

# Usporedba algoritama za prepoznavanje lica

---

Jeger, Lorena

Master's thesis / Diplomski rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:137:056358>

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

Download date / Datum preuzimanja: **2024-08-08**



Repository / Repozitorij:

[Digital Repository Juraj Dobrila University of Pula](#)



Sveučilište Jurja Dobrile u Puli  
Fakultet informatike u Puli

**LORENA JEGER**

**USPOREDBA ALGORITAMA ZA PREPOZNAVANJE LICA**

Diplomski rad

Pula, rujan, 2022. godine

Sveučilište Jurja Dobrile u Puli  
Fakultet informatike u Puli

**LORENA JEGER**

**USPOREDBA ALGORITAMA ZA PREPOZNAVANJE LICA**

Diplomski rad

**JMBAG: 0303076169, redoviti student**

**Studijski smjer: Informatika**

**Predmet: Umjetna inteligencija**

**Znanstveno područje: Društvene znanosti**

**Znanstveno polje: Informacijske i komunikacijske znanosti**

**Znanstvena grana: Informacijski sustavi i informatologija**

**Mentor: Izv. prof. dr. sc. Darko Etinger**

Pula, rujan, 2022. godine



## IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani **Lorena Jeger**, kandidat za magistra **informatike** ovime izjavljujem da je ovaj Diplomski rad rezultat isključivo mogega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Diplomskog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

Lorena Jeger

U Puli, rujan, 2022. godine



IZJAVA  
o korištenju autorskog djela

Ja, **Lorena Jeger** dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj diplomski rad pod nazivom "**Usporedba algoritama za prepoznavanje lica**" koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.  
Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, 12.9.2022.g

Potpis

Lorena Jeger

## Sadržaj

1	Uvod	1
2	Računalni vid	2
3	Prepoznavanje lica	4
3.1	Struktura sustava za prepoznavanje lica	4
3.1.1	Detekcija lica	5
3.1.2	Prethodna obrada	5
3.1.3	Izdvajanje značajki	5
3.1.4	Prepoznavanje lica	5
3.2	Algoritmi za prepoznavanje lica	6
3.2.1	Eigenfaces	7
3.2.2	Fisherfaces	8
3.2.3	Histogrami lokalnih binarnih uzoraka (LBPH)	9
3.2.4	SVM	10
3.3	Ostali algoritmi za prepoznavanje lica	12
3.3.1	CNN	12
3.3.2	PCA	14
3.3.3	Haar Cascade	15
3.3.4	Trodimenzionalno prepoznavanje	15
3.3.5	TIR prepoznavanje lica	17
3.3.6	FaceNet	18
3.3.7	DeepFace	19
3.3.8	VGG model	20
3.4	Primjena prepoznavanja lica	20
3.5	Prednosti i nedostaci prepoznavanja lica	21
4	Implementacija algoritama	24
5	Usporedba algoritama	31
6	Zaključak	34
	Literatura	35
	Popis slika	44
	Popis tablica	45
	Sažetak	46
	Abstract	47

# 1 Uvod

Prepoznavanje lica je proces identifikacije ljudskog lica koje je prikazano na slici ili na videozapisu, sa slikama lica osoba koje su spremljene u bazi podataka. Sustavi za prepoznavanje lica mogu se koristiti za prepoznavanje ljudi u stvarnom vremenu, na videozapisima i na slikama.

Postoji mnogo različitih algoritama za prepoznavanje lica. U današnje vrijeme u praksi se određeni modeli kombiniraju zajedno kako bi se postigla veća prednost u prepoznavanju lica, to jest da bi se iskoristile prednosti oba modela.

Zadatak ovog rada bio je opisati i usporediti algoritme za prepoznavanje lica te implementirati iste. Opisat će se jedanaest različitih algoritama, od kojih će se implementirati četiri.

U drugom poglavlju bit će opisan računalni vid.

U sljedećem poglavlju će biti opisano prepoznavanje lica. Nabrojati će se i objasniti faze prepoznavanja lica. Bit će opisani najčešći algoritmi koji se koriste za prepoznavanje lica, kao i primjena te prednosti i nedostaci korištenja.

Četvrto poglavlje posvećeno je implementaciji samih algoritama.

U petom poglavlju će se prikazati rezultati ispitivanja ovog završnog rada. Točnije, prikazat će se usporedbe točnosti prepoznavanja lica različitih algoritama na malom skupu podataka.

## 2 Računalni vid

Računalni vid je polje umjetne inteligencije (eng. Artificial intelligence) koje omogućuje računalima i sustavima da izvuku značajne informacije iz digitalnih slika i videozapisa te poduzmu radnje ili daju preporuke na temelju tih informacija. (IBM, 2021.)

Uzimajući to u obzir, može se reći da računalni vid pruža mogućnost računalu da "vidi", to jest razumije što se nalazi na slici zahvaljujući digitalnim sustavima koji obrađuju, analiziraju i daju smisao vizualnim podacima na isti način kako to čine i ljudi.

Suvremeni računalni vid oslanja se na duboko učenje, specifičan podskup strojnog učenja, koji koristi algoritme za dobivanje uvida iz podataka. Strojno učenje, s druge strane, oslanja se na umjetnu inteligenciju, koja djeluje kao temelj za obje tehnologije.


Strojno učenje je tehnologija koja stroju daje mogućnost da na temelju svojih prošlih iskustava riješi problem koji mu je zadan. Strojno učenje je steklo značajan interes u različitim područjima pojavom jeftinije računalne snage i jeftinije memorije. Omogućuje obradu i analizu vrlo velike količine podataka kako bi se otkrili uvidi i korelacije između podataka koji nisu toliko očiti ljudskom oku. Strojno učenje zahtijeva strukturirane podatke i učenje iz označenih značajki.

Duboko učenje je potpodručje strojnog učenja koje se temelji na dubokim neuronskim mrežama. U dubokom učenju, umjetne neuronske mreže slične su ljudskim neuronima te se koriste za učenje i predviđanje. Umjetne neuronske mreže (eng. Artificial neural network) sastoje se od slojevite strukture algoritama. Upravo one omogućuju računalima da automatski izdvajaju, analiziraju i razumiju korisne informacije iz sirovih podataka oponašajući način na koji ljudi misle i uče. Može se reći da je duboko učenje skup tehnika koje su vođene neuronskim podacima na temelju automatskog procesa identifikacije značajki. Automatska identifikacija i učenje značajki iz ulaza je ono što ga čini točnijim i boljim.

Glavna razlika između strojnog učenja i dubokog učenja je u tehnici izdvajanja značajki na kojem radi klasifikator. Izvučene značajke dubokog učenja od nekoliko



nelinearnih skrivenih slojeva čine svoju klasifikaciju performanski daleko bolju od strojnog učenja koje se oslanja na ručno označavanje značajki. (Khan, 2021.)



Slika 1.: Razlika između strojnog učenja i dubokog učenja

Izvor: Hayder, et al., 2019.

Na slici 1. u području strojnog učenja uočljivo je da je proces izdvajanja značajki odvojen od ulaza. Od istraživača se traži da razrade i kreiraju zasebno izdvajanje značajki u slučaju strojnog učenja koristeći različite matematičke formulacije i znanstvena izračunavanja.

U slučaju dubokog učenja, metode i pristupi za izdvajanje značajki integrirani su zajedno, što duboko učenje čini preciznijim i pametnijim.

Biblioteke dubokog učenja mogu se koristiti za istraživanja i razvoj u raznim aplikacijama, uključujući detekciju lica, analizu letećih objekata, otkrivanje neovlaštenih slika, itd. (Hayder, Hayder, i Oday, 2019)

### 3 Prepoznavanje lica


Prepoznavanje lica označava identifikaciju ili potvrđivanje identiteta pojedinca pomoću njegovog lica. Sustavi za prepoznavanje lica mogu se koristiti za prepoznavanje ljudi u stvarnom vremenu, na videozapisima i na slikama. Tehnologija je sve više u svakodnevnoj upotrebi.

Prepoznavanje lica predstavlja izazovan problem, u području računalnog vida i analize slika. Prepoznavanje lica je biometrijski sustav koji se koristi za identifikaciju ili provjeru osobe s digitalne slike. Sustavi za prepoznavanje lica trebaju biti sposobni da automatski detektiraju lice na slici. To uključuje izdvajanje njegovih značajki i zatim njihovo prepoznavanje bez obzira na osvjetljenje, varijaciju u izrazima lica, poze, starenje, transformacije (rotiranje i skaliranje slike), što je jako težak i izazovan zadatak. (Parmar Divyarajsinh i Brijesh, 2014.)

#### 3.1 Struktura sustava za prepoznavanje lica

Sustavi za prepoznavanje lica koriste računalne algoritme za odabir specifičnih, prepoznatljivih detalja o licu osobe. Ti se detalji, poput udaljenosti između očiju ili oblika brade, zatim pretvaraju u vektor značajki i uspoređuju s podacima o drugim licima prikupljenima u bazi podataka za prepoznavanje lica. Podaci o određenom licu često se nazivaju otiskom/predloškom lica i razlikuju se od fotografije na način da su dizajnirani tako da uključuju samo određene detalje koji se mogu koristiti za razlikovanje jednog lica od drugog. (Electronic Frontier Foundation, 2017.)

Struktura prepoznavanja lica se sastoji od 3 faze koje su prikazane na slici 2.



Slika 2.: Struktura sustava za prepoznavanje lica

Izvor: Kortli i ostali, 2020.

### 3.1.1 Detekcija lica

Glavna funkcija prvog koraka je otkriti nalazi li se lice na slici koja je unesena.

Algoritmi za detekciju lica obično započinju traženjem ljudskih očiju, što je jedna od najlakših značajki za otkrivanje lica. Algoritam bi tada mogao pokušati otkriti obrve, usta, nos, nosnice i šarenicu. Nakon što algoritam zaključi da je pronašao područje lica, primjenjuje dodatne testove kako bi potvrdio da je zapravo otkrio lice. (Bernstein, 2002.)

### 3.1.2 Prethodna obrada

Neki autori posebno izdvajaju ovaj korak kao zasebnu cjelinu dok neki to smatraju integrirano s drugim korakom. U koraku naziva "prethodna obrada", mogu se ukloniti neželjeni šum, zamućenje, različiti uvjeti osvjetljenja, efekti sjenčanja korištenjem tehnika predobrade. Nakon dobivene "čiste slike" slijedi daljnji korak koji se naziva ekstrakcija značajki. (Kasar, Bhattacharyya i Kim, 2016.)

### 3.1.3 Izdvajanje značajki

Sljedeća faza prepoznavanja lica je sama analiza detektiranog lica u prvom koraku. Značajke lica mogu se izdvojiti pomoću algoritma za izdvajanje značajki u vektor značajki. Softver čita geometriju lica. Ključni čimbenici uključuju udaljenost između očiju, udaljenost od čela do brade, dubinu očnih duplji, oblik jagodica i konturu usana, ušiju i brade. Nakon toga slijedi pretvorba slike u podatke. Proces snimanja lica pretvara analogne informacije (lica) u skup digitalnih informacija (podataka) na temelju crta lica osobe. Analiza lica je pretvorena u matematičku formulu. Otisak lica je dobiven brojčani kod. Svaka osoba ima svoj jedinstven otisak lica. Nakon dobivenog vektora značajki, slijedi sljedeći korak. (Kaspersky, 2022.)

### 3.1.4 Prepoznavanje lica

Četvrti, ujedno i zadnji korak sustava za prepoznavanje lica, naziva se prepoznavanje lica. On predstavlja pronalazak podudaranja između analiziranog otiska lica i otiska lica koji se nalazi u bazi podataka.

