



**Vilniaus
universitetas**

VEIKLOS ATASKAITA

Kelių asmenų kūno padėties sekimas realiuoju laiku taikant mašininio mokymosi metodus

Doktorantūros pradžios/pabaigos metai: 2022-2026

Studijų metai: 2025/2026 antras pusmetis

Doktorantas: Algimantas Skuodis

Vadovas: Olga Kurasova, prof. Dr

Studijų planas ir jo vykdymo suvestinė

Studijų metai	Egzaminai	
	Planas	Įvykdyta
I (2022/2023)	2	2
II (2023/2024)	2	2
III (2024/2025)		
IV (2025/2026)		
Iš viso:	4	4

Studijų metai	Dalyvavimas konferencijose				Publikacijos					
	Tarptautinėse		Nacionalinėse		Su citav. rodikliu			Be citav. rodiklio		
	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	Būklė	Planas	Įvykdyta	Būklė
I (2022/2023)										
II (2023/2024)		1	1	1				1	1	Publi kuota
III (2024/2025)	1				1	1	Publik uota			
IV (2025/2026)	1	1			1		Įteikta			
Iš viso:	2	2	1	1	2	1		1	1	

Egzaminai 2025/2026 (II pusmetis)		
Planas	Ivykdyta	Būklė

Dalyvavimas konferencijose 2025/2026 (II pusmetis)		
Planas	Ivykdyta	Konferencijos tipas

Publikacijos 2025/2026 (II pusmetis)			
Planas	Ivykdyta	Būklė	Publikacijos tipas
PeerJ Computer Science	Skuodis, A., Kurasova, O. Graph neural network-based recognition of skydiving formations	Įteikta 2026-08-13	Su cituojamumo rodikliu

Dalyvavimas tarptautinėse konferencijose	
	Aprašas
1.	The 16th International Baltic Conference on Digital Business and Intelligent Systems (2024 birželio 20 – liepos 3, Vilnius, Lietuva) Algimantas Skuodis and Olga Kurasova, Evaluation of Deep Learning-Based Models for Recognition of Skydiving Formations, The 16th International Baltic Conference on Digital Business and Intelligent Systems, 2024 birželio 20 – liepos 3
2.	21st International Conference on Computer Vision Theory and Applications (VISAPP 2026) (2026 kovo 9 - kovo 11, Bilbao, Ispanija) Algimantas Skuodis and Olga Kurasova, Deep Learning-Based Models for Recognition of Skydiving Formations, 21st International Conference on Computer Vision Theory and Applications 2026 kovo 9 - kovo 11

Publikacijos (tik su citavimo rodikliu)		
	Bibliografinias aprašas	Būklė
	Skuodis, A., Kurasova, O. Two-step distance-based skydiving formation recognition. Image and Vision Computing, 2026, vol. 173, art. no. 106085. https://doi.org/10.1016/j.imavis.2026.106085	Publikuota

Tyrimų objektas

Giliuoju mašininiu mokymusi paremtas kelių asmenų sąveikos atpažinimas grupiniuose šuoliuose parašiotu.

Tikslas

Sukurti mašininio mokymosi metodą kelių asmenų sąveikai atpažinti, skirtą laisvojo kritimo metu atliekamų derinių klasifikavimui.

Uždaviniai

1. Ištirti šiuolaikinius mašininio mokymosi metodus, naudojamus asmenų kūno padėčiai identifikuoti ir sekti.
2. Sukurti duomenų rinkinį, skirtą kelių asmenų sąveikos atpažinimo parašiotų sporto laisvojo kritimo derinių disciplinoje vertinimui.
3. Pasiūlyti mašininio mokymosi metodą, skirtą kelių asmenų sąveikai parašiotų sporto laisvojo kritimo derinių disciplinoje atpažinti.
4. Atlikti eksperimentinius tyrimus ir įvertinti pasiūlytą metodą naudojant sukurtą duomenų rinkinį.
5. Atlikti pasiūlyto metodo efektyvumo analizę, identifikuoti jo trūkumus ir pasiūlyti tolesnes metodo vystymo gaires.



Laisvojo kritimo deriniai

- 4 kilometrai
- 10 turų / šuolių
- 35 sekundės laisvojo kritimo
- 5-6 burtų būdu ištrauktos figūros
- Viso 16 figūrų ir 22 blokai (2 figūros)
- t.y., 60 skirtingų formacijų



1



17

7.1



Round 10 - 451 "Great Britain"

4-Way Female

8/33



Problema

- Nėra galimybės matyti preliminarų rezultatą gyvai

Kuriamas duomenų rinkinys

- 12 varžybų (2019-2022)
- 60 formacijų (figūrų)
- 26 436 kadrai

Competition	Rounds	Teams
Airspace2022	10	36
Eloy2022	10	25
Tanay2021	6	13
Eloy2019	10	20
FlyspotOpen2021	10	6
FlyspotOpen2022	10	11
DIPC2021	10	6
USPANationals2022	10	12
SwissNationals2022	8	3
USPANationals2022Advanced	10	15
1STDITC2021	10	7
AbhuDhabiFirstOpen2022	6	4

Experimentinis duomenų rinkinys

- Mokymo/validavimo:
 - Pirmos šešios figūros (A,B,C,D,E,F),
 - 1753 vaizdai,
 - 6 klasės,
 - Suvienodintas dydis,
 - Pašalintos šiukšlės,
 - Padalinta 80/20.




