Korištenje geometrije dlana za identifikaciju osoba

Hrastinski, Davor

Undergraduate thesis / Završni rad

2018

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:211:885423

Rights / Prava: Attribution 3.0 Unported/Imenovanje 3.0

Download date / Datum preuzimanja: **2024-03-28**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Davor Hrastinski

KORIŠTENJE GEOMETRIJE DLANA ZA IDENTIFIKACIJU OSOBA

ZAVRŠNI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Davor Hrastinski

Matični broj: Z 35365/06 J

Studij: ***Primjena informacijske tehnologije u poslovanju***

KORIŠTENJE GEOMETRIJE DLANA ZA IDENTIFIKACIJU OSOBA

ZAVRŠNI RAD

Mentorica:

Doc. dr. sc. Petra Grd

Varaždin, rujan 2018.

Davor Hrastinski

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

Sadržaj:

1. Uvod 1

2. Identitet i identifikacija 2

3. Biometrija 3

4. Biometrijske metode 4

4.1. Identificiranje temeljem otisaka prstiju 4

4.2. Lice 5

4.3. Geometrija dlana 5

4.4. Šarenica i mrežnica oka 6

4.5. Termogram lica i tijela 7

4.6. 3D fotogrametrijska antropologija i 3D facijalna rekonstrukcija 7

4.7. Tjelesni mirisi 8

4.8. Odontologija – utvrđivanje identiteta temeljem statusa zubala 8

4.9. Analiza glasa 9

4.10. Rukopis i potpis 9

4.11. Dinamika tipkanja 10

4.12. Dinamika hoda 11

4.13. Uho 11

4.14. DNK 12

5. Biometrijska metoda identifikacije osobe na temelju geometrije dlana 13

5.1. Biometrijsko prepoznavanje 13

5.2. Biometrija dlana 14

5.2.1. Građa dlana 15

5.2.2. Značajke dlana 15

5.2.3. Opis sustava za raspoznavanje dlana 16

5.2.4. Fourierova transformacija, PCA, LDA, ICA 20

5.2.5. RGB 20

6. Praktični dio rada 21
6.1. Točka koordinatnog sustava 21
6.2. Dohvaćanje i postavljanje piksela 22
6.3. Razlikovanje dlana od pozadine na slici 22
6.4. Pronalazak prstiju na dlanu 24
6.5. Izmjera udaljenosti između dvije točke 25
6.6. Pronalazak točke na zadanoj dužini 26
6.7. Okomica 27
6.8. Korištenje aplikacije 30
6.8.1. Administracija 31
6.8.2. Korisnik 32
7. Zaključak 33
Popis literature 34
Popis slika 35

1. Uvod

Biometrija (starogrčki bio-život, metron-mjera) je znanost o automatiziranim postupcima za jedinstveno prepoznavanje ljudi na temelju jedne ili više njihovih fizičkih i ponašajnih karakteristika. Kako se tehnologija brzo razvijala povećala se potreba za pouzdanim načinima identifikacije osoba [5].

U informatičkoj tehnologiji se biometrijska autentifikacija odnosi na tehnologije koje mjere i analiziraju fizičke (otisci prstiju, rožnica oka, prepoznavanje lica, dlana i slično), i ponašajne karakteristike (rukopis, tipkanje, hod i slično) čovjeka. Biometrija objedinjuje korištenje specijalnih uređaja koje prate određene fizičke ili ponašajne karakteristike te programa koji analiziraju dobivene informacije [4].

Biometrija se koristi od davnih vremena i razvijala se sukladno razvoju ljudskog znanja, odnosno tehnologije i znanosti, čiji vrtoglavi razvoj u zadnjim desetljećima otvara neslućene mogućnosti njihovog apliciranja u područjima identifikacije. U samim počecima izvedbe i upotrebe biometrijskih sustava, prednost je davana fiziološkim karakteristikama u odnosu na ponašajne karakteristike. Prevladavalo je mišljenje da fiziološke značajke, u odnosu na ponašajne, posjeduju ″uočljivost″. Prema tome mišljenju, prevladavalo je i uvjerenje kako su fiziološke karakteristike pouzdanije od ponašajnih, jer one imaju tendenciju manjih razlika unutar grupa, nego li to imaju ponašajne karakteristike. Klasične metode identifikacije u novom okruženju dobivaju novu, dodatnu kvalitetu, a ustanovljuju se i potpuno nove metode [1, 5].

U ovom radu ću opisati biometrijske metode te ih ukratko objasniti. Detaljno ću objasniti biometriju dlana te ću opisati sustave za raspoznavanje dlana. Također ću izraditi aplikaciju za identificiranje osoba kod ulaza u prostoriju kao praktični dio.

2. Identitet i identifikacija

Svaki čovjek, životinja ili predmet, jedinstven je, neponovljiv i identičan samo sam s sobom što znači da se razlikuje od svih ostalih ljudi, životinja ili predmeta. Identitet s toga predstavlja skup ustaljenih, nepromjenjivih, obilježja koja čine određenu osobu ili predmet, kojima se ta osoba i predmet razlikuje od svih drugih. No, često su objekti iste vrste vrlo slični i ne mogu se razlikovati bez primjene određenih metoda, kojima će se detektirati i u postupku identifikacije koristiti detalji po kojima se objekti ipak razlikuju. Taj skup karakteristika koje su specifične za pojedinca naziva se individualnost [1, 2].

Identitet određene osobe dijeli se na osobni identitet (temeljen na podacima stečenim samim rođenjem – ime, prezime, datum i mjesto rođenja te podaci o roditeljima), biografski identitet (koja osoba stječe kroz život, koji se prati preko službenih dokumenata i uvjerenja – škola, posao, banka, liječnički karton…) i biometrijski identitet (zasnovan je na jedinstvenim fizičkim ili ponašajnim karakteristikama – otisak dlana, analiza lica, DNK analiza…) [2].

Postoje 3 načina provjere identiteta:

- nešto što znaš (PIN, šifra, neka osobna informacija)
- nešto što imaš (dokument, identifikacijska kartica)
- nešto što jesi (izgled – biometrija) [8].

Identifikacija osoba je utvrđivanje istovjetnosti nepoznatog s otprije poznatim, na temelju određenih identifikacijskih obilježja. To je postupak usporedbe određenog broja identifikacijskih obilježja, pri čemu se ustanovljava podudarnost ili različitost između objekata koji se uspoređuju. Da bi se neko obilježje moglo koristiti u procesu identifikacije, treba zadovoljiti sljedeće zahtjeve:

- univerzalnost (da ga posjeduje svaka osoba)
- individualnost ili originalnost (da je različito kod svake osobe)
- trajnost i nepromjenjivost
- mogućnost izdvajanja iz ukupnosti obilježja
- jednostavno prikupljanje i korištenje [1].

3. Biometrija

Biometrija je znanost o automatiziranim postupcima za jedinstveno prepoznavanje ljudi na temelju jednog ili više urođenih tjelesnih obilježja, ili obilježja čovjekovog ponašanja. Može se također definirati i kao matematičko statistička metoda za istraživanje živih bića s obzirom na njihove odnose mjere i broja koji se utvrđuju korištenjem automatiziranih tehničkih sustava mjerenja i registracije [1].

Biometrijske metode temelje se na klasičnim, standardnim identifikacijskim metodama koje datiraju iz davne povijesti čovječanstva. Kao primjer možemo navesti mjerenje stopala djece u srednjovjekovnoj Kini kako bi se očuvao njihov identitet i onemogućila zamjena te u policijske svrhe mjerenja raznih dijelova tijela kako bi evidentirali i prepoznali počinitelje kaznenih dijela. Također se u Babilonu otisak prsta na glinenim pločicama koristio za poslovne transakcije. U novije vrijeme biometrija je doživjela punu afirmaciju i procvat. Razlog tome je brzi razvoj tehnologije koja klasičnim biometrijskim metodama daje novu dimenziju, a osobito u razvoju računalne industrije (hardverskih mogućnosti, softverskih alata) čime se mogućnosti primjene otvaraju do neslućenih granica, koje su u nedavnoj prošlosti bile nezamislive. Jedan od najboljih primjera je da prije desetak godina rijetko tko imao mobilni telefon, dok danas je nezamislivo da ga netko nema. Suvremena biometrijska tehnologija omogućuje gotovo neograničena precizna mjerenja i registriranja tjelesnih, ali i ponašajnih obilježja [1, 2].

4. Biometrijske metode

Temeljem navedenih fizioloških i bihevioralnih karakteristika nastale su sljedeće biometrijske metode identifikacije osoba.

4.1. Identificiranje temeljem otisaka prstiju

Identifikacija otiscima papilarnih linija prstiju i dlanova temelju se na jedinstvenom rasporedu udubljenja i ispupčenja kože – dermatoglifa. Za evidentiranje otisaka prstiju postoje mnoge tehnologije, a najpoznatije su: optička, kapacitivna, radijska, tehnologija tlaka, mikro-elektromehanička metoda i dr. [1, 2].

Otisci prstiju su jedinstveni za svaki prst osobe, uključujući i jednojajčane blizance. Koriste se već čitavo stoljeće i vrijednost takve identifikacije vrlo je dobro dokazana. Ovakva vrsta identifikacije najrasprostranjenija je u kriminalistici. Otisak prsta je jedna od najdostupnijih biometrijskih tehnologija. Uređaj za raspoznavanje otisaka prstiju za desktop, laptop i mobitel pristup su sada široko dostupni od mnogih proizvođača po niskom cijenama. S tim uređajima korisnici više ne trebaju utipkavati lozinke, samo dodir pruža trenutni pristup računalu. Sustavi za otiske prstiju mogu se također koristiti u identifikacijskom modu [2, 5].

Kako bi se spriječilo korištenje umjetno napravljenih otisaka prstiju neke osobe, mnogi sustavi uz skeniranje otiska mjere i protok krvi. Korištenje više prstiju u procesu prepoznavanja povećava sigurnost metode [5].



Slika 1: Digitalizirani predložak otiska prsta [4]

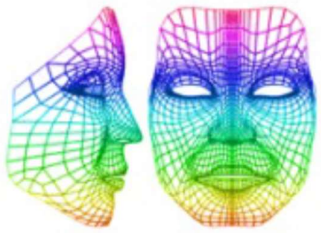
4.2. Lice

Sustavi za raspoznavanje lica imaju primjenu u različitim područjima kao što su: video telefonija, kompresija baza slika, pristup računalnim resursima, kriminalističke svrhe. To je jedna od relativno jeftinijih metoda jer ne zahtijeva skupu specijalnu opremu. Dovoljno je osobno računalo i video kamera [4, 5].

