

Primjena prijenosnog učenja u području forenzike

Jerković, Nika

Master's thesis / Diplomski 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://um.nsk.hr/um:nbn:hr:166:652759>

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

Download date / Datum preuzimanja: **2024-11-06**

Repository / Repozitorij:

[Repository of Faculty of Science](#)



UNIVERSITY OF SPLIT



SVEUČILIŠTE U SPLITU
PRIRODOSLOVNO MATEMATIČKI FAKULTET

DIPLOMSKI RAD

**PRIMJENA PRIJENOSNOG UČENJA U
PODRUČJU FORENZIKE**

Nika Jerković

Split, travanj 2024.

Temeljna dokumentacijska kartica

Diplomski rad

Sveučilište u Splitu

Prirodoslovno-matematički fakultet

Odjel za informatiku

Ruđera Boškovića 33, 21000 Split, Hrvatska

PRIMJENA PRIJENOSNOG UČENJA U PODRUČJU FORENZIKE

Nika Jerković

SAŽETAK

Određena područja, poput forenzike, suočavaju se s izazovima prikupljanja podataka zbog njihove specifičnosti i osjetljivosti. Fokus ovog istraživanja usmjeren je na različite strategije rješavanja problema nedostatka podataka, demonstriranih na primjeru klasifikacije spola lubanja na temelju 220 slika dobivenih 3D rekonstrukcijom MSCT snimaka. Detaljno je analiziran problem malih skupova podataka pružajući pregled relevantnih istraživanja, s naglaskom na tehnike povećanja skupa podataka i prijenosno učenje. Pokazano je da klasične tehnike povećanja skupa podataka, kao što su rotacija i razina osvjetljenja, pružaju bolje rezultate od sintetičkih metoda. U kontekstu prijenosnog učenja, model ResNet50 se istakao kao najučinkovitiji, a dodatan napredak postignut je finim podešavanjem. U konačnici su razvijeni modeli za svaki od triju pogleda (lateralni, frontalni i okcipitalni) koristeći klasične tehnike za povećanje skupa podataka i fino podešavanje. Pojedinačni modeli su kombinirani većinskim glasanjem te je postignuta krajnja točnost od 92,54%.

Ključne riječi: Mali skup podataka, klasifikacija, povećanje skupa podataka, GAN, cGAN, konvolucijska neuronska mreža, prijenosno učenje, ResNet50

Rad je pohranjen u knjižnici Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Rad sadrži: 63 stranice, 40 grafičkih prikaza, 7 tablica i 68 literaturnih navoda. Izvornik je na hrvatskom jeziku.

Mentor: **Dr. sc. Saša Mladenović**, redoviti profesor Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Ocjenjivači: **Dr. sc. Saša Mladenović**, redoviti profesor Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Dr. sc. Goran Zaharija, *docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

Dino Nejašmić, *predavač Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

Rad prihvaćen: travanj 2024.

Basic documentation card

Thesis

University of Split
Faculty of Science
Department of Computer Science
Ruđera Boškovića 33, 21000 Split, Croatia

APPLICATION OF TRANSFER LEARNING IN THE FIELD OF FORENSICS

Nika Jerković

ABSTRACT

Certain research areas, such as forensics, face challenges in collecting data due to the specificity of the data and the sensitive information involved. This research focuses on various strategies to address the data scarcity issue, demonstrated in the context of sex classification based on 220 images obtained through 3D reconstruction of MSCT scans of skulls. The problem of small datasets is analyzed in detail, providing an overview of relevant research and examining approaches such as dataset augmentation and transfer learning. Classical data augmentation techniques, such as rotation and lighting variations, yield better results than synthetic methods. In the context of transfer learning, the ResNet50 model stands out as the most effective, achieving additional progress through fine-tuning. Ultimately, models were developed for each view (lateral, frontal, and occipital) using classical dataset augmentation and fine-tuning techniques. Individual models were combined through majority voting, resulting in an accuracy of 92.54%.

Key words: Small dataset, classification, augmentation, GAN, cGAN, convolutional neural network, transfer learning, ResNet50

Thesis deposited in library of Faculty of science, University of Split

Thesis consists of: 63 pages, 40 figures, 7 tables and 68 references

Original language: Croatian

Mentor: **Saša Mladenović, Ph.D.** *Full Professor of Faculty of Science, University of Split*

Reviewers: **Saša Mladenović, Ph.D.** *Full Professor of Faculty of Science, University of Split*

Goran Zaharija, Ph.D. *Assistant Professor of Faculty of Science,
University of Split*

Dino Nejašmić , *Lecturer of Faculty of Science, University of Split*

Thesis accepted: April 2024.

IZJAVA

kojom izjavljujem s punom materijalnom i moralnom odgovornošću da sam diplomski rad s naslovom „Primjena prijenosnog učenja u području forenzike“ izradila samostalno pod voditeljstvom prof. dr. sc. Saše Mladenovića. U radu sam primijenila metodologiju znanstveno istraživačkog rada i koristila literaturu koja je navedena na kraju diplomskog rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući navela u diplomskom radu na uobičajen, standardan način citirala sam i povezala s fusnotama s korištenim bibliografskim jedinicama. Rad je pisan u duhu hrvatskog jezika.

Studentica

Nika Jerković

Sadržaj

| | |
|---|----|
| Uvod | 1 |
| 1. O istraživanju..... | 2 |
| 1.1. Motivacija..... | 2 |
| 1.2. Istraživačka pitanja | 3 |
| 1.3. Doprinosi | 4 |
| 2. Rad s malim skupom podataka | 5 |
| 2.1. Definicija | 6 |
| 2.2. Prednosti i nedostaci..... | 7 |
| 2.3. Pregled istraženosti..... | 9 |
| 2.3.1. Odabir istraživanja..... | 10 |
| 2.3.2. Tehnike povećavanja skupa podataka i prijenosno učenje | 12 |
| 3. Povećavanje skupa podataka | 16 |
| 3.1. Klasične tehnike | 16 |
| 3.1.1. Geometrijske transformacije..... | 17 |
| 3.1.2. Fotometrijske promjene | 20 |
| 3.1.3. Ostale tehnike | 21 |
| 3.2. Sintetičko generiranje podataka GAN-om | 22 |
| 3.2.1. Arhitektura..... | 23 |
| 3.2.2. Duboki konvolucijski GAN..... | 27 |
| 3.2.3. Uvjetni GAN | 29 |
| 4. Modeli strojnog učenja | 31 |
| 4.1. Osnove neuronskih mreža | 31 |
| 4.2. Konvolucijske neuronske mreže..... | 33 |
| 4.3. Prijenosno učenje..... | 35 |
| 4.3.1. ResNet50 | 37 |

| | | |
|--------|--|----|
| 5. | Realizacija | 39 |
| 5.1. | Podatci | 39 |
| 5.2. | Postupak povećavanja skupa podataka..... | 41 |
| 5.2.1. | Klasične tehnike | 41 |
| 5.2.2. | Generiranje podataka GAN-om i cGAN-om..... | 44 |
| 5.3. | Postupak odabira modela..... | 48 |
| 5.3.1. | Uvježbavanje odabranog modela..... | 53 |
| 5.4. | Fino podešavanje | 54 |
| 5.5. | Kombiniranje modela | 54 |
| 6. | Rezultati..... | 56 |
| 6.1. | Objašnjivost rezultata | 58 |
| | Zaključak | 63 |
| | Literatura | 64 |
| | Popis slika..... | 71 |
| | Popis tablica..... | 73 |

Uvod

Danas se svake sekunde generira i pohranjuje velika količina podataka. Unatoč rastućem broju dostupnih informacija, pristup istima ograničava se iz različitih razloga. Osim toga, u specifičnim domenama, poput medicine, forenzike i srodnih područja, uvijek postoji problem nedostatka podataka. U kontekstu strojnog učenja, posebno dubokog učenja, gdje je količina podataka ključna za uspješnost modela, nužno je istražiti pristupe koji omogućuju učinkovitu implementaciju modela, čak i kada je dostupan samo ograničen skup podataka. U domeni forenzike često se javlja problem nedostatka podataka, pa je ključno istražiti različite strategije prevladavanja tog izazova. Ovo istraživanje posebno analizira pristupe koji se oslanjaju na podatke, poput povećavanja skupa podataka, i one koji se usredotočuju na model, poput prijenosnog učenja. Fokus je stavljen na primjenu tih pristupa na konkretnom problemu klasifikacije lubanja po spolu na temelju slika dobivenih rekonstrukcijom višeslojnih kompjutoriziranih tomografija (engl. *Multislice Computerized Tomography* – MSCT).

Rad se sastoji od pet poglavlja. U prvom poglavlju se opisuje samo istraživanje, dok se u drugom detaljno analizira problem nedostatka podataka, pružajući uvid u postojeća istraživanja o toj temi. Treće poglavlje je posvećeno analizi klasičnih tehnika povećanja skupa podataka i sintetičkog generiranja podataka generativnim suparničkim mrežama (engl. *generative adversarial network* - GAN) te uvjetnim generativnim suparničkim mrežama (engl. *conditional generative adversarial network* – cGAN). U četvrtom poglavlju predstavljaju se neuronske mreže, s naglaskom na konvolucijske mreže koje se često koriste u obradi slika, te prijenosno učenje (engl. *transfer learning*) kao ključan koncept rješavanja izazova nedostatka podataka. Zatim se opisuju podatci, korišteni načini povećanja skupa podataka, odabrani model prijenosnog učenja i ostali detalji realizacije istraživanja. Konačno, u posljednjem poglavlju predstavljaju se dobiveni rezultati i razmatra se njihova objašnjivost.

1. O istraživanju

Svrha ovog rada je istražiti pristupe u rješavanju problema rada s malim skupovima podataka, s posebnim naglaskom na primjenu u forenzici. Cilj ovog rada je implementirati i usporediti odabrane modele za klasifikaciju lutanja po spolu koristeći prijenosno učenje. Uz to, cilj je i proučiti različite metode povećavanja skupa podataka - klasično i sintetički generiranim podacima te zaključiti koji od promatranih više doprinose točnosti modela. U okviru znanstvenog područja, ovo istraživanje pripada tehničkim znanostima, polju računarstva i grani umjetne inteligencije. Riječ je o primijenjenom istraživanju koje obuhvaća korištenje računalnih tehnologija za određivanje spola iz slika. Prema metodološkom pristupu, pripada kvantitativnim istraživanjima jer model daje vjerojatnost da je određena osoba muškarac ili žena. Budući da se istraživanje temelji na prikupljanju i analizi stvarnih podataka, ono pripada empirijskim istraživanjima, u kojima zaključci proizlaze izravno iz provedenih eksperimenata.

Istraživanje je provedeno u sklopu uspostavnog istraživačkog projekta Hrvatske zaklade za znanost „Forenzička identifikacija ljudskih ostataka analizom MSCT snimaka“ - CTforID (UIP-2020-02-7331). Provedbu istraživanja odobrilo je Etičko povjerenstvo Kliničkog bolničkog centra Split (klasa: 500–3/17–01/56; ur. broj: 2181–147-01/06/M.S.-17–2) i Etičko povjerenstvo Sveučilišnog odjela za forenzične znanosti Sveučilišta u Splitu (Klasa: 024–04/17–03/00026; ur. broj: 2181–227-05–12-17–0003).

1.1. Motivacija

U svijetu umjetne inteligencije i strojnog učenja, uspjeh modela često ovisi o količini i kvaliteti dostupnih podataka. Unatoč stalnom povećanju broja generiranih i prikupljenih podataka, pristup istima se sve češće ograničava. Postoje dva glavna razloga za to: prvi je prepoznavanje vrijednosti podataka u poslovnom svijetu, gdje se podatci koriste za stratešku analizu i odlučivanje, a drugi su sve stroži zakoni o privatnosti koji ograničavaju upotrebu osobnih podataka. Uz navedene trendove, posebnu pažnju zaslužuju specifične domene, poput forenzike, u kojima su skupovi podataka prirodno ograničeni zbog njihove osjetljivosti i etičkih aspekata. Uzimajući u obzir spomenute okolnosti, ključno je fokusirati se na

istraživanje i razvoj metoda koje omogućuju učinkovitu primjenu strojnog učenja i na malim skupovima podataka.

Motivacija za odabir forenzike kao domene za istraživanje određenih pristupa za rad s malim skupovima podataka proizlazi iz nekoliko čimbenika. Jedan od njih je dostupnost forenzičkih podataka, odnosno MSCT snimaka lubanje. Podatke, kao i softver za obradu istih, ustupio je Sveučilišni odjel za forenzične znanosti Sveučilišta u Splitu. Osim toga, postoji značajna sličnost između forenzičkih i medicinskih podataka što omogućuje primjenu sličnih metoda u oba područja. Unatoč sličnosti podataka, forenzika još uvijek nije u potpunosti iskoristila potencijal strojnog učenja ostavljajući znatan prostor za daljnji napredak. Kao dodatna motivacija za ovo istraživanje ističe se i prethodno razvijen prototip koji je poslužio za realizaciju dijela rada [1]. Prototip, izrađen pomoću alata za vizualno programiranje Orange [2], nije samo uspješno demonstrirao koncepte, već i pokazao zadovoljavajuće rezultate koji jasno ukazuju na opravdanost daljnjeg istraživanja u ovom području.

1.2. Istraživačka pitanja

Ovo istraživanje usmjereno je na razumijevanje i evaluacije određenih pristupa i tehnika strojnog učenja kada se radi s ograničenim skupom podataka. Konkretno, proučava se klasifikacija po spolu na temelju slika dobivenih iz 3D rekonstrukcije lubanje iz MSCT-a, s posebnim naglaskom na sljedeća istraživačka pitanja:

- Analiza odabranih prethodno uvježbanih modela - Kako se različiti prethodno uvježbani modeli ponašaju u izdvajanju značajki iz slika u okviru zadatka klasifikacije spola?
- Utjecaj finog podešavanja modela - kako fino podešavanje odabranih prethodno uvježbanih modela utječe na rezultate klasifikacije?
- Klasične tehnike povećavanja skupa podataka - kako konvencionalne metode povećanja skupa podataka, kao što su rotacija i skaliranje, utječu na sposobnost modela za preciznu klasifikaciju spola?

- Generativne suparničke mreže za povećavanje skupa podataka - koji od promatranih modela GAN-ova generira najrealnije podatke te kako tako nastali sintetički podatci utječu na performanse modela?

Na temelju ovih istraživačkih pitanja, postavljena je hipoteza da će kombinacija prijenosnog učenja i metoda za povećanje skupa podataka rezultirati povećanjem točnosti modela za klasifikaciju spola. Istraživanje je usmjereno na testiranje ove hipoteze i pronalaženje najučinkovitijih strategija za praktičnu primjenu, s ciljem pružanja podrške forenzičkim stručnjacima pri procjeni spola.

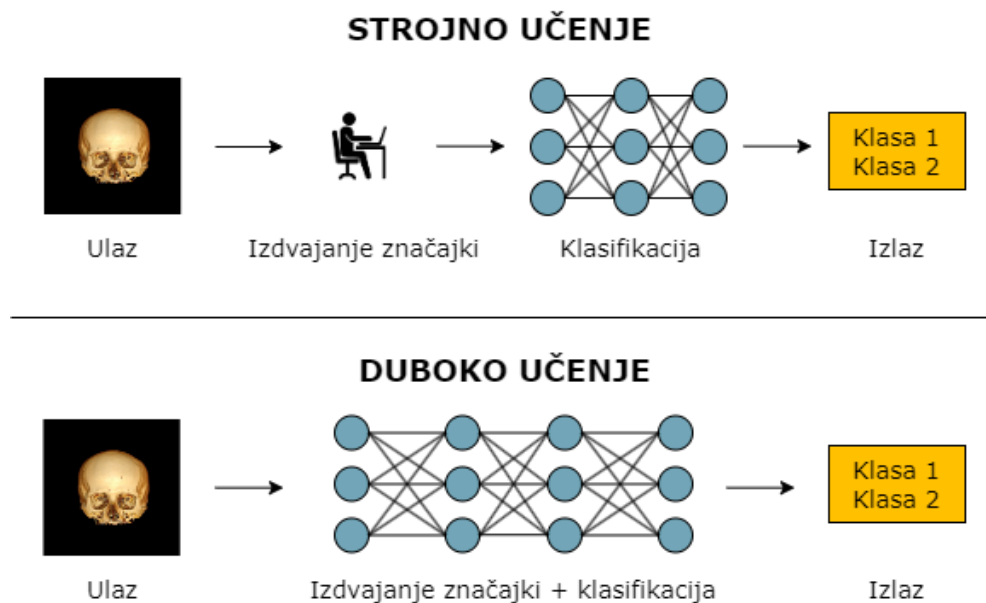
1.3. Doprinosi

Ovo istraživanje ističe učinkovitost promatranih metoda u suočavanju s izazovom malih skupova podataka u forenzičkoj domeni, konkretno pri klasifikaciji spola lubanja. Analizirane su dvije vrste pristupa – pristup utemeljen na podacima i pristup utemeljen na modelu. U prvom pristupu klasične metode povećavanja skupa podataka pokazale su se učinkovitijima od sintetičkih metoda. Ipak, promatrajući odabrani skup klasičnih metoda demonstrirano je da pojedine ne doprinose ili negativno utječu na rezultate. Iako nije nadmašilo klasične metode, sintetičko generiranje podataka GAN-om i uvjetnim GAN-om nije znatno ni naštetilo rezultatu. U nekim situacijama pokazalo se da postiže jednake rezultate kao i bez primjene bilo kakvih metoda proširenja skupa podataka. Takvi rezultati ukazuju na potencijal daljnjeg istraživanja složenijih arhitektura GAN-a koje zahtijevaju više računalnih resursa.

Pri odabiru arhitekture za prijenosno učenje ResNet50 se istaknuo kao najučinkovitiji. Fino podešavanje, zajedno s klasičnim metodama povećanja skupa podataka, rezultiralo je postizanjem najboljih rezultata u istraživanju. Kombiniranjem modela za sva tri pogleda većinskim glasanjem ostvaren je pomak u odnosu na pojedinačne modele, postižući ukupnu točnost od 92,54%. Postignuta točnost ukazuje na mogućnost razvoja pouzdanog alata koji bi forenzičarima pružio podršku pri identifikaciji pronađenih lubanja.

2. Rad s malim skupom podataka

Duboko učenje i tradicionalno strojno učenje pristupaju obradi podataka na različite načine, svaki sa svojim jedinstvenim karakteristikama i specifičnim zahtjevima. Dok tradicionalni algoritmi strojnog učenja zahtijevaju ručno izdvojene značajke koje moraju odrediti stručnjaci iz domene, algoritmi dubokog učenja uče značajke izravno iz podataka [3] čime se smanjuje potreba za detaljnom prethodnom obradom podataka, kao što je prikazano na Slici 2.1.



