

Različice opisnika EL

Jasna Maver

Univerza v Ljubljani, Filozofska fakulteta,
Oddelek za bibliotekarstvo, informacijsko znanost in knjigarstvo, Aškerčeva 2, 1000 Ljubljana, Slovenija
E-pošta: jasna.maver@ff.uni-lj.si

Povzetek. Z opisnikom EL predstavimo lokalno informacijo na sliki. EL je dvokomponentni opisnik, ki uporablja parcialne odvode prvega in drugega reda dvodimenzionalne Gaussove funkcije. V delu predlagamo dve različici opisnika. V prvem primeru raziščemo obnašanje opisnika, če odzive slike, izračunane za parcialne odvode prvega reda Gaussove funkcije, nadomestimo s slikovnim gradientom, izračunanim s postopkom, ki ga uporabljajo številni priljubljeni lokalni opisniki, med njim tudi opisnik SIFT. Opisnik EL uporablja odzive filtrov, izračunane le za eno standardno deviacijo Gaussove funkcije. Z drugo različico opisnika želimo ugotoviti, ali združevanje odzivov v opisniku, ki jih dobimo za različne standardne deviacije Gaussove funkcije oziroma merske lestvice, izboljša rezultate, ki jih opisnik dosega pri različnih nalogah. Eksperimenti so bili opravljeni na slikovni bazi HPatches za tri različne naloge: verifikacijo zaplat, ujemanje slik in poizvedovanje po zaplatah. Rezultati eksperimenta so pokazali na prednost uporabe parcialnih odvodov Gaussove funkcije prvega reda pred uporabo slikovnega gradienta, kot ga izračunava SIFT. Združevanje odzivov v opisniku, ki jih dobimo s filtriranjem slike na večjem številu merskih lestvic, je uspešno le za nalogo verifikacije zaplat in ujemanja slik.

Ključne besede: opisnik EL, slikovni gradient, slikovna baza HPatches

EL Descriptor Variants

The EL descriptor provides a local information in an image. EL is a two-component descriptor that utilizes the image responses to the first- and second-order partial derivatives of the two-dimensional Gaussian function. We propose two variants of the descriptor. First, we investigate the behavior of the descriptor by replacing the image responses calculated for the first-order partial derivative of the Gaussian function with an image gradient calculated by many popular local descriptors, including SIFT. The EL descriptor uses responses calculated for only one standard deviation of the Gaussian function. The second version of the descriptor is used to determine whether combining the descriptor responses obtained for different standard deviations of the Gaussian function improves the results the descriptor achieves in different tasks. The experiments are performed on the HPatches imaging database for three different tasks: patch verification, image matching, and patch retrieval. The experimental results show the advantage of using the first-order partial derivatives of the Gaussian function over the use of an image gradient computed by SIFT. Combining the responses obtained by filtering an image across multiple scales is successful only for the task of patch verification and image matching.

Keywords: EL descriptor, image gradient, imaging database HPatches

1 UVOD

Lokalni opisniki slik so pomembno področje raziskav računalniškega vida. Zanesljivo ujemanje lokalnih značilnic je potrebno v številnih aplikacijah, na primer pri mobilnem vizualnem iskanju (MVS) [7], združevanju

slik v panoramo [8], pri klasifikaciji teksturnih regij [23] in razpoznavanju predmetov [26], [17] in obrazov [13]. Raziskovalci računalniškega vida so predlagali številne vrste opisnikov, ki jih lahko razdelimo na ročno izdelane (SIFT [12], GLOH [18], SURF [6], BRIEF [9], KAZE [2], AG [15], Max-SIFT [25]) in tiste, ki temeljijo na učenju (BestDaisy [22], DeepCompare [24], DeepDesc [21], TFeat [5]).

