Daktiloskopija

Tkalčić, Ana

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:211:239787

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

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

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Ana Tkalčić

Daktiloskopija

ZAVRŠNI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Ana Tklačić
Matični broj: S-43495/14-1
Studij: Primjena informacijske tehnologije u poslovanju

Daktiloskopija

ZAVRŠNI RAD

Mentor:

Bača Miroslav

Varaždin, lipanj 2018.

Sadržaj

1. Uvod 1
2. Biometrija 2
2.1. Identifikacijska obilježja 3
2.2. Pregled biometrijskih metoda 3
3. Daktiloskopija 5
3.1. Povijest daktiloskopije i otisak prsta kroz povijest 6
3.2. Vrste poslova kod daktiloskopije 7
3.3. Poslovi identifikacije papilarnih linija 7
3.4. AFIS - Automated fingerprint identification system 8
4. Otisak prsta 10
4.1. Svojstva papilarnih linija – karakteristike otiska prsta 11
4.1.1. Minuciji 11
4.2. Tehnologija otiska prsta 13
4.3. Petlja ili zamke 15
4.4. Kružni uzorak 15
4.5. Krivotvorenje otiska prsta 16
4.6. Digitalni filteri za prepoznavanje otiska prstiju 17
4.6.1. Analiza otisaka prstiju 17
4.6.2. Usporedba ROC (*receiver operating characteristic*) krivulja 20
4.7. Metode identifikacije otiska prsta 21
5. Sustavi za klasifikaciju otiska prsta 23
5.1. Ivan Evangelista Purkinije 23
5.2. Henry Faulds 24
5.3. Sir Francis Galton 25
5.4. Vučetićev klasifikacijski sustav 25
6. Zaključak 27
Literatura 28
Popis slika 30

1. Uvod

Danas je sve češće potrebno identificirati neku osobu, predmet ili nešto treće. Nažalost vrlo često se surećemo sa kaznenim, krivičnim djelima, a pogotovo u zemlji poput Sjedinjenih Američkih država. Kod takvih slučajeva nastupa biometrija koja je zadužena da na temelju fizičkih osobina neke osobe i njegovih karakterisika identificira o kojoj se osobi radi. Vrlo je važno da se radi o karakteristikama osobe koje su nepromjenjive. S obzirom na to da se trenutno nalazimo u vremenu u kojem je ljudska sigurnost sve više i više ugrožena potrebno je razvijati kako sigurnosne tako i biometrijske sustave koji će omogućiti smanjenje razine prijetnji makar one bile samo potencijalne.

Daktiloskopija je zapravo glavna tema ovoga rada i ona je jedna od najzastupljenijih grana iz područja biometrije pa čak i cjelokupne forenzike, jer upravo otiska prsta je taj koji se vrlo često pronađe na mjestu na kojem je počinjen neki zločin ili neko krivično djelo. Potrebno je posjedovati dva otiska prsta iste osobe (jedan s mjesta zločina i jedan u bazi podataka ili uzet od potencijalne sumnjive osobe).Svakim danom se u bazi otisaka kao što je AFIS nalazi sve više otisaka prstiju i sve više je osoba evidentirano. Isto tako se svakodnevno pokušavaju razviti i poboljšati nove tehnologije kako bi se spriječio bilo kakav oblik krivotovorenja bilo kojeg dijela tijela (najčešće se krivotvori otisak prsta).

Kroz rad će biti obuhvaćena biometrija i njezina identifikacijska obilježja i metode. Daktiloskopija sa svojom povješću, vrstama poslova koje je potrebno odraditi, poslovima identifikacije papilarnih linija. Također spomenuti će se i AFIS (baza podataka sa otiscima prstiju). Nakon toga slijedi nešto više o samom otisku prsta, tehnologijama, petljama, uzorcima, krivotvorenju, filterima, meodama identifikacije otiska prsta. Sustavi za klasifikaciju otiska prsta će također biti jedno poglavlje koje će obuhvaćati velike znanstvenike i njihoe sustave, te na samome kraju sljedi zaključak.

2. Biometrija

U današnje vrijeme postoji veliki broj definicija što je to biometrija i čemu ona zapravo služi. iječ biometrija potječe od grčkih riječi bios (život) i metron (mjera), a ona predstavlja „*skup autoriziranih metoda za jedinstveno prepoznavanje ljudi temeljeno na jednoj ili većem broju njihovih fizičkih i ponašajnih karakteristika.“* Pa tako u samom nastavku slijedi nekoliko definicija biometrije:

„Biometrija (bio- + -metrija) ili biološka statistika, skupna oznaka za sve brojčane obradbe mjerljivih i brojem iskazivih vrijednosti u svim područjima biologije, a odnosi se osobito na istraživanja promjenljivosti svojstava pojedinih organizama zbog izvanjskih činitelja i naslijeđenih osobina.[1]*“*

„Biometrija (biostatistika), primjena matematičko-statističkih metoda u bioznanostima (osobito u genetici, ispitivanju lijekova, preventivnoj medicini i dr.)[2]*“*

Biometrija je znanost, „*o postupcima za jedinstveno prepoznavanje ljudi, na temelju uspoređivanja jednog ili više urođenih tjelesnih obilježja, ili obilježja čovjekovog ponašanja“*[3].

„Biometrija je disciplina koja razvojem znanosti, a prije svega digitalno-informacijske tehnologije, dobiva sve značajnije mjesto u različitim područjima društvenog života, ljudskog rada i interesa.“[4]

Biometrija za cilj ima idetifikaciju i identitet bilo osoba ili životinja. Identitet predstavlja nepromjenjivost obilježja koja čine neku osobu. Skup obilježja koji čine neku osobu odnosno ono po ćemu se ta osoba može prepoznati.[5] Skup obilježja ili individualnih karakteristika koje predstavljaju individualnost neke osobe ili predmeta, životinje. Identifikacija osoba je utvrđivanje nečeg nepoznatog s nečim od prije poznatim kako bi se utvrdilo o kome ili čemu se

[1] http://www.enciklopedija.hr/natuknica.aspx?id=7784 – dostupno 13.03.2018.
[2] http://proleksis.lzmk.hr/12336/ - dostupno 13.03.2018.
[3] Boban, Marija; Perišić, Mirjana. Biometrija u sustavu sigurnosti, zaštite i nadzora informacijskih sustava. // Zbornik radova Veleučilišta u Šibeniku / uredio Dragan Zlatović. Šibenik: Veleučilište u Šibeniku, 2015. Str. 124-125. URL: http://hrcak.srce.hr/142285 (13.03.2018.)
[4] Radmilović Želimir, Biometrijska identifikacija, kolovoz, 2008., stručni članak
[5] Kolar-Gregorić, T., Kriminalistička identifikacija osoba, Krimarak 9, Zagreb, 2002., 3.-5., MUP-RH

točno radi. Što znači da se uspoređuje određeni broj identifikacijskih obilježja i ustanovjuje se koliko se ona podudaraju ili koliko su različita. (Radmilović, 2008.)

Kod biometrije i biometrijskih identifikacija postoje razne dvojbe. Svaki autor (može se reći i povjesničar koji je sudjelovao u razvoju biometrije) ima svoje teorije i mišljenja koje smatra najboljima. Jedni od autora prihvaćaju suvremene tehnološke mogućnosti koje se javljaju ili se mogu javiti dok drugi ipak ne prihvaćaju. Iako, bez obzira na to da li autor prihvaća ili ne prihvaća nešto, nema dileme oko metode identifikacije koja je determinirana primarno digitalnim i informacijskim okruženjem. (Radmilović, 2008.)

2.1. Identifikacijska obilježja

Svaka osoba, životinja ili predmet su jedinstveni imaju svoje karakteristike prema kojima su jedinstveni, neponovljivi i razlikuju se od svih drugih. Kriterij po kojem se razlikuju od svih drugih su određena individualna obilježja, a dio tih obilježja se koristi u kriminalističkim identifikacijama. Kako bi se neko od obilježja moglo koristiti za identifikaciju mora zadovoljavati sljedeće uvjete:

- ✓ univerzalnost
- ✓ originalnost ili individualnost
- ✓ trajnost i nepromjenjivost
- ✓ izdavajanje iz ukupnog obilježja
- ✓ jednostavno sakupljanje i korištenje

Kada se radi o postupku utvrđivanja i provjere identiteta neke osobe koriste se tjelesna obilježja koja se još nazivaju i faktičkim ili stvarnim obilježjima, i još se koriste pravna obilježja. Identifikacijska obilježja se mogu klasificirati kao opća ili skupna i kao obilježja koja se koriste za identificiranje ili definiranje neke određene skupine (za određivanje neke rase, krvna grupa i dr.). Postoje još i ona za eliminaciju i posebna koja determiniraju određenu osobu (papilarne linije).

