

Beskontaktni sustav za prepoznavanje otisaka prstiju

Gojić, Andreja

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:390866>

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

Download date / Datum preuzimanja: **2024-08-16**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK**

Sveučilišni studij

**BESKONTAKNI SUSTAV ZA PREPOZNAVANJE
OTISAKA PRSTIJU**

Diplomski rad

Andreja Gojić

Osijek, 2023.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**Obrazac D1: Obrazac za imenovanje Povjerenstva za diplomski ispit**

Osijek, 14.09.2023.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za diplomski ispit

Ime i prezime Pristupnika:	Andreja Gojić
Studij, smjer:	Diplomski sveučilišni studij Računarstvo
Mat. br. Pristupnika, godina upisa:	D-1202R, 08.10.2021.
OIB studenta:	24332401510
Mentor:	izv. prof. dr. sc. Ratko Grbić
Sumentor:	,
Sumentor iz tvrtke:	Zvonimir Kaprocki
Predsjednik Povjerenstva:	prof. dr. sc. Marijan Herceg
Član Povjerenstva 1:	izv. prof. dr. sc. Ratko Grbić
Član Povjerenstva 2:	prof. dr. sc. Mario Vranješ
Naslov diplomskog rada:	Beskontaktni sustav za prepoznavanje otisaka prstiju
Znanstvena grana diplomskog rada:	Umjetna inteligencija (zn. polje računarstvo)
Zadatak diplomskog rada:	Prepoznavanje otisaka prstiju kao najvažnijeg biometrijskog obilježja koristi se u mnogim aplikacijama poput kontrole pristupa i sl. U novije vrijeme razvijaju se sustavi zasnovani na beskontaktnom prepoznavanju otisaka prstiju. Postupkom akvizicije bez dodira zaobilaze se mnogi problemi sustava koji se zasnivaju na dodiru, npr. prisutnost latentnih otisaka prstiju ili izobličenja uzrokovana pritiskom prstiju na površinu senzora. Kao beskontaktni senzor najčešće se koristi RGB kamera. U okviru diplomskog rada potrebno je razviti jedan takav sustav za beskontaktno prepoznavanje otisaka prstiju. Najprije je potrebno razviti algoritam za prepoznavanje otiska prsta iz RGB slike na osobnom računalu korištenjem standardnih tehnika za obradu u
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 2 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene od strane mentora:	14.09.2023.
Potvrda mentora o predaji konačne verzije rada:	<i>Mentor elektronički potpisao predaju konačne verzije.</i>
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**IZJAVA O ORIGINALNOSTI RADA**

Osijek, 26.09.2023.

Ime i prezime studenta:	Andreja Gojić
Studij:	Diplomski sveučilišni studij Računarstvo
Mat. br. studenta, godina upisa:	D-1202R, 08.10.2021.
Turnitin podudaranje [%]:	3

Ovom izjavom izjavljujem da je rad pod nazivom: **Beskontaktni sustav za prepoznavanje otisaka prstiju**

izrađen pod vodstvom mentora izv. prof. dr. sc. Ratko Grbić

i sumentora ,

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SADRŽAJ

1. UVOD	1
2. BESKONTAKTNO PREPOZNAVANJE OTISAKA PRSTIJU	3
2.1. Rješenje zasnovano na izdvajanju detalja	4
2.2. Rješenja zasnovana na dubokom učenju	6
2.3. Rješenja koja kombiniraju izdvajanje detalja i duboko učenje	9
3. PREDLOŽENI SUSTAV ZA BESKONTAKTNO PREPOZNAVANJE OTISAKA PRSTIJU	16
3.1. Izrada fizičkog okruženja za prikupljanje otisaka prstiju putem kamere	16
3.1.1. Jetson Nano jednokartično računalo i pripadna programska podrška	16
3.1.2. Izrada kutije okruženja za prikupljanje otisaka prstiju putem kamere	18
3.2. Izgradnja neuronske mreže za usporedbu otisaka prstiju	20
3.2.1. Sijamska neuronska mreža	20
3.2.2. Izgradnja skupa podataka sa slikama otisaka prstiju	21
3.2.3. Arhitektura sijamske neuronske mreže	24
3.2.1. Treniranje sijamske neuronske mreže	26
3.3. Implementacija neuronske mreže za prepoznavanje otisaka prstiju na NVIDIA Jetson Nano	29
3.4. Princip rada sustava i upute za korištenje sustava	30
4. EVALUACIJA RADA NEURONSKE MREŽE ZA PREPOZNAVANJE OTISAKA PRSTIJU	33
5. ZAKLJUČAK.....	39
LITERATURA	40
SAŽETAK.....	42
ABSTRACT	43
ŽIVOTOPIS.....	44
PRILOZI.....	45

1. UVOD

Napretkom tehnologije, tehnologija je postala sve dostupnija ljudima i sve više ljudi ju koristi, stoga se pojavila potreba za ograničenjem i kontrolom pristupa određenim sustavima. S druge strane sustavi poput pametnih telefona, računala, elektroničke pošte ili bankovnih aplikacija sadrže osjetljive podatke svojih korisnika te zahtijevaju da svaki korisnik može pristupiti samo svojim podacima. To se može osigurati procesom autentikacije. Autentikacija osobe je proces utvrđivanja je li neka osoba ona za koju tvrdi da jest. Identitet osobe se najčešće provjerava unosom PIN-a ili zaporke, ali u novije vrijeme se sve više poseže za autentikacijom preko biometrijskih obilježja [1].

Biometrija je znanost koja se bavi utvrđivanjem identiteta pojedinca na temelju fizičkih, bihevioralnih ili kemijskih osobina osoba. Fizičke biometrijske karakteristike se odnose na jedinstvene fizičke osobine ljudi po kojima je svaka osoba jedinstvena. U fizičke biometrijske karakteristike se ubrajaju zjenica oka, crte lica, otisak prsta, otisak dlana, geometrija ruke, izgled ušne školjke i otisak zuba. Bihevioralne biometrijske karakteristike podrazumijevaju određene dijelove ljudskog ponašanja koji su univerzalni za svakog pojedinca. Neke od bihevioralnih biometrijskih karakteristika su način potpisivanja, boja glasa i način na koji osoba hoda. S druge strane kemijske biometrijske karakteristike se odnose na jedinstvene kemijske značajke svakog pojedinca poput strukture DNK. Sve prethodno nabrojane karakteristike su daleko složenije od niza znakova te ih je teže zlorabiti, a proces autentikacije je jednostavniji za korisnika jer od korisnika zahtjeva samo da primjerice uslika lice, šarenicu oka ili otisak prsta [2].

Otisak prsta postao je najčešće korištena biometrijska karakteristika s obzirom na jednostavnost uzorkovanja, a pruža visoki stupanj sigurnosti. Otisak prsta se najčešće uzorkuje korištenjem kapacitivnog senzora na način da osoba dotakne senzor prstom. Neki od problema koji se javljaju kod kontaktnog načina prikupljanja otisaka prstiju su moguća izobličenja ovisno o jačini pritiska prsta na senzor, preklapanja trenutnog otiska s prethodnim otiskom zbog ostavljanja traga na senzoru, prljavštine koja se može nalaziti na senzoru, ali i higijenskih razloga zbog korištenja istog senzora na velikom broju osoba [3].


U novije vrijeme posvećena je pažnja razvijanju beskontaktnih sustava za prepoznavanje otisaka prstiju kako bi se izbjegla ograničenja kontaktnog prepoznavanja pomoću kapacitivnog senzora. Na primjer, u modernim pametnim telefonima se sve češće ispod zaslona ugrađuju ultrazvučni ili optički senzori za prepoznavanje otisaka prstiju [4].

U okviru ovog diplomskog rada izrađen je jedan takav beskontaktni sustav za prepoznavanje otisaka prstiju. Sustav se sastoji od ugradbene računalne platforme NVIDIA Jetson Nano s pripadajućom kamerom za beskontaktno očitavanje otiska prsta korisnika. Programska podrška za prepoznavanje otiska prsta temelji se na sijamskoj neuronskoj mreži. Za potrebe izrade neuronske mreže izgrađen je vlastiti skup podataka prikupljanjem slika otisaka prstiju od više osoba. Izgrađena mreža je implementirana na NVIDIA Jetson Nano kako bi se u stvarnom vremenu omogućilo očitavanje otiska prsta osobe i uspoređivanje s poznatim otiscima (korisnicima sustava). Kako bi se postigli što je moguće ujednačeniji uvjeti prilikom očitavanja otiska prsta, izrađeno je fizičko okruženje za prikupljanje otisaka prstiju. Ono se sastoji od kutije u koju je ugrađena RGB kamera za dohvaćanje slike otiska prsta te LED trake za osvjetljenje unutarnjeg prostora kutije gdje se odvija slikanje. Na taj način je postignuta podjednaka razina osvjetljenja i udaljenost od kamere prilikom svakog očitavanja.

U nastavku rada, u drugom poglavlju dan je pregled postojećih rješenja za beskontaktno prepoznavanje otisaka prstiju putem kamere. U trećem poglavlju je dan postupak izrade fizičkog okruženja za prikupljanje otisaka prstiju, kreiranja baze podataka, izgradnje sijamske neuronske mreže, implementacije neuronske mreže na NVIDIA Jetson Nano te je objašnjen način korištenja sustava. Nadalje, u četvrtom poglavlju je evaluiran rad predloženog sustava s obzirom na točnost klasifikacije i brzinu rada. Na samom kraju, u petom poglavlju je izložen zaključak rada.

2. BESKONTAKTNO PREPOZNAVANJE OTISAKA PRSTIJU

Kod primata na vrhovima prstiju ruku i nogu nalazi se naborana koža. Glavna evolucijska funkcija dolova i brjegova na koži vrhova prstiju odnosila se na stvaranje trenja između prsta i druge površine kako bi se pomoću prstiju mogli hvatati predmeti. Nabori ne teku kontinuirano već se savijaju i krivudaju, zaustavljaju se i počinju, spajaju se i razdvajaju, stvarajući pri tome jedinstvene otiske prstiju. Otisak prsta se formira prije rođenja te na njega utječu razni faktori poput stresova i opterećenja kože tijekom razvoja, hormona te genetike. Na slici 2.1. se nalazi prikaz tri osnovna tipa uzoraka otisaka prstiju, a to su lukovi, petlje i vijuge. Osim tri osnovna uzorka postoje mnoge varijacije i kombinacije spomenutih uzoraka [5].



Slika 2.1. Prikaz osnovnih vrsta uzoraka otiska prstiju: (a) lukovi, (b) vijuge, (c) petlje [5]

U drugoj polovici 19. stoljeća dr. Henry Faulds i William Herschel među prvima su otkrili kako je otisak prsta jedinstven za svaku osobu, odnosno za svaki prst te da on nije podložan promjenama tijekom odrastanja i starenja, jedine promjene koje se mogu dogoditi su one nastale uslijed ozljeda. Na temelju njihovog otkrića započelo se s kreiranjem skupova podataka otisaka prstiju te su se počeli koristiti u kriminalistici za rješavanje zločina i identifikaciju osoba [6].


Prilikom identifikacije osoba preko otiska prsta kroz povijest su se koristile razne tehnike, od stavljanja prsta u vosak ili tintu pa do suvremenih skenera otisaka prstiju. Sve prijašnje tehnike su zahtijevale fizički kontakt sa samim prstom kako bi se došlo do otiska, dok je u novije vrijeme započelo istraživanje beskontaktnog prepoznavanja osoba pomoću otisaka prstiju. Beskontaktno označava da ne postoji fizički kontakt između prsta i uređaja koji vrši prepoznavanje, već se prst fotografira pomoću kamere te se metodama iz područja obrade slike i računalnog vida slika otiska obrađuje i uspoređuje s već pohranjenim slikama kako bi se izvršila identifikacija osobe. Dva

osnovna pristupa kod beskontaktnog prepoznavanje otisaka prstiju su one temeljene na algoritmu izdvajanja detalja te one temeljene na dubokom učenju. U nastavku će biti opisano jedno rješenje temeljeno na izdvajanju detalja, dva rješenja temeljena na dubokom učenju te dva rješenja koja kombiniraju obje metode.

2.1. Rješenje zasnovano na izdvajanju detalja

Izdvajanje detalja (engl. *Minutiae extraction*) je najpopularnija i široko korištena metoda za izdvajanje značajki iz otiska prsta. Ova metoda uglavnom koristi crno-bijele slike koje se binariziraju, odnosno svim se elementima slike vrijednost postavi ili na 0 ili na 255, odnosno u crnu ili u bijelu boju, bez sivih nijansi. Zatim se linijama koje su prisutne na slici smanjuje debljina te se provodi izvlačenje detalja [2].

