Analiza demografske pristranosti u biometrijskom prepoznavanju

Gašljević, Matea

Undergraduate thesis / Završni rad

2024

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/urn:nbn:hr:211:060659

Rights / Prava: Attribution 3.0 Unported/Imenovanje 3.0

Download date / Datum preuzimanja: **2025-03-23**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Matea Gašljević

Analiza demografske pristranosti u biometrijskom prepoznavanju

ZAVRŠNI RAD

Varaždin, 2024.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Matea Gašljević

Matični broj: 0016150218

Studij: Informacijske tehnologije i digitalizacija poslovanja

Analiza demografske pristranosti u biometrijskom prepoznavanju

ZAVRŠNI RAD

Mentor:

Izv. prof. dr. sc. Petra Grd

Varaždin, rujan 2024.

Matea Gašljević

Izjava o izvornosti

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

Autorica potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Ovaj rad se bavi problematikom demografske pristranosti u biometrijskim sustavima s naglaskom na pristranost prepoznavanja rase i spola na temelju fotografije lica. U radu se razmatraju ključne varijable koje se koriste u biometriji, procesi kao što su verifikacija i identifikacija, te kako oni utječu na pristranost vezanu za demografske značajke kao što su spol, rasa i dob. Također se obrađuju dva alata koja služe za prepoznavanje lica, te njihova preciznost u određivanju demografskih obilježja. Metodološki, rad se oslanja na pregled postojećih radova koji istražuju korelaciju između demografskih obilježja i pristranosti biometrijskih sustava, te samostalno provođenje istraživanja na nasumičnim uzorcima iz javne baze podataka i u konačnici, analiziranje rezultata istraživanja te izvođenje prijedloga poboljšanja točnosti biometrijskih sustava. Glavne teze rada su postojanje demografske pristranosti, utjecaj demografskih varijabli na točnost algoritama za biometriju, te treniranje algoritama na uzorcima. Rezultati istraživanja pokazali su na veću točnost kod muškaraca mongoloidne rase, a manju točnost kod žena općenito, a posebice kod žena crne rase. Zaključak rada naglašava potrebu za daljnjim istraživanjem i razvojem algoritama koji su osjetljivi na različite demografske osobine u vidu treniranja na većem broju različitih uzoraka te za uspostavljanjem standarda koji će osigurati pravednost i jednakost u primjeni biometrijskih tehnologija.

Ključne riječi: biometrija, demografija, pristranost, prepoznavanje lica, rasa, spol, algoritam, klasifikacija

Sadržaj

1. Uvod 1
2. Metode i tehnike rada 2
3. Biometrija 3
3.1. Vrste biometrijskih tehnika 4
3.1.1. Prepoznavanje lica 4
4. Demografska pristranost u biometrijskim sustavima 6
4.1. Biometrijska pristranost 6
4.2. Demografska pristranost 7
5. Analiza demografske pristranosti u biometrijskim sustavima 9
5.1. Prikupljanje podataka 9
5.2. Obrada i analiza podataka 10
5.2.1. AI Face Detection 11
5.3. Analiza rezultata 12
5.3.1. Žene bijele rase 13
5.3.2. Muškarci bijele rase 14
5.3.3. Žene crne rase 15
5.3.4. Muškarci crne rase 16
5.3.5. Žene mongoloidne rase 17
5.3.6. Muškarci mongoloidne rase 18
5.4. Pogreške 20
6. Zaključak 24
Popis literature 26
Popis slika 28
Popis tablica 28
Popis dijagrama 28
Slike korištene u alatima 29

1. Uvod

Problem informacijske sigurnosti podrazumijeva zaštitu informacijskih elemenata (npr. multimedijskih podataka) čime se osigurava da samo ovlašteni korisnici mogu pristupiti sadržaju u digitalnim medijima. Vlasnici sadržaja, kao što su autori i ovlašteni distributeri, gube milijarde dolara godišnje zbog ilegalnog kopiranja i dijeljenja digitalnih medija. Kako bi se riješio ovaj problem, potrebno je uvesti sustav za upravljanje digitalnim pravima. Ključna komponenta ovakvih sustava je provjera autentičnosti korisnika koja utvrđuje je li određena osoba doista ovlaštena za pristup sadržaju. Najčešće se koristi kriptografska metoda provjere, no kriptografski ključevi su dugi i nasumični što ih čini teškim za pamćenje. S druge strane, većina lozinki je tako jednostavna da ih se lako može pogoditi ili otkriti jednostavnim napadima rječnikom. Mnogi korisnici koriste istu lozinku u različitim aplikacijama, gdje napadač lako pristupa više aplikacija istovremeno. Ova ograničenja povezana s upotrebom lozinki mogu se smanjiti uvođenjem naprednijih metoda autentifikacije korisnika, kao što je prepoznavanje lica (Jain, Ross i Pakanti, 2006).

Posljednjih godina pojavilo se mnogo pitanja o točnosti i pravednosti automatiziranih sustava. Na primjer, mnoga istraživanja koja se bave alatima za procjenu rizika i distribuciju socijalne pomoći otkrile su brojne probleme vezane uz sistemsku pristranost i diskriminaciju u predviđanjima tih sustava. Posljedice takvih automatiziranih odluka mogu značajno utjecati na živote pojedinaca koji su pogođeni pristranošću (Drosdowski et al., 2020).

Cilj ovog rada je istražiti postojanje demografske pristranosti u biometrijskim sustavima, identificirati karakteristike i varijable koje utječu na pristranost, te pronaći načine za njezino smanjenje. S obzirom na sve veću primjenu biometrijskih sustava, ključno je osigurati da oni budu pravedni i jednako učinkoviti za sve korisnike, neovisno o njihovim demografskim karakteristikama poput spola, rase ili dobi. Demografska pristranost može dovesti do ozbiljnih društvenih i etičkih posljedica, uključujući diskriminaciju i nejednakost u pristupu osnovnim uslugama.

Motivacija za odabir ove teme proizlazi iz interesa za područje umjetne inteligencije u tehnologiji. S obzirom da biometrijski sustavi postaju sve prisutniji u našem svakodnevnom životu, važno je osigurati da oni budu pravedni za sve korisnike. Također, postavlja se pitanje kako naši pametni uređaji svakodnevno prepoznaju naš identitet u različitim uvjetima, osvjetljenjima, izdanjima, te položajima. Osim toga, s obzirom na to da se u modernom dobu pojedinci sve više izražavaju na način koji stvara sve manju razliku među spolovima, postavlja se pitanje može li se uopće definirati univerzalni uzorak za prepoznavanje spola, rase ili dobi.

2. Metode i tehnike rada

Za analizu demografske pristranosti u biometrijskim sustavima primjenit će se kvantitativni istraživački pristup koji će obuhvatiti prikupljanje podataka iz javne baze, podjele istih u podskupove, analizu podataka i provođenje istraživanja te evaluaciju performansi biometrijskih algoritama „AI Face Detection by Rashid Shamloo“ i usporedba s algoritmom „Visage Technologies“. Prvo će se prikupiti relevantni podaci, u ovom slučaju slike iz javne baze podataka koje uključuju raznolike demografske skupine. Zatim će se primjeniti alati za analizu razlika među različitim demografskim skupinama s fokusom na spol i rasu, odnosno etničku pripadnost. Rezultati istraživanja će se bilježiti pomoću Microsoft Excel alata te će se izraditi dijagrami s postocima točnosti odnosno pogrešaka u prepoznavanju rase i spola kod pojedinih demografskih skupina.

Cilj ovih aktivnosti je identificirati ključne varijable i uzroke pristranosti te predložiti potencijalne metode za njihovo smanjenje.

3. Biometrija

Biometrijska autentifikacija ili biometrija odnosi se na utvrđivanje identiteta na temelju fizičkih karakteristika i karakteristika ponašanja, odnosno osobina ili identifikatora. Te karakteristike su lice, otisak prsta, geometrija ruke, boja i izgled šarenice, pritisak tipke, potpis ili glas itd. (Miteksystems, 2021).

Biometrijski sustavi nude brojne prednosti u odnosu na tradicionalne metode provjere autentičnosti. Oni su inherentno pouzdaniji od provjera autentičnosti temeljenima na lozinkama jer biometrijske značajke ne mogu biti izgubljene ili zaboravljene. Osim toga, teško ih je kopirati, dijeliti ili distribuirati, te zahtijevaju prisutnost osobe u trenutku i na mjestu provjere, što dodatno povećava sigurnost. Biometriju je teško krivotvoriti i vjerojatnost da korisnik zaniječe pristupanje digitalnom sadržaju korištenjem biometrije je minimalna (Jain, Ross i Pakanti, 2006).

Pojedinci diljem svijeta pristupaju ključnim uslugama putem digitalne tehnologije više nego ikada prije. Statistika pokazuje da je u siječnju 2021. bilo 4,66 milijardi aktivnih korisnika interneta širom svijeta, što čini gotovo 60% globalne populacije. Od tog broja, 93% korisnika pristupilo je internetu putem mobilnih uređaja. Kako bi se osiguralo nesmetano korisničko iskustvo, organizacije, uključujući vladine agencije i privatne tvrtke, koriste biometrijsku tehnologiju za provjeru identiteta (Miteksystems, 2021).

