

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Žiga Emeršič

**Večmodalna biometrična fuzija na
osnovi prstnih odtisov in obrazov**

DIPLOMSKO DELO

UNIVERZITETNI ŠTUDIJSKI PROGRAM PRVE STOPNJE
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: doc. dr. Peter Peer
SOMENTOR: doc. dr. Vitomir Štruc

Ljubljana 2013

Rezultati diplomskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljanje ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

Za celotno besedilo in uporabljene slike v poglavju 2.2.1 si doc. dr. Vito-
mir Štruc in podjetje Alpineon d.o.o. pridržujejo pravico za uporabo v drugih
materialih.

Besedilo je oblikovano z urejevalnikom besedil \LaTeX .



Št. naloge: 00106/2013

Datum: 12.04.2013

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Kandidat: **ŽIGA EMERŠIČ**


Naslov: **VEČMODALNA BIOMETRIČNA FUZIJA NA OSNOVI PRSTNIH
ODTISOV IN OBRAZOV**
**MULTIMODAL BIOMETRIC FUSION BASED ON FINGERPRINTS AND
FACES**

Vrsta naloge: Diplomsko delo univerzitetnega študija prve stopnje

Tematika naloge:

V diplomu naslovite postopek fuzije, ki bo združil obstoječa sistema za razpoznavanje prstnih odtisov in razpoznavanje obrazov. Osredotočite se predvsem na fuzije na nivoju mer podobnosti. Vsak od sistemov deluje v načinu verifikacije in vhodno sliko primerja zgolj z eno predlogo iz baze. Ta primerjava vodi do dveh ločenih mer podobnosti, ene za prstne odtise in ene za obraze. Meri podobnosti za oba sistema združite s postopki fuzije na podlagi fuzijskih pravil in na podlagi razvrščevalnikov. Opredelite najbolj optimalne postopke fuzije in podajte rezultate.

Mentor:


doc. dr. Peter Peer



Dekan:


prof. dr. Nikolaj Zimic

IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisani Žiga Emeršič, z vpisno številko **63070076**, sem avtor diplomskega dela z naslovom:

Biometrična fuzija prstnih odtisov in obrazov

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom doc. dr. Petra Peera in somentorstvom doc. dr. Vitomir Štruc,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, 23.9.2013

Podpis avtorja:

Zahvaljujem se mentorju doc. dr. Petru Peeru za pomoč, potrpežljivost in spodbudo tekom izdelave diplomske naloge ter za vzor in podporo tekom študija. Zahvaljujem se doc. dr. Vitomirju Štrucu iz Fakultete za elektrotehniko za pomoč, zelo koristne nasvete in usmerjanje. S svojo Matlab PhD knjižnico je bil v zares veliko pomoč, skupaj s podjetjem Alpineon d.o.o. je priskrbel opis uporabljenega postopka razpoznavanja obrazov. Prav tako se zahvaljujem as. Jerneju Buletu za pomoč, potrpežljivost in spodbudo med izdelavo diplomskega dela, priskrbel je tudi opis uporabljenega postopka razpoznavanja prstnih odtisov.

Kazalo

Kazalo

Povzetek

Abstract

1	Uvod	1
2	Arhitektura sistema	3
2.1	Razpoznavanje prstnih odtisov	5
2.1.1	Uporabljeni postopek razpoznavanja prstnih odtisov in pregled sistema	6
2.2	Razpoznavanje obrazov	9
2.2.1	Uporabljeni postopek razpoznavanja obrazov in pregled sistema	10
2.3	Normalizacija vhodnih podatkov	15
2.4	Fuzija	16
2.4.1	Fuzija na nivoju signalov	16
2.4.2	Fuzija na nivoju izpeljave značilnk	17
2.4.3	Fuzija na nivoju mer podobnosti	17
2.4.4	Fuzija na nivoju odločanja	18
3	Sorodna dela	19
3.1	Dvomodalna biometrična verifikacija z različnimi nivoji fuzije	19

3.2	Večmodalni biometrični prepoznavni sistem osnovan na fuziji dlani, prstnega odtisa in obraza	21
3.3	Merjenje algoritmov večmodalne biometrične fuzije z vidika kvalitete in cene	23
3.4	Večmodalna biometrična fuzija na nivoju mer podobnosti z uporabo metod GMM in Monte Carlo	24
4	Fuzija na podlagi fuzijskih pravil	27
4.1	Fuzija z vsoto	27
4.2	Fuzija s produktom	27
4.3	Min-max fuzija	28
4.4	Rezultati	28
4.4.1	ROC	28
4.4.2	Enakovredna stopnja napake EER	36
4.4.3	Verifikacija pri 0,1% FAR	38
5	Fuzija na podlagi metod razvrščanja	43
5.1	Metoda podpornih vektorjev	43
5.2	Klasifikacijsko drevo	45
5.3	Nevronske mreže	46
5.4	Rezultati	46
5.4.1	Metoda podpornih vektorjev	47
5.4.2	Klasifikacijsko drevo	47
5.4.3	Nevronske mreže	47
6	Zaključek	49
	Literatura	53
	Slike	57
	Tabele	59

Povzetek

V diplomski nalogi je predstavljen postopek večmodalne biometrične fuzije, ki združuje sistem za verifikacijo oseb na podlagi prstnih odtisov in sistem za verifikacijo oseb na podlagi obrazov. Implementirana je fuzija na nivoju mer podobnosti in sicer fuzija na podlagi fuzijskih pravil in fuzija na podlagi metod razvrščanja. Pri prstnih odtisih se kot vhod uporabi izhod iz FingerIdenta, na podlagi katerega se ustvari matrika razdalj.

Oba sistema delujeta na testni in učni množici vhodnih podatkov. Vsaka je sestavljena iz 800 vzorcev – 8 vzorcev na osebo, 100 oseb. Velikost vhodnih matrik v fuzijo je tako 800×800 .

Uspešnost fuzije je bila obravnavana skozi sledeče mere: ROC, AUC, EER, verifikacija pri 0,1% FAR. Rezultati so pokazali da fuzija pri izbranih postopkih izboljša uspešnost sistema.

Ključne besede:

fuzija, računalniški vid, prstni odtisi, obrazi, biometrija

Abstract

The diploma thesis presents the procedure of multimodal biometric fusion, which combines the verification system based on fingerprints and the verification system based on faces. The fusion is implemented at the matching score level, namely the fusion based on fusion rules and the fusion based on classification methods. For the fingerprint's part of the input, the FingerIdent's output is used. On the basis of which, the matrix of distances is then created and used in the fusion.

Both systems work on the learn and the test set. Each consists of 800 samples – 8 samples per person, 100 persons total. The size of the input matrices used for the fusion is 800×800 .

The performance of the fusion was addressed through the following measures: ROC, AUC, EER, Verification at 0,1% FAR.

The results have shown that the fusion improves the performance of the system.

Keywords:

fusion, computer vision, fingerprints, faces, biometrics

Poglavje 1

Uvod

Pri verifikaciji oseb se srečujemo s tradicionalnimi metodami in metodami, ki temeljijo na biometriji posameznika. Pri prvi skupini se za verifikacijo uporabljajo umetno ustvarjeni ključi – uporabniška gesla, fizični ključi, serija potez, v naprej pripravljena gesla v obliki kartic, elektronskih ključev in podobno. Pri drugi skupini se srečujemo s širokim naborom bioloških metrik – tako fizičnih značilnosti kot značilnosti obnašanja. Ti lahko zajemajo vse od prstnih odtisov, obraznih značilk, šarenice pa vse do načina hoje, bitja srca ali barve glasu, kot tudi načina govora ali lastnoročnega podpisa pri značilnostih obnašanja.

Prednost biometrične verifikacije je v tem, da je za vsakega posameznika unikatna in se je ne da odtujiti. Uporabniku prav tako ni potrebno posedovati specifičnih predmetov ali znanja, ki pri tradicionalnih metodah predstavljajo predpogoj za uspešno verifikacijo.

Slabosti biometrične verifikacije so odvisne od izbire metode in implementacije izbrane metode. Potrebno je skleniti kompromis med številom napačno sprejetih in številom napačno zavrnjenih primerov. Bolj ko je metrika preprosta za strojno obdelavo in hkrati še vedno ponuja dovolj posebnosti za razlikovanje med primeri, bolj zanesljiv bo postopek verifikacije. V splošnem so tako prstni odtisi bolj zanesljivi kot obrazi.

Z dograjevanjem in izboljševanjem metode za verifikacijo lahko metodo

izboljšamo le do neke mere. Naletimo lahko tudi na mejo, kjer je izboljševanje prezahtevno ali preveč potratno (tako finančno kot časovno) v primerjavi s prednostmi ki jih taka izboljšava prinaša.

Problem ponarejanja biometričnih metrik je prav tako težava, s katerim se vse pogosteje srečujemo. Pridobitev prstnega odtisa posameznika za namene zlorabe ni posebno težka. Sistemi, ki zajemajo prstne odtise zato pogosto potrebujejo dodatne mehanizme za preprečevanje ponarejanja. Detektor vlage, toplote ali srčnega utripa v čitalcu prstnih odtisov so le nekateri izmed njih. Z njimi se prepreči ponarejanje prstnega odtisa s preprostim odlitkom, ali celo fotografijo – če je čitalec kamera. Pri detekciji obraza so težave podobne, posameznik lahko verifikacijski sistem pretenta s fotografijo obraza. Temu se do neke mere da izogniti s stereo zajemom obraza, vendar je takšna analiza veliko bolj zahtevna.

Oba omenjena problema lahko omejimo ali celo zaobidemo tako, da se poslužimo fuzije dveh ali večih enomodalnih biometričnih verifikacijskih sistemov [1][2]. Temu pravimo večmodalna biometrična fuzija. Zanesljivost takega sistema bi se torej morala izboljšati brez kakršnega koli spreminjanja baznih verifikacijskih sistemov. Če, in do kolikšne mere to drži, je tema tega diplomskega dela.

V poglavju 2 je predstavljeno osnovno delovanje celotnega sistema. Od zajema vhodnih podatkov do postopka fuzije. Na področju biometrične fuzije je bilo narejenih veliko raziskav. Nekaj teh del je predstavljenih v poglavju 3. V poglavjih 4 in 5 so obravnavane metode preverjanja učinkovitosti različnih fuzijskih metod. V poglavju 4.4 so predstavljeni rezultati in njihova interpretacija. Sledi zaključek, v katerem so poleg prednosti slabosti uporabljenih postopkov izpostavljene tudi predloge za nadaljno delo.

