Zasnivanje modela evaluacije biometrijskih karakteristika u XML-u

Buden, Nikola

Professional thesis / Završni specijalistički

2017

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:702160

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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
VARAŽDIN

Nikola Buden

ZAVRŠNI RAD

Varaždin, 2016.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Poslijediplomski specijalistički studij
UPRAVLJANJE SIGURNOŠĆU I REVIZIJOM INFORMACIJSKIH SUSTAVA

Nikola Buden

ZASNIVANJE MODELA EVALUACIJE BIOMETRIJSKIH KARAKTERISTIKA U XML-u

Završni rad

Varaždin, 2016.

PODATCI O ZAVRŠNOM RADU

I. Autor

Ime i prezime	*Nikola Buden*
Datum i mjesto rođenja	*01.11.1980.*
Naziv fakulteta i datum diplomiranja	*Fakultet organizacije i informatike, Varaždin 23.09.2005.*
Sadašnje zaposlenje	*solicon IT GmbH*

II. Završni rad

Naslov	*Zasnivanje modela evaluacije biometrijskih karakteristika u XML-u*
Broj stranica, slika, tablica	*117 stranica, 42 slike, 2 tablice*
Znanstveno područje, smjer i disciplina iz koje je postignut akademski stupanj	*Društvene i humanističke znanosti, polje Informacijske znanosti*
Mentor ili voditelj rada	*Prof.dr.sc. Miroslav Bača*
Fakultet na kojem je rad obranjen	*FOI, Varaždin*
Oznaka i redni broj rada	18

III. Ocjena i obrana

Datum prihvaćanja teme od Fakultetskog vijeća	*14.7.2009.* *Ur.broj: 41/06-spec.*
Datum predaje rada	*6.7.2016.*
Datum sjednice FV-a na kojoj je prihvaćena pozitivna ocjena rada	*19.12.2016.*
Sastav povjerenstva koje je rad ocijenilo	*Prof.dr.sc. Miroslav Bača, predsjednik* *Prof.dr.sc. Željko Hutinski, član* *Prof.dr.sc. Mirko Čubrilo, član*
Datum obrane rada	*24.2.2017.*
Sastav povjerenstva pred kojim je rad obranjen	*Prof.dr.sc. Miroslav Bača, predsjednik* *Prof.dr.sc. Željko Hutinski, član* *Prof.dr.sc. Mirko Čubrilo, član*
Datum promocije	

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Poslijediplomski specijalistički studij

UPRAVLJANJE SIGURNOŠĆU I REVIZIJOM INFORMACIJSKIH SUSTAVA

Redni broj: S-41/2006

NIKOLA BUDEN

ZASNIVANJE MODELA EVALUACIJE BIOMETRIJSKIH KARAKTERISTIKA U XML-u

Završni rad

Voditelj rada:

Prof. dr. sc. Miroslav Bača

Varaždin, 2016.

Mojoj obitelji

PREDGOVOR

Biometrija s tehnološkog aspekta gledano, predstavlja „mlado“ područje s velikim potencijalom istraživanja i napretka. Ubrzanim razvojem tehnologije postaje sve pristupačnija što omogućava širok spektar primjene. Tu dolazimo do problema odabira biometrijske karakteristike/sustava, pri čemu je nužna procjena samih biometrijskih sustava. Navedeno predstavlja veliku mogućnost dodatnih testiranja i istraživanja.

Tema „Zasnivanje modela evaluacije biometrijskih karakteristika u XML-u“ nastala je na ideji i prepoznatoj potrebi postojanja unificiranog modela procjene biometrijskih sustava kojim bi se lakše i jednostavnije proveo odabir. Time bi se uvidjele mogućnosti i potencijal svake pojedine biometrijske karakteristike, a u konačnici odabrao sustav koji je najbolji i najprihvatljiviji određenoj organizaciji s obzirom na njene specifičnosti i potrebe. Prema definiranom modelu, svaki proizvođač bi ih mogao opisati XML-om, te učiniti javno dostupnima kako bi zainteresirane strane bile u mogućnosti dohvatiti ih i usporediti s podatcima evaluacije drugih proizvođača. S tim ciljem kreirani su i standardizirani testovi, koji se provode od strane neprofitnih organizacija za standarde, a na kojima sudjeluju dobrovoljno sami proizvođači biometrijskih sustava.

Rad je u osnovi podijeljen na dva dijela. Prvi dio odnosi se na proučavanje tematike s ciljem pobližeg upoznavanja problematike, uz potrebu uvođenja i zasnivanja modela evaluacije biometrijskog sustava u XML-u. Drugi dio odnosi se na pregled postojećih standarda za evaluaciju biometrijskih sustava, te temeljem njihovih rezultata i kategorizacije, zasnivanje modela evaluacije biometrijskih sustava u XML-u.

Ponajprije bih htio zahvaliti svojem mentoru prof. dr. sc. Miroslavu Bači na potpori tijekom pisanja rada i ohrabrenju za njegov završetak, bez kojega ovaj rad sigurno nikada ne bi ni ugledao svijetlo dana.

Najveća zahvala mojoj obitelji, roditeljima Ljubici i Dragutinu na potpori i poticaju, kao i ženi Nataliji na svim lijepim trenucima, a ponajviše kćerima Dominiki i Doroteji, kojima je najviše i posvećen ovaj rad. Hvala vam djevojke, na sreći i osmjesima koje ste mi pružile te na vremenu u kojem sam vam uskratio zajedničko druženje i igru, kako bih pisao ovaj rad.

Nikola Buden

SADRŽAJ

PREDGOVOR I

SADRŽAJ III

Popis kratica V

Popis slika VII

Popis tablica i grafikona IX

1. UVOD 1

1.1. Ciljevi istraživanja i razrada problema 1

1.2. Opravdanost i motiv izbora teme 2

1.3. Metodika rada 2

1.4. Prikaz strukture rada po poglavljima 3

2. BIOMETRIJA 5

2.1. Povijest 6

2.2. Moderna perspektiva biometrije 10

2.3. Fizičke biometrijske karakteristike 14

2.3.1. Lice 14

2.3.2. Otisak prsta 16

2.3.3. Geometrija dlana 17

2.3.4. Šarenica 19

2.3.5. Mrežnica 20

2.3.6. Termogram lica i tijela 21

2.3.7. Uho 22

2.3.8. Miris 23

2.3.9. Deoksiribonukleinska kiselina (DNK) 24

2.4. Ponašajne biometrijske karakteristike 25

2.4.1. Potpis 25

2.4.2. Glas 26

2.4.3. Hod 27

3. EXTENSIBLE MARKUP LANGUAGE (XML) 28

3.1. Povijest 29

3.2. Svrha 31

3.3. Povezanost s ostalim tehnologijama 37

4. EVALUACIJA BIOMETRIJSKIH KARAKTERISTIKA 38

4.1. Povijest 39
4.2. Metode 40
4.3. Trendovi 45
5. MODELI EVALUACIJE BIOMETRIJSKIH KARAKTERISTIKA U XML-U 57
5.1. Model fizičkih biometrijskih karakteristika 67
5.1.1. Lice 67
5.1.2. Otisak prsta 71
5.1.3. Geometrija dlana 76
5.1.4. Šarenica 79
5.1.5. Mrežnica 82
5.1.6. Termogram lica i tijela 84
5.1.7. Uho 86
5.1.8. Miris 88
5.1.9. Deoksiribonukleinska kiselina (DNK) 90
5.2. Model ponašajnih biometrijskih karakteristika 93
5.2.1. Potpis 93
5.2.2. Glas 95
5.2.3. Hod 99
5.3. Unimodalni sustavi 102
5.4. Multimodalni sustavi 104
6. ZAKLJUČAK 109
POPIS LITERATURE 111
PRILOG 115

Popis kratica

XML – eXtensible Markup Language

DNK – Deoksiribonukleinska kiselina

FBI – Federal Bureau of Investigation

NIST – National Institute of Standards and Technology

CODIS – Combined DNA Index System

ISO – International Organization for Standardization

IEC – International Electrotechnical Commission

ICAO – International Civil Aviation Organization

US-VISIT – United States Visitor and Immigrant Status Indicator Technology

DOD – US Department of Defense

WTC – World Trade Center

RFID – Radio-frequency identification

PCA – Principal component analysis

LDA – Linear discriminant analysis

ICA – Independent Component Analysis

LFA – Local Feature Analysis

LED – Light-emitting diode

API – Application Programming Interfaces

SGML – Standard Generalized Markup Language

RSS – Rich Site Summary

SOAP – Simple Object Access Protocol

XHTML – Extensible Hypertext Markup Language

XMPP – Extensible Messaging and Presence Protocol

IETF – Internet Engineering Task Force

RFC – Request for Comments

SQL – Structured Query Language

HBSI – Human-biometric sensor interaction

IPBC – IP Business Congress

OOEPBS – Otvoreni Okvir Za Evaluaciju Pouzdanosti Biometrijskih Sustava

FTA – Failure to Acquire

FTE – Failure to enroll

FMR – False match rate

FNMR – False non-match rate

XCBF – XML Common Biometric Format

CBEFF – Common Biometric Exchange File Format

XER – Encoding Rules

XCMS – XML Cryptographic Message Syntax

BIR – Biometric Information Record

ANSI – American National Standards Institute

MAC – Message authentication code

HMAC – Hash message authentication code

FERET – FacE REcognition Technology Evaluation

DARPA – Defense Advanced Research Products Agency

FRVT – Face Recognition Vendor Tests

FpVTE – Fingerprint Vendor Technology Evaluation

FPIR – False positive identification rate

FNIR – False negative identification rate

RAM – Random-access memory

ICE – Iris Challenge Evaluation

FRR – False reject rate

FAR – False accept rate

CMR – Correct matching rate

*IMR – In*correct matching rate

NFSTC – National Forensic Science Technology Center

DET – Detection Error Tradeof

EER – Equal Error Rate

FAp – False Acceptance probability

FRp – False Rejection probability

SRE – Speaker Recognition Evaluation

MP – Miss Probability

FAP – False Alarm Probability

PCA – Principal Component Analysis

ICA – Independent Component Analysis

Popis slika

Slika 1. Počeci biometrije - Alphonse Bertillon 7
Slika 2. Google glass prepoznavanje uzorka lica 15
Slika 3. Papilarne linije 16
Slika 4. Uzorak otiska prsta 16
Slika 5. Uzorak otiska dlana 17
Slika 6. Usporedba dlana ruke, skeniranog uzorka i konačnog uzorka vena 18
Slika 7. Fujitsu PalmSecure čitač 18
Slika 8. Sken šarenice 19
Slika 9. Mrežnica 20
Slika 10. Termogram lica 21
Slika 11. Anatomija uha i mjerenje prema Iannarelli sustavu 22
Slika 12. Analiza mirisa 23
Slika 13. Deoksiribonukleinska kiselina 24
Slika 14. Uređaj za uzimanje uzorka potpisa 25
Slika 15. Prepoznavanje glasa 26
Slika 16. Analiza hoda 27
Slika 17. Tijek razvoja XML-a 29
Slika 18. Primjer strukture XML-a 35
Slika 19. Aspekti evaluacije biometrijskih sustava 42
Slika 20. Konceptualni HBSI model 45
Slika 21. HBSI evaluacijska metoda 48
Slika 22. HBSI model evaluacije na primjeru geometrije dlana ruke 50
Slika 23. Konceptualni model OOEPBS 52
Slika 24. Evaluacijski model OOEPBS 56
Slika 25. Primjer strukture XCBF-a 63
Slika 26. Model evaluacije biometrijskih karakteristika 64
Slika 27. Model evaluacije biometrijskih sustava prepoznavanja lica 69
Slika 28. Podatci klase A 71
Slika 29. Podatci klase B 71
Slika 30. Podatci klase C 72
Slika 31. Model evaluacije biometrijskih sustava otiska prsta 74
Slika 32. Model evaluacije biometrijskih sustava geometrije dlana 77

Slika 33. Primjer kutijastog dijagrama 79
Slika 34. Model evaluacije biometrijskih sustava šarenice 80
Slika 35. Model evaluacije biometrijskih sustava mrežnice 82
Slika 36. Model evaluacije biometrijskih sustava termograma lica i tijela 84
Slika 37. Model evaluacije biometrijskih sustava uha 86
Slika 38. Model evaluacije biometrijskih sustava mirisa 88
Slika 39. Model evaluacije biometrijskih sustava DNK analize 91
Slika 40. Model evaluacije biometrijskih sustava verifikacije potpisa 93
Slika 41. Model evaluacije biometrijskih sustava prepoznavanja glasa 96
Slika 42. Model evaluacije biometrijskih sustava prepoznavanja hoda 99

Popis tablica i grafikona

Tabela 1. Kronologija povijesnog razvoja biometrije..... 9
Tabela 2. Reference XML-a..... 34

1. UVOD

1.1. Ciljevi istraživanja i razrada problema

Prema postojećim istraživanjima koja su se bavila evaluacijom biometrijskih karakteristika, može se uvidjeti da su temeljena na evaluaciji pojedine biometrijske karakteristike. Tako postoji velik broj različitih modela evaluacije koji se primjerice bave samo evaluacijom uređaja zasnovanih na biometrijskoj karakteristici prsta. Oni se trude poboljšati tehnologiju i metode kako bi se postigla bolja učinkovitost uređaja za čitanje otiska prsta. Takva istraživanja obično izrađuju sami proizvođači uređaja, koji time žele predstaviti svoje prednosti spram konkurencije. Prema tome, može se zaključiti da postoji potreba evaluacije među biometrijskim karakteristikama kako bi se moglo ocijeniti koja je od njih najučinkovitija, odnosno najprimjerenija potrebama različitih organizacija.

Dakle, postoji potreba za jedinstvenim modelom koji bi mogao prihvatiti podatke evaluacije biometrijskih karakteristika. Budući da se svaka od biometrijskih karakteristika zasniva na različitim osnovama, cilj ovog rada je izrada jedinstvenog modela u Extensible Markup Language-u (XML) koji će moći prihvatiti podatke različitih biometrijskih karakteristika, na temelju kojih bi se izvršila evaluacija.

Iz navedenog može se izvesti slijedeća radna hipoteza:

Moguće je načiniti jedinstveni model evaluacije biometrijskih karakteristika u XML-u koji će omogućiti jednostavniji odabir najprikladnije zadanoj situaciji.

1.2. Opravdanost i motiv izbora teme

Očekivani *doprinos* ovog završnog rada trebao bi biti upoznavanje, informiranje i približavanje novim mogućnostima, upotrebljivih pri odabiru najbolje odnosno najprikladnije tehnologije zaštite i osiguranja sigurnosti informacijskih sustava. Obzirom da se radi o ulaganjima koje predstavljaju dodatne, katkada i poprilične financijske izdatke, tada bi interes odabira najprikladnije biometrijske tehnologije odnosno biometrijskog sustava, trebao biti još i veći. Doprinos rada bi trebao biti vidljiv i iz rezultata koji su nastali kao posljedica izrade modela evaluacije biometrijskih karakteristika u XML-u čime se postiže standardizacija same evaluacije, što je u cilju zajednica koje definiraju standarde i preporuke, kao i zajednica krajnjih korisnika.

1.3. Metodika rada

Na temelju problema, ciljeva i hipoteze istraživanja koja se želi dokazati, izabrane su metode koje čine metodiku istraživanja. Istraživanje se temelji na pragmatičnim stručnim pretpostavkama. Nastoji se razumjeti problem istraživanja, faktori odabira modela evaluacije i njihov utjecaj na uspješnost modela.

Podatci će se prikupljati analizom modela i proučavanjem postojećih standarda evaluacije, a tako prikupljeni podatci će se u fazi analize koristiti za izradu modela.

Metoda analize slučaja koristiti će se za proučavanje uzroka i posljedica u kojem se sustav nalazi. Pri izradi samog modela u XML-u, koji je zapravo opisnik podataka, koristit će se njegove mogućnosti strukturiranja, kako bi se stekla potpunija slika o prirodi problema istraživanja.

1.4. Prikaz strukture rada po poglavljima

Struktura rada povezana je s prethodno navedenim problemima. U prvom i uvodnom dijelu, opisuje se predmet i cilj istraživanja. Zatim je ukratko obrazložena razrada problema, navedene su metode koje su korištene u istraživanju, te je dana struktura rada.

Iz prirode opisa biometrijskih karakteristika pokušat će se kreirati model koji bi ih na odgovarajući način opisao i time poslužio za njihovu evaluaciju. Utvrđeni modeli će se opisati pomoću XML-a, te će se pokušati kreirati jedinstveni model evaluacije biometrijskih karakteristika. Na temelju opisa svake pojedine biometrijske karakteristike, doći će se do svih njihovih dobrih i loših strana koje proizlaze iz njihova opisa. Zadnja poglavlja daju nam odgovore na izgled i funkciju kao i učinkovitost kreiranog modela.

U uvodnom poglavlju dati će se opis problema i predmeta istraživanja. Zatim će se definirati ciljevi i svrha rada, te opisati metode koje će se koristiti tijekom istraživanja. Na kraju će biti opisana dosadašnja istraživanja na ovom području.

Poglavlje pod radnim naslovom Biometrija – biometrijske karakteristike daje uvod u biometriju kao znanost, uz to pruža i opise biometrijskih karakteristika koji će služiti kao polazna točka kreiranja modela evaluacije. Ovdje će se formirati dvije skupine biometrijskih karakteristika, fizičke i ponašajne, odnosno bihevioralne. Odredit će se njihova osnovna grupacija kao i konkretan opis pojedinačno svake od biometrijskih karakteristika.

Radni naslov trećeg poglavlja je Extensible markup language (XML), a u njemu ćemo se upoznati s alatom, zapravo programskim jezikom koji će poslužiti za opis, odnosno prikaz modela evaluacije biometrijskih karakteristika. U ovom poglavlju će se navesti razlozi odabira XML-a kao tehnologije opisa podataka modela evaluacije biometrijskih karakteristika i koje su njegove prednosti. Bit će naveden i velik broj mogućnosti povezivanja s ostalim tehnologijama koje ga mogu koristiti za čitanje podataka kao i njihovu razmjenu.

U četvrtom poglavlju će se razraditi evaluacija biometrijskih karakteristika, postojeće metode, kao i najbolja praksa. Ovo je prilično specifičan dio gdje se može uvidjeti da su se istraživanja usmjerila pojedinačno na biometrijske karakteristike, pa svaka zasebno ima svoj model evaluacije koji nije primjeren za evaluaciju ostalih biometrijskih karakteristika.

Peto poglavlje, Modeli evaluacije biometrijskih karakteristika u XML-u daje sintezu ranijih poglavlja u kojem se objedinjuju potrebni opisi biometrijskih karakteristika XML-om da bi se došlo do modela evaluacije, kako za pojedine karakteristike, tako i za model koji će objediniti i opisati sve njih zajedno.

U šestom, zaključnom poglavlju napravit će se sinteza čitavog rada te dati opis ovog istraživanja. Na kraju će se prihvatiti ili odbaciti hipoteza ovog istraživanja.

2. BIOMETRIJA

Riječ biometrija dolazi od *starogrčkih riječi:* ***bios*** što znači *„život"* i ***metron*** što znači *"mjera"*. **Biometriju** možemo definirati kao znanost o automatiziranim postupcima za jedinstveno prepoznavanje ljudi na temelju jednog ili više urođenih tjelesnih obilježja, ili obilježja čovjekovog ponašanja [1]. Brzi razvoj tehnologije omogućio je pouzdanije načine identifikacije osoba.

Postoje dvije vrste biometrijskih karakteristika*[2]*:

- *Fizičke karakteristike:* geometrija lica, otisak prsta, geometrija dlana, šarenica, mrežnica, termogram lica i tijela, uho, miris, DNK, te uzorak vena.
- *Ponašajne karakteristike:* potpis, glas, dinamika tipkanja, hod.

Glavne prednosti biometrijskih metoda prepoznavanja su*[2]:*

- biometrijski parametri nas definiraju u svakom trenutku,
- biometrijski parametri se teško kopiraju i krivotvore,
- biometrijski parametri zahtijevaju fizičku prisutnost osobe koja se prepoznaje na mjestu identifikacije.

U samim počecima biometrijskih sustava, prednost je davana fizičkim karakteristikama naspram ponašajnih. Prevladavalo je mišljenje da fizičke značajke, u odnosu na ponašajne, posjeduju ″uočljivost″. Prema tome, prevladavalo je i uvjerenje kako su fizičke karakteristike pouzdanije od ponašajnih, jer one imaju tendenciju manjih razlika unutar grupa, nego što je to kod ponašajnih karakteristika. Danas postoji velik broj biometrijskih tehnika koje se uvelike koriste ili su gotovo pri kraju istraživanja i na početku same primjene.

2.1. Povijest

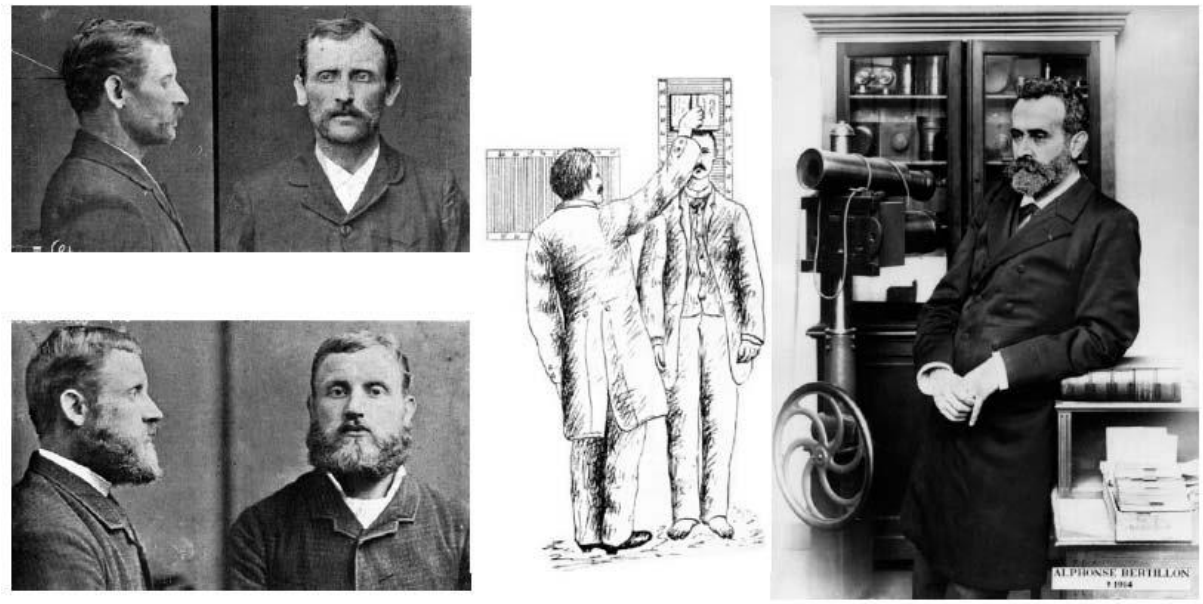
Od davnina ljudi koriste lice kao jednu od najstarijih i najosnovnijih karakteristika za prepoznavanje. Ta jednostavna radnja je postala kompliciranija povećanjem broja stanovništva i mobilnošću ljudi te na koncu i samom globalizacijom. Takav jednostavan koncept individualnoga prepoznavanja predstavlja i prepoznavanje glasa i hoda koje ljudi učestalo koriste, a oni spadaju u bihevioralne biometrijske karakteristike.

Kroz povijest čovječanstva korištene su razne karakteristike kao što su npr.[27]:

- U pećinama, kojima se starost procjenjuje na 30 000 godina, nalaze se crteži koji su okruženi otiscima dlanova za koje se pretpostavlja da predstavljaju ˝potpis˝ autora crteža.
- Postoje dokazi da se 500 godina p.n.e koristio otisak prsta na glinenim pločicama kao potvrda poslovnih transakcija.
- Španjolski istraživač i pisac, Joao de Barros je napisao da su stari Kinezi koristili otisak prsta kao potvrdu poslovnih transakcija, te da su roditelji koristili otisak prsta kao i otisak stopala za prepoznavanje male djece.
- Stari Egipćani su kod zaključivanja poslovnih transakcija koristili fizičke opise trgovaca za lakše raspoznavanje i vezanje trgovaca uz pojedine poslove.

S druge strane, na zapadu se identifikacija dugo zasnivala uglavnom na “fotografskom pamćenju”, odnosno crtežima lica i opisnim karakteristikama

pojedinca, kao npr. na tjeralicama koje se i dan danas koristile prilikom potrage za kriminalcima. Francuski policijski službenik i antropolog Alphonse Bertillon (Slika 1.) je 1883. godine razvio antropometrijski sustav kasnije prozvan “Bertillonage”. To je bio prvi precizan, znanstveni sustav koji je našao široku primjenu u identifikaciji osoba. Bertillon je razvojem spomenutog sustava zaslužan što je biometrija postala grana znanosti. Sustav se bazirao na preciznom mjerenju širina i dužina glave i tijela, te bilježenju osobnih oznaka kao što su tetovaže ili ožiljci. Bertillonov sustav je bio odlično prihvaćen na zapadu sve do otkrivanja njegovih mana koje su se uglavnom očitovale u problemima s različitim postupcima mjerenja i promjenjivim mjerama. Tek nakon tih spoznaja, na zapadu se krenulo s primjenom postupaka koji koriste otiske prstiju, s time da su se oni u Kini koristili već stotinama godina.



Slika 1. Počeci biometrije - Alphonse Bertillon [27]

Prvi pravi sustav klasifikacije otisaka prstiju, po uzoru na Bertillonov sustav, razvio je krajem 1800-te Azizul Haque za Edwarda Henrya, glavnog policijskog inspektora u Bengalu, Indiji. Taj sustav, Henryjev sustav, kao i njegove varijacije koristi se i danas kod klasifikacije otisaka prstiju [4]. Biometrija je doživjela značajan

razvoj i procvat pojavom računala sredinom prošlog stoljeća. Posebno u 90-tim godinama prošlog, te početkom ovog stoljeća.

Kronologija razvoja biometrije može se vidjeti u „Tabeli 1."

Godina	Opis
1858.	Zapis o prvom sustavnom prikupljanja slika ruku u svrhu identifikacije
1870.	Bertillon razvija antropometrijski sustav identificiranja
1892.	Galton razvija sustav klasificiranja otisaka prstiju
1894.	Izdana je knjiga *The Tragedy of Pudd'nhead Wilson*
1896.	Razvijen Henryjev sustav klasifikacije otisaka prstiju
1903.	Zatvori New York-a počinju s korištenjem otisaka prstiju
	Bertillonov sustav se napušta zbog nedostataka
1936.	Predložen koncept korištenja rožnice oka za identifikaciju
1960.	Postupak prepoznavanja lica postaje polu-automatiziran
	Kreiran prvi model prepoznavanja govora
1963.	Hughes Research Laboratories objavljuje rad o automatizaciji otiska prsta
1965.	Započinje istraživanje automatskog prepoznavanja potpisa
1969.	FBI ulaže napore u automatizaciju procesa prepoznavanja otiska prsta
1970.	Razvijen model prepoznavanja ponašajnih komponenti govora
1974.	Pojavljuje se prvi komercijalni sustav prepoznavanja geometrije dlana
1975.	FBI pokreće istraživanje tehnologije senzora
1976.	Razvijen prvi prototip sustava za prepoznavanje govora
1977.	Nagrađen patent za prikupljanje dinamičkih informacija potpisa
1980.	Oformljena „NIST Speech" grupa
1985.	Predstavljen koncept jedinstvenosti rožnica
	Nagrađen patent prepoznavanja geometrije dlana
1986.	Objavljen standard razmjene podataka otiska prsta
1987.	Nagrađen patent za prepoznavanje osoba pomoću rožnice
1988.	Razvijen prvi poluautomatski sustav prepoznavanja geometrije lica
	Razvijena Eigenface tehnika za prepoznavanje geometrije lica
1991.	Razvijen sustav prepoznavanja geometrije lica u realnom vremenu
1992.	Uspostavljena Biometrijska udruga u Vladi SAD-a
1993.	Počeo razvoj prototipa jedinice za prepoznavanje šarenice oka
1994.	Patentiran prvi algoritam prepoznavanja šarenice oka
	Održano natjecanje integriranih automatskih sustava za prepoznavanje otiska prsta
1995.	Prototip sustava prepoznavanja šarenice oka postaje dostupan kao komercijalni proizvod
1996.	Sustav prepoznavanja geometrije dlana je korišten na Olimpijskim igrama
1998.	FBI pokreće CODIS (DNK forenzičku bazu podataka)
1999.	Pokrenuto istraživanje o kompatibilnosti biometrije i strojno čitljivih putnih dokumenata

2000.	Održan prvi test sustava prepoznavanja lica
	West Virginia University pokreće studij biometrije
2001.	Sustav prepoznavanja lica korišten na Super Bowl-u u Tampi, Florida
2002.	Organizacija ISO/IEC uspostavlja pododbor za biometriju
	Formiran je M1 Techical Committee za biometriju
2003.	Službeno započinje s radom koordinacija američke vlade za biometrijske aktivnosti
	ICAO prilagođava shematski plan kako bi se biometrija mogla integrirati u putničke dokumente čitljive računalima
	Osnovan europski biometrijski forum
2004.	US-VISIT program započeo s radom
	DOD implementira ABIS
	Pokreće se Face Recognition Grand Challenge
2005.	Ističe patent SAD-a na koncept prepoznavanja rožnice oka
	Na konferenciji konzorcija biometrije najavljen je „Iris on the Move™“
2008.	Vlada SAD-a započela koordinaciju korištenja biometrijskih baza podataka
2010.	SAD Služba za nacionalnu sigurnost koristi biometriju za identifikaciju terorista
2011.	Biometrijska identifikacija koristi se za identifikaciju tijela Osame bin Ladena
2013.	Apple ugrađuje skenere otiska prsta u svoje pametne telefone

Tabela 1. Kronologija povijesnog razvoja biometrije [27]

2.2. Moderna perspektiva biometrije

Biometrija je brzo rastuće i kontraverzno područje glede kojeg organizacije građanskih sloboda izražavaju zabrinutost zbog narušavanja privatnosti. Zakoni i propisi vezani uz biometriju su u povojima, a različiti biometrijski industrijski standardi su u procesu testiranja. Metoda prepoznavanja geometrije lica nije dostigla prevladavajuću otiska prstiju, ali s konstantnim tehnološkim napretkom, uz poticaj terorističkih prijetnji, neupitan je razvoj biometrijske znanosti i tehnologije.

