



**Kauno technologijos universitetas**

Informatikos fakultetas

# **Piniginių monetų nudėvėjimo lygio nustatymas**

Baigiamasis magistro projektas

---

**Matas Gumbinas**

Projekto autorius

**Doc. dr. Armantas Ostreika**

Vadovas

---

**Kaunas, 2020**



**Kauno technologijos universitetas**

Informatikos fakultetas

## **Piniginių monetų nudėvėjimo lygio nustatymas**

Baigiamasis magistro projektas

Informatika (6211BX007)

---

**Matas Gumbinas**

Projekto autorius

**Doc. dr. Armantas Ostreika**

Vadovas

**Prof. Gintaras Palubeckis**

Recenzentas

---

**Kaunas, 2020**



**Kauno technologijos universitetas**

Informatikos fakultetas

Matas Gumbinas

## **Piniginių monetų nudėvėjimo lygio nustatymas**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Mato Gumbino, baigiamasis projektas tema „Piniginių monetų nudėvėjimo lygio nustatymas“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

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

---

(vardą ir pavardę įrašyti ranka)

---

(parašas)

Gumbinas Matas. Piniginių monetų nudėvėjimo lygio nustatymas. Magistro baigiamasis projektas / vadovas doc. dr. Armantas Ostreika; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Informatika, Fiziniai mokslai.

Reikšminiai žodžiai: Vaizdų apdorojimas, apšvietimo įtakos mažinimas, daugiapakopis filtravimas, objektų segmentavimas, monetų nudėvėjimas.

Kaunas, 2020. 56 p.

### **Santrauka**

Monetų nudėvėjimo lygio nustatymas iš skaitmeninių 2D vaizdų yra sudėtinga problema. Didelių bei kokybiškų duomenų rinkinių trūkumas, skirtumai tarp monetų atvaizdų ir jų dizainų bei jų nuotraukose naudojamo fono ar apšvietimo įtaka daro šią problemą sunkiai išsprendžiama realiomis sąlygomis. Siekiant padėti spręsti dalį šių problemų, šiame darbe yra siūlomi bei tiriami nauji metodai monetos fono šalinimui, jos apšvietimo normalizavimui bei nudėvėjimą nusakančios informacijos sudarymui. Galiausiai, šio darbo metu buvo sudarytas ir pateiktas realiomis sąlygomis randamo monetų nudėvėjimo duomenų rinkinys.

Gumbinas Matas. Level of Wear Estimation for Currency Coins / supervisor assoc. prof. dr. Armantas Ostreika; Faculty of Informatics, Kaunas University of Technology.

Study field and area (study field group): Informatics, Physical sciences.

Keywords: Image processing, illumination invariance, multilevel threshold, object segmentation, coin wear.

Kaunas, 2020. 56 pages.

### **Summary**

Estimating modern coin wear based on 2D digital images is a difficult problem. Lack of sufficiently large data sets, wide range of inter-class variance between the coin's visual designs and unstable lightning or background conditions makes this problem increasingly complex to solve in real-life conditions. To help alleviate some of these issues, we introduce and evaluate new methods for coin background elimination, achieving illumination invariance and coin wear information extraction. Finally, we created and provided a new coin wear estimation dataset based on real-life coins images with various wear features.

## Turinys

<b>Lentelių sąrašas .....</b>	<b>7</b>
<b>Paveikslų sąrašas .....</b>	<b>8</b>
<b>Įvadas.....</b>	<b>9</b>
<b>1. Literatūros apžvalga .....</b>	<b>10</b>
1.1. Piniginių monetų nudėvėjimo lygio nustatymo problema.....	10
1.1.1. Vizualinės kokybės vertinimo kriterijų analizė.....	10
1.1.2. Monetos vizualinės kokybės įvertinimo analizė.....	12
1.1.3. Šiuolaikinių monetų nudėvėjimo įtaka jų vertei.....	14
1.1.4. Iškeltos problemos analizės išvados.....	15
1.2. Esamų bei susijusių darbų apžvalga.....	15
1.3. Vaizdų fono segmentavimo metodai.....	19
1.4. Monetos apšvietimo efektų šalinimo metodai.....	23
1.5. Monetos nudėvėjimo deskriptoriai.....	24
1.5.1. Kontrasto taškų nustatymas mastelio erdvėje.....	24
1.5.2. Taškų lokalizavimas.....	27
1.5.3. Orientacijos priskyrimas.....	29
1.5.4. Taško vaizde deskriptoriaus sudarymas.....	30
<b>2. Piniginių monetų nudėvėjimo lygio nustatymo projekto specifikacija .....</b>	<b>31</b>
2.1. Reikalavimai.....	31
2.2. Monetos lokalizavimas bei segmentavimas.....	32
2.3. Monetos apšvietimo normalizavimas.....	34
2.4. Monetos nudėvėjimo nustatymas.....	36
<b>3. Piniginių monetų nudėvėjimo lygio nustatymo metodų tyrimo eiga ir rezultatai.....</b>	<b>38</b>
3.1. Duomenų rinkinių sudarymas.....	38
3.2. Pradinių duomenų analizė.....	39
3.3. CORT algoritmo taikymas monetos segmentavimui.....	41
3.4. Monetos slenkstinės ribos segmentavimo metodų palyginimas.....	41
3.5. Nuo apšvietimo nepriklausomos spalvų erdvės skaitinis stabilumas.....	42
3.6. Pasiūlyto monetos apšvietimo normalizavimo metodo taikymas.....	43
3.7. Monetos apšvietimo normalizavimo metodų palyginimas.....	44
3.8. Monetų nudėvėjimo lygio klasifikavimo rezultatai.....	46
3.8.1. SIFT algoritmo parametrų įtakos tyrimas.....	48
3.8.2. Pasiūlytų metodų įtakos tyrimas.....	50
<b>Išvados .....</b>	<b>54</b>
<b>Literatūros sąrašas .....</b>	<b>55</b>
<b>Priedai.....</b>	<b>57</b>
1 priedas. Pranešimas iš „Information Technology And Control“ redakcijos dėl publikacijos priėmimo.....	57
2 priedas. Publikacija "Methods for Adaptive Equalization of Illumination and Foreground Detection in Coin Images“ .....	58

## Lentelių sąrašas

<b>1.1 lentelė.</b> Šeldono skalė – naudotos monetos <sup>[4,19]</sup> .....	13
<b>1.2 lentelė.</b> Monetos klasifikavimo DNT architektūra.....	15
<b>2.1 lentelė.</b> Monetos lokalizavimo bei išskyrimo iš turimo jos paveikslėlio panauda.....	31
<b>2.2 lentelė.</b> Monetos paveikslėlio normalizavimo panauda .....	32
<b>2.3 lentelė.</b> Monetos nudėvėjimo lygio nustatymo panauda .....	32
<b>3.1 lentelė.</b> Naudotos skaitmeninės kameros specifikacija .....	38
<b>3.2 lentelė.</b> Coinset1 duomenų rinkinio sudėtis. ....	39
<b>3.3 lentelė.</b> Naudotų modelių konfigūracijų parametrai.....	46
<b>3.4 lentelė.</b> Galutiniai monetų nudėvėjimo klasifikavimo rezultatai .....	53

## Paveikslų sąrašas

<b>1.1 pav.</b> „Indėnas/Auksinis erelis“ 2,50 JAV auksinio dolerio moneta <sup>[26]</sup> .....	10
<b>1.2 pav.</b> „1933 Dvigubas erelis“ 20 JAV auksinių dolerių moneta <sup>[27]</sup> .....	10
<b>1.3 pav.</b> Monetų įspaudų palyginimas <sup>[5]</sup> .....	11
<b>1.4 pav.</b> Monetos lopinėliai. Paveiksliukas adaptuotas iš <sup>[16]</sup> .....	16
<b>1.5 pav.</b> Monetos lopinėlių tekstūros. Paveikslėlis adaptuotas iš <sup>[16]</sup> .....	16
<b>1.6 pav.</b> Antikinės monetos segmentavimas. Paveikslėlis adaptuotas iš <sup>[6]</sup> .....	17
<b>1.7 pav.</b> Šiuolaikinės monetos segmentavimas. Paveikslėlis adaptuotas iš <sup>[6]</sup> .....	17
<b>1.8 pav.</b> Monetos apdirbimas. Paveikslas adaptuotas iš <sup>[1]</sup> .....	19
<b>1.9 pav.</b> Žaizdos nuotrauka ir jos histograma. Paveikslas adaptuotas iš <sup>[7]</sup> .....	22
<b>1.10 pav.</b> Žaizdos nuotraukos slenkstinės ribos filtravimo metodų palyginimas. Paveikslas adaptuotas iš <sup>[7]</sup> .....	22
<b>1.11 pav.</b> Trikampio slenkstinės ribos nustatymo metodo grafas <sup>[25]</sup> .....	22
<b>1.12 pav.</b> Mastelio erdvė $L$ su kvantavimo dydžiu $s = 3$ .....	25
<b>1.13 pav.</b> Dvejų oktavų sandara ( $s = 1$ ) .....	25
<b>1.14 pav.</b> Dvejų oktavų sudarymas ( $s = 2$ ) be ekstremumo taškų paieškos dalies (dvi pakopos) <sup>[11]</sup> .....	26
<b>1.15 pav.</b> 3x3x3 paieškos langas diskrečioje Gauso f-jos skirtumų erdvėje $D$ . $X$ – centrinis lango elementas <sup>[11]</sup> .....	26
<b>1.16 pav.</b> Principiniai Gauso skirtumų funkcijos $D$ lenkimai ties nurodytu tašku.....	28
<b>2.1 pav.</b> Monetos nudėvėjimo lygio nustatymo sistemos panaudos atvejų diagrama.....	31
<b>2.2 pav.</b> CORT monetos lokalizavimo bei segmentavimo algoritmas.....	33
<b>2.3 pav.</b> +5% praplėstas lokalizuotos monetos, $L$ , gaubiantis tūris, $Lbb$ .....	34
<b>3.1 pav.</b> Domenų rinkinio klasterizavimas į 4-ias grupes <sup>[2]</sup> .....	39
<b>3.2 pav.</b> Coinset1 duomenų rinkinio informacijos dimensijų analizė.....	40
<b>3.3 pav.</b> Coinset1 duomenų rinkinio monetų nudėvėjimo pasiskirstymas.....	40
<b>3.4 pav.</b> Monetos lokalizavimas ir segmentavimas CORT algoritmu .....	41
<b>3.5 pav.</b> Monetos slenkstinės ribos segmentavimo rezultatai .....	42
<b>3.6 pav.</b> Modifikuotos spalvų erdvės funkcijos skaitinis stabilumas .....	43
<b>3.7 pav.</b> Monetos apšvietimo normalizavimas.....	44
<b>3.8 pav.</b> Monetos apšvietimo normalizavimo metodai .....	45
<b>3.9 pav.</b> Monetos vaizdų apšvietimo normalizavimo metodų palyginimas .....	46
<b>3.10 pav.</b> Alkūninio metodo taikymas randant k-vidurkių metodo klasterių dydžius .....	47
<b>3.11 pav.</b> Coinset1 duomenų rinkinio nudėvėjimo lygio pasiskirstymas naudojant žodžių kratinio metodą .....	48
<b>3.12 pav.</b> Klasifikavimo rezultatai su skirtingais klasterių skaičiais .....	48
<b>3.13 pav.</b> Klasifikavimo rezultatai su skirtingais oktavų sluoksnių skaičiais.....	49
<b>3.14 pav.</b> Klasifikavimo rezultatai su skirtingomis kontrasto ribinėmis vertėmis.....	49
<b>3.15 pav.</b> Klasifikavimo rezultatai su skirtingomis kampo ribinėmis vertėmis.....	50
<b>3.16 pav.</b> Klasifikavimo rezultatai su skirtingais vaizdų apdorojimo metodais .....	50
<b>3.17 pav.</b> Klasifikavimo rezultatai su skirtingais žodžių kratinio sudarymo metodais.....	51
<b>3.18 pav.</b> Klasifikavimo lentelės naudojant 2 ir 4 klases.....	52



## Įvadas

Piniginės monetos nuo senų senovės buvo dažniausiai naudojama piniginių atsiskaitymų forma. Nors jų pagaminimo kaštai yra didesni nei piniginių kupiūrų, tačiau jos lyg šiol yra neatsiejama piniginių atsiskaitymų dalis. Tai lemia jų patvarumas ir ilgaamžiškumas, leidžiantys šiuos grynuosius pinigus naudoti. Dėl šių bei kitų priežasčių dauguma šalių pasaulyje naudoja monetas kaip vieną iš pagrindinių atsiskaitymo grynaisiais pinigais būdų. Vis dėlto, monetas, pagamintos iš įvairių metalų, taip pat gali būti pažeidžiamos naudojantis jomis ilgą laiką. Stipriai pažeistos monetas yra laikomos nusidėvėjusios. Priešingai nei popierines kupiūras, kurios yra daug pigesnės, tokias monetas bankai yra suinteresuoti surinkti ir perdirbti į naujas monetas, o ne sunaikinus išmesti jas. Taip pat yra skiriamas didesnis dėmesys šių monetų nusidėvėjimo lygiui nustatyti, siekiant perdirbti tik blogiausios būklės monetas, tokiu būdu išvengiant perdirbimo kaštų. Vis dėlto, esant dideliame kiekiui monetų, jų nusidėvėjimo lygio nustatymas tampa sudėtinga bei brangia užduotimi. Dėl šios priežasties šiame darbe bus siekiama prisidėti prie šios problemos sprendimo, bandant rasti ar sukurti metodus, kurių dėka būtų galima automatiškai aptikti, klasifikuoti bei išmatuoti piniginių monetų nusidėvėjimo lygį.

### Darbo tikslas:

Sudaryti metodus skirtus tinkamai parengti skaitmeninius vaizdus siekiant aptikti, klasifikuoti ir išmatuoti šiuolaikinių monetų nusidėvėjimo lygį.

### Tyrimo objektas:

Šiuolaikinės apvalios piniginės monetos skaitmeninis RGB vaizdas, gaunamas naudojant skaitmeninę kamerą.

### Uždaviniai:

1. Rasti ir aprašyti galimas savybes, kuriomis pasižymi įvairaus nusidėvėjimo lygio monetos.
2. Sudaryti naujus arba rasti jau esamus duomenų rinkinius, kurie galėtų būti naudojami darbo metu, atliekant metodų kūrimo bei tyrimo dalis.
3. Sukurti metodus skirtus išskirti monetų nusidėvėjimo informaciją, ją aptikti, klasifikuoti bei išmatuoti.
4. Ištirti bei palyginti šio darbo metu sukurtų metodų rezultatus bei jų efektyvumą su jau esamų darbų rezultatais.

### Darbo struktūra:

Šiame dokumente yra 4 pagrindiniai skyriai.

1. **Literatūros apžvalga.** Analizuojama piniginių monetų nusidėvėjimo problema bei iškeliami kriterijai monetų vizualiniam vertinimui. Apžvelgiami esami darbai panašiomis temomis. Analizuojami esami metodai skirti skirtingoms šiame darbe kylančioms problemoms.
2. **Piniginių monetų nusidėvėjimo lygio nustatymo projekto specifikacija.** Sudaroma projekto specifikacija, iškeliami darbo reikalavimai. Sudaromi metodai šio darbo problemoms spręsti.
3. **Piniginių monetų nusidėvėjimo lygio nustatymo metodų tyrimo eiga ir rezultatai.** Pateikiami šio darbo metu atlikti tyrimai bei jų rezultatai.
4. **Išvados.** Pateikiamos galutinės tiriamojo darbo išvados.

## 1. Literatūros apžvalga

### 1.1. Piniginių monetų nudėvėjimo lygio nustatymo problema

Siekiant nustatyti piniginių monetų nudėvėjimo lygį, visų pirma reikia įsigilinti į šią problemą. Ji susideda iš kelių atskirų problemų: monetos vizualinės kokybės apibrėžimo bei jos vertinimo subjektyvumo ir monetos nudėvėjimo pasireiškimo. Siekiant išanalizuoti bei geriau suprasti šias problemas buvo atlikta iškeltų problemų analizė.

#### 1.1.1. Vizualinės kokybės vertinimo kriterijų analizė

Dažniausiai pagrindinis tikslas vertinant piniginių monetų vizualinę kokybę yra nustatyti jų galimą vertę. Tai atliekant, dėmesys yra skiriamas į tai, kaip kokybiškai yra iškaldinta moneta, įvertinama, kaip gerai ši moneta yra išsilaikiusi bei kokią žalą ji yra patyrus nuo dėvėjimo. Vertinant monetų vizualinę kokybę, įprastai ji yra nustatoma pagal penkis kriterijus: įspaudas, paviršiaus išsilaikymas, blizgesys ir žvilgėjimas, spalvingumas bei patrauklumas [24].

**Įspaudas.** Monetos kaldinimas – procesas, kurio metu tam tikras dizainas yra įspaudžiamas į metalinę monetos formos plokštelę. Moneta gali turėti stiprius arba silpnus šio dizaino įspaudus. Pavyzdžiui, tam tikri atvejai kaip „1933 Dvigubas erelis“ 20 JAV auksinių dolerių moneta (1.2 pav.) pasižymi nedideliais metalo reljefo pokyčiais abeiose pusėse, o tai parodo, jog šie įspaudai yra „silpni“. Kiti monetų dizainai, tokie kaip „Indėnas/Auksinis erelis“ 2,50 JAV auksinio dolerio moneta (1.1 pav.), išsiskiria giliais įspaudais ant abiejų savo pusių, kas rodo, jog šie įspaudai yra „stiprūs“, tačiau ant kitų šios monetos leidimų šie įspaudai gali būti „silpni“.




1.1 pav. „Indėnas/Auksinis erelis“ 2,50 JAV auksinio dolerio moneta [26]



1.2 pav. „1933 Dvigubas erelis“ 20 JAV auksinių dolerių moneta [27]

Dėl šios priežasties monetų įspaudų stiprumas nėra esminė monetų vizualinės kokybės vertinimo dalis, išskyrus tuos atvejus, kuomet monetos vertė tiesiogiai priklauso nuo įspaudų stiprumo. To pavyzdys yra „Mercury Dime“ serijos monetos. Ši moneta, turinti nežymiai silpną įspaudą, gali būti verta iki 15\$, tačiau ta pati moneta su stipriu įspaudu verta net iki 7500\$ (1.3 pav.). Vis dėlto, tokie atvejai yra itin reti, todėl dažniausiai įspaudų stiprumas nėra esminė monetų kokybės vertinimo dalis [24].



1.3 pav. Monetų įspaudų palyginimas [5]

a) Silpno įspaudo „Mercury Dime“ serijos moneta; b) Stipraus įspaudo „Mercury Dime“ serijos moneta

**Paviršiaus išsilaikymas.** Vienas svarbiausių bei geriausiai apibrėžtų monetų vizualinės kokybės vertinimo kriterijų yra jos paviršiaus išsilaikymas. Moneta, priklausomai nuo ant jos paviršiaus randamų defektų kiekio bei jų vietos, gali būti vertinama labai skirtingai. Tipiškai, esant didesniai kiekiui monetos paviršiaus pažeidimų, ji atitinkamai yra laikoma prastesnės būklės. Vis dėlto, norint nusakyti jos vertę neužtenka žinoti tik pažeidimų kiekio, bet būtina atsižvelgti ir į jų vietą monetoje. Pavyzdžiui, moneta kuri turi labai gilų įpjovimą galinėje savo pusėje, esantį ne ant svarbių, mažai pastebimų, monetos dizaino vietų, gali būti vertinama žymiau geriau nei tokia pati moneta turinti labai nežymų įpjovimą priekinėje savo pusėje ant svarbios jos dizaino vietos. Taigi, monetos paviršiaus išsilaikymo kokybė yra nusakoma jos dizaino pažeidimo svarbos kontekste [24].

**Blizgesys ir žvilgėjimas.** Priklausomai nuo monetos dizaino, jos pagaminimo vietos bei laikotarpio ir metalo, iš kurio ji buvo iškaldinta, ji gali turėti skirtingas tekstūras. Monetų paviršiai dažniausiai turi šerkšno, lygaus matinio ar net veidrodinio atspindžio tekstūras. Analizuojant monetų paviršių pagal jų blizgesį bei siekiant nustatyti jų vertę, dėmesys yra atkreipiamas į du dalykus:

- Originalaus, nepažeisto monetos paviršiaus plotas;
- Paviršiaus defektų kiekis bei jų buvimo vieta.

Lyginant monetas bendrai, jų paviršiaus tekstūrų tipai negali būti laikomi geresni vieni už kitus, todėl būtina lyginti monetas atskirai. Vis dėlto, žinant tam tikros monetos etaloninį blizgumą (tekstūros tipą bei jos kokybę), šis vertinimo kriterijus yra labai svarbus nusakyti, ar moneta buvo naudota ar ne. Jei ji yra naudota, pasižymi žymiai mažesniu blizgesio lygiu lyginant su nenaudota moneta [24].

**Spalvingumas.** Spalva yra labiausiai subjektyvus kriterijus vertinant monetos vertę. Moneta gali būti arba gerai iškaldinta, arba blogai, o tai yra objektyvu bei apibrėžiama. Siekiant nusakyti monetos kokybę bei jos vertę, pirma būtina žinoti iš kokios medžiagos ji padaryta bei kaip ši medžiaga keičia spalvines savybes laikui bėgant. Monetas, pagamintas iš aukso, nekeičia savo spalvos žymiai, todėl spalvingumas jas vertinant nėra svarbus kriterijus. Vis dėlto, monetas, pagamintas iš tokių medžiagų kaip sidabras, varis ar žalvaris, laikui bėgant ar esant kontaktui su riebalais ar kitom medžiagom oksiduojasi, ar kitaip keičia savo savybes, o dėl šios priežasties žymiai keičiasi monetų spalva <sup>[24]</sup>.

**Patrauklumas.** Aukščiau išvardinti vertinimo kriterijai kartu sudaro bendrą monetos vizualinį patrauklumą. Monetos vizualinis patrauklumas jos kokybės vertinimo kontekste nereikalauja papildomo apibrėžimo. Tai yra savaimė suvokiamas terminas. Moneta, kuri yra patraukli savo išvaizda, gali būti vertinama labai gerai vienoje srityje (pvz.: puikus blizgesys) bei gerai kitoje (pvz.: geras, bet ne puikus spalvingumas). Kita vertus, jei moneta yra vertinama blogai vienoje srityje (pvz.: dideli paviršiaus defektai), bet yra patenkinama kitose srityse, šios monetos vizualinis patrauklumas yra laikomas žemiau vidutinio. Monetos vizualinis patrauklumas gali pasirodyti kaip labai subjektyvi sąvoka, bet tai netiesa. Dauguma patyrusių monetų vertintojų laikosi nuomonės, jog tam tikra vertinama moneta gali būti vizualiai patraukli, arba priešingai - nepatraukli. Vis dėlto, siekiant tai įvertinti, būtinas tam tikras kiekis žinių šioje srityje. Galiausiai, būtina atsižvelgti į tai, jog šis vertinimo kriterijus negali būti taikomas visoms monetos taip pat. Taip yra todėl, kad skirtingos monetos net geriausioje savo būklėje turi skirtingą patrauklumo lygį, todėl būtina vertinti monetas individualiai pagal jų serijos leidimą <sup>[24]</sup>.

Išskyrus svarbiausius kriterijus skirtus monetų kokybės įvertinimui nustatyti, galima pastebėti, jog šis procesas yra gana subjektyvus bei gali priklausyti nuo individualaus monetos vertintojo ir jo sukauptos patirties bei žinių. Taigi, siekiant specifikuoti šiuos kriterijus ir norint naudoti juos bendroje vertinimo sistemoje, būtina analizuoti monetas, suskirstant jas į grupes pagal jų serijas. Tokiu būdu bus pašalinamas didelis kiekis vertinimo subjektyvumo faktoriaus.

### 1.1.2. Monetos vizualinės kokybės įvertinimo analizė

Siekiant rasti ir sukurti metodus bei būdus vertinti monetos kokybę, būtina naudoti bendrą vertinimo sistemą. Ši problema pirma karta buvo iškelta XIX – XX amžiuje, kuomet monetų kolekcionavimo rinka pradėjo sparčiai plėstis. Tai sukūrė poreikį sudaryti bendrą ir pakankamai tikslią monetų vertinimo sistemą. Vienos monetos gali būti geresnės paviršiaus kokybe, kitos gali būti nenaudotos ir dėl to turėti daugiau blizgesio bei mažiau pažeidimų lyginant su likusiomis. Dėl tokių priežasčių buvo pradėti naudoti tikslesni terminai skirti apibūdinti monetų kokybę. Vis dėlto, tik 1948 metais žinomas monetų vertintojas bei kolekcionierius Dr. Viliamas Herbertas Šeldonas (angl. William Herbert Sheldon) standartizavo monetų vertinimą pasiūlydamas savo sukurtą Šeldono skalę, kuri turi įvertį nuo 1 iki 70 <sup>[19]</sup>. Ši skalė taip pat turi dvi atskiras įverčių grupes <sup>[4]</sup>:

- **Naudotos monetas;**
- **Nenaudotos monetas** (MS, angl. Mint State) – šiame darbe ši grupė yra neaktuali, nes darbo tikslas yra analizuoti monetų nedėvėjimo lygio išmatavimo būdus. Nenaudotos monetas yra nenudėvėtos.

