

# Registracija slik obrazov za izboljšanje uspešnosti razpoznavanja oseb

Tilen Mlakar, Janez Zaletelj, Jurij F. Tasič

Univerza v Ljubljani Fakulteta za elektrotehniko, Tržaška 25, 1000 Ljubljana

E-mail: [tlen.mlakar@fdos.fe.uni-lj.si](mailto:tlen.mlakar@fdos.fe.uni-lj.si)

**Povzetek.** V članku predstavljamo izvedbo algoritma računalniškegavida, katerega namen je registracija digitalnih slik obrazov, zajetih s kamero ali fotoaparatom. Algoritem pomeni stopnjo predobdelave slike, s katero povečamo učinkovitost postopka biometrične razpoznavne obrazov oziroma ga omogočimo. Pri tem za zaznavanje obraza v sliki uporabimo algoritem AdaBoost in Haarove značilke, nato pa detektiramo značilne točke obraza, kot so oči. S tem določimo geometrijski položaj obraza, ki ga lahko potem izločimo iz ozadja ter normaliziramo njegovo geometrijo. Z ekvalizacijo histograma normaliziramo tudi osvetlitev slik, nato pa preizkusimo uspešnost razpoznavne z metodo PCA na dveh bazah slik.

**Ključne besede:** razpoznavanje obrazov, zaznavanje obrazov, zaznavanje oči, registracija slik

## Face image registration for improving face recognition rate

**Extended Abstract.** Face recognition has become an active area in the field of pattern recognition. It has numerous commercial and law-enforcement applications including video surveillance, information security and entertainment [1]. One of the main advantages of face recognition, when compared to other identification techniques, is its non-intrusiveness. This means that users are not asked for any kind of cooperation while the system identifies them and may even fail to notice that the identification process is running.

In this paper we present an algorithm for registration and normalization of digital face images. Using this algorithm we can either improve the recognition rate or make recognition possible in cases where this was not possible before. In the first phase we have to detect faces on the image. This is achieved by using a face detector that implements a set of Harr-like features and AdaBoost learning algorithm [5], [6]. In the next phase we have to detect selected characteristic points of the detected face, such as eyes. The proposed algorithm improves eye detection by transforming images from the RGB color space to YCbCr. In that space it can be seen that the eye area consists of pixels that have high Cb component value and pixels that have low Cr component value. By thresholding each channel using different thresholds and logically combining them, a mask which presents potential eyes objects is obtained. These objects are then accepted or rejected using contour analysis. Potential eye objects are accepted by minimizing objective function, which takes the contour size and position for input parameters. When the eye coordinates are known, the face image can be transformed into a coordinate space, created using these coordinates, by using methods such as shift and scale and rotation transformation. To further increase the face recognition rate, the images are photometrically normalized using histogram equalization. Once the image is processed using the proposed method, we can use it in the recognition process.

In order to test the efficiency of the proposed method, we use the face recognition algorithm based on PCA [2], [3], [4] and test it on registered and non-registered face images from two different databases. The results show that by using image

registration and normalization it is possible to significantly increase the recognition rate. From 68.9%, when using unregistered images from AR database without color normalization, to 88.5% when using registered images from the same database with color normalization. The highest recognition rate of 96.2% was achieved using registered and normalized face images from Frontal Face image database.

**Key-words:** face recognition, face detection, eyes detection, image registration

## 1 Uvod

Biometrično razpoznavanje obrazov je aplikacija računalniškegavida, ki ima veliko uporabno vrednost v sistemih avtomatizirane identifikacije in avtentikacije oseb. Razpoznavana podlagi obrazov ima pred drugimi načini identifikacije to prednost, da je za uporabnika dokaj nemoteča, pogosto se je uporabnik niti ne zaveda. Postopek razpoznavne lahko razdelimo na zaznavo obraza, na izločanje značilk in na razpoznavo. Pri zaznavi poiščemo obraz na sliki ter ga barvno in geometrijsko normaliziramo. Nato z uporabo določenih metod izločimo značilke, ki jih uporabimo za razpoznavo. Pri razpoznavi identificiramo ali avtenticiramo obraz na podlagi prej shranjenih značilk poznanih obrazov.

