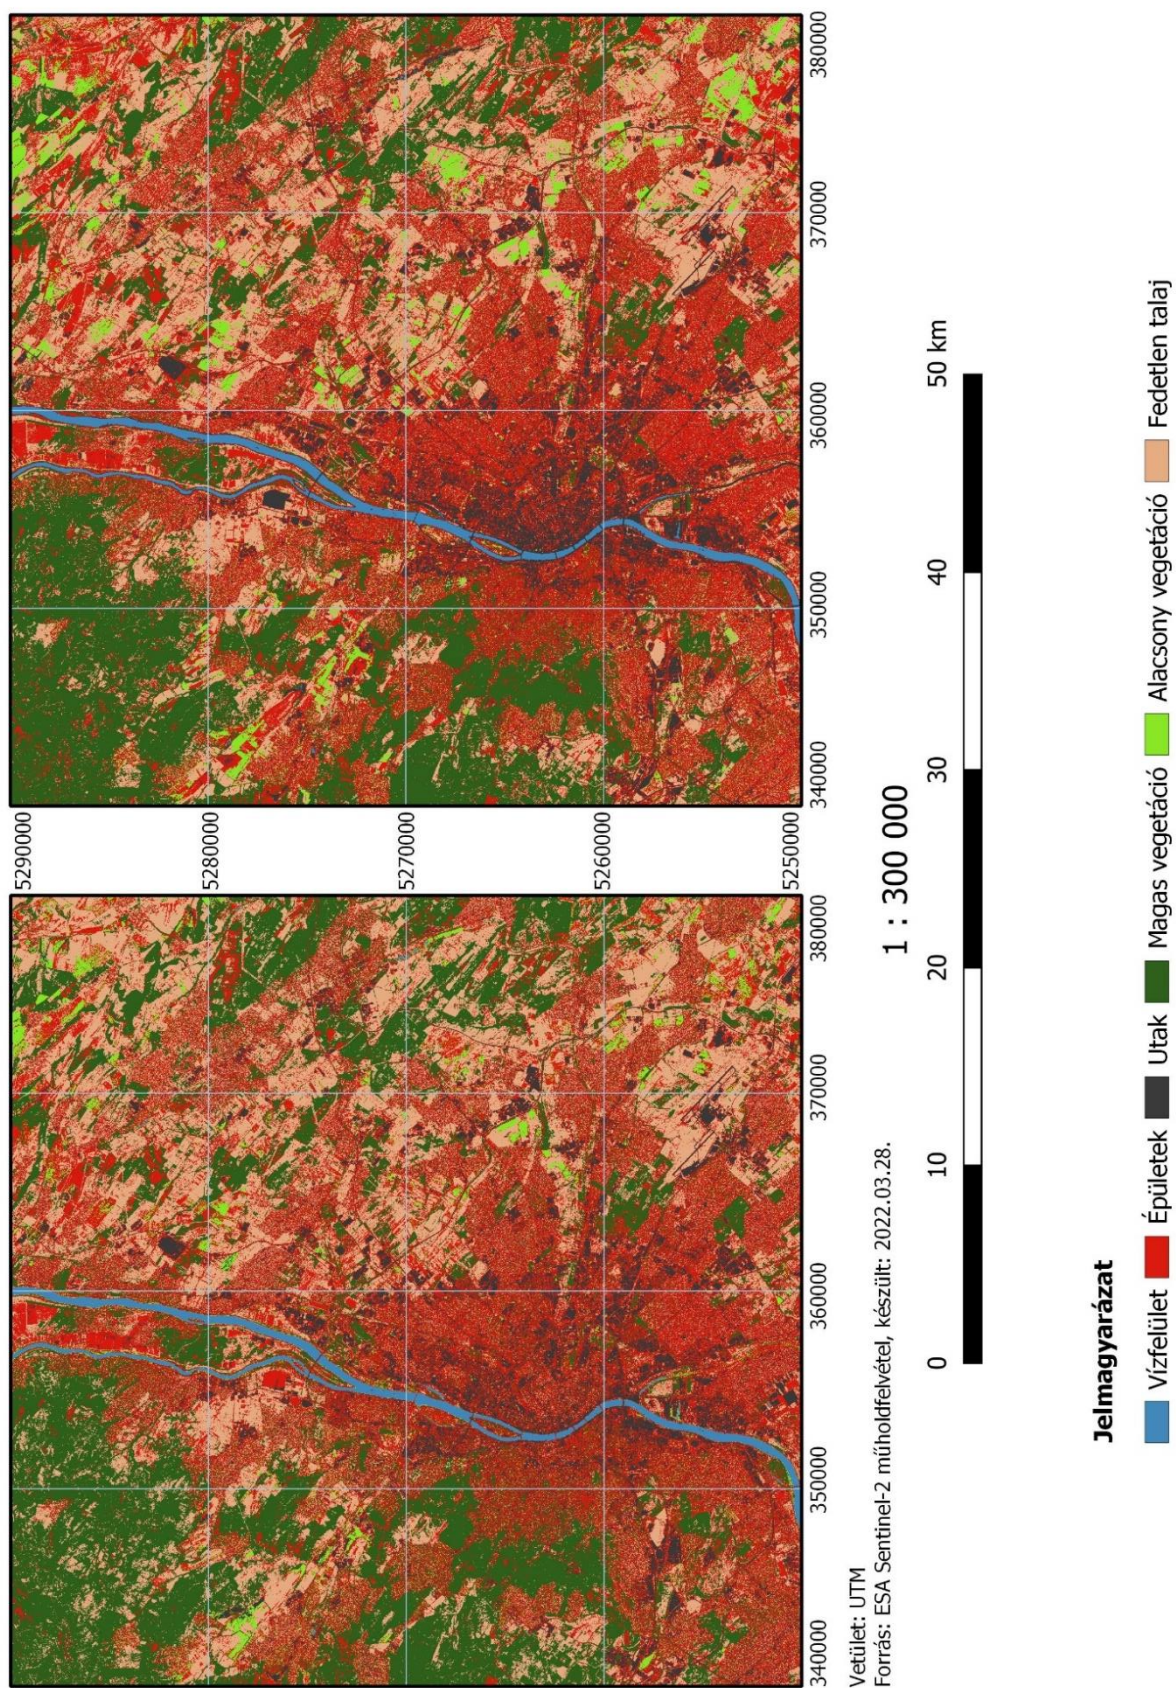
Bayes - féle osztályozás 6 osztály esetén																				
Sentinel-2 (2,3,4-es sáv)							Sentinel-2 (2,3,4, 8 -as sáv)							Eltérés						
	1	2	3	5	6	8		1	2	3	5	6	8		1	2	3	5	6	8
1	860	1	0	0	6	0	1	863	0	4	0	0	0	1	3	-1	4	0	-6	0
2	0	572	138	67	8	82	2	0	620	154	42	3	48	2	0	48	16	-25	-5	-34
3	0	196	651	7	2	11	3	0	92	770	0	0	5	3	0	-104	119	-7	-2	-6
5	0	25	0	836	1	5	5	0	20	4	841	0	2	5	0	-5	4	5	-1	-3
6	6	30	0	0	831	0	6	0	12	0	0	849	6	6	-6	-18	0	0	18	6
8	0	22	0	13	0	832	8	0	31	0	2	0	832	8	0	9	0	-11	0	0

Az eredményekből látszódik, hogy a legnagyobb pontatlanságot az épületek (2) és az utak(3) csoportok alkotják.

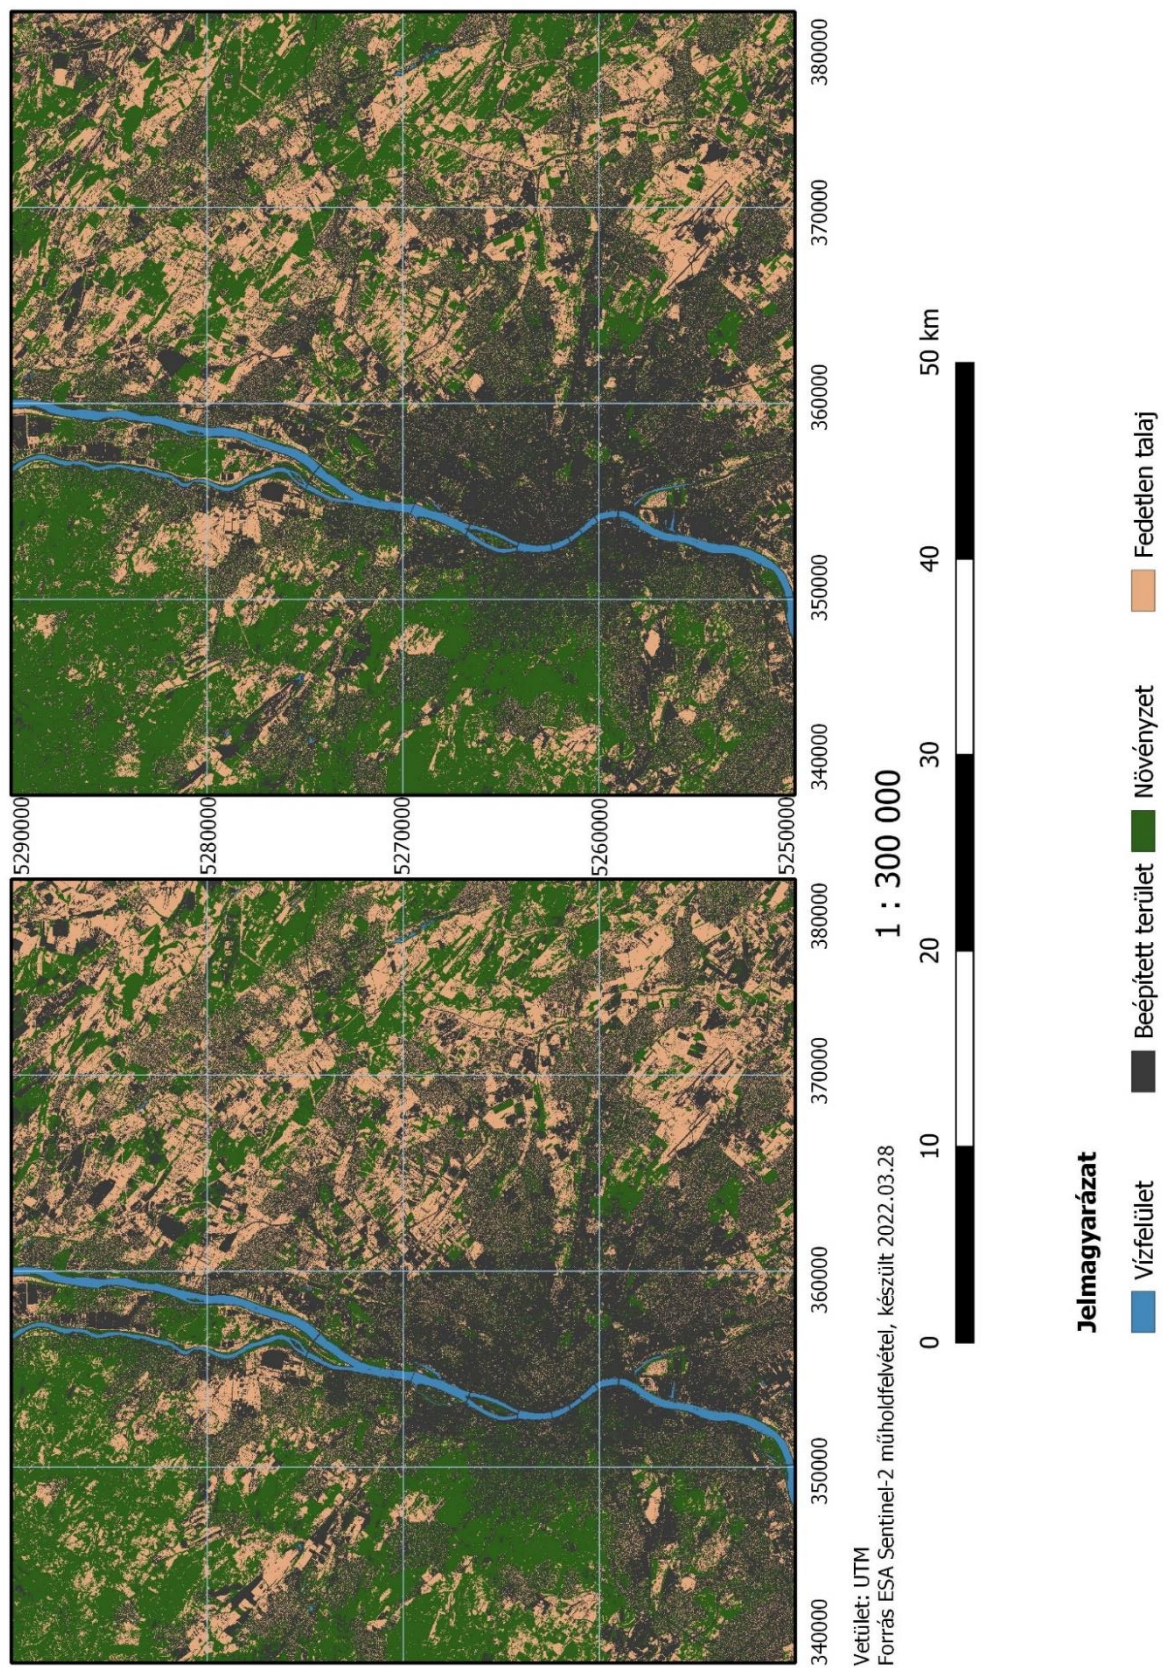
Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	99%	99%	99%	1	100%	100%	100%
2	68%	66%	67%	2	80%	72%	76%
3	83%	75%	78%	3	83%	89%	86%
5	90%	96%	93%	5	95%	97%	96%
6	98%	96%	97%	6	100%	98%	99%
8	89%	96%	92%	8	93%	96%	95%
	Kappa index		85%		Kappa index		90%