Poglavje 2

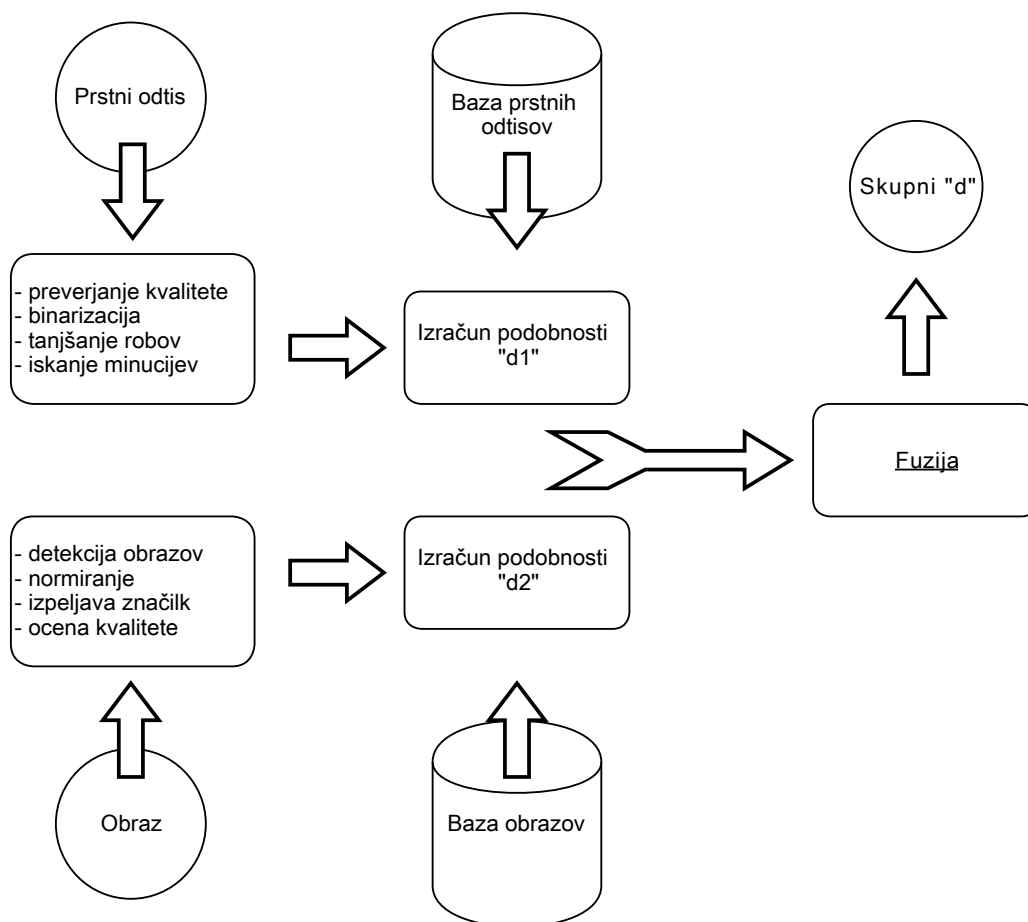
Arhitektura sistema

Sistem je sestavljen iz dveh ločenih sistemov. Iz sistema namenjenega razpoznavi prstnih odtisov in iz sistema namenjenega razpoznavanju obrazov. Oba sistema delujeta ločeno v načinu verifikacije in vhodno sliko primerjata zgolj z eno predlogo iz sistema.

Vsak sistem ima svojo bazo, sestavljeno iz 1600 primerov. Pri prstnih odtisih so to slike prstnih odtisov, pri obrazih slike obrazov. Polovica primerov predstavlja učno množico, druga polovica pa testno.

Ker oba sistema delujeta ločeno to vodi do dveh ločenih mer podobnosti oz. razdalj. Ena mera podobnosti za prstne odtise in ena za obraz. Vsak par mer d_1 in d_2 nato služi kot vhod v postopek fuzije, katere rezultat je enotna ocena d za vsakega od vhodnih parov. Vhodna sistema za razpoznavanje prstnih odtisov in obrazov tako ostajata nespremenjena.

Sistem trenutno ne deluje v realnem času, vendar ni teoretičnih razlogov, da tudi ne bi. Groba arhitektura sistema je prikazana na sliki 2.1.



Slika 2.1: Diagram arhitekture sistema

Vse mere obeh sistemov smo obravnavali v obliki razdalj. Gre za dogovor, saj bi vse mere lahko obravnavali v obliki podobnosti. Pretvorba med oblikama je trivialna (enačba 2.1). Nujno je le, da so vse mere podane na enak način.

$$\text{podobnost} = -1 \times \text{razdalja} \quad (2.1)$$

Pri čemer velja, da majhne vrednosti mere v obliki razdalje pomenijo veliko podobnost, velike vrednosti pomenijo majhno podobnost. Ravno obratno pri obliki podobnosti, kjer velika vrednost pomeni veliko podobnost in majhna vrednost majhno podobnost. Povezava je torej enostavna in eno pretvarjamo v drugo zgolj z množenjem z -1 .

2.1 Razpoznavanje prstnih odtisov

Vir podatkov predstavlja sistem FingerIdent opisan v nadaljevanju. Sistem za poljubni slikovni datoteki prstnih odtisov poda oceno podobnosti. Vhodne slikovne datoteke so shranjene na datotečnem sistemu.

Potrebno je bilo razviti podporni program, ki iterira skozi celotno bazo 800 slik učne množice in bazo 800 slik testne množice. Pri vsaki iteraciji podporni program poda FingerIdent sistemu trenutno kombinacijo slik. Na podlagi mer podobnosti se v vsaki iteraciji zgradi dve 800×800 veliki matriki podobnosti. Kot že omenjeno v poglavju 2 mora matrika, ki vsebuje mere o prstnih odtisih kot tudi matrika obrazov vsebovati enak tip mer – razdalje ali podobnosti. Ker smo se odločili za prvo, je bilo potrebno v tem delu vse mere pretvoriti v razdalje, torej celotno matriko pridobljeno s podpornim programom množiti z -1 .

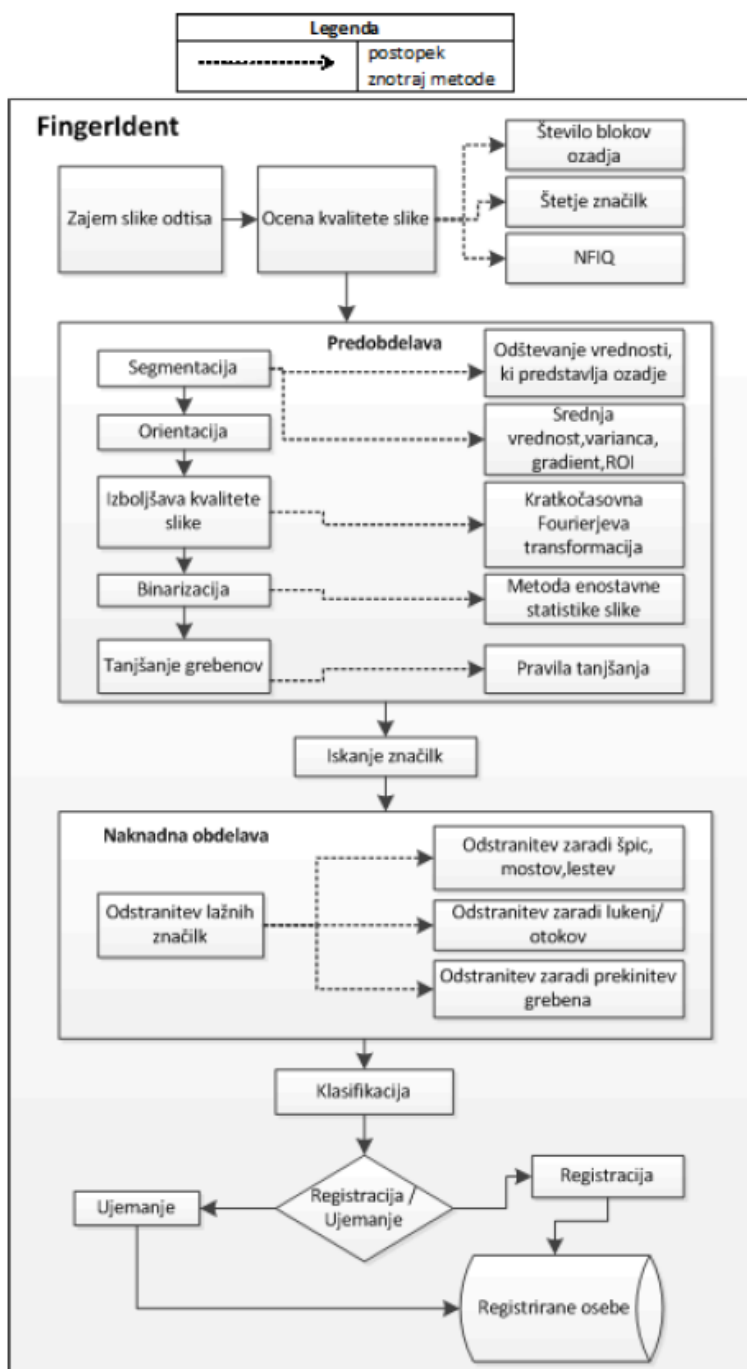
Cilj je matrika učne množice velikosti 800×800 in matrika testne množice enake velikosti 800×800 . Potrebno je poudariti, da primerjave, ki jih izvaja FingerIdent sistem niso komutativne. Velja torej enačba 2.2, kjer \circ predstavlja primerjavo prstnih odtisov, ki jih izvaja FingerIdent.

$$odtis_1 \circ odtis_2 \neq odtis_2 \circ odtis_1 \quad (2.2)$$

Literatura predlaga vrsto izboljšav pri zajemu prstnih odtisov. Delo [3] obravnava predhodno obdelavo zajetih slik pred postopkom analize in verifikacije – za izboljšavo je uporabljen Gabor filter. V [4] so avtorji postopek razpoznave izboljšali s serijo algoritmov v okolju Matlab, kar je s stališča tega diplomskega dela še posebej zanimivo. Pomemben del zajema prstnih odtisov je preprečevanje ponarejanja. Delo [5] je zanimivo, ker avtorji obravnavajo ponarejanje prstnih odtisov na nivoju slikovnega zajema – in ne z rabo dodatne strojne opreme. Ponaredke je tako mogoče zaznati v majhnih poškodbah in nenaravnih prekinitvah grebenov.

2.1.1 Uporabljeni postopek razpoznavanja prstnih odtisov in pregled sistema

Splošno lahko delovanje biometrične knjižnice FingerIdent [6] razdelimo na dva glavna dela. To sta registracija uporabnika (angl. enrollment) in proces verifikacije uporabnika (angl. verification). V procesu registracije se s pomočjo biometrične naprave zajamejo podatki, v naslednji fazi pa se preveri kvaliteta zajetega vzorca. Če je kvaliteta ustrezna, se v zajetem vzorcu poiščejo značilnosti, ki se shranijo v podatkovno bazo. V procesu verifikacije se na zajetem vzorcu poiščejo značilnosti, ki se primerjajo s tistimi, ki so shranjeni v bazi. Uporabnik se uspešno identificira, ko pride do ujemanja vzorcev.



Slika 2.2: Shema sistema za verifikacijo na podlagi prstnega odtisa

Podrobnejše delovanje sistema FingerIdent oziroma sistema algoritmov dotičnega sistema v grobem opišemo z moduli, ki so predstavljeni na sliki 2.2. V nadaljevanju sledi kratek opis korakov algoritma za verifikacijo oseb na podlagi prstnega odtisa.

Zajem prstnega odtisa

Prstni odtis zajamemo s pomočjo optičnega čitalca prstnih odtisov. Čas pridobitve slike je zelo kratek, saj današnji čitalci zajemajo slike v časovnem intervalu ene sekunde. Zajem prstnega odtisa je zelo pomemben korak, saj so vsi nadaljnji koraki obdelave odvisni od kvalitete zajetega odtisa.

Segmentacija

Pri segmentaciji poskušamo čim boljše ločiti prstni odtis od ozadja. S tem se izognemo procesiranju predelov slike, ki bodisi vsebujejo preveliko šuma, bodisi za nas niso zanimivi. Na ta način skrajšamo čas procesiranja in hkrati povečamo natančnost primerjanja odtisov. Natančna segmentacija je posebej pomembna za pravilno in zanesljivo iskanje značilnk, singularnih točk.

Izboljšanje kvalitete slike prstnega odtisa

Včasih se zgodi, da pride pri zajemu prstnih odtisov do določenih nepravilnosti, kot so npr. prekinitve grebenov ali pa razne poškodbe (ureznine). Ker je učinkovitost algoritma za iskanje značilnk zelo odvisna od kvalitete zajetih prstnih odtisov, lahko slabo zajet odtis močno zmanjša učinkovitost algoritma. Za takšne primere je nujno, da uporabimo algoritem za izboljšanje kvalitete slike prstnega odtisa. Takšni algoritmi popravijo strukturo obnovljivih regij in označijo neobnovljive regije kot nezmožne za nadaljnjo procesiranje.

Binarizacija

Namen binarizacije je doseči, da je vsak slikovni element predstavljen z 0 ali 1. Rezultat je slika, kjer so grebeni predstavljeni z bitom 1, ozadje pa z

bitom 0.