Biometrijski sustavi mjere i analiziraju fizičke ili ponašajne osobine pojedinca u svrhu provjere identiteta i autentifikacije. Automatizirani biometrijski sustavi koriste umjetnu inteligenciju za dovršavanje ovog procesa. Sustav uspoređuje biometrijski unos s prethodno pohranjenim biometrijskim podacima kako bi potvrdio identitet (Miteksystems, 2021).

Automatizirani biometrijski sustav sastoji se od nekoliko komponenti: uređaja za snimanje koji prikuplja biometrijske uzorke i slike (npr. kamera u sustavu za prepoznavanje lica), baze podataka u koju se pohranjuju biometrijski podaci i drugi osobni podaci, algoritama za obradu signala koji procjenjuju kvalitetu uzorka, identificiraju područja od interesa (npr. lice ili otisak prsta) i izdvajaju razlikovna obilježja iz njega, algoritama usporedbe i odlučivanja koji utvrđuju razinu sličnosti dva biometrijska uzorka usporedbom podataka. Iako biometrijska tehnologija nudi prednosti poput praktičnosti i visoke sigurnosti, također ima nedostatke, uključujući visoke troškove i pristranost (Miteksystems, 2021).

Biometrijski markeri kao što su boja očiju ili ožiljak na licu služe kao jedinstvene značajke za prepoznavanje. Obučavanjem modela strojnog učenja da skeniraju, razumiju i prepoznaju ove jedinstvene značajke, možemo stvoriti visoko sigurnosne identifikatore. Međutim, umjetna inteligencija ne zna što je nos ili obrva, ili čak ljudsko lice. Istraživači koji

razvijaju tehnologije snimanja i prepoznavanja lica najprije moraju prikupiti velike količine slika lica kako bi obučili modele da prepoznaju što tražiti i što razlikovati pri otkrivanju biometrije lica (Ritter, 2020).

Biometrijski sustavi imaju za cilj utvrđivanje ili provjeru identiteta ili demografskih atributa pojedinaca. Ljudi posjeduju fiziološke karakteristike koje su gotovo univerzalno jedinstvene, što omogućuje razlikovanje različitih pojedinaca s visokim stupnjem preciznosti. (Drosdowski et al., 2020).

3.1. Vrste biometrijskih tehnika

Biometrija se temelji na prepoznavanju i razlikovanju fizičkih karakteristika i karakteristika ponašanja pojedinaca. Fizičke biometrijske tehnike često se smatraju pouzdanijima zbog jedinstvenih obilježja svakog pojedinca i manjih varijacija unutar skupine u usporedbi s karakteristikama ponašanja. Neke od fizičkih biometrijskih tehnika su otisak prsta, prepoznavanje šarenice oka, mrežnice oka, prepoznavanje lica, termogram lica i analiza DNK. Ovaj rad fokusira se na pristranost povezanu s fizičkim izgledom i točnost algoritama u odnosu na fizičke karakteristike, stoga će se detaljnije razmotriti tehnika prepoznavanja lica. Algoritmi za prepoznavanje lica često se kritiziraju zbog pristranosti i označavaju se kao „rasistički“ ili „pristrani“ od strane medija, nevladinih organizacija i istraživača. (Drozdowski et al.,2020).

3.1.1. Prepoznavanje lica

Prepoznavanje lica koristi se u različitim područjima i disciplinama. Uz brojne primjene kao što su identifikacija bankovnih kartica, kontrola pristupa, pretraga fotografija osumnjičenih, sigurnosni nadzor i sustav za praćenje i prepoznavanje lica također predstavlja temeljno ljudsko ponašanje ključno za učinkovitu komunikaciju i interakciju među ljudima. Prvi algoritmi za prepoznavanje lica razvijeni su na temelju analize profila lica, gdje su se koristile krivulje za pronalaženje normi i klasifikaciju drugih profila prema njihovim odstupanjima od normi. Napredak u tehnologiji omogućio je primjenu sustava za prepoznavanje lica u stvarnim uvjetima. Brz razvoj prepoznavanja lica rezultat je kombinacije čimbenika aktivnog razvoja algoritama, dostupnosti velikih baza podataka sa slikama lica i metode za evaluaciju učinkovitosti algoritama za prepoznavanje lica (Tolba, El-Baz i El-Harby, 2006).

Za prepoznavanje lica koristi se strojno učenje, a najpoznatiji alati postižu čak 99,97% točnosti kod slika u idealnim uvjetima. Kod slika koje imaju lošiju kvalitetu, lice se ne vidi idealno, ili je osvjetljenje loše, točnost može pasti na 90%. Sustavi za prepoznavanje lica koriste računalne algoritme za odabir detalja lica i stvaranje predloška lica. Elementi koji se gledaju i uzimaju u obzir su udaljenost između očiju, između čela i brade, oblik kostiju jagodica te obrise usana, brade i ušiju. Sustav sliku pretvara u skup digitalnih podataka, koji se zatim

koriste za stvaranje „otisaka lica“. Kao i otisak prstiju, ovaj brojčani kod je jedinstven za svaku osobu (Salvaro, 2023).

Procjena kvalitete lica je ključna za postizanje visokih performansi u prepoznavanju lica. Trenutno, visoke performanse ovih sustava za prepoznavanje lica često dolaze uz izraženu pristranosti prema određenim demografskim i nedemografskim skupinama. Nedavna istraživanja pokazala su da algoritmi za procjenu kvalitete lica trebaju biti prilagođeni specifičnom implementiranom sustavu za prepoznavanje lica kako bi postigli visoko precizne procjene kvalitete. Međutim, to može dovesti do prijenosa pristranosti na procjenu kvalitete lica (Terhorst et al., 2020).

Trenutna biometrijska rješenja uglavnom su optimizirana za maksimalnu ukupnu točnost, ali su često izrazito pristrana prema određenim demografskim skupinama. Performanse prepoznavanja lica značajno ovise o kvaliteti slike, koja se definira kao korisnost uzorka u svrhu prepoznavanja i ključna je za mnoge primjene (Terhorst et al., 2020).

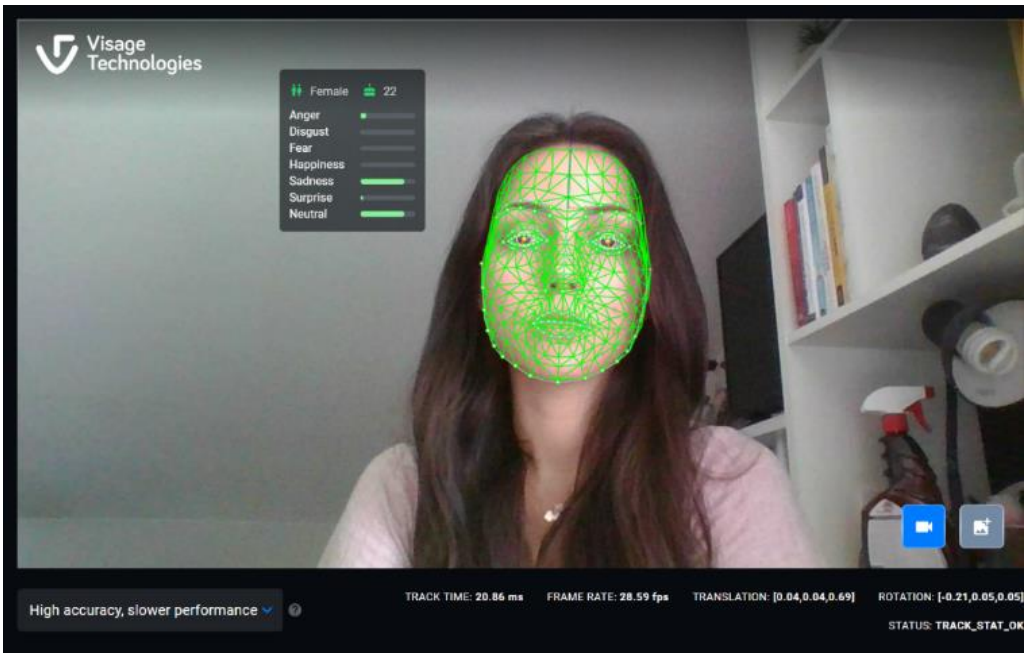

Slika 1: Primjer biometrije lica (Visage Technologies, 2024.)

4. Demografska pristranost u biometrijskim sustavima

4.1. Biometrijska pristranost

Biometrijska pristranost označava situaciju u kojoj algoritam ne funkcionira pravedno i točno na temelju zadataka za koje je programiran – automatizirano prepoznavanje pojedinaca na temelju njihovih fizičkih i ponašajnih karakteristika. Biometrijski algoritmi se smatraju pristranim ako postoje značajne razlike u njihovoj učinkovitosti kada se koriste za različite demografske skupine korisnika. To može rezultirati privilegiranjem određenih skupina, dok su druge skupine stavljene u nepovoljni položaj (Miteksystems, 2021).