Slika 2.1 Razlika između tradicionalnog strojnog učenja i dubokog učenja (prema [3])

Ključna razlika između ovih pristupa je u tome što algoritmi dubokog učenja zahtijevaju veliku količinu podataka. Za duboko učenje su potrebne veće količine podataka zbog arhitekture koja uključuje manje prethodno postavljenih pretpostavki, ali zato veći broj parametara. Ova struktura omogućuje dubokom učenju da efikasno i automatski izdvađa značajke iz podataka, od onih osnovnih do složenih značajki, što doprinosi preciznosti predviđanja. Kada su dostupni veliki skupovi podataka, dubokim učenjem se izbjegava potreba za ručnom obradom značajki. No, čest izazov u praksi je nedovoljan broj označenih informacija [4] što je sve izraženiji problem u području umjetne inteligencije. U takvim okolnostima istraživači su potaknuti da istražuju i razvijaju tehnike dubokog učenja koje su optimizirane za rad s ograničenim skupovima podataka.

U nastavku ovog poglavlja će se razjasniti što se smatra malim skupom podataka i postoji li stroga definicija, koje su prednosti i nedostaci korištenja malog skupa podataka te će se napraviti pregled istraženosti koji obuhvaća određene metode.

2.1. Definicija

Prije samog proučavanja metoda za rad s malim skupom podataka, potrebno je razjasniti što se smatra malim skupom podataka. Prema [4], skup podataka se može smatrati velikim kada sadrži više od 100 000 označenih uzoraka ili kada pokriva cijelo područje distribucije vjerojatnosti u visokodimenzionalnom prostoru. Na primjer, postoje brojni besplatni veliki skupovi podataka koji se mogu koristiti za duboko učenje, kao što je ImageNet [5], skup s preko 14 milijuna označenih slika. Takvi skupovi podataka mogu se koristiti za uvježbavanje velikih modela dubokog učenja s tisućama do milijunima parametara. Tada se očekuje visoka generalizacija i mogućnost prenošenja znanja modela. Generalizacija se odnosi na sposobnost modela da točno predviđa na novim, nepoznatim podacima, a prenosivost je sposobnost uvježbanog modela da dobro radi na zadatku ili skupu podataka različitom od onoga na kojem je izvorno uvježban.

Nasuprot tomu, skupovi podataka se obično smatraju malima (ili nedovoljno velikima) kada sadrže manje od 1000 označenih uzoraka [4], ne pokrivaju cijelo područje distribucije vjerojatnosti ili se broj uzoraka smatra nedovoljnim za korištenje dubokog učenja za izdvajanje smislenih značajki. Važno je napomenuti da se problem malih podataka ne odnosi samo na ukupnu količinu podataka, već i na neravnotežu među klasama i neodgovarajuću distribuciju podataka. Sve spomenute situacije se često javljaju u praksi [6], pri čemu mogu predstavljati značajan izazov za uvježbavanje dubokih neuronskih mreža. Relativno mali skup podataka može negativno utjecati na učinkovitost modela dubokog učenja zbog prekomjernog prilagođavanja podacima za učenje (engl. *overfitting*). Tada model dobro radi s podacima za učenje, ali loše s novim, testnim podacima. To dovodi do niske razine generalizacije i nemogućnosti prenošenja znanja modela. Nadalje, u praksi se mogu pojaviti i skupovi podataka koji su „izuzetno mali“, što znači da skup podataka sadrži samo 1-10 označenih uzoraka (npr. povijesne prirodne katastrofe i izbijanja bolesti). Ovakva veličina

skupa podataka mogla bi biti dostatna za ljudsku analizu i identifikaciju jedinstvenih značajki, no ne i za automatsko izdvajanje značajki u dubokom učenju.


Unatoč spomenutim kriterijima za razlikovanje velikih i malih skupova podataka, praksa ukazuje na potrebu za fleksibilnijim pristupom. Veličina potrebnog skupa podataka ovisi o različitim čimbenicima poput složenosti zadatka i broja značajki u podacima. Ovdje fenomen dvostrukog pada (engl. *double descent*) [7] pruža novu perspektivu. Učinkovitost modela inicijalno se poboljšava s povećanjem složenosti ili veličine skupa podataka, zatim se smanjuje zbog prekomjernog prilagođavanja, a na kraju se ponovno poboljšava. Ovo proturječi uobičajenim očekivanjima o balansu između pristranosti i varijance sugerirajući da veći modeli ili veći skupovi podataka ne dovode nužno do boljih rezultata. Stoga, umjesto striktno podjele između malih i velikih skupova podataka, trebalo bi primijeniti pristup koji uzima u obzir specifičnosti svakog zadatka i prilagođava veličinu skupa podataka sukladno potrebama i karakteristikama pojedinačnih modela.

Problem malog skupa podataka u dubokom učenju često se uspoređuje s poznatim statističkim problemom „mali n , veliki p “ ($n < p$) [4], gdje je veličina uzoraka (n) znatno manja od broja parametara (p). Prema općem pravilu, svaki parametar može se procijeniti s 5 do 10 uzoraka. U praksi dubokog učenja, čak i najjednostavnije arhitekture konvolucijskih neuronskih mreža, poput LeNet-5, imaju desetke tisuća parametara, dok napredniji modeli, poput AlexNet-a ili VGG-a, sadrže milijune parametara daleko nadmašujući broj dostupnih uzoraka. Ovaj pravac u razvoju modela dubokog učenja pokazuje odmak od statističkih preporuka, stavljajući naglasak na upravljanje velikim brojem parametara unatoč ograničenim podacima. Ključno je pronaći ravnotežu kako bi se izbjeglo prekomjerno prilagođavanje podacima i osigurala pouzdanost modela, što zahtijeva precizne pristupe uvježbavanju i validaciji u dubokom učenju.

2.2. Prednosti i nedostaci

Iako se na prvi pogled čini da rad s malim skupom podataka donosi isključivo izazove, u praksi se pokazuje da ova situacija, uz nedostatke, ima i određene prednosti. Glavni nedostatak malih skupova podataka je, kao što je već spomenuto, njihova ograničena

generalizacija i nemogućnost prenošenja znanja zbog prekomjernog prilagođavanja podacima koje često dovodi do neučinkovitosti modela. Kako bi bilo jasnije kako detektirati prekomjernu prilagodbu podacima, potrebno je promotriti Sliku 2.2. Graf na lijevoj strani prikazuje kako model s vremenom postaje sve točniji na skupu za uvježbavanje (padajuća stopa pogreške), ali njegova učinkovitost na validacijskom skupu počinje padati nakon određene točke (točka infleksije). To ukazuje na to da model počinje „učiti napamet“ podatke za uvježbavanje gubeći sposobnost pravilnog rada na novim podacima. Nasuprot tomu, graf na desnoj strani prikazuje optimalni scenarij u kojem model pokazuje slične stope pogreške na oba skupa podataka kroz sve epohe uvježbavanja. Iz toga se zaključuje da model uspješno generalizira naučene informacije na novi, neviđeni skup podataka.



Slika 2.2 Usporedba *overfittinga* i optimalnog učenja (prema [8])

Osim toga, mali skupovi podataka mogu biti podložni pristranosti [9] što dodatno komplicira njihovu primjenu u raznim domenama dubokog učenja.

S druge strane, jedna od ključnih prednosti korištenja malog skupa podataka je brzina uvježbavanja modela. Ovo može biti posebno korisno za izradu prototipa i eksperimentiranje s različitim modelima i hiperparametrima. S manjim skupom podataka, više modela se može uvježbati u relativno kratkom vremenu što olakšava usporedbu i odabir najboljeg modela [9]. Manji skupovi podataka također zahtijevaju manje memorije za izvođenje i prostora za pohranu, što omogućuje uvježbavanje na uređajima s ograničenim resursima poput prijenosnih računala. Kada se radi s malim skupovima podataka, složeni modeli s velikim brojem parametara često nisu praktični pa se preferiraju manje kompleksni modeli zbog njihove lakše implementacije i efikasnije validacije [10]. Kombinacija malog skupa podataka s jednostavnijim modelom može se i dalje pokazati kao zadovoljavajuće rješenje.

Osim toga, prikupljanje i označavanje podataka može biti skupo i složeno pa korištenje manjeg skupa podataka može smanjiti troškove, a pritom je i lakše za ručno označavanje.

2.3. Pregled istraženosti

U istraživanju metoda za rad s malim skupovima podataka, razlikuju se dva osnovna pristupa: prvi se odnosi na različite metode uvježbavanja i arhitekture modela, dok drugi pristup stavlja naglasak na obogaćivanje i poboljšanje skupova podataka. U sklopu prvog pristupa [3][4] ističu se metode poput samonadziranog učenja (engl. *self-supervised learning*) koje se oslanja na neoznačene podatke, polunadziranog učenja (engl. *semi-supervised learning*) koje kombinira označene i neoznačene podatke, aktivnog učenja (engl. *active learning*) u kojem modeli samostalno biraju podatke za označavanje te slabo nadziranog učenja (engl. *weakly supervised learning*) s djelomično označenim podacima. Učenje više zadataka istovremeno (engl. *multi-task learning*) omogućuje obradu različitih problema u istom modelu, dok kombiniranje učenja više modela (engl. *ensemble learning*) spaja njihove snage za postizanje boljih rezultata. Među naprednijim tehnikama koje se spominju [3], ističu se one namijenjene optimizaciji arhitekture samih modela i one koje se bave razvojem neuronskih mreža obogaćenih fizičkim znanjem (engl. *physics-informed neural network*). Prema [4], još uvijek je najveći dio istraživanja u sklopu prvog pristupa usredotočen na prijenosno učenje, metodu koja omogućuje korištenje već uvježbanih modela za nove zadatke koristeći prethodno stečena znanja za brže i učinkovitije učenje.

Uz pristup koji obuhvaća metode uvježbavanja i arhitekture modela, važno je istražiti i drugi pristup koji se odnosi na tehnike povećanja skupa podataka. U izvoru [4] navedeno je da 71% istraživanja koja se bave radom s malim skupovima podataka uključuje primjenu neke od tehnika povećanja skupa podataka. Tehnike povećanja skupa podataka obuhvaćaju različite metode koje se mogu podijeliti na klasične i napredne metode [8]. Pritom, klasične metode uključuju geometrijske transformacije, prilagodbe boja, upotrebu raznih filtara, miješanje slika, a napredne metode se temelje na dubokom učenju te obuhvaćaju GAN-ove, prijenos neuralnog stila (engl. *neural style transfer*) i meta učenje (engl. *meta learning*). Cilj tih metoda je stvaranje dodatnih, sintetičkih podataka koji obogaćuju postojeće skupove podataka i tako doprinose boljem učenju i generalizaciji modela.

Pri odabiru metoda za rad s malim skupom podataka je ključno uzeti u obzir karakteristike dostupnih podataka. Odluka o primjeni određene metode temelji se na tome jesu li podatci označeni ili ne, njihovoj količini i specifičnosti zadataka koji se rješavaju. U okviru ovog istraživanja usmjerenog na zadatak klasifikacije u domeni forenzike, svi dostupni podatci su označeni. Upravo zbog toga, daljnje istraživanje je fokusirano na prijenosno učenje i tehnike povećanja skupa podataka. U sklopu povećanja skupa podataka, istražuju se klasične metode i generativne suparničke mreže kao napredna tehnika za obogaćivanje skupa podataka.

2.3.1. Odabir istraživanja

Nakon odluke o tome koje će se metode istraživati slijedi provođenje temeljitog pregleda literature. Svrha ovog pregleda je razumjeti načine na koje su odabrane metode primijenjene u drugim istraživanjima i različitim domenama. Za ovaj postupak korištena je PRISMA metodologija. PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) [11] predstavlja skup standardiziranih smjernica za precizno i transparentno prikupljanje i analizu literature. Ove smjernice osiguravaju detaljan i nepristran pristup u provođenju sustavnih pregleda i meta-analiza.

Pretraživanje baza podataka Web of Science i IEEE Xplore provedeno je koristeći ključne riječi u sažetcima: („small dataset“ OR „limited sample size“ OR „data scarcity“) AND „labeled data“ AND („deep learning“ OR „neural network“) AND „image classification“ AND („transfer learning“ OR („GAN“ AND „augmentation“)). Ovim upitom pronađena su 163 članaka u bazi Web of Science i 16 članaka u bazi IEEE Xplore, uz dodatnih 7 članaka pronađenih drugim metodama. To čini ukupno 186 članaka, od kojih je 8 identificirano kao duplikati. Kako bi se istraživanje usmjerilo na najrelevantnije radove, primijenjeni su jasno definirani kriteriji uključivanja i isključivanja koji su omogućili efikasno filtriranje i odabir članaka. Kriteriji uključivanja su sljedeći:


- Radovi moraju biti napisani na engleskom jeziku
- Radovi objavljeni u razdoblju od 2019. do 2023. godine
- Radovi koji obrađuju problem klasifikacije slika

- Radovi koji istražuju prijenosno učenje ili tehnike povećanja skupa podataka

S druge strane, kako bi se izbjegli radovi koji nisu predmet interesa ovog istraživanja, primijenjeni su sljedeće kriterije isključivanja:

- Nisu napisani na engleskom jeziku
- Objavljeni izvan perioda 2019.-2023. godine
- Bave se problemima segmentacije ili detekcije objekata.
- Koriste podatke koji nisu slike (npr. 3D, video, tekst)
- Istražuju neoznačene podatke, podatke s više oznaka ili se bave problemom označavanja neoznačenih podataka
- Zahtijevaju domensko znanje stručnjaka
- Fokusirani su isključivo na rješavanje instanci problema

Primjenom ovih kriterija isključeno je ukupno 155 radova. Nakon filtriranja, ukupno 16 članaka pronađenih u bazama i 7 članaka pronađenih drugim metodama zadovoljilo je kriterije uključivanja, čime je u konačnici 23 članka ušlo u daljnju analizu. Postupak odabira radova za ovo istraživanje detaljno je prikazan PRISMA dijagramom na Slici 2.3.



Slika 2.3 Postupak odabira radova za istraživanje

2.3.2. Tehnike povećavanja skupa podataka i prijenosno učenje

U ovom poglavlju se pregledava relevantna literatura s fokusom na tehnike povećavanja skupa podataka, uključujući klasične i sintetičke metode, te prijenosno učenje. Iako je većina analiziranih radova iz domene medicine, što ukazuje na čestu pojavu problema malog skupa podataka u tom području, pojavljuju se i radovi koji istražuju primjenu ovih tehnika u drugim područjima.

Pri analizi histopatoloških slika raka dojke, upotreba generativne suparničke mreže s pomoćnim klasifikatorom (engl. *auxiliary classifier generative adversarial network* - ACGAN) značajno je unaprijedila rezultate klasifikacija. Ova metoda je omogućila povećanje točnosti u binarnoj klasifikaciji (benigni nasuprot malignim tumorima) za 9,35%, dok je točnost u klasifikaciji podtipova tumora povećana za 8,88% [12]. Nadalje, u radu [13], koji se također bavi klasifikacijom histopatoloških slika raka dojke, istaknuta je efikasnost kombiniranja više modela zasnovanih na prijenosnom učenju. Ovaj inovativni pristup uključuje integraciju modela, kao što su VGG16, Xception, ResNet50 i DenseNet201, kako bi se povećala točnost binarne klasifikacije benignih i malignih lezija

dojke. Osim toga, u istraživanjima vezanim za mamografiju GAN-ovi su primijenjeni za generiranje sintetičkih mamograma različitih kategorija (normalni, benigni, maligni slučajevi), što je rezultiralo poboljšanjem točnosti klasifikacije raka dojke za 3,9% [14].

U dermatološkom istraživanju upotreba generativnih suparničkih mreža temeljenih na stilu (engl. *style-based generative adversarial network* - StyleGAN) za sintezu slika kožnih lezija, primijenjena u [15], pokazala se efikasnom u poboljšanju dijagnostičkih metrika. Ovo istraživanje demonstrira kako korištenje StyleGAN-a prilagođenog za kožne lezije povećava točnost za 1,6%, osjetljivost za 2,4% i specifičnost za 3,6% na skupu podataka ISIC 2018 Challenge. Dodatno, rad [16] se usredotočuje na problematiku prikupljanja podataka za određene kožne bolesti, poput rozaceje, gdje nedostatak podataka predstavlja značajan izazov. U tom se kontekstu istražuje potencijal GAN-ova u generiranju dodatnih podataka, meta-učenje i klasifikacija s malim brojem primjera.

Pri dijagnosticiranju pneumonije, primjena CycleGAN-ova [17] za prilagodbu domene na malim skupovima rendgenskih slika pluća rezultirala je rastom točnosti klasifikacije do 97,78%, što predstavlja značajan napredak u usporedbi s 90,03% točnosti kod standardnog prijenosnog učenja. Slično, u [18] za dijagnosticiranje pneumonije iz rendgenskih slika pluća koristi se model VGG16 i InceptionV3 za prijenosno učenje, kao i kapsularna mreža uvježbana od početka. Primjena klasičnih tehnika povećanja skupa podataka, uključujući rotaciju i promjenu orijentacije, poboljšala je performanse svih triju pristupa. Uz dijagnostiku pneumonije, [19] se također fokusira na prepoznavanje koronavirusa iz rendgenskih slika pluća. Model koristi postupak finog podešavanja pri čemu ostvaruje točnost od 98% i osjetljivost od 98,33%. Dodatno, demonstrira se i tehnika Grad-CAM (Gradient Weighted Class Activation Mapping) za vizualizaciju ključnih regija na slikama što omogućuje usporedbu s radiolozima. Za razliku od toga, [20] koristi CT snimke za dijagnostiku koronavirusa primjenjujući model DenseNet-121 u okviru prijenosnog učenja. Takav metodološki pristup rezultirao je visokom točnošću od 87% i mjerom F1 koja iznosi 86%.

U kardiologiji za istraživanje akutnog infarkta miokarda [21] koristile su se varijante GAN-a uključujući progresivno rastuće GAN-ove (engl. *progressive growing of generative adversarial network* - PGGAN) i ciklički konzistentne GAN-ove (engl. *cycle-consistent generative adversarial network* - CycleGAN) za generiranje dodatnih slika. Ovo je dovelo točnost klasifikacije do 92,7% na slikama magnetske rezonancije srca. U području gastroenterologije istražuje se primjena prijenosnog učenja za klasifikaciju gastroskopijskih slika iz skupa podataka Kvasirv2 [22]. Kroz primjenu prethodno uvježbanih modela EfficientNet, ResNet i DenseNet istraživanje demonstrira uspješnost prijenosnog učenja i u ovoj domeni. Nadalje, [23] istražuje primjenu prijenosnog učenja, ovog puta koristeći model VGG16, za klasifikaciju malih kirurških skupova podataka. Osim prijenosnog učenja, u ovom radu se istražuju i klasične tehnike povećanja skupa podataka.

