Poboljšani algoritam identifikacije osoba putem irisa

Vido, Ivan

Undergraduate thesis / Završni rad

2016

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:200:051531

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAZERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni studij

POBOLJŠANI ALGORITAM IDENTIFIKACIJE OSOBA PUTEM IRISA

Završni rad

Ivan Vido

Osijek, 2016

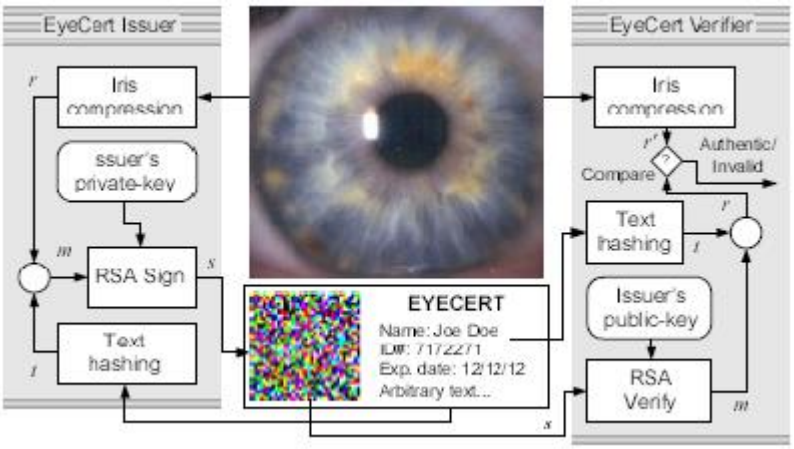
SADRŽAJ

1. UVOD 1
1.1 Princip rada biometričkog sustava identifikacije irisa 2
2 ZADATAK RADA 3
3 Detekcija irisa 3
3.1 Aproksimacija irisa 4
4 Transformacija 6
5 Haar wavelet 7
5.1 Pretraživački algoritam 10
6 Zaključak 12
7 Literatura 13
8 Sažetak 14
9 Abstract 15
10 Životopis 16

1. UVOD

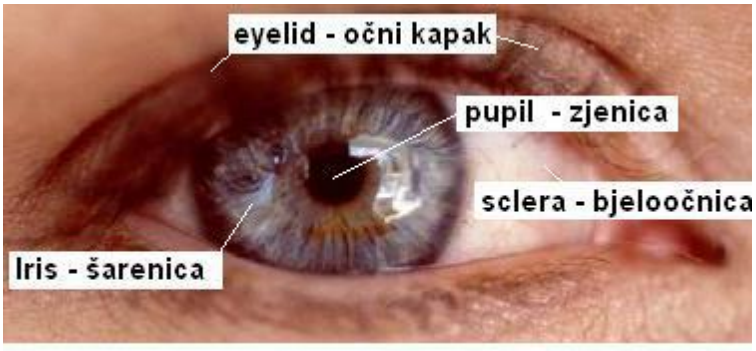
Potreba za identifikacijom ljudi proizlazi iz više aspekata. Jedan od najbitnijih je autentikacija, odnosno zaštita, enkripcija podataka ili čak materijalnih dobara. Na primjer sefovi na biometričke „brave“. Postoje jos mnogi drugi razlozi od kojih ponajviše se izdvajaju kriminalistički razlozi, gdje bi se na to moglo gledati kao na otisak prsta. To bi dalo u ne tako dalekoj budućnosti, mogućnost sigurnosnih kamera(CCTV) uz dovoljno visoku rezoluciju, identifikaciju osoba iz snimaka a da sumnjiva osoba nije nužno direktno pogledala u objektiv kamere, što se trenutno zahtjeva od sadašnjih sustava za identifikaciju putem irisa.

Kako su biometričke karakteristike nešto što osoba nužno nosi uvijek sa sobom, te karakteristike postaju fokus istraživanja o identifikaciji. Takve sustave možemo zamisliti kao osobne iskaznice na zajedničkom *cloud* računalu svih građana. Iz obilja karakteristika poput, otiska prsta, dlana, oblik lica, šarenica, DNA (kosa, slina) ovaj rad se bavi identifikacijom osoba putem irisa (šarenice).



