

Vilniaus universitetas
Fizikos fakultetas
Teorinės fizikos ir astronomijos institutas

Dalius Janonis

M51 GALAKTIKOS SPIEČIŲ TYRIMAS KONVOLIUCINIAIS NEURONINIAIS
TINKLAIS

Magistrantūros studijų baigiamasis darbas

Teorinės fizikos ir astronomijos studijų programa

Studentas

Dalius Janonis

Leista ginti

2021-05-20

Darbo vadovas

dr. Stepas Toliautas

Instituto atstovas

prof. Egidijus Anisimovas

Vilnius 2021

Turinys

1	Įvadas	3
2	Dirbtinių neuroninių tinklų sandara	5
3	Žvaigždžių spiečių duomenys	6
3.1	Naudoti duomenys	6
3.2	Apmokymo duomenų generavimas	8
4	Konvoliucinis tinklas spiečių klasifikavimui	11
4.1	Tinklo struktūra	11
4.2	Tinklo apmokymas	12
5	M51 galaktikos spiečiai	14
5.1	M51 galaktikos spiečių katalogo analizė	14
5.2	M51 galaktikos spiečių aptikimas	15
6	Rezultatų aptarimas	15
7	Išvados	18

1 Įvadas

Konvoliuciniai neuroniniai tinklai per pastarąjį dešimtmetį itin išpopuliarėjo spręsti įvairiems vaizdų ir kalbos atpažinimo, duomenų analizės, klasifikavimo uždaviniams [1]. Tinkamai apmokytas neuroninis tinklas sugeba greitai ir tiksliai klasifikuoti didelius jam paduodamų duomenų masyvus. Be jų naudojimo objektų ar simbolių nuotraukose atpažinimui, neuroniniai tinklai taip pat sėkmingai pritaikomi astronomijoje - žvaigždžių, jų spiečių ar galaktikų aptikimui astronominėse apžvalgose [2] ir jų savybių analizei [3–10]. Dėl vis sparčiau augančio astronominių duomenų kiekio šio metodo taikymas ir plėtojimas yra labai svarbus tolesnei astrofizikos mokslo raidai. Dažnai tokio tinklo klasifikavimo tikslumas lenkia rankiniu būdu vykdomo klasifikavimo tikslumą. Neuroniniai tinklai taip pat pritaikomi stebėjimo duomenų kokybės įvertinimui [11], spektrų klasifikavimui [12] ir gravitacinių bangų aptikimui [13]. Platesnė neuroninių tinklų ir mašininio mokymosi taikymo astronomijoje apžvalga pateikiama [14]. Didžioji dauguma žvaigždžių gimsta žvaigždžių spiečiuose. Kadangi spiečiai paprastai formuojasi iš vieno molekulinio debesies [15], jų žvaigždėms būdingas vienodas savasis judėjimas, metalingumas ir amžius. Dėl šių savybių žvaigždžių spiečiai yra svarbūs žvaigždžių ir galaktikų formavimuisi, evoliucijos modeliams bei žvaigždėdaros mechanizmams tirti. Nepaisant to, žvaigždžių spiečių aptikimas ir klasifikavimas automatizuotais metodais yra vis dar besivystanti sritis. Šiame darbe M51 galaktikos spiečiams aptikti ir klasifikuoti naudojamas konvoliucinis neuroninis tinklas, apmokytas sukurtais dirbtiniais stebėjimų kadrais.

Darbo tikslas – sukurti ir apmokyti konvoliucinių neuroninių tinklų pagrindu veikiančią algoritmą, kuris suklasifikuotų jam pateikiamus Hubble kosminiu teleskopu gautus M51 galaktikos (1 pav.) daugiabangių stebėjimų duomenis pagal tai, ar juose yra aptinkamas žvaigždžių spiečius, ir nustatytų aptikto spiečiaus dydį.

Darbo uždaviniai:

- Sugeneruoti dirbtinius kadrus neuroninio tinklo apmokymui.
- Apmokyti neuroninį tinklą.
- Patikrinti dydžio nustatymo tikslumą su dirbtiniais testavimui sukurtais duomenimis.
- Suklasifikuoti M51 galaktikos spiečius.



1 pav. M51 galaktika [16].


2 Dirbtinių neuroninių tinklų sandara

Dirbtiniai neuroniniai tinklai yra mašininio mokymosi (angl. machine learning) tipas, šiuo metu itin plačiai taikomas įvairiose mokslo šakose. Jų pradmenys tyrinėti dar ketvirtajame praėjusio amžiaus dešimtmetyje, platesnį naudojimą įgalino sukurtas atgalinio sklidimo metodas [17], tačiau neuroninių tinklų nebuvo galima plačiai pritaikyti praktikoje dėl tuomet nepakankamai spartaus kompiuterių skaičiavimo greičio. Per pastarąjį dešimtmetį išaugusi kompiuterių procesorių bei grafinių plokščių sparta, specialių TPU (angl. tensor processing unit) taikymas leidžia plačiai taikyti šiuos metodus ir net tam naudotis namų kompiuteriais.

Klasikinis neuroninis tinklas sudarytas iš dirbtinių neuronų sluoksnių, kurie sujungti tarpusavyje. Kaip ir organinis jo analogas, kiekvienas dirbtinis neuronas turi tam tikrą aktyvaciją, kuri paprastai kinta intervale, pvz. $(0, 1)$. Neurono aktyvacija apibrėžiama funkcija

$$a(x) = \sigma \left(\sum_{i=1}^n w_i x_i + b \right).$$

Aktyvacijai apskaičiuoti neuronas priima aktyvacijas iš visų ankstesniame sluoksnyje esančių neuronų, jas paveikia svoriu (angl. weight) w ir poslinkiu (angl. bias) b ir aktyvacijos funkcija θ . Savo apskaičiuotą aktyvaciją jis perduoda toliau esantiems neuronams. Neurono, esančio sluoksnyje j , schema pavaizduota 2 pav. Neuronų aktyvacija pirmajame sluoksnyje gaunama tiesiai iš duomenų. Paskutiniame sluoksnyje neuroninis tinklas grąžina rezultatus, pavyzdžiui, masyvą, kurio kiekvienas elementas atitinka tam tikrą užkoduotą rezultatą.



