



**KAUNO TECHNOLOGIJOS UNIVERSITETAS
MATEMATIKOS IR GAMTOS MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA**

Rima Linaburgytė

**DEFEKTŲ TEKSTŪRINIUIOSE
PAVIRŠIUOSE NUSTATYMAS TAIKANT
HAARO TRANSFORMACIJĄ**

Magistro darbas

**Vadovas
prof. dr. J. Valantinas**

KAUNAS, 2014



KAUNO TECHNOLOGIJOS UNIVERSITETAS
MATEMATIKOS IR GAMTOS MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA

TVIRTINU
Katedros vedėjas
doc. dr. N. Listopadskis
2014 06 05

DEFEKTŲ TEKSTŪRINIUIOSE
PAVIRŠIUOSE NUSTATYMAS TAIKANT
HAARO TRANSFORMACIJĄ

Taikomosios matematikos magistro baigiamasis darbas

Vadovas
prof. dr. J. Valantinas
2014 06 02

Recenzentas
doc.dr. Romas Marcinkevičius
2014 06 02

Atliko
FMMM-2 gr. stud.
R. Linaburgytė
2014 05 30

KAUNAS, 2014

KVALIFIKACINĖ KOMISIJA

Pirmininkas: Juozas Augutis, profesorius (VDU)

Sekretorius: Eimutis Valakevičius, profesorius (KTU)

Nariai: Jonas Valantinas, profesorius (KTU)

Vytautas Janilionis, docentas (KTU)

Kristina Šutienė, docentė (KTU)

Zenonas Navickas, profesorius (KTU)

Arūnas Barauskas, dr., direktoriaus pavaduotojas (UAB „Danet Baltic“)

SANTRAUKA

Šiame darbe pateikiami ir palyginami du defektų tekstūriniuose paviršiuose nustatymo metodai, kuriuos galima praktiškai pritaikyti pramoniniame procese, automatizuotai tikrinant gaminių kokybę, nes vartotojų lūkesčių ir kokybės reikalavimų netenkinanti produkcija gali nulemti pardavimų sumažėjimą ir taip sukelti finansinius sunkumus.

Abu metodai pagrįsti Haaro transformacijos (HT), kuri defektus tekstūriniuose paviršiuose aptinka efektyviau negu kitos diskrečiosios bangelių transformacijos (DBT), kaip: Daubechies, Symlets, Coinflets ir t.t., taikymu. Transformacijos filtravimo metu skaitmeninis vaizdas yra skaidomas į skirtingo dažnio segmentus, kurie sudaryti iš spektrinių koeficientų, kaupiančių savyje ne tik pradinio vaizdo informaciją, bet ir pasižyminčių savybe, esant defektams ar spalvos kontrasto anomalijoms vaizde, stipriai susvyruoti. Šie spektrinių koeficientų bruožai, empirinės taisyklės žinios bei maksimalių koeficientų modulių skirtumų apskaičiavimas yra sudarytų metodų kokybės kriterijų pagrindas.

Metodų veikimas pademonstruojamas su kokybiškų ir brokuotų betoninių plytelių tekstūriniais paviršių vaizdais. Tyrimo rezultatai parodė, kad visi plytelių paviršių su įvairiais mechaniniais pažeidimais: įskilimais, nelygumais, skylėmis ar dėmėmis, vaizdai buvo pripažinti kaip defektuoti, tačiau 15- 20% gerų vaizdų buvo identifikuoti kaip brokuoti vaizdai, tačiau tokie atvejai gali būti netgi naudingi, jei reikalaujama nepriekaištinga produkto kokybė.

Defektų aptikimo rezultatai gali būti labai svarbi informacija ir jų lokalizavimui. Šiame darbe pateikiami tik baziniai lokalizavimo principai, kurie galėtų būti pagrindas kitų lokalizavimo metodų kūrimui bei jų tyrimams.

Linaburgytė R. Defect detection in texture surfaces using Haar transform: Master's work in applied mathematics / supervisor dr. assoc. prof. J. Valantinas; Department of Applied mathematics, Faculty of Mathematics and Natural Sciences, Kaunas University of Technology. – Kaunas, 2014. – 50 p.

SUMMARY

In this paper, two methods have been offered to detect defects in texture surfaces. These methods could be practically used for an automated visual inspection and quality control in a process of serial production to avoid the financial problems caused by the selling decrements.

The discrete Haar wavelet transform (HT) has been applied in the failure detection algorithms, because Haar wavelet is better than other wavelet basis functions such as Daubechies, Symlets, Coinflets, for the inspection of defects. The wavelet transform decomposition can be performed by passing the digital image through the low- pass and high- pass filters to generate the different frequency components whose spectral coefficients store all information about the original image. Besides, the experiments were carried out to show that at least one of the obtained components consists of enhanced wavelet coefficients in the image with the different kind of failure. This property of discrete wavelet transform gives possibility of the detecting of defects in texture surfaces. The empirical rule and the calculation of the relative differences between the corresponding maxima of wavelet coefficients are used in the detection procedure too.

The proposed methods were analyzed using the digital images of the intact and defected surfaces of the paving blocks. The experimental results revealed that all images with every type of manufacturing defects such as cracks, pinholes and spots, were classified correctly, but about 15- 20 percent of the intact images were classified falsely as the defected ones. Sometimes the situation when a part of the undamaged paving blocks are rejected is required because of the perfect quality of the production.

The results showed that the proposed methods detect defects successfully, so the obtained information about the inspection of defects in the texture images could be meaningful for the localization procedure. The basics principles about the localization of the defects are described in this paper too.

TURINYS

ĮVADAS.....	9
1. BENDROJI DALIS.....	11
1.1. TEKSTŪRINIO PAVIRŠIAUS SĄVOKA IR ANALIZĖ	11
1.1.1. TEKSTŪROS SAMPRATA	11
1.1.2. STATISTINIAI TEKSTŪRINIŲ PAVIRŠIŲ ANALIZĖS METODAI.....	11
1.1.3. STRUKTŪRINIAI TEKSTŪRINIŲ PAVIRŠIŲ ANALIZĖS METODAI.....	12
1.1.4. SPEKTRINIAI TEKSTŪRINIŲ PAVIRŠIŲ ANALIZĖS METODAI.....	16
1.2. DISKREČIOSIOS BANGELIŲ TRANSFORMACIJOS (DBT) IR JŲ TAIKYMAI.....	16
1.2.1. BENDROSIOS BANGELIŲ SAVYBĖS IR DBT APSKAIČIAVIMO ALGORITMAI	16
1.2.2. PRAKTINIO DBT PANAUDOJIMO SRIČIŲ APŽVALGA	20
1.2.3. DISKREČIOJI HAARO TRANSFORMACIJA	21
2. METODOLOGINĖ DALIS	26
2.1. DEFEKTŲ NUSTATYMO IR LOKALIZAVIMO (DNL) TEKSTŪRINIUOSE PAVIRŠIUOSE PROBLEMA	26
2.1.1. SKAITMENINIO VAIZDO KOKYBĖS KRITERIJAUŠ FORMAVIMAS.....	26
2.1.2. DEFEKTŲ TEKSTŪRINIUOSE PAVIRŠIUOSE LOKALIZAVIMAS	30
3. TIRIAMOJI DALIS	30
3.1. TEKSTŪRINIŲ PAVIRŠIŲ DNL EKSPERIMENTAS	30
3.1.1. TEKSTŪRINIŲ PAVIRŠIŲ PARINKIMAS EKSPERIMENTUI.....	30
3.1.2. DEFEKTŲ NUSTATYMO EKSPERIMENTAS	31
3.1.3. DEFEKTŲ LOKALIZAVIMO EKSPERIMENTAS	34
IŠVADOS.....	37
LITERATŪRA.....	38
1 PRIEDAS	40

LENTELIŲ SĄRAŠAS

1.1 lentelė. Dydžiai, apskaičiuoti iš GLCM matricos $P(i, j)$	11
1.2 lentelė. Kalbiniai terminai, įvertinantys Tamuros ir kt.dydžius	14
1.3 lentelė. Tekstūrinių paviršių pavyzdžiai ir jų savybės.....	15
1.4 lentelė. Parametrų k , r ir m reikšmės.....	24
3.1 lentelė. Metodų palyginimas atpažįstant vaizdus su defektais.....	33
3.2 lentelė. Metodų palyginimas atpažįstant vaizdus be defektų.....	33
3.3 lentelė. DBT palyginamas.....	34

PAVEIKSLŲ SĄRAŠAS

1.1 paveikslas. Diskrečiosios bangelių transformacijos schema.....	18
1.2 paveikslas. DBT spektrinių koeficientų segmentai.....	19
1.3 paveikslas. Skaitmeninis vaizdas ir jo DBT transformacija.....	19
1.4 paveikslas. Greito HT apskaičiavimo algoritmo schema.....	22
1.5 paveikslas. Haaro funkcijų sistema.....	25
2.1 paveikslas. Empirinė taisyklė.....	27
2.2 paveikslas. HT spektro segmentų $X_{A,1}$ ir $X_{A,1}^*$ koeficientai kokybiškame ir brokuotame vaizde....	28
2.3 paveikslas. HT spektro segmentų $X_{H,1}$ ir $X_{H,1}^*$ koeficientai kokybiškame ir brokuotame.....	28
2.4 paveikslas. HT spektro segmentų $X_{V,1}$ ir $X_{V,1}^*$ koeficientai kokybiškame ir brokuotame vaizde...28	
2.5 paveikslas. HT spektro segmentų $X_{D,1}$ ir $X_{D,1}^*$ koeficientai kokybiškame ir brokuotame vaizde...29	
3.1 paveikslas. Natūralių tekstūrinių paviršių pavyzdžiai.....	30
3.2 paveikslas. Dirbtinių tekstūrinių paviršių pavyzdžiai.....	31
3.3 paveikslas. Kokybiškos ir brokuotos plytelių pavyzdžiai.....	31
3.4 paveikslas. DBT palyginimas.....	34
3.5 paveikslas. Testuojamas vaizdas.....	35
3.6 paveikslas. Defektų lokalizavimo procedūra.....	36

IVADAS

Nors šiomis dienomis produkcija gaminama ir rūšiuojama automatinio būdu, naudojant pažangią techninę bei programinę įrangą, tačiau neretai pramoninio proceso metu pasitaiko pažeistų, su įvairiais mechaniniais defektais gaminių, netinkančių vartojimui. Netenkinanti kokybės reikalavimų produkcija gali nulemti pardavimų sumažėjimą ir taip sukelti finansinius sunkumus, todėl kokybės kontrolė yra būtina gamybos proceso dalis, norit išvengti nuostolių ar bankroto. Be to, brokuoti produktai gali įspėti ir apie juos gaminančios sistemos gedimus, kurie gali kelti pavojų aplinkai, žmonių gyvybei ir saugumui.

