

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

**Projekt iz predmeta Raspoznavanje uzorka**

**Ak. god. 2016/17**

# **Deidentifikacija geometrijskih karakteristika lica**

**Autori:**

Mislav Jurić  
Marin Koštić  
Mihovil Kucijan  
Marin Maršić  
Domagoj Nakić  
Fran Varga

prosinac, 2016

# Sadržaj

<b>1. Projektni zadatak</b>	<b>3</b>
<b>1.1. Opis projektnog zadatka</b>	<b>3</b>
<b>1.2. Opis i pregled srodnih rješenja</b>	<b>4</b>
<b>1.2.1. Posljedica geometrijskih izobličenja na raspoznavanje lica</b>	<b>4</b>
<b>1.3. Konceptualno rješenje zadatka</b>	<b>8</b>
<b>2. Postupak rješavanja zadatka</b>	<b>9</b>
<b>2.1. Ispitna baza</b>	<b>9</b>
<b>2.2. Opis programske implementacije eksperimenta</b>	<b>11</b>
<b>2.3. Neuronska mreža</b>	<b>13</b>
<b>3. Ispitivanje rješenja</b>	<b>14</b>
<b>3.1. Rezultati učenja i ispitivanja</b>	<b>14</b>
<b>3.2. Analiza rezultata</b>	<b>16</b>
<b>4. Zaključak</b>	<b>17</b>
<b>5. Literatura</b>	<b>18</b>

# **1. Projektni zadatak**

## **1.1. Opis projektnog zadatka**

Raspoznavanje uzoraka kao grana strojnog učenja u računarstvu razvila je mnogo algoritama i sustava za raspoznavanje lica. Mnogi od tih sustava raspoznavanja uvode apriorne prepostavke ili ograničenja kako bi algoritmi bili izvedivi u stvarnom vremenu. Tako pojedini sustavi koriste samo pojedine značajke lica, poput šarenice oka, kako bi uspješno klasificirali lica. No jedino ljudska percepcija lica<sup>[3]</sup> je sustav za raspoznavanje koji nadilazi sve danas poznate računarske algoritme i sustave raspoznavanja. Pokazalo se da je ona izuzetno uspješna na slikama lica koje sadrže šum, pa tako pojedine informacije nisu dostupne. Mnoga psihološka istraživanja su pokazala kako ljudska percepcija koristi dvije strategije u raspoznavanju lica<sup>[2]</sup>. Prva strategija se zasniva na međuodnosu pojedinih značajaka lica (npr. proporcije lica), dok se druga strategija oslanja na same značajke i njihove karakteristike (npr. oblik usana) neovisno o drugim značajkama. Cilj ovog projektnog zadatka je istražiti kako geometrijske karakteristike lica utječu na deidentifikaciju lica, odnosno kada dolazi do prosopagnosije<sup>[4]</sup>. Prosopagnosija je kognitivni poremećaj kod kojeg osoba nije u stanju raspozнатi lica poznatih osoba (uključujući svoje lice), iako raspoznaće sve karakteristike koje formiraju lice te nije došlo do oštećenja vidnih organa i živaca. Također zadatak je pronaći i granicu kod koje promjenom geometrijskih karakteristika dolazi do deidentifikacije, te pomoći te granice nekom od računarskih metoda učenja oponašati ljudsku percepciju.

## **1.2. Opis i pregled srodnih rješenja**

### **1.2.1. Posljedica geometrijskih izobličenja na raspoznavanje lica**

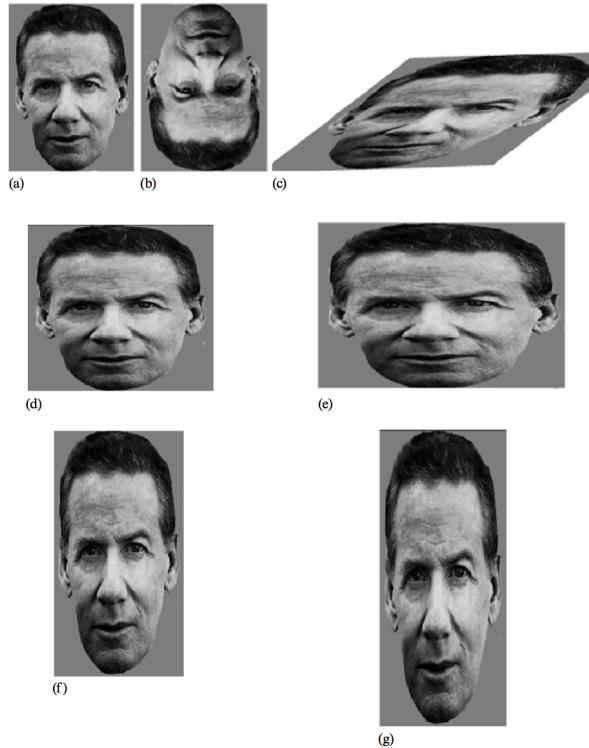
G. J. Hole, P. A. George, K. Eaves i A. Rasek u svom radu „Effects of geometric distortions on face-recognition performance”<sup>[1]</sup> proveli su četiri eksperimenta kojima su istražili posljedice različitih geometrijskih izobličenja na uspješnost raspoznavanja poznatih lica. U prvom eksperimentu su ispitali posljedice izobličenja cijele slike lice, odnosno uspoređivali su uspješnost raspoznavanja lica na pet različitih vrsta slika.