V grobem lahko metode za izločanje značilk razdelimo v dve skupini. V prvi so metode, ki razpoznavajo obraz kot celoto, za izpeljavo značilk pa uporabljajo tekssturo obraza. V drugi skupini so metode, ki za izpeljavo značilk uporabljajo posamezne značilnosti obrazov

in njihove medsebojne odvisnosti (npr. razdalje). Obstaja tudi tretja skupina metod, to so hibridne metode, ki naj bi združevale najboljše lastnosti prvih dveh vrst metod. Pregled stanja na področju razpoznavne obrazov in posameznih metod ter njihovih prednosti in slabosti je narejen v [1].

Metode, ki za izpeljavo značilk uporabljajo teksturo obraza, celotno sliko najprej preslikajo v ustrezen podprostor, v katerem so slike predstavljene bolj zgoščeno, poleg tega pa so podobnosti in razlike med obrazmi maksimirane. Zaradi delovanja teh metod je pomembno, da obraze geometrijsko normaliziramo oziroma registriramo glede na položaj referenčnih točk, kot so oči, nos ali usta. Poleg tega moramo odstraniti čim več motilnih dejavnikov, kot so ozadje, lasje ipd. Metode, ki za izpeljavo značilk uporabljajo posamezne značilnosti obrazov, pa že zaradi načina delovanja potrebujejo lokalne informacije o obrazu, to so položaj oči, nosa, ust ipd., ter njihove medsebojne odvisnosti. V članku predstavljamo algoritem za registracijo obrazov, s katerim omogočimo razpoznavo obrazov z metodo glavnih komponent [2], [3], [4] na poljubnih slikah\*. Metoda glavnih komponent ali *Principal Component Analysis* (PCA) za izpeljavo značilk uporablja teksturo obraza, zato je za uspešno delovanje potrebna registracija slik. Na sliki najprej zaznamo obraz in ga izločimo iz ozadja. Nato na obrazu zaznamo oči, nato pa z operacijami premikanja, skaliranja in rotacije normaliziramo geometrijo obrazov. Za barvno normalizacijo slik uporabimo še izravnavo histograma. Uspešnost razpoznavne registriranih in barvno normaliziranih slik smo preizkusili na slikah iz dveh različnih baz.

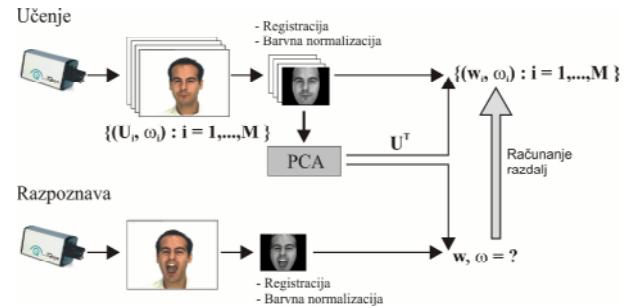
## 2 Arhitektura sistema

Na sliki 1 je prikazana arhitektura celotnega sistema za razpoznavo oseb na podlagi obrazov. Najprej izvedemo učenje sistema. Za to potrebujemo učno množico  $M$  oseb, ki jo označimo z

$$\mathcal{U} = \{(U_i, \omega_i) : i = 1, \dots, M\}, \quad (1)$$

kjer je  $U_i$  množica slik ene osebe in  $\omega_i$  ime oziroma oznaka te osebe. Slike obrazov učne množice registriramo. Pri učenju, kjer hitrost in delovanje v realnem času nista pomembna, bi lahko oči poiskali in označili ročno ter izvedli ročno registracijo. Za odstranitev razlik v osvetljenosti obrazov uporabimo eno izmed metod za barvno normalizacijo. Uporabili smo izravnavo histograma. Nato nad registriranimi in barvno normaliziranimi slikami izvedemo PCA. Rezultat učenja je ena značilka  $w_i$  za vsako osebo v učni množici.

\*Pri razpoznavi nismo več vezani na baze slik, ki so namenjene preizkušanju metod za razpoznavo obrazov. Slike teh baz so delno registrirane oziroma so vsaj brez ozadja.



