

VILNIAUS UNIVERSITETAS

EDGARAS ARTEMČIUKAS

**HIBRIDINIS OBJEKTŲ SEKIMO METODAS
PAPILDYTOS REALYBĖS SISTEMOSE NAUDOJANT
KALMANO FILTRĄ**

Daktaro disertacija

Fiziniai mokslai, informatika (09P)

Vilnius, 2017

Disertacija rengta 2012–2016 metais Vilniaus universitete.

Mokslinis vadovas

prof. habil. dr. Leonidas Sakalauskas (Vilniaus universitetas, fiziniai mokslai,
informatika – 09P).

Santrauka

Daugelis papildytos realybės sprendimų veikia vaizdo požymių apdorojimo metodų pagrindu, norint atpažinti ir sekti objektus, kurių atžvilgiu atvaizduojamas kompiuteriu sugeneruotas virtualus turinys. Pagrindinė tokių metodų problema – vaizdų transformacijos, chaotiška aplinka, apšvietimo sąlygos, kur objektų atpažinimas ir sekimas realiu laiku tampa sudėtingu, o kartais neįmanomu procesu. Dėl aplinkoje esančių okliuzijų dažniausiai dingsta 3D virtualus turinys. Tai yra neigiamas aspektas naudotojui, o dėl įvardintų priežasčių ištirti šiuo metu plačiausiai naudojami požymių aptikimo ir aprašymo metodai. Šie metodai iš dalies leidžia išspręsti okliuzijų problemas ir tinkama padėti atvaizduoti virtualų turinį. Naudojant skirtingo tipo vaizdo transformacijų rinkinius, tyrime atliktas robastiškumo palyginimas pagal atkartojimo kriterijų. Įvertintas santykinis požymių išskyrimo iš vaizdo metodų sparta ir tinkamumas papildytos realybės sistemose. Atliktas tyrimas svarbus norint pasiūlyti pagerintą sekimo metodą papildytos realybės srityje, įtraukiant inercinių jutiklių informaciją.

Disertacijoje išanalizuotas kvaternionų taikymas mikroelektromechaninių jutiklių duomenims, norint įvertinti kameros orientaciją. Tyrime siekiama pašalinti pavienių jutiklių matavimų trūkumus ir pagerinti kameros orientacijos sekimo tikslumą, patikimumą bei virtualaus turinio atvaizdavimą papildytoje realybėje, kai kuriais atvejais nenaudojant požymių išskyrimo iš vaizdo metodų. Pasiūlytas sprendimas pritaikytas ne tik iš sekimo perspektyvos, bet taip pat sąveikos įrenginiui plėtoti. Pateikta detali Kalmano filtro analizė, praktinis taikymas jutiklių orientacijos duomenims, kurie išreikšti kvaternionais. Atlikta gradientinio nusileidimo metodo analizė bei taikymas.

Disertacijoje pasiūlytas hibridinis objekto sekimo metodas papildytos realybės sistemose naudojant Kalmano filtrą. Požymių išskyrimo iš vaizdo bei apdorojimo ir jutiklių sintezės metodai susietai ir susistemintai išanalizuoti, norint gauti patikimus sekamo objekto orientacijos ir pozicijos įverčius. Jutiklių masyvo duomenys naudojami pašalinti gautų pavienių jutiklių netikslus matavimus ir pagerinti kameros sekimo tikslumą bei patikimumą, nenaudojant arba iš dalies naudojant kompiuterinės regos metodus. Tyrime atlikti eksperimentai, kur orientacijos-pozicijos informacija imituota. Įvestos papildomos sąlygos optimalių orientacijos-pozicijos įverčių gavimui. Tyrimo

rezultatai palyginti naudojant tik požymių išskyrimo ir sutapdinimo bei tik jutiklių duomenų sujungimo metodų atvejais. Pademonstruotos papildančios pasiūlyto hibridinio sekimo metodo naudojant Kalmano filtrą savybės, užtikrinančios nenutrūkstamą sekimą net esant greitiems kameros padėties pokyčiams. Sprendimas adaptuotas mobiliems įrenginiams papildytos realybės daiktų interneto srityje.

Siekiant gauti tikslesnius kameros orientacijos ir pozicijos įverčius erdvėje bei praplėsti papildytos realybės naudojimo galimybes, darbe ištirtas požymių išskyrimo ir sutapdinimo bei inercinių jutiklių duomenų sujungimo metodų efektyvumas ir pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą. Toks sprendimas leidžia praplėsti papildytos realybės taikymo galimybes, pagerinti objekto orientacijos ir pozicijos sekimą ir užtikrinti patikimą virtualaus turinio atvaizdavimą net tuo atveju, kai tinkama informacija apie konkrečius vaizdo išskyrimo ir sutapdinimo požymius yra neprieinama.

Disertaciją sudaro įvadas, 3 skyriai, išvados, literatūros sąrašas, autoriaus publikacijų disertacijos tema sąrašas ir priedų sąrašas. Disertacijos apimtis: 107 puslapiai, 109 numeruotos formulės, 46 paveikslai ir 3 lentelės. Literatūros sąrašą sudaro 118 šaltinių.

Tyrimų rezultatai publikuoti 7 recenzuojamuose periodiniuose mokslo žurnaluose: 2 iš jų – tarptautinės ISI publikacijos, 2 – tarptautinių konferencijų medžiagoje, recenzuojamuose leidiniuose, 3 nacionalinės publikacijos. Rezultatai pristatyti tarptautinėse ir nacionalinėse konferencijose.

Abstract

Most augmented reality solutions are based on computer vision techniques to detect and track objects using a camera and display a computer generated virtual content. However, main issues of such techniques are image transformations, chaotic environment and illumination level. In general, such noisy environment causes complex or even impossible task for object tracking in real-time. In case of computer vision tracking techniques, occlusions causes 3D virtual content to disappear, therefore it has negative impact for the usability of applications. Because of the named reasons, most widely used modern feature detection and description techniques were analyzed that allows to solve partial occlusion problems and properly display virtual content. In this research robustness comparison according to repeatability criteria was accomplished using different type of image transformations sets by verifying specific image pairs. Computer vision techniques performance estimates in respect of speed was also analyzed to inspect suitability for the augmented reality. Research results are critical to propose improved tracking techniques in augmented reality field, also, by integrating inertial sensor information.

Quaternion application for microelectromechanical sensor data were also thoroughly analyzed to estimate camera orientation. With this solution it is aimed to eliminate separate sensor disadvantages and improve camera orientation tracking accuracy, reliability and virtual content representation in augmented reality, without using any computer vision technique. The proposed solution was adapted not only from tracking perspective, but also for the development of spherical form interaction device. Detailed Kalman filter analysis and practical application are also presented for orientation data acquired from real sensors, which are expressed in quaternions. Analysis of gradient descent method and practical application for sensor data fusion were also accomplished.

The proposed hybrid tracking technique for augmented reality was proposed, where orientation and position estimates from computer vision and sensor fusion techniques were analyzed in a systemic approach. Sensor array was used to eliminate separate sensor disadvantages and improve tracking without using or partially using computer vision data. Provided research experiments has predefined assumptions and orientation-position data were imitated in respect to computer vision and sensor fusion. Additional conditions were introduced to acquire optimal orientation-position

estimates and results were compared. Complementary properties of Kalman filter hybrid tracking technique were demonstrated. Solution was adapted for mobile devices in the field of augmented reality for internet of things.

To achieve more accurate and reliable camera orientation and position estimates in space and expand augmented reality application possibilities, in this dissertation computer vision and sensor fusion technique efficiency were analyzed and a new hybrid object tracking technique using Kalman Filter was proposed. For this purpose. The main use of presented technique is to expand augmented reality application fields, also improve object orientation and position tracking for reliable virtual content representation even in cases, when useful information from feature extraction and matching from image is not available.

Dissertation consists of introduction, 3 chapters, conclusion, literature list, author publication list related to this work and list of attachments. Dissertation amount: 107 pages, 109 formulas, 46 figures, 3 tables and list of literature that contains 118 references.

Research results were published in 7 periodical science journals: 2 international periodical science journals with impact factor, 2 international conference proceedings, 3 national level publications in periodical science journals. Results were presented in national and international conferences.

Žymėjimai

Simboliai

\hat{x}_k – būsenos prognozės vektorius k laiko momentu.

\bar{x}_k – būsenos atnaujinimo vektorius k laiko momentu.

z_k – matavimo vektorius.

w_k – proceso prognozės vektoriaus nepriklausomas Gauso triukšmas.

v_k – matavimo atnaujinimo vektoriaus nepriklausomas Gauso triukšmas.

A – būsenų perėjimo matrica.

B – valdymo matrica.

u_k – valdymo vektorius.

K_k – Kalmano filtro koeficientas.

\hat{y}_k – Kalmano filtro inovacijos parametras (angl. *Kalman filter innovation*).

\bar{y}_k – Kalmano filtro liekanos parametras (angl. *Kalman filter residual*).

\hat{P}_k – prognozės būsenos įverčių kovariacijų matrica.

\bar{P}_k – atnaujinimo būsenos įverčių kovariacijų matrica.

Q – nepriklausomo proceso triukšmo kovariacijų matrica.

R – nepriklausomo matavimo triukšmo kovariacijų matrica.

H – matavimų matrica.

R – matavimų kovariacijos matrica.

I – identiškumo matrica.

z_{TH} – slenkstinė orientacijos matavimo riba.

$\omega_{\phi, \theta, \psi}$ – objekto orientacija x , y ir z ašių atžvilgiu naudojant giroskopo kampinio greičio duomenis.

ω_{k_t} – objekto kampinio greičio matavimai naudojant giroskopą, kur k yra matavimai x , y ir z ašių atžvilgiu t laiko momentu.

$a_{\phi, \theta}$ – objekto orientacija x ir y ašių atžvilgiu naudojant akselerometro pagreičio duomenis.

a_{k_t} – objekto pagreičio matavimai naudojant akselerometrą, kur k yra matavimai x , y ir z ašių atžvilgiu t laiko momentu.

m_k – magnetinio lauko matavimai, kur k atitinkamai x , y ir z ašių atžvilgiu.

b_{ψ} – magnetometro krypties įvertis.

Δt – laiko tarpas tarp matavimų.

q – kvaternionas, kuris sudarytas iš keturių elementų $[q_0, q_1, q_2, q_3]$ vektoriaus.

e_a – Eulerio kampų vektorius $[\phi, \theta, \psi]$ paskaičiuotas naudojant kvaterniono elementus.

e_r – Eulerio kampų vektorius $[\phi, \theta, \psi]$ paskaičiuotas naudojant rotacijos matricos elementus.

σ – standartinis nuokrypis.

μ – vidurkis.

g – sunkio jėgos vektorius.

f_{cv}, f_{sf} – duomenų gavimo greitis požymių ištraukimo iš vaizdo ir apdorojimo bei jutiklių duomenų sujungimo atvejais.

I_p – analizuojamo pikselio p intensyvumo reikšmė.

$r(I_1, I_2)$ – atkartojimo kriterijaus įvertis lyginant du skirtingus vaizdus I_1 ir I_2 .

X – vaizdą aprašantis vektorius $[x_1, x_2, \dots, x_p]$, kur x_p yra konkretus vaizdo požymis.

Santrumpos

FAST – požymių išgavimo iš vaizdo ir jų apdorojimo algoritmas (angl. *Feature from Accelerated Segment Test*).

SURF – požymių išgavimo iš vaizdo ir jų apdorojimo algoritmas (angl. *Speeded Up Robust Features*).

SIFT – požymių išgavimo iš vaizdo ir jų apdorojimo algoritmas (angl. *Scale Invariant Feature Transform*).

SLAM – objektų pozicijos ir orientacijos nustatymas erdvėje naudojant vaizdų informaciją (angl. *Simultaneous Localization and Mapping*).

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

MEMS – mikroelektromechaniniai jutikliai (angl. *Microelectromechanical sensors*).

MARG – jutiklių masyvas, kurį sudaro akselerometras, giroskopas ir magnetometras (angl. *Magnetic, Angular Rate and Gravity Sensor*).

IMU – jutiklių masyvas, kurį sudaro akselerometras ir giroskopas (angl. *Inertial Measurement Unit*).

AHRS – objekto orientacijos ir pozicijos atskaitos sistema (angl. *Attitude and Heading Reference System*).

RANSAC – iteratyvus metodas stebimų duomenų įvertinimui (angl. *Random Sample Consensus*).

AR – papildyta realybė (angl. *Augmented Reality*).

KF – Kalmano filtras.

SF – jutiklių duomenų sujungimas (angl. *Sensor Fusion*).

CV – kompiuterinės rega (angl. *Computer Vision*).

GT – baziniai duomenys (angl. *Ground Truth*).

IoT – daiktų internetas (angl. *Internet of Things*).

RMSE – kvadratinės šaknies vidurkio klaidos (angl. *Root Mean Square Error*).

RMSPE (arba $\%RMSE$) – kvadratinės šaknies vidurkio klaidos procentinė išraiška (angl. *Root Mean Square Percentage Error*).

Sąvokos

Eulerio kampai – objekto orientacijos išraiška naudojant kampus ϕ (angl. *Roll*), θ (angl. *Pitch*), ψ (angl. *Yaw*) (angl. *Euler Angles*).

Kvaternionas – keturių elementų $[q_0, q_1, q_2, q_3]$ kompleksinis skaičius: q_0 nustato orientacijos pasikeitimo greitį; q_1, q_2, q_3 – rotacija atitinkamai x, y ir z ašių atžvilgiu (angl. *Quaternions*).

Deskriptorius – vaizdo požymių parametrų reikšmės (angl. *Descriptor*).

Kalmano filtro inovacija – skirtumas tarp tikrojo matavimo z_k ir matavimo prognozės $H\hat{x}_k$ vadinamas inovacija (angl. *Kalman filter innovation*).

Hibridinis objektų sekimas – tai toks sekimas, kuris apima tiek kompiuterinės regos, tiek jutiklių duomenų sujungimo atveju gautą pozicijos ir orientacijos informaciją apie sekamą objektą (angl. *Hybrid object tracking*).

Okliuzijos – sekamas objektas uždengtas arba nematomas dėl kitų esančių objektų/kliūčių aplinkoje (angl. *Occlusions*).

Haar bangų atsakas – filtras naudojamas kompiuterinės regos metoduose (angl. *Haar wavelet response*)

Turinys

ĮVADAS	1
Tyrimo problemos aktualumas	2
Tyrimo objektas.....	3
Tyrimo tikslas.....	3
Tyrimo uždaviniai	3
Tyrimo metodika.....	4
Darbo mokslinis naujumas ir jo reikšmė	4
Darbo rezultatų praktinė reikšmė	5
Ginamieji teiginiai.....	6
Darbo rezultatų aprobavimas.....	6
Disertacijos struktūra	8
I. Vaizdo požymių išskyrimo metodų tyrimas	10
1.1. Požymių išskyrimo ir klasifikavimo metodų analizė	11
1.2. Požymių išskyrimo iš vaizdo metodų problematika	15
1.2.1. Požymių išskyrimo metodas <i>FAST</i>	21
1.2.2. Požymių išskyrimo metodas <i>SIFT</i>	24
1.2.3. Požymių išskyrimo metodas <i>SURF</i>	29
1.3. Požymių išskyrimo metodų <i>FAST</i> , <i>SURF</i> ir <i>SIFT</i> greitaveikos palyginimas ..	31
1.4. <i>FAST</i> , <i>SIFT</i> ir <i>SURF</i> metodų atkartojimo kriterijaus įvertinimas	33
1.5. Skyriaus išvados.....	36
II. Objekto, turinčio padėtį nustatančius jutiklius, sekimo tyrimas	38
2.1. Objektų sekimo metodų apžvalga papildytos realybės sistemose	38
2.2. Skaitmeninių jutiklių tyrimas.....	40
2.3. Kvaternionų algebros taikymas jutiklių matavimų duomenims	43
2.4. Kameros orientacijos įvertinimas ir taikymas papildytoje realybėje.....	46
2.5. Objekto orientacijos nustatymo sprendimo taikymas sferos formos įrenginiui	50
2.6. Kalmano filtro naudojimas sekant objektų orientaciją	54
2.7. Diskretusis Kalmano filtras.....	55
2.8. Kalmano filtro <i>Q</i> ir <i>R</i> parametrų derinimas	58
2.9. „Sunkios uodegos“ Kalmano filtre	60
2.10. Kalmano filtro taikymas jutiklių duomenims įvertinti ir eksperimentų rezultatai	63

2.11. Gradientinio nusileidimo metodo taikymas matavimo reikšmei nustatyti	70
2.12. Skyriaus išvados	72
III. Hibridinis objektų sekimo metodas papildytos realybės sistemose naudojant Kalmano filtrą.....	74
3.1. Kameros orientacijos ir pozicijos įvertinimas (sekimas) jutiklių duomenų sujungimo atveju	77
3.2. Objekto orientacijos ir pozicijos įvertinimas (sekimas) požymių išskyrimo iš vaizdo ir sutapdinimo atveju	80
3.3. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą eksperimentai ir jų rezultatai	81
3.4. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą adaptacija mobiliesiems įrenginiams papildytos realybės srityje	90
3.5. Skyriaus išvados.....	94
BENDROSIOS IŠVADOS	96
LITERATŪROS SĄRAŠAS.....	98
PRIEDŲ SĄRAŠAS	106

IVADAS

Papildyta realybė (angl. *Augmented Reality*) yra sritis, išsivysčiusi iš virtualiosios realybės, kurioje vartotojas mato realioje aplinkoje virtualų turinį ir turi galimybę su juo sąveikauti. Papildytos realybės galimos taikymo sritys yra medicina, švietimas, gamyba, pramogos, rinkodara ir kt. Papildyta realybė suteikia galimybę matyti tikrąjį pasaulį įterpiančią į jį virtualius objektus ar kitą informaciją. Tokiu būdu objektai nėra pakeičiami, o integruojami į realybę. Atliekant objektų sekimą aplinkoje dažniausiai naudojami kompiuterinės regos metodai. Jie atlieka sudėtingą informacijos iš realios aplinkos išgavimo ir apdorojimo procesą, norint suteikti patikimą informaciją, kaip ir kur vartotojui turi būti pateiktas virtualus turinys. Efektyvus objektų atpažinimas ir sekimas yra esminis uždavinys, sprendžiamas papildytos realybės srityje norint patikimai atvaizduoti virtualų turinį sekamo objekto atžvilgiu. Šiuo metu papildytos realybės sistemos dažniausiai naudojamos mobiliuosiuose įrenginiuose, todėl reikalingas sprendimo būdas, kuris patikimai įvykdytų atpažinimo, sekimo ir virtualaus turinio atvaizdavimo užduotis. Inercinių jutiklių sistemos šiuo metu dažnai naudojamos dėl galimybės įvertinti įrenginių orientaciją, todėl jų taikymas yra perspektyvus papildytos realybės srityje. Pagrindinės papildytos realybės tyrimų sritys susijusios su tokiais aspektais:

- a) Grafikos perteikimo techninė ir programinė įranga.
- b) Sekimo metodai, kurie leidžia tinkamoje padėtyje pateikti virtualų turinį sekamo objekto atžvilgiu.
- c) Sekimo metodo kalibravimo ir registravimo priemonės, skirtos tiksliai suderinti realų ir virtualų vaizdą vartotojo atžvilgiu.
- d) Rodymo techninė įranga norint sujungti virtualų vaizdą su realaus pasaulio vaizdu.
- e) Kompiuterinė techninė įranga apdoroti papildytos realybės algoritmus.
- f) Sąveikos metodai, kurie nurodo kaip vartotojas gali manipuluoti papildytos realybės virtualiu turiniu.

Paprastai pilno papildytos realybės sprendimo kūrimas apima techninės, programinės įrangos ir metodų iš punktuose a)–f) minėtų aspektų integraciją. Objektų pozicijos ir orientacijos sekimo metodai yra pagrindinė nagrinėjama problema daugelio mokslinių tiriamųjų darbų. Šie metodai naudojami papildytos realybės srityje ir vis dar turi daug neišspręstų problemų, todėl hibridinių objektų sekimo metodų sudarymas yra

tikslingas, kai naudojama tiek kompiuterinės regos, tiek jutiklių duomenų sujungimo atveju gauta pozicijos ir orientacijos informacija apie sekamą objektą, siekiant patikimiau įvertinti tiek objekto poziciją, tiek objekto orientaciją erdvėje tuo pačiu metu. Kitos tyrimų problemos yra susijusios su sąveikos metodais, kurių pagrindu manipuluojama skaitmeniniu turiniu.

Tyrimo problemos aktualumas

Papildyta realybė yra vizualizavimo technika, kuri plačiai naudojama daugelyje mobiliųjų programėlių, dažniausiai sekant dirbtinį objektą vaizdo požymių išskyrimo ir apdorojimo metodų pagrindu, pavyzdžiui, naudojant kvadratinį žymeklį (angl. *markers*). Vaizdo požymių išskyrimo ir apdorojimo metodo pagrindu paskaičiuojama, kurioje padėtyje (pozicijoje ir orientacijoje) turi būti atvaizduotas 2D/3D virtualus turinys vartotoją supančioje realioje aplinkoje. Pagrindinės problemos, naudojant žymeklius, vartotojo ar objektų iš aplinkos okliuzijos. Dėl šių okliuzijų dažniausiai dingsta 3D virtualus turinys, todėl jos turi neigiamą įtaką mobiliajai programai naudoti. Kai kurie kompiuterinės regos metodai leidžia išspręsti dalinės okliuzijos problemas atvaizduojant virtualų turinį, tačiau būtina įvertinti šių metodų greitį bei tinkamumą, nes užduotys turi būti vykdomos realiu laiku. Žymeklių sekimo metodas sumažina skaičiavimų reikalavimus, tačiau turi apribojimų dėl sekamo objekto dydžio vaizde bei nutrūkstančio sekimo, kai žymeklis nėra matymo lauke. Pagrindinė kompiuterinės regos metodų realaus laiko sekimo sistemose problema – aplinkos kompleksiskumas ir sekamo objekto judėjimas. Pavyzdžiui, objektas gali atsiskirti, susilieti dėl dalinių okliuzijų ar vaizdo triukšmo, objekto vaizdas gali keistis dėl skirtingo apšvietimo, o didesniu atstumu esančių objektų požymiai nėra patikimai rekonstruojami, todėl neefektyviai paskaičiuojama sekamo objekto orientacija bei padėtis. Greitas arba netolygus kameros judėjimas sukelia vaizdo sekimo sutrikimų. Tokie trūkumai gali būti pašalinami naudojant inercinius jutiklius. Inercinių jutiklių matavimų informacija suteikia galimybę įvertinti staigius objekto, pavyzdžiui, įrenginio kameros orientacijos bei pozicijos pokyčius, kurie gali atsirasti naudotojui judinant įrenginį, tačiau atskira jutiklių informacija nėra tiksli ir patikima. Jutiklių matavimai paveikiami triukšmo, nuokrypių ir magnetinės interferencijos, todėl yra poreikis sudaryti efektyvų orientacijos ir pozicijos įvertinimo modelį.

Tyrimo objektas

Darbo tyrimo objektas – objektų sekimo metodai papildytos realybės sistemose, leidžiantys įvertinti objektų orientaciją ir poziciją realioje erdvėje, požymių išskyrimo iš vaizdo bei apdorojimo ir jutiklių duomenų sujungimo pagrindu.

Tyrimo tikslas

Darbo tyrimo tikslas – pasiūlyti hibridinį objekto sekimo metodą naudojant Kalmano filtrą papildytos realybės srityje, požymių išskyrimo iš vaizdo ir jutiklių duomenų sujungimo metodų pagrindu, siekiant pagerinti objektų orientacijos ir pozicijos sekimo tikslumą realioje erdvėje.

Tyrimo uždaviniai

Tikslui įgyvendinti keliami tokie darbo uždaviniai:

1. Atlikti objektų sekimo metodų, kompiuterinės regos ir jutiklių duomenų sujungimo pagrindu, tyrimą bei pateikti taikymo rekomendacijas papildytos realybės srityje.
2. Išanalizuoti analitiniu-eksperimentiniu būdu inercinių jutiklių taikymo galimybes bei jutiklių orientacijos duomenų sujungimo metodus, siekiant pritaikyti objekto sekimo informaciją ne tik papildytos realybės sistemose, bet ir sukonstruoti sąveikos įrenginį, skirtą manipuluoti skaitmeniniu turiniu.
3. Pasiūlyti hibridinį objekto sekimo metodą naudojant Kalmano filtrą papildytos realybės srityje, pasižymintį papildančiomis savybėmis orientacijos ir pozicijos įvertinime, lyginant su ne hibridinių metodų naudojimu, kai informacija galimai neprieinama, bei užtikrinantį pagerintą objektų sekimo sprendimą tikslumo ir patikimumo atžvilgiu.
4. Palyginti pasiūlyto hibridinio objekto sekimo metodo, naudojant Kalmano filtrą, tyrimo rezultatus su baziniais orientacijos ir pozicijos duomenimis ir pritaikyti šį sprendimą papildytos realybės daiktų interneto srityje, kur būtų užtikrintas sukurtos vartotojo sąsajos, skirtos daiktų internetui, nenutrūkstamas atvaizdavimas realiu laiku, esant greitiems kameros judesiams ar okliuzijoms aplinkoje.

Tyrimo metodika

Analizuojant mokslinius darbus objektų pozicijos ir orientacijos sekimo erdvėje atžvilgiu, naudoti informacijos paieškos, sisteminimo, analizės, lyginamosios analizės ir apibendrinimo metodai. Atliktų tiek teorinių, tiek empirinių tyrimų pagrindu sukonstruotas sąveikos įrenginio prototipas ir pasiūlytas hibridinis objektų sekimo metodas naudojant Kalmano filtrą. Eksperimentinio tyrimo metodu atliktas skaitmeninis signalų apdorojimas ir statistinė tyrimų rezultatų analizė, o gautiems rezultatams įvertinti naudotas palyginimo ir apibendrinimo metodas.

Darbo mokslinis naujumas ir jo reikšmė

Rengiant disertaciją buvo gauti šie mokslui nauji rezultatai:

1. Daugelis nagrinėtų objekto pozicijos ir orientacijos sekimo metodų tyrimų labiau teoriniai, aprašomojo pobūdžio arba analizuojama tik dalinė problema: a) pozicijos ir orientacijos įvertinimas tik kompiuterinės regos metodų atvejais; b) tik pozicijos arba tik orientacijos įvertinimas jutiklių duomenų sujungimo atvejais. Nėra sisteminių tyrimų, leidžiančių kompiuterinės regos metodų trūkumus sumažinti, kai objekto sekimas nutrūksta dėl besikeičiančių išorės savybių po vaizdo transformacijų, okliuzijų ar kitų aplinkos sąlygų, naudojant papildomus objektų sekimo metodus, pavyzdžiui, jutiklių duomenų sujungimą, tačiau išskirtinai šioje disertacijoje toks tyrimas pateiktas.

2. Pasiūlytas hibridinis objektų sekimo metodas naudojant Kalmano filtrą pasižymi papildančiomis savybėmis pozicijos ir orientacijos įvertinimo atžvilgiu, kuriame pašalinti atskirai naudojamų objekto sekimo metodų trūkumai kaip triukšmas, nuokrypiai ir sekimo sutrikimai. Šie sekimo sutrikimų gerinimai yra svarbūs dėl problemų esančių tiek vaizdo požymių išskyrimo ir apdorojimo, tiek jutiklių matavimų duomenų sujungimo metoduose. Hibridinio objektų sekimo metodo rezultatai, eksperimentiškai įvertinti ir palyginti su imituotais kompiuterinės regos bei jutiklių duomenų sujungimo metodo duomenimis, rodo padidėjusį sekimo tikslumą. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą orientacijos įvertinimo paklaida siekia tik $RMSPE_{KF}^o = 0,24\%$, kai tuo tarpu tik jutiklių duomenų sujungimo atveju $RMSPE_{SF}^o = 0,30\%$, o tik kompiuterinės regos atveju $RMSPE_{CV}^o = 0,30\%$. Pozicijos įvertinimo paklaida siekia $RMSPE_{KF}^p = 0,96\%$, tik jutiklių duomenų sujungimo atveju – $RMSPE_{SF}^p = 13,06\%$, o tik kompiuterinės regos atveju – $RMSPE_{CV}^p = 19,75\%$.

3. Atliktas hibridinis objektų sekimo metodas naudojant Kalmano filtrą tyrimas universalus tuo, kad gali būti taikomas ne tik papildytos realybės sistemose, bet taip pat parodyta, kad atskira jutiklių duomenų sujungimo tyrimo dalis panaudota konstruojant nauju naudojimo būdu pasižymintį sąveikavimo įrenginį.

Darbo rezultatų praktinė reikšmė

1. Pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą yra aktualus daugelyje praktinių taikymo sričių, tačiau tyrime numatyta pagrindinė taikymo sritis yra papildyta realybė. Šiuo metodu siūlomas patikimas objektų orientacijos ir pozicijos įvertinimas erdvėje, kuriuo užtikrinamas virtualaus turinio pateikimas realaus vaizdo kontekste nepertraukiamai sąveikaujant net aplinkoje esant trikdžių, atsirandančių dėl greitai naudotojo judinamos kameros, okliuzijų aplinkoje ir pan.

2. Priklausomai nuo prieinamos informacijos, gautos išskyrus ir apdorojus požymius iš vaizdo ar jutiklių duomenų sujungimo įverčių, pasiūlyti skirtingi orientacijos ir pozicijos informacijos pasiklivimo atvejai, atsižvelgiant į Kalmano filtro inovacijos parametro sąlygas. Pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą pagerina objekto sekimo patikimumą ir eliminuoja atsirandantį delsimą požymių išskyrimo iš vaizdo atveju.

3. Sukurta papildytos realybės programa mobiliams įrenginiams, kurioje adaptuotas hibridinis objekto sekimo metodas naudojant Kalmano filtrą. Sprendimas pritaikomas mobiliuosiuose įrenginiuose, turinčiuose akcelerometrą, giroskopą ir magnetometrą.

4. Dalis atlikto tyrimo rezultatų panaudoti *Erasmus IP* projekte „Virtual bridge construction modelling and demonstration in augmented reality environment“. Tarptautinio projekto dalyviai: Klaipėdos valstybinė kolegija, Didžiosios Britanijos *Leeds Metropolitan* universitetas, Bulgarijos *Varna Free* universitetas, 2014 m.

5. Rezultatai panaudoti mokslo, inovacijų ir technologijų agentūros projekte „Inovatyvaus verslo kūrimo skatinimas (INOVEKS)“, 2014 – 2015 m., pateikiant patentinę paraišką disertacijoje gautų jutiklių duomenų sujungimo tyrimo rezultatų pagrindu. Pareiškėjas – Edgaras Artemčiukas. Išradimo pavadinimas – „Sferos formos sąveikos įrenginys“. Patento paraiškos Nr. 2015 063. Paraiškos pateikimo data: 2015-07-24. Būsena: taisomas. Realizaciją galima pažiūrėti:

Ginamieji teiginiai

1. Siekiant užtikrinti tikslų objekto sekimą vaizde ir nepertraukiamą virtualaus turinio atvaizdavimą papildytos realybės aplinkoje, tikslinga naudoti ne tik kompiuterinės regos metodus, bet ir jutiklių duomenų sujungimą, kai jutikliai yra pritvirtinti prie kameros.
2. Pasiūlytas hibridinis objektų sekimo metodas naudojant Kalmano filtrą leidžia išvengti požymių ištraukimo bei apdorojimo iš vaizdo ir jutiklių duomenų sujungimo pagrindu naudojamų sekimo metodų sutrikimų, kurie atsiranda dėl sekamo objekto transformacijų vaizde, išorinių aplinkos sąlygų, jutiklių matavimų, pritvirtintų prie kameros, triukšmo, nuokrypių ar kitų iškraipymų.
3. Pateiktas hibridinis objektų sekimo metodas naudojant Kalmano filtrą leidžia užtikrinti patikimus sekamo objekto pozicijos ir orientacijos įverčius tiek imituotų duomenų atžvilgiu, tiek taikant papildytos realybės aplinkoje realaus naudojimo sąlygomis greitai judant kamerai ir esant sekamo objekto okliuzijomis vaizde.

Darbo rezultatų aprobavimas

Mokslinės publikacijos Thomson Reuters žurnaluose:

1. Artemciukas, E., Plestys, R., Andziulis, A., Gerasimov, K., Zulkas, E., Pasviestis, L., Krauze, A. (2012). Real-time Control System for Various Applications using Sensor Fusion Algorithm. *Elektronika ir elektrotechnika*, Vol. 18, No. 10, p. 61–64, ISSN 1392-1215, DOI: 10.5755/j01.eee.18.10.3064.
2. Artemciukas, E., Sakalauskas, L., Zulkas, E. (2016). Kalman Filter for Hybrid Tracking Technique in Augmented Reality. *Elektronika ir elektrotechnika*, Vol. 22, No. 6, p. 73–79, ISSN: 1392-1215, DOI: 10.5755/j01.eie.22.6.17228.

Mokslinės publikacijos ISI Proceedings:

1. Lukosiunas, E., Bulbenkiene, V., Andziulis, A., Artemciukas, E. (2011). An ultrasonic tracking method for augmented reality. *Proceedings of the 17th International Conference on Information and Software Technologies*, Kaunas, Lithuania, p. 170–173.

2. Zulkas, E., Artemciukas, E., Dzemydiene, D., Guseinoviene, E. (2015). Energy consumption prediction methods for embedded systems. *Tenth International Conference on Ecological Vehicles and Renewable Energies (EVER)*, Monte Carlo, p. 1–5, ISBN 978-1-4673-6784-4, DOI: 10.1109/EVER.2015.7112932.

Mokslinės publikacijos kituose recenzuojamuose žurnaluose:

1. Artemčiukas, E., Sakalauskas, L. (2014). Vaizdo apdorojimo metodų tyrimas ir taikymas papildytos realybės sistemose. *Jaunųjų mokslininkų darbai*. Nr. 1 (41), p. 91–98, ISSN 1648-8776.
2. Artemčiukas, E., Sakalauskas, L. (2014). Jutiklių orientacijos duomenų integracija papildytos realybės technologijoje. *Mokslas – Lietuvos ateitis. Elektronika ir elektrotechnika*, Vilnius: Technika, Nr. 6 (2), p. 172–177, ISSN 2029-2341 (print) / ISSN 2029-2252 (online).
3. Artemčiukas, E., Sakalauskas, L. (2014). *Leap Motion* valdiklio taikymas papildytos realybės technologijoje. *Technologijos mokslo darbai Vakarų Lietuvoje IX*, Nr. 9, p. 10–15, ISSN 1822-4652.

Dalyvavimas tarptautinėse konferencijose:

1. Artemciukas, E. Real-time Control System for Various Applications using Sensor Fusion Algorithm (2012). *The 16th International Conference ELECTRONICS 2012*, Palanga, Lithuania, 18th-20th June.
2. Artemciukas, E. Kalman Filter for Hybrid Tracking Technique in Augmented Reality (2016). *The 20th International Conference ELECTRONICS 2016*, Palanga, Lithuania, 13th-15th June.

Dalyvavimas nacionalinėse konferencijose:

1. Artemčiukas, E. (2013). Computer vision methods research and application in augmented reality systems. *5-oji Lietuvos jaunųjų mokslininkų konferencija „Operacijų tyrimas ir taikymai“*, Šiaulių universitetas.
2. Artemčiukas, E. (2014). *Leap Motion* valdiklio taikymas papildytos realybės technologijoje. *IX-oji mokslinė konferencija „Jūros mokslai ir technologijos*, Klaipėdos universitetas.

3. Artemčiukas, E. (2015). 3D virtualaus turinio manipuliavimas papildytos realybės technologijoje. *Penktoji jaunųjų mokslininkų konferencija: „Tarpdalykiniai tyrimai fiziniuose ir technologijos moksluose“*, Lietuvos mokslų akademija.

Disertacijos struktūra

Disertaciją sudaro įvadas, 3 skyriai, bendrosios išvados, literatūros ir priedų sąrašas. Disertacijos apimtis: 107 puslapiai, 109 numeruotos formulės, 46 paveikslai ir 3 lentelės. Literatūros sąrašą sudaro 118 šaltinių.

Įvade aprašyta mokslinio tyrimo dalykinė sritis, nagrinėjamos problemos aktualumas, tyrimo objektas, tikslas, uždaviniai, mokslinis naujumas bei jo reikšmė, rezultatų praktinė reikšmė, ginamieji teiginiai ir disertacijos rezultatų aprobavimo sąrašas.

1 skyriuje atliktas požymių išskyrimo iš vaizdo ir apdorojimo metodų tyrimas, siekiant išsiaiškinti šių metodų tinkamumą plėtojant papildytos realybės sistemas. Skyriuje pateikiami šiuo metu kai kurie plačiausiai naudojami požymių aptikimo ir aprašymo metodai, kurie leidžia išspręsti dalinės okliuzijos problemas ir tinkamai atvaizduoti virtualų turinį papildytos realybės aplinkoje. Tyrime atliktas našumo palyginimas pagal atkartojimo kriterijų naudojant skirtingo tipo vaizdų transformacijos rinkinius, tikrinant specifines vaizdų poras. Įvertintas santykinis požymių išskyrimo ir apdorojimo metodų greitis ir tinkamumas papildytos realybės sistemose.

2 skyriuje atliktas jutiklių orientacijos duomenų sujungimo tyrimas ir integracija papildytos realybės srityje. Nagrinėjamas gradientinio nusileidimo metodo (kvaternionų pagrindu) taikymas mikroelektromechaninių jutiklių duomenims, norint tiksliau įvertinti kameros orientaciją trimatėje erdvėje. Tyrime siekiama eliminuoti pavienių jutiklių matavimo duomenų triukšmą ir pagerinti kameros orientacijos sekimo tikslumą, patikimumą, kur virtualus turinys atvaizduojamas papildytoje realybėje nenaudojant požymių iš vaizdo išskyrimo ir jų apdorojimo metodų. Demonstruojamas orientacijos įvertinimo sprendimas pritaikytas ne tik iš kameros sekimo aspekto ir taikymo papildytos realybės srityje, bet ir plėtojant sąveikos įrenginį. Nagrinėjamas Kalmano filtro panaudojimas sekant objektų orientaciją. Pateikta detali Kalmano filtro analizė, praktinis taikymas gautiems jutiklių matavimų duomenims, kurie išreikšti kvaternionais.

3 skyriuje pasiūlytas hibridinis objekto sekimo metodas papildytos realybės sistemose, naudojant Kalmano filtrą. Tyrime atlikti eksperimentai su imituotais objekto pozicijos bei orientacijos duomenimis požymių ištraukimo iš vaizdo ir apdorojimo bei jutiklių duomenų sujungimo atvejais. Rezultatai palyginti bei pateikti pasiūlyto metodo pagerinti aspektai objekto sekimo atžvilgiu. Hibridinis objekto sekimo metodas naudojant Kalmano filtrą adaptuotas mobiliems įrenginiams papildytos realybės daiktų interneto srityje.

Pateiktas priedų sąrašas su turiniu *CD* duomenų laikmenoje ir *Google Drive*_diske.

