



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

TAIKOMOSIOS MATEMATIKOS KATEDRA

Kristina Dankovskaja

**ILGŪJŲ MUZIKOS NATŲ SEKŲ
PRIKLAUSOMUMO TYRIMAS**

Taikomosios matematikos magistro baigiamasis darbas

**Vadovas
doc. dr. T. Ruzgas**

KAUNAS, 2014



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

TAIKOMOSIOS MATEMATIKOS KATEDRA

**TVIRTINU
Katedros vedėjas
doc.dr. N.Listopadskis
2014 06 01**

**ILGŪJŲ MUZIKOS NATŲ SEKŲ
PRIKLAUSOMUMO TYRIMAS**

Taikomosios matematikos magistro baigiamasis darbas

**Vadovas
doc. dr. T. Ruzgas
2014 06 01**

**Recenzentas
doc.dr. M.Vaičiulis
2014 06 01**

**Atliko
FMMM - 2 gr. stud.
K. Dankovskaja
2014 05 23**

KAUNAS, 2014

KVALIFIKCINĖ KOMISIJA

Pirmininkas: Juozas Augutis, profesorius (VGTU)

Sekretorius: Eimutis Valakevičius, profesorius (KTU)

Nariai:

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

Vytautas Janilionis, docentas (KTU)

Zenonas Navickas, profesorius (KTU)

Kristina Šutienė, docentė (KTU)

Jonas Valantinas, profesorius (KTU)

Dankovskaja K. Research on dependencies of long musical notes sequences Master's work in applied mathematics / supervisor dr. T. Ruzgas; Department of Applied mathematics, Faculty of Fundamental Sciences, Kaunas University of Technology. – Kaunas, 2014. – 97p.

SUMMARY

The problem of correlations between music and mathematics is as old as Pythagoras himself. Statistical approach was widely used by various composers from middle ages to current days for the creation of music. However modern scientific approach started to examine the correlations in the music only in mid of XX century. And it is only the last decades of the century brought some significant studies on the subject. Along with theoretical bases for correlation analysis wide range of practical use of statistics can be traced in music. Statics based programs are essential for the creation of music compositions. With a help of statics some missing parts of older compositions can be traced and recreated. It helps in solving copyright issues, allowing to detect and prove plagiarism. Also it allows to segment different musical compositions into certain musical clusters.

Music can be analyzed using various different statistic approaches. Statistic models varies from simple descriptive statistics to creating formal models, using parametric or non-parametric statistics. Variety of statistic models used for musical analysis increases each year due to numerous researches. It only shows both, that there is a lot interest in the field, and that much is to be done to find optimum methods for analyzing the musical data.

As music melody line is not a stationary process, non-parametric statistical method was chosen for the study. Specifically rank autocorrelation with coefficients was used. Although method itself is not a new one, however it was never a basis for the analysis of music. Therefore this study aims to test is rank autocorrelation with coefficients efficient in handling the task. Although main aim of the study is finding arguments which can support or deny hypothesis of J.Moorer, claiming that absolute majority of musical compositions by different composers have melody line of unique development and unique unrepeatableness.

The scope of analysis is focused on music sheet. Notes sequence of one instrument is analyzed with pitch and length of the note being key criteria. The pitch of note is equaled to the weight function, and helps to determine which notes tend to have biggest mutual dependency. Length of note are used to create data sequences, from which ranks are created, and then the calculations are made based on ranks. Four methods are used for calculations: Van der Waerden, Wilcoxon, Laplace and Spearman.

The method of Spearman ranked autocorrelation proved to be most exquisite and interesting one. The method is most sensitive of all the methods tried and it was best at finding notes dependencies. In almost all of the cases tried Spearman autocorrelation has found most significant

dependencies among notes. While weighted Wilcoxon ranked autocorrelation proved to be least sensitive. For example specific method was not able to find any significant statistical correlation or repetition in any of three tested musical pieces by M.Clementi.

TURINYS

PAVEIKSLŲ SĄRAŠAS.....	7
PRIEDŲ SĄRAŠAS	8
ĮVADAS.....	9
1 TEORINĖ DALIS	10
1.1 STATISTINIŲ TYRIMŲ MUZIKOJE APŽVALGA.....	10
1.2 MUZIKOS NATŲ SEKŲ PRIKLAUSOMYBĖS TYRIMO GALIMYBĖS	11
1.2.1 PARAMETRINIAI IR NEPARAMETRINIAI STATISTINIAI METODAI	11
1.2.2 LAIKO EILUTĖS.....	13
1.2.3 AUTOKORELIACIJA	13
1.2.3.1 AUTOKORELIACIJOS TAIKYMAS	14
1.2.3.1.1 AUTOKORELIACIJOS TAIKYMAS MUZIKOJE	14
1.2.3.2 RANGINĖ AUTOKORELIACIJA.....	15
1.2.3.3 RANGINĖS AUTOKORELIACIJOS KOEFICIENTAI.....	15
1.2.3.4 SVERTINĖ FUNKCIJA	18
1.2.3.4.1 DISKRETŪS SVORIAI	18
1.2.3.5 SVERTINIAI AUTOKORELIACIJOS KOEFICIENTAI.....	19
1.3 TYRIMO ĮGYVENDINIMAS SAS APLINKOJE	22
1.4 TYRIMO TIKSLAI.....	23
2 TIRIAMOJI DALIS.....	25
2.1 DUOMENŲ STRUKTŪRA	25
2.2 MUZIKOS NATŲ SEKŲ PRIKLAUSOMYBĖS STATISTINĖS ANALIZĖS MODELIAI.....	26
2.2.1 HORIZONTALI REZULTATŲ ANALIZĖ.....	34
2.2.2 VERTIKALI REZULTATŲ ANALIZĖ	40
3 PROGRAMINĖ REALIZACIJA IR INSTRUKCIJA VARTOTOJUI.....	46
4 DISKUSIJOS.....	49
4.1 ANALIZUOJAMŲ DUOMENŲ IMTIS	49
4.2 TYRIMO PRITAIKYMAS	49
4.3 REZULTATŲ PALYGINIMAS	49
5 IŠVADOS.....	51
6 REKOMENDACIJOS.....	52
PADĖKOS	53
ŠALTINIAI IR LITERATŪRA.....	54
PRIEDAI	56

PAVEIKSLŲ SĄRAŠAS

1.1 pav. Programos struktūra.....	22
2.1 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	32
2.2 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	33
2.3 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	33
2.4 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	34
2.5 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	34
2.6 pav. Viloksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	35
2.7 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	35
2.8 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	36
2.9 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	36
2.10 pav. Viloksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	36
2.11 pav. Spyrmano svertinė ranginė autokoreliacija ir pasikliautiniai intervalai.....	37
2.12 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	37
2.13 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL).....	38
2.14 pav. Viloksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	38
2.15 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)	39

PRIEDŲ SĄRAŠAS

PRIEDAS NR. 1 FORMULĖ.....	56
PRIEDAS NR. 2 FORMULĖ.....	56
PRIEDAS NR. 3 FORMULĖ.....	57
PRIEDAS NR. 4 FORMULĖ.....	57
PRIEDAS NR. 5 AUTOKORELIACIJOS LENTELĖS	57
PRIEDAS NR. 6 PROGRAMOS KODAS	59
PRIEDAS NR. 7 ANALIZUOJAMŲ KŪRINIŲ SĄRAŠAS.....	63
PRIEDAS NR. 8 AUTOKORELIACIJOS GRAFIKAI.....	64
PRIEDAS NR. 9 DARBE NAUDOJAMI MUZIKINIAI TERMINAI.....	97

ĮVADAS

Muzikos ir matematikos istorija prasidėjo 500 metų prieš Kristų. Kai Pasak legendos, kalvėje išgirdęs kalant į prikalą skirtingo dydžio plaktukus, Pitagoras nustatė jų intervalų santykį. Pitagoras buvo pirmasis, kuris nustatė ryšį tarp muzikos natų ir trupmenų. Praėjo daugiau nei pora tūkstantmečių kol statistiniai metodai muzikos analizei pradėti plačiau taikyti. Tai prasidėjo tik nuo XX a. antros pusės, tačiau pastaruosius keliolika metų pastebimas itin išaugęs populiarumas.

Statistinių metodų taikymo nauda muzikinėje analizėje yra itin svarbi. Jų pagalba gauti rezultatai leidžia atkurti muzikinį kūrinį iš esamų fragmentų, apsaugoti autorines teises, siekiant identifikuoti autorystę ir plagiatą, rasti skirtingų tautų muzikos kultūrinius panašumus.

Kadangi statistinių metodų, taikytinų muzikinėje kūriniių analizėje, sąrašas nėra baigtinis ir vis papildomas naujais metodais, tyrimo metu nuspręsta išbandyti dar netaikytą metodą – svertines rangines autokoreliacijas. Tyrimui buvo specialiai sukonstruota formulė integravus svertinę funkciją į ranginės autokoreliacijos formulę. Pats iš savęs metodas nėra naujas, tačiau taikytas muzikos kūriniių analizėje dar nebuvo.

Tyrimui išskelti uždaviniai:

- Muzikos teorijoje teigiama, kad daugumos kompozitorių muzikos kūriniių melodijos linijai būdingas vystymas ir unikalus nepakartojamumas (J. A. Moorer, 1972). Darbo tikslas – matematiniais metodais patikrinti šį teiginį.
- Patikrinti svertinių ranginės autokoreliacijų metodų tinkamumą muzikinių kūriniių analizėje, palyginti metodus ir apibendrinti gautus rezultatus.
- Atsitiktinai pasirinkus kompozitorių, nustatyti ar jo kūriniių melodijos linijai yra būdingas atsikartojamumas.

Tyrimo metodika ir įgyvendinimas.

Tyrimui buvo pasirinkti dar niekada netaikyti svertinės ranginės autokoreliacijos metodai:

- svertinė Spyrmano ranginė autokoreliacija;
- svertinė Van der Vaerdeno ranginė autokoreliacija;
- svertinė Vilkoksono ranginė autokoreliacija;
- svertinė Laplaso ranginė autokoreliacija.

Muzikinių kūriniių analizė bus atlikta SAS programinės įrangos pagalba, naudojant *%MACRO* kodą.

1 TEORINĖ DALIS

1.1 STATISTINIŲ TYRIMŲ MUZIKOJE APŽVALGA

„Sielos aritmetika“ – taip muziką pavadino vokiečių filosofas ir matematikas Gotfrydas Vilhelmas Leibnicas. Gilus filosofinis teiginys, kurio visas sudėtingumas – apibrėžti, ką iš tikrųjų jis galėtų reikšti. Kai kurie kompozitoriai, ypač 20-ojo amžiaus, sąmoningai pradėjo naudoti matematinius elementus savo kompozicijose.

Tikėtina, kad kaip dabar, taip ir ateityje statistika atliks reikšmingą vaidmenį muzikologijai plečiantis, daugiausia dėl šių priežasčių: a) statistika yra susijusi su duomenų struktūros ieškojimu; b) statistiniai metodai ir struktūros yra matematiniai ir dažnai gali būti išplečiamos iki įvairių duomenų tipų; todėl statistika yra idealus tarpdisciplininis mokslas, kuris gali sujungti skirtingas mokslines disciplinas; ir c) duomenys muzikoje yra masyvūs ir sudėtingi, todėl iš esmės nenaudingi, nebent būtų taikomi atitinkami įrankiai tam, kad išgautume esminius bruožus (J. Beran, 2004).

Matematikas, prof. J. Beranas statistinius metodus, taikytinus muzikologijoje, suskirsto į dvi grupes: pagrindinius klasikinius metodus ir tikslus naujus metodus, sukurtus tam, kad būtų išspręsti tam tikri muzikiniai uždaviniai. Be laiko eilučių, hierarchinių metodų, Markovo grandinių ir paslėptų Markovo modelių, pagrindinių komponentų analizės (angl. *principal component analysis*) yra naudojama diskriminantinė bei klasterinė analizė (J. Beran, 2004).

Muzikoje gali būti panaudota labai didelė statistinių modelių įvairovė – pradedant paprastosiomis aprašomosiomis statistikomis, baigiant formaliuoju modeliavimu, kuomet naudojami parametriniai ir neparimetriniai metodai. Kiekvienais metais paskelbiama apie naujus tyrimus, rezultatus, vienaip ar kitaip atnaujinami ar adaptuojami statistiniai metodai. Tai rodo, kad šioje srityje vyksta intensyvios paieškos, kurių pagrindinis tikslas – noras atrasti optimalų duomenų tyrimo būdą ar jų taikymo aspektą.

Kiekvienas muzikologijoje sprendžiamas uždavinys turi savo tikslą, kartais ne visuomet tiesiogiai susijusį su pačia muzika. Pavyzdžiui, partitūroje nurodytos tonacijos, jos pasikeitimų, raktų pasikeitimo identifikacija atliekama tiriant muzikos tonacijas (Temperley, 2004). Panašumo paieškos tyrimais siekiama užklaustos metu duomenų bazėje atrasti kuo daugiau artimų muzikos kūrinių (Typke ir kt., 2003, Lemstrom ir Tarhio, 2000). Kūrinio fragmentų panašumo nustatymas yra taikomas tiek padainuotai melodijai rasti, tiek ir autorinių teisių apsaugai, siekiant identifikuoti autorystę ir plagiatą.

Lietuvoje tikimybinis-statistinius metodus muzikologijoje taikė prof. R. K. Kašponis. Jis analizavo lietuvių liaudies melodikos ir harmonijos bruožus, lygino muzikinio teksto dydžių

pasiskirstymą, priklausomumui tirti naudojo chi-kvadrato statistiką (R. K. Kašponis, 1992). D. Kučinskas ir R. Ambrazevičius nagrinėjo M. K. Čiurlionio simfoninės muzikos ritmiką, ritmines formules, jų dažnius ir kaitą.

1.2 MUZIKOS NATŲ SEKŲ PRIKLAUSOMYBĖS TYRIMO GALIMYBĖS

Nata – garso aukštumo ir trukmės užrašymo ženklas. Muzikoje natomis žymimi tam tikro aukščio (jį lemia virpesių dažnis) ir santykinės trukmės garsai, kuriems duodami raidiniai, skiemeniniai pavadinimai arba užrašomi grafiniai simboliai, reiškiantys nustatytą garsą muzikos notacijoje ir kartais jo trukmę. Taip pat nata gali reikšti ir konkretų muzikos kūrinio garsą (bendrasis ir konkretusis natos apibrėžimas gali būti naudojamas drauge). Nata yra muzikos diskretizacija, todėl naudojant natas muzikinė analizė tampa įmanoma. Matematikoje natos atitikmuo būtų trupmena, ją analizuoti galima bent dviem skirtingais rakursais: aukščio ir ilgio aspektu.

Muzikinė skalė yra diskreti garso aukščio aibė. Kiekvienos natos aukštis atitinka tam tikrą dažnį, išreikštą hercais (Hz). Pagal garso trukmę natos skirstomos į sveikąsias, pusines, ketvirtines, aštuntines, šešioliktines ir kt.. Natų konvertavimas į skaitines vertes, atsižvelgus į natos struktūrą, suteikia mums galimybę analizuoti muziką: skirtingais statistiniais metodais tirti skirtingus muzikinius kūrinius, kadangi kiekvienas kūrinys turi savo unikalią natų (duomenų) seką.

