



**Vilniaus
universitetas**

Ataskaitinė informatikos ir informatikos inžinerijos kryptių doktorantų ataskaitinės konferencija 2024-10-03

Kasparas Karlauskas, Informatikos inžinerija 2-as kursas

Preliminari tema:

Trimačių taškų debesų analizė ir objektų atpažinimas
(Three dimensional point cloud analysis and object detection)

Vadovas: prof. dr. Povilas Treigys

Studijų pradžios ir pabaigos metai: 2023–2027

Studijų metai: I (2023 / 2024)

Ataskaitinis laikotarpis: I studijų metų pavasario semestras

Studijų plano vykdymo suvestinė

Vilniaus
universitetas

Studijų metai	Dalyvavimas konferencijose				Publikacijos					
	Tarptautinėse		Nacionalinėse		Su citavimo rodikliu			Be citavimo rodiklio		
	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	Būklė	Planas	Įvykdyta	Būklė
I (2023/2024)			1	1				1	0	
II (2024/2025)			1	0				1 + 1 (skola iš I metų)	0	
III (2025/2026)	1				1					
IV (2026/2027)	1				1					
Iš viso:	2	0	2	0	2			2		

Ataskaitinio pusmečio darbų planas ir jų vykdymo suvestinė

Vilniaus
universitetas

Egzaminai 2023/2024 (II pusmetis)		
Planas	vykdyta	Būklė
Informatikos ir informatikos inžinerijos tyrimo metodai ir metodika (2024 II ketvirtis)	Informatikos ir informatikos inžinerijos tyrimo metodai ir metodika, 2024-06-25	Išlaikytas

Dalyvavimas konferencijose 2023/2024 (II pusmetis)		
Planas	vykdyta	Konferencijos tipas
33rd European Conference on Operational Research, 2024-07-02, Copenhagen, Denmark	Povilas Treigys & Kasparas Karlauskas , Geometry and deep learning-based methods comparison for segmentation of trees in aerial laser scan point clouds // Euro 2024: 33rd European conference on operational research, 2024-07-02, Copenhagen, Denmark	Tarptautinė konferencija

Visų mokslinių tyrimų ir disertacijos rengimo etapai

Vilniaus
universitetas

Darbo pavadinimas		Atlikimo terminai		Pastabos
		Nuo	Iki	
1.	Mokslinių tyrimų disertacijos tema apžvalga ir analizė (Lietuvoje ir užsienyje):			
1.1.	Disertacijos tyrimo objekto konkretizavimas.	2023 m. IV ketvirtis	2024 m. I ketvirtis	Individualių medžių segmentavimas iš oro skanuotuose miškų trimačiuose taškų debesyse, naudojantis giliojo mokymosi metodais

Visų mokslinių tyrimų ir disertacijos rengimo etapai

Vilniaus
universitetas

1.2.	3D taškų debesų analizės metodų apžvalga. a) Giliojo mokymosi metodai b) Geometriniai metodai	2023 m. IV ketvirtis	2024 m. III ketvirtis	a) Apžvalga atlikta, savo eksperimentuose išmėgintas vienas segmentavimo neuroninis tinklas b) Aptikti perspektyvūs atviro kodo klasikiniai individualių medžių segmentavimo algoritmai, taip pat du straipsniai be kodo, bet detaliu algoritmo įgyvendinimo aprašymu
1.3.	Atliktos apžvalgos apibendrinimas ir pateikimas disertacijos analitinės dalies aprašyme.	2023 m. IV ketvirtis	2024 m. III ketvirtis	Algoritmų bei duomenų rinkinių apžvalga pateikta mokslinės ataskaitos skyriuje "2. Related Work"

Visų mokslinių tyrimų ir disertacijos rengimo etapai

Vilniaus
universitetas

2.	Mokslinio tyrimo vykdymas:			
2.1.	Tyrimo metodikos sudarymas:			
2.1.1.	Pagrindžiamas temos aktualumas, nurodoma darbo problema ir suformuluojamas tikslas.	2024 m. IV ketvirtis	2024 m. IV ketvirtis	
2.1.2.	Atliekamas uždavinių pasirinkimas bei sprendžiamos problemos formulavimas.	2024 m. IV ketvirtis	2024 m. IV ketvirtis	
2.1.3.	Taikomos metodologijos ar tyrimo metodo pateikimas ir aprašymas	2024 m. IV ketvirtis	2024 m. IV ketvirtis	
2.2.	Teorinis tyrimas:			
2.2.1.	Mokslinės ir kitos informacijos analizė ir sisteminimas.	2024 m. IV ketvirtis	2025 m. III ketvirtis	
2.2.2.	Objektų detekcijos 3D taškų debesyse metodai (geometriniai, giliojo mokymosi).	2024 m. IV ketvirtis	2025 m. III ketvirtis	
2.2.3.	3D taškų debesyse aptiktų objektų parametrų nustatymas.	2024 m. IV ketvirtis	2025 m. III ketvirtis	

