Metoda identifikacije osoba putem irisa

Tomić, Mario

Undergraduate thesis / Završni rad

2017

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:283953

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

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

Sveučilišni studij računarstva

METODA IDENTIFIKACIJE OSOBA PUTEM IRISA

Završni rad

Mario Tomić

Osijek, 2017.

SADRŽAJ

1. UVOD 1

1.1. Zadatak završnog rada 2

2. POVIJEST IDENTIFIKACIJE PUTEM IRISA 3

3. UZORKOVANJE 4

3.1. Aproksimacija irisa 4

4. METODE 7

4.1. Fourier-Mellinova transformacija 7

4.2. Haar wavelet 8

5. OSTALE METODE IDENTIFIKACIJE 11

6. ZAKLJUČAK 13

7. LITERATURA 14

8. SAŽETAK 16

9. ABSTRACT 17

10. ŽIVOTOPIS 18

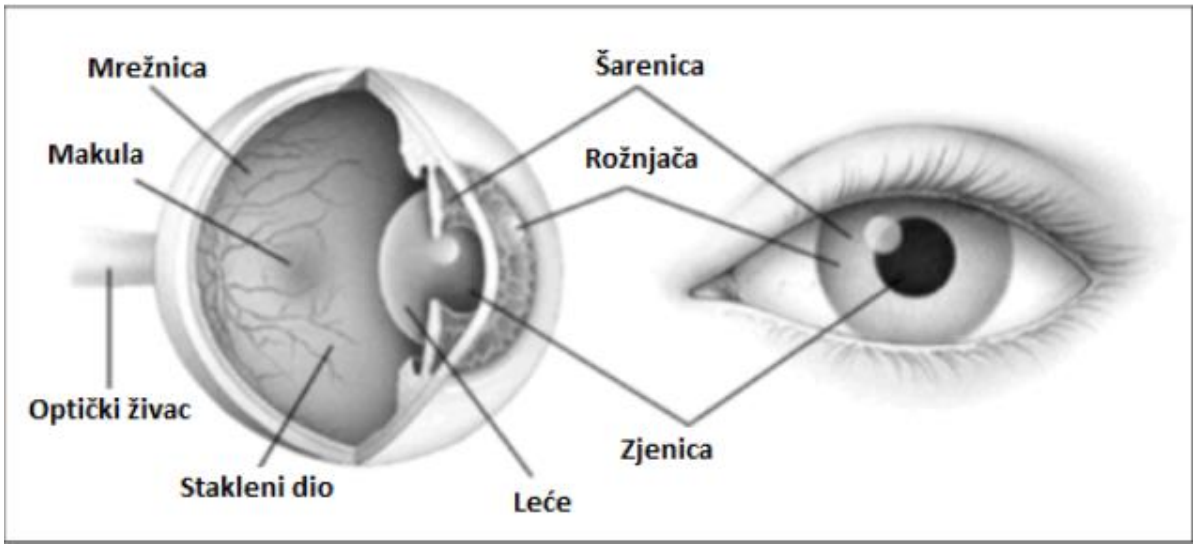
1. UVOD

Svaka osoba, životinja, predmet ili bolje rečeno bilo koja stvar u prirodi razlikuje se od svih drugih. Ponekad su razlike između njih očite, pa je identitet stvari jednostavno utvrditi. No, često su stvari iste vrste poprilično slične i nemoguće ih je razlikovati ako ne koristimo određene metode, kojima će se otkriti i u postupku prepoznavanja upotrijebiti detalji po kojima su stvari ipak različite.

Identitet je skup nepromjenjivih svojstva koja tvore određenu osobu, predmet ili objekt prema kojima se ona/ono može razlikovati od ostalih. Takav skup karakteristika, odnosno pojedinačnih svojstava predstavlja individualnost.

Identifikacija ili prepoznavanje osoba uspoređivanje je nepoznatog s ranije poznatim, na temelju nekih identifikacijskih obilježja.

Tehnologija prepoznavanja osoba putem očne šarenice počela se razvijati 1992. godine i vrlo je moderna komercijalna biometrijska tehnologija. Tehnologija se temelji na vidljivim svojstvima šarenice oka (eng. *eye's iris*) (prsten u boji, u području oko zjenice oka) (eng. *pupil*) (Sl. 1.1).



Slika 1.1: Šarenica i ostali dijelovi oka. [16]

Utvrđeno je da kao što svaka osoba ima jedinstvene otiske prstiju, također ima i jedinstvene očne šarenice. S obzirom na to da se šarenice u potpunosti formiraju u prvih 6 mjeseci i gotovo su nepromjenjive s obzirom na fizički razvoj i bolesti, ova metoda je postala poprilično popularan način identifikacije.