I. Vaizdo požymių išskyrimo metodų tyrimas


Kompiuterinės regos metodai (požymių išskyrimas iš vaizdo) yra daugelio disciplinų tyrimų objektas. Požymių išskyrimas naudojamas mašininio mokymo, struktūros atpažinimo ir vaizdo požymių apdorojimo srityse, o pastaroji neatsiejama nuo papildytos realybės srities. Vaizde paprastai yra įvairios informacijos apie jame esančius objektus: objektų tarpusavio padėtį, santykinį dydį ir atstumą tarp jų, kampą, objektų spalvą ir tekstūrą. Dažnai daugumai uždavinių pakanka tik dalies šios informacijos, kad būtų galima sumažinti apdorojamų duomenų kiekį ir padidinti apdorojimo spartą. Praktinio naudojimo sąlygomis požymių išskyrimas priklauso nuo sprendžiamos konkrečios problemos, taikymo srities, todėl nėra vienintelio apibendrinto požymių išskyrimo metodo, veikiančio visais taikymo atvejais. Dėl šios priežasties svarbu iširti požymių išskyrimo ir apdorojimo algoritmus, kurie potencialiai yra tinkamiausi papildytos realybės srityje. Papildytos realybės srityje svarbi ne tik tiksli vaizdo požymių analizė, bet ir galimybė juos sutapdinti tarp skirtingų vaizdų realiu laiku.

Papildyta realybė yra vizualizavimo technika, kuri plačiai naudojama daugybėje taikymo sričių, dažniausiai sekant dirbtinius objektus, pavyzdžiui, kvadratinius žymeklius (angl. *Markers*). Sekamas žymeklis vaizde leidžia nustatyti poziciją bei orientaciją erdvėje ir įterpti 3D virtualų turinį realioje aplinkoje. Pagrindinės problemos naudojant žymeklius – vartotojo ar objektų iš aplinkos okliuzijos. Okliuzijos šiuo atveju yra kliūtys, kiti objektai aplinkoje, dėl kurių sekamas objektas yra uždengtas ir tampa visiškai arba dalinai nematomas kameros vaizde. Dėl šių okliuzijų dažniausiai dingsta 3D virtualus turinys, todėl jos turi neigiamą įtaką naudojant mobiliąsias programas. Šiame skyriuje atlikta požymių išskyrimo metodų analizė. Detalesnei analizei pasirinkti šiuo metu labiausiai naudojami požymių išskyrimo metodai *FAST* (angl. *Feature from Accelerated Segment Test*), *SIFT* (angl. *Scale Invariant Feature Transform*) ir *SURF* (angl. *Speeded Up Robust Features*), kurie leidžia išspręsti dalinės okliuzijos problemas atvaizduojant virtualų turinį. Tyrime atliktas našumo įvertinimas naudojant atkartojimo (angl. *repeatability*) kriterijų, lyginant skirtingo tipo vaizdų transformacijos rinkinius. Tikrinant specifines vaizdų poras, atpažinti objektą, įvertintas požymių išskyrimo ir sutapdinimo metodų greitis ir tinkamumas papildytos

realybės technologijoje. Tyrimo rezultatai svarbūs pasiūlyti pagerintą sekimo metodą papildytos realybės srityje, norint vėliau įtraukti inercinių jutiklių informaciją.

1.1. Požymių išskyrimo ir klasifikavimo metodų analizė

Objektų atpažinimo srityse naudojami konkrečių objektų požymiai, kurie apskaičiuojami iš pradinių duomenų bei nusako esmines objekto savybes. Dažniausiai atlikus požymių išskyrimą svarbu nustatyti, kuriuos tikslingiausia naudoti objektui aprašyti. Požymių kiekis turi būti kuo mažesnis norint atlikti greitą požymių palyginimą. Kitas svarbus aspektas – požymiai turi kuo detaliau nusakyti pradinį atpažinti pateikiamą objektą, o idealiu atveju – iš požymių tiksliai rekonstruoti pradinį objektą. Požymių išskyrimo procesą galima apibrėžti kaip aibę požymių arba vaizdo charakteristikų, kurios efektyviai pateikia objekto informaciją, reikalingą tolesnei analizei ar klasifikacijai. Dimensijų sumažinimas (angl. *dimensionality reduction*) statistikoje yra procesas, skirtas sumažinti atsitiktinių arba kintamųjų kiekį, kaip neturinčių jokių tarpusavio koreliacijų. Analogiškas procesas taikomas išskiriant požymius iš vaizdų. Dažnu atveju po požymių išskyrimo naudojamas jų parinkimas, siekiant išvengti perteklinių požymių. Požymių išskyrimas turi pradinę aibę duomenų, iš kurių išskiriamos reikšmės yra informatyvios ir neperteklinės, palengvinant tolesnį mokymąsi ir generalizaciją, kad būtų geriau suprantama vaizdo informacija. Esant pradinių duomenų pertekliui, galima juos transformuoti į sumažintą požymių vektorių atitinkamai juos parenkant. Parinkti požymiai turi informaciją, susijusią su pilnais įvesties duomenimis, norint atlikti objekto sekimą vaizde. Išskirtų požymių (duomenų) klasifikavimą nusako pateiktas pavyzdys, 1 pav.



1 pav. Duomenų klasifikavimas (Raschka, S., 2015)

Pirmuoju a) atveju gauti blogai suklasifikuoti duomenys, didelis klasės atskyrimo ribos poslinkis dėl per mažo duomenų kiekio (angl. *Underfitting*). Antruoju b) atveju gauti tinkamai suklasifikuoti duomenys, surastas naudojamų duomenų kiekio balansas.


Paskutiniu metu c) atveju klasių atskyrimas per daug priklauso nuo naujų duomenų, todėl klasės nėra atskirtos tinkamai viena nuo kitos, o duomenys yra tinkamai klasifikuoti, tačiau klasifikatorius netinka naujų duomenų klasifikavimui. Tokia problema dar vadinama persimokymu (angl. *Overfitting*). Persimokymo problema tiriama klasifikavimo kontekste, siekiant sumažinti duomenų kiekį, nes šis atvejis lemia didesnę klaidų santykį naujiems duomenims ir prognozavimo tikslumas suprastėja.

Didesnis kiekis požymių nebūtinai suteikia didesnę tikslumą atpažįstant objektus vaizde. Požymių išskyrimas ir klasifikacijos algoritmai dideliems duomenų kiekiams yra aktuali ir seniai tiriama problema (Lee, C.; Landgrebe, D., 1993). Tyrimuose klasifikavimo tikslumas gerinamas mažinant duomenų kiekį, norint gauti patikimesnes tendencijas (Liu, R.; Gillies, D. F., 2016). Disertacijoje (Wu, C., 2007) tyrinėjami kriterijai susiję su vaizdo kokybe, segmentacija, vaizdo gerinimu bei požymių aptikimu, siekiant gauti didelio tikslumo požymių išskyrimo algoritmus. Perteklinis kiekis požymių, pagal kuriuos sekami objektai, gali pareikalauti didelio kiekio atminties, ilgėti apdorojimo trukmę, sukelti klasifikavimo algoritmui atsitiktinių klaidų ir netikslų prognozavimą esant naujiems duomenims. Požymių išskyrimas apima duomenų sumažinimą iš didelio jų kiekio ir pakankamai tikslų tų duomenų aprašymą. Siūlomi požymių išskyrimo algoritmai turi pasižymėti keliomis svarbiomis savybėmis:

1) Prognozuoti minimalų kiekį požymių, būtinų pasiekti tą patį klasifikavimo tikslumą, kaip ir esant pradiniam duomenų kiekiui šiai objekto struktūros atpažinimo problemai spręsti.

2) Rasti būtinus požymių vektorius.


Visur požymių išskyrimo esminiai principai išlieka tie patys – kaip iš kuo mažesnio duomenų kiekio gauti kuo daugiau tų konkretų objektą nusakančios informacijos. Klasifikavimo metodai, kurie gali būti naudojami vaizdo požymių išskyrimo, pateikti 2 pav.



2 pav. Požymių išskyrimo ir klasifikavimo metodų skirstymas

Šiuo metu sukurta įvairių klasifikavimo metodų, tokių kaip Bajeso klasifikatorius, klasifikavimo medžiai (Verikas, A.; Gelzinis, A.; Bacauskiene, M., 2011), k-NN

artimiausių kaimynų klasifikatorius (angl. *k-nearest neighbor* – k-NN) (Bishop, C. M., 2006), (Alpaydin, E., 2009), tačiau klasifikuojant vaizdo struktūrą dažniausiai naudojamas atraminių vektorių klasifikatorius (angl. *Support Vector Machines* – SVM) (Bahrampour, S.; Ray, A.; Sarkar, S.; Damarla, T.; Nasrabadi, N. M., 2013), 3 pav.



3 pav. Atraminių vektorių klasifikatorius (Tharwat, A.; Hassanien, A. E.; Elnaghi, B. E., 2016)

Atraminių vektorių klasifikatorius (toliau SVM) yra klasifikavimo metodas, taikomas ir klasifikavime, ir regresinėje analizėje. SVM klasifikatorius sukuria tokią hiperplokštumą, kuri duomenis atskiria į dvi klases. Sudarant hiperplokštumą, mokymo aibės objektai skirstomi į dvi dalis taip, kad atstumas tarp artimiausių elementų, priklausančių skirtingoms klasėms, iki tos hiperplokštumos būtų maksimalus.

Tarkim, turime mokymo duomenų aibę x_i , kur kiekvienas aibės objektas turi nustatytą klasę y_i . Sudaromos tokios poros $\{x_i, y_i\}$, $i = 1, \dots, m$, čia $m \in N$ mokymo duomenų kiekis, $x_i \in R^n$ ir dviejų reikšmių klasės $y_i = \{1, -1\}$. Konstruojant tinkamiausią hiperplokštumą, sprendžiamas optimizavimo su apribojimais uždavinys. Hiperplokštumos išreiškiamos (1) lygtimi:

$$w \cdot x + b = 0, \quad (1)$$

čia w vektorius ortogonalus hiperplokštumai, $b \in R$ – konstanta. Hiperplokštuma (w, b) , kuri skiria duomenis išreiškiama naudojant tikslo funkciją (2):

$$f(x) = \text{sign}(w \cdot x + b). \quad (2)$$

Sudarant tinkamiausią hiperplokštumą, sprendžiamas optimizavimo (3) su apribojimais (4), (5) uždavinys (Bernatavičienė, J., 2008):

$$\min_{w,b} \frac{1}{2} \|w\|^2, \quad (3)$$

$$x_i \cdot w + b \geq 1, \text{ kai } y_i = 1, \quad (4)$$

$$x_i \cdot w + b \leq -1, \text{ kai } y_i = -1. \quad (5)$$

Pirmuoju nustatytos ribos atveju (4) duomenys priskiriami pirmai klasei, o antruoju nustatytos ribos atveju (5) – antrai klasei. Minimizuojama paklaida, maksimizuojant hiperplokštumos ribas (3).

Dažnai skirtingų klasių duomenys negali būti tiesiškai atskirti, todėl taikomos įvairios branduolio funkcijos. Šios branduolio funkcijos klasifikuojamus duomenis transformuoja į kitą erdvę, kurioje įmanoma tiesiškai atskirti klases. SVM klasifikatorius yra plačiai taikomas vaizdams klasifikuoti. Jis gali būti efektyviai naudojamas, kai vaizdai klasifikuojami į kategorijas pagal juose esančias tekstūras ir objektus (Zhang, J.; Marszalek, M.; Lazebnik, S.; Schmid, C., 2007) bei didelėms vaizdų aibėms klasifikuoti (Yuanqing, L.; Fengjun, L.; Shenghuo, Z.; Ming, Y., 2011).

Klasifikavimo metodais siekiama tiriamus vaizdus priskirti vienai iš klasių pagal jų skaitinius duomenis. Tarkim, vaizdas yra aprašomas n -mačiu vektoriumi $S = (s_1, s_2, \dots, s_n)$, o Y_1, Y_2, \dots, Y_l žymi klases, kurioms gali priklausyti vaizdas, l – klasių kiekis. Dažnai klasifikavimo uždaviniai sprendžiami dviem etapais (Tichonov, J.; Kurasova, O.; Filatovas, E., 2015):

1) Naudojant vaizdą aprašančiu vektoriumi S , nustatomi vaizdo požymiai x_p ir sudaromas vektorius $X = [x_1, x_2, \dots, x_p]$, čia $p \leq n$. Siekiama rasti kuo mažesnę požymių kiekį p , neprarandant daug informacijos apie vaizdą. Iš požymių reikšmių galima sudaryti vaizdus, atitinkančius daugiamačius vektorius X_1, X_2, \dots, X_m . Čia $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]$, m – analizuojamų vaizdų (vektorių) kiekis. Kiekvienas vektorius X_i , $i = 1, \dots, m$ yra priskiriamas vienai iš klasių Y_j , kur $j \in [1, \dots, l]$.

2) Sukuriamas klasifikatorius, remiantis vaizdus charakterizuojančiais vektoriais X_1, X_2, \dots, X_m . Klasifikatoriumi vadinamas vektorių X_1, X_2, \dots, X_m atvaizdis į klasių žymių aibę Y_1, Y_2, \dots, Y_l . Pagal sukurtą klasifikatorių vaizdas, kurio klasė nėra žinoma, priskiriamas vienai iš žinomų klasių.

Sukūrus klasifikatorių, reikia nustatyti, ar jis tinkamai klasifikuoja duomenis. Tam yra įvairių matų, o vienas iš dažniausiai naudojamų – bendras klasifikavimo tikslumas (angl. *accuracy*). Tai santykis tarp teisingai klasifikuotų ir visų klasifikuojamų duomenų kiekių. Klasifikavimo tikslumui nustatyti naudojamas kryžminis

patikrinimas (angl. *cross-validation*), kurio metu visa klasifikuojamų duomenų imtis yra padalijama į k lygių dalių, paskui atliekamas klasifikatoriaus mokymas, naudojant $k - 1$ imties dalis, ir testavimas, naudojant likusią duomenų dalį. Testavimo metu duomenys, nenaudoti mokyti, pateikiami sukurtam klasifikatoriui. Nustatoma, kiek duomenų buvo teisingai klasifikuota, ir apskaičiuojamas klasifikavimo tikslumo matas. Procedūra kartojama k kartų, tokiu būdu užtikrinama, kad kiekviena iš k dalių yra panaudojama testuoti. Apskaičiuota gautų klasifikavimo matų vidutinė reikšmė parodo, kiek procentų vaizdų buvo priskirta tinkamai klasei (Tichonov, J.; Kurasova, O.; Filatovas, E., 2015).

1.2. Požymių išskyrimo iš vaizdo metodų problematika

Daugelis klasikinių kompiuterinės regos metodų analizuoja kiekvieną vaizdo elementą (piksely) ir greta esančių (kaimyninių) pikselių reikšmes. Kompiuterinės regos metodo įgyvendinimo metu kiekvienas pikselio įvertinimas užima nemažą dalį skaičiavimo resursų, todėl požymių išskyrimo įgyvendinimas turi didelės įtakos viso proceso efektyvumui. Požymių aptikimas (angl. *feature detection*) nurodo, koks turi būti aptinkamų požymių pobūdis, o požymių išskyrimas (angl. *feature extraction*) charakterizuoja jau aptiktus požymius, kurie vėliau naudojami objektui aptikti ir sutapdinti tarp vaizdų, todėl tai svarbūs tyrinėjami aspektai.

Papildytos realybės sistemų tikslas – pateikti virtualų turinį realybėje, vietose, kur yra sekami skirtingų dydžių ir formų objektai. Objektų sekimas šiuo metu intensyviai tyrinėjamas kompiuterinės regos (angl. *Computer Vision – CV*) srityje (Yilmaz, A.; Javed, O.; Shah, M., 2006). Algoritmų skaičiavimų greitis, reikalingas išgauti nekintamus požymius, yra viena iš pagrindinių sprendžiamų problemų kompiuterinės regos metodų pagrindu, kuri aktuali papildytos realybės sistemose (Lepetit, V., Vacchetti, L., Thalmann, D., Fua, P., 2003). Sekant mažus objektus galima pritaikyti esamus papildytos realybės kompiuterinės regos sekimo algoritmus, pavyzdžiui, *SIFT* (Vedaldi, A., 2006), *SURF* (Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V., 2008) arba *FAST* (Rosten, E.; Porter, R.; Drummond, T., 2010). Šiuo metu daugelis sukurtų sekimo metodų seka objektus, kurie telpa į kameros vaizdo matymo lauką įrenginių ekrane. Problemos sprendimas, kai matoma tik 10% viso objekto dydžio per mobiliojo įrenginio kamerą, pateiktas (Hwang, Jae-In; Sung, Min-Hyuk; Kim, Ig-Jae; Ahn, S. C.; Kim, Hyoung-Gon; Ko, H., 2013) darbe. Pasiūlytame sprendime sekamas objektas

dalinamas į kelias dalis, o tų dalių ištraukti požymiai įtraukiami į duomenų bazę. Sekamo objekto atpažinimas vykdomas lyginant kiekvienos vaizdo dalies požymius su požymių įvesties rinkiniu iš duomenų bazės, o suradus ieškomą dalį paskaičiuojama kameros pozicija ir orientacija. Objekto aptikimo laikas priklauso nuo dalių kiekio ir dydžio, o norint išvengti nesėkmingų atitikimų duomenų bazėje būtina turėti skirtingo dydžio sekamus objektus.

Šiuo metu tyrimuose (Wagner, D.; Reitmayr, G.; Mulloni, A.; Drummond, T.; Schmalstieg, D., 2010) naudojamų kompiuterinės regos metodų pagrindą sudaro modifikuoti šiuolaikiniai požymių deskriptoriai *SIFT* ir *Ferns* su vaizdo struktūros atitikimo sekimu. Nors *SIFT* metodas yra tikslus, tačiau požymių deskriptoriaus sudarymas reikalauja didelių skaičiavimo resursų, o *Ferns* (Bosch, A.; Zisserman, A.; Munoz, X., 2007) klasifikavimas yra greitas, tačiau jam reikia daug atminties, todėl virtualaus turinio atvaizdavimas sekamo objekto atžvilgiu netinkamas mobiliuosiuose įrenginiuose ir būtinas šių metodų modifikavimas, norint naudoti papildytos realybės sprendimuose realiu laiku.

MSER regionų detektorius (Natarajan, V., 2012) gali būti parinktas kaip pagrindas papildytos realybės sistemose, nes sekimas nenutrūksta esant įvairioms galimoms vaizdo transformacijoms, dideliame greičiui ir stabilumui. *MSER* naudoja sekamų objektų ploto informaciją, todėl tai nėra geras metodas norint sekti objektus tekstūros pagrindu ir nėra toks stabilus esant kompleksiškiems vaizdams.

Sekimo algoritmai gali būti skirstomi į generatyvinius (angl. *generative tracking*) (Natarajan, V., 2012) ir skiriamuosius (angl. *discriminative tracking*) (Ross, D. A.; Lim, J.; Lin, R.-S.; Yang, M.-H., 2008), (Grabner, H.; Leistner, C.; Bischof, H., 2008), (Babenko, B.; Yang, M.-H.; Belongie, S., 2011). Generatyviu sekimu ieškomas geriausio atitikimo rezultatas tam tikrame vaizdo regione. Pateikta daug sėkmingų abiejų kategorijų algoritmų, tačiau sudėtinga rasti algoritmą, kuris atliktų sekimo užduotį tiksliai ir efektyviai dėl objektų išorinių savybių pokyčių. Paimti du vienodi vaizdai su skirtingo apšvietimo sąlygomis negali būti unikaliai identifikuoti kaip tas pats objektas. Norint išspręsti šią problemą, buvo pasiūlyta įvairių metodų, kur vaizdo požymiai nekinta nuo apšvietimo. Sudarytas našus sekimo karkasas, kurio pagrindą sudaro vietos intensyvumo histogramos (Kwon, J.; Lee, K. M., 2009), (He, S.; Yang, Q.; Lau, R. W. H.; Wang, J.; Yang, M. H., 2013), norint vykdyti objekto atpažinimą ir sekimą. Vietos intensyvumo histogramos paskaičiuojamos kiekvienai pikselio vietai.

Šis sprendimas susideda iš 2 dalių: a) naujas sekimo požymis, kuris nepriklauso nuo apšvietimo pokyčių; b) naujas didelio kiekio regionų sekimo algoritmas realiu laiku. Atlikti išsamūs eksperimentai rodo, kad pasiūlytas objekto sekimas užtikrina efektyvų požymių sekimą, nepriklausomai nuo apšvietimo pokyčių, geriau nei daugelis šiuolaikinių algoritmų, tačiau apšvietimo sąlygos yra ne vienintelė aktuali kompiuterinės regos metoduose sprendžiama problema. Bendru atveju, svarbiausia tinkamai įvertinti sekamo objekto išorinių savybių pokyčius (Kalal, Z.; Mikolajczyk, K.; Matas, J., 2012), siekiant našaus objekto sekimo.

Norint užtikrinti nepertraukiamą virtualaus turinio atvaizdavimą papildytoje realybėje, atsiranda poreikis ieškoti efektyvesnių objekto sekimo metodų. Šiuo metu prieinami daug požymių aptikimo metodų (deskriptorių), tačiau pagrindinė problema, kurią reikia išspręsti, vaizdo požymių išskyrimas ir sutapdinimas realiu laiku (Rosten, E.; Drummond, T., 2006).

SLAM (angl. *Simultaneous Localization and Mapping*) metodas dažniausiai naudojamas autonominėse navigacijos sistemose, tačiau yra perspektyvus papildytos realybės sprendimuose (Kozlov, A., 2012). *SLAM* metode sudaromas nežinomos aplinkos žemėlapis bei lygiagrečiai nustatoma tiksli objekto pozicija ir orientacija aplinkoje (tiek patalpų viduje, tiek išorėje) (Eade, E.; Drummond, T., 2006). Nepaisant pastaruoju metu plėtoto vizualinio *SLAM* metodo, šiuo metu vis dar yra sudėtingai sprendžiamų problemų, norint sėkmingai panaudoti vaizdinio *SLAM* metodo realizavimą realiuose scenarijuose dėl požymių sutapdinimo tarp skirtingų vaizdų (Davison, A. J.; Cid, Y. G.; Kita, N., 2004), (Herath, D. C.; Kodagoda, S.; Dissanayake, G., 2006). *SLAM* metodą galima įgyvendinti įvairiais būdais, todėl tai yra labiau kaip koncepcija, o ne vientisas algoritmas. Panašiai, kaip iš kitų požymių išskyrimo iš vaizdo metodų atveju, pirminiame etape išgaunami požymiai, tie požymiai sutapdinami ir nuolat atnaujinami judant aplinkoje.


Papildytos realybės srityje šis metodas gali padėti užtikrinti mobiliųjų įrenginių (kamerų) vietos ir orientacijos nustatymą aplinkoje (Xu, K.; Chia, K. W.; Cheok, A. D., 2008). Atliekant požymių išgavimą iš vaizdų ir šių požymių sužymėjimą erdvėje galima bet kurioje realios aplinkos vietoje atvaizduoti virtualų turinį (Klein, G. and Murray, D., 2007). Vizualinis *SLAM* metodas leidžia sistemai su viena kamera sukurti vartotojo aplinkos modelį be jokios iš anksto žinomos informacijos (Reitmayr, G.; Eade, E.; Drummond, T. W., 2007). Sistemai veikiant susiduriama su lokalizacijos

netikslumais, todėl *SLAM* naudoja praplėstą Kalmano filtrą, dalelių filtrą (angl. *particle filters*) bei kitus optimizavimo metodus (Strasdata, H.; Montielb, J. M. M.; Davison, A. J., 2012), kurie pateikia padėties tikimybinus įverčius ir žemėlapių parametrus. Vizualinio *SLAM* metodo taikymas sekimo procese užtikrintų geresnį objekto sekimo metodą papildytos realybės sistemose, tačiau reiktų atsižvelgti į tai, kad vietos nustatymas ir žemėlapių sudarymas nežinomose aplinkose tampa sudėtingesnis aplinkai besiplečiant bei reikalauja didesnių techninės įrangos resursų, o tai gali ne visuomet tikti mobiliams įrenginiams.

Tinkamas požymių išskyrimo metodo iš vaizdo parinkimas labai svarbus papildytos realybės srityje ir priklauso nuo konkretaus sekamo objekto vaizde. Papildytos realybės sistemose galima išskirti kelias svarbias užduotis:

- a) objekto aptikimą ir sekimą;
- b) virtualaus turinio atvaizdavimą priklausomai nuo sekamo objekto pozicijos ir orientacijos;
- c) sąveikos užtikrinimą su virtualiu turiniu.


Principinis papildytos realybės sistemos įgyvendinimas pateiktas 4 pav.



4 pav. Papildytos realybės sistemos įgyvendinimas

Daugelis papildytos realybės sprendimų įgyvendinami pradedant analizuoti realią naudotoją supančią aplinką, kurioje siekiama aptikti ir sekti konkretų objektą. Toliau sekamo objekto atžvilgiu atvaizduojamas turinys (3D modeliai, vaizdo medžiaga, tekstas, paveikslai) ir juo galima sąveikauti.

Papildytos realybės sprendimai, kuriuose naudojami žymekliai, turi būti visiško matomumo zonoje. Dalinio žymeklio uždengimo atveju virtualus turinys gali dingti, 5 pav.



5 pav. Papildytos realybės pavyzdys naudojant *NyARToolkit*: a) atvaizduotas virtualus turinys ant žymeklio; b) neatvaizduotas virtualus turinys dėl kliūtis ant žymeklio

Nutrūkstamo virtualaus turinio atvaizdavimo problema, kai sekamas objektas uždengiamas, nėra išspręsta net gerai žinomose papildytos realybės priemonėse (Wagner, D. and Schmatstieg, D., Feb. 2007). Dėl pastarosios priežasties šiame darbe skiriamas dėmesys tirti požymių išskyrimo ir apdorojimo metodus, kurie gali išspręsti dalinės okliuzijos problemą:

- 1) Požymių išskyrimo metodas *FAST* (angl. *Feature from Accelerated Segment Test*).
- 2) Požymių išskyrimo metodas *SIFT* (angl. *Scale Invariant Feature Transform*).
- 3) Požymių išskyrimo metodas *SURF* (angl. *Speeded Up Robust Features*).

Naudojant požymių išskyrimo metodus *FAST*, *SIFT* ir *SURF* galima atpažinti tekstūros pagrindu sudėtingesnius objektus nei žymekliai ir išspręsti dalinių okliuzijų problemą, analizuojant tekstūros pagrindu esančius objektus vaizduose, taip užtikrinant nenutrūkstamą virtualaus turinio pateikimą. Požymių išskyrimo metodų našumo įvertinimas greičio atžvilgiu taip pat svarbus kriterijus, nes papildytos realybės srityje visos užduotys turi būti vykdomos realiu laiku.

Šiuo metu papildytos realybės srityje vienas iš svarbiausių kompiuterinės regos uždavinių – požymių išskyrimas bei apdorojimas. Kompiuterinės regos metodai (Rosten, E.; Porter, R.; Drummond, T., 2010), (Lowe, D. G., 2004), (Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V., 2008) naudoja požymių aptikimo ir aprašymo metodus, norint rasti kampus ir atlikti tokias užduotis kaip: vaizdo išgavimą, objektų atpažinimą, sekimą, atitikimą judant (angl. *match moving*), 3D modelio atvaizdavimą ir pan. Aptikti požymiai nėra pastovūs ir priklauso nuo vaizdo dydžio, pakreipimo, postūmio, apšvietimo lygio ir kameros peržiūros vietos (Khan, N. Y.; McCane, B. and Wyvill, G., 2011), norint užtikrinti patikimą objektų aptikimą ir atitikimą tarp to paties vaizdo

skirtingų peržiūros vietų. Požymių aptikimas ir sutapdinimas taip pat priklauso nuo kitų sąlygų. Pavyzdžiui, didinant vaizdo suspaudimą, svarbių požymių aptikimo kokybė ir kiekis mažėja (Wyss, M. L., 2011), (Khan, N. Y.; McCane, B. and Wyvill, G., 2011). Suspaudimo būtinybė atsiranda tuomet, kai reikia perduoti ribotą duomenų kiekį toliau apdoroti vaizdus mobiliuosiuose įrenginiuose (Chandrasekhar, V.; Takacs, G.; Chen, D.; et al., 2009).

Užduotis, susijusi su požymių išskyrimu iš vaizdo ir apdorojimo metodais, rekonstruoja ir interpretuoja trimačio vaizdo požymius tik iš dvimatės projekcijos. Algoritmo požiūriu šias užduotis galima suskirstyti į du etapus:

- 1) pagrindinių požymių iš vaizdo ištraukimas (angl. *acquisition*), pavyzdžiui, kampų, briaunų ar kontūrų;
- 2) objekto požymių atpažinimas (angl. *recognition*), sutapdinimas (angl. *matching*) ir sekimas (angl. *tracking*).

Norint patikimiau aptikti ir sutapdinti vaizdo požymius, būtinos šios pagrindinės skiriamosios charakteristikos:

- išskirtinumas (angl. *distinctness*) – požymis, kuris visiškai išsiskiria iš fono;
- pastovumas (angl. *invariant*) – nekintantis požymis geometriniais trikdžiams;
- suvokimas (angl. *interpretability*) – požymis, kuris padeda interpretuoti susijusias reikšmes;
- stabilumas (angl. *stability*) – požymis, kuris atsparus trikdžiams;
- unikalumas (angl. *uniqueness*) – požymis, kuris išsiskiria iš kitų taškų.

Požymių aptikimo kokybė priklauso nuo vaizdo turinio, apšviestumo, apšviestumo tolygumo ir kitų priežasčių. Išskyrus iš vaizdo požymius, galima sumažinti apdorojamų duomenų kiekį, išsaugant pagrindines objekto savybes, atskirų objektų dydį ir vietą. Trijų požymių išskyrimo metodų *SIFT*, *SURF* ir *FAST* parinkimas atliktas atsižvelgiant į toliau pateiktus kriterijus:

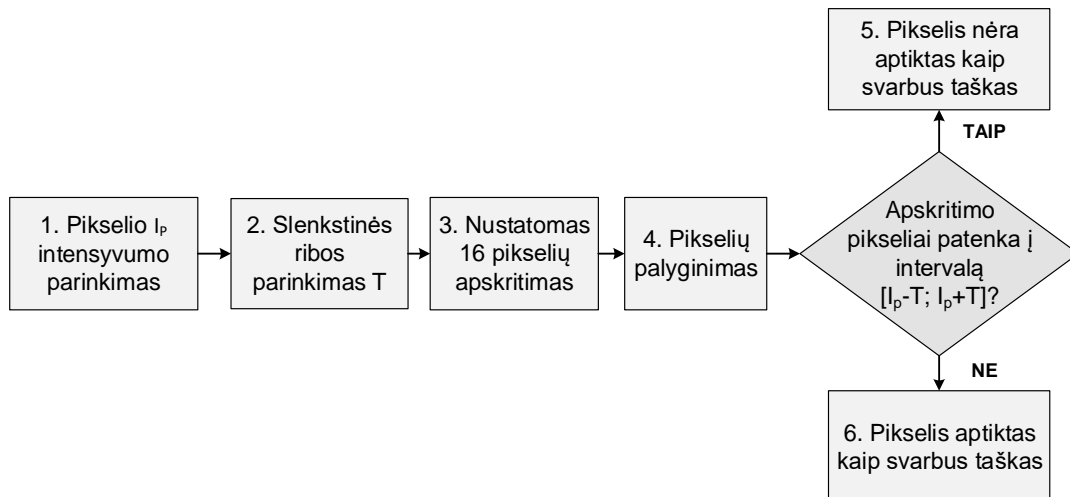
- 1) taikymo sritis ir jos reikalavimai;
- 2) sekamo objekto savybės, nuo kurių priklauso požymių prieinamumas;
- 3) objekto sekimo tikslumas atsižvelgiant į aplinkos sąlygas.

Kai kurie požymių ištraukimo iš vaizdo metodai dažniausiai veikia gerai sprendžiant tik vieną iš toliau išvardytų užduočių: vaizdų sutapdinimas ir objekto sekimas, esant skirtingam objekto dydžiui, okliuzijoms, skirtingų vaizdų orientacijoms, tekstūros arba briaunų pagrindu objektams, objekto ribų nustatymui kompleksiskame

fone bei apšvietimui. Dėl šios priežasties analizuoti metodų efektyvumą parinkti galimai universalūs *SIFT*, *SURF* ir *FAST* metodai, kurie sprendžia visas įvardytas problemas kompleksiskai. Analizuojant kiekvieną metodą parinkti greičio ir atkartojimo kriterijai, esant įvairių tipų vaizdo transformacijoms. Tyrimu bus įvertintas algoritmų veikimas skirtingomis aplinkos sąlygomis.

1.2.1. Požymių išskyrimo metodas *FAST*


FAST metodas (Rosten, E.; Porter, R.; Drummond, T., 2010) skirtas užtikrinti greitą kampų išskyrimą iš vaizdo. Dėl kampų aptikimo savybių metodas taikomas sutapdinant vaizdus, atpažįstant bei lokalizuojant objektus. Egzistuoja keletas nusistovėjusių kampų aptikimo algoritmų: *Moravec* (Moravec, H., 1980), *Harris & Stephens* (Harris, C.; Stephens, M., 1988), *SUSAN* (Smith, S. M.; Brady, J. M., 1997) ir pan. Šie metodai aptinka kokybiškus požymius, tačiau reikalauja intensyvių skaičiavimų ir nėra tinkami realaus laiko taikymo srityse. Pagrindinė *FAST* algoritmo pasirinkimo priežastis – greitas kampų aptikimas ir panaudojimas užduotims atlikti realiu laiku. Pavyzdžiui, požymių lokalizavimas ir žymėjimas naudojant *SLAM* metodą (angl. *Simultaneous Localization and Mapping*), kurio taikymas suteikia galimybę sukurti bežymeklį papildytos realybės sprendimą (Klein, G. and Murray, D., 2007). *FAST* algoritmo veikimo principas kampams aptikti pateiktas 6 pav.



6 pav. *FAST* algoritmo veikimo principas aptikti kampus

FAST algoritmo pirmajame etape daroma prielaida, kad pikselio intensyvumas turi būti I_p norint identifikuoti pikselį p kaip svarbų kampą (požymį). Tolesniame algoritmo etape parenkama p pikselio intensyvumo slenkstinė riba T . Šis potencialus

kampas (p pikselis) lyginamas su greta esančiais 16 pikselių, kurie išdėstyti apskritimu, 7 pav.



7 pav. Pikselio analizė potencialiam kampui aptikti vaizdo fragmente. Pažymėti balti kvadratai yra pikseliai naudojami kampui aptikti. Pikselis p centre yra tikrinamas, o lankas nurodo, kad eina per 12 besiribojančių pikselių, kurie yra ryškesni nei p (Rosten, E.; Drummond, T., 2006)

Norint užtikrinti našesnį algoritmo veikimą iš pradžių tikrinami keturių pikselių intensyvumai I_1 , I_5 , I_9 ir I_{13} , kurie išdėstyti apskritimu keturiomis skirtingomis kryptimis. Šiame tikrinimo etape, jeigu p yra kampas, bent 3 iš 4 pikselių turi būti ryškesni nei $I_p + T$ arba tamsesni nei $I_p - T$. Jeigu bent viena iš dviejų sąlygų netenkinamos, tuomet pikselis p negali būti kampas. Po šių pirminių pikselių analizės, tenkinant sąlygas, atliekamas pilnas visų likusių pikselių, kurie išdėstyti apskritimu, tikrinimas.

Pikselis p klasifikuojamas kaip kampas (požymis), jeigu egzistuoja n besiribojančių pikselių apskritime, kurie yra ryškesni nei potencialaus pikselio intensyvumas I_p su slenkstine riba T arba visi tamsesni nei $I_p - T$, kaip pateikta 7 pav. Pirminiame algoritmo variante pasirenkama $n = 12$ ir tikrinama, ar iš 16 pikselių n atitinka nustatytą kriterijų. Nustatytas 12 pikselių tikrinimas garantuoja didelį greitį ir atmetamas didelis kiekis netinkamų potencialių požymių. Toks pikselių aptikimo santykis yra labai aukštas, o 16 pikselių lyginimo užklausa turi įtakos algoritmo vykdymo greičiui. Taip pat algoritmo greitis priklauso nuo parinktos slenkstinės ribos T : kuo slenkstinė riba didesnė, tuo mažiau požymių aptinkama ir tuo aptikimo greitis didesnis.

Algoritmas pasižymi dideliu našumu, tačiau yra keli trūkumai:

1. Algoritmas neveikia patikimai, kai $n < 12$.
2. Pikselių pasirinkimas ir pasiskirstymas turi numanomas prielaidas apie požymių atsiradimo pasiskirstymą.
3. Atmetamos žinios iš pirmų keturių patikrintų pikselių.
4. Aptinkami keli požymiai arti vienas kito.

Norint sudaryti kampų aptikimo detektorių duotam n kiekiui, pirmiausia kampai aptinkami iš aibės vaizdų, susijusių su konkrečia taikymo sritimi, naudojant pilną n pikselių tikrinimą (iš 16) su slenkstine riba. Kiekviena vieta apskritime gali būti priskirta $x \in \{1..16\}$, čia pikselis tam tikroje santykinėje padėtyje p (žymimas $p \rightarrow x$) gali būti trijų būsenų (6):

$$S_{p \rightarrow x} = \begin{cases} d, & I_{p \rightarrow x} \leq I_p - t & (\text{tamsesni}) \\ s, & I_p - t < I_{p \rightarrow x} < I_p + t & (\text{panašūs}) \\ b, & I_p + t \leq I_{p \rightarrow x} & (\text{ryškesni}) \end{cases} \quad (6)$$

Pasirenkant x ir skaičiuojant $S_{p \rightarrow x}$ visiems $p \in P$ (aibė visų pikselių visuose mokymo vaizduose). P skirstomas į 3 poaibius: P_d, P_s, P_b , kur kiekvienas p priskiriamas $P_{S_{p \rightarrow x}}$.

Imkim, kad K_p yra loginio tipo kintamasis, kuris yra *true* (tiesa), jeigu p yra kampas ir *false* (melas) kitu atveju. Antrasis algoritmo etapas apima x parinkimą, kuris turi daugiausia informacijos ar tikrinamas pikselis yra kampas ir paskaičiuojamas entropija $H(P)$ (Rosten, E.; Drummond, T., 2006) (7):

$$H(P) = (c + \bar{c}) \log_2(c + \bar{c}) - c \log_2 c - \bar{c} \log_2 \bar{c}, \quad (7)$$

čia $c = |\{p | K_p \text{ yra true}\}|$ yra kampų kiekis, o $\bar{c} = |\{p | K_p \text{ yra false}\}|$ ne kampų kiekis.

Parinktas x , kuris turi daugiausia informacijos, procesas taikomas rekursyviai visiems triems poaibiams, t. y. x_b parenkamas poaibiui P_b , o šis dar $P_{b,d}, P_{b,s}, P_{b,b}$ poaibiams, x_s parenkamas poaibiui P_s , pastarasis dar į $P_{s,d}, P_{s,s}, P_{s,b}$ ir t. t., kur kiekvienas parinktas x turi daugiausia informacijos apie aibę, kuriai jis priskiriamas. Procesas stabdomas, kai entropijos poaibis yra 0. Tai rodo, kad visi p tame poaibyje turi tą pačią K_p reikšmę, t. y. jie visi arba yra kampai, arba nėra kampai.

