

---

Anđelina Maksimović i Elena Sladojević

## Klasifikacija morfologije galaksija konvolucionim neuronskim mrežama

---

*Cilj ovog rada je morfološka klasifikacija galaksija upotrebom mašinskog učenja. Podela galaksija na diskolike, izrazito eliptične, blago eliptične, sferne i spiralne, u osnovi je bazirana na klasifikacionoj shemi koju je postavio Edvin Hubble 1925 godine. U cilju klasifikacije galaksija na ovih pet kategorija konstruisana su i trenirana tri različita modela dubokog učenja: rezidualna neuronska mreža, konvoluciona mreža sa 14 slojeva i VGG16 neuronska mreža. Poređene su preciznosti i odzivi ova tri modela. Modeli su trenirani i testirani na bazi Galaxy Zoo (Lintott et al. 2008), filtriranoj tako da se sastoji samo od slika za koje je jasno izraženo kojoj kategoriji galaksije pripadaju. U cilju proširenja baze izvršen je niz transformacija postojećih slika iz tako filtrirane baze. Najbolji rezultati su postignuti rezidualnom neuronskom mrežom sa tačnošću od 88.0%, a potom slede neuronska mreža VGG16 sa tačnošću 86.7% i jednostavni konvolucionim model sa 14 slojeva sa tačnošću 85.6%.*

---

### Uvod

Moderni istraživači danas pokušavaju da odgovore na mnoga pitanja astronomije koristeći neke od najnaprednijih naučnih instrumenata kao što su teleskopi, kako u optičkom, tako i u drugim spektralnim domenima. Međutim, savremene opservatorije posmatranjem uspevaju da prikupe ogromne količine podataka, čak do nekoliko PB tokom jedne noći. Od 2000. godine SDSS (Sloan Digital Sky Survey) je prikupio

više podataka nego što je prethodno bilo dostupno u celoj istoriji astronomije (Albaret et al. 2017). Naučnici koji se bave analizom prikupljenih podataka ovog projekta kao najteži problem (u smislu težine rada stručnjaka) identifikuju problem morfološke klasifikacije galaksija, jer „ručna“ klasifikacija, koju su do sada radili astronomi, a koja je neophodna za automatizaciju, jako dugo traje na tolikoj količini podataka. Automatizacija rešavanja ovog problema je takođe kompleksna i klasične metode automatske obrade podataka nemaju zadovoljavajuće rezultate. Zbog toga se u ovoj oblasti pojavila potreba za razvijanjem metoda obrade slike primenom mašinskog učenja.

### Hablov klasifikacioni dijagram

Godinama se smatralo da su svi objekti koji su vidljivi na nebu deo jednog sistema, naše galaksije. Svakako je postojala ideja da možda i postoje zvezdani sistemi izvan našeg, ali za to nije bilo nikakvog dokaza jer nisu postojali dovoljno veliki teleskopi kojima bi se to potvrdilo. Prvi koji je, pomoću 2.5 metarskog teleskopa, uočio postojanje galaksija daleko izvan granica naše galaksije, je bio američki astronom Edvin Hubble (Edwin Hubble 1889-1953) 1924. godine. Samo godinu dana kasnije, 1925. godine, on postavlja dijagram za klasifikaciju galaksija po obliku (Hablov dijagram), poznati i kao Hablova viljuška (Hubble tuning fork), koji predstavlja prvu klasifikaciju galaksija.

---

*Anđelina Maksimović (2002), Kragujevac, učenica 2. razreda Prve kragujevačke gimnazije*

*Elena Sladojević (2001), Beograd, učenica 3. razreda Matematičke gimnazije u Beogradu*

### MENTORSTVO:

*Vladimir Ranković, Microsoft Development Center Serbia, softverski inženjer*

*Miloš Stojanović, TomTom d.o.o Beograd, Data Scientist*

*Sofija Petrović, studentkinja Elektrotehničkog fakulteta Univerziteta u Beogradu*

Galaksije predstavljaju gravitaciono vezane sisteme sastavljene od velikog broja zvezda, gasa, prašine, i tamne materije. Njihovo formiranje traje milijardama godina, stoga njihova morfologija (oblik i vizuelna pojava) astronomima daje podatke o formiranju i evoluciji same galaksije. Sve galaksije Habla deli na tri osnovna tipa; eliptične, spiralne (sa prečkom i bez nje) i nepravilne.

1. **Eliptične galaksije**, kategorija galaksija vidno eliptičnog oblika, koje za razliku od spiralnih galaksija nemaju nikakvu priznaku rotacione strukture u obliku (Vukićević-Karabin i Atanacković 2004). Predstavljaju homogene, spororotirajuće zvezdane sisteme u obliku trosnog elipsoida. Na osnovu spljoštenosti lika, ( $0 < n < 7$ ), svrstavaju se u osam podgrupa od skoro sfernih (E0, slika 1) koje su u ovom radu identifikuju kao kategorija sfernih galaksija, do najspljoštenijih (E7), od kojih se podgrupa E3 u ovom radu identifikuje kao kategorija blago eliptičnih i E7 kao kategorija izrazito eliptičnih galaksija. Spljoštenost lika galaksije  $n$  se računa kao najbliži ceo broj izraza  $10(1 - b/a)$ , pri čemu su  $a$  i  $b$  velika i mala poluosa eliptičnog lika galaksije. Orbite zvezda u ovim galaksijama su izdužene. Brže zvezde mogu putovati na dužim relacijama pre nego ih gravitacija okrene u suprotnom smeru, što kao rezultat daje izduženu osu eliptične galaksije u smeru u kojem se ove zvezde kreću. Raspon veličine eliptičnih galaksija varira od retkih ogromnih galaksija veličine od par hiljada kiloparseka do veoma malih patuljastih galaksija do 0.3 kpc. Kiloparsek (kpc) je merna jedinica koja odgovara razdaljini dužine 3260 svetlosnih godina. Koncentracija zvezda kod ove kategorije opada ka njihovoj periferiji. Takođe je otkriveno da u njima ima jako malo hladne međuzvezdane materije, dok su prisutne velike količine međuzvezdanog gasa. Sadrže znatno manje prašine i gasa nego spiralne i nepravilne galaksije.