2.2. Pregled biometrijskih metoda

Korištenjem biometrijskih metoda za prepoznavanje otkrivaju se brojne mogućnosti zlouporabe i umanjuju se nedostaci poput pada pouzdanosti standardnih metoda identifikacije, porasta sigurnosnig zahtjeva i dr.[6]

Postoje sljedeće biometrijske metode za identifikaciju osoba:

- ✓ Identifikacija putem ostisaka dlanova i prstiju – afis
- ✓ geometrija lice
- ✓ geometrija dlana, ruke
- ✓ raspored vena
- ✓ izgled šarenice
- ✓ izgled mrežnice oka
- ✓ termogram lica i tijela
- ✓ 3d fotogramterijska antropologija i 3d facijalna rekonstrukcija
- ✓ tjelesni mirisi
- ✓ dnk analiza
- ✓ analiza glasa, rukopisa i potpisa
- ✓ analiza zubala

U biometriju ponašanja spadaju prepoznavanje glasa, prepoznavanje rukopisa ili potpisa, dinamika tipkanja, dinamika hoda. U fizičku biometriju spadaju skeniranje rožnice, prepoznavanje lica, termogram lica i tijela, geometrija šake i dlana, otisak uha, miris, DNK analiza.

[6] Subotić, Oliver. Biometric Identification System: A Critical Study. Biometrics, Security and Human Rights, 2008

3. Daktiloskopija

Daktiloskopija je poznata primjena biometrijske analize. Radi se o analizi otisaka prstiju i dlanova te analizi papilarnih linija ukoliko je potrebno identificirati počinitelja nekog kaznenog djela ili je potrebno utvrditi identitet preminule osobe. [7] Klasična daktiloskopija u digitalnom okruženju dobiva potpuno novi oblik i veliko područje primjene. Sustavi privatne zaštitem sustavi za autorizaciju i autentikaciju baziraju se na daktiloskopiji. Načela daktiloskopije koja su temeljena na klasičnim sustavima poput Vučetićevog ili Roscherovog više se ne koriste i ne primjenjuju. (Radmilović, 2008)

„Daktiloskopija (daktilo- + -skopija), suvremena, najsigurnija i najrašireniji metoda utvrđivanja identiteta osoba na temelju papilarnih linija (ispupčenja koja tvore vijuge raznih šara na površini unutar. strane prstiju, dlanova i tabana).“[8]

„Daktiloskopija, kriminalistička metoda kojom se uzimaju, klasificiraju i registriraju crteži papilarnih linija dlanova i tabana. To je najsigurnija kriminalistička metoda za utvrđivanje identiteta živih i umrlih osoba.“[9]

„Daktiloskopija (grč. daktylos – prst; skopeo – gledam) je metoda identifikacije osoba prilikom kriminalističkog istraživanja i otkrivanja identiteta počinitelja ili žrtve kaznenog djela.“[10]

Identifikacija na temelju otisaka prstiju zajedno s onom temeljenom na dlanovima se temelji na jedinstenom rasporedu udubljenja i raznih ispupčenja kože poznato i kao dermatoglifa. Već je ranije spomenut Ivan Vučetić koji je prvi uveo deseteroprsno daktiloskopiranje i evidentiranje kriminalaca koje se temeljilo na razvrstavnju otisaka prstiju lijeve i desne ruke. (Radmilović, 2008)

[7] Pavišić B, Modly D, Veić P, Kriminalistika 1, Zagreb, Golden marketing – Tehnička knjiga.
[8] Encikopedija, http://www.enciklopedija.hr/Natuknica.aspx?ID=13709, dostupno 18.03.2018.
[9] Leksikografski zavod Miroslav Krleža - http://medicinski.lzmk.hr/daktiloskopija/, dostupno 18.03.2018.
[10] Papilarne linije, Podnar Ante, VNT Gospić, 2013. - https://hrcak.srce.hr/104885, dostupno 18.03.2018.





Slika 1: Jagodica prsta s odgovarajućim otiskom prsta
(http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, - dostupno 18.03.2018.)

3.1. Povijest daktiloskopije i otisak prsta kroz povijest

Još u predhitosrijsko doba ljudi su bili upoznati s time da na dlanovima imaju odreene linije koje daju određene karakteristike. Brojni crteži ruku su pronađeni po zidovima u pećinama i na iskopanim starim predmetima. Poznato je kako je otisak prsta najstarija tehnika koja se koristi za identifikaciju. Povijest samog otiska prsta odlazi i do 2000 godina prije Krista. Koljevkom daktiloskopije se smatra Daleki Istok. Točnije u Japanu, Kini, ali i Perziji su se otisci prstiju još prije nove ere koristili kao sredstva za identifikaciju i sredstvo ovjeravanja pravnih isprava.[11] Do god se nije pomo izučila ljudska koža odnosno anatomija ljudske kože korištenje otisaka dlanova i prstiju nije imalo previše smisla.

Anatomi Nehemaih Grew i Marcello Malpighi su bili među prvima koji su opisali grđau i svojstva papilarnih linija na dlanovima u 17. stoljeću. Tek nakon nešto više od 100 godina Ivan Evangelisa Purkinije je prvi sastavio skicu otiska prsta i klasificirao uzorke šara koji se javljaju na prstima. Klasificirao ih je u devet skupina. Također, još jedan od važnijih ljudi za daktiloskopiju je Sir Wiliam Herschel koji je u Indiji 1860. godine počeo uzimati otiske prstiju na potvrdama prilikom isplate penzija. Uz njega važan je još i Henrya Fauldsa koji je u praksi potvrdio kako se tragovi otisaka prstiju koji su nađeni na nekom mjestu zločina mogu upotrijbiti za identificiranje počinitelja. Ivan vučetić je razvio metode za dobivanje otisaka papilarnih linija na papiru i sastavio je vrlo jednostavn sustav klasifikacije. La Plati šef identifkacijske službe u Argentini uveo je u svoj susav klasifikaciju svih 10 otisaka prstiju, ujedno prvi je

[11] The History of fingerprints http://onin.com/fp/fphistory.html, dostupno 18.03.2018.

uspoređivanjem šara papilarnih linija na krvavom otisku pronađenom na mjestu zločina uspio otkriti počinitelja. Naravno morao je doći do otiska sumnjivca i na taj način je izvršio usoredbu i dobio rješenje zločina (slučaj Fancisce Rojas).[12]

Godine 1903. New York State Prision je počeo koristii otisak prsta kao sredstvo za identificiranje zatvorenika, a od 1905. koristi ga i američka vojska. [13] 1924. godine FBI organizira odnosno osniva odjel za prepoznavanje otisaka prstiju. Nešto kasnije u radu će se pronači još neke bitne osobe povezane s klasifikacijom otiska prsta, ali će neke biti u opširnijem obliku opisane.

3.2. Vrste poslova kod daktiloskopije

Prema vrstama razlikuju se:

- ✓ poslovi detekcije
- ✓ poslovi identifikacije
- ✓ poslovne identifikacije spornih tragova papilarnih linija
- ✓ poslovi identifikacije osoba

Kod poslova detekcije radi se o pregledu predmeta koje foranzičari pronalaze na mjestima događaja, odnosno kaznenih djela. Primjenjuje se forenzčko svjetlo kako bi se pronašli određeni tragovi i predmeti. Kod detekcije papilarnih linija potrebno je pažljivo odabrati određene metode i zatim provesti daktiloskopsku pretragu. Sve to skupa za cilj ima identificiranje počinitelja ako se radi o nekom kaznenom djelu, a u krajnjem slučaju identifikaciju preminule osobe ukoliko nema nikakvih osobnih dokumenata pored sebe.[14]

3.3. Poslovi identifikacije papilarnih linija

Ovi poslovi obuhvaćaju:

- ✓ Identificiranje počinitelja na temelju tragova odnosno papilarnih linija koje su pronađene na mjestu zločina odnosno mjestu kaznenog djela
- ✓ Zatim je potrebno vještačenje tragova koji su pronađeni na tom istom mjestu gdje je počinjeno kazneno djelo

[12] Kolar – Gregorić, T., (1996.) Kriminalistička tehnika, Krimarak 3, MUP, Zagreb
[13] The History of fingerprints http://onin.com/fp/fphistory.html, dostupno 18.03.2018.
[14] Daktiloskopija_MUP - http://www.forenzika.hr/964.aspx, dostupno 18.03.2018.