Įvairius gaminių dydžio nukrypimus nesunkiai gali aptikti tam tikros automatizuotos sistemos, bet tokie defektai, kaip antai: paviršiaus nelygumai, skylės, dėmės, įtrūkimai daugiausiai tikrinami žmonių pagalba, o toks būdas yra labai subjektyvus ir nepatikimas. Taigi šio darbo tikslas yra sudaryti ir palyginti metodus defektams tekstūriniuose paviršiuose nustatyti, nes kompiuterizuotas produkcijos testavimo procesas būtų ne tik tikslesnis, bet ir spartesnis bei pigesnis. Tekstūriniuose paviršiuose defektus identifikuoti yra žymiai lengviau negu nereguliuose paviršiuose, todėl sudarytų metodų veikimas pademonstruojamas su betoninių plytelių tekstūriniais paviršių skaitmeniniais vaizdais.

Defektų aptikimo metodika yra glaudžiai susijusi su skaitmeninių vaizdų apdorojimo procedūromis. Dažniausiai tekstūrinių paviršių analizei yra naudojami spektriniai metodai, pagrįsti įvairių diskrečiųjų bangelių transformacijų taikymu, kurios hierarchine tvarka pateikia išsamią informaciją apie skaitmeninio vaizdo struktūrą kiekviename jo filtravimo lygyje. Skaitmeninio vaizdo transformacijos spektras yra sudarytas iš skirtingo dažnio segmentų koeficientų, kurių staigūs svyravimai gali reikšti defektų egzistavimą. Kitas diskrečiųjų bangelių transformacijų pranašumas yra didelis bazinių bangelių funkcijų pasirinkimas, tačiau išsamūs tyrimai parodė, kad defektų aptikimui geriausiai tinka Haaro motininė bangelė. Gaboro filtrais pagrįsti defektų nustatymo algoritmai taip pat plačiai naudojami praktiniuose taikymuose, bet jie pasižymi sudėtingais skaičiavimais. Diskrečiųjų bangelių transformacijų žemo ir aukšto dažnio filtrai yra vienodi visuose skaitmeninio vaizdo filtravimo etapuose, kai tuo tarpu Gaboro filtrai yra kintantys parametrai, kurie reikalauja tarpusavio suderinamumo.

Be spektrinių metodų išskiriami dar du tekstūrinių paviršių analizės būdai: statistiniai ir struktūriniai. Pagrindiniai statistiniai metodai: autokoreliacinė funkcija ar GLCM matrica, nagrinėja erdvinį reikšmių su pilka šviesos intensyvumo skale pasiskirstymą, o struktūrinėje tekstūrinių paviršių

analizėje tekstūra yra apibrėžiama kaip aibė, sudaryta iš pirminių elementų, tekselių, išsidėsčiusių kvaziperiodine tvarka, tačiau šie būdai nėra efektyvesni už diskrečiąsias bangelių transformacijas.

Šiame darbe siūlomi defektų tekstūriniuose paviršiuose nustatymo metodai, paremti diskrečiosios Haaro transformacijos bei empirinės taisyklės taikymu, yra gana greiti, patikimi ir ekonomiškai. Gauti rezultatai yra užtektinai informatyvūs, todėl jais pasinaudojus būtų galima ne tik lokalizuoti defekto vietą, kurioje vaizdas buvo pažeistas, bet galbūt pavyktų nustatyti ir defekto tipą, kas padėtų išsiaiškinti konkrečias jo atsiradimo priežastis.

1. BENDROJI DALIS

1.1. TEKSTŪRINIO PAVIRŠIAUS SĄVOKA IR ANALIZĖ

1.1.1. TEKSTŪROS SAMPRATA

Tekstūra yra įgimta beveik visų natūralių ir dirbtinių paviršių savybė, kuri labai svarbi skaitmeninių vaizdų apdorojime. Vieningo tekstūros apibrėžimo nėra, tačiau, galima sakyti, kad tekstūra apibūdinama remiantis žmogaus regėjimo ir lytėjimo pojūčiais. Tiksliausių tekstūros apibrėžimą, geriausiai atitinkantį žmogaus regėjimo suvokimą, 1978 m. pateikė mokslininkai Tamura, Mori ir Yamawaki: „ Tai, kas sudaro makroskopinę sritį, galima laikyti tekstūra. Jos struktūra priskiriama prie turinčių raštą vaizdų, kurių pirminiai elementai yra išsidėstę pagal tam tikrą tvarką” [19].

Išskiriami trys tekstūrinių paviršių analizės metodai: statistinis, struktūrinis ir spektrinis [10, 13, 19].

1.1.2. STATISTINIAI TEKSTŪRINIŲ PAVIRŠIŲ ANALIZĖS METODAI

Pagrindiniai statistiniai tekstūrinių paviršių analizės metodai yra autokoreliacijos funkcija ir GLCM (Gray-Level Co-occurrence Matrix) matrica.

Skaitmeninio vaizdo autokoreliacijos funkcija gali būti naudojama tekstūros reguliarumui įvertinti arba paviršiaus grublėtumui nustatyti. Pavyzdžiui, jei tekstūros paviršius yra grubus, tai autokoreliacijos funkcija mažės lėtai, o priešingu atveju – sparčiai.

GLCM matrica yra vienas anksčiausių metodų, pradėtų naudoti tekstūriniams paviršiams analizuoti ir klasifikuoti. Iš GLCM normuotos matricos $P(i, j)$, kur i ir j žymi atitinkamai matricos eilutės ir stulpelio numerius, apskaičiuojami keturi pagrindiniai dydžiai: energija, entropija, kontrastas ir homogeniškumas, kurių formulės pateiktos 1.1 lentelėje [4, 8, 14, 19].

1.1 lentelė

Dydžiai, apskaičiuoti iš GLCM matricos $P(i, j)$

Dydis	Formulė
Energija	$\sum_i \sum_j P^2(i, j)$
Entropija	$\sum_i \sum_j P^2(i, j) \log P(i, j)$
Kontrastas	$\sum_i \sum_j (i - j)^2 P(i, j)$
Homogeniškumas	$\sum_i \sum_j \frac{P(i, j)}{1 + i - j }$

1.1.3. STRUKTŪRINIAI TEKSTŪRINIŲ PAVIRŠIŲ ANALIZĖS METODAI

Struktūrinėje tekstūrinių paviršių analizėje tekstūra yra apibrėžiama kaip aibė, sudaryta iš pirminių elementų, tekselių, išsidėsčiusių tam tikra tvarka. Tamura ir kt. išskiria šešis matematinius dydžius, kurie apibūdina nagrinėjamą tekstūrinį paviršių.

Grublėtumas (coarseness). Šis dydis yra pagrindinis tekstūrinių paviršių struktūrinėje analizėje. Grublėtoje tekstūroje tekseliai yra pakankamai dideli ir išsidėstę palyginus toli vienas nuo kito. Priešingu atveju, negrublėtą tekstūrą sudaro daugybė tekselių, esančių arti vienas šalia kito.

Norint įvertinti paviršiaus grublėtumą, pirmiausia būtina apskaičiuoti paveikslą blokų $2^k \times 2^k$ ($k = 0, 1, \dots$) elementų vidurkius. Vidurkis taške (x, y) apskaičiuojamas pagal 1.1. formulę

$$A_k(x, y) = \sum_{i=x-2^{k-1}}^{x+2^{k-1}-1} \sum_{j=y-2^{k-1}}^{y+2^{k-1}-1} \frac{f(i, j)}{2^{2k}}, \quad (1.1)$$

čia $f(i, j)$ yra pilkos šviesos intensyvumo reikšmė taške (x, y) .

Tuomet kiekvienam taškui yra skaičiuojami skirtumai tarp dviejų nepersidengiančių vidurkių, esančių priešingose to taško pusėse, horizontalia ir vertikalia kryptimis, kaip parodyta 1.2 formulėje.

$$E_{k,h}(x, y) = |A_k(x + 2^{k-1}, y) - A_k(x - 2^{k-1}, y)|, \quad (1.2)$$

$$E_{k,v}(x, y) = |A_k(x, y + 2^{k-1}) - A_k(x, y - 2^{k-1})|.$$

Kiekvienam pikseliui parenkama tokia k reikšmė, kuri maksimizuoja E abiejomis kryptimis, tam kad būtų gaunama didžiausia S_{best} reikšmė

$$S_{best}(x, y) = 2^k. \quad (1.3)$$

Galiausiai grublėtumo reikšmė F_{crs} yra apskaičiuojama pagal 1.4 formulę

$$F_{crs} = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n S_{best}(i, j), \quad (1.4)$$

čia m ir n yra nagrinėjamo paveikslą matmenys.

Kontrastingumas (contrast). Šis dydis parodo pilkos šviesos intensyvumo skirtumą tarp greta esančių pikselių. Aukšto kontrasto tekstūrinių paviršių intensyvumo skirtumai tarp kaimyninių pikselių yra didesni nei žemo kontrasto paviršiuose.

Išskiriami keturi faktoriai, nuo kurių priklauso tekstūros kontrastingumas:

1. Pilkos šviesos intensyvumo skalės reikšmė.
2. Juodos ir baltos spalvų pasiskirstymas pilkos šviesos intensyvumo histogramoje.
3. Objektų briaunų ryškumas paveiksle. Pavyzdžiui, susilieusių paveikslų kontrastingumas yra mažesnis.
4. Pasikartojančių objektų periodiškumas. Pavyzdžiui, jei turime du paveikslus, sudarytus iš juodų ir baltų kvadratų, tai kontrastingumas bus didesnis to, kurio tie kvadratai yra didesni.