**1.1 lentelė.** Šeldono skalė – naudotos monetos <sup>[4,19]</sup>

Įvertis	Pavadinimas	Kodas	Aprašymas
1	Prasta	PO	Pakankamai aiškus dizainas, kad būtų įmanoma identifikuoti monetą. Monetos data gali būti pilnai sudėvėta, o viena iš monetos pusių gali nebeturėti savo dizaino. Monetos paveiktos stiprios korozijos, taip pat patenka į šią kategoriją.
2	Patenkinama	FR	Galima įžiūrėti nedidelį kiekį monetos dizaino detalių.
3 - 3.5	Beveik gera	AG	Išskaitomi rašmenys bei žodžiai, tačiau labai stipriai nudėvėti. Data bei monetos dizainas gali būti pilnai nutrintas.
4	Gera	G, G4	Monetos žiedai yra nežymiai nudėvėti, dizainas yra matomas, tačiau sunkiai įžiūrimas vietose. Daug monetos vietų yra lygiai nutrintos. Periferiniai rašmenys beveik išsilaikę.
6	Kokybiška	G+, G6	Monetos žiedai, bei periferiniai rašmenys pilnai išsilaikę.
8	Labai gera	VG, VG8	Nežymios dizaino detalės matomos. Bent 30% stambiausių monetos rašmenų yra matomi.
10	Labai kokybiška	VG+, VG10	Nežymiai aiškesnės dizaino detalės. Bent 70% stambiausių monetos rašmenų yra išsilaikę bei matomi.
12	Detali	F, F12	Matoma dalis įdubusių vietų detalių. Visi stambūs rašmenys yra puikiai matomi, tačiau dalis gali būti nežymiai nudėvėti. Pastebimas vidutiniškai-rimtas, tačiau tolygus nudėvėjimas visoje monetoje.
15	Labiau detali	F+, F15	Nežymiai daugiau detalumo įdubusiuose monetos vietose.
20	Labai detali	VF, VF20	Vidutinis nudėvėjimas monetos paviršiaus iškilimuose.
25	Labai detali	VF25	Visi rašmenys bei pagrindinės monetos dizaino detalės yra aiškiai įžiūrimos. Matomas silpnai-vidutinis, bet tolygus nudėvėjimas ant monetos paviršiaus bei jo iškilimų.
30	Ypatingai detali	Ch. VF, VF+, VF30	Visi rašmenys bei svarbiausios dizaino detalės yra puikiai matomos. Švelnus, tačiau tolygus nudėvėjimas pastebimas ant monetos paviršiaus bei jo iškilimų.
35	Ypatingai detali	Ch. VF, VF+, VF35	Visi rašmenys bei svarbiausios dizaino detalės yra puikiai matomos. Švelnus, tačiau tolygus nudėvėjimas pastebimas ant monetos paviršiaus bei jo iškilimų. Gali nežymiai matytis kaldinimo metu įgautas blizgesys.
40	Puiki	Ex. Fine, EF40	Lengvas nudėvėjimas aukščiausiuose monetos paviršiaus iškilimuose. Monetos dizaino detalės yra labai geros kokybės. Nežymus kaldinimo blizgesio žymės gali būti matomos.
45	Ypatingai puiki	Ch. Ex. Fine, EF45	Nežymus monetos paviršiaus iškilimų nudėvėjimas. Visos dizaino detalės yra puikios kokybės. Kaldinimo blizgesys gali būti matomas sunkiai pažeidžiamose monetos vietose.
50	Beveik nedėvėta	AU, AU50	Pastebimas labai nežymus nudėvėjimas monetos paviršiaus iškilimuose. Išlikę bent pusė viso originalaus kaldinimo blizgesio.
55	Nepastebimai dėvėta	Ch. AU, AU55	¼ išlikusio originalaus kaldinimo blizgesio.
58	Nepastebimai dėvėta	Ch. AU, AU58	Išlikęs beveik visas originalus kaldinimo blizgesys.

Šio darbo tikslas yra iširti ar sukurti galimus monetos nudėvėjimo lygio būdus. Dėl šios priežasties tiriamos tik dėvėtos monetos. Tai supaprastina turimą problemą sudarant sąlygas lengviau atskirti labai geros kokybės monetas nuo kitų naudojant aprašytą Šeldono skalę (1.1 lentelė). Šiuo atveju bus sudaryti du atskiri monetų pogrupiai:

- **Mažai nudėvėtos monetos** – šio pogrupio monetos reikės vertinti pagal nežymų nudėvėjimo lygį bei, kas svarbiausia, pagal jų spalvingumą ir kaldinimo metu sudarytą blizgesį;
- **Nudėvėtos monetos** – šios monetos neturi išlikusio blizgesio ar išraiškingo spalvingumo, todėl jas vertinant dėmesys bus telkiamas į jų paviršiaus bei defektų analizę.

Taigi, Šeldono skalės bei jos pateiktų monetų įverčių apibrėžimų dėka bus galima paprasčiau vertinti įvairaus nudėvėjimo lygio monetas.

### 1.1.3. Šiuolaikinių monetų nudėvėjimo įtaka jų vertei

Istoriškai, monetos buvo gaminamos iš brangiųjų metalų, o jų vertė priklausė nuo šių metalų kiekio. Auksas ir sidabras buvo vieni iš dažniausiai naudojamų metalų šiai paskirčiai. Jie pasižymi savo minkštumu, todėl monetos gaminamos iš jų yra linkusios erozijai skatinamai įvairių mechaninių veiksnių: įbrėžimų, įpjovimų, įlenkimų bei kasdieninio jų naudojimo – dėvėjimo. Dėl šios priežasties, laikui bėgant tokios monetos tapo vis lengvesnės, o jų vertė vis mažesnė. Tuo tarpu šiuolaikinės monetos yra gaminamos iš kietųjų, pigių metalų, tokių kaip plienas, varis ar jo bei nikelio lydinys. Šie metalai yra sunkiau veikiami mechaninių veiksnių, todėl iš jų gaminamos monetos ilgainiui yra atsparesnės erozijai, tačiau yra labiau veikiamos korozijos – cheminių medžiagų poveikio. Šio poveikio metu jos oksiduojasi, o jų išorinis sluoksnis dėl susidariusio oksido praranda savo spalvos savybes bei tekstūrą. Dėl stiprios korozijos moneta gali netekti dalies savo dizaino bei skiriamųjų detalių, kurių dėka būtų galima ją identifikuoti bei patvirtinti jos autentiškumą, kas lemia visiška jos vertės praradimą. Įprastomis sąlygomis naudojant monetą, korozija bei erozija ją gali sugadinti tik per daugybę metų.

Jungtinių Amerikos Valstijų Federalinis rezervų bankas monetas keičia maždaug kas 30 metų <sup>[28]</sup>. Dauguma monetų per šį laiką tarpą išlaiko pakankamą kokybę, jog būtų sėkmingai identifikuojamos bei pakeičiamos naujomis. Vis dėlto, neretai monetos yra nudėvimos tiek, kad šis procesas tampa ypač sudėtingu ar net neįmanomu. Siekiant, atrinkti monetas, kurios yra vis dar pakankamos kokybės, jog būtų autentifikuojamos, tačiau tiek nudėvėtos, kad pakartotinai išleidus jas į apyvartą jos taps nebesugražinamos – yra taikomas jų nudėvėjimo nustatymas. Lietuvos bankas, vadovaujantis Europos Sąjungos reglamentu <sup>[22]</sup>, nepadirbtas bei sąmoningai nesugadintas monetas, tačiau pakitusia išvaizda dėl ilgo buvimo apyvartoje (subraižytos, šiek tiek deformuotos) ar paveiktas aplinkos sąlygų (ilgai buvusios vandenyje, surūdijusios ir pan.), keičia tik tuo atveju jei yra aiškiai matomi pateiktos monetos abėjų pusių vaizdai <sup>[10]</sup>.

Taigi, siekiant tikslingai sudaryti šiuolaikinių monetų kokybės vertinimo metodus, būtina atkreipti dėmesį į nudėvėjimą, būdingą ilgalaikio monetos buvimo apyvartoje bruožams, į kuriuos įeina smulkūs įbrėžimai, įlenkimai, erozijos bei korozijos sudaryti defektai.

#### 1.1.4. Iškeltos problemos analizės išvados

Šios analizės dėka buvo išanalizuota monetų vertinimo problema. Buvo išskirti svarbiausi kriterijai, vertinant monetas, pagal kuriuos galima sudaryti atitinkamą metodiką šiai užduočiai. Taip pat buvo aprašytos sąlygos, kurių dėka galima išspręsti vertinimo kriterijų subjektyvumo faktorių. Šių kriterijų dėka buvo aprašyta monetų kolekcionierių naudojama standartizuota vertinimo skalė – Šeldono skalė. Ją apsirąšius bus galima sudaryti kokybiškesne bei universalesne vertinimo pagal iškelto kriterijus sistemą. Galiausiai, buvo išskirti aktualiausi nudėvėjimo bruožai vertinant šiuolaikines, apyvartoje esančias monetas. Taigi, monetų nudėvėjimo vertinimo problemos analizės dėka buvo sudarytos gairės, kuriomis vadovaujantis bus galima kurti atitinkamus metodus spręsti šią problemą.

#### 1.2. Esamų bei susijusių darbų apžvalga

Šiuo metu monetų nudėvėjimo nustatymo tema nėra plačiai tiriama. Vienas iš darbų, kuriame tiriama ši problema buvo pateiktas Veldė. Savo darbe jis pasiūlė šios problemos sprendimo būdą pagrįsta Brauno judėjimo pritaikymu monetų nudėvėjimo nustatymui pagal jų svorio praradimą <sup>[23]</sup>. Savo darbą jis orientavo į 18-19 amžiaus monetas. Vis dėlto, šiuolaikinių monetų vertinime jų svoris nėra aktualiausias bei efektyviausias kriterijus, ypač lyginant su vizualiniu jų pateikimu. Gilinantis į šį kriterijų, kompiuterinės vizijos srityje, yra išleisti keli darbai panašiomis temomis.

Viename iš jų, tiriamas dirbtinių neuronų tinklų (trumpiau – DNT) panaudojimas klasifikuojant šiuolaikines monetas. Šiame darbe <sup>[9]</sup> buvo sudarytas mažas, 2-jų sluoksnių tankiai apjungtas neuroninis tinklas, kurio architektūra pateikta lentelėje apačioje (1.2 lentelė). Šis modelis buvo treniruojamas su 20 monetų nuotraukų. Siekiant išmokyti modelį klasifikuoti monetas buvo naudojamas nuotraukų apdirbimas, kurio metu 352x288 rezoliucijos paveikslėlis yra suspaudžiamas iki 20x20 dydžio. Toks apdirbimas žymiai palengvina modelio treniravimą, skirtą klasifikavimo užduočiai, atmetant didelę dalį paveikslėlio informacijos. Vis dėlto, siekiant įvertinti monetos nudėvėjimą, ši prarasta informacija daro šią užduotį neįmanoma.

1.2 lentelė. Monetos klasifikavimo DNT architektūra

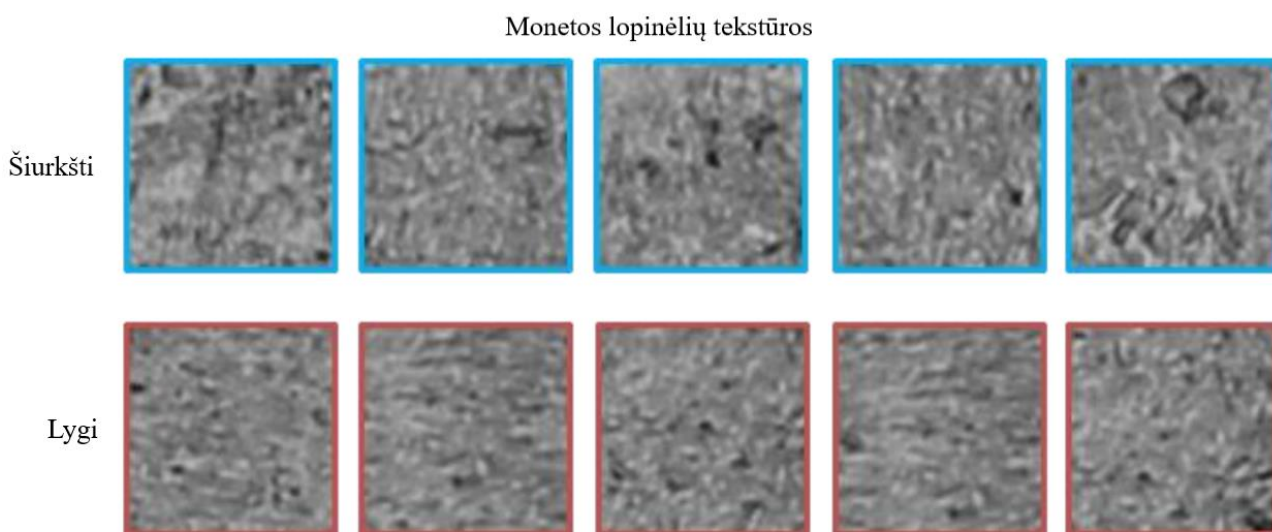
Eil. Nr.	Sluoksnio pav.	Neuronų skaičius
1	Įėjimo sluoksnis	400
2	Vidinis sluoksnis	25
3	Išėjimo sluoksnis	2

Kitame darbe, jo autoriai Pan ir Tougné <sup>[16]</sup> panaudojo gilųjį sąsūkos dirbtinių neuronų tinklą (trumpiau – SDNT) siekiant klasifikuoti monetos 64x64 dydžio lopinėlius (1.4 pav.), gautus iš plokščių monetos reljefo vietų, į dvi kategorijas: „lygus“ ir „šiurkštus“ (1.5 pav.). Besistengiant apeiti mažo duomenų kiekio problemą treniruojant tokio tipo modelį, jie pasiūlė naudoti perduodamo mokymo (angl. transfer-learning) sprendimą. Šiuo būdu, Pan ir Tougné panaudojo jau apmokytą AlexNet SDNT modelį. Tuo tarpu, darbe buvo naudojamas duomenų rinkinys susidedantis iš profesionaliai padarytų kolekcinų monetų nuotraukų esant visiškai nekintančioms apšvietimo bei padėties sąlygoms. Realiomis sąlygomis, vertinant šiuolaikines pinigines monetas susiduriama su problema, jog jos nėra identiška nufotografuotos, o nudėvėjimas gali būti randamas ir ant neplokščių jos reljefo vietų.






**1.4 pav.** Monetos lopinėliai. Paveikslukas adaptuotas iš [16]



**1.5 pav.** Monetos lopinėlių tekstūros. Paveikslėlis adaptuotas iš [16]

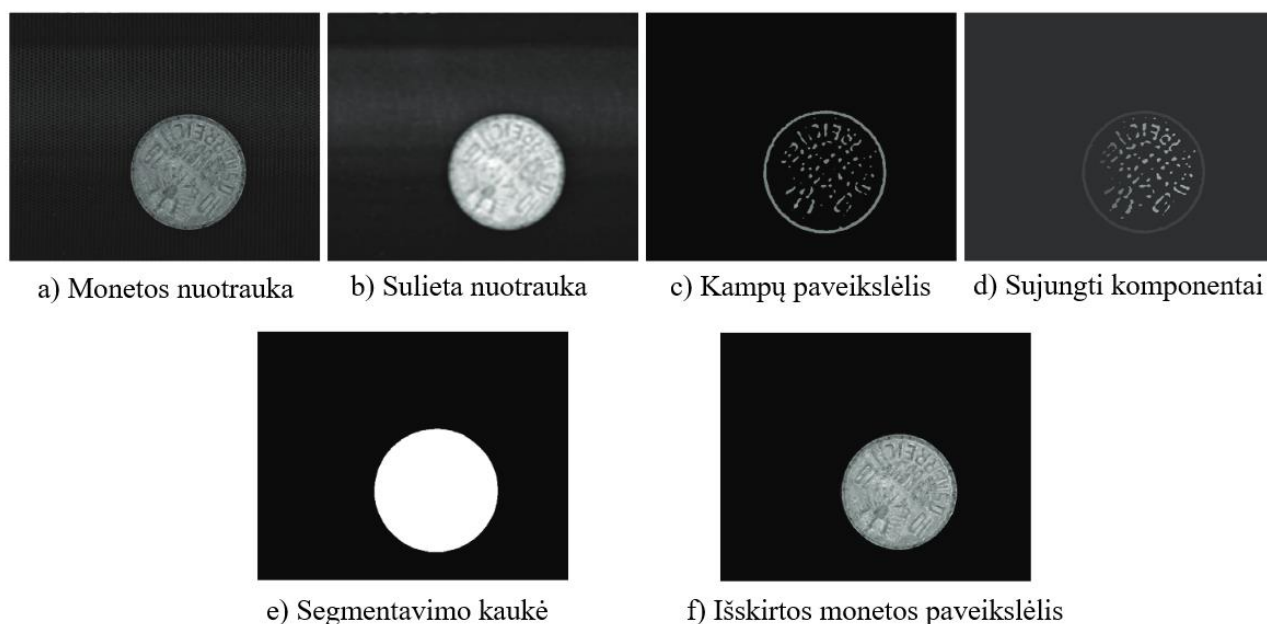
Huber-Mörk et al. darbe buvo dirbama su realiomis sąlygomis darytomis monetų nuotraukomis [6]. Jo tikslas buvo sudaryti šiuolaikinių bei antikinių monetų identifikavimo ir klasifikavimo metodus. Siekiant pasiekti kuo geresnius rezultatus, įvairūs monetos nuotraukos apdirbimo metodai buvo panaudoti. Autoriai šiuolaikinių ir antikinių monetų apdirbimui bei klasifikavimui naudojo du skirtingus būdus. Antikinių monetų išskyrimui iš nuotraukos buvo naudojamas globalios slenkstinės ribos filtravimas. Siekiant rasti šios ribos vertę buvo pasiūlyta optimalios vertės,  $t$ , radimo strategija, kurios metu mažais žingsniais didinant  $t$  yra bandoma maksimizuoti išskirtos monetos glaustumo santykį  $r = 4\pi S/P^2$ , kur  $S$  ir  $P$  yra jos plotas ir perimetras (1.6 pav.).





**1.6 pav.** Antikinės monetos segmentavimas. Paveikslėlis adaptuotas iš [6]

Tuo tarpu, šiuolaikinėms monetoms buvo pasiūlytas kampų aptikimo grįstas filtravimo metodas. Šio metodo metu, pradinis paveikslėlis buvo filtruojamas Gauso filtru, siekiant panaikinti aplinkos triukšmo detales. Tuomet, gautam filtravimo rezultatui pritaikytas Laplaso kampų aptikimas su nulinės ribos perėjimo (angl. zero-crossing) operacija. Gavus paveikslėlio kampų informaciją, naudojant sujungtų komponentų metodą buvo rastas objektas turintis didžiausią gaubiantį turį. RADIUS jį buvo apskaičiuota išgaubta jo forma, o jos tūris užpildytas, gaunant galutinę monetos segmentavimo paveikslėlyje kaukę (1.7 pav.). Šie monetos segmentavimo metodai veikia pakankamai gerai esant reliatyviai švarioje aplinkoje ir kontroliuojamoje aplinkoje, tačiau būtina juos kruopščiai sukongigūruoti individualioms situacijoms.



**1.7 pav.** Šiuolaikinės monetos segmentavimas. Paveikslėlis adaptuotas iš [6]

Šiame darbe taip pat buvo pasiūlytas metodas norint sistemą padaryti nepriklausomą nuo monetos posūkio kampo. Šiam tikslui buvo naudotas posūkio kampo radimas, naudojant greitos Furjė transformacijos pritaikymą kryžminės koreliacijos apskaičiavimui tarp apdorojamos bei šabloninės monetos. Vis dėlto, monetų nudėvėjimo vertinimo problemos atveju, tokia operacija turėtų būti naudojama atsargiai, kuomet kalbama apie kampinę interpoliaciją. Tokios operacijos metu, yra tikimybė jog susidarys nepageidaujami vizualiniai artefaktai, kurie gali pakenkti tiksliai nudėvėjimo nustatymui. Galiausiai, šiame darbe, siekiant pasiekti sistemos nepriklausomybę nuo skirtingų

apšvietimo sąlygų, jo autoriai kiekvienai išskirtai monetai pritaikė tikrinių vektorių dekompoziciją bei apskaičiavo jos tikrinį paveikslėlį (angl. Eigen-image), o jį, apdorojimo metu, pavertė į tikrinių kalvų (angl. Eigen-hills) paveikslėlį. Vis dėlto, yra nustatyta, jog šis metodas nėra tinkamas siekiant išlaikyti smulkia, su monetos nudėvėjimu susijusią informaciją <sup>[17]</sup>.

Atighehchian'ė savo tezėje <sup>[1]</sup> pasiūlė naudoti Gauso aukštų dažnių filtrą siekiant palikti tik smulkias vizualines detales monetos paveikslėlyje. Į šias detales įeina ir su monetos nudėvėjimu asocijuojami artefaktai. Autorė naudojo Gauso filtrą,  $G$ , su dideliu standartiniu nuokrypiu,  $\sigma$ , kaip žemų dažnių filtrą. Šį filtrą naudojant su monetos bespalviu paveikslėliu,  $I$ , buvo gautas stambių detalių paveikslas,  $I_L$ . Į šias detales įeina tokia vaizdo informacija kaip netiesinis jo apšvietimas, šešėliai, ir net monetos metalo spalvos. Toliau, šių detalių paveikslėlis yra atimamas iš pradinio paveikslo, ko rezultate gaunama tik aukštų dažnių informacija. Galiausiai, siekiant normalizuoti šią informaciją, prie jos yra pridama žemų dažnių informacijos vidutinė reikšmė,  $\mu_L$ . Gautas rezultatas yra normalizuotas aukštų dažnių (smulkių detalių) paveikslas,  $I_H$ , į kurį įeina tokios vizualinės detalės kaip monetos dizaino kontūrai, įbrėžimai ir deformacijos.

$$I_L = G(x, y, \sigma) * I(x, y) \quad (1)$$

$$\mu_L = \frac{1}{nm} \sum_{i,j}^{n,m} I_L(i, j) \quad (2)$$

$$I_H = I - I_L + \mu_L \quad (3)$$

Šiame darbe paveikslėlio segmentavimui, kaip kad Huber-Mörk et al. darbo atveju buvo naudojamas kampų aptikimu pagrįstas segmentavimo algoritmas. Autorė šiai užduočiai nusprendė naudoti Canny'io kampų aptikimo metodą kartu su Hough'o transformacija, kuri yra skirta rasti apskritimus aptiktų kampų paveiksle. Vis dėlto, šiems metodams būtina nustatyti tinkamus parametrus individualiems atvejams, o jų naudojimas realiomis – nestabiliomis sąlygomis gali atnešti nepageidaujamų rezultatų. Savo darbe, Atighehchian'ė pristatė, gerai žinomą kompiuterinių vaizdų apdorojimo algoritmą monetų nudėvėjimo įvertinimui. Ji naudojo, SIFT (angl. Scale Invariant Feature Transform) deskriptorių ir vaizdinių žodžių kratinio (angl. Bag of Visual Words, BoVW) metodo junginį, siekiant išgauti monetos nuotrauką apibūdinantį duomenų vektorių. Šį vektorių ji pasiūlė klasifikuoti į dvi arba tris klases nurodančias monetos nudėvėjimo lygį. Tai buvo atliekama atraminių vektorių (angl. Support Vector Machine, SVM), ir  $k$  arčiausių kaimynų klasifikatoriais (angl.  $k$  – Nearest Neighbors,  $k$ -NN). Šio darbo eigos metu buvo nustatyta jog SVM klasifikatorius yra geriausias kandidatas šiai užduočiai. Eksperimentų metu buvo įrodyta, jog klasifikuojant monetas į daugiau nei dvi grupes, naudojant SVM klasifikatorių su RBF (angl. Radial Basis Function), priešingai nei tiesiniu branduoliu, modelis geba geriau atskirti šias klases. Tai parodo jog, monetos nudėvėjimo detalės gali būti įvardijamos kaip netiesinė informacija.



a) Originali moneta;

b) Moneta su pašalintu fonu ir normalizuotu apšvietimu;

**1.8 pav.** Monetos apdirbimas. Paveikslas adaptuotas iš <sup>[1]</sup>

Atlikus esamų darbų apžvalgą galima pastebėti, jog dauguma aprašytų metodų ir sprendimų naudoja monetų apdirbimo strategijas, siekiant išskirti kuo aktualesnę informaciją monetų nudėvėjimo problemai. Vienas iš didžiausių trūkumų šiuose darbuose yra monetų išskyrimas iš jos paveikslų fono. Beveik visi šie metodai reikalauja kruopštaus segmentavimo parametrų suderinimo prieš jų panaudojimą. Galiausiai, buvo atkreiptas dėmesys į monetos nudėvėjimo nustatymo ryšį su jos tekstūros klasifikavimu.

### 1.3. Vaizdų fono segmentavimo metodai

Siekiant sukurti monetos fono segmentavimo metodą, kuris būtų kokybiškesnis – labiau prisitaikantis prie įvairių apšvietimo bei fono sąlygų, šiame poskyryje buvo atlikta galimų metodų analizė.