Detalji se izvlače iz otiska prsta i pohranjuju kao skupovi točaka u 2D ravnini. Svaki detalj se smatra uređenom trojkom vrijednosti $m = (x, y, \theta)$. (x, y) su koordinate položaja detalja na slici dok je θ kut orijentacije detalja. Jedna od tehnika usporedbe dvaju otisaka prstiju je temeljena na lokalnom podudaranju. Lokalno podudaranje podrazumijeva detalje koji su nepromjenjivi u odnosu na globalnu transformaciju poput translacije i rotacije otiska prsta. S druge strane globalno podudaranje je niske računalne složenosti te predstavlja kompromis između visoke tolerancije na izobličenja i visoke sposobnosti razlikovanja. Novije metode većinom kombiniraju globalno i lokalno podudaranje. Na slici 2.2. prikazan je postupak izdvajanja detalja [2].



a)

b)

c)


d)

Slika 2.2. Postupak izdvajanja detalja: a) crno-bijela slika, b) binarizirana slika, c) binarizirana slika sa stanjenim linijama otiska, d) slika s označenim detaljima [2]

U radu [7], autori su predložili rješenje temeljeno na izdvajanju detalja. Prilikom predobrade slike, ulazna slika se najprije pretvara iz RGB u crno-bijelu sliku, to jest vrijednosti

svih elemenata slike se postavljaju na vrijednosti između 0 i 255. Zatim se provodi normalizacija promjenom dinamičkog raspona vrijednosti intenziteta elemenata slike kako bi se smanjile razlike nastale zbog osvjetljenja. Nakon normalizacije na ulaznoj RGB slici se radi segmentacija. Prilikom segmentacije prvo se određuje područje boje kože, potom se provodi metoda adaptivnog praga i morfološka obrada. Slike dobivene segmentacijom i normalizacijom se množe te se rezultirajuća slika izrezuje i poboljšava pomoću STFT algoritma. Na poboljšanoj slici se određuje središnja točka otiska i time završava proces predobrade.

Nakon određivanja središnje točke otiska prsta, slika se ponovno izrezuje na veličinu 200x200 elemenata slike sa središtem otiska prsta u sredini slike. Nad takvim slikom se primjenjuje niz od šest Gabor filtara s kutovima od 0°, 30°, 60°, 90°, 120° i 150°. Filtrirane slike se zatim dijele u skup od 8x8 blokova koji se ne preklapaju, a konačna veličina podatka se pretvara u skalarni broj. Budući da je broj ekstrahiranih Gabor značajki ogroman, PCA se koristi za smanjenje dimenzionalnosti vektora značajki uz zadržavanje glavnih komponenti vektora značajki. Na slici 2.3. prikazan je funkcionalni blok dijagram sustava predloženog u radu [7].



Slika 2.3. Predloženi sustav klasifikacije otiska prsta u radu [7]

Za usporedbu dvaju vektora značajki korištene su tri metrike: Manhattan udaljenost, euklidska udaljenost i kosinus kuta između značajki. Otisci su isti ukoliko je vrijednost udaljenosti

manja od zadanog praga vrijednosti, dok su različiti ako je vrijednost udaljenosti veća ili jednaka pragu.

Testiranje je provedeno na vlastitom skupu slika veličine 640x480 koje su fotografirane u zatvorenom prostoru s Canon PowerShot Prol kamerom te je za osvjetljenje korištena stolna lampa bijele svjetlosti. Prilikom testiranja predobrade upotrijebljeno je 1938 slika te je postignuta točnost određivanja središta otiska prsta od 95.44%. Za testiranje podudaranja korišteno je 1030 predobrađenih slika na kojima se nalazi 103 različita prsta, od svakog prsta po 10 slika. Prilikom testiranja uspoređeni su rezultati dobiveni Manhattan udaljenosti, euklidske udaljenosti i kosinusa kuta između značajki s obzirom na broj značajki koji je dobiven PCA metodom. Primijećeno je kako se za klasifikaciju pomoću euklidske udaljenosti i kosinusa kuta između značajki rezultati poboljšavaju do određene veličine vektora značajki, a nakon toga postaju sve lošiji rezultati predviđanja, dok prilikom klasifikacije s Manhattan udaljenosti rezultati postaju sve bolji povećanjem veličine vektora značajki. Najbolji rezultat sa stopom jednake pogreške od 1.58% dobiveni su s Manhattan udaljenosti i 100 značajki.

2.2. Rješenja zasnovana na dubokom učenju

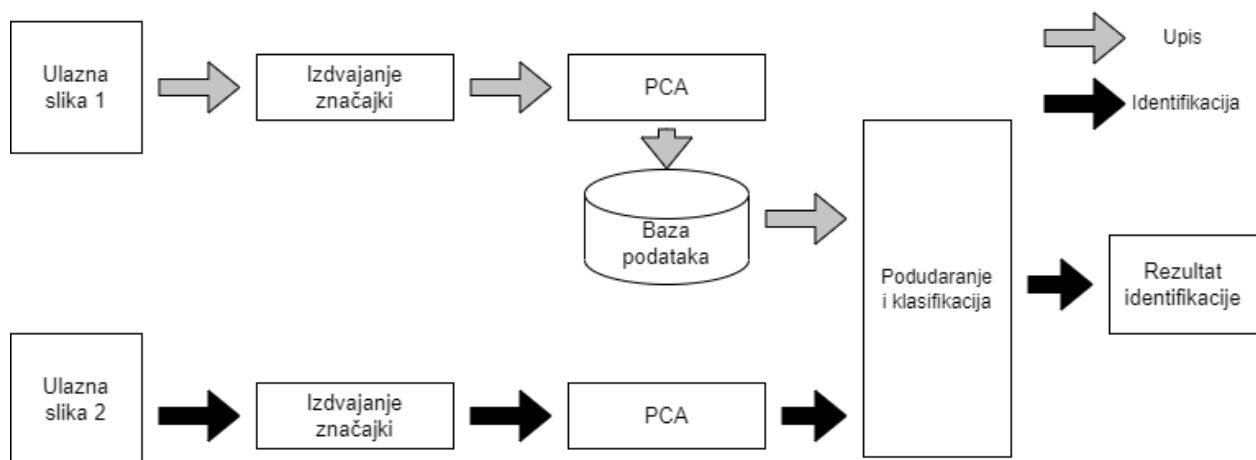
Duboko učenje je podskup strojnog učenja koje se ubraja u veliki pojam nazvan umjetna inteligencija. Duboko učenje je temeljeno na umjetnim neuronskim mrežama koje se sastoje od većeg broja skrivenih slojeva u kojima se nalaze neuroni. Svaki neuron je zasebna jedinica koja ima svoje težine, a težine se tijekom procesa učenja prilagođavaju namjeni modela. Konvolucijska neuronska mreža (engl. *Convolution neural network* - CNN) je često korištena duboka mreža u okviru računalnog vida, a sastoji se od četiri osnovna sloja, a to su konvolucijski sloj, sloj sažimanja (engl. *pooling*), sloj s ReLu (engl. *Rectified linear activation unit*) aktivacijskom funkcijom te potpuno povezani sloj [8].

Autori su u radu [9] koristeći duboko učenje riješili problem prepoznavanja na temelju otisaka prstiju. Za izdvajanje značajki su koristili sedam različitih CNN arhitektura (VGG16, VGG19, ResNet50, Xception, DenseNet169, DenseNet201 i MobileNet) i šest deskriptora tekstura (LPQ, HOG, GIST, LTP, POEM i LBP). Izdvojene značajke su klasificirali pomoću četiri različita tipa klasifikatora: metoda potpornih vektora (engl. *Support vector machines* - SVM), algoritam k -najbližih susjeda (engl. *K-nearest neighbors* - KNN), višeslojni perceptron (engl. *Multi-layer Perceptron* - MLP) i logistička regresija (engl. *Logistic regression*).

Autori u radu [9] odlučili su trenirati modele metodom prijenosnog učenja (engl. *transfer learning*). Razlog tomu je jer su koristili CNN arhitekture koje su ranije istrenirane (engl. *pre-*

trained model) na velikom skupu podataka ImageNet te sadrže težine prilagođene ImageNet skupu podataka. Prijenosno učenje [9] je tehnika učenja neuronske mreže na način da se već istrenirani model odabire kao početni model prilikom podešavanja parametara na novom skupu podataka. U radu [9] modeli su trenirani ovim principom na PolyU skupu podataka koji je nastao uzorkovanjem otisaka prstiju 366 osoba kontaktnim i beskontaktnim postupkom.

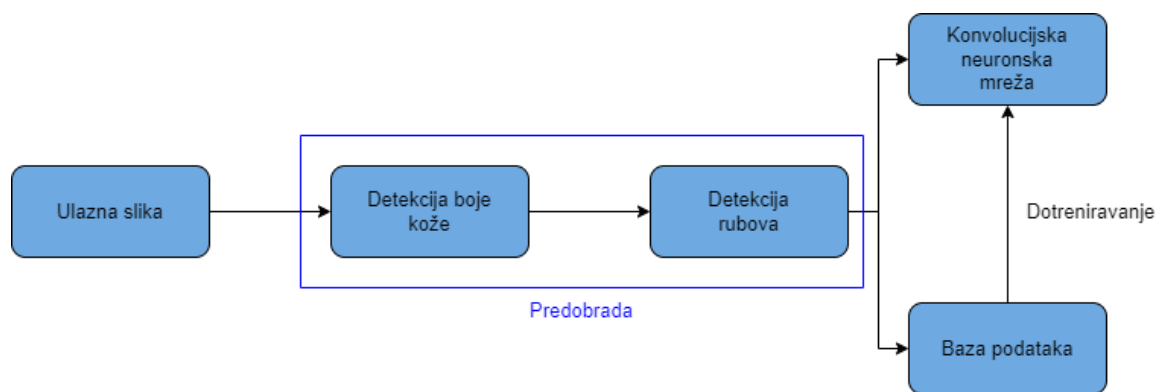
Najveću točnost klasifikacije na testnom skupu postigla mreža MobileNet u kombinaciji sa SVM klasifikatorom i to u iznosu od 96.61%. Stoga je taj model odabran za korištenje prilikom prepoznavanja. Prijedlog njihovog sustava za prepoznavanje na temelju otiska prsta prikazan je na slici 2.4. Prijedlog rješenja se sastoji od dvije „grane“. Jedna grana predstavlja unos podataka (engl. *enrolment*) u bazu podataka (engl. *database*). Uzima se slika koja se predaje neuronskoj mreži kako bi se izvukle značajke zatim se smanji veličina podatka s izdvojenim značajkama pomoću PCA metode. Nakon PCA redukcije podatci se pohranjuju u bazu. Druga grana predstavlja identifikaciju (engl. *identification*), postupak je isti samo što se podatak ne sprema u bazu. Dvije grane se spajaju na način da se podatak iz grane za identifikaciju predaje klasifikatoru (engl. *matching & classification*) kojemu se predaju i svi podatci iz baze podataka, na kraju klasifikator vraća rezultat (engl. *identification decision*) postoji li taj otisak u bazi ili ne.



Slika 2.4. Funkcionalni blok dijagram sustava za identifikaciju osoba na temelju otiska prsta u radu [9]


Autori su u radu [10] izradili mobilnu aplikaciju za prijavljivanje nazočnosti učenika na nastavi. Aplikacija se temelji na prepoznavanju otiska prsta, za svaki razred je izrađena baza podataka u koju su dodani učenici toga razrednog odjeljenja, a svoju nazočnost prijavljuju na način da uslikaju prst i daljnjom obradom slike se potvrđuje nazočnost.

Slika 2.5. prikazuje predloženi sustav za prepoznavanje osoba preko otiska prsta iz rada [10]. U sustav ulazi slika (engl. *Input image*) koja je snimljena pomoću kamere mobitela, a zatim slijedi predobrada slike (engl. *pre-processing stage*). Predobrada se sastoji od primjene dvaju filtara. Prvi filtar služi za detekciju boje kože (engl. *Skin color detection filter*), a drugi filtar služi za detekciju rubova (engl. *Edge detection filter*). Nakon predobrade koristi se CNN kako bi se utvrdio identitet osobe. Ako je potrebno, novi identitet moguće je dodati u bazu podataka te se model dotrenirava s novim otiskom prsta, odnosno dodaje se nova klasa i model se uči prepoznati novododanu klasu.



Slika 2.5. Blok shema sustava za identifikaciju osoba putem otiska prsta u radu [10]

Kada je iz ulazne slike izdvojeno područje boje kože te kada su prepoznati rubovi, slika se može predati neuronskoj mreži. Neuronska mreža u ulaznom sloju prima sliku veličine 1000x1000x3 elementa slike, osim ulaznog sloja sastoji se od dva aktivacijska bloka koji slijede jedan za drugim. Prvi sloj aktivacijskog bloka je konvolucijski sloj koji se sastoji od 32 filtara veličine 5 s korakom pomaka 2 i ReLu aktivacijskom funkcijom, zatim se sastoji od drugog konvolucijskog sloja s 32 filtara, veličine 5, nakon toga slijedi sloj sažimanja po maksimalnoj vrijednosti. Dva aktivacijska bloka su korištena kako bi se smanjila veličina slike, nakon njih je upotrijebljen sloj koji 3D matricu pretvara u 1D polje te potpuno povezani sloj koji za rezultat predviđanja vraća polje s brojem elemenata koji odgovara broju klasa spremljenih u bazu podataka. Na slici 2.6. je prikaza arhitektura opisane neuronske mreže.