Visų mokslinių tyrimų ir disertacijos rengimo etapai

Vilniaus
universitetas

2.2.	Teorinis tyrimas:			
2.2.1.	Mokslinės ir kitos informacijos analizė ir sisteminimas.	2024 m. IV ketvirtis	2025 m. III ketvirtis	
2.2.2.	Objektų detekcijos 3D taškų debesyse metodai (geometriniai, giliojo mokymosi).	2024 m. IV ketvirtis	2025 m. III ketvirtis	
2.2.3.	3D taškų debesyse aptiktų objektų parametrų nustatymas.	2024 m. IV ketvirtis	2025 m. III ketvirtis	
2.3.	Empirinis tyrimas:			
2.3.1.	Eksperimentinės dalies aprašas.	2025 m. I ketvirtis	2026 m. II ketvirtis	
2.3.2.	Egzistuojančio metodo realizavimas kuriamo metodo palyginimui.	2025 m. I ketvirtis	2026 m. II ketvirtis	
2.3.3.	Metodų modifikacijos sukūrimas.	2025 m. I ketvirtis	2026 m. II ketvirtis	
2.3.4.	Sukurtų modifikacijų eksperimentinis tyrimas ir modifikacijų palyginimas su publikuotais egzistuojančiais metodais.	2025 m. I ketvirtis	2026 m. II ketvirtis	

Visų mokslinių tyrimų ir disertacijos rengimo etapai

Vilniaus
universitetas

2.4.	Gautų duomenų analizė, apibendrinimas, išvadų parengimas:			
2.4.1.	Teorinio tyrimo apibendrinimas.	2025 m. III ketvirtis	2026 m. II ketvirtis	
2.4.2.	Empirinio tyrimo apibendrinimas.	2025 m. III ketvirtis	2026 m. II ketvirtis	
2.4.3.	Rezultatų apibendrinimas, išvadų parengimas.	2025 m. III ketvirtis	2026 m. II ketvirtis	

Visų mokslinių tyrimų ir disertacijos rengimo etapai

Vilniaus
universitetas

3.	Atskirų daktaro disertacijos dalių (tyrimo metodikos, rezultatų, ginamų teiginių, išvadų, ir kt.) parengimas:			
3.1.	Tikslų, uždavinių, tyrimo metodikos, ginamųjų teiginių patikslinimas.	2026 m. II ketvirtis	2027 m. I ketvirtis	
3.2.	Analitinės disertacijos dalies parengimas.	2026 m. II ketvirtis	2027 m. I ketvirtis	
3.3.	Teorinės disertacijos dalies parengimas.	2026 m. II ketvirtis	2027 m. I ketvirtis	
3.4.	Eksperimentinės disertacijos dalies parengimas.	2026 m. II ketvirtis	2027 m. I ketvirtis	
3.5.	Bendrųjų išvadų formulavimas.	2026 m. II ketvirtis	2027 m. I ketvirtis	
4.	Daktaro disertacijos <u>parengimas</u> ir svarstymas padalinyje:	2027 m. II ketvirtis	2027 m. II ketvirtis	
5.	Daktaro disertacijos gynimas:	2027 m. III ketvirtis	2027 m. III ketvirtis	

Tyrimo objektas


- Trimačiai taškų debesys, užfiksuoti naudojantis lazerinio skanavimo aparatais, pritvirtintais prie dronų, leidžia atlikti sudėtingesnę analizę negu dvimačiai vaizdai. Miškų taškų debesys naudojami miškininkijoje (medžių inventorizacija) bei infrastruktūroje (elektros perdavimo laidų saugumas).
- Individualių medžių segmentacija išorinio lazerinio skanavimo 3D taškų debesyse
 - Kol kas vyrauja geometriniai algoritmai, kurių veikimas tankiose medžių zonose ne idealus, sudėtinga atitaikyti algoritmo parametrus (per smulkus/stambus segmentavimas);
 - Literatūroje pateikiami mašininio mokymosi metodai orientuoti į antžeminius lazerinio skanavimo duomenis, arba didelio tankio išorinius (žemas skrydis);
 - Sužymėti duomenys individualių medžių segmentacijai reti, gavimo procesas sudėtingas.

Tyrimo objektas


- Tyrimui bus naudojami viešai prieinami 3D taškų debesys iš nacionalinių geoportalų (Estijos, Lenkijos, Lietuvos) ir akademiniai duomenų rinkiniai (FORInstance, SYSSIFOSS)
- Tyrimu siekiama išvystyti (tikriausiai giliuoju mokymusi grįstą) metodą, kuris geriau negu klasikiniai geometriniai algoritmai segmentuotų išorinius žemesnės raiškos taškų debesis
 - Dėl anotavimo sudėtingumo, ketiname eksperimentuoti su sintetiniais duomenimis bei triukšmingomis anotacijomis

Individualių medžių segmentacija

Taškų debesies taškų priskyrimas individualiems tos pačios klasės objektams.



Semantinė segmentacija: suklasifikuoti kiekvieną tašką kaip žemės, pastato, medžio ir t.t.




