



Využití modulu deep learning v rámci softwaru ArcGIS Pro pro detekci vojenské techniky

Ondřej Mucha

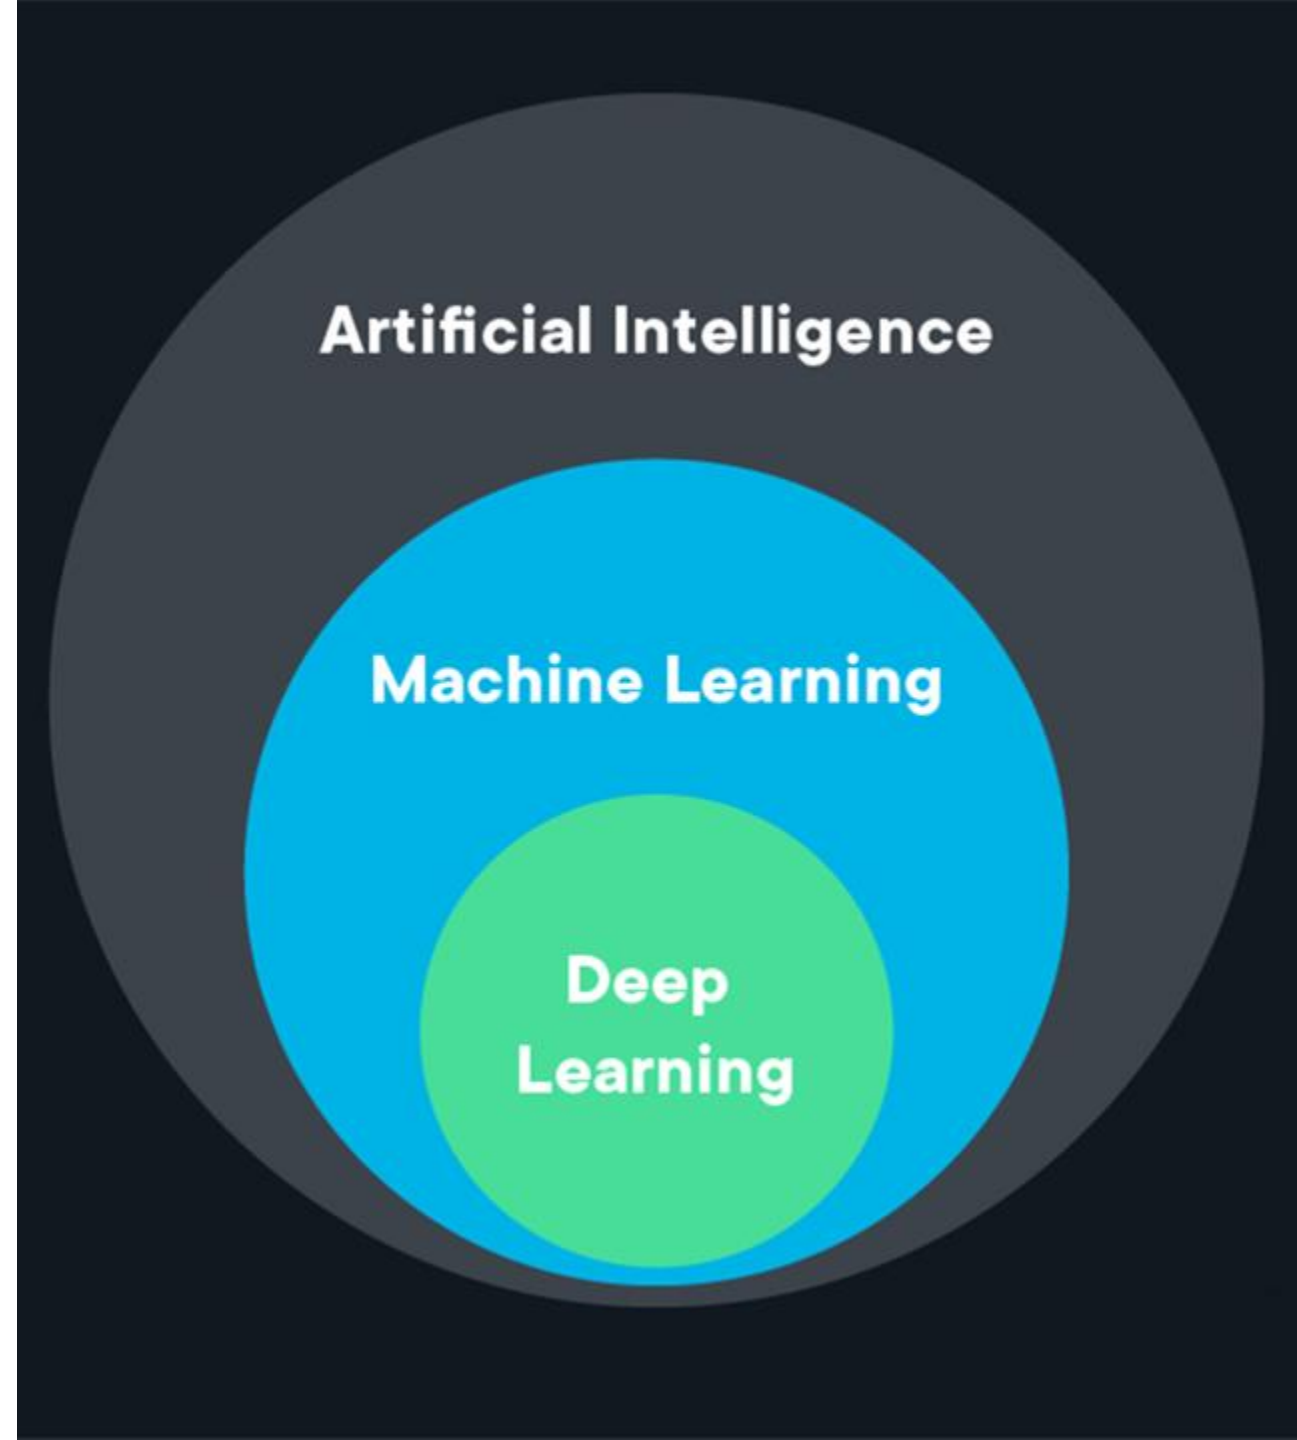
Konference GIS Esri v ČR 8.-9. 11. 2023

Obsah

- benefity deep learningu
- cíle práce
- požadavky
- definice vojenské techniky
- vstupní data
- popis kroků
- výsledky
- závěry

Benefity deep learningu v DPZ

- podmnožina strojového učení
- založena na trénování modelů v podobě neuronových sítí
- umožňuje detekovat prakticky jakýkoliv druh objektu nebo povrchu



Benefits deep learning v DPZ

- automatizace operací, které bylo nutné provádět manuálně
- urychlení zavedených postupů
- uplatnění napříč obory



Cíle práce

- prozkoumání různých druhů detekčních modelů
- tvorba modelu schopného detekce vojenské techniky – zimní, letní
- detekce by měla probíhat na podkladu satelitních dat s vysokým prostorovým rozlišením



Požadavky

- ArcGIS Pro
- licence Image Analyst
- rozšiřující pythonový balíček deep-learning-frameworks
- oddělovač nastavený na desetinnou tečku
- **paměťová kapacita GPU alespoň 8 GB**

Definice vojenské techniky

- vzhledem k prostorovému rozlišení dostupných dat by bylo složité rozeznat jednotlivé druhy techniky – tanky, nákladáky
- existuje sice studie, která techniku rozeznávala – ale z radarových dat
- proto byla zvolena práce s jednou kategorií, která by měla zahrnovat všechny druhy techniky



Definice vojenské techniky

- vzhledem k prostorovému rozlišení dostupných dat by bylo složité rozeznat jednotlivé druhy techniky – tanky, nákladáky
- existuje sice studie, která techniku rozeznávala – ale z radarových dat
- proto byla zvolena práce s jednou kategorií, která by měla zahrnovat všechny druhy techniky



