

Usporedba vektorizacija za klasifikaciju slika

Grgat, Šimun

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of Science / Sveučilište u Splitu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/um:nbn:hr:166:298234>

Rights / Prava: [In copyright/Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-11-24**

Repository / Repozitorij:

[Repository of Faculty of Science](#)



SVEUČILIŠTE U SPLITU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET

ZAVRŠNI RAD

Usporedba vektorizacija za klasifikaciju slika

Šimun Grgat

Split, Rujan, 2024.

Temeljna dokumentacijska kartica

Završni rad

Sveučilište u Splitu

Prirodoslovno – matematički fakultet

Odjel za informatiku

Ruđera Boškovića 33, 21000 Split Hrvatska

Usporedba vektorizacija za klasifikaciju slika

Šimun Grgat

SAŽETAK

Ovaj završni rad bavi se usporedbom različitih metoda vektorizacije i klasifikacije slika u alatu Orange. Korištena su tri postupka vektorizacije: Painters, InceptionV3 i Deeploc, kako bi se slike pretvorile u numeričke reprezentacije. Na ove vektore primijenjene su tri metode klasifikacije: logistička regresija, k najbližih susjeda (kNN) i neuronske mreže. Cilj rada je analizirati i usporediti performanse ovih kombinacija na temelju točnosti. Rezultati istraživanja pružaju uvid u optimalne kombinacije vektorizacije i klasifikacije za specifične zadatke u području klasifikacije slika.

Ključne riječi: logistička regresija, k najbližih susjeda (kNN), neuronske mreže, Painters, InceptionV3, Deeploc, Orange program, strojno učenje

Rad sadrži: 29 stranica, 11 grafičkih prikaza, izvornik je na hrvatskom jeziku

Mentor: doc. dr. sc. Saša Mladenović

Ocenjivači:

doc. dr. sc. Saša Mladenović, redoviti profesor, Prirodoslovno – matematički fakultet, Sveučilišta u Splitu

Nika Jerković, asistent, Prirodoslovno – matematički fakultet, Sveučilišta u Splitu

Antonela Prnjak, asistent, Prirodoslovno – matematički fakultet, Sveučilišta u Splitu

Rad prihvaćen: Rujan, 2024.

Basic documentation card

Final thesis

University of Split

Faculty of Science

Department of Informatics

Ruđera Boškovića 33, 21000 Split Croatia

Comparison of Vectorization Methods for Image Classification

Šimun Grgat

ABSTRACT

This final thesis deals with the comparison of different methods of image vectorization and classification using the Orange tool. Three vectorization methods were used: Painters, InceptionV3, and Deeploc, to transform images into numerical representations. These vectors were then classified using three methods: logistic regression, k-nearest neighbors (kNN), and neural networks. The aim of the thesis is to analyze and compare the performance of these combinations based on accuracy. The research results provide insight into the optimal combinations of vectorization and classification methods for specific tasks in image classification..

Keywords: logistic regression, k-nearest neighbors (kNN), neural networks, Painters, InceptionV3, Deeploc, Orange tool, machine learning

The paper contains: 29 pages, 11 graphics, the original is in Croatian

Supervisor: Saša Mladenović, PhD, Full Professor, Faculty of Science, University of Split

Evaluators:

Saša Mladenović, PhD, Full Professor, Faculty of Science, University of Split

Nika Jerković, Instructor, Faculty of Science, University of Split

Antonela Prnjak, Instructor, Faculty of Science, University of Split

Zahvala:

Zahvaljujem se svojoj obitelji koji su mi omogućili da uopće imam priliku studirati na ovom predivnom fakultetu i da dospijem do ovog krajnjeg cilja stjecanja diplome.

Zahvalu upućujem i svom voditelju dr. sc. Saši Mladenoviću na odličnom mentorstvu, potpori i svim savjetima koji su mi pomogli u izradi ovog rada.

Također želim zahvaliti i prijateljima, kolegama koji su učinili moje studiranje posebnim razdobljem u životu, što su mi uvijek bili podrška, te proživljavali sa mnom i neke predivne i neke ne baš tako lijepo trenutke.

Zahvalu također upućujem i svim djelatnicama referade koje su svojim toplim i srdačnim pristupom svaki problem rješavale bez ikakvog problema, te učinile svaki odlazak u referadu jednim zabavnim iskustvom.

Sadržaj

1. UVOD.....	6
1.1. Problem i motivacija.....	6
1.2. Cilj i zadaci rada	7
1.3. Struktura rada	7
2. PREGLED LITERATURE.....	7
2.1. Klasifikacija slika	7
2.2. Vektorizacija slika.....	8
2.3. Pregled korištenih metoda klasifikacije.....	9
2.4. Alati za analizu podataka.....	9
3. METODOLOGIJA	10
3.1. Opis skupa podataka	10
3.2. Implementacija metoda vektorizacije	10
3.3. Implementacija metoda klasifikacije	11
3.4. Evaluacija i usporedba metoda	12
4. REZULTATI I DETALJNA ANALIZA	16
4.1. k najbližih susjeda (kNN).....	16
4.2. Logistička regresija.....	19
4.3. Neuronske mreže	23
5. ZAKLJUČAK.....	27
6. LITERATURA	27
7. POPIS SLIKA	29

1. UVOD

Klasifikacija slika jedan je od najizazovnijih zadataka u području računalnog vida, s primjenama koje obuhvaćaju širok spektar domena, od prepoznavanja objekata do analize medicinskih slika. Ovaj zadatak postaje posebno složen kada se radi o velikom broju klasa i varijabilnosti unutar slika, kao što je slučaj s klasifikacijom pasmina pasa. Psi su jedna od najraznovrsnijih životinjskih vrsta, s više od 800 različitih pasmina koje se značajno razlikuju po fizičkim karakteristikama, što čini njihovu klasifikaciju izazovnim zadatkom. U ovom radu fokusirat ćemo se na klasifikaciju slika pasa koristeći skup podataka koji sadrži preko 20,000 slika, raspoređenih u 120 različitih pasmina. Cilj istraživanja je analizirati i usporediti učinkovitost različitih metoda vektorizacije i klasifikacije slika. Koristeći alat Orange Data Mining, istražit ćemo kako se različite metode vektorizacije, poput InceptionV3, DeepLoc i Painters, ponašaju u kombinaciji s različitim klasifikacijskim algoritmima poput logističke regresije, k najbližih susjeda (kNN) i neuronskih mreža. Rezultati ovog istraživanja pružit će uvid u optimalne kombinacije vektorizacije i klasifikacije za specifične zadatke u području klasifikacije slika pasa.



Slika 1 Orange data mining logo

1.1. Problem i motivacija

Klasifikacija slika pasa predstavlja izazov zbog velike varijabilnosti između različitih pasmina, ali i unutar iste pasmine, zbog različitih položaja, osvjetljenja i kvalitete slika. Postoji značajan interes za razvoj automatiziranih sustava za prepoznavanje pasmina pasa, bilo za potrebe veterinarske prakse, identifikacije pasa u skloništima ili čak za komercijalne aplikacije poput mobilnih aplikacija za prepoznavanje pasmina. Razvoj takvih sustava zahtijeva učinkovite

metode vektorizacije i klasifikacije koje mogu točno identificirati pasmine na temelju vizualnih informacija.

1.2. Cilj i zadaci rada

Cilj ovog rada je analizirati i usporediti različite metode vektorizacije i klasifikacije slika pasa te identificirati najbolje pristupe za postizanje visoke točnosti klasifikacije. Specifični zadaci rada uključuju:

Implementaciju tri metode vektorizacije: InceptionV3, DeepLoc i Painters.

Primjenu tri različita algoritma klasifikacije: logistička regresija, kNN i neuronske mreže.

Evaluaciju performansi svake kombinacije vektorizacije i klasifikacije na temelju točnosti.

Analizu rezultata i identifikaciju optimalnih metoda za klasifikaciju slika pasa.

1.3. Struktura rada

Rad je organiziran u nekoliko ključnih poglavlja. Nakon uvoda, u drugom poglavlju bit će prikazana relevantna literatura i teoretska podloga potrebna za razumijevanje korištenih metoda vektorizacije i klasifikacije. Treće poglavlje opisuje korištenu metodologiju, uključujući detalje o skupu podataka, procesima vektorizacije i klasifikacije te metodama evaluacije. U četvrtom poglavlju bit će prikazani rezultati istraživanja te njihova detaljna analiza i diskusija. Na kraju, u petom poglavlju, donosi se zaključak rada uz preporuke za buduće istraživanje.

2. PREGLED LITERATURE

2.1. Klasifikacija slika

Klasifikacija slika je ključno područje istraživanja u računalnom vidu, s ciljem automatskog prepoznavanja i kategorizacije objekata unutar slika. Različite metode klasifikacije slika evoluirale su kroz godine, počevši od jednostavnih ručnih tehniki ekstrakcije značajki do naprednih metoda temeljenih na dubokom učenju.