Za ovrednotenje lokalnega opisnika slik so na voljo različna merila uspešnosti in različni protokoli [18], [11], [19], [14], [1], [20]. Nedavno je Balntas s soavtorji [4] predstavil HPatches, novo javno dostopno bazo slikovnih zaplat, in protokole za ocenjevanje lokalnih opisnikov. Baza vključuje več kot 2,5 milijona zaplat, pridobljenih na zaporedju slik različnih prizorov, posnetih v različnih svetlobnih razmerah in z velikimi spremembami v lokaciji in orientaciji kamere pri zajemanju slik. Na voljo je odprtokodna implementacija protokolov za ocenjevanje lokalnih opisnikov za tri različne naloge: verifikacijo zaplat, ujemanje slik in poizvedovanje po zaplatah. V istem prispevku avtorji pokažejo, da različica, ki vključuje naknadno normalizacijo ZCA opisnika RootSIFT [3], znatno izboljša rezultate. To spoznanje nas je spodbudilo k proučevanju uporabe parcialnih odvodov prvega in drugega reda dvodimenzionalne Gaussove funkcije pri določanju lokalnega opisnika. V članku [16] predlagamo tri različne opisnike E, L in EL. Opisnik E je zasnovan na parcialnih odvodih prvega reda, L na parcialnih odvodih drugega reda, EL pa združi opisnika E in L v skupni vektor. Izkazalo se

je, da sta E in EL zelo dobra opisnika, predvsem pri nalogah ujemanja slik in poizvedovanju po zaplatah. V tem članku želimo preveriti, ali je pri opisniku E, bolje uporabiti parcialne odvode Gaussovega filtra ali je boljše alternativa slikovni gradient, izračunan na način, ki ga uporabljajo številni priljubljeni opisniki, med njimi tudi SIFT oz. RootSIFT. Druga naloga je ugotoviti, ali filtriranje zaplat na večjem številu merskih lestvic pripomore k izboljšavi opisnika EL.


V drugem poglavju predstavimo opisnik EL, v tretjem poglavju njegove različice. V poglavju Eksperimentalni rezultati predstavimo podatkovno bazo HPatches in rezultate, dosežene z različicami opisnika E oz. EL za tri naloge. V sklepu povzamemo glavne ugotovitve, ki sledijo iz eksperimentov.

2 OPISNIK EL

Opisnik EL [16] uporablja parcialne odvode prvega in drugega reda dvodimenzionalne Gaussove funkcije

$$g(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\left(\frac{x^2}{2\sigma^2} + \frac{y^2}{2\sigma^2}\right)\right) \quad (1)$$

in teorijo krmilnih filtrov [10].



Slika 1: Gaussov filter in pet izbranih bazičnih filtrov $g_x^{0^\circ}$ in $g_x^{90^\circ}$ ter $g_{xx}^{60^\circ}$ in $g_{xx}^{120^\circ}$

2.1 Pet bazičnih filtrov in optimalni odziv

Slika 1 prikazuje Gaussov filter (1) in pet bazičnih filtrov, ki jih uporablja algoritem opisnika EL. Prvi bazični filter

$$g_x^{0^\circ} = \frac{\partial}{\partial x} g(x, y) = -\frac{x}{\sigma^2} g(x, y)$$

je parcialni odvod Gaussove funkcije prvega reda v smeri x osi, drugi bazični filter $g_x^{90^\circ}$ je njegova rotacija za 90° okrog koordinatnega izhodišča v nasprotni smeri urnega kazalca. Tretji bazični filter,

$$g_{xx}^{60^\circ} = \frac{\partial^2}{\partial x^2} g(x, y) = \left(-\frac{1}{\sigma^2} + \frac{x^2}{\sigma^4}\right) g(x, y),$$

je parcialni odvod Gaussove funkcije drugega reda v smeri osi x . Filtra $g_{xx}^{60^\circ}$ in $g_{xx}^{120^\circ}$ sta rotaciji filtra $g_{xx}^{0^\circ}$ za 60° oziroma 120° .

Naj bo $(\dots)^\theta$ operator rotacije. Poljubno funkcijo $f(x, y)$, rotirano za kot θ okoli izhodišča v nasprotni smeri urnega kazalca, označimo kot $f^\theta(x, y)$. Teorija krmilnih filtrov pravi, da lahko filter g_x^θ določimo z linearno kombinacijo dveh bazičnih filtrov

$$g_x^\theta = \cos(\theta)g_x^{0^\circ} + \sin(\theta)g_x^{90^\circ},$$

filter g_{xx}^θ pa z linearno kombinacijo treh bazičnih filtrov

$$g_{xx}^\theta = k_1 g_{xx}^{0^\circ} + k_2 g_{xx}^{60^\circ} + k_3 g_{xx}^{120^\circ}$$

z interpolacijskimi funkcijami

$$k_j = \frac{1}{3} [1 + 2(\cos(2(\theta - \theta_j)))] ,$$

$j = 1, 2, 3$ in z vrednostmi kotov $\theta_1 = 0^\circ$, $\theta_2 = 60^\circ$ in $\theta_3 = 120^\circ$.