Slika 2.6. *Struktura mreže korištene u radu [10]*

Model je treniran na skupu podataka koji sadrži 21 različitu klasu, odnosno 21 osobu. Od svake osobe je fotografirano 40 slika što rezultira ukupnom bazom podataka od 840 slika. Model je treniran kroz 30 epoha s veličinom serije (engl. *batch size*) 20 po svakoj epohi, a testiran je na 40 slika. Testiranjem je postignuta točnost klasifikacije od 95%.

2.3. Rješenja koja kombiniraju izdvajanje detalja i duboko učenje

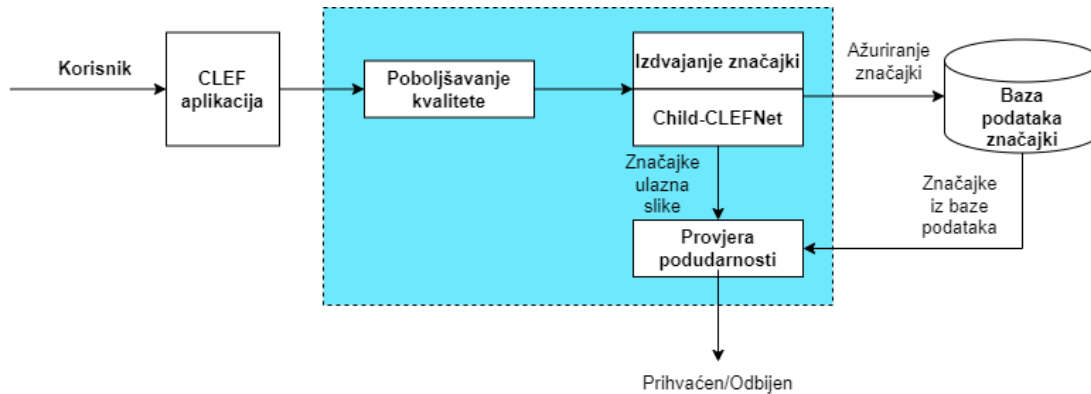
Autori su u radu [11] predložili Child-CLEF sustav za beskontaktno prepoznavanje otisaka prstiju djece temeljen na metodi izdvajanja detalja pomoću neuronske mreže koju su nazvali Child-CLEF Net, dok se identifikacija djece vrši pomoću algoritma za usklađivanje.

Child-CLEF sustav se sastoji od dodavanja otiska u bazu i identifikacije osobe. Na slici 2.7. prikazan je modul za dodavanje otiska u bazu podataka. Otisak se fotografira pomoću mobilne aplikacije CLEF, zatim se poboljšava kvaliteta slike otiska prsta (engl. *quality enhancement*), nakon toga slika se predaje neuronskoj mreži Child-CLEF Net u kojoj se izdvajaju značajke (engl. *feature extraction*) te se u bazu podataka pohranjuju izdvojene značajke (engl. *minutiae template database*).



Slika 2.7. *Blok shema modula za dodavanje otiska u bazu u radu [11]*

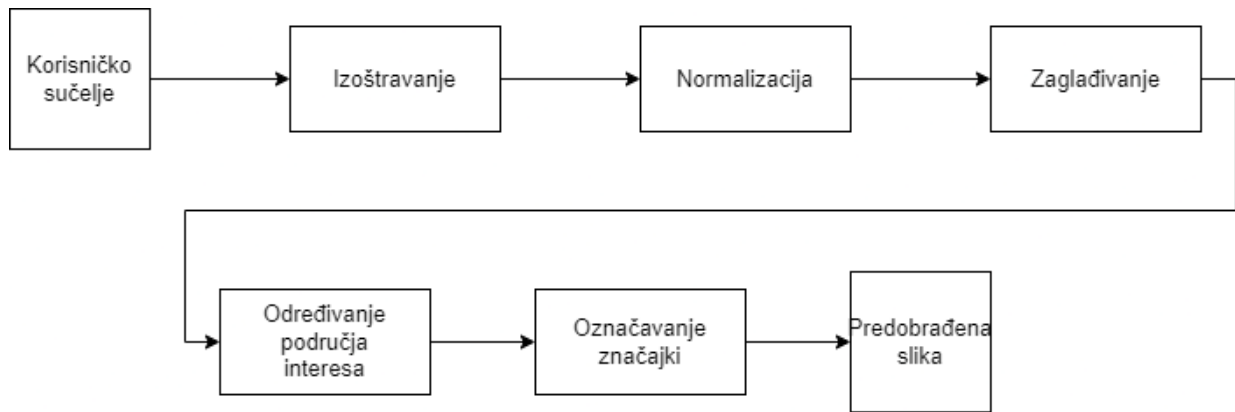
Modul za identifikaciju djece prikazan je na slici 2.8. gdje se, kao i kod prethodnog modula, za fotografiranje koristi CLEF mobilna aplikacija, zatim se poboljšava kvaliteta slike te se izdvajaju značajke, a potom se ažurira baza podataka s novim izdvojenim značajkama (engl. *minutiae update*). Nove izdvojene značajke (engl. *input feature set*) i značajke koje su pohranjene u bazi podataka (engl. *template feature set*) se uspoređuje međusobna podudarnost (engl. *fingerprint matching*) i na kraju se dobiva odgovor je li uslikani prst prihvaćen ili odbijen (engl. *accept/reject*).



Slika 2.8. Blok shema modula za identifikaciju djece [11]


Za fotografiranje prsta autori su koristili kameru iPhone-a SE s dodanom 20X makro lećom. Ograničenje ovakve leće je što se prst mora postaviti između 30mm i 80mm udaljenosti od leće jer ako je izvan toga područje prst neće biti u fokusu. Autori su izradili već spomenutu CLEF iOS aplikaciju za fotografiranje prstiju, ali i za registraciju i za identifikaciju prstiju. Nakon fotografiranja početna fotografija dimenzija 4032x3024 elementa slike se smanji na 1280x720 elemenata slike, nakon toga slijedi predobrada slika.

Predobrada započinje izoštravanjem slike (engl. *sharpening*) pomoću 3x3 filtera, a zatim se izoštrana slika pretvara u crno-bijelu sliku. Izoštrena crno-bijela slika puna je šumova te se provodi normalizacija (engl. *normalization*) za uklanjanje šumova pomoću CLAHE (engl. *contrast limited adaptive threshold*) metode. Na normaliziranoj slici je poboljšan kontrast i uklonjeni su šumovi niskih prostornih frekvencija, dok se šumovi visokih prostornih frekvencija uklanjaju pomoću zaglađivanja (engl. *smoothing*). Zatim se na zaglađenoj slici određuje područje interesa (engl. *region of interest marking*) te se označavaju značajke (engl. *features marking*). Postupak predobrade prikazan je na slici 2.9.



Slika 2.9. Postupak predobrade slike u radu [11]


Na slici 2.10. nalazi se arhitektura korištene Child-CLEF mreže. U mrežu ulaze prethodno predobrađene slike otisaka prstiju (engl. *preprocessed fingerprint*). Izlazi iz drugog i trećeg sloja sažimanja po srednjoj vrijednosti se predaju ASPP mreži (engl. *Atrous Spatial Pyramid Pooling Network*) s odgovarajućim stopama učenja za segmentaciju. Uloga ASPP-a je ulančavanje dilatiranih konvolucijskih slojeva s različitim faktorima dilatacije i pružanje višerazmjernih polja prijema bez povećanja veličine arhitekture mreže. Mreža za izlaz daje ranije objašnjenu uređenu trojku (x, y, θ) .



Slika 2.10. Arhitektura Child-CLEF mreže u radu [11]

Za računanje podudaranja otisaka prstiju, odnosno izdvojenih značajki koristi se BOZORTH3 algoritam kojem se predaju uređene trojke (x, y, θ) . Slika 2.11. prikazuje predloženi pristup procjene podudaranja. Prilikom registracije izdvojene značajke otisaka prstiju se

pohranjuju u bazu podataka. Za identifikaciju otiska prsta ulazne slike izdvojene se značajke zatim uspoređuju sa značajkama iz baze podataka. Za preciznije rezultate uspoređuje se podudaranje lijevog i desnog kažiprsta (engl. *left/right index*) te lijevog i desnog palca (engl. *left/right thumb*), zatim se rezultati podudaranja (engl. *matching score*) spajaju (engl. *fuse scores*) i dobiva se konačni rezultat podudaranja (engl. *matching results*).



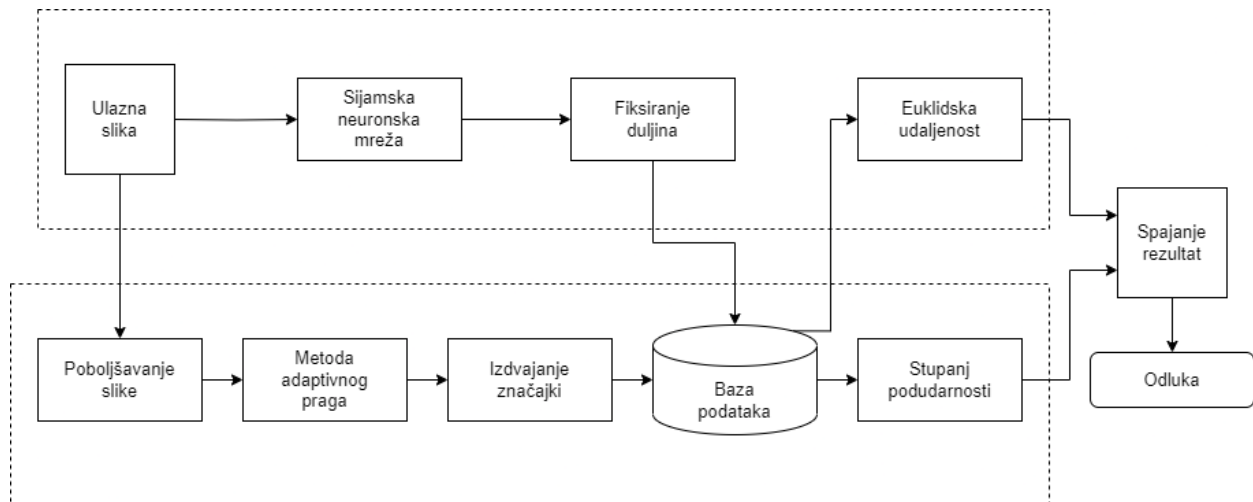
Slika 2.11. Predloženi pristup procjene podudaranja u radu [11]

Za treniranje modela izrađenog u radu [11] kreiran je skup podataka nazvan CLCF koji se sastoji od 1016 slika, fotografiranih od 101 djeteta u dobi između 6 mjeseci i 8 godina, od svakog djeteta je fotografirano 8 slika od dva palca i dva kažiprsta. Predloženi sustav uspoređen je s MINDTCT metodom i postigao je značajno veću točnost klasifikacije u iznosu od 98.46%.

Autori su u radu [12] predložili sustav za prepoznavanje na temelju otiska prsta koji kombinira metodu izvlačenja detalja i duboko učenje. Cilj im je bio razviti sustav koji će raditi u stvarnom vremenu sa minimalnom latencijom i prihvatljivom točnosti prepoznavanja. Svoje su rješenje implementirali na NVIDIA Jetson Nano razvojnu platformu.

Za duboko učenje korištena je sijamska neuronska mreža te se njome izvlače globalne značajke, dok se izvlačenjem detalja dobivaju lokalne značajke. Na kraju se ta dva rezultata spajaju i dobiva se konačna odluka jesu li otisci prstiju slični ili različiti. Na slici 2.12. shematski je prikazan prijedlog sustava. U sustav ulazi slika otiska prsta (engl. *fingerprint image*), zatim se slika paralelno prosljeđuje algoritmu za poboljšavanje slike (engl. *image enhancement*) i sijamskoj neuronskoj mreže (engl. *Siamese Neural Network - SNN*). Nakon poboljšavanja slike iz nje se izvlače detalji i uspoređuju se s predlošcima pohranjenim u bazu podataka (engl. *database templates*), dok se izlazu iz sijamske neuronske mreže fiksira duljina (engl. *fixed length embeddings*) te se računa euklidska udaljenost (engl. *euclidean score*) između izlaza iz neuronske mreže i predložaka iz baze podataka. Zatim se spaja (engl. *score fusion*) rezultat koji je dobiveni

računanjem euklidske udaljenosti i rezultat koji je dobiven podudaranjem detalja (engl. *minutiae matching score*) te se donosi konačna odluka (engl. *decision*).