Neki sustavi za prepoznavanje lica, umjesto da pozitivno identificiraju nepoznatu osobu, dizajnirani su za izračunavanje rezultata podudaranja vjerojatnosti između nepoznate osobe i određenih predložaka lica pohranjenih u bazi podataka. Ti će sustavi ponuditi nekoliko potencijalnih podudaranja, rangiranih po vjerojatnosti ispravne identifikacije, umjesto da samo vrte jedan rezultat. Unatoč sveprisutnosti prepoznavanja lica i poboljšanju tehnologije, podaci o prepoznavanju lica podložni su pogreškama. Prepoznavanje lica pogoršava se kako se povećava broj ljudi u bazi podataka. To je zato što velik broj ljudi na svijetu izgleda slično. Kako se povećava vjerojatnost sličnih lica, smanjuje se točnost podudaranja. (Electronic Frontier Foundation, 2017.)

Veliki izazov je i vrijeme. Kako se baza podataka povećava, linearno se povećava i vrijeme prepoznavanja što postaje veliko ograničenje.

### 3.2 Algoritmi za prepoznavanje lica

Umjetne neuronske mreže najpopularnija su i najuspješnija metoda u prepoznavanju slika. Algoritmi za prepoznavanje lica temelje se na matematičkim izračunima, a neuronske mreže izvode veliki broj matematičkih operacija istovremeno. Postoji niz algoritama i metoda za prepoznavanje lica. Iako svi imaju jedan cilj, mogu biti specifični ovisno o zadatku i problemu. Ovisno o namjeni upotrebe i okolnostima implementacije, kreću se od neuronskih mreža i matematičkih modela do tehnoloških rješenja privatnih tvrtki. (RecFaces, 2021.)

Algoritmi za prepoznavanje lica mogu u osnovi raditi na dva načina:

- Provjera autentičnosti slike lica: u osnovi uspoređuju ulaznu sliku lica sa slikom lica koja se odnosi na korisnika koji zahtijeva provjeru autentičnosti. To je u osnovi usporedba 1x1.
- Identifikacija ili prepoznavanje lica: u osnovi uspoređuju ulaznu sliku lica sa svim slikama lica iz skupa podataka s ciljem pronalaženja korisnika koji odgovara tom licu. To je u osnovi usporedba 1xN. (Salton do Prado, 1017.)

Postoje različite vrste algoritama za prepoznavanje lica. U praksi, kako bi se dobila bolja točnost, kombiniraju se različiti algoritmi. Najpoznatiji algoritmi su: Eigenfaces,

Fisherfaces, LBPH, SVM (Stroj potpornih vektora), CNN, PCA (Analiza glavnih komponenti), trodimenzionalno prepoznavanje, termalne kamere, FaceNet, DeepFace, itd.


### 3.2.1 Eigenfaces

Eigenfaces je metoda koja je korisna za prepoznavanje i detekciju lica određivanjem varijance lica u zbirci slika lica (skupovima slikovnih podataka). Korištenjem tih varijanci za kodiranje i dekodiranje lica na način strojnog učenja bez pune informacije, smanjuje se složenost izračuna i prostora. Prvi put su ga upotrijebili Turk i Pentland 1991. godine. Danas su njegove osnove još uvijek korisne za praksu iako ima ograničenja u usporedbi s današnjom tehnologijom. (Nev Acar, 2018.)

Skup vlastitih lica je skup "standardiziranih sastojaka lica" utvrđenih statističkom analizom velikog broja slika lica. Crtama lica dodijeljene su matematičke vrijednosti, jer ova metoda ne koristi digitalne slike već statističke baze podataka. Svako ljudsko lice kombinacija je ovih vrijednosti s različitim postocima.

Strategija Eigenfaces metode sastoji se od izdvajanja karakterističnih crta na licu predstavljajući lice kao linearnu kombinaciju takozvanih "sastojaka lica" eng. 'Eigenfaces', dobivenih iz značajki procesa ekstrakcije. Izračunavaju se glavne komponente lica u skupu za obuku. U procesu prepoznavanja, vlastito lice se formira za danu sliku lica, i izračunavaju se euklidske udaljenosti između ovog svojstvenog lica i prethodno pohranjenih svojstvenih lica. Ako je udaljenost dovoljno mala, osoba je identificirana. S druge strane, ako je udaljenost prevelika, slika se smatra onom koja pripada pojedincu za kojeg se sustav mora osposobiti. (Çarıkçı i Özen, 2012.)

Dijagram toka algoritma Eigenfaces prikazan je slici 3.



Slika 3.: Dijagram toka algoritma metode Eigenfaces

Izvor: Çarıkcı i Özen, 2012.

Neke od prednosti Eigenfacesa su sljedeće: neovisnost od geometrije lica, jednostavnost implementacije, mogućnost realizacije u stvarnom vremenu, jednostavnost i brzina prepoznavanja u odnosu na druge metode. Izazov metode prepoznavanja lica vlastitih lica je vrijeme izračunavanja. Ako je baza podataka velika, može potrajati neko vrijeme da dohvati identitet dotične osobe. Nedostatak je što je vrlo osjetljiv na uvjete osvjetljenja i položaj glave. (Çarıkcı i Özen, 2012.)

Postoji visoka korelacija između podataka o obuci i podataka o prepoznavanju. Točnost Eigenfacea ovisi o mnogim stvarima. Kako uzima vrijednost piksela kao usporedbu za projekciju, točnost bi se smanjivala s različitim intenzitetom svjetlosti. Osim toga, razmjer i orijentacija slike uvelike će utjecati na točnost. Za postizanje zadovoljavajućeg rezultata potrebna je prethodna obrada slike.

### 3.2.2 Fisherfaces

Fisherfaces je sličan Eigenfacesu, ali s poboljšanjem u boljoj klasifikaciji slike različitih klasa. Ovaj algoritam omogućava klasifikaciju seta za obuku tako što se bavi različitim ljudima i različitim izrazima lica. Samim time omogućava bolju preciznost u izrazu lica od Eigenfacesa. Ključna prednost ovog algoritma je njegova sposobnost interpolacije i ekstrapolacije u odnosu na varijacije osvjetljenja i izraza

lica. Fisherova linearna diskriminirajuća metoda (FLD) preslikava značajku na potprostore koji najviše razdvajaju dvije klase.

Za razliku od koncepta Eigenfacesa, metoda Fisherfaces pokušava maksimizirati omjer raspršenosti između klasa naspram raspršenosti unutar klase. Rezultat toga oblikuje projekcije tako da su udaljenosti između klasa maksimalne, dok su udaljenosti između uzoraka iste klase minimalne. Mogući nedostatak je ukoliko postoji veliko raspršivanje između klasa, onda bi raspršivanje unutar klase također moglo biti relativno velike vrijednosti. (Jaiswal, Bhadauria i Jadon, 2011.)

### 3.2.3 Histogrami lokalnih binarnih uzoraka (LBPH)

Ovaj algoritam koristi lokalne binarne uzorke (eng. Local Binary Pattern Histogram), jednostavan, učinkovit operator tekstone u računalnom vidu koji označava piksele na slici postavljanjem praga susjedstva svakog piksela i tretiranjem rezultata kao binarnog broja. U fazi učenja, LBPH algoritam stvara histograme za svaku sliku koja je označena i klasificirana. Svaki histogram predstavlja svaku sliku iz skupa za treniranje. Na taj način proces prepoznavanja podrazumijeva usporedbu histograma bilo koje dvije slike.

Za usporedbu histograma, to jest za izračunavanje udaljenosti dvaju histograma, postoje različiti pristupi, kao na primjer: euklidska udaljenost, hi-kvadrat, apsolutna vrijednost, itd. Algoritam vraća ID slike s najbližim histogramom (prije spremanja u bazu za svaku sliku treba definirati ID koji označava broj ili naziv osobe na slici) te također vraća izračunatu udaljenost koja se izražava kao mjera pouzdanosti. Niža pouzdanost označuje da je udaljenost između dva histograma bliža. (Salton do Prado, 2017.)


LBPH je jedan od najjednostavnijih algoritama za prepoznavanje lica, vrlo je jednostavan za implementaciju. LBPH može prepoznati i bočne i prednje strane lica te na njega ne utječu varijacije osvjetljenja što znači da je fleksibilniji. Vjerojatno će raditi bolje od Fisherfacesa te može predstavljati lokalne značajke na slikama. Otporan je na monotone transformacije sivih ljestvica. U LBPH-u svaka se slika analizira neovisno, dok metode Eigenfaces i Fisherfaces promatraju skup podataka kao cjelinu. Omogućuje ga OpenCV knjižnica (eng. Open Source Computer Vision

Library). Također, točnost prepoznavanja ovisi o definiranim skupovima podataka za treniranje i testiranje. (Yashwant, 2020.)

### 3.2.4 SVM

Support Vector Machine (SVM) je nadzirani model strojnog učenja koji se koristi za probleme klasifikacije u dvije grupe. Nakon davanja SVM modela skupa označenih podataka o obuci za svaku kategoriju, oni mogu kategorizirati nove podatke testa. SVM klasificira podatke na temelju ravnine koja maksimizira marginu. Granica odluke SVM-a je ravna. SVM je jako dobar algoritam za klasifikaciju slika. (Javed, 2020.)

Linearni SVM koristi se za linearno odvojive podatke, što znači da ako se skup podataka može klasificirati u dvije klase pomoću jedne ravne crte, tada se takvi podaci nazivaju linearno odvojivi podaci, a klasifikator se koristi kao linearni SVM klasifikator.




Slika 4.: Linearni SVM

Izvor: Javatpoint, 2021.

Nelinearni SVM se koristi za nelinearno odvojene podatke, što znači da ako se skup podataka ne može klasificirati pomoću ravne crte, tada se takvi podaci nazivaju nelinearnim podacima, a korišteni klasifikator naziva se nelinearni SVM klasifikator. U slučaju nelinearnog SVM-a, dodaje se treća dimenziju  $Z$ . Određuje se optimalna



hiper-ravnina, međutim, budući da se onda korisnik nalazi u 3D prostoru, mora ga pretvoriti u 2D prostor. U većini slučajeva hiper-ravnina u slučaju nelinearnih podataka, postaje opseg radijusa. (Javatpoint, 2021.)



Slika 5.: Nelinearni SVM

Izvor: Javatpoint, 2021.

Kod prepoznavanja lica, SVM koristi načelo klasifikacije s dvije skupine za razlikovanje lica od "ne-lica". Za svaku kategoriju, SVM model prima označeni skup podataka za obuku za kategorizaciju novih podataka testa. Istraživači primjenjuju linearne i nelinearne SVM modele obuke za prepoznavanje lica. Nedavna istraživanja pokazuju da nelinearni stroj za vježbanje ima veću marginu i bolje rezultate prepoznavanja i klasifikacije. (RecFaces, 2021.)

