

► Poglobljen pogled v beločnično biometrijo: nova podatkovna množica in študija delovanja

Matej Vitek¹, Peter Rot^{1,2}, Vitomir Štruc², Peter Peer¹

¹Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Večna pot 113, Ljubljana, Slovenija

²Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška cesta 25, Ljubljana, Slovenija

{matej.vitek,peter.rot,peter.peer}@fri.uni-lj.si, vitomir.struc@fe.uni-lj.si

Izvleček

Prepoznavanje ljudi je temeljni problem, s katerim se ukvarja področje biometrije. V našem delu se ukvarjam s prepoznavo beločničnih žilnih struktur, ki imajo številne prednosti pred ostalimi značilkami: beločnične žile so edinstvene, tudi med identičnimi dvojčki – celo bolj kot prstni odtisi; za zajem ne potrebujemo posebnih naprav, le običajen fotoaparat ali mobilno kamero; zajem je neinvaziven in omogoča zajem na daljavo; žilne strukture se bistveno ne spreminjajo med življenjem; žilne strukture je težko ponareediti. Ker se biometrija, podobno kot mnoga ostala področja računalniškega vida, vedno bolj poslužuje globokega učenja, so izredno pomembne kvalitetne dobro označene podatkovne množice. Naša podatkovna množica SBVPI je javno dostopna in vsebuje očesne slike visoke kvalitete skupaj z ročnimi oznakami različnih regij v očesu (čarenica, zenica, ...). Poleg predstavitev SBVPI pa se naše delo tudi poglobi v bolj splošna vprašanja beločnične biometrije. V eksperimentalnem delu primerjamo 5 različnih pristopov za prepoznavo, ki jih evalviramo na SBVPI. Poleg tega analiziramo vpliv ločljivosti slik in smeri pogleda na uspešnost teh pristopov. Globoki model se je izkazal za najboljšega v splošnih poskusih, obenem pa tudi za najbolj robustnega, saj se je najbolje odrezal pri manjših ločljivostih in manj smereh pogleda. S tako poglobljeno analizo smo naslovili številna odprta vprašanja v beločnični biometriji, predvsem ker prikazujejo smiselnost uporabe globokega učenja (ki jo omogoča naša podatkovna množica SBVPI) in pa pomembnost uporabe različnih smeri pogleda v sami prepoznavi.

Ključne besede: Podatkovna množica, Prepoznavanje oseb, Očesna biometrija, Beločnica, Žilna biometrija.

Abstract

Ocular biometrics is the study of the applicability of various ocular modalities in different tasks, most prominently identity recognition. It can be useful in various applications such as surveillance systems, forensics or authentication systems. However, the existing datasets for ocular research are often inappropriate for the study of all three of the visible modalities – the sclera, the iris and the periocular region. In this work, we present a novel dataset of high-quality eye images captured in the visible spectrum appropriate for the study of all three modalities. We have performed an analysis of the covariance with several state-of-the-art recognition methods, studying the performance of the approaches not only on the dataset itself but also across different image resolutions and gaze directions. The results of this comprehensive study give insight not only into the general usability of our dataset, but also into the effects of different image resolutions and gaze directions on the accuracy of sclera-based recognition methods. Our experiments show that deep networks outperform handcrafted approaches in sclera recognition both in terms of overall performance as well as the robustness to lower resolutions and missing gaze directions.

Keywords: Dataset, identity recognition, ocular biometrics, sclera, vein-pattern recognition.

1 UVOD

Očesna biometrija je že od Daugmanovega dela na temo razpozname šarenice [1] aktivno področje biomeetričnih raziskav in velja za eno najbolj natanč-

nih vej biometrije s premnogimi primeri uporabe v različnih domenah [2]. Večina rabljenih podatkovnih množic v literaturi pa ni namenjena beločničnim raziskavam in so



Slika 1: Primer slike iz SBVPI in pripadajočih oznak: beločnice, periokularne regije, šarenice, beločničnih žil, zenice, trepalnic, kantusa.