Obzirom na cijene sustava možemo ih podijeliti:

- Kućne sustave – koristi se za zaštitu osobnih računala omogućujući zaključavanje određenih datoteka, dijelova tvrdog diska, aplikacija ili čitavog računala.
- Poslovne proizvode – ovi mrežno centralizirani sustavi dijele se na one koji se usko vežu na sigurnost domene u mrežnom operacijskom sustavu ili isporučuju svoje vlastite alate za bazu podataka i administriranje, te su dizajnirani za velik broj korisnika [5].

U klasičnim postupcima identifikacije, ona se bazira na izgledu lica, a takav način identifikacije ljudima je urođen jer su osobe prepoznatljive po izgledu lica, odnosno lice svakog pojedinog čovjeka je individualno (razlikuje se od svih ostalih lica). No, problem kod identifikacije prepoznavanja je u subjektivnosti (kako se ljudi sjećaju, pamte, percipiraju i sl.) pa je ovakav način identifikacije često i vrlo nepouzdan. Raspoznavanje osoba preko lica spada u nenametljive tehnike zbog čega ljudi obično nemaju problema sa prihvaćanjem lica, kao biometrijske karakteristike [2].



Slika 2: Biometrijski uzorak prepoznavanja lica [4]

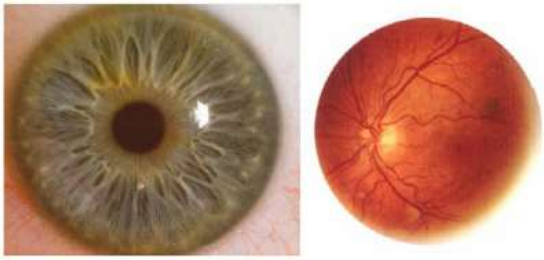
4.3. Geometrija dlana

Raspoznavanje ruke dostupno je već preko 20 godina. Ekstrakcija značajki postiže se mjerenjem širine i duljine prstiju na različitim lokacijama. To uključuje dužinu, širinu, debljinu i površinu područja dlana. Izmjerene vrijednosti predstavljaju vektor značajki korisnikove ruke koji se koristi za usporedbu s vektorima u bazi. Vrlo jednostavna i cijenom prihvatljiva tehnika niskog praga točnosti. Više o geometriji dlana u nastavku rada [4, 5].

4.4. Šarenica i mrežnica oka

Šarenica je obojeni dio oka koji okružuje zjenicu, a sastoji se od prstena, brazdi i pjega u različitim bojama, koji čije jedinstveni vremenski nepromjenjiv kompleks boja i šara kod svakog pojedinca. Ispunjava pretežiti broj zahtjeva koje se traže za identifikacijska obilježja – univerzalna, trajna i nemoguće ju je mijenjati bez velikog rizika gubitka vida. Sustav se ne može prevariti lećama (postoje algoritmi koji registriraju leće), staklenim ili pravim okom odstranjenim s mrtvog čovjeka (nema očekivane kontrakcije ili širenja zjenice pri obasjavanju oka). Ova tehnika vrlo je jednostavna i pouzdana, neinvazivna, može se obaviti i snimanje s običnom kamerom s udaljenosti i do pola metra. Za pregled baze potrebno je par sekundi. Skeniranje šarenice (irisologija) jedna je od najpouzdanijih biometrijskih metoda, ponajviše zbog prirodnih karakteristika šarenice [1, 2].

Mrežnica je tanki sloj stanica, splet krvnih žila koji se nalazi u stražnjem dijelu oka. Njena struktura je individualna, jedinstvena karakteristika svake osobe. Ovo je jedno od najsigurnijih biometrijskih identifikacijskih obilježja, jer nije moguće promijeniti ili replicirati unutarnju strukturu oka, niti se ona mijenja tijekom čitavog života, a mrežnica mrtve osobe toliko brzo propada da nisu neophodne dodatne mjere utvrđivanja znakova smrti. Za uspješno skeniranje mrežnice oka potrebno je oko približiti skeneru te fokusirati pogled na određenu točku. Proces skeniranja traje između 10 i 15 sekundi, oko se za vrijeme skeniranja osvjetljava blagim snopom svjetlosti, zbog čega spada u neugodnije i nametljive biometrijske metode. Zbog visoke cijene i visoke pouzdanosti koristi se u područjima i objektima visokog stupnja sigurnosti [1, 2].

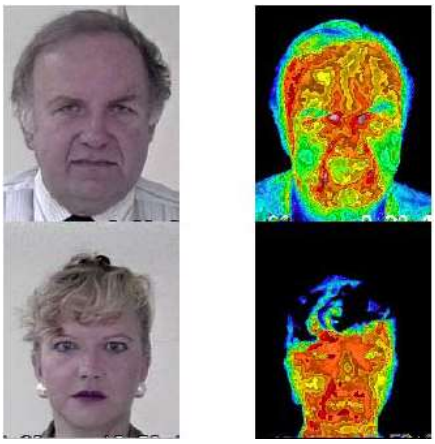


Slika 3: Šarenica oka i mrežnica oka [5]

4.5. Termogram lica i tijela

Snimanje lica i tijela infracrvenom kamerom naziva se termogram lica i tijela. Splet krvnih žila kojima je prožeto ljudsko tijelo, a posebno njegov potkožni dio, predstavlja jedinstveno obilježje i individualan je kod svakog pojedinog čovjeka. Snimanjem infracrvenom kamerom (mjerenjem razlika u temperaturi na površini ljudske kože) omogućuje se registriranje toplinskog zračenja koje krvne žile emitiraju kroz kožu. Termogram lica i tijela jedinstven je za svaku osobu i predstavlja postojanu biometrijsku karakteristiku jer se može promijeniti samo kirurškim zahvatom. Nedostatak ove metode je cijena infracrvene kamere, a kako dobivene slike zauzimaju dosta prostora ova metoda nije pogodna za velike baze [1, 5].

Koristi se u situacijama kada je potrebno izvršiti brzu identifikaciju, izdvajanje željenog lica iz skupine. Identifikaciju je moguće obaviti pod raznim svjetlosnim uvjetima uključujući i po mraku. Omogućuje prepoznavanje i bez suradnje osobe, snimanje s veće udaljenosti te spada u grupu nenametljivih tehnika [1, 5].



Slika 4: Termogram lica [5]

4.6. 3D fotogrametrijska antropologija i 3D facijalna rekonstrukcija

3D fotogrametrijska antropologija je metoda kojom se iz snimaka dobivenih videokamerama uz pomoć odgovarajućeg softvera mogu izmjeriti pojedini dijelovi tijela osobe, te na osnovi tih mjera vrlo precizno razlikovati tu osobu od drugih. 3D facijalna rekonstrukcija je metoda identifikacije primjenom odgovarajućeg softvera radi rekonstrukcije izgleda lica osobe na temelju izgleda kostura lica i glave [1].

Obje od ovih metoda vrlo su važne osobito u slučaju posjedovanja video snimke s mjesta počinjenja kaznenog dijela na kojoj su vidljivi nepoznati počinitelji kao i kod identifikacije pronađenih nepoznatih mrtvih tijela na kojima je uništeno meko tkivo [1].

4.7. Tjelesni mirisi

Miris tijela ima nekoliko funkcija, među kojima su komunikacija, privlačenje partnera, zaštita okoliša, obrana od napada i slično. Komponenta mirisa emitiranog od ljudskog (ili životinjskog) tijela, različita je za svaku jedinku. Biometrijski sustavi koji detektiraju mirise rade na principu upuhivanja zraka preko kemijskih senzora od kojih je svaki osjetljiv na određenu grupu mirisa, tj. na njegova kemijska svojstva. Miris se opisuje mjerenjima obuhvaćenom od senzora i u njegovom intenzitetu na svakome od njih. Pretpostavljajući da svaka osoba sadrži karakterističan miris, moguće je po parametrima svakog od senzora odrediti o kojoj se osobi radi i odrediti glavnu notu mirisa od sporedne. Upitno je da li postoji utjecaj kemijskih tvari (poput losiona, sapuna, parfema) na kvalitetnu detekciju mirisa. Ova metoda spada u grupu nametljivih tehnika [4, 5].

4.8. Odontologija – utvrđivanje identiteta temeljem statusa zubala

Prvi aspekt, traseološki se odnosi na identifikaciju osoba temeljem tragova zuba (ugriza, odgriza i slično) pronađenih na mjestu događaja. Drugi aspekt, identifikacijski se odnosi na identifikaciju osoba i mrtvih tijela. Identifikacija se odnosi na broj zubi, njihov položaj i raspored, veličina, razmak, osobitosti zuba i zubala. Ponekad se koriste i tragovi stomatoloških zahvata poput popravaka, plombi, kruna, mostova i dr. Može se zaključiti da se više uspoređuje vizualno dok se u području biometrijske identifikacije koristi dentalna radiologija, tj. rendgenske snimke [1].

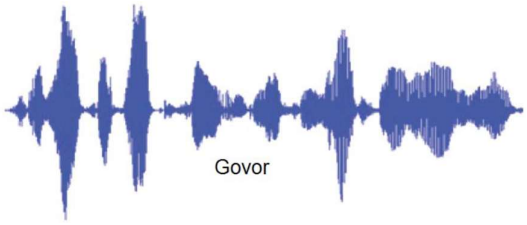
4.9. Analiza glasa

Prepoznavanje glasa koristi se u svrhu autentikacije različitih korisnika na temelju njihovih jedinstvenih glasovnih karakteristika. Naime, da bi se korisnik autenticirao, isti mora izgovoriti neki tekst koji je prethodno izgovorio i koji je spremljen u bazu podataka. Tu postoji visoka jedinstvenost pošto ljudi uglavnom različito izgovaraju iste rečenice (tonalitet, brzina, prekidi). Ipak, ukoliko bi netko snimio autentikaciju ovlaštene osobe, isti bi je mogao ponoviti pa je stoga ovu metodu autentikacije potrebno koristiti u kombinaciji s drugim metodama [4].