2. **Spiralne galaksije**, kategorija galaksija koje u sebi sadrže podsisteme u vidu najpre diska sa elipsoidnim ispupčenjem u kome se nalazi kompaktno jezgro (Vukićević-Karabin i Atanacković 2004). U sredini galaksije sadrže centralni oval galaksije koje predstavlja gusto grupisane zvezde u njihovom centru. Dobile su naziv po strukturama koje se protežu od centralnog ovala

ka obodu galaktičkog diska gradeći spiralne grane galaksije. Spiralne grane galaksije sadrže ogromne količine međuzvezdane materije, koje samim tim ima znatno više u ovoj kategoriji nego u kategoriji eliptičnih galaksija. Prema veličini centralnog ovala i razvijenosti spiralnih grana dele se na tri osnovna podtipa: sa masivnim središtem i tek naznačenim spiralnim granama (Sa, slika 1), sa znatno manjim središtem i razvijenim granama (Sb) i sa izraženim spiralnim granama koje polaze iz vrlo malog središta (Sc).

**Spiralne galaksije sa prečkom**, posebna kategorija spiralnih galaksija koje u disku imaju izraženu prečku, odnosno izraženu strukturu od koje ka obodu kreću spiralne grane. Na slici 1 označene su sa SB (gde B potiče od eng. bar što znači prečka). Kroz istoriju univerzuma se odnos broja spiralnih galaksija bez prečke i sa prečkom znatno promenio. Pre 8 milijardi godina samo 10% ukupnog broja spiralnih galaksija su zauzimala spiralne galaksije sa izduženom centralnom strukturom, dok danas ove galaksije čine dve trećine klase spiralnih, i kao takve se izdvajaju kao zasebna kategorija. Veruje se da i naša galaksija, Mlečni put, takođe spada u kategoriju spiralnih galaksija sa prečkom. Takođe su spiralne galaksije i trenutno najbrojnije u univerzumu. One zauzimaju 60% ukupnog broja svih galaksija. Sve spiralne galaksije, i sa prečkom i bez nje, su u ovom radu klasifikovane kao kategorija spiralnih galaksija.

Postoje i galaksije koje su po obliku svrstane između eliptičnih i spiralnih galaksija (S0, slika 1). One nemaju spiralne grane (ili se bar ne vide), ali sadrže disk sa velikim centralnim ispupčenjem u kome su pretežno stare zvezde (Vukićević-Karabin i Atanacković 2004). U ovom radu su galaksije koje su forma između eliptičnih i spiralnih kategorija, svrstane u zasebnu kategoriju diskolikih galaksija.

3. **Nepravilne galaksije**, kategorija galaksija koje nemaju tačno definisan oblik ili nekakvu pravilnost u njemu, kao prethodne kategorije. Nemaju jak sjaj pa su poznate samo one bliže (Vukićević-Karabin i Atanacković 2004). Od svih navedenih tipova ove galaksije sadrže najviše zvezdane međumaterije – gasa i prašine. One zauzimaju nešto manje od četvrtine ukupnog broja galaksija u univerzumu. Za njih se smatra da su nekada bile spiralne ili eliptične, i da

je vremenom došlo do njihove deformacije usled gravitacione interakcije sa drugim galaksijama. Takođe, imaju jako malu masu. Masa prosečne galaksije ove kategorije iznosi otprilike jednu desetinu ukupne mase Mlečnog puta. Zbog jako male količine podataka o ovoj kategoriji, u vidu slika, u ovom radu se njihova klasifikacija ne vrši.