Apdorojant specifinius objektus paveikslėlyje dažniausiai naudojamas žingsnis yra jų išskyrimas iš paveikslėlio fono atliekant segmentavimo operaciją. Tai ypač svarbu kalbant apie monetų vaizdų pradinį apdorojimą, siekiant paruošti juos jų klasifikavimui ar nudėvėjimų įvertinimui bei aptikimui. Fono įtakos pašalinimas yra itin svarbus tokio tipo problemose, nes dažnai jame esanti informacija gali būti sulyginama su nudėvėjimu susijusiomis vizualiniais artefaktais. Šiems artefaktams gali priklausyti spalvų iškraipymai, įbrėžimai, paviršiaus įlenkimai arba priešingai – išskiriamos tekstūros trūkumas, kaip kad turint monetą kurios reljefas yra glotniai nudilęs nuo per ilgo jos naudojimo.

Dažniausiai naudojami fono šalinimo būdai susideda iš pikselių verčių slenkstinės ribos filtravimo bei klasterizavimo. Kaip kad Oliverio darbe <sup>[14]</sup>, šiame darbe slenkstinės ribos filtravimas laikomas specialiu klasterizavimo atveju, kuomet yra naudojami tik du klasteriai norint atskirti informaciją. Tai yra aktualu šiame darbe, nes monetos paveikslų segmentavimas yra sudarytas iš dvejų kategorijų: monetos ir jos fono. Savo darbe, Fu ir Mui <sup>[3]</sup> atskyrė slenkstinės ribos filtravimo metodus atskyrė į dvi grupes pagal jų erdvinės informacijos panaudojimą: statistinius ir struktūrinius metodus. Statistiniai metodai nenaudoja erdvinės informacijos turimuose duomenyse bei gali būti dvejų tipų: vietiniai, arba globalūs. Šios grupės filtravimas gali būti apibrėžtas kaip funkcija  $T(x, y, I, N)$ , kur  $x$  ir  $y$  yra paveikslų erdvinės koordinatės,  $I(x, y)$  yra jo pikselis šiose koordinatėse, o  $N(x, y)$  yra vietinės kaimynystės vertė duotai koordinatei. Globalūs, priešingai nei vietiniai filtravimo metodai netaiko  $N$ , todėl jie yra labiau naudojami situacijose, kuomet yra tvirtas įsitikinimas, jog turimi

duomenys yra dvimodaliniai <sup>[18]</sup>. Būtent tokia situacija yra ir šiame darbe, kuomet tikimasi rasti tik dvi atskiras grupes pikselių verčių. Vis dėlto, tokiais atvejais, kuomet monetos nuotraukos fonas nėra vientisas dėl galimų kitimų apšvietime ar fono tekstūroje (pvz.: nešvarus ar stipriai tekstūruotas konvejerio takas), yra tikimybė, jog dalis fono gali būti klaidingai klasifikuojama kaip monetos objekto dalis. Spręsti šia problema, dažnai naudojamas kitas filtravimo tipas – struktūrinis filtravimas. Šis tipas neretai naudoja prieš tai minėtus statistinio filtravimo metodus siekiant išskirti skirtingas pikselių intensyvumo zonas skaitmeniniame vaizde. Šias zonas, struktūrinio filtravimo algoritmas, apdirba topologiją apibrėžiančiais būdais, tokiais kaip sujungtų komponentų metodu, kurio metu yra sunumeruojamos atskiros pikselių zonos bei joms apskaičiuojama ir priskiriama geometrinė informacija kaip kad perimetras, plotas, masės centras, gaubiančio tūrio koordinatės ir kt. Turint šią objektų struktūrinę informaciją yra naudojamas antras slenkstinės ribos filtravimas, kurio metu segmentavimas atliekamas ne paveikslų vertėms, o geometrinės jų zonų reikšmėms. Taip yra išgaunamas struktūriškai išskaidytas paveikslėlis į skirtingus geometrinius objektus <sup>[3]</sup>.

Viena iš pagrindinių problemų, kuria pasižymi visi slenkstinės ribos filtravimo algoritmai – tai tikslios ribinės vertės,  $t$ , nustatymas, siekiant taisyklingai padalyti duomenų skirstinį. Šiai problemai spręsti yra pasiūlytas ne vienas metodas. Vienas iš populiariausių, bei žinomiausių yra Otsu sukurtas algoritmas <sup>[16]</sup>. Šis algoritmas yra paremtas eikvotu vienspalvio paveikslėlio histogramos,  $h$ , atskirų klasių dispersijų minimizavimu. Tai taip pat gali būti išreikšta ir tarpklasinės dispersijos maksimizavimu.

$$h_k = \sum_{i,j}^{n,m} [I(i,j) = k], \quad 0 < k \leq \max I \quad (4)$$

$$z_b = \sum_{i=0}^t h_i \quad (5)$$

$$w_b = \frac{z_b}{nm} \quad (6)$$

$$\mu_b = \frac{1}{z_b} \sum_{i=0}^t h_i i \quad (7)$$

$$\sigma_b^2 = \frac{1}{z_b} \sum_{i=0}^t h_i (i - \mu_b)^2 \quad (8)$$

$$z_f = \sum_{i=t+1}^{k-t} h_i \quad (9)$$

$$w_f = \frac{z_f}{nm} \quad (10)$$

$$\mu_f = \frac{1}{z_f} \sum_{i=t+1}^{k-t} h_i i \quad (11)$$

$$\sigma_f^2 = \frac{1}{Z_f} \sum_{i=t+1}^{k-t} h_i (i - \mu_f)^2 \quad (12)$$

$$t = \arg \min w_b \sigma_b^2 + w_f \sigma_f^2 \quad (13)$$

Žinoma, jog Otsu metodas geriausiai veikia naudojant jį apskaičiuoti griežtai dvimodalinės histogramos, su plačiu bei giliu skyrimu tarp jos dvejų viršūnių, ribinę vertę. Vis dėlto, šis algoritmas dažnai pateikia prastos kokybės rezultatus, kuomet pradinio vaizdo fono ir subjekto plotų santykiai yra nelygus 1. Šis pastebėjimas kelia susirūpinimą, kuomet kalbama apie monetų paveikslėlio segmentavimą, nes tokiu atveju šis santykis dažnai yra gerokai didesnis ar mažesnis už 1.

Kitas gerai žinomas slenkstinės ribos,  $t$ , nustatymo metodas yra pasiūlytas Kapuro, Sahoo ir Wongo [9]. Šis metodas yra paremtas Shannon'o informacijos entropija [22]. Autoriai iškėlė sąlygą, jog vienspalvio paveikslėlio pikselių vertės sudaro du atskirus tikimybių skirstinius priklausančius jo fono bei subjekto zonoms. Jų pasiūlytas metodas yra sudarytas taip, kad maksimizuojant paveikslėlio histogramos tarpklasines entropijas, būtų randama geriausia reikšmė  $t$ .

$$g_k = \frac{h_k}{\sum_{i=0}^n h_i} \quad (14)$$

$$H_b^t = - \sum_{i=0}^t \frac{g_i}{\sum_{j=0}^t g_j} \log \frac{g_i}{\sum_{j=0}^t g_j} \quad (15)$$


$$H_f^t = - \sum_{i=t+1}^{k-t} \frac{g_i}{\sum_{j=t+1}^{k-t} g_j} \log \frac{g_i}{\sum_{j=t+1}^{k-t} g_j} \quad (16)$$

$$t = \arg \max H_b + H_f \quad (17)$$

Testavimo metu su realiais vaizdais (1.9 pav.), turinčius santykinai maža plotą užimančius objektus, buvo pastebėta, kad šis entropijos didinimu pagrįstas metodas nėra stipriai veikiamas objektų dydžio, o dirbant su didelio kontrasto, dvimodaline informacija pasiekiami geresni rezultatai nei Otsu ar kitais panašiais metodais (1.10 pav.) [8].

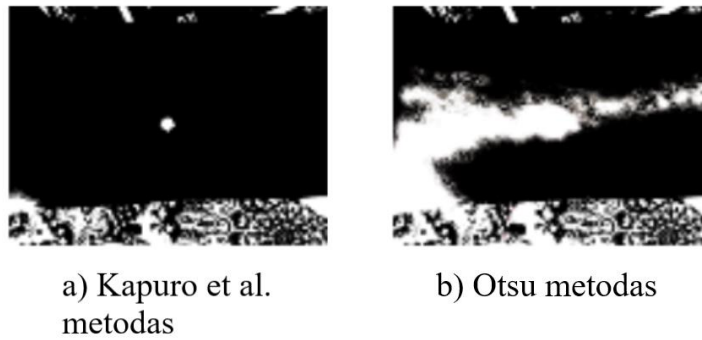


a) Paveikslas



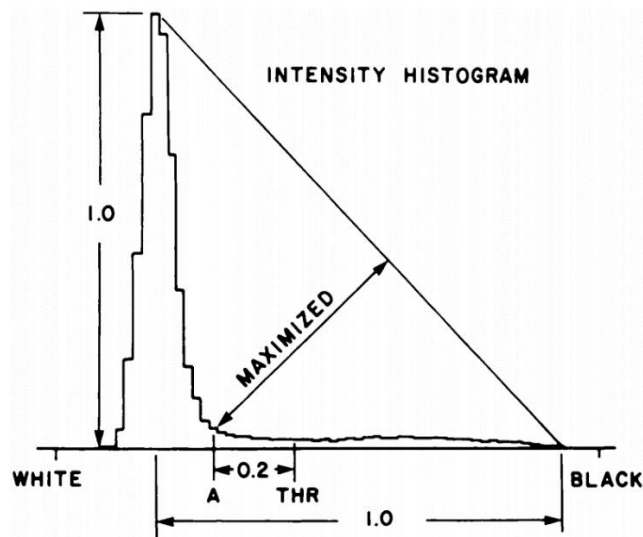
b) Paveikslas histograma

1.9 pav. Žaizdos nuotrauka ir jos histograma. Paveikslas adaptuotas iš [7]



1.10 pav. Žaizdos nuotraukos slenkstinės ribos filtravimo metodų palyginimas. Paveikslas adaptuotas iš [7]

Savo darbe, Zack'as, Rogers'as ir Latt'as [25] pasiūlė globalios slenkstinės ribos radimo algoritmą skirtą naudoti kartu su vienspalviais paveikslėliais, biomedicinos srityje. Šiuose paveiksluose buvo pateiktos žmogaus chromosomos, kurių dydis yra santykinai mažas lyginant su jų fono plotu. Siekiant išskirti jas iš aplinkos, autoriai pasiūlė naudoti slenkstinę ribą, *THR*, kurią galima rasti normalizavus histogramos aukštį bei jos verčių intervalą ir randant tašką *A*, prie kurio pridedama statistiškai pasirinktą postūmio reikšmę 0,2, kaip kad parodytą jų pačių pateiktoje diagramoje (1.11 pav.). Šis metodas nėra remiamas teoriniais išvedimais bei įrodymais, tačiau galimai buvo sudarytas eksperimentų metu. Vis dėlto, šis metodas yra dažnai naudojamas vaizdų apdorojime bei yra vertinamas dėl savo paprastumo ir kokybės, tiek tikslumo, tiek laiko sąnaudų atžvilgiu.



1.11 pav. Trikampio slenkstinės ribos nustatymo metodo grafas [25]

Taigi, šioje dalyje buvo apžvelgti monetos ir jos fono segmentavimui tinkami metodai, kuriems nebūtina nustatyti pradinių parametru siekiant gauti gerus rezultatus. Taip pat buvo atkreiptas dėmesys į kiekvieno iš šių metodų panaudojimo galimybes bei problemas, kurių galima tikėtis darbo eigoje naudojant juos.

#### 1.4. Monetos apšvietimo efektų šalinimo metodai

Apdorojant monetų nuotraukas, net ir kontroliuojamomis sąlygomis, yra svarbu sumažinti apšvietimo įtaką rezultatams. Taip yra todėl, kad visos monetos, net ir to pačio dizaino, gali pateikti skirtingus atspindžius bei skirtingai sklaidyti šviesą savo paviršiumi. Keletas galimų priežasčių tam yra monetos paviršiaus užterštumas ar nudėvėjimas. Monetų nudėvėjimo nustatymo problemos atveju, juose naudotų metalų spalva kelia problemą, nes dažniausiai nudėvėjimas gali būti apibendrinamas net ir daugiau nei vienam monetos dizainui, tačiau skirtingų monetų nuotraukų pikselių intensyvumo reikšmės sudaromos dėl spalvos nekoreliuoja su pačiu nudėvimu. Tai kelia papildomus iššūkius siekiant tiksliai nustatyti šį nudėvėjimo lygį.

Šiuo metu yra keletas darbų, kuriuose tiriama nepriklausomybė nuo šviesos skaitmeniniuose vaizduose. Vis dėlto, dauguma metodų šiuose darbuose buvo orientuoti į specifinius panaudos atvejus. Gerai žinomi bei plačiai naudojami SIFT deskriptoriai, sukurti Lowe'o <sup>[11]</sup> yra vienas iš geriausių to pavyzdžių. SIFT dėka, kompiuterinės vizijos srityje buvo pasiekta daug proveržių, o šis metodas buvo ir yra plačiai naudojamas robotikos bei medicinos srityse. Nepriklausomybę nuo apšvietimo buvo bandoma pasiekti keliais būdais. Pirma, išskiriant lokalizuotas paveikslėlio vietas, kas sumažina deskriptorių priklausomybę nuo vietinio apšvietimo sukeltų efektų. Antra, apskaičiuojant deskriptoriaus histogramą bei ją normalizuojant į 128 vienetų ilgio ortą, kas sumažina tiesinio apšvietimo intensyvumo įtaką. Trečia, siekiant sumažinti netiesinių apšvietimo efektų įtaką, deskriptoriaus orto reikšmės buvo nurežiamos iki nustatyto lygio, priklausomai nuo jų pasiskirstymo. Vis dėlto, SIFT algoritmas nepasiekia gerų rezultatų, kuomet dirbama su vaizdais pasižyminčiais didesniu apšvietimo sąlygų kitimu. Tai buvo ištestuota ir įrodyta esamų darbų, kurių metu buvo siekiama pritaikyti SIFT deskriptorius realiems, nestabiliaus apšvietos, scenarijams <sup>[11]</sup>.

Tikras, nepriklausomybę nuo apšvietimo pasiekiantis sprendimas, skirtas įprastoms 2D RGB skaitmeninėms kameroms buvo pasiūlytas Maddern'o et al. <sup>[13]</sup>. Šiame darbe buvo pasiūlyta nuo apšvietimo nepriklausoma, vieno kanalo kompiuterinių vaizdų spalvų erdvė (19). Ši spalvų erdvė yra sudaryta taip, kad ją būtų galima išgauti iš RGB erdvės, atlikus transformaciją, kurios metu yra naudojami optinio sensoriaus, naudojančio Bayer'io filtrą, parametrai. Ši transformacija yra atliekama RGB erdvėje esančiam paveikslėliui,  $I$ . Darbo autoriai, pasiūlė metodą, kurio dėka būtų galima išgauti spalvų erdvės konversijos parametras,  $\alpha$ , priklausomą nuo naudojamo optinio sensoriaus. Šis parametras yra apskaičiuojamas žinant sensoriaus atskirų RGB kanalų didžiausias spektrinio atsako vertes,  $\lambda_r < \lambda_g < \lambda_b$ , kurios yra randamos arba apskaičiuojamas iš jo specifikacijos (18). Toks konversijos parametro radimo būdas yra priešingas kitam darbui šia tema, kuriame parametras  $\alpha$  yra parenkamas statistiškai, naudojant nuotraukų duomenų rinkinį <sup>[2]</sup>.

$$\frac{1}{\lambda_g} = \frac{\alpha}{\lambda_r} + \frac{(1 - \alpha)}{\lambda_b} \quad (18)$$

$$I_{inv} = \frac{1}{2} + \log I_g - \alpha \log I_r - (1 - \alpha) \log I_b \quad (19)$$

Taigi, šiame skyriuje buvo apžvelgti du metodai turintys savybes šalinti ar ignoruoti apšvietimo sąlygas. Vienas iš šių metodų yra orientuotas į vaizdų vietinių detalių apdorojimą, tuo tarpu kitas sprendžia turimą problemą taikant nuo apšvietimo nepriklausomą spalvų erdvės transformaciją.

## 1.5. Monetos nudėvėjimo deskriptoriai

Lowe'o sukurtas SIFT algoritmas <sup>[11]</sup> yra vienas populiariausių algoritmų skirtų vaizdų atpažinimui bei yra plačiai naudojamas kompiuterinės vizijos srityje. SIFT algoritmo esmė yra jo metu sudaryti deskriptoriai, nusakantis lokalaus paveiksluko turinio išraišką. Šie deskriptoriai gali būti lyginami su kitais turimais deskriptoriais, siekiant rasti panašų turinį skirtingose vaizduose ar jų vietose. Tai yra ypač naudinga kompiuterinės vizijos uždaviniuose kaip objektų bei tekstūros atpažinimas, pozos nustatymas ir palyginimas.

SIFT algoritmas veikia pakopinio filtravimo būdu. Šiuo būdu paprastos mažų sąnaudų operacijos yra taikomos didelei imčiai duomenų siekiant išskirti mažą kiekį elementų, kuriems vėliau yra taikomos sudėtingesnės operacijos. Šis algoritmas yra sudarytas iš keturių šių pakopų, kurių metu yra siekiama išgauti specifinį paveiksluko turinį nusakancias savybes. Šios pakopos yra:


5. **Kontrasto taškų nustatymas mastelio erdvėje.** Tai yra pirmasis paveiksluko apdorojimo etapas, kurio metu yra ieškomi paveiksluko mastelio pokyčiams atsparūs taškai.
6. **Lokalizacija.** Kiekvienam rastam taškui yra taikomas lokalizacijos modelis, kurio metu yra apskaičiuojama tiksli jo pozicija paveiksliuke bei mastelio erdvėje. Taip pat, taikomas taškų filtravimas pagal jų stabilumą.
7. **Orientacijos priskyrimas.** Kiekvienam lokalizuotam taškui yra priskiriama viena ar daugiau galimų orientacijų pagal jį aplink apskaičiuotų intensyvumo pokyčio krypčių. Visos tolimesnės operacijos yra atliekamos su paveiksluko duomenimis transformuotais pagal nustatyta orientaciją, lokaciją ir mastelį. Tai užtikrina duomenų apsaugą nuo šių parametrų įtakos.
8. **Paveiksluko taško deskriptoriaus sudarymas.** Lokalūs gradientai yra apskaičiuojami aplink kiekvieną nustatytą tašką. Šie gradientai yra pateikiami forma, kuri yra atspari apšvietimo bei tekstūros iškraipymo įtakai.

Sudaryti SIFT deskriptoriai tai yra lokalaus paveiksluko turinio išraiška. Šie deskriptoriai gali būti lyginami su kitais turimais deskriptoriais, siekiant rasti panašų turinį skirtingose paveiksliukuose ar jų vietose. Tai yra ypač naudinga kompiuterinės vizijos uždaviniuose kaip objektų atpažinimas, pozos nustatymas ir palyginimas.

### 1.5.1. Kontrasto taškų nustatymas mastelio erdvėje

Pirmas etapas sudarant SIFT algoritmą yra kontrasto taškų nustatymas paveiksluko mastelio erdvėje  $L(x, y, \sigma)$ . Ši erdvė yra sudaryta iš trijų dimensijų: paveiksluko pikselių  $x$  ir  $y$  pozicijų bei jo mastelio  $\sigma$ . Paveiksluko mastelį galima išivaizduoti kaip jo peržiūra iš skirtingų atstumų. Žiūrint iš arčiau, pastebimos smulkios jo detalės – tuo tarpu, žiūrint iš toliau pastebimos tik stambesnio mastelio detalės. Paveiksluko taškas, kuriame skirtumas tarp gretimų mastelio reikšmių yra itin didelis lyginant su jį supančiomis reikšmėmis (ekstremumo taškas), nusako, jog jame esanti paveiksluko tekstūra yra atspari mastelio pokyčiams. Mastelių skirtumų funkciją galima efektyviai sudaryti naudojant normalizuotos Laplaso funkcijos aproksimaciją – Gauso skirtumų funkciją  $D(x, y, \sigma)$ . Šios aproksimacijos įrodymas yra pateiktas originaliame SIFT algoritmo darbe. Diskreti mastelio erdvė yra sudaroma paveiksliukui  $I(x, y)$  taikant Gauso funkciją  $G(x, y, \sigma)$  naudojant sąsūkos operaciją  $s$  kartų, kurios metu gauti nauji paveiksliukai yra nutolę vienas nuo kito  $k\sigma$  masteliu. Parametras  $s$  yra mastelio erdvės kvantavimo dydis, kuris nusako jos rezoliuciją.





1.12 pav. Mastelio erdvė  $L$  su kvantavimo dydžiu  $s = 3$


Atstumai tarp diskrečių mastelio taškų yra lygūs  $k = 2^{1/s}$  (1.12 pav.). Tai užtikrina, jog kas  $s$  mastelio taškų, mastelis įgaus dvigubai didesnę reikšmę nei pradinę:  $\sigma_{i+s} = 2\sigma_i$ .

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (20)$$

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (21)$$


$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (22)$$

Siekiant rasti minėtus paveiksluko taškus, kuriuose jo tekstūra yra atspari mastelio pokyčiams yra naudojama Gauso skirtumų funkcija  $D$  gretimoms mastelio taškų poroms. Sudarius  $s + 3$  mastelio taškus yra gaunama viena diskrečios mastelio erdvės oktava. Oktava, įgauna savo pavadinimą dėl to, kad sudarius ją kuomet  $s = 1$ , yra gaunami 8 paveikslukai. Pateiktame paveiksle (1.13 pav.) galima matyti kaip atrodo dvejų oktavų struktūra. Iš mastelio erdvės taškų porų sudaromi Gauso skirtumai  $D$ , o tarp jų yra ieškoma ekstremumo taškų.




1.13 pav. Dvejų oktavų sandara ( $s = 1$ )

Originaliame darbe, oktavos sudarymo metu pradiniam paveiksliukui yra taikoma sąsūkos operacija naudojant tą pačią Gauso funkciją. Taip yra daroma, nes vietoje to, kad būtų naudojamas vis didesnio standartinio nuokrypio Gauso filtras kiekvieno mastelio generavimo metu, galima naudoti vieną mažą filtrą, kurį panaudojus kelis kartus tam pačiam paveiksliukui gaunamas identiškas rezultatas kaip ir pirmu būdu. Šis būdas yra gerokai našesnis, tačiau, šiame darbe, jis nebuvo sėkmingai realizuotas, todėl jis nebuvo buvo naudojamas. Sudarius oktavą, yra nuskaitomas paveiksliukas  $D(x, y, 2\sigma_i)$  esantis 2 kartus aukštesniame mastelyje nei pradinis oktavos paveiksliukas  $\sigma_i$ . Šis paveiksliukas yra nuskaitomas kas antrą pikselį, kas sumažina jo dydį du kartus. Tai padarius jam yra taikomas Gauso filtras  $G$ , kaip ir pirmos pakopos sudarymo metu. Taip yra sudaroma antroji bei likusios pakopos. Šis procesas yra pateiktas šiuose paveiksluose (1.13 pav. ir 1.14 pav.).



**1.14 pav.** Dvejų oktavų sudarymas ( $s = 2$ ) be ekstremumo taškų paieškos dalies (dvi pakopos) <sup>[11]</sup>

Galiausiai, apskaičiuavus Gauso funkcijų skirtumo paveiksliukus yra naudojamas  $3 \times 3 \times 3$  dydžio paieškos langas, kurio paskirtis yra rasti nuo mastelio nepriklausomus taškus diskrečioje mastelio erdvėje aptinkant ekstremumo taškus  $D$  erdvėje (1.15 pav.).



**1.15 pav.**  $3 \times 3 \times 3$  paieškos langas diskrečioje Gauso f-jos skirtumų erdvėje  $D$ . X – centrinis lango elementas <sup>[11]</sup>

Tai yra atliekama stumiant paieškos langą erdvėje  $D(x, y, \sigma)$  bei tikrinant ar centrinio paieškos lango elemento vertė yra didžiausia arba mažiausia iš visų lango elementų verčių, kas nusako jog rastas

taškas yra šios diskrečios funkcijos lokalus ekstremumas. Taip nustatomi diskretūs, mastelio pokyčiams atsparūs taškai diskrečioje mastelio erdvėje.

