

Usporedba algoritama i ljudske procjene za klasifikaciju osoba prema dobi, spolu i rasi na temelju fotografije lica

Dolenec, Sara

Undergraduate thesis / Završni rad

2020

*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://urn.nsk.hr/um:nbn:hr:211:530174>

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

*Download date / Datum preuzimanja: **2024-06-30***



Repository / Repozitorij:

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



**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN**

Sara Dolenec

**USPOREDBA ALGORITAMA I LJUDSKE
PROCJENE ZA KLASIFIKACIJU OSOBA
PREMA DOBI, SPOLU I RASI NA
TEMELJU FOTOGRAFIJE LICA**

ZAVRŠNI RAD

Varaždin, 2020.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Sara Dolenec

Matični broj: 0016124574

Studij: Poslovni sustavi

**USPOREDBA ALGORITAMA I LJUDSKE PROCJENE ZA
KLASIFIKACIJU OSOBA PREMA DOBI, SPOLU I RASI NA
TEMELJU FOTOGRAFIJE LICA**

ZAVRŠNI RAD

Mentor/Mentorica:

Doc. dr. sc. Grd Petra

Varaždin, srpanj 2020.

Sara Dolenc

Izjava o izvornosti

Izjavljujem da je moj završni/diplomski 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

U ovom radu analizirani su algoritmi za klasifikaciju osoba prema dobi, spolu i rasi. Napravljeno je ispitivanje ljudske procjene na bazi FG-NET pomoću ankete. Uspoređena je točnost više algoritama i ljudske procjene. Pretpostavljeno je da će ljudska procjena biti točnija od algoritama. Istraživanjem je zaključeno da to ipak nije u većini slučajeva istinito. Algoritmi i metode koje se koriste za klasifikaciju ljudi po dobi, spolu i rasi su napredovali, a uskoro možda i neće biti usporedivi s ljudskom procjenom.

Ključne riječi: biometrija; slika lica; procjena dobi; procjena rase; procjena spola; algoritam; klasifikacija;

Sadržaj

| | |
|--|----|
| 1. Uvod | 1 |
| 2. Percepcija lica i problemi s određivanjem dobi, spola i rase..... | 3 |
| 2.1. Percepcija lica..... | 3 |
| 2.1.1. Razlike lica po spolu..... | 3 |
| 2.1.2. Razlike lica po dobi | 4 |
| 2.1.3. Razlike lica po rasi | 6 |
| 2.2. Problemi s procjenom spola, dobi i rase..... | 7 |
| 3. Problem istraživanja i hipoteza | 9 |
| 4. Metode i tehnike prikupljanja podataka | 10 |
| 4.1. Anketa..... | 11 |
| 4.2. Algoritmi za klasifikaciju lica po dobi, spolu i rasi..... | 12 |
| 4.2.1. Algoritam za klasifikaciju dobi..... | 12 |
| 4.2.2. Algoritam za klasifikaciju spola..... | 13 |
| 4.2.3. Algoritam za klasifikaciju rase | 15 |
| 4.2.4. Algoritam za zajedničku klasifikaciju dobi, spola i rase..... | 17 |
| 5. Rezultati istraživanja | 18 |
| 5.1. Rezultati ljudske procjene | 18 |
| 5.2. Rezultati algoritama za klasifikaciju lica po dobi, spolu i rasi | 19 |
| 5.2.1. Rezultati algoritma za klasifikaciju dobi | 19 |
| 5.2.2. Rezultati algoritma za klasifikaciju spola..... | 19 |
| 5.2.3. Rezultati algoritma za klasifikaciju rase | 20 |
| 5.2.4. Rezultati algoritma za zajedničku klasifikaciju dobi, spola i rase..... | 20 |
| 6. Zaključak | 22 |
| Popis literature | 24 |
| Popis slika | 27 |
| Popis tablica | 28 |

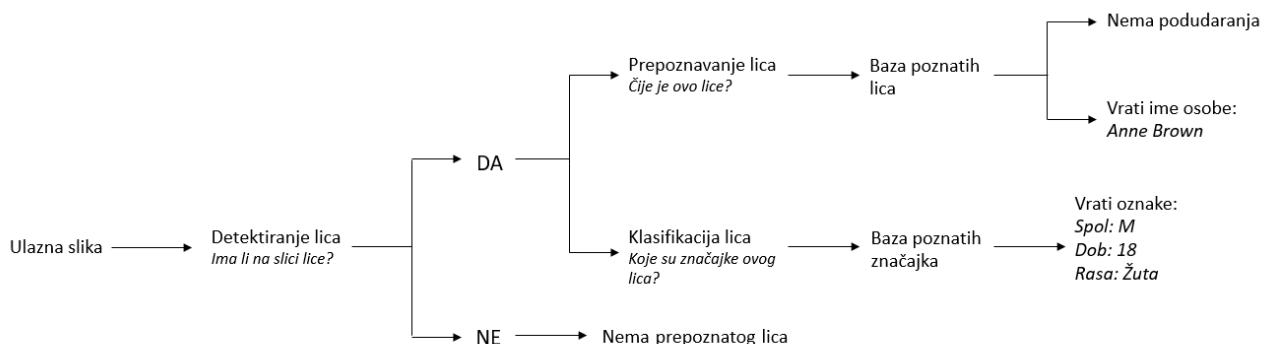
1. Uvod

„Automatizirana analiza lica podskup je tehnologije računalnog vida dizajnirane za specifični zadatak analize ljudskih lica u digitalnim slikama i videozapisima. Tehnologije analize lica izrađene su koristeći brojne pristupe strojnom učenju, uglavnom za postizanje dva cilja: prepoznavanje i klasifikacija lica.“ (Scheuerman, Wade, Lustig, Brubaker, 2020, str. 6).

Identifikacija ljudskog lica široko je rasprostranjena i poprilično istražena. Koristi se kod policijske istrage, video nadzora pa čak i kod pametnih telefona koji se otključavaju na prepoznavanje lica. Puno je manje istraženo kako procijeniti ljudsku dob, spol i rasu na temelju fotografije lica.

Scheuerman i sur. (2020, str. 6) su pisali da je klasifikacija lica osmišljena da označi specifične osobine ljudskog lica, na primjer spol osobe ili etnicitet, smatra li se osoba lijepom ili ne... lako su prepoznavanje lica i klasifikacija lica odvojeni zadaci, oboje ovise o uspješnoj detekciji lica i prepoznavanju značajka ljudskog lica.

Na slici 1 vidimo dijagram zadataka analize lica, gdje jedna grana predstavlja prepoznavanje, a druga klasifikaciju lica. Dijagram predstavlja jedan jednostavan pristup i proces prepoznavanja lica sa slike, provjeru te vraćanje procijenjenih podataka.



Slika 1: Dijagram zadataka analize lica (Scheuerman i sur., 2020, str. 6).

U posljednjem desetljeću došlo je do pojave sve većeg broja aplikacija i tehnologija koje iziskuju više od samog prepoznavanja lica. Kao što navode Han, Otto, Liu i Jain (2014, str.1) neke od tih tehnologija su:

1. kontrola pristupa (primjer kontrole pristupa jest automatska procjena dobi koja može zabraniti prodaju duhanskih proizvoda i alkohola maloljetnicima kod automata za prodaju)
2. interakcija između čovjeka i računala (primjer je pametni digitalni plakat koji mijenja svoj sadržaj ovisno o marketinškoj skupini kojoj osoba pripada)

3. policijski posao (automatska procjena koja može pomoći identificirati osumnjičenog efikasnije filtrirajući bazu s procijenjenim spolom, dobi i rasom).

Automatska procjena dobi, spola i rase i dalje ostaje teško rješivi problem zbog ljudske jedinstvenosti te ona uvelike ovisi o unutarnjim i vanjskim faktorima na koje se ponekad ne može utjecati. Osobno smatram da je to vrlo zanimljiva tema, zbog posebnosti i same ljudske procjene spola, dobi i rase. Takav nesvjestan proces procjene je potrebno naučiti algoritam na primjerima koji su jedinstveni.

U ovom radu će biti istraženi i uspoređeni algoritmi za procjenu dobi, spola i rase te sam aspekt ljudske procjene. Smatram da će to biti zanimljiva usporedba jer me zanima hoće li učenik nadmašiti učitelja.

