

Klasifikacija osoba prema spolu na temelju slike lica

Paskal, Šimec

Undergraduate thesis / Završni rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:211:383348>

Rights / Prava: [Attribution-NonCommercial 3.0 Unported / Imenovanje-Nekomercijalno 3.0](#)

Download date / Datum preuzimanja: **2024-07-11**



Repository / Repozitorij:

[Faculty of Organization and Informatics - Digital Repository](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ź D I N

Paskal Šimec

KLASIFIKACIJA OSOBA PREMA SPOLU
NA TEMELJU SLIKE LICA

ZAVRŠNI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Paskal Šimec

Matični broj: 44158/15–R

Studij: Informacijski sustavi

KLASIFIKACIJA OSOBA PREMA SPOLU NA TEMELJU SLIKE
LICA

ZAVRŠNI RAD

Mentor/Mentorica:

Doc. dr. sc. Petra Grd

Varaždin, kolovoz 2018.

Paskal Šimec

Izjava o izvornosti

Izjavljujem da je moj završni rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor/Autorica potvrdio/potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Cilj ovog rada je odrediti spol osobe na osnovi slike lica korištenjem algoritma ugrađenog u računalni program. U radu su opisane razlike između muškog i ženskog lica te su predstavljene najbitniji pojmovi vezani za biometriju u svrhu lakšeg shvaćanja promatrane problematike. Predstavljene su najpopularniji algoritmi koji se bave klasifikacijom i objašnjeni su osnovni principi rada algoritama. Klasifikacijski program implementiran je korištenjem neuronske mreže Inception-v3. Prikazana je građa i način rada neuronske mreže. Skup korištenih slika prilikom izrade rada grafički je prikazan i opisan. Programsko rješenje implementirano je u grafičko sučelje s ciljem povećanja korisničkog iskustva. Dobiveni rezultati su grafički obrađeni, a na temelju dobivenih rezultata može se zaključiti da je korištena neuronska mreža Inception-V3 prikladna za upotrebu kako u širem krugu korisnika tako i u profesionalne svrhe. Obzirom na uočene greške za vrijeme testiranja, zaključeno je da postoji prostor za poboljšanje.

Ključne riječi: lice; spol; biometrija; neuronska mreža; klasifikacija; algoritam;

Sadržaj

1. Uvod	1
2. Biometrija.....	2
2.1. Principi rada biometrijskih tehnika	2
2.1.1. Digitalizacija	2
2.1.2. Umjetna inteligencija.....	3
2.2. Biometrijske tehnike.....	3
2.2.1. Fizička biometrija	3
2.2.2. Biometrija ponašanja.....	4
3. Razlike muškog i ženskog lica	5
3.1.1. Oblik lica.....	5
3.1.2. Obrve	6
3.1.3. Oči.....	6
3.1.4. Obrazi.....	7
3.1.5. Nos	7
3.1.6. Usta i usne	8
3.1.7. Brada.....	8
4. Upotreba računala u postupku prepoznavanja spola.....	9
5. Pregled algoritama za određivanje spola na temelju slike lica.....	10
5.1. Analiza glavnih komponenti	11
5.2. Analiza linearnih diskriminanti	12
5.3. Metoda potpornih vektora	12
5.4. Samo organizirajuća mapa	13
6. Neuronska mreža kao algoritam za određivanje spola	14
6.1. Umjetne neuronske mreže.....	14
6.1.1. Neuron	15
6.1.2. Aktivacijske funkcije	16
6.1.3. Struktura mreže.....	17
6.2. Konvolucijska mreža	18

6.3. Google Inception-v3.....	19
7. Aplikacija za klasifikaciju osoba prema spolu na temelju slike lica	22
7.1. DataSet.....	22
7.2. Korištena tehnologija i alata.....	23
7.3. Prikaz aplikacije	23
7.4. Dobiveni rezultati	25
8. Zaključak	29
Popis literature.....	30
Popis slika.....	32
Popis tablica	34

1. Uvod

Klasifikacija osoba prema spolu na temelju slike lica jedna je od zanimljivijih tema. Na prvi pogled ova tema može izgledati jednostavno i mnogima može promaknuti bit same problematike. Naime, čovjek ima sposobnost prepoznavanja spola osobe s vrlo visokom preciznošću, dok se ne može reći isto i za računalo. Kako bi računalo dobilo tu mogućnost mora ga se naučiti razlike između spolova, odnosno algoritme, koji raznim tehnikama dobivaju razlike između lica te na temelju tih podataka s određenom preciznošću mogu zaključiti o kojem se spolu radi.

U današnje vrijeme svugdje je prisutan pojam klasifikacije. Svakodnevno se susrećemo s računalnom tehnologijom koja se koristi nekom vrstom klasifikacije. Područje u kojem se klasifikacija lica i spola osoba je vrlo široko te se kreće od zabavnih svrha kao što se društvene mreža pa sve to sigurnosti. Računalni programi putem algoritama dobivaju bitne informacije o ljudima koje uspoređuju s podacima iz baze podataka te dobivaju sve pouzdanije rezultate.

Svrha ovog rada je upoznati se s tehnikama i načinima prepoznavanja spola na temelju slike lica. Kako bi mogli prikazati algoritme te razumjeti njihove procese, najprije se moramo upoznati s pojmovima koji su vrlo bitni za ovu temu. U početku rada upoznat ćemo se s biometrijom te pojmovima vezanim za biometriju koji nam pomažu pri shvaćanju ove teme. Potom će biti prikazane razlike između muškog i ženskog lica i opisani algoritmi koji se koriste prilikom klasifikacije. Praktični dio ovog rada odnosit će se na aplikaciju koja prepoznaje spol željene osobe. Uz aplikaciju bit će opisan algoritam koji koristi sama aplikacija kao i njezini rezultati.

2. Biometrija

Riječ biometrija dolazi od grčkih riječi *bios* (život) i *metron* (mjera) te se koristi skupom metoda za prepoznavanje osoba temeljem njihovih fizičkih karakteristika i ponašanja. Klasifikacija spola samo je jedna od brojnih klasifikacijskih osobina kojima se bavi biometrija. U informatičkoj tehnologiji se biometrijska autentifikacija odnosi na tehnologije koje mjere i analiziraju fizičke i ponašajne karakteristike čovjeka.[3]

Prema CARnet CERT [3] biometrija objedinjuje korištenje specijalnih uređaja koji prate određene fizičke ili ponašajne karakteristike te programa koji analiziraju dobivene informacije. Važno je napomenuti da digitalizacija ima veliku ulogu u samom procesu klasifikacije. Proces se odvija tako da se računalo koristi isključivo kao posrednik, dok programski paket preuzima odluku što će poduzeti s digitaliziranim uzorcima.

2.1. Principi rada biometrijskih tehnika

Osnovni elementi na kojima se temelje biometrijske tehnike su digitalizacija i umjetna inteligencija.

