

Vpliv kakovosti vhodnih slik na zanesljivost samodejnega razpoznavanja obrazov

Vitomir Štruc, Nikola Pavešić

Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška 25, 1001 Ljubljana, Slovenija
E-pošta: vitomir.struc@fe.uni-lj.si, nikola.pavesic@fe.uni-lj.si

Povzetek. Zanesljivost samodejnega razpoznavanja obrazov je odvisna od številnih dejavnikov, med katerimi so najpomembnejši natančnost določitve slikovnega območja obraza in njegova odpornost na slabšo kakovost slik, izbira ustreznega postopka izpeljave obraznih značilik ter uporaba primerne algoritma za izračun podobnosti in sprejetje odločitve o identiteti osebe. V članku predstavljamo rezultate vrednotenja napak, ki jih v biometrični sistem vnašajo različne degradacije vhodnih slik. Njihov vpliv smo proučili za tri na področju razpoznavanja obrazov pogosteje uporabljene postopke izpeljave značilik (analizo glavnih komponent – PCA, analizo linearne diskriminante – LDA ter analizo neodvisnih komponent – ICA), pri čemer smo za določitev zanesljivosti razpoznavanja (verifikacije) uporabili bazo XM2VTS; za ovrednotenje napak, ki jih v biometrični sistem vnašajo spremembe v kakovosti slik, pa njene degradirane različice.

Ključne besede: razpoznavanje obrazov, analiza glavnih komponent, analiza linearne diskriminante, analiza neodvisnih komponent, zanesljivost razpoznavanja, kakovost vhodnih slik

Impact of image degradations on the face recognition accuracy

Extended abstract. The accuracy of automatic face recognition systems depends on various factors among which robustness and accuracy of the face localization procedure, choice of an appropriate face-feature extraction procedure, as well as use of a suitable matching algorithm are the most important.

Current systems perform relatively well whenever test images to be recognized are captured under conditions similar to those of the training images. However, they are not robust enough if there is a difference between test and training images. Changes in image characteristics such as noise, colour depth, background and compression all cause a drop in performance of even the best systems of today.

At this point the main question is which image characteristics are the most important in terms of face recognition performance and how they affect the recognition accuracy. This paper addresses these issues and presents performance evaluation (Table 2.) of three popular subspace methods (PCA, LDA and ICA) using ten degraded versions of the XM2VTS face image database [10]. The presented experimental results show the effects of different changes in image characteristics on four score level fusion rules, namely, the maximum, minimum, sum and product rule. All of the feature

extraction procedures as well as the fusion strategies are rather insensitive to the presence of noise, JPEG compression, colour depth reduction, and so forth, while on the other hand they all exhibit great sensitivity to degradations such as face occlusion and packet loss simulation.

Keywords: face recognition, principal component analysis, linear discriminant analysis, independent component analysis, recognition accuracy

1. Uvod

Razvoj sodobnih informacijskih tehnologij, interneta in zmeraj zmogljivejših računalnikov so le nekateri izmed dejavnikov, ki ljudem po vsem svetu omogočajo čedalje lažji dostop do najrazličnejših podatkovnih baz, uslug in storitev. Omogočajo nam opravljanje denarnih transakcij, dostop do osebnih podatkov, naročanje različnih potrdil ipd. Ker pa omenjena opravila nemalokrat zahtevajo potrditev identitete osebe, ki ta opravila izvaja, je skupaj z njimi nastala tudi potreba po hitrih, učinkovitih in do uporabnikov prijaznih mehanizmov za avtentikacijo oseb. Istovetenje oseb z razpoznavanjem obrazov ponuja univerzalen in nevsiljiv način potrjevanja identitete, vendar trenutno še ne dovolj zanesljivega, saj segajo tipične vrednosti celotne

napake (angl. Total Error Rate – TER) razpoznavanja obstoječih sistemov od dveh pa vse do 25 odstotkov.

Zanesljivost samodejnega razpoznavanja obrazov je odvisna od številnih dejavnikov, med katerimi so najpomembnejši natančnost lokalizacije obraza in njena odpornost na slabšo kakovost slik, izbira ustreznega postopka izpeljave obraznih značilnk ter uporaba primerne algoritma za izračun podobnosti in sprejetje odločitve o identiteti osebe na sliki.