Slika 1. Arhitektura sistema razpoznavanja uporabnikov  
Figure 1. System architecture of the user authentication system

Ko je učenje opravljeno, lahko sistem uporabimo za razpoznavo. Sliko neznanega obrazu registriramo in barvno normaliziramo. Ker je pri razpoznavi pomembno delovanje v realnem času, morata biti detekcija obrazu in oči ter registracija samodejni. Nato nad registriranimi slikami izvedemo PCA, rezultat, značilko  $w$ , pa primerjamo z značilkami, ki smo jih dobili pri učenju. V nadaljevanju članka bomo predstavili algoritem za registracijo in normalizacijo slik obrazov, v sam opis razpoznavne in metode PCA pa se ne bomo poglobili.

## 3 Algoritem za registracijo in normalizacijo obrazov na sliki

V tem poglavju predpostavljamo, da imamo na voljo posamezno sliko iz zaporedja slik, zajetih z videokamerou, torej ne uporabljamo nikakršnega sledenja oseb.

Cilj algoritma registracije slik obrazov je izločiti uporabnikov obraz v predpisani geometrijski postavitvi ter pri tem izločiti čim več motilnih dejavnikov na sliki (ozadje, lasje ipd.). Poleg tega želimo normalizirati osvetlitev obrazov.

### 3.1 Zaznavanje območja obraza

Za zaznavo obrazov v sliki uporabimo algoritem za zaznavo objektov, ki sta ga razvila Paul Viola in Michael Jones [5], nadgradila pa Rainer Lienhart in Jochen Maydt [6]. Njihov algoritem obljudlja hitro delovanje in velik delež pravilne zaznave obrazov ob majhnem deležu napačne zavrnitve. Algoritem uporablja Haarove\* značilke in več šibkih razvrščevalnikov, ki so naučeni z algoritmom AdaBoost. Šibki razvrščevalniki so prek odločitvenega drevesa združeni v enega močnega, ki na sliki zazna obraz. Algoritem je za potrebe razpoznavne obrazov naučen za frontalno zaznavo obrazov. Na sliki 2 je prikazan primer zaznave obrazov.

Ker lahko pride pri zaznavi različnih obrazov do odstopanj pri položaju in velikosti obraza, poleg tega pa ta postopek zazna tudi rotirane obraze (do neke meje), je

\* Izračunamo jih podobno kot Haarove funkcije, zato imajo tako ime.



Slika 2. Zaznava obraza z Haarovimi značilkami in algoritmom AdaBoost  
Figure 2. Face detection using the Haar-like features and AdaBoost algorithm

treba znotraj področja obraza zaznati še oči, potem pa obraz registrirati glede na položaj oči. V nadaljevanju predstavljamo preprost in učinkovit algoritem za zaznavo oči.

### 3.2 Segmentiranje področja oči

Postopke za zaznavanje oči lahko razdelimo v dve večji skupini. V prvi so postopki, ki uporabljajo aktivno IR luč. Ti postopki so učinkoviti, vendar za njihovo delovanje potrebujemo IR luč oziroma slike obrazov, ki so bili osvetljeni s tako lučjo. V drugi skupini so postopki, ki za zaznavo oči potrebujejo navadno barvno ali sivinsko sliko. Te postopke lahko naprej delimo na postopke z ujemanjem (*Template based*), postopke na podlagi videza (*Appearance based*) in postopke na podlagi značilnosti oči (*Feature based*). Prvi temeljijo na ujemaju z vzorcem oči, ki ga skonstruiramo pred zaznavanjem. Postopki na podlagi videza temeljijo na videzu očesa in potrebujejo za delovanje veliko pozitivnih in negativnih vzorcev, postopki na podlagi značilnosti oči pa temeljijo na določenih lastnostih oči, kot so porazdelitev barve na različnih delih oči, položaj oči itd. Osnovni pregled postopkov za zaznavo oči je narejen v [7].