2. Percepcija lica i problemi s određivanjem dobi, spola i rase

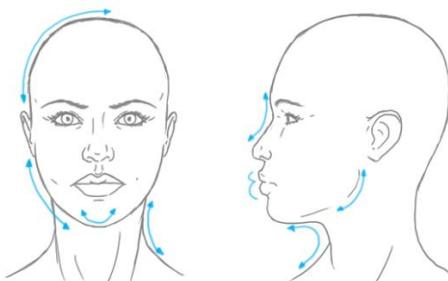
U ovom poglavlju će biti opisane karakteristike ljudskog lica pomoću kojih određujemo dob, spol ili rasu. Jednim pogledom na lice osobe možemo saznati koliko ima godina po borama na licu. Po obliku glave, obrvama i čeljusti možemo reći je li osoba muškog ili ženskog spola, a boja kože, oči i nos nam govore koje je osoba rase. Problem s određivanjem dobi, spola i rase jest da je svaka osoba jedinstvena. Svatko ima više ili manje naglašena obilježja koja karakteriziraju rasu, a biološka dob osobe često se razlikuje od kronološke.

2.1. Percepcija lica

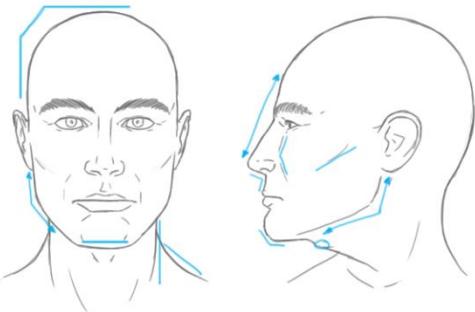
Od malena, djeca promatrajući ljude oko sebe, nesvesno klasificiraju lica. Kasnije mogu svjesno odrediti je li osoba muškog ili ženskog spola, koliko približno ima godina i koje je rase. S obzirom da je svaka osoba jedinstvena, ponekad je teško točno odrediti gore navedene biometrijske čimbenike. Ne stari svaka osoba jednakom, nema svaka osoba jedinstveni oblik lica i ne postoje samo tri boje kože. S tim na umu, za početak ćemo pokušati napraviti približnu razliku između muškog i ženskog lica.

2.1.1. Razlike lica po spolu

Ramirez (2017) navodi da su muška lica četvrtastog oblika i imaju blago četvrtaste vilice. Kao što vidimo na slici 2, ženska lica su češće u oblicu srca, zaobljenih uglova. Profili lica se također razlikuju. Profili žena su ravni, dok se kod muškaraca čela naginju natrag, a donji dio lica strši prema naprijed što vidimo na slici 3. Ženske obrve su više zakrivljene, a kod muškaraca su obrve guste i ravne bez luka. Nos kod žena je manji i kraći s užim nosnicama i mostom. Muškarci imaju veću udaljenost između baze nosa i vrha usne. Žene češće imaju veće oči, a oblik ruba iznad čela utječe na oblik jagodica.



Slika 2: Primjer ženskog portreta (Peters, 2013).



Slika 3: Primjer muškog portreta (Peters, 2013).

Kod klasifikacije spola razlikujemo dvije klase – muško ili žensko. Većina pristupa klasifikacije spolova, kako navode Dwivedi i Singh (2019, str. 1090), sudjeluju u tri faze: ekstrakcija značajki lica, učenje klasifikatora i prepoznavanje uz pomoć učenog klasifikatora. Značajke za prepoznavanje spola su izlučene metodama koje se temelje na izgledu ili geometrijskim metodama. Metode koje se temelje na izgledu promatraju cijelu sliku lica umjesto lokalnih značajaka koje odgovaraju različitim dijelovima lica. Kod geometrijskih metoda, u prvom planu su geometrijske značajke kao što su duljina lica, širina i udaljenost između očiju i tako dalje.

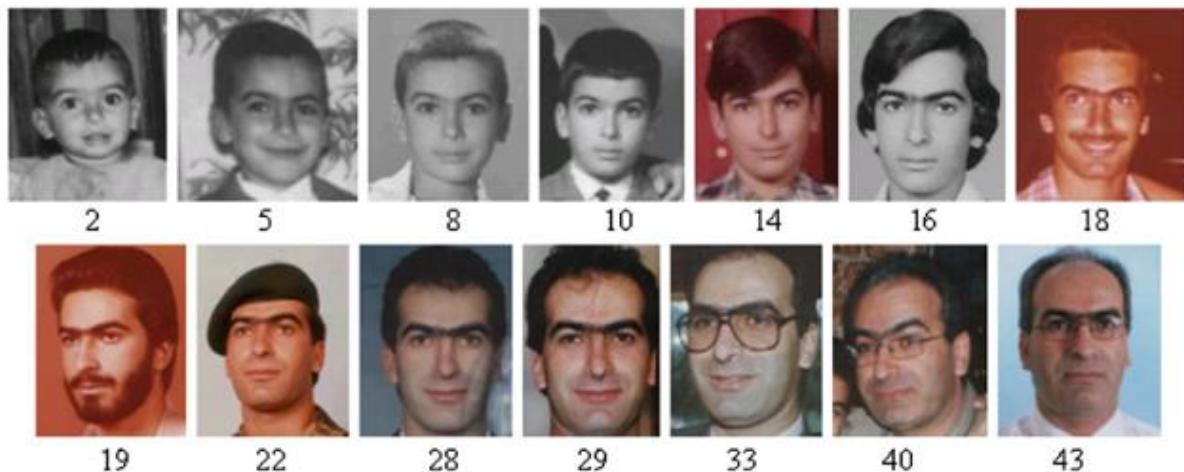
2.1.2. Razlike lica po dobi

Promatrajući od malena ljude oko sebe i njihov razvoj kroz vrijeme, ljudi su u mogućnosti procijeniti nečiju starost. Većina ljudi ni ne razmišlja kako će odrediti dob osobe, već procjenjuje po nekoj svojoj intuiciji, a nisu ni svjesni koji su to sve čimbenici koje nesvesno primjećuju. Potrebno je napomenuti karakteristike starenja.

Kako navode Geng, Zhou i Smith-Miles (2007, str. 2234) starenje ima tri jedinstvene karakteristike.

1. Napredak starenja nije moguće kontrolirati. Nitko ne može voljno ubrzati ili usporiti starenje. Postupak starenja je spor i nepovratan.
2. Obrasci starenja su osobni. Obrazac starenja svake osobe određuje se prema njihovim genima i mnogim vanjskim čimbenicima kao što su zdravlje, stil života, kvaliteta zraka...
3. Uzorci starenja su vremenski podaci. Napredak starenja mora poštovati redoslijed vremena. Status lica u nekoj određenoj dobi će utjecati na sva starija lica, ali neće utjecati na ona mlađa.

Kako bismo mogli shvatiti na koji način ljudsko lice stari Fu, Guo i Huang (2010, str. 1958) opisali su rast i razvoj lica od rođenja do starosti. Tijekom ranog rasta i razvoja lica, od rođenja do odrasle dobi, najveća je promjena kraniofacijalni rast. Čelo se naginje natrag, smanjuje se i oslobađa razmak na površini lubanje, obraz se šire i brada raste. Koža lica se previše ne mijenja ali mogu se pojaviti dlake na licu, poput brkova. Boja kože se može malo promijeniti, a pore se mogu povećati i otvoriti. Tijekom starenja odraslih, odnosno od odrasle dobi do starosti, najuočljivija promjena postaje starenje kože i promjena njene strukture. Koža postaje tamnija, tanja i manje elastična. Bore i nabori, koji se stvaraju tijekom gibanja mišića, postaju sve veći i veći kako vrijeme prolazi. Na slici 4 možemo vidjeti starenje muške osobe.



Slika 4: Posljedica starenja muške osobe u FG-NET bazi (*Face Aging Modeling*, bez dat.).

Kao i u slučaju klasifikacije lica po spolu, kako pišu Dantcheva, Elia i Ross (2016, str. 449), zadatak automatizirane procjene dobi može se odvojiti u dva modularna podzadatka: ekstrakciju značajki sa slike lica te modularni dio automatizirane klasifikacije gdje izvučene značajke vode do klasifikacije (koja odgovara binarnom formatu – je li osoba mlada ili stara) ili se izvučene značajke koriste za daljnju obradu kako bi algoritam mogao dati poboljšanu procjenu (točna procjena ljudske dobi).

