

Barvni prostori za razpoznavanje obrazov

Vitimir Štruc, France Mihelič, Nikola Pavešić

Fakulteta za elektrotehniko, Univerza v Ljubljani
Tržaška 25, 1000 Ljubljana, Slovenija
vitimir.struc@fe.uni-lj.si, mihelicf@fe.uni-lj.si, nikolap@fe.uni-lj.si

Color spaces for face recognition

The paper investigates the impact that the face-image color space has on the verification performance of two popular face recognition procedures, i.e., the Fisherface approach and the Gabor-Fisher classifier - GFC. Experimental results on the XM2VTS database show that the Fisherface technique performs best when features are extracted from the C_r component of the $YCbCr$ color space, while the performance of the Gabor-Fisher classifier is optimized when grey-scale intensity face-images are used for feature extraction. Based on these findings, a novel face recognition framework that combines the Fisherface and the GFC method is introduced in this paper and its feasibility demonstrated in a comparative study where, in addition to the proposed method, six widely used feature extraction techniques were tested for their face verification performance.

1 Uvod

Postopke razpoznavanja obrazov lahko glede na način pridobivanja obraznih značilik delimo na holistične postopke, ki pri izpeljavi značilik upoštevajo celotno sliko obraza in torej temeljijo na videzu (angl. appearance based methods), ter analitične postopke, ki za določitev obraznih značilik uporabljajo le specifične lokalne lastnosti obraza.

Med značilne predstavnike prve skupine metod se uvrščajo projekcijske tehnike, kot so analiza glavnih komponent [1], analiza neodvisnih komponent [2] in linearna diskriminantna analiza [3]. V zadnjih letih pa našteje postopke vse bolj izpodrivajo njihove nelinearne različice (angl. kernel methods) [4, 5], ki značilke določajo v višje dimenzionalnih Hilbertovih prostorih ter s tem omogočajo tudi razmeroma zanesljivo razpoznavanje obrazov iz slik, zajetih v spremenljivih pogojih (npr. pod različnimi svetlobnimi pogoji, različnimi položaji obraza ipd.).

V skupino analitičnih metod se uvrščajo postopki, ki obraze razpoznavajo na podlagi značilik, izluščenih v značilnih točkah obraza. Zanje je značilno, da so manj občutljive na spremembe v osvetlitvi, položaju in izrazu obraza, a je določitev karakterističnih točk obraza, potrebnih za izpeljavo značilik, težavnejša. Med pogosteje uporabljene metode te skupine postopkov štejemo pristope, ki temeljijo na prikritih Markovovih modelih (angl. Hidden Markov Models - HMM) [6],

postopke prileganja elastičnih grafov [7] ter postopke, ki temeljijo na filtriranju z orientacijsko selektivnimi Gaborjevimi filtri [8].

Kot najučinkovitejše so se v zadnjem času izkazale metode, ki kombinirajo postopke iz obeh skupin. Tako so v skupinskih evaluacijah različnih sistemov za razpoznavanje obrazov na zbirkah BANCA in XM2VTS [9] prva mesta zasedle prav metode, ki so obrazne značilke določale na podlagi kombinacije Gaborjevih filtrov in nelinearnih projekcijskih metod. Primer takšne metode je predstavljen v [10].

Ne glede na način pridobivanja značilik, pa je vsem naštetim postopkom skupno, da predstavlja osnovo za izpeljavo značilik siva slika obraza, dobljena s povprečenjem komponent RGB barvnega prostora. Ker je predpostavka o sivi sliki obraza kot najboljši izbiri za določitev obraznih značilik vprašljiva, bomo v članku proučili vpliv (petih) različnih barvnih prostorov na uspešnost razpoznavanja obrazov (verifikacije).

V nadaljevanju bomo tako najprej predstavili dva postopka določitve obraznih značilik (postopek »Fisherjevih obrazov« in »Gabor-Fisherjev razvrščevalnik«), s katerima bomo ovrednotili vpliv barvnih prostorov na uspešnost razpoznavanja. V tretjem poglavju bomo opisali podatkovno zbirko ter eksperimentalni protokol, ki smo ju uporabili v naših preizkusih; v četrtem poglavju bomo na kratko predstavili pet barvnih prostorov, ki lahko služijo kot osnova za izpeljavo obraznih značilik; v petem poglavju pa bomo podali rezultate izvedenih eksperimentov.

