



Vilniaus universitetas
Duomenų mokslo ir skaitmeninių technologijų institutas
Kognityvinių skaičiavimų grupė



Povilas Gudžius
Informatikos O9P doktorantas
Doktorantūros pradžios ir pabaigos metai: 2017–2021

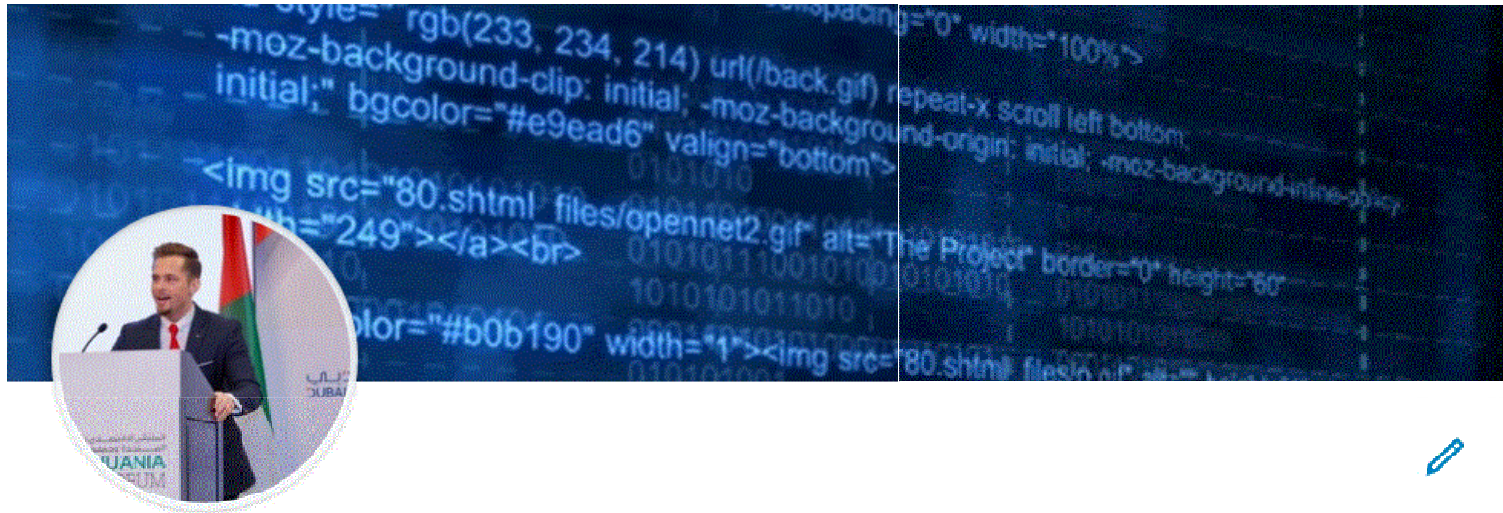
Disertacijos pavadinimas : *“Convolutional neural network architecture for object recognition problems in optical satellite imagery”*

Darbo vadovas: Prof. Dr. Olga Kurasova
Konsultantas: Doc. Dr. Ernestas Filatovas

Turinys

- 1. Tyrimo objektas, tikslai ir planuojami rezultatai**
- 2. Tyrimo problema: GSD, Finansai, Satelitiniai vaizdai**
- 3. 2017 – 2018 ataskaitinių metų darbo planas**
- 4. 2017 – 2018 ataskaita**
- 5. Gautų pirminių mokslinių rezultatų pristatymas**
- 6. Kitų metų darbo planas**

Apie mane



Povilas Gudžius

Head of Financial Technology Sales - UAE at Bloomberg LP

United Arab Emirates

Add profile section ▼

More...



Bloomberg LP



CFA Institute



See contact info



See connections (500+)

"Future comes one day at a time." -- Dean Acheson

Tyrimų objektas, tikslas ir uždaviniai

Tyrimo objektas: *Palydovinių vaizdų atpažinimas.*

Tyrimo tikslas: *Pasiūlyti efektyvią konvoliucinių neuroninių tinklų architektūrą, skirtą tiksliai atpažinti objektus, esančius vaizduose iš optinių palydovų.*

Tyrimu objektas, tikslas ir uždaviniai


Tyrimo uždaviniai:

- *Atlikti skirtingų metodų analizę naudojamų palydoviniams vaizdams atpažinti;*
- *Nustatyti (identifikuoti) mokslines problemas, kylančias uždaviniuose, susijusiuose su palydovinių vaizdų atpažinimu;*
- *Dirbtiniu neuroniniu tinklu pagrįsto algoritmo sukūrimas palydoviniams vaizdams atpažinti;*
- *Sukurto algoritmo tyrimas sprendžiant keletą testinių uždavinių, įskaitant ir praktinį panaudojimą finansų rinkoje;*
- *Gautų rezultatų analizė*