### 1.5.2. Taškų lokalizavimas

Nustačius galimus mastelio pokyčiams atsparius taškus diskrečioje erdvėje, sekantis žingsnis yra juos perskaičiuoti tolydžioje mastelio erdvėje. Tai yra atliekama pritaikius 3D kvadratinę funkciją prieš tai naudotam paieškos langui Gauso funkcijų skirtumo erdvėje  $D$ , kuriame buvo aptiktas diskretus šios erdvės ekstremumas. SIFT algoritmo aprašyme, autorius pasirinko naudoti mastelių skirtumo erdvės funkcijos,  $D(x, y, \sigma)$ , Teiloro kvadratinį išplėtimą, pastūmus funkcijos pradžia į prieš tai nustatytą tašką:

$$\mathbf{x} = \{x, y, \sigma\} \quad (23)$$


$$D(\mathbf{x}) = D + \frac{\partial D^T}{\partial \mathbf{x}} \mathbf{x} + \frac{1}{2} \mathbf{x}^T \frac{\partial^2 D}{\partial \mathbf{x}^2} \mathbf{x} \quad (24)$$

$$\hat{\mathbf{x}} = -\frac{\partial^2 D^{-1}}{\partial \mathbf{x}^2} \frac{\partial D}{\partial \mathbf{x}} \quad (25)$$

$$D(\hat{\mathbf{x}}) = D + \frac{1}{2} \frac{\partial D^T}{\partial \mathbf{x}} \hat{\mathbf{x}} \quad (26)$$

Išvedus pirmo ir antro laipsnio dalines išvestines taikant baigtinių skirtumų metodą jos yra naudojamos apskaičiuoti 3D parabolės ekstremumo koordinatės  $\hat{\mathbf{x}}$  tolydžioje mastelio erdvėje. Apskaičiavus šio taško tikslias koordinatės erdvėje, yra apskaičiuojama jo vertė  $D(\hat{\mathbf{x}})$ , kuri yra tikrinama ar nėra mažesnė už 0,03. Jei ši vertė yra didesnė už šį skaičių, laikoma, kad taškas esantis nustatytose koordinatėse yra pakankamai atsparus mastelio pokyčiams, tačiau jei šis kriterijus yra nepatenkinamas, taškas yra praleidžiamas ir daugiau nevertinamas.

Didelė dalis taškų yra aptinkami ties įvairiais kampais, tačiau tokie taškai dažniausiai yra lengvai veikiami triukšmo nes jie yra prastai nustatyti. Dėl šios priežasties, SIFT darbe šie kampai yra atmetami. Tai yra atliekama remiantis tuo, jog prastai nustatyti ekstremumo taškai Gauso skirtumų funkcijoje išsiskiria aiškios viršūnės nebuvimu. Turint aptiktą tašką ties kampu, galima pastebėti, jog principinis lenkimas einantis ištisai šį kampą (1.16 pav.) yra žymiai mažesnis lyginant su lenkimu einančiu statmenai jam (lenkimu per kampą).



**1.16 pav.** Principiniai Gauso skirtumų funkcijos  $D$  lenkimai ties nurodytu tašku

Čia  $\vec{\alpha}$  ir  $\vec{\beta}$  yra erdvės lenkimų tikriniai vektoriai.

Taigi, pirma yra apskaičiuojami principiniai lenkimai. Jie yra apskaičiuojami naudojant  $2 \times 2$  Hesse matricą  $\mathbf{H}$  sudarytą ties nustatytu funkcijos  $D(x, y, \sigma)$  tašku randant santykį tarp matricos tikrinių verčių,  $\alpha$  ir  $\beta$ , kurios nusako didžiausią ir mažesnę principinių lenkimų dydžius. Ši sąlyga supaprastina šio santykio apskaičiavimą, nes tai leidžia praleisti šių verčių apskaičiavimą, ieškant tik jų santykio  $r$ .

$$\mathbf{H} = \begin{bmatrix} \frac{\partial^2 D}{\partial x^2} & \frac{\partial^2 D}{\partial x \partial y} \\ \frac{\partial^2 D}{\partial x \partial y} & \frac{\partial^2 D}{\partial y^2} \end{bmatrix} \quad (27)$$

$$\text{tr}(\mathbf{H}) = \frac{\partial^2 D}{\partial x^2} + \frac{\partial^2 D}{\partial y^2} = \alpha + \beta \quad (28)$$

$$\det(\mathbf{H}) = \frac{\partial^2 D}{\partial x^2} \frac{\partial^2 D}{\partial y^2} - \frac{\partial^2 D}{\partial x \partial y}^2 = \alpha\beta \quad (29)$$

Apskaičiavus Hesse matricos tikrinių reikšmių sumą bei sandaugą naudojant pateiktas formules (28)(29) galima apskaičiuoti ir santykį tarp jų  $r$ , kuris naudojamas sąlygoje  $\alpha = r\beta$ . Įvykus retam atvejui, kuomet tikrinių vektorių sandauga yra lygi ar mažiau 0, naudojamas taškas yra atmetamas. Taigi, naudojantis sudarytomis sąlygomis yra tikrinama ar  $r > \frac{\alpha}{\beta}$ . Šią sąlyga galima pateikti kita išraiška (31), kuri nereikalauja tikrinių verčių apskaičiavimo. Ši nauja išraiška gaunama išsprendus pateiktą tiesinių lygčių sistemą (30).

$$\begin{cases} r = \frac{\alpha}{\beta} \\ \text{tr}(\mathbf{H}) = \alpha + \beta \\ \det(\mathbf{H}) = \alpha\beta \end{cases} \quad (30)$$

$$\alpha = r\beta$$

$$\text{tr}(\mathbf{H}) = r\beta + \beta = \beta(r + 1)$$

$$\beta = \frac{\text{tr}(\mathbf{H})}{r + 1}$$

$$\det(\mathbf{H}) = \alpha \frac{\text{tr}(\mathbf{H})}{r + 1}$$

$$\alpha = \det(\mathbf{H}) \frac{(r + 1)}{\text{tr}(\mathbf{H})}$$

$$r = \frac{\alpha}{\beta} = \det(\mathbf{H}) \frac{(r + 1)^2}{\text{tr}(\mathbf{H})^2}$$

$$r > \det(\mathbf{H}) \frac{(r+1)^2}{\text{tr}(\mathbf{H})^2}$$

$$\frac{\text{tr}(\mathbf{H})^2}{\det(\mathbf{H})} < \frac{(r+1)^2}{r} \quad (31)$$

Sudarytos sąlygos (31) nepatenkinus, yra laikoma, kad taškas yra ties kampu ir jis nėra stabilus, todėl jis yra atmetamas.

### 1.5.3. Orientacijos priskyrimas

Nustačius geros kokybės paveiksluko taškus mastelio erdvėje  $L(x, y, \sigma)$  sekantis žingsnis yra apskaičiuoti aplink šiuos taškus esančias lokalias pikselių intensyvumo gradientus. Šie gradientai nusako šiuose taškuose aptiktų tekstūrų orientacijas. Žinant šias orientacijas, nesunku pastebėti, jog jų dėka yra įmanoma išgauti lokalių paveiksluko tekstūrų informaciją nepriklausančia nuo jo peržiūros bei posūkio kampo.

SIFT darbo autorius šiam tikslui nusprendė naudoti metodą, kurio principas yra panašus į taip vadinamą gradientų orientacijų histogramą. Šio metodo metu turint rastą tolydų tašką diskrečioje mastelio erdvėje  $L(x, y, \sigma)$ , yra parenkamas artimiausias apskaičiuotas mastelis jam. Kiekvienam paveikslukui,  $L(x, y)$ , šiame mastelyje, apskaičiuojami gradientų dydžiai  $m(x, y)$  ir jų orientacijos  $\theta(x, y)$ , regione aplink turimo taško koordinatės naudojant gretimų pikselių skirtumus.

$$m(x, y) = \sqrt{[L(x+1, y) - L(x-1, y)]^2 + [L(x, y+1) - L(x, y-1)]^2} \quad (32)$$

$$\theta(x, y) = \tan^{-1} \left( \frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)} \right) \quad (33)$$

Regionė aplink analizuojamą paveiksluko tašką yra sudaroma gradientų orientacijų histograma. Ši histograma turi 36 stulpelius aprėpiančius 360 laipsnių orientacijos erdvę  $\theta$ . Kiekvienas apskaičiuotas regiono orientacijos dydis,  $m$ , yra talpinamas į jam skirtą histogramos stulpelį prieš tai pasveriant šio dydžio įtaką naudojant normalizuotą 2D Gauso funkciją, kuri yra centruota ties lokalizuoto paveiksluko taško koordinatėmis. Šios Gauso funkcijos standartinis nuokrypis,  $\sigma$ , yra 1,5 karto didesnis nei taško mastelis. Sudarius histogramą, joje esančios reikšmių viršūnės rodo, dominuojančias regiono gradientų orientacijas.

$$\begin{cases} a\theta_{i-1}^2 + b\theta_{i-1} = z_{i-1} \\ a\theta_i^2 + b\theta_i = z_i \\ a\theta_{i+1}^2 + b\theta_{i+1} = z_{i+1} \end{cases} \quad (34)$$

$$\hat{\theta}(x, y, \sigma) = -\frac{b}{2a} \quad (35)$$

Kiekvienas aptiktas paveiksluko mastelio erdvės taškas gali turėti daugiau nei vieną orientaciją. Dėl šios priežasties, histogramos viršūnėms, kurių vertės yra nemažesnės nei 80% didžiausios viršūnės vertės, yra sukuriami orientuoti mastelio erdvės taškai, kurių koordinatės erdvėje yra lygios analizuojam taškui, o orientacijos priskiriamos taikant parabolės funkciją (34) trims artimiausioms histogramos vertėms  $\{\theta_{i-1}, \theta_i, \theta_{i+1}\}$  aplink kiekvieną iš šių viršūnių. Taip yra daroma siekiant interpoliuoti tikslią viršūnės poziciją, randant parabolės ekstremumą  $\hat{\theta}(x, y, \sigma)$ .

#### 1.5.4. Taško vaizde deskriptoriaus sudarymas

Galiausiai, apskaičiavus kiekvienam paveiksluko taškui jo poziciją, mastelį bei orientaciją turime paveiksluko reikšmių 2D erdvę, kuri yra normalizuota bei nepriklausoma nuo mastelio bei orientacijos. Sekantis žingsnis yra sudaryti šių lokalių paveiksluko taškų savybių deskriptorius. Šie deskriptoriai turi nusakyti paveiksluko lokalias tekstūras, bei būti pakankamai atsparūs apšvietimo įtakai.

Siekiant sudaryti paveiksluko taško deskriptorių, lokalizuotas deskriptoriaus regionas aplink šį tašką yra normalizuojamas pasukant jį pagal taškui priskirtą orientaciją. Tuomet, yra apskaičiuojamos jo gradientų orientacijos  $\theta(x_{norm}, y_{norm})$  bei dydžiai  $m(x_{norm}, y_{norm})$ . Šios regiono reikšmės, pagal savo koordinates yra dalijamos į 4x4 zonas. Apskaičiavus šių zonų reikšmes, joms yra sudaromos atskiros, 8 stulpelių dydžio, histogramos, skirtos aprėpti 360 laipsnių orientacijų erdvę. Kiekvieno pikselio gradiento dydžiai yra pasveriami 2D Gauso funkcijos, centruotos ties analizuojamo taško koordinatėmis. Šios funkcijos standartinis nuokrypis,  $\sigma$ , yra lygus 1,5 kartų didesnis už naudojamą lokalaus regiono lango plotis (šio darbo, bei originalaus SIFT darbo metu regiono lango plotis yra 16). Galiausiai, prieš talpinant pasvertas gradientų dydžių reikšmes į jiems atitinkamas orientacijų vietas histogramose, kiekvienai iš jų yra taikoma 3D tiesinė interpoliacija. Jos metu talpinama reikšmė yra interpoliuojant išskaidoma ir į aplinkines histogramas bei jų orientacijų stulpelius. Tai užtikrina, kad orientacijų vertės esančios tarp pikselių, pačių histogramų ar jų stulpelių, bus žymiai tiksliau paskirstytos, remiantis nuokrypiu nuo joms skirtos diskrečios vietos centro. Sudarius deskriptoriaus, 4x4 histogramas, turime 4x4x8 dimensijų vieno deskriptoriaus duomenų struktūrą, kurios duomenys yra performuojami į 128 elementų ilgio vektorius.

Siekiant, kad turimas deskriptoriaus vektorius būtų kuo atsparesnis netiesiniai apšvietimo įtakai, pirma jis yra normalizuojamas į vienetinį vektorius. Tai užtikrina deskriptoriaus atsparumą tiesiniams apšvietimo poveikiams, kuomet viena apšvietimo konstanta veikia visus deskriptoriaus pikselius tolygiai. Vis dėlto, šis būdas neapsaugo nuo netiesinio apšvietimo efektų, kurių metu pasireiškia dideli apšvietimo pokyčiai. Norint sumažinti jų įtaką, jie yra naikinami dideli deskriptoriaus gradientų dydžiai taikant ribinę vertę, lygią 0,2, kiekvienai vektoriaus reikšmei. Reikšmei esant didesnei nei ši riba, ji yra mažinama iki 0,2.

## 2. Piniginių monetų nudėvėjimo lygio nustatymo projekto specifikacija

### 2.1. Reikalavimai

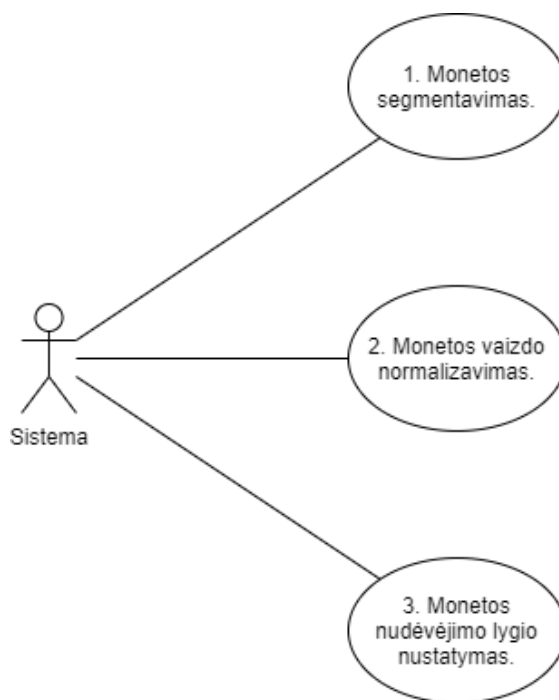
Kuriamos piniginių monetų nudėvėjimo lygio nustatymo sistemos nefunkciniai reikalavimai:

1. Moneta fotografuojama nustatyta, nekintančiame apšvietime;
2. Kuriamas algoritmas ar metodas turi gebėti klasifikuoti ir mažą nudėvėjimo lygį turinčias monetas.

Šiai sistemai yra išskirti trys funkciniai reikalavimai:

1. Lokalizuoti bei išskirti monetą iš turimo jos paveikslėlio;
2. Monetos paveikslėlio normalizavimas;
3. Monetos nudėvėjimo lygio nustatymas.

Funkciniai reikalavimai yra pateikti sistemos panaudos atvejų diagramoje (2.1 pav.):



2.1 pav. Monetos nudėvėjimo lygio nustatymo sistemos panaudos atvejų diagrama

2.1 lentelė. Monetos lokalizavimo bei išskyrimo iš turimo jos paveikslėlio panauda

<b>ID</b>	PA-01
<b>Pavadinimas</b>	Lokalizuoti bei išskirti monetą iš turimo jos paveikslėlio.
<b>Aprašymas</b>	Monetos objekto aptikimas bei išskyrimas iš aplinkos.
<b>Aktoriai</b>	Sistema.
<b>Pradinės sąlygos</b>	Privalo būti padaryta monetos nuotrauka;
<b>Pagrindiniai žingsniai</b>	Aptinkama moneta paveikslėlyje; Nustatomi jos matmenys bei pozicija; Monetos objektui priklausantys pikseliai yra išskiriami iš jo aplinkos.
<b>Galutinės sąlygos</b>	Gražinamos monetos objekto pikselių reikšmės

## 2.2 lentelė. Monetos paveikslėlio normalizavimo panauda

<b>ID</b>	PA-02
<b>Pavadinimas</b>	Monetos paveikslėlio normalizavimas.
<b>Aprašymas</b>	Pašalinama su monetos nudėvėjimu nesusijusi informacija iš apdorojamo paveikslėlio.
<b>Aktoriai</b>	Sistema.
<b>Pradinės sąlygos</b>	Privalo būti padaryta monetos nuotrauka; Moneta privalo būti išskirta iš paveikslėlio.
<b>Pagrindiniai žingsniai</b>	Atmetama ar modifikuojama informacija kuri nesusijusi su monetos nudėvėjimui būdingomis savybėmis (apšvietimo efektai, objekto dydis, pikselių intensyvumas).
<b>Galutinės sąlygos</b>	Gražinamos monetos nuotraukos normalizuotos pikselių vertės.

## 2.3 lentelė. Monetos nudėvėjimo lygio nustatymo panauda

<b>ID</b>	PA-03
<b>Pavadinimas</b>	Monetos nudėvėjimo lygio nustatymas.
<b>Aprašymas</b>	Nustatomas monetos nudėvėjimo lygis pagal kurį gaunamas jos įvertis.
<b>Aktoriai</b>	Sistema.
<b>Pradinės sąlygos</b>	Privalo būti padaryta monetos nuotrauka; Moneta turi būti išskirta iš paveikslėlio bei normalizuota.
<b>Pagrindiniai žingsniai</b>	Gaunamas monetos analizės operacijos vertinimas ir išvedamas monetos nudėvėjimo lygis.
<b>Galutinės sąlygos</b>	Gražinamas monetos nudėvėjimo lygis.

## 2.2. Monetos lokalizavimas bei segmentavimas

Šiame darbe monetų lokalizavimui bei segmentavimui buvo sukurtas ir naudojamas naujas objektų segmentavimo algoritmas, pavadinimu CORT (angl. „Circular Object Refined Threshold“), specializuotas apvalios formos monetoms. Šis algoritmas yra sudarytas taip, kad geriau veiktų su monetų nuotraukomis darytomis prie įvairių bei nestabilių apšvietimo bei objekto fono sąlygų. Šio algoritmo gebėjimas prisitaikyti prie įvairių situacijų suteikia jam pranašumą lyginant su kitais panašiais metodais, nes nėra būtina kruopščiai parinkti tinkamus jo veikimo parametrus. Šis algoritmas veikia su viena kanalą turinčiais – vienspalviais paveikslėliais  $I$ . Šiuose paveikslėliuose tikimasi, jog yra tik vienas apskritimo formos objektas, kuris privalo būti didesnis nei nustatytas mažiausias leistinas tokio objekto dydis  $minsize_c$ . CORT algoritmas gali būti laikomas, dvilypiu daugiapakopiu struktūriniu slenkstinės ribos filtravimo algoritmu, kuris naudoja dvi šias ribas: lokalizacijai ir segmentacijai, su tarp jų įterpta paieškos seka, kuri paremta objekto struktūriniu vertinimu siekiant rasti geriausią kandidatą paveikslėlyje.

Esminis monetos paveikslėlio filtravimo algoritmas yra pateiktas žemiau (2.2 pav.), tačiau jo realizavimo metu buvo naudoti papildomi optimizavimo žingsniai. Pirma, siekiant sumažinti resursų bei laiko sąnaudas apdorojant paveikslėlį, jo rezoliucija buvo sumažinta iki 720x720 pikselių. Labiau sumažinus paveikslėlį tai gali paveikti monetos kraštinius mažo kontrasto pikselius, ko sekoje jos segmentavimo kokybė gali nukristi (pvz.: klaidingas monetos ir jos šešėlių atskyrimas). Vis dėlto, būtina paminėti, jog šis rezoliucijos dydis nėra universalus, ir priklauso nuo individualaus panaudos atvejo.



---

**Algorithm 1** Circular Object Refined Threshold

---


```
1: procedure CORT
2:    $h_I^k \leftarrow \sum_{i,j}^{n,m} [I_{ij} = k]$   $\triangleright$  compute image histogram's  $k$ -th bin size.
3:    $t_1 \leftarrow LocalizationThreshold(h_I)$   $\triangleright$  find threshold value for localization.
4:    $c_{best} \leftarrow \emptyset$ 
5:    $r_{best} \leftarrow 0$ 
6:   for each  $c \in CC[T(I_{xy}, t_1)]$  do  $\triangleright$  Iterate through external connected
   components in the thresholded image.
7:     if  $c_{size} < minsize_c$  then
8:       continue
9:     end if
10:     $c_{contour} \leftarrow FindContour(c)$   $\triangleright$  find external contour.
11:     $S \leftarrow Area(c_{contour})$ 
12:     $P \leftarrow Perimeter(c_{contour})$ 
13:     $r \leftarrow 4\pi S/P^2$   $\triangleright$  estimate contour compactness ratio.
14:    if  $r \geq r_{best}$  then
15:       $c_{best} \leftarrow c$ 
16:       $r_{best} \leftarrow r$ 
17:    end if
18:  end for
19:   $L_{bb} \leftarrow BB(c_{best}, padding)$   $\triangleright$  compute padded bounding box.
20:   $L \leftarrow Crop(I, L_{bb})$   $\triangleright$  localized image region.
21:   $h_L^k \leftarrow \sum_{i,j}^{n,m} [L_{ij} = k]$   $\triangleright$  compute image histogram's  $k$ -th bin size.
22:   $t_2 \leftarrow SegmentationThreshold(h_L)$   $\triangleright$  find threshold value for local
  segmentation.
23:   $contour \leftarrow Contour(c_{best})$ 
24:   $L_{out} \leftarrow FillHoles[T(L_{xy}, t_2) \wedge Fill(contour)]$   $\triangleright$  fill holes in the thresh-
  old result.
25:   $I_{out} \leftarrow L_{out}$   $\triangleright$  remap local threshold values  $L_{out}$  to global result  $I_{out}$ .
26:  return  $I_{out}$ 
27: end procedure
```

---

**2.2 pav.** CORT monetos lokalizavimo bei segmentavimo algoritmas

Apskritų ir į monetas panašių objektų lokalizavimui paveikslėlyje, atliktų tyrimų dėka buvo pasirinkta naudoti Kapuro et al. maksimalia entropija pagrįstą globalios slenkstinės ribos,  $t_1$ , filtravimo metodą. Atlikus šį filtravimą, toliau naudojama morfologinė pikselių „uždarymo“ operacija, kuri yra praplėtimo bei erozijos operacijų kombinacija. Šiai operacijai yra naudojamas 7x7 dydžio elipsės formos branduolys. Šio žingsnio paskirtis yra sudaryti vientisą, išgaubtą monetos kontūrą paveikslėlyje, kuris skirtų ją nuo jos fono. Ši sąlyga yra itin svarbi, nes nesudarius šio kontūro moneta nebus sėkmingai rasta. Išskyrus individualius objektus turinčius vienalyčius kontūrus buvo panaudotas sujungtų komponentų metodas, kurio dėka yra randama geometrinė informacija apie kiekviena iš šių objektų. Šios informacijos dėka pašalinami visi objektai, kurių pikselių skaičius yra mažesnis nei nurodytas parametro  $minsize_c$ . Tai atlikus yra pašalinama didžioji dalis monetos paveikslėlio foninio triukšmo. Taip paliekamas tik monetos objektas ir kiti dideli paveikslėlio segmentai, kurie atsiranda dėl prastų apšvietimo sąlygų. Siekiant juos atmesti, yra apdorojamas kiekvienas paveikslėlio plotas, apibrėžtas atitinkamą segmentą gaubiančiu stačiakampiu tūriu. Tai sutaupo dalį sisteminių resursų, nes kiekvienoje iteracijoje apdorojamas tik lokalus paveikslėlio

plotas. Išskyrus individualius segmentus iš viso paveikslėlio yra randami jų kontūrai, *contour*, naudojant kontūrų radimo algoritmą. Šiame darbe naudojamas algoritmas yra sukurtas Satoshi'o ir Keiichi'o [20] bei skirtas binarinių paveikslėlių apdorojimui. Toliau, apskaičiuojamos segmento kontūro geometrinės savybės: plotas ir perimetras. Apdorojant visus objektus paveikslėlyje, yra pasirenkamas segmentas turintis didžiausią glaustumo įvertį  $r$ . Objektas su didžiausia  $r$  reikšme, užtikrina jog jis yra apvaliausias objektas,  $c_{best}$ , paveikslėlyje. Galiausiai yra apskaičiuojamas stačiakampis gaubiantis tūris,  $L_{bb}$ , su nustatyto dydžio praplėtimu, o jį iškirpus iš pradinio paveikslėlio gaunamas lokalizuotas monetos paveikslėlis  $L$ .



**2.3 pav.** +5% praplėstas lokalizuotos monetos,  $L$ , gaubiantis tūris,  $L_{bb}$ .

Lokaluotos monetos segmentavimui yra naudojamas Otsu globalios slenksstinės ribos,  $t_2$ , filtravimas. Šis filtravimas yra pritaikomas ne visam paveikslėliui, o tik  $L$ . Tyrimo metu buvo patvirtinta, jog šis algoritmas geriausiai veikia, naudojant jį dvimodaliniam subalansuotam duomenų skirstiniui.  $L_{bb}$  gaubiantis tūris yra praplečiamas būtent dėl šios priežasties. Siekiant subalansuoti monetos bei jos fono pikselių santykį,  $L_{bb}$  yra iš visų pusių praplečiamas dydžiu, *padding*, lygiu 5% nuo lokalizuotos monetos skersmens (2.3 pav.). Toliau, atliekama loginė sąjungos operacija tarp gautų lokalizuoto monetos regiono filtravimo rezultatų,  $T(L_{xy}, t_2) \wedge Fill(contour)$ . Tuomet, gautam rezultatui atliekama pikselių morfologinių operacijų seka: „uždarymas“ ir „atidarymas“, naudojant  $7 \times 7$  elipsės formos branduolius. Priešingai nei „uždarymo“ operacija, „atidarymo“ metu naudojama pikselių erozija po kurios eina jų praplėtimas. Tai užtikrina, kad išfiltruotos monetos objekto kontūrai yra uždari bei glotnūs. Galiausiai, užpildomos skylės monetos objekto kaukėje naudojant pikselių užliejimo algoritmą, o pasitelkus sujungtų komponentų metodu randamas naujas, tikslus monetos gaubiantis tūris. Jo koordinatės bei gauta monetos segmentavimo kaukė,  $L_{out}$ , yra perskaičiuojami į pradinio paveikslėlio koordinatės sistemą. Taip išskiriamas monetos objektas,  $I_{out}$ , pradiniam paveikslėliui pritaikius apskaičiuotą segmentavimo kaukę  $L_{out}$ .