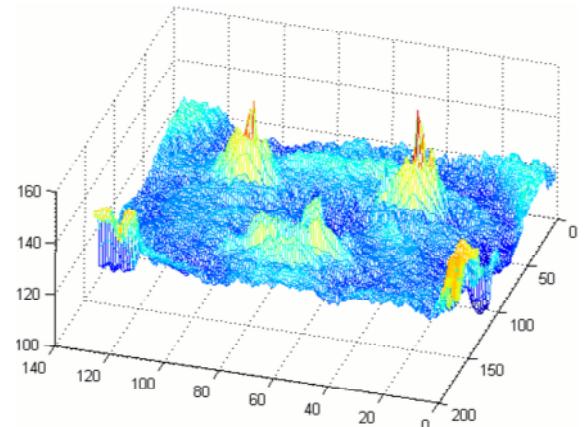
Za zaznavo oči smo napisali algoritem, ki spada med postopke na podlagi lastnosti oči. Najprej na sliki določimo območje obraza z zgoraj omenjeno metodo. Ker bi bila zaznava v RGB barvnem prostoru preveč odvisna od osvetljenosti, smo sliko pretvorili v barvni prostor YCbCr.



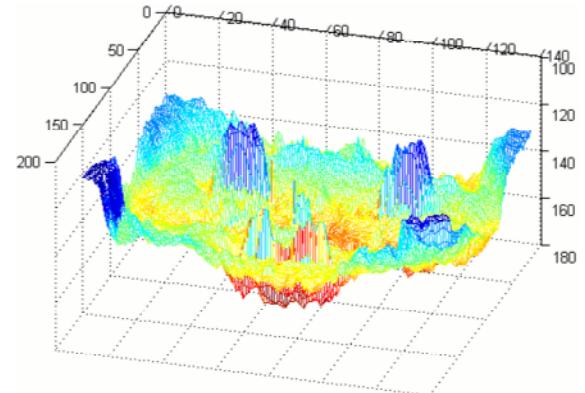
Slika 3. Komponente Y, Cb in Cr YCbCr prostora  
Figure 3. Y, Cb, Cr components of the YCbCr color space

Barvni prostor YCbCr ima to dobro lastnost, da je v njem komponenta osvetljenosti Y ločena od barvnih komponent Cb in Cr. Tako je zaznava oči manj občutljiva na spremembe v osvetljenosti. Na sliki 3 se vidi, da oči v

tem barvnem prostoru ni težko modelirati. Izkaže se, da imajo slikovni elementi, ki pripadajo očem, visoko vrednost komponente Cb in nizko vrednost komponente Cr [8].



Slika 4. Visoke vrednosti slikovnih elementov, ki pripadajo očem pri komponenti Cb  
Figure 4. High Cb component value of eye pixels



Slika 5. Nizke vrednosti slikovnih elementov, ki pripadajo očem pri komponenti Cr  
Figure 5. Low Cr component value of eye pixels

Na sliki 4 so prikazane vrednosti slikovnih elementov komponente Cb. Slikovni elementi, ki pripadajo očem, imajo v primerjavi z drugimi deli obraza visoko vrednost. Na sliki 5 so prikazane vrednosti slikovnih elementov komponente Cr. V primerjavi s komponento Cb, imajo tu slikovni elementi, ki pripadajo očem, nizko vrednost. Ravno tako se izkaže, da imajo slikovni elementi, ki pripadajo očem, nizko vrednost komponente Y (zenica in šarenica sta temnejši od beločnice). Kandidate za oči lahko torej dobimo tako, da vse tri barvne komponente upragovimo z ustreznim pragom, nato pa dobljene binarne maske združimo z logično operacijo IN. Ker se ustrezna vrednost praga spreminja od obraza do obraza, poleg tega pa je tudi odvisna od osvetlitve, uporabimo adaptivno upragovljenje. Ugotovili smo, da dobimo najboljši rezultat zaznave oči pri takšni vrednosti praga,

kjer dobljeno območje oči zavzema približno 4 odstotke površine celotnega obraza. Po združitvi mask iz različnih kanalov uporabimo morfološko operacijo poplavljanja, s čimer popravimo nepravilnosti kandidatov za oči v maski. Nazadnje odpravimo šum in manjše napake z glajenjem z median filtrom. V neidealnem primeru dobimo več kandidatov za oči, zato uporabimo še analizo kontur. Pred tem upoštevamo, da se lahko oči nahajajo le v zgornji polovici zaznanega obraza.