Kontrastingumas F_{con} apskaičiuojamas pagal 1.5 formulę

$$F_{con} = \frac{\sigma}{\left(\sqrt[4]{\frac{\mu_4}{\sigma^4}} \right)}, \quad (1.5)$$

čia σ yra standartinis nuokrypis, μ_4 yra ketvirtasis pradinis momentas.

Kryptingumas (directionality). Šis dydis parodo tekstūros elementų išsidėstymą, formą. Tekseliai gali neturėti arba turėti vieną ar daugiau krypčių. Kryptingumas F_{dir} apskaičiuojamas pagal 1.6 formulę

$$F_{dir} = 1 - r n_p \sum_p \sum_{\phi \in W_p} (\phi - \phi_p)^2 H_D(\phi), \quad (1.6)$$

čia H_D yra lokalios krypties histograma, n_p - viršūnių skaičius histogramoje H_D , ϕ_p yra p - osios viršūnės pozicija, r yra normalizavimo faktorius.

Linijiškumas (line - likeness). Šis dydis parodo tik tekstūros elementų formą. Tekstūra, pasižyminti šia savybe, gali turėti tiesias arba banguotas linijas, kurių kryptis nėra fiksuota, tačiau dažnai tekstūros linijos yra kryptingos. Linijiškumą F_{lin} galima apskaičiuoti pagal 1.7 formulę

$$F_{lin} = \frac{\sum_i^m \sum_j^n P_{Da}(i, j) \cos \left[(i - j) \frac{2\pi}{N} \right]}{\sum_i^m \sum_j^n P_{Da}(i, j)}. \quad (1.7)$$

Reguliarumas (regularity). Reguliarūs tekstūriniai paviršiai (tapetai, audiniai) yra sudaryti iš vienodų ar panašių tekstūros elementų, kurie yra reguliariai arba beveik reguliariai išsidėstę. Nereguliarių tekstūrinių paviršių (žolės, debesų) elementai yra išsidėstę nereguliariai, atsitiktinai.

Reguliarumas F_{reg} apskaičiuojamas pagal 1.8 formulę

$$F_{reg} = 1 - r(\sigma_{crs} + \sigma_{con} + \sigma_{dir} + \sigma_{lin}), \quad (1.8)$$

čia r yra normavimo faktorius, σ - standartinis kiekvieno dydžio F nuokrypis.

Nelygumas (roughness). Šis dydis yra naudojamas tik apčiuopiamų fizinių paviršių atveju. Nelygūs paviršiai sudaryti iš kampuotų tekstūros elementų, o lygų – apvalaini. Nelygumas F_{rgh} apskaičiuojamas pagal 1.9 formulę

$$F_{rgh} = F_{crs} + F_{con}. \quad (1.9)$$

Apskaičiavus šiuos šešis dydžius tiriamam paveikslui, tikrinama, į kurį iš penkių galimų intervalų patenka gautos reikšmės. Kiekvieną intervalą atitinka kalbinis terminas. Tokiu būdu lengviau nusakyti tekstūrinį paviršių, negu turint tik skaitines dydžių reikšmes. Pavyzdžiui, grublėtumas gali būti apibūdinamas nuo labai negrublėto iki labai grublėto. Visi kalbiniai terminai, atitinkantys Tamuros ir kt. pateiktus dydžius, parodyti 1.2 lentelėje [1, 10, 19].

1.2 lentelė

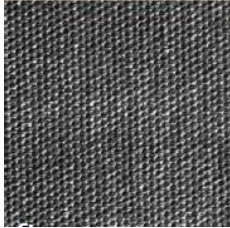
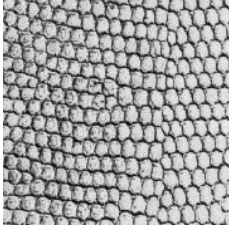
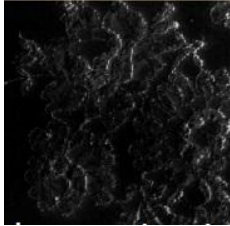



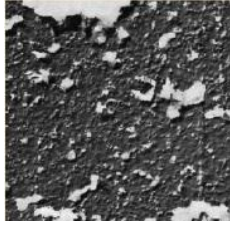
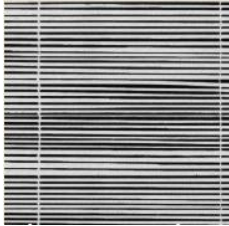

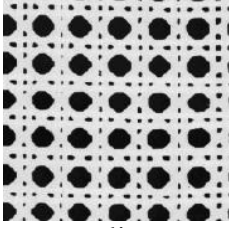
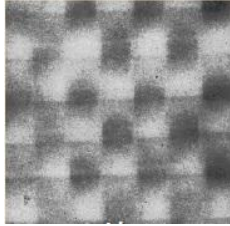
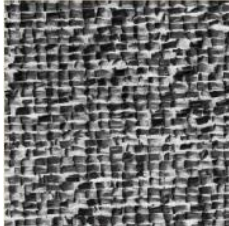
Kalbiniai terminai, įvertinantys Tamuros ir kt. dydžius

Dydis	Kalbinis terminas				
Grublėtumas	labai negrublėtas	negrublėtas	vidutinis grublėtumas	grublėtas	labai grublėtas
Kontrastingumas	labai žemas kontrastingumas	žemas kontrastingumas	vidutinis kontrastingumas	aukštas kontrastingumas	labai aukštas kontrastingumas
Kryptingumas	labai nekryptingas	nekryptingas	vidutiniškai kryptingas	kryptingas	labai kryptingas
Linijos	nėra linijų	neaiškios linijos	vidutiniškai aiškios linijos	linijos	labai ryškios linijos
Reguliarumas	labai nereguliarus	nereguliarus	vidutinio reguliarmo	reguliarus	labai reguliarus
Nelygumas	labai nelygus	nelygus	vidutinio lygumo	lygus	labai lygus

Tekstūrinių paviršių savybės ir jas geriausiai atspindintys pavyzdžiai pateikti 1.3 lentelėje.

1.3 lentelė

Tekstūrinių paviršių pavyzdžiai ir jų savybės

Grublėtumas	 negrublėtas	 grublėtas
Kontrastingumas	 žemas kontrastingumas	 aukštas kontrastingumas
Kryptingumas	 nekryptingas	 kryptingas
Linijiškumas	 nėra linijų	 linijos
Reguliarumas	 nereguliarus	 reguliarus
Nelygumas	 lygus	 nelygus

1.1.4. SPEKTRINIAI TEKSTŪRINIŲ PAVIRŠIŲ ANALIZĖS METODAI

Spektriniai analizės metodai dar kitaip vadinami transformacijos metodais. Taikant šiuos metodus, tekstūriniai paviršiai nagrinėjami kaip transformacijos spektrinių koeficientų aibė.

Pagrindinė tekstūrinių paviršių spektrinių analizės metodų esmė yra Furje, Gaboro filtrų arba diskrečiųjų bangelių transformacijų taikymas. Bangelių transformacijos yra pranašiausios, lyginant su kitais metodais, nes iš didelio bangelių funkcijų pasirinkimo galima išsirinkti tą, kuri duoda geriausius tekstūrinių paviršių analizės rezultatus.

Šiame darbe tekstūrinių paviršių analizei ir defektų nustatymui naudojama viena iš diskrečiųjų bangelių transformacijų, kurios detaliau aprašomos 1.2 skyrelyje [5, 13, 19].

1.2. DISKREČIOSIOS BANGELIŲ TRANSFORMACIJOS (DBT) IR JŲ TAIKYMAI

1.2.1. BENDROSIOS BANGELIŲ SAVYBĖS IR DBT APSKAIČIAVIMO ALGORITMAI

Bangeles generuoja motininė bangelė ψ , kuri priklauso baigtinės energijos funkcijų erdvei $L_2(\mathbb{R})$ ir turi tenkinti 1.10 sąlygą

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0. \quad (1.10)$$

Kiekvienai motininei bangelei ψ galima apibrėžti funkcijų šeimą $\psi_{j,k}$, kuri laikoma ortogonalia baze erdvėje $L_2(\mathbb{R})$

$$\psi_{j,k}(t) = \text{const} \cdot \psi(2^j t - k), \quad (1.11)$$

čia $j, k \in \mathbb{Z}$.

Konstanta, su kuria ortogonalioji bazė tampa ortonormuota, lygi $2^{-\frac{j}{2}}$. Taigi bet kuri erdvės $L_2(\mathbb{R})$ elementą $f \in L_2(\mathbb{R})$ galima išreikšti šių bazinių funkcijų tiesiniu dariniu:

$$f = \langle f, \psi_{j,k} \rangle_{j,k \in \mathbb{Z}} \cdot \psi_{j,k}, \quad (1.12)$$

čia $f, \psi_{j,k}$ žymi f ir $\psi_{j,k}$ skaliarinę sandaugą. Aibė $\{\psi_{j,k}, j \in \mathbb{Z}, k \in \mathbb{Z}\}$ yra ortonormuota bazė erdvėje $L_2(\mathbb{R})$.

Tolydžioji bangelių transformacija funkcijai $f \in L_2(\mathbb{R})$ apibrėžiama 1.13 lygybe

$$x_{j,k}(f) = \langle f, \psi_{j,k} \rangle = \int \psi_{j,k}(t) f(t) dt. \quad (1.13)$$

Transformacijai įvedama funkcija 1.14, kuri taip pat generuoja bazinių funkcijų aibę, ir vadinama mastelio funkcija

$$\phi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - k). \quad (1.14)$$

Mastelio funkcija $\phi_{j,k}$ yra ortonormuota ir turi tenkinti 1.15 sąlygą

$$\int_{-\infty}^{+\infty} \phi_{j,k}(t) dt = 1. \quad (1.15)$$

Iteracijos j metu funkcijos f ir mastelio funkcijos $\phi_{j,k}$ skaliarinė sandauga duoda apytikslus tiriamo vaizdo koeficientus x_A :

$$x_{A,j,k}(f) = \langle \phi_{j,k}, f \rangle = \int \phi_{j,k}(t) f(t) dt. \quad (1.16)$$

Tarp motininės bangelės ir mastelio funkcijos egzistuoja sąryšis, vadinamas bangelės lygtimi

$$\psi(t) = \sqrt{2} \sum_k g(k) \phi(2t - k). \quad (1.17)$$

Mastelio funkcija taip pat tenkina 1.18 lygtį

$$\phi(t) = \sqrt{2} \sum_k h(k) \phi(2t - k). \quad (1.18)$$

Koeficientai $g(k)$ ir $h(k)$ turi būti parinkti taip, kad tenkintų bangelės **1.10** ir **1.15** sąlygas.