Bayes - féle osztályozás 4 osztály esetén														
Sentinel-2 (2,3,4-es sáv)					Sentinel-2 (2,3,4, 8 -as sáv)					Eltérés				
	1	4	7	8		1	4	7	8		1	4	7	8
1	2787	16	0	0	1	2793	10	0	0	1	6	-6	0	0
4	0	2255	283	265	4	0	2411	230	162	4	0	156	-53	-103
7	2	82	2694	25	7	0	52	2740	11	7	-2	-30	46	-14
8	0	107	17	2679	8	0	82	21	2700	8	0	-25	4	21

Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	100%	99%	100%	1	100%	100%	100%
4	92%	80%	86%	4	94%	86%	90%
7	90%	96%	93%	7	92%	98%	95%
8	90%	96%	93%	8	94%	96%	95%
	Kappa index		91%		Kappa index		93%



5. ábra A Bayes- féle osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén



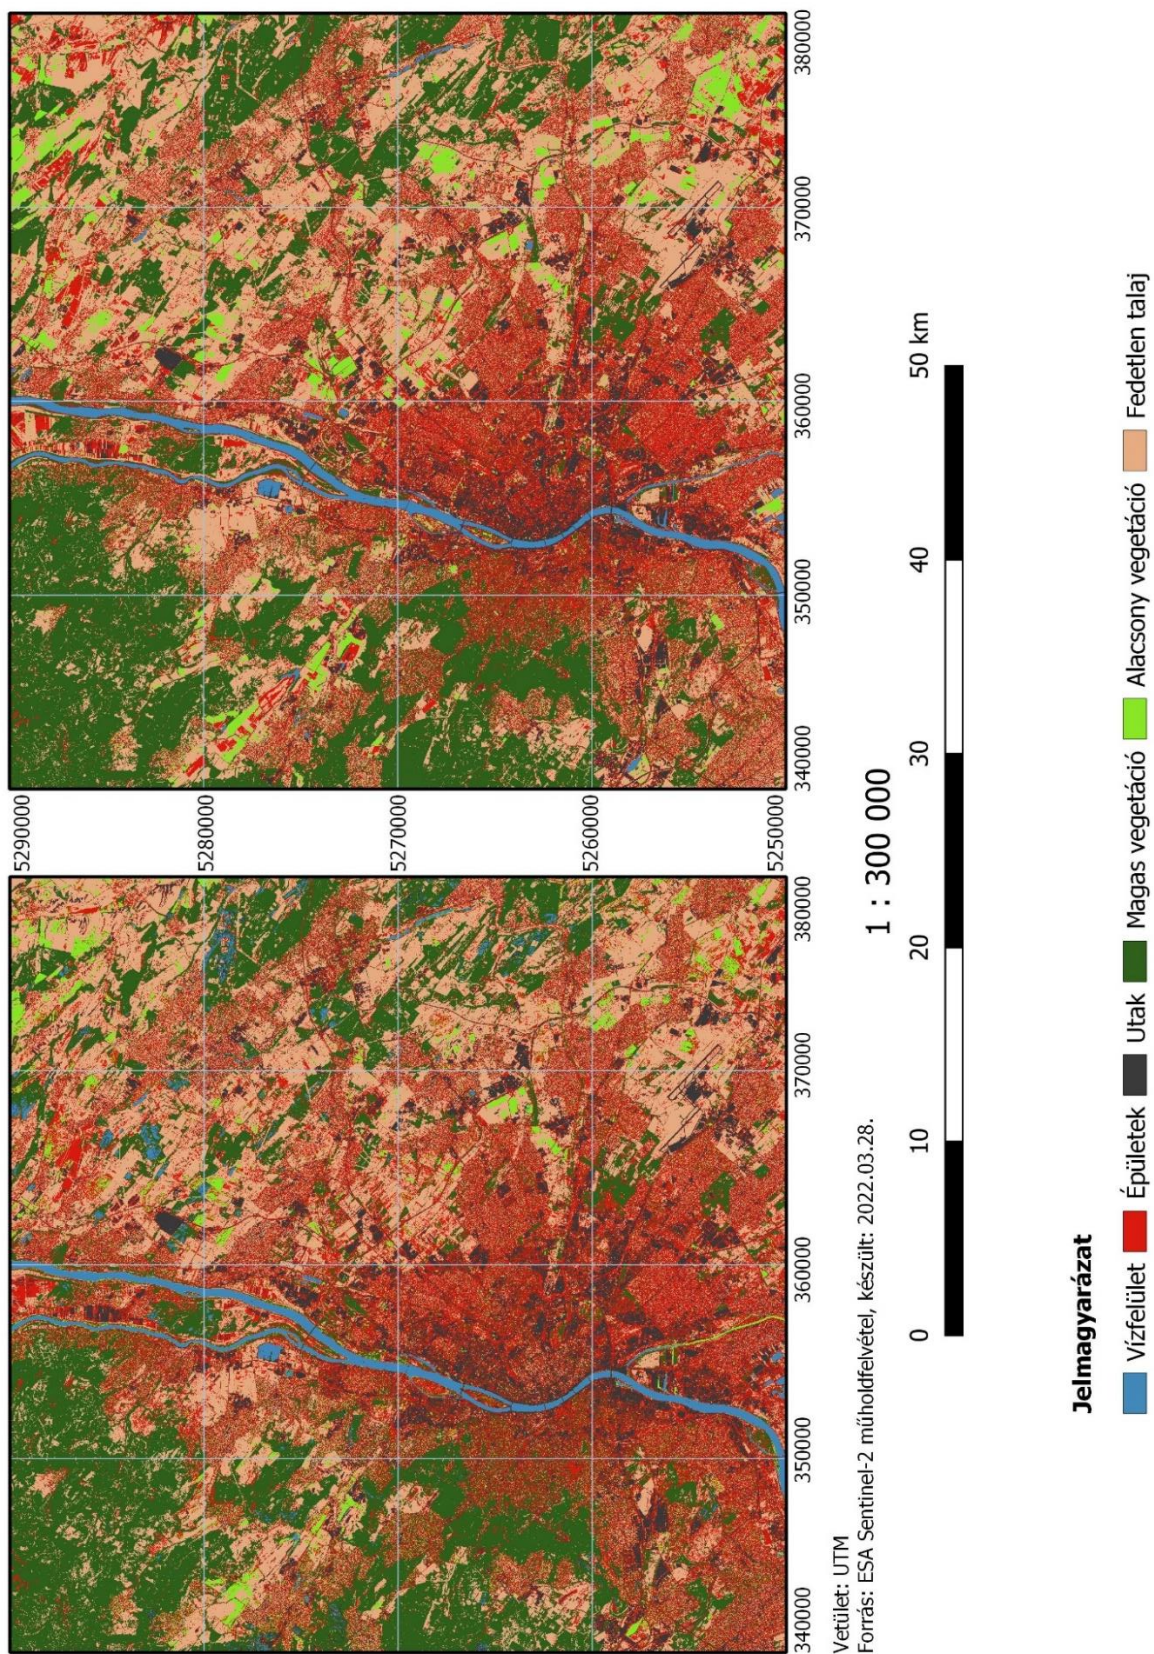
6. ábra A Bayes- féle osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén

KNN osztályozás 6 osztály esetén																				
Sentinel-2 (2,3,4-es sáv)							Sentinel-2 (2,3,4, 8 -as sáv)							Eltérés						
	1	2	3	5	6	8		1	2	3	5	6	8		1	2	3	5	6	8
1	865	0	0	0	2	0	1	866	0	1	0	0	0	1	1	0	1	0	-2	0
2	1	469	164	85	8	140	2	0	557	118	60	6	106	2	-1	88	-46	-25	-2	-34
3	4	138	695	9	7	14	3	11	72	773	0	0	11	3	-7	-65	75	-9	-7	-3
5	0	6	4	848	2	7	5	0	6	0	857	0	4	5	0	0	-4	9	-2	-3
6	22	5	6	0	819	15	6	0	3	1	9	849	5	6	-22	-2	-5	9	30	-10
8	0	20	0	2	0	845	8	0	13	0	2	0	852	8	0	-7	0	0	0	7

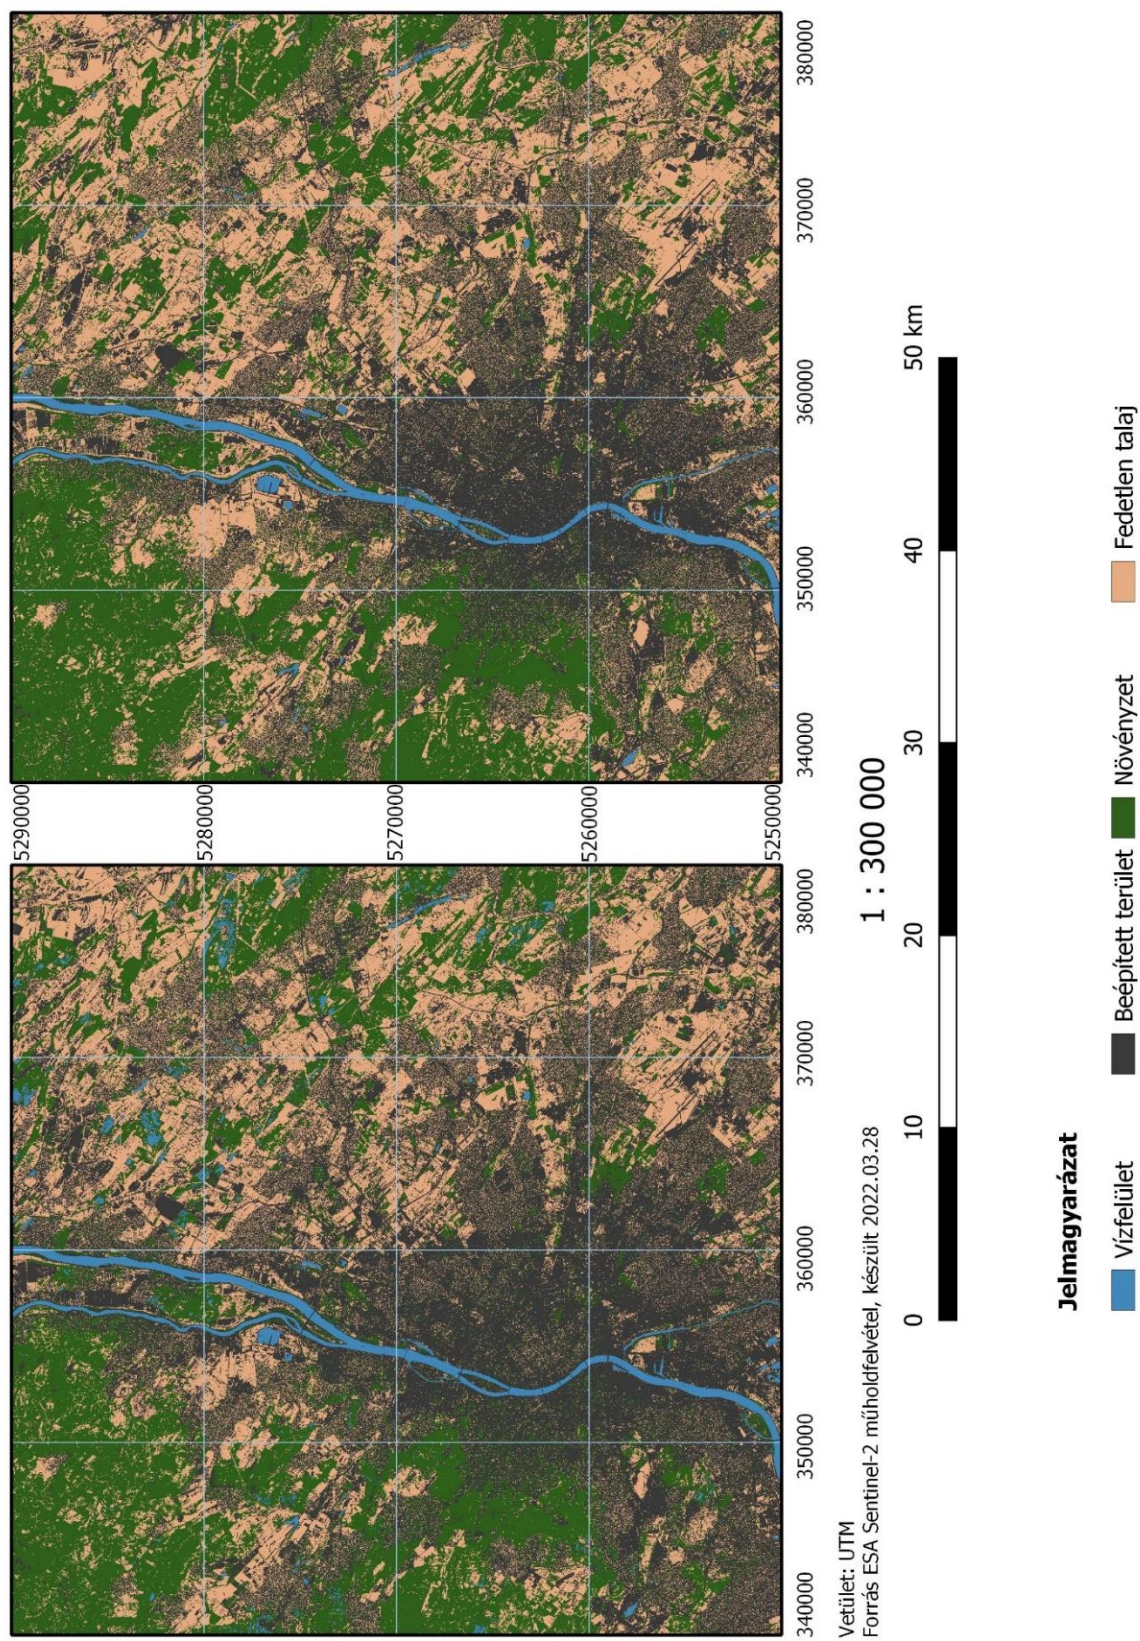
Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	97%	100%	98%	1	99%	100%	99%
2	74%	54%	62%	2	86%	67%	75%
3	80%	80%	80%	3	87%	89%	88%
5	90%	98%	94%	5	92%	99%	95%
6	98%	94%	96%	6	99%	98%	99%
8	83%	97%	90%	8	87%	98%	92%
	Kappa index		85%		Kappa index		90%

KNN osztályozás 4 osztály esetén														
Sentinel-2 (2,3,4-es sáv)					Sentinel-2 (2,3,4, 8 -as sáv)					Eltérés				
	1	4	7	8		1	4	7	8		1	4	7	8
1	2798	0	5	0	1	2801	2	0	0	1	3	2	-5	0
4	3	2306	199	295	4	7	2380	160	256	4	4	74	-39	-39
7	6	73	2705	19	7	0	32	2758	13	7	-6	-41	53	-6
8	0	45	10	2748	8	0	22	4	2777	8	0	-23	-6	29

Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	100%	100%	100%	1	100%	100%	100%
4	95%	82%	88%	4	98%	85%	91%
7	93%	97%	95%	7	94%	98%	96%
8	90%	98%	94%	8	91%	99%	95%
	Kappa index		92%		Kappa index		94%



7. ábra A KNN osztályozás eredménye hat kategória esetén három (bal oldal)illetve négy (jobb oldal)spektrális sáv esetén