Ker temeljijo številne metode razpoznavanja obrazov na vizualnem učenju, je zanesljivost razpoznavanja v veliki meri odvisna tudi od kakovosti vhodnih (testnih) slik. Kadar se le-ta bistveno razlikuje od kakovosti slik, uporabljenih za učenje sistema, se zanesljivost razpoznavanja ustrezno zmanjša.

Na tem mestu se postavlja vprašanje, katere spremembe v kakovosti slik najbolj vplivajo na zanesljivost razpoznavanja in kolikšen je njihov vpliv. Različni avtorji so se že v preteklosti posvečali tem problemom. Tako so Huan, Chiang in Lin [1] proučili vpliv šuma na zanesljivost istovetenja obrazov z značilnkami, dobljenimi z analizo glavnih (PCA) ter analizo neodvisnih komponent (ICA), v [2] sta Kukula in Elliott ovrednotila zanesljivost komercialnega sistema za razpoznavanje obrazov za slike, ki so nastale pod različnimi svetlobnimi pogoji, učinek delnega prekrivanja obrazov na vrsto algoritmov razpoznavanja pa je bil predmet raziskovalnega dela v [3].

V nadaljevanju bomo predstavili biometrični sistem za samodejno razpoznavanje obrazov, s katerim smo ovrednotili vplive različnih degradacij vhodnih slik na zanesljivost razpoznavanja. V 3. poglavju bomo opisali slikovne baze in protokole, ki smo jih uporabljali pri preizkusih, vpliv spremenjene kakovosti testnih slik na delovanje posameznih delov sistema pa bomo na osnovi eksperimentalnih rezultatov ovrednotili v 4. poglavju.

2. Opis sistema

Za izvajanje poskusov smo zgradili sistem za samodejno razpoznavanje obrazov, ki ga prikazuje slika 1. Zgrajen je iz naslednjih medsebojno povezanih funkcijskih enot:

- enote za določitev in normalizacijo slikovnega območja obraza,
- enote za izpeljavo obraznih značilnk, ki temelji na postopkih PCA, LDA in ICA (arhitektura 1 in 2),
- enote za izračun podobnosti med značilnkami vhodne slike in modeli uporabnikov (shranjenimi v bazi sistema) ter
- enote za združevanje izračunanih mer podobnosti in sprejetje odločitve o identiteti uporabnika.

2.1 Lokalizacija obraza

Postopek določitve slikovnega območja obraza je v sistemu na sliki 1 izveden takole:

- z detektorjem točk kožne barve se iz vhodne slike izločijo objekti, ki ne ustrezajo barvi kože,
- očiščeni sliki se odvzame barvna informacija in izravna histogram,
- s pomočjo Sobelovih gradientnih operatorjev se pridelata sliki vodoravnih in navpičnih robov,
- prek integralnih projekcij dobljenih slik se izračuna kot nagiba obraza, slika pa se poravna,
- s eliptično Houghovo transformacijo se omeji območje iskanja obraza,
- lega obraza se določi na mestu, kjer je Hausdorffova razdalja med binarno sliko robnih elementov in modelom obraza najmanjša,
- izrez obraza (8-bitna sivinska slika) se normalizira na standardno velikost 87x100 slikovnih elementov,
- po velikosti normirana slika se fotometrično normalizira z odstranitvijo povprečne vrednosti svetilnosti izreza in skaliranjem slikovnih elementov z njihovo standardno deviacijo.

Opisani postopek (podrobneje je predstavljen v [4]) izvedemo za vse učne slike sistema, ki so nato primerne za izpeljavo značilnk s postopki, opisanimi v naslednjih razdelkih.

2.2 Analiza glavnih komponent – PCA

Analizo glavnih komponent sta za razpoznavanje obrazov kot prva predlagala Turk in Pentland [5]. Postopek temelji na predstavitvi vhodne slike obraza \mathbf{x} z linearno kombinacijo ortonormalnih vektorjev \mathbf{e}_i , ki jih določimo na podlagi učnih slik biometričnega sistema.