Diskrečiajai funkcijai f gali būti taikoma diskrečioji bangelių transformacija, taikant greitojo skaičiavimo algoritmo 1.18 formules


$$\begin{aligned} x_{j,k}(f) &= \sum_n g_{2k-n} x_{A,j-1,k}(f), \\ x_{A,j,k}(f) &= \sum_n h_{2k-n} x_{A,j-1,k}(f). \end{aligned} \quad (1.18)$$

Žemo ir aukšto dažnio filtrai, atitinkamai, $H(\omega)$ ir $G(\omega)$ yra susiję su $g(k)$ ir $h(k)$ 1.19 sąryšiais [2, 7, 12, 16].

$$H(\omega) = \frac{1}{\sqrt{2}} \sum_k h(k) e^{-j\omega k},$$

$$G(\omega) = \frac{1}{\sqrt{2}} \sum_k g(k) e^{-j\omega k}.$$
(1.19)

Diskrečioji bangelių transformacija gali būti suprantama kaip skaitmeninio vaizdo filtravimas žemo ir aukšto dažnio filtrais, atitinkamai H ir G. Kadangi vaizdas yra dvimatis signalas, tai DBT taikoma horizontalia u ir vertikalia v kryptimis, kaip parodyta 1.1 paveiksle. Po pirmo filtravimo gautą spektrą sudaro keturi skirtingo dažnio segmentai: $X_{A,1}$, $X_{V,1}$, $X_{H,1}$ ir $X_{D,1}$, kurių išsidėstymas pavaizduotas paveikslo 1.2 a) dalyje. Segmentą $X_{A,1}$ sudaro žemiausio dažnio spektro koeficientai, o $X_{D,1}$ - aukščiausio. Segmento $X_{H,1}$ koeficientai gaunami filtruojant vaizdą pirmiausia aukšto dažnio filtru horizontalia kryptimi, o po to žemo dažnio filtru vertikalia kryptimi. Sukeitus filtrus vietomis gaunami $X_{V,1}$ koeficientai. Žemiausio dažnio segmentas $X_{A,1}$ yra pradinio vaizdo aproksimacija ir vadinamas glodžiuoju vaizdu. Pašalinus būtent šio segmento spektrinius koeficientus, pradinis vaizdas išsikraipytų labiausiai. Likę trys segmentai atitinka pradinio vaizdo horizontalią ($X_{H,1}$), vertikalią ($X_{V,1}$) ir diagonalią ($X_{D,1}$) kryptis. Pastarojo segmento spektrinius koeficientai daro mažiausią įtaką pradinio vaizdo iškreipimui [6, 7, 9, 11, 15].



1.1 pav. Diskrečiosios bangelių transformacijos schema

Antro filtravimo metu segmentas $X_{A,1}$ vėl skaidomas į keturias dalis: $X_{A,2}$, $X_{V,2}$, $X_{H,2}$, $X_{D,2}$, trečio filtravimo metu $X_{A,2}$ skaidomas į $X_{A,3}$, $X_{V,3}$, $X_{H,3}$, $X_{D,3}$ ir t.t. Jei skaitmeninio vaizdo matmenys yra $N \times N$, tai filtravimo procedūros iteracijų skaičius lygus $n = \log_2 N$. Paveikslo 1.2 b) dalis parodo spektro struktūrą po pilno filtravimo.

$X_{A,1}$	$X_{H,1}$
$X_{V,1}$	$X_{D,1}$


a) DBT spektras po pirmo filtravimo

$X_{V,3}$	$X_{D,3}$	$X_{H,2}$	$X_{H,1}$
$X_{V,2}$	$X_{D,2}$		
$X_{V,1}$	$X_{D,1}$		

b) DBT spektras po pilno filtravimo

1.2 pav. a), b) DBT spektrinių koeficientų segmentai

Skaitmeninis vaizdas ir jo DBT spektras pateikti 1.3 paveiksle. Transformacijos vaizde nesunkiai galima išvelgti pasikartojančius horizontalia ir vertikalia kryptimis ištemptus pradinio vaizdo kontūrus, todėl akivaizdu, kad po filtravimo išsaugoma lokaloji pirminio vaizdo informacija.



1.3 pav. Skaitmeninis vaizdas ir jo DBT transformacija

1.2.2. PRAKTINIO DBT PANAUDOJIMO SRIČIŲ APŽVALGA

Diskrečiosios bangelių transformacijos plačiai naudojamos vienmačių signalų analizėje, pavyzdžiui, triukšmams pašalinti kalbos bei audio signaluose, arba jų suspaudimo algoritmuose, siekiant sumažinti perdavimo laiką. Be to, DTB taikomos ne tik vienmačių, bet ir dvimačių signalų: vaizdų bei video, kompresijai. Viena svarbiausių DBT panaudojimo sričių yra dvimačių vaizdų suglaudavimo standartas JPEG 2000, kuris yra pranašesnis už JPEG metodą, paremtą diskrečiosios kosinusinės transformacijos (DCT) taikymu. Dvimatis skaitmeninis vaizdas, naudojant JPEG standartą, yra skaidomas į 8×8 dydžio blokelius, kurie apdorojami individualiai vienas po kito, nekreipiant dėmesio į šalia esančius blokus, todėl, esant dideliame suspaudimo laipsniui, atkūrus vaizdą išryškėja blokinė struktūra. Priešingai nei JPEG, bangelėmis grįstas suspaudimo metodas JPEG 2000 vaizdą konvertuoja į eilę bangelių, kurios gali būti saugomos efektyviau negu pikselių blokai. JPEG 2000 naudoja Daubechies 5/3 bangeles tiksliam suspaudimui arba Daubechies 9/7 bangeles apytiksliam suspaudimui. Video suspaudimo procedūra yra analogiška kaip ir dvimačių skaitmeninių vaizdų, tačiau įvedama nauja dimensija, būtent laikas.

Įvairios saugumo ir tyrimo tarnybos, pavyzdžiui, FBI (Federal Bureau of Investigation), DBT naudoja elektroniniam pirštų antspaudų saugojimui. Ilgą laiką FBI pirštų antspaudus laikydavo tiesiog popieriaus lape, kurie buvo saugomi pagrindiniame Vašingtono tyrimų biure. Pirštų antspaudų buvo prikaupta tiek, kad patalpa, kurioje jie buvo laikomi, savo dydžiu prilygo futbolo aikštei. Jei kuriai nors tarnybai prireikdavo pirštų antspaudų palyginimui, tai jie būdavo siunčiami paštu, kas užtrukdavo gana ilgai, todėl buvo pradėta ieškoti būdų, kaip pagreitinti informacijos paiešką ir perdavimą. Be to, šiuo metu FBI turi sukaupę apie 30 milijonų pirštų antspaudų paketų (paketus sudaro dar po 10 pirštų antspaudų) ir kiekvieną dieną dar papildo apie 30000. Tokiam dideliame kiekiui informacijos reikia labai daug vietos, tad tokiu atveju būtinas duomenų suspaudimas. Tam tikslui buvo sukurtas vaizdų suglaudavimo algoritmas WSQ (The Wavelet Scalar Quantization Gray-scale Fingerprint Image Compression Algorithm), pagrįstas Daubechies biortogonalios splaino bangelės taikymu. Pirštų antspaudų verifikavimas yra vienas patikimiausių asmens identifikavimo metodų. Rankinis pirštų antspaudų patikrinimas yra varginantis, brangus ir ilgas procesas, todėl buvo sukurta automatizuota pirštų antspaudų identifikavimo sistema (AFIS), pagrįsta taip pat DBT taikymu.

Diskrečiosios bangelių transformacijos taikomos tekstūroms klasifikuoti ir analizuoti, kraštų aptikimo algoritmuose, paprastosioms bei dalinių išvestinių diferencialinėms lygtims spręsti. Be to,

ortonormuotos bangelės sėkmingai naudojami atmosferos sluoksnio turbulencijoms, jūros dugno batimetriniams, topografiniams matavimams ar įvairiems geofiziniams reiškiniams tirti.

Diskrečių bangelių taikymai labai reikšmingi medicinoje, biologijoje ir netgi ekonomikoje [16, 17].