1.1. Zadatak završnog rada

Objasniti način rada programa koji identificira osobe putem očne šarenice i u kojim je slučajevima dobro koristiti baš ovu metodu. Pojasniti postupak identificiranja počevši od uzorkovanja, pa sve do formuliranja jedinstvenog koda šarenice i u konačnici utvrđivanja identiteta.

2. POVIJEST IDENTIFIKACIJE PUTEM IRISA

Zamisao prepoznavanja osoba putem irisa prvi je predložio Dr. Frank Burch 1939. godine. Metoda se prvi put počela primjenjivati kada je Dr. John Daugman stvorio odgovarajuće algoritme. Navedeni algoritmi baziraju se na uzimanju uzoraka i matematičkim izračunima za prepoznavanje irisa.

Hashemitsko Kraljevstvo Jordan - 2009, IrisGuard je implementirao prvi operativni iris na svijetu koji je omogućio bankomat (ATM) u Cairo Amman banci, gdje klijenti banke mogu nesmetano podići gotovinu iz bankomata bez kreditne kartice ili PIN-a, već jednostavno približavanjem oka na iris Fotoaparat za prepoznavanje na bankomatu. Prilikom stvaranja računa u banci klijentima su morali fotografirati oči kako bi mogli koristiti taj način identifikacije (Sl. 2.1).



Slika 2.1: IrisGuard učlanjivanje i uzimanje uzoraka. [10]

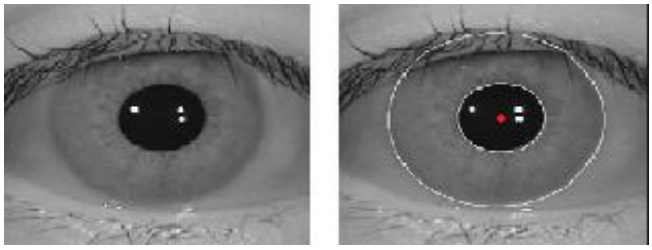
3. UZORKOVANJE

Da bi bilo moguće identificirati osobu putem irisa, najprije je potrebno prije početka identifikacije imati fotografije oka za određene identitete.

Prilikom identificiranja se mogu pojaviti otežavajuće okolnosti zbog kojih identificiranje može postati otežano.

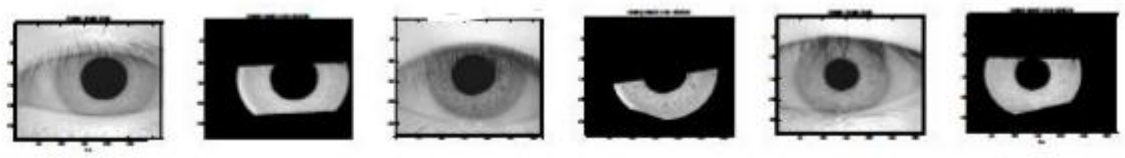
Otežavajuće okolnosti su slabija kvaliteta fotografije zbog slabe osvijetljenosti, očni kapci koji smanjuju količinu podataka za obradu, trepavice koje proizvode sjenu preko šarenice, promjena veličine zjenice zbog različitog osvjetljenja itd., pa je preporučljivo prilikom uzimanja uzoraka za određene identitete uzeti više uzoraka pod različitim kutem fotografiranja.

Prilikom obrade fotografije potrebno je što preciznije locirati središte zjenice, otkriti vanjsku kružnicu šarenice i ukloniti smetnje(Sl. 3.1).



Slika 3.1: Lociranje središta zjenice i vanjske kružnice šarenice

Zbog otežavajućih okolnosti se prilikom identificiranja uzimaju u obzir samo dijelovi šarenice nezahvaćeni smetnjama(Sl. 3.2).



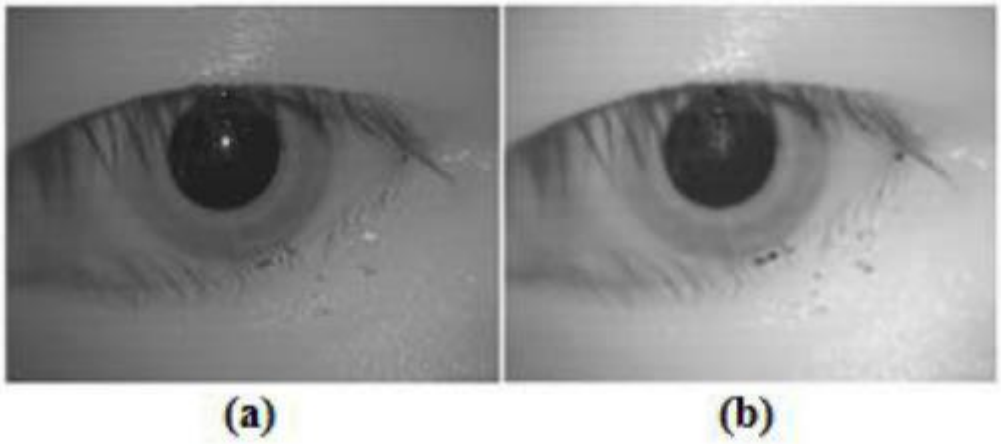
Slika 3.2: Područja šarenice koja se uzimaju u obzir.