Verta atkreipti dėmesį į tai, jog norint pasiekti aukštesnį objekto segmentavimo tikslumą naudojant pasiūlytą CORT algoritmą, užtenka kartoti 19-24 kodo eilutėse (2.2 pav.) pateiktus veiksmus. Kiekviena papildoma šių veiksmų iteracija mažina Otsu metodo paklaidą, mažinant fono ir objekto ploto disproporciją, aprašytą literatūros apžvalgos dalyje. Vis dėlto, šio darbo temos apimties rėžiuose, šios paklaidos sumažinimas nėra reikšmingas.

### 2.3. Monetos apšvietimo normalizavimas

Atighehchian'os pasiūlytas aukšto dažnio filtro panaudojimas monetų paveikslėliams atlieka dvi užduotis: pašalina jame matomus apšvietimo efektus esančius žemų dažnių juostoje ir išryškina bei akcentuoja likusias, aukštų dažnių juostoje slypinčias detales. Tarp šių detalių neretai yra randami

monetos nudėvėjimui būdingi artefaktai. Apšvietimo sudaromi vizualiniai efektai, tokie kaip atspindžiai <sup>[12]</sup> bei mažos vietinės dėmės ar spalvų iškraipymai, dažniausiai yra randami aukštų dažnių juostose, todėl jie nėra veikiami šio filtravimo. Dalis šių efektų yra nepageidaujami, siekiant vertinti monetos paviršiaus nudėvėjimą. Dėl atspindžių sudaromi mažo kontrasto dizaino kontūrai yra viena iš problemų siekiant aptikti nudėvėjimo detales šiose vietose. Siekiant pašalinti šiuos atspindžius, kurie užgožia šalia esančius nudėvėjimo artefaktus, šiame darbe yra naudojamas Gauso aukštų dažnių filtravimas, nuo apšvietimo nekintančioje spalvų erdvėje.

Literatūros analizėje minėta spalvų erdvės transformacijos funkcija (19) buvo pasirinkta naudoti šiame darbe siekiant sumažinti tokių apšvietimo efektų, kaip atspindžių bei šviesos sklaidos monetos paviršiumi, įtaką. Ši spalvų erdvė buvo pasirinkta, nes ji turi tik vieną spalvos komponentą (kanalą), yra specializuota lengvai prieinamoms skaitmeninėms RGB kameroms, ir svarbiausia, žinant kameros parametrus, ši funkcija nereikalauja duomenų rinkinio, siekiant nustatyti jos konversijos santykio parametą,  $\alpha$ . Ši transformacijos funkcija atlieka logaritminius skaičiavimus, todėl gali būti skaitiškai nestabili, dirbant su įvairiomis vaizdų pikselių reikšmėmis. Siekiant išvengti šios problemos, šiame darbe yra siūloma naudoti šios funkcijos modifikaciją (37), kuri užtikrintų, jog ji yra stabili. Pirma, pradinė funkcijos išraiška yra supaprastinama, kad būtų naudojamos tik dvi logaritmo operacijos vietoje trijų (36). Antra, naudojamas naujas parametras,  $\varepsilon$ , kuriam yra priskiriama itin maža reikšmė. Šis parametras yra naudojamas siekiant apsaugoti funkciją nuo neleistinų skaitinių operacijų, spalvų erdvės transformacijos kontekste, tokių kaip dalyba ar logaritmas iš nulio. Šios problemos yra dažnas reiškinys taikant logaritmo ar dalybos veiksmus kompiuterinėse programose. Modifikuota funkcija yra tiek skaitiškai stabilesnė, tiek greitesnė, nes yra naudojamos tik dvi logaritmo operacijos.

$$\begin{aligned} I_{inv} &= \frac{1}{2} + \log I_g - \alpha \log I_r - (1 - \alpha) \log I_b = \\ &= \frac{1}{2} + \log I_g - \log I_b + \alpha(\log I_b - \log I_r) = \\ &= \frac{1}{2} + \log \frac{I_g}{I_b} + \alpha \log \frac{I_b}{I_r} \end{aligned} \quad (36)$$

$$\widehat{I}_{inv} = \frac{1}{2} + \log \left( \frac{I_g}{I_b + \varepsilon} + \varepsilon \right) + \alpha \log \left( \frac{I_b}{I_r + \varepsilon} + \varepsilon \right), \quad \lim_{\varepsilon \rightarrow 0} \widehat{I}_{inv} = I_{inv} \quad (37)$$

Turima nuo apšvietimo nepriklausomos spalvų erdvės transformacijos funkcija,  $\widehat{I}_{inv}$ , yra taikoma išskirtos iš fono monetos RGB paveikslėliui, pašalinant visą nuo apšvietimo priklausančią informaciją tačiau paliekant tokias detales kaip paviršiaus apnašas bei monetos metalo spalvą. Tuomet, ši informacija yra atimama iš pradinio bespalvio monetos paveikslėlio,  $I$ , taip pašalinant minėtas detales (38). Šiame rezultate galima tikėtis rasti monetos kontūrus, bei jos nudėvėjimo detales, kaip kad apnašas, korozijos poveikį ir paviršiaus defektus. Siekiant išryškinti tik svarbiausią nudėvėjimo informaciją, yra atliekamas aukštų dažnių filtravimas (40) Gauso filtru,  $G$ , su dideliu standartiniu nuokrypiu,  $\sigma$ , gaunant rezultatą  $I_H$ . Šis filtravimas atlieka du darbus: pašalina stambias monetos vizualines detales ir padidina vaizdo kontrastą akcentuojant nudėvėtas monetos vietas. Priešingai nei literatūros analizėje minėtame Atighechian'os darbe, prie filtravimo rezultato nėra pridėdama normalizavimo reikšmė,  $\mu_L$ , nes šiuo atveju, normalizavimas yra pasiekiamas naudojant nuo apšvietimo nepriklausomą spalvų erdvę.

$$D = I - I_{inv} \quad (38)$$

$$I_L = G(x, y, \sigma) * D(x, y) \quad (39)$$

$$I_H = D - I_L \quad (40)$$

#### 2.4. Monetos nudėvėjimo nustatymas

Šiame darbe, monetos nudėvėjimo lygio nustatymui yra naudojamas SIFT ir SVM algoritmų junginys. SIFT metodo metu yra sudaromi nuo mastelio nepriklausomi deskriptoriai. Dėl šios priežasties jie yra dėmesio vertas pasirinkimas siekiant įvertinti vaizduose matomas tekstūras. Kadangi monetų nudėvėjimo žymės dažnai yra dalinai nepriklausomos nuo pačios monetos dydžio, šie deskriptoriai yra tinkamas būdas užfiksuoti jų informaciją, siekiant palyginti ją su kitomis, skirtingo dizaino monetomis.

SIFT algoritmo veikimo metu, iš vieno pateikto paveikslo yra išskiriama  $N_i$  mastelio pokyčiams mažai priklausomų taškų,  $P_i$ , kuriems sukuriama minėti deskriptorių vektoriai,  $F_i$ , turintys 128 dimensijas. Turint šiuos deskriptorius, bei pačios monetos, ekspertinės analizės metu, priskirtą įvertį, galima atlikti jų klasifikavimą į skirtingo nudėvėjimo tipo grupes. Šiame darbe, šiam tikslui buvo naudojamas atraminių vektorių klasifikavimas (SVM). Vis dėlto, SVM modelis veikia jam pateikiant  $M \times N$  matricą, kur  $M$  yra duomenų rinkinio dydis, o  $N$  – informacijos vektoriaus dimensijų skaičius. Pritaikant SVM klasifikavimą šiame darbe, turimo duomenų rinkinio dydis yra laikomas  $M$ , tačiau kaip kad buvo minėta, kiekvienas rinkinyje esantis paveikslukas gali pateikti unikalų deskriptorių skaičių. Dėl šios priežasties, visi paveikslui persiklausantys deskriptoriai negali būti paprasčiausiai sujungiami į vieną bendrą vektorių, nes nėra užtikrinama sąlyga  $N_{i \dots M} \neq N$ . Šiai problemai spręsti pasitelkiame gerai žinomą vaizdinių žodžių kratinio (angl. Bag of Visual Words, BoVW) metodą.

Pirma, išgaunami SIFT deskriptoriai visiems duomenų rinkinio paveikslėliams, gaunant  $\sum_{i=1}^M N_i \times 128$  dydžio matricą. Ši matrica, toliau yra grupuojama į  $k$  grupių, naudojant klasterizavimo metodus. Šiam tikslui, buvo naudojamas  $k$  vidurkių (angl. k-means) algoritmas, kurio centroidų inicializavimui buvo naudojamas Arthuro ir Vassilvitskio <sup>[1]</sup> sukurtas k-means++ metodas, kurio dėka yra parenkami geresnės kokybės pradiniai grupių centrai. Siekiant nustatyti optimaliausią grupių skaičių,  $k$ , yra naudojamas alkūnės (angl. elbow) metodas, kurio metu duomenų rinkinys yra grupuojamas į vis didėjančių grupių skaičių, bei skaičiuojant kiekvienos iteracijos kvadratinę paklaidą,  $SSE$ , kaip kad tai yra pateikta šioje formulėje:

$$SSE(k) = \sum_{i=1}^k \sum_{x_j \in c_i} (x_j - \mu_i)^2 \quad (41)$$

Čia,  $c$  – klasteris (grupė),  $x$  – sugrupuoti duomenų rinkinio elementai,  $\mu$  – vidutinė klasterio reikšmė.

Pagal šį metodą ir naudojant pateiktą paklaidos metriką,  $SSE$ , nustatomas optimaliausias klasterių skaičius,  $k_{best}$ , kuomet ekspertinės analizės būdu (42) yra parenkamas mažiausias leistinas paklaidos sumažėjimas  $\Delta_{min}$ .

$$k_{best} = \arg \min_{1 < k < \sum_{i=1}^M N_i} SSE'(k), \quad SSE' > \Delta_{min} \quad (42)$$

Duomenų rinkinyje sudarius  $k_{best}$  klasterius, jie yra laikomi vizualinių žodžių žodynu. Šie klasteriai toliau yra naudojami identifikuoti kiekvieno paveikslėlio skirtingus SIFT deskriptorius kaip žodžius žodyne. Naudojantis sudarytu žodynu, kiekvienam paveikslėliui yra skaičiuojami žodžiai sudarant  $k_{best}$  dydžio žodyno panaudos vektorius (žodžių kratinį) trimis būdais. Pirmuoju būdu, sudaroma žodyno naudotų žodžių paveikslėlyje histograma. Tai yra atliekama grupuojant visus paveikslėlio SIFT deskriptorius į nustatytas  $k_{best}$  grupes (43). Suskaičiavus kiekvienos grupės dydį gaunamas nurodyto dydžio vektorius. Šis būdas yra laikomas griežto kodavimo metodu, nes kiekvienas deskriptorius yra priskiriamas tik vienai grupei.

$$a_{m,j} = 1, \quad \text{jei } m = \arg \min_{i \in \{1, \dots, k\}} (x_j - c_i)^2 \quad (43)$$

Antruoju būdu yra siūloma naudoti vadinamąjį – minkštąjį kodavimą, kurio metu SIFT deskriptorius yra priskiriamas nebūtinai vienai grupei. Šiame darbe siūloma apskaičiuoti deskriptoriaus priklausomybės kiekvienai grupei tikimybę (45) nustatant atstumus iki jų naudojant Euklido atstumą (44).

$$d_{L2}(j, i) = \sqrt{(x_j - c_i)^2} \quad (44)$$

$$a_{j,i} = \frac{1}{k-1} \left( 1 - \frac{d(j, i)}{\sum_l^k d(j, l)} \right) \quad (45)$$

Trečiasis būdas yra identiškam antrajam, tačiau vietoje Euklido atstumo yra naudojamas kvadratinis atstumas (46) siekiant labiau pabrėžti deskriptoriaus priklausomybes artimesnėms grupėms.

$$d_{SD}(j, i) = (x_j - c_i)^2 \quad (46)$$

Visiems paveikslėliams sudaryti  $k_{best}$  elementų dydžio vektoriai yra naudojami sukonstruoti  $N \times k_{best}$  dydžio matricą. Ši matrica toliau naudojama kaip SVM algoritmo treniravimo bei testavimo duomenys.

Galiausiai, šiame darbe siekiant apmokyti SVM modelį kruopščiai nederinant jo parametrų kiekvienai duomenų imčiai buvo pasiūlytas atsitiktinių modelio parametrų paieškos algoritmas:

1. Duomenys atsitiktinai išskirstomi į apmokymo (80%) bei testavimo (20%) dalis.
2. Atsitiktinai parenkama 100-tas SVM modelio reguliarizavimo verčių,  $C_i$ , imtis iš rėžių nuo 1 iki 70.
3. SVM modelio, RBF branduolio parametro  $\gamma$  reikšmė parenkama automatiškai apskaičius duomenų imties mastelį.
4. Modelis apmokomas su kiekviena  $C$  reikšme, ieškant modelio, kuris suklasifikavimo didžiausią skaičių monetų nuotraukų testavimo duomenų imtyje.
5. Radas geriausią modelį, apskaičiuojamas standartinis nuokrypis,  $\sigma_C$ , visų sugeneruotų  $C_i$  verčių ir sudaromi nauji šių verčių rėžiai  $C_{i+1} = \{C_i^{best} - \sigma_C, C_i^{best} + \sigma_C\}$ .
6. Kartojami žingsniai 2-5 tris kartus.

### 3. Piniginių monetų nudėvėjimo lygio nustatymo metodų tyrimo eiga ir rezultatai

#### 3.1. Duomenų rinkinių sudarymas

Šio tyrimo metu siekiant įvertinti pasiūlytų metodų kokybę nustatant šiuolaikinių piniginių monetų nudėvėjimo lygį buvo sudaryti ir naudojami 2 monetų nuotraukų rinkiniai:

- **Coinset1.** Sudarytas iš 90-ies 1 EUR monetų nuotraukų. Šios nuotraukos buvo daromos sąlyginai stabiliomis sąlygomis, naudojant vientisą foną ir fotografavimo palapinę užtikrinančią išorinių šviesos šaltinių difuzija, kas apsaugo monetą bei jos foną nuo didelio kontrasto atspindžių ir šešėlių bei sudaro tolygų apšvietimą. Šiame duomenų rinkinyje esančių monetų nudėvėjimas buvo įvertintas ekspertinės analizės būdu, pasitelkiant Šeldono skalės sudarytus kriterijus. Siekiant sumažinti žmogiškąją paklaidą bei užtikrinti, kad šis vertinimas būtų kuo objektyvesnis ir kokybiškesnis, monetos buvo lyginamos tarpusavyje viena prie vienos. Tai susiaurina monetų palyginimo kriterijus, nes dėmesys yra kreipiamas tik dvejoms konkrečioms monetoms vienu metu. Siekiant greičiau atlikti rankinį monetų nudėvėjimo lygio vertinimą, buvo pasitelkiama kompiuterių moksle naudojama suliejimo rikiavimo (angl. merge-sort) strategija. Šios strategijos naudojimas, vietoje įprasto visų su visomis monetų lyginimu užtikrina rankinio rūšiavimo laiko sąnaudų sumažėjimą nuo  $O(n^2)$  iki  $O(n \log n)$ , kas taip pat prisideda prie padaromų žmogiškų klaidų sumažinimo.
- **Coinset2.** Sudarytas yra iš 154-ių įvairaus nominalo britiškų monetų. Šių monetų nuotraukos buvo daromos prastomis, nekontroliuojamomis sąlygomis. Vaizduose galima matyti didelio kontrasto atspindžius, šešėlius. Apšvietimas šiose nuotraukose nėra tolydus ir vientisas. Šio duomenų rinkinio pagrindinė paskirtis šiame darbe yra įvertinti siūlomų monetos segmentavimo ir apšvietimo įtakos mažinimo metodus. Šiame duomenų rinkinyje esančių monetų nudėvėjimas nėra įvertintas, nes jų nuotraukų kokybė yra itin maža.

Abejuose rinkiniuose, monetų posūkio kampas nėra kontroliuojamas, o jų padėtis svyruoja ~10% nuo nuotraukos centro.

Visos nuotraukos buvo daromos ~9cm atstumu tarp kameros objektyvo ir monetos. Šiame tyrime buvo naudojama viena skaitmeninė vaizdo kamera – išmanusis mobilus įrenginys OnePlus 7 Pro GM1913, kuris naudoja skaitmeninį optinį sensorių Sony IMX586. Išsamesnė įrenginio specifikacija pateikta lentelėje (3.1 lentelė):

#### 3.1 lentelė. Naudotos skaitmeninės kameros specifikacija

Įrenginio pavadinimas	OnePlus 7 Pro
Modelis	GM1913
Įrenginio OS versija	Oxygen OS 10.0.5.GM21BA
Optinis sensorius	Sony IMX586
Bitų gylis	24
Spalvų erdvė	sRGB
Rezoliucija	72 (tašk./colyje)
Nuotraukos matmenys	3000x3000 (pikseliai)

Coinset1 duomenų rinkinys buvo sugrupuotas į 4-ias grupes pagal jame esančių monetų, rankiniu būdu, įvertintą nudėvėjimo lygį. Skirtumai tarp gretimų monetų grupių nėra dideli. Šių grupių pasiskirstymas yra pateiktas lentelėje apačioje (3.2 lentelė).

**3.2 lentelė.** Coinset1 duomenų rinkinio sudėtis.

Grupės kodas	Grupės pavadinimas	Monetų skaičius
0	Nenudėvėta	13
1	Mažai nudėvėta	25
2	Nudėvėta	38
3	Labai nudėvėta	14


Dėl duomenų rinkinio mažo dydžio, šio darbo metu buvo nuspręsta nekompensuoti atskirų klasių mažo dydžio lyginant su kitomis klasėmis. Šis sprendimas užtikrina, kad keli vienetai nuotraukų drastiškai nenulems klasifikavimo rezultatų.

### 3.2. Pradinių duomenų analizė

Siekiant palyginti Coinset1 duomenų rinkinį su duomenimis naudotais literatūros analizėje aprašytame Atighehchian‘os darbe, buvo atlikta identiška analizė šiam darbui. Šios analizės žingsniai buvo identiški abejuose darbuose:

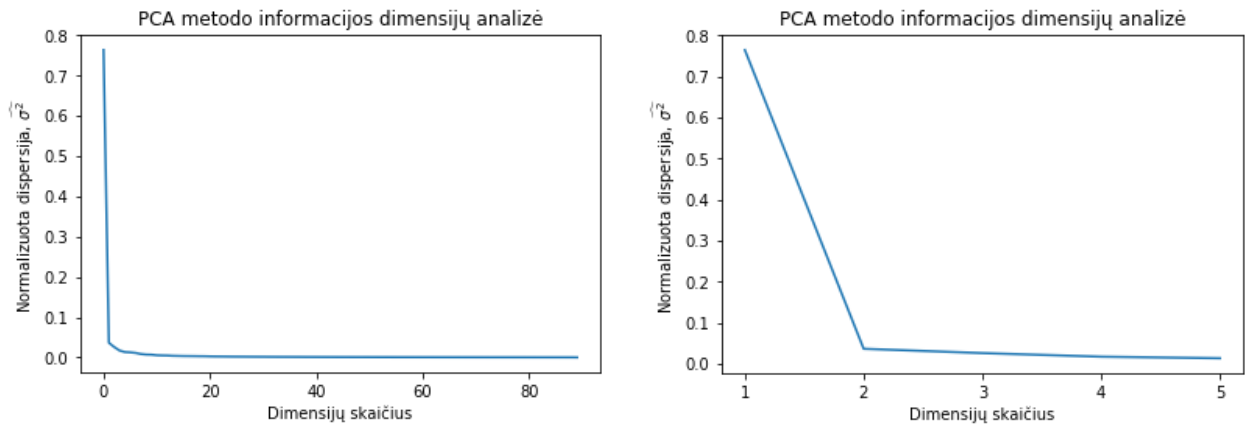
7. Apskaičiuojamos nuo apšvietimo nepriklausomos monetos nuotraukos visų eilučių bei stulpelių pikselių vidutinės reikšmės (atmetus monetos fonui priskirtas reikšmes).
8. Eilučių bei stulpelių reikšmių vektoriai yra sujungiami į vieną bendrą vektorių, o šie sujungiami su visų kitų paveikslėlių išgautais vektoriais sudarant  $N \times H + W$  dydžio matricą, kur  $H + W > N$ .
9. Naudojamas principinių komponentių analizės metodas (PCA), kurio dėka atliekamas turimos matricos antros dimensijos dydžio mažinimas.
10. Vykdomas turimos duomenų matricos klasterizavimas 4-5 grupes, siekiant įvertinti monetų nudėvėjimo pasiskirstymą bei naudojamo duomenų rinkinio klasifikavimo sudėtingumą.

Atighehchian‘a, atlikus šį eksperimentą, sugebėjo išgauti atskirus ir nepersidengiančius 4-is nudėvėjimo klasterius (3.1 pav.).




**3.1 pav.** Domenų rinkinio klasterizavimas į 4-ias grupes<sup>[2]</sup>

Kartojant pateiktus veiksmus darbe su Coinset1 duomenų rinkiniu, buvo sudaryta  $90 \times 1200$  apjungtų eilučių bei stulpelių reikšmių matrica, kuriai buvo pritaikytas PCA dimensijų mažinimo metodas. Atlikus jo rezultatų analizę stebint informacijos pasiskirstymo priklausomybę nuo naudojamų dimensijų skaičiaus (3.2 pav.), buvo pastebėta, kad šiame duomenų rinkinyje, kaip kad Atighehchian'os eksperimento atveju, didžioji dalis informacijos slypi pirmose 2-jose dimensijose.



**3.2 pav.** Coinset1 duomenų rinkinio informacijos dimensijų analizė

Šių rezultatų dėka, buvo nuspręsta sumažinti nudėvėjimą apibūdinančių dimensijų skaičių iki 2, gaunant  $90 \times 2$  dydžio paveikslėlių informacijos matricą. Vizualizavus ją, o kiekvieną paveikslėlio elementą grafike pažymėjus pagal jo tikrąjį nudėvėjimo lygį, buvo gautas Coinset1 duomenų rinkinio monetų nudėvėjimo lygio pasiskirstymas (3.3 pav.).




**3.3 pav.** Coinset1 duomenų rinkinio monetų nudėvėjimo pasiskirstymas

Lyginant šiuos du duomenų rinkinius galima teigti, jog šiame darbe naudojamas Coinset1 nuotraukų rinkinys pateikia žymiai sudėtingesnę bei realesnę problemą siekiant įvertinti monetų nudėvėjimo lygį. Faktas, jog šioje analizėje naudotu būdu neįmanoma išskirti net dvejų aiškių klasterių šiame duomenų rinkinyje, lemia, jog šiame darbe naudojamų metodų efektyvumo vertinimas negali būti tiesiogiai lyginamas su panašiuose darbuose pateikiamais rezultatais.



### 3.3. CORT algoritmo taikymas monetos segmentavimui

Šioje dalyje siekiama pavaizduoti CORT algoritmo veikimą objektų segmentavimo metu. Šis metodas buvo taikomas 1 EUR monetos nuotraukai, imtai iš Coinset1 duomenų rinkinio. Svarbiausi algoritmo žingsniai yra pateikiami šiame paveiksliuke (3.4 pav.):




3.4 pav. Monetos lokalizavimas ir segmentavimas CORT algoritmu

- a) Pradinis paveikslėlis; b) Maksimalios entropijos filtravimo rezultatas; c) Morfologinis „uždarymas“; d) Išfiltruotas segmentas su didžiausiu glaustumo santykiu; e) Lokalizuotas monetos paveiksliukas,  $L$ ; f) Lokalizuoto paveiksliuko filtravimo (naudojant Otsu metodą) rezultatas; g) Morfologinių „uždarymo“ ir „atidarymo“ operacijų seka, po kurios eina skylių užpildymas galutiniame filtravimo rezultate; h) Išskirtos monetos paveikslėlis,  $L_{out}$ , pritaikius apskaičiuotą segmentavimo kaukę  $L_{out}$ .

Iš pateiktų monetos segmentavimo etapų naudojant pasiūlytą CORT algoritmą galima matyti, moneta buvo sėkmingai lokalizuota nuotraukoje, o naudojant pakartotinį filtravimą, buvo išgaunamas lygesnis bei tikslesnis jos kontūras.