2.1.1. Digitalizacija

Jedan od najvažnijih procesa u biometriji je digitalizacija, odnosno pretvaranje analognog signala u digitalni. Kako bi računalo moglo obrađivati podatke te iz njih dobivati korisne informacije, podaci moraju biti u digitalnom obliku. Analogni se signal pretvara pomoću elektroničkog uređaja DAC (engl. *Digital audio-video converter*). Kako bismo dobili što kvalitetniji digitalni oblik potrebno je imati kvalitetan DAC, a razlog tome je što se DAC nalazi u sklopovskom senzoru za prepoznavanje uzoraka pa se proporcionalno kvaliteti senzora dobiva kvaliteta uzorka. [3]

2.1.2. Umjetna inteligencija

Umjetna inteligencija (skraćeno UI) je mogućnost digitalnog računala ili računalno kontroliranog robota da izvodi zadatke povezane uz inteligentna bića [5]. U počecima su znanstvenici htjeli postići što višu razinu inteligencije te su napravili umjetnu inteligenciju koju su koristili za igranje šaha te su time povećavali inteligenciju i mjerili napredak. Kasnije se umjetna inteligencija počela koristiti za govornu interakciju s čovjekom u kojoj je predstavljala ravnopravnog sugovornika. U današnje je vrijeme umjetna inteligencija svugdje prisutna, dok se s njom najviše susrećemo u mobilnim uređajima. Umjetna inteligencija kao podloga za biometriju potrebna je zbog neuronskih mreža koje se primjenjuju u analizi slika i zvuka. [3]

2.2. Biometrijske tehnike

Biometriju možemo definirati kao model identifikacije osobe temeljem njihovih fizičkih karakteristika ili biometrijskih ponašanja. Prema CARnet CERT [3] je definirano kako se biometrija bavi identifikacijom pojedinca, temeljenoj na njihovim biološkim karakteristikama ili karakteristikama ponašanja, odnosno da predstavlja svojstvenu metodologiju za rješavanje identifikacije prema navedenim kriterijima.

2.2.1. Fizička biometrija

Fizička biometrija je grana biometrije koja nam omogućuje raspoznavanje ljudi temeljem njihovih fizičkih karakteristika. Kako bi se točno identificirali promatrani pojedinci potrebno je promatrati uzorke koji klasificiraju pojedince.[3] Neki od tih navedenih uzoraka su:

- **Biometrija lica** – prepoznavanje lica promatrane osobe jedna je od manje zahtjevnih metoda za koju je dovoljno svega jedna kamera i računalo. Nakon što kamera snimi lice promatrane osobe slika se uspoređuje s već postojećom slikom na računalo. Proces uspoređivanja bazira se na uspoređivanju ključnih obilježja lica kao što su dimenzija nosa, veličina brade, udaljenost između očiju, oblik uha itd. [3]. Iz navedenih činjenica možemo uočiti da je prepoznavanje lica vrlo jednostavna metoda koja u svijetu ima vrlo široku primjenu.
- **DNK zapis** – polazeći od činjenice da svaka osoba ima svoj jedinstveni DNK moguće je izraditi čitač DNK koji bi klasificirao osobe. Doista, takav čitač se u današnje vrijeme

i koristi. Nedostatak koji se može uočiti je ta da nakon što se sazna DNK pojedinaca potrebno ga je usporediti sa zapisom u bazi podataka kako bi dobili informacije o pojedincu. Drugim riječima, trebala bi postojati baza podataka koji bi sadržavala informacije o svim ljudima. Unatoč navedenom problemu čitač DNK zapisa koristi se u nekim područjima gdje ima veliki doprinos, npr. u medicini za određivanje rodbinskih veza. [3]

- **Skeniranje rožnice** – prilikom identificiranja osoba moguće je koristiti tehniku skeniranja rožnice. Pod pretpostavkom da svaka osoba ima jedinstvenu rožnicu može se saznati identitet osobe [3]. Ova tehnika najviše se koristi u području sigurnosti, primjerice u svrhu vođenja evidencije dolazaka, kamera snimi rožnicu te se dalje pomoću algoritama određuju karakteristične točke koje uz sliku služe kao identifikator osoba.
- **Geometrija šake** – autentifikacija pomoću geometrije šake jedna je od tehnika koja se primjenjuje već duže vrijeme. Osobe se prepoznaju po jedinstvenoj dužini i širini šake te debljini i površini [3]. Navedena tehnika u današnje vrijeme nema veliku primjenu.
- **Otisak prsta** – otisak prstiju sigurno je najpoznatija tehnika prepoznavanja ljudi. Naime, svaki čovjek ima jedinstvene pore i brazde kože prstiju što ga čini jedinstvenim, čak i jednojajčani blizanci imaju različite otiske prstiju [3]. Navedena tehnika klasifikacije vrlo se često primjenjuje u računalnim programima i mobilnim uređajima.

2.2.2. Biometrija ponašanja

Budući da su čovjekove fizičke karakteristike jedinstvene, one se također mogu koristiti za identifikaciju. Neke od tih fizičkih karakteristika promatranih pojedinaca su:

- **Prepoznavanje glasa** – kod autentifikacije pomoću glasa bitne karakteristike glasa su: boja glasa, modulacije, frekvencije, specifičnost izgovora, govorne mane i drugo [17]. Glas pojedinaca je u većini slučajeva jedinstven zato jer svaki pojedinac na svoj jedinstven način izgovara određene riječi te se pomoću glasa može identificirati. [3]


- **Prepoznavanje rukopisa** – jedan od načina autentifikacije je prepoznavanje rukopisa. Kako bi se utvrdio identitet osobe promatra se brzina pisanja, pritisak te kut pisanja. Ova metoda je veoma jednostavna te ne zahtijeva nikakvu posebnu opremu. Bitno je napomenuti da postoji mogućnost krivotvorenja rukopisa što može otežati sam proces prepoznavanja. [17]
- **Dinamika hoda** – ljudsko hodanje predstavlja prostorno-vremensku biometriju ponašanja[3]. Problem prilikom identifikacije pomoću dinamike hoda je sklonost mijenjanju načina hoda. Naime, svaki čovjek starenjem mijenja dinamiku hoda. Određene bolesti također mogu utjecati na dinamiku hoda.

3. Razlike muškog i ženskog lica

Razlike između muškog i ženskog lica su velike te lako uočljive. Kako bi računalo uspješno klasificiralo spol osobe potrebno je usporediti slike lica. Ponekad su razlike veoma očite te računalo s vrlo velikom preciznošću određuje spol, dok u nekim drugim slučajevima jedan spol zna poprimiti osobine drugog te postoji mogućnost donošenja krive odluke prilikom klasifikacije osoba prema spolu. U ovom poglavlju prikazane su slike pojedinih dijelova lica te su jasno istaknute njihove najbitnije razlike.