- ✓ Osobe koje su bile u svakodnevnom doticaju s pronađenim predmetima eliminiraju se kako bi bilo lakše otkriti krivca
- ✓ Usporedba nepoznatih otisaka osoba s poznatim otiscima da bi se utvrdilo koristi li koja osoba tuđe identifikacijske isprave [15]

3.4. AFIS - Automated fingerprint identification system

Moderni računalni sustav za automatiziranu obradu otisaka prstiju papilarnih linija i dlanova. Baza AFIS-a se sastoji od baze otisaka prstiju. Koristi suvremene metode za identifikaciju koja se temelji na otiscima prstiju. AFIS znatno skraćuje vrijeme koje je potrebno za unos podataka i dobiavju se znatno veće mogućnosti za provjeru kompletne baze podataka. (Radmilović, 2008)

AFIS (Automated Fingerprint Identification System) je sustav za prepoznavanje otisaka prstiju. U Hrvatskoj je u MUP-ovom centru prisutan od 2006. godine. AFIS sustav se sastoji od dvije baze[16]:

- Baza otisaka prstiju
- Baza spornih tragova papilarnih linija

Sami sustav omogućuje unošenje otisaka prstiju osoba i spornih tragova na kojima su vidljive papilarne linije. Sustav poput ovoga omogućuje provjeru otisaka osoba te spornih tragova. Vrste provjera koje se mogu poduzimati su[17]:

- otisci osobe - kroz postojeću bazu spornih tragova papilarnih linija
- otisci osobe - kroz postojeću bazu otisaka osoba
- sporni tragovi papilarnih linija - kroz postojeću bazu spornih tragova papilarnih linija
- sporni tragovi papilarnih linija - kroz postojeću bazu otisaka osoba

[15] Daktiloskopija_MUP - http://www.forenzika.hr/964.aspx, dostupno 18.03.2018.

[16] http://www.forenzika.hr/234633.aspx, dostupno 11.09.2018.
[17] http://www.forenzika.hr/234633.aspx, dostupno 11.09.2018.

U svim tim centrima zaposleni su viši kriminalistički tehničari koji svakodnevno unose nove podatke i provjeravaju sporne tragove papilarnih linija kroz AFIS sustav. U Hrvatskoj je na AFIS-ov centar spojeno pet dislociranih radnih jedinica u sljedećim gradovima[18]:

1. Osijek
2. Zagreb
3. Rijeka
4. Pula
5. Split

Sustav radi na temelju nekoliko provjera (Radmilović, 2008):

1. Provjera deseteroprsnog s deseteroprsnim obrascima – znači otisci svih 10 prstiju, a služi za sravnivanje baze na način da se izbjegavaju duplikati u bazi podataka. Služi za utvrđivanje lažnih prezimena i imena u zamjenjuje klasični ručni način klasifikacije i pretraživanja daktiloskopske baze podataka.
2. Provjera deseteroprsnog obrasca s baznom sponih tragova – uspoređuju se sve novoevidentirane osobe s bazom spornih otisaka
3. Provjera spornog traga s bazom spornih tragova – pomoću ove provjere se povezuju činitelji kaznenih djela sa serijama kaznenih djela
4. Usporedba spornog traga s bazom deseteroprsnih obrazaca – uspoređuje se sa svim osobama koje su do tada daktiloskopira
5. Mogućnosti različitih obrada spornih tragova s ciljem poboljšanja kvalitete koja će olakšati ili omogućiti identifikaciju

AFIS radi tako da se otisci digitaliziraju – unose u bazu podataka na način da se skeniraju otisci na mjestu događaja, bilo da se radi o mrtvim ili živim osobama. Skeiranje otiska s mjesta događaja, prije toga je potrebno da je izuzet na foliju ili je fotografiran. Fotografije se moraju izrađivati u traženoj rezoluciji. To je rezolucija od 500 dpi jer upravo ta ista se koristi i u čitačima otisaka ali i algoritmima kompresije otisaka. Nakon što je slika otiska prenesena u bazu podataka analizira se na način da se naliziraju mjesta spajanja i završetaka papilarnih linija. Za analiziranje otisaka AFIS NE koristi klasifikaciju koja se temelji na osnovna tri uzorka (luk, zamke ili krug) kao to je to u daktiloskopskim zbirkama. (Radmilović, 2008)

[18] http://www.forenzika.hr/234633.aspx, dostupno 11.09.2018.

AFIS sustav se ubodi 1965. godine u svojoj bazi sadržo 810 000 otisaka prstiju, 2000. godine se uvodi IAFIS s preko 47 milijuna otisaka prstiju, a u 2016. godini taj suatav sadrži preko 60 milijuna otisaka prstiju i koristi se za civilnu i forenzičku upotrebu. (Usporedba i klasifikacija otisaka prstiju, 2011)



0

Slika 2: Tri glavne vrste otiska prsta (http://www.enciklopedija.hr/Natuknica.aspx?ID=13709, 18.03.2018.)



Slika 3: Pet vrsta odnosno kategorija otiska prsta - lijeva na desno: lijevo petlja, spirala, šatorski luk, desna petlja i luk
(Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008)

4. Otisak prsta

Svaka osoba ima jedinstveni otisak prsta, kako je ranije već spomenuto nijedna osoba nema identičan otisak prsta kao neka druga osoba. Otisak linija (papilarnih) je jedinstven.

4.1. Svojstva papilarnih linija – karakteristike otiska prsta

Karakteristike ostiska prsta se mogu podijeliti na lokalne i globalne karakteristike. Kod globalnih se dešava da obuhvaćaju tok papilarnih linija koje daju pet klasa, dok globalne karakteristike nisu dovoljne za pouzdanu identifikaciju. (Borković sa suradnicima, 2008) Tri glavna svojastva su nepromjenjivost, individualnost i mogućnost klasifikacije (Kolarić, Gregorić,1996):

a) ***Nepromjenjivost*** – papilarne linije imaju odnosno stvaraju crteže i šare različitih oblika. Šare nastaju već kada se u utrobi majke nalazimo kao zametak i one se ne mijenjaju sve do poslije smrti. Rastom i razvoje organizma povećavaju se papilarne linije no svejedno se oblici i šare ne mijenjaju. Oblici šara se ne mijenjaju niti nakon površinskih ozljeda kože. Do promjene može doći samo nakon što se povrijedi unutarnji sloj kože ili u slučaju neke teške bolesti.

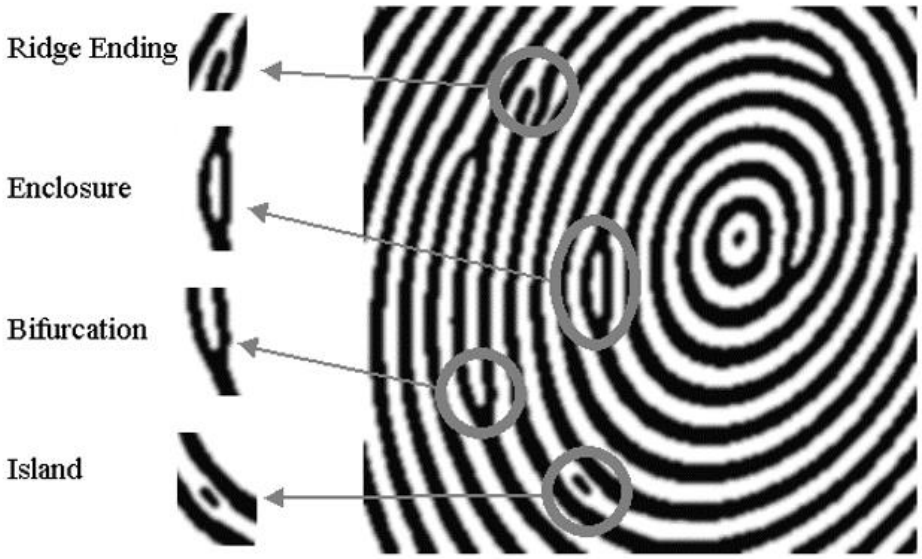
b) ***Individualnost*** – svaki otisak prsta kod svake osobe je jedinstven. Na svijetu ne postoje dvije osobe koje imaju identični otisak prsta odnosno identične papilarne linije. Čak ne postoje niti jednojajčani blizanci koji imaju identične papilarne linije. Vrlo često dolazi do zabune jer ljudi smatraju kako su svi crteži prstiju isti, a zapravo se razlikuju u malim sitnim detaljima koji ih čine potpuno različitima. Matematičkim putem se došlo do spoznaje kako je vjerojatnost pojavljivanja identičnog crteža papilarnih linija 1:64 milijarde. Minuciji se pojavljuju sa različitom učestalosti i najčešće su to kraj i prijelom, a vrlo rijetko se javljaju otočić i križanje. Kada se otisci koji se ispituju podudaraju u 20 minucija onda se može sa sigurnošću reći kako su oni identični da se radi o istoj osobi.

4.1.1. Minuciji

Minuciji su točke koje daju identifikaciju odnosno autentičnost otisku prsta i oni ako se poklapaju na dvije slike otiska potvrđuju nečiji identitet. Postoji pet raziličitih značajki minucijskih točki. Vrste minucija koje postoje su:

- ✓ papilarni svršetak
- ✓ papilarno grananje
- ✓ papilarno širenje

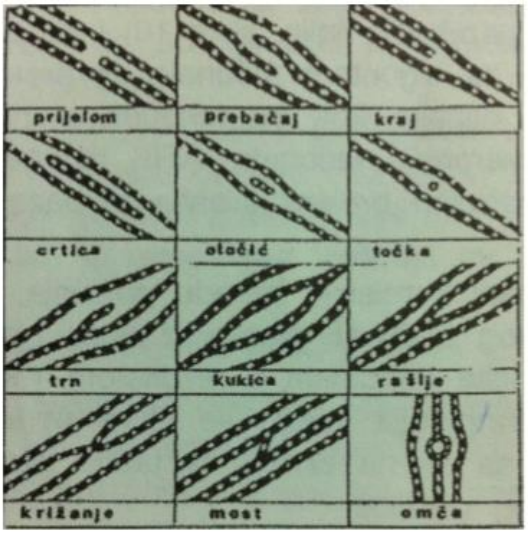
- ✓ papilarna točka ili otok
- ✓ papilarni ogib
- ✓ kratka papilarna linija
- ✓ orijentacija minucije
- ✓ plošna frekvencija minucija
- ✓ minucijske koordinate



Slika 4: Vrste minucija (www.anilaggrawal.com/ij/vol_002_no_001/papers/paper005.html, 18.03.2018.)