### 3.3 Zaznavanje oči z analizo kontur

V večini primerov dobimo več kandidatov za oči. Pravilne izberemo s pomočjo analize kontur. Konture binarnih objektov v maski izločimo in izračunamo koordinati težišča in površino vsake konture. Kot kriterijsko funkcijo za izbiro oči uporabimo enačbo 2, v kateri za iskanje oči upoštevamo položaj in velikost posamezne konture.

$$K_i = \alpha \cdot |\Delta\bar{x} - \Delta x_i| + \beta \cdot |\bar{y} - y_i| + \gamma \cdot |\bar{a} - a_i|, \quad (2)$$

kjer je  $\Delta x_i$  vodoravna razdalja med težiščem  $i$ -te konture in sredino obraza,  $y_i$  ordinata težišča ter  $a_i$  površina  $i$ -te konture.  $\Delta\bar{x}$ ,  $\bar{y}$  in  $\bar{a}$  so povprečne vrednosti zgoraj omenjenih parametrov. Vrednosti parametrov so v slikovnih elementih in so odvisne od ločljivosti vhodnih slik in od velikosti zaznanega obraza na sliki. Zato ne moremo določiti absolutnih vrednosti za povprečne vrednosti. Povprečne vrednosti smo zato določili kot razmerje med velikostjo zaznanega obraza in faktorji, ki smo jih določili empirično.  $\alpha$ ,  $\beta$  in  $\gamma$  so uteži, ki določajo prispevek posameznega dela k vrednosti kriterijske funkcije. Oči so koordinate težišča konture oziroma binarnega objekta z najmanjšo vrednostjo kriterijske funkcije. V tabeli 1 so prikazane vrednosti posameznih parametrov za konkretno sliko obraza iz baze FFD.

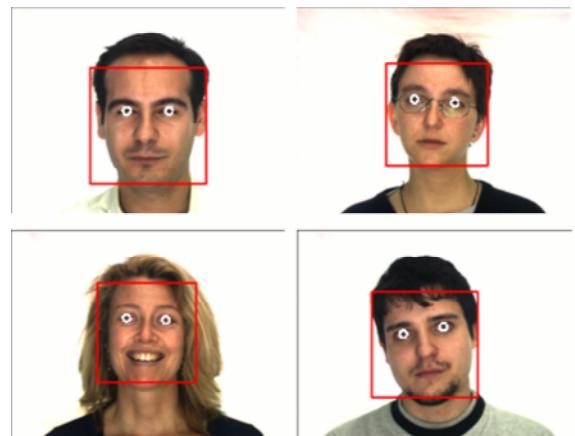
Parameter	Vrednost
$\Delta\bar{x}$	27.5 sl. el.
$\bar{y}$	36.6 sl.el.
$\bar{a}$	1210 sl. el.
$\alpha$	1
$\beta$	1
$\gamma$	0.2

Tabela 1. Vrednosti posameznih parametrov  
Table 1. Parameter values

### 3.4 Rezultati zaznave oči

Opisani algoritem zaznave obraza in oči smo preizkusili na dveh bazah slik. Prva je baza AR [9], ki vsebuje slike obrazov na belem ozadju, druga pa je baza *Frontal*

*face dataset* (FFD) [10], ki vsebuje vsakdanje posnetke obrazov z realnimi ozadji. V bazi AR smo uporabili le slike obrazov z enakomerno osvetlitvijo in slike obrazov, ki niso bili zakriti. Ugotovili smo, da zaznava oči na slikah obrazov z očali zaradi odbleskov stekla in okvirjev ne deluje dovolj zanesljivo, zato smo take slike izločili. Kljub temu je na sliki 6 prikazana ena izmed pravilnih zaznav oči na obrazu z očali. Na slikah 6 in 7 je prikazana zaznava obrazov in oči na nekaj slikah iz obeh baz.



