



APŠVIETIMO NORMALIZAVIMO ALGORITMŲ TYRIMAS VEIDAMS ATPAŽINTI

Rokas SEMĖNAS

*Vilniaus Gedimino technikos universitetas, Vilnius, Lietuva
El. paštas rokas.semenas@vgtu.lt*

Santrauka. Praktikoje taikomos veidų atpažinimo programos susiduria su daugybe iššūkių. Pagrindinis iš jų – sprendimams priimti taikomų algoritmų jautrumas šviesos variacijoms. Taikant esamus apšvietimo normalizavimo metodus dažniausiai koncentruojamasi į mažo mastelio požymių išskyrimą ir atmetami didelio mastelio požymiai. Straipsnyje siūlomas apšvietimo normalizavimo metodas, kurį taikant įvertinamos abi požymių kategorijos. Aptariami taikomi algoritmai, pateikiami eksperimentinių bandymų rezultatai ir išvados.

Reikšminiai žodžiai: apšvietimo normalizavimas, veidų atpažinimas, mažo (*Small-scale features*) ir didelio mastelių požymiai (*Large-scale features*), PCA, LDA, LBP.

Įvadas

Asmens identifikavimas pagal jo veido struktūrą yra vienas iš pagrindinių polinominių kompiuterinės regos uždavinių. Dėl itin plataus pritaikymo spektro, ši problema išlieka aktuali tiek pramogų industrijoje, tiek mokslo ir saugumo srityse. Biometriniai informacijos užraktai ateityje gali tapti nepakeičiama visuomenės apsaugos užtikrinimo sistemos dalimi. Tinkamai integruotos kompiuterinės atpažinimo sistemos bankų sektoriuje gali padėti apsisaugoti nuo asmens identiteto vagysčių ar neautorizuotų prisijungimų prie vartotojo sąskaitos. Įdiegus šią technologiją jau įrengtose gatvių stebėjimo kamerose galima būtų padėti surasti ieškomus asmenis ar nustatyti sekamų objektų buvimo vietą. Gyvenamuosiuose pastatuose ir įmonėse šios sistemos gali padėti apriboti nepageidaujamų asmenų patekimą į patalpas ar darbuotojų prieigą prie jų kvalifikacijos neatitinkančios technikos. Be to, individualūs žmogaus išvaizdos ir elgsenos požymiai teoriškai nesuklostojami ir yra itin patogūs naudotojo atžvilgiu. Daugybę skirtingų slaptažodžių ir PIN kodų galėtų būti pakeisti viena paprasta veido požymių analize. Nuo pat 1970 m. iki šių dienų veido atpažinimo problemos tyrimams buvo skirta daugybė išteklių, o pirmieji visuomenei matomi rezultatai paplito kartu su išmaniaisiais mobiliojo ryšio įrenginiais. Deja, ši technologija vis dar yra pramoginio lygio ir vartotojai savo informacijos saugoti jai nepatiki.

Viena pagrindinių priežasčių, lėmusių gana ribotą veidų atpažinimo technologijų pritaikymą saugumo

srityje, yra nepastovus atpažinimo tikslumo koeficientas. Dauguma geriausių rezultatų yra pasiekiami visiškai ar iš dalies valdomoje aplinkoje, naudojant specializuotą įrangą ir taikant daug sistemos resursų reikalaujančius algoritmus. Realiomis sąlygomis, taikant asmens identifikavimo metodus, galima susidurti su tokiais problemomis kaip asmens galvos posūkio kampas, veido išraiškų įtaka, dalinis arba visiškas veido uždengimas kitais objektais, vaizdo ar fotokameros rezoliucijos ir triukšmo problema bei prasto apšvietimo įtaka paveikslo kokybei.