2 pav. Neurono, esančio sluoksnyje j , schema. Čia θ - aktyvacijos funkcija, a - neurono aktyvacija, w - svoris, b - poslinkis.

Apmokant neuroninį tinklą, jam paduodami jau suklasifikuoti duomenys, kuriuos tinklas mokosi pats priskirti tinkamai kategorijai, t.y., kiekvienam įvesties duomenų masyvui priskirti tinkamą išvesties vertę (angl. label). Tinklo pasiekiamo klasifikavimo tikslumą nustato paklaidos funkcija, kuri bendru atveju nurodo, kiek neuroninio tinklo gaunami galutiniai rezultatai skiriasi nuo tų verčių, kurias tikėjimės gauti. Neuroniniai tinklai mokosi iteracijomis ir kiekvieną iteraciją neuroninis tinklas ieško tokių svorių ir poslinkių verčių, kurioms esant paklaidos funkcija mažiausia. Tai atliekama apskaičiuojant paklaidos funkcijos dalinę išvestinę kiekvienam neuroniniame tinkle esančiam svoriui ir poslinkiui. Tada atitinkamai koreguojamos jų vertės. Svorių korekcijų amplitudė priklauso nuo mokymosi spartos parametro - kuo jis didesnis, tuo greičiau neuroninis tinklas mokosi, bet sprendinys prasčiau konverguoja. Kuo jis mažesnis - tuo lėčiau neuroninis tinklas mokosi, bet sprendinys konverguoja geriau. Dėl per mažos mokymosi duomenų aibės neuroninis tinklas gali „persimokyti“ - išmokti gerai suklasifikuoti duomenų aibę, kurią naudojo mokymuisi, tačiau prastai klasifikuoti kitus analogiškus duomenis. Siekiant išvengti šios problemos taikoma „dropout“ operacija, kuri atsitiktinai atjungia tam tikrą dalį sujungimų tarp neuronų sluoksnių mokymo metu.

Konvoliuciniai neuroniniai tinklai yra neuroninių tinklų tipas, atliekantis gaunamų duomenų masyvo X konvoliuciją su tam tikrais filtrais, kurių dydį galima pasirinkti. Ši operacija apibūdinama funkcija

$$z(X) = W * X + bJ,$$

kur W - filtras (angl. kernel), J - vienetų matrica. Gauti rezultatai įrašomi į tokio pat dydžio masyvą ir taip sukuriama tam tikrų abstraktesnių ypatybių, kaip kraštinių, regionai (angl. feature maps). Konvoliucinius filtrus galima slinkti didesniu nei vieno pikselio žingsniu (angl. stride), tokiu būdu mažinant gaunamos išvesties matricos dydį. Šios procedūros paprastai daromos kelis kartus, kol galiausiai gautas masyvas ištiesinamas į vienmatį masyvą ir sujungiamas su paprastų neuronų sluoksniu.

3 Žvaigždžių spiečių duomenys

3.1 Naudoti duomenys

M51 galaktika nuo mūsų nutolusi $7,1 \pm 1,2$ Mpc [18] atstumu, sudaryta iš dviejų sąveikaujančių galaktikų - NGC 5194 ir NGC 5195. NGC 5194 yra spiralinė galaktika, pasižymi ryškiomis vijomis. Dėl sąveikos su kompanione sukeltos žvaigždėdaros ir gerai matomo disko M51 galaktika yra populiarus žvaigždėdaros, spiečių formavimosi ir evoliucijos tyrimų objektas [19–21].

Tinklo apmokymui skirtų sintetinių kadrų fonams sukurti bei rezultatų analizei atlikti naudoti archyviniai M51 galaktikos stebėjimų duomenys, gauti iš Mikulski Archive for Space Telescopes¹. Stebėjimai daryti F435W (B), F555W (V), F814W (I) filtruose su ACS kamera (angl. Advanced Camera for Surveys), esančia Hubble kosminiam teleskope [22]. Stebėjimai