Slika 5: Minuciji završetak i račvanje papilarnih linija (Graevenitz - Introduction to Fingerprinttechnology, A&S International under "Sensing Fingerprints", Volume 53, Taipei, 2003:84/6)



Slika 6: Anatomska obilježja papilarnih linija (Kolar – Gregorić, T., Kriminalistička tehnika, Krimarak 3, MUP, Zagreb, 1996:31)

c) ***Klasifikacija*** – kako je svaki otisak prsta individualan postoje i određene sličnosti oblika papilarnih linija. Radi tih sličnosti crteži linija se mogu grupirati u vrlo mali broj osovnih skupina. Mogu se stavrati zbirke otisaka. Vrlo je značajno za identifikaciju jer kada dođe do potrebe vrlo bezo se može pronaći u zbirci otisak koji je potreban za usporedbu.

4.2. Tehnologija otiska prsta

Glavni problem koji se javlja kod tehnologije otiska prsta je prihvatljivost te iste tehnologije običnom korisniku. Otisci prsta se tradicionalno koriste u kriminalističkim i forenzičkim istragama, odnosno policijskom poslu. Korisni se u većini slučajeva ne osiječaju ugodno kada se radi o civilnoj primjeni. Kako je već rećeno otisci su nepromjenjivi. Razlikuju se četiri osnovna oblika papilarnih linija[19]:

- ✓ oblik luka
- ✓ oblik petlje s otvorom prema palcu – radijalna petlja
- ✓ oblik petlje s otvorom prema malom prstu – ulnarna petlja
- ✓ oblik kruga – oblik vrtloga

[19] Otisak prsta - http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, dostupno 18.03.2018.

Otisci koji spadaju u skupinu uzoraka luka su oni kod kojih se papilarne linije nalaze u središtu otiska i čine manje ili više uzdignut luk prema vrhu. Linije (papilarne) mogu imati i lučni čuk koji podsjeća na jelku i tu se govori o podskupinama[20]:

- ✓ čisti lukovi
- ✓ jeloviti lukovi



Slika 7: Čisti luk - otisak prsta (http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, dostupno 18.03.2018.)



Slika 8: Jeloviti luk - otisak prsta (http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, dostupno 18.03.2018.)

[20] Otisak prsta - http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, dostupno 18.03.2018.

4.3. Petlja ili zamke

Uzorci kod papilarnih linija koji prolaze s jedne strane u središtu i blizu središta se savijaju odnosno stvaraju petlju i vraćaju se nazad. Početak i kraj linija koje čine petlju su te koje stvaraju i sami otvor petlje. Razlikuju se dvije vrste petlji ovisno o tome na kojoj strani se nalazi otvor:

1. radijalna petlja
2. ulnarna petlja



Slika 9: Radijalna petlja (https://www.hayat.ba/vijest.php?id=102174, dostupno 18.03.2018.)



Slika 10: Ulnarna petlja (https://www.hayat.ba/vijest.php?id=102174, dostupno 18.03.2018.)

4.4. Kružni uzorak

U kružni uzorak soadaju otisci kod kojih papilarne linije obavijaju jedna drugu u središtu otiska. Većinom čine koncentrične manje ili više pravilne krugove, elipse ili spirale. Postoji šest skupina uzoraka kruga:

1. krug
2. spirala

3. petlja blizanac
4. dvostruka petlja
5. elipsa
6. mješoviti uzorak

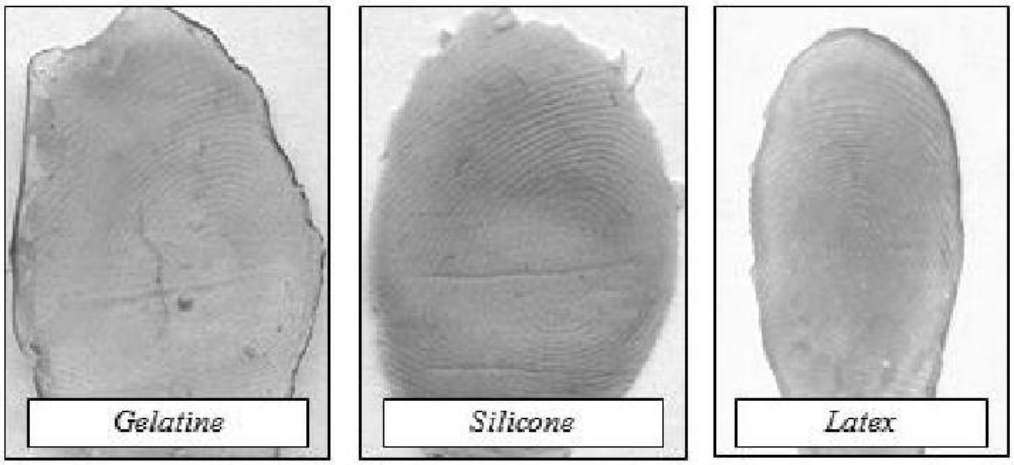


Slika 11: Kružni uzorak otiska prsta (https://www.express.hr/life/sto-vrhovi-vasih-prstiju-otkrivaju-o-vama-2916 dostupno 18.03.2018.)

4.5. Krivotvorenje otiska prsta

Kako i svaka tehnologija tako i ova ima problem. Kod ostiska prsta najveći problem stvara mogućnost krivotvorenja otiska. Ukoliko je kopija kvalitetna mogla bi vrlo uspješno zamjeniti stvarni otisak prsta kod senzorskih čitača. Otisak prsta iako je nepromjenjiv u potpunosti za razliku od lica ili hoda koji su izmjenjivi je ipak najpodložniji krivotvorenju. (Krmpotić, 2012.)

Zbog mogućnosti krivotvorenja otiska prsta, tehnologije koje se korsite za prepoznavanje otisaka trebale bi razlikovati prirodni prst od onog primjerka koji je krivotvoren ili nekog umjetnog dodatka na prst (prikaz na slijedećoj slici). Danas se provode brojna istraživanja kojima se pokušava spriječiti krivotvorenje. Ujedno, radi se na tehnologijama koje će mogći prepoznati i razlikovati pravi prst od bilo kakvog lažnog oblika. Smatra se kako bi bilo dobro koristiti još dodatni oblik identifikacije u kombinaciji s otiskom prsta da bi se osigurao što veći stupanj sigurnosti. (Krmpotić, 2012.)

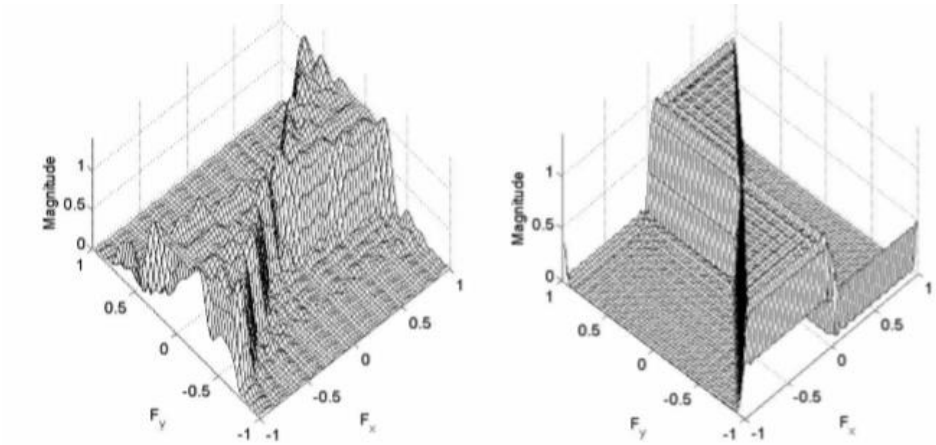


Slika 12: Materjali od kojih se može izraditi krivotvoreni otisak prsta (http://biolab.csr.unibo.it/research.asp?organize=Activities&pathSubj=111, 18.03.2018.)