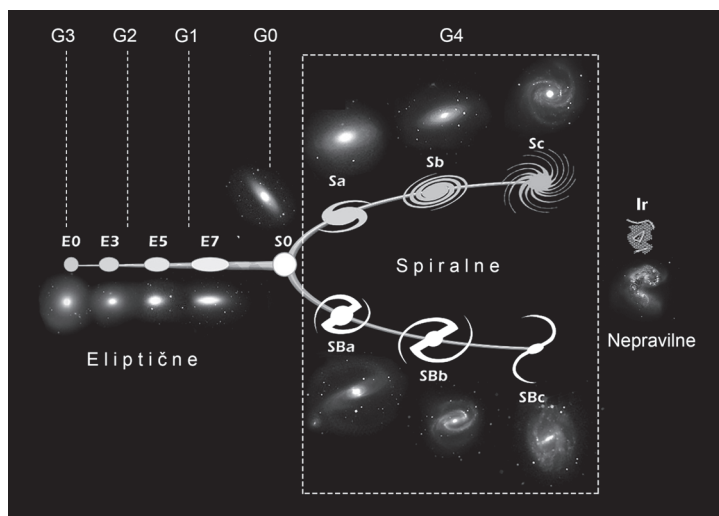
## Cilj

Osvrćući se na prethodno navedenu podelu, ali i vizuelne karakteristike koje su lakše prepoznatljive na slikama (i samim tim pogodnije za učenje neuronskim mrežama), galaksije su podeljene u 5 izmenjenih klasa, po uzoru na referentni rad (Dai i Tong 2019) i to: diskolike (G0), izrazito eliptične (G1), blago eliptične (G2), sferne (G3) i spiralne (G4). Kategorija G0 se nalazi između grupa 1 i 2 Hablove klasifikacije, kategorije G1-G3 spadaju u Hablovu grupu 1 (eliptične galaksije), G4 obuhvata oba tipa spiralnih (Hablova grupa 2), dok je grupa 3 (nepravilne galaksije) izostavljena zbog nedostatka karakterističnih morfoloških odlika (slika 1). Ovaj rad se bavi ispitivanjem uspešnosti klasifikacije galaksija po obliku na ovih pet kategorija. Klasifikovanje se vrši različitim modelima konvolucionih i rezidualnih neuronskih mreža, na filtriranoj bazi.

Pre no što se pristupilo klasifikaciji galaksija, urađena je obrada slika radi proširenja gustine informacija, skraćanja vremena treniranja mreže i odstranjivanja šuma, kao i u cilju povećanja broja primeraka slika u bazi. Cilj je bio dizajn i treniranje optimalne arhitekture: rezidualne neuronske mreže, jednostavnog konvolucionog modela sa 14 slojeva i VGG16 neuronske mreže, te poređenje tačnosti, odziva i preciznosti klasifikacije ova tri modela. Porede se i performanse različitih hiperparametara mreže. Klasifikacija je vršena na podskupu originalne baze, koji se sastoji samo iz slika na kojima je jasno izraženo kojoj kategoriji pripada galaksija sa slike.

## Baza podataka

Baza podataka koja je korišćena potiče od Galaxy Zoo projekta (Lintott *et al.* 2008), koji predstavlja anketu tipa stabla odlučivanja. Ovom anketom je tokom 175 dana nešto više od 100 hiljada ispitanika klasifikovalo SDSS galaksije. Na taj način je svaku od SDSS galaksija, odgovorima na pitanja akete, klasifikovalo u proseku 38 ispitanika. Procenjeno je da se navedeni način klasifikovanja, uz pomoć dobrovoljaca i jednostavnih pitanja, poklapa sa mišljenjem stručnih astronoma u 98% slučajeva, gde se 2% smatra za neminovnu grešku usled nesavršenosti ljudske percepcije (Beck *et al.* 2018). Ovako klasifi-



Slika 1. Klasifikacija galaksija na osnovi Hablovog klasifikacionog dijagrama. Sa G su označene grupe korišćene u ovom radu. (adaptirano prema <https://commons.wikimedia.org/wiki/File:HubbleTuningFork.jpg>)

Figure 1. Galaxy classification based on Hubble Tuning Fork. G is used to denote groups used in this paper. (Adapted from <https://commons.wikimedia.org/wiki/File:HubbleTuningFork.jpg>)

kovana baza sastoji se od preko 60 hiljada slika dimenzija  $424 \times 424$  piksela, pri čemu za slike nije eksplicitno navedeno kojoj kategoriji pripada koja od galaksija, već je svakoj pojedinačno priložen broj glasova (odgovora) ispitanika na 37 pitanja ankete. U našem radu, postavljanjem granica i uslova za pripadnost određenoj klasi sve slike su labelirane na pet kategorija (diskolike, izrazito eliptične, blago eliptične, sferne i spiralne – slika 2). Na svakoj slici je galaksija koja se posmatra u centru, a oko nje je crnilo ili druga nebeska tela i strukture.

## Filtriranje i podela filtrirane baze

Baza je filtrirana po uzoru na referentni rad (Dai i Tong 2019) da bi se omogućilo poređenje rezultata. Iz nje su izbačene sve slike čiji oblik nije jasno pripadao ni jednoj od klasa, i na taj način su izdvojene 28793 slike iz baze, kao galaksije idealnih oblika. Primenom klasifikacionih uslova (tabela 1) baza je u ovom slučaju podeljena na 5 kategorija predviđenih za klasifikaciju:

diskolike, izrazito eliptične, blago eliptične, sferne i spiralne. Brojevi kojima su određeni uslovi predstavljaju verovatnoću da je na odgovarajuće pitanje dat traženi odgovor, tj. udeo ukupnog broja ispitanika koji su smatrali da slika ima određenu karakteristiku.

Očekuje se znatno veća preciznost klasifikacije ovako preuređene baze, jer će mreža moći mnogo bolje da nauči osobine oblika iz kategorija gde nema loših slika sa nedefinisanim oblicima koji se onda ne mogu jasno rasporediti u predodređene pet klase. Što se tiče raspodele slika po setovima, oko 80% svake klase je predodređeno za trening, 10% za validaciju i 10% za test (tabela 2).

## Metod

### Augmentacija slika


Prvo su slike isečene do dimenzija  $150 \times 150$  piksela. Nakon toga je izvršen downsampling

Tabela 1. Filtriranje i labeliranje slika filtrirane baze

Kategorija	Naziv kategorije	Uslovi (Dai i Tong 2019)	Spljoštenost	Broj primeraka
G0	Diskolike	feature disk $\geq 0.430$ edge on, yes $\geq 0.602$	–	3903
G1	Izrazito eliptične	smooth $\geq 0.469$ cigar shaped $\geq 0.50$	$n = 7$	579
G2	Blago eliptične	smooth $\geq 0.469$ in between $\geq 0.50$	$n = 3$	8069
G3	Sferne	smooth $\geq 0.469$ completely round $\geq 0.50$	$n = 0$	8436
G4	Spiralne	feature disk $\geq 0.430$ edge on, no $\geq 0.715$ spiral, yes $\geq 0.50$	–	7806

Tabela 2. Raspodela isfiltrirane baze na trening, validacioni i test set

Set	Klasa					Ukupno
	G0	G1	G2	G3	G4	
Trening set	3143	467	6440	6742	4248	23040
Validacioni set	382	61	801	854	790	2888
Test set	378	51	828	837	768	2865



Slika 2. Primeri slika iz baze, tipovi galaksija prema obliku: G0 – diskolike G1 – izrazito eliptične, G2 – blago eliptične, G3 – kružne, G4 – spiralne.