Slika 1.1 Primjer kako bi izgledala "osobna iskaznica" na biometriju

Ljudska šarenica(iris) je jedna od naprominentnijih biometričkih karakteristika koje se mogu koristiti za identifikaciju osoba[1]. Sustavi temeljeni na prepoznavanju šarenice(irisa) osoba mogu naći jedinstvene karakteristike čak i za jednojajčane blizance[4], što je prednost u usporedbi s DNA analizom. Šarenica je u potpunosti formirana već 6 mjeseci nakon rođenja i gotovo nepromjenjiva na fizičke promjene poput bolesti i trudnoće (npr. dijabetička retinopatija). Uostalom, za sad nije moguće lažirati tuđu šarenicu u zločinačke svrhe, stoga ove osobine šarenicu čine izvrsnim kandidatom za biometričke sustave za identifikaciju.



Slika 1.2 Primjer oka s definiranim pojedinim dijelovima

1.1 Princip rada biometričkog sustava identifikacije irisa

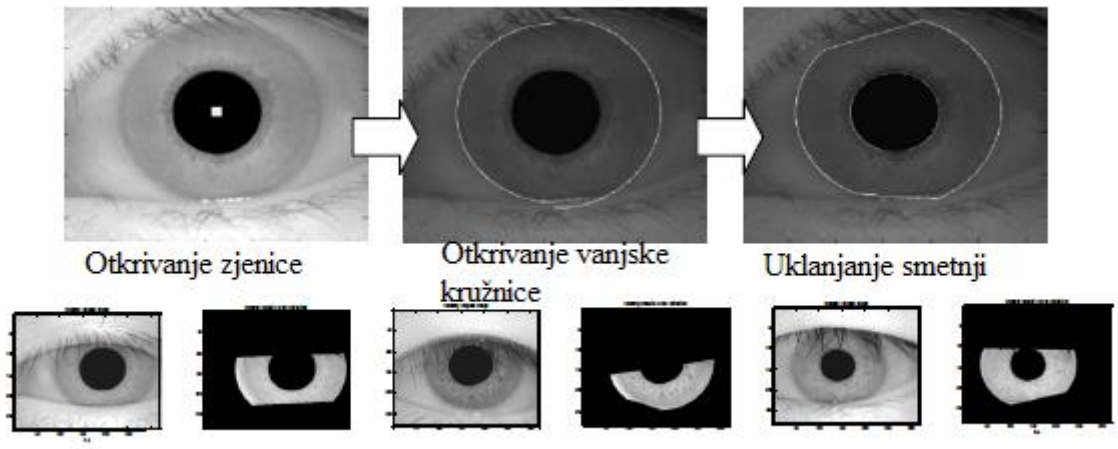
Identifikacija u najsurovijem obliku funkcionira tako da se oko prvo skenira kamerom, te se iz slike (Sl.3.1) odredi kružni oblik šarenice, odnosno vanjski okvir, te unutarnji okvir zjenice. Granice se smanjuju zbog smetnji kapaka i trepavica što znači da nećemo dobiti savršeni prstenasti oblik. Potrebna je aproksimacija nakon koje najčešće jednostavniji sustavi prebacuju boju u *grayscale* kako bi se smanjila količina podataka potrebnih da se pohrani uzorak. Prstenasti oblik sive šarenice se onda izreže iz slike i izvravna u pravokutnik, primjene se algoritmi normalizacije te se u konačnici dobije uzorak nalik na dvodimenzionalni bar kod. Na kraju preostaje samo ponovno skeniranje oka koje usporedjuje početni uzorak s trenutnim i uz određenu nesigurnost zbog neizbježnih smetnji utvrđuje je li to ista osoba.