### 3.4. Monetos slenkstinės ribos segmentavimo metodų palyginimas

Šioje darbo dalyje buvo lyginami slenkstinės ribos vaizdų segmentavimo metodai siekiant pašalinti nuotraukos foną bei išskirti monetos objektą joje. Eksperimento metu buvo naudojami šie metodai: Otsu, Kapuro et al. entropijos maksimizavimas, Zacko et al. trikampio metodas ir šiame darbe pasiūlytas CORT algoritmas. Visi išvardinti metodai buvo atskirai vertinami su Coinset1 ir Coinset2 duomenų rinkiniais. Siekiant objektyviai įvertinti kiekvieną iš šių metodų, yra naudojamas Huber-Mörk et al. darbe minėtas glaustumo įvertis,  $r$ . Šio įverčio dėka, kiekvienas segmentavimo rezultatas yra įvertinamas rėžiuose nuo 0 iki 1, nusakant gauto objekto panašumą į tobulą apskritimą, nes duomenų rinkiniuose esančios monetos yra apskirtos. Toks įvertinimas apibūdina išgauto monetos objekto kontūrų kokybę. Glaustumo įvertis,  $r$ , buvo taikomas visiems nesijungiantiems objektams segmentavimo rezultate, o iš gautų rezultatų buvo parenkama didžiausia jo vertė, laikant, jog tai yra monetos objekto įvertinimas.



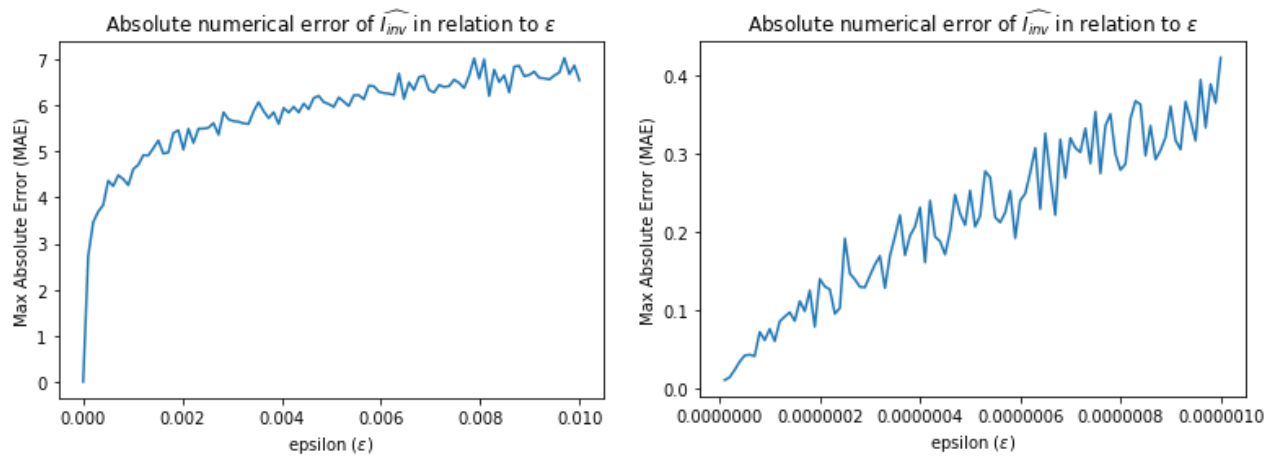
3.5 pav. Monetos slenkstinės ribos segmentavimo rezultatai

Atlikus šį eksperimentą, kurio rezultatai yra pateikti paveikslėliuose aukščiau (3.5 pav.), gavome keturias išvadas:

1. Otsu pasiūlytas metodas geriausiai veikia dirbant su vaizdais, kurie buvo išgaunami esant kontroliuojamoms aplinkos sąlygoms (Coinset1), tačiau pateikus nuotraukas, kuriose yra matomi stiprūs apšvietimo sudaromi efektai ar netolygus vaizdo fonas (Coinset2), šis metodas pateikia prastesnius rezultatus.
2. Dirbant su prastomis sąlygomis darytomis nuotraukomis (Coinset2) Kapuro et al. entropijos maksimizavimo metodas pateikia geresnius rezultatus nei Otsu ar trikampio metodai. Vis dėlto, šis metodas yra žymiai jautresnis monetų sudaromiems šėšeliams. Dėl šios priežasties, šis metodas yra netinkamas rasti tikslų monetos kontūrą.
3. Tiek Kapuro et al., tiek Zacko et al. „trikampio“ slenkstinės ribos filtravimo rezultatai stipriai koreliuoja tarpusavyje. Dėl šios priežasties trikampio metodas, žinant jog jis reikalauja žymiai mažesnių resursų, gali būti naudojamas kaip entropijos maksimizavimo slenkstinės ribos funkcijos aproksimacija.
4. Šiame darbe pasiūlytas CORT algoritmas, lyginant su likusiais metodais, pateikia žymiai geresnius rezultatus su Coinset1 ir Coinset2 duomenų rinkiniais. Tai parodo, jog automatinio daugiapakopio lokalizuotos slenkstinės ribos filtravimo strategija yra dėmesio verta, kuomet siekiama išgauti aiškius objekto kontūrus vaizde, nepriklausomai nuo jo kokybės sąlygų.

### 3.5. Nuo apšvietimo nepriklausomos spalvų erdvės skaitinis stabilumas

Šioje tyrimo dalyje buvo siekiama nustatyti šiame darbe pasiūlytos nuo apšvietimo nepriklausomos spalvų erdvės funkcijos,  $I_{inv}$ , modifikacijos (37) skaitinį stabilumą. Šis eksperimentas buvo atliekamas lyginant  $I_{inv}$  funkciją ir jos modifikaciją,  $\widehat{I}_{inv}$ , naudojant maksimalios absoliutinės paklaidos įvertinimą,  $MAE = \max|\widehat{I}_{inv} - I_{inv}|$ . Ši paklaida buvo skaičiuojama su  $N$  tiesiškai didėjančiomis  $\varepsilon$  reikšmėmis, kur  $\varepsilon \in \{10^{-8}, 10^{-2}\}$ . Kiekvienoje  $\varepsilon$  iteracijoje yra sukuriama naujas  $100000 \times 3$  dydžio atsitiktinių RGB pikselių verčių masyvas. Galiausiai, kiekviena ši iteracija buvo kartojama 50 kartų siekiant gauti vidutinę  $MAE$  vertę.




**3.6 pav.** Modifikuotos spalvų erdvės funkcijos skaitinis stabilumas

Kaip tai galima matyti iš pateiktų grafų (3.6 pav.), tiesiškai didėjant  $\epsilon$ , maksimali paklaida,  $MAE$ , didėja logaritmiškai. Vis dėlto, naudojant mažesnes  $\epsilon$  vertes nei  $10^{-6}$ , galima užtikrinti kad gaunama didžiausia įmanoma paklaida bus nedidesnė nei 0,5 pikselio vertės dydžio. Šio eksperimento dėka galima teigti, jog šiame darbe pasiūlyta,  $\widehat{I}_{inv}$ , modifikuota funkcija yra pakankamai skaitiškai stabili, naudojant pakankamai mažą  $\epsilon$ .

### 3.6. Pasiūlyto monetos apšvietimo normalizavimo metodo taikymas

Šioje dalyje yra siekiama pavaizduoti šiame darbe pasiūlyto algoritmo, skirto monetų apšvietimo normalizavimui, veikimą. Šis metodas buvo taikomas 1 EUR monetos nuotraukai, imtai iš Coinset1 duomenų rinkinio. Svarbiausi algoritmo žingsniai yra pateikiami paveiksliuke apačioje (3.7 pav.):



**3.7 pav.** Monetos apšvietimo normalizavimas

a) monetos bespalvė nuotrauka,  $I$ ; b) moneta nuo apšvietimo nepriklausomoje spalvų erdvėje,  $I_{inv}$ ; c) a ir b vaizdų skirtumas,  $D$ ; d) c vaizdo Gauso žemo dažnio paveikslas,  $I_L$ ; e) c vaizdo Gauso aukšto dažnio paveikslas,  $I_H$ .

Iš pateiktų monetos apšvietimo normalizavimo etapų naudojant pasiūlytą funkciją (40) galima matyti, jog monetos apšvietimo efektai, tokie kaip atspindžiai bei metalo spalva buvo sėkmingai pašalinti. Tuo tarpu monetos nudėvėjimo detalės buvo išryškintos.


### 3.7. Monetos apšvietimo normalizavimo metodų palyginimas

Siekiant palyginti šiame darbe pasiūlyto apšvietimo normalizavimo metodo veiksmingumą su Atighehchian'os naudotu metodu (3), buvo atlikta šių metodų lyginamoji analizė. Analizės metu buvo naudojami trys apšvietimo normalizavimo metodai:

1. Atighehchian'os pasiūlytas Gauso aukštų dažnių filtravimas su žemų dažnių vidurkio normalizavimu.
2. Šio darbo metu pasiūlytas Gauso aukštų dažnių filtravimas (40), nuo apšvietimo nepriklausomos spalvų erdvės,  $I_{inv}$ , skirtumų erdvėje,  $D$ .
3. Šio darbo metu pasiūlyta nuo apšvietimo nepriklausomos spalvų erdvės,  $I_{inv}$ , skirtumų erdvės,  $D$ , funkcija (38).

Šių metodų rezultatai, naudojant juos išskirtai 1 EUR monetos nuotraukai, yra pateikiami paveikslėlyje žemiau (3.8 pav.). Pateiktam pavyzdyje, galima matyti, jog monetos apšvietimą normalizavus antruoju metodu, moneta pilnai netenka savo spalvos informacijos, o paviršiaus


defektai asocijuojami su jos nudėvėjimu yra išryškinami labiau nei naudojant pirmąjį normalizavimo metodą.



**3.8 pav.** Monetos apšvietimo normalizavimo metodai

- a) Baspalvė monetos nuotrauka; b) Normalizuota moneta metodu – 1; c) Normalizuota moneta metodu – 3; d) Normalizuota moneta metodu – 2.

Siekiant įrodyti šiame darbe pasiūlyto metodo pranašumą statistiškai, buvo atliktas visų išvardintų normalizavimo būdų palyginimas naudojant Coinset1 ir Coinset2 duomenų rinkinius. Norint įvertinti apšvietimo įtaką monetos vaizdui, buvo siekiama apskaičiuoti pikselių intensyvumo pasiskirstymą. Šiam tikslui, buvo naudojamas dispersijos įvertis,  $\sigma^2 = \frac{1}{nm} \sum_i^n (x_i - \mu_x)^2$ .



**3.9 pav.** Monetos vaizdų apšvietimo normalizavimo metodų palyginimas

„HPV +  $\mu_L$ “ – metodas 1, „HPV with  $I_{inv}$ “ – metodas 2, o „ $I_{inv}$ “ – metodas 3.

Iš pateiktų eksperimento rezultatų galima aiškiai matyti, jog dirbant su monetų nuotraukomis darytomis esant geresnėms apšvietimo sąlygoms (Coinset1), šiame darbe pasiūlyti apšvietimo normalizavimo metodai pranoksta literatūros analizėje aprašytą ir Atighehchian‘os darbe naudotą būdą. Vis dėlto, pasiūlytų metodų rezultatai naudojant Coinset2 duomenų rinkinį yra ženkliai prastesni. Tai gali būti paaiškinama artefaktų susidarymu sumažinant didelio ploto stiprius atspindžius, bei išryškinant juose esančias tekstūras, kurios metodo-1 atveju yra neišskiriamos ir panaikinamos.

### 3.8. Monetų nudėvėjimo lygio klasifikavimo rezultatai

Šiame skyriuje yra pateikti monetų klasifikavimo, pagal jų nudėvėjimo lygį, rezultatai. Monetos buvo klasifikuojamos į 2 ir 4 klases. Šio eksperimento metu, buvo sudaromos visos įmanomos modelių konfigūracijos iš pateiktų parametrų (3.3 lentelė):

**3.3 lentelė.** Naudotų modelių konfigūracijų parametrai


Parametro pavadinimas	Parametrų vertės
Oktavų sluoksnių skaičius	Nuo 1 iki 4 kas 1
Kontrasto ribinė vertė	Nuo 0,01 iki 0,04 kas 0,01
Kampo ribinė vertė	Nuo 5 iki 20 kas 5
Klasterių skaičius	8, 19 ir 46
Vaizdų apdorojimo metodas	„Nėra“, „senas“ ir „naujas“
Žodžių kratinio sudarymo metodas	Euklido atstumas, griežtas ir vidutinis kvadratinis atstumas

Viso buvo sudarytos 1728 skirtingos parametrų konfigūracijos. Jos visos buvo naudojamos, kartu su Coinset1 duomenų rinkiniu, randant skirtingus  $k$  – vidurkių metodo klasterių centrus. Klasterių skaičiaus variantai buvo parinkti atlikus pirminę rezultatų analizę naudojant „senas“ – literatūros analizėje aprašytą, Atighehchian‘os, naudotą monetos vaizdų segmentavimo bei apšvietimo normalizavimo metodus bei grupuojant SIFT deskriptorius nuo vieno iki 128 klasterių. Naudojant projektinėje dalyje aprašytą alkūninę ekspertinę analizę buvo pasirinkti 3 klasterių kiekiai (3.10 pav.). Klasteriai  $k_0$ ,  $k_1$  ir  $k_2$  buvo parinkti pagal formules (47), (48) ir (49):

$$k_0 = \text{Elbow}(\mu_{SSE} + 2\sigma_{SSE}) \quad (47)$$

$$k_1 = \text{Elbow}(\mu_{SSE} + 1\sigma_{SSE}) \quad (48)$$

$$k_2 = \text{Elbow}(\mu_{SSE} + 0\sigma_{SSE}) \quad (49)$$




**3.10 pav.** Alkūninio metodo taikymas randant k-vidurkių metodo klasterių dydžius

Siekiant objektyviai įvertinti kiekvieną nudėvėjimo nustatymo modelio konfigūraciją, jos analizavimo metu buvo sukurtas bei apmokytas SVM klasifikatorius 2 ir 4 nudėvėjimo klasėms. Norint kuo objektyviau parinkti SVM modelio parametrus kiekvienai eksperimento konfigūracijai siekiant maksimizuoti jo apmokymo kokybę buvo naudojamas projekcinėje dalyje aprašytas paprastas atsitiktinės paieškos algoritmas. Šis algoritmas parenka geriausius parametrus kiekvienai duomenų imčiai. Kiekviena konfigūracija buvo įvertinta jai apmokyto SVM modelio rezultatais iš kurių buvo apskaičiuotos dvi vertės:

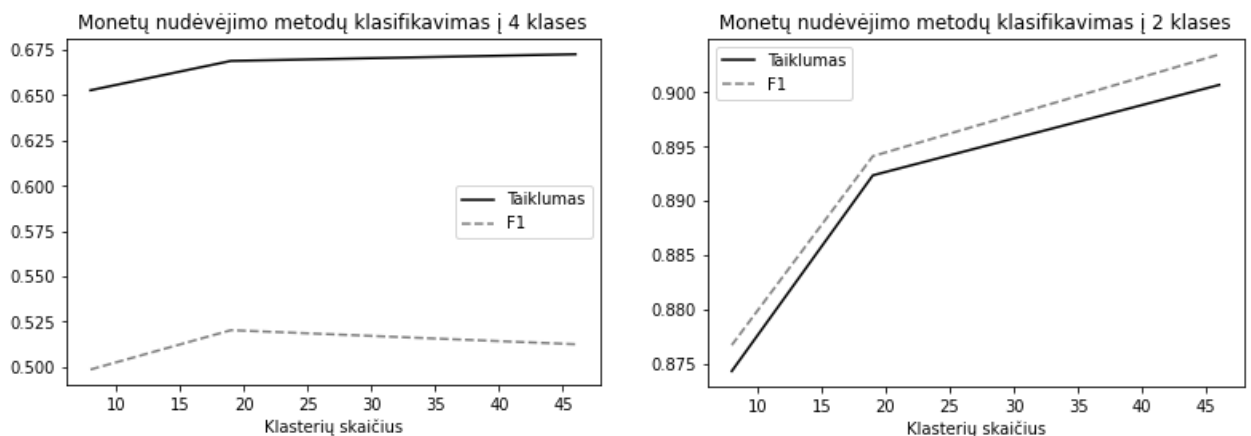
- **Taiklumas.** Tai įprasta vertė kuri vertina tinkamai suklasifikuotų elementų skaičių santykį su visų elementų skaičiumi,  $a = \frac{TP+TN}{TP+TN+FP+FN}$ .
- **F1.** Ši vertė yra naudojama siekiant apskaičiuoti optimalią bendrą tikslumo bei specifiškumo įverčių vertę,  $F1 = 2 \frac{p+r}{p+r}$ , kur tikslumas yra apibrėžiamas kaip  $p = \frac{TP}{TP+FP}$ , o specifiškumas,  $r = \frac{TP}{TP+FN}$ .

Pirma, tiriant duomenų rinkinio, Coinset1, nudėvėjimo informacijos pasiskirstymą buvo atliekamas SIFT deskriptorių žodžių kratinio klasterizavimas naudojant  $k_1$  grupes. Gautiems rezultatams, toliau taikomas PCA metodas, kurio metu, kiekvieno paveikslėlio SIFT deskriptorių žodžių kratinio dimensijų skaičius yra sumažinamas iki 2 siekiant vizualizuoti gautą informaciją. Galiausiai kiekvienam taškui grafe yra priskiriama jo klasė (3.11 pav.):



**3.11 pav.** Coinset1 duomenų rinkinio nudėvėjimo lygio pasiskirstymas naudojant žodžių kratinio metodą

Iš gautų grafų galima aiškiai matyti, jog nudėvėjimo lygiai, Coinset1 duomenų rinkinyje, gali būti aiškiai atskiriami į dvi grupes, tačiau siekiant tai padaryti naudojant 4 grupes susiduriama su grupių persidengimu. Toliau buvo taikytas klasifikavimo rezultatų tyrimas naudojant  $k_0$ ,  $k_1$  ir  $k_2$  klasterių kiekius (3.12 pav.).





**3.12 pav.** Klasifikavimo rezultatai su skirtingais klasterių skaičiais

Iš klasterių skaičiaus analizės rezultatų galima matyti, jog klasifikuojant monetas į 4 jų nudėvėjimo grupes, nežymiai geresnius rezultatus pateikia 19 klasterių žodžių kratiniai, tačiau klasifikuojant į 2 grupes, modelio tikslumas pasiekia geriausius rezultatus su didesniu klasterių skaičiumi,  $k_2$ . Šių rezultatų dėka galima teigti, jog esant dideliame klasifikuojamų grupių persidengimui, naudojamas klasterių skaičius neturi didelės įtakos galutiniams rezultatams. Siekiant sumažinti šį persidengimą, toliau yra atliekama išsami SIFT algoritmo parametrų bei pasiūlytų metodų analizė.

### 3.8.1. SIFT algoritmo parametrų įtakos tyrimas

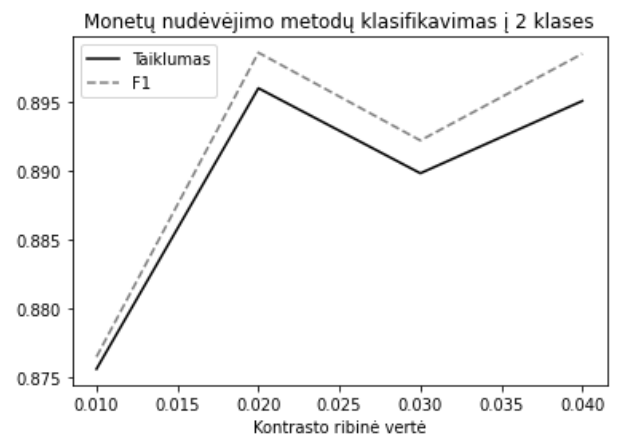
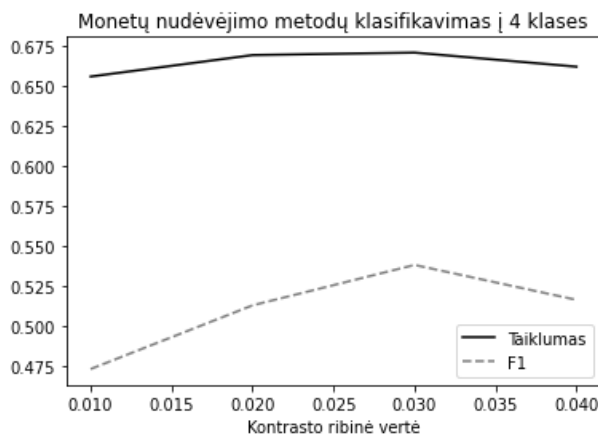
Tiriant SIFT algoritmo parametrų įtaką monetų nudėvėjimo lygio klasifikavimui buvo lyginami 2 ir 4 klasių klasifikavimo rezultatai. Šio tyrimo metu buvo tiriama oktavų sluoksnių skaičiaus ir kontrasto bei kampų ribinių verčių įtaka.





**3.13 pav.** Klasifikavimo rezultatai su skirtingais oktavų sluoksnių skaičiais

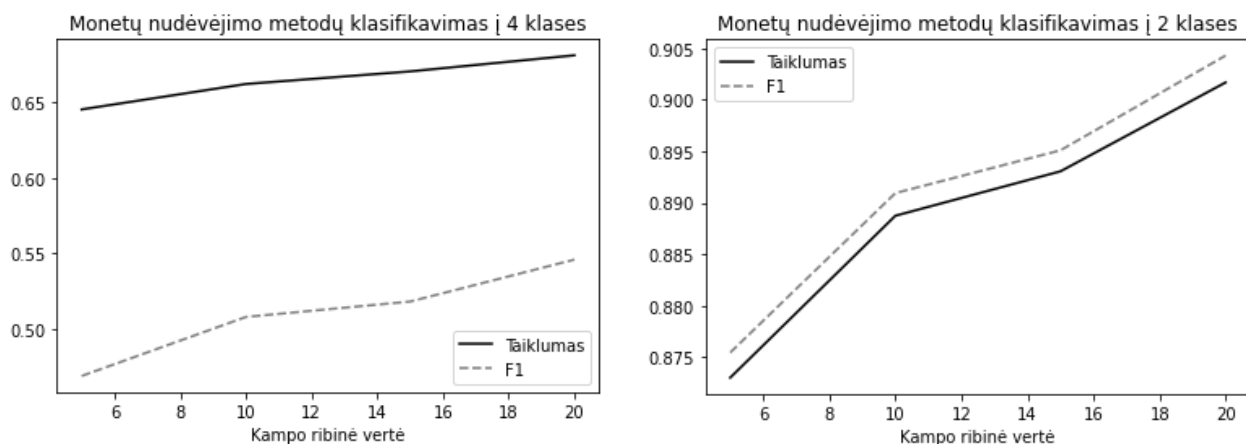
Iš pateiktų grafų aukščiau (3.13 pav.) galima, jog oktavų sluoksnių skaičius daro didelę įtaką monetų nudėvėjimo klasifikavimo metu. Klasifikuojant monetas į dvi klases ir naudojant daugiau nei vieną sluoksnį matomas staigus tiek, taiklumo, tiek F1 įverčių kritimas. Tai gali būti paaiškinama tuo, kad naudojant papildomus sluoksnius monetas vaizdas praranda didelę dalį savo nudėvėjimo informacijos, dėl vaizdo mastelio didinimo aprašyto SIFT analizės metu. Didinant mastelį yra prarandama aukšto dažnio informacija, kurioje slypi monetas nudėvėjimo informacija. Klasifikuojant į keturias klases, yra matomas neryškus F1 įverčio pakilimas naudojant 2 oktavų sluoksnius, o tikslumas nežymiai didėja, didinant šių sluoksnių skaičių. Žinant, jog Coinset1 duomenų rinkinyje esančios 4 klasės persidengia, tai galima paaiškinti paprasčiausiu SVM modelio persimokymu, kuomet jis pradeda kreipti didesnę dėmesį į abstrakčią informaciją nesusijusia su monetų nudėvėjimu.



**3.14 pav.** Klasifikavimo rezultatai su skirtingomis kontrasto ribinėmis vertėmis

Toliau buvo tiriamas SIFT algoritmo kontrasto ribinės vertės parametras poveikis monetų nudėvėjimo klasifikavimui. Šio eksperimentu metu galima atkreipti dėmesį, jog kaip galima matyti iš dvejų pateiktų grafų (3.14 pav.), šios vertės didinimas mažinant SIFT deskriptorių skaičių (parametro prasmė pateikta literatūros analizėje) mažina aptinkamų nudėvėjimo žymių skaičių, nes jos palyginti su monetas kontūrais ar dizainu yra dažnai mažesnio kontrasto. Tai, turint persidengiančias nudėvėjimo grupes, gali sumažinti reikiamų grupių svarą dar labiau. Vis dėlto, esant aiškiai atskirčiai

tarp minėtų grupių, SIFT taškų mažinimas palieka tik žymiausius nudėvėjimo taškus monetoje bei išskiriamų klasių skaičiaus kaina, pasiekia tikslesnę klasifikavimą turint tik 2 klases.