1.2.1 PARAMETRINIAI IR NEPARAMETRINIAI STATISTINIAI METODAI

Parametriniai kriterijai susieti su teoriniu normaliu skirstiniu – Gauso (angl. *Gaussian*) kreive. Šis teorinis skirstinys statistikoje labai gerai išnagrinėtas, todėl, jeigu įrodoma, kad gauti empiriniai skirstiniai nuo jo mažai tesiskiria, galima pritaikyti precizinį šio skirstinio matematinį aparatą ir matavimų duomenis varijuoti formaliame matematiname modelyje. Vis dėlto tyrimai rodo, kad parametrinių metodų galimybes riboja dvi priežastys:

- Retai kada pavyksta sukonstruoti algebriniu požiūriu nepriekaištingą kiekybinę skalę (santykių arba intervalinę), išskyrus, galbūt, tik tuos atvejus, kai matuojama standartizuotais testais arba, kai matuojami bandomųjų antropometriniai ir fiziniai duomenys.
- Ne visi empiriniai dėsniumai atitinka normalaus skirstinio teorinį modelį. Tuo tarpu nepriekaištinga empirinė skalė ir pagrįsta empirinio skirstinio aproksimacija į normalų teorinį skirstinį yra pagrindinės korektiško parametrinių metodų naudojimo sąlygos.[2]

Analizuojamas dydis – partitūra, vizualus muzikinio kūrinio pateikimas naudojant muzikos notaciją. Pilnose partitūrose nurodomos visų kūrinių atliekančių instrumentų bei vokalistų partijos, tačiau gali būti išleidžiamos specialios partitūros, kurios yra skirtos konkrečiam instrumentui, dirigentu, chorui. Pauzės ir natos yra pagrindinės partitūros sudedamosios dalys. Akivaizdu, kad muzikinio kūrinio melodijos linija nėra stacionari. Štai todėl tyrimams reikšmingi neparametriniai statistiniai kriterijai, kurie leidžia varijuoti įvairių skalių (intervalinės, tvarkos, vardų) duomenis ir neatsižvelgti į empirinio skirstinio tipą. Neparametriniai metodai paremti ne parametrų skaičiavimu, kurie aprašo požymio generalinės aibės skirstinį. Todėl šie metodai neretai vadinami nuo parametrų nepriklausomais metodais ar nuo skirstinio nepriklausomais metodais. Neparametriniai metodai skirstomi į tris kategorijas:

- a) Grupių skirtumų kriterijai – skirti įvertinti nepriklausomų imčių skirtumus;
- b) Požymių skirtumų kriterijai – skirti įvertinti skirtumus tarp požymių priklausomose imtyse;
- c) Požymių ryšio kriterijai.

Statistikoje terminas neparametrinė statistika turi mažiausiai dvi reikšmes. Pirma, neparametrinės statistikos reikšmė apima metodus, kurie nepasikliauja kokio nors konkretaus pasiskirstymo duomenimis.

- Metodai, kurie nesiremia prielaidomis, kad duomenys yra gauti iš duotojo tikimybinio pasiskirstymo, vadinami metodais be skirstinių. Tai būtų priešprieša parametrinėms statistikoms, kurios apima neparametrines kiekinio pasiskirstymo statistikas, statistinius modelius ir statistinius kriterijus.
- Statistika (apibrėžta, kaip nuo parametrų nepriklausanti funkcija), kurios interpretacija nepriklauso nuo imties priklausomumo parametrizuotam skirstiniui, vadinama neparametrine. Rangų statistika, kuri grindžiama stebinių rangais, yra viena iš tokio tipo statistikos pavyzdžių bei vienas pagrindinių metodų neparametrinėje statistikoje.

Antra neparametrinės statistikos reikšmė apima metodus, kurie nesiremia prielaida, kad modelio struktūra yra nekintanti. Dažniausiai, modelio dydis kinta siekiant prisitaikyti prie duomenų tipo. Šiuose metoduose atskiri kintamieji dažniausiai laikomi priklausančiais parametriniam skirstiniui ir daromos prielaidos apie jungčių tipus tarp kintamųjų.

Neparametriniai metodai yra plačiai naudojami analizuojant tvarkos skalės duomenų imtis. Taip pat nepakeičiami, kuomet duomenys yra keičiami rangais, tačiau šiuo atveju nėra aiškios skaitinės interpretacijos, kaip pavyzdys gali būti naudojamas prioritetų vertinimas. Naudojant neparametrinius metodus gaunami duomenys yra „ordinarūs“, t.y. pasižymi eiliškumu [2].

Kadangi neparametriniai metodai remiasi mažiau prielaidų, jų pritaikymas yra gerokai platesnis nei atitinkamų parametrinių metodų. Ypač tuomet, kai prielaidos yra silpnos ar jų nėra, kai mažai žinoma apie užklausas. Be to, dėl mažesnio prielaidų skaičiaus neparametriniai metodai patikimesni. Neparametriniai modeliai nuo parametrinių skiriasi tuo, kad šiuose modeliuose struktūra nėra iš anksto apibrėžta, o nustatoma atsižvelgiant į duomenis.

1.2.2 LAIKO EILUTĖS

Laiko eilutė (laiko seka) – pagal laiko indeksą t išdėstyta atsitiktinio kintamojo X_t seka $\{X_t\}$. Periodiškų stebinių visuma, kurių duomenis gali sudaryti tam tikrais laiko momentais fiksuoti stebinių dydžiai, arba per periodą stebimų dydžių suma. Laiko eilutės gali būti suformuotos iš įvairaus dažnumo, tačiau vienodo periodiškumo duomenų: valandinių, kasdienių, savaitinių, mėnesinių, metinių ir panašiai. Vienas iš pagrindinių laiko eilučių analizės tikslų yra atrasti duomenų kaitos dėsningumus ir pritaikyti matematinius modelius aprašančius dėsningumus. Laiko eilutės yra naudojamos statistikoje, signalų procesuose, ekonometrijoje, orų prognozavime, žemės drebbėjimų nuspėjime, astronomijoje, valdymo ir ryšių inžinerijoje.[20]

Tyrimui buvo pasirinktas laiko eilučių metodas, kadangi duomenų struktūra yra labai tinkama tokio pobūdžio analizei: atsitiktinio kintamojo atitiktumu – nata, iš natų sudaroma seka, o laikas indeksas t - natos skambėjimo eilės numeris kūrinyje, jei natos tiesiog nėra, traktuojama jog tai yra pauzė.

1.2.3 AUTOKORELIACIJA

Autokoreliacija yra kryžminė signalų koreliacija su savimi. Kitaip tariant, tai panašumas tarp stebinių nutolusių laike. Autokoreliacijos sąvoka gali būti traktuojama kaip matematinis įrankis, skirtas surasti pasikartojimams, išskirti periodiškai sklindantį signalą triukšme ar rasti trūkstamą esminį dažnį signale, pasižyminčiame harmoningais dažniais. Autokoreliacija taip pat dažnai naudojama signalų apdorojimui analizuojant funkcijos reikšmių eilutes, tokias kaip laiko srities signalai.

Statistikoje atsitiktinių procesų autokoreliacija apibrėžia koreliaciją tarp proceso reikšmių skirtingais laiko momentais, kuri yra išreikšta dviejų skirtingų laiko momentų funkcija arba laiko vėlavimo funkcija. Tyrime muzikinio kūrinio natoms atsižvelgiant į jų skambėjimo aukštį ir ilgį bus

priskiriamos atitinkamos skaitinės vertės, todėl šiuo atveju bus taikomas diskretusis atvejis, kai vidurkis ir dispersija yra žinomi bei stebima n stebinių $\{X_1, X_2, \dots, X_n\}$, autokoreliacijos vertinimas gali būti gaunamas:

$$\hat{R}(k) = \frac{1}{(n-k)\sigma^2} \sum_{t=1}^{n-k} (X_t - \mu)(X_{t+k} - \mu) \quad (1.1)$$

su visais teigiamais sveikaisiais skaičiais $k < n$. [2]

1.2.3.1 AUTOKORELIACIJOS TAIKYMAS

Autokoreliacijos metodas, naudojant optines autokoreliacijas, taikomas naudojant optinio spektro matavimus bei matuojant lazerio skleidžiamus labai trumpos trukmės šviesos impulsus. Taip pat autokoreliacija naudojama analizuojant dinaminio šviesos pasiskirstymo duomenis, įgalinant nustatyti dalelių dydžių skirstinius lizuojant nano-metrinio dydžio dalelių terpes. Elektronų tankio Furjė transformacijos erdvinės autokoreliacijos funkcija parodo rentgeno spindulių pasiskirstymo intensyvumą nano-struktūrinėse sistemose. O optikoje normalizuotos ir priešpriešinės autokoreliacijos leidžia surasti koherencijos laipsnį elektromagnetiniuose laukuose. [9]

1.2.3.1.1 AUTOKORELIACIJOS TAIKYMAS MUZIKOJE

Apdorojant signalus autokoreliacija gali suteikti informacijos apie pasikartojančius procesus, tokius kaip muzikinis ritmas (tempui nustatyti) ar pulsinis dažnis, tačiau jos pagalba neįmanoma nustatyti kaip ritmas išsidėstęs laike. Autokoreliacija taip pat gali būti naudojama nustatyti natos aukščiu. Muzikos įrašuose ši sąvoka naudojama natos aukščio nustatymo algoritme prieš balso apdorojimą kaip efektas, skirtas pašalinti nepagedaujamos klaidoms ir neatitikimams. [2,9]

Darbe pateikiamas naujas būdas, kaip galima tirti muzikos natų sekų priklausomybę ir kartu įvertinti tolimą priklausomybę tarp natų naudojant svertinės ranginės autokoreliacijas su koeficientais. Siekiama išsiaiškinti, ar iš tikrųjų daugumos kompozitorių muzikos kūrinų melodijos linijai yra būdingas nepakartojamas unikalumas, ar visgi melodijos pasižymi dėsningumu.

1.2.3.2 RANGINĖ AUTOKORELIACIJA

Neparametriniai metodai buvo sukurti vienmačių duomenų analizei ir tik gerokai vėliau buvo naudojami daugiamačių stebinių analizei kaip atoveiksmis į pasiskirstymo dėsnį (dažniausiai normalumo), kuriam priklauso dauguma klasikinių išvadų. Neparametrinių procedūrų poreikis yra netgi didesnis laiko eilučių analizėje. Iš tiesų dauguma rangų pagrįstų procedūrų (ne laiko eilučių kontekste) skirtos tirti atsitiktinumą.

Duotos sekos X_1, \dots, X_n , kuomet $n \geq 3$, tolydūs atsitiktiniai dydžiai bei jų rangai R_1, \dots, R_n yra pirmos eilės serijinės priklausomybės neparametriniai dydžiai, kurie dažniausiai grupuojami poromis $(R_1, R_2), (R_2, R_3), \dots, (R_{n-1}, R_n)$ su galimybe papildyti seką (R_n, R_1) tokiu atveju statistika vadinama apskritąja (angl. *circled*). Van der Vaerdeno, Vilkoksono, Laplaso, (angl. *Van der Waerden, Wilcoxon ir Laplace*) autokoreliacijos koeficientai apima šių porų imties koreliacijas. [7,8]

1.2.3.3 RANGINĖS AUTOKORELIACIJOS KOEFICIENTAI

Tegu $X = (X_1, \dots, X_n)$ yra n ilgio stebėjimo eilutės. Stebiniai X_t yra nepriklausomi ir vienodai pasiskirstę su neapibrėžta pasiskirstymo funkcija $F(x)$ ir tankiu $f(x)$. Tegu R_t nurodo X_t rangą tarp X_1, \dots, X_n . $\mathbf{R} = (R_1, \dots, R_n)$ yra atsitiktinis derinys iš $\{1, 2, \dots, n\}$ ir \mathbf{R} matuojamas neparametriniais metodais. Susiję stebiniai gali pasitaikyti praktikoje ir gali būti tvarkomi naudojant įprastą vidutinio rango (angl. *midrank*) procedūrą. [7,8]

Darant prielaidą, kad $f'(x) = \frac{d}{dx} f(x)$, $\phi(x) = \frac{f'(x)}{f(x)}$; ir, tarkime, kad $F^{-1}(u) = \inf\{x | F(x) \geq u\}$, $u \in (0, 1)$.

k -tosios eilės ranginės autokoreliacijos koeficientai susieti su f rūšies tankiu (arba tiesiog f -rango k eilės autokoreliacija) buvo pristatyti Marko Halino (angl. *Marc Hallin*) ir kt. kaip serijinės priklausomybės (su vėlavimu k) neparametrinis matas, kuris esant tankiui f , pasižymi optimalumo savybėmis, panašiomis į paprastojo skirstinio autokoreliaciją esant Gauso (angl. *Gaussian*) tankiui. [7,8]

k -tosios eilės f -rango autokoreliacija yra:

$$\rho_f(k) = \left\{ \frac{1}{n-k} \sum_{t=1}^{n-k} \phi \left(F^{-1} \left(\frac{R_t}{n+1} \right) \right) F^{-1} \left(\frac{R_{t+k}}{n+1} \right) - m_f \right\} / \sigma_f$$

(1.2)

Akivaizdu, kad m_f ir σ_f normalizuoja taip, kad $\sqrt{(n-k)}\rho_f(k)$ yra normalizuotas.

$$m_f = \frac{1}{n(n-1)} \sum_{1 \leq i_1 \neq i_2 \leq n} \phi \left(F^{-1} \left(\frac{i_1}{n+1} \right) \right) F^{-1} \left(\frac{i_2}{n+1} \right) \quad (1.3)$$

ir

$$\begin{aligned} \sigma_f^2 &= \frac{1}{n(n-1)} \sum_{1 \leq i_1 \neq i_2 \leq n} \left[\phi \left(F^{-1} \left(\frac{i_1}{n+1} \right) \right) F^{-1} \left(\frac{i_2}{n+1} \right) \right]^2 \\ &+ \frac{2(n-2k)}{n(n-1)(n-2)(n-k)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \leq n} \phi \left(F^{-1} \left(\frac{i_1}{n+1} \right) \right) \phi \left(F^{-1} \left(\frac{i_2}{n+1} \right) \right) F^{-1} \left(\frac{i_2}{n+1} \right) F^{-1} \left(\frac{i_3}{n+1} \right) \\ &+ \frac{n^2 - n(2k+3) + k^2 + 5k}{n(n-1)(n-2)(n-3)(n-k)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \neq i_4 \leq n} \sum \sum \phi \left(F^{-1} \left(\frac{i_1}{n+1} \right) \right) \phi \left(F^{-1} \left(\frac{i_2}{n+1} \right) \right) F^{-1} \left(\frac{i_3}{n+1} \right) F^{-1} \left(\frac{i_4}{n+1} \right) \\ &- (n-k)m_f^2 \end{aligned} \quad (1.4)$$

Specifikuodami tankio rūšį gauname Van der Vaerdeno (angl. *Van der Waerden*) ranginę autokoreliaciją su Gauso (angl. *Gaussian*) tankiu.

$$\rho_{vdW}(k) = \left\{ \frac{1}{n-k} \sum_{t=1}^{n-k} \Phi^{-1} \left(\frac{R_t}{n+1} \right) \Phi^{-1} \left(\frac{R_{t+k}}{n+1} \right) - m_{vdW} \right\} / \sigma_{vdW} \quad (1.5)$$

Čia $\Phi(\cdot)$ kaip įprastai žymi standartinę normaliojo pasiskirstymo funkciją – Vilkssono (angl. *Wilcoxon*) autokoreliaciją su logistine tankio funkcija:

$$\rho_W(k) = \left\{ \frac{1}{n-k} \sum_{t=1}^{n-k} \left(\frac{2R_t}{n+1} - 1 \right) \log \left(\frac{R_{t+k}}{n+1 - R_{t+k}} \right) - m_W \right\} / \sigma_W \quad (1.6)$$

ir Laplaso (angl. *Laplace*) rango autokoreliacija su dvigubu eksponentiniu tankiu,

$$\rho_L(k) = \left\{ \frac{1}{n-k} \sum_{t=1}^{n-k} \text{sign} \left(R_t - \frac{n+1}{2} \right) F_s^{-1} \left(\frac{R_{t+k}}{n+1} \right) - m_L \right\} / \sigma_L$$

$$\text{su } F_s^{-1}(u) = \begin{cases} \log(2u) & 0 < u \leq \frac{1}{2} \\ -\log(2-2u) & \frac{1}{2} < u < 1 \end{cases} \quad (1.7)$$

Kitas koreliacijos eilutėse serijinės priklausomybės ranginis matas yra Spyrmano – Valdo – Volfovitzo (angl. *Spearman-Wold-Wolfowitz*) eilučių koreliacijos koeficientas (čia vadinamas k -tosios eilės Spyrmano (angl. *Spearman*) autokoreliacijos koeficientu). Pirmieji bandymai Spyrmano (angl. *Spearman*) autokoreliacijos pagrindu atlikti dar A. Valdo (angl. *Wold*) ir R. Volfovitzo (angl. *R. Wolfowitz*) (1943 m.). F -rango autokoreliacijos neturėtų būti painiojamos su Spyrmano (angl. *Spearman*) rango autokoreliacijomis, kurios yra, tikriausiai, vienos iš populiariausių rangais pagrįstų serijinių priklausomybių vertinimo priemonių. Išėmus nenaudingus indeksus, apibrėžiame Spyrmano (angl. *Spearman*) autokoreliaciją:

$$\rho_S(k) = \left\{ \frac{1}{n-k} \sum_{t=1}^{n-k} R_t R_{t+k} - m_S \right\} / \sigma_S \quad (1.8)$$

Spyrmano (angl. *Spearman*) k eilės autokoreliacijos koeficientas yra [7]:

$$\rho_S(k) = \frac{\frac{1}{n-k} \sum_{t=1}^{n-k} R_t R_{t+k} - \frac{(n+1)^2}{4}}{(n^2 - 1)/12} \quad (1.9)$$

Turėdami imties reikšmes bei jas atitinkančias rangų vertes galime įvertinti imties rangines autokoreliacijas: $\hat{\rho}_{v\bar{d}W}(k)$, $\hat{\rho}_W(k)$, $\hat{\rho}_L(k)$, $\hat{\rho}_S(k)$.