2. ZADATAK RADA

Ovaj rad se fokusira na objašnjavanje algoritma za indetifikaciju ljudskog irisa, ponajviše Haar wavelet transformacijom. Prvo će biti objašnjeno kako se iris detektira odnosno prepoznaje, te način na koji se transformira u log-polarnu domenu i na kraju se obrađuje Haar wavelet algoritam kroz sve faze identifikacije.

3. Detekcija irisa

Kao što je ukratko opisano ranije, šarenicu je potrebno izolirati iz slike oka, tako što se odrede granice koje čine kapci i prstenasti oblik šarenice. Da bi se povećala preciznost i smanjila količina lažno negativnih rezultata identifikacije nužno je uzeti u obzir smetnje kojih ima mnogo na slikama oka. Najveće smetnje su očigledno kapci jer smanjuju količinu podataka koje uzimamo za uzorak. Ostale faktore koje je potrebno uzeti u obzir su osvjetljenje koje uz to što smanjuje kvalitetu slike ako ga ima premalo, utječe i na veličinu zjenice, a ako je previše osvjetljeno onda se povećava problem refleksije na mrežnici oka. Tu je još i faktor sjene koju mogu stvarati bilo kakvi predmeti koji se nadju izmedju izvora svjetlosti i oka, a najznačanija je sjena od trepavica.



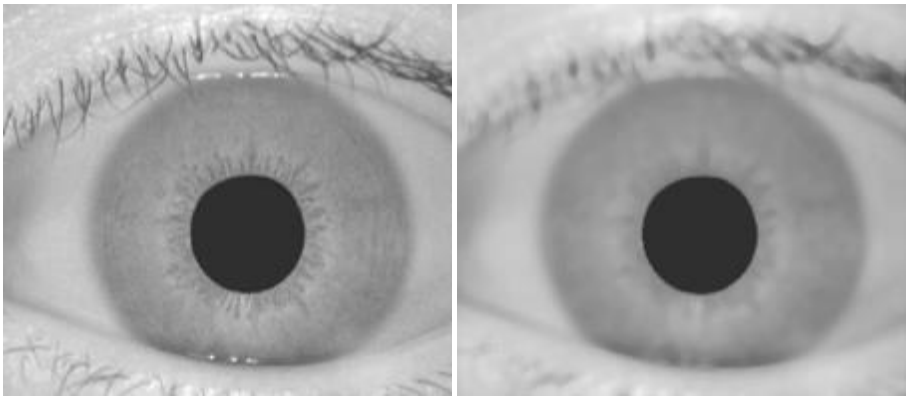
Slika 3.1 Prikaz određivanja zjenice i mogući načini uklanjanja smetnji

3.1 Aproksimacija irisa

Prvi korak u odredjivanju kružnice šarenice oka je aproksimacija radijusa šarenice. Neke metode koriste nasumične krugove da bi odredili specifične parametre kružnice šarenice, odnosno iterativna metoda konstatnog pretpostavljanja neke kruznice i uspoređivanja ga sa stvarnom šarenicom.

Odlučuje se metoda aproksimacija irisa, koja za prvi korak ima traženje središta zjenice, te po horizontalnoj liniji presjek točaka sa kružnicom šarenice. Odabire se horizontalna linija naravno da se izbjegnu ponajviše smetnje kapaka i trepavica. Koristeći ***median filter*** slika(sl 3.2) se zamuti kako bi se smanjio utjecaj smetnji u uzimanju uzorka, te kako bi se izbjegla nepreciznost i gubitak podataka nakon izrezane slike potrebno je dodatno izoštriti detalje šarenice.