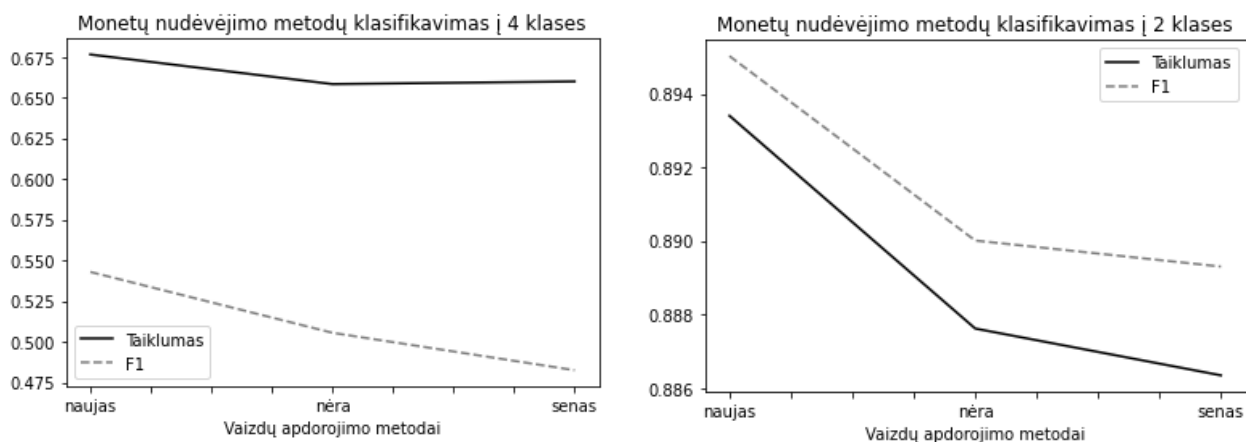


**3.15 pav.** Klasifikavimo rezultatai su skirtingomis kampo ribinėmis vertėmis

Paskutinis SIFT algoritmo parametras tirtas šiame darbe yra kampo ribinės vertės parametras. Šis parametras yra atsakingas SIFT algoritmo jautrumą kampams. Didinant jo vertę yra randamas didesnis kiekis taškų ant įvairių paveikslų tekstūros briaunų. Monetos nudėvėjimo vizualiniai artefaktai, tokie kaip įbrėžimai yra būtent šio pavidalo. Tuo galima įsitikinant ir šio eksperimento metu (3.15 pav.), kuomet kampo ribinė vertė yra didinama, o klasifikavimo rezultatai tiek su 2-jom, tiek su 4-iom klasėmis gerėja. Vis dėlto, verta atsižvelgti ir į tai, jog didinant šią ribinę vertę aptinkamų monetos dizaino kontūrų skaičius, nesusijęs su nudėvėjimu, taip pat didėja, kas gali neigiamai paveikti klasifikavimo rezultatus.

### 3.8.2. Pasiūlytų metodų įtakos tyrimas


Atlikus SIFT parametrų įtakos monetų nudėvėjimo klasifikavimui tyrimą, toliau identiška atliekamas pasiūlytų monetos normalizavimo ir žodžių kratinio sudarymo metodų rezultatų tyrimas.



**3.16 pav.** Klasifikavimo rezultatai su skirtingais vaizdų apdorojimo metodais

Klasifikuojant monetas pagal jų nudėvėjimo lygį į 2 ir 4 grupes iš pateiktų grafų (3.16 pav.) galima aiškiai matyti du dalykus. Pirma, literatūros analizėje aprašytas bei naudotas panašiam darbe Gauso

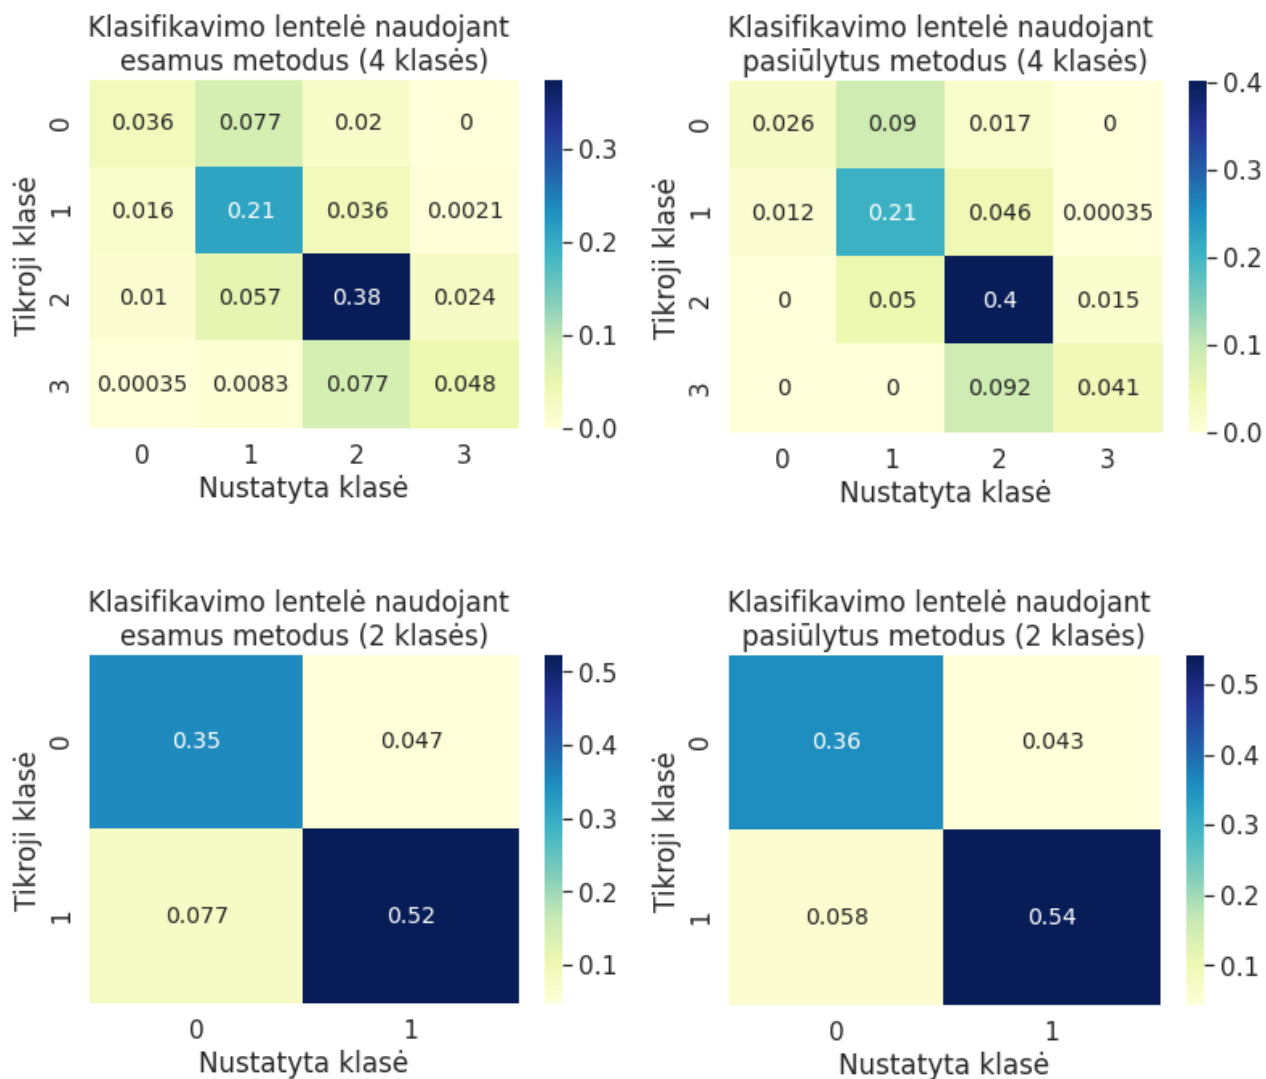
aukštų dažnių filtravimo metodas su žemų dažnių vidutinės reikšmės normalizavimu ženkliai atsilieka nuo kitų tirtų metodų. Net nenaudojant jokio apšvietimo normalizavimo metodo yra pasiekiami geresni rezultatai. Taip gali būti dėl naudojamo, Coinset1, duomenų rinkinio, kuris yra sudarytas realiomis sąlygomis. Antras, pastebėjimas šio eksperimento metu yra jog šiame darbe pasiūlytų CORT bei apšvietimo normalizavimo metodų naudojimas pranoksta kitus tirtus metodus.



**3.17 pav.** Klasifikavimo rezultatai su skirtingais žodžių kratinio sudarymo metodais

Sekančio eksperimento metu, šiame darbe buvo tiriami SIFT deskriptorių žodžių kratinio sudarymo metodai. Šio tyrimo metu buvo analizuojami trys metodai: įprastas, bei esamuose darbuose naudotas griežtas žodžių kratinio sudarymo metodas (angl. hard-coding), bei du šiame darbe pasiūlyti minkšto kodavimo metodai (angl. soft-coding) naudojantys skirtingas atstumų funkcijas. Iš pateiktų eksperimento rezultatų (3.17 pav.) galima matyti, jog klasifikuojant monetas į dvi grupes, šiame darbe pasiūlyti metodai nežymiai pranoksta griežto kodavimo metodą. Vis dėlto, klasifikuojant monetas į 4 grupes, griežtas kodavimas pateikia geresnius rezultatus. Tai galima pilnai paaiškinti duomenų rinkinio grupių persidengimu, kuomet pasiūlyti žodžių kratinio kodavimo metodai tik išryškina šį persidengimą.

Galiausiai, buvo atliktas naujų pasiūlytų bei esamų metodų klasifikavimo rezultatų palyginimas. Šio palyginimo metu buvo sudarytos klasifikavimo lentelės skirtos įvertinti dvejų ir keturių klasių klasifikavimo kokybę. Šiose lentelėse yra pateiktos duomenų rinkinio dalys klasifikuotos į atitinkamas klases.



**3.18 pav.** Klasifikavimo lentelės naudojant 2 ir 4 klases

Iš pateiktų 4-ių klasių klasifikavimo rezultatų (3.18 pav.) galima matyti, jog esami metodai nežymiai geriau atskiria labai nudėvėtas nuo vidutiniškai nudėvėtų monetų bei n nudėvėtas nuo mažai nudėvėtų. Vis dėlto, šiame darbe pateikti metodai geriau atskiria Coinset1 duomenų rinkinio monetas į dvi grupes: nudėvėtas ir mažai nudėvėtas. Iš pateiktų 2-ių klasių klasifikavimo rezultatų, tuo galima įsitikinti.

**3.4 lentelė.** Galutiniai monetų nudėvėjimo klasifikavimo rezultatai

Klasių skaičius	Metodų tipas	Vidutinė reikšmė		Didžiausia reikšmė		Mažiausia reikšmė	
		Taiklumas	F1	Taiklumas	F1	Taiklumas	F1
2	Esami metodai	0,876	0,879	1,0	1,0	0,6	0,609
	Pasiūlyti metodai	0,899	0,9	1,0	1,0	0,667	0,664
4	Esami metodai	0,671	0,55	0,933	0,934	0,4	0,253
	Pasiūlyti metodai	0,677	0,524	0,867	0,913	0,4	0,264

Galutiniai, šio tyrimo rezultatai yra pateikiami aukščiau pateiktoje lentelėje (3.4 lentelė). Šie rezultatai parodo, jog sukurti metodai skirti monetų nudėvėjimo išskyrimui, bei jų lygio klasifikavimo kokybės pagerinimui pateikia geresnius įverčius nei esami metodai.

## Išvados

1. Šiame darbe buvo identifikuotos monetų nudėvėjimui būdingos vizualinės savybės. Vis dėlto, išskirti unikalias savybes skirtingiems nudėvėjimo lygiams nebuvo įmanoma, tačiau vertinant bendrų nudėvėjimo savybių kiekį monetose buvo sudaryti vertinimo kriterijai skirti skirstyti jas pagal jų nudėvėjimo lygį.
2. Darbo metu, buvo sudarytas ir pateiktas realiomis sąlygomis randamo monetų nudėvėjimo duomenų rinkinys, Coinset1. Šis rinkinys išsiskyrė iš esamų darbų dėl savo sudėtingumo. Šio duomenų rinkinio dėka galima įvertinti monetos nudėvėjimo nustatymo metodus realiomis sąlygomis. Dėl šios priežasties pasiekti rezultatai naudojant šį duomenų rinkinį gali suteikti objektyvesnę požiūrį į jų efektyvumą.
3. Šiame darbe buvo sudaryti, nauji metodai skirti monetos nuotraukos fono šalinimui, jos apšvietimo normalizavimui bei nudėvėjimą nusakančios informacijos sudarymui.
4. Buvo atliktas klasifikavimo modelio parametrų bei pasiūlytų vaizdų apdorojimo metodų įtakos tyrimas monetų nudėvėjimo lygio nustatymo problemai. Atlikus pasiūlytų metodų tyrimą buvo ištirti jų rezultatai bei įvertintas jų efektyvumas lyginant su esamais metodais. Visi pasiūlyti metodai pasižymėjo pranašumu prieš kitus aprašytus metodus. Naudojant pasiūlytus metodus klasifikuojant Coinset1 duomenų rinkinį į dvi klases buvo pasiektas 89,9% klasifikavimo taiklumas bei 90% F1 tikslumo įvertis, tuo tarpu naudojant jau esamus metodus šie rezultatai buvo 87,6% ir 87,9%. Vis dėlto, klasifikavimas į 4-ias monetų nudėvėjimo lygio klases buvo nesėkmingas dėl persidengimo tarp duomenų rinkinyje esančių labai nudėvėtų ir mažai nudėvėtų monetų klasių. Siekiant klasifikuoti monetas į daugiau nei dvi klases, būtina sudaryti didesnę duomenų rinkinį kuriame būtų daugiau monetų turinčių labai didelį bei itin mažą nudėvėjimo lygį.

## Literatūros sąrašas

1. ATIGHEHCHIAN, P. *Coin Wear Estimation and Automatic Coin Grading*. [s.l.]: Concordia University, 2017. .
2. CORKE, P. et al. Dealing with shadows: Capturing intrinsic scene appearance for image-based outdoor localisation. In *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems* . [s.l.]: IEEE, 2013. p. 2085–2092. .
3. FU, K.S. - MUI, J.K. A survey on image segmentation. In *Pattern Recognition* . 1981. p. 14. .
4. HEADLEY, S. Coin Grading Made Simple. In [interaktyvus]. [žiūrėta 2019-01-27]. Prieiga per internetą: <<https://www.thesprucecrafts.com/coin-grading-made-simple-768384>>.
5. HERNANDEZ, J. Mercury Dimes with Full Bands. In [interaktyvus]. 2009. [žiūrėta 2019-01-27]. Prieiga per internetą: <<https://www.pcg.com/news/Mercury-Dimes-With-Full-Bands>>.
6. HUBER-MRK, R. et al. Automatic Coin Classification and Identification. In *Advances in Object Recognition Systems* . [s.l.]: InTech, 2012. .
7. ILKIN, S. et al. Comparison of Global Histogram-based Thresholding Methods that Applied on Wound Images. In *International Journal of Computer Applications* . 2017. Vol. 165, p. 23–28. .
8. KAPUR, J.N. et al. A new method for gray-level picture thresholding using the entropy of the histogram. In *Computer Vision, Graphics, and Image Processing* . 1985. Vol. 29, no. 3, p. 273–285. .
9. KHASHMAN, A. et al. Coin Identification Using Neural Networks. In *5th WSEAS International Conference on Signal Processing* . Istanbul, 2006. .
10. LIETUVOS BANKAS Susidėvėjusių ir sugadintų eurų monetų keitimas. In [interaktyvus]. [žiūrėta 2020-05-11]. Prieiga per internetą: <<https://www.lb.lt/lt/susidevejusiu-ir-sugadintu-euru-monetu-keitimas>>.
11. LOWE, D.G. Distinctive Image Features from Scale-Invariant Keypoints. In *International Journal of Computer Vision* . 2004. Vol. 60, no. 2, p. 91–110. .
12. LU, H. et al. Illumination Invariance Face Recognition Using Wavelet Coefficients and Local Binary Pattern. In *International Conference on Artificial Intelligence and Software Engineering* . 2014. .
13. MADDERN, W.P. et al. Illumination Invariant Imaging: Applications in Robust Vision-based Localisation, Mapping and Classification for Autonomous Vehicles. In [interaktyvus]. 2014. Prieiga per internetą: <<https://www.semanticscholar.org/paper/Illumination-Invariant-Imaging-%3A-Applications-in-%2C-Maddern-Stewart/7647e5bc73a61a2a9201e26b682e25e2877f4681?citationIntent=methodology#citing-papers>>.
14. OLIVER, A. *Automatic mass segmentation in mammographic images*. [s.l.]: Universitat de Girona, 2008. .
15. OTSU, N. A Threshold Selection Method from Gray-Level Histograms. In *IEEE Transactions on Systems, Man, and Cybernetics* . 1979. p. 62–66. .
16. PAN, X. - TOUGNE, L. Image Anaysis and Deep Learning for Aiding Professional Coin Grading. In *International Conference on Image Video Processing and Artificial Intelligence* . Shanghai, 2018. .
17. RAMESH, S. et al. Eigenedginess vs. eigenhill, eigenface and eigenedge. In [interaktyvus]. Prieiga per internetą: <[http://www.cse.iitm.ac.in/~vplab/publi\\_journal/conference/Eusipco-paper594.pdf](http://www.cse.iitm.ac.in/~vplab/publi_journal/conference/Eusipco-paper594.pdf)>.
18. ROGOWSKA, J. Overview and Fundamentals of Medical Image Segmentation. In *Handbook of Medical Imaging* . [s.l.]: Elsevier, 2000. p. 69–85. .
19. RUDDY, J.F. *Photograde: A Photographic Grading Encyclopedia for United States Coins*. . [s.l.]: Zyrus Press, 2005. 17–20 p.
20. SATOSHI, S. - KEIICHI, A. Topological structural analysis of digitized binary images by border

- following. In *Computer Vision, Graphics, and Image Processing* . 1985. Vol. 30, no. 1, p. 32–46. .
21. SHANNON, C.E. A mathematical theory of communication. In *The Bell System Technical Journal* . 1948. Vol. 27, no. 3, p. 379–423. .
22. THE EUROPEAN PARLIAMENT REGULATION (EU) No 1210/2010 OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL. In *Official Journal of the European Union* . 2010. .
23. VELDE, F.R. On the Evolution of Specie: Circulation and Weight Loss in 18th and 19th Century Coinage. In *Revue numismatique* . 2013. Vol. 170, no. 6, p. 605–650. .
24. WINTER, D. The Five Components of Coin Grading. In [interaktyvus]. 2001. [žiūrėta 2019-01-27]. Prieiga per internetą: <<https://raregoldcoins.com/blog/articles/the-five-components-of-coin-grading>>.
25. ZACK, G.W. et al. Automatic measurement of sister chromatid exchange frequency. In *Journal of Histochemistry & Cytochemistry* . 1977. Vol. 25, no. 7, p. 741–753. .
26. Indian head quarter eagle gold. In [interaktyvus]. [žiūrėta 2019-01-27]. Prieiga per internetą: <<https://www.usacoinbook.com/us-coins/600/indian-head-quarter-eagle-gold.jpg>>.
27. Liberty, 20 Dollar “1933 Double Eagle” Coin, United States of America, 1933. In [interaktyvus]. [žiūrėta 2019-06-20]. Prieiga per internetą: <[https://americanhistory.si.edu/sites/default/files/exhibitions/JN2015-5607\\_crop.jpg](https://americanhistory.si.edu/sites/default/files/exhibitions/JN2015-5607_crop.jpg)>.
28. Production & Circulation. In [interaktyvus]. [žiūrėta 2020-05-11]. Prieiga per internetą: <[https://www.treasury.gov/resource-center/faqs/Coins/Pages/edu\\_faq\\_coins\\_production.aspx](https://www.treasury.gov/resource-center/faqs/Coins/Pages/edu_faq_coins_production.aspx)>.



## Priedai

### **1 priedas. Pranešimas iš „Information Technology And Control“ redakcijos dėl publikacijos priėmimo**

Hello,

Armantas Ostreika has submitted the manuscript, "Methods for Adaptive Equalisation of Illumination and Foreground Detection in Coin Images" to Information Technology And Control.


If you have any questions, please contact me. Thank you for considering this journal as a venue for your work.

Prof. Vacius Jusas

---

Information Technology And Control <http://www.itc.ktu.lt/>

## 2 priedas. Publikacija "Methods for Adaptive Equalization of Illumination and Foreground Detection in Coin Images"

ITC X/XX Journal of Information Technology and Control Vol. XX / No. X / 201X pp. XX-XX DOI © Kaunas University of Technology	Methods for Adaptive Equalization of Illumination and Foreground Detection in Coin Images	
	Received 201X/XX/XX	Accepted after revision 201X/XX/XX
		

# Methods for Adaptive Equalization of Illumination and Foreground Detection in Coin Images

Matas Gumbinas, Armantas Ostreika

Faculty of Informatics; Kaunas University of Technology; Studentų Str. 50, LT-51368, Kaunas, Lithuania; phone: +370 37 350 730; fax: +370 37 300 352; e-mails: [matas.gumbinas@gmail.com](mailto:matas.gumbinas@gmail.com), [armantas.ostreika@ktu.lt](mailto:armantas.ostreika@ktu.lt)

Corresponding author: [armantas.ostreika@ktu.lt](mailto:armantas.ostreika@ktu.lt)

Estimating coin wear based on RGB digital images is a difficult problem. Lack of sufficiently large data sets, wide range of inter-class variance between the coins and unstable lightning or background conditions makes this problem very complex. To help alleviate some of these issues, we introduce few two new approaches for improving coin images inter and intra class invariance, focusing on illumination effects reduction and background segmentation.

**KEYWORDS:** Image processing, illumination invariance, multilevel threshold, object segmentation, coin wear.

## Introduction

In this paper, we investigate methods and approaches used in image preprocessing specialized for wear determination by use of modern coin images. In coin wear estimation problem one of the biggest challenges is dealing with variances between the coin images that are not related to their wear. These variances make difficulties in creating wear estimation models that could allow differentiating between wear and depiction differences found in various coins. Background and illumination variance are often found to be the reason for improper classification. Therefore, two problems were considered in this work: background and illumination variance.

To evaluate our proposed methods, and improvements, we collected and used two datasets

of real-life coin images to represent images taken in relatively variant and unstable conditions. All images were acquired using common digital RGB cameras and later the photographs were converted to one-channel grayscale images.

## Related Works

Currently there is limited amount of work being done in wear estimation specific for modern currency coins. Some authors [6] developed a model based on Brownian motion for evaluation of coin wear in terms of its weight loss. Here work is focused on 18<sup>th</sup> and 19<sup>th</sup> century coins. As for modern coins wear estimation, weight is not the most critical and efficient aspect, as opposed to visual

presentation of it. Fortunately, there are some recent work on this and similar subjects in the field of computer vision using common digital images of the coins.

In one of the more recent works a solution for modern coins classification was presented using a simple and small fully connected neural network [2]. For using this model with small dataset, authors proposed the use of heavy pre-processing of coin image to reduce its information to just a fraction of the original's. Unfortunately, such preprocessing would not be useful when dealing with such task as coin wear estimation. Another work [20] proposed a deep convolution neural network (CNN) to classify coin image patches, the size of 64x64 pixels, into two "smooth" and "grainy" categories. To circumvent the issue of the need to have large dataset, authors used transfer learning approach, and used pretrained AlexNet CNN model for this task. Their use of professionally made dataset of collector coin images taken in stable conditions makes their results questionable when dealing with real life images of modern coins taken in not ideal environmental conditions.

Another paper [1515] proposed a more real-life applicable solution, based on heavy pre-processing methods for classifying, both ancient and modern coins. In this work, authors proposed using two types of approaches. For ancient coins, a global threshold value was used to separate coin from the background. They suggested using an exhaustive optimal threshold finding strategy that tries to maximize the compactness ratio  $r = 4\pi S/P^2$  of the coin, where  $S$  and  $P$  are area and perimeter of the threshold result, by continuously increasing threshold value in small steps, until the highest compactness is found. On the other hand, for modern coins, an edge-based thresholding was employed. A Laplacian edge detection followed by zero-crossing operation on a Gaussian blurred coin image was applied, after which, the object with the largest bounding box was selected and a blob image was constructed by computing convex hull of the candidate region. These methods were performing well in a relatively clean environment and are also needed to be configured for individual conditions. Authors also applied rotational invariance by finding the correction angle of the coin using FFT based cross-correlation method. However, in coin wear estimation such transformations, should be used with caution due to possibility of angular interpolation introduced artifacts. Finally, transformations to compute coins' Eigen-images were applied, which later were processed into Eigen-hills to achieve illumination

invariance. However, this approach is not suited when dealing with small visual artifacts like the ones created by wear of the coin, as it fails to capture such information effectively [17].

