

Tartu Ülikool
Humanitaarteaduste ja kunstide valdkond
Kultuuriteaduste instituut
Etnoloogia, folkloristika ja rakendusantropoloogia õppekava

Tanel Torn

MUUSIKA ANDMEANALÜÜTIKA RAKENDAMINE
RAHVAPILLIMUUSIKA UURIMISEL EESTI
RAHVALUULE ARHIIVI HELISALVESTUSTE PÕHJAL

Magistritöö

Juhendajad:
Taive Särg, PhD
Anna Aljanaki, PhD

Tartu 2025

Autorideklaratsioon

Olen magistritöö kirjutanud iseseisvalt. Kõigile töös kasutatud teiste autorite töödele, põhimõttelistele seisukohtadele ning muudest allikaist pärinevatele andmetele on viidatud.

Autor: Tanel Torn

(allkiri)

..... (26.05.2025)

Annotatsioon

Käesolev magistritöö uurib, kuidas saab muusika andmeanalüütika (MIR) meetodeid rakendada eesti rahvapillimuusika helisalvestuste analüüsimisel. Uurimistöö aluseks on Eesti Rahvaluule Arhiivi 20. sajandi pillilugudest koostatud uurimiskorpus, mis koosneb enam kui 9000 helisalvestusest. Töö keskmes on masinõppemudeli CoverHunter rakendamine meloodiliselt sarnaste lugude rühmitamiseks otse helisignaali põhjal – ilma transkriptsioonide ja noodistusteta. Uuritakse, kuidas võimaldab selline lähenemine tuvastada sama viisitüübi erinevaid esitusi, avastada salvestuste dubleerimist ning metaandmetes esinevaid ebatäpsusi, toetades sellega rahvapillimuusika tõhusamat süstematiseerimist. Töö tulemused näitavad, et muusika andmeanalüütika meetodid võivad kujuneda väärtuslikuks töövahendiks eesti rahvamuusika uurimisel, aidates kaasa nii arhiivimaterjalide korrastamisele kui ka esitustevaheliste seoste tuvastamisele suurtes ja muusikaliselt mitmekesistes andmestikes.

Märksõnad: muusika andmeanalüütika, rahvapillimuusika, helisalvestused, klasteranalüüs, masinõpe

Sisukord

Eessõna	6
Lühendid ja mõisted	7
Sissejuhatus	11
1. Teoreetilised lähtekohad	15
1.1. Mis on heli?.....	15
1.2. Muusika andmeanalüütika.....	17
1.2.1. Fourier' teisendus.....	18
1.2.2. Spektrogrammid.....	21
1.2.3. Kaverlugude tuvastamine.....	23
2. Andmestik	25
2.1. Lähtematerjal.....	25
2.1.1. Ülevaade Eesti Rahvaluule Arhiivi helikogudest.....	25
2.1.2. Pilliloo mõiste antud töö kontekstis.....	27
2.1.3. Eesti rahvapillimuusika arhiivisalvestuste eripäradest.....	27
2.2. Uurimiskorpuse loomine.....	28
2.2.1. Pillilugude nimekirja koostamine.....	28
2.2.2. Helifailide konverteerimine.....	32
2.2.3. Andmete märgendamine.....	33
3. Metoodika	37
3.1. CoverHunter mudeli tutvustus.....	37
3.1.1. Mudeli arhitektuur.....	37
3.1.2. Mudeli väljund.....	39
3.1.3. Mudeli valimisest.....	39
3.2. Mudeli tõhususe hindamine.....	40
3.2.1. Mõõdik mAP.....	41
3.2.2. Mõõdik MR1.....	43
3.2.3. Testandmestiku loomine.....	43
3.2.4. Optimaalse konfiguratsiooni leidmine.....	45
3.2.5. Mudeli efektiivsus erinevate treeningandmestike põhjal.....	47
3.3. Kogu andmestiku kasutamine mudeli treenimisel.....	51
3.4. Visuaalse klasterkaardi loomine.....	52
4. Analüüs ja tulemused	55
4.1. "Kaverite" leidmine klasterkaardil.....	55
4.1.1. Kõrge täpsusega klastrid.....	56
4.1.2. Segatäpsusega klastrid.....	57
4.1.3. Poolitatud klastrid.....	58
4.1.4. Uustekkelised klastrid.....	59

4.1.5. Täiendamata klastrid.....	60
4.1.6. Mudeli rakendatavuse hindamine.....	60
4.2. Arhiivivigade tuvastamine.....	61
4.3. Uute salvestuste viisitüübi tuvastamine.....	62
4.3.1. Sarnasusel põhineva pingerea koostamine.....	63
4.3.2. Tulemuste kvantitatiivne hindamine täpsusmõõdikute alusel.....	65
Kokkuvõte.....	69
Summary.....	72
Kasutatud kirjandus.....	74
Lisad.....	78
Lisa 1. Loodud pillilugude infosüsteemi prototüüp.....	78
Lisa 2. Treening- ja testandmete jaotuse tabel.....	79
Lisa 3. Tuvastatud viisitüüpide statistika.....	84
Lisa 4. Skript helifailide konverteerimiseks.....	87
Lisa 5. Sarnaste salvestuste pingeread sisendsalvestuste kaupa.....	88

Eessõna

Käesoleva uurimistöö kirjutamist ajendas minu isiklik huvi rahvamuusika vastu, mis on kujunenud aastate jooksul nii rahvatantsija kui ka pillimängijana tegutsedes. Uurimistöö teostamist toetas ja suunas minu taust infotehnoloogia valdkonnas, eelkõige pikaajaline kogemus tarkvaraarenduse alal. Enne töö sisulise osa juurde asumist soovin avaldada tänu neile, kes on mind selle teekonna jooksul oma nõuga toetanud.

Esmalt soovin tänada oma juhendajaid Taive Särge ja Anna Aljanakit. Taive järjepidev ning pühendunud tagasiside on olnud töö valmimisel äärmiselt oluline. Tema kommentaarid aitasid kujundada töö teadusmetoodilist täpsust ning süvendada selle seotust folkloristikas kesksete uurimisküsimustega. Anna aitas töö algfaasis määratleda selle tehnilise suuna ning tema nõuanded olid olulised sobiva metoodilise lähenemisviisi valikul ja hilisemal rakendamisel. Just tema soovitas mul kasutada masinõppemudelit CoverHunter, millest kujunes töö keskne vahend helisalvestuste muusikalise sarnasuse tuvastamisel.

Täna siiralt etnomusikoloog ja rahvamuusikut Krista Sildoja, kes salvestas spetsiaalselt selle töö tarbeks viis viiulil mängitud rahvapillilugu. Tema panuse abil sain laiendada pillivalimit, mida kasutasin uurimuses rakendatud metoodika tõhususe hindamiseks.

Avaldan ka tänusõnu pikaajalisele tantsupedagoogile ja Leigarite kunstilisele juhile Sille Kapper-Tiislerile, kelle asjatundlikul juhendamisel õnnestus mul määrata suurele osale pillilugudest üldine tantsutüüp. See omakorda toetas mitmekesisema treeningandmestiku koostamist.

Lõpetuseks soovin tänada Alan Ng't, kelle töö CoverHunteri mudeli dokumenteerimise ja edasiarendamisega lõi olulised eeldused selle rakendamiseks käesolevas uurimuses. Samuti hindan kõrgelt tema valmidust jagada praktilisi kogemusi mudeli kasutamisest.

Lühendid ja mõisted

AMT (automaatne muusikatraskriptsioon) – meetod, mis teisendab helifailid automaatselt noodikirjaks või mõneks muuks sümboolseks esituseks, tuues esile muusikalisi omadusi nagu meloodia, rütm või harmoonia.

Conformer – masinõppemudeli arhitektuur, mis ühendab kahte lähenemist – konvolutsioonid närvivõrgud ja transformerid –, et töödelda keeruka struktuuriga ajas muutuvaid andmeid, nagu näiteks helisignaale või kõnet. See võimaldab mudelil samaaegselt haarata nii üksikuid detaile kui ka laiemat ajalisk struktuuri. (Vt ka CNN ja transformer.)

CoverHunter – käesolevas töös kasutatav masinõppemudel, mis tuvastab helisalvestuste vahelisi sarnasusi, toetudes nende akustilistele omadustele. Mudelit kasutatakse peamiselt selleks, et leida sama loo erinevaid esitusi ehk kaverid.

CQT (*constant-Q transform* ehk konstantse kvaliteedifaktoriga teisendus) – muusika andmeanalüütikas sageli kasutatav teisendus, mis põhineb sarnastel põhimõtetel nagu Fourier' teisendus, kuid mille sagedustelg on logaritmiline – sarnaselt sellele, kuidas inimene tajub helikõrgusi. (Vt ka Fourier' teisendus)

CNN (*convolutional neural network* ehk konvolutsiooniline närvivõrk) – tehisnärvivõrkude arhitektuur, mida kasutatakse sagedasti piltide ja heli visuaalsete kujutiste (nagu spektrogrammid) analüüsimisel.

diskreetimissagedus ehk **näiduvõtusagedus** – heli digiteerimisel kasutatav proovivõtusagedus, mis määrab, kui tihti mõõdetakse helirõhku kindla ajaühiku jooksul.

ERA (Eesti Rahvaluule Arhiiv) – Eesti Kirjandusmuuseumi alla kuuluv arhiiv, kus säilitatakse eesti folklooriga seotud materjale, sh helisalvestusi.

esitus – rahvaluuleteose konkreetne avaldumisvorm kindlas ajas, ruumis ja olukorras. Käesolevas töös tähistab see eelkõige pilliloo helilist jäädvustust.

Fourier' teisendus – matemaatiline teisendus, mis võimaldab helisignaali esitada erinevate sageduskomponentidena. Fourier' analüüsis mõõdetakse helisagedusi hertsides (Hz), mis on

lineaarne skaala – igale sagedusele vastab sama laiusega vahemik. Inimese kuulmistaju seevastu on logaritmiline: meie jaoks on helikõrguste vahed (nt pooltoonid) tajutavalt võrdsed, kuigi nende hertsiväärtused erinevad oluliselt. Seetõttu on Fourier' spektris kõrgemate helide vahed visuaalselt suuremad kui madalamate helide omad, mis teeb muusikaliste mustrite võrdlemise keerulisemaks. (Vt ka CQT)

GitHub – veebipõhine koodirepositoorium, mida kasutatakse ka teadusprojektide lähtekoodi avaldamiseks.

heliklass (*pitch class*) – mõiste, mis tähistab kõiki samanimelisi noote, mis erinevad teineteisest n arvu oktavite võrra. Näiteks kuuluvad kõik C noodid – olgu need C3, C4 või C5 – samasse heliklassi.

hõlmanguruum (*embedding space*) – mitmemõõtmeline matemaatiline ruum, kuhu objektid projitseeritakse nende hõlmanguvektorite kaudu. Selles ruumis paiknevad sarnased objektid (nt meloodiliselt sarnased salvestused) üksteisele lähedal, võimaldades masinõppel tuvastada seoseid, rühmi ja mustreid.

hõlmanguvektor (*embedding vector*, sageli ka lihtsalt *embedding*) – matemaatiline vektor, mis esindab objekti (nt helisalvestuse) omadusi mitmemõõtmelises arvuruumis viisil, mis on masinõppele sobiv. Sellised vektorid võimaldavad võrrelda andmeobjektide omavahelisi sarnasusi.

hüperparameeter – masinõppemudeli parameeter, mida ei õpita andmete põhjal, vaid määratakse enne treenimist. Hüperparameetrite sobiv valik mõjutab mudeli töökindlust ja täpsust.

implementeerima – tarkvaraarenduses tähendab see mingi meetodi, algoritmi või funktsiooni tehnilist teostamist sellisel kujul, et see töötaks reaalses süsteemis või rakenduses.

ISMIR (*International Society for Music Information Retrieval*) – rahvusvaheline teadusorganisatsioon, mis ühendab muusika andmeanalüütika (MIR) uurijaid ja korraldab iga-aastast ISMIR konverentsi.

kaver ehk kaverlugu – sama muusikapala erinev esitus (nt erinev esitaja, tempo või instrumentatsioon), mida muusika andmeanalüütikas püütakse automaatselt tuvastada.

Käesolevas töös, mis keskendub rahvapillimuusikale, käsitletakse kaverit kui ühe ja sama rahvaviisi erinevat esitust ehk varianti. Folkloristika laiemas vaates võib kaver hõlmata ka lauluteksti ja viisi seoseid, kuid siin on fookus ainult meloodilisel materjalil.

klasterdamine – meetod, mille abil grupeeritakse sarnased andmepunktid (nt helisalvestused) rühmadesse ehk klastritesse nende omavahelise sarnasuse alusel. Erinevalt klassifitseerimisest ei eelda klasterdamine andmepunktide eelnevat sildistamist.

klasterkaart – visuaalne kahemõõtmeline projektsioon, mis kuvab, kuidas helisalvestused jagunevad klastritesse.

konfiguratsioon – mudeli või süsteemi seadistus, mis koosneb erinevatest parameetritest, hüperparameetritest ja töötlusvalikutest. Ühe konfiguratsiooni all mõistetakse konkreetset kombinatsiooni, mida kasutatakse teatud eksperimendis.

mAP (*mean average precision* ehk keskmine täpsus) – mõõdik, mis hindab mudeli täpsust ja järjestuse õigsust, näiteks infootsingus ja kaverite tuvastuses.

MIR (*music information retrieval*) – muusika andmeanalüütika; valdkond, mis tegeleb muusikalise info automaatse analüüsi ja otsinguga helisignaali põhjal.