Figure 2. Image examples from the dataset: disc – G0, extremely elliptical – G1, slightly elliptical – G2, spherical – G3, spiral – G4.

(umanjenje broja piksela) slika do dimenzija  $64 \times 64$  piksela kao i u referentnom radu (Dai i Tong 2019). Kako su kategorije galaksija invarijantne na rotaciju, translaciju, osvetljenost i mnoge druge parametre, sa slikama su vršene sledeće operacije, kako bi i sama mreža naučila takvu invarijantnost:

1. Rotacija za nasumičan ugao od  $0^\circ$  do  $180^\circ$
2. Osnosimetrično preslikavanje po  $x$  i  $y$  osi
3. Zumiranje za nasumičnu vrednost u opsegu od 0.8 do 1.2
4. Menjanje osvetljenosti od 1 do 2 puta po intenzitetu

## Konvolucione neuronske mreže

Sve neuronske mreže pa i konvolucione, sastavljene su od neurona, jednostavnih adaptivnih jedinica koje su međusobno povezane i napravljene po uzoru na biološki nervni sistem.

Model svake neuronske mreže se sastoji od sledećih slojeva:

1. Ulazni sloj koji se sastoji od ulaznih neurona koji predstavljaju ulazne podatke
2. Skriveni sloj koji služi za procesiranje podataka (njegova složenost uglavnom utiče na ukupnu kompleksnost same mreže)
3. Izlazni sloj koji se sastoji iz izlaznih neurona koji daju izlaz iz celog sistema

Učenje koje se dešava u neuronskim mrežama zapravo predstavlja postepeno menjanje parametara mreže kako bi ona davala željeni izlaz za date ulazne podatke. Ovo menjanje parametara se vrši pomoću optimizatora, tj. algoritama čiji je cilj smanjenje funkcije greške. U ovom radu su korišćeni poznati SGD (stochastic gradient descent) i Adam algoritmi.

Konvolucione neuronske mreže (slika 4) pripadaju klasi dubokih neuronskih mreža. Najveću primenu imaju u analizi vizualnih podataka, najčešće slika, video zapisa itd. Razlika konvolucionih neuronskih mreža u odnosu na druge tipove arhitekture neuronskih mreža jeste u slojevima u kojima se vrši operacija matematičke konvolu-

cije, po kojoj su i dobile ime. Konvolucija je specijalna linearna operacija transformacije matrica pomoću filtera koji tokom konvolucije prolazi kroz matricu slike. Filter predstavlja operator sa težinama koje se optimizuju u procesu treniranja mreže u cilju smanjenja funkcije gubitaka. Funkcija gubitaka je funkcija oblika  $g(y, y')$ , gde je  $y'$  očekivani, odnosno ispravan izlaz, a  $y$  je dobijeni izlaz. Minimizacija funkcije gubitaka, odnosno greške, podrazumeva svođenje razlike između vrednosti  $y$  i vrednosti  $y'$  na najmanju moguću meru.

Kao izlaz konvolucionog sloja dobija se mapa karakteristika, koja je rezultat konvolucije pomenutim težinskim filtrima i primene nelinearnosti, kao što je aktivaciona funkcija Leaky ReLU. Izlaz iz  $k$ -tog konvolucionog sloja matematički se može prikazati sledećom jednačinom (Kim i Brunner 2016):

$$y^k = \sigma \left( \sum_m w_m^k * x_m + b^k \right) \quad (1)$$


U jednačini (1)  $y^k$  predstavlja izlaz iz konvolucionog sloja, tačnije  $k$ -tu mapu karakteristika po redu,  $\sigma$  je aktivaciona funkcija (u ovom slučaju Leaky ReLU),  $w_m^k$  filteri,  $*$  operacija konvolucije,  $x_m$  je ulaz u konvolucioni sloj (u našem slučaju slika) i  $b^k$  je pomeraj (eng. bias) koja predstavlja konstantnu vrednost koja se dodaje ulaznoj sumi.

Kao što je rečeno, ove mreže se razlikuju od običnih po tome što imaju više vrsta slojeva, i njima nije potrebno dovoditi projektovane karakteristike, već se mreža sama trenira učeći najbitnije karakteristike sa ulaznih podataka koje dobija. To su često slojevi za združivanje kao i slojevi maksimalne verovatnoće da je izlaz ono što je očekivano itd. Neki od najbitnijih slojeva svake konvolucione neuronske mreže su konvolucioni slojevi, pooling slojevi i potpuno povezani slojevi.

1. **Konvolucioni slojevi** su slojevi u kojima se vrši konvolucija slika različitim filterima, čiji se parametri tokom treniranja neprestano menjaju, sve dok ne dostignu vrednosti koje daju optimalne performanse filtriranja. Kako konvolucija predstavlja specijalnu vrstu linearnih operacija, može se predstaviti kao množenje matricom izabranih dimenzija čije se vrednosti tokom

treninga optimizuju. Funkcija ovih slojeva jeste učenje karakterističnih osobina ulaznih podataka, koje su bitne za izvršavanje zadatka mreže. Za konvolucione mreže je, generalno, karakterističan filter sa parametrima koji se optimizuju tokom učenja mreže u cilju smanjenja funkcije gubitka.