There is master thesis [1313] where Gaussian high-pass filter is used for achieving illumination invariance specialized for enhancing coin wear features. Using Gaussian blur  $G$  as a low-pass filter with large standard deviation  $\sigma$  on the original grayscale intensity coin image  $I$ , only the low frequency details were kept (1). These details corresponded to such visual features, like gradient light, shadows and even coin material color. Next, these details were subtracted in a pixel-wise manner from the image  $I$  which only high frequency  $I_H$  information leaved there. Furthermore, a suggestion was made to replace the eliminated low frequency values with their mean  $\mu_L$  by adding it to  $I_H$  (3). The result was high frequency details image  $I_H$  containing such information as coin design edges and wear marks, e.g. scratches and deformations.

$$I_L = G(x, y, \sigma) * I(x, y), \quad (1)$$

$$\mu_L = \frac{1}{nm} \sum_{i,j}^{n,m} I_L(i, j) \quad (2)$$

$$I_H = I - I_L + \mu_L. \quad (3)$$

For background segmentation, author of this work also used edge-based threshold method to segment coin image from the background, however the Canny edge detection algorithm, that was used, demands finetuning its parameters to achieve good performance.

## Background Thresholding

When processing specific objects in the scene, most of the time takes their segmentation and separation from the surrounding background. This is especially important when dealing with coin image preprocessing prior to their classification or specific features analysis.

Background invariance is very important in coin wear estimation, because background often contains visual features commonly found in coins and are associated with wide range of wear artifacts. These artifacts may include discolorations, scratches, surface indentations or lack of discerning textures as in the case of smoothed coin design due to their prolonged handling.

Commonly used techniques for background segmentation involves thresholding and clustering. Similar to [3], we view thresholding as a special case of clustering approach that uses only 2 clusters to separate information. This is relevant to our work since the goal of coin image segmentation is to remove its background, having to deal with only two clusters of pixels: background and coin. In work [11] authors divided thresholding strategies into two groups based on their use of spatial information: statistical and structural. Statistical thresholding methods can be either local or global, and they do not consider spatial relation in the given data. This type of thresholding can be defined as a function  $T(x, y, I, N)$ , where  $x$  and  $y$  are the image spatial coordinates,  $I(x, y)$  is the image pixel value, while  $N(x, y)$  is image local region value. Global, opposite to local, threshold methods do not use local image information  $N$ , thus they are preferred in situations where the source image intensity values are assumed to be strictly bimodal [10]. In this work, only two groups of image intensities are expected however, in the case of coin image background being non-uniform, due to possible variations in lightning conditions and its texture, e.g. unclean or texturized conveyor belt, there is a possibility that some of the background regions might be falsely classified as foreground. In such cases, structural thresholding strategy is employed. Such strategy might use previously described statistical thresholding methods to extract different intensity regions in the image, followed by a topology building algorithms, such as connected components, to create a structural representation of these regions. Having obtained its topological and individual nodes properties a second threshold is applied resulting in structurally segmented image.

One of the main problems, that all thresholding methods have, is finding the exact inter-class border value  $t$ , used for separating data distribution. There are number of proposed methods to find this value. One of the most popular algorithms for this task has been developed by Otsu [12]. This method is based on exhaustive grayscale image histogram intra-class variance minimization and conversely, inter-class variance maximization. This method is known to be best used for strictly bimodal histograms that show wide and nuanced separation between the two peaks. However, it often shows poor results when the source image background area is greater than foreground. This causes concern due to the fact that coin in the image often takes up less than a quarter of the image area.


Another, well known method for finding optimal threshold value  $t$ , was proposed by Kapur [9]. It is

based on Shannon's information entropy [4]. Kapur assumes that image intensity values form two distinct probability distributions belong to background and foreground regions. This method is designed to find the best threshold value by maximizing histogram inter-class entropy. Through empirical testing with real life images containing small relative area objects, it was observed that this entropy-based method does not show large bias towards object size and is performing well on high contrast bimodal information [16].

In their work, Zack, Rogers & Latt [7] proposed a global threshold method for image intensity histogram specific to biomedical images (see Figure 1). These images contained small objects of interest relative to their background area. Authors proposed to select threshold value by normalizing the height and dynamic range of the intensity histogram, locating point A and adding empirically determined constant offset. This method does not seem to have a theoretical background but is likely defined empirically. Nonetheless, it is widely used in image processing while preferred for its simplicity and performance in both, accuracy, and speed.

**Figure 2**

Zack, Rogers & Latt [247] proposed threshold method visual description.



## Illumination Invariance

Even in controlled environments illumination invariance is a very important aspect of coin images processing. That is because all coins, even those of the same design, can produce different reflection and scattering of light. Some of the reasons for this are coin surface contamination and wear. In coin wear estimation, the color of the metal used for the production causes problems, because in most



cases, wear could be generalized for a number of different coin designs, however different coin image intensity values produced by color that do not correlate to wear hinders attempts to accurately estimate it.

There has been some work attempting to achieve illumination invariance. However, in most cases, it was highly specific to individual use-case. SIFT descriptors invented by Lowe [5] are one of the best examples solving this problem. Using SIFT, many great achievements were made in computer vision and it was applied extensively in the robotics and biomedical fields. Illumination invariance was attempted to be achieved by extracting localized image regions, reducing the importance of spatial discrimination of lighting effects. Furthermore, linear illumination of these regions was reduced by computing them as their histogram’s unit vectors, eliminating constant changes in contrast. Additionally, non-linear gradient illumination was addressed, by simply clipping highest values of the histogram vector. Unfortunately, SIFT illumination invariance does not achieve, good results, when dealing with stronger variation in lightning. This was tested and proved by recent work in applying local descriptors in real-life illumination variant scenarios [1].

Authors suggested a very good illumination invariant approach for common 2D RGB digital cameras in another recent work [19] in which an illumination invariant single-channel color space was proposed (4). This color space was designed to be derived from RGB image, captured by a digital optical sensor that uses a Bayer filter. Authors also proposed a method to infer a specific color-space conversion parameter  $\alpha$  for a given three-channel camera simply with knowledge of the peak spectral responses of each sensor channel. This is opposed to another work where such parameter was determined empirically using a training images dataset [14].

$$I_{inv} = \frac{1}{2} + \log I_g - \alpha \log I_r - (1 - \alpha) \log I_b \quad (4)$$

---

## Proposed methods

In this work we present two improvements in coin image preprocessing for coin estimation problem.

### Circular Object Refined Threshold

We propose a new, improved threshold method “Circular Object Refined Threshold” or CORT, specific for modern coin image segmentation,

designed to be more adaptive to various lightning and background conditions and not requiring special finetuning of its parameters. We expect an intensity image  $I$  to contain only one instance of a coin and the rest to be background, while the coins themselves to not have holes and have greater image area than arbitrarily set constant  $minsize_c$ . Our method can be considered as a multilevel binary threshold algorithm that uses two threshold steps for localization and segmentation, with a search sequence in between, based on object’s structure for the best foreground candidate.

The basic coin image structural threshold algorithm is shown below (see **Figure 3**), however further optimizations and configurations should be made. First, we downsize initial image to 720x720 resolution. This helps to increased performance, but leave sufficient image resolution as it could affect image border regions with lower contrast, e.g. fail to separate slight shadows from the coin. Though, it should be noted, that the target size selection is up to each individual use-case.

For localization of the circle-like objects in the source image, through our own empirical testing of three different global threshold methods, we chose to use Kapur’s max-entropy based global threshold. Next, we employ a morphological closing operation with an elliptical 7x7 kernel, to form a closed border between background and foreground objects. This is of the utmost importance as failing to do so results in miss-localization and segmentation. Having extracted individual objects in the image, we use connected components algorithm to gain spatial information about them. Having it, we discard any object in the scene with size less than  $minsize_c$ , thus removing possible background noise. After doing so, image should contain only coin region and possibly, other large regions that occur due to bad lightning conditions. To eliminate them, we process each object’s bounding box region, excluding it from the rest of the image to save computational resources, and we define their contours with a contour finding algorithm. In this work we chose to use contour finding algorithm created by Satoshi & Keiichi [18] for binary images. Next, we estimate each region’s circular compactness based on its contour’s geometrical properties: area and perimeter. By choosing the region with the

highest compactness, we ensure that we find the most circle-like object  $c_{best}$  in the image. We compute a padded bounding box,  $L_{bb}$ , for this

object with a pre-set padding size and extracted it from the source image to get localized coin image  $L$ .

Figure 4

Proposed CORT algorithm for image thresholding.

---

**Algorithm 1** Circular Object Refined Threshold

---

```

1: procedure CORT
2:    $h_I^k \leftarrow \sum_{i,j}^{n,m} [I_{ij} = k]$   $\triangleright$  compute image histogram's  $k$ -th bin size.
3:    $t_1 \leftarrow LocalizationThreshold(h_I)$   $\triangleright$  find threshold value for localization.
4:    $c_{best} \leftarrow \emptyset$ 
5:    $r_{best} \leftarrow 0$ 
6:   for each  $c \in CC[T(I_{xy}, t_1)]$  do  $\triangleright$  Iterate through external connected
                                     components in the thresholded image.
7:     if  $c_{size} < minsize_c$  then
8:       continue
9:     end if
10:     $c_{contour} \leftarrow FindContour(c)$   $\triangleright$  find external contour.
11:     $S \leftarrow Area(c_{contour})$ 
12:     $P \leftarrow Perimeter(c_{contour})$ 
13:     $r \leftarrow 4\pi S/P^2$   $\triangleright$  estimate contour compactness ratio.
14:    if  $r \geq r_{best}$  then
15:       $c_{best} \leftarrow c$ 
16:       $r_{best} \leftarrow r$ 
17:    end if
18:  end for
19:   $L_{bb} \leftarrow BB(c_{best}, padding)$   $\triangleright$  compute padded bounding box.
20:   $L \leftarrow Crop(I, L_{bb})$   $\triangleright$  localized image region.
21:   $h_L^k \leftarrow \sum_{i,j}^{n,m} [L_{ij} = k]$   $\triangleright$  compute image histogram's  $k$ -th bin size.
22:   $t_2 \leftarrow SegmentationThreshold(h_L)$   $\triangleright$  find threshold value for local
                                     segmentation.
23:   $contour \leftarrow Contour(c_{best})$ 
24:   $L_{out} \leftarrow FillHoles[T(L_{xy}, t_2) \wedge Fill(contour)]$   $\triangleright$  fill holes in the thresh-
                                     old result.
25:   $I_{out} \leftarrow L_{out}$   $\triangleright$  remap local threshold values  $L_{out}$  to global result  $I_{out}$ .
26:  return  $I_{out}$ 
27: end procedure

```

---

For the refined segmentation of the localized coin image, we use Otsu's global threshold method to compute a more accurate foreground for the coin image, applying it to  $L$  instead of the full image.

In our experimentations, we determined that Otsu's threshold works best when dealing with balanced bimodal distributions. To increase this balance, we use a bounding box with a padding size set to 5% of the localized coin size in both dimensions.


Next, we perform bitwise AND operation to merge Otsu's threshold result with previously found localized coin region, and afterwards, we perform two sequential, closing and opening,

morphological operations with 7x7 elliptical kernel on the threshold result. This ensures that the border of the thresholded coin image is closed and it also removes some small background noise attached to border of the threshold result. Finally, we fill holes in the coin threshold with Flood Fill algorithm and use connected components approach to find the new, precise bounding box of the local coin foreground region  $L_{out}$  and mapped it's coordinates along with the region mask to original image coordinate space, resulting in the image threshold  $I_{out}$ .

Visual results of the described processing steps are presented in Figure 5.

Figure 6

a) Source image; b) Max-entropy threshold result; c) Morphological closing; d) Threshold region with the highest compactness ratio; e) Localized coin image; e) Localized image threshold result using Otsu's method; g) Morphological closing followed by opening and hole filling with merged with coin localization region (d); h) Extracted coin image after applying the computed threshold mask (g).



## Illumination Invariant Color-space Filtering

The use of high-pass filter, as suggested in [1313], accomplishes two tasks: captures and eliminates lightning effects found in image low frequency band and enhances remaining fine details, e.g. coin surface wear features. Lightning effects such as reflections [8] and small, local blemishes or discolorations are mainly found in higher frequency bands and are not affected by the filtering. Some of these effects may create additional distortions when trying to extract wear details in the coin, e.g. low contrast around the edges of the design, and patches of low contrast discolorations that blends possible wear details. Commonly used high-pass filters do not filter out these effects, due to their relatively small size. Instead, to achieve image illumination invariance in the context of coin wear estimation we propose a 2-step method based on Gaussian high-pass filtering and illumination invariant color-space for minimizing illumination variance in the coin.

For illumination invariant color-space we chose to use previously described equation (4). We chose this color-space, due to it being single-channel, designed specifically for digital RGB cameras, and most importantly, because it does not require to use empirical configuration for its conversion ratio

parameter  $\alpha$ . Since this equation performs computations in log-space, it is naturally prone to numerical instability when dealing with various pixel intensity values. Therefore, before applying this function in our work, we suggest a modification of it (8), which would ensure it is numerically stable. We first simplify the equation so that only two log operations would take place (7). Second, we introduce a new parameter  $\epsilon$ , which is set to a very small value, and would act as a guard against illegal operations such as division by zero or underflows, which are a common problem when dealing with  $\log$  operations and fractions. The modified formula is both, more numerically stable and faster due to use of only two  $\log$  computations.

Having the illumination invariant color-space equation  $\hat{I}_{inv}$ , we apply it to coin region in the RGB image and subtract the resulting lightning invariant features from the original intensity image of the coin (10). The output of this operation results in elimination of unwanted lightning invariant effects found in the original coin image, e.g. color of material, small blemishes & discolorations, and visible low-contrast illumination gradients found near design edges. These changes take place independent of the frequency band. To



remove the remaining unwanted lighting effects that can be found in the low frequency band of the image, we use Gaussian high-pass filter. This eliminates the final remaining illumination effects in the coin image, such as shadows, low-contrast highlights, and further reduces the color of material, which is important when dealing with bimetal coins. Unlike in [1313], we do not add value  $\mu_L$  to the result image, as the normalization of intensities was addressed by using illumination invariant color-space.

$$I_{inv} = \frac{1}{2} + \log I_g - \alpha \log I_r - (1-\alpha) \log I_b, \quad (5)$$

$$= \frac{1}{2} + \log I_g - \log I_b + \alpha(\log I_b - \log I_r), \quad (6)$$

$$= \frac{1}{2} + \log \frac{I_g}{I_b} + \alpha \log \frac{I_b}{I_r}. \quad (7)$$

$$\hat{I}_{inv} = \frac{1}{2} + \log \left( \frac{I_g}{I_b + \varepsilon} + \varepsilon \right) + \alpha \log \left( \frac{I_b}{I_r + \varepsilon} + \varepsilon \right). \quad (8)$$

$$\lim_{\varepsilon \rightarrow 0} \hat{I}_{inv} = I_{inv}. \quad (9)$$

$$D_{inv} = I - I_{inv}, \quad (10)$$

$$I_L = G(x, y, \sigma) * D(x, y), \quad (11)$$

$$I_H = D - I_L. \quad (12)$$

## Experiments and Results

To evaluate and validate our proposed methods and improvements performance in pre-processing coin images for coin wear estimation problems, we collected and used two datasets:

- Coinset1 – is made of 90 samples of 1Euro coin images, taken in relatively controlled environment. This dataset is most important when evaluating illumination invariance of coins.
- Coinset2 – consists of 154 images of various denominations of British coins. The images were taken in poor conditions, such as strong glare on coin and background, high perspective variations in images. This dataset is most relevant when evaluating the image background segmentation performance.

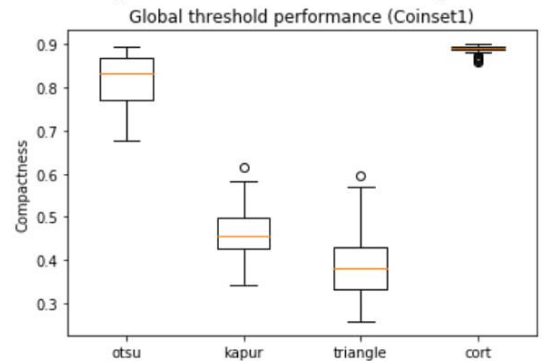
The first experiment was focused on evaluating the performance of three optimal global threshold finding algorithms: Otsu, Kapur's max-entropy and triangle method and finally comparing them to our proposed method. All methods were evaluated on both datasets separately; the results are presented

in **Figure 7** and in **Figure 8**. The criteria for performance regarding the threshold of coin image, was chosen to be its best compactness ratio  $r$ , selected from the pool of separable objects in the threshold result. This ratio estimates the threshold's roundness since the modern coins in the datasets are expected to be round. From the results of the experiment we came to four conclusions:

1. Otsu method works best with images taken in good, controlled environment, but underperforms when dealing with more variant background and lightning conditions (Coinset1).
2. Kapur's max-entropy method outperforms Otsu and triangle methods when dealing with images taken in highly variant conditions (Coinset2), but captures more area around the coin object, representing shadows.
3. Kapur's max-entropy and triangle methods computed threshold values highly correlate to each other, thus triangle method could be used as an approximation of max-entropy method which is much more computationally expensive.
4. Our proposed CORT method outperforms all other tested threshold methods by a large margin, showing that the use of automatic localized multilevel threshold is a valid strategy when the goal is to achieve clean segmentation of an object in the image.

**Figure 9**


Threshold performance with Coinset1 images.





**Figure 10**

Threshold performance with Coinset2 images.



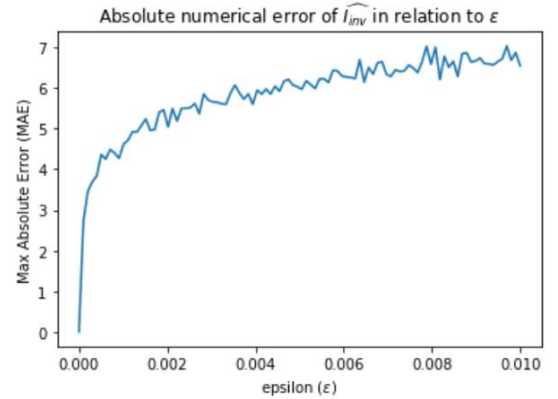
The second experiment was focused on validating the proposed and derived numerically stable version of illumination invariant function (8). The experiment was conducted by comparing  $I_{inv}$  and  $\hat{I}_{inv}$  functions using max absolute error,  $MAE = \max|\hat{I}_{inv} - I_{inv}|$ , with  $N$  linearly increasing values of  $\varepsilon \in \{10^{-8}, 10^{-2}\}$ . At each iteration of  $\varepsilon$  a new array of random real numbers taken from uniform distribution is created. The size of these arrays during this experiment was set to 100000 samples of RGB points resulting in a size of 100000x3 randomly initialized array. Furthermore, each  $\varepsilon$  iteration was repeated 50 times to get an average MAE value. As we can see from the plot diagram bellow (Figure 11), the absolute error in increasing  $\varepsilon$  linearly results in a logarithmic increase of error. This experiment shows that the stabilization of the illumination invariance function is stable enough when a sufficiently small  $\varepsilon$  value is used, and it fully works in preventing underflows, overflows, and illegal operations such as division by zero.

The final experiment focuses on evaluating our proposed processing method for illumination invariance of a coin image. We evaluated three approaches:

1. Gaussian high-pass filter (HPV) with  $\mu_L$  intensities normalization factor (3).
2. Our proposed method (12) applying Gaussian high-pass filter used alongside illumination invariant color-space  $I_{inv}$ .
3. Our proposed method (10) using only illumination invariant color-space  $I_{inv}$  and original image difference.


**Figure 12**

Modified illumination invariant color-space function's max absolute numerical error analysis.



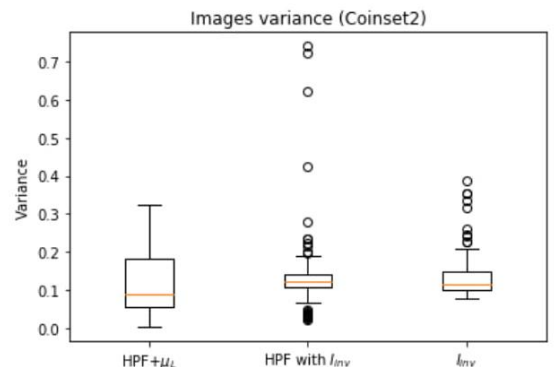
**Figure 13**

Images variance for Coinset1 using different illumination invariance methods.



**Figure 14**

Images variance for Coinset2 using different illumination invariance methods.




In the conclusion of this experiment, as can be seen in the Figure 15 and Figure 16, we can

observe a considerable improvement in variance reduction using our suggested method on images with relatively stable illumination conditions (Coinset1). The results for not using HPV were also good however, upon closer inspection of the processed coin images, we found that this approach was inferior to all other approaches that we have tested, due to it leaving out too much of lighting effects. Meanwhile, the original method showed small edge in dealing with very variant illumination conditions, such as strong reflections and uneven or directed lightning.

**Figure 17**

Illumination invariance methods preview: (top-left) original grayscale image; (top-right) HPF+ $\mu_L$  method (3); (bottom-left) proposed method of HPF with  $\hat{I}_{inv}$  (12). (bottom-right) only  $\hat{I}_{inv}$  method (10).



Visual results of the experiments, using different illumination invariance methods for the Coinset1, are shown in **Figure 18**.

## Conclusions

In this work different methods for achieving illumination invariance and foreground detection for coin images were analyzed.

A new threshold approach, CORT, designed specifically for coin-like objects was elaborated. Experimental testing showed that CORT outperforms other tested methods by a large margin.

Another improvement seeking to stabilize illumination invariant color-space conversion, was introduced. The proposed function (8) was evaluated and tested for the numerical accuracy.

Finally, the use of proposed color-space conversion

paired with Gaussian high-pass filter was suggested and validated. It allowed to achieve coin image illumination invariance in most cases.

## References

1. A. J. Glover, W. P. Maddern, M. J. Milford and G. F. Wyeth, "FAB-MAP + RatSLAM: Appearance-based SLAM for Multiple Times of Day," IEEE International Conference on Robotics and Automation, 2010.
2. A. Khashman, B. Sekeroglu and K. Dimililer, "Coin Identification Using Neural Networks," in 5th WSEAS International Conference on Signal Processing, 2006, Istanbul.
3. A. Oliver, "Automatic mass segmentation in mammographic images," 17 06 2008. [Online]. Available: <http://eia.udg.edu/~aoliver/publications/tesi/no de32.html>. [Accessed 04 05 2020].
4. C. E. Shannon, "A Mathematical Theory of Communication," The Bell System Technical Journal, 1948, vol. 27.
5. D. G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," International Journal of Computer Vision, 2004.
6. F. R. Velde, "On the Evolution of Specie: Circulation and Weight Loss in 18th and 19th Century Coinage," Revue numismatique, 2013, vol. 170, pp. 605-650.
7. G. W. Zack, W. E. Rogers and S. A. Latt, "Automatic Measurement of Sister Chromatid Exchange Frequency," The Journal of Histochemistry and Cytochemistry, 1977, vol. 25, pp. 741-753.
8. H. Lu, M. Yang and X. Ben, "Illumination Invariance Face Recognition Using Wavelet Coefficients and Local Binary Pattern," in International Conference on Artificial Intelligence and Software Engineering, 2014.
9. J. N. Kapur, P. K. Sahoo and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," Computer Vision, Graphics, and Image Processing, 1985, vol. 29, no. 3, pp. 273-285.
10. J. Rogowska, "Overview and Fundamentals of Medical Image Segmentation," Handbook of Medical Image Processing and Analysis, no. 2, pp. 73-90, 2009.
11. K. S. Fu and J. K. Mui, "A survey on image segmentation," Pattern Recognition, 1981, vol. 13, p. 14.
12. N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," IEEE Transactions on Systems, Man, and Cybernetics, vol. 9, no. 1, pp.

- 62 - 66, 1979.
13. P. Atighehchian, "Coin Wear Estimation and Automatic Coin Grading", 2017.
  14. P. Corke, R. Paul, W. Churchill and P. Newman, "Dealing with Shadows: Capturing Intrinsic Scene Appearance for Image-based Outdoor Localisation".
  15. R. Huber-Mörk, M. Nölle, M. Rubik, M. Hödlmose, M. Kampel and S. Zambanini, "Automatic Coin Classification and Identification," *Advances in Object Recognition Systems*, 2012.
  16. S. İlkin, F. S. Hangişi and S. Şahin, "Comparison of Global Histogram-based Thresholding Methods that Applied on Wound Images," *International Journal of Computer Applications*, 2017, vol. 165.
  17. S. Ramesh, S. Palanivel, S. Das and B. Yegnanarayana, "Eigenedginess vs. eigenhill, eigenface and eigenedge," [Online]. Available: [http://www.cse.iitm.ac.in/~vplab/publi\\_journal/conference/Eusipco-paper594.pdf](http://www.cse.iitm.ac.in/~vplab/publi_journal/conference/Eusipco-paper594.pdf). [Accessed 05 05 2020].
  18. S. Satoshi and A. Keiichi, "Topological Structural Analysis of Digitized Binary Images by Border Following," *Computer Vision, Graphics, and Image Processing*, 1985, vol. 30, pp. 32-46.
  19. W. Maddern, A. D. Stewart, C. McManus, B. Upcroft, W. Churchill and P. Newman, "Illumination Invariant Imaging: Applications in Robust Vision-based Localisation, Mapping and Classification for Autonomous Vehicles".
  20. X. Pan and L. Tougne, "Image Anaysis and Deep Learning for Aiding Professional Coin Grading," in *International Conference on Image Video Processing and Artificial Intelligence*, 2018, Shanghai.