Tanjšanje grebenov

Namen tega koraka je, da zmanjšamo debelino grebena na en slikovni element. Uporabljeni algoritem deluje tako, da začne odstranjevati slikovne elemente na zunanjih robovih grebenov, dokler niso debeli zgolj en slikovni element.

Iskanje in obdelava značilk

Osnovna tipa značilk sta razcep in zaključek. Naloga algoritma za iskanje značilk je, da najde ta dva osnovna tipa. Ker pri iskanju značilk večkrat pride do napak, je potrebno dobljene značilke dodatno obdelati. Vse značilke zato preverimo še z algoritmom za verifikacijo značilk, odstranimo nepravilne značilke ter tako povečamo zanesljivost sistema.

Iskanje ujemanja

Primerjanje je zadnji korak sistemov za verifikacijo na podlagi prstnih odtisov. Obstaja več načinov primerjanja prstnih odtisov (korelacijska metoda, primerjanje na podlagi značilk in metoda primerjanja grebenov [7]), pri čemer naš sistem uporablja primerjanje na podlagi značilk. Pri tem načinu primerjanja se prstni odtisi ujemajo takrat, ko obstaja potrebno število značilk, ki se ujemajo v tipu, lokaciji in usmerjenosti. V koraku primerjanja torej dobimo odgovor na vprašanje, ali se vhodni prstni odtis ujema s katerim od odtisov, ki jih imamo registrirane v podatkovni bazi za neko osebo.

2.2 Razpoznavanje obrazov

Vhodni podatki dela obrazov predstavlja že zgenerirana matrika razdalj. Tu obravnava slikovne baze obrazov in izdelava podpornega programa zato ni

bila potrebna. Podatki so razporejeni enako kot pri prstnih odtisih – dve 800×800 matriki, učna in testna.

Obe matriki sta simetrični glede na diagonalno os. To pomeni, da so primerjave obraza komutativne, velja enačba 2.3, kjer \circ predstavlja primerjavo obrazov.

$$obraz_1 \circ obraz_2 = obraz_2 \circ obraz_1 \quad (2.3)$$

To je pomemben podatek zaradi zmogljivostnih razlogov, saj je potrebno narediti le polovico primerjav. Pri implementacijem delu diplomske naloge težav s pomanjkanjem pomnilniškega prostora sicer ni bilo, težave z dolgim izvajanjem pa so bile prisotne. Dolgo izvajanje je predstavljajo resnični problem pri SVMju, kjer je vsako izvajanje na 64.000 vzorcih trajalo reda velikosti ure in več, na nekoliko starejšem (leta 2013) procesorju Intel Core 2 generacije in 64-bitnem operacijskem sistemu.

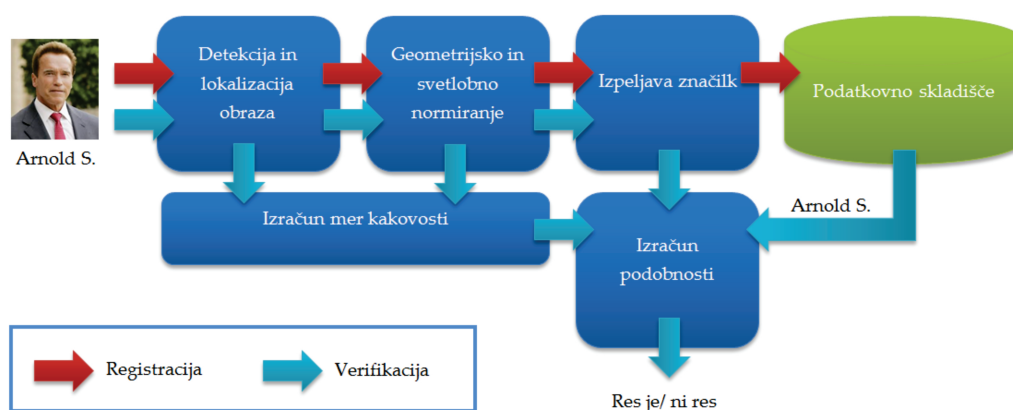
Vse to je za končno odločitev nepomembno, če je namen rabe omejen na sisteme, ki ne zahtevajo realno časovnega procesiranja. Pri sistemu v realnem času pa je lahko odločitev izbire algoritma odločilnega pomena. Lahko si namreč predstavljamo vgnedene (embedded) sisteme pri katerih je čim cenejša strojna oprema pomemben faktor pri gradnji, odzivnost pa lastnost, ki lahko predstavlja mejo med nakupom ali zavrnitvijo sistema.

2.2.1 Uporabljeni postopek razpoznavanja obrazov in pregled sistema

V tem razdelku na kratko predstavimo sistem za razpoznavanje obrazov, ki smo ga uporabili kot osnovo za naše delo. Sistem je nastal kot rezultat razvojno-raziskovalnega dela podjetja Alpineon d.o.o. v okviru kompetenčnega centra KC CLASS. Poudarimo, da namen tega razdelka ni natančna predstavitev vseh delov sistema, ampak zgolj opis osnovnih konceptov delovanja.

Osnovna shema uporabljenega sistema za razpoznavanje obrazov je predstavljena na sliki 2.3. Kot lahko opazimo je delovanje sistema razdeljeno v

dva ločena dela: registracijo in verifikacijo. Pri tem je registracija namenjena izgradnji biometričnih predlog danega uporabnika v sistemu in verifikacija potrjevanju identitete uporabnika na podlagi zajete slike obraza.



Slika 2.3: Bločna shema uporabljenega sistema


Ne glede na trenutni način delovanja sistema (registracija ali verifikacija), je postopek obdelave vhodne slike podoben. Ko sistem registrira uporabnika, se na vhodni sliki najprej detektira obrazno področje, le-to se nato geometrijsko in svetlobno normira, iz normiranega področja pa se v zadnjem koraku izpeljejo značilke, ki se skupaj z identifikacijsko oznako vhodne slike shranijo v podatkovnem skladišču sistema. Ko sistem deluje v načinu verifikacije, se vsi predstavljeni koraki ponovijo, pri čemer se shranjevanje biometrične predloge nadomesti z izračunom podobnosti s predlogami iz podatkovnega skladišča sistema. V nadaljevanju predstavimo osnovno delovanje posameznih delov sistema in opišemo pomen in vlogo vsakega od njih.

Detekcija in lokalizacija obrazov

Prvi korak v verigi obdelave vhodne slike obraza predstavlja detekcija obrazov. Z detekcijo želimo ugotoviti ali so na vhodni sliki prisotni obrazi in kje se nahajajo. S stališča razpoznavanja vzorcev ta korak predstavlja postopek določanja področja zanimanja. V sistemu, ki smo ga uporabili za naše ekspe-

rimente je ta korak izveden s pomočjo detektorja Viole in Jonesa [8]. Vhodne slike so predhodno obdelane s preprostim postopkom za odpravljanje svetlobnih motenj na podlagi gama korekcije in adaptivne izravnave histograma, s katerim se poskuša detekcijo prirediti tudi za zahtevne svetlobne razmere.

Rezultat tega postopka predstavlja informacija o prisotnosti, številu in okvirni lokaciji vseh obrazov na vhodni sliki. Ilustracija rezultatov detekcije je prikazana na sliki 2.4.



Slika 2.4: Ilustracija rezultata postopka detekcije

Detekciji širšega obraznega področja sledi še lokalizacija. V postopku lokalizacije se določi lega značilnih delov obraza, ki služijo kot podlaga za geometrijsko normiranje obraznega področja. Podobno kot v primeru detekcije obraznega področja, se tudi pred postopkom lokalizacije izvede svetlobno normiranje obraznega področja, tokrat na podlagi postopka »retinex«. Sam postopek lokalizacije se izvede na podlagi korelacijskih filtrov PSEF [9]. Rezultat procesiranja predstavlja detektirano obrazno področje skupaj s koordinatami značilnih delov obrazov.

Geometrijsko in svetlobno normiranje

Detekciji in lokalizaciji obraznega področja sledi geometrijsko in svetlobno normiranje, s katerim želimo iz našega področja zanimanja izločiti vse, kar v

postopek razpoznavanja vnaša nezaželeno variabilnost.

V okviru geometrijskega normiranja obraz postavimo v pokončno lego (ne podlagi razmerij med legami značilnih delov obraza) in ga skaliramo na standardno velikost 128×128 slikovnih elementov. S poravnavo obraznega področja se doseže neodvisnost postopka razpoznavanja na manjše spremembe v zornem kotu, pod katerim je bila slika obraza zajeta, s skaliranjem na določeno velikost pa se izloči vpliv različnih oddaljenosti zajetega obraza od kamere. V okviru svetlobnega normiranja tokrat pa izvedemo najzahtevnejši in s tem tudi najučinkovitejši postopek normiranja.

Rezultat obdelave v tem delu predstavlja slikovno področje obraza, s katerega so odstranjeni vsi (oz. večina) variabilni deli, kot so pričeska, zunanji obris obraza, ipd. Primer slike obraza pred in po obdelavi lahko vidimo na sliki 2.5.



Slika 2.5: Ilustracija učinka normiranja: vhodne slike (levo), po detekciji in geometrijskem normiranju (sredina), po svetlobnem normiranju (desno)

Izpeljava značilk

Normirano področje obraza predstavlja vhodni podatek za naslednji del sistema, ki je namenjen izpeljavi obraznih značilk. V tem delu se obrazno področje predstavi v obliki kar se da diskriminatornega vektorja značilk. V sistemu, ki smo ga uporabili je za naše poizkuse je bilo to izveden na podlagi filtriranja z množico Gaborjevih filtrov ter kodiranja amplitudnih odzivov filtriranja z krajevnimi dvojiškimi vzorci (angl. local binary pattern – LBP). Kot podporna predstavitev se v sistemu uporablja še amplituda gradienta

slike in nekaj koeficientov DCT transformacije slike [10].

Značilke slike se v fazi registracije uporabnika skupaj z identifikacijsko oznako shranijo v podatkovnem skladišču sistema, v fazi verifikacije identitete uporabnika pa se uporabijo za določitev podobnosti s shranjenimi predlogami.

Izračun mer kakovosti

Tekom celotnega postopka obdelave, se na podlagi vmesnih rezultatov obdelave slike izračunavajo še različne mere kakovosti slike, ki opisujejo slikovne karakteristike, ki niso nujno povezane z identiteto osebe na sliki, ampak z zunanjimi razmerami, ki so bile prisotne ob zajemu vhodne slike obraza. Te mere opisujejo veličine kot so kontrast slike, gostoto robov na obraznem področju, korelacijo s povprečnim obrazom, ipd. Namen teh mer je dodajanje prostostnih stopenj v postopek razvrščanja in s tem upoštevanje zunanjih pogojev pri procesu odločanja. Učinek oz. vpliv mer podobnosti lahko enačimo z učinkom oz. vplivom postopkov normiranja mer podobnosti, ki v sistemih za prepoznavanje obrazov služijo podobnemu namenu [10].

Rezultat izračuna različnih mer kakovosti je vektor mer kakovosti, ki je uporabljen zgolj v postopku izračuna podobnosti.

Izračun podobnosti

V zadnjem koraku, torej samem postopku razpoznavanja oz. v našem primeru verificiranja, se izvede še izračun podobnosti med dvema vektorjema značilk. V sistemih za verifikacijo to pomeni izračun podobnosti med vektorjem, ki je izpeljan iz obraznega področja vhodne slike, in vektorja, ki ustreza identiteti, za katero uporabnik trdi, da mu je lastna. Omenimo, da je merjenje podobnosti nujno, saj dva zajeta vzorca (t.j., vhodni sliki) zaradi različnih virov šuma, variabilnosti zaradi spremenljivih svetlobnih razmer, zornih kotov, obrazne mimike, ipd nista nikoli povsem enaka. V sistemu, ki smo ga uporabljali je merjenje podobnosti izvedeno s posebno razdaljo za merjenje podobnosti histogramov ter večkratnega učenja z uteževanjem

učnih primerov (angl. AdaBoost). Rezultat postopka je skupna mera podobnosti, ki služi kot osnova za sprejem odločitve o tem ali je uporabnik res ta, za katerega se izdaja [10].