3.1. Aproksimacija irisa

Kako bismo mogli odrediti kružnicu šarenice, moramo aproksimirati njezin radijus. To možemo učiniti tako da brojnim uspoređivanjem slučajno zadanih radijusa kružnice i stvarne šarenice dođemo do najodgovarajućeg radiusa.

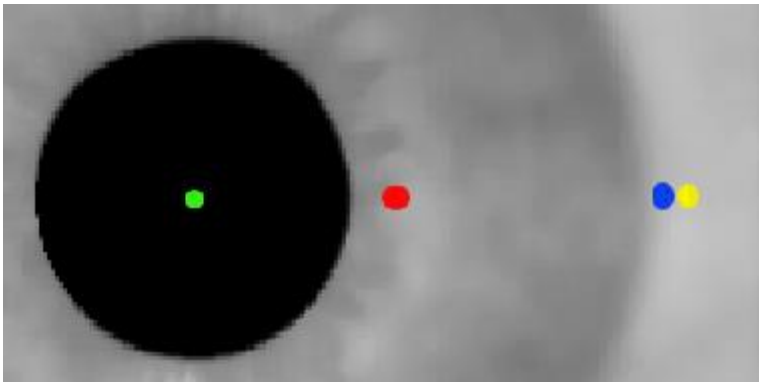
Najprije je potrebno pronaći središte zjenice, pa na horizontalnoj crti označiti točkama završetak zjenice tj. Početak šarenice i u konačnici krajnjom točkom označiti završetak šarenice. Korištenjem horizontalne crte smanjena je mogućnost da će slabije otvoreno oko, trepavice ili

sjena od trepavica utjecati na određivanje karakteristika čime se ujedno i povećava točnost određivanja granica. Boljoj točnosti pridonosi i median filter (Sl. 3.3) koji zamagli fotografiju te samim time smanjuje brojne smetnje (npr. utjecaj osvjetljenja). Nakon toga šarenica se dodatno izoštrava da bi izbjegli nepreciznost ili gubljenje podataka.



Slika 3.3: Prikaz šarenice prije (a) i nakon primjene median filtera(b). [15]

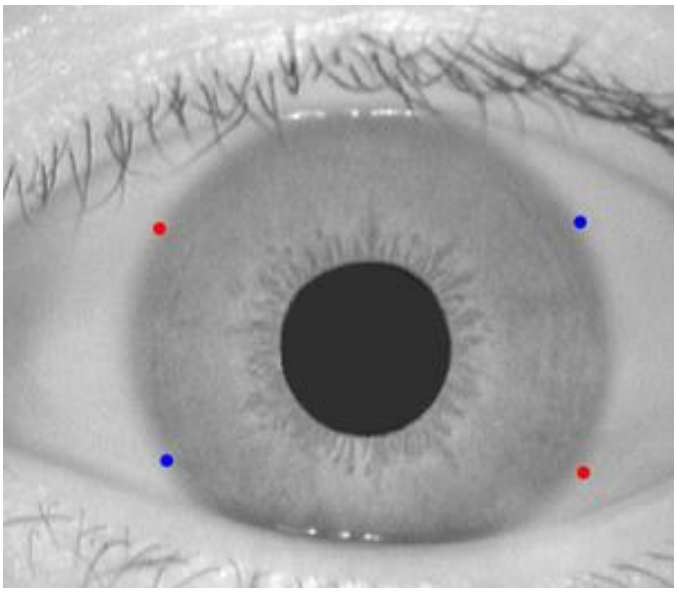
Nakon median filtera slika je pripremljena i moguće je obaviti detekciju rubova. Budući da je očigledna promjena u boji na rubu šarenice, haar wavelet filterom jednostavno je odrediti rubove. Na taj način odredimo rubove šarenica i središte zjenice (Sl. 3.4). Treba napomenuti da udaljenost rubova od središta zjenice ne odgovara radiusu kružnice šarenice jer šarenica nije koncentrična kružnica.