Naj velja $G_x^{0^\circ} = g_x^{0^\circ} * I$, $G_x^{90^\circ} = g_x^{90^\circ} * I$, $G_{xx}^{0^\circ} = g_{xx}^{0^\circ} * I$, $G_{xx}^{60^\circ} = g_{xx}^{60^\circ} * I$ in $G_{xx}^{120^\circ} = g_{xx}^{120^\circ} * I$. Tu je $*$ operator, ki označuje filtriranje slike I z izbranim filtrom. V skladu s teorijo krmilnih filtrov [10] izračunamo odziv slike I na filter g_x^θ po enačbi

$$G_x^\theta = g_x^\theta * I = \cos(\theta)G_x^{0^\circ} + \sin(\theta)G_x^{90^\circ}, \quad (2)$$

odziv slike I na filter g_{xx}^θ pa po enačbi

$$G_{xx}^\theta = k_1 G_{xx}^{0^\circ} + k_2 G_{xx}^{60^\circ} + k_3 G_{xx}^{120^\circ}. \quad (3)$$

Na poljubni lokaciji na sliki je najboljša orientacija filtra tista, ki ima maksimalni odziv. Opisnik EL je zasnovan na takšnih maksimalnih odzivih. Pri parcialnem odvodu prvega reda je najboljša orientacija filtra [16]

$$\theta_E = \text{atan2}(G_x^{90^\circ}, G_x^{0^\circ}). \quad (4)$$

Magnitudo filtra $G_E = G_x^{\theta_E}$ določimo z enačbo 2:

$$G_E = \cos(\theta_E)G_x^{0^\circ} + \sin(\theta_E)G_x^{90^\circ}. \quad (5)$$

Pri parcialnem odvodu drugega reda pa želimo izbrati odziv, ki ima največjo vrednost v absolutnem smislu. V tem primeru izračunamo orientaciji filtra, ki imata minimalni in maksimalni odziv. Naj označuje $A = \sqrt{3}(G_{xx}^{120^\circ} - G_{xx}^{60^\circ})$ in $B = G_{xx}^{120^\circ} - G_{xx}^{60^\circ} - 2G_{xx}^{0^\circ}$. Iskani orientaciji filtra sta [16]:

$$\theta_{L_{\min}} = \frac{1}{2} \text{atan2}(A, B)$$

in

$$\theta_{L_{\max}} = \frac{1}{2} \text{atan2}(-A, -B).$$

Minimalni odziv ustreza detekciji svetle črte, maksimalni pa detekciji temne črte. Za izračunani vrednosti kotov izračunamo z enačbo 3 odziva slike $-G_{xx}^{\theta_{L_{\min}}}$ in $G_{xx}^{\theta_{L_{\max}}}$. Odziva primerjamo in ohranimo večjo vrednost:

$$G_L = \max(-G_{xx}^{\theta_{L_{\min}}}, G_{xx}^{\theta_{L_{\max}}}). \quad (6)$$

Prav tako zabeležimo le orientacijo, ki ustreza večji vrednosti.

$$\theta_L = \begin{cases} \theta_{L_{\min}} & \text{if } -G_{xx}^{\theta_{L_{\min}}} > G_{xx}^{\theta_{L_{\max}}}, \\ \theta_{L_{\max}} & \text{otherwise.} \end{cases} \quad (7)$$


Torej, G_L je vedno pozitiven ali enak nič.

2.2 Gradnja opisnika EL

Opisnik EL je sestavljen iz dveh delov. Del E (angl. Edges) uporablja θ_E in G_E , del L (angl. Lines) pa θ_L in G_L . Konstrukcija opisnika zahteva naslednje tri korake: kvantizacijo orientacije, združevanje magnitud maksimalnih odzivov filtrov v histogram v skladu s kvantizirano orientacijo in lokacijo ter normalizacijo histograma.