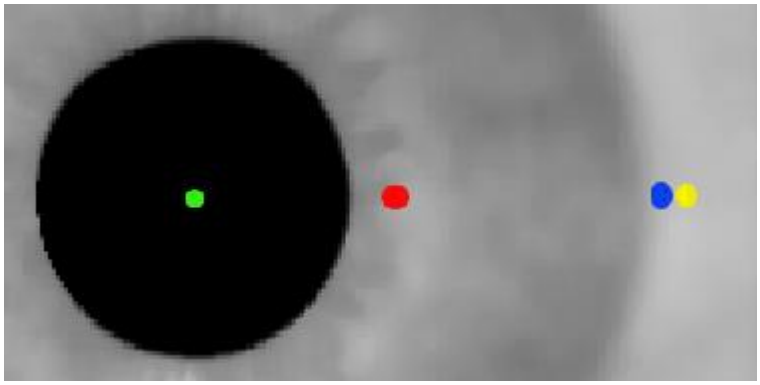
Koristeći haar wavelet filter određuje se rub šarenice i minimizirao utjecaj osvjetljenja (luminiscencije).



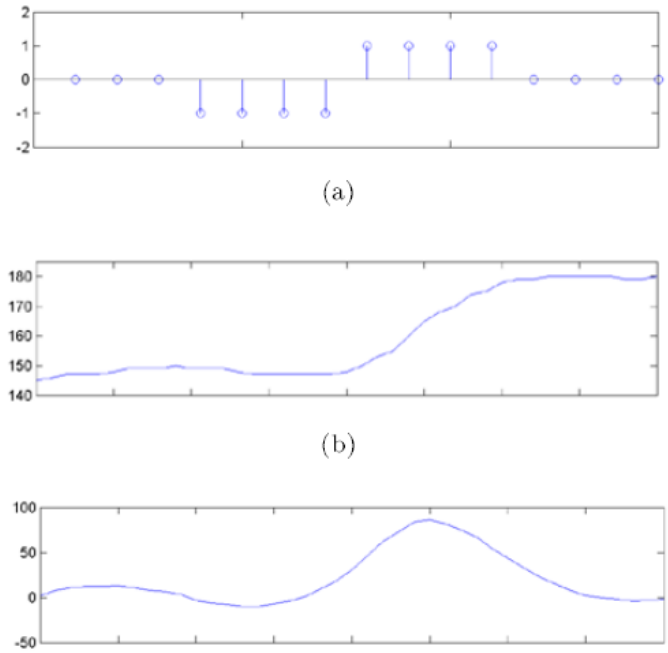
Slika 3.2 (lijevo) oko prije filtera, (desno) nakon primjenjenog median filtera[7]

Šarenica bi trebala prestavljati najveću promjenu osvjetljenjanja u promatranom potručju, stoga će taj dio slike pretstavljati maksimalni izlaz iz wavelet filtra. Te tako pronađemo rubove šarenica,

točke na unutarnjoj i vanjskoj kružnici i imamo središte zjenice. Ovdje se mora uzeti u obzir da oko nije koncentrična kružnica te polumjeri ne moraju biti svugdje isti.



Slika 3.3 Pronađene točke korištenjem haar wavelet filtra



Slika 3.4 a) haar wavelet b) promatrano područje c) promatrano područje nakon haar wavelet filtera

4. Transformacija

Detektiranu sliku, prstenastog oblika sada je potrebno transformirati u pravokutni oblik. Koristeći ***Fourier Mellin transformaciju***(FMT):

$$D(c) = \frac{1}{\sqrt{2\pi}} \int_0^\infty s(t) \frac{e^{-jc\ln t}}{\sqrt{t}}\, dt \tag{4.1}$$

Koja je pogodna za transformaciju jer je sklarano nepromjenjiva, tj neće ovisiti o promjanama poput proširenih zjenica, malo drukčije udaljenosti od skenera i osvjetljenje

Ovako je FMT povezana sa Fourierovom transformacijom.

$$f(t) = s(e^t)e^{t/2}, \;\; D(c) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^\infty f(t)e^{-jct}\, dt \tag{4.2}$$

U diskretnoj domeni FMT je definiran s tri dijela, interpolacija, duljina i Fourierova transformacija.