Praktikoje standartiniais pripažįstami nuotraukų analizės metodai – pagrindinių komponentų analizė (angl. *Principal component analysis* – PCA), linijinė diskriminanto analizė (angl. *Linear discriminant analysis* – LDA) bei vietiniai dvejetainiai modeliai (angl. *Local binary pattern* – LBP) – yra pakankamai jautrūs apšvietimo sukurtiems nuokrypims. Vietiniai šešėliai gali pakeisti individualių veido bruožų, pavyzdžiui, akių, lūpų ar nosies formas. Taip pat jie prisideda prie veido zonos ribų iškraipymo. Globalūs šešėliai gali ne tik užmaskuoti atskiras veido dalis, bet ir jį patį sulyginti su paveikslėlio fonu. Keičiant šviesos kitimo kryptį, keičiasi ir šešėlių dydis bei pozicija. Norint padidinti veido atpažinimo tikslumo koeficientą, privalomas išankstinis nuotraukos normalizavimas.

Tyrimo tikslas – pasiūlyti apšvietimo normalizavimo metodą, patikrinti standartinių apšvietimo normalizavimo algoritmų sujungimo naudą veido atpažinimo tikslumui.

Nagrinėjamas apšvietimo normalizavimo modelis

Veidų atpažinimo ir asmens identifikavimo algoritmų seka bendroju atveju yra vienoda: pirmiausia pateikiama analizuojama nuotrauka. Taikant žmogaus veido aptikimo algoritmus, išskiriamas analizei tinkamas nuotraukos regionas. Ši nuotraukos dalis normalizuojama ir iškerpama – sukuriamas standartinis veido stačiakampis. Toliau paveikslas palyginamas su duomenų bazėje esančių nuotraukų rinkiniu ir remiantis panašumais identifikuojamas asmuo.

2008–2011 m. X. Xie (Xie *et al.* 2011) savo moksliniuose darbuose suformulavo pagrindinę šių procedūrų problemą. Praktikoje dažnai taikomi veidų atpažinimo metodai (PCA, LDA, LBP) yra jautrūs apšvietimo variacijoms, o standartiniai normalizavimo algoritmai vykdomi iš karto visam paveiksliui arba išskiriant tik linijų, kraštinių ar kitų smulkių objektų dalis. Eksperimentiniai tyrimai parodė, kad asmeniui identifikuoti gali pakakti didelio mastelio veido komponentių analizės. Esant nedideliame šviesos triukšmui, atpažinimo tikslumo koeficientai tokiu atveju gali siekti 96–85 %, o ekstremaliois sąlygomis ~10 %.

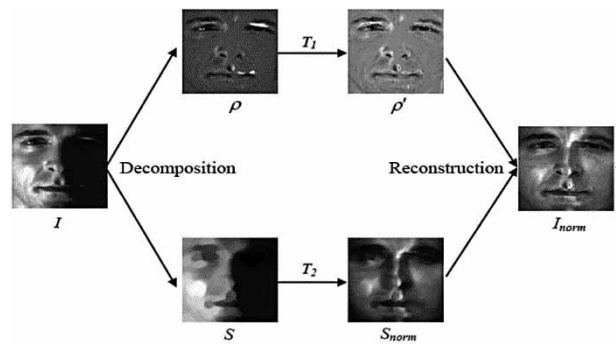
Remdamasis šiais tyrimais X. Xie apšvietimo normalizavimo problemą siūlo spręsti pritaikant paveikslo dekompozicijos metodą. Nagrinėjamai nuotraukai pirmiausiai yra pritaikoma logaritminė transformacija – sandaugos modelis konvertuojamas į sudėties modelį pagal (1) formulę:

$$\log(I(x, y)) = \log(p) + \log(S) = v + u. \quad (1)$$

Tai suteikia galimybę ne tik pritaikyti standartinius dekompozicijos metodus, bet ir iš dalies pašalina apšvietimo sukurtą triukšmą. Po šios transformacijos yra pritaikomas LTV (angl. *Logarithmic total variation*) modelis (2):

$$\hat{u} = \operatorname{argmin} \left[\int (\nabla \hat{u} + \lambda(f - u))_L^1, \right. \\ \left. \hat{v} = f - \hat{u}. \right] \quad (2)$$