Toks būdas sukuria sprendimų medį, teisingai klasifikuojantį visus aptiktus kampus mokymosi aibėje, todėl teisingai įgyvendina taisyklės parinktam FAST kampų

aptikimo algoritmui. Šis sprendimų medis toliau konvertuojamas į C-kodą, sukuriant ilgą *if-else* sąlygos sakinių seką, kuri naudojama kampams aptikti.

Naudojant FAST algoritmą galima aptikti daugiau nei vieną kampą greta esančiuose pikseliuose. Norint sumažinti ši aptiktų kampų kiekį, skaičiuojama nemaksimalaus slopinimo (angl. *Non-Maximal Suppression*) funkcija V (8):

$$V = \max \left(\sum_{x \in S_{bright}} |I_{p \rightarrow x} - I_p| - T, \sum_{x \in S_{dark}} |I_p - I_{p \rightarrow x}| - T \right), \quad (8)$$

čia $S_{bright} = \{x | I_{p \rightarrow x} \geq I_p + T\}$, $S_{dark} = \{x | I_p - I_{p \rightarrow x} \geq T\}$, I_p – tikrinamas pikselis, esantis centre su greta esančiais pikseliais $I_{p \rightarrow x}$ iš apskritimo. Funkcija V skaičiuojama kiekvienam aptiktam kampui ir nemaksimalaus slopinimo funkcija taikoma norint pašalinti kampus, kurių gretimas kampas yra didesnės paskaičiuotos funkcijos V vertės (Rosten, E.; Drummond, T., 2006).

Požymių aptikimo stabilumą (Trajkovic, M., Hedley, M., 1998) nusako santykis tarp surastų atitikmenų kiekio tarp skirtingų vaizdų ir iš viso vaizde surastų požymių (kampų) kiekio pradiname vaizde. Stabilumo įvertinimas šiuo atveju priklauso tiek nuo sekimo, tiek atitikmens metodų naudojimo.

Įvertinant patikimumą labai svarbu, ar tie patys realaus vaizdo požymiai aptinkami iš kelių skirtingų vaizdo peržiūros vietų. Pavyzdžiui, dviejuose skirtinguose vaizduose požymis laikomas *aptiktu*, jeigu išskirtas požymis viename vaizde taip pat randamas ir kitame. Šis požymis taip pat yra *atkartojamas*, jeigu jis yra rastas arti pradinės vietos kitame vaizde. *Atkartojimas* yra santykis požymių atitikmenų tarp dviejų vaizdų ir aptiktų požymių dviejuose vaizduose vidurkio. Šis atkartojimo kriterijus apima tiek stabilumo, tiek patikimumo sąvokas – tai ir bus skaičiuojama tolesnių skyrių pateiktuose eksperimentuose.

1.2.2. Požymių išskyrimo metodas *SIFT*

Vaizdo atitikimas yra pagrindinis kompiuterinės regos nagrinėjamų problemų aspektas, įskaitant objekto atpažinimą bei judėjimo sekimą. Vaizdo požymiai turi daug savybių, kurios gali atitikti tarp skirtingų objekto vaizdų. Šie požymiai yra nepriklausomi nuo vaizdo dydžio ar pakreipimo, taip pat iš dalies nekinta esant skirtingoms apšvietimo sąlygoms. Jie yra gerai lokalizuoti tiek erdvės, tiek dažnių srityse, sumažinant tikimybę įvykti sutrikimams dėl okliuzijų ar triukšmo. Gali būti

surastas didelis kiekis skiriamųjų požymių, kurie leidžia rasti teisingus atitikmenis didesne tikimybe.

SIFT metodo pasirinkimą lėmė didelis aptinkamų požymių kiekis. *SIFT* požymių išskyrimo metodas leidžia nustatyti skiriamuosius stabilius požymius, kurie nepriklauso nuo vaizdo dydžio, pakreipimo, postūmio, ir šis metodas naudojamas atliekant patikimą atitikimą tarp skirtingų vaizdų peržiūrų, siekiant atpažinti objektą vaizde. Pagal (Lowe, D. G., 2004) darbą *SIFT* požymių išskyrimo iš vaizdo ir apdorojimo metodo įgyvendinimas susideda iš keturių pagrindinių etapų:

1. Dydžio-erdvės ekstremumo radimas (angl. *Scale-space extrema detection*).
2. Požymių vietos radimas (angl. *Keypoint localization*).
3. Požymių orientacijos skaičiavimas ir priskyrimas (angl. *Orientation assignment*).
4. Požymių deskriptoriaus išskyrimas (angl. *Keypoint descriptor extraction*).

Pirmame etape skaičiavimai atliekami su skirtingų dydžių vaizdais skirtingose vietose. Dydžio-erdvės ekstremumo radimas naudojamas nustatyti potencialius informatyvius požymius, kurie vaizde būtų stabilūs, nepriklausomi nuo sekamo objekto dydžio ar orientacijos. Šiame etape sudaroma Laplaso piramidė ir skaičiuojama Gauso skirtuminė funkcija (angl. *Difference-of-Gaussian*), naudojant (9) išraišką:

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) = L(x, y, k\sigma) - L(x, y, \sigma), \quad (9)$$


čia $G(x, y, \sigma)$ yra Gauso funkcija; k – koeficientas; $I(x, y)$ – įvesties vaizdas; $*$ – konvoliucijos (angl. *convolution*) procesas. Gauso funkcija išreiškiama (10) formule:

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2}. \quad (10)$$

Gauso skirtuminė funkcija naudojama nustatyti stabilias požymių vietas dydžio-erdvės funkcijoje $L(x, y, \sigma)$ bei skaičiavimo spartai padidinti. $L(x, y, \sigma)$ dar išreiškiamas (11):

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y). \quad (11)$$

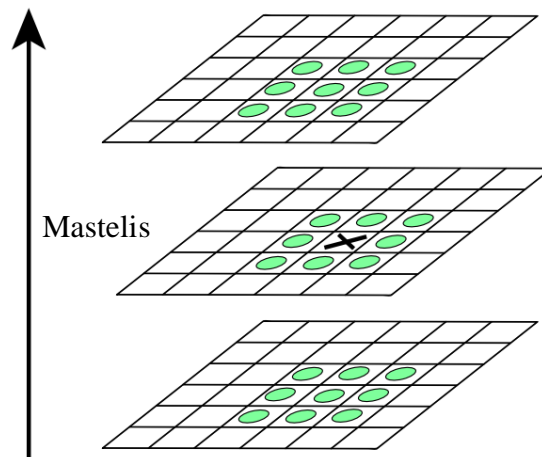
Ši funkcija efektyvi norint paskaičiuoti skirtingų dydžių požymių deskriptorius, todėl D gali būti paskaičiuotas pagal paprastą vaizdų skirtumą. Gauso skirtuminės funkcijos $D(x, y, \sigma)$ taikymas pateiktas 8 pav.



8 pav. Skirtuminės Gauso funkcijos taikymas (Lowe, D. G., 2004)

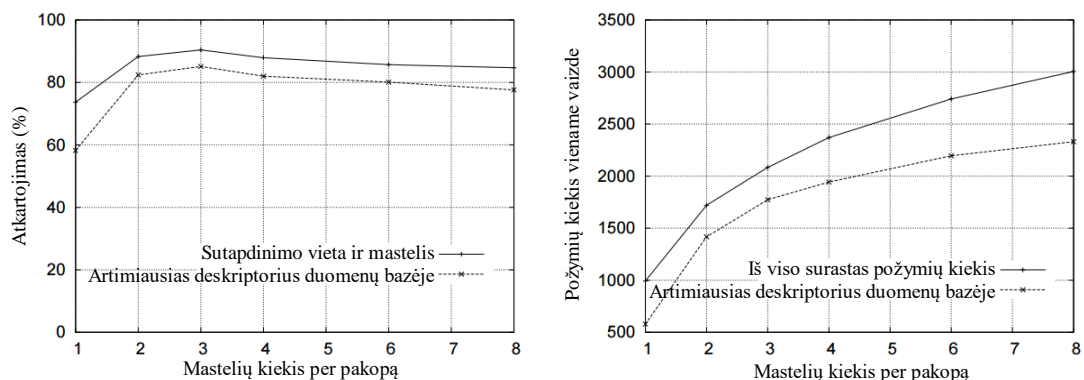
Kiekvienai dydžio-erdvės oktavai pradiniam vaizdui yra pakartotinai taikomas konvoliucijos procesas naudojant Gauso funkciją, norint gauti aibę dydžio-erdvės vaizdų (kairėje pusėje). Skaičiuojamas panašaus dydžio vaizdų skirtumas, norint gauti Gauso skirtumą (dešinėje pusėje). Po kiekvienos dydžio-erdvės oktavos Gauso vaizdas yra sumažinamas daugikliu $k = 2$, kai kas antras pikselis iš kiekvienos eilutės ir stulpelio pašalinamas, ir procesas kartojamas. Laplaso pakopų formavimas yra pasikartojantis vaizdo vienodinimo procesas. Naudojant Gauso skirtuminę funkciją galima pasiekti aukštesnes pakopas.

Antrame požymių vietos radimo **etape** žemo kontrasto ir netinkamai aptikti požymiai atmetami pagal nustatytą slenkstinę ribą. Norint aptikti $D(x, y, \sigma)$ vietinį maksimumą ar minimumą, kiekvienas taškas lyginamas su 8 gretimais taškais esamame vaizde ir 9 gretimais pikseliais tiek didesniame, tiek mažesniame vaizde už pradinį vaizdą, 9 pav.



9 pav. Ekstremumų radimas (Lowe, D. G., 2004)

Vaizdų Gauso skirtumo funkcijos maksimumas ir minimumas randamas, lyginant pikselį (pažymėtas „X“) su gretimais 26 pikseliais 3×3 regionuose esamame ir gretimuose vaizdų dydžiuose (šie pikseliai pažymėti apskritimu). Svarbi sprendžiama problema yra nustatyti $D(x, y, \sigma)$ dažnumą vaizde ir dydžių sritis, kurios būtinos norint patikimai aptikti ekstremumus. Eksperimentiškai nustatyta, kad didėjant požymių kiekiui didinamas ekstremumų radimo stabilumas, 10 pav.



10 pav. Aptikti atkartojami požymiai: a) viršutinė linija rodo požymių atkartojimą, aptiktą toje pačioje vietoje transformuotame vaizde; b) apatinė linija rodo požymius, kurie turi savo deskriptorius, buvo teisingai sugretinti su požymiais iš didelės duomenų bazės; c) dešinioji diagrama rodo, kiek iš viso požymių buvo aptikta vaizduose (Lowe, D. G., 2004)

Atlikti eksperimentai susiję su sugretinimo užduotimi, naudojant 32 skirtingų scenarijų vaizdus. Kiekvienas vaizdas buvo paveiktas transformacijų, įskaitant pakreipimą, dydžio keitimą, ryškumo pokyčius, kontrastą ir pridėjus vaizdui triukšmą. Dėl šių dirbtinių pakeitimų įmanoma tiksliai prognozuoti, kur kiekvieno požymio padėtis pradiniam vaizde turi atsirasti transformuotuose vaizduose, o tai leidžia pamatuoti teisingą atkartojimą ir padėtis tikslumą kiekvienam požymiui. Nustatyta, kad vaizdo sritis neturi įtakos rezultatams.


Trečiame etape kiekvienam požymiui priskiriama nuosekli orientacija. Atsižvelgiant į vaizdo savybes požymio deskriptorius gali būti išreikštas santykinai pagal vaizdo orientaciją, todėl galima pasiekti nekintamumą vaizdo pakreipimams. Kiekvienam vaizdai orientacijos histograma paskaičiuojama pagal (12 ir 13) išraiškas:

$$m(x, y) = \sqrt{(L(x + 1, y) - L(x - 1, y))^2 + (L(x, y + 1) - L(x, y - 1))^2}, \quad (12)$$

$$\theta(x, y) = \tan^{-1} \frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)}, \quad (13)$$

čia $m(x, y)$ – gradiento dydis, $L(x, y)$ – tam tikro mastelio vaizdas, o $\theta(x, y)$ – paskaičiuota orientacija naudojant pikselių skirtumą. Norint užtikrinti aptinkamų požymių stabilumą, nepriklausomai nuo sekamo objekto pakreipimo, paskaičiuojami kiekvieno požymio vietos gradiento histogramos kryptis ir dydis (angl. *octave*). Svarbiausiam taškui paskiriama geriausia regione aptikta orientacija, kuri suskirstyta į 36 dalis po 10 laipsnių.

Ketvirtame etape kiekvienam požymiui paskaičiuojamas unikalus deskriptorius. Pagal paskaičiuotą orientacijos histogramos maksimumą formuojamas požymio deskriptorius, turintis tą orientaciją. Sudarant požymio deskriptorių iš pradžių paskaičiuojami vaizdo gradiento dydžiai ir orientacijos aplink požymio vietą. Požymio deskriptoriaus sudarymo principas pateiktas 11 pav.



11 pav. Požymio deskriptoriaus sudarymas (Lowe, D. G., 2004)

Požymių deskriptorius sudaromas paskaičiuojant 4×4 gradientų histogramų dydžius regionuose ir aprašomas aštuonių orientacijų reikšmėmis. Deskriptoriaus vektoriumi yra aprašoma požymio kryptis, dydis ir gradientas. Deskriptoriaus vektorius aprašo objekto vietinį požymį, bet ne visą vaizdo objektą. Todėl, norint išsamiai aprašyti ieškomą objektą, reikia surasti visus objekto informatyviuosius vietinius požymius. Požymiai yra pastovūs ir nepriklausomi nuo vaizdo transformacijų. Kiekvienas deskriptorius yra vektorius, aprašantis specifines vaizdo vietas.

Paskaičiavus dviejų vaizdų I_1 ir I_2 deskriptorius, atliekamas požymių sugretinimo įvertinimas, kuriame atmetami neapibrėžti požymiai.

Svarbus *SIFT* metodo aspektas yra tas, kad generuojamas didelis kiekis požymių, kurie tankiai apdengia skirtingo dydžio vaizdus. Požymių kiekis yra svarbus norint atpažinti nedidelius objektus aplinkoje. Atpažįstant ir atitinkant vaizdą, *SIFT* požymiai yra išskiriami iš aibės pradinių vaizdų ir įtraukiami į duomenų bazę. Kiekvieno naujo vaizdo atitikmuo randamas individualiai, lyginant kiekvieną požymį iš naujo vaizdo su požymiais, esamais duomenų bazėje, ir randant potencialus požymių atitikmenis pagal požymių vektorių Euklido atstumo skaičiavimą. Detalesnis *SIFT* metodo įgyvendinimas analizuojamas (Lowe, D. G., 2004), (Vedaldi, A., 2006) ir (Nam, J. E.; Maurer, M. and Mueller, K., 2009) darbuose.

1.2.3. Požymių išskyrimo metodas *SURF*


SURF požymių išskyrimo metodas naudojamas pastoviams požymiams aptikti ir juos aprašyti, esant skirtingo mastelio ir pakreipimo vaizdams (Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V., 2008). *SURF* naudojamas objektams atpažinti (angl. *recognition*), sekti (angl. *tracking*), sutapdinti (angl. *matching*) (Pimenov, V., 2009), trimatės rekonstrukcijos uždaviniuose ir norint nustatyti vaizdų klastotės atvejus (Shivakumar, B. L. and Santhosh Baboo, Lt. Dr. S., 2011). *SURF* panašus į kitus požymių išskyrimo algoritmus, tačiau *SURF* deskriptorius gali būti daug greičiau apskaičiuotas ir palygintas. *SURF* naudoja tarpinį vaizdo pateikimą, vadinamą integraliniu vaizdu (angl. *integral image*), kuris paskaičiuojamas iš vaizdo įvesties, norint pagreitinti skaičiavimus stačiakampio srityje. *SURF* detektorius vaizde aptinka požymius, naudodamas Hesiano (angl. *Hessian*) matricas (14):

$$H(x, \sigma) = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix}, \quad (14)$$

čia $H(x, \sigma)$ – Hesiano matrica, apibrėžiama duotame taške $x = (x, y)$; $L_{xx}(x, \sigma)$ – Gauso antros eilės išvestinė su vaizdu I taške x ; atitinkamai – $L_{xy}(x, \sigma)$ ir $L_{yy}(x, \sigma)$ atvejais. Gauso antros eilės išvestinės skaičiuojamos (15):

$$L_{xx}(x, \sigma) = \left(\frac{x^2}{\sigma^4} + \frac{1}{\sigma^2} \right) e^{-\frac{x^2}{2\sigma^2}}. \quad (15)$$

Antros eilės Gauso išvestinių aproksimacijos gali būti įvertinamos labai greitai, naudojant integralinius vaizdus, nepriklausomai nuo jų dydžių. Toliau pateiktame 12 paveiksle 9×9 dėžučių filtrai yra Gauso antros eilės išvestinių aproksimacijos su nuokrypiu $\sigma = 1.2$ ir išreiškia mažiausią dydį (aukščiausią erdvinę rezoliuciją).



12 pav. Gauso antros eilės dalinės išvestinės y ir xy kryptimis bei aproksimacijos, naudojant dėžučių filtrus. Pilki regionai prilyginami nuliui (Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V., 2008)

Hesiano matricos determinantas skaičiuojamas kiekvienam vaizdo pikseliui, kurių reikšmės naudojamos norint nustatyti požymius ir jų tikslumą (16):

$$\det(H_{approx}) = D_{xx}D_{yy} - (0.9D_{xy})^2, \quad (16)$$

čia D_{xx} , D_{yy} , D_{xy} – aproksimacijų žymėjimas, kurios paskaičiuojamos naudojant (10) išraišką. Šios aproksimacijos taikomos stačiakampiems regionams dėl skaičiavimo efektyvumo. Siekiant požymius padaryti kuo atsparesnius objekto dydžių pokyčiams, Hesiano matricos determinantas yra skaičiuojamas aštuonių dydžių lygiuose. Tarp trijų gretimų lygių ieškoma lokalių ekstremumų – tai determinanto vertės, kurios didesnės už kaimyninius taškus. Informatyviausiems požymiams išskirti ekstremumai filtruojami pagal slenkstį.

Požymių nekintamumui orientacijos atžvilgiu nustatyti apskaičiuojamas *Haar* bangų atsakas (angl. *Haar wavelet response*) x ir y kryptimis (13 pav.) aplink požymių spinduliu $6s$, kur s – dydžio pakopa, kuriame aptiktas požymis.




13 pav. *Haar* bangų tipai naudojami *SURF* požymių išskyrimo metode (Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V., 2008)

Haar bangos naudojamos orientaciją priskirti požymiui prieš suformuojant požymio deskriptorių. Tokiu būdu SURF metode sukonstruojamas apskritimo regionas apie aptiktą požymį, o tuomet konstruojamas deskriptorius pagal regionus aplink požymį. Kiekvienam požymiui skaičiuojami posūkio kampai ir deskriptoriai. *SURF* deskriptorius aprašo, kaip pikselių intensyvumas yra pasiskirstęs nuo šalia esančio kiekvieno požymio. Objekto aptikimas naudojant *SURF* sąlyginai yra nepriklausomas nuo vaizdo orientacijos ir dydžio bei nereikalauja ilgos sekamo vaizdo mokymo trukmės. Šis aspektas bei skirtingų vaizdo transformacijų sutapdinimas yra svarbus tiek papildytos realybės, tiek robotikos srityse, kai objektas, kuris turi būti atpažintas, gali būti skirtingos orientacijos nei mokymo vaizdas.

1.3. Požymių išskyrimo metodų *FAST*, *SURF* ir *SIFT* greitaveikos palyginimas

Vaizdo požymių išskyrimo metodų tyrimui buvo atlikti eksperimentai naudojant *MathWorks MATLAB* programinę įrangą, kuri gali būti taikoma spręsti įvairių sričių problemas: kompiuterinės regos, komunikacijų, signalų, valdymo sistemų, duomenų analizės, modeliavimo, algoritmų kūrimo ir t. t. Toliau eksperimentai atlikti naudojant *AMD Phenom 9950 Quad-Core 2.6 GHz* procesorių, *ATI Radeon™ HD 4870 GPU* ir *4 GB* atminties su *Windows 7 × 64bit OS*. Tolesniuose eksperimentuose mastelio, pasukimo ir postūmio transformacijos buvo atliekamos naudojant šį pradinį vaizdą, 14 pav.

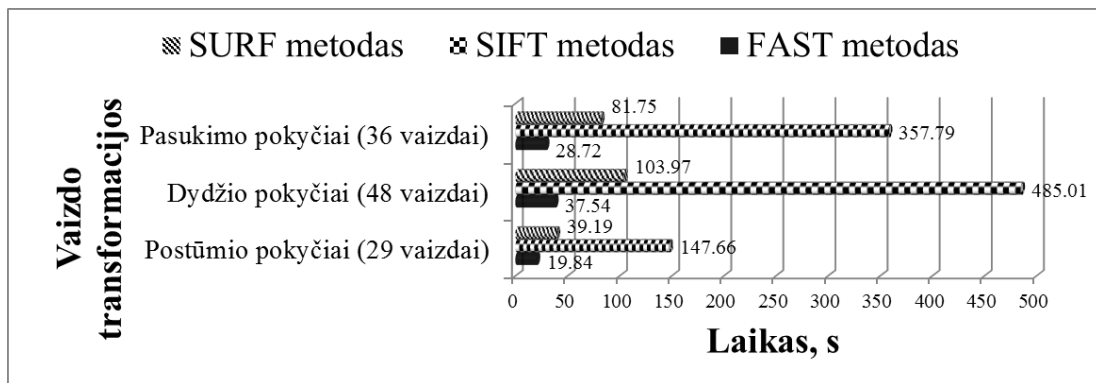


14 pav. Eksperimentams naudotas vaizdas

Pradiniam vaizdui 48 kartus atliktos mastelio keitimo operacijos. Nuo pradinio vaizdo mastelio, kuris atitinka 100% (349×300 rezoliucija) buvo didinamas iki


200% ir mažinamas iki 8% (4% žingsniu). Vaizdo pasukimo operacijos buvo vykdomos kas 10 laipsnių 36 kartus ir vaizdo postūmio operacijos (10, 10) (*ilgis* × *plotis*) pikselių *x* ir *y* ašių atžvilgiu – 29 kartus. Tollesniuose tyrimuose įvertintas požymių išskyrimo metodų *FAST*, *SURF* ir *SIFT* našumas. Atlikti eksperimentai greitaveikos ir atkartojimo kriterijų atžvilgiu, naudojant to paties vaizdo skirtingas transformacijas.

Požymių išskyrimo metodų greitaveika labai svarbi realaus laiko papildytos realybės realizacijose. Greitaveikos rezultatams įtaką daro daug kriterijų: vaizdo mastelis, vaizdo kokybė bei algoritmo parametrai, pavyzdžiui, nustatytos slenkstinės ribos. *FAST*, *SURF* ir *SIFT* požymių išskyrimo metodų greitaveikos eksperimentai mastelio, pasukimo ir postūmio pokyčiais pateikti 15 pav.



15 pav. *FAST*, *SIFT* ir *SURF* požymių išskyrimo metodų greitaveikos palyginimas

Rezultatai rodo, kad vienas iš *SIFT* metodo trūkumų, lyginant su *SURF* ir *FAST* metodais, yra lėtas požymių išskyrimas. *SIFT* metodo taikymas papildytos realybės sistemose gali būti sudėtingas, nes požymių išskyrimas bei sutapdinimas ir virtualaus turinio atvaizdavimas turi vykti realiu laiku. Požymių išskyrimas iš vaizdo ir vaizdų sutapdinimas *FAST*, *SIFT* ir *SURF* metodų atvejais pateiktas 16 pav.



16 pav. Vidutinis požymių sutapdinimas naudojant *FAST*, *SIFT* ir *SURF* požymių išskyrimo metodus

Požymiai iš mokymo vaizdo išgaunami vieną kartą, jie toliau lyginami su užklausiama vaizdo požymiais norint rasti atitikmenis. *SIFT* metodo atveju užklauso vaizdo ir mokymo vaizdo požymių sutapdinimas vidutiniškai trunka 8.39 s, *SURF* – 1.93 s, o *FAST* – 0.76 s. Nors *SIFT* metodo požymių atitikimo trukmė didelė, reikia pabrėžti, kad *SIFT* vidutinis požymių atitikmenų tarp 2 vaizdų kiekis yra didesnis nei kitų metodų – 1434.87; *SURF* metodo atveju – 338.07, o *FAST* – 54.06. Žinoma, didesnis atitikimų kiekis rodo ir didesnę randamų požymių kiekį, ir atvirkščiai.

1.4. *FAST*, *SIFT* ir *SURF* metodų atkartojimo kriterijaus įvertinimas

Šiame skyriuje atliekamas *FAST*, *SIFT* ir *SURF* metodų atkartojimo kriterijaus palyginimas. Patikimas sudėtingų objektų atpažinimas yra pagrindinė problema kompiuterinės regos metoduose. Dėl šios priežasties kiekvienas požymių išskyrimo metodas turi nustatyti objekto požymius, priklausomai nuo atitinkamų pikselių, įsiminti ir naudoti informaciją, norint įvertinti, ar užklauso vaizdas turi specifinius to objekto požymius. Vartojamos sąvokos „mokymo vaizdas“, kurį detektorius naudoja norimam sekti vaizdui išmokti, ir „užklauso vaizdas“, kuriame detektorius, išmokęs vaizdą aptinka objektą aplinkoje.

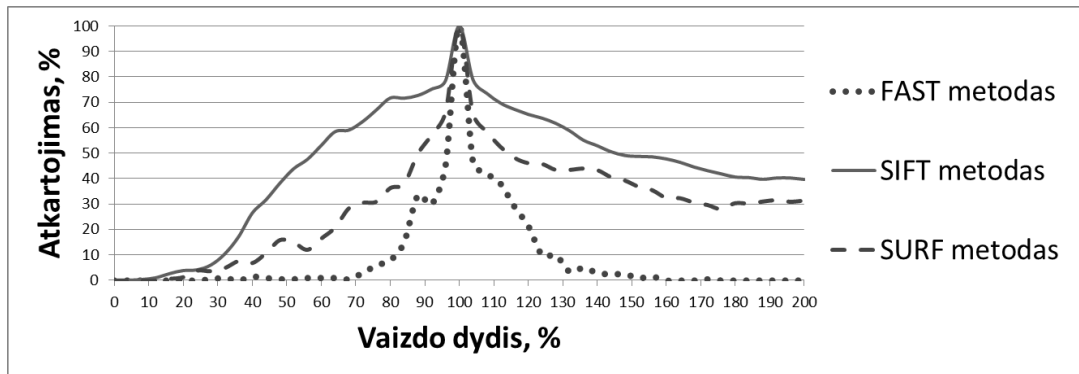
Aptiktas didelis kiekis požymių vaizde nėra sekimo patikimumo įvertis. Tam tikros vaizdo dalys turi daugiau informacijos nei kitos ir yra didesnė galimybė surasti atitikmenį. Eksperimentuose naudojamas atkartojimo kriterijus (angl. *repeatability criteria*), norint įvertinti *FAST*, *SIFT* ir *SURF* metodų požymių sutapdinimo santykį. Atkartojimo kriterijus naudojamas aprašyti požymių aptikimo tikslumą – galimybę identifikuoti tikslią pikselio vietą; stabilumą – galimybę identifikuoti tuos pačius požymius po geometrinių transformacijų; jautrumą esant nepalankioms sąlygoms – galimybę aptikti pastovius požymius esant prastam apšvietimui. Jeigu išskirtų ir sutapdintų vaizdo požymių rezultatas negali būti pateiktas kaip patikimas ar atkartojamas, tuomet negalima pereiti prie tolesnio rezultatų tikslumo verifikavimo etapo. Atkartojimo kriterijus paskaičiuotas naudojant (16) išraišką (Juan, L.; Gwun, O., 2009):

$$r(I_1, I_2) = \frac{C(I_1, I_2)}{M(m_1, m_2)}, \quad (16)$$

čia $r(I_1, I_2)$ – įvertintas atkartojimo kriterijus tarp dviejų skirtingų vaizdų I_1 ir I_2 ; $C(I_1, I_2)$ – požymių sutapdinimo kiekis tarp dviejų vaizdų; $M(m_1, m_2)$ rastų požymių

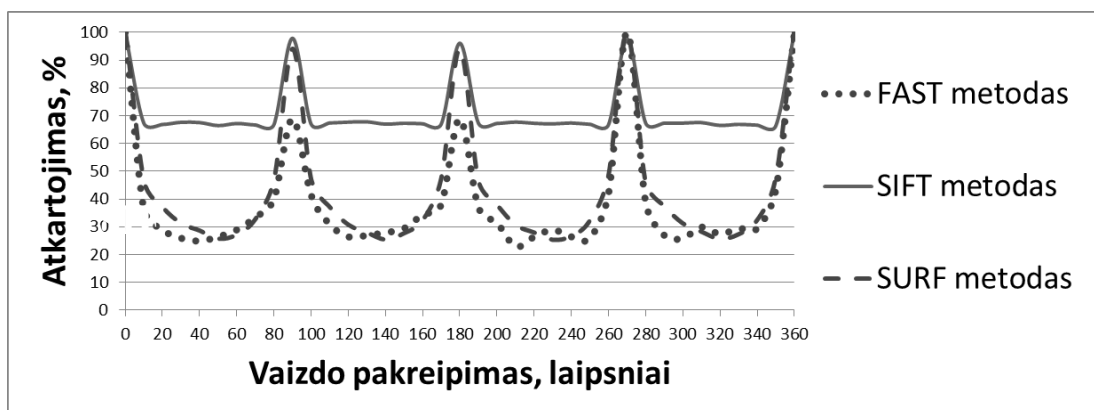
kiekio abiejuose vaizduose vidurkis. Atkartojimo kriterijus paskaičiuojamas kaip santykis abiejuose vaizduose sutapdintų požymių kiekio ir aptiktų požymių kiekio abiejuose vaizduose vidurkio.

Požymių išskyrimo ir sutapdinimo *FAST*, *SIFT* ir *SURF* metodų atkartojimo kriterijaus rezultatai, priklausomai nuo vaizdo mastelio, pateikti 17 pav.



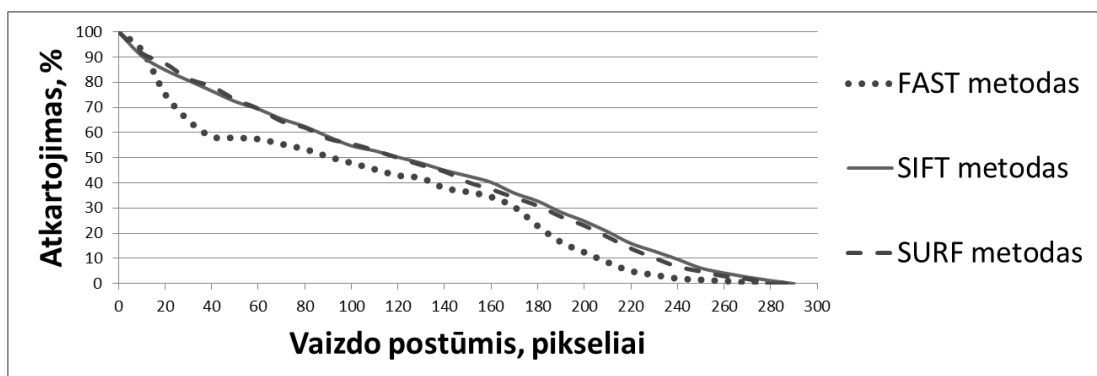
17 pav. *FAST*, *SIFT* ir *SURF* požymių išskyrimo metodų atkartojimo kriterijaus įvertinimas esant skirtingo mastelio vaizdai

Pradinis mokymo vaizdo dydis yra 349×300 pikselių – atitinka 100%. Šio eksperimento metu naudoti 48 skirtingo mastelio vaizdai. Pradinis vaizdas buvo didinamas iki 200% bei mažinamas iki 8%, nes požymių išgavimas iš mažesnio mastelio vaizdų neįmanomas. *FAST* metodo atveju rezultatai rodo, kad, pradinį vaizdą sumažinus ar padidinus 10%, atkartojimas siekia 30–40%, *SURF* metodo – apie 55%, o *SIFT* – 75%. Keičiant dydį $\pm 30\%$ nuo pradinio vaizdo, *FAST* metodo atveju, atkartojimas yra mažesnis nei 10%, *SURF* – 30–45%, o *SIFT* – 60%. Esant didesniems vaizdo dydžio pokyčiams, pavyzdžiui, vaizdo dydį mažinant, *FAST* metodo atkartojimo kriterijus artėja prie 0%. Visais atvejais *SIFT* metodo atkartojimo įvertinimas, priklausomai nuo vaizdo dydžio, rodo geriausius rezultatus. Mažinant vaizdo mastelį, tiek aptinkamas požymių kiekis vaizde, tiek požymių atitikimų abiejuose vaizduose kiekis proporcingai mažėja. Pradinį vaizdą didinant, didėja aptinkamų požymių kiekis vaizde (išskyrus *FAST* metodą), tačiau vaizdų požymių sutapdinimas lieka tolygiai pasiskirstęs. Atkartojimo įvertinimas, priklausomai nuo vaizdo pakreipimo, pateiktas 18 pav.



18 pav. *FAST*, *SIFT* ir *SURF* požymių išskyrimo metodų atkartojimo įvertinimas pasukant vaizdą

Šio eksperimento metu pradinis vaizdas pakreipiamas kiekviename etape kas 10° , kol sugrįžtama į pradinę vaizdo padėtį. Svarbu pastebėti, kad, atliekant vaizdo pasukimo transformacijas, vaizdo mastelis 349×300 keičiasi į 300×349 . Šio perėjimo metu prarandama dalis požymių, kurie patenka už pradinio mastelio ribų. Iš atliktų eksperimentų matyti, kad geriausias atkartojimas pasiekiamas 90° pakreipus vaizdus: *SURF* ir *SIFT* metodų atveju siekia nuo 94–100%, o *FAST* – 68–100%. Kitais vaizdų pakreipimo atvejais atkartojimas sumažėja: *SIFT* metodo – iki 67%, o *FAST* ir *SURF* metodų – iki 25%. Atkartojimo įvertinimas, priklausomai nuo vaizdo postūmio, pateiktas 19 pav.




19 pav. *FAST*, *SIFT* ir *SURF* požymių išskyrimo metodų atkartojimo įvertinimas pastumiant vaizdą

Šio eksperimento metu pradinis vaizdas buvo pastumiamas kas $(10,10)$ (*ilgis* \times *plotis*) pikselių, kol užklauso vaizdas nebeturėjo jokios naudingos informacijos. Pastaba: x ašyje skaičius, pavyzdžiui, 80 atitinka $(80,80)$ pikselių postūmį nuo pradinio vaizdo. Nesunku įsitikinti, kad atkartojimo kriterijus mažėja didėjant vaizdo postūmiui. Taikant *SURF* ir *SIFT* metodus, atkartojimas sutampa ir tiesiniu būdu mažėja, o *FAST* metodą – priklausomai nuo vaizdo postūmio, tampa mažesnis 4–20%.

Šio tipo eksperimentas yra dalinės objekto okliuzijos imitavimas, kuris aktualus papildytos realybės sistemose.

Kiekviename atliktame eksperimente *SIFT* metodas aptinka daugiausia atitikmenų vaizdo mastelio, pasukimo ir postūmio atvejais. Žinoma, realiomis sąlygomis atpažįstant vaizdą susiduriama su keliomis problemomis vienu metu: apšvietimo skirtumai, vaizdo pasukimas, mastelio pokyčiai bei dalinės okliuzijos, todėl randamų požymių bei atitikimų kiekis gali būti mažesnis. Požymių sutapdinimas naudojant *SURF* ir *SIFT* metodus realiomis sąlygomis pateiktas 20 pav.



20 pav. Požymių sutapdinimo pavyzdys įvairiomis aplinkos sąlygoms: a) *SURF*; b) *SIFT*

Šiame eksperimente atliktas požymių išskyrimas ir sutapdinimas tarp skirtingų realios aplinkos 10 vaizdų rinkinio ir sutapdinimas su mokymo vaizdu. *SIFT* metodo atkartojimas siekia 11,35%, o *SURF* – 4,59%. Nors *FAST* metodas ištraukia požymius greičiau nei kiti metodai, jis nėra patikimas esant kelioms vaizdo transformacijoms vienu metu, todėl šiame eksperimente nenaudotas. Tokio pobūdžio eksperimentai aktualūs siekiant įvertinti požymių išskyrimo metodų tinkamumą papildytos realybės sistemose, kurios leistų pasiekti patikimą objekto atpažinimą vaizde, net jeigu objektas užklauso vaizde yra iš dalies uždengtas, skirtingo mastelio, pasukimo ar postūmio nei mokymo vaizdas.

Atliktas požymių išskyrimo metodų tyrimas toliau bus panaudotas kaip tyrimų pagrindas papildytos realybės srityje, toliau tobulinant bei papildomai integruojant informaciją iš inercinių jutiklių.

1.5. Skyriaus išvados

1. Atlikus požymių išskyrimo ir klasifikavimo metodų analizę nustatyta, kad tiek klasifikavimo metodai, tiek požymių išskyrimo metodai sprendžia vaizdo požymių pertekliaus problemą, transformuojant perteklių į sumažintą požymių kiekį, kuris vis dar suteiktų pakankamai informacijos, norint atpažinti ir sekti konkretų objektą aplinkoje.

2. Atlikus *SIFT*, *SURF* ir *FAST* požymių išskyrimo metodų tyrimą įvertintas stabilumas naudojant atkartojimo kriterijų, kur didesnė reikšmė nurodo didesnę metodo stabilumą aptinkant ir sekant objektą vaizde. Pradinio vaizdo mastelio keitimo atveju *SIFT* atkartojimo kriterijus yra 15–30% didesnis už *SURF* metodą ir 35–55% didesnis už *FAST*. Vaizdą pasukant *SIFT* metodo atkartojimo kriterijus didesnis 40% lyginant tiek su *SURF*, tiek *FAST* metodais. Vaizdą pastumiant *SIFT* ir *SURF* atkartojimo kriterijaus rezultatai panašūs, bet 4–20% didesni už *FAST* metodą.

3. Nors požymių išskyrimo iš vaizdo rezultatai atkartojimo kriterijaus atžvilgiu geresni *SIFT* metodo atveju, greitaveika nėra pastarojo metodo privalumas, nes vaizduose aptinkamas didelis kiekis požymių nebūtinai turi naudingos informacijos, o algoritmas reikalauja daugiau skaičiavimo resursų. Taip pat didesnės rezoliucijos vaizdai turi didesnę kiekį požymių, todėl metodų vykdymo trukmė atitinkamai ilgesnė. Pagal atliktus greitaveikos eksperimentus nustatyta, kad požymių išskyrimas ir sutapdinimas vyksta daugiau nei 4 kartus lėčiau už *SURF* metodą ir 11 kartų lėčiau už *FAST* metodą. Papildytos realybės sistemose objekto sekimas turi būti vykdomos realiu laiku, o nuo požymių išskyrimo kiekio priklauso metodo vykdymo trukmė.

4. Nėra vieno universalus požymių išskyrimo metodo, kur objekto sekimo uždavinių atlikimas tiktų bet kuriai taikymo sričiai, nes egzistuoja kiti reikalavimai skirtingose taikymo srityse, skiriasi konkretaus sekamo objekto savybės ir aplinkos sąlygos, nuo kurių priklauso požymių prieinamumas.