Tipovi slika u eksperimentu :

1. Normalna slika bez geometrijskih izobličenja, crno-bijela (256 razina intenziteta sive boje), dimenzija 5x4 cm (visina i širina).
2. Slika rotiranog lica za 180 stupnjeva bez geometrijskih izobličenja, istih karakteristika kao i normalna slika.
3. Slika vertikalno izduženog lica, izobličenje dobiveno povećanjem dimenzije slike u visinu, dimenzije slike 10x4 cm.
4. Slika horizontalno izduženog lica, dimenzije slike 5x8 cm.
5. Slika razvučenog lica u obliku trapeza, izobličenje dobiveno smicanjem slike za 45 stupnjeva.

Primjeri svih vrsta slika s geometrijskim izobličenjima su prikazani na slici 1.

Ispitanici su u prvom eksperimentu bili podvrgnuti testu od 30 sekvenci slika, te su bili dužni raspoznati da li je osoba na slici slavna ili nije u što je moguće kraćem vremenu. Sekvenca slika je generirana slučajnjim izvlačenjem slika iz baze s uvjetom da je omjer slavnih osoba i nepoznatih osoba jedan naprema jedan (15 slika iz svake klase). Rezultati testiranja prikazani su u tablici 1., iz rezultata je vidljivo da vertikalna, horizontalna i izobličenja smicanja nemaju utjecaja na sposobnost ispitanika da ispravno raspozna lice slavne osobe na slici. No u prosjeku je ispitaniku potrebno više vremena da donese odluku o klasifikaciji u odnosu na normalnu sliku.



*Slika 1. (a) normalna, (b) invertirana slika, (c) slika dobivena smicanjem, (d) horizontalno izoblicenje (150%), (e) horizontalno izoblicenje (200%), (f) vertikalno izoblicenje (150%), (g) vertikalno izoblicenje (200%).*

Tablica 1. Rezultati prvog eksperimenta

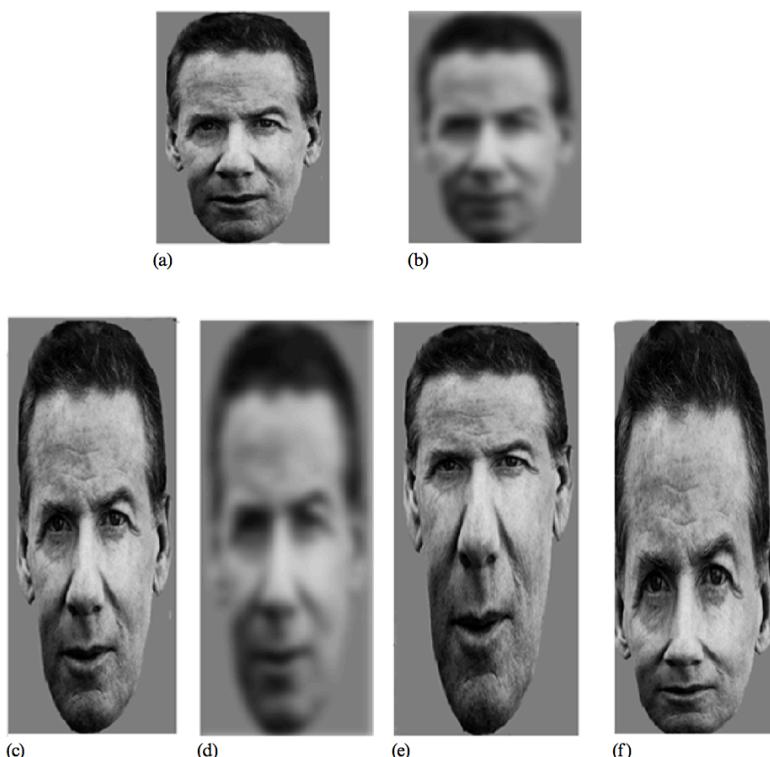
Vrsta slike	(a) normalna	(b) invertirana	(g) vertikalno izoblicenje	(e) horizontalno izoblicenje	(c) smicanje
Srednje vrijeme odziva (ms)	1338	1921	1137	1365	1392
Srednji broj točnih klasifikacija	11.9	8.1	12.2	10.2	9.7
Postotak točne klasifikacije (%)	79	54	82	68	64

Drugi eksperiment proveden je u cilju detaljnijeg proučavanja utjecaja horizontalnog i vertikalnog izobličenja. Ispitanici su ispitivani na originalnim slikama lica, te na slikama vertikalnog i horizontalnog izobličenja dvije jačine. Na slici 1. vidimo iznose izobličenja u odnosu na originalnu sliku, slike (a), (d), (e), (f) i (g). Svaki od ispitanika je bio testiran na sekvenci od 38 slika, sekvenca je generirana nasumičnim izvlačenjem slika iz baze. Zadatak ispitanika je opet bio da u što kraćem vremenu klasificira lice kao poznate osobe ili nepoznate. Rezultati ovog eksperimenta su prikazani u tablici 2., te također pokazuju kako vertikalna i horizontalna izobličenja cijele slike nemaju utjecaja na sposobnost ispitanika da ispravno klasificira lica poznatih osoba, ne dolazi do prosopagnosije.