Napad na World Trade Center (WTC) 11. rujna 2001. uvelike je promijenio pogled na biometriju. Kao prvo, taj događaj je drastično smanjio otpor koji su ljudi imali spram te tehnologije. Prije navedenog događaja biometrija je smatrana preinvazivnom, odnosno da previše zadire u privatnost pojedinca. Iznenađujuće, strah potaknut šokom, kreirao je atmosferu odobravanja učinkovitije tehnologije kojom se omogućava veća sigurnost. Nakon spomenutog napada, Amerikanci su s odobravanjem prihvatili biometrijsku tehnologiju u zračnim lukama i ostalim važnim točkama s ciljem sprečavanja terorističkih napada i hvatanja potencijalnih terorista[28].

Biometrijska identifikacija je dobila na važnosti, te je potpomognuta i samim zakonskim propisima u Sjedinjenim Američkim Državama. 2001. godine je donesen „The Patriot Act“ (Providing Appropriate Tools Required to Intercept and Obstruct Terrorism), a 2006. je doživio izmjene kojima je uspostavljen standard biometrijske identifikacije.

Kreiranje standarda i novih tehnologija rezultiralo je izravnim masovnim financijskim potporama od strane vlade SAD-a. Novinar Evan Ratliff iz Wired Inc. navodi da je 2005. godine uloženo 10 bilijuna dolara na razvoj biometrije, a u *United*

States Visitor and Immigration Status Indicator Technology (US-VISIT) također isti iznos [29].

U čemu je stvar? Novi prioriteti (koji su primarno posloženi i postavljeni pod sve većom globalnom terorističkom prijetnjom) i novac koji je iz istog razloga dostupniji za biometrijska istraživanja, ubrzali su razvoj novih tehnologija. SAD je već uveo novu tehnologiju skeniranja svih deset prstiju ruke posjetitelja koji ulaze na njihov teritorij, za razliku od ranijeg uzimanja otisaka samo dva prsta (sastavni dio US-VISIT sustava). State Department već izdaje elektroničke putovnice („ePassports“) koje na Radio-frequency identification (RFID) čipovima pohranjuju i nose biometrijske podatke. U Hrvatskoj se također izdaju biometrijske putovnice i to od 29. lipnja 2009. godine.

S druge strane, nisu baš svi uvjereni da će nas biometrijska identifikacija učiniti još sigurnijima. Neki čak smatraju da nam predstavlja svojevrsnu prijetnju. Na primjer, postoji zabrinutost glede sigurnosti čipova na novim e-putovnicama, odnosno postavlja se pitanje da li mogu biti hakirani od strane kriminalaca. Barry Steinhardt, direktor projekta tehnologije i sloboda na American Civil Liberties Union, izjavio je 2006. godine da navedene putovnice omogućavaju teroristima „one-stop shopping“ za otmice američkih građana s ciljem korištenja biometrijskih podataka za svoje terorističke aktivnosti. S druge strane, Ann Barrett, koja je u to vrijeme obnašala dužnost Deputy Assistant Secretary of State for Passport Services, izjavila je da nova putovnica predstavlja najsigurniju putovnicu ikada izdanu od strane SAD-a, te da posjeduje „novu generaciju“ sigurnosnih značajki [28].

Pošto se i dalje lome koplja glede etičnosti identifikacije pomoću biometrijskih karakteristika, navest ćemo njezine prednosti i nedostatke:

Prednosti

- biometrijski sustavi identifikacije mogu pomoći pri identifikaciji osumnjičenika za kriminal/terorizam
- znanstveni podatci mogu uvelike smanjiti pristrano ljudsko promatranje/prosuđivanje (rasno i etničko etiketiranje)
- biometrijska identifikacija može povećati privatnost, jer pomaže u zaštiti osobnih informacija
- enorman izdatak za tehnološka istraživanja koji se odvija u privatnom sektoru može doprinijeti razvoju mnogih polja i van sigurnosti, pošto se primjena biometrijske identifikacije koristi i u medicinske svrhe, te u svrhu bihevioralnih znanosti i psihologije.

Nedostaci

- velika preciznost biometrijskih „čitanja“ može navesti na pogrešan zaključak da ljudska prosudba nije bitna. Dobro je oslanjati se na tehnologiju, ali ne treba podcijeniti ljudsku prosudbu temeljenu na iskustvu
- biometrijska identifikacija nije 100% pouzdana te se moraju uzeti u obzir i kvarovi, odnosno greške uređaja
- objektivnost biometrijske identifikacije ovisi o političkim namjerama koje stoje iza nje
- biometrijski uređaji krše privatnost – može se reći da vlada nema pravo na informacije o našem tijelu, a kada ih uzme, te informacije se mogu zloupotrijebiti.

Usprkos vječitoj borbi „za i protiv“, budućnost biometrijskih tehnologija se očituje u naglom tehnološkom razvoju potpomognutim globalnom terorističkom prijetnjom u kojoj se svijet nalazi. U današnje vrijeme, biometrija je zauzela značajnu ulogu kod sustava fizičke sigurnosti, te postoji velik broj biometrijskih uređaja namijenjenih toj svrsi. Biometrija je područje koje se brzo i naglo razvija, a pošto cijena uređaja s vremenom pada, sve više će se primjenjivati u privredi (financijskim institucijama itd.).

Današnji proizvođači koriste razne tehnike za 3D rekonstrukciju ljudskog lica, npr. A4Vision Inc., koristi jedva primjetan snop infracrvenog svijetla kojim utvrđuje i izrađuje model lica "skenirane" osobe. S druge strane, tvrtka Geometrix kombinira dvije ili više kamera kako bi kreirala 3D model lica [30]. Obje tvrtke kod svojih rješenja koriste kamere visokih rezolucija kako bi postigle očekivane rezultate, pri čemu su oni ujedno i najbolji kada je osoba snimljena s udaljenosti od nekoliko metara. Iako loša slika može smanjiti učinkovitost navedenih metoda, ulažu se veliki napori u tehnologiju i standardizaciju kvalitete slike kao i poboljšanje kvalitete i veličine baze podataka biometrijskih matrica.

2.3. Fizičke biometrijske karakteristike

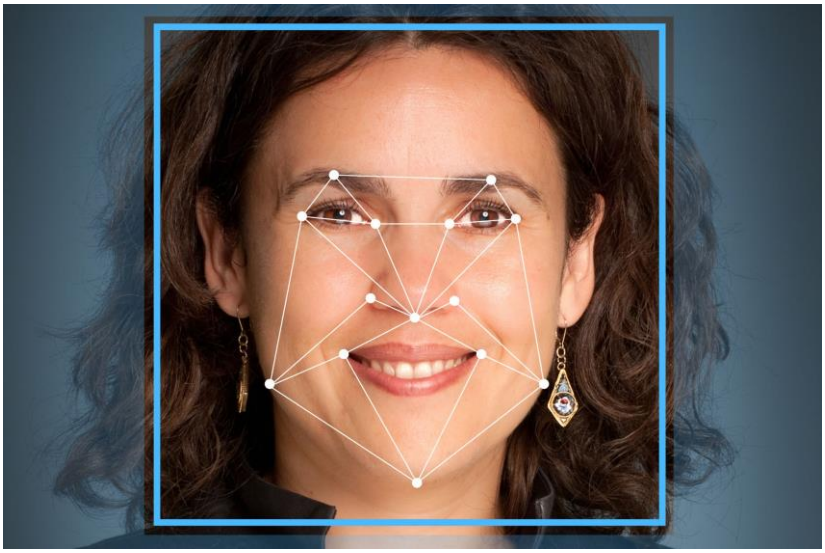
Fizičke biometrijske karakteristike su one koje se temelje na fizičkom izgledu ili osobinama pojedinca. Među njih svrstavamo[3] otisak prsta, rožnicu oka, geometriju lica, usana i uha, geometriju ruke, uzorak vena, termogram lica i tijela i naposljetku DNK. To su karakteristike koje smo naslijedili genetski i stekli ih rođenjem, te ih naravno ne možemo jednostavno i lako promijeniti.

Biometrijske karakteristike se koriste u širokom spektru tehnologija i aplikacija. Svaka biometrijska karakteristika ima svoje prednosti i nedostatke, tako da izbor ovisi o velikom broju faktora, naravno uz samu učinkovitost odnosno performanse sustava.

2.3.1. Lice

Spada u najuobičajeniju biometrijsku karakteristiku koja se koristi za osobnu identifikaciju od davnina. Prihvaćena je u društvu pošto nije nametljiva odnosno invazivna. Prate je intenzivna istraživanja s primjenom u širokom rasponu od statičke, kontrolirane verifikacije, pa sve do pokretne slike i nekontrolirane verifikacije s metežom u pozadini.

Identifikacija osoba prema njihovoj slici lica može se provesti na više načina, npr. dohvat slike lica u vidljivom spektru korištenjem kamere ili infracrvenih uzoraka termalne emisije lica. Neki sustavi za raspoznavanje lica zahtijevaju statičkog korisnika kako bi mogli dohvatiti sliku, iako sad već mnogi sustavi posjeduju mogućnost „uzimanja uzorka lica“ u pokretu i realnom vremenu.



Slika 2. Google glass prepoznavanje uzorka lica [59]

Prema zastupljenim shemama ekstrakcije za prezentaciju uzorka lica, raspoznavanje se može podijeliti u dvije kategorije: metode bazirane na značajkama, te metode bazirane na izgledu. Metode bazirane na značajkama kao kriterij za prepoznavanje lica koriste svojstva i geometrijske odnose kao što su područja, udaljenosti i kutovi između značajnih točaka lica. Metode bazirane na značajkama spremaju vektorske podatke kako bi prezentirale sliku lica. S druge strane, metode bazirane na izgledu u obzir uzimaju globalna svojstva slike lica. Najpopularniji algoritmi prepoznavanja lica su Principal component analysis(PCA), Linear discriminant analysis(LDA), Independent Component Analysis(ICA), Local Feature Analysis(LFA), korelacijski filtri, Manifolds, Tensorfaces itd.

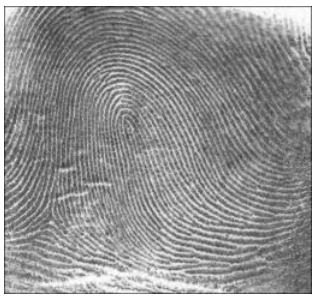
2.3.2. Otisak prsta

Otisak prsta ostavlja uzorak struktura brazdi(izbočina i udubljenja), odnosno takozvanih papilarnih linija na jagodici ljudskog prsta. Papilarne linije nisu svojstvene samo prstima, dakako mogu se pronaći na čitavom dlanu te na stopalima, zapravo može se reći na dijelovima ljudskog tijela koji nisu obrasli dlakom. Također, papilarne linije nisu svojstvene samo ljudima. Naime i neke životinje (točnije sisavci poput čovjekolikih majmuna) također na svojim rukama i nogama imaju papilarne linije [31].



Slika 3. Papilarne linije [60]

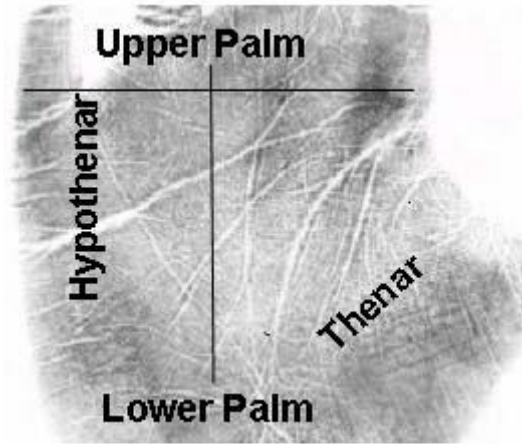
Otisak prsta je biometrijska karakteristika koja se pri identifikaciji koristi više od stoljeća. Zatvori u New York-u su ih počeli koristiti 1903. godine, a smatra se da su jedinstveni, teško se mijenjaju, te da su postojani tijekom ljudskog života, odnosno da ne postoje dvije osobe na svijetu koje bi imale isti otisak prsta. Iz navedenog proizlazi da se svakog čovjeka na svijetu može jedinstveno identificirati na temelju otiska njegovih prstiju.



Slika 4. Uzorak otiska prsta [60]

2.3.3. Geometrija dlana

Geometrija dlana je biometrijska karakteristika koja koristiti iste tehnologije koje su omogućile uzorku otiska prsta da postane najpoznatija i najkorištenija biometrijska karakteristika. Ona se zasniva na mjerenju geometrije, osnovnih linija, te papilarnih linija dlana. Razlika u odnosu na otisak prsta očituje se u tome što postoji veći spektar podataka kao što je tekstura, udubljenja i karakteristike koje se koriste prilikom usporedbe dva uzorka dlana.



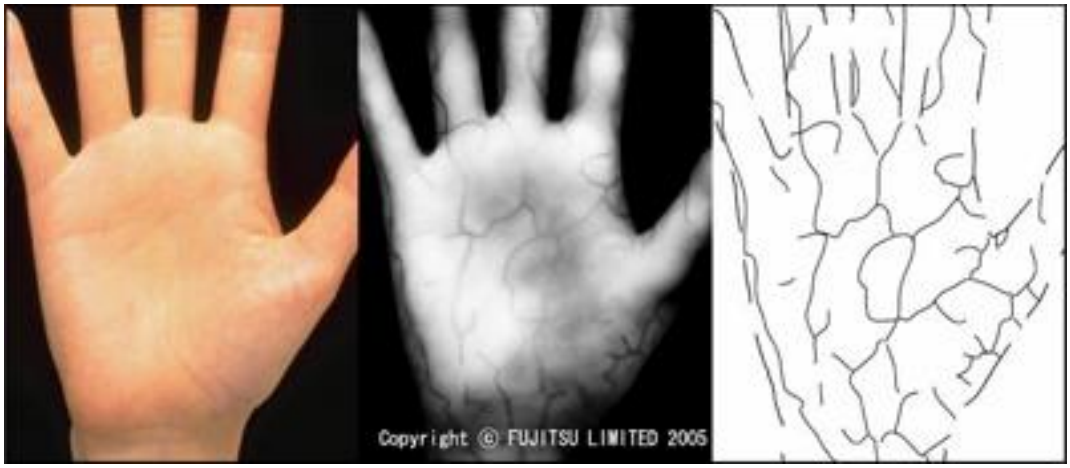
Slika 5. Uzorak otiska dlana [61]

Iz razloga što uzorak otiska prsta i uzorak otiska dlana odlikuje jedinstvenost i trajnost, koriste se kao pouzdani oblik identifikacije već više od stoljeća. Sama geometrija dlana sporije se razvijala i rjeđe koristila, pošto je bila pod restrikcijama uzrokovanim težom automatizacijom poradi restrikcija u računalnim mogućnostima te tehnologijama uzimanja uzorka dlana. Njeni početci korištenja sežu u 80-te godine prošlog stoljeća.

Također, postoji i tehnologija uzorka vena koju je osmislio Joseph Rice [32] 1985. godine. On je uspio izraditi prvi uređaj za čitanje uzorka vena koristeći light-emitting diode(LED), fotodiode i BBC-B računalo.

Postoje različite varijacije tehnologije uzoraka vena koje se često kombiniraju s ostalim biometrijskim tehnologijama kao što su npr. otisak prsta ili geometrija ruke.

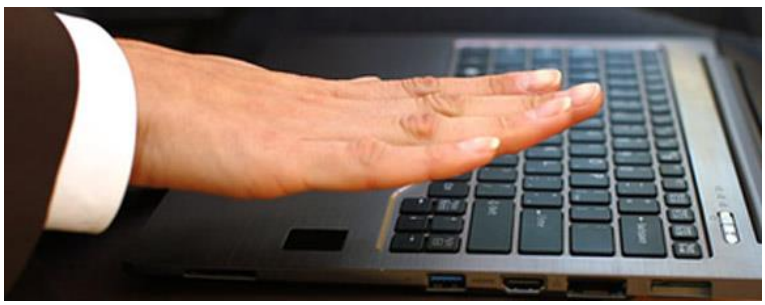
Od trenutka kada je ova tehnologija komercijalizirana 2004.-te godine, pojavilo se veliko zanimanje i širenje njenog tržišta.



Slika 6. Usporedba dlana ruke, skeniranog uzorka i konačnog uzorka vena [33]

Tehnologija uzorka vena je „novost“ na području biometrijskih tehnologija pošto je komercijalno predstavljena „tek“ 2004. godine u Japanu.

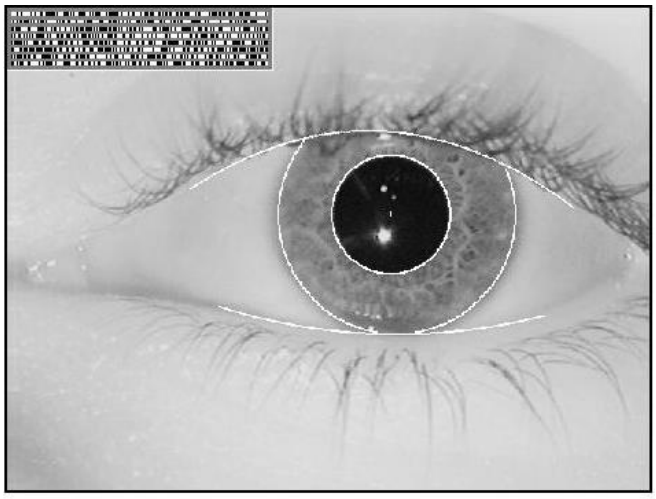
U Japanu i Južnoj Koreji se prilično raširila i prihvatljivija je od ostalih biometrijskih tehnologija zbog samog kulturološkog i mentalnog sklopa ljudi. Primarni razlog očituje se u tome što za korištenje ove tehnologije nije potreban fizički kontakt.



Slika 7. Fujitsu PalmSecure čitač [34]

2.3.4. Šarenica

Šarenica oka je obojeni dio oka koji okružuje zjenicu, a sastoji se od mreže radijalnih linija koja je jedinstvena, vremenski nepromjenjiva za svaku osobu i ne ovisi o genetskim parametrima. Zbog njenih jedinstvenih svojstava, šarenicu oka je izrazito teško krivotvoriti. Nakon smrti, brzo se raspada pa je zloupotreba tuđe šarenice gotovo nemoguća. Na šarenici je definirano dvjestotinjak obilježja pogodnih za identifikaciju. Ova identifikacijska tehnika vrlo je jednostavna i pouzdana, neinvazivna je iz razloga što nije potreban fizički kontakt osobe sa skenerom. Može se obaviti i snimanjem šarenice oka, običnom kamerom s udaljenosti i do pola metra [35].



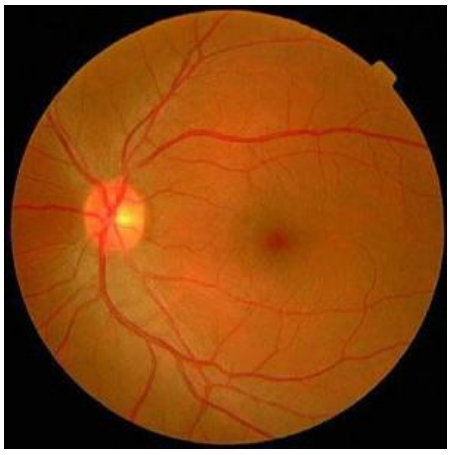
Slika 8. Sken šarenice [35]

Prepoznavanje osoba skeniranjem šarenice (irisologija) jedna je od najpouzdanijih biometrijskih metoda, ponajviše zbog prirodnih obilježja šarenice.

2.3.5. Mrežnica

Mrežnica je tanak sloj stanica, splet krvnih žila koji se nalazi u stražnjem dijelu oka. Njena struktura je individualna te predstavlja jedinstveno obilježje svake osobe. Riječ je o jednoj od najsigurnijih biometrijskih identifikacijskih obilježja, pošto nije moguće promijeniti ili replicirati unutarnju strukturu oka. Mrežnica se ne mijenja tijekom čovjekova života, a prilikom smrtnog slučaja, toliko brzo propada da nisu ni neophodne dodatne mjere za utvrđivanje smrti [36].

Skeniranje mrežnice izvodi se pomoću snopa niskoenergetske infracrvene svjetlosti kojom se obasja oko osobe s pogledom prema okularu skenera. Snop svjetlosti prati standardizirani uzorak na mrežnici. Krvne žile mrežnice apsorbiraju svjetlost puno jače od okolnog tkiva, pa količina refleksije varira tijekom skeniranja.



Slika 9. Mrežnica [61]

Ova metoda je invazivnija od skeniranja šarenice, pošto je potrebno približiti oko na okular skenera. Ujedno je i odbojna ljudima jer prilikom skeniranja u oko subjekta prodire laserska svijetlost što izaziva nelagodu. Negativnost se očituje i u tome što je uzorak mrežnice jako podložan promjenama kod nekih bolesti oka, pri čemu se uzorak može toliko izmijeniti da onemogućava proces prepoznavanja.

2.3.6. Termogram lica i tijela

Splet krvnih žila kojima je prožeto čovjekovo tijelo jedinstveno je obilježje svake osobe. Snimanje infracrvenom kamerom (mjerenjem razlika u temperaturi na površini kože) omogućava detekciju zračenja koje krvne žile emitiraju kroz kožu. Takvim se postupkom dobiva snimka, takozvani termogram, koji je jedinstven za svaku osobu. Identifikaciju je moguće obaviti pod različitim svjetlosnim uvjetima, čak i u mraku. Ova metoda omogućava prepoznavanje osobe bez njezine suradnje kao i prikupljanje uzorka s veće udaljenosti. Pripada skupini neinvazivnih metoda identifikacije [37].



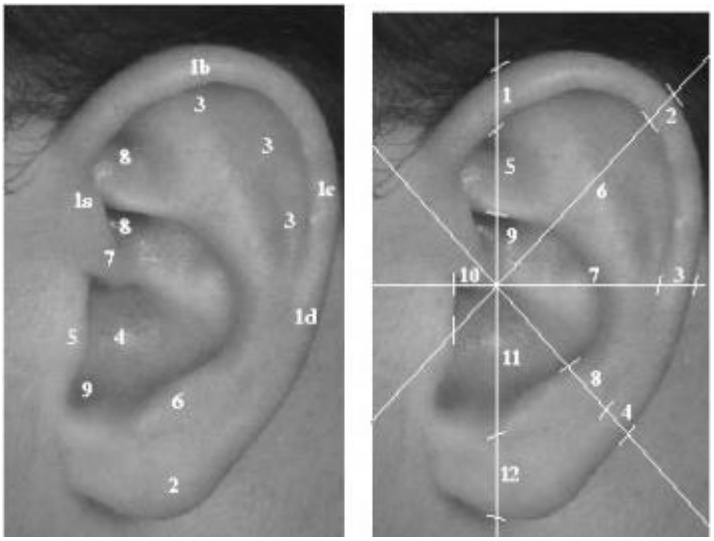
Slika 10. Termogram lica [61]

Jedinstvenost dobivenih uzoraka je velika te za razliku od metode prepoznavanja lica, slike se mogu prikupljati bez obzira na osvjetljenje okoline. Prednost je nenametljivost prema korisniku pošto od njega zahtjeva samo da uputi pogled prema kameri. Prepoznavanje je neovisno o dobi, izrazu lica i estetskim modifikacijama. Zbog visoke točnosti i brzine, metoda je pogodna za identifikaciju, ali u većoj komercijalizaciji sputava je skupoća potrebne opreme. Za termogram tijela vrijede ista pravila, ali ono je još u začecima istraživanja.

2.3.7. Uho

Oblik uha i struktura hrskavog tkiva na površini uha razlikuju se među osobama. Metoda je neinvazivna, ali potrebna su dodatna istraživanja kako bi se proglasila jedinstvenom osobinom. Iako postoji mnogo znanstvenih radova u kojima se ova karakteristika smatra vrlo obećavajućom, još uvijek ne postoji komercijalna tehnologija za nju. Prednost spram geometrije lica, očituje se u tome što su karakteristike uha postojanije i otpornije, npr. spram promjena na licu, kao što su različiti izrazi lica, starenje itd.

Prema jednom istraživanju provedenom u Kaliforniji na 10000 uzoraka, utvrđeno je da nisu pronađena dva uha istih svojstava. Druga studija je ispitivala strukturu uha blizanaca i utvrđeno je da iako su blizancima uha slična, s lakoćom su se mogle utvrditi razlike [38].



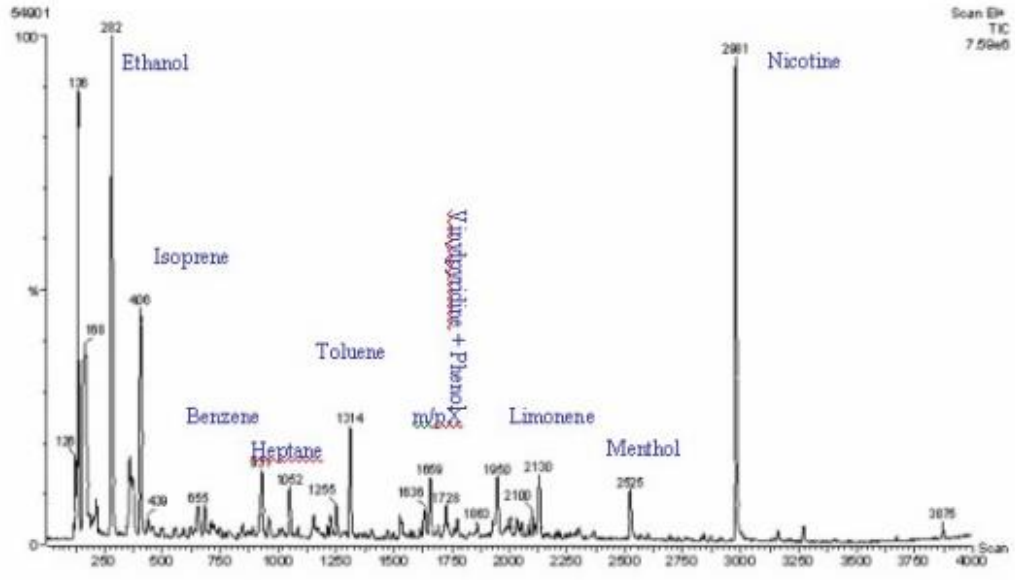
Slika 11. Anatomija uha i mjerenje prema Iannarelli sustavu [39]

Iannarelli sustav se sastoji u mjerenju dvanaest karakteristika uha, kao što se može vidjeti na slici [13].

2.3.8. Miris

Miris je skup izlučevina ljudskog tijela koji je individualan za svaku osobu. To je neinvazivna biometrijska karakteristika koja predstavlja vrlo značajno i perspektivno područje. Zahvaljujući činjenici da ljudsko tijelo u okolinu ispušta oko 300 različitih mirisnih sastojaka, moguće ih je registrirati i razlikovati. Time se otvaraju široke mogućnosti primjene mirisa u biometriji.

Kad je riječ o egzaktnijim metodama, pomoću spektrometra masa moguće je identificirati oko 130 specifičnih sastojaka tjelesnog mirisa. Prema dosadašnjim istraživanjima nepobitno je utvrđena individualnost i nepromjenljivost temeljnih karakteristika mirisa čovjeka. Ljudski miris predstavlja posebnu vrstu mikrotraga jer čovjek prilikom kretanja iza sebe u zraku ostavlja molekule mirisa koje se sastoje od individualnog mirisa osobe i raznovrsnih mirisa sredine u kojima boravi. Složenost takvog traga pridonosi njegovoj individualnosti [5].



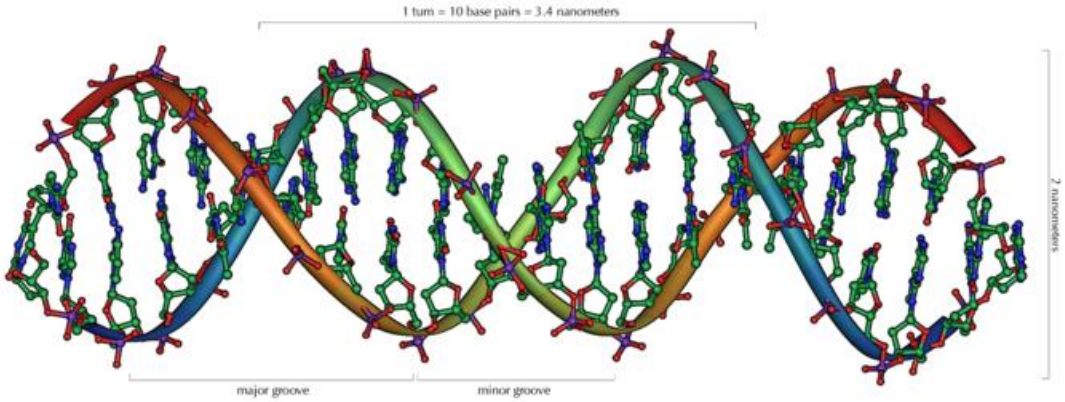
Slika 12. Analiza mirisa [5]

U današnje vrijeme intenzivno se radi na pronalaženju metoda prikladnih za prikupljanje i pohranu uzoraka, s ciljem stvaranja baze podataka mirisa.