Postoje tri pristupa identifikacije govornika:

- Provjera govornika ovisno o tekstu – dokazuje identitet subjekta provjerom na unaprijed određenoj frazi.
- Provjera govornika neovisno o tekstu – teži pristup jer se govornikov identitet provjerava neovisno o frazi.
- Provjera govornika neovisno o jeziku na kojem govori [5].

Ova metoda spada u grupu nenametljivih tehnika. Podložna je promjenama govornika (bolest, mutacije i sl.), te ju je također relativno lako i imitirati. Koristi se za identifikaciju preko telefona [4, 5].



Slika 5: Frekvencija glasa [5]

4.10. Rukopis i potpis

Svaka osoba ima jedinstven rukopis, a potpis je neka vrsta otiska, te se otvara mogućnost koja se može iskoristiti u identifikaciji osoba. Svaki rukopis ima svoja opća i posebna obilježja. Opća obilježja su opći izgled rukopisa, stupanj ispisanosti, raspored teksta, odnos prema liniji pisanja, veličina rukopisa razmaci, vezanost i nevezanost slova, rastavljanje riječi, brzina pisanja, pritisak na papir, nagib rukopisa, ukrašavanje i dr. Posebna obilježja se za razliku od općih ne mogu u potpunosti definirati, jer su individualna od osobe do osobe, ali se baziraju na mjerenju nagiba brzine, jačine pritiska, duljine poteza ruke. Upravo na ovim obilježjima temelji se biometrijska identifikacija skriptora [1, 5].

Potpisi nekih osoba često variraju, i to u tolikoj mjeri da su uzastopni otisci njihovih potpisa značajno različiti. Identifikacijska točnost sustava temeljenih na metodi potpisa je prihvatljiva iako postoji mogućnost krivotvorenja potpisa [5].

Postoje dva pristupa identifikacije potpisa:

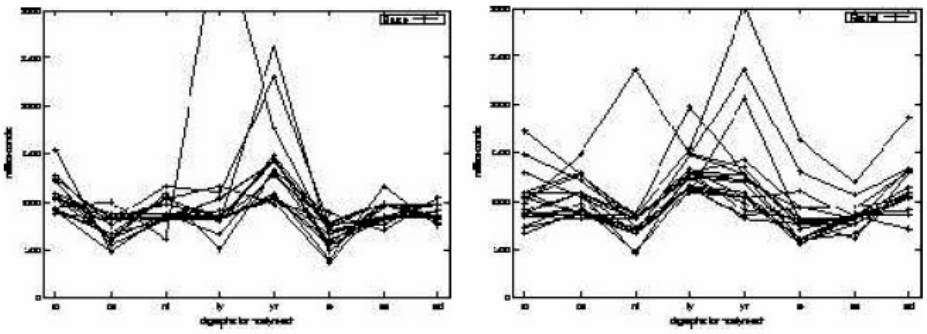
- Statički – promatra se geometrija potpisa.
- Dinamički – promatra se geometrija potpisa, te brzina i putanja [1, 5].



Slika 6: Potpis opisan krivuljama i njihovim međusobnim odnosima [4]

4.11. Dinamika tipkanja

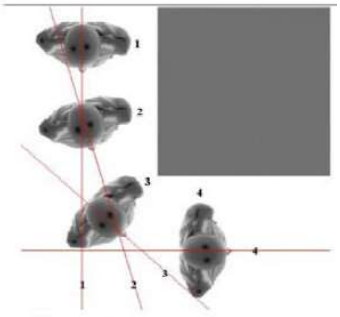
Govorimo o dinamici tipkanja po tipkovnici. Razvila se za vrijeme drugog svjetskog rata kod radiotelegrafista, jer je uočeno da se po brzini tipkanja mogu razlikovati pošiljatelji poruka. Kao tehnika je vrlo nenametljiva jer nije potrebno uvoditi nikakve dodatne uređaje za detektiranje, osim zvučne kartice. Eventualno je moguće posjedovati specijalizirani program koji bi na razini operacijskog sustava pratio korisnikovo tipkanje. Bazira se na vremenskom razmaku između korisnikovog pritiskanja na tipkovnicu [4, 5].



Slika 7: Grafički prikaz brzine tipkanja iste riječi za dvije različite osobe [4]

4.12. Dinamika hoda

Predstavlja složenu prostorno – vremensku biometriju ponašanja. Nije jedinstven za svakog pojedinca, ali je dovoljno karakterističan da omogući provjeru identiteta. Hod nije nepromjenjiv, pogotovo kod dužeg vremenskog perioda jer se osoba umara. Značajke hoda izvode se iz analize video materijala. Provjeravanje temeljeno na hodu tipično upotrebljava slijed slika hodajuće osobe, a sama se provjera zasniva na karakterizaciji nekoliko različitih pokreta svakog artikuliranog zgloba. Ova metoda spada u grupu nenametljivih tehnika [1, 4, 5].



Slika 8: Prikaz kuta pod kojim osoba zaobilazi prepreku [4]

4.13. Uho

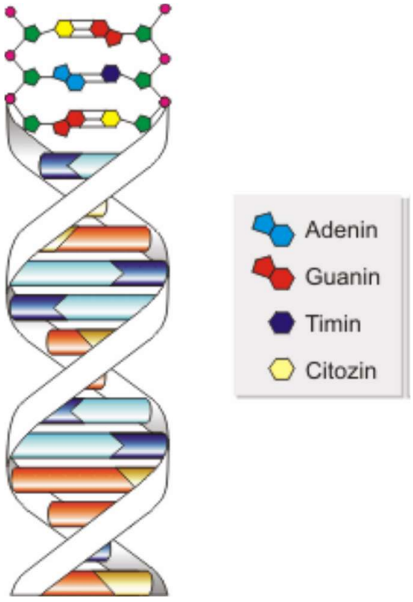
Oblik uha i struktura hrskavog tkiva na površini uha različiti su među osobama. Kod uha nije za očekivati da su značajke jedinstvene za svaku osobu. Pristupi prepoznavanju uha temelje se na poklapanju vektora duljine izbočenih točaka na površini od lokacije graničnih znakova na uhu. Ova metoda spada u grupu nametljivih tehnika [5].



Slika 9: Biometrija uha [5]

4.14. DNK

DNK je jednodimenzionalna jedinstvena oznaka za nečiju individualnost, a najviše se koristi u kontekstu forenzičnih aplikacija pri identifikaciji. Većina ljudskih DNK identična je za cijelu ljudsku populaciju i samo relativno malen broj posebnih lokacija na DNK predočava individualne varijacije. Te se varijacije pokazuju ili u broju ponavljanja blokade osnovnog toka ili u manjim nefunkcionalnim smetnjama osnovnog toka. Procesi uključeni u identifikaciju na bazi DNK određuju potječu li dva uzorka DNK od istog, odnosno različitih pojedinca. S obzirom da se iz DNK mogu dobiti i "privatni" podaci (poput raznih vrsta bolesti i sl.), ovakva identifikacijska tehnika još uvijek ne uživa veliku popularnost kod krajnjih korisnika. U kombinaciji s drugim biometrijskih tehnikama može se osigurati vrlo visoki stupanj zaštite i prepoznavanje ukoliko se doista radi o osobi kojoj su pridodana izvjesna ovlaštenja. DNK analiza se danas koristi u brojnim sferama kao što su dokazivanje očinstva ili rodbinske povezanosti ili u pravosuđu u kojem su na taj način identificirani brojni kriminalci, ali su i brojni neopravdani osuđeni zatvorenici pušteni na slobodu. Ova metoda spada u grupu nametljivih tehnika [4, 5].



Slika 10: Shematski izgled DNK molekule [4]

5. Biometrijska metoda identifikacije osobe na temelju geometrije dlana

Identifikacija na temelju geometrije dlana i prstiju provodi se snimanjem ruku te usporedbom karakteristika istih kojih ima oko 90. Budući da geometrija dlana i prstiju nije dovoljno jedinstvena, ovakva metoda je često nepouzdana, ali se najčešće koristi za provjeru identiteta, odnosno za autentifikaciju. Prednosti su što se mogu koristiti slike niske rezolucije, nenametljiva je, društveno prihvatljiva, jeftiniji su prikladni senzori te ima stabilne strukturalne značajke koje su nepromjenjive tijekom života. U odnosu na otiske prstiju također imaju prednosti. Otisak dlana ima veliku površinu pa se može izučiti mnogo linijskih značajki koje se ne mijenjaju tijekom života, na dlanu ima manje prljavštine ili masti nego na prstu, brža su pretprocesiranja zbog korištenja slika manje rezolucije, itd. [2, 3].

5.1. Biometrijsko prepoznavanje

Biometrijski sustavi identifikacije automatski autentificiraju, identificiraju i provjeravaju osobu na temelju psiholoških i ponašajnih karakteristika, a s obzirom na potrebe, biometrijski sustav radi na dva načina. Autentifikacija je potvrda identiteta, gdje sustav potvrđuje ili odbija identitet uspoređivanjem biometrijskih karakteristika s prethodno sačuvanim uzorkom u bazi podataka. Naziva se i pozitivno prepoznavanje, a cilj je spriječiti da više ljudi koristi isti identitet [2]. Dva osnovna tipa autentifikacije su:

- Verifikacija – vrši se uspoređivanje identiteta neke osobe, u smislu uspoređivanja dobivenog podatka s točno određenim uzorkom u bazi podataka. Ovaj oblik autentifikacije predstavlja 1:1 sustav. Obavlja se na način da korisnik unosi svoje ime ili najčešće PIN kojim tvrdi da je to njegov identitet. Zatim se korisniku uzimaju biometrijske karakteristike i pretvaraju se u digitalni oblik. Ovaj oblik se preko algoritma za uspoređivanje, uspoređuje s već postojećim (povučen iz baze na osnovi PIN-a) [8].
- Identifikacija – U slučaju identifikacije vrši se provjera podudaranja dobivenog uzorka s svim sačuvanim uzorcima u bazi podataka s ciljem dobivanja podataka o identitetu neke osobe. Ovaj oblik autentifikacije predstavlja 1:N (1 prema više) sustav. U ovom slučaju osoba ne unosi PIN. Sustav usporedi uzete biometrijske karakteristike s oblicima svih osoba upisanih u bazu podataka. Kao rezultat dobiva se identitet upisane osobe ili upozorenje da osoba nije identificirana [8].