Slika 6. Rezultati zaznave oči na slikah iz baze AR  
Figure 6. Results of eye detection on face images from the AR database



Slika 7. Rezultati zaznave oči na slikah iz baze FFD  
Figure 7. Results of eye detection on face images from the FFD database

V tabeli 2 je prikazana uspešnost algoritma za zaznavo oči. Pri obeh bazah je uspešnost večja od 90 odstotkov, čas obdelave ene slike pa je znašal približno 23 ms na računalniku s procesorjem Intel Pentium 4 3.2 GHz in 2 GB pomnilnika.

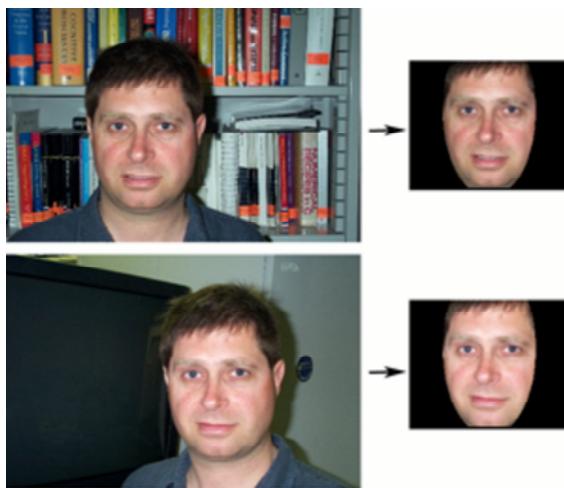
### 3.5 Registracija obrazov na sliki

Ker smo v prvem koraku zaznali obraz in dobili koordinate obraza, lahko obraz izrežemo iz prvotne slike. Ker poznamo tudi koordinate oči lahko slike registriramo

Baza	Ločljivost	Št. slik	Uspešnost	Čas
AR	384 × 288	541	91.7%	≈ 23ms
FFD	448 × 296	436	92.9%	≈ 24ms

Tabela 2. Uspešnost zaznave oči na obrazu  
Table 2. Eyes detection rate on the face area

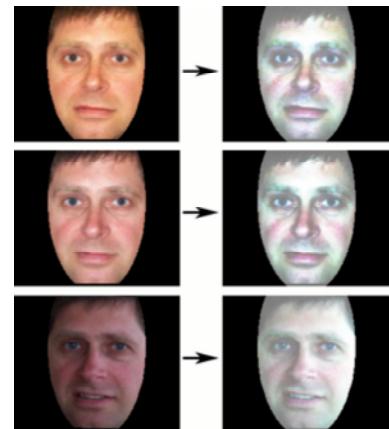
glede na položaj oči. Za referenčno točko izberemo aritmetično sredino med očmi ter sliko premaknemo tako, da se referenčna točka po premiku nahaja na sredini. Nato obraz zavrtimo okrog referenčne točke za kot, ki je enak kotu med vodoravnico in zveznico, ki poteka skozi oči. Ker poznamo tudi razdaljo med očmi, lahko obraz skaliramo. Tako so razdalje med očmi pri vseh slikah enake. Na koncu čez obraz nalepimo elipso, s čimer poskušamo odstraniti čim več motilnih elementov, kot so ozadje, lasje, ipd. Na sliki 8 je prikazan rezultat registracije.



Slika 8. Rezultat registracije slik obrazov  
Figure 8. Results of face image registration

### 3.6 Barvna normalizacija

Izravnava histograma je postopek izboljšanja slik[11]. Z izravnavo želimo doseči, da so vsi svetlostni nivoji slike zastopani v enaki meri. Torej želimo, da je histogram izravnane slike čim bolj raven. Tako lahko slike z različno osvetlitvijo barvno normaliziramo. Za razpoznavo obrazov morajo biti vse slike enako osvetljene, zato smo na registriranih slikah izvedli izravnavo histograma. Na sliki 9 je prikazan rezultat barvne normalizacije. Po izravnavi histograma se spremeni tudi barva ozadja, ki je na originalnih slikah črna. To ozadje se spremeni različno od slike do slike (zaradi različne zastopanosti svetlostnih nivojev na sliki), zato moramo na sliko z izravnanim histogramom zopet nalepiti elipso s črnim ozadjem. Za potrebo razpoznavne obrazov barvno sliko na koncu pretvorimo v sivinsko.