Če vsebuje baza sistema N učnih slik, lahko poljubno sliko \mathbf{x} zapišemo kot:

$$\mathbf{x} = c_1\mathbf{e}_1 + c_2\mathbf{e}_2 + \dots + c_N\mathbf{e}_N = \sum_{i=1}^N c_i\mathbf{e}_i . \quad (1)$$

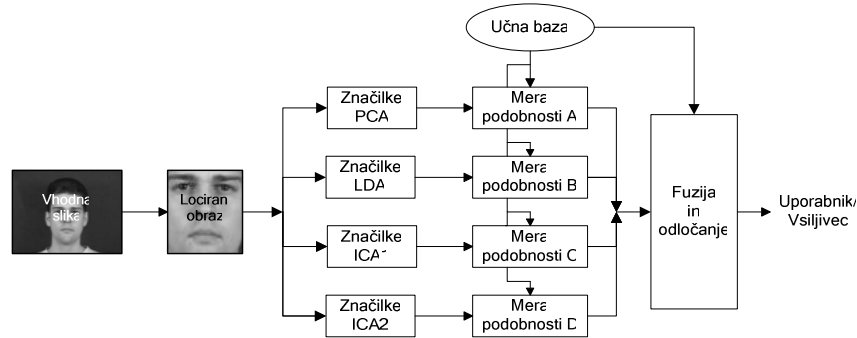
Ortonormirane vektorje \mathbf{e}_i pri tem določimo s pomočjo transformacije Karhunen in Loèveja, ki je definirana kot postopek minimizacije srednje kvadratne napake (SKN) približnega zapisa vzorca. Izkaže se, da dosežemo najmanjšo SKN , če kot bazne vektorje \mathbf{e}_i izberemo lastne vektorje kovariančne matrike \mathbf{K} učnih slik biometričnega sistema. Rešiti moramo torej sistem:

$$(\mathbf{K} - \lambda_i\mathbf{I}) \cdot \mathbf{e}_i = 0 . \quad (2)$$

Transformacijsko matriko postopka PCA nato sestavimo iz r lastnih vektorjev, ki ustrezajo r največjim lastnim vrednostim. Tako zajamemo v transformacijo (4), kar največ informacije o učnih vzorcih sistema:

$$\mathbf{W}_{PCA} = [\mathbf{e}_1^T, \mathbf{e}_2^T, \dots, \mathbf{e}_r^T] , \quad (3)$$

kjer vektorji \mathbf{e}_i ($i = 1, 2, \dots, r$) ustrezajo členom zaporedja $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r$ [5].



Slika 1: Bločni diagram eksperimentalnega sistema za samodejno razpoznavanje obrazov
Figure 1. Block diagram of the experimental setup for automatic face recognition

S tako določeno transformacijsko matriko \mathbf{W}_{PCA} lahko poljubno sliko \mathbf{x} s pomočjo enačbe (4) preslikamo v prostor značilk \mathbf{c} :

$$\mathbf{c} = \mathbf{W}_{PCA}^T (\mathbf{x} - \mathbf{m}). \quad (4)$$

V zgornji enačbi je \mathbf{m} srednji vektor (povprečni obraz) učne množice slik sistema.

2.3 Analiza linearne diskriminante – LDA

Drugače kot pri postopku PCA, kjer se vektorji \mathbf{e}_i določijo na podlagi variance učnih slik, se pri analizi linearne diskriminante (LDA) osi razvrstitve (1) izračunajo tako, da maksimizirajo naslednjo kriterijsko funkcijo:

$$J(\mathbf{W}) = \frac{|\mathbf{W}^T \mathbf{S}_B \mathbf{W}|}{|\mathbf{W}^T \mathbf{S}_W \mathbf{W}|}, \quad (5)$$

kjer \mathbf{S}_B pomeni matriko med razredne razpršenosti (angl. between-class scatter matrix):

$$\mathbf{S}_B = \sum_{i=1}^C |\mathcal{X}_i| (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T \quad (6)$$

in \mathbf{S}_W matriko znotraj razredne razpršenosti (angl. within-class scatter matrix):

$$\mathbf{S}_W = \sum_{i=1}^C \sum_{\mathbf{x} \in \mathcal{X}_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T. \quad (7)$$

V enačbah (6) in (7) pomeni \mathbf{m}_i povprečni vektor i -tega razreda, \mathbf{m} povprečni vektor vseh učnih slik, C število razredov, $|\mathcal{X}_i|$ število učnih slik razreda \mathcal{X}_i in \mathbf{x} sliko iz učne množice slik.