Support Vector Machine (SVM) je binarna klasifikacijska metoda, a prepoznavanje lica je problem klase K gdje je K broj poznatih pojedinaca. Svrha SVM-a je tražiti optimalnu hiper-ravninu razdvajanja koja minimizira rizik od pogrešne klasifikacije. Nakon pristojne količine obuke, SVM-ovi mogu predvidjeti spada li ulaz u jednu od dvije kategorije. To se postiže konstruiranjem hiper-ravnine u visoko dimenzionalnom prostoru i zatim mapiranjem ulaznih podataka u točke u ovom prostoru. Modeli za prepoznavanje lica pronalaze razlike između dvije slike lica u prostoru razlika. Formulira se prepoznavanje lica kao dvoklasni problem kojem su klase razlike između lica iste osobe i različitih ljudi. Promjenom interpretacije

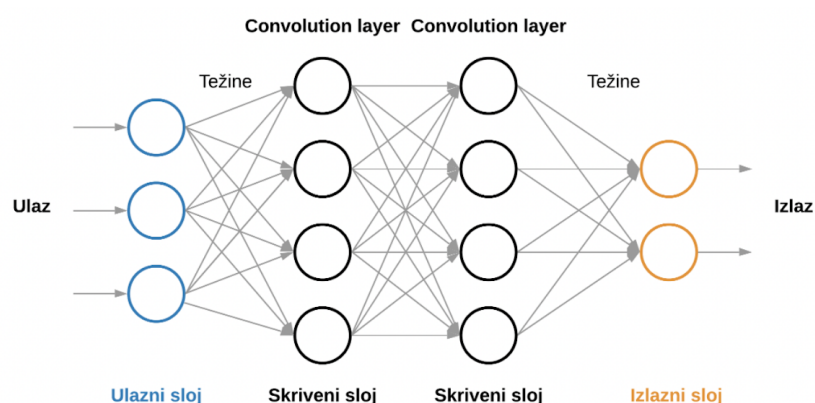
površine odluke koju generira SVM, generira se metrika sličnosti između lica koja se uči iz primjera razlike između lica. Algoritam temeljen na SVM-u uspoređuje se s algoritmom koji se temelji na analizi glavnih komponenti (PCA) na težem skupu slika. (Bhashkar, 2020.)

### 3.3 Ostali algoritmi za prepoznavanje lica

#### 3.3.1 CNN

Konvolucijska neuronska mreža (eng. Convolutional neural network) je jedna od vrsta neuronske mreže. S konceptualnog stajališta izgleda kao normalna neuronska mreža, a jedina razlika su posebni slojevi koji se nazivaju konvolucijski slojevi. CNN može imati desetke i stotine ovih slojeva, a svaki od njih uči otkrivati različite značajke slike.

Za razliku od potpuno povezanih slojeva, u kojima je svaki neuron povezan sa svim neuronima iz prethodnog sloja, neuroni konvolucijskog sloja primaju ulaz samo od onih u svojem receptivnom polju. To prisiljava ekstrakciju lokalne značajke i smanjuje broj naučenih parametara. (Hrga, 2017.)



Slika 6.: Prikaz konvolucijske neuronske mreže

Izvor: Šajina, Convolutional neural networks - Magic behind image classification

Kako se svi slojevi mogu trenirati, nema potrebe za izradom alata za izvlačenje značajki ručno. Prvi slojevi će izdvojiti jednostavne karakteristike (prisutnost kontura) koje će sljedeći slojevi kombinirati kako bi formirali sve složenije i apstraktnije koncepte: sklopove kontura u uzorke, uzorke u dijelove objekata, dijelove objekata u objekte, itd. CNN-ovi dizajnirani su za automatsko izdvajanje karakteristika ulaznih slika.

Neuroni u konvolucijskom sloju su organizirani u karte značajki. Svi neuroni u karti značajki izvode isti rad na različitim dijelovima slike i na dijeljenju iste težine. Umjesto množenjem matrice, težine se izračunavaju savijanjem konvolucijskog sloja sa skupom lokalnih filtara. (Šajina, 2019.)

Slažeći aktivacijske mape svih filtara, dobiva se izlazni volumen konvolucijskog sloja. Kontroliranje izlaznog volumena određuju tri parametra: dubina (engl. depth), korak (engl. stride) i dopunjavanje (engl. padding). Dubina označava broj filtara, korak označava broj za koliko se elemenata slike pomiče filter, a dopunjavanje označava veličinu koja definira koliko su puta popunjeni rubovi ulaznog podatka s nulama. (Blog XRDS, 2020.)

U praksi često dolazi do prenaučivosti modela. Model na podacima treninga ima visoku točnost, međutim, na drugim podacima ima lošiju točnost. Prilikom izbjegavanja prenaučivosti modela, koriste se regulacije i optimizira se rad neuronske mreže. (Nitish et al., 2014.)

Prenaučivost modela može se izbjeći povećanjem podataka za treniranje. Trening podaci se mogu povećati augmentacijom. To znači da se za svaku sliku u treningu napravi neka od transformacija (zumiranje, zrcaljenje, rotacija).

Najjednostavniji način "obrane" od prenaučivosti modela je u točno vrijeme zaustaviti proces treniranja dok nije došlo do pojave prenaučivosti.

Izbjegavanje prenaučivosti modela može se postići i mijenjanjem stope učenja (eng. learning rate).

Stopa učenja je parametar koji određuje do koje će mjere nove težine zamijeniti stare težine. Ispravnim odabirom može se izbjeći predugo trajanje učenja. (Zulkifli, 2018.)

Za računanje ažuriranja težina koristi se učenje s unutrašnjim rasprostiranjem (eng. Backpropagation). Backpropagation koristi optimizaciju baziranu na gradijentima. (Kingma et al., 2014.)

Batch size određuje koliko će se podataka provesti kroz mrežu odjedanput, a njegova veličina određuje koliko brzo će model odraditi svaku epohu. Epoha označava prolazak svih trening podataka kroz mrežu. Optimalnim će izborom te veličine ubrzati učenje i izbjeći da se model ne može generalizirati nad podacima koje nije vidio. (Deeplizard, 2017.)

### 3.3.2 PCA

Analiza glavnih komponenti (eng. Principal component analysis) je algoritam strojnog učenja koji se široko koristi u istraživačkoj analizi podataka i za izradu prediktivnih modela. Obično se koristi za smanjenje dimenzionalnosti projiciranjem svake podatkovne točke na samo prvih nekoliko glavnih komponenti kako bi se dobili niži dimenzionalni podaci uz očuvanje što je moguće veće varijacije podataka. Metoda smanjenja broja značajki (smanjenje dimenzionalnosti podataka) je stvaranje novih značajki izdvajanjem važnih informacija i ispuštanjem onih najmanje važnih. Na taj se način neće izgubiti podaci, nego će biti smanjene značajke, ali i manje šanse za prenamjenu modela.

Cilj PCA-a je zamjena koreliranih vektora velikih dimenzija nekoreliranim vektorima manjih dimenzija, a drugi cilj je izračunati osnovu za skup podataka. (Çarıkçı i Özen, 2012.)

Ideja iza njega je linearno projicirati izvorne podatke na niži dimenzionalni potprostor nudeći glavnim komponentama (vlastitim vektorima) maksimalnu varijaciju projiciranih podataka i/ili minimalnu pogrešku izobličenja od projekcija. (Nev Acar, 2018.)

Kao što je već rečeno, kada se koristi u procesu prepoznavanja lica, PCA nastoji smanjiti veličinu izvornih podataka uz očuvanje najrelevantnijih informacija. Generira skup ponderiranih vlastitih vektora koji, zauzvrat, grade svojstvena lica - opsežne skupove različitih slika ljudskih lica. Linearna kombinacija vlastitih lica predstavlja svaku sliku u skupu za obuku. PCA se koristi za primanje ovih vlastitih vektora iz matrice kovarijance skupa slika za obuku. Za svaku sliku izračunavaju se njezine

glavne komponente. Ostale komponente kodiraju manje razlike između lica i šuma. Proces prepoznavanja uključuje usporedbu glavne komponente nepoznate slike s komponentama svih ostalih slika.

Glavne prednosti PCA su njegova niska osjetljivost na šum, smanjenje zahtjeva za memorijom i kapacitetom te povećanje učinkovitosti zbog rada u prostoru manjih dimenzija. (Çarıkçı i Özen, 2012.)

### 3.3.3 Haar Cascade

Haar Cascade je algoritam strojnog učenja u kojem se klasifikator izvlači iz velikog broja pozitivnih i negativnih fotografija. Pozitivne slike su one slike koje u sebi sadrže lice, a negativne slike su slike koje ne sadrže sliku lica. (Rashad et al., 2021.)

Algoritam su iznijeli Paul Viola i Michael Jones u svojem istraživačkom radu "Rapid Object Detection using a Boosted Cascade of Simple Features", objavljenom 2001. godine.

Kaskadni klasifikatori temeljeni na Haar značajkama su klasifikatori implementirani za detekciju objekata. Klasifikator prati postupak strojnog učenja u kojem se kaskadna operacija uvodi iz fotografija kako bi se otkrile stavke na dodatnim fotografijama. Prepoznavanje lica i izrazi lica na slici također se uspješno otkrivaju. Vježba se završava davanjem pozitivnih i negativnih slika klasifikatoru. Zatim se karakteristike izvlače iz slike. Svaka karakteristika je pojedinačna vrijednost, koja se dobiva oduzimanjem zbroja piksela u bijeloj boji pravokutnika iz zbrajanja piksela u crnom pravokutniku u kojem klasifikator detektira lica različitih pojedinaca u različitim okruženjima. Značajka slična Haaru bilo koje veličine može se izračunati u stalnom vremenu zbog integralnih slika. (Shetty, et al., 2021.)


Metoda je korištena u identifikaciji kriminalaca u kombinaciji s algoritmom lokalnog binarnog uzorka za prepoznavanje lica. Haar kaskadni klasifikator koristi 200 (od 6000) značajki, što osigurava stopu prepoznavanja od 85-95% čak i s različitim izrazima. (RecFaces, 2021.)

### 3.3.4 Trodimenzionalno prepoznavanje

Brza evolucija 3D senzora omogućava značajan napredak prilikom prepoznavanja lica.

3D prepoznavanje lica nasljeđuje prednosti tradicionalnog 2D prepoznavanja lica, kao što su prirodni proces prepoznavanja i širok raspon primjena. 3D sustavi za prepoznavanje lica mogu točno prepoznati ljudska lica pri slabom svjetlu i s raznim varijacijama, položajima i izrazima lica, gdje bi u takvim uvjetima 2D sustavi za prepoznavanje lica imali ogromne poteškoće u radu.

Kako radi 3D algoritam za prepoznavanje lica, prikazano je na slici 7. 3D prepoznavanje dijeli se u dvije faze: trening i testiranje. U fazi treninga prikupljaju se 3D podaci o licu, a zatim se prethodno obrađuju kako bi se dobila "čista" 3D lica. Zatim se podaci obrađuju algoritmima za izdvajanje značajki kako bi se pronašle značajke koje bi se mogle koristiti za razlikovanje lica. Značajke svakog lica zatim se pohranjuju u bazu podataka značajki. U fazi testiranja, ciljno lice prolazi kroz faze akvizicije, predobrade i ekstrakcije značajki koje su identične fazama u fazi treninga. U fazi podudaranja značajki, značajke ciljanog lica uspoređuju se s licima pohranjenima u bazi podataka o značajkama i izračunavaju se rezultati podudaranja. Kada je rezultat podudaranja dovoljno visok, ciljno lice je prepoznato. (Zhou i Xiao, 2018.)



Slika 7.: 3D sustav za prepoznavanje lica

Izvor: Zhou i Xiao, 2018.

Postoji nekoliko problema sa 3D prepoznavanjem lica. U nekontroliranom okruženju, 3D prepoznavanje može dovesti do toga da određeni dijelovi lica ne budu snimljeni jer mogu biti prekriveni kosom ili zbog kape na glavi, sunčanih naočala, itd. Nedostupnost ovih 3D podataka o licu uzrokovana je okluzijom vanjskih objekata. Tijekom procesa skeniranja, zbog nefrontalne poze lica otkrivene osobe, neki dijelovi lica možda neće biti snimljeni, što rezultira pogrešnim podacima i to se naziva unutarnjom okluzijom.

