



**KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS**

Eglė Vainauskaitė

**VIETOVĖS ATPAŽINIMO PAGAL CHARAKTERINGUOSIUS
TAŠKUS TYRIMAS**

Baigiamasis magistro projektas

Vadovas

Dr. Tomas Blažauskas

KAUNAS, 2017
KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS

**VIETVĖS ATPAŽINIMO PAGAL CHARAKTERINGUOSIUS
TAŠKUS TYRIMAS**

Baigiamasis magistro projektas
Informatika (621I10003)

Vadovas Dr. Tomas Blažauskas
(parašas)
(data)

Recenzentas Liudas Motiejūnas
(parašas)
(data)

Projektą atliko Eglė Vainauskaitė
(parašas)
(data)

KAUNAS, 2017



KAUNO TECHNOLOGIJOS UNIVERSITETAS

Informatikos

(Fakultetas)

Eglė Vainauskaitė

(Studento vardas, pavardė)

Informatika 621I10003

(Studijų programos pavadinimas, kodas)

Magistrinio darbo „Vietovės atpažinimo pagal charakteringuosius taškus tyrimas“

AKADEMINIO SAŽININGUMO DEKLARACIJA

Kaunas

Patvirtinu, kad mano, **Eglės Vainauskaitės**, baigiamasis projektas tema „Vietovės atpažinimo pagal charakteringuosius taškus tyrimas.“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

(vardą ir pavardę įrašyti ranka)

(parašas)

Santrauka

Eglė Vainauskaitė vietovės atpažinimo pagal charakteringuosius taškus tyrimas. Informatikos magistro baigiamasis projektas/ vadovas prof. dr. Tomas Blažauskas; Kauno Technologijos Universitetas, Informatikos fakultetas.

Reikšminiai žodžiai: charakteringieji taškai; vietovės atpažinimas; SIFT; SURF; HOG; BRISK;

Kaunas, 2017.

Informatikos magistro darbo tema yra aktuali įvairiose šiuolaikinėse technologijų vystymosi ir pritaikymo srityse. Didėjant išmaniųjų mašinų, robotų poreikiui, siekiama sukurti labiausiai efektyviausią metodą, kuris galėtų atlikti žmogaus funkciją - atpažinti objektus, vietoves, žmones iš tam tikros informacijos. Vienas iš atpažinimo būdų - metodai grįsti charakteringaisiais taškais, kurie nusako objekto ryškiausias vietas, pastato kampą ir kitas detales.

Šiame darbe vietovės atpažinimui nuotraukose pasirinkta SIFT, SURF, FAST su aprašu SURF, SURF su aprašu HOG, SURF su aprašu BRISK. Išanalizuota šių metodų veikimo principai, aprašyti kiti charakteringųjų taškų aprašai ir detektoriai. Vietovės atpažinimui panaudotas MATLAB programos paketas. Eksperimentų metu nustatyta ir ištirta charakteringųjų taškų metodų trūkumai. Vietovės kiekybinio įvertinimui apskaičiuota logaritminė tikimybė.

Summary

Eglė Vainauskaitė. A study of location identification using algorithms based on characteristic points detection. Master thesis of informatics/ supervisor prof. dr. Tomas Blažauskas; Faculty of Informatics, Kaunas University of Technology.

Key words: characteristic points; location identification; SIFT; SURF; HOG; BRISK; Kaunas, 2017.

The topic analysed in this Master's thesis is relevant in various modern high-tech development and application domains. As the need for smart machines and robots is increasing, scientists are trying to create the most effective method which could carry out human functions – recognizing objects, locations, and people from specific information. Modern methods of model detection are procedures based on characteristic points. Characteristic points describe the most distinctive elements of an object and place the corners and other details.

In this thesis methods like SIFT, SURF, FAST with a detector SURF, SURF with a detector HOG, SURF with a detector BRISK were chosen in order to identify a location from a picture. Moreover, an overview of these methods was given as well as the description of the main characteristic points and detectors. An algorithm was developed for using *MATLAB* program to study the method. The performance deficiencies and inaccuracies of the experiment were identified. The logarithmic probability was calculated for location quantified estimation.

Turinys

Terminių ir santrumpų žodynas	8
Paveikslėlių sąrašas.....	9
Lentelių sąrašas.....	10
IVADAS	11
Darbo tikslas ir uždaviniai.....	11
Darbo struktūra.....	11
1 Objektų atpažinimo analitinė apžvalga	12
1.1 Objekto atpažinimo procesas	12
1.2 Objekto aptikimo algoritmai	12
1.3 Egzistuojančios objektų atpažinimo algoritmų realizacijos.....	13
1.3.1 Automatinis panoraminių nuotraukų sujungimas	13
1.3.2 Mobilieji robotai.....	14
1.3.3 Veidų atpažinimas	15
1.3.4 Optinių simbolių atpažinimas.....	16
1.4 Trumpas skyriaus apibendrinimas	17
2 Charakterizuojančių taškų išskyrimo metodų analizė.....	18
2.1 Aprašai ir detektoriai.....	20
2.2 SIFT	20
2.3 RANSAC	23
2.4 SURF.....	23
2.4.1 HOG aprašas	26
2.4.2 BRISK detektorius	27
2.4.3 FAST detektorius	28
2.5 BRIEF Aprašas	29
2.6 ORB	30
2.7 Tikėtinumo santykio logaritmas	31
2.8 Trumpas skyriaus apibendrinimas	32
3 Vaizdų atpažinimo realizacinė dalis.....	34
3.1 Paskirtis.....	34
3.2 Funkciniai reikalavimai	34
3.3 Nefunkciniai reikalavimai.....	35
3.4 Naudojami trečiųjų šalių metodai	35
3.5 Sistemos architektūrinis modelis	36
3.6 Sistemos suskirstymas į modulius	36

3.7	Sistemos veiklos diagrama.....	37
4	Charakteringųjų taškų eksperimentinė dalis	40
4.1	Tyrimo duomenys	40
4.2	Skirtingo mastelio objekto esančio nuotraukoje tyrimo rezultatai	42
4.3	Apšvietimo tyrimo rezultatai	43
4.4	Vaizdo pasukimo tyrimo rezultatai	43
4.5	Greitaveikos tyrimo rezultatai.....	44
4.6	Skirtingų perspektyvų tyrimo rezultatai.....	46
4.7	Skirtingų atstumų tyrimo rezultatai	48
4.8	Logaritminės tikimybės įvertinimas	51
4.9	Vietovės atpažinimo tyrimas.....	52
	Išvados	54
	Literatūra.....	55

Terminių ir santrumpų žodynas

SIFT	(angl. <i>Scale-Invariant Feature Transform</i>) – pastovios skalės požymio transformavimas.
DoG	(angl. <i>Difference of Gaussian</i>) – Gaussianų skirtumai.
SURF	(angl. <i>Speeded-up Robust Features</i>) – Greitas požymio išskyrimas.
GLOH	(angl. <i>Gradient Location and Orientation Histogram</i>) – Gradientinė lokalizacija ir orientavimo histogramos.
ORB	(angl. <i>Oriented FAST and rotated BRIEF</i>) – greitas lokalių ypatybių detektorius.
BRISK	(angl. <i>Binary Robust Invariant Scalable Keypoint</i>) – dvejetainis, kintamo mastelio charakteringojo taško suradimas.
HOG	(angl. <i>Histogram of Oriented Gradients</i>) – Histogramos pagal orientuotos gradientą.
BRIEF	(angl. <i>Binary Robust independent elementary features</i>) – dvejetainis bendrosios paskirties nepriklausomų požymių išskyrimas.

Paveikslėlių sąrašas

1 pav. Objekto atpažinimo etapai [4]	12
2 pav. Nuotraukos sulietos pagal homografiją (a, b, c, d)	14
3 pav. Automatinės optinės sistemos atpažinimo veikimo schema	16
4 pav. Vaizdo pavertimas į išplėstą tekstą schema	16
5 pav. Marr reprezentacinis modelis [27].....	18
6 pav. Ullman lyginimo teorijos pavyzdys.....	19
7 pav. SIFT metodo schemas	21
8 pav. Paveiklo gradiento ir charakteringojo taško aprašo vaizdas [37]	23
9 pav. Charakteringų taškų suradimas paremtas <i>Hessian</i> detektoriumi.	24
10 pav. Orientacijos priskyrimo vaizdas [20]	25
11 pav. Orientuoto aprašo langas su skirtingais dydžiais[20].....	25
12 pav. Aprašas, orientuotas kvadratiname tinkelyje su 4x4 kvadratinu išskirstymu apie charakteringąjį tašką [20].....	26
13 pav. Dviejų charakteringųjų taškų palyginimas pagal kontrastą	26
14 pav. Vizualinis HOG aprašo pavyzdys [31]	27
15 pav. Taškais koncentruotas apskritimas [30].....	28
16 pav. <i>Bresenham</i> ratas[29].....	29
17 pav. Tiriamosios sistemos panaudos atvejų diagrama	34
18 pav. Tiriamosios sistemos architektūrinis modelis	36
19 pav. Tiriamosios sistemos suskirstymas į paketus	37
20 pav. Veiklos diagrama	38
21 pav. Tyrimo eigos apdorojimo schema	40
22 pav. Nuotraukos su skirtiniais apšvietimo padidinimais.....	40
23 pav. Vaizdo pasukimai	41
24 pav. Nuotraukų pavyzdžiai.....	41
25 pav. Skirtingų atstumu nuotraukos a, b, c, d	42
26 pav. Gauti metodu rezultatai: bendri taškai, kai mastelis mažinamas, didinamas	42
27 pav. Metodu rezultatai, bendri taškai, kai apšvietimas mažinamas, didinamas	43
28 pav. Metodų rastų bendri taškai, kai yra objekto pasukimas	44
29 pav. Laiko priklausomybė nuo vaizdo pasukimo	44
30 pav. Laiko priklausomybė nuo apšvietimo pasikeitimo	45
31 pav. Laiko priklausomybė nuo mastelio pasikeitimo	45
32 pav. SURF metodo bendrieji taškai	47
33 pav. Tiriamų metodų rezultatai	48
34 pav. SURF metodo bendrieji taškai	49
35 pav. Tiriamų metodų rezultatai	50

Lentelių sąrašas

1Lentelė Tikėtinumo santykio LR ir jo natūraliojo logaritmo LLR reikšmės[26]	31
4 Lentelė SIFT metodo rezultatai	46
5 Lentelė SURF metodo rezultatai	46
6 Lentelė Aprašo HOG ir detektoriaus SURF rezultatai	47
7 Lentelė Aprašo SURF ir detektoriaus BRISK rezultatai	47
8 Lentelė Aprašo SURF ir detektoriaus FAST rezultatai	47
9 Lentelė SIFT rezultatai	48
10 Lentelė SURF rezultatai	49
11 Lentelė Aprašo HOG ir detektoriaus SURF rezultatai	49
12 Lentelė Aprašo SURF ir detektoriaus BRISK rezultatai	50
13 Lentelė Aprašo SURF ir detektoriaus FAST rezultatai	50
14 Lentelė SIFT rezultatai	51
15 Lentelė SURF rezultatai	51
16 Lentelė Aprašo HOG ir detektoriaus SURF rezultatai	51
17 Lentelė Aprašo SURF ir detektoriaus BRISK rezultatai	52
18 Lentelė Aprašo SURF ir detektoriaus FAST rezultatai	52
19 Lentelė Vietovės atpažinimo rezultatų vidurkis.....	53

ĮVADAS

Žmogus geba atpažinti daugybę matomų objektų kaip raides, pažįstamus žmones, įžymius pastatus, be papildomų mąstymo pastangų. Vizualų objektą atpažįstame iš neįprastų orientacijų (priekio, šono) nepriklausomai nuo apšvietimo sąlygų ar programoje esančių kitų sudėtingų objektų. Žmogui užtenka dalinės informacijos, iš kurios gali nuspręsti, koks tai objektas. Pavyzdžiui, vandenyno horizonte esantis stiebas su buria interpretuojamas kaip jachta. Technikos srityje net pats paprasčiausias automatizuotas objekto atpažinimas reikalauja daug daugiau informacijos, ne tik stiebo ir burės. Užtrunka daug ilgiau negu žmogaus galvoje vykstantys atpažinimo procesai.

Automatizuotas sėkmingas objekto atpažinimas priklauso nuo aplinkos, tame kadre esančių kitų objektų, apšvietimo. Tokiose sistemose atsižvelgiama į vaizdo pastovumą, paveiklo modelio dimensijų kiekį, objektų kiekį objektų duomenų bazėje [1]. Susiduriama su tikslumo ir našumo problemomis. Vis dar atliekami tyrimai, siekiant sukurti našesnius ir tikslesnius algoritmus, kurie be žmogaus įsikišimo galėtų identifikuoti atitinkamą objektą ar vietovę.

Tobulėjant technologijoms, ieškoma įvairių būdų kaip būtų galima pagerinti vietovės atpažinimą pasitelkiant išmaniuosius telefonus ir derinant įvairiausių algoritmus

Darbo tikslas ir uždaviniai

Tikslas – realizuoti egzistuojančius objektų atpažinimo algoritmus pagal charakteringuosius taškus ir įvertinti tikslumą bei našumą.

Uždaviniai:

1. Išanalizuoti vaizdų atpažinimo sistemas;
2. Išanalizuoti charakteringųjų taškų metodus;
3. Suprojektuoti ir sukurti charakteringųjų taškų metodų testavimo sistemą;
4. Ištirti skirtingų perspektyvų ir atstumo iki vietovės poveikį;
5. Atlikti vietovės atpažinimo tyrimą;
6. Įvertinti kiekybiškai tiriamosios ir lyginamosios nuotraukoje esančios vietovės sutapimą/nesutapimą;
7. Ištirti ir palyginti metodų greitaveiką ir jos priklausomybę nuo pagrindinių faktorių (objekto mastelio, objekto pasisukimo, apšvietimo).

Darbo struktūra

Darbą sudaro įvadas, terminų ir santrumpų žodynas, paveikslėlių ir lentelių sąrašas ir 5 pagrindiniai skyriai. Įvade supažindinama su darbo aktualumu, problematika išdėstomi tikslai bei uždaviniai, aptariama darbo struktūra. Pirmajame skyriuje „Objektų atpažinimo apžvalga“ pateikiamas objekto atpažinimo procesas bei aprašomas jų taikymas. Kitame skyriuje „Charakterizuojančių taškų išskyrimo metodų analizė“ pateikta detali SIF ir SURF, BRISK, HOG, FAST informacija. Kitame skyriuje „Vaizdų atpažinimo realizacinė dalis“ pateikiama funkciniai, nefunkciniai tiriamosios sistemos reikalavimai. Kitame skyriuje „Eksperimentinė dalis“ pateikiamos eksperimento sąlygos ir gauti rezultatai. Skyriuje „Rezultatai ir išvados“ pateikta darbo metu gauti rezultatai ir išvados. Paskutiniame skyriuje pateikiamas darbo metu naudotos literatūros sąrašas.

1 Objektų atpažinimo analitinė apžvalga

1.1 Objekto atpažinimo procesas

Objektų atpažinimas – tai technologija, kuri lygina tam tikrus duomenis, kurie yra išskirti iš daugiau nei vieno objekto, su duomenimis, esančiais duomenų bazėje. Objekto atpažinimo technologija turi draugišką vartotojo sąsają, jei užtenka vaizdo kameros, kuri yra kiekviename kompiuteryje ar išmaniajame telefone. Pagrindinis technologijos trūkumas, kad ji priklauso nuo išorinių veiksnių, pavyzdžiui, šviesos, triukšmo.

Objektų atpažinimo sistemos suskirstytos į du modulius. Pirmasis „Aptikimo modulis“. Šiame etape įvesties paveikslas gaunamas iš kameros, apdorojama, pašalinama perteklinė informacija (triukšmai). Surastame objekte išskiriamos charakteristikos ir lyginama su duomenimis esančiais duomenų bazėje. Duomenų lyginimas priskiriamas antrajam moduliui „Objekto atpažinimas“. Objekto atpažinimo etapai pateikti 1 paveiksle.



1 pav. Objekto atpažinimo etapai [4]

1.2 Objekto aptikimo algoritmai

Objekto nustatymo algoritmuose yra naudojami statiniai vaizdai, taip pat gali būti naudojamos ir reguliariais laiko intervalais gautų statinių vaizdų sekos. Statiniuose vaizduose yra lengviau pašalinti foną ir rasti objektą. Atsiranda problemų kai fonas yra sudėtinis: pilna įvairaus dydžio ir formų objektų. Objekto nustatymui erdvėje ir jo kontūro nustatymui taikomas ribų aptikimo (angl. *Edge matching*) algoritmas.

Segmentavimas

Per pastaruosius metus buvo pasiūlyta daug įvairių segmentavimo metodų [16,17, 18], tačiau *K-mean* vienas iš dažniausiai naudojamų grupavimo algoritmų. Šio algoritmo tikslas – apibrėžti, kuriose grupėse yra taškas. *Gonzalez* [19] pateikia tokias grupavimo procedūras:

1. Pasirinkite K grupės centrą $z_1(1), z_2(1), \dots, z_k(1)$.
2. Kartoti šiuos veiksmus:
 $x \in C_j(k)$ jeigu $\|x - z_j(k)\| < \|x - z_i(k)\|$
 Kur $i = 1, 2, \dots, K; i \neq j; C_j(k)$ grupė taškų, kur grupės centras yra $z_j(k)$.
3. Apskaičiuojamas naujas grupės centras, pagal 1 formulę

$$z_j(k+1) = \frac{1}{N_j} \sum_{x \in C_j(k)} x, \quad j = 1, 2, \dots, K \quad (1)$$
4. Jeigu $z_j(k+1) = z_j(k)$ kai skirtas $j = 1, 2, \dots, K$. Kai algoritmas praeina visus galimus variantus, baigiasi. Kitu atveju grįžta į antrą žingsnį.
 Grupavimas priklausys nuo pradinių grupių centrų.

Požymių palyginimas

Sugrupavus objekto taškus, jie turi būti palyginti, jog būtų nuspręsta ar tikrai yra tas objektas. Požymiams tarp taškų lyginti pagal koordinates ir aprašus (taškų požymius) naudojamas *Kd-tree*.

Prieš atliekant palyginimą yra sudaroma *Kd-tree* duomenų struktūra. *Kd-tree* struktūra sudaroma iš taškų požymių. Daugiamatėje erdvėje taškų požymiai klasifikuojami, nustatomi atstumai. Atstumai skaičiuojami pagal *Euklido* atstumą arba L^2 metriką [20] (žr. 2 formulę).

$$L^2 = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{k=1}^n (p_k - q_k)^2} \quad (2)$$

čia $p = (p_1, p_2, \dots, p_n)$ – pirmas taškas n -matėje erdvėje, $q = (q_1, q_2, \dots, q_n)$ – antras taškas n -matėje erdvėje, k – kintamasis. Įėjime gaunami, dviejų objektų, taškų požymiai reikšmės, o išėjime gaunami, dviejų objektų, taškų požymių atitikimai (atitikimų pora) ir atstumas tarp atitikusių taškų. Atitinkančiais taškais laikomi tie taškai, kurie būdami skirtinguose objektų paviršiuose turi panašius arba vienodus požymių vektorius – aprašus.

Gautiems rezultatams, požymių vektoriams skaičiuojami atstumai, tada skaičiuojamas suskaičiuotų taškų porų atstumų vidurkis arba suma. Kurio atstumas mažiausias, tai daugiausiai panašumo turintis objektas, tokiu atveju objektas laikomas atpažintu.

1.3 Egzistuojančios objektų atpažinimo algoritmų realizacijos

Objektų atpažinimas plačiai naudojamas nuo nuotraukoje aptinkančio žmogaus akies iki žmogaus atpažinimo ir jo sekimo kadrų sekoje. Pats objektas gali būti stiklinė, žmogus, gyvūnas ir kita.