Tablica 2. Rezultati drugog eksperimenta

Vrsta slike	(a) normalna	(f) vertikalno izobličenje (150%)	(g) vertikalno izobličenje (200%)	(d) horizontalno izobličenje (150%)	(e) horizontalno izobličenje (200%)
Srednje vrijeme odziva (ms)	1006	984	988	1023	1038
Srednji broj točnih klasifikacija	26.3	27.2	26.6	26.7	26.5
Postotak točne klasifikacije (%)	73	76	74	74	74

Na temelju prva dva eksperimenta koji su proveli u svom istraživanju [1], pokazano je kako ispitanici mogu s dobrom preciznošću raspoznati lica poznatih od nepoznatih, unatoč vertikalnim i horizontalnim izobličenjima cijele slike. Ti eksperimenti potvrđuju kako je ljudska percepcija lica jako prilagodljiva kada se neki međuodnosi značajka promjene, te se može doći do zaključka kako ljudska percepcija kao sustav raspoznavanja lica koristi prethodno spomenute dvije strategije raspoznavanja u kombinaciji [2]. Treći eksperiment osim promjene originalne slike na globalnoj razini uvodi novo vertikalno izobličenje, ovo izobličenje se primjenjuje na gornjoj ili donjoj polovici slike lica. Ideja ovog izobličenja je proučiti utjecaj lokaliziranih izobličenja, čime bi se više utjecalo na same međuodnose između značajki lica (proporcije). Primjere izobličenja za treći eksperiment vidimo na slici 2.



Slika 2. (a) normalna slika lica, (b) zamućena bez izobličenja, (c) vertikalno izobličenje cijele slike, (d) zamućena i vertikalno izobličena cijela slika, (e) donja polovica izobličena, (f) gornja polovica izobličena.

Ispitanici su u trećem eksperimentu bili testirani na isti način kao i u prvom eksperimentu. Rezultati eksperimenta su prikazani u tablici 3. iz njih je vidljivo da u slučaju kada se na sliku primjeni globalno i lokalno izobličenje ispitanici imaju lošije rezultate raspoznavanja nego na ostalim slikama, iako je točnost raspoznavanja još uvijek vrlo visoka. Iz tih rezultata može se prepostaviti ukoliko bi primijenili globalne i lokalne transformacije u određenoj mjeri, možda je moguće postići željeni rezultat deidentifikacije odnosno prouzročiti prosopragnoziju.

Tablica 3. Rezultati trećeg eksperimenta				
Vrsta slike	(a) normalna	(c) vertikalno izobličenje cijele slike	(f) gornja polovica izobličena	(e) donja polovica izobličena
Srednje vrijeme odziva (ms)	1089	1170	1413	1682
Srednji broj točnih klasifikacija	13.9	14.1	11.9	11.8
Postotak točne klasifikacije (%)	93	94	79	79

Četvrti eksperiment proveden je uvođenjem dodatne transformacije odnosno zamućivanje cijele slike (engl. “blurring”). U ovom eksperimentu su korištene četiri vrste slike, normalna slika bez transformacija, slika s vertikalnim izobličenjem cijele slike, zamućena slika normalnih dimenzija, te slika koja kombinira zamućenje i vertikalno izobličenje cijele slike. Ispitanici su bili podvrgnuti identičnom testu kao i u prethodnom eksperimentu, te u tablici 4. su prikazani rezultati ovog eksperimenta.

Tablica 4. Rezultati četvrtog eksperimenta				
Vrsta slike	(a) normalna	(c) vertikalno izobličenje cijele slike	(b) zamućena normalna slika	(d) vertikalno izobličena i zamućena slika
Srednje vrijeme odziva (ms)	1123	1321	1435	1501
Srednji broj točnih klasifikacija	10.9	10.7	7.6	8.3
Postotak točne klasifikacije (%)	73	71	51	55

Kao i u prethodna tri eksperimenta ispitanicima je bilo potrebno duže vrijeme za donijeti odluku klasifikacije na slikama koje su izmijenjene, također vidimo da zamućivanje smanjuje točnost ispravne klasifikacije iako ne dolazi do prosopragnozije. Taj rezultat upućuje da ljudska percepcija lica čak i s manjom količinom informacije na slikama uspijeva raspoznati lica poznatih osoba. Očito postoje jaki međuodnosi između značajka na licu koje omogućuju točno raspoznavanje s manje informacija o pojedinim značajkama.

### 1.3. Konceptualno rješenje zadatka

Cilj zadatka je ljudsku percepciju lica dovesti u stanje prosopragnozije, odnosno korištenjem geometrijskih karakteristika lica pronaći točno koje karakteristike i u kojoj mjeri dovode do deidentifikacije. Ideja je konstruirati početnu bazu podataka lica poznatih osoba. Kako bi eliminirali utjecaj drugih karakteristika lica, poput oblika kose, te u fokus testiranja stavili samu geometriju lica, potrebno je slike preprocesirati i ukloniti sve karakteristike osim geometrijskih. Primjer takve slike je prikazan na slici 3.



*Slika 3. Lice nakon preprocesiranja, Paul McCartney*

Zatim je potrebno osigurati izlučivanje pojedinih geometrijskih karakteristika i njihovo manipuliranje. Primjer manipulacije pojedinih geometrijskih karakteristika može biti pomicanje usta osobe na slici gore-dolje za određeni iznos. Nakon toga je potrebno generirati niz slika u bazi podataka na koje su primijenjene geometrijske transformacije karakteristika lica. Sljedeći korak je provesti testiranje na prosopragnoziju na tim slikama. Provesti statistiku nad rezultatima testiranja, te je iz rezultata je potrebno doći do zaključka koje to točno karakteristike lica i u kojoj mjeri utječu na deidentifikaciju.