Slika 9. Rezultat normalizacije slik obrazov  
Figure 9. Results of face image photometric normalization

## 4 Rezultati

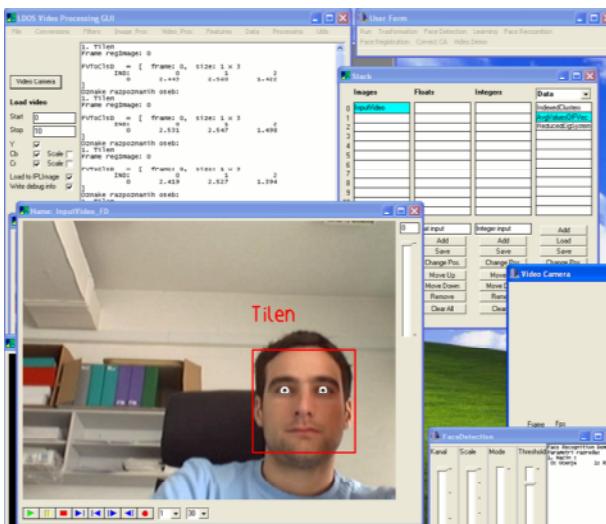
Uspešnost razpoznavne smo primerjali med barvno normaliziranimi in nenormaliziranimi slikami. Pri bazi AR smo razpoznavo primerjali tudi z neregistriranimi slikami (\* v tabeli 3). Pri bazi FFD to ni bilo mogoče, ker so v njej slike z realnimi ozadji. Ker smo želeli doseči čim boljši rezultat razpoznavne, smo za učno množico pri obeh bazah uporabili čim več slik za vsako izmed oseb. Iz baze AR smo izbrali po 5 slik vsake izmed 61 oseb, jih označili in uporabili za učno množico. Za testno množico smo uporabili za vsako osebo eno sliko. Iz baze FFD smo uporabili po 11 slik za vsako od 18 oseb za učno množico, preostale slike teh oseb pa smo uporabili za testno množico. Vse slike smo registrirali z zgoraj opisanim algoritmom in jih barvno normalizirali z izravnavo histograma. Nato smo izvedli učenje sistema in razpoznavo. Rezultati so zbrani v tabeli 3.

Baza	Ločljivost	Št. slik v u. m.	Št. slik v t. m.	Uspešnost	Uspešnost -EQ
AR*	192 × 244	305	61	68.9%	/
AR	200 × 163	305	61	80.3%	88.5%
FFD	200 × 163	198	157	79.6%	96.2%

Tabela 3. Uspešnost razpoznavne obrazov  
Table 3. Face recognition rate

Iz tabele je razvidno, da se je uspešnost razpoznavne pri bazi AR z registracijo izboljšala za dobrih 11 odstotkov, pri bazi FFD pa jo je omogočila. Razpoznavo je izboljšala tudi normalizacija osvetlitve. Pri bazi AR se je uspešnost izboljšala za približno 8 odstotkov, pri bazi FFD, kjer so velike razlike v osvetljenosti obrazov, pa celo za dobrih 16 odstotkov. Boljši rezultat razpoznavne pri bazi FFD pripisujemo večjemu številu slik za posamezno osebo v učni množici. V bazi AR je na voljo le po 6 ustreznih slik za posamezno osebo, kar vpliva na uspešnost razpoznavne.

Razpoznavo smo preizkusili tudi pri delovanju v realnem času iz kamere, priključene na računalnik. Po sneli smo okrog 100 slik za vsako izmed treh oseb, za katere smo izvedli učenje. Nato smo preizkusili razpoznavo. Razpoznavna je bila uspešna, če je bila osvetlitev enakomerna. Medtem ko je pri razpoznavni prihajalo do malo napak prve vrste (oseba, ki je bila v učni množici, je bila večinoma pravilno razpoznana), je pogosto prihajalo do napak druge vrste, kar pomeni, da je sistem tudi osebo, ki ni bila v učni množici, razpoznał kot eno izmed oseb v učni množici. Na sliki 10 sta prikazana vmesnik in rezultat razpozname. Celoten postopek zaznave obraza in oči, registracije, normalizacije histograma in razpozname je potekal v realnem času, s hitrostjo približno 4 slik na sekundo.