Klasične metode klasifikacije slika oslanjaju se na ručni inženjerинг značajki, gdje se specifične karakteristike slika, poput rubova, tekstura ili oblika, izvlače pomoću algoritama kao što su

SIFT¹ ili HOG². Te značajke zatim služe kao ulaz u algoritme strojnog učenja, poput SVM-a³ ili k najbližih susjeda (kNN).

Suvremeni pristupi, pogotovo oni bazirani na dubokom učenju, omogućili su automatsko učenje značajki iz sirovih slikevnih podataka, eliminirajući potrebu za ručnim odabirom značajki. Konvolucijske neuronske mreže (CNN) postale su dominantne u ovom području, omogućujući izgradnju vrlo preciznih modela koji se mogu skalirati na velike količine podataka i različite zadatke klasifikacije.

2.2. Vektorizacija slika

Vektorizacija slika odnosi se na proces pretvaranja vizualnih podataka u numeričke reprezentacije koje su pogodne za daljnju obradu pomoću algoritama strojnog učenja. Ovaj korak je ključan jer omogućava efikasnu analizu i klasifikaciju slike na temelju njenih značajki.

U ovom radu korištene su tri različite metode vektorizacije:

InceptionV3: InceptionV3 je napredni model konvolucijske neuronske mreže razvijen od strane Googlea, koji je postao standard u mnogim zadacima klasifikacije slika. Ovaj model koristi složenu arhitekturu koja uključuje višestruke filtere različitih dimenzija u paraleli, omogućujući ekstrakciju značajki na različitim skalama i razinama apstrakcije. InceptionV3 se često koristi za prijenosno učenje, gdje se predtrenirani modeli prilagođavaju specifičnim zadacima, kao što je klasifikacija pasmina pasa.

DeepLoc: DeepLoc je specijalizirani model dizajniran za preciznu lokalizaciju i klasifikaciju objekata unutar slike. Iako primarno razvijen za biološke aplikacije, ovaj model se može prilagoditi za različite zadatke vektorizacije, uključujući klasifikaciju slika pasa. DeepLoc koristi duboke neuronske mreže kako bi iz slike izvukao detaljne značajke koje omogućuju preciznu klasifikaciju.

Painters: Painters je metoda koja se temelji na tehnikama likovne umjetnosti, pokušavajući uhvatiti vizualne karakteristike slike koje su slične onima koje bi koristili umjetnici. Ova

¹ SIFT (Scale-Invariant Feature Transform) algoritam je tehnika računalnog vida koja se koristi za detekciju i opis značajki

² Histogram usmjerenih gradijenata (HOG) je metoda za izdvajanje značajki iz slike, koja ima mnoge primjene u računalnom vidu

³ Vektorski strojevi za podršku (SVM) su nadzirani modeli koji analiziraju podatke

metoda fokusira se na teksture, oblike i boje koje su izražene na sličan način kao što bi to radili slikari, što je korisno u zadacima gdje su vizualni detalji ključni za razlikovanje između različitih kategorija, poput pasmina pasa.

2.3. Pregled korištenih metoda klasifikacije

U svrhu klasifikacije vektoriziranih slika, u ovom radu korištene su sljedeće metode:

Logistička regresija je osnovna, ali moćna metoda nadziranog učenja koja se koristi za binarne klasifikacijske zadatke, a može se proširiti i na višeklasne probleme. U principu, logistička regresija procjenjuje vjerojatno da se neki događaj dogodi. Temelji se na linearnom modelu koji koristi sigmoidnu funkciju za modeliranje vjerojatnosti pripadnosti određenoj klasi. Zbog svoje jednostavnosti i interpretabilnosti, logistička regresija često služi kao početna točka u analizama klasifikacije.

kNN je jednostavna, ali učinkovita metoda nenadziranog učenja koja se temelji na sličnosti između točaka u prostoru značajki. Klasifikacija se provodi na temelju glasanja k najbližih susjeda ciljne točke, gdje k predstavlja broj susjeda koje uzimamo u obzir. Ova metoda je intuitivna i jednostavna za implementaciju, no može postati računalno zahtjevna kod većih skupova podataka.

Neuronske mreže: Neuronske mreže su složeni modeli inspirirani biološkim mozgom, sastoje se od slojeva povezanih "neurona" koji mogu učiti složene obrasce u podacima. U zadatku klasifikacije slika, konvolucijske neuronske mreže (CNN) se najčešće koriste zbog svoje sposobnosti da automatski uče relevantne značajke iz sirovih slikovnih podataka. CNN-ovi su se pokazali vrlo uspješnima u mnogim izazovima računalnog vida, uključujući klasifikaciju slika, detekciju objekata i segmentaciju.

2.4. Alati za analizu podataka

Za analizu i implementaciju metoda vektorizacije i klasifikacije, korišten je Orange, vizualni alat za podatkovnu analitiku i strojno učenje. Orange je sveobuhvatan softverski paket za strojno učenje i rudarenje podataka koji se sastoji od više komponenata. Razvijen je u Laboratoriju za bioinformatiku na Fakultetu računarstva i informatike Sveučilišta u Ljubljani, Slovenija, uz suradnju s otvorenom zajednicom programera. Orange omogućuje korisnicima izgradnju složenih modela za analizu podataka putem jednostavnog grafičkog sučelja, što olakšava eksperimentiranje i optimizaciju različitih algoritama.

Orange nudi širok spektar modula za strojno učenje, uključujući podršku za metode korištene u ovom radu, kao što su logistička regresija, kNN i neuronske mreže. Njegova fleksibilna struktura omogućava jednostavno povezivanje različitih dijelova analize, od vektorizacije slika do konačne klasifikacije i evaluacije rezultata. Zbog svoje jednostavnosti korištenja i snage u analizi podataka, Orange je postao popularan alat među istraživačima i stručnjacima u različitim područjima, uključujući bioinformatiku, obradu teksta i računalni vid.

3. METODOLOGIJA

3.1. Opis skupa podataka

Za potrebe ovog istraživanja korišten je skup podataka preuzet s platforme Kaggle, koja je popularna među istraživačima i entuzijastima u području strojnog učenja. Za preuzimanje podataka napravljen je račun na istoimenoj stranici. Skup podataka sadrži preko 20,000 slika pasa, razvrstanih u 120 različitih pasmina. Slike variraju u kvaliteti, rezoluciji i uvjetima snimanja, što dodatno otežava zadatku klasifikacije. Svaka slika pripada jednoj od definiranih pasmina, a veličina slike je standardizirana na unaprijed definiranu dimenziju kako bi se osigurala konzistentnost u procesu obrade.

Prije početka vektorizacije i klasifikacije, slike su prošle kroz nekoliko faza preprocesiranja, uključujući:

Promjena veličine (resize): Sve slike su promijenjene u standardnu dimenziju kako bi se omogućila dosljedna obrada kroz modele vektorizacije.

Normalizacija: Pikseli su normalizirani kako bi se smanjila varijabilnost među slikama i poboljšala efikasnost učenja.

Augmentacija: Kako bi se poboljšala generalizacijska sposobnost modela, slike su podvrgnute augmentaciji koja uključuje rotacije, translacije, promjene u svjetlini i kontrastu.

3.2. Implementacija metoda vektorizacije

U radu su korištene tri različite metode vektorizacije kako bi se iz slika izlučile relevantne značajke:

InceptionV3 model je korišten kao alat za duboko učenje u svrhu ekstrakcije značajki. Ovaj model je unaprijed treniran na velikom skupu slika (ImageNet)⁴ i prilagođen za potrebe ovog rada. Slike su prošle kroz ovaj model, a značajke su izdvojene iz predzadnjeg sloja mreže, koji sadrži visoko apstraktne reprezentacije slike.

DeepLoc je korišten za ekstrakciju specifičnih značajki koje mogu pomoći u preciznoj klasifikaciji slika. Ovaj model je prilagođen za prepoznavanje detalja koji su relevantni za određene pasmine pasa, kao što su specifične karakteristike dlake, oblike tijela i drugih vizualnih elemenata.

Metoda Painters koristi umjetnički pristup vektorizaciji, fokusirajući se na tekture, oblike i boje unutar slike. Ova metoda pokušava oponašati način na koji bi slikar vizualizirao i interpretirao sliku, što je korisno za prepoznavanje pasmina koje se mogu razlikovati po suptilnim vizualnim značajkama.

3.3. Implementacija metoda klasifikacije

Nakon što su značajke vektorizirane, primijenjene su tri različite metode klasifikacije kako bi se identificirala pasmina pasa:

Logistička regresija je jednostavna, ali učinkovita metoda za binarne klasifikacijske zadatke, često korištena zbog svoje interpretabilnosti i sposobnosti procjene vjerojatnosti pripadnosti određenoj klasi (Murphy, 2012). Model je treniran na vektoriziranim značajkama i evaluiran na testnom skupu podataka. Iako je jednostavna, logistička regresija može pružiti solidne rezultate kada su značajke dobro definirane.

kNN, ili algoritam k-najbližeg susjeda, algoritam je strojnog učenja koji koristi blizinu za usporedbu jedne podatkovne točke sa skupom podataka na kojima je obučen i koje je zapamtio za predviđanje. kNN metoda je korištena za klasifikaciju na temelju sličnosti između vektoriziranih slika. Različite vrijednosti k su testirane kako bi se utvrdila optimalna konfiguracija za ovaj zadatak. Iako kNN može biti računalno zahtjevan, pruža intuitivne rezultate koji se temelje na izravnoj usporedbi značajki.