U konačnici se koristi modificirana FMT ili mFMT, koje je zapravo samo naziv za konačni oblik korištenja FMT i Fourierove transformacije, te izgleda ovako:

$$f(t_1, t_2) = e^{t_2/2} s(e^{t_2}\cos t_1, e^{t_2}\sin t_1), \tag{4.3}$$

$$D(c_1, c_2) = \frac{1}{2\pi} \int_{-\infty}^\infty \int_{-\infty}^\infty f(t_1, t_2) e^{-j(c_1 t_1 + c_2 t_2)}\, dt_1\, dt_2 \tag{4.4}$$

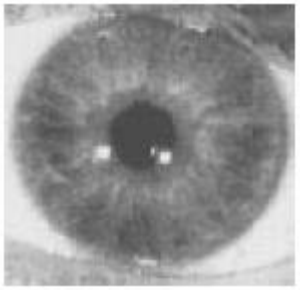
Kao prvo, interpolira se iris tako da napravimo uzorke na 256 kutova i na 256 radijana kvdratnih. Radijani su logaritamski raspoređeni od unutrasnjeg prema vanjskom tako da se oblik rastegne u pravokutni. Nakon interpolacije šarenica je u log-polar domeni i po radijalnoj osi je sklairana po FMT-u. Konačno se koristi dovdimenzionalna Fourierova transformacija i tako smo se riješili log-polarne domene. Sada je moguće raditi usporedbe tih piksela.



Slika 4.1 Primjer transofrmacije izolirane maske irisa, u log-polar domenu te u mFMT domenu

5. Haar wavelet

Pri korištenju ove tehnike uzimaju se u obzir samo primjerci u *greyscale*-u da bi se dobio uzorak šarenice. Nakon što se izolira samo dio slike koji je šarenica, izvlače se skupovi jednodimenzionalnih signala i dobiva se njihova reprezentacija u *zero-crossing*. Pri izradi reprezentaciji šarenice, skup uzoraka podataka se prikupi te se na njima izgradi *zero-crossing* reprezentacija temeljena na dualnoj wavelet transformaciji(WT)[2].



Slika 5.1 *Grayscale* slika irisa

Izvlačenje informacija počinje s određivanjem gdje se nalazi zjenica oka, što se može postiči bilo kojom tehnikom detekcije rubova. Znajući da je kružnog oblika rubovi koji su detektirani formiraju zatvorenu krivulju. Centar detektirane zjenice se odabire kao referentna točka za daljnje izvlačenje karakterstika šarenice. Količina sive boje na konturama tih virtualnih koncetričnih kružnica se zapišu i pohrane u kružne *buffere*. Ovi podatkci će kasnije poslužiti u objašnjavanju procesa i njega će se oslovaljati kao potpis šarenice. Odabirani centar osigurava da je reprezentacija neosjetljiva na translaciju. Slijedeća briga je promjena u veličini zbog različitih udaljenosti lica i kamere pri svakoj autentikaciji.