Još jedno od istraživanja [24], koje se tiče generiranja sintetičkih medicinskih slika, proučava generiranje slika magnetske rezonancije kralježnice GAN-om s ciljem povećanja točnosti klasifikacija u slučaju rijetkih bolesti. Ovaj pristup uključuje četiri metode generiranja sintetičkih slika, od kojih jedna omogućuje stvaranje slika iz čak manje od 50 izvornih slika. Potom, rad [25] nudi detaljan pregled strategija koje se koriste u radiološkoj analizi slika u uvjetima gdje su podatci ograničeni. Pregled ističe važnost pažljivog odabira metoda uključujući primjenu klasičnih tehnika povećavanja skupa podataka, primjenu GAN tehnologije i prijenosnog učenja kao ključnih alata za poboljšanje učinkovitosti modela u radiologiji.

Izazovi povezani s malim skupovima podataka, kao i korištenje tehnika povećavanja skupa podataka i prijenosnog učenja, imaju široku primjenu i izvan medicinske domene. Jedno od takvih područja, gdje ove metode imaju značajnu ulogu, je forenzika. Primjer toga je istraživanje [26] usmjereno na određivanje spola na temelju lubanje koristeći metode dubokog učenja. U radu su korišteni virtualno rekonstruirani snimci lubanja na temelju kojih je prethodno uvježbana neuronska mreža GoogLeNet uspjela postići 95% točnosti u određivanju spola. Pritom, klasične metode povećavanja skupa podataka primijenjene su na skup za uvježbavanje koji čini 900 slika, a za testiranje je korišteno 100 slika. Spomenuti rad je od posebne važnosti jer se bavi istom domenom kao i ovo istraživanje – forenzikom te na sličan način pristupa rješavanju problema.

Metode koje se razmatraju pronalaze svoju primjenu i u poljoprivredi. Na primjer, [27] koristi prijenosno učenje za klasifikaciju hiperspektralnih slika usjeva. Koriste se VGGNet i ResNet mreže, uvježbane na ImageNet skupu podataka, za prijenos značajki na nove podatke uključujući skupove podataka poput Indian Pines i Salinas, kao i novi skup podataka iz regije Kota u Rajastanu. Slično tomu, [28] se u geoznanosti fokusira na prilagodbu prethodno uvježbanih konvolucijskih neuronskih mreža za specifičan zadatak klasifikacije tankih petrografskih presjeka muljastog kamena. Također se naglašava uloga finog podešavanja modela čime se omogućuje učinkovita prilagodba prethodno naučenih modela na promatrane podatke. U kontekstu infrastrukture, [29] predstavlja metodu dubokog učenja za identifikaciju pukotina na kolnicima koristeći ograničeni broj terenskih slika. Korištenje modela AlexNet, SE-Net i ResNet, s naglaskom na tehnike augmentacije podataka i specijaliziranu ekstrakciju pukotina, doprinijela je značajnom poboljšanju točnosti klasifikacije.

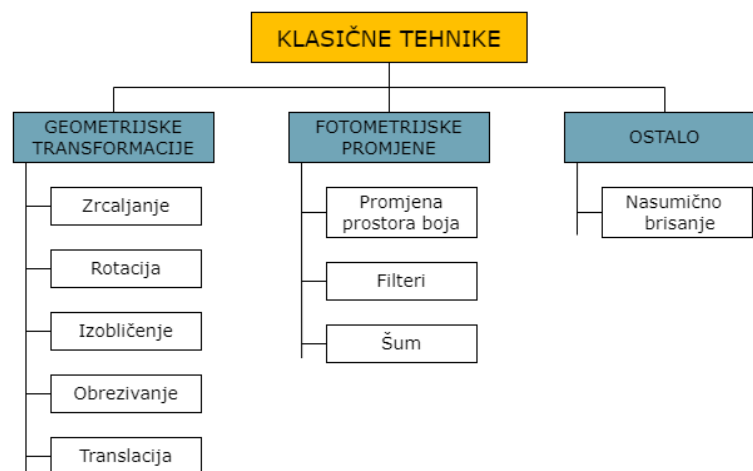
Zatim, istraživanje daljinske detekcije [4] daje pregled izazova povezanih s malim skupovima podataka i nudi deset tehnika dubokog učenja kao rješenje. Među spomenutim tehnikama našlo se prijenosno učenje, a ističu se njegove varijacije učenja s nekoliko primjera (engl. *few-shot learning*) i učenja bez primjera (engl. *zero-shot learning*). Zanimljiv dio istraživanja je i razvoj dijagrama koji pomaže korisnicima pri odabiru najprikladnije metode prema karakteristikama dostupnih podataka. Konačno, [30] se fokusira na usporedbu učenja s nekoliko primjera i prijenosnog učenja koje koristi višeslojni perceptron (engl. *multi-layer perceptron*) s finim podešavanjem na vrhu prethodno uvježbane konvolucijske neuronske mreže. Rad evaluira ove pristupe na različitim skupovima podataka, uključujući ImageNet, Caltech-UCSD Birds, FGVC-Aircraft i Omniglot, demonstrirajući bolju učinkovitost u odnosu na tradicionalne pristupe.

3. Povećavanje skupa podataka

Kao što je već prethodno pojašnjeno, metode povećanja skupa podataka igraju važnu ulogu u procesu razvoja i uvježbavanja modela dubokog učenja. Za razliku od prijenosnog učenja koje se oslanja na prethodno uvježbane modele, pristupi povećanja skupa podataka problem rješavaju direktno od izvora, odnosno samih podataka. Kroz povećanje skupa podataka različitim se tehnikama izvlače dodatne informacije iz originalnog skupa podataka. Ovo poglavlje fokusirat će se na klasične metode povećanja te sintetičke metode generiranja novih uzoraka GAN-ovima. Spomenuti pristupi nisu međusobno isključivi, već se često kombiniraju kako bi se postigli optimalni rezultati. Ipak, važno je biti umjeren u kombiniranju različitih tehnika. Prekomjerna primjena različitih tehnika na istom primjeru može dovesti do toga da slika postane teško prepoznatljiva i izgubi svoj smisao.

3.1. Klasične tehnike

Klasične tehnike povećanja skupa podataka često se u literaturi nazivaju i „osnovnim tehnikama povećanja“. Ove tehnike uključuju temeljne manipulacije podacima, kao što su geometrijske transformacije i fotometrijske promjene. Geometrijske transformacije obuhvaćaju tehnike poput zrcaljenja, rotacije, izobličenja, obrezivanja i translacije slike, dok fotometrijske promjene uključuju promjene u prostoru boja, primjenu filtera i dodavanje šuma. Upravo takva klasifikacija klasičnih metoda povećanja skupa podataka prikazana je na Slici 3.1.



Slika 3.1 Klasifikacija klasičnih tehnika za povećanje skupa podataka

Osim značajki pojedinih tehnika, važno je također obratiti pažnju na sigurnosti njihove primjene. Sigurnost primjene [31] određene tehnike odnosi se na očuvanje originalne oznake nakon transformacije. Na primjer, geometrijske transformacije poput rotacija i zrcaljenja mogu biti sigurne u kontekstu prepoznavanja životinja, no te iste tehnike nisu prikladne za zadatke prepoznavanja brojeva. Primjer takve situacije je razlikovanje brojeva 6 i 9 gdje rotacija može dovesti do promjene oznake. Transformacije koje ne zadržavaju oznaku teoretski mogu ojačati sposobnost modela da izrazi nedoumicu u predviđanju, no to zahtijeva precizno definirane oznake nakon transformacije. To može biti izazovan i računalno zahtjevan proces. Stoga je pri odabiru tehnika povećavanja važno razmotriti njihovu sigurnost u smislu očuvanja oznake kako bi se osiguralo da transformirani podaci ostaju relevantni i pouzdani za uvježbavanje modela.

3.1.1. Geometrijske transformacije

Prva geometrijska transformacija koju će se promatrati je zrcaljenje (engl. *flipping*). Zrcaljenje [32] je jedna od najjednostavnijih transformacija, a odnosi se na refleksiju slike oko vertikalne, horizontalne ili obje osi. Iako je zrcaljenje oko horizontalne osi češće, vertikalno zrcaljenje može biti korisno u određenim situacijama. Nasuprot tomu, vertikalno zrcaljenje nije primjereno kod prepoznavanja teksta jer ne osigurava zadržavanje oznake.

Kod vertikalnog zrcaljenja, slika se okreće naopako tako da se y-os nalazi na vrhu, a x-os na dnu. Koordinate f_x i f_y označavaju trenutne koordinate svakog piksela nakon zrcaljenja duž vertikalne osi što opisuje jednačba (3.1).

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.1)$$

Nadalje, pri horizontalnom zrcaljenju slika se okreće horizontalno pri čemu lijeva i desna strana mijenjaju mjesta, što je matematički zapisano jednačbom (3.2). Koordinate f_x i f_y predstavljaju trenutne koordinate piksela nakon refleksije duž horizontalne y-osi.

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.2)$$

Postoji i mogućnost kombinacije vertikalnog i horizontalnog zrcaljenja pri čemu se slika okreće i oko vertikalne i oko horizontalne osi, kao što je opisano jednačbom:

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.3)$$

Ova vrsta zrcaljenja omogućuje stvaranje varijacija slika koje zadržavaju osnovni oblik i strukturu originalne slike, ali s promijenjenom orijentacijom u oba smjera. To može biti korisno u scenarijima gdje je cilj povećati raznolikost slika u skupu podataka bez značajne promjene sadržaja slike.

Potom, rotacija (engl. *rotation*) je još jedna od klasičnih geometrijskih tehnika za povećavanje skupa podataka. Proces rotacije [33] uključuje okretanje slike oko osi, udesno ili ulijevo, za kutove između 1° i 359° . Rotacija se može primijeniti i tako da se slika postupno rotira pod određenim kutom, na primjer okretanjem slike za 30° . Takvim pristupom može se proizvesti 11 slika rotacijom pod kutovima 30° , 60° , 90° , 120° , 150° , 180° , 210° , 240° , 270° , 300° i 330° . Prikazana jednačba rotacije (3.4) opisuje kako se f_x i f_y , nove pozicije svakog piksela, mijenjaju nakon procesa rotacije.

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.4)$$

Sigurnost primjene rotacije uvelike ovisi o parametru kuta rotacije. Blage rotacije, poput onih između 1° i 20° ili -1° do -20° , su pogodne za većinu slučajeva, čak i za zadatke prepoznavanja brojeva. Međutim, povećanjem kuta rotacije očuvanje oznake više nije zagarantirano.

Sljedeća tehnika koja se razmatra je izobličenje (engl. *shearing*) [32] koje mijenja izgled izvorne slike mijenjanjem njenih dimenzija duž x i y osi. Ova tehnika je idealna za promjenu oblika postojećih objekata na slici. Osim toga, izobličenje uključuje dva tipa gdje se prvi tip

odnosi na promjene duž x-osi, a drugi tip na promjene duž y-osi. Jednadžba (3.5) predstavlja izobličenje u smjeru x-osi, dok jednadžba (3.6) predstavlja izobličenje u smjeru y-osi.

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} 1 & shX \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.5)$$

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ shY & 1 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.6)$$

Potom se pažnja usmjerava na tehniku obrezivanja (engl. *cropping*) [33] slika, koja se ponekad u znanstvenim istraživanjima spominje i kao zumiranje ili skaliranje. Obrezivanje je proces povećavanja izvorne slike kroz dvije različite operacije. Prva operacija obuhvaća rezanje slike od početne lokacije X, Y do druge lokacije X, Y. Na primjer, ako je veličina slike 200x200 piksela, može se izrezati od lokacije (0, 0) do (150, 150) ili od (50, 50) do (200, 200). Druga operacija je skaliranje slike na njenu izvornu veličinu koje je prikazano jednadžbom (3.7). U prethodnom primjeru slika se mora ponovno skalirati na 200x200 piksela nakon operacije rezanja.

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} Xscale & 0 \\ 0 & Yscale \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (3.7)$$

Obrezivanje slika može se koristiti i kao korak obrade slika s različitom visinom i širinom izrezivanjem središnjeg dijela svake slike. Također, nasumično obrezivanje može se koristiti za postizanje efekta vrlo sličnog translaciji. Razlika između nasumičnog obrezivanja i translacije je u tome što obrezivanje smanjuje veličinu ulazne slike, dok prilikom translacije slika zadržava svoje prostorne dimenzije.

Translacija (engl. *translation*) [32] je proces premještanja objekta unutar slike s jedne pozicije na drugu. U ovom postupku objekt se može pomicati u smjeru X osi, Y osi ili istovremeno u oba smjera, što je zapisano jednadžbom (3.8). Nakon translacije, preostali dio slike može ostati prazan (bijela ili crna površina) ili se popuniti nasumičnim ili Gausovim šumom kako bi se sačuvala izvorna veličina slike.

$$\begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} T_x \\ T_y \end{bmatrix} \quad (3.8)$$

Ova tehnika je korisna za izbjegavanje pozicijske pristranosti u skupu podataka. Na primjer, u skupovima podataka za prepoznavanje lica, gdje su slike često centrirane, model bi također trebao biti testiran na slikama koje nisu savršeno centrirane. Translacija omogućuje zadržavanje izvorne prostorne dimenzije slike nakon primjene, što je ključno za očuvanje pouzdanosti podataka.

Konačno, korištenje geometrijskih tehnika povećanja skupa podataka može povećati potrošnju memorije, zahtijevati više računalne snage i produžiti vrijeme uvježbavanja. K tomu, tehnike poput obrezivanja i translacije mogu ukloniti bitne značajke iz slika pa je njihova primjena ograničena i zahtijeva pažljivo ručno upravljanje, posebno u osjetljivim područjima poput medicinske obrade slika.

3.1.2. Fotometrijske promjene

Nakon geometrijskih transformacija detaljno se analiziraju fotometrijske promjene. Među njima se ističe promjena prostora boja (engl. *color space shifting*) [34] kojom se mogu otkriti skrivene značajke u specifičnom prostoru boja. Neki od poznatijih prostora boja su CMY (K) (cijan, magenta, žuta, crna), HSL (nijansa, zasićenje, svjetlina) i RGB (crvena, zelena, plava). Pretvorba između ovih prostora boja vrši se posebnim jednadžbama. U području promjene prostora boja primjenjuju se tehnike poput podešavanja svjetline slike povećanjem ili smanjenjem vrijednosti piksela. Pritom, neovisna obrada RGB matrica boje i ograničavanje piksela na minimalne ili maksimalne vrijednosti omogućuje različite vizualne efekte i poboljšanje kvalitete slika. Ipak, bitno je uzeti u obzir da transformacije prostora boja mogu ukloniti ključne informacije o boji, što ih čini manje prikladnima za primjenu u određenim situacijama, kao što je analiza sentimenta na slikama, gdje je boja kritičan faktor.

Nadalje, u obradi slika često se koriste tehnike poput izjednačavanja histograma, povećanja svjetline, izoštravanja, zamućivanja i uporabe filtara [35]. Ove tehnike djeluju klizanjem matrice dimenzija $n \times m$ kroz cijelu sliku. Na primjer, izjednačavanje histograma prilagođava intenzitet slike radi poboljšanja kontrasta, dok balansiranje bijele boje mijenja sliku kako bi

izgledala osvijetljena neutralnim izvorom svjetlosti. Filtri za izoštravanje koriste se za isticanje sitnih detalja na slici ili za pojačavanje detalja koji su zamagljeni, dok je zamućivanje proces usrednjavanja susjednih piksela. Ove tehnike mogu promijeniti izgled slike stvarajući visok kontrast što olakšava prepoznavanje detalja. Spomenuti filtri primjenjuju se množenjem izvorne slike s matricom filtra, mijenjajući boje i kontrast slike.

Prema [31], dodavanje šuma (engl. *noise*) se pokazalo kao efikasna metoda za testiranje otpornosti modela na različite vrste vizualnih smetnji. Jedna od češćih vrsta šuma je Gaussov šum koji se manifestira kao zrnasta tekstura na slici imitirajući blage varijacije u boji i teksturi. Ovaj šum se dodaje tako da se vrijednosti piksela mijenjaju prema normalnoj distribuciji, stvarajući efekt blagog narušavanja slike. S druge strane, Poissonov šum često se pojavljuje u slikama s elektromagnetskim frekvencijama, kao što su rendgenske slike. Njegova distribucija prati Poissonovu formulu simulirajući efekte specifičnog osvjetljenja i izlaganja, što ga čini korisnim u medicinskim primjenama. Šum soli i papra mijenja određene piksele slike u crno ili bijelo stvarajući kontrast koji može biti koristan za testiranje modela na iznenadne promjene u intenzitetu piksela. Ovaj šum može posebno utjecati na slike gdje su male izolirane promjene važne za prepoznavanje uzoraka. Iako šum može obogatiti skup podataka, važno je paziti da se ne iskrivi sliku do te mjere da se izgubi važna informacija.

3.1.3. Ostale tehnike


Nasumično brisanje (engl. *random erasing*) [36], tehnika koja se ne svrstava ni u geometrijske ni u fotometrijske promjene povećanja skupa podataka, temelji se na uklanjanju odabranih kvadrata sa slike. Korisna je u kontekstu detekcije objekata, posebice kada su dijelovi objekta nejasni ili skriveni. Ova tehnika potiče model da se usredotoči na manje primjetne značajke slike čime se smanjuje rizik od prekomjernog prilagođavanja na pojedine vizualne detalje. Nasumično brisanje implementira se odabirom $n \times m$ dijela slike koji se zatim maskira nulama, prosječnim vrijednostima piksela ili nasumičnim vrijednostima. Međutim, ova tehnika ne jamči uvijek očuvanje oznake. Na primjer, u prepoznavanju rukom pisanih brojeva izbrisani gornji dio „8“ može se zamijeniti sa „6“. Stoga je nužan oprez pri korištenju nasumičnog brisanja, posebno u zadacima gdje su specifični detalji ključni.

U kontekstu ovog istraživanja, koje se fokusira na klasifikaciju lubanja po spolu, nasumično brisanje nije optimalno rješenje. Budući da se klasifikacija temelji na cjelovitoj analizi svake slike, uklanjanje bilo kojeg dijela slike može rezultirati gubitkom ključnih značajki lubanji, što može negativno utjecati na točnost i pouzdanost klasifikacije.

3.2. Sintetičko generiranje podataka GAN-om

Generativno modeliranje, kao strategija za povećanje skupa podataka, otvorilo je nova vrata u svijetu umjetne inteligencije. Odnosi se na stvaranje umjetnih instanci iz skupa podataka koje zadržavaju karakteristike slične originalnom skupu podataka. Generativne suparničke mreže predstavljaju temeljni okvir u ovom području. Prema [37], GAN-ovi su revolucionarni jer omogućuju „otključavanje“ dodatnih informacija iz skupa podataka. GAN-ovi uče reprezentacije iz podataka bez potrebe za označenim skupom podataka koristeći mehanizme suparničkog učenja koji uključuju par neuronskih mreža. Ova tehnika se ističe svojom brzinom računanja i kvalitetom rezultata u odnosu na druge tehnike generativnog modeliranja. Kroz razne primjene, od sinteze slika do semantičke obrade slika, GAN-ovi su donijeli značajne promjene u mnogim područjima.