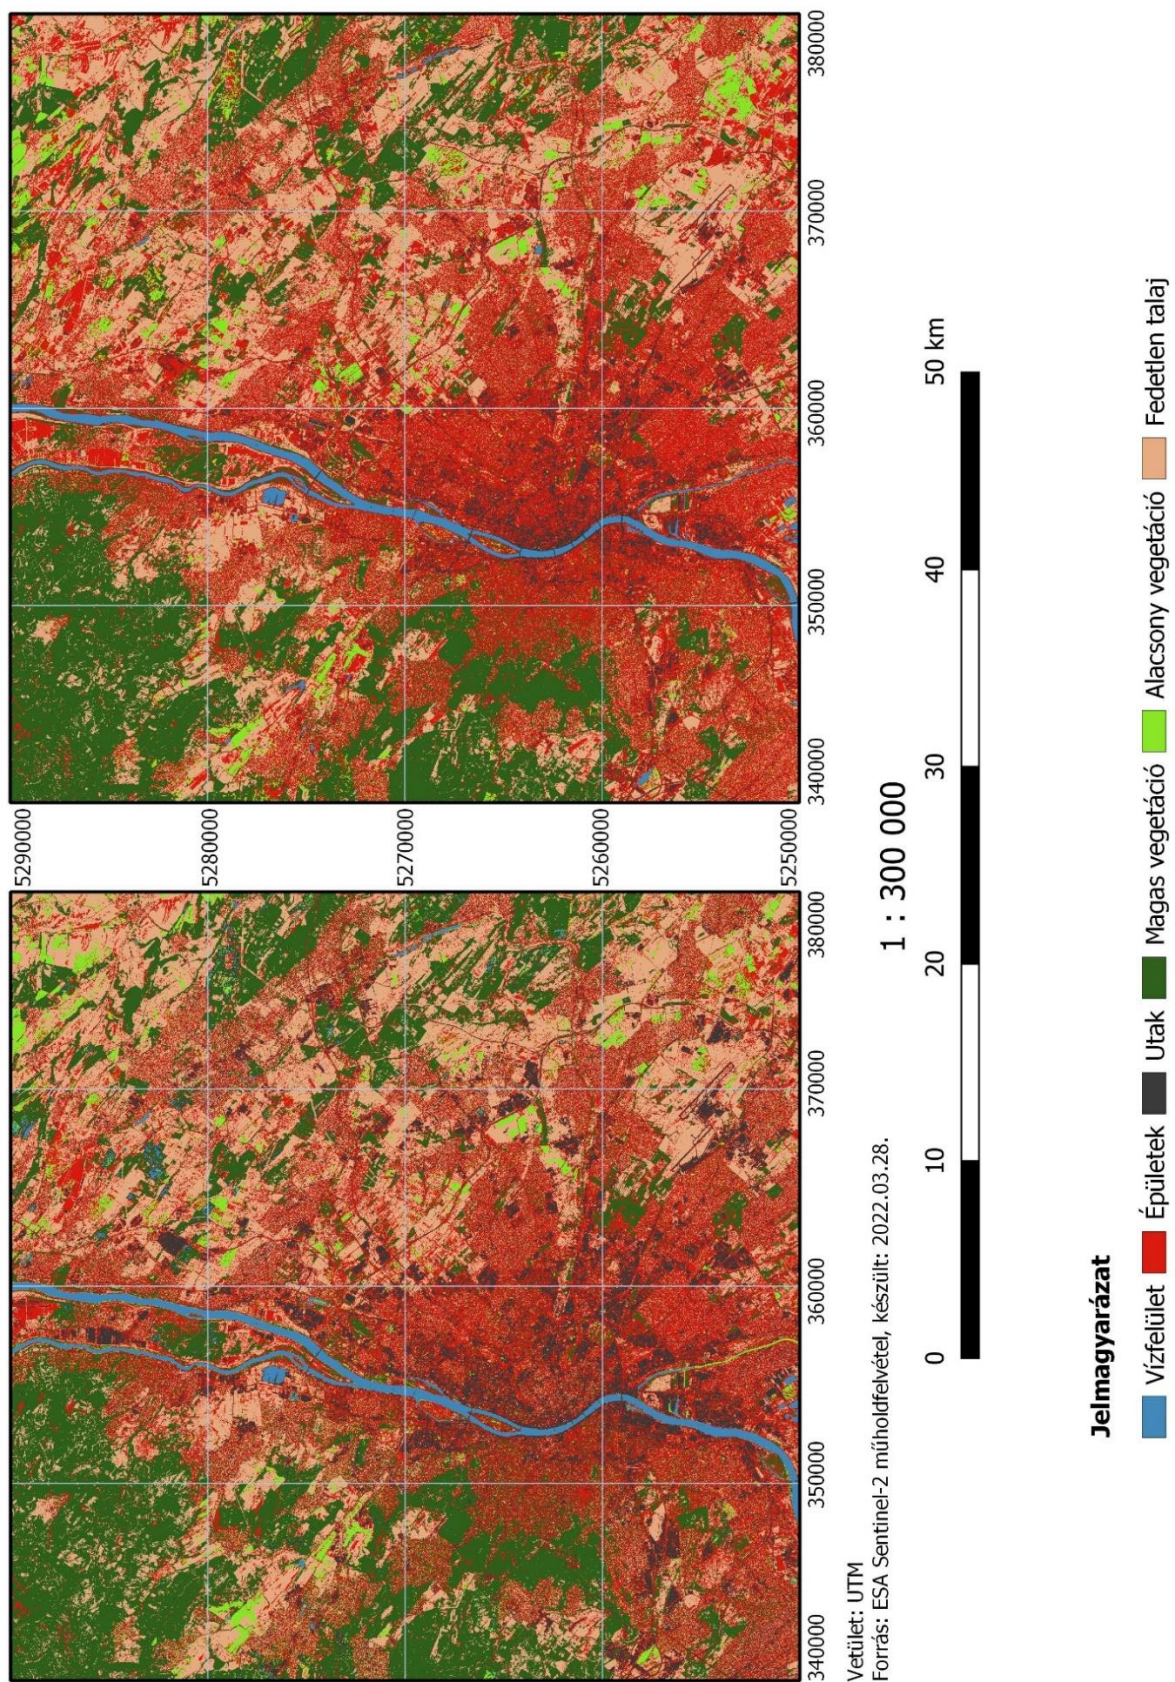
8. ábra A KNN osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén

SVM (RBF) osztályozás 6 osztály estén																				
Sentinel-2 (2,3,4-es sáv)						Sentinel-2 (2,3,4, 8 -as sáv)						Eltérés								
	1	2	3	5	6	8		1	2	3	5	6	8		1	2	3	5	6	8
1	866	0	0	0	1	0	1	866	0	1	0	0	0	1	0	0	1	0	-1	0
2	0	561	148	68	4	86	2	0	661	88	52	4	62	2	0	100	-60	-16	0	-24
3	1	137	709	4	5	11	3	0	91	767	0	0	9	3	-1	-46	58	-4	-5	-2
5	0	18	6	835	0	8	5	0	14	2	849	0	2	5	0	-4	-4	14	-1	-6
6	19	8	2	0	833	5	6	0	10	0	0	854	3	6	-19	-8	-2	0	21	-2
8	0	19	0	1	0	847	8	0	21	0	2	0	844	8	0	2	0	1	0	-3

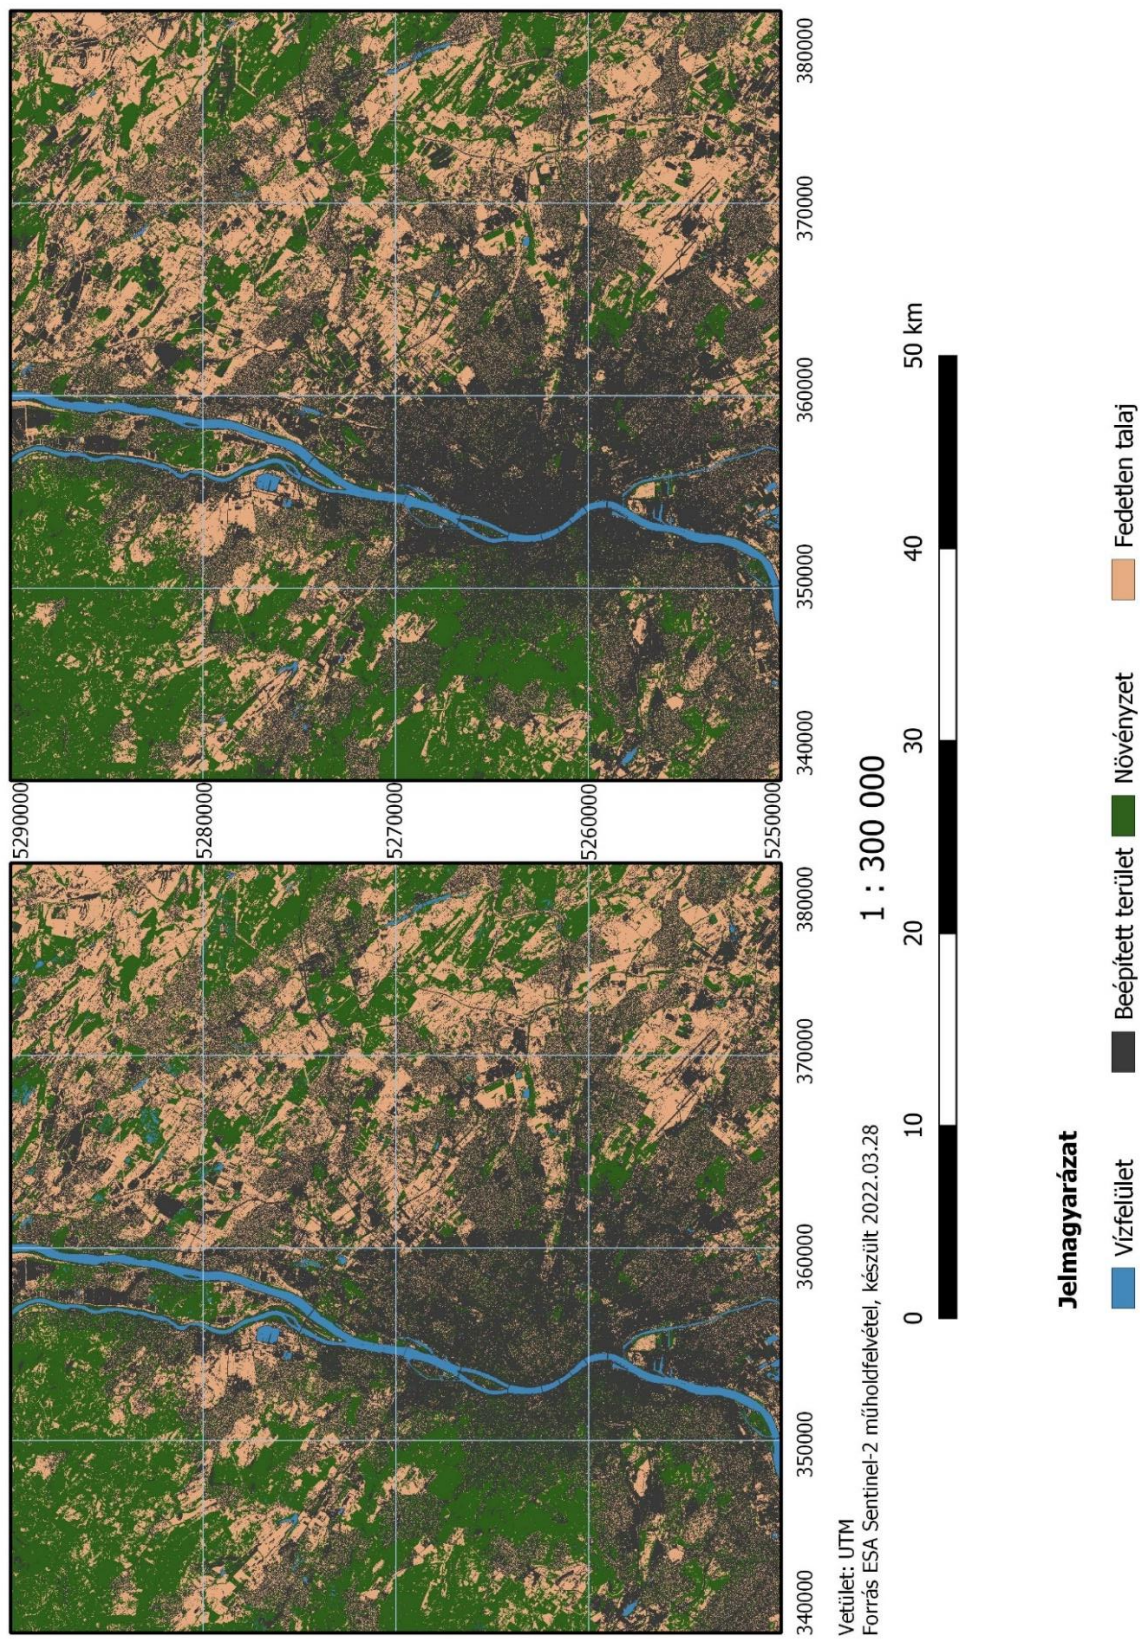
Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	98%	100%	99%	1	100%	100%	100%
2	76%	65%	70%	2	83%	76%	79%
3	82%	82%	82%	3	89%	88%	89%
5	92%	96%	94%	5	94%	99%	99%
6	99%	96%	97%	6	100%	99%	99%
8	89%	98%	93%	8	92%	97%	94%
	Kappa index		87%		Kappa index		92%