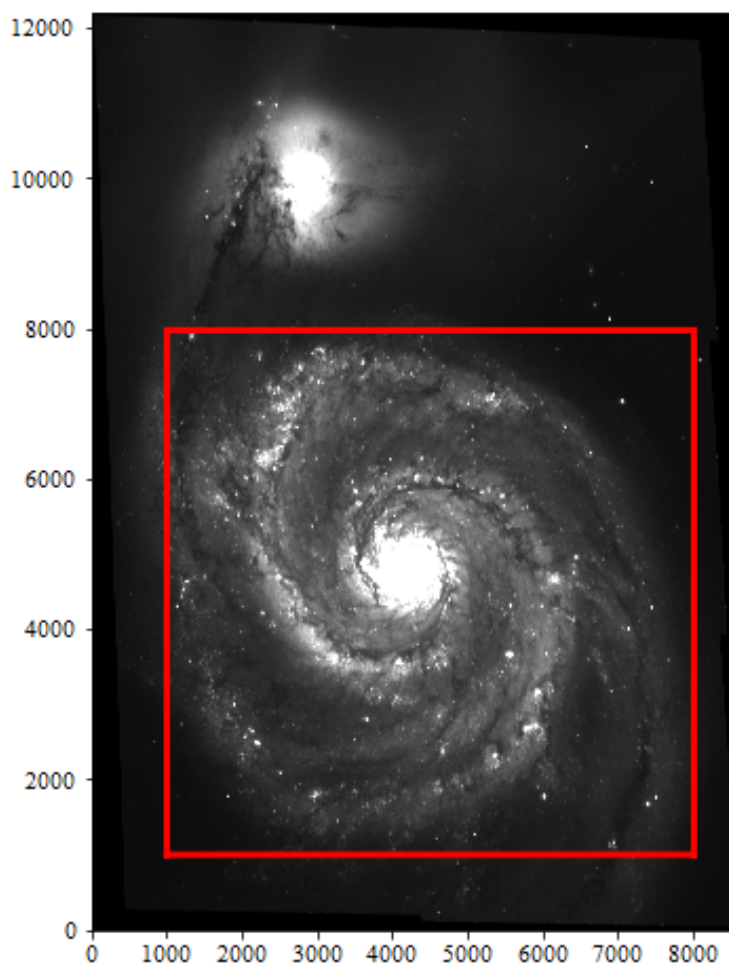
¹<https://archive.stsci.edu/prepds/m51/>

vykdyti 2005 m. sausio 12-22 d. Kadrai yra 8600x12200 pikselių dydžio, skalė - 0,05 kampinių sekundžių į pikselį. Ekspozicijos laikai B, V ir I filtrams atitinkamai 2720, 1360 ir 1360 sekundžių. Stebėjimų programos pavadinimas - GO/DD 10452. M51 galaktikos atvaizdas B, V ir I filtruose pavaizduotas 3 pav.



3 pav. M51 galaktikos vaizdas B (kairėje), V (viduryje) ir I (dešinėje) filtruose.


3.2 Apmokymo duomenų generavimas



4 pav. Regionas, iš kurio kerpami fonai apmokymo kadrams generuoti.

Neuroniniam tinklui apmokyti reikia turėti iš anksto suklasifikuotų duomenų masyvą. Tam iš pradžių sukuriamas tuščias 32 pikselių aukščio ir pločio kadras, turintis 3 sluoksnius, kurie atitinka B, V ir I filtrus. Tada atsitiktinai parenkama pozicija kadro centriniuose 12x12 pikselių. Tuomet į tą poziciją kiekviename filtre įdedamas sintetinis spiečius, kuris yra Gauso funkcija, padauginta iš atsitiktinai parenkamos fotonų srauto vertės. V filtrui srauto vertė renkama iš intervalo [4:20], B ir I filtrams - atsitiktinai parenkama nuo 0,8 iki 1,2 V filtro srauto vertės. Taip pat atsitiktinai pasirenkamas ir spiečiaus vaizdą atitinkančios Gauso funkcijos standartinis nuokrypis. Šis nuokrypis renkamas iš intervalo [0,2:4] (pikseliais). Gauta Gauso funkcija konvoliuojama su sugeneruota TinyTim² taško sklaidos funkcija kiekvienam filtrui. Taško sklaidos funkcija (angl. point spread function) nusako, kokį atvaizdą tam tikroje optinėje sistemoje suformuotų taškinis šviesos šaltinis. Šiuo atveju taško sklaidos funkcija atitinka Hubble teleskopo ACS kameros optinės sistemos parametrus. Tuomet iš M51 stebėjimo duomenų atsitiktinai pasirinktoje vietoje, nepriklausomai nuo to, ar į ją patenka žvaigždės ar kiti spiečiai, iškerpamas 32x32 pikselių fono kadras, kuris pridodamas į sintetinį kadrą. Kadras kerpamas iš 1000:8000,1000:8000 regiono, kuris pavaizduotas 4 pav.

²www.stsci.edu/software/tinytim/



5 pav. Apmokymui sukurtų dirbtinių kadro pavyzdžiai.

Norint konvertuoti kadro vertes į fotonų kiekius, jos padauginamos iš stiprinimo (angl. gain) (2) ir ekspozicijos laiko kiekvienam filtrui. Galiausiai kadras paveikiamas Puasono triukšmo siekiant atkurti realiems stebėjimams būdingas fotonų srauto fliuktuacijas. Puasono skirstinys apibrėžiamas

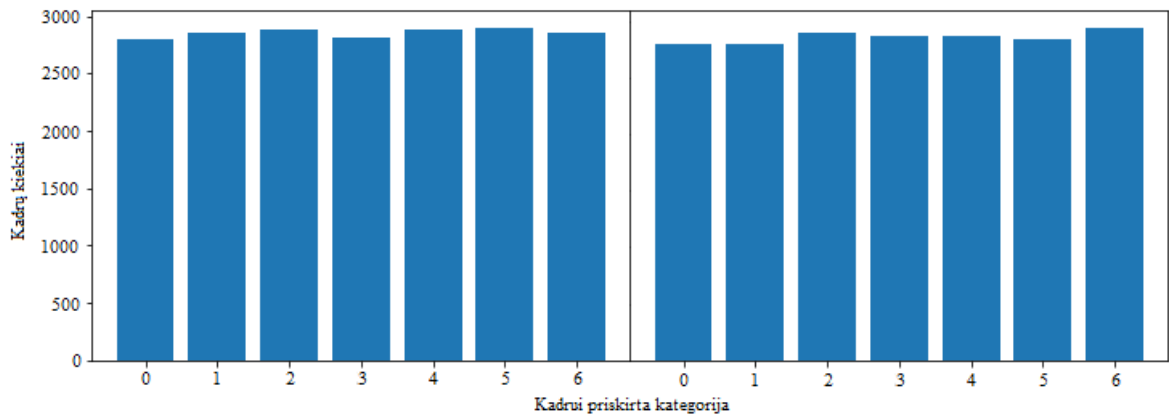
$$P(k) = \frac{N^k e^{-N}}{k!},$$

kur N - vidutinis įvykių (detekcijų) kiekis. Iš viso apmokymui sugeneruota 20000 kadro - 17200 kadro su dirbtiniu spiečiumi ir 2800 kadro be spiečiaus. Tiek pat kadro sugeneruota ir tinklo testavimui. Apmokymui sukurtų dirbtinių kadro pavyzdžiai pavaizduoti 5 pav.