5.2. Biometrija dlana

Sve tehnologije imaju svoje prednosti i mane te ni jedna tehnologija nije savršena za svaku situaciju. Upravo manji troškovi, jači procesori i ostala današnja elektronika omogućili su proizvodnju uređaja koji pružaju očitanje geometrije dlana, te su ih napravili komercijalno dostupnima. Pri tome, vremenske neprilike ili oštećena kože nemaju nikakvog utjecaja na njihovu točnost prilikom verifikacije osoba. No veliki utjecaj ima nakit na ruci, nedostatak dijela prstiju ili pak izostanak prstiju s ruke. Analizirajući geometriju dlana, analiziramo njegove različite mjere. Današnji sustavi gledaju između 16 i 30 mjera dlana. Bulatov, Jambawalikar, Kumar i Sethia definirali su 2004. godine trideset mjera koje se promatraju prilikom analize geometrije dlana, a koje su navedene dolje na slici 11 [3, 7].

1. Duljina palca
2. Duljina kažiprsta
3. Duljina srednjeg prsta
4. Duljina prstenjaka
5. Duljina malog prsta
6. Širina palca
7. Širina kažiprsta
8. Širina srednjeg prsta
9. Širina prstenjaka
10. Širina malog prsta
11. Polumjer gornjeg dijela palca
12. Polumjer donjeg dijela kažiprsta
13. Polumjer gornjeg dijela kažiprsta
14. Polumjer donjeg dijela srednjeg prsta
15. Polumjer gornjeg dijela srednjeg prsta
16. Polumjer donjeg dijela prstenjaka
17. Polumjer gornjeg dijela prstenjaka
18. Polumjer donjeg dijela malog prsta
19. Polumjer gornjeg dijela malog prsta
20. Opseg palca
21. Opseg kažiprsta
22. Opseg srednjeg prsta
23. Opseg prstenjaka
24. Opseg malog prsta
25. Površina palca
26. Površina kažiprsta
27. Površina srednjeg prsta
28. Površina prstenjaka
29. Površina malog prsta
30. Polumjer najveće upisane kružnice (površina dlana bez prstiju)

Slika 11: Mjere za analizu geometrije dlana [7]

Dodatne prednosti geometrije dlana su sljedeće:

- Cijena nije velika jer je potrebna samo platforma i kamera kojom se snima, ne mora biti visoke rezolucije.
- Koristi algoritme koji ne uzimaju puno procesorskog vremena i to dovodi do brzih rezultata.
- Mala veličina predloška (352 do 1029 byte-ova) što smanjuje potrebu za velikim diskovnim prostorom.
- Jednostavno i zanimljivo za korisnike – vodi do velike prihvatljivosti.
- Koristeći geometriju dlana ne stvara se podsvjesna povezanost s policijom, sudom i policijskim dosjeima [7].

5.2.1. Građa dlana

Unutarnji dio šake od zgloba šake do vršaka prstiju smatra se dlanom. Dlanovi imaju površinu puno veću nego vršci prstiju, ali je pokriven s istim tipom kože. Kod građe dlana mislimo na tri stvari :

- **Glavne linije** – Svaka osoba ima 4 glavne linije koje se formiraju na isti način, no bez obzira na to razlikuju se od osobe do osobe. Jedan od razloga za to je način na koji osoba hvata/uzima stvari. Različita veličina prstiju i debljina dlana je još jedan razlog. Također svaka šaka se savija drugačije što također oblikuje te 4 linije.
- **Nabori** – Pružaju koži određenu rastezljivost te nastaju po cijelom tijelu. Kako koža gubi na elastičnosti tako nabori postaju sve uočljiviji. Neki nabori su urođeni dok neki nabori na dlanu većinom nastaju zbog načina hvatanja stvari.
- **Grebeni** – Grebeni su trajna zadebljanja na epidermu (vanjskom ćelijskom dijelu kože). Nalaze se samo na dlanovima i stopalima te se uzdižu iznad normalne razine kože. Njihova rasprostranjenost ovisi o područjima koja su pod naporom od hvatanja ili nošenja velike težine [6].

5.2.2. Značajke dlana

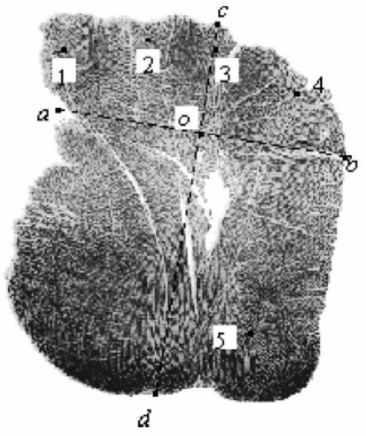
Značajke dlana su glavne linije, nabori, grebeni, singularne točke i detaljne točke. Mnoge karakteristike dlana možemo koristiti za identifikaciju osoba. To je metoda za identifikaciju osobe pomoću jedinstvenih značajki dlana koja mogu, ali i ne moraju biti vidljive golom oku. To se postiže pomoću algoritama koji mogu razlučiti razlike između dvije osobe prema tim značajkama. Značajke dlana možemo prikupiti uzimanjem otisaka dlana. Otisak je utisak na nekoj površini pritiskom. Čini ga obrazac kože na dlanu sastavljen od svojih jedinstvenih karakteristika kao sto su linije, točke i tekstura. Zbog znojenja, otiske dlana možemo naći na

površinama raznih objekata. Ako je dlan suši, to su otisci manje vidljivi. Možemo ga prikazati sa i bez tinte. Četiri značajke možemo preuzeti iz oba načina prikaza dok dvije možemo samo s otiska korištenjem tinte. Te značajke su:

- **Geometrijske značajke** – Ovisno o obliku dlana možemo izlučiti neke značajke kao sto su dužina, širina i debljina.
- **Značajke glavnih linija** – Zato što se jako malo mijenjaju tijekom godina, lokacija i forma glavnih linija dlana su važne značajke kod identifikacije.
- **Značajke nabora** – Dlan ima mnoštvo nabora koji se razlikuju od glavnih linija po tome što su tanji i neregularni. Razlikujemo hrapave i glatke nabore tako da imamo više detalja za usporedbu.
- **Krajnje točke** – Pomoću glavnih linija dobivamo dvije krajnje točke. Omogućuju dobar način registracije dlana te se nalaze na krajevima obje strane dlana. Veličina dlana može biti izmjerena pomoću euklidske dužine između te dvije točke.
- **Značajke delta točaka** – Delta točke su središnje točke koje se nalaze u području korijena prsta. One nam pružaju jedinstvenu mjeru za identifikaciju dlana.
- **Detaljne točke** – Kako se dlan sastoji od grebena to nam dozvoljava da koristimo detaljne točke kao značajke u usporedbi dlanova [6].

5.2.3. Opis sustava za raspoznavanje dlana

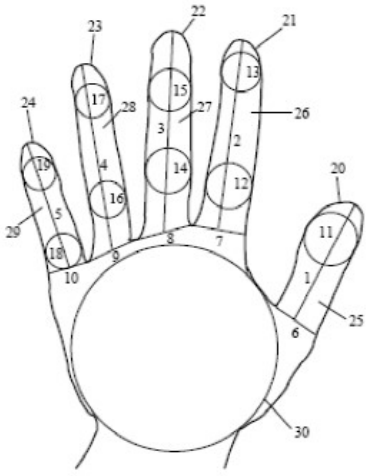
1) Shu i Zhang su razvili sustav za raspoznavanje dlana s kasnijom obradom. U svome radu kao značajke dlana navode geometrijske značajke, glavne linije, bore, delta točke i minucije. Autori su koristili širinu i visinu dlana, te položaje nekoliko točaka duž glavnih linija dlana kao značajke za raspoznavanje. Na maloj bazi na kojoj je izvršeno 48 eksperimenata poklapanja dlanova iste osobe i 844 eksperimenata poklapanja dlanova različitih osoba dobiven je rezultat 0.0% FAR i 0.0% FRR [3].



Slika 12: Dlan s označenim točkama na temelju kojih se računaju geometrijske značajke (a, b, c, d) i delta točkama (1, 2, 3, 4, 5) [3]

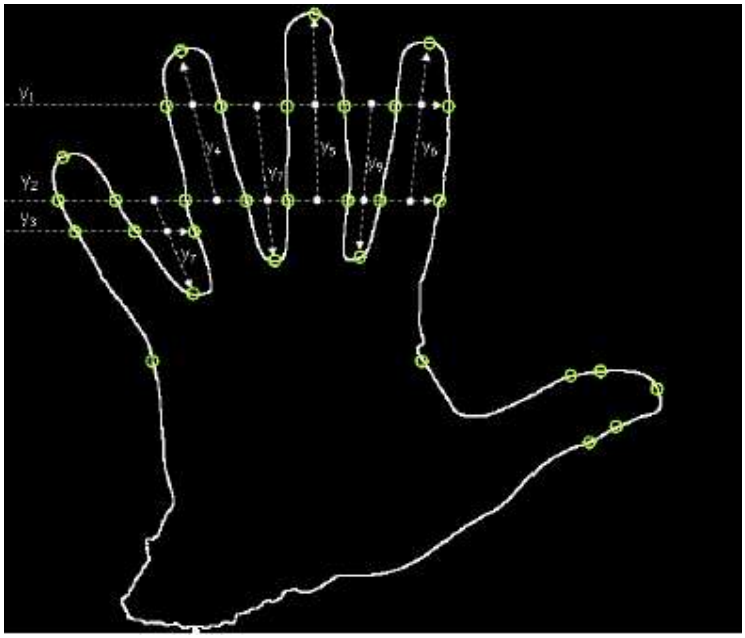
FAR – Udio pogrešno prihvaćenih uljeza (engl. False Acceptance Rate).
FRR – Udio pogrešno odbijenih klijenata (engl. False Rejection Rate) [3].