2.3 Normalizacija vhodnih podatkov

Pred postopkom fuzije je potrebno opraviti normalizacijo vhodnih podatkov. Mere podobnosti oz. razdalj namreč niso v istem velikostnem rangju. To povzroči težave predvsem pri min-max fuzijskem algoritmu, saj nižja vrednost mere razdalje sistema prstnih odtisov od mere razdalje sistema obrazov ne pomeni nujno tudi večje bližine. Vrednosti je zato potrebno pretvoriti v skupno velikostno področje [11].

Odločili smo se za min-max normalizacijo. Na tem mestu morda ni odveč opozorilo, da min-max normalizacija ni povezana z min-max fuzijskim algoritmom, le imeni sta podobni. Min-max normalizacijska tehnika je bila uporabljena med drugim v delu [12], ki je podrobneje obravnavano v poglavju 3.2.

Omenjena normalizacijska tehnika sledi enačbi prikazani v 2.4.

$$\begin{aligned}d_{norm}(odtisi) &= \frac{d(odtisi) - \min(odtisi)}{\max(odtisi) - \min(odtisi)} \\d_{norm}(obrazi) &= \frac{d(obrazi) - \min(obrazi)}{\max(obrazi) - \min(obrazi)}\end{aligned}\tag{2.4}$$

Slabost te tehnike je v tem, da ni robustna [11][13] in je občutljiva na robne primere. To se je pokazalo že na primeru prstnih odtisov in obrazov, kjer so robne vrednosti glede na ostale podatke različnih velikostnih razmer. Razmerje robne vrednosti proti srednji je pri prstnih odtisih 1 : 100, medtem ko pri obrazih znaša približno 1 : 3. Dobra stran je njena preprostost.

V delu [13] in v literaturi je obravnavanih še veliko drugih normalizacijskih

tehnik. V splošnem jih delimo na več načinov [11]. V delu [13] je predlagana delitev na dve skupini: adaptivne in neadaptivne tehnike normalizacije. V slednjo spada že omenjena min-max, decimalno skaliranje, ocena-Z, mediana, tanh. V prvo skupino, skupino adaptivnih tehnik normalizacije pa uvrstimo QQ, QLQ in dvojni sigmoid [13].

2.4 Fuzija

Fuzija lahko v grobem poteka na večih nivojih [14]

1. na nivoju signalov
2. na nivoju izpeljave značilnik
3. na nivoju mer podobnosti
4. na nivoju odločanja

Zaradi že vzpostavljenih ločenih sistemov za razpoznavanje prstnih odtisov in obrazov je odločitev o izboru nivoja smiselna le za zadnja dva – fuzija na nivoju mer podobnosti in na nivoju odločanja. Odločili smo se za fuzijo na nivoju mer podobnosti zaradi preprostejšje izvedbe in pogostosti takšnega načina fuzije. Takšna fuzija se je glede na EER (angl. Equal Error Rate) empirično izkazala tudi za najbolj uspešno[14].

Omeniti je potrebno, da se v literaturi obravnava tudi fuzijo na nivoju rangiranja za identifikacijske sisteme, kjer vsak klasifikator vsak nov primer uvrsti v rang. Rang nato služi kot mera za dobro ali slabo ujemanje.

2.4.1 Fuzija na nivoju signalov

Posnetek govora, slika obraza, slika prstnega odtisa ali video sekvenca hoje so v končni obliki vedno predstavljeni kot 1-dimenzionalni signal [14]. V delu [15] je predlagan sistem, ki za verifikacijo kombinira podatke prstnega odtisa, obraza, šarenice in podpisa. Fuzija je opravljena na nivoju signalov, ki so

razdeljeni s pomočjo DWT (angl. Discrete Wavelet Transform). Dokazano je bilo, da tak fuzijski pristop zmanjša porabo pomnilnika ob istočasni izboljšavi uspešnosti takega biometričnega sistema [15]. Na primeru obraza lahko 2-dimenzionalno informacijo o teksturi in 3-dimenzionalno informacijo o značilnostih obraza sestavimo v enotno 3-dimenzionalno teksturo, na kateri se izvaja nadaljna analiza [16]. Težava fuzije na nivoju signalov je v šumu, ki se na višjih nivojih zatire in so zato bolj primerni za fuzijo od signalnega nivoja [12].

2.4.2 Fuzija na nivoju izpeljave značilnk

Fuzija se opravlja v fazi parametrizacije. Če so značilke medsebojno združljive, se končni vektor značilnk izračuna na podlagi združevanja posameznih vektorjev značilnk. Taka fuzija ojača značilke, vendar potrebuje dodatne parametre za odpravo nepotrebnih informacij [14]. Geometrijske lastnosti roke se lahko razširi s koeficienti obraza, to pa potem sestavlja nov visoko dimenzionalni vektor značilnk [16]. Ker, tako kot fuzija na nivoju signalov, deluje že v fazi vsakega posameznega enomodalnega verifikacijskega sistema in je zato potrebno vsak tak sistem prilagoditi, se za tako fuzijo nismo odločili.

2.4.3 Fuzija na nivoju mer podobnosti

V diplomskem delu smo se odločili za fuzijo na nivoju mer podobnosti. Oba verifikacijska sistema – sistem za razpoznavanje prstnih odtisov in tudi sistem za razpoznavo obrazov dajeta končne rezultate v obliki razdalj oz. mer podobnosti. Te mere v obliki matrik služijo kot vhod v fuzijo na nivoju mer podobnosti. Rezultat je enotna združena ocena. Kot že omenjeno, se je ta fuzija izkazala tudi za najbolj uspešno [15]. Eden izmed glavnih razlogov, da je fuzija na nivoju mer podobnosti boljša od fuzije na nivoju odločanja, je v tem, da imamo v tem nivoju na voljo več informacij. Pri vsaki stopnji se podatki kompresirajo informacija pa posledično izgublja [12].

Osredotočili smo se na dva pristopa:

1. fuzija na podlagi fuzijskih pravil
2. fuzija na podlagi razvrščevalnikov

Fuzija na podlagi razvrščevalnikov namreč omogoča nelinearne meje med vsiljivci in klienti in je zato pomembna za analizo uspešnosti fuzije.

2.4.4 Fuzija na nivoju odločanja

Pri fuziji na nivoju odločanja vsak posamezen enomodalni sistem že vrne končni rezultat o sprejetju ali zavrnitvi primerka. Ker gre za binarne podatke, se fuzija lahko izvaja preko 'OR' in 'AND' operatorjev, večinskega glasovanja ali preko katere druge metode nad binarnimi vhodnimi podatki [14].

Poglavje 3

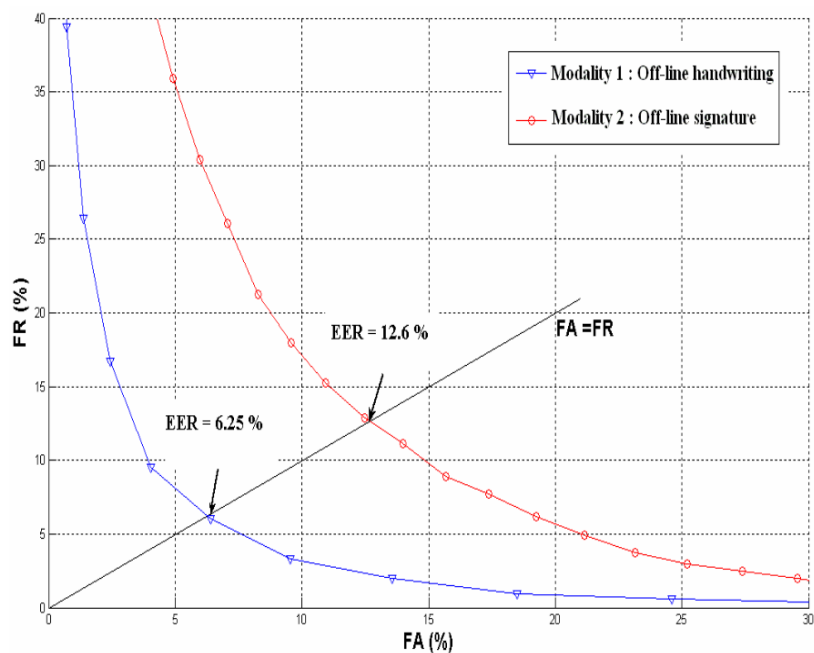
Sorodna dela

3.1 Dvomodalna biometrična verifikacija z različnimi nivoji fuzije

V delu "Bimodal Biometric Verification With Different Fusion Levels" [14] je predlagana fuzija dveh enomodalnih biometričnih verifikacijskih sistemov na več nivojih. Sistema temeljita na lastnoročnem podpisu in pisavi. Delo je zanimivo, ker obravnava fuzijo na večih nivojih.

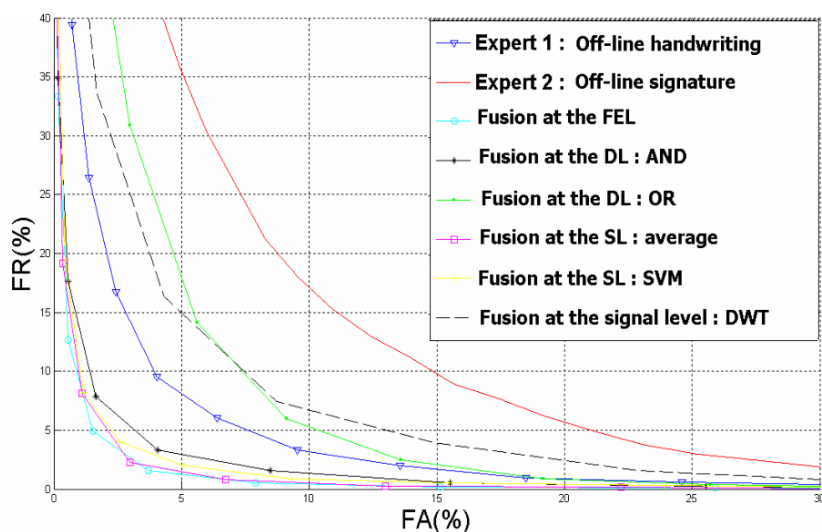
V prvem primeru se avtorji osredotočajo na fuzijo na nivoju izpeljave značilk – z združevanjem vektorjev glede na vsako modalnost. V drugem primeru gre za fuzijo na odločitvenem nivoju s konjuktivnimi (*AND*) in disjuktivnimi (*OR*) operatorji. Fuzija na nivoju mer podobnosti je realizirana na dva načina: aritmetično povprečje in metoda podpornih vektorjev SVM (angl. support vector machines). Fuzija informacij iz biometričnih slik temelji na diskretni valovni transformaciji DWT (angl. discrete wavelet transform). Na podlagi baze 12.000 primerov avtorji ugotavljajo, da najboljše rezultate daje fuzija na nivoju mer podobnosti.

Slika 3.1 prikazuje ROC krivulji za ločena enomodalna verifikacijska sistema. Krivulja označena z modro pripada ročni pisavi, rdeča lastnoročnemu podpisu.



Slika 3.1: ROC krivulji ločenih enomodalnih verifikacijskih sistemov [15]

Slika 3.2 ROC krivulje ločenih enomodalnih verifikacijskih sistemov v primerjavi z dvomodalnimi verifikacijskimi sistemi. Kratica FEL (angl. feature extraction level) označuje fuzijo na nivoju izpeljave značilnk. Kratica DL (decision level) označuje fuzijo na nivoju odločanja, SL (score level) pa fuzijo na nivoju mer podobnosti. Iz grafa je razvidno, da je fuzija na nivoju mer podobnosti (rumena in rdeča črta s kvadrati) najboljša. To vrsto fuzije smo uporabili tudi v tem delu.