Šie sintetiniai duomenys skirstomi į 7 kategorijas, kurios sunumeruotos nuo 0 iki 6. 0 kategorija atitinka kadro be spiečiaus, kitos kategorijos nustatytos pagal sintetinio spiečiaus plotį (standartinį nuokrypį). Kategorijų reikšmės pavaizduotos 1 lentelėje. Sugeneruotų apmokymo ir testavimo kadro kiekis kiekvienoje kategorijoje pavaizduotas 6 pav. Matyti, kad skirtingas kategorijas atitinkančių kadro kiekis yra apylygis.

Kategorija	σ
0	Tuščia
1	(0,2:0,83]
2	(0,83:1,47]
3	(1,47:2,1]
4	(2,1:2,73]
5	(2,73:3,27]
6	(3,27:4]

1 lentelė. Spiečių klasifikavimo kategorijų reikšmės.



6 pav. Apmokymo (kairėje) ir testavimo (dešinėje) kadru kategorijų histograma.

4 Konvoliucinis tinklas spiečių klasifikavimui

4.1 Tinklo struktūra

Tyrimui naudotas neuroninis tinklas sukurtas pasinaudojant TensorFlow³ [23] ir Keras⁴ bibliotekomis. Šiame darbe naudojamas „Adam“ optimizatorius [24], kryžminės entropijos (angl. categorical crossentropy) paklaidos funkcija ir ReLU aktyvacijos funkcija

$$f(x) = \max(0, x).$$


Tinklas sudarytas iš keturių konvoliucinių sluoksnių. Po konvoliucinių sluoksnių gaunami kadrai transformuojami į vienmatį duomenų masyvą. Šis masyvas sujungiamas su paprastu, pilnai sujungtu sluoksniu iš 128 neuronų. Pastarasis sluoksnis sujungtas su paskutiniu, normuotu rezultatų masyvu, kurio kiekvienas iš 7 neuronų atitinka galimą klasifikavimo kategoriją. Paskutinio rezultatų sluoksnio aktyvacijos funkcija yra „softmax“:

$$f(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^N \exp(x_j)}.$$

Šiame darbe naudoto neuroninio tinklo schema pavaizduota 7 pav. Iš viso treniruojami 591,527 parametrai. Konvoliuciniuose sluoksniuose pateikiama įvestis konvoliuojama su 3x3 pikselių matmenų filtrais, kurių pradinės reikšmės parenkamos siekiant sparčiausio koeficientų nusistovėjimo [25]. Jei konvoliucija vykdoma su pikseliu, esančiu kadro krašte, trūkstamas regionas papildomas tuščiais pikseliais. Tarp konvoliucinių sluoksnių duomenų aukščiui ir pločiui sumažinti panaudojama „max pooling“ operacija. Tarp priešpaskutinio tinklo sluoksnio su 128 neuronų ir paskutinio sluoksnio yra vykdoma „dropout“ operacija, kuri atsitiktinai pa-