2.1.3. Razlike lica po rasi

Ljudsku rasu određujemo pretežito prema boji kože. Naravno, to nije dovoljno da bi se osobu smjestilo u jednu od tri rasne skupine. Svaka od rasa ima svoje karakteristike koje su Roomi, Virasundarii, Selvamegala, Jeevanandham i Hariharasudhan (2011, str. 54) opisali.

Kavkazoidnu odnosno bijelu rasu, karakterizira čisto bijela do bogato smeđa koža, tanak i visok nos, srednje usne, srednji do visoki stas, dugi ili široki oblik glave (slika 5, desno). Kosa je svijetloplava do tamno smeđe boje, fine teksture te je ravna ili valovita.

Žutu (mongoloidnu) rasu karakterizira žućkasta sjajna koža, mala uska lubanja s prilično ravnim stranama. Imaju nisko čelo, a oči su im uske, bademovog oblika (slika 5, lijevo). Imaju duge crne kose.

Najupečatljivije karakteristike crne odnosno negroidne rase jesu crna koža, crna kovrčava kosa, nisko čelo, visoke jagodične kosti, ravan i širok nos te široka i mala brada (slika 5, sredina). Imaju jake i bijele zube.

Iznad navedene karakteristike, triju rasa, uzete su kao znak za prepoznavanje rasa putem lica.



Slika 5: Primjeri lica različitih rasa (*Muhammad*, bez dat.).

Boja ljudske kože varira između različitih rasa. Primarna varijacija je u intenzitetu koji je proporcionalan s količinom melanina u koži. Kako bi algoritam prepoznao kožu, dominantna boja lica koristi se kao značajka za predstavljanje kože. Dakle, učinkovito otkrivanje boje kože predstavlja prvi korak u klasifikaciji rase. Kako bi se klasifikacija mogla vršiti pomoću boje, potreban je pouzdan model boje kože za svaku specifičnu rasu. (Roomi i sur., 2011, str. 55).

Često zbog različitih faktora kao što su osvjetljenje, ima li osoba na fotografiji naočale ili brkove može dovesti do pogrešne klasifikacije. Zato je uz boju kože, potrebno gledati i neke druge značajke rase kao što su područje čela i boja usana.

Općenito je poznato da ljudi provode klasifikaciju rasa primjenom pristupa temeljenog na značajkama lica, a mnoga obećavajuća računalna rješenja primjenjuju pristupe temeljene na holističkim i lokalnim značajkama lica. (Dantacheva i sur., 2016, str. 451).

2.2. Problemi s procjenom spola, dobi i rase

U ovom djelu ćemo objasniti sve faktore koji utječu na učenje algoritama i njihovu procjenu. Biti će objašnjeno što su to kovarijati, zašto je bitno etičko učenje algoritama i kakav utjecaj ima uljepšavanje lica na učenje algoritma.

„Kovarijat je varijabla koja ima učinak na povećanje varijacije unutar klase... Primjeri kovarijata slika koji utječu na performanse prepoznavanja lica su poza, osvjetljenje, izraz lica te razlučivost slike.“ (Abdurrahim, Samad i Huddin, 2017, str. 1618).

Poza u prepoznavanju lica i procjeni spola, dobi i rase odnosi se kada osoba ne gleda ravno u kameru ili nije okrenuta ravno licem u kameru. Različiti kutovi lica se nalaze na fotografiji što znači da neke crte lica nije moguće vidjeti. Shodno tome, točnost algoritma će se drastično smanjiti. Osvjetljenje na fotografiji može u potpunosti promijeniti izgled lica. Položaj svjetla i kako ono pada na lice i radi sjenu onemogućava algoritam da u potpunosti prepozna lice i točno napravi klasifikaciju. Izraz lica, to jest, iskazuje li osoba na slici sreću, tugu, zbuđenost, bijes, uvelike otežavaju algoritmu procjenu dobi, spola i rase. Iskazivanje emocija na fotografiji rezultira varijacijama izgleda i geometrije lica. Fotografije lica mogu biti različitih rezolucija. Fotografije lica niže rezolucije, što podrazumijeva lošiju ili nestabilnu kameru, manjak fokusa pri fotografiranju, zamućene fotografije ili nizak kontrast, smanjuju performanse algoritma. (Abdurrahim i sur., 2017, str. 1618-1619).

Kako je već prije bilo napomenuto, ljudski proces starenja za svaku osobu je jedinstven. Algoritam najbolje uči na starećim bazama slika. Jedina javno dostupna takva baza je FG-NET. Kako bi algoritam što točnije mogao procijeniti nečiju dob, potrebno mu je mnogo primjera starenja pokazati, na različitim spolovima, ali i rasama.

Iako je dokazano da muškarci i žene imaju drugačiju strukturu lubanje, djevojčice i dječaci imaju vrlo sličnu, što čini klasifikaciju spola teškom kada se radi o slikama djece. (Ngan, Grother, 2015, str. 7). Iz toga možemo vidjeti zašto bi algoritam imao veću pogrešku kod procjene spola kod beba ili djece koja su tek prohodala.

Bitno je napomenuti i etičko učenje algoritama to jest FATE ML (eng. *Fairness, Accountability, Transparency and Ethics in Machine Learning*). Pristranost u razvoju umjetne inteligencije može rezultirati nepoštenim ishodima za ljudi različitih rasa ili roda.

Kako navode Scheuerman i sur. (2020, str. 5) rasa i spol su dvije najveće brige u literaturi o poštenju strojnog učenja zbog pristranosti. Posebno zbog toga što su sustavi pristrani prema određenim rasama i spolovima. Svi ili većina algoritama učena je da postoje samo dva spola, muški i ženski. Mnogi trans ljudi su kritizirali restriktivnu rodnu klasifikaciju zbog povećane vjerojatnosti da će oni biti dodatno izloženi rizičnim interakcijama s policijskim

i sigurnosnim službenicima. Mnogi znanstvenici i danas pokušavaju iskorijeniti pristranost iz algoritama, poput onih izazvanih političkim ugnjetavanjem protiv crnaca.

U 2019. godini Kineska vlada je pomoću ogromnog, tajnog sustava napredne tehnologije za prepoznavanje lica, pratila Ujgure, Muslimansku manjinu. To je bio prvi poznati primjer vlade da namjerno koristi umjetnu inteligenciju za rasnu klasifikaciju. Tehnologija je bila brzo integrirana u brzo rastuće mreže nadzornih kamera, tražeći isključivo Ujgure na temelju njihovog izgleda. Ovakvo neetično učenje i korištenje tehnologija može dovesti do nove ere automatiziranog rasizma kako navode u članku The New York Times-a. (Mozur, 2019.).

Dosad, mnogo je istraživanja napravljeno kako bi se otkrile pristranosti u sustavima za analizu. Nacionalni institut za standarde i tehnologiju (eng. *National Institute of Standards and Technology – NIST*) je u istraživanju 2019 u evaluaciji tehnologija za prepoznavanje lica uvidio da algoritam radi bolje na muškarcima i starijim ljudima, a gore na ženama i mlađim ljudima. (Grother, Ngan. Hanaoka, 2019, str.7).

Potrebno je spomenuti utjecaj uljepšavanja lica na prepoznavanje i klasifikaciju. Tehnike i metode uljepšavanja možemo podijeliti na tri kategorije. Prema Rathgebu, Dantchevu i Buschu (2019, str. 1-2) to su: plastična operacija lica koja predstavlja medicinski inducirano promjenu. Ona ima za cilj ispravljanje karakteristika lica, s ciljem poboljšanja izgleda. Drugo je kozmetika za lice, odnosno šminka. Kozmetika je široko rasprostranjena, jednostavna je za primjeniti, jeftinija je u usporedbi s drugim zahvatima i često je u svakodnevnoj upotrebi za mnoge. Treća kategorija je retuširanje lica, što se često i naziva fotošopiranjem (eng. *photoshopping*). Retuširanje lica se odnosi na promjene na licu unutar digitalne domene. Retuširanjem se može postići izgled i plastične operacije i upotrebu kozmetike, ali i daljnje promjene kao što su premještanje ili mijenjanje karakteristika lica (pomicanje i povećanje očiju, povećanje usana i slično).