SVM (RBF) osztályozás 4 osztály esetén														
Sentinel-2 (2,3,4-es sáv)					Sentinel-2 (2,3,4, 8 -as sáv)					Eltérés				
	1	4	7	8		1	4	7	8		1	4	7	8
1	2800	3	0	0	1	2803	0	0	0	1	3	-3	0	0
4	2	2272	263	266	4	0	2476	129	198	4	-2	204	-134	-68
7	6	63	2717	17	7	0	59	2733	11	7	-6	-4	16	-6
8	0	87	10	2706	8	0	32	4	2767	8	0	-55	-6	61

Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	100%	100%	100%	1	100%	100%	100%
4	94%	81%	87%	4	96%	88%	92%
7	91%	97%	94%	7	95%	98%	96%
8	91%	97%	93%	8	93%	99%	96%
	Kappa index		91%		Kappa index		95%



9. ábra A SVM osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén



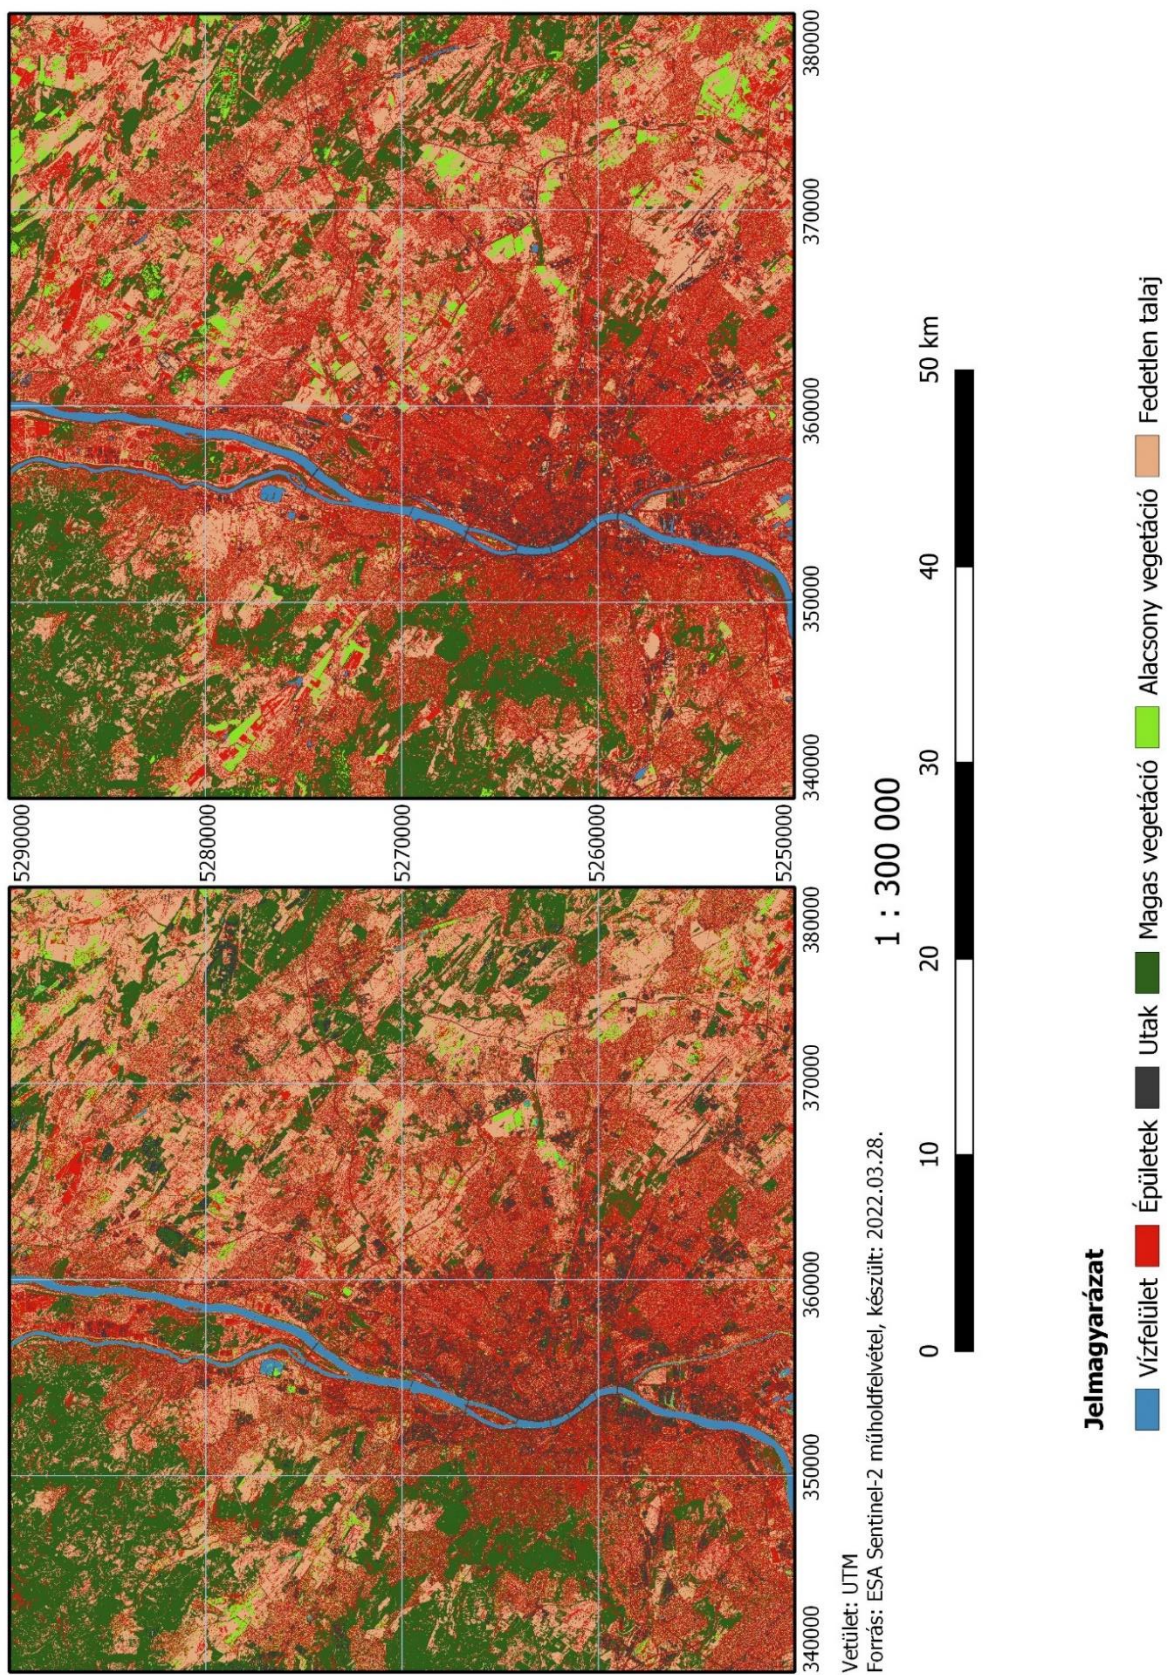
10. ábra A SVM osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén

DT osztályozás 6 osztály esetén																				
Sentinel-2 (2,3,4-es sáv)							Sentinel-2 (2,3,4, 8 -as sáv)							Eltérés						
	1	2	3	5	6	8		1	2	3	5	6	8		1	2	3	5	6	8
1	859	0	2	0	6	0	1	865	0	2	0	0	0	1	3	-1	4	0	-6	0
2	0	574	144	55	10	84	2	0	642	95	54	0	73	2	0	48	16	-25	-5	-34
3	0	186	663	2	2	14	3	0	119	740	0	0	8	3	0	-104	119	-7	-2	-6
5	0	23	2	831	1	10	5	0	25	1	831	0	10	5	0	-5	4	5	-1	-3
6	6	14	7	0	825	15	6	0	7	0	0	856	4	6	-6	-18	0	0	18	6
8	0	59	0	0	6	803	8	0	55	3	0	0	809	8	0	9	0	-11	0	0