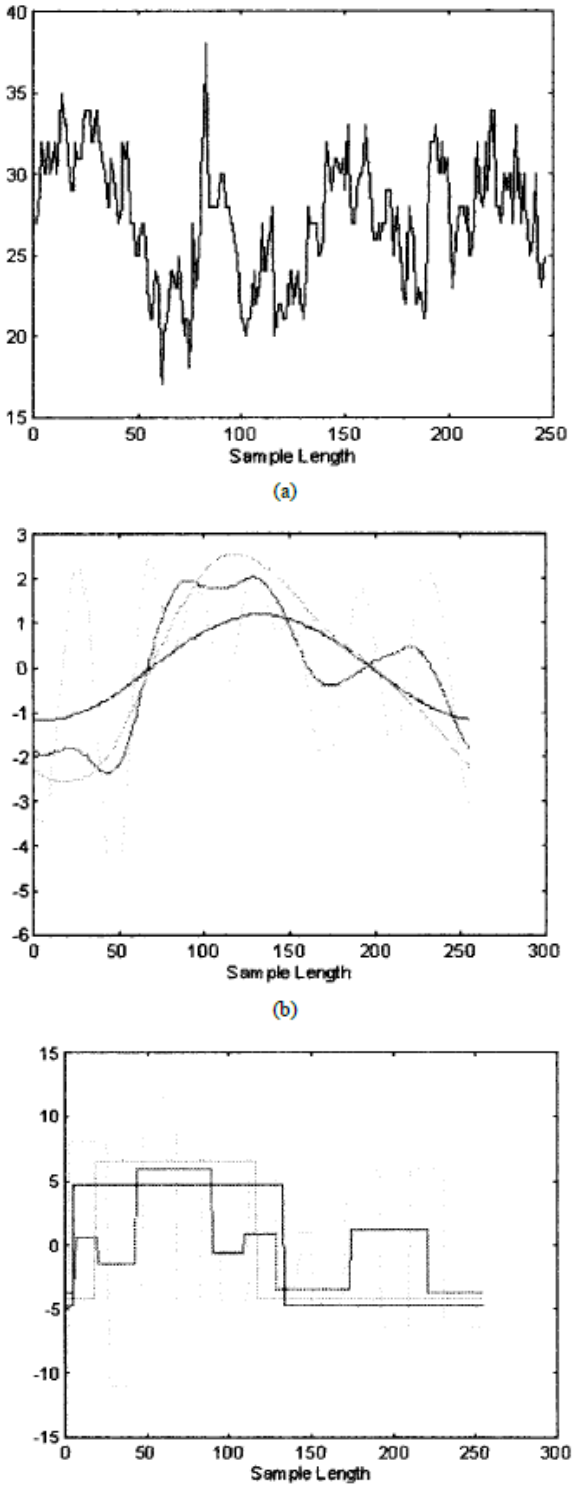
Dobivene informacije od iste šarenice mogu biti različite iako se promjer virtualne kružnice ne promjeni, ponajviše zbog mogućih razlika udaljenosti lica i kamere. Za svrhe uspješne autentikacije, informacije se moraju obraditi a) kako bi osigurali točnu lokaciju virtualne kružnice i b) kako bi se popravile duljine uzoraka prije nego se počne stvarati *zero-crossing* reprezentaciju.

Koristeći sliku šarenice čiji su rubovi određeni, izračuna se maksimalni promjer šarenice u bilo kojoj slici. Pri usporedbi dvije slike jedna će biti definirana kao referentna slika. Omjer maksimalnih promjera obje slike se također izračuna, te nakon toga se koristi taj omjer kako bi se ocrtale virutalne kružnice, koje izvlače karakteristike šarenice, istim promjerima. Odnosno, dimenzije šarenice u slikama će biti skalirane na isti promjer bez obzira na prvotnu veličinu slike.

Slijedeće, dobivene informacije od bilo koje od virutalnih kružnica moraju biti normalizirani na jednak broj podatkovnih točaka. Ovdje se koristi normalizirana vrijednost N koja predstavlja potenciju broja dva. Tako je odabrano jer je dualna(binarna) wavelet transformacija korištena za dobivanje cijelopne informacije potpisa šarenice. Mjenjajuci normaliziranu vrijednost može se mjenjati preciznost procesa. Velika vrijednost N rezultira u većem broju detalja analiziranog potpisa šarenice a manjoj brzini i obrnuto.

Slijedeći korak je generacija *zero-crossing* reprezentacije iz normaliziranog potpisa šarenice $f(n), n\epsilon Z$. kako normalizirani potpis šarenice prestavlja zatvoreni prsten, to znači da je prirodno periodičan s periodom N, stoga *zero-crossing* reprezentacija će također biti periodična jer su wavelet koeficijenti periodični. Ovo u konačnici znači da je reprezentacija neovisna o početnoj točki virtualnih kružnica šarenice.

Binarna wavelet transformacija rastavlja signal na skup signala različitih rezolucijskih razina. Na podatke na višim razinama rezolucije smetnje utječu najviše. Kako bi se to smanjilo uzimaju se niže rezolucijske razine. Time se smanjuje broj potrebnih računalnih prelazaka preko informacija i bolja reprezentacija u prostorima zagušenim smetnjama.