Ove tehnike uljepšavanja lica mogu utjecati na algoritam i u aspektu procjene ljudske dobi i rase, ali i spola. Primjerice ako dob procjenjuje prema borama na licu, a osoba ima ubrizgan botoks, algoritam će osobu klasificirati u mlađu dobnu skupinu od one kojoj pripada.

Da bismo razumjeli zašto je i dalje potrebno raditi na poboljšavanju algoritama, moramo uzeti u obzir sve gore navedene probleme i aspekte. Osobe koje treniraju algoritme moraju sve faktore uzeti u obzir kako bi algoritam bio što točniji i pravedniji. Algoritam mora biti naučen na različite kvalitete slika, osvjetljenje, ljudi koji nose naočale, šminku, ljudi s brkovima, žene s kratkom kosom, muškarce s dugom kosom i tako dalje, ako želimo što realniju upotrebu tog algoritma u razne svrhe.

3. Problem istraživanja i hipoteza

Sve više sustava, vjerojatno i više nego su ljudi svjesni, u današnjem svijetu koristi prepoznavanje ljudskog lica kao i njegovu klasifikaciju. Naravno, s većim korištenjem tehnologije, više istraživanja se provodi i takvi sustavi napreduju rapidnom brzinom. Ljudi su općenito poprilično dobri u prepoznavanju spolova. Evolucijski smo sposobni klasificirati dob rano u životu kao i odrediti koje je osoba rase. Zbog tog razmišljanja da su ljudi ipak ti koji uče algoritme kako prepoznati spol osobe sa slike, ili procijeniti njegovu dob, došla sam do pretpostavke da će ljudi bolje procijeniti i klasificirati osobe sa slika nego većina algoritama.

S obzirom da je vrlo malo istraživanja napravljeno u kojoj se uspoređuje ljudska procjena i performanse algoritma na nekoj biometriji, uvidjela sam da bi bilo korisno to ispitati. Hoće li algoritmi nadmašiti ljudsku sposobnost procjene i kolika je već sad razlika istražiti ćemo u ovom radu.

4. Metode i tehnike prikupljanja podataka

Ovdje će biti opisane sve metode korištene za prikupljanje i obradu podataka kao i korištene tehnike.

Istraživanje je rađeno na FG-NET bazi slika. FG-NET stareća baza (eng. *Aging Database*) naziva se tako jer sadrži 1002 slike ljudskog lica prikupljene od 82 osobe. Svaka osoba ima otprilike 12 slika lica od rane dobi (0 godina) pa do starosti (69 godina). Sve osobe su bijele rase.

Kako bismo prikupili podatke, napravljena je online anketa pomoću koje se prikupio dio ljudske procjene. Točnost procjene spola i rase izračunat je pomoću aritmetičke sredine. Kolika je točnost odnosno odstupanje ljudske procjene dobi računato je pomoću statističke metode srednje apsolutne pogreške (eng. *Mean Absolute Error - MAE*). MAE je mjera pogreške između dva opažanja iste pojave. Računa se prema formuli:

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n}$$

y_i je predviđena vrijednost, a x_i je stvarna vrijednost. („Mean absolute error“, bez dat.)

Kod klasifikacije lica po dobi, srednja apsolutna pogreška je prosječna vrijednost apsolutne pogreške između predviđene dobi i stvarne starosti kroz procjenu dobi svih testiranih slika lica. Što je niži MAE to je algoritam točniji.

4.1. Anketa

Anketa je napravljena pomoću desktop aplikacije Google Forms. Google Forms je besplatna aplikacija za provedbu istraživanja. Anketa se sastojala od 50 nasumičnih slika iz FG-NET baze koje možemo vidjeti na slici 6.



Slika 6: 50 nasumično odabralih slika lica iz baze FG-NET

Na posebnoj stranici ankete se nalazila svaka pojedinačna fotografija. Ispod fotografije nalaze se pitanja o spolu, dobi i rasi osobe na slici što vidimo na slici 7. Anketom se ispitivala točnost ljudskih odgovora kod procjene spola sa slike, koliko osoba sa slike ima godina i koje je osoba rase.

The form consists of three stacked sections. The top section is titled "Spol osobe na slici" and contains two radio buttons: "Žensko" and "Muško". The middle section is titled "Dob osobe na slici" and includes a placeholder "Upišite samo broj" and a text input field labeled "Vaš odgovor". The bottom section is titled "Rasa osobe na slici" and contains three radio buttons: "Bijela rasa (Europeid)", "Crna rasa (Negroid)", and "Žuta rasa (Mongoloid)".

Slika 7: Izgled ankete

Za spol osobe na slici bila su ponuđena sva odgovora – žensko i muško. Za dob osobe na slici bilo je potrebno upisati samo broj na predviđenu crtu, a za rasu osobe na slici bila su ponuđena tri odgovora: bijela rasa (Europeid), crna rasa (Negroid) te žuta rasa (Mongoloid). Ispitanici su mogli odabrati samo jedan od ponuđenih odgovora.

Online anketom je prikupljeno 196 odgovora, od toga jedan nije bio valjan. Pomoću Google Forms aplikacije odgovori su izvezeni u Excel datoteku gdje su napravljeni proračuni.

4.2. Algoritmi za klasifikaciju lica po dobi, spolu i rasi

U ovom poglavlju opisani su pojedinačni algoritmi za procjenu dobi, spola i rase. Na kraju opisana je i metoda koja sadrži klasifikaciju svih promatranih značajka zajedno.

4.2.1. Algoritam za klasifikaciju dobi

Zhu, Chen, Hu i Li (2018, str. 1) navode različita istraživanja procjene dobi s različitim algoritmima. Zhu i sur. govore kako su Geng i sur. predložili *Aging Patterns Subspace* (AGES). AGES je linearna metoda, a osnovna ideja je modelirati uzorak starenja, koji je definiran kao slijed slika lica određenog pojedinca sortiranih u vremenskom slijedu, konstrukcijom reprezentativnog podprostora. Pravilan obrazac starenja za prethodno neviđena lica određuje se projekcijom koja može rekonstruirati sliku lica s minimalnom pogreškom rekonstrukcije, dok će položaj slike lica u tom uzorku starenja naznačiti njegovu dob. (Geng i sur, 2007). Prednost AGES metode je ta da se konstrukcijom reprezentativnog podprostora modelira obrazac starenja ljudskog lica, a mana je dugo vrijeme modeliranja. Zatim su Fu i sur. predložili klasifikaciju dobi pomoću stroja za podršku vektora (eng. *Support Vector Machine – SVM*). Algoritam im je jednostavan i robustan, ali troši puno memorije računala i dugo je vrijeme računanja.

Postoji još mnogo metoda i algoritama, no u svojem radu Zhu i sur. odabrali su algoritam temeljen na razvrstavanju s više oznaka (eng. *Multi-label Sorting*). Učenje razvrstavanja s više oznaka može prirodno izraziti složene semantičke informacije o objektima i bilo je uspješno na mnogim područjima. Ključ učenja razvrstavanja s više oznaka je naučiti moguće veze između izlaznih oznaka učenih uzoraka te koristeći te veze za optimizaciju matematičkih modela i poboljšanje točnosti modela. Poteškoća s kojom se susreće istraživanje Zhu i sur. je nedostatak uzoraka za obuku o procjeni dobi slika lica. Kako bi procjena dobi bila što točnija, učenje sortiranja se temelji na povezanosti dobne oznake i slike lica. Tako algoritam za klasifikaciju dobi može dobro uspostaviti odnos mapiranja između slike lica i dobi na temelju razvrstavanja s više oznaka. Algoritam je testiran na dvije baze slika FG-NET i Refined-MORPH.

Značajka modela aktivnog izgleda (eng. *Active Appearance Model Feature - AAM*) izdvaja se iz značajki lica. Ona uključuje informacije o obliku lica i teksturi, čime u potpunosti prikazuje promjene lubanje lica i opuštene kože tijekom ljudskog rasta i razvoja. Prema karakteristikama samog skupa podataka dobnih skupina, koristi se obrada izostavi jednu osobu (eng. *Leave-one-person-out – LOPO*) za podjelu skupova setova za učenje i testnih setova kod FG-NET baze. Sve slike skupa su odabrane kao testni set, a ostale se koriste za učenje algoritma.