Neuronske mreže su sredstvo za strojno učenje, u kojem računalo uči obavljati neki zadatak analizirajući primjere obuke. Konvolucijske neuronske mreže (CNN) su korištene kao

⁴ velika vizualna baza podataka dizajnirana za korištenje u istraživanju softvera za vizualno prepoznavanje objekata

naj sofisticiranija metoda klasifikacije. Modeli su trenirani na vektoriziranim značajkama, koristeći različite arhitekture i hiperparametre kako bi se postigla maksimalna točnost. Neuronske mreže su posebno pogodne za ovaj zadatak zbog svoje sposobnosti da prepoznaju složene uzorce unutar podataka. Konvolucijske neuronske mreže (CNN) postale su ključni alat u računalnom vidu jer omogućuju automatsko učenje značajki iz sirovih slikovnih podataka. Njihova struktura temelji se na korištenju slojeva konvolucijskih filtera koji omogućuju modelu da uči hijerarhijske reprezentacije slike, od jednostavnih rubova do složenijih struktura. CNN-ovi su posebno učinkoviti u zadacima klasifikacije slika zbog svoje sposobnosti da prepoznaju prostorne odnose između piksela unutar slike (Goodfellow, Bengio i Courville, 2016).

3.4. Evaluacija i usporedba metoda

Za evaluaciju performansi svake metode korišten je strukturiran postupak kako bi se osigurala pouzdanost i generalizabilnost rezultata:

Veličina skupa za treniranje: Skup podataka podijeljen je na skup za treniranje i skup za testiranje u omjeru 70:30, pri čemu je 70% podataka korišteno za treniranje modela, a preostalih 30% za testiranje.

Cross-validacija: Korištena je metoda k-struke (k-fold)⁵ cross-validacije s 5 foldova. Cross-validation omogućava pouzdanu procjenu performansi modela, smanjujući utjecaj potencijalne pristranosti u podjeli podataka. Svaki model je treniran i testiran pet puta, pri čemu se rezultati različitih foldova agregiraju kako bi se dobio prosječni performans modela.

Ponavljanje treniranja i testiranja: Kako bi se dodatno osigurala pouzdanost rezultata, postupak treniranja i testiranja je ponovljen 10 puta. Ova tehnika smanjuje utjecaj slučajnih varijacija u skupu podataka i osigurava stabilnije i reprezentativnije rezultate.

Evaluacijske metrike: Glavni kriteriji evaluacije bili su sljedeći:

- AUC (Area Under the Curve)

Definicija: AUC je mjera koja predstavlja površinu ispod ROC krivulje (Receiver Operating Characteristic). ROC krivulja prikazuje odnos između stope istinskih pozitivnih rezultata (True

⁵ Vrsta validacije gdje je originalni uzorak nasumično podijeljen u k poduzoraka jednakog veličine

Positive Rate - TPR, ili Recall) i stope lažnih pozitivnih rezultata (False Positive Rate - FPR) za različite pragove klasifikacije.

AUC pokazuje koliko dobro model razlikuje između različitih klasa. Vrijednost AUC-a može varirati od 0 do 1:

AUC = 1: Model savršeno razlikuje između klasa.

AUC = 0.5: Model ne razlikuje između klasa i jednako je dobar kao nasumično pogađanje.

AUC < 0.5: Model radi gore od nasumičnog pogađanja, što znači da je možda model zamijenio pozitivne i negativne primjere.

AUC je posebno koristan kada imamo neuravnotežene klase to jest kada je broj pozitivnih i negativnih primjera vrlo različit, jer pokazuje koliko dobro model može razlikovati pozitivne od negativnih primjera bez obzira na prag klasifikacije.

- CA (Classification Accuracy)

Točnost (Classification Accuracy) je omjer ispravno klasificiranih primjera, bilo pozitivnih ili negativnih, u odnosu na ukupan broj primjera u skupu podataka. Što znači da točnost mjeri koliko je model bio uspješan u ispravnom klasificiranju instanci, bez obzira na njihovu klasu.

CA = $(TP + TN) / (TP + TN + FP + FN)$, gdje su:

TP (True Positives): Broj ispravno klasificiranih pozitivnih primjera.

TN (True Negatives): Broj ispravno klasificiranih negativnih primjera.

FP (False Positives): Broj pogrešno klasificiranih pozitivnih primjera.

FN (False Negatives): Broj pogrešno klasificiranih negativnih primjera.

Točnost je intuitivna i lako razumljiva, ali može biti varljiva u slučaju neuravnoteženih klasa. Na primjer, ako imamo 99% negativnih i 1% pozitivnih primjera, model koji uvijek predviđa negativne može imati visoku točnost, ali u praksi neće biti koristan.

- F1 mjera

F1 mjera je harmonijska sredina između preciznosti i odziva. Harmonijska sredina se koristi umjesto aritmetičke jer bolje balansira situacije gdje su preciznost i odziv različite.

F1 = $2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$

F1 mjera daje uravnoteženu procjenu modela, posebno u situacijama kada su klase neuravnotežene i kada je važno da model ne favorizira jednu metriku nad drugom. F1 mjera je posebno korisna kada želimo pronaći balans između preciznosti (koliko su predikcije točne) i odziva (koliko model prepoznaje sve stvarne pozitivne primjere). Idealna je za situacije u kojima su troškovi lažnih pozitivnih i lažnih negativnih rezultata različiti.

- Preciznost (Precision)

Preciznost je omjer ispravno predviđenih pozitivnih instanci u odnosu na sve instance koje su model klasificirao kao pozitivne.

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

Preciznost mjeri koliko od svih pozitivnih klasifikacija modela su stvarno pozitivni. Visoka preciznost znači da model daje malo lažno pozitivnih rezultata to jest situacija u kojoj je predikcija pozitivna, a zapravo nije. Preciznost je važna u situacijama gdje je važno minimizirati lažno pozitivne rezultate, npr. u medicinskim dijagnozama gdje je važno izbjegići pogrešno dijagnosticiranje bolesti.

- Odziv (Recall)

Odziv, poznat i kao osjetljivost, je omjer ispravno predviđenih pozitivnih instanci u odnosu na ukupan broj stvarnih pozitivnih instanci.

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

Odziv mjeri koliko od svih stvarno pozitivnih primjera model uspješno prepoznaje. Visoki odziv znači da model daje malo lažno negativnih rezultata to jest situacija u kojoj je predikcija negativna, a zapravo je pozitivna. Odziv je važan kada je važno uhvatiti sve stvarne pozitivne primjere, čak i po cijenu povećanja lažno pozitivnih, npr. u situacijama ranog otkrivanja bolesti.

- MCC (Matthews Correlation Coefficient)

MCC je mjera kvalitete binarne klasifikacije koja uzima u obzir sve četiri kategorije iz matrice zabune (TP, TN, FP, FN). Zhu, Q.(2020.) definira MCC formulom:

$$\text{MCC} = (\text{TP} * \text{TN} - \text{FP} * \text{FN}) / \text{sqrt}((\text{TP} + \text{FP}) * (\text{TP} + \text{FN}) * (\text{TN} + \text{FP}) * (\text{TN} + \text{FN}))$$

MCC pruža uravnoteženu procjenu uspješnosti modela, uzimajući u obzir točne i pogrešne predikcije u obje klase. Vrijednosti MCC-a mogu varirati od -1 do 1:

MCC = 1: Savršena predikcija.