Iščemo torej transformacijsko matriko \mathbf{W} , s katero zmanjšamo razdalje med projekcijami slik istih razredov (oseb) in hkrati povečamo razdalje med projekcijami slik različnih razredov.

Pokažemo lahko, da ustreza transformacijska matrika \mathbf{W}_{LDA} postopka LDA množici lastnih vektorjev izraza:

$$\mathbf{S}_W^{-1} \mathbf{S}_B \mathbf{e}_i = \lambda_i \mathbf{e}_i. \quad (8)$$

Kadar je število slik, uporabljenih za izračun matrike znotraj razredne razpršenosti, manjše od njihove dimenzije, je matrika \mathbf{S}_W singularna. V tem primeru uporabimo različico postopka LDA [6], pri katerem matriki \mathbf{S}_B in \mathbf{S}_W najprej preslikamo v prostor glavnih komponent, sistem (8) pa nato rešimo v novem, manj razsežnem prostoru. Transformacijsko matriko tako prilagojenega postopka na koncu določimo v skladu z naslednjim izrazom:

$$\mathbf{W}_{PCA+LDA}^T = \mathbf{W}_{LDA}^T \mathbf{W}_{PCA}^T. \quad (9)$$

Značilke poljubne slike \mathbf{x} tudi tokrat izračunamo s pomočjo enačbe (4), v kateri matriko \mathbf{W}_{PCA} nadomestimo z matriko $\mathbf{W}_{PCA+LDA}$.

2.4 Analiza neodvisnih komponent – ICA

Analizo neodvisnih komponent lahko obravnavamo kot posplošitev postopka PCA, pri čemer upoštevamo poleg statističnih momentov drugega reda (PCA) še višje statistične momente, ki naj bi vsebovali več informacije o ločljivosti razredov. Tekom časa sta se razvila dva pristopa k izvedbi postopka: ICA1 ter ICA2 [7]. V prvem primeru iščemo neodvisne komponente v obliki slik, v drugem pa v obliki neodvisnih koeficientov c_i linearne kombinacije (1).

S postopkom ICA želimo poiskati linearno transformacijo, s katero lahko izrazimo množico N naključnih spremenljivk \mathbf{x}_i kot linearno kombinacijo N statistično neodvisnih izvornih spremenljivk \mathbf{s}_i :

$$\mathbf{x}_i = a_{i1} \mathbf{s}_1 + a_{i2} \mathbf{s}_2 + \dots + a_{iN} \mathbf{s}_N \quad (10)$$

oziroma v matrični obliki:

$$\mathbf{X} = \mathbf{A} \mathbf{S}. \quad (11)$$

V našem sistemu smo za določitev neznanih parametrov modela (11) uporabili algoritem FastICA.

ICA – arhitektura 1

Postopek določitve obraznih značilk z ICA1 lahko strnemo v naslednje korake:

- na podlagi učnih slik se določi transformacijska matrika WPCA (3),
- izračunajo se značilke cPCA postopka PCA (4),
- na matriki WPCA se izvede algoritem FastICA,
- iz značilke cPCA se izračunajo značilke cICA1:

$$\mathbf{c}_{ICA1} = \mathbf{c}_{PCA} \cdot \mathbf{A}. \quad (12)$$

Za postopek ICA1 je značilno, da išče izvorne spremenljivke \mathbf{S} v obliki neodvisnih slik obrazov. Značilke, ki jih te slike opisujejo, so lokalne narave.

ICA – arhitektura 2

Potek izračuna značilke po drugi arhitekturi postopka ICA je precej podoben poteku določitve značilke, predstavljenemu v prejšnjem razdelku:

- izračuna se transformacijska matrika WPCA (3) in matrika značilke učnih slik sistema cPCA (4),
- na matriki cPCA se izvede algoritem FastICA,
- koeficienti razvrstitve ICA2 se določijo kot:

$$\mathbf{c}_{ICA2} = \mathbf{A}^{-1} \cdot \mathbf{c}_{PCA}^T. \quad (13)$$

Kot lahko razberemo iz enačbe (13), moramo za določitev značilke poljubne slike \mathbf{x} najprej izračunati koeficiente razvrstitve PCA, ki jih nato pomnožimo z inverzom matrike \mathbf{A} .

