

On separability of boreal tree species in multispectral lidar data (valmiin työn esittely)

Milla Laurikkala

27.08.2021

Ohjaaja: *TkT Antero Kukko*

Valvoja: *Prof. Pauliina Ilmonen*


Työn saa tallentaa ja julkistaa Aalto-yliopiston avoimilla verkkosivuilla. Muilta osin kaikki oikeudet pidätetään.

Taustaa

- Puulajit ovat tärkeitä metsän monimuotoisuuden ja kestävyysden takia
- Täsmällistä ja ajan tasalla olevaa dataa metsien puulajeista tarvitaan metsänhoitoa, -suojelua ja inventointia varten
- Perinteiset menetelmät metsän inventointiin ovat kalliita ja hitaita
- MS-ALS:n avulla voidaan kerätä tarkkaa pistepilvidataa suuriltakin alueilta nopeasti
- Työn tavoitteena on kehittää menetelmiä, joilla voidaan tunnistaa puulajeja ilmasta kerätystä pistepilvidatasta


Aineisto

- Kuvattu keväällä 2018 Evon alueella Etelä-Suomessa
- Koostuu erillisistä 1 ha:n kokoisista alueista
- Tiheää pistepilvidataa
 - 1550 nm ja 905 nm aallonpituudet
- Jokaiseen pisteeseen on liitetty 3D-sijainnin lisäksi heijastuneen pulssin intensiteetti, kaikunumero ja kaikujen kokonaismäärä



- Referenssidata vuodelta 2014
- Sisältää jokaisen puun sijainnin, lajin, tilavuuden, ympärysmitan ja muita ominaisuuksia

Aineiston esikäsittely



- Pistepilvistä segmentoitii 93 puuta käsin CloudCompare-ohjelman avulla
- Jokaisen puun laji tunnistettiin referenssidatan avulla

puulaji	mänty	kuusi	koivu	muut lehtipuut
lukumäärä	28	24	26	15

Aineiston esikäsittely - 2

- Segmentoiduista puista poistettiin alimmat 2 metriä, jotta maahan tai aluskasvillisuuteen kuuluvat pisteet eivät vääristäisi tuloksia
 - Valittiin puita, jotka kasvoivat mahdollisimman paljon erillään muista puista
- Jokainen puu muutettiin MATLABiin struct arrayksi

Menetelmät

Feature	Definition
Geometric features	
Hmax	Maximum of normalized height of points
Hmean	Mean normalized height
Hstd	Standard deviation of normalized height
CA	Crown area (from 2D convex hull)
CD	Crown diameter considering crown area as a circle
CV	Crown volume (from 3D convex hull)
D_i	Proportion of points in each layer when tree height was segmented into 10 equal layers
Reflectance features for both channels	
Imax	Maximum of reflectance
Imin	Minimum of reflectance
Imean	Mean reflectance
Istd	Standard deviation of reflectance
Iskew	Skewness of reflectance
Ikurt	Kurtosis of reflectance
$I_{5, 10 \text{ to } 90}$	5th, 10th, ... to 90th percentiles of reflectance
Echo features	
O	Proportion of only returns
F	Proportion of first returns
Id	Proportion of intermediate returns (2, 3)
L	Proportion of last returns

Luokittelumenetelmät

- Naiivi Bayes, satunnaismetsä, tukivektorikone
- Yksittäisristiinvalidointi käyttäen kaikkia ominaisuuksia
- Lisäksi tukivektorikoneen kanssa käytettiin poistovalintaa parhaiden ominaisuuksien löytämiseksi
- Luokittelun hyvyyttä mitattiin tarkkuudella eli suhteella oikein luokitellut puut / kaikki puut

Tulokset - 1

- Luokittelumenetelmien tulokset (%)

	Naive Bayes	Random Forest	Support vector machine
CV accuracy	91.4	94.6	91.4

- Puulajien keskimääräiset tulokset (%)

	pine	spruce	birch	other deciduous trees
accuracy	91.7	95.8	88.5	93.3

Tulokset - 2

- Sekaannusmatriisi naiivi Bayes –luokittelijan tuloksista

Reference \ Predicted	Predicted			
	Pine	Spruce	Birch	Other
Pine	26	2	0	0
Spruce	0	23	1	0
Birch	0	1	23	2
Other	0	1	1	13

- Sekaannusmatriisi satunnaismetsän tuloksista

Reference \ Predicted	Predicted			
	Pine	Spruce	Birch	Other
Pine	26	2	0	0
Spruce	0	23	1	0
Birch	1	0	24	1
Other	0	1	0	14

Tulokset - 3

- Sekaannusmatriisi tukivektorikoneen tuloksista

Reference \ Predicted				
	Pine	Spruce	Birch	Other
Pine	25	3	0	0
Spruce	0	23	1	0
Birch	0	4	22	0
Other	0	0	0	15

- Poistovalinnan mukaan parhaiten luokittelevat ominaisuudet
 - 1550 nm: CD, D1, D2, I20, I50
 - 905 nm: I_{max}, I_{min}, I20, I40, I70, I80, I90

Tulokset - 4

- Sekaannusmatriisi tukivektorikoneen tuloksista, kun käytettiin parhaita ominaisuuksia

Reference \ Predicted				
	Pine	Spruce	Birch	Other
Pine	27	1	0	0
Spruce	0	23	1	0
Birch	0	2	24	0
Other	0	1	0	14

Yhteenveto

- Kaikilla luokittelumenetelmillä oli korkeat tarkkuudet ja hyvät tulokset
- Havupuut tunnistettiin parhaiten, koivut huonoiten
- Enemmistö parhaiten luokittelevista ominaisuuksista oli 905 nm:n datasta
 - Eniten intensiteettipiirteitä, hieman geometrisiä piirteitä
- Jatkotutkimukset:
 - Enemmän puita, useampia puulajeja
 - Erilaisia ristiinvalidointimenetelmiä (esim. k-kertainen)
 - Ohjaamaton oppiminen

Lähteet

- Yu, X., Hyypä, J., Litkey, P., Kaartinen, H., Vastaranta, M., Holopainen, M. Single-sensor solution to tree species classification using multispectral airborne laser scanning. *Remote Sensing* 2017, 9(2):108; doi:10.3390/rs9020108
- A. Axelsson, E. Lindberg, and H. Olsson. Exploring multispectral ALS data for tree species classification. *Remote Sensing* 2018, 10(2):183; <https://doi.org/10.3390/rs10020183>.
- J. Hyypä, X. Yu, H. Kaartinen, A. Kukko, A. Jaakkola, X. Liang, Y. Wang, M. Holopainen, M. Vastaranta, and H. Hyypä. Forest inventory using laser scanning. In J. Shan and C.K. Toth, editors, *Topographic Laser Ranging and Scanning: Principles and Processing*, Second Edition, pages 379–412. CRC Press, Boca Raton, 2017
- M.B. Campos, P. Litkey, Y. Wang, Y. Chen, H. Hyyti, J. Hyypä, and E. Puttonen. A long-term terrestrial laser scanning measurement station to continuously monitor structural and phenological dynamics of boreal forest canopy. *Frontiers in Plant Science*, 11:2132, 2021. <https://doi.org/10.3389/fpls.2020.606752>.