1.3.1 Automatinis panoraminių nuotraukų sujungimas


Automatinis panoraminių nuotraukų sujungimas (angl. *Recognizing panoramas*). Čia naudojamos objektų atpažinimo technikos grįstos vietos suradimu ir nustatymu kitoje nuotraukoje [1]. Šios sistemos esmė – be žmogaus įsikišimo iš nuotraukų kadrų sekos sudėti panoraminę nuotrauką. Kiekvienoje nuotraukoje ieškoma funkcinių taškų, panaudojant SIFT metodą arba sujungus SIFT su RASAN. Tada kitose nuotraukose ieškoma panašumo. Jeigu randa, tada sujungia. Šio proceso pavyzdys pateiktas a – d paveiksluose, galutinis rezultatas pateiktas 2 paveiksle (a, b, c, d).



a) Paveikslas 1




b) Paveikslas 2



c) Pritaikytas SIFT metodas 1-ajam paveikslui



d) Pritaikytas SIFT metodas 2-ajam paveikslui



2 pav. Nuotraukos sulietos pagal homografiją (a, b, c, d)

1.3.2 Mobilieji robotai

Mobilieji robotai turi važiuoklę – ratinę, vikšrinę ar žingsniuojančią – ir autonominį maitinimo šaltinį. Atlieka transportavimo darbus tarp sandėlių ir įrengimų. Cechuose tokiems robotams specialiai įrengiami judėjimo keliai ir suplanuojama darbo zona. Vienas iš būdų vietai ir orientacijai erdvėje nustatyti, naudojamas vaizdo jutiklis. Robotui vaizdo jutikliai yra kaip žmogui akys. Per pastaruosius metus buvo suprojektuota kelios vaizdu paremtos lokalizacijos nustatymo sistemos. Iš esmės jos skiriasi tuo, kaip yra surandamas atitinkamas paveikslas.

Robotai naudojami taip pat ir atliekant namų ruošos darbus, ligoninėse, padedant prižiūrėti sergančius žmones, biuro padėjėjai, skirti gerinti darbo našumą [8]. Robotams keliami dideli reikalavimai, nes svarbu saugiai, tiksliai ir efektyviai atlikti užduotis namuose, biuruose, ligoninėse.

1.3.3 Veidų atpažinimas

Plačiai naudojamos asmenų identifikavimo sistemos yra tos, kurios visiškai nereikalauja vartotojo įsikišimo. Šiai kategorijai galima priskirti veidų atpažinimą. Automatinis asmens identifikavimas turi didžiulį potencialą ir begalę pritaikymo sričių, pradedant nuo draugų automatinio atpažinimo nuotraukų galerijoje iki ypač aukšto lygio saugumo sistemų, kuriose yra būtina identifikuoti asmenį.

Veido atpažinimo taikomosios programos gali būti suskirstytos į tris pagrindines grupes:

- Veidų atpažinimas išmaniosiose aplinkose;
- Veido atpažinimas išmaniosiose mašinose;
- Veido atpažinimas foto-nuotraukose ar vaizdo medžiagoje.

Pirmajai grupei priklausančios programos identifikuoja žmones, pavyzdžiui, įeinančius į „protingą namą“. Atpažinimas atliekamas nepriklausomai nuo apšvietimo ir galvos pozicijos.

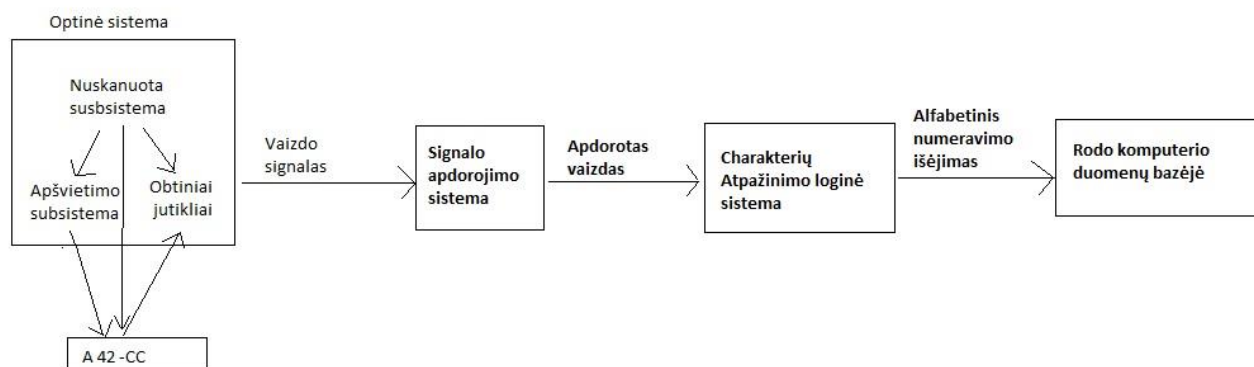
Veido atpažinimo išmaniosiomis mašinomis grupei priklausančios programos identifikuoja asmenį, su kuriuo ji sąveikauja, pavyzdžiui kompiuteris ar išmanusis telefonas identifikuoja naudotoją. Vienas iš pavyzdžių yra naujai užpatentuota *Google* veido atpažinimo technologija, vadinama *Face unlock*. Pirmą kartą pasirodė operacinės sistemos versijoje *Android 4.0 Ice Cream Sandwich*. Ši technologija skirta mobiliųjų įrenginių vartotojų identifikavimui, pasitelkiant priekinėje dalyje esančią kamerą: jei vartotojo veidas sėkmingai atpažįstamas, sistema automatiškai atblokuoja mobilų įrenginį ir suteikia prieigą prie jame esančių programų ir duomenų.

Trečiajai grupei priklausančias veidų atpažinimas yra naudojamas kaip paieškos priemonė objektams aptikti. Ji ypač sudėtinga, nes visos sąlygos yra nepriklausomos ir nekontroliuojamos. Vienas iš pavyzdžių – veidų atpažinimo funkcija įdiegta plačiai naudojamame *Facebook* tinklalapyje. Ji buvo sukurta palengvinanti žmonių tapatybių žymėjimą įkėlus naują albumą. Tam tikri asmenys atpažįstami lyginant daugybės pažymėtų žmonių nuotraukas tarpusavyje ir sukuriant jų skaitmeninę tapatybę. *Picasa* saityno albumų programa taip pat turi veidų atpažinimo funkciją. Vartotojui nuotraukose pažymėjus ir įvardinus pažįstamus veidus, programa analizuoja kitas nuotraukas ir mėgina pati pažymėti atrastus žmones.

Japonų kompanija *Hitachi Kokusai Electric* pristatė naują vaizdo stebėjimo sistemą, kuri gali išskirti vieną veidą iš minios ir perrinkti per sekundę net 36 mln. variantų, ieškodama reikalingo individo. Tokia sistema leis ir prekybos tinklui, ir vyriausybinėms organizacijoms, ir teisėsaugos institucijoms aptikti reikiamą žmogų jau esamoje duomenų bazėje. Teisėsaugos įstaigų atveju tai leis daug greičiau surasti, pavyzdžiui, besislapstantį nuo teisingumo asmenį. Ši sistema visų pirma skirta geležinkelių kompanijoms, energetikos korporacijoms, teisėsaugos organams, taip pat dideliems parduotuvių tinklams.

1.3.4 Optinių simbolių atpažinimas


William D. Barber, Thomas M. Cipolla, Joseph L. Mundy užpatentavo automatinę optinę sistemą skirtą atpažinti ant metalo ar kitų atspindinčių paviršių esančius simbolius. Optinė sistema gauna duomenis ir juos perduoda apdoroti į signalo apdorojimo sistemą, ši apdorojus siunčia toliau į charakterių atpažinimo loginę sistemą iš jos yra siunčiama toliau, atvaizduojama kompiuterio duomenų bazėje[6]. Veikimo schema pateikti 3 paveiksle.



3 pav. Automatinės optinės sistemos atpažinimo veikimo schema

Ravina Mithe, Supriya Indalkar, Nilam Divekar pasiūlė optinį charakterių atpažinimą mobiliosioms aplikacijoms [4]. Ši technologija leidžia atpažinti tekstą pasinaudojant optiniu mechanizmu. Žmogaus atveju akys yra optinis mechanizmas. Matomas vaizdas yra įėjimo signalas smegenims. Gebėjimas suprasti įeinančius signalus ir juos atpažinti priklauso nuo kiekvieno žmogaus[4]. Optinių charakterių atpažinimas (OCR – angl. *Optical character recognition*) technologija kurios funkcija panaši į žmogaus gebėjimą skaityti. Ši technologija gali atpažinti tiek ranka rašytą tekstą tiek spausdintą kompiuteriu, tačiau atpažinimo kokybė priklauso nuo vaizdo kokybės.

Šioje technologijoje įeinamas signalas yra pilkas arba nespalvotas vaizdas, kuris vėliau apdorojamas. Susiduriama su įvairiomis problemomis, pagrindinė iš jų – parašyto teksto išskaidymas atskirais simboliais, kompiuterinės sistemos apmokymas pagal tam tikrą raštą ir paties teksto atpažinimas[7]. Veikimo schema pateikta 4 paveiksle.



4 pav. Vaizdo pavertimas į išplėstą tekstą schema

Naudojama kaip popierinius dokumentus paversti skaitmenines taip sumažinant popierinių dokumentų užimamą vietą. Paverstus dokumentus į skaitmeninį formatą galima naudoti teksto paiešką. Taip greitai ir lengvai galima rasti didelėje duomenų bazėje reikiamą informaciją. Ši technologija taip pat taikoma švietime, finansuose ir vyriausybinėse agentūrose, siekiant taupyti laiką ir pinigus.

1.4 Trumpas skyriaus apibendrinimas

Šiame skyriuje aprašyta objektų atpažinimo etapai (1 pav.) . Atpažinimas prasideda nuo nespaltoto įvesties paveikslo. Toliau yra pašalina perteklinę informaciją. Objekto nustatymui erdvėje ir jo kontūro nustatymui taikoma ribų aptikimo (angl. *Edge matching*) algoritmas. Objektas suskirstomas į segmentus. Paskutinis atpažinimo žingsnis objektų paviršių požymių palyginimas ir panašaus pavyzdžio (objekto) išrinkimas. Požymių palyginimo metodai daugiamatėje požymių erdvėje skaičiuoja atstumus tarp taškų požymių – ieškoma požymių atitikimų. Mažiausius atstumus turintys atitinkantys taškai laikomi teisingais atitikimais. Klaidingų atitikimų pašalinimui numatyti tam skirti metodai.

Objektų suradimas ir atpažinimas taikomas įvairiose srityse prasidedant nuo parasto simbolių atpažinimo, iki ligos indentifikavimo (ligoninėse) ar net iki įtartinų žmonių sekimo viešuosiuose erdvėse.

2 Charakterizuojančių taškų išskyrimo metodų analizė

Realybėje objektai, kaip namas, stolas, paveikslas yra trimačiai (3D), nuotraukoje tie patys objektai tampa dvimačiais (2D). Padarius nuotrauką stalo iš kito pusės, šis bus nebeatpažįstamas, nes dvimatėje nuotraukoje trūks informacijos apie realų objektą. Tad kyla problemos tinkamai ir greitai spręsti atpažinimo uždavinį, neimant kitų problemų, pavyzdžiui, vaizdo pastovumo, objektų kiekio, apšvietimo, pasukimo kampo. Paveikslo modelio dimensijų kiekio problemos sprendimo variantai:

1. Padaryti erdvę 2.5 D;
2. Ortografiškai sudaryti objekto modelius;
3. Reprezentuoti taškais;

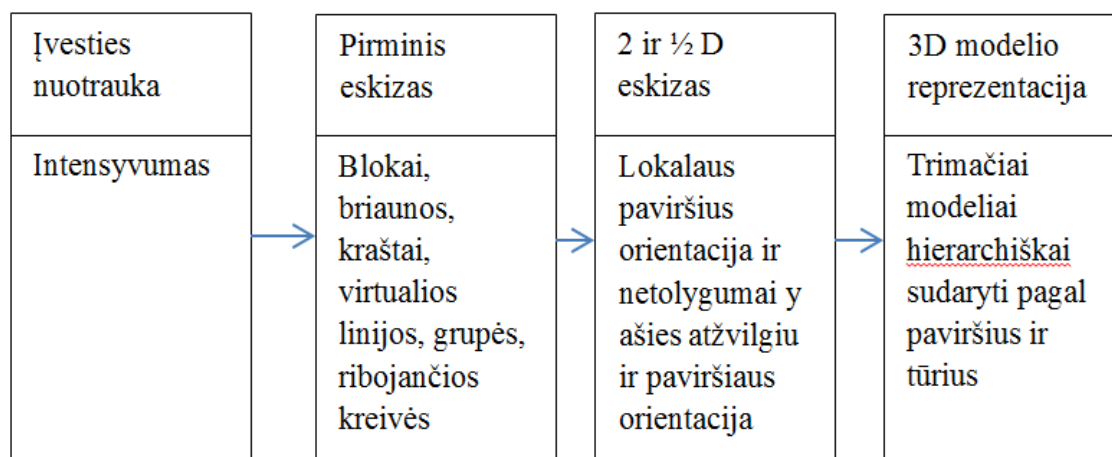
Pirmuoju variantu *Marr* pasiūlė reprezentacinį modelį, tinkamą objektų atpažinimui, tačiau jo negalėjo pritaikyti, dėl sudėtingų modelio etapų. Antrojo sprendimo būdą pasiūlė *Ullman*. Ortografiškai sudarytus objekto modelius lyginti su tiriamuoju objektu.

Taškų reprezentacijai sukurta daug įvairių algoritmų, kurios sudaro detektorius ir aprašai. Pavyzdžiui SIFT, SURF, FAST, BRISK, ORB ir kiti.

Marr reprezentacinis modelis

Vienas iš sprendimo būdų pasiūlytas *D. Marr* (angl. *Marr*) teorija kaip reprezentuoti taškus ir algoritmą reprezentaciniai sistemai nuo pradinio eskizo iki trimačio modelio suformavimo nuotraukos objektui. Pagrindinis *Marr* tikslas išspręsti uždavinį: formų informacijos gavimą iš nuotraukos.

Reprezentacinė sistema susideda iš dviejų dalių: žiūrovo centro ir objekto centro. Pirmasis dar išskirstytas į 3 dalis: Įvesties nuotrauka, pirminis apdorojimas, 2 ir 0.5 D apdorojimas (žr. 5 pav.). Antroje dalyje objekto centre – 3D modelio reprezentavimas. Pirminiame apdorojime gaunama iš kameros nuotrauka.



5 pav. *Marr* reprezentacinis modelis [27]

Įvesties nuotrauka analizuojama pagal intensyvumo pokyčius. Pagal juos aptinkama apšvietimo efektai, geometrinės struktūros. Pirminiame eskizo sudarymo etapas yra svarbus dalykas, dėl to, kad jame gautas rezultatas atspinti matomą paviršiaus struktūrą. *Marr* siūlo taikyti paprasto lygio funkcijas, kurios atitinka orientuotas briaunas, blokus, briaunos kraštinės, virtualios linijos, grupės, ribojančios kreivės. Šios funkcijos nustato tipą, poziciją, orientaciją, mastelį, kontrastą. 2 ir ½ D eskizo etape nustatoma orientacija gylio y ašimi ir x

ašimi matomi paviršiai. Paviršiai sujungiami nepertraukiamomis linijomis. Šios orientacijos padeda nurodyti į žiūrovo orientuotą koordinacių sistemą. Orientuota žiūrovo koordinacių sistema sudaroma iš primityvių paviršiaus orientacijų, atstumo nuo žiūrovo ir gylio paviršiaus orientacijų.


Paskutinis etapas trimačio (3D) modelio reprezentavimas. Šiame etape nustatoma apibūdinančios formos taikant modulinę ir hierarchinę struktūrą. Šis trimatis modelis gali būti sudarytas hierarhiškai pagal informacijos specifiškumą. Aukščiausio lygio hierarchijoje apibūna modelio pagrindinę ašį, kuri nėra skaidoma į dar mažesnes. Kitame lygmenyje detaliau pridedamas dalys išilgai pagrindinės ašies. Žemiausią lygį sudaro kampai ir jų komponentai. Pavyzdys: žmogaus kūnas sudarytas iš pagrindinės dalies stuburo ir šalutinių rankų, kojų, kurios dar yra išskaidomos į mažesnes dalis. Hierarchinėje struktūroje bus žmogus, tada išskaidoma tam tikra dalis į atskiras dalis, pavyzdžiui: ranka į viršutinę dalį (žastikaulis) ir apatinę (ją sudaro stipinkaulis, alkūnkaulis), apatinė dalis dar išskaidoma į stipinkaulį, alkūnkaulį ir plaštaką. Plaštaka į delnakaulį ir pirštus. Skaidymas vyksta tol kol yra skaidomų dalių.

Hierarhiškai sudarytame modelyje saugoma informacija yra specifiškumo indeksas, papildomas rodiklis ir tėvų indeksas. Hierarhiška paieška prasideda nuo aukščiausio ir eina žemyn iki paskutinio. Kai turima bibliotekos, kuriose apibrėžta kiekvienas objektas, nuotraukoje esantį objektą su bibliotekoje aprašytu objektu galima lyginti tarpusavyje.

Marr teorijos problema, kad jos neina įgyvendinti, nes sunku padaryti visus tris etapus, nuo pirminio eskizo iki trimačio modelio reprezentacijos.

***Ullman* 's lyginimo teorija**

Pasiūlytame *Ullman* lyginimo uždavinį pateikiama objektas iš įvairų žiūrėjimo kampų, dar vadinamų objektų modelių su ortografiniu objektų vaizdavimu. Susiduriama su problema, kad realiame pasaulyje, kai žiūrime į objektą, pavyzdžiui namą, žiūrovas nemato kai kurių linijų, taškų. Tad, kad žiūrovas pamatytų ir kitas linijas, reikia namą padaryti permatomą, tačiau nuotraukoje šito padaryti nėra galima, nebent nuspėti, kur turėtų būti ortografinio vaizdo linijos.



6 pav. Ullman lyginimo teorijos pavyzdys

Sudaromas objekto ortografinis vaizdas (žr. 6 pav.), su skirtingomis rotacijomis. A ir B – objekto modelis, o U – nežinomas objektas. Atitinkamai tiek A tiek B tiek C pažymėti kampai skirtingomis spalvomis. Kiekvienam kampui sudaroma lygtis tik x ašies atžvilgiu (3,4,5 formulės):

$$x_{\text{žalias}} = \alpha x_A + \beta x_B + \gamma \quad (3)$$

$$x_{\text{geltonas}} = \alpha x_A + \beta x_B + \gamma \quad (4)$$

$$x_{raudonas} = \alpha x_A + \beta x_B + \gamma \quad (5)$$

X ašies atžvilgiu žaliojo taško koordinatės nusako atitinkamas dydis ar pasukimo kampas α iš A objekto modelio padaugintas iš A modelio x koordinatės, pridėta atitinkamas dydis β iš B objekto modelio, bei padauginta A modelio x koordinatės ir dydis γ . Jeigu šios lygties teisingos galima apskaičiuoti α, β, γ . Jeigu žinoma šios reikšmės α, β, γ , galima nuspėti, nežinomo objekto kitų taškų koordinatės.

Ullman lyginimo teorijos pagrindinė idėja išskaidyti kraštinių, kampų paieška į du etapus:

- a) Nustatyti objekto modelį ir žiūrėjimo kampą.
- b) Nustatyti objekto modelį, kuris geriausiai atitiks lyginamojo objekto žiūrėjimo kampą.