³www.tensorflow.org

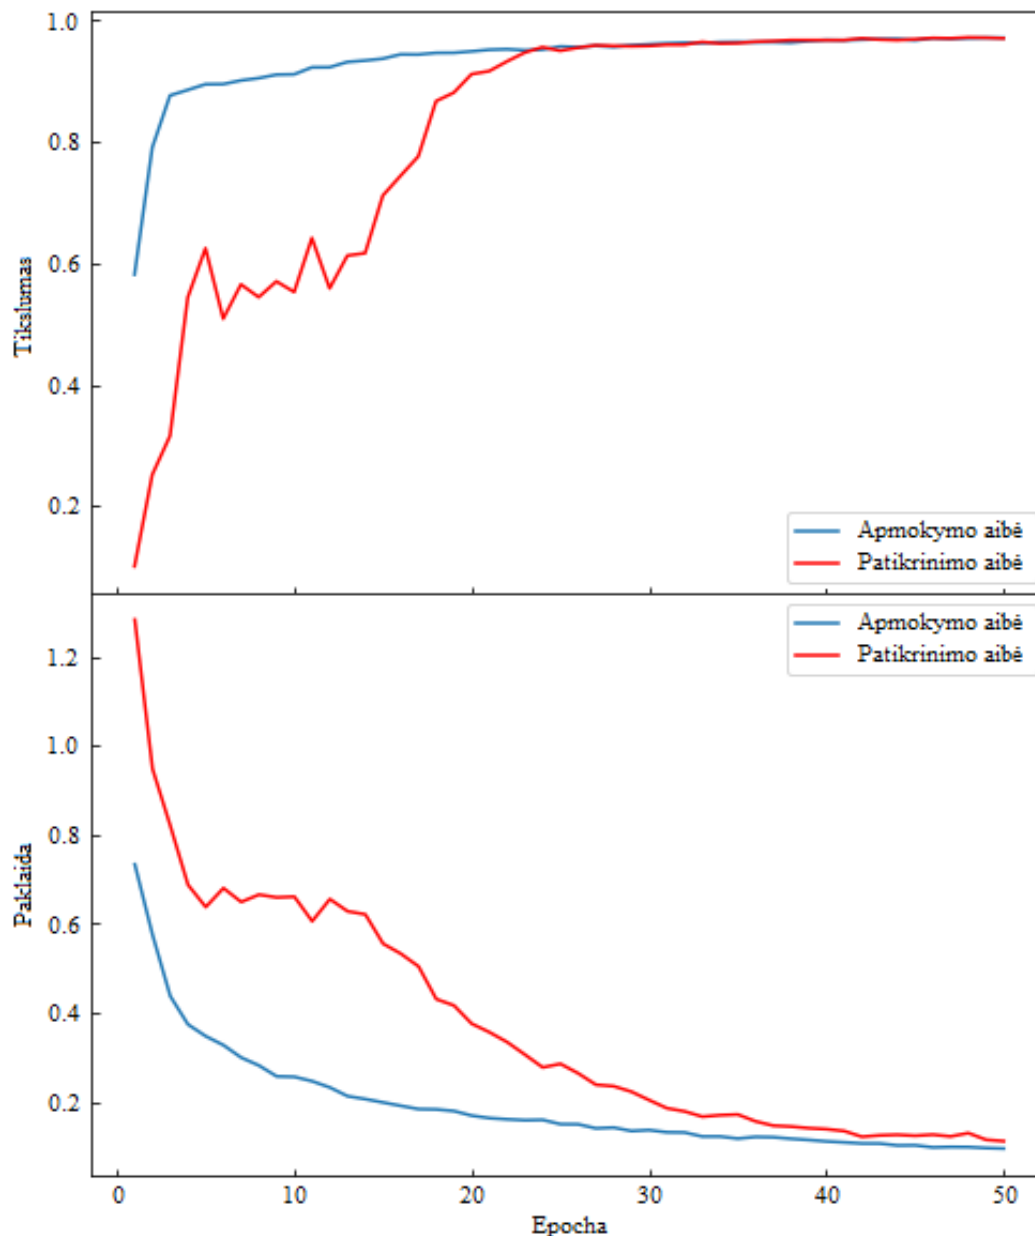
⁴www.keras.io



7 pav. Sukurto ir pritaikyto neuroninio tinklo schema.


naikina 50% sujungimų tarp šių neuronų sluoksnių. Tai padeda neuroniniam tinklui išvengti persimokymo.

4.2 Tinklo apmokymas



8 pav. Tinklo klasifikavimo tikslumo (viršuje) ir paklaidos funkcijos (apačioje) priklausomybė nuo mokymosi epochos, klasifikuojant kadrus į dvi kategorijas. Mėlyna linija pavaizduotas tikslumas apmokymo duomenų aibei, raudona linija - patikrinimui atskirtų duomenų aibei.

Tinklas apmokomas su 18000 sugeneruotų sintetinių kadru. Likęs apmokymų kadru aibės dešimtadalis yra atskirtas tikslumo patikrinimui ir kitaip apmokymo procese nedalyvauja. Kadrai tinklui paduodami partijomis po 2000. Po kiekvienos partijos apskaičiuojama ir pritaikoma suvidurkinta kiekvieno neurono svorio ir poslinkio korekcija. Neuroniniam tinklui paduodama kita kadru partija ir šis procesas kartojamas tol, kol visi 20000 kadru pereina




9 pav. Tinklo klasifikavimo tikslumo (viršuje) ir paklaidos funkcijos (apačioje) priklausomybė nuo mokymosi epochos, klasifikuojant kadrus į septynias kategorijas. Mėlyna linija pavaizduotas tikslumas apmokymo duomenų aibe, raudona linija - patikrinimui atskirtų duomenų aibe.

šį procesą. Toks visų 20000 kadrų perėjimo ciklas vadinamas epocha. Darbe nagrinėjamas tinklas apmokytas dviem atvejais. Vienu atveju tinklas kadrus klasifikuoja tik į dvi kategorijas - priklausomai nuo to, ar kadre aptinkamas spiečius. Antru atveju klasifikuojama į 7 kategorijas, priklausančias nuo spiečiaus funkcijos standartinio nuokrypio. Pirmuoju atveju apmokymas įvykdomas per 50 epochų. Tinklo mokymasis nutraukiamas ties 50 epocha, nes mokymosi ir patikrinimo duomenų aibės klasifikavimo tikslumas nebekinta. Tikslumo ir paklaidos funkcijos priklausomybė nuo mokymosi epochų skaičiaus šiuo atveju pavaizduota 8 pav. Pasiekiamas tinklo klasifikavimo tikslumas apmokymo ir testavimo duomenims - 97%. Antruoju atveju tinklo apmokymas vykdomas 80 epochų. Tikslumo ir paklaidos funkcijos

priklausomybės pavaizduotos 9 pav. Pasiekiamas 83% klasifikavimo (kategorijos nustatymo) tikslumas apmokymo kadru aibe. Testavimui sukurtiems sintetiniams duomenims pasiekiamas 73% klasifikavimo tikslumas. Geresnio tikslumo pasiekti galėjo nepavykti dėl pašalinių spiečių, žvaigždžių, pasitaikančių tuščiuose kadruose, ar prasto kai kurių spiečių ryškumo.

Atskirai testavimui analogiškai buvo sukurta 20000 nepriklausomų sintetinių kadru. Šių duomenų testo rezultatai pavaizduoti 10 pav. Iš šio kadru rinkinio 71% suklasifikuojami teisingai. Kategorijos, atitinkančios panašaus dydžio spiečius, kartais būna supainiojamos tarpusavyje arba palaikomos kadru be spiečiaus. Kadrai be spiečių taip pat palaikomi kadrais su spiečiumi, su didesne tikimybe būti priskirtiems kadru su spiečiumi, turinčiu didelį plotį.