Veido nuotrauka yra išskaidoma į mažo mastelio (angl. *Small-scale features*) ir didelio mastelio požymių (angl. *Large-scale features*) turinčias dalis $p \approx \exp(\hat{v})$ bei $S \approx \exp(\hat{u})$. Kiekviena dalis normalizuojama atskirai. LTV modelis yra tinkamas, kai reikia išsaugoti nuotraukoje esančias linijas. Tačiau ekstremaliois sąlygomis galimas pikselių peršvietimas. Siekiant išspręsti šią problemą, aukštojo dažnio komponentės filtruojamos vidurkinimo filtru. Naudojant $N \times N$ dydžio kernelį, nagrinėjamame plote esantys pikseliai, kurių vertės yra didesnės už nustatytą slenkstį Q , yra suvidurkinami priklausomai nuo lokalių verčių. Žemojo dažnio komponentėms normalizuoti siūloma naudoti diskrečiąją kosinuso transformaciją (angl. *Discrete cosine transformation*) ir aukštųjų dažnių filtrą. Taikant siūlomą mažo ir didelio mastelių požymių sujungimo metodą veiksmų nuoseklumas pavaizduotas 1 pav.



1 pav. Mažo ir didelio mastelio požymių sujungimo metodas (Xie *et al.* 2011)

Fig. 1. Small-scale and Large-scale features normalization method (Xie *et al.* 2011)

Siūlomas apšvietimo normalizavimo modelis

X. Xie siūlomas veido zonų dekompozicijos ir rekonstrukcijos modelis yra gana sudėtingas savo matematine išraiška ir reikalauja daug skaičiavimo laiko. Norėdami supaprastinti šį metodą, taikome prielaidą, kad kiekvieno asmens mažo mastelio požymių zonos yra išsidėsčiusios aplink pagrindines veido dalis – akių centrus, nosies bei lūpų regionus. Didelio mastelio veido požymių zonas sudaro kaktos sritis, skruostai ir smakras. Loginiame lygmenyje atskyrę šias dalis, galime nuotraukoje tiesiogiai pašalinti šviesos triukšmą, o gautus rezultatus sujungti, kaip tai parodyta 2 pav.

Siūlomam modeliui testuoti buvo panaudoti 10 apšvietimo normalizavimo algoritmų, laikomų baziniais. Jų rinkinį sudaro fotometriniai ir histograminiai metodai:

1. *Gama korekcija* (angl. *Power-law*) – transformacija. Normalizuojant paveiksliuką, pirmiausia pikselių spalvų intervalas pakeičiamas iš [0–255] į [0–1]. Tada perskaiciuojama nauja kiekvieno



2 pav. Siūlomas normalizavimo metodas. Didelio ir mažo mastelių požymių regionai yra tiesiogiai atskiriami, normalizuojami dviem skirtingais algoritmais ir sujungiami į vieną nuotrauką

Fig. 2. The proposed normalization method. Large and Small-scale feature regions are separated, normalized by using two different algorithms and merged into a single picture

nuotraukos pikselio vertė pagal (3) formulę (Shan *et al.* 2003):

$$I(x, y) = 255.0 \cdot I(x, y)^q. \quad (3)$$

2. *CLAHE* (angl. *Contrast limited adaptive histogram equalization*) – tai kompiuterinės regos algoritmas, skirtas nuotraukų kontrastui normalizuoti. Skirtingai nei įprastas histogramos išlyginimas, taikant *CLAHE* metodą nuotrauka padalinama į vienodo dydžio kvadratus ir kiekviename jų vykdomas standartinis histogramos išlyginimas. Jei tokia normalizuotame kvadrato išlieka nustatyta slenkstį viršijantys pikseliai, jie yra perskirstomi per visą nuotrauką taip, kad būtų gautas apylygis intensyvumo pasiskirstymas (3 pav.). Šis metodas labiausiai taikomas, kai norima išskirti nagrinėjamo objekto linijas ir vietinius kontrastus (Leszczynski 2010).