MIREX (*Music Information Retrieval Evaluation eXchange*) – iga-aastane rahvusvaheline võistlus, kus hinnatakse MIR-algoritmide tõhusust.

MRI (*mean rank of first relevant item* ehk esimese asjakohase vaste keskmine järjestuskoht) – mõõdik, mis näitab, mitmendana leiti esimene õige vaste otsingutulemuste seas.

mudel – käesolevas kontekstis masinõppemudel: algoritmiline süsteem, mis on treenitud andmete põhjal teatud ülesande täitmiseks, näiteks helisalvestuste sarnasuse hindamiseks või kaverite tuvastamiseks.

märgendamine ehk sildistamine – protsess, mille käigus lisatakse andmetele täiendavaid tähendusi või kategooriaid, näiteks märgitakse, millist viisitüüpi salvestus esindab.

pillilugu – rahvamuusikapala, mille esituses on keskne roll pillil. Üks pillilugu võib esineda mitmes esituses ning kuuluda mõnda viisitüüpi.

Python – laialt kasutatav programmeerimiskeel, mis võimaldab kirjutada analüütilisi skripte, töödelda helifaile, visualiseerida andmeid ning rakendada masinõppemeetodeid.

sinusoid – korrapärane lainekuju, mis esindab lihtheli ehk puhast tooni ühe kindla sagedusega, ilma ülemhelideta.

spektrogramm – graafiline esitus (soojuskaart) helisignaali sageduslikust struktuurist ajas, kus telgedel on aeg, sagedus ning värviga tähistatud amplituud.

tarkvarateek – kogum korduvkasutatavat tarkvarakoodi (funktsioone, klasse jm), mida saab kasutada programmeerimises.

transformer – närvivõrkude arhitektuur, mis sobib järjestikuste andmete (nt keele või heli) töötlemiseks ja millel põhineb paljude kaasaegsete mudelite ehitus.

triplet loss – kolmikkadufunktsioon, mida kasutatakse andmete treenimiseks, suunates sarnased andmepunktid üksteisele lähemale ja erinevad kaugemale.

t-SNE (*t-distributed stochastic neighbor embedding*) – masinõppe meetod, mida kasutatakse andmete visualiseerimiseks. See vähendab kõrgedimensioonilise andmestiku mõõtmete arvu kahe- või kolmemõõtmeliseks, säilitades samas andmepunktide vahelised lokaalsed sarnasused, et klastreid ja mustreid oleks lihtsam visualiseerida.

viisitüüp – sarnaste muusikaliste tunnustega muusikapalada (nt pillilugude) rühm. Käesolevas töös on mõiste kasutusel analüütilises tähenduses, võimaldamaks võrrelda ja liigitada salvestusi nende meloodiliste omaduste põhjal.

Sissejuhatus

Eesti Kirjandusmuuseumi Eesti Rahvaluule Arhiivi (ERA) kogudes leidub ligikaudu 10 000 rahvapillimuusika helisalvestust 20. sajandist. Paljud neist on märgendatud üldiste pealkirjadega, nagu “valss” või “polka”, kuid sama muusikapala võib kanda ka erinevaid nimetusi sõltuvalt piirkonnast, kus see on kogutud. Kuna rahvamuusika paladel puuduvad sageli kindlad, fikseeritud pealkirjad või ühtne viisikuju, ei kajastu esituste tegelik meloodiline sarnasus alati metaandmetes ning pelgalt nende põhjal on keeruline otsustada, kas kaks salvestust on sama loo variandid või hoopis erinevad palad. Paljude salvestuste vahelised seosed jäävad seega sageli varjatuks ning nende tuvastamine nõuab täiendavat kuulamist ja analüüsi.

Lisaks võib arhiivides leiduda ebatäpsusi, mida saab tuvastada üksnes helisisu põhjal ning mis jäävad pelgalt metaandmetele tuginedes märkamata. Näiteks võib salvestuse metaandmetes või failinimes olla märgitud üks pala, kuid tegelikult sisaldub helifailis hoopis teine lugu. Samuti võib esineda duplikaate, mida ei ole metaandmetes fikseeritud. Folkloori kogumisel või digiteerimisel tehtud inimlikud eksimused võivad tekitada eksitavat muljet andmestiku mitmekesisusest (või vastupidi, andmestiku ühetaolisusest) ning andmeanalüüse tugevalt kallutada. Taolised ebatäpsused on eriti tõenäolised just suuremates ja pikema ajaloo arhiivides, kus andmete haldamise, digiteerimise ja märgendamise on tegelenud erinevad isikud eri ajaperioodidel.

Kuna pelgalt metaandmetele tuginemine ei võimalda usaldusväärselt kokku viia ühe ja sama muusikapala või viisitüübi eri esitusi, on vajalik sisulisem analüüs, mis lähtuks otseselt helimaterjalist. See omakorda tõstatab küsimuse, kuidas saaks rahvamuusika salvestusi uurida senisest tõhusamalt ja süsteemsemalt.

Eestis on rahvamuusika süstematiseerimise ja viisitüüpide määratlemise vallas olulist tööd teinud Ingrid Rüütel, kelle käsitlused on märkimisväärselt arendanud eesti regiviiside uurimise teoreetilist poolt ja süstematiseerimise meetodikat. Rüütel jõudis järeldusele, et eesti regivärsiliste rahvalaulude viisitüüpide tuvastamisel on kõige tõhusamaks meetodiks klasteranalüüs, mille puhul rühmitatakse uuritavad viisid ümber ühiste tsentrite ehk klastritesse (Rüütel, 2006: 84). See vastab Rüütli sõnul folklooriteoorias tüübi ja variandi vahekorrale, mille kohaselt kõigil variantidel on ühine põhikuju, milles nad erinevad

detailides (samas: 84). Koostöös programmeerija Koit Haugasega töötas Rüütel välja meetodika regiviiside automaatseks klasterdamiseks, mis põhines laulude meloodilise konteksti statistilisel analüüsil (Rüütel ja Haugas, 1990).

Samas põhines Rütli ja Haugase käsitus käsikirjalistel noodistustel, mitte helisalvestuste vahetul analüüsil. Suuremahuliste helikogude puhul, kus salvestusi võib olla tuhandeid, muutub käsitsi tehtav noodistamise protsess kiiresti ebapraktiliseks. Lisaks nõuab transkribeerimine helisalvestuste kuuldelise sisu täpset tõlgendamist, mis võib olla keeruline, eriti mikrotonaalsuse, ornamentika või ebastandardsete rütmiliste vormide puhul. Käsitsi noodistamist nõudvad meetodid piiravad seeläbi analüüsile ulatust ja läbiviimise kiirust, tekitades vajaduse alternatiivsete, osaliselt automatiseeritud lähenemiste järele.

Ühe võimalusena on nähtud automaatse muusikatraskriptsiooni (AMT) kasutamist. Kuigi AMT tehnoloogia on viimastel aastatel märkimisväärselt arenenud (Jamshidi jt., 2024), on selle täpsus siiski piiratud, eriti keerukamate või ebastandardsete helimaterjalide puhul. Kuna paljusid tänapäevaseid AMT-mudeleid on treenitud stuudiokvaliteediga lääne muusika salvestuste põhjal, võib nende rakendamine rahvapillimuusikas olla ebausaldusväärne ning esitada täiendavaid väljakutseid olemasolevatele süsteemidele (Ozaki jt. 2021). Nende tegurite mõju võimendab veelgi ajalooliste arhiivisalvestuste madal helikvaliteet, taustamüra ning pillispetsiifiline akustiline varieeruvus. Seetõttu ei pruugi AMT olemasoleval kujul sobida usaldusväärseks töövahendiks eesti rahvapillimuusika analüüsimisel.

Lisaks transkriptsioonile, tuleb arvestada ka võrdlemise protsessile kuluvat aega. Ükskõik millise meetodi kasuks otsustada, olgu see kuuldeline, noodipõhine või arvutuslik analüüs, eeldab see paratamatult komparatiivset lähenemist, kus salvestusi või noodistusi võrreldakse omavahel. Võrdlemiseks kuluvat aega on mõnevõrra keeruline täpselt määratleda, kuna see sõltub suuresti andmete sisust ja analüüsi teostaja muusikalisest pädevusest või arvutusliku meetodi tõhususest. Siiski saame hõlpsasti välja arvutada paarikaupa võrdluste koguarvu n suuruse korpuse puhul, mis annab vähemalt esmase ettekujutuse töö võimalikust kogumahust.

Näiteks, kui uurimiskorpuses on kolm helisalvestust (A, B, C), tuleb binaarse võrdlemise korral teostada kolm võrdlust: AB, AC ja BC. Kuigi antud näites ei ole võrdluste arv märkimisväärselt suur, on oluline märkida, et vajalike võrdluste koguarv kasvab

kvadraatilisel¹ koos korpuse suuruse suurenemisega. Võrdluste koguarvu saab välja arvutada kombinatoorika valemiga, mis leiab kõikide võimalike k -liikmega alamhulkade arvu n -liikmelisest hulgast:

$$C_n^k = \frac{n!}{k!(n-k)!} \quad (1)$$

kus:

- k on 2, kuna võrdleme salvestusi paarikaupa
- n on kataloogi suurus

Käesoleva magistritöö raames koostas in uurimiskorpuse 9222 helisalvestusega, mis teoreetiliselt tähendaks 42 518 031 võimalikku võrdluspaari. Praktikas ei teostata neid võrdlusi aga isoleeritult ning ei ole tingimata alati vajalik kõiki lugusid omavahel võrrelda. Siiski võib nimetatud koguarvu käsitleda teoreetilise maksimumina. Oluline ei ole siinjuures mitte pelgalt saadud arvu suurus, vaid see, mida see arv illustreerib – nimelt seda, kui kiiresti kasvab võrdluste hulk korpuse laienedes ning kui mahukaks muutub andmete käsitlemine. Sellest tulenevalt on oluline leida viise, kuidas optimeerida võrdlemise protsessi, muutes seda kiiremaks ja efektiivsemaks.

Alternatiiv käsitsi tehtud transkribeerimisele ja võrdlemisele võib põhineda muusika andmeanalüütikal (ingl k *music information retrieval*, edaspidi MIR). MIR ühendab muusikateaduse, arvutiteaduse ja signaalitöötluse elemente, võimaldades tuvastada muusikaliselt olulist informatsiooni otse helisignaali põhjal, ilma et oleks vaja noodistusi. Selline lähenemine võib oluliselt kiirendada ja laiendada analüüside tegemist, võimaldades tuvastada mustreid ning seoseid suurtes helikogudes, mis sisaldavad tuhandeid salvestusi ning mille analüüsimine oleks traditsiooniliste meetoditega äärmiselt ajamahukas või isegi teostamatu. Üheks tüüpiliseks näiteks on ühe ja sama muusikapala erinevate esituste tuvastamine – muusika andmeanalüütikas tuntud kui kaverlugude tuvastamine (ingl k *cover song identification*) –, mis moodustab olulise osa MIR-i rakendusvaldkondadest, kuid on eesti etnomusikoloogias seni valdavalt toimunud kuuldeliselt ja noodistuste võrdluse abil.

Käesolev magistritöö jätkab Rütli ja Haugase suunda viisitüüpide automatiseeritud määramiseks eesti rahvamuusikas, kuid erineb eelnevatest käsitlustest eelkõige analüüsitava

¹ Algoritmiline keerukus on võrdne: $n \cdot (n - 1) / 2$

materjali ja meetodite poolest. Kui Rüütel ja Haugas keskendusid regilauludele ning tegid oma analüüsi noodistuste põhjal, siis sinne töö keskendub pillilugudele ning kasutab otseselt helisignaali töötlevaid arvutuslikke meetodeid.

Töös keskendun muusika andmeanalüütika rakendamisele helisalvestatud ning digiteeritud rahvapillilugude automaatseks klasterdamiseks ehk grupeerimiseks otse helisignaali põhjal, eesmärgiga selle abil tuvastada sama muusikapala erinevaid esitusi. Selline lähenemine võimaldab tuvastada meloodiliselt sarnaseid salvestusi ilma, et oleks vaja eelnevalt transkribeeritud noodistust. Kaugemaks eesmärgiks on aga laiem rahvapillimuusika süstematiseerimine.

Täpsemalt püütakse töö käigus leida vastus järgmistele uurimisküsimustele:

- Milliseid meetodeid saab kasutada rahvapillimuusika helisalvestuste võrdlemiseks ja rühmitamiseks ilma noodistust kasutamata?
- Kui sobivad on tänapäevased (*state-of-the-art*) kaverituvastuse algoritmid eesti rahvapillimuusika analüüsimiseks?
- Kui tõhus on automaatne klasterdamine sama muusikapala erinevate esituste tuvastamisel?
- Kas automaatne klasterdamine võimaldab tuvastada duplikaate või märgendamisvigu arhiivimaterjalides?

Magistritöö koosneb neljast peatükist. Esimeses peatükis tutvustan töö teoreetilisi lähtekohti, sealhulgas kirjeldan heli olemust ja muusika andmeanalüütika peamisi meetodeid, rõhuasetusega kaverlugude tuvastamisel. Teine peatükk keskendub uurimistöö andmestikule: kirjeldan kasutatud arhiivisalvestusi ja uurimiskorpuse loomist. Kolmandas peatükis selgitan töös rakendatud meetodikat pillilugude sarnasuse tuvastamisel, sealhulgas CoverHunter mudeli tööpõhimõtteid ja selle tõhususe hindamist. Neljandas peatükis analüüsin saadud tulemusi, keskendudes klasterkaardi tõlgendamisele ja pillilugude erinevate esituste kui ka arhiivandmetes võimalike vigade tuvastamisele.