2.2.1 Kvantizacija orientacije: Za del E opisnika je kvantizacija orientacije povsem enaka tisti, ki jo uporablja priljubljeni opisnik SIFT [12]. Orientacijo θ_E kvantiziramo v osem razredov, ki ustrezajo vrednostim $\theta = -180^\circ, -135^\circ, -90^\circ, -45^\circ, 0^\circ, 45^\circ, 90^\circ$ in 135° . Za del L opisnika uporabimo zaradi simetrije filtra $g_{xx}^{0^\circ} = g_{xx}^{180^\circ}$ le štiri kvantizacijske vrednosti $\theta = -90^\circ, -45^\circ, 0^\circ$ in 45° , vendar pa kvantiziramo ločeno vrednosti, kjer θ_L pomeni $\theta_{L_{min}}$ in θ_L pomeni $\theta_{L_{max}}$. Za vsako lokacijo na sliki imamo tako 16 kvantiziranih vrednosti.

2.2.2 Združevanje magnitud v histogram: Združevanje magnitud maksimalnih odzivov se izračuna za 17 združevalnih centrov. Vrednost magnitude se uteži z Gaussovo funkcijo v skladu z oddaljenostjo točke do združevalnega centra. Uporabljajo se tri različne Gaussove funkcije [22]. Slika 2 prikazuje razporeditev združevalnih centrov z ustrežno Gaussovo utežitveno funkcijo. Po združevanju uteženih magnitud



Slika 2: Polarna razporeditev sedemnajstih združevalnih centrov z ustrežno Gaussovo utežitveno funkcijo. Krogi označujejo eno standardno deviacijo. Za zaplato z dimenzijami 65×65 so standardne deviacije Gaussovih filtrov $\sigma_0 = 3$, $\sigma_1 = 5.5$ in $\sigma_2 = 9.75$. Združevalni centri ležijo na krožnicah s polmerom $r_0 = 0$, $r_1 = 14.5$ in $r_2 = 31.5$. Vse mere so v piksljih.

v združevalne centre v skladu s kvantizirano orientacijo je vsak združevalni center predstavljen z osmimi vrednostmi, ki pomenijo odzive G_E , in osmimi vrednostmi, ki pomenijo odzive G_L . Vrednosti iz vseh centrov se združijo v skupni vektor oz. histogram, ki je opisnik EL:

$$D = [d_1, d_2, \dots, d_n], \quad (8)$$

z $n = 272$.

2.2.3 Normalizacija opisnika: Z normalizacijo opisnika dosežemo robustnost opisnika na velikost spremembe v kontrastu, ki je posledica linearnih in nelinearnih sprememb v osvetlitvi. Opisnik EL pri tem uporablja adaptivno iterativno določanje praga [16]:

- 1) izračuna se povprečna vrednost histograma, $\bar{d} = \sum_{i=1}^n d_i/n$;
- 2) izračuna se prag, $T = T_c \cdot \bar{d}$;
- 3) komponente opisnika, ki presegajo prag, se postavijo na vrednost T .

Vrednost konstante, $T_c = 2, 6$, je določena eksperimentalno. Nato sledi normalizacija, ki jo uporablja RootSIFT [3]:

- 4) opisnik je normaliziran tako, da ima norma L_1 vrednost ena;
- 5) vsaka komponenta opisnika je predstavljena z njenim kvadratnim korenem.

3 RAZLIČICE OZIROMA NADGRADNJA OPISNIKA EL

3.1 Slikovni gradient

Veliko opisnikov, med njimi tudi SIFT [12], uporablja za opisovanje lokalne strukture na sliki slikovni gradient. Slikovni gradient, ki ga uporablja SIFT, zahteva eno filtriranje slike manj, kot ga zahtevata parcialna odvoda prvega reda dvodimenzionalne Gaussove funkcije. Sliko $I(x, y)$ najprej filtriramo z Gaussovim filtrom $g(x, y)$ (1):

$$L(x, y) = I(x, y) * g(x, y). \quad (9)$$

Standardna deviacija Gaussovega filtra je tu enaka standardni deviaciji Gaussovega filtra, ki ga uporabljata parcialna odvoda prvega reda v pri opisniku E. Na filtrirani sliki $L(x, y)$ izračunamo magnitudo in orientacijo slikovnega gradienta z naslednjimi enačbami:

$$\begin{aligned} D_x &= L(x+1, y) - L(x-1, y), \\ D_y &= L(x, y+1) - L(x, y-1), \\ m(x, y) &= \sqrt{D_x^2 + D_y^2}, \end{aligned} \quad (10)$$

$$\theta_g(x, y) = \text{atan2}(D_y, D_x). \quad (11)$$

Nova različica opisnika uporablja isti postopek gradnje opisnika, kot je razložen v poglavju 2.2. V novi različici opisnika nadomestimo vrednosti G_E (5) in θ_E (4) z vrednostima m (10) in θ_g (11). Dimenzija nove različice opisnika je enaka dimenziji opisnika E; $n = 136$.