Tegu $\bar{R} = \frac{1}{n} \sum_{t=1}^n R_t$ apibrėžia R_t reikšmių vidurkį ir $\hat{\gamma}(k)$ yra ranginės autokovariacijos koeficientas esant vėlavimui k , čia $k = 0, 1, 2, \dots, n$. Autokovariacija, kai $k = 0$ yra dispersija $\hat{\sigma}^2 = \hat{\gamma}(0)$. Autokoreliacijos pavyzdys, kai vėlavimas k gali būti užrašytas 0 su autokovariacijos sąlygomis:

$$\hat{\rho}(k) = \frac{\hat{\gamma}(k)}{\hat{\gamma}(0)} \quad (1.10)$$

Spyrmano k vėlinimo ranginė autokoreliacija gali būti užrašyta:

$$\hat{\rho}_S(k) = \frac{\hat{\gamma}_S(k)}{\hat{\gamma}_S(0)}, \quad (1.11)$$

$$\hat{\gamma}_S(k) = \frac{1}{n-k} \sum_{t=1}^{n-k} (R_t - \bar{R})(R_{t+k} - \bar{R})$$

čia

$$(1.12)$$

f -rango autokoreliacijos negali būti užrašytos naudojant autokovariacijas.

Korelograma padeda atsakyti į klausimą ar seka yra atsitiktinė, ar ne. Atsitiktinėms sekoms, sekos vėlavimo reikšmės nekoreliuoja ir $\hat{\rho}(k) \cong 0$. $(1 - \alpha)$ pasikliautinieji intervalai korelogramoje gali būti žymimos ties $-1/n \pm t_{(1-\frac{\alpha}{2}; n-1)}/\sqrt{n}$, ir dažnai yra aproksimuojamos į $0 \pm t_{(1-\frac{\alpha}{2}; n-1)}/\sqrt{n}$. Dažniausiai $(1 - \alpha)$ pasikliautinieji intervalai yra koreguojami dėl tarpusavio priklausomumo $\pm t_{(1-\frac{\alpha}{2}; n-1)} SE_k$, kur didelio vėlavimo standartinė paklaida $SE_k = \sqrt{\frac{1}{n} (1 + 2 \sum_{t=1}^{k-1} \rho^2(k))}$, $t_{(1-\frac{\alpha}{2}; n-1)}$ yra $(1 - \frac{\alpha}{2})$ kritinė vertė Stjudento (angl. *Student*) t statistiniame modelyje su $n - 1$ laisvės laipsniu. Kuomet vėlavimas lygu 1, neegzistuoja jokios ankstesnės autokoreliacijos, todėl $\rho^2(0)$ yra prilyginamas 0.

1.2.3.4 SVERTINĖ FUNKCIJA

Svertinė funkcija yra matematinis įrankis, naudojamas atliekant sumavimo, integravimo ar vidurkio skaičiavimo veiksmus suteikiant kai kuriems elementams atitinkamą „svorį“, kuris daro įtaką galutiniam rezultatui lyginant su kitais tos pačios aibės elementais. Svertinė funkcija dažnai naudojama statistinėje analizėje ir yra glaudžiai susijusi su mato samprata. Ji gali būti naudojama norint sukonstruoti skaičiavimo sistemas. Tyrime svertinės funkcijos vaidmenį atliks natos skambėjimo ilgis. Kadangi pagal skambėjimo trukmę natos yra skirstomos į sveikąsias, pusines, ketvirtines, aštuntines, šešioliktines ir kt., joms gali būti priskirta atitinkama vertė – svoris.

1.2.3.4.1 DISKRETŪS SVORIAI

Partitūroje natos yra išdėstytos atitinkama eilės tvarka. Kadangi kiekviena nata ar pauzė turės atitinkamą skaitinę vertę, galime ją tapatinti su skaičių seka, todėl tyrimo metu bus taikomas svertinės

funkcijos diskretus atvejis, kurio metu svartinė funkcija $w : A \rightarrow \mathbb{R}^+$ yra teigiama funkcija apibrėžta diskrečioje baigtinėje A aibėje. Svertinė funkcija $w(a) := 1$ atitinka nesvertinę situaciją, kurioje visi elementai turi vienodą svorį. Pastaroji funkcija gali būti pritaikoma įvairiose situacijose.[21]

Jei funkcija $f : A \rightarrow \mathbb{R}$ yra realiųjų skaičių funkcija, tuomet nesvertinę funkcijų f svorių suma aibėje A yra apibrėžiama kaip:

$$\sum_{a \in A} f(a); \quad (1.13)$$

Kuomet duotoji funkcija yra svartinė $w : A \rightarrow \mathbb{R}^+$, tuomet svartinė suma yra apibrėžiama kaip:

$$\sum_{a \in A} f(a)w(a). \quad (1.14)$$

Svertinis vidurkis:

$$\frac{\sum_{a \in A} f(a)w(a)}{\sum_{a \in A} w(a)}. \quad (1.15)$$

Svertiniai vidurkiai dažniausiai taikomi statistikoje siekiant kompensuoti poslinkius. Kiekį f matuojant keletą nepriklausomų kartų f_i su dispersija σ_i^2 , tiksliausia signalo prognozė gaunama skaičiuojant visų matmenų vidurkį su svoriu $w_i = \frac{1}{\sigma_i^2}$, ir galiausiai gaunama dispersija yra mažesne nei kiekvieno atskiro matmens $\sigma^2 = 1 / \sum w_i$.

1.2.3.5 SVERTINIAI AUTOKORELIACIJOS KOEFICIENTAI

Tarkime duotajai laiko eilutei X svartinė eilutė yra $w = (w_1, \dots, w_n)$. Tuomet svartinė Spearmano (angl. *Spearman*) autokoreliacijos funkcija gali būti apibrėžta kaip:

$$\hat{\rho}_{wS}(k) = \frac{\hat{\gamma}_{wS}(k)}{\hat{\gamma}_{wS}(0)}, \quad (1.16)$$

čia

$$\hat{\gamma}_{wS}(k) = \frac{\sum_{t=1}^{n-k} (R_t - \bar{R}_w)(R_{t+k} - \bar{R}_w)w_t w_{t+k}}{\sum_{t=1}^{n-k} w_t w_{t+k} \left(1 - \frac{k}{n}\right)} \quad (1.17)$$

ir svertinis vidurkis

$$\bar{R}_w = \sum_{t=1}^n R_t w_t / \sum_{t=1}^n w_t. \quad (1.18)$$

Svertinė f -rango autokoreliacijos funkcija, gauta pakeitus svorio vienetus, gali būti apibrėžta kaip:

$$\hat{\rho}_{wf}(k) = \frac{\left\{ \frac{1}{\sum_{t=1}^{n-k} w_t w_{t+k}} (n-k) \times \sum_{t=1}^{n-k} w_t w_{t+k} \phi \left(F^{-1} \left(\frac{R_t}{n+1} \right) \right) F^{-1} \left(\frac{R_{t+k}}{n+1} \right) - \hat{m}_{wf} \right\}}{\hat{\sigma}_{wf}} \quad (1.19)$$

čia

$$\begin{aligned} \hat{m}_{wf} &= \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{1 \leq i_1 \neq i_2 \leq n} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \leq n} w_{i_1} w_{i_2} \phi \left(F^{-1} \left(\frac{i_1}{1 + \sum_{i_1} 1} \right) \right) F^{-1} \left(\frac{i_2}{1 + \sum_{i_2} 1} \right) \end{aligned} \quad (1.20)$$

Ir

$$\begin{aligned} \hat{\sigma}_{wf}^2 &= \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{i_1 i_2} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \leq n} \left[w_{i_1} w_{i_2} \phi \left(F^{-1} \left(\frac{i_1}{1 + \sum_{i_1} 1} \right) \right) F^{-1} \left(\frac{i_2}{1 + \sum_{i_2} 1} \right) \right]^2 \\ &+ \frac{2 \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2k}{\sum_{i_1 i_2 i_3} 1} \right) \right)}{\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \end{aligned}$$

$$\begin{aligned}
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3} 1} \right) \right) \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\
& \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \leq n} \sum_{i_1} w_{i_1} w_{i_2}^2 w_{i_3} \phi \left(F^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \phi \left(F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right) \\
& \quad \times F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) F^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) \\
& + \left\{ \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right)^2 - \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right)^2 \left(\frac{2k+3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right. \\
& \quad \left. + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right)^2 k^2 + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right) 5k \right\} \\
& \times \frac{1}{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right) \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \quad \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \neq i_4 \leq n} \sum_{i_1} \sum_{i_2} \sum_{i_3} \sum_{i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \phi \left(F^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \\
& \quad \times \phi \left(F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right) F^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) F^{-1} \left(\frac{i_4}{1 + \frac{1}{\sum_{i_4} 1}} \right) \\
& \quad - \left(\sum_t w_t \left(1 - \frac{k}{n} \right) \right) \hat{m}_{wf}^2
\end{aligned}$$

(1.21)

Svertinėms autokoreliacijoms pasikliautinasis intervalas $(1 - \alpha)$ turi viršutinius ir apatinius rėžius, kurie yra apibrėžti, kaip:

$$\pm t_{(1-\frac{\alpha}{2}; n-1)} SE_{wk} \quad (1.21)$$

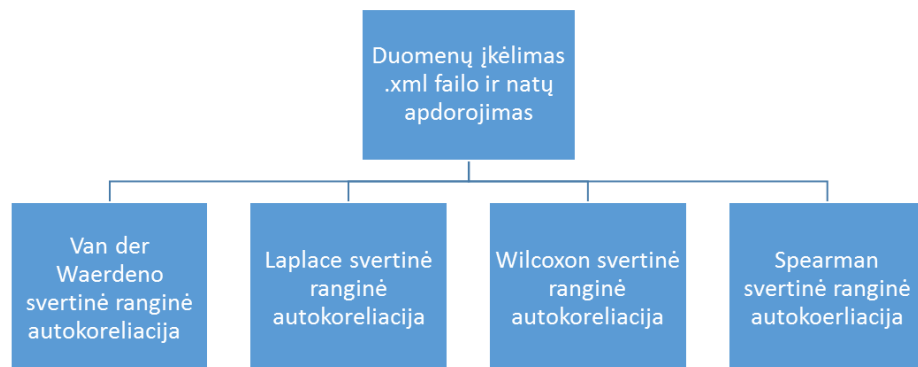
čia $SE_k = \sqrt{\frac{1}{\sum_{i=1}^n w_i} (1 + 2 \sum_{t=1}^{k-1} \rho_w^2(k))}$ yra pasverta didelio vėlavimo standartinė paklaida, $\rho_w(k)$ yra pasvertas autokovariacijos koeficientas prie vėlavimo k , ir yra svoris kiekvienam i -tajam stebiniui.

1.3 TYRIMO ĮGYVENDINIMAS SAS APLINKOJE

Šiuolaikinių tyrimų duomenys paprastai apdorojami kompiuteriu. Yra sukurtos specialios bendros statistinės programos, skirtos empirinių socialinių tyrimų duomenims apdoroti. Matematiniais metodams įvertinti naudojama SAS programinė įranga ir `%MACRO` kalba. Kompiuteriu apdoroti duomenys analizuojami tyrimo koncepcijos požiūriu, prasideda tyrimo duomenų interpretacijos faze, tuomet sprendžiama apie tyrimo hipotezės patvirtinimą (atmetimą) ir pabaigoje formuluojamos išvados.

Pradiniame etape įkeliamas duomenų failas, iš kurio duomenys paruošiami tyrimui. Duomenys įkeliami `.xml` žemėlapiu pagalba (angl. `xml map`), jeigu yra tam tikrų netikslumų, apdorojimo ir paruošimo procese gali dalyvauti vartotojas.

Programos struktūra:



1.1 pav. Programos struktūra

Įkėlus duomenis apdorojimui yra sukuriamas naujas duomenų failas, kuriame yra tiek nuskaityti duomenys, tiek papildomai sugeneruoti nauji duomenų stulpeliai, pritaikyti programos kodui. Duomenų nuskaitymo metu turi būti pasirinkta analizuojama partitūra. Pasirinkus vieną iš analizės būdų : Van der Vaerdeno, Laplaso, Wilkoksono ar Spyrmano (angl. Van der Waerden, Laplace, Wilcoxon) ir paleidus skaičiavimus, duomenys yra išvedami į rezultatų failą, kuris vėliau yra perkeliamas į *.xls* formato failą.

1.4 TYRIMO TIKSLAI

Muzikos teorijoje teigiama, kad daugumos kompozitorių muzikos kūrinių melodijos linijai būdingas vystymas ir unikalus nepakartojamumas [James A. Moorer] Darbo tikslas – matematiniais metodais patikrinti šį teiginį.

Muzikinės kūrinių natos paverčiamos duomenimis, kuriuos galima analizuoti statistiniais metodais. Pasirinktas uždavinio sprendimo būdas - svertinė ranginė autokoreliacija su koeficientais. Tyrimo metu bus atliekama statistinė duomenų analizė: tiriama, ar egzistuoja statistinis ryšys tarp kūrinių natų. Norint gauti tikslesnius tyrimo rezultatus bus naudojama svertinė funkcija, kurios pagalba galėsime vertinti galutinį rezultatą, išgrynindami svariausią informaciją. Bus tiriama Liudvigo van Bethoveno (angl. *Ludwig van Beethoven*), Frederiko Šopeno (angl. *Frederic Chopin*), Volfgango Amadėjaus Mocarto (angl. *Wolfgang Amadeus Mozart*), Antonijaus Vivaldžio (angl. *Antonio Vivaldi*), Piotro Čaikovskio (rus. *Пётр Ильич Чайковский*), Nikolo Paganinio (angl. *Niccolo Paganini*) ir kt. autorių kūriniai.

Kūriniams tirti bus taikomi šie metodai:

- Van der Waerden svertinė ranginė autokoreliacija su koeficientais;
- Wilcoxon svertinė ranginė autokoreliacija su koeficientais;
- Laplace svertinė ranginė autokoreliacija su koeficientais;
- Spearman svertinė ranginė autokoreliacija su koeficientais.

Lygindami išvardintais metodais gautus rezultatus galime išskirti metodus, kurie suteikia daugiausiai informacijos ir yra tinkami tyrimams muzikoje ar bent jau pasirinktoje kūrinių grupėje.

