

VILNIAUS UNIVERSITETAS

JEVGENIJ TICHONOV

KLASIFIKAVIMO METODAIS GRINDŽIAMI SKAITMENINIŲ VAIZDŲ
GLAUDINIMO SPRENDIMAI

Daktaro disertacija

Technologijos mokslai, informatikos inžinerija (07 T)

Vilnius, 2018

Disertacija rengta 2013–2017 metais Vilniaus universitete.

Mokslinė vadovė

prof. dr. Olga Kurasova (Vilniaus universitetas, technologijos mokslai, informatikos inžinerija – 07 T).

PADĖKA

Nuoširdžiai dėkoju mokslinei vadovei prof. dr. Olgai Kurasovai už neįkainojamą pagalbą ruošiant šį darbą.

Dėkoju recenzentams doc. dr. Povilui Treigiui ir prof. dr. (HP) Sauliui Gudui už skirtą laiką ir vertingus patarimus.

Taip pat dėkoju draugams ir publikacijų bendraautoriams doc. dr. Ernestui Filatovui ir Vytautui Jakščiui už patarimus, palaikymą ir prasmingą bendravimą studijų procese.

Ačiū žmonai Kristinai, tėvams Liudmilai ir Kęstučiui, vaikams Darijai ir Artūriui už visapusišką palaikymą, kantrybę ir supratimą.

Nuoširdžiai dėkoju visam Vilniaus universiteto Duomenų mokslo ir skaitmeninių technologijų instituto Kognityvinių skaičiavimų grupės darbuotojams ir doktorantams už bendradarbiavimą.

SANTRAUKA

Disertacijoje nagrinėjamas vaizdų glaudinimas, kai gaunamo vaizdo kokybė vertinama objektyviais, palyginamaisiais kokybės vertinimo metodais. Darbe tiriami įvairūs vaizdai be specifinio turinio, gauti skirtingais skaitmeniniais fotoaparatais.

Disertacijoje pasiūlyta nauja skaitmeninių vaizdų grupių glaudinimo technologija, siekiant taupyti vaizdų užimamą vietą, bet išlaikant nustatytą jų kokybę. Taip pat darbe pristatyti ir ištirti du klasifikavimu grįsti būdai glaudinti vaizdus JPEG formatu, klasifikuojant saugomus vaizdus į dvi arba į tris klases prieš naudojant glaudinimo algoritmą. Šių būdų taikymas leidžia apdoroti dideles vaizdų grupes JPEG algoritmu taip, kad JPEG QF reikšmė būtų automatiškai parenkama kiekvienam vaizdui, atsižvelgiant į pageidaujamą vaizdo kokybę.

Siekiant sukurti minėtus vaizdų glaudinimo sprendimus, darbe nustatytas būdas apskaičiuoti ir atrinkti vaizdus apibūdinančius požymius, kurie turi būti naudojami kiek galima tiksliau klasifikuojant vaizdus pagal jų kokybę po apdorojimo glaudinimo algoritmais.

Pagrindiniai disertacijos rezultatai publikuoti 10 mokslinių leidinių: keturi darbai publikuoti periodiniuose, recenzuojamuose moksliniuose žurnaluose; vienas darbas publikuotas konferencijų recenzuojamame leidinyje; penki darbai paskelbti konferencijų santraukose. Šie rezultatai pristatyti šešiose tarptautinėse ir trijose nacionalinėse konferencijose.

Disertacijos apimtis 122 puslapiai, pateikti 35 paveikslėliai, 28 lentelės ir 38 formulės. Literatūros sąrašą sudaro 92 šaltiniai.

SUMMARY

In this thesis the universal technology for compression of groups of digital images is proposed, which allow saving space occupied by the images while maintaining the pre-defined quality. The main idea of the technology is: with the application of classification, possible impact of the compression algorithm on the quality of the image is predicted, where the quality is assessed by objective quality assessment methods. With the application of the proposed technology two classification-based approaches for the compression of images in the JPEG format by classifying stored images into two or three classes prior to the application of the compression algorithm are proposed and analysed in the thesis.

The approach for computing and selection of feature describing images, used for a maximally precise classification of images in accordance with their quality after they have been processed by compression algorithms, is defined in the thesis.

The main results of the dissertation were published in 10 research papers: four papers are published in periodicals, reviewed scientific journals, one paper are published in conference proceedings, and five papers are published in conference abstracts. The main results have been presented and discussed at three national and six international conferences.

Dissertation amount: 122 pages, 38 formulas, 35 figures, 28 tables and list of literature that contains 92 references.

Žymėjimai ir trumpiniai

CIQST – išmanioji kokybės pasirinkimo technika (angl. *Computational Intelligence-based Quality Selection Technique*).

DCT – diskreti kosinuso transformacija (angl. *Discrete Cosine Transform*).

IF – vizualinės atitikties matas (angl. *Image Fidelity*).

HVS – žmogaus regos sistema (angl. *Human Visual System*).

ISSIM – atvirkštinis struktūrinis panašumas (angl. *Inverse Structural Similarity*).

ITU – tarptautinė telekomunikacijų sąjunga (angl. *International Telecommunication Union*).

ITU-T – telekomunikacinio standartizavimo sektorius (angl. *Telecommunication Standardization, ITU-T*).

LDA – tiesinė diskriminantinė analizė (angl. *Linear Discriminant Analysis*).

MOS – vidutinis nuomonės įvertis (angl. *Mean Opinion Score*).

MSE – vidutinis kvadratinis nuokrypis (angl. *Mean Square Error*).

PQST – tiksli kokybės pasirinkimo technika (angl. *Precise Quality Selection Technique*).

PSNR – signalo atsako į triukšmą vertė (angl. *Peak Signal to Noise Ratio*).

QF – kokybės faktorius (angl. *Quality Factor*).

SSIM – struktūrinis panašumas (angl. *Structural Similarity*).

SSIM MAP – struktūrinio panašumo žemėlapis (angl. *Structural Similarity Map*).

STD – standartinis nuokrypis (angl. *Standard Deviation*).

SVM – atraminių vektorių klasifikatorius (angl. *Support Vector Machine*).

TURINYS

1. ĮVADAS	9
1.1 Darbo aktualumas	9
1.2 Tyrimo objektas.....	9
1.3 Darbo tikslas	9
1.4 Darbo uždaviniai	9
1.5 Problemos formulavimas	11
1.6 Autoriaus pozicija ir tyrimų metodika	12
1.7 Darbo mokslinis naujumas	14
1.8 Darbo rezultatų praktinė reikšmė.....	15
1.9 Ginamieji teiginiai.....	15
1.10 Darbo rezultatų aprobavimas	16
1.11 Disertacijos struktūra	18
2. VAIZDŲ KLASIFIKAVIMAS PAGAL GLAUDINIMO ALGORITMO POVEIKŲ JŲ KOKYBEI.....	21
2.1 Vaizdų glaudinimas JPEG algoritmu.....	21
2.2 Vaizdų kokybės vertinimas	27
2.2.1 PSNR.....	31
2.2.2 SSIM indekso metodas	32
2.3 Vaizdų klasifikavimas	36
2.3.1 Sprendimų medžiai.....	42
2.3.2 Tiesinė diskriminantinė analizė.....	43
2.3.3 Atraminių vektorių klasifikatorius	44
2.4 Vaizdų klasifikavimas, kai atsižvelgiama į vaizdų kokybę ...	46
2.5 Poskyrio išvados	49
3. VAIZDŲ KOKYBĖS EKSPERIMENTINIAI TYRIMAI	51
3.1 SSIM indekso metodo taikymas didelės raiškos vaizdams vertinti.....	51

3.1.1	Poskyrio išvados	59
3.2	JPEG algoritmo poveikis vaizdų kokybei.....	59
3.2.1	Poskyrio išvados	69
4.	SIŪLOMI VAIZDŲ GLAUDINIMO SPRENDIMAI	70
4.1	Vaizdų grupių glaudinimo JPEG algoritmu būdas, kai klasifikuojama į dvi klases	72
4.1.1	Siūlomo būdo tyrimas (klasifikuojama į dvi klases).....	73
4.1.2	Klasifikavimas	76
4.1.3	Standartinio JPEG algoritmo ir siūlomo būdo (klasifikuojama į dvi klases) palyginimas.....	78
4.1.4	Poskyrio išvados	80
4.2	Siūloma vaizdų glaudinimo technologija	80
4.3	Vaizdų grupių glaudinimo JPEG algoritmu būdas, kai klasifikuojama į tris klases.....	84
4.4	Siūlomo būdo tyrimas (klasifikavimas į tris klases)	86
4.4.1	Klasifikavimas	86
4.4.2	Požymių išskyrimas.....	89
4.4.3	Klasifikavimo rezultatai.....	92
4.4.4	Standartinio JPEG algoritmo ir siūlomo būdo (klasifikuojama į tris klases) palyginimas.....	94
4.4.5	Laiko sąnaudų analizė	102
4.4.6	Poskyrio išvados	107
5.	DISERTACIJOS APIBENDRINIMAS IR IŠVADOS	108
	Literatūra.....	110
	Autoriaus publikacijų sąrašas disertacijos tema	120

1. ĮVADAS

1.1 Darbo aktualumas

Šiuo metu neatsiejama gyvenimo ir mus supančio pasaulio dalis yra skaitmeniniai duomenys ir informacija. Skaitmeninių duomenų saugojimo, apdorojimo ir informacijos pateikimo uždaviniai šiandien yra itin aktualūs. Skaitmeniniai vaizdai – tai ypatinga informacija, kuri pateikiama (atvaizduojama) apdorojant specifinius duomenų rinkinius. Vaizdinės informacijos pateikimas ir saugojimas reikalauja didžiulių kompiuterinės įrangos resursų. Tam, kad būtų galima patenkinti vis didėjančius vartotojų poreikius, vaizdo fiksavimo ir jo atvaizdavimo įrangos kūrėjai stengiasi pateikti vis pažangesnius sprendimus, tačiau jie reikalauja dar didesnių resursų. Vienai šiuolaikiniu fotoaparatu padarytai nuotraukai saugoti reikia daugiau fizinės atminties nei visos knygos tekstui išsaugoti.

Kasdien interneto naudotojai į socialinių tinklų ir specializuotų skaitmeninių vaizdų duomenų saugyklų infrastruktūrą perduoda šimtus milijonų vaizdų. Naudojant interneto paieškos sistemas, galima nesunkiai rasti daugelio populiariausių socialinių tinklų skelbiamus duomenis apie jų valdomus vaizdų kiekius. Vien mobiliaisiais telefonais padarytų ir perduotų vaizdų kiekis skaičiuojamas trilijonais per metus. Nepaisant to, kad diskinė vieta ilgainiui pinga, perduodamų duomenų kiekiai auga sparčiau. Vis didėjantis perduodamų duomenų kiekis daro įtaką didesniai energijos sunaudojimui ir tai yra problema. Tinklo ir duomenų saugyklų infrastruktūros plėtimas, tobulinimas ir optimizavimas – tai tik viena iš priemonių problemai spręsti, todėl būtina kurti pažangesnius ir tobulinti jau esamus skaitmeninių vaizdų glaudinimo sprendimus. Jau kelis dešimtmečius skaitmeninių vaizdų duomenų glaudinimo, saugojimo ir pateikimo (atvaizdavimo) algoritmų kūrimas ir tobulinimas yra mokslinių tyrimų objektas. Vaizdų glaudinimo problemos, kai gautų vaizdų kokybė

vertinama objektyviais, palyginamaisiais kokybės vertinimo metodais, sprendžiamos ne viename moksliniame darbe (Forczmanski, 2014) (Coulombe, 2010) (Pigeon, 2012) (Kozhemiakin, 2017).

Šiame darbe nagrinėjami vaizdų glaudinimo sprendimai aktualūs ir taikytini įvairioms prieglobos ir debesijos paslaugoms, socialiniams tinklams, elektroninės komercijos platformoms ir pan.

1.2 Tyrimo objektas

Šio darbo tyrimo objektas yra įvairūs skaitmeniniai vaizdai ir šių vaizdų grupių glaudinimas, įvertinant saugojimo išteklius.

1.3 Darbo tikslas

Šio darbo tikslas – sukurti skaitmeninių vaizdų grupių glaudinimo technologiją, siekiant taupyti vaizdų užimamą vietą, tačiau išlaikant pageidaujamą kokybę.

1.4 Darbo uždaviniai

Darbo tikslui pasiekti išskelti šie uždaviniai:

1. Išanalizuoti esamus skaitmeninių vaizdų kokybės vertinimo metodus ir pritaikyti juos didelių¹ vaizdų kokybei įvertinti;
2. Išanalizuoti vaizdų požymių išskyrimo metodus ir nustatyti, kokie vaizdus apibūdinantys požymiai turi būti naudojami klasifikuojant šiuos vaizdus pagal jų kokybę;

¹ Subjektyvios vaizdų kokybės duomenų bazes (angl. *Subjective Image Quality Databases*), skirtas tirti objektyvius kokybės vertinimo metodus, sudaro mažos rezoliucijos testiniai vaizdai. Šiame darbe tiriami įvairūs, skaitmeniniais fotoaparatais gauti vaizdai. Darbe sąvoka „didelis vaizdas“ apibūdinama kaip skaitmeninis vaizdas, kurio dydis ne mažesnis nei 1024×768 taškų. Didesni nei 6144×4096 taškų dydžio vaizdai nėra nagrinėjami.

3. Sukurti vaizdų grupių glaudinimo technologiją, kurioje prieš vaizdų glaudinimą būtų taikomas vaizdų klasifikavimas, siekiant pagal klasifikavimo rezultatus parinkti tinkamiausią glaudinimo algoritmą;
4. Pritaikant pasiūlytą technologiją, sukurti ir iširti vaizdų glaudinimo JPEG algoritmu būdą, kuris leistų sutaupyti vaizdų užimamos vietos kiekį, lyginant su standartiniu JPEG algoritmu. Įvertinti siūlomą būdą laiko sąnaudų aspektu.

1.5 Problemos formulavimas

Dirbant su didelėmis vaizdų grupėmis, kaip ir su kitais dideliais duomenų rinkiniais, iškyla duomenų apdorojimo, perdavimo ir saugojimo problemos. Atsižvelgiant į tai, kad matomas vaizdas yra specifinis informacijos atvaizdavimas, o šį vaizdą žmonės suvokia subjektyviai, iškyla vaizdo kokybės vertinimo problema.

Disertacijoje tiriamos įvairių vaizdų grupės be specifinio turinio, gautos skirtingais skaitmeniniais fotoaparatais, todėl neįmanoma nustatyti glaudinimo algoritmų parametrų taip, kad jie keistų vaizdus tendencingai, atsižvelgiant į vaizdų kokybės vertinimo matavimus. Darbe parodyta, kad net tuo atveju, kai vaizdai fiksuojami tuo pačiu fotoaparatu su identiškais nustatymais, priklausomai nuo vaizdo scenos (matomo vaizdo), vaizdų kokybė nevienoda, kai jų kokybė vertinama skirtingais vaizdų kokybės vertinimo matais.

Kita problema yra ta, kad objektyvūs vaizdo kokybės vertinimo metodai kuriami atsižvelgiant į žmogaus matymo specifiką (ypatybes), o vaizdų glaudinimo metodai ir algoritmai su informacijos praradimu kuriami siekiant išsaugoti, atkurti, atvaizduoti kuo didesnę informacijos kiekį. Nėra tiesioginio ryšio tarp išsaugotos informacijos kiekio ir gauto vaizdo kokybės, kadangi tai skirtingos paradigmos. Šiuo metu kuriamos tam tikros glaudinimo algoritmų modifikacijos, siekiant, kad rezultatas

atitiktų tam tikrą kokybės matą, bet tai nėra universalu, nes rezultatas tenkina tik pasirinkto kokybės mato reikalavimus.

Iškeltam tikslui pasiekti darbe sprendžiama dar viena problema – siekiama nustatyti, kokie pradiniai vaizdus apibūdinantys požymiai turi / gali būti naudojami klasifikuojant šiuos vaizdus pagal jų kokybę po apdorojimo glaudinimo algoritmais.

Atsižvelgiant į tyrimo pobūdį, bendra problema nagrinėjama trimis aspektais: vaizdų glaudinimas; vaizdų kokybės vertinimas; vaizdų klasifikavimas.

Iškeltam tikslui pasiekti bei uždaviniams išspręsti nėra universalus veikimo modelio, todėl būtina pasitelkti tarpdalykinių sričių, tokių kaip duomenų tyryba (angl. *Data Mining*), kompiuterinė rega (angl. *Computer Vision*) ir kitų su informacijos pateikimu susijusių sričių žinias ir taikomus metodus.

1.6 Autoriaus pozicija ir tyrimų metodika

Disertacijos tikslas suformuotas atsižvelgiant į esamus, plačiai naudojamus skaitmeninių duomenų valdymo (apdorojimo, saugojimo, atvaizdavimo ir kt.) procesus. Darbe siekiama aiškių, pamatuojamų rezultatų, o siūlomi technologiniai sprendimai sukurti laikantis pragmatinio požiūrio, t. y. atsižvelgiant į šios dienos aktualius visuomenės įpročius (naudojimąsi socialiniais tinklais, debesijos sprendimais ir kt.) ir visuomenėje naudojamą technologijas (išmanūs telefonai, planšetiniai kompiuteriai ir kt.).

Moksliniu aspektu disertacijoje nepasirinkta principinė filosofinė pozicija, bet laikomasi kai kurių aiškių nuostatų:

- dirbama esamų mokslo paradigų rėmuose, neginčijami nusistovėję metodai. Tai ypač aktualu nagrinėjant subjektyvius dalykus, pavyzdžiui, kaip žmogus suvokia vaizdo kokybę;

- darbe keliamos prielaidos, hipotezės ir idėjos yra falsifikabilios ir grindžiamos empiriniais tyrimais. Siekiama gauti geresnius rezultatus už esamus pagal vieną arba kelis kriterijus.

Moksliniai pasiekimai vertinami informacijos paieškos, analizės, lyginamosios analizės, sisteminimo ir apibendrinimo būdu. Eksperimentinių tyrimų statistinė rezultatų analizė ir apibendrinimas atlikti remiantis eksperimentinio tyrimo metodu.

Iškeltam tikslui pasiekti darbe naudojamos skirtingų disciplinų žinios ir teorijos: kokybės vertinimo; duomenų klasifikavimo; skaitmeninių vaizdų tyrimo.

Vaizdo kokybės kiekybiniam (skaitiniam) suvokimui įvertinti naudojamas vidutinis nuomonės įvertis MOS (angl. *Mean Opinion Score*). Nagrinėjami ir naudojami objektyvūs, palyginamieji minėto įverčio metodai. Vaizdams klasifikuoti darbe naudojami klasifikavimo su mokymu metodai. Vaizdų analizė vykdoma kompiuterinės regos (angl. *Computer Vision*) paradigmos (kaip mokslo disciplinos) rėmuose. Parengtiniam vaizdų filtravimui ir tarpinių rezultatų apdorojimui naudojami vaizdų analizės (angl. *Image Analysis*) metodai. Vaizdus apibūdinančių požymių skaitinėms charakteristikoms nustatyti pasitelktos geometrinės transformacijos (angl. *Geometric Transformations*), vaizdo regionų savybės (angl. *Region and Image Properties*), vaizdo sandaros ir tekstūros analizė (angl. *Texture Analysis*). Atsižvelgiant į tai, kad tiriamos vaizdų grupės, kurių imtis nėra griežtai specifinė (naudojami įvairūs, skirtingais fotoaparatais gauti vaizdai), objektų analizės (angl. *Object Analysis*) metodai darbe nėra taikomi. Pagrindinės idėjos pateiktos modeliuotais procesais pagal veikseną.

1.7 Darbo mokslinis naujumas

Disertacijoje pasiūlyta skaitmeninių vaizdų grupių glaudinimo technologija, kuri gali būti naudojama kitų technologijų sukūrimui ir naujoms žinioms gauti. Šios technologijos pagrindu yra pasiūlytas būdas įvairių vaizdų, gautų skaitmeniniais fotoaparatais ir neturinčių specifinio turinio, grupėms glaudinti JPEG algoritmu, taupant vaizdų užimamą vietą, tačiau išlaikant nustatytą kokybę (kokybė vertinama objektyviais kokybės vertinimo matais).

Darbe iškelta ir patvirtinta hipotezė – naudojant klasifikavimą, kai klasifikatorius išmokytas atpažinti vaizdus pagal juos apibūdinančius požymius, galima numatyti, kaip glaudinimo algoritmas įtakos suglaudintus vaizdus, kai jie suskirstomi į klases pagal vaizdų kokybę, kas leistų sutaupyti vaizdų užimamą vietą. Disertacijoje į iškeltą duomenų saugojimo problemą, kai norima taupyti vaizdų užimamą vietą, žvelgiama naujaip – siekiama ne tobulinti esančius glaudinimo algoritmus, norint išsaugoti kuo daugiau informacijos apie vaizdą, o parinkti tinkamus algoritmų nustatymus skirtingoms vaizdų grupėms.

Disertacijoje pasiūlyti sprendimai ypatingi tuo, kad po glaudinimo gauti vaizdai atitinka pasirinktą kokybės slenkstį (gautų vaizdų kokybė ne mažesnė, nei nustatyta kokybės mato reikšmė), nors glaudinimo procese vaizdų kokybė, priešingai nei daroma kitų autorių darbuose, nevertinama. Vaizdų klasifikavimas prieš parenkant glaudinimo algoritmą naudingas dar ir tuo, kad glaudinimo algoritmas su reikiamais nustatymais vienam vaizdai naudojamas vieną kartą.

Pasiekti geriausią sprendimą (visų gautų vaizdų kokybė lygi pasirinktam kokybės matui), kai tinkamas algoritmas būtų parenkamas kiekvienam vaizdai, galima patikrinant kiekvieną vaizdą kokybės vertinimo matu, bet tai labai imlus laikui procesas. Disertacijoje pasiūlytas kompromisas tarp minėto sprendimo ir įprasto, kai visiems vaizdams taikomas vienas glaudinimo algoritmas.

Tyrimų rezultatai parodė, kad pasiūlyti sprendimai turi perspektyvą tais atvejais, kai norima gauti ne mažesnę kokybės reikšmę už nustatytą kokybės slenkstį kiekvienam nagrinėjamos vaizdų grupės vaizdui. Pasiūlyti sprendimai, kai išmaniuoju būdu nustatoma (angl. *Intelligence-based Approach*) kaip algoritmas įtakos vaizdą yra ypač aktualūs, kai saugomos didelės vaizdų grupės.

1.8 Darbo rezultatų praktinė reikšmė

Disertacijoje pasiūlyta technologija ir šia technologija grįstas būdas vaizdų grupėms apdoroti JPEG algoritmu ir joms išsaugoti, sutaupant vaizdų užimamą vietą, bet išlaikant nustatytą kokybę. Atsižvelgiant į tai, kad didžioji dalis fototechnikos gamintojų bei vartotojų „de-facto“ naudoja JPEG glaudinimo algoritmą ir vaizdų formatą, toks sprendimas yra aktualus socialiniams tinklams, įvairioms prieglobos ir debesijos paslaugoms, elektroninės komercijos platformoms ir pan. Disertacijoje pasiūlytas vaizdų glaudinimo būdas aukščiau išvardintoms paslaugoms teikti gali būti naudojamas be papildomų modifikavimų. Apmokytas klasifikatorius gali būti naudojamas neapibrėžtą laiko tarpą be papildomo permokymo.

Disertacijoje pasiūlyta technologija gali būti naudojama kitų technologijų sukūrimui ir naujoms žinioms gauti. Šios technologijos taikymas gali būti naudingas darbui su specifinio turinio vaizdais: medicininiais vaizdais; palydoviniais vaizdais; įvairia specifinės vaizdo fiksavimo technika gautais vaizdais ir pan.

1.9 Ginamieji teiginiai

1. Darbe nustatytas būdas apskaičiuoti ir atrinkti vaizdus apibūdinančius požymius, kurie turi būti naudojami kiek

galima tiksliau klasifikuojant vaizdus pagal jų kokybę po apdorojimo glaudinimo algoritmais.

2. Darbe pasiūlyta universali skaitmeninių vaizdų grupių glaudinimo technologija taupo vaizdų užimamą vietą, išlaikant nustatytą kokybę. Pagrindinė technologijos idėja – naudojant klasifikavimą numatyti, kaip glaudinimo algoritmas įtakos vaizdo kokybę, kai kokybė vertinama objektyviais kokybės vertinimo metodais.
3. Darbe pasiūlytas būdas įvairių vaizdų (gautų skaitmeniniais fotoaparatais) grupėms apdoroti JPEG algoritmu, sutaupo daugiau nei 20 % vaizdų užimamos vietos, išlaikant nustatytą kokybę. Vaizdų kokybė vertinama SSIM indekso ir PSNR matais.

1.10 Darbo rezultatų aprobavimas

Disertacijoje pateiktų tyrimų rezultatai publikuoti 4 periodiniuose moksliniuose leidiniuose:

1. Tichonov J., Kurasova O., Classification of Large Images Before Applying Compression Algorithms, *Journal of Young Scientists*, 2015, Vol. 1(43): 87–94.
2. Tichonov J., Kurasova, O., Filatovas, E., Vaizdų klasifikavimas pagal suspaudimo algoritmo poveikį jų kokybei, *Informacijos mokslai*, 2015, Vol. 73: 127–134.
3. Petkus T., Tichonov J., Filatovas E., Jakštys V., Quality Assessment of High-Resolution Images with Small Distortions after Compression, *Baltic Journal of Modern Computing*, 2017, Vol. 5 (32): 206–220.
4. Tichonov J., Kurasova O., Filatovas E., Image Classification for JPEG Compression, *Advances in Science and Technology Research Journal*, ISSN: 2299-8624 (priimtas 2018-03-19).

Darbas publikuotas konferencijų medžiagoje (angl. *Proceedings*), esančioje *Clarivate Analytics Web of Science* duomenų bazėje:

1. Tichonov J., Kurasova O., Filatovas E., Quality Prediction of Compressed Images via Classification, *Image Processing and Communications Challenges 8*, Springer International Publishing, 2017, Vol. 525, 35–42.

Tyrimų rezultatai buvo pristatyti šiose nacionalinėse ir tarptautinėse konferencijose:

1. SSIM metodo taikymas didelių vaizdų vertinimui, 4-oji LMA jaunųjų mokslininkų konferencija „Fizinių ir technologijos mokslų tarpdalykiniai tyrimai“, Vilnius, 2014 vasario mėn. 20 d.
2. The SSIM Index Method in Quality Assessment of Large Images, 3-oji IEEE tarptautinė VGTU rengiama konferencija „Bio-Inspired Signal and Image Processing“, Vilnius, 2014 gegužės mėn. 5 d.
3. Didelių vaizdų klasifikavimas prieš taikant suspaudimo algoritmus, 6-oji Lietuvos jaunųjų mokslininkų konferencija „Operacijų tyrimas ir taikymas“, Vilnius, 2014 rugsėjo mėn. 22 d.
4. Classification of Large Images before Applying Compression Algorithm, 6-oji tarptautinė mokslinė konferencija „Data Analysis Methods for Software Systems“, Druskininkai, 2014 gruodžio mėn. 4–6 d.
5. Vaizdų klasifikavimas pagal suspaudimo algoritmo poveikį jų kokybei, 17-oji kompiuterininkų konferencija „Kompiuterininkų dienos 2015“, Panevėžys, 2015 rugsėjo mėn. 17–19 d.
6. Image Classification for Quality Prediction after JPEG Compression, 7-oji tarptautinė mokslinė konferencija „Data

Analysis Methods for Software Systems“, Druskininkai, 2015 gruodžio mėn. 3–5 d.