2.5 Izračun podobnosti in odločanje

Podobnost med vektorjem značilke vhodne slike \mathbf{c} in modelom (srednjim vektorjem značilke $\boldsymbol{\mu}_i$) poljubnega uporabnika merimo z normiranim korelacijskim koeficientom [8]:

$$s_N(\mathbf{c}, \boldsymbol{\mu}_i) = \frac{\|\mathbf{c}^T \boldsymbol{\mu}_i\|}{\sqrt{\mathbf{c}^T \mathbf{c} \boldsymbol{\mu}_i^T \boldsymbol{\mu}_i}}. \quad (14)$$

Če je vrednost normiranega korelacijskega koeficienta (14) večja od praga, potem osebi na vhodni sliki potrdimo identiteto, sicer pa ne.

Odločitev o identiteti osebe na vhodni sliki lahko sprejmemo tudi na podlagi podobnosti, ki jih dobimo z združevanjem mer posameznih predstavitev ($s_{N_{PCA}}$, $s_{N_{lda}}$, $s_{N_{ica1}}$, $s_{N_{ica2}}$). V sistemu smo za namene preizkušanja robustnosti razpoznavanja realizirali štiri postopke fuzije na ravni podobnosti, in sicer: fuzijo s pravilom vsote, s pravilom produkta, s pravilom najmanjše vrednosti ter fuzijo s pravilom največje vrednosti [8].

3. Uporabljene baze in protokoli

Učinkovitost delovanja posameznih enot predstavljenega sistema smo preizkusili s pomočjo slikovnega dela baze XM2VTS, ki smo jo v skladu s prvo konfiguracijo lausanskega protokola razdelili v nize učnih, testnih ter evalucijskih slik. Z učnim nizom smo zgradili modele uporabnikov, z evalucijskim

nizom smo določili pragove, potrebne za odločitev o identiteti osebe na sliki, testni niz pa smo uporabili za določitev zanesljivosti razpoznavanja.

Vpliv kakovosti testnih slik na delovanje sistema smo ovrednotili s pomočjo desetih degradiranih različic baze XM2VTS, ki so nastale z uporabo naslednjih degradacijskih postopkov:

- D1 - simulacijo izgubljanja podatkovnih paketov,
- D2 - dodajanjem močnega belega šuma,
- D3 - dodajanjem šibkega belega šuma,
- D4 - dodajanjem kompleksnega ozadja,
- D5 - JPEG kompresijo,
- D6 - zmanjšanjem barvne globine,
- D7 - glajenjem z 2D Gausovim filtrom za $\sigma = 2$,
- D8 - glajenjem z 2D Gausovim filtrom za $\sigma = 4$,
- D9 - geometrijskimi transformacijami ter
- D10 - delnim prekrivanjem obraza.

Podrobnejši opis vseh uporabljenih baz in protokolov je na voljo v [9, 10].

4. Opis poskusov in rezultati

4.1 Prvi poskus

Ker je zanesljivost razpoznavanja v veliki meri odvisna od pravilne lokalizacije obraza na sliki, smo pri prvem poskusu preverili uspešnost uporabljenega postopka določevanja slikovnega območja obraza na originalni in na degradiranih bazah. Pri tem smo za testiranje uporabili tiste slike iz baze, ki jih za preizkušanje določa prva konfiguracija lausanskega protokola

Na originalni bazi smo uspešno določili lego obraza na 97,8 odstotka preizkušenih slikah, kar je primerljivo tudi z rezultati drugih raziskovalcev. Na istih slikah so Jesorsky et. al [11] s podobno metodo dosegli 98,4 odstotno uspešnost lokalizacije, Pozne pa s postopkom predstavljenim v [12] celo 99,9 odstotno.

Degradacija	D1	D2	D3	D4	D5
Uspešnost	80,7	95,3	96,2	89,9	96,1
Degradacija	D6	D7	D8	D9	D10
Uspešnost	95,8	96,0	94,6	81,4	89,6

Tabela 1: Rezultati preizkušanja lokalizacije
Table 1. Localisation procedure performance

Iz tabele 1, v kateri so predstavljeni rezultati (v %) lokalizacije slikovnega območja obraza za degradirane baze, lahko razberemo, da je uporabljeni postopek lokalizacije na podlagi Hausdorffove razdalje razmeroma neobčutljiv na spremembe v kakovosti slik, kot so šum, glajenje, kompresija, zmanjšanje barvne globine ipd. Občutljivost pa je na degradacije, ki vnašajo v slike robnih elementov dodatne, nezaželene robove (npr. izguba paketov informacije, delno prekrivanje obraza, prisotnost kompleksnega ozadja itd.).