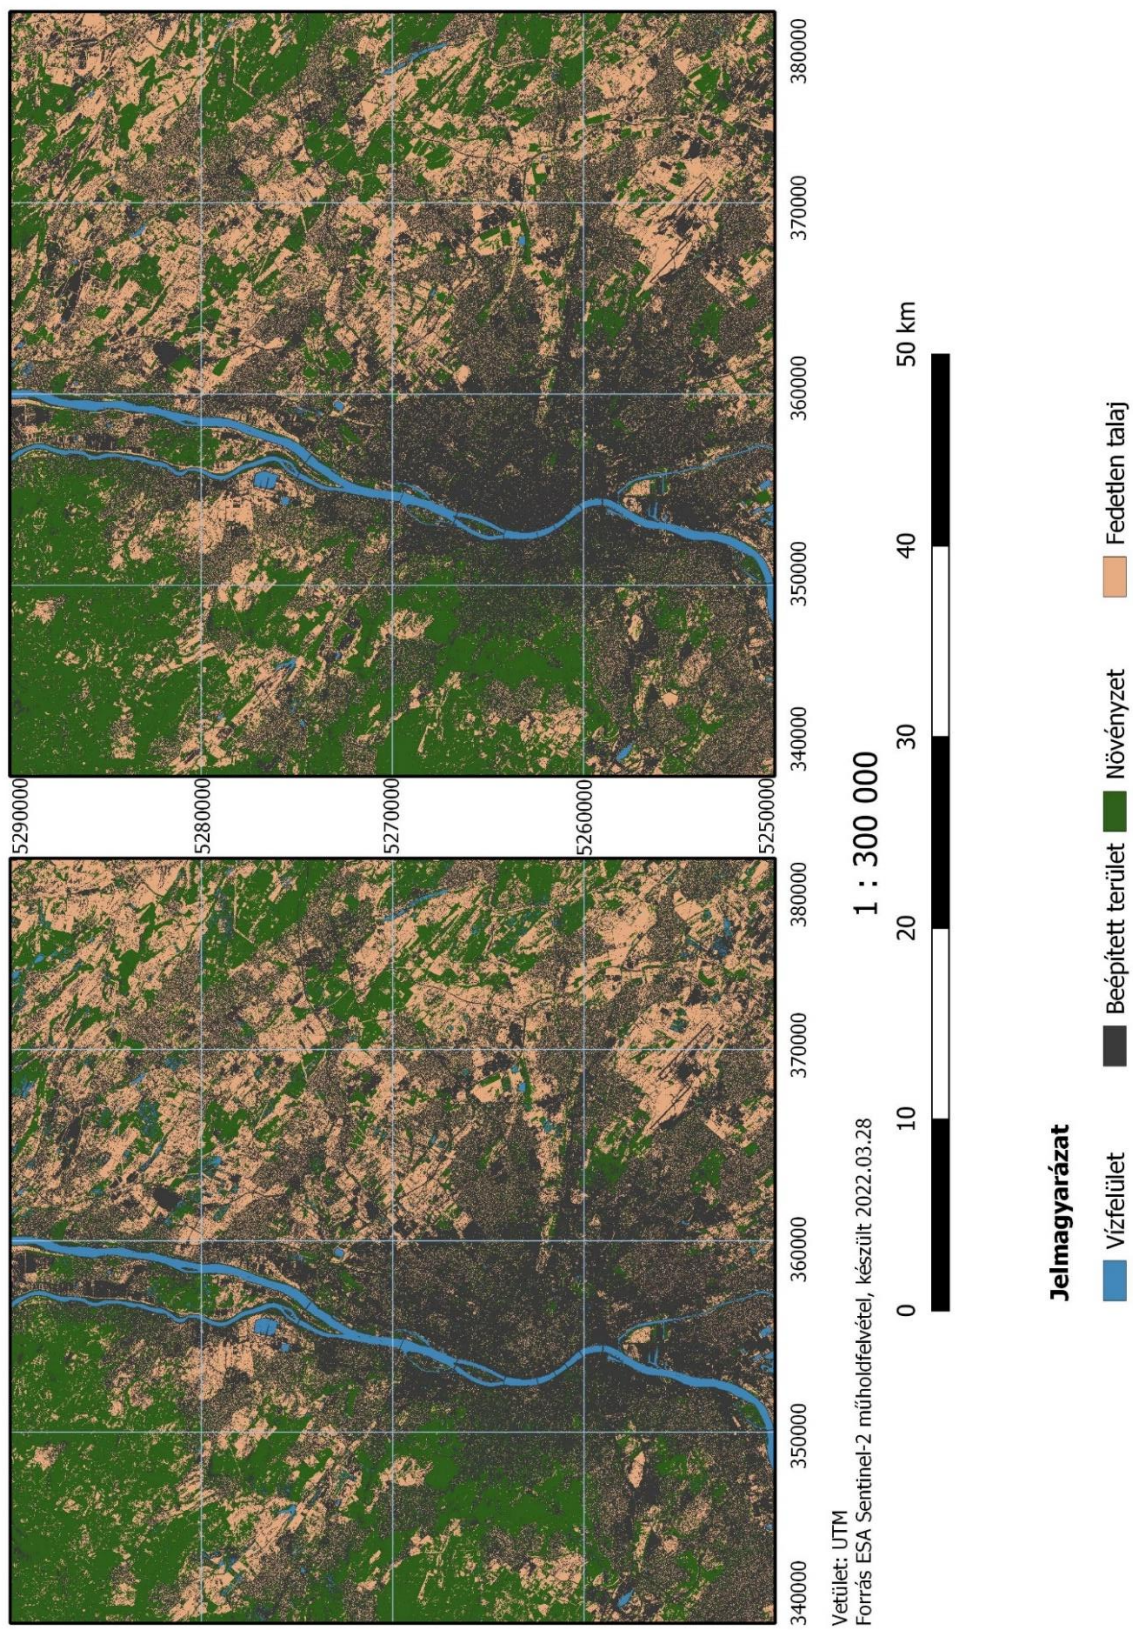
Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	99%	99%	99%	1	100%	100%	100%
2	67%	66%	67%	2	76%	74%	75%
3	81%	76%	79%	3	88%	85%	86%
5	94%	96%	95%	5	94%	95%	96%
6	97%	95%	96%	6	100%	99%	99%
8	87%	93%	90%	8	89%	93%	91%
	Kappa index		85%		Kappa index		89%

DT osztályozás 4 osztály esetén														
Sentinel-2 (2,3,4-es sáv)					Sentinel-2 (2,3,4, 8 -as sáv)					Eltérés				
	1	4	7	8		1	4	7	8		1	4	7	8
1	2801	1	1	0	1	2803	0	0	0	1	2	-1	-1	0
4	2	2369	172	266	4	0	2452	161	190	4	-2	83	-11	-76
7	8	129	2648	18	7	0	108	2689	6	7	-8	-21	41	-12
8	0	127	16	2660	8	0	107	12	2684	8	0	-20	-4	24

Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	100%	100%	100%	1	100%	100%	100%
4	90%	84%	87%	4	92%	87%	90%
7	93%	94%	94%	7	94%	96%	95%
8	90%	95%	93%	8	93%	96%	94%
	Kappa index		91%		Kappa index		93%



11. ábra A DT osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén



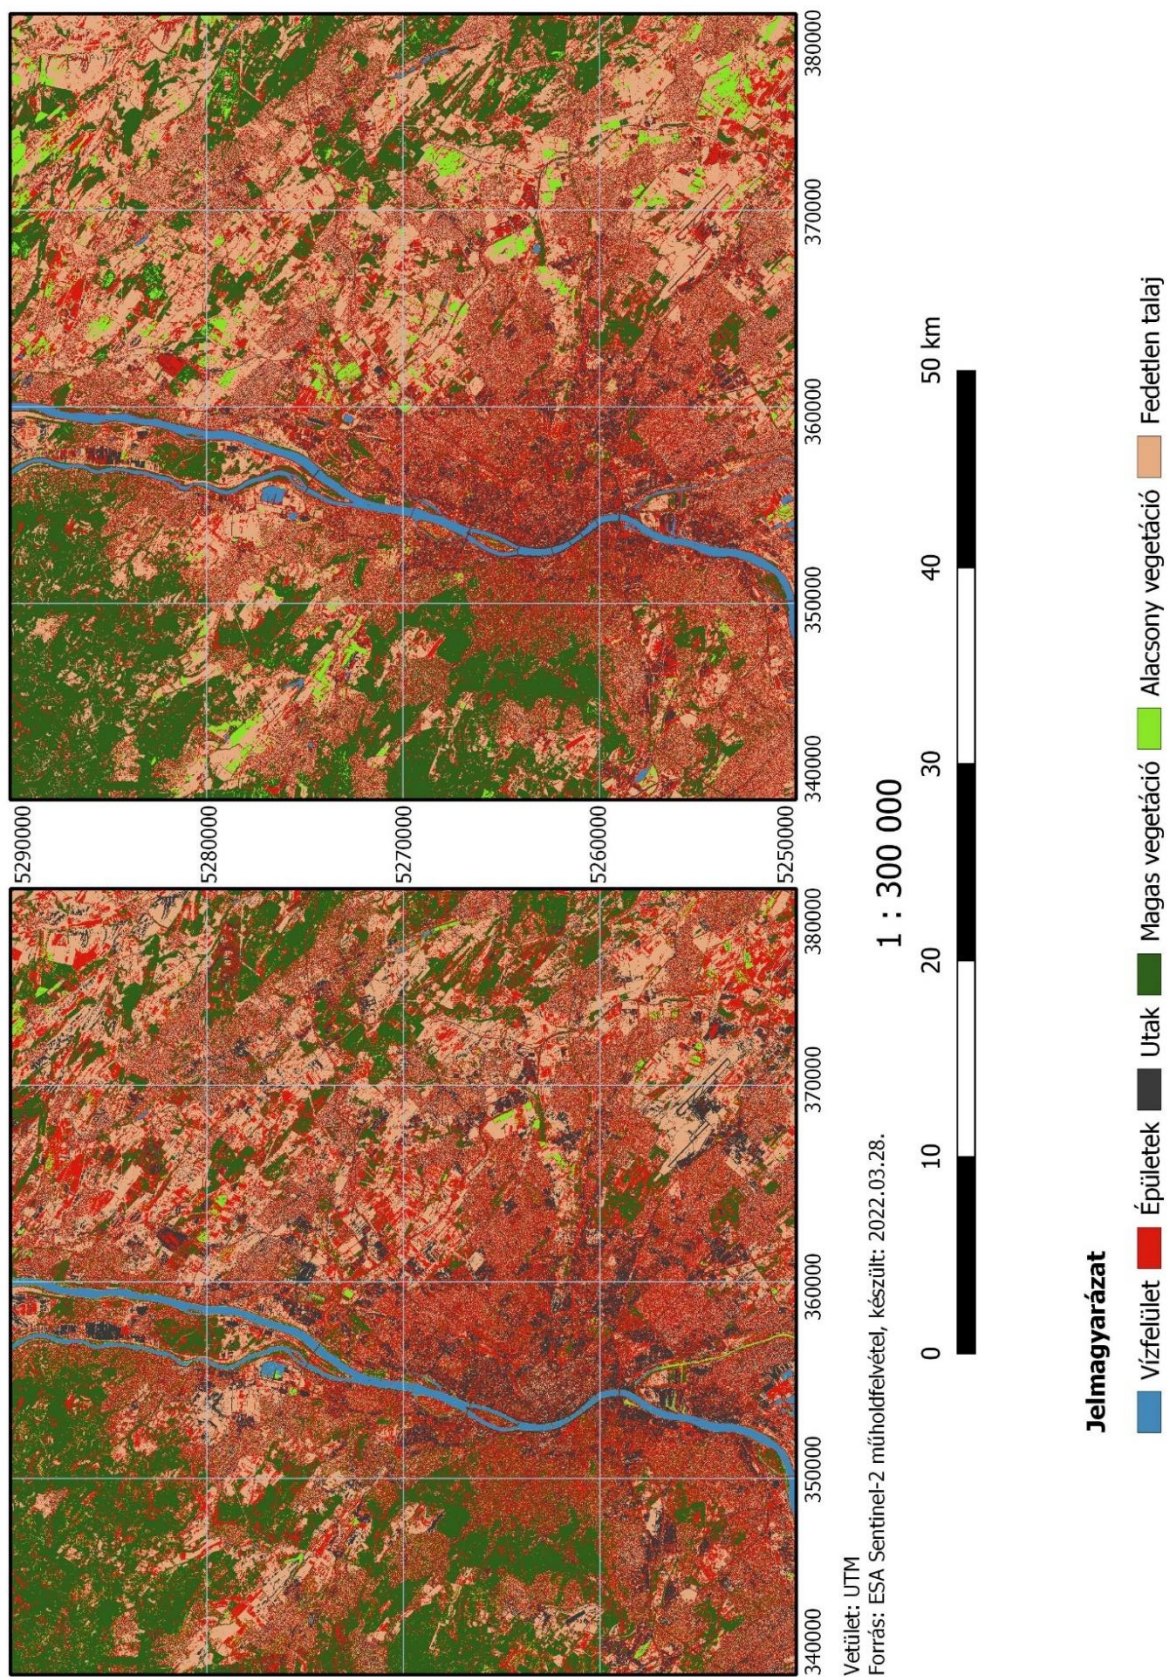
12. ábra A DT osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén

RF osztályozás 6 osztály esetén																				
Sentinel-2 (2,3,4-es sáv)							Sentinel-2 (2,3,4, 8 -as sáv)							Eltérés						
	1	2	3	5	6	8		1	2	3	5	6	8		1	2	3	5	6	8
1	861	1	0	0	5	0	1	865	0	2	0	0	0	1	4	-1	2	0	-5	0
2	0	420	184	65	10	188	2	0	420	153	52	3	239	2	0	0	-31	-13	-7	51
3	0	178	644	10	2	33	3	0	144	692	0	0	31	3	0	-34	48	-10	-2	-2
5	0	32	1	828	6	0	5	0	30	1	833	0	3	5	0	-2	0	5	-5	3
6	9	54	4	2	780	18	6	0	4	0	1	854	8	6	-9	-50	-4	-1	74	-10
8	0	99	13	0	0	755	8	0	39	1	0	1	826	8	0	-60	-12	0	1	71

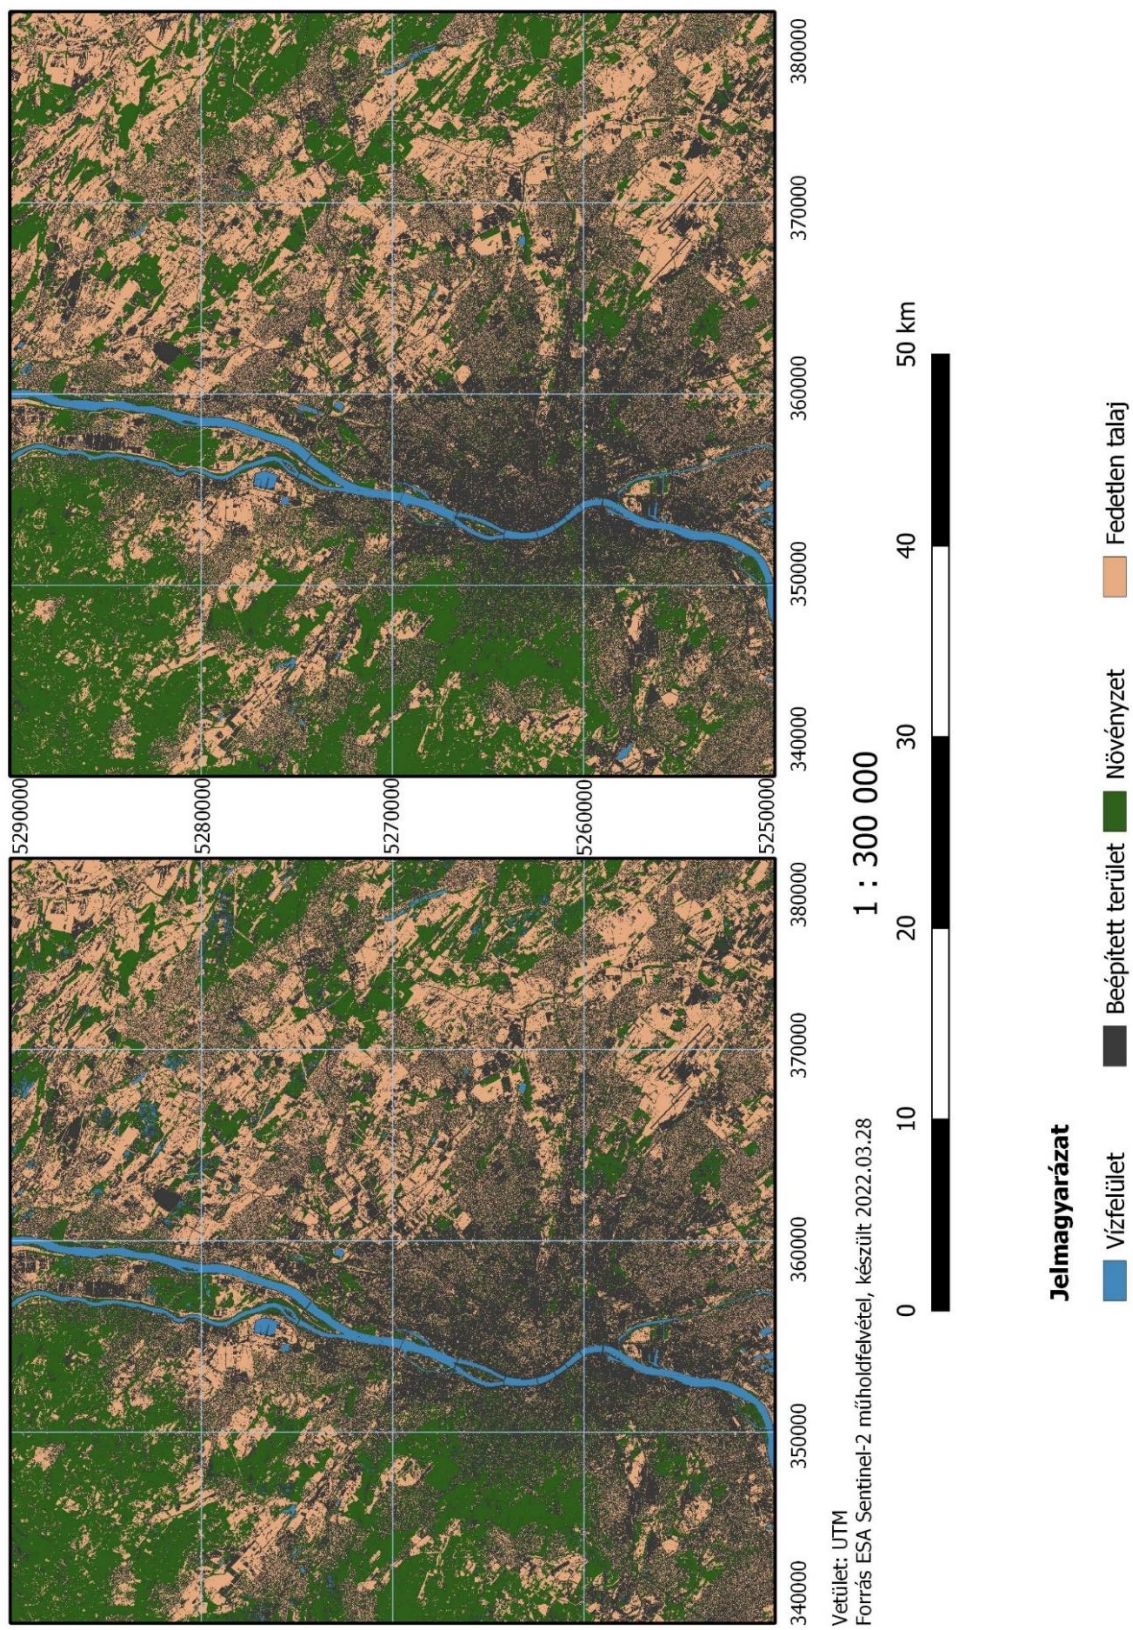
Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	99%	99%	99%	1	100%	100%	100%
2	53%	48%	51%	2	66%	48%	56%
3	76%	74%	75%	3	82%	80%	81%
5	91%	96%	93%	5	94%	96%	95%
6	97%	90%	93%	6	100%	99%	99%
8	75%	87%	81%	8	75%	95%	84%
	Kappa index		79%		Kappa index		84%

RF osztályozás 4 osztály esetén														
Sentinel-2 (2,3,4-es sáv)					Sentinel-2 (2,3,4, 8 -as sáv)					Eltérés				
	1	4	7	8		1	4	7	8		1	4	7	8
1	2796	1	6	0	1	2801	2	0	0	1	5	1	-6	0
4	1	1980	215	607	4	0	2146	204	453	4	-1	166	-11	-154
7	2	122	2660	19	7	0	79	2707	17	7	-2	-43	47	-2
8	0	119	5	2679	8	0	118	5	2680	8	0	-1	0	1

Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	100%	100%	100%	1	100%	100%	100%
4	89%	71%	79%	4	92%	77%	83%
7	92%	95%	94%	7	93%	97%	95%
8	81%	96%	88%	8	85%	96%	90%
	Kappa index		87%		Kappa index		90%



13. ábra A RF osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén



14. ábra A RF osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén

Megfigyelhető, hogy jellemzően jó eredményeket adtak vissza már az alapértelmezett beállításokkal is. Általánosságban elmondható, hogy a beépített terület részleteit a három sávon készült osztályozások bizonytalanul becslik meg, annak részleteinek elkülönítése gondot okozott. Azonban a 4 sávós osztályzások estében javulás tapasztalható.

Az előrejelzések pontosságát a Kappa index érték arányával szemléltetem.

Bayes-féle osztályozás	
Sentinel-2 (2,3,4-es sáv)	Sentinel-2 (2,3,4, 8 -as sáv)
4 kategória esetén 91%	4 kategória esetén 93%
6 kategória esetén 85%	6 kategória esetén 90%
KNN osztályozás	
Sentinel-2 (2,3,4-es sáv)	Sentinel-2 (2,3,4, 8 -as sáv)
4 kategória esetén 92%	4 kategória esetén 94%
6 kategória esetén 85%	6 kategória esetén 90%
SVM (RBF) osztályozás	
Sentinel-2 (2,3,4-es sáv)	Sentinel-2 (2,3,4, 8 -as sáv)
4 kategória esetén 91%	4 kategória esetén 95%
6 kategória esetén 87%	6 kategória esetén 92%
DT osztályozás	
Sentinel-2 (2,3,4-es sáv)	Sentinel-2 (2,3,4, 8 -as sáv)
4 kategória esetén 91%	4 kategória esetén 93%
6 kategória esetén 85%	6 kategória esetén 89%
RF osztályozás(OpenCV)	
Sentinel-2 (2,3,4-es sáv)	Sentinel-2 (2,3,4, 8 -as sáv)
4 kategória esetén 87%	4 kategória esetén 90%
6 kategória esetén 79%	6 kategória esetén 84%

Az eredményeken látszik, hogy hat kategória esetén döntően 5% körülire tehető az előrejelzés javulása, valamint 4 kategória esetén is 3% körüli javulás látható a multispektrális kép esetén. A legjobb becslést az SVM RBF kernelje érte el.