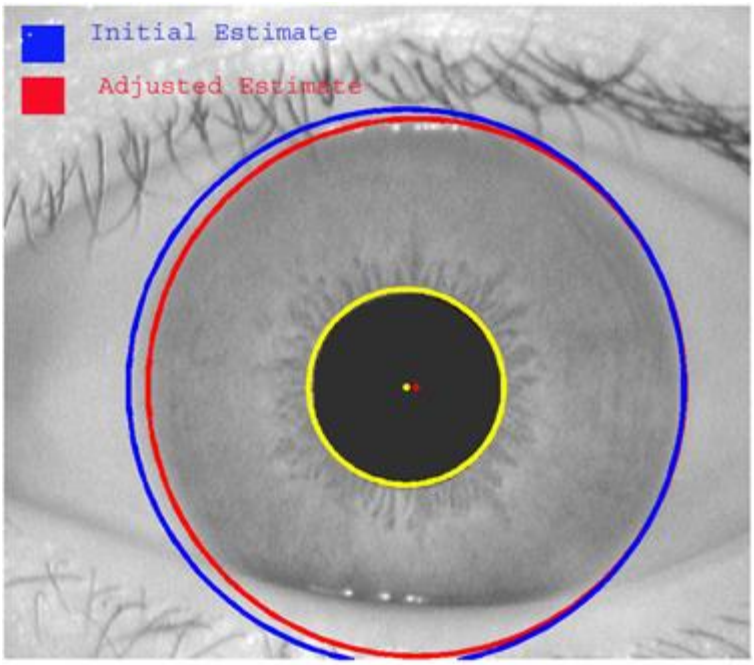
Slika 3.4:Haar wavelet horizontalne točke. [14]

Na slici 3.1.2 zelena točka označava centar zjenice, pronađen pomoću ranije navedene metode. Crvena točka označava početnu točku područja interesa. Udaljenost od zelene do plave točke je približni polumjer radiusa šarenice dok je žuta točka postavljeni polumjer za upotrebu u pronalaženju stvarnih parametara irisa.

U konačnici nakon nekoliko određenih točaka na rubu šarenice (Sl. 3.5) možemo odrediti i stvarnu kružnicu šarenice (Sl. 3.6).



Slika 3.5: šarenica s određenim točkama . [14]



Slika 3.6: Stvarna kružnica šarenice označena crvenom bojom . [14]

4. METODE

4.1. Fourier-Mellinova transformacija

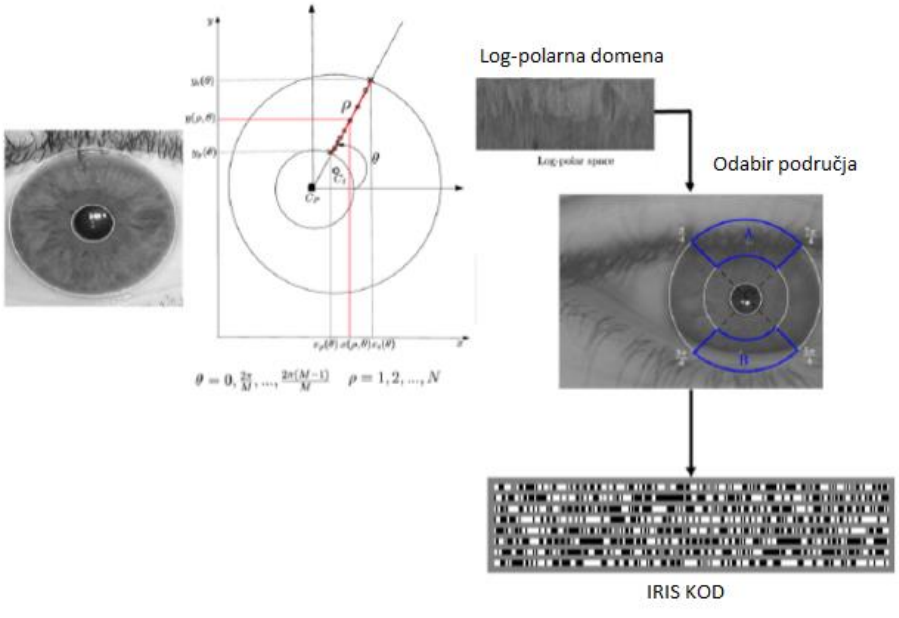
U matematici Mellinova transformacija je integralna transformacija koja se može smatrati multiplikativnom verzijom obostrane Laplaceove transformacije. Ova integralna transformacija često se koristi u teoriji brojeva, matematičkim statistikama i teoriji asimptotskih ekspanzija.

Fourier-Mellin transformacija predložena je u kasnim 70-im godinama i korištena je za obradu signala i slike. Za preuzimanje slike, rotaciju i skaliranje mogu se koristiti nepromjenjive značajke temeljene na FMT. Ova transformacija istražuje sličnost slike. U ovom slučaju funkcija pokazuje razinu sive boje 2D slike. Standardna FMT definirana je izrazom (4-1).

$$\mathcal{M}_{f\sigma}(k,v) = \frac{1}{2\pi}\int_0^{\infty}\int_0^{2\pi} f(r,\theta)\, r^{\sigma - iv}\, e^{-ik\theta}\, d\theta \frac{dr}{r}. \tag{4-1}$$

Ovakva funkcija ne ovisi o otežavajućim okolnostima kao što su drugačije osvjetljenje, slabije otvoreno oko, drugačija pozicija i udaljenost itd.