II. Objekto, turinčio padėtį nustatančius jutiklius, sekimo tyrimas

Efektyvus objektų atpažinimas ir sekimas yra esminiai sprendžiami uždaviniai papildytos realybės srityje. Papildytos realybės sprendimai dažniausiai naudojama mobiliuosiuose įrenginiuose, todėl reikalingas sprendimo būdas, kuris efektyviai vykdytų atpažinimo, sekimo ir virtualaus turinio atvaizdavimo užduotis. Šiame skyriuje nagrinėjamos mikroelektromechaninių jutiklių (angl. *Microelectromechanical sensors*) panaudojimo galimybės ir kvaternionų taikymas jutiklių matavimų duomenims, norint patikimai bei tiksliai įvertinti objekto orientaciją erdvėje – t. y. atlikti kameros sekimą. Šiuo sprendimu siekiama pašalinti pavienių jutiklių trūkumus ir pagerinti kameros sekimo (orientacijos įvertinimo) tikslumą, patikimumą bei virtualaus turinio atvaizdavimą papildytoje realybėje, nenaudojant jokio požymių išskyrimo metodo. Dėl esamų požymių išskyrimo metodų trūkumų geresni rezultatai gali būti pasiekti papildomai naudojant jutiklių matavimų duomenis, tačiau jutiklių matavimų sujungimo metodai šiame etape bus nagrinėjami nepriklausomai nuo kompiuterinės regos metodų.

Demonstruojamas orientacijos įvertinimo sprendimas pritaikytas ne tik iš kameros sekimo aspekto ir taikymo papildytos realybės srityje, bet ir plėtojant sąveikos įrenginį. Taip pat nagrinėjamas Kalmano filtro panaudojimas sekant objektų orientaciją. Pateikta detali Kalmano filtro analizė, praktinis taikymas gautiems jutiklių matavimų duomenims, kurie išreikšti kvaternionais. Atlikta gradientinio nusileidimo metodo analizė ir adaptacija Kalmano filtre, siekiant gauti tikslesnius sekamo objekto orientacijos įverčius. Atlikto tyrimo pagrindu šiame skyriuje vėliau bus siūlomas hibridinis objektų sekimo metodas naudojant Kalmano filtrą.

2.1. Objektų sekimo metodų apžvalga papildytos realybės sistemose

Šiuo metu mikroelektromechaniniai jutikliai (akselerometrai, giroskopai ir magnetometrai) dominuoja mobiliuosiuose įrenginiuose. Mobiliųjų įrenginių rinka nepaliaujamai plečiasi ir telkiasi į jutiklių integracijos procesą, pridedamas papildomas funkcionalumas kuriamoms aplikacijoms. Tokiu būdu suteikiama galimybė pritaikyti jutiklių informaciją papildytos realybės sprendimuose. Pavyzdžiui, mobiliuosiuose įrenginiuose naudojami inerciniai jutikliai suteikia galimybę įvertinti integruotų


įrenginių kameros orientaciją, kuri gali būti panaudota kuriant papildytos realybės sprendimus.

Kompiuterinės regos metodai sprendžia problemas, susijusias su klaidingu kontrastu dėl įvairių apšvietimo sąlygų, atspindžių bei pasvirimo kampų, kurie paslepia svarbius vaizdų požymius. Dėl šių problemų sudėtinga įvykdyti sėkmingą objekto sekimą papildytos realybės srityje. Priklausomai nuo sekamo objekto vietos vaizde, realiu laiku galima apskaičiuoti kameros poziciją ir orientaciją erdvėje bei atvaizduoti virtualų turinį. Naujesni papildytos realybės technologijos sprendimai dažniausiai naudoja nagrinėtus ankstesniame skyriuje požymių išskyrimo metodus *FAST* (Rosten, E.; Porter, R.; Drummond, T., 2010) ir *SURF* (Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V., 2008) bei įvairias šių metodų modifikacijas, norint identifikuoti ir sekti objektą esant kliūtims. Konkrečių atpažinimo vaizdų mokymas suteikia galimybę papildytos realybės turinį susieti su realistiškesne ir natūralesne aplinka, pavyzdžiui, knygos paviršiumi. Naudojant vien tik požymių išskyrimo metodus, objektų sekimas gali būti klaidingas dėl galimų vaizdo transformacijų ir virtualus turinys bus netinkamai atvaizduotas: vartotojo matomas vaizdas skirsis nuo laukiamo vaizdo. Todėl atsiranda poreikis nagrinėti papildomas galimybes, kaip pagerinti objekto sekimą ne tik taikant požymių išskyrimo metodus, bet ir gaunant papildomos informacijos iš jutiklių matavimų. Požymių išskyrimo metodų atžvilgiu objekto sekimas priklauso nuo požymių išskyrimo, objekto atpažinimo ir sekimo per vaizdų seką efektyvumo, todėl vaizdų sekimas tampa sudėtingas arba neįmanomas dėl greitų kameros judesių. Greitas arba netolygus kameros judėjimas sukelia vaizdo sekimo sutrikimų ar nestabilumą. Toks trūkumas gali būti pašalintas naudojant inercinius jutiklius, norint įvertinti greitus kameros orientacijos pokyčius ir sėkmingai sekti objekto poziciją bei orientaciją vaizde (Bleser, G.; Stricker, D., 2008), (Kanbara, M., et al., 2000) (You, S., 2001). Ultragarsiniai jutikliai taip pat sėkmingai naudojami objektams sekti, tačiau vartotoją riboja maža darbo erdvė (Lukosiunas, E. et al., 2011). Sistemose, kuriose naudojami jutiklių duomenų sujungimo metodai (angl. *sensor data fusion*), galima pasiekti pagerintą stabilumą sekimo atveju, nei naudojant jutiklių duomenis atskirai, o viena iš galimų tokių jutiklių taikymo sričių yra papildyta realybė. Daugelis kitų pažangių sprendimų objektų orientacijai nustatyti naudoja kvaternionus (Trawny & Roumeliotis, 2005) ir jiems pritaiko Kalmano filtrą (Hol, J. D. et al., 2006), (Marins, J. L.; et. al., 2001), (Sabatini, A. M., 2006).

2.2. Skaitmeninių jutiklių tyrimas

Judesio sekimo sistemose naudojami inerciniai jutikliai gali atlikti matavimus dideliu greičiu, o tai suteikia galimybę aptikti ir sparčius objektų (šiuo atveju kameros) pozicijų ar orientacijų pokyčius. Pasirenkant sekimo metodą daugelis papildytos realybės sistemų reikalauja judesio apribojimų, kad būtų užtikrintas patikimas virtualaus turinio atvaizdavimas. Pagrindinė šiuo atveju sprendžiama problema – patikimų orientacijos įverčių užtikrinimas po tam tikro laiko tarpo, naudojant jutiklių matavimus, siekiant sumažinti arba eliminuoti jutiklių triukšmą, nuokrypius ir magnetinę interferenciją.

Toliau pateiktiems eksperimentams atlikti pasirinktas *Arduino Nano* mikrovaldiklis, tačiau tyrimui galima pasirinkti bet kokią *Arduino* mikrovaldiklio modelį ar kitą mikrovaldiklio analogą. Mikrovaldiklis gali veikti autonomiškai arba gali komunikuoti su kita programine ir technine įranga, surinkti bei apdoroti gautą informaciją iš jutiklių. Orientacijos duomenų nuskaitymas atliekamas naudojant skaitmeninius jutiklius: akselerometrą *ADXL345*, giroskopą *ITG3200* ir magnetometrą *HMC5883L* (toliau – *MARG* jutiklis (angl. *Magnetic, Angular Rate and Gravity*)), 21 pav.




21 pav. Parinkta techninė įranga: a) *Arduino Nano* mikrovaldiklis; b) *MARG* jutiklis

Akselerometras matuoja Žemės gravitaciją bei įrenginio pagreitį. Bendru atveju šis jutiklis tinkamas norint nustatyti, kaip orientuotas objektas priklausomas nuo Žemę veikiančios gravitacijos jėgos. Naudojant gautus akselerometro matavimų duomenis galima apskaičiuoti $a_{\phi, \theta}$ objekto pasvirimą naudojant (17):

$$a_{\phi, \theta} = \begin{bmatrix} a_{\phi_t} \\ a_{\theta_t} \end{bmatrix} = \begin{bmatrix} \arctan \left(a_{y_t} / \sqrt{a_{x_t}^2 + a_{z_t}^2} \right) \\ \arctan \left(a_{x_t} / \sqrt{a_{y_t}^2 + a_{z_t}^2} \right) \end{bmatrix}, \quad (17)$$


čia a_{x_t} , a_{y_t} , a_{z_t} – akselerometro pagreitis x , y ir z ašių atžvilgiu esamu laiko momentu t ; a_{ϕ_t} , a_{θ_t} – paskaičiuotas objekto pasvirimo kampas x ir y ašių atžvilgiu.

Pagrindinė matavimų problema – matavimai paveikiami mechaninio triukšmo, o sparčiai judinamo įrenginio a_ϕ ir a_θ kampų reikšmės yra klaidingos ir nepatikimos. Gravitacijos jėga, kaip atskaitos vektorius, nesuteikia informacijos apie objekto orientaciją z ašies atžvilgiu. Vidurkinant akcelerometro duomenis galima filtruoti išorinius pagreičius, tačiau gaunami uždelsti rezultatai. Žemiau pateiktame akcelerometro matavimų eksperimente (22 pav.) norima parodyti gaunamų duomenų, paveiktų triukšmo, pobūdį, kai matavimų diapazonas parinktas $\pm 2 g$, o duomenų nuskaitymo sparta $100 Hz$.



22 pav. Trijų ašių skaitmeninio akcelerometro matavimų duomenys x (mėlyna kreivė), y (raudona kreivė) ir z (juoda kreivė) ašių atžvilgiu

Keičiant objekto padėtį, gravitacijos vektorius pereina iš y į x ašį, ir atvirkščiai, o papildomi maksimalūs signalų lygiai (triukšmai) atsiranda dėl jutiklio pagreičio pokyčių. Didinant matavimų nuskaitymo greitį (maksimalus – $400 Hz$) triukšmas dar labiau didėja. Kitaip nei akcelerometras, giroskopas matuoja kampinį greitį ir nėra jautrus linijiniams judesių pagreičiams, 23 pav.



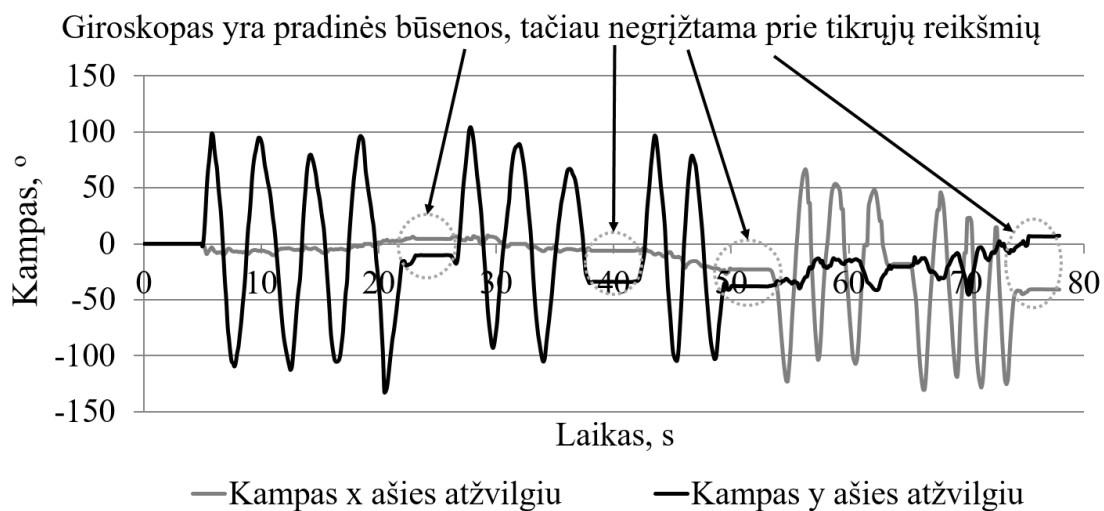
23 pav. Trijų ašių skaitmeninio giroskopo matavimų duomenys

Giroskopo kampinio greičio matavimai, atlikti $400 Hz$ dažniu esant $\pm 2000 \text{ %/sec}$ matavimo diapazonui, nekaupia paklaidų. Naudojant kampinį greitį galima

apskaičiuoti objekto orientaciją $\omega_{\phi, \theta, \psi}$ (x (kampas ω_{ϕ_t}), y (kampas ω_{θ_t}) ir z (kampas ω_{ψ_t}) ašių atžvilgiu) pagal (18) išraišką:

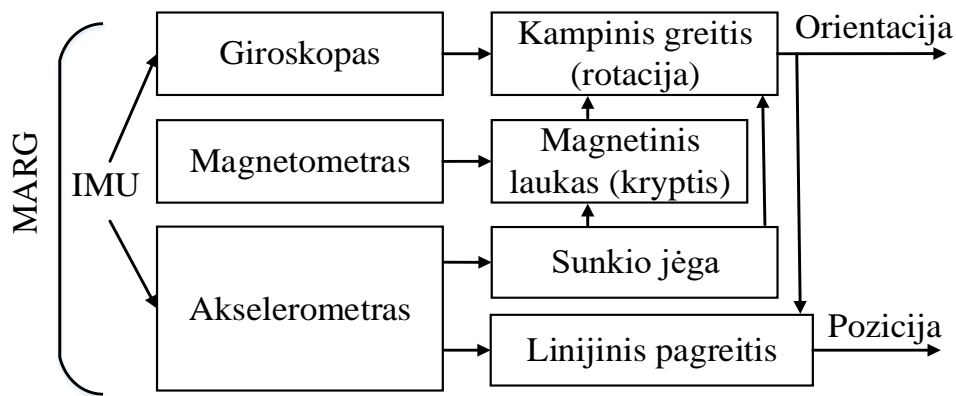
$$\omega_{\phi, \theta, \psi} = \begin{bmatrix} \omega_{\phi_t} \\ \omega_{\theta_t} \\ \omega_{\psi_t} \end{bmatrix} = \begin{bmatrix} \omega_{\phi_{t-1}} + \omega_{x_t} \Delta t \\ \omega_{\theta_{t-1}} + \omega_{y_t} \Delta t \\ \omega_{\psi_{t-1}} + \omega_{z_t} \Delta t \end{bmatrix} \quad (18)$$

čia $\omega_{x_t}, \omega_{y_t}, \omega_{z_t}$ – giroskopo kampinis greitis esamu laiko momentu t ; $\omega_{\phi_{t-1}}, \omega_{\theta_{t-1}}, \omega_{\psi_{t-1}}$ – giroskopo apskaičiuotas kampas (orientacija) x, y ir z ašių atžvilgiu ankstesniu $t - 1$ laiko momentu; Δt – laiko tarpas tarp matavimų. Šiuo atveju apskaičiuota orientacija iš giroskopo duomenų yra labai tiksli trumpais laiko tarpais, tačiau nukrypsta po ilgesnio laiko, 24 pav.



24 pav. Objekto orientacijos įvertinimas naudojant skaitmeninį giroskopą

Giroskopas suteikia informaciją apie gravitacijos vektorius, tačiau kampų įverčiai po tam tikro laiko tarpo akumuliuoja klaidas, kitaip nei matuojant kampinį greitį. Orientacijos sekimo sistemose bei papildytoje realybėje šis aspektas yra kritinis. Norint nustatyti patikimą objektų orientaciją erdvėje, naudojami kombinuoti šiuolaikiniai skaitmeniniai jutikliai: akselerometras, giroskopas ir magnetometras. Kitaip nei giroskopo kampinio greičio matavimai, magnetometro magnetinio lauko matavimai iškraipomi dėl šalia esančių feromagnetinių objektų. Šiuos iškraipymus galima kompensuoti. Giroskopas užtikrina greitus matavimus z ašies atžvilgiu, o magnetometras – koreguotą sekamo objekto krypties (z ašies atžvilgiu) įvertį, suderinimui naudojant akselerometro duomenis. Jutiklių duomenų sujungimo principinė diagrama pateikta 25 pav.



25 pav. Jutiklių duomenų sujungimo principinė diagrama

MARG jutikliai sudaryti iš hibridinio *IMU* (angl. *Inertial Measurement Unit*) jutiklio. *MARG* papildomai turi trijų ašių magnetometrą, kuris užtikrina išsamius x , y ir z ašių orientacijos matavimus, priklausomai nuo gravitacijos jėgos krypties ir Žemės magnetinio lauko matavimų, kitaip dar žinomą kaip orientacijos ir pozicijos atskaitos sistemą (angl. *Attitude and heading reference system*). Šiuo metu yra daug įrenginių, kuriuose galima rasti įvairių jutiklių, padedančių nustatyti objektų orientaciją ir poziciją erdvėje: GPS imtuvai, virtualiosios ir papildytos realybės akiniai, mobilieji bei gestų pagrindu veikiantys sąveikos įrenginiai. Naudojant kelių jutiklių duomenis galima kompensuoti atskirų jutiklių trūkumus ir tiksliau apskaičiuoti orientaciją bei poziciją, kuri labai svarbi ne tik papildytos realybės sistemose, bet ir aviacijoje, robotikoje, navigacijoje, taip pat tiriant žmogaus judesius ar žmonių ir mašinų sąveiką.

2.3. Kvaternionų algebros taikymas jutiklių matavimų duomenims

Kalmano filtro taikymas numatomas kvaternionams, todėl labai svarbu aptarti esminius kvaternionų aspektus, lyginant su kitais orientacijos perteikimo būdais – rotacijos matricomis ir Eulerio kampais. Šiuo metu kvaternionai taikomi tiek teorinėje, tiek taikomojoje matematikoje, kur skaičiavimai susiję su trimate erdve. Kvaternionų algebroje atliekamos trys operacijos: sudėtis, skaliarinė daugyba ir kvaternionų daugyba. Kiekvienas kvaterniono elementas gali būti užrašytas baziniais elementais $a + bi + cj + dk$, kur a , b , c , d yra realieji skaičiai. Paprastai objekto orientacijai nustatyti naudojami Eulerio kampai. Pagrindinis Eulerio kampų trūkumas: nėra tokie tikslūs kaip kvaternionai, kai integruojami orientacijos pokyčiai per tam tikrą laiko tarpą. Dėl šių trūkumų pradėti naudoti kvaternionai. Kvaternionai tinkami integruoti

kampinį greitį kūno koordinatinių sistemoje per tam tikrą laiko tarpą. Pagrindiniai kvaternionų trūkumai:

- 1) keturi kvaternionų parametrai neturi jokios intuityvios prasmės;
- 2) kvaternionas privalo turėti vieneto normalizaciją, kad išreikštų tikrąją orientaciją.

Kvaternionų duomenys išreiškiami dviejose skirtingose koordinatinių sistemose:

- 1) pasaulio koordinatinių sistema (angl. *world coordinate system*) yra fiksuota inercinėje erdvėje; koordinatinių sistemos pradžia žymima x_w . x'_w yra pasaulio koordinatinių sistemos pradžia, išreikšta kūno koordinatinių sistemoje.
- 2) kūno koordinatinių sistema (angl. *body-fixed coordinate system*) susieta su objektu, kurio orientaciją norime aprašyti; koordinatinių sistemos pradžia žymima x_b (yra kūno koordinatinių sistemos pradžia, išreikšta pasaulio koordinatinių sistemoje).

Taškai ir vektoriai, išreiškiami kūno koordinatinių sistemoje, atskiriami nuo pasaulio koordinatinių sistemos pagal pradžios simbolį. Pavyzdžiui, jeigu x yra taškas pasaulio koordinatinių sistemoje, tuomet x' yra tas pats taškas, išreikštas kūno koordinatinių sistemoje (Diebel, J., 2006).

Tarkim, turime vieneto kvaternioną, aprašytą naudojant (19) išraišką:

$$q = [q_0, q_1, q_2, q_3]^T. \quad (19)$$

Visa kvaternionų algebra vykdoma pagal toliau pateiktas išraiškas, pavyzdžiui, dviejų kvaternionų p ir q sandauga (20) (Kuipers, J. B., 1999):

$$pq = p_0q_0 - p \cdot q + p_0q + q_0p + p \times q, \quad (20)$$

$$\text{čia } p = p_0 + p = p_0 + ip_1 + jp_2 + kp_3, \text{ o } q = q_0 + q = q_0 + iq_1 + jq_2 + kq_3.$$

Kvaternionai gali būti pateikti įvairiais būdais (19) ir (21):

$$q = q_0 + q = q_0 + q_1i + q_2j + q_3k. \quad (21)$$

Apibendrinant: q_0 vadinama skaliarinė kvaterniono dalis, o q – vektorinė kvaterniono dalis (Kuipers, J. B., 1999). Kompleksinis kvaterniono sujungimas (angl. *complex conjugate*) pateiktas (22) išraiškoje:

$$q^* = q_0 - q = q_0 - iq_1 - jq_2 - kq_3. \quad (22)$$

Kvaternionų sandauga gali būti išreikšta 4×4 ortogonalia matrica ir keturių elementų vektoriumi. Kvaternionų sandauga žymima \otimes ir gali būti išreikšta (23), (24):

$$p \otimes q = Q(p)q = \bar{Q}(q)p = \begin{bmatrix} q_0 & -q_1 & -q_2 & -q_3 \\ q_1 & q_0 & -q_3 & q_2 \\ q_2 & q_3 & q_0 & -q_1 \\ q_3 & -q_2 & q_1 & q_0 \end{bmatrix} \cdot \begin{bmatrix} p_0 \\ p_1 \\ p_2 \\ p_3 \end{bmatrix}, \quad (23)$$

$$p \otimes q = \begin{bmatrix} p_0 q_0 - p_1 q_1 - p_2 q_2 - p_3 q_3 \\ p_0 q_1 + p_1 q_0 - p_2 q_3 + p_3 q_2 \\ p_0 q_2 + p_1 q_3 + p_2 q_0 - p_3 q_1 \\ p_0 q_3 - p_1 q_2 + p_2 q_1 + p_3 q_0 \end{bmatrix}. \quad (24)$$

Jeigu p žymi vieną rotaciją ir q žymi kitą rotaciją, tokiu atveju $p \otimes q$ yra kombinuota rotacija. $\bar{Q}(q)p$ skiriasi nuo $Q(p)q$ tuo, kad 3×3 matrica transponuota. Kvaternionų sandauga rodo, kad nėra komutatyvaus pobūdžio. Kvaterniono normalizacija $\|q\|$ skaičiuojama pagal (25) išraišką:

$$\|q\| = \frac{q_0 + q_1 + q_2 + q_3}{\sqrt{q_0^2 + q_1^2 + q_2^2 + q_3^2}}. \quad (25)$$

Kompleksiniame kvaterniono sujungime pakeičiamas kompleksinės dalies ženklas (26):

$$q^* = [q_0, -q_1, -q_2, -q_3]^T. \quad (26)$$

Atvirkštinis kvaternionas paskaičiuojamas naudojant (27) išraišką:

$$q^{-1} = \frac{q^*}{\|q\|^2}. \quad (27)$$

Norint rasti kvaterniono išvestinę, reikia atlikti algebrines manipuliacijas. Galimi du būdai, priklausomai nuo atskaitos sistemų, kaip kampinis greitis pakeičiamas į kvaternionų kampinį greitį:

1) kampinio greičio vektorius yra pasaulio koordinačių sistemoje (28):

$$\dot{q}_\omega(q, \omega) = \frac{1}{2} q \otimes \begin{bmatrix} 0 \\ \omega \end{bmatrix} = \frac{1}{2} Q(q) \otimes \begin{bmatrix} 0 \\ \omega \end{bmatrix} = \frac{1}{2} \begin{bmatrix} -q_1 & -q_2 & -q_3 \\ q_0 & -q_3 & q_2 \\ q_3 & q_0 & -q_1 \\ -q_2 & q_1 & q_0 \end{bmatrix} \cdot \begin{bmatrix} \omega_x \\ \omega_y \\ \omega_z \end{bmatrix}. \quad (28)$$

2) kampinio greičio vektorius yra kūno koordinačių sistemoje (29):

$$\dot{q}_{\omega'}(q, \omega') = \frac{1}{2} q \otimes \begin{bmatrix} 0 \\ \omega' \end{bmatrix} = \frac{1}{2} \bar{Q}(q) \otimes \begin{bmatrix} 0 \\ \omega' \end{bmatrix} = \frac{1}{2} \begin{bmatrix} -q_1 & -q_2 & -q_3 \\ q_0 & q_3 & -q_2 \\ -q_3 & q_0 & q_1 \\ q_2 & -q_1 & q_0 \end{bmatrix} \cdot \begin{bmatrix} \omega'_x \\ \omega'_y \\ \omega'_z \end{bmatrix}. \quad (29)$$

Tarkime turime du kvaternionus $q_A = q_0^A + q_1^A i + q_2^A j + q_3^A k$ ir $q_B = q_0^B + q_1^B i + q_2^B j + q_3^B k$. Kvaternionų Hamiltono sandauga pateikta (30), (31) išraiškose, kur galioja distributyvumo taisyklės:

$$q_{AB} = q_A \otimes q_B = (q_0^A + q_1^A i + q_2^A j + q_3^A k) \cdot (q_0^B + q_1^B i + q_2^B j + q_3^B k). \quad (30)$$

$$\begin{aligned}
q_{AB} &= \begin{bmatrix} q_0^A q_0^B + q_0^A q_1^B i + q_0^A q_2^B j + q_0^A q_3^B k \\ q_1^A q_0^B i + q_1^A q_1^B i^2 + q_1^A q_2^B ij + q_1^A q_3^B ik \\ q_2^A q_0^B j + q_2^A q_1^B ji + q_2^A q_2^B j^2 + q_2^A q_3^B jk \\ q_3^A q_0^B k + q_3^A q_1^B ki + q_3^A q_2^B kj + q_3^A q_3^B k^2 \end{bmatrix} = \\
&= \begin{bmatrix} q_0^A q_0^B - q_1^A q_1^B - q_2^A q_2^B - q_3^A q_3^B \\ (q_0^A q_1^B + q_1^A q_0^B + q_2^A q_3^B - q_3^A q_2^B) i \\ (q_0^A q_2^B - q_1^A q_3^B + q_2^A q_0^B + q_3^A q_1^B) j \\ (q_0^A q_3^B + q_1^A q_2^B - q_2^A q_1^B + q_3^A q_0^B) k \end{bmatrix}, \tag{31}
\end{aligned}$$

čia $i^2 = j^2 = k^2 = -1$; $ij = -ji = k$; $jk = -kj = i$; $ki = -ik = j$.

Naudojant 4×4 matricas, tas pats kvaternionas gali būti užrašytas naudojant (32)

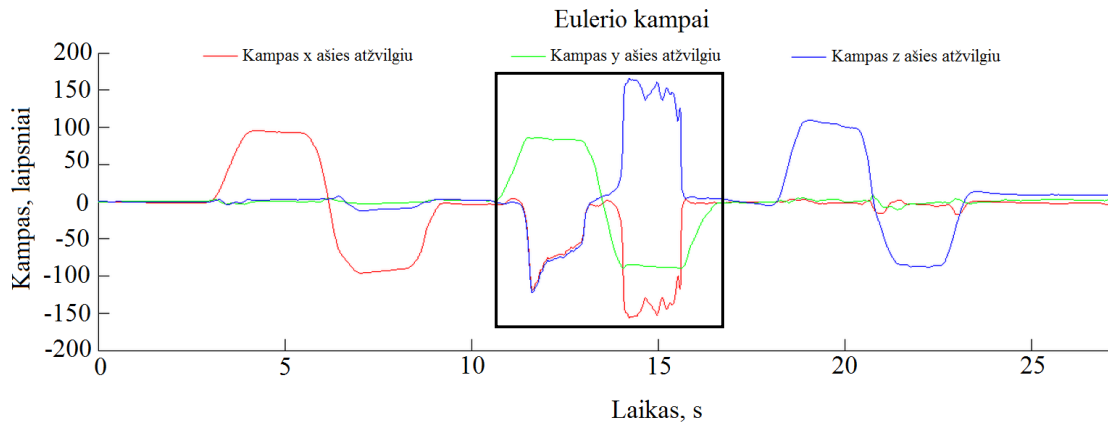
išraišką:

$$\begin{aligned}
\begin{bmatrix} q_0 & q_1 & q_2 & q_3 \\ -q_1 & q_0 & -q_3 & q_2 \\ -q_2 & q_3 & q_0 & -q_1 \\ -q_3 & -q_2 & q_1 & q_0 \end{bmatrix} &= q_0 \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} + q_1 \begin{bmatrix} 0 & 1 & 0 & 0 \\ -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 \\ 0 & 0 & 1 & 0 \end{bmatrix} + \\
&+ q_2 \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 \end{bmatrix} + q_3 \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 0 & -1 & 0 \\ 0 & 1 & 0 & 0 \\ -1 & 0 & 0 & 0 \end{bmatrix} \tag{32}
\end{aligned}$$

Kvaternionas perteikia rotacijos ašį (x , y arba z) ir rotacijos dydį. Su šiomis reikšmėmis galima sudaryti matricą, kuri sudaro visas rotacijas be jokių trūkumų. Rotacijas taip pat lengviau modifikuoti naudojant kvaternionus, galima išvengti rotacijų matricos nuokrypio problemų ir yra tolygesnė interpoliacija rotacijose (Berner, P., 2008).

2.4. Kameros orientacijos įvertinimas ir taikymas papildytoje realybėje

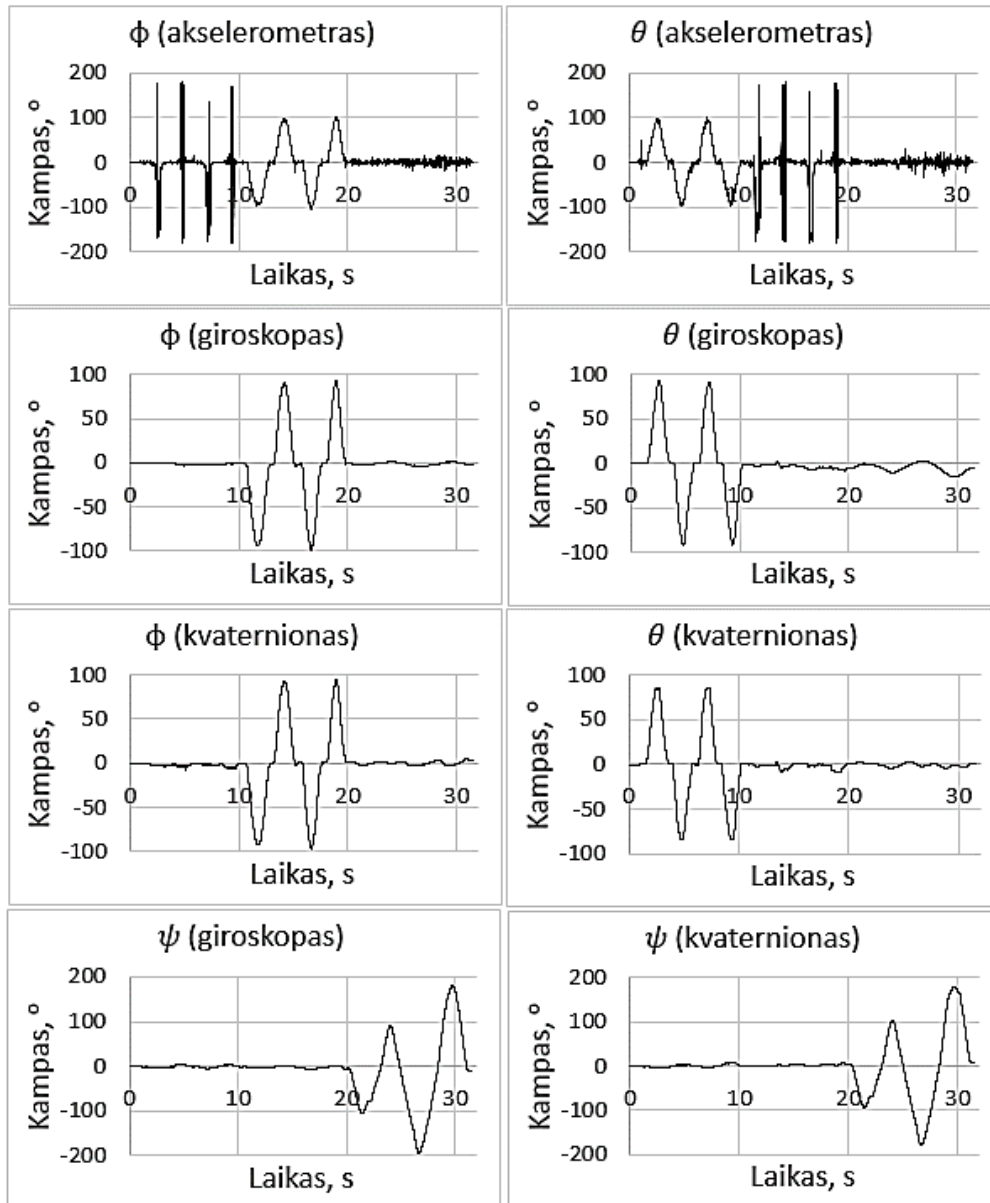
Kameros orientaciją erdvėje galima nustatyti x , y ir z ašių atžvilgiu, naudojant Eulerio kampus (angl. *Euler angles*), rotacijų matricas (angl. *rotation matrix*) ir kvaternionus (angl. *quaternions*). Pagrindinė Eulerio kampų problema – svarbi rotacijų atlikimo seka bei atsirandantis efektas, kuriuo prarandamas vienas laisvės laipsnis trimatėje erdvėje, 26 pav.



26 pav. Eulerio kampų probleminė dalis

Pateikta Eulerio kampų probleminė dalis, kur ϕ ir ψ dalies kampų reikšmės turėjo artėti prie 0 laipsnio kampo, tačiau pagal kreivę matoma, kad objektas tuo pačiu laiko momentu tarsi buvo pasuktas visų 3 ašių atžvilgiu, o tai yra neįmanoma, todėl prasminga naudoti kvaternionus atliekant skaičiavimus. Netiksliai įvertinus kameros orientaciją gali atsirasti vizualinių netikslumų dėl nenuolatinių klaidų pateikiant virtualų turinį papildytoje realybėje. Žinoma, pagrindinis Eulerio kampų privalumas – galimybė lengvai atskirti, interpretuoti ir vizualizuoti orientaciją x , y ir z ašių atžvilgiu. Naudojant kvaternionus išvengiama problemų, būdingų Eulerio kampams. Kvaternionas yra keturių elementų kompleksinis skaičius $q = [q_0, q_1, q_2, q_3]$, kuris taip pat naudojamas objektams orientacijos trimatėje erdvėje nustatyti: x , y ir z ašių atžvilgiu vyksta rotacijos ir nusako jų dydį. Kvaternionas, aprašantis orientaciją, turi būti normalizuotas pagal (26) išraišką. Šios išraiškos $\|q\|$ gauta vieneto reikšmė rodo, kad objekto orientacija trimatėje erdvėje yra tiksli.

Jutiklių duomenų sujungimo rezultatas yra sunkio jėga, linijinis pagreitis (siekiant įvertinti poziciją) ir orientacija (Eulerio kampai, rotacijų matricos, kvaternionai). Naudotas pasiūlytas gradientinio nusileidimo metodas (Madgwick, S. O. H., 2011), pritaikytas parinktų skaitmeninių jutiklių matavimų duomenims (detalizuotas 2.11 poskyryje), kurie išreikšti kvaternionais, norint sekti kameros orientaciją ir atvaizduoti virtualų turinį per papildytą realybę. Metode įtraukta magnetinio lauko iškraipymų kompensacija. Kameros orientacijos sekimo eksperimento rezultatai, pateikti 27 pav.



27 pav. Įvertinti tolygūs kameros orientacijos pokyčiai

Pateiktose 27 pav. diagramose kvaterniono vektorius konvertuotas į Eulerio kampus. Turint kvaternioną, galima apskaičiuoti orientaciją naudojant Eulerio kampus $e_a = [\phi, \theta, \psi]^T$ pagal (33) išraišką:

$$e_a = \begin{bmatrix} \phi \\ \theta \\ \psi \end{bmatrix} = \begin{bmatrix} \tan^{-1} \left(\frac{2(q_2q_3 - q_0q_1)}{2q_0^2 + 2q_3^2 - 1} \right) \\ -\sin^{-1}(2q_1q_3 + 2q_0q_2) \\ \tan^{-1} \left(\frac{2(q_1q_2 - q_0q_3)}{2q_0^2 + 2q_1^2 - 1} \right) \end{bmatrix}. \quad (33)$$

Orientacijos skaičiavimai visais atvejais pritaikyti realiems jutiklių duomenims. Akselerometro ϕ ir θ kampų skaičiavimai rodo, kad realūs matavimai paveikti triukšmo. Giroskopo atveju ϕ , θ ir ψ kampų skaičiavimų rezultatai po tam tikro laiko

nukrypsta, o gradientinio nusileidimo metodas kvaternionų pagrindu išlieka stabilus. Pagrindinis jutiklių duomenų sujungimo aspektas – naudoti akselerometro gravitacijos ir magnetometro magnetinio lauko vektorius, norint gauti pakoreguotus giroskopo x , y ir z ašių atžvilgiu įverčius bei pašalinti atsiradusį nuokrypį. Akselerometru kompensuojamas nuokrypis skaičiuojant kampus ϕ ir θ , o magnetometru – kampas ψ . Norint įvertinti gautų rezultatų patikimumą apskaičiuotas standartinis nuokrypis σ (34):

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=0}^n (\bar{x} - x_i)^2}, \quad (34)$$


čia x_i – akselerometro, giroskopo, magnetometro arba kvaterniono sprendimo įvertintų orientacijų rezultatai skirtingų x , y ir z ašių atžvilgiu; \bar{x} – įvertintų orientacijų vidutinė vertė atitinkamai x , y ir z ašių atžvilgiu; n – matavimų kiekis. Orientacijų standartinių nuokrypių rezultatai σ pateikti 1 lentelėje.

1 lentelė. Standartinių nuokrypių rezultatai

Įvertis	Orientacijos įverčiai naudojant akselerometrą		Orientacijos įverčiai naudojant giroskopą			Orientacijos įverčiai naudojant gradientinio nusileidimo algoritmą kvaternionams		
	a_ϕ	a_θ	ω_ϕ	ω_θ	ω_ψ	q_ϕ	q_θ	q_ψ
Tolygiems orientacijos pokyčiams								
σ_T	42,0	45,9	30,0	28,2	59,1	30,2	27,2	58,1
Atsitiktiniams orientacijos pokyčiams								
σ_A	75,4	74,3	66,2	197,2	73,1	66,1	38,1	61,7

Pagal pirmoje lentelėje pateiktus rezultatus, esant tiek tolygiems, tiek atsitiktiniams orientacijos pokyčiams, dauguma orientacijos įverčių standartinio nuokrypio rezultatų, naudojant kvaternionų sprendimą, yra mažiausi. Mažesnė standartinio nuokrypio reikšmė rodo nedidelį duomenų pokytį nuo vidutinės reikšmės, todėl gradientinis nusileidimo algoritmas (kvaternionų pagrindu) yra patikimesnis nei orientacijos įvertinimas, naudojant atskirų jutiklių duomenis. Pagal tikslingus orientacijos pokyčius, tik kampo ϕ standartinis nuokrypis, naudojant giroskopą (ω_ϕ), rodo geresnį rezultatą nei kvaterniono (q_ϕ) sprendimas. Tokia situacija galima dėl sąlyginai trumpo ~30 sekundžių eksperimento, todėl giroskopo įverčiai nenukrypo nuo tikrųjų reikšmių. Per minėtą laiko intervalą nuskaityti 1989 duomenys kas 0,015 s. Gradientinio nusileidimo algoritmo taikymo atveju (kvaternionų pagrindu) minėti jutiklių trūkumai sumažinami, todėl, priklausomai nuo įvertintos kameros orientacijos,

galima patikimai pritaikyti pateikiant virtualų turinį bežymekliame papildytos realybės sprendime, 28 pav.