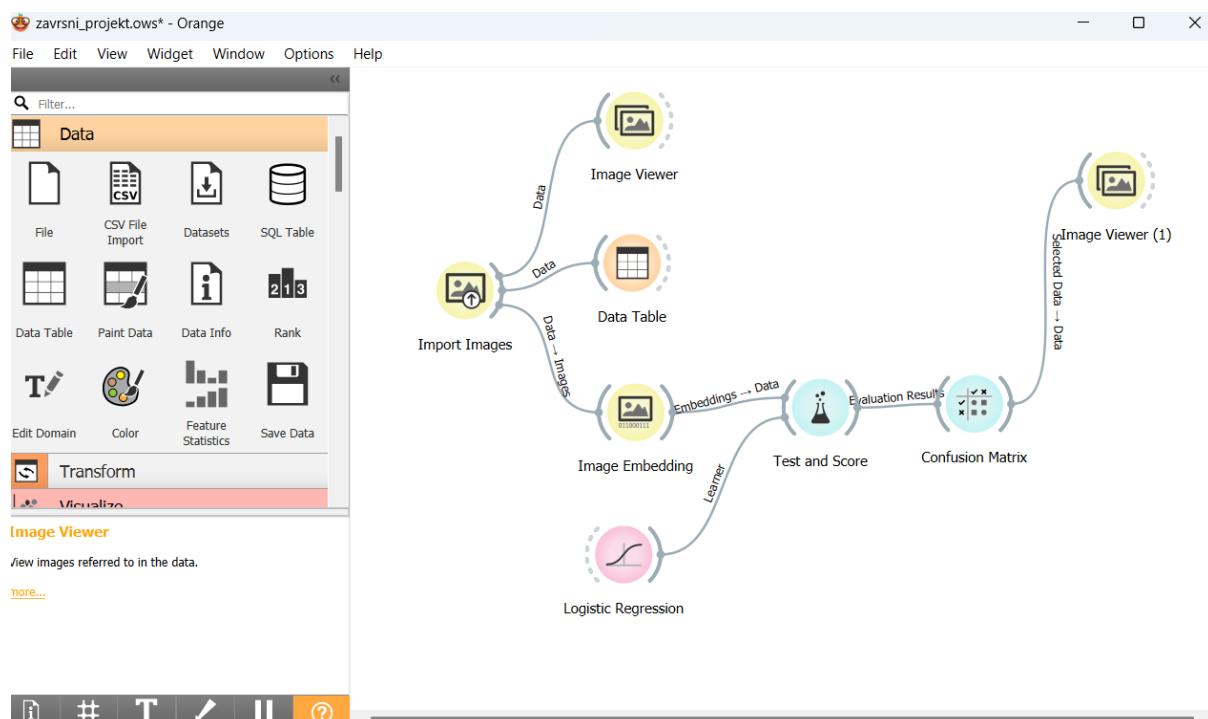
MCC = 0: Model radi na razini nasumične predikcije.

MCC = -1: Model daje potpuno pogrešne predikcije.

MCC je posebno koristan u situacijama kada su klase neuravnotežene i kada je važno uzeti u obzir sve aspekte performansi modela. Smatra se boljim pokazateljem ukupne uspješnosti modela u binarnoj klasifikaciji od jednostavne točnosti.

Svaka od ovih metrika pruža jedinstveni uvid u performanse modela, a njihov kombinirani pregled pomaže u razumijevanju kako se model ponaša u različitim scenarijima klasifikacije. Za složene i neuravnotežene skupove podataka, upotreba svih ovih metrika omogućuje cjelovitu evaluaciju kvalitete modela.

Rezultati evaluacije prikazani su kroz tablice i grafičke prikaze, uključujući matrice zabune i ROC krivulje, što omogućuje detaljnu analizu performansi svake kombinacije vektorizacije i klasifikacije. Ova analiza omogućila je identifikaciju prednosti i nedostataka svake metode te pružila uvid u optimalne pristupe za klasifikaciju pasmina pasa.



Slika 2 korisničko sučelje

4. REZULTATI I DETALJNA ANALIZA

4.1. k najbližih susjeda (kNN)

a) DeepLoc

AUC (Area Under the Curve): 0.540

AUC od 0.540 ukazuje na vrlo slabu sposobnost modela da razlikuje između različitih klasa. Vrijednost blizu 0.5 sugerira da je model tek nešto bolji od nasumičnog pogađanja.

CA (Classification Accuracy): 0.032

Točnost od 3.2% je izuzetno niska, što ukazuje na to da je model gotovo neupotrebljiv za zadatku klasifikacije pasmina pasa.

F1 mjera: 0.029

Niska F1 mjera potvrđuje da model ima lošu ravnotežu između preciznosti i odziva. Loša F1 mjera znači da model često pogrešno klasificira, s puno lažno pozitivnih i lažno negativnih rezultata.

Preciznost (Precision): 0.046

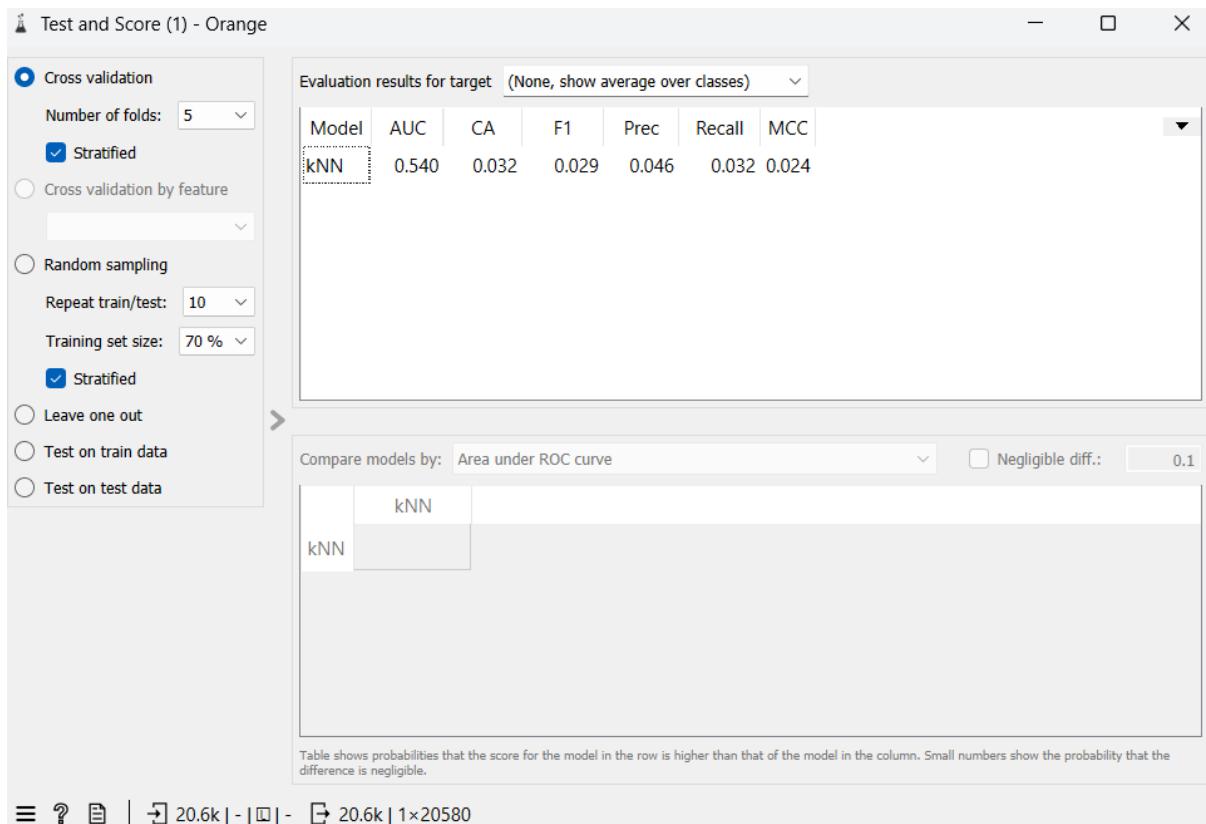
Preciznost od 4.6% sugerira da od svih klasifikacija koje model označi kao pozitivne (ispravne), samo mali dio njih stvarno pripada toj klasi.

Odziv (Recall): 0.032

Odziv od 3.2% znači da model pronađe samo mali postotak stvarno pozitivnih instanci unutar cijelog skupa podataka.

MCC (Matthews Correlation Coefficient): 0.024

MCC od 0.024 također potvrđuje da model gotovo nema korelacije između stvarnih i predviđenih klasa, što upućuje na vrlo lošu izvedbu modela.



Slika 3 Deeploc knn rezultati

b) InceptionV3

AUC: 0.979

AUC od 0.979 ukazuje na izvanrednu sposobnost modela da razlikuje između klase. Ova vrijednost znači da model gotovo savršeno rangira pozitivne primjere ispred negativnih.

CA: 0.887

Točnost od 88.7% je vrlo visoka, što znači da je model uspješan u prepoznavanju pasmina pasa u većini slučajeva.

F1 mjera: 0.886

F1 mjera blizu 1 ukazuje na vrlo dobru ravnotežu između preciznosti i odziva, što znači da je model i precizan i da ima visoku stopu otkrivanja pravih pozitivnih instanci.