3.1.1. Oblik lica


Kod proučavanja muškog i ženskog lica možemo uočiti znatne razlike. Muško lice znatno je veće i izduljeno s naglašenim dijelovima kao što su nos, obrve, usta, dok je žensko lice nježno te su svi dijelovi manji. Još je jedna bitna razlika u samom obliku. Muško lice poprima pravokutni oblik, a žensko više kružni odnosno više zaobljen u odnosu na muško. [1]



Slika 1 Razlike između muškog i ženskog lica [2]

3.1.2. Obrve


Promatramo li obrve možemo zaključiti da je razlika u širini te debljini. Muške obrve su u pravilu šire i deblje te pokrivaju veću površinu u odnosu na ženske. Također, razlika je u poziciji obrva, muške obrve su spuštene, drugim riječima nalaze se bliže očiju u odnosu na ženske koje su bliže čelu. [1]



Slika 2 Razlike između muških i ženskih obrva [2]

3.1.3. Oči


Već sam oblik očiju muškaraca i žena je različit. Muške oči su u pravilu manje te okruglog obliku, dok su ženske veće i više okrugle, također muške oči su u pravilu manje otvorene od ženskih. Još jedna bitna razlika je u trepavicama, muške trepavice su manje i teško primjetljive za razliku od ženskih. [1]



Slika 3 Razlike između muških i ženskih očiju [2]

3.1.4. Obrazi


Muške obraze karakteriziraju naglašene linije te je naglašen dio bliži ustima dok je kod žena više naglašen dio ispod očiju. Ženski obrazi za razliku od muških nisu toliko naglašeni te su, moglo bi se reći, nježniji. Također, sam oblik je različit, dok muškarce karakteriziraju jake linije i pravokutni oblik, kod žena se može uočiti spiralni oblik obraza. [1]



Slika 4 Razlike između muških i ženskih obraza [2]

3.1.5. Nos


Razlika u nosu između muškaraca i žena najviše se uočava u veličini. Muškarce karakteriziraju veći nosovi s oštrim vrhom. Kod žena su najčešće dosta manji te je sam oblik nosa drugačiji, više zakrivljen i općenito manje uočljiv. [1]



Slika 5 Razlike između muškog i ženskog nosa [2]

3.1.6. Usta i usne


Ako promatramo razlike u ustima, možemo uočiti da su muške usne u pravilu tanje od ženskih, ali su šire. Znatna razlika u debljini usana može se uočiti kod gornje usne koja je znatno manja kod muškaraca. Također, udaljenost od usta do nosa je veća kod muškaraca u odnosu na žene. [1]



Slika 6 Razlike između muških i ženskih usta i usana [2]

3.1.7. Brada

Brada čini najveću razliku u izgledu muškog i ženskog lica. Muško lice ima četvrtastu čeljust s jakim oblinama dok je brada ravna, a ženska čeljust je zaobljena. Kao i kod većine prethodno proučavanih dijelova lica, muška brada je istaknuta i veća u odnosu na žensku.[1]

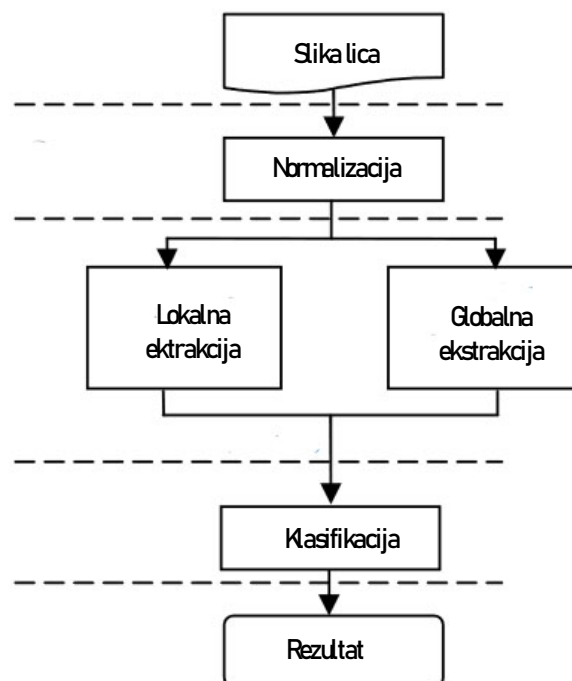


Slika 7 Razlike između muške i ženske brade [2]

4. Upotreba računala u postupku prepoznavanja spola

Klasifikacija osoba prema spolu temeljem slike lica ljudima je jednostavna, dok se isto ne može reći za računala. Klasifikacija spola je binarni problem u kojem se mora ustanoviti spol promatrane osobe. U ranim fazama razvijanja ove problematike znanstvenici su se koristili metodama prepoznavanja fizičkih sličnosti među spolovima. U današnje se vrijeme ovom problemu pristupa na posve drugačiji način. Sam problem dijeli se u dvije skupine prema načinu na koji se promatraju značajke lica: globalni i lokalni.

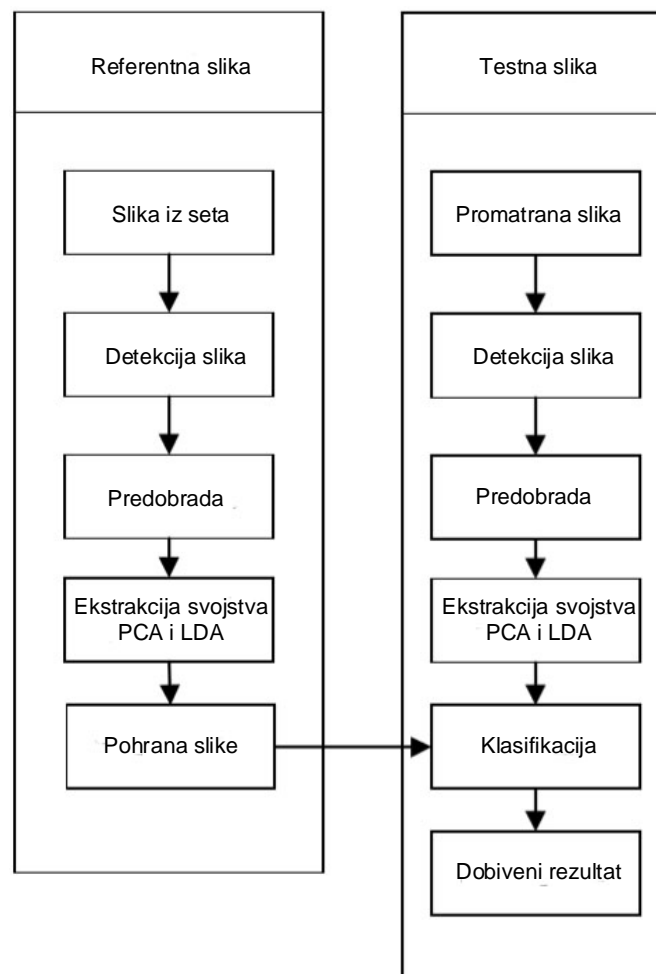
Globalni postupak klasifikacija (engl. *appearance feature-based*) koristi cijelu sliku lica prilikom klasifikacije te na nju gleda kao na jedan višedimenzionalni vektor. Lokalni postupak klasifikacije (engl. *geometric feature-based*), za razliku od globalnog, gleda pojedine dijelove slike te na temelju razlike utvrđuju spol. U pravilu je globalni postupak klasifikacije jednostavniji te brži od lokalnog postupka. Prilikom korištenja oba postupka moramo paziti na različite faktore kao što su način slikanja, osvjetljenje, pozadina slike itd. koji mogu utjecati na točnost. Na slici 8 prikazana je arhitektura klasifikacija spola osobe. [15]



Slika 8 Arhitektura klasifikacije spola [15]

5. Pregled algoritama za određivanje spola na temelju slike lica

Proces određivanja spola promatrane osobe sastoji se od više koraka. Korake koji se provode možemo podijeliti u dvije skupine. Prvi dio provodi se na referentnim slikama kako bi se dobili podaci koji će služiti za usporedbu, nadalje drugi korak je procesirati sliku za koju želimo dobiti rezultati te je potom usporediti sa slikom iz prvog koraka. Slika 9 prikazuju korake opisanog procesa. [18]




Slika 9 Koraci određivanja spola osobe [18]

U nastavku su ukratko opisani algoritmi koji imaju veliku primjenu prilikom prepoznavanja lica i spola promatrane osobe.