## **2. Postupak rješavanja zadatka**

### **2.1. Ispitna baza**

Ispitna baza podataka se može podijeliti na dva dijela, prvi dio se sastoji od 30 slika lica na koje nisu primijenjene transformacije geometrijskih karakteristika lica. Tih 30 originalnih slika se koriste u generiranju drugog dijela ispitne baze, koji se koristi u samom ispitivanju deidentifikacije. Slike su u JPEG (engl. Joint Photographic Experts Group) formatu, dimenzija 200x300 te koriste RGB model boja. U sljedećem popisu su napisana imena i prezimena poznatih osoba u bazi podataka koje će se koristiti za testiranje.

Popis osoba u bazi podataka:

- Arnold Schwarzenegger
- Ben Stiller
- Brad Pitt
- Cher
- Condoleezza Rice
- Elvis Presley
- George W. Bush
- Jennifer Aniston
- Jerry Seinfeld
- Jim Carrey
- John F. Kennedy
- John Travolta
- Keanu Reeves
- Madonna
- Mahatma Gandhi
- Margaret Thatcher
- Oprah Winfrey
- Patrick Stewart
- Paul McCartney
- Princess Diana
- Richard Nixon
- Robert De Niro
- Robin Williams
- Ronald Reagan
- Rowan Atkinson
- Sylvester Stallone
- Tom Cruise
- Tom Hanks
- Tony Blair

Drugi dio baze čini skup od 3000 slika koje su nastale primjenom transformacija geometrijskih karakteristika lica iz originalnog skupa. Slike su također u JPEG formatu, dimenzija 200x300 te koriste RGB model boja. Ovaj skup slika je korišten u izradi eksperimenta i na njemu su sakupljeni statistički podaci u otkrivanju uspješnosti deidentifikacije. Svako od 3000 slika je bio dodijeljen 18 dimenzionalni vektor značajki, svaka značajka je mogla poprimiti vrijednosti iz intervala [1,7] gdje broj 4 označava da nije došlo do promjene pojedine geometrijske karakteristike na licu.

U tablici 5. je detaljno opisano 18 dimenzionalni vektor, uz poziciju indeksa vektora je napisana točno koja se geometrijska karakteristika mijenja na licu. Također prikazan je i interval promjene, odnosno mogući iznos promijene svake pojedine karakteristike na licu. Sve promjene su bile slučajno odabrane prilikom generiranja 3000 slika za testiranje. Odabrana promjena je zatim bila skalirana na interval [1,7] kako bi vektor imao uniforman oblik.

Tablica 5. Vektori značajki i geometrijske karakteristike lica

Broj značajke	Geom. karakteristika lica	Interval promjene
1.	Širina lica	0.85-1.15
2.	Dužina lica	0.85-1.15
3.	Širina nosa	0.85-1.15
4.	Dužina nosa	0.85-1.15
5.	Vertikalna translacija nosa	-1.5-1.5
6.	Širina usana	0.85-1.15
7.	Dužina usana	0.85-1.15
8.	Vertikalna translacija usana	-1.5-1.5
9.	Širina očiju	0.85-1.15
10.	Dužina očiju	0.85-1.15
11.	Vertikalna translacija očiju	-1.5-1.5
12.	Horizontalna translacija očiju	-1.5-1.5
13.	Rotacija očiju	-pi/12-pi/12
14.	Širina obrva	0.85-1.15
15.	Dužina obrva	0.85-1.15
16.	Vertikalna translacija obrva	-1.5-1.5
17.	Horizontalna translacija obrva	-1.5-1.5
18.	Rotacija obrva	-pi/12-pi/12

## 2.2. Opis programske implementacije eksperimenta

Za potrebe sakupljanja podataka o deidentifikaciji lica sa slika iz baze podataka razvijena je web aplikacija, ona služi kao platforma za provođenje eksperimenta. Web aplikacija je izabrana zbog jednostavnosti izvedbe i provođenja više eksperimenata paralelno u svrhu što bržeg i jednostavnijeg načina skupljanja rezultata. Aplikacija je napisana u razvojnom okviru Ruby on Rails, te je dostupna na adresi:

<http://rasuzo-deidentifikacija-lica.herokuapp.com>

Za pristup web aplikaciji potrebno se prijaviti na jedan od dva moguća načina, kao ispitanik ili kao administrator. Za administratorske ovlasti koristi s korisničko ime admin@fer.hr i lozinka “admin\_fer”, dok se ispitanik prijavljuje s korisničkim imenom user@fer.hr i lozinkom “user\_fer”. Nakon prijave u web aplikaciju prikazuje se početna stranica na kojoj se nalazi kratki opis eksperimenta i gumb pomoću kojeg ispitanik započinje testiranje. Na slici 4. je prikazana početna stranica.



Slika 4. Početna stranica web aplikacije.

Ispitaniku se iz baze podataka prikazuje slika odabrana slučajnim odabirom uz uvjet da se za trenutno odabranu osobu u sljedećih pet novo odabralih slika izbjegavaju sve slike iste osobe i dodatni uvjet da se ista osoba smije pojaviti samo dva puta u 15 slika za redom. Svaka slučajno odabrana slika se prikazuje u zasebnom html pogledu, kako je prikazano na slici 5., osim slike ispitaniku je prikazano i polje za unos teksta. Polje za unos služi za upis imena i/ili prezimena osobe koju ispitanik prepoznaje na slici, u slučaju da ispitanik ne prepoznači osobu na slici polje za unos teksta ostaje prazno.