2. **Pooling slojevi** (slojevi za sažimanje) služe za smanjenje dimenzija matrice, odnosno smanjenje broja piksela slike (downsampling), i funkcionišu tako što najčešće uzimaju maksimalne (Max Pooling) ili srednje vrednosti (Average Pooling) svakog sledećeg pravougaonika matrice, određenog dimenzijama izabranog pooling filtera. Na slici 3 je prikazan primer sažimanja maksimumom, sa dimenzijama Max Pooling filtera  $2 \times 2$ . Sažimanje se generalno vrši tako što se polazna matrica podeli na onoliko delova koliko će iznositi broj piksela u novonastaloj matrici, i iz svakog dela uzima maksimalna vrednost piksela koja se upisuje kao odgovarajuća vrednost nove matrice. Average Pooling (sažimanje srednjom vrednošću) se vrši na isti

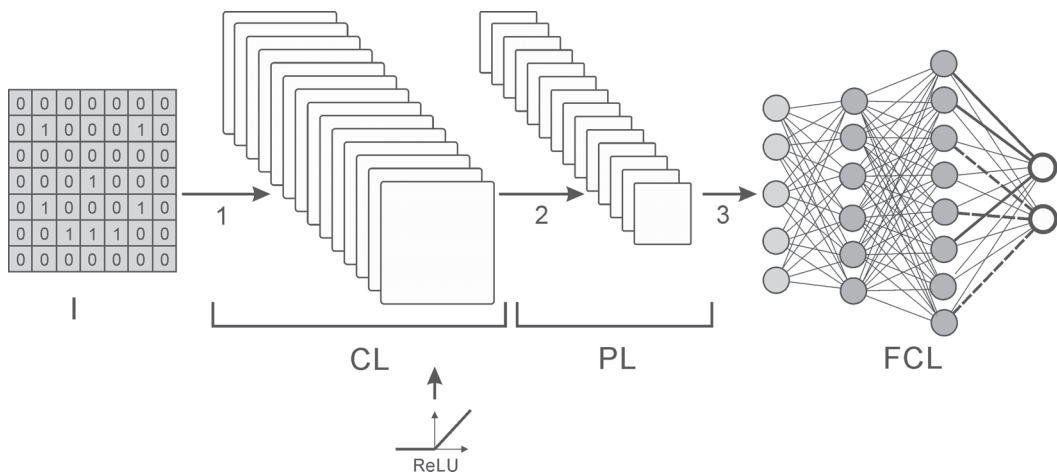


Slika 3. Primer rada Max Pooling filtra dimenzija  $2 \times 2$  na matrici dimenzija  $4 \times 4$

Figure 3. Example of Max Pooling layer size  $2 \times 2$  on a matrix size  $4 \times 4$

način, samo što se uzima srednja vrednost od svih vrednosti u tom delu polazne matrice.

3. **Potpuno povezani slojevi** (fully connected layers, FCL) se nalaze iza konvolucionih i pooling slojeva, i njihovi neuroni su povezani sa svim neuronima iz prethodnog sloja neuronske mreže. Prethodni sloj je kod konvolucionih mreža najčešće pooling sloj, radi smanjenja dimenzija, ali može biti i običan konvolucioni



Slika 4. Primer prolaska slike kroz jednostavnu konvolucionu neuronsku mrežu (adaptirano prema Ali 2019): Inp. – ulazna slika, CL – konvolucionni sloj, PL – sloj sažimanja, FCL – potpuno povezani sloj, Outp. – izlaz, 1 – konvolucija, 2 – sažimanje, 3 – konverzija u vektor.

Figure 4. An example of image flow throughout a simple convolutional neural network (adapted from Ali 2019): Inp. – input image, CL – convolutional layer, PL – pooling layer, FCL – fully connected layer, Outp. – output, 1 – convolution, 2 – pooling, 3 – flattening.


sloj, sve zavisi od arhitekture mreže. Kod potpuno povezanih slojeva je svaki neuron, vezama otežinjanim vrednostima koje su im dodeljene, povezan sa svim neuronima narednog sloja, dok je kod ostalih slojeva broj veza ograničen širinom filtera.

U procesu konvolucije (slika 4), najčešće se sukcesivno smanjuju prve dve vrednosti dimenzija matrice, dok se ređe dešava da one ostanu nepromenjene. Istovremeno se broj kanala matrice svakom novom konvolucijom povećava u cilju izduženja matrice i „pretvaranja” iste u vektor. S obzirom da su u ovom radu slike galaksija predstavljene trodimenzionalnim matricama početnih dimenzija  $424 \times 424 \times 3$ , one bi i kao takve bile spremne za operacije konvolucija kroz mrežu, ali im se ipak format još smanjuje, iz razloga koji su navedeni u odeljku o augmentaciji slika. Na slikama koje su posle augmentacije formata  $150 \times 150 \times 3$  piksela, konvolucija se vrši svakim novim slojem. Tokom svakog novog ciklusa treninga parametri se optimizuju do najbolje performanse filtriranja. To podrazumeva sakupljanje najbitnijih informacija sa slike o morfologiji galaksija, u cilju njihove klasifikacije.