Preciznost: 0.888

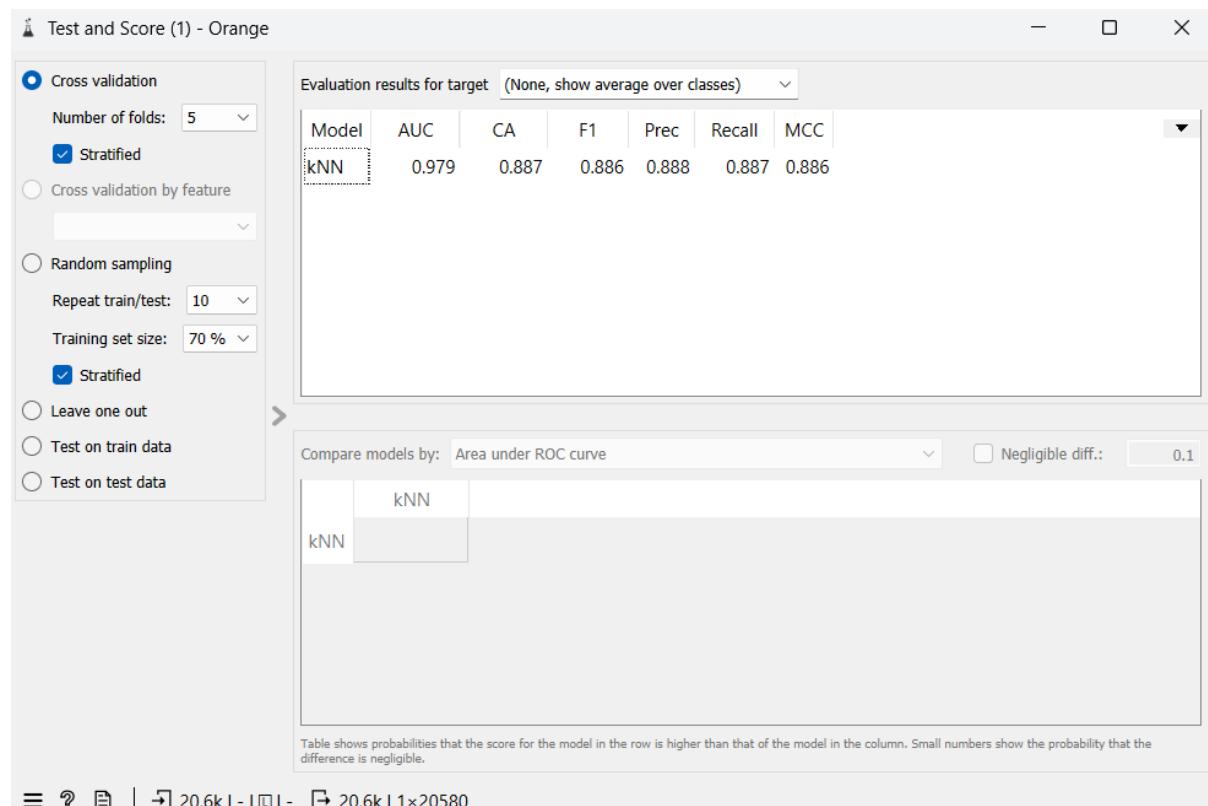
Preciznost od 88.8% znači da je model vrlo pouzdan u svojim pozitivnim predikcijama.

Odziv: 0.887

Odziv također pokazuje da model uspijeva otkriti gotovo sve prave pozitivne primjere.

MCC: 0.886

MCC od 0.886 potvrđuje da postoji snažna korelacija između predviđenih i stvarnih klasa, što pokazuje da model vrlo dobro funkcionira.



Slika 4 InceptionV3 knn rezultati

c) Painters

AUC: 0.636

AUC od 0.636 ukazuje na prosječnu sposobnost modela da razlikuje između klasa. Iako nije katastrofalno, daleko je od idealnog.

CA: 0.128

Točnost od 12.8% je izuzetno niska, što znači da model često pogrešno klasificira slike.

F1 mjera: 0.129

F1 mjera ukazuje na vrlo slabu izvedbu, s velikim brojem pogrešno klasificiranih slika.

Preciznost: 0.184

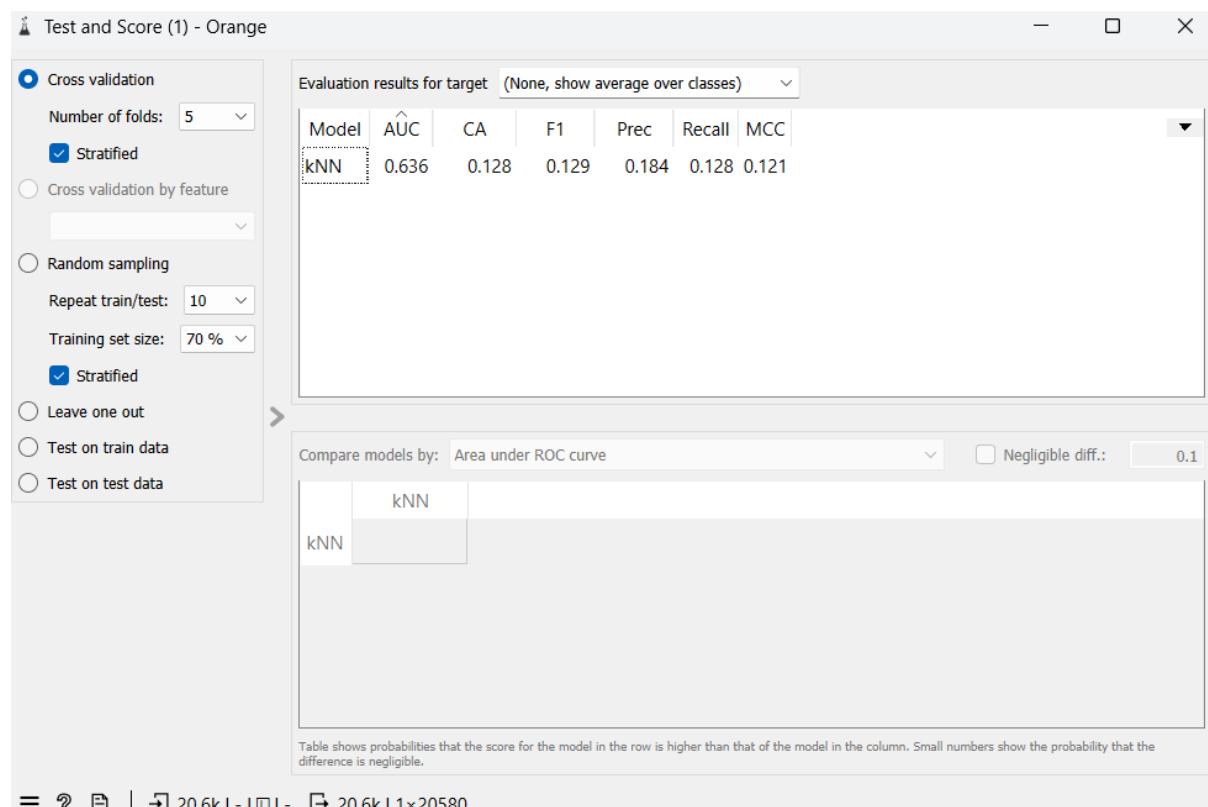
Preciznost je nešto bolja od točnosti, ali još uvijek niska, što znači da model nije pouzdan.

Odziv: 0.128

Niski odziv sugerira da model ne uspijeva otkriti većinu pravih pozitivnih instanci.

MCC: 0.121

MCC je vrlo niska, što potvrđuje slabost modela.



Slika 5 Painters knn rezultati

4.2. Logistička regresija

a) DeepLoc

AUC: 0.713

AUC od 0.713 sugerira da model ima umjerenu sposobnost razlikovanja klasa, bolji od kNN s DeepLoc metodom, ali još uvijek ne zadovoljavajući.

CA: 0.064

Točnost od 6.4% ukazuje na vrlo lošu izvedbu, što znači da model rijetko pravilno klasificira slike.

F1 mjera: 0.059

F1 mjera potvrđuje nisku točnost i lošu ravnotežu između preciznosti i odziva.