Slika 2.12. Shematski prikaz prijedloga rješenja

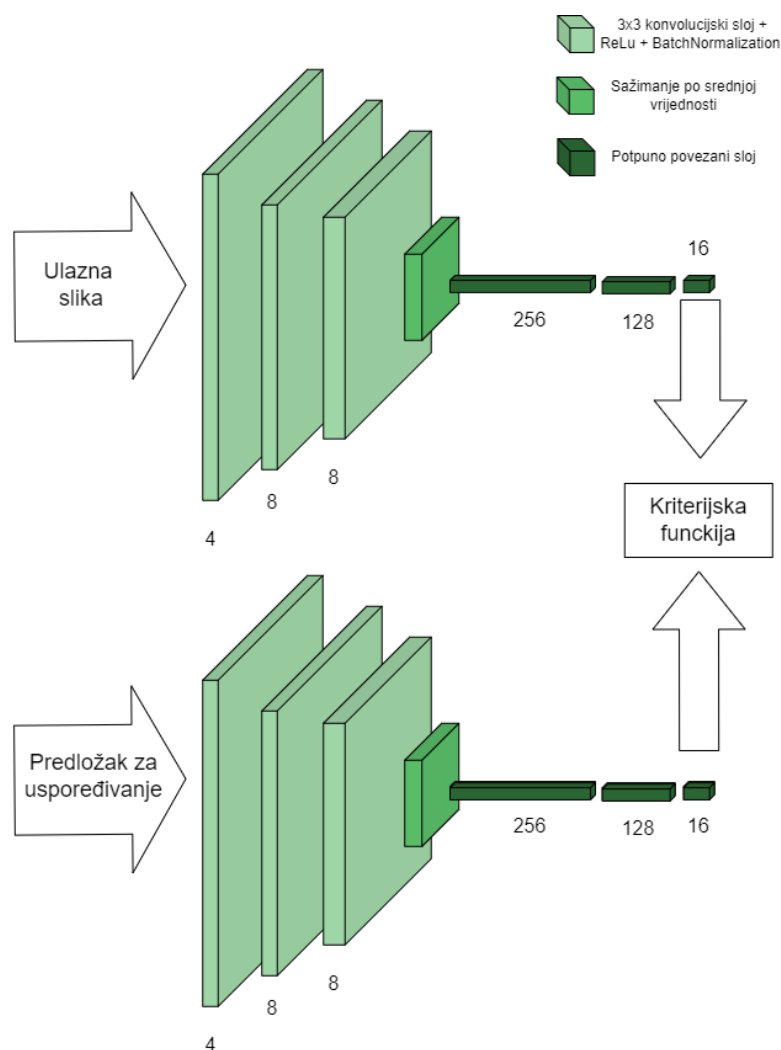
Tijekom poboljšavanja slike, ulazna RGB slika se pretvara u crno-bijelu sliku, zatim se na crno-bijeloj slici primjenjuje tehnika AMT (engl. *Adaptive Mean Thresholding*) koja se pokazala boljom od globalne metode praga (engl. *global thresholding method*). Obradena slika se prosljeđuje MINDTCT algoritmu koji izdvaja detalje iz slike te ih označava u formatu uređene trojke (x, y, θ) . Izdvojene značajke se zatim prosljeđuju BOZORTH3 algoritmu koji određuje podudaranje između ulazne slike i one pohranjene u bazi podataka.

Za razliku od izdvajanja detalja gdje ulazna slika zahtjeva predobradu, sijamskoj neuronskoj mreži predaje se originalna RGB slika. Ulazna slika (engl. *input image*) uspoređuje se s predloškom za uspoređivanje (engl. *template to compare*) iz baze podataka te se predaje sijamskoj neuronskoj mreži. Arhitektura sijamske neuronske mreže prikazana je na slici 2.13.

Rezultati dobiveni ovim dvjema metodama (metoda izvlačenja detalja i metoda dubokog učenja) kombiniraju se prema izrazu (2-1):

$$S_f = w_d S_d + w_m S_m \quad (2-1)$$

gdje S_f konačni rezultat, S_d je rezultat dobiven metodom dubokog učenja, a S_m predstavlja rezultat dobiven metodom izvlačenja detalja, svi rezultati su u rasponu od 0 do 1. w_d i w_m su težine povezane s rezultatima ovih metoda, a one su empirijski određene da iznose 0.4 i 0.6.



Slika 2.13. *Struktura sijamske neuronske mreže u radu [12]*

Sustav izrađen u radu [12] sastoji se od dva modula, modul za identifikaciju i modul za upis korisnika u sustav. Sustav za upis dodjeljuje korisniku jedinstveni ID, zatim fotografira tri slike prsta, zatim slike smanji na vektor 16x1 te izračuna srednju vrijednost tih vektora i srednju vrijednost pohranjuje u lokalnu bazu podataka, pritom se pohranjuju i izdvojeni detalji. Prilikom identifikacije korisnik mora unijeti svoj ID, a sustav uzima podatke iz stvarnog vremena s kamere te u bazi podataka pretražuje postoje li spremljeni podaci za uneseni ID, ukoliko oni postoje uspoređuje podatke iz stvarnog vremena sa spremljenim podacima te vraća rezultat prepoznavanja. Opisani sustav je implementiran na NVIDIA Jetson Nano te slike prikuplja pomoću Raspberry Pi NoIR V2 kamera modula, kamera modul je ugrađen u kartonsku kutiju sa stalnim LED osvjetljenjem te je napravljen kvadratni otvor kroz koji se stavlja prst.

Izrađeni sustav je treniran i testiran na vlastitom skupu podataka koji se sastoji od ukupno 205 prstiju, svaki prst je fotografiran 8 puta što daje ukupno 1640 slika. U skupu za treniranje se

nalazi 840 slika, a preostalih 800 slika je korišteno za testiranje. Testiranje je provedeno pojedinačno za metodu dubokog učenja i pojedinačno za metodu izdvajanja detalja te predloženim rješenjem koje kombinira oba pristupa. Dubokim učenjem je postignuta stopa jednake pogreške (engl. *Equal Error Rate* - EER) od 11.39%, izdvajanjem detalja stopa pogreške iznosila je 4.09%, dok je kombinacijom metoda stopa jednake pogreške bila 2.19%. Osim stope jednake pogreške testiranjem je ispitan postotak pogrešno uparenih otisaka (engl. *False Matching Rate* - FMR) na 100 i 1000 parova, također pojedinačno za svaki od modula te kombinacijom rezultata oba modula. Iz dobivenih rezultata zaključeno je kako svaka metoda zasebno ne može postići dobre rezultate kao kad se kombiniraju rješenja obje metode.

3. PREDLOŽENI SUSTAV ZA BESKONTAKTNO PREPOZNAVANJE OTISAKA PRSTIJU

U ovom poglavlju je opisana izrada vlastitog rješenja za beskontaktno prepoznavanje osoba na temelju otiska prsta. S obzirom na to da se prepoznavanje vrši usporedbom dvije slike i donošenjem odluke radi li se o istom ili različitom otisku prsta odlučeno je koristiti sijamsku neuronsku mrežu koja se pokazala kao najpogodnija za problem usporedbe. U nastavku je opisan postupak izrade fizičkog okruženja koje služi za prikupljanje otisaka prstiju, zatim je objašnjeno što je sijamska neuronska mreža, na koji način je izrađen skup podataka, arhitektura i treniranje predložene sijamske neuronske mreže te princip rada predloženog sustava s uputama za korištenje.

3.1. Izrada fizičkog okruženja za prikupljanje otisaka prstiju putem kamere

3.1.1. Jetson Nano jednokartično računalo i pripadna programska podrška

NVIDIA Jetson Nano je malo jednokartično računalo (engl. *single board computer*) proizvedeno od tvrtke NVIDIA. Na ovom računalo se mogu pokrenuti višestruke neuronske mreže te su neke od primjena klasifikacija, detekcija objekata, procesiranje govora, segmentacija i slično. Ima ugrađen 128-core Maxwell GPU, Quad-core ARM A57 @ 1.43 GHz CPU, 4 GB RAM memorije, nema ugrađen uređaj za trajnu pohranu, ali posjeduje ulaz za microSD karticu koja kada se umetne služi za trajnu pohranu podataka, podržava microSD kartice veličine 32 GB i 64 GB. Od ulaza ima HDMI ulaz i Display ulaz za monitor, četiri USB 3.0 ulaza te jedan USB 2.0 micro-B ulaz, dva ulaza za kameru, ethernet ulaz, ulaz za napajanje te GPIO, I²C, I²S, SPI, UART ulaze. Napaja se putem ispravljača od 5V i 4A. Pločica je dimenzija 69x45mm, a prikazana je na slici 3.1. [13].



Slika 3.1. *Nvidia Jetson Nano* [13]

S obzirom na to da NVIDIA Jetson Nano nema unutarnju memoriju pa samim time niti operacijski sustav, najprije je potrebno na trajnu memoriju pohraniti željeni operacijski sustav. Prvo je bilo potrebno na osobno računalo preuzeti Jetson Nano Developer Kit SD Card Image i pomoću njega prebaciti sliku operacijskog sustava na microSD karticu. Nakon toga se microSD kartica umetne u NVIDIA Jetson Nano te s pokretanjem Jetson Nano-a počinje instalacija operacijskog sustava. Nakon namještanja općih postavki poput jezika, regije, jezika tipkovnice, korisničkog imena, lozinke i slično, operacijski sustav je instaliran i može se započeti s radom.

Sljedeći korak je instalacija JetPack-a. JetPack pruža potpuno razvojno okruženje za hardverski ubrzani AI-at-the-edge razvoj na NVIDIA Jetson modulima. Prilikom izrade neuronske mreže korišten je Keras API, a s obzirom na to da je Keras ugrađen u TensorFlow, bilo je potrebno prvo instalirati TensorFlow [14]. Matematičke operacije i rad s matricama su ostvareni pomoću NumPy biblioteke. Postupak instalacije svih potrebnih biblioteka detaljnije je objašnjen u prilogu P.3.1.

Keras je API za duboko učenje visoke razine koji je razvio Google. Napisan je u Python-u i koristi se za jednostavnu implementaciju neuronskih mreža te podržava više pozadinskih neuronskih mreža. Osim toga pruža sve potrebne ugrađene module za izračune neuronskih mreža. Keras je ugrađen u TensorFlow i predstavlja sučelje koje je prilagođeno korisnicima za korištenje TensorFlow biblioteke [15].

NumPy je biblioteka otvorenog koda koja omogućuje numeričko računanje u Python-u. NumPy je nastao 2005. godine spajanjem tada postojećih biblioteka Numeric i Numarray tim su objedinjene sve numeričke operacije i višedimenzionalna polja i matrice te sve operacije koje se provode nad njima. Unutar NumPy biblioteke je moguće definirati vlastiti tip podataka što pruža mogućnost povezivanja s velikim brojem baza podataka [16].

3.1.2. Izrada kutije okruženja za prikupljanje otisaka prstiju putem kamere

Prilikom treniranja, testiranja i konačnog korištenja sustava koji je izrađen u ovome radu bilo je potrebno postići što veću točnost rada sustava. Kontrolirani uvjeti u kojima se očitavaju otisci prstiju mogu značajno doprinijeti točnosti sustava. Pri tome je važno postići podrazumijevanu konstantnu razinu osvjetljenja, nepromjenjivu pozadinu te približno istu udaljenost prsta od kamere prilikom slikanja prsta s kamerom. Kako bi se postigli navedeni uvjeti bilo je potrebno izraditi odgovarajuće fizičko okruženje s pripadnim sklopovljem.

Fizičko okruženje temelji se na kutiji koja je izrađena od tvrde plastike dimenzija 10x10x10 cm kao što je prikazano na slici 3.2. Na prednjoj strani kutije nalazi se otvor dovoljno velikog promjera kako bi se kroz njega mogao staviti prst u kutiju, ali ne prevelikog promjera kako ne bi ulazilo previše vanjskog svjetla koje bi moglo narušiti razinu osvjetljenja slika. Na gornjoj plohi kutije s unutarnje strane ugrađen je Raspberry Pi kamera modul te je oko njega sa svih strana postavljena RGB LED traka. Upotrijebljena LED traka ima mogućnost postavljanja razine osvjetljenja na 25%, 50%, 75% i 100%, odabrana je 100%-tna razina osvjetljenja i žuto-narančasta nijansa svjetla. Budući da se LED traka napaja s 5V putem USB kabela ona je spojena na USB ulaz koji se nalazi na NVIDIA Jetson Nano-u, na njega je spojen i kamera modul u ulaz predviđen za kameru. Cijeli sustav se napaja pomoću ispravljača od 5V i 4A. Izrađena kutija spojena na NVIDIA Jetson Nano je prikazana na slici 3.3.