Antrajame etape paieška vyksta per visas turimus objektų modelius (anksčiau minėtame pavyzdyje pateikiama tik du modeliai, žr. 6 paveiksle) Lyginamo objekto su tiriamojo objekto modeliu ieškoma tinkamo atitikmens atliekant transformacijas. *Ullman* lyginimo teorijos problema, nėra galima nustatyti kiekvieno potencialaus objekto atitinkančio atitikmens, nors ir buvo atliekamos transformacijos.

2.1 Aprašai ir detektoriai

Detektorius suranda charakteringuosius taškus, netinkamus atmeta. Sprendžia problema kaip greitai surasti charakteringuosius taškus nuotraukoje. Detektoriai gali būti: LoG filtras, FAST, BRISK, ORB. Programoje *Matlab* yra realizuota šie aprašai: FAST, SURF, BRISK, MSER.

Aprašas yra tam tikros savybės ar bruožo apibūdinimas ir jis apibrėžia savybių sintaksinę ir semantiką. Savybių išgavimas sprendžia problemą, kaip apibūdinti charakteringuosius taškus, kad galėtume palyginti juos su kitoje nuotraukoje esančiais charakteringais taškais. Aprašai gali būti: Normalizuotas gradientas, HOG, GLOH, LESH, BRISK, FREAK, LDB. Programoje *Matlab* yra realizuota šie aprašai: HOG, LBP, SURF, FAST, BRISK.

2.2 SIFT

SIFT – charakteringų taškų išskyrimo metodas. Jį sudaro charakteringų taškų detektorius ir aprašai [37]:

1. Mastelio-erdvės ekstremumų paieška;
2. Charakteringų taškų lokalizacija;
3. Orientacijos priskyrimas charakteringiems taškams;
4. Sudaromas aprašai;

Šio metodai pagrindiniai plusai:

- Atsparus vaizdo mastelio pasikeitimui;
- Nepriklauso nuo vaizdo pasukimo;
- Turi mažai įtakos apšvietimo pasikeitimams;
- Nepriklauso nuo stebėjimo taško kampo.

Pirmajame etape ieškoma vaizdo masteliuose charakteringų taškų, kurie *Gauso* funkcijos reikšmės yra ekstremumai. Suradus charakteringiems taškams, atliekamas netinkamų taškų filtravimas pagal kontrasto ir objektų kraštų slenksčius.

Mastelio-erdvės ekstremumų paieška

Mastelio-erdvės ekstremumų paieška (angl. *Scale-space extrema detection*) – tai pirmasis žingsnis, kai ieškoma per atvaizdo vietas charakteringų taškų. Tam taikoma tolydžios *Gauso* funkcijos, *Gauso* branduolys (žr. 3 formulę):

$$L(x, y, \sigma) = G(x, y, \sigma) \cdot I(x, y), G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (3)$$

Kur L – mastelio erdvės funkcijos reikšmė pasirinktame taške, (x, y) – pasirinkto taško koordinatės, σ – glotninimo spindulys, G – *Gauso* funkcijos branduolys, I – vaizdo funkcija, \cdot – sąsukos operacija.


Mastelio-erdvės ekstremumų paieškai efektyvesnis yra *Gauso* funkcijų skirtumas *DoG* (angl. *Difference of Gaussians*), kuris gali būti suskaičiuojamas su skirtingais glotninimo funkcijos spindulio koeficientais k (žr. 4 formulę).

$$D(x, y, \sigma) = G(x, y, k\sigma) - G(x, y, \sigma) \cdot I(x, y) = L(x, y, |k\sigma) - L(x, y, \sigma) \quad (4)$$

Kur k – glotninimo funkcijos spindulio koeficientais, D – *Gauso* skirtumų funkcija, L – *Laplaso* funkcija. *Gauso* mastelio normalizacija atliekama taikant *Laplaso* funkciją su koeficientu σ^2 .

Sudaroma *Gausi* piramidė, tam kad būtų galima sudaryti skirtingų mastelių vaizdus. Šios piramidės visa kintamo dydžio erdvė sudalinama į tam tikrus ruožus – oktavas. Prieš tai sekanti oktava visada bus dvigubai didesnė negu prieš tai buvusioji. Kiekvieną kartą pereinant prie kitos oktavos atliekami duomenų pergrupavimas, kurio rezultatas yra sumažėjęs duomenų kiekis du kartus (žr. 7 a pav.). Pagal glotninimo žingsnį σ išrenkami tam tikras kiekis *Gausianų* iš N piramidės. Pavyzdžiui, turime tam tikrą kiekį *Gausianų* N piramidėje. Iš jų kiekvienas *DoG* vaizdo taškas yra palyginamas su tuo pačiu vaizdu, tik jau kitoje kaimynystėje esančiais, aštuoniais taškais. Taip pat taškai lyginami su kitais taškais esančiais *DoG* vaizde piramidėje su žemesniu lygiu. Taip atliekami iš viso 26 palyginimai.

Taškas laikomas charakteringu, tuo atveju jeigu pažymėtas taškas (X), 7 b paveiksle. paveiksle priklauso *DoG* funkcijos lokaliame ekstremumui.



a) Mastelio erdvės oktava [37]

b) Ekstremumų skaičiavimas [37]

7 pav. SIFT metodo schemos

Kai surandami charakteringieji taškai pereinama prie ekstremumų patikros, tam taikoma charakteringųjų taškų lokalizacija.

Charakteringųjų taškų lokalizacija

Charakteringųjų taškų lokalizacija (angl. *Keypoint localization*). Šiame žingsnyje nustatoma, taško tikslumu, atrinktų taškų koordinatės. Taikant antros eilės *Teiloro* daugianarij, atliekamas DoG funkcijos aproksimavimas[37]:

$$D(x) = D + \frac{\partial D^T}{\partial x} x + \frac{1}{2} x^T \frac{\partial^2 D}{\partial x^2} x \quad (5)$$

Kur D – DoG funkcija, $x = (x, y, \sigma)^T$ – taško poslinkio vektorius. Teiloro daugianario ekstremumas randamas paskaičiuojant DoG funkcijos išvestinei, kuri prilyginama nuliui. Ekstremumo taško poslinkis skaičiuojamas pagal žemiau pateiktą formulę:

$$\hat{x} = \frac{\partial^2 D^{-1}}{\partial x^2} \frac{\partial D}{\partial x} \quad (6)$$

Jeigu ekstremumo rezultatas gaunamas didesnis negu 0,5, tai reiškia, kad buvo netinkamai išreikštas taškas, jis gali būti kaimynystėje. Tada pereinama prie kito taško. Taip einama kol patikrinama visi kaimyniniai taškai. Jeigu išeinama iš oktavos ribų, tada nėra atliekamas ekstremumo taško tikrinimas. Funkcijos ekstremumo verte $D(\hat{x})$ taikoma atmesti netinkamiems taškams:

$$D(\hat{x}) = D + \frac{1}{2} \frac{\partial D^T}{\partial x} \hat{x} \quad (7)$$

Orientacijos priskyrimas charakteringiems taškams

Orientacijos priskyrimas charakteringiems taškams (angl. *Oreintation assignment*), juos priskiriant remiamasi lokaliomis vaizdo savybėmis. Pasiiekti pastovų orientacijos priskyrimą nepriklausiant nuo vaizdo pasukimo, atliekami šie žingsniai:

- Sukuriama histograma lokaliios vietos gradiento kryptims skaičiuoti pasirinktu masteliu;
- Parinkti kanoninę orientaciją išlygintos histogramos viršuje;
- Kiekvienas charakteringasis taškas aprašomas 2D koordinatėmis (x, y) , dydžiu ir orientacija.

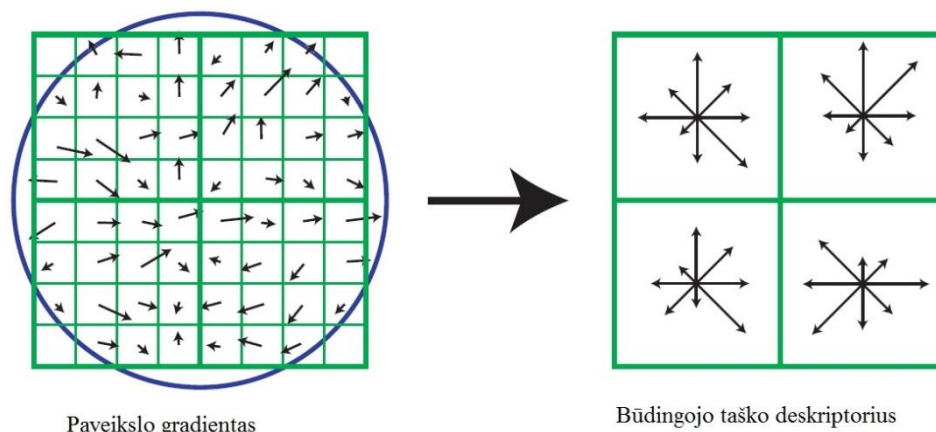
Vaizdas išlyginamas su *Gauso* funkcija pagal charakteringųjų taškų gauto rezultata nuotraukoje L . Tada apskaičiuoja gradiento dydį $m(x, y)$ ir orientaciją kiekvienam taškui $Q(x, y)$, kurių koordinatės yra (x, y) aplink jį esantį regioną (žr. 8 ir 9 formules).

$$m(x, y) = \sqrt{(L(x + 1, y) - L(x - 1, y))^2 + (L(x, y + 1) - L(x, y - 1))^2}, \quad (8)$$

$$Q(x, y) = \arctan(L(x, y + 1) - L(x, y - 1)) / (L(x + 1, y) - L(x - 1, y)) \quad (9)$$

Aprašas

Aprašas (angl. *keypoint decriptor*) – tam tikros savybės ar bruožo apibūdinimas, kuris nustato savybių sintaksę ir semantiką.



8 pav. Paveikslo gradiento ir charakteringojo taško aprašo vaizdas [37]

Kiekvienam charakteringam taškui nustatoma lokalizacija, dydis, orientacija, tai apibrėžiama lokaliais 2D koordinatėmis, kuri apima apibūdintas sritis. Pirmiausiai apskaičiuojamas paveikslo gradientas ir orientacija kiekvienam paveikslo taškui esančiam šalia charakteringo taško. Vėliau sudaromos orientacijų histogramos 8 krypčių. Kiekvienos rodyklės ilgis atitinka histogramos įėjimo dydį (žr. 8 pav.). Pavyzdžiui, sukuriamas 4x4 aprašas 16x16 regionams esantiems šalia charakteringo taško, gaunasi $4 \cdot 4 \cdot 8 = 128$ elemento vektoriai.

2.3 RANSAC

RANSAC (agl. *Random sample and consensus*) buvo pristatys *Fischler* ir *Bolles* 1981 metais, kaip metodas suskaičiuoti pradinius taškus iš tam tikro modelio. Vėliau šis metodas patobulintas *Lowe* 1999 metais. Šio tikslas – panoraminių nuotraukų sujungimui, pagal atitinkamus taškus (Apie panoraminių nuotraukų sujungimą aprašyta plačiau 1.3.1). Dar vienas iš būdų panaudoti šį metodą yra roboto matomo vaizdo (kairės ir dešinės) sujungimas į vieną vaizdą. Šio variantu, kad atsirastų mažiau paklaidų taikoma homografija.

RANSAC susidaro iš dviejų etapų:

- a) Atrinkimas. Atsitiktiniu būdu atrenkami charakteringieji taškai lyginamojoje ir tiriamojame nuotraukoje.
- b) Patikrinimas. Lyginama charakteringi taškai tarp lyginamosios ir tiriamosios nuotraukos. Jeigu daugiau už atitinkamą ribą, tada šių taškų pora laikoma atitikmeniu.

Šie du žingsniai kartojami tol kol praeina visą nuotrauką ir randa poras, kurios tarpusavyje sutinka. Artimiausio kaimyno radimui taikomas *Kd-trees* ir jo variacijos.

2.4 SURF

SURF (agl. *Speeded-up Robust Features*) – Greitas požymio išskyrimas. Šio metodo bendrų nuotraukų transformacijos gali būti:

- Nuotraukos pasukimas;
- Dydis;
- Apšvietimo pakeitimas;
- Maži žiūrėjimo taško pasikeitimai.

Bendras procesas aprašomas šiais žingsniais:

1. Greitas charakteringo taško suradimas;
2. Orientacijos nustatymas;
3. Aprašas;
4. Aprašų atitikimas.

Greitas charakteringo taško suradimas

Greito charakteringo taško suradimui (angl. *Fast interest point detection*) taikoma vientisas paveikslas, kuris leidžia įgyvendinti kvadrato tipo sąsukos filtrus. Vientiso vaizdo įėjimas $I_{\Sigma}(x)$ padėtis $x = (x,y)$ pateikia sumai visų vaizdo elementų įvesties vaizde stačiakampio srityje. Stačiakampį suformuoja nuo pradžios iki taško x pagal formulę [20]:


$$I_{\Sigma}(x) = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq y} I(i, j) \quad (10)$$

Apskaičiavimas vyksta tik per keturis pridėjimus, apskaičiuotus pagal intensyvumo sumą vertikaliai stačiakampio formos ploto, nepriklausimai nuo dydžio. Po šio žingsnio seka detektoriaus suradimas pagal *Hessian* matricą. Šis matricos skaičiavimas greitas ir tikslus [21], tačiau, užuot naudoję skirtingą matą, tam kad išskirtų vietą ir mastelį, kaip ieškoma *Hessian-Laplace* detektoriaus[21], čia skaičiuojamas abiem variantams *Hessian* determinantas.

$$\mathcal{H}(x, \sigma) = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix} \quad (11)$$

Kur $L_{xx}(x, \sigma)$ – *Gauso* sąsukos antroji išvestinė $\frac{\partial^2}{\partial x^2} g(\sigma)$ su paveikslu I taške x , taip pat $L_{xy}(x, \sigma)$ ir $L_{yy}(x, \sigma)$.

Charakteringojo taško suradimui nuotraukoje apskaičiuojama maksimumas iš *Hessian* matricos determinanto ir tada interpoliuojama mastelio ir vaizdo erdvėje pagal *Brown et al*[22] metodą. 9-tame paveiksle vaizduojama greitas *Hessian* detektoriaus pavyzdys.




9 pav. Charakteringų taškų suradimas paremtas *Hessian* detektoriumi.

Orientacijos nustatymas

Orientacijos nustatymas reikalingas tam, kad rastų charakteringus taškus, jeigu nuotraukoje esantis objektas yra paverstas ar pati nuotrauka yra pasukta kitu kampu. Orientacijos nustatymui taikoma *Harr wavelet* atsakas, kur x ir y kryptimis einantis per apskritimo kaimynystės spindulius apie charakteringuosius taškus, su s dydžiu, kuriuo buvo aptiktas. Reikalinga tik 6 operacijos apskaičiuoti atsaką x ir y kryptimis bet kokio dydžio. Kai yra apskaičiuotas *Harr wavelet* atsakas ir apskaičiuojamas centro svoris charakteringame taške pagal *Gauso* funkcija ($\sigma = 2s$). Atsakas yra kaip kiekis erdvėje su horizontale atsako

stiprumu vaizduojama abscisių ašyje ir vertikalus atsako stiprumas – ordinačių ašyje. Dominuojanti orientacija įvertinama apskaičiuojant visų atsakų sumą su keičiamu orientacijos dydžiu $\pi/3$. Tai galima pamatyti 8 paveiksle.



10 pav. Orientacijos priskyrimo vaizdas [20]


Vertikalūs ir horizontalūs atsakai su skirtingais lango dydžiais sumuojami. Dvieju susumuotų atsakų yra lokalus orientacijos vektorius. Ilgiausiais toks vektorius per visus skirtingus lango dydžius laikomas charakteringojo taško orientacija. Įtakos turi lango dydžio parinkimas, jeigu netinkamai bus parinktas dydis, tada gali atsirasti netinkami vektoriai, tai per ilgi tai per trumpi, kurie nebus laikomi charakteringojo taško orientacija.

Haar wavelet atsako sumos skaičiavimai atliekami sudarant centralizuotą kvadratą apie charakteringąjį tašką. Sudarytų kvadratų pavyzdys paveiktas 11 paveiksle.



11 pav. Orientuoto aprašo langas su skirtingais dydžiais[20]

Po to kvadratas padalinamas į mažesnius 4×4 kvadratus. Šie kvadratai išsaugo svarbią erdvinę informaciją. Kiekviename mažesniame kvadrato apskaičiuojama *Haar wavelet* atsakas su reguliariais 5×5 tarpais imties taškų. *Haar wavelet* atsakas horizontalioje ašį žymimas d_x , vertikalioje ašyje d_y (taip pažymėta 12 paveiksle). Horizontalumas ir vertikalumas priklauso nuo sąsajos su pasirinktu charakteringuoju tašku.



12 pav. Aprašas, orientuotas kvadratiname tinklelyje su 4x4 kvadratinu išskirstymu apie charakteringąjį tašką [20]


Absoliučios reikšmės $|d_x|$ ir $|d_y|$ skaičiuojamos sužinoti informacija apie ryškumo/tamsumo pasikeitimus.

Tiek SURF tiek SIFT charakteringųjų taškų orientacijos sudarymas panašus, abudu metodai taiko erdvinį paskirstytą gradientą. Tik SURF metodas yra geresnis tuo, kad viena kvadratas yra išskaidomas dar į mažesnius kvadratus. Dėl šio dalyko SURF metodas atsparesnis triukšmams.

Aprašo atitikimas

Greitas numeravimas atliekamas aprašų atitikimo stadijoje, įsitikinant ar charakteringasis taškas yra įtrauktas į sąrašą. Dažniausiai charakteringieji taškai randami pagal bloko struktūrą. Taikant *Laplaso* metodą išskiria šviesiuosius blokus tamsiame fone iš atvirkštinės situacijos. Ši funkcija nereikalauja papildomų resursų, nes atliekama per charakteringoje taško nustatymo etapą.

Aprašų atitikimo stadijoje, lyginama požymis pagal tą patį kontrastą (žr. 13 pav.)



13 pav. Dviejų charakteringųjų taškų palyginimas pagal kontrastą

Toks palyginimas vyksta greitai ir nereikalauja papildomų resursų.


2.4.1 HOG aprašas

HOG (angl. *histogram of oriented gradients*) – dar vienas charakteringųjų taškų aprašas, taikomas aptikti objektus nuotraukų apdorojimo procese. Šis metodas paremtas orientuoto gradiento skaičiavimu atitinkamose nuotraukos dalyse.

Šio metodo procesas išskirstomas į etapus:

1. Nuotraukos vaizdo mažus regionus – ląstelės. Pavyzdžiui ląstelę sudaro x ašimi 4 ir y ašimi 4 aktyvieji vaizdo elementai. Kiekvienam vaizdo elementui ląstelėje sudaroma gradiento histograma arba kampo orientacija.
2. Diskretizuojama kiekviena ląstelė pagal gradiento orientacijas.

3. Kiekvienas ląstelės vaizdo elementas turi svartinį gradientą, pagal kurį suskirsto į atitinkamas histogramos stulpelius.
4. Kaimyninės ląstelės sugrupuojamos į blokus. Normalizuoja histogramos reikšmės.
5. Normalizuotos histogramos grupė atstovauja bloko histogramą. O šie sudaro aprašą.



14 pav. Vizualinis HOG aprašo pavyzdys [31]


Vizualinis ląstelės (angl. *cells*), bloko (angl. *block*), ląstelių histogramos (angl. *cell histograms*) ir normalizuotos histogramos (angl. *normalized histograms*) (žr. 14 pav.).