## Deidentifikacija geometrijskih karakteristika lica

Početna Slike Testovi Download log datoteke Odjava

### Prepoznaj osobu na slici



Ako ne prepoznaјete osobu na slici gornje polje ostavite prazno i kliknite Odgovori

Odgovori

Slika 5. Primjer prikaza jednog testa ispitaniku.

Na vrhu web stranice se nalazi navigacijska traka s izbornikom. Administrator kada se prijavi u sustav može pomoću navigacijske trake pregledati sve dosadašnje testove, te može preuzeti .txt log datoteku u kojoj se nalazi strukturirani zapis svakog pojedinog testa. Zapis u log datoteci služi za izradu statistike nad podacima i provođenja ispitivanja. Log datoteka je strukturirana na sljedeći način, u slučaju da korisnik nije prepoznao osobu na slici i nije upisao ime i/ili prezime u polje za unos teksta u datoteci se nalazi sljedeći tekst.

“puno\_ime\_slike\_iz\_baze | n”

Ako je korisnik prepoznao osobu na slici te unio ime i/ili prezime u polje za unos u datoteci je zapisan sljedeći tekst.

“puno\_ime\_slike\_iz\_baze | y | ime i/ili prezime | 0/1”

U zapisu zadnja oznaka 0/1 predstavlja lažno pozitivne (enlg. false positive) primjere. Primjer klasificiramo kao lažni pozitiv ako je ispitanik upisao ime i/ili prezime neke druge osobe od one koja je stvarno na slici. Pomoću dobivene log datoteke iz web aplikacije smo mogli upariti 18 dimenzionalni vektor koji pripada svakoj od 3000 slika iz baze s oznakom klasifikacije. Time smo na vrlo jednostavan način uspjeli konstruirati skup primjera za nadzirano učenje bilo kojeg modela strojnog učenja.

## 2.3. Neuronska mreža

Neuronska mreža je skup međusobno povezanih jednostavnih procesnih elemenata (jedinica, čvorova) čija se funkcionalnost temelji na biološkom neuronu i koji služe u distribuiranoj paralelnoj obradi podataka. Neuronske mreže najčešće pronađavamo u primjeni kod rješavanja problema klasifikacije i predviđanja, dobre su u procijeni nelinearnosti te rade s velikim brojem parametara i varijabli. Višeslojni perceptron je neuronska mreža bez povratnih veza, koja koristi Backpropagation algoritam<sup>[7]</sup> pri nadziranom učenju prilikom klasifikacije ili regresije<sup>[5]</sup>. Kako je višeslojni perceptron model koji se koristi u nadziranom učenju potrebno je imati skup označenih primjera za učenje  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ , gdje su  $x \in \mathbf{R}$  i  $y_i \in \{0, 1\}$  ako se radi o binarnoj klasifikaciji. Izlaz svakog neurona u mreži predstavlja funkcija :

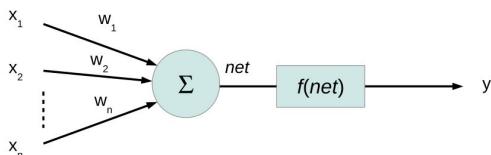
$$f(x) = \mathbf{W}_2 g(\mathbf{W}_1^T x + b_1) + b_2.$$

gdje su  $\mathbf{W}_1 \in \mathbf{R}^n$  i predstavlja težine na prvom sloju dok  $\mathbf{W}_2, b_1, b_2 \in \mathbf{R}$  predstavljaju težine na ulazu u skriveni sloj, te pomak koji se dodaje skrivenom sloju i izlazu perceptronu<sup>[6]</sup>. Funkcija  $g(x) : \mathbf{R} \rightarrow \mathbf{R}$ , se naziva aktivacijska funkcija. Kod binarne klasifikacije kao aktivacijsku funkciju najčešće se koristi "sigmoide" ili logistička funkcija. Također kada se radi o klasifikacijskom problemu, višeslojni perceptron kao funkciju gubitka koristi pogrešku unakrsne entropije koja je dana formulom:

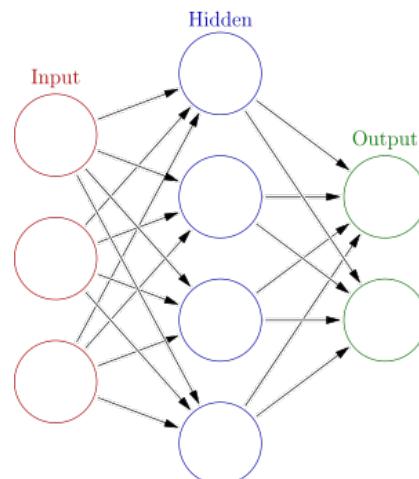
$$\text{Loss}(y', y, \mathbf{W}) = 0.5 * ||y' - y||_2^2 + \alpha \|\mathbf{W}\|_2^2,$$

gdje je  $\alpha \|\mathbf{W}\|_2^2$  faktor L2 - regularizacije , a parametar je  $\alpha > 0$ <sup>[6]</sup>.