3.2 Večločljivostna metoda

S filtriranjem slike le na eni merski lestvici zajamemo le del informacije na sliki. Zato je smiselno, da sliko filtriramo na različnih merskih lestvicah. Dodatno filtriranje zahteva dodatnen čas. Zato bomo v našem primeru filtrirali le na dveh merskih lestvicah. Mersko lestvico določimo s standardno deviacijo Gaussovega filtra, v našem primeru s σ_1 in σ_2 . Z dodatnim filtriranjem pa ne želimo povečevati dimenzije opisnika. Najprej zgradimo ločena histograma (8) za vrednosti $G_E(\sigma_1)$, $\theta_E(\sigma_1)$ in $G_L(\sigma_1)$, $\theta_L(\sigma_1)$ ter vrednosti $G_E(\sigma_2)$, $\theta_E(\sigma_2)$ in $G_L(\sigma_2)$, $\theta_L(\sigma_2)$:

$$D(\sigma_1) = [d_1(\sigma_1), d_2(\sigma_1), \dots, d_n(\sigma_1)]$$

in

$$D(\sigma_2) = [d_1(\sigma_2), d_2(\sigma_2), \dots, d_n(\sigma_2)],$$

z $n = 272$. Histograma nato seštejemo v skupen histogram

$$D = D(\sigma_1) + D(\sigma_2) \quad (12)$$

in šele nato normaliziramo s postopkom, predstavljenim s koraki od 1 do 5 v podpoglavju 2.2.3. Tako ohranimo isto dimenzijo opisnika EL.

Tabela 1: Rezultati za naloge verifikacija zaplat, ujemanje slik in poizvedovanje po zaplatah, izračunani za opisnika E in Eg. Vse vrednosti so podane v mAP[%] (angl. mean Average Precision). Doseženi rezultati so podani v parih. Prva vrednost je rezultat, dobljen z osnovno metodo, druga z normalizirano različico ZCA [4]. Opisnik, ki uporablja slikovni gradient, je označen kot Eg. Najboljši rezultat v stolpcu je poudarjen.

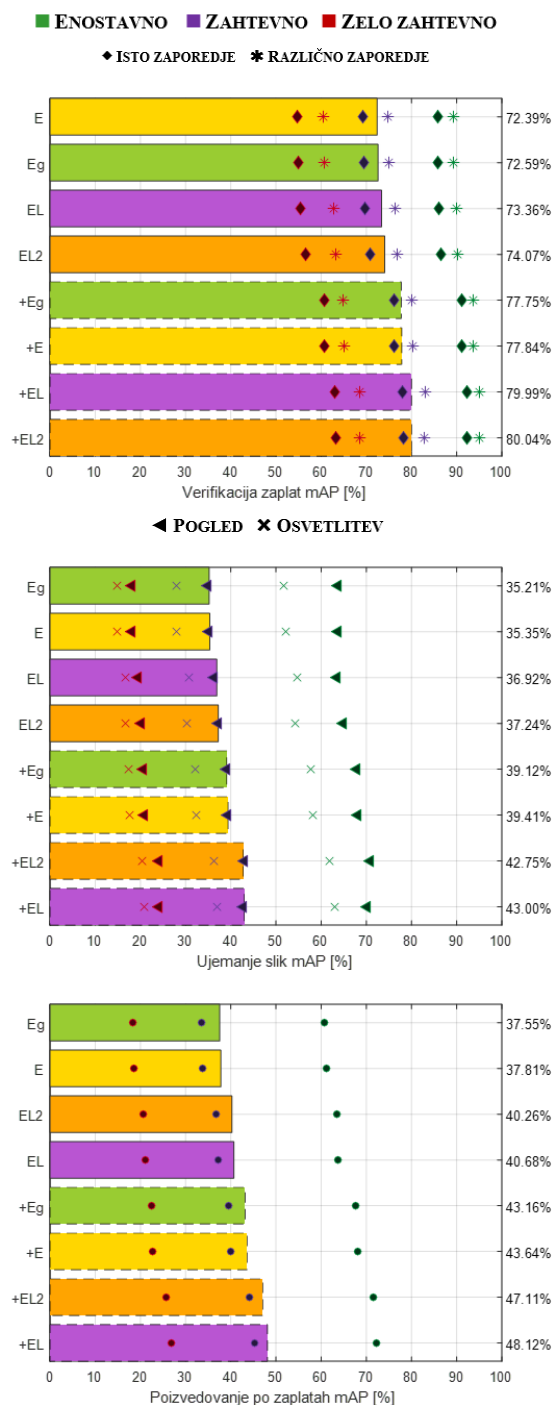
Op.	Verifikacija		Ujemanje sl.		Poizved.	
	osn. , ZCA	osn. , ZCA	osn. , ZCA	osn. , ZCA	osn. , ZCA	osn. , ZCA
E	72,39 , 77,84	35,35 , 39,41	37,81 , 43,64			
Eg	72,59 , 77,75	35,21 , 39,21	37,55 , 43,16			