Dakle uzorak šarenice se interpolacijom pretvara u log-polar domenu i skalira se po radijalnoj osi pomoću Fourier-Mellin transformacije. Kako bi poboljšali točnost, odabire se područje šarenice gdje se ne nalaze trepavice i kapci. Nakon toga se dobiva jedinstveni iris kod koji je spreman za uspoređivanje. Cijeli postupak je prikazan na slici (Sl. 4.1).

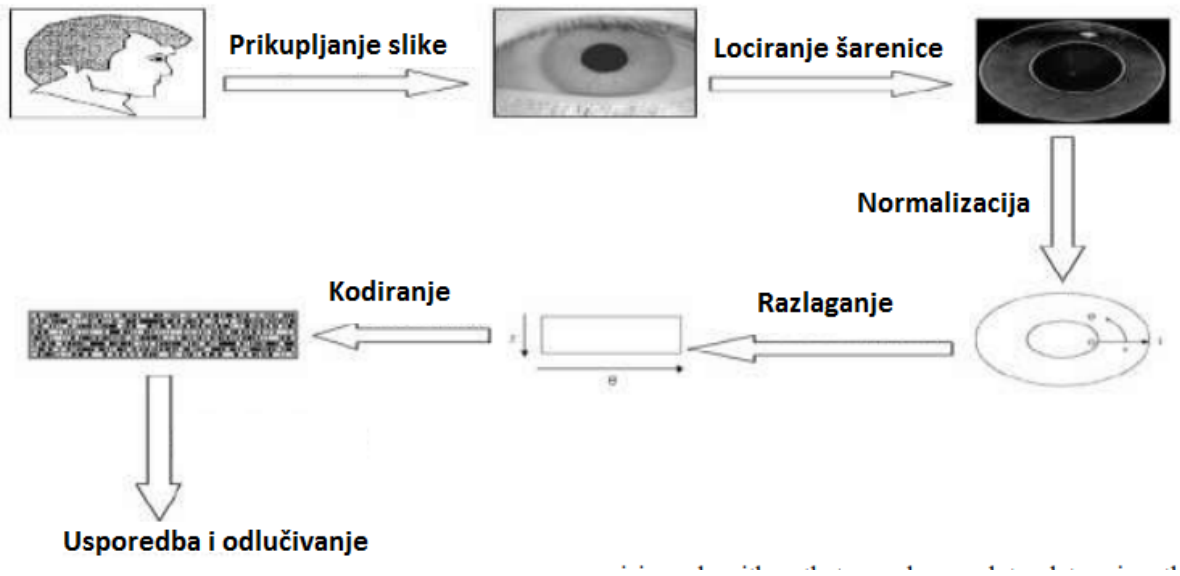


Slika 4.1: Postupak interpolacije, odabira područja i prikaz iris koda . [12]

4.2. Haar wavelet

Postoje mnogobrojni pristupi pri prepoznavanju irisa ali jedan od najbržih i najtočnijih je korištenjem WPT (*Wavelet packet transform*) transformacije koja ima višerezolucijski pristup. Iris se kodira na temelju energije wavelet paketa, a uspoređivanje se odvija korištenjem Hammingove udaljenosti. Ova metoda značajno smanjuje stope krivog prepoznavanja i identificiranja.

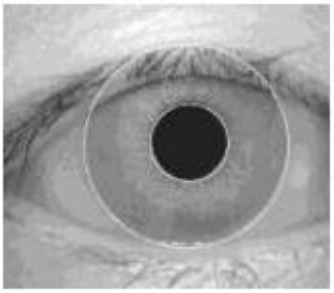
Postupak prepoznavanja *Haar wavelet* metodom opisan je na slici (Sl. 4.2).



Slika 4.2: Haar wavelet metoda identifikacije putem irisa . [13]

Prikupljanje slike je jedna od glavnih zadaća prilikom korištenja ove metode. Prilikom prikupljanja slike, poželjno je da bude u velikoj rezoluciji i da je kvaliteta visoka. Poželjno je što manje kretati se prilikom fotografiranja.

Lociranje šarenice ili lokalizacija drugi je korak. Rubovi šarenice kao i njena kružnica određuju se što preciznije. U ovom koraku se uzima uzorak cijele šarenice, bez obzira na to je li trepavica zaklonila rubove sjenom ili postoje neke druge smetnje (Sl: 4.3.).