5.1. Analiza glavnih komponenti

Analiza glavnih komponenti (engl. *Principle Component Analysis*, PCA) jedan je od najefikasnijih algoritama u području kompresije slike, razvijen 1901. godine. Razvio ga Karl Pearson. PCA je biometrijska tehnika koja je klasificirana kao jedna od statističkih metoda u ovom području. Glavna svrha PCA algoritma je smanjenje dimenzionalnosti slike. [19]

Algoritam uzima jednostavne dijelove ulazne slike te od njih sastavlja nove slike manjih dimenzija koje mogu asociirati na sijenu. [19] Takve slike se nazivaju *Eigenfaces* i prikazane su na slici 10. Iz jedne originalne slike nastaje više pojednostavljenih slika.



Slika 10 Prikaz slika nastalih korištenjem PCA algoritma [25]

Način na koji taj algoritam radi je takav da za svaku ulaznu sliku odredi koliko korisnih informacija sadrži za pojedinu dimenziju te ih poreda po važnosti. Nadalje, algoritam temeljem važnosti komponenti određuje koliko ih će se koristiti. Ovim postupkom odvajaju se nepotrebni podaci, a dobivene se slike sastoje od isključivo korisnih informacija koje se dalje mogu obrađivati.[20]

5.2. Analiza linearnih diskriminanti

Analiza linearnih diskriminanti (engl. *Linear Discriminant Analysis*, LDA) koristi se kod reduciranja dimenzionalnosti u brojnim klasifikacijskim problemima kao što su prepoznavanje spola, lica govora i drugo. Algoritam projektira visoko dimenzionirane podatke u nisko dimenzionirane tako što odvaja točke različitih klasa i minimizira raspršenost samih podataka.[21]

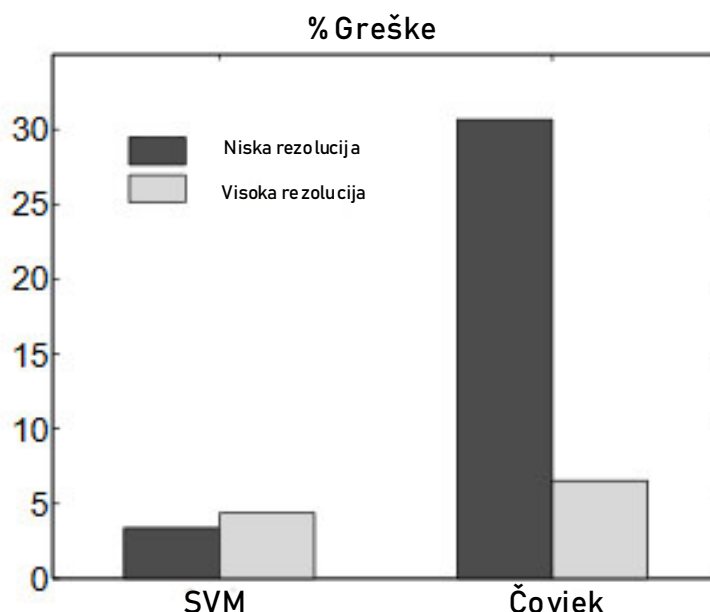
Način rada LDA algoritama vrlo je sličan PCA algoritmu. Oba algoritma koriste se linearnom transformacijom koja rezultira smanjenjem dimenzija promatranog skupa podataka.

Prema [22] usporedbom navedenih algoritama na malom skupu podataka zaključeno je da PCA algoritam kod klasifikacije lica i spola daje bolje rezultate. Bitno je napomenuti da se u svrhu što boljih rezultata navedeni algoritmi često kombiniraju. PCA algoritam se koristi kako bi se smanjio broj dimenzija, a zatim LDA algoritam optimalno dijeli klase. [18]

5.3. Metoda potpornih vektora

Metoda potpornih vektora (engl. *Support Vector Machines*, SVM) prema raznim izvorima jedna je od najboljih pristupa pri klasifikaciji podataka. Algoritam se može definirati kao binarni klasifikator koji se u najčešće koristi pri raznim klasifikacijama podataka. SVM algoritam radi na način da odvaja značajke suprotnih klasa hiper-ravnine s ciljem da je razmak između najbližih elemenata i hiper-ravnine najveći. [20]

U znanstvenom radu „Gender Classification with Support Vector Machines“ [23] napravljena je usporedba rezultata klasifikacije spola između SVM algoritma i čovjeka. U istraživanju je pristupilo 30 sudionika koji su klasificirali 254 slike. Slike su bile podijeljene u dvije skupine, slike niske rezolucije te slike visoke rezolucije. Slika 11 prikazuje dobivene rezultate.



Slika 11 Usporedba rezultata SVM algoritma i čovjeka [11]

Na slici 11 možemo uočiti da su rezultati za SVM algoritam bolji u odnosi na čovjekove rezultate nevezano za kvalitetu slike. Kod niske rezolucije slike ljudska greška je znatno veća, dok su kod visoke rezolucije greške vrlo slične ali SVM algoritam ipak ostvaruje niži postotak greške.

5.4. Samo organizirajuća mapa

Samo organizirajuća mapa (engl. *Self-Organizing Map*, SOM) je poznata umjetna neuronska mreža koja se često koristi u klasifikacijskim problemima. Kako i kod svake neuronske mreže značajan čimbenik u konačnom rezultatu su ulazni podaci. Također, sami rezultati će ovisiti i o broju treninga provedenih na samom skupu, veći broj treninga rezultira većom točnošću konačnih rezultata. Samo ime algoritam dobiva prema neuronima koji sami sebe reorganiziraju u svrhu boljih rezultata.

Način na koji radi SOM algoritam nije posve isti kao i neuronske mreže. Sam proces se može podijeliti u dva modula. Prvi modul pod nazivom „trening“ zadužen je za izgradnju mape koristeći ulazne podatke, dok drugi modul naziva „mapiranje“ automatski klasificira nove ulazne vektore. [24] Način rada neuronske mreže detaljnije je opisan u nadolazećim poglavljima.