Preciznost: 0.057

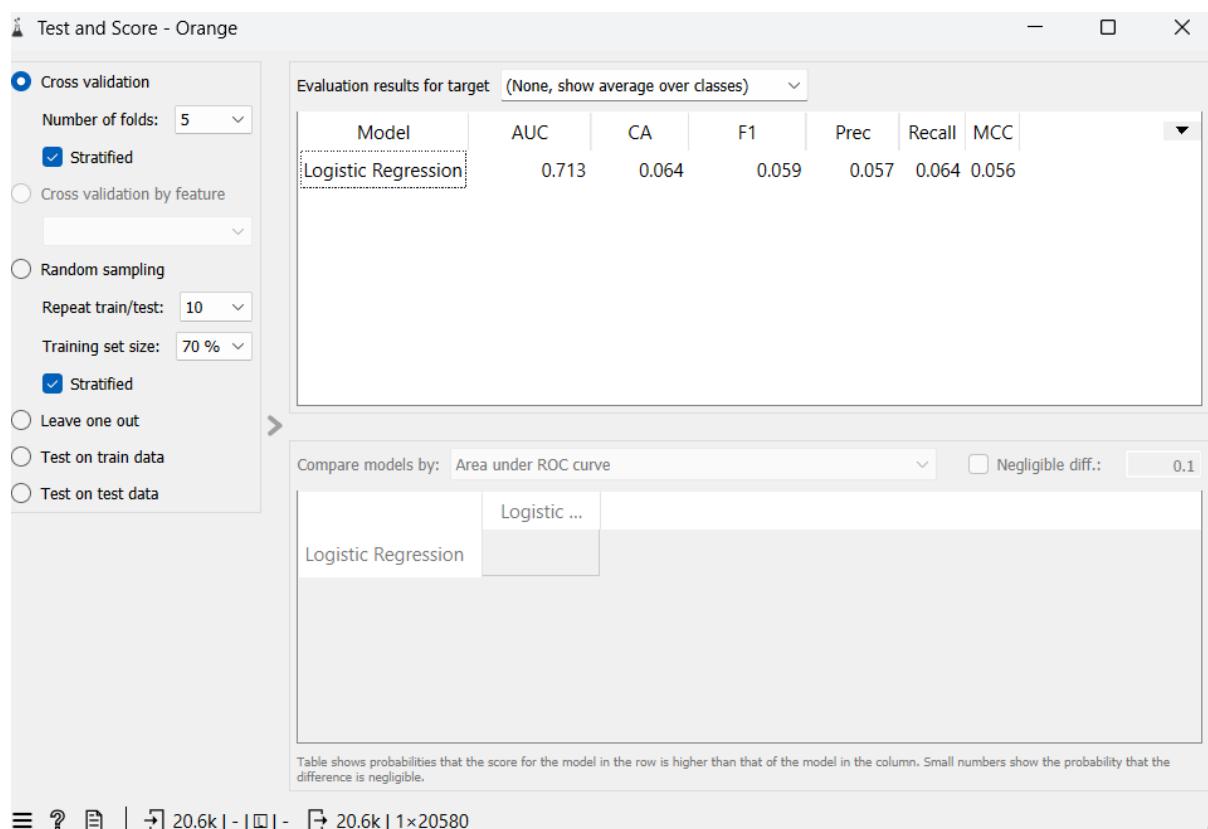
Preciznost od 5.7% ukazuje na to da je model vrlo često pogrešan u svojim pozitivnim predikcijama.

Odziv: 0.064

Odziv je također vrlo nizak, što znači da model rijetko pronalazi stvarne pozitivne primjere.

MCC: 0.056

Nizak MCC sugerira slabu korelaciju između predviđenih i stvarnih klasa.



Slika 6 Deeplock logistička regresija rezultati

b) InceptionV3

AUC: 0.999

AUC od 0.999 pokazuje gotovo savršenu sposobnost modela da razlikuje između klasa.

CA: 0.896

Točnost od 89.6% je vrlo visoka, što sugerira da model vrlo uspješno klasificira slike.

F1 mjera: 0.896

F1 mjera ukazuje na vrlo dobru ravnotežu između preciznosti i odziva.

Preciznost: 0.896

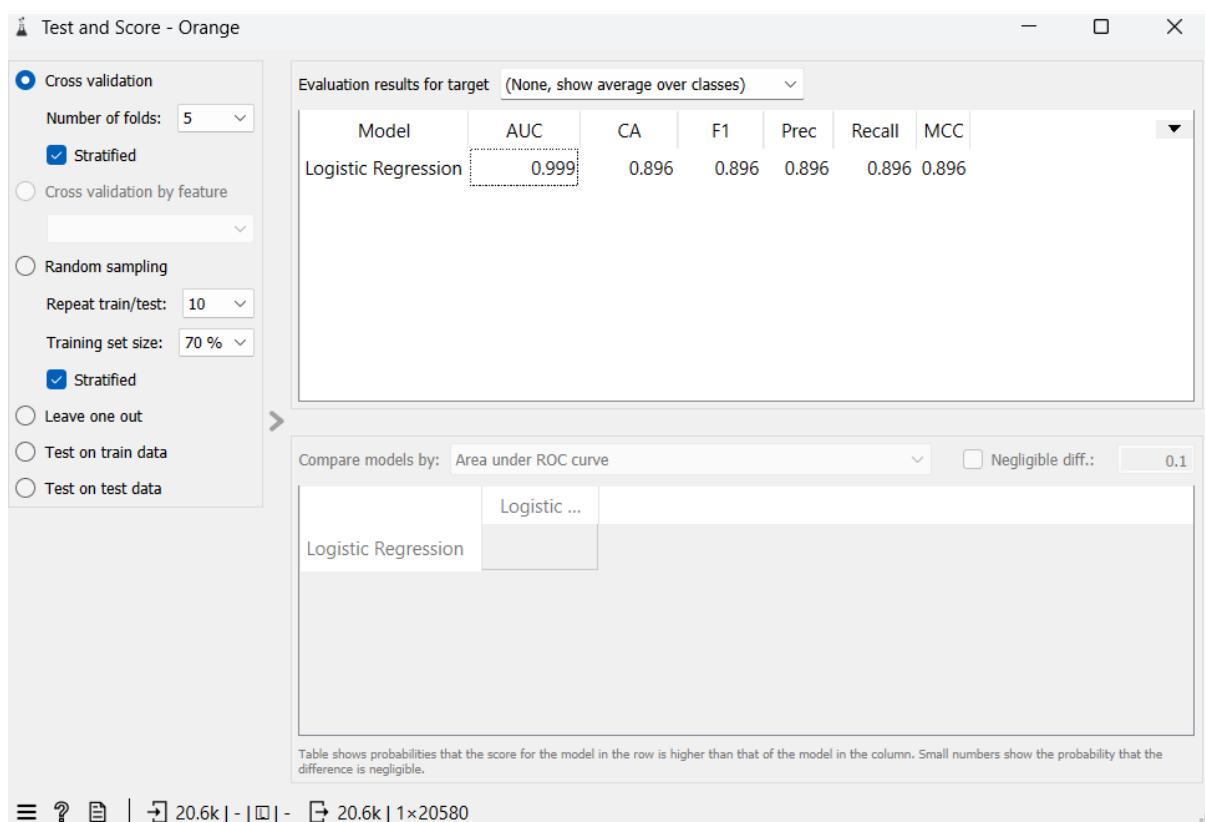
Visoka preciznost znači da model vrlo rijetko grijesi u pozitivnim predikcijama.

Odziv: 0.896

Odziv je također vrlo visok, što znači da model prepoznaje većinu stvarnih pozitivnih primjera.

MCC: 0.896

MCC potvrđuje vrlo snažnu korelaciju između predviđenih i stvarnih klasa, što znači da model vrlo dobro funkcioniра.



Slika 7 InceptionV3 logistička regresija rezultati

c) Painters

AUC: 0.877

AUC od 0.877 pokazuje dobru sposobnost modela da razlikuje između klasa, ali je manje učinkovit nego InceptionV3.

CA: 0.223

Točnost od 22.3% je vrlo niska, što sugerira da model često grijšeši.

F1 mjera: 0.223

F1 mjera ukazuje na lošu ravnotežu između preciznosti i odziva.

Preciznost: 0.223

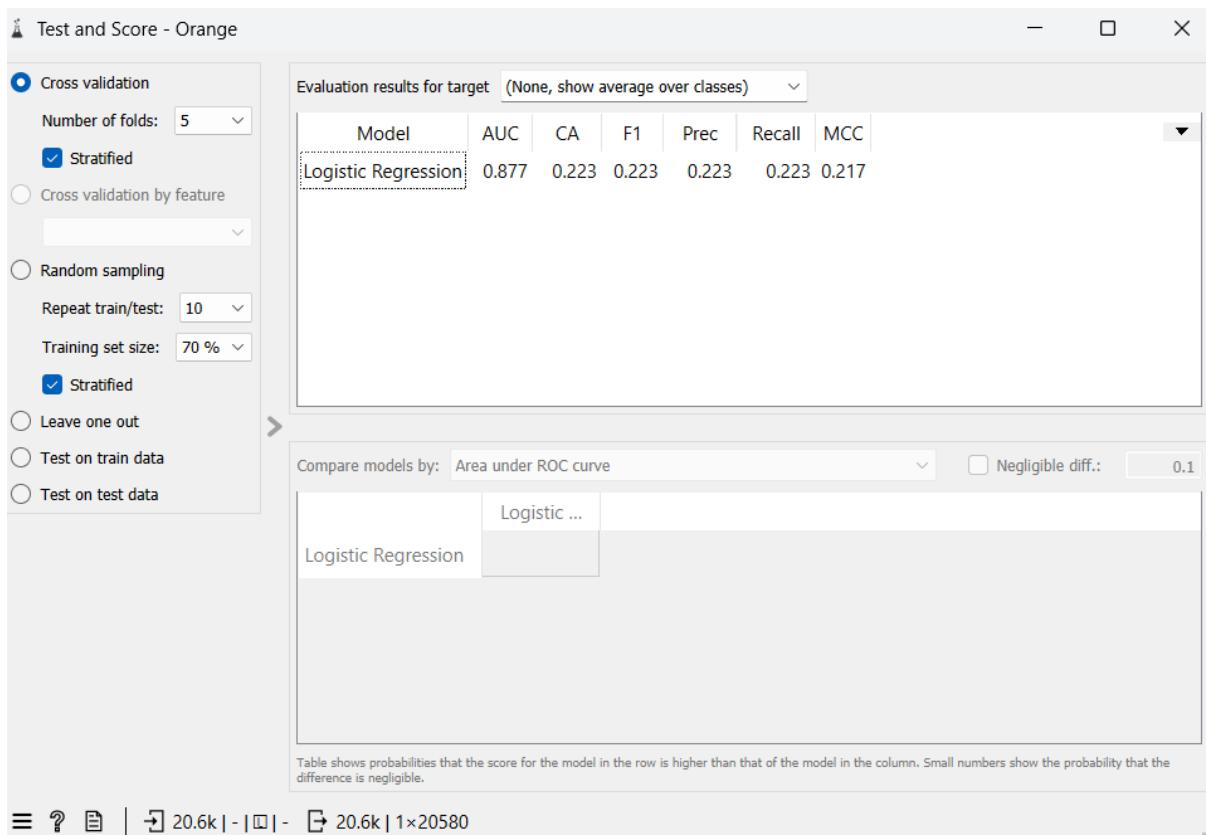
Preciznost također nije zadovoljavajuća, što znači da model često daje pogrešne pozitivne predikcije.