2.3.9. Deoksiribonukleinska kiselina (DNK)

DNK je nukleinska kiselina u obliku dvostruke spiralne zavojnice. DNK sadrži genetske upute za specifični biološki razvoj staničnih oblika života i većine virusa. Dugačak je polimer nukleotida i kodira redoslijed aminokiselina u proteinima rabeći genetski kod, tj. trostruki kod nukleotida.

Osnovna je molekula nasljeđivanja čime je odgovorna za prenošenje nasljednog materijala i osobina. Kod ljudi te osobine se očituju u velikom rasponu npr. od boje kose do sklonosti prema nekim bolestima. Za vrijeme diobe stanice DNK se replicira i prenosi potomcima reprodukcijom, tako da je DNK svake osobe, naslijeđen od oba roditelja [40].



Slika 13. Deoksiribonukleinska kiselina [40]

Ova biometrijska karakteristika je vrlo je pouzdana, a spada u nenametljive tehnike. U forenzici se koristi DNK iz krvi, sjemena, kože, sline ili kose u procesu koji se naziva genetski otisak prsta u određivanju DNK profila. Metodu je razvio 1984. godine engleski genetičar Alec Jeffreys na Sveučilištu u Leicesteru za dokazivanje krivnje Colina Pitchforka 1988. godine pomoću računalne baze podataka. Navedena metoda je pomogla kod mnogih starih slučajeva u kojima je zločinac bio nepoznat, a s mjesta zločina je izuzet uzorak DNK.

2.4. Ponašajne biometrijske karakteristike

Ponašajne biometrijske karakteristike su one koje se temelje na bihevioralnim osobinama pojedinca. Ovdje spadaju potpis, glas i hod. To su karakteristike koje smo naučili, odnosno razvili kroz određeni vremenski period, te nas opisuju jedinstveno po specifičnim obilježjima.

2.4.1. Potpis

Potpis je jedan od najstarijih oblika identifikacije pošto svaka osoba ima jedinstven rukopis. On se kod svake osobe razvija i mijenja s vremenom, ali prevladava stav da je identifikacijska točnost ove karakteristike prihvatljiva. Predstavlja neinvazivan sustav identifikacije koji je univerzalan i vrlo jednostavan svim korisnicima pa ne postoji potreba za učenjem i obukom glede korištenja tehnologije. U elektronskoj uporabi potpisa kao biometrijske karakteristike uređaj može pratiti brzinu, pritisak, akceleraciju i ritam pisanja korisnika. To je i relativno pogodna tehnologija za uporabu u današnjem rastućem tržištu tablet računala [41].

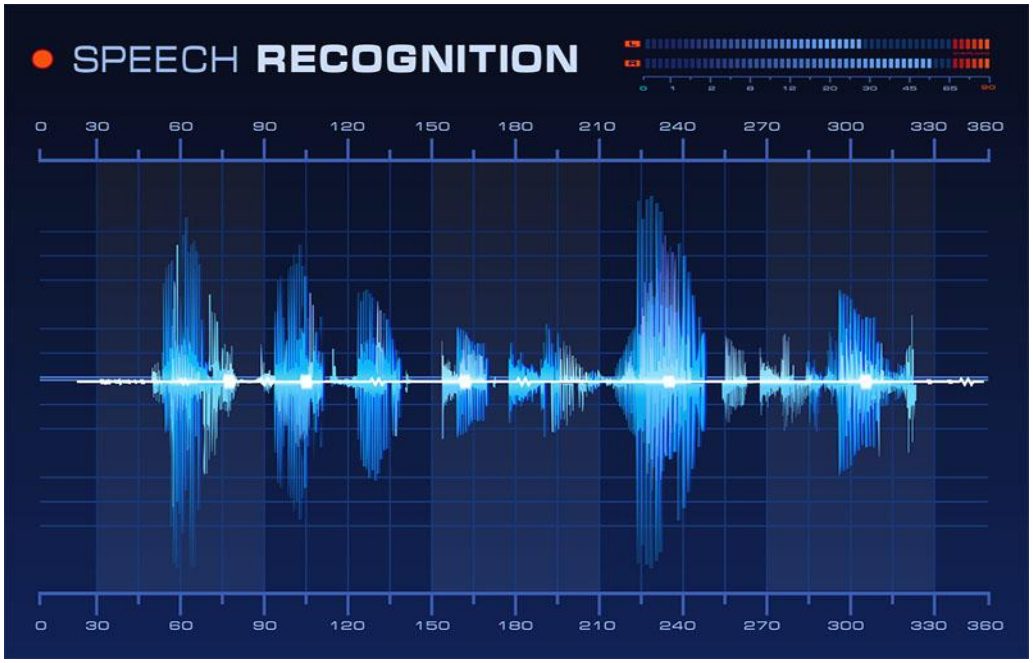


Slika 14. Uređaj za uzimanje uzorka potpisa [62]

2.4.2. Glas

Glas je prepoznat kao je autentifikacijska metoda iz razloga što je jedinstveno obilježje pojedinca, baš kao i otisak prsta ili šarenica oka. Karakteristike glasa svake osobe ovise o anatomiji glasnica, grla i usne šupljine, ali i o naučenim karakteristikama (tempu i stilu govora). Cilj autentifikacije glasom jest utvrditi tko je govornik uspoređujući pohranjeni uzorak s trenutnim, time da se sustav oslanja na karakteristike glasa, a ne na izgovor pojedinih riječi. Dakle, mjeri se velik raspon različitih obilježja kao što su dijalekt, stil i dinamika govora, spektralna magnituda i format frekvencije glasa [42].

Sustav je vrlo prihvatljiv i nenametljiv za korisnike, podložan je prijevarama, ali primjenom najnovijih tehnologija i algoritama taj se nedostatak sveo na minimum. Sustav je osjetljiv na buku u pozadini, a glas osobe može varirati ovisno o dobi i raspoloženju.

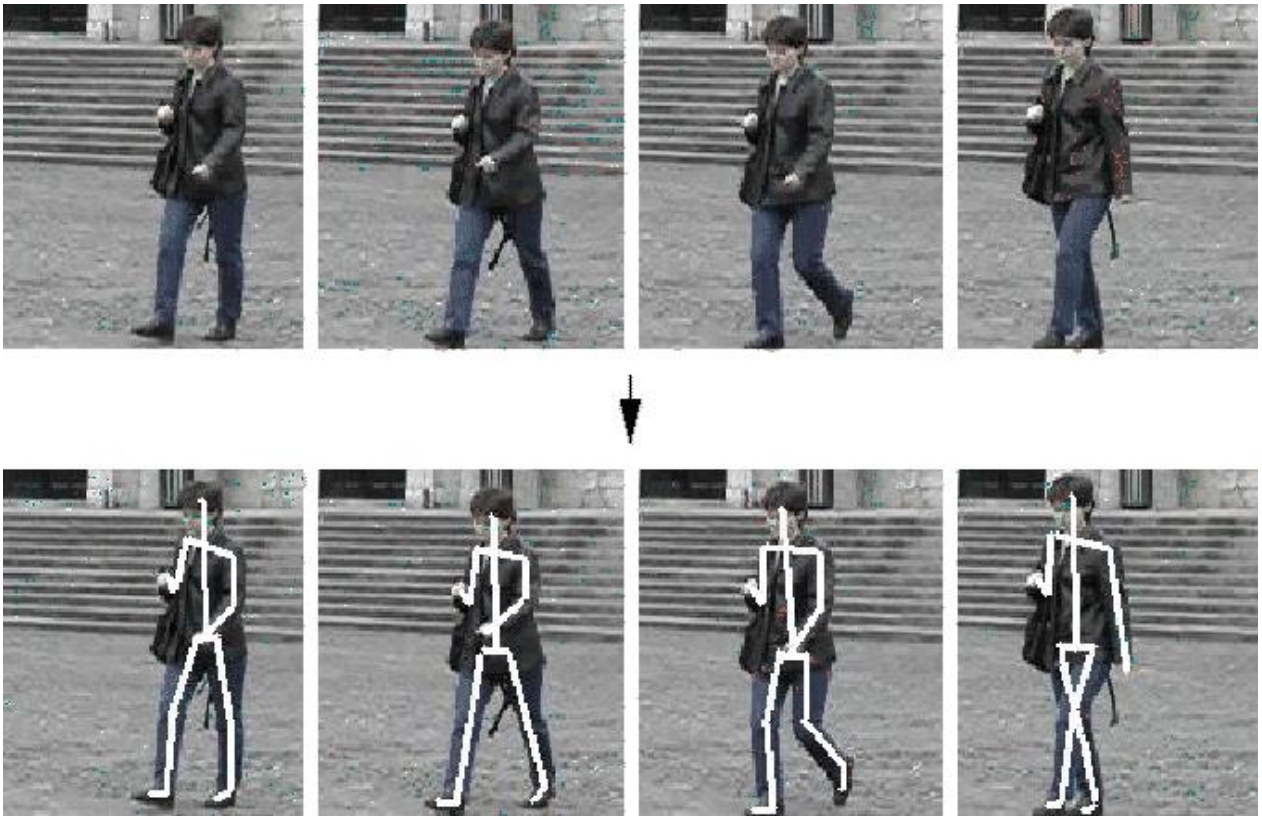


Slika 15. Prepoznavanje glasa [63]

2.4.3. Hod

Hod je složena tjelesna i prostorno-vremenska ponašajna biometrijska karakteristika koja nije jedinstvena za svakog pojedinca, ali je prihvatljivo karakteristična da se njome može izvršiti identifikacija. Pošto je uvjetovan brojnim tjelesnim karakteristikama, kao što su i glas i potpis, podložan je promjenama tokom vremena te uslijed ozljeda ili bolesti. Hod spada u nenametljivu biometrijsku karakteristiku [43].

Ova metoda slična je biometrijskoj metodi 3D fotogrametrijske antropologije po tome što se koristi analizom videozapisa, no razlika je u tome što se ne mjere precizne dimenzije određenih dijelova tijela, već se bilježe ponašajne karakteristike hoda kroz amplitude gibanja, međusobne pokrete, položaj zglobova i ostalih dijelova tijela.



Slika 16. Analiza hoda [64]

3. EXTENSIBLE MARKUP LANGUAGE (XML)

Extensible Markup Language (XML) je „opisni“ jezik koji definira skup pravila opisa podataka u formatu koji je i ljudski i računalno čitljiv. Definicija mu proizlazi iz W3C-ove XML 1.0 specifikacije [44] te još nekih povezanih specifikacija, koje sve zapravo predstavljaju besplatne otvorene standarde [45].

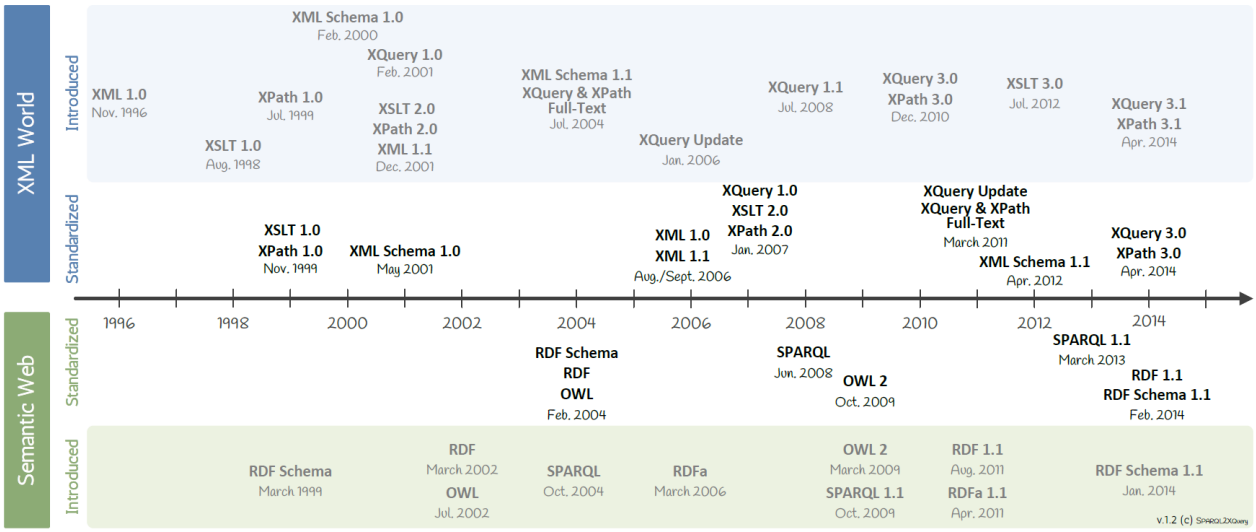
Dakle, XML služi za opis podataka, odnosno njihovu pohranu i razmjenu, te omogućava definiranje podataka u „čistom“ obliku, odnosno može se reći da je to „samoopisni jezik“ [7][9]. Kako bi mogli pravilno interpretirati podatke, obje strane, odnosno ona koja šalje i ona koja prima podatke, moraju koristiti XML.

Cilj XML-lova dizajna je jednostavnost, općenitost i laka upotrebljivost na Internetu [8]. To je tekstualni format podataka uz snažnu potporu Unicode standarda za različite ljudski čitljive jezike. Iako je dizajniran za rad s dokumentima, on se naširoko koristi za rad s proizvoljnim strukturama podataka, npr. poput onih što se koriste na web baziranim uslugama.

Postoji nekoliko sustava za definiranje jezika baziranih na XML-u, a razvijeno je i mnogo Application Programming Interfaces (API) pomoću kojih se procesiraju XML podatci.

3.1. Povijest

XML je zapravo primijenjeni Standard Generalized Markup Language(SGML) (ISO 8879) standard [10]. Svestranost SGML-a pri dinamičkom prikazu podataka bila je poznata digitalnim medijskim izdavačima kasnih 1980-ih prije samog uspona Interneta. Do sredine 1990-ih prepoznate su prednosti SGML-a te je on predstavljao rješenje za neke od problema koji su se počeli pojavljivati prilikom brzog rasta WWW-a. 1995. Godine, Dan Connolly je dodao SGML na popis aktivnosti World Wide Web Consortium-a (W3C), a s radom na standardu se započelo sredinom 1996. godine kada je Jon Bosak, inženjer Sun Microsystemsa razvio licencu i okupio tim koji je bio sastavljen od ljudi s dobrim poznavanjem SGML-a i web-a [46].



Slika 17. Tijek razvoja XML-a [47]

XML je kreirala radna skupina od jedanaest članova, uz potporu od otprilike 150 vanjskih članova. Tehnička rasprava vodila se preko elektroničke pošte, a problemi su rješavani konsenzusom. U slučaju kada se nije mogao postići dogovor oko neke teme, odlučivala je većina glasova radne skupine. Zapis o odlukama dizajna i njihovim obrazloženjima sastavio je Michael Sperberg-McQueen 4. prosinca

1997. Ime XML, osmislio je James Clark koji je ujedno bio i tehnički voditelj radne skupine, a definirao je i sintaksu „praznog“ elementa ("<empty />"). Kourednici specifikacije su Tim Bray i Michael Sperberg-McQueen.

Usred projekta, Tim Bray je prihvatio savjetnički angažman s Netscapeom, što je izazvalo negodovanje od strane Microsofta, pa je od Braya zatraženo privremeno povlačenje iz uredništva projekta. To je dovelo do intenzivnog sukoba u radnoj skupini koji je na kraju riješen imenovanjem Microsoftovog čovjeka Jeana Paolia kao trećeg kourednika. Radna skupina se nikada nije susrela uživo, a dizajn XML-a je nastao korištenjem kombinacije e-pošte i tjednih telekonferencijskih sastanaka. Osnovni dizajn je kreiran u kratkom razdoblju intenzivnog rada radne skupine između kolovoza i studenog 1996. godine, kada je objavljen prvi radni nacrt XML specifikacije. Daljnji rad na dizajnu je nastavljen kroz 1997. godinu, a XML 1.0 je 10. veljače 1998. godine postao preporučeni standard od strane W3C-a [48].

3.2. Svrha

Kao što je već ranije navedeno, primarni cilj i svrha razvoja XML-a je jednostavnost, općenitost i lak rad s podatcima. XML olakšava komunikaciju i prijenos podataka, te je odličan alat za razmjenu podataka. Njime možemo opisati i druge jezike, a jedan od dobrih primjera je WML (Wireless Markup Language) koji se koristi u WAP komunikaciji. WML je zapravo samo dijalekt XML-a.

Od 2009. godine razvijen je velik broj formata dokumenata pomoću XML sintakse, uključujući *Rich Site Summary*(RSS), Atom, Simple Object Access Protocol (SOAP) i Extensible Hypertext Markup Language(XHTML). Formati temeljeni na XML-u postali su primarni za mnoge uredske alate kao što su Microsoft Office (Office Open XML), OpenOffice.org i LibreOffice (OpenDocument), te Appleov iWord. XML je također prihvaćen kao osnovni jezik komunikacijskih protokola, npr. Extensible Messaging and Presence Protocol (XMPP). Aplikacije Microsoft .NET platforme koristite XML datoteke za konfiguraciju, a i Apple-ov registar je baziran na XML-u.

XML je postao standardan format za razmjenu podataka na Internetu. Internet Engineering Task Force(IETF) Request for Comments(RFC) 7303 [49] definira pravila konstrukcije tipova Internet medija prilikom razmjene podataka XML-om. Također definira aplikacijske i tekstualne tipove podataka, otkrivajući samo da su podatci opisani XML-om, ali ništa o njihovom značenju. Smjernice za daljnje korištenje XML-a se mogu pronaći u RFC 3470, poznatom i kao IETF BCP 70, a to je dokument koji pokriva mnoge aspekte dizajna jezika baziranih na XML standardu.

Prednost XML-a se očituje u tome što nije ograničen prilikom opisa podataka, već se može po potrebi proširiti novim varijablama. Navedeno omogućava nesmetan prijenos i prezentaciju opisanih podataka.

Sintaksa XML-a

Svaki XML dokument mora imati osnovni (root) element

Struktura jezika XML zasnovana je na strukturi stabla. Postoji osnovni (root) element koji se dalje grana na podelemente (child). Podelementi (child) se dalje mogu granati na podelemente druge razine (subchild).

```
<root>
  <child>
    <subchild>.....</subchild>
  </child>
</root>
```

XML Prolog

Prolog je opcionalan i uvijek se nalazi na početku XML dokumenta. U njemu navodimo verziju dokumenta i vrstu „kodiranja“ koja se koristi. U osnovi kodiranje je u UTF-8 formatu, isto kao i u jezicima HTML5, CSS-u, JavaScript-i, PHP-u, te Structured Query Language-u (SQL).

```
<?xml version="1.0" encoding="UTF-8"?>
```

Svi elementi XML-a moraju imati oznaku „zatvaranja“

```
<p>Ovo je paragraf.</p>
```

XML-a oznake su osjetljive na velika i mala slova

Oznake koje otvaraju programski kod (nalaze se na početku) moraju biti iste kao i oznake koje zatvaraju kod (nalaze se na kraju).

```
<Poruka>Ovo je netočno.</poruka>
```

Odnosno, pravilno je:

```
<poruka>ovo je točno.</poruka>
```

XML elementi moraju biti pravilno ugniježđeni

Kod slaganje elemenata, mora se poštivati njihovo pravilno ugnježđivanje, odnosno slijediti pravilo njihovih međusobnih odnosa – hijerarhije.

```
<b><i>Ovaj tekst je podebljan i italic.</i></b>
```

Na gornjem primjeru možemo vidjeti da ako je element <i> otvoren „unutar“ elementa <b>. U tom slučaju on mora biti i zatvoren unutar elementa <b>. Navedeni primjer nam prikazuje pravilno pisanje XML jezika, ali za lakše razumijevanje hijerarhije, možemo gornji „kod“ prikazati kao:

```
<b>
      <i>
            Ovaj tekst je podebljan i italic.
      </i>
</b>
```

Ili s druge strane, nepravilno „zatvaranje“ izgleda ovako:

```
<b><i>Ovaj tekst je podebljan i italic.</b></i>
```

Vrijednosti atributa u XML-u moraju se navesti pod navodnicima

XML elementi mogu imati atribute u imenima/vrijednostima, pa se atributi uvijek moraju stavljati pod navodnicima.

```
<zapis date="23.01.2016">
      <za>Hrvoje</za>
      <od>Ana</od>
</zapis>
```

Znakovi jednakosti i referenciranje entiteta

U XML-u ne mogu se koristiti znakovi jednakosti, pa se ne može staviti znak „<“ unutar entiteta jer takav programski kod vraća grešku.

```
<message> salary < 1000</message>
```

Postoji pet predefiniranih referenci:

<	<	manji od
>	>	veći od
&	&	veznik „i“
'	'	apostrof
"	“	navodnik

Tabela 2. Reference XML-a [47]

Dakle, pravilno pisanje gore navedenog primjera bilo bi:

```
<message>salary &lt; 1000</message>
```

Pisanje komentara u XML-u

Za pisanje komentara koriste se dva znaka „minus“ na početku i na kraju komentara, s time da na samom početku dolazi uskličnik, a unutar komentara nije dozvoljeno korištenje dvostrukog znaka „minus“:

```
<!-- Ovo je komentar -->
```

U XML-u znak „razmaka“ se čuva

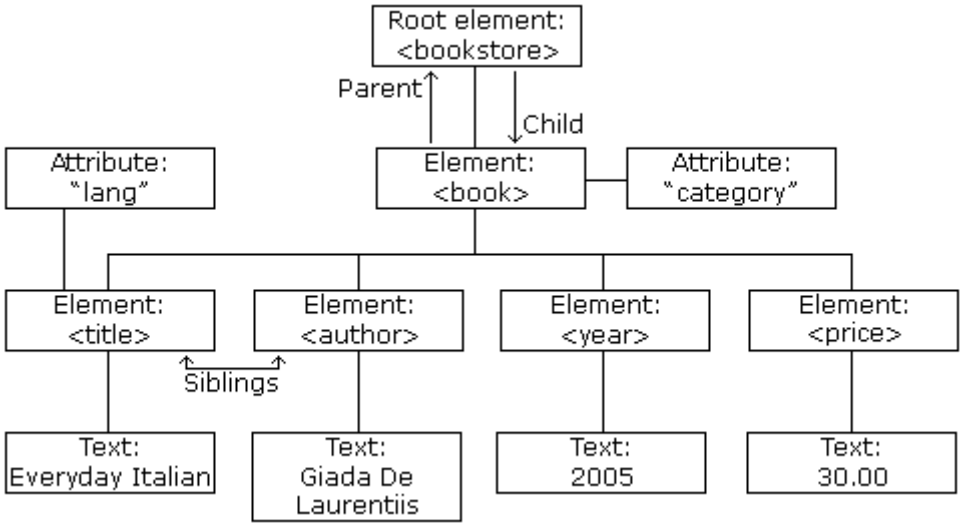
Unutar XML-a znak „razmaka“ se ne briše/gubi (za razliku od HTML-a, gdje se „višak“ razmaka automatikom briše).

XML: Hello Ana

HTML: Hello Ana

XML „tree“ struktura

Kao što je ranije navedeno, XML počiva na strogoj hijerarhiji i počinje osnovnim (root) elementom koji se nadalje grana.



Slika 18. Primjer strukture XML-a [48]

Navedeni primjer iz slike 18. se može opisati programskim kodom te se mogu dodavati novi zapisi poštujući strukturu i hijerarhiju XML jezika:

```
<?xml version="1.0" encoding="UTF-8"?>
<bookstore>
  <book category="cooking">
    <title lang="en">Everyday Italian</title>
    <author>Giada De Laurentiis</author>
    <year>2005</year>
    <price>30.00</price>
  </book>
  <book category="web">
    <title lang="en">Learning XML</title>
    <author>Erik T. Ray</author>
    <year>2003</year>
    <price>39.95</price>
  </book>
  <book category="children">
    <title lang="en">Harry Potter</title>
    <author>J K. Rowling</author>
    <year>2005</year>
    <price>29.99</price>
  </book>
</bookstore>
```

3.3. Povezanost s ostalim tehnologijama

Pošto je XML standard kojim se olakšava dijeljenje opisanih podataka, on zapravo predstavlja most koji može povezati različite tehnologije, odnosno omogućuje razmjenu podataka među različitim sustavima.

Značajke XML-a su:

- definira strukturu podataka
- razmjenu podataka čini neovisnu o tehnologiji/platformi
- podatci opisani XML-om mogu se automatizirano procesirati
- njime možemo definirati vlastite oznake.

XML nam pojednostavljuje:

- dijeljenje podataka
- prijenos podataka
- razmjenu podataka između različitih platformi
- dostupnost podataka.

S druge strane, XML ne može odrediti prikaz tih istih podataka, već su nam za to potrebne neke druge tehnologije. Tako na primjer, u velikom broju HTML aplikacija, XML služi za pohranu i razmjenu podataka, a sam HTML služi za formatiranje i prikaz tih istih podataka. Prednost se očituje u tome što se kod prikaza podataka HTML-om, ne treba mijenjati sam HTML programski kod u slučaju da se dogodi promjena nad samim podatcima.

4. EVALUACIJA BIOMETRIJSKIH KARAKTERISTIKA

Pojam evaluacija ili vrednovanje dolazi od latinske riječi *valere* što znači *biti zdrav, jak, sposoban*. Općenito, evaluacija označava opis, analizu, vrednovanje i ocjenu projekata, procesa i organizacijskih jedinica po utvrđenom kriteriju ili standardu. Ona može predstavljati konačnu ocjenu, ali i kontinuirani proces prilikom svih faza određenog projekta [27].

Općenito, evaluacija biometrijskih sustava predstavlja skup postupaka analize biometrijskih algoritama, komponenata, biometrijskih karakteristika ili cijelih aplikacija sa svrhom testiranja njihove sposobnosti da ispunjavaju svoju ulogu proizvodeći empirijski opipljive dokaze [11].

Kao što je spomenuto u ranijim poglavljima, nagli razvoj biometrijskih tehnologija i istraživanja biometrijskih karakteristika uvelike je potpomognut sveopćom situacijom u svijetu, koju prvenstveno predstavlja nesigurnost, terorističke prijetnje itd.. Također, navedeno je potaknuo i nagli razvoj tehnologije, posebno „pametnih telefona“ i popratnih gadgeta koji su doživjeli strelovit razvoj u zadnjem desetljeću. Prilikom tog naglog tehnološkog razvoja na vidjelo je isplivao problem očitog nedostatka standardizacije procjene kvalitete samih biometrijskih tehnologija/sustava. U razvoju je, kao i u samoj primjeni, velik broj različitih tehnoloških rješenja vezanih za raznolike biometrijske karakteristike, a na njihovu primjenjivost i prihvatljivost utječe velik spektar objektivnih i subjektivnih čimbenika. U tome se očituje potreba metodičkog pristupa evaluaciji biometrijskih karakteristika s ciljem postizanja ravnoteže između poslovnih potreba i mogućnosti samog sustava, a pri čemu je preduvjet objektivna/standardizirana procjena.

Standardizirana evaluacija predstavljala bi temelj za sam standard ocjene kvalitete biometrijskih karakteristika/sustava, odnosno objektivnu procjenu samih

karakteristika te njihovu poslovnu primjenjivost. Takvoj standardizaciji teže i organizacije koje objavljuju tehnološke standarde, kao npr. NIST.

4.1. Povijest

Sam razvoj metoda i evaluacija biometrijskih karakteristika uvijek se temeljila na pojedinačnim istraživanjima. Ona su bila striktno vezana za pojedinu biometrijsku karakteristiku koja je predstavljala predmet istraživanja, a dobiveni rezultati nisu se uspoređivali s podatcima drugih biometrijskih karakteristika, odnosno nije se toliko pridavala pažnja usporedbi s rezultatima drugih biometrijskih karakteristika. Proizvođači biometrijskih uređaja/sustava uvijek su bili fokusirani samo na biometrijsku karakteristiku za koju se razvijali tehnologiju, pa su i njihova istraživanja usmjerena samo na predmetnu biometrijsku karakteristiku. Oni svojim istraživanjima žele istaknuti prednosti biometrijske karakteristike i samih njihovih uređaja koji obrađuju pojedinu biometrijsku karakteristiku.

Slijedom toga, može se prikazati povijesni razvoj i istraživanje, odnosno evaluacija biometrijskih karakteristika, svake zasebno, s time da njihova međusobna usporedba i evaluacija nije još u potpunosti formalizirana, te predstavlja velik potencijal za znanstvena istraživanja.

4.2. Metode

S primarnog gledišta same evaluacije, postoje dvije osnovne metode koje predstavljaju temelj svih evaluacija, a to su kvantitativne i kvalitativne metode. Kvantitativna metoda se oslanja na egzaktne vrijednosti pomoću kojih želi prikazati podatke, a kvalitativna ne koristi egzaktne vrijednosti kod same procjene, već dobivene „okvirne vrijednosti“ na kraju kvantificira radi lakšeg prikaza, odnosno, interpretacije konačnih podataka.

Kvantitativne metode

Kvantitativne metode se zasnivaju na egzaktnim numeričkim vrijednostima, odnosno predstavljaju sustavno empirijsko istraživanje opažljivih fenomena pomoću statističkih, matematičkih ili računalnih tehnika koje dokumentiraju i odražavaju stvarno postojanje ili odsutnost problema, ponašanja ili pojava. Egzaktni podatci mogu se prikupljati na reprezentativnom uzorku s ciljem generalizacije ili poopćenja na cijelu populaciju odnosno skup. Kvantitativna metoda je obično objektivna i zahtijeva uporabu standardiziranih mjera, tako da se različite perspektive i iskustva mogu svrstati u ograničen broj unaprijed određenih kategorija. Ovu metodu je obično lakše sažeti i usporediti za razliku od kvalitativnih metoda.