6. Neuronska mreža kao algoritam za određivanje spola

6.1. Umjetne neuronske mreže

Prema definiciji, umjetna neuronska mreže je skup međusobno povezanih jednostavnih procesnih elemenata (neurona) čija se funkcionalnost temelji na biološkom neuronu koji služi distribuiranoj paralelnoj obradi podataka [6]. U današnje vrijeme korištenje neuronskih mreža jako je zastupljeno te ima veliko područje primjene. Međutim, nije uvijek tako bilo. Godine 1943. znanstvenici iz „*Massachusetts Institute of Technology*“ [6] počeli su proučavati rad ljudskog mozga te su na temelju proučavanja napravili prvi model neuronske mreže. Samo ime dolazi po uzoru na ljudski mozak. Deset godina nakon početnog modela počeli su se javljati modeli koji su imali veću primjenljivost. Jedini problem tog razdoblja je bila neusklađenost u razvitku, drugim riječima tadašnja računala nisu bila dovoljno jaka za rješavanje kompleksnijih problem. S godinama računala su se razvijala isto kao i pristup korištenja i sama struktura mreže, te je danas primjena i funkcionalnost izrazito visoka.

6.1.1. Neuron

Prema uzoru na biološki neuron, McCulloch-Pitts definiraju jednostavni model biološkog neurona perceptron, odnosno TLU-perceptron (engl. *Threshold Logic Unit*) [6] koji će u nastavku biti i detaljnije pojašnjen. Na slici 12 nalazi se perceptron.



Slika 12 Prikaz perceptrona

Kao što se može uočiti na slici, svaki neuron se sastoji od n ulazi i jednog izlaza. Dani neuron sastoji se od tri ulaza redom nazvanih x_1 , x_2 i x_3 , te jednog izlaza y . Svaki ulaz ima svoju osjetljivost odnosno težinu s kojom se množi, te težine su realni brojevi baš kao i ulazi. Težine možemo označavati redom w_1, w_2, w_3 . Nakon što se ulazi pomnože sa svojim težinama, njihovoj sumi dodaje se pomak w_0 (još se označava i s b engl. *bias*). [9]

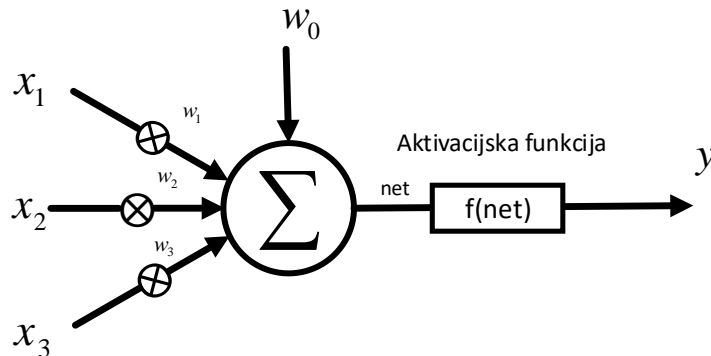
Rezultat odnosno izlaz svakog neurona može biti 1 ili 0. Kako bismo došli do traženog rezultata dobiveni umnožak potrebno je usporediti s parametrom t . Parametar t (engl. *threshold*) predstavlja realan broj pri kojem će se neuron aktivirati. Ako je umnožak veći od t rezultat će biti 1, dok će u suprotnom biti 0. Matematički gledano, rezultat možemo zapisati algebarskim izrazom.

$$y = \begin{cases} 0, & \sum_{i>0}^n x_i \cdot w_i + w_0 < t \\ 1, & \sum_{i>0}^n x_i \cdot w_i + w_0 > t \end{cases}$$

Definiranim matematičkim izrazom opisuje se vrlo jednostavni TLU-perceptron.

6.1.2. Aktivacijske funkcije

Općenito, umjetni neuron ne mora koristiti ranije opisanu funkciju praga za izračun vrijednosti, već može koristiti i druge aktivacijske funkcije (prijenosne funkcije, transfer funkcije). Razlog zašto se u većini slučajeva ne koristi jednostavni TLU-perceptron je taj što i mali utjecaj na težinu može uzrokovati promjenom konačnog rezultata iz 0 u 1 i obrnuto. [6]



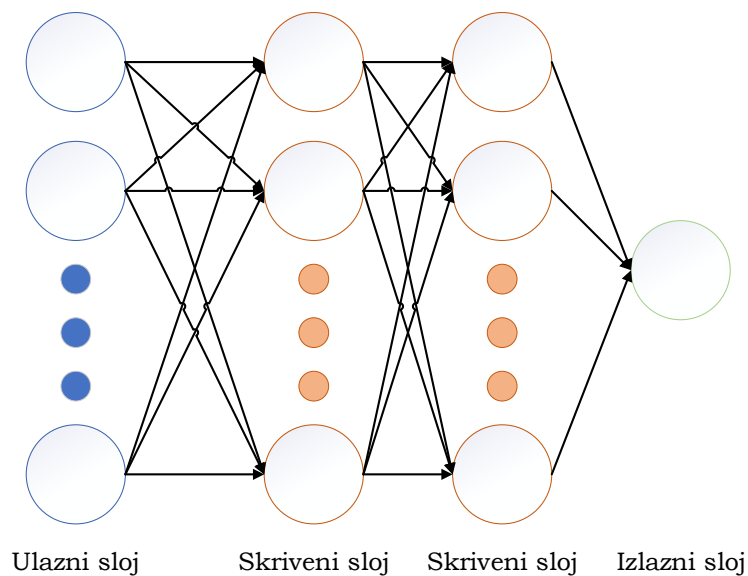
Slika 13 Umjetni neuron

Slika 13 prikazuje umjetni neuron te aktivacijsku funkciju. U današnje vrijeme postoje brojne aktivacijske funkcije, neke od češće korištenih su [6]

- Funkcija identiteta (ADALINE - neuron)
- Funkcija skoka (TLU - perceptron)
- Sigmoidalna funkcija (sigmoidalni neuron)
- Tangens hiperbolna funkcija
- Zglobnica (engl. *Rectified Linear Unit*, ReLU)
- Propusna zglobnica (engl. *Leaky Rectified Linear Unit*, LReLU)

6.1.3. Struktura mreže

Do sada navedeni primjeri odnosili su se isključivo na jedan neuron, dok u stvarnosti mrežu čini više neurona podijeljenih u slojeve. Tako razlikujemo tri sloja: ulazni, skriveni i izlazni sloj. Ulazni sloj kako mu i samo ime kaže predstavlja ulazne podatke odnosno početne vrijednosti na temelju koji se izračunava vrijednost traženog problema. Izlazni sloj predstavlja traženu vrijednost, drugim riječima gotov rezultat. Sve između ulaznog sloja i izlaznog sloja pripada skrivenom sloju. Pojednostavljeni izgled strukture neuronske mreže prikazan je na slici 14. [9]




Slika 14 Prikaz arhitekture neuronske mreže

Kako bi mreža rezultirala točnom vrijednošću potrebno je podesiti težine. Najpopularnije algoritam za izračunavanje težina je algoritam širenja unatrag (engl. *error backpropagation*) koji se vrlo često koristi te ima veliku razinu točnosti ali i sama složenost algoritma je na visokoj razini. [9]

6.2. Konvolucijska mreža

Konvolucijske neuronske mreže možemo promatrati kao nadogradnju na višeslojne neuronske mreže. Kao i ostale mreže, konvolucijska mreža se sastoji od ulaznog, skrivenog i izlaznog sloja. Karakteristično za konvolucijsku neuronsku mrežu su konvolucijski sloj, sloj sažimanja (engl. *pooling*) te potpuno povezani sloj, koji su prikazani na slici 15. Na ulazu u mrežu nalazi se slike u boji, zatim naizmjenice slijede konvolucijski sloj i sloj sažimanja. Mreža se u prosijeku sastoji od oko deset slojeva što ju svrstava u kategoriju dubokih neuronskih mreža.