4.2 Drugi poskus

V drugem poskusu smo preverili zanesljivost razpoznavanja z značilkami postopkov PCA, LDA, ICA1 in ICA2 ter vpliv kakovosti slik na postopke fuzije (razdelek 2.5). Pri tem smo uporabili pragove, ki smo jih določili pri učenju sistema z originalno bazo, s čimer smo simulirali razmere, ki jih srečamo tudi v praksi, ko se testne slike zaradi spremenjenih razmer pri njihovem zajemu razlikujejo od slik, uporabljenih za učenje sistema.

Ker smo želeli proučiti vpliv kakovosti testnih slik na zanesljivost razpoznavanja obrazov z različnimi metodami izpeljave značilk, smo v tem delu vse nepravilno lokalizirane obraze nadomestili z obrazy, katerih lego smo določili ročno. Za vsako od enajstih baz smo izračunali vrednost napake zavrnitve prave osebe (FRR), vrednost napake potrditve lažne osebe (FAR) in vrednost polovične napake verifikacije (HTER), ki jo določimo kot srednjo vrednost napak FRR in FAR.

V tabeli 2 so podane vrednosti napake HTER za vse preizkušene postopke izpeljave značilk. Podrobnejša predstavitev rezultatov (napak FRR in FAR ter vrednosti HTER za pravila fuzije) pa je dosegljiva v [4].

Degradacije	HTER (%)			
	PCA	LDA	ICA1	ICA2
Brez	10.29	4.37	9.19	6.59
D1	16.82	17.62	16.21	15.10
D2	10.26	5.09	9.75	7.96
D3	9.87	4.73	9.69	8.17
D4	12.07	6.14	11.29	8.97
D5	9.99	4.25	9.47	6.71
D6	12.00	6.74	11.41	9.38
D7	10.85	4.53	9.83	6.37
D8	12.11	4.73	11.39	7.26
D9	13.38	6.96	12.52	8.80
D10	42.30	35.34	38.85	28.50

Tabela 2: Vpliv kakovosti slik na zanesljivost razpoznavanja z različnimi značilkami

Table 2. Impact of image degradations on face recognition accuracy with different face features

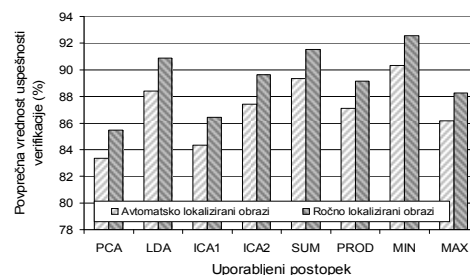
Kot smo pričakovali, so se kot najučinkovitejše med vsemi značilkami izkazale značilke postopka LDA, s katerimi smo na originalni bazi dosegli napako verifikacije HTER=4,37%. Nekoliko slabše so se odrezale značilke ICA2, kjer smo polovično napako verifikacije določili pri 6,59%. Z značilkami PCA ter ICA1 smo dobili napako 10,29% oziroma 9,19%.

Med pravili za združevanje mer podobnosti smo na originalni bazi dosegli najboljše rezultate z uporabo pravila najmanjše vrednosti, katerega napaka je znašala HTER=4,49%. Sledijo mu pravilo vsote s HTER =5,00%, pravilo produkta s HTER = 6,58% ter pravilo največje vrednosti s polovično napako verifikacije 7,89%. Opazimo lahko, da postopki fuzije na originalni

bazi niso prinesli izboljšav v primerjavi s postopkom LDA. Rezultati so pri pravilu vsote in najmanjše vrednosti približno enaki, pri pravilu produkta ter največje vrednosti pa so celo nekoliko slabši. Vzrok takšnih rezultatov je dejstvo, da značilke posameznih predstavitev (PCA, LDA in ICA) med seboj niso neodvisne in torej z združevanjem mer podobnosti ne pridobimo nove informacije o ločljivosti posameznih razredov.