U 3D prepoznavanju lica, promjena položaja glave može značajno utjecati na točnost 3D prepoznavanja lica. Mnogi 3D sustavi za prepoznavanje lica oslanjaju se na model prednjeg lica. Ako glava nije u uspravnoj poziciji ili se orijentacija lica zarotira od prednje poze, sustav ima poteškoća da uskladi skeniranje lica s unaprijed postavljenim modelima lica. (Zhou i Xiao, 2018.)

### 3.3.5 TIR prepoznavanje lica

Toplinsko infracrveno prepoznavanje lica (eng. Thermal Infrared Face Recognition) postaje sve popularnije kako tehnologija toplinskog snimanja postaje jeftinija i dostupnija potrošačima.

Temperatura kože lica usko je povezana s donjim krvnim žilama, a uzorak krvnih žila ispod kože može se izdvojiti dobivanjem termalne karte ljudskog lica. Izvođenjem morfoloških operacija, poput otvaranja i segmentacije vrha kako bi se dali toplinski potpisi, može se postići ekstrakcija toplinske značajke iz slika lica.

Dosljedne značajke mogu se definirati kao značajke koje su prisutne u tri ili više toplinskih potpisa sa slika snimljenih u različito vrijeme. Toplinski potpisi se zatim mogu izdvojiti iz svake slike, a proces ekstrakcije toplinskog potpisa podijeljen je u četiri glavna dijela. Ti dijelovi obuhvaćaju segmentaciju lica, uklanjanje šuma, morfologiju slike i naknadnu obradu. Individualni toplinski potpisi variraju iz dana u dan zbog vježbe, temperature okoline, zdravlja pojedinca, težine, sobne temperature snimanja i drugih čimbenika. Zbog ovih čimbenika koji mogu utjecati na toplinski potpis, preporuča se uspostaviti predložak toplinskog potpisa koji zadržava

karakteristike u toplinskom potpisu pojedinca koje su dosljedne tijekom vremena. Generiranje predloška toplinskog potpisa zahtjeva uzimanje ekstrahiranih termalnih potpisa za svakog pojedinca i njihovo zbrajanje. Time se stvara slika koja je sastavljena od višestrukih, različitih ekstrakcija potpisa. Zadržat će se značajke koje su prisutne na svim slikama kao dominantne značajke koje mogu najbolje definirati individualni potpis.

Kao što je već rečeno, s obzirom na velika istraživanja koja su već provedena u području TIR prepoznavanja lica, zaključuje se da se dugovalni infracrveni valovi mogu koristiti za izradu toplinskih slika karata obilježja lica i vaskularnih karata lica kako bi se identificirali pojedinci. Ova tehnologija obećava da će biti održiva alternativa metodama i tehnologijama prepoznavanja lica vidljivim svjetlom, čime se omogućuje da se kritična funkcija prepoznavanja lica izvodi neovisno o uvjetima ambijentalnog osvjetljenja. Nadalje, zbog detaljnije i veće količine crta lica koje se mogu otkriti s TIR-om, očekuje se da će ova metoda razlikovati kvantitativno dostupne crte lica u usporedbi s prepoznavanjem lica vidljivim svjetlom. Slike se mogu snimiti toplinskim senzorima u potpunom mraku. (Weidlich, 2021.)

Korištenje termalne metode u prepoznavanju lica ima jako veliku prednost zato što šminka, dlake na licu, šeširi i naočale ne utječu na njegovu točnost. Štoviše, razlikuje braću i sestre blizance.

### 3.3.6 FaceNet

FaceNet je sustav za prepoznavanje lica kojeg su razvili Googleovi istraživači 2015. godine. Temelji se na dubokoj konvolucijskoj mreži i gubitku trojki, osposobljavanju za izvođenje podataka o obuci, ali proces treninga zahtijeva složeno računanje i dugo vremena.

Temelji se na referentnim skupovima podataka za prepoznavanje lica. Pokazuje izvrsne rezultate u provođenju istraživanja, performansi testiranja i točnosti u usporedbi s drugim algoritmima razvijenima ranije. FaceNet precizno izdvaja ugradnje lica, visokokvalitetne značajke koje se koriste za obuku sustava za identifikaciju lica u kasnijim fazama. (Recfaces, 2021.)

FaceNet je metoda koja koristi duboku konvolucijsku mrežu kako bi se optimiziralo njegovo ugrađivanje u usporedbi s korištenjem srednjih slojeva uskog grla kao test




prethodnih dubokih pristupa učenju. Ova metoda se zove jednokratno učenje. Metoda može koristiti mali uzorak slika lica za izradu početnog modela, a kada postane novi model, početni model se može koristiti bez prekvalifikacije. FaceNet izravno trenira lice koristeći Euklidski prostor gdje se udaljenost sastoji od sličnosti između modela lica. Kada se rezultati sličnosti između modela lica podudaraju, moguće je na lakši način provesti prepoznavanje lica i klasifikaciju pomoću korištenog FaceNeta gdje oni postaju vektori značajki. U procesu treninga FaceNet primjenjuje trojke po usklađivanju licem u lice. Trojka se sastoji od zbirke sidrene slike, gdje se svaka slika sastoji od pozitivne i negativne slike. Na slici 8. vidi se mreža FaceNet. FaceNet se sastoji od batch ulaznog sloja i dubokog CNN-a nakon čega slijedi L2 normalizacija, koja rezultira ugradnjom lica. Nakon toga slijedi gubitak trojki tijekom treninga (slika 9). Metode treninga gubitka trojki imaju tri glavna elementa: sidro, pozitivno i negativno. Slika 9. prikazuje trostruki gubitak. Trostruki gubitak minimizira udaljenost između sidra i pozitivno, od kojih sidro i pozitivno imaju isti identitet. Zatim maksimizira udaljenost između sidra i negativno za drugačiji identitet. (Maheswari, et al., 2020.)



Slika 8.: Struktura FaceNet-a

Izvor: Schroff, et al., 2015.



Slika 9.: Trostruki gubitak

Izvor: Schroff, et al., 2015.

Prednost korištenja FaceNet metode je da model zahtijeva minimalno poravnanje u smislu prilično čvrstog rezanja područja lica. Nedostatak FaceNeta je što je izvedba treninga prilično teška zbog korištenja CPU-a. (Rachmawanto, et al., 2020.)

### 3.3.7 DeepFace

DeepFace je razvio Facebook koristeći 3D modeliranje lica. Koristili su afinu transformaciju kako bi izvukli prednju stranu lica. Prepoznavanje je napravljeno pomoću duboke neuronske mreže koja koristi iste težine za dva različita ulaza kako bi se izračunao usporedivi izlaz. Jedan ulaz čini osnovicu koji je prije izračunat i s kojim se onda uspoređuje drugi izlaz. (Taigman, et al., 2014.)

### 3.3.8 VGG model

VGG (eng. Visual Geometry Group) sastoji se od blokova, gdje je svaki blok sastavljen od slojeva konvolucijskih i potpuno povezanih slojeva. VGG dolazi u dva modela: VGG16 i VGG19.

VGG16 je model konvolucijske neuronske mreže sa 16 slojeva koji su predložili A. Zisserman i K. Simonyan sa Sveučilišta u Oxfordu. Ovi su istraživači objavili svoj model u istraživačkom radu pod naslovom "Duboke konvolucijske mreže za prepoznavanje slika velikih razmjera". (Boesch, 2021.)

## 3.4 Primjena prepoznavanja lica

Mnogi moderni uređaji koriste metode prijave različite od standardnog korisničkog imena i lozinke ili sustava PIN brojeva. Biometrija se koristi za identifikaciju i autorizaciju određenih korisnika u borbi protiv kibernetičkih kriminalaca. Metode kao što su prepoznavanje glasa, skeniranje otisaka prstiju i prepoznavanje lica razvile su se i implementirale u mnoge uređaje; osobne i javne. (Mitchell i Shing, 2018.)

Prepoznavanje lica u današnjem svijetu je u svakodnevnoj upotrebi. Razni telefoni koriste prepoznavanje lica za otključavanje uređaja. Agencije za provedbu zakona sve češće koriste prepoznavanje lica u rutinskom policijskom radu. Prepoznavanje lica postalo je uobičajen prizor na mnogim zračnim lukama diljem svijeta. Sve veći broj putnika ima biometrijske putovnice, koje im omogućuju da preskoče uobičajeno duge redove i umjesto toga prođu kroz automatiziranu kontrolu e-putovnice kako bi

brže stigli do ulaza. Biometrijsko internetsko bankarstvo još je jedna prednost prepoznavanja lica. Sve je veći napredak zabilježen i u području zdravstva. U Kini poslodavci prate prisutnost radnika na radnim mjestima putem skeniranja lica prilikom dolaska i odlaska na posao. Automobilske tvrtke eksperimentiraju s prepoznavanjem lica kako bi zamijenili ključeve automobila. Tehnologija bi zamijenila ključ za pristupano pokretanje automobila te zapamtila vozačeve preferencije za položaje sjedala i zrcala te unaprijed podešene radijske postaje.

Kao što je vidljivo, postoji svakodnevna primjena prepoznavanja lica u raznim područjima.

Tehnologije za prepoznavanje lica redovito razvijaju Google, Apple, Facebook, Amazon i Microsoft. Facebook je razvio 2014. godine DeepFace, a u lipnju 2015. godine Google je postao bolji s FaceNetom. (Thales, 2021.)

FaceNet se koristi u Google fotografijama za sortiranje slika i za automatsko označavanje fotografija na kojima se prepoznaje lice osobe. FaceNet koristi skup podataka "označena lica u divljini" (eng. Labelled Faces in the Wild) koji je javno mjerilo za provjeru lica. (Recfaces, 2021.)

Facebook je počeo koristiti prepoznavanje lica u SAD-u 2010. godine, kada je automatski označio ljude na fotografijama koristeći svoj alat za prijedloge oznaka. Alat skenira lice korisnika i nudi prijedloge o tome tko je ta osoba. 2019. godine Facebook je uključio tu značajku kao dio nastojanja da se više usredotoči na privatnost i također pruža informacije o tome kako je moguće uključiti se ili isključiti za prepoznavanje.

### 3.5 Prednosti i nedostaci prepoznavanja lica

Najveća prednost je biometrijsko prepoznavanje. Biometrijsko prepoznavanje odnosi se na automatsko prepoznavanje pojedinaca na temelju vektora značajki. Biometrijski sustavi prepoznavanja trebali bi pružiti povećanu sigurnost prilikom prepoznavanja lica za potvrdu ili određivanja identiteta pojedinca. Primjene takvog sustava uključuju sigurnost računalnih sustava, sigurno elektroničko bankarstvo, mobilne telefone, kreditne kartice, siguran pristup zgradama, zdravstvenim i socijalnim uslugama. Korištenjem biometrije, osoba se može

identificirati na temelju "tko je on/ona", a ne na temelju "što on/ona ima" (kartica, token, ključ) ili "što on/ona zna" (lozinka, PIN). (Delač i Grgić, 2014.)

U tablici 1. su prikazane prednosti i nedostaci koje tehnologija prepoznavanja lica omogućava. U nastavku će se detaljnije objasniti svaka.

Tablica 1.: Prednosti i nedostaci korištenja tehnologija za prepoznavanje lica

Prednosti	Nedostaci
Povećana sigurnost	Kršenje privatnosti
Smanjen kriminal	Nadzor
Veća udobnost	Opseg za pogrešku
Brza i učinkovita provjera identiteta	Ogromna pohrana podataka

Potreba za pouzdanom identifikacijom i autorizacijom u kontroli pristupa rezultiralo je povećanim interesom za biometriju koja bi zamijenila lozinku i identifikacijsku (ID) karticu. Lozinka i osobna iskaznica lako se mogu probiti jer se lozinka može otkriti neovlaštenom korisniku, a osobna iskaznica može biti ukradena. Pojavom biometrije ti su problemi riješeni. Za prepoznavanje identiteta osobe može se koristiti biometrija koja koristi ljudske značajke kao što su šarenica, mrežnica, lice, otisak prsta, dinamika pisanja i govor. Biometrijski podaci imaju prednost u odnosu na tradicionalne sigurnosne metode budući da se ne mogu lako ukrasti ili podijeliti. (Mitchell i Shing, 2018.)