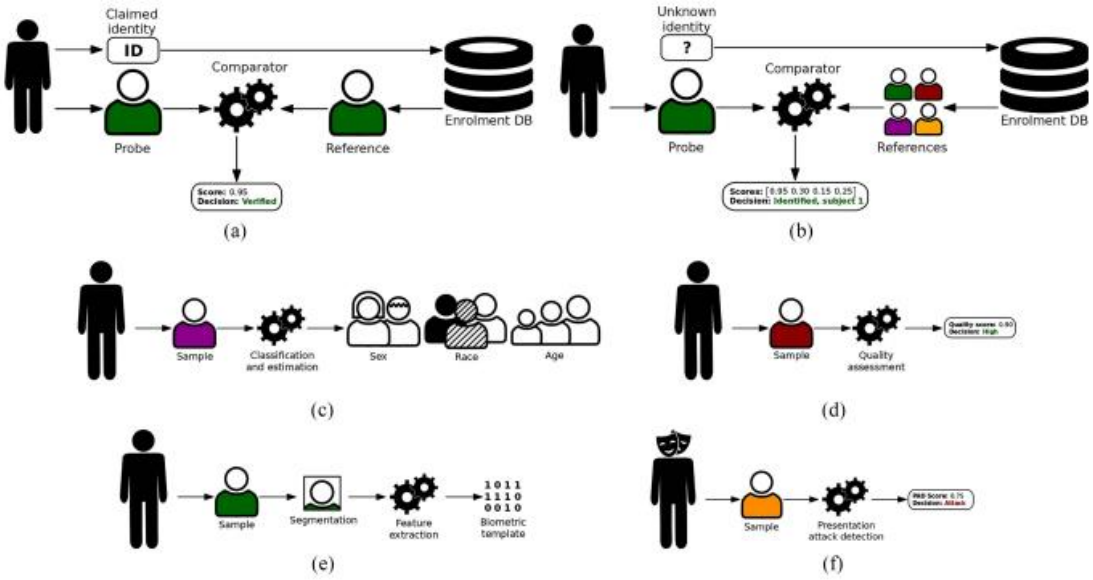

Slika 2: Algoritmi za biometriju (Drosdowski et al., 2020.)

Biometrijski algoritmi mogu biti podložni pristranostima povezanima s različitim varijablama. Te varijable mogu uključivati demografske čimbenike poput spola, dobi i rase subjekta, što može dovesti do demografske pristranosti. Ostale varijable koje mogu utjecati na biometrijske algoritme su okolišne poput osvjetljenja i pozadine, te specifične za subjekt kao što su ponašanje, položaj lica, izraz lica i korištenje dodataka poput naočala ili šminke (Drosdowski, 2020).

Sustavi za prepoznavanje lica obično imaju dva glavna scenarija primjene: verifikaciju i identifikaciju. Verifikacija se odnosi na proces potvrđivanja biometrijskog zahtjeva usporedbom biometrijskih podataka (usporedba jedan na jedan) kako bi se utvrdilo je li osoba

zaista ta za koju se predstavlja. Identifikacija se odnosi na proces pretraživanja baze podataka biometrijskih podataka kako bi se pronašao i identificirao biometrijski referentni identifikator koji pripada određenom pojedincu, odnosno postoji li u bazi osoba čije lice odgovara uzorku (Drosdowski, 2020).

4.2. Demografska pristranost

Prema dokumentarnom filmu 'Coded Bias' (Kantayya, 2020), algoritam se trenira na velikom broju uzoraka, uključujući fotografije koje sadrže lice, kao i one koje ne sadrže lice. Također, protagonistica Joy Buolamwini suočila se s problemima prilikom rada na svom projektu, jer algoritam nije uspijevao prepoznati njezino lice. Da bi ga algoritam prepoznao, morala je nositi bijelu masku.

U istraživanju koje je provela na tri različita algoritma, točnost je bila veća kod muškaraca nego kod žena, kao i kod svjetlijih lica u usporedbi s tamnijim. Sve kompanije imale su najlošije rezultate u prepoznavanju tamnijih žena (Buolamwini, n.d.).

Nacionalni institut za standarde i tehnologiju SAD-a otkrio je da su lica Afroamerikanaca i Azijata imala 10 do 100 puta veću stopu lažno pozitivnih rezultata u usporedbi s licima bijele rase kada je riječ o algoritmima za prepoznavanje lica. Lažno pozitivni rezultati nastaju kada biometrijski sustav netočno prepozna dva različita lica kao ista. Osim toga, ženska i mlađa lica također imaju veću stopu lažno negativnih rezultata. Druge znanstvene studije potvrđuju da su biometrijske performanse kod žena i mlađih pojedinaca slabije, te da tamnopute žene imaju posebno manju točnost klasifikacije. Smanjenje demografskih čimbenika biometrijske pristranosti može biti izazovno, osobito ako postoji nedostatak svijesti o tom problemu. Međutim, nedostatak dosljednosti i točnosti softvera za biometrijsku autentifikaciju može imati negativne posljedice na korisnika i na organizaciju. Ne samo da visoke stope pogrešaka povećavaju potencijal prijevare, osobito u slučaju lažno pozitivnih podudaranja, već također diskriminiraju korisnike koji mogu doživjeti lažno negativna podudaranja (Miteksystems, 2021).

U Velikoj Britaniji policija koristi algoritme za prepoznavanje lica kako bi identificirala potencijalne prekršitelje zakona među ljudima na ulici. Međutim, ovaj sustav je pokazao pristranost kada je slučajnog prolaznika, 14-godišnjeg mladića crne rase, pogrešno identificirao kao osobu koja se nalazi na listi traženih. Coded Bias, 2020).

Američka unija za građanske slobode (eng. American Civil Liberties Union) provela je istraživanje algoritma „Rekognition“ od kompanije Amazon nad članovima kongresa gdje je 28 osoba bilo pogrešno identificirano kao osoba s dosjeom, od kojih je 11 bilo crne rase (ACLU, 2018).

Pristranost nastaje kada podaci za obuku skreću prema određenoj demografskoj skupini. To rezultira vrlo specifičnom vrstom pogreške poznatom kao prekomjerno uklapanje. Kada skupovi podataka neproporcionalno pokazuju određene karakteristike, model strojnog učenja će se jače usredotočiti na tu karakteristiku. To znači da biometrijski sustav nije pristran ni prema jednoj određenoj rasi ili spolu, već je umjesto toga manje sposoban identificirati obrasce koji su tipični za manje zastupljene demografske skupine (Ritter, 2020).

U biometriji prepoznavanja lica, pristranost obično nastaje zbog neravnomjerno raspoređenih klasa u podacima za obuku. Mnoga istraživanja su pokazala da je točnost prepoznavanja lica snažno pod utjecajem demografskih atributa. Postoji nekoliko standarda za osiguranje kvalitete slika lica, koja je podijeljena na kvalitete povezane sa slikom (npr. osvjetljenje, sjene) i mjere kvalitete povezane sa subjektom (npr. položaj lica, izraz lica, dodaci). Prvi algoritmi za procjenu kvalitete lica koristili su metričke vrijednosti kvalitete koje su se temeljile na čimbenicima kvalitete slike. Međutim, ovi pristupi su zahtijevali ručno razmatranje svih mogućih čimbenika. Novi pristupi, poput višedimenzionalnog skaliranja, pokušavaju mapirati značajke karakterizacije prostora na stvarne rezultate kako bi se predvidjela učinkovitost prepoznavanja lica (Terhorst et al., 2020).

U kontekstu automatiziranih algoritama, postoji mnoštvo potencijalnih uzroka pristranosti. Najistaknutije, podaci za obuku mogu biti pristrani, nepotpuni, zastarjeli, disproporionalni ili imati ugrađene povijesne pristranosti, što sve šteti obuci algoritma i širi pristranosti prisutne u podacima (Drosdowski et al., 2020).

Prema zaključcima Drosdowski et al., zabilježeni su sljedeći obrasci performansi: bolje biometrijske performanse za starije muškarce iz istočne Azije, više pogrešaka za žene nego za muškarce, niže performanse za mlade žene crne rase, više performanse za starije subjekte iz Azije, loše performanse za djecu, najviše performanse za bijele muškarce, najniže za žene iz Azije.

5. Analiza demografske pristranosti u biometrijskim sustavima

Za praktični dio ovog rada potrebno je prikupiti podatke s raznolikim biometrijskim skupinama koje uključuju različite rase i spolove. Podaci će biti strukturirani prema ovim demografskim kriterijima kako bi se omogućila detaljna analiza pristranosti. Planira se implementacija modela za prepoznavanje lica AI Face Detection kako bi se testirale performanse na različitim demografskim skupinama.