GAN-ovi su originalno bili zamišljeni kao potpuno nenadzirani okvir sposoban za generiranje realističnih sintetičkih slika iz nasumičnog šuma. Međutim, uvođenjem cGAN-a [38] ovaj okvir je dobio mogućnost transformacije u nadzirani generativni okvir. Uvjetni GAN-ovi stvaraju specifične vrste slika koristeći unaprijed poznate informacije, poput oznaka klasa, za usmjeravanje procesa generiranja. Dakle, uvjetni GAN-ovi uvođenjem elementa nadzora proširuju primjenjivost generativnih modela. Osim cGAN-a, razvijaju se i brojne druge varijante GAN-a koje su prikazane na Slici 3.2.



Slika 3.2 Hijerarhijski prikaz različitih vrsta GAN-ova (prema [39])

Među njima se ističu duboki konvolucijski GAN (engl. *deep convolutional generative adversarial network* - DCGAN) [40] i Pix2pix [41], kao i CycleGAN [42]. DCGAN koristi konvolucijske slojeve, zajedno s aktivacijskim funkcijama LeakyReLU/ReLU, koji doprinose stabilizaciji uvježbavanja GAN-ova kod slika veće rezolucije. S druge strane, Pix2pix, umjesto nasumičnog šuma, kao ulaz u generator prima slike čime se ostvaruje translacija iz slike u sliku. CycleGAN uvodi koncept cikličke konzistentnosti omogućujući uvježbavanje GAN-a i u situacijama kada podatci nisu upareni, odnosno kada za svaku ulaznu sliku ne postoji točno odgovarajuća izlazna slika. Sukladno tomu, CycleGAN se ističe kao najbolje rješenje u situacijama gdje je cilj transformirati sliku iz jednog stila u drugi bez striktno definiranih parova.


Unatoč potencijalu svih spomenutih varijanti GAN-ova, u ovom istraživanju će se koristiti DCGAN i cGAN. Sukladno tomu, samo će se te arhitekture detaljnije analizirati.

3.2.1. Arhitektura

Prije analize kompleksnijih arhitektura, treba proučiti opću arhitekturu GAN-ova. Naime, arhitekturu GAN-a čine dvije duboke neuronske mreže koje se nazivaju generator i diskriminator. Za početak je bitno razumjeti kako generator stvara slike. Proces [43]


započinje uzorkovanjem šuma z iz normalne ili uniformne distribucije. Koristeći z kao ulaz, generator G stvara sliku x , što se zapisuje kao $x = G(z)$. Konceptualno, z predstavlja latentne značajke generiranih slika kao što su boja i oblik. Uz to, ne kontrolira se semantičko značenje z , već se dopušta da se to nauči tijekom procesa uvježbavanja. Na primjer, ne određujemo koji bajt u z određuje boju kose. Da bismo otkrili njegovo značenje, najučinkovitiji način je vizualizacija generiranih slika i njihovo analiziranje.

Postavlja se pitanje što je zapravo generator G . Jedan od popularnih arhitektura za mrežu generatora je DCGAN koji će se detaljno analizirati u idućem poglavlju. Međutim, generator bi bez usmjerenja diskriminatora stvarao samo nasumični šum. Uloga diskriminatora u arhitekturi GAN-a je pružiti smjernice generatoru o tome kakve slike treba stvarati. Diskriminator se uvježbava s pravim i generiranim slikama kako bi se izgradila sposobnost prepoznavanja karakteristika koje čine slike stvarnima. Zahvaljujući toj sposobnosti, diskriminator šalje povratne informacije generatoru za stvaranje slika koje više nalikuju pravim slikama, kao što je vizualizirano na Slici 3.3.



Slika 3.3 Prikaz rada GAN-a na višoj razini (prema [43])


Iz tehničkog aspekta, prikazanog na Slici 3.4, proces funkcionira tako da diskriminator promatra stvarne slike (uzorke za uvježbavanje) i generirane slike odvojeno. Dakle, razlikuje slike koje ulaze u diskriminator na stvarne i generirane. Izlaz $D(x)$ je vjerojatnost da je ulaz x stvarna slika, odnosno $P(\text{klasa ulaza} = \text{stvarna slika})$.



Slika 3.4 Osnovna arhitektura GAN-a (prema [43])

Diskriminator se zapravo uvježbava kao duboka mreža za klasifikaciju. U slučaju da je izlaz stvaran cilj je dobiti $D(x) = 1$. Ako je generiran, tada bi trebalo vrijediti $D(x) = 0$. Kroz ovaj proces diskriminator identificira značajke koje doprinose stvarnim slikama.

S druge strane, cilj je da generator stvara slike $D(x) = 1$ što znači da generirane slike odgovaraju stvarnoj slici. Stoga, generator se može uvježbavati kroz proces unazadne propagacije (engl. *backpropagation*) gdje se ciljna vrijednost (stvaranje slika koje diskriminator identificira kao stvarne) prenosi natrag kroz mrežu do samog generatora. Spomenuti proces vizualiziran je na Slici 3.5. Cilj je usavršiti generator u stvaranju slika koje diskriminator ne može razlikovati od stvarnih.



Slika 3.5 Prikaz učenja GAN-a (prema [43])

Obje mreže se uvježbavaju naizmjenično tako da se generator i diskriminator stalno natječu s ciljem da nadmaše jedan drugog. Ovaj proces uzajamnog „nadmetanja“ neprestano poboljšava sposobnost generatora da stvara uvjerljive slike, dok istovremeno diskriminator postaje sve precizniji u razlikovanju stvarnih slika od generiranih. Konačno, model konvergira i generira slike koje izgledaju prirodno.

Potom se razmatra kako se objašnjeni koncepti mogu matematički zapisati. Izlaz iz diskriminatora $D(x)$ označuje šansu da je slika x stvarna. Cilj je maksimizirati šanse za poznavanje stvarnih slika kao stvarnih i generiranih slika kao lažnih. Za mjerenje gubitka koristi se unakrsna entropija (engl. *cross-entropy*): $p \log q$. Za stvarne slike vrijednost p

(oznaka za stvarne slike) je jednaka 1, a za generirane slike oznaka se postavlja na suprotnu vrijednost, odnosno na -1. Stoga, cilj diskriminatora se zapisuje kao:

$$\max V(D) = \mathbb{E}_{x \sim p_{data}(x)}[\log D(x)] + \mathbb{E}_{z \sim p_z(z)}[\log(1 - D(G(z)))] \quad (3.9)$$


S druge strane, cilj funkcije generatora je da model generira slike s najvišom mogućom vrijednošću $D(x)$ kako bi prevario diskriminator:

$$\min V(G) = \mathbb{E}_{z \sim p_z(z)}[\log(1 - D(G(z)))] \quad (3.10)$$

U literaturi se GAN često opisuje kao „minimax“ igra u kojoj G želi minimizirati V , dok ga D želi maksimizirati, što je zapisano izrazom (3.11).

$$\min \max V(D, G) = \mathbb{E}_{x \sim p_{data}(x)}[\log D(x)] + \mathbb{E}_{z \sim p_z(z)}[\log(1 - D(G(z)))] \quad (3.11)$$

Nakon definicija ciljnih funkcija, obje se uvježbavaju zajedno korištenjem naizmjenične primjene algoritma gradijentnog spusta (engl. *gradient descent*). Prvo se fiksiraju parametri modela generatora i izvršava se jedna iteracija gradijentnog spusta na diskriminatoru koristeći stvarne i generirane slike. Zatim se mijenjaju strane, fiksira se diskriminator i uvježbava se generator za još jednu iteraciju. Objе mreže uvježbavaju se naizmjenično dok generator ne proizvede slike visoke kvalitete. Na Slici 3.6 prikazan je sažetak toka podataka i gradijenata korištenih za unazadnu propagaciju.



Slika 3.6 Sažetak cijelog procesa uvježbavanja GAN-a (prema [43])

Tijekom uvježbavanja GAN-a, diskriminator uvježbava razlikovanje stvarnih i generiranih slika, dok generator uvježbava stvaranje sve uvjerljivijih slika. Kroz proces natjecanja GAN uspijeva stvoriti izuzetno realistične sintetičke slike koje su naizgled ne razlikuju od stvarnih.


Ova sposobnost generiranja visokokvalitetnih slika čini GAN-ove iznimno korisnim u raznim primjenama, od sinteze slika do poboljšanja rezolucije i klasifikacije slika.

Jedan od problema koji se javlja kod uvježbavanja generatora je problem smanjenja gradijenta. Diskriminator u ranim fazama obično brzo nadjača generator jer je lakše razlikovati generirane slike od stvarnih slika. Tada vrijednost funkcije gubitka V teži prema nuli, što se zapisuje kao $-\log(1 - D(G(z))) \rightarrow 0$. To uzrokuje nestajanje gradijenta za generator čime se postupak optimizacije gradijentnim spustom znatno usporava. Kako bi se smanjio utjecaj ovog problema, predlaže se alternativna funkcija koja omogućuje efikasnije propagiranje gradijenta prema generatoru, a zapisana je kao:

$$-\nabla_{\theta_g} \log(1 - D(G(z^i))) \rightarrow 0 \text{ mijenja se u } \nabla_{\theta_g} \log(D(G(z^i))) \quad (3.12)$$

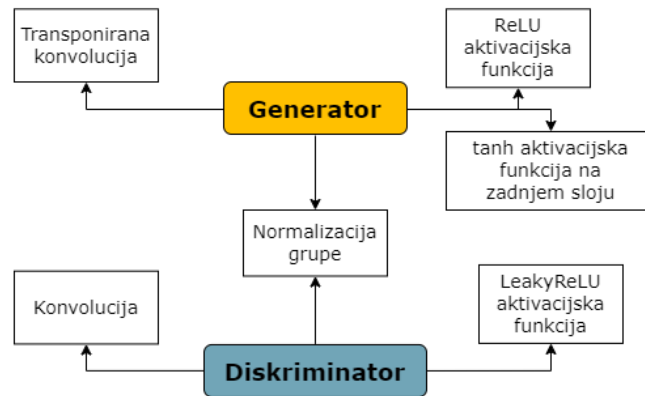
3.2.2. Duboki konvolucijski GAN

Duboke konvolucijske generativne suparničke mreže predstavljaju inovativnu arhitekturu unutar domene generativnih modela. U arhitekturi DCGAN-a, prikazanoj na Slici 3.7, diskriminator koristi standardne konvolucijske slojeve za analizu i razlikovanje stvarnih od generiranih slika, dok generator koristi transponirane konvolucijske slojeve [44]. Ovi slojevi, koji se mogu shvatiti kao inverzija standardne konvolucije, zamjenjuju tradicionalne sažimajuće slojeve (engl. *pooling layer*). Također omogućuju povećavanje uzoraka (engl. *up-sampling*), odnosno povećavanje dimenzija ulazne značajke, što generatoru omogućuje da od manje dimenzionalnog prostora stvara slike veće rezolucije. Transponirana konvolucija ne invertira standardnu konvoluciju po vrijednostima, već samo po dimenzijama. Sukladno tomu, krajnji rezultat je prostorno veća slika koja proizlazi iz manjeg skupa značajki. Standardni konvolucijski slojevi rade tako da primjenjuju skup filtara na ulazne slike kako bi izdvojili važne značajke, dok transponirani konvolucijski slojevi rade suprotno - uzimaju sažete značajke i pretvaraju ih u veće slike.



Slika 3.7 Arhitektura generatora i diskriminatora u DCGAN-u (prema [45])


Potom, arhitekturu DCGAN-a [46] karakterizira aktivacijska funkcija ReLU u cijelom generatoru, osim u posljednjem sloju gdje se koristi aktivacijska funkcija Tanh. S druge strane, diskriminator uvijek koristi LeakyReLU kao aktivacijsku funkciju, što doprinosi povećanju performansi u odnosu na klasične ReLU funkcije. Korištenje ovih aktivacijskih funkcija, zajedno s primjenom normalizacije grupe (engl. *batch normalization*) u oba modela, doprinosi stabilnosti tijekom procesa uvježbavanja i generiranja kvalitetnih slika. Kao optimizator u DCGAN-u koristi se Adam uz stohastički gradijentni spust. Sve spomenute ključne komponente arhitekture DCGAN-a prikazane su na Slici 3.8. Uz to, za razliku od tradicionalnih metoda koje se oslanjaju na logaritamsku vjerojatnost, evaluacija DCGAN-a bazira se na točnosti klasifikacije i stopi grešaka. Ovaj pristup omogućuje detaljnije razumijevanje učinkovitosti modela i kvalitete generiranih slika.



Slika 3.8 Komponente DCGAN arhitekture (prema [44])

3.2.3. Uvjetni GAN

Uvjetne generativne suparničke mreže [38] predstavljaju značajnu modifikaciju standardnog GAN modela, kao što je prikazano na Slici 3.9. Naime, uvodi se koncept uvjetovanja generativnog procesa korištenjem dodatnih informacija poput oznaka klasa ili drugih relevantnih atributa. Ova inovacija omogućuje generiranje specifičnih vrsta podataka s ciljnim oznakama čime se povećava raznolikost i preciznost generiranih slika. Dakle, specifičnost arhitekture cGAN-a je informacija y koja je implementirana kao dodatni ulazni sloj u generator i diskriminator. U generatoru se nasumični ulazni šum z kombinira s uvjetom y , stvarajući zajedničku skrivenu reprezentaciju koja se koristi za generiranje slika. Diskriminator, pak, prima stvarne podatke x zajedno s uvjetom y i generirane slike $G(z)$, kako bi razlikovao stvarne i generirane slike. Poput standardnih GAN-ova, cGAN također koristi stohastički gradijentni spust za uvježbavanje i procjenu logaritamske vjerojatnosti za evaluaciju rezultata [38].



Slika 3.9 Usporedba GAN-a i cGAN-a (prema [44])

Funkcija gubitka (engl. *loss function*) [47] za cGAN modificirana je dodavanjem uvjeta y . U matematičkom smislu, funkcija gubitka uključuje uvjet y u izračunavanju vjerojatnosti da su slike koje diskriminator procjenjuje stvarne $D(x|y)$ ili generirane $G(z|y)$. Nakon tih promjena, gubitak se može zapisati kao:

$$\min \max V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x|y)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z|y)))] \quad (3.13)$$

Ova modifikacija omogućuje cGAN-u da kontrolira izlaz generatora, što rezultira boljim razlikovanjem stvarnih slika.

CGAN se pokazao posebno korisnim u domenama gdje je raznolikost generiranih podataka od ključnog značaja, poput medicinske slike, gdje različite vrste slika zahtijevaju specifične uvjete za generiranje. Zbog svoje sposobnosti da generira podatke s ciljnim oznakama, cGAN je postao popularan alat u različitim domenama gdje se zahtijeva visoka razina točnosti generiranih podataka.


4. Modeli strojnog učenja

Strojno učenje je grana umjetne inteligencije koja omogućuje računalima da uče iz iskustva i obavljaju zadatke bez eksplicitnog programiranja. Duboko učenje (engl. *deep learning*), kao napredna tehnika unutar strojnog učenja, postiglo je izuzetne uspjehe u područjima poput računalnog vida i obrade prirodnog jezika. Ono se oslanja na primjenu umjetnih neuronskih mreža koje mogu otkriti kompleksne obrasce u visokodimenzionalnim podatcima. Radi se o skupini tehnika strojnog učenja koje koriste neuronske mreže za aproksimaciju funkcija.

Postoje različite vrste neuronskih mreža od kojih svaka ima svoju specifičnu primjenu. Konvolucijske neuronske mreže (CNN) su iznimno učinkovite u obradi vizualnih podataka, dok rekurentne neuronske mreže (RNN) dominiraju u analizi sekvencijalnih podataka poput jezika, govora ili vremenskih serija. Ovo istraživanje fokusira se na primjenu konvolucijskih neuronskih mreža u okviru prijenosnog učenja. U nastavku su predstavljane osnove neuronskih mreža, nakon čega se obrađuju konvolucijske neuronske mreže, a zatim analizira koncept prijenosnog učenja i odabrane modele.

4.1. Osnove neuronskih mreža

Perceptron [48] predstavlja osnovnu komponentu umjetnih neuronskih mreža. Njegova funkcija je primiti ulazne podatke, pomnožiti ih s težinama (engl. *weights*) i dati izlaz na temelju definiranog praga (engl. *bias*). Težine u ovom kontekstu služe kao pokazatelji snage veza između čvorova unutar mreže, dok se prag može prilagođavati tijekom procesa uvježbavanja mreže. Pojednostavljeno rečeno, perceptron, čija je struktura prikazana na Slici 4.1, se može shvatiti kao funkcija koja kombinira ulaze kako bi stvorila izlaz.



Slika 4.1 Perceptron (prema [49])

U umjetnoj neuronskoj mreži, perceptroni su organizirani u slojeve koji formiraju sekvencijalnu strukturu. Svaki perceptron unutar tih slojeva provodi jednostavne, ali nelinearne izračune. Ova sposobnost provođenja nelinearnih izračuna čini neuronske mreže izuzetno sposobnima za aproksimaciju složenih funkcija koje se ne mogu jednostavno opisati linearnim modelima.

Neuronske mreže predstavljaju napredak u odnosu na tradicionalno programiranje, omogućujući računalima da samostalno uče i prilagođavaju se zahvaljujući ulaznim podacima i željenim izlazima. Ovaj pristup omogućuje mrežama da formiraju vlastite metode rješavanja problema bez potrebe za detaljnim programiranjem svake funkcije. Postoje dvije osnovne vrste neuronskih mreža: prve su one s jednosmjernim protokom informacija (engl. *feedforward*) koje se često koriste za analizu podataka, a druge one u kojima se informacije kreću u oba smjera (engl. *feedback*) čineći ih idealnima za kompleksne zadatke kao što su optimizacija i obrada sekvencijalnih podataka.

U procesu uvježbavanja i razvoja neuronskih mreža, postoji nekoliko koncepata koji su presudni za učinkovitost i sposobnost rješavanja složenih zadataka [48]:

- Aktivacijska funkcija - oblikuje izlazne vrijednosti na temelju ulaznih podataka te je sastavni dio svake jedinice u neuronskoj mreži. Ova funkcija uvodi nelinearnost u mrežu čime omogućuje učenje složenih veza među podacima. Postoje različite aktivacijske funkcije, kao što su sigmoidna, ReLU i softmax, koje se biraju ovisno o problemima i njihovim karakteristikama.

- Funkcija gubitka - mjeri razliku između predviđenih izlaza mreže i stvarnih vrijednosti te je ključna za procjenu performansi mreže. Cilj je minimizirati vrijednost funkcije gubitka kako bi se poboljšala usklađenost između predviđanja mreže i stvarnih podataka.
- Unazadna propagacija greške - algoritam koji omogućuje da se greške, izračunate na izlaznom sloju, šalju natrag prema ulazima mreže, pri čemu se prilagođavaju težine neurona. Proces uključuje korištenje parcijalnih derivacija za izračun gradijenta funkcije gubitka u odnosu na težine, koji se potom koristi za njihovo ažuriranje.
- Gradijent - označava smjer i veličinu promjene vrijednosti funkcije gubitka u odnosu na težine u mreži. Računanje gradijenta ključno je za različite optimizacijske algoritme kao što je gradijentni spust.