Prepoznavanje lica olakšava pronalaženje provalnika, lopova i prijestupnika. Osim fizičke sigurnosti, prednosti ima i kibernetička sigurnost.

Korištenje prepoznavanja lica zajedno sa sveprisutnim video kamerama, umjetnom inteligencijom i analitikom podataka, stvara potencijal za masovni nadzor, što bi moglo ograničiti slobodu pojedinca.

Pitanje etike i privatnosti je najspornije u ovoj tehnologiji. Poznato je da vlade pohranjuju slike građana bez njihovog pristanka. Europska komisija je 2020. godine odlučila da će razmatrati zabranu tehnologije prepoznavanja lica u javnim prostorima do pet godina, kako bi se omogućilo vrijeme za izradu regulatornog okvira za sprječavanje privatnosti i etičkih zlouporaba.

Softver za prepoznavanje lica oslanja se na tehnologiju strojnog učenja, koja zahtijeva ogromne skupove podataka da bi se "učili" za isporuku točnih rezultata. Tako veliki skupovi podataka zahtijevaju robusnu pohranu podataka. (Kaspersky, 2022.)

Dva najveća problema prepoznavanja lica su problem sa osvjetljenjem i problem poze koji onda dovode do mogućnosti opsega pogreške. Podaci o prepoznavanju lica ne sadrže pogreške, što bi moglo dovesti do toga da ljudi budu upleteni u zločine koje nisu počinili. Na primjer, mala promjena kuta kamere ili promjena izgleda, kao što je nova frizura, može dovesti do pogreške.

## 4 Implementacija algoritama

Ovaj rad ima za cilj usporediti algoritme za prepoznavanje lica uspoređujući njihovu točnost na malom skupu podataka. Veliki problem današnjice je kako izvršiti ispitivanje i predviđanje na malom skupu podataka. Potaknut člankom pod nazivom "Mali podaci također su ključni za strojno učenje" autora Husanjot Chahal i Helen Toner, diplomski rad za ideju obrađuje prepoznavanje lica maksimizirajući podatke lica kad je prisutan mali skup podataka te je rad s ono malo podataka ograničen.

Implementirani su sljedeći algoritmi: Eigenfaces, Fisherfaces, LBPH i SVM.

Moderniji algoritmi prepoznavanja lica nisu implementirani zbog ograničenih resursa.

Algoritmi Eigenfaces, Fisherfaces i LBPH su algoritmi za prepoznavanje lica dostupni unutar knjižnice OpenCV2, koja je namijenjena područjima računalnog vida i strojnog učenja. Korišteni programski jezik je Python, alat je Visual Studio Code.

Prilikom detekcije lica korišteni su sljedeći detektori...

U algoritmima Eigenfaces, Fisherfaces i LBPH, za detekciju lica korišten je Haar Cascade koji dolazi sa cv2 knjižicom. Također, u CV2 knjižici postoji i LBP Cascade koji radi bržu detekciju lica na slikama, međutim, prilikom detekcije lica na testnom skupu imao je lošije rezultate.

```
face_cascade =  
cv2.CascadeClassifier('opencv-files/haarcascade_frontalface_alt.xml')
```

U SVM modelu za detekciju lica korišten je HOG.

```
28     if dir_name.startswith("."): continue  
29     subject_dir_path = data_folder_path + "/" + dir_name  
30     subject_images_names = os.listdir(subject_dir_path) (function) face_locations: (img: Any, number_of_times_to_upsample: int = 1, model: str = "hog") ->  
31     for image_name in subject_images_names: #za svak list[tuple[int, Any, Any, int]]  
32  
33         if image_name.startswith("."): #ignor Returns an array of bounding boxes of human faces in a image
```

```
def detect_face(img):  
  
    gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)  
    face_cascade = cv2.CascadeClassifier('opencv-files/haarcascade_frontalface_alt.xml')  
    faces = face_cascade.detectMultiScale(gray, scaleFactor=1.2, minNeighbors=5)  
    if (len(faces) == 0):  
        return None, None  
    (x, y, w, h) = faces[0]  
  
    return gray[y:y+w, x:x+h], faces[0]
```

U gore prikazanoj funkciji pod nazivom `detect_face` vidljivo je da funkcija prima sliku kao parametar. Slika se mora pretvoriti u sivu sliku budući da `openCV` recognizer tako očekuje. `Face_cascade` je definiran sljedećom linijom: `cv2.CascadeClassifier`. Korišten je Haar Cascade koji je sporiji od LBP Cascade, ali je točniji. Dalje je korištena metoda `detectMultiScale` za otkrivanje svih lica na slici. `Faces` sadržava popis svih lica koja su detektirana. Ako lice nije definirano, vraća originalnu sliku. Lica koja vraća `detectMultiScale` su zapravo pravokutnici dimenzija (x, y, širina, visina), a ne slike stvarnih lica. Potrebno je izdvojiti područje slike lica iz glavne slike. U predzadnjoj liniji izvlači se područje lica pod pretpostavkom da je na slici jedno lice. Izdvaja se područje lica iz sive slike. Funkcija vraća područje slike lica i pravokutnik lica.

```
def prepare_training_data(data_folder_path):
    i=0
    dirs = os.listdir(data_folder_path)
    faces = []
    labels = []

    for dir_name in dirs:

        if dir_name.startswith("."): continue
        if(i == 0): print("null indeks")
        print("i:", i)
        name = dir_name
        subjects.append(name)
        i_string= str(i)
        label = int(dir_name.replace(name, i_string))
        subject_dir_path = data_folder_path + "/" + dir_name
        subject_images_names = os.listdir(subject_dir_path)

        for image_name in subject_images_names:

            if image_name.startswith("."): continue
            image_path = subject_dir_path + "/" + image_name
            image = cv2.imread(image_path)
            cv2.imshow("Training on image...", cv2.resize(image, (width_d, height_d)))
            cv2.waitKey(100)
            face, rect = detect_face(image)
            if face is not None:
                faces.append(cv2.resize(face, (width_d, height_d)))
                labels.append(label)

        i += 1
    cv2.destroyAllWindows()
    cv2.waitKey(1)
    cv2.destroyAllWindows()

    return faces, labels, subjects
```

Funkcija naziva `prepare_training_data` prima jedan parametar koji označava trening skup. Budući da face recognition očekuje da mu vektor oznaka bude niz, postavlja se varijabla `i = 0` te samim tim `labels` sadrži vrijednosti integera. Sukladno tome, model predviđa i vraća labelu u numeričkoj vrijednosti za svaku osobu. `Faces` je lista u kojoj se spremaju sva lica. `Labels` je lista u kojoj se spremaju sve labele. Vanjska for petlja prolazi kroz sve mape osoba u trening mapi i sprema naziv pojedinih mapa u listu "subjects". `Dir_name` označava naziv mape pojedine osobe. Unutarnja for petlja prolazi kroz svaku sliku u `subject_images_names`. Drugim riječima, prolazi kroz sve slike pojedine osobe u njenoj mapi. `Image_path` označava putanju te slike. Nakon spremljene putanje, čita se slika na istoj. Zatim se poziva funkcija za detekciju lica koja je gore objašnjena i prosljeđuje joj se trenutna slika. Ako lice nije `None`, to jest ako je pronađeno lice, dodaje se u listu "faces" te se dodaje labela za to lice.

Dolje navedeni kod prikazuje *face\_recognizere* koji su se koristili za prepoznavanje lica u algoritmima.

```
face_recognizer = cv2.face.EigenFaceRecognizer_create()
face_recognizer = cv2.face.FisherFaceRecognizer_create()
face_recognizer = cv2.face.LBPHFaceRecognizer_create()
```

```
clf = svm.SVC(gamma='scale')
clf.fit(faces, names)
```

Nakon što je kreiran *face\_recognizer*, prosljeđuje mu se polje lica i numpy polje labele budući da *face\_recognizer* očekuje da mu vektor oznaka bude niz.

```
face_recognizer.train(faces, np.array(labels))
```

Dolje su prikazane dvije funkcije, `draw_rectangle` i `draw_text`. `Draw_rectangle` služi za crtanje pravokutnika, a `draw_text` služi za pisanje imena.



```

# Funkcija za crtanje pravokutnika
def draw_rectangle(img, rect):
    (x, y, w, h) = rect
    cv2.rectangle(img, (x, y), (x+w, y+h), (0, 0, 255), 2)

#Funkcija za pisanje imena
def draw_text(img, text, x, y):
    cv2.putText(img, text, (x, y), cv2.FONT_HERSHEY_PLAIN, 2, (255, 255, 255), 1)

```

Funkcija `predict` prepoznaje osobu danu na slici koju prima kao parametar i crta pravokutnik oko otkrivenog lica s imenom. Stvara se kopija slike kako bi se sačuvao original te se detektira lice na kopiji slike. Ako lice nije otkriveno, vraća se `None`. U suprotnom, ako je lice detektirano, radi se *resize* slike s obzirom na to da Fisherfaces traži da su sve slike iste veličine. Nakon toga slijedi predviđanje predikcije pomoću *face\_recognizera* koji je treniran na trening skupu. U "label\_text-u" dobiva se odgovarajući naziv kojeg vraća `face_recognizer`. Nakon toga na slici se crta pravokutnik oko detektiranog lica pozivajući funkciju `draw_ractangle` te nakon toga se poziva i funkcija "draw\_text". Funkcija vraća sliku (koja je kopija od originalne i sadrži pravokutnik i ime predviđene osobe) i predviđeno ime.

```

def predict(test_img, predvideno_ime):

    img = test_img.copy()
    face, rect = detect_face(img)

    if face is None or rect is None :
        return None, None

    else:
        face = cv2.resize(face, (width_d, height_d))
        label, confidence = face_recognizer.predict(face)
        label_text = subjects[label]
        predvideno_ime=label_text
        draw_rectangle(img, rect)
        draw_text(img, label_text, rect[0], rect[1]-5)
        return img, predvideno_ime

```

Prolazeći se kroz svaku sliku u testnom skupu i promatra se što je predikcija vratila. Ako je predikcija vratila None to znači da lice nije detektirano, a ako je rezultat predikcije različit od None, znači da je lice detektirano. U polje “y\_test” dodaje se naziv slike testa koji se prethodno prilagodi, a u polje “y\_pred” dodaje se predviđeno ime dobiveno predikcijom. Na kraju for petlje, poziva se classification report.

```
#Pozivanje funkcije predviđanja na testnom skupu
print("Predikcija slika u tijeku...")
start_time = datetime.now() #sluzi da prikaz trajanja vremena

data_folder_path='test-data'
dirs = os.listdir(data_folder_path)
nazivi=[]
y_test= []
y_pred= []
for slika in dirs:
    if slika.startswith("."): #ignoriraj system files like .DS_Store
        continue
    name= slika
    subjects.append(nazivi)

    img_path= data_folder_path + "/" + name
    img = cv2.imread(img_path, cv2.IMREAD_COLOR)
    predvideno_ime=""
    predict_img, predvideno_ime=predict(img, predvideno_ime)

    if(predict_img is None):
        ne_detektirano_lice= ne_detektirano_lice +1
    else:
        detektirao_lice=detektirao_lice+1
        cv2.imshow("Predvidam na testu", cv2.resize(predict_img, (400, 500)))
        tocnost= usporedbaImena(name, predvideno_ime)
        y_test.append(''.join([i for i in name.replace(" ", "").split(".")].casefold()).replace("_", "").replace("test", "") if not i.isdigit()))
        y_pred.append(predvideno_ime.replace(" ", "").replace("_", "").casefold()))

cv2.waitKey(100)

end_time = datetime.now()
print('Vrijeme predikcije: {}'.format(end_time - start_time))

print("Classification_report")
print(classification_report(y_test, y_pred))
```

Prilikom dobivanja točnosti korišten je klasifikacijski izvještaj kojeg omogućava sklearn.metrics.

```
from sklearn.metrics import classification_report
```

Točnost je definirana kao:


$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Slika 10.: Formula točnosti

Izvor: Almbady i Elrefaei, 2019.