7. Decision Tree Classification to Predict Effect of JPEG Compression on Images, EURO 2016, 28th European Conference on Operational Research, July 3–6, 2016, Poznan, Poland.
8. Quality Prediction of Compressed Images via Classification, IP&C 2016, 8th International Conference on Image Processing & Communications, September 7-9, 2016, Bydgoszcz, Poland.
9. Classification-Based Storage of JPEG Images, 8-oji tarptautinė mokslinė konferencija „Data Analysis Methods for Software Systems“, Druskininkai, 2016 gruodžio mėn. 1-3 d.

1.11 Disertacijos struktūra

Disertaciją sudaro 5 skyriai. Pirmasis, įvadinis disertacijos skyrius skirtas pristatyti mokslinio darbo kryptis, aktualumą, tikslą ir uždavinius. Antrajame skyriuje pateikta darbui aktualių mokslinių darbų ir metodų apžvalga. Trečiajame skyriuje pristatomi autoriaus atlikti eksperimentiniai tyrimai, pagrindžiantys disertacijos uždavinius:

- nustatytos problemos, susijusios su Struktūrinio panašumo indekso taikymu didelės raiškos vaizdų kokybei vertinti, pasiūlyti sprendimai.
- parodyta, kad spaudžiant skirtingus vaizdus JPEG algoritmu su vienodu glaudinimo faktoriumi, gaunamas skirtingas glaudinimo efektyvumas ir kokybė.

Ketvirtasis skyrius skirtas aprašyti autoriaus pristatomus vaizdų glaudinimo sprendimus ir lyginamuosius tyrimus. Disertacijos apibendrinimas ir išvados pateikti penktajame skyriuje. Darbo struktūrinė schema pateikta 1 pav.



1 pav. Disertacijos schema

Schemoje mėlynai išskirtos dalys, kuriose pateiktas asmeninis autoriaus indėlis, siekiant užsibrėžto disertacijos tikslo ir sprendžiant iškeltus uždavinius. Taip pat disertacijoje pateiktas žymėjimų ir trumpinių sąrašas. Disertacijos apimtis 122 puslapiai, pateikti 35 paveikslėliai, 28 lentelės ir 38 formulės. Literatūros sąrašą sudaro 92 šaltiniai.

2. VAIZDŲ KLASIFIKAVIMAS PAGAL GLAUDINIMO ALGORITMO POVEIKŲ JŲ KOKYBEI

2.1 Vaizdų glaudinimas JPEG algoritmu

Šiuo metu visuotinai naudojamas vaizdų glaudinimo JPEG standartas bei jo baziniai veikimo ir sandaros principai pasiūlyti jau seniai (Wallace, 1992), nepaisant to, šis standartas išlieka populiariausiu vaizdų glaudinimo algoritmu. 1986 metais Tarptautinė standartizacijos organizacija (ISO) ir Tarptautinė elektrotechnikos komisija (IEC) įsteigė darbo grupę – ISO/IECJTC1/SC29/WG1, kurią sudarė pripažinti fotografijos ekspertai iš viso pasaulio. Tuo metu atsirado akronimas – JPEG, kuris yra Jungtinės fotografijos ekspertų grupės (angl. *Joint Photographic Experts Group*) trumpinys. Šiuo metu ši grupė turi pavadinimą – JPEG komitetas (angl. *JPEG Committee*) (JPEG, 2017).

Algoritmo pagrindas yra diskreti kosinuso transformacija (angl. *Discrete Cosine Transform, DCT*) (Rao, 1990), kuri taikoma nepersidengiančių 8×8 pikselių vaizdo blokų matricai. DCT išdėsto šiuos blokus pagal tam tikrų dažnių amplitudes (parodyta žemiau pateiktame pavyzdyje). Rezultatas yra matrica, kurioje daug artimų nuliui koeficientų, kuriuos galima atstatyti be didesnių informacijos praradimų.

Žemiau JPEG algoritmas apžvelgiamas išsamiau. Tarkime, kad spaudžiamas *RGB* (Hunt, 2004) spalvotas 24 bitų (3 kanalai po 8 bitus) vaizdas:

1. Vaizdo spalvinė erdvė iš *RGB* keičiama į *YCbCr* (Hunt, 2004) pagal išraišką:

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ 0,5 & -0,4187 & -0,0813 \\ 0,1687 & -0,3313 & 0,5 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} + \begin{bmatrix} 0 \\ 128 \\ 128 \end{bmatrix}. \quad (1)$$

2. Vaizdas skirstomas į blokus 8×8 kiekvienai komponentei YCbCr.
3. Blokams yra taikomas DCT. Formaliai DCT kiekvienam 8×8 blokui gali būti užrašomas taip:

$$D(u, v) = \frac{1}{4} \sum_{i=0}^7 \sum_{j=0}^7 A(u)A(v)X(i, j) \cos\left(\frac{\pi(i+0,5)}{8} u\right) \cos\left(\frac{\pi(j+0,5)}{8} v\right), \quad (2)$$

čia

$$A(x) = \begin{cases} \frac{1}{\sqrt{2}}, & x = 0 \\ 1, & x \neq 0 \end{cases}. \quad (3)$$

Atsižvelgiant į tai, kad DCT yra JPEG pagrindas, ji turi būti paskaičiuojama kaip galima greičiau, todėl aukščiau pateiktą išraišką galima užrašyti taip:

$$D(u, v) = \underbrace{\frac{1}{4} \sum_{i=0}^7 \underbrace{A(u) \cos\left(\frac{\pi(i+0,5)}{8} u\right)}_{C(i,u)}}_C X(i, j) \underbrace{\sum_{j=0}^7 \underbrace{A(v) \cos\left(\frac{\pi(j+0,5)}{8} v\right)}_{C(j,v)}}_{C^T}. \quad (4)$$

Čia C yra 8×8 elementų dydžio matrica, aprašanti aštuonmatę erdvę (bloko X stulpelių išraiška šioje erdvėje). C^T yra transponuota matrica C, nusakanti X eilutes. Gautą rezultatą matricos forma galima užrašyti taip:

$$D = CXC^T. \quad (5)$$

Čia D – DCT rezultatas, kurio apskaičiavimui reikia $2 \cdot 8 \cdot 64 = 1024$ daugybos ir tiek pat sudėties veiksmų, o tai

yra mažiau nei skaičiuojant tiesiogiai pagal formulę (4). Pavyzdžiui, 512×512 dydžio vaizdo glaudinimui reikia $64 \cdot 64 \cdot 1024 = 4194304$ aritmetinių operacijų. Atsižvelgiant į tris spalvines komponentes, gauname 12582912 aritmetines operacijas. Daugybės ir sudėties operacijų skaičius gali būti dar labiau sumažintas, naudojant spartųjį Furje transformacijos algoritmą (Parker, 2010). Taigi, vieno 8×8 bloko pertvarkai reikės atlikti 54 daugybos ir 468 sudėties operacijas.

DCT rezultatas – D matrica, kurioje viršutiniojo kairiojo kampo koeficientai atitinka žemo dažnio komponentus vaizde, o apatiniame dešiniajame kampe – aukšto dažnio. Šie komponentai taip pat gali būti išdėstomi matricos centre.

4. Kvantavimas. Šiame etape „išmetama“ dalis informacijos. Čia kiekvienas matricos D elementas dalomas iš tam tikro skaičiaus iš „kvantavimo lentelės“, o rezultatas apvalinamas iki sveiko skaičiaus:

$$D^q(u, v) = \text{Round} \left(\frac{D(u, v)}{q(u, v)} \right). \quad (6)$$

Kiekvienai spalvinės komponentės matricai Y, Cb ir Cr galima sudaryti skirtingas kvantavimo lenteles. Pvz., turint DC koeficientą – 415,37 ir kvantavimo koeficientą – 16, gauname rezultatą $\text{Round} \left(\frac{415,37}{16} \right) = \text{Round}(25,96) = 26$. JPEG standartas numato dvi rekomenduojamas kvantavimo lenteles Q: šviesumui ir spalvingumui. Jos gali būti apskaičiuojamos naudojant naudotojo laisvai pasirinkamą parametą R pagal formulę:

$$Q(i, j) = 1 + (i + j)R. \quad (7)$$

Taip pat galima naudoti tipines lenteles. Tipinės kvantavimo lentelės, nurodytos JPEG standarte (50 % kokybės), pateikiamos žemiau:

Šviesumui –

16	11	10	16	24	40	51	61	
12	12	14	19	26	58	60	55	
14	13	16	24	40	57	69	56	
14	17	22	29	51	87	80	62	
18	22	37	56	58	109	103	77	
24	35	55	64	81	104	113	92	
49	64	78	87	103	121	120	101	
72	92	95	98	112	100	103	99	

Spalvingumui –

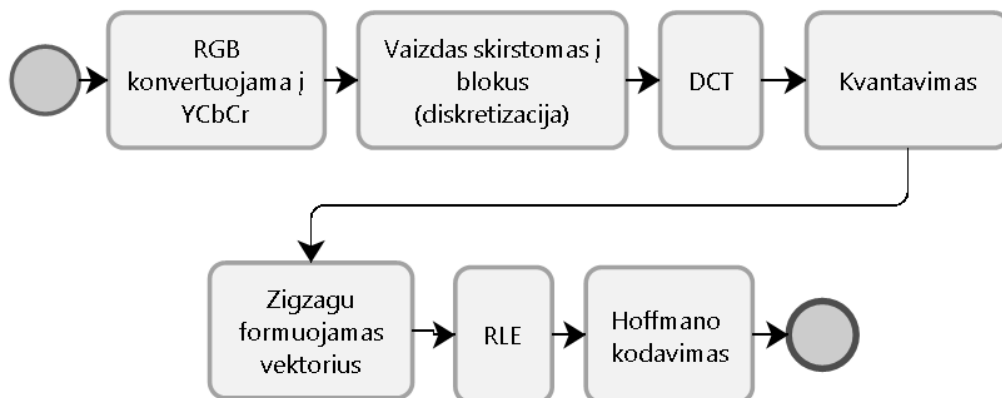
17	18	24	47	99	99	99	99	
18	21	26	66	99	99	99	99	
24	26	56	99	99	99	99	99	
47	66	99	99	99	99	99	99	
99	99	99	99	99	99	99	99	
99	99	99	99	99	99	99	99	
99	99	99	99	99	99	99	99	
99	99	99	99	99	99	99	99	

Glaudinimo laipsnis (stiprumas) apsprendžiamas kvantavimo etape, tuo metu ir atsiranda didžiausi praradimai. Naudojant kvantavimo lenteles su dideliais koeficientais, gaunama daugiau nulių ir, atitinkamai, gaunamas didesnis glaudinimo laipsnis.

Su kvantavimu susijusios ir kitos specifinės algoritmo įtakos vaizdui. Esant dideliame kvantavimo žingsniui, praradimai gali būti tokie dideli, kad vaizdas bus suskirstytas į monochromatinius (vienatonių) 8×8 kvadratus. Taip pat gali

7. JPEG dažniausiai naudojamas Huffmano kodavimas (Huffman, 1962), (Abrahams, 1997). Šiuo būdu simboliai konvertuojami į duomenų srautą. Huffmano kodavimui reikalingos Huffmano kodų lentelės (skirtingos DC ir AC koeficientams). Tos pačios lentelės reikalingos ir vaizdo dekodavimui. Huffmano lentelės gali būti iš anksto apibrėžtos ir naudojamos algoritme kaip numatytasis parametras arba apskaičiuojamos konkrečiai tam tikram vaizdui pradinio duomenų apdorojimo etape.

JPEG algoritmo procesas pateiktas 3 pav. Atkreiptinas dėmesys, kad vaizdo atstatymas yra simetriškas aukščiau aprašytam procesui.



3 pav. JPEG algoritmo procesas

Vaizdų glaudinimo algoritmų, kuriuose naudojama diskreti kosinuso transformacija (DCT), principai pateikti darbe (Watson, 1994). Yra nemažai tyrimų, skirtų JPEG standarto analizei, kuriuose nagrinėjamos skirtingos glaudinimo nuostatos, spaudžiant skirtingus vaizdus. Pavyzdžiui, yra parodyta, kad spaudžiant skirtingus vaizdus JPEG algoritmu su vienodu glaudinimo faktoriumi, gaunamas skirtingas glaudinimo efektyvumas (Viraktamath, 2011), taip pat skirtinga suspaustų vaizdų kokybė [1 A]. Glaudinimo efektyvumui nustatyti vertinama, koks

yra sumažinto vaizdo užimamos vietos kiekis ir kiek pasikeitė pradinis vaizdas po glaudinimo. Susijusių eksperimentinių tyrimų rezultatai pateikti 3.2. poskyryje. Pradinio vaizdo pasikeitimas darbe (Viraktamath, 2011) vertinamas šiais būdais: CR (angl. *Compression Ratio*), SNR (angl. *Signal to Noise Ratio*), PSNR (angl. *Peak Signal to Noise Ratio*) ir MSE (angl. *Mean Square Error*) (Salomon, 2013). Plačiau pradinio bei iškraipyto vaizdo skirtumų vertinimas aprašytas 2.2 poskyryje. Daug darbų yra skirtų JPEG algoritmo modifikacijoms tarpusavyje palyginti (Haseeb, 2006) (Sokolov, 2016) (Chouhan, 2016). JPEG standartą įgyvendinantys glaudinimo algoritmai leidžia varijuoti daugeliu algoritmo nuostatų. Pavyzdžiui, JPEG procedūrose galima keisti spalvų imtį, taikyti skirtingus DCT metodus, mažinti informacijos apie spalvas kiekį (po spalvinės erdvės RGB pertvarkos į YCbCr, spalvos kanalai Cb ir Cr gali būti „praretinti“ (angl. *subsampling*), naudoti Hoffmano optimizaciją, progresinę saugojimą ir kt. Keičiant nuostatų reikšmes, galima gauti daug įvairių rezultatų, turinčių skirtingas charakteristikas. Pagrindinė ir svarbiausia nuostata, įtakoianti vaizdo kokybę po glaudinimo, yra kokybės faktorius (angl. *Quality Factor*, QF), kuris nustato glaudinimo laipsnį (stiprumą). Tai sveikas skaičius tarp 0 ir 100, naudojamas kvantavimo lentelei (matricai) parametrizuoti ir kuo jis didesnis, tuo mažiau informacijos prarandama, o tai tiesiogiai veikia gauto vaizdo kokybę.

2.2 Vaizdų kokybės vertinimas

Įprastai suspaudžiant vaizdus, sumažėja ne tik jų dydžiai, bet ir kokybė. Vaizdo dydį galima išmatuoti užimamų baitų skaičiumi, tačiau kokybės išmatavimas nėra trivialus dalykas. Vaizdo kokybės kiekybiniam (skaitiniam) suvokimui „de-facto“ naudojamas vidutinės nuomonės įvertis MOS (angl. *Mean Opinion Score*) (Strejil, 2016). Šį įvertį yra standartizavusi tarptautinė telekomunikacijų sąjunga (angl. *International Telecommunication Union*, ITU), telekomunikacinio standartizavimo

sektorius (angl. *Telecommunication Standardization*, ITU-T). MOS gali būti subjektyvus ir objektyvus.

Vaizdo kokybė gali būti vertinama subjektyviai (angl. *Subjective MOS*), remiantis žmonių, iš kurių vieni gali būti ekspertai, t. y. išmanantys vaizdų glaudinimo technikas, kiti – neturintys specifinių žinių apie vaizdų iškreipimus, nuomone. Tiek vieni, tiek kiti dalyvauja vaizdų vertinimo procese, kai vaizdai pateikiami su tam tikra specifika. ITU-T rekomendacijose pateikti tokie metodai:

- Absoliutus kategorijos vertinimo metodas (angl. *Absolute Category Rating Method*) yra toks vertinimas, kai bandymo (vertinimo) sekos elementai pateikiami po vieną ir nepriklausomai įvertinami pagal kategorijos skalę (penkių lygių įvertinimų skalė: puiku; gerai; vidutiniškai; blogai; labai blogai). Šis metodas taip pat vadinamas pavienio vertinimo metodu (angl. *Single Stimulus Method*);
- Kategorijos vertinimo pagal informacijos praradimą / iškreipimą metodas (angl. *Degradation Category Rating Method*) yra toks vertinimas, kai bandymo (vertinimo) sekos elementai pateikiami poromis: pirmasis elementas yra pradinis (originalus), o antrasis elementas yra tas pats pradinis elementas su informacijos praradimais / pakeitimais / iškreipimais. Antrojo elemento informacijos praradimas / pakeitimas / iškreipimas įvertinamas pagal kategorijos skalę (penkių lygių įvertinimų skalė: nežymus; pastebimas, bet neerzinantis; nežymiai erzinantis; erzinantis; labai erzinantis). Šis metodas dar vadinamas dviejų elementų suporavimo vertinimo metodu (angl. *Double Stimulus Impairment Scale Method*);
- Porų sulyginimo metodas (angl. *Method of Pair Comparisons*) yra toks vertinimas, kai bandymo (vertinimo) elementai iš tos

pačios sekos pakeisti / iškraipyti vienokiu būdu, po to kitokiu ir t.t. Rezultatai (A, B, C ir t.t.) kombinuojami tarpusavyje visomis įmanomomis $n(n - 1)$ kombinacijomis AB, BA, AC ir t.t. Rezultatų poros turi būti pateikiamos abejomis eilės tvarkomis (pvz., AB, BA). Po kiekvieno palyginimo fiksuojama, kuris elementas yra labiau pageidaujamas pateiktoje poroje.

Gauti rezultatai pateikiami kartu su eksperimento detalėmis. Kiekvienam testo kintamųjų deriniui pateikiamas vertinimo balų statistinio pasiskirstymo vidurkis ir standartinis nuokrypis.

Toks vertinimas gerai parodo, kaip iškraipymai paveikia vaizdą, bet šis kokybės vertinimo būdas turi neigiamų aspektų: stebėtojas, žvelgdamas į pateiktą vaizdą, negali įvertinti jo dydžio, rezoliucijos; stebėtojų motyvacija yra subjektyvi; vaizdo pateikimą veikia apšvietimas, ekrano kokybė ir pan. (Eskicioglu, 2000). Be to, šis kokybės vertinimo būdas labai brangus ir lėtas (Cadik, 2004).

Automatiniai algoritmai, kuriais vertinami vaizdo iškraipymai, vadinami objektyviais kokybės vertinimo matais arba objektyviu MOS (angl. *Objective or Predicted MOS*). Kuriant arba plėtojant objektyvius kokybės vertinimo matus, stengiamasi pasiekti kuo didesnę mato koreliaciją su subjektyviu MOS.

Objektyvius kokybės vertinimo matus galima skirstyti į tris kategorijas (Moorthy, 2011) (ITU, 2001):

- absoliutūs, aklieji algoritmai (angl. *No-Reference (NR) / Blind Approaches*), skirti vertinti vaizdo kokybę, kai nėra pradinio vaizdo, su kuriuo galima būtų palyginti;
- dalinio palyginimo, kai iškraipytas vaizdas vertinamas turint dalį informacijos apie pradinį vaizdą (angl. *Reduced-Reference*);

- palyginamieji, kai iškraipytas vaizdas yra lyginamas su pradiniu vaizdu (angl. *Full-Reference*).

Pastaruosius kelis dešimtmečius daug dėmesio skirta objektyviems kokybės vertinimo metodams (matams) plėtoti. Buvo sukurta bei patobulinta nemažai metodų, kurie atsižvelgia į vienokias ar kitokias žmogaus regėjimo ypatybes, kitaip vadinamas žmogaus regos sistema (angl. *Human Visual System, HVS*) (Mrinal, 2003). Problema yra ta, kad HVS negali būti formaliai apibrėžta ir suformuluota, kadangi ji nėra iki galo ištirta (Wang, 2002). Dėl anksčiau išvardintų priežasčių dauguma objektyvių vertinimo metodų yra euristiniai, bet juose naudojamos formuluotės priimamos kaip aksiomos.

Norint įvertinti gauto rodiklio atitikimą žmogaus suvokimui, kuriamos testinių vaizdų duomenų bazės. Išsamus tokių bazių tyrimas pateiktas (Winkler, 2012) (Chandler, 2013). Šios duomenų bazės turi etaloninius vaizdus bei vaizdus, iškraipytus įvairiais triukšmais, taip pat kiekvieno vaizdo vidutinės ekspertų nuomonės MOS reikšmes (Ponomarenko, 2009). Pavyzdžiui, viena didžiausių duomenų bazių „TID2013“ (Ponomarenko, 2013) turi 1700 iškraipytų vaizdų, kur kiekvienam etaloniniam vaizdui gauti 68 iškraipyti vaizdai (keturi lygiai kiekvienam iš septyniolikos rūšių iškraipymų). Iš viso penkiose šalyse (Ukrainoje, Suomijoje, Prancūzijoje, JAV ir Italijoje) buvo atlikti 985 vertinimai.

Šiuo metu yra pasiūlyti įvairūs skaitiniai matai (Streijl, 2016) (Eskicioglu, 2000), iš kurių populiariausi yra MSE, PSNR (Salomon, 2013), SSIM (angl. *Structural Similarity*) indekso metodas (Wang, 2004) ir jų modifikacijos. Išsamios objektyvių kokybės metodų apžvalgos pateiktos (Thung, 2009), (George, 2014), (Joy K., 2014).

2.2.1 PSNR

PSNR tiesiogiai priklauso nuo MSE, jis vertina didžiausią galimą skirtumą tarp pradinio ir suspausto vaizdo. MSE – tai pradinio ir suspausto vaizdo pikselių skirtumų kvadratų vidurkis.

Tegul X ir Y yra $m \times n$ dydžio vaizdai, kur vaizdas Y yra vaizdo X kopija su triukšmais. MAX_X – maksimali pikselio priimama reikšmė, kai pikselis koduojamas 8 bitais, $MAX_X = 255$. Kitaip tariant, kai B – bitai, $MAX_X = 2^B - 1$. PSNR apskaičiuojamas pagal formulę:

$$PSNR = 10 \log_{10} \left(\frac{MAX_X^2}{MSE} \right) = 20 \log_{10} \left(\frac{MAX_X}{\sqrt{MSE}} \right), \quad (8)$$

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} |X(i, j) - Y(i, j)|^2. \quad (9)$$

Kuo mažesnis skirtumas tarp dviejų vaizdų, tuo mažesnis kvadratinis nuokrypis MSE, o tai reiškia, kad PSNR yra didesnis. Logaritmo naudojimas padaro gaunamas reikšmes ne tokias jautrias triukšmams. Šis rodiklis iš esmės neturi kokybės gerumo mato, nes tiek vardiklis, tiek skaitiklis priklauso nuo pikselių galimų reikšmių kiekio. Dėl logaritmo naudojimo PSNR rodiklis matuojamas decibelais (dB).

Dažniausiai PSNR reikšmė kinta tarp 20 ir 50 dB. Kai pikselių reikšmės yra intervale $[0, 255]$, tai esant MSE lygiam 25,5, gaunamas PSNR lygus 20, o esant MSE lygiam 2,55, gaunamas PSNR = 40. Jeigu lyginami vaizdai yra lygūs, PSNR reikšmė bus lygi begalybei. Jeigu MSE bus lygus 255, PSNR bus lygus 0.

Šis rodiklis yra iš esmės panašus į vidutinį kvadratinį nuokrypį, tačiau jį yra patogiau naudoti dėl logaritminės skalės, nes dauguma signalų turi labai platų dinaminį diapazoną. Atkreiptinas dėmesys, jog visi kvadratinio nuokrypio trūkumai yra būdingi ir PSNR, o maža MSE ir didelė

PSNR reikšmės ne visada reiškia aukštą suspausto vaizdo kokybę (Hore, 2010) (Martinez-Rach, 2014).

2.2.2 SSIM indekso metodas

Struktūrinio panašumo indekso metodą 2004 metais pristatė keturių mokslininkų komanda – Zhou Wangas ir Eer P. Simoncelli iš Teksaso universiteto bei Alanas C. Bovikas ir Hamidas R. Sheikhas iš Niujorko universiteto. Šis metodas nagrinėtas 2013 metų disertanto magistriniame darbe „SSIM metodo taikymas didelių vaizdų analizei“ (Tichonov, 2013);

SSIM indekso metodas naudojamas vaizdų kokybei vertinti, vaizdams apdoroti (Russ, 2011), taip pat vaizdų klasifikavimui (Gao, 2011), vaizdų atstatymui (Piella, 2003), (Rehman, 2012), triukšmui optimizuoti (Huang, 2010).

SSIM indekso metodu gaunamas rodiklis gerai atspindi žmogaus vaizdo suvokimo ypatybes, lyginant su kitais populiariais matais (Wang, 2009), (Ponomarenko, 2009), (Ponomarenko, 2009a). Daugeliu vaizdų iškraipymų atvejų SSIM indekso metodo pagrindu sukurtais algoritmais gaunamos reikšmės labai gera koreliuoja su HVS (HVS reikšmė gaunama nustatant koreliacijos koeficientą tarp subjektyvaus MOS ir „idealaus“ MOS, kai eksperimentų kiekis artėja į begalybę), lyginant su kitais populiariausiais metodais.

Tarkime yra du vaizdo signalai X ir Y . Jeigu vienas iš vaizdų yra nepriekaištingos kokybės, tada panašumas gali būti naudojamas kaip kiekybinis kokybės matas.

Kokybės pakitimo užduotis skirstoma į tris palyginimus – ryškumo, kontrasto bei struktūros, darant prielaidą, jog diskretiniai signalai vidutinio intensyvumo. Palyginimo komponentės skaičiuojamos pikselių skaičiui N .

Pirma komponentė – ryškumo palyginimo funkcija $l(X, Y)$ yra funkcija pagal μ_X ir μ_Y :

$$\mu_X = \bar{X} = \frac{1}{N} \sum_{i=1}^N X_i. \quad (10)$$

Antra komponentė – iš signalo šalinamas vidutinis intensyvumas. Rezultatas – diskrečioje formoje, signalas $X - \mu_X$ atitinka vektoriaus X projekciją į hyperplokštumą:

$$\sum_{i=1}^N X_i = 0. \quad (11)$$

Signalo kontrastui įvertinti naudojamas standartinis nuokrypis:

$$\sigma_X = \left(\frac{1}{N-1} \sum_{i=1}^N (X_i - \mu_X)^2 \right)^{\frac{1}{2}}. \quad (12)$$

$c(X, Y)$ yra skirtumai tarp σ_X ir σ_Y .