Ugotovili smo, da se vsi postopki približno enako odzivajo na spremembe v kakovosti testnih slik. Tako je bilo razpoznavanje v vseh primerih razmeroma neobčutljivo na degradacije, kot so šum (D2, D3), JPEG kompresija (D5) in glajenje (D7, D8). Večji vpliv pa se je pokazal pri zmanjšanju barvne globine slik (D6), prisotnosti kompleksnega ozadja (D4) in geometrijskih transformacij (D9) in pri izgubi paketov informacije (D1) in prekrivanja obraza (D10), kjer se je napaka občutno povečala.

Čeprav postopki fuzije niso bistveno izboljšali rezultatov razpoznavanja na posameznih bazah, pa je tako pravilo vsote kot tudi pravilo najmanjše vrednosti doprineslo k večji robustnosti razpoznavanja. Povprečna vrednost HTER_{mean} prek vseh enajstih preizkušenih baz se je v prvem primeru zmanjšala iz 9,13% (LDA) na 7,44% (MIN), v drugem pa na 8,5% (SUM) (slika 2).



Slika 2: Povprečne vrednosti uspešnosti verifikacije
Figure 2. Average recognition rates

4.3 Tretji poskus

V zadnjem poskusu smo preverili še zanesljivost samodejnega razpoznavanja obrazov, pri katerem sistem na vhodni sliki povsem samodejno lokalizira obraz, njegovo slikovno področje normalizira ter osebi na sliki potrdi (oz. ne potrdi) identiteto. Vnovič smo izračunali vrednosti napak HTER, ki so za vse realizirane postopke izpeljave značilk podane v tabeli 3.

Med vsemi preizkušenimi postopki razpoznavanja se je na degradiranih slikah kot najučinkovitejše izkazalo združevanje mer podobnosti s pravilom najmanjše vrednosti (tabela 4), s katerim smo na originalni bazi dosegli napako HTER=5,36% ter povprečno napako prek vseh uporabljenih baz HTER_{mean}=9,69% (slika 2). Kot pri razpoznavanju s pravilno lokaliziranimi obrazy se je tudi tokrat izkazalo, da je sistem najbolj občutljiv na izgubo paketov informacije, prisotnost kompleksnega ozadja, zmanjšanje barvne globine, geometrijske

transformacije ter delno prekrivanje obraza. V naštetih primerih se je v sistemu povečalo število zavrnjenih vsiljivcev, kot tudi število zavrnjenih uporabnikov. Velika napaka HTER pa je hkrati tudi posledica nepravilno določenega slikovnega območja obraza, saj je bila uspešnost postopka lokalizacije prav v teh primerih med manjšimi.

Degradacije	HTER (%)			
	PCA	LDA	ICA1	ICA2
Brez	10.98	5.21	9.91	7.21
D1	23.94	24.55	23.26	20.70
D2	11.01	6.05	10.47	8.58
D3	10.69	5.81	10.53	8.54
D4	14.45	8.86	13.84	11.47
D5	11.31	5.72	10.79	7.95
D6	13.46	7.94	12.87	10.25
D7	12.39	5.87	11.30	7.74
D8	13.67	5.82	12.71	8.88
D9	20.06	16.19	19.76	17.99
D10	42.20	35.52	36.99	29.23

Tabela 3: Vpliv kakovosti slik na zanesljivost razpoznavanja z različnimi značilkami

Table 3. Impact of image degradations on face recognition accuracy with different face features

Degradacija	D1	D2	D3	D4	D5
HTER (%)	18.16	4.30	5.32	8.15	4.84
Degradacija	D6	D7	D8	D9	D10
HTER (%)	6.80	4.68	6.37	13.55	29.09

Tabela 4: Vpliv kakovosti slik na zanesljivost razpoznavanje s pravilom najmanjše vrednosti

Table 4. Impact of image degradations on face recognition accuracy with minimum fusion rule

Razlike med najuspešnejšim postopkom fuzije (MIN) ter najuspešnejšim posamičnim postopkom (LDA) so tokrat nekoliko večje, kot tedaj, ko smo uspešnost verifikacije preizkušali na ročno lokaliziranih obrazih. Večja učinkovitost fuzije pri samodejnih biometričnih sistemih je posledica dejstva, da lahko s kombinacijo različnih mer podobnosti nekoliko kompenziramo vpliv nepravilno določene lege obraza, napaka verifikacije HTER pa se s tem ustrezno zmanjša.

