



Faállomány típusok térképezése Sentinel-2 űrfelvétel idősorozaton Deep learning osztályozóval


Barton Iván¹, Czimmer Kornél¹, Király Géza¹, Moskal L. Monika²




¹Soproni Egyetem, Erdőmérnöki Kar, GEVI FTT

²Precision Forestry Cooperative, UW SEFS


Faállomány típusok tárolása a jelenlegi rendszerben





- 2-3 hektáros erdőrészek
- Korlátozott lehetőségek vannak az egyes fafajok térbeli elhelyezkedésének tárolására



Faállomány típusok megjelenése több időpontú Sentinel-2 felvételeken




NIR (Band4) time stack





NIR (Band4) time stack



Képosztályozás munkafolyamata
hagyományos osztályozó módszerekkel:




Képosztályozás munkafolyamata Deep learning
osztályozó módszerekkel:




Anyag

A Börzsöny hegység és környezete




Vizsgált időszak:
2017.03.01 - 2017.10.31

Erdőrészlet poligonok faállomány-
típus szerint színezve




Sentinel-2 műholdak felvételei




Sentinel-2A és 2B
10 és 20 m felbontású sávok


Előfeldolgozás áttekintése





Idősorozat alapú felhő és felhőárnyék maszkolás




Vastag felhőréteg a kék sáv idősorozatának 8. időpontjában:



Felhőárnyék a közeli infravörös sáv idősorozatának 8. időpontjában:




Vékony felhőréteg a kék sáv idősorozatának 5. időpontjában:





Idősorozat alapú felhő és felhőárnyék maszkolás II.

Sebesség változás kép a közeli infravörös sávok alapján:



Sebesség változás kép a kék sávok alapján:




$$x_k = F_k x_{k-1} + W_k$$


x_k : A rendszer állapot vektora k időpontban
 F_k : Az állapot változás modell alapján meghatározott érték $k-1$ időpontban
 W_k : A folyamat zaja k időpontban

$$\hat{x}_k = \begin{bmatrix} \text{pozíció} \\ \text{sebesség} \end{bmatrix}$$


$\hat{x}_k$: A rendszer állapotának optimális becslése k időpontban



A hiányzó reflektancia értékek modellezése az idősorozatban



Topográfiai normalizáció az empirikus forgatás módszerével



$$L_h(\lambda)_{xy} = L_i(\lambda)_{xy} - a(\lambda) \cdot (IC_{xy} - IC_h)$$

$L_h(\lambda)_{xy}$: Normalizált reflektancia az adott sáv egy pixelén.
 $L_i(\lambda)_{xy}$: Eredeti reflektancia az adott sáv egy pixelén.
 $a(\lambda)$: Lineáris regresszió meredeksége az adott sávon.
 IC_{xy} : Megvilágítottsági állapot a felületen.
 IC_h : A vízszintes felület megvilágítottsági állapota, mely egyenlő a napállás zenith szögének koszinuszával.

Osztályozás áttekintése

Faállomány típusok osztályozás űrfelvételek alapján:

1980: csak spektrális jellemzők

Landsat for Practical Forest Type Mapping: A Test Case

Computer classified Landsat maps agreed to within 5 percent of a conventional inventory of forest lands in northern Maine.

KEVIN BRADY
Department of Earth Sciences
Dartmouth College
Hanover, NH 03755
and NASA/Goddard Institute for Space Studies
New York, NY 10526

ARTHUR G. DITCH, JR.
Cooperative Forestry Program
Cooperative Extension Service
University of New Hampshire
Durham, NH 03824
SARAH D. WOODCOCK
Senior Forest Land Computer
Analyst, ME 04401

2018: spektrális-időbeli jellemzők



Remote Sensing of Environment
Volume 210, 1 June 2018, Pages 193-207



Improved mapping of forest type using spectral-temporal Landsat features

Valerie J. Pasquarella ^{a, b, c}, Christopher E. Holden ^a, Curtis E. Woodcock ^a

2018: spektrális-időbeli-térbeli jellemzők

Faállomány típusok térképezése Sentinel-2 űrfelvétel idősorozaton Deep learning osztályozóval

Barton Iván¹, Czimmer Kornél¹, Király Géza¹, Moskal L. Monika²




11+1 faállomány típus:


- Akác
- Bükk
- Fenyők
- Magaskőris
- Gyertyán
- Tölgyek
- Hársak
- Virágos Kőris
- Cser
- Éger
- Vöröstölgy
- Egyéb

Deep learning osztályozó

DEEP LEARNING: olyan gépi tanulási módszerek összefoglaló neve, melyek mély mesterséges neurális hálózatok segítségével oldanak meg osztályozási vagy regressziós problémákat. Jellemzően adatvezérelt, felügyelt típusú osztályozók készítésére alkalmazzák nagyon széles körben. A távérzékelte adatok kiértékelésének munkafolyamatába integrálható.