zato zajete v bližnjem infrardečem (NIR) področju ali pa nimajo potrebnih oznak beločnice in žil, ki so potrebne za raziskovanje (predvsem globokih) pristopov za segmentacijo in prepoznavo beločnice. Da bi naslovili te pomanjkljivosti, v našem delu predstavimo naslednje doprinose:

Predstavimo novo javno dostopno očesno podatkovno množico, ki je namenjena razpoznavi beločnice (vseeno pa je primerna tudi za ostale očesne modalnosti), z imenom SBVPI. Množica vsebuje kvalitetne slike in ročne označbe regij očesa, vključno z ročno označenimi žilami pri podmnožici slik (česar nima nobena druga javno dostopna množica).

Evalviramo in primerjamo pet sodobnih pristopov za razpoznavo na naši množici. S tem pokaže-

mo, da je množica dovolj kvalitetna za pomenljive rezultate, obenem pa dovolj težka, da je zanimiva za nadaljnje raziskave.

S kovariančno analizo primerjamo delovanje petih pristopov iz prejšnje točke z manjšimi slikami in različnimi smermi pogleda.

2 PODATKOVNE MNOŽICE

V tabeli 1 pregledamo obstoječe podatkovne množice za očesno biometrijo in prikažemo razlike z našo SBVPI. Večina beločničnih raziskav uporablja UBIRIS v1 [3, 4, 5, 6, 7, 8, 9], MASD [10, 11, 12], UBIRIS v2 [13, 14], MICHE [13, 14] in UTIRIS [3]. Prav tako so pogosto uporabljene zasebne podatkovne množice, ki pa jih v tabeli ne naštevamo. SBVPI ima številne

Tabela 1: Obstojče podatkovne množice na temo očesne biometrije.

Podatkovna množica	Modalnost [†]	Javna	Orodje za zajem	Spekter	Velikost slik	Št. oseb	Št. slik	Oznake beločnice	Oznake žil	Smer(i) pogleda
CASIA Iris v1 [15]	Š	Da	Lasten skener šarenice	NIR	320 × 280	54	756	Ne	Ne	Statična
CASIA Iris v2 [15]	Š	Da	Lasten skener šarenice	NIR	640 × 480	60	2400	Ne	Ne	Statična
CASIA Iris v3 [15]	Š	Da	Lasten & OKI skener šarenice	NIR	640 × 480	> 700	22 034	Ne	Ne	Statična
CASIA Iris v4 [15]	Š	Da	Lasten & OKI skener šarenice	NIR	640 × 480	> 2800	54 601	Ne	Ne	Statična
ND-IRIS-0405 [16]	Š	Da	LG 2200 IIS	NIR	640 × 480	356	64 980	Ne	Ne	Statična
UPOL [17]	Š	Da	TOPCON TRC50IA	VIS	768 × 576	64	384	Ne	Ne	Statična
UTIRIS [18]	BŠ	Da	Canon EOS 10D	Oba	2048 × 1360	79	1540	Ne	Ne	Statična
UBIRIS v1 [19]	BŠ	Da	Nikon E5700	VIS	800 × 600	241	1877	Ne	Ne	Statična
UBIRIS v2 [20]	BPŠ	Da	Canon EOS 5D	VIS	400 × 300	261	11 102	Ne	Ne	Različne
ICE [21]	Š	Ne		N/A	N/A	120	3056	Ne	Ne	N/A
WVU [22]	Š	Ne		N/A	Oba	N/A	380	1852	Ne	N/A
IITD [23]	Š	Da	JIRIS JPC1000 CMOS Camera	NIR	320 × 240	224	1120	Ne	Ne	Statična
MICHE-I [24]	BPŠ	Da	Mobilna kamera	VIS	2048 × 1536	92	3732	Ne	Ne	Statična
UBIPr [25]	P	Da	Canon EOS 5D	VIS	500 × 400	261	10 950	Ne	Ne	Različne
UBIPosePr [26]	P	Da		VIS	N/A	100	2400	Ne	Ne	Različne
IMP [27]	P	Da	Cogent Iris Scanner, Nikon SLR	Oba	260 × 270	62	930	Ne	Ne	Statična
IUPUI [28]	SPI	Ne		N/A	Oba	N/A	44	352	Ne	Različne
MASD [29]	S	Ne		NIKON D 800	VIS	7500 × 5000	82	2624	Podmnožica	Ne
SBVPI (naša)	SPI	Da	Canon EOS 60D	VIS	3000 × 1700	55	1858	Celota	Podmnožica	Različne

[†]B – Beločnica, P – Periokularna regija, Š – šarenica

Oznaka N/A pomeni, da informacije nismo mogli pridobiti iz podatkovne množice in pripadajoče literature.