Slika 3.2. Izrađena kutija za očitavanje slika otisaka prstiju

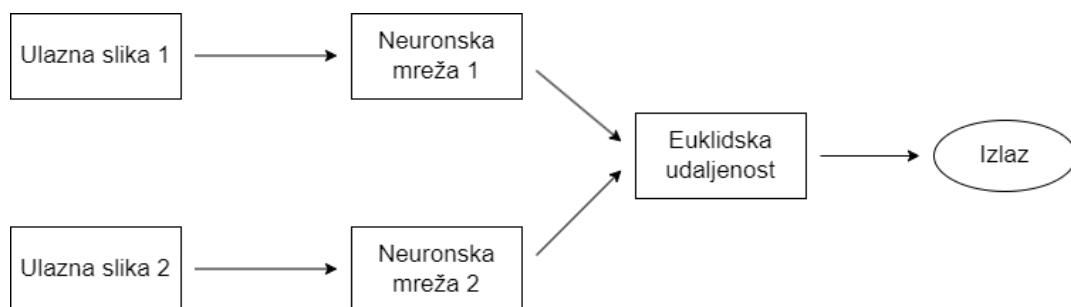


Slika 3.3. Prikaz fizičkog okruženja za očitavanje otiska prsta s pripadnim sklopovljem

3.2. Izgradnja neuronske mreže za usporedbu otisaka prstiju

3.2.1. Sijamska neuronska mreža


Sijamske neuronske mreže (engl. *Siamese neural network* - SNN) prvi su uveli u ranim 1990-ima Bromley i Le Cunn kako bi riješili provjeru potpisa kao problem podudaranja slike [17]. Sijamska neuronska mreža koristi se za pronalaženje sličnosti između ulaza usporedbom vektora značajki. Arhitektura sijamske neuronske mreže se sastoji od dvije ili tri identične podmreže u zasebnim granama. Kada se kaže da su podmreže identične to znači da imaju istu konfiguraciju s istim parametrima. Budući da se ovakva neuronska mreža sastoji od dvije ili tri podmreže predaju joj se dva ili tri ulaza ovisno o broju podmreža. Ako se mreža sastoji od dvije podmreže, tada se kreiraju pozitivni i negativni parovi koji se predaju mreži. Pozitivni par predstavljaju dvije slike istog otiska, dok se negativni par odnosi na dvije slike različitog otiska prsta. Nakon obrade ulaznih slika kroz podmreže dobiju se vektori značajki za svaku ulaznu sliku, a rezultat koji sijamska neuronska mreža daje je udaljenost između dva vektora značajki. Udaljenost između vektora značajki označava mjeru sličnosti ulaznih podataka. Na slici 3.4. prikazana je arhitektura sijamske neuronske mreže koja se sastoji od dvije podmreže.



Slika 3.4. Prikaz sheme sijamske neuronske mreže

Za računanje udaljenosti između izlaznih vektora podmreža najčešće se koristi euklidska udaljenost te je odlučeno koristiti ju i prilikom izrade ovoga rada. Euklidska udaljenost predstavlja najkraću udaljenost između dvije točke, ona se temelji na Pitagorinom poučku. U 2D Kartezijevom koordinatnom sustavu za točke P i Q sa slike 3.5. euklidska udaljenost $d(P, Q)$ računa se prema izrazu (3-1) [18]:

$$d(P, Q) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2} \quad (3-1)$$



Slika 3.5. Prikaz točka u koordinatnom sustavu

Prema tome u n -dimenzionalnom koordinatnom sustavu euklidska udaljenost $d(p, q)$ između točke $p = (p_1, p_2, \dots, p_n)$ i točke $q = (q_1, q_2, \dots, q_n)$ računa se prema izrazu (3-2).

$$d(p, q) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2} \quad (3-2)$$

3.2.2. Izgradnja skupa podataka sa slikama otisaka prstiju

Za izgradnju sijamske neuronske mreže neophodni su podatci koji se koriste prilikom treniranja, validacije i testiranja. S obzirom na to da se u ovome radu izrađuje beskontaktni sustav za prepoznavanje otisaka prstiju potrebni podatci moraju biti u obliku RGB slika nastalih pomoću kamere na kojima su prikazani otisci prstiju. Budući da nije dostupan skup podataka koji se sastoji od RGB slika otisaka prstiju već samo skupovi podataka sa slikama prstiju koje su nastale pomoću skenera otisaka prstiju, pojavila se potreba za izradom vlastitog skupa podataka na temelju kojega će se izvršiti treniranje, validacija i testiranje sijamske neuronske mreže. Za izgradnju skupa podataka korišteno je prethodno izrađeno fizičko okruženje za prikupljanje otisaka prstiju s ugrađenom kamerom čija je izrada opisana u potpoglavlju 3.1.

Tijekom prikupljanja slika, svaka slika je imenovana na sljedeći način:

ID osobe_broj prsta_broj slike toga prsta.png

ID osobe predstavlja jedinstvenu oznaku svake osobe, *broj prsta* su brojevi od 1 do 8 kojima je numeriran svaki prst, a *broj slike toga prsta* su brojevi od 1 do 4 koji označavaju koja je slika pojedinog prsta jer je svaki prst fotografiran više puta. Prema tome, primjer imenovanja jedne slike bi bio *6345_4_2.png*, dakle iz naziva je vidljivo da je ovo druga slika četvrtog prsta od osobe s ID-em *6345*. Ovakav način imenovanja je odabran kako bi se prilikom učitavanja podataka, podaci mogli ispravno uparivati u pozitivne i negativne parove koji će se koristiti za treniranje, validaciju i testiranje. Fotografirani su svi prsti osim palčeva jer kutija nije ergonomski prilagođena da se u nju može staviti palac.

U izradi baze podataka sudjelovala je 21 osoba kojoj je dodijeljen jedinstveni ID, kako svaka osoba ima deset prstiju na rukama, a svaki prst ima jedinstven otisak, od svake osobe je fotografirano osam prstiju s obzirom na to da se palčevi nisu fotografirali. Tijekom fotografiranja fotografiran je samo prvi članak prsta, odnosno samo dio na kojem se nalazi otisak. Svaki prst je fotografiran četiri puta kako bi se, kasnije tijekom treniranja, testiranja i validacije, mogli kreirati pozitivni parovi. Prema tome, skup podataka se sastoji od ukupno 652 slike. Slike su u boji rezolucije 940x540 elemenata slike. Slike su podijeljene u tri skupa, skup za treniranje, testiranje i validaciju. Prilikom podijele podataka po skupovima pazilo se na razdiobu podataka na način da se sve slike pojedinog otiska prsta nalaze u jednom skupu podataka, odnosno da slike jednog otiska prsta nisu podijeljene u više skupova.

U skupu za treniranje nalazi se 70% slika iz ukupnog skupa, tj. 448. Skupovima za validaciju i testiranje dodijeljeno je preostalih 30% slika, odnosno 14% validacijskom skupu što je 96 slika i 16% testnom skupu, odnosno 108 slika. Broj slika i broj različitih prstiju u svakom skupu dan je u tablici 3.1. Na slici 3.6. prikazana su četiri primjera slike jednog prsta.

Tablica 3.1. *Raspodjela prikupljenih podataka na skup za treniranje, validaciju i testiranje*

	Broj slika	Broj različitih prstiju
Skup za treniranje	448	112
Skup za validaciju	96	24
Skup za testiranje	108	27




Slika 3.6. Četiri primjera slike jednog prsta osobe

3.2.3. Arhitektura sijamske neuronske mreže

Kako je na početku 3. poglavlja spomenuto, za rješavanje problema beskontaktnog prepoznavanja osoba na temelju otiska prsta korištena je sijamska neuronska mreža. Sijamska neuronska mreža je odabrana jer se izvrsno pokazala za probleme usporedbe, odnosno određivanja u kojoj su mjeri ulazni podatci slični. Drugi razlog korištenja ovakve arhitekture neuronske mreže jest taj što se ne raspolaže s velikim brojem podataka na kojima se provodi učenje mreže, a sijamska mreža je pogodna za takvu vrstu problema.

Na slici 3.7. prikazana je arhitektura korištene sijamske neuronske mreže. Prikazana arhitektura odabrana je nakon treniranja različitih arhitektura s različitim hiperparametrima, a odabrana arhitektura postigla je najbolje rezultate tijekom testiranja. U mrežu ulaze dvije slike, referentna i testna, dimenzija 384x216x3, nakon prolaska slika kroz mrežu na izlazu se dobivaju dva vektora značajki od 16 elemenata. Potom se dobiveni vektori smještaju u vektorski prostor te se računa njihova udaljenost. Na izlazu iz neuronske mreže se vrijednost dobivena euklidskom udaljenosti normalizira kako bi se osiguralo da izlaz bude rasponu između 0 i 1.



Slika 3.7. Prikaz arhitekture korištene neuronske mreže


Mreža se sastoji od pet konvolucijskih blokova koji se sastoje od konvolucijskog sloja s ReLu aktivacijskom funkcijom, sloja za normalizaciju podataka i sloja sažimanja po maksimalnoj vrijednosti, a blokovi se međusobno razlikuju po broju i dimenziji filtara u konvolucijskom sloju. U prvom konvolucijskom bloku se nalazi konvolucijski sloj sa 16 filtara dimenzija 11x11 te veličinom koraka koja iznosi 1, drugi konvolucijski blok sadrži konvolucijski sloj od 32 filtara s dimenzijama 11x11 i korakom pomaka 1, treći konvolucijski blok se sastoji od konvolucijskog sloja sa 64 filtara dimenzija 5x5 i korakom pomaka 1, u četvrtom konvolucijskom bloku se nalazi 128 filtara s dimenzijama 5x5 te korakom pomaka 1 i u posljednjem konvolucijskom bloku konvolucijski sloj sadrži 256 filtara s dimenzijama 3x3, korak pomaka iznosi 1. Nakon 5 konvolucijskih blokova slijedi sažimanje po srednjoj vrijednosti, zatim sloj koji dobivenu matricu pretvara u vektor te potpuno povezani sloj s nasumičnim isključivanjem neurona (engl. *dropout*). U potpuno povezanom sloju svaki neuron prima ulazni podatak od svih neurona iz prethodnog sloja [19], a nasumično isključivanje neurona s vjerojatnosti iznosa 0.3 je dodano kako bi se spriječilo pretjerano učenje (engl. *overfitting*) na podatke iz trening skupa. Nakon potpuno povezanog sloja s isključivanjem neurona slijede još dva potpuno povezana sloja, prvi sa 64 elementa i posljednji sa 16 elemenata. Zatim se računa euklidska udaljenost između vektora od 16 elemenata te se dobivena vrijednost normalizira tako što se predaje sloju za normalizaciju na razini grupe podataka (engl. *batch normalization*) i potpuno povezanog sloja od jednog neurona sa Softmax aktivacijskom funkcijom.

U konvolucijskim blokovima se nalaze slojevi za normalizaciju podataka, oni služe kako bi spriječili pretjerano učenje mreže na trening podatke te kako bi ubrzali sam proces učenja i učinili ga stabilnijim, odnosno kako ne bi došlo do velikih oscilacija u rezultatima treniranja. Korištena metoda normalizacije je normalizacija na razini grupe podataka. Osim slojeva za normalizaciju podataka, konvolucijski blokovi sadrže i sloj za sažimanje po maksimalnoj vrijednosti, blok veličine 2x2 s korakom pomaka (2, 2), to znači da će blok veličine 2x2 prolaziti kroz cijelu matricu koja izađe iz konvolucijskog bloka te će vrijednost svaka četiri elementa na koja naliježe zamijeniti s najvećom vrijednosti od ta četiri elementa. Korak pomaka (2, 2) označava da se blok pomiče za dva elementa po x i za dva elementa po y osi. Također se koristi i sažimanje po srednjoj vrijednosti s blokom veličine 2x2 i korakom pomaka (2, 2), ova metoda sažimanja funkcionira na istom principu kao i sažimanje po maksimalnoj vrijednosti osim što se vrijednost četiri elementa na koja naliježe blok ne mijenja s najvećom vrijednosti već sa srednjom vrijednosti ta četiri elementa.

3.2.1. Treniranje sijamske neuronske mreže

Prilikom opisivanja arhitekture mreže spomenuta je kriterijska funkcija, pri izradi ovoga rada korištena je kontrastna kriterijska funkcija (engl. *contrastive loss*). Kontrastna funkcija se uobičajeno koristi uz sijamske neuronske mreže jer u svojoj domeni i kodomeni sadrži minimalno dva elementa.