Atsižvelgiant į tyrimo naujumą, gauti rezultatai leistų patvirtinti arba paneigti taikomų matematinių metodų naudą tokio tipo tyrimuose. Jeigu tyrimo metu gauti rezultatai būtų informatyvūs, tai reikštų priartėjimą prie gebėjimo statistinių metodų pagalba atskirti muzikinius kūrinius. Tuomet

metodai galėtų padėti spręsti muzikinių kūrinių trūkstamų dalių atkūrimo problemą ar muzikinio kūrinio identifikavimą, esant dalinei informacijai.

2 TIRIAMOJI DALIS

2.1 DUOMENŲ STRUKTŪRA

Pagrindiniai muzikinio kūrinio parametrai, kurie yra naudojami darbe: natos ilgis, natos aukštis (dažnis), oktava, partitūra. *Xml* žemėlapiu pagalba iš muzikos *xml* (music *XML*) failo nuskaityti duomenys, reikalingi svertinei ranginei autokoreliacijai apskaičiuoti ir atrinkti reikalingas duomenų grupes.

Nuskaičius *.xml* failą, yra gaunami muzikinio kūrinio duomenys: natos skambėjimo eilė, natos pavadinimas, oktava, natos skambėjimo trukmė, instrumentas, partitūra. Norint atlikti muzikinio kūrinio natų statistinę analizę buvo naudojami natos ilgio ir aukščio (dažnio) duomenys, tam reikėjo papildomai atlikti duomenų apdorojimo žingsnius:

- Duomenys apdorojami trisdešimt antrinės natos tikslumu, t.y. kiekvienam natos ilgiui priskiriama skaitinė vertė, sveikoji nata atitinka 1, pusinė - $\frac{1}{2}$, ketvirtinė – $\frac{1}{4}$, aštuntinė – $\frac{1}{8}$ ir t.t.. šešiasdešimt ketvirtinės natos nebuvo vertinamos, kadangi pasitaiko labai retai.
- Įvertinamas natos ilgis. Įgyta skaitinė natos vertė tyrime atliks svertinės funkcijos vaidmenį.
- Įvertinamas natos aukštis. Iš muzikos teorijos žinome, kad viso yra 10 oktavų; remiantis natos skambėjimo aukščiu ir oktava natai yra priskiriama eilė, kuri vėliau konvertuojama į rangą.
- Kūrinys yra suskirstomas į atskiras partitūras ir kiekviena partitūra analizuojama atskirai.

Akivaizdu, kad muzikinių kūrinų melodijų linijos nėra pasiskirsčiusios pagal normalųjį dėsnį, dėl to buvo nuspręsta taikyti neparametrinius statistinės analizės metodus. Ko sekoje, atliekant skaičiavimus buvo analizuojami ne patys stebėjimai, o jų rangai. Atliekant duomenų nuskaitymą buvo išskiriami svarbiausi duomenys: natos aukštis ir ilgis. Realizuojant svertinių ranginės autokoreliacijos koeficientų formules programoje, tyrime svorio funkciją atitiko natos ilgis. Iš natų aukščio buvo sudaryta duomenų eilutė, kurioje duomenys buvo konvertuoti į rangus.

Tyrimas buvo atliktas dviem skirtingais rakursais, taikant horizontalią ir vertikalią rezultatų analizę. Horizontalios analizės metu, kiekvienas kūrinys buvo lyginamas skirtingais svertinės ranginės autokoreliacijos metodais (Waerdeno, Laplaso, Wilcoxon ir Spearmano). Vertikali analizė bus skirta vieno pasirinkto kompozitoriaus kūrybos bruožams išskirti. Tyrimo metu bus siekiama nustatyti, kuris metodas skaičiuoja geriausiai, ar tiesiog yra universaliausias.

2.2 MUZIKOS NATŲ SEKŲ PRIKLAUSOMYBĖS STATISTINĖS ANALIZĖS MODELIAI

Autokoreliacijos metodas šiam skaičiavimui buvo pasirinktas todėl, kad jis yra įvykių atsiradimo po tam tikro kito įvykio nuliniu laiko momentu dažnio matas. Jei matas po mato įvykiai koreliuoja, t.y. kai didesnis įvykių atsiradimo dažnis yra tuomet, kai laikas tarp matų yra didesnis, tada autokoreliacijos funkcijos šuolis į viršų turi nurodyti mato pradžios laiką. Tyrimo metu buvo sukonstruotos naujos ranginės autokoreliacijos su koeficientais formulės su integruota svertine funkcija. Programoje buvo realizuoti keturi metodai:

- Van der Waerden svertinė ranginė autokoreliacija

$$\hat{\rho}_{wf}(k) = \frac{\left\{ \frac{1}{\sum_{t=1}^{n-k} w_t w_{t+k}} \times \sum_{t=1}^{n-k} w_t w_{t+k} \phi \left(\Phi^{-1} \left(\frac{R_t}{n+1} \right) \right) \Phi^{-1} \left(\frac{R_{t+k}}{n+1} \right) - \hat{m}_{wf} \right\}}{\hat{\sigma}_{wf}}, \quad (2.1)$$

čia

$$\begin{aligned} \hat{m}_{wf} &= \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{1 \leq i_1 \neq i_2 \leq n} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \leq n} w_{i_1} w_{i_2} \phi \left(\Phi^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \Phi^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \end{aligned} \quad (2.2)$$

ir

$$\begin{aligned} \hat{\sigma}_{wf}^2 &= \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{i_1 i_2} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \leq n} \left[w_{i_1} w_{i_2} \phi \left(\Phi^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \Phi^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right]^2 \end{aligned}$$

$$\begin{aligned}
& + \frac{2 \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2k}{\sum_{i_1 i_2 i_3} 1} \right) \right)}{\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3} 1} \right) \right) \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\
& \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \leq n} \sum w_{i_1} w_{i_2}^2 w_{i_3} \phi \left(\Phi^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \phi \left(\Phi^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right) \\
& \quad \times \Phi^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \Phi^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) \\
& + \left\{ \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right)^2 - \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right) \left(\frac{2k+3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right. \\
& \quad \left. + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right)^2 k^2 + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right) 5k \right\} \\
& \times \frac{1}{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right) \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \quad \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \quad \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \neq i_4 \leq n} \sum \sum w_{i_1} w_{i_2} w_{i_3} w_{i_4} \phi \left(\Phi^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \\
& \quad \times \phi \left(\Phi^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right) \Phi^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) \Phi^{-1} \left(\frac{i_4}{1 + \frac{1}{\sum_{i_4} 1}} \right) - \left(\sum_{\tau} w_{\tau} \left(1 - \frac{k}{n} \right) \right) \hat{m}_{wf}^2
\end{aligned}$$

(2.3)

- Wilcoxon svertinė ranginė autokoreliacija

$$\hat{\rho}_{wf}(k) = \left\{ \frac{1}{\sum_{t=1}^{n-k} w_t w_{t+k} (n-k)} \sum_{t=1}^{n-k} w_t w_{t+k} \log \left(\frac{R_{t+k}}{n+1-R_{t+k}} \right) - \hat{m}_{wf} \right\} / \hat{\sigma}_{wf}, \quad (2.4)$$

čia

$$\begin{aligned} \hat{m}_{wf} &= \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{1 \leq i_1 \neq i_2 \leq n} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \leq n} w_{i_1} w_{i_2} \left(\frac{2i_1}{1 + \frac{1}{\sum_{i_1} 1}} - 1 \right) \log \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1} - i_2} \right) \end{aligned} \quad (2.5)$$

ir

$$\begin{aligned} \hat{\sigma}_{wf}^2 &= \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{i_1 i_2} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \leq n} \left[w_{i_1} w_{i_2} \left(\frac{2i_1}{1 + \frac{1}{\sum_{i_1} 1}} - 1 \right) \log \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1} - i_2} \right) \right]^2 \\ &+ \frac{2 \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2k}{\sum_{i_1 i_2 i_3} 1} \right) \right)}{\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\ &\times \frac{1}{\left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3} 1} \right) \right) \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \leq n} w_{i_1} w_{i_2}^2 w_{i_3} \left(\frac{2i_1}{1 + \frac{1}{\sum_{i_1} 1}} - 1 \right) \left(\frac{2i_2}{1 + \frac{1}{\sum_{i_2} 1}} - 1 \right) \end{aligned}$$

$$\begin{aligned}
& \times \log\left(\frac{i_3}{1 + \frac{1}{\sum_{i_n} 1} - i_3}\right) \log\left(\frac{i_4}{1 + \frac{1}{\sum_{i_4} 1} - i_4}\right) \\
& + \left\{ \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right)^2 - \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right) \left(\frac{2k+3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right. \\
& \quad \left. + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right)^2 k^2 + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right) 5k \right\} \\
& \times \frac{1}{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right) \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \quad \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \quad \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \neq i_4 \leq n} \sum \sum \sum w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(\frac{2i_1}{1 + \frac{1}{\sum_{i_1} 1}} - 1 \right) \\
& \times \left(\frac{2i_2}{1 + \frac{1}{\sum_{i_n} 1}} - 1 \right) \log\left(\frac{i_3}{1 + \frac{1}{\sum_{i_n} 1} - i_3}\right) \log\left(\frac{i_4}{1 + \frac{1}{\sum_{i_4} 1} - i_4}\right) - \left(\sum_t w_t \left(1 - \frac{k}{n} \right) \right) \hat{m}_{wf}^2
\end{aligned} \tag{2.6}$$

- Laplace svertinè ranginè autokoreliacija

$$\hat{\rho}_{wf}(k) = \frac{\left\{ \frac{1}{\sum_{t=1}^{n-k} w_t w_{t+k} (n-k)} \times \sum_{t=1}^{n-k} w_t w_{t+k} \text{sign} \left(R_t - \frac{n+1}{2} \right) F_{\sigma}^{-1} \left(\frac{R_{t+k}}{n+1} \right) - \hat{m}_{wf} \right\}}{\hat{\sigma}_{wf}}, \tag{2.7}$$

čia

$$\hat{m}_{wf} = \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{1 \leq i_1 \neq i_2 \leq n} 1} \right) \right)}$$

$$\times \sum_{1 \leq i_1 \neq i_2 \leq n} \sum_{1 \leq i_1 \neq i_2 \leq n} w_{i_1} w_{i_2} \text{sign} \left(i_1 - \frac{1 + \frac{1}{\sum_{i_1} 1}}{2} \right) F_{\theta}^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \quad (2.8)$$

ir

$$\begin{aligned} \hat{\sigma}_{wf}^2 &= \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{i_1 i_2} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \leq n} \left[w_{i_1} w_{i_2} \text{sign} \left(i_1 - \frac{1 + \frac{1}{\sum_{i_1} 1}}{2} \right) F_{\theta}^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right]^2 \\ &+ \frac{2 \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2k}{\sum_{i_1 i_2 i_3} 1} \right) \right)}{\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\ &\times \frac{1}{\left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3} 1} \right) \right) \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\ &\times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \leq n} \sum_{1 \leq i_1 \neq i_2 \neq i_3 \leq n} w_{i_1} w_{i_2}^2 w_{i_3} \text{sign} \left(i_1 - \frac{1 + \frac{1}{\sum_{i_1} 1}}{2} \right) \text{sign} \left(i_2 - \frac{1 + \frac{1}{\sum_{i_2} 1}}{2} \right) \\ &\quad \times F_{\theta}^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) F_{\theta}^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) \\ &+ \left\{ \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right)^2 - \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right)^2 \left(\frac{2k+3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right. \\ &\quad \left. + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right)^2 k^2 + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right) 5k \right\} \\ &\times \frac{1}{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\ &\times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right) \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \end{aligned}$$

$$\begin{aligned}
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \neq i_4 \leq n} \sum \sum w_{i_1} w_{i_2} w_{i_3} w_{i_4} \operatorname{sign} \left(i_1 - \frac{1 + \frac{1}{\sum_{i_1} 1}}{2} \right) \\
& \times \operatorname{sign} \left(i_2 - \frac{1 + \frac{1}{\sum_{i_2} 1}}{2} \right) F_s^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) F_s^{-1} \left(\frac{i_4}{1 + \frac{1}{\sum_{i_4} 1}} \right) - \left(\sum_t w_t \left(1 - \frac{k}{n} \right) \right) \hat{m}_{wf}^2,
\end{aligned}$$

$$\text{čia } F_s^{-1}(u) = \begin{cases} \log(2u) & 0 < u \leq \frac{1}{2} \\ -\log(2-2u) & \frac{1}{2} < u < 1 \end{cases}.$$

(2.9)

- Spearman svertinė ranginė autokoreliacija

$$\hat{\rho}_{wS}(k) = \frac{\hat{\gamma}_{wS}(k)}{\hat{\gamma}_{wS}(0)},$$

(2.10)

čia

$$\hat{\gamma}_{wS}(k) = \frac{\sum_{t=1}^{n-k} (R_t - \bar{R}_w)(R_{t+k} - \bar{R}_w) w_t w_{t+k}}{\sum_{t=1}^{n-k} w_t w_{t+k} \left(1 - \frac{k}{n} \right)}$$

(2.11)

$$\text{ir } \bar{R}_w = \sum_{t=1}^n R_t w_t / \sum_{t=1}^n w_t.$$


(2.12)

Pradėjus vykdyti ranginių autokorelacijų skaičiavimus paaiškėjo, kad norint apskaičiuoti vieno muzikinio kūrinio partitūrą, pavyzdžiui: kuriame yra $n=137$ stebėjimai su vėlavimu $k=100$ programa skaičiuoja apie 48 valandas. Norint kūrinį alizuoti visais keturiais metodais, tai galėtų užtrukti daugiau nei 100 valandų. Didinant stebinių ir atsilikimo žingsnių skaičių skaičiavimo laikas tik ilgėtų. Dėl to tyrimo metu buvo siekta ir bandyta sutrumpinti programos skaičiavimo laiką. Visų

pirma reikėjo išsiaiškinti, kuriuose skaičiavimuose programa užtrunka ilgiausiai ir kaip tuos skaičiavimus galima sutrumpinti ar koreguoti.


Darant įvairias prielaidas ir analizuojant programos kodo struktūrą: išvedant tarpinius skaičiavimo rezultatus, sekant kiek laiko programa užtrunka gaunant vieną ar kitą tarpinį rezultatą, buvo nustatyta, kad daugiausia laiko yra sugaištama kuomet yra skaičiuojami ranginių autokoreliacijų vidurkių ir dispersijos parametrai. Kadangi, jie yra skaičiuojami tik Van der Vaerdeno, Laplaso ir Vilkoksono skirstinių atveju, skaičiuojant Spyrmanno metodu jų nėra, dėl to rezultatai yra gaunami greitai. Remiantis gautomis išvadomis, buvo analizuojami tik tie metodai, kuriuose buvo vykdomi koeficientų skaičiavimai. Atsitiktinai pasirinktas kūrinys, kuris buvo panaudotas tarpiniams rezultatams gauti ir išanalizuoti. Pastebėta, kad beveik visą skaičiavimo laiko dalį atima dispersijos $\hat{\sigma}_{wf}^2$ skaičiavime esanti keturių dėmenų suma (žr. priedą Nr. 1), antroj vietoj būtų trijų iš eilės einančių trijų dėmenų suma (žr. priedą Nr. 2). Programos kode koeficientų skaičiavimas yra išskaidytas į atskiras dalis ir tik pabaigoje yra apjungiamas į vieną formulę, toks kodavimo būdas lengvai leido išskirti konkrečias problemines vietas. Kadangi visi kiti likę skaičiavimai buvo vykdomi normaliu tempu, jie liko nepakitę. Išsiryginus, kurios programos vietos yra problemiškesnės, buvo išvesti tarpiniai dispersijos skaičiavimo rezultatai ir pastebėta, kad reali dispersija mažai kuo skiriasi nuo pirmojo dėmens (žr. priedą Nr. 3). Tai reiškia, kad likę kiti formulės dėmenys nereikšmingai įtakoja galutinį dispersijos rezultatą. Siekiant išanalizuoti kuo daugiau kūrinių, taupant laiką ir paaukojant rezultatų tikslumą buvo atsisakyta skaičiuoti likusių dispersijos formulės dėmenis ir palikta sutrumpinta - pakoreguota formulė (žr. priedą Nr. 4). Gauti tarpiniai rezultatai buvo palyginti tarpusavyje.