¹ SBVPI je javno dostopna za raziskovalne namene na: <http://sclera.fri.uni-lj.si/>

prednosti pred obstoječimi podatkovnimi množicami, saj je edina javno dostopna očesna podatkovna množica z ročno označenimi beločnicami in žilami.

V tabeli 2 predstavimo glavne lastnosti SBVPI1. V sliki 1 pokažemo primer slike SBVPI in pripadajočih oznak očesnih regij.

Zaradi oznak očesnih regij in metapodatkov, ki so vključeni v podatkovni množici, je SBVPI, v nasprotju z obstoječimi podatkovnimi množicami,

primerena za raziskavo pristopov za segmentacijo in prepoznavo beločnice. Na piksele natančne oznake žil na podmnožici slik so še posebej pomembne in so edinstvena lastnost podatkovne množice SBVPI. Ker SBVPI vsebuje tudi oznake preostalih regij, je primerna tudi za študijo pristopov razpozname šarenice in periokularne regije v vidnem delu spektra, kar omogoča študijo pristopov združenja različnih očesnih modalnosti.

Tabela 2: Opis podatkovne množice SBVPI (Sclera Blood Vessels, Periocular and Iris).

Lastnost	Opis
Število slik	1858
Število oseb	55
Starost oseb	15–80, večina pod 35
Spoli oseb	29 žensk, 26 moških
Število slik na osebo	Najmanj 32, nekatere osebe več
Velikost slik	3000 × 1700 pikselov
Oznake (vse slike)	Beločnica, periokularna regija
Oznake (~ 130 slik)	Šarenica, zenica, kantus, trepalnice, ožilje
Metapodatki (vse slike)	Identiteta, levo/desno oko, smer pogleda, starost, spol, barva
Smeri pogleda	Levo, desno, navzgor, naravnost

3 PREPOZNAVANJE BELOČNICE

V našem delu primerjamo klasične pristope, ki so se do nedavnega uporabljali v biometriji in globoko učenje, ki predstavlja smer, v katero se v zadnjem času premika računalniški vid v splošnem. Uporabimo SegNet iz [30] (ki je bil naučen z žilnimi oznakami iz SBVPI in je trenutno edini model za segmentacijo žil beločnice v literaturi), da iz slik izločimo žilne maske. Nato implementiramo globoki model ScleraNet [30] in ga na problemu razpozname identitete primerjamo z deskriptorskimi metodami, ki so se uporabljale pred globokim učenjem: tremi ki temeljijo na detekciji ključnih točk (SIFT [31], SURF [32], and ORB [33]) in gostem SIFTu [34], ki temelji na gosti mreži. Vse metode poganjamo na žilnih maskah prej omenjenega modela SegNet, da omogočimo pravično primerjavo razpoznavnih metod.

V verifikacijskih eksperimentih uporabimo galerijo (ki vsebuje 4 naključne slike za vsako osebo – 1 za vsako smer pogleda) in poskusno množico (ki vsebuje vse ostale slike). V enem poskusu avtentikacije