Instance segmentation: išskirti individualius medžius

Tree instance segmentation - applications


Knowing the locations and spatial extent of individual trees has relevant applications such as:

- Forestry - tree inventorization
- Infrastructure - electricity transmission corridor surveys



Tree encroaching a power line
(Chen et al. 2022)

Common errors in tree instance segmentation



Example of segmentation errors by the region growing Li et al. (2012) algorithm on *FORinstance* dataset (Puliti et al. 2023)

Henrich et al. (2023) trained a Neural Network for instance segmentation of **terrestrial** laser scans of forests, first training the model on auto-annotated data (**noisy labels**). The resulting model **outperformed the original auto-annotation algorithm**.

The aim of this study is to find out, whether the selected Neural Network trained with **noisy labels** on the Estonian GeoPortal **aerial** laser scan data, can lead to improved instance segmentation performance on the test set, compared to the original auto-annotation algorithm.

Data used for this study

Estonian GeoPortal publishes yearly aerial laser scans

Training, validation and test data were plots north of Tallinn.


Plots consisting of mostly coniferous trees were selected using the Estonian tree species distribution map from Lang et al. (2018).



Training and validation data



Raster based algorithm
Dalponte et al. (2016)




Region growing based algorithm
Li et al. (2012)

Making a new synthetic benchmark



1. Classically segment point cloud
2. Manually select and refine tree instances
3. Use treetop location algorithm on test plot
4. Place randomly selected and transformed trees into real tree positions

Result: synthetically constructed forest point cloud with precise ground truth




Test set


Using the tree distribution in the test plot, two higher density and two lower tree density 150 x 150 m regions are generated for testing:




sparse1



sparse2



dense1




dense2

Results


- The raster based algorithm by Dalponte et al. (2016) performs better than Li et al. (2012)
- Li et al. (2012) with default parameters tends to oversegment, but the model trained on these noisy labels leads to the best performing algorithm in terms of recall and F1 score

	li2012			NN-li2012		
Plot	Recall	Precision	F1 score	Recall	Precision	F1 score
sparse1	0.7138	0.7471	0.7300	0.7593	0.8436	0.7992
sparse2	0.6187	0.6824	0.6490	0.7394	0.7920	0.7648
dense1	0.4912	0.6013	0.5407	0.6450	0.8048	0.7161
dense2	0.4187	0.5475	0.4745	0.5439	0.7161	0.6182
all	0.5314	0.6311	0.5770	0.6527	0.7838	0.7123


	dalponte2016			NN-dalponte2016		
Plot	Recall	Precision	F1 score	Recall	Precision	F1 score
sparse1	0.7361	0.9124	0.8148	0.7148	0.8813	0.7894
sparse2	0.6453	0.8674	0.7401	0.6303	0.8229	0.7139
dense1	0.4965	0.7855	0.6084	0.5044	0.7533	0.6042
dense2	0.4627	0.7707	0.5783	0.4714	0.7417	0.5764
all	0.5556	0.8246	0.6639	0.5543	0.7895	0.6514



Ground truth (synthetic forest)



Li et al. (2012) auto-annotation




Neural network trained on auto-annotated data

Kito semestro tikslai

Vilniaus
universitetas

- Konferencijoje pristatytame tyrime parodžiau, jog iš blogo algoritmo galima gauti šiek tiek geresnį
- Aptikau modernių atviro kodo segmentavimo algoritmų, kurie (validuojant su pavišintu duomenų rinkiniu) teigia geresnį tikslumą
- Papildžius eksperimentą šiais algoritmais, galimai verta publikacijos




Zhang ir kt. (2024)

DOI: 10.1080/17538947.2024.2356124


Kito semestro tikslai

- OpenStreetMap pažymėtos 73000 medžių koordinatės (60000 jų Vilniuje)
- Prieinami nacionaliniai Lietuvos, Estijos ir Lenkijos taškų debesys
- Medžių koordinatės nėra idealios
- Šalia pažymėtų medžių yra ir nepažymėtų
- BONUS: OpenStreetMap galima rasti ir kitų objektų koordinates, pvz. suolai, stulpai ir t.t.



Kito semestro tikslai

- Keli miško plotai Vokietijoje nuskenuoti skirtinguose aukščiuose ore, ir nuo žemės paviršiaus - SYSSIFOSS duomenų rinkinys
- Pateikti ir individualių medžių taškų debesys
- Nėra klasių, iš individualių medžių nesigauna pilni tikri miškai
- Apdorojus – puikus tyrimas kaip įvairių algoritmų segmentavimo kokybė priklauso nuo taškų tankio, vertas publikacijos



Kito pusmečio darbo planas

1. Išklaustyti ir išlaikyti privalomojo dalyko "Fundamentalieji informatikos ir informatikos inžinerijos metodai" egzaminą
2. Išklaustyti ir išlaikyti pasirenkamojo dalyko "Didžiųjų duomenų analitika" egzaminą
3. Pakartoti konferencijoje pristatytą tyrimą su stipresniais klasikiniais algoritmais, publikuoti patobulintą tyrimą straipsnyje
4. Paruošti SYSSIFOSS duomenų rinkinį naudojimui mašininio mokymosi tyrimuose
5. Eksperimentuoti su neidealiai pažymėtų objektų išskyrimu taškų debesyse