Pri analizi prikupljenih podataka, bit će potrebno koristiti standardizirane demografske izraze, koji su već usvojeni u istraživanjima poput onih Drosdowski et al. Kao što je navedeno, Drosdowski et al. izbjegavaju društveno osjetljive rasprave o spolovima, rasama i etnicitetu. Stoga se izraz spol koristi na binaran način, te se ne pravi razlika između izraza „rasa“ i „etnicitet“, a demografski faktori su razmatrani na fenotipskoj osnovi, odnosno u vezi sa vidljivim osobinama uzorka. Ovaj pristup omogućuje fokusiranje na tehničke aspekte istraživanja, što je ključno za održavanje ciljeva i integriteta, te će se isti primijeniti i u ovom radu.

Rezultati analize će omogućiti procjenu pristranosti, a dobivene informacije će poslužiti kao temelj za daljnje diskusije o potrebnim poboljšanjima u biometrijskim sustavima kako bi se smanjile pristranosti i povećala pravednost u primjeni biometrijske tehnologije.

5.1. Prikupljanje podataka

Za evaluaciju rezultata koristi se javno dostupna baza podataka „Labeled Faces in the Wild„ (LFW). LWF sadrži 13.233 fotografija lica te je dizajnirana za proučavanje problema prepoznavanja lica. Sadrži 5.749 jedinstvenih identiteta sa 1.680 ljudi s dvije ili više slika. Bazu su izradili i održavali istraživači sa Sveučilišta Massachusetts, Amherst (Papers with Code, n.d.).

U svrhu ove analize, uzet će se u obzir tri rase: bijela (kavkaska), crna (negroidna), te žuta (mongoloidna) (Wikipedia, 2023).

Uz to, uzorci će biti podijeljeni na dva spola; muški i ženski. Za svaku od tri navedene rasne skupine potrebno je odabrati reprezentativan broj uzoraka. Kako bi se izbjegla pristranost u rezultatima, broj uzoraka za svaku rasu će biti podjednak (100). Unutar svake rasne skupine, podaci će biti dalje podijeljeni prema spolu na 50 uzoraka za svaku podskupinu. Time će se omogućiti analiza performansi algoritama s obzirom na spolne razlike. Zbog prisutnih tehnologija za pomlađivanje i drugih faktora, dob osobe se na temelju izgleda teško

procjenjuje i ljudskim okom, te se također želi zaštititi identitet maloljetnih osoba, stoga u ovom radu dob neće biti uzeta u obzir kao varijabla pri analizi preciznosti algoritama.

5.2. Obrada i analiza podataka

Postoji nekoliko algoritama za prepoznavanje lica, uključujući one zasnovane na konvencionalnim, ručno dizajniranim karakteristikama, te one zasnovane na dubokom učenju. Neki od najpopularnijih algoritama uključuju OpenCV, Face++, Amazon Rekognition, DeepFace, FaceNet, Visage Technologies i AI Face Detection. U nastavku je prikazan primjer prepoznavanja lica u alatu Visage Technologies.

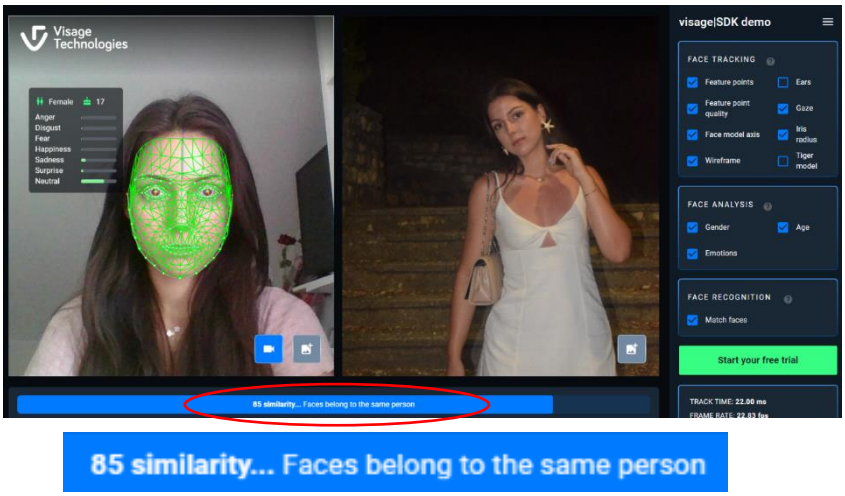

Slika 3: Usporedba sličnosti osoba sa dvije slike (Visage Technologies, 2024)

Slika 3 prikazuje rezultate usporedbe dviju slika iste osobe. Softver izračunava sličnost lica između dviju slika koristeći brojevnu skalu do 100. U prikazanom primjeru, podudaranje iznosi 85, što sugerira visoku razinu sličnosti. Na temelju tog rezultata, može se zaključiti da je na obje slike prikazana ista osoba.

5.2.1. AI Face Detection

AI Face Detection softver, kojeg je kreirao Rashid Shamloo, koristi napredne tehnike umjetne inteligencije za prepoznavanje lica pod različitim kutevima. Ovaj softver može prepoznati više lica u jednoj fotografiji, te izračunava dob, spol i etnicitet sa visokom razinom pouzdanosti (Rashid Shamloo, n.d.).

Ovaj softver pokazuje svestranost i preciznost u analizi biometrijskih podataka, čineći ga relevantnim alatom u kontekstu biometrijskih istraživanja i aplikacija.

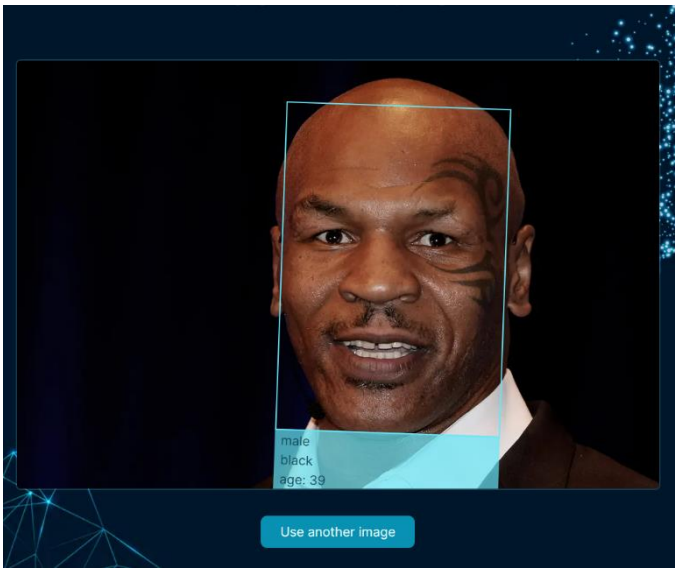

Slika 4: Prepoznavanje spola, dobi i etničke pripadnosti (AI Face Detection, 2024.)

Ova aplikacija korištena je za testiranje i izračunavanje pristranosti u biometriji s obzirom na spol i etnicitet (rasu). Kako bi se osigurao konzistentan pristup klasifikaciji, etničke kategorije poput „indian“ i „hispanic“ smatrane su dijelom bijele rase. U svakoj kategoriji ima otprilike 50 uzoraka, što rezultira ukupnim brojem od 300 uzoraka. Svaki uzorak je ručno učitan u aplikaciju, a rezultati su bilježeni za analizu prepoznavanja sveukupnog broja uzoraka, kao i zasebno za analizu preciznosti prepoznavanja spola i rase. Ako algoritam nije uspio točno prepoznati jedan od kriterija, taj se rezultat smatrao pogrešnim.

5.3. Analiza rezultata

U ovom istraživanju, analiza je provedena kroz ručno učitavanje svake slike u AI Face Detection program, nakon čega su bilježeni rezultati. U prvom dijelu, broj točnih prepoznavanja lica, spola i rase je zabilježen, dok su pogrešni rezultati ili slučajevi u kojima algoritam nije mogao generirati rezultat, ostavljeni neuzeti u obzir.

Na temelju ovih podataka, izračunati su postoci točnih prepoznavanja lica u cjelini, kao i zasebni postoci za točnost prepoznavanja spola i rase. Također su zabilježeni postoci netočnih prepoznavanja, tj. pogrešaka, te njihovo obrazloženje. Ovaj pristup omogućio je detaljnu evaluaciju učinkovitosti algoritma u različitim demografskim skupinama i pružio uvid u potencijalnu pristranost prisutnu u sustavu.