3 pav. CLAHE normalizavimo metodo pavyzdys. Slenksčio parametras lygus 5, kernelio dydis lygus 120×120

Fig. 3. CLAHE normalization method example. Threshold parameter is equal to 5, kernel size is equal to 120×120

3. *Histogramos išlyginimas*. Histograma – tai grafiškai atvaizduojamas nuotraukos intensyvumo lygių pasiskirstymas, iš kurio matyti, kiek tam tikros rūšies pikselių yra paveiksle. Histogramų išlyginimas taikomas siekiant pilkumo lygius padaryti pastovius ir išryškinti vietinius objekto kontrastus. Normalizuojant, histograma ištempinama – mažos pikselių vertės padidinamos, o dideli lokalūs klasteriai yra sumažinami, kol gaunamas apylygis intensyvumo pasiskirstymas.
4. *Single scale retinex* – (dar vadinama SSR) normalizacija vaizdą $I(x, y)$ laiko apšvietimo $L(x, y)$ ir atspindžio $R(x, y)$ sandauga. Siekiant sumažinti nuotraukos pikselių dinaminį diapazoną yra taikomas *Gauso* funkcijos branduolys $F(x, y)$ ir logaritminės atimties algoritmas (4) (Leszczynski 2010; Petro *et al.* 2014):

$$I_{SSR}(x, y) = \log(I(x, y)) - \log[F(x, y) * I(x, y)]. \quad (4)$$

5. *Multi scale retinex* – papildyta SSR algoritmo versija. Šiuo atveju kombinuojami keli skirtingų dydžių $N \times N$ *Gauso* filtrai su skirtingais svoriais w_n , kurių suma lygi vienetui. *Multi scale retinex* išraiška užrašoma bendrąja forma (5) (Leszczynski 2010; Petro *et al.* 2014):

$$I_{MSR}(x, y) = \sum_{n=1}^N w_n [\log(I(x, y)) - \log(F(x, y) * I(x, y))]. \quad (5)$$

6. *Single scale self quotient* (dar vadinamas SSQ) – taikant normalizacijos metodą apšvietimas analizuojamas kaip žemojo dažnio komponentė. Filtravimui galima taikyti *Gauso* blukinimo metodą, o bendroji SSQ formulė (6) aprašoma taip (Leszczynski 2010):

$$I_{SSQ}(x, y) = \frac{I(x, y)}{F(x, y) * I(x, y)}. \quad (6)$$

7. *Multi scale self quotient* – SSQ metodo rezultatai tiesiogiai priklauso nuo teisingai parinkto *Gauso* filtro kernelio dydžio. Jei jis bus per mažas, nukentės normalizacijos procesas, o jei per didelis – ties požymių kraštinėmis gali susidaryti papildomo triukšmo. Siekiant išspręsti šią problemą, galima pritaikyti nelinejinę funkciją T su svoriais pagal (7) formulę (Leszczynski 2010):

$$I_{MSSQ}(x, y) = \sum_{n=1}^N w_n T \left[\frac{I(x, y)}{F(x, y) * I(x, y)} \right]. \quad (7)$$

8. *Homomorfinis filtravimas* – kadangi apšvietimas yra žemojo dažnio komponentė, taikant šį metodą filtravimas vyksta dažnių srityje. Pirmiausiai taikant natūrinį logaritmą yra atsiejami $L(x, y)$ ir $R(x, y)$. Tada, naudojant Furjė transformaciją (FT), nuotrauka yra konvertuojama į dažnių sritį. Panaudojamas aukštųjų dažnių filtras ir įvykdoma atvirkštinė Furjė transformacija (IFT) pagal (8) formulę (Leszczynski 2010; Prabhakar, Praveen Kumar 2011):

$$I'(x, y) = e^{\text{IFT}(\text{FT}(\ln(I(x, y))H))}. \quad (8)$$

9. *Pilkų lygių normalizacija* vykdoma siekiant suvidurkinti visų nuotraukos pikselių spalvas. Pirmiausiai nuotrauka yra išblukinama panaudojus plačiajuostį *Gauso* žemųjų dažnių filtrą, o tada tokį patį siaurajuostį filtrą. Procesas yra lėtas, tačiau atsparus vaizdo posūkio variacijai. Normalizuotam vaizdai gauti taikomos (9) ir (10) formulės:

$$I(x, y) = 0,5 + \text{const}_1 \cdot \partial, \quad (9)$$

$$I(x, y) = 0,5 + \text{const}_2 \cdot \left(\partial + \frac{\partial}{\sqrt{I(x, y)}} \right), \quad (10)$$