1. Teoreetilised lähtekohad

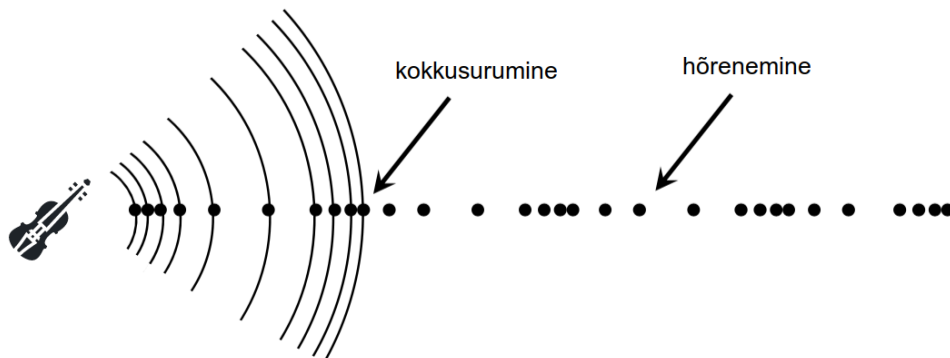
Käesolevas peatükis käsitlen töös kasutatava arvutusliku metodoloogia teoreetilisi aluseid. Selgitan helilainete olemust füüsilisest vaatepunktist ning kirjeldan muusika andmeanalüütika teoreetilisi lähtekohti. Füüsiliste ja matemaatiliste protsesside kirjeldamisel toetun eelkõige Meinhard Mülleri teosele “Fundamentals of Music Processing” (Müller, 2015), millest on saanud muusika andmetöötluse valdkonnas standardne õpik ning mida tsiteeritakse sageli nii teadustöös kui ka õppetöös (Olagunju jt, 2023; Eikmeier jt, 2021; Aljanaki, 2024).

1.1. Mis on heli?

Heli võib defineerida perioodiliste õhurõhu² muutustena, mis levivad ruumis lainetena. Selle nähtuse illustreerimiseks võib tuua näite viulist, millel mängitakse esimese oktavi C-nooti (C4). Poognaga üle viiuli keelte tõmbamine paneb keeled võnkuma. Keelte võnkumine põhjustab ümbritsevate õhumolekulide liikumise, mille tagajärjel tekivad järjestikused õhumolekulide kokkupõrked. Selle tulemusena moodustuvad õhus piirkonnad, kus õhumolekulide kontsentratsioon ajutiselt suureneb (kokkusurutud piirkonnad) ning piirkonnad, kus see väheneb (hõrendatud piirkonnad). Sellised perioodilised tiheduse muutused levivad ruumis helilainetena ning kannavad edasi energiat. Seda protsessi visualiseerib Joonis 1.


² Käesolevas peatükis keskendun heli levimisele õhus, kuigi heli võib levida ka teistes keskkondades, näiteks vedelikes ja isegi tahketes kehaosades.

Joonis 1. Õhumolekulide liikumine heli tekitamisel. Ruumis tekivad alad, kus õhurõhk on suurem kui ümberitseva keskkonna rõhk, ning alad, kus see on väiksem. Nii tekivad järjestikuseid rõhulained, mis levivad läbi õhu ja mida me tajume helina. (Müller, 2015: 20)



Helilainete mõõtmine ja nende visuaalne kujutamine on võimalik spetsiaalsete seadmetega, näiteks mikrofoniaga, mis registreerib õhurõhu muutused ja teisendab need elektrilisteks signaalideks. Mõõtmistulemused on seejärel esitatavad graafikuna. Joonisel 2a on näidatud viiulil esitatud C4-noodi poolt tekitatud helilaine. Graafiku horisontaaltelg tähistab aega, vertikaaltelg aga õhurõhu mõõdetud väärtust võrreldes ümbritseva keskkonna rõhuga, st amplituudi, mis väljendab helitugevust. Joonis 2b kujutab samast helisignaalist võetud 10 millisekundilist lõiku, mis võimaldab täpsemalt vaadelda helirõhu muutumise mustrit.

Joonised 2a ja 2b. Helilainete visuaalne esitus. Vasakul on viiulil mängitud C4 noodi helilaine. Paremal on kujutatud sama helilaine ühte 10 millisekundilist lõiku. Visualiseerimiseks on kasutatud Pythoni tarkvarateeki Librosa ja Matplotlib.



Jooniselt 2b on selgelt eristatav signaali perioodilisus: õhurõhk suureneb, saavutab maksimumi ning seejärel väheneb ja jõuab miinimumini, mille järel protsess kordub. Sellel 10 millisekundilisel lõigul võib eristada viit suuremat üles-alla kõikumist (tsüklit). Selliste tsüklite arv ajaühiku kohta määratlebki signaali sageduse, mis tähistab üles-alla kõikumiste arvu sekundis. Muusikaliselt on sagedus oluline, kuna see on otseselt seotud helikõrguse tajumisega.

Lisaks on näha, et tsüklid ei ole identsed: nende sees ilmnevad väiksemad kõikumised, mis viitavad signaali keerukusele. Selline keerulisem lainekuju illustreerib, et heli ei koosne ainult ühest sagedusest, vaid mitmest samaaegselt toimuvast võnkumisest ehk osahelidest, mille hulka kuuluvad nii põhisagedus kui ka ülemhelid. Osahelide olemust ja akustilist tähendust käsitletän täpsemalt jaotises 1.2.1.

Tähelepanu väärrib ka asjaolu, et graafikul kujutatud helisignaali ei ole pidev, vaid astmeline. See tuleneb digiteeritud heli eripärast: mõõtmised on tehtud kindlatel, diskreetsetel ajahetkedel. Kokkuvõtlikult võib aga öelda, et digitaalne helisignaali on lihtsalt numbrite jada, mis esindab õhurõhu suhtelist väärtust ümbritseva keskkonna suhtes igal mõõtehhetkel.

1.2. Muusika andmeanalüütika

Muusika andmeanalüütika (MIR) on uurimisvaldkond, mis ühendab endas muusikateaduse, arvutiteaduse ja signaalitõõtluse elemente ning keskendub helilainetest muusikaga seotud andmete eraldamisele ja analüüsimisele. MIR-meetodite abil arendatakse tehnoloogiaid, mida kasutatakse mitmesugustes valdkondades, sealhulgas muusikaotsingus, soovitusüsteemides ja klassifitseerimises (Yesiler jt., 2021). Muusika andmeanalüütikat kui teadusharu edendab mittetulundusorganisatsioon International Society for Music Information Retrieval (ISMIR³), mis koordineerib ülemaailmset teaduskoostõõd, korraldab iga-aastaseid rahvusvahelisi konverentse ja võistlusi, ning annab välja teadusajakirja “Transactions of the International Society for Music Information Retrieval⁴”.

Olulise osana valdkonna arengust toimuvad igal aastal ka *Music Information Retrieval Evaluation eXchange*⁵ (MIREX) võistlused, kus erinevate MIR-algoritmide loojaid

³ <https://ismir.net/>

⁴ <https://transactions.ismir.net/>

⁵ https://www.music-ir.org/mirex/wiki/MIREX_HOME

kutsutakse osalema standardiseeritud katsetes. MIREX võimaldab objektiivselt hinnata ja võrrelda erinevate meetodite tõhusust mitmesugustes ülesannetes, nagu näiteks meloodiaekstraktsioon, žanrituvastus, kaverlugude tuvastamine, helituvastus ja paljud teised. Selline süstemaatiline lähenemine toetab uute lahenduste arengut ja soodustab avatud teaduslikku koostööd kogu valdkonnas.

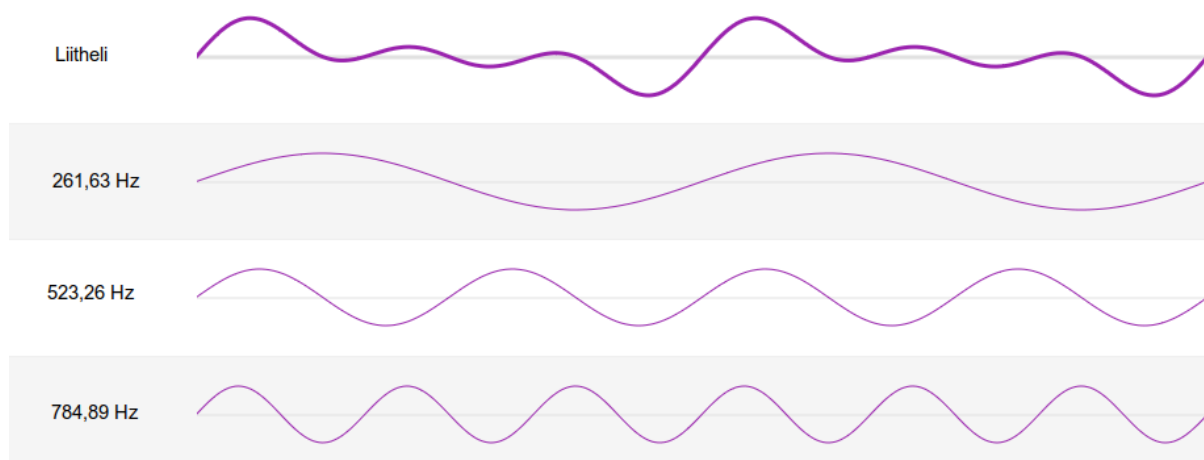
1.2.1. Fourier' teisendus

Muusika andmeanalüütika üheks peamiseks tööriistaks on Fourier' teisendus, mis teisendab õhurõhu muutused ajas (ajadomeen) sagedusspektriks (sagedusdomeen). Fourier' teisenduse näol on tegu küllaltki keerulise matemaatilise operatsiooniga, mille detailne lahtiseletamine nõuaks ühtlasi ka mitmete erinevate matemaatiliste kontseptsioonide nagu integraalide ja kompleksarvude põhjalikku tutvustamist ja käsitlemist. Arvestades käesoleva magistritöö eesmärke ja sihtrühma, milleks on antud juhul humanitaarteaduste valdkond, leian, et on asjakohane hoiduda ülemäärastest matemaatilistest üksikasjadest ning piirduda üksnes Fourier' teisenduse üldiste põhimõtete ja praktilistele väljundite kirjeldamisega.

Helisignaali võib käsitleda kui kompleksset liitheli, mis koosneb erineva sageduse ja amplituudiga lihtsatest osahelidest ehk liithelidest, mille lainekujuks on sinusoid. Muusikaliselt oluline on siinjuures eristada põhisedust, mis määrab tajutava helikõrguse, ning sellest kõrgema sagedusega ülemhelisid, mille intensiivsuse ja sagedusjaotuse variatsioonid määratlevad heli tämbri ehk kõlavärvi. Ülemhelide sagedused on põhiseduse täisarvulised kordajad. Näiteks noodi C4 puhul (põhisedus 271,63 Hz) on esimene ülemheli sagedusel 523,26 Hz ($2 \times 271,63$ Hz), teine 784,89 Hz ($3 \times 271,63$ Hz) jne. Mitmete sinusoidide liitmise tulemusel moodustub liitheli. Näide kolme sinusoidiga konstrueeritud liithelist on toodud Joonisel 3.

Joonis 3. Lihthelidest konstrueeritud liitheli. Alumised kolm sinusoidi moodustavad ülemise helilaine.

Visualiseerimiseks kasutasin veebipõhist tarkvara Harmonics Explorer⁶.




Fourier' teisenduse peamine tööpõhimõte seisneb komplekssignaali ehk liitheli lahtivõtmises selle elementaarseteks osadeks ehk sinusoidseteks komponentideks. Selleks võrreldakse algset helisignaali erinevate sagedustega sinusoididega ning arvutatakse välja koefitsiendid, mis näitavad, kui võrd vastav sinusoid ehk konkreetne sagedus on helisignaalis esindatud. Väikese väärtusega koefitsiendid tähendavad, et vastava sagedusega sinusoidil puudub signaalis oluline roll või see puudub sootuks, samal ajal kui suure väärtusega koefitsiendid viitavad konkreetse sageduse tugevale esinemisele signaalis. Nende koefitsientide põhjal koostatakse sagedusspekter, mis näitab, millistest erineva sagedusega osahelidest analüüsitava helisignaali koosneb.

Helisignaalist muusikalise informatsiooni eraldamise seisukohalt on sagedusel kriitiline tähtsus, kuna sagedus on otseselt seotud inimkõrva tajutava helikõrgusega. Näitlikuks illustatsiooniks on Joonisel 4 toodud viulil mängitud noodi C4 sagedusspekter.

⁶ <https://teropa.info/harmonics-explorer/>

Joonis 4. Viiulil mängitud C4 noodi sagedusspekter. Spekter koosneb erinevatest sagedustest, mis vastavad konkreetsetele helikõrgustele. Graafiku horisontaaltelg näitab sagedust hertsides, vertikaaltelg aga iga sageduse suhtelist tugevust ehk osakaalu kogu helisignaalis. Sagedusspektri visualiseerimiseks on kasutatud Pythoni tarkvarateeki Matplotlibi.