4.6. Digitalni filteri za prepoznavanje otiska prstiju

4.6.1. Analiza otisaka prstiju

Analiza otiska prsta provodi se dvodimenzionalnim filterima nulte faze i onima klinastog oblika područja propuštanja (poznati kao i fan filetri). Svojim rotiranjem propusnog područja propuštaju prostorne frekvencije signala. Najveća suma propuštenih piksela za neki kut omogućuje dolazak do dominantne usmjerenosti sadržaja slike ili samo dijelova slike koja se trenutno analizira. Slijedeća slika prikazuje korištenje fan filtera 31. reda, širine propusnog područja koja iznosi 15° ili 20°. (Borković sa suradnicima, 2008)

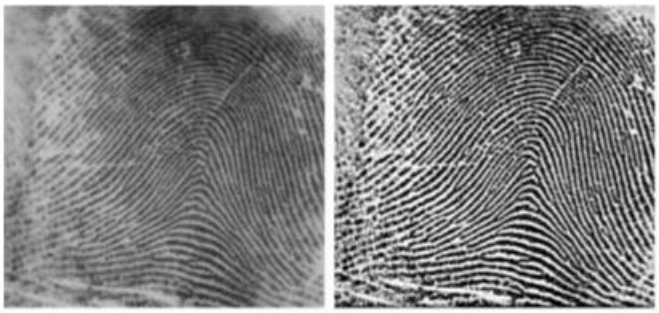


Slika 13: 3D prikaz fan filtera nižeg reda (lijevo) i višeg reda (desno) istih su kuteva, ali su različitog zaokreta (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008)

Tijekom analize dva različita otiska ističe se nekoliko zasebnih koraka (Borković sa suradnicima, 2008):

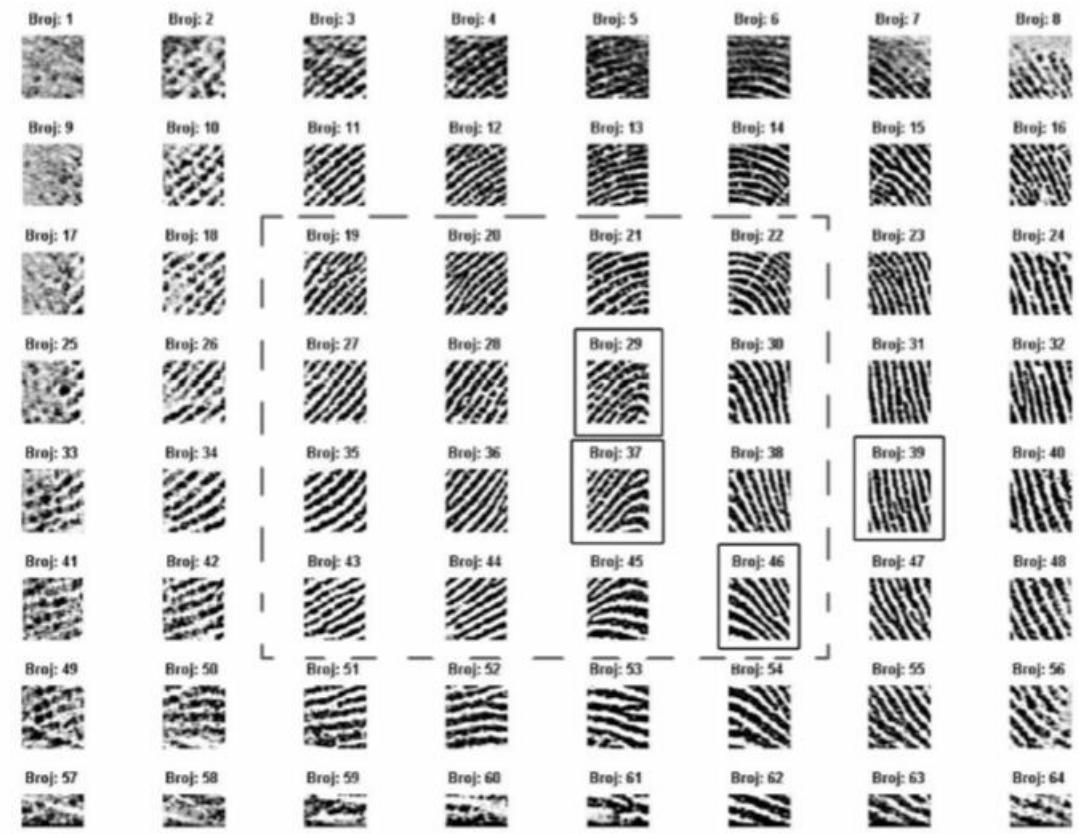
- ✓ predobrada
- ✓ nalazak referentne točke
- ✓ odabir područja interesa i kompoziciju rotacije
- ✓ analiza roi-a te izračun sličnosti između ta dva otiska koja se analiziraju

Predobrada predstavlja poboljšavanje kvalitete slike koje se ne izvodi uz pomoć fan filtera, već se koristi metoda zvana unsharp masking. Uz pomoć te metode se slike koje imaju brojne razine sivila može dobiti crno-bijela slika sa istaknutim papilarnim linijama. Postupak je slijedeći zamućuje se kopija originalne slike koja se potom uspoređuje s originalom, i ako je razlika veća od postavljenog praga slike se oduzimaju i kao rezultat se dobije znatno oštrija slika za razliku od originala.



Slika 14: Lijevo je slika otiska prije unsharp maskinga, a desno je nakon unsharp maskinga (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008

Referentna točka se pronalazi na način da se slika dijeli na 8x8 dijelova (64 kvadratića) i svakom kvadratiću se pronalazi dominantni kut usmjerenosti. Pikseli koji nisu dominantni zajedno s kutom koji je dominantan nazvati će ih se sumom usmjerenosti, a ta je suma različita za svaki kvadratić. Radi veličine ROI-a uvjek se analiziraju samo sume usmjerenosti unutrašnjih podjeljaka. Papilarne linije što su zakrivljenije i nepravilnije to će udio preostalih usmjernosti biti veći. Na slici ispod se radi o sličicama pod brojem 29, 37 i 46. (Borković sa suradnicima, 2008)



Slika 15: Podjela otiska na 64 kvadratića (8x8) (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008)

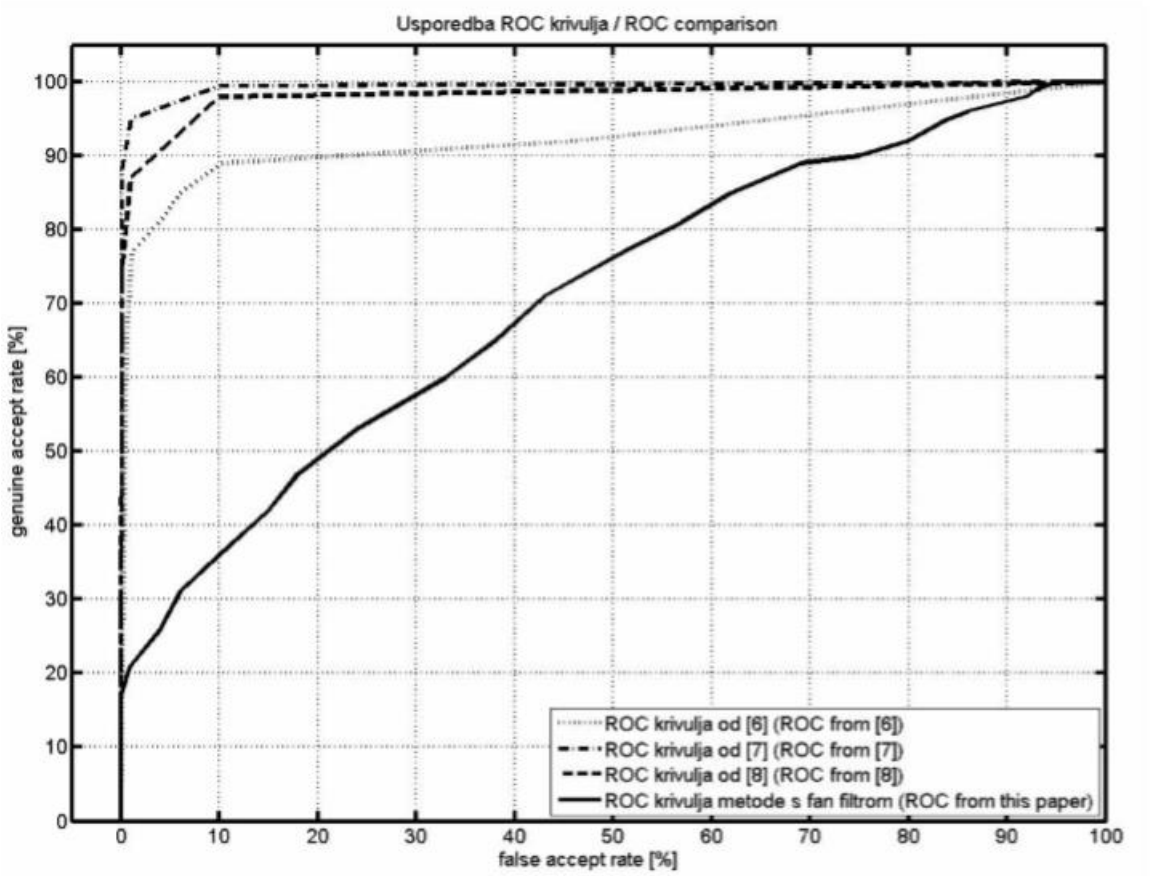
Kompenzacija rotacije nakon što se odredio ROI analizira se globalna usmjerenost papilarnih linija. Temeljem samo jednog kuta može se reći u kojem smjeru je potrebno zarotirati otisak. ROI se upravo radi toga moda podijeliti na četiri podjeljka. (Borković sa suradnicima, 2008)

