

Dirbtinio intelekto metodų tyrimas astrofizikinių objektų klasifikavimui ir/arba svarbių savybių nustatymui

Doktorantas: Tomas Mūžas

Darbo vadovas: prof. dr. Tadas Meškauskas

Darbo konsultantas: dr. Andrius Vytautas Misiukas Misiūnas

Doktorantūros studijų laikotarpis: 2022 – 2026 m.

Studijų planas ir jo vykdymo suvestinė

Metai	Egzaminai		Dalyvavimas konferencijose				Publikacijos		
			Tarptautinės		Nacionalinės		Su citav. rodikl.		
	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	Būsena
I (2022/2023)	2	2	-	1	-	-	-	-	-
II (2023/2024)	2	2	-	-	-	-	-	-	-
III (2024/2025)	-	-	1	-	-	-	1	-	Pateikta, Recenzuojama
IV (2025/2026)	-	-	1	-	-	-	1	-	-
Iš viso	4	4	2	1	-	-	2	0	-

2024/2025 m.m. planas ir jo vykdymas

Egzaminai

Planas	Įvykdyta	Būklė
Vaizdų ir duomenų analizė (FF) (2023-06-14)	2023-06-14	Išlaikyta
Informatikos ir informatikos inžinerijos tyrimo metodai ir metodika (2023-06-22)	2023-06-22	Išlaikyta
Fundamentalieji informatikos ir informatikos inžinerijos metodai (2024-01-24)	2024-01-24	Išlaikyta
Gilieji neuroniniai tinklai (2024-06-11)	2024-06-11	Išlaikyta

Tyrimo objektas

- Astrofizikinių objektų klasifikavimas ir/ar savybių nustatymas
- profesionalų parengti arba savanorių balsavimu grįsti duomenų rinkiniai
- antžeminių ir kosmoso teleskopų nuotraukos

Tyrimo tikslas

Pasiūlyti naują arba patobulintą astrofizikinių objektų klasifikavimo modelį, paremtą dirbtinio intelekto metodais

Tyrimo uždaviniai

1. Sukurti astrofizikinių objektų duomenų analizės metodiką, apibrėžti kriterijus objektų klasifikavimo ir/ar savybių patikimumui įvertinti. Taip pat parengti metodiką sintetinių duomenų generavimui.
2. Atrinkti patikimų duomenų rinkinius, skirtus modelių apmokymui ir validavimui.
3. Apmokyti skirtingus dirbtinio intelekto modelius naudojant parengtą apmokymo duomenų rinkinį. Skaičiavimus atlikti naudojant paskirstyto skaičiavimo resursus bei grafinius procesorius.
4. Išskirti efektyviausius modelius bei jų parametrus, optimizuoti jų taikymą.

Nagrinėjami galaktikų tipai

Spiral (barred)



Spiral (no bar)



Elliptical






Edge-on






Duomenų rinkiniai

- Siekiant gauti kuo didesnės apimties duomenų rinkinius, buvo naudojami 5 savanorių balsavimu grįsti Galaxy Zoo (GZ) duomenų rinkiniai – GZ1, GZ2, GZ CANDELS, GZ Hubble, GZ DECaLS.
- Bendras galaktikų kiekis – 1.2 milijono.
- Kadangi ta pati galaktika galėjo būti keliuose rinkiniuose, rinkiniai pradžiai buvo apjungiami pagal koordinatas. Tai sumažina bendrą *unikalių* galaktikų skaičių.
- Paliekamos tik tos unikalios galaktikos, dėl kurių klasės sutaria ne mažiau nei 80% savanorių, ir klasė sutampa visuose duomenų rinkiniuose, kur yra ta galaktika.
- Galutinis 4 klasių galaktikų kiekis – 99,335

Nauji sluoksniai – Focal conv.



Nauji sluoksniai – Wave conv.