Použitá data

- sledovaná technika měla v průměru rozměry 3x8 metrů
- snaha nalézt data s co nejvyšším prostorovým rozlišením
- původní plán – použít data ze satelitů PlanetScope, maximální prostorové rozlišení 3 m -> nedostatečné
- přes vedoucí stáže nakonec zajištěn přístup ke snímkům SkySat -> rozlišení 0,5 m -> dostačující

PlanetScope




3 m/pixel

VS

SkySat



0,5 m/pixel



Daily Scenes

Valuyki, Russia 30998

Filter | Dates | Save search

Back

8. října 2022 12:33 UTC – SSC15

2022 7:41 UTC – SSC2

Unidentified assets

	7:41:20 UTC SkySat Scene 20221008_074120_ssc2d3_0011
Purchase Access	0%
	7:41:20 UTC SkySat Scene 20221008_074120_ssc2d3_0010
Purchase Access	0%

Area of Interest

2.183 km²

available base


Soloti

Popis kroků deep learningu

- tvorba trénovacích ploch
- export dat pro deep learning
- trénování modelu deep learning
- detekce objektů pomocí deep learningu

Tvorba trénovacích ploch

- manuální označování jednotlivých kusů techniky
- obecně platí, čím více trénovacích ploch vytvoříme, tím lepší model můžeme získat
- pro zimní model bylo vytvořeno 936 trénovacích ploch, pro letní model 490



Export dat pro deep learning

- úprava trénovacích ploch do formátu vhodného pro trénování modelů
- výstupem je složka s tzv. image chipy a složka s metadatovými soubory
- volba metadat ovlivňuje možnost následného výběru detektoru

Trénování modelu

- trénování modelů následně schopných detekce
- na základě metadat image chipů volba detektoru
- batch size – důvod požadavků na GPU
- nejnáročnější část deep learningu

Geoprocessing ⌵ 🔍 ✕

⬅️ Train Deep Learning Model ➕

Parameters Environments ?