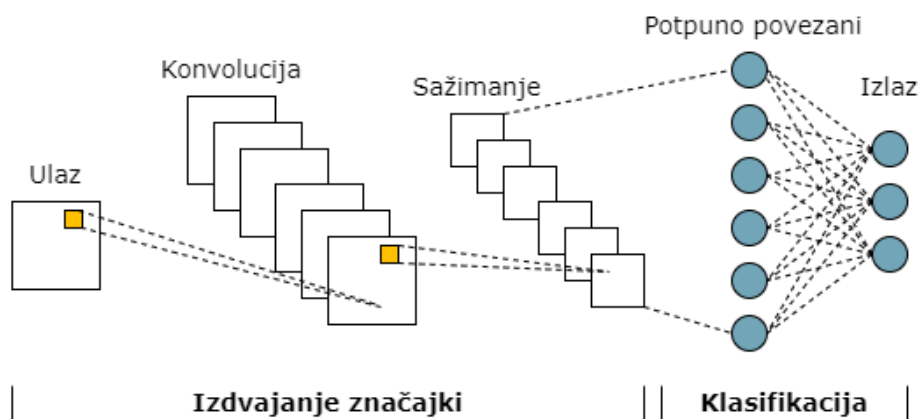
Kombinirajući ove elemente, neuronske mreže postižu sposobnost učenja složenih funkcija i izvođenja različitih zadataka. Ovi koncepti zajedno tvore temelj za učinkovito učenje u neuronskim mrežama čineći ih ključnim aspektima dubokog učenja.

4.2. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže su napredni algoritmi dubokog učenja, specijalno prilagođeni za analizu vizualnih podataka poput slika i videozapisa. One se ističu sposobnošću prepoznavanja različitih elemenata unutar slike, pridajući im važnost kroz težine i pristranosti koje se uče tijekom procesa uvježbavanja. Sposobnost razlikovanja pojedinih elemenata čini ih superiornijim u odnosu na tradicionalne algoritme klasifikacije koji često zahtijevaju opsežnu prethodnu obradu podataka. Nadalje, važno je razmotriti prednosti konvolucijskih neuronskih mreža [50] u odnosu na neuronske mreže s jednosmjernim protokom informacija. Iako bi se slike mogle jednostavno pretvoriti u vektorski oblik i koristiti u višeslojnim perceptronima, ovakav način ne bi bio adekvatan za složene slike s ovisnostima među pikselima. Konvolucijske neuronske mreže spomenuti problem rješavaju primjenom posebnih filtara koji olakšavaju hvatanje prostornih i vremenskih veza na slici. Njihova struktura omogućuje prilagođavanje skupu podataka uz smanjenje broja parametara i mogućnost ponovnog korištenja težina.

Arhitektura konvolucijske neuronske mreže, vizualizirana na Slici 4.2, se sastoji od triju osnovnih vrsta slojeva [52]:

- Konvolucijski slojevi – srž su konvolucijskih mreža i odgovorni za većinu računalnih operacija. U konvolucijskim slojevima, ulazni podatci prolaze kroz filtre koji izdvajaju i analiziraju značajke iz slike, pri čemu se zadržavaju prostorne veze među pikselima. Operacija konvolucije koristi se za obradu ulaznih podataka gdje se male matrice, poznate kao kerneli, pomiču preko slike množeći svoje vrijednosti s vrijednostima piksela. Ovo omogućuje detaljno filtriranje i prepoznavanje određenih karakteristika, poput rubova, tekstura i oblika unutar slike.
- Sažimajući slojevi – namijenjeni su za smanjenje dimenzionalnosti obrađenih podataka iz konvolucijskih slojeva. Glavna uloga im je smanjenje broja parametara potrebnih za obradu. Postoje dva osnovna tipa sažimanja: maksimalno sažimanje koje odabire najveću vrijednost unutar određenog područja i prosječno sažimanje koje računa prosjek vrijednosti unutar tog područja. Cilj oba tipa je izdvajanje dominantnih značajki iz slike.
- Potpuno povezani slojevi - slojevi koji povezuju sve neurone u mreži omogućujući globalnu interakciju između različitih dijelova slike. Za razliku od konvolucijskih i sažimajućih slojeva, koji se fokusiraju na lokalne prostorne regije, potpuno povezani slojevi integriraju sve značajke i transformiraju ih u konačne izlaze poput klasifikacije ili regresijskih vrijednosti.

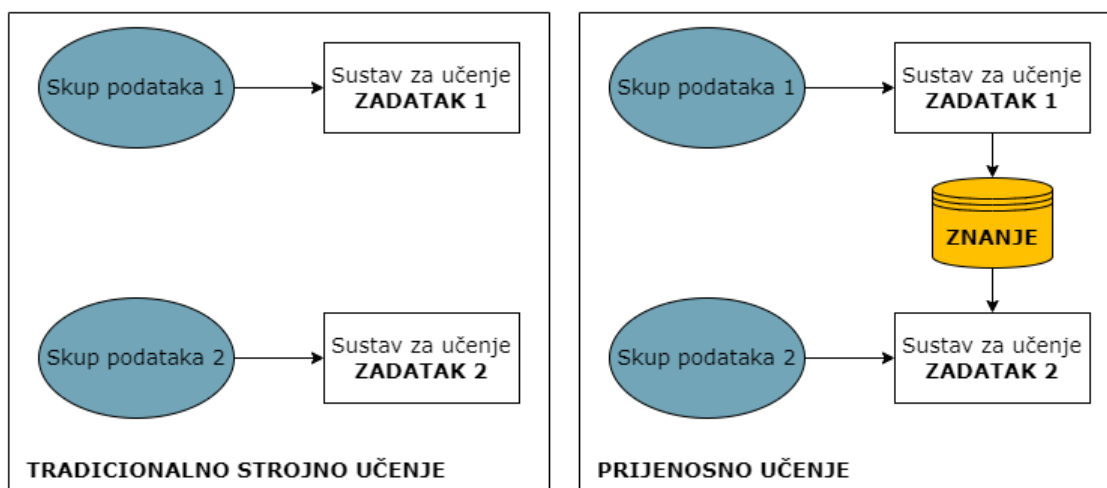


Slika 4.2 Arhitektura konvolucijske neuronske mreže (prema [51])

Spomenuti slojevi zajedno omogućuju konvolucijskim neuronskim mrežama prepoznavanje složenih uzoraka u slikama ili drugim vizualnim podacima. Kroz arhitekturu koja obuhvaća konvolucijske, sažimajuće i potpuno povezane slojeve, mreža može efikasno izdvajati značajke, reducirati njihovu dimenzionalnost te ih klasificirati ili analizirati, što je nužno za različite primjene u području računalnog vida i drugih vizualnih analiza.

4.3. Prijenosno učenje

Prijenosno učenje nije koncept karakterističan isključivo za duboko učenje, već se značajno razlikuje od tradicionalnog pristupa izgradnje i uvježbavanja modela strojnog učenja. Temeljna razlika, vizualizirana na Slici 4.3, je u metodologiji i principima koje prijenosno učenje donosi. Tradicionalno učenje se temelji isključivo na specifičnim zadacima, skupovima podataka i uvježbavanju odvojenih modela za te zadatke. U takvom pristupu nema prijenosa znanja s jednog modela na drugi. Nasuprot tomu, prijenosno učenje [3] omogućuje korištenje znanja iz prethodno uvježbanih modela za uvježbavanje novih, čak i u situacijama kada postoji manjak podataka za novi zadatak. Dakle, ako postoji znatno više podataka za prvi zadatak, može se koristiti njegovo znanje (značajke, težine itd.) i generalizirati ga za drugi zadatak (sa znatno manje podataka). U problemima računalnog vida određene značajke na niskoj razini (engl. *low level*), poput rubova, oblika, kutova i intenziteta, mogu se dijeliti među zadacima, omogućujući na taj način prijenos znanja.



Slika 4.3 Usporedba tradicionalnog strojnog učenja i prijenosnog učenja (prema [53])

Nadalje, postoje dvije glavne strategije primjene dubokog prijenosnog učenja [53]: korištenje prethodno uvježbanih modela za izdvajanje značajki i fino podešavanje prethodno uvježbanih modela. Da bi prva strategiju prijenosnog učenja bila jasnija, važno je razumjeti da su duboke mreže zapravo kompleksne arhitekture gdje se različite značajke uče na različitim slojevima. Ovi slojevi su na kraju povezani s posljednjim slojem (obično potpuno povezanim slojem u nadziranom učenju) kako bi se dobio konačni izlaz. Takva slojevita arhitektura omogućuje korištenje prethodno uvježbane mreže, bez njenog završnog sloja, za izdvajanje značajki u drugim zadacima. Glavna ideja je iskoristiti slojeve prethodno uvježbanog modela za izdvajanje značajki, ali ne ažurirati težine slojeva modela tijekom uvježbavanja s novim podacima za novi zadatak. Na primjer, izostavljanje završnog klasifikacijskog sloja prilikom korištenja ResNet50 pomaže transformirati slike u 2048-dimenzionalni vektor. To omogućuje izdvajanje značajki iz slika novog domenskog zadatka koristeći znanje stečeno u izvornoj domeni.

Druga strategija prijenosnog učenja, koja uključuje fino podešavanje prethodno uvježbanih modela, složenija je u usporedbi s prvom. Spomenuta strategija ne podrazumijeva samo zamjenu završnog sloja modela, već i selektivno uvježbavanje prethodnih slojeva. Takav pristup omogućuje „zamrzavanje“ određenih slojeva (fiksiraju se njihove težine), dok se ostali prilagođavaju, odnosno fino podešavaju prema potrebama zadatka. Prilikom prilagođavanja koristi se postojeće znanje o arhitekturi mreže, a njena prethodna stanja koriste se kao polazište za prilagodbu. Na taj način se postižu bolji rezultati uz kraće vrijeme uvježbavanja. Kada se donosi odluka o zamrzavanju slojeva mreže ili finom podešavanju, važno je uzeti u obzir specifičnosti zadatka i dostupnost podataka. Zamrzavanje slojeva i korištenje mreže kao izvora značajki je ponekad dovoljno, no u drugim situacijama fino podešavanje slojeva pruža bolje rezultate [53]. Fino podešavanje je posebno važno ako se novi zadatak znatno razlikuje od izvornog za koji je model inicijalno uvježban.

Prijenosno učenje pruža rješenja za složene probleme s različitim ograničenjima [3]. Primjerice, rješava izazove poput onih gdje postoji malo ili gotovo nema dostupnih označenih podataka, što je čest slučaj u stvarnim primjenama. Osim toga, olakšava prijenos znanja s jednog modela na drugi prilagođavajući ih određenim domenama i zadacima. Kroz ovakav pristup, prijenosno učenje otvara put prema ostvarenju ideje opće umjetne

inteligencije (engl. *artificial general intelligence*) [53], potencirajući razvoja modela koji mogu obavljati širok spektar zadataka u različitim okruženjima i uvjetima.


U području računalnog vida postoji nekoliko popularnih modela koji se često koriste poput VGG-16, VGG-19, InceptionV3, Xception i ResNet50. U daljnjem istraživanju i primjeni prijenosnog učenja fokus je stavljen na ResNet50, koji nudi izvrsnu osnovu za različite primjene u računalnom vidu.

4.3.1. ResNet50

ResNet50 [54] je konvolucijska neuronska mreža koja predstavlja inačicu popularne ResNet arhitekture posebno uspješne u klasifikaciji slika. ResNet je skraćena za „Residual Network“ (rezidualna mreža), a broj 50 u njenom nazivu predstavlja broj slojeva unutar mreže. Ključna inovacija ResNet50 je upotreba rezidualnih veza koje omogućuju mreži da uči skup rezidualnih funkcija i tako preslikavaju ulaz u željeni izlaz. Rezidualne veze olakšavaju učenje u izuzetno dubokim mrežama bez problema nestajućih gradijenata.


Arhitektura ResNet50, prikazana na Slici 4.4, podijeljena je na četiri glavna dijela [55]:

- Konvolucijski slojevi – zaduženi za izdvajanje značajki iz ulazne slike poput rubova, tekstura i oblika.
- Identitetski blok i konvolucijski blok - obrađuju i transformiraju izdvojene značajke. Identitetski blok prosljeđuje ulazne podatke kroz niz konvolucijskih slojeva i dodaje ulazne podatke na izlaz, omogućujući mreži da uči rezidualne funkcije. Konvolucijski blok funkcionira slično, ali uključuje dodatni 1x1 konvolucijski sloj za smanjenje broja filtara prije 3x3 konvolucijskog sloja.
- Potpuno povezani slojevi - odgovorni su za konačnu klasifikaciju. Izlaz posljednjeg potpuno povezanog sloja se šalje u aktivacijsku funkciju *softmax* kako bi se dobile konačne klase.



Slika 4.4 ResNet50 arhitektura (prema [55])

Mreža ResNet50 koristi rezidualne veze, poznate i kao veze preskakanja (engl. *skip connections*), kako bi prevladala problem nestajućih gradijenata. Problem nastaje kada gradijenti parametara u dubljim slojevima postaju neprimjetno mali čime se otežava učenje. Veze preskakanja omogućuju direktan protok informacija kroz mrežu zaobilazeći određene slojeve. Tako mreža uči rezidualne funkcije, kao što je prikazano na Slici 4.5, umjesto cjelokupnog mapiranja od ulaza do izlaza. Upotrebom ovih veza zadržava se sposobnost učenja i prilagodbe, čak i u dubokim arhitekturama.



Slika 4.5 Rezidualni blok (prema [54])


5. Realizacija

Za razvoj i testiranje modela dubokog učenja u ovom projektu koristio se programski jezik Python. Kao razvojno okruženje poslužio je Jupyter Notebooka na platformi Google Colab [56], koja je pružila pristup naprednim resursima poput T4 GPU-a i 12.7 GB RAM-a. Ova konfiguracija osigurala je potrebnu računalnu snagu za brzu obradu i efikasno uvježbavanje modela. Nadalje, TensorFlow [57], koji je razvio Google Brain tim, koristio se za implementaciju modela dubokog učenja – GAN-ova i prijenosnog učenja. Pandas [58] je bio neophodan za upravljanje podacima, a NumPy [59] za obradu nizova i matrica. Za vizualizaciju podataka korištene su biblioteke Matplotlib [60] i Seaborn [61], koje omogućuju prikazivanje rezultata analiza i modela. Zatim, Scikit-learn [62] se koristio za evaluaciju modela, točnije za izračunavanje različitih metrika poput točnosti i matrice zabune (engl. *confusion matrix*). Kombinirajući spomenute alate i biblioteke, složeni modeli dubokog učenja su uspješno realizirani, uvježbani i evaluirani. Cijeli kod potreban za realizaciju ovog projekta dostupan je na [63].


U sljedećim poglavljima detaljno su objašnjeni svi koraci potrebni za realizaciju projekta, uključujući informacije o podacima, odabranim klasičnim tehnikama povećavanja skupa podataka, odabranim arhitekturama GAN-ova i postupku odabira modela za prijenosno učenje.

5.1. Podatci

U okviru ovog istraživanja fokus je na klasifikaciji spola na temelju MSCT snimaka glava 220 pacijenata s jednakim brojem žena i muškaraca. Pacijenti koji su pretrpjeli traumu glave su isključeni iz istraživanja. Za ovaj projekt koristile su se slike dobivene 3D rekonstrukcijom MSCT snimaka pomoću softvera OsiriX [64]. Pritom, pohranjena su tri različita prikaza svake lubanje: sa strane (lateralni), sprijeda (frontalni) i straga (okcipitalni). Primjeri podataka su prikazani na Slici 5.1 i Slici 5.2, gdje se na jednoj vidi ženska, a na drugoj muška lubanja, demonstrirajući razlike koje su ujedno i motiv istraživanja.



Slika 5.1 Primjer lubanje žene



Slika 5.2 Primjer lubanje muškarca

Morfološke razlike između lubanja muškaraca i žena se uočavaju kroz nekoliko ključnih karakteristika [65]. Općenito su lubanje muškaraca veće i robusnije, s posebno naglašenim obrvama i čelom, dok su lubanje žena manje i delikatnije s blažim crtama. Nadalje, muške čeljusti su šire i oštrije, dok su ženske zaobljene i finije s blažim kutom vilice. Još jedna od razlika su očne šupljine koje su kod muškaraca izraženije, a kod žena okruglije i manje istaknute. Spomenute karakteristike lubanja su korisni pokazatelji za identifikaciju spola, no ključno je prepoznati i široki spektar varijacija koje se javljaju među pojedincima, rasama i u različitim podnebljima. Ove razlike naglašavaju potrebu za pažljivom analizom i razumijevanjem da svaki uzorak nosi jedinstveni skup obilježja.

Sve slike su ujednačene na veličinu od 700x700 piksela kako bi se osigurala konzistentnost u analizi. Za potrebe realizacije modela, 70% podataka iskorišteno je za uvježbavanje

modela, a ostalih 30% za testiranje modela. Dakle, skup za uvježbavanje sastoji se od 153 podatka, a skup za testiranje od 67 podataka od kojih ima 33 žene i 34 muškarca.

5.2. Postupak povećavanja skupa podataka

Jedan od aspekata na koje se ovo istraživanje fokusira je analiza i usporedba odabranih klasičnih tehnika za povećanje skupa podataka, kao i primjena sintetičkog generiranja podataka. Detaljno se razmatra učinkovitost određenih klasičnih metoda, čak i onih koje su dovele do pogoršanja rezultata. Nadalje, tumače se pristupi korišteni u sintetičkom generiranju podataka GAN-om i cGAN-om uz vizualizaciju generiranih uzoraka.

5.2.1. Klasične tehnike

Za realizaciju klasičnih tehnika povećanja skupa podataka koristi se ImageDataGenerator iz biblioteke Keras. Spomenuti generator funkcionira tako da preuzima ulazne podatke, nasumično ih transformira i vraća isključivo rezultate tih transformacija. Preciznije, ne uključuje originalne podatke, već samo nove izmijenjene verzije. Na taj način se umjetno proširuje skup podataka i poboljšava učenje modela zahvaljujući raznovrsnijim primjerima.

Jedna od transformacije koje su doprinijele poboljšanju rezultata je rotacija u rasponu od 15 stupnjeva. Dakle, slika se nasumično rotira za vrijednost između -15° i $+15^\circ$, što olakšava prepoznavanje objekata u različitim orijentacijama. Riječ je o geometrijskoj augmentaciji koja mijenja položaj i perspektivu objekata unutar slike. Nadalje, rasponom osvjetljenja se prilagođava intenzitet svjetlosti na slikama, što modelu omogućuje prilagođavanje na promjenjive svjetlosne uvjete. Kao fotometrijska augmentacija, ova tehnika mijenja boje i osvjetljenje slike bez izmjena njena oblika. Primjena ovih tehnika, prikazanih na Slici 5.3, rezultirala je poboljšanjem rezultata za 3% demonstrirajući njihov značaj u procesu uvježbavanja modela.