Trečia komponentė – signalas yra normuojamas (dalomas) pagal savo paties standartinį nuokrypį.

Galiausiai visos trys sudedamosios dalys yra kombinuojamos ir gaunamas bendras panašumas.

$$S(X, Y) = f(l(X, Y), c(X, Y), s(X, Y)). \quad (13)$$

Svarbu yra tai, kad visi trys komponentai yra santykinai nepriklausomi. Pavyzdžiui, ryškumas ir / arba kontrasto pokytis neturi įtakos vaizdų struktūroms.

Šis indeksas tenkina tokias sąlygas:

- 1) Simetriškumas: $S(X, Y) = S(Y, X)$;

- 2) Aprėžtumas: $S(X, Y) \leq 1$;
- 3) Unikalus maksimumas: $S(X, Y) = 1$ tada ir tik tada, kai $X = Y$ ($X_i = Y_i$), visiems $i = 1, 2, \dots, N$.

Ryškumo palyginimas apskaičiuojamas pagal formulę:

$$l(X, Y) = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1}, \quad (14)$$

čia C_1 yra konstanta nestabilumui išvengti, kai $\mu_X^2 + \mu_Y^2$ yra labai arti nulio, apskaičiuojama pagal formulę:

$$C_1 = (K_1 L)^2, \quad (15)$$

čia L yra dinaminis pikselio reikšmių diapazonas (pvz., 8 bitų maksimali reikšmė yra $2^8 - 1 = 255$), o K yra labai maža konstanta, pagal nutylėjimą naudojama $K_1 = 0,01$.

Kontrasto palyginimas skaičiuojamas analogiškai kaip ir ryškumo:

$$c(X, Y) = \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2}, \quad (16)$$

$$C_2 = (K_2 L)^2. \quad (17)$$

Pagal nutylėjimą naudojama $K_2 = 0,03$.

Struktūros palyginimas skaičiuojamas taip:

$$s(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3}. \quad (18)$$

Diskrečioje formoje σ_{XY} gali būti skaičiuojamas taip:

$$\sigma_{XY} = \left(\frac{1}{N-1} \sum_{i=1}^N (X_i - \mu_X)(Y_i - \mu_Y) \right). \quad (19)$$

Galiausiai šie trys palyginimai sukombinuojami:

$$SSIM(X, Y) = [l(X, Y)]^\alpha \cdot [c(X, Y)]^\beta \cdot [s(X, Y)]^\gamma, \quad (20)$$

čia $\alpha > 0$, $\beta > 0$, $\gamma > 0$ parametrai, naudojami santykinės svarbos reguliavimui. Siekiant supaprastinti išraišką, juos prilyginame vienetui $\alpha = \beta = \gamma = 1$, o $C_3 = \frac{C_2}{2}$.

Gauname SSIM indekso galutinę išraišką:

$$SSIM(X, Y) = \frac{(2\mu_X\mu_Y\sigma_{XY} + C_1)(2\sigma_{XY} + C_2)}{(\mu_X^2 + \mu_Y^2 + C_1)(\sigma_X^2 + \sigma_Y^2 + C_2)}, \quad (21)$$

μ_X, σ_X bei σ_{XY} yra skaičiuojami kvadratinio 8×8 dydžio lango, kuris juda po vieną pikselį ir kiekvienam lange yra apskaičiuojamas SSIM indeksas, ribose. Skaičiuojant tokiu būdu, gaunamas SSIM žemėlapis „blokuoja“ tam tikrus artefaktus, todėl yra naudojamas 11×11 simetrinis langas ir pagal Gauso svorių funkciją $w = \{w_i | i = 1, 2, \dots, N\}$ „svorių suma yra normuojama $\sum_{i=1}^N w_i = 1$.

Nepaisant to, kad SSIM indekso metodo matematinis modelis yra gana sudėtingas, manoma, kad gautas rodiklis labai gerai atitinka HVS. Detaliau metodo matematinės savybės aptariamos darbe (Brunet, 2012).

Verta paminėti, kad atstumas, iš kurio žiūrima į vaizdą, daro įtaką vaizdo kokybės suvokimui. Atsižvelgiant į tai, darbe (Wang, 2004) buvo pristatytas daugiaskalis SSIM (angl. *Multi-Scale SSIM*, MS-SSIM):

$$S(X, Y) = [l(X, Y)]^{\alpha P} \times \prod_{i=1}^P [c(X, Y)]^{\beta_i} [s(X, Y)]^{\gamma_i}. \quad (22)$$

Čia kontrastas ir struktūra skaičiuojami kiekvienai skalei i , o šviesumas tik atstumui P . Vidutinė kokybė gaunama kombinuojant matus pagal skirtingas P . MS-SSIM indeksas geriau koreliuoja su HVS, kai vertinami maži vaizdai (tokio dydžio vaizdai, kad subjektyvus kokybės vertinimas priklauso nuo atstumo, iš kuriuo žmogus žiūri į vaizdą). Vertinant didelius vaizdus, pateikiamus didele raiška, šio metodo privalumai nėra aktualūs.


Taip pat SSIM indekso metodo pagrindu sukurti ir kiti metodai: HWSSIM metodas (Ji, 2008), kuriame naudojamos Haaro bangelių transformacijos (angl. *Wavelet Transform*) (Chui, 1992); DWT-SSIM metodas (Yang, 2008), kuriame taikomos diskrečiosios bangelių transformacijos; PSSIM^c metodas (Yang, 2008), kur lokalių regionų SSIM indekso vertės koreguojamos pagal svorius, nustatytus pagal šių regionų kontrastus.

2.3 Vaizdų klasifikavimas

Tam, kad būtų galima suprasti vaizdų klasifikavimo specifiką, klasifikavimą reikia vertinti kaip kompiuterinės regos (angl. *Computer Vision*) (Richard, 2011) sudedamąją dalį. Kompiuterinė rega, kaip mokslinė disciplina, yra susijusi su dirbtinių sistemų, reikalingų gauti (suvokti) informaciją iš vaizdų, kūrimo teorija. Apibendrintai kompiuterinės regos uždavinių sprendimą galima suskirstyti į tris etapus: parengtinis (preliminarius) filtravimas (apdorojimas); tarpinių vaizdų apdorojimas; sprendimo priėmimas. Sunku nustatyti griežtas ribas tarp šių etapų. Parengtiniam filtravimui ir tarpinių vaizdų apdorojimui gali būti naudojami vaizdų analizės (angl. *Image Analysis*) metodai (Solomon, 2011). Dažniausiai tarpinių vaizdų apdorojimas vyksta išskiriant konkrečius, specifinius objektus vaizde (angl. *Object Recognition*). Sprendžiant kompiuterinės regos uždavinius, reikia išskirti informacijos

klases ir čia yra pasitelkiami klasikiniai klasifikavimo metodai (Kiang, 2003).

Vaizdų klasifikavimas – tai procesas, kurio metu iš daugiakanalio rastrinio vaizdo yra išskiriamos informacijos klasės. Kitaip tariant, konstruojama funkcija $Y' = f(X')$, kuri kiekvienam požymių vektoriui X' duoda atsakymą Y' – kuriai klasei priklauso X' . Funkcija $f()$ vadinama klasifikatoriumi, kuris dalina požymių erdvę į regionus (4 pav.).



4 pav. Požymių erdvė

Klasifikavimo uždavinys, arba matematinėje statistikoje kitaip vadinamas diskriminantine analize (angl. *Discriminant Analysis*), dažniausiai apibūdinamas kaip atpažinimo uždavinys su mokytoju (angl. *Supervised Classification*). Klasifikavimas be mokytojo yra toks, kai mokymo imties objektai nėra suskirstyti į iš anksto žinomas klases, o jų klasifikavimas vyksta vertinant objektų panašumą vienas į kitą. Tokio tipo uždavinius priimta vadinti klasterizavimo uždaviniais, o klases – klasteriais. Toliau darbe terminas klasifikavimas bus suprantamas kaip atpažinimo uždavinys su mokytoju.

Klasifikavimo metodais siekiama tiriamus objektus priskirti vienai iš žinomų klasių pagal juos apibūdinančius skaitinius duomenis. Tarkime, objektas yra aprašomas d -mačiu vektoriumi $S = (s_1, s_2, \dots, s_d)$, o

Y'_1, Y'_2, \dots, Y'_l žymi klases, kurioms gali priklausyti objektas, čia l – klasių skaičius. Dažnai klasifikavimo uždaviniai yra sprendžiami tokiais etapais:

- 1) Remiantis objektą aprašančiu vektoriumi S , nustatomi charakteringi objekto požymiai x_p (nepriklausomi arba diskriminavimo kintamieji) ir sudaromas vektorius $X' = (x_1, x_2, \dots, x_p)$, čia $p \leq d$. Įprastai siekiama rasti kuo mažesnę požymių skaičių p , neprarandant daug informacijos apie objektą. Iš požymių reikšmių galima sudaryti objektus atitinkančius daugiamacių vektorius X'_1, X'_2, \dots, X'_n , čia $X'_i = (x_{i1}, x_{i2}, \dots, x_{ip})$, n – analizuojamų objektų (vektorių) skaičius. Kiekvienas vektorius $X_i, i = 1, \dots, n$, yra priskiriamas vienai iš klasių $Y'_k, k \in [1, \dots, l]$.
- 2) Sukuriamas klasifikatorius, remiantis objektus charakterizuojančiais vektoriais X'_1, X'_2, \dots, X'_n . Klasifikatoriumi vadinamas vektorių X'_1, X'_2, \dots, X'_n atvaizdas į klasių žymių aibę Y'_1, Y'_2, \dots, Y'_l . Pagal sukurtą klasifikatorių objektas, kurio klasė nėra žinoma, priskiriamas vienai iš žinomų klasių. Tam tikslui reikia sudaryti klasifikavimo taisyklę $\delta: x_p \rightarrow Y'_k, k \in [1, \dots, l]$. Objektas priskiriamas tai klasei, kurios didžiausia aposteriorinė tikimybė $\tau(x) = P(X' \in Y', | X' = x)$. Ši tikimybė dažniausiai apskaičiuojama pagal Bajeso formulę (Gutierrez-Pena, 2004):

$$\tau_i(x) = \frac{y_i f_i(x)}{\sum_{i=1}^l y_i f_i(x)}, i \in [1, \dots, l]. \quad (23)$$

Čia $y_i = P(X' \in Y'_i)$ – apriorinė tikimybė, kad parinktas objektas priklauso klasei Y'_i , f_i yra X' tankio funkcijos klasėse Y'_i . Tikimybių suma $\sum_{i=1}^l y_i = 1$. Atsižvelgiant į tai, kad y_i ir f_i

nėra žinomi, reikia surasti jų įverčius \hat{y}_i ir \hat{f}_i . Apriorinė tikimybė skaičiuojama pagal formulę:

$$y_i = \frac{n_i}{n}, \quad i \in [1, \dots, l], \quad (24)$$

čia n_i – objektų skaičius i -tojoje klasėje, n – bendras objektų skaičius.


Sprendimas dėl objekto priskyrimo klasei priimamas pagal aposteriorinės tikimybės įvertį $\hat{\tau}_i$, kuris apskaičiuojamas naudojant Bajeso formulę (23).

Sukūrus klasifikatorių, nustatoma ar jis tinkamai klasifikuoja objektus. Vienas iš dažniausiai naudojamų matų – bendras klasifikavimo tikslumas (angl. *Accuracy*). Tai santykis tarp teisingai klasifikuotų duomenų skaičiaus ir visų klasifikuojamų duomenų skaičiaus. Jam atvirkštinis matas yra neteisingai klasifikuotų duomenų santykis (angl. *Misclassification Rate*), kitai vadinamas klasifikavimo klaida (angl. *Error*). Šie matai gerai atspindi klasifikavimo tikslumą tuo atveju, jeigu klasėms priskirtų objektų kiekis yra panašus, o pačių klasių kiekis nedidelis.

Gauti išsamesnei informacijai apie klasifikavimo rezultata, skaičiuojamas pilnumas / jautrumas (angl. *Recall / Sensitivity*) ir tikslumas (angl. *Precision*). Šiuos matus galima išreikšti apibrėžus šias sąvokas apie gautą rezultatą (Fawcett, 2006):

- tikrai teigiamas (TT) (angl. *True Positive*) – objektas priskirtas klasei ir iš tiesų jis jai priklauso;
- tikrai neigiamas (TN) (angl. *True Negative*) – objektas nepriskirtas klasei ir iš tiesų jis jai nepriklauso;
- klaidingai neigiamas (KN) (angl. *False Negative*) – objektas nepriskirtas klasei, bet iš tiesų jis jai priklauso;

- klaidingai teigiamas (KT) (angl. *False Positive*) – objektas priskirtas klasei, bet iš tiesų jis jai nepriklauso.



5 pav. Klasifikavimo kokybės / tikslumo matai

Matų išraiškos (5 pav.):

$$\text{jautrumas} = \frac{TT}{TT + KN}; \quad (25)$$

$$\text{tikslumas} = \frac{TT}{TT + KT}; \quad (26)$$

$$\text{bendras klasifikavimo tikslumas} = \frac{TT+TN}{TT+TN+KN+KT}; \quad (27)$$

$$\text{klasifikavimo klaida} = 1 - \text{bendras klasifikavimo tikslumas}. \quad (28)$$

Klasifikavimo tikslumui nustatyti yra naudojamas kryžminis patikrinimas (angl. *Cross-Validation*), kurio metu visa klasifikuojamų

duomenų imtis yra padalinama į k lygių dalių, po to atliekamas klasifikatoriaus mokymas, naudojant $k - 1$ imties dalis, ir testavimas, naudojant likusią duomenų dalį. Testavimo metu duomenys, nenaudoti mokymui, pateikiami sukurtam klasifikatoriui, nustatoma, kiek duomenų buvo teisingai klasifikuota, ir apskaičiuojami klasifikavimo tikslumo matai. Procedūra kartojama k kartų, tokiu būdu užtikrinama, kad kiekviena iš k dalių yra panaudojama testavimui. Apskaičiuotos gautų klasifikavimo matų vidutinės reikšmės parodo, kiek procentų vaizdų buvo priskirta tinkamai klasei, t. y. kaip gerai klasifikatorius atpažįsta klases.

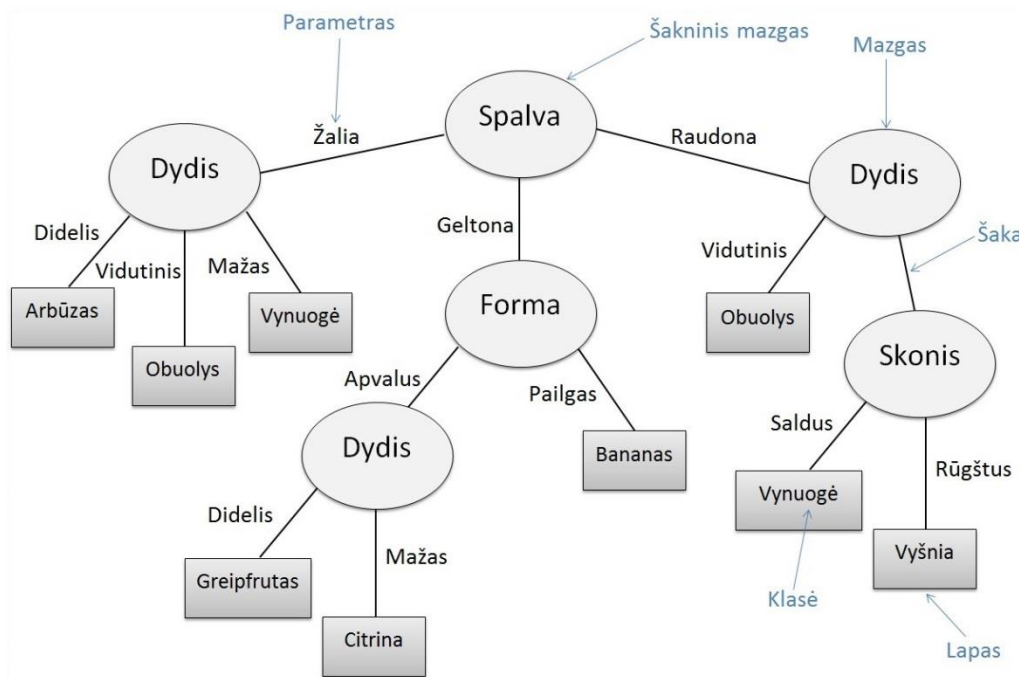
Klasifikavimo rezultatų vizualizavimui naudojama klasifikavimo matrica (angl. *Confusion matrix*), kurios eilutės parodo tikrąsias klases, o stulpeliai – prognozuojamas klases.

Šiuo metu yra sukurta įvairių klasifikavimo metodų, tokių kaip *Naive Bayes*, įvairūs klasifikavimo medžiai, taisyklėmis pagrįsti klasifikatoriai ir kt. (Alpaydin, 2009). Nemažai darbų yra skirta klasifikavimo metodams palyginti tarpusavyje ir šiuos metodus kategorizuoti (Giberta, 2010) (Entezari-Maleki, 2009) (Talwar, 2013).

Atsižvelgiant į tai, kad iškeltiems uždaviniams pasiekti nėra pagrįstų motyvų naudoti specifinį kompiuterinio mokymosi (angl. *Machine Learning*) algoritmą, darbe pasirinkti skirtingais principais grįsti kompiuterinio mokymosi algoritmai: statistinio mokymosi (angl. *Statistical Learning*) klasifikavimo algoritams priskiriama tiesinė diskriminantinė analizė (angl. *Linear Discriminant Analysis, LDA*) (Mika, 1999) (Guo, 2007), loginio pasirinkimo (angl. *Logic Based*) algoritams priskiriamas sprendimų medžio mokymosi metodas (angl. *Decision Tree Learning*) (Breiman, 1984) ir atraminių vektorių klasifikatorius (angl. *Support Vector Machine, SVM*) (Vapnik, 1995). Minėtos klasifikatorių kategorijos pristatytos darbe (Kotsiantis, 2007).

2.3.1 Sprendimų medžiai

Sprendimų medžio algoritmo rezultatas – tai į medį panaši struktūra. Šio medžio šakos yra sąlygos tenkinimas / netenkinimas. Tokiu būdu sudaromos taisyklės, leidžiančios klasifikuoti objektus pagal požymių savybes (parametrus) (Kaminski, 2017). 6 pav. pateiktas pavyzdys, nusakantis vaisiaus parinkimą.



6 pav. Sprendimų medis

Klasifikavimo medis yra modeliavimo metodas, naudojamas prognozuoti kintamojo Y' reikšmei, atitinkančiai parametru vektoriu X' . Mokymo algoritmui reikalinga (X'_n, Y'_n) pavidalo mokymo imtis L , čia Y'_n – objekto reikšmė, priklausoma nuo parametru vektoriaus X'_n , $n = 1, 2, \dots, N$, N – pavyzdžių skaičius. Tarkime, konstruojamas medis, kurio pradžioje yra vienas šaknis mazgas t_1 (tai ypatingas mazgas, nes jis yra pradinis ir vienintelis), jį sudaro visi aibės L mokymo pavyzdžiai. Šiame mazge vyksta padalinimas į dvi dalis t_L, t_R . Gauti mazgai t_L, t_R taip

pat dalinami į dvi dalis. Procedūra kartojama iki bus patenkinta sustojimo sąlyga. Tipiniu atveju dalijimo procesas vyksta, kol stebimas klaidos mažėjimas. Siekiama rasti optimalų aibės L padalinimą, pasirenkant klaidos vertinimo būdą.

2.3.2 Tiesinė diskriminantinė analizė

Tiesinė diskriminantinė analizė – tai Fišerio diskriminantu (Fisher, 1936) grįstas metodas, skirtas rasti tokią kintamųjų tiesinę kombinaciją, kuri geriausiai atskiria dvi ar daugiau klasių. Kitaip tariant, ieškoma tiesinė transformacija maksimizuojanti sklaidą tarp klasių ir minimizuojanti sklaidą klasių viduje (Guo, 2007). Nors tiesinė diskriminantinė analizė naudojama darbui su informacija atsižvelgiant į duomenų klases, savaime tai nėra klasifikavimo algoritmas. Dažniausiai tiesinės diskriminantinės analizės rezultatas yra naudojamas kaip dalis tiesinio klasifikavimo. Kitas populiarus taikymas yra daugiamatės erdvės duomenų transformacija į mažesnio skaičiaus matmenų erdvę taip, kad klasių atskiriamumo kriterijaus reikšmė būtų optimali (prieš taikant netiesinius klasifikavimo algoritmus).

Taikant tiesinę diskriminantinę analizę, turi būti tenkinama tokia prielaida:

$$f_i(x) = \frac{1}{(2\pi)^{p/2} |C|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu_i)^T C^{-1}(x - \mu_i)\right), i \in [1, \dots, l], \quad (29)$$

čia C – jungtinė kovariacijų matrica (angl. *The Pooled Covariance Matrix*), $\mu_i - X'$ vidurkis i -tojoje klasėje, p – diskriminavimo kintamųjų kiekis.

Sudaroma diskriminavimo taisyklė, pagal kurią objektas priskiriamas klasei Y'_k , kurios dydis $D_k^L(x)$ maksimalus (pagal Bejeso

formulę (24) objektas gali būti priskirtas klasei Y'_k , kai $y_k f_k(x) \geq y_i f_i(x)$, $i \in [1, \dots, l]$):

$$D_k^l(x) = \mu_i^T C^{-1} x - \frac{1}{2} \mu_i^T C^{-1} \mu_i + \ln(y_i). \quad (30)$$

Toliau skaičiuojami C ir μ_i įverčiai \hat{C} ir $\hat{\mu}_l$. Juos galima skaičiuoti taikant formules:

$$\hat{\mu}_l = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{ij}, i \in [1, \dots, l], \quad (31)$$

$$\hat{C} = \frac{\sum_{i=1}^l (n_i - 1) \hat{C}_i}{\sum_{i=1}^l n_i - l}, \quad (32)$$

$$\hat{C}_i = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (x_{ij} - \hat{\mu}_l)(x_{ij} - \hat{\mu}_l)^T, i \in [1, \dots, l], \quad (33)$$

čia x_{ij} – i -tosios klasės j -tasis objektas.

Klasifikavimo taisyklės gaunamos įstačius įverčius į (30) formulę.

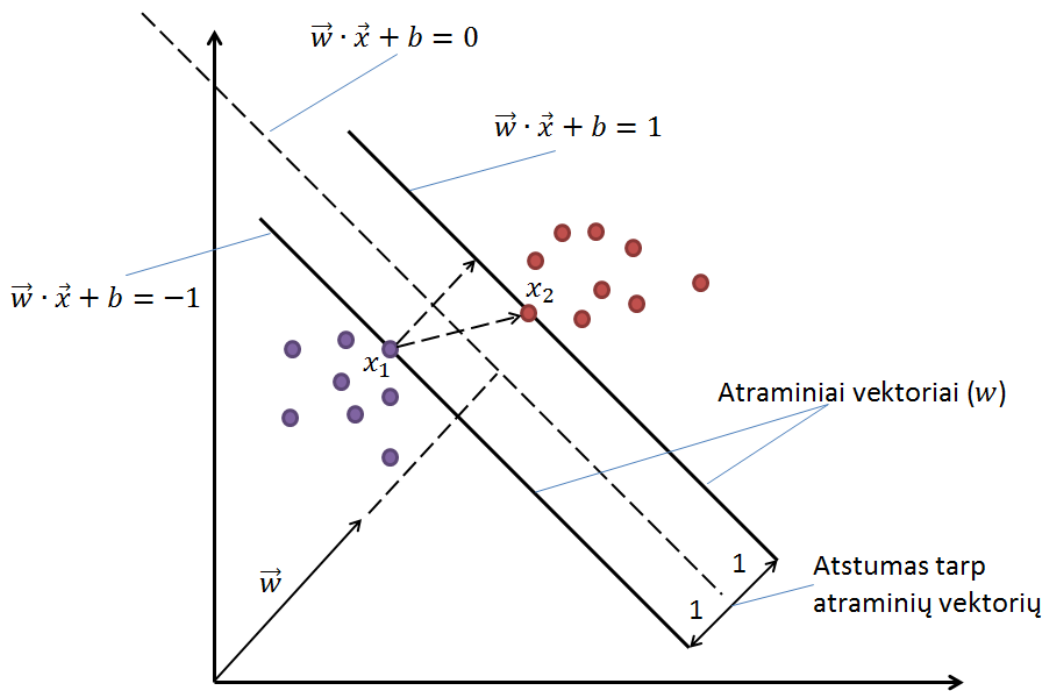
2.3.3 Atraminių vektorių klasifikatorius

Vienu iš tiksliausių metodų išlieka atraminių vektorių klasifikatorius (SVM). Šio klasifikatoriaus esmė – sukurti tokią hiperplokštumą, kuri duomenis atskirtų į dvi klases. Kuriant hiperplokštumą, mokymo aibės objektai suskirstomi į dvi dalis taip, kad atstumas tarp artimiausių elementų, priklausančių skirtingoms klasėms, iki tos hiperplokštumos būtų maksimalus. Sukurta hiperplokštuma priklauso vien tik nuo mokymo aibės poaibio, sudaryto iš taip vadinamų atraminių vektorių (7 pav.).

Galiojančios nelygybės: $(w \cdot x + b) \geq 1, \forall x$ iš 1-os klasės;
 $(w \cdot x + b) \leq 1, \forall x$ iš 2-os klasės.

Konstruojant hiperplokštumą, sprendžiamas optimizavimo su apribojimais uždavinys. Maksimizuojamas atstumas tarp atraminių vektorių:

$$\frac{w}{\|w\|} \cdot (x_2 - x_1) = \frac{2}{\|w\|}. \quad (34)$$



7 pav. Atraminiai vektoriai

Atraminiai vektoriai surandami išsprendus tokį minimizavimo uždavinį:

$$\min \frac{1}{2} \|w\|^2, \quad y_i(w \cdot x_i + b) \geq 1, \forall x_i. \quad (35)$$

Idealiu atveju sprendinys – hiperplokštumą, perskirianti objektus (vektorius) į nepersidengiančias klases. Kitu atveju ieškoma tokios hiperplokštumos, kuri maksimizuotų atstumą ir minimizuotų klaidingą klasifikavimą.

Dažnai skirtingų klasių duomenys negali būti tiesiškai atskirti, todėl taikomos įvairios branduolio (angl. *Kernel*) funkcijos, kurios klasifikuojamus duomenis transformuoja į kitą erdvę, kurioje įmanomas tiesinis klasių atskyrimas. Dažniausiai naudojamos branduolio funkcijos: tiesinė, polinominė, Gausinė, sigmoidinė.

SVM klasifikatorius yra plačiai taikomas vaizdams klasifikuoti. Šis klasifikatorius gali būti efektyviai naudojamas, kai objektų požymiai yra aprašomi daugiamatėmis histogramomis (Chapelle, 1999), kai vaizdai klasifikuojami į klases pagal juose esančias tekstūras ir objektus (Zhang, 2007). SVM klasifikatorius taikomas ir didelių vaizdų aibėms klasifikuoti pagal vaizdo scenas ir objektus (Mensink, 2012), (Sanchez, 2011), (Yuanqing, 2011).