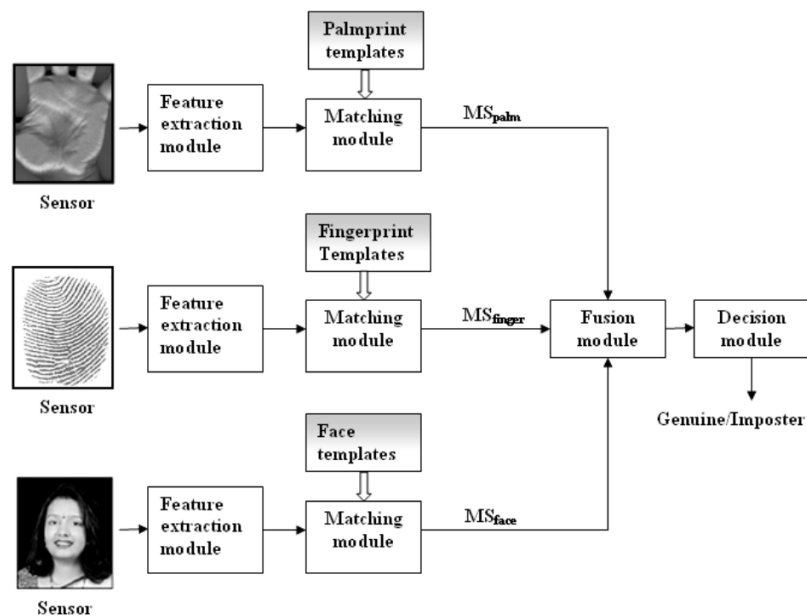


Slika 3.2: ROC krivulje ločenih enomodalnih verifikacijskih sistemov v primerjavi z dvomodalnimi verifikacijskimi sistemi [15]

3.2 Večmodalni biometrični prepoznavni sistem osnovan na fuziji dlani, prstnega odtisa in obraza

Avtorji dela "A Multimodal Biometric Recognition System Based on Fusion of Palmprint, Fingerprint and Face" [12] izvajajo večmodalno fuzijo na nivoju mer podobnosti. Fuzijski modul po prejemu mer podobnosti izvede normalizacijo in fuzijo na podlagi pravila utežene vsote. Delo je ravno zaradi naštetega zanimivo za obravnavo v tem diplomskem delu – normalizacija in fuzija na podlagi pravila utežene vsote.

Shema sistema, vidna na sliki 3.3, je analogna sistemu, obravnavanemu v tem diplomskem delu. Glavna razlika izhaja iz dejstva, da gre za večmodalni in ne dvomodalni sistem.

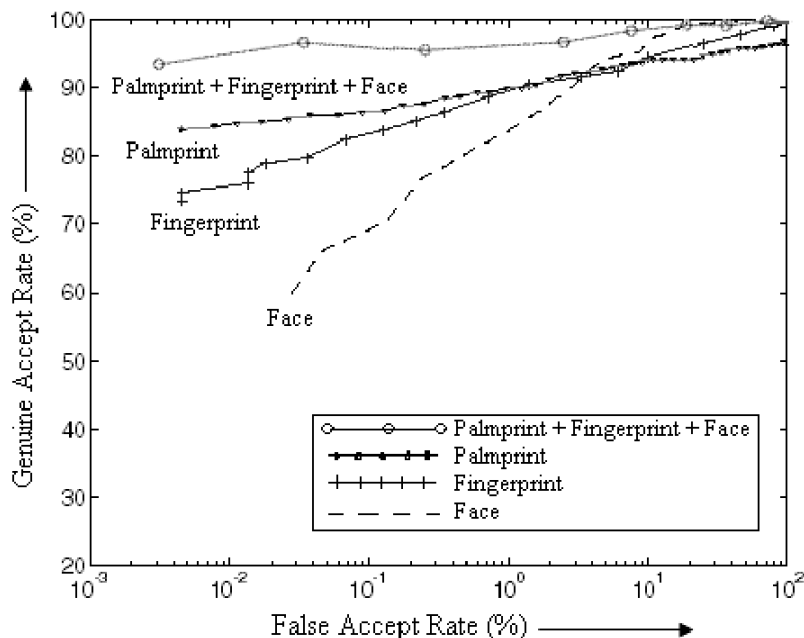


Slika 3.3: Bločni diagram večmodalnega biometričnega prepoznavnega sistema, ki temelji na fuziji dlani, prstnega odtisa in značilk obraza [12]

Normalizacija vseh treh mer podobnosti je potekala po enačbi 3.1, enaki enačbi v tem diplomskem delu. N_x predstavlja normirano mero podobnosti.

$$N_x = \frac{MS_x - \min_x}{\max_x - \min_x} \quad (3.1)$$

Rezultati so pokazali, da fuzija izboljša zmogljivost sistema. ROC krivulja fuzije na pravilu vsote je vidna na sliki 3.4, označena je s črto s krogi.



Slika 3.4: ROC krivulja fuzije v primerjavi s posameznimi ROC krivuljami obraza, prstnega odtisa dlani [12]

3.3 Merjenje algoritmov večmodalne biometrične fuzije z vidika kvalitete in cene

V delu "Benchmarking Quality-Dependent and Cost-Sensitive Score-Level Multimodal Biometric Fusion Algorithms" [17] se avtorji ukvarjajo z merjenjem kvalitete in cene algoritmov večmodalne biometrične fuzije. Delo je razdeljeno v dva dela: evalvacijo na podlagi odvisnosti od kvalitete in evalvacijo na podlagi občutljivosti na ceno.

Evalvacija odvisnosti od kvalitete ugotovlja, kako dobro se fuzijski algoritmi obnesejo pri spremenljivi kvaliteti surovih biometričnih slik. Evalvacija odvisnosti od cene pa ugotovlja, kako dobro se fuzijski algoritem obnaša pri danih strojnih, programskih in časovnih omejitvah ter pri namernih programskih in strojnih napakah. Delo je zanimivo ravno iz tega stališča, saj v

literaturi redko najdemo dela, ki bi obravnavale fuzijo iz tega stališča.


V delu ugotavljajo, da z večanjem števila posameznih biometričnih sistemov zanesljivost fuzijskega sistema narašča, vendar tudi cena. Rešitev, ki minimizira ceno celotnega sistema in hkrati daje dobre rezultate, je sekvenčna fuzija (sequential fusion). Fuzijski algoritem v tem primeru zaporedno uporablja mere podobnosti dokler ni dosežena zadana stopnja zanesljivosti oz. dokler niso obravnavane vse podane mere podobnosti.

3.4 Večmodalna biometrična fuzija na nivoju mer podobnosti z uporabo metod GMM in Monte Carlo

V delu "A Novel Approach for Multimodal Biometric Score Fusion using Gaussian Mixture Model and Monte Carlo Method" [18] je predlagana fuzija na podlagi GMM metode (Gaussian Mixture Model method) in na podlagi Monte Carlo metode. Prednost takega pristopa je, da je sistem sposoben dobro delovati na majhnem številu mer podobnosti in ko so mere podobnosti poljubno razporejene. Oboje je lastnost realnih sistemov, zato je omemba dela smiselna.


V delu je pokazana učinkovitost Monte Carlo metode v primerjavi z drugimi, bolj konvencionalnimi metodami kot so vsota, utežena vsota, FLD (Fishers Linear Discriminate Analysis) in LR (Likelihood Ratio).

Testi so bili izvedeni na treh podatkovnih bazah. Prva baza sestavljena iz kombinacije obrazov in dlani (na sliki 3.5a), druga iz kombinacije obrazov in govora (na sliki 3.5b) in tretja iz kombinacije dlani in govora (na sliki 3.5c).



(a) ROC krivulja na prvi pod. bazi

(b) ROC krivulja na drugi pod. bazi



(c) ROC krivulja na tretji pod. bazi

Slika 3.5: Primerjava ROC krivulj fuzije z metodo Monte Carlo v primerjavi z drugimi [18]

Poglavje 4

Fuzija na podlagi fuzijskih pravil

4.1 Fuzija z vsoto

Pri fuziji z vsoto se obe pridobljeni meri podobnosti d_1 in d_2 sešteje z različnimi utežmi – enačba 4.1.

$$d = w \times d_1 + (1 - w) \times d_2; 0 < w < 1 \quad (4.1)$$

Analiza se je opravljala na vrednostih w med 0 in 1, v korakih vrednosti 0, 1.

4.2 Fuzija s produktom

Pri fuziji s produktom se obe pridobljeni meri podobnosti d_1 in d_2 vrednotita kot prikazuje enačba 4.2.

$$d = d_1^w + d_2^{(1-w)}; 0 < w < 1 \quad (4.2)$$

Analiza se je, tako kot pri fuziji z vsoto, opravljala na vrednostih w med 0 in 1, v korakih vrednosti 0,1.

4.3 Min-max fuzija

Pri min-max fuziji se za skupno mero d izmed nabora d_1 in d_2 vedno vzame tisto ki je večja ali tisto ki je manjša, kot je to razvidno iz enačbe 4.3

$$d_{min} = \min(d_1, d_2) \tag{4.3}$$

$$d_{max} = \max(d_1, d_2)$$

4.4 Rezultati

Splošna zmogljivost verifikacijskega sistema se v splošnem da dobro opisati z ROC krivuljo (angl. Receiver Operation Characteristic), ki za vsako vrednost napačno sprejetih (FAR) primerov podaja vrednost napačno zavrženih (FRR). Razlika omenjenih mer je pogosto edina mera za končno zmogljivost sistema [14]. Zaradi tega je bila vključitev te mere v analizo nujna. V uporabi je veliko mer za določanje zmogljivosti sistema. Odločili smo se za sledeče:

- ROC krivulja
- Površina pod ROC krivuljo – AUC
- Enakovredna stopnja napake EER
- Verifikacija pri 0,1%FAR



Razlogi za takšno izbiro so v pogostosti uporabe in nizki zahtevnosti izvedbe. Izračun večine zgoraj omenjenih mer je na voljo že v osnovnem naboru Matlabovih knjižnic, za druge smo uporabili PhD knjižnico[19][20].

Posamezne mere so podrobneje opisane v nadaljevanju.


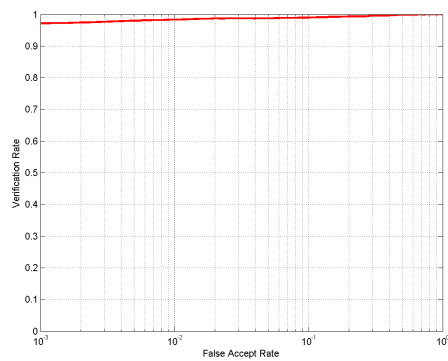



4.4.1 ROC







ROC krivulja, kot že omenjeno za vsako stopnjo sprejetih primerov podaja stopnjo napačno zavrženih. Take krivulje so dobre, ker omogočajo dobro

vizualno primerjavo, pogoste so v literaturi (med drugim v delu [21]). Hitro se lahko namreč oceni površina pod krivuljo (AUC) in strmina krivulje. Bolj, ko se krivulja približa zgornjemu levemu robu, bolj je. Skrajno levi zgornji rob – ob predpostavki, da so na x osi prikazani napačno sprejeti primeri in na y osi sprejeti primeri (v literaturi so osi tudi zamenjane) – označuje 100% pravilno sprejetje primerov. Točka na krivulji, ki se najbolj približa omenjenemu robu, se imenuje optimalna točka in je v analizo nismo vključili, saj se običajno ne uporablja.

(a) ROC krivulja za d_1 (b) ROC krivulja za d_2 Slika 4.1: ROC krivulji mer podobnosti d_1 in d_2 pred postopkom fuzije


ROC krivulji za obraze – d_1 in prstne odtise – d_2 sta prikazani na sliki 4.1.