primerek iz poskusne množice primerjamo z vsemi 4 iz galerije s pristopi za prepoznavo, ki smo jih opisali zgoraj. Najmanjšo od 4 razdalj vzamemo kot ujemanje, na podlagi katerega potem avtentikacijo sprejmemo ali zavrnemo. Ta odločitev je lahko pravilna ali napačna, glede na to, ali je oseba iz poskusne množice enaka galerijski ali ne. S spremjanjem praga sprejetja lahko nadziramo ravnovesje med deležem napačnih sprejetij (angl. false acceptance rate – FAR) in deležem napačnih zavrnitev (angl. false rejection rate – FRR). Rezultat lahko poročamo kot površino pod krivuljo ROC, ki slika to ravnovesje pri različnih pragovih (angl. area under curve – AUC). V literaturi se uporablja tudi metrika točke enake napake (angl. equal error rate – EER), ki predstavlja točko, kjer sta FAR in FRR enaka. Ker so napačna sprejetja bolj kritična kot napačne zavrnitve, poročamo tudi delež verifikacije (VER = 1 – FRR) pri nizkih vrednostih FAR (v našem delu 1 % in 0.1 %). V tabeli 3 prikažemo rezultate splošnih poskusov.

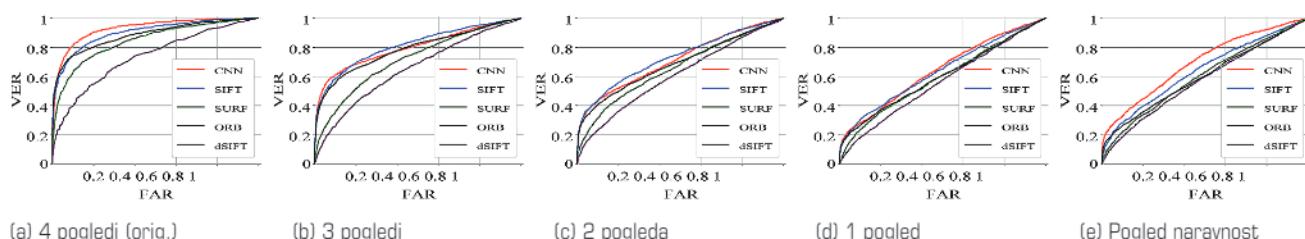
Tabela 3: Rezultati splošne prepozname, v katerih vidimo, da se je ScleraNet (označen s CNN) odrezal najbolje v celovitem delovanju, medtem ko je bil gosti SIFT (označen z dSIFT) najboljši pri nizkih vrednostih FAR. Rezultati so podani kot $\mu \pm \sigma$ (z 10-kratno evalvacijo na SBVPI).

Model	VER@0.1FAR	VER@1FAR	EER	AUC
CNN	0.178 ± 0.008	0.451 ± 0.008	0.144 ± 0.003	0.933 ± 0.003
SIFT	0.184 ± 0.076	0.452 ± 0.040	0.176 ± 0.005	0.903 ± 0.005
SURF	0.100 ± 0.008	0.285 ± 0.014	0.233 ± 0.006	0.844 ± 0.005
ORB	0.052 ± 0.011	0.148 ± 0.013	0.330 ± 0.007	0.736 ± 0.007
dSIFT	0.256 ± 0.012	0.496 ± 0.012	0.193 ± 0.003	0.889 ± 0.004

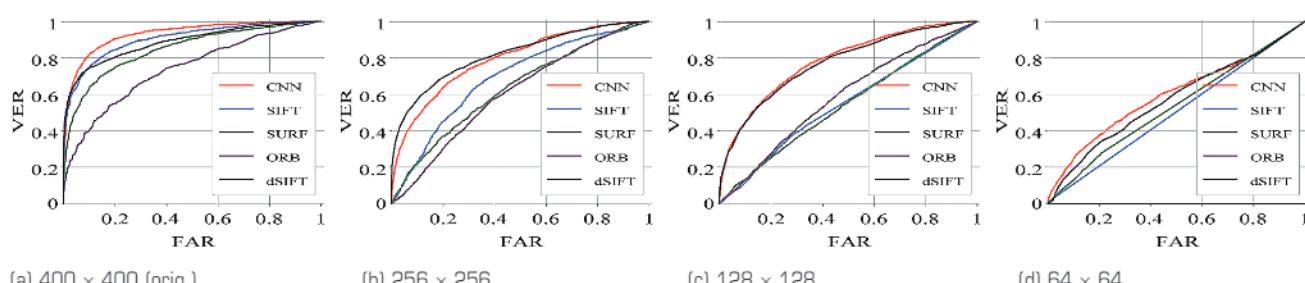
Ker se v različnih smereh pogleda vidijo različne žilne strukture, smo v galerijo vedno vključili vse 4 smeri pogleda. Zanima pa nas, kako bi se rezultati spremenili, če bi uporabili manj smeri pogleda. V drugi seriji poskusov zato galerijo s 4 pogledi nadomestimo z galerijo, kjer ima vsaka oseba le 3/2/1 slike, še vedno z različnimi (a naključno izbranimi) smermi pogleda. Ker pogled naravnost da najbolj ce-