Naudojant pilną dispersijos formulę:




2.1 pav. Van der Vaerdeno svartinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)

Naudojant dalinai sutrumpintą dispersijos formulę:



2.2 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)

Naudojant sutrumpintą dispersijos formulę:




2.3 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)

Kaip matome iš autokoreliacijos ir pasikliautinių intervalų grafiku, duomenys skiriasi tūkstantosiomis dalimis (**žr. priedą Nr. 5**). Įvertinus autokoreliacijos ir pasikliautinių intervalų paklaidas, gauname jog tarpiniai ir galutiniai rezultatai skiriasi vos 0,32-0,35%. Įvertinus, tai jog prarandame tik tokią rezultatų tikslumo dalį, tačiau gerokai laimime laiko atžvilgiu, tyrimo metu buvo nuspręsta naudoti sutrumpintą – pakoreguotą dispersijos formulę.


2.2.1 HORIZONTALI REZULTATŲ ANALIZĖ

Horizontali analizė buvo skirta metodų palyginimui. Analizės tikslas buvo sužinoti, kuris metodas jautriausiai reaguoja į natų priklausomybę. Tarpusavyje buvo lygintos Van der Vaerdeno, Laplaso, Vilkoksono ir Spyrmano svertinės ranginės autokoreliacijos. Pateikiami išskirtinesni tyrimo rezultatai.


1. Beethoven - Sonata No 14 Op 27 n. 2 - Moonlight in C-sharp minor (partitūra Nr. 1)



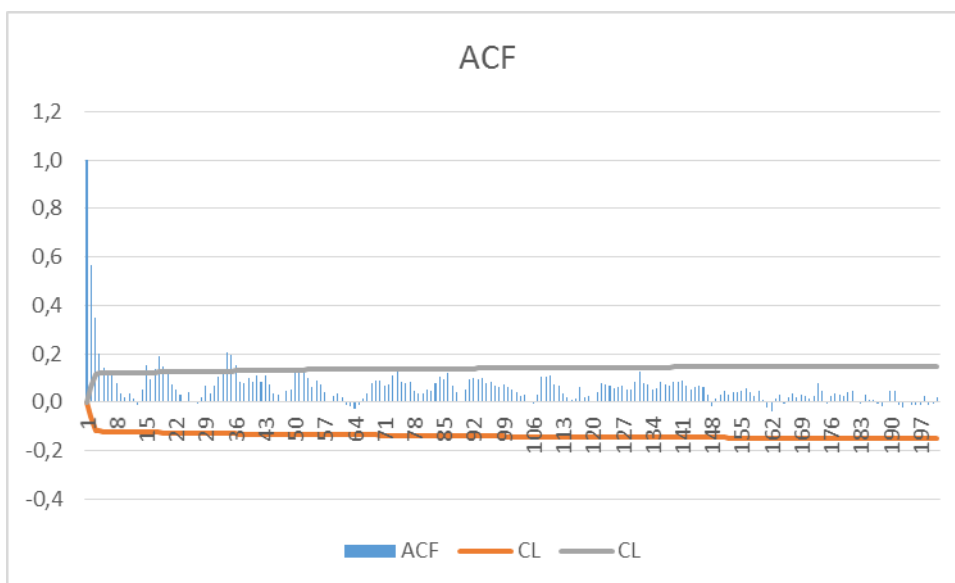
2.4 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.5 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




2.6 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




2.7 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)

Analizuojamas kūrinys - Beethoven - Sonata No 14 Op 27 n. 2 - Moonlight in C-sharp minor, pirma partitūra. Iš autokoreliacijos grafikų matome, jog su visais metodais gauname gan panašias autokoreliacijos vertes ir atsispindintį kūrinio pasikartojamumą. Visais keturiais metodais paskaičiuota autokoreliacija parodo, jog kūrinys silpnai atkartoja save du kartus: ties 15-20 ir 30-36 natomis. Visais atvejais gauname statiškai reikšmingus rezultatus: tarp natų egzistuoja reikšmingas statistinis ryšys.


2. L. Debussy - Claude Clair Lune (partitūra Nr. 1)




2.8 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.9 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.10 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




2.11 pav. Spyrmans svertinė ranginė autokoreliacija ir pasikliautiniai intervalai

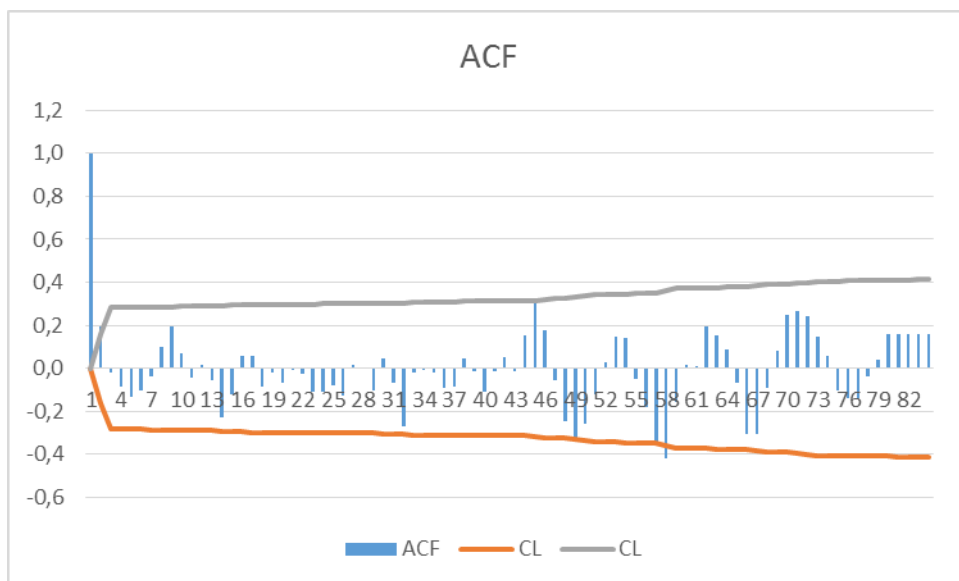
Analizuojamas kūrinys - Debussy-Claude Clair Lune, pirma partitūra. Šiuo atveju keturių metodų rezultatai skiriasi. Laplaso ir Spyrmans – atveju buvo rasti trys atsikartojimai, du iš jų buvo atvirkštinio atsikartojimo atvejai (tai reiškia, kad kūrinys atkartuoja save priešinga kryptim).

Laplaso ir Spyrmans būdu skaičiuotais metodais yra aptinkamas statistiškai reikšmingas ryšys tarp natų, tuo tarpu Van der Vaerdeno ir Vilkoksono metodas neaptinka jokio statistiškai reikšmingo ryšio.


3. Franz Shubert - Marche Militaire (partitūra Nr. 1)




2.12 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.13 pav. Laploso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.14 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.15 pav. Spyrmans svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


Analizuojamas kūrinys - Franz Shubert - Marche Militaire, pirma partitūra. Rezultatai labai artimi Debussy-Claude Clair Lune atveju: Laplaso ir Spyrmans atveju yra aptinkamas reikšmingas statinis ryšys tarp natų: ties 47-50 ir 57-58 natomis kūrinys atkartoja save priešinga kryptimi.

Vertinant rezultatus abstrakčiai visi metodai išskiria panašias tendencijas, bet jeigu pažiūrėtumėm į rezultatus iš arčiau pastebėtumėme, jog ne visi metodai išskiria statistiškai reikšmingą priklausomybę tuose pačiuose kūrinuose. Apibendrinant galima teigti, jog naudojant tuos pačius duomenis, gaunami skirtingi rezultatai.

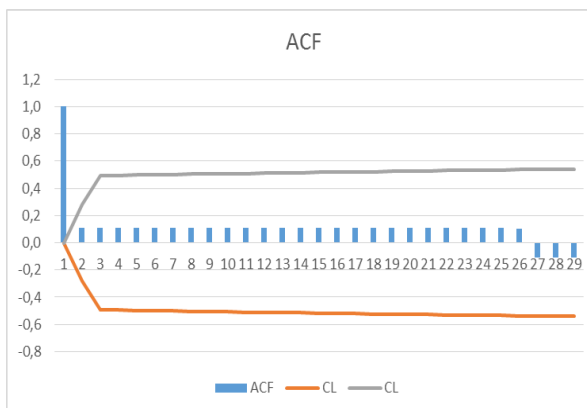
2.2.2 VERTIKALI REZULTATŲ ANALIZĖ

Šiai tyrimo daliai buvo pasirinkti vieno kompozitoriaus M. Clementi kūriniai. Muzio Clementi - nusipelnęs Italijos Klasicizmo epochos kompozitorius, pianistas, pedagogas ir dirigentas. Viso buvo ištirta vienuolika skirtingų šio kompozitoriaus partitūrų.


1. Sonatina 36-1, partitūra Nr. 1.



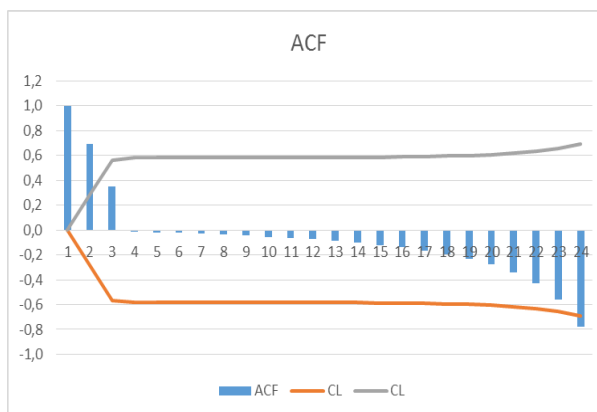
2.16 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.17 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautieji intervalai (CL)

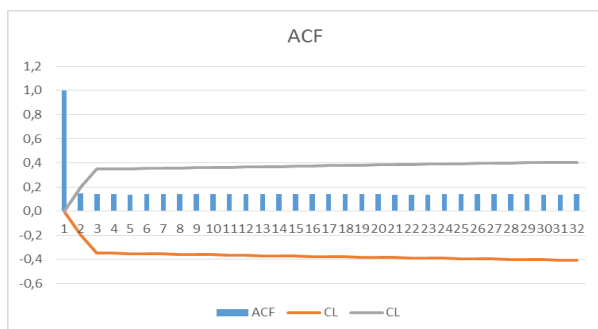


2.18 pav. Viloksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)

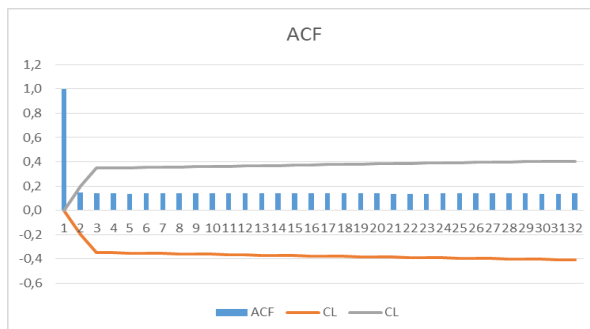


2.19 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautieji intervalai (CL)


2. Sonatina 36-2, partitūra Nr. 1.




2.20 pav. Van der Waerdeno svertinē ranginē autokoreliācija (ACF) ir pasīkļiautīnēji intervalai (CL)



2.21 pav. Laplaso svertinē ranginē autokoreliācija (ACF) ir pasīkļiautīnēji intervalai (CL)




2.22 pav. Vilkoḡsono svertinē ranginē autokoreliācija (ACF) ir pasīkļiautīnēji intervalai (CL)




2.23 pav. Spyrmano svertinē ranginē autokoreliācija (ACF) ir pasīkļiautīnēji intervalai (CL)

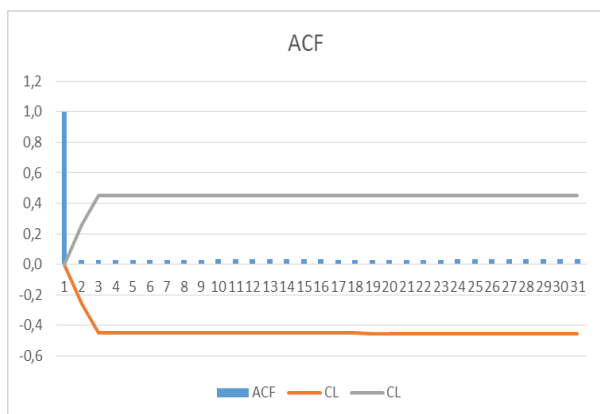
3. Sonatina 36-2, partitūra Nr. 2.




2.24 pav. Van der Waerdeno svertinē ranginē autokoreliācija (ACF) ir pasīkļiautīnēji intervalai (CL)



2.25 pav. Laplaso svertinē ranginē autokoreliācija (ACF) ir pasīkļiautīnēji intervalai (CL)




2.26 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)

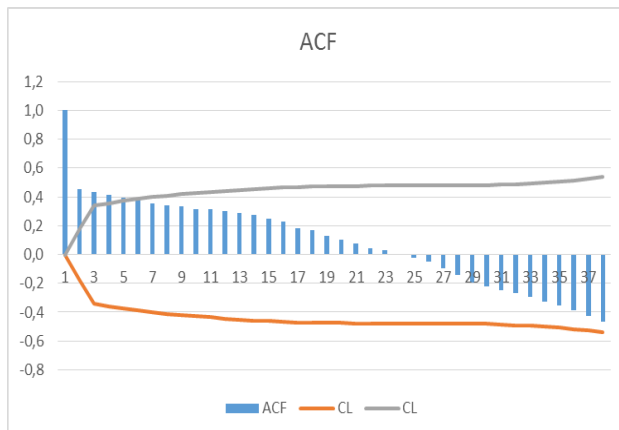


2.27 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


4. Sonatina 36-3, partitūra Nr. 1.




2.28 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



2.29 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




2.30 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




2.31 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


5. Sonatina 36-3, partitūra Nr. 2.




2.32 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



2.33 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




2.34 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




2.35 pav. Spirmano svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


6. Sonatina 36-4, partitūra Nr. 1.




2.36 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



2.37 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




2.38 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




2.39 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautieji intervalai (CL)


7. Sonatina 36-4, partitūra Nr. 2.




2.40 pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



2.41 pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautieji intervalai (CL)



2.42 pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




2.43 pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautieji intervalai (CL)

Išanalizavus M. Clementi kūrybą pastebime, kad kūriniai iš esmės nėra linkę save atkartoti ilgalaikėje perspektyvoje. Analizės metu galima išskirti svertinę Spyrmano ranginę autokoreliaciją. Šis metodas jautriausiai sureagavo į natų priklausomybę. Metodas beveik visais atvejais rado reikšmingą statistinį ryšį tarp muzikinio kūrinio natų. Mažiausiai jautrus pasirodė svertinis Vilkoksono ranginės autokoreliacijos metodas, nei viename iš M. Clementi tirtų kūrinių nerado jokio reikšmingo statistinio ryšio ir natų atsikartojimo. Likusios M. Clementi autokoreliacijos grafikus galime peržiūrėti priede Nr.8.