4 EKSPERIMENTALNI REZULTATI

Za eksperimentiranje uporabimo slikovno bazo HPatches*, ki je podrobno predstavljena v [4]. HPatches vključuje več kot 2,5 milijona zaplat velikosti (65 × 65) pikslov, zajetih na 116 različnih prizorih. Vsak prizor predstavlja zaporedje šestih slik. Spremembe na slikah so posledica spremenjenih razmer osvetlitve prizora in različnih pogledov (različne lokacije in orientacije kamere, s katero so bile slike zajete). Na voljo sta tudi evalvacijski protokol in prosto dostopna programska oprema za nepristransko primerjavo opisnikov na treh nalogah: verifikaciji zaplat, ujemanju slik in poizvedovanju po zaplatah. Zaplate v slikovni bazi so po težavnosti razvrščene v tri skupine: enostavno, zahtevno in zelo zahtevno. S protokolom je mogoče ovrednotiti običajno obliko opisnika in njegovo normalizirano različico ZCA. V eksperimentu dosledno sledimo predlaganemu protokolu.

Opraviti želimo dva eksperimenta. S prvim preverjamo, ali je za predstavitev lokalne regije bolje uporabljati vrednosti G_E in θ_E , določene z enačbama 5 in 4, kjer uporabljamo parcialne odvode prvega reda Gaussove funkcije, ali vrednosti m in θ_g , določene z enačbama 10 in 11. Standardna deviacija Gaussove funkcije je za obe različici opisnika enaka 2,4 piksela. Rezultate eksperimenta prikazujeta slika 3 in tabela 1. Rezultati so boljši za opisnik, kjer uporabljamo parcialne odvode prvega reda Gaussove funkcije. Izjema je naloga verifikacije zaplat, kjer dobi osnovna oblika opisnika boljši rezultat za slikovni gradient. Kot je navedeno v članku [16], sta opisnika E in EL manj primerna za nalogo verifikacije zaplat, zelo uspešna pa za nalogo ujemanja slik in poizvedovanja po zaplatah.

Z drugim eksperimentom želimo ugotoviti, ali večkratno filtriranje zaplat na različnih merskih lestvicah pripomore k izboljšavi opisnika EL. Opisnik, ki uporablja dvakratno filtriranje, označimo z EL2. Opisnik uporablja dve množici filtrov (Slika 1), v prvem primeru velja $\sigma_1 = 2,4$ piksela, v drugem pa $\sigma_2 = 4,2$ piksela. Tabela 2 in slika 3 prikazujeta rezultate eksperimenta.



Slika 3: Rezultati, dobljeni za različice opisnika E in EL za tri različne naloge: verifikacija zaplat, ujemanje slik in poizvedovanje po zaplatah. Zaplate so po težavnosti razvrščene v tri skupine: enostavna, zahtevna in zelo zahtevna. Rezultati predstavljajo mAP (angl. mean Average Precision), kot je podano v članku [4]. Opisnik, ki uporablja slikovni gradient, je označen kot Eg. Opisnik, ki uporablja dvakratno filtriranje, je označen kot EL2. Znak + pred imenom opisnika in črtni okvir označujeta rezultate, dosežene z normalizirano različico ZCA [4].