Slika 5.2 a) potpis irisa u grayscale-u b) najniže četiri razine rezolucije wavelet transfomracije c) zero-crossing reprezentacija[6]

5.1 Pretraživački algoritam

Ovo je algoritam temeljen na modelima jer reprezentacije irisa su sačuvane u bazi podataka kao modeli *zero-crossinga*. Te se uzima nova slika tako zvani unknown i uspoređuje se sa modelima u bazi podataka. Proces ima dvije faze: učenje i klasifikacija. Za vrijeme učenja sustav sastavlja modele irisa bez smetnji te se odabiru sretnje vrijednosti rezolucije koje sadržavaju najviše podataka reprezentacije tog irisa. U fazi klasifikacije nepoznata reprezentacija irisa (*uknown*) se normalizira jednako kao i model. Te nakon usporedbe unkwnona sa modelom koristimo funkcije različitosti.

Uvodimo oznake *f* za potpis isrisa i razinu rezolucije *j*, stoga *je zero-crossing* $Z_j f$. Također odredimo $P_j = \{p_j(r): r = 1 \dots R_j\}$ kao skup koji sadrži lokacije *zero-crossinga* na razini $_j$, gdje R_j predstavlja broj *zero-crossinga* na trenutnoj razini. Tada $Z_j f$ se može eksplicitno prikazati kao skup kompleksnih brojeva čiji imaginarni $[\mu_j]_f$ i realni $[p_j]_f$ dijelovi sugeriraju poziciju i amplitudu $Z_j f$ između dvije susjedne *zero-crossing* točke.

Dvije funkcije različitosti:

$$d_j{}^{(1)}(f,g) = min \sum_{n=1}^{N} |Z_j f(n) - \Gamma Z_j g(n+m)|^2 \qquad (5.1)$$

$m \in [0, N-1]$

$$d_j{}^{(2)}(f,g) = min \frac{\sum_{r=1}^{R_j} \{[\mu_j(r)]_f [\rho_j(r)]_f - \Gamma [\mu_j(r+m]_g [\rho_j(r+m)]_g\}^2}{\Gamma \sum_{r=1}^{R_j} |[\mu_j(r)]_f [\rho_j(r)]_f| |[\mu_j(r)]_g [\rho_j(r)]_g|} \qquad (5.2)$$

$m \in [0, R_j - 1]$

Gledajući *unknown* g uspoređujemo ga s potencijalnim modelo f na određenoj rezoluciji j, gdje Γ predstavlja faktor skaliranja koji se izračuna iz omjera radijusa virtualnog kruga od potencijalnog modela i nepoznatog potpisa(*uknown*). Sveukupna vrijednost različitosti u intervalu rezolucija [K,L] će biti srednja vrijednost svih izračunatih raličitosti.

$$D^{(p)} = \sum_{j=K}^{L} \frac{d_j^{(p)}(f,g)}{Q} \quad (5.3)$$

Gdje p predstavlja broj 1 ili 2 koji određuje koja funkcija se koristi, Q broj srednjih razina rezolucije, a L i K opisuju granice najniže i najviše od tih srednjih razina rezolucije.

Prva funkcija d_j^1 [3]uzima u obzir sve točke različitosti kroz prostornu domenu obiju zero-crossing reprezentacija na određenoj razini rezolucije j. S ciljem da se ubrza proces i izoliraju samo najbitnije informacije koristi se druga funkcija d_j^2 koja uspoređuje dvije reprezentacije na dimenzijama kvadratičnih pulseva *zero-crossing* reprezentacije. Druga funkcija nailazi na problem, što ako obje reprezentacije nemaju jednak broj zero-crossinga na svakoj od razina rezolucije. Rješenje slijedi: prebrojati *zero-crossinge* i ako zadovoljavaju za makar dvije susjedne točke možemo primjeniti drugu funkciju, inače koristiti eliminaciju krivih zero-crossinga kako bi se obrisali nevažni *zero-crossingi* i tako izjednačio broj *zero-crossinga* u uknownu i modelu.