Antud jooniselt nähtub, et C4 näite puhul domineerib põhisagedusel paiknev energia, millele järgnevad ülemhelid järk-järgult väheneva intensiivsusega. Selline jaotus on iseloomulik paljudele, kuid mitte kõikidele pillidele. Näiteks flöotide või vilepillide puhul võib suurem osa helienergiast olla koondunud hoopis ülemhelide piirkonda. Lisaks väärib märkimist, et viiulil esitatud noodi C4 sagedusspektris esineb lisaks põhisagedusele ka teistest heliklassidest pärit sagedusi, näiteks noot G5. See tuleneb asjaolust, et ülemhelide sagedused on põhisageduse täisarvulised kordajad, mille tulemusena osa ülemhelidest langeb kokku teiste heliklasside põhisagedustega. See tähendab, et muusikahelide, sealhulgas pillihelide tajumine ei põhine pelgalt ühest heliklassist noodil, vaid hõlmab mitmete heliklasside kombineeritud kooskõla. Just erinevused osahelide energijaotuses määravad suuresti heli tämbri ehk selle iseloomuliku kõlavärvingu. Tämbri mõistega tähistataksegi heli omadust, mis võimaldab kuulajal eristada omavahel erinevaid helisid, sh pille ka siis, kui helikõrgus ja helitugevus on identsed (Acoustical Society of America, i.a.).

Fourier' teisenduse protsessi võib kujundlikult võrrelda valge valguse dispersiooniga läbi prisma. Valge valgus on liitvalgus, mis koosneb erineva lainepikkusega osavalgustest, millest igaühel on kindel värvus. Kui valgus läbib prisma, siis refraktsiooni tõttu murduvad erinevad osavalgused erinevate nurkade all ning nähtavale ilmub värvispekter. Analoogselt võimaldab


Fourier' teisendus analüüsida helisignaali komponente, tuues esile kõik osahelid ehk sagedused, millest kompleksne helisignaali koosneb. Nii Fourier' teisendus kui ka valguse dispersioon illustreerivad komplekssete signaalide dekonstrueerimist nende lihtsamateks koostisosadeks.

1.2.2. Spektrogrammid

Kui rakendada Fourier' teisendust tervele helisignaali korraga, avaneb võimalus uurida signaali koostisosi sagedusdoomeenis, kuid samal ajal kaotatakse täielikult ajaline komponent. Sagedusspekter näitab küll sagedusi, mis signaalis esinevad, kuid mitte seda, millistel ajahetkedel need sagedused kõlavad. Muusikalise analüüsi jaoks on aga olulised mõlemad komponendid.

Ajaliselt muutuva sagedusinformatsiooni uurimiseks kasutatakse spektrogramme. Spektrogramm on visuaalne esitusviis, mis kajastab signaali sageduskomponentide muutumist ajas. Selle loomiseks kasutatakse lühiajalist Fourier' teisendust (ingl k *Short-Time Fourier Transform* ehk STFT), mis rakendatakse signaali väikestele, ajaliselt piiritletud lõikudele eraldi. Nende lõikude sagedusspektrid ühendatakse seejärel ajateljele, säilitades seeläbi ajalise mõõtme ning võimaldades vaadelda sageduste muutumist aja jooksul. Näiteks on Joonisel 5 välja toodud Juhan Saare poolt mängitud perekonnavalsi esimese läbimängu A-osa spektrogramm.

Joonis 5. Juhan Saare poolt suupillil mängitud “Perekonna valtsi” (RKM, Mgn. II 4124 (6)) I läbimängu A osa spektrogramm logaritmilise y-teljega, mis näitab erinevate sageduste ehk tajutud helikõrguste jaotumist ajas. Visualiseerimine on teostatud Pythoni tarkvarateekide Librosa ja Matplotlib.



Spektrogramm on visuaalne kujutus helisignaali sageduslikust ülesehitusest ajas, mis võimaldab tuvastada selgeid ja korduvaid mustreid. See kujutab heli kolme mõõdet – aega, sagedust ja amplituudi – kasutades horisontaalsel teljel aega, vertikaalsel teljel sagedust ning värvitooni intensiivsuse kaudu helitugevust. Heledamad (kollakad) alad viitavad suurema amplituudiga sageduskomponentidele ehk sagedustele, mis on vastaval ajahetkel tugevamini esindatud. Joonisel 5 esitatud spektrogrammi keskel (512 ja 1024 Hz vahel) on nähtav meloodia kulg, mille moodustab põhisageduse tajutav muutumine. Kõrgemates sagedustes (üle 1024 Hz) paiknevad ülemhelid, madalamatel sagedustel (kuni 512 Hz) on näha müra, mis võib pärineda nii salvestustehnikast kui ka ümbritsevast keskkonnast.

Käesolevas töös rakendatavad arvutuslikud mudelid töötavad samuti just spektrogrammide põhjal, kuna need kujutavad endast heli struktuuri tihedalt kirjeldavat lähteandmestikku, mis võimaldab helisalvestusi sisuliselt võrrelda ja omavahel rühmitada.

1.2.3. Kaverlugude tuvastamine

Üheks muusika andmeanalüütika keskseks uurimisprobleemiks on kaverlugude tuvastamine (ingl k *cover song identification*), mis on olnud MIREX-i võistlusprogrammi kavas juba aastast 2006⁷. Selle eesmärgiks on leida muusikapalade hulgast erinevaid esitusi, mis põhinevad samal muusikalisel teosel, kuid võivad erineda nii tempo, struktuuri, harmoonia, meloodia kui ka esituse stiili poolest. Näiteks võivad samast loost olla olemas nii stuudiosalvestus, *live*-versioon kui ka akustiline kaver mõne teise esitaja poolt – kuigi kuuldav esitus võib olla oluliselt erinev, jagavad nad siiski ühist muusikalist alust.

Kaverlugude tuvastamisele on ajalooliselt lähenetud erinevate käsitsi loodud tunnuste kaudu (*feature engineering*⁸), näiteks meloodiakontuuride, harmooniliste progressioonide või tempo-invariantsete sarnasuste mõõtmise abil. Varasemates süsteemides kasutati tihti klassikalisi signaalitöötlusmeetodeid, nagu *chroma*-vektorid või DTW (*Dynamic Time Warping*), et leida kaudseid kattuvusi kahe salvestuse vahel (Yesiler jt., 2021). Tänapäeval on aga üha enam kasutusel süvaõppel põhinevad meetodid (Liu jt., 2023; Du jt., 2021), kus masinõppemudelid õpivad ise sobivad esitusinvariantsed tunnused suurtest andmehulkadest. Sellised mudelid võimaldavad paremini toime tulla keeruliste variatsioonidega ning saavutavad üldjuhul paremaid tulemusi just sellistes olukordades, kus traditsioonilised tunnused jäävad hätta – näiteks rahvapärases materjalis, kus esituste varieeruvus on loomulik osa muusikalisest praktikast.

Sageli kasutatakse selleks nn hõlmanguruume (ingl k *embedding space*) – kujuteldavaid matemaatilisi „kaarte“, kuhu iga lugu asetatakse selliselt, et sarnased lood paikneksid lähestikku, erinevad aga üksteisest kaugel. Iga lugu esitatakse seal numbrilise vektorina ehk koordinaatide kogumina, mille põhjal saab arvutada lugudevahelisi kaugusi. Selliste ruumide õppimiseks kasutatakse masinõppes meetodeid, mis suunavad sarnased lood koondult grupeeruma. Üheks levinud lähenemiseks on kolmikvõrk (*triplet network*; Hoffer ja Ailon, 2015), kus mudelit õpetatakse kolmikute abil: ankur (alguslugu), selle teine esitus (positiivne näide) ning mõni muu, sisuliselt erinev lugu (negatiivne näide). Mudelile antakse ülesandeks „paigutada“ need lood ruumi nii, et sama loo versioonid jääksid üksteisele lähedale ja võõrad lood kaugemale.

⁷ https://www.music-ir.org/mirex/wiki/2006:Audio_Cover_Song

⁸ *Feature engineering* ehk tunnuste või omaduste väljatöötamine tähendab antud kontekstis protsessi, kus inimene määratleb, milliseid heli omadusi mõõta ja kasutada muusikaliselt olulise informatsiooni leidmisel.

Säärast õppimist suunab kolmikkadufunktsioon (*triplet loss*), mis mõõdab, kas mudel asetab sama loo versioonid hõlmanguruumis piisavalt lähestikku ja erinevad lood piisavalt kaugele (Schroff jt., 2015: 2). Kui kaugused on valed, suunab kadufunktsioon mudelit lugude paigutust parandama. Sellise lähenemise eesmärk on võimaldada mudelil õppida automaatselt esituste vahelisi seoseid, ilma et tuleks käsitsi defineerida, milliseid heliandmete tunnuseid täpselt järgida. Tulemuseks on paindlik süsteem, mis suudab edukalt töötada ka muusikaga, kus esitused varieeruvad suuresti – nagu on sageli rahvapillilugude puhul.

Antud töö kontekstis on oluline rõhutada, et kaverlugude tuvastamise uurimisprobleem on oma olemuselt väga sarnane ülesandega leida omavahel meloodiliselt seotud rahvapillilood, mida on eri aegadel mänginud erinevad esitajad, sageli väiksemate või suuremate meloodiliste ja rütmiliste variatsioonidega. Selliste lugude koondamine ühise viisitüübi alla nõuab samu analüütilisi lähenemisi nagu kaverite tuvastamine popmuusikas. Seetõttu püüan antud töös rakendada popmuusikas juba läbiproovitud meetodeid eesti rahvapillimuusika analüüsimisel, et automaatselt tuvastada meloodiliselt sarnaseid palu.

2. Andmestik

Käesolevas peatükis tutvustan töös kasutatavat lähteandmestikku ning kirjeldan uurimiskorpuse loomise protsessi, mis hõlmas pillilugude tuvastamist arhiivandmestikust, helifailide tehnilist ettevalmistust ja käsitsi teostatud märgendamist.

2.1. Lähtematerjal

Käesoleva töö lähtematerjaliks valisin Eesti Rahvaluule Arhiivis (ERA) hoiustatud pillimuusika helisalvestused. Uurimisainese ulatuse mõistliku piiramise eesmärgil keskendusin 20. sajandil⁹ Eestis kogutud salvestustele, ning salvestustele, mis on kogutud välismaal, kuid mille metaandmed sisaldavad eestikeelset pealkirja või mille esitaja nimi viitab eestipärasele päritolule. Selline piirang oli vajalik, et vältida korpuse liigset hajumist ning tagada uurimistöö teostatavus.

Töö ettevalmistuse etapis kaalusin võimalust kaasata ka Eesti Rahvusringhäälingu (ERR) heliarhiivi salvestused. Sellest ideest tuli siiski loobuda, kuna ERR-i arhiivimaterjalide metaandmed osutusid ebaühtlasteks ja sageli puudulikeks. Ehkki viiside võrdlemiseks arvutuslike meetoditega piisab teoreetiliselt üksnes helifailist, osutus käesolevas töös praktilistel kaalutlustel vajalikuks koostada struktuurne uurimiskorpus, mis sisaldaks iga salvestuse kohta ka olulisi taustandmeid, nagu pealkiri, esitaja nimi, kogumisaasta, koguja nimi, kihelkond ja mängitav pill.

Siiski tuleb rõhutada, et käesoleva töö keskmeks on eelkõige arvutusliku meetodika praktiline väljatöötamine ja kohandamine; arhiivimaterjali käsitus on seejuures valikuline ja lähtub meetodilistest vajadustest, mitte täielikust ülevaatlikkusest.

2.1.1. Ülevaade Eesti Rahvaluule Arhiivi helikogudest

Eesti Rahvaluule Arhiivis (ERA) leiduvad helisalvestused jagunevad 2021. aasta seisuga 14 erineva seeria vahel (ERA heliarhiiv, i.a.), mis sisaldavad eri ajaperioodidel erinevate tehniliste vahenditega tehtud salvestusi. Salvestused hõlmavad erinevaid rahvaluuležanre, sealhulgas regilaule, uuemaid rahvalaule, pillilugusid, vanasõnu, muistendeid, jutte,

⁹ Täpsemalt perioodil 1912–1999.

uskumusi, kombekirjeldusi jne. 2021. aasta lõpu seisuga sisaldas ERA heliarhiiv kokku 185 797 pala 11 568 säilikul (samas), kuid need arvud on tänaseks juba kasvanud. ERA heliarhiivi kujunemislugu ja helisalvestamise ajalugu on põhjalikult käsitletud näiteks Janika Oras oma doktoritöös (Oras, 2008), mistõttu piirdub siinne ülevaade üksnes olulisimaga käesoleva uurimistöökontekstis.

Kõige varasemad Eesti Rahvaluule Arhiivis leiduvad helisalvestused pärinevad aastast 1912, mil soome folklorist Armas Otto Väisänen alustas tänapäeva Eesti aladel fonograafia salvestamist¹⁰. Tema tööd jätkasid hiljem eestlastest heliloojad ja kogujad Cyrillus Kreek, Eduard Oja, Johannes Muda jt. Fonograafia tehtud salvestused (kogu **ERA Fon.**) talletati vaharullidele, mis on paraku haprad ja madala helikvaliteediga. Madalast kvaliteedist hoolimata on nad siiski kaasatud käesolevas töös kasutatud korpusesse, moodustades veidi enam kui 5% kogu andmestikust.

Kvaliteedilt oluliselt paremad helisalvestused asuvad Herbert Tampere ja August Pulsti eestvedamisel Riigi Ringhäälingu studios salvestatud reportaažplaatidelt. Vastav kogu (**ERA, PI.**) on salvestatud ajavahemikus 1936–1938 ning sisaldab instrumentaalpalasid paljudelt tuntud eesti rahvamuusikutelt, kelle hulka kuuluvad näiteks Mihkel Toom, Jaan Rand, Jaan Piht jpt.