Disertacijoje naudojami metodai taikomi ne tik binariniam klasifikavimui, todėl, kai reikia klasifikuoti daugiau nei į dvi klases, naudojamas atraminių vektorių klasifikatorius daugeliui klasių (angl. *Multi-Class SVM*). Darbe (Furnkranz, 2002) analizuojami daugiaklasių uždavinių sprendimai, naudojant binarinius klasifikatorius. Pagrindinė idėja yra porų binarizavimas, t. y. c klasių uždavinys transformuojamas į $\frac{c(c-1)}{2}$ binarizavimo uždavinius, žymimus $\langle i, j \rangle$, vieną kiekvienam klasių rinkiniui $\{i, j\}, i = 1 \dots c - 1, j = i + 1 \dots c$. Binarinis klasifikatorius uždaviniui $\langle i, j \rangle$ mokomas klasių pavyzdžiais i ir j , o kai yra klasių pavyzdžiai $k \neq i, j$ šiam uždaviniui ignoruojamas. Pavyzdžiui, turint 6-ių klasių uždavinį, klasifikavimo procedūra kartojama 15 kartų. Smulkiau atraminių vektorių klasifikatorius daugeliui klasių aprašomas darbe (Wang, 2014).

2.4 Vaizdų klasifikavimas, kai atsižvelgiama į vaizdų kokybę

Vaizdų glaudinimas, kai atsižvelgiama į objektyvią gaunamo vaizdo kokybę, grindžiamas gauto vaizdo kokybės vertinimu objektyviais,

palyginamaisiais (angl. *Full-Reference*) kokybės vertinimo metodais. Pavyzdžiui, darbe (Forczmanski, 2014) pristatomas adaptyvus JPEG algoritmas, leidžiantis spausti vaizdus efektyviau, atsižvelgiant į vaizdų turinį. Vertinamas vaizdo lygumas, t. y. glotnesni (angl. *Smooth*) vaizdai yra spaudžiami labiau, o ne tokie glotnūs, turintys daugiau briaunų, mažiau. Tam tikslui buvo pasitelkti MSE, SSIM ir vizualinės atitikties (angl. *Image Fidelity*) (Daly, 1993) kokybės vertinimo matai. Vaizdų kokybės slenksčiams (angl. *Quality Thresholds*) nustatyti buvo naudojamas Laplaso briaunų aptikimo filtras (angl. *Laplace Edge Detection*) (Maini, 2009). Naudojant darbe pasiūlytą adaptyvų algoritmą, JPEG algoritmas turi būti naudojamas ne mažiau nei vieną kartą ir kiekvieną kartą turi būti lyginami pradiniai ir apdoroti vaizdai.

Darbe (Coulombe, 2010) pristatoma sistema, kurios pagalba optimizuojama JPEG apdoroto vaizdo kokybė pagal JPEG kokybės faktorių ir vaizdo mastelį, kai nurodytas maksimalus vaizdo dydis ir rezoliucija. Kitaip tariant, darbe siekiama nustatyti optimalų parametrų kiekį ir gauti didžiausią santykinį failo dydį pagal rodomo vaizdo mastelį. Vaizdo kokybė yra skaičiuojama naudojant SSIM. Atsižvelgiant į tai, kad naudojant pasiūlytą sistemą reikia daug transkodavimo operacijų kiekvienam vaizdai, tam, kad būtų gautas optimalus sprendinys (naudojant tikslų kokybės kriterijų, kuris yra įvertintas kiekviename tarpiniame transkodavime), ta pati kompiuterio mokymosi metodika naudojama optimalaus parametrų rinkinio nustatymui, atsižvelgiant į didžiausią santykinį failo dydį pagal rodomo vaizdo mastelį. Sprendimas, pasiūlytas (Coulombe, 2010), nenustato gaunamo failo dydžio, atsižvelgiant į kokybę, bet maksimizuoja kokybę, apribojant failo dydį. Patobulinimai buvo realizuoti (Pigeon, 2012) darbe, naudojant K-vidurkių klasterizavimu (angl. *K-Means Clustering*) (Lloyd, 1982) paremtą sprendimą numatyti transkoduotą JPEG failo dydį pagal struktūrinį panašumą. Tam, kad

sistema pritaikytų geriausių kokybės faktorių, dažnai reikia papildomų JPEG transkodavimo operacijų.

Aukščiau aprašyti vaizdų glaudinimo būdai turi vieną panašumą – tam, kad būtų parinkta geriausia JPEG QF reikšmė, gali tekti glaudinimo algoritmą vienam vaizdai kartoti daugiau nei vieną kartą.

Darbe (Kozhemiakin, 2017) pristatytas metodas numatyti MSE ir / arba PSNR reikšmes juodai baltam vaizdai suspaustam JPEG algoritmu su vienodu AGU kvantavimu ir ADCT (Kozhemiakin, 2017). Siūlomas metodas gali tiksliai numatyti suspausto vaizdo kokybę, naudojant ribotą analizuojamų blokų skaičių. Šis prognozavimas pagrįstas hipoteze, kad MSE tarp kvantinių DCT koeficientų blokuose (vadinamuose MSE DCT), yra praktiškai lygus glaudintų vaizdų MSE. Kitaip tariant, iškraipymai po glaudinimo yra praktiškai tokie patys kaip iškraipymai, nustatyti tarp DCT koeficientų kvantavimo metu. Šiuo atveju kokybė vertinama pikselio lygmenyje.

Darbe (Laua, 2003) tiriamas JPEG poveikis vaizdų klasifikavimui, o tiksliau - vaizdų atpažinimui (angl. *Pattern Recognition*). Naudojamas ISODATA (Ball, 1965) algoritmas, o apmokymo duomenys (angl. *Training Sets*) – vektoriniai vaizdo segmentai (angl. *Vector Segments*). Segmentai darbe netikslinami. Klasifikuojant siekiama palydoviniuose vaizduose atpažinti keturias klases: vanduo, augalinė danga, miesto teritorijos, netinkama / nederlinga žemė. Darbe daroma išvada, kad vaizdo glaudinimo poveikis kokybei yra priklausomas nuo vaizdo turinio (angl. *Scene-Dependent*).

Darbe (Venkatesh Babu, 2006) sprendžiamas klasifikavimo uždavinys, kurio tikslas yra nuspėti vaizdo kokybę ir ištirti ryšį tarp HVS požymių ir MOS. Darbo tikslas – sukurti kokybės vertinimo metodą, kuris gerai koreliuotų su žmogaus vaizdo kokybės suvokimu, nenaudojant pradinio vaizdo. Naudojamas nuoseklus mokymosi algoritmas, vadinamas augančiu ir apkarpančiu radialinių bazinių funkcijų tinklas

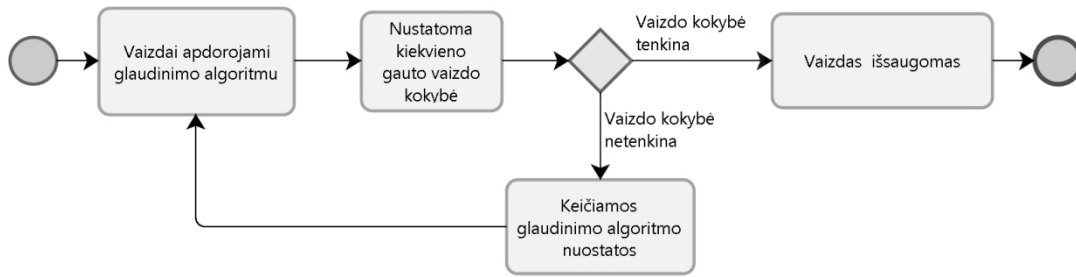
(GAP-RBF) (angl. *Growing and Pruning Radial-Basis Function (GAP-RBF) Network*). Neuroninio tinklo (Dzemyda, 2008) mokymui naudojami tokie požymiai: briaunos amplitudė (angl. *Edge Amplitude*), briaunos ilgis (angl. *Edge Length*), fono aktyvumas (angl. *Background Activity*), fono šviesumas (angl. *Background Luminance*) (Karunasekera, 1995). Briaunos darbe yra nustatomos išilgai horizontaliomis ir vertikaliomis kryptimis, naudojant atitinkamus Prewitto briaunų nustatymo operatorius (Maini, 2009; Maini, 2009). Gaunamas mažesnis vidutinis kvadratinis nuokrypis (angl. *The Root Mean Square Error, RMSE*) (Kenney, 1962) nuo MOS nei kitų nagrinėjamų metrikų.

2.5 Poskyrio išvados

Universalus vaizdų grupių be specifinio turinio glaudinimas, atsižvelgiant į gautų vaizdų kokybę, kai vaizdų kokybė yra vertinama objektyviais palyginamaisiais kokybės vertinimo metodais tiek pikselio lygmenyje, tiek bendrai pagal charakteristikas, galimas dviem būdais:

- (1) tiksliai nustatant suspaustų vaizdų kokybę ir pagal tai parenkant glaudinimo algoritmo nuostatas (angl. *Precise Quality Selection Technique, PQST*) (8 pav.);
- (2) nuspėjant glaudinimo algoritmo poveikį kokybei ir pagal tai parenkant glaudinimo algoritmo nuostatas (angl. *Computational Intelligence-based Quality Selection Technique, CIQST*) (9 pav.).

Naudojant PQST, t. y. pritaikant glaudinimo algoritmo nuostatas, kai yra įvertinta kiekvieno vaizdo kokybė, galima gauti optimalų rezultatą (kiekvieno gauto vaizdo kokybė bus lygi nustatytai, o sutaupytos diskinės vietos kiekis bus maksimalus). Tačiau dirbant su didesnėmis vaizdų grupėmis, reikėtų labai didelių laiko sąnaudų. Laiko sąnaudų analizė pateikta 4.4.5 poskyryje.



8 pav. PQST: vaizdų glaudinimas, kai tiksliai nustatoma suspaustų vaizdų kokybė



9 pav. CIQST: vaizdų glaudinimas, kai naudojamas klasifikavimas

3. VAIZDŲ KOKYBĖS EKSPERIMENTINIAI TYRIMAI

3.1 SSIM indekso metodo taikymas didelės raiškos vaizdams vertinti


Šiame skyriuje analizuojamas originalaus SSIM indekso metodo taikymas didelės raiškos vaizdų kokybei vertinti. Tyrimo rezultatai pristatyti darbe [3 A], minėta problematika buvo pradėta nagrinėti disertanto magistriniame darbe (Tichonov, 2013). Šio poskyrio tyrimas yra minėto darbo apibendrinimas ir tęsinys. Nepaisant to, kad šiuo metu yra pasiūlyta daug skirtingų metodų, SSIM indekso variacijų, šiame darbe analizuojamas ir naudojamas originalus SSIM indekso metodas (Wang, 2004), kuris yra visų šių metodų pagrindas.

Eksperimentuose vaizdų panašumo skaičiavimui naudojami 30 skirtingų aukštos raiškos vaizdų (3882×2608 pikselių dydžio, 28,9 MB). Vaizdai apdorojami JPEG glaudinimo algoritmu, išlaikant numatytas nuostatas, bet keičiant kokybės faktorių. Pirmuoju atveju (a) pasirenkama QF=85, antruoju atveju (b) pasirenkama QF=70 ir trečiuoju atveju (c) QF=50. SSIM indeksas skaičiuotas kiekvienam vaizdai, naudojant Zhou Wang parašyta MATLAB funkcija (Wang, 2014) (toliau darbe vadinamas – „1-asis algoritmas“). Gautos vidutinės 30 vaizdų SSIM reikšmės pateiktos 1 lentelėje.


1 lentelė. Vidutinės SSIM reikšmės gautos 1-uoju algoritmu

Vaizdo glaudinimas	SSIM reikšmė	Failo dydis
Originalus vaizdas	1,0000	29,8 MB
QF=85	0,9999	897 KB
QF=70	0,9998	527 KB
QF=50	0,9985	355 KB


SSIM indekso reikšmės yra labai arti 1. Šiuo atveju, tarp duotųjų didelės raiškos vaizdų žmogaus akis nefiksuotų akivaizdžių skirtumų, todėl SSIM reikšmės yra labai didelės. Šį faktą iliustruoja 10 pav. Tik priartinus nagrinėjamo vaizdo fragmentą matyti, kad skirtumai tarp suspaustų vaizdų yra akivaizdūs.



Originalus vaizdas, 29,8 MB, SSIM=1




Akies fragmentas



(a) JPEG QF=85

888 KB, SSIM=0,9998



(b) JPEG QF=70

512 KB, SSIM=0,9998



(c) JPEG QF=50

333 KB, SSIM=0,9982

10 pav. Vaizdo, pakeisto JPEG algoritmais, fragmentai (SSIM indeksai skaičiuojami 1-uoju algoritmu)

10 pav. (a) ir (b) atvejais SSIM indekso reikšmės yra vienodos (kai imami keturi skaitmenys po kablelio), tačiau vaizdų kokybė skiriasi. (c) atveju SSIM indekso reikšmė pasikeitė nežymiai, bet vaizdo iškreipymai yra reikšmingi. Problema yra ta, kad SSIM reikšmės tyrėjams atrodo

panašios ir neatspindi vaizdo iškraipymų po glaudinimo tiek, kiek reikėtų, tiriant JPEG algoritmo variacijas prie skirtingų QF. Ši problema ypač aktuali, jei reikia apdoroti dideles vaizdų grupes ir kokybės vertinimas turi būti automatinis. Nepaisant to, kad žmogus negali pastebėti aukšta raiška pateiktų vaizdų smulkių iškraipymų, šių vaizdų kokybė turi likti aukšta (su kuo mažesniais pakitimais) tolesniam apdorojimui / naudojimui, pvz., naudojant didelius vaizdus spaudai, medicininius vaizdus diagnozei nustatyti, vaizdų atpažinimui ir pan.

Vaizdo glaudinimas prieš taikant SSIM indeksą

1-jame algoritme naudojamas vaizdo duomenų mažinimas (angl. *Downsampling*) prieš kokybės vertinimą SSIM indekso metodu (Wang, 2004). Vaizdo mažinimo koeficientas F apskaičiuojamas pagal formulę:

$$F = \max\left(1, \text{round}\left(\frac{\min(M,N)}{f}\right)\right), \quad (36)$$


čia N yra vaizdo (daugiamačio masyvo) plotis, M – aukštis; f – sumažinto vaizdo mastelis (256 pikseliai) (Wang, 2004). Pvz., vaizdui, kurio dydis 1536×1536 , $F = 6$ ir jis turi būti mažinamas su koeficientu – 6. Vaizdo fragmento $F \times F$ duomenų mažinimas vykdomas pagal formulę:

$$g(F^2) = \sum_{i=1}^F \sum_{j=1}^F \frac{img[i,j]}{F^2}, \quad (37)$$

čia $img[i,j]$ kiekvieno pikselio reikšmė. Vaizdo duomenų mažinimo procedūra pavaizduota 11 pav., formulės skaičiavimas kartojamas nuo 1 iki M ir nuo 1 iki N žingsniu F .

Algoritmas, kuriame nenaudojamas vaizdo glaudinimas, toliau vadinamas 2-uoju algoritmu. 2 lentelėje pateiktos abiem algoritmais gautos SSIM reikšmės. Nenaudojant vaizdo mažinimo fragmento

algoritme, gaunamos reikšmės geriau atspindi nedidelių iškraipymų kokybės pokytį.



11 pav. Vaizdo duomenų mažinimas pagal nutylėjimą naudojamas 1-jame algoritme

2 lentelė. SSIM reikšmės gautos 1-uoju ir 2-uoju algoritmais

Vaizdo glaudinimas	SSIM (1-asis algoritmas)	SSIM (2-asis algoritmas)
Originalus vaizdas	1,0000	1,0000
QF=85	0,9998	0,9765
QF=70	0,9998	0,9661
QF=50	0,9982	0,9558

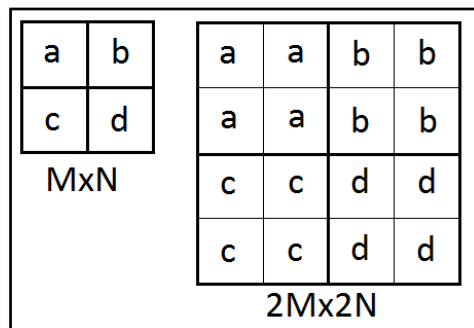
Tačiau 2-asis algoritmas turi trūkumų. Pirma, jis yra lėtas, nes reikia apdoroti labai didelius duomenų kiekius. Buvo atliktas tyrimas naudojant 30 3882×2608 pikselių dydžio vaizdų ir tiek pat 1941×1304 dydžio vaizdų. Eksperimentas buvo kartojamas 10 kartų kiekvienam vaizdai taikant 1-ąjį ir 2-ąjį algoritmus. Tyrimais nustatyta, 1-asis algoritmas skaičiavo apytiksliai 2 kartus greičiau už 2-ąjį, lyginant

1941×1304 pikselių dydžio vaizdus ($F = 5$) ir net apytiksliai 7 kartus greičiau už 2-ąjį, lyginant 3882×2608 pikselių dydžio vaizdus ($F = 10$). Tyrimas atliktas MATLAB R2012 sistemoje, naudojant kompiuterį su „Pentium DualCore T4200“ procesoriumi, 4 GB operatyviosios atminties.

Antras trūkumas – SSIM reikšmė yra labai priklausoma nuo tiriamų vaizdų dydžio, ypač, jeigu keičiama iškraipyto vaizdo struktūra.

2-ojo algoritmo apskaičiuojamos reikšmės priklausomybės nuo vaizdo dydžio analizei atliekami veiksmai:

1. Originalus vaizdas (512×512) škraipomas naudojant: šviesinimą (angl. *Brightening*), kontrasto didinimą (angl. *Increase of the Contrast*), impulsinį triukšmą (angl. *Impulsive Noise*), suliejimą (angl. *Blurring*), glaudinimą JPEG algoritmu su maža QF reikšme;
2. Originalaus vaizdas didinamos 4 kartus iki vaizdo dydžio – 2048×2048 , nenaudojant jokių interpoliacijų bei kokybės pagerinimų. Pavyzdžiui, didinant $M \times N$ dydžio vaizdą iki $2M \times 2N$, kiekvienas pikselis keturgubinamas, taip išlaikant proporcijas bei struktūrą (12 pav.);
3. Glausti vaizdai taip pat didinami 4 kartus;
4. Vienodų dydžių vaizdai yra palyginami skaičiuojant SSIM reikšmę 2-ju algoritmu.



12 pav. Vaizdo didinimas

Šie žingsniai taikyti 30-čiai vaizdų, paskaičiuotos vidutinės SSIM reikšmės vienodo dydžio vaizdams ir jos pateiktos 3 lentelėje. Iš pateiktų rezultatų matyti, kad SSIM reikšmės priklauso nuo iškraipymų, t. y. SSIM reikšmė priklauso ne tik nuo vaizdo dydžio, bet ir nuo iškraipymo tipo. Didžiausias SSIM reikšmės skirtumas, skaičiuojant skirtingo dydžio vaizdų kokybę, yra tada, kai vertinami impulsiniu triukšmu iškraipyti vaizdai.

3 lentelė. SSIM indekso priklausomybė nuo vaizdo dydžio (skaičiuojama 2-uju algoritmu)

Iškraipymas	SSIM reikšmė (vaizdo dydis 512×512)	SSIM reikšmė (vaizdo dydis 2048×2048)
Originalus vaizdas	1	1
Šviesinimas	0,937	0,922
Kontrasto didinimas	0,923	0,911
Impulsinis triukšmas	0,723	0,902
Suliejimas	0,731	0,767
JPEG algoritmas	0,681	0,729

Galima daryti išvadą, kad vaizdo dydis labai paveikia SSIM reikšmes, kai netaikomas vaizdo glaudinimas prieš SSIM panašumo vertinimą.

Vertinant didelės raiškos vaizdus, duomenų mažinimas prieš vertinimą yra būtinas, tačiau toks duomenų mažinimas, koks taikomas 1-jame algoritme ((36) ir (37) formulės) nėra tinkamas, kai vertinami dideli vaizdai.

Vaizdo duomenų mažinimas gali būti vykdomas skirtingais būdais naudojant interpoliaciją. Populiariausi interpoliacijos metodai vaizdai mažinti apžvelgti darbe (Meijering, 2002):

- Artimiausio kaimyno interpoliacija (angl. *Nearest-Neighbour Interpolation*), kai išeities pikselio reikšmei yra priskiriama originalaus vaizdo vidinė pikselio reikšmė, o kiti pikseliai nėra vertinami;
- Tiesinė interpoliacija (angl. *Linear Interpolation*), kai išėjimo pikselių reikšmė yra pikselių svartinis vidurkis artimiausių 2 pikselių kaimynystėje;
- Kubinė interpoliacija (angl. *Cubic Interpolation*), kai išėjimo pikselių reikšmė yra pikselių svartinis vidurkis artimiausių 4 pikselių kaimynystėje.

Kad būtų galima nustatyti geriausiai tinkančią interpoliaciją vaizdui mažinti, atliktas eksperimentinis tyrimas. Vidutinės SSIM reikšmės, apskaičiuotos 30-čiai vaizdų naudojant skirtingas interpoliacijas, pateiktos 4 lentelėje.

4 lentelė. SSIM indekso reikšmės naudojant skirtingas interpoliacijas

Vaizdo glaudinimas	Artimiausio kaimyno interpoliacija	Kubinė interpoliacija	Tiesinė interpoliacija
Originalus vaizdas	1	1	1
QF=85	0,9845	0,9965	0,9984
QF=70	0,9768	0,9952	0,9982
QF=50	0,9672	0,9976	0,9976

Pateikti rezultatai rodo, kad didžiausias skirtumas tarp SSIM reikšmių gaunamas naudojant artimiausio kaimyno interpoliaciją, todėl siūloma didelės raiškos vaizdus su nedideliais iškraipymais vertinti naudojant artimiausio kaimyno interpoliaciją (toliau vadinamas – 3-asis algoritmas).

Nepaisant to, kad vaizdo duomenų mažinimas yra vienintelis nagrinėtų algoritmų skirtumas, jis labai įtakoja galutinę SSIM reikšmę (tais atvejais, kai vaizdo dydis didesnis nei 256×256). Vidutinės SSIM reikšmės, apskaičiuotos vertinant 30 aukštos raiškos vaizdų su nedideliais iškreipymais, taikant visus nagrinėtus algoritmus, pateiktos 5 lentelėje.

5 lentelė. SSIM indekso reikšmės, apskaičiuotos analizuojamais algoritmais

Vaizdo glaudinimas	SSIM (ISSIM) (1-asis algoritmas)	SSIM (ISSIM) (2-asis algoritmas)	SSIM (ISSIM) (3-asis algoritmas)
Originalus vaizdas	1 (0)	1 (0)	1 (0)
QF=85	0,9999 (0,01)	0,9765 (2,35)	0,9845 (1,5)
QF=70	0,9998 (0,02)	0,9661 (3,39)	0,9768 (2,32)
QF=50	0,9985 (0,15)	0,9558 (4,42)	0,9672 (3,28)

3-asis algoritmas, priešingai nei 1-asis, gerai atspindi skirtumus (5 lentelė). Lyginant 1-ojo ir 3-ojo algoritmo skaičiavimo greitį, gauti labai nežymūs skirtumai. Vertinant aukštos raiškos vaizdus su nedideliais iškreipymais, dėl informatyvumo reikėtų skaičiuoti ne struktūrinį panašumą (angl. *similarity*), o atvirkštinį panašumo (angl. *Inverse Structural Similarity*, (ISSIM)) indeksą. Jis apskaičiuojamas pagal formulę:

$$ISSIM = (1 - SSIM) \cdot 100, \quad (38)$$

geresnė kokybė yra ISSIM reikšmei esant arčiau 0.

3.1.1 Poskyrio išvados

Skyriuje pasiūlyta tirti didelės raiškos vaizdus SSIM indekso metodu, o sudarant algoritmą SSIM reikšmei apskaičiuoti, patariama naudoti vaizdo mažinimo fragmentą. Eksperimentais nustatyta, jog algoritmas be vaizdo mažinimo fragmento yra gerokai lėtesnis ir kuo tiriamas vaizdas didesnis, tuo daugiau užtrunka algoritmo vykdymas. Be to, tyrimais nustatyta, kad gaunamos SSIM reikšmės labai priklauso nuo tiriamų vaizdų dydžio, ypač, jeigu yra keičiama vaizdo struktūra.

Tiriant didelės raiškos vaizdus, apdorotus JPEG algoritmų variacijomis, vaizdo mažinimo fragmentą SSIM algoritme siūloma realizuoti taikant artimiausio kaimyno interpoliaciją, tokiu būdu gaunamos reikšmės gerai atspindi skirtumus. Tiriant aukštos raiškos vaizdus, kai SSIM reikšmės kinta tik šimtosiose dalyse, dėl informatyvumo tikslinga skaičiuoti ne struktūrinį panašumą, o pasiūlytą atvirkštinį panašumo indeksą ISSIM.

3.2 JPEG algoritmo poveikis vaizdų kokybei

Šiame poskyryje aprašomi trys atlikti eksperimentiniai tyrimai, kuriais siekiama nustatyti, kaip JPEG algoritmas veikia vaizdų kokybę. Dalis minėtų tyrimų pristatyta darbe [1 A]. Atsižvelgiant į tai, kad JPEG algoritmas ir kokybės vertinimo algoritmai vienas nuo kito nepriklauso, daroma prielaida, kad JPEG algoritmas turės skirtingą poveikį vaizdams, priklausomai nuo vaizdų turinio ir prigimties.

Pirmasis eksperimentas

Pirmajam skyriaus eksperimentui parenkami keturi atsitiktiniai vaizdai iš turisto kelionės: Turkey1 (13 pav. (a)), Turkey2 (13 pav. (b)), Turkey3 (13 pav. (c)), Turkey4 (13 pav. (d)). Vaizdai yra 3872×2592 dydžio, gauti veidrodiniu fotoaparatu Nikon D60, naudojant identiškus

nustatymus. Daroma prielaida, kad apdorojus šiuos vaizdus tuo pačiu JPEG algoritmu, bus gauti ne vienodos kokybės vaizdai.



(a) *Turkey1*



(b) *Turkey2*



(c) *Turkey3*



(d) *Turkey4*

13 pav. Vaizdai iš turisto kelionės

Vaizdai apdorojami JPEG glaudinimo algoritmu išlaikant numatytuosius nustatymus, bet keičiant kokybės faktorių. Pirmuoju atveju visi vaizdai yra suspaudžiami nustatant kokybės faktoriaus reikšmę – 90. Antruoju atveju visi pradiniai vaizdai keičiami nustatant kokybės faktoriaus reikšmę – 50. Gautų vaizdų kokybė vertinama SSIM indekso metodu ir MSE, lyginant pradinius bei apdorotus vaizdus. Dėl patogumo kokybė išreikšta ne struktūrinio panašumo (SSIM) indeksu, o atvirkštiniu struktūrinio panašumo (ISSIM) indeksu (pagal formulę (38)). Pradinių bei pakeistų vaizdų dydžiai po apdorojimo JPEG algoritmu, esant anksčiau išvardintiems nustatymams, pateikti 6 lentelėje, o 7 lentelėje pateikti pakeistų vaizdų kokybės pokyčiai bei pakeistų vaizdų vidutinio kvadratinio nuokrypio (MSE) pokyčiai.