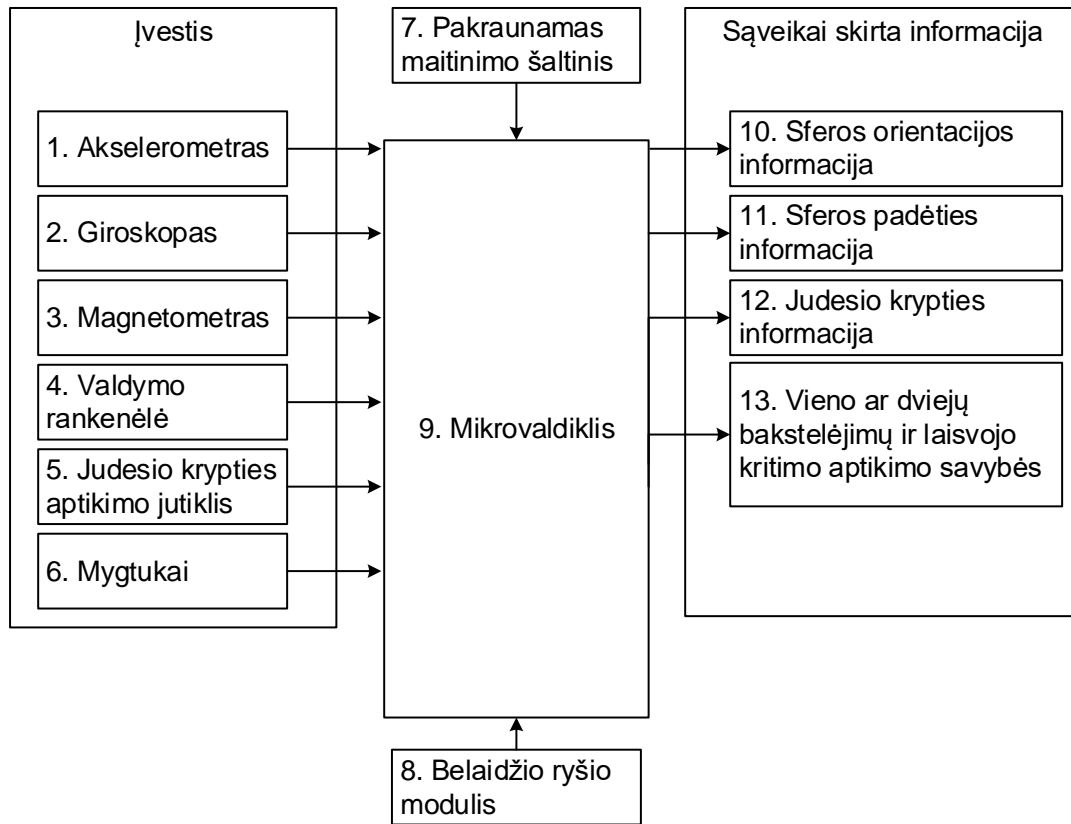
28 pav. Bežymekliame papildytos realybės sprendime visais atvejais virtualus turinys atvaizduojamas savo pradinės padėties: a) pradinė kameros, mikrovaldiklio su jutkliais ir virtualaus turinio padėtis; b), c) kameros orientacija pagal kampą ϕ ; d) kameros orientacija pagal kampą θ ; e), f) kameros orientacija pagal kampą ψ

Pateiktame bežymekliame papildytos realybės sprendime neatliekamas joks vaizdų apdorojimas. Tokia jutiklinė sistema yra visiškai savarankiška, matavimai nėra ribojami nei judesių, nei specifinės aplinkos ar vietos. Tolesniame darbo tyrime numatyta Kalmano filtrą taikyti vaizdo ir jutiklių duomenų ne tik įvertinti orientaciją, bet ir poziciją erdvėje. Tokiu būdu tikimasi praplėsti papildytos realybės taikymo galimybes bei sąveikavimo su turiniu būdus

2.5. Objekto orientacijos nustatymo sprendimo taikymas sferos formos įrenginiui


Disertacijoje gautų jutiklių duomenų sujungimo tyrimo rezultatų pagrindu buvo sukurtas sferos formos sąveikos įrenginys. Skyriuje norima pademonstruoti, kad disertacijos tyrimų rezultatai aktualūs ne tik teoriškai, bet atskiri tyrimo fragmentai gali būti pritaikyti plėtoti įrenginį ar įrenginius, skirtus sąveikauti su skaitmeniniu turiniu ar kita technine įranga. Tokio prietaiso viduje įtaisytų jutiklių (akselerometrui, giroskopui ir magnetometrui) matavimų duomenims pritaikytas kvaternionų sprendimas, kad galima būtų patikimai nustatyti sferos formos įrenginio pasukimus įvairiomis kryptimis. Sąveikaujant su turiniu ar kita technine įranga tas prietaisas laikomas rankoje bei laisvai judinamas įvairiomis kryptimis erdvėje. Sferos formos

įrenginio konstrukcija (vidiniai elementai), skirti jo funkcionalumui užtikrinti, pateikti 29 pav.



29 pav. Sferos formos sąveikos įrenginio vidinės dalies elementai

Akselerometro, giroskopo ir magnetometro jutiklių padėtis turi būti horizontali ir centruota įrenginio viduje, kad patikimai įvertintume įrenginio pasukimus erdvėje x , y ir z ašių atžvilgiu. Norint, kad tas prietaisas būtų pakankamai funkcionalus, galima parinkti skirtingą jo modifikaciją: integruoti papildomą judesio krypties atpažinimo jutiklį arba valdymo rankenėlę. Įrenginys savo konstrukcija, elementų išdėstymu ir nedideliu svoriu užtikrina ergonomišką, patogų, nevarginantį rankos ir intuityvų naudojimo būdą. Prietaisas turi vieno ir dviejų bakstelėjimų į korpusą aptikimo galimybes bei laisvojo kritimo nustatymo funkciją – tai dar labiau praplečia įrenginio funkcionalumą. Pagal įrenginiu gaunamą informaciją atliekama atitinkama nustatyta funkcija, kuri belaidžiu ryšiu perduodama į informaciją priimančią įrenginį. Tokiu būdu praplečiamas ir gerinamas sąveikavimas su skaitmeniniu turiniu ar technine įranga, įgalinami skirtingi veikimo režimai bei taikymo galimybės. Sferos formos įrenginių prototipai pateikti 30 pav.



30 pav. Sferos formos įrenginių, skirtų sąveikauti su skaitmeniniu turiniu ar kita technine įranga, prototipai

Įrenginio pateikiami duomenys visiškai nepriklauso nuo išorinių sąlygų, užtikrintas belaidis ryšys, mobilumas ir ilgesnis veikimo laikas, o tai yra kitų, toliau analizuotų analogų trūkumas:

1) Žinomas analogas, skirtas sąveikauti su skaitmeniniu turiniu ar kita technine įranga atliekant tiek kūno, tiek rankų judesio sekimą kompiuterinės regos metodų pagrindu, pateiktas (US2011150271 A1, 2011) patente. Pagrindinis trūkumas – judesio sekimas priklauso nuo įvairių aplinkos sąlygų, turi ribotą darbo erdvę, nėra užtikrinamas mobilumas, t. y. naudojamas tik patalpų viduje ir negali sekti mažos amplitudės judesių, pavyzdžiui, riešo pasukimų.

2) Panašaus pobūdžio sistema ir metodai, skirti sekti rankų, pirštų ar į pirštus panašius objektus trimatėje erdvėje, pateikta (US2013182902 A1, 2013) patente. Nors sprendimas užtikrina didelį sekimo tikslumą bei greitį, pagrindinis sistemos trūkumas – ribota darbo erdvė, kuri siekia tik apie vieną metrą.

3) Patentuose (US2011150271 A1, 2011) ir (US2013182902 A1, 2013) nėra galimybės perduoti duomenis belaidžiu ryšiu. Tai reikalauja papildomos tarpinės kompiuterinės įrangos, valdant įvairią techninę įrangą, pavyzdžiui, skraidymo aparatus ar robotus. Taip pat gestų atpažinimas ir objektų sekimas nėra visuomet tiksliai ir patikimai užtikrinami kompiuterinės regos metodų pagrindu dėl skirtingų aplinkos sąlygų.

4) Kitame žinomame analoge pateiktas metodas ir judesio valdiklis-įrenginys (WO1997021166 A1, 1997) patente, kuriame atliekamas judesio sekimas bei gestų atpažinimas, norint valdyti virtualaus kūno judesius. Pagrindinis trūkumas – funkcijos užtikrinamos esant tik staigiems įrenginio judesiams bei nėra prieinami tikslūs orientacijos duomenys x, y ir z ašių atžvilgiu – tai sumažina įrenginio funkcionalumą.

Kitaip nei įvardytų 4 skirtingų analogų trūkumai, siūlomo įrenginio neriboja konkreti darbo erdvė. Šis prietaisas gali būti naudojamas tiek patalpų viduje, tiek išorėje. Jį naudojant galima tiksliai manipuluoti tiek 2D/3D skaitmeniniu turiniu, tiek valdyti kompiuterio žymeklį ar kitą techninę įrangą.

Artimiausias pateiktam siūlomam sprendimui sąveikos įrenginys pateiktas (US20140236393 A1, 2014) patente, kuriame sąveikauti su programine-technine įranga naudojama orientacijos informacija. Pagrindinis šio analogo trūkumas – veikdamas ir taikomas šis įrenginys sunaudoja daug elektros energijos, todėl realus naudojimo laikas yra mažesnis nei viena valanda. Tai svarbus aspektas jį naudojant ir sukonstruoto prietaiso veikimo laikas yra ilgesnis – 3 valandos. Svarbu paminėti, kad dėl tų pačių konstrukcinių įrenginio elementų, turinčių įtakos naudojant, yra padidėjęs viso įrenginio svoris, dėl to prietaisas yra lengvesnis už artimiausią analogą, o tai reiškia – ir ergonomiškesnis naudojant rankoje. Taip pat galima pabrėžti, kad siūlomo įrenginio konstrukcijoje nėra jokių judančių dalių, todėl nėra galimybės atsirasti papildomai inercijai jį pakreipiant, o tai gali turėti įtakos skaitmeninio turinio ar techninės įrangos valdymo tikslumui kritiniais atvejais.

Šiuo sferos formos įvesties-sąveikos įrenginiu aktyvuojama informacija nauju būdu, nenaudojant kompiuterio pelės, klaviatūros ar liečiant jautrius ekranus. Šis įrenginys nebūtinai skirtas visiškai pakeisti šias priemones, labiau – naudoti kartu. Didžiausias siūlomo įvesties-sąveikos prietaiso privalumas yra plačios pritaikymo galimybės įvairiose srityse. Sukonstruotas įrenginys išbandytas toliau pateiktais taikymo atvejais:

1) 2D/3D skaitmeninio turinio, galimai virtualių trimačių objektų, sumodeliuotų pagal realius objektus, manipuliavimas virtualiojoje arba papildytoje realybėje. Šiuo atveju 2D/3D skaitmeninis turinys gali būti peržiūrimas iš skirtingų perspektyvų, atliekamos didinimo, mažinimo, pakreipimo, pasukimo ir kitos funkcijos.

2) Įvesties-sąveikos įrenginys, skirtas kompiuterio žymekliui valdyti. Kitaip nei esamuose kompiuterio pelių analoguose, siūlomas įvesties-sąveikos įrenginys pasižymi savybe, kad žymeklis valdomas ore ir tam nereikalingas joks paviršius. Mygtukų paspaudimai gali būti pakeičiami bakstelėjimais į įrenginio korpusą. Laisvojo kritimo aptikimo galimybė, kai prietaisas išmetamas į viršų ir pagaunamas, naudojamas sąveikavimo režimams pakeisti. Integruoti jutikliai leidžia nustatyti pakreipiamo objekto orientaciją, todėl naudotojui reikia tik nedidelio riešo pasukimo, norint valdyti kompiuterio žymeklį.

3) Žaidimų ar kitos techninės įrangos valdiklis, pavyzdžiui, skraidančių aparatų ar robotų valdymas judinant įvesties-sąveikos įrenginį įvairiomis kryptimis.

Išvardytus taikymo atvejus galima pažiūrėti nuorodoje, pateiktoje *Įvade* → *Darbo rezultatų praktinė reikšmė (6 punktas)*.

2.6. Kalmano filtro naudojimas sekant objektų orientaciją

Kalmano filtras žinomas dėl galimybės per deterministinį modelį pašalinti triukšmą iš matavimų bei prognozuoti tolesnę sistemos būseną pagal ankstesnius būsenos įverčius. Pagrindinis Kalmano filtro tikslas – minimizuoti matavimo klaidas, remiantis žiniomis apie būseną, ir vidurkinti perteklinius matavimus. Kalmano filtro optimalus taikymo atvejis yra tas, kuriame:

- a) modelis puikiai atitinka realią sistemą;
- b) įverčių triukšmas yra Gauso;
- c) triukšmo kovariacijos yra tiksliai žinomos.

Nustačius kovariacijas, naudinga įvertinti filtro našumą, t. y. būsenos įvertinimo kokybę. Kalmano filtrui veikiant optimaliai, inovacijų seka yra Gauso triukšmas. Gauso triukšmo savybė nurodo būsenų įvertinimo kokybę. Pagrindiniai Kalmano filtro taikymo aspektai:

- 1) Kalmano filtre matavimai pasikartoja vienodais laiko periodais, tačiau nežinoma, kas vyksta tarp konkrečių laiko periodų, o pats procesas rekursyvus.
- 2) Procesų ir matavimo procesai paveikti Gauso triukšmo.

- 3) Kalmano filtras vykdo prognozavimą, gaudamas tikrus matavimus, palygina su proceso modelio reikšmėmis, pakoreguoja skirtumą ir nustato naują pakoreguotą įvertį.
- 4) Tikslus situacijos matematinio modelio apibrėžimas suteikia tikslesnius Kalmano filtro rezultatus, t. y. įverčiai konverguoja prie tikrosios reikšmės.

Kalmano filtro metodas naudojamas navigacijoje, realaus laiko sistemose kaip vaizdų apdorojimo pagrindas, sujungiant skirtingų jutiklių duomenis, prognozuojant objektų judėjimo trajektorijas, išvengiant kelių autonominių transporto priemonių susidūrimo, apie susidūrimus įspėjančiose sistemose, perplanuojant kelią, įvertinant skraidančių autonominių aparatų ar kitų objektų orientaciją-poziciją, sekant raketas, bendru atveju – įvairiose triukšmingose sistemose (Fonseca, J.V.; Oliveira, R.C.L.; Abreu, J.A.P.; Ferreira, E.; Machado, M., 2013), (Abreu, J.A.P.; Neto, J.V.F.; Limão Oliveira, R.C., 2011), (Araguas, G.; Paz, C.; Gaydou, D.; Paina, G. P., 2013), (Zhou, Qing-Li; Zhang, Y.; Qu, Yao-Hong; Rabbath, C., 2010), (Belokon, S. A.; Zolotukhin, Yu. N.; Kotov, K. Yu.; Mal'tsev, A. S.; Nesterov, A. A.; Pivkin, V. Ya.; Sobolev, M. A.; Filippov, M. N.; Yan, A. P., 2013), (Prevost, C.G.; Desbiens, A.; Gagnon, E., 2007), (Atev, S.; Arumugam, H.; Masoud, O.; Janardan, R.; Papanikolopoulos, N.P., 2005), (Carvalhosa, S.; Aguiar, A. P.; Pascoal, A., 2010). Adaptyvus Kalmano filtro metodas plačiai naudojamas kompleksiškai apdorojant dviejų ar daugiau jutiklių informaciją, pavyzdžiui, navigacijoje GPS dažniausiai naudojamas kartu su inercinių jutiklių informacija (Bistrovs, V., 2008), (Sabatini, A. M., 2011).

2.7. Diskretusis Kalmano filtras

Kalmano filtras sprendžia bendrąją problemą, susijusią su diskretaus laiko proceso būsenų \hat{x}_k įvertinimu, kuris valdomas tiesinių stochastinių skirtuminių lygčių (angl. *difference equation*) (35, 36):

$$\hat{x}_k = A\bar{x}_{k-1} + Bu_k + w_k, \quad (35)$$

$$z_k = Hx_k + v_k, \quad (36)$$

čia: A – būsenų perėjimo matrica; B , u_k – atitinkamai valdymo matrica ir valdymo vektorius; \hat{x}_k – būsenos prognozės vektorius, paveiktas triukšmo w_k ; \bar{x}_{k-1} – būsenos atnaujinimo vektorius; z_k – matavimo vektorius, paveiktas triukšmo v_k ; H – matavimų matrica. Diskrečiajame Kalmano filtre w_k ir v_k atitinkamai yra proceso ir matavimo

Gauso triukšmų, kurie nepriklauso vienas nuo kito. Gauso triukšmo tankio funkcija išreiškiama (37):

$$f(x|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad (37)$$

čia μ – vektoriaus vidurkis; σ – standartinis nuokrypis, kuris paskaičiuojamas naudojant (38) išraišką:

$$\sigma = \sqrt{E[(x - \mu)^2]}, \quad (38)$$

čia x – atitinkamai konkreti triukšmo vertė w_k arba v_k . Nepriklausomų triukšmų w_k ir v_k normalieji tikimybiniai skirstiniai (angl. *normal probability distributions*) pateikti (39, 40) išraiškose:

$$p(w_k) \sim N(\mu, Q), \quad (39)$$

$$p(v_k) \sim N(\mu, R), \quad (40)$$

čia Q – proceso triukšmo kovariacijos matrica; R – matavimo triukšmo kovariacijos matricos gali keistis kiekviename matavimo etape, tačiau tyrimuose dažniausiai priimamos prielaidos, kad jos yra pastovios. Proceso Q ir triukšmo R kovariacijų matricos išreiškiamos atitinkamai per triukšmą w_k ir v_k . Triukšmo parinkimas priklauso nuo to, kaip tiksliai apibrėžti proceso ir matavimo modeliai. Praktiškai įgyvendinant filtrą, matavimo klaidos kovariacija dažniausiai matuojama anksčiau nei pradėdamas naudoti filtras. Galima praktiškai pamatuoti matavimo klaidos kovariaciją, norint nustatyti matavimo triukšmo nuokrypį.

$\hat{x}_k \in R^n$ žymi apriorinį (nepriklausantį nuo bandymų) būsenos įvertį k laiko momentu su duotomis proceso žiniomis prieš k laiko momentą, o $\bar{x}_k \in R^n$ yra aposteriorinis (priklausantis nuo bandymų) būsenos įvertis k laiko momentu su matavimu z_k . Galima apibrėžti apriorinio ir aposteriorinio įvertio paklaidas $\hat{e}_k = x_k - \hat{x}_k$ ir $e_k = x_k - \bar{x}_k$.

Sudarant lygtis Kalmano filtrui, pagrindinis tikslas rasti lygtį, kuri paskaičiuoja aposteriorinį būsenos įvertį \bar{x}_k kaip tiesinę kombinaciją apriorinio įvertio \hat{x}_k ir įvertinto skirtumo tarp tikrojo matavimo z_k ir matavimo prognozės $H\hat{x}_k$ (41):

$$\bar{x}_k = \hat{x}_k + K_k(z_k - H\hat{x}_k), \quad (41)$$

Čia K_k – Kalmano filtro koeficientas; $z_k - H\hat{x}_k$ skirtumas, kuris vadinamas matavimo inovacija arba liekana. Liekana yra neatitikimas tarp prognozuoto matavimo

$H\hat{x}_k$ ir tikrojo matavimo z_k . Nulio vidurkio liekana žymi, kad tarp jų yra sutapimas. Skirtumą siekiama minimizuoti naudojant Kalmano koeficientą K_k (42):

$$K_k = \hat{P}_k H^T (H \hat{P}_k H^T + R)^{-1} = \frac{\hat{P}_k H^T}{H \hat{P}_k H^T + R}, \quad (42)$$

čia H^T – transponuota matavimų matrica, \hat{P}_k – prognozės būsenų įverčių kovariacijų matrica. Pagal pastarąją išraišką matoma, kad artėjant matavimo paklaidos kovariacijai R prie nulio, K_k koeficiento įtaka liekanai didesnė (43):

$$\lim_{R \rightarrow 0} K_k = H^{-1}. \quad (43)$$

Ir atvirkščiai – kai apriorinis paklaidos kovariacijos \hat{P}_k įvertis artėja prie nulio, K koeficiento įtaka liekanai mažesnė (44):

$$\lim_{\hat{P}_k \rightarrow 0} K_k = 0. \quad (44)$$

Matavimo paklaidos kovariacijai R artėjant prie nulio, tikruoju matavimu z_k pasitikima daugiau, o prognozės matavimu $H\hat{x}_k$ pasitikima mažiau. Arba atvirkščiai – jeigu apriorinės paklaidos kovariacijos įvertis \hat{P}_k artėja prie nulio, tai tikruoju matavimu z_k pasitikima mažiau, o prognozės matavimu $H\hat{x}_k$ pasitikima daugiau (Welch, G.; Bishop, G., 2006).

Galutinis Kalmano filtro algoritmo įvertis yra prognozės-atnaujinimo algoritmas, skirtas spręsti įvairias problemas. Kalmano filtras plačiai taikomas ne tik įvertinti stochastinės dinaminės sistemos būsenas, bet ir modelio parametrus, aptinkant staigius būsenų ar parametrų pokyčius. Modeliuojant Kalmano filtrą didžiausias dėmesys skiriamas sudarant sistemos proceso ir matavimo modelius. Tai labai svarbus aspektas nustatyti proceso Q ir matavimo R triukšmo kovariacijų matricų reikšmes, pradinį būsenos vektorių \bar{x}_0 bei paklaidos kovariacijos matricą \hat{P}_0 .

Filtro tikimybinė kilmė. Tikimybinis apriorinis įvertis \hat{x}_k sąlygojamas visų ankstesnių matavimų z_k . Kalmano filtras užtikrina du būsenų skirstinių aspektus:

- 1) posteriorinis būsenos įvertis \bar{x}_k nurodo būsenos skirstinio vidurkį $E[x_k] = \bar{x}_k$;
- 2) posteriorinis paklaidos kovariacijos įvertis nurodo būsenos skirstinio nuokrypį (45):

$$E[(x_k - \bar{x}_k)(x_k - \bar{x}_k)^T] = \bar{P}_k. \quad (45)$$

Kalmano filtro lygtys užtikrina būsenos \hat{x}_k ir paklaidos kovariacijos \hat{P}_k įverčius rekursyviai. Įvertis ir jo kokybė priklauso nuo sistemos parametrų ir triukšmo statistikos. Kai nėra patikimos statistikos arba tikrųjų triukšmo kovariacijų matricių reikšmių Q ir R , gaunama išraiška nebeužtikrina tikrosios kovariacijos paklaidos (46):

$$\bar{P}_k = (I - K_k H) \bar{P}_{k-1} (I - K_k H)^T + K_k R K_k^T, \quad (46)$$

čia I – identiškumo matrica; \bar{P}_k – atnaujinimo kovariacijų matrica.

Realaus laiko aplikacijose Kalmano filtre naudojamos kovariacijų matricos skiriasi nuo tikrojo kovariacijų matricių triukšmo. Robastiškumas nustatomas pagal paklaidos kovariacijos įvertinimo elgseną, kai triukšmo kovariacijos bei sistemos matricos A ir H įvedamos į filtrą neteisingai. Kalmano filtro būsenų įverčiai nustatomi esant neaiškiai apibrėžtomis statistinėms ir parametrinėms įvestims.

Kalmano koeficiento K_k išvedimas. Kalmano filtras įvertina minimalią vidutinę kvadratinę paklaidą. Kalmano koeficiento K_k skaičiavimas yra ekvivalentas minimizuojant kovariacijos matricos posteriorinį įvertį \bar{P}_k . Praplečiant \bar{P}_k (59) išraišką gaunama (47):

$$\bar{P}_k = \bar{P}_{k-1} - K_k H \bar{P}_{k-1} - H^T K_k^T + K_k S_k K_k^T, \quad (47)$$

čia $S_k = H \bar{P}_{k-1} H^T + R_k$. Pėdsakas (angl. *trace*) minimizuojamas, kai matricos \bar{P}_k išvestinė, priklausomai nuo koeficiento K_k , yra 0. Pagal gradientines matricos taisykles ir matricos simetriją gauname (48):

$$\frac{\partial \text{tr}(\bar{P}_k)}{\partial K_k} = -2(H \bar{P}_{k-1})^T + 2K_k S_k = 0. \quad (48)$$

Sprendžiant K_k Kalmano koeficientą gauname (49) išraišką:

$$K_k = H^T \bar{P}_{k-1} S_k^{-1}. \quad (49)$$

Optimalus Kalmano koeficientas suteikia mažiausių kvadratų metodo įverčius.

2.8. Kalmano filtro Q ir R parametrų derinimas

Q ir R atitinkamai yra proceso ir matavimo triukšmo kovariacijų matricos. Kalmano filtro realizacijose matavimo triukšmo kovariacija R dažniausiai pamatuojama prieš filtro vykdymą. Matavimo paklaidos kovariaciją R (matavimo triukšmo nuokrypį) galima nustatyti, nes būtina pamatuoti procesą, kai skaičiavimai jau vykdomi.

Proceso triukšmo kovariacijos Q nustatymas yra sudėtingesnis, nes nėra galimybės tiesiogiai stebėti procesą, kurį norime įvertinti. Kartais santykinai prastas proceso modelis gali suteikti priimtinus rezultatus, jeigu bus įvedama pakankamai neužtikrintumo į procesą per Q kovariacijos pasirinkimą. Žinoma, šiuo atveju bus tikimasi, kad proceso stebėjimai yra patikimi.

Bet kuriuo atveju, nepriklausomai nuo to, ar turimas racionalus pagrindas parenkant parametrus, dažnai geresnis filtro našumas gali būti pasiektas derinant filtro Q ir R parametrus. Derinimas daugiausiai atliekamas netiesiogiai (angl. *off-line*). Bendru atveju, pagal Q ir R pastovias sąlygas, tiek klaidos kovariacijos įvertis P_k , tiek Kalmano koeficientas K_k greitai stabilizuosis ir liks pastovus. Tada šie parametrai gali būti suskaičiuojami iš anksto, nustatant stabilios būsenos P_k reikšmę. Tai dažnas atvejis, tačiau matavimo paklaida nelieka pastovi. Proceso triukšmas Q kartais keičiasi dinamiškai per filtro operacijas, norint prisitaikyti prie skirtingos sistemos dinamikos. Pagrindiniai Q ir R apskaičiavimo būdai:

1) Priimamos prielaidos, kad R žinomas, norint įvertinti Q , arba atvirkščiai. R gali būti paskaičiuotas apdorojant matavimus, kol sistemos išvestis yra pastovi. Šiuo atveju, kai vidurkis pašalinamas, lieka tik triukšmas ir gali būti paskaičiuojama kovariacija.

2) Autokoreliacijos funkcija naudojama inovacijų sekoms, norint įvertinti Q ir R . Šios sistemos inovacijų sekos naudojamos netiesiogiai įvertinti kovariacijų matricas Q ir R .

Mokslinėje literatūroje yra daug metodų, skirtų sudaryti Kalmano filtrą, jeigu kovariacijų matricos Q ir R nežinomos (Bos, R.; Bombois, X.; Van den Hof, P. M. J., 2005). Metodai skirstomi į dvi pagrindines klases:

1) Pirmoje metodų klasėje apibrėžiamos Q ir R matricos, tuomet šie parametrai yra įvertinami naudojant matavimo duomenis.

2) Antroji metodų klasė apibrėžia Kalmano koeficientą K . Pagrindinis privalumas – sistema visiškai stebima, todėl K koeficientas bus identifikuojamas, o Q ir R – ne.

Parametrų įvertinimo metodai skirstomi į keturias kategorijas:

1) Bajeso įvertinimas (angl. *Bayesian Estimation*) (Sarkka, S. and Hartikainen, J., 2013).

2) Maksimalaus tikėtinumo įvertinimas (angl. *Maximum Likelihood Estimation*) (Won, Joong-Ho; Lim, J.; Kim, Seung-Jean; Rajaratnam, B., 2009).

3) Prognozės klaidos identifikavimas (angl. *Prediction Error Identification*) (Oussalah, M.; De Schutter, J., 2000).

4) Koreliacijos ar kovariacijos atitikimas (angl. *Correlation or covariance matching*) (Wang, J. G.; Gopaul, S. N.; Guo, J., 2010).

Lyginant modelio prognozės vertes su realiais matavimais galima įvertinti Q , kurio reikšmės parinkimas nustato, kaip tiksliai apibrėžtas modelis. Kuo tiksliau sudarytas modelis, tuo geriau įvertinamas tikrasis procesas, todėl Q reikšmė parenkama mažesnė. Jeigu sudarytas proceso modelis turi klaidų, tai Q reikšmė yra didesnė, t. y. pasitikėjimas prognozavimu mažesnis ir, atvirkščiai, R – mažesnė, t. y. pasitikėjimas matavimo duomenimis didesnis. Nors pasitikėjimas matavimų duomenimis skirtingas, dalis triukšmo vis tiek pašalinama. Dažnu atveju matavimo klaida nelieka pastovi. Proceso triukšmas keičiasi, kad filtras prisitaikytų prie skirtingos dinamikos. Šiuo atveju Q gali būti skirtas aprašyti tiek vartotojo ketinimus, tiek modelio neužtikrintumą.

2.9. „Sunkių uodegų“ Kalmano filtre

Metodai, skirti objektams sekti, dažniausiai sudaryti būtent pagal Gauso triukšmo prielaidas tiek sistemos proceso, tiek matavimo modeliams. Tai suprantama iš analitinės patogumo pusės, nes Gauso paklaida ir struktūra yra tiksli ir aiški Kalmano filtro tyrimo rezultatuose. Standartiniu Kalmano filtro atveju priimamos prielaidos, kad triukšmas yra atsitiktinis su žinomomis Gauso skirstinio savybėmis. Vienintelė sąlyga, pagal kurią Kalmano filtras nėra našus, – „sunkių uodegų“ (angl. *heavy-tail*) triukšmas (Gordon, N.; Percival, J.; Robinson, M., 2003) esant klaidingiems duomenims. Net retais atvejais neįprastai dideli stebėjimai (nenormalus triukšmas) labai sumažina Kalmano filtro našumą. Toks atvejis sukelia nepakankamus būsenos įverčius, ne Gauso liekanas ir nepagrįstas išvadas. Ignoruoti neįprastus stebėjimus nėra priimtina statistiškai, nes tokie stebėjimai gali turėti vertingos informacijos kitoms sistemos charakteristikoms, modelio sutrikimams, matavimo klaidoms ir pan. Aptikti neįprastus stebėjimus įmanoma tik tuomet, kai lyginimas atliekamas pagal tendencijas ar elgseną. Pagrindiniai keliami tikslai, norint atsižvelgti į klaidingus duomenis:

- 1) būti kuo arčiau optimalumo, kai nėra klaidingų duomenų;
- 2) atsparumas klaidingiems duomenims, kai jų atsiranda.

Ankstesni atlikti „sunkių uodegų“ šalinimo tyrimai Kalmano filtre mažina Kalmano filtro klaidingų duomenų efektą atmetant stebėjimus, kurių liekanos yra per

didelės (*Ad-hoc* metodas), iki labiau formalių metodų, kurių pagrindą sudaro neparametrinė statistika, Bajeso metodai ar minimakso teorija (Bavdekar, V. A.; C. Patwardhan, S., 2010).

Ad-hoc metodas sumažina neteisingų duomenų įtaką Kalmano filtre. Paprasčiausias būdas tai atlikti – atmesti stebėjimus, kurių liekana per didelė. Tokiu būdu, prognozuojamas įvertis \hat{x}_k nebūtų atnaujinamas pagal z_k , jeigu netenkinama toliau pateikta sąlyga (50):

$$\bar{y}_k^T \sigma^{-1} \bar{y}_k > \beta, \quad (50)$$

čia β – teigiama slenkstinė riba; \bar{y}_k – atnaujinimo liekana (Kalmano filtro matavimo ir atnaujinimo įverčių skirtumas). Ekvivalentiškai Kalmano filtro būsenos \bar{x}_k įverčių atnaujinimą per matavimą z_k galime išreikšti taip (51):

$$\bar{x}_k = \hat{x}_k + K_k \psi_n(z_k - H\hat{x}_k), \quad (51)$$

čia ψ_n – įtaką ribojanti funkcija, kuri yra tiesinė tarp kai kurių nuo laiko priklausančių slenkstinių ribų, pavyzdžiui, kovariacijos. Pagrindiniai *Ad-hoc* metodo trūkumai:

- 1) trūksta tinkamo būdo parinkti slenkstinę ribą – dažniausiai naudojama tris kartus didesnis standartinis nuokrypis;
- 2) nepanaudojama informacija, kuri patenka už numatytos slenkstinės ribos, todėl kai kuriais atvejais gali sumažėti Kalmano filtro našumas;
- 3) jeigu žinoma informacija apie neteisingų duomenų statistines savybes, tuomet galima išgauti informacijos iš neteisingų duomenų stebėjimų. Šių duomenų atmetimas gali būti ne pats tinkamiausias būdas, o dažnas rezultatas – netinkamos kovariacijų matricos.

Be *Ad-hoc* metodo, rekursyviai įvertinti naudojamas Bajeso metodas, kur nebūtinai yra Gauso triukšmas, bet žinomos jo statistinės savybės. Įverčiai gali būti gauti iš Bajeso karkaso, kur stebėjimai naudojami atnaujinti ankstesnę informaciją. Šių įvertinimų parametrai parenkami pagal tam tikrą našumo kriterijų. Neparametriniai metodai taikomi tuomet, kai statistinės triukšmo savybės yra visiškai nežinomos, žinomos iš dalies arba galimai žinomos, bet yra labai sudėtingos. Minimakso metodas yra kitas būdas išspręsti problemą, esant nevisoms žinioms apie triukšmo statistines savybes. Jame pasirenkama klasė skirstinių ir išskiriamas įvertis, kurio blogiausio atvejo našumas yra optimumas. Matavimo triukšmo R kovariacijos matricos derinimas

yra paprasčiausias būdas mažinti neteisingų duomenų įtaką. Kalmano filtro rekursijoje gautas koeficientas K_n sumažina neteisingų duomenų įtaką. Deja, tai sukelia visų stebėjimų įtakos sumažėjimą, o tokiu būdu nėra labai efektyviai naudojami matavimo duomenys, kai jie yra tinkami (Bavdekar, V. A.; C. Patwardhan, S., 2010).

Kitais atvejais priimamos prielaidos, kad neteisingi matavimai vyksta retai ir santykinai priklauso nuo filtro dinamikos. Pavyzdžiui, mažai tikėtina, kad įvyks du neteisingi matavimai per mažesnę laiko tarpą nei Δt tarp matavimų. Tai reiškia, kad įvertinimas yra robastiškas esant retiems ir izoliuotiems neteisingiems matavimams, bet ne tuomet, kai sunkios uodegos (neteisingi matavimai) įvyksta vienas po kito. Tai svarbus apribojimas. Esant „sunkių uodegų“ matavimo triukšmui, našumas pagerėja ir priklauso nuo konkrečios taikymo srities (Roth, M.; Ozkan, E.; Gustafsson, F., 2013).

Būsenų įvertinime vienas neteisingas stebėjimas neturi daryti įtakos filtro dinamikai. Visų liekanų sekos turi likti Gauso, kai triukšmo stebėjimas yra normaliojo skirstinio, išskyrus pasitaikančius neteisingus duomenis. Neteisingi duomenys gali būti sugeneruoti tokiu būdu (52, 53):


$$w_k \sim \begin{cases} N(0, Q), \text{ su } 0,95 \text{ tikimybe} \\ N(0, 1000Q), \text{ su } 0,05 \text{ tikimybe,} \end{cases} \quad (52)$$

$$v_k \sim \begin{cases} N(0, R), \text{ su } 0,90 \text{ tikimybe} \\ N(0, 1000R), \text{ su } 0,10 \text{ tikimybe.} \end{cases} \quad (53)$$

Pagal Gauso skirstinį sugeneruoti proceso w_k ir matavimo v_k triukšmai paveikti neteisingų duomenų. 5% proceso ir 10% matavimo triukšmo realizacijos gaunamos iš Gauso skirstinio su keliais kartais padidintomis kovariacijų matricomis Q ir R . Iš taikymo perspektyvos, „sunkių uodegų“ triukšmo skirstiniai naudojami modeliuoti neteisingus matavimo duomenis iš nepatikimų jutiklių, staigių pokyčių iš nežinomų įvesties signalų, kurių efektas sukeltas sudėtingų realaus pasaulio procesų. Neteisingi duomenys, kurių reikšmės yra toli nuo vidurkio, negali būti sugeneruoti Gauso skirstiniu. Tokie neteisingi duomenys gali atsirasti daugybėje signalų apdorojimo atvejų, todėl pagrįstai tiriami ne Gauso skirstiniai su „sunkiomis uodegomis“, pavyzdžiui, t -skirstinys, kuris turi panašią savybių į Gauso.

2.10. Kalmano filtro taikymas jutiklių duomenims įvertinti ir eksperimentų rezultatai

Egzistuoja daug sprendimų, kurie nagrinėja orientacijos nustatymo problemas (Madgwick, S. O. H., 2010), (Comotti, D., 2011), (Jurman, D.; Jankovec, M.; Kamnik, R.; Topič, M., 2007), (Choukroun, D.; Bar-Itzhack, I. Y.; Oshman, Y., 2006), (Kong, X., 2004). Šiame skyriuje Kalmano filtras taikomas kvaternionams, norint patikimai nustatyti objektų orientaciją trimatėje erdvėje, naudojant inercinių jutiklių duomenis. Kalmano filtro taikymas jutiklių orientacijos duomenims bus atliekamas 31 pav. pateiktu principu.