2.4.2 BRISK detektorius

BRISK (angl. *Binary Robust Invariant scalable keypoints*) - tai dvejetainis charakteringųjų taškų radimo detektorius. Jį galima derinti kartu su SIFT, SURF ir kitais aprašais. Šio metodo pagrindiniai privalumai: nesudėtingas skaičiavimas, nėra gradiento skaičiavimo, taiko *Hamming* atstumo radimą, vietoje *Euklido*. Pagal atliktus ankstesnius tyrimus, išaiškinta, kad jis greitesnis už SIFT ir SURF metodus. Tokį rezultatą gavo *Leutenegger S., M. Chli, ir R. Siegwart* [30]. Dvejetainis charakteringųjų taškų metodas rekomenduojamas naudoti realiu laiku apdorojamose įrenginiuose arba mažos energijos įrenginiuose.

BRISK metodas išskirstomas į etapus:

1. Charakteringojo taškas apibūdinamas kaip dvejetainė eilutė. Charakteringojo taško kaimynai randami pagal deterministinį modelį, vienodai išdėstytus taškus ar pagal to taško koncentruotus apskritimus. Taško koncentruotas apskritimo pavyzdys pateiktas 15 paveiksle. Jame sudaryta 60 taškų. Mėlynas taškas nusako vietą. Raudona apskritimas atitinkamu atstumu aplink šį tašką, nurodo atitinkantį standartinio nuokrypio *Gauso* funkcijos intensyvumo reikšmes.



15 pav. Taškais koncentruotas apskritimas [30]

1. Ieškomos charakteringųjų taškų poros. Jos dar skirstomos į trumpąsias ir ilgąsias. Šioms poros nurodoma slenkstinė riba, kuri nurodo kuriai grupei pora priklauso.
2. Orientacijos nustatymo metu apskaičiuojamas gradientas tarp tolimųjų porų. Sudedamas gradientas pagal formulę 12.

$$g(p_i, p_j) = (p_j - p_i) \cdot \frac{I(p_j, \sigma_j) - I(p_i, \sigma_i)}{\|p_j - p_i\|^2} \quad (12)$$

Kur g – gradientas, p_i, p_j – vaizdo elementai, σ_j – slenksinės ribos reikšmė.

3. Sudaromas dvejetainis aprašas. Palyginama charakteringi taškai. Trumpo atstumo porų radimui taikoma 13 formulė:

$$b = \begin{cases} 1, & \text{jeigu } I(p_j^\alpha, \sigma_j) > I(p_i^\alpha, \sigma_i) \\ 0, & \text{kitu atveju} \end{cases} \quad (13)$$

$$\forall (p_i^\alpha, p_j^\alpha) \in S$$


Palyginimui taikoma *Hamming* atstumo skaičiavimas tarp dviejų vienodų simbolių eilučių pozicijų, kuriame kiekvienas simbolis yra skirtingas. Jis matuoja minimalų alternatyvų skaičių, kai pakeičia viena eilutė kitą. Taip pat gali ieškoti minimalaus klaidų skaičiaus, kurios galėjo transformuoti vieną eilutę į kitą.

2.4.3 FAST detektorius

FAST (angl. *Features from Accelerated Segment Test*) – charakteringųjų taškų aptikimo algoritmas pagal kampus (kampus detektorius). Šį metodą pasiūlė *Rosten* [28], tačiau sukonkretino ir aprašė ieškomų taškų atvaizdavimą *Drummond*. Taip pat yra kitų charakteringųjų taškų radimo pagal kampus, pavyzdžiui: *Moravec*, *Harris* ir *Stephens Susan*.

FAST metodas apibrėžia tiksliai charakteringojo taško vietą nuotraukoje. Kai lyginama charakteringieji taškai, jie turi būti toje pačioje vietoje. Bet koks vaizdo pasukimas,

didesnis apšvietimas gali turėti įtakos rezultatams. Šį detektorių galima derinti su kitais aprašais kaip SURF.



16 pav. *Bresenham* ratas[29]

FAST metodo išskaidomas į 7 etapus [29]:

1. Nuotraukoje pažymimas vaizdo elementas p (žr. 16 pav.). Šio vaizdo elementas turi būti indikatorius I pateiktos nuotraukos. Jis turi nurodyti nuotraukoje esantį kampą ar ne kampą.
2. Nustatoma intensyvumo vertė T . (pavyzdžiui 20 %).
3. Sudaromas *Bresenham* ratas. Į šį ratą įeina 16 aplinkinių vaizdo elementų (žr.16 pav.).
4. *Bresenham* rate esantys aplinkiniai 16 vaizdo elementai turi atitinkamą vertę I . Ji mažesnė arba didesnė už p vaizdo elemento I reikšmę ir atitikti charakteringojo taško kriterijų.
5. Patikrinamas vaizdo elementų intensyvumas *Bresenham* rato taškuose 1,5,9 ir 13.
6. Jeigu trys arba keturios vaizdo elemento indikatorius reikšmės yra žemiau arba lygios $I+T$, tada p nėra charakteringasis taškas (ieškomas kampas), Jeigu yra bent trys taškai virš arba žemiau ribos $I+T$ tada yra patikrinami visi 16 elementai. Jeigu 12 atitinka tada vaizdo elementas priskiriamas charakteringajam taškui.
7. Kartoti procedūrą visiems vaizdo elementas nuotraukoje.

Siekiant pagreitinti veikimą sumažinama *Bresenham* rato vaizdo elementų skaičiaus nuo 16 iki 12, tačiau tokiu variantu atsiranda labai daug charakteringųjų taškų.

2.5 BRIEF Aprašas

BRIEF (angl. *Binary robust independent elementary features*) aprašas, jį galima derinti su kitais detektoriais, sudarant pilną aprašo ir detektoriaus porą. Tokią porą galima panaudoti vaizdų atpažinime.

Aprašo etapai:

1. Sukuriamas centruotas gaubiantis fragmentas apie charakteringąjį tašką;
2. Fragmentas apdorojamas *Gauso* filtru (žr. 14 formulę);

$$f(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (14)$$

3. Lyginama du vaizdo elementai pagal intensyvumą tame pasirinktame fragmente. Nustatoma x ir y vieta, tada apskaičiuojama $p(x)$, $p(y)$ intensyvumas vaizdo elementas. Vietos nustatymui, x ir y , taikoma *Gauso* skirstinys.
4. Sudaroma dvejetainė seka n ilgio su n kartų palyginimų. Dvejetainė seka tai yra BRIEF aprašas (žr. 15 formulę), kurio ilgis gali būti 128, 256 ir 512 bitų. Naudojama atitikimui *Hemingo* atstumas.

$$f_{n_d}(p) := \sum_{1 \leq i \leq n_d} 2^{i-1} \tau(p; x_i, y_i) \quad (15)$$

Michael Calonder, Vincent Lepetit, Christoph Strecha, ir Pascal Fua [36] atliko tyrimus su BRIEF aprašu. Pagrindiniai tikslai išsiaiškinti ar BRIEF priklauso nuo vaizdo požiūrio kampo, suspaudimo, apšvietimo pasikeitimų ir suliejimo. BRIEF lyginamas su SURF. Iš tyrimo rezultatų galima teikti tokius BRIEF privalumus:

- Didelės spartos apdorojimas;
- Naudoja mažai atminties;
- Atsparus apšvietimo, suliejimo pasikeitimas.

BRIEF Trūkumai:

- Priklauso nuo vaizdo požiūrio pasikeitimų;
- Priklauso nuo šviesos pokyčių. Kuo didesnis pokytis, tuo mažiau randa charakteringųjų taškų.

Hemingo atstumo ir Euklido atstumo skaičiavimas

Euklido atstumo algoritmas skirtas surasti ilgį tarp dviejų a ir b taškų. Atstumas tarp dviejų taškų žymimas d ir skaičiuojamas pagal 16 formulę.

$$d(a, b) = d(b, a) = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2 + \dots + (a_n - b_n)^2} \quad (16)$$

Ši formulė gali būti pritaikyta vienmatei, dvimatei, trimatei erdvei. Jeigu dvimatė erdvė tai skristis tuo, kad atsiras koordinatės $a = (a_1, a_2)$ ir $b = (b_1, b_2)$, žiūrėti 17 formulę.

$$d(a, b) = d(b, a) = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2} \quad (17)$$

Toks algoritmas pritaikytas surasti atstumui tarp dviejų charakteringųjų taškų.

Hemmingo algoritmas skirtas skaičiuoti skirtumą tarp dviejų simbolių/skaičių sekų (angl. *codeword*). Pavyzdys: Turime seką 1011101 ir 1001001. Apatiniu brūkšniu pažymėtas skirtumas 1011101 ir 1001001. Tarp šios sekos *Hamming* atstumas 2. Jis matuoja minimalų padavimų skaičių, kuriuos norint pakeisti vieną eilutę į kitą. Kitaip dar minimalus klaidų skaičius.

2.6 ORB

ORB – yra pagrįstas tais pačiais principais kaip BRIEF, tik papildyta atsparumu nuotraukos triukšmams ir įvairiems pasukims. *Ethan Rublee, Vincent Rabaud, Kurt Konolige, Gary Bradski* atliko tyrimus su ORB [23] įrodydami, kad šis metodas yra alternatyva SURF ir SIFT metodams. Našumo atžvilgu ORB gauti rezultatai geresni nei SIFT, SURF.

2.7 Tikėtinumo santykio logaritmas

Tikėtinumo santykio logaritmas nurodo kiek kiekybiškai objektai vienas su kitu panašūs. Ši metrika galima taikyti veidų atpažinimo sistemose ar kitose sistemose kur reikalinga nustatyti kiek tiriamasis objektas panašus į lyginamąjį objektą. Kuo tikėtinumo santykio logaritmas didesnis, tuo didesnė tikimybė, kad objektai tarpusavyje sutampa. Tiriamasis ir lyginamasis objektai atpažinimo sistemoje, tarpusavyje lyginami ir pateikiama jų tarpusavio panašumo ir nepanašumų. Šių porų reikšmių sritis priklauso nuo lyginamos metrikos.

Tikėtinumo santykio logaritmas bus taikomas vietovės objektų atpažinimui. Priklausimai nuo to kur taikoma, tai gali apsunkinti panašumo reikšmių interpretacija [26]. Jeigu turime lyginamosios ir tiriamosios porų panašumo koeficientus: $p_1 = 0.8$ ir $p_2 = 0.72$, iš to seka, kad p_1 poros koeficientas didesnis, negu antrosios ir pirmosios poros objektai panašesnis.

Lyginamos biometrijos poros (X, Y) panašumo tikėtinumo santykis apibrėžiamas 14 formule [26]:

$$LR(X, Y) = \frac{\text{Tikėtinumas, kad lyginamos poros}(X, Y) \text{ biometrikos sutampa}}{\text{Tikėtinumas, kad lyginamos poros}(X, Y) \text{ biometrikos nesutampa}} \quad (14)$$

Vietovės objektų atpažinimui biometrika – tai atitikę/ neatitikę charakteringieji taškai. $P(A)$ – tikėtinumas, kad atitikę charakteringieji taškai priklauso tiriamai vietai, darant prielaidą, kad vietovės yra tos pačios. Apskaičiuojamas pagal 15 formulę:

$$P(A) = \frac{\text{Atitikę charakteringieji taškai}}{\text{Nuotraukos visi charakteringieji taškai}} \quad (15)$$

$$P(B) = 1 - P(A) \quad (16)$$

$P(B)$ – Tikėtinumas, kad charakteringieji taškai nepriklauso tiriamai vietai, darant prielaidą, kad lyginamosios ir tiriamosios nuotraukos vietovės skirtingos. Apskaičiuojamas pagal 16 formulę.

Bendraja prasme tikėtinumas yra modelio tikimybė, kai žinomi atlikto eksperimento rezultatai [26]. Šiuo atveju eksperimento rezultatai yra tiriamosios ir lyginamosios nuotraukos bendri charakteringieji taškai. Šiuo atveju ar lyginami objektai sutampa galima remtis dviem savybėmis – jų panašumu ir nepanašumu.

LR koeficientai gali kisti nuo iki ∞ . Jei $LR = LR(X, Y) < 1$, labiau tikėtina, kad lyginamos vietovės yra skirtingos. Priešingai, jei $1 < LR < \infty$, labiau tikėtina, kad lyginamo vietovės sutampa. Kartais, kad vartotojui būtų suprantamiau pateikiama LLR (angl. *Log Likelihood Ratio*) reikšmės. Apskaičiuojamas pagal 17 formulę

$$LLR(X, Y) = LLR = \log(LR(X, Y)) \quad (17)$$

Pagal LLR reikšmes paprasčiau nusakyti ar tiriamos vietovės yra panašios ar ne. Jeigu LLR yra teigiamas tada labiau tikėtina, kad tiriamosios ir lyginamosios vietovės sutampa, abiejuose nuotraukose yra ta pati vietovė. Jeigu LLR reikšmė yra neigiama, tada labiau tikėtina, kad tiriamosios ir lyginamosios vietovės yra skirtingos, abiejuose nuotraukose pateikiama skirtingos vietovės.

1.4 lentelėje pateiktos LR ir LLR reikšmės bei jų interpretacija. Pavyzdžiui, jei $LLR = 6$, tai apie 403,4 kartų labiau tikėtina, kad lyginamosios ir tiriamosios vietovės sutampa.

1Lentelė Tikėtinumo santykio LR ir jo natūraliojo logaritmo LLR reikšmės[26]

LR	LLR	Interpretacija
----	-----	----------------

1000	6,9	Labai tikėtina, kad lyginami objektai sutampa
403,4	6	Labai tikėtina, kad lyginami objektai sutampa
100	4,6	Pakankamai tikėtina, kad lyginami objektai sutampa
20,1	3	Tikėtina, kad lyginami objektai sutampa
10	2,3	Labiau tikėtina, kad lyginami objektai sutampa
7,4	2	Labiau tikėtina, kad lyginami objektai sutampa
1	0	Vienodai tikėtina, kad lyginami objektai sutampa arba nesutampa
1/7,4	-2	Labiau tikėtina, kad lyginami objektai nesutampa
1/10	-2,3	Labiau tikėtina, kad lyginami objektai nesutampa
1/20,1	-3	Tikėtina, kad lyginami objektai nesutampa
1/100	-4,6	Pakankamai tikėtina, kad lyginami objektai nesutampa
1/403,4	-6	Labai tikėtina, kad lyginami objektai nesutampa
1/1000	-6,9	Labai tikėtina, kad lyginami objektai nesutampa

Taip pat yra ir kitokių palyginimo algoritmų. Pavyzdžiui, formuluojant apibendrinamuosius statistinius rezultatus, galima išskirti du pagrindinius kriterijus [26] kuriais siūloma remtis:

1. Centrinės tendencijos matas: reikia pasirinkti statistiką kuri rodytų kiek panašūs yra skirtingi objektai;
2. Statistinio kintamumo matas: pasirinkti kitą statistiką, kuri rodytų kaip labai jie skiriasi.

2.8 Trumpas skyriaus apibendrinimas

SIFT charakteringųjų taškų išskyrimo metodas susideda iš detektoriaus ir aprašais. Detektorius suranda charakteringuosius taškus, netinkamus atmeta. Sprendžia problema kaip greitai surasti charakteringuosius taškus nuotraukoje. Detektoriai gali būti: LoG filtras, FAST, BRISK, ORB ir kiti.

Aprašas yra tam tikros savybės ar bruožo apibūdinimas ir jis apibrėžia savybių sintaksinę ir semantiką. Savybių išgavimas sprendžia problemą, kaip apibūdinti charakteringuosius taškus, kad galėtume palyginti juos su kitoje nuotraukoje esančiais charakteringais taškais. Siekiant išgauti tikslesnį objekto atpažinimą galima derinti su aprašais ir detektoriais. Pavyzdžiui, galima naudoti SIFT detektorių ir vietoje normalizuoto gradiento aprašo taikyti BRISK.

Be SURF, SIFT charakteringųjų taškų išskyrimo ir aprašo sudarymo metodų yra GLOH, DAISY. GLOH metodas panašus į SIFT, tačiau turi platesnį erdvinį išdėstymą histogramoms. Antrasis DAISY aprašas panašus į SIFT ir GLOH, kur histogramų gradientas apskaičiavimui taikoma *Gaussian* svorinę funkciją ir sukamąjį simetrinį branduolį. Dėl šių funkcijų pasirinkimo gaunamas greitas ir efektingas skaičiavimas. Maždaug per 5 sekundes galima surasti 200 aprašų kiekvienam aktyviajam vaizdo elementui, kai nuotraukos dydis 800x600.

Taip pat yra dvejetainiai aprašai: BRIEF, ORB, BRISK, LDAHash. BRIEF – bendrosios paskirties charakteringųjų taškų aprašas, kuris gali būti sujungtas su detektoriais,

pavyzdžiui SURF arba SIFT metoduose galima pritaikyti BRIEF charakteringųjų taškų aprašų, taip pagreitinant metodų efektyvumą. ORB tai greitas lokalių ypatybių detektorius, paremtas charakteringų taškų suradimu ir BRIEF aprašu. ORB alternatyva metodams SIFT ir SURFT[23]. BRISK – charakteringojo taško krypties nustatymas, tam kad eitų sudaryti orientaciją/normalizacija aprašo. Šiuos funkcijos tikslas, pasiekti atsparumą nuotraukos pasisukimui.

SIFT metodas atsparus apšvietimo pasikeitimui, bei mažiems stebėtojo kampo pasikeitimams[22]. Palyginus SIFT su SURF, antrasis gali susitvarkyti su nuotraukos esančiais neryškiais objektais, tačiau ne visada susitvarko su apšvietimo ir stebėtojo kampo pasikeitimams [20]

Nustatyti ar tikrai lyginamųjų objektų charakteringieji taškai sutampa sprendžiama pagal tikėtino santykio logaritmą.

3 Vaizdų atpažinimo realizacinė dalis

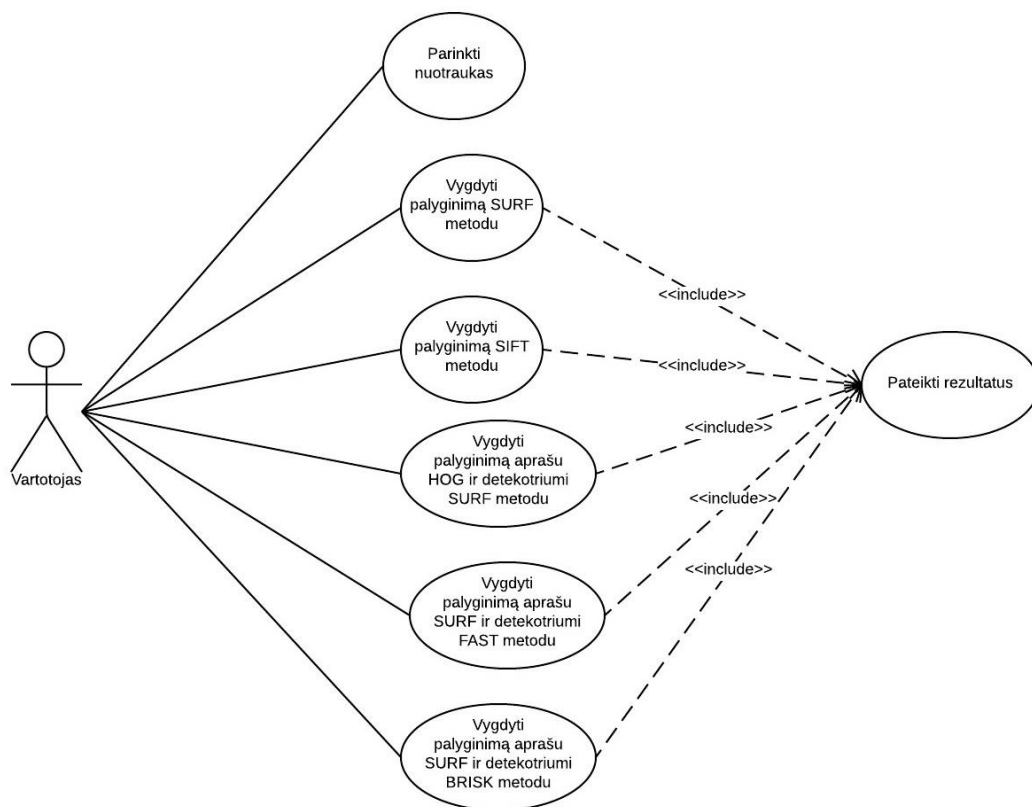
3.1 Paskirtis

Tiriamoji sistema skirta eksperimentuoti su charakteringųjų taškų metodais. Sistemos vartotojas gali rinktis, kokį charakteringųjų taškų metodą pasirinkti. Charakteringųjų taškų metodai: SURF, aprašas HOG ir detektorius SURF, aprašas SURF ir detektorius FAST, SIFT, aprašas SURF ir detektorius BRISK.