Povzamemo lahko, da je uporaba fuzije v sistemih za samodejno razpoznavanje obrazov upravičena, čeprav pri preizkušanju na idealnih slikah z njo ne dosežemo bistvenega izboljšanja rezultatov.

5. Sklep

Glavni prispevek pričujočega dela je v ovrednotenju vpliva kakovosti vhodnih slik na zanesljivost samodejnega razpoznavanja obrazov.

Razvili in preizkusili smo biometrični sistem, ki na digitalni sliki poišče obraz ter preveri identiteto osebe na njej. Nato smo proučili vpliv različnih degradacij slik

na uspešnost postopka lokalizacije, na zanesljivost verifikacije z različnimi značilkami in kriteriji odločanja (fuzija) ter na zanesljivost razpoznavanja sistema kot celote. Ugotovili smo, da so vsi preizkušani postopki razmeroma neobčutljivi na prisotnost šuma, glajenje slike in JPEG kompresijo, medtem ko izkazujejo večjo občutljivost na degradacije, kot so prekrivanje obraza, izguba paketov informacije, prisotnost kompleksnega ozadja in geometrijske transformacije.

6. Literatura

- [1] P.S. Huang, C. Chaing, Y. Lin, The Evaluation of Noise Immunity for PCA and ICA in Face Recognition, *J. C.C.I.T.*, vol. 33, no. 1, 2004.
- [2] E.P. Kukula, S.J. Elliott, Evaluation of a Facial Recognition Algorithm Across Three Illumination Conditions, *AESM*, vol. 19, no. 9, pp. 19-23, 2004.
- [3] J. Kim, J. Choi, J. Yi, M. Turk, Effective Representation Using ICA for Face Recognition Robust to Local Distortion and Partial Occlusion, *PAMI*, vol. 27, no. 12, pp. 1977-1981, 2005.
- [4] Domača stran laboratorija LUKS, <http://luks.fe.uni-lj.si/sl/osebje/vitimir/pub/seminar.pdf>
- [5] M. Turk, A. Pentland, Eigenfaces for Recognition, *Journal of Cognitive Neuroscience*, vol. 3, no.1, pp. 71-86, 1991.
- [6] P.N. Belhumeur, J.P. Hespanha, D.J. Kriegman, Eigenfaces vs. Fisherfaces, *PAMI*, vol. 19, no. 7, pp. 711-720, 1997.
- [7] M. Bartlett, T. Sejnowski, Independent components of face images, *PAJSNC*, 1997.
- [8] J. Czyz, J.Kittler, L. Vandendorpe, Multiple Classifier for face-based identity verification, *PR*, vol. 37, no. 7, pp. 1459-1469, 2004.
- [9] Domača stran podatkovne baze M2VTS in Lausanski prot. : <http://xm2vtsdb.ee.surrey.ac.uk/>
- [10] N. Pavešić, I. Fratrić, S. Ribarić., Degradation of the XM2VTS Database Face Images, *Biometrics on the Internet - proceedings*. Vigo (Spain): University of Vigo, pp. 17-21, 2004.
- [11] O. Jesorsky, K. J. Kirchberg, R. W. Frishholz, Robust Face Detection Using the Hausdorff Distance. *PIC AVBPA, LNCS-2091*, pp. 90-95, Springer, Halmstad, 2001.
- [12] A. Pozne, Pridobivanje vizualnih značilk za samodejno razpoznavanje govora, doktorska disertacija, FE, Univerza v Ljubljani, 2005.

Vitimir Štruc je mladi raziskovalec na Fakulteti za elektrotehniko Univerze v Ljubljani. Raziskovalno se ukvarja s področjem razpoznavanja obrazov.

Nikola Pavešić je redni profesor na Fakulteti za elektrotehniko Univerze v Ljubljani. Področje njegovega raziskovalnega dela zajema razpoznavanje vzorcev, obdelavo slik, razpoznavanje in razumevanje govora ter teorijo o informacijah.