1.2.3. DISKREČIOJI HAARO TRANSFORMACIJA

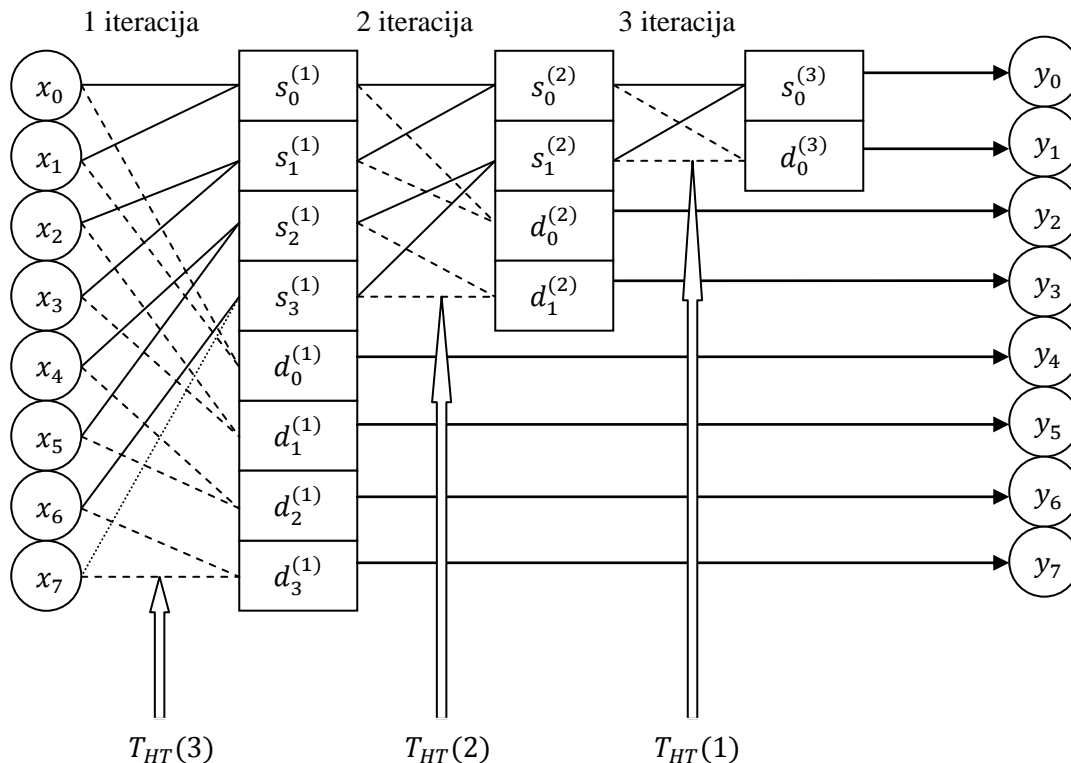
Vienmačiu atveju kiekvienos diskrečiosios bangelių transformacijos iteracijos metu skaitmeniniam signalui yra taikoma mastelio funkcija. Jei signalas $X = (x_0 \ x_1 \ x_2 \ \dots \ x_{N-1})^T$ sudarytas iš N ($N = 2^n, n \in \mathbb{N}$) elementų, pritaikius mastelio funkciją, po pirmos DBT iteracijos gaunamos $\frac{N}{2}$ suvidurkintos (suglodintos) reikšmės $s_0^{(1)}, s_1^{(1)}, s_2^{(1)}, \dots, s_{2^{n-1}-1}^{(1)}$. Sutvarkytoje bangelių transformacijoje šios reikšmės yra išsidėsčiusios viršutinėje vektoriaus, sudaryto iš N elementų, pusėje. Be to, tam pačiam skaitmeniniam signalui X taikoma bangelės funkcija skirtumams $d_0^{(1)}, d_1^{(1)}, d_2^{(1)}, \dots, d_{2^{n-1}-1}^{(1)}$ apskaičiuoti. Šios skirtuminės reikšmės yra išsidėsčiusios apatinėje vektoriaus pusėje. Sekančioje iteracijoje mastelio ir bangelės funkcijos taikomos sutvarkytai suglodintų reikšmių, kurios buvo gautos pirmoje iteracijoje, aibe. Po baigtinio skaičiaus žingsnių n gaunamas skaitmeninio signalo X DBT spektras $Y = (y_0 \ y_1 \ y_2 \ \dots \ y_{N-1})^T$, sudarytas iš vienos glodžiosios reikšmės, kuri gaunama paskutiniosios iteracijos metu, ir skirtuminių reikšmių [18].

Atvirkštinės DBT atveju visi minėti žingsniai atliekami priešinga tvarka.

Tegu $S^{(i)} = (s_0^{(i)} \ s_1^{(i)} \ s_2^{(i)} \ \dots \ s_{2^{n-i}-1}^{(i)})^T$ ir $D^{(i)} = (d_0^{(i)} \ d_1^{(i)} \ d_2^{(i)} \ \dots \ d_{2^{n-i}-1}^{(i)})^T$ yra DBT mastelio ir bangelės funkcijų taikymo pradiniam arba tarpiniam vektoriui $S^{(i-1)}$ ($i \in \{1, 2, \dots, n\}$) rezultatas. Akivaizdu, kad $S^{(0)} = X = (x_0 \ x_1 \ x_2 \ \dots \ x_{N-1})^T$, t.y. $s_k^{(0)} = x_k$ ($k = 0, 1, \dots, N-1$). Tuomet duomenų vektoriaus X diskretusis DBT spektras Y yra lygus

$$Y = \left(s_0^{(n)} \ d_0^{(n)} \ d_0^{(n-1)} \ d_1^{(n-1)} \ d_0^{(n-2)} \ d_1^{(n-2)} \ d_2^{(n-2)} \ d_3^{(n-2)} \ d_0^{(n-3)} \ \dots \ d_0^{(1)} \ d_1^{(1)} \ \dots \ d_{\frac{N}{2}-1}^{(1)} \right)^T.$$

Vienmačio skaitmeninio signalo $X = (x_0 \ x_1 \ x_2 \ \dots \ x_7)^T$, kai $N = 8$, diskrečiosios bangelių transformacijos spektro $Y = (y_0 \ y_1 \ y_2 \ \dots \ y_7)^T$ apskaičiavimo struktūra pateikta 1.4 paveiksle.



1.4 pav. Greito HT apskaičiavimo algoritmo schema

Teoriškai, i – oji ($i \in \{1, 2, \dots, n\}$) iteracija gali būti realizuojama, naudojant DBT $(n - i + 1)$ eilės DBT matricą T_{DBT}

$$\begin{pmatrix} S^{(i)} \\ D^{(i)} \end{pmatrix} = T_{DBT}(n - i + 1)S^{(i-1)}, \quad (1.20)$$

laikydami, kad $S^{(n)} = \begin{pmatrix} s_0^{(n)} \end{pmatrix}$ ir $D^{(n)} = \begin{pmatrix} d_0^{(n)} \end{pmatrix}$.

Matricos $T_{DBT} = T_{DBT}(n - i + 1)$, ($i \in \{1, 2, \dots, n\}$), iš esmės priklauso nuo mastelio ir bangelės funkcijų koeficientų reikšmių pagrindinėje 1.20 DBT išraiškoje [18].

Haaro transformacijos mastelio funkcijos koeficientai yra $h_0 = \frac{1}{\sqrt{2}}$ ir $h_1 = \frac{1}{\sqrt{2}}$, o bangelės funkcijos koeficientų reikšmės yra $g_0 = h_0 = \frac{1}{\sqrt{2}}$ ir $g_1 = -h_0 = -\frac{1}{\sqrt{2}}$. Taigi HT matricos atrodytų taip

$$T_{HT}(1) = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}, \quad (1.21)$$

$$T_{HT}(2) = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & -1 \end{pmatrix}, \quad (1.22)$$

$$T_{HT}(3) = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \\ 1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 \end{pmatrix} \quad (1.23)$$

ir t.t.

Be to, galioja 1.24 lygybė

$$\hat{T}_{HT}(n) = \prod_{i=1}^n T_{HT_i}(n). \quad (1.24)$$

Pavyzdžiui, $\hat{T}_{HT}(2)$ matrica gaunama taip:

$$\hat{T}_{HT}(2) = T_{HT_1}(n) \cdot T_{HT_2}(n) = \begin{pmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 & 0 \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} & 1 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 & 0 \\ 0 & 0 & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} & 0 & 0 \\ 0 & 0 & \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \end{pmatrix}. \quad (1.25)$$

Tuomet N – mačio duomenų vektoriaus $X = (x_0 \ x_1 \ x_2 \ \dots \ x_{N-1})^T$ diskrečioji HT transformacija gali būti apibrėžiama ir 1.26 formule

$$Y = (y_0 \ y_1 \ y_2 \ \dots \ y_{N-1})^T = \hat{T}_{HT}(n) \cdot X. \quad (1.26)$$

Matrica $\hat{T}_{HT}(n)$, kurios matmenys $N \times N$, gaunama, diskretizuojant Haaro funkcijų $h_k(t)$ ($k = 0, 1, \dots, N-1$), apibrėžtų intervale $0 \leq t < 1$, aibę. Su tam tikra k reikšme funkcijos $h_k(t)$ forma priklauso nuo dviejų parametru: r ir m :

$$k = 2^r + m - 1. \quad (1.27)$$

Pavyzdžiui, kai $N = 16$, tuomet indeksas k su atitinkamais parametrais r ir m pateikti 1.4 lentelėje.

1.4 lentelė

Parametų k , r ir m reikšmės

k	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
r	0	0	1	1	2	2	2	2	3	3	3	3	3	3	3	3
m	0	1	1	2	1	2	3	4	1	2	3	4	5	6	7	8

Su visais $r = 0, 1, \dots, \log_2 N - 1$ ir $m = 1, 2, \dots, 2^r$ gauname, kad kai $k = 0$, tai

$h_0(t) = \frac{1}{\sqrt{N}}$, o kai $k > 0$, tada $h_k(t)$ apskaičiuojama pagal 1.28 formulę.

$$h_k(t) = \frac{1}{\sqrt{N}} \begin{cases} 2^{\frac{r}{2}}, & \frac{m-1}{2^r} \leq t < \frac{m-0,5}{2^r}, \\ -2^{\frac{r}{2}}, & \frac{m-0,5}{2^r} \leq t < \frac{m}{2^r}, \\ 0, & \text{kitu atveju.} \end{cases} \quad (1.28)$$


HT matricos gautos, diskretizuojant $h_k(t)$ funkcijų sistemą (žr. 1.5 pav.), atrodytų taip

$$\hat{T}_{HT}(1) = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}, \quad (1.29)$$

$$\hat{T}_{HT}(2) = \frac{1}{2} \begin{pmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & -1 & -1 \\ \sqrt{2} & -\sqrt{2} & 0 & 0 \\ 0 & 0 & \sqrt{2} & \sqrt{2} \end{pmatrix}, \quad (1.30)$$

$$\hat{T}_{HT}(3) = \frac{1}{2\sqrt{2}} \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & -1 & -1 & -1 & -1 \\ \sqrt{2} & \sqrt{2} & -\sqrt{2} & -\sqrt{2} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \sqrt{2} & \sqrt{2} & -\sqrt{2} & -\sqrt{2} \\ 2 & -2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 2 & -2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 2 & -2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 2 & -2 \end{pmatrix} \quad (1.31)$$

ir t.t.