Pagalbinės priemonės, tokios, kaip kiekybinis nuotraukų įvertinimas, atitikusių charakteringųjų taškų atvaizdavimas palengvina eksperimentavimo darbus.

3.2 Funkciniai reikalavimai

Žemiau esančiame paveikslėlyje pateikia tiriamosios sistemos panaudos atvejų diagrama (žr. 17 pav.).



17 pav. Tiriamosios sistemos panaudos atvejų diagrama

Tiriamosios sistemos panaudos atveju diagrama nurodo naudotojo sąveiką su sistema bei jų tarpusavio ryšius su skirtingais naudojimo atvejais.

Vartotojas gali atlikti 6 veiksmus. Iš jų 5 atvejai yra vykdyti skirtingus metodus. Įvykdžius šiuos metodus visada pateikiami rezultatai.

Svarbiausios 6 sistemos funkcijos yra šios:

- Parinkti nuotraukas;
- Vykdyti palyginimą SURF metodu;
- Vykdyti palyginimą SIFT metodu;
- Vykdyti palyginimą aprašu HOG su detektoriumi SURF metodu;
- Vykdyti palyginimą aprašu SURF su detektoriumi FAST metodu;
- Vykdyti palyginimą aprašu SURF su detektoriumi BRISK metodu;

3.3 Nefunkciniai reikalavimai

Nefunkciniai reikalavimai išskirstomi į: reikalavimai vykdymo charakteristikoms, veikimo sąlygas. Reikalavimai vykdymo charakteristikoms dar išskaidoma į užduočių vykdymo greičio apribojimus ir nuotraukų failo apribojimus.

Reikalavimai vykdymo charakteristikoms

Užduočių vykdymo greičio apribojimai:

- Maksimalus nuotraukos apdorojimo laikas iki 3 h.
- Maksimalus nuotraukų atpažinimo laikas iš nuotraukų failo iki 24 h.

Viršijant nustatytus apribojimus procesas nepradedamas arba nutraukiamas ir tolimesni procesai vykdomi su duomenimis, kurie buvo apdoroti per duotąjį laiką.

Reikalavimai nuotraukų failui:

- Maksimalus nuotraukų failo dydis iki 1. 1GB.
- Nuotraukų kiekis ne daugiau negu 1000.
- Maksimalus nuotraukos raiška 2048 taškų pagal x plotį ir 1152 taškų pagal aukštį.
- Tiriamoji ir lyginamoji nuotraukos tokios pačios raiškos.

Viršijant nustatytus apribojimus procesas nepradedamas.

Reikalavimai veikimo sąlygoms

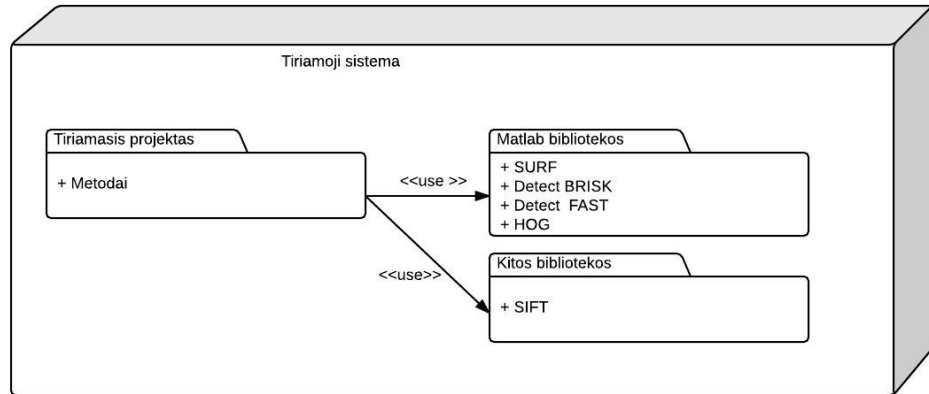
Sistema turi veikti *Windows* 64 bitų operacinėse sistemose, kuriose būtų įrašytas *Matlab R2016a* paketas. Sistema turi veikti tiek nešiojamuose, tiek stacionariuose kompiuteriuose.

3.4 Naudojami trečiųjų šalių metodai

Pritaikytas trečiosios šalies SIFT metodas. Jis paimtas iš viešai prieinamo saityno <https://se.mathworks.com>.

3.5 Sistemos architektūrinis modelis

Žemiau esančiame paveikslėlyje pateikiama tiriamosios sistemos architektūrinis modelis.

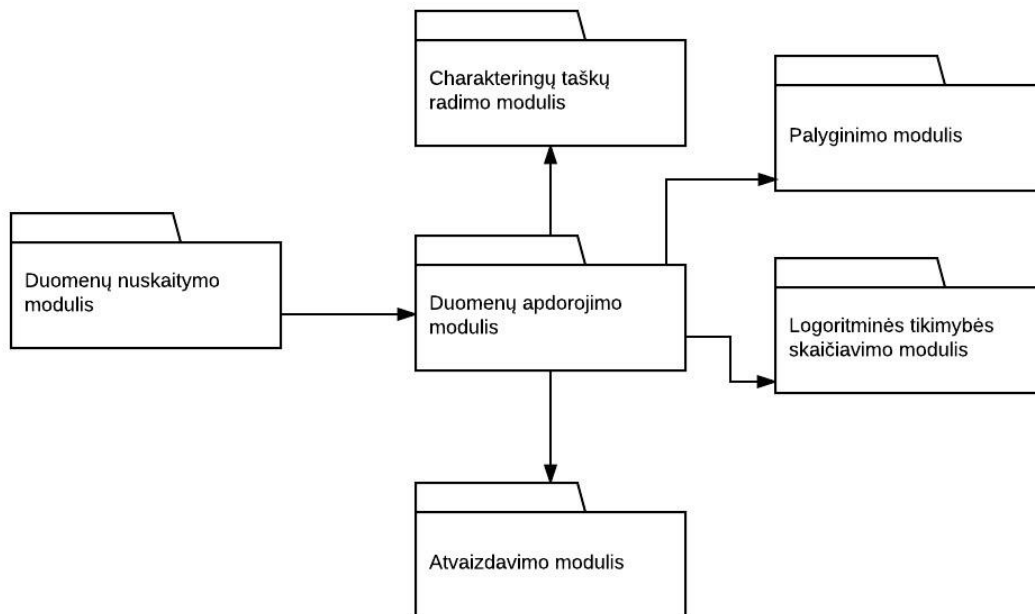


18 pav. Tiriamosios sistemos architektūrinis modelis

Tiriamoji sistema susideda iš tiriamojo projekto, *Matlab* bibliotekų, kitų bibliotekų. Pagrindinis projektas naudoja *Matlab* bibliotekas, bei papildomas bibliotekas paimtas iš trečiųjų šalių.

3.6 Sistemos suskirstymas į modulius

Žemiau pateikiama sistemos suskirstymas į modulius (žr.19 pav).



19 pav. Tiriamosios sistemos suskirstymas į paketus

Sistemą sudaro 6 paketus:

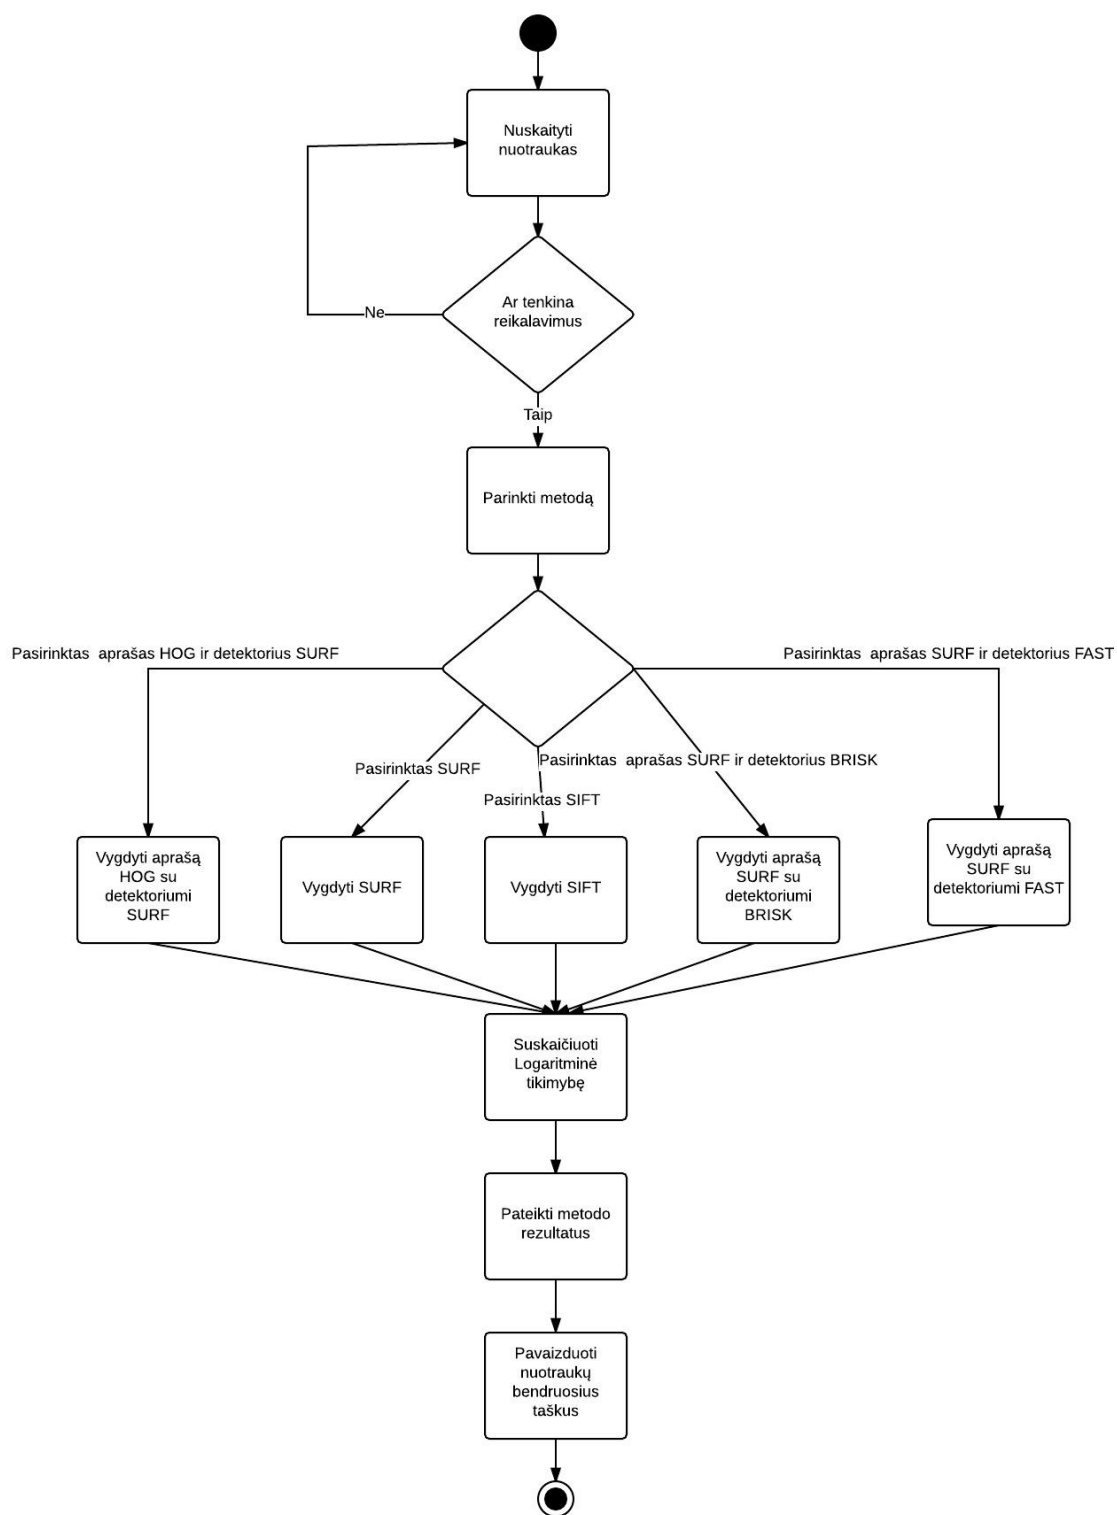
- Duomenų nuskaitymo modulis. Šis paketas atsakingas už nuotraukų nuskaitymą, tiek lyginamosios tiek tiriamosios, bei nuotraukų nuskaitymą iš failo.
- Charakteringųjų taškų radimo modulis. Šiame pakete yra realizuoti charakteringųjų taškų metodai arba pritaikyti prie sistemos.
- Palyginimo modulis. Šiame pakete yra realizuota dviejų nuotraukų palyginimas pagal charakteringuosius taškus.
- Logaritminės tikimybės modulis. Šiame pakete yra realizuotas logaritminės tikimybės apskaičiavimas pagal charakteringuosius taškus.
- Atvaizdavimo modulis. Šiame pakete yra realizuotas bendrųjų taškų atvaizdavimas nuotraukose.

3.7 Sistemos veiklos diagrama

Veiklos diagrama vizualiai parodo sistemos atvejų eigą ir veiksmus. Veiklos diagrama sudaro keletas formų sujungtų su rodyklėmis. Pagrindinės formos:

- Suapvalinti stačiakampiai - nurodo veiksmus;
- Deimanto formos nurodo sprendimus;
- Juodas apskritimas nurodo pradžią (pradinį mazgą) darbo srautams;
- Apvesta juodas apskritimas nurodo pabaigą.

Rodyklės nuleistos nuo pradžios link pabaigos ir nurodo tvarką, kuria vyksta veikla. Žemiau pateikiama tiriamosios sistemos veiklos diagrama.



20 pav. Veiklos diagrama

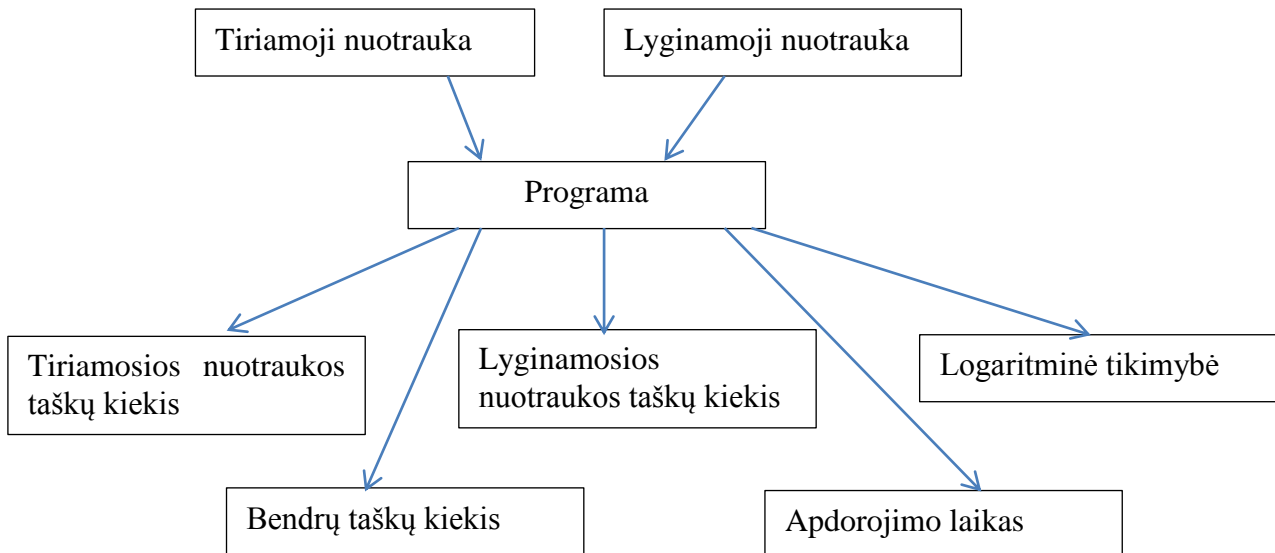
Ją sudaro juodas apskritimas, apvestas juodas apskritimas, du deimanto formos ir 10 suapvalinti stačiakampiai. Pirmasis suapvalintas stačiakampis reiškia veiksmą, nuskaudo lyginamąją ir tiriamąją nuotraukas. Deimanto forma nurodo, kad sistemoje vyksta patikrinimas ar atitinka reikalavimus. Jeigu taip, tada sistema tęsia darbą, jeigu ne – tada vėl

iš pradžių. Po patikrinimo parenkamas charakteringųjų taškų metodas. Galima pasirinkti iš 5 metodų. Būtinai parenkamas kuris nors vienas iš metodų, jis įvykdomas. Metodo vykdymo metu randa charakteringuosius taškus, juos tarpusavyje palygina. Pagal rastų charakteringųjų taškų kiekį apskaičiuoja logaritminę tikimybę. Pateikia metodo rezultatus: tiriamosios, lyginamosios nuotraukų charakteringųjų taškų kiekius, bendrąjį kiekį, logaritminę tikimybę. Paskutiniame veiklos etape pavaizduoja atitinkančius taškus nuotraukose.

4 Charakteringųjų taškų eksperimentinė dalis

Eksperimento tikslas iširti, kuris algoritmas pagal charakteringuosius taškus geriau ir našiau atpažįsta vietovę.

Pirmiausiai programai pateikiama dvi nuotraukos: tiriamoji ir lyginamoji. Programa tai, tam tikras charakteringųjų taškų algoritmas. Programa pateikia lyginamosios nuotraukos charakteringųjų taškų kiekį, bendrą taškų kiekį, apdorojimo laiką ir logaritminę tikimybę.



21 pav. Tyrimo eigos apdorojimo schema


Aukščiau pateikta (žr. 21 pav.) tyrimo eigos apdorojimo schema, tai yra schema, kuri parodo kokie duomenys paduodami ir kokie rezultatai gaunami.

Tyrimai atlikti naudojant asmeninę kompiuterį esant tokiems techniniams parametrms: Nvidia kompanijos vaizdo plokštė *Intel GT-650M*), procesorius *i5 2.30Hz*, atminties kiekis - 4 GB, 64 bitų operacinė sistema. Nuotraukos padarytos su išmaniuoju telefonu *Asus zenfone selfie*, kurio kamera yra 8 megapikselių raiška. Tirtų nuotraukų raiška 2048 taškų pagal x plotį ir 1152 taškų pagal aukštį.

4.1 Tyrimo duomenys

Kiekvienam tyrimui parinkta skirtingi tyrimo duomenys. Skirtingo mastelio tyrimui parinkta skirtingų objektų mastelio nuotraukos, tačiau su ta pačia raiška.