10 pav. Konvoliucinio neuroninio tinklo testavimo rezultatai logaritminėje skalėje. Šio grafiko y ašis atitinka mums žinomą tikrą duomenų kategoriją, x ašis - neuroninio tinklo nustatytą kategoriją.

5 M51 galaktikos spiečiai

5.1 M51 galaktikos spiečių katalogo analizė

M51 galaktikos spiečių analizei naudoti 2224 spiečių profilio puspločio duomenys iš [26] katalogo. Šių spiečių kadrai buvo iškirpti iš M51 nuotraukų nustatant jų poziciją iš kataloge pateiktų koordinatų, iš jų sudaromas masyvas pateikiamas neuroniniam tinklui suklasifikuoti. 11 pav. pateikiami spiečių vaizdų pavyzdžiai V filtre. Pirmuoju neuroninio tinklo apmokymo atveju, skirstant kadrus tik į dvi kategorijas priklausomai nuo to, ar aptinkamas spiečius, tinklas 99% [26] katalogo spiečių suklasifikuoja kaip kadrus su spiečiumi. Antruoju



11 pav. Spiečių iš Hwang ir Lee (2008) katalogo pavyzdžiai


atveju, papildomai skirstant kadrus į kategorijas pagal juose esančių spiečių plotį, tinklas 85% katalogo kadru atpažįsta kaip kadrus su 1-6 kategorijos spiečiumi. Neuroninio tinklo priskirtos kategorijos vidutinio standartinio nuokrypio ir vidutinio profilio puspločio iš Hwang ir Lee katalogo kiekvienai kategorijai pasiskirstymas pavaizduotas 12 pav. Yra pastebima spiečiui tinklo priskiriamo dydžio ir spiečiaus profilio puspločio koreliacija.

5.2 M51 galaktikos spiečių aptikimas

Siekiant neuroniniu tinklu aptikti spiečius visame M51 galaktikos nuotraukos lauke jis padalintas į 32x32 pikselių laukelius, laukelį slenkant po 16 pikselių. Iš šių laukelių suformuotas masyvas neuroniniam tinklui klasifikuoti. Iš viso aptikti 8935 kadrai su potencialiais spiečiais. Aptikimo rezultatai pavaizduoti 13 pav. Matyti, kad taškai grupuojasi galaktikos centre ir ant vijų, kuriuose aktyviausia žvaigždėdara, tad palankiausios sąlygos formuotis spiečiams. Pastebimos netikros detekcijos kadro kraštuose. Taip pat daug perteklinių detekcijų yra galaktikų centruose bei spiečiais palaikomos atskiros lauko žvaigždės.

6 Rezultatų aptarimas

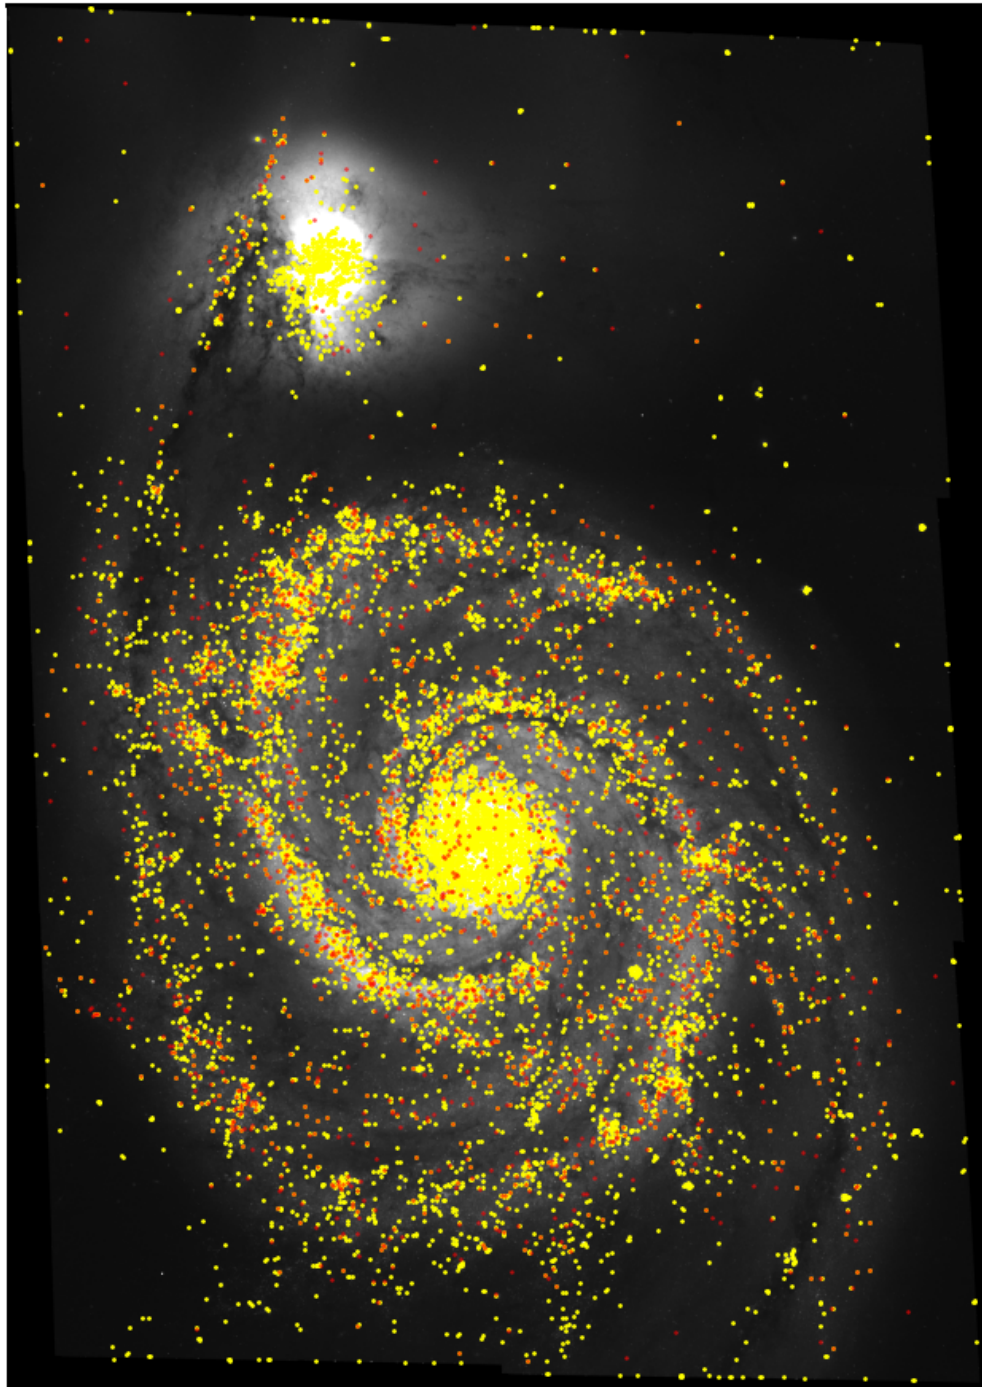
Sukurtas konvoliucinis neuroninis tinklas apmokytas su 20000 apmokymams sugeneruotų stebėjimo kadru. Apmokymas vykdomas dviem variantais - klasifikuojant kadrus į dvi kategorijas pagal tai, ar jame aptinkamas žvaigždžių spiečius, ir į septynias kategorijas pagal žvaigždžių spiečiaus plotį. Pirmuoju atveju tinklas pasiekia 97% dirbtinių duomenų aibės klasifikavimo (spiečiaus atpažinimo) tikslumą, antruoju atveju (spiečiaus atpažinimo ir klasifikavimo) - 73%. Pastebimas kadru painiojimas su kadrais, turinčiais viena kategorija didesnę ar mažesnę spiečių. Nepaisant to, tinklas dažniausiai teisingai nustato kategoriją. Kartais kadrai su spiečiais palaikomi tuščiais kadrais. Taip pat pastebimas ir atvirkščias efektas - tušti kadrai palaikomi kadrais su spiečiais. Tai galėtų sukelti sintetinių kadru generavimo metu naudojamo fono imties regiono pasirinkimas - tinklas išmoksta tankius laukus su sunkiai išskiriamais pavieniais objektais, kurie sudaro didžiąją dalį minėto regiono, klasifikuoti kaip tuščius kadrus. Dėl to paties efekto tinklas gali išmokti ir tuščius kadrus su pasitaikiusiais