Kontrastnu kriterijsku funkciju prvi je uveo Le Cunn kako bi smanjio dimenzionalnost podataka. Trebala mu je funkcija parametarskog preslikavanja s dva ograničenja. Prvo ograničenje je da ukoliko su dva podatkovna primjera vrlo slična prije transformacije, nakon transformacije bi se trebali nalaziti blizu jedan drugom u vektorskom prostoru. Drugo ograničenje je bilo ako su dva podatkovna primjera različita prije transformacije da se tada nakon transformacije u vektorski prostor smještaju bliže jedan drugome[20]. Na slici 3.8. prikazana je transformacija podataka u vektorski prostor pomoću CNN-a. Iz slike je vidljivo kako je udaljenost između sličnih podataka u vektorskom prostoru manja dok je udaljenost između različitih podataka veća.



Slika 3.8. Transformacija podataka u vektorski prostor

Pretpostavimo da imamo par ulaznih podataka (I_i, I_j) i oznaku Y koja je jednaka 0 ako su ulazne slike slične, a 1 ako su različite. Kako bi se smanjila dimenzija ulaznih slika koristi se konvolucijska neuronska mreža f koja izdvaja značajke ulaznim podacima (I_i, I_j) gdje je $x_i = f(I_i)$ i $x_j = f(I_j)$, tada se kontrastna funkcija definira jednadžbom (3-3):

$$L = (1 - Y) * \left\| x_i - x_j \right\|^2 + Y * \max(0, m - \left\| x_i - x_j \right\|^2) \quad (3-3)$$

gdje je m hiperparametar koji definira najveću udaljenost različitih podataka [21]. Iz izraza (3-3) je vidljivo da ako je $Y = 0$, odnosno ako su ulazni podatci slični tada je izraz jednak $\left\| x_i - x_j \right\|^2$ što je zapravo euklidska udaljenost između podataka, a ukoliko su podatci različiti, tj. ukoliko je $Y = 1$, u tom slučaju je izraz jednak $\max(0, m - \left\| x_i - x_j \right\|^2)$ što je ekvivalentno maksimiziranju njihove euklidske udaljenosti do neke granice m [21].

Na modelu opisanom u potpoglavlju 3.2.3. provedeno je treniranje sa skupom podataka opisanim u potpoglavlju 3.2.2. Kako je u potpoglavlju 3.2.2. navedeno da se skup podataka koji se koristi za treniranje sastoji od 448 slika, od toga je 112 različitih otisaka prstiju, tj. od jednog otiska prsta postoje četiri slike. Prilikom učitavanja podataka za treniranje kreirani su parovi podataka s obzirom na to da sijamska mreža prima dva podatka na ulazu, odnosno u ovom slučaju dvije slike. Parovi su kreirani na način da se za svaku sliku kreiraju dva pozitivna i dva negativna para, drugim riječima za svaku sliku se kreiraju dva para koja se sastoje od slika koje prikazuju isti otisak prsta i dva para slika koja prikazuju različiti otisak prsta. Kod učitavanja podataka naziv slike rastavljen je s obzirom na pojavljivanje „_“ u nazivu te se ID osobe, broj prsta i broj slike toga prsta spremaju u zasebne varijable.

Ako je broj učitane slike jednak 1 tada se učitavaju slike toga prsta s brojevima 3 i 4 koje čine pozitivne parove te dvije nasumične slike kod kojih se razlikuje ID osobe s kojima se stvaraju negativni parovi. Ukoliko je broj učitane slike 2 tada se pozitivni parove kreiraju s brojevima slika toga prsta 1 i 4, a za negativne parove se isto odabiru dvije nasumične slike s različitim ID-em osobe, a ukoliko je broj učitane slike 3 tada se učitavaju slike s brojevima 2 i 4 toga prsta koje čine pozitivne parove, dok se negativni parovi kreiraju kao i u prethodna dva slučaja kada je broj slike prsta učitane slike bio 1 i 2. Na ovaj način je postignuto da je ujednačen broj pozitivnih i negativnih parova kako bi mreža podjednako naučila klasificirati iste i različite otiske prstiju. Nadalje, ovime je postignuto i da se parovi slika ne ponavljaju, npr. da se upare slike s brojevima 1 i 4, a poslije da se pojavi par istog toga prsta s brojevima slika 4 i 1, mreža na taj način neće ništa više naučiti samo će proces učenja trajati duže.

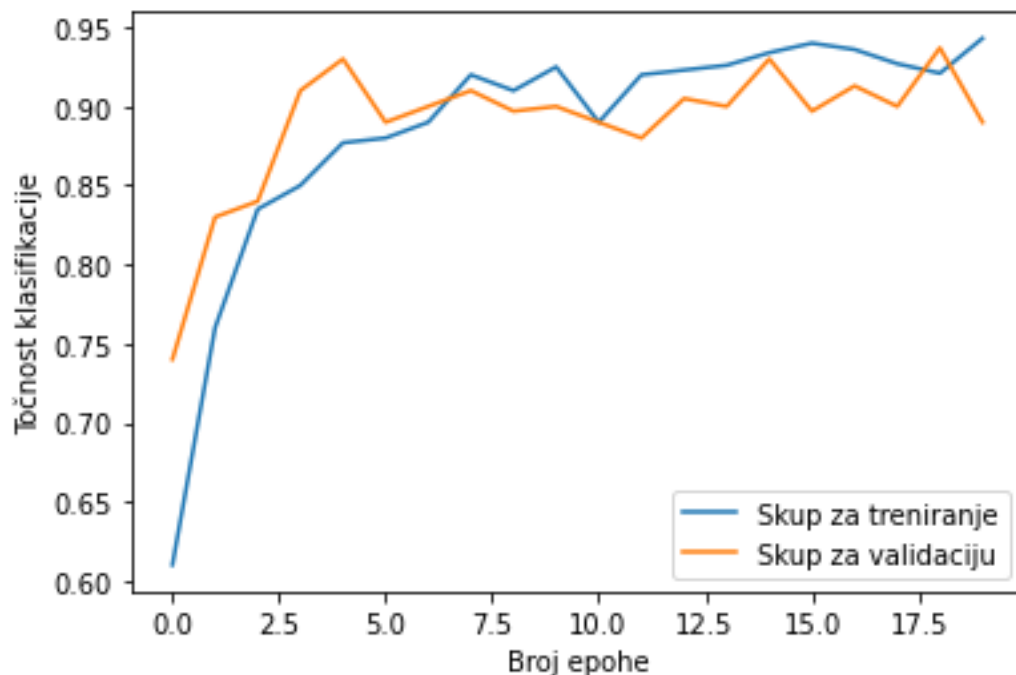
Opisanim postupkom je napravljeno 1344 pozitivna para i 1344 negativnih parova koji su korišteni za treniranje sijamske neuronske mreža. Tijekom provođenja treniranja nakon svake epohe je provedena validacija. Za validaciju su korišteni podatci iz validacijskog skupa opisanog u potpoglavlju 3.2.2. gdje je navedeno kako se validacijski skup sastoji od 96 slika. Podatci za validacijski skup učitavani su i uparivani na isti način kao i podatci za treniranje te je kreirano 144 pozitivna para i 144 negativna para.

Tijekom treniranja neuronske mreže korišteni su sljedeći parametri:

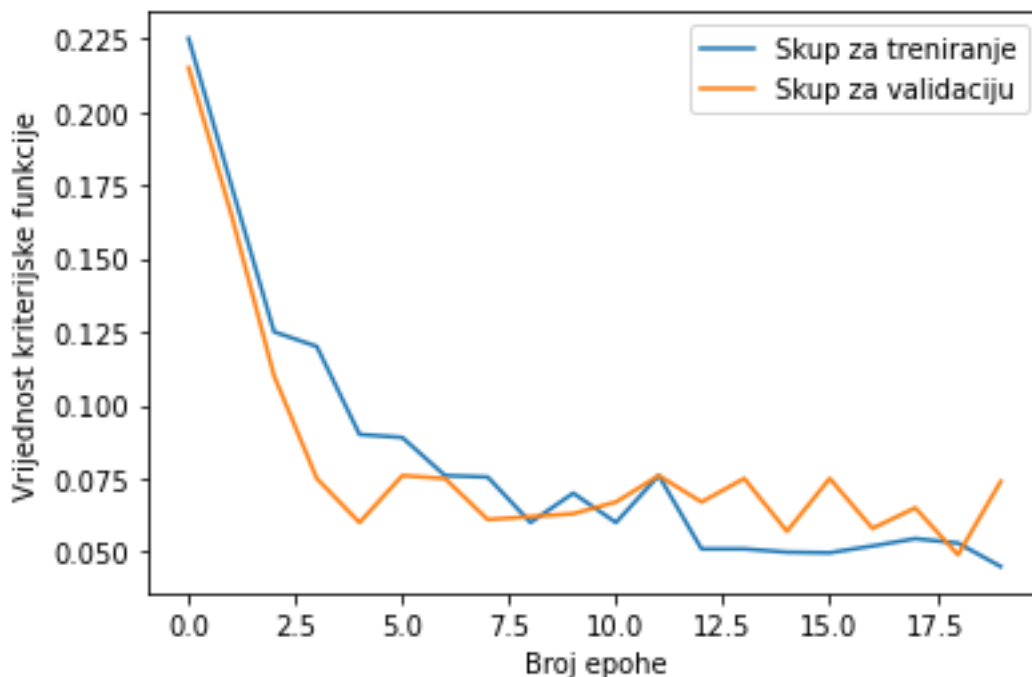
- Stopa učenja: 0.001
- Veličina serije: 8
- Broj epoha: 20

Mreža je trenirana s kontrastnom kriterijskom funkcijom čiji je rad objašnjen u potpoglavlju 3.2. te u kombinaciji s kontrastnom funkcijom korišten je RMSprop optimizator koji se pokazao uspješan kod treniranja sijamskih mreža.

Rezultati treniranja prikazani su na slikama 3.9. i 3.10. Na slici 3.9. prikazan je rezultat točnosti klasifikacije na skupu za treniranje i skupu za validaciju po epohama. Na slici 3.10. prikazana je vrijednost kriterijske funkcije tijekom treniranja, također na skupu za treniranje i skupu za validaciju.



Slika 3.9. Točnost klasifikacije na skupu za treniranje i skupu za validaciju po epohama



Slika 3.10. Vrijednost kriterijske funkcije na skupu za treniranje i skupu za validaciju po epohama

Prilikom treniranja mreže pratila se točnost klasifikacije na validacijskom skupu podataka te su pohranjene težine modela u trenutku kada je točnost na skupu za validaciju bila najveća. Prema tome točnost modela istrenirane neuronske mreže na skupu za validaciju iznosi 93.52%.

3.3. Implementacija neuronske mreže za prepoznavanje otisaka prstiju na NVIDIA Jetson Nano

Nakon izgradnje neuronske mreže, postignute težine su pohranjene na osobno računalo u formatu H5. H5 je hijerarhijski format podataka koji se koristi pri velikoj količini podataka na način da ih organizira u višedimenzionalne nizove. Zatim je datoteka s pohranjenim težinama neuronske mreže prebačena na USB *stick*, a s njega na NVIDIA Jetson Nano. Pohranjene težine se učitavaju sljedećom naredbom koja je ugrađena u Keras biblioteku:

```
keras.models.load_model('naziv_datoteke.h5')
```

Nad učitanim težinama se zatim provodi podjela s obzirom na slojeve neuronske mreže. Prvi dio neuronske mreže u kojem se odvija izdvajanje značajki korišten je prilikom pohranjivanja


slika u bazu podataka sustava, odnosno pohranjuju se vektori značajki tih slika. Posljednji slojevi u kojima se donosi odluka predviđanja korišteni su prilikom provjere otiska prsta za usporedbu dva otiska prsta, to jest dva vektora značajki.

3.4. Princip rada sustava i upute za korištenje sustava

U ovom potpoglavlju objašnjen je način korištenja sustava. Sustav je implementiran na NVIDIA Jetson Nano stoga se ondje pokreće. Skripta pomoću koje se sustav pokreće napisana je u Python programskom jeziku te je za pokretanje potrebno u terminal unijeti sljedeću naredbu:


```
python3 fingerprint_scanner.py
```

Nakon pokretanja potrebna je interakcija između korisnika i sustava. Dijagram tijeka rada sustava prikazan je na slici 3.11.



Slika 3.11. Dijagram toka rada sustava za provjeru otiska prsta

Korisniku se najprije postavlja pitanje želi li dodati novi otisak u bazu podataka ili želi izvršiti provjeru otiska prsta. Ukoliko korisnik želi provjeriti otisak prsta potrebno je u terminal upisat slovo „P“, nakon toga je potrebno umetnuti prst u kutiju koja je opisana u potpoglavlju 3.3. Kada se prst umetne potrebno je opet pritisnuti slovo „P“ kako bi se izvršila predikcija. Predikcija se izvršava na način da se trenutni otisak prsta uspoređuje sa svima koji su pohranjeni u bazu podataka, zatim se na temelju rezultata predikcije određuje postoji li otisak prsta u bazi, to jest je li otisak prst poznat (engl. *known*) ili nepoznat (engl. *unkown*), odnosno ne postoji u bazi. Na slikama 3.12. i 3.13. prikazani su slučajevi kada je otisak prsta pohranjen u bazu podataka te slučaj kada nije.



Slika 3.12. *Rezultat rada sustava kada se otisak prsta za provjeru nalazi u bazi podataka*



Slika 3.13. *Rezultat rada sustava kada se otisak prsta za provjeru ne nalazi u bazi podataka*

Nakon predikcije korisniku se daje izbor želi li provjeriti neki drugi otisak, želi li dodati novi otisak ili isključiti sustav. Za novu provjeru potrebno je stisnuti slovo „N“, za dodavanje prsta slovo „A“, dok za izlaz iz sustava slovo „Q“. Ukoliko korisnik odabere dodavanje novog otiska prsta, sustav će zatražiti unos administracijske zaporke kako bi se ograničilo da samo ovlaštene osobe mogu unijeti novi otisak prsta. Nakon unosa zaporke, ukoliko je ona neispravna korisnik može pokušati ponovno unijeti zaporku, unosom slova „A“ u terminal, ili unosom slova „S“ u terminal može se vratiti na početni odabir. Ako je zaporka ispravna, od korisnika se zatraži da unese ID, nakon toga je potrebno umetnuti prst u kutiju te pritiskom slova „S“ fotografirati prst. Prst je potrebno 3 puta fotografirati uz lagano pomicanje prsta kako bi se dobio prikaz prsta u različitim pozama, a nakon uspješnog dodavanja otiska korisnik će o tome biti obavješten. Kada je otisak prsta uspješno unesen u bazu podataka korisniku se daje izbor želi li izvršiti novi unos otiska u bazu podataka ili želi izvršiti provjeru, ako želi dodati novi otisak potrebno je u terminal upisati slovo „A“, a ako želi izvršiti provjeru potrebno je u terminal upisati slovo „P“.

4. EVALUACIJA RADA NEURONSKE MREŽE ZA PREPOZNAVANJE OTISAKA PRSTIJU

Evaluacija je postupak utvrđivanja performansi istrenirane sijamske neuronske mreže za usporedbu otisaka prstiju. Prilikom evaluacije korišten je testni skup podataka opisan u potpoglavlju 3.2.2. Testni skup sastoji se od ukupno 108 slika, od kojih je 27 različitih prstiju. Testni skup je podijeljen je na dva dijela. Prvi dio sadrži 27 slika dok drugi dio sadrži 81 sliku na način da se u drugom dijelu nalaze preostale tri slike za svaki otisak (sliku) iz prvog dijela. Testiranje je provedeno tako što se iz prvog dijela odabire jedna po jedna slika i svaka odabrana slika se uspoređuje sa svim slikama iz drugog dijela. Tim postupkom se za svaku sliku iz prvog dijela (za jedan prst) dobiva 3 pozitivna para i 78 negativnih parova. Prema tome se za testni skup podataka ukupno dobiva 81 pozitivan par i 1971 negativan par.

Na temelju rezultata testiranja dobivene su vrijednosti ispravno klasificiranih pozitivnih parova slika (engl. *True Positive* - TP), pogrešno klasificiranih pozitivnih parova (engl. *False Negative* - FN), ispravno klasificiranih negativnih parova (engl. *True Negative* - TN) i pogrešno klasificiranih negativnih parova (engl. *False Positive* - FP).


Najčešće metrike koje se primjenjuju pri evaluaciji biometrijskih sustava su stopa pogrešno predviđenih podudaranja (engl. *False Matching Rate* - FMR) koja je dana izrazom (4-1) i stopa pogrešno predviđenih nepodudaranja (engl. *False Non-Matching Rate* - FNMR) koja je dana izrazom (4-2).

$$FMR = \frac{FP}{FP + TN} \quad (4-1)$$

$$FNMR = \frac{FN}{TP + FN} \quad (4-2)$$

Najprije je na skupu za validaciju izrađen graf koji prikazuje promjene vrijednosti FMR i FNMR u ovisnosti o promjeni praga odluke izgrađene mreže. Prag odluke označava graničnu vrijednost između pozitivnih i negativnih parova, sve vrijednosti predviđanja koje su manje od praga odluke se klasificiraju kao pozitivni parovi, dok vrijednosti predviđanja koje su jednake ili veće od praga odluke se klasificiraju kao negativni parovi. Na slici 4.1. nalazi se graf na kojem su prikazane krivulje FMR i FNMR u ovisnosti o promjeni vrijednosti praga odluke izgrađene mreže. Iz grafa je vidljivo kako povećanjem praga odluke krivulja FMR raste, dok krivulja FNMR opada. Razlog tomu je što se povećanjem praga odluke povećava broj pogrešno klasificiranih negativnih parova i smanjuje udio pozitivnih parova u skupu kojeg je model klasificirao kao pozitivne parove.

Odnosno smanjenjem praga odluke smanjuje se broj pogrešno klasificiranih negativnih parova te će u skupu koji je model klasificirao kao pozitivne parove biti veći udio parovi koji su zaista pozitivni. Nadalje, iz grafa se može iščitati stopa jednake pogreške (engl. *Equal Error Rate* - EER). Vrijednost y osi sjecišta krivulje FMR i FNMR predstavlja stopu jednake pogreške, u ovome slučaju ona iznosi 6.54%.



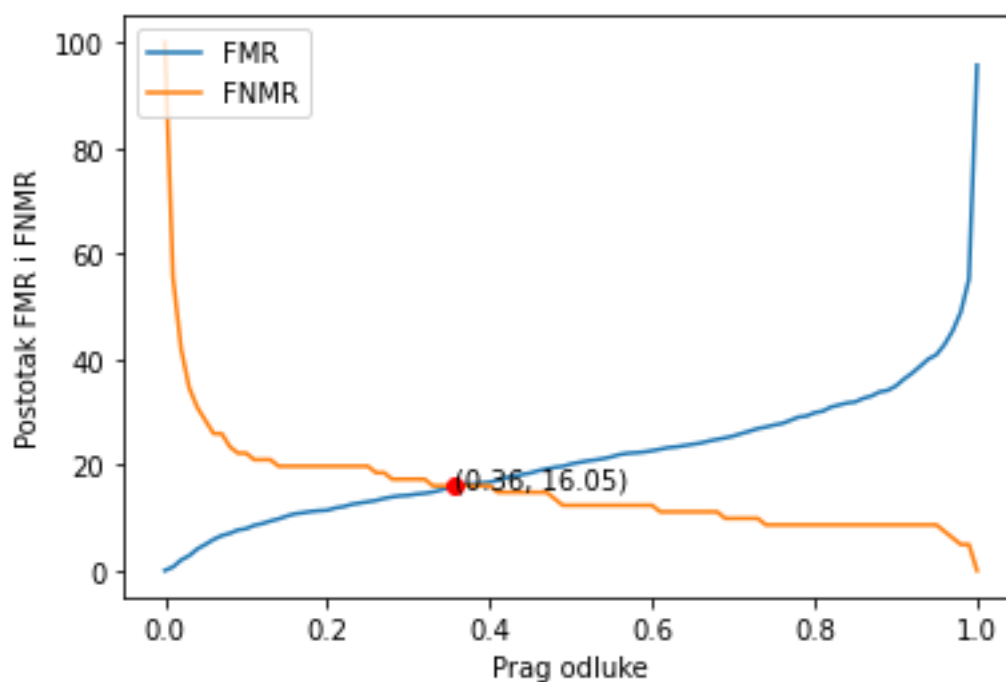
Slika 4.1. Prikaz FMR i FNMR s dobivenom vrijednosti stope jednake pogreške na skupu za validaciju

Dobiveni prag odluke od 0.42 korišten je kao granična vrijednost prilikom evaluacije predložene neuronske mreže na skupu za testiranje. Svi parovi slika čija je vrijednost predikcije ispod 0.42 klasificirani su kao jednaki, a parovi čija je vrijednost predikcije veća ili jednaka 0.42 klasificirani su kao različiti. Dobiveni rezultati na skupu za testiranje uz prag odluke od 0.42 prikazani su u tablici 4.1. u obliku matrice zabune.

Tablica 4.1. Dobivena matrica zabune na testnom skupu uz primijenjeni prag odluke 0.42

		Predviđene vrijednosti	
		Pozitivni parovi	Negativni parovi
Stvarne vrijednosti	Pozitivni parovi	69	12
	Negativni parovi	346	1625

Određivanje EER obavljeno je i na testnom skupu jer predstavlja realan slučaj korištenja sustava. Na slici 4.2. prikazane su krivulje FMR i FNMR u ovisnosti o vrijednosti praga odluke za testni skup. Može se primijetiti sličan tijek krivulja kao i u slučaju validacijskih podataka, premda je testni skup prilično nebalansiran.



Slika 4.2. Prikaz FMR i FNMR s dobivenom vrijednosti stope jednake pogreške na skupu za testiranje

Dobivena je stopa jednake pogreške na skupu za testiranje od 16.05%, dok prag odluke iznosi 0.36 te je primijenjen prilikom testiranja. Dobiveni rezultati testiranja prikazani su tablicom 4.2.

Tablica 4.2. Dobivena matrica zabune na testnom skupu uz primijenjeni prag odluke 0.36

		Predviđene vrijednosti	
		Pozitivni parovi	Negativni parovi
Stvarne vrijednosti	Pozitivni parovi	68	13
	Negativni parovi	321	1650

Usporedbom rezultata iz tablica 4.1. i 4.2. vidljivo je kako se smanjenjem praga odluke s 0.42 na 0.36 smanjio broj pogrešno klasificiranih negativnih parova s 346 na 321 što je izrazito važno za praktičnu upotrebu ovog sustava.

Pomoću rezultata dobivenih u tablici 4.2. mogu se dodatno evaluirati performanse izgrađenog modela. Metrike neuronske mreže se izražavaju preko točnosti (engl. *accuracy*), preciznosti (engl. *precision*) te odziva (engl. *recall*).

Točnost predstavlja udio točno klasificiranih parova, računa se omjerom broja točno klasificiranih parova i ukupnog broja svih parova u testnom skupu što je prikazano izrazom (4-3).

$$Točnost = \frac{TP+TN}{TP+TN+FP+FN} \quad (4-3)$$

Preciznost je udio točno klasificiranih parova u skupu koje model klasificira kao pozitivne. Računa se pomoću omjera broja ispravno klasificiranih pozitivnih parova i zbroja ispravno klasificiranih pozitivnih parova i pogrešno klasificiranih negativnih parova, izraženo izrazom (4-4).

$$Preciznost = \frac{TP}{TP+FP} \quad (4-4)$$

Odziv se definira kao udio točno klasificiranih parova u skupu pozitivnih parova. Računa se prema izrazu (4-5), odnosno kao omjer broja ispravno klasificiranih pozitivnih parova i ukupnog broja pozitivnih parova.

$$Odziv = \frac{TP}{TP+FN} \quad (4-5)$$

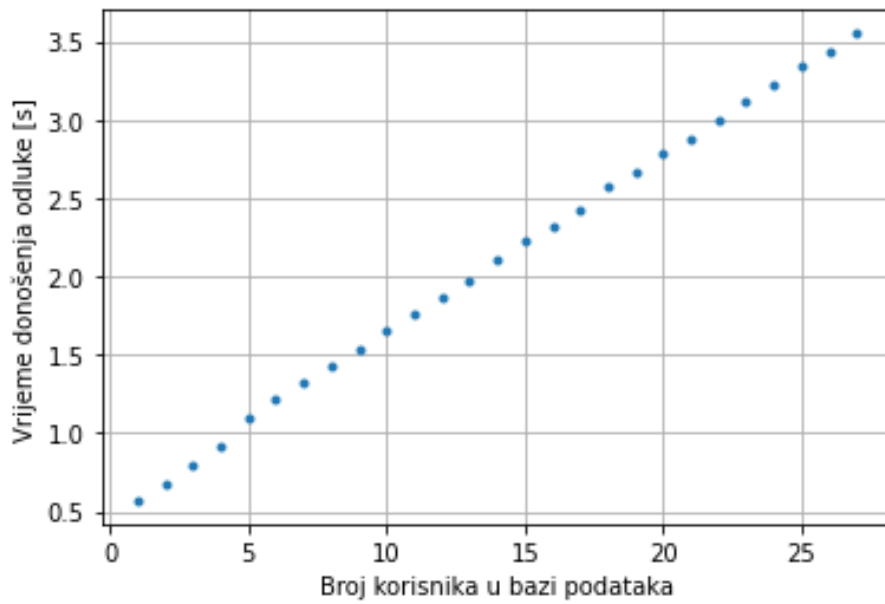
Na osnovu navedenih izraza određene su vrijednosti metrika za izrađenu neuronsku mrežu na skupu za validaciju i na skupu za testiranje, rezultati su prikazani u tablici 4.3.

Tablica 4.3. *Vrijednosti metrika na skupovima za validaciju i testiranje*

	Točnost	Preciznost	Odziv	FMR	FNMR	EER
Skup za validaciju	93.52%	94.34%	92.59%	5.56%	7.4%	6.54%
Skup za testiranje	83.72 %	85%	83.95%	16.29%	16.05%	16.05%

Usporedbom dobivene točnosti klasifikacije s dosadašnjim radovima, predloženi sustav je postigao lošije rezultate u odnosu na radove [9] i [10], dok je usporedbom vrijednosti FMR postigao bolje rezultate u odnosu na rezultate dubokog učenja iz rada [12]. Za ovakav sustav najbitnije je da ima visoku preciznost jer se ona odnosi na to u kojoj je mjeri model točno klasificirao pozitivne parove, odnosno najbitnije je da model u što manjoj mjeri negativne parove klasificira kao pozitivne. Također je bitno da je vrijednost FMR što manja jer ona označava postotak negativnih parova koji su klasificirani kao pozitivni.

Osim evaluacije neuronske mreže preko metrika, mreža je evaluirana s obzirom na brzinu rada. Na slici 4.3. prikazani su rezultati testiranja brzine donošenja odluke u odnosu na broj korisnika koji se nalaze u bazi podataka. Evaluacija je provedena na način da se brzina donošenja odluke mjeri najprije za jednog korisnika te se u svakoj sljedećoj iteraciji broj korisnika povećava za jedan i tako sve dok broj korisnika ne bude 27 jer se toliko različitih otisaka prstiju nalazi u testnom skupu podataka. Za svakog su korisnika u bazi podataka pohranjena tri vektora značajki nastali prilikom unosa korisnika u bazu podataka te se prilikom provjere otiska prsta vektor značajki ulazne slike uspoređuje s 3 vektora značajki za svakog korisnika iz baze podataka.



Slika 4.3. *Brzina donošenja odluke s obzirom na broj slika u bazi podataka*

Prema slici 4.3. može se uočiti kako se povećanjem broja korisnika, vrijeme odluke povećava linearno, odnosno približno 0.11 sekundi za svakog dodanog korisnika. U prilogu P.3.6. nalaze se precizni rezultati evaluacije brzine donošenja odluke u obliku tablice.

5. ZAKLJUČAK

Kako bi se omogućila sigurnija autentikacija osoba od autentikacije pomoću PIN-a ili zaporke pojavila se potreba za drugim pristupima te se počela koristiti provjera biometrijskih obilježja jer su daleko složenija od tradicionalnih vrsta zaštita. Otisak prsta kao najkorištenije biometrijsko obilježje tema je i ovoga rada jer je primijećena manjkavost kontaktnih čitača otisaka prsta te se počeo istraživati beskontaktni način prikupljanja otisaka prsta. Prilikom beskontaktnog prikupljanja otisaka prstiju senzor je RGB kamera te se daljnjim algoritmima utvrđuje podudara li se taj otisak prsta s nekim iz baze podataka. Tri glavne metode za provjeru su algoritam za izdvajanje detalja, duboko učenje i kombinacija te dvije metode.

U okviru ovog rada izrađen je sustav za beskontaktno prepoznavanje otisaka prstiju temeljen na dubokom učenju, odnosno korištenjem sijamske neuronske mreže. Najprije je bilo potrebno izraditi fizičko okruženje za prikupljanje slika otisaka prstiju. Fizičko okruženje se sastoji od NVIDIA Jetson Nano jednokartičnog računala i izrađene kutije s ugrađenom kamerom i osvjetljenjem. Potom je izgrađeni skup podataka za treniranje, validaciju i testiranje neuronske mreže. U prikupljanju podataka sudjelovala je 21 osoba, od kojih je uzorkovano 8 prstiju, prikupljene slike podijeljene su u tri skupa podataka, za treniranje, validaciju i testiranje. Korištena arhitektura neuronske mreže je detaljno opisana kao i korišteni parametri prilikom treniranja te kriterijska funkcija. Nakon toga je treniranjem više različitih arhitektura neuronske mreže odabrana ona koja postiže najveću točnost klasifikacije na validacijskom skupu podataka. Istrenirani model je testiran na skupu za testiranje te je postigao točnost klasifikacije od 83.72%, preciznost od 85% te odziv od 83.95%. Zatim je istrenirani model implementiran na NVIDIA Jetson Nano te je opisan način korištenja sustava.

Postignuti rezultati bi se mogli poboljšati povećanjem skupa podataka za učenje i unaprjeđenjem same arhitekture neuronske mreže. Osim toga, dodavanjem metode za izdvajanje detalja te kombinacijom rezultata dobivenih dubokim učenjem i metodom izdvajanja detalja također se mogu postići bolji rezultati rada sustava.

LITERATURA

[1] TechTarget. Com [Mrežno] dostupno na:

<https://www.techtarget.com/searchsecurity/definition/authentication#:~:text=Authentication%20is%20the%20process%20of,in%20a%20data%20authentication%20server> [20.8.2023.]

[2] A. K. Jain, A. A. Ross, P. Flynn, „Handbook of Biometrics“, New York, Springer US, 2008.

[3] S. M. Furman, B. C. Stanton, M. F. Theofanos, J. M. Libert and J. D. Grantham, "Contactless fingerprint devices usability test", 2017.

[4] A. Kumar, „Contactless 3D Fingerprint Identification“, Springer International Publishing, Cham, 2018.

[5] M. M. Houck „Foresnic fingerprints“, Elsevier Science, Petersburg, 2016.

[6] B. Innes, J. Singer „Fingerprints and impressions“, aylot & Francis, New York, 2015.

[7] B. Y. Hiew, A. B. J. Teoh, Y. H. Pang. „Digital camera based fingerprint recognition“, IEEE International Conference on Telecommunications and Malaysia International Conference on Communications, sv. 3. str. 1-6, 2007.

[8] S. Daas, A. Yahi, T. Bakir, M. Sedhane, M. Boughazi, and E.-B. Bourennane, “Multimodal biometric recognition systems using deep learning based on the finger vein and finger knuckle print fusion,” IET Image Processing, sv. 14, br. 15, str. 3859–3868, 2020.

[9] Herbadji, N.Guermat, Z. Akhtar, „Deep neural networks based contactless fingerprint recognition“, International Conference on New Technologies of Information and Communication, sv. 1, str. 1-6, 2022.

[10] S. Rote, P. Pimpale, K. Reddy, G.T. Haldankar i P. Chimurkar „Contactless Fingerprint Verification Using Neural Networks“, International Conference on Communication information and Computing Technology, sv. 5, str. 1-4, Mumbai, 2021.

[11] K. Rajaram, N. G. Bhuvaneshwari Amma, S. Selvakumar , „Convolutional neural network based children recognition system using contactless fingerprints“, Springer Link, Indija, 2023., dostupno na: <https://link.springer.com/article/10.1007/s41870-023-01306-7> [19.7.2023.]

[12] A. Attrish, N. Bharat, V. Anand „A Contactless Fingerprint Recognition System“, Computer Vision and Pattern Recognition, sv. 1, str. 1-8, Ithaca, 2021.

- [13] Nvidia.com [Mrežno], dostupno na: <https://developer.nvidia.com/embedded/jetson-nano-developer-kit> [24.7.2023.]
- [14] Nvidia.com [Mrežno], dostupno na: <https://docs.nvidia.com/deeplearning/frameworks/install-tf-jetson-platform/index.html> [25.7.2023.]
- [15] Keras.io [Mrežno], dostupno na: <https://keras.io/> [24.7.2023.]
- [16] NumPy.org [Mrežno], dostupno na: <https://numpy.org/> [25.7.2023.]
- [17] J. Bromley, J. W Bentz, L. Bottou, I. Guyon, Y. LeCun, C. Moore, E. Sackinger, R. Shah, „Signature verification using a siamese time delay neural network. International Journal of Pattern Recognition and Artificial Intelligence“, American Telephone and Telegraph Company, Holmdel, 1994.
- [18] M. P. Deisenroth, A. A. Faisal, C. Soon Ong „Mathematics for Machine Learning“, Cambridge University Press, UK, 2020.
https://www.google.hr/books/edition/Mathematics_for_Machine_Learning/pFjPDwAAQBAJ?hl=en&gbpv=0
- [19] R. T. Kneusel „Practical Deep Learning: a python-based introduction“, William Pollock, San Francisco, 2021.
- [20] Q. Huang, Y. Wang, Y. Peng „Image and Graphics Technologies and Applications“, Springer Nature Singapore, Beijing, 2019.
- [21] Baeldung.com [Mrežno], dostupno na: <https://www.baeldung.com/cs/contrastive-learning> [24.7.2023.]

SAŽETAK

U ovom diplomskom radu izrađen je beskontaktni sustav za prepoznavanje otisaka prstiju. Prije svega dan je pregled dosadašnjih rješenja koji se temelje na tri metode, metoda za izdvajanje detalja, dubokim učenjem te kombinacije tih dviju metoda. Zatim je opisano predloženo rješenje u ovom radu. Budući da nije pronađen odgovarajući skup podataka za učenje neuronske mreže, izrađen je vlastiti skup podataka koji je služio za treniranje i testiranje neuronske mreže. Sustav se temelji na sijamskoj neuronskoj mreži koja se sastoji od dvije neuronske mreže. Sijamska neuronska mreža na ulazu prima dvije RGB slike na kojima su prikazani otisci prstiju, slike se predaju neuronskoj mreži čiji su izlazi vektori značajki. Zatim se računa euklidska udaljenost između dobivenih vektora koja predstavlja mjeru sličnosti u intervalu između 0 i 1. Izlaz iz mreže će biti bliže 1 ukoliko su otisci prstiju različiti ili bliže 0 ukoliko su otisci prstiju sličniji. Istrenirani model je implementiran na NVIDIA Jetson Nano te je izrađeno fizičko okruženje s ugrađenom kamerom i LED trakom koja služi za slikanje otisaka prstiju. Izrađena sijamska neuronska mreža evaluirana je na skupu podataka za testiranje i iz rezultata testiranja je vidljivo kako ima mjesta za napredak.

Ključne riječi: otisak prsta, sijamska neuronska mreža, autentikacija, NVIDIA Jetson Nano

ABSTRACT

In this master thesis, a non-contact system for recognizing fingerprints was developed. Firstly, an overview of the previous solutions based on three methods, methods for extracting details, deep learning and a combination of these two methods is given. Then the solution proposed in this paper is described. Since no suitable data set was found for learning the neural network, an own data set was created that was used for training and testing the neural network. The system is based on a Siamese neural network consisting of two neural networks. Siamese neural network at the input receives two RGB images on which fingerprints are displayed, the images are given to the neural network whose outputs are feature vectors. Then the Euclidean distance between the obtained vectors is calculated, which represents a measure of similarity in the interval between 0 and 1. The output from the network will be closer to 1 if the fingerprints are different or closer to 0 if the fingerprints are more similar. The trained model was implemented on NVIDIA Jetson Nano and a physical environment was created with a built-in camera and an LED strip used for fingerprint imaging. The constructed Siamese neural network was evaluated on the test data set and the test results show that there is room for improvement.

Keyword: Fingerprint, Siamese neural network, Authentication, Nvidia Jetson Nano

ŽIVOTOPIS

Andreja Gojić rođena je u Našicama 18. listopada 1999. godine. 2014. godine završava Osnovnu školu A. G. Matoša u Čačincima te iste godine upisuje Srednju školu „Stjepan Ivšić“ Orahovica, smjer opća gimnazija. Nakon završene srednje škole, 2018. godine, upisuje sveučilišni preddiplomski studij Računarstva na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku. Preddiplomski studij završava 2021. godine, a iste godine upisuje diplomski studij, smjer Informacijske i podatkovne znanosti također u Osijeku. Na završnoj godini diplomskog studija postaje stipendist tvrtke TTTechAuto d.o.o.

Potpis:

PRILOZI

Prilog P.3.1. Instalacija korištenih biblioteka (elektronički prilog)

Prilog P.3.2. Skup podataka koji je kreiran za potrebe izrade rješenja (elektronički prilog).

Prilog P.3.3. Programski kod korišten za treniranje neuronske mreže (elektronički prilog).

Prilog P.3.4. Programski kod korišten za testiranje neuronske mreže (elektronički prilog).

Prilog P.3.5. Programski kod koji je implementiran na Nvidia Jetson Nano (elektronički prilog).

Prilog P.3.6. Brzina donošenja odluke s obzirom na broj korisnika u bazi podataka (elektronički prilog).