1.5 pav. Haaro funkcijų sistema

Atvirkštinė diskrečioji Haaro transformacija (AHT) nusakoma 1.32 lygybe

$$X = \hat{T}_{HT}(n) \cdot Y. \quad (1.32)$$

Dvimačių HT ir AHT išraiškos atrodytų taip:

$$\begin{aligned} [Y(k_1, k_2)] &= \hat{T}_{HT}(n_1)[X(m_1, m_2)]\hat{T}_{HT}^T(n_2), \\ [X(m_1, m_2)] &= \hat{T}_{HT}^T(n_1)[Y(k_1, k_2)]\hat{T}_{HT}(n_2), \end{aligned} \quad (1.33)$$

čia $[X(m_1, m_2)]$ yra dvimatis duomenų masyvas ($k_i, m_i = 0, 1, \dots, N_i - 1$; $n_i = \log_2 N_i$; $i = 1, 2$).

Praktiniuose skaičiavimuose vektoriaus X , kurio dydis $N = 2^n$ ($n \in \mathbb{N}$) HT spektrui Y gauti naudojamos 1.34 formulės

$$\begin{aligned} s_k^{(i)} &= h_0 s_{2k}^{(i-1)} + h_1 s_{2k+1}^{(i-1)} = \frac{1}{\sqrt{2}} (s_{2k}^{(i-1)} + s_{2k+1}^{(i-1)}), \\ d_k^{(i)} &= g_0 s_{2k}^{(i-1)} + g_1 s_{2k+1}^{(i-1)} = \frac{1}{\sqrt{2}} (s_{2k}^{(i-1)} - s_{2k+1}^{(i-1)}), \end{aligned} \quad (1.34)$$

su visais $k = 0, 1, 2, \dots, 2^{n-i} - 1$ ir $i \in \{1, 2, \dots, n\}$.

Dvimačiu atveju skaitmeninio vaizdo X , kurio matmenys $N_1 \times N_2$ ($N_i = 2^{n_i}$, $n_i \in \mathbb{N}$, $i = 1, 2$), DBT spektras gaunamas vienmatę HT pritaikius $N_1 + N_2$ kartų [17, 18].

2. METODOLOGINĖ DALIS

2.1. DEFEKTŲ NUSTATYMO IR LOKALIZAVIMO (DNL)

TEKSTŪRINIUIOSE PAVIRŠIUOSE PROBLEMA

2.1.1. SKAITMENINIO VAIZDO KOKYBĖS KRITERIJAUS FORMAVIMAS

Defektų nustatymo problemą iš esmės galima apibrėžti kaip vaizdų klasifikavimo uždavinį. Tegu V yra visų tos pačios objektų klasės tekstūrinių vaizdų aibė. Išskirkime šios aibės poaibį $V_1 \subset V$, kurį vadinsime kokybiškų vaizdų aibe, ir jo papildinį $V_2 = V \setminus V_1$, kurį vadinsime defektuotų vaizdų aibe.

Tekstūrinio vaizdo kokybės kriterijus formuojamas, panaudojant tam tikrą kokybiškų vaizdų aibės V_1 poaibį $V_1^{(krit)} = \{X_1, X_2, \dots, X_r\}$, sudarytą iš r tekstūrinių paviršių vaizdų.

Eksperimento metu testuojama vaizdų aibė $V' = V'_1 \cup V'_2$, kur $V'_1 \subset V_1$, $V'_2 \subset V_2$, ir $V'_1 \neq \emptyset$,

$V'_2 \neq \emptyset$. Tegu $X \in V'$ – testuojamas vaizdas pagal suformuotą kokybės kriterijų. Galimi atvejai:

- $X \in V'_1$ ir X tenkina kokybės kriterijų, t.y. kokybiškas vaizdas pripažįstamas kokybišku.
- $X \in V'_1$ ir X netenkina kokybės kriterijaus, t.y. kokybiškas vaizdas pripažįstamas nekokybišku.
- $X \in V'_2$ ir X tenkina kokybės kriterijų, t.y. nekokybiškas vaizdas pripažįstamas kokybišku.
- $X \in V'_2$ ir X netenkina kokybės kriterijų, t.y. nekokybiškas vaizdas pripažįstamas nekokybišku.


Formuojant kokybės kriterijų, kiekvienam kokybiškų vaizdų aibės V_1 poaibio $V_1^{(krit)}$ elementui X_i ($i \in \{1, 2, \dots, r\}$) apskaičiuojamas jo diskretusis Haaro transformacijos spektras, kuriame išskiriamos diagonaliosios krypties spektrinių koeficientų segmentai $X_{D,j}$ ($j \in \{1, 2, \dots, \log_2 N\}$), jei tarsime, kad kiekvieno vaizdo matmenys $N \times N$. Tada galima apskaičiuoti energiją, tenkančią kiekvienam segmentui, paimdami kiekvieno segmento elementų vidurkį, t.y.

$$m_{i,j} = \frac{1}{2^{2(n-j)}} \sum_{(k_1, k_2) \in X_{D,j}} Y_i(k_1, k_2). \quad (2.1)$$

Kadangi šie vidurkiai $m_{i,j}$ visuose segmentuose $X_{D,j}$ ($j \in \{1, 2, \dots, \log_2 N + 1\}$) turi normalųjį skirstinį, t.y. $m_{i,1} \sim N(\mu_1, \sigma_1^2)$, $m_{i,2} \sim N(\mu_2, \sigma_2^2)$ ir t.t., todėl galima pritaikyti empirinę taisyklę. Ši taisyklė


teigia, kad jei duomenų histograma yra varpo formos, tai apytiksliai 68,27 % visų duomenų patenka į intervalą $(\mu - \sigma, \mu + \sigma)$, apytiksliai 95,45 % visų duomenų patenka į intervalą $(\mu - 2\sigma, \mu + 2\sigma)$ ir beveik visi duomenys (99,73 %) patenka į intervalą $(\mu - 3\sigma, \mu + 3\sigma)$ [3]. Empirinę taisyklę iliustruoja 2.1 paveikslas. Tada iš atitinkamų imčių suskaičiuojami parametrai μ_j, σ_j^2 ($j \in \{1, 2, \dots, \log_2 N + 1\}$) įverčiai $\hat{\mu}_j$ ir $\hat{\sigma}_j^2$ ir suformuojami prognozės intervalai, kurie ir sudaro kokybės kriterijų

$$K^{(1)} = \left((\hat{\mu}_1 - t\hat{\sigma}_1^2), (\hat{\mu}_2 - t\hat{\sigma}_2^2), (\hat{\mu}_3 - t\hat{\sigma}_3^2), \dots, (\hat{\mu}_{\log_2 N + 1} - t\hat{\sigma}_{\log_2 N + 1}^2) \right). \quad (2.2)$$




2.1 pav. Empirinė taisyklė


Defektų aptikimui tekstūriniuose paviršiuose gali būti naudojami ir kiti segmentai. 2.2, 2.3, 2.4 ir 2.5 paveiksluose pavaizduoti tekstūrinio paviršiaus vaizdo be defektų HT spektro segmentų $X_{A,1}, X_{V,1}, X_{H,1}$ ir $X_{D,1}$ koeficientai ir tekstūrinio paviršiaus vaizdo su defektais HT spektro segmentų $X_{A,1}^*, X_{V,1}^*, X_{H,1}^*$ ir $X_{D,1}^*$ koeficientai po pirmo filtravimo. Iš segmentų $X_{A,1}$ ir $X_{A,1}^*$ koeficientų defekto aptikti negalima, nes koeficientai išsidėstę gana chaotiškai. Kokybiško vaizdo spektre $X_{V,1}, X_{H,1}$ ir $X_{D,1}$ segmentų koeficientai pasiskirstę maždaug vienodai, tačiau tuose pačiuose vaizdo su defektais segmentuose $X_{V,1}^*, X_{H,1}^*$ ir $X_{D,1}^*$ atsiranda smarkiai išsiskiriančių spektrinių koeficientų reikšmių, kurios gali padėti nustatyti defektus tekstūriniuose paviršiuose [7]. Šiuo atveju daugiausiai išsiskiriančių spektrinių koeficientų yra $X_{H,1}^*$ segmente (žr. 2.3 pav.), tačiau, paėmus kitą brokuotą vaizdą, daugiausiai tokių koeficientų gali būti tiek $X_{V,1}^*$, tiek $X_{D,1}^*$ segmente.




2.2 pav. HT spektro segmentų $X_{A,1}$ ir $X_{A,1}^*$ koeficientai kokybiškame ir brokuotame vaizde



2.3 pav. HT spektro segmentų $X_{H,1}$ ir $X_{H,1}^*$ koeficientai kokybiškame ir brokuotame vaizde



2.4 pav. HT spektro segmentų $X_{V,1}$ ir $X_{V,1}^*$ koeficientai kokybiškame ir brokuotame vaizde



2.5 pav. HT spektro segmentų $X_{D,1}$ ir $X_{D,1}^*$ koeficientai kokybiškame ir brokuotame vaizde

Taigi įvairūs tekstūrinių paviršių defektai gali sukelti koeficientų padidėjimą bent viename iš segmentų $X_{D,1}^*$, $X_{V,1}^*$ arba $X_{H,1}^*$, tačiau pastarųjų dviejų segmentų koeficientai nėra pasiskirstę pagal normalųjį skirstinį, todėl empirinė taisyklė jiems negalios. Įvairiems trūkumams tekstūriniuose paviršiuose aptikti galima apskaičiuoti skirtumus:

$$RDH = \frac{\max|X_H^*| - \max|X_H|}{\max|X_H|}, \quad (2.3)$$

$$RDV = \frac{\max|X_V^*| - \max|X_V|}{\max|X_V|}, \quad (2.4)$$

$$RDD = \frac{\max|X_D^*| - \max|X_D|}{\max|X_D|}, \quad (2.5)$$

čia $X_{V,1}$, $X_{H,1}$ ir $X_{D,1}$ yra etaloninio vaizdo segmentai, o $X_{D,1}^*$, $X_{V,1}^*$ arba $X_{H,1}^*$ - testuojamo vaizdo atitinkami segmentai. Jei bent vienas iš dydžių RDH , RDV ir RDD yra didesnis už nustatytą defekto aptikimo jautrumo lygį (DSL), tai tiriamas vaizdas yra pripažįstamas brokuotu. Etaloninis vaizdas, su kuriuo yra lyginami visi tiriami vaizdai, yra laikomas visų kokybiškų vaizdų aibės V_1 poaibio $V_1^{(krit)}$ vaizdų vidurkis. Pirmo priedo paveiksluose pavaizduoti etaloninio vaizdo HT spektro segmentų $X_{A,1}$, $X_{V,1}$, $X_{H,1}$ ir $X_{D,1}$ koeficientai, kurių reikšmės artimos nuliui.