Slika 10. Razpoznavna s kamere  
Figure 10. Recognition from a video camera

## 5 Sklep

V članku smo želeli predstaviti potrebo po registraciji in barvni normalizaciji slik obrazov pred razpoznavo. Predstavili smo geometrijsko registracijo in barvno normalizacijo, kar vključuje zaznavo obrazov in oči ter izravnavo histograma. Uspešnost razpozname se je po registraciji in normalizaciji izboljšala in je v najboljšem primeru znašala 96.1 odstotkov. Slabost metode za zaznavo oči je računska zahtevnost in odvisnost od osvetljenosti, saj je metoda odpovedala pri slabši ali neenakomerni osvetlitvi. Računska zahtevnost sicer ni velik problem pri čedalje hitrejši strojni opremi, odvisnosti od osvetljenosti pa se lahko vsaj v kontroliranem okolju izognemo. Kljub temu je v samem algoritmu za zaznavo oči še veliko možnosti za nadaljnje delo, predvsem pri izboljševanju natančnosti in uspešnosti zaznave.

**Zahvala.** Raziskave, opisane v članku, so bile delno opravljene v okviru raziskovalnega programa P2-0246 Algoritmi in optimizacijski postopki v telekomunikacijah.

## 6 Literatura

- [1] W. Zhao; R. Chellappa; P.J. Phillips; A. Rosenfeld: Face Recognition: A Literature Survey. *ACM Computing Surveys*, Vol. 35, No. 4, str. 399-458, December 2003.
- [2] M. A. Turk; A. P. Pentland: Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*, Vol. 3, No. 1, str. 71-86, 1991.
- [3] M. A. Turk; A. P. Pentland: Face Recognition Using Eigenfaces. *Proceedings of Computer Vision and Pattern Recognition*, IEEE, str. 586-591, June 1991.
- [4] J. Zhang; Y. Yan; M. Lades: Face Recognition: Eigenface, Elastic Matching, and Neural Nets. *Proceedings of the IEEE*, Vol. 85, No. 9, str. 1423-1435, September 1997.
- [5] P. Viola; M. Jones: Rapid object detection using a boosted cascade of simple features. *IEEE Conference on Computer Vision and Pattern Recognition, Proceedings*, str. 905-910, Hawaii, 2001.
- [6] R. Lienhart; J. P. Maydt: An extended set of haar-like features for rapid object detection. *IEEE Conference on Image Processing (ICIP'02), Proceedings*, New York, September 2002.
- [7] K. Peng; L. Chen; S. Ruan; G. Kukharev: A Robust Algorithm for Eye Detection on Gray Intensity Face without Spectacles. *Journal of Computer Science & Technology*, Vol. 5, No. 3, October 2005.
- [8] R-L. Hsu; M. Abdel-Mottaleb; A. K. Jain: Face detection in color images. *International Conference on Image Processing 2001, Proceedings*, Volume 1, str. 1046 - 1049, October 2001.
- [9] A.M. Martinez; R. Benavente: *The AR face database, CVC Tech. Report #24*, 1998, <http://rvg-www.ecn.purdue.edu/RVL/>, dostopano: 7.6.2006.
- [10] M. Weber: *Frontal face dataset*, California Institute of Technology, <http://www.vision.caltech.edu/html-files/archive.html>, dostopano: 7.6.2006.
- [11] T. Acharya; A.K. Ray: *Image Processing: Principles and Applications*, Wiley Interscience, str.: 110-115, 2005.

**Tilen Mlakar** je diplomiral leta 2005 na Fakulteti za elektrotehniko v Ljubljani. Od leta 2006 je zaposlen v Laboratoriju za digitalno obdelavo, slik in videa kot raziskovalec. Skupaj s sodelavci razvija multimedidske telekomunikacijske sisteme in storitve pod okriljem Evropskih projektov. Trenutno na Fakulteti za elektrotehniko opravlja magisterij. Njegove raziskave obsegajo digitalno obdelavo signalov in analizo vsebin digitalnih slik.