lovito sliko žilnih struktur v očesu, poskus izvedemo še z galerijo s pogledom naravnost. Pri teh eksperimentih modela ScleraNet ne učimo ponovno, pač pa uporabimo enakega, kot smo ga uporabili za splošne poskuse.

Rezultate eksperimentov prikažemo v sliki 2. Več eksperimentov z bolj poglobljeno analizo je bilo opravljeno v razširjenem delu[35].



Slika 2: Rezultati poskusov z manjšimi galerijami. Prvi trije eksperimenti (b–d) v galeriji vsebujejo 3/2/1 smeri pogleda za vsako osebo, zadnji pa ima v galeriji samo pogled naravnost. ScleraNet (označen s CNN) in SIFT se obneseta najbolje pri naključnih smereh, pri pogledu naravnost pa ScleraNet opazno premaga vse ostale pristope. ScleraNet tudi edini opazno izboljša delovanje pri prehodu iz ene naključne smeri na pogled naravnost, kar pomeni, da se najbolje nauči pomena celotnega očesnega ožilja.



Slika 3: Rezultati poskusov s pomanjšanimi slikami. ScleraNet (označen s CNN) in gosti SIFT (označen z dSIFT) se izkažeta kot precej robustna, saj oba delujeta dobro na velikostih do 128×128 . ScleraNet pa opazno premaga ostale pristope tudi na manjših slikah, saj očitno najde pomenljive značilke celo na slikah velikosti 64×64 .

Zanima nas tudi potrebna kvaliteta slik in robustnost pristopov na manj kvalitetne slike, zato slike velikosti 400×400 , ki smo jo uporabili v prejšnjih eksperimentih, pomanjšamo na različne manjše ločljivosti.

Pri tem spet uporabimo enak model ScleraNet in ga ne učimo še enkrat na manjših slikah. Rezultate eksperimentov poročamo v sliki 3.

4 SKLEP

Predstavili smo novo podatkovno množico namenjeno raziskovanju beločnične biometrije in pokazali njene prednosti pred ostalimi obstoječimi javnimi podatkovnimi množicami, ki se uporablajo za očesno biometrijo. Med pomembnejšimi prednostmi so: javna dostopnost, kvalitetne slike visoke ločljivosti, zajetje v vidnem delu spektra in (najpomembnejše) ročne označbe očesnih regij, vključno s podrobnimi označbami očesnih žil.

Evalvirali in primerjali smo pet sodobnih pristopov za prepoznavo – en globok model, tri deskriptorske metode z detektorjem ključnim točk in eno deskriptorsko metodo z gosto mrežo. Naši rezultati prikazujejo, da globoki model deluje bolje kot deskriptorske metode, kar je v skladu z rezultati zadnjih let v biometriji in ostalih področjih računalniškega vida. Gosti SIFT pa je deloval najbolje pri nizkih vrednostih FAR.

Raziskali smo tudi vpliv različnih smeri pogleda in velikosti slik na delovanje razpozname beločnice. Po manjkljive galerije z manj smermi pogleda povzročijo precej slabše delovanje, saj se pri različnih smereh pogleda vidijo različne žilne strukture. Globoki model se je izkazal za najbolj robustnega pri manjših galerijah, obenem pa je bil edini, ki je pri pogledu naravnost deloval bolje kot pri 1 naključno izbrani smeri pogleda, kar nakazuje, da se je najbolje naučil celovite predstavitev žilnih struktur (saj se le-te pri pogledu naravnost vidijo najbolj celovito). Gosti SIFT in globoki model sta se izkazala za najbolj odporna na slabšo kvaliteto slik, saj sta dobro delovala na slikah vse do velikosti 128×128 , globoki model pa je pomenljive predstavitev žil našel celo na slikah do velikosti 64×64 in se tako ponovno izkazal za najbolj robustnega.