Slika 4.3: Lociranje šarenice . [13]

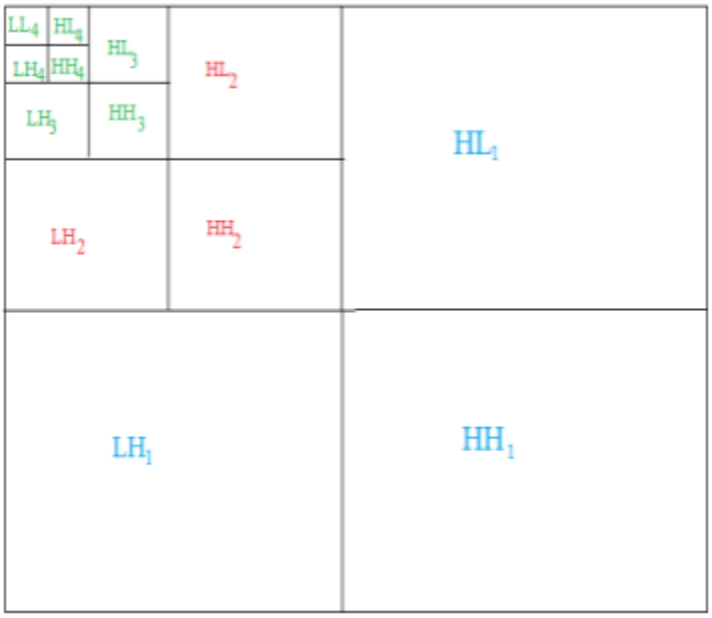
Treći korak je normalizacija. Njena je zadaća da transformira područje šarenice u zadane dimenzije. Prilikom normalizacije šarenica se pretvara u svoj polarni ekvivalent. Radijalna razlučivost postavlja se na 20 i kutna razlučivost do 240 piksela. Nakon toga se uklanjaju sve smetnje korištenjem maske. Najčešće smetnje su trepavice ili njihova sjena, odraz svjetlosti ili slabije otvoreni kapci koji suze kružnicu (Sl. 4.4).



Slika 4.4: Slika nakon primijenjene normalizacije . [13]

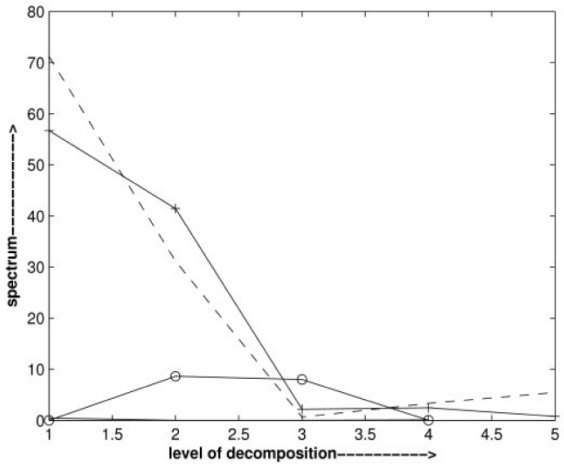
Sljedeći korak je ekstraktiranje i kodiranje značajki. Većina istraživača predložila je da se za snimanje lokalnih značajki na različitim ljestvicama koriste valovi. Nakon završetka procesa segmentacije slike irisa, šifra irisa se dobvja pomoću Haar wavelet paketa i energije podslika da bi se ekstraktirale teksture informacija šarenice i izračunale 256-bitne šifre šarenice.

Kao rezultat, četiri podslike su proizvedene: LL1, HL1, LH1 i HH1 (Sl.4.5).



Slika 4.5: Podslike Haar Waveleta . [13]

Te slike se razlažu da bi se dobila detaljna slika. Valna transformacija pretvara sliku u aproksimiranu sliku s nižom rezolucijom horizontalno, vertikalno i dijagonalno. Proces se ponavlja više puta da bi se izračunalo više valova (Sl. 4.6).



Slika 4.6: Valovi izračunati valnom transformacijom . [13]

Sada je konačno moguće kodirati i uspoređivati dobivene podatke. Proces se odvija uparivanjem iris kodova dobivenih iz valnih slika. Svaki val je određen kodom od 256 bita. Najpoznatija metoda sažimanja tih podataka je korištenjem Hammingove udaljenosti.

Izračunavanje se bazira na binarnom algoritmu podudaranja implementiranog pomoću operatora „isključivo ili“ koji se primjenjuje na 256 bitnom vektoru na iris kodovima koje uspoređujemo.

Kada bi Ci(j) i Ck(j) bili iris binarni kodovi, Hammingova udaljenost mjerila bi se određenom formulom (4-2).

$$HD_{i,k} = \frac{1}{N}\sum_{j=0}^{j=N} C_i(j) \oplus C_k(j) \qquad .(4\text{-}2)$$

5. OSTALE METODE IDENTIFIKACIJE

Uz odlike da je šarenica jedan od najzaštićenijih organa, vremenski nepromjenjiva, ima potpuno jedinstvena svojstva, nemoguće ju je kirurški izmijeniti i uvijek je imamo sa sobom ova metoda identifikacije nije najpopularnija, ali ne zbog svoje pouzdanosti.