Prednost kvantitativnih metoda očituje se u njihovoj jednostavnoj primjeni. One mogu sadržavati relativno velik broj pitanja, mogu prikupiti velike uzorke, lakše ih je sažeti, te su naširoko prihvaćene kao oblik dokaza o učinkovitosti pojedinog sustava.

S druge strane, nedostaci proizlaze iz činjenice da podatci ne mogu biti toliko iscrpni i opširni kao što je to slučaj kod kvalitativnih metoda. Upitnici koji se koriste prilikom istraživanja mogu biti teški i nerazumljivi pojedinim sudionicima iz razloga što su kreirani na način da su podatci strogo kategorizirani, te ne mogu pružiti sve

informacije koje su potrebne za specifičnu interpretaciju podataka. Velike količine podataka koje se pritom prikupe, mogu zahtijevati sofisticiranije pristupe analize.

Kvalitativne metode

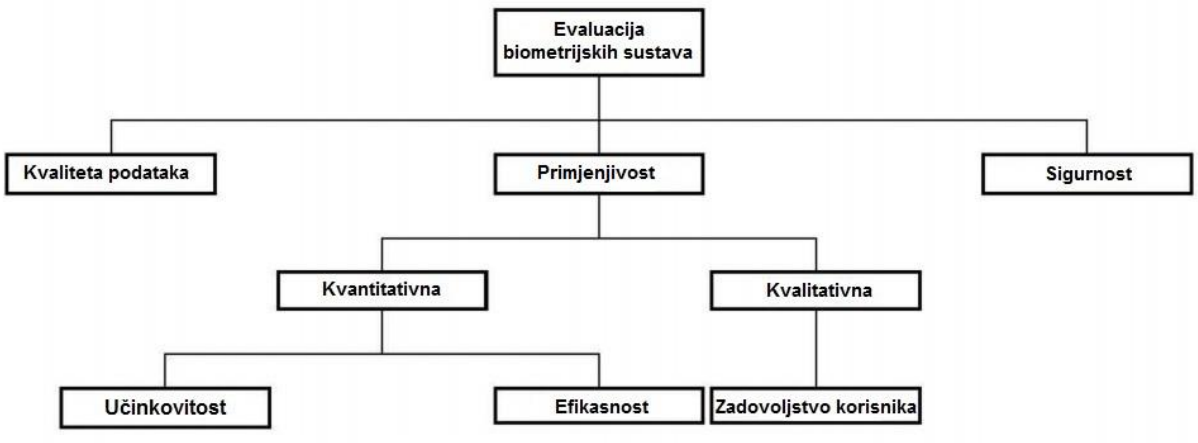
Kvalitativne metode zasnivaju se na podatcima koji rezultiraju opisima problema, ponašanja ili događaja, u njima se mogu izraziti opisi misli, te iznositi mišljenja o svojim iskustvima, stavovima i uvjerenjima. Ove metode kao rješenje nude modele koji ilustriraju samu prirodu promatranog problema. Primjena kvalitativnog pristupa zahtjeva iskustvo, stručnost te sposobnost ljudi koje provode istraživanje, jer pri kvalitativnoj metodi veliki utjecaj predstavlja subjektivnost pojedinca koji se bavi određenom problematikom.

Prednost kvalitativnih metoda očituje se u mogućnosti shvaćanja dubine kao i samog značenja, te mogućnosti pružanja uvida o tome "zašto" i "kako". One mogu pojasniti kvantitativne podatke, a ponekad omogućavaju i stavljanje rezultata istraživanja u sam kontekst života i iskustva ljudi. To čini kvantitativno prikupljene podatke razumljivim, daje im više detalja i nijansi, te objašnjava što istraživanje predstavlja za ljude koji u njemu participiraju.

Glavni nedostatak kvalitativne metode proizlazi iz činjenice da je potrebno mnogo vremena za prikupljanje i analizu podataka. Podatci prikupljeni ovom metodom su subjektivniji, pa mogu biti problematični, pošto ih je teško sažeti i sustavno usporediti. Općenito, na kvalitativne metode se gleda kao manje pouzdane, za razliku od kvantitativnih, jer kvalitativni podatci su pod utjecajem subjektivne procjene pojedinca, a u pravilu se odrađuju i na manjoj veličini uzorka. Osnovni problem ovog pristupa je subjektivnost pri procjeni prikupljenih podataka, što je ujedno i glavni uzrok nepouzdanosti. Pošto se kvalitativne veličine parametara procjenjuju subjektivno, kako bi se postigla ponovljivost, važno je osigurati da sam

način procjene može biti jednoznačno interpretiran i proveden s istim ili sličnim rezultatima od strane više kompetentnih osoba.

Postoje neka ograničenja biometrijskih sustava koja uvelike utječu na njihovu uspješnost, a to su ograničenja performansi, prihvatljivosti, te ograničenja arhitekture samih biometrijskih sustava. Prema tome, evaluacija biometrijskih sustava u osnovi počiva na kvaliteti podataka, primjenjivosti samog sustava i njegovoj sigurnosti, odnosno sigurnosti biometrijskih podataka [12]. Nadalje primjenjivost se dijeli na kvantitativnu i kvalitativnu. Kvantitativnu čine učinkovitost i efektivnost, a kvalitativnu zadovoljstvo korisnika.



Slika 19. Aspekti evaluacije biometrijskih sustava [12]

S druge strane, ako se orijentiramo primarno na evaluaciju samih biometrijskih karakteristika, može se zaključiti da postoje različiti pogledi, naravno u ovisnosti o opsegu same evaluacije te u kojem se kontekstu i s kojim ciljem ona odrađuje.

U osnovi, primjenu biometrijskih karakteristika možemo sagledati preko tri osnovna tipova evaluacije koji predstavljaju temelj procjene biometrijskog sustava za određenu namjenu [6]:

Evaluacija tehnologije

Evaluacija tehnologije je fokusirana na mjerenje performansi biometrijskih sustava s naglaskom na pojedine komponente sustava. Ocjenjivanje je ponovljivo i u pravilu kratkog trajanja, za razliku od druge dvije vrste evaluacije. Općenito, evaluacija tehnologije koristi se za identifikaciju specifičnih područja koja zahtijevaju buduća istraživanja te pruža podatke o izvedbi koji se koriste prilikom odabira algoritama za procjenu scenarija. Tehnički gledano, glavni cilj navedene evaluacije je usporedba algoritama pojedine tehnologije. Testiranje svih algoritama se obavlja na standardiziranoj bazi podataka koji se prikupljaju univerzalnim senzorom. Tako kreirana baza biometrijskih podataka uvelike ovisi o okolini i populaciji nad kojom su podatci prikupljeni. Prilikom razvoja, mogu se koristiti na taj način prikupljeni podatci, ali testiranje mora biti odrađeno na skupu podataka kojeg razvojni programeri algoritama nisu ranije vidjeli ili obrađivali. Testovi se provode uz upotrebu „offline“ obrade podataka, odnosno pošto je baza podataka „fiksna“, rezultati tehnoloških ispitivanja su ponovljivi.

Evaluacija scenarija

Svrha evaluacije scenarija sastoji se od mjerenja performansi biometrijskih sustava koji su u određenoj primjeni. Sustav koji se ispituje uključuje pribavljanje podataka pomoću senzora. Kao posljedica toga, rezultati ispitivanja nisu uvijek ponovljivi. Rezultati tipičnih evaluacija scenarija prokazuju područja koja zahtijevaju dodatnu sistemsku integraciju. Primarni cilj evaluacije scenarija je utvrđivanje performansi biometrijskih sustava u simulaciji korištenja sustava. Testiranje se

provodi na sustavu u okruženju koje predstavlja model „stvarnog svijeta“ ciljanog istraživanja.

Operativna evaluacija

Operativni evaluacija ili evaluacija primjene je slična evaluaciji scenarija, s razlikom što se testiranje obavlja u realnom okruženju s krajnjim korisnicima, dijelom korisnika ili na reprezentativnom uzorku korisnika. Njen primarni cilj je utvrđivanje utjecaja primjene biometrijskog sustava, odnosno utvrđivanje performansi cjelokupnog biometrijskog sustava u realnoj okolini i sa specifičnim uzorkom. U pravilu, operativna evaluacije nije ponovljiva.

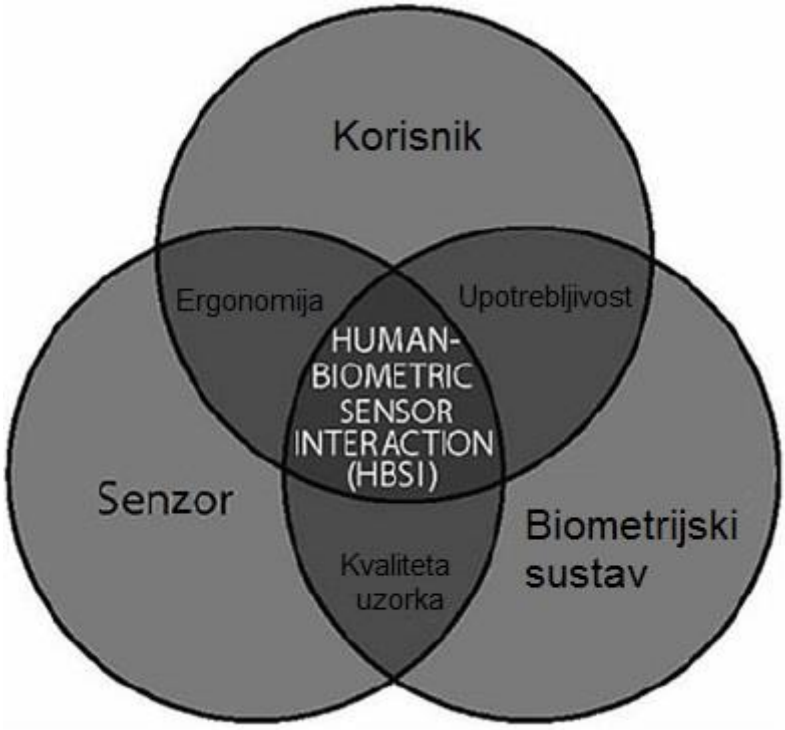
Idealan proces evaluacije sastoji se od vrednovanja tehnologije usporedbom svih primjenjivih tehnologija koje uvjerljivo mogu zadovoljiti tražene zahtjeve. Iako istraživači koristite dobivene podatke o performansama za identifikaciju područja na kojima se može postići dodatna poboljšanja, potencijalni korisnici dobivene rezultate koriste za određivanje najboljeg sustava svojih specifičnih potreba. Podatci o učinkovitosti, zajedno s podatcima o utjecaju, koji se prikupe naknadnim operativnim procjenama, pomažu donositeljima odluka pri odabiru najboljeg potencijalnog sustava.

4.3. Trendovi

Može se reći da se kod evaluacije biometrijskih karakteristika teži standardizaciji koja bi doprinijela lakšim i svrsishodnim odabirom biometrijskih sustava. U tom pogledu možemo istaknuti Human-biometric sensor interaction model evaluacije biometrijskih sustava, te H-B Interakcijski model.

HBSI model

S. Elliott i E. Kukula, znanstvenici sa sveučilišta Purdue (Indiana, SAD), su u razdoblju od 2006. do 2010. godine razvili Human-biometric sensor interaction model (HBSI). Spomenuti model bavi se proučavanjem utjecaja korisnika na performanse biometrijskih sustava. Metrički ih definira koristeći pretpostavke prethodno navedenih specifičnih modela evaluacije. Tri osnove na kojima počiva HBSI model su biometrijski sustav, korisnik i senzor [50].



Slika 20. Konceptualni HBSI model [50]

Kao što se iz prethodne slike može vidjeti, područja preklapanja Korisnika, Senzora i Biometrijskog sustava tvore okosnicu HBSI modela.

Preklapanje korisnika i senzora tvori ***Ergonomiju*** koja pruža podatke o prilagođenosti predmeta s kojima čovjek dolazi u kontakt. Ergonomija omogućava prilagodbu ili promjenu predmeta u najprikladnijoj kombinaciji za čovjeka. Idealna situacija bi bila kada bi dizajn nekog uređaja krenuo od čovjeka, ali najčešće se događa suprotno. Iz tog razloga važno je uočiti nužnost da dizajn bude oblikovan na osnovu podataka o konačnom korisniku. Ergonomija kao znanost daje principe dimenzija za oblikovanje predmeta s kojima korisnik dolazi u doticaj.

Upotrebljivost čine preklapanje područja Korisnik s područjem Biometrijski sustav. Ono se uvelike zasniva na pravilnom korištenju biometrijskog sustava, a u tom području, korisnik predstavlja najslabiju kariku. Stvar je u tome što postoje raznovrsni korisnici, pa je nužno da pri interakciji s korisnikom sustav bude što jednostavniji i što manje podložan nepravilnom korisničkom.

Kvaliteta uzorka predstavlja prostor koji tvore preklapanje područja Biometrijski sustav i Senzor. To znači da Kvaliteta uzorka uvelike ovisi o kvaliteti Senzora, kao i učinkovitosti biometrijskog sustava te njihovoj međusobnoj usklađenosti.

Naposljetku, može se vidjeti da na preklapanju *Ergonomije*, *Upotrebljivosti* i *Kvalitete uzorka* počiva sam HBSI model prema kojem je razvijena metoda evaluacije uzimajući u obzir faktore koji utječu na funkcioniranje biometrijskih sustava, te ih kategorizira u dvije primarne skupine:

1. Upotrebljivost
    a. Zadovoljstvo
        i. Nadzor
        ii. Povratna informacija

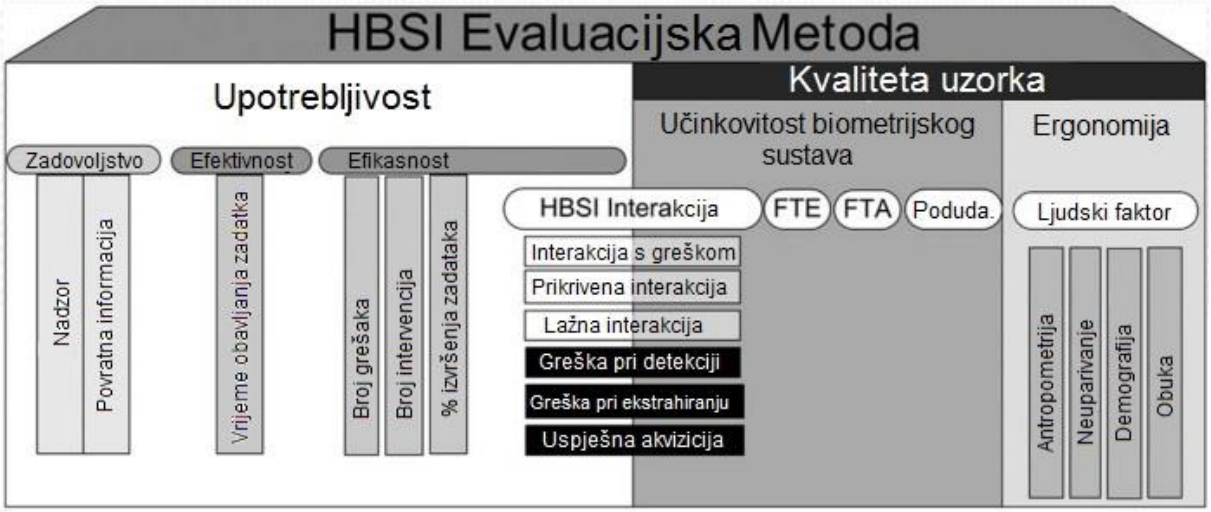
b. Efektivnost
    i. Vrijeme obavljanja zadatka
c. Efikasnost
    i. Broj grešaka
    ii. Broj intervencija
    iii. % izvršenja zadataka

2. Kvaliteta uzorka
    a. Učinkovitost biometrijskog sustava
        i. FTE
        ii. FTA
        iii. Broj podudarnosti
    b. Ergonomija
        i. Ljudski faktor
            1. Antropometrija
            2. Neuparivanje
            3. Demografija
            4. Obuka

Poveznicu upotrebljivosti i kvalitete uzorka čini HBSI interakcija koja se sastoji od:

1. Interakcija s greškom – događa se kod nefunkcionalnog prezentiranja biometrijske karakteristike, pa se kao rezultat dobiva neprihvaćanje od strane sustava,
2. Prikrivena interakcija – događa se kada je verificirana pogrešna prezentacija biometrijske karakteristike, pa pošto je sustav nije ni prepoznao, nije zavedena kao interakcija s greškom,

3. Lažne interakcije – događa se kada je sustav prepoznao pogrešnu prezentaciju biometrijske karakteristike, te je kao takvu i zabilježio,
4. Grešaka pri detekciji – događa se kada postoje prezentirane karakteristike zabilježene od strane testnog tima koje nisu zabilježene od strane biometrijskog sustava,
5. Grešaka pri ekstrahiranju – događa se kada je sustav u nemogućnosti procesiranja predstavljene biometrijske karakteristike,
6. Uspješnih akvizicija – događa se kada predočenu biometrijsku karakteristiku sustav uredno prepoznaje te adekvatno procesira.



Slika 21. HBSI evaluacijska metoda [13]

Na priloženoj slici može se vidjeti unaprijeđena verzija HBSI evaluacijske metode. Zapravo se radi o drugoj verziji koja je predstavljena od strane autora nakon nekoliko godina. Ono što drugu verziju razlikuje od prve je to što je pridodana veća važnost „Kvaliteti uzorka“ koja je izdvojena iz ergonomije i dignuta razinu iznad zamjenjujući „Kvalitetu slike“ koja je zauzimala primarno mjesto u prvoj verziji metode.

S ciljem unifikacije i proširenja primjene evaluacijskog modela na sve biometrijske karakteristike i na one kod kojih rezultat uzimanja uzorka nije slika,

kreirana je ranije opisana druga verzija HBSI evaluacijskog modela, kojoj je kvaliteta uzorka od primarne važnosti, naravno uz upotrebljivost samog biometrijskog sustava.

2012. godine je na IP Business Congress(IPBC) konferenciji prezentirana je treća verzija HBSI modela evaluacije biometrijskih sustava. U trećoj verziji, detaljnije je razrađen sam model na kojem se temelji HBSI. Proširene su metrike vezane uz ***korisnika biometrijskog sustava***, te je definirano da korisnik biometrijskog sustava može predstavljati:

1. Subjekt – osoba koja je predmet biometrijskog skeniranja (*Biometric donor*),
2. Operater – osoba koja vrši prikupljanje biometrijskog uzorka, odnosno upravlja biometrijskim sustavom (*Biometric Sensor operator*),
3. Ostale prisutne osobe (u okruženju biometrijskog sustava, zaključeno je da one mogu imati određen utjecaj na subjekte i operatera).

Ujedno, proširene su i varijable vezane uz ***okolinu biometrijskog sustava***, i to na *stanje subjekta* te *prikupljeno stanje okoline*. ***Stanje subjekta*** se odnosi na varijable:

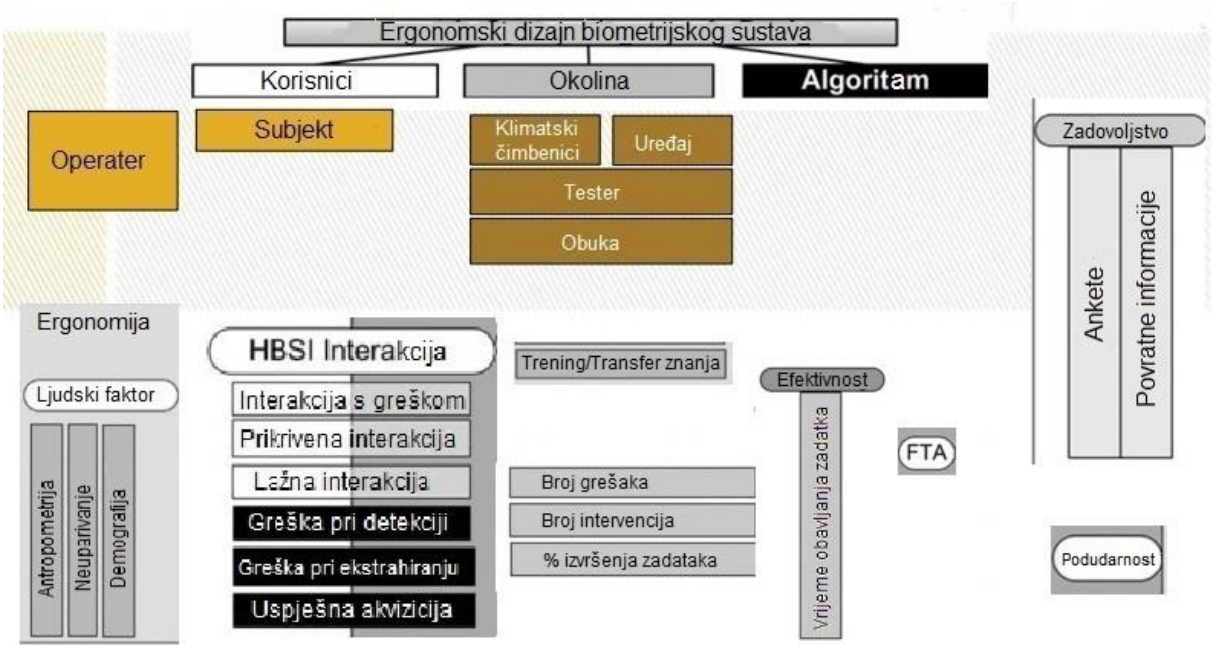
1. Vlažnost
2. Elastičnost
3. Masnoću (oiliness).

Prikupljeno stanje okoline se odnosi na varijable:

1. Temperaturu
2. Vlagu zraka.

Struktura treće verzije HBSI modela evaluacije biometrijskih sustava, predstavljena je na primjeru biometrijske karakteristike geometrije dlana ruke. Na

niže priloženoj slici može se detaljnije vidjeti proširenje korisnika varijablama Subjekt(*Biometric donor*) i Operater (*Biometric Sensor operator*), a okolina biometrijskog sustava je proširena tako da se mogu prikupiti varijable temperatura i vlaga okoline(*Cimate*) te varijable vezane uz stanje subjekta (vlažnost, elastičnost i masnoću) koje se prikupljaju (*Device*).



Slika 22. HBSI model evaluacije na primjeru geometrije dlana ruke [13]

H-B Interakcijski model

Mª Belén Fernández Saavedra 2013. godine u svojoj doktorskoj disertaciji „Evaluation Methodologies for Security Testing of Biometric Systems beyond Technological Evaluation“ [14], predstavlja H-B Interakcijski model, punog naziva „Evaluacijska metoda za H-B interakcijski test biometrijskih sustava“. Navedena metoda zapravo predstavlja proširenje ranije spomenutog HBSI modela. Saavedra je proširio HBSI evaluacijski model v2 s parametrom *Okoline* koji utječe na funkcionalnost samog biometrijskog sustava.

H-B interakcijski model sadrži opis funkcionalnih testova kod kojih je skup korisnika(subjekata) u interakciji s biometrijskim sustavom s ciljem izračuna stupnja preciznosti i brzine algoritama prepoznavanja biometrijskih karakteristika u jednoj ili više realiziranih okolnosti:

a. Dogodila se promjena na određenoj biometrijskoj karakteristici a vezana je uz senzor,
b. Osoba i pridružena biometrijska karakteristika sadrži određene specifičnosti/posebnosti,
c. Bilo koji faktor koji ima utjecaj na H-B interakcijski proces je promijenjen.

Dakle, H-B interakcijski model je zapravo „end-to-end“ evaluacija biometrijskih sustava koja uzima u obzir dodatne faktore okoline, ergonomije te mogućnosti samog korištenja biometrijskog sustava. On se bavi proučavanjem utjecaja korisnika na performanse biometrijskih sustava, te ih metrički definira koristeći pretpostavke samog HBSI modela.

Evaluacijski model OOEPBS

Zoran Ćosić je 2015. godine u svojoj doktorskoj disertaciji „Metoda evaluacije pouzdanosti biometrijskih sustava“, predstavio Otvoreni Okvir Za Evaluaciju Pouzdanosti Biometrijskih Sustava(OOEPBS).

„Otvoreni okvir za evaluaciju pouzdanosti biometrijskih sustava podrazumijeva definiciju aspekata i pripadajućih činitelja pouzdanosti biometrijskih sustava sukladno definicijama, gdje se pouzdanost definira kao: « sposobnost sustava da izvršava i održava svoju operativnu funkciju u rutinskim okolnostima, ali i u neprikladnim i neočekivanim okolnostima». Sposobnost sustava da izvršava svoju operativnu funkciju, odnosno pouzdanost, podložna je utjecajima aspekata konteksta uporabe samog sustava.“ [15]

Autor je kreirao model koji se također zasniva na tri aspekta, korisnik, okolina i tehnologija, kao i ranije spomenuti HBSI i H-B interakcijski model, s time da su područja preklapanja definirana kao činitelji utjecaja A, B i C.



Slika 23. Konceptualni model OOEPBS [15]

Prema konceptualnom modelu trijade aspekata biometrijskih sustava autor je parametrizirao činitelje pouzdanosti biometrijskog sustava, koje su u funkciji definicije modela evaluacije pouzdanosti biometrijskih sustava te služe kao temelj definicije metode za evaluaciju biometrijskih sustava. Autor je model OOEPBS zamislio kao otvoreni okvir koji predstavlja temelj za daljnja proširenja i nadogradnje. Detaljnija razrada modela zasniva se na specifikaciji svakog od navedena 3 aspekta tehnologije, okoline i korisnika [15].

Aspekt ***tehnologije*** prikazan je kroz parametre činitelja pouzdanosti:

- *Softver* – opisan putem parametra pouzdanosti
- *Hardver* – opisan putem parametra pouzdanosti
- *Performanse biometrijskog sustava* – opisane statistikama Failure to Acquire(FTA) i Failure to enroll(FTE), statistikama False match rate(FMR), te statistikama False non-match rate(FNMR).

Aspekt ***okoline*** definiran je preko:

- Atmosferskih prilika – opisana putem temperature i vlažnosti
- Fizičkih svojstva – opisana putem osvjetljenja i buke.

Aspekt ***korisnika*** prikazan kroz sljedeću podjelu:

- Činitelj biometrijske karakteristike
    - Kratkoročni utjecaj – predstavlja utjecaj na funkcioniranje sustava koji se može korigirati tijekom interakcije korisnik-sustav
        - Ponašajni utjecaj – ovisi o trenutnom raspoloženju i emocijama promatranog subjekta
        - Fizički utjecaj – ovisi o fizičkim svojstvima promatranog subjekta, kojima on može utjecati na senzor
    - Dugoročni utjecaj - predstavlja utjecaj na funkcioniranje sustava koji se ne može korigirati tijekom interakcije korisnik-sustav

        - Bolest – utjecaj koji u pojedinim slučajevima mijenja biometrijsku karakteristiku, pa njome više nije moguća identifikacija korisnika (npr. prehlada prilikom prepoznavanja glasa)
        - Izgled – utjecaj vanjskih obilježja korisnika (npr. kosa, brkovi itd.)
- Osobni činitelji korisnika,
    - Antropometrija,
        - Tjelesna obilježja - prirođena obilježja (npr. boja kose ili očiju, položaj tijela itd.)
        - Tjelesne dimenzije - stečena obilježja (npr. debljina, mršavost)
    - Iskustvo,
        - Uvježbanost (s vremenom i češćim korištenjem, korisnik nauči kako koristiti biometrijski sustav)
    - Osjetljivost na ergonomiju,
        - Uvjeti korištenja - predstavljaju utjecaj eventualnih nečistoća ili oštećenja prisutnih na senzoru biometrijskog sustava
        - Pozicija – predstavlja utjecaj putem visine senzora, orijentacije te nagiba senzora spram korisnika kao i njegovu interakciju sa biometrijskim sustavom.