Z najboljšim rezultatom točke enake napake 14,4 % in precej nizkih verifikacijskih uspešnostih pri nizkih vrednostih FAR ostaja precej prostora za izboljšave tudi na samem pristopu za prepoznavo, saj bi za praktično uporabo žeeli boljše rezultate z majhnim številom napačnih sprejetij.

LITERATURA

- [1] J. Daugman, "High confidence visual recognition of persons by a test of statistical independence," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 15, no. 11, pp. 1148–1161, 1993.
- [2] I. Nigam, M. Vatsa, and R. Singh, "Ocular biometrics: A survey of modalities and fusion approaches," *Information Fusion*, vol. 26, pp. 1–35, 2015.
- [3] S. Alkassar, W. L. Woo, S. S. Dlay, and J. A. Chambers, "Robust sclera recognition system with novel sclera segmentation and validation techniques," *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 47, no. 3, pp. 474–486, 2017.
- [4] A. Das, U. Pal, M. A. F. Ballester, and M. Blumenstein, "A new efficient and adaptive sclera recognition system," in *2014 IEEE Symposium on Computational Intelligence in Biometrics and Identity Management (CIBIM)*, pp. 1–8, IEEE, 2014.
- [5] V. Gottemukkula, S. Saripalle, S. P. Tankasala, and R. Dera-khshani, "Method for using visible ocular vasculature for mobile biometrics," *IET Biometrics*, vol. 5, no. 1, pp. 3–12, 2016.
- [6] Y. Lin, E. Y. Du, Z. Zhou, and N. L. Thomas, "An efficient parallel approach for sclera vein recognition," *IEEE Transactions on Information Forensics and Security*, vol. 9, no. 2, pp. 147–157, 2014.
- [7] K. Oh and K. A. Toh, "Extracting sclera features for cancelable identity verification," in *2012 5th IAPR International Conference on Biometrics (ICB)*, pp. 245–250, IEEE, 2012.
- [8] N. L. Thomas, Y. Du, and Z. Zhou, "A new approach for sclera vein recognition," in *Mobile Multimedia/Image Processing, Security, and Applications 2010*, vol. 7708, p. 770805, International Society for Optics and Photonics, 2010.
- [9] Z. Zhou, E. Y. Du, N. L. Thomas, and E. J. Delp, "A new human identification method: Sclera recognition," *IEEE Transactions on Systems, Man, and Cybernetics (TSMC) -Part A: Systems and Humans*, vol. 42, no. 3, pp. 571–583, 2012.
- [10] P. Radu, J. Ferryman, and P. Wild, "A robust sclera segmentation algorithm," in *International Conference on Biometrics: Theory, Applications, and Systems (BTAS)*, pp. 1–6, 2015.
- [11] D. Riccio, N. Brancati, M. Frucci, and D. Gragnaniello, "An unsupervised approach for eye sclera segmentation," in *Iberoamerican Congress on Pattern Recognition (CIARP)*, pp. 550–557, Springer, 2017.
- [12] P. Rot, V. Štruc, and P. Peer, "Deep multi-class eye segmentation for ocular biometrics," in *IEEE International Work Conference on Bio-inspired Intelligence*, 2018.
- [13] S. Alkassar, W. L. Woo, S. Dlay, and J. Chambers, "Sclera recognition: on the quality measure and segmentation of degraded images captured under relaxed imaging conditions," *IET Biometrics*, vol. 6, no. 4, pp. 266–275, 2016.
- [14] D. R. Lucio, R. Laroca, E. Severo, A. S. B. Jr, and D. Menotti, "Fully convolutional networks and generative adversarial networks applied to sclera segmentation," in *IEEE ICB: Theory, Applications, and Systems*, 2018.
- [15] L. Ma, T. Tan, Y. Wang, and D. Zhang, "Efficient iris recognition by characterizing key local variations," *IEEE Transactions on Image processing*, vol. 13, no. 6, pp. 739–750, 2004.
- [16] K. W. B. Bowyer and P. J. Flynn, "The ND-IRIS-0405 iris image dataset," tech. rep., Notre Dame University.
- [17] M. Dobeš, L. Machala, P. Tichavský, and J. Pospišil, "Human eye iris recognition using the mutual information," *Optik*, vol. 115, no. 9, pp. 399–404, 2004.
- [18] M. S. Hosseini, B. N. Araabi, and H. Soltanian-Zadeh, "Pigment melanin: Pattern for iris recognition," *Instrumentation and Measurement, IEEE Transactions on*, vol. 59, pp. 792–804, april 2010.
- [19] H. Proença and L. Alexandre, "Ubiris: A noisy iris image database," in *International Conference on Image Analysis and Processing*, pp. 970–977, Springer, 2005.
- [20] H. Proença, S. Filipe, R. Santos, J. Oliveira, and L. A. Alexandre, "The ubiris. v2: A database of visible wavelength iris images captured on-the-move and at-a-distance," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 32, no. 8, pp. 1529–1535, 2010.