Apšvietimo pasikeitimo tyrimui parinkta nuotraukos su atitinkamu apšvietimo didinimu. Pirmoji nuotrauka su standartiniu 0% apšvietimo, antrosios padidintas iki 20%, trečiosios – 40%, Ketvirtosios – 60%, penktosios – 80%, šeštosios – 95% (žr. 22 pav.).



a) Apšvietimas +20 % b) Apšvietimas +40% c) apšvietimas +60% d) Apšvietimas +80%

22 pav. Nuotraukos su skirtingais apšvietimo padidinimais

Apšvietimo vaizdo pasukimo tyrimui pasirinkta nuotraukoje esantį objektą pasukti atitinkamais laipsniais, pvz.: 30 %, 45%, 60% 90 % (žr. 23 pav.).



23 pav. Vaizdo pasukimai

Nuotraukos imamos nespalvotos, skirtingų objektų, dėl to, kad spalva turėtų mažiau įtakos charakteringųjų taškų pažymėjimui.

Skirtingų perspektyvų tyrimui parinkta vietovė su pastatu. Nuotraukų pavyzdžiai pateikti 24 paveiksle.



a) pradinė nuotrauka



b) 10 laipsnių



c) 20 laipsnių



d) 30 laipsnių

24 pav. Nuotraukų pavyzdžiai

Skirtingų atstumų tyrimui parinkta ta pati vietovė kaip ir prieš tai tyrime, tik vietovės nuotraukos padarytos iš skirtingų atstumų: 16, 21, 26 ir 52 metrų (žr. 25 paveiksle).



a) 16 m atstumu



b) 21 m atstumu



c) 26 m atstumu

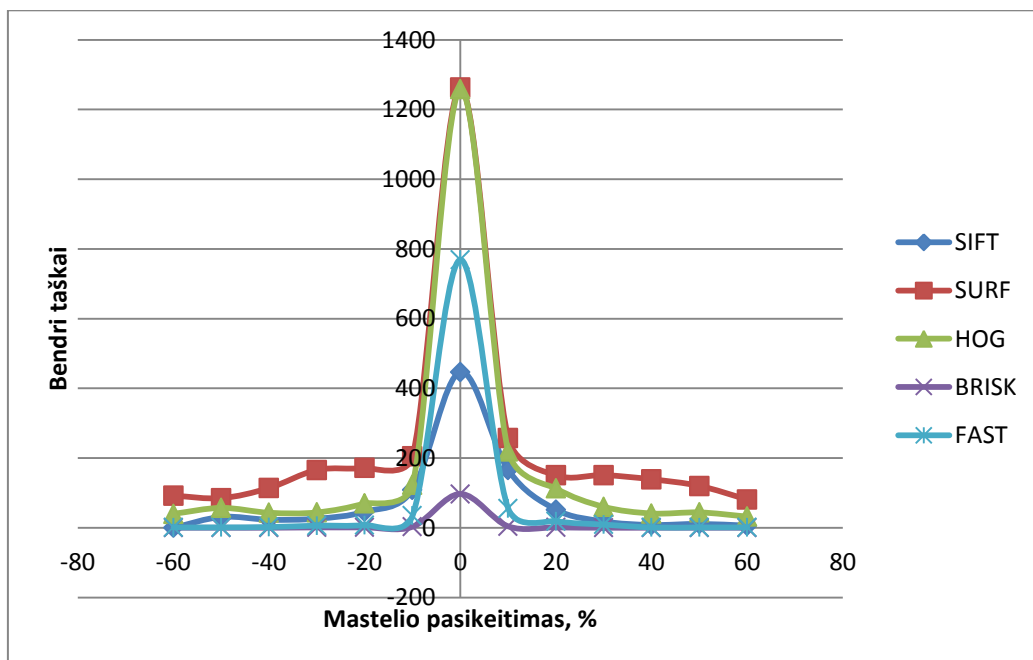


d) 51 m atstumu

4.2 Skirtingo mastelio objekto esančio nuotraukoje tyrimo rezultatai

Skirtingo mastelio objekto pasikeitimo tyrimo tikslas ištirti kaip priklauso mastelio dydis nuo rastų bendrų taškų. Mastelio pasikeitimo tyrimui naudojama tokios pačios nuotraukos raiškos, tik objektas procentaliai sumažinamas arba padidinamas. Metodų rezultatai pateikti paveiksle, x ašimi yra mastelio pakeitimo dydis procentais, y ašimi yra rasti bendri charakteringieji taškai tarp tiriamosios ir lyginamosios nuotraukos. Paveiksle metodai žymimi SURF – SURF, aprašas HOG ir detektorius SURF – HOG, aprašas SURF ir detektorius FAST – FAST, SIFT – SIFT, aprašas SURF ir detektorius BRISK – BRISK

Kaip matosi iš 21 paveikslo, jeigu didinamas mastelis, taip pat keičiasi charakteringųjų taškų kiekis. Jeigu dydis padidinamas 10 procentų, tai charakteringųjų taškų kiekis SIFT – 281, SURF – 1006, aprašas HOG ir detektorius SURF – 1041, aprašas SURF ir detektorius BRISK – 93, aprašas SURF ir detektorius FAST – 714.



26 pav. Gauti metodu rezultatai: bendri taškai, kai mastelis mažinamas, didinamas

SIFT, SURF, aprašas HOG ir detektorius SURF, aprašas SURF ir detektorius BRISK, aprašas SURF ir detektorius FAST, kai objektas mažinamas charakteringųjų taškų kiekis mažėja, panašiai kai objektas yra didinamas. Kuo daugiau mažėja objekto mastelis, tuo mažiau charakteringųjų taškų rasta.

Iš 26 paveikslo matosi, kad bendri taškai priklauso nuo mastelio pakeitimo sudaro simetrinį varpą, panašų į *Gauso* funkciją. *Gauso* funkcijos grafikas pasižymi savo simetriniu varpo pavidalu, kuris slopsta funkcijos argumento vėrtėms artėjant į teigiamą arba neigiamą begalybę.

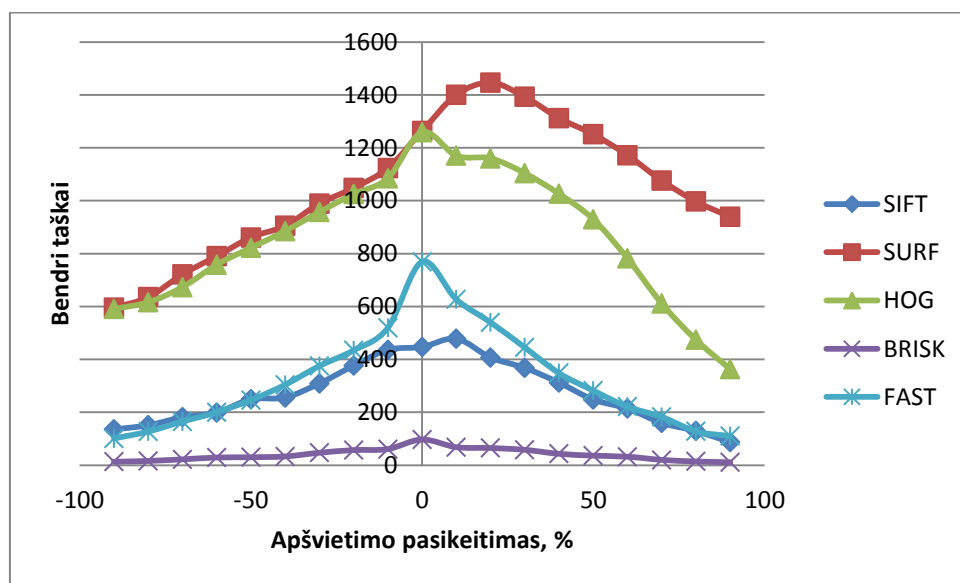
Iš gautų rezultatų, galima spręsti, jog daugiau suranda charakteringųjų taškų SURF, SURF su aprašu HOG metodai. Tiek tuo atveju, kai nuotraukoje esantis objektas sumažinamas ir tiek kai objektas padidintas. Analizuotų metodų bendrų taškų ir mastelio pakeitimo priklausomybė pasižymi simetriniu varpo pavidalu panašiu į *Gauso* funkcija.

4.3 Apšvietimo tyrimo rezultatai

Apšvietimo tyrimo tikslas ištirti kaip priklauso bendrų taškų radimas nuo apšvietimo pokyčių. Apšvietimas tiek didinamas tiek mažinamas. Pradedama nuo 0, tada kada apšvietimas toks koks nuotraukoje. Gauti rezultatai pateikti 27 paveiksle, x ašimi yra apšvietimo pasikeitimas procentais, y ašimi yra rasti bendri taškai.

Kaip matome iš 27 paveikslo, kad SURF metodas daugiausiai suranda charakteringų taškų. Pagal rastų charakteringųjų taškų kiekį rezultatai gauti toki (surikiuota nuo geriausio iki prasčiausio varianto):

1. SURF;
2. Aprašas HOG ir detektorius SURF (HOG);
3. Aprašas SURF ir detektorius FAST (FAST);
4. SIFT;
5. Aprašas SURF ir detektorius BRISK (BRISK);




27pav. Metodu rezultatai, bendri taškai, kai apšvietimas mažinamas, didinamas

Iš gautų rezultatu galima daryti išvada, kad analizuoti metodai priklauso nuo apšvietimo pasikeitimo. Mažiausiai priklauso SURF metodas.

4.4 Vaizdo pasukimo tyrimo rezultatai

Vaizdo pasukimo tyrimo tikslas ištirti objekto pasukimo įtaką bendrų taškų radimui. Charakteringųjų taškų radimui įtaka vaizdo pasikeitimo analizė pagal 23 paveiksle nurodytus nuotraukos pavyzdžius. Vaizdo pasukimas atliekamas kas 10 laipsnių, pradinis nuo 0, kada paveiksle esantis objektas nėra pasuktas. Gauti rezultatai pateikti 28 paveiksle, x ašimi yra vaizdo pasukimas procentais, y ašimi yra rasti bendri taškai.

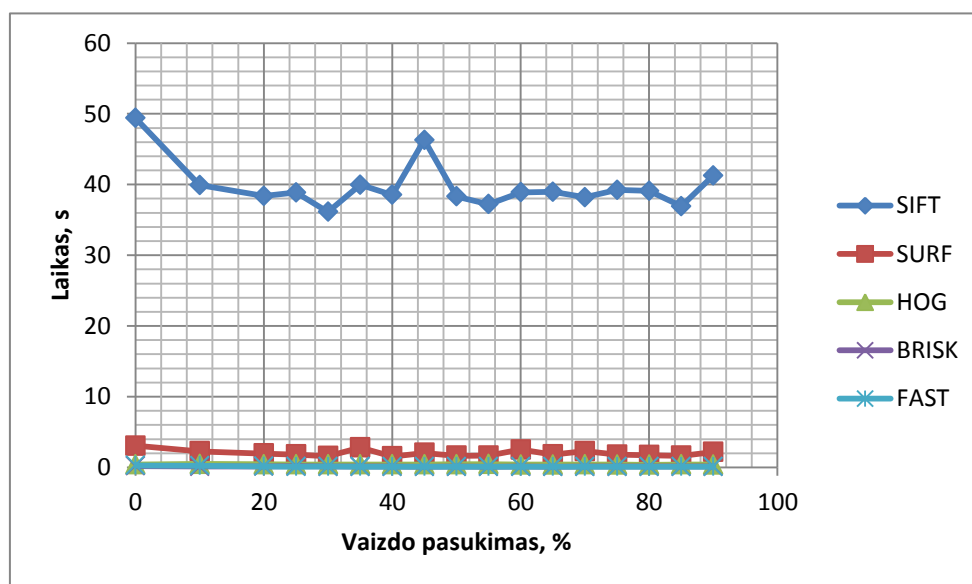


28 pav. Metodų rastų bendri taškai, kai yra objekto pasukimas

Kaip matosi iš 28 paveikslo galima teikti, kad visi metodas nėra atsparūs objekto pasukimo kampui. SURF labiau atsparus, nes jis surado daugiausiai charakteringų taškų. Su SIFT geriausi rezultatai gaunasi, kai pasukamas objektas iki 10 laipsnių, o SURF iki 30 laipsnių. Aprašas SURF ir detektorius BRISK (BRISK), aprašas HOG ir detektorius SURF (HOG), aprašas SURF ir detektorius FAST (FAST) metodai, kai vaizdo pasukimas padidėja randa kelis arba 0 charakteringų taškų.


4.5 Greitaveikos tyrimo rezultatai

Greitaveikos tyrimo tikslas – nustatyti nuo ko priklauso charakteringųjų taškų radimo laikas. Taškų radimo laikas skaičiuojamas nuo tada kada programa pradėjo darbą. Pateikti 3 tyrimų greitaveikos rezultatai (žr. 29 pav., 30 pav., 31 pav.). Pirmajame nurodyta laiko priklausomybė nuo vaizdo pasukimo, antrajame – nuo apšvietimo, trečiajame – nuo mastelio pasikeitimo.



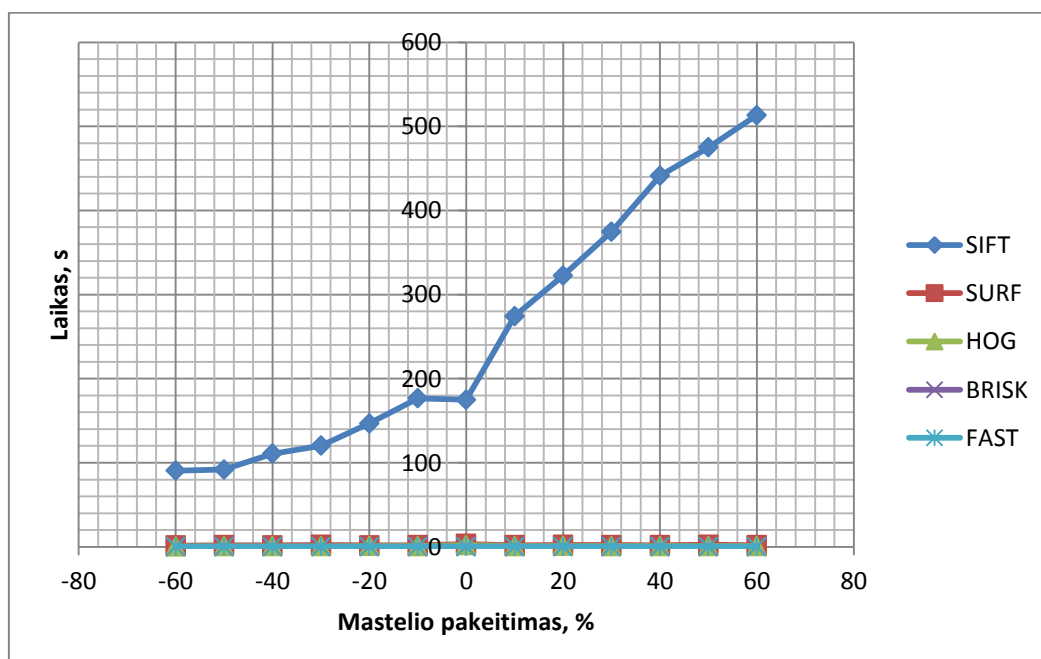
29 pav. Laiko priklausomybė nuo vaizdo pasukimo

Kaip matosi iš 29 paveiksle, SIFT metodas ilgiausiai užtrunka apdoroti nuotraukas. SURF vaizdo pasukimo tyrime visada išlaiko vidurkį apie 2 sekundes, o SIFT svyruoja nuo 45 sekundžių iki 50 sekundžių. Aprašas HOG ir detektorius SURF, aprašas SURF ir detektorius BRISK, aprašas SURF ir detektorius FAST užtrunka porą sekundžių, tačiau reikia atsižvelgti ir į mažą rastų charakteringųjų taškų kiekį.



30 pav. Laiko priklausomybe nuo apšvietimo pasikeitimo

SURF apšvietimo pasikeitimas tyrime visada išlaiko vidurkį apie 2 sekundes, o SIFT svyruoja nuo 130 sekundžių iki 180 sekundžių. Aprašas HOG ir detektorius SURF (HOG), aprašas SURF ir detektorius BRISK (BRISK), Aprašas SURF ir detektorius FAST (FAST) užtrunka porą sekundžių, tačiau reikia atsižvelgti ir į mažą rastų charakteringųjų taškų kiekį.



31 pav. Laiko priklausomybe nuo mastelio pasikeitimo

SURF mastelio pasikeitimas tyrime visada išlaiko vidurkį apie 2 sekundes, o SIFT proporcingai laikas kyla nuo mastelio didėjimo. Jeigu mastelis 50 % sumažintas tai ir charakteringųjų taškų radimas vyksta greičiau, 90 sekundžių. Jeigu mastelis padidintas 50 %, tai charakteringųjų taškų radimas trunka 510 sekundžių. Aprašas HOG ir detektorius SURF (HOG), aprašas SURF ir detektorius BRISK (BRISK), aprašas SURF ir detektorius FAST (FAST) užtrunka porą sekundžių, tačiau reikia atsižvelgti ir į mažą rastų charakteringųjų taškų kiekį. Iš to galima daryti išvadas, kad metodo apdorojimo laikas priklauso nuo mastelio pasikeitimo rastų taškų kiekio.

Iš to seka, kad metodo apdorojimo laikas priklauso nuo mastelio pasikeitimo, apšvietimo pasikeitimo, vaizdo pasukimo bei rastų charakteringųjų taškų kiekio.

4.6 Skirtingų perspektyvų tyrimo rezultatai

Šis tyrimas skirtas išnagrinėti skirtingų perspektyvų poveikį, kai stebėtojas (žmogus) pakeičia stebėjimo kampą į vietovę, pasisuka tam tikru kampu. Pasisukimo kampai į atpažįstamą vietovę: 10, 20, 30 ir 40 laipsnių. Tiriamoji nuotrauka užfiksuota esant 52 metrų atstumui.

2 Lentelė SIFT metodo rezultatai


Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Pasisukimo kampas, laipsniais
1.	8380	3088	59	10
2.	8380	12442	72	20
3.	8380	12826	64	30
4.	8380	14217	56	40

Kaip matosi iš 2 lentelės SIFT metodas pagal atitinkamus pasukimo kampus randa atitinkamai bendrų taškų, ku didesnis pasukimo kampas tuo mažiau randa bendrų taškų. Pirmuoju tyrimo atveju bendrų taškų kiekis mažas, nes lyginamosios nuotraukos charakteringųjų taškų kiekis 4 kartus mažesnis negu kituose tyrimuose.

3 Lentelė SURF metodo rezultatai

Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Pasisukimo kampas, laipsniais
1.	15544	11910	170	10
2.	15544	21101	196	20
3.	15544	20207	237	30
4.	15544	18848	205	40

Kaip matosi iš 3 lentelės SURF metodas surado daugiau tiek tiriamosios tiek lyginamosios nuotraukos charakteringųjų taškų bei žinoma bendrų taškų, negu SIFT metodo (žr. 2 ir 3 lentelę) Atitinkamai bendrų taškų skaičius priklauso nuo pasisukimo kampo.



32 pav. SURF metodo bendrieji taškai

Taškų atitikimas pateiktas 32 paveiksle. Iš jo matosi, kad ne tik pastato dalys buvo pažymėtos kaip charakteringi taškai, bet ir tam tikra dalis žolės, medžio. Vienas iš pasiūlymų, kad išvengti nereikalingos informacijos, tai iš nuotraukos išimti ją. Pašalinus nereikalingą informaciją gali kilti problema, kai nuotrauka padaryta iš kitos perspektyvos. Su nereikalinga informacija, gali būti pašalinta ir būtina informacija vietovės atpažinimui iš skirtingų perspektyvų.

4 Lentelė Aprašo HOG ir detektoriaus SURF rezultatai

Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Pasisukimo kampas, laipsniais
1.	15544	11910	161	10
2.	15544	21101	183	20
3.	15544	20207	175	30
4.	15544	18848	224	40

Kaip matosi iš 4 lentelės aprašą HOG ir detektorių SURF palyginus su SURF metodo rado tiek pat tiriamosios ir lyginamosios nuotraukos charakteringųjų taškų (žr. 4 lentelę), tačiau rado mažiau bendrų taškų. Atitinkamai bendri taškai priklauso nuo pasisukimo kampo.