2) U svom radu Karlovčec i Fotak su razvili sustav za autentikaciju koji se sastoji od izuzimanja slike sa skenera ili digitalnog fotoaparata u rezoluciji 842 x 612 piksela, zatim njezinog predprocesiranja da bismo dobili konturu dlana, izlučivanja karakteristika, odnosno specifičnih točaka geometrije dlana, a na kraju i izrade minimalno razapinjućeg stabla dobivenih točaka pomoću kojeg će se vršiti uspoređivanje dobivenog predloška s postojećim predloškom u bazi predložaka. Slike dlanova, za potrebe tog rada, izuzimale su se Epsonovim Perfection V30 skenerom. Svaka je osoba morala dati 4 slike istog dlana. Ograničenje je bilo držanje srednjeg prsta u uspravnom položaju u odnosu na donji desni dio palčane uzvisine, radi daljnje obrade izuzetog uzorka. Prosječna brzina izuzimanja jednog uzorka je bila 6 sekundi. Nizom postupaka digitalne obrade slike iz originalne slike dobivamo konturu dlana i na njoj vršimo daljnju obradu. Na slici se prvo odbacuju sve boje te se konvertira u nijanse sive boje kako bi se u sljedećem koraku mogao izvršiti thresholding s vrijednošću 35. Tako su dobili binarnu sliku koju je jednostavnije dalje obrađivati. Primjenom Median filtera otklonili su sve „ogrebotine“ na slici, odnosno male dijelove izvan područja dlana, a koji imaju istu boju kao dlan (u ovom slučaju bijelu). Na samom kraju su dobili konturu dlana primjenjujući Sobelov Edge Detector filter. Za izlučivanje karakterističnih točaka, normalizirana slika se obrađuje koristeći osnovne elemente vektorske grafike. Analizom svojstava piksela definiraju se lokacije karakterističnih točaka pa je konačan rezultat vektorska slika sastavljena od trideset i jedne točke [7].



Slika 13: Geometrijske karakteristike dlana [7]

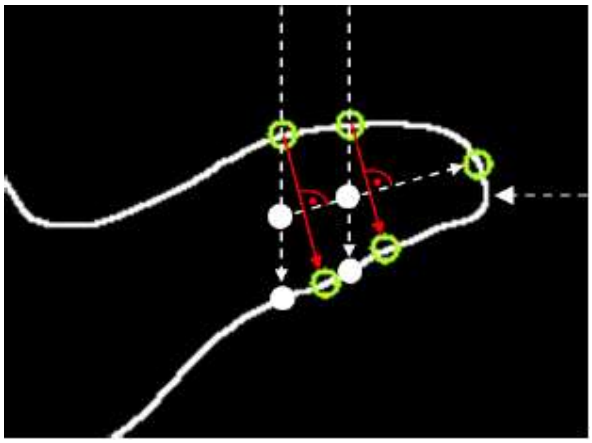
Da bi se geometrija ruke smjestila u odgovarajuću poziciju u y-osi, koristi se referentna točka i to na vršku srednjeg prsta ruke. Da bi se dobila lokacija ove točke, horizontalnim pravcem se prolazi slikom. Analiziranjem točaka na ovom pravcu dobivamo šest točaka, koje predstavljaju rubove kažiprsta, srednjeg prsta i prstenjaka. Kako znamo da su treća i četvrta točka rubovi gornjeg dijela srednjeg prsta, računa se lokacija točke između treće i četvrte te se definira vertikalni pravac koji prolazi kroz dobivenu točku. Od dobivene točke analiziraju se pikseli prema vrhu slike, sve dok se ne pronađe rub prsta. Dobivena točka je referentna točka za utvrđivanje vertikalne pozicije geometrije ruke. Horizontalna pozicija se utvrđuje na temelju ruba malog prsta, pri čemu je y koordinata u ovom slučaju definirana u odnosu na prethodno dobivenu referentnu točku. Nakon što je ruka pravilno pozicionirana, dvama horizontalnim pravcima pronalaze se drugi parovi malog prsta, prstenjaka, srednjeg prsta i kažiprsta. Kako postoje po dva ruba za svaki od ovih četiri prsta, definiran je pravac koji aproksimira prste i orijentacije koja odgovara usmjerenju svaka od ovih četiri prsta. Za određivanje ovog pravca najprije se pronalaze polovišta dužina koje spajaju dva ruba istog prsta, a potom se koristi jednadžba pravca kroz dvije točke (te dvije točke su dobivena polovišta). Prolaženjem ovim pravcima prema vrhu slike dobivaju se pozicije vrhova ovih četiri prsta. Na sličan način dobivaju se pozicije točaka između dva prsta, pri čemu se pronalaze polovišta dužina koje spajaju rubove susjednih prstiju, a pravcem se prolazi prema dnu slike [7].



Slika 14: Kontura dlana s izlučenim karakterističnim točkama [7]

Palac se zbog svojih posebnih karakteristika u odnosu na ostala četiri prsta obrađuje zasebno. Najprije se pronalazi krajnja desna pozicija palca. Dvama vertikalnim pravcima se dobivaju po dva ruba palca. Pronalaze se polovišta dužina koje spajaju te rubove, a dobivena

polovišta se uvrštavaju u formulu za definiranje jednadžbe pravca kroz dvije točke. Analiziranjem točaka dobivenog pravca dobiva se vršak palca. Da bi se dobile karakteristične točke koje opisuju širinu palca koristi se prethodno dobiveni pravac i gornji rubovi palca. Na temelju da dva elementa koristeći formulu za dobivanje jednadžbe pravca koji prolazi kroz neku točki i okomit je na neki pravac, dobivaju se dva pravca za dobivanje druga dva ruba [7].



Slika 15: Izlučivanje karakterističnih točaka palca [7]

5.2.4. Fourierova transformacija, PCA, LDA, ICA

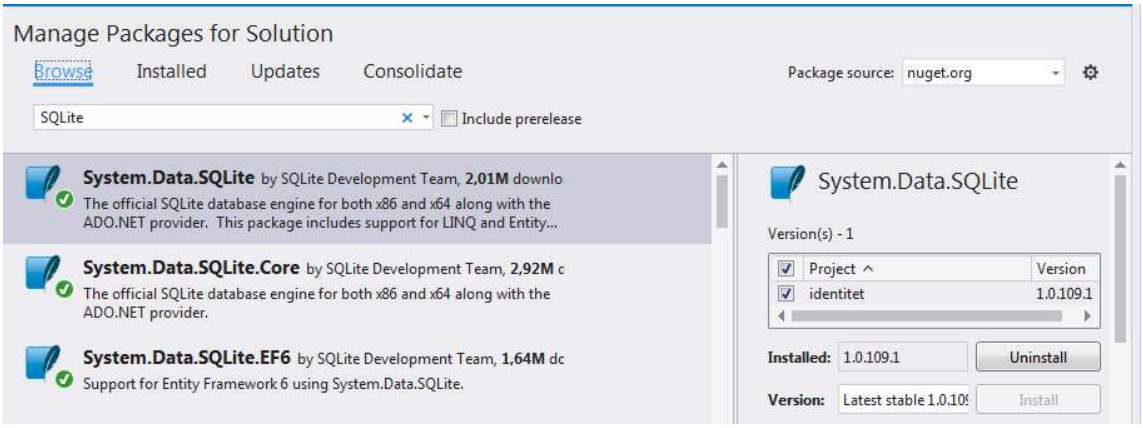
Umjesto korištenja unaprijed poznatih transformacija za izlučivanje značajki, kao što je Fourierova transformacija (metoda promatranja cijele slike interesnog područja kao vektor značajki, pri čemu su komponente vektora intenziteti pojedinih slikovnih elemenata) često je bolje koristiti transformaciju koja je naučena na uzorcima za učenje, PCA, LDA i ICA. PCA je analiza glavnih komponenti koja nalazi optimalni potprostor izvornoga prostora značajki u smislu reprezentacije uzoraka. LDA je linearna diskriminantna analiza koja nastoji naći značajke pogodne za raspoznavanje tako da nalazi potprostor izvornog prostora značajki u kome se maksimizira raspršenje uzoraka između razreda, a minimizira raspršenje uzoraka unutar pojedinih razreda. ICA nalazi potprostor koji čine nezavisne komponente za koje se pretpostavlja da su analizom uzorci koje vidimo nastali kao linearna kombinacija nekih nepoznatih, statističkih nezavisnih komponenti [3].

5.2.5. RGB

Boja kože je također jedna od značajki dlana korištenih u biometriji. Eksperimentalno je utvrđeno da su normalizirana crvena i normalizirana plava komponenta u normaliziranome RGB modelu boja najpogodnije u smislu točnosti raspoznavanja [3].

6. Praktični dio rada

U ovom poglavlju opisan je princip rada aplikacije. Cijela aplikacija se sastoji od linija koda, metoda i klasa, a ovdje su navedeni samo najznačajniji dijelovi koda koji rješavaju neki važniji problem praktičnog dijela rada. Koristio sam programski jezik C# u razvojnom alatu za programiranje Microsoft Visual Studio 2015. Koristio sam SQLite sustav za bazu podataka. Razlog zbog kojeg sam izabrao SQLite je taj što sam želio da se cijela aplikacija s bazom podataka pokreće pomoću samo jedne ikone tj. ***exe*** datoteke. SQLite ima mogućnost da se pokreće zajedno s izvršnom datotekom napisanom u C#-u. Sljedeća slika prikazuje instalaciju SQLite biblioteka.



Slika 16: NuGet package manager

Da bismo mogli koristiti programski kod `using System.Data.SQLite` potrebno je instalirati SQLite biblioteke u razvojnom alatu Visual Studio. To možemo učiniti klikom na „tools“ potom „NuGet package manager“ potom „NuGet package manager for Solution“ da bismo dobili dio ekrana na kojem možemo pretražiti „SQLite“.

6.1. Točka koordinatnog sustava

Kako bismo mogli izmjeriti bilo što na slici (dužine prstiju, širine prstiju itd.), potrebno je odrediti neke točke na istoj slici. Kao temelj takvog programiranja najprije je napisana klasa Tocka. Kompletan programski kod klase Tocka naveden je ispod.

```
class Tocka
{
        public int x = 10;
        public int y = 10;
}
```

Klasa Tocka je u aplikaciji referencirana preko stotinu puta što pokazuje da je ista klasa vrlo korisna. Klasa Tocka je vrlo jednostavna obzirom na samo dvije linije koda. Svaka točka ima x i y cjelobrojnu vrijednost što predstavlja smještaj piksela u koordinatnom sustavu odnosno rasteru slike. Točka kojoj je x jednak 0 i y jednak 0 se nalazi lijevo i gore na slici. Početna vrijednost svake točke za x je 10, a za y je 10. Tokom programa, točkama se moraju promijeniti x i y da ne ostanu početne vrijednosti.

6.2. Dohvaćanje i postavljanje piksela

U ovom pod poglavlju je prikazan pojednostavljen programski kod kako bi se objasnio princip na kojem aplikacija radi sa slikom. Najznačajnije metode korištene u ovom radu za upravljanje slikom su GetPixel i SetPixel. Pretpostavimo da imamo varijablu „slika“ tipa Bitmap i „tocka“ tipa Tocka. Sljedeći kod je primjer dohvaćanja piksela.

```
Color piksel = slika.GetPixel(x, y);
```

Sljedeći kod je primjer postavljanja piksela.

```
Color boja = Color.Green;
slika.SetPixel(x, y, boja);
```

Kompletan kod korišten u praktičnom dijelu rada je mnogo složeniji.

6.3. Razlikovanje dlana od pozadine na slici

Za razlikovanje dlana od pozadine koristi se metoda `ispitajRuka` koja je tako nazvana jer osim dlana na slici može biti zahvaćen dio ruke. Metoda `ispitajRuka` se nalazi u klasi Boja. Metoda `ispitajRuka` prima kao parametar boju piksela. Boja piksela se izražava pomoću sustava boja Crveno Zeleno Plavo (eng. Red Green Blue - RGB). Svaki piksel ima R, G i B komponentu: R kao „red“ (crveno), B kao „blue“ (plavo) i G kao „green“ (zeleno). Kombinacijom triju osnovnih boja moguće je dobiti bilo koju boju u prirodi (teorijski). Svaka od navedenih komponenti ima svoju cjelobrojnu vrijednost od 0 do 255 pri čemu veći broj predstavlja svjetliju nijansu boje, a manji broj tamniju. Ista metoda vraća logičku *istinu* ako taj piksel predstavlja ruku odnosno dlan, a vraća logičku *laž* ako primljeni piksel predstavlja pozadinu.

```
public static int svjetlinaRG = 15;
public static int svjetlinaRB = 15;

public static bool ispitajRuka(Color pixel)
{
            int r = pixel.R;
            int g = pixel.G;
            int b = pixel.B;

            if(r - g > svjetlinaRG && r - b > svjetlinaRB)
            {
                return true;

            } else {
                return false;
            }

}
```

Problem u praktičnom dijelu rada kojeg rješava ova metoda jest kako razlikovati dlan od pozadine na slici. Pretpostavka je da dlan odnosno boja kože ima više crvenila odnosno R komponente u odnosu na G i B komponentu (isto vrijedi za sve boje kože). Na potpitanje „koliko više?“ odgovaraju varijable svjetlinaRG i svjetlinaRB koje su podrazumijevano postavljene na 15. Vrijednosti varijabli svjetlinaRG i svjetlinaRB je zbog nesavršenosti aplikacije potrebno prilagoditi svakoj slici posebno kako bi aplikacija radila ispravno uslijed različitog osvjetljenja prostorije, dlana i podloge. Radi boljih rezultata poželjno je prilikom slikanja dlana koristiti bijeli papir, ili zeleni ili plavi fascikl, a izbjegavati crvene i smeđe podloge. Sljedeći kod je primjer provjere da li je otkrivena granica između nečije ruke i podloge.

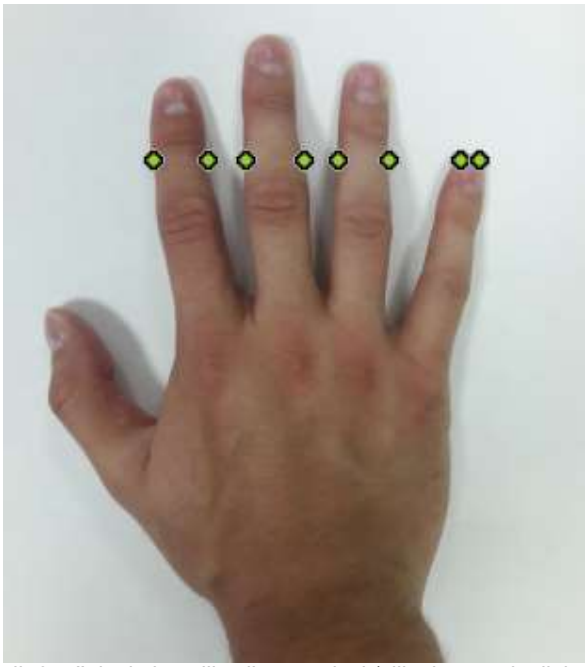
```
pixel1 = slika.GetPixel(x-1, y);
pixel2 = slika.GetPixel(x, y);

if (Boja.ispitajRuka(pixel1)
    && !Boja.ispitajRuka(pixel2))
{
     //Otkrivena nečija ruka
}
```

U kodu iznad, najprije se dohvate dva susjedna piksela u koordinatnom sustavu. Ako je neki piksel dio nečije ruke, a piksel do njega nije dio ruke, onda to znači da je otkrivena granica između nečije ruke i podloge.

6.4. Pronalazak prstiju na dlanu

Poziva se metoda `pronadiPrste` koja ovdje nije navedena jer je prilično dugačka. Metoda `pronadiPrste` traži prste provjeravajući svaki piksel odozgo prema dolje i s lijeva na desno tražeći početak i kraj svakog prsta u istom redu (na istom y-u) dok ne pronađe četiri prsta. Ista metoda kao parametar prima sliku tipa Bitmap i postavlja prvih 8 točaka koje aplikacija pronalazi. Tih prvih 8 točaka predstavljaju početak i kraj svakog prsta osim palca. Spomenute točke ne služe izmjeri radi identifikacije korisnika, nego samo daju informaciju o tome gdje se prsti nalaze na slici kako bi te točke mogle poslužiti kasnije.



Slika 17: Prvih 8 točaka koje aplikacija pronalazi (slika je nastala tijekom razvoja).

Slika iznad je nastala tijekom razvoja aplikacije. Prvih 8 točaka koje aplikacija pronalazi služe kako bi se pronašli vrhovi prstiju, a vrhovi služe radi izmjere dužine prstiju. Među spomenutim prvim točkama su 4 početka prsta i 4 kraja prsta koje se nalaze na istom redu (imaju zajednički y). Između svakog početka i kraja prsta pronalazi se po jedan vrh prsta. Vrh prsta je najkraća udaljenost od gornjeg ruba slike do pronalaska dlana (najmanji y) omeđen x-om nekih od prvih 8 točaka.

6.5. Izmjera udaljenosti između dvije točke

Udaljenost između dvije točke se mjeri pomoću metode `udaljenost`. Metoda `udaljenost` prima dvije točke između kojih želimo izmjeriti udaljenost, a vraća cjelobrojnu udaljenost izraženu u pikselima.

```
public static int udaljenost(Tocka A, Tocka B)
        {
            //Apsolutne vrijednosti kateta
            int x = Math.Abs(A.x - B.x);
            int y = Math.Abs(A.y - B.y);

            //Pitagorin poučak
            double c = Math.Pow((x*x + y*y), 0.5);

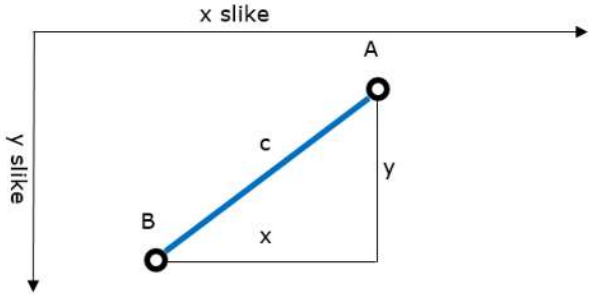
            //Zaokružen rezultat na cijeli broj
            return (int) Math.Round(c);

                                                    }
```

Metoda `udaljenost` najprije izračunava apsolutnu vrijednost razlike između točaka na x osi i na y osi. U navedenoj metodi, varijabla x predstavlja uvijek horizontalnu dužinu, a varijabla y predstavlja uvijek vertikalnu dužinu. Osi x i y čine pravi kut, stoga je moguće upotrijebiti matematičku formulu za pravokutni trokut. Korištena udaljenost između dvije točke u ovom radu naziva se Euklidska udaljenost. Formula za Euklidsku udaljenost je sljedeća:

$$d_2(A,B) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

Euklidska udaljenost je prema definiciji najkraći razmak između dvije točke u ravnini.



Slika 18: Udaljenost između dvije točke u koordinatnom sustavu prilagođeno metodi u C#-u

Primjenom Pitagorinog poučka izračunava se hipotenuza c koja predstavlja udaljenost između točke A i točke B. Rezultat se zaokružuje na cjelobrojnu vrijednost.

6.6. Pronalazak točke na zadanoj dužini

Metoda `tockaCKojaPripadaDuziniAB` prima točke A i B, udaljenost između točke A i točke C te vraća točku C. Problem koji rješava ova metoda je pronalazak točnih koordinata točke C koja pripada dužini AB. Ova metoda poziva metodu `udaljenost`.

```
public static Tocka tockaCKojaPripadaDuziniAB(Tocka A, Tocka B, int udaljenostCA)
        {
            Tocka C = new Tocka();
            int udaljenostAB = udaljenost(A, B);

            int x = Math.Abs(B.x - A.x);
            int y = Math.Abs(B.y - A.y);

            if(x < 1) { x = 1; }
            if(y < 1) { y = 1; }

            double koeficijentX = udaljenostAB / x;
            double koeficijentY = udaljenostAB / y;

            C.x = A.x + (int) Math.Round((double) udaljenostCA * koeficijentX);
            C.y = A.y + (int) Math.Round((double) udaljenostCA * koeficijentY);

            return C;
                                                    }
```

Na temelju metode `tockaCKojaPripadaDuziniAB` moguće je izvesti formule za koordinate točke C. X koordinatu točke C možemo izračunati prema slijedećoj formuli:

$$C_x = \frac{udaljenostAC * udaljenostAB}{|B_x - A_x|}$$

Y ordinatu točke C možemo izračunati prema slijedećoj formuli:

$$C_y = \frac{udaljenostAC * udaljenostAB}{|B_y - A_y|}$$

Ovime smo izračunali koordinate točke C. Metoda `tockaCKojaPripadaDuziniAB` je poslužila tijekom razvoja aplikacije, a zamijenila ju je poboljšana metoda `tockaCKojaPripadaDuziniAB2` koja traži treću točku na zadanoj dužini na drugi način tj. koristeći parametar `razmakY`. Ova metoda je manje razumljiva, stoga su navedene obje metode. Metoda `tockaCKojaPripadaDuziniAB2` na temelju zadanog y-a traži odgovarajući x točke C kako slijedi.

```
public static Tocka tockaCKojaPripadaDuziniAB2(Tocka A, Tocka B, int razmakY)
        {
            Tocka C = new Tocka();

            int ABx = Math.Abs(B.x - A.x);
            int ABy = Math.Abs(B.y - A.y);

            double k = (double) ABx / ABy;
            int razmakX = (int) Math.Round((double) k * razmakY);

            if (B.x > A.x) { C.x = A.x + razmakX; if (C.x > B.x) { C.x = B.x; } }

            else { C.x = A.x - razmakX; if (C.x > A.x) { C.x = A.x; } }

            if (B.y > A.y) { C.y = A.y + razmakY; if (C.y > B.y) { C.y = B.y; } }

            else { C.y = A.y - razmakY; if (C.y > A.y) { C.y = A.y; } }

            return C;
                                                }
```

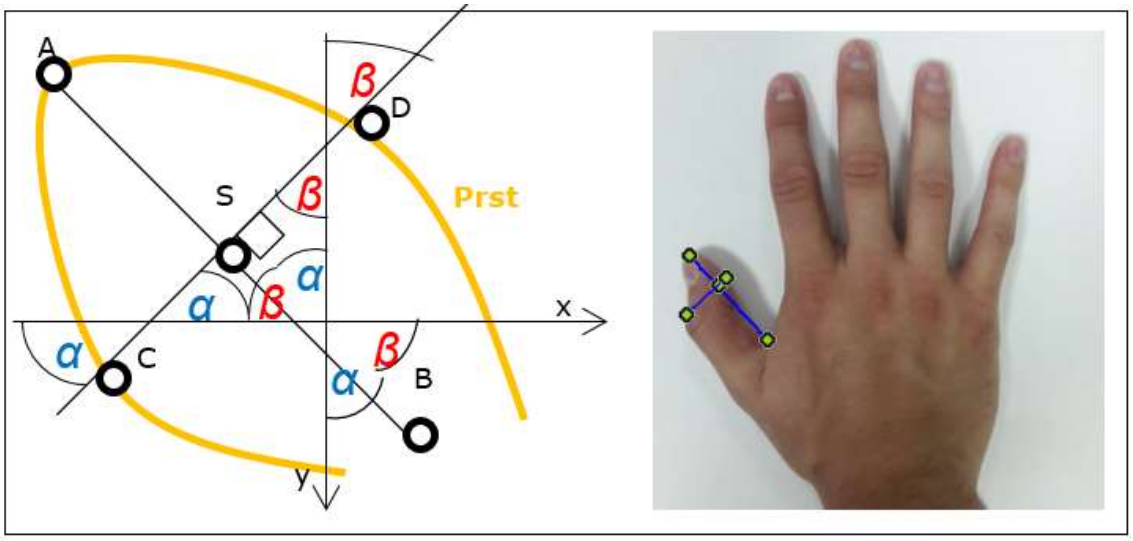
Metoda je praktično poslužila prije izmjere širine prstiju. Sljedeći programski kod prikazuje metodu koja se poziva u slučaju da treću točku tražimo točno na polovici puta između točke A i B, odnosno da tražimo središte dužine.

```
public static Tocka sredisteDuzine(Tocka A, Tocka B)
{
            Tocka S = new Tocka();
            S.x = (A.x + B.x) / 2;
            S.y = (A.y + B.y) / 2;
            return S;
                                                }
```

Metoda je praktično poslužila prije izmjere dužine prstiju kod određivanja početka prsta da početak prsta nije ni s lijeve ni s desne strane prsta nego na sredini.

6.7. Okomica

Praktično kod izmjere dužine i širine prsta, širina prsta je okomita na dužinu prsta. Na sljedećoj slici, dužina AB koja predstavlja dužinu prsta je okomita na dužinu CD koja predstavlja širinu prsta. Da bismo praktično postavili i riješili okomicu programski, pomaže razumijevanje gdje se matematički nalazi kut alfa ili kut beta. Dovoljan je jedan od navedena dva kuta da bismo ga uvrstili u formulu.



Slika 19: Širina prsta je okomita na dužinu prsta (skica lijevo) i dobivena slika tijekom razvoja aplikacije (desno)

Kako bismo počeli programski rješavati okomicu, pomaže klasa Duzina. Klasa Duzina definirana je s dvije točke koristeći klasu Tocka koja je opisana ranije. Kompletna klasa Duzina izgleda slično klasi Tocka:

```
class Duzina
    {
        public Tocka Tocka1 = new Tocka();
        public Tocka Tocka2 = new Tocka();
                                                }
```

Klasa Duzina služi dalje u programu kako bi varijabla tipa Duzina imala četiri cjelobrojna podatka: x i y jedne točke te x i y druge točke. Na taj način metoda `traziCD` vraća četiri cjelobrojne vrijednosti. Sljedeća metoda `traziCD` traži točke C i D pomoću zadane točke S, A i B te zadane slike.

```
public Duzina traziCD(Tocka S, Tocka A, Tocka B, Bitmap slika) {

            Duzina duzinaCD = new Duzina();
            Tocka C = new Tocka();
            Tocka D = new Tocka();

            int ABx = Math.Abs(B.x - A.x);
            int ABy = Math.Abs(B.y - A.y);

            double tanAlfa = (double) ((double) ABx / (double) ABy);
            double alfa = Math.Atan(tanAlfa);

            bool isPronadenC = false, isPronadenD = false;
            int traziY = 0, x, y;

            for (int traziX = 0; !isPronadenD; traziX++) {

                traziY = (int) Math.Round((double) traziX * alfa);
                x = S.x + traziX;
                if (B.x > A.x) { y = S.y - traziY; } else { y = S.y + traziY;  }
```

```
        if (!Validacija.isValidXY(x, y, slika)) { break; }

        if (!Boja.ispitajRuka(slika.GetPixel(x, y)))
        {
            D.x = x;
            D.y = y;
            isPronadenD = true;
        }

    }

    for (int traziX = 0; !isPronadenC; traziX++)
    {
        traziY = (int) Math.Round((double) traziX * alfa);
        x = S.x - traziX;
        if (B.x > A.x) { y = S.y + traziY; } else { y = S.y - traziY; }

        if (!Validacija.isValidXY(x, y, slika)) { break; }

        if (!Boja.ispitajRuka(slika.GetPixel(x, y)))
        {
            C.x = x;
            C.y = y;
            isPronadenC = true;
        }

    }

    duzinaCD.Tocka1 = C;
    duzinaCD.Tocka2 = D;
    return duzinaCD;

                                                    }
```

Metoda `traziCD` pomoću trigonometrije pravokutnog trokuta izračunava moguće koordinate točke C i D, a konačno pronalazi točke C i D na granici između prsta i podloge. Metoda `traziCD` služi se sljedećom formulom:

$$\tan \alpha = \frac{ABx}{ABy}$$

gdje je ABx nasuprotna kateta kutu alfa, a ABy je priležeća kateta kutu alfa. Obrnutom metodom od tangensa (Atan) kuta alfa dobiven je kut alfa. Metoda `traziCD` često poziva metodu `isValidXY`. Metoda `isValidXY` koja je definirana u klasi Validacija vraća logičku istinu ako se x i y nalaze na slici u zadanim marginama od 10 piksela sa svih strana (gore, dolje, lijevo i desno) od ruba slike. Metoda `isValidXY` vraća logičku laž u suprotnom.

Metoda `isValidXY` izgleda ovako:

```
public static bool isValidXY(int x, int y, Bitmap slika)
        {
            int limit = 10;
            if(x > limit && y > limit
                && x < slika.Width – limit && y < slika.Height - limit)
            {

                return true;
            } else
            {

                return false;
            }


                                                    }
```

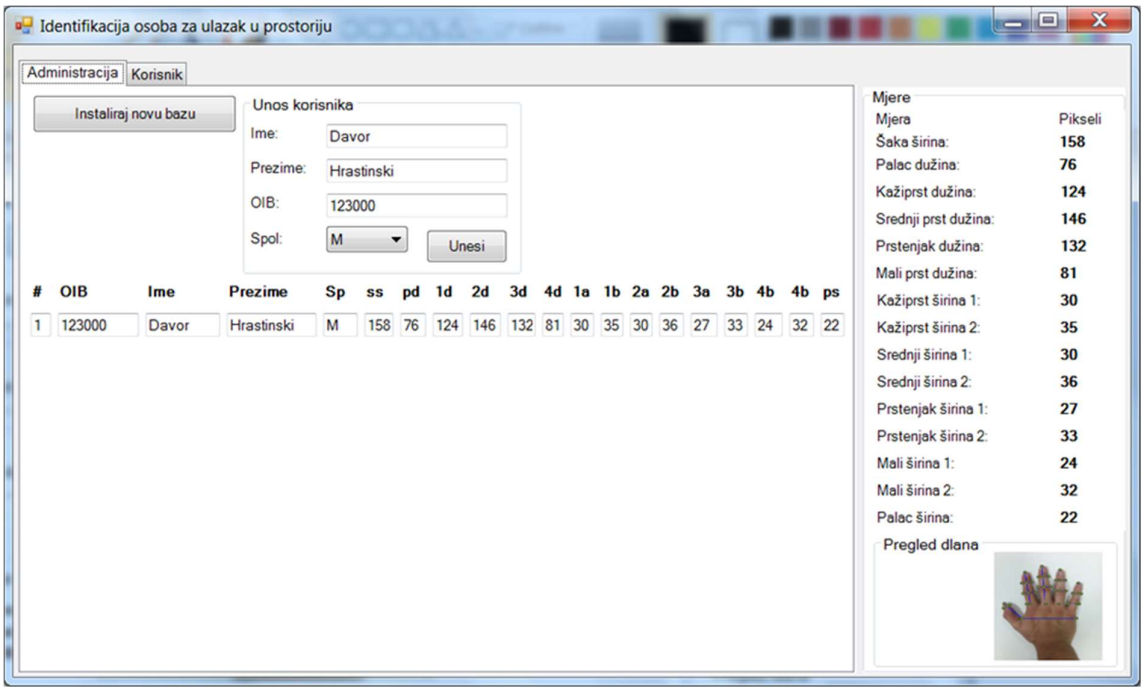
Poziv metode `isValidXY` u drugim metodama osigurava da se koordinate ne traže izvan zadanih margina i time se sprječava zaustavljanje aplikacije. U slučaju da metoda `isValidXY` vrati logičku laž, aplikacija nastavlja s radom, ali se točke nalaze na krivim mjestima, stoga je potrebno namjestiti korekcije slike (u kartici „korisnik“).