6 lentelė. Pradinių bei pakeistų vaizdų dydžiai (1 eksp.)

	Pradinis vaizdas (failo dydis MB)	QF=90 (failo dydis MB)	QF=50 (failo dydis MB)
<i>Turkey1</i>	28,7	1,7	0,7
<i>Turkey2</i>	28,7	1,9	0,7
<i>Turkey3</i>	28,7	1,7	0,7
<i>Turkey4</i>	28,7	1,9	0,8

7 lentelė. Pradinių bei pakeistų vaizdų kokybės pokyčiai (1 eksp.)

	Pradinis vaizdas ISSIM (MSE)	QF=90 ISSIM (MSE)	QF=50 ISSIM (MSE)
<i>Turkey1</i>	0 (0)	0,5 (2,5)	1,7 (8,9)
<i>Turkey2</i>	0 (0)	1,0 (3,3)	3,1 (11,8)
<i>Turkey3</i>	0 (0)	1,1 (3,6)	2,8 (12,6)
<i>Turkey4</i>	0 (0)	0,5 (2,7)	1,5 (9,3)

Iš pateiktų rezultatų matyti, kad naudojant tuos pačius JPEG procedūros nustatymus, kokybiškesni vaizdai gaunami glaudinant *Turkey1* (13 pav. (a)) bei *Turkey4* (13 pav. (d)) vaizdus, o mažiau kokybiški spaudžiant *Turkey2* (13 pav. (b)) ir *Turkey3* (13 pav. (c)) vaizdus. Iš dalies taip yra dėl to, kad *Turkey2* ir *Turkey3* vaizduose yra aiškūs, kontrastingi perėjimai tarp atskirų dalių, tokių kaip kalnas ir dangus, o tokiose perėjimuose JPEG algoritmas padaro daug matomų artefaktų (specifinių triukšmų). *Turkey1* bei *Turkey4* vaizduose tokių aiškių perėjimų nėra, be to, šie vaizdai yra triukšmingi. Nors *Turkey4* vaizde taip pat yra perėjimas tarp vandens ir kalno, bet jis nėra staigus ir kontrastingas, o vandenyje yra daug smulkių bangelių. Be abejo, gali būti ir daug daugiau priežasčių, dėl kurių skiriasi apdorotų vaizdų kokybė.

Šiuo konkrečiu atveju matyti, kad turint apmokyta klasifikatorių, kuris suskirstytų vaizdus į klases tokiu būdu, kad pirmai klasei priklausytų *Turkey1* bei *Turkey4* vaizdai, o vaizdai *Turkey2* bei *Turkey3* – antrai klasei, ir pritaikius kiekvienai klasei skirtingus JPEG procedūros nustatymus, galima būtų arba sutaupyti failų užimamos vietos kiekį, arba pagerinti vaizdų grupės kokybę. Šis tyrimas parodo, kad konkrečiu atveju vaizdų klasifikavimas prieš taikant glaudinimo algoritmus gali būti naudingas taupant užimamą vietą saugykloje arba norint suvienodinti visų suspaustų vaizdų kokybę.

Antrasis eksperimentas

Atsižvelgiant į tai, kad darbe siekiama sukurti technologiją skirtingiems skaitmeniniams vaizdams glaudinti, antrojo eksperimento sąlygos praplečiamos.

Tyrimui naudojama SUN2012 (Xiao, 2010) skaitmeninių vaizdų duomenų bazė, kuri sudaryta iš 16 873 skirtingų vaizdų. Atrenkami septyni vaizdai pagal vienintelį kriterijų – vaizdai turi būti vienodo 2048×1536 dydžio (*Sun1–7*, 14 pav., (a)–(g)).

Vaizdai apdorojami JPEG glaudinimo algoritmu išlaikant numatytuosius nustatymus, bet keičiant kokybės faktoriaus reikšmę. Pirmuoju atveju visi vaizdai yra suspaudžiami nustatant QF reikšmę lygią 90. Antruoju atveju visi pradiniai vaizdai keičiami nustatant QF reikšmę lygią 50.

Pradinių bei pakeistų vaizdų dydžių lentelėje (8 lentelė) pateikti vaizdų dydžiai po apdorojimo JPEG algoritmu, esant anksčiau išvardintiems nustatymams, o vaizdų kokybės lentelėje (9 lentelė) yra pateikti pakeistų vaizdų kokybės pokyčiai bei pakeistų vaizdų vidutinio kvadratinio nuokrypio (MSE) pokyčiai.



(a) Sun1



(b) Sun2




(c) Sun3




(d) Sun4



(e) Sun5



(f) Sun6



(g) Sun7

14 pav. Vaizdai iš SUN2012 duomenų bazės

8 lentelė. Pradinių bei pakeistų vaizdų dydžiai (2 eksp.)

	Pradinis vaizdas (failo dydis MB)	QF=90 (failo dydis MB)	QF=50 (failo dydis MB)
<i>Sun1</i>	9,0	0,44	0,08
<i>Sun2</i>	9,0	0,70	0,39
<i>Sun3</i>	9,0	0,69	0,38
<i>Sun4</i>	9,0	0,52	0,14
<i>Sun5</i>	9,0	1,11	0,57
<i>Sun6</i>	9,0	0,62	0,18
<i>Sun7</i>	9,0	0,66	0,20

9 lentelė. Pradinių bei pakeistų vaizdų kokybės pokyčiai (2 eksp.)

	Pradinis vaizdas ISSIM (MSE)	QF=90 ISSIM (MSE)	QF=50 ISSIM (MSE)
<i>Sun1</i>	0 (0)	4,3 (4,1)	7,7 (7,6)
<i>Sun2</i>	0 (0)	0,2 (1,2)	3,3 (24,3)
<i>Sun3</i>	0 (0)	0,2 (1,1)	3,5 (25,7)
<i>Sun4</i>	0 (0)	3,9 (4,9)	7,6 (12,3)
<i>Sun5</i>	0 (0)	0,1 (2,2)	0,8 (12,5)
<i>Sun6</i>	0 (0)	3,5 (6,8)	8,9 (17,9)
<i>Sun7</i>	0 (0)	5,2 (11,4)	11,7 (25,8)

Antrojo eksperimento rezultatai yra informatyvesni nei pirmojo. Šiuo atveju, kaip ir pirmuoju, matyti, kad JPEG algoritmas vaizdų kokybę veikia ne vienodai, taip gaunamas skirtingas sutauptos vietos ir kokybės santykis (kai pradinis vaizdo dydis lyginamas su suspausto vaizdo dydžiu išlaikant tą patį QF). Skirtumas tame, kad antruoju atveju parinkti vaizdai, kurių kilmė nėra aiški. Pvz., mažinant QF, MSE rodiklis kinta netolygiai, taip yra galbūt dėl to, kad vaizdas jau prieš tai buvo apdorotas JPEG su panašiais nustatymais. Taip pat matyti, kad vertinant vaizdą pikselių

lygmenyje ir vertinant bendrą vaizdą, nėra jokios priklausomybės. Taip pat nėra tiesinės priklausomybės tarp JPEG deklaruojamų QF reikšmių ir kokybės vertinimo algoritmų rezultatų (šiuo atveju SSIM, MSE ir akivaizdu – PSNR). Kai kurių vaizdų kokybę JPEG algoritmas paveikia pagal SSIM, kai kurių pagal MSE, o kai kurių pagal abu matus ir atvirkščiai.

Trečiasis eksperimentas

Pirmasis eksperimentas parodo, kad vaizdo scena turi įtakos vaizdų kokybei po vaizdo glaudinimo JPEG. Bet pirmajame eksperimente buvo parinkti vaizdai, gauti tuo pačiu fotoaparatu su analogiškais nustatymais. Atsižvelgiant į tai, kad tyrimo objektas yra įvairūs skaitmeniniai vaizdai, gauti skirtingais fotoaparatais, trečiajam eksperimentui atrinkti panašūs pagal sceną vaizdai iš SUN2012 duomenų bazės (15 pav.). Nagrinėjamos trys panašios scenos: modeliai ant podiumo, pastatai, virš kurių matosi dangus, ir miegamieji kambariai su lovomis. Vaizdai apdorojami JPEG glaudinimo algoritmu išlaikant numatytuosius nustatymus, bet keičiant kokybės faktoriaus reikšmę. Pirmuoju atveju visi vaizdai yra suspaudžiami nustatant QF reikšmę lygią 90. Antruoju atveju visi pradiniai vaizdai keičiami nustatant QF reikšmę lygią 50.

Pradinių bei pakeistų vaizdų dydžių lentelėje (10 lentelė) pateikti vaizdų dydžiai po apdorojimo JPEG algoritmu, esant anksčiau išvardintiems nustatymams, o vaizdų kokybės lentelėje (11 lentelė) yra pateikti pakeistų vaizdų kokybės pokyčiai bei pakeistų vaizdų vidutinio kvadratinio nuokrypio (MSE) pokyčiai. Eksperimentas parodo, kad net panašios scenos vaizdus JPEG algoritmas veikia nevienodai, t. y. gaunami skirtingi kokybės matai.



(a) *Model1*



(b) *Model2*



(c) *Model3*



(d) *BuildHeaven*



(e) *BuildHeaven2*



(f) *BuildHeaven3*



(g) *BedRoom1*



(h) *BedRoom2*



(i) *BedRoom3*

15 pav. Vaizdai iš SUN2012 duomenų bazės pagal scenas


10 lentelė. Pradinių bei pakeistų vaizdų dydžiai (3 eksp.)

	Pradinis vaizdas (failo dydis MB)	QF=90 (failo dydis MB)	QF=50 (failo dydis MB)
<i>Model1</i>	5,69	0,36	0,09
<i>Model2</i>	4,88	0,3	0,09
<i>Model3</i>	5,12	0,18	0,07
<i>BuildHeaven1</i>	5,48	0,48	0,15
<i>BuildHeaven2</i>	4,84	0,44	0,13
<i>BuildHeaven3</i>	5,49	0,3	0,11
<i>BedRoom1</i>	4,75	0,3	0,11
<i>BedRoom2</i>	5,49	0,37	0,11
<i>BedRoom3</i>	4,57	0,27	0,1

11 lentelė. Pradinių bei pakeistų vaizdų kokybės pokyčiai (3 eksp.)

	Pradinis vaizdas ISSIM (MSE)	QF=90 ISSIM (MSE)	QF=50 ISSIM (MSE)
<i>Model1</i>	0 (0)	3,7 (5,3)	10,6 (18,1)
<i>Model2</i>	0 (0)	3,3 (6,1)	6,8 (15,4)
<i>Model3</i>	0 (0)	1,4 (2,6)	2,73 (7,3)
<i>BuildHeaven1</i>	0 (0)	3,2 (9,4)	8,1 (27,2)
<i>BuildHeaven2</i>	0 (0)	5,6 (11,8)	13,6 (31,9)
<i>BuildHeaven3</i>	0 (0)	1,8 (5,3)	4,1 (18,6)
<i>BedRoom1</i>	0 (0)	1,6 (5,2)	4,5 (16,6)
<i>BedRoom2</i>	0 (0)	3,2 (6,0)	7,3 (15,7)
<i>BedRoom3</i>	0 (0)	2,8 (9,3)	5,2 (20,5)

Norint parinkti tinkamą JPEG algoritmo nustatymą tam tikrai vaizdų grupei, kokybę reikia vertinti vienu kokybės matu arba ieškoti kelių matų sankirtos. Parinkti tinkamą kokybės matą nesudėtinga, kai vertinami specifiniai vaizdai, pvz., medicininiai / diagnostiniai vaizdai, palydoviniai vaizdai ir pan., gauti vienoda vaizdo fiksavimo įranga. Kai vertinami įvairūs vaizdai, gauti skaitmeniniais fotoaparatais ir neturintys specifinio turinio (šio darbo tyrimų objektas), būtina ieškoti kokybės matų suderinimo / sankirtos. Darbe (Forczmanski, 2014) pateiktos normuotos kokybės matų reikšmės pagal JPEG QF (16 pav.).



16 pav. Normuotos kokybės metrikų reikšmės pagal JPEG QF reikšmę (Forczmanski, 2014)

Atsižvelgiant į paveiksle pateiktą informaciją, šiame darbe kokybė bus vertinama derinant du kokybės matus (plačiau – darbe pristatytų vaizdų glaudinimo sprendimų tiriamojoje dalyje), vieną – pikselio lygmenyje (PSNR, priklausomo nuo MSE) ir kompleksinį vaizdo kokybės matą – SSIM.


3.2.1 Poskyrio išvados

Atlikus eksperimentinius tyrimus nustatyta, kad spaudžiant skirtingus vaizdus JPEG algoritmu su vienodu glaudinimo faktoriumi, gaunamas skirtingas glaudinimo efektyvumas ir kokybė. Vertinant vaizdą pikselių lygmenyje ir vertinant vaizdą kompleksiškai, nėra jokios priklausomybės. Taip pat nėra tiesinės priklausomybės tarp JPEG QF reikšmių ir kokybės vertinimo algoritmų rezultatų (šiuo atveju SSIM, MSE ir PSNR).

Tyrimai parodo, kad vaizdų klasifikavimas prieš taikant glaudinimo algoritmus gali būti labai naudingas taupant užimamą vietą informacijos saugykloje arba siekiant geresnės kokybės turimų vaizdų visumai. Kai vertinami įvairūs vaizdai, gauti skaitmeniniais fotoaparatais ir neturintys specifinio turinio, kokybės vertinimui būtina ieškoti kokybės matų suderinimo / sankirtos.


4. SIŪLOMI VAIZDŲ GLAUDINIMO SPRENDIMAI

Pagrindinė darbe iškelta hipotezė – naudojant klasifikavimą, kai klasifikatorius mokyta vaizdus apibūdinančiais požymiais, galima numatyti, kaip glaudinimo algoritmas įtakos suspaustus vaizdus, kai vaizdai suskirstomi į klases pagal vaizdų kokybę, kas leistų taupyti vaizdų užimamą vietą. Kitaip tariant, jeigu klasifikatorius yra juoda dėžė, o įvestis – informacija apie konkretų vaizdą, galima gauti atsakymą: kaip stipriai konkretus glaudinimo algoritmas paveiks vaizdo kokybę, kuomet kokybė vertinama objektyviais vaizdų kokybės vertinimo metodais (17 pav.).



17 pav. Darbe iškelta hipotezė

Siūloma vaizdų glaudinimo technologijos koncepcija pateikta 18 pav. Ją sudaro dvi dalys: klasifikatoriaus mokymas; vaizdų glaudinimas atsižvelgiant į klasę, kuriai priskirtas vaizdas. Pagrindinė problema yra ta, kad vaizdai priskiriami klasėms, atsižvelgiant į vaizdų kokybę po vaizdo glaudinimo, kai kokybė vertinama objektyviais kokybės vertinimo metodais, o klasifikuoti vaizdus reikia atsižvelgiant į vaizdus apibūdinančius požymius. Šios problemos esmė yra ta, kad objektyvūs vaizdo kokybės vertinimo metodai ir algoritmai kuriami atsižvelgiant į žmogaus vaizdo suvokimo ypatybes, o vaizdų glaudinimo metodai ir algoritmai su informacijos praradimu kuriami siekiant išsaugoti, atkurti, atvaizduoti kuo didesnę informacijos kiekį. Nėra tiesioginio ryšio tarp išsaugotos informacijos kiekio ir gauto vaizdo kokybės.



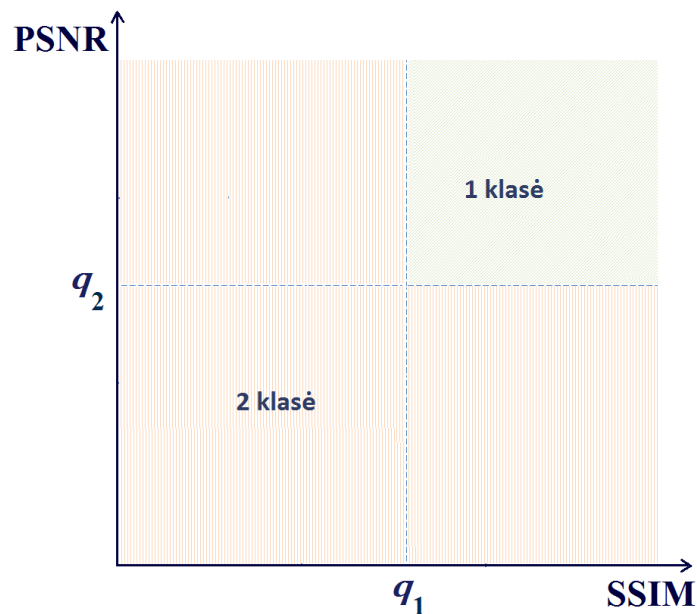
18 pav. Siūlomos skaitmeninių vaizdų grupių glaudinimo technologijos koncepcija: a) klasifikatoriaus mokymas; b) vaizdų grupės glaudinimas

Siekiant disertacijoje užsibrėžto tikslo – pasiūlyti skaitmeninių vaizdų grupių glaudinimo technologiją, siekiant taupyti vaizdų užimamą vietą, išlaikant pageidaujamą kokybę, nuspręsta empiriškai patikrinti iškeltą hipotezę ir ją patvirtinti. Tuo tikslu buvo atlikti tyrimai (pristatyti 3 skyriuje ir darbuose [1 A]–[3 A], [6 A]–[8 A]) ir atsižvelgiant į jų rezultatus, pasiūlytas ir ištirtas vaizdų grupių glaudinimo JPEG algoritmu būdas, kai klasifikuojama į dvi klases (pristatytas 4 skyriuje ir darbuose [5 A], [9 A], [10 A]). Atsižvelgiant į gautus rezultatus ir suformuotas išvadas, disertacijoje pasiūlyta vaizdų grupių glaudinimo technologija ir šia technologija grįstas būdas įvairiems vaizdams, neturintiems specifinio turinio, glaudinti JPEG, kai klasifikuojama į tris klases (4.2 ir 4.3 poskyriai).


4.1 Vaizdų grupių glaudinimo JPEG algoritmu būdas, kai klasifikuojama į dvi klases

Visi šio poskyrio tyrimai yra pristatyti darbe [5 A]. Poskyryje pristatomas būdas apdoroti vaizdų grupę JPEG algoritmu taip, kad visi apdoroti vaizdai tenkintų minimalų kokybės slenkstį, o kokybės faktorius būtų parenkamas automatiškai.

Kokybės slenkstis nustatomas tokiu būdu – vaizdai, apdoroti JPEG algoritmu, kurių $SSIM > q_1$ ir $PSNR > q_2$, priskiriami pirmai klasei (vaizdai, kurių kokybė kito mažiau), o visi kiti vaizdai priskiriami antrai klasei (vaizdai, kurių kokybė kito labiau) (19 pav.). Siūlomo vaizdų glaudinimo JPEG algoritmu būdo (kai klasifikuojama į dvi klases) procesas pavaizduotas 20 pav.



19 pav. Kokybės slenkščių nustatymas (2 klasės)



20 pav. Siūlomas vaizdų grupių glaudinimo būdas (2 klasės):

a) klasifikatoriaus mokymas; b) vaizdų grupės glaudinimas JPEG

4.1.1 Siūlomo būdo tyrimas (klasifikuojama į dvi klases)

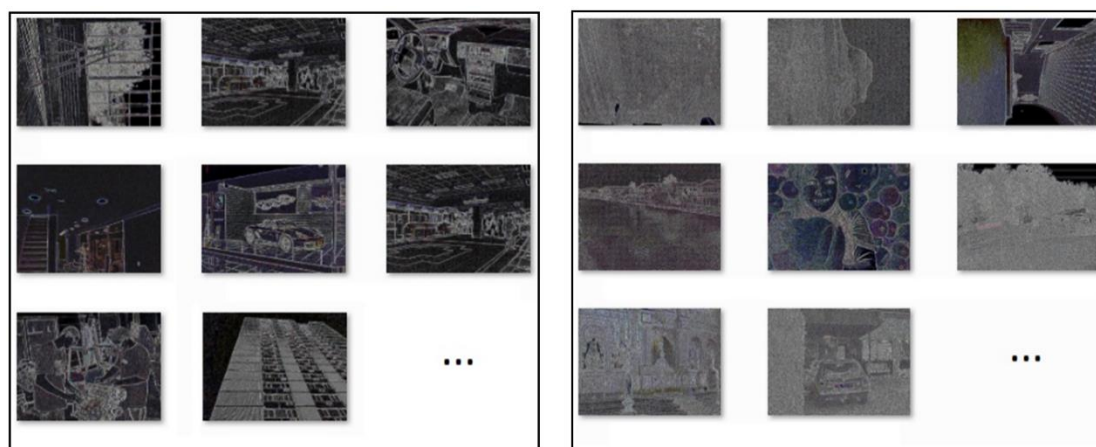
Klasifikatoriaus formavimas

Vaizdas yra aprašomas d -mačiu vektoriumi $S = (s_1, s_2, \dots, s_d)$, o Y'_1, Y'_2, \dots, Y'_l žymi klases, kurioms gali priklausyti vaizdas, l – klasių skaičius. Remiantis vaizdą aprašančiu vektoriumi S , nustatomi vaizdo požymiai x_n ir sudaromas vektorius $X' = (x_1, x_2, \dots, x_n)$, čia $n \leq d$. Iš požymių reikšmių sudaryti vaizdus atitinkantys daugiamaciai vektoriai X'_1, X'_2, \dots, X'_m , čia $X'_i = (x_{i1}, x_{i2}, \dots, x_{in})$, m – analizuojamų vaizdų (vektorių) skaičius. Vektorių X'_1, X'_2, \dots, X'_m atvaizdavimui į klasių žymių aibę Y'_j naudojamas LDA klasifikatorius.

Klasifikavimo reikšmės: klasių kiekis $l = 2$; požymių kiekis $n = 9$; vaizdų (vektorių) kiekis $m = 405$; klasifikavimo tikslumas (angl. *accuracy*) vertinamas atliekant 10-ies dalių kryžminį patikrinimą.

Vaizdus apibūdinantys požymiai

Požymiai parenkami atsižvelgiant į eksperimentinius bandymus, kurie buvo daromi siekiant pagerinti klasifikavimo tikslumą. Darbe [2 A] buvo atliekami tyrimai, siekiant nustatyti, kokie vaizdus apibūdinantys požymiai turi būti naudojami klasifikatoriaus mokymui, kai vaizdų kokybė vertinama SSIM indekso metodu, o vaizdai padalinti į dvi klases pagal jų kokybę po apdorojimo JPEG. Atsižvelgiant į tai, kad JPEG algoritmas mažina tarpinių spalvų skaičių bei keičia vaizdo struktūrą, minėtame darbe daroma prielaida, kad panaudojus kraštų aptikimo (angl. *Edge Detection*) filtrą originaliam vaizdui, galima išryškinti tas vietas, kurias JPEG algoritmas labiausiai paveiks mažindamas tarpinių spalvų skaičių ir keisdamas struktūrą.



Pirma klasė


Antra klasė

21 pav. Pirmos ir antros klasės vaizdai, apdoroti Laplaso kraštų aptikimo filtru

Rezultatai parodė, kad panaudojus Sobelio (angl. *Sobel Edge Detection*) arba Laplaso (angl. *Laplacian Edge Detection*) (Maini, 2009) kraštų aptikimo filtrus kiekvienai RGB komponentei, o gautą rezultatą (pavertus į pilkąją skalę) užrašius vektoriais, klasifikavimo tikslumas auga.

Vaizdų, apdorotų Laplaso kraštų aptikimo filtru, grupės fragmentai pateikti 21 pav. Matomi gan ryškūs skirtumai tarp skirtingų klasių vaizdų.

Atsižvelgiant į tai, kad darbe [2 A] klasės nustatomos tik pagal vieną kokybės matą, t. y. SSIM, o siūlomam vaizdų glaudinimo būdai dėl objektyvumo parinkta dviejų matų sankirta, buvo atlikta daugiau eksperimentų su kitais kraštų aptikimo filtrais. Geriausi rezultatai gauti naudojant Prewitto kraštų aptikimo filtrą (Prewitt, 1970). Atsižvelgiant į gautus rezultatus (jie pristatyti kitame poskyryje), žemiau aprašyti siūlomi vaizdus apibūdinantys požymiai.



22 pav. Panašių spalvų regionai vaizde

Originalus vaizdas aprašomas vektoriumi $X'_i = (x_{i1}, x_{i2}, \dots, x_{i9}) = (Q_i, MR_i, MG_i, MB_i, SR_i, SG_i, SB_i, AB_i, AS_i)$, čia Q_i parodo, kiek sunaudojama fizinės atminties vienam pikseliui (santykis tarp pikselių kiekio ir failo dydžio). Kiti požymiai gaunami iš vaizdų, prieš tai juos apdorojant aukšto dažnio Prewitto kraštų aptikimo filtru pagal kiekvieną spalvos komponentę RGB (Prewitto kraštų aptikimo filtro naudojimas nežymiai padidino klasifikavimo tikslumą, lyginant su [2 A] darbe naudotais filtrais):

- MR_i, MG_i, MB_i – vidutinės pikselių reikšmės pagal kiekvieną spalvos komponentę RGB;
- SR_i, SG_i, SB_i – standartiniai nuokrypiai pagal RGB;
- AB_i, AS_i – atitinkamai didelių ir mažų regionų kiekiai vaizduose, kuriems buvo pritaikytas binarizavimas pagal automatinį slenkstį (Otsu, 1979). Atsižvelgiant į tai, kad JPEG naudojamas DCT taikomas vienodo dydžio blokams, regionai nustatomi nekeičiant vaizdo rezoliucijos. Mažų ir didelių regionų vaizde pavyzdys parodytas 22 pav.

4.1.2 Klasifikavimas

Vaizdų klasifikavimo eksperimentiniam tyrimui panaudota SUN2012 (Xiao, 2010) skaitmeninių vaizdų duomenų bazė, kuri sudaryta iš 16 873 skirtingų vaizdų. Vaizdų apdorojimui JPEG, požymių išskyrimui, klasifikatoriaus formavimui ir klasifikavimui naudojama MATLAB aplinka.