Zhu i sur. zaključuju da je još uvijek nepoznato je li se poboljšala točnost procjene dobi lica iako se učenje s više oznaka široko koristi na područjima analize, bioinformatike i predstavlja dobru sposobnost generalizacije u rješavanju složenih stvari. Zbog nedostatka skupa podataka o dobi, njihov rad prvo transformira pojedinačnu dobnu oznaku uzorka slike lica u vektor s više oznaka prema stupnju korelacije, a zatim integrira matricu dobnih karakteristika slijedeći dojni niz, što mijenja tradicionalnu metodu višestruke binarne klasifikacije.

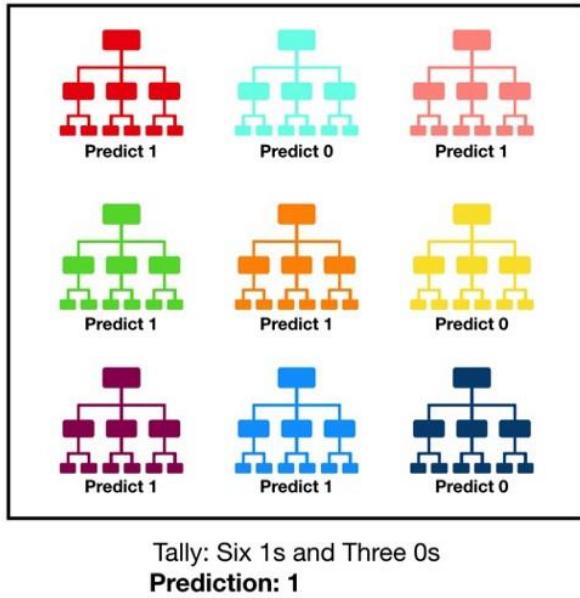
4.2.2. Algoritam za klasifikaciju spola

Većina algoritama procjene spola učena je i testirana je na FERET bazi. Algoritmi učeni na toj bazi slika postižu visok postotak točnosti klasifikacije čak od 99,1% no FERET baza ne sadrži fotografije djece. Wang, Ricanek, Chen i Chang (2010, str. 2) u svom radu koriste FG-NET bazu slika lica. Iako se ta baza široko koristi za procjenu dobi, Wang i sur. uzeli su bazu upravo zbog činjenice da sadrži lica osoba mlađih od 20 godina, što je čini izazovan skup podataka za spolnu klasifikaciju. Koriste se i evaluiraju izvedbe tri modela korištenih za klasifikaciju spola. Prvi pristup koristi PCA za smanjenje dimenzija i bira značajke redoslijedom.

Analiza glavnih komponenti (eng. *Principal Component Analysis - PCA*) je metoda smanjenja dimenzija koja se često koristi za smanjenje dimenzionalnosti velikih skupova podataka, pretvarajući veliki skup varijabli u manji, koji još uvijek sadrži većinu informacija u velikom skupu. (Jaadi, 2019).

Drugi pristup koristi također PCA za smanjenje dimenzije i Slučajnu šumu (eng. *Random Forest*) za selekciju varijabli s Gini važnošću (eng. *Gini Importance*). Random Forest sadrži veliki broj pojedinačnih stabala odluke koji zajedno odlučuju. Svako pojedinačno stablo u nasumičnoj šumi izbací predviđanje klase, a klasa s najviše glasova postaje predviđanje modela, kao što možemo vidjeti na slici 8. (Yiu, 2019). Svako stablo odluke predvidi klasu 1 ili 0, a u slučaju klasifikacije spola su to muško ili žensko. Sve procjene se izbroje, na slici je bilo šest jedinica i tri nule, stoga je predviđena klasa 1.

Gini Importance ili Mean Decrease in Impurity (MDI) je ukupno smanjenje nečistoće čvora (ponderirano vjerojatnošću da će doći do tog čvora(koji se izračunava udjelom uzorka koji doseže taj čvor)) u prosjeku za sva stabla. (Lee, 2017).



Slika 8: Vizualizacija Random Forest modela (Yiu, 2019).

Treći pristup koristi projekcije koje čuvaju lokalitet (eng. *Locality Preserving Projections* - *LPP*) kao drugu metodu smanjenja dimenzije, nakon PCA. Zatim odabire značajke sekvensionalno. He i Niyogi (2004, str. 153) navode da bi LPP trebalo promatrati kao alternativu PCA, no u ovom radu je Wang i sur. koriste za dvostruko smanjenje dimenzije skupa podataka.

Za procjenu koriste unakrsnu provjeru LOPO i petostruku unakrsnu validaciju (eng. *5-fold cross validation*) kako bi evaluirali stope prepoznavanja za sve predložene pristupe gore navedene.

Postupak unakrsne validacije ima parametar k koji se odnosi na broj skupina u koje se mora podijeliti određeni uzorak podataka. Kao takav, postupak se često naziva k-fold cross validation. Kada je odabrana određena vrijednost za k , ona se može koristiti umjesto k , kao što je na slučaju ovog rada $k=5$, stoga je 5-fold cross validation. Ovaj pristup uključuje nasumičnu podjelu skupa opažanja u k skupina, približno jednake veličine. Prvi skup se tretira kao skup validacije, a metoda se uči na preostalih $k-1$ skupova. (James, Witten, Hastie, Tibshirani, 2015, str. 181).

Brownlee (2018.) govori da se validacija prvenstveno koristi u primijenjenom strojnog učenju za procjenu vještina modela strojnog učenja na neviđenim podacima. Odnosno, korištenje ograničenog uzorka kako bi se procijenilo očekivanje performansi modela kada će se on koristiti za predviđanje podataka koji nisu korišteni tijekom obuke modela. Metoda je

popularna zato što je lako razumljiva i zato što općenito rezultira s manje pristranom procjenom od ostalih modela.

4.2.3. Algoritam za klasifikaciju rase

Boja kože i određene crte lica razlikuju rase. Prvi korak u klasifikaciji rase čini prepoznavanje lica. Varijacije u veličini fotografije, izrazu lica i osvjetljenju čine prepoznavanje lica težim. Metodologija koju su koristili Roomi i sur. (2011, str. 54) opisuje linearu metodu klasifikacije rasa. U području strojnog učenja, cilj statističke klasifikacije je identificirati kojoj klasi ili grupi pripada određeni objekt pomoću njegovih karakteristika. Linearna metoda to postiže donošenjem odluke o klasifikaciji na temelju vrijednosti linearne kombinacije karakteristika. Karakteristike objekta su također poznate kao vrijednosti svojstava i obično se u stroju prikazuju u vektoru koji se naziva vektor karakteristika. („Linear classifier“, bez dat.).

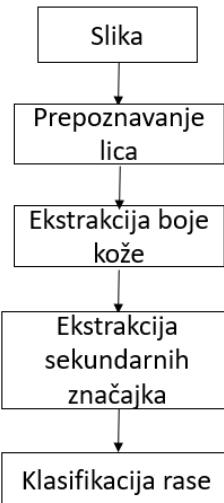
Područje lica izdvaja se iz slike pomoću metode koja se zove Viola-Jones. Paul Viola i Michael Jones u radu *Rapid Object Detection using a Boosted Cascade of Simple Features* napisanom 2001. godine opisuju pristup strojnom učenju za vizualno otkrivanje objekata koji je u mogućnosti obraditi slike izuzetno brzo i postiže visoke stope otkrivanja. Njihov rad sadrži tri ključna doprinosa. Prvi predstavlja uvođenje novog prikaza slike pod nazivom „integralna slika“ (eng. *Integral image*) koja omogućuje da se značajke koje koristi detektor vrlo brzo izračunaju. Drugi je algoritam koji uči, temeljen na AdaBoostu. Algoritam koji provodi klasifikaciju, posebno u konkretnoj implementaciji naziva se klasifikator (eng. *classifier*). AdaBoost je prilagodljiv u smislu da su naknadni slabi klasifikatori prilagođeni onim slučajevima koji su pogrešno klasificirani od strane prethodnih klasifikatora. AdaBoost je osjetljiv na outliere. Algoritam odabire mali broj kritičnih vizualnih značajki iz većeg skupa i doprinosi izuzetno učinkovitim klasifikatorima. Treći doprinos je metoda za kombiniranje sve složenijih klasifikatora u „kaskadu“ (eng. *Cascade*) koja omogućava da se pozadina slike brzo odbaci kako bi ostalo više vremena na računanje obećavajućih objektnih regija. (Viola, Jones, 2001, str.1).