2 Izpeljava značilik in izračun podobnosti

2.1 Izpeljava značilik z Gaborjevimi filtri

Za izpeljavo vektorja Gaborjevih obraznih značilik \mathbf{x} uporabimo množico 40 Gaborjevih filtrov (njihovi realni deli so prikazani na Sliki 1), ki jih določimo v skladu z naslednjo enačbo:

$$\psi_{g,h}(x,y) = \frac{f_g^2}{\pi\gamma\eta} e^{-\left(\frac{f_g^2}{\gamma^2}x^2 + \frac{f_g^2}{\eta^2}y^2\right)} e^{i2\pi f_g x}, \quad (1)$$

$$x_t = x \cos \theta_h + y \sin \theta_h,$$


$$y_t = -x \sin \theta_h + y \cos \theta_h,$$

kjer je $f_g=0.25/(2)^{g/2}$ frekvenca kompleksne sinusuide izraza (1) za $g \in \{0, 1, 2, 3, 4\}$, je $\theta_h=(h/8)\pi$ orientacija Gaborjevega filtra za $h \in \{0, 1, 2, 3, 4, 5, 6, 7\}$ ter sta γ in η parametra, ki določata velikost filtra.


Po določitvi množice Gaborjevih filtrov, izpeljemo vektor značilk \mathbf{x} poljubne slike obraza v skladu z naslednjim postopkom:

- sliko obraza $I(x,y)$ filtriramo z vsakim od 40 Gaborjevih filtrov $\psi_{g,h}(x,y)$, rezultate pa označimo z $O_{g,h}(x,y)$,
- amplitude $O_{g,h}(x,y)$ predstavimo v obliki slik (glej Sliko 2 - desno), ki jim v nadaljevanju zmanjšamo dimenzije (število slikovnih elementov zmanjšamo za faktor ρ),
- slike zmanjšanih dimenzij normiramo na srednjo vrednost nič ter varianco ena,
- normirane slike pretvorimo v vrstične vektorje, ki jih označimo z $\mathbf{o}_{g,h}$,
- sestavimo vektor Gaborjevih značilk \mathbf{x} kot:

$$\mathbf{x} = (\mathbf{o}_{0,0}^T \ \mathbf{o}_{0,1}^T \ \dots \ \mathbf{o}_{4,7}^T)^T. \quad (2)$$



Slika 1. Realni deli množice 40 Gaborjevih filtrov
Figure 1. Real parts of all 40 Gabor filters from the filter bank



Slika 2. Rezultata filtriranja z Gaborjevimi filtri: levo – primer sive slike obraza, desno – amplitude rezultatov filtriranja
Figure 2. An example of Gabor filtering: left – a sample gray-scale face image, right – magnitudes of the filtering results

Ker je velikost vektorja \mathbf{x} precej velika (za slike velikosti 128×128 slikovnih elementov, kakršne smo uporabili v naših poskusih, in faktor $\rho = 64$, je velikost vektorja \mathbf{x} enaka 1×10240), ga na koncu preslikamo še v podprostor, dobljen s postopkom linearne diskriminantne analize (predstavljene v naslednjem razdelku). Opisanemu pristopu izpeljave značilk pravimo Gabor-Fisherjev razvrščevalnik (angl. Gabor-Fisher Classifier - GFC), podrobneje pa je opisan v [11].

2.2 Linearna diskriminantna analiza -LDA

Recimo, da imamo n N -dimenzionalnih učnih vzorcev \mathbf{x} (bodisi učnih slik bodisi vektorjev Gaborjevih značilk),

ki pripadajo C razredom (t.j. osebam). Z linearno diskriminantno analizo želimo poiskati takšno transformacijsko matriko \mathbf{W} , da bo kriterijska funkcija (3) dosegla maksimalno vrednost:

$$J(\mathbf{W}) = |\mathbf{W}^T \mathbf{S}_B \mathbf{W}^T| / |\mathbf{W}^T \mathbf{S}_W \mathbf{W}^T|, \quad (3)$$

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

$$\mathbf{S}_B = \sum_{i=1}^C n_i (\boldsymbol{\mu}_i - \boldsymbol{\mu})(\boldsymbol{\mu}_i - \boldsymbol{\mu})^T, \quad (4)$$

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

$$\mathbf{S}_W = \sum_{i=1}^C \sum_{\mathbf{x} \in C_i} (\mathbf{x} - \boldsymbol{\mu}_i)(\mathbf{x} - \boldsymbol{\mu}_i)^T \quad (5)$$

in je $\boldsymbol{\mu}_i$ povprečni vektor i -tega razreda, $\boldsymbol{\mu}$ povprečni vektor vseh učnih vzorcev, C število razredov, n_i število vzorcev razreda C_i in \mathbf{x} vzorec iz učne množice vzorcev.