Slika 5.3 Odabrane tehnike za lateralni pogled

Osim spomenutih dviju tehnika, isprobano je i horizontalno zrcaljenje. Primjeri dobiveni primjenom svih triju metoda prikazani su na Slici 5.4. Kao metoda geometrijske augmentacije, horizontalno zrcaljenje mijenja prostorni raspored elemenata na slici pružajući modelu širi spektar uzoraka za učenje. Ipak, potreban je oprez pri korištenju navedene tehnike jer može imati neželjene učinke u nekim kontekstima, kao što je bio slučaj u ovom istraživanju, gdje su zrcaljene slike izazvale konfuziju kod modela te utjecale na smanjenje točnosti za 2%.



Slika 5.4 Tehnike koje pogoršavaju rezultate - lateralni pogled

Nadalje, kada je riječ o frontalnom pogledu, korištene su iste tehnike kao kod lateralnog – rotacija i raspon osvjjetljenja, što je prikazano na Slici 5.5. Upravo su te tehnike dovele do povećanja točnosti modela za otprilike 3%.




Slika 5.5 Odabrane tehnike za frontalni pogled

S ciljem pokušaja poboljšanja modela, korištene su i metode poput horizontalnog pomicanja i vertikalnog pomicanja slike, oba postavljena na 10% dimenzija slike. Ove metode, poznate u sklopu geometrijskih augmentacija, namijenjene su pružanju modelu iskustva s objektima na različitim položajima unutar slike, čime se teoretski povećava njegova sposobnost generalizacije. Dodatno, korišten je *fill_mode* postavljen na *nearest*, kako bi se popunile praznine koje su nastale pomicanjem slike najbližim pikselima, osiguravajući tako glatke i prirodne prijelaze. Međutim, unatoč teoretskim prednostima, ove tehnike nisu donijele očekivana poboljšanja, već su pogoršale rezultat za čak 6%.



Slika 5.6 Tehnike koje pogoršavaju rezultate - frontalni pogled

Iste spomenute metode – rotacija i svjetlina, donijele su poboljšanje i u okcipitalnom pogledu. Također, tehnike horizontalnog pomicanja i vertikalnog pomicanja slike, donijele su pad točnosti za 5%, u odnosu na situaciju bez ikakvih tehnika povećavanja skupa podataka. Na Slici 5.7 prikazane su tehnike koje su doprinijele poboljšanju modela za 4%, a na Slici 5.8 one koje su rezultirale spomenutim padom točnosti.



Slika 5.7 Odabrane tehnike za okcipitalni pogled



Slika 5.8 Tehnike koje pogoršavaju rezultate - okcipitalni pogled

5.2.2. Generiranje podataka GAN-om i cGAN-om

Uz klasične tehnike povećavanja skupa podataka, promatrani su i modeli generiranja sintetičkih podataka. Po uzoru na [24], uspoređena su dva pristupa generiranja podataka: generiranje svake klase zasebno GAN-om i korištenje uvjetnog GAN-a. Cilj ove usporedbe bio je ispitati kako predznanje o klasama tijekom uvježbavanja utječe na kvalitetu i relevantnost generiranih podataka.

Prije same analize generiranih slika je potrebno promotriti arhitekture modela. Svi slojevi arhitekture generatora (lijevo) i diskriminatora (desno) prikazani su na Slici 5.9 Generator započinje s gustim slojem (engl. *dense*) koji preoblikuje ulazni šum u $7 \times 7 \times 256$ tenzor. Potom se tenzor postupno skalira kroz niz transponiranih konvolucijskih slojeva. Svaki korak uvećanja uključuje normalizaciju serije i aktivacijsku funkciju *LeakyReLU* za stabilnost i učinkovitost učenja. Ključni dodatak ovoj arhitekturi je sloj unutarnje pažnje (engl. *self-attention*) [66] koji se primjenjuje nakon što je slika skalirana na 28×28 dimenzije. Dodavanjem tog sloja model bolje „razumije“ odnose između različitih dijelova slike, što je posebno korisno u generiranju kompleksnih slika s puno detalja. S druge strane,

diskriminator koristi niz konvolucijskih slojeva za postupno smanjivanje ulazne slike i povećanje broja njihovih značajki. Svaki sloj uključuje aktivacijsku funkciju *LeakyReLU* i *dropout* za sprječavanje pretjerane prilagođenosti podacima za uvježbavanje. Osim toga, normalizacijom serija osigurava se stabilnost i brzina uvježbavanja. Posljednji sloj je gusti sloj koji predviđa vjerojatnost da je slika stvarna (ne generirana). Ovakva arhitektura omogućuje diskriminatoru da efikasno uči razlikovati prave od generiranih slika, što je ključno za uspješno uvježbavanje GAN-a.

| Layer (type) | Output Shape | Param # | Layer (type) | Output Shape | Param # |
|---|----------------------|---------|--|----------------------|---------|
| dense (Dense) | (None, 12544) | 1254400 | conv2d_11 (Conv2D) | (None, 112, 112, 16) | 784 |
| batch_normalization (Batch Normalization) | (None, 12544) | 50176 | leaky_re_lu_15 (LeakyReLU) | (None, 112, 112, 16) | 0 |
| leaky_re_lu (LeakyReLU) | (None, 12544) | 0 | dropout_5 (Dropout) | (None, 112, 112, 16) | 0 |
| reshape (Reshape) | (None, 7, 7, 256) | 0 | conv2d_12 (Conv2D) | (None, 56, 56, 32) | 8224 |
| conv2d_transpose (Conv2DTranspose) | (None, 14, 14, 128) | 524288 | batch_normalization_14 (Batch Normalization) | (None, 56, 56, 32) | 128 |
| batch_normalization_1 (Batch Normalization) | (None, 14, 14, 128) | 512 | leaky_re_lu_16 (LeakyReLU) | (None, 56, 56, 32) | 0 |
| leaky_re_lu_1 (LeakyReLU) | (None, 14, 14, 128) | 0 | dropout_6 (Dropout) | (None, 56, 56, 32) | 0 |
| conv2d_transpose_1 (Conv2DTranspose) | (None, 28, 28, 64) | 131072 | conv2d_13 (Conv2D) | (None, 28, 28, 64) | 32832 |
| batch_normalization_2 (Batch Normalization) | (None, 28, 28, 64) | 256 | batch_normalization_15 (Batch Normalization) | (None, 28, 28, 64) | 256 |
| leaky_re_lu_2 (LeakyReLU) | (None, 28, 28, 64) | 0 | leaky_re_lu_17 (LeakyReLU) | (None, 28, 28, 64) | 0 |
| self_attention (SelfAttention) | (None, 28, 28, 64) | 6241 | dropout_7 (Dropout) | (None, 28, 28, 64) | 0 |
| conv2d_transpose_2 (Conv2DTranspose) | (None, 56, 56, 32) | 32768 | conv2d_14 (Conv2D) | (None, 14, 14, 128) | 131200 |
| batch_normalization_3 (Batch Normalization) | (None, 56, 56, 32) | 128 | batch_normalization_16 (Batch Normalization) | (None, 14, 14, 128) | 512 |
| leaky_re_lu_3 (LeakyReLU) | (None, 56, 56, 32) | 0 | leaky_re_lu_18 (LeakyReLU) | (None, 14, 14, 128) | 0 |
| conv2d_transpose_3 (Conv2DTranspose) | (None, 112, 112, 16) | 8192 | dropout_8 (Dropout) | (None, 14, 14, 128) | 0 |
| batch_normalization_4 (Batch Normalization) | (None, 112, 112, 16) | 64 | conv2d_15 (Conv2D) | (None, 7, 7, 256) | 524544 |
| leaky_re_lu_4 (LeakyReLU) | (None, 112, 112, 16) | 0 | batch_normalization_17 (Batch Normalization) | (None, 7, 7, 256) | 1024 |
| conv2d_transpose_4 (Conv2DTranspose) | (None, 224, 224, 3) | 768 | leaky_re_lu_19 (LeakyReLU) | (None, 7, 7, 256) | 0 |
| | | | dropout_9 (Dropout) | (None, 7, 7, 256) | 0 |
| | | | flatten_1 (Flatten) | (None, 12544) | 0 |
| | | | dense_3 (Dense) | (None, 1) | 12545 |


Slika 5.9 Arhitektura generatora i diskriminatora GAN-a

Za bolje razumijevanje arhitekture, bitno je upoznati se s mehanizmom unutarnje pažnje. Na početku koristi tri konvolucijske operacije kako bi transformirao ulazne podatke u tri skupa informacija: upit (engl. *query*), ključ (engl. *key*) i vrijednost (engl. *value*). Potom se te reprezentacije koriste za određivanje važnosti pojedinih dijelova ulaza. Konkretno, upiti i ključevi se uspoređuju kako bi se izračunala važnost, odnosno težina, koja će se pridati svakom dijelu ulaza, a zatim se te težine koriste za izračunavanje ponderiranog zbroja vrijednosti. Tako nastaje skup značajki koje su prilagođene prema najrelevantnijim dijelovima ulaza za trenutni zadatak. Dodatno, parametar *gamma* u sloju unutarnje pažnje,

koji se prilagođava tijekom uvježbavanja, određuje ukupan intenzitet pažnje. Na taj način, model može naučiti usmjeravati svoj fokus na dijelove podataka koji sadrže korisnije informacije.

Implementacija uvjetnog GAN-a gotovo je identična kao prethodno opisana arhitektura klasičnog GAN-a, s dodatkom uvjetovanja koji omogućuje generiranje slika na temelju određenih informacija, konkretno oznaka klasa. Generator cGAN-a sličan je generatoru standardnog GAN-a, ali prima dodatne informacije o klasama. Ulazne oznake klasa se prvo ugrađuju (engl. *embed*), a zatim spajaju s ulaznim šumom prije nego što prođu kroz mrežu. Spomenutim spajanjem se generirani izlaz prilagođava specifičnoj klasi koja se traži. Struktura generatora, kao i prethodno, uključuje transponirane konvolucijske slojeve, normalizaciju serije i aktivacijsku funkciju *LeakyReLU*. Potom, diskriminator u modelu cGAN uvodi koncept uvjetovanja, drugim riječima prima slike i pripadajuće oznake klasa kao ulaz. Oznake se ugrađuju i preoblikuju kako bi odgovarale dimenzijama ulaznih slika s kojima se poslije spajaju. Rezultat je mreža koja ne samo da ocjenjuje autentičnost slika, već i koliko dobro slike odgovaraju zadanim oznakama klasa. Pritom su se modeli GAN i cGAN uvježbavali kroz 10 000 epoha te generirali slike dimenzija 224x224. U oba slučaja su generirane 152 slike, odnosno 76 po klasi, čime se skup za uvježbavanje povećao na 305 podataka.

Nakon analize arhitektura se promatraju generirani podatci te se uspoređuje njihova sličnost s originalnim podacima. Na primjeru za lateralni pogled, na Slici 5.10, primjećuje se da ni GAN ni cGAN nisu uspjeli generirati jagodičnu kost da se ističe kao na originalnoj slici, koja je od krucijalne važnosti za određivanje spola iz ovog pogleda. Ipak, prema prikazanom, čini se da slika generirana cGAN-om ima više izraženih detalja i samim tim više nalikuje na original.




Slika 5.10 Generirani podatci - lateralni pogled

Zatim, na Slici 5.11 se mogu promotriti generirane slike iz frontalnog pogleda. Na prvi pogled, ni jedna od njih se značajno ne razlikuju od originala. Međutim, ako se bolje pogleda, primjećuje se da je lubanja generirana GAN-om nepravilnija te u oba slučaja nedostaje izraženost kostiju čela i bočnih dijelova lubanje.



Slika 5.11 Generirani podatci - frontalni pogled

U konačnici, na Slici 5.12 prikazan je okcipitalni pogled gdje je vidljivo da je u oba slučaja generirana lubanja značajno glađa, što može biti problem jer sprječava isticanje dijelova koji trebaju biti naglašeni za uspješno određivanje spola.



Slika 5.12 Generirani podatci - okcipitalni pogled


5.3. Postupak odabira modela

Postupak odabira modela započeo je odabirom arhitektura koja će uzeti u obzir. Odluka je donesena na temelju toga koje od njih su se spominjale u radovima iz 2.3.2. Dakle, razmatra se ukupno 12 modela, a oni su: MobileNetV2, MobileNet, EfficientNetB0, DenseNet121, VGG16, VGG19, Xception, InceptionV3, ResNet50V2, ResNet50, ResNet101V2 i ResNet101. Svi spomenuti modeli su prethodno uvježbani na skupu podataka ImageNet, koji je standard u području dubokog učenja i sadrži više od 14 milijuna označenih slika raspoređenih u tisuće klasa. Odluka se donosila na temelju točnosti unakrsne validacije i broja parametara koje model koristi. Naime, ako dva modela daju slične rezultate, a jedan od njih koristi manje parametara od drugog, tada bi taj model bio prvi izbor. Prilikom uvježbavanja se koristila unakrsna validacija, točnije njena inačica slojevito razvrstavanje k -puta (engl. *stratified k-fold*). U ovom slučaju k je 5, to jest riječ je o razvrstavanju 5-puta. Za razliku od standardne k -podjele (engl. *k-fold*) koja podatke dijeli nasumično, slojevito razvrstavanje k -puta osigurava da svaka podjela ima sličan postotak uzoraka za svaku klasu kao i cijeli skup podataka. Spomenuto je presudno za očuvanje omjera klasa u skupu za uvježbavanje i testiranje, čime se poboljšava reprezentativnost i smanjuje pristranost. Prednost ovakvog pristupa ističe se u područjima gdje je visoka preciznost od iznimne važnosti poput medicine i financija.

Na početku procesa odabira modela, uvježbava se svih 12 modela tijekom 5 epoha bez primjene bilo kakvih optimizacijskih tehnika. Nakon toga se grafički prikazuju točnosti unakrsnih validacija uzimajući u obzir veličinu svakog modela. Na temelju ovih informacija

odabiru se tri najperspektivnija modela. U drugoj fazi, odabrani modeli se dalje uvježbavaju do 10 epoha. Model koji se nakon toga pokaže najučinkovitijim, odabire se za detaljniju analizu i daljnje poboljšanje.

Nakon inicijalne selekcije za lateralni pogled, posebno su se istakli MobileNetV2, ResNet50V2 i Xception. U prvom krugu se MobileNetV2 činio kao najbolja opcija jer, kao što je prikazano na Slici 5.13 i detaljnije u Tablici 5.1, on je postigao najveću točnost, a koristio je najmanji broj parametra.



Slika 5.13 Odnos točnosti i veličine modela - lateralni pogled

Tablica 5.1 Točnost nakon 5 epoha - lateralni pogled

| Naziv modela | Broj parametara | Točnost unakrsne validacije (%) |
|--------------------|-----------------|---------------------------------|
| MobileNetV2 | 2259265 | 68,13 |
| ResNet50V2 | 23566849 | 67,48 |
| Xception | 20863529 | 67,46 |


Nakon uvježbavanja na 10 epoha, kod modela MobileNetV2 se stvorila razlika oko 7% između točnosti unakrsne validacije i točnosti na testnom skupu podataka, što ukazuje na to da se model već nakon 10 epoha prilagodio podacima za uvježbavanje. Prema podacima iz

Tablice 5.2, kao bolji izbor nameće se ResNet50V2 jer ima drugi najbolji rezultat unakrsne validacije, a točnost se ne razlikuje značajno ni na testnom skupu.

Tablica 5.2 Točnost nakon 10 epoha - lateralni pogled

| Naziv modela | Broj parametara | Točnost unakrsne validacije (%) | Točnost na testnom skupu (%) |
|--------------|-----------------|---------------------------------|------------------------------|
| MobileNetV2 | 2259265 | 75,87 | 68,66 |
| ResNet50V2 | 23566849 | 71,98 | 70,15 |
| Xception | 20863529 | 71,31 | 67,16 |

Nadalje, za frontalni pogled su se kao tri najbolja modela pokazali ResNet50V2, Xception, InceptionV3. Na Slici 5.14 se primjećuje da broj parametara modela ne može biti presudan jer je u sva tri slučaja sličan. Ipak, ResNet50V2 se, kao što je prikazano u Tablici 5.3, pokazao kao najbolji kandidat, a to je potvrđeno i nakon 10 epoha. Zapravo, nakon 10 epoha ResNet50V2 i Xception imaju jednaku točnost na skupu za testiranje, no iz Tablice 5.4 je očito da ResNet50V2 ima manju razliku između tog rezultata i rezultata unakrsne validacije.



Slika 5.14 Odnos točnosti i veličine modela - frontalni pogled


Tablica 5.3 Točnost nakon 5 epoha - frontalni pogled

| Naziv modela | Broj parametara | Točnost unakrsne validacije (%) |
|---------------------|------------------------|--|
| ResNet50V2 | 23566849 | 77,70 |
| Xception | 20863529 | 76,37 |
| InceptionV3 | 21804833 | 76,33 |

Tablica 5.4 Točnost nakon 10 epoha - frontalni pogled

| Naziv modela | Broj parametara | Točnost unakrsne validacije (%) | Točnost na testnom skupu (%) |
|---------------------|------------------------|--|-------------------------------------|
| ResNet50V2 | 23566849 | 76,41 | 76,11 |
| Xception | 20863529 | 72,52 | 76,11 |
| InceptionV3 | 21804833 | 76,97 | 68,65 |

U konačnici, za okcipitalni pogled se kao kandidati nameću ResNet50V2, MobileNet i ResNet101V2. Pritom je na Slici 5.15 očito da MobileNet koristi najmanji broj parametara, a uz to je, kao što je prikazano u Tablici 5.5, drugi po redu po točnosti unakrsne validacije. No, iz Tablice 5.6 se vidi da njegova točnost opada prilikom uvježbavanja na 10 epoha pa je tada ResNet50V2 najbolji izbor.



Slika 5.15 Odnos točnosti i veličine modela - okcipitalni pogled

Tablica 5.5 Točnost nakon 5 epoha - okcipitalni pogled

| Naziv modela | Broj parametara | Točnost unakrsne validacije (%) |
|--------------------|-----------------|---------------------------------|
| ResNet50V2 | 23566849 | 70,75 |
| MobileNet | 3229889 | 68,83 |
| ResNet101V2 | 42628609 | 66,25 |

Tablica 5.6 Točnost nakon 10 epoha - okcipitalni pogled

| Naziv modela | Broj parametara | Točnost unakrsne validacije (%) | Točnost na testnom skupu (%) |
|--------------------|-----------------|---------------------------------|------------------------------|
| ResNet50V2 | 23566849 | 75,22 | 73,13 |
| MobileNet | 3229889 | 63,12 | 70,15 |
| ResNet101V2 | 42628609 | 80,28 | 70,15 |

Zaključuje se da se ResNet50V2 pokazao najboljim za sva tri pogleda, stoga se taj model koristi za daljnju implementaciju.