Helisalvestuste arvult kõige suurema hulga moodustavad magnetofoniga tehtud salvestused, millega Eesti Kirjandusmuuseum¹¹ (EKM) alustas juba 1953. aastal ja mis jagunevad kaheks suuremaks seeriaks - **RKM, Mgn. I** (stereolindistused) ja **RKM, Mgn. II** (monolindistused), millest viimane moodustab enam kui poole tervest uurimiskorpusest.

Paralleelselt EKM-ile salvestasid magnetofoniga ka Eesti Raadio (perioodil 1955–1992), TRÜ Eesti kirjanduse ja rahvaluule kateeder (1955–1989) ning Keele ja Kirjanduse Instituut (1949–1988), mille helisalvestused on tänaseks liidetud ERA helikoguga (Eesti Raadio salvestused siiski osaliselt) ja moodustavad vastavalt seeria **RKM, Mgn. ER** ning kogud **EKRK, Fon.** ja **KKI, RLH.**

¹⁰ Tuleb siiski märkida, et need ei ole vanimad teadaolevad eesti rahvapillilugude helisalvestused üldiselt. Juba 1908. aastal salvestas soomerootsi muusikateadlane Otto Andersson Helsingis Hiiu maalt pärit meremehe Jüri (Georg) Bruusi esitatud hiiu kandle palasid (Kõmmus, 2017: 10).

¹¹ Tol ajal nimega “ENSV Teaduste Akadeemia Fr. R. Kreutzwaldi nimeline Kirjandusmuuseum” – Meist. Eesti Kirjandusmuuseumi koduleht, <https://www.kirmus.ee/et/meist> (vaadatud 08.08.2025).

1990. aastatel tulid käibele uued heli salvestamise võimalused, sh digitaalsed salvestustehnikad, millega kaasnes ka uute kogude loomine. 20. sajandi pillilugude seisukohalt on neist kõige olulisemad **ERA**, **DAT** (DAT-kassettsalvestused) ja **FAM** (stereokassettsalvestused), milles on kokku üle 1500 helisalvestuse, ent mille digiteerimine pole veel lõppenud. Möödunud sajandi lõpul ning käesoleva alguses salvestati ka digitaalsetele MiniDisc-ketastele. Vastavad salvestused – koos üksikute DAT-maki salvestustega – on koondatud kogusse **ERA**, **CD**. Käesolevasse uurimiskorpusesse kaasasin sellest kogust üksnes salvestused ajavahemikust 1997–1999.

Korpusest jätsin välja ERA kogud **ERA**, **MD** (digitaalsalvestused minidiskidel) ja **ERA**, **DH** (digitaalsalvestused arvuti kõvakettal), kuna vastavad salvestused pärinevad juba 21. sajandist.

Kogude täpne ülevaade ja korpusesse kaasatud helisalvestuste arv on esitatud jaotises 2.2.1, Tabelis 1.

2.1.2. Pilliloo mõiste antud töö kontekstis

Käesolevas töös määratlen pilliloo kui mistahes helisalvestuse, milles on kuuldav vähemalt üks muusikainstrument. Selline määratlus tugineb töö metoodilisele eesmärgile: keskenduda helimaterjali struktuursele analüüsile ja testida arvutuslikke meetodeid rahvaviiside meloodilise sarnasuse võrdlemiseks. Esituse tähenduslik ja kultuuriline kontekst – sealhulgas funktsioon, sotsiaalne olukord või pealkirjaga seotud tõlgendused – jäävad seejuures vaatluse alt välja. Fookuses on ühtse ja arvutuslikult töödeldava andmestiku loomine, mille keskmes on meloodia kui uurimisobjekt.

2.1.3. Eesti rahvapillimuusika arhiivisalvestuste eripäradest

Arhiivisalvestuste üheks keskseks eripäraks rahvapillimuusika uurimisel on nende helikvaliteedi märgatav varieeruvus, mis avaldub nii salvestustasemes, mürasuhte tasakaalus kui ka esitusheli selguses. Paljud ülesvõtted on tehtud välitöödel, kasutades tolle aja salvestustehnikat, mille võimalused olid piiratud võrreldes tänapäevaste tehnoloogiatega. Kuigi osa salvestustest on tehtud ka stuudios, kus tehniline kvaliteet on reeglina parem, ei vasta ka need enamasti nüüdisaegsele stuudiokvaliteedile.

Sellest tulenevalt sisaldavad arhiivisalvestused sageli märkimisväärses mahus taustamüra, häireid või salvestusseadmete piirangutest tingitud helilisi moonutusi. Lisaks tehnilistele aspektidele iseloomustab arhiivimaterjali ka sisuline mitmekesisus: muusikaliste esituste kõrval leidub sageli vestlusi, juhendavaid kommentaare või muid kõrvalhelisid, millel puudub muusikaline tähendus.

Eelpool kirjeldatud piirangud muudavad arhiivisalvestuste analüüsimise ja automatiseeritud töötuse võrreldes kaasaegsete heliülesvõtetega oluliselt keerulisemaks. Sellest hoolimata langetasin käesolevas uurimuses teadliku otsuse jätta salvestused sisuliselt töötlemata. Lähtusin eeldusest, et rakendatav masinõppemudel peaks pärast treeningperioodi suutma eristada sagedusspektris muusikaliselt olulist teavet (nt meloodiat või harmooniat) ebaolulistest komponentidest (nt taustamüra või vestlusfragmendid).

Seetõttu kasutasin analüüsis kõiki salvestusi nende täies ulatuses, rakendamata lõikamist ega puhastust. Ainsaks eelnevaks töötlemisetapiks oli helifailide teisendamine sobivasse andmevormingusse (vt jaotist 2.2.2), mis ei mõjutanud tajutavat muusikalist sisu.

2.2. Uurimiskorpuse loomine

Et võimaldada masinõppel põhinevat muusikalist analüüsi, oli esmaseks eeltingimuseks usaldusväärse ja sihipäraselt struktureeritud uurimiskorpuse olemasolu. Kuigi ERA andmestikes leidub ulatuslikult rahvapillimuusikat, puudus nende seas terviklik ülevaade üksikute pillilugude kohta. Seetõttu tuli esmalt käsitsi koostada pillilugude loend ja täpsustada olemasolevaid metaandmeid, et moodustada analüüsiks sobiv lähteandmestik.

Järgnevad alajaotused kirjeldavad üksikasjalikult, milliste sammude kaudu see uurimiskorpus loodi: alates pillilugude nimekirja koostamisest ja helifailide tehnilisest ettevalmistusest kuni salvestuste sisulise märgendamiseni viisitüüpide alusel. Loodud korpus on ühtaegu nii selle töö alusmaterjal kui ka potentsiaalne lähtepunkt edasistele rahvapillimuusika uurimustele.

2.2.1. Pillilugude nimekirja koostamine

Esimese sammuna uurimiskorpuse loomisel oli vajalik koostada terviklik nimekiri kõigist 20. sajandil Eesti Rahvaluule Arhiivis leiduvatest pillilugudest. Kuigi arhiivis leidis varasem tabel, mis kajastas pillilugude statistikat esitajate, kihelkondade ja kogude lõikes, ei

sisaldanud see teavet individuaalsete salvestuste kohta. Seetõttu osutus vältimatuks uue, detailsema andmestiku koostamine, mis hõlmaks iga pilliloo kohta eraldi kirjet ning võimaldaks nende hilisemat tehnilist ja sisulist töötlemist.

Pillilugude esmane tuvastamine ja andmete kogumine toimus Eesti Kirjandusmuuseumi infosüsteemi Kivike¹² kaudu, mis toimib digitaalse repositooriumina, koondades eesti rahvaluule, kirjakultuuri ja kultuuriloo materjale. Märkimisväärne osa Eesti Rahvaluule Arhiivis talletatud pillilugudest on digiteeritud ning varustatud põhiliste metaandmetega, sealhulgas kogumise aja, koha, koguja nime ja muude arhiivitunnustega. Kivike võimaldab nende andmete päringut läbi liitotsingu mooduli ning tulemuste eksporti struktureeritud CSV-formaadis, mis sobib edasiseks töötamiseks.

Pillilugude leidmiseks kasutasin liitotsingut järgmiste parameetritega:

- Leitav: Pala
- Arhiiv: Eesti Rahvaluule Arhiiv (ERA)
- Kataloog: Heliarhiiv
- Žanr: Pillilugu

Otsingupäringu koostamisel jätsin otsinguväljadest teadlikult välja lõpuaasta (1999), kuna puudus kindlus selle osas, kuidas Kivikese liitotsingu sisemine loogika käsitleb piiripealseid juhtumeid – näiteks olukordi, kus a) salvestuse lõppkuupäev on määramata või b) aasta 1999 jääb määratud algus- ja lõppkuupäeva vahele. Et tagada andmestiku usaldusväärsus, eemaldas 2000. aastast alates kogutud palad otsingutulemustest käsitsi. Samuti jätsin välja välismaal kogutud pillilood, millel puudus eestikeelne sisukirjeldus või mille esitajate nimed ei viidanud selgelt eesti päritolule.

Sel moel õnnestus mul leida kokku 6319 pillilugu. Samas tuleb arvestada, et mitte kõik arhiivisalvestused ei ole tänaseks digiteeritud ega Kivikesse sisestatud. Antud otsing kasutas leitava üksusena mõistet *pala*, mis tähistab väikseimat sisulist folklooriüksust – antud juhul üksikut pillilugu (Kivikese veebipõhine juhend, 2025). Palad koonduvad *säilikutesse*, milleks võivad olla heliplaadid, magnetofonilindid või kassetid. Üks säilik võib sisaldada mitmeid palasid, sageli ühelt esitajalt, kuid mitte alati. Kuigi säilikute üldandmed võivad olla

¹² <https://kivike.kirmus.ee>

infosüsteemis nähtavad, ei pruugi neis sisalduvad palad olla veel eraldi kirjetena süsteemi sisestatud. Seetõttu ei kajastu kõik ERA pillilood Kivikese otsingutulemustes.

Sellest tulenevalt lähtusin lõpliku nimekirja koostamisel eelkõige ERA-s leiduvatest füüsilistest inventariraamatutest, mille põhjal on Kivikesse andmeid sisestatud. Töötasin rea haaval läbi kõik olemasolevad inventariraamatud, lisades nimekirja Kivikeses puuduvad pillilood, kuid ühtlasi kontrollides ja vajadusel korrigeerides juba sissekantud kirjeid. See oli töömahukas ja ajaliselt koormav protsess, mis muutus pikapeale rutiinseks ning altiks näpuvigadele. Vigade vähendamiseks ja andmete järjepidevuse tagamiseks jaotasin töö etapiviisiliselt, kontrollisin sisestusi korduvalt ning rakendasin lisaks ka arvutuslikke võtteid, näiteks duplikaatide automaatset tuvastust ERA viidete alusel.

Töö tulemusena kujunes andmestik¹³, mis sisaldab kokku 9658 pillilugu. Mõned salvestused jäid lõplikust versioonist siiski välja, kuna hilisema kontrolli käigus selgus, et need ei vastanud töö käigus määratletud pilliloo kriteeriumile (puudus pilliline esitus). Võrreldes arhiivis varem eksisteerinud pillilugude tabeliga suurenes tulemuslik kirjete arv ligikaudu 2000 pala võrra. Kogudepõhine jaotus on esitatud Tabelis 1.

Tabel 1. ERA helisalvestuste seeriad/kogud¹⁴ ja neist uurimiskorpusesse kaasatud pillilugude statistika (sisaldab ka digiteerimata helifailidega kirjeid).

Kogu	Kirjeldus	Salvestused aastatest	Pillilugusid
ERA, Fon.	vaharullid	1912–1948	527
ERA, Pl.	reportaažplaadid	1936–1938	310
RKM, Mgn. I	stereolindistused	1973–1993	157
RKM, Mgn. II	monolindistused	1953–1993	5559
RKM, Mgn. ER	Eesti Raadio lindistused	1957–1992	809
RKM, Mgn. K	koopiad teistest arhiividest	1939–1991	0
ERA, DAT	DAT-magnetofoni salvestused	1992–	941
FAM	stereokassettsalvestused, analoog	1991–	647
ERA, CD	digitaalsalvestused CD-del	1997–2002	64
ERA, MD	digitaalsalvestused minidiskidel	2003–	0
ERA, DH	digitaalsalvestused arvuti kõvakettal	2003–	0
ERA, ML	salvestused magnetlindil	1957–	136

¹³ Uurimiskorpuse tabel on kõigile kättesaadav aadressil:

https://docs.google.com/spreadsheets/d/1LkuVKidj8XozlD96gwVry6YEXLrEjv_Hkas_g97UmDY


¹⁴ <https://www.folklore.ee/era/leidmine/heli.htm>

EKRK, Fon.	Eesti kirjanduse ja rahvaluule kateedri magnetofonilindid	1955–1989	71
KKI, RLH	Keele ja Kirjanduse Instituudi rahvaluule helisalvestused, monolindistused	1949–1988	437


Pärast andmestiku koostamist pöördusin Eesti Rahvaluule Arhiivi poole, et taotleda juurdepääsu vastavatele helifailidele. Pärast materjali kasutamistingimuste lepingu allkirjastamist anti mulle ligipääs suuremale osale soovitud salvestustest. Siiski ei olnud võimalik kõiki 9658 kirjes sisalduvaid salvestusi kätte saada, kuna osa neist ei olnud veel digiteeritud – eriti puudutab see FAM stereokassettide kogu. Seetõttu kujunes käesolevas töös kasutatavate helifailide lõplikuks arvuks 9222. Pillilugude jaotus aastate ja kihelkondade lõikes on esitatud Joonistel 6 ja 7.