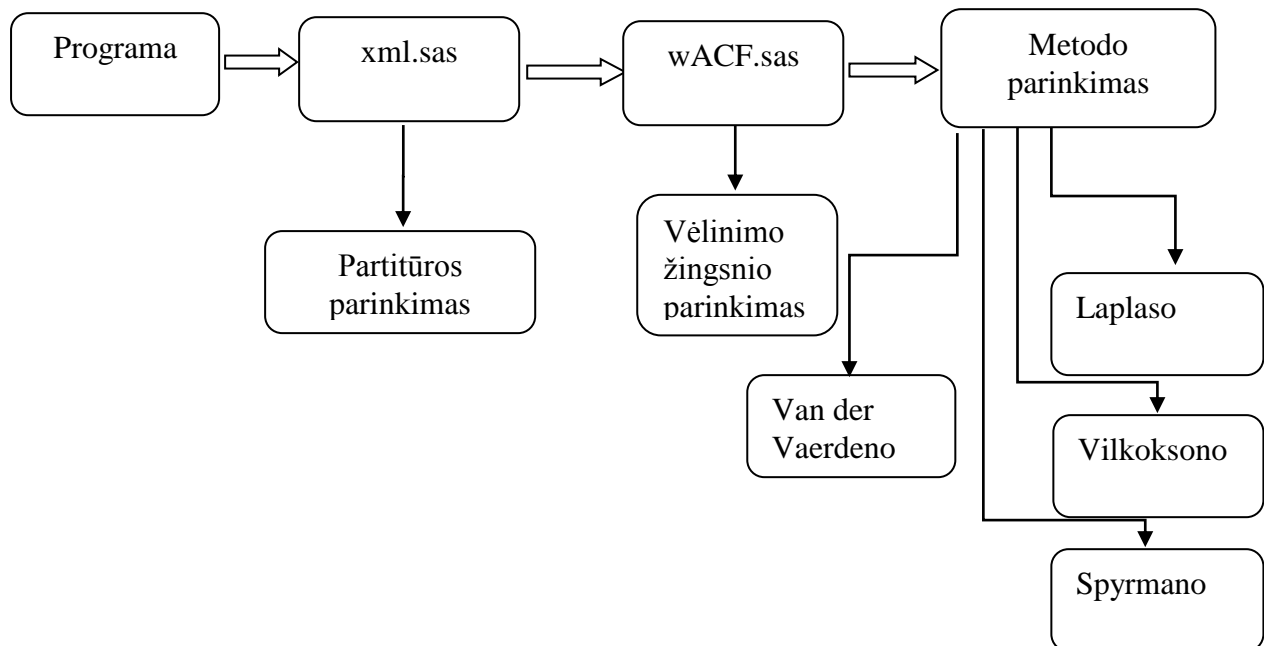
3 PROGRAMINĖ REALIZACIJA IR INSTRUKCIJA VARTOTOJUI

Programą sudaro du SAS programos kodai (žr. Pav. 3.1).



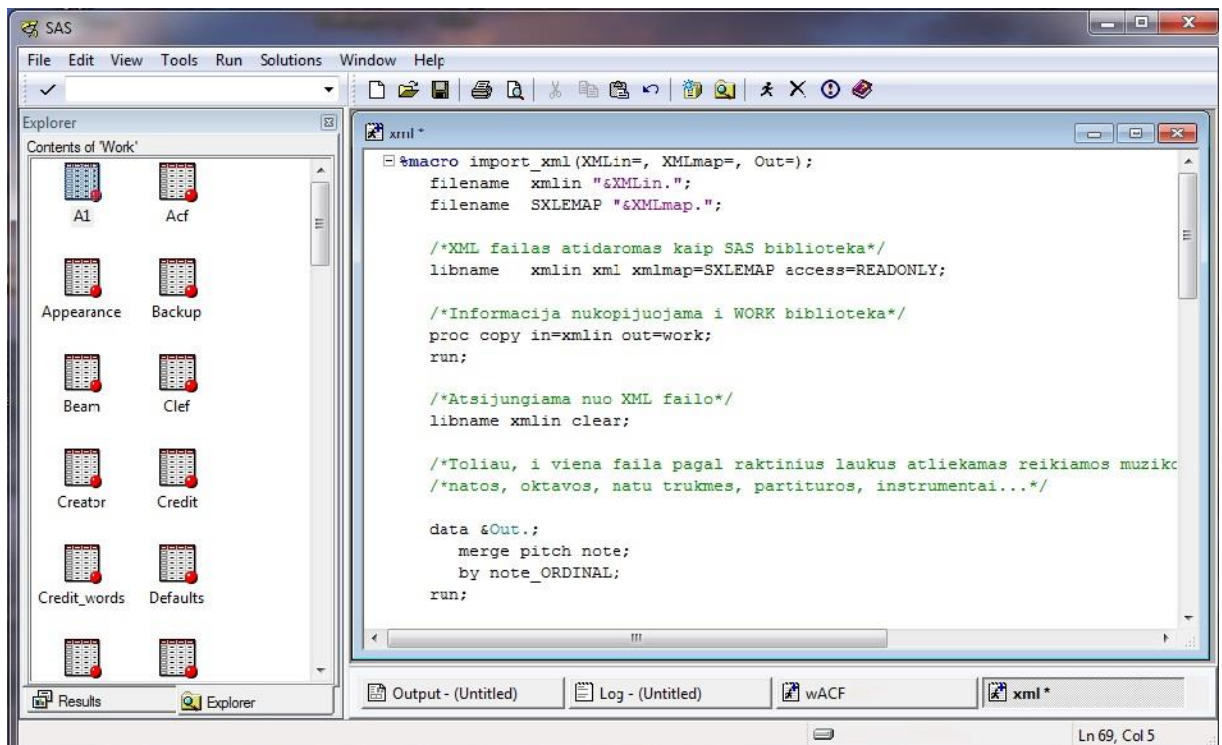
3.1 pav. Programos struktūra

Atidarius programą visų pirma turi būti atliktas duomenų nuskaitymas, tai yra padaroma *xml.sas* kodo pagalba paspaudus F8. Nuskaitant duomenis yra sukuriama pagrindinės bibliotekos, kuriose saugomi darbiniai SAS duomenų failai. *Xml.sas* faile yra parenkama kūrinių partitūra, tai daroma tik tuo atveju, kai *.xml* tipo faile yra daugiau nei viena partitūra. Antras žingsnis yra *wACF.sas* failo paleidimas. Jame yra parenkamas autokoreliacijos metodas. Atlikus šiuos veiksmus skaičiavimai yra paleidžiami paspaudus F8.

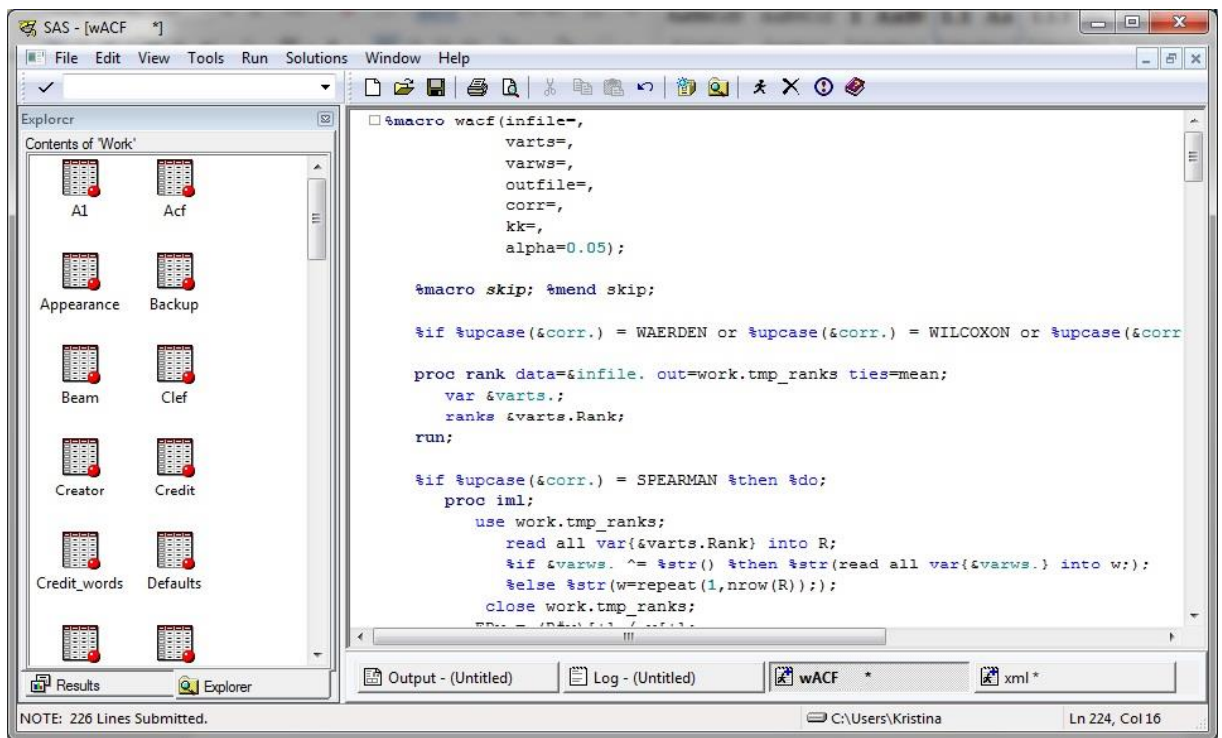


3.2 pav. Metodų įgyvendinimo struktūra programoje

Programą sudaro du langai: duomenų nuskaitymo ir metodo vykdymo.



3.3 pav. Duomenų nuskaitymo programos langas, *xml.sas*



3.4 pav. Svertinės ranginės autokoreliacijos programos langas, *wACF.sas*

Atlikus duomenų nuskaitymą, duomenys iš *.xml* yra nuskaityti ir išsaugomi A1 duomenų bazės SAS faile, perjungus programos langą į *wACF.sas* failą ir paleidus skaičiavimus, autokoreliacijos, pasikliautinųjų intervalų ir paklaidų rezultatai yra sugeneruojami *Acf.sas* faile. Iš programos rezultatų failo duomenys transponuojami į *.xls* rezultatų failą.

4 DISKUSIJOS

4.1 ANALIZUOJAMŲ DUOMENŲ IMTIS

Muzikinių kūrinių duomenų analizei buvo parinkti klasikinės muzikos kūriniai. Pagrindą sudarė XVIII a. pab. XIX a. pr. gyvenusių kompozitorių kūryba. Patys kompozitoriai buvo pasirinkti atsitiktinai siekiant išanalizuoti kuo daugiau to laikmečio skirtingų kompozitorių kūrinius.

Pastebėta, kad kai kuriems kompozitoriams, pvz. tokiems kaip M. Clementi ar L. van Bethoveni yra būdingas kūrinio atsikartojimas pačioje kūrinio pradžioje, tuo tarpu C. Debussy kūrybai atsikartojimas yra aptinkamas ties 50-60 natomis - kūriniui įsibėgėjus. Taip pat galima išskirti grupę kompozitorių, kurių kūrybai būdingas unikalumas, neatsikartojamumas. Šiai grupei galėčiau priskirti V. A. Mocartą, P. Čaikovskį: šių autorių kūrinių natų autokoreliacija viso kūrinio metu yra artima 0.

Pastebėjimai gali būti netikslūs, kadangi, norint ištirti vieno kompozitoriaus kūrybos bruožą, reikėtų tirti visus jo kūrinius. Tyrime atliktų skaičiavimų duomenų imtis nėra didelė, dėl to yra sudėtinga konstatuoti kompozitoriaus kūrybos bruožus ar ypatumus.

4.2 TYRIMO PRITAIKYMAS

Mūsų dienomis muzika yra ne tik menas ir kūryba, bet ir komercija. Kiekvienais metais organizuojami muzikinių kūrinių konkursai, kiekvienais metais yra sudaromi dainų reitingai pagal jų populiarumą ir klausytojų skaičių. Tyrimas gali būti labai naudingas tiriant būtent tokius muzikinius kūrinius. Pasvarstykime. O kas jeigu konkurse pripažinto muzikinio kūrinio melodijos linija turi reikšmingą statistinį ryšį? Galėtumėme išsiaiškinti, ar toks kūrinys, kuriame natos turi tarpusavio priklausomybę koreliuoja su klausytojo klausa, t.y. muzikinis kūrinys yra pripažintas konkurso nugalėtoju arba yra reitingo viršūnėse. Juk muzika turi būti harmoninga, kad jos būtų malonu klausytis, todėl tyrime naudoti metodai gali padėti rasti atsakymą į šį klausimą.

4.3 REZULTATŲ PALYGINIMAS

Naudotų metodų svertinei ranginei autokoreliacijai gauti rezultatai panašūs, tačiau pasitaikydavo atveju, kai vienas ar kitas metodas išskirdavo kūrinio atsikartojimą, tuo tarpu kiti metodai statiškai reikšmingų ryšių nerasdavo. Rezultatai nėra galutinai apribotami, t.y. nežinoma ar galėtume šiuos rezultatus taikyti visiems klasikinės muzikos kūriniams, kadangi gauti rezultatai buvo įvairiapusiški.

Išskirti būtų galima svertinį Spyrmano ranginės autokoreliacijos metodą, kadangi šis metodas pasižymėjo savo jautrumu: dažniausiai rasdavo reikšmingą statistinį ryšį tarp natų, kai kiti autokoreliacijos metodai jokio ryšio neaptikdavo. Tai galėjo nutikti dėl to, kad svertinis Spyrmano

ranginės autokoreliacijos metodas skiriasi nuo kitų naudotų metodų. Jis yra grindžiamas Stjudento statistika ir jame nėra naudojami normavimo parametrai.

5 IŠVADOS

Tyrimo metu gautos kelios išvados:

- Pagrindinis darbo tikslas buvo patvirtinti ar paneigti J. Moorer hipotezę, jog „Muzikos teorijoje teigiama, kad daugumos kompozitorių muzikos kūrinų melodijos linijai būdingas vystymas ir unikalus nepakartojamumas“. Remiantis gautais tyrimo rezultatais, ši hipotezė yra atmetama. Daugumai muzikos kūrinų išties nėra būdingas atsikartojamumas, ypač jei kalbame apie klasikinę muziką. Tačiau ne visų kūrinų melodijos linija, patekusių į analizuojamąją imtį, turėjo unikalų nepakartojamumą. Keletas kūrinų tokių kaip: Beethoven - Sonata No 14 Op 27 n. 2 - Moonlight in C-sharp minor, pirma partitūra; L. Debussy – Claude Clair Lune, pirma partitūra; Franz Shubert - Marche Militaire, pirma partitūra atkartoją save partitūros eigoje. Žinoma viskas priklauso nuo pasirinktų kūrinų grupės, tačiau įsitikinome, kad klasikinė muzika išties pasižymi savo unikalumu.
- Kitas tyrimo tikslas buvo patikrinti metodų tinkamumą muzikėje analizėje, kadangi tokio pobūdžio tyrimuose metodai yra visiškai nauji ir neišbandyti. Išanalizavus visus tyrimo rezultatus ir palyginus visus metodus tarpusavyje paaiškėjo, jog informatyviausias yra – svertinis Spyrmano ranginės autokoreliacijos metodas. Skaičiuojant autokoreliaciją šiuo būdu buvo dažniausiai randamas statistiškai reikšmingas ryšys tarp natų, randamos kūrinio atsikartojamumo vietos. Rečiausiai pasitaikydavo toks rezultatas taikant – Vilkoksono metodą. Tokie tyrimo rezultatai leidžia padaryti išvadą, jog taikant svertinę Vilkoksono ranginę autokoreliaciją ir nustačius reikšmingą autokoreliaciją kiti metodai ją taip pat nustatys.-
Tyrimas parodė, jog muzikinėje analizėje išties gali būti taikomi svertiniai ranginės autokoreliacijos metodai, iš kurių jautriausias yra Spyrmano k vėlinimo svertinė ranginė autokoreliacija.
- Tyrimo metu buvo koreguojamos formulės – sutrumpintas dispersijos skaičiavimas (Van der Vaerden, Laplaso ir Vilkoksono metuose). Gauti rezultatai leido padaryti išvadas, kad net ir stipriai pakoregavus formules galutiniai rezultatai pakito vos 0,33-0,35 %, tačiau net ir toks rezultatų tikslumo paaukojimas leido gerokai sutaupyti laiko ir ištirti žymiai daugiau kūrinų.