5.3.1. Žene bijele rase

Tablica 1: Pogreške pri prepoznavanja žena bijele rase

SLUČAJEVI	BIJELA RASA - žene
6	Iz profila ne prepoznaje rasu, smeđe kose
3	Iz profila ne prepoznaje spol, zavezana kosa
2	Iz profila ne prepoznaje spol, kratka kosa
1	Stariju ženu bez definiranih crta lica prepoznaje kao žutu rasu
1	Ne prepoznaje rasu kod tamnopute bijele žene
2	Ne prepoznaje rasu, izravna slika duža plava kosa
1	Ne prepoznaje rasu i krivo prepoznaje spol, žena sa zavezanom kosom manje ženstvenih crta lica
1	Ne prepoznaje rasu kod starije žene sijede kratke kose
Broj krivo prepoznatih osoba	**17 / 50**
Postotak krivo prepoznatih osoba	**34%**

Rezultati ovog istraživanja pokazuju da su algoritmi za prepoznavanje lica imali značajne poteškoće u procjeni rasne pripadnosti i spola kod žena bijele rase, s netočnom klasifikacijom u 34% slučajeva. Od ukupno 50 osoba, 17 ih je bilo netočno klasificirano u kontekstu rasne pripadnosti i spola. Poteškoće u prepoznavanju bile su naročito prisutne kod osoba sa smeđom, zavezanom ili kratko ošišanom kosom. Također, starije žene s manje definiranim crtama lica bile su sklonije pogrešnoj klasifikaciji. Ovi rezultati ukazuju na značajne izazove u prepoznavanju specifičnih osobina kod bijelih žena, konkretno kose i crta lica.

a) b)

Slika 5: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)

5.3.2. Muškarci bijele rase

Tablica 2: Pogreške pri prepoznavanju muškaraca bijele rase

SLUČAJEVI	BIJELA RASA - muškarci
2	Iz profila ne prepoznaje spol kod muškarca kratke plave kose
1	Iz profila muškarca prepoznaje kao ženu
2	Iz profila ne prepoznaje rasu, smeđe kose
1	Iz profila prepoznaje muškarca kao ženu
5	Kod loše kvalitete slike ne prepoznaje rasu, naočale i kapa
1	Iz profila krivo prepoznaje rasu
Broj krivo prepoznatih osoba	**12 / 50**
Postotak krivo prepoznatih osoba	**24%**

Rezultati istraživanja pokazuju da je algoritam netočno klasificirao muškarce bijele rase u 24% slučajeva, odnosno njih 12 od 50. Najčešće greške uključuju nemogućnost prepoznavanja spola ili rase zbog položaja glave, odnosno kada je prema kameri okrenut profil osobe. Loša kvaliteta slike, prisutnost naočala ili kape dodatno su otežavali pravilnu klasifikaciju spola i rase. U nekim slučajevima, muškarci su prepoznati kao žene, što ukazuje na izazove u razlikovanju spola.

a) b)

Slika 6: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)

5.3.3. Žene crne rase

Tablica 3: Pogreške pri prepoznavanju žena crne rase

SLUČAJEVI	CRNA RASA - žene
1	Krivo prepoznaje rasu - žena kratke afro frizure
6	Iz profila ne prepoznaje rasu kod crne žene s afro pletenicama, zavezane kose
1	Ženu s pokrivenom glavom prepoznaje kao muškarca
1	Iz profila ne prepoznaje spol žene obrijane glave
5	Ne prepoznaje spol žene zalizane kose
5	Ne prepoznaje spol žene puštene kose
6	Ne prepoznaje rasu žene puštene kose iz profila
2	Ne prepoznaje ni rasu ni spol žene zalizane kose
Broj krivo prepoznatih osoba	**27 / 48**
Postotak krivo prepoznatih osoba	**56%**

Rezultati istraživanja pokazuju da su žene crne rase bile krivo prepoznate u čak 56% slučajeva, što je najviša stopa pogrešaka među testiranim skupinama. Od ukupno 48 uzoraka, 27 ih je bilo pogrešno klasificirano. Najčešće pogreške uključuju neprepoznavanje rase i spola, posebno kod žena s tradicionalnim frizurama, kod žena sa zalizanom kosom ili onih obrijane glave. Žene s pokrivenom glavom su često pogrešno prepoznate kao muškarci. Ovi rezultati ukazuju na značajne izazove u pravilnom prepoznavanju žena crne rase.

a) b)

Slika 7: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)

5.3.4. Muškarci crne rase

Tablica 4: Pogreške pri prepoznavanju muškaraca crne rase

SLUČAJEVI	CRNA RASA - muškarci
5	Ne prepoznaje rasu muškarca
4	Prepoznaje krivu rasu muškarca
Broj krivo prepoznatih osoba	**9 / 50**
Postotak krivo prepoznatih osoba	**18%**

Rezultati istraživanja pokazuju da je kod muškaraca crne rase došlo do relativno niske stope grešaka u prepoznavanju, s ukupno 18% pogrešaka, odnosno 9 osoba od njih 50. Jedine dvije greške bile su neprepoznavanje ili u pogrešnom prepoznavanje rase. Manji broj grešaka može se pripisati činjenici da u ovoj podskupini muškarci crne rase imaju većinom vrlo kratku kosu i izražene muževnije crte lica specifične za ovu demografsku skupinu, što olakšava klasifikaciju i smanjuje mogućnost zamjene s drugim rasama i spolovima.

a)

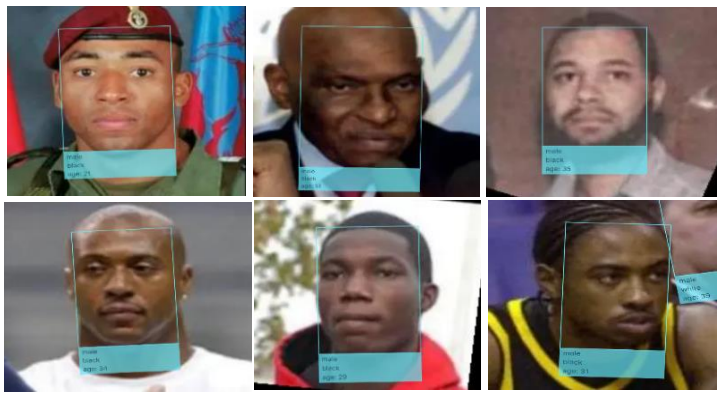

Slika 8: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)

5.3.5. Žene mongoloidne rase

Tablica 5: Pogreške pri prepoznavanju žena mongoloidne rase

SLUČAJEVI	MONGOLOIDNA RASA - žene
9	Ne prepoznaje rasu
3	Ne prepoznaje spol - kapa i odora
2	Ne prepoznaje spol - kratka kosa
1	Ne prepoznaje ni spol ni rasu
Broj krivo prepoznatih osoba	**15 / 48**
Postotak krivo prepoznatih osoba	**31%**

Rezultati istraživanja pokazuju da su žene mongoloidne rase bile krivo prepoznate u 31% slučajeva. Od ukupno 48 osoba, 15 ih je bilo netočno klasificirano. Najčešće greške uključuju neprepoznavanje rase, kao i spola kod žena s kapom, odorom i kratkom kosom. U jednom slučaju nije prepoznat ni spol ni rasa. Ovi rezultati ukazuju na izazove u klasifikaciji žena mongoloidne rase, posebno kada su prisutni specifični faktori poput pokrivala za glavu ili kratke kose, što može otežati pravilnu procjenu spola i rase.

a) b)

Slika 9: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)

5.3.6. Muškarci mongoloidne rase

Tablica 6: Pogreške pri prepoznavanju muškaraca mongoloidne rase

SLUČAJEVI	MONGOLOIDNA RASA - muškarci
6	Ne prepoznaje spol
5	Ne prepoznaje rasu
1	Krivo prepoznaje rasu
1	Krivo prepoznaje spol
Broj krivo prepoznatih osoba	**13 / 50**
Postotak krivo prepoznatih osoba	**26%**

Rezultati istraživanja pokazuju da je kod muškaraca mongoloidne rase došlo do pogrešne procjene demografskih podataka u 20% slučajeva, što uključuje 13 pogrešaka od ukupno 50 uzoraka. Najčešće greške uključuju neprepoznavanje spola (6 slučajeva) i rase (5 slučajeva), te krivo prepoznavanje spola (1 slučaj) i rase (1 slučaj). Greške su podjednako raspoređene na one kod procjene spola i rase, što sugerira da se izazovi u prepoznavanju ne odnose isključivo na jedan atribut. Ovi rezultati mogu biti povezani sa specifičnim karakteristikama mongoloidne rase koji mogu otežati precizno prepoznavanje u nekim slučajevima.

a) b)

Slika 10: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)