Eksperimentams atsitiktinai buvo atrinkti 405 skirtingi vaizdai, kurių matmenys ne mažesni nei 1024×768 pikselių. Šie vaizdai suspaudžiami JPEG algoritmu su žemu QF ir apskaičiuota suspaustų vaizdų kokybė lyginant juos su originaliais vaizdais. Gautos SSIM reikšmės svyruoja nuo 0,802 iki 0,999, PSNR nuo 25,7 iki 57,3. Atsižvelgiant į tai, kad nėra galimybės nustatyti SUN2012 duomenų bazėje esamų vaizdų kilmės (kokiais fotoaparatais šie vaizdai buvo fiksuojami ir kokiais algoritmais apdoroti), mokymo klasės atrenkamos atsitiktinai, neatsižvelgiant į vaizdo sceną.

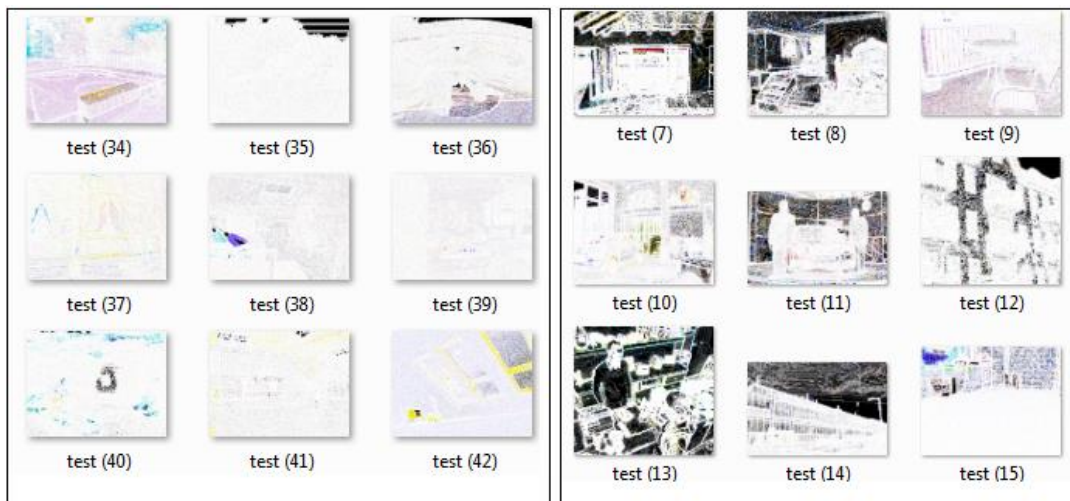
Iš eksperimentiniame tyrime naudojamų vaizdų buvo sudarytos $l = 2$ klasės tokiu būdu:

- Iš eksperimentinių vaizdų atrenkama 200 vaizdų su didžiausia SSIM reikšme ir 200 vaizdų su didžiausia PSNR reikšme. Šių dviejų grupių vaizdų sankirta priskiriama pirmai

klasei (viso 116 vaizdų). Laikoma, kad šių vaizdų kokybė po glaudinimo JPEG kito mažiau;

- Likę vaizdai priskiriami antrai klasei (iš viso 289 vaizdai). Šių vaizdų kokybė po glaudinimo JPEG kito labiau.

Aukščiau aprašytu būdu išskiriami vaizdus apibūdinantys požymiai. Kadangi dauguma požymių išskirta vaizdus apdorojus Prewitto kraštų aptikimo filtru, skirtingų vaizdų klasių fragmentai pateikti 23 pav.



Pirma klasė

Antra klasė

23 pav. Pirmos ir antros klasės vaizdų grupių, apdorotų Prewitt'o kraštų aptikimo filtru, fragmentai

Vaizdų klasifikavimui gali būti naudojami skirtingi klasifikavimo metodai, bet anksčiau vykdyti tyrimai parodė, kad klasifikavimo rezultatui didžiausią įtaką daro požymių išskyrimas, o ne klasifikavimo metodo parinkimas.

Atlikus kryžminį patikrinimą nustatyta, kad bendras klasifikavimo tikslumas (angl. *accuracy*) yra 0,85. Šis skaičius nėra labai informatyvus, nes klasių elementų kiekis skiriasi. Daugiau galima pasakyti žiūrint į 12 lentelėje pateiktą klasifikavimo matricą ir 13 lentelėje pateiktus klasifikavimo rezultatus.

12 lentelė. Klasifikavimo matrica (naudojant LDA), kai vaizdai klasifikuojami pagal 9 atrinktus požymius

	Prognozuojamos klasės		
		1 klasė	2 klasė
Tikrosios klasės	1 klasė	66	50
	2 klasė	11	278

13 lentelė. Duomenų klasifikavimo tikslumo rezultatai (LDA)

	Tikslumas (Precision)	Jautrumas (Recall)
1 klasė	0,57	0,86
2 klasė	0,96	0,85

Nors pirmą klasę klasifikatorius atpažįsta prastai (66 vaizdai priskirti teisingai klasei, o 50 vaizdų – ne), antros klasės klasifikavimo tikslumas (angl. *precision*) – 0,96. Tai yra gerai, nes būtent antrai klasei taikoma didesnė QF reikšmė (20 pav. b)), todėl kokybė nenukentės, t. y. neteisingai suklasifikuotiems pirmos klasės vaizdams bus pritaikyta antros klasės nustatyta QF reikšmė.

4.1.3 Standartinio JPEG algoritmo ir siūlomo būdo

(klasifikuojama į dvi klases) palyginimas

Su aukščiau aprašytais duomenimis buvo atliktas eksperimentas, kuriame buvo palygintas vaizdų glaudinimo būdas bei standartinis JPEG. Abiems algoritmams buvo nustatyta būtinoji sąlyga, kad vaizdų kokybė po glaudinimo tenkintų tokius reikalavimus: $q_1 = 0,91$ ir $q_2 = 33$, t. y. $SSIM > 0,91$ ir $PSNR > 33$.

Eksperimentas kartotas 10 kartų su vis kitais vaizdais. Po glaudinimo paskaičiuoti ir palyginti failų dydžiai.

Buvo parinktas toks standartinio JPEG QF=95, kad visi vaizdai po glaudinimo tenkintų nustatytą kokybės slenkstį. Siūlomam būdui buvo parinkti skirtingi QF: aukštas QF=95 (kuris lygus parinktam standartinio JPEG QF) ir žemas QF=30. Žemas QF buvo parinktas atsižvelgiant į vaizdų klases taip, kad tik pirmos klasės vaizdai tenkintų kokybės slenkstį. Kiekviename klasifikatoriaus kryžminio patikrinimo etape buvo fiksuojamos vaizdų grupės pagal klases ir atitinkamoms klasėms buvo taikomas atitinkamas QF. Tai pat buvo fiksuoti gautų failų dydžiai. Eksperimento rezultatai pateikti 14 lentelėje.

Iš pateiktų rezultatų matyti, kad taikant siūlomą būdą, galima sutaupyti apie 15 % vaizdų užimamos vietos, išlaikant nustatytą kokybę (lyginant su standartiniu JPEG). Nors antros klasės vaizdus klasifikatorius nuspėdavo su 0,04 klaida, šiuo atveju neatsirado nei vieno vaizdo, kuris netenkintų kokybės sąlygos (visi 405 vaizdai tenkino kokybės slenkstį).

14 lentelė. Palyginamojo eksperimento rezultatai

Patikrinimo Nr.	Standartinis JPEG (užimamos vietos kiekis MB)	Siūlomas būdas (užimamos vietos kiekis MB)
1	35,3	29,4
2	19,1	16,8
3	71,6	58,3
4	19,2	17,5
5	32,6	30,1
6	52,2	41,5
7	34,5	31,1
8	22,1	20,3
9	50,4	38,7
10	27,5	25,7
Viso:	364,5	309,4


4.1.4 Poskyrio išvados

Šiame poskyryje pristatytas ir ištirtas klasifikavimu grįstas būdas glaudinti vaizdus JPEG algoritmu, kai klasifikuojama į dvi klases. Būdas sudarytas iš dviejų dalių: klasifikatoriaus mokymas; vaizdų glaudinimas JPEG atsižvelgiant į klasę, kuriai priskirtas vaizdas. Klasifikatoriaus mokymas vyksta vieną kartą, o vaizdų glaudinimas su apmokytu klasifikatoriumi gali būti naudojamas neapibrėžtą laiką. Didžiausias šio būdo privalumas yra tas, kad klasifikavimas leidžia numatyti, kaip JPEG algoritmas paveiks vaizdo kokybę ir pagal tai galima nustatyti JPEG QF reikšmę kiekvienam vaizdui dar prieš taikant JPEG. Vaizdų glaudinimas šiuo būdu leidžia sutaupyti failų užimamos vietos kiekį, išlaikant aukštą vaizdų kokybę. Eksperimentinis tyrimas parodė, kad lyginant standartinį JPEG su siūlomu būdu, galima sutaupyti apie 15 % vaizdų užimamos vietos kiekio. Šio būdo taikymas ypač naudingas dirbant su didelėmis vaizdų grupėmis. Atsižvelgiant į pateiktus tyrimus daroma prielaida, kad klasifikavimas į didesnę klasių kiekį gali padidinti sutaupytos vietos kiekį.

Remiantis atliktais eksperimentais daroma išvada, kad tinkamas požymių ir mokymo klasių parinkimas svarbus rezultatams, todėl vėlesniuose tyrimuose tikslinga patikslinti požymių nustatymo procesą, o klasių slenkstį nustatyti naudojant didesnes vaizdų imtis (susiję sprendimai yra detaliam pristatyti ir eksperimentiškai ištirti 4.2 ir 4.3 poskyriuose).

4.2 Siūloma vaizdų glaudinimo technologija

Disertacijoje siūloma technologija, skirta skaitmeninių vaizdų grupėms glaudinti, siekiant taupyti ne tik vaizdų užimamą vietą, bet ir išlaikyti norimą kokybę.



24 pav. Vaizdų grupės glaudinimo procesas

Pagrindinė technologijos idėja yra klasifikuoti vaizdus prieš naudojant glaudinimo algoritmą, o glaudinimo algoritmo parametrus / nuostatas parinkti atsižvelgiant į klasifikavimo rezultatą. Glaudinimo algoritmo parametrai parenkami siekiant patenkinti nustatytą kokybės slenkstį. Vaizdų grupės glaudinimo procesas pavaizduotas 24 pav.

Proceso (24 pav.) aprašymas:

V1 – duomenų perdavimas gali būti iš lokaliai saugojimo vietos arba iš vaizdo fiksavimo įrangos;

V2 – naudojami vaizdų kokybės vertinimo matai. Nustatoma(-os) kokybės slenksčio skaitinė(-ės) reikšmė(-ės);

S1 – naudojami klasifikavimo metodai, klasifikatoriaus formavimas aprašytas žemiau;

S2 – glaudinimo algoritmo parametrai (nuostatos) kiekvienai klasei parenkami taip, kad kiekvienos klasės vaizdų kokybė po glaudinimo tenkintų nustatytą kokybės slenkstį;

S3 – kiekvienos klasės vaizdai spaudžiami tai klasei nustatytu glaudinimo algoritmu;

S4 – vaizdai saugomi nustatytu formatu.

Klasifikatoriaus formavimas:

Tarkime, vaizdas aprašomas d -mačiu vektoriumi $S = (s_1, s_2, \dots, s_d)$, o Y'_1, Y'_2, \dots, Y'_l žymi klases, kurioms gali priklausyti vaizdas, l – klasių skaičius. Klasifikavimo uždavinys sprendžiamas tokiais etapais:

- 1) Remiantis vaizdą aprašančiu vektoriumi S , nustatomi vaizdo požymiai x_p ir sudaromas vektorius $X' = (x_1, x_2, \dots, x_p)$, čia $p \leq d$. Reikia rasti kuo mažesnę požymių skaičių p , neprarandant daug informacijos apie vaizdą. Iš požymių reikšmių sudaromi vaizdus atitinkantys daugiamačiai vektoriai X'_1, X'_2, \dots, X'_n , čia $X'_i = (x_{i1}, x_{i2}, \dots, x_{ip})$, n – analizuojamų vaizdų (vektorių) skaičius. Kiekvienas vektorius $X'_i, i = 1, \dots, n$, yra priskiriamas vienai iš klasių $Y'_k, k \in [1, \dots, l]$.

Sukuriamas klasifikatorius, remiantis vaizdus charakterizuojančiais vektoriais X'_1, X'_2, \dots, X'_n . Klasifikatoriumi vadinamas vektorių X'_1, X'_2, \dots, X'_n atvaizdis į klasių žymių aibę Y'_1, Y'_2, \dots, Y'_l . Pagal sukurtą klasifikatorių vaizdas, kurio klasė nėra žinoma, priskiriamas vienai iš žinomų klasių.

Klasifikatoriaus formavimo proceso (25 pav.) aprašymas:

K1 – parenkama reprezentatyvi vaizdų grupė. Reprezentatyvi imtis formuojama atsižvelgiant į vaizdų pobūdį ir prigimtį (medicininiai vaizdai, GIS vaizdai, kasdienės fotografijos ir kt.);

K2 – vaizdai apdorojami glaudinimo algoritmu. Naudojamas tas pats glaudinimo algoritmas, kuris bus naudojamas vaizdų glaudinimo procese. Algoritmo nuostatos parenkamos taip, kad algoritmas kuo stipriau paveiktų vaizdo kokybę (prarastų daugiau informacijos). Tai daroma tam, kad būtų gautas kuo didesnis kokybės matų diapazonas, palengvinantis klasių formavimą;

K3 – naudojant vaizdų kokybės vertinimo matavimus, įvertinama gautų vaizdų kokybė, lyginant juos su pradiniais vaizdais;

K4 – išskiriami (nustatomi, apskaičiuojami) vaizdus apibūdinantys požymiai. Požymiai išskiriami atsižvelgiant į vaizdų pobūdį ir prigimtį;

K5 – apskaičiuojamos koreliacijos tarp vaizdus apibūdinančių požymių skaitinių reikšmių;

K6 – atrenkami silpniausiai koreliuojantys požymiai;

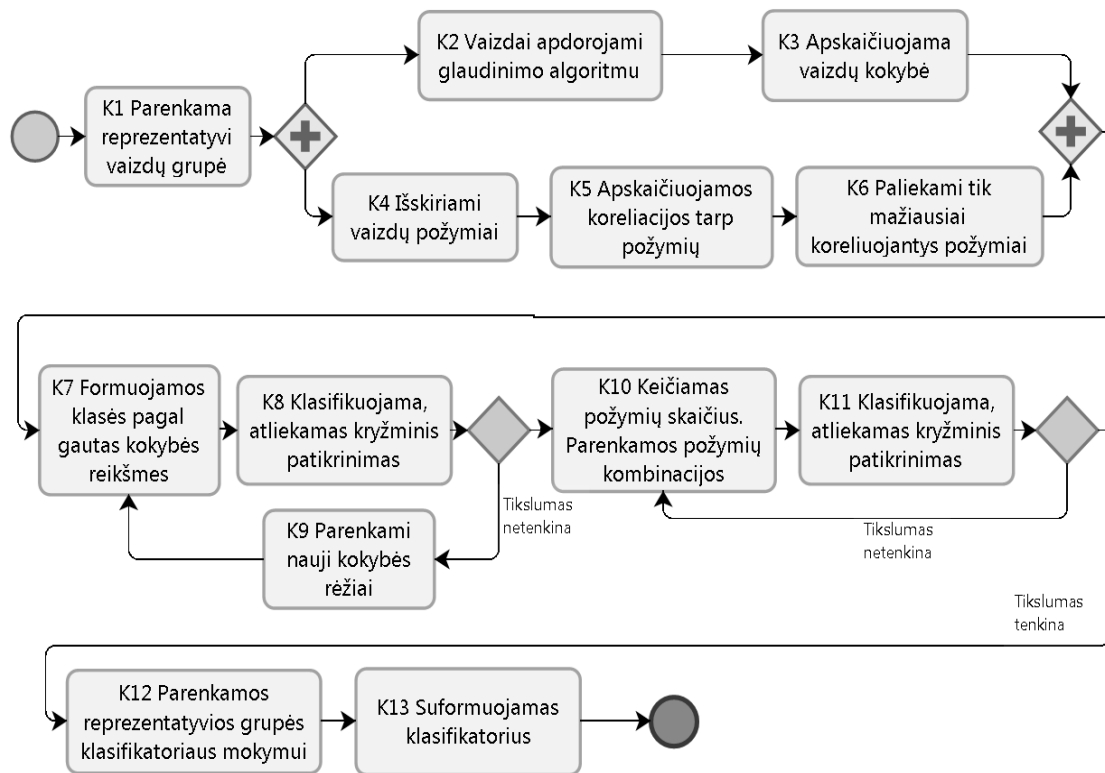
K7 – pagal nustatytas kokybės reikšmes formuojamos klasės. Klasių kiekis nustatomas įvertinus, kaip skirtingai naudotas glaudinimo algoritmas įtakoja atskirų vaizdų kokybę, t.y., koks gautų kokybės reikšmių nuokrypis. Nustatoma(-os) kokybės slenksčio skaitinė(-ės) reikšmė(-ės);

K8 – naudojami klasifikavimo metodai. Klasifikatorius mokomas nustatytais požymiais, atsižvelgiant į suformuotas klases. Klasifikavimo tikslumas nustatomas kryžminio patikrinimo metu;

K9 – jeigu klasifikavimo tikslumas yra mažas ir netenkina vartotojo, formuojamos naujos klasės, pagal kitą(-us) kokybės slenkstį(-čius) (kokybės matų režį(-ius));

K10, K11 – mažinamas požymių skaičius, parenkamos skirtingos požymių kombinacijos tol, kol gaunamas tenkinantis klasifikavimo tikslumas. Klasifikatorius mokomas skirtingomis požymių kombinacijomis, atsižvelgiant į suformuotas klases. Klasifikavimo tikslumui nustatyti naudojamas kryžminis patikrinimas;

K12, K13 – kiekvienai klasei parenkamos reprezentatyvios vaizdų klasės, suformuojamas klasifikatorius, kuris bus naudojamas vaizdų glaudinimo procese, pateiktame 26 pav.




25 pav. Klasifikatoriaus formavimas

4.3 Vaizdų grupių glaudinimo JPEG algoritmu būdas, kai klasifikuojama į tris klases

Šiame poskyryje pristatomas būdas apdoroti vaizdų grupę JPEG algoritmu taip, kad visi apdoroti vaizdai tenkintų minimalų kokybės slenkstį, o kokybės faktorius būtų parenkamas automatiškai. Kitaip tariant, siūlomas būdas, kuris leidžia numatyti, kaip JPEG algoritmas paveiks vaizdų kokybę.

Siūlomo būdo procese sprendžiamas klasifikavimo uždavinys, siekiant suskirstyti vaizdus į tris klases, priklausomai nuo to, kaip stipriai JPEG algoritmas paveiks jų kokybę. Kokybės slenkstis apskaičiuojamas naudojant kokybės vertinimo matus. Siekiant objektyvumo, kokybė vertinama dviem matais: pikselio lygmenyje naudojant PSNR, o bendras vaizdo pasikeitimas, apskaičiuojant SSIM. Kokybės slenkščiai nustatomi šių matų sankirtose. Siūlomo vaizdų glaudinimo JPEG algoritmu būdo procesas pavaizduotas 26 pav.



26 pav. Siūlomas vaizdų grupių glaudinimo būdas (3 klasės):
 a) klasifikatoriaus mokymas; b) vaizdų grupės glaudinimas JPEG


Klasifikatoriaus formavimas siūlomam sprendimui

Taikant ankščiau aprašytą technologiją vaizdams glaudinti, apdorojant juos JPEG algoritmu, siūloma vaizdus klasifikuoti į tris klases. Klasifikavimas į daugiau nei 3 klases nėra tikslingas, nes apdorotų vaizdų kokybė nėra pasiskirsčiusi tokiu plačiu diapazonu, kad būtų galima suformuoti daugiau skirtingų klasių.

Formuojant mokymo klases laikomasi šių taisyklių:

- pirmai klasei priskiriami vaizdai, kurių kokybė po JPEG algoritmo pakito mažiausiai ($SSIM > q_{s1}$ ir $PSNR > q_{p1}$);
- antrai klasei priskiriami vaizdai, kurių kokybė pakito labiausiai ($SSIM < q_{s2}$ ir $PSNR < q_{p2}$);
- trečiai klasei priskiriami vaizdai, kurių kokybė kito vidutiniškai ($q_{s2} < SSIM < q_{s1}$ ir $q_{p2} < PSNR < q_{p1}$).

Kokybės slenksčiai ir vaizdų skirstymas į klases parodyti 27 pav. Atkreiptinas dėmesys, kad ne visi vaizdai patenka į nustatytas ribas, o griežtos ribos nustatytos siekiant tikslesnio klasifikatoriaus mokymo.



27 pav. Kokybės slenksčių nustatymas (3 klasės)

4.4 Siūlomo būdo tyrimas (klasifikavimas į tris klases)

4.4.1 Klasifikavimas

Tolimesniems eksperimentiniams tyrimams panaudota SUN2012 (Xiao, 2010) skaitmeninių vaizdų duomenų bazė, kuri sudaryta iš 16873 skirtingų vaizdų. Naudojami vaizdai, kurių matmenys ne mažesni nei 1024×768 taškų (viso tokių vaizdų yra 2963). Vaizdai, pradiniam vaizdų priskyrimui klasėms, yra apdorojami JPEG algoritmu su maža kokybės faktoriaus reikšme $QF=30$. Apskaičiuojami gautų vaizdų kokybės pokyčiai: gautos SSIM reikšmės nuo 0,69 iki 0,999, PSNR – nuo 20,3 iki 57,3.

Atsižvelgiant į tai, kad nėra galimybės nustatyti SUN2012 duomenų bazėje esamų vaizdų kilmės (kokiais fotoaparatais šie vaizdai buvo fiksuojami ir kokiais algoritmais apdoroti), mokymo klasės atrenkamos atsitiktinai, neatsižvelgiant į vaizdo sceną (ankstesniais eksperimentais parodyta, kad vaizdo scena turi įtakos suspausto vaizdo

kokybei, bet sąryšį galima nustatyti tik tuomet, kai vertinami tuo pačiu fotoaparatu fiksuoti vaizdai).

Klasifikavimui atrenkama 450 vaizdų, po 150 vaizdų kiekvienai klasei. Naudojamas sprendimų medžio metodas, tiesinė diskriminantinė analizė ir atraminių vektorių klasifikatorius daugeliui klasių (angl. *Multi-Class SVM*).

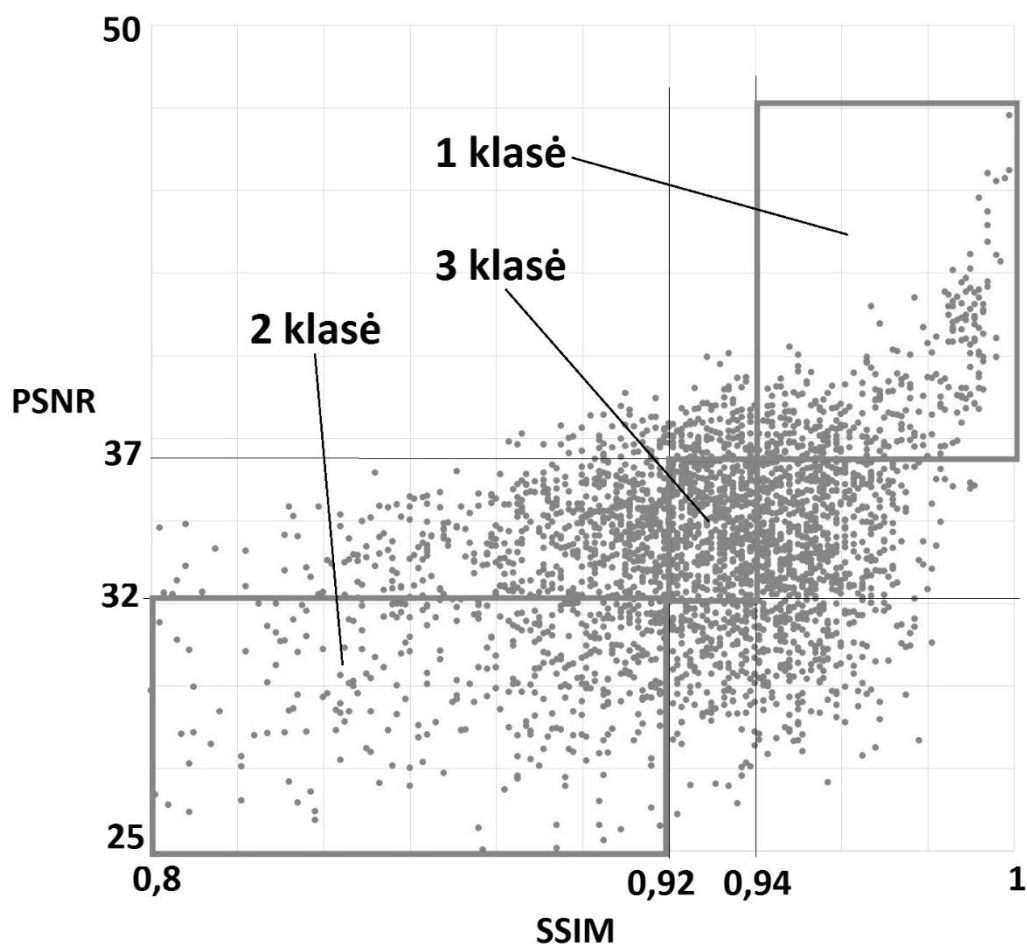
15 lentelė. Kokybės slenksčio reikšmės, su kuriomis gautas geriausias klasifikavimo tikslumas

q_{s1}	q_{s2}	q_{p1}	q_{p2}	Tikslumas
0,94	0,92	37	32,5	72,9
0,94	0,92	37	33,5	73,0
0,94	0,92	37	34	73,1
0,94	0,925	37	33	73,3
0,94	0,91	37	33,5	73,3
0,935	0,92	37	33	73,3
0,935	0,91	37	32,5	73,3
0,94	0,92	37	32	73,4

Klasifikatoriaus tikslumas (angl. *Accuracy*) apskaičiuojamas naudojant 10-ies dalių kryžminį patikrinimą. Kokybės slenksčio skaitinės reikšmės (ribos) nustatytos technologijos aprašyme pateiktu būdu (žr. 25 pav., K7, K8, K9 ir 27 pav.). Tam, kad būtų nustatytos kokybės slenksčių ribos, buvo skaičiuojamas LDA klasifikatoriaus tikslumas, perrenkant visas kokybės režių kombinacijas tokiuose intervaluose: SSIM – $0,92 < q_{s1} < 0,97$ ir $0,90 < q_{s2} < 0,95$ žingsniu 0,005, PSNR – $34 < q_{p1} < 37$ ir $31 < q_{p2} < 36$ žingsniu 0,5. Intervalai parinkti taip, kad į vieną klasę patektų ne mažiau nei 10 % visų tiriamų vaizdų. Klasifikatoriaus mokymui naudoti 27 vaizdus apibūdinantys požymiai, kurių tarpusavio koreliacija mažesnė

nei 0,7 (detaliau 4.4.2 poskyryje). Parinktos kokybės slenksčio reikšmės, su kuriomis gautas geriausias klasifikavimo tikslumas, kai kiekvienos klasės jautrumas ne mažesnis nei 0,6. Kokybės slenksčio reikšmės, su kuriomis gautas geriausias tikslumas, pateiktos 15 lentelėje.