Naujų architektūrų paieška

- Pagrindas – Cavanagh (CNN) architektūra
- Keras Tuner + Hyperband
- Number of CNN layers – $\{3, 4, 5\}$
- CNN layer types:
 - Simple conv – Filters $\{16, 32, 48, 64\}$, Kernel $\{3, 5, 7\}$
 - Focal Conv – Filters $\{16, 32, 48, 64\}$, Kernel $\{3, 5, 7\}$, Factor $\{1..10\}$
 - Wave Conv – Filters $\{16, 32, 48, 64\}$, Kernel $\{3, 5, 7\}$, Factor $\{1..10\}$
- Number of dense layers – $\{1, 2, 3\}$
- Dense layer neurons – $\{32, 64 \dots, 256\}$

Kriterijai

- Best accuracy
 - Focal, Simple, Simple, Wave
- Best accuracy (top 10 mediana)
 - Focal, Focal, Simple, Wave
- Best F1
 - Focal, Simple, Focal
- Best F1 (top 10 mediana)
 - Focal, Focal, Focal

Rezultatai

Model	Augmentations	Accuracy (σ)	Precision (σ)	Recall (σ)	F1 (σ)
resnet50	No augmentations	77.10 (2.19)	77.01 (2.44)	76.05 (2.87)	76.21 (2.51)
<i>cavanagh</i>	<i>No augmentations</i>	<i>86.01 (0.82)</i>	<i>86.85 (0.82)</i>	<i>84.78 (1.08)</i>	<i>85.68 (0.90)</i>
Best accuracy (Top 10)	No augmentations	86.78 (0.67)	87.29 (1.01)	86.12 (0.84)	86.63 (0.76)
Best F1	No augmentations	87.23 (0.43)	87.78 (0.65)	86.59 (0.45)	87.12 (0.46)
Best accuracy	No augmentations	87.29 (0.42)	87.75 (0.73)	86.84 (0.50)	87.21 (0.45)
Best F1 (Top 10)	No augmentations	87.31 (0.32)	88.31 (0.41)	86.29 (0.68)	87.20 (0.40)
resnet50	With augmentations	85.26 (0.64)	85.68 (1.12)	84.34 (0.91)	84.83 (0.77)
Best accuracy (Top 10)	With augmentations	88.20 (0.56)	89.06 (0.65)	87.54 (0.92)	88.21 (0.67)
Best accuracy	With augmentations	88.38 (0.64)	89.15 (0.51)	87.99 (0.77)	88.52 (0.64)
<i>cavanagh</i>	<i>With augmentations</i>	<i>88.49 (0.27)</i>	<i>89.06 (0.50)</i>	<i>88.17 (0.42)</i>	<i>88.57 (0.25)</i>
Best F1 (Top 10)	With augmentations	88.61 (0.48)	89.34 (0.40)	88.28 (0.62)	88.76 (0.51)
Best F1	With augmentations	88.65 (0.38)	89.46 (0.46)	88.20 (0.47)	88.77 (0.39)

Išvados

- Geriausi modeliai, apmokyti tiek pagal tikslumą, tiek pagal F1 dažniausiai rinkosi naujus FocalConv arba WaveConv sluoksnius vietoje įprasto konvoliucinio sluoksnio
- Apmokant modelius pagal F1, top 10 architektūrų dažniausiai naudojo FocalConv sluoksnį visuose 3 sluoksniuose
- Nenaudojant augmentacijų, naujosios architektūros parodė geresnius rezultatus nei pradinė architektūra
- Augmentacijos naujosioms architektūroms turi sąlyginai nedidelį poveikį, todėl galima teigti, kad naujieji sluoksniai savo efektyvumu prilygsta augmentacijoms.

Numatomi darbai

- Publikuoti straipsnį 2024/2025 m. m.
- Pritaikyti VisionTransformers, parinkti geriausią architektūrą
- Pritaikyti knowledge distillation, CNN -> transformer / transformer -> CNN

Ačiū už dėmesį!