Autor je istaknuo glavnu pretpostavku modela, da svi aspekti međusobno predstavljaju jednaku važnost kao i podjednak utjecaj na pouzdan rad i funkcioniranje samog biometrijskog sustava te je definirao model OOEPBS kao [15]:

OOEPBS= { f(

Aspekt_korisnika

Karakteristike

Kratkoročni_utjecaj (fizički,ponašajni)

Dugoročni_utjecaj (bolest,izgled)

Osobni činitelji

Antropometrija (tjelesna_obilježja, tjelesne_dimenzije)

Iskustvo (uvježbanost_korisnika)

Ergonomija (pozicija, uvjeti_korištenja)

Aspekt_okoline

Fizička_svojstva

Osvjetljenje

Buka

Atmosferska_svojstva

Temperatura

Vlažnost

Aspekt_tehnologije

Softver

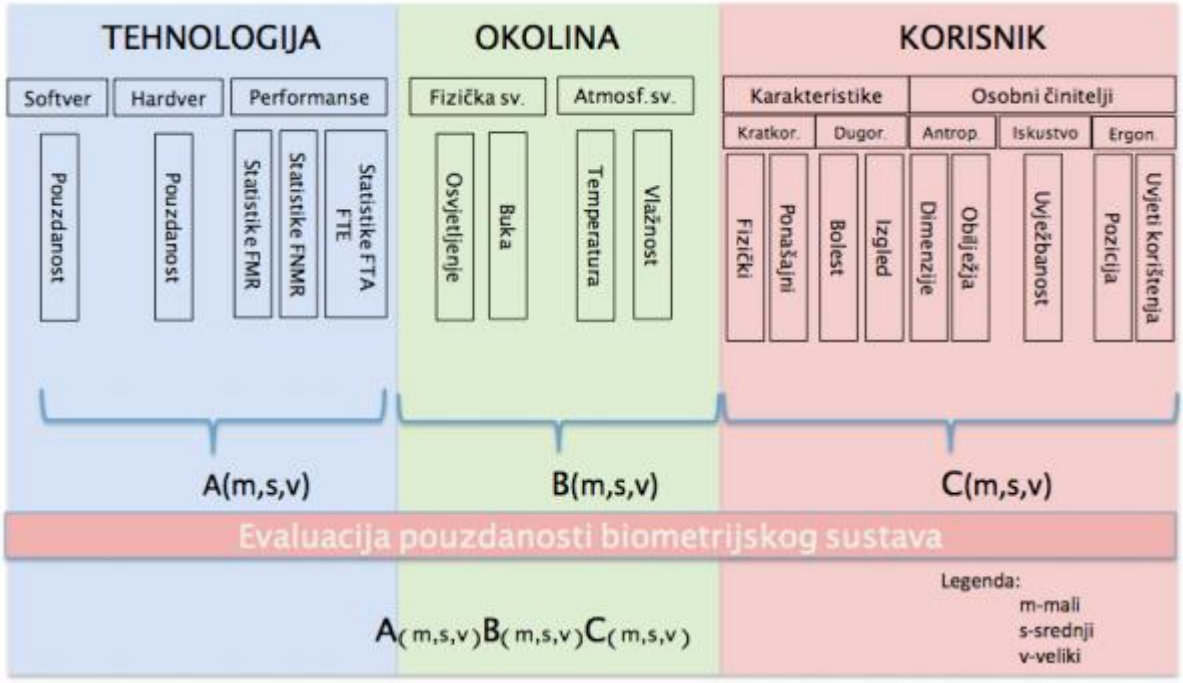
Pouzdanost

Hardver

Pouzdanost

Performanse

Statistike (FMR,FNMR,FTE;FTA)}



Slika 24. Evaluacijski model OOEPBS [15]

Dakle, evaluacijski model OOEPBS objedinjuje trijadu aspekata koju čine tehnologija, okolina i korisnik, a u konačnici evaluaciju predstavljaju:

- A – rezultat evaluacije utjecaja aspekta tehnologije
- B – rezultat evaluacije utjecaja aspekta okoline
- C – rezultat evaluacije utjecaja aspekta korisnika.

Navedeni rezultati su iskazani gradacijom m – mali, s – srednji i v – veliki utjecaj, a konačan rezultat evaluacije je *A(vrijednost)B(vrijednost)C(vrijednost)*.

5. MODELI EVALUACIJE BIOMETRIJSKIH KARAKTERISTIKA U XML-U

U ovom poglavlju glavna aktivnost bit će razrada modela evaluacije biometrijskih karakteristika te njegov opis u XML-u, kako za pojedine karakteristike, tako i za model koji bi objedinio i opisao sve biometrijske karakteristike zajedno. Idealna biometrijska karakteristika mora zadovoljavati sljedeće uvijete [16]:

- univerzalnost
- posebnost
- prikupljivost
- prevarljivost
- prihvatljivost
- performanse

U ranijim poglavljima naveden je povijesni razvoj istraživanja biometrijskih karakteristika, metode njihovih proučavanja te modeli koji predstavljaju sistematizirane formate kreirane s ciljem standardizacije postupka evaluacije biometrijskih sustava. U samom početku rada, krenulo se s namjerom da se napravi model evaluacije biometrijskih karakteristika kojim bi potencijalni korisnici lakše odlučili pri odabiru najbolje biometrijske karakteristike za svoje specifične potrebe. Kasnije kroz obradu teme uvidjela se nužnost povezivanja biometrijske karakteristike i tehnologije koja se koristi pri njenoj obradi, kao i utjecaja okoline. Opseg koji ima evaluacija samih biometrijskih karakteristika, bez uzimanja u obzir tehnologije i utjecaja okoline, nedovoljno opisuje mogućnosti i potencijal svake pojedine biometrijske karakteristike. Ovaj zaključak se jednostavno nameče na temelju istraživanja koja su provedena na svakoj pojedinoj biometrijskoj karakteristici.

U njima do izražaja dolazi tehnologija i algoritmi kojima se biometrijska karakteristika opisuje i obrađuje.

Navedeno se može lako uočiti na primjeru biometrijske karakteristike otiska prsta koja uvelike ovisi o tehnologiji kojom se uzima njen uzorak. Postoji velik broj različitih tehnologija čitača otiska prstiju, od kojih možemo navesti optičke čitače (2D i 3D), kapacitivne, ultrasonične čitače otiska prsta, RF čitače, senzore pritiska [51] itd. Samo iz primjera optičkih čitača možemo uvidjeti da su 2D optički čitači vrlo nepouzdani i podložni manipulaciji, za razliku od naprednijih 3D čitača. To s druge strane ne znači da je biometrijska karakteristika otiska prsta nepouzdana ili lošija od neke druge biometrijske karakteristike, već samo potvrđuje da svaka biometrijska karakteristika značajno ovisi o tehnologiji kojom se obrađuje, odnosno da se bez uzimanja u obzir tehnologije ne može napraviti kvalitetan odabir biometrijskog sustava.

Kao što je već ranije spomenuto u 4. poglavlju, idealan proces evaluacije sastoji se od vrednovanja tehnologije usporedbom svih primjenjivih tehnologija koje uvjerljivo mogu zadovoljiti tražene zahtjeve. lako istraživači koristite dobivene podatke o performansama za identifikaciju područja na kojima se mogu postići dodatna poboljšanja, potencijalni korisnici dobivene rezultate koriste za određivanje najboljeg sustava za svoje specifične potrebe. Podatci o učinkovitosti zajedno s podatcima o utjecaju, koji se prikupe naknadnim operativnim procjenama, pomažu donositeljima odluka pri odabiru najboljeg potencijalnog sustava.

S ciljem pružanja standardiziranog načina opisivanja podataka koji se koriste za potvrdu identiteta, temeljeni na biometrijskim karakteristikama kao što su DNK, otisak prstiju, rožnica oka, i geometrija dlana ruke, od strane OASIS-a [52], neprofitne organizacije koja potiče razvoj, konvergenciju i usvajanje otvorenih standarda za globalno informacijsko društvo, kreiran je XML Common Biometric Format (XCBF).

OASIS promiče i aktivno sudjeluje u kreiranju svjetskih standarda za IT, Internet of Things (IoT), cloud computing, energetiku, tehnologije sadržaja, upravljanje hitnim situacijama te drugim područjima. OASIS standardi pružaju mogućnost smanjenja troškova, potiču inovacije, kao i rast globalnih tržišta, te osiguravaju pravo na slobodan izbor tehnologije.

Članovi OASIS-a su uglavnom predstavnici javnog i privatnog tehnološkog sektora, tehnoloških predvodnika, korisnika i ljudi od utjecaja na tehnološkim područjima. OASIS ima više od 5.000 članova koji predstavljaju oko 600 organizacija u 65 zemalja diljem svijeta.

XML Common Biometric Format (XCBF)

XCBF je objedinjeni skup sigurnog XML koda za formate navedene u Common Biometric Exchange File Formatu (CBEFF) [53]. Navedeni XML kod kreiran je na temelju ASN.1 sheme definirane u American National Standards Institute(ANSI) standardu ANSI X9.84: 2003. Biometrics Information Management and Securit. Oni su u skladu s Encoding Rules (XER) za ASN.1 koja su definirana u ITU-T Recommendation X.693, te se oslanjaju na sigurnost i obradu minimalnih zahtjeva navedenih u X9.96 XML Cryptographic Message Syntax (XCMS). Vrijednosti Biometric Information Record (BIR) definirane u ANSI/INCITS 358-2002 - *Information technology - BioAPI Specification* koji može biti prezentiran u obliku X9.84 biometric object formata, također mogu biti prezentirane i osigurane koristeći XML kod i sigurnosne tehnike navedene u XCBF standardu [54].

OASIS je 16.9.2003. g. objavio da je od strane članova odobren i potvrđen XCBF version 1.1, kao OASIS standard. Izneseno je da XCBF pruža standardizirani način opisa podataka koji služe za potvrdu identiteta temeljenom na ljudskim karakteristikama. Istaknuto je da se XCBF može koristiti u širokom spektru aplikacija,

kao što su aplikacije koje koristi domovinska sigurnost, korporacije koje osiguravaju sigurnost, policijske snage, kao i prilikom biotehničkih istraživanja.

XCBF standard definira izgled kriptiranih poruka u XML-u s ciljem osiguranja sigurnog prikupljanja, prijenosa i obrade biometrijskih informacija. Korištenje navedenog formata osigurava integritet podataka, autentifikaciju porijekla, te privatnost biometrijskih podataka u aplikacijama i sustavima temeljenima na XML-u. Mehanizmi i tehnike koje su opisane u standardu služe za siguran prijenos, pohranu i očuvanje integriteta, kao i zaštite privatnosti biometrijskih podataka [55].

Tyky Aichelen iz IBM-a, predsjedatelj tehničkog odbora OASIS XCBF, je izjavio: "XCBF premošćuje jaz između svijeta biometrije i web-servisa, tako da omogućava zajednički, standardiziran i siguran način za definiranje, pohranu, upravljanje i razmjenu biometrijskih podataka s mnogo većom interoperabilnosti među sustavima. "

John Messing, predstavnik American Bar Association u OASIS-u, izjavio je da: "Tradicionalni biometrijski standardi se temelje na binarnim formatima pisanja programskog koda koje ozbiljno ograničava njihovu uporabu u sustavima i aplikacijama koje podržavaju XML. Pružajući standardizirani način za razmjenu biometrijskih informacija pomoću XML-a, XCBF doslovno redefinira biometriju kao vrlo praktično rješenje za web-bazirana okruženja."

"XCBF je izuzetno važan u razvoju proizvoda lakšom integriracijom i značajnije doprinijeti našim klijentima koji tvore životni ciklus same industrije biometrijske znanosti.", zaključak je Karle Norsworthy, direktorice Dynamic e-Business Technologies u IBM-u.

Iz svega navedenog, očita je težnja standardizaciji kojom se postiže transparentna i kvalitetnija upotreba tehnologija, kako samih aplikacija, tako i cjelokupnih sustava.

XCBF opisuje proces „prevođenja“ između X9.84 ***BiometricObject*** i BioAPI-1.1 BIR. Kada su vrijednosti BIR formata kao vrijednost podatka tipa BiometricObject, podatci mogu biti osigurani koristeći tehnike opisane u XCBF standardu.

Struktura XCBF-a započinje glavnim objektom, ***BiometricSyntaxSets*** koji može predstavljati seriju jednu ili više skupina podataka tipa ***BiometricSyntax*** [17]. ***BiometricSyntax*** tip podatka ima četiri alternativne vrijednosti:

- ***biometricObjects*** - predstavlja skup biometrijskih podataka (neštićenih/nekriptiranih)
- ***integrityObjects*** - predstavlja skup digitalno potpisanih biometrijskih podataka
- ***privacyObjects*** - predstavlja skup kriptiranih biometrijskih podataka
- ***privacyAndIntegrityObjects*** - predstavlja skup digitalno potpisanih i kriptiranih biometrijskih podataka.

Dakle, ***BiometricSyntaxSets*** predstavlja skup jedne ili više ponuđenih alternativa. Pošto svaka od navedenih alternativa predstavlja skup jednog ili više biometrijskih objekata, ***BiometricSyntaxSets*** je zapravo skup skupova. Koristeći ponuđene alternative, pošiljatelj poruke ima slobodu sam odrediti skup podataka i njihov redoslijed, što omogućava poredak zapisa podataka prema vjerojatnosti podudaranja, formatu dobavljača, tipu biometrijske karakteristike, kvaliteti podataka i starosti zapisa.

BiometricObjects predstavlja skup jedne ili više biometrijskih podataka tipa ***BiometricObject*** koji se sastoji od dvije komponente, ***biometricHeader*** i ***biometricData***.

BiometricHeader predstavlja apstraktne vrijednosti koje su neovisne o tipu implementacije, programskom jeziku, operacijskom sustavu, hardveru ili načinu

prijenosa podataka, čime omogućava maksimalnu slobodu i fleksibilnost. Komponente ***BiometricHeader***-a su:

- version
- recordType (id)
- dataType
- purpose
- quality
- validityPeriod (notBefore, notAfter)
- format (formatOwner, formatType).

BiometricData je tip podataka koji sadrži opis biometrijskih podataka.

IntegrityObjects se sastoji od komponenata:

- **biometricObjects**
- **integrityBlock**.

biometricObjects predstavlja skup jedne ili više vrijednosti tipa **BiometricObjects** u kodiranom obliku. To je oblik koji je potreban za proces digitalnog potpisivanja te proces verifikacije digitalnog potpisa. Kao što je ranije navedeno, **BiometricObjects** se sastoji od komponenata ***BiometricHeader*** i ***BiometricData***.

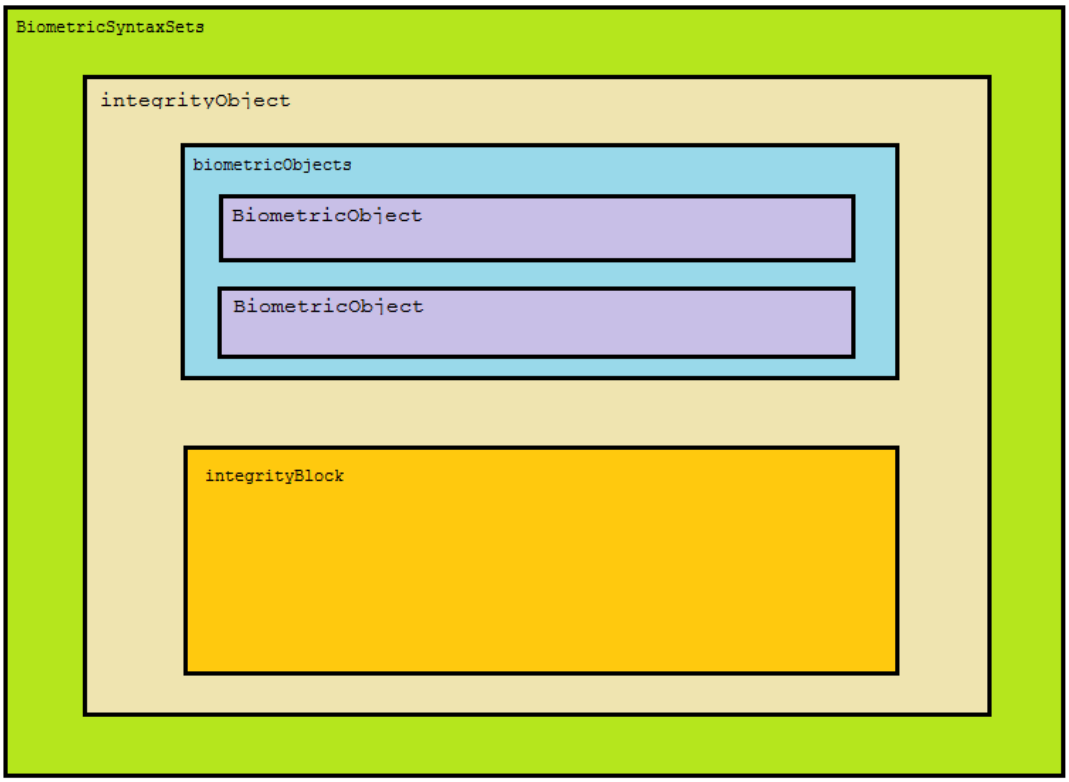
integrityBlock komponenta je vrijednost tipa **IntegrityBlock** te pruža četiri alternative:

- **digitalSignature** - jednostavan digitalni potpis korištenjem fiksnog para ključeva,
- **messageAuthenticationCode** - jednostavan Message authentication code(MAC) ili Hash message authentication code(HMAC),

- **signedData** - jednostavan digitalni potpis pomoću fiksnog para ključeva s informacijama o autentifikaciji izvora podataka,
- **authenticatedData** - jednostavan MAC ili HMAC s informacijama o autentifikaciji izvora podataka.

Svakoj od navedenih alternativa se nadalje može detaljnije prikazati struktura, ali bi s time otišli preduboko. Cilj je bio pokazati logiku i strukturu XCBF standarda te način na koji on opisuje biometrijske podatke. Kako bi lakše shvatili samu strukturu i koncept, bit će prikazan standard na primjeru skupa biometrijskih podataka, te kako oni zapravo izgledaju opisani XML-om [17] (PRILOG A).

Iz programskog koda koji je naveden u prilogu A, očituje se najbolja karakteristika XML-a, a to je njegova nevjerojatno laka sposobnost strukturiranja i prikaza hijerarhije, kao i mogućnost ugnježđivanja. Navedeno je vidljivo na donjoj slici.

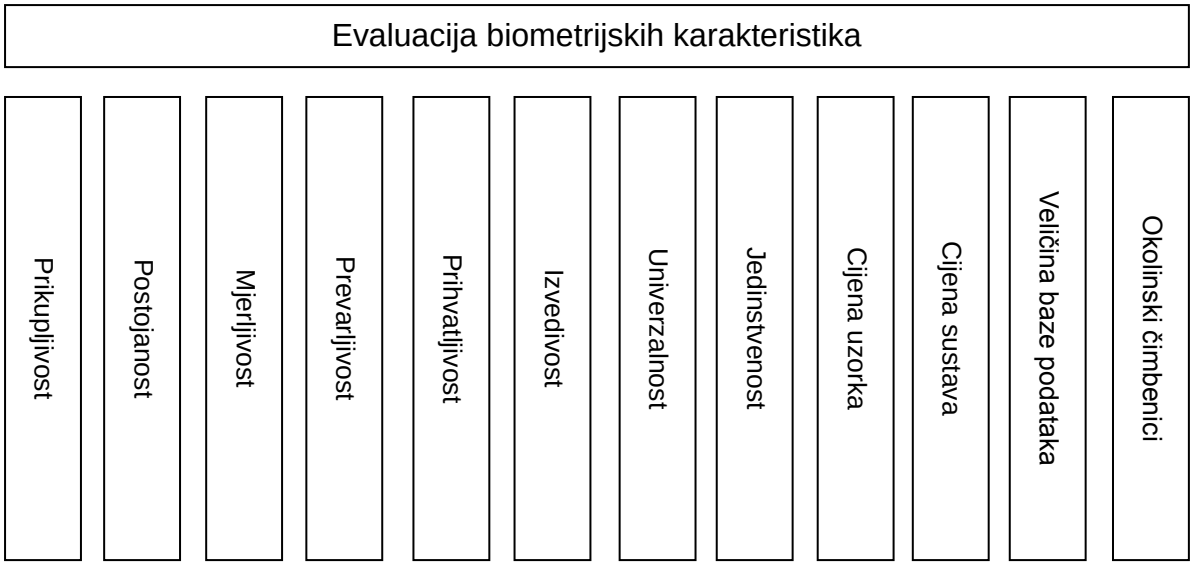


Slika 25. Primjer strukture XCBF-a [17]

Model evaluacije biometrijskih karakteristika

U magistarskom radu „Zasnivanje otvorene ontologije odabranih segmenata biometrijske znanosti“ Markus Schatten je definirao opisne parametre biometrijskih karakteristika s ciljem implementacije mogućeg ekspertnog sustava za izbor biometrijske karakteristike. Prema autoru, opisni parametri biometrijskih karakteristika su prikupljivost, postojanost, mjerivost, prevarljivost, prihvatljivost, izvedivost, univerzalnost, jedinstvenost, cijenaUzorka, cijenaSustava, veličina baze podataka, te okolinski□čimbenici o kojima uvelike ovisi izbor karakteristike u danoj situaciji. Definirani parametri mogu poprimiti vrijednosti „visoka“, „srednja“ i „niska“ [18].

Prema navedenoj klasifikaciji moguće je kreirati model evaluacije biometrijskih karakteristika.



Slika 26. Model evaluacije biometrijskih karakteristika

Kako bi XML zapis navedenog modela evaluacije biometrijskih karakteristika bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih karakteristika „biometrijskaKarakteristika“. Ona se sastoji od zaglavlja i parametara, pri čemu „zaglavlje“ sadrži zapise o id-u

biometrijske karakteristike, njegovom nazivu i opisu, a „podatci“ sadrže vrijednosti parametara evaluacije dane biometrijske karakteristike.

Model evaluacije biometrijskih karakteristika u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihKarakteristika>

   <biometrijskaKarakteristika>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <parametri>
         <prikupljivost> vrijednost </prikupljivost>
         <postojanost> vrijednost </postojanost>
         <mjerljivost> vrijednost </mjerljivost>
         <prevarljivost> vrijednost </prevarljivost>
         <prihvatljivost> vrijednost </prihvatljivost>
         <izvedivost> vrijednost </izvedivost>
         <univerzalnost> vrijednost </univerzalnost>
         <jedinstvenost> vrijednost </jedinstvenost>
         <cijenaUzorka> vrijednost </cijenaUzorka>
         <cijenaSustava> vrijednost </cijenaSustava>
         <velicinaBazePodataka> vrijednost </velicinaBazePodataka>
         <okolinskiCimbenici> vrijednost </okolinskiCimbenici>
      </parametri>
   </biometrijskaKarakteristika>

</EvaluacijaBiometrijskihKarakteristika>
```

Gore navedeni model XML-a omogućava opis bilo koje biometrijske karakteristike preko definiranih parametara. Na temelju definiranih vrijednosti može se izvršiti evaluacija te njome olakšati odabir biometrijske karakteristike koja bi predstavljala najbolje rješenje pri odabiru najprikladnije i najprihvatljivije tehnologije zaštite i osiguranja sigurnosti određene organizacije. Kao što je već ranije navedeno na početku ovog poglavlja, kroz obradu teme uvidjela se nužnost povezivanja biometrijske karakteristike i tehnologije, koja se koristi pri njenoj obradi, kao i utjecaja

okoline, kako na biometrijsku karakteristiku, tako i na tehnologiju. Model evaluacije biometrijskih karakteristika u XML-u kreiran je s ciljem da se na samom primjeru može argumentirati nužnost proširenja opsega evaluacije na biometrijske sustave, uključivanjem utjecaja tehnologije i okoline. Time će se bolje uvidjeti mogućnosti i potencijal svake pojedine biometrijske karakteristike te odabrati sustav koji je najbolji i najprihvatljiviji određenoj organizaciji s obzirom na njene specifičnosti i potrebe.

5.1. Model fizičkih biometrijskih karakteristika

Kao što je već ranije navedeno u poglavlju 2.3. fizičke biometrijske karakteristike se temelje na fizičkom izgledu ili osobinama pojedinca. To su karakteristike koje smo naslijedili genetski i stekli ih rođenjem te ih se ne može jednostavno i lako promijeniti. Svaka biometrijska karakteristika ima svoje prednosti i nedostatke, tako da izbor ovisi o velikom broju faktora, naravno uz samu učinkovitost odnosno performanse podudaranja.

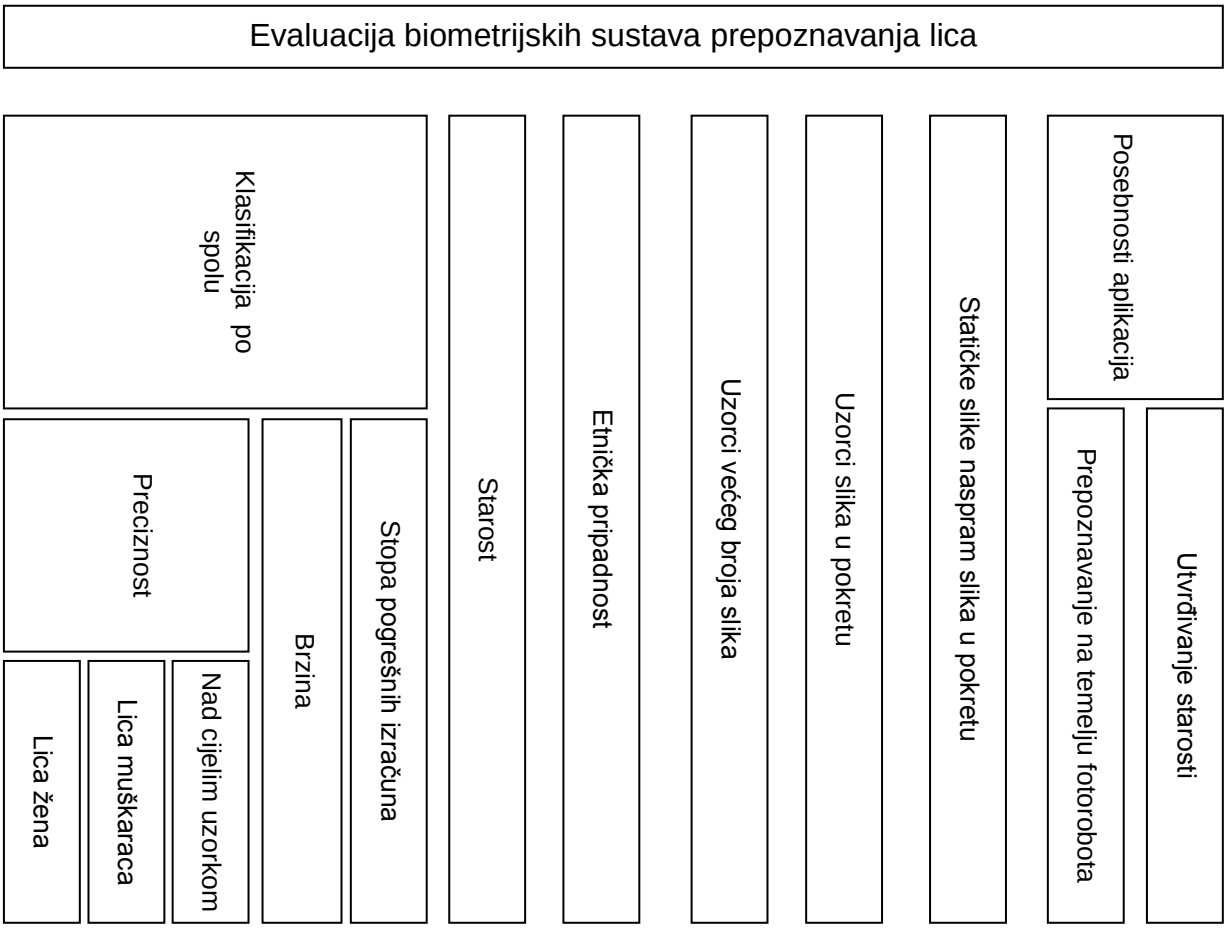
5.1.1. Lice

Kako bi ispitala potencijal, mogućnosti i ograničenja prepoznavanja lica kao biometrijske karakteristike te potaknula i usmjerila razvoj biometrijskih sustava prepoznavanja lica, američka vlada je sponzorirala nekoliko evaluacijskih događaja. U početku se krenulo s FacE REcognition Technology Evaluation (FERET) koji je bio sponzoriran od strane Defense Advanced Research Products Agency (DARPA) u razdoblju od 1993. do 1997. Kasnije je nastao Face Recognition Vendor Tests (FRVT) koji se izvodio 2000., 2002. i 2006. godine. NIST je 2015. godine izdao „Face Recognition Vendor Test (FRVT) Performance of Automated Gender Classification Algorithms“ u kojem su opisani ključni elementi evaluacije biometrijskih sustava prepoznavanja lica. Kroz rad se vrši testiranje i konačna evaluacija devet algoritama za prepoznavanje lica. Podatci, odnosno rezultati dobiveni navedenim testom, klasificirani su prema [19]:

- ***Gender Classification on Large Constrained Dataset*** – predstavlja klasifikaciju prema spolu na velikom skupu podataka,
    - ***Accuracy*** – mjeri se preciznost prepoznavanja;
        - ***Female*** – lica žena

        - ***Male*** – lica muškarca
        - ***Overall*** – ukupna uspješnost
    - ***Speed*** – brzina algoritama i samog biometrijskog sustava je ponekad vrlo važna kada se odluke moraju donijeti brzo i na temelju pokretnih slika
    - ***Failure to Compute Rate*** – predstavlja stopu pogrešnih izračuna
- ***Age*** – određivanje starosti prema uzorku slike, starost je grupirana po desetljećima, te je utvrđen njen veliki utjecaj na sposobnost i preciznost algoritama kao i ukupno biometrijskih sustava prepoznavanja lica
- ***Ethnicity*** – odnosi se na evaluaciju sposobnosti algoritama i biometrijskih sustava da iz slika uspješno klasificiraju ljude prema etničkoj pripadnosti
- ***Multiple Image Samples*** – provjerava se kolika je preciznost biometrijskog sustava na uzorcima s većim brojem slika, npr. izdvojene slike iz video sekvence osobe koja je prošla ispred kamere
- ***In the Wild*** – evaluacija sustava prepoznavanja nad uzorcima slika koje nisu statički/pravilno uslikane, npr. selfiji, slike lica ljudi koji su u pokretu itd.
- ***Constrained versus In the Wild*** – usporedba uspješnosti nad pravilnim, statičkim uzorcima slika spram uzoraka slika u pokretu, savršenim uvjetima
- ***Specific Applications*** – posebnosti aplikacija, koje se odnosi na;
    - ***Gender Verification*** – sposobnost biometrijskog sustava da odredi starost osobe
    - ***Sketches*** – sposobnost biometrijskog sustava da prepozna osobu prema skici odnosno fotorobotu.

Prema dobivenim rezultatima i strukturi klasificiranih podataka, moguće je zasnovati model evaluacije biometrijskih sustava prepoznavanja lica.



Slika 27. Model evaluacije biometrijskih sustava prepoznavanja lica

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava prepoznavanja lica bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavPrepoznavanjaLica“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava prema FRVT-u.

Model evaluacije biometrijskih sustava prepoznavanja lica u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaPrepoznavanjaLica>

   <biometrijskiSustavPrepoznavanjaLica>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <klasifikacijaPoSpolu>
            <preciznost>
               <licaZena> vrijednost </licaZena>
               <licaMuskaraca> vrijednost </licaMuskaraca>
               <nadCijelimUzorkom> vrijednost </nadCijelimUzorkom>
            </preciznost>
            <brzina> vrijednost </brzina>
            <stopaPogresnihIzracuna> vrijednost </stopaPogresnihIzracuna>
         </klasifikacijaPoSpolu>
         <starost> vrijednost </starost>
         <etnickaPripadnost> vrijednost </etnickaPripadnost>
         <uzorciVecegBrojaSlika> vrijednost </uzorciVecegBrojaSlika>
         <uzorciSlikaUPokretu> vrijednost </uzorciSlikaUPokretu>
         <statickeVsSlikaUPokretu> vrijednost </statickeVsSlikaUPokretu>
         <posebnostiAplikacije>
            <prepoznavanjeFotorobota> vrijednost </prepoznavanjeFotorobota>
            <utvrdjivanjeStarosti> vrijednost </utvrdjivanjeStarosti>
         </posebnostiAplikacije>
      </podatci>
   </biometrijskiSustavPrepoznavanjaLica>

</EvaluacijaBiometrijskihSustavaPrepoznavanjaLica>
```

5.1.2. Otisak prsta

2014. godine od strane NIST-a, izdan je „Fingerprint Vendor Technology Evaluation (FpVTE) - Evaluation of Fingerprint Matching Algorithms“ u kojem su opisani ključni elementi evaluacije biometrijskih sustava otiska prsta.