## Rezidualne mreže

Unapređenje performansi neuronskih mreža se postiže njihovim produbljanjem, odnosno dodavanjem slojeva. Poznato je da mreža svakim novim slojem progresivno uči složenije karakteristike obeležja slika neke kategorije. Ipak, može se desiti i sasvim suprotno, ukoliko je mreža previše duboka. Neke od informacija, krećući se od sloja do sloja, usled brojnih parametara slojeva mogu se „zagubiti” u previše dubokoj mreži. Stoga se umesto produbljanja mreže dodavanjem novih konvolucionih slojeva, posle primene aktivacione funkcije dodaju rezidualni blokovi. Rezidualni blokovi se koriste u cilju prevencije od grešaka koje su vrlo česte u mrežama velike kompleksnosti. Oni koriste specifičnu vezu koja je funkcija identiteta i spaja svakih nekoliko slojeva. Na taj način se omogućava preskakanje slojeva koji transformišu ulazne vrednosti, sa ciljem da se ulazna informacija očuva neizmenjenom u slučaju greške (engl. skip connection identity mapping). Ovaj metod je jako koristan, pošto ne sadrži nikakve parametre koji bi bespotrebno zakomplikovali mrežu, već

jednostavno služi da prenese tačan izlaz iz prethodnog sloja sledećem sloju mreže. Ipak, nekada  $x$ , odnosno ulazni podaci koje treba proslediti sledećem sloju, i  $F(x)$ , odnosno izlazni podaci iz prethodnog sloja (slika 5), neće biti istih dimenzija.



Slika 5. Primer rezidualnog bloka

Figure 5. Example of the residual block

Razlika u dimenzijama između  $x$  i  $F(x)$  nije redak slučaj jer, kao što je navedeno, sama operacija konvolucije smanjuje dimenziju ulaznih slika u cilju njihovog pretvaranja u vektore. Zato se  $x$  množi linearnom projekcijom  $W$ , kako bi se proširio broj kanala u cilju podudaranja  $x$  i  $F(x)$  (He *et al.* 2016). Na taj način se omogućava da ulaz  $x$  i izlaz  $F(x)$  zajedno budu kombinovan ulaz za sledeći sloj, čime se izbegava da se bilo koji od njih ne prosledi, što bi se desilo kod predbukih mreža:

$$y = F(x, \{W_i\} + W_s x) \quad (3)$$

U jednačini (3) linearne projekcije  $W_i$  i  $W_s$  mogu se implementirati kao  $1 \times 1$  konvolucije.

Ovakvim načinom preskakanja veza između slojeva omogućava se prosleđivanje izlaza iz svih prethodnih slojeva poslednjem sloju u bloku. Dakle, rezidualni blokovi rade tako što se izlazne informacije iz prethodnog sloja dodaju sledećem sloju, pre primene aktivacione funkcije. Samim tim se ostvaruje treniranje dubokih mreža bez problema nastalih usled grešaka unutar samih slojeva mreže.

## Arhitektura mreža

Arhitektura prve mreže je rađena po uzoru na referentni rad (Kim i Brunner 2016) sa manjim izmenama. Za drugi model usvojena je arhitektura rezidualne duboke neuronske mreže po uzoru na referentni rad (Dai i Tong 2019).

### 1. Jednostavni konvolucioni model

Prvi model, čija je arhitektura navedena u tabeli P1 u prilogu, imao je 14 slojeva, od kojih su prva dva bila konvoluciona. U ulazni sloj dolaze podaci u vidu matrice dimenzija  $64 \times 64$ . Na njoj se vrši konvolucija prvobitno grupom od 32 filtera dimenzija  $5 \times 5$  bez paddinga (dopunjavanja). Dalje se kao što je prikazano u tabeli vrše konvolucije filterima različitih dimenzija ( $3 \times 3$ ,  $2 \times 2$ ) čije se vrednosti neprestano optimizuju tokom treninga. U cilju izbegavanja preteranog smanjenja prve dve vrednosti dimenzija slike, u nekim konvolucionim slojevima je prisutno dopunjavanje ivica jedinicama (padding). Kod svih konvolucionih slojeva koristi se korak 1, kao i ReLU aktivaciona funkcija koja se u većini referentnih radova pored Leaky ReLU pokazala kao efikasna. Koristi se *glorat uniform* inicijalizator, i bias se na početku inicijalizuje na 0.1. Između konvolucionih slojeva prisutni su i Max Pooling slojevi, uzimaju maksimum tako što filterom prolaze kroz matricu koja pristize iz prethodnog sloja i sa korakom 1 uzimaju maksimalnu vrednost matrice koja je trenutno u opsegu filtera. Na kraju su prisutna tri potpuno povezana sloja od kojih poslednji ima aktivacionu funkciju *softmax* i vraća verovatnoću da slika pripada svakoj od postojećih kategorija.

### 2. Rezidualna konvoluciona mreža

Drugi model mreže je rađen prema referentnom radu (Dai i Tong 2019). U njemu je upotrebljena arhitektura rezidualne mreže kao u tabeli P2 (prilog). Prvi deo mreže čine konvolucioni sloj veličine  $7 \times 7$ , BatchNormalization i Max Pooling ( $2 \times 2$ ). Ukratko, BatchNormalization predstavlja tehniku za treniranje jako dubokih neuronskih mreža, koja služi da standardizuje ulaze u slojeve. Samim tim, BatchNormalization čini rad mreže znatno bržim i stabilnijim. Ostatak mreže podeljen je u četiri rezidualna bloka slične građe. Svaki blok se sastoji od dva segmenta –



konvolucionog i identičkog. Identički blokovi u sebi imaju tri složena konvoluciona sloja sa kernelima  $1 \times 1$ ,  $3 \times 3$  i  $1 \times 1$  kao i BatchNormalization i aktivacionu funkciju. Razlika između rezidualnih segmenata i običnih konvolucionih je u tome što se u konvolucionim vrši down-sampling slika, tj. smanjenje broja piksela, dok se u identičkom segmentu to ne radi. U svakom od četiri bloka identički i konvolucioni segmenti se naizmenično smenjuju. Mreža se završava Average Pooling ( $2 \times 2$ ) i FC slojem sa SoftMax aktivacionom funkcijom sa pet klasa.