Iščemo torej transformacijsko matriko \mathbf{W} , s katero zmanjšamo razdalje med projekcijami vzorcev istih razredov (oseb) in hkrati povečamo razdalje med projekcijami vzorcev različnih razredov. Pokažemo lahko, da ustreza transformacijska matrika \mathbf{W} postopka LDA množici lastnih vektorjev izraza:

$$\mathbf{S}_W^{-1} \mathbf{S}_B \mathbf{w}_i = \lambda_i \mathbf{w}_i. \quad (6)$$

S transformacijsko matriko \mathbf{W} lahko izračunamo vektor značilk \mathbf{y} poljubnega vhodnega vzorca \mathbf{x} kot:

$$\mathbf{y} = \mathbf{W}^T \mathbf{x}. \quad (7)$$

Kadar je število učnih vzorcev, uporabljenih za izračun matrike znotraj razredne razpršenosti, manjše od njihove dimenzije, je matrika \mathbf{S}_W singularna. V tem primeru uporabimo različico postopka LDA, pri katerem matriki \mathbf{S}_B in \mathbf{S}_W najprej preslikamo v prostor glavnih komponent, sistem (6) pa nato rešimo v novem, manj razsežnem prostoru. Opisani pristop imenujemo postopek »Fisherjevih obrazov«, podrobneje pa je predstavljen v [3].

2.3 Izračun podobnosti

Podobnost med vektorjem značilk vhodne slike \mathbf{y} in modelom i -tega uporabnika (srednjim vektorjem značilk $\bar{\mathbf{y}}_i$ učnih slik i -tega uporabnika) merimo z normiranim korelacijskim koeficientom (8), ki se je izkazal kot ena najprimernejših mer za določevanje podobnosti med vektorji obraznih značilk [12]. Korelacijski koeficient je definiran kot:

$$d_c(\mathbf{y}, \bar{\mathbf{y}}_i) = \|\mathbf{y}^T \bar{\mathbf{y}}_i\| / \sqrt{\mathbf{y}^T \mathbf{y} \bar{\mathbf{y}}_i^T \bar{\mathbf{y}}_i}. \quad (8)$$

Kadar je vrednost korelacijskega koeficienta večja od odločitvenega praga, osebi na vhodni sliki potrdimo identiteto, če je vrednost koeficienta manjša, identitete ne potrdimo.

3 Opis podatkovne zbirke in eksperimentalnega protokola

Vpliv barvnih prostorov slik obrazov na uspešnost verifikacije smo preizkusili s pomočjo podatkovne zbirke XM2VTS, ki vsebuje 2360 slik obrazov 295 oseb. V skladu s prvo konfiguracijo Lausanskega protokola (eksperimentalni protokol podatkovne zbirke XM2VTS) smo slike zbirke razdelili v nize učnih, evalvacijskih in testnih slik. Z učnim nizom smo zgradili modele uporabnikov, z evalvacijskim nizom smo določili pragove, potrebne za odločitev o identiteti osebe na sliki, testni niz pa smo uporabili za določitev uspešnosti verifikacije. V poskusih, opisanih v petem poglavju, smo tako uporabili/izvedli:

- 600 učnih slik uporabnikov (po 3 slike na osebo),
- 600 poskusov verificiranja registriranih uporabnikov v evalvacijskem delu,
- 40000 poskusov verificiranja neregistriranih uporabnikov v evalvacijskem delu,
- 400 poskusov verificiranja registriranih uporabnikov v testnem delu in
- 112000 poskusov verificiranja neregistriranih uporabnikov v testnem delu.

Podrobnejši opis uporabljene podatkovne zbirke in eksperimentalnega protokola je na voljo v [13].


4 Pred-obdelava slik in barvni prostori

Preden lahko pričnemo z učenjem oz. preizkušanjem opisanih postopkov, moramo na slikah zbirke XM2VTS določiti ožje področje obraza (t.j. izločiti motnje kot so ozadje, obleka, pričeska, ipd.) in dobljena področja ustrezno normirati. V ta namen na vseh slikah zbirke ročno označimo lokacije oči, sliko rotiramo tako, da je daljica, ki povezuje oči, vodoravna, na podlagi med-očesne razdalje določimo meje področja obraza, dobljeno področje pa izrežemo. Izrezano sliko obraza normiramo na velikost 128×128 slikovnih elementov, jo pretvorimo v zeleni barvni prostor, v katerem izvedemo še svetlobno normiranje (zmanjševanje vpliva svetlobnih razmer pri zajemu slike) z odštevanjem srednje vrednosti svetilnosti vseh slikovnih elementov področja obraza in deljenjem z njihovo varianco.