(a) ROC krivulja za $w = 0$ (b) ROC krivulja za $w = 0, 1$ (c) ROC krivulja za $w = 0, 2$ (d) ROC krivulja za $w = 0, 3$ (e) ROC krivulja za $w = 0, 4$ Slika 4.2: ROC krivulj fuzije na podlagi vsote za $0 \leq w \leq 0, 4$


(a) ROC krivulja za $w = 0,5$ (b) ROC krivulja za $w = 0,6$ (c) ROC krivulja za $w = 0,7$ (d) ROC krivulja za $w = 0,8$ (e) ROC krivulja za $w = 0,9$ (f) ROC krivulja za $w = 1$ Slika 4.3: ROC krivulj fuzije na podlagi vsote za $0,5 \leq w \leq 1$

Sliki 4.2 in 4.3 prikazujeta ROC krivulje za vrednosti w med 0 in 1 s stopnjo koraka 0,1. Krivulji za $w = 0$ in $w = 1$ sta enaki krivuljama d_1 in


d_2 , prikazanima na slici 4.1.




(a) ROC krivulja za $w = 0$




(b) ROC krivulja za $w = 0, 1$



(c) ROC krivulja za $w = 0, 2$










(d) ROC krivulja za $w = 0, 3$



(e) ROC krivulja za $w = 0, 4$

Slika 4.4: ROC krivulj fuzije na podlagi produkta za $0 \leq w \leq 0, 4$

(a) ROC krivulja za $w = 0,5$ (b) ROC krivulja za $w = 0,6$ (c) ROC krivulja za $w = 0,7$ (d) ROC krivulja za $w = 0,8$ (e) ROC krivulja za $w = 0,9$ (f) ROC krivulja za $w = 1$ Slika 4.5: ROC krivulj fuzije na podlagi produkta za $0,5 \leq w \leq 1$



(a) ROC krivulja po min pravilu

(b) ROC krivulja po max pravilu

Slika 4.6: ROC krivulj fuzije na podlagi min-max pravila

Površina pod ROC krivuljo – AUC

Površina pod ROC krivuljo AUC izhaja direktno iz ROC krivulje in se v literaturi sicer nekoliko redkeje uporablja za mero uspešnosti, vendar se je tekom dela pri primerjavi različnih metod fuzije izkazala za uporabno. Predpostavlja se namreč, da je najbolj pomembno razmerje med napačno sprejetimi in pravilno sprejetimi primeri. Višja ko je vrednost, boljši je klasifikator. Težava mere je v tem, da bo strma krivulja (hitro doseže stopnjo pravilno sprejetih primerov) ovrednotena enako kot položna (počasi doseže stopnjo pravilno sprejetih primerov). V nadaljevanju omenjena enakovredna stopnja napake ERR je zato v splošnem bolj primerna.

Tabela 4.1 prikazuje AUC vrednosti za osnovna d_1 in d_2 parametra pred fuzijo. Površino pod krivuljo mero smo izbrali, ker je hitro razvidna približna učinkovitost izbrane metode, vendar se ne uporablja pogosto, saj ne pove veliko o FAR in FRR razmerju.

d_1	d_2
0,9755	0,9912

Tabela 4.1: AUC vrednosti d_1 in d_2

V tabeli 4.2 so zbrani rezultati fuzije na podlagi vsote. Hitro je jasno, da učinkovitost narašča le do neke mere in nato prične padati. To je hkrati prvi dokaz, da fuzija daje boljše rezultate od posameznih ločenih sistemov.

w	d
0	0,99124
0,1	0,99374
0,2	0,99499
0,3	0,99578
0,4	0,99630
0,5	0,99661
0,6	0,99677
0,7	0,99682
0,8	0,99668
0,9	0,99585
1	0,97552

Tabela 4.2: AUC vrednosti fuzije na podlagi utežene vsote d_1 in d_2

w	d
0	0,99124
0,1	0,96149
0,2	0,86137
0,3	0,73268
0,4	0,60447
0,5	0,50444
0,6	0,50704
0,7	0,66111
0,8	0,83234
0,9	0,94560
1	0,97552

Tabela 4.3: AUC vrednosti fuzije na podlagi uteženega produkta d_1 in d_2

min	max
0,99135	0,97552

Tabela 4.4: AUC vrednosti fuzije na podlagi min-max pravila za d_1 in d_2

4.4.2 Enakovredna stopnja napake EER

Enakovredna stopnja napake EER (angl. Equal Error Rate) podaja točko kjer sta FAR – stopnja napačno sprejetih (angl. False Acceptance Rate) in FRR – stopnja napačno zavrženih (angl. False Rejection Rate) enaka. Nižja kot je enakovredna stopnja napake EER, boljši je klasifikator. Pri nastajanju tega dela je bila enakovredna stopnja napake EER najpogosteje uporabljena mera v literaturi in sorodnih delih. Vrednosti so prikazane v tabelah 4.5 za d_1 in d_2 . Enakovredna stopnja napake EER fuzije na podlagi utežene vsote za $0 \leq w \leq 1$ so prikazane v tabeli 4.6. V tabeli 4.7 so prikazane

vrednosti fuzije na podlagi produkta, v tabeli 4.8 pa vrednosti za fuzijo na podlagi min-max pravila.

Enakovredna stopnja napake EER je razdeljena v pet podmer:

- ER: dejanska vrednost EER; nižje je bolje
- TR: prag potreben za dosego EER
- FRR: vrednost FRR (stopnja napačno zavrženih) pri ERR; nižje je bolje
- VER: vrednost stopnje verifikacije pri EER; višje je bolje
- FAR: vrednost FAR (stopnja napačno sprejetih) pri EER; nižje je bolje

	EER_{ER}	EER_{TR}	EER_{FRR}	EER_{VER}	EER_{FAR}
d_1	0,0717	-0,0796	0,0725	0,9275	0,0709
d_2	0,0161	-185,979	0,0156	0,9844	0,0166

Tabela 4.5: EER vrednosti d_1 in d_2

w	EER_{ER}	EER_{TR}	EER_{FRR}	EER_{VER}	EER_{FAR}
0	0,0161	-185,979	0,0156	0,9844	0,0166
0,1	0,0146	-167,181	0,0147	0,9853	0,0146
0,2	0,0137	-146,757	0,0133	0,9867	0,0141
0,3	0,0121	-128,284	0,0123	0,9877	0,0119
0,4	0,0097	-110,346	0,0098	0,9902	0,0096
0,5	0,0080	-92,490	0,0081	0,9919	0,0078
0,6	0,0070	-74,669	0,0067	0,9933	0,0072
0,7	0,0068	-58,817	0,0069	0,9931	0,0066
0,8	0,0089	-43,000	0,0089	0,9911	0,0089
0,9	0,0142	-27,038	0,0145	0,9855	0,0138
1	0,0717	-0,0796	0,0725	0,9275	0,0709

Tabela 4.6: Enakovredna stopnja napake EER fuzije na podlagi utežene vsote d_1 in d_2

w	EER_{ER}	EER_{TR}	EER_{FRR}	EER_{VER}	EER_{FAR}
0	0,0162	-185,579	0,0155	0,9845	0,0170
0,1	0,0856	-13,4329+8,8837i	0,0856	0,9144	0,0856
0,2	0,2065	-6,8306+4,5151i	0,2062	0,7937	0,2068
0,3	0,3244	-2,7848+1,9123i	0,3253	0,6747	0,3234
0,4	0,4249	-0,7671+0,5567i	0,4256	0,5744	0,4242
0,5	0,5013	0,0582-0,0063i	0,5016	0,4984	0,5011
0,6	0,4983	0,1221-0,0635i	0,4984	0,5016	0,4982
0,7	0,3895	0,0054-0,0290i	0,3528	0,6472	0,4261
0,8	0,2614	0,0427+0,0054i	0,1767	0,8233	0,3460
0,9	0,1333	-0,0131+0,0178i	0,0894	0,9106	0,1770
1	0,0715	-0,0898	0,0728	0,9272	0,0702

Tabela 4.7: Enakovredna stopnja napake EER vrednosti fuzije na podlagi uteženega produkta d_1 in d_2

tip	EER_{ER}	EER_{TR}	EER_{FRR}	EER_{VER}	EER_{FAR}
min	0,0161	-185,996	0,0156	0,9844	0,0166
max	0,0717	-0,0796	0,0725	0,9275	0,0709

Tabela 4.8: Enakovredna stopnja napake EER vrednosti fuzije na podlagi min-max pravila za d_1 in d_2

4.4.3 Verifikacija pri 0,1% FAR

Verifikacija pri 0,1% FAR (VER@0,1%FAR) je, podobno kot enakovredna stopnja napake EER, pogosto uporabljena mera uspešnosti. Podaja stopnjo verificiranih primerov v točki, kjer je napačno sprejetih 0,1% primerov. Mera je dobra, saj podaja stopnjo sprejetih primerov pri nizkih vrednostih napačno sprejetih, kar je zelo pomembno v sistemih, kjer je nizko napačno sprejetje vsiljivcev pomembnejše od napačnih zavrnitev. To je značilno za sisteme, ki

so namenjeni zamenjavi za klasične metode verifikacije (uporabniško geslo, ključ ipd.). Višja kot je mera, bolje je.

Vrednosti $VER@0,1\%FAR$ so prikazane v tabelah 4.9, 4.10, 4.11 in 4.12. Mera $VER@0,1\%FAR$ je, podobno kot enakovredna stopnja napake EER, razdeljena v pet podmer, opisanih v poglavju 4.4.2:

- ER: dejanska vrednost $VER@0,1\%FAR$; nižje je bolje
- TR: prag potreben za dosego $VER@0,1\%FAR$
- FRR: vrednost FRR (stopnja napačno zavrnjenih) pri $VER@0,1\%FAR$; nižje je bolje
- VER: vrednost stopnje verifikacije pri $VER@0,1\%FAR$; višje je bolje
- FAR: vrednost FAR (stopnja napačno sprejetih) pri $VER@0,1\%FAR$; nižje je bolje

	$V@0,1\%F_{ER}$	$V@0,1\%F_{TR}$	$V@0,1\%F_{FRR}$	$V@0,1\%F_{VER}$	$V@0,1\%F_{FAR}$
d_1	0,3127	-70,207	0,6253	0,3747	0,0001
d_2	0,0222	-275,104	0,0444	0,9556	0,0001

Tabela 4.9: $VER@0,1\%FAR$ vrednosti d_1 in d_2

w	$V@0,1\%F_{ER}$	$V@0,1\%F_{TR}$	$V@0,1\%F_{FRR}$	$V@0,1\%F_{VER}$	$V@0,1\%F_{FAR}$
0	0,0222	-275,104	0,0444	0,9556	0,0001
0,1	0,0208	-245,319	0,0414	0,9586	0,0001
0,2	0,0189	-217,183	0,0377	0,9623	0,0001
0,3	0,0171	-187,158	0,0341	0,9659	0,0001
0,4	0,0156	-158,613	0,0311	0,9689	0,0001
0,5	0,0142	-131,094	0,0283	0,9717	0,0001
0,6	0,0133	-107,795	0,0264	0,9736	0,0001
0,7	0,0138	-90,442	0,0275	0,9725	0,0001
0,8	0,0239	-82,091	0,0477	0,9523	0,0001
0,9	0,0775	-75,628	0,1550	0,8450	0,0001
1	0,3127	-70,207	0,6253	0,3747	0,0001

Tabela 4.10: VER@0,1%FAR vrednosti fuzije na podlagi utežene vsote d_1 in d_2

w	$V@0,1\%F_{ER}$	$V@0,1\%F_{TR}$	$V@0,1\%F_{FRR}$	$V@0,1\%F_{VER}$	$V@0,1\%F_{FAR}$
0	0,0223	-276,244	0,0445	0,9555	0,0001
0,1	0,3682	-52,4008+34,1497i	0,7362	0,2638	0,0001
0,2	0,4815	-56,7475+38,4192i	0,9628	0,0372	0,0001
0,3	0,4993	-46,7394+32,2329i	0,9984	0,0016	0,0001
0,4	0,4998	-33,4191+23,3708i	0,9995	0,0005	0,0001
0,5	0,5014	0,0080+0,0003i	0,5097	0,4903	0,4930
0,6	0,4971	-0,0462-0,0464i	0,5344	0,4656	0,4596
0,7	0,3895	0,0054-0,0290i	0,3528	0,6472	0,4261
0,8	0,2614	0,0427+0,0054i	0,1767	0,8233	0,3460
0,9	0,1333	-0,0131+0,0178i	0,0894	0,9106	0,1770
1	0,3125	-70,046	0,6248	0,3752	0,0001

Tabela 4.11: VER@0,1%FAR vrednosti fuzije na podlagi uteženega produkta d_1 in d_2

w	$V@0,1\%F_{ER}$	$V@0,1\%F_{TR}$	$V@0,1\%F_{FRR}$	$V@0,1\%F_{VER}$	$V@0,1\%F_{FAR}$
min	0,0222	-275,344	0,0442	0,9558	0,0001
max	0,3127	-70,207	0,6253	0,3747	0,0001

Tabela 4.12: VER@0,1%FAR vrednosti fuzije na podlagi min-max pravila za d_1 in d_2

Poglavje 5


Fuzija na podlagi metod razvrščanja

Metode razvrščanja so primerne, ker lahko določijo tudi nelinearne ločilne meje. To lahko privede do boljših rezultatov od fuzije na podlagi fuzijskih pravil. Iz obeh mer podobnosti se sestavi dvo-dimenzionalni vektor značilnik $g = [d_1, d_2]$. Za potrebe primerjave s čistimi merami podobnosti so bili uporabljeni tudi enodimenzionalni vektorji značilnik $g_1 = [d_1]$ in $g_2 = [d_2]$. Na podani učni množici nato metodo razvrščanja naučimo ločevati med dvema razredoma. Klienti (1) in vsiljivci (0). Končna mera podobnosti, ki jo poda metoda na izhodu, se uporabi kot skupna mera d . Uporabili smo sledeče metode razvrščanja: metodo podpornih vektorjev, klasifikacijska drevesa in nevronske mreže.