6.8. Korištenje aplikacije

Aplikacija iz perspektive korisnika je podijeljena u dvije kartice (tabs): Administracija i Korisnik. Kartica Korisnik je predviđena za korisnika kojeg treba identificirati, a kartica Administracija je namijenjena za osobu zaduženu za spremanje podataka o korisnicima. Da bi aplikacija mogla prepoznati korisnika, isti mora postojati evidentiran u bazi podataka.

6.8.1. Administracija

Kartica „Administracija“ služi za unos podataka o korisniku. Podaci o korisniku su ime, prezime, OIB, spol, širina dlana, dužina palca, dužina kažiprsta, dužina srednjaka, dužina prstenjaka, dužina mezimca, širina palca, širina kažiprsta, širina srednjaka, širina prstenjaka, širina mezimca, druga širina kažiprsta, druga širina srednjaka i druga širina prstenjaka. Kod prvog korištenja aplikacije potrebno je kliknuti na gumb „Instaliraj novu bazu“. Isti gumb kasnije može poslužiti za brisanje svih podataka i obnovu baze podataka bez upozorenja.

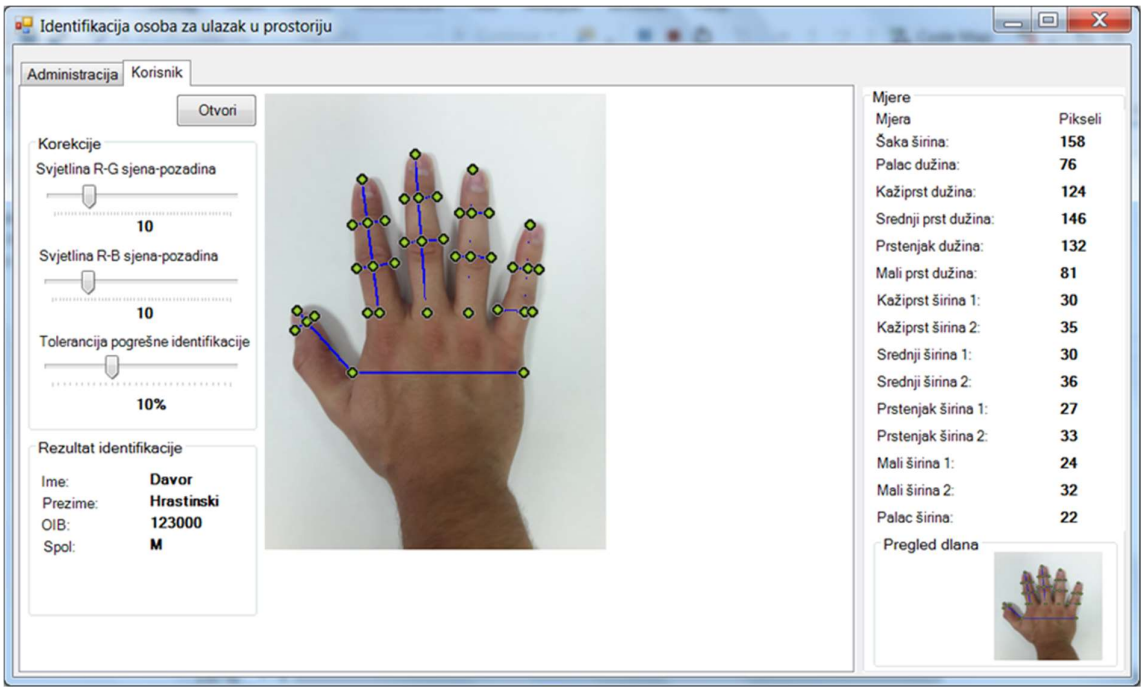


Slika 20: Kartica „Administracija“

Klikom na gumb „Unesi“ unose se podaci iz obrasca zajedno sa podacima dobivenih temeljem slike dlana.

6.8.2. Korisnik

Kartica „Korisnik“ služi za prepoznavanje korisnika na temelju ranije unesenih podataka. Klikom na gumb „Otvori“ pojavljuje se standardni okvir za otvaranje datoteke gdje je potrebno izabrati sliku dlana. Dobivene podatke je potrebno spremiti u kartici „Administracija“ ako je otvorena slika novog korisnika prvi put.



Slika 21: Kartica „Korisnik“

Cilj je otvoriti neku drugu sliku istog korisnika i aplikacija bi trebala identificirati korisnika na temelju ranije unesenih podataka. Aplikacija mjeri udaljenosti na dlanu. Mogućnost pogreške mjerenja je velika.

7. Zaključak

Primjena biometrije i biometrijskih metoda identifikacije u svim područjima ljudskog života pa i kriminalističkog istraživanja već danas je prisutna realnost. U teorijskom dijelu rada prikazane su razne metode identifikacije te detaljnije identifikacija pomoću biometrije dlana. Većina poznatih biometrijskih metoda tek je u povojima, a mogućnosti razvoja tih i ustanovljavanje novih može se širiti u nedogled. Interes društva, bilo da se radi o području policijsko-kriminalističke ili na području privatne sigurnosti, je da se istraživanje i razvitak biometrijskih mogućnosti u području identifikacije nastavi.

Vezano za moj rad o geometriji dlana, opisana je identifikacija osoba korištenjem dlana i način na koji on funkcionira kroz razne sustave. Dan je pregled biometrijskih značajki dlana kao što su geometrija dlana, glavne linije, nabori, grebeni te način njihovog prikupljanja i daljnje obrade kako bi se koristili za identifikaciju osoba.

Sustavi od kojih se ne očekuje visoka razina točnosti postali su sveprisutni i koriste se već npr. na mobilnim telefonima i prijenosnim računalima za autentifikaciju korisnika. U skoroj budućnosti očekujem sve veću prisutnost sustava za kontrolu ulaska u različite objekte i pristup različitim aplikacijama te da će se njihov razvoj neprestano usavršavati. Smatram da će biometrija ići toliko daleko da će biti personalizirana za razne životne potrebe kao što su plaćanje dlanom prilikom kupnje u trgovinama, otključavanje auta ili paljenje auta pomoću prsta itd…

U praktičnom dijelu rada, izradio sam aplikaciju u jeziku C# i koristeći bazu podataka SQLite. Aplikacija mjeri dužine i širine prstiju te širinu šake. Cilj korištenja aplikacije je otvoriti sliku dlana drugi put i aplikacija bi trebala prepoznati korisnika temeljem slike otvorene prvi put. Zbog nesavršenosti aplikacije potrebno je namjestiti „korekcije“ i identifikacija nije potpuno pouzdana iz praktičnih i teorijskih razloga. Tome najznačajniji praktični razlog je mogućnost pogreške mjerenja, a najznačajniji teorijski razlog je mogućnost da dvije osobe imaju identične mjere.

Popis literature

[1] Želimir Radmilović, Biometrijska identifikacija, stručni članak, 2008., Dostupno: https://hrcak.srce.hr/file/117825

[2] Marina Dimić, Biometrijski sustavi identifikacije, završni rad, 2016., Dostupno: https://repozitorij.ffos.hr/islandora/object/ffos:2344/preview

[3] Ivan Fratrić, Biometrijska verifikacija osoba temeljena na značajkama dlana i lica dobivenim iz video sekvenci, doktorski rad, 2011., Dostupno: https://www.bib.irb.hr/511729/download/511729.rad.pdf

[4] Carnet, Biometrija, Carnet Cert u suradnji s LS&S, 2006., Dostupno: https://www.cis.hr/www.edicija/LinkedDocuments/CCERT-PUBDOC-2006-11-167.pdf

[5] Igor Vasiljević, Biometrija, seminar, 2007., Dostupno: http://spvp.zesoi.fer.hr/seminari/2007/seminari/IgorVasiljevic_Biometrija.pdf

[6] Manuel Maraš, Korištenje biometrijskih značajki dlana za identifikaciju osoba, diplomski rad, 2018., Dostupno: https://repository.inf.uniri.hr/islandora/object/infri%3A192/datastream/PDF/view

[7] Mario Karlovček, Tomislav Fotak, Autentikacija osobe primjenom minimalno razapinjućih stabala na dvodimenzionalnu sliku dlana, 2009., Dostupno: https://apps.unizg.hr/rektorova-nagrada/javno/stari-radovi/377/preuzmi

[8] Hanadi Beganović, Biometrijska identifikacija, specijalistički rad, Dostupno: http://www.vladimirbozovic.net/univerzitet/bozovic/wp-content/uploads/2011/06/biometrijakonacna.doc

Popis slika

Slika 1: Digitalizirani predložak otiska prsta [4] 4
Slika 2: Biometrijski uzorak prepoznavanja lica [4] 5
Slika 3: Šarenica oka i mrežnica oka [5] 6
Slika 4: Termogram lica [5] 7
Slika 5: Frekvencija glasa [5] 9
Slika 6: Potpis opisan krivuljama i njihovim međusobnim odnosima [4] 10
Slika 7: Grafički prikaz brzine tipkanja iste riječi za dvije različite osobe [4] 10
Slika 8: Prikaz kuta pod kojim osoba zaobilazi prepreku [4] 11
Slika 9: Biometrija uha [5] 11
Slika 10: Shematski izgled DNK molekule [4] 12
Slika 11: Mjere za analizu geometrije dlana [7] 14
Slika 12: Dlan s označenim točkama na temelju kojih se računaju geometrijske značajke (a, b, c, d) i delta točkama (1, 2, 3, 4, 5) [3] 16
Slika 13: Geometrijske karakteristike dlana [7] 17
Slika 14: Kontura dlana s izlučenim karakterističnim točkama [7] 18
Slika 15: Izlučivanje karakterističnih točaka palca [7] 19
Slika 16: NuGet package manager 21
Slika 17: Prvih 8 točaka koje aplikacija pronalazi (slika je nastala tijekom razvoja). 24
Slika 18: Udaljenost između dvije točke u koordinatnom sustavu prilagođeno metodi u C#-u 25
Slika 19: Širina prsta je okomita na dužinu prsta (skica lijevo) i dobivena slika tijekom razvoja aplikacije (desno) 28
Slika 20: Kartica „Administracija“ 31
Slika 21: Kartica „Korisnik“ 32