31 pav. Kalmano filtro taikymas jutiklių duomenims

Pateiktoje diagramoje būsenų atnaujinimo vektorius \bar{x}_k su matavimais iš giroskopo paduodamas į būsenos \hat{x}_k prognozavimo lygtį (35), o akselerometro ir magnetometro duomenų vektoriui pritaikytas gradientinio nusileidimo metodas, kuris detaliau nagrinėjamas 2.11 skyriuje. Gauti akselerometro ir magnetometro vektoriaus įverčiai paduodami į Kalmano filtrą, kaip matavimas z_k , į būsenų atnaujinimo \bar{x}_k lygtį (41). Šio Kalmano filtro taikymo kontekste jutiklių orientacijos duomenys (empiriniai) išreiškiami naudojant kvaternionus. Sistemos būsenos pradinis vektorius yra kvaternionas q_t (54):

$$q_t = \begin{bmatrix} q_0 \\ q_1 \\ q_2 \\ q_3 \end{bmatrix}, \quad (54)$$

čia pradinio q_k kvaterniono elemento realioji dalis $q_0 = 1$; trys menamosios kvaterniono dalys $q_1 = q_2 = q_3 = 0$. Įverčių prognozavimo etape išreikšti kampinį greitį kvaternionu naudojama toliau pateikta (55) išraiška:

$$\dot{q}_t = \begin{pmatrix} \dot{q}_0 \\ \dot{q}_1 \\ \dot{q}_2 \\ \dot{q}_3 \end{pmatrix} = \frac{1}{2} q_{t-1} \otimes \omega_a, \quad (55)$$

čia \dot{q}_t – kampinio greičio kvaternionas; q_{t-1} – vėliausiai paskaičiuotas kvaternionas; \otimes – kvaternionų sandauga; $\omega_a = [0, \omega_x, \omega_y, \omega_z]^T$ – kampinio greičio vektorius esamu laiku t . Kampinio greičio kvaternionas paskaičiuojamas kas Δt matavimo periodą ir, norint prognozuoti būsenos reikšmę, naudojame (56) išraišką:

$$\hat{x}_k = \bar{x}_{k-1} + \dot{q}_t \Delta t. \quad (56)$$

Kalmano filtro būsenų perėjimo matrica A šiuo atveju apibrėžiama tokiu būdu (57):

$$A = \begin{bmatrix} 1, & -\frac{1}{2}\omega_x \Delta t, & -\frac{1}{2}\omega_y \Delta t, & -\frac{1}{2}\omega_z \Delta t \\ \frac{1}{2}\omega_x \Delta t, & 1, & \frac{1}{2}\omega_z \Delta t, & -\frac{1}{2}\omega_y \Delta t \\ \frac{1}{2}\omega_y \Delta t, & -\frac{1}{2}\omega_z \Delta t, & 1, & \frac{1}{2}\omega_x \Delta t \\ \frac{1}{2}\omega_z \Delta t, & \frac{1}{2}\omega_y \Delta t, & -\frac{1}{2}\omega_x \Delta t, & 1 \end{bmatrix}. \quad (57)$$

Norint sumodeliuoti proceso triukšmą w_k yra įvertinamas giroskopo nukrypimas x, y ir z ašių atžvilgiu, tuomet paskaičiuojama Q kovariacijų matrica pagal naudojamų ašių įverčius (58):

$$Q = E \left[\begin{bmatrix} -\omega_x - \omega_y - \omega_z \\ \omega_x - \omega_y + \omega_z \\ \omega_x + \omega_y - \omega_z \\ -\omega_x + \omega_y + \omega_z \end{bmatrix} \cdot \begin{bmatrix} -\omega_x - \omega_y - \omega_z \\ \omega_x - \omega_y + \omega_z \\ \omega_x + \omega_y - \omega_z \\ -\omega_x + \omega_y + \omega_z \end{bmatrix}^T \right]. \quad (58)$$

Priimama prielaida, kad $E[\omega_i] = 0$ (giroskopo nuokrypis paskaičiuotas ir pašalintas iš matavimo, norint turėti labai mažą nuokrypį nuo $0.1^\circ/s$ iki $0.2^\circ/s$) ir $E[\omega_i \cdot \omega_j] = 0$. Kovariacijos matrica Q gali būti paskaičiuojama pagal (59):

$$Q = \begin{bmatrix} \omega_x^2 + \omega_y^2 + \omega_z^2 & -\omega_x^2 + \omega_y^2 - \omega_z^2 & -\omega_x^2 - \omega_y^2 + \omega_z^2 & \omega_x^2 - \omega_y^2 - \omega_z^2 \\ -\omega_x^2 + \omega_y^2 - \omega_z^2 & \omega_x^2 + \omega_y^2 + \omega_z^2 & \omega_x^2 - \omega_y^2 - \omega_z^2 & -\omega_x^2 - \omega_y^2 + \omega_z^2 \\ -\omega_x^2 - \omega_y^2 + \omega_z^2 & \omega_x^2 - \omega_y^2 - \omega_z^2 & \omega_x^2 + \omega_y^2 + \omega_z^2 & -\omega_x^2 + \omega_y^2 - \omega_z^2 \\ \omega_x^2 - \omega_y^2 - \omega_z^2 & -\omega_x^2 - \omega_y^2 + \omega_z^2 & -\omega_x^2 + \omega_y^2 - \omega_z^2 & \omega_x^2 + \omega_y^2 + \omega_z^2 \end{bmatrix}. \quad (59)$$

Šiame etape Kalmano filtro prognozavimo išraiška apibrėžiama naudojant (60):

$$\hat{x}_k = A \bar{x}_{k-1}. \quad (60)$$

Šiuo atveju valdymo vektoriaus u_k bei valdymo matricos B nėra, nes duomenys nėra imituojami, o eksperimentuojama su realiais iš jutiklio nuskaitytais duomenimis, kurių rezultatai skiriasi priklausomai nuo objekto orientacijos pokyčių. Prognozavimo paklaidos kovariacija paskaičiuojama pagal (61) išraišką:

$$\hat{P}_k = (A\bar{P}_{k-1}A^T) + Q. \quad (61)$$

Matavimo etapas susideda iš keturių kvaterniono elementų, kurie gaunami iš akselerometro ir magnetometro matavimo duomenų. Norint paskaičiuoti orientacijos kvaternioną, naudojant akselerometro ir magnetometro matavimus, naudojamas gradientinio nusileidimo algoritmas. Stebėjimo matrica H lygi identiškumo matricai I , kadangi būsenos erdvė atitinka stebėjimų erdvę, t. y. jie abu rodo kvaterniono orientaciją trimatėje erdvėje (62):

$$H = I = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (62)$$

Būsenų atnaujinimo etape Kalmano filtras koreguoja prognozuotą būseną \hat{x}_k , naudojant paskaičiuotus stebėjimus (63, 64):

$$\bar{x}_k = \hat{x}_k + K(z_t - H\hat{x}_k), \quad (63)$$

$$K_k = \hat{P}_k H^T (H\hat{P}_k H^T + R)^{-1}, \quad (64)$$


čia \hat{P}_k prognozavimo kovariacijų matrica. Atnaujinimo kovariacijų matrica \bar{P}_k paskaičiuojama naudojant (65):

$$\bar{P}_k = (I - KH)\hat{P}_k, \quad (65)$$

čia I – identiškumo matrica ($I = H$).

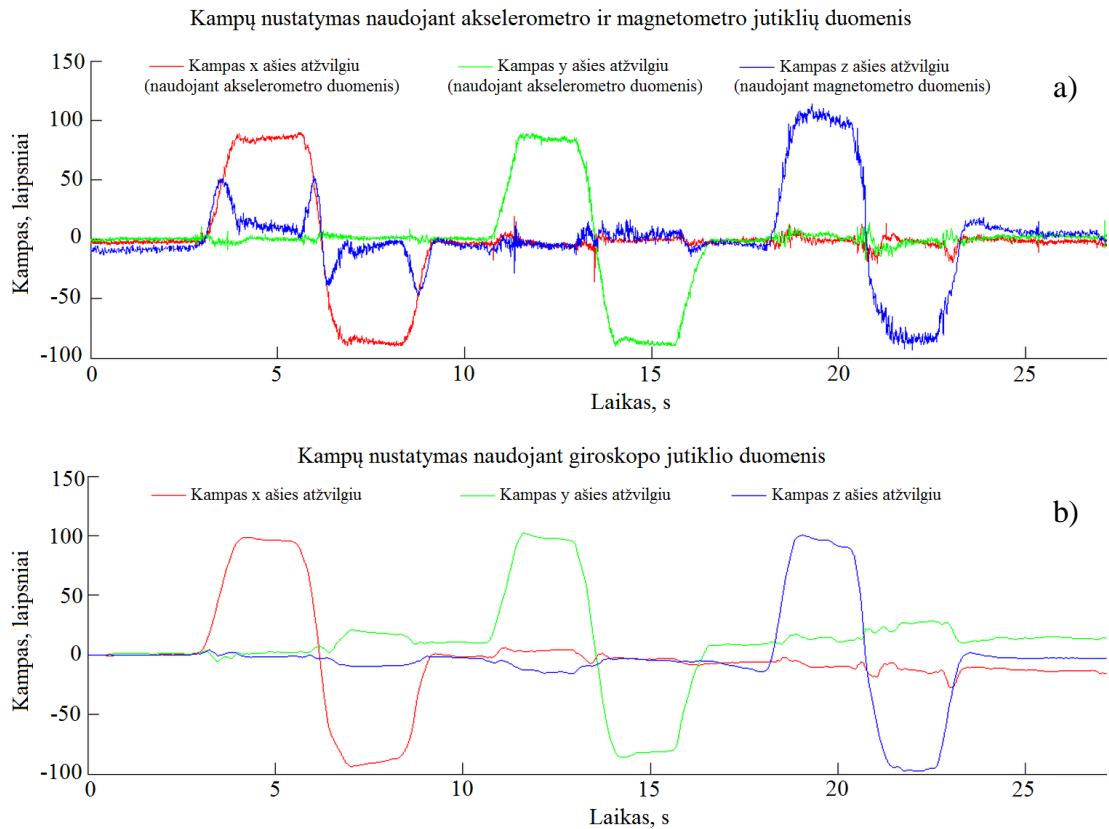
Jeigu matavimo triukšmas yra didelis, K koeficientas bus mažas, todėl matavimo duomenimis pasitikima mažiau, ir atvirkščiai. Akselerometras ir magnetometras nėra tiesiogiai įtraukiami į būsenų modelį, todėl, norint gauti geriausius rezultatus, reikia empiriniu būdu išmėginti kelių reikšmių stebėjimų kovariacijos R matricas. Kadangi R yra naudojamas skaičiuojant Kalmano priaugį K , bus naudojamas $I \cdot 1 \times 10^{-2}$, kad nuslopinti mažus nuokrypius apie įvertį. Taip pat svarbu akcentuoti, kad norint gauti tikslus rezultatus, labai svarbu parinkti tinkamas reikšmes algoritmo inicializavimo metu. Parinktas pradinės būsenos vektorius $x_0 = [1, 0, 0, 0]$, kovariacijos matrica $P_0 = I$, o atnaujinimo nuokrypis $R = I \cdot 1 \times 10^{-2}$.

Toliau atliktas eksperimentas su 6959 duomenų matavimais naudojant akselerometrą, giroskopą ir magnetometrą. Šie jutiklių matavimų duomenys viešai publikuojami (Madgwick, S. O. H., 2010) darbe. Neapdoroti jutiklių duomenys pateikti 32 pav.







32 pav. Neapdoroti jutiklių duomenys: giroskopo kampinis greitis; akselerometro pagreitis; magnetometro magnetinio srauto tankis

Jutiklių matavimų eksperimento trukmė yra apie 25 sekundės, jo metu objektas buvo pasukamas skirtingomis ašimis. Šie gauti neapdoroti kampinio greičio, pagreičio bei magnetinio srauto tankio matavimai naudojant (17) ir (18) išraiškas leidžia įvertinti objekto pasukimo kampą (orientaciją). Orientacijos nustatymas (Eulerio kampų) pagal esamus jutiklių duomenis, nenaudojant Kalmano filtro, pateiktas 33 pav.



33 pav. Eulerio kampai pagal akcelerometro, magnetometro ir giroskopo matavimus


Pirmuoju (a) akcelerometro ir magnetometro kampų įvertinimo atveju matomi triukšmingi įverčiai, o antruoju (b) giroskopo įvertinimo atveju – diverguoti įverčiai. Norint eliminuoti triukšmingus ir diverguotus įverčius, naudojamas Kalmano filtras jutiklių matavimams išreikštiems kvaternionu. Kalmano filtro taikymo rezultatai kvaternionams, (67–78) išraiškų pagrindu, pateikti 34 pav.



34 pav. Kalmano filtro taikymas kvaterniono elementams q_0 , q_1 , q_2 ir q_3

Kreivėje (a) kvaterniono elementas q_0 nurodo kampo dydžio pokytį, o kvaterniono elementai q_1 , q_2 ir q_3 atitinkamai nurodo kampo pokytį x (b), y (c) ir z (d) ašių atžvilgiu.

Stebėjimų rezultatai (pagal akselerometrą ir magnetometrą) gauti naudojant gradientinio nusileidimo metodą, galutinis rezultatas (naudojant giroskopa) įvertinamas naudojant Kalmano filtrą. Palyginti Eulerio kampų atžvilgiu pateikti vienos ašies atžvilgiu akselerometro, giroskopo ir Kalmano filtro rezultatai 35 pav.



35 pav. Kampo θ palyginimas naudojant Kalmano filtrą

Kalmano filtru siekiama užtikrinti optimalų balansą tarp matavimų ir jų įvertinimų. Kalmano filtro pritaikymas akselerometro, magnetometro ir giroskopo duomenims suteikia tikslesnę objekto orientacijos informaciją, nes jutiklių duomenys atsparesni triukšmui ir nuokrypiams, nei naudojant jutiklius atskirai. Lyginant Kalmano filtro įvertinimo klaidas su atskaitos duomenų reikšmėmis, galima nustatyti orientacijos sekimo klaidas. Orientacijos nustatymo efektyvumas gali būti derinamas optimizuojant jų parametrus, pavyzdžiui, proceso Q ir matavimo R triukšmų kovariacijos derinimas labai svarbus sistemos būsenoms įvertinti.

2.11. Gradientinio nusileidimo metodo taikymas matavimo reikšmei nustatyti

Gradientinio nusileidimo metodas aprašomas tokia forma (66):

$$x_{k+1} = x_k - \lambda_k \nabla f(x_k), \quad (66)$$

čia x_k – ankstesnė parametro, pagal kurį optimizuojama, reikšmė; x_{k+1} – nauja parametro reikšmė; $\nabla f(x_k)$ – tikslo funkcijos pokytis; λ_k – žingsnio dydis, kuris gali būti pastovus arba keičiamas kiekviename etape. Gradientinio nusileidimo metodo atveju greitai artėjama prie minimumo, tačiau konvergavimas taps labai lėtas, kai bus arti sprendinio.

Atlikto (Madgwick, S. O. H., 2011) tyrimo pagrindu gradientinis nusileidimo metodas pateiktas toliau. Trijų ašių giroskopas matuoja kampinį greitį x , y ir z ašių atžvilgiu. Atitinkamai įvesti žymėjimai ω_x , ω_y , ω_z ir suformuotas s_{ω_t} vektorius (67), o kvaternionas \hat{q}_t aprašo orientacijos pokyčio dydį, kuris skaičiuojamas naudojant (68) išraišką:

$$s_{\omega_t} = [0, \omega_{x_t}, \omega_{y_t}, \omega_{z_t}], \quad (67)$$

$$\dot{q}_t = \frac{1}{2} \hat{q}_{t-1} \otimes s_{\omega_t}, \quad (68)$$

čia \hat{q}_{t-1} – vėliausiai paskaičiuotas kvaternionas; pradinis kvaternionas $t = 1$ laiko momentu yra $\hat{q}_0 = [1 \ 0 \ 0 \ 0]$, s_{ω_t} – kampinis greitis esamu laiko momentu t ; \otimes – kvaternionų sandauga. Iš to seka, kad orientaciją giroskopo duomenų pagrindu galima paskaičiuoti naudojant tokią kvaterniono q_t išraišką (69):

$$q_t = \hat{q}_{t-1} + \dot{q}_t \Delta t, \quad (69)$$

čia Δt – laiko intervalas tarp matavimų. Toliau įvertinant orientaciją algoritme priimama prielaida, kad akselerometras matuoja tik sunkio jėgą (angl. *gravity*), o magnetometras tik Žemės magnetinį lauką. Kvaternionui gauti sprendžiama optimizavimo problema, norint nustatyti jutiklio orientaciją pagal (70) ir tikslo funkcijos (71) išraiškas:

$$\min_{q \in R^4} f(\hat{q}, e_d, s_\omega), \quad (70)$$

$$f(\hat{q}, e_d, s_\omega) = \hat{q}^* \otimes e_d \otimes \hat{q} - s_\omega. \quad (71)$$

Gradientinio nusileidimo algoritmas n iteracijoms siekiant įvertinti orientaciją \hat{q}_{n+1} , kurio pagrindą sudaro pradinė orientacijos reikšmė \hat{q}_0 ir kintamasis dydžiu μ paskaičiuojamas naudojant (72) išraišką:

$$\hat{q}_{k+1} = \hat{q}_k - \mu \frac{\nabla f(\hat{q}_k, e_d, s_\omega)}{\|\nabla f(\hat{q}_k, e_d, s_\omega)\|}, k = 0, 1, 2 \dots n \quad (72)$$

Atsižvelgiant į tikslo funkciją $f(\hat{q}, e_d, s_\omega)$ ir Jakobianą J , paskaičiuojama paklaida (73):

$$\nabla f(\hat{q}_k, e_d, s_\omega) = J^T(\hat{q}_k, e_d) f(\hat{q}_k, e_d, s_\omega) \quad (73)$$

Lygtys (72) ir (73) yra apibendrinta algoritmo forma. Tinkama sąlyga galima laikyti, kad gravitacijos jėga yra vertikali z ašis, kaip pateikta $e_g = [0, 0, 0, 1]$. Normalizuotus akselerometro matavimus atitinkamai pažymime $s_a = [0, a_x, a_y, a_z]$. Naudojant akselerometro matavimus, gaunamos atitinkamos gradientinio nusileidimo metodo (74) ir (75) išraiškos:

$$f_g(q, e_g, s_a) = \begin{bmatrix} 2(q_1 q_3 - q_0 q_2) - a_x \\ 2(q_0 q_1 + q_2 q_3) - a_y \\ 2(0.5 - q_1^2 - q_2^2) - a_z \end{bmatrix}, \quad (74)$$

$$J_g(q) = \begin{bmatrix} -2q_2 & 2q_3 & -2q_0 & 2q_1 \\ 2q_1 & 2q_0 & 2q_3 & 2q_2 \\ 0 & -4q_1 & -4q_2 & 0 \end{bmatrix}. \quad (75)$$

Žemės magnetinis laukas turi komponentes horizontalioje ir vertikalioje ašyje, todėl pažymime $e_b = [0, b_x, 0, b_z]$. Normalizuoti magnetometro parodymai $s_m = [0, m_x, m_y, m_z]$. Naudojant magnetometro matavimus, gaunamos atitinkamos gradientinio nusileidimo metodo (76) ir (77) išraiškos:

$$f_b(q, e_b, s_m) = \begin{bmatrix} 2b_x(0.5 - q_2^2 - q_3^2) + 2b_z(q_1 q_3 - q_0 q_2) - m_x \\ 2b_x(q_1 q_2 - q_0 q_3) + 2b_z(q_0 q_1 + q_2 q_3) - m_y \\ 2b_x(q_0 q_2 + q_1 q_3) + 2b_z(0.5 - q_1^2 - q_2^2) - m_z \end{bmatrix}, \quad (76)$$

$$J_b(q, e_b) = \begin{bmatrix} -2b_z q_2, & 2b_z q_3, \\ -2b_x q_3 + 2b_z q_1, & 2b_x q_2 + 2b_z q_0, \\ 2b_x q_2, & 2b_x q_3 - 4b_z q_1, \\ -4b_x q_2 - 2b_z q_0, & -4b_x q_3 + 2b_z q_1 \\ 2b_x q_1 + 2b_z q_3, & -2b_x q_0 + 2b_z q_2 \\ 2b_x q_0 - 4b_z q_2, & 2b_x q_1 \end{bmatrix} \quad (77)$$

Tik gravitacijos arba Žemės magnetinio lauko matavimai neužtikrintų tikslios jutiklio orientacijos, todėl matavimai ir abiejų laukų kryptys turi būti sujungti pagal

(78) ir (79). Tikslo funkcijos sprendiniai f_g ir f_b turi būti apibrėžti atitinkamai pagal (78) ir (79) išraiškas, kur $b_x \neq 0$:

$$f_b(\hat{q}, e_g, s_a, e_b, s_m) = \begin{bmatrix} f_g(\hat{q}, s_a) \\ f_b(\hat{q}, e_b, s_m) \end{bmatrix}, \quad (78)$$

$$J_b(\hat{q}, e_b) = \begin{bmatrix} J_g^T(\hat{q}) \\ J_b^T(\hat{q}, e_b) \end{bmatrix}. \quad (79)$$

Gradientinis nusileidimo metodas reikalauja kelių lygties (77) iteracijų kiekvienai naujai orientacijai ir atitinkamiems jutiklių matavimams. Žingsnio dydis μ su kiekviena iteracija artėja prie optimalios reikšmės. Kiekvienoje iteracijoje konvergavimo laikas valdomas pagal μ_t , kuris yra lygus arba didesnis nei tikrasis orientacijos pokyčių fizinis dydis. Pagal (77) lygtį įvertinta orientacija $q_{\nabla,t}$, paskaičiuota laiku t , kurios pagrindą sudaro ankstesnis orientacijos įvertinimas $q_{\text{est},t-1}$ ir tikslo funkcijos gradientas ∇f , apibrėžtas pagal jutiklio matavimus s_{a_t} ir s_{m_t} laiku t (80, 81):

$$q_{\nabla,t} = \hat{q}_{\text{est},t-1} - \mu \frac{\nabla f}{\|\nabla f\|}, \quad (80)$$

$$\nabla f = \begin{cases} J_g^T(\hat{q}_{\text{est},t-1})f_g(\hat{q}_{\text{est},t-1}, s_{a_t}) \\ J_{g,b}^T(\hat{q}_{\text{est},t-1}, e_b)f_{g,b}(\hat{q}_{\text{est},t-1}, s_{a_t}, e_b, s_{m_t}) \end{cases} \quad (81)$$

Optimali μ_t reikšmė gali būti apibrėžta, norint užtikrinti $q_{\nabla,t}$ konvergavimo greitį, ir apribotas fizinės orientacijos dydžio, nes išvengiama nereikalingai didelio žingsnio. Žingsnis μ_t paskaičiuojamas naudojant (82) išraišką:

$$\mu_t = \alpha \|\dot{q}_{\omega,t}\| \Delta t, \alpha > 1, \quad (82)$$

čia Δt – laiko tarpas tarp matavimų; $\dot{q}_{\omega,t}$ – kampinis greitis, pamatuotas girokopu; $\alpha - \mu$ papildymas, kuris yra akselerometro arba magnetometro matavimų triukšmas.

2.12. Skyriaus išvados

1. Analizė parodė, kad naudoti pavienių jutiklių matavimų duomenis, objektų orientacijai nustatyti – nėra patikimas sprendimas.

2. Įvertinti ir palyginti eksperimentiniai atskirų jutiklių ir jutiklių duomenų sujungimo orientacijų rezultatai. Pagal atliktų eksperimentų, pateiktų diagramose, ir skaičiavimų rezultatus parodyta, kad orientacijai įvertinti naudotas Kalmano filtras, kurio tikslo funkcija minimizuojama su gradientinio nusileidimo metodu jutiklių

(akselometro, magnetometro, giroskopo) masyvo matavimų sujungimui, eliminuoja atskirų jutiklių matavimų trūkumus: triukšmą bei matavimų divergavimą.

3. Pateiktas kameros orientacijos sekimo sprendimas, kuris gali būti pritaikytas bežymekliuose papildytos realybės sprendimuose. Šis sprendimas nenaudoja jokio požymių išskyrimo metodo ir yra suderintas su atvaizduojamu turiniu be jokio pastebimo delsimo. Pademonstruotas šio sprendimo taikymas ne tik sekti objektą (kamerą) papildytos realybės srityje, bet taip pat parodyta galimybė adaptuoti jį sąveikos įrenginiui, skirtą manipuluoti skaitmeniniu turiniu ar valdyti kitus įrenginius.

III. Hibridinis objektų sekimo metodas papildytos realybės sistemose naudojant Kalmano filtrą

Papildyta realybė yra specialus skaitmeninio turinio atvaizdavimo būdas, kuriame sekamo realus objekto atžvilgiu įterpiamas virtualus turinys vaizde. Daugelis papildytos realybės atliktų tyrimų nagrinėja problemas, susijusias su objektų atpažinimu ir sekimu požymių išskyrimo metodų pagrindu, ir sąveikos su virtualiu turiniu metodais, naudojant įvairius įrenginius. Pagrindinės tiriamos problemos išskiriant ir sutapdinant požymius susijusias su konkrečių objektų vaizdo transformacijomis, okliuzijomis ir apšvietimu aplinkoje, o tai turi neigiamą įtaką naudojant papildytos realybės sprendimus, kai virtualus turinys dingsta.

Sekimo metodai suteikia galimybę tinkamoje orientacijoje ir pozicijoje atvaizduoti skaitmeninį (arba virtualų) turinį, keičiant vartotojo žiūrėjimo perspektyvą, o sąveikos metodai suteikia galimybę tuo turiniu manipuliuoti. Šiuo metu įgyvendinti papildytos realybės objekto sekimo sprendimai yra požymių išskyrimo metodų pagrindu, pavyzdžiui: *SIFT*, *SURF*, *FAST*, *Ferns* ir kitos įvardintų metodų pagrindu atliktos modifikacijos, pavyzdžiui, *FAST-ER* (angl. *Features from Accelerated Segment Test - Enhanced Repeatability*), *SLAM* ir pan. (Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V., 2008), (Rosten, E.; Porter, R.; Drummond, T., 2010), (Klein, G. and Murray, D., 2007), (Wagner, D.; Reitmayr, G.; Mulloni, A.; Drummond, T.; Schmalstieg, D., 2010). Kiekviename požymių išskyrimo metodo pagrindu esančiame papildytos realybės sprendime būtina atsižvelgti į šias pagrindines užduotis:


- 1) aptikti ir sekti objektą aplinkoje;
- 2) pateikti skaitmeninį turinį priklausomai nuo sekamo objekto orientacijos ir pozicijos erdvėje;
- 3) užtikrinti galimybę sąveikauti su skaitmeniniu turiniu.

Turi būti tuo pačiu metu išspręstos kelios problemos, norint sekti objektą realiomis aplinkos sąlygomis: apšvietimo lygis, vaizdo transformacijos dėl skirtingų kameros vaizdo peržiūros perspektyvų, vaizdo kokybė, atspindžiai bei dalinės okliuzijos. Dėl šių aplinkos sąlygų aptinkama mažiau pastovių požymių bei atitikimų tarp skirtingų kameros peržiūros vietų toje pačioje aplinkoje, siekiant, kad objekto sekimas būtų patikimas. Skaitmeninis turinys neatvaizduojamas, jeigu objekto sekimas nutrūksta. Požymių išskyrimo metodų greitaveika taip pat yra kritinis aspektas, nes papildytos realybės sistemose visos užduotys turi būti atliktos realiu laiku.

Priklausomai nuo papildytos realybės taikymo sričių, galima išskirti kelis sekimo metodus. Pavyzdžiui, ultragarsinio sekimo metodas (Lukosiunas, E. et al., 2011) skirtas sekti konkrečių objektų poziciją erdvėje. Šiuo metu objektų judesio sekimas, naudojant skaitmeninius inercinius jutiklius, taip pat yra aktyvi tyrimų sritis, kuri analizuojama šiuose darbuose (Hol, J. D. et al., 2006), (Madgwick, S. O. H., 2011). Greiti ir netolygūs kameros judesiai sukelia sekimo klaidų kompiuterinės regos metodų atveju. Ši problema gali būti išspręsta naudojant inercinius jutiklius, kai vyksta greiti kameros orientacijos pakitimai. Kameros sekimas naudojant inercinius jutiklius yra tinkamas metodas dėl didelio matavimų greičio, tačiau labai svarbu išlaikyti stabilumą po ilgesnio laiko tarpo. Jutikliai paveikiami triukšmo, nuokrypių ir magnetinės interferencijos. Integruojant ir sujungiant kelių jutiklių informaciją, atskirų jutiklių trūkumai eliminuojami su jutiklių sintezės sprendimais (Sabatini, A. M., 2006), (Zhou, F.; Duh, H.B.-L.; Billingham, M., Sept. 2008), (Bleser, G.; Stricker, D., 2008). Tokiu būdu įmanoma užtikrinti patikimus orientacijos įverčius.

Sudarant hibridinį objekto sekimo metodą šiame skyriuje nagrinėjamas orientacijos ir pozicijos informacijos panaudojimas, kuris buvo gautas kompiuterinės regos ir jutiklių duomenų sujungimo metodais susistemintu būdu naudojant Kalmano filtrą. Tyrime atlikti eksperimentai su priimtomis prielaidomis, kad objektas gali būti atpažintas ir sekamas naudojant *SURF* požymių išskyrimo metodą 20 kadrų per sekundę. Tai yra turi trūkumą greičio atžvilgiu, o požymių išskyrimo bei sutapdinimo ir jutiklių duomenų sujungimo orientacijos-pozicijos sekimo informacija yra imituojama su tikėtinomis klaidomis realaus naudojimo sąlygomis. Bendru atveju, pademonstruota, kaip gautus klaidingus arba laikinai neprieinamus orientacijos-pozicijos įverčius kompiuterinės regos metodo pagrindu galima atitinkamai papildyti naudojant jutiklių duomenų sujungimo metodo suteikiamą informaciją. Objekto sekimo uždavinys naudojant orientacijos ir pozicijos įverčius bei metodo taikymas papildytos realybės srityje yra pagrindiniai analizuojami aspektai šiame etape. Gauti hibridinio objektų sekimo metodo naudojant Kalmano filtrą tyrimo rezultatai palyginti su baziniais duomenimis atskirai naudojamų požymių išskyrimo ir sutapdinimo bei jutiklių duomenų sujungimo metodų atžvilgiu. Pateiktos papildančios pasiūlyto hibridinio objekto sekimo metodo naudojant Kalmano filtrą savybės ir įvestos Kalmano filtro inovacijos parametrai sąlygos, norint gauti patikimus orientacijos-pozicijos įverčius.

Iš vartotojo perspektyvos papildytos realybės sistemose svarbūs du pagrindiniai aspektai: a) sistema privalo veikti realiu laiku, t. y. be jokio uždelsimo; b) sekimas turi būti patikimas net esant staigiems kameros judesiams ar sekamo objekto okliuzijoms vaizde. Šiems aspektams hibridinis sekimo metodas turi užtikrinti nepertraukiamą veikimą, kai virtualus turinys atvaizduojamas papildytoje realybėje. Matavimai iš jutiklių naudojami siekiant pagerinti iš kompiuterinės regos metodo gautą informaciją. Konceptinė hibridinio objekto sekimo metodo naudojant Kalmano filtrą diagrama pateikta 36 pav.



36 pav. Hibridinis objekto sekimo metodas naudojant Kalmano filtrą: orientacijos ir pozicijos įvertinimas naudojant kompiuterinės regos ir jutiklių duomenų sujungimo metodus

Pateiktas hibridinis objekto sekimo metodas naudojant Kalmano filtrą apibendrintas modelis. Gaunami x_{sf} ir x_{cv} orientacijos ir pozicijos vektoriai jutiklių duomenų sujungimo bei kompiuterinės regos metodų pagrindu ir naudojami konstruojant Kalmano filtrą, taip gaunant atnaujintą orientacijos ir pozicijos vektorių x_{KF} Kalmano filtro pagrindu. Orientacijos ir pozicijos vektorių x_{sf} ir x_{cv} gavimas bei Kalmano filtro pagrindu vektoriau x_{KF} įvertinimas detalizuotas atitinkamai 3.1, 3.2 ir 3.3 poskyriuose. Tikslingai pritaikyti hibridinį objekto sekimo metodą naudojant Kalmano filtrą priimamos toliau pateiktos prielaidos:

- 1) Kameros ir jutiklių kalibracija atlikta iš anksto.

2) Jutikliai yra pritvirtinti prie kameros, todėl laikoma, kad jutiklių ir kameros koordinačių sistemos (centrai) sutampa.

3) Taikant kompiuterinės regos ir jutiklių duomenų sujungimo metodus, duomenys gaunami ir apdorojami lygiagrečiai. Apdorotų duomenų gavimo dažnis f_{cv} iš kompiuterinės regos metodo yra 20 Hz ($\Delta t = 0,05$), o jutiklių duomenų sujungimo metodo f_{sf} yra 100 Hz ($\Delta t = 0,01$). Duomenų gavimas imituojamas.

4) Aplinkoje juda kamera su pritvirtintais jutikliais, bet ne pats sekamas objektas aplinkoje požymių ištraukimo ir sutapdinimo metodo pagrindu. Taip yra todėl, kad vien tik judančio vaizde objekto atžvilgiu jutiklių matavimai nesuteiktų jokios naudingos informacijos apie kameros padėties pokyčius, jeigu kamera būtų stacionarios padėties.

Kompiuterinės regos metodo atveju (toliau *CV* – pagal *Computer Vision* termino trumpinį) santykinė kameros orientacijos-pozicijos informacija įvertinama iš surasto sekamo objekto vaizde, o jutiklių duomenų sujungimo metodo (toliau *SF* – pagal *Sensor Fusion* termino trumpinį) atveju ši informacija užtikrinama tiesiogiai iš judančios kameros aplinkoje. Atitinkamai toliau tiek *CV* ir *SF* orientacijos-pozicijos informacija imituojama nuo bendro pradžios taško.

3.1. Kameros orientacijos ir pozicijos įvertinimas (sekimas) jutiklių duomenų sujungimo atveju

Objekto orientacijos įvertinimas, šiuo atveju kameros, naudojant skaitmeninius jutiklius, yra populiari tyrimų sritis. Skaitmeninis akselerometras matuoja pagreitį ir gravitacijos pagreitį (arba laisvojo kritimo pagreitį). Pagal akselerometro gautus pagreičio matavimus, orientacijos vektorius $a_{\phi, \theta} = [a_{\phi_t}, a_{\theta_t}]^T$ įvertinamas naudojant (83) išraišką:

$$a_{\phi, \theta} = \begin{bmatrix} a_{\phi_t} \\ a_{\theta_t} \end{bmatrix} = \begin{bmatrix} \arctan \left(a_{y_t} / \sqrt{a_{x_t}^2 + a_{z_t}^2} \right) \\ \arctan \left(a_{x_t} / \sqrt{a_{y_t}^2 + a_{z_t}^2} \right) \end{bmatrix}, \quad (83)$$

čia a_{x_t} , a_{y_t} , a_{z_t} – akselerometro išvestis x , y ir z ašių atžvilgiu esamu laiko momentu t ; a_{ϕ_t} , a_{θ_t} – objekto pasukimo kampas (rotacija) atitinkamai x ir y ašių atžvilgiu. Stabilioje būsenoje akselerometro matavimai paveikiami triukšmo, todėl a_{ϕ_t} ir a_{θ_t} orientacijos įverčiai gali būti klaidingi ir nepatikimi. Gravitacijos pagreitis nesuteikia jokios informacijos apie a_{ψ_t} (rotacija z ašies atžvilgiu) orientaciją.

Pradiniai giroskopo kampinio greičio matavimai nėra paveikiami triukšmo, todėl neakumuliuoja klaidų. Objekto orientacijos vektorius $\omega_{\phi, \theta, \psi} = [\omega_{\phi_t}, \omega_{\theta_t}, \omega_{\psi_t}]^T$ įvertinamas naudojant (84) išraišką:

$$\omega_{\phi, \theta, \psi} = \begin{bmatrix} \omega_{\phi_t} \\ \omega_{\theta_t} \\ \omega_{\psi_t} \end{bmatrix} = \begin{bmatrix} \omega_{\phi_{t-1}} + \omega_{x_t} \Delta t \\ \omega_{\theta_{t-1}} + \omega_{y_t} \Delta t \\ \omega_{\psi_{t-1}} + \omega_{z_t} \Delta t \end{bmatrix}, \quad (84)$$

čia $\omega_{x_t}, \omega_{y_t}, \omega_{z_t}$ – giroskopo kampinis greitis esamu laiko momentu t ; $\omega_{\phi_{t-1}}, \omega_{\theta_{t-1}}, \omega_{\psi_{t-1}}$ – orientacijos įvertis ankstesniu laiko momentu $t - 1$; $\omega_{\phi_t}, \omega_{\theta_t}, \omega_{\psi_t}$ – objekto pasukimo kampas (rotacija) atitinkamai x ir y ašių atžvilgiu; Δt – laiko tarpas tarp matavimų.

Tik trumpais laiko tarpais įvertinta orientacija, naudojant giroskopo kampinio greičio matavimus, yra tiksli. Po tam tikro laiko, nuokrypis eksponentiškai didėja ir be fiksuotos atskaitos klaidos akumuliuojamos. Papildytos realybės sekimo sistemoje tai yra kritinis aspektas.

Magnetometro krypties b_{ψ} įvertis paskaičiuojamas naudojant (85) išraišką:

$$b_{\psi} = -\arctan\left(\frac{m_{y_t} \cos(a_{\phi_t}) \sin(a_{\theta_t}) - m_{z_t} \sin(a_{\phi_t})}{m_{x_t} \cos(a_{\theta_t}) + m_{y_t} \sin(a_{\phi_t}) \sin(a_{\theta_t}) + m_{z_t} \cos(a_{\phi_t}) \sin(a_{\theta_t})}\right), \quad (85)$$

čia: $m_{x_t}, m_{y_t}, m_{z_t}$ – magnetinio lauko matavimai naudojant skaitmeninį magnetometrą x, y ir z ašių atžvilgiu t laiko momentu. Pagrindinis skaitmeninių magnetometrų trūkumas – magnetinio lauko matavimai iškraipomi dėl aplinkoje esančių feromagnetinių objektų. Šiuos magnetinio lauko iškraipymus galima kompensuoti naudojant giroskopą. Akselerometro kampų įverčiai leidžia paskaičiuoti b_{ψ} esant skirtingam objekto pasukimo kampui ir magnetometro padėtis nebūtinai turi būti horizontali.

Norint užtikrinti patikimą kameros orientaciją 3D erdvėje, skaitmeninių jutiklių (akselerometro, giroskopo, magnetometro) matavimų informacija naudojama neatsiejamai. Giroskopo orientacijos nuokrypis pašalinamas naudojant akselerometrą, kuris pataiso ϕ ir θ orientacijos kampus. Magnetometro ir akselerometro gauta informacija užtikrina pataisyta krypties ψ matavimą. Tai yra pagrindinis jutiklių duomenų sujungimo aspektas, kur matavimai išreikšti naudojant kvaternionus. Kvaternionų naudojimas užtikrina trumpesnę skaičiavimų laiką, patikimą orientacijos įvertinimą ir išlaiko stabilumą lyginant su Eulerio kampų arba rotacijos matricių

išraiškomis. Kvaternioną q galima išreikšti kaip keturių elementų vektorių $q = [q_0, q_1, q_2, q_3] = [w, xi, yj, zk]$, kur $q_0(w)$ nustato orientacijos pasikeitimo greitį; $q_1(x)$, $q_2(y)$, $q_3(z)$ – rotacija atitinkamai x , y ir z ašių atžvilgiu. Įvertinta orientacija gradientinio nusileidimo metodo pagrindu, naudojant kvaternionų išraiškas, pateikta 2.11 poskyryje, todėl detalesnė analizė šiame skyriuje nepateikiama. Sistemos, kurios naudoja tokius orientacijos įvertinimo metodus, nėra apribotos judesio, specifinės aplinkos, vietos ar okliuzijų, todėl tai pagrindinis privalumas lyginant su požymių išskyrimo metodais.