Input Training Data ✕ 📁
 📁

Output Model 📁

Max Epochs

▼ Model Parameters

Model Type ⌵

Batch Size

Model Arguments

Name	Value
✕ chip_size	256
monitor	valid_loss
<input type="text"/>	<input type="text"/>

▼ Advanced

Learning Rate

Backbone Model ⌵

Pre-trained Model 📁

Validation %

Stop when model stops improving


Freeze Model

Přehled detektorů pro detekci objektů

- ArcGIS Pro nabízí celkem 9 detektorů vhodných pro detekci objektů
- dělení na jednostupňové a dvoustupňové
 - jednostupňové – např. SSD, YOLOv3
 - dvoustupňové – např. Faster R-CNN, MASK R-CNN
- v předtrénovaných modelech dostupných z ESRI knihovny nejčastěji využít detektor **MASK R-CNN**
- v článcích věnujících se detekci vozidel jsou to nejčastěji YOLO a Faster R-CNN

MASK R-CNN

- rozšíření detektoru Faster R-CNN
- zatímco Faster R-CNN je schopen detekovat objekty a určit jejich bounding boxy, MASK R-CNN jde ještě dále tím, že umožňuje segmentovat objekty na pixelové úrovni



Srovnání detekce MASK R-CNN (červeně) a Faster R-CNN (žlutě)

Detekce objektů

- na základě natrénovaného modelu na vybraném snímku
- nastavení různých parametrů ovlivňujících detekci
- výstupem je vrstva s detekovanými objekty
- lze využít i jiné předtrénované modely

← Detect Objects Using Deep Learning +

Parameters Environments ?

Input Raster
[]

Output Detected Objects
[]

Model Definition
[]

Arguments

Name	Value
padding	[]
batch_size	[]
✗ threshold	[]
return_bboxes	[]
test_time_augmentati	[]
merge_policy	[]
tile_size	[]
[]	[]

Non Maximum Suppression


Confidence Score Field
[Confidence]

Class Value Field
[Class]

Max Overlap Ratio [0]

Očištění výsledků

- minimální hranice rozpoznatelnosti vozidla (threshold)
- odstranění části falešných detekcí dle minimální velikosti techniky (20 m²)




Výsledky – metodika

- výběr testovací části snímku
 - neprovádělo se na něm trénování modelu
 - dobře identifikovatelná technika
- 2 ukazatele hodnocení
 - udávaná přesnost modelu při tvorbě př. `{'average_precision_score': {'Zimni_vozidla': 0.3225196646526456}}`
 - skutečná přesnost detekce – procentuální vyjádření

$$\frac{(\text{počet detekovaných vozidel} - \text{falešné detekce})}{\text{skutečný počet vozidel}} * 100$$

Výsledky zimní model

- detektor MASK R-CNN
 - udávaná přesnost modelu: 48,9 %
 - skutečná přesnost detekce: 44,7 %



Výsledky zimní model

- detektor MASK R-CNN
 - udávaná přesnost modelu: 48,9 %
 - skutečná přesnost detekce: 44,7 %
- detektor Faster R-CNN
 - udávaná přesnost modelu: 34,7 %
 - skutečná přesnost detekce: 23,8 %



Výsledky letní model

- MASK R-CNN Medvedivka
 - udávaná přesnost modelu: 43,7 %
 - skutečná přesnost detekce: 36,8 %



Výsledky letní model

- MASK R-CNN Medvedivka
 - udávaná přesnost modelu: 43,7 %
 - skutečná přesnost detekce: 36,8 %
- MASK R-CNN Soloti
 - udávaná přesnost modelu: 43,7 %
 - skutečná přesnost detekce: 42,3 %



Závěry

- potvrzení možného využití pro detekci vojenské techniky
- využití spíše jako upozornění pro analytiky, že by se v dané oblasti technika mohla vyskytovat
- pro lepší výsledky podrobnější data a více snímků
- velká časová náročnost – operace trvají hodiny
- závislost na dostupném hardwaru – hlavně GPU

DĚKUJI ZA POZORNOST