5 Lentelė Aprašo SURF ir detektoriaus BRISK rezultatai

Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Pasisukimo kampas, laipsniais
1.	2185	788	1	10
2.	2185	2280	0	20
3.	2185	2537	0	30
4.	2185	2395	0	40

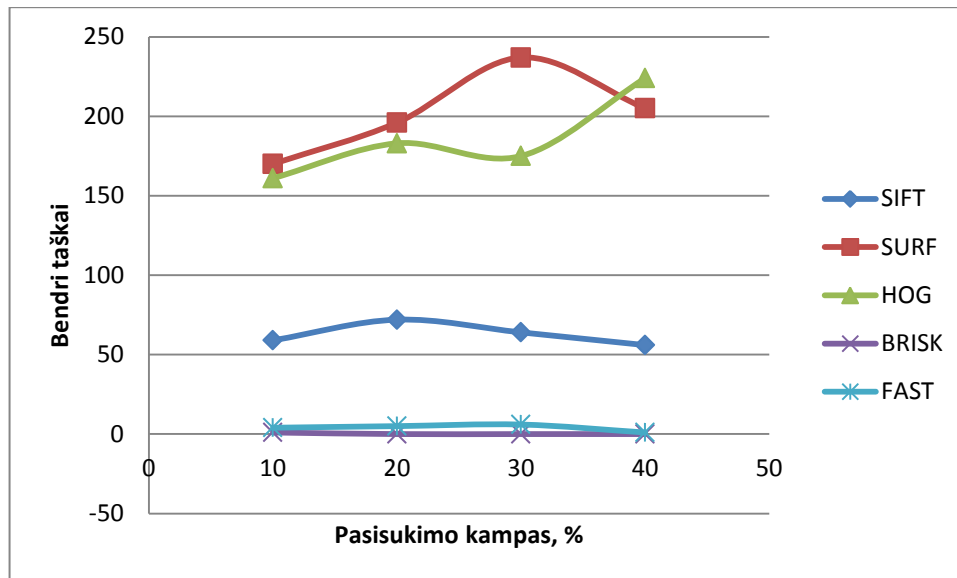
Kaip matosi iš 5 lentelės aprašo SURF ir detektoriaus BRISK bendrų taškų kiekis vienas arba nulis. Iš to galima spręsti, kad aprašas SURF ir detektorius BRISK nėra tinkamas vietovės atpažinimui su atitinkamais kampų pasukimais.

6 Lentelė Aprašo SURF ir detektoriaus FAST rezultatai

Nr.	Tiriamosios nuotraukos	Lyginamosios nuotraukos	Bendri taškai	Pasisukimo kampas,
				kampas,

	charakteringieji taškai	charakteringieji taškai		laipsniais
1.	6343	1856	4	10
2.	6343	5131	5	20
3.	6343	6520	6	30
4.	6343	5366	1	40

Kaip matosi iš 6 lentelės aprašo SURF ir detektoriaus FAST bendrų taškų kiekis labai mažas. Iš to galima spręsti, kad netinka naudoti vietovės atpažinimui.



33 pav. Tiriamų metodų rezultatai

Atlikus skirtingų perspektyvų rezultata, galima teigti, kad aprašas SURF ir detektorius BRISK ir aprašas SURF ir detektorius FAST nėra tinkami naudoti vietovės atpažinime. Netinkami, nes randa mažai charakteringųjų taškų, pagal kuriuos būtų galima identifikuoti vietovę. SURF ir aprašas HOG su detektoriumi SURF tinkami naudoti vietovės atpažinime.

4.7 Skirtingų atstumų tyrimo rezultatai

Šis tyrimas skirtas išnagrinėti skirtingų atstumų įtaką, tai kai stebėtojas (žmogus) yra arčiau arba toliau nuo objekto esančioje vietovėje. Kai stebėtojas yra arčiau, tam tikri dalykai nesimato palyginus su stebėtojo matomu vaizdu kai jis yra toliau nuo objekto esančio toje pačioje vietovėje.

Vietovės nuotraukos padarytos iš skirtingų atstumų: 16, 21, 26 ir 52 metrų. Tiriamasis objektas, šiuo atveju vietovė ir lyginamasis objektas – ta pati vietovė tik kitu atstumu padaryta nuotrauka, lyginamos tarpusavyje. Tiriamaoji nuotrauka užfiksuota esant 52 metrų atstumui iki objekto.

7 Lentelė SIFT rezultatai

Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Atstumas iki objekto
1.	8380	1652	63	16

2.	8380	2519	68	21
3.	8380	2773	44	26


Kaip matosi iš 7 lentelės, SIFT metodo atpažinimo tikslumas priklauso nuo atstumo. 26 metrų atstumo atpažinimą galėjo įtakoti nuotraukos kokybė, netinkamas apšvietimas, pasukimas ar lyginamosios nuotraukos charakteringųjų taškų kiekis.

8 Lentelė SURF rezultatai

Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Atstumas iki objekto
1.	15544	7165	168	16
2.	15544	12350	181	21
3.	15544	12746	196	26

Kaip matosi iš 8 lentelės, SURF metodo atpažinimo tikslumas priklauso nuo atstumo. Kuo daugiau nuotraukoje yra vietovės tuo daugiau randa bendrų taškų.

SURF metodas greičiau apdoroja nuotraukas (tyrimo atveju - 430 kartus), negu SIFT. Apdorojimo laiką įtakoja kompiuterio parametrai, nuotraukos dydis.



34 pav. SURF metodo bendrieji taškai

Charakteringų taškų atitikimas antrojo tyrimo rezultato pateiktas 34 paveiksle. Pirmoji nuotrauka yra 52 m atstumu, o antroji 21 m atstumu. Pateikiama tik ryškiausi 50 charakteringų taškų. Kaip matosi iš šio paveikslo charakteringus taškus pažymėjo ne tik pastatą, bet ir žolė, medį. Kai kurie žolės taškai pažymėti, kad sutampa su pastato pamato ar lango dalimis. Iš to galima daryti išvadą, kad šis metodas nėra tikslus.

9 Lentelė Aprašo HOG ir detektoriaus SURF rezultatai

Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Atstumas iki objekto
1.	15544	7165	149	16
2.	15544	12350	170	21
3.	15544	12746	189	26

Kaip matosi iš 9 lentelės aprašo HOG ir detektoriaus SURF taip pat priklauso nuo atstumo. Artėjant atstumui iki pradinio, didėja rasti bendri taškai.

10 Lentelė Aprašo SURF ir detektoriaus BRISK rezultatai


Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Atstumas iki objekto
1.	2185	255	2	16
2.	2185	701	1	21
3.	2185	737	0	26

Kaip matosi iš 10 lentelės aprašas SURF ir detektorius BRISK taip pat priklauso nuo atstumo. Šiuo variantu kuo didesnis atstumas tuo mažesnis taškų kiekis. Iš to galima teigti, kad aprašas SURF ir detektorius BRISK nėra tinkami naudoti, kai nuotraukose vietovės atstumai yra skirtingi.

11 Lentelė Aprašo SURF ir detektoriaus FAST rezultatai

Nr.	Tiriamosios nuotraukos charakteringieji taškai	Lyginamosios nuotraukos charakteringieji taškai	Bendri taškai	Atstumas iki objekto
1.	6343	346	2	16
2.	6343	1481	3	21
3.	6343	1777	2	26

Kaip matosi iš 11 lentelės aprašo SURF ir detektoriaus FAST metodo bendrų taškų kiekis mažas. Pirmojo ir antrojo tyrimo bendri taškų kiekis toks pats, nes galėjo tai įtakoti lyginamosios nuotraukos charakteringųjų taškų kiekis, apšvietimas, pasisukimo kampas. Iš to galima spręsti, kad aprašas SURF ir detektorius FAST nėra tinkami naudoti, tada kai nuotraukose vietovės atstumai yra skirtingi.



35 pav. Tiriamų metodų rezultatai

Atlikus skirtingų atstumų tyrimą, galima teigti, kad charakteringųjų taškų metodas aprašas SURF ir detektorius BRISK (BRISK) ir aprašas SURF ir detektorius FAST (FAST) nėra tinkami naudoti vietovės atpažinime. Netinkami, nes randa mažai charakteringųjų taškų,

pagal kuriuos būtų galima identifikuoti vietovę. Geriausiai ir mažiausiai priklausanti nuo skirtingų atstumų SURF ir aprašas HOG su detektorius SURF (žr. 35 paveiksle).

4.8 Logaritminės tikimybės įvertinimas

Šis tyrimas skirtas nustatyti nuotraukų vietovės sutapimą/ nesutapimą. Tyrimų rezultatai pateikti žemiau.

12 Lentelė SIFT rezultatai

Tyrimo Nr.	Bendri taškai/ Iš viso taškų	LR	Interpretacija
1.	59/3088	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
2.	72/12442	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
3.	64/12826	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
4.	56/12217	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa

Kaip matosi iš 12 lentelės, SIFT metodo rastiems taškams apskaičiuota LR sutampa ir yra lygi 0,01, todėl pakankamai tikėtina, kad lyginami objektai nesutampa.

13 Lentelė SURF rezultatai

Tyrimo Nr.	Bendri taškai/ Iš viso taškų	LR	Interpretacija
1.	170/11910	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
2.	196/21101	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
3.	237/20207	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
4.	205/18848	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa

13-oje lentelėje pateikta SURF metodo tikėtinumo santykio (LR) metrika. Rastiems bendriems taškams jos sutampa ir lygios 0,01 – pakankamai tikėtina, kad lyginami objektai nesutampa.

14 Lentelė Aprašo HOG ir detektoriaus SURF rezultatai

Tyrimo Nr.	Bendri taškai / Iš viso taškų	LR	Interpretacija
1.	161/11910	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
2.	183/15544	0.01	Pakankamai tikėtina, kad lyginami

			objektai nesutampa
3.	175/20207	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa
4.	224/18848	0.01	Pakankamai tikėtina, kad lyginami objektai nesutampa

14-oje lentelėje pateikta aprašo HOG ir detektoriaus SURF metodo tikėtinumo santykio (LR) metrika. Rastiems bendriems taškams jos sutampa ir lygios 0,01 – pakankamai tikėtina, kad lyginami objektai nesutampa.

15 Lentelė Aprašo SURF ir detektoriaus BRISK rezultatai

Tyrimo Nr.	Bendri taškai / Iš viso taškų	LR	Interpretacija
1.	1/788	∞	Labai tikėtina, kad lyginami objektai nesutampa
2.	0/2280	∞	Labai tikėtina, kad lyginami objektai nesutampa
3.	0/2537	∞	Labai tikėtina, kad lyginami objektai nesutampa
4.	1/2395	∞	Labai tikėtina, kad lyginami objektai nesutampa

15-oje lentelėje aprašo SURF ir detektoriaus BRISK metodo tikėtinumo santykio (LR) metrika. Rastiems bendriems taškams jos sutampa ir lygios ∞ – labai tikėtina, kad lyginami objektai nesutampa.

16 Lentelė Aprašo SURF ir detektoriaus FAST rezultatai

Tyrimo Nr.	Bendri taškai / Iš viso taškų	LR	Interpretacija
1.	4/1856	0.001	Labai tikėtina, kad lyginami objektai nesutampa
2.	5/5131	0.001	Labai tikėtina, kad lyginami objektai nesutampa
3.	6/6520	0.001	Labai tikėtina, kad lyginami objektai nesutampa
4.	1/5366	0.001	Labai tikėtina, kad lyginami objektai nesutampa

16-oje lentelėje pateikta aprašo SURF ir detektoriaus FAST metodo tikėtinumo santykio (LR) metrika. Rastiems bendriems taškams jos sutampa ir lygios 0,001 – labai tikėtina, kad lyginami objektai nesutampa.

Tai reiškia, kad taikyti LR vietovės atpažinimui pagal charakteringuosius taškus nėra tikslinga, nes charakteringų taškų randa daug, o bendrų taškų žymiai mažiau. Visų metodų gauti rezultatai yra 0,01 arba mažesni, tai reiškia kad lyginami objektai pakankamai arba labai tikėtina, kad nesutampa. Tad dėl mažo bendrų taškų skaičiaus gaunasi mažas vietovės tikėtinumo sutapimas.

4.9 Vietovės atpažinimo tyrimas

Vietovės atpažinimo tyrimo tikslas nustatyti kuris iš tiriamų metodų tinkamas naudoti realiose sistemose, kai vietovę reikia atpažinti iš nuotraukų rinkinio. Nuotraukų

rinkinys sudarytas iš dviejų tipų: a) tiriamosios vietovės nuotraukų, b) nuotraukų iš 3 saitynų [33, 34, 35]. Antruoju variantu nuotraukos įvairios tematikos, nuo vietovės iki gamtos vaizdų. Bendras nuotraukų kiekis 929. Kiekybinis nuotraukos tikėtinumas paimtas iš 3.8 skyriuje apskaičiuoto $LR = 0.01$.

Atliktos trys iteracijos, gautų rezultatų vidurkis pateiktas 19 lentelėje.

17 Lentelė Vietovės atpažinimo rezultatų vidurkis

	SIFT	SURF	BRISK	FAST	HOG
Atitikmenys	-	121	1	1	-
Laikas	-	7436,6	286,5	572,4	-

Kaip matosi iš 17 lentelės, daugiausiai nuotraukos atitikmenų rado SURF metodas. Tarp testinių duomenų buvo įtraukta 17 tiriamojo pastato nuotraukų. SURF su aprašu BRISK ir aprašas SURF su detektoriumi FAST rado tik vieną atitikmenį. Rastas atitikmuo sutapo su lyginamąja nuotrauka. SIFT ir aprašas HOG su detektoriumi SURF nėra rezultatų, dėl to kad kompiuteris per 24h neapdorojo duomenų, pagal užduoties vykdymo greičio ribojimus, buvo nutrauktas procesas. Vertinant laiko atžvilgiu, greičiausiai rado atitikmenį aprašas SURF su detektoriumi BRISK. Iš to galima daryti išvadas, SURF randa daugiau atitikmenų, kurie nėra tos vietovės, tačiau užtrunka 25,9 karto ilgiau negu aprašas SURF su detektoriumi BRISK.

Rezultatai ir išvados

Rezultatai:

- Atlikta vaizdo atpažinimo sistemų analizė.
- Atlikta charakteringųjų taškų metodų analizė.
- Suprojektuotas ir realizuota testavimo sistema *Matlab 2016a* programiniame pakete.
- Atlikta skirtingų perspektyvų ir atstumo iki vietovės poveikį tyrimai.
- Atlikta vietovės atpažinimas pagal charakteringus taškus tyrimas.
- Atlikta vietovės kiekybinio įvertinimo tyrimas.
- Atlikta greitaveikos tyrimas.
- Parašyta straipsnis „Vietovės atpažinimo algoritmų pagal charakteringuosius taškus tyrimas“ konferencijai IVUS 2017 (žr. Prieduose).

Išvados:

1. Atlikus vaizdo atpažinimo sistemų analizę, nustatyta, kad, vaizdo atpažinimas pritaikytas ir naudojamas įvairiose srityse, pvz.: saugos sistemose, automatinių panoraminių nuotraukų sujungime, mobiliuose robotuose, veidų atpažinime, apsaugos sistemose.
2. Atlikus charakteringųjų taškų metodų analizę, nustatyta, kad metodai SIFT, SURF, BRISK, FAST, HOG tinkami atpažinti 3D objektus ir yra tinkami 3D objektų atpažinimo užduotims spręsti.
3. Atlikus testavimo sistemos projektavimą, nustatyta, kad ši sistema tinkama realizuoti *Matlab 2016a* programiniame pakete.
4. Atlikus skirtingų perspektyvų ir atstumo iki vietovės poveikį nustatyta, kad:
 - Didžiausias poveikis skirtingų perspektyvų ir atstumui iki vietovės turi aprašas SURF su detektoriumi BRISK ir aprašas SURF su detektoriumi FAST. Šie metodai pasikeitus atstumui, randa nuo 0 iki 2 charakteringųjų taškų.
 - Mažesnę poveikį skirtingų perspektyvų ir atstumui iki vietovės turi SURF ir aprašas HOG su detektoriumi SURF. Šie metodai randa nuo 149 iki 196 charakteringųjų taškų.
5. Atlikus vietovės atpažinimą pagal charakteringus taškus tyrimą, nustatyta, kad:
 - Apdorojimo sparta yra žema šių metodų: SIFT ir aprašo HOG su detektoriumi SURF. Šie metodai negali apdoroti 929 kiekio nuotraukų per 24 valandas.
 - Vietovės atpažinimui tinkama naudoti SURF metodą, tačiau jis nėra tikslus. Šis metodas randa daugiau atitikmenų. Rasta 121 atitikmuo iš 929 nuotraukų. Iš jų tik 17 būtent tos vietovės.
 - Vietovės atpažinimui nėra tinkama naudoti aprašą SURF su detektoriumi BRISK ir aprašą SURF su detektoriumi FAST. Šie metodai atpažįsta tik identišką nuotrauką.
6. Atlikus vietovės kiekybinio įvertinimo tyrimą, nustatyta, kad logaritminės tikimybės taikymas nėra tinkamas, nes charakteringų taškų randa mažai, todėl vietovės atitikimo tikimybė būna žema $LR \leq 0.01$ (Labai tikėtina, kad lyginamosios vietovės nesutampa).
7. Atlikus greitaveikos tyrimą nustatyti, kad tiriamų metodų greitaveika priklauso nuo šių faktorių: apšvietimo, objektų pasisukimo, objektų mastelio pasikeitimo skirtumo. Kuo šių faktorių skirtumas mažesnis nuo pradinės nuotraukos, tuo greičiau įvykdoma užduotis. SIFT užduotį įvykdo ~ 430 kartų lėčiau negu kiti tirti metodai.