Prepoznato lice na slici se obrađuje, kako bi se dobila boja kože pomoću Gaussove raspodjele. Gaussova odnosno normalna raspodjela, vrsta je kontinuirane raspodjele vjerojatnosti za stvarnu vrijednost slučajne varijable. Normalne raspodjele predstavljaju stvarne vrijednosti slučajnih varijabli čija distribucija nije poznata. („Normal distribution“, bez dat.)

Podaci na kojima je algoritam učio, uključuje slike s različitim osvjetljenjem kako bi algoritam mogao klasificirati boju kože bez obzira na osvjetljenje.

Sam parametar boje kože nije dovoljan kako bi se pravilno klasificirala slika, stoga Roomi i sur. (2011, str. 55) koriste ekstrakciju značajka pomoću crta lica. Na temelju tih značajka klasifikacija rasa je automatizirana.

Na slici 9 možemo vidjeti shematski prikaz koji nam ukratko prikazuje postupak klasifikacije rase iz slike. Za prvi korak je potrebna fotografija na kojoj se nalazi lice. Kada se lice prepozna, odbaci se pozadina i napravi se ekstrakcija samo lica iz slike (Slika 9.). Tada se iz te slike lica radi ekstrakcija boje kože. Boja ljudske kože je distribuirana u RGB (eng. *Red Green Blue*) modelu boja. Modeli boje kože su razvijeni za tri rase. Slike na kojima je algoritam trenirao sadrže velike varijacije u bojama kože svake pojedine rase. Roomi i sur. (2011, str. 55) koriste YCbCr model boja za modeliranje boje kože. YCbCr je model boja, gdje je Y svjetlina (eng. *Luma*), a Cb i Cr su plava i crvena komponenta povezane s komponentom krome (eng. *Chroma*). Kroma je signal, korišten u digitalnim slikama i video zapisima, za prijenos informacija o boji na slici, odvojen od pratećeg signala Luma. („YCbCr“, bez dat.). Slika lica se pretvara iz RGB modela boja u YCbCr model boja i svaki je piksel slike klasificiran kao kožni piksel ili ne-kožni piksel. Zatim slijedi ekstrakcija sekundarnih značajka što su u ovom slučaju područje čela i boja usana. Tek tada algoritam može lice na slici klasificirati u jednu od rasa – bijelu, crnu ili žutu.



Slika 9: Shematski prikaz metodologije klasifikacije rase (Roomi i sur., 2011, str. 55).

4.2.4. Algoritam za zajedničku klasifikaciju dobi, spola i rase

Han i sur. (2014, str. 2) predstavili su generički okvir za automatsku demografsku procjenu jedne slike lica. Izdvajali su prethodno predložene biološki nadahnute osobine (eng. *biologically inspired features – BIF*) iz slike lica i odabrali demografski informativne značajke koristeći algoritam za poticanje (eng. *boosting algorithm*). Boosting algoritmi su generički algoritmi, a ne specifični modeli. Za poboljšanje je potrebno odrediti slabi model i zatim ga poboljšati. Dva takva velika algoritma su Adaptive Boosting (AdaBoost) i Gradient Boosting. (Zhang, 2019).

Zatim su predložili hijerarhijski procjenitelj koji se sastoji od klasifikacije između grupa i regresije unutar grupe kako bi predviđeli dob, spol i rasu. Razlika između klasifikacije i regresije je ta da se u strojnog učenju klasifikacija koristi kao predviđanje neke oznake, a regresija predviđa neku kvantitetu. Također u svom radu Han i sur. rade procjenu kvalitete metoda za otkrivanje nekvalitetnih slika lica koje nastaju od različitih osvjetljenja, poza i razlike u izrazu lica.

Algoritam je procijenjen velikim i raznovrsnim bazama fotografija, konkretnije na: FG-NET, FERET, MORPH II, PCSO i LFW bazama. FG-NET bazu smo već u radu opisali, ona sadrži osobne fotografije osoba od djetinjstva do starosti. MORPH II i PCSO su obje baze fotografija lica ljudi pri uhićenju (eng. *mugshot*). Baze sadrže veliki broj fotografija različitih dobnih skupina, spolova i rasa no ne sadrže slike mladih i djece. FERET je baza fotografija od ljudi koji su bili voljni podijeliti svoje slike. LFW predstavlja opću populaciju lica u neograničenim uvjetima. U radu je napravljena ljudska procjena te je uspoređena s algoritmom.

5. Rezultati istraživanja

5.1. Rezultati ljudske procjene

Za rezultate ankete uzeto je 195 odgovora. Anketa je bila anonimna, a dob ispitanika se kretala između 18 i 66 godina.

Točnost ljudske procjene spola izračunata je aritmetičkom sredinom. Za svaku sliku izračunata je točnost, to jest koliki postotak ljudi je točno procijenio spol, a zatim su ti postoci bili zbrojeni i podijeljeni s brojem slika na kojem se istraživanje vršilo. 92,07% ljudi je bilo točno u svojoj procjeni spola sa slike. Važno je napomenuti da postotak točnosti raste s godinama osobe na slici. Veći je bio postotak pogreške kod dojenčadi i djece nego odraslih i starijih.

Kao što je prije bilo napomenuto, odstupanje od točne procjene dobi izračunato je MAE metodom. Za svaku pojedinačnu sliku svaki odgovor je bio oduzet od stvarne dobi, taj broj je pretvoren u apsolutnu vrijednost. Zatim suma svih tih apsolutnih vrijednosti je bila podijeljena s brojem odgovora koji je 195. Time smo dobili za svaku pojedinu sliku prosječnu grešku od stvarne dobi. Kada smo za sve slike izračunali MAE, on je bio sumiran i podijeljen s brojem slika koje se nalaze u anketi te smo dobili prosječnu grešku u procjeni dobi od 6,699 godina. Daljnjoj analizom i podjelom dobi osoba sa slikama u kategorije može se vidjeti pojava koja se naziva neuravnotežena procjena dobi (eng. *Imbalanced Age Estimation*) što vidimo u tablici 1. „Uobičajeno je da se mijenja izgled lica kod različitih stadija starenja. Obično se mlada lica mijenjaju brže od starijih. Shodno tome, procjena dobi je osjetljivija na pogreške u starijoj dobi.“ (Geng, Zhou, Smith-Miles, 2007, str. 2238).

Tablica 1: Prikaz neuravnotežene procjene dobi

| Raspont dobi | MAE |
|--------------|-------|
| 0-12 | 2,627 |
| 13-18 | 6,498 |
| 19-69 | 9,291 |

Procjena rase, računala se aritmetičkom sredinom. Za svaku pojedinu fotografiju izračunat je postotak točnosti procjene rase. Zatim su svi postoci zbrojeni i podijeljeni s brojem fotografija. Postotak točnosti ljudske procjene rase je 88,36 %. FG-NET baza sadrži samo slike osoba bijele rase, što znači da je 11,74% bila netočna procjena.

5.2. Rezultati algoritama za klasifikaciju lica po dobi, spolu i rasi

5.2.1. Rezultati algoritma za klasifikaciju dobi

Za prikaz podataka se koristi MAE. U tablici 2 vidimo prosječnu apsolutnu pogrešku za svaku od klasičnih metoda za procjenu dobi i zadnje u tablici vidimo MAE za Multi-label sorting. Obzirom da je u ovom radu bila korištena FG-NET baza, rezultati su prikazani samo za tu određenu bazu. (Zhu i sur., 2018, str. 7)

Tablica 2: MAE rezultati na FG-NET bazi

| Metode | FG-NET |
|-------------|--------|
| AGES | 6,77 |
| SVM | 7,25 |
| SVR | 5,91 |
| kNN | 8,24 |
| OHRank | 4,48 |
| IIS-LLD | 5,76 |
| CPNN | 4,76 |
| Multi-label | 4,35 |

5.2.2. Rezultati algoritma za klasifikaciju spola

Rezultati klasifikacije spola različitih algoritama koje su izradili Wang i sur.(2010, str. 4) možemo vidjeti u tablici 3 i 4. Najbolje rezultate je dala metoda PCA s redoslijedno uzetim značajkama u kombinaciji s 5-fold cross validation metodom. Postotak točnosti klasifikacije spola iz FG-NET baze je 84,33%.