Kod **uspoređivanja** se ROI dijeli na 16 dijelova, baš kao i do sada svaki dio ima svoju dominantnu usmjerenost, te uz tu dominantnu usmjerenost ima i sumu udjela preostalih kuteva. Tri varijable ima svaki neravnopravni udio u sličnosti. Dogodi li se da je izračunata sličnost između dva ista otiska manja od prethodno određenog praga i da se ta dva otiska ne podudaraju ili ako se desi da je veća ili jednaka granična sličnost tada se na dvije različit slike nalaze dva ista otiska prsta. (Borković sa suradnicima, 2008)

4.6.2. Usporedba ROC (*receiver operating characteristic*) krivulja

Slika ispod prikazuje analizu većeg broja otisaka prstiju iz baze NIST-4, a prikazuje ih putem ROC krivulje. Radi se o bazi koja ima ukupno 4000 otisaka prstiju odnosno to je 2000 parova koji su digitalizirani i pohranjeniu JPEG formatu. 8-bitne su slike i razina sivila slika je 256. Dimenzije slike su 512x512 piksela. (Borković sa suradnicima, 2008)

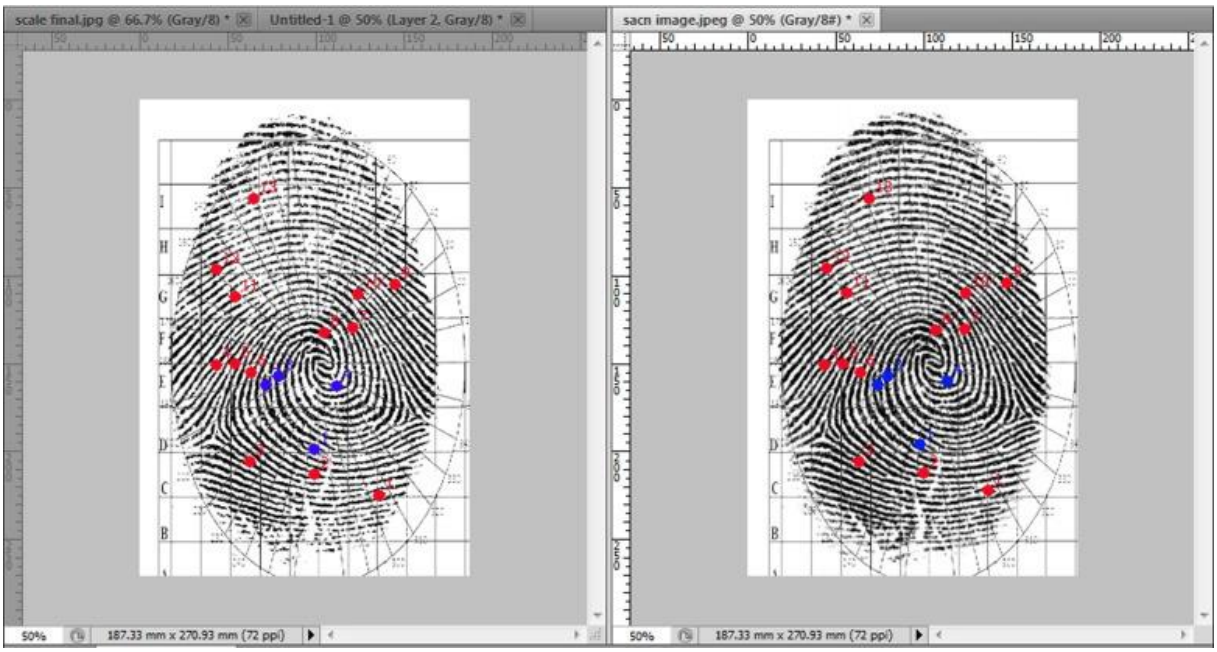
Ono što prikazuje krivulja na slici su rezultati nasumično odabranih 1000 otisaka. Preostale ROC krivulje koje se nalaze na slici su dobivene putem metoda i filtara korištenih u nekim drugim radovima. GAR (genuine acceptance rate) je mjera za ocjenu algoritma za prepoznavanje otiska prsta. FAR predstavlja omjer prihvaćenih lažnih uzoraka kao istih i ukupnog broja obrađenih uzoraka. Međusobna ovisnost GAR i FAR predstavlja upravo ROC krivulju. (Borković sa suradnicima, 2008)



Slika 16: Usporedba ROC krivulja (preostale krivulje su tu radi usporedbe samo) (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008)

4.7. Metode identifikacije otiska prsta

Osbornova mreža - je metoda kod koje se fotografiraju latentni otisci i zatim se te iste fotografije uvećavaju. Potom se na otisak koji je uvećan stavi mreža jednakih kvadrata. Potrebno je da pravokutnici mreže pokrivaju identične pozicije na svakom otisku. Nakon toga se pravokutnici uspoređuju, ako se utvrdi da su identični onda su i otisci identični.[21]



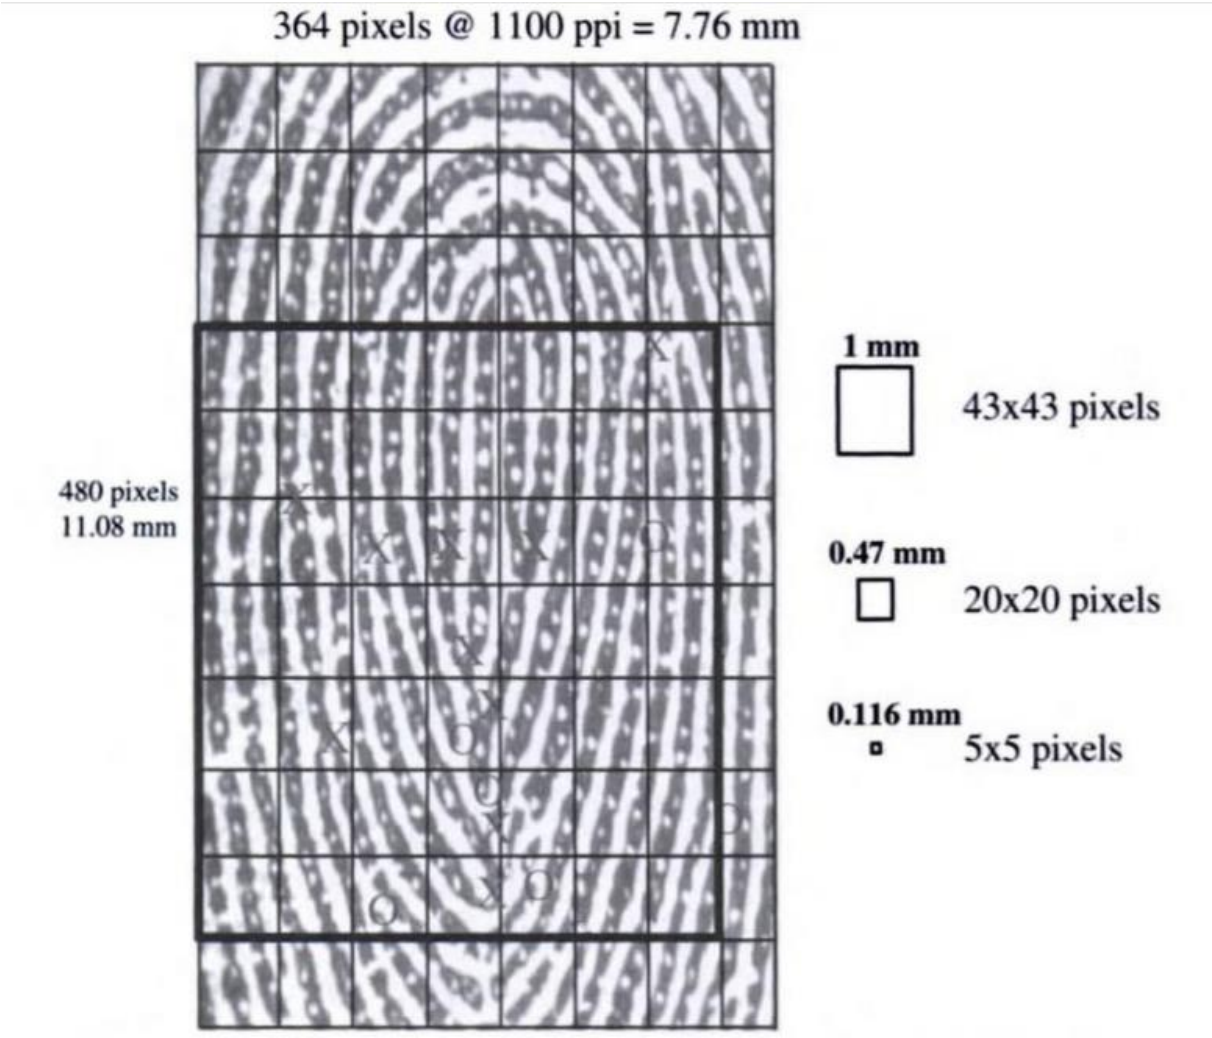
Slika 17: Osbornova mreža
(https://www.sciencedirect.com/science/article/pii/S2090536X16300181, 18.03.2018.)