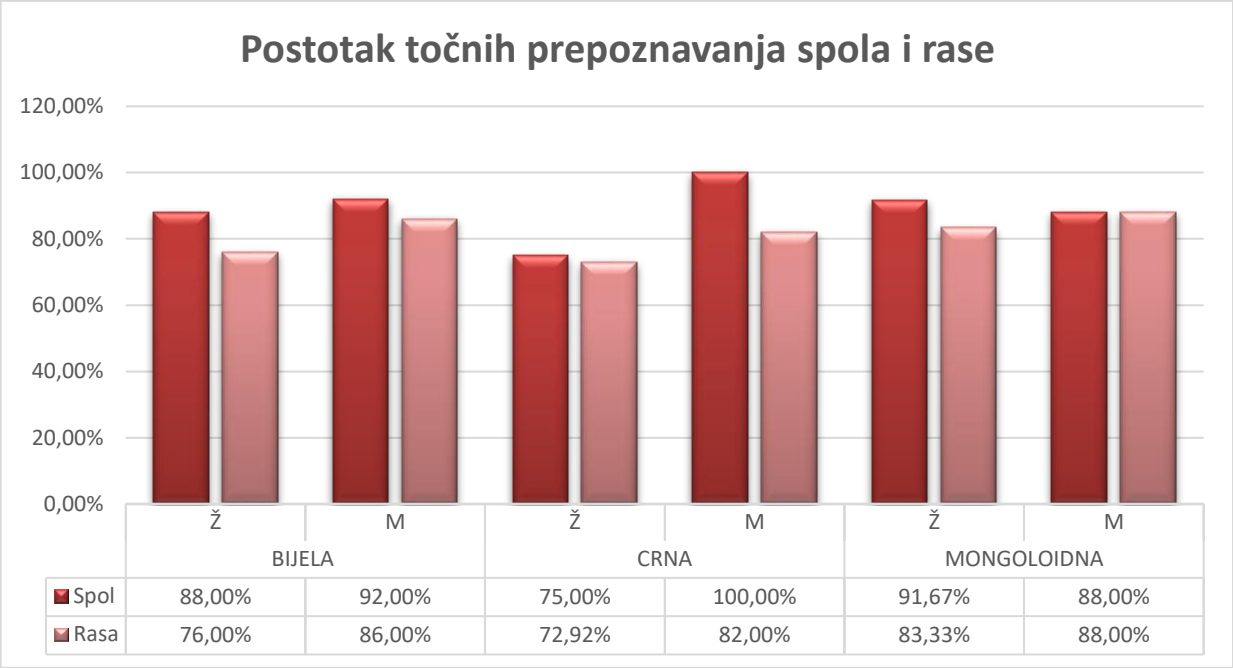

Dijagram 1: Postotak točnosti prepoznavanja lica

Rezultati istraživanja pokazuju značajne varijacije u točnosti prepoznavanja spola i rase među različitim demografskim skupinama. Najveću točnost algoritam je imao kod procjene spola muškaraca crne rase (100%), a najmanju kod procjene spola žena crne rase (75%). Kod procjene rase najveća točnost je bila kod muškaraca mongoloidne rase (88%), a najmanja kod žena crne rase (72,9%). Budući da različite rasne skupine imaju različite karakteristike lica, to može otežati prepoznavanje kod algoritama koji nisu dovoljno trenirani na različitim tipovima lica i demografskih obilježja. Točnost za žene crne rase niža je od ostalih, što može značiti da algoritam nije dovoljno prilagođen prepoznavanju karakteristika te podskupine, odnosno da je treniran na premalom broju uzoraka te demografske skupine. Uvelike imaju utjecaj i raznolikost frizura, boje kose, te crta lica, te se nerijetko algoritam zabuni oko procjene rase i spola. Budući da crna rasa ima muževnije crte lica, to može biti razlog iza velike točnosti prepoznavanja spola. Upravo frizura može biti razlog razlike između točnosti prepoznavanja muškaraca i žena unutar crne rase (mnogo crnih žena nosilo je kratku frizuru nalik onoj kod muškaraca). Kod mongoloidne rase točnost je relativno uravnotežena jer postoje određene sličnosti u karakteristikama lica u toj skupini (oči, oblik glave...).

5.4. Pogreške

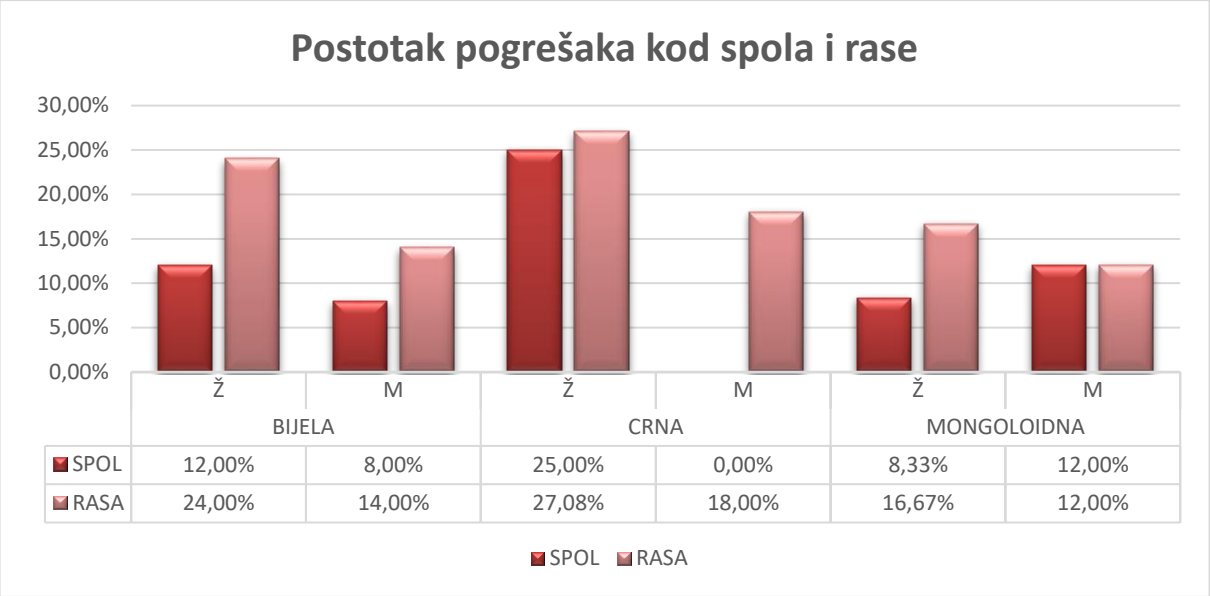

Dijagram 2: Postotak pogrešaka po rasi i spolu

Prilikom analize rezultata, došlo je do mnogo pogrešaka. U svakom podskupu bila je barem jedna pogreška, osim kod procjene spola muškaraca crne rase (0%). Najveći postotak pogrešaka bio je pri procjeni rasne pripadnosti žena crne rase (27,5%). U nastavku su rezultati podijeljeni na spol i rasu zbog lakšeg tumačenja rezultata.

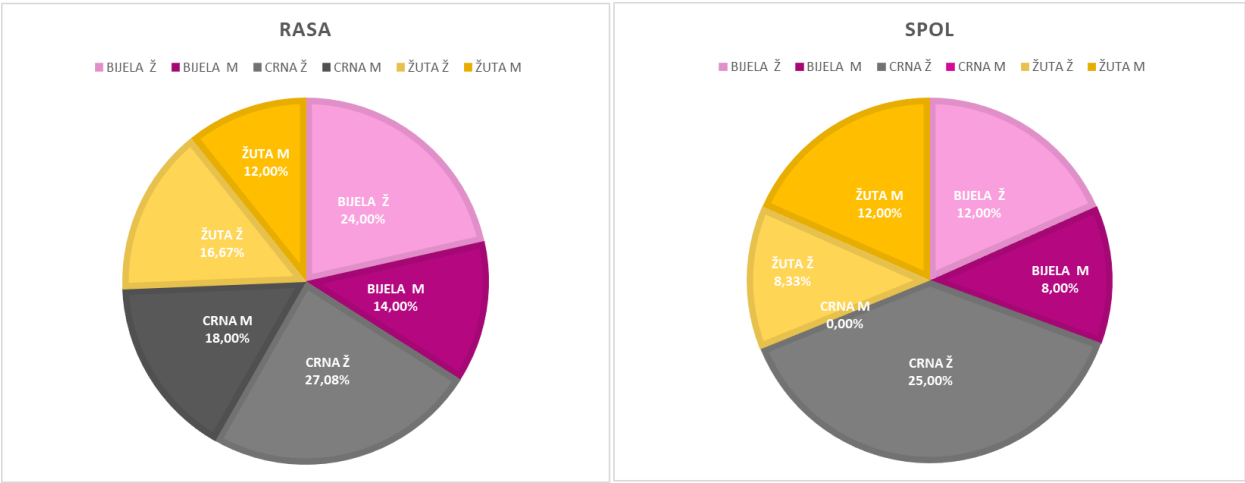

Slika 11: Podjela postotka pogrešaka po rasi i spolu

Kod analize rezultata preciznosti određivanja rase u AI Face Detection alatu vidljivo je da je najviše grešaka nastalo kod žena koje pripadaju crnoj rasi (čak 27,08%, odnosno 15 osoba od 48 uzoraka za tu podskupinu), a najmanje kod muškaraca koji pripadaju mongoloidnoj rasi (12%, odnosno 6 osoba).

Kod analize rezultata preciznosti određivanja spola, vidljivo je da je kod čak 25% uzoraka žena crne rase krivo određen spol, no kod nijednog muškarca crne rase.

Greške koje je algoritam radio tijekom istraživanja uključuju pogrešnu procjenu spola, etničke pripadnosti, ali i izostanak rezultata u cjelini. Neke od uzoraka algoritam nije htio učitati, te je bilo potrebno koristiti zamjensku fotografiju.

Slika 12: Kriva procjena spola (AI Face Detection, 2024.)