, gdje je TP stopa točno pozitivnih (eng. true positives), TN stopa točno negativnih (eng. true negatives), FN stopa lažno negativnih (eng. false negatives) te FP stopa lažno pozitivnih (eng. false positives). (Almabdy i Elrefaei, 2019.)

Na slici 11. prikazane su vrijednosti TP, FP, FN i TN u konfuzijskoj matrici.



Slika 11.: Vrijednosti TP, FP, FN i TN u konfuzijskoj matrici

Izvor: MA, et al., 2019.

Opoziv (eng. Recall) predstavlja činjenicu da je udio pravih pozitivnih instanci u zbroju pravih pozitivnih i lažno negativnih. (Almabdy i Elrefaei, 2019.)

Opoziv je definiran sljedećom formulom:

$$\text{Recall} = \frac{TP}{TP + FN}$$

Slika 12.: Formula opoziva

Izvor: Almabdy i Elrefaei, 2019.

Preciznost (eng. Precision) predstavlja udio pravih pozitivnih instanci prema svim pozitivnim instancama. (Almabdy i Elrefaei, 2019.)

Preciznost se izračunava pomoću formule:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

Slika 13.: Formula preciznosti

Izvor: Almabdy i Elrefaei, 2019.

U klasifikacijskom izvještaju kojeg omogućava sklearn metrics nailazi se još na F1 mjeru koja se naziva i F mjera. F mjera može se tumačiti kao harmonijska sredina preciznosti i prisjećanja, pri čemu F mjera postiže svoju najbolju vrijednost pri 1, a najgori rezultat pri 0 (scikit-learn, f1\_score). F mjera se definira sljedećom formulom:

$$F1 = 2 * (\text{precision} * \text{recall}) / (\text{precision} + \text{recall})$$

Slika 14.: Formula F mjere

Izvor: Scikit-learn, f1\_score

Implementacija koda je dostupna na sljedećem linku:  
<https://github.com/LorenaJeger/PrepoznavanjeLica>

## 5 Usporedba algoritama

Ovaj diplomski rad ima za cilj usporediti postojeće algoritme za prepoznavanje lica. U tablici usporedbe je prikazana usporedba točnosti prepoznavanja lica.

Računalo na kojem je izvršen eksperiment sadrži sljedeće komponente: M1 čip, 8 core CPU, 7 core GPU, 16 giga RAM-a.

Tablica 2.: Usporedba točnosti prepoznavanja lica u sljedećim algoritmima

Algoritam/ metrike	Točnost prepoznavanja
Eigenfaces	49,0 %
Fisherfaces	68,0 %
LBPH	54,0 %
SVM	95,0 %

Na slici 15. je vidljivo kako je algoritam Eigenfaces postigao točnost prepoznavanja lica u iznosu od 49%.

	precision	recall	f1-score	support
anapalacio	0.00	0.00	0.00	1
andreagassi	0.33	0.33	0.33	3
angelabasset	1.00	0.50	0.67	2
angelamerkel	0.00	0.00	0.00	1
angelinajolie	0.00	0.00	0.00	4
elvispresley	0.50	1.00	0.67	1
lleytonhewitt	0.33	0.50	0.40	2
lorenajeger	0.82	0.82	0.82	11
ramizraja	1.00	1.00	1.00	1
robertzoellick	0.50	1.00	0.67	1
sarahjessicaparker	0.50	1.00	0.67	1
timhenman	1.00	0.50	0.67	2
tomcruise	1.00	0.33	0.50	3
tommyfranks	0.00	0.00	0.00	0
tommyhaas	0.00	0.00	0.00	0
vladimirputin	0.00	0.00	0.00	4
accuracy			0.49	37
macro avg	0.44	0.44	0.40	37
weighted avg	0.55	0.49	0.49	37

Slika 15.: Klasifikacijski izvještaj modela Eigenfaces

Na slici 16. je vidljivo kako je algoritam Fisherfaces postigao točnost prepoznavanja lica u iznosu od 68%.

	precision	recall	f1-score	support
anapalacio	0.00	0.00	0.00	1
andreagassi	0.75	1.00	0.86	3
angelabassett	1.00	0.50	0.67	2
angelamerkel	0.00	0.00	0.00	1
angelinajolie	0.50	0.25	0.33	4
elvispresley	1.00	1.00	1.00	1
lleytonhewitt	0.50	0.50	0.50	2
lorenajeger	0.85	1.00	0.92	11
ramizraja	1.00	1.00	1.00	1
robertzoellick	1.00	1.00	1.00	1
sarahjessicaparker	0.00	0.00	0.00	1
timhenman	0.25	0.50	0.33	2
tomcruise	1.00	0.67	0.80	3
tommyfranks	0.00	0.00	0.00	0
vladimirputin	0.67	0.50	0.57	4
accuracy			0.68	37
macro avg	0.57	0.53	0.53	37
weighted avg	0.70	0.68	0.67	37

Slika 16.: Klasifikacijski izvještaj modela Fisherfaces

Na slici 17. je vidljivo kako je algoritam LBPH postigao točnost prepoznavanja lica u iznosu od 54%.

	precision	recall	f1-score	support
anapalacio	0.00	0.00	0.00	1
andreagassi	1.00	0.67	0.80	3
angelabassett	1.00	1.00	1.00	2
angelamerkel	1.00	1.00	1.00	1
angelinajolie	1.00	0.50	0.67	4
elvispresley	0.25	1.00	0.40	1
lleytonhewitt	0.00	0.00	0.00	2
lorenajeger	1.00	0.36	0.53	11
ramizraja	0.07	1.00	0.13	1
robertzoellick	1.00	1.00	1.00	1
sarahjessicaparker	1.00	1.00	1.00	1
timhenman	1.00	0.50	0.67	2
tomcruise	1.00	1.00	1.00	3
vladimirputin	1.00	0.25	0.40	4
yanmartel	0.00	0.00	0.00	0
accuracy			0.54	37
macro avg	0.69	0.62	0.57	37
weighted avg	0.87	0.54	0.61	37

Slika 17.: Klasifikacijski izvještaj modela LBPH

Na slici 18. je vidljivo kako je algoritam SVM postigao točnost prepoznavanja lica u iznosu od 95%.

	precision	recall	f1-score	support
anapalacio	1.00	1.00	1.00	1
andragassi	1.00	1.00	1.00	3
angelabassett	1.00	1.00	1.00	2
angelamerkel	0.00	0.00	0.00	1
angelinajolie	1.00	1.00	1.00	4
elvispresley	1.00	1.00	1.00	2
lleytonhewitt	1.00	1.00	1.00	2
lorenajeger	0.93	1.00	0.96	13
ramizraja	1.00	1.00	1.00	1
robertzoellick	0.00	0.00	0.00	1
sarahjessicaparker	1.00	1.00	1.00	1
timhenman	0.67	1.00	0.80	2
tomcruise	1.00	1.00	1.00	3
vladimirputin	1.00	1.00	1.00	4
accuracy			0.95	40
macro avg	0.83	0.86	0.84	40
weighted avg	0.91	0.95	0.93	40

Slika 18.: Klasifikacijski izvještaj modela SVM

Usporedbom algoritama nailazi se na sljedeći problem- uviđa se lošija točnost prepoznavanja lica u algoritmima Eigenfaces, Fisherfaces i LBPH. Kroz daljnje sljedeće razdoblje bi trebalo utvrditi zašto je to tako.

## 6 Zaključak

Uspoređujući literaturu raznih autora dolazi se do sljedećih zaključaka. Metoda LBPH je bolja u svojem radu od Fisherfaces metode u različitim okruženjima i svjetlosnim uvjetima. LBPH operator otporan je na monotone transformacije sivih ljestvica. Fisherfaces sprječava osobine osobe da postanu dominantne, ali i dalje smatra varijacije osvjetljenja korisnom značajkom. Međutim, varijacija svjetla nije korisna značajka za izdvajanje jer nije dio stvarnog lica. Fisherfaces zahtijeva veću pohranu podataka o licu i više vremena obrade u prepoznavanju. U LBPH-u svaka se slika analizira neovisno, dok metoda Eigenfaces i Fisherfaces promatra skup podataka kao cjelinu. LBPH može prepoznati lica s prednje, ali i s bočne strane. SVM je binarna klasifikacijska metoda, a prepoznavanje lica je problem klase  $K$  gdje je  $K$  broj poznatih pojedinaca. Svrha SVM-a je tražiti optimalnu hiper-ravninu razdvajanja koja minimizira rizik od pogrešne klasifikacije. Algoritam SVM rezultira visokom točnošću prepoznavanja lica uključujući i slučajeve na malim skupovima podataka, međutim zahtijeva daleko veće vrijeme izvođenja. U istraživačkim radovima autori primjenjuju linearne i nelinearne SVM modele obuke za prepoznavanje lica. Nedavna istraživanja pokazuju da nelinearni stroj za vježbanje ima veću marginu i bolje rezultate prepoznavanja i klasifikacije. Algoritam temeljen na SVM-u autori uspoređuju s algoritmom PCA koji se temelji na analizi glavnih komponenti.

Fisherfaces i LBPH traže da su sve slike iste veličine što predstavlja nedostatak u odnosu na Eigenfaces. Najbolji za detekciju lica se pokazao HOG. Uspješno je detektirao sva lica na cijelom skupu testnih slika. Haar Cascade ima veći broj detektiranih lica u odnosu na LBP Cascade, međutim, dosta je spor u odnosu na LBP Cascade. Haar Cascade nije uspješno detektirao lice na tri slike u testu.

Uspoređujući Eigenfaces, Fisherfaces, LBPH i SVM na malom skupu podataka, slijedi zaključak da najbolju točnost prepoznavanja ima SVM algoritam. Eigenfaces, Fisherfaces i LBPH imaju malu točnost prepoznavanja lica na malim skupovima podataka. Međutim, uspoređujući ta tri modela, zaključuje se da Fisherfaces radi najbolje od ta tri modela. U daljnjem razdoblju bilo bi poželjno utvrditi zašto Eigenfaces, Fisherfaces i LBPH rade lošije na manjem skupu podataka te zašto u mojem slučaju Fisherfaces radi bolje od LBPH metode.