Visualiseerimiseks kasutasin enda loodud tarkvara, millest tuleb põgusalt juttu jaotises 2.2.3 ja on ülevaatlilikult kirjeldatud Lisas 1.

Joonis 6. Uurimiskorpusesse kaasatud pillilugude statistika aastate lõikes.



Joonis 7. Uurimiskorpusesse kaasatud pillilugude statistika kihelkondade lõikes. Parema loetavuse huvides ei kaasanud ma kaardile kihelkondade nimesid, vaid üksnes statistika, mitu pilliloo helisalvestust igast kihelkonnast (või linnast) on kogutud.



Kokkuvõtlikult võib öelda, et loodud andmestik hõlmab märkimisväärset osa Eesti Rahvaluule Arhiivi pillimuusika salvestustest. Võrreldes arhiivisises varasema koondtabeliga on selle ulatus suurem, tuginedes nii Kivikese infosüsteemis kättesaadavatele üksikandmetele kui ka arhiivi füüsilistele inventariraamatutele. Ehkki osa salvestusi ei ole tänaseni digiteeritud või pole veel Kivikesse sisestatud, pakub 9658 kirjest koosnev korpus – millest 9222 helifaili osutus analüüsiks kasutatavaks – esinduslikku ja seni kõige terviklikumalt struktureeritud lähteandmestikku eesti rahvapillimuusika arvutuslikuks uurimiseks.

2.2.2. Helifailide konverteerimine

Kõik käesolevas töös kasutatud helisalvestused on saadud Eesti Rahvaluule Arhiivist .wav-formaadis diskreetimissagedusega 44,1 kHz, mis vastab CD-plaadi standardsele helikvaliteedile. Kuigi selline kõrge diskreetimissagedus võimaldab salvestada kõrgsageduslikku helisisu, ei ole see masinõppe ja muusika analüüsi kontekstis üldiselt

vajalik ega praktiline. Tüüpiliselt kasutatakse heliandmete masinõppepõhisel analüüsimisel madalamat diskreetimissagedust 16 kHz (vt näiteks Louro jt, 2024: 8; Jang jt, 2019: 4; Hernandez-Olivan jt, 2021), kuna see võimaldab märkimisväärselt vähendada nii andmemahtu kui ka andmetöötluseks kuluvat aega.

Samas säilib ka selle madalama diskreetimissageduse puhul piisavalt oluline informatsioon heli omaduste ja mustrite analüüsimiseks ning masinõppemudelite treenimiseks. Nyquist-Shannoni teoreemi järgi peab diskreetimissagedus olema vähemalt kaks korda suurem kui kõrgeim analüüsitav sagedus. Kuna enamik muusikalistest komponentidest – sealhulgas põhitoonid ja suurem osa tajutavatest ülemhelidest – paiknevad praktiliselt sagedusvahemikus alla 8 kHz (näiteks on klaveri kõige kõrgem noot C8 sagedusega 4186 Hz¹⁵), võimaldab 16 kHz diskreetimissagedus nende piisavalt täpset esitamist ja analüüsi.

Lisaks madalamale diskreetimissagedusele, kasutatakse analüüsis tihti peale ka ühekanalist helisignaali. Ka käesolevas töös kasutatav masinõppemudel eeldab just ühekanalist sisendheli, mistõttu oli tarvilik konverteerida kõik kahekanalised stereosalvestused monosalvestusteks. Originaalfailide konverteerimiseks 16 kHz ühekanalisteks monosalvestusteks kirjutasin Pythoni skripti, mis on välja toodud Lisas 4.

2.2.3. Andmete märgendamine

Käesoleva uurimistöö raames kasutatavate arvutuslike meetodite rakendamiseks ei ole piisav üksnes digiteeritud helifailide olemasolu, vaid oluline on ka nende korrastatud ja struktureeritud märgendamine. Masinõppemudeli edukaks treenimiseks ja testimiseks on vaja koostada treeningandmestik, mis sisaldaks selgelt piiritletud positiivseid ja negatiivseid näiteid. See võimaldab masinõppemudelil õppida eristama erinevaid viisitüüpe vastavalt spektrogrammidest tuvastatavatele mustritele, mille abil on võimalik muusikapalade korrektne klasterdamine.

Selle eesmärgi saavutamiseks alustasin esmalt helisalvestuste süstemaatilist läbikuulamist ja sarnaste esituste koondamist ühise nimetaja ehk viisitüübi alla. Olles teadlik, et tegemist on aeganõudva ning mahuka tööga, tundsin vajadust efektiivse ja mugava märgendamisprotsessi järele, mis võimaldaks andmete kiiret ja täpset määratlemist. Praktikas kujutasin ette lahendust, kus andmeid on võimalik hoiustada ja muuta tabelina, võimaldades samal ajal

¹⁵ <https://mixbutton.com/music-tools/frequency-and-pitch/music-note-to-frequency-chart>

kuulata salvestusi otse samast vaatest. Sellise lähenemise eelisena nägin eeskätt võimalike vigade minimeerimist: soovisin vältida olukorda, kus pendeldamine erinevate keskkondade, näiteks Exceli tabeli ja operatsioonisüsteemi kaustastruktuuri vahel, põhjustaks kogemata vale helifaili kuulamist ja sellest tingitud märgendamisvigu.

Sobiva lahenduse leidmiseks kaalusin esmalt olemasolevaid vahendeid. Internetist otsides näis esmapilgul sobivaimaks veebipõhine platvorm Airtable, mis võimaldas tabeli kujul andmete haldamist koos integreeritud helifailide kuulamise võimalusega. Sügavama analüüsi tulemusena selgus siiski, et Airtable ei vasta minu vajadustele, seda peamiselt kahel põhjusel: esiteks oleks teenuse hind andmete mahu ja hulga tõttu liiga kõrge, teiseks puudus vajalik hulgiüleslaadimise tugi, mis tähendas, et iga helifail oleks tulnud üles laadida eraldi. Lisaks jäi küsimärgi alla ka õiguslik aspekt, kuna mul ei olnud kindlust, kas ERA helifailide üleslaadimine kolmanda osapoolse serveritesse oleks olnud üldse lubatud.

Eespool nimetatud puuduste tõttu otsustasin loobuda Airtable'i kasutamisest ning asusin looma kohandatud tarkvaralahendust, mis vastaks täpselt minu vajadustele. Loodud tarkvaralahendust kirjeldan detailsemalt Lisas 1, kuid praegusel hetkel olgu mainitud, et käesolevas töös käsitlen seda vaid kui abivahendit andmete hõlpsamaks ja kiiremaks märgendamiseks. Selle põhjuseks on soov säilitada töö keskmes muusika andmeanalüütika ja masinõppemeetodite rakendamine rahvapillimuusika uurimisel. Sellegipoolest näen, et loodud tarkvarast võiks tulevikus kujuneda laiemalt kasutatav praktiline tööriist nii pärimusmuusikutele kui ka rahvapillimuusika uurijatele.

Märgendamise läbiviimisel võtsin esialgseks eesmärgiks määrata viisitüüp vähemalt 10–15% kõikidest helisalvestustest. Alustasin tuttavatest lugudest, millega olen varasemalt kokku puutunud pillimängu ja rahvatantsuga tegelemise kaudu. Potentsiaalsed kandidaadid selekteerisin korpusest välja otsingusõnade abil, mis kajastusid loo pealkirjas või sisukirjelduses. Näiteks viisitüübi “Perekonnavalss” puhul filtreerisin välja kõik kirjed, mille pealkirjas või kirjelduses esinesid sõnad “perekonna” (nt “Perekonnavalss”, “Perekonnavaltser”) või “vanamees” (nt “Üks vanamees raius”). Seejärel kuulasin valitud salvestused üksipulgi läbi ja määrasin sobivuse korral vastava viisitüübi.

Joonisel 8 on toodud näitena väljavõtte loodud tarkvara prototüübi kasutusest andmete märgendamise käigus, milles määran esitusele **RKM, Mgn. II 2208 d** sobivat viisitüüpi.

Tarkvara võimaldab ühes vaates tabeli kujul andmete haldamist ning helisalvestuste kuulamist.

Joonis 8. Väljavõte loodud tarkvarast, mis võimaldab töödelda andmeid tabelina ning samas vaates helisalvestuse kuulamist.

The screenshot shows a web application interface for a music database. At the top, there are several filter menus: 'Viide' (set to 'perekonna'), 'Viis', 'Aasta', 'Pill', 'Esitaja', and 'Kihelkond'. Below these is a table with 10 rows of records. Each row contains a record ID, a title, a genre (all 'Perekonnavalss'), a year, an instrument, a performer, and a location. The table is currently displaying records from 1967 to 1971. At the bottom of the table, there are pagination controls (10, 25, 50) and a page indicator (1, 2, 3, 4, 5). Below the table is a playback player for the selected record 'RKM, Mgn. II 2208 d - Perekonnavalss < Martna khk. < Jüri Toomingas (1971)'. The player shows a progress bar at 00:41 / 01:16.

Viide	Viis	Aasta	Pill	Esitaja	Kihelkond
RKM, Mgn. II 1379 d	Perekonnavalss	1967	akordion	Jaan Veskiäär	Kolga-Jaani khk.
RKM, Mgn. II 1488 c	Perekonnavalss	1968	kannel	Hugo Loot	Rannu khk.
RKM, Mgn. II 1725 f	Perekonnavalss	1970	lõõts	Elmar Koovik	Võru linn
RKM, Mgn. II 1727 a	Perekonnavalss	1970	lõõts	Elmar Koovik	Võru linn
RKM, Mgn. II 1729 a	Perekonnavalss + vestlus: kannelt hakkas mängima 10-aastasena, esimene lugu oli perekonnavalss	1970	kannel	Leonhard Kuuskalu	Tartu linn
RKM, Mgn. II 1774 d	Perekonnavalss "Vanamees raidus" (+ vestlus ringmängust)	1970	lõõts	Hermann Kukka	Paistu khk.
RKM, Mgn. II 2002 a	Perekonnavalss	1971	kannel	Leonhard Kuusk	Tartu linn
RKM, Mgn. II 2029 d	Perekonnavalss	1971	lõõts	Aleksander Kompus	Viljandi khk.
RKM, Mgn. II 2191 e	Perekonnavalss	1971	lõõts	Evald Zirk	Põlva khk.
RKM, Mgn. II 2208 d	Perekonnavalss	1971	lõõts	Jüri Toomingas	Martna khk.

Viisitüübi määramisel lähtusin peamiselt meloodia tunnustest ning isiklikust muusikalisest tunnetusest. Eestis levinud pillilood koosnevad enamasti A- ja B-osadest, mis eri esitustes varieeruvad erineval määral. Esineb ka lugusid, millel on küll identne A-osa, kuid erinev B-osa (või vastupidi), samuti võib esineda ka kolmas C-osa. Sellistel puhkudel lähtusin määramisel lugude ühisosast – kui vähemalt üks oluline meloodiline lõik kattus erinevate esituste vahel ning erisused ei sarnanenud mõne teise viisitüübiga, liigitasin need samasse tüüpi. Viisitüübi kirjakuju lähtusin eelkõige esituste pealkirjade statistikast, tantsulugude puhul aga raamatutest “Valimik XX sajandi I poole seltskonnatantse” (Aassalu jt, 1997), “Valimik eesti rahvatantse” (Põldmäe ja Tampere, 1938) ja “Viron vakka: 105 eesti rahvatantsu” (Torop, 2008).

Kuulates helisalvestusi, kujunes vaatamata esituste variatiivsusele kiiresti välja intuiitvne tunnetus meloodia ootuspärasest kulgemisest. Selline ettekujutus põhineb meloodia mõttelisel põhiliinil või algkujul, mille olemust on kirjeldanud ka Juhan Uppin oma väitekirjas (Uppin, 2022: 64). Selline muusikalise ootuspärasuse tunnetamine kujunes oluliseks

hindamiskriteeriumiks viisitüüpide määramisel. Protsessi toetas ka asjaolu, et paljud lood olid mulle varasemast tuttavad, eriti tantsulood.

Tuleb siiski rõhutada, et selline kuuldel põhinev liigitamine on paratamatult subjektiivne. Piir, mille puhul variatiivsus õigustab uue viisitüübi määramist, ei ole üheselt määratletav ning erinevad uurijad võivad samade salvestuste alusel jõuda erinevate otsusteni. Sarnane määratlemisraskus on iseloomulik ka näiteks muusika žanride liigitamisele, kus täielik konsensus sageli puudub (Dong, 2018: 1).

Sellest hoolimata ilmnes, et enamik eesti rahvapillilugudest kujutab endast meloodiliselt üheselt tuvastatavaid tüüpe. Märghendamise käigus lähtusin töökindla lähteküsimusena järgmisest printsiibist: *kas mina ise, tuginedes ainult meloodiale, liigitaksin selle esituse konkreetse viisitüübi alla?* Positiivse vastuse korral lisasin esituse treeningandmestikku, negatiivse või kõhkleva puhul jätsin selle välja. Lisaks jätsin välja kõik salvestused, mis sisaldasid rohkem kui ühte pala või mille meloodia oli raskesti eristatav – näiteks popuriid või parmupillilood –, vältimaks ebaselgete sisuelementide mõju mudeli õppele.