Odziv: 0.223

Odziv je nizak, što znači da model ne prepoznaje velik broj stvarnih pozitivnih primjera.

MCC: 0.217

Nizak MCC potvrđuje slabu izvedbu modela.



Slika 8 Painters logistička regresija rezultati

4.3. Neuronske mreže

a) DeepLoc

AUC: 0.672

AUC od 0.672 ukazuje na umjerenu sposobnost modela da razlikuje između klasa.

CA: 0.047

Točnost od 4.7% je vrlo niska, što znači da model rijetko pravilno klasificira slike.

F1 mjera: 0.045

F1 mjera potvrđuje nisku točnost i lošu ravnotežu između preciznosti i odziva.

Preciznost: 0.044

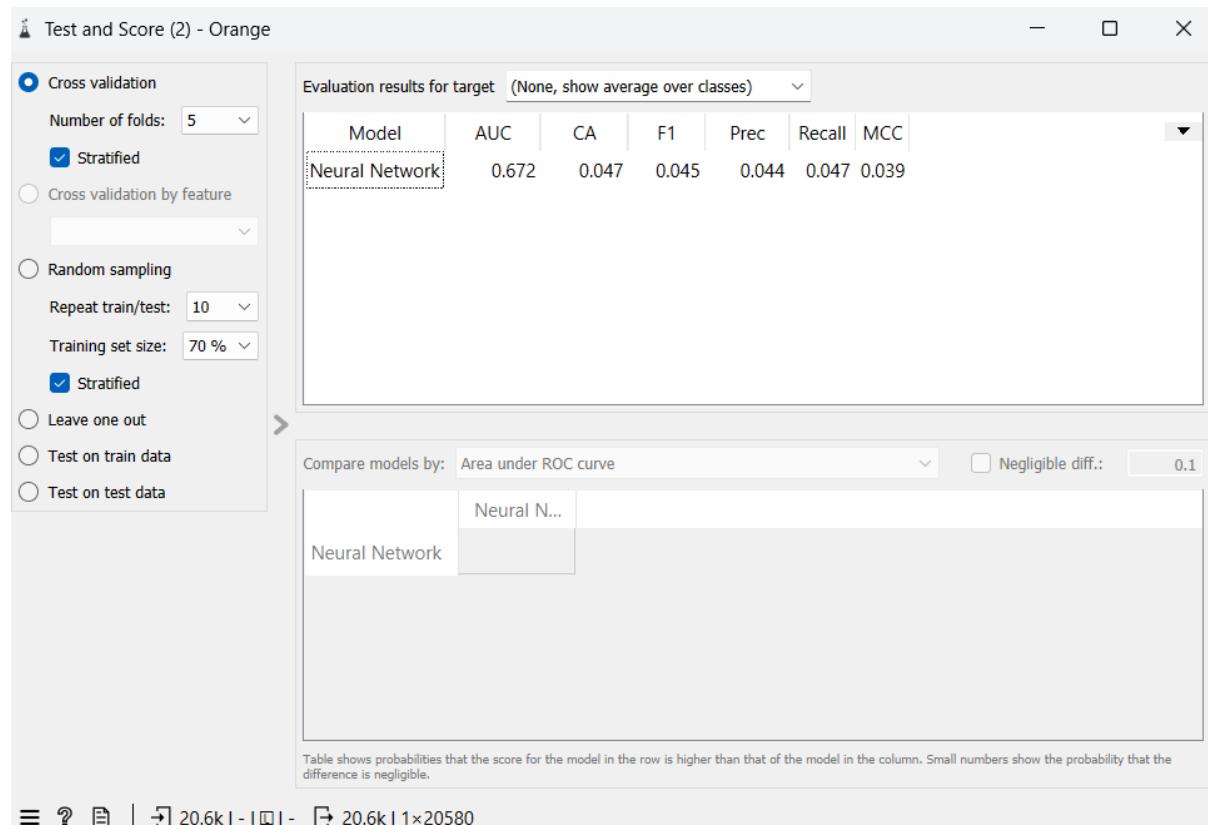
Preciznost od 4.4% sugerira da model vrlo često daje pogrešne predikcije.

Odziv: 0.047

Odziv od 4.7% znači da model rijetko pronalazi stvarne pozitivne primjere.

MCC: 0.039

Nizak MCC sugerira vrlo slabu izvedbu modela.



Slika 9 Deeploc neuronske mreže rezultati

b) InceptionV3

AUC: 0.997

AUC od 0.997 pokazuje izvrsnu sposobnost modela da razlikuje između klasi.

CA: 0.872

Točnost od 87.2% je vrlo visoka, što znači da model često pravilno klasificira slike.

F1 mjera: 0.872

F1 mjera ukazuje na vrlo dobru ravnotežu između preciznosti i odziva.

Preciznost: 0.872

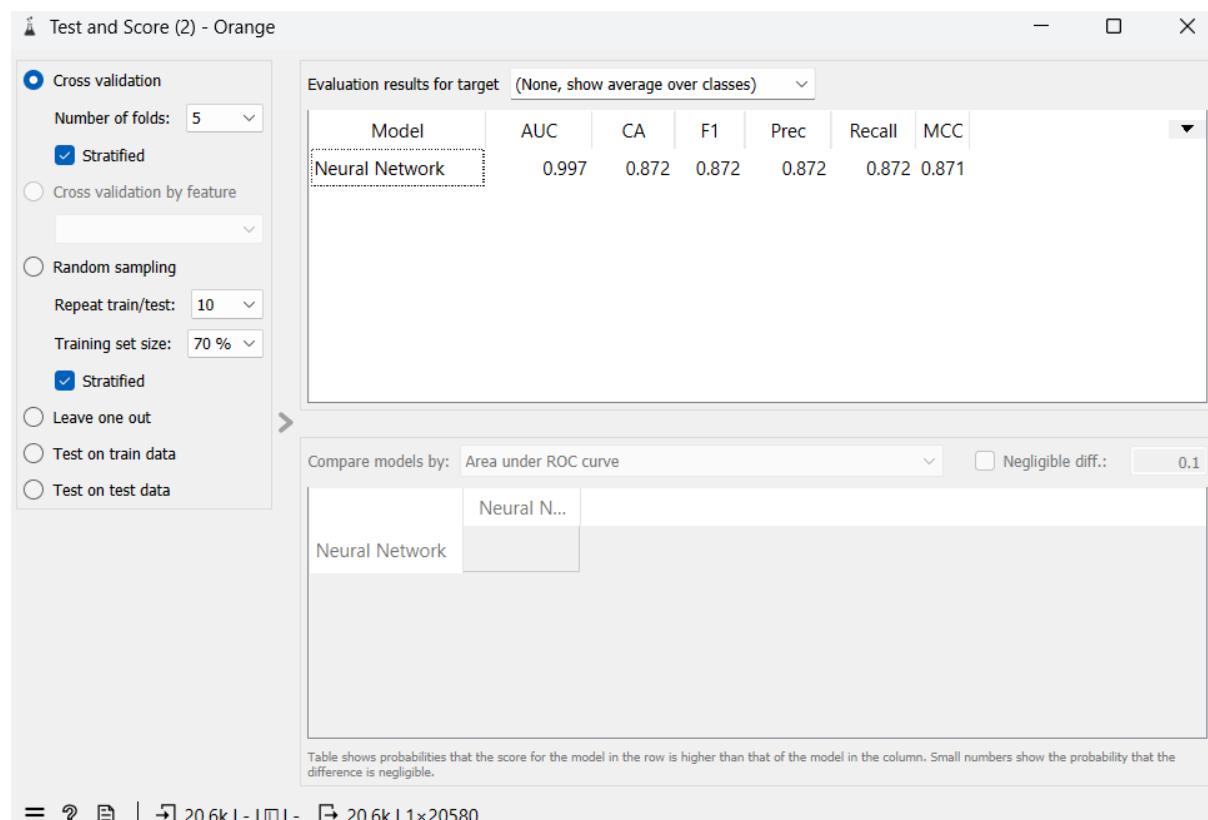
Visoka preciznost znači da model vrlo rijetko grijšeši.