Šiuo atveju kokybės kriterijus $K^{(2)} = (RDH, RDV, RDD, DSL)$.

2.1.2. DEFEKTŲ TEKSTŪRINIUIOSE PAVIRŠIUOSE LOKALIZAVIMAS

Jei testavimo metu skaitmeninis vaizdas $X \in V'$ yra pripažįstamas brokuotu, tuomet galima bandyti lokalizuoti defekto vietą. Norint tai padaryti, taikant prieš tai aprašytus metodus, būtina tiriamą vaizdą suskaidyti į blokus. Blokų skaičius priklauso nuo to, koks yra pageidaujamas lokalizavimo tikslumas.

Tarkime, kad tekstūrinio paviršiaus vaizdas X , kurio matmenys $N \times N$, dalinamas į lygius blokus, kurių dydis $2^p \times 2^p$, $p \in \{1, 2, 3, \dots, n-1\}$, $N = 2^n$. Tada blokelių skaičius lygus $bn = \left(\frac{2^n}{2^p}\right)^2$. Kiekvienas vaizdo blokas X_1, X_2, \dots, X_{bn} tikrinamas, taikant kokybės kriterijų $K^{(1)}$ arba $K^{(2)}$, kurie aprašomi anksčiau. Blokeliai, kurie netenkina kokybės kriterijaus sąlygų, yra pripažįstami kaip defektuoti.

3. TIRIAMOJI DALIS

3.1. TEKSTŪRINIŲ PAVIRŠIŲ DNL EKSPERIMENTAS


3.1.1. TEKSTŪRINIŲ PAVIRŠIŲ PARINKIMAS EKSPERIMENTUI

Ankstesniuose skyriuose aprašyti ir paaiškinti defektų aptikimo metodai buvo patikrinti su realiais duomenimis - betoninių trinkelėlių tekstūriniais paviršiais.

Eksperimentui atlikti tinka ne tik dirbtiniai, bet ir natūralūs tekstūriniai paviršiai. Be to, nepakanka, kad tekstūros priklausytų tai pačiai objektų klasei. Paveiksluose 3.1 ir 3.2 pateikti medžių žievių (natūralūs) ir audinių (dirbtiniai) tekstūrinių paviršių pavyzdžiai. Nors medžių žievės priklauso tai pačiai objektų klasei, bet jų tekstūros labai skiriasi, todėl bendros analizės šiems vaizdams taikyti negalima.




3.1 pav. Natūralių tekstūrinių paviršių pavyzdžiai



3.2 pav. Dirbtinių tekstūrinių paviršių pavyzdžiai

Tyrimui pasirinkta 200 nufotografuotų betono trinkelėlių vaizdų, iš kurių 100 neturėjo jokių matomų defektų, o likusieji pasižymėjo įskilimais, ištrupėjusiais fragmentais, dėmėmis ir kitokiais panašiais trūkumais. Nagrinėjamų betoninių plytelių paviršių vaizdai, kurių matmenys 256×256 , yra su pilka šviesos intensyvumo skale (vaizdo elemento – pikselio reikšmė $I \in [0; 255]$). Kokybiškos ir brokotos plytelių paviršių pavyzdžiai pateikti 3.3 paveiksle.



3.3 pav. Kokybiškos ir brokuotos plytelių pavyzdžiai

3.1.2. DEFEKTŲ NUSTATYMO EKSPERIMENTAS

Pirmojo metodo kokybės kriterijus $K^{(1)}$ formuojamas iš kokybiškų vaizdų aibės V_1 poaibio $V_1^{(krit)} = \{X_1, X_2, \dots, X_{100}\}$, sudaryto iš 100 tekstūrinių paviršių vaizdų. Visiems vaizdams apskaičiuojamas diskretusis Haaro transformacijos spektras, kuriame išskiriami diagonaliosios krypties

spektrinių koeficientų segmentai $X_{D,j} (j \in \{1, 2, \dots, 9\})$. Tada apskaičiuojami visų 100 vaizdų segmentų $X_{D,j} (j \in \{1, 2, \dots, 9\})$ vidurkiai $m_{i,j}$, kur i žymi vaizdo numerį, o j – segmento numerį. Kadangi šie vidurkiai $m_{i,j}$ visuose segmentuose $X_{D,j} (j \in \{1, 2, \dots, 9\})$ turi normalųjį skirstinį, todėl pagal empirinę taisyklę suformuojami 9 prognozės intervalai, kurie ir sudaro kokybės kriterijų $K^{(1)}$.

Antrojo metodo atveju etaloninis vaizdas gaunamas taip pat iš to paties vaizdų be defektų poaibio $V_1^{(krit)}$, sudaryto iš 100 vaizdų, apskaičiuojant jų vidurkį. Tada parenkamas kokybiškų vaizdų poaibis, taip pat sudarytas iš 100 vaizdų, ir apskaičiuojami skirtumai RDH , RDV , RDD tarp kiekvieno poaibio elemento ir etaloninio vaizdo. Tokie skirtumai apskaičiuojami ir tarp kiekvieno brokuotų vaizdų aibės elemento ir etaloninio vaizdo. Pagal gautus rezultatus parenkamas optimalus defektų aptikimo jautrumo lygis (DSL). Jei testuojamo vaizdo bent viena iš skirtuminių reikšmių viršija DSL , tuomet toks vaizdas pripažįstamas brokuotu, priešingu atveju – kokybišku.

Defektų aptikimo metodai buvo realizuoti programinėje aplinkoje MATLAB. Kadangi šio darbo tikslas yra sudaryti metodus defektams tekstūriniuose paviršiuose nustatyti, o ne sukurti programinę įrangą konkreitiems taikymams su grafikos priemonėmis pagrįsta sąsaja tarp žmogaus ir kompiuterio, todėl 2 priede pateiktomis programomis įgyvendinami tik metodų skaičiavimai ir patikrinamas sudarytų metodų efektyvumas.

Kiekvieno eksperimento metu iš 100 kokybiškų vaizdų atsitiktinai pasirenkama 50 ir iš 100 brokuotų vaizdų atsitiktinai pasirenkama 50. Defektams aptikti taikomi abu pasiūlyti metodai. Atskirai skaičiuojama, kiek iš jų bus identifikuoti teisingai, t.y. kiek betoninių trinkelių paviršių be defektų vaizdų yra pripažįstami kokybiškais, ir kiek vaizdų su defektais yra pripažįstami brokuotais.

Eksperimentų rezultatai pateikti 3.1 ir 3.2 lentelėse. Pirmasis metodas su tikėtinumo reikšme $t = 2,2681$ visus vaizdus su defektais atpažino teisingai, o antrasis metodas – su $DSL = 14,0485$, tačiau kai kuriais atvejais kokybiški vaizdai buvo priskirti prie brokuotų. Taikant pirmąjį metodą, 84,4 % gerų vaizdų buvo identifikuoti teisingai, o taikant antrąjį metodą - apie 80,4 %. Atvejai, kai geri vaizdai atpažįstami kaip brokuoti, gali netgi būti naudingi, jei reikalaujama nepriekaištinga produkto kokybė. Padidinus tikėtinumo reikšmę pirmajame metode ir DSL reikšmę antrajame metode, gerų vaizdų kokybiškų vaizdų klasėje padaugėtų, tačiau brokuotų vaizdų klasėje gali atsirasti tokių, kurie būtų atpažinti kaip geri vaizdai.

3.1 lentelė

Metodų palyginimas atpažįstant vaizdus su defektais

Eksperimento eilės numeris	Teisingai atpažinti vaizdai su defektais (%)	
	1 metodas	2 metodas
1	100 (50/50)	100 (50/50)
2	100 (50/50)	100 (50/50)
3	100 (50/50)	100 (50/50)
4	100 (50/50)	100 (50/50)
5	100 (50/50)	100 (50/50)
Vidurkis	100 (50/50)	100 (50/50)

3.2 lentelė

Metodų palyginimas atpažįstant vaizdus be defektų

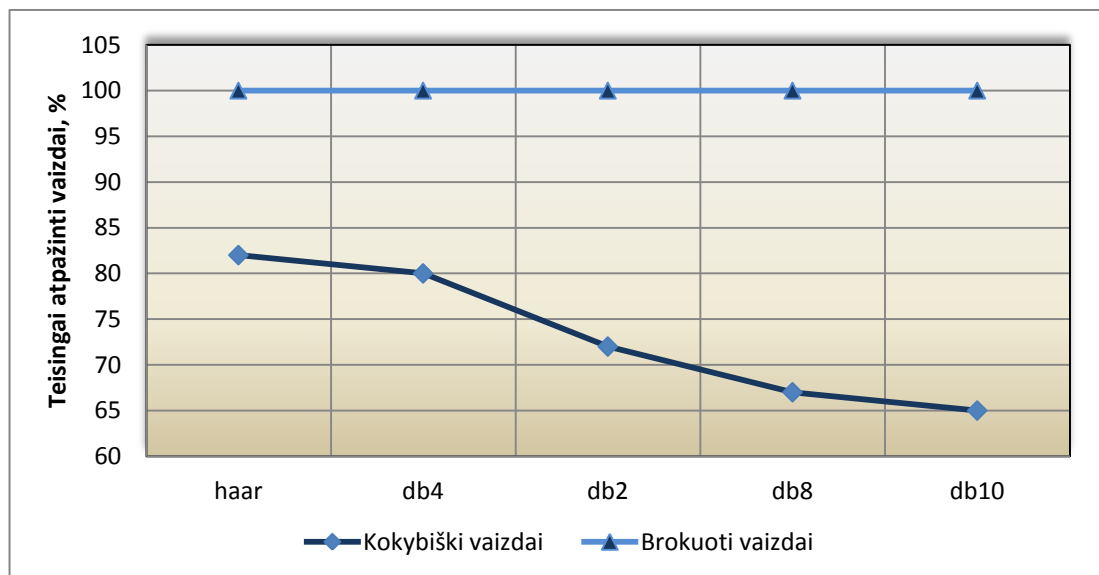
Eksperimento eilės numeris	Teisingai atpažinti vaizdai be defektų (%)	
	1 metodas	2 metodas
1	94 (47/50)	80 (40/50)
2	82 (41/50)	84 (42/50)
3	80 (40/50)	82 (41/50)
4	86 (43/50)	76 (38/50)
5	80 (40/50)	80 (40/50)
Vidurkis	84,4 (42,2/50)	80,4 (40,2/50)

Pirmojo metodo metu transformacijos spektrui gauti vaizdo filtravimas atliekamas aštuonis kartus, o antrojo metodo atveju – vieną kartą, todėl, paprastumo dėlei, pastarojo metodo pagalba buvo nustatyta, kad Haaro transformacija yra efektyvesnė defektams tekstūriniuose paviršiuose aptikti nei įvairios Daubechies transformacijos variacijos. Tyrimo rezultatai, pateikti 3.3 lentelėje ir 3.4 paveiksle, rodo, kad su atitinkamomis defektų aptikimo jautrumo lygio reikšmėmis, su visais filtrais visi brokuoti vaizdai buvo atpažinti teisingai, o kokybiški vaizdai geriausiai atpažinti, naudojant Haaro transformaciją - 82%.