Specifičnost klasifikacije podataka prema FpVTE-u očituje se u tome što su podatci grupirani u tri klase: A, B i C. Svi sudionici evaluacije biometrijskih sustava otiska prsta bili su obvezni koristiti podatke klase A, te proizvoljno koristiti podatke klase B ili obje klase B i C. Klasa A se sastojala od podataka skeniranja otiska kažiprsta lijeve i desne ruke.



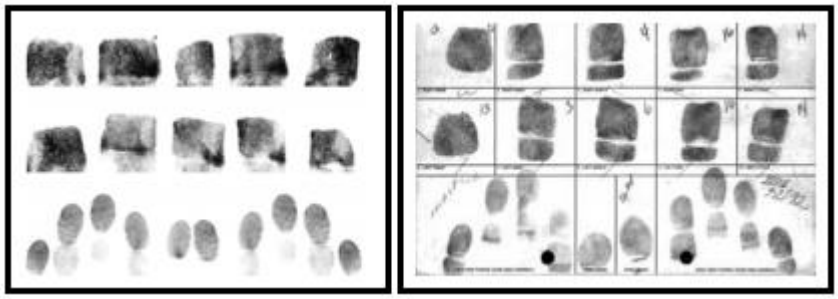
Slika 28. Podatci klase A [20]

Klasa B je sadržavala podatke takozvanih IDFlat-ova, skeniranih otisaka četiri prsta lijeve i desne ruke, te oba palca(lijeve i desne ruke) zajedno, poznat kao i „4-4-2“ uzorak.



Slika 29. Podatci klase B [20]

U klasi C su podatci koje je tvorila kombinacija od četrnaest kartica, što prikupljenih što skeniranih uzoraka tinte.



Slika 30. Podatci klase C [20]

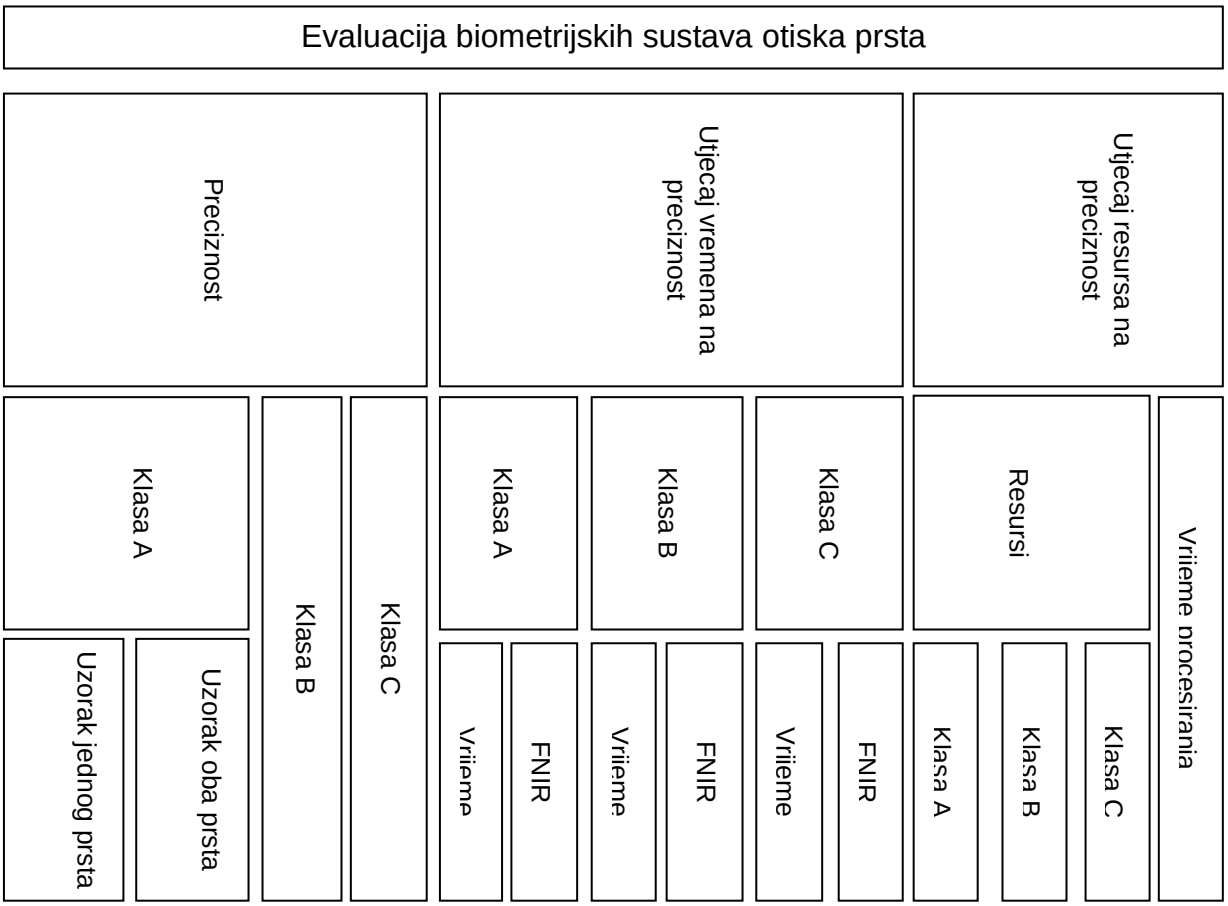
Izvršeno je testiranje i konačna evaluacija algoritama osamnaest proizvođača, a rezultati dobiveni navedenim testom su strukturirani prema [20]:

- ***Accuracy*** – preciznost algoritama izražena prema False positive identification rate (FPIR) i False negative identification rate (FNIR),
    - ***Class A*** – preciznost podataka klase A;
        - ***Single-Index Finger Identification*** – predstavlja korištenje uzorka jednog prsta
        - ***Two-Index Finger Identification*** – predstavlja korištenje uzorka oba prsta (lijevi i desni)
    - ***Class B*** – preciznost podataka klase B
    - ***Class C*** – preciznost podataka klase C
- ***Accuracy*/Search Time Tradeoff** – predstavlja utjecaj vremena na preciznost sustava. Kako bi se utvrdio taj utjecaj, bile su dozvoljene dvije iteracije po potvrdi uzorka;
    - ***Class A*** – rezultati podataka klase A
        - ***Time;***
        - ***FNIR;***
    - ***Class B*** – rezultati podataka klase B
        - ***Time;***
        - ***FNIR;***

- ***Class C*** – rezultati podataka klase C
  - ***Time;***
  - ***FNIR;***

- ***Accuracy Computational Resources Tradeoff*** – odnosi se na utjecaj veličine pohranjenog uzorka na tvrdom disku te mogućnosti i brzine njegova učitavanja prilikom kreiranja predloška.
  - ***Storage and Memory*** – predstavlja težnju što manjeg broja iteracija pohranjivanja/učitavanja podataka prilikom ciklusa prepoznavanja uzorka, s ciljem trošenja što manje resursa, odnosno Random-access memory (RAM);
    - ***Class A*** – predstavlja količinu korištenog rama prilikom obrade podataka klase A
    - ***Class B*** – predstavlja količinu korištenog rama prilikom obrade podataka klase B
    - ***Class C*** – predstavlja količinu korištenog rama prilikom obrade podataka klase C
  - ***Processing Time*** – predstavlja vrijeme potrebno za obradu uzorka, kao i za kreiranje predloška.

Prema dobivenim rezultatima i strukturi klasificiranih podataka, moguće je zasnovati model evaluacije biometrijskih sustava otiska prsta.



Slika 31. Model evaluacije biometrijskih sustava otiska prsta

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava otiska prsta bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavOtiskaPrsta“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava po FpVTE.

Model evaluacije biometrijskih sustava otiska prsta u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaOtiskaPrsta>

   <biometrijskiSustavOtiskaPrsta>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <preciznost>
            <klaseA>
               <uzorakJednogPrsta> vrijednost </uzorakJednogPrsta>
               <uzorakObaPrsta> vrijednost </uzorakObaPrsta>
            </klaseA>
            <klaseB> vrijednost </klaseB>
            <klaseC> vrijednost </klaseC>
         </preciznost>
         <utjecajVremenaNaPreciznost>
            <klaseA>
               <vrijeme> vrijednost </vrijeme>
               <fnir> vrijednost </fnir>
            </klaseA>
            <klaseB>
               <vrijeme> vrijednost </vrijeme>
               <fnir> vrijednost </fnir>
            </klaseB>
            <klaseC>
               <vrijeme> vrijednost </vrijeme>
               <fnir> vrijednost </fnir>
            </klaseC>
         </utjecajVremenaNaPreciznost>
         <utjecajResursaNaPreciznost>
            <resursi>
               <klaseA> vrijednost </klaseA>
               <klaseB> vrijednost </klaseB>
               <klaseC> vrijednost </klaseC>
            </resursi>
            <vrijemeProcesiranja> vrijednost </vrijemeProcesiranja>
         </utjecajResursaNaPreciznost>
      </podatci>
   </biometrijskiSustavOtiskaPrsta>

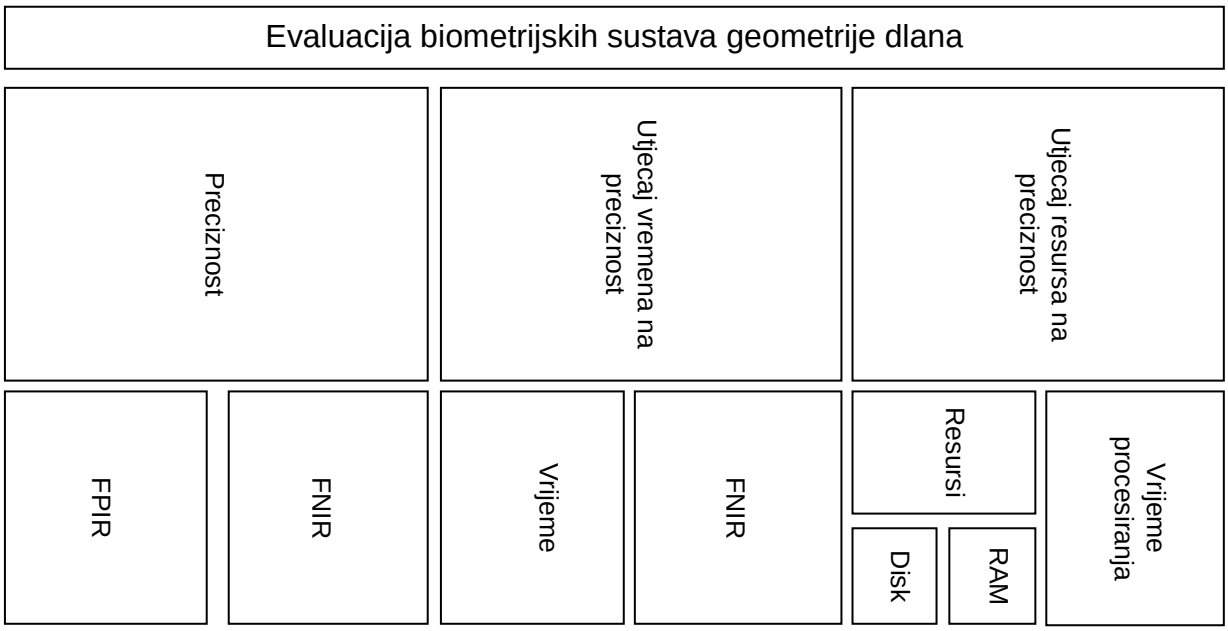
</EvaluacijaBiometrijskihSustavaOtiskaPrsta>
```

5.1.3. Geometrija dlana

Biometrijska karakteristika geometrije dlana koristi iste tehnologije i algoritme kao i biometrijska karakteristika otiska prsta i okvirno se zasniva na istim specifičnostima i vrijednostima mjerenja geometrije, osnovnih linija, te papilarnih linija dlana. Na žalost ne postoji NIST-ov tehnološki test biometrijskih sustava geometrije dlana, ali pošto počiva na istim vrijednostima mjerenja kao i otisak prsta, povodeći se ranije spomenutim NIST-ovim „Fingerprint Vendor Technology Evaluation (FpVTE) - Evaluation of Fingerprint Matching Algorithms“, može se preuzeti njegova osnovna struktura vrednovanja uzorka [20]:

- ***Accuracy*** – preciznost algoritama izražena prema
    - False positive identification rate (FPIR) i
    - False negative identification rate (FNIR)
- ***Accuracy*/Search Time Tradeoff** – predstavlja utjecaj vremena na preciznost sustava. Kako bi se utvrdio taj utjecaj, također bi definirali dvije iteracije po potvrdi uzorka;
    - ***Time***
    - ***FNIR***
- ***Accuracy Computational Resources Tradeoff*** – odnosi se na utjecaj veličine pohranjenog uzorka na tvrdom disku, te mogućnosti i brzine njegova učitavanja i procesiranja prilikom kreiranja predloška;
    - ***Storage and Memory*** – predstavlja težnju što manjeg broja iteracija pohranjivanja/učitavanja podataka prilikom ciklusa prepoznavanja uzorka, s ciljem trošenja što manje resursa, odnosno RAM-a
    - ***Processing Time*** – predstavlja vrijeme potrebno za obradu uzorka, kao i za kreiranje predloška.

Prema definiranoj strukturi klasificiranja podataka, moguće je zasnovati model evaluacije biometrijskih sustava geometrije dlana.



Slika 32. Model evaluacije biometrijskih sustava geometrije dlana

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava geometrije dlana bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavGeometrijeDlana“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava geometrije dlana u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaGeometrijeDlana>

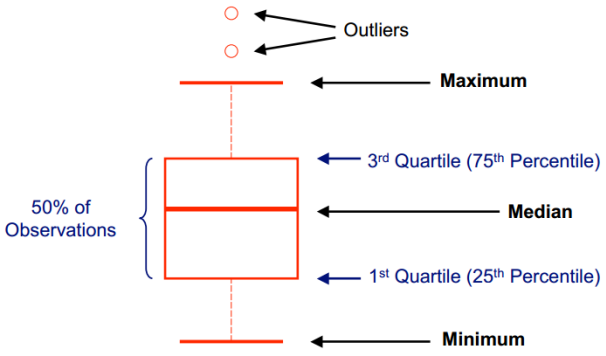
   <biometrijskiSustavGeometrijeDlana>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <preciznost>
            <fpir> vrijednost </fpir>
            <fnir> vrijednost </fnir>
         </preciznost>
         <utjecajVremenaNaPreciznost>
            <vrijeme> vrijednost </vrijeme>
            <fnir> vrijednost </fnir>
         </utjecajVremenaNaPreciznost>
         <utjecajResursaNaPreciznost>
            <resursi>
               <disk> vrijednost </disk>
               <ram> vrijednost </ram>
            </resursi>
            <vrijemeProcesiranja> vrijednost </vrijemeProcesiranja>
         </utjecajResursaNaPreciznost>
      </podatci>
   </biometrijskiSustavGeometrijeDlana>

</EvaluacijaBiometrijskihSustavaGeometrijeDlana>
```

5.1.4. Šarenica

NIST je 2007. godine izdao „FRVT 2006 and ICE 2006 Large-Scale Results“[21] prema tehnološkom testu proizvođača biometrijskih sustava koji se održao 2006. godine. „Iris Challenge Evaluation (ICE) 2006“ odnosi se na testiranje performansi tehnologije biometrijskih sustava šarenice oka. ICE 2006 koristi isti protokol kao i FRVT 2006, predstavljajući prvu evaluaciju koja mjeri performanse algoritama biometrijskih sustava šarenice oka.

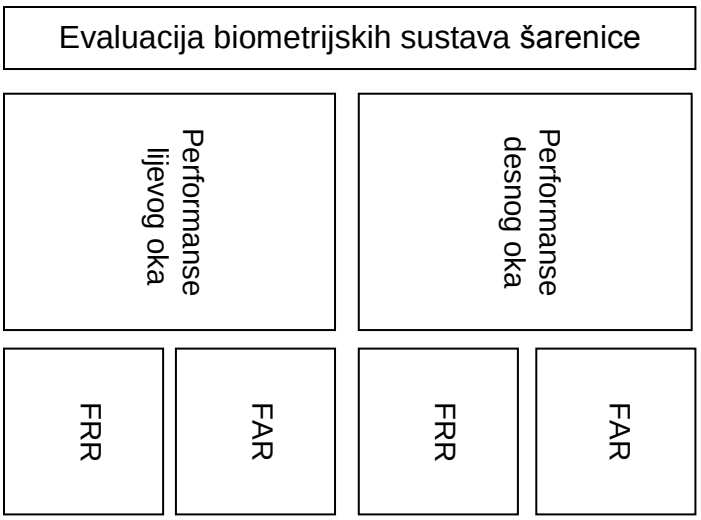
Izvršeno je testiranje i konačna evaluacija algoritama triju proizvođača, pri čemu su rezultati prikazani pomoću kutijastog dijagrama (box plot).



Slika 33. Primjer kutijastog dijagrama [21]

Na primjeru kutijastog dijagrama iz slike 32. može se vidjeti da horizontalna linija koja prolazi sredinom „kutije“ predstavlja medijan raspona performansi (50% zapažanja je veće od medijana i 50% je manje od medijana). Gornja linija „kutije“ predstavlja 1. četvrtinu (25%), a donja 3. četvrtinu (75%) vrijednosti. Nad kutijom i ispod nje, nalaze se vertikalne linije koje predstavljaju minimalne i maksimalne vrijednosti a završavaju horizontalnim linijama. Krugovi predstavljaju podatke koji iskaču iz skupa. Rezultati testiranja su kategorizirani prema podjeli na rezultate lijevog i rezultate desnog oka izračuna False reject rate (FRR) i False accept rate (FAR) kao i mjerenja performansi.

Prema definiranoj strukturi klasificiranja podataka, moguće je zasnovati model evaluacije biometrijskih sustava šarenice.



Slika 34. Model evaluacije biometrijskih sustava šarenice

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava šarenice bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavSarenice“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava šarenice u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaSarenice>

   <biometrijskiSustavSarenice>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <performanseLijevogOka>
            <frr> vrijednost </frr>
            <far> vrijednost </far>
         </performanseLijevogOka>
         <performanseDesnogOka>
            <frr> vrijednost </frr>
            <far> vrijednost </far>
         </performanseDesnogOka>
      </podatci>
   </biometrijskiSustavSarenice>

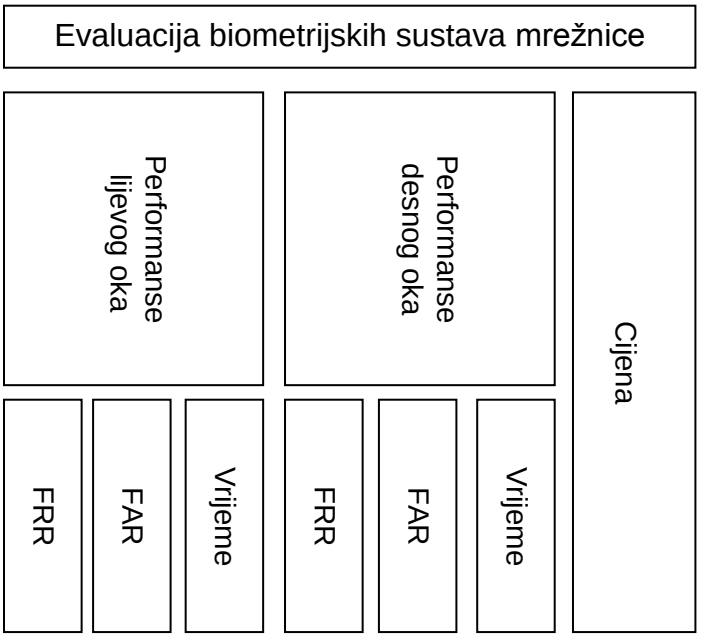
</EvaluacijaBiometrijskihSustavaSarenice>
```

5.1.5. Mrežnica

Sken mrežnice zapravo predstavlja uzorak spleta krvnih žila koji se nalazi u stražnjem dijelu oka. Prema tome, algoritmi biometrijskih sustava mrežnice se zasnivaju na prepoznavanju uzorka spleta krvnih žila.

Prednosti biometrijske karakteristike mrežnice oka su niska pojavnost FAR, ekstremno niska stopa FRR, velika pouzdanost, te brzina procesiranja uzoraka. S druge strane nedostaci su velika podložnost bolestima subjekta, percipira se kao invazivna metoda prikupljanja uzorka, te skupa tehnologija [56].

Uzimajući u obzir prednosti i nedostatke, te strukturu testova koji su izvedeni na šarenici oka prema NIST-ovom ICE 2006 [21], moguće je zasnovati model evaluacije biometrijskih sustava mrežnice.



Slika 35. Model evaluacije biometrijskih sustava mrežnice

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava mrežnice bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavMreznice“. Ona se sastoji od zaglavlja i podataka, pri čemu

„zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava mrežnice u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

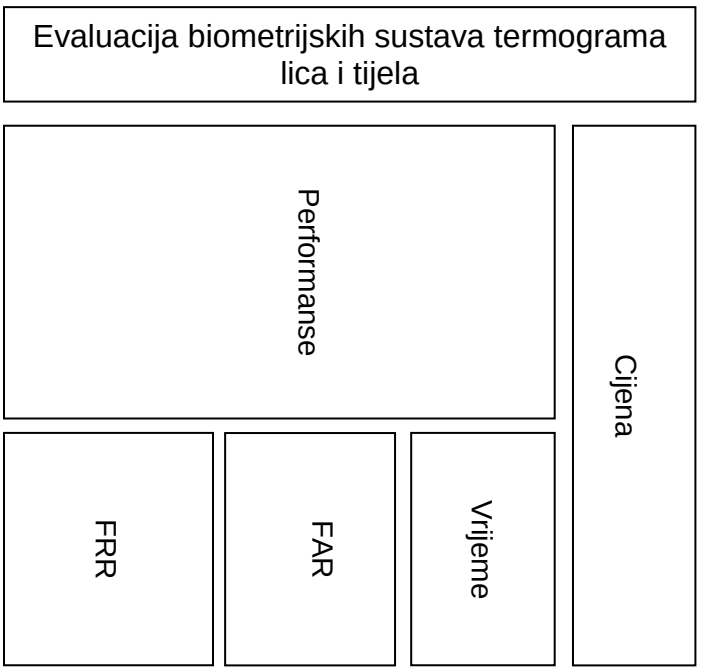
<EvaluacijaBiometrijskihSustavaMreznice>

   <biometrijskiSustavMreznice>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <performanseLijevogOka>
            <frr> vrijednost </frr>
            <far> vrijednost </far>
            <vrijeme> vrijednost </vrijeme>
         </performanseLijevogOka>
         <performanseDesnogOka>
            <frr> vrijednost </frr>
            <far> vrijednost </far>
            <vrijeme> vrijednost </vrijeme>
         </performanseDesnogOka>
         <cijena> vrijednost </cijena>
      </podatci>
   </biometrijskiSustavMreznice>

</EvaluacijaBiometrijskihSustavaMreznice>
```

5.1.6. Termogram lica i tijela

Biometrijske sustave termograma lica i tijela obilježavaju pretežno iste karakteristike kao i biometrijske sustave mrežnice. Prednosti se očituju u velikoj pouzdanosti, jedinstvenosti, brzini procesiranja. Budući da korisnik mora lice ili tijelo okrenuti ravno prema kameri, krasi ga neinvazivnost, a uzorak se uzima s razdaljine kao npr. kod fotografa. S druge strane, negativnosti se očituju u izrazitoj skupoći opreme, odnosno termalnih kamera. Slijedom navedenoga kreiran je model evaluacije biometrijskih sustava termograma lica i tijela.



Slika 36. Model evaluacije biometrijskih sustava termograma lica i tijela

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava termograma lica i tijela bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavTermogramaLicaTijela“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava termograma lica i tijela u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

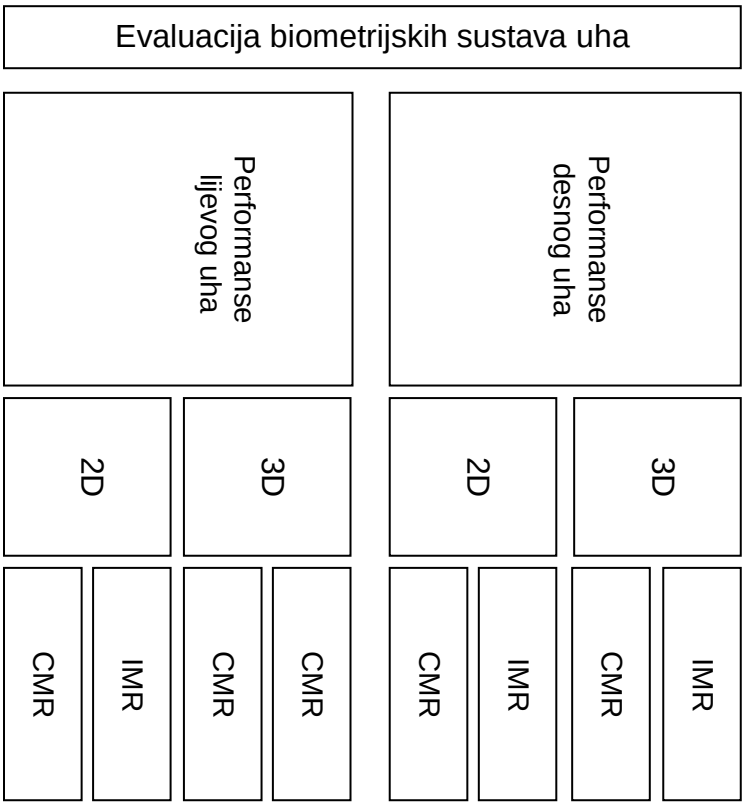
<EvaluacijaBiometrijskihSustavaTermogramaLicaTijela>

   <biometrijskiSustavTermogramaLicaTijela>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <performanse>
            <frr> vrijednost </frr>
            <far> vrijednost </far>
            <vrijeme> vrijednost </vrijeme>
         </performanse>
         <cijena> vrijednost </cijena>
      </podatci>
   </biometrijskiSustavTermogramaLicaTijela>

</EvaluacijaBiometrijskihSustavaTermogramaLicaTijela>
```

5.1.7. Uho

Biometrijska karakteristika uha predstavlja neinvazivnu metodu identifikacije osoba koja predstavlja prilično novu metodu s velikim potencijalom te je nedovoljno zastupljena u komercijalnoj primjeni. U svom radu Ping Yan i Kevin W. Bowyer „Empirical Evaluation of Advanced Ear Biometrics“ klasificirali su podatke za evaluaciju biometrijskih sustava uha prema performansama i uzorcima lijevog i desnog uha, 2D i 3D modelima te correct matching rate (CMR) koja predstavlja vjerojatnost uspješnog prepoznavanja i incorrect matching rate (IMR) koja predstavlja vjerojatnosti neuspješnog prepoznavanja [22]. Prema njihovoj klasifikaciji, moguće je konstruirati model evaluacije biometrijskih sustava uha.



Slika 37. Model evaluacije biometrijskih sustava uha

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava uha bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup

podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavUha“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava uha u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

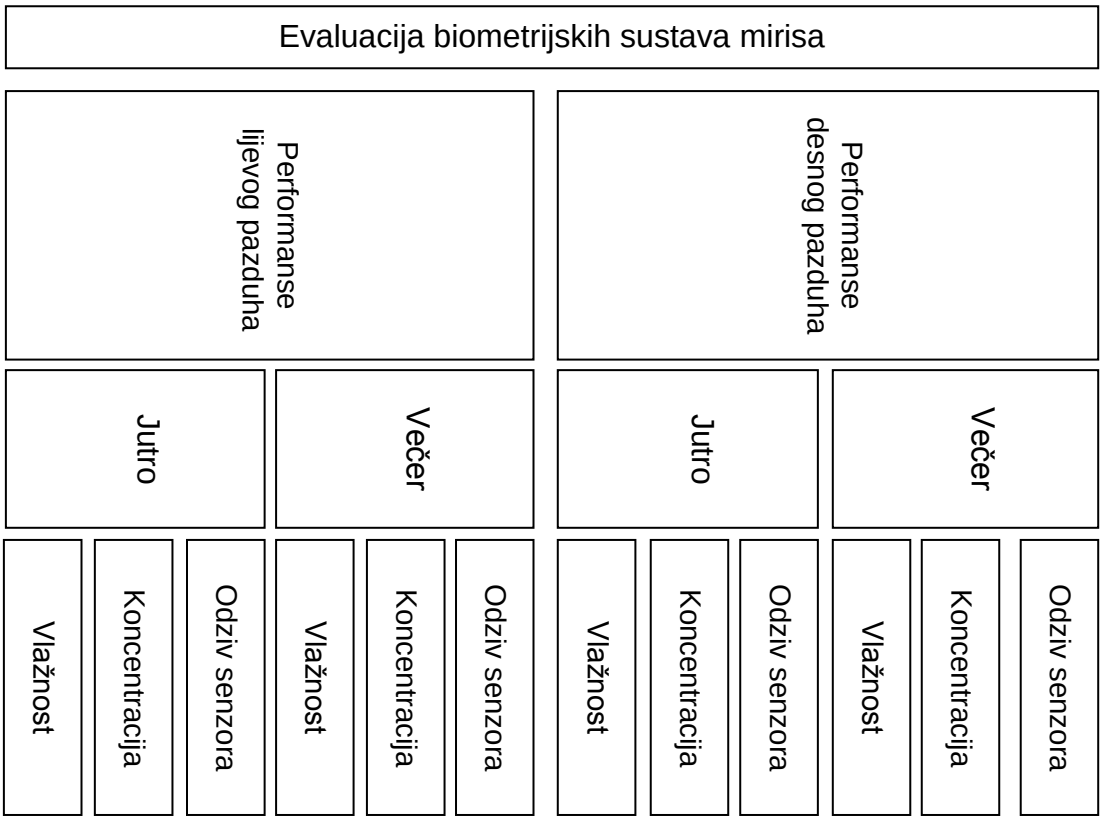
<EvaluacijaBiometrijskihSustavaUha>

   <biometrijskiSustavUha>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <performanseLijevogUha>
            <2d>
               <cmr> vrijednost </cmr>
               <imr> vrijednost </imr>
            </2d>
            <3d>
               <cmr> vrijednost </cmr>
               <imr> vrijednost </imr>
            </3d>
         </performanseLijevogUha>
         <performanseDesnogUha>
            <2d>
               <cmr> vrijednost </cmr>
               <imr> vrijednost </imr>
            </2d>
            <3d>
               <cmr> vrijednost </cmr>
               <imr> vrijednost </imr>
            </3d>
         </performanseDesnogUha>
      </podatci>
   </biometrijskiSustavUha>

</EvaluacijaBiometrijskihSustavaUha>
```

5.1.8. Miris

U poglavlju 2.3. spomenuta je definicija mirisa kao skupa izlučevina ljudskog tijela koji je individualan za svaku osobu, a kao prednosti ove biometrijske karakteristike ističe se to što je neprevarljiva i ne može se maskirati parfemima ili dezodoransima[23]. Autori Chatchawal Wongchoosuk , Mario Lutz i Teerakiat Kerdcharoen su u članku „Detection and Classification of Human Body Odor Using an Electronic Nose“ predstavili shematski prikaz biometrijskog sustava prepoznavanja mirisa pod nazivom E-nose. Prema njima, najveći utjecaj na performanse sustava predstavlja vlažnost zraka, koja je podijeljena u tri kategorije, 25%, 50% i 75%, koncentraciji uzorka (grupiran u 6 kategorija), razdoblju uzimanja uzorka (jutro i večer) te su uzorci klasificirani na lijevi i desni pazuh. Točnost se mjeri na temelju odziva senzora. Prema navedenoj podjeli kreiran je model evaluacije biometrijskih sustava mirisa.