Experimentinis duomenų rinkinys

- Testinis - praplėstas:
 - 700 pavyzdžių:
 - A 124
 - B 128
 - C 114
 - D 106
 - E 93
 - 26.9% indoor
 - 73.1% outdoor



Dviejų etapų metodas

- Kūno taškų detektorius (1),
- Formacijų klasifikatorius (2).




Nuoroda į video.








YOLO Pose apmokymas

64 pavyzdžiai, 15 kūno dalių. Nereikia detalių.


No. Keypoint		No. Keypoint	
1	Head	9	Right hip
2	Neck	10	Right knee
3	Right shoulder	11	Right ankle
4	Right elbow	12	Left hip
5	Right wrist	13	Left knee
6	Left shoulder	14	Left ankle
7	Left elbow	15	Chest
8	Left wrist		





YOLO Pose apmokymas

Vilniaus
universitetas




**O kaip su
grafais?**


Ar galime interpretuoti formaciją kaip
grafą ir taikyti GNN modelius?



Modelio paieška





(a)





(b)

Modelio paieška





Config.	Node features (d_n)	Skeleton edges	Wrist edges	Edge features (d_e)
D1	$[x, y]$ (2)	56	—	none
D2	$[pid, kid, x, y]$ (4)	56	—	none
D3	$[pid, kid, x, y]$ (4)	56	336	none
D4	$[pid, kid, x, y]$ (4)	56	336	Euclidean distance (1)

Modelio paieška



Exp.	Config.	Description	Val Acc.	Test Acc.	Test F1	Test Params
1	D1	Grid search, coordinates only	0.746	0.720	0.71	431,515
2	D2	Single run, identity features	0.815	0.820	0.81	282,375
3	D3	Single run, Exp. 2 architecture	0.755	0.720	0.71	282,375
4	D3	Grid search	0.937	0.880	0.88	282,905
5	D3	Best config	0.951±0.008	0.950	0.95	286,951
6	D4	Best config + edge dist.	0.944±0.011	0.950	0.95	287,463

Modelio paieška



Rezultatų palyginimas



Method	Source	Test F1	Test Acc.	Params
ConvMixer_768_32 (single-step)	[1]	0.95	0.95	20.3M
YOLO + FCNN wrist distances (two-step)	[2]	0.95	0.95	~3.0M
YOLO + GNN, Exp. 6 (two-step)	[3]	0.95	0.95	~3.1M

Parameter counts reflect neural network components only. YOLO11n-Pose contributes 2.8M parameters to both two-step methods. The FCNN classifier contributes 0.14M and the GNN classifier contributes 0.29M.

Problemos?

- Per mažas testinis duomenų rinkinys – galima praplėsti.
- Nėra augmentavimo – galima augmentuoti sintetiškai.
- Kraštinės nuo riešų iki visų kūno dalių - ar visos svarbios ?

Modelio paieška



Rezultatų palyginimas

Exp.	Method	Source	F1 (60)	F1 (ext.)	Params
5	GNN (D3)	[3]	0.947	0.875	287K
6	GNN (D4)	[3]	0.932	0.866	287K
7	GNN + augmentation	[3]	0.933	0.890	287K
8	LCT-GNN	[3]	0.933	0.881	37.5K
9	LCT-GNN + augmentation	[3]	0.966	0.901	37.5K
—	FCNN wrist distances	[2]	0.898	0.850	138K
—	CatBoost wrist distances	[2]	0.917	0.843	—
—	ConvMixer_768_32 (single-step)	[1]	0.932	0.909	20.3M
—	FastViT-MA36 (single-step)	[1]	0.966	0.908	42.9M
—	ResNet-50 (single-step)	[1]	1.000	0.858	23.5M

Rezultatų palyginimas

Method	F1 (ext.)	Δ
Full method (LCT-GNN + keypoint augmentation)	0.901	—
without keypoint augmentation	0.881	−0.020
without LCT-GNN (GraphGym-based classifier)	0.890	−0.011
without both	0.875	−0.026

Klaidų analizė


Stage	Cause	Images	Share
Detection	Missing person or persons	36	52.2%
Detection	Incorrect keypoints	25	36.2%
Condition	Formation too small or distant	19	27.5%
Condition	Image too dark	11	15.9%
Classification	Genuine classifier error	8	11.6%
Detection	Keypoints crowded or overlapping	5	7.2%




(a)



(b)




(c)



(d)



(e)



(f)

Išvados

- Dviejų etapų metodas yra tinkama strategija figūrų klasifikavimui ir gali būti taikomas kūno padėčiai sekti bei taškams skaičiuoti parašiotų sporto laisvojo kritimo derinių disciplinoje.
- Lyginant su ankstesnėmis dviejų etapų metodo strategijomis, GNN modeliai pasiekia aukščiausias rezultatus išplėstame testiniame duomenų rinkinyje.
- Koordinatinių augmentavimas yra prasmingas ir prisideda prie geresnių klasifikavimo rezultatų.
- LCT-GNN modelis geba išmokti atpažinti didžiausią reikšmę klasifikavimui turinčias kraštines.

Tolimesni darbai

- Tyrimų apibendrinimas ir disertacijos rengimas.

Klausimai?