3.3 lentelė

DBT palyginamas

Filtrai	Teisingai atpažinti vaizdai su defektais (%)	Teisingai atpažinti vaizdai be defektų (%)
haar ($DSL = 14,0485$)	100	82
db4 ($DSL = 14,9274$)	100	80
db2 ($DSL = 15,4917$)	100	72
db8 ($DSL = 15,0853$)	100	67
db10 ($DSL = 16,6320$)	100	65




3.4 pav. DBT palyginimas

3.1.3. DEFEKTŲ LOKALIZAVIMO EKSPERIMENTAS


Nepaisant to, kad šio darbo tikslas buvo tik sudaryti metodus defektams tekstūriniuose paviršiuose nustatyti, tačiau gauti defektų aptikimo rezultatai gali būti labai svarbi informacija jų lokalizavimui. Šiame skyrelyje pateikiami tik baziniai lokalizavimo principai, kurie galėtų būti pagrindas kitiems lokalizavimo metodams bei jų tyrimams.

Ekspperimentui atsitiktinai pasirenkamas brokuotas betoninės trinkelės tekstūrinio paviršiaus vaizdas, kuris pateiktas 3.5 paveiksle.




3.5 pav. Testuojamas vaizdas


Defektų lokalizavimas tekstūriniuose paviršiuose pademonstruojamas, taikant antrąjį metodą. Testuojamas vaizdas suskaidomas į blokus, kurie atskirai tikrinami pagal sudarytą kokybės kriterijų. Blokeliai, netenkinantys kriterijaus sąlygų, yra pripažįstami kaip brokuoti. Defektų lokalizavimo rezultatai pateikti 3.6 paveikslo a), b), c), d) dalyse, kai blokelių skaičius atitinkamai 4, 16, 64 ir 256. Išryškinami tik turintys defektų blokai, o vaizdo fragmentai be defektų užtušuojami juodai. Matome, kad vaizdą suskaidžius į 64 dalis, tame ketvirtyje, kuris buvo pripažintas kaip kokybiškas, kai vaizdas buvo dalinamas į 4 blokus, atsirado vienas blokėlis, turintis defektą. Taip yra todėl, kad visais vaizdo skaidymo į blokus atvejais defektų aptikimo jautrumo lygis yra vienodas. Norint patikslinti defekto vietą tame bloke, kuris buvo pripažintas kaip turintis defektą, reikia nustatyti optimalius defekto aptikimo lygius kiekvienu skaidymo į blokėlius atveju.



a) Bloko dydis 128×128



b) Bloko dydis 64×64



a) Bloko dydis 32×32

b) Bloko dydis 16×16

3.6 pav. Defektų lokalizavimo procedūra

IŠVADOS

1. Nustatyta, kad Haaro transformacija yra efektyvesnė defektams tekstūriniuose paviršiuose aptikti nei įvairios Daubechies transformacijos variacijos.
2. Nustatyta, kad vaizdo defektams aptikti gali būti naudojami Haaro transformacijos spektro segmentų $X_{V,1}$, $X_{H,1}$ ir $X_{D,1}$ koeficientai.
3. Defektų aptikimo metodai yra lankstūs, t.y. priklauso nuo tikėtinumo reikšmės arba defektų aptikimo jautrumo lygio parinkimo.
4. Šiame darbe siūlomi metodai defektams tekstūriniuose paviršiuose nustatyti yra gana efektyvūs, tačiau pirmasis metodas yra šiek tiek geresnis už antrąjį. Pirmasis metodas su tikėtinumo reikšme $t = 2,2681$ visus vaizdus su defektais atpažino teisingai, o antrasis metodas visus vaizdus su defektais atpažino teisingai su $DSL = 14,0485$. Taikant pirmąjį metodą, 84,4 % gerų vaizdų buvo identifikuoti teisingai, o taikant antrąjį metodą - apie 80,4 %. Atvejai, kai geri vaizdai atpažįstami kaip brokuoti, gali netgi būti naudingi, jei reikalaujama nepriekaištinga produkto kokybė.
5. Defektų tekstūriniuose paviršiuose nustatymo metodai gali būti naudojami ir defektams lokalizuoti, tačiau būtina pradinį vaizdą dalinti į blokus ir parinkti atitinkamus parametrus kiekvienu vaizdo skaidymo į norimo dydžio blokus atveju. Be to, defektų lokalizavimo tikslumas priklauso nuo blokų skaičiaus parinkimo.


LITERATŪRA

1. Atiqur R., G.M., Hossain, M. Automatic Defect Detection and Classification Technique from Image: A Special Case using Ceramic Tiles. *International Journal of Computer Science and Information Security (IJCSIS)*, vol. 1, No. 1, pp. 22-30, May 2009.
2. Barford, L.A, Fazzio, R.S., Smith, D.R. An Introduction to Wavelets. September 1992.
3. Čekanavičius, V., Murauskas, G. Statistika ir jos taikymai. Vilnius: TEV, 2009.
4. Dewan, R., Aggarwal, M. Identification of Defects in Textiles based on Statistical Analysis of DCT Coefficients of Textile Images. *Aarhat Multidisciplinary International Education Research Journal (AMIERJ)* – ISSN: 2278-5655, vol. 1, Issue 2, pp. 70-77, June-July 2012.
5. Elbehiery, H., Hefnawy, A., and Eason, E.I. Surface Defects Detection for Ceramic Tiles Using Image Processing and Morphological Techniques. *Proceedings of World Academy of Science, Engineering and Technology (PWASET)* – ISSN: 1307-6884. vol. 5, pp. 158-162, April 2005.
6. Ghazvini, M., Monadjemi, S.A., Movahhedinia, N., and Jamshidi, K. Defect Detection of Tiles Using 2D-Wavelet Transform and Statistical Features. *World Academy of Science, Engineering and Technology (WASET)*, pp. 844-847, January 2009.
7. Hocenski, Ž., Rimac-Drlje, S., Keser, T. Automatic Inspection of Defects in Plain and Texture Surfaces.
8. Howarth, P., Ruger, S. Evaluation of Texture Features for Content – Based Image Retrieval. Department of computing, Imperial College London, South Kensington Campus, London.
9. Kociolek, M., Materka, A., Strzelecki, M., Szczypinski, P. *International Conference on Signals and Electronic Systems*, Lodz, Poland, pp. 163-168, September 2001.
10. Lin, H.C., Chiu, C.Y., and Yang, S.N. Texture Analysis and Description in Linguistic Terms. The 5th Asian Conference on Computer Vision, Melbourne, Australia, pp. 23-25, January 2002.
11. Mahajan, P.M., Kolhe, S.R., and Patil, P.M. Classification of Texture Images using Multiresolution Transform. *International Journal of Advanced Research in Computer and Communication Engineering* - ISSN: 2319-5940, vol. 2, Issue 8, pp. 3171-3175, August 2013.
12. Mallat, S. A Wavelet Tour of Signal Processing. New York: Academic, 1998.
13. Materka, A., Strzelecki, M. Texture Analysis Methods – A Review. Technical University of Lodz, Institute of Electronics, Lodz, Poland, 1998.


14. Mostafaeipour, A., Sedaghat, A., Hazrati, A., and Vahdatzad, M. The use of Statistical Process Control Technique in the Ceramic Tile Manufacturing: A Case Study. *International Journal of Applied Information Systems (IJ AIS)* - ISSN: 2249-0868, vol. 2– No.5, pp. 14-19, February 2012.
15. Rimac-Drlje, S., Žagar, D., and Rupčič, S. Adaptive Image Processing Technique for Quality Control in Ceramic Tile Production. *Strojarstvo* - ISSN: 0562-1887, pp. 205-215, February 2010.
16. Sifuzzaman, M., Islam, M.R., Ali, M.Z. Application of wavelet Transform and its Advantages Compared to Fourier Transform. *Journal of Physical Sciences* – ISSN: 0972-8791, pp. 121-134, October 2009.
17. Valantinas, J. Diskrečiosios transformacijos. Kaunas: Technologija, 2008.
18. Valantinas, J., Kančelkis, D., Valantinas, R., Ražanskas, P. Improving Space Localization Properties of the Discrete Wavelet Transform. *Informatica* – ISSN: 0868-4952, vol. 24 – No. 4, pp. 657-675, 2013.
19. Wells, N. An Investigation into Texture Features for Image Retrieval. Bachelor of Science in Computer Science with Honours, the University of Bath, May 2007.

1 PRIEDAS


Šio priedo 1 paveiksle pateikti etaloninio vaizdo Haaro transformacijos spektro segmentų $X_{A,1}$, $X_{H,1}$, $X_{V,1}$, $X_{D,1}$ koeficientų grafikai.




a) HT spektro segmento $X_{A,1}$ koeficientai



b) HT spektro segmento $X_{H,1}$ koeficientai



c) HT spektro segmento $X_{V,1}$ koeficientai



d) HT spektro segmento $X_{D,1}$ koeficientai

1 pav. a), b), c), d) Etaloninio vaizdo HT spektro segmentai