Tablica 3: Procjena spola različitih algoritama LOPO metodom

| LOPO | PCA + redoslijedno | PCA + Random Forest | PCA + LPP |
|------------|--------------------|---------------------|-----------|
| Dob (0-69) | 73,35% | 73,45% | 72,26% |

Tablica 4: Procjena spola različitih algoritama 5-fold cross validation metodom

| 5-fold | PCA + redoslijedno | PCA + Random Forest | PCA + LPP |
|-----------|--------------------|---------------------|-----------|
| Dob(0-69) | 84,33% | 82,73% | 83,03% |

Wang i sur. zaključili su da je veća pogreška algoritma kod procjene spola mladih (0-18).

5.2.3. Rezultati algoritma za klasifikaciju rase

Roomi i sur. (2011, str. 56) učili su algoritam na Yale i FERET bazi slika. Gotovo 250 primjera bijele, crne i žute rase bili su korišteni u svrhe osposobljavanja algoritama za određivanje odgovarajućih pragova piksela kože za tri rase. Algoritam je testiran na 52 slike lica u boji, različitih veličina, prepoznate Viola Jones algoritmom. Boja kože osobe sa slike mjerena je YCbCr modelom boja. Od 52 slike, klasifikacija samo pomoću boje kože dala je točan rezultat za 35 slika, što je 67,31%. Koristeći sekundarne značajke, odnosno crte lica, algoritam je dao puno točnije rezultate. Za drugi dio istraživanja uzete su 82 fotografije bijele rase, 98 žute rase i 97 crne rase, tako da je set podataka bio uravnotežen. Testiranjem algoritma utvrđeno je da je njegova točnost 81,74 %, odnosno krivo klasificira 8,36% slika.

Han i sur. (2014, str. 4) naveli su u svojem radu sažetak klasifikacije rase u drugim radovima. Chen i Ross (2013.) postigli su točnost procjene rase, na bazama MORPH i CASPEAL, od 98,7%. Gou i Mu (2013.) također su postigli točnost klasifikacije od 98,9%, no njihova baza je bila MORPH II koja sadrži samo slike lica crne i bijele rase.

5.2.4. Rezultati algoritma za zajedničku klasifikaciju dobi, spola i rase

Rezultati koje postižu Han i sur. (2014, str. 8) korištenjem procjene kvalitete (eng. *quality assessment - QA*) postigli odlične rezultate, ali to znači da je 5% svih slika lica bilo odbačeno. U tablici 5 možemo vidjeti MAE algoritma promatranog u radu s QA i bez, kao i rezultate ljudske procjene s i bez QA.

Tablica 5: MAE promatranog algoritma i ljudske procjene dobi

| Baza | Promatrani algoritam | | Ljudska procjena | |
|-----------------|----------------------|-------|------------------|-------|
| | Bez QA | Sa QA | Bez QA | Sa QA |
| FG-NET | 4,8 | 3,8 | 4,7 | 4,5 |
| MORPH II | 3,8 | 3,6 | 6,3 | 4,3 |
| PCSO | 4,3 | 4,1 | 7,2 | 6,6 |

Na bazi LFW algoritam postiže prosječnu absolutnu pogrešku od 7,8 godina.

Za usporedbu BIF metode koja je smatrana jednom od najuspješnijih za klasifikaciju dobi, El Dib i El-Saban (2010) predložili su EBIF (eng. *extended BIF*) koji uključuje fine detalje crta lica, uključuje automatsku inicijalizaciju pomoću modela aktivnog oblika (eng. *active shape*

model) i analizu potpunog područja lica uključivanjem detalja čela. Postigli su MAE od 3,17 godina.

Klasifikacija spola je napravljena na bazama MORPH II i PCSO. Na bazi MORPH II algoritam je ostvario točnost od 97,6%, a ljudska procjena na istoj bazi je 96,9%. Na bazi PCSO točnost je 97,1% a točnost ljudske procjene je 96,5%. Procjena spola je ispitana i na bazama FERET i LFW, no one ne daju toliko visoku točnost. Za bazu FERET je to 96,8%, a za LFW 94%.

Klasifikacija rase je također rađena na MORPH II i PCSO bazama, no rađena je procjena samo između bijele i crne rase. Na MORPH II bazi slika algoritam postiže točnost od 99,1% dok ljudska procjena doseže točnost od 97,8%. Na PCSO bazi točnost algoritma je 98,7%, a ljudska procjena je 96,5% točna. Za bazu LFW je algoritam postigao točnost od 90%.

6. Zaključak

Ljudska procjena spola na bazi FG-NET je 92,07%, dok je najbolja procjena algoritma na također na bazi FG-NET 84,33%. Wang i sur. u svom radu, ali i mi u ovom istraživanju ljudske procjene uvidjeli smo da je niži postotak točnosti procjene spola na djeci i mlađima. Zato možemo i zaključiti zašto algoritmi učeni i testirani na FG-NET bazi imaju niži postotak točne klasifikacije spola.

U radu Han i sur. na bazama MORPH i PCSO postižu također viši postotak točnosti procjene algoritma od 97,6% i 97,1%. Oni su testirali i ljudsku procjenu koja je bila 96,9% i 96,5%, otprilike 4% viša nego procjena spola koju smo proveli mi u ovom radu, ali ponovno napominjem u MORPH i PCSO bazama nema slika djece.

Time bih zaključila da je ipak ljudska procjena što se tiče klasifikacije slike lica po spolu ipak bolja od algoritama za 7,74% zbog težine zadatka.

Ljudska procjena dobi na FG-NET bazi je poprilično loša u ovom ispitivanju. MAE je 6,7 godina. Algoritmi općenito, bez obzira na metodu korištenu postižu puno manju srednju apsolutnu pogrešku. Najbolji MAE je 3,17 godina, što je za 3,53 godina bolje nego ljudska procjena. U tablici 5. vidimo ljudsku procjenu napravljenu u radu Han i sur. gdje je MAE 4,7.

Iznenađena sam rezultatima ljudske procjene. Očekivala sam puno bolje rezultate, obzirom da outliera nije ni bilo. Iz gore navedenih podataka možemo zaključiti da je automatizirana procjena dobi puno bolja od ljudske procjene.

Postotak ljudske procjene rase je 88,36%, što me odmah u početku začudilo jer FG-NET baza sadrži samo fotografije bijele rase. Upravo zbog te činjenice ni jedan algoritam za klasifikaciju rase nije učen ni testiran na FG-NET bazi slika. Što se tiče algoritama, a postoje i ispitani su mnogi, najveći postotak točnosti postižu Han i sur. na MORPH bazi od 99,1%, no u njihovom istraživanju rađena je procjena samo na bijeloj i crnoj rasi. Roomi i sur. postigli su postotak od 81,74% točnosti algoritma za sve tri rase.

U ovom, malo rjeđe istraženom slučaju, smatram da za automatiziranu klasifikaciju rase i ljudsku procjenu ipak veliku ulogu igraju slike koje se nalaze u bazi, to jest na kojoj se bazi slika vrši istraživanje. A što se tiče ljudske procjene, smatram da i geografsko područje u kojem se provodi istraživanje i njegov demografski sastav utječu na rezultate. Primjerice, ovo ispitivanje je održano u Republici Hrvatskoj gdje živi, većinskim djelom, bijela rasa, koja nema puno doticaja s drugim rasama i moguće je da ljudi ne prepoznaju značajke drugih rasa. Još jedna bitna stavka je ta, da su ispitanicima u anketi bili ponuđeni odgovori, to jest bile su napisane sve tri rase, bez obzira što FG-NET baza sadrži samo slike lica bijelaca. Mislim da

zbog više ponuđenih rasa u odgovorima, ispitanici su pretpostavili da na nekim slikama moraju biti druge rase osim bijele.

Usporedivši samo rezultate ljudske procjene ispitane u ovom radu i radu od Han i sur., možemo vidjeti da su njihovi ispitanici ostvarili puno bolje rezultate i klasificirali s puno većom točnošću. Jedini zaključak koji mogu izvući iz toga da kontroliranijim uzorkom postižu se bolji rezultati.

Pretpostavka je bila da će ljudska procjena biti točnija od procjene algoritama. Ovim usporedbama vidimo da to u većini slučajeva nije istinito. Zanimljivo je vidjeti kako u starijim radovima znanstvenici pokušavaju učenjem algoritama dostići mogućnosti i kapacitete ljudske procjene, a uskoro će algoritamska klasifikacija u potpunosti nadmašiti i vrlo vjerojatno zamijeniti ljude.