Višeslojni perceptron ovako opisan je u potpunosti implementiran u programskom jeziku Python i dostupan je kao dio biblioteke otvorenog koda Scikit Learn<sup>[6]</sup>. Binarni klasifikator je implementiran kao klasa pod nazivom MLPClassifier, parametre koje prima klasa su broj skrivenih slojeva, aktivacijska funkcija, metoda koja pronađe minimum funkcije gubitka (npr. stohastički gradijentni spust), faktor regularizacije  $\alpha$  i maksimalni broj iteracija.



Slika 6. Osnovni model neurona.

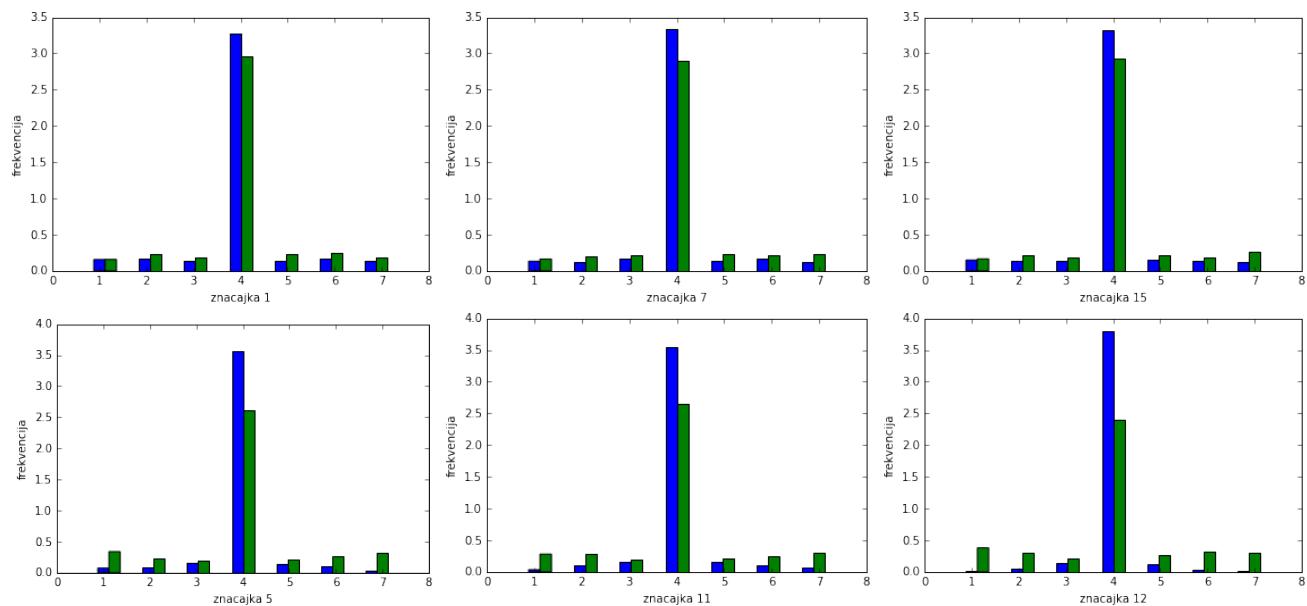


Slika 7. Neuronska mreža arhitekture  
3 x 4 x 2

### 3. Ispitivanje rješenja

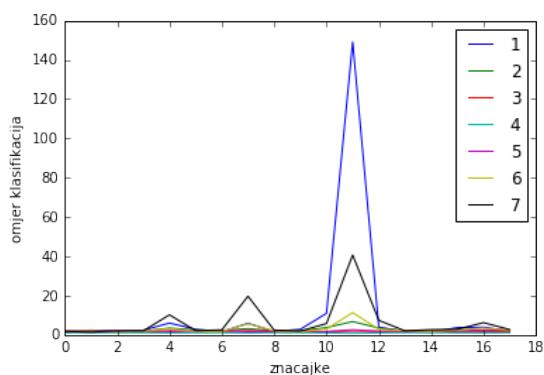
#### 3.1. Rezultati učenja i ispitivanja

Nakon provedenog eksperimenta i sakupljanja podataka o uspješnosti deidentifikacije sljedeći zadatak je bio istražiti zakonitosti u sakupljenim podacima. Kao prvu i najjednostavniju statističku metodu izabran je histogram. Histogrami su izračunati za svaku pojedinu značajku u ovisnosti klasifikacije, plavi histogrami na slici 8. su primjeri koje su ispitanici klasificirali kao poznati, dok zeleni histogrami su primjeri nepoznate klasifikacije. Sve ukupno je izračunato 18 histograma za svaku pojedinu značajku. Na slici 8. su prikazane dvije skupine histograma, u gornjem redu se nalaze histogrami značajki za koje su razdiobe različitih klasifikacija podjednake i one ne doprinose značajno prilikom klasifikacije. Dok se u drugom redu nalazi skupina histograma gdje se jako dobro vidi razlika u razdiobama i to su značajke koje najviše doprinose deidentifikaciji.