Konvolúciós mély neurális hálózat osztályozó



Bemenő adatok

Konvolúciós szűrők


Neuron rétegek

Osztályozó modell

Forrás: <https://playground.tensorflow.org>


2D Konvolúciós Neurális Hálózat

(CNN) felépítése




- 5 konvolúciós blokk
- 3 teljesen kapcsolt blokk
- ~511424 kapcsolat


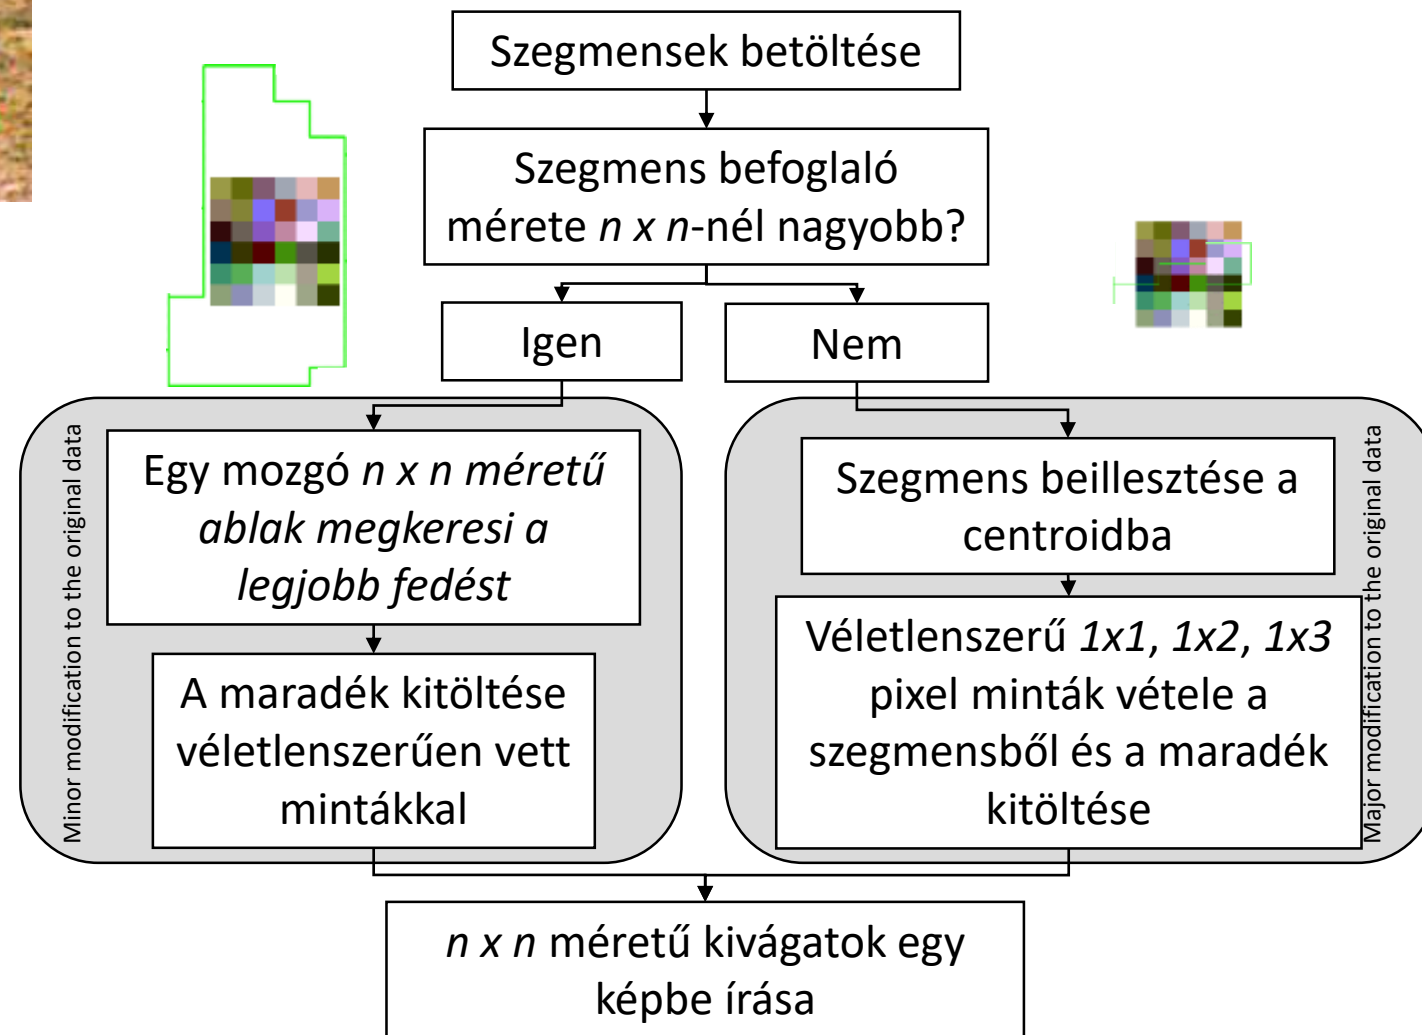


Konvolúciós blokkok:



Teljesen összekapcsolt blokkok:



Szegmenss konverzió




Előfeldolgozás eredménye

Multitemporális felhőmaszkolás


Felhasználói pontosságok:

Dátum	KF maszk	S2C maszk
2017.04.27	78.7%	7.2%
2017.06.28	93.7%	28.0%
2017.07.03	86.6%	3.5%
2017.07.11	98.9%	13.3%
2017.07.26	67.8%	0.1%
2017.09.01	89.0%	19.5%



Átlag: 86% 12%





A felhőmaszkok alapján az elérhető érvényes megfigyelések száma



Topográfiai normalizáció



Kép pótlás





Osztályozás eredménye

CNN

Random forest



Jelmagyarázat

- Akác
- Bükk
- Fenyők
- Magaskőr
- Gyertyán
- Tölgyek
- Hársak
- Virágos Kőr
- Cser
- Éger
- Vöröstölgy
- Egyéb



Osztályozás eredménye



Természetes eredetű erdők



Jelmagyarázat

- Akác
- Bükk
- Fenyők
- Magaskőris
- Gyertyán
- Tölgyek
- Hársak
- Virágos Kőris
- Cser
- Éger
- Vöröstölgy
- Egyéb

Mesterséges eredetű erdők



CNN osztályozás összehasonlítása

Random forest osztályozóval


Hibamátrix a két osztályozás között

		CNN												
		Akác	Bükk	Fenyő	Magas kőris	Gyertyán	Tölgyek	Hársak	Virágos kőris	Cser	Éger	Vöröstölgy	egyéb	
Random Forest	Akác	3164	0	1	1	16	542	9	0	16	21	1	8	83.73%