12 pav. Spiečių iš Hwang ir Lee katalogo vidutinio profilio puspločio kiekvienai kategorijai ir tinklo priskirtos kategorijos standartinio nuokrypio medianos pasiskirstymas. Tiesė žymi aproksimuotą koreliaciją. Koreliacijos koeficientas - 0,078

objektais fone priskirti kadrams su spiečiumi.

Sukurti ir suklasifikuoti 2224 M51 galaktikos spiečių kadrai iš Hwang ir Lee katalogo. Pirmuoju atveju 99% jų tinklas atpažįsta kaip kadrus su spiečiais, antruoju - 85%. Jiems priskiriama kategorija koreliuoja su jų profilio puspločiu.



13 pav. M51 nuotrauka V filtre. Geltonais taškais pažymėti neuroniniu tinklu aptikti spiečiai, raudonais taškais pažymėti spiečiai iš Hwang ir Lee katalogo.

7 Išvados

1. Dirbtiniais duomenimis apmokytas konvoliucinis neuroninis tinklas pasiekia 73% spiečių aptikimo ir klasifikavimo pagal dydį tikslumą.
2. Neuroniniu tinklu suklasifikuotas visas M51 galaktikos nuotraukos laukas, rastos 8935 potencialių spiečių padėtys (esamame kataloge pateikti 2224 spiečiai).
3. Neuroninis tinklas 85% M51 spiečių iš Hwang ir Lee katalogo atpažįsta kaip kadrus su spiečiais. Nustatyta spiečių profilio puspločio ir priskiriamos kategorijos koreliacija.