Planuojami rezultatai:

- *Sukurta unikali konvoliucinių neuroninių tinklų architektūra, pritaikyta efektyviam objektų atpažinimui dideles rezoliucijos optinių palydovų gautuose vaizduose.*

Tyrimo problema: Geospatial data (GSD) revolution




Tyrimo problema: pritaikymas finansų rinkai




Tyrimų problema: Satelitinių vaizdų peripetijos

Satelitinių vaizdų specifiška ir iššūkiai:

- Rezoliucija: 5m – 0.3m per pixel
- Perspective distortion
- Scale and size variability
- Atmosferos ir šviesos pokyčiai (haze, fog)
- Debesys ir triukšmas
- Hyperspectral – images: 12 Band (RGB, P-band, M-Band, A-band)



Studijų planas (2017–2021)



2017–2018 darbo planas

• Studijų planas:

- Išlaikyti egzaminą „*Skaitinis intelektas investuojant į vertybinius popierius*“. Vertinimo komisija: doc. dr. A. Raudys
- Išlaikyti egzaminą „Atpažinimo teorija“. Vertinimo komisija: doc. dr. Povilas Treigys, dr. G. Korvel, doc. dr. G. Tamulevičius


• Rezultatų pristatymo planas:

- Dalyvavimas mokslinėje konferencijoje „9th International Workshop on Data Analysis Methods for Software Systems“, vyksiančioje Lietuvoje, Druskininkuose, 2017 m. gruodžio mėnesį.
- Dalyvavimas mokslinėje konferencijoje „International Conference on Control and Computer Vision ICCCV 2018“, vyksiančioje 2018 m. birželio 15-18 d. Singapūre.

• Mokslinių tyrimų planas:

- Atlikti skirtingų metodų analizę naudojamų palydoviniams vaizdams atpažinti;
- Nustatyti (identifikuoti) mokslines problemas, kylančias uždaviniuose, susijusiuose su palydovinių vaizdų atpažinimu;
- Parinkti tyrimo metodiką iškeltam uždaviniui spręsti;
- Teorinio ir empirinio tyrimo suplanavimas pagal pasirinktą metodiką.

2017–2018 detalus darbo planas



Ataskaita už 2017–2018 mokslo metus

1) 2017–2018 m. išlaikyti egzaminai:

- Išlaikytas egzaminas: „*Skaitinis intelektas investuojant į vertybinius popierius*“. Vertinimo komisija: doc. dr. A. Raudys, doc. dr. O. Kurasova, dr. S. Blažiūnas: **įvertinimas 10 (puikiai)**.
- Išlaikytas egzaminas: „*Atpažinimo teorija*“. Vertinimo komisija: doc. dr. Povilas Treigys, dr. G. Korvel, doc. dr. G. Tamulevičius: **įvertinimas 8 (gerai)**.


2) 2017–2018 m. rezultatų pristatymai mokslinėse konferencijose:

- Dalyvavimas mokslinėje konferencijoje „**9th International Workshop on Data Analysis Methods for Software Systems**“, vykusioje Lietuvoje, Druskininkuose, 2017 m. lapkričio 30 - gruodžio 2 d., stendinis pranešimas: “Object detection and classification in satellite imagery”
- Dalyvavimas mokslinėje konferencijoje „**International Conference on Control and Computer Vision ICCCV 2018**“, vykusioje 2018 m. birželio 15-18 d. Singapūre, skaitytas pranešimas: “Convolutional neural networks in object detection and classification problems in satellite imagery”

Ataskaita už 2017–2018 mokslo metus

3) Papildomas įgūdžių įgijimas:

- New York Data Science Academy program, "Python for Data Science", Rugpjūčio 17, 2018




Ataskaita už 2017–2018 mokslo metus


4) 2017–2018 m. m. gauti moksliniai rezultatai:

- Atlikta skirtingų metodų, naudojamų palydoviniams vaizdams atpažinti, analizė;
- Nustatytos mokslinės problemos, kylančios uždaviniuose, susijusiuose su palydovinių vaizdų atpažinimu;
- Sukurti kanalai įsigyti sunkiai prieinamiems optiniams palydoviniams vaizdams, skirtiems algoritmo apmokymui ir testavimui;
- Sukurtas dirbtiniu neuroniniu tinklu pagrįstas algoritmas palydoviniams vaizdams atpažinti;
- Sukurta didelio galingumo Google Cloud Platform (GCP) debesyje esanti didelės apimties skaičiavimui, apmokymui, validavimui ir rezultatų vizualizavimui skirta sistemų architektūra
- Atlikti pirminiai tyrimai

Pirminiai moksliniai tyrimai: sistemų architektūra




Pirminiai moksliniai tyrimai: CNN U-net



Pirminiai moksliniai tyrimai: CNN U-net

“Our fully convolutional model is based on the U-Net architectures [B14], where low-level feature maps are combined with higher-level ones, enables precise localization (practical use – cell location). This type of network architecture was especially designed to effectively solve image segmentation problems. Due to this reason this architecture has been chosen as a default architecture for our research problem.”