Slika 15 Prikaz konvolucijske neuronske mreže [8]

Konvolucijski slojevi te slojevi sažimanja sastoje se od dvodimenzionalnih neurona koji se nazivaju mapa značajki (engl. *Feature maps*). U svakom sloju mapa značajki postaje sve manja te je u zadnjem sloju 1×1 i predstavlja vezu na perceptron koji se nalazi u zadnjim slojevima konvolucijske neuronske mreže. [7]

Rad s konvolucijskim mrežama pokazao je da je sama arhitektura konvolucijskih mreža vrlo pogodna za rješavanje problema prepoznavanja značajki slika odnosno bilo kakvom radu sa slikama. Iz navedenog razloga konvolucijske mreže se nameću kao vrlo dobar odabir pri radu sa slikama. [9]


6.3. Google Inception-v3

Inception-v3 je konvolucijska neuronska mreža namijenjena za klasifikaciju slika. Sama arhitektura mreže napravljena je po uzoru na GoogLeNet još poznatu kao i Inception-v1 prikazanu na slici 16.



Slika 16 Arhitektura GoogLeNet mreže [11]


GoogLeNet mreža nastala je 2014. godine kao rezultat ILSVRC2014 natjecanja gdje je osvojila prvo mjesto. Razina greške prepoznavanja koju je GoogLeNet postigla iznosila je 6.67% što je bilo vrlo blizu greške čovjeka. Sama mreža se sastoji od nekoliko vrlo malih konvolucija sa smanjenim brojem parametara. Arhitektura se sastoji od 22 sloja konvolucijske neuronske mreže čime je smanjen broj parametara sa 60 milijuna (AlexNet, popularna mreža i 2012. godine) na 4 milijuna. [12]



Slika 17 Arhitektura Inception-v3 mreže [11]

Na slici 17 nalazi se arhitektura Inception-v3 mreže. Ako usporedimo slike broj 16 i 17 možemo uočiti da su arhitekture GoogLeNet i Inception-v3 mreže vrlo slične što dokazuje da je Inception-v3 posljedica GoogLeNet mreže.

Inception-v3 neuronska mreža arhitekturno nije građena kao ostale konvolucijske mreže. Kao što je već prije navedeno konvolucijska mreža sastoji se od mape značajki koja se kroz mrežu smanjuje dok ne dođe do veličine 1x1. Inception-v3 modul uzima prethodni sloj te istovremeno koristi četiri konvolucije, 1x1 , 3x3 , 5x5 i 3x3 konvoluciju sažimanja, te se konvolucije spajaju i nastavljaju postupak. Ovaj pristup mreži omogućuje višerazinsko odvajanje komponenata slike uz mali broj parametara i malu razinu greške. Slika 18 prikazuje pojednostavljeni modul neuronske mreže Inception-v3. [11]



Slika 18 Modul mreže Inception-v3 [11]

Tablica 1 [10] prikazuje greške najpoznatijih neuronskih mreža današnjice. Možemo primijetiti da ranije spomenuta mreža GoogLeNet ima grešku od 6.67% dok mreža s najmanjom greškom je baš Inception-v3 te iznosi 3.58%

Neuronska mreža	Razina greške
VGGNet	6.8%
GoogLeNet	6.67%
PReLU	4.94%
BN-Inception	4.9%
Inception-v3	3.58%

Tablica 1 Pregled greški popularnih neuronskih mreža [10]

Implementacija Inception-v3-a napravljena je u Tensor Flow-u. Tensor Flow je open-source biblioteka namijenjena za područje umjetne inteligencije razvijena od strane Google-a. U praktičnom radu koji je detaljno opisan u sljedećem poglavlju korištena je Googleova implementacija Inception-v3 mreže pomoću Tensor Flow-a.

7. Aplikacija za klasifikaciju osoba prema spolu na temelju slike lica

Praktični dio rada je aplikacija koja koristi jedan od prethodno navedenih algoritama te pomoću njega klasificira osobe prema spolu. Algoritam koji je implementiran je neuronska mreža, točnije ranije opisana konvolucijska mreža Inception-v3. Implementacija konvolucijske mreže je preuzeta gotova, implementirana pomoću TensorFlow-a od strane Google-a [16].

7.1. DataSet

U izradi praktičnog dijela rada korištena je Faces94 baza podataka [13]. Faces94 baza podataka sadrži slike lica 153 pojedinca veličine 180x200 piksela. U kolekciji slika nalazi se 20 ženskih osoba te 133 muške osobe. Jedna od vrlo dobrih karakteristika ovog skupa podataka je raspodijeljenost slika. Naime, slike muških i ženskih osoba odvojene su u različite direktorije te samim time skup podataka čine vrlo pogodnim za daljnje korištenje. Na slikama 19 i 20 nalaze se primjeri slika muškaraca i žena iz odabranog skupa.



Slika 19 Primjer slika muškaraca [13]



Slika 20 Primjer slika žena [13]

Uzmemo li u obzir prethodno navedene podatke o Faces94 bazi podataka možemo uočiti da broj slika muškaraca i žena nije jednak. Iz navedenog razloga prilikom izrade aplikacije nije korišten cijeli skup slike nego samo jedan dio. Korišteno je svega 760 slika od kojih se 380 slika odnosilo na muškarce, a drugih 380 na žene. Skup za pojedini spol sadrži slike 19 različitih osoba, a svaka osoba ima 20 različitih izraza lica.

7.2. Korištena tehnologija i alata


Kao što je već prije navedeno, izrada praktičnog dijela izvedena je pomoću neuronskih mreža, točnije, konvolucijske mreže Inception-v3. Korištena je već gotova i istrenirana mreža implementirana pomoću TensorFlow-a. Googleova okvir TensorFlow nudi gotove skripte implementirane u programskom jeziku Python za potrebe ponovnog treniranja neuronske mreže na vlastitom skupu podataka [16]. Navedena neuronska mreža trenirana je na prethodno opisanom skupu podataka te su dobiveni rezultati grafički prikazani.

Osim klasifikacije prema spolu, implementirana je i klasifikacija lica. Za klasifikaciju lica korištena je već gotova skripta „*haarcascade_frontalface*“ implementirana pomoću open-source alata OpenCV [14] te imenovana prema mađarskom matematičaru Alfréd Haar-u.