Literatūra

- [1] Li Z., Yang W., Peng S., Liu F., A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects, 2020, arXiv:2004.02806
- [2] Hausen, R. ir Robertson, B. E., Morpheus: A Deep Learning Framework For Pixel-Level Analysis of Astronomical Image Data, 2019, arXiv:1906.11248
- [3] Bialopetravičius, J., Narbutis, D., ir Vansevicius, V., Deriving star cluster parameters with convolutional neural networks. I. Age, mass, and size, 2019, A&A, 621, A103
- [4] Bialopetravičius J. ir Narbutis D., Deriving star cluster parameters with convolutional neural networks. II. Extinction and cluster-background classification, 2020, A&A, 633, A148, 17
- [5] Bialopetravičius J. ir Narbutis D., Study of Star Clusters in the M83 Galaxy with a Convolutional Neural Network, 2020, AJ, 160, 264
- [6] Castro-Ginard ir kt., Hunting for open clusters in Gaia DR2: 582 new open clusters in the Galactic disc, 2020, A&A, 635, A45
- [7] Domínguez Sánchez H., Huertas-Company M., Bernardi M., Tuccillo D., Fischer J., L., Improving galaxy morphologies for SDSS with Deep Learning, 2018, MNRAS, 476, 3661
- [8] Pérez ir kt., STARNET: Machine Learning for Star Cluster Identification, 2021, ApJ, 907, 100
- [9] Yan Z., Mead A. J., Van Waerbeke L., Hinshaw G., McCarthy I. G., Galaxy cluster mass estimation with deep learning and hydrodynamical simulations, 2020, arXiv:2005.11819
- [10] Wei W. ir kt., Deep transfer learning for star cluster classification: I. application to the PHANGS-HST survey, 2020, MNRAS, 493, 3178–3193
- [11] Teimoorinia ir kt., Assessment of Astronomical Images Using Combined Machine-learning Models, 2020, AJ, 159, 170
- [12] Villavicencio-Arcadia E., Navarro S.G., Corra L.J., Application of Artificial Neural Networks for the Automatic Stellar Spectral Classification, 2020, ASPC, 522, 401
- [13] Krastev P. G., Real-time detection of gravitational waves from binary neutron stars using artificial neural networks, 2020, PhLB, 803, 135330
- [14] Fluke C. J. ir Jacobs C., Surveying the reach and maturity of machine learning and artificial intelligence in astronomy, 2019, arXiv:1912.02934
- [15] Lada C. J. ir Lada E. A., Embedded Clusters in Molecular Clouds, 2003, ARA&A, 41, 57

- [16] ESA, S. Beckwith (STScI) ir Hubble Heritage Team (STScI/AURA)
- [17] Kelley, H., J., Gradient theory of optimal flight paths, 1960, ARS Journal, 30 (10), 947-954
- [18] Takáts, K. ir Vinkó, J., Distance estimate and progenitor characteristics of SN 2005cs in M51, 2006, MNRAS, 372, 1735-1740
- [19] Bik A., Lamers H. J. G. L. M., Bastian N., Panagia N., Romaniello M., Clusters in the inner spiral arms of M51: The cluster IMF and the formation history, 2003, A&A, 397, 473
- [20] Messa M., ir kt., The young star cluster population of M51 with LEGUS - I. A comprehensive study of cluster formation and evolution, 2018, MNRAS, 473, 996
- [21] Messa M., ir kt., The young star cluster population of M51 with LEGUS - II. Testing environmental dependences, 2018, MNRAS, 477, 1683
- [22] Mutchler ir kt., Hubble Space Telescope multi-color ACS mosaic of M51, the Whirlpool Galaxy, 2005, AAS, 37, 2
- [23] Abadi M., ir kt., TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems, 2016, arXiv:1603.04467
- [24] Kingma, D.P., ir Ba, J., Adam: A Method for Stochastic Optimization, 2014, arXiv:1412.6980
- [25] Glorot, X., ir Bengio, Y., Understanding the difficulty of training deep feedforward neural networks, 2010, PMLR, 9, 249
- [26] Hwang, N., ir Lee, M., G., A Catalog of Bright Star Clusters in the Interacting Galaxy M51, 2008, AJ, 135, 1567

M51 GALAKTIKOS SPIEČIŲ TYRIMAS KONVOLIUCINIAIS NEURONINIAIS TINKLAIS

Dalius Janonis

Santrauka

Per pastarąjį dešimtmetį padidėję kompiuterių skaičiavimo greičiai padarė konvoliucinius neuroninius tinklus plačiai prieinamus ir naudojamus įvairiose mokslo ir technologijų srityse. Neuroniniai tinklai taip pat sėkmingai taikomi astronomijoje aptinkant ir klasifikuojant galaktikas, žvaigždžių spiečius ir žvaigždes. Šio darbo tikslas yra sukurti ir panaudoti konvoliucinių neuroninių tinklų pagrindu veikiančią algoritmą klasifikuoti daugiabanges M51 galaktikos nuotraukas. Kadrai klasifikuojami pagal tai, ar juose yra aptinkamas spiečius, ir aptikto spiečiaus plotį.

Užduotys:

- Sugeneruoti dirbtinius kadrus neuroninio tinklo apmokymui.
- Apmokyti neuroninį tinklą.
- Patikrinti dydžio nustatymo tikslumą su dirbtiniais testavimui sukurtais duomenimis.
- Suklasifikuoti M51 galaktikos spiečius.

Spiečiui apmokyti ir testuoti sugeneruota po 20000 dirbtinių stebėjimo kadru. Tinklas apmokomas ir pasiekia 73% tikslumą klasifikuojant dirbtinių stebėjimo duomenų imtį. 85% M51 galaktikos spiečių iš Hwang ir Lee (2008) katalogo suklasifikuojami kaip spiečiai. Stebima spiečių profilio puspločio ir priskiriamo dydžio koreliacija.

ANALYSIS OF CLUSTERS IN THE M51 GALAXY USING CONVOLUTIONAL NEURAL NETWORK

Dalius Janonis

Summary

Advancements in computing in the last decade have made the use of machine learning readily available in many scientific and technological fields, including astronomy. Convolutional neural networks are presently widely used in classifying and detecting galaxies, stellar clusters and stars. The aim of this work is to construct and apply a convolutional neural network to classify multi-band images of the M51 galaxy, based on whether the frame contains a stellar cluster and found cluster's parameters.

Tasks:

- Generate artificial frames to train the neural network.
- Perform the training of the neural network.
- Analyze the classification precision on dedicated artificial data.
- Classify the M51 cluster sample.

Conclusions:

20000 artificial images are generated for training and testing the neural network. The network is trained successfully and manages to reach 73% accuracy in classifying artificial data. 85% of M51 clusters from a catalogue by Hwang and Lee (2008) are classified as clusters. Clusters display a correlation between their catalogue-based FWHM and neural network-determined σ .