5.3.1. Uvježbavanje odabranog modela

Kako bi se ResNet50V2 prilagodio za zadatak klasifikacije lubanja po spolu, izostavlja se originalni klasifikacijski sloj i „zaleđuju“ težine modela. Na taj način se iskorištavaju prethodno naučene značajke. Zatim, na mjesto izostavljenog sloja dodaje se novi prilagođeni gusti sloj koji omogućuje rješavanje postavljenog zadatka. Osim toga, model obuhvaća i sloj normalizacije serija, koji stabilizira aktivacije unutar mreže i ubrzava uvježbavanje s većim stopama učenja. Nakon toga, slijedi regularizacijski *dropout* sloj koji nasumično „isključuje“ neurone tijekom uvježbavanja kako bi se osigurala robusnost naučenih značajki i smanjila pretjerana prilagodba podacima za uvježbavanje. Svi ti segmenti vidljivi su u sažetku korištenog modela na Slici 5.16.

| Layer (type) | Output Shape | Param # |
|---|--------------|----------|
| resnet50v2 (Functional) | (None, 2048) | 23564800 |
| batch_normalization (Batch Normalization) | (None, 2048) | 8192 |
| dropout (Dropout) | (None, 2048) | 0 |
| dense (Dense) | (None, 1) | 2049 |
| ===== | | |
| Total params: 23575041 (89.93 MB) | | |
| Trainable params: 6145 (24.00 KB) | | |
| Non-trainable params: 23568896 (89.91 MB) | | |

Slika 5.16 ResNet50V2 i sloj za klasifikaciju

Za optimizaciju modela koristi se optimizator Adam, koji prilagođava stopu učenja za svaki parametar. Dodatno, implementiran je i pristup zakazivanja stope učenja (engl. *scheduled learning rate*), gdje se stopa učenja vremenom smanjuje kako bi se preciznije pronašla optimalna točka funkcije gubitka. Model je, uz spomenute promjene, uvježbavan kroz 10 epoha, što je dovelo točnost model za lateralni i okcipitalni pogled do 79,10% te za frontalni do 85,07%.

5.4. Fino podešavanje

S obzirom na to da se skup podataka ImageNet, na kojem je prvobitno uvježbavan ResNet50V2, bitno razlikuje od skupa podataka u ovom istraživanju, potrebno je primijeniti tehniku finog podešavanja modela. Prethodno su težine svih slojeva bile zaleđene, dakle broj parametara koji se uvježbavao je bio jednak 0, kao što je prikazano na Slici 5.17.

```
=====
Total params: 23564800 (89.89 MB)
Trainable params: 0 (0.00 Byte)
Non-trainable params: 23564800 (89.89 MB)
```

Slika 5.17 Parametri ResNet50V2 modela sa zamrznutim težinama svih slojeva

Često se u praksi pri finom podešavanju odmrzavaju težine samo zadnjeg sloja. Međutim, u ovom slučaju ta metoda nije rezultirala povećanjem točnosti zbog velikih razlika između domena skupova podataka. Umjesto toga, odmrznute su težine posljednjih 36 slojeva, preciznije, posljednjeg od ukupno četiri konvolucijska bloka. Na Slici 5.18 je prikazan broj parametara koji se uvježbavaju nakon odmrzavanja tih slojeva. Budući da se radi o većem broju parametara, model se uvježbavao tijekom 100 epoha, koristeći iste metode optimizacije koje su opisane u prethodnom poglavlju.

```
=====
Total params: 23564800 (89.89 MB)
Trainable params: 14970880 (57.11 MB)
Non-trainable params: 8593920 (32.78 MB)
```

Slika 5.18 Parametri ResNet50V2 modela s odmrznutim težinama zadnjeg konvolucijskog bloka

5.5. Kombiniranje modela

Ističu se dvije glavne metode za kombiniranje modela u području strojnog učenja [67]: većinsko glasanje (engl. *majority voting*) i težinsko glasanje (engl. *weighted voting*). Većinsko glasanje kombinira predviđanja različitih modela tako što se za konačnu odluku odabire klasa koja je najčešće predviđena. To je intuitivan i jednostavan pristup, gdje svaki model ima jednako pravo glasa bez obzira na njegovu individualnu točnost ili pouzdanost. Nasuprot tomu, težinsko glasanje pridjeljuje različite težine glasovima modela, obično prema njihovoj učinkovitosti (npr. točnost, preciznost). Modeli koji su učinkovitiji tako

dobivaju veću težinu u konačnoj odluci, što znači da njihovo predviđanje ima veći utjecaj na ishod.

Iako težinsko glasanje nudi prednost u scenarijima gdje pojedini modeli pokazuju značajno veću točnost, u ovom istraživanju koristilo se većinsko glasanje. Taj pristup je pogodan za situaciju kada su performanse modela slične i želimo izbjeći komplikacije koje nose dodjeljivanje i prilagodba individualnih težina. Dodatna prednost većinskog glasanja leži u njegovoj robusnosti. Dakle, kada modeli djeluju nezavisno i prave različite pogreške, dolazi do međusobne neutralizacije tih pogrešaka, što rezultira pouzdanijim konačnim predviđanjem.

6. Rezultati

S obzirom na to da su obje klase jednako zastupljene modeli su se uspoređivali koristeći mjeru točnosti, koja predstavlja postotak ukupnog broja ispravno klasificiranih primjera (pozitivnih i negativnih) u odnosu na ukupan broj svih primjera. Analizirajući rezultate iz Tablice 6.1, jasno je da su tradicionalne tehnike povećanja skupa podataka poboljšale performanse u sva tri slučaja, uključujući i one dobivene većinskim glasanjem. Međutim, uočava se da primjena generativnih suparničkih mreža (GAN-ova i cGAN-ova), osim u slučaju okcipitalnog pogleda, nije dovela do povećanja točnosti modela. Štoviše, u većini slučajeva modeli koji su koristili sintetičke podatke pokazali su se manje točnima od onih bez ikakvih metoda povećanja skupa podataka. Zanimljivo je primijetiti da cGAN nije nadmašio standardni GAN za pojedinačne modele, ali je pokazao bolje rezultate kada su modeli kombinirani većinskim glasanjem.


Tablica 6.1 Rezultati svih eksperimenata

| Točnost (%) | Lateralni | Frontalni | Okcipitalni | Većinsko glasanje |
|------------------------------|-----------|-----------|-------------|-------------------|
| Bez augmentacija | 79,10 | 85,07 | 79,10 | 85,07 |
| Klasične augmentacije | 82,09 | 88,06 | 83,58 | 88,06 |
| GAN | 74,63 | 82,09 | 80,60 | 83,58 |
| cGAN | 76,12 | 77,61 | 79,10 | 85,07 |
| Fino podešavanje | 86,57 | 89,55 | 86,57 | 92,54 |

Iz usporedbe dobivenih rezultata proizlazi da su za ovaj konkretni skup podataka tradicionalne metode povećanja skupa podataka primjerenije. Razlog tomu je relativno mali skup podataka, koji nije dovoljno velik za uspješno generiranje relevantnih sintetičkih podataka. Primjenom klasičnih tehnika povećavanja skupa podataka i kombiniranjem modela većinskim glasanjem, postigao se rezultat od 88.06%. Budući da su se klasične tehnike pokazale najučinkovitijima za sva tri pogleda, odabrani su upravo ti modeli za

daljnje fino podešavanje. Procesom finog podešavanja točnost modela za lateralni pogled je povećana za 4,48%, za frontalni za 1,49%, a za okcipitalni za 2,99%. Kroz strategiju kombiniranja ovih modela većinskim glasanjem, postignuta je točnost od 92,54%, što je ujedno i najbolji rezultat dobiven tijekom svih provedenih eksperimenata.

Osim same točnosti, važno je uzeti u obzir i druge metrike za procjenu učinkovitosti najboljeg modela provedenim eksperimentima. Temelj za izračunavanje ostalih metrika je matrica konfuzije, prikazana na Slici 6.1. Iz nje se iščitava da su tri žene od njih 33 pogrešno klasificirane kao muškarci, dok su od 34 muškarca, dvojica pogrešno klasificirana kao žene.



Slika 6.1 Matrica konfuzije

Neke od metrika koje se mogu izračunati na temelju matrice konfuzije su preciznost (engl. *precision*), osjetljivost (engl. *recall*) i mjera F1 (engl. *F1-score*), čije su vrijednosti prikazane na Slici 6.2. Preciznost za klasu žena računa se kao omjer broja ispravno klasificiranih žena prema ukupnom broju predviđanja koje model označava kao žene, uključujući i one muškarce koji su pogrešno klasificirani kao žene. Konkretno, model je točno identificirao 30 žena, dok je 2 muškarca pogrešno označio kao žene, što daje preciznost od 93,75% za žene ($30 / (30 + 2)$). Slično tomu, za muškarce preciznost od 91,43% ($32 / (32 + 3)$) proizlazi iz broja ispravno klasificiranih muškaraca prema ukupnom broju predviđanja označenih kao muškarci. Nadalje, osjetljivost za žene mjeri koliko dobro model prepoznaje stvarne žene.

Izračunava se kao omjer ispravno identificiranih žena prema ukupnom broju stvarnih žena. U ovom slučaju, osjetljivost za žene, koja iznosi 90,91%, računa se kao omjer ispravno prepoznatih žena (30) prema ukupnom broju stvarnih žena (30 + 3). Nasuprot tomu, za muškarce, model je ispravno identificirao 32 muškarca, a samo dvojicu pogrešno klasificirao kao žene, čime postiže osjetljivost od 94,12% (32 / (32 + 2)). Mjera F1 je harmonijska sredina preciznosti i osjetljivosti, što ju čini izvrsnom metrikom za procjenu ukupne točnosti modela, posebno kada je važno uravnotežiti sposobnost točnog prepoznavanja žena i muškaraca s minimalnim brojem pogrešaka u klasifikaciji. Za žene, mjera F1 iznosi 0,923, dok za muškarce iznosi 0,928, što pokazuje da model postiže visoku ravnotežu u preciznosti i sposobnosti prepoznavanja oba spola. Visoke vrijednosti za oba spola potvrđuju efikasnost i nepristranost modela u razlikovanju spola, čineći ga pouzdanim alatom u klasifikaciji.

Classification Report:

| Class | Precision | Recall | F1-Score | Support |
|--------------|--------------------|--------------------|----------|---------|
| F | 0.9375 | 0.9090909090909091 | 0.923 | 33 |
| M | 0.9142857142857143 | 0.9411764705882353 | 0.928 | 34 |
| macro avg | 0.9258928571428571 | 0.9251336898395721 | 0.925 | 67 |
| weighted avg | 0.9257196162046909 | 0.9253731343283582 | 0.925 | 67 |
| accuracy | | | 0.925 | |

Slika 6.2 Izvještaj o rezultatima klasifikacije


6.1. Objašnjivost rezultata

U ovom istraživanju, korišten je algoritam Grad-CAM (*Gradient-weighted Class Activation Mapping*) kako bi se vizualno predstavile i analizirale regije slike koje su ključne za donošenje odluka. Prema [68], Grad-CAM je napredna tehnika u dubokom učenju koja omogućuje vizualizaciju dijelova slike koji su najvažniji za donošenje odluka konvolucijske neuronske mreže. Implementacija ovog algoritma ja inspirirana resursima kao što je PyImageSearch, uz prilagodbe za potrebe ovog projekta. Zapravo, Grad-CAM koristi informacije o gradijentima predviđene klase u odnosu na mape značajki posljednjeg konvolucijskog sloja mreže. Na temelju tih informacija, algoritam određuje „težinu“ svakog dijela mape značajki, a zatim te težine koristi za stvaranje toplinske mape (engl. *heatmap*). Ova toplinska mapa vizualno prikazuje regije slike koje su važne za predviđanje određene

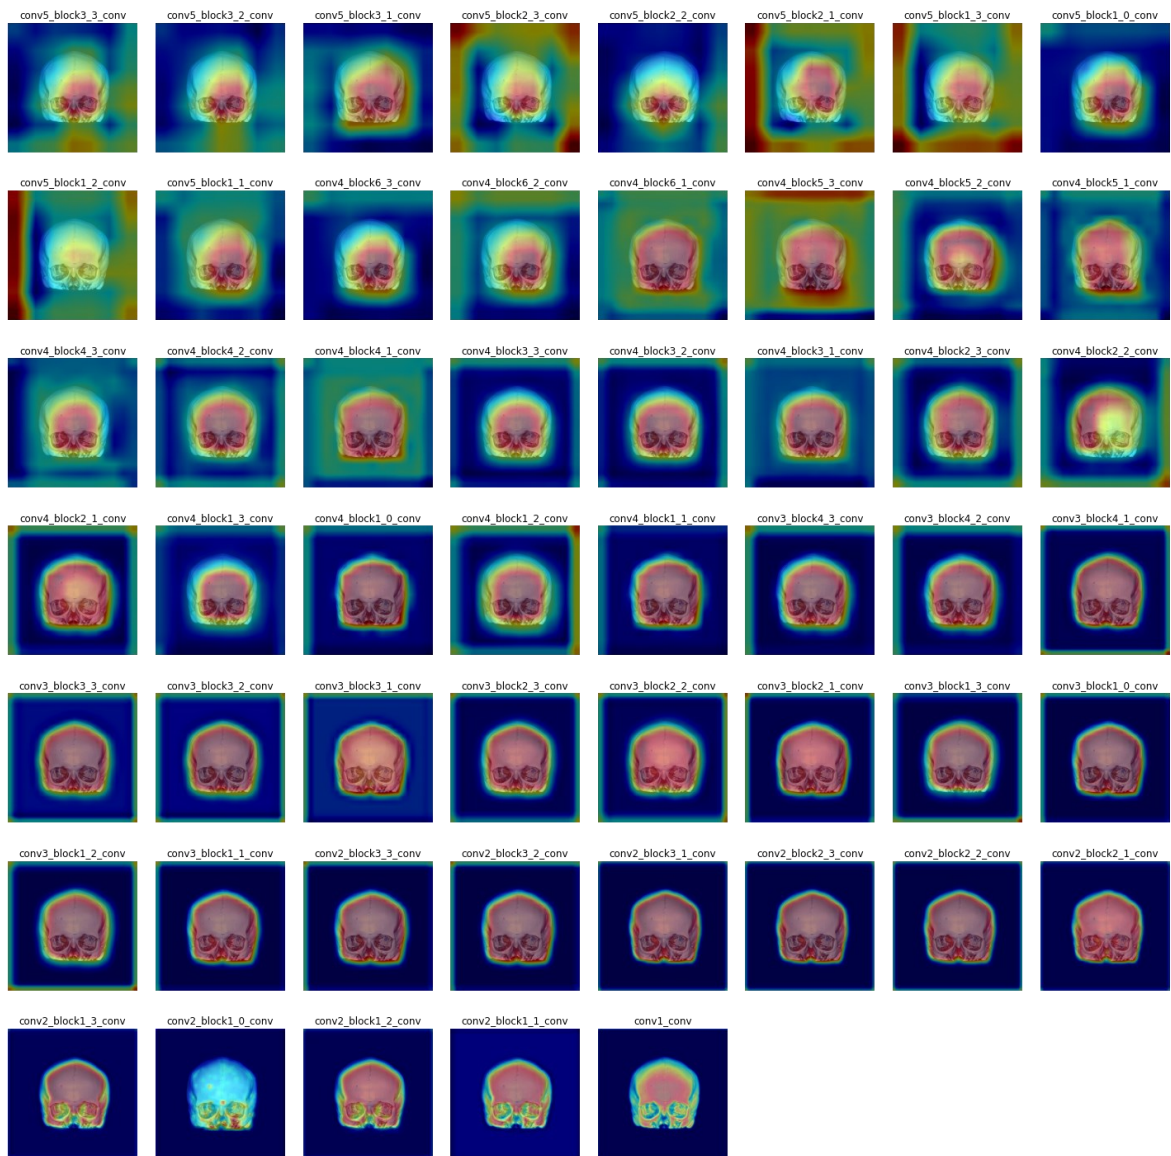
klase. Takav uvid je izuzetno koristan, ne samo za razumijevanje kako mreža donosi svoje odluke, već i za identifikaciju potencijalnih pristranosti i slabosti unutar modela.

Primjena Grad-CAM-a posebno dolazi do izražaja u medicini i drugim osjetljivim područjima, kao što je i forenzika, gdje je razumijevanje i povjerenje u odluke modela od ključne važnosti. Na primjer, vizualizacijom aktivacijskih mapa vidi se fokusira li se mreža na relevantne medicinske indikatore ili nešto nevezano za dijagnozu. Osim što pruža uvid u to koje dijelove slike mreža „gleda“, Grad-CAM može ukazati na potrebu za dodatnim prilagodbama modela. Ako mreža ne aktivira ispravne uzorke ili objekte na slici, to može značiti da mreža nije pravilno naučila osnovne obrasce u skupu podataka, da treba ponoviti postupak uvježbavanja, da je potrebno prikupiti više podataka ili čak da model nije spreman za primjenu.


Toplinske mape dobivene primjenom algoritma Grad-CAM na ovom skupu podataka ilustrirane su na Slici 6.3, Slici 6.4 i Slici 6.5. Zajednička karakteristika svih prikaza je postupno usmjeravanje pažnje mreže. Na početku konvolucijske mreže, slojevi se fokusiraju na općenite karakteristike slike (npr. rubovi), dok slojevi bliže kraju postupno usmjeravaju pažnju prema specifičnijim i relevantnim regijama, što je jasno vidljivo iz toplinskih mapa. Primjerice, u slučaju lateralnog prikaza, koncentracija pažnje mreže u kasnijim slojevima je usmjerena na područje oko jagodične kosti i konture lubanje. Kod frontalnog pogleda, završni slojevi mreže najviše se fokusiraju na regiju oko očiju, dok se u okcipitalnom pogledu posebna pažnja pridaje potiljku.



Slika 6.3 Toplinske karte po konvolucijskim slojevima za lateralni pogled



Slika 6.4 Toplinske karte po konvolucijskim slojevima za frontalni pogled



Slika 6.5 Toplinske karte po konvolucijskim slojevima za okcipitalni pogled

Ovako detaljan prikaz pruža temelj za usporedbu i raspravu s ekspertima iz struke, omogućujući vrijedan uvid u interpretaciju i analizu modela.

Zaključak

U ovom istraživanju analizirane su strategije za suočavanje s izazovom malog skupa podataka u klasifikaciji spola lubanja, koristeći rekonstrukciju MSCT snimaka glava 220 pacijenata iz splitske bolnice. Skup podataka se sastoji od jednakog broja žena i muškaraca izuzevši pacijente koji su pretrpjeli traumu glave. U okviru provedenog istraživanja doneseni su zaključci i odgovori na postavljena istraživačka pitanja.