5.1 Metoda podpornih vektorjev

Metoda podpornih vektorjev je v literaturi poznana kot SVM (Support Vector Machine). Gre za eno najuspešnejših statističnih klasifikacijskih metod učenja [13]. Metoda podpornih vektorjev se da uporabiti le takrat, ko so podatki razdeljeni na točno dva razreda. Metoda podpornih vektorjev razrede klasificira tako linearno kot nelinearno, odvisno od uporabe funkcije jedra

(angl. kernel trick). Na sliki 5.1 je prikazana binarna linearna klasifikacija po metodi hiperravnine z največjo razliko, kjer se meja med razredoma določi tam, kjer je razlika največja.



Slika 5.1: Metoda podpornih vektorjev na podlagi hiperravnine z največjo razliko – gre za linearni klasifikator [22]

Pri delu z diplomsko nalogo se metoda podpornih vektorjev sicer ni najbolje izkazala (v primerjavi s klasifikacijskimi pravili in nevronskimi mrežami) ne v kvalitativnem in ne v cenovnem smislu. Od vseh obravnavanih metod je šlo za najpočasnejšo. Glede na delo [13] je normalizacija ključna. Predlagano je celo, da bi normalizacija postala eden izmed privzetih korakov metode podpornih vektorjev.

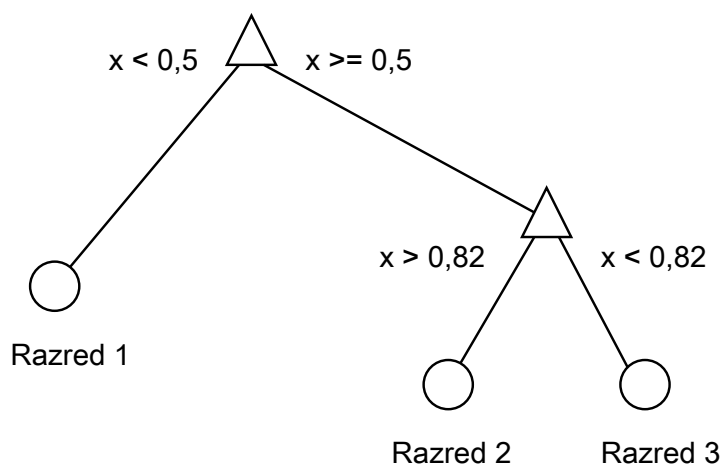
Metoda podpornih vektorjev se je izvajala v okolju Matlab. Postopek poteka v dveh fazah. Prva faza vključuje ukaz `svmtrain`, ki na podlagi vhodne učne množice in matrike pripadnosti razredu zgradi ustrezno strukturo,

ki se uporablja v nadaljni analizi. V drugi fazi se preko ukaza `svmclassify` vektorje (razdalje) testne množice primerja z oddaljenostjo od hiperravnine – na podlagi tega se podatek uvrsti v enega od razredov.

5.2 Klasifikacijsko drevo

Postopek klasificiranja s pomočjo klasifikacijskega drevesa poteka v Matlabu, s programerskega stališča podobno kot metoda podpornih vektorjev. Ukaz `ClassificationTree.fit` za dano učno množico in matriko pripadnosti razredu zgradi podporno binarno drevo. Z ukazom `predict` se na podanem drevesu in novimi podatki testne množice izvede klasifikacija.

Poenostavljena shema delovanja klasifikacijskega drevesa je prikazana na sliki 5.2. Na vrhu (v korenu drevesa) poteka prva razmejitev podatkov. Na dnu (v listih drevesa) se nahaja odziv na vhodne podatke. Klasifikacijska drevesa dajejo odgovor v obliki pripadnosti ali nepripadnosti podanemu razredu. Na primeru uporabljenega klasifikacijskega drevesa bi to bila *klient* in *vsiljivec*, oz. 1 in 0. Klasifikacijskim drevesom podobna so regresijska drevesa – ta podajajo številske rezultate in ne zgolj nominalnih.



Slika 5.2: Prikazano poenostavljeno klasifikacijsko drevo, ki klasificira v tri razrede


5.3 Nevronske mreže

Nevronske mreže so se izkazale za najuspešnejšo metodo izmed izbranih treh. Razlog verjetno leži tudi v tem, da je metoda podpornih vektorjev skrajno občutljiva na normalizacijo, ki pa je bila, kot že omenjeno, preprosta. Pri nevronskih mrežah to ne drži do take mere.

Uporabljena je bila uporabljena nevronska mreža, ki ima enosmerne povezave od vhoda do izhoda (angl. feedforward) in je prikazana na sliki 5.3. Take mreže se najpogosteje uporabljajo za napovedovanje, razpoznavanje vzorcev in prilagajanje nelinearnih krivulj [23]. Za učenje nevronske mreže na podlagi učne množice je bil uporabljen ukaz `train`. Klasifikacija podatkov testne množice se je izvajala preko ukaza `sim`. Matlab omogoča procesiranje na grafični procesni enoti, vendar merjanja niso pokazala večjih razlik – razlog za to je lahko nepodpora s strani gonilnikov. Vsekakor vredno nadaljne raziskave, ki pa tekom izdelave diplomskega dela ni bila opravljena.

Pri gradnji nevronske mreže Matlab omogoča določitev števila "nevronov", vendar za vrednosti med 1 in 10 na danih podatkih ni bilo opaziti večjih sprememb (odstopanja manjša od 3%).

Slaba stran nevronskih mrež je, da ob vsaki iteraciji dajo nekoliko drugačne rezultate – mejne primere tako včasih uvrstijo med kliente, včasih med vsiljivce. V poglavju 5.4.3 so rezultati tako podani z določenim odstopanjem.



Slika 5.3: Prikaz nevronske mreže v Matlabu

5.4 Rezultati

Pri primerjavi uspešnosti metod razvrščanja smo s omejili predvsem na mero EER. Kot že omenjeno v poglavju 4.4.2 nižja vrednost EER pomeni boljše rezultate. Enako velja za vrednosti FAR in VAR.

5.4.1 Metoda podpornih vektorjev

V tabeli 5.1 so prikazane FAR, VAR in EER vrednosti za metodo podpornih vektorjev.

	FAR+FRR	FAR	FRR	EER
d_1	0,03793	0,02966	0,00827	0,02139
d_2	0,00331	0,00316	0,00015	0,00301
fuzija	0,00195	0,00191	0,00004	0,00187

Tabela 5.1: SVM rezultati fuzije

5.4.2 Klasifikacijsko drevo

V tabeli 5.2 so prikazane FAR, VAR in EER vrednosti za klasifikacijsko drevo.

	FAR+FRR	FAR	FRR	EER
d_1	0,00389	0,00069	0,00320	-0,00251
d_2	0,00063	0,00034	0,00028	0,00005
fuzija	0,00038	0,00024	0,00014	0,00010

Tabela 5.2: Rezultati fuzije s klasifikacijskih drevesom

5.4.3 Nevronske mreže

V tabeli 5.1 so prikazane FAR, VAR in EER vrednosti za metodo podpornih vektorjev. Nevronske mreže dajejo najboljše rezultate med metodami razvrščanja. Rezultati imajo zabeležena odstopanja zaradi lastnosti nevronskih mrež – pri vsakem izvajanju se rezultati razlikujejo.

	FA+FRR \pm 0,002%	FAR \pm 0,002%	FRR \pm 0,002%	EER \pm 0,002%
d_1	0,00461	0,00095	0,00365	-0,00270
d_2	0,00040	0,00014	0,00026	-0,00013
fuzija	0,00021	0,00007	0,00014	-0,00007

Tabela 5.3: Rezultati fuzije z nevronske mreže

Poglavje 6

Zaključek

Rezultati so pokazali, da fuzija doprinese k skupni uspešnosti sistema. Pri fuziji na podlagi fuzijskih pravil se je za najuspešnejšo izkazala fuzija na podlagi utežene vsote z utežjo $w = 0,7$. Površina pod krivuljo se je iz 0,99124 pri prstnih odtisih in 0,97552 pri obrazih povečala na 0,99682 (0,6% oz. 2,2% izboljšanje). Enakovredna stopnja napake ERR se je iz 0,0161 in 0,0717 zmanjšala na 0,0068 (57,7% oz. 90,5% izboljšanje). Vrednost FRR pri enakovredni stopnji napake ERR se je iz 0,0156 in 0,0725 zmanjšala na 0,0069 (55,8% oz. 90,5% izboljšanje). Stopnja verifikacije pri enakovredni stopnji napake EER se je povečala iz 0,9844 pri prstnih odtisih in 0,9275 pri obrazih na 0,9931 pri fuziji (0,8% oz. 7,1% izboljšanje).

Pri fuziji na podlagi metod razvrščanja so bile najuspešnejše nevronske mreže. Stopnja napačno klasificiranih je iz 0,00461 pri obrazih in 0,00040 pri prstnih odtisih padla na 0,00021 (95,5% oz. 48,8% izboljšanje). Enakovredna stopnja napake ERR se je absolutno zmanjšala iz -0,00270 in -0,00013 na -0,00007 pri fuziji (97,7% oz. 50% izboljšanje).


Pri metodi podpornih vektorjev se je stopnja napačno klasificiranih znižala iz 0,03793 pri obrazih in 0,00331 pri odtisih na 0,00195 pri fuziji (94,8% oz. 40,9% izboljšanje). Enakovredna stopnja napake ERR se je absolutno zmanjšala iz 0,02139 pri obrazih in 0,00301 pri odtisih na 0,00187 pri fuziji (91,2% oz. 37,7% izboljšanje).

Pri klasifikacijskem drevesu se je število napačno klasificiranih znižalo iz 0,00389 pri obrazih in 0,00063 pri odtisih na 0,00038 pri fuziji (90,1% oz. 38,6% izboljšanje). Enakovredna stopnja napake ERR se je absolutno gledano spremenila iz -0,00251 pri obrazih in 0,00005 pri odtisih na 0,00010 pri fuziji (96% izboljšanje oz. 82,8% poslabšanje).