Popis literature

- Abdurrahim, S. H., Samad, S. A. & Huddin, A. B. (2017). The Visual Computer. *Review on the effects of age, gender, and race demographics on automatic face recognition*, 34(11), 1617-1630. doi:10.1007/s00371-017-1428-z
- Brownlee, J. (2018). Machine Learning Mastery. *A Gentle Introduction to k-fold Cross-Validation*. Preuzeto 29.08.2020. s <https://machinelearningmastery.com/k-fold-cross-validation/>
- Dantcheva, A., Elia, P. & Ross, A. (2016). IEEE Transactions on Information Forensics and Security. *What Else Does Your Biometric Data Reveal? A Survey on Soft Biometrics*, 11, 441-467. doi: 10.1109/TIFS.2015.2480381
- Dwivedi, N., Singh D. K., (2019). *Review of Deep Learning Techniques for Gender Classification in Images: Theory and Applications*, 1089-1099. doi:10.1007/978-981-13-0761-4_102
- El Dib, M. Y., El-Saban, M. (2010). IEEE International Conference on Image Processing Human Age. *Estimation Using Enhances Bio-inspired Features (EBIF)*, 1589-1592. doi: doi: 10.1109/ICIP.2010.5651440
- Face Aging Modeling (Face Image Modeling and Representation) (Face Recognition) Part 2* (bez dat.). Preuzeto 10.08.2020. s <http://what-when-how.com/face-recognition/face-aging-modeling-face-image-modeling-and-representation-face-recognition-part-2/>
- Fu, Y., Guo, G., Huang, T. S. (2010). IEEE Transactions on Pattern Analysis and Machine Intelligence. *Age Synthesis and Estimation via Faces: A Survey*, 32, 1955-1976.
- Geng, X., Zhou, Z., Smith-Miles, K. (2007). IEEE Transactions on Pattern Analysis and Machine Intelligence. *Automatic Age Estimation Based on Facial Aging Patterns*, 29, 2234-2240.
- Grother, P., Ngan, M., Hanaoka, K. (2019) *Face Recognition Vendor Test (FRVT) Part 3: Demographic Effects*. doi: 10.6028/NIST.IR.8280
- Han, H., Otto, C., Liu, X. & Jain A. K. (2014). IEEE Transactions on Pattern Analysis and Machine Intelligence. *Demographic Estimation from Face Images: Human vs. Machine Performance*, 37(6), 1148-1161. doi:10.1109/TPAMI.2014.2362759
- He, X., Niyogi, P., Thrun, S., Saul, L. K. & Schölkopf, B. (2004). Advances in Neural Information Processing Systems 16. *Locality Preserving Projections*, 153-160.

Jaadi, Z. (2019). *A Step by Step Explanation of Principal Component Analysis*. Preuzeto 29.08.2020. s <https://builtin.com/data-science/step-step-explanation-principal-component-analysis>

James, G., Witten, D., Hastie T., Tibshirani R. (2015). *An Introduction to Statistical Learning with Applications in R*, 1-436.

Lee, C. (2019). *Feature Importance Measures for Tree Models — Part I*. Preuzeto 30.08.2020. s <https://medium.com/the-artificial-impostor/feature-importance-measures-for-tree-models-part-i-47f187c1a2c3>

Linear classifier (bez dat.). U Wikipedia. Preuzeto 28.08.2020. s https://en.wikipedia.org/w/index.php?title=Linear_classifier&oldid=958172202

Mean absolute error. (bez dat.). U Wikipedia. Preuzeto 12.08.2020. s https://en.wikipedia.org/wiki/Mean_absolute_error

Mozur, P. (2019, Travanj 14). One Month, 500,000 Face Scans: How China Is Using A.I. to Profile a Minority. *The New York Times*. Preuzeto 17.08.2020. s <https://www.nytimes.com/2019/04/14/technology/china-surveillance-artificial-intelligence-racial-profiling.html>

Muhammad, G. (2012). *Example Faces of Different Races*. Preuzeto 10.08.2020. s https://www.researchgate.net/figure/Example-faces-of-different-races_fiq2_263907837

Ngan, M., Grother, P. (2015) *Face Recognition Vendor Test (FRVT) - Performance of Automated Gender Classification Algorithms*. doi: 10.6028/NIST.IR.8052

Normal distribution (bez dat.). U Wikipedia. Preuzeto 28.08.2020. s https://en.wikipedia.org/w/index.php?title=Normal_distribution&oldid=975157617

Peters N. (2013). *The Differences Between Male and Female Portraits* Preuzeto 09.08.2020. s <https://design.tutsplus.com/articles/the-differences-between-male-and-female-portraits--vector-14954>

Ramirez V. (2017). *The Differences Between Men's & Women's Faces* Preuzeto 09.08.2020. s <https://oureverydaylife.com/the-differences-between-mens-womens-faces-12557240.html>

Rathgeb, C., Dantcheva, A., Busch, C. (2019) *IEEE Access. Impact and Detection of Facial Beautification in Face Recognition: An Overview*, 7, 152667-152678. doi: 10.1109/ACCESS.2019.2948526

Roomi, S. M., Virasundarii, S. L., Selvamegala, S., Jeevanandham, S., Hariharasudhan, D. (2011). *2011 Third National Conference on Computer Vision, Pattern Recognition, Image Processing and Graphics. Race Classification Based on Facial Features*, 54-57. doi: 10.1109/NCVPRIPG.2011.19

Scheuerman, M. K., Wade, K., Lustig, C. & Brubaker J. R. (2020). Proceedings of the ACM on Human-Computer Interaction. *How We've Taught Algorithms to See Identity: Constructing Race and Gender in Image Databases for Facial Analysis*, 4, 1-35. doi:10.1145/3392866

Viola, P., Jones, M. (2001). *Rapid object detection using a boosted cascade of simple features*, 511-518.

Wang, Y., Ricanek, K., Chen, C. & Chang, Y. (2010). 2010 Fourth IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS). *Gender classification from infants to seniors*, 1-6. doi: 10.1109/BTAS.2010.5634518

YCbCr – Computer Definition (bez dat.). U *Your Dictionary*. Preuzeto 28.08.2020. s <https://www.yourdictionary.com/ycbcr>

Yiu, T. (2019). *Understanding Random Forest*. Preuzeto 29.08.2020. s <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>

Zhang, Z. (2019). *Boosting Algorithms Explained*. Preuzeto 29.08.2020. s <https://towardsdatascience.com/boosting-algorithms-explained-d38f56ef3f30>

Zhu, Z., Chen, H., Hu, Y. & Li, J. (2018). EURASIP Journal on Image and Video Processing. *Age estimation algorithm of facial images based on multi-label sorting*, 1, 1-10. doi: 10.1186/s13640-018-0353-z

Popis slika

| | |
|---|----|
| Slika 1: Dijagram zadataka analize lica (Scheuerman i sur., 2020, str. 6)..... | 1 |
| Slika 2: Primjer ženskog portreta (Peters, 2013)..... | 3 |
| Slika 3: Primjer muškog portreta (Peters, 2013). | 4 |
| Slika 4: Posljedica starenja muške osobe u FG-NET bazi (<i>Face Aging Modeling</i> , bez dat.).. | 5 |
| Slika 5: Primjeri lica različitih rasa (<i>Muhammad</i> , bez dat.) | 6 |
| Slika 6: 50 nasumično odabranih slika lica iz baze FG-NET | 11 |
| Slika 7: Izgled ankete | 11 |
| Slika 8: Vizualizacija Random Forest modela (Yiu, 2019)..... | 14 |
| Slika 9: Shematski prikaz metodologije klasifikacije rase (Roomi i sur., 2011, str. 55). | 16 |

Popis tablica

| | |
|---|----|
| Tablica 1: Prikaz neuravnotežene procjene dobi | 18 |
| Tablica 2: MAE rezultati na FG-NET bazi | 19 |
| Tablica 3: Procjena spola različitih algoritama LOPO metodom..... | 19 |
| Tablica 4: Procjena spola različitih algoritama 5-fold cross validation metodom | 19 |
| Tablica 5: MAE promatranog algoritma i ljudske procjene dobi..... | 20 |