Kameros pozicijos įvertinimas naudojant vien tik akselerometro duomenis yra sudėtinga užduotis. Jau minėta, kad akselerometro išvestis matuoja pagreitį ir gravitaciją tuo pačiu metu, todėl labai svarbu pašalinti gravitacijos jėgą norint gauti tiesinį pagreitį. Jeigu visi matavimai iš jutiklių masyvo (akselerometro, giroskopo ir magnetometro) prieinami, tuomet gravitacijos vektorius $g = [g_x, g_y, g_z]^T$ įvertinamas naudojant (86) išraišką:

$$g = \begin{bmatrix} g_x \\ g_y \\ g_z \end{bmatrix} = \begin{bmatrix} 2q_1q_3 - 2q_0q_2 \\ 2q_0q_1 + 2q_2q_3 \\ q_0^2 - q_1^2 - q_2^2 + q_3^2 \end{bmatrix}, \quad (86)$$

čia q_0, q_1, q_2, q_3 – kvaternionų elementai, kurie perteikia kameros sukimosi greitį ir orientaciją; g_x, g_y, g_z – akselerometro gravitacijos kryptis kiekvienos ašies atžvilgiu. Įvertinta orientacija naudojant kvaternionų išraiškas turi būti tiksli. Net mažos klaidos įvertinant orientaciją, kurios naudojamos gravitacijos vektoriui gauti, gali sukelti didelių klaidų skaičiuojant tiesinio pagreičio vektorius. Tiesinio pagreičio vektorius a_g , pašalinus gravitacijos jėgą g , atitinkamų ašių atžvilgiu įvertinamas naudojant (87) išraišką.

$$a_g = \begin{bmatrix} a_{g_x} \\ a_{g_y} \\ a_{g_z} \end{bmatrix} = \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix} - \begin{bmatrix} g_x \\ g_y \\ g_z \end{bmatrix}. \quad (87)$$

Paskaičiuojant tiesinio pagreičio a_g vektorius, kai iš akselerometro išvesties pašalinamas gravitacijos vektorius. Greičio v_t ir pozicijos p_t vektoriai kiekvienos ašies atžvilgiu įvertinami naudojant (88) ir (89) išraiškas:

$$v_t = v_{t-1} + a_{g_s} \Delta t, \quad (88)$$

$$p_t = p_{t-1} + v_t \Delta t + a_{g_s} \frac{\Delta t^2}{2}, \quad (89)$$

čia Δt – laiko intervalas tarp matavimų; a_{g_s} – tiesinis pagreitis, kur s yra pagreitis x , y arba z ašių atžvilgiu; $v_0 = 0$ ir $p_0 = 0$, kai $t = 1$ pradiniu laiko momentu. Akselerometro matavimai yra paveikti triukšmo, jie negali būti efektyviai pašalinti skaičiuojant pozicijos įverčius vien tik jutiklių pagrindu, kaip bus vėliau pademonstruota eksperimentinėje dalyje. Įsivedame naują orientacijos, pozicijos, greičio ir pagreičio vektorių x_{sf} (90) gautų jutiklių matavimų ir duomenų sujungimo pagrindu. Šis vektorius toliau bus naudojamas Kalmano filtre:

$$x_{sf} = \left[\phi_{sf}, \theta_{sf}, \psi_{sf}, [p_x, v_x, a_{g_x}], [p_y, v_y, a_{g_y}], [p_z, v_z, a_{g_z}] \right], \quad (90)$$

čia $\phi_{sf}, \theta_{sf}, \psi_{sf}$ – orientacijos įverčiai jutiklių duomenų sujungimo pagrindu x , y ir z ašių atžvilgiu; $[p_s, v_s, a_{g_s}]$ – pozicijos, greičio ir pagreičio vektorius naudojant jutiklių matavimus, kur s atitinkamai yra x , y ir z ašių atžvilgiu.

3.2. Objekto orientacijos ir pozicijos įvertinimas (sekimas) požymių išskyrimo iš vaizdo ir sutapdinimo atveju

Požymių išskyrimas ir sutapdinimas naudojamas kiekviename vaizde, norint sėkmingai sekti objektą. Tokiu būdu įvertinama santykinė kameros orientacija ir pozicija sekamo objekto vaizde atžvilgiu (pavyzdžiui, knygos paviršiaus) naudojant RANSAC tikimybinį metodą. Iš geometrinės perspektyvos šį atvejį galima paaikškinti naudojant taškinės angos (angl. *pinhole*) kameros modelį. Šis kameros modelis apibrėžia susietumą tarp trimačio taško $P = [X, Y, Z]^T$ iš aplinkoje sekamo vaizdo ir dvimatės projekcijos $p = [x, y]^T$ vaizdo plokštumoje. Trimačio taško atvaizdavimas į dvimatę erdvę vadinamas perspektyvine projekcija ir išreiškiamas naudojant (91) išraišką:

$$\underbrace{\begin{bmatrix} x \\ y \\ 1 \end{bmatrix}}_p = \underbrace{\begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}}_{\text{vidiniai parametrai}} \left(\underbrace{\begin{bmatrix} R_{11} & R_{12} & R_{13} & T_1 \\ R_{21} & R_{22} & R_{23} & T_2 \\ R_{31} & R_{32} & R_{33} & T_3 \end{bmatrix}}_{\text{išoriniai parametrai}} \underbrace{\begin{bmatrix} X \\ Y \\ Z \\ 1 \end{bmatrix}}_P \right), \quad (91)$$

čia vidiniai parametrai: f_x, f_y – židinio nuotolis; c_x, c_y – kameros optinis centras; ir išoriniai parametrai: rotacijos matricos elementai R_{ij} , o $i = 1, \dots, 3, j = 1, \dots, 3$ ir padėties vektoriaus elementai $T_{i1}, i = 1, \dots, 3$. Vidiniai kameros parametrai naudojami

siekiant pašalinti vaizdo iškraipymus, t. y. vaizdo išlenkimus į išorę ar įlenkimus į vidų. Išoriniai parametrai yra kameros koordinatinių sistemos transformacijos matrica, kuri sudaryta iš rotacijos matricos įvertinti orientaciją ir padėties vektoriaus poziciją. Kompiuterinės regos metodai dažniausiai tiria fundamentalios transformacijų matricos įverčius. Rotacijos matrica gali būti konvertuota į Eulerio kampus naudojant (92) išraišką:

$$e_r = \begin{bmatrix} \phi_{cv} \\ \theta_{cv} \\ \psi_{cv} \end{bmatrix} = \begin{bmatrix} \tan^{-1} \left(\frac{R_{23}}{R_{33}} \right) \\ -\sin^{-1} (R_{13}) \\ \tan^{-1} \left(\frac{R_{12}}{R_{11}} \right) \end{bmatrix}. \quad (92)$$

Įsivedame naują kameros orientacijos ir pozicijos vektorių x_{cv} (93) sekamo objekto vaizde atžvilgiu (gautą požymių išskyrimo ir sutapdinimo metodo pagrindu). Šis vektorius toliau bus naudojamas Kalmano filtre:

$$x_{cv} = [\phi_{cv}, \theta_{cv}, \psi_{cv}, p_x, p_y, p_z], \quad (93)$$

čia $\phi_{cv}, \theta_{cv}, \psi_{cv}$ – orientacijos įverčiai konvertuoti iš rotacijos matricos ($R_{3 \times 3}$) į Eulerio kampus; p_x, p_y, p_z – pozicijos koordinatės iš padėties vektoriaus ($T_{3 \times 1}$).

3.3. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą eksperimentai ir jų rezultatai

Įvertinus priimtas prielaidas Kalmano filtras (toliau *KF*) pritaikytas naudojant imituotą orientacijos-pozicijos informaciją x_{sf} ir x_{cv} . *KF* algoritmas yra rekursyvus ir plačiai naudojamas prognozuojant objektų trajektoriją, valdant, sekant, susidūrimų įspėjimo sistemose, apdorojant vaizdą, jutiklių matavimų sujungime ir t. t. Kalmano filtro lygtys skirstomos į dvi dalis: 1) laiko atnaujinimo (angl. *time update*) lygtis ir 2) matavimo atnaujinimo (angl. *measurement update*) lygtis. Laiko atnaujinimo lygtys skirtos prognozuoti esamas būsenas ir įvertinti paklaidos kovariaciją, norint gauti apriorinius įverčius tolesniame etape. Matavimo atnaujinimo lygtys skirtos grįžtamajam ryšiui, įtraukiant naują matavimą į apriorinį įvertį, kad gautume pagerintą aposteriorinį įvertį. Laiko atnaujinimo lygtys dar kitaip vadinamos prognozės lygtimis, o matavimo atnaujinimo lygtys – korekcijos lygtimis. Kalmano filtras sudarytas iš prognozavimo (proceso modelio) (94, 95) ir matavimo atnaujinimo (matavimo modelio) (96–98) lygčių:

1) Būsenų prognozė \hat{x}_k (94):

$$\hat{x}_k = A\bar{x}_{k-1} + Bu_k + w_k, \quad (94)$$

2) Būsenų kovariacijos \hat{P}_k prognozė (95):

$$\hat{P}_k = A\bar{P}_{k-1}A^T + Q, \quad (95)$$

3) Kalmano koeficiento K_k skaičiavimas norint pakoreguoti prognozuotas būsenas \hat{x}_k (96):

$$K_k = \hat{P}_k H^T (H\hat{P}_k H^T + R)^{-1}, \quad (96)$$

4) Būsenų įverčių \bar{x}_k atnaujinimas naudojant matavimą z_k (97):

$$\bar{x}_k = \hat{x}_k + K_k(z_k - H\hat{x}_k), \quad (97)$$

5) Kovariacijos \bar{P}_k atnaujinimas (98):

$$\bar{P}_k = (I - K_k H)\hat{P}_k, \quad (98)$$

čia \hat{x}_k – būsenos prognozės vektorius, paveiktas triukšmo w_k ; \bar{x}_k – būsenos atnaujinimo vektorius; $z_k = Hx_k + v_k$ – matavimo vektorius, paveiktas triukšmo v_k ; $w_k \sim N(0, Q)$, $v_k \sim N(0, R)$ – atitinkamai proceso prognozės ir matavimo atnaujinimo nepriklausomi Gauso triukšmai; A – būsenų perėjimo matrica; B , u_k – atitinkamai valdymo matrica ir valdymo vektorius; \hat{P}_k , \bar{P}_k – atitinkamai prognozės $E[(\hat{x}_k - E[\hat{x}_k])(\hat{x}_k - E[\hat{x}_k])^T]$ ir atnaujinimo $E[(\bar{x}_k - E[\bar{x}_k])(\bar{x}_k - E[\bar{x}_k])^T]$ būsenų įverčių kovariacijų matricos; $Q = E[w_k w_k^T]$, $R = E[v_k v_k^T]$ atitinkamai nepriklausomo proceso ir matavimo triukšmo kovariacijų matricos; H – matavimų matrica; R – matavimų kovariacijos matrica; $(H\hat{P}_k H^T + R)^{-1}$ – inovacijos kovariacija; I – identiškumo matrica.

Atnaujinimo etape skirtumas tarp matavimo ir prognozės būsenų kompensuojamas ir nustatomi nauji įverčiai. KF konvergavimo greitis priklauso nuo Q ir R kovariacijų matricių. Sumažėjusios Q ar R kovariacijų matricių vertės rodo pasikliovimą arba proceso, arba matavimo etapu. Efektyvumas nustatomas analizuojant nepriklausomas Kalmano filtro inovacijų \hat{y}_k (99) arba liekanų \bar{y}_k (100) sekas, kurios yra patikimas kokybės rodiklis:

$$\hat{y}_k = z_k - H_k \hat{x}_k, \quad (99)$$

$$\bar{y}_k = z_k - H_k \bar{x}_k, \quad (100)$$

čia $z_k - H\hat{x}_k$ arba $z_k - H_k \bar{x}_k$ skirtumas, kuris vadinamas atitinkamai matavimo inovacija arba liekana. Inovacija yra neatitikimas tarp prognozuoto matavimo $H\hat{x}_k$ ir tikrojo matavimo z_k . Nulio vidurkio inovacija žymi, kad tarp jų yra sutapimas, o skirtumą siekiama minimizuoti naudojant Kalmano koeficientą K_k . Idealiu atveju paskaičiuota Kalmano filtro inovacija \hat{y}_k ir liekana \bar{y}_k turi būti nulis arba arti nulio vidurkio reikšmės. Sistemos modelio parametrai A , H , Q ir R apibrėžiami iš anksto ir nėra perskaičiuojami Kalmano filtro vykdymo metu. Šie parametrai nustatomi pagal sistemos charakteristikas ar Kalmano filtro taikymo tikslą ir yra tiesiogiai susiję su Kalmano filtro našumu. Esant netinkamam Kalmano filtro našumui, derinami keturi parametrai, susiję su sistemos modeliu (A , H , Q ir R), nes vidiniai kintamieji (\bar{x}_k , \hat{x}_k , \bar{P}_k , \hat{P}_k , K_k) yra paskaičiuojami arba gaunami iš išorės (z_k).

Naudojamos dvi skirtingos Kalmano filtro perspektyvos orientacijai ir pozicijai įvertinti. CV turi lėtesnį duomenų (požymių) apdorojimo greitį, todėl prieinama greitesnė SF informacija, naudojama prognozėms tarp CV išgautos informacijos. KF taikomas naudojant prognozės ir atnaujinimo lygtis (94, 97) pagal toliau aprašytus orientacijos ir pozicijos įvertinimo scenarijus. Atliekant tolesnius eksperimentus dėl paprastumo pirminis jutiklių duomenų sujungimo vektorius x_{sf} yra išskaidytas į du atskirus vektorius x_{sf}^o ir x_{sf}^p :

a) orientacijos $x_{sf}^o = [\phi_{sf}, \theta_{sf}, \psi_{sf}]$ vektorių;

b) pozicijos-greičio-pagreičio $x_{sf}^p = \left[[p_x, v_x, a_{gx}], [p_y, v_y, a_{gy}], [p_z, v_z, a_{gz}] \right]$ vektorių.

CV vektorius x_{cv} taip pat išskaidytas į orientacijos $x_{cv}^o = [\phi_{cv}, \theta_{cv}, \psi_{cv}]$ ir pozicijos $x_{cv}^p = [p_x, p_y, p_z]$ vektorius. Norint išlaikyti aiškumą, matricos su viršutiniu indeksu „o“ žymi orientacijos, o „p“ – pozicijos arba pozicijos-greičio-pagreičio vektorius (101, 102):

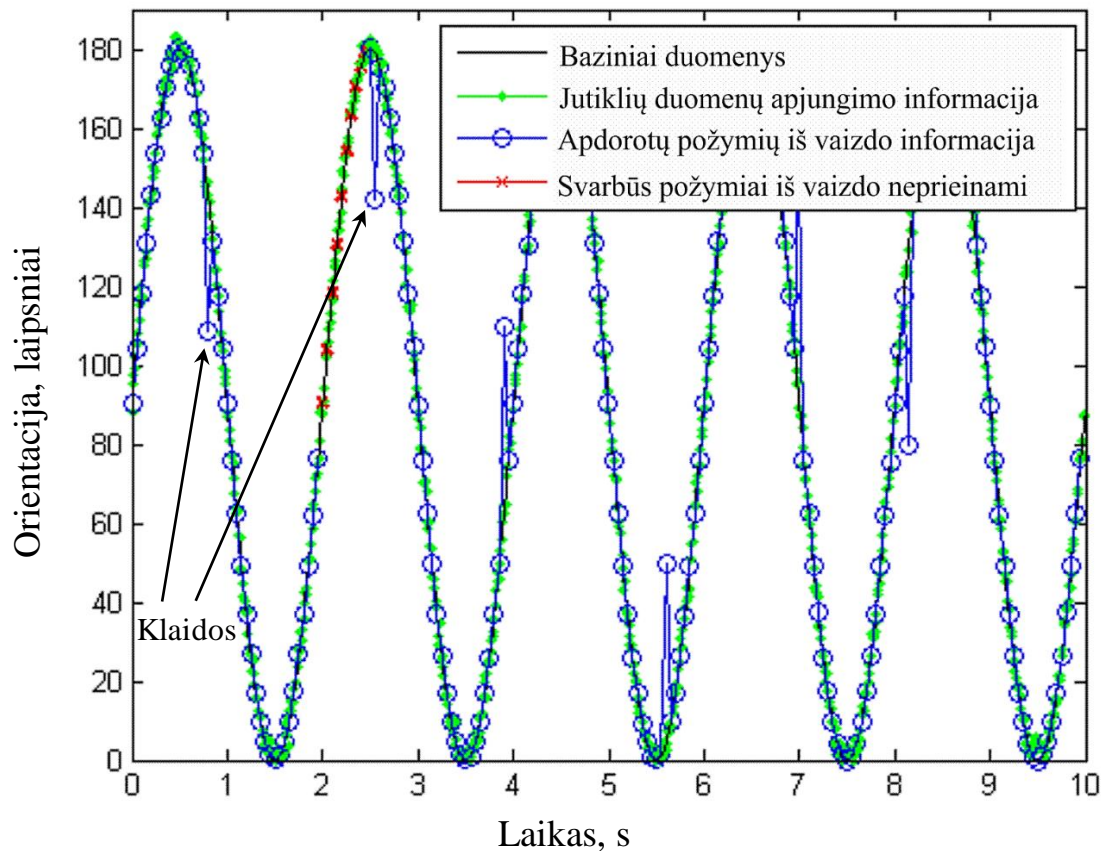
$$A^o = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, A^p = \begin{bmatrix} 1 & \Delta t & \Delta t^2/2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{bmatrix}, \quad (101)$$

$$H^o = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, H^p = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \quad (102)$$

čia Δt – laiko intervalas tarp matavimų.

Toliau imituojami baziniai orientacijos pakreipimų duomenys ϕ kampo atžvilgiu intervale nuo 0 iki 180 laipsnių. Atitinkamai bazinių duomenų atžvilgiu imituojami tikėtina jutiklių duomenų sujungimo atveju gauta informacija su $\sigma = 0.2$ nuokrypiu, $\Delta t = 0,01$ laiko intervalu tarp matavimų ir tikėtini kompiuterinės regos metodo atveju orientacijos įverčiai $\Delta t = 0,05$ laiko intervalu tarp matavimų su sekimo sutrikimais. Atitinkamai panašiu principu atliekamas pozicijos duomenų imitavimas. Orientacijos ir pozicijos duomenų imitavimas ir eksperimentai atlikti naudojant *MathWorks MATLAB* programinę įrangą.

Orientacijos įvertinimo etapas. Orientacijos nustatymo etape įvertinamos trys būsenos ϕ , θ , ψ hibridiniame objekto sekime naudojant Kalmano filtrą. Imituota kameros orientacija pagal kampą ϕ naudojant *SF* ir *CV* pateikta 37 pav.



37 pav. Imituota *SF* ir *CV* orientacija su tikėtinomis klaidomis bei neprieinamos informacijos fragmentais naudojant *CV*

Pradinė sekamo objekto orientacija – 90 laipsnių. Panašūs orientacijos rezultatai būtų gauti θ ir ψ kampų atžvilgiu, todėl toliau jie neaptariami. Apdoroti kameros vaizdo ir jutiklių duomenys gaunami vienodais laiko intervalais. Orientacijos informacija imituojama esant greitiems kameros judesiams. Nors daugeliu atveju

orientacijos informacija, naudojant *CV* prieinama, kai kuriais atvejais sekimas yra netinkamai įvertinamas, todėl gaunami klaidingi duomenys (angl. *outliers*). Sekimas gali būti prarandamas dėl aplinkoje atsirandančių okliuzijų (pažymėta raudonais kryžiuokais 38 pav.).


Hibridinio Kalmano filtro sekimo metodo taikymas pradedamas tuomet, kai išgaunama pirminė orientacijos informacija naudojant *CV* metodą ir naudojama kaip pradinė būseną \bar{x}_0 (pradžios taškas) prognozės lygtyje (94). Atnaujinimo vektorius \bar{x}_{k-1} prognozės lygtyje (94) atitinka x_{cv}^o vaizdo apdorojimo orientacijos vektorių, o matavimas z_k atitinka x_{sf}^o jutiklių sintezės orientacijos vektorių. Bendru atveju, labiau pasikliaunama prieinama *CV* (Q kovariacijų matrica – t. y. procesu), o ne *SF* informacija (R – matavimu) (103):

$$Q = \begin{bmatrix} 1 \cdot 10^{-4} & 0 & 0 \\ 0 & 1 \cdot 10^{-4} & 0 \\ 0 & 0 & 1 \cdot 10^{-4} \end{bmatrix}, R = \begin{bmatrix} 10 & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 10 \end{bmatrix} \quad (103)$$

Jeigu būsenos \hat{x}_k prognozei orientacijos vektorius \bar{x}_{k-1} , naudojant *CV* neprieinamas, tuomet *a posteriori* atnaujinimo būsenai \bar{x}_k priskiriamas *SF* matavimas z_k . Jis naudojamas prognozės etape tuo pačių pasiklovimu, kaip *CV* informacija. Toliau įvedamos sąlygos (104) nustatyti pasiklovimą, kai gaunamas klaidingas *SF* orientacijos vektorius:


$$\begin{cases} |\hat{y}_k| < z_k \cdot z_{TH} & \text{pasiklovimas suteikiamas procesui,} \\ |\hat{y}_k| > z_k \cdot z_{TH} & \text{pasiklovimas suteikiamas matavimui,} \end{cases} \quad (104)$$

čia z_{TH} – parinktas 5% slenkstinės ribos parametras. Inovacijos $|\hat{y}_k|$ palyginimas atliekamas su z_k matavimu, nes *SF* matavimai įverčiai visuomet prieinami. Jeigu gaunama kritinė *CV* informacija, inovacija viršija z_k matavimo slenkstinę ribą z_{TH} , todėl labiau pasikliaunama matavimu. Realiomis sąlygomis egzistuojančios *CV* klaidos sudaro didelį skirtumą lyginant su *SF* orientacijos informacija, dėl to z_{TH} slenkstinės ribos parametras parinktas 5%. Jeigu *CV* informacija prieinama be jokių klaidų, inovacija neviršija slenkstinės ribos, nes užtikrinami panašūs rezultatai, kaip ir *CV* orientacijos. Įvertinta orientacija naudojant Kalmano filtro hibridinį sekimą pateikta 38 pav.



38 pav. Hibridinis objekto sekimo metodas naudojant Kalmano filtrą orientacijai įvertinti

Klaidinga *CV* orientacija sėkmingai pašalinta naudojant *KF*. Tas pats taikoma ir neprieinamai orientacijos informacijai iš *CV*. Orientacijos inovacijos rezultatai pateikti 39 pav.

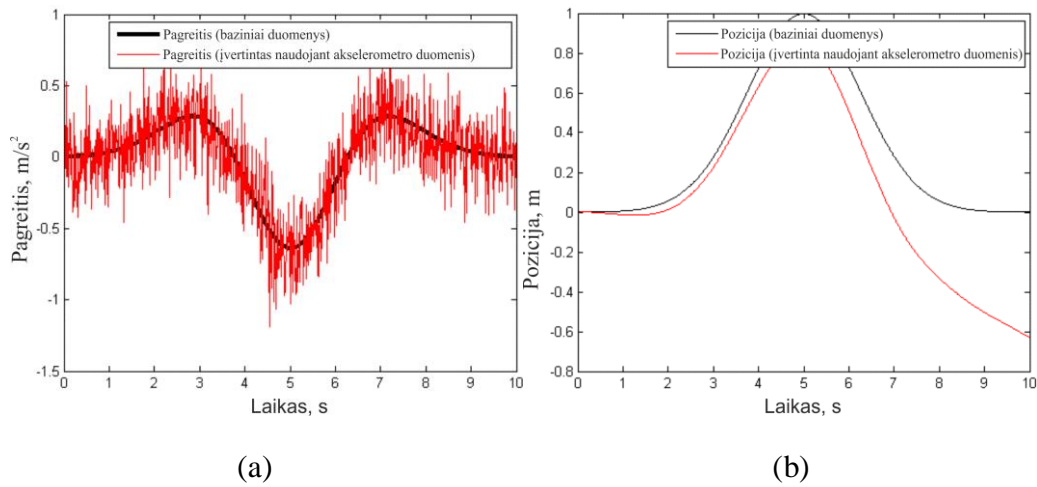


39 pav. Orientacijos prognozės ir atnaujinimo inovacijų sekos

Inovacijų sekoje esantys „pikai“ – tai gautos orientacijos klaidos iš *CV*, kurios nufiltruojamos naudojant hibridinį objekto sekimo metodą Kalmano filtro pagrindu.

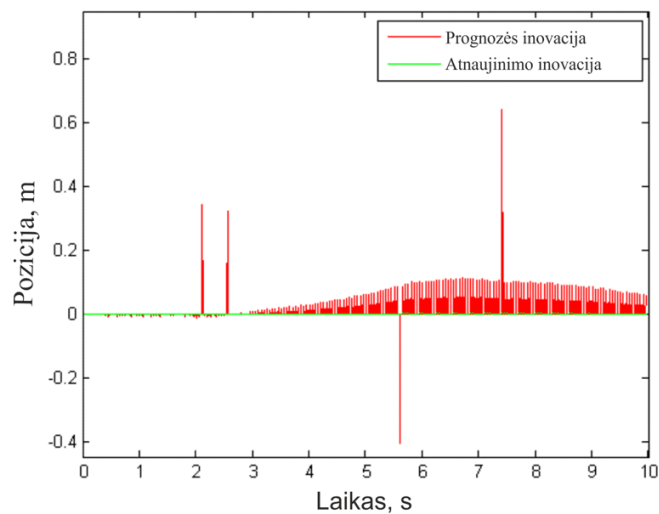
Pozicijos įvertinimo etapas. Pozicijos įvertinimo etape sekama viena koordinatė (analogiškai – kitos dvi). *SF* informacija naudojama proceso modeliui, o *CV* informacija – matavimo modeliui. A^p (101) dar žinomas kaip pastovaus pagreičio modelis (proceso modeliui) ir naudojamas paskaičiuoti vienos ašies poziciją, greitį ir pagreitį. Kitoms dvejoms ašims taikomas tas pats principas. Matavimo dalies atveju svarbi tik pozicijos informacija. Greitis ir pagreitis nėra stebimi, todėl naudojame H^p

atitinkamai pagal (102) išraišką. Imituotas pagreičio triukšmas ir įvertinta pozicija pateikta 40 pav.



40 pav. Imituotas pagreitis pozicijai įvertinti: a) triukšmo paveiktas pagreitis (normalusis skirstinys, $\sigma = 0.2$) pozicijai įvertinti; b) nukrypę pozicijos įverčiai iš triukšmo paveikto pagreičio duomenų, lyginant su bazinėmis pozicijos reikšmėmis (angl. *ground truth*)

Teigiamos ir neigiamos vertės diagramose nurodo pagreičio ir pozicijos kitimo kryptį, pavyzdžiui, vienos ašies atžvilgiu bus kairė–dešinė. Proceso modelyje (\bar{x}_{k-1}) pozicijos-greičio-pagreičio vektoriaus informacija įvertinama iš pagreičio, o matavimo modelis (z_k) poziciją gauna iš CV. Didesnis pasikliovimas suteikiamas kompiuterinės regos informacijai, paskiriant nepriklausomo matavimo triukšmo kovariacijų matricos R koeficientus $1 \cdot 10^{-4}$, nes pozicijos įvertinimas naudojant akcelerometro pagreičio matavimus dėl triukšmo akumuliuoja dideles klaidas. Pozicijos inovacijos sekos pateiktos 41 pav.



41 pav. Pozicijos prognozės ir atnaujinimo inovacijų sekos


Norint išvengti didėjančio skirtumo tarp proceso ir matavimo įverčių, atliekamas prognozės lygties modifikavimas, įterpiant valdymo vektorių (105, 106, 107):

$$\hat{x}_k = A^p \bar{x}_{k-1} + B u_k + w_k, \quad (105)$$

$$B = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, u_k = \begin{bmatrix} \hat{y}_k^m \\ 0 \\ 0 \end{bmatrix}, \quad (106)$$

$$\hat{y}_k^m = \hat{y}_k + \frac{f_{cv}}{f_{sf}} \cdot \frac{\sum_{i=k-n+1}^k (z_i - z_{i-1})}{(n-1)}, \quad (107)$$

čia B – valdymo matrica; u_k – valdymo vektorius; $n = 4$ – paskutiniai 4 prieinami matavimai naudojant CV . Valdymo vektoriaus pridėjimas, kuris sudarytas iš modifikuotos inovacijos \hat{y}_k^m , užtikrina, kad pozicijos įvertis naudojant SF nediverguos tuo metu, kai CV informacija neprieinama (t. y. iki kol bus apdorotas kitas vaizdas). Svarbu paminėti, kad SF atveju duomenų apdorojimas vyksta 5 kartus greičiau nei CV atveju. Modifikuota inovacija paskaičiuojama naudojant ankstesnius prieinamus z_k matavimus CV atveju ir esamą įvertintą poziciją iš jutiklių, iki kol prieinama kita CV pozicijos informacija. Įvertinta pozicijos informacija, naudojant hibridinį objekto sekimo metodą Kalmano filtro pagrindu, pateikta 42 pav.



42 pav. Hibridinis objekto sekimo metodas naudojant Kalmano filtrą pozicijai įvertinti

Pagrindinis hibridinio objekto sekimo metodo naudojant Kalmano filtrą poreikis yra tuo atveju, jeigu papildytos realybės sistemoje objekto sekimas nutrūksta naudojant vaizdo apdorojimą. Sekimo pratęsimą užtikrina kameros orientacijos-pozicijos informacija iš papildomų šaltinių – inercinių jutiklių. Atliktų orientacijos ir pozicijos eksperimentų apibendrinti vidurkių, standartinių nuokrypių bei kvadratinės šaknies vidurkių klaidų skaičiavimų rezultatai pateikti 2 ir 3 lentelėse naudojami metodų tikslumui įvertinti.

2 lentelė. Orientacijos įvertinimo rezultatai: vidurkis (μ), standartinis nuokrypis (σ) ir kvadratinės šaknies vidurkio klaidos ($RMSE$)

Įvertinamas parametras	Orientacijos įvertinimas, laipsniai			
	<i>GT</i>	<i>SF</i>	<i>CV</i>	<i>KF</i>
μ	90,00	90,30	88,55	90,28
σ	63,67	63,73	63,84	63,68
<i>RMSE</i>	-	89,73	90,27	89,79

3 lentelė. Pozicijos įvertinimo rezultatai: vidurkis (μ), standartinis nuokrypis (σ), kvadratinės šaknies vidurkio klaidos ($RMSE$)

Įvertinamas parametras	Pozicijos įvertinimas, metrai			
	<i>GT</i>	<i>SF</i>	<i>CV</i>	<i>KF</i>
μ	0,31	0,34	0,32	0,31
σ	0,35	0,38	0,36	0,35
<i>RMSE</i>	-	0,04	0,06	0,003

Lentelėse (2 ir 3) *GT* žymi bazinių verčių vidurkį, standartinį nuokrypį ir kvadratinės šaknies vidurkio klaidą, pagal kuriuos atliekami lyginimai su *SF* (jutiklių duomenų sujungimo), *CV* (kompiuterinės regos) ir *KF* (hibridinio objekto sekimo metodo naudojant Kalmano filtrą) atvejais. *RMSE* paskaičiuojamas tiek orientacijos, tiek pozicijos atvejais naudojant apibendrintą (108) išraišką:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{GT_i} - x_{EST_i})^2}, \quad (108)$$

čia n – duomenų kiekis; x_{GT} – konkreti bazinių duomenų reikšmė (orientacijos arba pozicijos), o x_{EST} – konkreti įvertinta orientacijos ϕ , θ arba ψ kampo vertė; arba konkreti pozicijos reikšmė x , y arba z ašių atžvilgiu, naudojant skirtingus objekto sekimo metodus, kurių pagrindą sudaro jutiklių duomenų sujungimas, kompiuterinė rega arba pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą. Norint paskaičiuoti procentinį *RMSE* pokytį nuo bazinių orientacijos ir pozicijos duomenų naudojama *RMSPE* (arba $\%RMSE$) (109) išraiška:

$$RMSPE = \frac{\sqrt{\sum_{i=1}^n (x_{GT_i} - x_{EST_i})^2}}{\mu_{GT}} \cdot 100\%, \quad (109)$$

čia μ_{GT} – atitinkamai bazinių orientacijos arba pozicijos duomenų vidurkis.

Iš pateiktų orientacijos-pozicijos įvertinimo rezultatų hibridinis objekto sekimo metodas naudojant Kalmano filtrą rodo geriausius rezultatus: vidurkiai ir standartiniai nuokrypiai yra artimiausi bazinėms reikšmėms. Kvadratinės šaknies vidurkio klaidos rezultatai orientacijai įvertinti yra mažiausi nuo pradinės objekto būsenos (90 laipsnių),

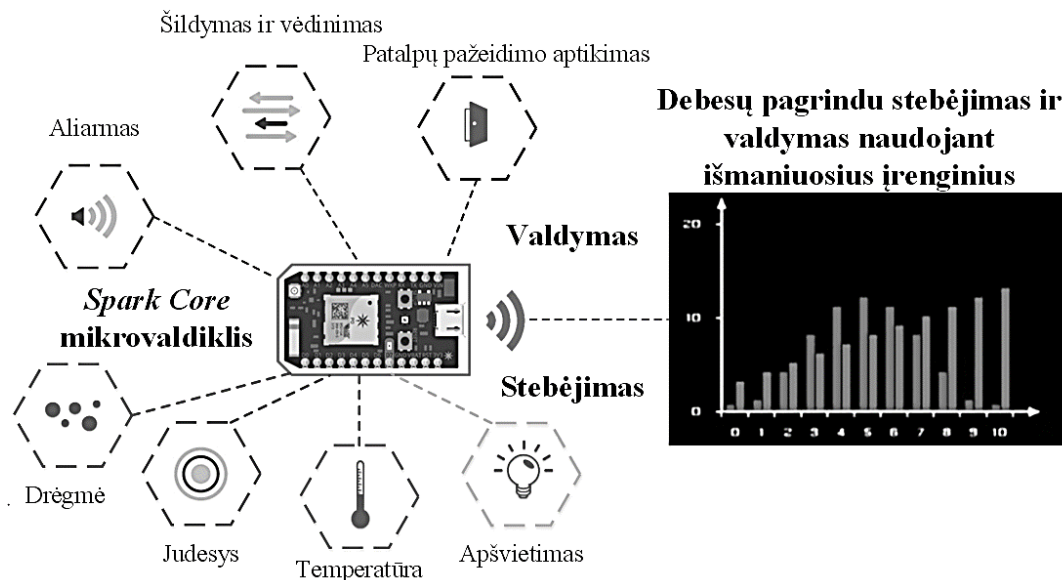
o pozicijos įvertinimo atveju yra arti nulio vertės – tai yra patikimas įvertintų rezultatų rodiklis. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą orientacijos įvertinimo paklaida siekia tik 0,24%, tik jutiklių duomenų sujungimo atveju – 0,30%, o tik kompiuterinės regos atveju – 0,30%. Tačiau pastarojo metodo atveju įvertintos reikšmės yra didesniu atstumu pasiskirsčiusios nuo vidurkio. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą pozicijos įvertinimo paklaida siekia 0,96%, tik jutiklių duomenų sujungimo atveju – 13,06%, o tik kompiuterinės regos atveju – 19,75%.

Kitų autorių tyrimuose, susijusiuose su sekimo metodais, nepateikiama eksperimentų rezultatų ar atskaitos reikšmių skaitine forma, norint atlikti objektyvius palyginimus, dėl šios priežasties visi eksperimentai buvo atlikti su imituotais duomenimis.

3.4. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą adaptacija mobiliesiems įrenginiams papildytos realybės srityje


Šiuo metu papildyta realybė ir daiktų internetas yra pagrindinės sritys, kurios artimiausiu metu turės didžiausią įtaką kiekvieno žmogaus gyvenime. Tokios prognozės pagrindą sudaro šių technologijų suteikiama vertė bei pritaikymas kiekvienoje srityje – tai praplečia žmogaus aplinką naudinga informacija apie mus supančią aplinką ar stebimus kitus procesus. Besiplėtojantys mobilieji įrenginiai (išmanieji telefonai, planšetiniai kompiuteriai, o šiuo metu ir papildytos realybės akiniai), turintys kameras, *GPS* (angl. *Global Positioning System*) modulius ir *MARG* jutiklius, sudaro palankias sąlygas papildytai realybei plėtotis. Tokių sparčiai progresuojančių technologijų naudojimas papildo mūsų aplinką ir keičia mūsų sąveikavimo su skaitmeniniu turiniu bei bendradarbiavimo būdus. Virtualaus turinio rodymas papildytoje realybėje atveria naujas galimybes daugelyje taikymo sričių, įskaitant daiktų internetą (angl. *Internet of Things*, toliau *IoT*) (Leppänen, T.; Heikkinen, A.; Karhu, A.; Harjula, E., 2014). *IoT* sprendimai – taip pat intensyviai nagrinėjama sritis, tačiau iki šiol buvusi sudėtinga įgyvendinti dėl nepakankamai išplėtos infrastruktūros. Siūlomas hibridinio metodo praktinis pritaikymas galimas ne tik išmaniesiems įrenginiams, bet ir papildytos realybės akiniams. Papildytos realybės akinių sekimo pagrindą taip pat sudaro kompiuterinės regos metodai ir jutiklių informacija apie vartotojo galvos poziciją ir orientaciją erdvėje.

Šiuo metu daugelis *IoT* įrenginių sukurti su integruotais *Wi-Fi* moduliais ir matavimų jutikliais. Šitaip kuriamos tinkamos sistemos ir procesai, maksimizuojant efektyvų duomenų naudojimą: optimizuoti procesus, aptikti, prognozuoti ir valdyti anomalijas. Efektyvus informacijos panaudojimas iš didelio duomenų kiekio bei *IoT* sistemų suderinamumas yra svarbiausi nagrinėjami aspektai. Įgyvendintas daiktų interneto sprendimas papildytoje realybėje pateiktas 43 pav.



43 pav. *Spark Core* papildytos realybės daiktų interneto mobiliosios programėlės diagrama

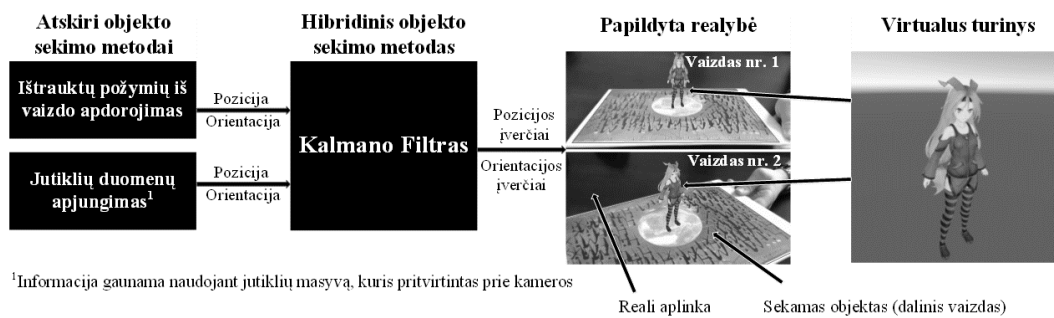
Duomenų išgavimas iš jutiklių nėra sudėtingas procesas. Aplinkos parametrus matuojančių jutiklių duomenys (drėgmės, judesio, temperatūros, apšvietimo) gauti ir vykdomųjų įtaisų valdymas (aliarmas, šildymas ir vėdinimas) ir informavimas atliekamas naudojant *Wi-Fi Spark Core* mikrovaldiklį. Svarbesnis aspektas – duomenų analizė ir sprendimų priėmimas pagal parinktas slenkstines ribas efektyviam valdymui iki tokio lygio, kad būtų galima atlikti prevencinius veiksmus. Nuotoliniai duomenų stebėjimai, diagnostika ir palaikymas yra svarbiausi sprendimai daiktų interneto srityje. Įrenginių gedimų prognozė ir sisteminė prevencija leidžia organizacijoms išvengti papildomų išlaidų. Sukurta *IoT* vartotojo sąsaja papildytos realybės aplinkoje pateikta 44 pav.