## Literatura

1. Babich, N., (2020.) What Is Computer Vision & How Does it Work? An Introduction, internet stranica: <https://xd.adobe.com/ideas/principles/emerging-technology/what-is-computer-vision-how-does-it-work/> , pristupano: 9.4.2022.
2. IBM, (2021.) What is computer vision? Internet stranica: <https://www.ibm.com/topics/computer-vision>, pristupano: 9.4.2022.
3. Khan, P i ostali, (2021.) Machine Learning and Deep Learning Approaches for Brain Disease Diagnosis: Principles and Recent Advances. IEEE Access. 9. 37622 - 37655. 10.1109/ACCESS.2021.3062484. Internet stranica: [https://www.researchgate.net/publication/349643727\\_Machine\\_Learning\\_and\\_Deep\\_Learning\\_Approaches\\_for\\_Brain\\_Disease\\_Diagnosis\\_Principles\\_and\\_Recent\\_Advances](https://www.researchgate.net/publication/349643727_Machine_Learning_and_Deep_Learning_Approaches_for_Brain_Disease_Diagnosis_Principles_and_Recent_Advances), pristupano: 9.4.2022.
4. Hayder, N., Hayder,A., i Oday, H., (2019.) AN EFFECTIVE IMPLEMENTATION OF FACE RECOGNITION USING DEEP CONVOLUTIONAL NETWORK. Xinan Jiaotong Daxue Xuebao/Journal of Southwest Jiaotong University. 54. 10.35741/issn.0258-2724.54.5.29., Internet stranica: [https://www.researchgate.net/figure/Key-Demarcation-Points-in-Deep-Learning-and-Machine-Learning\\_fig4\\_337306950](https://www.researchgate.net/figure/Key-Demarcation-Points-in-Deep-Learning-and-Machine-Learning_fig4_337306950) ,pristupano 9.4.2022
5. Hayder, A. i ostali (2019.) Improved Approach for Identification of Real and Fake Smile using Chaos Theory and Principal Component Analysis. Journal of Southwest Jiaotong University. 54. 1-11. 10.35741/issn.0258-2724.54.5.20. Internet stranica: [https://www.researchgate.net/figure/Difference-between-Machine-Learning-and-Deep-Learning\\_fig4\\_338585724](https://www.researchgate.net/figure/Difference-between-Machine-Learning-and-Deep-Learning_fig4_338585724) , pristupano: 9.4.2022
6. SmleaseDesign, Machine Learning vs Deep Learning What is the difference, Internet stranica: <https://www.smlease.com/entries/technology/machine-learning-vs-deep-learning-what-is-the-difference-between-ml-and-dl/> , pristupano: 9.4.2022.

7. Parmar, Divyarajsinh N. i Brijesh B., (2014.) Face Recognition Methods & Applications Internet stranica: <https://arxiv.org/abs/1403.0485> , pristupano:13.4.2022.
8. Zhao, W., Chellappa, R., Phillips, P. J., i Rosenfeld, A. (2003). Face recognition: A literature survey. *ACM computing surveys (CSUR)*, 35(4), 399-458.
9. Nazeer, S., Omar, N. i Khalid, M., (2007) Sustav za prepoznavanje lica koristeći pristupano umjetnim neuronskim mrežama, 2007. *Međunarodna konferencija o obradi signala, komunikacijama i umrežavanju* , 2007., str. 420-425, doi: 10.11207/IC74.3.5. Internet stranica: <https://ieeexplore.ieee.org/abstract/document/4156656>, pristupano: 13.4.2022.
10. Kortli i ostali, (2020.) Comparative Study of Face Recognition Approaches. 300-305. 10.1109/IC\_ASET49463.2020.9318305. Internet stranica: [https://www.researchgate.net/figure/Face-recognition-structure-3-21\\_fig3\\_348641437](https://www.researchgate.net/figure/Face-recognition-structure-3-21_fig3_348641437), pristupano: 13.4.2022.
11. Kasar, M., M. , Bhattacharyya, D. i Kim, T., (2016.) Face Recognition Using Neural Network: A Review, Internet stranica: [https://www.researchgate.net/profile/Manisha-Kasar/publication/301727666\\_Face\\_Recognition\\_Using\\_Neural\\_Network\\_A\\_Review/Internet\\_stranica:s/5ef18af5a6fdcc73be96ccc2/Face-Recognition-Using-Neural-Network-A-Review.pdf](https://www.researchgate.net/profile/Manisha-Kasar/publication/301727666_Face_Recognition_Using_Neural_Network_A_Review/Internet_stranica:s/5ef18af5a6fdcc73be96ccc2/Face-Recognition-Using-Neural-Network-A-Review.pdf), pristupano: 13.4.2022.
12. Kamenskaya, E. i Kukharev, G., (2022) Some aspects of automated psychological characteristics recognition from the facial image. Internet stranica: [https://www.researchgate.net/publication/255565371\\_Some\\_aspects\\_of\\_automated\\_psychological\\_characteristics\\_recognition\\_from\\_the\\_facial\\_image](https://www.researchgate.net/publication/255565371_Some_aspects_of_automated_psychological_characteristics_recognition_from_the_facial_image) ,Pristupano: 13.4.2022.
13. Le, T., H. (2011.) Applying Artificial Neural Networks for Face Recognition. *Advances in Artificial Neural Systems*. 2011. 10.1155/2011/673016. Internet stranica: [https://www.researchgate.net/figure/Structure-of-a-face-recognition-system\\_fig16\\_258380240](https://www.researchgate.net/figure/Structure-of-a-face-recognition-system_fig16_258380240), Pristupano 13.4.2022.

14. RecFaces, (2021.) Understanding Facial Recognition Algorithms, Internet stranica: <https://recfaces.com/articles/facial-recognition-algorithms>, Pristupano: 19.4.2022.
15. Šajina, Romeo, (2019) Convolutional neural networks - Magic behind image classification, Internet stranica: <https://github.com/RomeoSajina/AI-Tutorials/blob/master/CNN%20-%20Magic%20behind%20image%20classification/CNN%20-%20Magic%20behind%20image%20classification.ipynb>, pristupano: 19.4.2022.
16. Hrga, I., (2017.) Deep Image Captioning: Models, Data and Evaluation, Internet stranica: [https://www.inf.uniri.hr/images/studiji/poslijediplomski/kvalifikacijski/Hrga\\_Ingrid\\_Kvalifikacijski\\_rad.pdf](https://www.inf.uniri.hr/images/studiji/poslijediplomski/kvalifikacijski/Hrga_Ingrid_Kvalifikacijski_rad.pdf) , pristupano: 26.4.2022.
17. Said, Y., Barr, M., Ahmed, H.,E., (2020.) Design of a Face Recognition System based on Convolutional Neural Network (CNN) Internet stranica: <https://etasr.com/index.php/ETASR/article/view/3490/2236>, pristupano: 26.4.2022.
18. Peng, L., Song,B. i Xu, S., (2021) Human face recognition based on convolutional neural network and augmented dataset, Systems Science & Control Engineering, 9:sup2, 29-37, DOI: 10.1080/21642583.2020.1836526, Internet stranica: <https://www.tandfonline.com/doi/full/10.1080/21642583.2020.1836526> , pristupano: 26.4.2022.
19. Nev Acar, (2018.) Eigenfaces: Recovering Humans from Ghosts,izvor: <https://towardsdatascience.com/eigenfaces-recovering-humans-from-ghosts-17606c328184>, pristupano: 26.4.2022.
20. Çarıkçı, M., Özen, F., (2012.) A Face Recognition System Based on Eigenfaces Method Internet stranica: <https://www.sciencedirect.com/science/article/pii/S2212017312000242> , pristupano: 28.4.2022.

21. Zhang, S. i Turk, M. (2008.) Scholarpedia, Eigenfaces Internet stranica: <http://www.scholarpedia.org/article/Eigenfaces> , pristupano: 28.4.2022.
22. Jaiswal, S., Bhadauria, S.,S., i Dr. Jadon,R.,S., (2011.) COMPARISON BETWEEN FACE RECOGNITION ALGORITHM-EIGENFACES, FISHERFACES AND ELASTIC BUNCH GRAPH MATCHING Internet stranica: <https://www.rroij.com/open-access/comparison-between-face-recognition-algorithm-eigenfaces-fisherfaces-and-elastic-bnch-graph-matching-187-193.php?aid=37590> ,pristupano: 28.4.2022.
23. Javed, M., (2020.) Building a Facial Recognition Model using PCA & SVM Algorithms, Internet stranica: <https://towardsdatascience.com/building-a-facial-recognition-model-using-pca-svm-algorithms-c81d870add16>, Pristupano: 28.4.2022.
24. Javatpoint, (2021.) Support Vector Machine Algorithm, Internet stranica: <https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm> pristupano: 29.4.2022.
25. RecFaces, (2021.) Understanding Facial Recognition Algorithms, Internet stranica: <https://recfaces.com/articles/facial-recognition-algorithms>, Pristupano 29.4.2022.
26. Jonathon, P. , Support Vector Machines Applied to Face Recognition, internet stranica: <https://proceedings.neurips.cc/paper/1998/file/a2cc63e065705fe938a4dda49092966f-Paper.pdf>, pristupano: 29.3.2022.
27. Sang-Ki, i ostali, (2010.) SVM-based feature extraction for face recognition, internet stranica: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.1086.2363&rep=rep1&type=pdf>, pristupano: 29.4.2022.
28. Rashad J. Rasras, i ostali (2021.) Developing digital signal clustering method using local binary pattern histogram Int. J. Electric. Comput. Eng. (IJECE), Vol. 11 (1) (February 2021), pp. 872-878

29. Shetty, A. I ,i ostali, (2021.) Facial recognition using Haar cascade and LBP classifiers, Internet stranica: <https://www.sciencedirect.com/science/article/pii/S2666285X21000728> , Pristupano: 29.4.2022.
30. Zhou, S., Xiao, S, (2018.) 3D face recognition: a survey. Hum. Cent. Comput. Inf. Sci. 8, 35 (2018). Internet stranica: <https://doi.org/10.1186/s13673-018-0157-2> , Pristupano: 29.04.2022.
31. Weidlich, V.,A, (2021.) Thermal Infrared Face Recognition. Cureus. 13(3):e13736. Published 2021 Mar 6. doi:10.7759/cureus.13736, Internet stranica: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8021210/> , Pristupano: 29.04.2022.
32. Salton do Prado, K., (2017.) Face Recognition: Understanding LBPH Algorithm, Internet stranica: <https://towardsdatascience.com/face-recognition-how-lbph-works-90ec258c3d6b>, Pristupano: 30.4.2022.
33. Yashwant, (2020.) LBPH algoritam za prepoznavanje lica, Internet stranica: <https://iq.opengenus.org/lbph-algorithm-for-face-recognition/> Pristupano: 30.4.2022.
34. Rachmawanto, R.,I.,M. i ostali (2020.) Study Analysis of Human Face Recognition using Principal Component Analysis. 55-60. 10.1109/iSemantic50169.2020.9234250. Internet stranica: [https://www.researchgate.net/profile/De-Rosal-Ignatius-Moses-Setiadi/publication/346417651\\_Study\\_Analysis\\_of\\_Human\\_Face\\_Recognition\\_using\\_Principal\\_Component\\_Analysis/Internet\\_stranica:s/605a0218458515e83467c633/Study-Analysis-of-Human-Face-Recognition-using-Principal-Component-Analysis.pdf](https://www.researchgate.net/profile/De-Rosal-Ignatius-Moses-Setiadi/publication/346417651_Study_Analysis_of_Human_Face_Recognition_using_Principal_Component_Analysis/Internet_stranica:s/605a0218458515e83467c633/Study-Analysis-of-Human-Face-Recognition-using-Principal-Component-Analysis.pdf) Pristupano: 30.4.2022.
35. Schroff,F., Kalenichenko, D., Philbin,J., (2015.) FaceNet: A Unified Embedding for Face Recognition and Clustering, Internet stranica: [https://www.cv-foundation.org/openaccess/content\\_cvpr\\_2015/papers/Schroff\\_FaceNet\\_A\\_Unified\\_2015\\_CVPR\\_paper.pdf](https://www.cv-foundation.org/openaccess/content_cvpr_2015/papers/Schroff_FaceNet_A_Unified_2015_CVPR_paper.pdf) Pristupano: 30.4.2022.