Kirjeldataud metoodika alusel märgendasin kokku 2400 helisalvestust (26% korpusest), mis jagunesid 150 erinevaks viisitüübiks. Sellest moodustus minu treeningandmestik, mille nimetasin asjakohaselt **folk150** andmestikuks. Andmestiku nimetamisel järgisin tavapäraselt valdkonna praktikat, kus nimi sisaldab arvu, mis viitab esituste või lugude arvule. Vastavat andmestikku kasutasin järgnevalt masinõppemudeli treenimiseks ning spektrogrammidel põhinevate pillilugude automaatseks klasterdamiseks.

3. Metoodika

Käesolevas peatükis kirjeldan kasutatud arvutuslikku metoodikat, mille abil analüüsisin ja rühmitasin rahvapillimuusika helisalvestusi. Esmalt tutvustan töös kasutatavat masinõppemudelit CoverHunter, selle arhitektuuri, tööpõhimõtet ja valiku põhjendust. Seejärel selgitan, kuidas hindasin mudeli tõhusust kvantitatiivsete mõõdikute abil ning milliseid samme sisaldas mudeli optimaalse konfiguratsiooni leidmine. Lõpuks kirjeldan, kuidas loodud mudel võimaldas tuvastada salvestustevahelisi muusikalisi sarnasusi ning neid visualiseerida kahemõõtmelisel kaardil, mille alusel sai eristada sama või sarnast viisi esitusviise.

3.1. CoverHunter mudeli tutvustus

CoverHunter on 2023. aastal avaldatud masinõppemudel, mis on loodud muusikaliste seoste ja sarnasuste avastamiseks erinevate helisalvestuste vahel. Selle peamiseks eesmärgiks on tuvastada, millised helisalvestused on sama muusikapala erinevad versioonid ehk kaverid.

3.1.1. Mudeli arhitektuur

Järgnevalt toon välja CoverHunter mudeli peamised komponendid. Kirjeldus põhineb artiklil *CoverHunter: Cover Song Identification with Refined Attention and Alignments* (Liu jt., 2023).

CoverHunter põhineb *Conformer*-arhitektuuril, mis ühendab kahte tüüpi tehnoloogiaid: konvolutsioonilised närvivõrgud (CNN) ja transformerid. Konvolutsioonilised närvivõrgud sobivad hästi lühiajaliste mustrite (näiteks lühikeste rütmiliste või meloodiliste motiivide) äratundmiseks, samas kui transformerid võimaldavad mudelil haarata pikaajalisi seoseid muusikas (näiteks suuremad vormilised ülesehitused ja korduvad teemad). Nende ühendamise aitab mudelil mõista keerukaid muusikalisi struktuure nii väikestes kui ka suurtes ajaskaalades, mis on eriti oluline kaverite tuvastamisel, kus samad meloodiad võivad esineda väga erinevates esitusviisides.

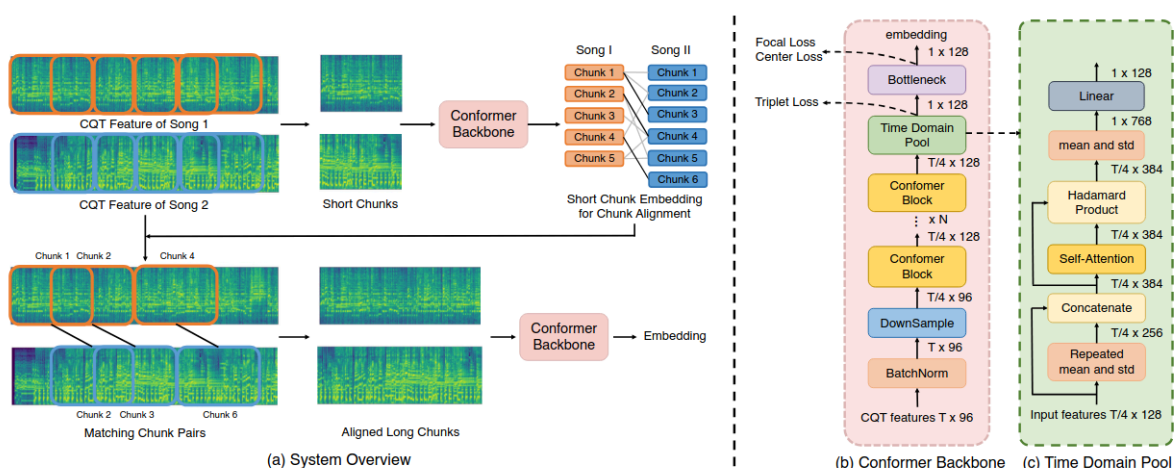
Lisaks kasutab CoverHunter tähelepanupõhist ajalist agregeerimist (*attention-based time pooling*). Lihtsustatult tähendab see, et mudel ei võta kõiki helilõike võrdselt arvesse, vaid

pöörab rohkem tähelepanu just nendele osadele, mis sisaldavad muusikaliselt olulist teavet. Näiteks võib mudel pidada tähtsamaks lõiku, kus kõlab meloodia, ja vähemoluliseks taustasaate osi. Selline lähenemine aitab luua igale loole või salvestusele lõppkokkuvõttes ühe hõlmanguvektori (ingl k *embedding vector*), mis sisaldab just neid tunnuseid, mis on kõige iseloomulikumad ja kaverite tuvastamiseks kõige kasulikumad.

Mudeli treenimine toimub jämedast peeneks (*coarse-to-fine training*) põhimõttel. Alguses õpib mudel leidma umbkaudseid vastavusi erinevate laulude lõikude vahel, et suunata tähelepanu suurtele struktuuridele ja üldisele sarnasusele. Seejärel toimub täpsem treenimine, kus juba varasemalt leitud vastavused aitavad mudelil keskenduda väiksematele, detailsematele sarnasustele. Selline kahefaasiline lähenemine aitab toime tulla probleemidega, mis tekivad kaverilaulude struktuuriliste ja rütmiliste erinevuste tõttu – näiteks kui ühes esituses on muusikalised lõigud ümber tõstetud, väljavenitatud või erinevas järjekorras.

Ülevaade CoverHunter mudel arhitektuurist on välja toodud Joonisel 9.

Joonis 9. CoverHunteri ülevaade. (a) Kõigepealt jagatakse lood lühikesteks lõikudeks, mille hõlmanguvektorid joondatakse vastavusse. Seejärel kasutatakse vastavusse viidud pikki lõike täpsustatud mudeli treenimiseks kaverilaulude otsinguks. (b) *Conformer*-põhine struktuur koos ajalise agregeerimise mooduliga. (c) Tähelepanupõhise ajalise agregeerimise mooduli üksikasjalik struktuur. (Liu jt., 2023: 4)



3.1.2. Mudeli väljund

CoverHunteri peamiseks väljundiks on fikseeritud pikkusega (128-mõõtmelised) hõlmanguvektorid, mis kirjeldavad helisalvestuste muusikalisi omadusi kompaktsel ja võrreldaval kujul. Need vektorid võimaldavad hinnata erinevate lugude omavahelist sarnasust viisil, mis on sobilik automaatseks analüüsiks ja võrdlemiseks.

Pärast hõlmanguvektorite loomist arvutatakse nende põhjal välja kauguste maatriks (ingl *distance matrix*). Oma olemuselt on kauguste maatriks lihtne tabel, kus iga rida ja veerg vastab ühele salvestusele ning iga tabeli lahter näitab kahe salvestuse hõlmanguvektorite vahelist kaugust. Näiteks, kui andmestikus on 100 salvestust, saadakse 100×100 suurune maatriks, kus igas (i, j) lahtris on arvuline väärtus, mis väljendab kahe konkreetse esituse vahelist kaugust hõlmanguruumis.

CoverHunter kasutab kauguste arvutamiseks koosinuskaugust (*cosine distance*). See tähendab, et kahe hõlmanguvektori vahelist kaugust mõõdetakse nende omavahelise nurga järgi, mitte otsese kauguse ehk absoluutväärtuste erinevuse põhjal, nagu seda tehakse näiteks eukleidilise kauguse puhul. Kui kahe salvestuse hõlmanguvektorite vaheline kaugus on väike, viitab see sellele, et esitused on muusikaliselt sarnased ja võivad olla kaverid. Kui kaugus on suur, on esitused tõenäoliselt muusikaliselt erinevad ning ei ole omavahel seotud.

Kauguste maatriks võimaldab CoverHunteril hinnata, millised salvestused on mudeli arvates muusikaliselt sarnased ning selle põhjal järjestada võimalikud kaverid sarnasuse järgi. Sama maatriks on sisendiks ka salvestuste kõrgemõõtmeliste hõlmanguvektorite mõõtmete vähendamisele t-SNE abil, mille tulemusel tekib visuaalne klasterkaart. Selle kaardi loomist käsitlen jaotises 3.4.

3.1.3. Mudeli valimisest

Valisin töös kasutatavaks masinõppemudeliks CoverHunteri peamiselt kahel põhjusel. Esiteks pakkus see 2024. aasta kevadel paremaid tulemusi võrreldes teiste saadaolevate mudelitega, ning teiseks oli sellel olemas avatud lähtekoodiga ametlik implementatsioon¹⁶, mis võimaldab mudelit kasutada ka kolmandatel osapooltel. Paraku oli algsete autorite poolt avaldatud CoverHunteri GitHubi projekt puudulikult dokumenteeritud, mistõttu oli raske aru saada,

¹⁶ <https://github.com/Liu-Feng-deeplearning/CoverHunter>

mida üks või teine parameeter täpselt tähendas ilma lähtekoodi süvitsi analüüsimata. Seetõttu ei kasutanud ma päris ametlikku lahendust, vaid selle edasiarendust¹⁷, mille lõi originaali põhjal Wisconsin-Madisoni Ülikooli Infotehnoloogia valdkonna direktor Alan Ng. Võrreldes algse projektiga lisab Alan Ng' versioon toe operatsioonisüsteemile macOS, mõningad tehnilised parandused ja täiustused, ning (kõige olulisemana) põhjaliku ja selge dokumentatsiooni, mis hõlmab kõiki vajalikke juhiseid CoverHunteri praktiliseks kasutamiseks.

Lisaks CoverHunterile proovisin 2024. aasta kevadel katsetada ka ByteCoveri mudelit, mille küll puudub ametlik avalik implementatsioon, kuid mille jaoks leidub GitHubis mitteametlik versioon¹⁸. Viimane on koostatud võimalikult täpselt vastavalt algse teadusartiklis (Du jt., 2021) esitatud kirjeldustele. Paraku ei õnnestunud seda mul tol hetkel enda arvutis edukalt tööle saada, mistõttu otsustasin keskenduda üksnes CoverHunterile. Tulevikus väärrib ByteCover siiski suuremat tähelepanu, kuna selle praegune versioon võitis 2024. aasta MIREX-i kaverlugude tuvastamise võistluse¹⁹ (CoverHunter jäi napilt kolmandaks). Probleemiks jääb aga ametliku implementatsiooni puudumine ning nagu näitasid Hachmeier ja Jäschke (2025: 13), ei pruugi mitteametliku lahendusega saadud tulemused olla võrreldavad algse teadusartiklis kirjeldatuga.

3.2. Mudeli tõhususe hindamine

Käesoleva töö peamiseks eesmärgiks on rakendada arvutuslikke meetodeid sama rahvapilliloo erinevate esituste tuvastamiseks. Selle eesmärgi saavutamiseks kasutan klasterdamist kui töövahendit, mis võimaldab grupeerida salvestusi meloodilise sarnasuse alusel. Sellest lähtuvalt tekib aga oluline küsimus, kuidas hinnata valitud meetodika tõhusust. Teisisõnu, kuidas adekvaatselt mõõta seda, kui efektiivselt suudab masinõppemudel rahvapillimuusika esitusi klasterdada? Pelgalt visuaalsel hindamisel põhinev efektiivsuse määramine ei anna piisavalt täpset ülevaadet, kuna selline hindamine on sageli subjektiivne ja raskesti korratav. Seeläbi tekib vajadus kvantitatiivsete mõõdikute järele, mis võimaldaksid tulemusi täpsemalt ja objektiivsemalt hinnata.

¹⁷ <https://github.com/alanngnet/CoverHunterMPS>

¹⁸ <https://github.com/Orfium/bytecover>

¹⁹ https://www.music-ir.org/mirex/wiki/2024:Cover_Song_Identification_Results

Nagu mainitud jaotises 3.1.2, väljastab CoverHunter mudel tulemuseks kauguste maatriksi, kus iga rahvapillimuusika pala kohta arvutatakse numbriline kaugus kõigi teiste palade suhtes. Sellest kauguste maatriksist saadakse iga päringpala kohta järjestatud nimekiri teistest paladest, mille järjestus näitab, kui võrd sarnaseks peab mudel neid konkreetse päringpalaga. See võimaldab kvantitatiivselt hinnata mudeli suutlikkust grupeerida omavahel sarnased esitused ja eristada neid, mis sarnased ei ole.

Käesolevas töös, ning ühtlasi ka muusika andmeanalüütika valdkonnas üldiselt, kasutatakse kaverlugude tuvastamise efektiivsuse hindamiseks peamiselt kahte mõõdikut: *mAP* (*mean average precision* ehk keskmine täpsus) ja *MRI* (*mean rank of first relevant item* esimese asjakohase vaste keskmine järjestuskoht). Mõlemad nimetatud mõõdikud on laialdaselt tunnustatud ning olid kasutusel ka 2024. aasta MIREX-i kaverlugude tuvastamise võistlusel²⁰. Ühtlasi toetub nende ka CoverHunteri mudel ning pakub kõik vajalikud tööriistad mõõdikute arvutamiseks.