Metoda poligona – ova se metoda zasniva na povećanju dva uzorka koja se zatim uspoređuju. Kod ove metode povećanja posebno moraju biti u istom mjerilu. Na točno odgovarajućim mjestima grebena se moraju probušiti male rupice i zatim se povećanja okrenu i s ravnim linijama se povežu rupice. Zatim slijedi nakon toga geometrijska usporedba odnosno konfiguracija jednog i drugog otiska. Ukoliko se poligon koji je dobiven probušenim rupicama podudara s latentnim i tintnim otiskom može se utvrditi idenitet osobe odnosno otiska prsta.

Osterburgova metoda - je samo početna tpčka otkrivanja teorijske preformance praktične primjene sustava za prepoznavanje ptiska prsta, a koja uključuje FAR i FRR. Istražuje ili pregledava segmente veličine 1 mm x 1 mm. Ovo je metoda koja ne uspoređuje karakteristike odgovarajućih čelija u mreži. Svaka karakteristika ima vrijednost prema nekoj od učestalih

[21] https://www.sciencedirect.com/science/article/pii/S2090536X16300181, dostupno 18.03.2018.

vrijednosti. Odluka o identitetu se donosi na temelju vrijednosti koja je ukupna na nekom određenom području. Bazirano na neovisnim pretpostavkama Ostenburg je iskombinirao individualne mogućnosti sa vjerojatnim mogućnostima. Podosta je uključivao Galtona u svoj rad vezan uz ovu metodu. Slijedeća slika prikazuje piksele veličine 1 mm, 0.47 mm i 0.116 mm, koji se koriste za ovu metodu.



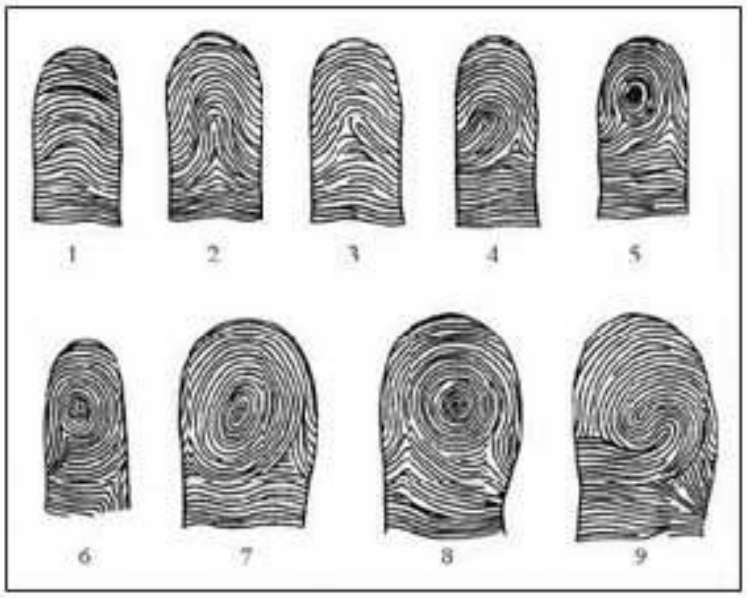
Slika 18: Primjer Osterburgove mreže (Jain, Halici, Hayashi, Lee, Tsutsui, Intelligent biometric techniques in fingerprint and face recognition, CRC Press, Boca Raton, London, New York, Washington, D.C., 2000.)

5. Sustavi za klasifikaciju otiska prsta

Identifikacija prsta, a pogotovo automatska vrlo je zahtjevan proces, a pogotovo za baze podataka koje su velike. Jedan otisak treba uspoređivati sa svima koji se nalaze u bazi. Tu je došlo do razvoja klasifikacije otiska prsta. Podjela otiska prsta u točno specificirane grupe omogućuje shemu indeksiranja koja je pogodna za identifikaciju otiska prstva u velikoj bazi. Što znači da ukoliko dvije slike predstavljaju isti prst one pripadaju istoj grupi te se onda otisak uspoređuje samo s tom grupom otisaka.

5.1. Ivan Evangelista Purkinije

Do klasifikacije dolazi 1823. godine. Te godine Purkinije objavljuje svoju prvu raspravu poznatu pod naslovom *„A Commentary on the Physiological Examination of the Organs of Vision an the Cutaneous System"*[22]. Opisao je klasifikaciju od devet grupa otisaka prstiju. U to je vrijeme to bila prva podjela otisaka prstiju. Iako je Purkinije prepoznao klasifikacijske mogućnosti papilarnih linije nije ih povezao sa klasifikacijskim sustavom za identifikaciju osoba.



Slika 19: Purkinjeova klasifikacija otisaka
(http://www.handresearch.com/diagnostics/fingerprints-classification.htm, 18.03.2018.)

[22] Commentatio de Examine Physiologico Organi Visus et Systematis Cutanei (izvorno) - http://www.handresearch.com/diagnostics/fingerprints-classification.htm, dostupno 18.03.2018.

5.2. Henry Faulds

Henry Faulsd je smislio i razvio sustav klasifikacije otiska prsta i predložio je korištenje otiska prsta kao metode u kriminalistci. Njegov sustav imao je pet slogova za svaki prst jedan slog. Svi slogovi su bili odvojeni crticom. Slogovi su mogli biti sastavljeni od ukupno dvadesetjednog suglasnika i šest samoglasnika, svaki od njih je predstavljao neku karaakteristiku. Fauldsov sustav može napraviti oko 17 trilijuna klasifikacija. Samoglasnici i suglasnici koje je osmislio su prikazani na slijedećoj slici.

Consonant	Pattern Description
CH	Hook with short leg facing right
J	Hook with short leg facing left
B	Convex bow with left lineation
P	Convex bow with right lineation
T	Pear-shaped, free-floating
D	Pear-shaped, fixed by stem
K	Spindle with one stem
G	Spindled with stems on both ends
W	Clockwise whorl
V	Counter-clockwise whorl
Q	Large circle/oval w/elements
M	Volcanic mountain peak
N	Flag-staff on mountain top
L	Loop with straight axis
R	Loop with curved axis
S	Sinuous with no angles
Z	Zigzag with angularity
X	Nondescript
F	Aspirate used strictly for pronunciation
H	Aspirate used strictly for pronunciation
Vowel	**Pattern Description**
A	Interior empty, simple
E	Three short ridges/dots
I	Simple detached line/no more than two lines in heart of encircling pattern
O	Small circle/oval/dot in core
U	Fork with 2+ prongs in core
Y	Fork with prongs turning away from concavity

Svaki od samoglasnika i suglasnika posjeduje svoj opis koji određuje npr. opis uzorka tako npr. samoglasnik E označava „tri kratke točke „three short dots“. Svaki taj opis je zapravo karakteristika otiska prsta. [23]

Slika 20: Faulds-ovi samoglasnici i suglasnici (https://www.ncjrs.gov/pdffiles1/nij/225325.pdf, 18.03.2018.)

[23] Systems of friction ridge classification, L.A. Hutchings https://www.ncjrs.gov/pdffiles1/nij/225325.pdf dostupno 18.03.2018.

5.3. Sir Francis Galton

Galton je postao veoma kritičan prema Bertillonage sustavi i upravo zato je otkrio da postoji velika mogužnost da se dogodi greška prilikom identifikacije. Nakon što je to otkrivo postao je veoma nezadovoljan i odlučio da će istražiti ovog puta otisak prsta kao jednu od metoda identifikacije i uz pomoć prethodno spomeutog Fauldsa (njegovih djela) i Herchelovih dokumenata godine 1982. izdao je knjigu. U knjizi je uz karakteristike jedinstevnosti i nepromjenjivosti prsta prikazao i svoj sustav klasifikacije otisaka. U njegovoj su klasifikaciji uzorci bili podjeljeni na već ranije spomenutu petlju, luk i spiralu.[24]

Svakom od deset uzoraka prstiju je pridružio jedno slovo ovisno o tome kojoj skupini pripada pa je tako:

- ✓ L – petlja
- ✓ W – spirala
- ✓ A – luk

Svaka osoba koja bi imala na prstima desne ruke imala petlju osim na malom prstu na kojem se nalazila spirala, i ako je na prstima ljeve ruke imala sve spriale osim na malom prstu na kojem je luk bio klasifikacija bi izgledala: LLLWWWLWWA. Poredak slova je ovisan o prstu o kojem se radilo. [25]