6. Zaključak

Iako tehonologija ne sustiže nikada naše zahtjeve, puno se očekuje od područja identifikacija pomoću biometrijskih karakteristika, ponajviše irisa. Važno je konstatno ustrajati u istraživanju i konstatno tražiti nove, brže i učinkovitije načine kako bismo omogućili globalnu uporabu takvih tehnologija.

Predstavljeno je da je haar wavelet algoritam za sada najjednostavniji i daje najbolje rezultate za onoliko procesorske snage koje potroši. Taj algoritam ne ovisi o poziciji, rotaciji ili razlici u veličinama. Zbog toga što uzima manji broj rezolucijskih razina, algoritam je brži i jednostavniji od ostalih.

7. Literatura

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

[2] S. G. Mallat, "Zero-crossings of a wavelet transform," *IEEE Trans. Inform. Theory,* vol. 37, no. 14, pp. 1019–1033, 1991.

[3] Q. M. Tieng and W. W. Boles, "Recognition of 2D object contours using the wavelet transform zero-crossing representation," *IEEE Trans. Pattern Anal. Machine Intell,* vol. 19, pp. 910–916, Aug. 1997

[4] J. Daugman. Recognizing Persons by Their Iris Patterns. Biometrics: Personal Identification in Networked Society, Kluwer Academic Publishers, 1999.

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

[6] W. W. Boles and B. Boashash, "A Human Identification Technique Using Images of the Iris and Wavelet Transform," *IEEE Transactions on Signal Processing,* vol. 46, no. 4, pp 1185, April 1998

[7] Zhou Wang and David Zhang, "Progressive Switching Median Filter for the Removal of Impulse Noise from Highly Corrupted Images*", IEEE transactions on Circuits AND Systems—II: Analog and Digital Signal Processing*, vol. 46, no. 1, Jan 1999

8. Sažetak

Ljudska šarenica je savršen kandidat biometrijske identifikacije ljudi. Identifikacija osoba započinje uzimanjem slike oka, najčešće u grayscale-u, te aproksimacijom irisa na vritualne kružnice koje čine prsten koji će biti izrezan iz slike. Virtualni prsten se naknadno normalizira i interpolira po log-polar domeni čime dobivamo površinski izgled tog prstena u ravnini. Nakon što smo dobili prikaz virtualnog prstena u ravnini, sada je potrebno kompresirat podatke i sačuvat ih u bazi podataka sa svim drugim irisima.

Ključne riječi: identifikacija irisa, iris, šarenica, algoritam, haar wavelet

9. Abstract

Human iris is a perfect candidate for biometric identification of a person. The identification begins with taking a picture of a human eye, usually grayscale, after which comes the aproximation of iris with virtual circles. Those circles make up a virtual ring which is going to be normalized into a spatial domain via log-polar transformation. With Fourier transform we get the final result of iris looking like a bar code. Than we need to compress the bar code and save it in the data base with other irises.

Keywords: iris identification, iris, algorithm, haar wavelet

10. Životopis

Poštovani, ime mi je Ivan Vido. Rođen sam u malom gradu Požegi u Požeško-slavonskoj županiji. Pohađao sam prirodoslovno-matematički smijer u požeškoj gimnaziji nakon čega sam upisao studij na Fakultetu elektrotehnike i računarstva u Zagrebu s kojeg sam se ispisao zbog poteškoća sa savladavanjem gradiva i poteškoća sa smještajem i cijenama. Prebacio sam se u Osijek na Fakultet elektrotehnike, računarstva i informacijskih tehnologija, jer to mi je najbolja šansa da skupim potrebna znanja da se osposobim kao inženjera u području u kojem se želim vidjeti u budućnosti i kojeg smatram najbitnijim za današnje doba.