Za ovrednotenje vpliva barvnih prostorov na uspešnost verifikacije obrazov uporabimo naslednjih pet predstavitev vhodne slike obraza:

- sivo sliko obraza (v nadaljevanju Gr ; Slika 3 - prvi stolpec), dobljeno s povprečenjem barvnih komponent RGB prostora; $Gr = (R+G+B)/3$,
- komponento Cr slike obraza (Slika 3 - drugi stolpec), predstavljene v barvnem prostoru $YCbCr$,
- sliko obraza, predstavljeno z razmerjem zelene barvne komponente in sive slike $Cg = G/Gr$ (v nadaljevanju Cg ; Slika 3 - tretji stolpec),

- sliko obraza, predstavljeno z razmerjem razlike rdeče ter zelene barvne komponente in sive slike; $Crg = (R-G)/Gr$ (v nadaljevanju Crg ; Slika 3 - četrti stolpec),
- komponento Cb slike obraza (Slika 3 - peti stolpec), predstavljene v barvnem prostoru $YCbCr$.



Slika 3. Primeri slik obrazov v petih barvnih prostorih
Figure 3. Examples of face images in five color spaces

5 Opis poskusov in rezultati

5.1 Preizkušanje postopka »Fisherjevih obrazov«

V prvem poskusu smo proučili vpliv barvnega prostora slik obrazov na uspešnost verifikacije z značilkami izpeljanimi s postopkom »Fisherjevih obrazov«. Število značilk smo nastavili na največjo možno vrednost (t.j. $d = C-1 = 199$, kjer je C število oseb oz. razredov). Za vsak preizkušeni barvni prostor smo določili napako zavrnitve registriranih uporabnikov (angl. false rejection rate - FRR), napako potrditve neregistriranih uporabnikov (angl. false acceptance rate - FAR) in skupno napako verifikacije (angl. total error rate - TER). Rezultati poskusov so podani v Tabeli 1.

Barvni prostor	FAR (%)	FRR (%)	TER (%)
Gr	4,00	3,00	7,00
Cr	1,90	2,50	4,40
Cg	3,12	3,25	6,37
Crg	3,95	3,75	7,70
Cb	3,63	2,50	6,13

Tabela 1. Uspešnost verifikacije »Fisherjevih obrazov«
Table 1. Verification performance of the Fisherface approach

Opazimo lahko, da je uspešnost verifikacije (vrednost TER) v vseh barvnih prostorih podobna, razen v primeru, ko so slike obrazov predstavljene s Cr komponento prostora $YCbCr$. Skupna napaka verifikacije znaša v tem primeru le 4,40%, kar predstavlja bistveno izboljšavo v primerjavi s klasičnim pristopom, pri katerem so značilke izpeljane na podlagi sive slike obraza.

5.2 Preizkušanje postopka GFC

V drugem poskusu smo ovrednotili vpliv barvnega prostora slik obrazov na uspešnost verifikacije na podlagi postopka GFC. Zopet smo uporabili 199 značilk; vrednotenje uspešnosti verifikacije pa smo tudi

Postopek	PCA	KPCA	Fisherjevi obrazji	Gabor+PCA	Gabor+KPCA	GFC	GFC+Fisherjevi obrazji
FAR (%)	8,42	6,96	4,00	5,04	3,84	1,64	1,01
FRR (%)	10,00	6,50	3,00	4,25	5,00	1,25	0,50
TER (%)	18,42	13,46	7,00	9,29	8,84	2,89	1,51

Tabela 3. Uspešnosti verifikacije postopka »GFC+Fisherjevi obrazji« v primerjavi z različnimi postopki izpeljave značilik
Table 3. Comparison of the verification performance of the »GFC+Fisherface« approach with popular feature extraction techniques

tokrat izvedli s pomočjo napak *FAR*, *FRR* in *TER*. Rezultati poskusov so podani v Tabeli 2.