Ezután elvégeztem az egyes osztályozások eredményeinek kiértékelését véletlen ellenőrző pontok segítségével. Ehhez vettem 300 véletlenszerűen kiválasztott pontot, majd ezek kategóriáit meghatároztam. Az eredményt a control.shp-be mentettem el. Ezután kiszámítottam a kontrolpontot és az elkészült osztályozott kép hibamátrixát.

Bayes - féle osztályozás 6 osztály esetén																				
Sentinel-2 (2,3,4-es sáv)							Sentinel-2 (2,3,4, 8 -as sáv)							Eltérés						
	1	2	3	5	6	8		1	2	3	5	6	8		1	2	3	5	6	8
1	4	0	0	0	1	0	1	4	0	1	0	0	0	1	0	0	1	0	0	0
2	0	14	5	0	1	7	2	0	17	5	0	0	5	2	0	3	0	0	-1	-2
3	0	14	13	1	0	2	3	0	18	8	1	0	3	3	0	4	-5	0	0	1
5	0	31	1	70	1	10	5	0	31	0	69	0	13	5	0	0	-1	-1	-1	3
6	0	24	3	2	8	10	6	0	14	1	2	12	18	6	0	-10	-2	0	4	8
8	0	21	4	5	0	48	8	0	35	5	3	0	35	8	0	14	1	-2	0	-13

Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	100%	80%	89%	1	100%	80%	89%
2	13%	52%	21%	2	14%	63%	24%
3	50%	43%	46%	3	40%	26%	32%
5	90%	62%	73%	5	92%	61%	73%
6	73%	17%	28%	6	100%	26%	40%
8	62%	28%	62%	8	47%	45%	46%
	Kappa index		40%		Kappa index		35%

Bayes - féle osztályozás 4 osztály esetén														
Sentinel-2 (2,3,4-es sáv)					Sentinel-2 (2,3,4, 8 -as sáv)					Eltérés				
	1	4	7	8		1	4	7	8		1	4	7	8
1	4	1	0	0	1	4	1	0	0	1	0	0	0	0
4	0	45	3	9	4	0	46	3	8	4	0	1	0	-1
7	0	60	77	32	7	0	36	93	31	7	0	-24	26	1
8	0	26	4	48	8	0	38	4	36	8	0	12	0	-12

Pontosságbecslés							
Sentinel-2 (2,3,4-es sáv)				Sentinel-2 (2,3,4, 8 -as sáv)			
	Precision	Recall	F-score		Precision	Recall	F-score
1	100%	80%	89%	1	100%	80%	89%
4	34%	79%	48%	4	38%	81%	52%
7	92%	48%	63%	7	93%	58%	72%
8	60%	61%	60%	8	48%	46%	47%
	Kappa index		40%		Kappa index		41%

Az ellenőrzés eredményeként közepes pontosságú egyezés látható, azonban ez nem feltétlen utal az osztályozó hibájára. Az első (6 osztályos) ellenőrzés során leggyengébben teljesítő osztály az épületek (2.) osztálya volt, ám figyelembe véve a csoport természetét, azaz, hogy épületek utcákkal vannak elválasztva, amik az utak (3) osztályt alkotják, valamint, hogy az épülethez tartozhat kert is, ami a különböző vegetációs osztályokba tartozhat (5,6) és a Sentinel műholdak térbeli felbontásának korlátját (10m), nem meglepő, hogy a gépi tanulást alkalmazó algoritmusok némileg megzavarodhatnak. Ezt támasztja alá az is, hogy a második (4 osztályos) ellenőrzés során ez a csoport (4) jelentős javulást ért el. Hasonló javulás figyelhető meg az egyesített növényzet (7) osztályban is.

Konklúzió

Végezetül az alábbiakban szeretném összefoglalni a dolgozatom eredményeit. A távérzékelés felvétel-elemzésének alapproblémája az, hogy a Föld felszínét, hogy lehet különböző célkategóriák, tematikus osztályok feltérképezésére használni. Ezt a földfelszíni elemekről érkező sugárzásokon keresztül, ezen sugárzások együttes kiértékelésével, osztályozásával. Ez a numerikus osztályozás a megoldástól függően sok lépésből áll. Temérdek szoftver megvalósítása ismert az elmúlt évtizedekből. Kiemelkedik ezek közül a nyílt hozzáférésűek családja. Ezek közül az Orfeo Tool Box (OTB) nevű, eredetileg a Francia Űrügynökség kezdeményezésére kifejlesztett csomagját vettem használatba és vizsgáltam meg. Első lépésben multispektrális adatokat gyűjtöttem az Európai űrügynökség adatbázisából. Majd azokat ennek a nyílt forráskódú szoftvernek (OTB) segítségével feldolgoztam, több különböző eljárással. Ezeket az eljárásokat a dolgozatom első felében igyekeztem részleteiben is bemutatni.

A feldolgozás lépéseit dokumentáltam, ahol lehetett ezeket a lépéseket és a használandó paramétereket megmagyaráztam, majd a gyakorlatba átültetve ezeket egy egyszerű feladaton keresztül ki is próbáltam.

Az eredmények birtokában arra a megállapításra jutottam, hogy még egy nagyon bonyolult tematikus feladat is kellő pontossággal véghez vihető. Arra a megállapításra jutottam, hogy a szoftver tematikus szempontból is egy hasznos kutatási eszközrendszer, mely érdemes további vizsgálódásra.

Azonban meg kell jegyezni, hogy a hatékony felhasználáshoz szükséges a háttér AI/PR tudás és alkalmazásának mélyítése kiegészítő projekteken keresztül, de legalábbis egy hosszabb gyakorlati projekt-tapasztalat a technikai alkalmasságon túli tapasztalatszerzésre ezzel az eszközrendszerrel.

Mindenesetre ez egy hatékony sokoldalú (redundáns) eszközrendszer, amely egyes moduljainak elhagyása, vagy alternatív használata során is képes teljes eredményeket adni valódi tematikus projekteken is.

Irodalomjegyzék

<https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2> Utolsó elérés: 2022.12.29

<https://scihub.copernicus.eu/> Utolsó elérés: 2022.12.29

https://www.orfeo-toolbox.org/CookBook/Applications/app_ComputeImagesStatistics.html

https://www.orfeo-toolbox.org/CookBook/Applications/app_TrainImagesClassifier.html

https://www.orfeo-toolbox.org/CookBook/Applications/app_ImageClassifier.html

https://www.orfeo-toolbox.org/CookBook/Applications/app_ComputeConfusionMatrix.html

Utolsó elérés 2022.12.29

<https://docs.opencv.org/2.4/modules/ml/doc/ml.html>

Utolsó elérés 2022.12.29

http://image.diku.dk/shark/doxygen_pages/html/classes.html

Utolsó elérés 2022.12.29

Christian Igel-Verena Heidrich-Meisner-Tobias Glasmachers(2008): Shark. Journal of Machine Learning Research 9, pp. 993-996.

<https://www.csie.ntu.edu.tw/~cjlin/libsvm/>

Chih-Wei Hsu - Chih-Chung Chang - Chih-Jen Lin (2003), szerk.: A Practical Guide to Support Vector Classification., National Taiwan University Department of Computer Science

B. E. Boser, I. Guyon - V. Vapnik (1992). A training algorithm for optimal margin classifiers. Proceedings of the Fifth Annual Workshop on Computational Learning Theory, pages 144–152. ACM Press.

Friedman, J. H. - Hastie, T. - Tibshirani, - R. (1998): Additive Logistic Regression: a Statistical View of Boosting. Technical Report, *, Stanford University, Department. of Statistics.

Breiman, L. - Friedman, - J. Olshen, - R. and Stone, C. (1984): *Classification and Regression Trees*, Wadsworth.

K.Fukunaga (1990) szerk.: Introduction to Statistical Pattern Recognition., New York Academic Press.

https://www.stat.berkeley.edu/users/breiman/RandomForests/cc_home.htm

https://docs.opencv.org/2.4/modules/ml/doc/k_nearest_neighbors.html

Utolsó elérés 2022.12.29

Cohen, J. (1960): A Coefficient of Agreement for Nominal Scales. Educational and Psychological Measurement, 20(1), 37–46.

Ábrajegyzék

15. ábra A Sentinel-2 felvételek letöltésére szolgáló honlap kezelőfelülete (4. oldal)
216. ábra Az OTB számára megadandó kötelező paraméterek (11. oldal)
3. ábra A zavar mátrix leegyszerűsített modellje (19. oldal)
17. ábra A Sentinel-2
S2B_MSIL2A_20220328T095029_N0400_R079_T34TCT_20220328T125103 kódú
felvétele (21. oldal)
5. ábra A Bayes - féleosztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (24. oldal)
6. ábra A Bayes - féle osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (25. oldal)
7. ábra A KNN osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (27. oldal)
8. ábra A KNN osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (28. oldal)
9. ábra A SVM osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (30. oldal)
10. ábra A SVM osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (31. oldal)
11. ábra A DT osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (33. oldal)
12. ábra A DT osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (34. oldal)
13. ábra A RF osztályozás eredménye hat kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (36. oldal)
14. ábra A RF osztályozás eredménye négy kategória esetén három (bal oldal) illetve négy (jobb oldal) spektrális sáv esetén (37. oldal)

Köszönetnyilvánítás

Jelen dolgozat nem jöhetett volna létre a körülöttem lévő emberek segítségével nélkül. Hálás köszönettel tartozom mindenk előtt Dr. Jung András konzulensemnek, aki idejét és fáradságát nem kímélve mindig a rendelkezésemre állt valamint Csornai Gábornak.

SZAKDOLGOZAT / DIPLOMAMUNKA

EREDETISÉG NYILATKOZAT

AlulírottSipos Kristóf.....Neptun-kód:D7BSB1.....

ezennel kijelentem és aláírással megerősítem, hogy az Eötvös Loránd Tudományegyetem Informatikai Karának, Térképtudományi és Geoinformatikai Intézetében írt,

Multispektrális képfeldolgozás, nyílt forráskódú alkalmazások segítségével

.....

című diplomamunkám saját, önálló szellemi termékem; az abban hivatkozott szakirodalom felhasználása a szerzői jogok általános szabályainak megfelelően történt.

Tudomásul veszem, hogy szakdolgozat/diplomamunka esetén plágiumnak számít:

- szószerinti idézet közlése idézőjel és hivatkozás megjelölése nélkül;
- tartalmi idézet hivatkozás megjelölése nélkül;
- más publikált gondolatainak saját gondolatként való feltüntetése.

A témavezető által benyújtásra elfogadott szakdolgozat PDF formátumban való elektronikus publikálásához a tanszéki honlapon

HOZZÁJÁRULOK

NEM JÁRULOK HOZZÁ

Budapest, 2022.12.29

Sipos Kristóf

.....

hallgató aláírása