*<https://github.com/hpatches/hpatches-dataset>

Dodatno filtriranje izboljša rezultate na nalogi verifikacije zaplat in na nalogi ujemanja slik, vendar tu le za osnovno verzijo opisnika, za normalizirano različico ZCA rezultati niso izboljšani. Na sliki 3 opazimo, da se v primeru opisnika EL2 izboljšajo rezultati za spremembe v pogledu, predvsem na enostavni skupini zaplat, poslabšajo pa se rezultati na zaplatah, kjer se spreminja osvetlitev. Iz rezultatov prav tako sledi, da se dvakratno filtriranje ne splača za nalogo poizvedovanja po zaplatah.

Tabela 2: Rezultati za naloge verifikacija zaplat, ujemanje slik in poizvedovanje po zaplatah, izračunani za opisnika EL in EL2. Vse vrednosti so podane v mAP[%] (angl. mean Average Precision). Doseženi rezultati so podani v parih. Prva vrednost je rezultat, dobljen z osnovno metodo, druga z normalizirano različico ZCA [4]. Opisnik, ki uporablja dvakratno filtriranje, je označen kot EL2. Najboljši rezultat v stolpcu je poudarjen.

Op.	Verifikacija		Ujemanje sl.		Poizved.	
	osn.	ZCA	osn.	ZCA	osn.	ZCA
EL	73,36	79,99	36,92	43,00	40,68	48,12
EL2	74,07	80,04	37,24	42,75	40,26	47,11

5 SKLEP

V delu raziskujemo različice opisnika EL. Izkazalo se je, da so za različne naloge primerne različne različice opisnika EL. Za nalogi ujemanje slik in poizvedovanje po zaplatah je bolje uporabiti odzive slike na parcialne odvode prvega reda Gaussove funkcije kot pa slikovni gradient, ki ga računa opisnik SIFT. Filtriranje zaplat na različnih merskih lestvicah je dobrodošlo za nalogo verifikacije zaplat. Za nalogo ujemanja slik izboljša rezultate, ko v prizoru ni sprememb v osvetlitvi, za nalogo poizvedovanja po zaplatah pa je manj primerno.

ZAHVALA

Raziskavo je omogočilo Ministrstvo za izobraževanje, znanost in šport Republike Slovenije v okviru programa P2-0214-Računalniški vid.