Za izradu grafičkog sučelja aplikacije korišten je Visual Studio 2017 i programski jezik C#. Visual Studio nudi brojne ugrađene elemente koji olakšavaju korištenje aplikacije te samom korisniku nude vrlo dobro iskustvo korištenja.

7.3. Prikaz aplikacije

Sama aplikacija za klasifikaciju osoba prema spolu na temelju slike lica izrađena je kao što je već prije napisano u Visual Studio. Aplikacija je vrlo jednostavna i sastoji se svega od jednog glavnog izbornika. Izbornik prikazan na slici 1 omogućuje korisniku odabir slike koju želi klasificirati.



Slika 21 Prikaz izbornika aplikacije

Nakon što korisnik na vlastitom računalu odabere željenu sliku, aplikacija prikazuje odabranu sliku s broječanim vrijednostima koji odgovaraju svakom spolu. Osim prepoznavanja spola, aplikacija također prepoznaje i lice promatrane osobe kao što je prikazano na slici 22.



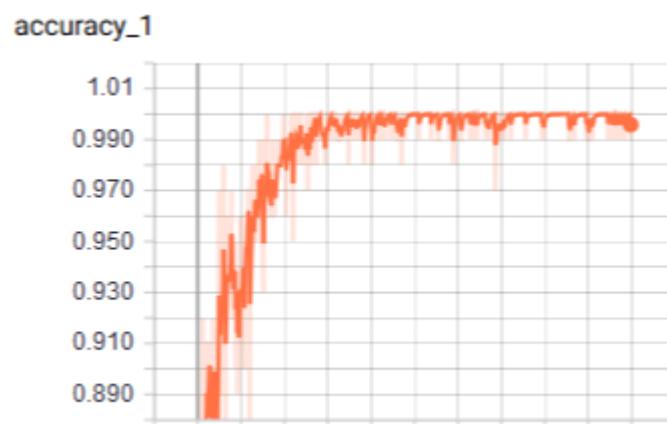
Slika 22 Prikaz rada aplikacije

7.4. Dobiveni rezultati

Uobičajeni pristup kod treniranja neuronske mreže je da se skup podataka podijeli u tri dijela: dio za trening, validaciju i dio za testiranje. Tako je od ukupnog broja slika iz odabranog seta odabrano 10% slika koje će se koristiti za validaciju, dok će preostalih 90% služiti za trening. Skup za testiranje je originalno korišten kao 10% istog seta, ali zbog unapređenja rezultata i veće pouzdanosti, korišten je potpuno novi skup podataka koji se sastoji od 100 muških i 100 ženskih slika.


Set za trening, kao što mu i samo ime govori, služi mreži za trening te se on u pravilu sastoji od najvećeg broja slika. Znatno manji skup za validaciju služi za provjeru točnosti mreže tijekom treninga te usklađivanje parametara mreže u svrhu boljih rezultata. Dok je skup za testiranje skup na kojem se provjerava točnost gotove, istrenirane mreže.

U nastavku su prikazani dobiveni rezultati za trening i validaciju. Rezultati su prikazani u grafičkom obliku .




Slika 23 Graf točnosti treninga

Graf na slici 23 prikazuje točnost treninga. Kao što možemo uočiti sa slike točnost raste tijekom treninga što je vrlo poželjno.

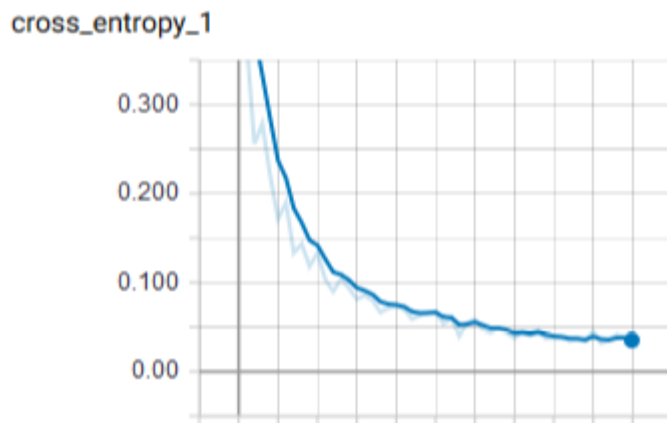


Slika 24 Graf gubitka tijekom trening

Slijedeći graf prikazuje gubitke tijekom treninga koji suprotno od točnosti padaju. Kako bismo postigli što točniji trening koeficijent gubitka treba biti što manji, odnosno što bliži nuli. Na slijedećim grafovima prikazana je točnost i koeficijent gubitka za validaciju treninga.




Slika 25 Graf točnosti validacije




Slika 26 Graf gubitka tijekom validacije

Zadnja dva grafa prikazuju preklapanja grafova validacije i treninga kako bismo lakše uočili sličnosti.



Slika 27 Graf usporedbe točnosti kod treninga i validacije



Slika 28 Graf usporedbe gubitka kod treninga i validacije

Jasno je uočljivo da su grafovi validacije i treninga vrlo slični. Razlog tome je velika preciznost tijekom trening izazvana sličnim slikama. Naime, set slika sastoji se od 20 slika svake osobe, a pozadina je uvijek zelena. Navedene činjenice značajno utječu na dobivene rezultate. Slike koje su služile za validaciju su izrazito slične testiranim slikama te je kao posljedica rezultat treninga, validacije i testiranja bio besprijekoran, odnosno 100%. Kako je vrlo mala šansa da sama mreža ima besprijekornu točnost, mreža je testirana, kao što je već prije navedeno, na 200 slika iz različitog seta.

Rezultat testiranja gotove mreže na novom setu slika dao je realnije rezultate. Testiranje je ostvarilo rezultat od 81.36% što je relativno nizak postotak. Kako bismo povećali efikasnost i sam postotak potrebno je uzeti drugi dataset s većim brojem slika i manjim sličnostima među slikama.

8. Zaključak

U radu su opisane najbitnije teme vezane za klasifikaciju osoba prema spolu na temelju slika. Razrađen je pogled s biometrijske strane, prikazane su fizičke razlike u licima muškaraca i žena, opisani su algoritmi koji se koriste pri klasifikaciji te je na kraju implementiran jedan od algoritama i napravljena je funkcionalna aplikacija za prepoznavanje spola osobe. Razlog zašto je baš neuronska mreža odabrana kao algoritam za klasifikaciju je njezina popularnost, velika funkcionalnost te kroz različite već razvijene okvire, module i alate izrazita jednostavnost. Dobiveni rezultati u praktičnom dijelu rada pokazuju da postoji mjesto za poboljšanje. Vrlo bitan faktor kod bilo kakve klasifikacije je točnost, posebice ako se aplikacija koristi na odgovornim mjestima gdje greške nisu poželjne. Kako bi se točnost praktičnog rada povećala potrebno bi bilo trenirati mrežu na većem i manje izoliranom skupu podataka, odnosno skupu s manjom sličnosti između slika. Ako gledamo na samu aplikaciju s pogleda korisnika, možemo zaključiti da je ona vrlo jednostavna te bez ikakvih računalnih ograničenja.