čia 0,5 žymi vidutinę pikselių vertę, const_1 ir const_2 parenkama taip, kad veido pilkumo lygmenys kistų nuo 0 iki 1. Jei vaizdas aplink nagrinėjamą tašką $P(x, y)$ keičiasi nedaug, tai ∂ vertė bus arti vidurkio 0,5. Kvadratinė šaknis naudojama smulkesnėms nuotraukos dalims išryškinti.

10. *Tano ir Trigso* metodas apima keturis apšvietimo normalizacijos etapus. Pirmiausiai atliekama paprasta Gama korekcija – tamsios nuotraukos dalys pašviesinamos, šviesios nugesinamos. Toliau normalizuojami pilki lygiai. Taikant Gauso filtrą filtruojami aukštieji dažniai. Trečiame etape galima, tačiau neprivaloma, atlikti maskavimo procesą. Jo metu yra pašalinami pertekliniai veido požymiai, kurie neaktualūs atpažįstant. Galiausiai atliekamas globalus kontrastų išlyginimas – šiame etape nuotraukoje vis dar gali būti didelių triukšmo sričių (Tan, Triggs 2007). Lyginama taikant dviejų veiksmų aproksimaciją pagal (11) ir (12) formules:

$$I(x, y) = \frac{I(x, y)}{\left(\text{mean} \left(\left(I(x', y') \right)^a \right) \right)^{1/a}}, \quad (11)$$

$$I(x, y) = \frac{I(x, y)}{\left(\text{mean} \left(\min \left(\partial, \left(I(x', y') \right)^a \right) \right) \right)^{1/a}}. \quad (12)$$

Eksperimentų aprašymas

Eksperimentams atlikti buvo naudojama Vilniaus Gedimino technikos universiteto Multimedijos ir kompiuterinio dizaino mokymo laboratorijos veidų duomenų bazė, sukurta valdomoje aplinkoje. Ją sudaro 30-ies asmenų nuotraukos su 11 skirtingo apšvietimo variantų:

- visiška prieblanda;
- kairysis 30 laipsnių apšvietimas 100 %;
- kairysis 30 laipsnių apšvietimas 30 %;
- dešinysis 90 laipsnių apšvietimas 100 %;
- dešinysis 30 laipsnių apšvietimas 100 %;
- kairysis 30 laipsnių ir dešinysis 90 laipsnių apšvietimai 100 %;
- viršutinis kairysis ir dešinysis apšvietimai 100 %;
- viršutinis kairysis apšvietimas 100 %;
- viršutinis dešinysis apšvietimas 100 %;
- apatinis prožektoriaus apšvietimas ~90 laipsnių kampų (pridengtas);
- apatinis prožektoriaus apšvietimas ~70 laipsnių kampų (pridengtas).

Nuotraukų rinkinyje yra 12 moterų ir 18 vyrų atvaizdų. Visos nuotraukos frontaliaios, jose nėra pašalinių ar fono objektų, o fotografuojami subjektai nerodo emocijų. Iš viso vienam asmeniui priskiriamos 33 nuotraukos, po 3 kiekvienam apšvietimo variantui. Bendras nuotraukų kiekis – 990.

Pirmajame eksperimente buvo siekiama sumažinti nagrinėjamų algoritmų aibę. PCA, LDA ir LBP metodai buvo išmokyti naudojant 20 asmenų 2 geros kokybės nuotraukas, o testuoti pateikiamos 3 itin prastos kokybės veido nuotraukos, kuriose daug lokalių ir globalių šešėlių bei papildomo triukšmo. Apšvietimo normalizavimas atliktas pagal siūlomą metodiką, algoritmai pritaikyti principu – visi su visais. 1 lentelėje pateikiamas bendras PCA, LDA ir LBP algoritmų tikslumo koeficientas. Algoritmų numeracija atitinka jų aprašymo eiliškumą.