Pirminiai mokslinių tyrimų rezultatai: 1 iš 4

Finding number 1: Winning U-net

- The highest Jaccard metric validation accuracy reached was 63.90% using 50 number of epochs for the backpropagation and the training set. Winning U-net parameters: Batch_size: 128, pixel frame: 160x160, 2% polygon qualification to the training set, ReLU as an activation function at each of the Conv layer, 50 epochs of training:

	Epochs	Training	Validation	Batch Size	"ISZ" mozaic size	Part_proc (proc c	Activation function	Pixel threshold	Jaccard Accuracy
U-net Experiment 17	50	25,000 objects	0.2(5)	128	160x160 pixel	0.02	ReLU	100	63.90%

	Epochs	Training	Validation	Batch Size	"ISZ" mozaic size	Part_proc (proc c	Activation function	Pixel threshold	Jaccard Accuracy	Experiment 12
U-net Experiment 8	20	25,000 objects	0.25	256	160x160 pixel	0.02	ReLU	100	ResourceExhaustedError	
U-net Experiment 9	160	25,000 objects	0.25	64	160x160 pixel	0.02	ReLU	100	62.18%	
U-net Experiment 10	20	25,000 objects	0.25	64	80x80 pixel	0.02	ReLU	100	50.02% (4 times faster)	
U-net Experiment 11	20	25,000 objects	0.25	64	80x80 pixel	0.02	Leaky_ReLU	100	Leaky_config	
U-net Experiment 12	20	25,000 objects	0.25	256	80x80 pixel	0.02	ReLU	100	47.99%	
U-net Experiment 13	50	25,000 objects	0.25	512	80x80 pixel	0.02	ReLU	100	51.49%	
U-net Experiment 14	50	25,000 objects	0.25	32	200x200 pixel	0.02	ReLU	100	MEMORY ERROR	
U-net Experiment 15	50	25,000 objects	0.25	512	160x160 pixel	0.02	ReLU	100	ResourceExhaustedError	
U-net Experiment 16	50	25,000 objects	0.25	128	160x160 pixel	0.01	ReLU	100	MEMORY ERROR	

Pirminiai mokslinių tyrimų rezultatai: 2 iš 4

Finding number 2: Real-life accuracy



- Jaccard metric is not the most representative metric given our research problem. After manual object count examination, we have established that 63.90% Jaccard metric accuracy is equivalent to an impressive 94.09% of object count measure:

SpaceNet 30cm high-res optical satellite imagery (RGB)	1.5km2
Number of manually marked car polygons AOI	288
Number of objects that U-net model predicted accurately	271
Number of objects were detected	17
Number of objects detected yet not marked in the training set	28
Model accuracy	94.09%
Jaccard Index of best performed U-net	63.90%

Pirminiai mokslinių tyrimų rezultatai: 3 iš 4

Finding number 3: Above human performance


- U-net architecture in some cases provided “better-than human accuracy” since it has detected 28 objects within the given manual test sample that were not discovered by human annotator.



Pirminiai mokslinių tyrimų rezultatai: 4 iš 4

Finding number 4: Epochs

- Efficient networks are able to train faster and an optimal number of two-way backpropagations is to be conducted between 25-50 times for network to be trained if considering computational restrains.



Kitų metų darbo planas (2018 – 2019)

- **Studijų planas:**

- Išlaikyti egzaminą „Duomenų analizės strategijos ir sprendimų priėmimas“. Vertinimo komisija: prof. habil. dr. G. Dzemyda, prof. dr. O. Kurasova, dr. J. Bernatavičienė

- **Rezultatų pristatymo planas:**

- Dalyvavimas tarptautinėje mokslinėje konferencijoje „**Artificial Intelligence and Data Science in Capital Markets 2019**“ vyksiančioje Londone, UK arba kitoje tarptautinėje konferencijoje vyksiančioje Lietuvoje ar užsienyje
- Dalyvavimas tarptautinėje mokslinėje konferencijoje „**14th Innovative Applications of Artificial Intelligence Conference**“ New Orleans, Louisiana USA arba kitoje užsienyje vyksiančioje tarptautinėje konferencijoje