REFERENCES

- [1] H. Aanæs, A. L. Dahl, and K. S. Pedersen. Interesting interest-points. *Int. J. Comput. Vis.*, 97, pp. 18–35, 2012.
- [2] P. Alcantarilla, A. Fernandez Bartoli, and A. J. Davison. KAZE features. *In Proc. 12th ECCV*, pp. 214–227, 2012.
- [3] R. Arandjelović and A. Zisserman. Three things everyone should know to improve object retrieval. *In Proc. IEEE Conf. CVPR*, pp. 2911–2918, 2012.
- [4] V. Balntas, K. Lenc, A. Vedaldi, and K. Mikolajczyk. Hpatches: A benchmark and evaluation of handcrafted and learned local descriptors. *In Proc. IEEE Conf. CVPR*, 2017.
- [5] V. Balntas, E. Riba, D. Ponsa, and K. Mikolajczyk. Learning local feature descriptors with triplets and shallow convolutional neural networks. *In Proc. British Machine Vision Conf.*, pp. 119.1–119.11, 2016.
- [6] H. Bay, A. Ess, T. Tuytelaars, L. van Gool. Speeded-up robust features (SURF). *Comput. Vis. Image Understanding*, vol. 110, pp. 346–359, 2008.
- [7] S. Bianco, D. Mazzinia, D. P. Paub, and R. Schettinia. Local detectors and compact descriptors for visual search: A quantitative comparison. *Digital Signal Processing*, vol. 4, pp. 1–13, 2015.
- [8] M. Brawn and D. G. Lowe. Automatic Panoramic Image Stitching using Invariant Features. *International Journal of Computer Vision*, vol.74, no.1, pp. 59–73, 2007.
- [9] M. Calonder, V. Lepetit, M. Ozuysal, T. Trzcinski, C. Strecha, P. Fua. BRIEF: Computing a local binary descriptor very fast. *IEEE Trans. PAMI*, vol. 34, pp. 1281–1298, 2012.
- [10] W. Freeman and E. Adelson. The design and use of steerable filters. *IEEE Trans. PAMI*, vol. 13, pp. 891–906, 1991.
- [11] J. Heinly, E. Dunn, and J. M. Frahm. Comparative evaluation of binary features. *In Proc. 12th ECCV*, pp. 759–773, 2012.
- [12] D. Lowe. Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vis.*, vol. 60, pp. 91–110, 2004.
- [13] D. Lušina and J. Maver. Prepoznavna obrazov z AG opisnikom. *Elektrotehniški vestnik*, vol. 86(1-2), pp. 7–13, 2019.
- [14] S. Madeo and M. Bober. Fast, compact, and discriminative: Evaluation of binary descriptors for mobile applications. *IEEE Trans. Multimedia*, vol. 19, pp. 221–235, 2017.
- [15] R. Mandeljc and J. Maver. AGs: local descriptors derived from the dependent effects model. *J. Vis. Commun. Image Rep.*, vol. 58, pp. 503–514, 2019.
- [16] J. Maver and D. Skočaj. EL - Local image descriptor based on extreme responses to partial derivatives of 2D Gaussian function. *Mathematical Problems in Engineering*, vol. 2019, article ID 1247925, 10 pages, 2019.
- [17] K. Mele, D. Šuc, and J. Maver. Local probabilistic descriptors for image categorisation. *IET Computer Vision*, vol.3, no. 1, pp. 8–23, 2009.
- [18] K. Mikolajczyk and C. Schmid. A performance evaluation of local descriptors. *IEEE Trans. PAMI*, vol. 27, pp. 1615–1630, 2005.
- [19] P. Moreels and P. Perona. Evaluation of features detectors and descriptors based on 3d objects. *Int. J. Comput. Vis.*, vol. 73, pp. 263–284, 2007.
- [20] J. L. Schoenberger, H. Hardmeier, T. Sattler, and M. Pollefeys. Comparative evaluation of hand-crafted and learned local features. *In Proc. Conf. Computer Vision and Pattern Recognition*, 2017.
- [21] E. Simo-Serra, E. Trulls, L. Ferraz, I. Kokkinos, P. Fua, and F. Moreno-Noguer. Discriminative learning of deep convolutional feature point descriptors. *In Proc. IEEE ICCV*, pp. 118–126, 2015.
- [22] S. Winder and M. Brown. Learning local image descriptors. *In Proc. IEEE Conf. CVPR*, pp. 1–8, 2007.
- [23] Xiaosheng Yu, Yifei Zhang, and Huan Wang. A Novel Local Human Visual Perceptual Texture Description with Key Feature Selection for Texture Classification. *Mathematical Problems in Engineering*, vol. 2019, 20 pages, 2019.
- [24] S. Zagoruyko and N. Komodakis. Learning to compare image patches via convolutional neural networks. *In Proc. IEEE Conf. CVPR*, pp. 4353–4361, 2015.
- [25] L. Xie, Q. Tian, and B. Zhang. Max-sift: flipping invariant descriptors for web logo search. *In Proc. of the 2014 IEEE International Conference on Image Processing (ICIP)*, pp. 5716–5720, 2014.
- [26] L. Xie, J. Wang, W. Lin, B. Zhang, and Q. Tian. Towards reversal-invariant image representation. *Int. J. Comput. Vis.*, vol. 123, no. 2, pp. 226–250, 2017.

Jasna Maver je leta 1995 doktorirala s področja računalništva na Fakulteti za elektrotehniko in računalništvo Univerze v Ljubljani. V letih 1990 in 1991 je bila raziskovalka v laboratoriju GRASP na Univerzi v Pensilvaniji, kjer je raziskovala na področju aktivnega robotskega vida. Je izredna profesorica za računalništvo in informatiko na Univerzi v Ljubljani. Zaposlena je na Oddelku za bibliotekarstvo, informacijsko znanost in knjigarstvo na Filozofski fakulteti, kjer predava računalniške predmete. Na raziskovalnem področju sodeluje z Laboratorijem za računalniški vid in Laboratorijem za umetne vizualne spoznavne sisteme na Fakulteti za računalništvo in informatiko. Njeno trenutno področje raziskovanja je gradnja nizkonivojskih opisnikov lokalnih regij v slikah, ki jih lahko uporabimo za različne naloge računalniškega vida.