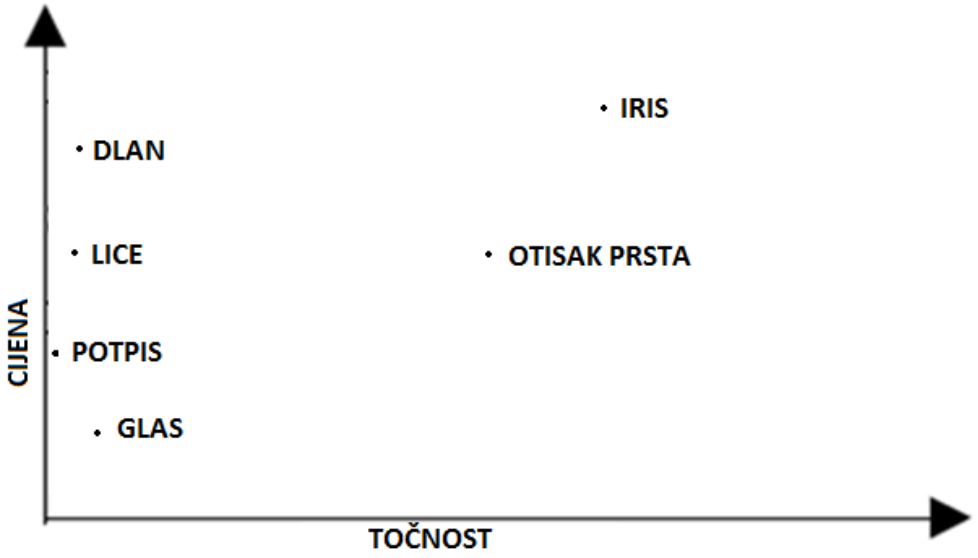
Prema mnogobrojnim istraživanjima, metoda identifikacije putem irisa pokazala se kao najtočnija i najpouzdanija. U usporedbi s drugim metodama, ova metoda identifikacije je najsigurnija (Tab. 5.1).

METODA	KARAKTERISTIKE METODE	MOGUĆNOST GREŠKE	SIGURNOST	PRIMJENA
IRIS	IRIS KOD	**1/1200000**	VISOKA	VISOKO OSIGURANE USTANOVE
OTISAK PRSTA	OTISAK PRSTA	**1/1000**	SREDNJA	UNIVERZALNA
PREPOZNAVANJE GLASA	GLASOVNE KARAKTERISTIKE	**1/30**	NISKA	TELEFONSKA SLUŽBA
POTPIS	POTPISIVANJE, STIL PISANJA	**1/100**	NISKA	NISKO OSIGURANJE
PREPOZNAVANJE LICA	OBLIK LICA I POZICIJA OČIJU I NOSA	**1/100**	NISKA	NISKO OSIGURANJE
OTISAK DLANA	VELIČINA, DUŽINA	**1/700**	NISKA	NISKO OSIGURANJE

Tablica 5.1: Usporedba sigurnosti, primjene i mogućnosti greške metode identifikacije putem irisa s ostalim metodama identifikacije. [9]

Jedan od ključnih nedostataka identifikacije putem irisa je to što je to najskuplja metoda.

Na slici (Sl. 5.1) prikazan je odnos cijene i točnosti za metodu identifikacije putem irisa i ostale metode.



Slika 5.1: Usporedba metode identifikacije putem irisa s ostalim metodama . [9]

Ostali nedostaci vezani su uz točnost identifikacije, a slabija točnost može nastupiti u slabijem ili jačem osvjetljenju i slaboj kvaliteti slike. Prilikom identifikacije ovom metodom poželjno je da osoba nije u pokretu prilikom uzimanja uzoraka, što znači da u većini slučajeva osoba mora surađivati da bi bila identificirana. Također je moguće ugraditi leće na kojima je kopiran uzorak irisa druge osobe ali je jako teško ostvarivo. Jedan od problema je također konzumiranje alkohola jer može izazvati deformaciju očne šarenice.

6. ZAKLJUČAK

Iako je metoda identifikacije putem irisa jedna od najtočnijih, još uvijek nije najprimjenjenima metoda za identifikaciju zbog svoje cijene. Samim napretkom tehnologije, identifikacija putem irisa će biti točnija i imat će širu primjenu.

Haar wavelet metoda identifikacije je trenutno jedna od najbržih i najtočnijih metoda. Koristi vrlo malo računalnih resursa i pogodna je za mnoge sigurnosne sustave. Vjerujem da će se ova metoda razvijati i u budućnosti.

Bez obzira na visoku novčanu cijenu primjene ove metode, važno je ustrajati i razvijati ovu tehnologiju do savršenstva. Ako ova metoda ne postane globalni i univerzalni način identifikacije jednog dana, još uvijek će se koristiti za sustave s visokom razinom sigurnosti.

7. LITERATURA

[1] K N Pushpalatha 1, Aravind Kumar Gautham2 D.R.Shashikumar3 and K.B ShivaKumar4 " Iris Recognition System with Frequency Domain Features optimized with PCA and SVM Classifier" 5, No 1, September 2012.