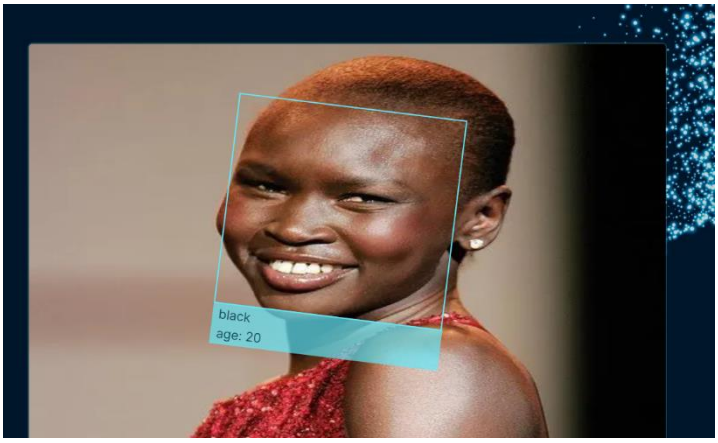

Slika 13: Nedostatak procjene spola (AI Face Detection, 2024.)

Kod uzoraka lošije kvalitete, te nejasnom obliku glave, odnosno frizure, algoritam je često kao rezultat za žene izbacivao da su muškarci, ili nije dao rezultat, dok je za istu fotografiju alat Visage Technologies dao točan rezultat. Ovaj softver može koristiti naprednije metode za prepoznavanje spola koje su otpornije na promjene u kvaliteti slike i varijacije u frizurama, kao što su bolje tehnike obrade slike. To također može ukazivati na jaču otpornost na varijacije u kvaliteti slike i bolje performanse u prepoznavanju karakteristiika lica koje su ključne za pravilnu procjenu spola.

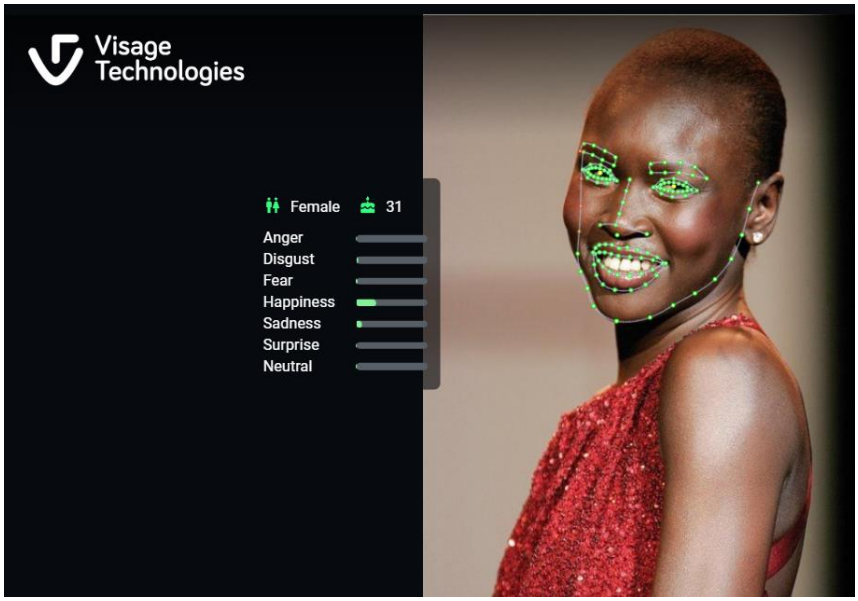

Slika 14: Točna procjena spola (Visage Technologies, 2024.)

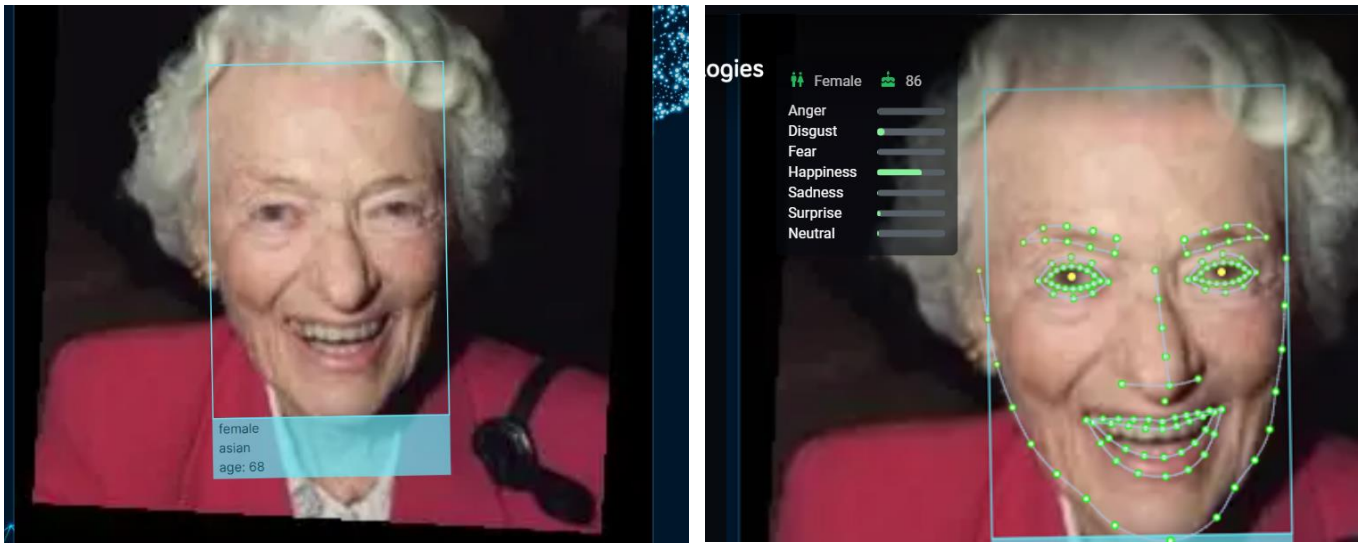

Slika 15: Procjena starijeg lica u alatima a) Face Detection i b) Visage Technologies (2024.)

Kod starijih osoba kojima su crte lica manje definirane pogrešno određuje rasnu pripadnost.

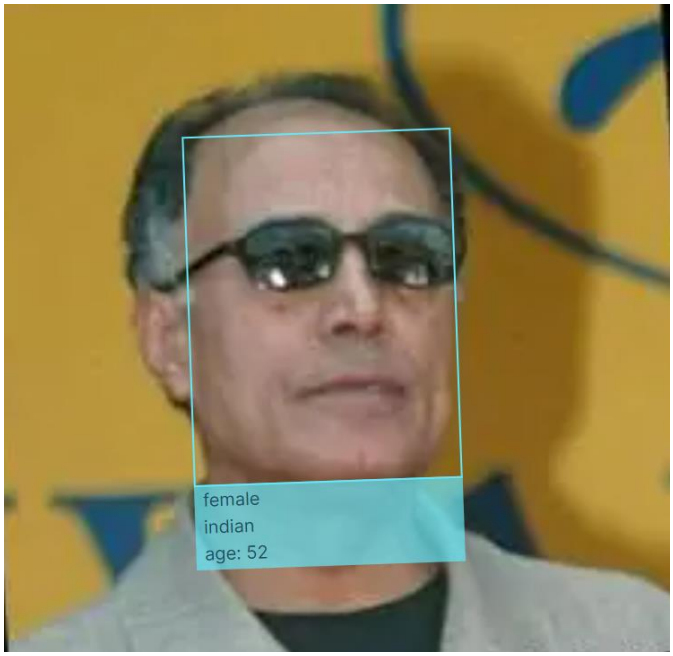

Slika 16: Kriva procjena spola i etničke pripadnosti (AI Face Detection, 2024.)

U nekim slučajevima algoritam je pogriješio i spol i etničku pripadnost bez jasno vidljivog razloga; na slici 16. je muškarca prepoznao kao ženu. Ovome razlog može biti pogrešno konfigurirani model ili greška u softveru. Također, osoba je okrenuta kameri profilom te se koriste sunčane naočale koje sakrivaju ključni dio lica; oči.

Kako bismo postigli pravednije rezultate u tehnologiji, važno je svjesno pristupiti kreiranju inkluzivnog koda. Ključno je ne samo tko kodira, već i kako se kodira. Potrebno je identificirati i razumjeti moguće pristranosti u postojećim sustavima i aktivno raditi na uvođenju inkluzivnih setova podataka (Buolamwini, n.d.).

6. Zaključak

Algoritam AI Face Detection pokazao je visoku preciznost u prepoznavanju spola kod muškaraca crne rase te kod prepoznavanja rase muškaraca mongoloidne rase, dok su pogreške bile posebno izražene kod žena crne i bijele rase. Točnost prepoznavanja ovisi o spolu, rasi i kvaliteti slike. Frizure, boja kose i karakteristike lica (npr. izražajnost ženstvenih ili muževnih crta lica) igraju značajnu ulogu u preciznosti prepoznavanja. Kratke frizure kod žena crne rase mogu zbuniti algoritam, dok su izražene crte lica kod starijih osoba i žena bijele rase također problematične. Algoritam je imao značajan broj pogrešaka u procjeni spola, etničke pripadnosti, te u nekim slučajevima nije dao nikakav rezultat. Ove pogreške bile su izraženije kod žena bijele i crne rase. Niska kvaliteta slika i nedostatak vidljivosti određenih karakteristika često su uzrokovali pogreške.