- **Mokslinių publikacijų planas:**

- Įteikti mokslinį straipsnį į žurnalą, turintį cituojamumo rodiklį *Clarivate Analytics Web of Science* duomenų bazėje, „***U-net architecture for small objects detection and classification in optical satellite imagery***“

Praktinio panaudojimo pavyzdžiai finansų rinkoje

Ultimate objective is to develop an accurate, optimal and computationally efficient Machine Learning image recognition model with custom features and applied to financial markets. Examples include:

- “Chipotle Stock Price” prediction prior to earnings release. ML model counts quantity, type, color of cars in the car park predicting revenue
- “China Construction Index” prediction. ML model estimates growth based on shadows cast by buildings (Orbital insight)
- “Crop Yield Prediction”. ML model consumes multi-wave length (infrared, Rband) images and estimates Crop harvest (Descartes)
- “Global Oil Reserves Calculation”. ML model captures the height of reserve containers and produces global oil reserves figure (RS Metrics)

References


- [1] I. H. Witten Eibe Frank Mark A. Hall Christopher J. Pa, Data Mining: Practical Machine Learning Tools and Techniques, Edition (2016), 509-529.
- [2] R. Trippi, E. Turban, Neural Networks in Finance and Investing: Using Artificial Intelligence to Improve Real World Performance, McGraw-Hill, New York
- [3] Wolken, John D. "“New” data sources for research on small business finance." *Journal of Banking & finance* 22.6: 1067-1076.
- [4] Zeng, Yongnian, et al. "Fusion of satellite images in urban area: Assessing the quality of resulting images." *Geoinformatics, 2010 18th International Conference on*. IEEE, 2010.
- [5] Merchant, Nathan D., et al. "Assessing sound exposure from shipping in coastal waters using a single hydrophone and Automatic Identification System (AIS) data." *Marine pollution bulletin* 64.7 (2012): 1320-1329.
- [6] El-Beltagy, Mohammed A., Prasanth B. Nair, and Andy J. Keane. "Metamodeling techniques for evolutionary optimization of computationally expensive problems: Promises and limitations." *Proceedings of the 1st Annual Conference on Genetic and Evolutionary Computation-Volume 1*. Morgan Kaufmann Publishers Inc., 1999.
- [7] Lary, David J., et al. "Machine learning in geosciences and remote sensing." *Geoscience Frontiers* 7.1 (2016): 3-10.

APPENDIX: Machine learning techniques research for object detection in satellite imagery

- Support Vector Machines (SVM)
- Self-organizing map (SOM)
- Assemble methods such as Random Forests (RF)
- Case-based reasoning (CBR)
- Neuro-Fuzzy (NF)
- Genetic Algorithm(GA)
- Neural Networks (NN)

CNN is most effective object detection and recognition (up to 95.05% accuracy).

APPENDIX: Convolutional Neural Net – hyper-parameters




Feature Extraction phase: Conv.block:

- 1) Convolution
- 2) Activation function
- 3) Pooling

APPENDIX: Convolutional Neural Net – hyper-parameters

CNN architektūros hiper-parametri, kurie bus testuojami optimizacijai:

- Window stride
- Pooling window size
- Number of neurons
- Number of features
- Size of those features
- Padding (zero padding) and the size of it
- Activation functions
- CNN architecture itself (Capsules, ResNet)





APPENDIX: Convolutional Neural Net - hyper-parameters

CNN architektūros hiper-parametri, kurie bus testuojami optimizacijai:



- Window stride

CONVOLUTIONS



APPENDIX: Convolutional Neural Net - hyper-parameters – RELU


- Activation functions

Name	Plot	Equation	Derivative
Identity		$f(x) = x$	$f'(x) = 1$
Binary step		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x \neq 0 \\ ? & \text{for } x = 0 \end{cases}$
Logistic (a.k.a Soft step)		$f(x) = \frac{1}{1 + e^{-x}}$	$f'(x) = f(x)(1 - f(x))$
TanH		$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$	$f'(x) = 1 - f(x)^2$
ArcTan		$f(x) = \tan^{-1}(x)$	$f'(x) = \frac{1}{x^2 + 1}$
Rectified Linear Unit (ReLU)		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
Parameteric Rectified Linear Unit (PReLU) [2]		$f(x) = \begin{cases} \alpha x & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
Exponential Linear Unit (ELU) [3]		$f(x) = \begin{cases} \alpha(e^x - 1) & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} f(x) + \alpha & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
SoftPlus		$f(x) = \log_e(1 + e^x)$	$f'(x) = \frac{1}{1 + e^{-x}}$

APPENDIX: Convolutional Neural Net – Architecture

CNN architektūros hiper-parametriai, kurie bus testuojami optimizacijai:

- CNN architecture itself (Capsules, ResNet, Inception, ResNet)



APPENDIX: Architektūra + padaryti darbai