Grafinis vaizdų pasiskirstymas, kai vaizdai glausti su JPEG QF=30 ir kokybės slenksčiai, su kuriais gautas geriausias klasifikavimo tikslumas, parodyti 28 pav. Klasifikatoriaus formavimo taisyklės pateiktos 16 lentelėje.



28 pav. Kokybės slenksčiai ir vaizdų pasiskirstymas kai JPEG QF=30.

16 lentelė. Klasifikatoriaus formavimo taisyklės

	1 klasė (kokybė po JPEG kito mažiausiai)	2 klasė (kokybė po JPEG kito labiausiai)	3 klasė (kokybė po JPEG kito vidutiniškai)
Klasifikavimo metodai	Spendimų medis, LDA, SVM		
Klasifikavimo tikslumo nustatymas	10-ies dalių kryžminis patikrinimas		
Kokybės slenksčio reikalavimai	$SSIM > q_{s1}$ ir $PSNR > q_{p1}$	$SSIM < q_{s2}$ ir $PSNR < q_{p2}$	$q_{s2} < SSIM < q_{s1}$ ir $q_{p2} < SSIM < q_{p1}$
Kokybės slenksčių ribos	$q_{s1} = 0,94, q_{p1} = 37, q_{s2} = 0,92, q_{p2} = 32$		
Klasių dydžiai	150	150	150

4.4.2 Požymių išskyrimas


Vaizdus apibūdinančių požymių skaitinėms reikšmėms (Choras, 2007) nustatyti naudojamos geometrinės transformacijos (angl. *Geometric transformations*), vaizdo regionų savybės (angl. *Region and image properties*), vaizdo sandaros ir struktūros analizė (angl. *Texture analysis*) (Gonzalez, 2003), (Haralick, 1992), (Haralick, 1973).

Prieš nustatant požymius, vaizdų matmenys mažinami iki 256×192 . Naudojama artimiausio kaimyno interpoliacija (angl. *Nearest-Neighbor Interpolation*). Iš viso nustatyti 55 vaizdus apibūdinantys požymiai. Kiekvienam vaizdui apskaičiuojama:

- Pikselių ir histogramų entropijos (angl. *Entropy*), vidutinės reikšmės (angl. *Mean*), standartiniai nuokrypiai (angl.

Standard Deviation, Std) pagal kiekvieną spalvos komponentę skirtingose spalvinėse erdvėse (RGB, YCbCr, HSV);

- Santykis tarp pikselių kiekio ir failo dydžio, kuris parodo, kiek sunaudojama fizinės atminties vienam pikseliui;
- Vaizdo, perskaičiuoto į pilkumo toną (angl. *Grayscale*) ir binarizuoto pagal automatinį slenkstį (angl. *Global Image Threshold*) (Otsu, 1979), vidutinė pikselių reikšmė, standartinis nuokrypis;
- Vaizdo, perskaičiuoto į pilkumo toną ir binarizuoto pagal automatinį slenkstį, skirtingų dydžių regionų skaičius. Iš viso išskirti 8 regionai pagal pikselio reikšmę lygią vienetai (juodi regionai) ir 8 regionai pagal pikselio reikšmę lygią nuliui (balti regionai) nuo mažiausio iki didžiausio (29 pav.). Buvo atrinkti tokio ploto (pikseliais) regionai: nuo 1 iki 10; nuo 11 iki 50; nuo 51 iki 200; nuo 201 iki 1000; nuo 1001 iki 5000; nuo 5001 iki 10000; nuo 10001 iki 25000; nuo 25001.



29 pav. Panašių spalvų regionai

Apskaičiavus koreliacijas tarp požymių, tolesnei analizei buvo palikti tik tokie požymiai, kurių tarpusavio koreliacija mažesnė nei 0,7. Dėl to liko 27 požymiai.

Atsižvelgiant į tai, kad klasifikavime naudojamų skaitinių reikšmių kiekis nedaro reikšmingos įtakos laiko sąnaudoms (laiko sąnaudų analizė pateikta 4.4.5 poskyryje), darbe nenaudojamos faktorinė ir pagrindinių komponentų analizės. Bet tam, kad nebūtų atliekami pertekliniai skaičiavimai išskiriant požymius, siekiama nustatyti kuo mažesnę vaizdus apibūdinančių požymių kiekį. Visų įmanomų požymių tarpusavio kombinacijoms patikrinti reikalingos labai didelės laiko sąnaudos, todėl požymiai buvo atrenkami pagal empirinę iteracinę procedūrą.

Bandymai vyko iteracijomis po 1000 kartų, t. y.:

- 1 žingsnis: Atsitiktinai pasirenkami 4 požymiai;
- 2 žingsnis: 1000 kartų bandomos vis skirtingos 4 požymių kombinacijos ir skaičiuojamas klasifikavimo tikslumas;
- 3 žingsnis: išrenkama požymių kombinacija, duodanti tiksliausią klasifikavimo rezultatą;
- 4 žingsnis: prie surastos geriausios požymių kombinacijos pridedami dar 4 nenaudojami atsitiktiniai požymiai (iš likusiųjų). Grįžtama prie 2 žingsnio. Procedūra stabdoma, kai klasifikavimo tikslumas pradeda mažėti.

Atsitiktiniu būdu, bandant skirtingas požymių kombinacijas, buvo atrinkta 16 požymių, kurie toliau naudojami klasifikatoriui mokytį (formuoti).

Atrinkti tokie požymiai:

- x_1 – santykis tarp pikselių kiekio ir failo dydžio;
- x_2, x_3, x_4 – juodų regionų nuo 1 iki 10 pikselių kiekis, baltų regionų nuo 1 iki 10 ir nuo 11 iki 50 pikselių kiekiai;
- x_5, \dots, x_{16} – pikselių ir histogramų entropijos, vidutinės reikšmės, standartiniai nuokrypiai pagal kiekvieną spalvos

komponentę. Atrinkti požymiai parodyti matricoje, pažymėti „+“ (17 lentelė).

17 lentelė. Atrinkti 12 požymių (x_5, \dots, x_{16}) pagal kiekvieną spalvos komponentę

	Standartinis nuokrypis	Vidutinė reikšmė	Entropija	Histogramos entropija
R	-	-	-	-
G	+	-	-	-
B	+	-	-	-
Y	+	-	-	-
Cb	+	-	-	-
Cr	+	-	-	-
H	+	-	+	-
S	-	+	-	-
V	+	+	-	-
Binarizavimas	+	+	-	-

Atkreiptinas dėmesys, kad buvo užfiksuota ir daugiau požymių tarpusavio kombinacijų, davusių vienodai aukštą klasifikavimo tikslumą, bet siekiant kuo mažesnės jų įvairovės, pasirinkti aukščiau aprašyti požymiai. Šiuo atveju visai atsisakyta histogramų entropijų skaitinių reikšmių.

4.4.3 Klasifikavimo rezultatai

Keli tarpiniai rezultatai, gauti perrenkant požymių tarpusavio kombinacijas (po 1000 eksperimentų su skirtingomis požymių tarpusavio kombinacijomis), pateikti 18 lentelėje.

18 lentelė. Klasifikatoriaus tikslumo rezultatai esant skirtingoms požymių kombinacijoms

Požymių kiekis	Sprendimų medis	LDA	SVM
4	57 – 65 %	61 – 70 %	61 – 71 %
8	58 – 65 %	61 – 71 %	62 – 71 %
12	60 – 69 %	64 – 73 %	65 – 74 %
16	62 – 70 %	70 – 76 %	70 – 76 %
27	71 %	76 %	76 %
55	69 %	73 %	72 %

Gautas geriausias klasifikatoriaus tikslumas – 76 % (naudojant LDA ir SVM). Naudojant mažesnę požymių kiekį, gaunamas mažesnis klasifikatoriaus tikslumas, naudojant didesnę – tikslumas nedidėja. Klasifikavimo matrica parodyta 19 lentelėje, o duomenų klasifikavimo tikslumas pagal klases parodytas 20 lentelėje. Atsižvelgiant į tai, kad SVM esant didesniam klasių kiekiui yra ypač lėtas, toliau skaičiavimams naudojamas LDA.

19 lentelė. Klasifikavimo matrica (LDA), kai klasifikuojama su 16 atrinktų požymių

	Prognozuojamos klasės			
		1 klasė	2 klasė	3 klasė
Tikrosios klasės	1 klasė	108	3	39
	2 klasė	0	108	42
	3 klasė	8	16	126

20 lentelė. Duomenų klasifikavimo tikslumo rezultatai (LDA)

	Tikslumas (Precision)	Jautrumas (Recall)
1 klasė	0,93	0,72
2 klasė	0,85	0,72
3 klasė	0,61	0,84

Iš 19 ir 20 lentelių matyti, kad pirmoji ir antroji klasės nesimaišo tarpusavyje, o tai reiškia, kad vaizdams, kurių kokybę JPEG veikia labiausiai, nebus pritaikytas JPEG su maža QF reikšme ir atvirkščiai. Pavyzdžiui, taikant antros klasės vaizdui glaudinimo algoritmą su pirmos klasės vaizdui skirtais nustatymais, bus gautas labai nekokybiškas vaizdas.

4.4.4 Standartinio JPEG algoritmo ir siūlomo būdo

(klasifikuojama į tris klases) palyginimas

Šiame poskyryje vaizdų grupių glaudinimo JPEG algoritmu būdas, kai klasifikuojama į tris klases, lyginamas su standartiniu JPEG. Tyrimui atsitiktinai atrenkama 450 vaizdų klasifikatoriaus mokymui, po 150 vaizdų kiekvienai klasei ir 10 vaizdų grupių po 500 vaizdų algoritmų palyginimui (vaizdai, naudojami klasifikatoriaus mokymui į šias grupes neimami).

Nagrinėjami du atvejai:

Pirmas atvejis – kai norima gauti aukštos kokybės vaizdus po glaudinimo (kokybės slenkstis – $SSIM > 0,94$ ir $PSNR > 37$);

Antras atvejis – kai norima gauti vidutinės kokybės vaizdus (kokybės slenkstis – $SSIM > 0,92$ ir $PSNR > 32$).

Eksperimentiškai nustatyta, kad norint pasiekti nustatytus kokybės slenkščius naudojant standartinį JPEG algoritmą, pirmuoju atveju reikia taikyti QF=95, antruoju atveju QF=85.

Norint pasiekti nustatytus kokybės slenksčius naudojant siūlomą būdą, JPEG QF reikšmė nustatoma priklausomai nuo to, kokiai klasei priskirtas vaizdas:

Pirmuoju atveju: 1-os klasės vaizdams QF=50, 2-os klasės vaizdams QF=95, 3-ios klasės vaizdams QF=85.

Antruoju atveju: 1-os klasės vaizdams QF=40, 2-os klasės vaizdams QF=85, 3-ios klasės vaizdams QF=65.

Palyginamojo eksperimento nuostatos parodytos 21 lentelėje.

21 lentelė. Palyginamojo eksperimento nuostatos

	Pirmasis atvejis		Antrasis atvejis	
	Standartinis JPEG	Siūlomas būdas	Standartinis JPEG	Siūlomas būdas
Tikslas	Aukšta vaizdų kokybė		Vidutinė vaizdų kokybė	
JPEG nuostatos	QF=95	QF=50 (1 klasė) QF=95 (2 klasė) QF=85 (3 klasė)	QF=85	QF=40 (1 klasė) QF=85 (2 klasė) QF=65 (3 klasė)
Reikalavimai	$SSIM > 0,94$ ir $PSNR > 37$		$SSIM > 0,92$ ir $PSNR > 32$	

31 pav. parodyti pirmai klasei priklausančio vaizdo (30 pav.) fragmentai, kai vaizdas yra apdorotas algoritmu su QF=95 ir QF=50. Iš pateiktų fragmentų galima matyti, kad kai kuriems vaizdams didesnė QF reikšmė nedaro jokios akivaizdžios įtakos. 33 pav. parodyti antrai klasei priklausančio vaizdo (32 pav.) fragmentai su analogiškais QF. Iš pateiktų fragmentų galima matyti, kad kai kuriems vaizdams didesnė QF reikšmė daro akivaizdžią įtaką.

Eksperimentas buvo kartojamas po 10 kartų, kiekvienam atvejui nagrinėjant skirtingus vaizdus (vaizdų grupės po 500 vaizdų). Buvo fiksuojamas užimamos vietos kiekis po glaudinimo, taip pat fiksuojamas vaizdų, kurie netenkina keliamų kokybės reikalavimų, kiekis. Atkreiptinas dėmesys, kad vaizdai, kurie netenkina reikalavimų, buvo labai arti kokybės slenksčio. Taip yra dėl to, kad 1-os ir 2-os klasių vaizdai beveik nesupainiojami, t. y. klasifikuojami tiksliai.



30 pav. Pirmos klasės vaizdas (vaizdas, kurio kokybę JPEG veikia silpnai)



Originalas

JPEG QF=95 750 KB

JPEG QF=50 328 KB

SSIM=0,999 PSNR=42

SSIM=0,992 PSNR=41

31 pav. Pirmos klasės vaizdo, apdoroto JPEG su skirtingais QF, fragmentai



32 pav. Antros klasės vaizdas (vaizdas, kurio kokybė JPEG veikia stipriai)



Originalas



JPEG QF=95 1,15 MB
SSIM=0,94 PSNR=39



JPEG QF=50 244 KB
SSIM=0,78 PSNR=30

33 pav. Antros klasės vaizdo, apdoroto JPEG su skirtingais QF, fragmentai

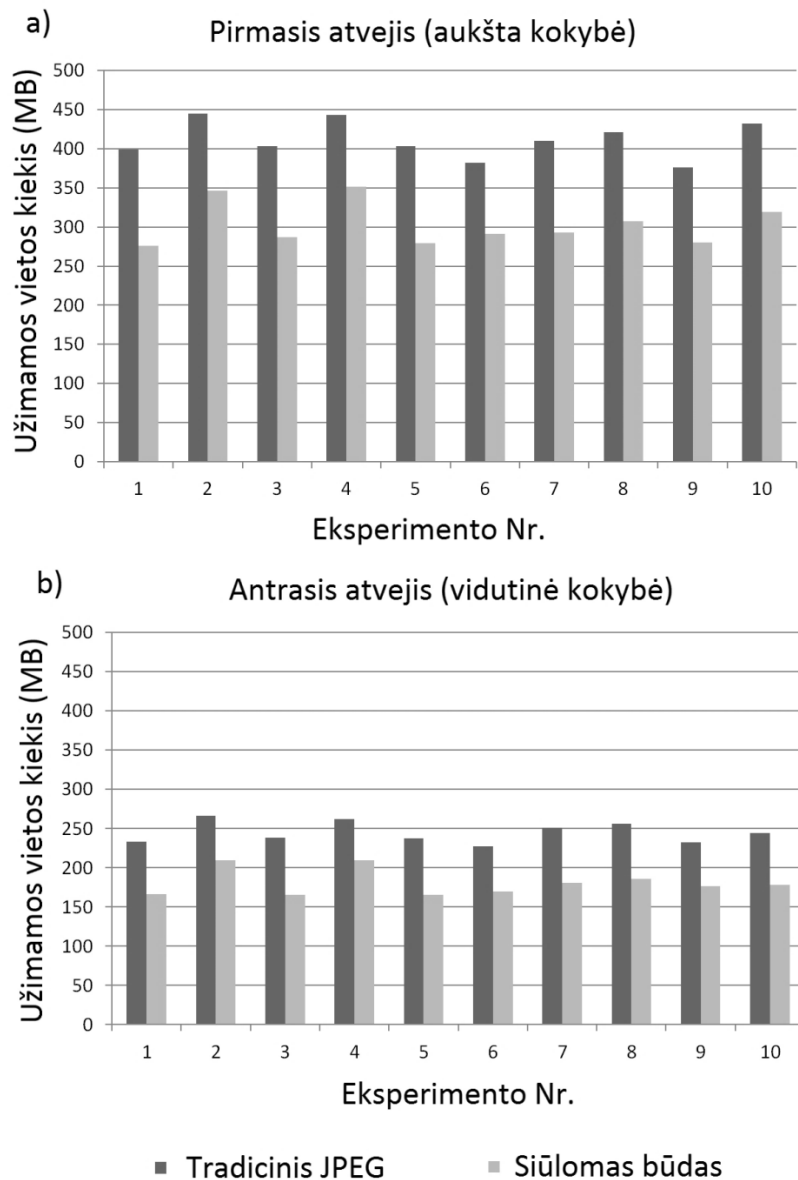
22 lentelė. Eksperimento rezultatai (pirmas atvejis, aukšta kokybė)

Eksp. Nr.	Standartinis JPEG		Siūlomas būdas		Sutaupyta užimamos vietos kiekis, MB
	Užimamos vietos kiekis, MB	Vaizdai, kurie netenkina reikalavimų	Užimamos vietos kiekis, MB	Vaizdai, kurie netenkina reikalavimų	
1	399	6 (1,2 %)	276	20 (4,0 %)	123 (30,1 %)
2	445	8 (1,6 %)	346	23 (4,6 %)	99 (22,2 %)
3	403	6 (1,2 %)	287	18 (3,6 %)	116 (28,8 %)
4	443	10 (2 %)	351	21 (4,2 %)	92 (20,8 %)
5	403	3 (0,6 %)	279	22 (4,4 %)	124 (30,1 %)
6	382	5 (1 %)	291	18 (3,6 %)	91 (23,8 %)
7	410	4 (0,8 %)	293	20 (4,0 %)	117 (28,5 %)
8	421	7 (1,4 %)	307	17 (3,4 %)	114 (27,1 %)
9	376	5 (1 %)	280	22 (4,4 %)	96 (25,5 %)
10	432	6 (1,2 %)	319	24 (4,8 %)	113 (26,2 %)
Viso:	4114	60 (1,2 %)	3029	205 (4,1%)	1085 (26,4 %)

23 lentelė. Eksperimento rezultatai (antras atvejis, vidutinė kokybė)

Eksp. Nr.	Standartinis JPEG		Siūlomas būdas		Sutaupyta užimamos vietos kiekis, MB
	Užimamos vietos kiekis, MB	Vaizdai, kurie netenkina reikalavimų	Užimamos vietos kiekis, MB	Vaizdai, kurie netenkina reikalavimų	
1	233	5 (1,0 %)	166	10 (2,0 %)	67 (28,9 %)
2	266	5 (1,0 %)	209	24 (4,8 %)	57 (21,4 %)
3	238	6 (1,2 %)	165	23 (4,6 %)	73 (30,7 %)
4	262	8 (1,6 %)	209	15 (3,0 %)	53 (20,2 %)
5	237	4 (0,8 %)	165	21 (4,2 %)	72 (30,4 %)
6	227	3 (0,6 %)	170	18 (3,6 %)	57 (25,1 %)
7	251	4 (0,8 %)	181	17 (3,4 %)	70 (27,9 %)
8	256	5 (1,0 %)	186	19 (3,8 %)	70 (27,3 %)
9	232	4 (0,8 %)	176	20 (4,0 %)	56 (24,1 %)
10	244	6 (1,2 %)	178	17 (3,4 %)	66 (27,1 %)
Viso:	2446	50 (1,0 %)	1805	184 (3,7 %)	641 (26,2 %)

22 ir 23 lentelėse ir 34 pav. pateikti rezultatai rodo, kad taikant 21 lentelėje pateiktus nustatymus, galima sutaupyti apie 26 % užimamos vietos (pirmuoju atveju po dešimties eksperimentų – 1,85 GB duomenų iš 4,11 GB, antruoju atveju – 0,64 GB duomenų iš 2,45 GB), bet apie 4 % vaizdų netenkina nustatyto kokybės slenksčio (vaizdai, kurie netenkina kokybės slenksčio buvo labai arti jo).



34 pav. Palyginamojo eksperimento rezultatai: a) pirmasis atvejis, aukšta kokybė; b) antrasis atvejis, vidutinė kokybė

Siūlomo būdo JPEG QF nustatymai gali būti ir kitokie, didinant skirtingų klasių QF reikšmes, mažės vaizdų, netenkinančių nustatytos kokybės slenksčio, bet tuo pačiu, mažės ir sutaupytos vietos kiekis. Mažinant skirtingų klasių QF reikšmę, didės vaizdų, netenkinančių nustatytos kokybės slenksčio, kiekis, bet tuo pačiu, didės ir sutaupytos vietos kiekis.

Atlikus eksperimentus su kitomis QF (palyginamojo eksperimento nuostatos pateiktos 24 lentelėje), gauti tokie rezultatai: siekiant aukštos kokybės (pirmasis atvejis) sutaupyta 35,3 % užimamos vietos, o vaizdų, netenkinančių nustatyto kokybės slenksčio, būta 9,7 %, siekiant vidutinės kokybės (antrasis atvejis) sutaupyta 31,7 % užimamos vietos, o vaizdų, netenkinančių nustatyto kokybės slenksčio, būta 7,1 % (rezultatai pateikti 25 lentelėje).

24 lentelė. Palyginamojo eksperimento nuostatos su kitomis QF reikšmėmis

	Pirmasis atvejis		Antrasis atvejis	
	Standartinis JPEG	Siūlomas būdas	Standartinis JPEG	Siūlomas būdas
Tikslas	Aukšta vaizdų kokybė		Vidutinė vaizdų kokybė	
JPEG nuostatos	QF=95	QF=40 (1 klasė) QF=95 (2 klasė) QF=75 (3 klasė)	QF=85	QF=30 (1 klasė) QF=85 (2 klasė) QF=55 (3 klasė)
Reikalavimai	$SSIM > 0,94$ ir $PSNR > 37$		$SSIM > 0,92$ ir $PSNR > 32$	

25 lentelė. Palyginamojo eksperimento rezultatai su skirtingomis QF reikšmėmis

		JPEG nuostatos	Užimamos vietos kiekis	Vaizdai, kurie netenkina reikalavimų	Sutaupyta užimamos vietos kiekis
Pirmasis atvejis (viso 10 eksp.)	Standartinis JPEG	QF=95	4114 MB	60 (1,2 %)	-
	Siūlomas būdas	QF=50 QF=95	3029 MB	205 (4,1 %)	1085 MB (26,4 %)
		QF=85			
Antrasis atvejis (viso 10 eksp.)	Standartinis JPEG	QF=40 QF=95 QF=75	2663 MB	485 (9,7 %)	1451 MB (35,3 %)
	Siūlomas būdas	QF=85	2446 MB	50 (1,0 %)	-
		QF=40 QF=85 QF=65	1805 MB	184 (3,7 %)	641 MB (26,2 %)
Siūlomas būdas	QF=30 QF=85 QF=55	1671 MB	355 (7,1 %)	775 MB (31,7 %)	

4.4.5 Laiko sąnaudų analizė

Pasiekti darbe nustatytą tikslą – efektyviai saugoti duomenis – galima dviem būdais: tiksliai nustatant suspaustų vaizdų kokybę ir pagal tai parenkant glaudinimo algoritmo nustatymus (PQST) (8 pav.) arba

nuspėjant glaudinimo algoritmo poveikį kokybei ir pagal tai parenkant glaudinimo algoritmo nustatymus (CIQST) (9 pav.), kaip pasiūlyta 4.3 poskyryje. Naudojant PQST galima gauti optimalų rezultatą (sunaudoti minimalų saugojimo vietos kiekį, kai visi vaizdai tenkins kokybės slenkstį), bet toks sprendimas didelėms vaizdų grupėms yra netinkamas dėl laiko sąnaudų. Šiame poskyryje siekiama palyginti šių dviejų technikų ir standartinio JPEG laiko sąnaudas vaizdams saugoti, kai siekiama aukštos kokybės (21 lentelė, pirmasis atvejis).

Vertinant laiko sąnaudas, atsižvelgiama tik tiesioginį vaizdų saugojimą paruoštomis sistemomis. CIQST atveju klasifikatoriaus formavimui panaudotas laikas nevertinamas, nes tai padaroma tik vieną kartą, o vaizdų glaudinimo sprendimas naudojamas neribotai, juolab dalies 25 pav. pavaizduoto proceso veiklų laiko sąnaudų neįmanoma vienareikšmiškai įvertinti, nes laikas priklauso nuo tyrėjo (sprendimo priėmėjo). Standartinio JPEG ir CIQST laiko sąnaudos buvo fiksuojamos palyginamojo eksperimento metu. Bendroms PQST procesų laiko sąnaudoms nustatyti buvo naudojama procesų simuliacija, pasitelkiant *Bizagi Modeler 3.1.0.011* programinę įrangą. Naudojant PQST daroma prielaida, kad JPEG algoritmu vaizdai bus apdorojami ne daugiau nei du kartus – jeigu gautas vaizdas su nustatyta minimalia QF reikšme netenkins kokybės reikalavimų, bus parinkta tinkama QF reikšmė.

Atsižvelgiant į 8 pav. parodytų PQST procesų veiklas, verta išskirti pagrindines, įtakančias bendras vaizdų saugojimo laiko sąnaudas: vaizdų apdorojimas glaudinimo algoritmu; vaizdų kokybės nustatymas; požymių išskyrimas; klasifikavimas.


Standartinio JPEG algoritmo ir CIQST palyginimo metu 4.4 poskyryje aprašytomis sąlygomis atlikti laiko sąnaudų matavimai pateikti 26 lentelėje (vidutiniai 10 eksperimentų rezultatai 500-ams vaizdų). Laiko matavimams naudotas kompiuteris su Intel Core i-7-5500U

procesoriumi ir 8 GB operatyviosios atminties. Matavimai atlikti naudojant MATLAB R2015a.

26 lentelė. Procesų veiklų laiko sąnaudų matavimo rezultatai

Proceso elementas	Vidutinis laikas (sekundėmis) 500 vaizdų	Vidutinis laikas (sekundėmis) 1 vaizdas
Vaizdų apdorojimas JPEG, QF=50	128	0,256
Vaizdų apdorojimas JPEG, QF=85	136	0,272
Vaizdų apdorojimas JPEG, QF=95 (Standartinis JPEG)	163	0,326
16 vaizdų požymių išskyrimas	75	0,15
Klasifikavimas	0,01	2×10^{-5}
Siūlomo būdo (CIQST) bendras procesas	219	0,446

Taip pat aprašytomis sąlygomis buvo nustatoma, kokios yra tikimybės (tikimybės įverčiai šiam konkrečiam atvejui), kad vaizdams tiks nustatyta QF reikšmė (21 lentelė, pirmasis atvejis). Tikimybės įvertis, kad vaizdas tenkins kokybės slenkstį, kai QF=50, yra 0,32, o kad likusieji vaizdai tenkins kokybės slenkstį, kai QF=85, tikimybės įvertis yra 0,84. Tikimybės įvertis buvo skaičiuojamas imant visus vaizdus (10 atsitiktinių vaizdų grupių po 500 vaizdų), kuriems tiks kokybės slenkstis, kai QF=50, ir dalinant juos iš visų vaizdų. Tas pats atliekama su likusiais vaizdais, kai QF=85. PQST simuliuojamas procesas pavaizduotas 35 pav., o rezultatas pateiktas 27 lentelėje.