Usporedbom rezultata modela prijenosnog učenja u tri različita slučaja - bez povećanja skupa podataka, s povećanjem klasičnim tehnikama te s povećanjem sintetički generiranim podatcima, uočeno je da su klasične tehnike, poput rotacije i razine osvjetljenja slike, pokazale bolje rezultate od sintetičkog generiranja podataka. U kontekstu sintetičkog generiranja podataka, kada je primijenjeno većinsko glasanje, cGAN se pokazao učinkovitijim od GAN-a. Važno je istaknuti da dodavanje sintetički generiranih podataka nije doprinijelo, no nije ni značajno narušilo rezultate. Iz toga se zaključuje da su generirane slike bile slične izvornima, što ukazuje na potrebu za daljnjim istraživanjem, posebno složenijih arhitektura GAN-ova ili korištenja prethodno uvježbanih GAN-ova na većim skupovima podataka.

U istraživanju različitih modela prijenosnog učenja, ResNet50 se pokazao kao najučinkovitiji, a dodatno povećanje točnosti postignuto je finim podešavanjem koje uključuje odmrzavanje posljednjeg konvolucijskog bloka. Najbolji rezultat postignut je kombinacijom klasičnih metoda povećanja skupa podataka, finog podešavanja i većinskim glasanjem, čime se postigla točnost od 92,54%. Postignuti rezultati naglašavaju učinkovitost promatranih metoda u kontekstu klasifikacije spola lubanja, otvarajući put za daljnja istraživanja. To uključuje spomenuto ispitivanje kompleksnijih GAN-ova, detaljniju analizu zaleđivanja određenih slojeva pri finom podešavanju te mogući razvoj aplikacije koje bi mogla poslužiti kao pomoćni alati forenzičarima u identifikaciji pronađenih ostataka. Dodatno, izvedeni zaključci mogu se primijeniti i na druge domene koje obuhvaćaju podatke sličnih karakteristika.

Literatura

- [1] Bašić, Ž.; Jerković, I.; Bareša, T.; Jerković, N.; Mladenović, S.; Skejić, I.; Dolić, K.; Kružić, I.: „Bipartite parietal bone: a case from Croatian population“, Journal of Bioanthropology, 2022.
- [2] <https://orangedatamining.com/>, s Interneta, posljednji put pristupljeno: 15.11.2023.
- [3] Alzubaidi, L.; Bai, J.; Al-Sabaawi, A. et al.: „A survey on deep learning tools dealing with data scarcity: definitions, challenges, solutions, tips, and applications“, Journal of Big Data 10, 2023.
- [4] Safonova, A.; Ghazaryan, G.; Stiller, S.; Main-Knorn, M.; Nendel, C.; Ryo, M.: „Ten deep learning techniques to address small data problems with remote sensing“, International Journal of Applied Earth Observation and Geoinformation 125, 2023.
- [5] Russakovsky, O.; Deng, J.; Su, H. et al.: „ImageNet Large Scale Visual Recognition Challenge“, International Journal of Computer Vision 115, pp. 211–252, 2015.
- [6] Adadi, A.: „A survey on data-efficient algorithms in big data era“, Journal of Big Data 8, 2021.
- [7] Nakkiran, P.; Kaplun, G.; Bansal, Y.; Yang, T.; Barak, B.; Sutskever, I.: „Deep double descent: where bigger models and more data hurt“, Journal of Statistical Mechanics: Theory and Experiment, 2021.
- [8] Shorten, C.; Khoshgoftaar, T.M.: „A survey on Image Data Augmentation for Deep Learning“, Journal of Big Data 6, 2019.
- [9] Althnian, A.; AlSaeed, D.; Al-Baity, H.; Samha, A.; Dris, A.B.; Alzakari, N.; Abou Elwafa, A.; Kurdi, H.: „Impact of Dataset Size on Classification Performance: An Empirical Evaluation in the Medical Domain“, Applied Sciences 11, 2021.
- [10] D’souza, R.N.; Huang, P.Y.; Yeh, F.C.: „Structural Analysis and Optimization of Convolutional Neural Networks with a Small Sample Size“, Scientific Reports 10, 2020.
- [11] <https://about.nested-knowledge.com/2022/07/22/how-publications-flow-in-prisma-2020/>, s Interneta, posljednji put pristupljeno: 17.11.2023.

- [12] Gheshlaghi, S.H; Nok Enoch Kan, C.; Ye D.H.: „Breast Cancer Histopathological Image Classification with Adversarial Image Synthesis“, 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society, 2021.
- [13] Zheng, Y.; Li, C.; Zhou, X.; Chen, H.; Xu, H.; Li, Y.; Zhang, H.; Li, X.; Sun, H.; Huang, X.; Grzegorzec, M.: „Application of transfer learning and ensemble learning in image-level classification for breast histopathology“, *Intelligent Medicine*, Vol. 3, pp. 115-128, 2023.
- [14] Joseph, A.J.; Dwivedi, P.; Joseph, J; Francis, S; Pournami P.N.; Jayaraj P.B.; Shamsu, A.V.; Sankaran, P.: „Prior-guided generative adversarial network for mammogram synthesis“, *Biomedical Signal Processing and Control*, 2023.
- [15] Qin, Z.; Liu, Z.; Zhu, P.; Xue, Y.: „A GAN-based image synthesis method for skin lesion classification“, *Computer Methods and Programs in Biomedicine*, Vol. 195, 2020.
- [16] Mohanty, A.; Sutherland, A.; Bezbradica, M.; Javidnia, H.: „Skin Disease Analysis With Limited Data in Particular Rosacea: A Review and Recommended Framework“, *IEEE Access*, vol. 10, pp. 39045-39068, 2022.
- [17] Sanchez, K.; Hinojosa, C.; Arguello, H.; Kouame, D.; Meyrignac, O.; Basarab, A.: „CX-DaGAN: Domain Adaptation for Pneumonia Diagnosis on a Small Chest X-Ray Dataset“, *IEEE Trans Med Imaging*, 2022.
- [18] Yadav, S.S.; Jadhav, S.M.: „Deep convolutional neural network based medical image classification for disease diagnosis“, *Journal of Big Data*, Vol. 6, 2019.
- [19] Qjidaa, M.; Ben-Fares, A.; Amakdouf, H.; El Mallahi, M.; Alami, B.E.; Maaroufi, M.; Lakhssassi, A.; Qjidaa, H.: „Recognizing COVID-19 from chest X-ray images for people in rural and remote areas based on deep transfer learning model“, *Multimedia Tools and Applications* , 2022.
- [20] Li, C.; Yang, Y.; Liang, H.; Wu, B.: „Transfer learning for establishment of recognition of COVID-19 on CT imaging using small-sized training datasets“, *Knowledge-Based Systems*, Vol. 218, 2021.

- [21] Zhao, K.: „Multiple GAN Augmentation for Acute Myocardial Infarction Classification“, ProQuest Dissertations Publishing, 2020.
- [22] Du, W.; Nini, R.; Yingchun, W.; Hu, D.; Jiahao, Y.: „Efficient Transfer Learning Used in the Classification of Gastroscopic Images with Small Dataset“, 17th International Computer Conference on Wavelet Active Media Technology and Information Processing , pp. 73-76, 2020.
- [23] Bali, S.; Tyagi, S.S.: „Evaluation of transfer learning techniques for classifying small surgical dataset“, 10th International Conference on Cloud Computing, Data Science & Engineering, pp. 744-750, 2020.
- [24] Röglin, J.; Ziegeler, K.; Kube, J.; König, F.; Hermann, K.G.; Ortmann, S.: „Improving classification results on a small medical dataset using a GAN; An outlook for dealing with rare disease datasets“, Frontiers in Computer Science 4, 2022.
- [25] Candemir, S.; Nguyen, X.V.; Folio, L.R.; Prevedello, L.M.: „Training Strategies for Radiology Deep Learning Models in Data-limited Scenarios“, Radiology: Artificial Intelligence, 2021.
- [26] Bewesa, J.; Lowa, A.; Morphetb, A.; Patec, F.C.; Henneber, M.: „Artificial intelligence for sex determination of skeletal remains: Application of a deep learning artificial neural network to human skulls“, Journal of Forensic and Legal Medicine 6, pp. 40-43, 2019.
- [27] Munipalle, V.K.; Nelakuditi, U.R.; Nidamanuri, R.R.: „Agricultural Crop Hyperspectral Image Classification using Transfer Learning“, International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing, pp. 1-4, 2023.
- [28] Pires de Lima, R.; Duarte, D.: „Pretraining Convolutional Neural Networks for Mudstone Petrographic Thin-Section Image Classification“, Geosciences 11, pp. 336., 2021.
- [29] Hou, Y. et al.: „A Deep Learning Method for Pavement Crack Identification Based on Limited Field Images“, IEEE Transactions on Intelligent Transportation Systems, Vol. 23, pp. 22156-22165, 2022.

- [30] Chowdhury, A.: „Meta Approaches to Few-Shot Image Classification“, 2021., Rice University (Dissertation)
- [31] Khalifa, N.E.; Loey, M.; Mirjalili, S.: „A comprehensive survey of recent trends in deep learning for digital images augmentation“, *Artificial Intelligence Review* 55, 2022.
- [32] Vyas, A.; Yu, S.; Paik, J.: „Fundamentals of digital image processing“, *Signals and Communication Technology*, 2018.
- [33] Sifre, L.; Mallat, S.: „Rotation, scaling and deformation invariant scattering for texture discrimination“, *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1233-1240, 2013.
- [34] Winkler, S.: „Color space conversions“, *Digital Video Quality: Vision Models and Metrics*, 2013.
- [35] Galdran, A.; Alvarez-Gila, A.; Meyer, M.I. et al.: „Data-driven color augmentation techniques for deep skin image analysis“, 2017.
- [36] Zhong, Z.; Zheng, L.; Kang, G.; Li, S.; Yang, Y.: „Random erasing data augmentation“, 2017.
- [37] Bowles, C.; Chen, L.; Guerrero, R.; Bentley, P.; Gunn, R.; Hammers, A.; Dickie, D.; Hernández, M.; Wardlaw, J.; Rueckert, D.: „GAN Augmentation: Augmenting Training Data using Generative Adversarial Networks“, 2018.
- [38] Mirza, M.; Osindero, S.: „Conditional generative adversarial nets“, *arXiv*, 2014.
- [39] Jeong, J.J.; Tariq, A.; Adejumo, T.; Trivedi, H.; Gichoya, J.W.; Banerjee, I.: „Systematic Review of Generative Adversarial Networks (GANs) for Medical Image Classification and Segmentation“, *Journal of Digital Imaging*, pp. 137-152, 2022.
- [40] Radford, A.; Metz, L.; Chintala, S.: „Unsupervised representation learning with deep convolutional generative adversarial networks“, *arXiv*, 2015.
- [41] Isola, P.; Zhu, J.Y.; Zhou, T. et al.: „Image-to-image translation with conditional adversarial networks“, *IEEE conference on computer vision and pattern recognition*, 2017.

- [42] Zhu, J.Y.; Park, T.; Isola, P. et al.: „Unpaired image-to-image translation using cycle-consistent adversarial networks“, IEEE international conference on computer vision, 2017.
- [43] <https://jonathan-hui.medium.com/gan-whats-generative-adversarial-networks-and-its-application-f39ed278ef09>, s Interneta, posljednji put pristupljeno: 1.12.2023.
- [44] Cheng, K.; Tahir, R.; Eric, L.K. et al: „An analysis of generative adversarial networks and variants for image synthesis on MNIST dataset“, Multimedia Tools and Applications 79, 2020.
- [45] Suh, S.; Lee, H.; Jo, J.; Lukowicz, P.; Lee, Y.: „Generative Oversampling Method for Imbalanced Data on Bearing Fault Detection and Diagnosis“, Applied Sciences 9, 2019.
- [46] <https://medium.com/@kyang3200/deep-learning-dcgan-deep-convolutional-generative-adversarial-network-882624fdefe3>, s Interneta, posljednji put pristupljeno: 5.12.2023.
- [47] <https://towardsdatascience.com/synthetic-data-generation-using-conditional-gan-45f91542ec6b>, s Interneta, posljednji put pristupljeno: 5.12.2023.
- [48] <https://towardsdatascience.com/simply-deep-learning-an-effortless-introduction-45591a1c4abb>, s Interneta, posljednji put pristupljeno: 6.12.2023.
- [49] <https://www.pallavibharadwaj.com/perceptron-and-its-implementation-in-python>, s Interneta, posljednji put pristupljeno: 6.12.2023.
- [50] <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, s Interneta, posljednji put pristupljeno: 7.12.2023.
- [51] Phung, R.: „A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets“ Applied Sciences 9, 2019.
- [52] <https://medium.com/codex/understanding-convolutional-neural-networks-a-beginners-journey-into-the-architecture-aab30dface10>, s Interneta, posljednji put pristupljeno: 8.12.2023.

- [53] <https://towardsdatascience.com/a-comprehensive-hands-on-guide-to-transfer-learning-with-real-world-applications-in-deep-learning-212bf3b2f27a>, s Interneta, posljednji put pristupljeno: 8.12.2023.
- [54] Kaiming, H.; Xiangyu, Z.; Shaoqing, R.; Jian, S.: „Deep Residual Learning for Image Recognition“, arXiv, 2015.
- [55] <https://medium.com/@nitishkundu1993/exploring-resnet50-an-in-depth-look-at-the-model-architecture-and-code-implementation-d8d8fa67e46f>, s Interneta, posljednji put pristupljeno: 10.12.2023.
- [56] <https://colab.research.google.com/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [57] <https://www.tensorflow.org/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [58] <https://pandas.pydata.org/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [59] <https://numpy.org/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [60] <https://matplotlib.org/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [61] <https://seaborn.pydata.org/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [62] <https://scikit-learn.org/stable/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [63] Jerković, N. (2024). Transfer-Learning-in-Forensics. GitHub. <https://github.com/nikajerkovic/Transfer-Learning-in-Forensics>
- [64] <https://www.osirix-viewer.com/>, s Interneta, posljednji put pristupljeno: 12.12.2023.
- [65] White, T.D.; Black, M.T.; Folkens, P.A.: „Human Osteology“, Academic Press, Third Edition, 2011.
- [66] Zhang, H.; Goodfellow, I.; Metaxas, D.; Odena, A.: „Self-Attention Generative Adversarial Networks“, arXiv, 2018.

- [67] <https://machinelearningmastery.com/voting-ensembles-with-python/>, s Interneta, posljednji put pristupljeno: 15.12.2023.
- [68] <https://pyimagesearch.com/2020/03/09/grad-cam-visualize-class-activation-maps-with-keras-tensorflow-and-deep-learning/>, s Interneta, posljednji put pristupljeno: 15.12.2023.

Popis slika

| | |
|--|----|
| Slika 2.1 Razlika između tradicionalnog strojnog učenja i dubokog učenja (prema [3]) | 5 |
| Slika 2.2 Usporedba <i>overfittinga</i> i optimalnog učenja (prema [8])..... | 8 |
| Slika 2.3 Postupak odabira radova za istraživanje | 12 |
| Slika 3.1 Klasifikacija klasičnih tehnika za povećanje skupa podataka..... | 16 |
| Slika 3.2 Hijerarhijski prikaz različitih vrsta GAN-ova (prema [39])..... | 23 |
| Slika 3.3 Prikaz rada GAN-a na višoj razini (prema [43]) | 24 |
| Slika 3.4 Osnovna arhitektura GAN-a (prema [43]) | 25 |
| Slika 3.5 Prikaz učenja GAN-a (prema [43]) | 25 |
| Slika 3.6 Sažetak cijelog procesa uvježbavanja GAN-a (prema [43]) | 26 |
| Slika 3.7 Arhitektura generatora i diskriminatora u DCGAN-u (prema [45]) | 28 |
| Slika 3.8 Komponente DCGAN arhitekture (prema [44]) | 29 |
| Slika 3.9 Usporedba GAN-a i cGAN-a (prema [44])..... | 30 |
| Slika 4.1 Perceptron (prema [49]) | 32 |
| Slika 4.2 Arhitektura konvolucijske neuronske mreže (prema [51])..... | 34 |
| Slika 4.3 Usporedba tradicionalnog strojnog učenja i prijenosnog učenja (prema [53]) | 35 |
| Slika 4.4 ResNet50 arhitektura (prema [55])..... | 38 |
| Slika 4.5 Rezidualni blok (prema [54]) | 38 |
| Slika 5.1 Primjer lubanje žene..... | 40 |
| Slika 5.2 Primjer lubanje muškarca..... | 40 |
| Slika 5.3 Odabrane tehnike za lateralni pogled | 42 |
| Slika 5.4 Tehnike koje pogoršavaju rezultate - lateralni pogled | 42 |
| Slika 5.5 Odabrane tehnike za frontalni pogled | 43 |
| Slika 5.6 Tehnike koje pogoršavaju rezultate - frontalni pogled..... | 43 |
| Slika 5.7 Odabrane tehnike za okcipitalni pogled | 44 |

| | |
|---|----|
| Slika 5.8 Tehnike koje pogoršavaju rezultate - okcipitalni pogled | 44 |
| Slika 5.9 Arhitektura generatora i diskriminatora GAN-a | 45 |
| Slika 5.10 Generirani podatci - lateralni pogled..... | 47 |
| Slika 5.11 Generirani podatci - frontalni pogled | 47 |
| Slika 5.12 Generirani podatci - okcipitalni pogled..... | 48 |
| Slika 5.13 Odnos točnosti i veličine modela - lateralni pogled..... | 49 |
| Slika 5.14 Odnos točnosti i veličine modela - frontalni pogled | 50 |
| Slika 5.15 Odnos točnosti i veličine modela - okcipitalni pogled..... | 52 |
| Slika 5.16 ResNet50V2 i sloj za klasifikaciju | 53 |
| Slika 5.17 Parametri ResNet50V2 modela sa zamrznutim težinama svih slojeva | 54 |
| Slika 5.18 Parametri ResNet50V2 modela s odmrznutim težinama zadnjeg konvolucijskog bloka | 54 |
| Slika 6.1 Matrica konfuzije | 57 |
| Slika 6.2 Izvještaj o rezultatima klasifikacije..... | 58 |
| Slika 6.3 Toplinske karte po konvolucijskim slojevima za lateralni pogled..... | 60 |
| Slika 6.4 Toplinske karte po konvolucijskim slojevima za frontalni pogled | 61 |
| Slika 6.5 Toplinske karte po konvolucijskim slojevima za okcipitalni pogled..... | 62 |

Popis tablica

| | |
|--|----|
| Tablica 5.1 Točnost nakon 5 epoha - lateralni pogled..... | 49 |
| Tablica 5.2 Točnost nakon 10 epoha - lateralni pogled..... | 50 |
| Tablica 5.3 Točnost nakon 5 epoha - frontalni pogled..... | 51 |
| Tablica 5.4 Točnost nakon 10 epoha - frontalni pogled..... | 51 |
| Tablica 5.5 Točnost nakon 5 epoha - okcipitalni pogled..... | 52 |
| Tablica 5.6 Točnost nakon 10 epoha - okcipitalni pogled..... | 52 |
| Tablica 6.1 Rezultati svih eksperimenata..... | 56 |