Odziv: 0.872

Odziv od 87.2% znači da model prepozna većinu stvarnih pozitivnih primjera.

MCC: 0.871

MCC od 0.871 potvrđuje da postoji vrlo snažna korelacija između predviđenih i stvarnih klasa.



Slika 10 InceptionV3 neuronske mreže rezultati

c) Painters

AUC: 0.849

AUC od 0.849 pokazuje dobru sposobnost modela da razlikuje između klasa.

CA: 0.177

Točnost od 17.7% je niska, što znači da model često grijšeši.

F1 mjera: 0.177

F1 mjera ukazuje na lošu ravnotežu između preciznosti i odziva.

Preciznost: 0.177

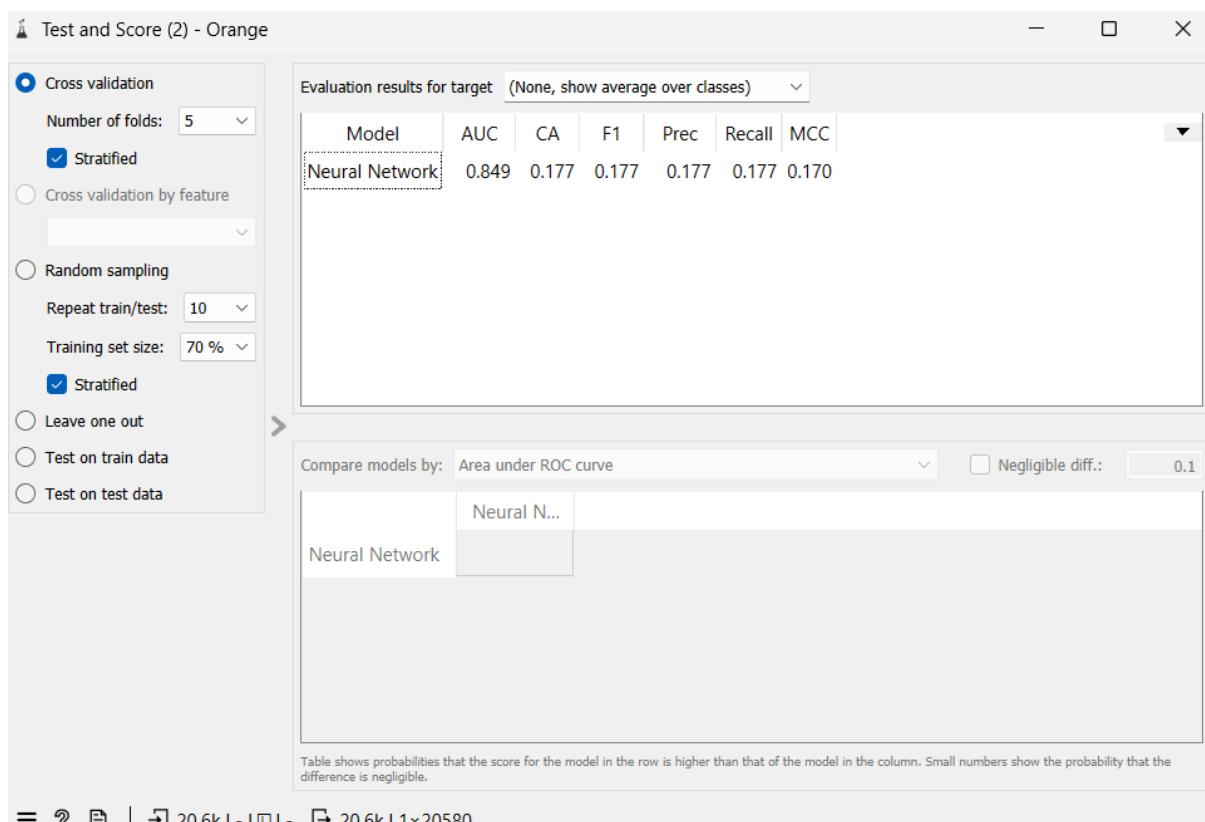
Niska preciznost sugerira da model često daje pogrešne predikcije.

Odziv: 0.177

Nizak odziv od 17.7% znači da model ne prepoznaje većinu stvarnih pozitivnih primjera.

MCC: 0.170

Nizak MCC potvrđuje slabu izvedbu modela.



Slika 11 Painters neuronske mreže rezultati

5. ZAKLJUČAK

Na temelju detaljne analize rezultata, možemo donijeti nekoliko ključnih zaključaka:

InceptionV3 je jasno nadmašio druge metode vektorizacije (DeepLoc i Painters) u svim slučajevima. Kada se koristi u kombinaciji s logističkom regresijom i neuronskim mrežama, InceptionV3 je pokazao izvanredne rezultate, s AUC vrijednostima blizu 1.0 i visokim točnostima (CA = 0.896 i 0.872). To sugerira da je InceptionV3 vrlo učinkovit u ekstrakciji relevantnih značajki za zadatak klasifikacije pasmina pasa.

Loše performanse DeepLoc-a i Painters-a: Metode DeepLoc i Painters pokazale su se neadekvatnima za ovaj zadatak, s vrlo niskim vrijednostima točnosti, preciznosti i MCC-a. Ovi rezultati upućuju na to da ove metode ne uspijevaju učinkovito diferencirati slike pasmina pasa, vjerojatno zbog nedovoljne sposobnosti da izluče ključne značajke potrebne za točnu klasifikaciju.

Logistička regresija i neuronske mreže: Ova dva klasifikacijska algoritma pokazala su se kao najučinkovitiji kada su korišteni u kombinaciji s InceptionV3 metodom vektorizacije. Logistička regresija i neuronske mreže postigle su vrlo visoke vrijednosti AUC-a, točnosti i drugih evaluacijskih metrika, što sugerira da su ovi algoritmi dobro prilagođeni za zadatak klasifikacije pasmina pasa kada im se osiguraju kvalitetne značajke.

Iako je kNN također postigao visoke vrijednosti kada se koristi s InceptionV3, nije dosegao iste razine performansi kao logistička regresija i neuronske mreže. Ipak, kNN se pokazao kao solidan izbor za zadatke gdje je potrebna jednostavna i intuitivna klasifikacija.

Iako je Painters metoda prikladna za određene vizualne zadatke, u ovom slučaju se pokazala kao neadekvatna za klasifikaciju slika pasmina pasa. Njene loše performanse sugeriraju da nije uspjela izlučiti ključne vizualne značajke potrebne za razlikovanje između pasmina.

Zaključno, rezultati ovog istraživanja potvrđuju važnost odabira odgovarajuće metode vektorizacije i klasifikacije za specifične zadatke. InceptionV3, u kombinaciji s logističkom regresijom ili neuronskim mrežama, pokazao se kao najbolja opcija za klasifikaciju slika pasmina pasa, dok su druge metode dale znatno lošije rezultate. Ovi nalazi mogu služiti kao smjernice za buduće istraživanje i praktičnu primjenu u klasifikaciji slika.

6. LITERATURA

1. IBM URL: <https://www.ibm.com/topics/logistic-regression/> (pristupljeno 25. 8. 2024.)
2. Orange Data Mining URL: <https://orangedatamining.com/license/> (pristupljeno 25. 6. 2024.)
3. Machine learning URL: <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall#:~:text=of%20the%20word.-,Recall%2C%20or%20true%20positive%20rate,is%20also%20known%20as%20recall.&text=False%20negatives%20are%20actual%20positives,they%20appear%20in%20the%20denominator./> (pristupljeno 25. 8. 2024.)
4. Zhu, Q. (2020). On the performance of Matthews correlation coefficient (MCC) for imbalanced dataset. *Pattern Recognition Letters*, 136, 71-80.
5. Kaggle URL: <https://www.kaggle.com/> (pristupljeno 25. 6. 2024.)
6. Elastic URL: <https://www.elastic.co/what-is/knn> (pristupljeno 25. 8. 2024.)
7. Massachusetts Institute of Technology URL: <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414> (pristupljeno 28. 8. 2024.)
8. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
9. Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.

7. POPIS SLIKA

Slika 1 Orange data mining logo	6
Slika 2 korisničko sučelje	15
Slika 3 Deeploc knn rezultati	17
Slika 4 InceptionV3 knn rezultati	18
Slika 5 Painters knn rezultati	19
Slika 6 Deeplock logistička regresija rezultati.....	20
Slika 7 InceptionV3 logistička regresija rezultati	21
Slika 8 Painters logistička regresija rezultati	23
Slika 9 Deeploc neuronske mreže rezultati.....	24
Slika 10 InceptionV3 neuronske mreže rezultati	25
Slika 11 Painters neuronske mreže rezultati	26