35 pav. Palyginamojo eksperimento rezultatai
(pirmasis atvejis, aukšta kokybė)

27 lentelė. PQST simuliuto proceso rezultatai

Proceso elementas	Vidutinis laikas (sekundėmis)	Vidutinis laikas (sekundėmis)
	500 vaizdų	1 vaizdas
Vaizdų apdorojimas JPEG, QF=50	128,1	0,256
Vaizdų apdorojimas JPEG, QF=85	81,81	0,272
Vaizdų apdorojimas JPEG, QF=95 (Standartinis JPEG)	19,55	0,326
Vaizdų kokybės nustatymas, PSNR	177	0,354
Vaizdų kokybės nustatymas, SSIM	216	0,432
PQST procesas	622,46	1,234

Standartinio JPEG, CIQST ir PQST laiko sąnaudų rezultatai su nustatytais sąlygomis pateikti 28 lentelėje. Atkreiptinas dėmesys, kad CIQST taiko QF atsižvelgiant į tai, kokiai klasei yra priskirtas vaizdas, tuo tarpu PQST pritaiko QF preciziškai įvertinęs kiekvieną vaizdą.

28 lentelė. Standartinio JPEG, CIQST ir PQST laiko sąnaudų rezultatai

	Pirmasis atvejis		
	Standartinis JPEG	Siūlomas būdas (CIQST)	PQST
Tikslas	Aukšta vaizdų kokybė		
Reikalavimai	$SSIM > 0,94$ ir $PSNR > 37$		
JPEG nustatymai	QF=95	QF=50 (1 klasė) QF=95 (2 klasė) QF=85 (3 klasė)	QF=50 QF=95 QF=85
Bendras proceso laikas	163 sek.	219 sek.	622 sek.

28 lentelėje pateikti rezultatai rodo, kad CIQST veikia apytiksliai 3 kartus greičiau už PQST ir tik trečdaliu laiko lėčiau už standartinį JPEG. Akivaizdu, kad naudojant PQST bus sutaupyta daugiau vietos, bet sprendžiant šį konkretų uždavinį, kai vaizdų kiekis yra didelis ir įvertinus tai, kad didinant vaizdų kiekį laiko sąnaudos tiesiškai didėja, PQST gali būti netinkamas dėl didelių laiko sąnaudų. Pvz., norint išsaugoti eksperimentuose naudotą vaizdų kiekį (5000 vaizdų), standartinis JPEG užtruktų apie 27 min., CIQST užtruktų apie 36 min., o PQST prireiktų net apie 1 val. 44 min.

4.4.6 Poskyrio išvados

Šiame poskyryje pristatytas ir ištirtas klasifikavimu grįstas būdas saugoti vaizdus JPEG algoritmu, klasifikuojant saugomus vaizdus į tris klases prieš naudojant glaudinimo algoritmą. Pasiūlytas būdas sudarytas iš dviejų dalių: klasifikatoriaus mokymas; vaizdų glaudinimas JPEG atsižvelgiant į klasę, kuriai priskirtas vaizdas. Siekiant numatyti JPEG poveikį vaizdo kokybei, išspręsta vaizdų klasifikavimo į tris klases problema. Šio būdo taikymas leidžia apdoroti dideles vaizdų grupes JPEG algoritmu taip, kad JPEG QF reikšmė būtų automatiškai parenkama kiekvienam vaizdui, atsižvelgiant į pageidaujamą vaizdo kokybę. Parinkti tinkami vaizdus apibūdinantys požymiai. Gautas pakankamai aukštas klasifikavimo tikslumas (atsižvelgiant į tai, kad klasifikuojama į tris klases) lygus 0,76. Be to, klasifikavimo matrica parodė, kad pirmos (aukštos kokybės vaizdų) ir antros (žemos kokybės vaizdų) klasių vaizdai nepainiojami tarpusavyje.

Siekiant pabrėžti siūlomo būdo pranašumus, buvo atlikti lyginamieji eksperimentiniai tyrimai. Eksperimentai parodė, kad siūlomas būdas leidžia sutaupyti apie 26 % skaitmeninės atminties vietas, išlaikant pageidaujamą vaizdo kokybę, lyginant su įprastu JPEG algoritmu. Vaizdo kokybė vertinama taikant PSNR ir SSIM indekso metodus. Naudojant siūlomą būdą, daugiau kaip 95 % vaizdų tenkina pageidaujamą kokybės slenkstį. Siūlomas būdas skirtas saugoti įvairias skaitmenines nuotraukas, užfiksuotas skaitmeniniais fotoaparatais ir gali būti pritaikytas įvairioms prieglobos ir debesijos paslaugoms, socialiniams tinklams, elektroninės komercijos platformoms ir pan.

5. DISERTACIJOS APIBENDRINIMAS IR IŠVADOS

Darbe pasiūlyta skaitmeninių vaizdų grupių glaudinimo technologija, siekiant taupyti vaizdų užimamą vietą, bet išlaikant nustatytą jų kokybę. Ši technologija gali būti naudojama kitų technologijų sukūrimui ir naujoms žinioms gauti. Taip pat darbe pristatyti ir ištirti du klasifikavimu grįsti būdai glaudinti vaizdus JPEG formatu, klasifikuojant saugomus vaizdus į dvi arba į tris klases prieš naudojant glaudinimo algoritmą. Siūlomi būdai leidžia įvertinti, kaip JPEG algoritmas paveiks vaizdų kokybę. Pasiūlyti būdai sudaryti iš dviejų dalių: klasifikatoriaus mokymo ir vaizdų glaudinimo JPEG atsižvelgiant į klasę, kuriai priklauso vaizdas. Šių būdų taikymas leidžia apdoroti dideles vaizdų grupes JPEG algoritmu taip, kad JPEG QF reikšmė būtų automatiškai parenkama kiekvienam vaizdai, atsižvelgiant į pageidaujamą vaizdo kokybę. Naudojant pasiūlytą technologiją, klasifikatoriaus mokymas vyksta vieną kartą, o vaizdų glaudinimas pagal apmokytą klasifikatorių gali būti naudojamas pagal poreikį, neapibrėžtą laiko tarpą.

Siekiant disertacijoje iškelto tikslo, darbe ištirtas SSIM indekso metodas ir pritaikytas didelės raiškos vaizdų su mažais iškraipymais kokybei vertinti. Taip pat nustatyta, kad spaudžiant skirtingus vaizdus JPEG algoritmu su vienodomis QF reikšmėmis, gaunamas skirtingas glaudinimo efektyvumas ir kokybė. Tyrimai parodė, kad vaizdų klasifikavimas prieš taikant glaudinimo algoritmus gali būti naudingas taupant užimamą vietą informacijos saugykloje.

Eksperimentinio tyrimo metu buvo sprendžiamas uždavinys, siekiant nustatyti, kokie pradiniai vaizdus apibūdinantys požymiai turi būti naudojami klasifikuojant šiuos vaizdus pagal jų kokybę po glaudinimo JPEG algoritmu. Parinkti tinkami vaizdus apibūdinantys požymiai.

Remiantis disertacijoje atliktais tyrimais suformuluotos išvados ir apibendrinti rezultatai:

1. Pasiūlytos technologijos taikymas įvairių vaizdų, gautų skaitmeniniais fotoaparatais ir neturinčių specifinio turinio, grupėms apdoroti JPEG algoritmu, leidžia sutaupyti apie 15 % vaizdų užimamos vietos, kai klasifikuojama į dvi klases ir apie 26 % vaizdų užimamos vietos, kai klasifikuojama į tris klases, lyginant su standartiniu JPEG algoritmu. Rezultatas - daugiau kaip 95 % vaizdų tenkina pageidaujamą kokybės slenkstį, kokybę vertinant SSIM indekso ir PSNR metodais. Ši technologija ir ja grįstas vaizdų glaudinimo būdas leidžia varijuoti kokybės nustatymais. Didinant QF reikšmes atskiroms klasėms, mažėja vaizdų, kurie netenkina kokybės slenksčio, o mažinant šias reikšmes, didėja sutaupomos vietos kiekis. Pasiūlyta technologija yra lanksti ir gali būti lengvai priderinama prie naudotojų poreikio.

2. Nustatytas vaizdus apibūdinančių požymių rinkinys, pagal kurį klasifikuojant vaizdus, bendras klasifikavimo tikslumas lygus 0,85, kai klasifikuojama į dvi klases ir 0,76 – klasifikuojant į tris klases.

3. Nustatyta, kad vaizdų glaudinimas, kai tiksliai nustatoma suspaustų vaizdų kokybė (PQST), beveik tris kartus lėtesnis nei pasiūlytas klasifikavimu grįstas vaizdų glaudinimas (CIQST), numatant JPEG algoritmo poveikį vaizdų kokybei, klasifikuojant vaizdus į tris klases.

Literatūra

Abrahams J. Code and parse trees for lossless source encoding. Compression and Complexity of Sequences 1997. Proceedings, 1997.

Alpaydin E. Introduction to Machine Learning Second Edition. The MIT Press, 2009.

Ball G. H., Hall, D. J. Isodata: a method of data analysis and pattern classification. Stanford Research Institute, Menlo Park, United States. Office of Naval Research. Information Sciences Branch, 1965.

Breiman L., Friedman, J., Olshen, R., Stone, C. Classification and Regression Trees. Boca Raton, FL: CRC Press, 1984.

Brunet D., Vrscay E. R., Wang, Z. On the mathematical properties of the structural similarity index. IEEE Transactions on Image Processing, 2012, T. 21, p. 1488–1499.

Cadik M., Slavik P. Evaluation of two principal approaches to objective image quality assessment. 8th International Conference on Information Visualisation. London, 2004, p. 513–551.

Chandler D. M. Seven challenges in image quality assessment: past, present, and future research. ISRN Signal Processing, 2013, p. 53 pages.

Chapelle O., Haffner, P., Vapnik, N. Support vector machines for histogram-based image classification. IEEE Transactions on Neural Networks, 1999, T. 10., p. 1055–1064.

Choras R. Image Feature Extraction Techniques and Their Applications for CBIR and Biometrics Systems. International Journal of Biology and Biomedical Engineering, 2007, T. 1. p. 6–16.

Chouhan A., Nigam M.J. Double compression of JPEG image using DCT with estimated quality factor. Power Electronics, Intelligent Control and Energy Systems (ICPEICES), IEEE International Conference on. IEEE , 2016.

Chui C. An Introduction to Wavelets. Academic Press, 1992.

Coulombe S., Pigeon S. Low-Complexity Transcoding of JPEG Images With Near-Optimal Quality Using a Predictive Quality Factor and Scaling Parameters. IEEE TRANSACTIONS ON IMAGE PROCESSING. 2010, T. 19, p. 712–721.

Daly S. The Visible Differences Predictor: An Algorithm for the Assessment of Image Fidelity. Proceedings of SPIE - The International Society for Optical Engineering 1666, 1993, p. 179–206.

Dzemyda G., Kurasova, O., Žilinskas, J. Daugiamačių duomenų vizualizavimo metodai. Mokslo aidai, 2008.

Entezari-Maleki R., Rezaei A., Minaei-Bidgoli B. Comparison of Classification Methods Based on the Type of Attributes and Sample Size. Journal of Convergence Information Technology, 2009, p. 94–102.

Eskicioglu A. M. Quality measurement for monochrome compressed images in the past 25 years. Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing. Istanbul, 2000, T. 4, p. 1907–1910.

Fawcett T. Introduction to ROC analysis. Pattern Recognition Letters, 2006, T. 27, p. 861–874.

Fernando A., Worrall S. T., Ekmekcioglu E. 3DTV: processing and transmission of 3D video signals. John Wiley & Sons, 2013, 224 pages.

Fisher R. A. The Use Of Multiple Measurements In Taxonomic Problems. Annals of Eugenics, 1936, T. 7, p. 179–188.

Forczmanski P., Mantiuk R. Adaptive and Quality-Aware Storage of JPEG Files in the Web Environment. International Conference, ICCVG. - Warsaw : Springer International Publishing, 2014, p. 212–219.

Furnkranz J. Round Robin Classification. Journal of Machine Learning Research, 2002, T. 2, p. 721–747.

Gao Y., Rehman A., Wang Z. SW-SSIM based image classification. 18th International Conference on Image Processing (ICIP), IEEE, 2011, p. 1249–1252.

George A. G., Prabavathy, A. K. A survey on different approaches used in image quality assessment. International Journal of Computer Science and Network security (IJCSNS), 2014. T. 14, p. 78.

Giberta K., Sanchez-Marrea M., Codinaa C. Choosing the Right Data Mining Technique: Classification of Methods and Intelligent Recommendation. International Congress on Environmental Modelling and Software. - Ottawa, 2010.

Gonzalez R.C., Woods R.E., Eddins S.L. Digital Image Processing Using MATLAB . New Jersey: Prentice Hall, 2003.

Guo Y., Hastie T., Tibshirani R. Regularized Discriminant Analysis and Its Application in Microarrays. Biostatistics, 2007, T. 8, p. 86–100.

Gutierrez-Pena E. Bayesian classification methods. Psychology Science, 2004, p. 52–64.

Haralick R.M., Shapiro L.G. Computer and Robot Vision: Vol. 1: Addison-Wesley, 1992.

Haralick R.M., Shanmugan K., Dinstein I. Textural Features for Image Classification. IEEE Transactions on Systems, Man, and Cybernetics, 1973, Tom. SMC-3, p. 610–621.

Haseeb Shariq, Khalifa Othman O. Comparative Performance Analysis of Image Compression by JPEG 2000. *Information Technology Journal*, 2006, T. 5, p. 35–39.

Hore A., Ziou D. Image quality metrics: PSNR vs. SSIM. *Pattern Recognition (ICPR), 2010 20th International Conference on*, IEEE, 2010, p. 2366–2369.

Huang Y.H., Ou, T.-S., Su, P.Y., Chen, H. H. Perceptual rate-distortion optimization using structural similarity index as quality metric. *IEEE Transactions on Circuits and Systems for Video Technology*, 2010. T. 20 (11), p. 1614–1624.

Huffman D.A. A method for the construction. *Proceedings IRE*, 1962. T. 40, p. 1098–1101.

Hunt R. W. G. *The Reproduction of Colour*, 6th Edition . - [s.l.] : Chichester UK: Wiley-IS&T Series in Imaging Science and Technology, 2004.

ITU Objective perceptual video quality measurement techniques for digital cable television in the presence of a full reference. *SERIES J: CABLE NETWORKS AND TRANSMISSION OF TELEVISION, SOUND PROGRAMME AND OTHER MULTIMEDIA SIGNALS*, 2001, T. J. 144.

Ji G., Ni, X., Bae, H. A full-reference image quality assessment algorithm based on haar wavelet transform. *International Conference on Computer Science and Software Engineering*, IEEE, 2008, T. 1, p. 791–794.

Joy K. Sarma, E. G. Recent developments in image quality assessment algorithms. A review *Journal of Theoretical and Applied Information Technology*, 2014, T. 65, p. 192–201.

JPEG The Joint Photographic Experts Group (JPEG) committee [Tinkle], 2017, <https://jpeg.org/>.

Kaminski B., Jakubczyk, M., Szufel, P. A framework for sensitivity analysis of decision trees. *Central European Journal of Operations Research*, 2017, p. 1–25.

Karunasekera S. A., Kingsbury S. A. A distortion measure for blocking artifacts in images based on human visual sensitivity. *IEEE Transactions on Image Processing*, 1995, T. 4, p. 713–724.

Kenney J. F., Keeping, E. S. Root Mean Square. §4.15 in *Mathematics of Statistics*. Princeton, NJ: Van Nostrand, 1962.

Kiang M. Y. A comparative assessment of classification methods. *Decision Support Systems*, 2003, T. 35, p. 441–454.

Kotsiantis S. B. Supervised Machine Learning: A Review of Classification Techniques. *Informatica*, 2007, T. 31, p. 249–268.

Kozhemiakin R., Lukin V., Vozel B. Image Quality Prediction for DCT-based Compression. *Proceedings of the 14-th International Conference "The Experience of Designing and Application of CAD Systems in Microelectronics" (CADSM)*. Polyana, 2017, p. 225–268.

Laua W. L., Lia Z.L., Lama K. W. K. Effects of JPEG compression on image classification. *International Journal of Remote Sensing*, 2003, T. 24, p. 1535–1544.

Lloyd S. P. Least Squares Quantization in PCM. *IEEE Trans. Inf. Theory*, 1982, T. 28, p. 129–137.

Maini R, Aggarwal H Study and Comparison of Various Image Edge Detection Techniques. *International Journal of Image Processing*, 2009, T. 3, p. 1–11.

Martinez-Rach M. O., Pinol P., Lopez O. M., Malumbres M. P., Oliver J., Calafate C. T. On the Performance of Video Quality Assessment Metrics under Different Compression and Packet Loss Scenarios. *The Scientific World Journal*, 2014, T. 3, p. 1–18.

Meijering E. A chronology of interpolation: from ancient astronomy to modern signal and image processing. Proceedings of the IEEE, 2002, T. 90, p. 319–342.

Mensink T., Verbeek J., Perronnin F., Csurka G. Metric learning for large scale image classification: Generalizing to new classes at near-zero cost. Proceedings of the 12th European conference on Computer Vision, 2012, T. 2, p. 488–501.

Mika S., Ratsch, G., Weston J., Scholkopf B., Mullers K.R. Fisher discriminant analysis with kernels. Neural Networks for Signal Processing IX, 1999. Proceedings of the 1999 IEEE Signal Processing Society Workshop, Madison, WI, USA, 1999.

Moorthy A. K., Bovik A.C Blind Image Quality Assessment: From Natural Scene Statistics to Perceptual Quality. IEEE Transactions on Image Processing , 2011, T. 20, p. 3350–3364.

Mrinal K. M. The Human Visual System and Perception. Multimedia Signals and Systems, Springer, 2003, p. 33–56.

Otsu N. A Threshold Selection Method from Gray-Level Histograms. IEEE Transactions on Systems, Man, and Cybernetics, 1979, T. 9, p. 62–66.

Parker M. Discrete and fast Fourier transforms. Digital Signal Processing , 2010, p. 97–112.

Piella G., Cwi, A. N., Heijmans H. A new quality metric for image fusion. International Conference on Image Processing (ICIP), IEEE, 2003.

Pigeon S., Coulombe S. K-Means Based Prediction of Transcoded JPEG File Size and Structural Similarity. International Journal of Multimedia Data Engineering and Management, 2012, T. 3, p. 41–57.

Ponomarenko N., Battisti F., Egiazarian K., Astola, J., Lukin, V. Metrics performance comparison for color image database. Proceedings of

the Fourth International Workshop on Video processing and Quality Metrics, Scottsdale, 2009, p. 14–16.

Ponomarenko N., Lukin V., Zelensky A., Egiazarian K., Carli, M., Battisti, F. TID2008 - A database for evaluation of full-reference visual quality assessment metrics. *Advances of Modern Radioelectronics*, 2009, T. 10, p. 30–45.

Ponomarenko N., Ieremeiev, O., Lukin V., Egiazarian, K. Color image database TID2013: Peculiarities and preliminary results. 4th European Workshop on Visual Information Processing (EUVIP), 2013, p. 106–111.

Prewitt J., M., S. *Object Enhancement and Extraction*, New York : Picture Processing and Psychopictorics, Academic Press, 1970.

Rao K. R., Yip, P. *Discrete cosine transform: algorithms, advantages, applications*: Academic Press Professional, Inc., 1990.

Rehman A., Rostami M., Wang Z., Brunet D., Vrscay E. R. SSIM - inspired image restoration using sparse representation. *EURASIP Journal on Advances in Signal Processing*, 2012, T. 1, p. 1–12.

Richard S. *Computer Vision: Algorithms and Applications*, Springer-Verlag London, 2011.

Russ J. C. *The Image Processing Handbook*: CRC press, 2011.

Salomon D. *A guide to data compression methods*: Springer Science & Business Media, 2013.

Sanchez J., Perronnin, F. High-dimensional signature compression for large-scale image classification. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2011, p. 1665–1672.

Sokolov R., Abdullin R. Nonlinear JPEG image filtering at stage of preprocessing. *Telecommunications Forum (TELFOR)*, IEEE, 2016.

Solomon Ch., Breckon T. Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab, John Wiley & Sons, Inc., 2011.

Streijl R.C., Winkler S., Hands D.S. Mean opinion score (MOS) revisited: methods and applications, limitations and alternatives. Multimedia Systems, 2016, T. 22, p. 213–227.

Talwar A., Kumar Y. Machine Learning: An artificial intelligence methodology. International Journal Of Engineering And Computer Science, 2013, T. 2, p. 3400–3404.

Thung K., Raveendran, P. A survey of image quality measures. International Conference for Technical Postgraduates, TECHPOS, 2009, p. 1–4.

Tichonov J. SSIM metodo taikymas didelių vaizdų analizei , 2013.

Union International Telecommunication Recommendation T.45 (02/00): Run-length colour encoding , 2000.

Vapnik V., Cortes C. Support-vector networks. Machine Learning , 1995, 3 : T. 20, p. 273–297.

Venkatesh Babu R., Suresh S. GAP-RBF Based NR Image Quality Measurement for JPEG Coded Images. 5th Indian Conference, ICVGIP 2006, Madurai : Springer Berlin Heidelberg, 2006, p. 718–727.

Viraktamath S. V., Attimarad G. V. Performance Analysis of JPEG Algorithm. 2011 International Conference on Signal Processing, Communication, Computing and Networking Technologies (ICSCCN 2011), Thuckafay, 2011, p. 629–633.

Wallace Gregory K. The JPEG still picture compression standard. IEEE Transactions on Consumer Electronics, 1992, February, T. 38, p. 18–34.

Wang Z, Xue, X Multi-Class Support Vector Machine. Support Vector Machines Applications, Springer, 2014, p. 23–28.

Wang Z., Bovik A. C., Sheikh H. R., Simoncelli E. P. Image quality assessment: From error visibility to structural similarity. IEEE Transactions on Image Processing, 2004, April, T. 13, p. 600–612.

Wang Z., Bovik A. C. Mean squared error: love it or leave it? - A new look at signal fidelity measures. IEEE Signal Processing Magazine, 2009, January, T. 26, p. 98–117.

Wang Z. MATLAB function, SSIM Index with automatic downsampling, Version 1.0 Copyright (c) 2009, 2014, <https://ece.uwaterloo.ca/~z70wang/research/ssim/ssim.m>.

Wang Z., Bovik C. A., Lu I. Why Is Image Quality Assessment So Difficult?. Acoustics, Speech, and Signal Processing (ICASSP), 2002 IEEE International Conference on, 2002, p. 1520–6149 .

Wang Z., Simoncelli E. P., Bovik A. C. Multiscale structural similarity for image quality assessment. Conference Record of the Thirty-Seventh Asilomar Conference on Signals, Systems and Computers, IEEE, 2004, T. 2, p. 1398–1402.

Watson Andrew B. Image Compression Using the Discrete Cosine Transform. Mathematica Journal, 1994, T. 4, p. 81–88.

Winkler S. Analysis of public image and video databases for quality assessment. IEEE Journal of Selected Topics in Signal Processing, 2012, p. 616–625.

Xiao J., Hays J., Ehinger K., Oliva A., Torralba A. SUN Database: Large-scale Scene Recognition from Abbey to Zoo. IEEE Conference on Computer Vision and Pattern Recognition, 2010, p. 3485–3492.

Yang C., Gao, W., Po, L. Discrete wavelet transform-based structural similarity for image quality assessment. 15th IEEE International Conference on Image Processing (ICIP), IEEE, 2008, p. 377–380.

Yuanqing L., Fengjun, L., Shenghuo, Z., Ming, Y. Large-scale image classification: Fast feature extraction and SVM training. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2011, p. 1689–1696.

Zhang J., Marszalek, M., Lazebnik, S., Schmid, C. Local Features and Kernels for Classification of Texture and Object Categories: A Comprehensive Study. International Journal of Computer Vision, 2007, T. 73, p. 213–238.

Сэлмон Д. Сжатие данных, изображений и звука, Москва : Техносфера, 2004.

Autoriaus publikacijų sąrašas disertacijos tema

Straipsniai periodiniuose moksliniuose leidiniuose:

[1 A] Tichonov J., Kurasova O., Classification of Large Images Before Applying Compression Algorithms, Journal of Young Scientists, 2015, Vol.1(43): 87–94.

[2 A] Tichonov J., Kurasova, O., Filatovas, E., Vaizdų klasifikavimas pagal suspaudimo algoritmo poveikį jų kokybei, Informacijos mokslai, 2015, Vol. 73: 127–134.

[3 A] Petkus T., Tichonov, J., Filatovas, E., Jakštys, V., Quality Assessment of High-Resolution Images with Small Distortions after Compression, Baltic Journal of Modern Computing, 2017, Vol. 5 (32): 206–220.

[4 A] Tichonov J., Kurasova O., Filatovas E., Image Classification for JPEG Compression, Advances in Science and Technology Research Journal, ISSN: 2299-8624 (priimtas 2018-03-19).

Straipsnis konferencijų mokslinėje medžiagoje:

[5 A] Tichonov J., Kurasova O., Filatovas E., Quality Prediction of Compressed Images via Classification, Image Processing and Communications Challenges 8, Springer International Publishing, 2017 Vol. 525, 35–42.

Santraukos konferencijų leidiniuose:

[6 A] Tichonov J., Kurasova O., Classification of Large Images before Applying Compression Algorithm, 6-oji tarptautinė mokslinė konferencija „Data Analysis Methods for Software Systems“, Druskininkai, 2014 gruodžio mėn. 4–6 d.

[7 A] Tichonov J., Kurasova O., Filatovas E., Image Classification for Quality Prediction after JPEG Compression, 7-oji tarptautinė mokslinė

konferencija „Data Analysis Methods for Software Systems“, Druskininkai, 2015 gruodžio mėn. 3–5 d.

[8 A] Tichonov J., Kurasova O., Filatovas E., Decision Tree Classification to Predict Effect of JPEG Compression on Images, EURO 2016, 28th European Conference on Operational Research, July 3–6, 2016, Poznan, Poland.

[9 A] Tichonov J., Kurasova O., Filatovas E., Quality Prediction of Compressed Images via Classification, IP&C 2016, 8th International Conference on Image Processing & Communications, September 7-9, 2016, Bydgoszcz, Poland.

[10 A] Tichonov J., Kurasova O., Filatovas E., Classification-Based Storage of JPEG Images, 8-oji tarptautinė mokslinė konferencija „Data Analysis Methods for Software Systems“, Druskininkai, 2016 gruodžio mėn. 1-3 d.

Jevgenij Tichonov

KLASIFIKAVIMO METODAIS GRINDŽIAMI SKAITMENINIŲ VAIZDŲ
GLAUDINIMO SPRENDIMAI

Daktaro disertacija

Technologijos mokslai, informatikos inžinerija (07 T)

Redaktorius Kęstutis Sukackas