Barvni prostor	FAR (%)	FRR (%)	TER (%)
<i>Gr</i>	1,64	1,25	2,89
<i>Cr</i>	1,83	2,25	4,08
<i>Cg</i>	3,08	2,25	5,33
<i>Crg</i>	2,20	1,75	3,95
<i>Cb</i>	2,92	2,25	5,17

Tabela 2. Uspešnost verifikacije s postopkom GFC
Table 2. Verification performance of the GFC approach

Podobno kot v razdelku 5.1, lahko tudi tokrat zaključimo, da so vrednosti skupne napake verifikacije razmeroma podobne, pri čemer tokrat izstopa postopek GFC izveden na sivih slikah obrazov. Napaka *TER* znaša v tem primeru zgolj 2,89%.

5.3 Preizkušnje postopka GFC+Fisherjevi obrazji

V zadnjem poskusu smo postopek, pri katerem smo za mero podobnosti uporabili vsoto mer podobnosti postopka GFC (izvedenega na sivih slikah obrazov) in postopka Fisherjevih obrazov (izvedenega na slikah obrazov predstavljenih s *Cr* komponento prostora *YCrCb*), primerjali z naslednjimi postopki izpeljave obraznih značilik (izvedenih na sivih slikah obrazov): analizo glavnih komponent - PCA [1], nelinearno analizo glavnih komponent z jedri - KPCA [4], postopkom »Fisherjevih obrazov« [3] in kombinacijami naštetih pristopov z vektorji Gaborjevih značilik. V vseh primerih smo parametre postopkov (št. značilik, prag, jedro, ipd.) določili tako, da smo zagotovili največjo možno uspešnost verifikacije. Iz Tabele 3, v kateri so prikazani rezultati opisane primerjave, lahko ugotovimo, da predlagani postopek zagotavlja najmanjšo skupno napako verifikacije med vsemi preizkušenimi postopki.

6 Zaključek

V članku smo proučili vpliv petih barvnih prostorov slik obrazov na uspešnost verifikacije dveh popularnih pristopov izpeljave obraznih značilik. Ugotovili smo, da dobimo najmanjšo napako verifikacije z različico postopka LDA, če le-tega izvedemo na komponenti *Cr* prostora *YCrCb*, medtem ko dobimo najboljše rezultate z Gabor-Fisherjevim razvrščevalnikom, če uporabimo sive slike obrazov.

Literatura

- [1] M. Turk, A. Pentland, Eigenfaces for Recognition, *Journal of Cognitive Neuroscience*, vol. 3, no.1, 1991, pp. 71-86.
- [2] M.S. Bartlett, J.R. Movellan, T.J. Sejnowski, Face Recognition by Independent Component Analysis, *IEEE Trans. on Neural Networks*, Vol. 13, No. 6, 2002, pp. 1450-1464.
- [3] P.N. Belhumeur, J.P. Hespanha, D.J. Kriegman, Eigenfaces vs. Fisherfaces, *PAMI*, vol. 19, no. 7, 1997, pp. 711-720.
- [4] B., Schölkopf, A.J., Smola, K.R., Müller, Nonlinear component analysis as a kernel eigenvalue problem, *Neural Computation*, vol. 10, 1998, pp. 1299-1319.
- [5] M.H., Yang, Kernel eigenfaces vs. kernel fisherfaces: face recognition using kernel methods, *Proc. 5th IEEE ICAFG*, Washington D.C., 2002, pp. 215-220.
- [6] A. Nefian, M. Hayes, An embedded hmm-based approach for face detection and recognition, *Proc. IEEE CASSP*, 1999, pp. 3553-3556.
- [7] L., Wiskott, J.M., Fellous, N., Kruger, C., von der Malsburg, Face recognition by elastic bunch graph matching, *IEEE Trans. PAMI*, vol. 19, pp. 775-779.
- [8] V., Kyrki, J.K., Kamarainen, H., Kalviainen, H., Simple Gabor feature space for invariant object recognition, *Pattern Recognition Letters*, vol. 25, 2004, pp. 311--318.
- [9] K., Messer, et. al., Face authentication competition on the BANCA database, *International Conference on Biometric Authentication*, Hong Kong, 2004.
- [10] C., Liu, Gabor-based kernel PCA with fractional power polynomial models for face recognition, *IEEE Trans. PAMI*, vol. 26, 2004, pp. 572-581.
- [11] C. Liu, H. Wechsler, Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition", *TPAMI*, vol. 11, no. 4, 2002, pp. 467-476.
- [12] J. Kittler, Y. Li, J. Matas, On matching scores for LDA-based face verification, *BMVC'00*, Bristol, UK, 2000, pp. 42-51.
- [13] Domača stran podatkovne baze M2VTS in Lausanski prot. : <http://xm2vtsdb.ee.surrey.ac.uk/>