1 lentelė. Didelio ir mažo mastelio požymių regionų normalizavimo rezultatų lentelė

Table 1. Small and Large-scale feature region normalization result table

		Mažo mastelio požymių normalizavimo algoritmas (%)									
		1	2	3	4	5	6	7	8	9	10
Didelio mastelio požymių normalizavimo algoritmas (%)	1	44	46	47	44	50	47	43	43	44	43
	2	36	32	36	36	36	36	31	31	29	29
	3	48	42	27	39	35	26	49	51	50	54
	4	53	41	26	35	33	29	37	49	57	51
	5	50	43	55	64	44	48	54	54	64	54
	6	51	43	38	47	39	31	53	53	47	56
	7	25	26	39	44	42	41	19	35	30	16
	8	27	26	32	32	23	23	23	23	26	26
	9	26	23	35	40	33	36	36	29	16	24
	10	33	30	27	36	47	31	43	44	44	30

Antrajame eksperimente mokant veido atpažinimo metodus buvo panaudotos 22, o testuoti pateikiama 11 nuotraukų. Testuoti buvo atrinkti trys pirmoje eksperimento dalyje geriausias rezultatus pateikę algoritmų junginiai: 4–9; 5–4; 5–9. Toliau apskaičiuojamos siūlomų metodų klaidingo priėmimo (angl. *False positive* – FP) ir teisingo atpažinimo (angl. *True positive* – TP) vertės (2–4 lentelės). Pateikiamos šių verčių ROC kreivės (4–6 pav.). Rezultatų apibendrinimas pateiktas po grafikais.

2 lentelė. PCA, LDA ir LBP metodais įvertintos 4–9 algoritmų junginio TP ir FP vertės

Table 2. 4–9 algorithm combination TP and FP value evaluation based on PCA, LDA and LBP

	PCA 4–9, %		LDA 4–9, %		LBP 4–9, %	
	TP	FP	TP	FP	TP	FP
0	0	0	0	0	0	0
3	1	18	4	0	0	0
22	21	59	28	5	0	0
43	71	82	73	62	1	1
50	84	84	83	71	19	19
51	91	86	86	76	45	45
51	100	86	100	95	100	100

3 lentelė. PCA, LDA ir LBP metodais įvertintos 5–4 algoritmų junginio TP ir FP vertės


Table 3. 5–4 algorithm combination TP and FP value evaluation based on PCA, LDA and LBP

PCA 5–4, %		LDA 5–4, %		LBP 5–4, %	
TP	FP	TP	FP	TP	FP
1	0	8	0	0	0
5	0	45	1	9	0
21	12	76	21	63	2
47	42	87	58	71	20
60	68	92	82	73	45
78	84	92	91	78	58
78	100	92	100	93	94

4 lentelė. PCA, LDA ir LBP metodais įvertintos 5–9 algoritmų junginio TP ir FP vertės

Table 4. 5–9 algorithm combination TP and FP value evaluation based on PCA, LDA and LBP

PCA 5–9, %		LDA 5–9, %		LBP 5–9, %	
TP	FP	TP	FP	TP	FP
1	0	17	0	0	0
10	0	60	7	22	0
45	24	82	42	64	3
70	66	89	77	73	19
75	81	92	82	76	59
82	100	97	100	95	100




4 pav. PCA metodu gauti rezultatai. Taikant siūlomą apšvietimo normalizavimo metodą pagerinami nuotraukos atpažinimo koeficientai (linija 0_0), tačiau gautas rezultatas yra nepatenkinamas

Fig. 4. PCA results. The offered illumination normalization method improves overall recognition rate (line 0_0), but the result is not satisfactory


Išvados

1. Pirmojo testo metu patvirtinta hipotezė, kad atskiras didelio ir mažo mastelio požymių apšvietimo normalizavimas gali pagerinti veido atpažinimo koeficientą.
2. Pasiūlytu metodu gauti geriausi rezultatai atliekant LDA ir LBP analizes. Esant didžiausio jautrumo pa-



5 pav. LDA metodu gauti rezultatai. Taikant siūlomą metodą pagerinami nenormalizuotos nuotraukos atpažinimo koeficientai (linija 0_0). Geriausi rezultatai gaunami esant 5–4 ir 5–9 algoritmų junginio normalizacijai

Fig. 5. LDA results. The offered method improves overall recognition rate (line 0_0). The best results are given by 5–4 and 5–9 algorithm combinations



6 pav. LBP metodu gauti rezultatai. Taikant siūlomą metodą pagerinami nenormalizuotos nuotraukos atpažinimo koeficientai (linija 0_0). Geriausi rezultatai gaunami esant 5–9 algoritmų junginio normalizacijai

Fig. 6. LBP results. The offered method improves overall recognition rate (line 0_0). The best results are given by 5–9 algorithm combinations

rametrans, LBP atpažinimo koeficientas siekia 95 %, o LDA – 97 %. Atsižvelgiant į PCA ROC kreivę, taip pat matomas atpažinimo koeficiento pagerėjimas, tačiau gauti rezultatai yra ties spėliojimo riba arba žemiau jos.

3. Teisingo veido atpažinimo ir klaidingo priėmimo santykis, gautas taikant apšvietimo normalizavimo metodą, yra per mažas, kad būtų tinkamas taikyti apsaugos sistemose, tačiau pakankamas pramoginio turinio programoms įgyvendinti. Toliau testuojant algoritmą siūloma praplėsti mokymo duomenų bazę ir dirbti taikant LDA ir LBP analizės metodus.

Literatūra

- Leszczynski, M. 2010. Image preprocessing for illumination invariant face verification, *Journal of Telecommunications and Information Technology* 4: 19–25 [interaktyvus], [žiūrėta 2017 m. sausio 20 d.]. Prieiga per internetą: <http://www.nit.eu/czasopisma/JTIT/2010/4/19.pdf>
- Petro, A. B.; Sbert, C.; Morel, J. M. 2014. Multiscale Retinex, *Image Processing on Line* 4(2014): 71–18. <https://doi.org/10.5201/ipol.2014.107>
- Prabhakar, C. J.; Praveen Kumar, P. U. 2011. An image based technique for enhancement of underwater images, *International Journal of Machine Intelligence* 3(4): 217–224 [interaktyvus], [žiūrėta 2017 m. sausio 29 d.]. Prieiga per internetą: <https://arxiv.org/ftp/arxiv/papers/1212/1212.0291.pdf>
- Shan, S.; Gao, W.; Cao, B.; Zhao, D. 2003. Illumination normalization for robust face recognition against varying lighting conditions, in *Proceedings of the IEEE International Workshop on Analysis and Modeling of Faces and Gestures*, 17 October 2003, Nice, France, 157–164.
- Tan, X.; Triggs, B. 2007. Enhanced local texture feature sets for face recognition under difficult lighting conditions, *IEEE Transactions on Image Processing* 19(6): 1635–1650. https://doi.org/10.1007/978-3-540-75690-3_13
- Xie, X.; Zheng, W.; Lai, J.; Yuen, P. C.; Suen, C. Y. 2011. Normalization of face illumination based on large-and small-scale features, *IEEE Transactions on Image Processing* 20(7): 1807–1821. <https://doi.org/10.1109/TIP.2010.2097270>

ILLUMINATION NORMALIZATION ALGORITHM COMBINATION ANALYSIS IN FACE RECOGNITION

R. Semėnas

Abstract

Face recognition programs have many practical usages in various fields, such as security or entertainment. Existing recognition algorithms must deal with various real life problems – mainly with illumination. In practice, illumination normalization models are often used only for Small-scale features extraction, ignoring Large-scale features. In this article, new and more direct approach to this problem is offered, used algorithms and test results are given.

Keywords: illumination normalization, face recognition, small-scale features, large-scale features, PCA, LDA, LBP.