6 REKOMENDACIJOS

- Norint tiksliai apskaičiuoti svertines rangines autokoreliacijas su normavimo parametrais užima kelias ir daugiau dienų. Problema yra dispersijos skaičiavime esantis trijų ir keturių sumų dėmuo. Išėitis optimizuoti programos kodą, sudėjus papildomas sąlygas į ciklus, kas iš esmės galėtų sutrumpinti veikimo laiką.
- Tyrime buvo naudojama svertinė funkcija, kuri suteikė atitinkamas svorio reikšmes tik funkcijoms, bet ne funkcijos parametrms. Dvigubas svertinės funkcijos panaudojimas galėtų leisti geriau išskirti reikšmingus statistinius ryšius tarp natų.
- Šiame tyrime nėra išnaudotos visos natų priklausomybės galimybės – būtų galima vertinti atskirų natų priklausomybę suskaidžius į atitinkamas grupes pagal instrumentus.
- Tyrimo tikslas buvo išanalizuoti kuo daugiau skirtingų kompozitorių kūrybą ir metodų tinkamumą, tačiau dėl šios priežasties buvo pasirinkta tik po kelis vieno kompozitoriaus kūrinius. Rekomenduotina atrinkti daugiau konkretaus kompozitoriaus kūrinių tam, kad būtų galima išskirti kompozitoriui būdingus kūrybos bruožus.
- Tyrimas buvo atliktas tik su klasikinės muzikos kūriniais. Įdomu būtų patikrinti šiuolaikinės muzikos tendencijas. Tikėtina, kad reikšmingas statistinis ryšys atsispindėtų didesnėje imtyje.

PADĖKOS

Dėkoju doc. dr. Tomui Ruzgui už patarimus ir pagalbą įgyvendinant statistinius tyrimus.

ŠALTINIAI IR LITERATŪRA

1. Altyeb A. A., Sharif S. M., Abumaaly I.A. - Modeling of Autocorrelation Functions Using Weighted Non-linear least Squares, Iš *Mircosoft Academic Search*, 2006, [žiūrėta 2014-02-25]. Prieiga per internetą <http://65.54.113.26/Publication/4839426/modeling-of-autocorrelation-functions-using-weighted-non-linear-least-squares>
2. Autocorrelation, [žiūrėta 2014-04-20]. Prieiga per internetą <http://en.wikipedia.org/wiki/Autocorrelation>
3. Benson D.J. “ Music A Mathematical Offering”, Cambridge University Press 2007.
4. Beran J. - Statistics in Musicology. Chapman and Hall press, 2004.
5. Fauvel J., Flood R. and Wilson R.J. - Music and Mathematics from Pythagoras to Fractals
6. Gareth D. Loy - Musimathics the Mathematical Foundations of Music, The MIT Press Cambridge, 2006.
7. Hallin M. and Madan, Puri L, Ingenbleek J.F. - Linear Serial Rank Tests for Randomness Against Arma Alternatives. Iš *Journal of Time Series Analysis*, 2008, sausio 28 [žiūrėta 2014-03-15]. Prieiga per internetą <http://onlinelibrary.wiley.com/doi/10.1111/j.1467-9892.1987.tb00004.x/abstract>
8. Hallin M. and Madan, Puri L. - Rank tests for time series analysis a survey, IMA preprint series, 1991.
9. Harkleroad L. - The Math Behind the Music. Cambridge University Press 2006.
10. Judith C. Brown - Determination of the meter of musical scores by autocorrelation. Iš *The Journal of the Acoustical Society of America*, 1993, [žiūrėta 2014-03-25]. Prieiga per internetą <http://scitation.aip.org/content/asa/journal/jasa/94/4/10.1121/1.407518>
11. Kašponis, Rimtautas. Lietuvių muzikos melodika ir harmonija. 1992.
12. Math and Music - Exploring the connections, College of the Holy Cross, 2008.
13. Mathematics of Music - undergraduate research. Iš *Journal of Undergraduate Research XIV*, 2006 [žiūrėta 2014-02-15]
14. Micheloud, François-Xavier. Correspondence Analysis. 1997.
15. Music and mathematics, [žiūrėta 2014-02-10] http://en.wikipedia.org/wiki/Music_and_mathematics.
16. Rezaul, K.M - Identifying Long-range Dependent Network Traffic through Autocorrelation Functions, 2007, [žiūrėta 2014-03-20]. Prieiga per internetą http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4367903&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D4367903

17. SAS Institute, Inc. SAS/STAT® User's Guide. Vol. Version 8. Cary, NC: SAS Institute Inc., 1999.
18. SAS, %MACRO Statement, [žiūrėta 2014-02-15]. Prieiga per internetą <http://support.sas.com/documentation/cdl/en/mcrolref/61885/HTML/default/viewer.htm#macro-stmt.htm>
19. Temperley D.- Music and Probability, The MIT Press Cambridge, 2007.
20. Time Series [žiūrėta 2014-05-15]. Prieiga per internetą http://en.wikipedia.org/wiki/Time_series
21. Weight function [žiūrėta 2014-05-15]. Prieiga per internetą http://en.wikipedia.org/wiki/Weight_function

PRIEDAI

PRIEDAS NR. 1 FORMULĖ

$$\begin{aligned}
& \left\{ \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right)^2 - \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \right) \left(\frac{2k+3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right. \\
& \left. + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right)^2 k^2 + \left(\frac{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4}}{\sum_{i_1 i_2 i_3 i_4} 1} \right) 5k \right\} \\
& \times \frac{1}{\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right) \left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{3}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3 i_4} w_{i_1} w_{i_2} w_{i_3} w_{i_4} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3 i_4} 1} \right) \right)} \\
& \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \neq i_4 \leq n} \sum \sum w_{i_1} w_{i_2} w_{i_3} w_{i_4} \phi \left(F^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \\
& \times \phi \left(F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right) F^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) F^{-1} \left(\frac{i_4}{1 + \frac{1}{\sum_{i_4} 1}} \right)
\end{aligned}$$

PRIEDAS NR. 2 FORMULĖ

$$\begin{aligned}
& \frac{2 \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2k}{\sum_{i_1 i_2 i_3} 1} \right) \right)}{\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{1}{\sum_{i_1 i_2 i_3} 1} \right) \right)} \\
& \times \frac{1}{\left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{2}{\sum_{i_1 i_2 i_3} 1} \right) \right) \left(\sum_{i_1 i_2 i_3} w_{i_1} w_{i_2}^2 w_{i_3} \left(1 - \frac{k}{\sum_{i_1 i_2 i_3} 1} \right) \right)}
\end{aligned}$$

$$\begin{aligned} & \times \sum_{1 \leq i_1 \neq i_2 \neq i_3 \leq n} \sum w_{i_1} w_{i_2}^2 w_{i_3} \phi \left(F^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) \phi \left(F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right) \\ & \times F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) F^{-1} \left(\frac{i_3}{1 + \frac{1}{\sum_{i_3} 1}} \right) \end{aligned}$$

PRIEDAS NR. 3 FORMULĖ

$$\begin{aligned} & \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{i_1 i_2} 1} \right) \right)} \\ & \times \sum_{1 \leq i_1 \neq i_2 \leq n} \left[w_{i_1} w_{i_2} \phi \left(F^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right]^2 \end{aligned}$$

PRIEDAS NR. 4 FORMULĖ

$$\hat{\sigma}_{wf}^2 = \frac{1}{\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(\sum_{i_1 i_2} w_{i_1} w_{i_2} \left(1 - \frac{1}{\sum_{i_1 i_2} 1} \right) \right)} \times \sum_{1 \leq i_1 \neq i_2 \leq n} \left[w_{i_1} w_{i_2} \phi \left(F^{-1} \left(\frac{i_1}{1 + \frac{1}{\sum_{i_1} 1}} \right) \right) F^{-1} \left(\frac{i_2}{1 + \frac{1}{\sum_{i_2} 1}} \right) \right]^2$$

PRIEDAS NR. 5 AUTOKORELIACIJOS LENTELĖS

1. LENTELĖ

Duomenys gauti naudojant koreguota dispersormulę.

Duomenys gauti naudojant pirminę dispersijos sijos Formulę.

Vėlinimo žingsnis	Autokoreliacija	Apatinis pasikliautinis intervalas	Viršutinis pasikliautinis intervalas
0	1	0	0
1	0,4076	-0,12259	0,12259
2	0,38679	-0,22379	0,22379
3	0,36708	-0,23362	0,23362
4	0,34683	-0,24213	0,24213

Vėlinimo žingsnis	Autokoreliacija	Apatinis pasikliautinis intervalas	Viršutinis pasikliautinis intervalas
0	1	0	0
1	0,40907	-0,4076	0,4076
2	0,38818	-0,38679	0,38679
3	0,36838	-0,36708	0,36708
4	0,34805	-0,34683	0,34683

5	0,33175	-0,24948	0,24948
6	0,31027	-0,25603	0,25603
7	0,29493	-0,26162	0,26162
8	0,27866	-0,26657	0,26657
9	0,25682	-0,27091	0,27091
10	0,24118	-0,27454	0,27454
11	0,22274	-0,27771	0,27771
12	0,20256	-0,28038	0,28038
13	0,18292	-0,28257	0,28257
14	0,15873	-0,28435	0,28435
15	0,13586	-0,28568	0,28568
16	0,10698	-0,28665	0,28665
17	0,09014	-0,28724	0,28724
18	0,06168	-0,28767	0,28767
19	0,04181	-0,28787	0,28787
20	0,02155	-0,28796	0,28796
21	-0,0061	-0,28798	0,28798
22	-0,02381	-0,28799	0,28799
23	-0,04879	-0,28802	0,28802
24	-0,07401	-0,28814	0,28814
25	-0,1005	-0,28843	0,28843
26	-0,13083	-0,28895	0,28895
27	-0,1618	-0,28984	0,28984
28	-0,19341	-0,29119	0,29119
29	-0,2181	-0,29312	0,29312
30	-0,23359	-0,29555	0,29555
31	-0,24942	-0,29831	0,29831
32	-0,24781	-0,30143	0,30143
33	-0,24616	-0,30447	0,30447
34	-0,24448	-0,30745	0,30745
35	-0,24275	-0,31036	0,31036
36	-0,2492	-0,3132	0,3132
37	-0,24749	-0,31616	0,31616
38	-0,24553	-0,31906	0,31906
39	-0,23356	-0,32189	0,32189
40	-0,22132	-0,32443	0,32443
41	-0,19971	-0,32669	0,32669
42	-0,17759	-0,32852	0,32852
43	-0,15492	-0,32996	0,32996
44	-0,13168	-0,33105	0,33105
45	-0,11122	-0,33183	0,33183
46	-0,08714	-0,33239	0,33239
47	-0,06641	-0,33274	0,33274
48	-0,05472	-0,33294	0,33294
49	-0,0296	-0,33307	0,33307
...

5	0,33291	-0,33175	0,33175
6	0,31135	-0,31027	0,31027
7	0,29594	-0,29493	0,29493
8	0,27962	-0,27866	0,27866
9	0,2577	-0,25682	0,25682
10	0,242	-0,24118	0,24118
11	0,22349	-0,22274	0,22274
12	0,20324	-0,20256	0,20256
13	0,18353	-0,18292	0,18292
14	0,15926	-0,15873	0,15873
15	0,13631	-0,13586	0,13586
16	0,10734	-0,10698	0,10698
17	0,09043	-0,09014	0,09014
18	0,06188	-0,06168	0,06168
19	0,04195	-0,04181	0,04181
20	0,02162	-0,02155	0,02155
21	-0,00612	0,0061	-0,0061
22	-0,02389	0,02381	-0,02381
23	-0,04894	0,04879	-0,04879
24	-0,07425	0,07401	-0,07401
25	-0,10082	0,1005	-0,1005
26	-0,13126	0,13083	-0,13083
27	-0,16232	0,1618	-0,1618
28	-0,19404	0,19341	-0,19341
29	-0,21881	0,2181	-0,2181
30	-0,23436	0,23359	-0,23359
31	-0,25024	0,24942	-0,24942
32	-0,24862	0,24781	-0,24781
33	-0,24697	0,24616	-0,24616
34	-0,24529	0,24448	-0,24448
35	-0,24356	0,24275	-0,24275
36	-0,25003	0,2492	-0,2492
37	-0,24832	0,24749	-0,24749
38	-0,24636	0,24553	-0,24553
39	-0,23436	0,23356	-0,23356
40	-0,22208	0,22132	-0,22132
41	-0,20041	0,19971	-0,19971
42	-0,17821	0,17759	-0,17759
43	-0,15546	0,15492	-0,15492
44	-0,13215	0,13168	-0,13168
45	-0,11162	0,11122	-0,11122
46	-0,08746	0,08714	-0,08714
47	-0,06666	0,06641	-0,06641
48	-0,05492	0,05472	-0,05472
49	-0,02971	0,0296	-0,0296
...

PRIEDAS NR. 6 PROGRAMOS KODAS

Failas xml.sas

```

%macro import_xml(XMLin=, XMLmap=, Out=);
  filename xmlin "&XMLin.";
  filename SXLEMAP "&XMLmap.";

  /*XML failas atidaromas kaip SAS biblioteka*/
  libname xmlin xml xmlmap=SXLEMAP access=READONLY;

  /*Informacija nukopijuojama i WORK biblioteka*/
  proc copy in=xmlin out=work;
  run;

  /*Atsijungiama nuo XML failo*/
  libname xmlin clear;

  /*Toliau, i viena faila pagal raktinius laukus atliekamas reikiamos muzikos
  kurinio informacijos apjungimas*/
  /*natos, oktavos, natu trukmes, partituros, instrumentai...*/

  data &Out.;
    merge pitch note;
    by note_ORDINAL;
  run;

  proc sql noprint;
    create table &Out. as
      select
        f.*,
        part.id
      from &Out. as f
        left join measure
          on f.measure_ORDINAL = measure.measure_ORDINAL
        left join part /*prijungiamos partituros*/
          on measure.part_ORDINAL = part.part_ORDINAL
      order by f.note_ORDINAL
    ;
  quit;

  data &Out.;
    set &Out.;
    if missing(Type) then __NATOS_ILGIS = 1;
    else if lowercase(Type) = 'breve' then __NATOS_ILGIS = 2;
    else if lowercase(Type) = 'whole' then __NATOS_ILGIS = 1;
    else if lowercase(Type) = 'half' then __NATOS_ILGIS = 1/2;
    else if lowercase(Type) = 'quarter' then __NATOS_ILGIS = 1/4;
    else if lowercase(Type) = 'eighth' then __NATOS_ILGIS = 1/8;
    else if lowercase(Type) = '16th' then __NATOS_ILGIS = 1/16;
    else if lowercase(Type) = '32nd' then __NATOS_ILGIS = 1/32;

    step_id = 0;
    if step = 'C' then step_id = 0;
    else if step = 'C#' then step_id = 1;
    else if step = 'D' then step_id = 2;
    else if step = 'D#' then step_id = 3;
    else if step = 'E' then step_id = 4;
    else if step = 'F' then step_id = 5;
    else if step = 'F#' then step_id = 6;
    else if step = 'G' then step_id = 7;
    else if step = 'G#' then step_id = 8;
    else if step = 'A' then step_id = 9;
    else if step = 'A#' then step_id = 10;
    else if step = 'B' then step_id = 11;
    else if missing(step) then step_id = -1;

    if step_id = -1 then
      midi = -1;
    else
      midi = (octave+1)*12+step_id;
  
```

```

drop step_id;
  if id = 'P1';

run;

%mend import_xml;
%import_xml (XMLin=%str(C:\Users\Kristina\Desktop\xml\Beethoven - FurElise.xml),
XMLmap=%str(C:\Users\Kristina\Desktop\Magistrinis\xmlmap.map), Out=al);