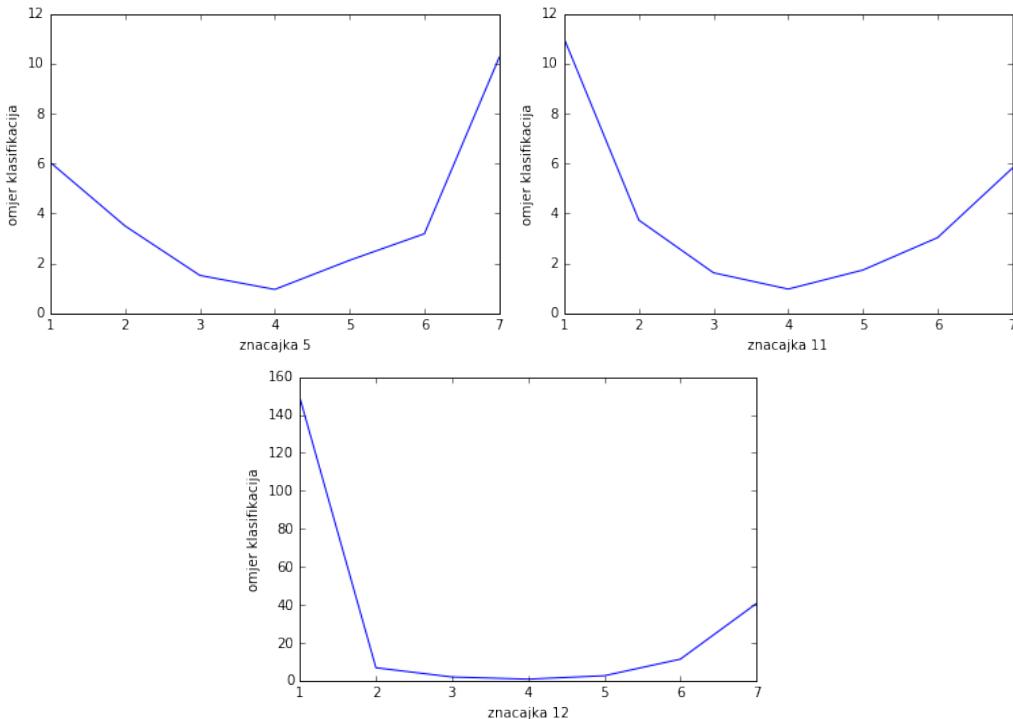
Slika 8. Izračunati histogrami za pojedine značajke.

Kako bismo bolje prikazali utjecaj pojedine značajke na uspješnost deidentifikacije, izračunali smo omjer klasifikacija u odnosu na svaku pojedinu značajku. Slika 9. prikazuje krivulje koje predstavljaju točno određenu vrijednost svake pojedine značajke, na x-osi se nalazi svaka pojedina značajka, dok na y-osi se nalazi omjer identifikacije i deidentifikacije.



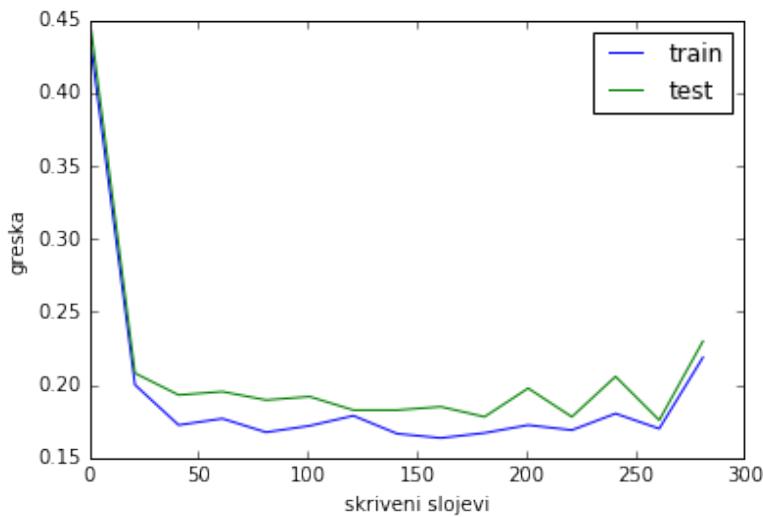
Slika 9. Omjer uspješnosti deidentifikacije u ovisnosti iznosa vrijednosti svake značajke.

Iz prethodnog grafa jasno je vidljivo kako najveći iznosi promjena geometrijskih karakteristika na licu imaju najveći utjecaj na deidentifikaciju, ta činjenica je vrlo intuitivna. Ono što je zanimljivo je da na deidentifikaciju najviše utjecaja imaju vertikalna i horizontalna translacija očiju, dužina usana, te vertikalna translacija nosa. Dok značajke poput dužine i širine lica nemaju skoro pa nikakav utjecan na uspješnost deidentifikacije, što su G. J. Hole, P. A. George, K. Eaves i A. Rasek opisuju u svome istraživanju<sup>[1]</sup>. Također su na slici 10. izdvojene tri najznačajnije značajke koje najviše doprinose deidentifikaciji.