36. RecFaces, (2021.) Understanding Facial Recognition Algorithms, Internet stranica: <https://recfaces.com/articles/facial-recognition-algorithms#14> , pristupano: 30.4.2022.
37. RecFaces, (2021.) How Facial Recognition Works: Technology Explained in Detail, internet stranica: <https://recfaces.com/articles/how-facial-recognition-works>, pristupano: 30.4.2022.
38. Kaspersky, (2022.) What is Facial Recognition, Internet stranica: <https://www.kaspersky.com/resource-center/definitions/what-is-facial-recognition>, Pristupano: 1.5.2022.
39. OpenCV, Face Recognition with OpenCV, Internet stranica: [https://docs.opencv.org/3.4/da/d60/tutorial\\_face\\_main.html](https://docs.opencv.org/3.4/da/d60/tutorial_face_main.html), Pristupano: 17.5.2022.
40. Rosebrock, A., (2018.) OpenCV Face Recognition, Internet stranica: <https://pyimagesearch.com/2018/09/24/opencv-face-recognition/> pristupano: 17.5.2022.
41. Bhashkar, K., (2020.) Face Recognition: Real-Time Face Recognition System using Deep Learning Algorithm and Raspberry Pi 3B, Internet stranica: <https://bhashkarkunal.medium.com/face-recognition-real-time-webcam-face-recognition-system-using-deep-learning-algorithm-and-98cf8254def7> , Pristupano: 10.06.2022.
42. Krizhevsky,A., Sutskever, I., Hinton, G. E., (2012.) ImageNet Classification with Deep Convolutional Neural Network, University of Toronto, Kanada, Internet stranica: <https://www.cs.toronto.edu/~fritz/absps/imagenet.pdf> Pristupano: 2.7.2022.
43. Nitish, H., Hinton, C. G., Krizhevsky, A., Sutskever, I. i Salakhutdinov, R., (2014.) Dropout: A Simple Way to Prevent Neural Networks from overfitting, Journal of Machine Learning Research, No. 1, Vol. 15, pp. 1929–1958, 2014
44. Zulkifli, H. , (2018.) Understanding Learning Rates and How It Improves Performance in Deep Learning, Towards Data Science, January 2018, Internet stranica:

- <https://towardsdatascience.com/understanding-learning-rates-and-how-it-improve-sperformance-in-deep-learning-d0d4059c1c10> , Pristupano: 2.7.2022.
45. Kingma, D. P. i Ba, J., (2014.) Adam: A Method for Stochastic Optimization, December 2014, Internet stranica: <https://arxiv.org/abs/1412.6980> , Pristupano: 2.7.2022.
46. Deeplizard, (2017.) Batch Size in a Neural Network explained, November 2017, Internet stranica: <https://deeplizard.com/learn/video/U4WB9p6ODjM> , Pristupano: 2.7.2022.
47. Blog XRDS, (2020.), Convolutional Neural Networks (CNNs): An Illustrated Explanation, Internet stranica: <https://blog.xrds.acm.org/2016/06/convolutional-neural-networks-cnns-illustrated-explanation/> Pristupano: 2.6.2022.
48. Sladić, A. i ostali, (2022.) Određivanje kompleksnosti glazbenog žanra pomoću generativnih modela neuronskih mreža
49. Taigman, Y., Yang, M., Ranzato, M. A. i Wolf, L., (2014.) DeepFace: Closing the Gap to HumanLevel Performance in Face Verification, IEEE Conference on Computer Vision and Pattern Recognition, 2014, Internet stranica: [https://zpaschal.net/cvpr2014/Taigman\\_DeepFace\\_Closing\\_the\\_2014\\_CVPR\\_paper.pdf](https://zpaschal.net/cvpr2014/Taigman_DeepFace_Closing_the_2014_CVPR_paper.pdf) , Pristupano: 2.7.2022.
50. Parkhi, O. M., Vedaldi, A., Zisserman, A., (2015.) Deep face recognition, BMVC, Vol. 1, pp. 6, 2015, Internet stranica: <https://www.robots.ox.ac.uk/~vgg/publications/2015/Parkhi15/parkhi15.pdf> , Pristupano: 2.7.2022.
51. Thales, (2021.) Facial recognition, Internet stranica: <https://www.thalesgroup.com/en/markets/digital-identity-and-security/government/biometrics/facial-recognition> Pristupano: 4.7.2022.
52. Ageitgey, Face\_recognizer, Internet stranica: [https://github.com/ageitgey/face\\_recognition](https://github.com/ageitgey/face_recognition) , pristupano: 1.6.2022.

53. Rosebrock, A., (2021.) OpenCV Eigenfaces for Face Recognition, Internet stranica:  
<https://pyimagesearch.com/2021/05/10/opencv-eigenfaces-for-face-recognition/> ,  
pristupano: 1.6.2022.
54. Özdil, A. i Özbilen, M., M. (2014.) "A survey on comparison of face recognition algorithms," 2014 IEEE 8th International Conference on Application of Information and Communication Technologies (AICT), 2014, pp. 1-3, doi: 10.1109/ICAICT.2014.7035956. Internet pristup: <https://ieeexplore.ieee.org/abstract/document/7035956>, Pristup: 4.7.2022.
55. Boesch, (2021.) VGG vrlo duboke konvolucijske mreže (VGGNet) – Što trebate znati, internet pristup: <https://viso.ai/deep-learning/vgg-very-deep-convolutional-networks/>, pristup: 5.7.2022.
56. Mitchell, C. i Shing, C., (2018.) Discussing Alternative Login Methods and Their Advantages and Disadvantages, 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), 2018, pp. 1353-1356, doi: 10.1109/FSKD.2018.8687163. Internet Pristup: <https://ieeexplore.ieee.org/abstract/document/8687163>, Pristup: 5.7.2022.
57. Delač, K. i Grgić, M., (2004.) Pregled metoda biometrijskog prepoznavanja", Zbornik radova. Elmar-2004. 46. međunarodni simpozij o elektronicima u pomorstvu, 2004., str. 184-193. internet pristup: <https://ieeexplore.ieee.org/abstract/document/1356372>, pristup: 5.7.2022.
58. Electronic Frontier Foundation, (2017.) Face Recognition, internet pristup: <https://www.eff.org/pages/face-recognition>, Pristup: 5.7.2022.
59. Grady, C. L., Bernstein, L. J., Beig, S., i Siegenthaler, A. L. (2002.) The effects of encoding task on age-related differences in the functional neuroanatomy of face memory. *Psychology and Aging*, 17(1), 7–23.
60. Almabdy i Elrefaei, (2019.), Deep Convolutional Neural Network-Based Approaches for Face Recognition, Internet stranica:



[https://www.researchgate.net/publication/336619872\\_Deep\\_Convolutional\\_Neural\\_Network-Based\\_Approaches\\_for\\_Face\\_Recognition](https://www.researchgate.net/publication/336619872_Deep_Convolutional_Neural_Network-Based_Approaches_for_Face_Recognition) , Pristup: 6.7.2022.

61. MA i ostali, (2019.), Analyzing the Leading Causes of Traffic Fatalities Using XGBoost and Grid-Based Analysis: A City Management Perspective, Internet stranica:

[https://www.researchgate.net/publication/336402347\\_Analyzing\\_the\\_Leading\\_Causes\\_of\\_Traffic\\_Fatalities\\_Using\\_XGBoost\\_and\\_Grid-Based\\_Analysis\\_A\\_City\\_Management\\_Perspective](https://www.researchgate.net/publication/336402347_Analyzing_the_Leading_Causes_of_Traffic_Fatalities_Using_XGBoost_and_Grid-Based_Analysis_A_City_Management_Perspective) , Pristup: 6.7.2022

62. Scikit-learn, sklearn.metrics.f1\_score, Internet stranica:  
[https://scikit-learn.org/stable/modules/generated/sklearn.metrics.f1\\_score.html#sklearn-metrics-f1-score](https://scikit-learn.org/stable/modules/generated/sklearn.metrics.f1_score.html#sklearn-metrics-f1-score), Pristup: 6.7.2022.

63. Scikit-learn, sklearn.metrics.fclassification\_report, Internet stranica:  
[https://scikit-learn.org/stable/modules/generated/sklearn.metrics.classification\\_report.html#sklearn.metrics.classification\\_report](https://scikit-learn.org/stable/modules/generated/sklearn.metrics.classification_report.html#sklearn.metrics.classification_report), Pristup: 6.7.2022.

## Popis slika

Slika 1.: Razlika između strojnog učenja i dubokog učenja	3
Slika 2.: Struktura sustava za prepoznavanje lica	4
Slika 3.: Dijagram toka algoritma metode Eigenfaces	8
Slika 4.: Linearni SVM	10
Slika 5.: Nelinearni SVM	11
Slika 6.: Prikaz konvolucijske neuronske mreže	12
Slika 7.: 3D sustav za prepoznavanje lica	16
Slika 8.: Struktura FaceNet-a	19
Slika 9.: Trostruki gubitak	19
Slika 10.: Formula točnosti	28
Slika 11.: Vrijednosti TP, FP, FN i TN u konfuzijskoj matrici	29
Slika 12.: Formula opoziva	29
Slika 13.: Formula preciznosti	30
Slika 14.: Formula F mjere	30
Slika 15.: Klasifikacijski izvještaj modela Eigenfaces	31
Slika 16.: Klasifikacijski izvještaj modela Fisherfaces	32
Slika 17.: Klasifikacijski izvještaj modela LBPH	32
Slika 18.: Klasifikacijski izvještaj modela SVM	33

## Popis tablica

Tablica 1.: Prednosti i nedostaci korištenja tehnologija za prepoznavanje lica	22
Tablica 2.: Usporedba točnosti prepoznavanja lica u sljedećim algoritmima	31

## Sažetak

Prepoznavanje lica označava identifikaciju ili potvrđivanje identiteta pojedinca pomoću njegovog lica. Tehnologija je u zadnjem desetljeću dobila veliku popularnost te se široko primjenjuje u biometriji, sigurnosnim informacijama, u provedbi zakona od strane različitih tijela, tehnologiji nadzora, pametnim karticama i tako dalje. Ovaj rad pruža uvid u sam proces prepoznavanja lica. Kroz rad su nabrojani i opisani različiti algoritmi za prepoznavanje lica.

Cilj ovog diplomskog rada je bio usporediti algoritme za prepoznavanje lica na malom skupu podataka. U ovome radu je implementirano i uspoređeno četiri algoritma: Eigenfaces, Fisherfaces, LBPH i SVM. Većina istraživanja temelji svoje rezultate na velikim skupovima podataka. Ovdje je korišten mali skup podataka za treniranje veličine 200 slika i skup podataka za testiranje veličine 40 slika, želeći ispitati vrijedi li visoka točnost prepoznavanja i na manjem skupu podataka.

**Ključne riječi:** Eigenfaces, Fisherfaces, LBPH, SVM, prepoznavanje lica, identifikacija lica

## **Abstract**

Face recognition refers to the identification or confirmation of the identity of a person using their face. This technology has gained great popularity in the last decade and is widely used in biometrics, security information, law enforcement by various agencies, surveillance technology, smart cards, and so on. This paper provides an insight into the face recognition process itself. Several different algorithms for face recognition are used and described throughout the paper.

The aim of this thesis is to compare facial recognition algorithms using a small set of data. In this work four algorithms are implemented and compared: Eigenfaces, Fisherfaces, LBPH and SVM. Most of the research is based on large sets of data. In order to find out whether high recognition accuracy can be achieved on a smaller set of data, a data set for training of 200 photos and a data set for testing of 40 photos are used.

**Keywords:** Eigenfaces, Fisherfaces, LBPH, SVM, face recognition, face identification