5.4. Vučetićev klasifikacijski sustav

Ivan Vučetić poznat i kao Juan Vucetich koji je bio policijski službenik u Argentini s Hrvatskim podrijetlom je uveo idenifikaciju osoba uz pomoć otiska prsta u kriminalistički sustav Argentine. Saznavši da Bertillonageov sustav nije dovoljno jak i siguran krenuo je u istraživanje drugih metoda. Tako je s vremenom razvio svoj sustav klasifikacije otiska prsta. Prvi naziv njegove klasifikacije bio je „Fineg track measurement“, a 1896. godine promijenio je naziv u „Finger descriptione“. Njegov je klasifikacijski sustav bio temeljn na Galtonovoj klasifikaciji. Sustav se temelji na tome da svaki od uzoraka koji se nalazi na palcu poprima

[24] Systems of friction ridge classification, L.A. Hutchings https://www.ncjrs.gov/pdffiles1/nij/225325.pdf dostupno 18.03.2018.
[25] Systems of friction ridge classification, L.A. Hutchings https://www.ncjrs.gov/pdffiles1/nij/225325.pdf dostupno 18.03.2018.

jedno od sljedećih slova – A, E, V, I. Koje slovo poprima ovisilo je o uzorku. Ostala četiri prsta poprimala su jedno od brojeva:

a) 1 – označava luk
b) 2 – označava unutarnju petlju
c) 3 – označava vanjsku petlju
d) 4 – označava spiralu

Vučerićeva klasifikacija se može podjeliti na svije vrste:

1. primarna klasifikacija
2. sekundarna klasifikacija

Kod primarne klasifikacije radi se o dvije skupine odnosno grupe jedna je brojnik, a druga je nazivnik. Brojnik ima još i naziv series i predstavlja uzorke otisaka prsta koji su na desnoj ruci. Nazivnik ima još i naziv section i predstavlja otiske prsta koji se nalaze na lijevoj ruci. [26]

[26] Systems of friction ridge classification, L.A. Hutchings https://www.ncjrs.gov/pdffiles1/nij/225325.pdf dostupno 18.03.2018.

6. Zaključak

Svjesni smo da se danas društvo vrlo brzo razvija i da svakim danom sve više raste. Koja je povezanost ove rečenice s ovom temom? Naime, svakodnevnim razvojem ljudskog društva razvijaju se nove tehnologije, ideje odnosno kompletni život. Daktiloskopija je znanost koja pomaže u otkrivanju počinitelja nekih kaznenih djela putem otiska prsta. Kako se tehnologija razvija razvijaju se novi načini krivotvorenja otisaka, ali se isto tako otkrivaju nove tehnologije za sprečavanje takvih kaznenih djela. Sama povijest daktiloskopije je vrlo opširna može se vidjeti kako su brojni znanestvenici sudjelovali u njezinom razvoju, i to svaki znanstvenik sa svojim sustavom. Svaki sustav ima sovje karaktersitike i nosi određenu vrijednost i važnost u području daktiloskopije.

Otisak prsta je nepromijenjiv osim u slučaju kada se desi unutarnja povreda, pa može doći do naprimjer nastanka ožiljka. Na svijetu ne postoje dvije osobe s istim otiskom prsta odnosno jednakim papilarnim linijama, pa čak ni jednojajčani blizanci nemaju iste papilarne linije. Nepromjnjivost, individualnost i klasifikacija su tri karakteristike otiska prsta koja su vrlo važne. One su uvjek postojane.

Literatura

Knjige:

[1] Divjak B, Lovrenčić A (2005) *Diskretna matematika s teorijom grafova* (udžbenik Sveučilišta u Zagrebu). Varaždin: TIVA-FOI.

[2] L.C.Jane, U.Halici, I.Hayashi, S.B.Lee, S. Tsutsui, Intelligent biometric techniques in fingerprint and face recognition, Boca Raton, London, New York, Washington, D.C., CRC press, 2000.

[3] Pavišić B, Modly D, Veić P, Kriminalistika 1, Zagreb, Golden marketing – Tehnička knjiga.

Znanstveni radovi:

[1] Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008.

[2] Graevenitz, G. v.: Introduction to Fingerprinttechnology, A&S International under "Sensing Fingerprints", Volume 53, Taipei, 2003.

[3] Podnar Ante, Papilarne linije, VNT Gospić, 2013. - https://hrcak.srce.hr/104885, dostupno 18.03.2018.

[4] Radmilović Želimir, Biometrijska identifikacija, kolovoz, 2008., stručni članak, https://hrcak.srce.hr/79284 dostupno 18.03.2018.

[5] Kolar-Gregorić, T., Kriminalistička identifikacija osoba, Krimarak 9, Zagreb, 2002., MUP-RH

Internet izvori:

[1] Daktiloskopija_MUP - http://www.forenzika.hr/964.aspx, dostupno 18.03.2018.

[2] Enciklopedija http://www.enciklopedija.hr/natuknica.aspx?id=7784 – dostupno 13.03.2018.

[3] Leksikografski zavod Miroslav Krleža - http://medicinski.lzmk.hr/daktiloskopija/, dostupno 18.03.2018.

[4] Proleksis http://proleksis.lzmk.hr/12336/ - dostupno 13.03.2018.

[5] The History of fingerprinst http://onin.com/fp/fphistory.html, dostupno 18.03.2018.

[6] Otisak prsta, Bača, Miroslav; Schatten, Markus; Kišasondi, Tonimir: Prstom otključaj vrata, ZAŠTITA, Časopis o zaštiti i sigurnosti osoba i imovine, broj 2, godina II, Zagreb, 2006. - http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, dostupno 18.03.2018.

[7] Hand Search http://www.handresearch.com/diagnostics/fingerprints-classification.htm, dostupno 18.03.2018.

[8] Systems of friction ridge classification, L.A. Hutchings - https://www.ncjrs.gov/pdffiles1/nij/225325.pdf, dostupno 18.03.2018.

Popis slika

Slika 1: Jagodica prsta s odgovarajućim otiskom prsta (http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, - dostupno 18.03.2018.) 6
Slika 2: Tri glavne vrste otiska prsta (http://www.enciklopedija.hr/Natuknica.aspx?ID=13709, 18.03.2018.) 10
Slika 3: Pet vrsta odnosno kategorija otiska prsta - lijeva na desno: lijevo petlja, spirala, šatorski luk, desna petlja i luk (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008) 10
Slika 4: Vrste minucija (www.anilaggrawal.com/ij/vol_002_no_001/papers/paper005.html, 18.03.2018.) 12
Slika 5: Minuciji završetak i račvanje papilarnih linija (Graevenitz - Introduction to Fingerprinttechnology, A&S International under "Sensing Fingerprints", Volume 53, Taipei, 2003:84/6) 12
Slika 6: Anatomska obilježja papilarnih linija (Kolar – Gregorić, T., Kriminalistička tehnika, Krimarak 3, MUP, Zagreb, 1996:31) 13
Slika 7: Čisti luk - otisak prsta (http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, dostupno 18.03.2018.) 14
Slika 8: Jeloviti luk - otisak prsta (http://arka.foi.hr/~mschatten/radovi/Fingerprint.pdf, dostupno 18.03.2018.) 14
Slika 9: Radijalna petlja (https://www.hayat.ba/vijest.php?id=102174, dostupno 18.03.2018.) 15
Slika 10: Ulnarna petlja (https://www.hayat.ba/vijest.php?id=102174, dostupno 18.03.2018.) 15
Slika 11: Kružni uzorak otiska prsta (https://www.express.hr/life/sto-vrhovi-vasih-prstiju-otkrivaju-o-vama-2916 dostupno 18.03.2018.) 16
Slika 12: Materjali od kojih se može izraditi krivotvoreni otisak prsta (http://biolab.csr.unibo.it/research.asp?organize=Activities&pathSubj=111, 18.03.2018.) 17
Slika 13: 3D prikaz fan filtera nižeg reda (lijevo) i višeg reda (desno) istih su kuteva, ali su različitog zaokreta (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008) 17
Slika 14: Lijevo je slika otiska prije unsharp maskinga, a desno je nakon unsharp maskinga (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008 18
Slika 15: Podjela otiska na 64 kvadratića (8x8) (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008) 19
Slika 16: Usporedba ROC krivulja (preostale krivulje su tu radi usporedbe samo) (Goran Borković, Miroslav Vrankić, Viktor Sučić, Usmjereni digitalni filtri za prepoznavanje otisaka prstiju, 2008) 20
Slika 17: Osbornova mreža (https://www.sciencedirect.com/science/article/pii/S2090536X16300181, 18.03.2018.) 21
Slika 18: Primjer Osterburgove mreže (Jain, Halici, Hayashi, Lee, Tsutsui, Intelligent biometric techniques in fingerprint and face recognition, CRC Press, Boca Raton, London, New York, Washington, D.C., 2000.) 22
Slika 19: Purkinjeova klasifikacija otisaka (http://www.handresearch.com/diagnostics/fingerprints-classification.htm, 18.03.2018.) 23
Slika 20: Faulds-ovi samoglasnici i suglasnici (https://www.ncjrs.gov/pdffiles1/nij/225325.pdf, 18.03.2018.) 24