*Slika 10. Omjeri uspješnosti deidentifikacije za najznačajnije značajke.*

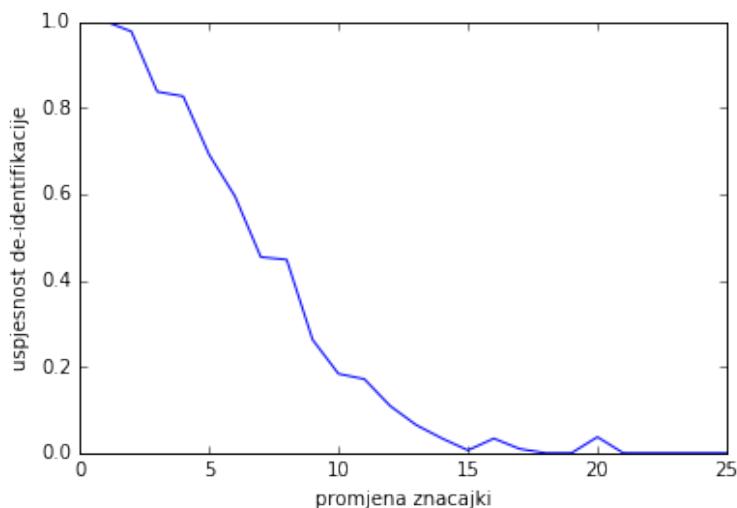
Kao sljedeći korak u analizi dobivenih podataka izabrali smo naučiti model neuronske mreže, odnosno višeslojni perceptron, te pokušati odrediti granicu kada dolazi do deidentifikacije. Model neuronske mreže je odabran zbog toga što svoje korijene ima u imitaciji neurona u ljudskome mozgu, a cilj je imitirati ljudsku percepciju lica. Primjere dobivene iz eksperimenta smo prvo podijelili u dvije skupine, kako bi mogli provesti unakrsnu provjeru prilikom treniranja neuronske mreže. Primjere za učenje modela i primjere za validaciju u omjeru 3:1. Trenirali smo više modela višeslojnog perceptrona u ovisnosti parametra broja skrivenih slojeva, na slici 11. je prikazan graf unakrsne provjere. Plava krivulja prikazuje grešku višeslojnog perceptrona na skupu za učenje, dok zelena krivulja prikazuje grešku na skupu za validaciju. Unakrsnom provjerom smo izabrali optimalan broj skrivenih slojeva koji minimizira grešku na primjerima za validaciju.



*Slika 11. Unakrsna provjera na modelu.*

### 3.2. Analiza rezultata

Kako bi uspješno odredili granicu kod koje dolazi do uspješne deidentifikacije, višeslojni perceptron je treniran na cijelom skupu primjera, najboljim parametrom dobivenim unakrsnom provjerom. Zatim smo sve primjere podijelili u 55 skupova, gdje prvi odnosno nulti skup označava broj primjere na kojima je apsolutna promjena svih značajki nula (originalna slika lica). Dok svaki sljedeći skup 1,2,3,...,55 sadrži primjere kojima je apsolutna promjena svih značajki jednaka broju skupa. Na primjer skup s rednim brojem 2 sadrži one primjere kod kojih se je jedna značajka promijenila za vrijednost 2 ili su se dvije značajke promijenile za vrijednost 1. Nakon što smo primjere podijelili u skupove ispitali smo izlaz višeslojnog perceptrona za svaki od skupova. Na slici 12. je prikazan postotak uspješnosti da model raspozna osobu odnosno, iz grafa se jasno vidi da ako je apsolutna promjena svih značajki veća od 15 postigli smo deidentifikaciju na modelu.



*Slika 12. Uspješnost identifikacije odnosno deidentifikacije na modelu.*

## **4. Zaključak**

Zaštita privatnosti je jedan od ključnih problema današnjeg modernog društva. Postoje mnogi algoritmi i sustavi za raspoznavanje lica, a osobne informacije pogotovo slike lica osoba su dostupne ma mnogim društvenim mrežama. Ta činjenica podiže mnoga pitanja kako uspješno zaštititi osobne informacije, deidentifikacija se zbog tih razloga sve više proučava u području računarstva kao i u drugim znanstvenim disciplinama. Deidentifikacija lica predstavlja poseban izazov, u ovom radu je predstavljen jedan od mnogih pristupa deidentifikaciji lica pojedinca. Geometrijske značajke lica osim što omogućuju zaštitu protiv pojedinih sustava za raspoznavanje lica koje ih koriste u klasifikaciji, omogućuju i zaštitu informacija i protiv ljudske percepcije lica. Pokazali smo kako određene geometrijske karakteristike lica poput položaja očiju, nosa, te usana ima veći utjecaj na deidentifikaciju lica. Ovakav pristup deidentifikaciji se može proširiti na transformaciju geometrijskih značajki lica u videozapisu.

## 5. Literatura

1. G. J. Hole, P. A. George, K. Eaves, A. Rasek : Perception ,vol.31, no. 10, pp. 1221-1240,2002.,<http://users.sussex.ac.uk/~grahamh/RESEARCH/GrahamPublicationsForWeb/Holeetal2002.pdf> , 10.12.2016.
2. Sargent J: British Journal of Psychology 75, pp. 221-242, 1984.
3. From Wikipedia, the free encyclopaedia : Face Perception, [https://en.wikipedia.org/wiki/Face\\_perception](https://en.wikipedia.org/wiki/Face_perception)
4. From Wikipedia, the free encyclopaedia : Prosopagnosia, <https://en.wikipedia.org/wiki/Prosopagnosia>
5. From Wikipedia, the free encyclopaedia : Multilayer Perceptron, [https://en.wikipedia.org/wiki/Multilayer\\_perceptron](https://en.wikipedia.org/wiki/Multilayer_perceptron)
6. Scikit Learn Documentation : Neural Networks Model, [http://scikit-learn.org/stable/modules/neural\\_networks\\_supervised.html](http://scikit-learn.org/stable/modules/neural_networks_supervised.html)
7. Stanford University : Backpropagation Algorithm, [http://ufldl.stanford.edu/wiki/index.php/Backpropagation\\_Algorithm](http://ufldl.stanford.edu/wiki/index.php/Backpropagation_Algorithm)