U današnje vrijeme klasifikacije osoba su svugdje prisutne i njihov korištenje se povećava. Svakodnevno se susrećemo s aplikacijama koje koriste nekakvu vrstu klasifikacije u raznim područjima od zabave pa sve do kriminalne policije i sigurnosti. Temeljem svega navedenog možemo zaključiti da je područje koje je opisano u ovom radu vrlo zanimljivo i veoma korisno i vrijedno proučavanja.

Popis literature

- [1] "The Differences Between Male and Female Portraits." [Na internetu]. Dostupno: <https://design.tutsplus.com/articles/the-differences-between-male-and-female-portraits--vector-14954>. [pristupano 27.08.2018].
- [2] "7 Features of a Feminine Face | Dr. Vartan Mardirossian." [Na internetu]. Dostupno: <http://palmbeachplastics.com/7-features-of-a-feminine-face/>. [pristupano 27.08.2018].
- [3] "Biometrija", 2006. [Na internetu]. Dostupno: <https://www.cis.hr/www.edicija/LinkedDocuments/CCERT-PUBDOC-2006-11-167.pdf>. [pristupano 27.08.2018].
- [4] M. Boban, M. Perišić, "BIOMETRIJA U SUSTAVU SIGURNOSTI , ZAŠTITE I NADZORA INFORMACIJSKIH SUSTAVA" pp. 115–148.
- [5] "Artificial intelligence | Definition, Examples, and Applications | Britannica.com." [Na internetu]. Dostupno: <https://www.britannica.com/technology/artificial-intelligence>. [pristupano 27.08.2018].
- [6] B. D. Bašić, M. Čupić, J. Šnajder, "Umjetne neuronske mreže," pp. 1–15, 2008.
- [7] V. Vukotić, "Raspoznavanje objekata dubokim neuronskim mrežama," 2014.
- [8] "An example of CNN architecture. | Download Scientific Diagram." [Na internetu]. Dostupno: https://www.researchgate.net/figure/An-example-of-CNN-architecture_fig1_320748406. [pristupano 27.08.2018].
- [9] D. Kopljar, "Konvolucijske neuronske mreže," 2016.
- [10] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," 2015.
- [11] C. Szegedy et al., "Going deeper with convolutions," Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., vol. 07-12-June-2015, pp. 1–9, 2015.
- [12] "CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more" [Na internetu]. Dostupno: <https://medium.com/@sidereal/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5>. [pristupano 27.08.2018].
- [13] "Face Recognition Data." [Na internetu]. Dostupno: <https://cswww.essex.ac.uk/mv/allfaces/faces94.html>. [pristupano 27.08.2018].

- [14] "OpenCV: Face Detection using Haar Cascades." [Na internetu]. Dostupno: https://docs.opencv.org/3.4.1/d7/d8b/tutorial_py_face_detection.html. [pristupano 27.08.2018].
- [15] Z. Xu, L. Lu, i P. Shi, "A Hybrid Approach to Gender Classification from Face Images," 19th Int. Conf. Pattern Recognit., pp. 1–4, 2008.
- [16] "How to Retrain an Image Classifier for New Categories | TensorFlow Hub | TensorFlow." [Na internetu]. Dostupno: https://www.tensorflow.org/hub/tutorials/image_retraining. [pristupano 27.08.2018].
- [17] Ž. Radmilović, "Biometrijska identifikacija," Polic. i Sigur., vol. 17, no. 3–4, pp. 159–180, 2008.
- [18] R. Ferizal, S. Wibirama, i N. A. Setiawan, "Gender recognition using PCA and LDA with improve preprocessing and classification technique," 2017.
- [19] A. Alkandari, "Principle Component Analysis Algorithm (PCA) for Image Recognition," Comput. Technol. Inf. Manag. (ICCTIM), 2015 Second Int. Conf., pp. 76–80, 2015.
- [20] J. Baketarić, "KLASIFIKACIJA EMOCIJA NA OSNOVI SLIKE LICA," 2017.
- [21] S. Ji and J. Ye, "Generalized linear discriminant analysis: A unified framework and efficient model selection," *IEEE Trans. Neural Networks*, vol. 19, no. 10, pp. 1768–1782, 2008.
- [22] S. Raschka, "Python Machine Learning", 2015.
- [23] B. Moghaddam i M. Yang, "Gender Classification with Support Vector Machines," Autom. Face Gesture Recognition, 2000. Proceedings. Fourth IEEE Int. Conf., pp. 306--311, 2000.
- [24] S. Roy i S. K. Bandyopadhyay, "Gender recognition using Self Organizing Map (SOM) -an unsupervised ANN approach," Int. J. Emerg. Res. Manag. &Technology, vol. 9359, no.
- [25] "Principal Component Analysis for Dimensionality Reduction - Subconscious Musings." [Na internetu]. Dostupno: <https://blogs.sas.com/content/subconsciousmusings/2015/10/26/principal-component-analysis-for-dimensionality-reduction/>. [pristupano 27.08.2018].

Popis slika

Slika 1 Razlike između muškog i ženskog lica [2]	5
Slika 2 Razlike između muških i ženskih obrva [2]	6
Slika 3 Razlike između muških i ženskih očiju [2]	6
Slika 4 Razlike između muških i ženskih obraza [2]	7
Slika 5 Razlike između muškog i ženskog nosa [2]	7
Slika 6 Razlike između muških i ženskih usta i usana [2]	8
Slika 7 Razlike između muške i ženske brade [2]	8
Slika 8 Arhitektura klasifikacije spola [15]	9
Slika 9 Koraci određivanja spola osobe [18]	10
Slika 10 Prikaz slika nastalih korištenjem PCA algoritma [25]	11
Slika 11 Usporedba rezultata SVM algoritma i čovjeka [11]	13
Slika 12 Prikaz perceptrona	15
Slika 13 Umjetni neuron	16
Slika 14 Prikaz arhitekture neuronske mreže	17
Slika 15 Prikaz konvolucijske neuronske mreže [8]	18
Slika 16 Arhitektura GoogLeNet mreže [11]	19
Slika 17 Arhitektura Inception-v3 mreže [11]	19
Slika 18 Modul mreže Inception-v3 [11]	20
Slika 19 Primjer slika muškaraca [13]	22
Slika 20 Primjer slika žena [13]	22
Slika 21 Prikaz izbornika aplikacije	24
Slika 22 Prikaz rada aplikacije	24
Slika 23 Graf točnosti treninga	25

Slika 24 Graf gubitka tijekom trening	26
Slika 25 Graf točnosti validacije	26
Slika 26 Graf gubitka tijekom validacije	27
Slika 27 Graf usporedbe točnosti kod treninga i validacije.....	27
Slika 28 Graf usporedbe gubitka kod treninga i validacije	28

Popis tablica

Tablica 1 Pregled greški popularnih neuronskih mreža [10]	20
---	----