[2] L. Ma, T. Tan, Y. Wang, and D. Zhang, "Efficient iris recognition by characterizing key local variations," IEEE Trans. Image Process, vol. 13, 2004, pp. 739–750.

[3] Ales Muron and Jaroslav Pospisil, "The human iris structure and its usages," Acta Univ. Palacki. Olomuc. Fac. Rerum Nat. Phys., vol. 39, 2000, pp. 87–95.

[4] Gatheejathul Kubra.J, Rajesh.P , " Iris Recognition and its Protection Overtone using Cryptographic Hash Function" SSRG International Journal of Computer Science and Engineering (SSRGIJCSE) – volume 3 Issue 5–May 2016

[5] J. Daugman. How iris recognition works. Proceedings of 2002 International Conference on Image Processing, Vol. 1, 2002.

[6] P. W. Hallinan, "Recognizing human eyes," Geometric Methods Comput. Vision, vol. 1570, pp. 214–226, 1991.

[7] L. Ma, T. Tan,D. Zhang, andY.Wang, "Local intensity variation analysis for iris recognition," Pattern Recognition, vol. 37, no. 6, , 2005, pp. 1287–1298.

[8] J.G. Daugman, "Demodulation by Complex-Valued Wavelets for Stochastic Pattern Recognition," Int'l J. Wavelets, Multiresolution and Information Processing, vol. 1, no. 1, 2003, pp. 1-17

[9] Computer Laboratory Faculty of Computer Science and Technology, http://www.cl.cam.ac.uk/ ,pristupljeno 1. kolovoza 2017.

[10] Iris recognition, https://en.wikipedia.org/wiki/Iris_recognition , pristupljeno 1. kolovoza 2017.

[11] A Fast and Accurate Iris Localization Technique for Healthcare Security System, https://www.researchgate.net/publication/283344986_A_Fast_and_Accurate_Iris_Localization_Technique_for_Healthcare_Security_System,pristupljeno 1. kolovoza 2017.

[12] A low-cost video-based iris recognition system , https://www.researchgate.net/publication/278771246_A_low-cost_video-based_iris_recognition_system ,pristupljeno 1. kolovoza 2017.

[13] Iris Recognition using Four Level HAAR Wavelet Transform: A Literature review, http://www.internationaljournalssrg.org/IJECE/2016/Volume3-Issue6/IJECE-V3I6P106.pdf,pristupljeno 1. kolovoza 2017.

[14] Iris Recognition: Detecting the Iris ,http://cnx.org/contents/XjQE6rBl@3/Iris-Recognition-Detecting-the,pristupljeno 1. kolovoza 2017.

[15] A Fast and Accurate Iris Localization Technique for Healthcare Security System, https://www.researchgate.net/publication/283344986_A_Fast_and_Accurate_Iris_Localization_Technique_for_Healthcare_Security_System , pristupljeno 1. kolovoza 2017.

[16] Health,Beauty,Fitness,Lifestyle,http://earnfromhomebyinternet.blogspot.hr/2010/12/eye-anatomyphysiologydiagram-and-parts.html, pristupljeno 1. kolovoza 2017.

8. SAŽETAK

Metoda identifikacije putem šarenice oka vrlo je moderna tehnologija, a šarenica oka savršen je kandidat za identifikaciju. Prilikom identifikacije najprije je potrebno fotografirati oko. Sljedeći korak je lociranje šarenice oka. Nakon što je šarenica locirana, normalizacijom se fotografija pretvara u polarni ekvivalent. Važno je ukloniti smetnje kako nebi negativno utjecale na postupak. Nakon što dobivene podatke obilježimo iris kodom, uspoređivanjem kodova utvrđujemo identitet osobe.

Ključne riječi: identifikacija, identifikacija irisa,normalizacija, šarenica, iris.

9. ABSTRACT

The eye iris identification method is a very modern technology, and the eye iris is the perfect candidate for identification. When identifying person's identity, first you need to take a picture of the eye. The next step is to locate the eye iris.After the eyeiris is located, normalization turns the photograph into a polar equivalent. It is important to remove the interference in order not to adversely affect the process. Once the data obtained is marked with the iris code, by comparing the codes we determine the identity of the person.

Key words: identification, iris identification, normalization, iris.

10. ŽIVOTOPIS

Mario Tomić rođen je 29.2.1996. u Virovitici. Živi u Đulovcu, mjestu pokraj grada Daruvara. Osnovnu školu pohađao je u Đulovcu te upisao i završio smjer računalni tehničar u Tehničkoj školi Daruvar. Nakon srednje škole upisuje računarstvo na Elektrotehničkom fakultetu u Osijeku. Na Otvorenom učilištu Algebra položio jeMicrosoft Certifikat iz područja Windows Operating System Fundamentals.