

Deep learning for tree line ecotone mapping from remote sensing data

Praha 2021

Vedoucí práce:
Ing. Markéta Potůčková Ph.D.

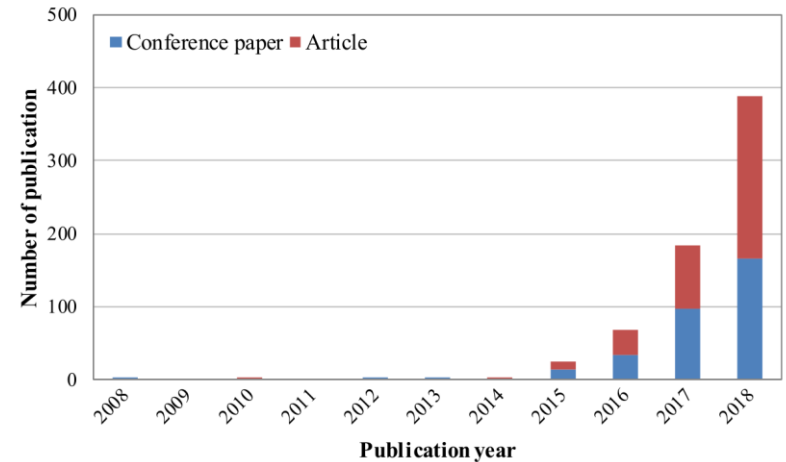
Autor práce:
Jakub Dvořák

Oponent práce:
Prof. Sébastien Lefèvre

Cíle práce

Shrnout principy fungování neuronových sítí a jejich aplikace v dálkovém průzkumu

Porovnání tradičních klasifikačních metod a hlubokých neuronových sítí pro mapování vegetace na horní hranici lesa



Zdroj:

MA, L., LIU, Y., ZHANG, X., YE, Y., YIN, G., JOHNSON, B. A. (2019): Deep learning in remote sensing applications: A meta-analysis and review. ISPRS Journal of Photogrammetry and Remote Sensing

Hluboké učení a DPZ

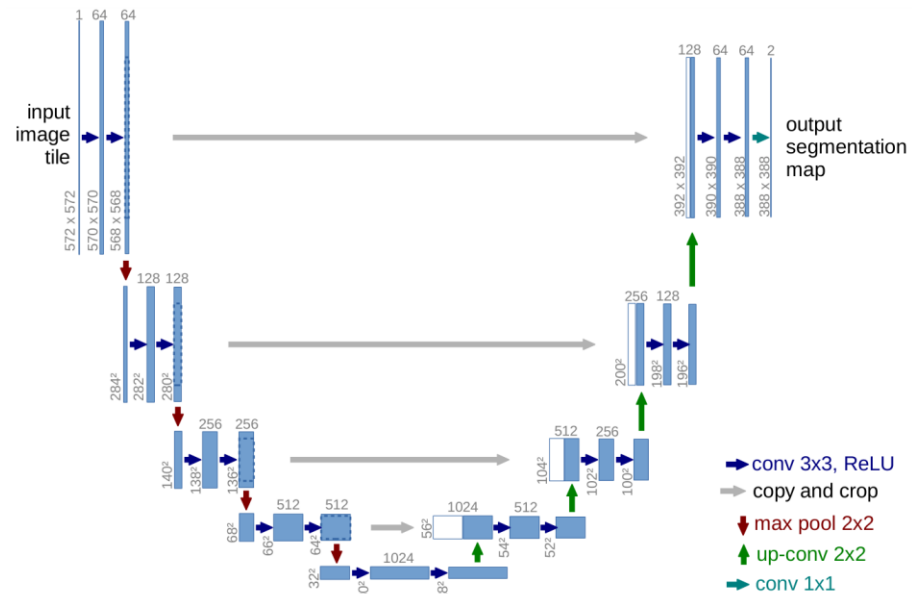
Především řízená klasifikace

Podrobně popsané principy neuronových sítí:

Multilayer perceptron

Konvoluční neuronové sítě

Plně konvoluční neuronové sítě, „encoder-decoder“ sítě




Data a popis experimentu

Detekce smrku a kosodřeviny v části východní tundry KRNAP

VHR letecké snímky – RGB, NIR

nDSM vygenerovaný z LiDARových dat
využit k poloautomatické anotaci



Tři experimenty, lišící se množstvím trénovacích dat:

- 1 % ruční anotace
- 33 %, 67 % poloautomatická anotace

V rámci čtvrtého experimentu byly neuronové sítě natrénovány s použitím pouze jednoho typu vstupních dat (RGB/CIR)



Porovnání klasifikačních metod

Běžně používané:

- Maximum Likelihood
- Random Forest
- Support Vector Machine

„Encoder-decoder“ síť:

- hojně využívaný U-Net
- navrhovaná adaptace KrakonosNet

Všechny klasifikace implementovány jako skripty v Pythonu (scikit-learn, PyTorch)

KrakonosNet:

batch normalisation vrstvy





dropout

snížení počtu *feature maps*

alternativní aktivační funkce (PReLU)

Výsledky

modely trénované na omezených vstupních datech (RGB/CIR) dosáhly srovnatelných výsledků jako ostatní neuronové sítě



	Background			Pinus mugo			Picea abies			OA	Mean F ₁
	UA	PA	F ₁	UA	PA	F ₁	UA	PA	F ₁		
MLC	94.07	43.35	58.41	41.54	25.69	31.74	4.59	52.85	8.45	37.61	32.87
SVM	92.26	60.53	73.10	56.10	60.94	58.42	15.38	81.70	25.70	61.61	52.47
RF	93.88	51.9	66.85	53.20	58.46	55.71	10.00	66.97	17.40	54.63	46.65
U-Net	83.60	80.20	81.87	66.21	58.90	62.34	31.73	74.56	44.52	73.28	62.91
KrakonosNet	83.44	81.22	82.32	66.45	58.84	62.41	35.13	76.46	48.14	74.00	64.29

Table 4: Results for the 67/33% data split



Diskuse a závěr

Potvrzení výhod hlubokého učení oproti běžným metodám klasifikace

„Encoder-decoder“ sítě – nejlepší výsledky pro nejvíce trénovacích dat

Běžné metody klasifikace – nejlepší výsledky pro ručně anotovaná data

V rámci práce dohromady vzniklo 8 skriptů v jazyce Python

U-Net a KrakonosNet byly dále využity v projektech pro stanovení horní hranice lesa v Krkonošském NP a CHKO Jeseníky