Slika 38. Model evaluacije biometrijskih sustava mirisa

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava mirisa bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavMirisa“. Ona se sastoji od zaglavlja i podataka. Pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava mirisa u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaMirisa>

   <biometrijskiSustavMirisa>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <performanseLijevogPazuha>
            <jutro>
               <vlaznost> vrijednost </vlaznost>
               <koncentracija> vrijednost </koncentracija>
               <odzivSenzora> vrijednost </odzivSenzora>
            </jutro>
            <vecer>
               <vlaznost> vrijednost </vlaznost>
               <koncentracija> vrijednost </koncentracija>
               <odzivSenzora> vrijednost </odzivSenzora>
            </vecer>
         </performanseLijevogPazuha>
         <performanseDesnogPazuha>
            <jutro>
               <vlaznost> vrijednost </vlaznost>
               <koncentracija> vrijednost </koncentracija>
               <odzivSenzora> vrijednost </odzivSenzora>
            </jutro>
            <vecer>
               <vlaznost> vrijednost </vlaznost>
               <koncentracija> vrijednost </koncentracija>
               <odzivSenzora> vrijednost </odzivSenzora>
            </vecer>
```

```
            </performanseDesnogPazuha>
         </podatci>
      </biometrijskiSustavMirisa>

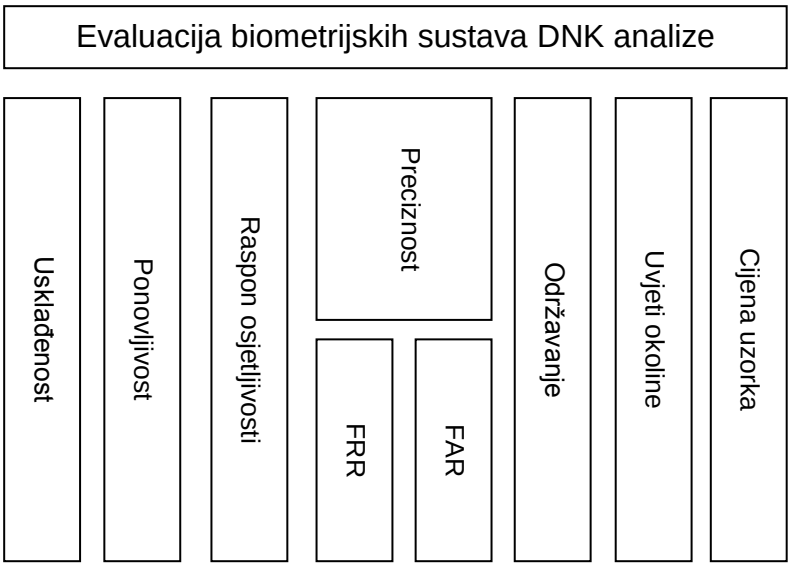
</EvaluacijaBiometrijskihSustavaMirisa>
```

5.1.9. Deoksiribonukleinska kiselina (DNK)

Biometrijska karakteristika DNK smatra se vrlo pouzdanom i posve nenametljivom, pošto je proces uzimanja uzorka jednostavan, a on se kasnije laboratorijski i računalno obrađuje, stoga se smatra vrlo prihvatljivom. Za zasnivanje modela evaluacije biometrijskih sustava DNK analize poslužit će NFSTC-ov „Technology Evaluation Report“. NFSTC je skraćenica od National Forensic Science Technology Center, a predstavlja neprofitnu organizaciju osnovanu na St. Petersburg College sa sjedištem u St. Petersburgu na Floridi. Okvirnu evaluaciju tehnologija forenzičke analize kategorizirali su prema područjima [65]:

- ***Conformity*** – predstavlja sposobnost točne identifikacije
- ***Reproducibility*** – poznati uzorci su višekratno testirani kako bi se utvrdila pouzdanost senzora(instrumenata)
- ***Sensitivity*** – poznati uzorci se testiraju u različitim količinama, kako bi se utvrdio raspon mogućnosti(osjetljivosti) uređaja
- ***Specificity*** – predstavlja performanse utvrđivanja FAR i FRR
- ***Maintenance*** – predstavlja broj „servisa“ instrumenata prilikom „normalnog“ korištenja
- ***Portability*** – predstavlja testiranje instrumenata na različite uvjete okoline
- ***Samples*** – predstavlja obujam posla i uložen trud koji je potreban za pripremu uzorka za testiranje.

Za navedena područja, s ciljem procjene uspješnosti, NFSTC kreira jedinstvene planove testiranja. Po navedenoj kategorizaciji kreiran je model evaluacije biometrijskih sustava DNK analize.



Slika 39. Model evaluacije biometrijskih sustava DNK analize

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava DNK analize bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavDnkAnalize“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava DNK analize u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaDnkAnalize>

   <biometrijskiSustavDnkAnalize>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <uskladjenost> vrijednost </uskladjenost>
         <ponovljivost> vrijednost </ponovljivost>
         <rasponOsjetljivosti> vrijednost </rasponOsjetljivosti>
         <preciznost>
            <frr> vrijednost </frr>
            <far> vrijednost </far>
         </preciznost>
         <odrzavanje> vrijednost </odrzavanje>
         <uvjetiOkoline> vrijednost </uvjetiOkoline>
         <cijenaUzorka> vrijednost </cijenaUzorka>
      </podatci>
   </biometrijskiSustavDnkAnalize>

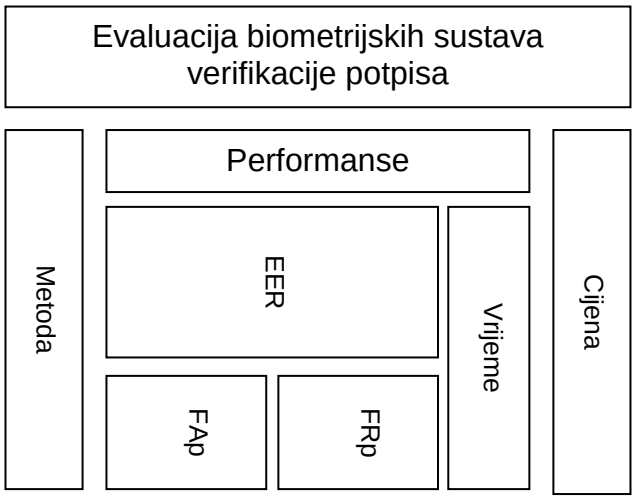
</EvaluacijaBiometrijskihSustavaDnkAnalize>
```

5.2. Model ponašajnih biometrijskih karakteristika

Kao što je već ranije navedeno u poglavlju 2.4. ponašajne biometrijske karakteristike se temelje na bihevioralnim osobinama pojedinca koje ih opisuju jedinstveno po specifičnim obilježjima.

5.2.1. Potpis

Potpis, kao biometrijsku karakteristiku, krasi obilježje lake prikupljivosti i nenametljivosti. Problem predstavlja to što se on kod svake osobe razvija i mijenja s vremenom, pa algoritmi moraju biti u mogućnosti procesirati spomenuti izazov. Postoje dvije metode verifikacije potpisa, statička koja koristi kao uzorak sliku potpisa s papira kako bi se izvršila validacija, te dinamički koji je automatiziran, pri čemu senzor prikuplja prostorne koordinate X i Y, pritisak, azimut, te nagib uzorka u realnom vremenu [24]. Performanse biometrijskog sustava verifikacije potpisa mjere se na Detection Error Tradeof (DET) krivuljama koje se dobivaju izračunom Equal Error Rate (EER) vrijednosti, odnosno presjeka False Acceptance probability (FAp) i False Rejection probability (FRp) [25]. Prema definiranim parametrima, moguće je zasnovati model evaluacije biometrijskih sustava verifikacije potpisa.



Slika 40. Model evaluacije biometrijskih sustava verifikacije potpisa

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava verifikacije potpisa bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavVerifikacijePotpisa“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava verifikacije potpisa u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaVerifikacijePotpisa>

   <biometrijskiSustavVerifikacijePotpisa>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <metoda> vrijednost </metoda>
         <performanse>
            <eer>
               <fap> vrijednost </fap>
               <frp> vrijednost </frp>
            </eer>
            <vrijeme> vrijednost </vrijeme>
         </performanse>
         <cijena> vrijednost </cijena>
      </podatci>
   </biometrijskiSustavVerifikacijePotpisa>

</EvaluacijaBiometrijskihSustavaVerifikacijePotpisa>
```

5.2.2. Glas

Evaluacija biometrijske karakteristike kojom se također pozabavio NIST, je biometrijska karakteristika glasa. Slijedom toga NIST je organizirao Speaker Recognition Evaluation (SRE12), kao dio već postojećih testiranja biometrijskih tehnologija. Krajem ožujka 2016.-te izdali su i „NIST 2016 Speaker Recognition Evaluation Plan“ prema kojem će se provesti testiranje i evaluacija biometrijskih sustava prepoznavanja glasa.

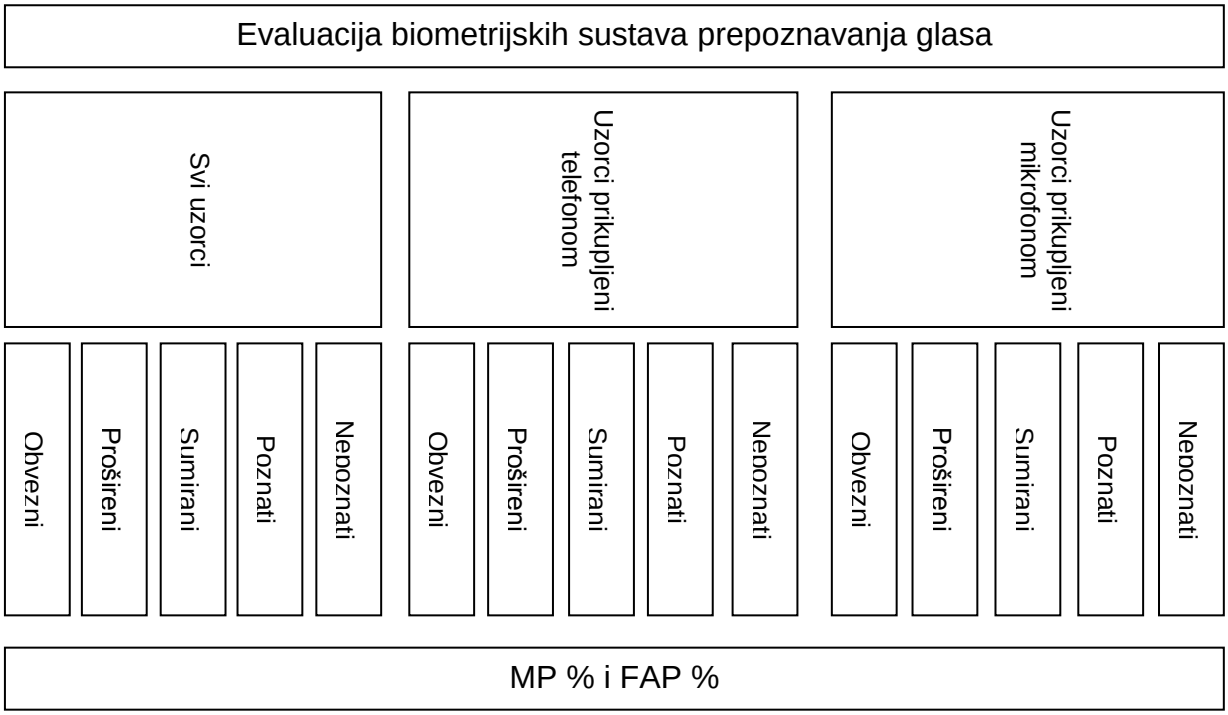
Navedena testiranja daju važan doprinos usmjeravanju istraživačkih napora i kalibracije tehničkih sposobnosti. Primarni cilj testiranja je da budu od koristi i interesa svim zainteresiranim stranama koje rade na generalnom problemu prepoznavanja glasa. U tu svrhu kreiran je jednostavan dizajn s fokusom na temeljna tehnološka pitanja, kako bi rezultati bili u potpunosti podržani i dostupni [57].

Slijedom rezultata koji su proizašli iz SRE12, definirana je klasifikacija prema [58]:

- ***Training Conditions***
    - ***core*** – predstavlja podatke uzoraka svih izvora, uključujući mikrofon i telefon
    - ***telephone*** – predstavlja podatke uzoraka kreiranih kanalom telefona
    - ***microphone*** – predstavlja podatke uzoraka kreiranih kanalom mikrofona.
- ***Test Conditions***
    - ***Core*** – jedan uzorak iz telefonskog razgovora ili intervjua u trajanju između 20 i 160 sekundi
    - ***extended*** – isto kao i kod core test conditions, s time da se povećava broj pokušaja

- ***summed*** – zbroj rezultata kanala dobivenih iz telefonskog razgovora i intervjua, u trajanju od 20 do 160 sekundi
- ***known*** – isto kao i kod extended test conditions, uz pretpostavku sustava da svi neidentificirani uzorci sigurno pripadaju poznatom subjektu
- ***unknown*** – isto kao i kod extended test conditions uz pretpostavku sustava da svi neidentificirani uzorci sigurno ne pripadaju poznatom subjektu.

Rezultati su iskazani prema postotku Miss Probability (MP %) i postotku False Alarm Probability (FAP %). Prema definiranoj klasifikaciji, moguće je zasnovati model evaluacije biometrijskih sustava prepoznavanja glasa.



Slika 41. Model evaluacije biometrijskih sustava prepoznavanja glasa

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava analize glasa bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava

„biometrijskiSustavAnalizeGlasa“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava prepoznavanja glasa u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaPrepoznavanjaGlasa>

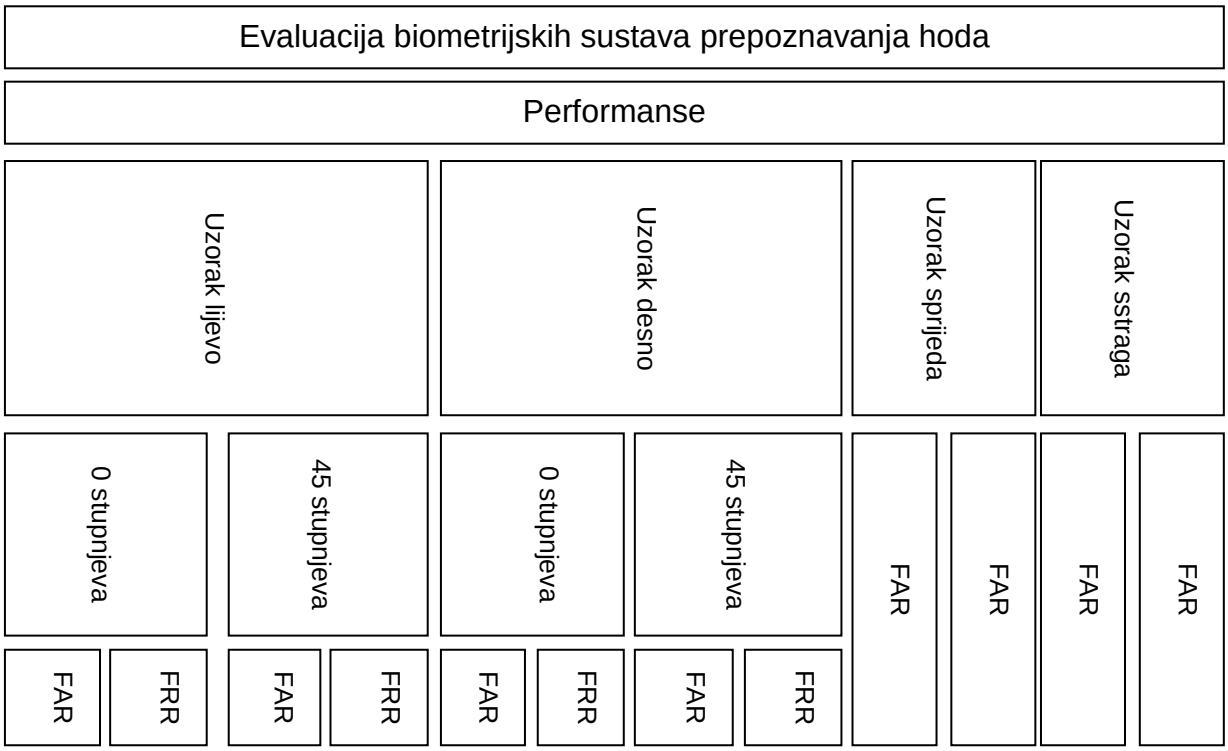
   <biometrijskiSustavPrepoznavanjaGlasa>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <sviUzorci>
            <obvezni>
               <mp> vrijednost </mp>
               <fap> vrijednost </fap>
            </obvezni>
            <prosireni>
               <mp> vrijednost </mp>
               <fap> vrijednost </fap>
            </prosireni>
            <sumarni>
               <mp> vrijednost </mp>
               <fap> vrijednost </fap>
            </sumarni>
            <poznati>
               <mp> vrijednost </mp>
               <fap> vrijednost </fap>
            </poznati>
            <nepoznati>
               <mp> vrijednost </mp>
               <fap> vrijednost </fap>
            </nepoznati>
         </sviUzorci>
         <telefon>
            <obvezni>
               <mp> vrijednost </mp>
               <fap> vrijednost </fap>
            </obvezni>
            <prosireni>
```

```
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </prosireni>
            <sumarni>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </sumarni>
            <poznati>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </poznati>
            <nepoznati>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </nepoznati>
        </telefon>
        <mikrofon>
            <obvezni>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </obvezni>
            <prosireni>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </prosireni>
            <sumarni>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </sumarni>
            <poznati>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </poznati>
            <nepoznati>
                <mp> vrijednost </mp>
                <fap> vrijednost </fap>
            </nepoznati>
        </mikrofon>
    </podatci>
</biometrijskiSustavPrepoznavanjaGlasa>

</EvaluacijaBiometrijskihSustavaPrepoznavanjaGlasa>
```

5.2.3. Hod

Tehnologija prepoznavanja hoda još je u razvojnoj fazi, pošto on predstavlja složenu tjelesnu i prostorno-vremensku ponašajnu biometrijsku karakteristiku uvelike ovisnu o tehnologiji i algoritmima koji je opisuju. Njezina prednost očituje se u tome što je bezkontaktna, ne zahtjeva suradnju promatranog subjekta, a uzorak može biti prikupljen s distance. Stoga će fokus evaluacije biometrijskih sustava hoda biti na spomenutim elementima. U svom radu M. Pushpa Rania i G. Arumugam „An Efficient Gait Recognition System for Human Identification Using Modified ICA“, ističu važnost algoritama prepoznavanja hod-a te uspoređuju svoj novopredloženi model s Principal Component Analysis (PCA) i Independent Component Analysis (ICA). Rezultate su predstavili prema klasifikaciji podataka performansi, koje ovise o kutu pod kojime je uzet uzorak. Grupiranje je izvršeno na uzorke 0° lijevo, 0° desno, 45° lijevo, 45° desno, 90° sprijeda i 90° straga. Rezultati navedenih grupa iskazuju se s False accept rate (FAR) i False reject rate (FRR).



Slika 42. Model evaluacije biometrijskih sustava prepoznavanja hoda

Kako bi XML zapis navedenog modela evaluacije biometrijskih sustava prepoznavanja hoda bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustavPrepoznavanjaHoda“. Ona se sastoji od zaglavlja i podataka, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu i vlasniku, a „podatci“ sadrže vrijednosti evaluacije danog biometrijskog sustava.

Model evaluacije biometrijskih sustava prepoznavanja hoda u XML-u:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustavaPrepoznavanjaHoda>

   <biometrijskiSustavPrepoznavanjaHoda>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
      </zaglavlje>
      <podatci>
         <performanse>
            <uzorakLijevo>
               <nulaStupnjeva>
                  <far> vrijednost </far>
                  <frr> vrijednost </frr>
               </nulaStupnjeva>
               <cetrdesetpetStupnjeva>
                  <far> vrijednost </far>
                  <frr> vrijednost </frr>
               </cetrdesetpetStupnjeva>
            </uzorakLijevo>
            <uzorakDesno>
               <nulaStupnjeva>
                  <far> vrijednost </far>
                  <frr> vrijednost </frr>
               </nulaStupnjeva>
               <cetrdesetpetStupnjeva>
                  <far> vrijednost </far>
                  <frr> vrijednost </frr>
               </cetrdesetpetStupnjeva>
            </uzorakDesno>
            <uzorakSprijeda>
               <far> vrijednost </far>
```

```
                <frr> vrijednost </frr>
            </uzorakSprijeda>
            <uzorakStraga>
                <far> vrijednost </far>
                <frr> vrijednost </frr>
            </uzorakStraga>
        </performanse>
    </podatci>
  </biometrijskiSustavPrepoznavanjaHoda>

</EvaluacijaBiometrijskihSustavaPrepoznavanjaHoda>
```

5.3. Unimodalni sustavi

U kontekstu ovog rada, smatra se da su unimodalni sustavi oni koji obrađuju jednu biometrijsku karakteristiku, bez obzira na to s koliko senzora. Prema tome, model evaluacije unimodalnih sustava, za svaku se pojedinu biometrijsku karakteristiku može pronaći u ranije razrađenim poglavljima 5.1. i 5.2.

Također, OOEPBS koji je spomenut u poglavlju 4.3., može biti primijenjen na unimodalne sustave. Kako bi XML zapis navedenog modela bio potpuniji i strukturno pravilniji, dodana je još jedna razina koja predstavlja skup podataka o jednoj ili više biometrijskih sustava „biometrijskiSustav“. Ona se sastoji od zaglavlja i samog OOEPBS-a, pri čemu „zaglavlje“ sadrži zapise o id-u biometrijskog sustava, njegovom nazivu, vlasniku i cijeni, a opis navedenog modela u XML-u slijedi:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaBiometrijskihSustava>

   <biometrijskiSustav>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
         <cijena> vrijednost </cijena>
      </zaglavlje>
      <ooepbs>
         <aspektTehnologije>
            <softver>
               <pouzdanost> vrijednost </pouzdanost>
            </softver>
            <hardver>
               <pouzdanost> vrijednost </pouzdanost>
            </hardver>
            <performanse>
               <fmr> vrijednost </fmr>
               <fmnr> vrijednost </fmnr>
               <ftaFte> vrijednost </ftaFte>
            </performanse>
         </aspektTehnologije>
```

```
            <aspektOkoline>
               <fizickaSvojstva>
                  <buka> vrijednost </buka>
                  <osvjetljenje> vrijednost </osvjetljenje>
               </fizickaSvojstva>
               <atmosferskaSvojstva>
                  <temperatura> vrijednost </temperatura>
                  <vlaznost> vrijednost </vlaznost>
               </atmosferskaSvojstva>
            </aspektOkoline>
            <aspektKorisnika>
               <karakteristike>
                  <kratkotrocniUtjecaj>
                     <fizicki> vrijednost </fizicki>
                     <ponasajni> vrijednost </ponasajni>
                  </kratkotrocniUtjecaj>
                  <dugorocniUtjecaj>
                     <bolest> vrijednost </bolest>
                     <izgled> vrijednost </izgled>
                  </dugorocniUtjecaj>
               </karakteristike>
               <osobniCinitelji>
                  <antropometrija>
                     <tjelesneDimenzije> vrijednost </tjelesneDimenzije>
                     <tjelesnaObiljezja> vrijednost </tjelesnaObiljezja>
                  </antropometrija>
                  <iskustvo>
                     <uvjezbanostKorisnika> vrijednost </uvjezbanostKorisnika>
                  </iskustvo>
                  <ergonomija>
                     <pozicija> vrijednost </pozicija>
                     <uvjetiKoristenja> vrijednost </uvjetiKoristenja>
                  </ergonomija>
               </osobniCinitelji>
            </aspektKorisnika>
         </ooepbs>
      </biometrijskiSustav>

</EvaluacijaBiometrijskihSustava>
```

5.4. Multimodalni sustavi

U kontekstu ovog rada, pod pojmom multimodalnih sustava smatra se svaki sustav koji pri procesu potvrde identifikacije obrađuje dvije ili više biometrijskih karakteristika.

Primjena OOEPBS-a na multimodalne biometrijske sustave zahtjeva dodatno proširenje. Dodana je razina koja predstavlja skup podataka evaluacije jednog ili više multimodalnih biometrijskih sustava „multimodalniSustav“, koji preuzima raniju funkciju objekta „biometrijskiSuatav“, pa tako sadrži „zaglavlje“ u kojem su podatci o id-u multimodalnog biometrijskog sustava, njegovom nazivu, vlasniku i cijeni. Ovako kreirana struktura ima za cilj evaluaciju dva ili više biometrijskih sustava, pri čemu zbroj rezultata evaluacija predstavlja ukupan rezultat bimodalnog sustava.