Iz rezultata možemo zaključiti da postoji demografska pristranost u modelu za prepoznavanje lica. Model bolje radi na bijelim i muškim osobama, dok se pristranost javlja kod drugih rasa i kod žena. Ova pristranost može biti rezultat neravnoteže u skupu podataka, pristrranih algoritama ili neadekvatnog treniranja modela na raznovrsnim podacima.

Izazovi koji su uočeni u prepoznavanju osoba različitih demografskih karakteristika posebno se odnose na žene crne rase. One su često pogrešno klasificirane zbog karakteristika koje se mogu smatrati sličnijima muškim osobinama, poput izraženijih muževnih crta lica ili obrijane glave koje su specifične za određene kulture. Muškarci su lakše prepoznatljivi zbog karakteristika lica i frizure koje imaju manje dodatnih varijacija u odnosu na žene, gdje ulaze i šminka, različite dužine, boje i oblici kose, dodaci kao naočale i šeširi, te nakit. Kod nekih rasa, poput mongoloidne, gdje postoje jasnije i konzistentnije karakteristike lica, algoritmi mogu postići veću točnost. Razumijevanje tih karakteristika može pomoći u poboljšanju prepoznavanja u drugim rasnim skupinama.

Algoritam može biti nedovoljno treniran na raznovrsnim skupinama lica, što uzrokuje nižu točnost u prepoznavanju specifičnih karakteristika među različitim rasama i spolovima. Kako bi se povećala točnosti, potrebno je uključiti veći broj slika crnih žena s različitim stilovima, izrazima, položajima glave i frizurama, ali isto tako treba uključiti i slike koje prikazuju varijacije u osvjetljenju i kvaliteti slike kako bi se model naučio prepoznavati karakteristike u različitim uvjetima. Također, korisno bi bilo i razviti specifične modele za prepoznavanje spola i rase koji se posebno fokusiraju na karakteristike koje su manje vidljive ili su suptilnije, poput detalja lica ili promjena u frizuri. Da bi se algoritam unaprijedio, potrebno je i redovito testirati model s novim skupovima podataka i evaluirati njegove performanse u prepoznavanju različitih demografskih grupa kako bi se smanjio broj pogrešaka.

Budući da kod žena crne rase često nije bilo rezultata, to ukazuje na nedostatak algoritma da prepozna crnu rasu, a ne na zabunu s drugom rasom, što ukazuje na potrebu za dodatnim treniranjem modela specifično za crne žene. Sama činjenica da je u bazi podataka pronađeno samo 48 slika žena crne rase naglašava nedostatak uzoraka tog podskupa.

Primjenom ovih strategija, model bi trebao postati učinkovitiji u prepoznavanju i razlikovanju crnih žena i drugih demografskih grupa.

Popis literature

[1] ACLU. (26.07.2018). *Amazon's face recognition falsely matched 28 members of Congress with mugshots*. Dostupno s https://www.aclu.org/news/privacy-technology/amazons-face-recognition-falsely-matched-28 Pristupano 09.09.2024.

[2] Buolamwini, J. (n.d.). *Gender shades: Intersectional accuracy disparities in commercial gender classification*. Dostupno s https://gendershades.org/overview.html Pristupano 09.09.2024.

[3] Drozdowski, P., Rathgeb, C., Dantcheva, A., Damer, N., & Busch, C. (2020). Demographic Bias in Biometrics: A Survey on an Emerging Challenge. *IEEE Transactions on Technology and Society*, *1*(2), 89–103. https://doi.org/10.1109/tts.2020.2992344 Dostupno s https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9086771 Pristupano 06.09.2024.

[4] Jain, A., Ross, A., & Pankanti, S. (2006). Biometrics: a tool for information security. *IEEE Transactions on Information Forensics and Security*, *1*(2), 125–143. Dostupno s: http://130.18.86.27/faculty/warkentin/SecurityPapers/Leigh/ZafarClark2009%20Other%20References/JainRossPankanti2006_IEEETIFS1_2_Biometrics.pdf Pristupano 27.08.2024. Pristupano 06.09.2024.

[5] Kantayya, S. (Redateljica). (2020). *Coded Bias* [Film]. 7th Empire Media.

[6] *Papers with Code - LFW Dataset*. (n.d.). Dostupno s https://paperswithcode.com/dataset/lfw Pristupano 06.09.2024.

[7] Miteksystems. (2021). What is demographic bias in biometrics? *Miteksystems*. Dostupno s: https://www.miteksystems.com/blog/what-is-demographic-bias-in-biometrics Pristupano 27.08.2024. Pristupano 06.09.2024.

[8] MIT media lab, (06.11.2016.) The Coded Gaze: Unmasking Algorithmic Bias [video], YouTube. Dostupno s https://www.youtube.com/watch?v=162VzSzzoPs&t=1s Pristupano 09.09.2024.

[9] Ritter, R. S. (2020). Biometrics aren't inherently biased - we're training them wrong. *Forbes*. Dostupno s: https://www.forbes.com/councils/forbestechcouncil/2020/11/04/biometrics-arent-inherently-biased---were-training-them-wrong/ Pristupano 27.08.2024.

[10] Salvaro M, (2023.) Kako nadmudriti softver za prepoznavanje lica?, *Bug.hr*, Dostupno s: https://www.bug.hr/sigurnost/kako-nadmudriti-softver-za-prepoznavanje-lica-34152 Pristupano 04.09.2024.

[11] Terhörst, P., Kolf, J.N., Damer, N., Kirchbuchner, F. and Kuijper, A., (2020), Face quality estimation and its correlation to demographic and non-demographic bias in face recognition. Dostupno s https://arxiv.org/pdf/2004.01019 Pristupano 06.09.2024.

[12] Tolba A.S., El-Baz A.H., El-Harby A.H., (2006.), Face Recognition: A Literature Review, International Journal of Signal Processing, Dostupno s: https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=720ef31b8fb5076c861fa55f55456ccbc9174132 Pristupano 06.09.2024.

[13] Visage Technologies (2024) *Visage Technologies Software*. Dostupno s: https://visagetechnologies.com/demo/ Pristupano 06.09.2024.

[14] Wikipedia. (n.d.) Rasa (mrežna stranica) Dostupno s https://hr.wikipedia.org/wiki/Rasa Pristupano 05.09.2024.

Popis slika

Slika 1: Primjer biometrije lica (Visage Technologies, 2024.) 5
Slika 2: Algoritmi za biometriju (Drosdowski et al., 2020.) 6
Slika 3: Usporedba sličnosti osoba sa dvije slike (Visage Technologies, 2024) 10
Slika 4: Prepoznavanje spola, dobi i etničke pripadnosti (AI Face Detection, 2024.) 11
Slika 5: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)...13
Slika 6: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)...14
Slika 7: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)...15
Slika 8: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)...16
Slika 9: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.)...17
Slika 10: Primjer osoba koje (a) nisu, i (b) jesu bile prepoznate (AI Face Detection, 2024.).18
Slika 11: Podjela postotka pogrešaka po rasi i spolu 20
Slika 12: Kriva procjena spola (AI Face Detection, 2024.) 21
Slika 13: Nedostatak procjene spola (AI Face Detection, 2024.) 21
Slika 14: Točna procjena spola (Visage Technologies, 2024.).....22
Slika 15: Procjena starijeg lica u alatima a) Face Detection i b) Visage Technologies (2024.) 22
Slika 16: Kriva procjena spola i etničke pripadnosti (AI Face Detection, 2024.) 23

Popis tablica

Tablica 1: Pogreške pri prepoznavanja žena bijele rase 13
Tablica 2: Pogreške pri prepoznavanju muškaraca bijele rase 14
Tablica 3: Pogreške pri prepoznavanju žena crne rase 15
Tablica 4: Pogreške pri prepoznavanju muškaraca crne rase.....16
Tablica 5: Pogreške pri prepoznavanju žena mongoloidne rase 17
Tablica 6: Pogreške pri prepoznavanju muškaraca mongoloidne rase 18

Popis dijagrama

Dijagram 1: Postotak točnosti prepoznavanja lica.....19
Dijagram 2: Postotak pogrešaka po rasi i spolu 20

Slike korištene u alatima

[1] The New York Times, (n.d.), Jury Reaches Verdict in Johnny Depp-Amber Heard Trial: What to Know, Dostupno 05.09.2024. s https://www.nytimes.com/2022/04/21/arts/johnny-depp-amber-heard-trial.html

[2] Teatar.hr, , (n.d.), Mike Tyson, (mrežna straniac), Dostupno 05.09.2024. s https://www.teatar.hr/osobe/mike-tyson/

[3] Wikipedia, (n.d.), Alek Wek, (mrežna stranica), Dostupno 05.09.2024. s https://en.wikipedia.org/wiki/Alek_Wek