- [21] P. J. Phillips, K. W. Boyer, P. J. Flynn, A. J. O'Toole, P. J. Phillips, C. L. Schott, W. T. Scruggs, and M. Sharpe, "Frvt 2006 and ice 2006 large-scale results," 2007.
- [22] C. Whitelam, Z. Jafri, and T. Bourlai, "Multispectral eye detection: A preliminary study," in *2010 20th International Conference on Pattern Recognition*, pp. 209–212, IEEE, 2010.
- [23] A. Kumar and A. Passi, "Comparison and combination of iris matchers for reliable personal authentication," *Pattern Recognition*, vol. 43, no. 3, pp. 1016 – 1026, 2010.
- [24] M. D. Marsico, M. Nappi, D. Riccio, and H. Wechsler, "Mobile iris challenge evaluation (miche)-i, biometric iris dataset and protocols," *Pattern Recognition Letters*, vol. 57, pp. 17 – 23, 2015. Mobile Iris CHallenge Evaluation part I (MICHE I).
- [25] C. N. Padole and H. Proença, "Periocular recognition: Analysis of performance degradation factors," in *Biometrics (ICB), 2012 5th IAPR International Conference on*, pp. 439–445, IEEE, 2012.
- [26] C. N. Padole and H. Proença, "Compensating for pose and illumination in unconstrained periotic biometrics," *International Journal of Biometrics*, vol. 5, no. 3-4, pp. 336–359, 2013.
- [27] A. Sharma, S. Verma, M. Vatsa, and R. Singh, "On cross spectral periotic recognition," in *Image Processing (ICIP), 2014 IEEE International Conference on*, pp. 5007–5011, IEEE, 2014.
- [28] Z. Zhou, E. Y. Du, N. L. Thomas, and E. J. Delp, "Multi-angle sclera recognition system," in *Computational Intelligence in Biometrics and Identity Management (CIBIM), 2011 IEEE Workshop on*, pp. 103–108, IEEE, 2011.
- [29] A. Das, U. Pal, M. A. Ferrer, M. Blumenstein, D. Štepec, P. Rot, Ž. Emeršič, P. Peer, V. Štruc, S. Kumar, et al., "SSERBC 2017: Sclera segmentation and eye recognition benchmark competition," in *International Joint Conference on Biometrics (IJCBI)*, pp. 742–747, 2017.
- [30] P. Rot, M. Vitek, K. Grm, Ž. Emeršič, P. Peer, and V. Štruc, "Deep sclera segmentation and recognition," in *Handbook of Vascular Biometrics* (A. Uhl, C. Busch, S. Marcel, and R. VeIdhuis, eds.), pp. 395–432, Springer, 2020.
- [31] D. G. Lowe, "Object recognition from local scale-invariant features," in *International Journal of Computer Vision (ICCV)*, vol. 2, pp. 1150–1157, Ieee, 1999.
- [32] H. Bay, T. Tuytelaars, and L. Van Gool, "Surf: Speeded up robust features," in *European conference on computer vision*, pp. 404–417, Springer, 2006.
- [33] E. Rublee, V. Rabaud, K. Konolige, and G. Bradski, "Orb: An efficient alternative to sift or surf," in *International conference on computer vision*, pp. 2564–2571, 2011.
- [34] A. Das, U. Pal, M. A. F. Ballester, and M. Blumenstein, "Sclera recognition using dense-sift," in *2013 13th International Conference on Intelligent Systems Design and Applications (ISDA)*, pp. 74–79, IEEE, 2013.
- [35] M. Vitek, P. Rot, V. Štruc, and P. Peer, "A comprehensive investigation into sclera biometrics: a novel dataset and performance study," *Neural Computing and Applications*, pp. 1–15, 2020.