Opis navedenog rješenja za evaluaciju multimodalnih biometrijskih sustava u XML-u slijedi:

```
<?xml version="1.0" encoding="UTF-8"?>

<EvaluacijaMultimodalnihBiometrijskihSustava>

   <multimodalniSustav>
      <zaglavlje>
         <id> vrijednost </id>
         <naziv> vrijednost </naziv>
         <vlasnik> vrijednost </vlasnik>
         <cijena> vrijednost </cijena>
      </zaglavlje>
      <biometrijskiSustav_1>
         <ooepbs>
            <aspektTehnologije>
               <softver>
                  <pouzdanosr> vrijednost </pouzdanost>
               </softver>
               <hardver>
                  <pouzdanosr> vrijednost </pouzdanost>
               </hardver>
               <performanse>
                  <fmr> vrijednost </fmr>
                  <fmnr> vrijednost </fmnr>
```

```
            <ftaFte> vrijednost </ftaFte>
         </performanse>
      </aspektTehnologije>
      <aspektOkoline>
         <fizickaSvojstva>
            <buka> vrijednost </buka>
            <osvjetljenje> vrijednost </osvjetljenje>
         </fizickaSvojstva>
         <atmosferskaSvojstva>
            <temperatura> vrijednost </temperatura>
            <vlaznost> vrijednost </vlaznost>
         </atmosferskaSvojstva>
      </aspektOkoline>
      <aspektKorisnika>
         <karakteristike>
            <kratkotrocniUtjecaj>
               <fizicki> vrijednost </fizicki>
               <ponasajni> vrijednost </ponasajni>
            </kratkotrocniUtjecaj>
            <dugorocniUtjecaj>
               <bolest> vrijednost </bolest>
               <izgled> vrijednost </izgled>
            </dugorocniUtjecaj>
         </karakteristike>
         <osobniCinitelji>
            <antropometrija>
               <tjelesneDimenzije> vrijednost </tjelesneDimenzije>
               <tjelesnaObiljezja> vrijednost </tjelesnaObiljezja>
            </antropometrija>
            <iskustvo>
               <uvjezbanosKorisnika> vrijednost </uvjezbanosKorisnika>
            </iskustvo>
            <ergonomija>
               <pozicija> vrijednost </pozicija>
               <uvjetiKoristenja> vrijednost </uvjetiKoristenja>
            </ergonomija>
         </osobniCinitelji>
      </aspektKorisnika>
   </ooepbs>
</biometrijskiSustav_1>

<biometrijskiSustav_2>
   <ooepbs>
      <aspektTehnologije>
         <softver>
            <pouzdanosr> vrijednost </pouzdanost>
         </softver>
```

```
            <hardver>
               <pouzdanosr> vrijednost </pouzdanost>
            </hardver>
            <performanse>
               <fmr> vrijednost </fmr>
               <fmnr> vrijednost </fmnr>
               <ftaFte> vrijednost </ftaFte>
            </performanse>
         </aspektTehnologije>
         <aspektOkoline>
            <fizickaSvojstva>
               <buka> vrijednost </buka>
               <osvjetljenje> vrijednost </osvjetljenje>
            </fizickaSvojstva>
            <atmosferskaSvojstva>
               <temperatura> vrijednost </temperatura>
               <vlaznost> vrijednost </vlaznost>
            </atmosferskaSvojstva>
         </aspektOkoline>
         <aspektKorisnika>
            <karakteristike>
               <kratkotrocniUtjecaj>
                  <fizicki> vrijednost </fizicki>
                  <ponasajni> vrijednost </ponasajni>
               </kratkotrocniUtjecaj>
               <dugorocniUtjecaj>
                  <bolest> vrijednost </bolest>
                  <izgled> vrijednost </izgled>
               </dugorocniUtjecaj>
            </karakteristike>
            <osobniCinitelji>
               <antropometrija>
                  <tjelesneDimenzije> vrijednost </tjelesneDimenzije>
                  <tjelesnaObiljezja> vrijednost </tjelesnaObiljezja>
               </antropometrija>
               <iskustvo>
                  <uvjezbanosKorisnika> vrijednost </uvjezbanosKorisnika>
               </iskustvo>
               <ergonomija>
                  <pozicija> vrijednost </pozicija>
                  <uvjetiKoristenja> vrijednost </uvjetiKoristenja>
               </ergonomija>
            </osobniCinitelji>
         </aspektKorisnika>
      </ooepbs>
   </biometrijskiSustav_2>
```

```
    .
    .
    .
</biometrijskiSustav_n>
   <ooepbs>
      <aspektTehnologije>
         <softver>
            <pouzdanosr> vrijednost </pouzdanost>
         </softver>
         <hardver>
            <pouzdanosr> vrijednost </pouzdanost>
         </hardver>
         <performanse>
            <fmr> vrijednost </fmr>
            <fmnr> vrijednost </fmnr>
            <ftaFte> vrijednost </ftaFte>
         </performanse>
      </aspektTehnologije>
      <aspektOkoline>
         <fizickaSvojstva>
            <buka> vrijednost </buka>
            <osvjetljenje> vrijednost </osvjetljenje>
         </fizickaSvojstva>
         <atmosferskaSvojstva>
            <temperatura> vrijednost </temperatura>
            <vlaznost> vrijednost </vlaznost>
         </atmosferskaSvojstva>
      </aspektOkoline>
      <aspektKorisnika>
         <karakteristike>
            <kratkotrocniUtjecaj>
               <fizicki> vrijednost </fizicki>
               <ponasajni> vrijednost </ponasajni>
            </kratkotrocniUtjecaj>
            <dugorocniUtjecaj>
               <bolest> vrijednost </bolest>
               <izgled> vrijednost </izgled>
            </dugorocniUtjecaj>
         </karakteristike>
         <osobniCinitelji>
            <antropometrija>
               <tjelesneDimenzije> vrijednost </tjelesneDimenzije>
               <tjelesnaObiljezja> vrijednost </tjelesnaObiljezja>
            </antropometrija>
            <iskustvo>
               <uvjezbanosKorisnika> vrijednost </uvjezbanosKorisnika>
            </iskustvo>
```

```
                    <ergonomija>
                        <pozicija> vrijednost </pozicija>
                        <uvjetiKoristenja> vrijednost </uvjetiKoristenja>
                    </ergonomija>
                </osobniCinitelji>
            </aspektKorisnika>
        </ooepbs>
    </biometrijskiSustav_n>

</multimodalniSustav>

</EvaluacijaMultimodalnihSustava>
```

6. ZAKLJUČAK

U današnjem svijetu konstantne terorističke prijetnje, pogotovo nakon 11. rujna i rušenja WTC-a, potaknut je nagli razvoj i istraživanje biometrijskih tehnologija, naročito od strane američke vlade. Također, pozitivan utjecaj na istraživanje i razvoj biometrije kao i prateće tehnologije, imao je i nagli razvoj tehnologija, posebno „pametnih telefona“ i popratnih gadgeta, koji su strelovito napredovali u zadnjem desetljeću, čime su postali pristupačniji širokim masama. Prilikom tog naglog tehnološkog razvoja na vidjelo je isplivao problem očitog nedostatak standardizacije procjene postojećih biometrijskih tehnologija/sustava. U primjeni a i u samom razvoju je velik broj tehnoloških rješenja vezanih za raznolike biometrijske karakteristike, prilikom čega na njihovu primjenjivost i prihvatljivost utječe širok spektar objektivnih i subjektivnih čimbenika. U tome se očituje potreba metodičkog pristupa evaluaciji biometrijskih karakteristika s ciljem postizanja ravnoteže između poslovnih potreba i mogućnosti samog sustava, za što je preduvjet standardizirana procjena.

Standardizirana evaluacija predstavljala bi temelj za sam standard procijene biometrijskih sustava, odnosno objektivnu procjenu samih karakteristika te njihovu poslovnu primjenjivost. S tim ciljem su i kreirani standardizirani testovi koji se provode od strane neprofitnih organizacija kao što je npr. NIST, na kojima sudjeluju dobrovoljno sami proizvođači biometrijskih sustava.

Kao što je već ranije navedeno, primarni cilj i svrha ovog rada je zasnivanje modela evaluacije biometrijskih karakteristika u XML-u, s ciljem omogućavanja unificiranog i standardiziranog procesa odabira biometrijskog sustava. Proučavanje i pregled postojećih standarda evaluacije biometrijskih sustava te temeljem njihovih rezultata i kategorizacije, omogućeno je zasnivanje modela evaluacije biometrijskih sustava u XML-u.

Uspješnim kreiranjem modela evaluacije biometrijskih sustava u XML-u, u radu navedenih biometrijskih karakteristika pojedinačno kao i za unimodalne te multimodalne biometrijske sustave, dan je temelj za prihvaćanje hipoteze ovog rada.

Prema definiranom modelu, svaki proizvođač bi mogao rezultate evaluacije opisati XML-om, učiniti ih javno dostupnima kako bi zainteresirane strane bile u mogućnosti dohvatiti i usporediti ih s podatcima evaluacije drugih proizvođača. Time je omogućeno provođenje evaluacije te određivanje najprikladnijeg i najprihvatljivijeg biometrijskog sustava za primjenu u određenoj organizaciji s obzirom na njene specifičnosti i potrebe.

Nikola Buden

POPIS LITERATURE

[1] M. Schatten, M. Bača, and M. Čubrilo (2010) "Towards a General Definition of Biometric Systems," IJCSI Int. J. Comput. Sci. Issues, vol. 7, no. 4, p. 1.

[2] John D. Woodward, Jr., Nicholas M. Orlans, and Peter T. Higgins (2003) „Biometrics", New York,McGraw Hill Osborne, str. 58.

[3] Jain, A. K., Flynn, P., Ross, A. (2008) Handbook of Biometrics, Springer, New York, str.4.

[4] J. L. Wayman (2004) „Biometrics – Now and Then: The development of Biometrics over the last 40 years" SecuMedia, Vol. 2 Issue 10.

[5] Želimir Rradmilović (2008) „Biometrijska identifikacija", stručni članak, str 172.

[6] Ted Dunstone (2008) Biometric System and Data Analysis: Design, Evaluation, and Data Mining, str. 104.

[7] Harold, E. R. (1999) The XML Bible, John Wiley & Sons, Hooboken, str. 17-98.

[8] Connolly, D. (2005) XML: Principles, Tools, and Techniques, Paperback, New York, str. 121-129.

[9] Goldfarb, C. F., PrescodThe, P. (2004) XML Handbook, Paperback, New York, str. 15-37.

[10] Charles F. Goldfarb (1990) „The SGML Handbook", Clarendon Press, str.36-38.

[11] IEEE (2013), Certified Biometrics Professional (CBP) Program, vol. 3. p. 54.

[12] Mohamad El-Abed and Christophe Charrier (2012) "Evaluation of Biometric Systems", str. 155.

[13] S. Elliott (2012) "Evolution of the Human Biometric Sensor Interaction" in *International Biometric Performance Testing Conference (ICBP 2012)*, str. 9-21.

[14] Ma Belén Fernández Saavedra (2013) "Evaluation Methodologies for Security Testing of Biometric Systems beyond Technological Evaluation," UNIVERSIDAD CARLOS III DE MADRID, str. 43-57.

[15] Zoran Ćosić, " Metoda evaluacije pouzdanosti biometrijskih sustava," Sveučilište u Zagrebu, FOI Varaždin, 2015, str. 68-83.

[16] J. Mahier, M. Pasquet, C. Rosenberger, and F. Cuozzo. (2008) „Biometric authentication. *Encyclopedia of Information Science and Technology"*, str. 346.

[17] XML Common Biometric Format, OASIS Standard, approved August 2003, Edited by John Larmouth, Individual Member

[18] Markus Schatten (2007) „Zasnivanje otvorene ontologije odabranih segmenata biometrijske znanosti“, str. 36.

[19] NISTIR 8052 (2014) Face Recognition Vendor Test (FRVT) Performance of Automated Gender Classification Algorithms, str. 4.

[20] NISTIR 8034 (2010) „Fingerprint Vendor Technology Evaluation (FpVTE) - Evaluation of Fingerprint Matching Algorithms“, str. 22.-74.

[21] NISTIR 7408 (2006) „FRVT 2006 and ICE 2006 Large-Scale Results“, str. 9.

[22] Ping Yan i Kevin W. Bowyer (2005) „Empirical Evaluation of Advanced Ear Biometrics“, str.6

[23] P.Inbavalli , G.Nandhini (2014) „Body Odor as a Biometric Authentication“, str. 5.

[24] Houmani, Nesmaa; A. Mayoue, S. Garcia-Salicetti, B. Dorizzi, M.I. Khalil, M. Mostafa, H. Abbas, Z.T. Kardkovàcs, D. Muramatsu, B. Yanikoglu, A. Kholmatov, M. Martinez-Diaz, J. Fierrez, J. Ortega-Garcia, J. Roure Alcobé, J. Fabregas, M. Faundez-Zanuy, J. M. Pascual-Gaspar, V. Cardeñoso-Payo, C. Vivaracho-Pascual (2012)."BioSecure signature evaluation campaign (BSEC'2009): Evaluating online signature algorithms depending on the quality of signatures". *Pattern Recognition* 45 (3).

[25] Ruben Vera-Rodriguez, Julian Fierrez, Aythami Morales, Javier Ortega-Garcia (2015) „Dynamic signature recognition for automatic student autentication“, Departamento de Tecnologia Electronica y de las Comunicaciones, EPS, Universidad Autonoma de Madrid (SPAIN).

[26] T. D. and Y. Neil (2009) Biometric Systems and Data Analysis. Design, Evaluation, and Data Mining. Springer-Verlag, NewYork, str. 158.

*****

[27] NSTC (2006), preuzeto 25.7.2008 s http://www.biometrics.gov/Documents/BioHistory.pdf, učitano.

[28] Amy Zalman, Ph.D. Global Terrorism Expert, preuzeto 7.1.2016. s http://terrorism.about.com/od/controversialtechnologies/i/Biometrics.htm

[29] Evan Ratliff, preuzeto 8.1.2016. s http://www.wired.com/2005/12/homeland/?pg=2&topic=homeland&topic_set=

[30] Video Surveillance Systems, preuzeto 11.1.2016. s http://www.video-surveillance-guide.com/biometric-technology.htm

[31] SWAGFAST, preuzeto 11.1.2016. s http://www.swgfast.org/documents/glossary/090508_Glossary_2.0.pdf
[32] Vein Biometric Home page, preuzeto 25.10.2007. s http://homepage.ntlworld.com/joseph.rice/
[33] Security Systems Technology Ltd., preuzeto 12.1.2016. s http://www.sstgroup.co.uk/solutions/palm-vein-scanners/
[34] Fujitsu PalmSecure, preuzeto 13.1.2016. s http://www.fujitsu.com/global/solutions/business-technology/security/palmsecure/
[35] MUP HR, preuzeto 13.1.2016. s http://www.mup.hr/UserDocsImages/muzej/izlozbe/2010/rukopisIdentiti.pdf
[36] Wikipedia, preuzeto 13.1.2016. s https://en.wikipedia.org/wiki/Retinal_scan
[37] Homeland Defense and Security Information Analysis Center, preuzeto 8.1.2016. s https://www.hdiac.org/facial_thermograph
[38] Arun Ross, preuzeto 12.4.2016. s http://www.biometrics.org/bc2011/presentations/FaceTechnology/0928_1600_Mr15_Ross.pdf
[39] Ayman Abaza, Arun Ross, preuzeto 12.4.2016. s http://www.cse.msu.edu/~rossarun/pubs/AbazaEarSymmetry_BTAS2010.pdf
[40] Wikipedia, preuzeto 18.1.2016 s https://hr.wikipedia.org/wiki/Deoksiribonukleinska_kiselina
[41] Wikipedia, preuzeto 18.1.2016 s https://en.wikipedia.org/wiki/Signature_recognition
[42] Authentify, preuzeto 19.1.2016. s http://authentify.com/solutions/authentication-concepts/voice-biometric-authentication/
[43] New Scientist, preuzeto 19.1.2016 s https://www.newscientist.com/article/mg21528835-600-cameras-know-you-by-your-walk/
[44] W3C, preuzeto 19.1.2016. s https://www.w3.org/TR/2006/REC-xml-20060816/
[45] W3C, preuzeto 19.1.2016. s https://www.w3.org/Consortium/Legal/2002/copyright-documents-20021231
[46] W. Eliot Kimber, preuzeto 19.1.2016. s http://drmacros-xml-rants.blogspot.hr/2006/11/xml-ten-year-aniversary.html
[47] National Technical University of Athens, preuzeto 19.1.2016. s http://www.dblab.ntua.gr/~bikakis/XML%20and%20Semantic%20Web%20W3C%20Standards%20Timeline-History.pdf, učitano 19.1.2016.
[48] Wikipedia, preuzeto 19.1.2016. s https://en.wikipedia.org/wiki/XML

[49] Internet Engineering Task Force, preuzeto 20.1.2016. s https://tools.ietf.org/html/rfc7303
[50] ResearchGate, preuzeto 1.5.2016. s https://www.researchgate.net/figure/274009253_fig1_Figure-1-The-Original-HBSI-Model
[51] 360 Biometrics, preuzeto 2.5.2016. s http://360biometrics.com/faq/fingerprint_scanners.php
[52] OASIS, preuzeto 3.5.2016. s https://www.oasis-open.org/org
[53] OASIS, preuzeto 3.5.2016. s https://www.oasis-open.org/news/pr/xml-common-biometric-format-xcbf-ratified-as-oasis-standard
[54] OASIS, preuzeto 4.5.2016. s http://xml.coverpages.org/XCBFv11-OasisStandard.pdf
[55] Cover pages, preuzeto 3.5.2016. s http://xml.coverpages.org/xcbf.html
[56] M2SYS Blog On Biometric Technology, preuzeto 14.5.2016. s http://blog.m2sys.com/biometric-hardware/iris-recognition-vs-retina-scanning-what-are-the-differences/
[57] NIST, preuzeto 15.5.2016. s http://www.nist.gov/itl/iad/mig/sre12.cfm
[58] NIST, preuzeto 15.5.2016. s http://www.nist.gov/itl/iad/mig/sre12results.cfm
[59] WIRED, preuzeto 23.1.2016. s http://www.wired.co.uk/article/google-glass-facial-recognition
[60] Wikipedia, preuzeto 19.1.2016. s https://en.wikipedia.org/wiki/Fingerprint
[61] Authentication technologies, preuzeto 23.1.2016. s http://biometrics.pbworks.com/w/page/14811351/Authentication%20technologies
[62] Scriptel, preuzeto 27.1.2016. s http://scriptel.com/products/compact-lcd-signature-pad/
[63] Plumvoice, preuzeto 22.1.2016. s http://www.plumvoice.com/resources/blog/voice-biometrics-preventing-contact-center-fraud/
[64] Gizmodo, preuzeto 4.6.2016. s http://www.gizmodo.com.au/2016/04/how-your-bodys-unique-biosignatures-are-used-for-surveillance/
[65] NSFTC, preuzeto 22.5.2016. s https://www.nfstc.org/past-performance/forensic-technology-center-of-excellence/

PRILOG

PRILOG A – OASIS XCBF

```
<?xml version="1.0" encoding="UTF-8"?>

<BiometricSyntaxSets>
   <integrityObjects>
      <biometricObjects>
         <BiometricObjects>

            <BiometricObject>
               <biometricHeader>
                  <version> 0 </version>
                  <recordType> <id> 4 </id> </recordType>
                  <dataType> <processed/> </dataType>
                  <purpose> <audit/> </purpose>
                  <quality> -1 </quality>
                  <validityPeriod>
                     <notBefore> 1998.10.1 </notBefore>
                     <notAfter> 2008.10.1 </notAfter>
                  </validityPeriod>
                  <format>
                     <formatOwner>
                        <oid> 2.23.42.9.10.4.2 </oid>
                     </formatOwner>
                  </format>
               </biometricHeader>
               <biometricData>
                  0102030405060708090A0B0C0D0E0F11
               </biometricData>
            </BiometricObject>

            <BiometricObject>
               <biometricHeader>
                  <version> 0 </version>
                  <recordType> <id> 4 </id> </recordType>
                  <dataType> <intermediate/> </dataType>
                  <purpose> <enroll/> </purpose>
                  <quality> 50 </quality>
                  <validityPeriod>
                     <notBefore> 1998.10.2 </notBefore>
                     <notAfter> 2008.10.2 </notAfter>
                  </validityPeriod>
                  <format>
```

```
                <formatOwner>
                   <oid> 2.23.42.9.10.4.2 </oid>
                </formatOwner>
             </format>
          </biometricHeader>
          <biometricData>
             0102030405060708090A0B0C0D0E0F11
             0102030405060708090A0B0C0D0E0F11
          </biometricData>
       </BiometricObject>

       <BiometricObject>
          <biometricHeader>
             <version> 0 </version>
             <recordType> <id> 4 </id> </recordType>
             <dataType> <raw/> </dataType>
             <purpose> <enroll/> </purpose>
             <quality> 100 </quality>
             <validityPeriod>
                <notBefore> 1998.10.3 </notBefore>
                <notAfter> 2008.10.3 </notAfter>
             </validityPeriod>
             <format>
                <formatOwner>
                   <oid> 2.23.42.9.10.4.2 </oid>
                </formatOwner>
             </format>
          </biometricHeader>
          <biometricData>
             0102030405060708090A0B0C0D0E0F110102030405060708
             090A0B0C0D0E0F11010203040506070809 0A0B0C0D0E0F11
          </biometricData>
       </BiometricObject>

    </BiometricObjects>
</biometricObjects>

<integrityBlock>
    <signedData>
       <version> 84 </version>
       <digestAlgorithms>
          <DigestAlgorithmIdentifier>
             <algorithm> 1.3.14.3.2.26 </algorithm>
             <parameters> <NullParms/> </parameters>
          </DigestAlgorithmIdentifier>
       </digestAlgorithms>
       <encapContentInfo>
```

```
            <eContentType> 1.2.840.113549.1.7.1 </eContentType>
         </encapContentInfo>
         <signerInfos>
            <SignerInfo>
               <version> 84 </version>
               <sid>
                  <certHash>
                     <withAlgID>
                        <hashAlgorithm>
                           <algorithm> 1.3.14.3.2.26 </algorithm>
                           <parameters>
                                 <NullParms/>
                              </parameters>
                        </hashAlgorithm>
                        <digest>
                         DA9245BCD6E666749F43C1A1BD070BAF259B70AA
                        </digest>
                     </withAlgID>
                  </certHash>
               </sid>
               <digestAlgorithm>
                  <algorithm> 1.3.14.3.2.26 </algorithm>
                  <parameters> <NullParms/> </parameters>
               </digestAlgorithm>
               <signatureAlgorithm>
                  <algorithm> 1.2.840.10040.4.3 </algorithm>
                  <parameters> <NullParms/> </parameters>
               </signatureAlgorithm>
               <signature>
                     302C021411BC0D3A74CAD4FA14C263C1B0556C68D7DBF5
                     E60214596C21B62E3715DE81D65F09C21B6CFA3998A5B0
               </signature>
            </SignerInfo>
         </signerInfos>
      </signedData>
   </integrityBlock>

</integrityObjects>
</BiometricSyntaxSets>
```

Bazična dokumentacijska kartica na hrvatskom jeziku

MRIZ 18 (FOI - Sveučilište Zagreb)
Završni specijalistički rad

Zasnivanje modela evaluacije biometrijskih karakteristika u XML-u

N. Buden
Fakultet organizacije i informatike
Varaždin, Hrvatska

Rad se bavi zasnivanjem modela u XML-u koji bi poslužio za evaluaciju biometrijskih karakteristika te olakšao i pojednostavio odabir najprikladnije karakteristike/sustava određenoj organizaciji. Rad je u osnovi podijeljen na dva dijela. Prvi dio odnosi se na proučavanje tematike s ciljem pobližeg upoznavanja problematike, uz potrebu uvođenja i zasnivanja modela evaluacije biometrijskih sustava u XML-u. Drugi dio odnosi se na pregled postojećih standarda za evaluaciju biometrijskih sustava, te temeljem njihovih rezultata i kategorizacije, zasnivanje modela evaluacije biometrijskih sustava u XML-u.

Rad je nastao na ideji i prepoznatoj potrebi postojanja unificiranog modela procjene biometrijskih sustava. Prema definiranom modelu, svaki proizvođač bi mogao rezultate evaluacije opisati XML-om, učiniti ih javno dostupnima te zainteresiranim stranama pružiti mogućnost usporedbe s podatcima evaluacije drugih proizvođača. Time je omogućeno provođenje evaluacije te određivanje najprikladnijeg i najprihvatljivijeg biometrijskog sustava za primjenu u određenoj organizaciji s obzirom na njene specifičnosti i potrebe.

Voditelj rada: Prof.dr.sc. M. Bača

Povjerenstvo za ocjenu i obranu: *Prof.dr.sc. Miroslav Bača*
Prof.dr.sc. Željko Hutinski
Prof.dr.sc. Mirko Čubrilo

Obrana: 24. veljače 2017. **Promocija:**

Rad je pohranjen u Biblioteci Fakulteta organizacije i informatike u Varaždinu.

(117 stranica, 42 slike, 2 tablice, 65 referenci, original na hrvatskom jeziku).

N. Buden

MRIZ-18

1. Zasnivanje modela evaluacije biometrijskih karakteristika u XML-u

I. Buden, N.

II. Fakultet organizacije i informatike
Varaždin, Hrvatska

biometrija
biometrijske karakteristike
evaluacija biometrijskih karakteristika
XML
model evaluacije biometrijskih karakteristika

Basic documentation card in English language

MRIZ 18 (FOI – University of Zagreb)
Master of Specialist Thesis

Establishment of evaluation model of biometric characteristics in the XML

N. Buden
Faculty of Organization and Informatics
Varaždin, Croatia

The thesis is focused on establishing the evaluation model in XML that could be used for evaluation of biometric characteristics/systems and to facilitate and simplify the selection of the most appropriate biometric system for a specific organization. The thesis is divided into two parts. The first part refers to the study of the topic with the need of introducing and establishing an evaluation model of biometric systems in XML. The second part refers to the overview of existing standards for the evaluation of biometric systems, and based on those results and categorization, the establishment of the evaluation model for biometric systems in XML.

This thesis is based on the idea, and recognized need, for a unified evaluation model of biometric systems. Per the defined model, each manufacturer could describe the results of the evaluation in XML, make them available to the public and interested parties so they could have the possibility to compare with data evaluation of other manufacturers. This allows the implementation of the evaluation and determination of the most appropriate and most acceptable biometric system for use in a specific organization in accordance with its specific needs.

Supervisor: *Full Prof. M. Bača, Ph.D.*

Examiners: *Full Prof. Miroslav Bača, Ph.D.*
Full Prof. Željko Hutinski, Ph.D.
Full Prof. Mirko Čubrilo, Ph.D.

Oral examination: 24th February 2017. **Promotion:**

The thesis deposited at the Library of the Faculty of Organiziation and Informatiacs, Varaždin.

(117 pages, 42 figures, 2 tables, 65 references, original in Croatian).

N. Buden

MRIZ-18

1. Establishment of evaluation model of biometric characteristics in the XML

I. Buden, N.

II. Faculty of Organization and Informatics
Varaždin, Croatia

biometry
biometric characteristics
evaluation of biometric characteristics
XML
evaluation model of biometrics characteristics

Životopis

Nikola Buden rođen je 1. studenoga 1980. godine u Varaždinu. Osnovnu školu završio je u Vinici, a Prirodoslovno-matematičku gimnaziju 1999. godine u Varaždinu. Diplomirao je na Fakultetu organizacije i informatike u Varaždinu 2005. godine na smjeru Informacijski sustavi s temom „Primjena aplikacije SWING Human Resources u upravljanju ljudskim potencijalima“ (mentor: Prof. dr. sc. Marijan Cingula, redoviti profesor). Nedugo nakon toga, na istom fakultetu 2007. godine upisuje poslijediplomski specijalistički studij Sigurnost i revizija informacijskih sustava.

Od rujna 2005. godine radi kao Software developer u Siemens d.d. Tijekom poslovnog odnosa u Siemensu, radi na dva velika projekta, jedan vezan uz bankarske aplikacije, a drugi uz izradu poslovne, projektne i financijske aplikacije MAPIS koristeći širok spektar programskih jezika i alata.

Krajem 2008. Godine prelazi u Konzum d.d. na poziciju Oracle DBA, gdje potpuno mijenja tehnologiju te s ranije Windows platforme prelazi na UNIX/linux okruženja. Kao Oracle DBA radi na administraciji i održavanju 9i i 10g baza, te središnje DWH baze u koju su se punili podatci svih transakcija Konzum trgovina iz Hrvatske, Bosne i Hercegovine te IDEA trgovina iz Srbije. Također radi na administraciji baza lokalno distributivnih centara te instalaciji i održavanju centralnog sustava nadzora Oracle produkata, Oracle Enterprise Manager 11g. Potpora je razvojnom timu programera rekreiranjem baza i novih razvojnih okolina temeljenih na Oracle tehnologiji. Krajem 2010. godine dodijeljena mu je i dužnost koordinatora informacijske sigurnosti, prilikom čega surađuje s funkcijski nadređenima iz informacijske sigurnosti Agrokora, te sudjeluje na projektima DRP, BIA, ISO14001, te Vulnerability test project.

U travnju 2011. prelazi u s-IT Solutions d.o.o, članicu Erste Bank grupe u Hrvatskoj kao Projektant-inženjer sistemske podrške (Oracle DBA). U s-IT Solutions-u radi na održavanju Oracle baza core banking sustava, kao i DWH sustava u međunarodnom okruženju, redom Erste&Steiermärkische Bank d.d. Hrvatska, Erste Bank a.d. Novi Sad, te Erste Bank AD Podgorica. Potpora je IT razvoju banke te sudjeluje u velikim projektima razvoja i implementacije bankarskog sustava u navedenom internacionalnom okruženju.

U lipanju 2015. godine prelazi u Erste&Steiermärkische Bank d.d. na poziciju Viši stručni suradnik za sigurnost digitalnog bankarstva, baveći se nadzorom i sigurnošću usluga digitalnog bankarstva, kao što su NetBanking, mBanking i Erste Wallet.

Rujan 2016. godine predstavlja prekretnicu i promjenu karijere prelaskom u solicon-IT GmbH na poziciju Senior Consultant na području Data Management-a, gdje radi i danas, pružajući potporu klijentima glede Oracle i MS SQL baza podataka, kao i Oracle Middleware-a.

Sretno je oženjen i otac dviju kćeri, Doroteje i Dominike.