```

Failas wACF.sas

```

%macro wacf(infile=,
  varts=,
  varws=,
  outfile=,
  corr=,
  kk=,
  alpha=0.05);

  %macro skip; %mend skip;

  %if %upcase(&corr.) = WAERDEN or %upcase(&corr.) = WILCOXON or %upcase(&corr.) =
LAPLACE %then %let acf = f_rank;

  proc rank data=&infile. out=work.tmp_ranks ties=mean;
    var &varts.;
    ranks &varts.Rank;
  run;

  %if %upcase(&corr.) = SPEARMAN %then %do;
    proc iml;
      use work.tmp_ranks;
      read all var{&varts.Rank} into R;
      %if &varws. ^= %str() %then %str(read all var{&varws.} into w);
      %else %str(w=repeat(1,nrow(R)));
      close work.tmp_ranks;
      ERw = (R#w)[+] / w[+];
      d = R - ERw;
      n = nrow(d);
      start wacf(d,w,n,k);
      d1 = d[1:n-k];
      d2 = d[k+1:n];
      w1 = w[1:n-k];
      w2 = w[k+1:n];
      g = (d1#d2#w1#w2)[+] / (w1#w2)[+];
      return(g);
    finish wacf;
    do k = 0 to &kk.;
      if k = 0 then do;
        LAG = 0;
        se = 0;
        g = wacf(d,w,n,k);
        g0 = g;
        ci = 0;
      end;
      else do;
        LAG = LAG // k;
        if k > 1 then se = se // sqrt((1+2*(g#g)[+]/(g0*g0))/w[+]);
        else se = se // sqrt((1+2*0)/w[+]);
        g = g // wacf(d,w,n,k);
        ci = ci // (tinv(1-&alpha./2,n-1)/sqrt(w[+]-k-3));
      end;
    end;
  ACF = g / g0;
  cl = tinv(1-&alpha./2,n-1)*se;
  create &outfile. var{LAG ACF SE CL CI};
  append;
  quit;
%end;

```

```

%if &acf. = f_rank %then %do;
  proc iml;
    use work.tmp_ranks;
    read all var{&varts.Rank} into R;
    %if &varws. ^= %str() %then %str(read all var{&varws.} into w);
    %else %str(w=repeat(1,nrow(R)));
    close work.tmp_ranks;
    LAG = 0;
    ACF = 1;
    SE = 0;
    CI = 0;
    n=nrow(R);
    ii = t(do(1,n,1));

    %if %upcase(&corr.) = WAERDEN %then %do;
      start f1(a);
        f = quantile('NORMAL',a);
        return(f);
      finish f1;
      start f2(a);
        f = quantile('NORMAL',a);
        return(f);
      finish f2;
      a_i1 = ii / (n + 1);
      a_i2 = a_i1;
      a_R1 = R / (n + 1);
      a_R2 = a_R1;
    %end;

    %if %upcase(&corr.) = WILCOXON %then %do;
      start f1(a);
        f = a;
        return(f);
      finish f1;
      start f2(a);
        f = log(a);
        return(f);
      finish f2;
      a_i1 = 2 * ii / (n + 1) - 1;
      a_i2 = ii / (n + 1 - ii);
      a_R1 = 2 * R / (n + 1) - 1;
      a_R2 = R / (n + 1 - R);
    %end;

    %if %upcase(&corr.) = LAPLACE %then %do;
      start f1(a);
        f = sign(a);
        return(f);
      finish f1;
      start f2(a);
        f = log(2*a) # (a <= 0.5) -log(2-2*a) # (a > 0.5);
        return(f);
      finish f2;
      a_i1 = ii - (n + 1) / 2;
      a_i2 = ii / (n + 1);
      a_R1 = R - (n + 1) / 2;
      a_R2 = R / (n + 1);
    %end;

    ff1_1 = f1(a_i1);
    ff1_2 = ff1_1;
    ff2_1 = f2(a_i2);
    ff2_2 = ff2_1;
    ff1_R = f1(a_R1);
    ff2_R = f2(a_R2);
  m = 0;
  w_sum = 0;
  do i1 = 1 to n;
    do i2 = 1 to n;
      if i1 ^= i2 then do;
        m = m + ff1_1[i1,] * ff2_1[i2,] * w[i1,] * w[i2,];
        w_sum = w_sum + w[i1,] * w[i2,];
      end;
    end;
  end;
end;

```

```

m = m / w_sum;

s1 = 0;
w_sum = 0;
n_sum = 0;
do i1 = 1 to n;
  do i2 = 1 to n;
    if i1 ^= i2 then do;
      s1 = s1 + (ff1_1[i1,] * ff2_1[i2,] * w[i1,] * w[i2,])##2;
      w_sum = w_sum + (w[i1,] * w[i2,])##2;
      n_sum = n_sum + 1;
    end;
  end;
end;
s1 = s1 / (n*(n-1)*w_sum/n_sum);

do k=1 to &kk.;

  s2 = 0;
  w_sum = 0;
  n_sum = 0;
  do i1 = 1 to n;
    do i2 = 1 to n;
      do i3 = 1 to n;
        if i1 ^= i2 & i1 ^= i3 & i2 ^= i3 then do;
          s2 = s2 + ff1_1[i1,] * ff1_2[i2,] * ff2_1[i2,] * ff2_2[i3,]
* w[i1,] * w[i2,] * w[i2,] * w[i3,];
          w_sum = w_sum + w[i1,] * w[i2,] * w[i2,] * w[i3,];
          n_sum = n_sum + 1;
        end;
      end;
    end;
  end;
  s2 = s2 * 2*(n-2*k) / (n*(n-1)*(n-2)*(n-k)*w_sum/n_sum);
  s3 = 0;
  w_sum = 0;
  n_sum = 0;
  do i1 = 1 to n;
    do i2 = 1 to n;
      do i3 = 1 to n;
        do i4 = 1 to n;
          if i1 ^= i2 & i1 ^= i3 & i1 ^= i4 & i2 ^= i3 & i2 ^= i4 & i3
^= i4 then do;
            s3 = s3 + ff1_1[i1,] * ff1_2[i2,] * ff2_1[i3,] *
ff2_2[i4,] * w[i1,] * w[i2,] * w[i3,] * w[i4,];
            w_sum = w_sum + w[i1,] * w[i2,] * w[i3,] * w[i4,];
            n_sum = n_sum + 1;
          end;
        end;
      end;
    end;
  end;
  s3 = s3 * (n##2-n*(2*k+3)+k##2+5*k) / (n*(n-1)*(n-2)*(n-3)*(n-
k)*w_sum/n_sum);
  ss = s1 + s2 + s3 - (n-k)*m##2;

  ss = s1+s2+s3;
d1=ff1_R[1:n-k];
d2=ff2_R[k+1:n];
w1 = w[1:n-k];
w2 = w[k+1:n];

  if k > 1 then SE = SE // sqrt((1+2*(ACF##2)[+])/w[+]);
  else SE = SE // sqrt((1+2*0)/w[+]);

  LAG = LAG // k;
  ACF = ACF // (((d1#d2#w1#w2)[+] / (w1#w2)[+] - m) / sqrt(ss));

  CI = CI // (tinv(1-&alpha./2,n-1)/sqrt(w[+]-k-3));

end;

CL = tinv(1-&alpha./2,n-1) * SE;

```

```

create &outfile. var{LAG ACF SE CL CI};
  append;
  quit;
%end;

%mend wacf;

%wacf(infile=work.a1,
      varts=midi,
      varws=__NATOS_ILGIS,
      outfile=acf,
      corr=WAERDEN,
      kk=200,
      alpha=0.05);

```


PRIEDAS NR. 7 ANALIZUOJAMŲ KŪRINIŲ SĄRAŠAS

- Beethoven – Fur Elise , partitūra Nr. 2
- Beethoven - Sonata No 8 Op 13 - Pathetique in C minor -2-let , partitūra Nr. 2
- Beethoven - Sonata No 8 Op 13 - Pathetique in C minor -3-let , partitūra Nr. 1
- Beethoven - Sonata No 14 Op 27 n. 2 - Moonlight in C-sharp minor , partitūra Nr. 1
- Clementi - Sonatina-36-1, partitūra Nr. 1
- Clementi - Sonatina-36-2, partitūra Nr. 1
- Clementi - Sonatina-36-1 , partitūra Nr. 2
- Clementi - Sonatina-36-3, partitūra Nr. 1
- Clementi - Sonatina-36-3 , partitūra Nr. 2
- Clementi - Sonatina-36-4, partitūra Nr. 1
- Clementi - Sonatina-36-4 , partitūra Nr. 2
- Clementi - Sonatina-36-5-a4, partitūra Nr. 1
- Clementi - Sonatina-36-5-a4 , partitūra Nr. 2
- Clementi - Sonatina-36-5-a4 , partitūra Nr. 3
- Clementi - Sonatina-36-6, partitūra Nr. 1
- Clementi - Sonatina-36-6 , partitūra Nr. 2
- Clementi - Sonatina-36-6 , partitūra Nr. 1
- Debussy – Claude Clair Lune , partitūra Nr. 1
- Franz Shubert - Marche Militaire, partitūra Nr. 1
- Johann Pachelbel - Canon in D, partitūra Nr. 1
- Ludwig van Beethoven-String Quartet No.15 in A minor Opus 132, partitūra Nr. 1
- Ludwig van Beethoven-String Quartet No.15 in A minor Opus 132,partitūra Nr.1
- Matt Baron - Imperial, partitūra Nr. 1
- Mozart Wolfgang Amadeus - Sonata K545-1-let, partitūra Nr. 1
- Mozart Wolfgang Amadeus - sonate for violin and piano major , partitūra Nr. 1
- Mozart Wolfgang Amadeus - sonate for violin and piano major , partitūra Nr. 2
- Mozart Wolfgang Amadeus - sonate for violin and piano major , partitūra Nr. 3
- Paganini Niccolo – Caprice for Violin , partitūra Nr. 1
- Pain Ludovic – Pulsing Universe, partitūra Nr. 1
- Pain Ludovic – Pulsing Universe, partitūra Nr. 12
- Pain Ludovic – Pulsing Universe, partitūra Nr. 20


- Rossini Gioacchino – Variations Pour Clarinette Sib piano, partitūra Nr. 2
- Rossini Gioacchino – Variations Pour Clarinette Sib piano, partitūra Nr. 3
- Rossini Gioacchino – Variations Pour Clarinette Sib piano, partitūra Nr. 4
- Scott Joplin - Elite Syncopations , partitūra Nr. 1
- Scott Joplin - Maple Leaf Rag , partitūra Nr. 1
- Tchaikovsky Piotr Ilitch - Dance of the Flowers , partitūra Nr. 1
- Tchaikovsky Piotr Ilitch – Violin Concerto major, partitūra Nr. 1
- Vivaldi Antonio – Concerto e-major Primavera spring solo- part-426, partitūra Nr. 1
- Vivaldi Antonio - Concerto e-major Primavera spring violin part-426 , partitūra Nr. 1
- Vivaldi-Sonata F Dur Rv 52 , partitūra Nr. 1

PRIEDAS NR. 8 AUTOKORELIACIJOS GRAFIKAI


1. Clementi - Sonatina-36-5-a4, partitūra Nr.1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


2. Clementi - Sonatina-36-5-a4, partitūra Nr. 2




pav. Van der Vaerden svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


3. Clementi - Sonatina-36-5-a4, partitūra Nr. 3




pav. Van der Vaerdeno svertinē ranginē autokorelācija (ACF) ir pasikļautinieji intervalai (CL)



pav. Laplaso svertinē ranginē autokorelācija (ACF) ir pasikļautinieji intervalai (CL)




pav. Vilkoksono svertinē ranginē autokorelācija (ACF) ir pasikļautinieji intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


4. Clementi - Sonatina-36-6, partitūra Nr.1




pav. Van der Vaerden svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplase svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


5. Beethoven – FurElise, partitūra Nr.2




pav. Van der Vaerden svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


6. Beethoven - Sonata No 8 Op 13 - Pathetique in C minor -2, partitūra Nr. 2




pav. Van der Vaerdeno svertinē ranginē autokorelācija (ACF) ir pasikļautinieji intervalai (CL)



pav. Laplaso svertinē ranginē autokorelācija (ACF) ir pasikļautinieji intervalai (CL)




pav. Vilkoksono svertinē ranginē autokorelācija (ACF) ir pasikļautinieji intervalai (CL)




pav. Spyromano svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


7. Beethoven - Sonata No 8 Op 13 - Pathetique in C minor -3, partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


8. Johann Pachelbel - Canon in D, partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


9. Ludwig van Beethoven - String Quartet No. 15 in A minor Opus 132 – viola, partitūra Nr. 1




pav. Van der Vaerdeno svertinē ranginē autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinē ranginē autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinē ranginē autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


10. Ludwig van Beethoven - String Quartet No. 15 in A minor Opus 132 – violoncello, partitūra Nr.1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


11. Matt Baron – Imperial, partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


12. Mozart - Sonata K545-1-let, partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Spyromano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


13. Mozart Wolfgang Amadeus - sonate for violin and piano major , partitūra Nr. 1




pav. Van der vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


14. Mozart Wolfgang Amadeus - sonate for violin and piano major , partitūra Nr. 2




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


15. Mozart Wolfgang Amadeus - sonate for violin and piano major , partitūra Nr. 3




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


16. Paganini Niccolo – Caprice for Violin , partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


17. Pain Ludovic – Pulsing Universe, partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


18. Pain Ludovic – Pulsing Universe, partitūra Nr. 12




pav. Van der Vaerden svertinē ranginē autokorelācija (ACF) ir pasīkļautinieji intervalai (CL)



pav. Laplaso svertinē ranginē autokorelācija (ACF) ir pasīkļautinieji intervalai (CL)




pav. Vilkoksono svertinē ranginē autokorelācija (ACF) ir pasīkļautinieji intervalai (CL)




pav. Spyrmans svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


19. Pain Ludovic – Pulsing Universe, partitūra Nr. 20




pav. Van der Vaerden svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


20. Rossini Gioacchino – Variations Pour Clarinette Sib piano, partitūra Nr. 2




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


21. Rossini Gioacchino – Variations Pour Clarinette Sib piano, partitūra Nr. 3




pav. Van der Vaerden svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Spyromano svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)


22. Rossini Gioacchino – Variations Pour Clarinette Sib piano, partitūra Nr. 4




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautinieji intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


23. Scott Joplin - Elite Syncopations , partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


25. Tchaikovsky Piotr Ilitch - Dance of the Flowers , partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)




pav. Spyromano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)


26. Tchaikovsky Piotr Ilitch – Violin Concerto major, partitūra Nr. 1




pav. Van der Vaerdeno svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Laplaso svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Vilkoksono svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)



pav. Spyrmano svertinė ranginė autokoreliacija (ACF) ir pasikliautiniai intervalai (CL)

PRIEDAS NR. 9 DARBE NAUDOJAMI MUZIKINIAI TERMINAI

Nata – garsą vienoje oktavoje apibūdinantis simbolis, vienas iš 7 simbolių A-G. Ritmo atžvilgiu nata reiškia garso buvimą.

Pauzė – muzikoje apibūdina tylą. Šis dydis turi ilgį taip pat kaip ir nata.

Natos ilgis – natos ar pauzės trukmę apibūdinantis parametras. Įgyjamos reikšmės – mažėjimo tvarka dalinant kiekvieną reikšmę pusiau: pilnoji, pusinė, ketvirtinė, aštuntinė, šešioliktinė, trisdešimtantrinė, šešiasdešimtketvirtinė.

Natos aukštis - Muzikinė skalė yra diskreti garso aukščio aibė. Kiekvienos natos aukštis atitinka tam tikrą dažnį, išreikštą hercais (Hz).

Partitūra - visų balsų ir instrumentų partijos. Pilnose partitūrose nurodomos visų kūrinių atliekančių instrumentų bei vokalistų partijos, tačiau gali būti išleidžiamos specialios partitūros, kurios yra skirtos konkrečiam instrumentui, dirigentu, chorui.