44 pav. Vartotojo sąsaja ir realaus laiko aplinkos stebėjimo duomenų atvaizdavimas


Šioje papildytos realybės programėlėje judesys, temperatūra, drėgmė ir apšvietimo intensyvumo jutiklių matavimai gaunami iš daiktų interneto platformos *particle.io* realiu laiku. Kiekvienas jutiklis turi matavimų apatinį ir viršutinį slenkstinės ribos parametą, kad galima būtų stebėti nuokrypius nuo įprastos matavimų informacijos. Pasiūlytas papildytos realybės sprendimas daiktų internetui naudojant hibridinį objekto sekimo metodą Kalmano filtro pagrindu šiuo metu veikia su *Android* įrenginiais ir galima parsisiųsti iš *Google Play* pagal raktinius žodžius *IoT AR Edgaras Art*. Mobilioji programėlė gali būti plečiama atsižvelgiant į konkretaus užsakovo reikalavimus.


Hibridinis objekto sekimas naudojant Kalmano filtrą yra svarbus aspektas papildytos realybės verslo mobiliosiose programėlėse dėl daugelio vartotojų netinkamo naudojimo būdo (Afif, F. N.; Basori, A. H., 2013), (Kaur, D. P.; Mantri, A., 2015), (Daponte, P.; De Vito, L.; Picariello, F.; Riccio, M., 2014). Pavyzdžiui, greiti ir netolygūs kameros judesiai, netinkamai nukreiptas įrenginys į sekamą objektą, sekamas objektas iš dalies uždengtas vartotojo – dažniausiai pastebėta pastarojo elgsena. Šiuos aspektus galima pagerinti naudojant pasiūlytą hibridinį objekto sekimo metodą naudojant Kalmano filtrą, kai turinys atvaizduojamas nekintančia padėtimi ir orientacija, nepriklausomai nuo naudojamo kompiuterinės regos metodo ar įrenginio laikymo būdo. Jeigu sprendimas veiktų tik kompiuterinės regos metodo pagrindu, toks virtualaus turinio atvaizdavimas nepasiteisintų, todėl siūloma šį naudojimo aspektą pagerinti. Pagrindinė hibridinio objekto sekimo naudojant Kalmano filtrą tyrimo realizacija pateikta 45 pav.



45 pav. Hibridinio objekto sekimo naudojant Kalmano filtrą tyrimo realizacija

Hibridinio objekto sekimo naudojant Kalmano filtrą metodui taikyti bei daiktų interneto programėlei įgyvendinti pasirinktos *Unity3D* ir *Vuforia SDK* priemonės. Adaptuotas sprendimas suteiks nenutrūkstamą vartotojo sąsajos atvaizdavimą, net jeigu sekamas objektas nėra kameros vaizde. Hibridinis objekto sekimas naudojant Kalmano filtrą ir taikymas daiktų interneto srityje pateiktas 46 pav.





46 pav. Hibridinis vaizdo sekimas naudojant Kalmano filtrą: a) pradinis vartotojo sąsajos padėties vaizdas; b) ir c) mobilusis įrenginys pakreiptas į apačią; d), e) ir f) mobilusis įrenginys pakreiptas į dešinę; g), h) ir i) mobilusis įrenginys pakreiptas į kairę; j) ir k) mobilusis įrenginys pakreiptas į viršų

Vartotojo sąsaja atvaizduojama sekamo objekto (vaizdo) atžvilgiu. Jeigu sekamas vaizdas aplinkoje neprieinamas, vartotojo sąsaja lieka toje pačioje pozicijoje ir orientacijoje, nepriklausomai nuo to, kaip vartotojas keičia savo žiūrėjimo perspektyvą.

Hibridinis sekimas yra svarbus aspektas papildytos realybės mobiliosiose verslo programose, nes daugelis vartotojų ne visiškai suvokia technologijos veikimo specifiką. Dėl šios priežasties pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą turi didelį potencialą ir poreikį komercinės paskirties mobiliosiose programose. Hibridinio sekimo metodo, turinčio sekimo atžvilgiu papildančių savybių, pritaikymas papildytos realybės sistemose yra pagrindinis tyrimo pritaikymo aspektas. Sukurtas daiktų interneto papildytos realybės sprendimas, kuriame praktiškai pritaikytas pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą. Orientacijos-pozicijos pagerinti įverčiai užtikrina patikimą vartotojo sąsajos pateikimą realaus vaizdo kontekste nepertraukiamai atvaizduojant ir turint galimybę sąveikauti su turiniu.

3.5. Skyriaus išvados

1. Pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą, kurio pagrindą sudaro tiek jutiklių duomenų sujungimo (sekti kamerą), tiek kompiuterinės regos (sekti vaizdą) pagrindu imituota orientacijos ir pozicijos informacija. Hibridinio objekto sekimo metodo eksperimentų rezultatai palyginti su imituotais kompiuterinės regos bei jutiklių duomenų sujungimo metodo duomenimis. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą orientacijos įvertinimo paklaida siekia tik 0,24%, kai

tuo tarpu tik jutiklių duomenų sujungimo bei tik kompiuterinės regos atveju – 0,30%. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą pozicijos įvertinimo paklaida siekia 0,96%, tik jutiklių duomenų sujungimo atveju – 13,06%, o tik kompiuterinės regos atveju – 19,75%.

2. Pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą pasižymi papildančiomis savybėmis pozicijos ir orientacijos įvertinimo atžvilgiu, kuriame pašalinti atskirai naudojamų objekto sekimo metodų trūkumai kaip triukšmas, nuokrypiai ir kiti sekimo sutrikimai, o adaptuotas hibridinis sekimo sprendimas mobiliuosiuose įrenginiuose leidžia atvaizduoti daiktų internetui skirtą vartotojo sąsają papildytoje realybėje nepertraukiamai tiek greitai judant kamerai, tiek esant okliuzijoms aplinkoje.

BENDROSIOS IŠVADOS

1) Atlikus požymių išskyrimo ir klasifikavimo metodų analizę nustatyta, kad tiek klasifikavimo metodai, tiek požymių išskyrimo metodai sprendžia vaizdo požymių pertekliaus problemą, transformuojant perteklių į sumažintą požymių kiekį, kuris vis dar suteiktų pakankamai informacijos, norint atpažinti ir sekti konkretų objektą aplinkoje. Nėra vieno universalaus požymių išskyrimo metodo, kur objekto sekimo uždavinių atlikimas tiktų bet kuriai taikymo sričiai, nes egzistuoja kiti reikalavimai skirtingose taikymo srityse, skiriasi konkreto sekamo objekto savybės ir aplinkos sąlygos, nuo kurių priklauso požymių prieinamumas. Pagal atliktus greitaveikos eksperimentus nustatyta, kad požymių išskyrimas ir sutapdinimas vyksta daugiau nei 4 kartus lėčiau už *SURF* metodą ir 11 kartų lėčiau už *FAST* metodą. Papildytos realybės sistemose objekto sekimas turi būti vykdomas realiu laiku. Įvertinus *SIFT*, *SURF* ir *FAST* požymių išskyrimo metodų stabilumą pradinio vaizdo mastelio keitimo atveju *SIFT* atkartojimo kriterijus yra 15–30% didesnis už *SURF* metodą ir 35–55% didesnis už *FAST*. Vaizdą pasukant *SIFT* metodo atkartojimo kriterijus didesnis 40% lyginant tiek su *SURF*, tiek *FAST* metodais. Vaizdą pastumiant *SIFT* ir *SURF* atkartojimo kriterijaus rezultatai panašūs, bet 4–20% didesni už *FAST* metodą.

2) Analizė parodė, kad naudoti pavienių jutiklių matavimų duomenis, objektų orientacijai nustatyti – nėra patikimas sprendimas. Analitiniu-eksperimentiniu būdu iširti akselerometro, giroskopo ir magnetometro jutikliai, taip pat jungtinis šių jutiklių informacijos naudojimo atvejis, pritaikius kvaternionų išraiškoms gradientinį nusileidimo metodą, kai jutiklių masyvas tvirtinamas prie kameros. Pagal atliktų eksperimentų ir skaičiavimų rezultatus nustatyta, kad naudojant gradientinio nusileidimo metodą, galima kompensuoti atskirų jutiklių trūkumus, padidinti įvertintų orientacijų tikslumą bei patikimumą, išvengiant nuokrypių, triukšmo jutiklių matavimų atvejais bei sumažinant delsimą kompiuterinės regos metodų atvejais. Nustatyta, kad tikslinga naudoti jutiklių duomenų sujungimą, siekiant papildyti nesamus objekto sekimo įverčius arba juos pagerinti. Šie įverčiai gauti kompiuterinės regos pagrindu, esant sekimo sutrikdymams, kylantiems dėl didelio kameros judėjimo greičio, okliuzijų ar netinkamai įvertintos padėties informacijos dėl skirtingų vaizdo transformacijų.

3) Pasiūlytas hibridinis objekto sekimo metodas naudojant Kalmano filtrą, kurį sudaro tiek jutiklių duomenų sujungimo (sekti kamerą), tiek kompiuterinės regos (sekti vaizdą) pagrindu imituota orientacijos ir pozicijos informacija. Hibridinio objekto

sekimo metodo eksperimentų rezultatai palyginti su imituotais kompiuterinės regos bei jutiklių duomenų sujungimo metodo duomenimis. Pasiūlyto hibridinio objekto sekimo metodo naudojant Kalmano filtrą orientacijos įvertinimo paklaida siekia tik 0,24%, o tik jutiklių duomenų sujungimo bei tik kompiuterinės regos atveju – 0,30%. Hibridinio objekto sekimo metodo naudojant Kalmano filtrą pozicijos įvertinimo paklaida siekia 0,96%, tik jutiklių duomenų sujungimo atveju – 13,06%, o tik kompiuterinės regos atveju – 19,75%.

4) Pasiūlytas hibridinis objektų sekimo metodas naudojant Kalmano filtrą pritaikytas mobiliesiems įrenginiams leidžia ne tik nepertraukiamai atvaizduoti daiktų internetui skirtą vartotojo sąsają papildytoje realybėje, bet atskira hibridinio objekto sekimo metodo dalis gali būti adaptuota sąveikos įrenginių plėtojimui, kuriais praplečiamas ir gerinamas sąveikavimas su skaitmeniniu turiniu ar kita technine įranga, įgalinami skirtingi veikimo režimai bei taikymo galimybės, todėl pasiūlytas hibridinis objekto sekimo sprendimas pasižymi universalumu.

LITERATŪROS SĄRAŠAS

- Abreu, J.A.P.; Neto, J.V.F.; Limão Oliveira, R.C. (2011). Ballistic Rockets Tracking: Kalman versus $\alpha\beta\gamma$ Filters. *13th International Conference on Computer Modelling and Simulation (UKSim)*, (p. 313–318). Cambridge. doi:10.1109/UKSIM.2
- Afif, F. N.; Basori, A. H. (2013). Orientation Control for Indoor Virtual Landmarks based on Hybrid-based Markerless Augmented Reality. *Procedia - Social and Behavioral Sciences*, 97, p. 648–655. doi:10.1016/j.sbspro.2013.10.284
- Alpaydin, E. (2009). Introduction to Machine Learning 2nd Edition. *Massachusetts Institute of Technology*, p. 584.
- Araguas, G.; Paz, C.; Gaydou, D.; Paina, G. P. (2013). Orientation estimation fusing a downward looking camera and inertial sensors for a hovering UAV. *16th International Conference on Advanced Robotics (ICAR)*, (p. 1–6). Uruguay, Montevideo.
- Atev, S.; Arumugam, H.; Masoud, O.; Janardan, R.; Papanikolopoulos, N.P. (2005). A vision-based approach to collision prediction at traffic intersections. *IEEE Transactions on Intelligent Transportation Systems*, 6(4), p. 416–423.
- Babaei, H. R.; Mohurutshe, P. L.; Lashkari, A. H. (2013). Image-processing with augmented reality (AR). *International Conference on Graphic and Image Processing (ICGIP 2012)*, 8768, p. 1–5.
- Babenko, B.; Yang, M.-H.; Belongie, S. (2011 m. August). Robust object tracking with online multiple instance learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(8), p. 1619–1632. doi:10.1109/TPAMI.2010.226
- Bae, H.; Golparvar-Fard, M.; White, J. (2013). High-precision vision-based mobile augmented reality system for context-aware architectural, engineering, construction and facility management (AEC/FM) applications. *Visualization in Engineering*, 1–13.
- Bahrapour, S.; Ray, A.; Sarkar, S.; Damarla, T.; Nasrabadi, N. M. (2013). Performance comparison of feature extraction algorithms for target detection and classification. *Pattern Recognition*, 34(16), 2126–2134. doi:http://dx.doi.org/10.1016/j.patrec.2013.06.021
- Bay, H.; Ess, A.; Tuytelaars, T. and Gool, L. V. (2008). SURF: Speeded Up Robust Features. *Computer Vision and Image Understanding (CVIU)*, 110(3), 346–359.
- Bancroft, J. B., & Lachapelle, G. (2011). Data Fusion Algorithms for Multiple Inertial Measurement Units. *Collaborative Sensors*, p. 6771–6798. doi:10.3390/s110706771
- Bavdekar, V. A.; C. Patwardhan, S. (2010). Identification of Noise Covariances for State Estimation of a Continuous Fermenter using Extended EM Algorithm. *Proceedings of the 9th International Symposium on Dynamics and Control of Process Systems*, (p. 689–694).
- Belokon, S. A.; Zolotukhin, Yu. N.; Kotov, K. Yu.; Mal'tsev, A. S.; Nesterov, A. A.; Pivkin, V. Ya.; Sobolev, M. A.; Filippov, M. N.; Yan, A. P. (2013 m. November). Using the Kalman filter in the quadrotor vehicle trajectory tracking system. *Optoelectronics, Instrumentation and Data Processing*, 49(6), p. 536–545.

- Bernatavičienė, J. (2008). Vizualios žinių gavybos metodologija ir jos tyrimas. *Daktaro disertacija*, p. 116. Nuskaityta iš http://www.mii.lt/files/mii_dis_08_bernataviciene.pdf
- Berner, P. (2008). *Technical Concepts: Orientation, Rotation, Velocity and Acceleration, and the SRM*. Nuskaityta iš <http://www.sedris.org/wg8home/Documents/WG80485.pdf>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Information Science and Statistics. Springer, pp. 738. ISBN-10: 0-387-31073-8.
- Bistrovs, V. (2008). Analyse of Kalman Algorithm for Different Movement Modes of Land Mobile Object. *Electronics and Electrical Engineering*, 6(86), p. 89–92.
- Bleser, G.; Stricker, D. (2008). Advanced Tracking through Efficient Image Processing and Visual-inertial Sensor Fusion. *IEEE Proceedings of Virtual Reality 2008 Conference* (p. 137–144). California: IEEE Computer Society Press: Los Alamitos.
- Bos, R.; Bombois, X.; Van den Hof, P. M. J. (2005). Designing a Kalman Filter When No Noise Covariance Information Is Available. *19th World Congress of the International Federation of Automatic Control*, (p. 1–6).
- Bosch, A.; Zisserman, A.; Munoz, X. (2007). Image Classification using Random Forests and Ferns. *IEEE 11th International Conference on Computer Vision*, (p. 1–8).
- Carvalhosa, S.; Aguiar, A. P.; Pascoal, A. (2010). Cooperative Motion Control of Multiple Autonomous Marine Vehicles: Collision Avoidance in Dynamic Environments. *7th IFAC Symposium on Intelligent Autonomous Vehicles (2010)*, 7(1), p. 395–400.
- Chandrasekhar, V.; Takacs, G.; Chen, D.; et al. (2009). Transform Coding of Image Feature Descriptors. *Visual Communications and Image Processing*, 1–9. Nuskaityta iš Visual Communications and Image Processing: <http://web.stanford.edu/~bgirod/pdfs/ChandrasekharVCIP09.pdf>
- Choukroun, D.; Bar-Itzhack, I. Y.; Oshman, Y. (2006 m. JANUARY). Novel quaternion Kalman filter. *IEEE TRANSACTIONS ON AEROSPACE AND ELECTRONIC SYSTEMS*, 42(1), p. 174–190. doi:0018-9251/06/\$17.00
- Comotti, D. (2011). Orientation Estimation Based on Gauss-Newton Method and Implementation of a Quaternion Complementary Filter. *Technical Report*, 1–8.
- Croeze, A., Pittman, L., & Reynolds, W. (1–16). *Solving Nonlinear Least-Squares Problems With the Gauss-Newton and Levenberg-Marquardt Methods*. Nuskaityta iš <https://www.math.lsu.edu/system/files/MunozGroup1%20-%20Paper.pdf>
- Daponte, P.; De Vito, L.; Picariello, F.; Riccio, M. (2014). State of the art and future developments of the Augmented Reality for measurement applications. *Measurement*, 57, p. 53–70.
- Davison, A. J.; Cid, Y. G.; Kita, N. (2004). Real-Time 3D Slam with Wide-Angle Vision. *In IFAC Symposium on Intelligent Autonomous Vehicles.*, (p. 1–6). Lisboa, Portugal.
- Diebel, J. (2006). Representing Attitude: Euler Angles, Unit Quaternions, and Rotation Vectors. *Stanford University*, p. 1–35. Nuskaityta iš https://www.astro.rug.nl/software/kapteyn/_downloads/attitude.pdf
- Eade, E.; Drummond, T. (2006). Scalable Monocular SLAM. *Computer Vision and Pattern Recognition. IEEE Computer Society Conference, 1*, p. 469–476.

- Euston, M.; et. al. (2008). A Complementary Filter for Attitude Estimation of a Fixed-Wing UAV. *International Conference on Intelligent Robots and Systems*, (p. 340–345). Nice, France.
- Fonseca, J.V.; Oliveira, R.C.L.; Abreu, J.A.P.; Ferreira, E.; Machado, M. (2013). Kalman Filter Embedded in FPGA to Improve Tracking Performance in Ballistic Rockets. *15th International Conference on Computer Modelling and Simulation (UKSim)*, (p. 606–610). Cambridge. doi:10.1109/UKSim.2013.149
- Fuji, T., & Mitsukura, Y. (2012). Hybrid visual tracking and model-based alignment using 6-DOF sensor. *Proceedings of SICE Annual Conference (SICE)*, (p. 2052–2056).
- Gallery, R. D. (1997). *Patento Nr. WO 1997021166 A1*. Nuskaityta iš <http://www.google.com/patents/WO1997021166A1>
- Gebre-Egziabher, D., Elkaim, G. H., Powell, J. D., & Parkinson, B. W. (2000). A Gyro-Free Quaternion-Based Attitude Determination System Suitable for Implementation Using Low Cost Sensors. *Position Location and Navigation Symposium* (p. 185–192). IEEE.
- Gordon, N.; Percival, J.; Robinson, M. (2003). The Kalman-Levy filter and heavy-tailed models for tracking manoeuvring targets. *Proceedings of the Sixth International Conference on Information Fusion, 2*, p. 1024–1031.
- Grabner, H.; Leistner, C.; Bischof, H. (2008). Semi-supervised on-line boosting for robust tracking. *Computer Vision – ECCV 2008*, (p. 234–247).
- Harris, C.; Stephens, M. (1988). A combined corner and edge detector. *In: Alvey Vision Conference*, p. 147–151.
- Hartikainen, J., Solin, A., & Särkkä, S. (2011). *Optimal Filtering with Kalman Filters and Smoothers: a Manual for the Matlab toolbox EKF/UKF, Department of Biomedical Engineering and Computational Science*.
- He, S.; Yang, Q.; Lau, R. W. H.; Wang, J.; Yang, M. H. (2013). Visual Tracking via Locality Sensitive Histograms. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition* (p. 2427–2432). Portland, OR: IEEE. doi:10.1109/CVPR.2013.314
- Herath, D. C.; Kodagoda, S.; Dissanayake, G. (2006). Simultaneous Localisation and Mapping: A Stereo Vision Based Approach. *In IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2006)* (p. 922–927). Beijing, China: IEEE.
- Hol, J. D. et al. (2006). Sensor Fusion for Augmented Reality. *In 9th International Conference on Information Fusion*, (p. 1–6). Florence, Italy.
- Holz, D. (2013). *USA Patento Nr. US2013182902 A1. Systems and methods for capturing motion in three-dimensional space*.
- Hwang, Jae-In; Sung, Min-Hyuk; Kim, Ig-Jae; Ahn, S. C.; Kim, Hyoung-Gon; Ko, H. (2013). Painting Alive: Handheld Augmented Reality System for Large Targets. *Virtual 5th International Conference on Virtual Augmented and Mixed Reality* (p. 32–38). Springer Berlin Heidelberg. doi:10.1007/978-3-642-39405-8_4
- Ian H. BERNSTEIN, A. W. (2014). *Patento Nr. US20140236393 A1*. Nuskaityta iš <http://www.google.com/patents/US20140236393>
- Yilmaz, A.; Javed, O.; Shah, M. (2006). Object tracking: a survey. *ACM Computing Surveys*, 38(4), 1–45. doi:10.1145/1177352.1177355
- You, S. (2001). Fusion of vision and gyro tracking for robust augmented reality registration. *In Proceedings of the Virtual Reality 2001 Conference*, (p. 71–78). Yokohama, Japan.

- Yuanqing, L.; Fengjun, L.; Shenghuo, Z.; Ming, Y. (2011). Large-scale image classification: Fast feature extraction and SVM training. *In IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (p. 1689–1696).
- Johnny Lee, T. L. (2011). *USA Patento Nr. US2011150271 AI*. Nuskaityta iš <http://www.google.com/patents/US20110150271>
- Juan, L.; Gwun, O. (2009). A Comparison of SIFT, PCA-SIFT and SURF. *International Journal of Image Processing*, 3(4), p. 143–152.
- Jurman, D.; Jankovec, M.; Kamnik, R.; Topič, M. (2007). Calibration and data fusion solution for the miniature attitude and heading reference system. *Sensors and Actuators A: Physical*, 138(2), p. 411–420.
- Kalal, Z.; Mikolajczyk, K.; Matas, J. (2012). Tracking-Learning-Detection. *IEEE Transactions on PAMI*, 34, p. 1409–1422.
- Kalman, R. E. (1960). A New Approach to Linear Filtering and Prediction Problems. *Transactions of the ASME–Journal of Basic Engineering*, p. 35–45. Nuskaityta iš <http://www.cs.unc.edu/~welch/kalman/media/pdf/Kalman1960.pdf>
- Kanbara, M., et al. (2000). A Stereo Vision-based Augmented Reality System with an Inertial Sensor. *In Proceedings of the IEEE and ACM International Symposium on Augmented Reality*, (p. 97–100). Munich, Germany.
- Kanbara, M.; Okuma, T.; Takemura, H.; Yokoya, N. (2000). A Stereoscopic Video See-through Augmented Reality System Based on Real-time Vision-based Registration. *In Processings Virtual Reality*. 2, p. 255–262. New Brunswick, NJ: IEEE. doi:10.1109/ICPR.1998.711920
- Kaur, D. P.; Mantri, A. (2015). Computer vision and sensor fusion for efficient hybrid tracking in augmented reality systems. *IEEE 3rd International Conference on Innovation and Technology in Education (MITE)*, p. 176–181. doi:10.1109/MITE.2015.7375310
- Khan, N. Y.; McCane, B. and Wyvill, G. (2011). SIFT and SURF Performance Evaluation Against Various Image Deformations on Benchmark Dataset. *2011 International Conference on Digital Image Computing: Techniques and Applications*, p. 501–506.
- Klein, G. and Murray, D. (2007 m. November). Parallel Tracking and Mapping for Small AR Workspaces. *6th IEEE and ACM International Symposium on Mixed and Augmented Reality*, p. 225–234.
- Kong, X. (2004). INS algorithm using quaternion model for low cost IMU. *Robotics and Autonomous Systems*, 46(4), p. 221–246. Nuskaityta iš http://prism2.mem.drexel.edu/~vefa/research/HeliExtLoadStabil/relevantPapers/imu/kalman_imu_gps.pdf
- Kozlov, A. (2012). *Augmented Reality Technologies for the Visualisation of SLAM Systems*. Thesis, The University of Auckland, New Zealand, Department of Electrical & Computer Engineering, p. 192.
- Kuipers, J. B. (1999). Quaternions and Rotation Sequences. *Geometry, Integrability and Quantization*, p. 127–143. Nuskaityta iš <ftp://ftp.math.ethz.ch/EMIS/proceedings/Varna1999/geom09.pdf>
- Kwon, J.; Lee, K. M. (2009). Tracking of a non-rigid object via patchbased dynamic appearance modeling and adaptive basin hopping monte carlo sampling. *in Proceedings CVPR, IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, (p. 1208–1215). Miami, Florida, USA.
- Laskauskas, R.; Vyšniauskas, V. (2008). Vaizdo kontūrų nustatymo būdų analizė. *Jaunujų mokslininkų darbai*, 5(21), 21–26. Nuskaityta iš http://www.su.lt/bylos/mokslo_leidiniai/jmd/08_05_21/06_visniauskas.pdf

- Lee, C.; Landgrebe, D. (1993). *Feature extraction and classification algorithms for high dimensional data*. TR-EE 93-1 ECE Technical Reports. , School of Electrical Engineering Purdue University., Indiana. Nuskaitytā iš <https://engineering.purdue.edu/~landgreb/ChulheeTR.pdf>
- Lepetit, V., Vacchetti, L., Thalmann, D., Fua, P. (2003). Fully Automated and Stable Registration for Augmented Reality Applications. *In Proceedings of the Second IEEE and ACM International Symposium on Mixed and Augmented Reality (ISMAR '03)* (p. 93–102). IEEE. doi:10.1109/ISMAR.2003.1240692
- Leppänen, T.; Heikkinen, A.; Karhu, A.; Harjula, E. (2014). Augmented Reality Web Applications with Mobile Agents in the Internet of Things. *Eighth International Conference on Next Generation Mobile Apps* (p. 54–59). Services and Technologies.
- Lin, B.-S. P., Tsai, W.-H., Wu, C., Hsu, P., Huang, J., & Liu, T.-H. (2013). The Design of Cloud-Based 4G/LTE for Mobile Augmented Reality with Smart Mobile Devices. *IEEE Seventh International Symposium on Service-Oriented System Engineering* (p. 561–566). RedWood: IEEE. doi:10.1109/SOSE.2013.57
- Liu, R.; Gillies, D. F. (2016). Overfitting in linear feature extraction for classification of high-dimensional image data. *Pattern Recognition*, 53, 73–86. doi:<http://dx.doi.org/10.1016/j.patcog.2015.11.015>
- Lowe, D. G. (2004). Distinctive Image Features from Scale Invariant Keypoints. *International Journal of Computer Vision*, 60(2), 91–110.
- Lukosiunas, E. et al. (2011). An ultrasonic tracking method for augmented reality. *In Proceedings of the 17th International Conference on Information and Software Technologies*, (p. 27–29). Kaunas, Lithuania.
- Madgwick, S. O. H. (2010). An efficient orientation filter for inertial and inertial/magnetic sensor arrays. *Internal Report*, 1–32.
- Madgwick, S. O. H. (2011). Estimation of IMU and MARG Orientation Using a Gradient Descent Algorithm. *International Conference on Rehabilitation Robotics (ICORR)* (p. 1–27). Zurich, Switzerland: IEEE.
- Maidi, M., Preda, M., & Le., V. (2011). Markerless tracking for mobile augmented reality. *IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*, (p. 301–306). doi:10.1109/ICSIPA.2011.6144077
- Marins, J. L.; et. al. (2001). An Extended Kalman Filter for Quater-nion-Based Orientation Estimation Using MARG Sensors. *In Proceedings of the IEEE/RSJ International Conference on In-telligent Robots and Systems* (p. 2003–2011). Maui, Hawaii: IEEE.
- Moravec, H. (1980). *Obstacle avoidance and navigation in the real world by a seeing robot rover*. Robotics Institute, Carnegie Mellon University & Stanford University, In: tech. report CMU-RI-TR-80-03.
- Naghshineh, S., Ameri, G., & Zereshki, M. (2010). Human Motion capture using Tri-Axial accelerometers., (p. 1–49). Nuskaitytā iš <http://edge.rit.edu/edge/P10010/public/PDF/HME.pdf>
- Nam, J. E.; Maurer, M. and Mueller, K. (2009 m. October). A high-dimensional feature clustering approach to support knowledge-assisted visualization. *Computers & Graphics*, 33(5), p. 607–615. doi:10.1016/j.cag.2009.06.006
- Natarajan, V. (2012). Human skeletal tracking using colour MSERs. *IVCNZ '12 Proceedings of the 27th Conference on Image and Vision Computing*, (p. 527–532). Dunedin, New Zealand.

- Nguyen, N., Nasrabadi, N., & Tran, T. (2011). Robust multi-sensor classification via joint sparse representation. *In: Proceedings of the 14th International Conference on Information Fusion (FUSION)*, (p. 1–8).
- Oshin, O., Gilbert, A., Illingworth, J., & Bowden, R. (2009). Action recognition using randomised ferns. *IEEE 12th International Conference In Computer Vision Workshops (ICCV Workshops)*, (p. 530–537).
- Oussalah, M.; De Schutter, J. (2000). ADAPTIVE KALMAN FILTER FOR NOISE IDENTIFICATION. *ISMA25 Conference*. Nuskaitytā iš http://www-isma-isaac-be.mech.kuleuven.be/publications/PMA_MOD_publications/ISMA25/p1225p1232.pdf
- Pimenov, V. (2009). Fast Image Matching with Visual Attention and SURF Descriptors. *19th International Conference on Computer Graphics and Vision*, (p. 1–8). Moscow.
- Prevost, C.G.; Desbiens, A.; Gagnon, E. (2007). Extended Kalman Filter for State Estimation and Trajectory Prediction of a Moving Object Detected by an Unmanned Aerial Vehicle. *American Control Conference*, (p. 1805–1810). New York.
- Qi-Nian, J. (2000). On the Iteratively regularized Gauss-Newton Method For Solving Nonlinear Ill-Posed. *Mathematics of Computation*, 232, 1603–1623. Nuskaitytā iš <http://www.ams.org/journals/mcom/2000-69-232/S0025-5718-00-01199-6/S0025-5718-00-01199-6.pdf>
- Raschka, S. (2015). Python Machine Learning. Packt Publishing, p. 454, ISBN-10: 1783555130.
- Reitmayr, G.; Eade, E.; Drummond, T. W. (2007). Semi-automatic Annotations in Unknown Environments. *6th IEEE and ACM International Symposium on Mixed and Augmented Reality*, (p. 67–70).
- Ribeiro, M. I. (2004). Gaussian Probability Density Functions: Properties and Error Characterization., (p. 1–30).
- Ross, D. A.; Lim, J.; Lin, R.-S.; Yang, M.-H. (2008). Incremental learning for robust visual tracking. *International Journal of Computer Vision*, 77(1-3), 125–141.
- Rosten, E.; Drummond, T. (2006). Machine learning for high-speed corner detection. *Proceedings of the 9th European conference on Computer Vision*, 3951, p. 430–443.
- Rosten, E.; Porter, R.; Drummond, T. (2010). FASTER and better: A machine learning approach to corner detection. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 105–119.
- Roth, M.; Ozkan, E.; Gustafsson, F. (2013). A Student's t filter for heavy tailed process and measurement noise. *IEEE International Conference on Acoustics, Speech and Signal Processing*, (p. 5770–5774).
- Sabatini, A. M. (2006). Quaternion-Based Extended Kalman Filter for Determining Orientation by Inertial and Magnetic Sensing. *IEEE Transactions on Biomedical Engineering*, 7(53), 1346–1356.
- Sabatini, A. M. (2006). Quaternion-Based Extended Kalman Filter for Determining Orientation by Inertial and Magnetic Sensing. 7(53), 1346–1356.
- Sabatini, A. M. (2011). Kalman-Filter-Based Orientation Determination Using Inertial/Magnetic Sensors: Observability Analysis and Performance Evaluation. *Sensors (Basel)*, 11(10), p. 9182–9206.
- Schick, I. C., & Mitter, S. K. (1994). Robust Recursive Estimation in the Presence of Heavy-Tailed Observation Noise. *Annual Statistics*, 22(2), p. 1045–1080.

- Shivakumar, B. L. and Santhosh Baboo, Lt. Dr. S. (2011 m. July). Detection of Region Duplication Forgery in Digital Images Using SURF. *International Journal of Computer Science Issues*, 8(4), p. 199–255.
- Smith, S. M.; Brady, J. M. (1997). SUSAN - a new approach to low level image processing. *International Journal of Computer Vision* (23), p. 45–78.
- Sorenson, H. W. (1970). Least-squares estimation: from Gauss to Kalman. *IEEE Spectrum*, 7, p. 63–68. Nuskaityta iš <http://www.cs.unc.edu/~welch/kalman/media/pdf/Sorenson1970.pdf>
- Strasdata, H.; Montielb, J. M. M.; Davison, A. J. (2012). Visual SLAM: Why filter? *Image and Vision Computing*, 30(2), p. 65–77.
- Tharwat, A.; Hassanien, A. E.; Elnaghi, B. E. (2016). A BA-based algorithm for parameter optimization of Support Vector Machine. *Pattern Recognition Letters*. doi:<http://dx.doi.org/10.1016/j.patrec.2016.10.007>
- Tichonov, J.; Kurasova, O.; Filatovas, E. (2015). Vaizdų klasifikavimas pagal suspaudimo algoritmo poveikį jų kokybei. *Informacijos Mokslai*, p. p. 127–134. Nuskaityta iš https://www.researchgate.net/publication/282761583_Vaizdu_klasifikavimas_pagal_suspaudimo_algoritmo_poveiki_ju_kokybei
- Trajkovic, M., Hedley, M. (1998). Fast corner detection. *Image and Vision Computing* 16, 78–87.
- Trawny, N., & Roumeliotis, S. I. (2005). *Indirect Kalman Filter for 3D Attitude Estimation. A Tutorial for Quaternion Algebra*. Technical Report, Multiple Autonomous Robotic Systems Laboratory, Department of Computer Science & Engineering, p. 24.
- Vedaldi, A. (2006). *An open implementation of the SIFT detector and descriptor*. Los Angeles: University of California.
- Verikas, A.; Gelzinis, A.; Bacauskiene, M. (2011 m. February). Mining data with random forests: A survey and results of new tests. *Pattern Recognition*, 44(2), p. 330–349. doi:<http://dx.doi.org/10.1016/j.patcog.2010.08.011>
- Wagner, D. and Schmatstieg, D. (Feb. 2007). ARToolKitPlus for Pose Tracking on Mobile Devices. *Proceedings of 12th Computer Vision Winter Workshop*, 139–146.
- Wagner, D.; Reitmayr, G.; Mulloni, A.; Drummond, T.; Schmalstieg, D. (2010). Real-time detection and tracking for augmented reality on mobile phones. *16(3)*, p. 355–368.
- Wang, J. G.; Gopaul, S. N.; Guo, J. (2010 m. August 17–20 d.). Adaptive Kalman Filtering Based on Posteriori Variance-Covariance Components Estimation. *CPGPS 2010 Technical Forum*. Nuskaityta iš http://www.yorku.ca/jgwang/pub/JWang_Paper_AKF.pdf
- Welch, G.; Bishop, G. (2006). *An Introduction to the Kalman Filter*. Technical Report 95-041, University of North Carolina at Chapel Hill, Department of Computer Science.
- Wyss, M. L. (2011). *Robustness of different feature extraction methods against image compression*. Zurich: Swiss Federal Institute of Technology Zurich, Autonomous Systems Lab.
- Won, Joong-Ho; Lim, J.; Kim, Seung-Jean; Rajaratnam, B. (2009). *Maximum Likelihood Covariance Estimation with a Condition Number Constraint*. Technical Report No. 2009-10, Stanford University, Department of Statistics.

- Wright, J., Yang, A., Ganesh, A., Sastry, S., & Ma, Y. (2008). Robust face recognition via sparse representation. *The IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31 (2), p. 210–227.
- Wu, C. (2007). *Advanced feature extraction algorithms for automatic fingerprint recognition systems*. Dissertation, University of New York at Buffalo. Nuskaityta iš http://www.cedar.buffalo.edu/~govind/chaohong_thesis.pdf
- Xu, K.; Chia, K. W.; Cheok, A. D. (2008). Real-time camera tracking for marker-less and unprepared augmented reality environments. *Image and Vision Computing*, 26(5), 673–689.
- Zejnilić, S. (n.d.). *Kalman Filtering with intermittent heavy tailed observations*. Nuskaityta iš http://users.isr.ist.utl.pt/~pjcro/courses/def0910/docs/report_SZ.pdf
- Zhang, J.; Marszałek, M.; Lazebnik, S.; Schmid, C. (2007). LocalFeatures and Kernels for Classification of Texture and Object Categories: A Comprehensive Study. *International Journal of Computer Vision*, 73, 213–238.
- Zhou, F.; Duh, H.B.-L.; Billingham, M. (Sept. 2008). Trends in Augmented Reality Tracking, Interaction and Display: A Review of Ten Years of ISMAR. In *7th IEEE/ACM International Symposium on Mixed and Augmented Reality (ISMAR)* (p. 193–202). Cambridge: IEEE.
- Zhou, Qing-Li; Zhang, Y.; Qu, Yao-Hong; Rabbath, C. (2010). Dead reckoning and Kalman filter design for trajectory tracking of a quadrotor UAV. *IEEE/ASME International Conference on Mechatronics and Embedded Systems and Applications (MESA)*, (p. 119–124). Qingdao, ShanDong.
- Zunino, G. (2002). *Simultaneous Localization and Mapping for Navigation in Realistic Environments*. Thesis, Royal Institute of Technology, Numerical Analysis and Computer Science, p. 1-99.

PRIEDŲ SĄRAŠAS

Priedai prieinami *CD* duomenų laikmenoje ir *Google Drive* diske:

https://drive.google.com/drive/folders/0BygvzTqnzm_wUjhaekJiNTc2bnc

Priedų sąrašas:

- 1) MATLAB optimizavimo dalies kodas.
- 2) MATLAB požymių ištraukimo iš vaizdo apdorojimo metodų dalies kodas.
- 3) MATLAB hibridinio objekto sekimo metodo naudojant Kalmano filtrą dalies kodas (pozicijos ir orientacijos įvertinimui).
- 4) MARG jutiklių dalies Arduino ir Processing kodai.
- 5) Unity3D C# ir Photon Particle mikrovaldikliui skirti kodai.

Edgaras Artemčiukas

HIBRIDINIS OBJEKTŲ SEKIMO METODAS PAPILDYOTOS REALYBĖS
SISTEMOSE NAUDOJANT KALMANO FILTRĄ

Daktaro disertacija
Fiziniai mokslai (P000)
Informatika (09P)

Redaktorė Vaida Leonavičienė