### 3. VGG16 konvoluciona mreža


VGG16 je konvoluciona neuronska mreža koju su 2014. patentirali Karen Simonyan i Andrew Zisserman sa Univerziteta za robotiku na Oksfordu. Ovaj model se smatra za najuniverzalniju mrežu za rešavanje problema u kompjuterskoj viziji i zbog toga je poreden sa druga dva modela koja su konkretno korišteni za prepoznavanje oblika galaksija. Arhitekture VGG16 je prikazana u tabeli P3 u prilogu.

## Rezultati

I filtrirana i originalna baza su podeljene u istoj razmeri na sledeće setove podataka: trening 80%, validacija 10% i test 10%. Trening set predstavlja deo podataka koji se koristi za samo učenje mreže i zbog toga čini većinu ukupnog broja slika. Validacioni set se koristi za kontrolu učenja tokom treniranja, tj. za proveru da se ne dešava overfitting. U ovo se uveravamo posmatranjem funkcija tačnosti tokom koraka učenja na trening i validacionom setu, koje bi trebalo obe da budu rastuće na globalnom nivou. Test set čine slike koje nisu imale dodira sa mrežom tokom treniranja, i koriste se za što preciznije procenu krajnje tačnosti modela.

#### 1. Jednostavni konvolucioni model.

Prvenstveno je praćen porast tačnosti i opadanja funkcije gubitka pri treningu na filtriranoj bazi. Na validacionim setu dobijena je tačnost od 85.6%. Na test setu takođe je dobijena tačnost od 85.6%. Matrica konfuzije data je na slici 6, a preciznost i odziv klasifikacije datog modela na test setu, po klasama, navedeni su u tabeli 3. Lako se uočava problem sa prepoznavanjem klase G1



Slika 6. Matrica konfuzije prvog modela (jednostavni konvolucioni model) na test setu

Figure 6. Confusion matrix of the first model (Simple Convolutional Model) on the test set


(izrazito eliptične galaksije), što je i očekivano zbog znatno manjeg broja ulaznih podataka za ovu klasu galaksija. Takođe, zbog njihove sličnosti sa diskolikim galaksijama, najvećim delom su svrstane u tu kategoriju.

Tabela 3. Preciznost i odziv klasifikacije jednostavnog konvolucionog modela, izražen u procentima

Mera	Klasa galaksija				
	G0	G1	G2	G3	G4
Preciznost	91.0	63.6	90.5	79.3	87.2
Odziv	92.1	13.7	70.3	93.8	94.8

2. **Rezidualna mreža.** Praćeno je opadanje funkcije gubitka i porast tačnosti pri treningu ovog modela na filtriranoj bazi. Ova mreža je postigla najbolje rezultate na validacionom setu – 88.0%, ali zbog tehničkih nemogućnosti nije dalje testirana.

3. **VGG16 mreže.** Na filtriranoj bazi je takođe praćeno opadanje funkcije gubitka i porast funkcije tačnosti na trening setu podataka filtrirane baze. Na validacionom setu podataka



Slika 7. Matrica konfuzije trećeg modela (VGG16) na test setu

Figure 7. Confusion matrix of the third model (VGG16) on the test set

dobijena je tačnost od 86.1%, dok je na test setu tačnost iznosila 86.7%. Matrica konfuzije data je na slici 7, a preciznost i odziv klasifikacije ovog modela na test setu u tabeli 4.

Tabela 4. Preciznost i odziv klasifikacije VGG16 (izraženi u procentima)

Mera	Klasa galaksija				
	G0	G1	G2	G3	G4
Preciznost	91.2	66.7	92.7	78.6	90.3
Odziv	93.6	7.8	70.3	96.0	96.2

## Završna diskusija

Pri menjanju aktivacionih funkcija tokom treniranja modela na manjim uzorcima baze pokazalo se da Leaky-ReLU funkcija ima bolje performanse od sigmoid i ReLU funkcije. Takođe, pokazala se neznatna razlika između Adam i SGD optimizacionih algoritama, pa je u daljem treniranju korišćen SGD. Mreže sa više slojeva su se pokazale kao preciznije, tj. duboka mreža sa rezidualnim slojevima se pokazala kao najbolja, posle koje sledi već poznati model neuron-

ske mreže – VGG16, dok se jednostavan model iz referentnog rada (Kim i Brunner 2016) pokazao kao najlošiji. Iako su dobijene razlike male – svega nekoliko procenata – rezidualna mreža ostvaruje najveći potencijal u daljem radu koji podrazumeva dodatnu optimizaciju parametara, augmentaciju slika u vidu promene kontrasta, saturacije, ekspozicije, rotacije i manipulaciju dodatnim slojevima. Takođe je primećena značajna razlika u vidu lošijeg performansa na klasi 1 (izrazito eliptične galaksije). To se objašnjava neujednačenošću podataka i značajno manjom zastupljenošću te klase u bazi, te stoga mreže nisu bile sposobne da nauče tu klasifikaciju. Što se tiče daljih unapređenja, proširivanje izvora originalnih slika, u smislu ujednačavanja broja trening podataka za svaku kategoriju, kao i preciznija podela i filtriranje baze bi dovelo do znatnog povećanja tačnosti klasifikacije.