	Bükk	1	12187	11	30	3375	664	810	678	54	134	43	893	64.55%
	Fenyő	21	5	2779	5	380	632	155	0	132	201	3	832	54.01%
	Magas kőris	0	183	6	463	243	214	644	2	13	52	24	45	24.51%
	Gyertyán	3	619	0	6	6380	765	252	276	152	36	157	311	71.23%
	Tölgyek	173	344	0	14	2350	17652	295	11	1191	238	141	181	78.14%
	Hársak	0	82	0	0	330	26	256	4	2	21	1	35	33.82%
	Virágos kőris	0	179	0	1	945	91	107	1066	60	13	38	468	35.92%
	Cser	268	28	1	5	1732	2754	108	12	6932	74	79	263	56.56%
	Éger	658	185	2	10	6315	6281	887	206	2378	4335	516	4252	16.66%
	Vöröstölgy	52	170	0	2	7501	2034	429	956	483	187	1620	9919	6.94%
	egyéb	7	902	70	8	4804	711	1003	584	613	271	388	38753	4.08%
		72.78%	1.33%	96.83%	84.95%	18.53%	54.54%	5.17%	28.09%	57.64%	77.65%	53.80%	69.25%	

Összesített pontosság: 8.78%

Kappa: 0.029

Egyező osztályok sűrűség térképe



Összegzés

- A fejlesztett előfeldolgozó módszer 25x25 km területen alkalmazható hatékonyan.
- Mezőgazdasági területek felett is alkalmazható, ha idősorozat modellt és további sávokat vezetünk be.
- Közeli időpontban, különböző műholdpályákról készült felvételek is hasznosak.
- Az idősorozatban a kor jellemző spektrálisan elmosódik, a szerkezet utal rá.
- Tanító és teszt adatok nagyon korlátozottan érhetőek el.
- Nem megszokott, erdő szerkezetet leíró paraméter is kinyerhető a módszerrel, aminek az eredményét kombinálni lehet a most bemutatott térképpel.

Köszönöm a figyelmet!

Köszönetnyilvánítás:

