Utvrđivanje rodbinskih veza na temelju slika lica

Tomislav, Šimović

Undergraduate thesis / Završni rad

2019

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:148619

Rights / Prava: Attribution-NonCommercial-NoDerivs 3.0 Unported/Imenovanje-Nekomercijalno-Bez prerada 3.0

Download date / Datum preuzimanja: **2024-03-29**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Tomislav Šimović

UTVRĐIVANJE RODBINSKIH VEZA NA TEMELJU SLIKE LICA

ZAVRŠNI RAD

Varaždin, 2019.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Tomislav Šimović

Matični broj: 44256/15–R

Studij: Poslovni sustavi

UTVRĐIVANJE RODBINSKIH VEZA NA TEMELJU SLIKE LICA

ZAVRŠNI RAD

Mentorica:

Doc. dr. sc. Petra Grd

Varaždin, travanj 2019.

Tomislav Šimović

Izjava o izvornosti

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

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

_____

Sažetak

Cilj ovog rada je utvrditi rodbinsku vezu dviju osoba na temelju slika lica korištenjem algoritama za detekciju lica, verifikaciju i prepoznavanje uzoraka koji se nalaze na proslijeđenim slikama lica pojedinaca. U radu su opisane razne biometrijske tehnike, osnovne sličnosti među pojedincima koji jesu u rodbinskim vezama. Također, opisani su principi rada algoritama za utvrđivanje rodbinskih veza, te je prikazana struktura i osnovne značajke dubokih neuronskih mreža. U poglavlju s praktičnim radom objašnjeni su i prikazani korišteni skupovi podataka. Grafičko sučelje izrađene aplikacije je rađeno u Visual Studio 2019 u programskom jeziku C# u koji se unose slike lica i u pozadini se pokreće skripta napisana u programskom jeziku Python 3.6.8. koja spaja te slike u jednu te ju prosljeđuje mreži koja validira postojanje rodbinske veze među pojedincima na slici. Nadalje, grafički su prikazani rezultati treniranja mreže, te je donesen zaključak teme s obzirom na sve navedeno u radu.

Ključne riječi: lice; rodbinska veza; biometrija; neuronska mreža; algoritam;

Sadržaj

1. Uvod 1
2. Biometrija 2
2.1. Biometrijske tehnike 3
2.1.1. Čitanje DNK zapisa 4
2.1.2. Skeniranje rožnice 4
2.1.3. Prepoznavanje lica 4
2.1.4. Geometrija šake 5
2.1.5. Provjera vena 5
2.1.6. Otisak prsta 5
2.1.7. Prepoznavanje glasa 6
2.1.8. Prepoznavanje rukopisa ili potpisa 6
2.1.9. Dinamika tipkanja 6
2.1.10. Dinamika hoda 6
3. Sličnosti osoba u rodbinskim vezama 7
4. Upotreba računala kod utvrđivanja rodbinskih veza putem slike lica 8
5. Umjetna neuronska mreža za utvrđivanje rodbinskih veza na temelju slike lica 10
5.1.1. Struktura neuronske mreže 13
5.1.2. Aktivacijske funkcije 14
5.1.3. Konvolucijske neuronske mreže 18
5.1.4. Google Inception-v3 19
6. Aplikativni prikaz utvrđivanja rodbinskih veza putem slike lica 20
6.1. Skup podataka 20
6.2. Korištene tehnologije 21
6.3. Praktični rad – Aplikacija za utvrđivanje rodbinskih veza na temelju slike lica 21
6.4. Rezultati 24
7. Zaključak 28
8. Literatura 29
Sadržaj slika 31

1. Uvod

Utvrđivanje rodbinskih veza na temelju slike lica je vrlo zanimljiv i zahtjevan zadatak. Razne su primjene validacije rodbinskih veza danas u svijetu, njihova primjena može se naći u genetičkim istraživanjima, pronalasku izgubljenih članova obitelji, na socijalnim mrežama i još mnogim drugima.

Ljudska sposobnost prepoznavanja rodbine je tema mnogih psiholoških istraživanja. Inspirirani tim istraživanjima, počelo se raditi na problemu verifikacije rodbinskih veza putem slike lica u računalnom vidu.

Prepoznavanje rodbinskih veza na temelju slike lica utvrđuje se na temelju slike lica dvoje pojedinaca i temeljem tih slika određuje se jesu li one u krvnom srodstvu tako što se uspoređuju njihove facijalne karakteristike. To je dosta zahtjevan zadatak zato što i samo ljudsko oko, koje je godinama trenirano za to, ponekad ima problema kod prepoznavanja rodbinskih veza, jer se može dogoditi da jedno dijete naslijedi potpuno suprotne karakteristike od drugog djeteta od istih roditelja.

Velika je aplikativna primjena kod prepoznavanja rodbinskih veza na temelju slike lica. Može se primijeniti kod izrade obiteljskih albuma, generiranja obiteljskih stabala na temelju povijesnih fotografija i sl.

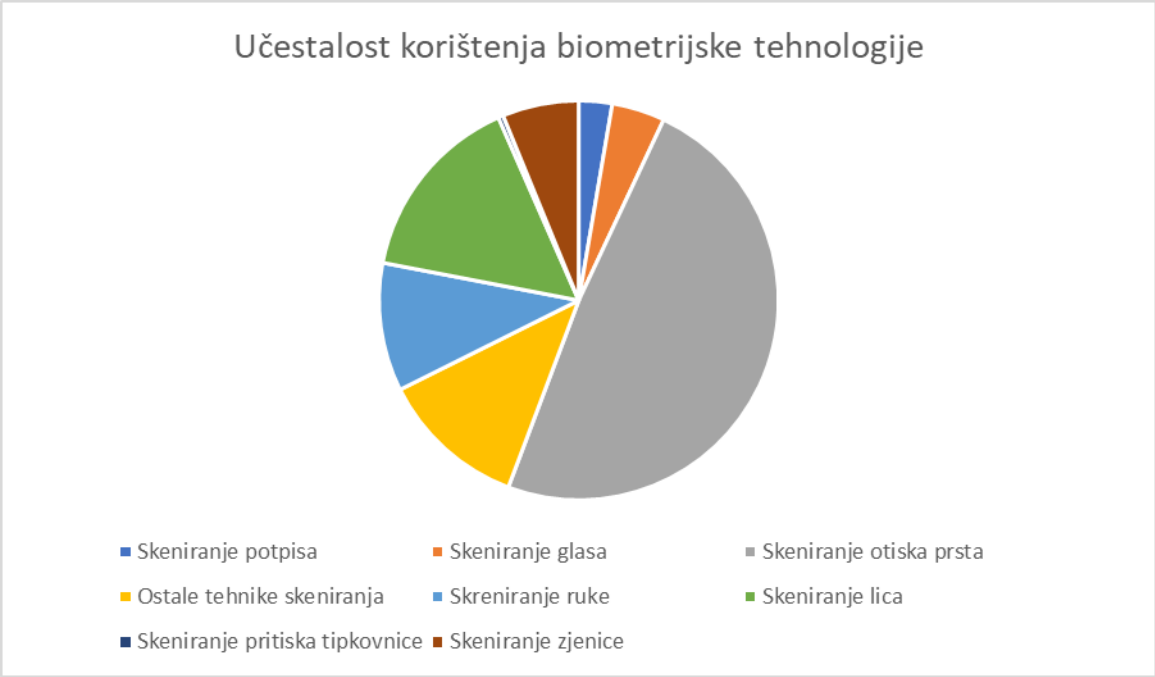
U ovom radu opisat će se osnovni pojmovi o biometriji kako bi se moglo dobiti dublje shvaćanje rada, zatim osnovni pojmovi vezani uz neuronske mreže. Kako bi mogli podrobnije razumjeti temu, objasniti će se svi bitni pojmovi vezani za algoritme za utvrđivanje rodbinskih veza i mehanizmi koji omogućuju računalu da prepozna iste. Rad će biti zaključen s prikazom aplikacije koja prepoznaje rodbinske veze na temelju slike lica, analiza rezultata dobivenih od istrenirane mreže i zaključak svega navedenog.

2. Biometrija

Riječ biometrija dolazi od grčkih riječi *bios*, život i *metron,* mjera i bavi se proučavanjem fizičkih i ponašajnih osobina čovjeka, najčešće u svrhu autentikacije. [3]

Prema CARnet CERT-u [1] biometrija predstavlja skup automatiziranih metoda za jedinstveno prepoznavanje ljudi temeljeno na jednoj ili većem broju njihovih fizičkih i ponašajnih karakteristika te programa koji analiziraju dobivene informacije. Neke od fizičkih ponašajnih karakteristika su: otisci prstiju, rožnica oka, prepoznavanje lica i sl. dok se ponašajne karakteristike odnose na rukopis, hod i sl.

Na grafikonu ispod su prikazane učestalosti korištenja biometrijske tehnologije prema CARnet CERT-u [1]. U ovom radu ćemo se bazirati na korištenju biometrijske tehnologije u svrhu skeniranja lica i utvrđivanju rodbinskih veza temeljem skenirane slike lica.



Slika 1 Prikaz učestalosti korištenja biometrijske tehnologije [1]

Biometrija se dijeli na biološku, morfološku i ponašajnu biometriju [1].

- Biološka biometrija: autentikacija pomoću DNA i pomoću krvi
- Morfološka biometrija: oblik dlana, otisci prstiju, lice, rožnica, glas (može biti i ponašajna), uši i sl.
- Ponašajna: hod (može biti i morfološka), rukopis i sl.

Nadalje će biti pobliže objašnjene biometrijske tehnike i njihova primjena.

2.1. Biometrijske tehnike

Biometrijske tehnike su utemeljene na idejama koje su potekle od prvih ljudi prije više tisuća godina. Od početka civilizacije, ljudi su koristili lica kao jednu vrstu autentikacije, odnosno prepoznavanja poznatih od nepoznatih ljudi. Naime, s povećanjem broja ljudi u zajednici i raznim istraživanjima i putovanjima, ova jednostavna metoda autentikacije postala je znatno teža.

Osim prepoznavanja lica, karakteristike koje su ljudi koristili za autentikaciju i prepoznavanje poznanika od neznanih ljudi su i prepoznavanje glasa i hoda. Ljudi te tehnike i danas koriste podsvjesno i na dnevnoj bazi.

Razvojem tehnologije, pojavili su se točniji i prikladniji načini autentikacije. Biometrijske tehnike rade na principu pretvaranja analognih podataka u digitalni format upotrebom umjetne inteligencije.

Digitalizacija je proces pretvaranja analognog signala u digitalni format, razumljiv računalu, s kojim može raditi i kojeg može koristiti u daljnjoj obradi. [1]

Prema B.J. Copelandu [2], umjetna inteligencija je sposobnost digitalnog računala ili računalom kontroliranog robota da izvodi zadaće obično povezane uz inteligentna bića.

Umjetna inteligencija, kao biometrijska tehnika, je potrebna radi dijela strojnog učenja, zvanog neuronske mreže, koji se primjenjuju u analizi signala i slika. Ideja neuronskih mreža je nastala na modelu ljudskog mozga i time se razvila mogućnost samostalnog zaključivanja. Model se sastoji od međusobno povezanih živčanih stanica, neurona, koje služe za obradu podataka. Pojedinačni neuroni su međusobno spojeni vezama kroz koje idu signali. Svaka neuronska mreža može imati jedan ili više ulaza i samo jedan izlaz. Kod višeslojnih mreža, između ulaza i izlaza nalazi se jedan ili više skrivenih slojeva, detaljnije o neuronskim vezama bit će opisano u 5. poglavlju.

Biometrija se dijeli na fizičku biometriju i biometriju ponašanja. Fizička biometrija se koristi za prepoznavanje i autentikaciju ljudi na temelju fizičke jedinstvenosti, dok se biometrija ponašanja koristi za opisivanje fizikalnih karakteristika ljudskog tijela koje su tek djelomično jedinstvene za svaku pojedinu osobu.

Nadalje su navedene i opisane biometrijske tehnike koje se danas koriste kao jedna od vrsta autentikacije.

2.1.1. Čitanje DNK zapisa

Svako živo biće ima svoj jedinstveni DNK kod po kojem se razlikuje od svih ostalih bića i organizama. Očitavanjem DNK pojedinca, isti se uspoređuje s pohranjenim zapisom iz baze podataka, te je na taj način moguće provoditi autentikaciju korisnika prilikom pristupanja nekom sustavu ili prostoru. Kada se čitanje DNK zapisa kombinira s drugom biometrijskom tehnikom, dobiva se vrlo visok stupanj zaštite ukoliko se radi o ovlaštenoj osobi. Tehnike čitanja DNK zapisa se koriste kod provjere očinstva i utvrđivanja rodbinskih veza. [1]

Tehnologija i znanost biometrije, te tehnike čitanja DNK zapisa, je danas toliko napredovala da se danas u Hong Kongu koristi kako bi se smanjilo bacanje otpadaka na ulicu, tako što bi ljudi skupljali smeće bačeno na ulice, kao što su ćikovi, žvakaće gume, omoti od čokoladica i proveli ih kroz poseban softver koji koristi DNK s otpatka kako bi izradio model lica čovjeka koji bi bio isprintan i prikazan po posterima preko cijelog grada kao javna sramota. [4]

2.1.2. Skeniranje rožnice

Skeniranje rožnice je tehnika dosta raširena kod vođenja računa o evidenciji ljudi koji dolaze i napuštaju osigurani prostor u razne svrhe kao što su autentikacija, kako bi se omogućio ulaz samo ovlaštenim osobama, te za evidenciju statistike posjetitelja i slično. [1]

Prepoznavanje uzoraka se temelji na kameri koja snima očnu rožnicu kao identifikacijsku karakteristiku pojedinca, a moguće ju je opisati s 242 jedinstvene točke, dok je kod tehnike skeniranja otiska prsta, predložak moguće opisati sa 7 do 22 točke [1].

Prema [18] šansa da dva pojedinca imaju jednak uzorak rožnice je 1 naprema 10^{78}, što ovu tehniku čini pouzdanom.

2.1.3. Prepoznavanje lica

Prepoznavanje lica je jedna od jeftinijih biometrijskih tehnika za prepoznavanje osoba jer ne zahtjeva nikakvu preskupu opremu, dovoljno je računalo i kamera. Tehnika prepoznavanja lica se temelji na identifikaciji osobe s digitalnih fotografija, video zapisa i slično.

Prvi korak kod prepoznavanja lica je skeniranje odraza lica u različitim mjerilima, te razlikovanje odraza lica od odraza okoline. Sljedeća faza je faza određivanja položaja glave te izrade korekcija na temelju X, Y i Z osi. Što više fotografija osobe postoji, to je veća vjerojatnost prepoznavanja. [1]

2.1.4. Geometrija šake

Geometrija šake kao vrsta biometrijske tehnike za autentikaciju koristi mjere fizičkih karakteristika šake i prstiju, kao što su debljina, duljina, širina i površina šake. Kombinacija ove tehnike s tehnikom otiska prsta se često može vidjeti u raznim filmovima kao visoka razina sigurnosti i autentikacije prilikom ulaska u visoko čuvane sefove i slično [1].

Prema provedenom istraživanju [19], na skupini od par stotina tisuća ljudi, ova se tehnika pokazala kao povjerljiva i geometrija šake se može voditi kao jedinstveni identifikator čovjeka, ali na većoj populaciji, postoji šansa za dvoje pojedinaca koji imaju sličan oblik šake, pa na većim populacijama nije povjerljiva i ne može služiti kao jedinstveni identifikator.

2.1.5. Provjera vena

Provjera vena se koristi kao dio jedinstvenosti čovjeka zato što su nepromjenjive i uglavnom skrivene, a u kombinaciji s geometrijom šake ili tehnikom prepoznavanja otiska prsta postiže se visok stupanj autentikacije osobe. Kamere za provjeru vena najčešće koriste infracrveni senzor kako bi se raspoznali detalji koje ljudsko oko ne može vidjeti [1]. Snimka koja se dobije infracrvenom kamerom naziva se termogram, te je on jedinstven za svakog pojedinca [20]

2.1.6. Otisak prsta

Autentikacija otiska prsta se koristi već godinama, a primjer je to što svaka osoba prilikom izrade osobne iskaznice daje svoj otisak prsta kao osobni i jedinstveni identifikator. Svaki prst ima svoj jedinstveni otisak, a to se odnosi i na jednojajčane blizance.

Otisak prsta je jedna od najdostupnijih tehnologija za autentikaciju i dostupna je za stolna i prijenosna računala kako se ne bi trebala unositi zaporka [1].

Ovo je jedna od najrasprostranjenijih biometrijskih tehnika, koristi se u bankarstvu i na područjima plaćanja, jednostavnim pritiskom prsta na senzor za čitanje otiska prsta se potvrdi identitet pojedinca, te se omogući pristup autoriziranoj osobi. [21]

2.1.7. Prepoznavanje glasa

Prepoznavanje glasa spada pod biometriju ponašanja koje opisuje fizikalna karakteristika. Kako bi se korisnik autenticirao mora izgovoriti prethodno postavljenu lozinku koja je spremljena u bazi podataka. Izgovorena lozinka se provjerava s lozinkom u bazi podataka, uzimajući u obzir brzinu, prekide, tonalitet i slično i ukoliko se podaci podudaraju autentikacija je izvršena i osoba je autenticirana [1].

Ova tehnika nije jako pouzdana jer bi neka neovlaštena osoba mogla snimiti ovlaštenu osobu i tako ući u prostor ili sustav u koji ne bi smjela. Stoga se uz tehniku prepoznavanja glasa koriste i druge biometrijske tehnike kako bi se povećala sigurnost.

2.1.8. Prepoznavanje rukopisa ili potpisa

Tehnika prepoznavanja rukopisa ili potpisa koristi dinamičku analizu kako b se autentificirala osoba. Temelji se na mjerenju brzine, pritiska i kuta koje osoba koristi prilikom potpisivanja ili prilikom nespecificiranog teksta [1].

2.1.9. Dinamika tipkanja

Dinamika tipkanja je tehnika koja se razvila tijekom drugog svjetskog rata kod radiotelegrafista kako bi se mogli razlikovati pošiljatelji poruka. Danas se dinamika tipkanja odnosi na dinamiku tipkanja po tipkovnici. Glavna karakteristika ove tehnike je vremenski razmak između svakog pritiska tipke na tipkovnici [1] [22].

2.1.10. Dinamika hoda

Karakteristika tehnike dinamike hoda je to što nije jedinstven za svakog pojedinca, ali precizno prikazuje karakter i situaciju osobe u kojoj se nalazi, te precizno pokazuje zdravstveno stanje osobe. Dinamika hoda se dobiva preko video zapisa, zatim se analizira i mogu se prepoznati navedene karakteristike. [1] [22]

3. Sličnosti osoba u rodbinskim vezama

Prepoznavanje rodbinskih veza je pojedinčeva sposobnost razlikovanja bliskih genetičkih srodnika od osoba koje nisu u nikakvom krvnom srodstvu s pojedincem.

Prema Hrvatskom leksikonu [22], „Srodstvo je povezanost osoba na osnovi fizioloških, pravnih, moralnih ili drugih činjenica“. U ovom radu naglasak će biti na povezanosti osoba na osnovi fizioloških činjenica, te odrediti jesu li dvoje pojedinaca u rodbinskoj vezi ili nisu.

Prilikom rođenja djeteta, često se događa da roditelji, prijatelji i rodbina gledaju u dijete i raspravljaju sliči li dijete više na majku ili oca i s relativnom točnošću ljudsko oko može prepoznati koje je karakteristike dijete naslijedilo od majke, odnosno koje je naslijedilo od oca.

Sljedeća situacija je usporedba brata i sestre, brata i brata ili sestra i sestre, u nekim slučajevima se teško može prepoznati jesu li oni u krvnom srodstvu ili nisu, jer se može dogoditi da jedan od članova naslijedi više karakteristika jednog od roditelja, a drugi član od drugog. U tom slučaju ni ljudsko oko ne može odrediti jesu li ili nisu oni u rodbinskoj vezi.

Znanost o nasljeđivanju naziva se genetika. Gregor Mendel je začetnik genetike, on je bio redovnik koji je uzgajao u vrtu povrće za potrebe samostana. Za genetiku je najvažnije to što je uzgajao grašak, odnosno oprašivao je grašak različitim bojama cvijeća, te je primijetio kako se pojavljuju neka nova svojstva, naslijeđena svojstva, kroz daljnje generacije grašaka. Moderna genetika se razvila na tim njegovim pretpostavkama o nasljeđivanju.

Što se tiče ljudi, svaki čovjek je naslijedio neke facijalne karakteristike svojih roditelja. I u ovom radu će biti riječ o pronalaženju uzoraka tih facijalnih karakteristika kroz razne algoritme.

4. Upotreba računala kod utvrđivanja rodbinskih veza putem slike lica

Kako bi računalo moglo prepoznati i verificirati rodbinsku vezu među pojedincima na dvoma slikama lica, mora imati fokus na ključnim točkama koje uspoređuje i pronalazi sličnosti među njima.

Korišteni skup podataka je KinFaceW-I i KinFaceW-II [16], to su skupovi podataka koji su javno dostupni i sadrže nekoliko stotina lica javnih ličnosti i njihove djece. Podaci su prikupljeni bez ograničenja u ekspresijama lica, pozicije gledanja, godina, rase i sl. i namijenjeni su kao pomoć za učenje o verifikaciji rodbinskih veza.

Svaki od skupa podataka sadrži četiri datoteke koje su ograničene na četiri različite obiteljske veze: Otac – Sin, Otac – Kćer, Majka – Sin i Majka – Kćer. Svaka slika sadrži izrezanu sliku lica, poravnatu i dimenzija 64x64. Radi jednostavnijeg treniranja neuronske mreže, kreirane su dvije datoteke. Jedna koja sadrži osobe koje jesu u obiteljskim vezana, i jedna u kojoj nisu osobe u obiteljskim vezama. U datoteci u kojoj su osobe u srodstvu, uzimani su parovi slika lica i pomoću izrađene skripte su povezivane jedna s drugom, dok su u drugoj datoteci povezivani parovi slika koji nisu u obiteljskoj vezi.

Na slici ispod, prikazane su, redom, poravnate i izrezane slike lica iz skupa podataka KinFaceW-I obiteljske veze: otac – kćer, otac – sin, majka – kćer, majka – sin.



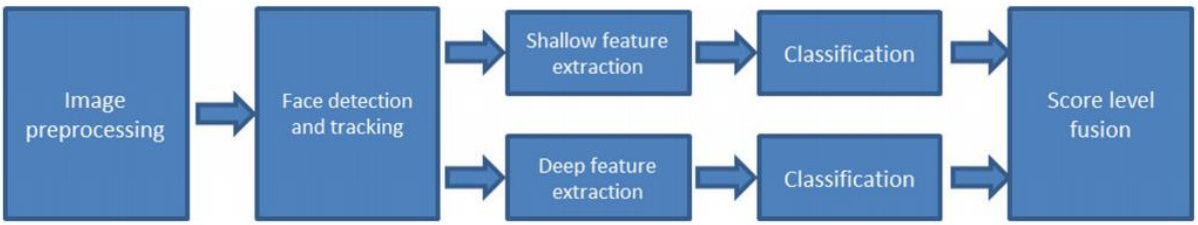
Slika 2 Slika iz KinFaceW-I skupa podataka

Na slici ispod, prikazane su, redom, poravnate i izrezane slike lica iz skupa podataka KinFaceW-II obiteljske veze otac – sin, otac – kćer, majka – kćer, majka – sin.



Slika 3 Slika iz KinFaceW-II skupa podataka

Kako je prikazano na slici 3, korišteni pristup se sastoji od pet glavnih koraka. Počinje se s prepoznavanjem, rezanjem i poravnavanjem slike lica na osnovi koordinata očiju i ostalih facijalnih karakteristika. Zatim se izdvajaju dvije vrste deskriptora, plitke prostorno-vremenske (engl. Spatiotemporal feature) teksture i duboka ekstrakcije tekstura, zatim klasifikacija i pregled rezultata [11].



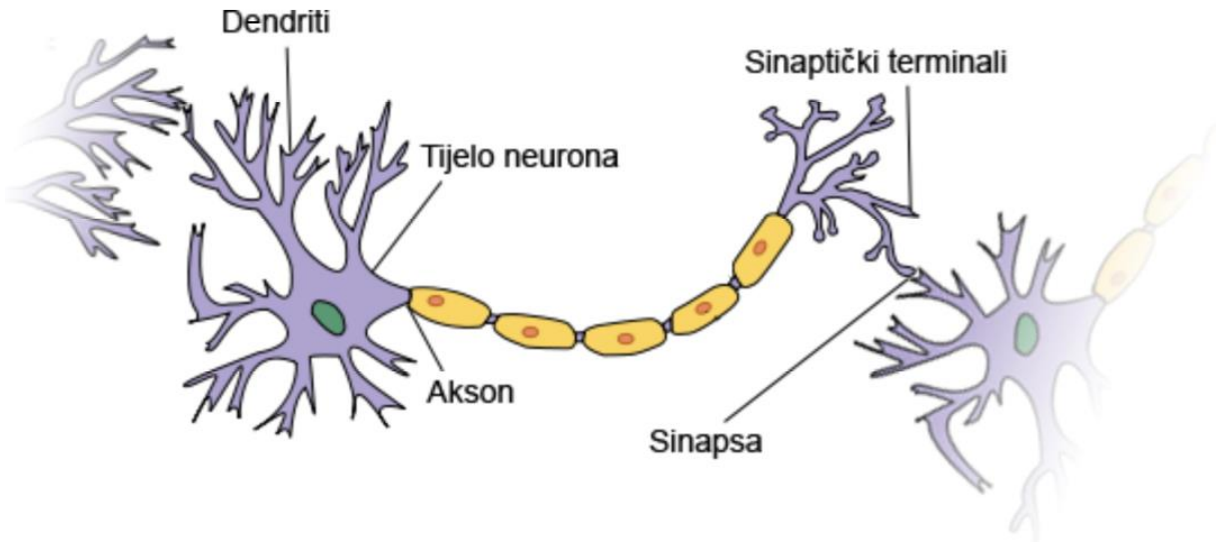
Slika 4 Prikaz metodologije za automatsku verifikaciju rodbinskih veza [11]

5. Umjetna neuronska mreža za utvrđivanje rodbinskih veza na temelju slike lica

Kako bi utvrdili postojanje rodbinske veze na temelju slike lica, računalo mora najprije pronaći i izvući lice sa slike. Postoje brojne metode kojima je to moguće. Opći postupak kojim se radi identifikacija, odnosno verifikacija slike lica je sljedeća. Prvo se radi segmentacija, odnosno detekcija lica iz slike, zatim slijedi ekstrakcija, odnosno izvlačenje ključnih značajki s područja lica i tek onda slijedi prepoznavanje, odnosno verifikacija.

Neuronska mreža je skup algoritama koji su napravljeni po modelu ljudskog mozga kako bi mogle prepoznavati uzorke i pronalaziti sličnosti, odnosno razlike. Uzorci koje prepoznaje su vektori koji sadrže numeričke podatke koji predstavljaju podatke iz stvarnosti i koji ne moraju biti u linearnoj vezi.

Ljudski mozak se sastoji od oko 10^{11} neurona i to je najsloženija jedinica u ljudskom organizmu. Neuron je glavni tip stanica od kojih se sastoji mozak. Na slici 4. prikazana je struktura neurona. [9]

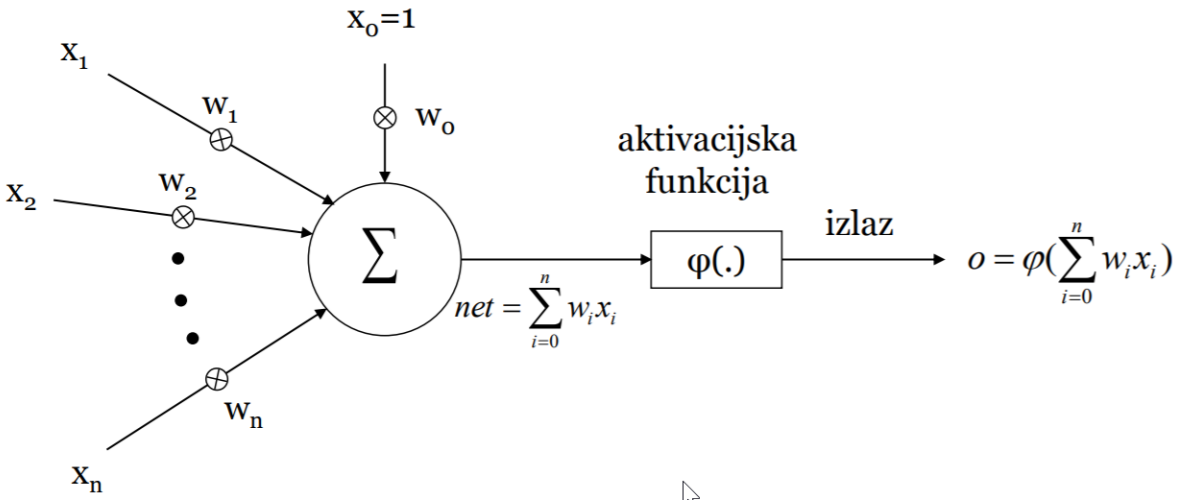


Slika 5 Struktura neurona

Kao što je vidljivo na slici 4. neuron se sastoji od pet dijelova, a to su: dendriti koji predstavljaju krajeve stanica i primaju signale od drugih neurona; aksona koji prenose elektroničke poruke, odnosno impulse do sinaptičkih terminala, odnosno telodendrona, soma koji predstavlja tijelo stanice i sinapse koja predstavlja mjesto komunikacije među dvama neuronima. Kada jedan dendrit zaprimi signal od drugog neurona, šalje te signale na

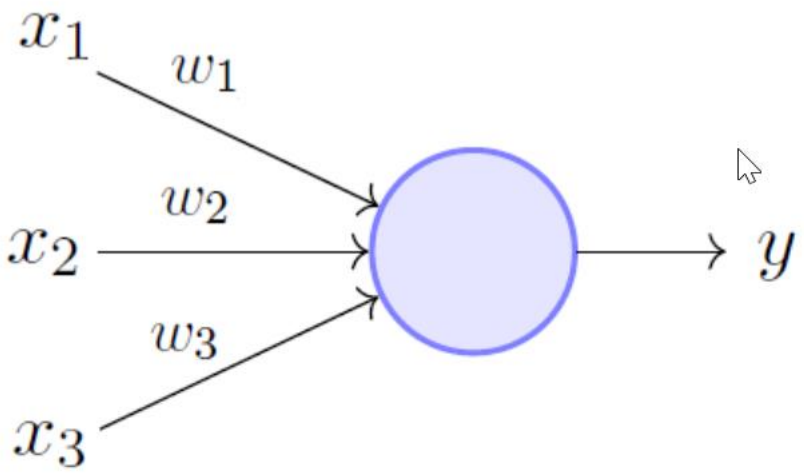
dendrite idućeg neurona preko aksona koji šalje te signale na sinaptički terminal i neuron taj signal zaprima na dendritu.

McCulloch-Pittsov modle neurona iz 1943. godine [10], koji predstavlja umjetni „ekvivalent“ neuronu, a sastoji se on više ulaza koji imaju svaki svoj težinski faktor koji je normaliziran kao (0,1) ili (-1,1). Na slici 5. prikazan je McCulloch-Pittsov model neurona. Sličnost umjetnog neurona s biološkim neuronom je sljedeća. Signali su numeričke vrijednosti, odnosno ulazi, jakost sinapse, odnosno mjesto komunikacije predstavlja težinski faktor (W_n), tijelo neurona predstavlja zbroj svih težinskih faktora od svakog od ulaza (∑), a akson predstavlja aktivacijska funkcija (φ).



Slika 6 McCulloch-Pitts model neurona [10]

Najjednostavniji oblik neuronske mreže je perceptron. To je umjetni neuron s funkcijom praga kao aktivacijskom funkcijom. Model perceptrona osmislili su Minsky i Papert 1969. [11] i ima širu upotrebu nego McCulloch-Pittsov neuron. Ulazi nisu više ograničeni na dualnu vrijednost (0 ili 1, -1 ili 1) već podržava stvarni ulaz i s time se može primijeniti u više slučajeve. Model je prikazan na slici 6.



Slika 7 Model perceptrona (Minsky-Papert 1969.)

Svaki neuron se sastoji od n ulaza i samo jednog izlaza. Kao i kod McCulloch-Pittsovog neurona, svaki od ulaza ima svoj težinski faktor, ti se težinski faktori množe sa svojim ulazima i, te se njihovim sumama dodaje pomak (engl. *bias)* [10].

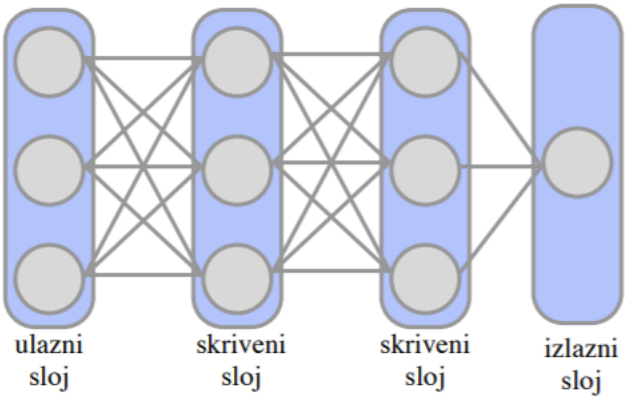
Kada pomnožimo sve inpute s korespondirajućim težinskim faktorima i nakon dodanog pomaka, rezultat se uspoređuje s parametrom *t* (engl. threshold). Parametar *t* predstavlja realan broj na kojem će se neuron aktivirati, odnosno rezultat sume umnožaka ulaza biti će 1 samo ako je suma umnožaka ulaza veća od *t*. Umjesto da računamo parametar *t*, dodajemo ga kao jedan od ulaza sa težinskim faktorom *–t*, što mu daje mogućnost učenja [11].

5.1.1. Struktura neuronske mreže

Kao što je navedeno, neuronska mreža se sastoji od velikog broja međusobno povezanih jedinica, odnosno neurona koji rade paralelno kako bi izvršili neki zadatak, odnosno kako bi pronašli poveznice između ulaza i izlaza ili kako bi pronašli povezane uzorke među podacima.

Neuronska mreža se sastoji od 3 tipa slojeva: ulazni sloj, skriveni sloj i izlazni sloj [13]. Mreža može imati jedan ili više ulaza, ali samo jedan izlaz. Između ulaznih i izlaznih slojeva nalazi se jedan ili više skrivenih slojeva. Skriveni slojevi se nazivaju i detektori značajki.

Ulazni sloj prikuplja podatke, skriveni sloj te podatke pregledava i pronalazi samo one bitne značajke, te pokušava otkriti koja je svrha, odnosno koja je poveznica ulaznih podataka, te onda te podatke šalje na drugi skriveni sloj, ukoliko se radi o višeslojnim mrežama i tako sve dok se ne dođe rješenja problema. Struktura jednostavne neuronske mreže je prikazana na slici 7.



Slika 8 Struktura jednostavne neuronske mreže [13]

5.1.2. Aktivacijske funkcije

Kao što je navedeno, vrijednost izlaza mreže može biti bilo koji broj od -∞ do +∞, neuron zapravo ne zna u kojim su granicama vrijednosti izlaza i upravo zbog toga su uvedene aktivacijske funkcije, kako bi provjerile vrijednost izlaza i odlučile treba li aktivirati neuron ili ne [13].

$$Y = \sum(\text{težinski } faktor * ulaz) + bias$$

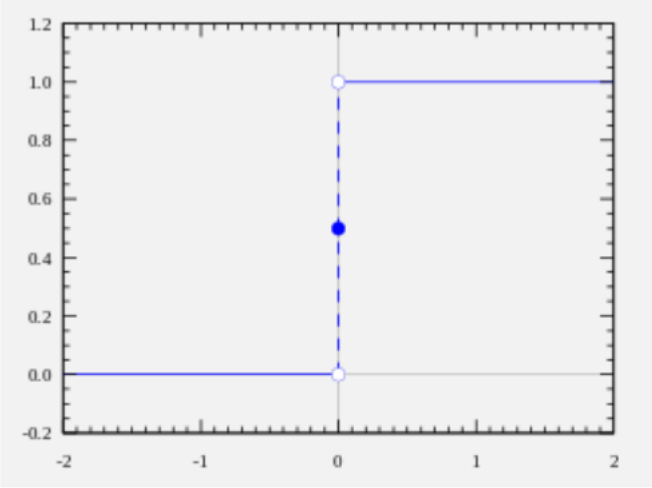
5.1.2.1. Step funkcija

Step funkcija je najjednostavnija aktivacijska funkcija. Neuron se aktivira i šalje signal samo ukoliko je izlaz (Y) veći od neke težine *t*, ukoliko je izlaz manji od težine *t* onda ga ne aktivira.

Step funkcija se nije pokazala kao dobra u praksi jer je gotovo nemoguće izgraditi klasifikator koji radi za više klasa. [12]

Aktivacijska funkcija F za *t = 0* bi izgledala ovako:

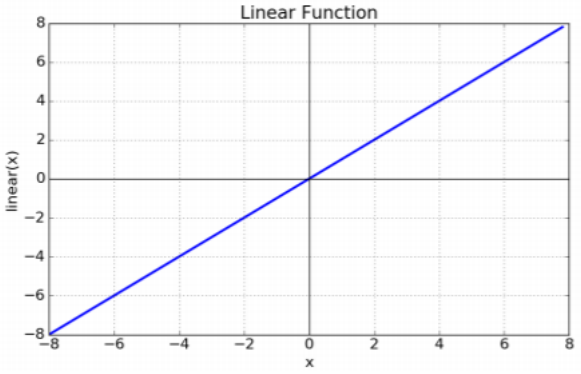
$$F(Y) = \begin{cases} 1, ako\ je\ Y \geq 0 \\ 0, ako\ je\ Y < 0 \end{cases}$$



Slika 9 Grafički prikaz Step funkcije [13]

5.1.2.2. Linearna funkcija

Linearna funkcija je oblika $F(x) = kx$, gdje je $k \in \mathbb{R}$. Linearna funkcija predstavlja ravnu liniju funkcije, gdje je aktivacija neurona proporcionalna ulazu. Zato što je aktivacija neurona proporcionalna ulazu postoji veći raspon vrijednosti koje bi aktivirale neuron i zato više nemamo binarnu aktivaciju [14].

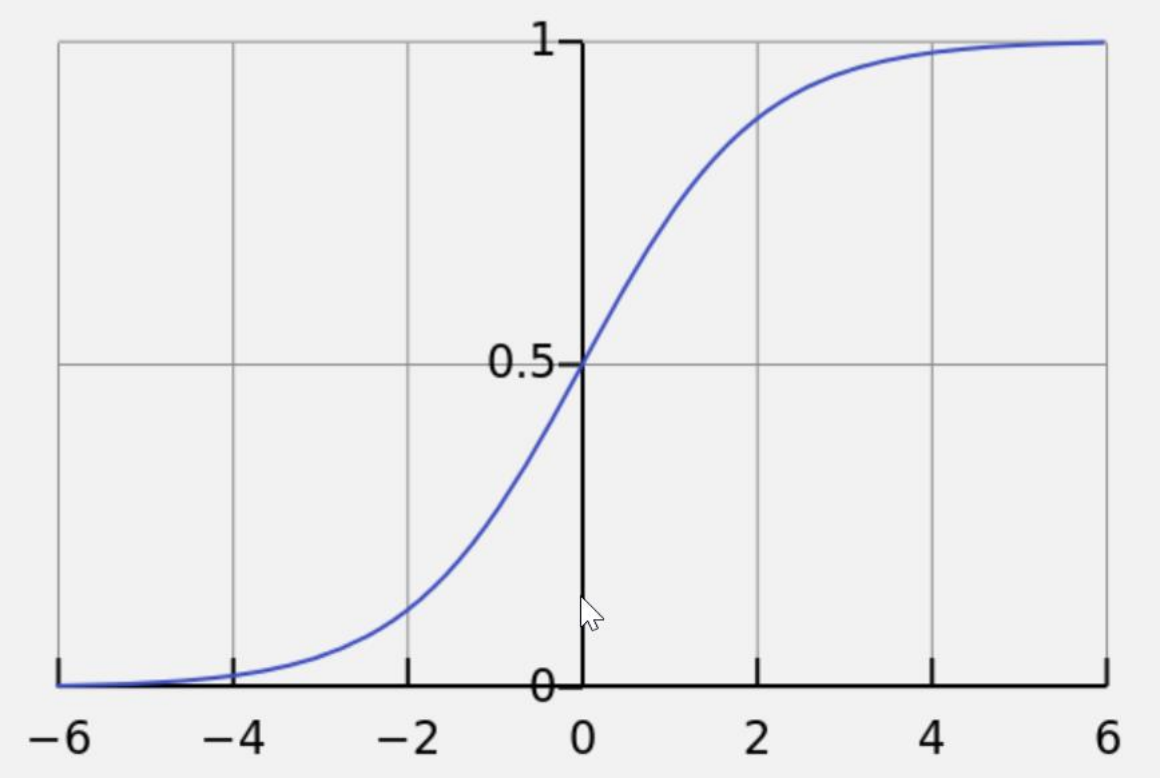


Slika 10 Grafički prikaz linearne funkcije [14]

Problem koji nastaje kod ove funkcije je ukoliko spojimo te funkcije, opet dobivamo novu linearnu funkciju.

5.1.2.3. Sigmoidalna funkcija

$$F = \frac{1}{1 + e^{-x}}$$



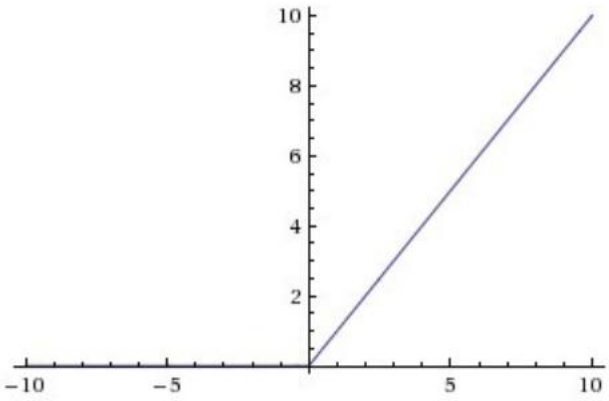
Slika 11 Grafički prikaz sigmodialne funkcije

Sigmodialna funkcija je slična Step funkciji, ali nema oštre prijelaze, što omogućuje svojstvo nelinearnosti, što znači da ukoliko spojimo više kombinacija ove iste funkcije i dalje će vrijediti svojstvo nelinearnosti. Još jedna prednost naspram linearne funkcije je što je izlaz uvije između 0 i 1, dok je kod linearne između -∞ i +∞ [13] [14].

5.1.2.4. ReLu funkcija

ReLu (engl. *Rectified linear unit*) je definirana formulom:

$$F(Y) = \begin{cases} 1, ako\ je\ Y < 0 \\ 0, ako\ je\ Y \geq 0 \end{cases}$$



Slika 12 Grafički prikaz ReLu funkcije

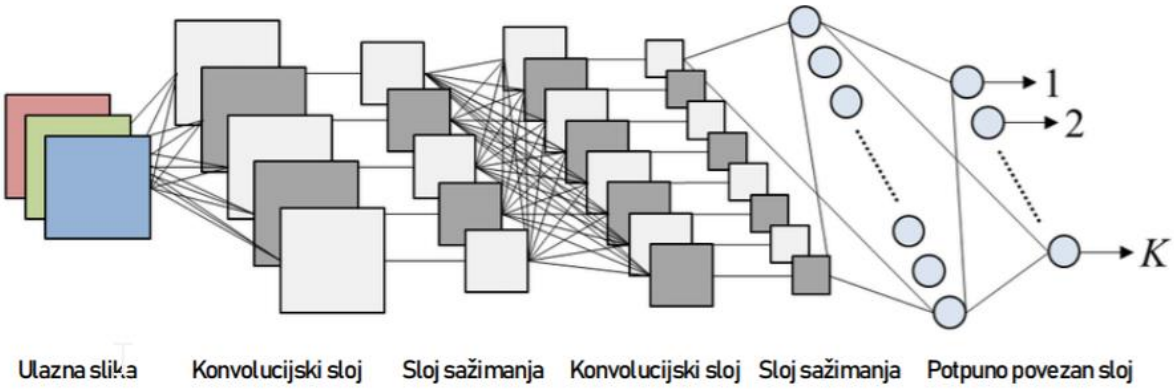
Radi horizontalne linije na negativnoj strani X osi, gradijent može poprimiti 0, što znači da će ti neuroni koji idu u stanje nule, prestati odgovarati varijacijama kod pogrešnog ulaza, pošto je gradijent 0 ništa se ne mijenja i to se naziva umirući ReLu problem. [13].

5.1.3. Konvolucijske neuronske mreže

Konvolucijske mreže su nastale kao nadogradnja za obične višeslojne neuronske mreže. One se, također, sastoje od tri sloja, jednog ulaznog, jednog izlaznog te jednog ili više skrivenih slojeva [13].

Najčešće se koriste kod klasifikacije slika i njihove podjele prema sličnostima. Može se reći da su konvolucijske neuronske mreže skup algoritama za detekciju lica, pojedinaca, prometnih znakova, tumora i mnogih drugih sličnih podataka koji se mogu postići vizualizacijom.

Efikasnost konvolucijskih neuronskih mreža u prepoznavanju slika jedan je od glavnih razloga poticanja interesa javnosti oko efikasnosti dubokog učenja. Najnovije tehnologije u autoindustriji, robotici, medicini i dr. koriste konvolucijske mreže kako bi poboljšali i automatizirali poslove koje su prije ljudi radili, odnosno kako bi uklonili mogućnost ljudske pogreške. U autoindustriji su prilikom proizvodnje automobila koji sami voze ugradili algoritme konvolucijskih neuronskih mreža kako bi automobili mogli prepoznavati prometne znakove i to s vrlo visokom preciznošću [13].



Slika 13 Konvolucijska neuronska mreža [24]

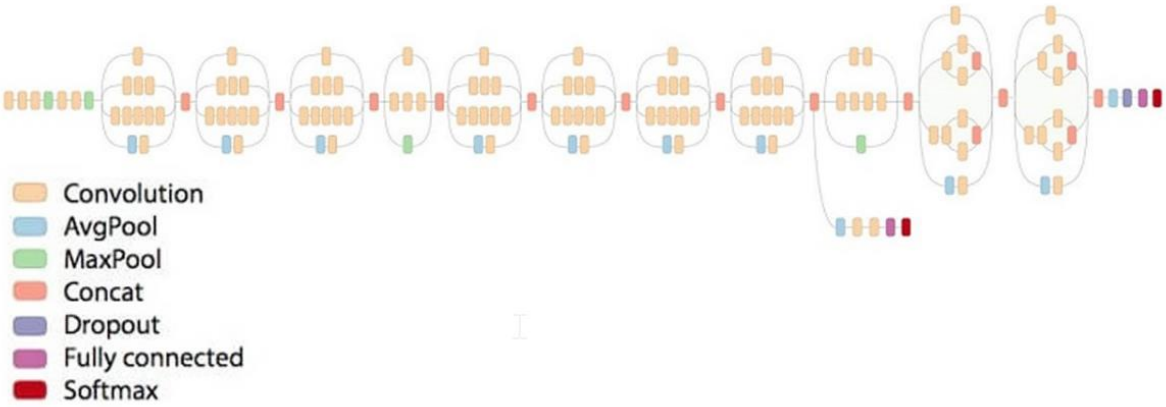
Razlika konvolucijskih od drugih vrsta neuronskih mreža je ta što konvolucijske mreže imaju konvolucijske slojeve i slojeve sažimanja. Konvolucijske mreže kreću s konvolucijskim slojem, zatim ide sloj sažimanja, pa ponovo konvolucijski sloj i tako nekoliko puta dok ne završi s jedim ili više potpuno povezanih slojeva za klasifikaciju, kao što je prikazano na slici 12.

Konvolucijski sloj se sastoji od filtara, svaki od tih filtara sadrži težinu koju je potrebno naučiti kako bi mreža dala dobre rezultate. Filteri su manjih dimenzija od ulaza, ali su uvijek jednakih dimenzija kao izlaz. [14]

Sloj sažimanja se koristi nakon konvolucijskih slojeva kako bi se smanjila rezolucija mapa i povećala prostorna neosjetljivost na manje pomake značajki u uzorku neuronske mreže [14].

5.1.4. Google Inception-v3

Prema [15], Google Inception je najefikasnija arhitektura dubokih neuronskih mreža jer koristi učenje prijenosom (engl. *transfer learning)* koji omogućuje ponovno treniranje finalnog sloja postojećeg modela, što rezultira drastičnom smanjenju i vremena treniranja i količine podataka za treniranje. Ponovo učenje samo finalnog sloja znači da mreža može zadržati znanje koje je prethodno naučila i primijeniti to znanje na manji skup podataka, što rezultira većom točnošću. Arhitektura Google Inception-v3 je prikazana na slici ispod. [15]



Slika 14 Arhitektura Google Inception-v3 [15]

Arhitektura se sastoji od 22 sloja konvolucijske mreže što rezultira smanjenjem rojem parametara sa 60 milijuna na 4 milijuna. [16]

6. Aplikativni prikaz utvrđivanja rodbinskih veza putem slike lica

Praktični dio rada je napraviti aplikaciju u kojoj se može utvrditi postojanje rodbinske veze između odabranih pojedinaca. Korišteni algoritam je, ranije opisani, Google Inception-v3 konvolucijska mreža koja je preuzeta s TensorFlow-a i implementirana od strane Google-a. [16]

6.1. Skup podataka

Korišteni skup podataka je KinFaceW-I i KinFaceW-II koji je javno dostupan kako bi poticao javnost na veće istraživanje o verifikaciji rodbinskih veza. Svaki od skupova sadrži po četiri datoteke s rodbinskim vezama koje su limitirane na: otac – sin, otac – kćer, majka – sin, majka – kćer. Svaka od datoteka sadrži po oko 150 parova slika, što čini sve skupa 600 parova slika, dimenzija 64x64, po skupu podataka, odnosno 1200 slika po skupu podataka. Podaci su prikupljani s videa na YouTube-u, te s govora javnih ličnosti i njihovih obitelji.

95% skupova podataka KinFaceW-I i KinFaceW-II su korišteni za treniranje mreže, a ostalih 5% po skupu podataka su korišteni za testiranje. Na slici ispod prikazane su slike, redom, majka – kći, otac – sin, majka – sin, otac – kći.

U praktičnom dijelu problem je nastao zbog parova slika, Google Inception-v3 pretpostavlja kao ulaz jednu sliku, a aplikacija je zamišljena da ulaz budu dvije slike. Napravljena je skripta u programskom jeziku Python 3.6.8 koja prolazi kroz datoteku u kojoj se nalaze slike lica i spaja parove u jednu sliku dimenzija 128x64.

Spojeni parovi slika, koji su u rodbinskoj vezi, pohranjeni su u datoteku Related, a spojeni parovi slika koji nisu u rodbinskoj vezi, pohranjeni su u datoteku NotRelated.

6.2. Korištene tehnologije

Kao što je navedeno, treniranje mreže je napravljeno pomoću konvolucijske mreže Inception-v3. Korištena je gotova istrenirana mreža implementirana pomoću TenserFlow-a. Preuzeta skripta je istrenirana nad skupovima KinFaceW-I i KinFaceW-II, skup koji je prethodno opisan.

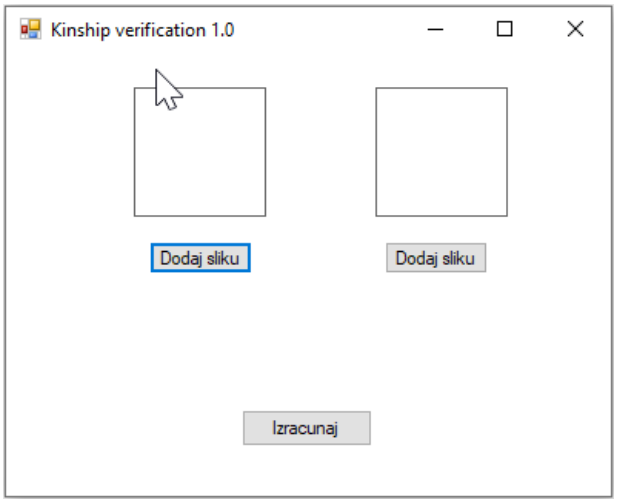
Prilikom treniranja neuronske mreže dogodio se problem što je računalo, na kojem se radilo treniranje mreže, pregrijavalo radi povećanog korištenja resursa, pa je bilo potrebno koristiti službeni laptop koji ima jači procesor i više radne memorije, pa je s time problem riješen.

Grafičko sučelje je izrađeno u Visual Studio 2019 u programskom jeziku C# i izrađena je desktop aplikacija koja će biti objašnjena u sljedećem poglavlju.

6.3. Praktični rad – Aplikacija za utvrđivanje rodbinskih veza na temelju slike lica

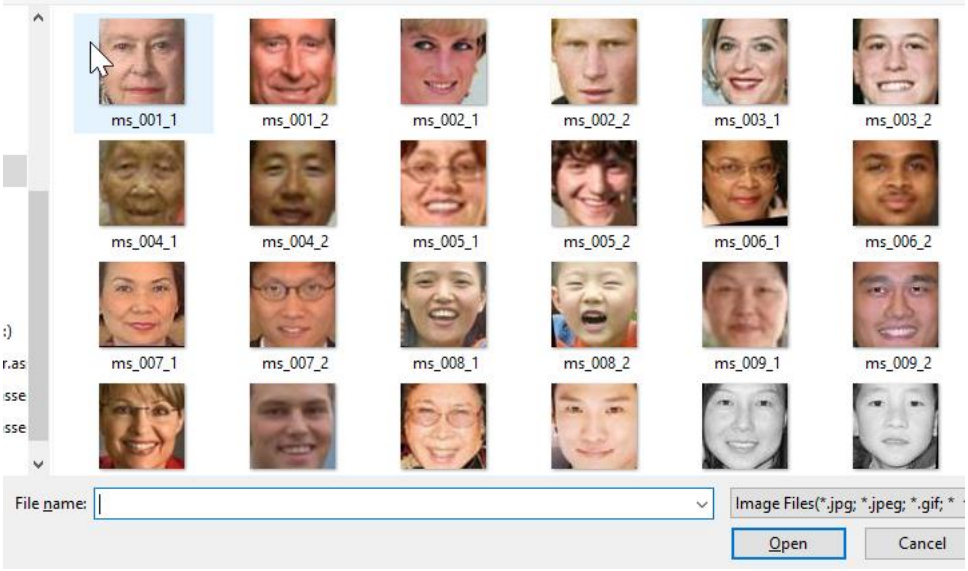
Praktični dio rada je izrađen u Visual Studio 2019 u programskom jeziku C# kao desktop aplikacija. Prilikom pokretanja, korisniku se otvara jednostavan prozor u kojem pritiskom na gumb „Odaberi sliku“ izabire jednu, pa zatim drugu sliku lica i pritiskom na gumb „Izračunaj“ u pozadini se pokreće, prethodno objašnjena, skripta koja koristi prethodno istreniranu Inception-v3 konvolucijsku mrežu za prepoznavanje rodbinskih veza.

Prilikom pokretanja aplikacije, prikaže se jednostavna forma prikazana na slici 15.



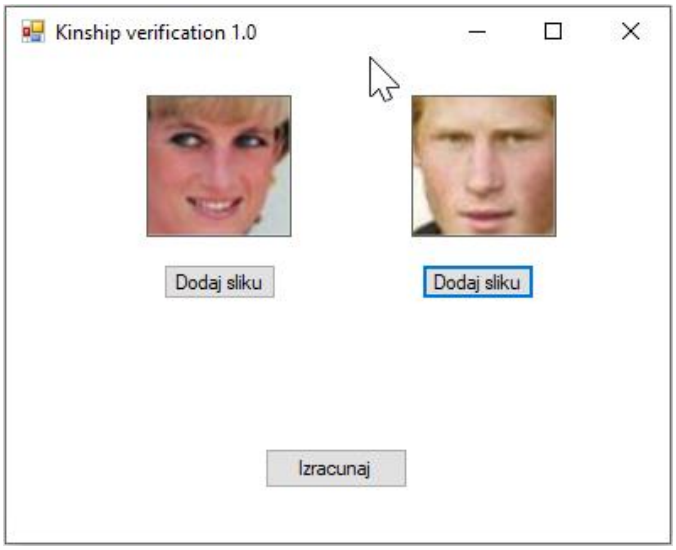
Slika 15 Prikaz glavnog izbornika

Korisnik odabirom gumba dodaj sliku dodaje slike lica osoba kojima želi utvrditi rodbinsku vezu. Kada se odabere gumb „Dodaj sliku“ otvara se izbornik i odabire se željena slika. Prikaz odabira slike prikazan je na slici 16.



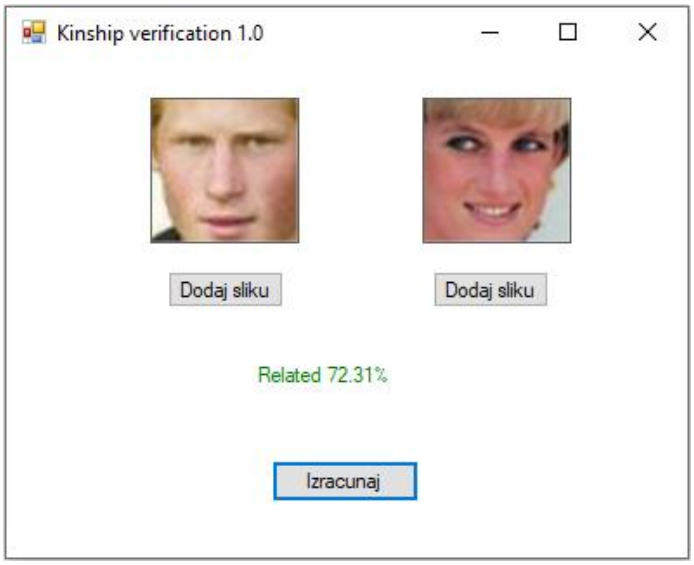
Slika 16 Odabir slike lica

Odabire se željena slika i pritišće se gumb „Open“. Nakon što se odaberu obje slike, glavni izbornik izgleda ovako:



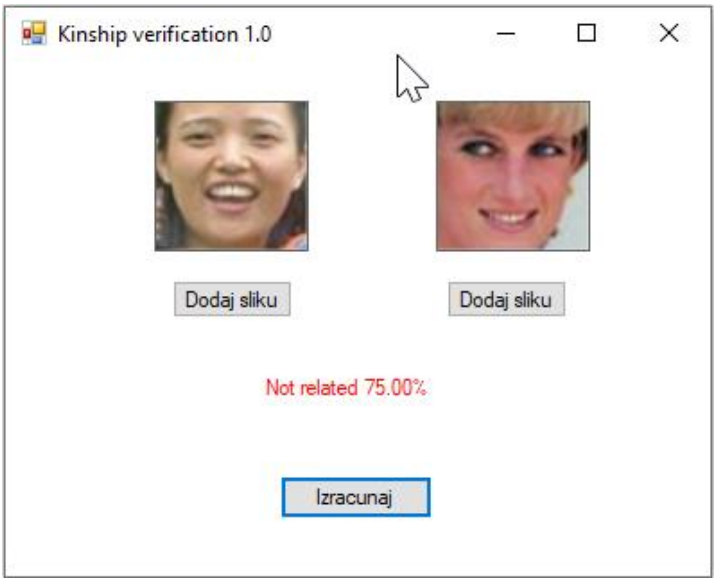
Slika 17 Prikaz nakon odabiranja slika lica

Nakon što su slike učitane, pritiskom na gumb „Izračunaj“ u pozadini se pokreće proces koji pokreće skriptu koja te dvije fotografije spaja u jednu, te spojenu fotografiju prosljeđuje istreniranoj konvolucijskoj neuronskoj mreži. Proces dobiva *output* od mreže i prikazuje ga korisniku, kako je prikazano na sljedećoj slici u slučaju rodbinske veze.



Slika 18 Prikaz rezultata mreže – u rodbinskoj vezi

Ukoliko mreža prepozna da nije riječ o rodbinskoj vezi, rezultat će biti sljedeći:



Slika 19 Prikaz rezultata mreže - nisu u rodbinskoj vezi

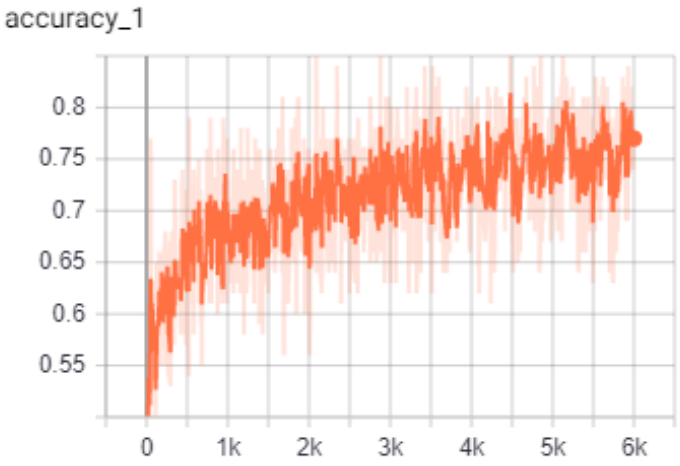
Mreža vrati rješenje jesu li u rodbinskoj vezi ili nisu (engl. *related, not related)* i postotak koji pripada rješenju. Grafički prikaz rezultata mreže obrađen je u sljedećem poglavlju.

6.4. Rezultati

Kod treniranja neuronske mreže, skup podataka je podijeljen u tri dijela. Dio za trening, validaciju i testiranje. Korišteni skup podataka je, kao što je navedeno u poglavlju 6.1, KinFaceW-I i KinFaceW-II, skupovi od oko 1200 slika osoba koje su u rodbinskoj vezi po skupu. 95% slika iz navedenih skupa je korišteno za trening, a 5% za validaciju. 5% skupova podataka KinFaceW-I i KinFaceW-II su korišteni za testiranje, što čini sve ukupno oko 120 slika za validaciju. Navedeni skupovi su korišteni kako bi povećali preciznost rezultata, te kako bi se dobila veća pouzdanost mreže.

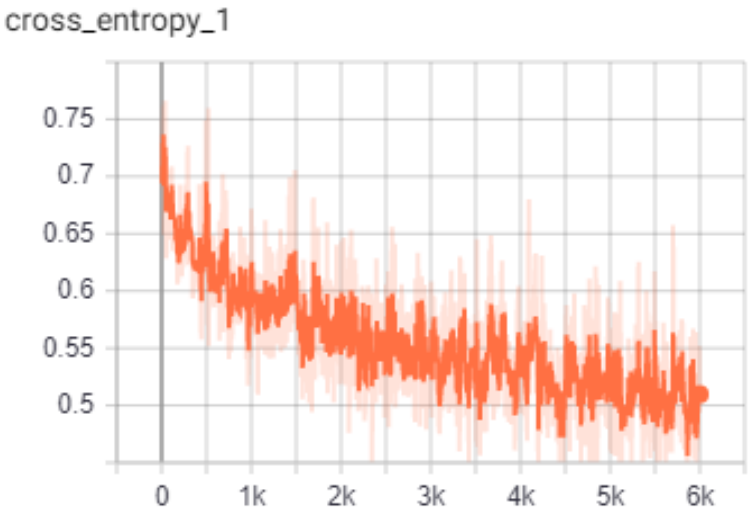
Skup za treniranje je skup na kojem se mreža uči i pronalazi uzorke među slikama kako bi mogla odrađivati poslove za koje je namijenjena. Taj skup se mora sastojati od najvećeg broja slika. Dio za validaciju služi kako bi mreža prilikom treninga mogla provjeravati točnost mreže i usklađivati dobivene parametre kako bi se dobili točniji rezultati. Skup za testiranje služi kako bi se već istrenirana mreža mogla testirati, odnosno provjeriti točnost mreže.

Dobiveni rezultati su prikazani na slikama ispod.



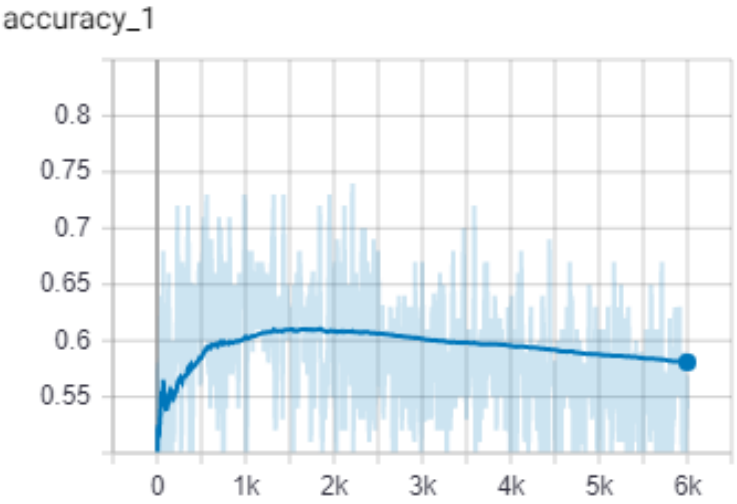
Slika 20 Prikaz točnosti treninga

Grafički prikaz točnosti treninga na slici 15 s brojem koraka raste, ali ne drastično koliko se očekivalo radi same složenosti zadatka.

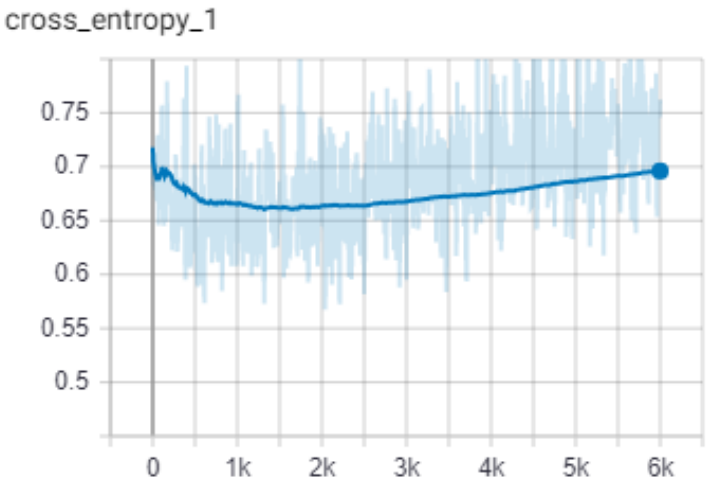


Slika 21 Prikaz gubitaka tijekom treninga

Slika 16 prikazuje gubitke tijekom treninga koji s brojem koraka opadaju, što je i očekivano. Što je koeficijent gubitka manji, to je točnost mreže veća. Nadalje su prikazani grafovi s prikazima točnosti i koeficijent gubitka tijekom dijela validacije.



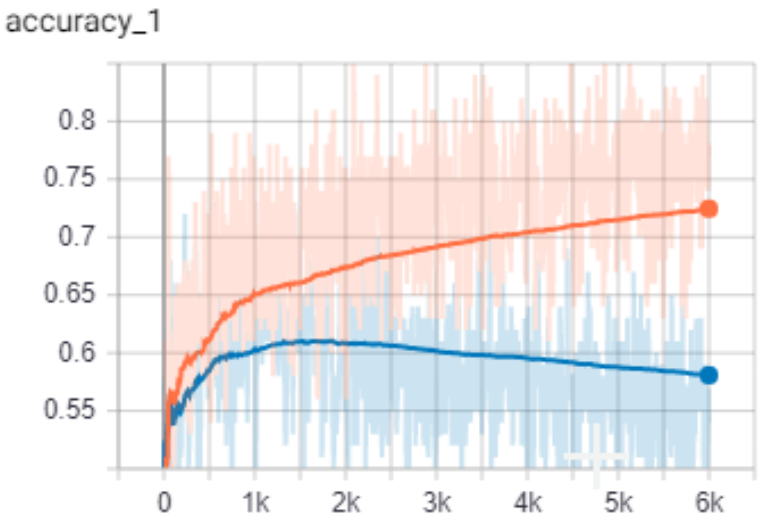
Slika 22 Prikaz točnosti validacije



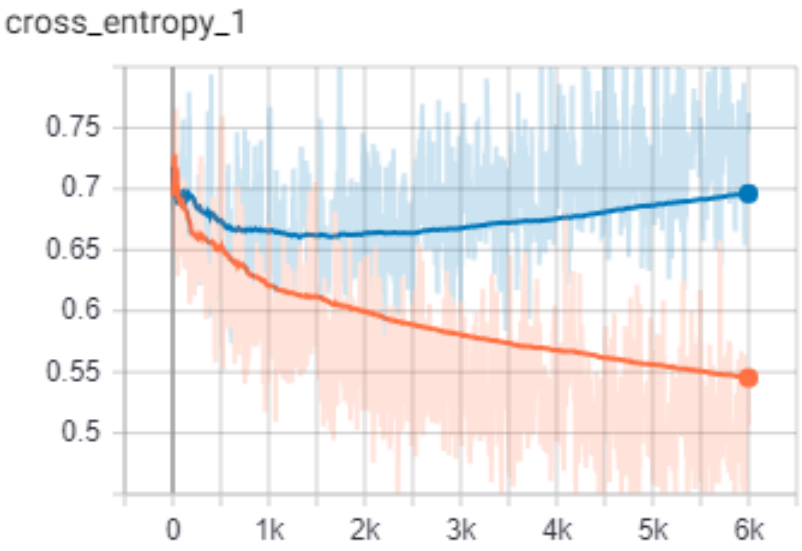
Slika 23 Prikaz gubitka tijekom validacije

Iz prikazanih grafova može se vidjeti sličnost prilikom dijela validacije i treninga. Prikazana odstupanja su se dogodila radi samog skupa podataka, jer postoji velika različitost među slikama. Neke slike su crno bijele, neke imaju veći stupanj crvene boje i slično.

Na grafovima ispod prikazana su preklapanja između grafova validacije i testiranja.



Slika 24 Usporedba grafova točnosti kod treninga i validacije



Slika 25 Usporedba grafova gubitka kod validacije i treninga

Iz prikazanih usporedbi grafova na slikama 19 i 20, može se vidjeti da su podjednake krivulje treniranja i validacije. Na prvim treniranjima točnost je bila relativno niska, oko 60%, pa je dodan skup KinFaceW-II za treniranje, što je skup za treniranje učinilo dvostruko većim, a time je postignuto povećanje krivulje točnosti za 15% i sad je točnost oko 75%.

7. Zaključak

U radu su opisani neki najvažniji pojmovi vezani za utvrđivanje rodbinskih veza na temelju slike lica. Opisana je i razrađena tema biometrije u kojoj je naglasak bio na biometrijskim tehnikama. U radu su korištene biometrijske tehnike za prepoznavanje lica preko duboke neuronske mreže, odnosno konvolucijskih neuronskih mreža.

Praktični dio rada sastojao se od jednostavne aplikacije koja u pozadini koristi skriptu te se ona pokreće prilikom unosa dvaju slika pojedinaca među kojima se pronalazi postojanje rodbinske veze. Nakon aplikacije, prikazani su dobiveni rezultati treniranja i validacije neuronske mreže. Analizom dobivenih rezultata utvrđeno je da postoji mjesta za napredak jer je točnost bila ispod očekivane. Točnost rada neuronske mreže bila je 75%, što je relativno nisko naspram ostalih mreža koje su javno dostupne.

Najveći izazov rada je bio povećati preciznost neuronske mreže, odnosno eksperimentirati s različitim brojem koraka korištenim za treniranje neuronske mreže, te eksperimentirati s različitim implementacijama neuronskih mreža.

Na samom kraju ovoga rada možemo zaključiti kako je utvrđivanje rodbinskih veza na temelju slike lica doista široka tema, ali je tek u početcima razvijanja. Nema puno javno dostupnih primjera gotovih mreža za ovaj konkretan slučaj. Tim stručnjaka koji se bave tom temom [17] izradili su skup podataka kako bi potakli veće zanimanje javnosti za obrađenu temu jer je ista svakako ima mjesta za napredak.

8. Literatura

[1] "Biometrija", lipanj 2006. [na internetu]. Dostupno na: https://www.cis.hr/www.edicija/LinkedDocuments/CCERT-PUBDOC-2006-11-167.pdf. [pristupano: 18.4.2019.].

[2] "Artificial intelligence | Definition, Examples, and Applications | Britannica.com," 18.5.2019. [na internetu]. Dostupno na: https://www.britannica.com/technology/artificial-intelligence. [pristupano: 18.5.2019.].

[3] "History of Biometrics | Biometric Update," 14.6.2019. [Na internetu]. Dostupno na: https://www.biometricupdate.com/201802/history-of-biometrics-2. [Pristupano: 14.6.2019.].

[4] TEDx Talks, *The business of biometrics | Madhumita Murgia | TEDxGateway*. 2019.

[5] "What is biometrics?," *IDEMIA*, [Na internetu]. Dostupno na: https://www.idemia.com/biometrics. [Pristupano: 23.6.2019.].

[6] K. Zhang, Y. Huang, C. Song, H. Wu, and L. Wang, "Kinship Verification with Deep Convolutional Neural Networks," in *Procedings of the British Machine Vision Conference 2015*, Swansea, 2015, pp. 148.1-148.12.

[7] "GitHub - HarshaVardhanP/KinShip-Verification-using-CNNs," 10.6.2019. [na internetu]. Dostupno na: https://github.com/HarshaVardhanP/KinShip-Verification-using-CNNs. [pristupano: 10.6.2019.].

[8] "A Beginner's Guide to Neural Networks and Deep Learning," *Skymind*, 18.5.2019. [na internetu]. Dostupno na: http://skymind.ai/wiki/neural-network. [pristupano: 18.5.2019].

[9] "Umjetne neuronske mreže" svibanj 2008. [Na internetu]. Dostupno na: https://www.fer.hr/_download/repository/UmjetneNeuronskeMreze.pdf . [Pristupano: 20.6.2019.]

[10] "2.3.1 The McCulloch-Pitts Model of Neuron," 18.4.2019. [na internetu]. Dostupno na: http://wwwold.ece.utep.edu/research/webfuzzy/docs/kk-thesis/kk-thesis-html/node12.html. [pristupano: 18.4.2019].

[11] A. C. Lagandula, "Perceptron: The Artificial Neuron (An Essential Upgrade To The McCulloch-Pitts Neuron)," *Towards Data Science*, 12.8.2018. [Na internetu]. Dostupno na: https://towardsdatascience.com/perceptron-the-artificial-neuron-4d8c70d5cc8d. [Pristupano: 20.6.2019.].

[12] A. S. V, "Understanding Activation Functions in Neural Networks," *Medium*, 30.3.2017. [Na internetu]. Dostupno na: https://medium.com/the-theory-of-

everything/understanding-activation-functions-in-neural-networks-9491262884e0. [Pristupano: 23.6.2019].

[13] "Konvolucijske neuronske mreže", D. Kopljar, srpanj 2016. [na internetu]. Dostupno na: http://ferko.fer.hr/ferko/EPortfolio!dlFile.action;jsessionid=42FAF2BB2A7E915516D462A818D598F3?id=350. [pristupano: 20.5.2019]

[14] "ResNet, AlexNet, VGGNet, Inception: Understanding various architectures of Convolutional Networks," *CV-Tricks.com*, 09.8.2017. [Na internetu]. Dostupno na: https://cv-tricks.com/cnn/understand-resnet-alexnet-vgg-inception/. [Pristupano: 20.6.2019.].

[15] S. Das, "CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more ….," *Medium*, 20.5.2019. [na internteu]. Dostupno na: https://medium.com/@sidereal/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5. [pristupano: 20.5.2019.].

[16] "KinFaceW: Kinship Face in the Wild database," 14.6.2019. [Na internetu]. Dostupno na: http://www.kinfacew.com/. [Pristupano: 14.6.2019].

[17] "Biometric authentication (What is biometrics?) | 2019 Review - Gemalto." [Na internetu]. Dostupno na: https://www.gemalto.com/govt/inspired/biometrics. [Pristupano: 14.6.2019].

[18] "Biometric authentication (What is biometrics?) | 2019 Review - Gemalto." [Na internetu]. Dostupno na: https://www.gemalto.com/govt/inspired/biometrics. [Pristupano: 24.6.2019].

[19] "Biometric Eye Scans | Encyclopedia.com." [Na internetu]. Dostupno na: https://www.encyclopedia.com/science/encyclopedias-almanacs-transcripts-and-maps/biometric-eye-scans. [Pristupano: 24.6.2019].

[20] Degordian (http://www.degordian.com), "Biometrija i otisci prstiju - Revolucija u plaćanju - Mercury Processing," *Mercury Processing Services International*, 13.7.-2017.

[21] Ž. Radmilović, „Biometrijska identifikacija", kolovoz 2008.

[22] "leksikon Hrvatska enciklopedija." [Na internetu]. Dostupno na: http://www.enciklopedija.hr/natuknica.aspx?id=35939. [Pristupano: 15.6.2019].

[23] "Hand Geometry Recognition Biometrics," *Bayometric*, 27.11.2018.

[24] "An example of CNN architecture. | Download Scientific Diagram." [Na internetu]. Dostupno: https://www.researchgate.net/figure/An-example-of-CNNarchitecture_fig1_320748406. [pristupano 24.6.2019].

Sadržaj slika

Slika 1 Prikaz učestalosti korištenja biometrijske tehnologije [1] 2
Slika 2 Slika iz KinFaceW-I skupa podataka 8
Slika 3 Slika iz KinFaceW-II skupa podataka 9
Slika 4 Prikaz metodologije za automatsku verifikaciju rodbinskih veza [11] 9
Slika 5 Struktura neurona 10
Slika 6 McCulloch-Pitts model neurona [10] 11
Slika 7 Model perceptrona (Minsky-Papert 1969.) 12
Slika 8 Struktura jednostavne neuronske mreže 13
Slika 9 Grafički prikaz Step funkcije [13] 14
Slika 10 Grafički prikaz linearne funkcije 15
Slika 11 Grafički prikaz sigmodialne funkcije 16
Slika 12 Grafički prikaz ReLu funkcije 17
Slika 13 Konvolucijska neuronska mreža 18
Slika 14 Arhitektura Google Inception-v3 [15] 19
Slika 15 Prikaz skupa podataka KinFaceW-I ..... **Error! Bookmark not defined.**
Slika 16 Prikaz glavnog izbornika 22
Slika 17 Odabir slike lica 22
Slika 18 Prikaz nakon odabiranja slika lica 23
Slika 19 Prikaz rezultata mreže – u rodbinskoj vezi 23
Slika 20 Prikaz rezultata mreže - nisu u rodbinskoj vezi 24
Slika 21 Prikaz točnosti treninga 25
Slika 22 Prikaz gubitaka tijekom treninga 25
Slika 23 Prikaz točnosti validacije 26
Slika 24 Prikaz gubitka tijekom validacije 26
Slika 25 Usporedba grafova točnosti kod treninga i validacije 27
Slika 26 Usporedba grafova gubitka kod validacije i treninga 27