Literatūra

1. Matthew Brown and David G. Lowe, *International Conference on Computer Vision (ICCV 2003)*, Nice, France (October 2003), pp. 1218-25.
2. Leonard, J.J. ; Dept. of Eng. Sci., Oxford Univ., UK ; Durrant-Whyte, H.F. Robotics and Automation, IEEE Transactions on (Volume:7 , Issue: 3) ISSN :1042-296X, 376 – 382
3. R. Basri and E. Rivlin. Localization and homing using combinations of model views. *Artificial Intelligence*, 78(1-2), 1995
4. Ravima Mithe, Supriya Indalkar, Nilam Divekar. Optical character recognition. *International Journal of Recent Technology and Engineering (IJRTE)* ISSN: 2277-3878, Volume-2, Issue-1, March 2013
5. William D.Barber, Thomas M. Cipolla, Joseph L. Munday, Optical recognition. US Patent 4,339,745, 1982
6. R. Smith. “An overview of the Tesseract OCR Engine.” *Proc 9th Int. Conf. on Document Analysis and Recognition*, IEEE, Curitiba, Brazil, Sep 2007, pp 629-633.
7. Petter M., Fragoso V., Turk M., Baur Ch., 2011 Automatic text detection for mobile augmented reality translation. *IEEE International Conference on Computer Vision Workshop (ICCV Workshop)* p. 48-55.
8. Lai K, Bo L, Ren X, Fox D. RGB-D Object Recognition: Features, Algorithms, and a Large Scale Benchmark. *Consumer Depth Cameras for Computer Vision: Research Topics and Applications*, 2013, pp 167-192.
9. Choi M.B. Local Threshold and Boolean Function Based Edge Detection. 3, s.l. : IEEE Transactions on Consumer Electronics, 1999 m..
10. Anto N. Sobel Edge Detection Algorithm. s.l. : B.Tech Seminar, 2010.
11. Canny J. A computational approach to edge detection. 1986
12. Nadernejad E., Sharifzadeh S., Hassanpour H. Edge Detection Techniques: Evaluations and Comparisons.. s.l. : Applied Mathematical Sciences, 2008 m., T. 2.
13. Yuancheng L., Ramani D. Canny Edge Detection on NVIDIA CUDA. s.l. : IEEE, 2008.
14. Azernikov S. Sweeping solids on manifolds. s.l. : Symposium on Solid and Physical Modeling, 2008. p. 249–255. 46
15. Mai F., Hung Y., Zhong H. and Sze W. A hierarchical approach for fast and robust ellipse extraction. 8, s.l. : Pattern Recognition, 2008 m., T. 41, p. 2512–2524.
16. King, M. Amadasun R.A. Low level segmentation of multispectral images via agglomerative clustering of uniform neighbours. s.l. : Pattern Recognition, 1988 m., T. 21.
17. Pavlidis, S.L. Horowitz T. Picture segmentation by directed split and merge procedure. Copenhagen : *Proc. 2nd Int. Joint Conf. Pattern Recognition*, 1974.
18. Ohlander R., Price K. and Reddy D.R. Picture segmentation using a recursive region splitting method.. s.l. : *Comput. Graphics Image Process.*, 1978 m., T. 8, p. 313-333
19. Gonzalez J.T. *Pattern Recognition Principles*. Massachusetts : Addison-Wesley, 1974. T. 56.
20. Bay Herbert, Tuytelaars Tinne, Luc Van Gool. SURF: Speeded Up Robust Features. *Computer Vision – ECCV2006: Springer Berlin Heidelberg*, ISSN:0302-9743, Volume 3951, p. 404-417
21. Mikolajczyk, K., Schmid, C.: Indexing based on scale invariant interest points. In: *ICCV. Volume 1*. (2001), p.525 – 531
22. M. Brown and D. Lowe. Invariant features from interest point groups. In *BMVC*, 2002.
23. Rublee, Ethan; Rabaud, Vincent; Konolige, Kurt; Bradski, Gary. ORB: an efficient alternative to SIFT or SURF. Willow Garage, Menlo Park, California, 2011.
24. RANSAC . [Žiūrėta 2016-06-19]. Prieiga per internetą:

- <http://se.mathworks.com/discovery/ransac.html>
25. Tarpautinių žodžių žodynas. Vyriausioji enciklopedijų redakcija, 1985, [žiūrėta 2017-01-06] prieiga per internetą: <http://www.zodziai.lt/>
 26. R. Kam-Art, T. Raicharoen, and V. Khera. Face recognition using feature extraction based on descriptive statistics of a face image. In IEEE Machine Learning and Cybernetics, International Conference on, volume 1, pages 193–197, 2009.
 27. Marr, D. Marr's theory: From primal sketch to 3D models. [žiūrėta 2017-03-15] URL: http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/GOMES1/marr.html
 28. E. Rosten and T. Drummond, „Machine learning for high speed corner detection“ in 9th, European Conference on Computer Vision, vol. 1, 2006, pp. 430-433
 29. FAST, [žiūrėta 2017-04-04] prieiga per internetą: <https://se.mathworks.com/help/vision/ref/detectfastfeatures.html>
 30. Leutenegger, S., Chli, M., & Siegwart, R. Y. (2011, November). BRISK: Binary robust invariant scalable keypoints. In Computer Vision (ICCV), 2011 IEEE International Conference on (pp. 2548-2555). IEEE.]
 31. HOG [žiūrėta 2017-04-09] prieiga per internetą: <https://software.intel.com/en-us/node/529070>
 32. RANSAN [žiūrėta 2017-04-22] prieiga per internetą: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.139.2808&rep=rep1&type=pdf>
 33. HD nuotraukos [žiūrėta 2017-05-01] prieiga per internetą: <https://snippets.khromov.se/stock-photo-archive-zip-77-images>
 34. HD nuotraukos [žiūrėta 2017-05-01] prieiga per internetą: <http://hdqwalls.com/2048x1152-resolution-wallpapers>
 35. HD nuotraukos [žiūrėta 2017-05-01] prieiga per internetą: http://wallpaperswide.com/black_and_white-desktop-wallpapers
 36. Michael Calonder, Vincent Lepetit, Christoph Strecha, and Pascal Fua, BRIEF: Binary Robust Independent Elementary Features [žiūrėta 2017-05-01], prieiga per internetą: https://infoscience.epfl.ch/record/149242/files/top_1.pdf
 37. LOWE D. G., Distinctive image features from scale invariant keypoints, Int. J. Comput. Vision, vol. 60, no. 2, pp. 91–110, November 2004

Priedai

Parašyti straipsniai

Vietovės atpažinimo algoritmų pagal charakteringuosius taškus tyrimas

Eglė Vainauskaitė
Informatikos fakultetas
Kauno technologijos universitetas
Kaunas, Lietuva
El.paštas: egle.vainauskaite@ktu.edu

Šiame straipsnyje nagrinėjamas vietovės atpažinimas taikant algoritmus paremtus charakteringaisiais taškais. Aptariamos atpažinimo metu kylančios problemos ir sprendimo būdai. Pasiūloma naudoti SIFT ir SURF algoritmus vietovės paveikslų charakteringų taškų aptikimui. Pateikiami eksperimentiniai tyrimai, parodantys, kad sudėtinga vykdyti vietovės atpažinimą remiantis charakteringais paveikslų taškais.

Reikšminiai žodžiai: vietovės atpažinimas; charakteringieji taškai;

I. Įvadas

Žmogui užtenka dalinės informacijos, iš kurios gali nuspręsti koks tai objektas. Pavyzdžiui, vandenyno horizonte esantis stiebas su buria interpretuojamas kaip jachta. Technikos srityje net pats paprasčiausias automatizuotas objekto atpažinimas reikalauja daug daugiau informacijos, užtrunka daug ilgiau negu žmogaus galvoje vykstantys atpažinimo procesai.

Automatizuotas sėkmingas objekto atpažinimas priklauso nuo aplinkos, tame kadre esančių kitų objektų, apšvietimo. Tokiose sistemose atsižvelgiama į vaizdo pastovumą, paveikslų modelio dimensijų kiekį, objektų kiekį objektų duomenų bazėje [1]. Susiduriama su tikslumo ir našumo problemomis. Vis dar atliekami tyrimai siekiant sukurti našesnius ir tikslesnius algoritmus, kurie be žmogaus įsikišimo galėtų identifikuoti atitinkamą objektą ar vietovę.

Tobulėjant technologijoms ieškoma įvairių būdų kaip būtų galima pagerinti vietovės atpažinimą pasitelkiant išmaniuosius telefonus ir derinant įvairiausias algoritmus.

II. Algoritmai

Vietovės atpažinimui galima taikyti įvairius algoritmus: įvertinančius formą, dydį, spalvą, charakteringuosius taškus. Šiame skyriuje pateikti charakteringųjų taškų algoritmai SURF ir SIFT.

A. SIFT

SIFT – nuo mastelio nepriklausomas charakteringų taškų išskyrimo metodas. Jį sudaro charakteringų taškų detektorius ir aprašas [2]. Aprašas yra tam tikros savybės ar bruožo apibūdinimas ir jis apibrėžia savybių sintaksinę ir semantiką. Detektorius suranda charakteringuosius taškus. Pagrindiniai algoritmo etapai:

- Mastelio-erdvės ekstremumų paieška. Šiame etape ieškoma charakteringų taškų, pagal *Gauso* funkcijos reikšmės. Suradus charakteringus taškus, atliekamas netinkamų taškų filtravimas pagal kontrasto ir objektų kraštų slenksčius.
- Charakteringų taškų lokalizacija. Šiame žingsnyje nustatomos atrinktų taškų koordinatės. Taikant antros eilės *Teilor* daugianarį ir atliekant *DoG* funkcijos aproksimavimą[2].
- Orientacijos priskyrimas charakteringiems taškams Priskyrimas remiamasi lokaliomis vaizdo savybėmis. Jį sudaro 3 žingsniai: sukuriama histograma lokalsios vietos gradiento kryptims skaičiuoti pasirinktu masteliu, parenkama kanoninė orientacija išlygintos histogramos viršuje, kiekvienas charakteringas taškas aprašomas dvimatėmis koordinatėmis, dydžiu ir orientacija.

- Sudaromas tam tikros savybės ar bruožo apibūdinimas, kuris nustato savybių sintaksę ir semantiką. Kiekvienam charakteringam taškui nustatoma lokalizacija, dydis, orientacija. Tai apibrėžiama lokaliomis dvimatėmis koordinatėmis, kurios apima apibūdintas sritis. Apskaičiuojamas paveikslų gradientas ir orientacija kiekvienam paveikslų taškui esančiam šalia charakteringo taško. Sudaromos aštuonių krypčių orientacijų histogramos.

Šio metodai privalumai: atsparus vaizdo mastelio pasikeitimui, nepriklauso nuo vaizdo pasukimo, turi mažai įtakos apšvietimo pasikeitimams, nepriklauso nuo stebėjimo taško kampo.

B. SURFT

SURF – greitas požymio išskyrimas. Šio metodas gali įvertinti tokios transformacijos: nuotraukos pasukimą, dydį, apšvietimo pakeitimą, mažą žiūrėjimo taško pasikeitimą. Bendras procesas aprašomas šiais etapais:

- Greitas būdingojo taško suradimas. Taikomi kvadrato tipo sąsukos filtrai [3].
- Orientacijos nustatymas. Reikalingas tam, kad rastų charakteringus taškus, jeigu nuotraukoje esantis objektas yra paverstas ar pati nuotrauka yra pasukta kitu kampu. Orientacijos nustatymui taikomas *Harr wavelet*.
- Savybės ar bruožo atitikimas. Dažniausiai charakteringieji taškai randami pagal bloko struktūrą. Taikant *Laplaso* metodą [4] išskiria šviesiuosius blokus tamsiame fone. Ši funkcija nereikalauja papildomų resursų, nes atliekama charakteringojo taško nustatymo metu.

C. Sistemos įgyvendinimas

Sistemos įgyvendinimui pasirinkt aptarti SIFT ir SURFT algoritmai. Šie algoritmai realizuoti naudojam *MatLab* paketą. Vietovės atpažinimo sistemoje tiriamasis ir lyginamasis paveikslo turi bendrus bruožus. Taikant logaritminę tikimybę galima kiekybiškai įvardinti kiek šios vietovės yra panašios. Kuo ši tikimybė didesnė tuo labiau tikėtina, kad tiriamosios ir lyginamosios nuotraukose esančios vietovės sutampa.

Tikėtumas – tam tikro modelio tikimybė, kai yra žinomi matavimo rezultatai. Matavimo rezultatai – vietovės X ir Y ir jų charakteringieji taškai. Tikėtinumo santykio metrika apskaičiuojamas pagal formulę $LR = A/B$, kur A yra tikėtumas, kad lyginamos poros (X ir Y) sutampa, B yra tikėtumas, kad lyginamos poros (X ir Y) nesutampa. Jei $LR = LR(X, Y) < 1$, labiau tikėtina, kad lyginamos vietovės X ir Y yra skirtingi. Priešingai, jei $1 < LR < \infty$, labiau tikėtina, kad lyginamos vietovės sutampa.

Egzistuoja ir kitokių požymių palyginimo algoritmų. Pavyzdžiui, formuluojant apibendrinamuosius statistinius rezultatus, išskiriami du pagrindiniai kriterijai [5], kuriais galima remtis:

- Centrinės tendencijos matas: reikia pasirinkti statistiką kuri rodytų kiek panašūs yra skirtingi objektai;
- Statistinio kintamumo matas: pasirinkti kitą statistiką, kuri rodytų kaip labai jie skiriasi.

Šiuo atveju ir tiriamosios ir lyginamosios nuotraukose esanti vietovė sutampa, tad galima remtis dviem savybėmis – jų panašumu ir skirtumu.

III. Eksperimento tyrimai


Eksperimento tikslas iširti, kuris algoritmas pagal charakteringuosius taškus geriau ir našiau atpažįsta vietovę.

Pirmiausiai programai pateikiama dvi nuotraukos: tiriamoji ir lyginamoji. Programa yra realizuotas SIFT arba SURF charakteringųjų taškų algoritmas. Programa pateikia lyginamosios nuotraukos charakteringųjų taškų kiekį, bendrą taškų kiekį, apdorojimo laiką ir logaritminę tikimybę. Bendrieji taškai – tai atitinkamų taškų sutapimas nuotraukose.

Tyrimai atlikti naudojant asmeninę kompiuterį esant tokiems techniniams parametrus: Nvidia kompanijos vaizdo plokštė (*intel GT-650M*), procesorius *i5 2.30Hz*, atminties kiekis - 4 GB, 64 bitų operacinė sistema. Nuotraukos padarytos su išmaniuoju telefonu *Asus zenfone selfie*, kurio kamera yra 8 megapikselių raiškos. Tirtų nuotraukų raiška 2048 taškų pagal x plotį ir 1152 taškų pagal aukštį.


Atlikti du eksperimentai. Pirmasis skirtas išnagrinėti skirtingų perspektyvų poveikį, kai stebėtojas (žmogus) pakeičia stebėjimo kampą į vietovę, pasisuka tam tikru kampu. Nuotraukos pateiktos žemiau.

1 PAV. NUOTRAUKŲ PAVYZDŽIAI



Antrasis skirtas išnagrinėti skirtingų atstumų įtaką, tai kai stebėtojas (žmogus) yra arčiau arba toliau nuo objekto esančioje vietovėje. Kai stebėtojas yra arčiau, tam tikri dalykai nesimato palyginus su stebėtojo matomu vaizdu kai jis yra toliau nuo objekto esančio toje pačioje vietovėje. Nuotraukos pateiktos žemiau.


2 PAV. NUOTRAUKŲ PAVYZDŽIAI



A. Skirtingų perspektyvų tyrimo rezultatai

Atliktas tyrimas kai skiriasi pasisukimo į vietovę kampai: 10, 20, 30, 40. Tiriamoji nuotrauka užfiksuota esant 52 metrų atstumui.

3 PAV. METODŲ REZULTATAI



Kaip matosi iš 3 paveikslo SURF metodas surado daugiau bendrų taškų. Bendrų taškų skaičius priklauso nuo kampo.

1 LENTELĖ METODŲ REZULTATAI

Pasisukimo kampas laipsniais	SURF Laikas, s	SIFT laikas, s
10	15.8	6149.9
30	21.0	16790.0
40	18.3	13082.0

Kaip matosi iš 1 lentelės, nuotraukų apdorojimo laikas priklauso nuo pasisukimo kampo. Žemiau pateikta SIFT metodo ryškiausi charakteringieji taškai. Jie pažymėti geltona spalva.

4 PAV. SIFT METODO CHARAKTERINGIEJI TAŠKAI NUOTRAUKOSE



Žemiau pateikta SURF metodo ryškiausi charakteringieji taškai. Jie pažymėti žalia spalva.

5 PAV. SURF METODO CHARAKTERINGIEJI TAŠKAI NUOTRAUKOSE




B. Skirtingų atstumų tyrimo rezultatai

Atliktas tyrimas, kai vietovės nuotraukos padarytos iš skirtingų atstumų: 16 m, 21 m, 26 m ir 52 m. Tiriamasis objektas, šiuo atveju vietovė ir lyginamasis objektas – ta pati vietovė tik kitu atstumu padaryta nuotrauka, lyginamos tarpusavyje. Tiriamoji nuotrauka užfiksuota esant 52 metrų atstumui iki objekto.

Kaip matosi iš 6 paveikslėlio, SURF metodo atpažinimo tikslumas priklauso nuo atstumo. Kuo daugiau nuotraukoje yra vietovės tuo daugiau randa bendrų taškų.

6 PAV. METODŲ REZULTATAI



2 LENTELĖ METODO REZULTATAI

Atstumas iki objekto, m	SURF laikas, s	SIFT laikas, s
16	9.7	5115.9
21	15.5	5533.6
26	13.6	5548.1


SIFT metodo atpažinimo tikslumas priklauso nuo atstumo. 26 metrų atstumo atpažinimą galėjo įtakoti nuotraukos kokybė, netinkamas apšvietimas ar pasukimas. Žemiau pateikti SIFT metodo ryškiausi charakteringieji taškai.

7 PAV. SIFT METODO CHARAKTERINGIEJI TAŠKAI NUOTRAUKOSE



Žemiau pateikta SURF metodo ryškiausi charakteringieji taškai.

8 PAV. SURF METODO CHARAKTERINGIEJI TAŠKAI NUOTRAUKOSE



SURF metodas greičiau apdoroja nuotraukas (tyrimo atveju - 430 kartus, žr. 2 lentelę), negu SIFT. Apdorojimo laiką įtakoja kompiuterio parametrai, nuotraukos dydis.

C. Logaritminės tikimybės įvertinimas

Atlikus tyrimus kiekybiškai nustatyta kiek esančios vietovės sutampa pagal charakteringuosius taškus. 3-oje lentelėje pateikta SURF metodo tikėtinumo santykio (LR) metrika. Rastiems bendriems taškams jos sutampa ir lygios 0,01 – pakankamai tikėtina, kad lyginami objektai nesutampa.

3 LENTELĖ SURF METODO REZULTATAI

Bendri taškai	LR	Interpretacija
170	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa
196	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa
237	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa
205	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa

Kaip matosi iš 4 lentelės, SIFT metodo rastiems taškams apskaičiuota LR sutampa ir yra lygi 0,01, todėl pakankamai tikėtina, kad lyginami objektai nesutampa.

4 LENTELE SIFT METODO REZULTATAI

Bendri taškai	LR	Interpretacija
59	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa
72	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa
64	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa
56	0,01	Pakankamai tikėtina, kad lyginami objektai nesutampa

Tai reiškia, kad taikyti LR vietovės atpažinimui pagal charakteringuosius taškus nėra tikslinga, nes charakteringų taškų randa daug, o bendrų taškų žymiai mažiau. Dėl mažo bendrų taškų skaičiaus gaunasi mažas vietovės tikėtinumo sutapimas.

Išvados

Atlikus eksperimentinius tyrimus paaiškėjo, kad SURF ir SIFT priklauso nuo kampo ir atstumo iki objekto, tačiau SURF suranda daugiau charakteringų taškų. Pagal gautus rezultatus SURF metodo greičiau suranda charakteringuosius taškus (tirtu atveju – 430 kartų). Iš šių rezultatų galima teigti, kad SURF metodo yra efektyvesnis įvertinant charakteringų taškų suradimo greitį ir kiekį.

Logaritminės tikimybės rezultatai gauti vienodi dėl to, kad rasta mažai bendrų taškų. Atsižvelgus į eksperimento tyrimo rezultatus galime teikti, kad kiekybiškai vertinti vietovės atpažinimą pagal charakteringuosius taškus taikant logaritminę tikimybę nėra tikslina.

Literatūros sąrašas

- [1] Bay Herbert, Tuytelaars Tinne, Luc Van Gool. SURF: Speeded Up Robust Features. Computer Vision – ECCV2006: Springer Berlin Heidelber, ISSN:0302-9743, Volume 3951, p. 404-417
- [2] LOWE D. G., Distinctive image features from scaleinvariant keypoints, Int. J. Comput. Vision, vol. 60, no. 2, pp. 91–110, November 2004
- [3] M. Brown and D. Lowe. Invariant features from interest point groups. In BMVC, 2002.
- [4] David J.C. Mackay, Information theory, inference, and learning algorithms, Cambridge University press 2003, ISBN-13: 9780521642989, p. 341- 342.
- [5] R. Kam-Art, T. Raicharoen, and V. Khera. Face recognition using feature extraction based on descriptive statistics of a face image. In IEEE Machine Learning and Cybernetics, International Conference on, volume 1, pages 193–197, 2009.