Matej Vitek je mladi raziskovalec in doktorski študent na Fakulteti za računalništvo in informatiko Univerze v Ljubljani. Leta 2015 je prejel diplomo s strani Fakultete za računalništvo in informatiko ter Fakultete za matematiko in fiziko, leta 2018 pa je od istih dveh ustanov prejel še magisterij. Trenutno se ukvarja z (predvsem lahkimi modeli za) biometrijo beločnice, deloval pa je tudi na področju umetne inteligence in razvoja iger.

Peter Rot je doktorski študent na Univerzi v Ljubljani na Fakulteti za računalništvo in informatiko. Leta 2015 je diplomiral iz računalništva in informatike, leta 2018 pa magistriral, prav tako iz računalništva in informatike. Trenutno se ukvarja z ohranjanjem zasebnosti in generiranjem obrazov, v preteklosti pa je deloval tudi na področju očesne biometrije.

Vitomir Štruc je izredni profesor na Fakulteti za elektrotehniko na Univerzi v Ljubljani. Od te fakultete je prejel tudi doktorat leta 2010. Vitomir je mednarodno priznan strokovnjak na področjih računalniškega vida, obdelave slik, prepoznavanja vzorcev in strojnega učenja. Je avtor (ali soavtor) čez 100 raziskovalnih člankov za priznane mednarodne znanstvene revije in konference na teh področjih. Pomagal je tudi pri organizaciji številnih svetovnih konferenc na temo računalniškega vida, med njimi IEEE Face and Gesture, ICB, WACV. Trenutno je predsednik programskega odbora IJCB 2020. Vitomir je pridruženi urednik IEEE Transactions on Information Forensics and Security, Pattern Recognition, Signal Processing in IET Biometrics. Bil je meta recenzent za WACV 2018, 2019, 2020, ICPR 2018, Eusipco 2019 in FG 2020. Je član IEEE, IAPR, EURASIP, trenutni predsednik SDRV in slovenski kontakt za EAB.

Peter Peer je redni profesor na Fakulteti za računalništvo in informatiko na Univerzi v Ljubljani, kjer je tudi vodja Laboratorija za računalniški vid, koordinator dvojnega študijskega programa z južnokorejsko univerzo Kyungpook National University in prodekan za gospodarske zadeve. Na Fakulteti za računalništvo in informatiko je doktoriral leta 2003. Po doktoratu je bil vabljén podoktorski raziskovalec na CEIT v San Sebastianu v Španiji. Raziskovalno se ukvarja z računalniškim vidom s poudarkom na biometriji. Sodeloval je v številnih državnih in EU projektih in je avtor več kot 100 raziskovalnih člankov v priznanih revijah in na konferencah. Nedavno je bil soorganizator tekmovanja Unconstrained Ear Recognition Challenge na IEEE/IAPR International Joint Conference on Biometrics 2017 in IAPR International Conference on Biometrics 2019. Leta 2018 je bil na to temo tudi sourednik posebne izdaje v reviji IET Biometrics. Trenutno je področni urednik v revijah IEEE Access in IET Biometrics. Je član EAB, IAPR in IEEE, v slovenski sekciji IEEE pa je 4 leta bil tudi predsednik računalniškega poglavja.