Pri absolutni primerjavi enakovrednih stopenj napake EER se fuzija na podlagi metod razvrščanja izkaže za bolj uspešno od fuzije na podlagi fuzijskih pravil, med njimi je najbolj uspešna fuzija s pomočjo nevronske mreže. Enakovredna stopnja napake EER fuzije na podlagi utežene vsote z $w = 0,7$ (najuspešnejša med fuzijami na podlagi fuzijskih pravil) znaša 0,0068, enakovredna stopnja napake EER fuzije s pomočjo nevronske mreže pa 0,00007. Izboljšanje je pri nevronske mreže tako 98,9%. Vendar pa so razlogi za to v tem, da nevronske mreže že osnovi bolje klasificirajo - izboljšanje d1 in d2 je tako 99,6% oz. 99,2%.

Primerjava metod fuzij zgolj glede na pridobitev fuzije (izničimo začetno klasifikacijsko izboljšanje) poda dve najuspešnejši metodi. Nevronske mreže in fuzija na podlagi utežene vsote pri $w = 0,7$. Razlika med njima namreč ni dovolj velika, da bi se bilo možno odločiti izključno za eno. Nevronske mreže so po primerjavi prstnih odtisov s fuzijo sicer boljše za 40 odstotnih točk, vendar hkrati pri primerjavi obrazov in fuzije slabše za 40,5 odstotnih točk.

Metoda podpornih vektorjev se, glede na pridobitev fuzije, v delu ni izkazala kot dobra navkljub literaturi. Vzroke za slabo delovanje gre iskati v izbiri preveč preproste normalizacijske tehnike. Na grafu 6.1 so prikazane vse obravnavane vrednosti enakovredne stopnje napake EER za fuzijo na podlagi fuzijskih pravil, na grafu 6.1 za fuzijo na podlagi metod razvrščanja.



Slika 6.1: Primerjava enakovrednih stopenj napake EER za fuzijo na podlagi fuzijskih pravil



Slika 6.2: Primerjava enakovrednih stopenj napake EER za fuzijo na podlagi metod razvrščanja

Zaključimo lahko, da bi kljub jasnemu prikazu uspešnosti fuzije uporaba zahtevnejših normalizacijskih tehnik in uporaba dodatnih fuzijskih pravil ter metod razvrščanja verjetno še dodatno doprinesli k učinkovitosti sistema in k bolj jasnim rezultatom. Veliko odprtega pušča jo nevronske mreže in metoda podpornih vektorjev – pri obeh metodah je možnih še veliko optimizacij. Možnosti za nadaljne raziskave so smiselne tudi v smeri fuzije na nivoju odločanja, čeprav v literaturi običajno ne prinaša boljših rezultatov od fuzije na nivoju mer podobnosti.

Literatura

- [1] Patrick Flynn; Arun A. Ross (Eds.) Anil K. Jain, *Handbook of Biometrics*, Springer Science Business Media, LLC, New York, USA, 2008.
- [2] Arun Ross Anil K. Jain and Sharath Pankanti, “Biometrics: A tool for information security”, *IEEE Transactions on Inforamtion Forensics and Security*, vol. 1, no. 2, junij 2006.
- [3] Hailong Jia and Kun Cao, “The research on the preprocessing algorithm for fingerprint image”, in *Electrical Electronics Engineering (EEESYM), 2012 IEEE Symposium on*, 2012, pp. 163–166.
- [4] Jiya Tian and Yanqin Peng, “Research of the matlab application in the fingerprint identification system”, in *Image Analysis and Signal Processing (IASP), 2012 International Conference on*, 2012, pp. 1–5.
- [5] Soweon Yoon, Jianjiang Feng, and A.K. Jain, “Altered fingerprints: Analysis and detection”, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 34, no. 3, pp. 451–464, 2012.
- [6] A.K. Jain S. Prabhakar D. Maltoni, D. Maio, *Handbook of Fingerprint Recognition*, Springer Science+Business Media, LLC, New York, USA, 2005.
- [7] Bule Jernej Žganec Gros Jerneja Štruc Vitomir Peer, Peter, “Building cloud-based biometric services”, *Informatika (Ljublj.)*, vol. 37, no. 1, pp. 115–122, 2013.

-
- [8] Paul Viola and Michael J. Jones, “Robust real-time face detection”, *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137–154, 2004.
- [9] J. Žganec-Gros V. Štruc and N. Pavešić, “Advanced correlation filters for facial landmark localization”, *Zbornik konference ERK*, vol. B, pp. 153–156, 2012.
- [10] P. Peer V. Štruc and B. Bule, “Specifikacija zahtev storitev za biometrično identifikacijo oz. avtentikacijo”, *Izroček D3.5.1 - KC CLASS*, junij 2013.
- [11] Anil Jain, Karthik Nandakumar, and Arun Ross, “Score normalization in multimodal biometric systems”, *Pattern Recognition*, vol. 38, no. 12, pp. 2270 – 2285, 2005.
- [12] S. Chaudhary and R. Nath, “A multimodal biometric recognition system based on fusion of palmprint, fingerprint and face”, in *Advances in Recent Technologies in Communication and Computing, 2009. ARTCom '09. International Conference on*, 2009, pp. 596–600.
- [13] M.S. Fahmy, A.F. Atyia, and R.S. Elfouly, “Biometric fusion using enhanced svm classification”, in *Intelligent Information Hiding and Multimedia Signal Processing, 2008. IIHMSP '08 International Conference on*, 2008, pp. 1043–1048.
- [14] A. Ben Khalifa and N.E. Ben Amara, “Bimodal biometric verification with different fusion levels”, in *Systems, Signals and Devices, 2009. SSD '09. 6th International Multi-Conference on*, 2009, pp. 1–6.
- [15] Afzel Noore, Richa Singh, and Mayank Vatsa, “Robust memory-efficient data level information fusion of multi-modal biometric images”, *Information Fusion*, vol. 8, no. 4, pp. 337 – 346, 2007.

-
- [16] Arun Ross and Rohin Govindarajan, “Feature level fusion using hand and face biometrics”, *SPIE Conference on Biometric Technology for Human Identification*, vol. 5779, no. 2, pp. 196–204, 2005.
- [17] N. Poh, T. Bourlai, J. Kittler, L. Allano, F. Alonso-Fernandez, O. Ambekar, J. Baker, B. Dorizzi, O. Fatukasi, J. Fierrez, H. Ganster, J. Ortega-Garcia, D. Maurer, A.A. Salah, T. Scheidat, and C. Vielhauer, “Benchmarking quality-dependent and cost-sensitive score-level multimodal biometric fusion algorithms”, *Information Forensics and Security, IEEE Transactions on*, vol. 4, no. 4, pp. 849–866, 2009.
- [18] R. Raghavendra, A. Rao, and G. Hemantha Kumar, “A novel approach for multimodal biometric score fusion using gaussian mixture model and monte carlo method”, in *Advances in Recent Technologies in Communication and Computing, 2009. ARTCom '09. International Conference on*, 2009, pp. 90–92.
- [19] Vitomir Štruc and Nikola Pavešić, “The complete gabor-fisher classifier for robust face recognition”, *EURASIP Advances in Signal Processing*, vol. 2010, pp. 26, 2010.
- [20] Vitomir Štruc and Nikola Pavešić, “Gabor-based kernel partial-least-squares discrimination features for face recognition”, *Informatika (Vilnius)*, vol. 20, no. 1, pp. 115–138, 2009.
- [21] Yan Tong, Frederick W. Wheeler, and Xiaoming Liu, “Improving biometric identification through quality-based face and fingerprint biometric fusion”, in *Computer Vision and Pattern Recognition Workshops (CV-PRW), 2010 IEEE Computer Society Conference on*, 2010, pp. 53–60.
- [22] (2013) Support vector machine, Dostopno na: http://en.wikipedia.org/wiki/Support_vector_machine.

- [23] (2013) Network Architectures - Neural Network Toolbox - MATLAB, Dostopno na: <http://www.mathworks.com/products/neural-network/description3.html>.

Slike

2.1	Diagram arhitekture sistema	4
2.2	Shema sistema za verifikacijo na podlagi prstnega odtisa	7
2.3	Bločna shema uporabljenega sistema	11
2.4	Ilustracija rezultata postopka detekcije	12
2.5	Ilustracija učinka normiranja: vhodne slike (levo), po detekciji in geometrijskem normiranju (sredina), po svetlobnem normiranju (desno)	13
3.1	ROC krivulji ločenih enomodalnih verifikacijskih sistemov [15]	20
3.2	ROC krivulje ločenih enomodalnih verifikacijskih sistemov v primerjavi z dvomodalnimi verifikacijskimi sistemi [15]	21
3.3	Bločni diagram večmodalnega biometričnega prepoznavnega sistema, ki temelji na fuziji dlani, prstnega odtisa in značilnk obraza [12]	22
3.4	ROC krivulja fuzije v primerjavi s posameznimi ROC krivuljami obraza, prstnega odtisa dlani [12]	23
3.5	Primerjava ROC krivulj fuzije z metodo Monte Carlo v primerjavi z drugimi [18]	25
4.1	ROC krivulji mer podobnosti d_1 in d_2 pred postopkom fuzije	29
4.2	ROC krivulj fuzije na podlagi vsote za $0 \leq w \leq 0,4$	30
4.3	ROC krivulj fuzije na podlagi vsote za $0,5 \leq w \leq 1$	31
4.4	ROC krivulj fuzije na podlagi produkta za $0 \leq w \leq 0,4$	32
4.5	ROC krivulj fuzije na podlagi produkta za $0,5 \leq w \leq 1$	33

4.6	ROC krivulj fuzije na podlagi min-max pravila	34
5.1	Metoda podpornih vektorjev na podlagi hiperravnine z največjo razliko – gre za linearni klasifikator [22]	44
5.2	Prikazano poenostavljeno klasifikacijsko drevo, ki klasificira v tri razrede	45
5.3	Prikaz nevronske mreže v Matlabu	46
6.1	Primerjava enakovrednih stopenj napake EER za fuzijo na podlagi fuzijskih pravil	51
6.2	Primerjava enakovrednih stopenj napake EER za fuzijo na podlagi metod razvrščanja	51

Tabele

4.1	AUC vrednosti d_1 in d_2	34
4.2	AUC vrednosti fuzije na podlagi utežene vsote d_1 in d_2	35
4.3	AUC vrednosti fuzije na podlagi uteženega produkta d_1 in d_2	36
4.4	AUC vrednosti fuzije na podlagi min-max pravila za d_1 in d_2	36
4.5	EER vrednosti d_1 in d_2	37
4.6	Enakovredna stopnja napake EER fuzije na podlagi utežene vsote d_1 in d_2	37
4.7	Enakovredna stopnja napake EER vrednosti fuzije na podlagi uteženega produkta d_1 in d_2	38
4.8	Enakovredna stopnja napake EER vrednosti fuzije na podlagi min-max pravila za d_1 in d_2	38
4.9	VER@0,1%FAR vrednosti d_1 in d_2	39
4.10	VER@0,1%FAR vrednosti fuzije na podlagi utežene vsote d_1 in d_2	40
4.11	VER@0,1%FAR vrednosti fuzije na podlagi uteženega produkta d_1 in d_2	41
4.12	VER@0,1%FAR vrednosti fuzije na podlagi min-max pravila za d_1 in d_2	41
5.1	SVM rezultati fuzije	47
5.2	Rezultati fuzije s klasifikacijskih drevesom	47
5.3	Rezultati fuzije z nevronske mrežo	48

Kratice

AUC Površina pod krivuljo – v diplomskem delu vedno površina pod ROC krivuljo (angl. Area under curve)

EER enakovredna stopnja napake (angl. Equal Error Rate) podaja točko kjer sta FAR – stopnja napačno sprejetih (angl. False Acceptance Rate) in FRR – stopnja napačno zavrženih (angl. False Rejection Rate) enaka

FAR stopnja napačno sprejetih (angl. False Acceptance Rate)

FRR stopnja napačno zavrženih (angl. False Rejection Rate)

ROC Krivulja, ki prikazuje uspešnost binarnega klasifikatorja (angl. Receiver operating characteristic)

SVM Metoda podpornih vektorjev (angl. Support Vector Machines)

TR prag (angl. Treshold)

VER verifikacija

VER at 0,1% FAR Verifikacija pri 0,1% napačno sprejetih