**Zahvalnost.** Veliku zahvalnost dugujemo Nikolini Milanović sa programa astronomije ISP, za značajnu pomoć koja se odnosi na astronomske aspekte ovog rada.

## Literatura

- Albaret F. D., Allende Prieto C., Almeida A., Anders F., Anderson S., *et al.* 2017. The 13th Data release of the Sloan Digital Sky Survey: First spectroscopic data from the SDSS-IV survey mapping nearby galaxies at Apache Point Observatory. *The Astrophysical Journal Supplement Series*, **233** (2): 25.
- Ali A. 2019. Convolutional Neural Network (CNN) with Practical Implementation. <https://medium.com/machine-learning-researcher/convlutional-neural-network-cnn-2fc4faa7bb63>
- Beck M. R., Scarlata C., Fortson L. F., Lintott C. J., Simmons B. D. 2018. Integrating human and machine intelligence in galaxy morphology classification tasks. *Monthly Notices of the Royal Astronomical Society*, **476**: 5516.
- Dai J. M., Tong J. 2019. Galaxy Morphology Classification with Deep Convolutional Neural Networks. *Astrophysics and Space Science*, **364**: 55.
- He K., Zhang X., Ren S., Sun J. 2016. Deep residual learning for image recognition. U *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, str. 770-778.

Kim E. J., Brunner R. J. 2016. Star–galaxy classification using deep convolutional neural networks. *Monthly Notices of the Royal Astronomical Society*, **464** (4): 4463.

Lintott C. J., Kevin Schawinski K., Slosar A., Land K., Bamford S., *et al.* 2008. Galaxy Zoo: Morphologies derived from visual inspection of galaxies from the Sloan Digital Sky Survey. *Monthly Notices of the Royal Astronomical Society*, **389** (3): 1179.

Vukićević-Karabin M., Atanacković O. 2004. *Opšta astrofizika*. Beograd: Zavod za udžbenike

---

*Anđelina Maksimović and Elena Sladojević*

## Galaxy Morphology Classification Using Convolutional Neural Networks

The main aim of this paper is to efficiently solve the problem of dividing galaxies into distinct categories. The scientific background of the division is the Hubble Tuning Fork diagram established by Edwin Hubble, in which the galaxies are separated in different categories based on

their shape and appearance. The categories are simplified to the 5 following: disk, extremely elliptical, slightly elliptical, spherical and spiral. The initial dataset consisted of 60 000 images gathered by Sloan Digital Sky Survey, already classified by volunteers in the Galaxy Zoo project (Lintott *et al.* 2008). Due to the irrelevance of certain images, the dataset was filtered leaving only images that undeniably belong to one and only one of the 5 groups and eliminating images that picture a star or galaxies for which it can not clearly be sure where they belong. The more precise dataset contained 27 000 images and it was used to train and test networks. To provide the solution with the most accuracy, it was used to experiment with different models of the network and hyper parameters within the network itself. The models used were the simple Convolutional model with 11 layers, VGG16 Neural Network with 16 layers, and Residual Neural Network with 26 layers. Due to the complexity of CNN, the model was improved by adding Residual layers which reduce the mistakes that can occur among networks with numerous convolutional layers. The results showed that deeper networks result in better accuracy. The best result was achieved by ResNet with accuracy (88.0%) followed by VGG16 (86.7%) and CNN (85.6%).

# Prilog

Tabela P1. Arhitektura mreže prvog modela (jednostavni konvolucioni model, Kim i Brunner 2016)

Tip sloja	Filteri	Dimenzije filtera	Padding	Aktivaciona funkcija	Inicijalizacija težina veza	Inicijalizacija bias-a
Konvolucioni	32	$5 \times 5$	–	Leaky ReLU	glorat uniform	0.1
Konvolucioni	32	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	64	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	64	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	64	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	64	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	64	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	64	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Fully connected	2048	–	–	Leaky ReLU	glorat uniform	0.1
Fully connected	2048	–	–	Leaky ReLU	glorat uniform	0.1
Fully connected	5	–	–	Softmax	glorat uniform	0.1

Tabela P2. Arhitektura mreže drugog modela (rezidualna konvoluciona mreža, Dai i Tong 2019)

Tip sloja	Filteri	Dimenzije filtera	Padding	Aktivaciona funkcija	Inicijalizacija težina veza	Inicijalizacija bias-a
Konvolucioni	64	$7 \times 7$	–	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	128	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	128	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	128	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	128	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	256	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	256	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	1024	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	256	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	256	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	1024	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	512	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	2048	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	2048	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	1024	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	1024	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	4096	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	1024	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	1024	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	4096	$1 \times 1$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Fully connected	5	–	–	Leaky ReLU	glorat uniform	0.1

Tabela P3. Arhitektura mreže trećeg modela (VGG16)

Tip sloja	Filteri	Dimenzije filtera	Padding	Aktivaciona funkcija	Inicijalizacija težina veza	Inicijalizacija bias-a
Konvolucioni	64	$3 \times 3$	–	Leaky ReLU	glorat uniform	0.1
Konvolucioni	64	$3 \times 3$	–	–	–	–
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	128	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	128	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	256	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	256	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	256	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Konvolucioni	512	$3 \times 3$	1	Leaky ReLU	glorat uniform	0.1
Pooling	–	$2 \times 2$	–	–	–	–
Fully connected	4096	–	–	Leaky ReLU	glorat uniform	0.1
Fully connected	4096	–	–	Leaky ReLU	glorat uniform	0.1
Fully connected	5	–	–	Leaky ReLU	glorat uniform	0.1