Järgnev mõõdikute kirjeldus tugineb eelkõige ISMIR-i 2024. aasta konverentsi tarbeks loodud veebiõpikule “Deep Learning 101 for Audio-based MIR” (Peeters jt, 2024) ja raamatule “An Introduction to Information Retrieval” (Manning jt., 2008).

3.2.1. Mõõdik *mAP*

Mõõdik *mAP* hindab mudeli võimet esitada õiged vasted järjestuse eesotsas, arvutades keskmise täpsuse iga päringpala kohta. Kui süsteemile esitatakse päring, järjestab süsteem kandidaatide nimekirja vastavalt nende sarnasusele päringuga.

Keskmise täpsuse arvutamiseks tehakse järgmist:

1. Liigutakse läbi järjestatud tulemuste nimekirja ülalt alla.
2. Igal positsioonil, kus leitakse korrektne (asjakohane) tulemus, arvutatakse täpsus (*precision*) antud hetkel, st kui palju asjakohaseid tulemusi on leitud kõikidest seni vaadatud tulemustest.

²⁰ https://www.music-ir.org/mirex/wiki/2024:Cover_Song_Identification

3. Kõik täpsuse väärtused, mis on arvatud kohtadel, kus leidub korrektne vaste, võetakse keskmiseks. See annab ühe päringu jaoks keskmise täpsuse väärtuse AP (*average precision*).

Üldistatud valem ühe päringu jaoks on:

$$AP = \frac{\sum_{k=1}^N P(k) \cdot rel(k)}{R} \quad (2)$$

kus:

- N on tagastatud tulemuste koguarv
- $P(k)$ tähistab täpsust (*precision*) kuni positsioonini k – ehk mitu asjakohast vastet on esinenud esimese k tulemuse hulgas
- $rel(k) \in \{0,1\}$ näitab, kas positsioonil k olev tulemus on asjakohane (1) või mitte (0)
- R on kõikide asjakohaste tulemuste koguarv antud päringu jaoks

Lõplik mAP arvutatakse kõigi päringute AP -de keskmisena:

$$mAP = \frac{1}{Q} \sum_{q=1}^Q AP(q) \quad (3)$$

kus:

- Q on päringute koguarv
- $AP(q)$ on keskmine täpsus päringu q kohta

Näiteks, kui mudel tagastab 5 järjestatud tulemust päringute A ja B puhul selliselt, et loo A tulemuste hulgas on õiged vasted positsioonidel 1, 2 ja 4 ning loo B puhul positsioonidel 2 ja 5, siis arvutuskäik mAP leidmiseks oleks järgmine:

$$AP(A) = \frac{\frac{1}{1} \cdot 1 + \frac{2}{2} \cdot 1 + \frac{2}{3} \cdot 0 + \frac{3}{4} \cdot 1 + \frac{3}{5} \cdot 0}{3} = 0,917$$

$$AP(B) = \frac{\frac{0}{1} \cdot 0 + \frac{1}{2} \cdot 1 + \frac{1}{3} \cdot 0 + \frac{1}{4} \cdot 0 + \frac{2}{5} \cdot 1}{3} = 0,45$$

$$mAP = \frac{AP(A) + AP(B)}{2} = \frac{0,917 + 0,45}{2} = 0,683$$

Mõõdiku mAP väärtus jääb alati vahemikku 0 kuni 1. Mida kõrgem väärtus, seda paremini oskab mudel asjakohased vasted üles leida.

Antud töös kasutan mAP väärtust peamise mõõdikuna tulemuste hindamisel.

3.2.2. Mõõdik MRI

MRI mõõdab seevastu keskmiselt seda, mitmendal positsioonil asub päringu tulemuste hulgas esimene õige vaste ehk esimene õigesti tuvastatud kaverlugu. Selle arvutamiseks võetakse iga päringu korral tulemuste järjestusest esimese õige vaste positsioon ning arvutatakse nende positsioonide keskmine üle kõigi päringute. MRI väärtust arvutatakse valemiga:

$$MRI = \frac{1}{Q} \sum_{q=1}^Q rank_q \quad (4)$$

kus:

- Q on päringute koguarv
- $rank_q$ on esimese õige vaste asukoht päringu q tulemustes

Näiteks, kui loo A puhul asub esimene õige vaste tulemuste hulgas 2. positsioonil ning loo B puhul 4. positsioonil, on MRI väärtuseks nende kahe positsiooni keskmine:

$$MRI = \frac{2+4}{2} = 3$$

Mida väiksem MRI väärtus, seda kiiremini ja täpsemini suudab süsteem esimese õige vaste üles leida. Ideaalne tulemus oleks $MRI = 1$, mis tähendab, et esimene õige vaste on alati kohe esimesel positsioonil.

3.2.3. Testandmestiku loomine

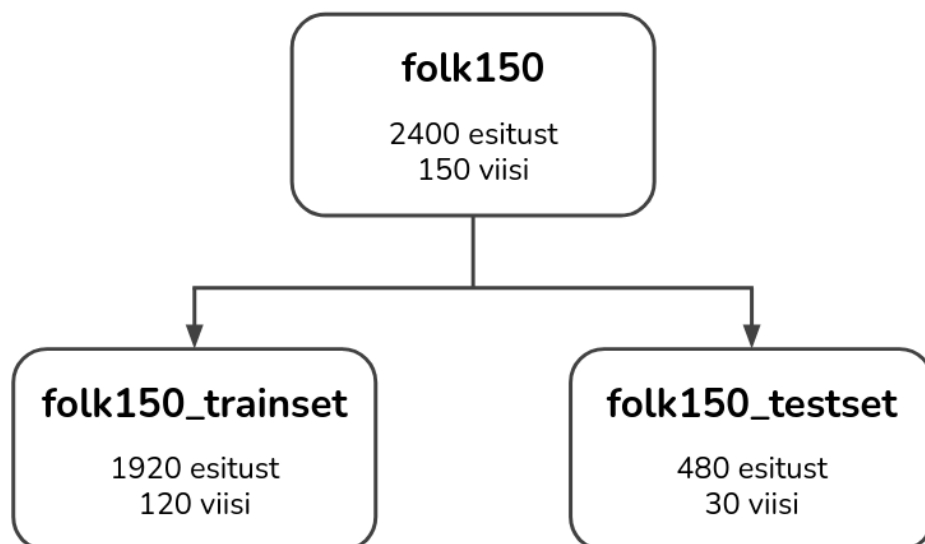
Mõõdikute rakendamiseks tuleb aga kasutada eraldiseisvaid testandmeid, mille põhjal mudeli tõhusust hinnatakse. Masinõppes kehtib põhimõte, et testandmed hoitakse alati

treeningandmetest eraldi, vältimaks olukorda, kus mudel omandab treeningu käigus teadmisi testandmete spetsiifilistest tunnustest, põhjustades seeläbi tulemuste kallutatust ja vähendades nende üldistatavust. Testandmete kasutamine treeningandmetena sarnaneb mõneti olukorraga, kus tudengile antaks konkreetseid eksamiküsimused kätte juba enne eksamineerimist – sellisel viisil võib tudeng eksami küll edukalt sooritada, kuid tulemus ei pruugi peegeldada tema tegelikke teadmisi.

Testandmestiku koostas juba märgendatud korpuse põhjal. Selleks jagasin **folk150** korpuse kaheks alamkorpuseks: 1) treeningandmestikuks (**folk150_trainset**), mida kasutasin ainult mudeli treenimiseks, ning 2) testandmestikuks (**folk150_testset**), mida kasutasin mudeli efektiivsuse hindamiseks ja ühtlasi ka CoverHunteri optimaalsete hüperparameetrite leidmiseks. Viimasest tuleb juttu jaotises 3.2.4.

Märgendatud korpuse jagamisel lähtusin tavapärasest 80/20 printsiibist (Gholamy jt, 2018), mille järgi treeningandmed moodustavad 80% ning testandmed 20% kogu andmestikust – seda nii esituste kui ka viiside lõikes. Seega jäi treeningkorpusesse 1920 esitust, mis jagunesid 120 erineva viisitüübi vahel, samas kui treeningkorpuse moodustas 480 esitust 30 erinevas viisitüübis (vt joonist 10). Seejuures ei esine kahe alamkorpuse vahel kattuvaid esitusi ega ka viisitüüpe. Selline range eraldatus aitab tagada hindamistulemuste võimalikult suure objektiivsuse ja vältida nn “albumiefekti”, kus mudel õpiks konkreetse pala spetsiifilisi tunnuste järgi mustreid, mis ei pruugi aga üldistuda teistele lugudele. Jaotamisel järgisin ka põhimõtet, et mõlemad alamkorpused oleksid võimalikult heterogeensed, sisaldades mitmesuguseid esitusi nii mängitavate pillide, salvestuste helikvaliteedi kui ka lugude iseloomu poolest, pöörates erilist tähelepanu just lugude tantsulisele iseloomule. Ülevaatluk tabel treening- ja testandmete jagunemisest on välja toodud Lisas 2.

Joonis 10. folk150 andmekorpuse jagamine treeningandmeteks (**folk150_trainset**) ja testandmeteks (**folk150_testset**). Jaotus järgib rangelt 80-20 printsiipi, kus täpselt 80% andmestikust on treeningandmed ning 20% testandmed.



Selguse huvides rõhutan, et selline korpuse poolitamine ja testandmestiku loomine oli vajalik üksnes selleks, et objektiivselt hinnata mudeli tõhusust ja optimaalse konfiguratsiooni leidmiseks. Töö lõplike tulemuste saavutamisel ma sellist poolitust ei teinud ning kasutasin mudeli treenimiseks kogu **folk150** korpust.

3.2.4. Optimaalse konfiguratsiooni leidmine

Masinõppemudelid, nagu CoverHunter, kasutavad mitmeid seadistusi ehk hüperparameetreid (ingl k *hyperparameters*), mis mõjutavad mudeli õppimist ja töötamist. Hüperparameetrid on mudeli tööks vajalikud eelmääratud väärtused, mida ei õpita automaatselt andmetest, vaid tuleb määrata käsitsi enne treeningprotsessi algust.

Nende hulka kuuluvad näiteks õppemäär (kui suurte sammudega mudel oma teadmisi uuendab), partii suurus (kui palju treeningnäiteid ehk andmepunkte mudel korraga ühe sammu jooksul töötleb) ja erinevad mudeli struktuuriga seotud valikud (näiteks kui palju kihte või kui palju teatud tüüpi komponente kasutada). CoverHunteri kontekstis mõjutavad hüperparameetrid otseselt seda, kui hästi mudel suudab muusikalisi seoseid tuvastada ja kui kiiresti või stabiilselt ta õpib.

Optimaalse mudelikonfiguratsiooni leidmine osutus üheks kõige aeganõudvamaks etapiks kogu tööprotsessis. Kulutasin ligikaudu 200 treeningtundi erinevate hüperparameetrite kombinatsioonide katsetamisele, eesmärgiga parandada mudeli täpsust ja üldist tõhusust. Katsetused viisin läbi oma isikliku lauarvutiga²¹ ning ülevaatlikult on need kokku võetud eraldiseisvas tabelis²².

Katsetused hõlmasid muuhulgas järgmisi hüperparameetreid:

- **Õppemäär** (*learning_rate*) – määrab, kui kiiresti mudel oma teadmisi iga sammuga uuendab.
- **Õppemäära kadu** (*lr_decay*) – õppemäära järkjärgulist vähenemine treeningu jooksul.
- **Partii suurus** (*batch_size*) – määrab, mitu salvestust mudel ühe iteratsiooni käigus korraga töötleb.
- **Heli lõigu pikkus** (*chunk_frame*) – määrab, kui pikk on iga heli lõik (*chunk*), mida mudel analüüsib, mõõdetuna CQT-spektri kaadrite arvuna. CoverHunter kasutab kolme erineva pikkusega lõiku, et mudel suudaks märgata nii lühikesi kui ka pikemaid muusikalisi mustreid.
- **Spektrogrammi augmentatsioon** (*spec_augmentation*) – treeningu ajal kasutatavad andmete rikastamise meetodid, mille käigus heli spektrisse tehakse juhuslikke "auke" või heli spekter nihutatakse üles- või allapoole helikõrguse teljel, et parandada mudeli vastupidavust väikestele variatsioonidele.
- **Kolmikкао vahemik** (*triplet_loss.margin*) – määrab, kui palju peab positiivne näide hõlmanguruumis olema ankrule lähemal kui negatiivne näide.

Terviklik ülevaade CoverHunteri erinevatest hüperparameetritest on välja toodud Alan Ng' GitHubi projektis CoverHunterMPS²³.

Hoolimata väga paljudest katsetustest ja erinevate seadistuste proovimisest osutus algselt kasutatud vaikimisi konfiguratsioon siiski kõige stabiilsemaks ja parimaid üldisi tulemusi andvaks. Seega võib öelda, et CoverHunteri artiklis soovitatud vaikimisi seadistused on küllaltki hästi tasakaalustatud ja sobivad kaverlaulude tuvastamise ülesande jaoks.

²¹ Protsessor AMD Ryzen 5 3600, 32GB muutmälu, graafikakaart Nvidia 3070 GTX.

²² https://docs.google.com/spreadsheets/d/1_1-zS69AdLiRwMrMezjoPp5IT6EhSlp-Mj_5O03j7X0

²³ <https://github.com/alannngnet/CoverHunterMPS>

Tuleb siiski märkida, et ülalnimetatud hüperparameetrid moodustavad vaid väikese osa kõikidest parameetritest, millega CoverHunter lubab eksperimenteerida. Peamiseks takistuseks on olnud aeg ja ressursid – iga uue parameetri lisamisel kasvab erinevate konfiguratsioonide arv eksponentsiaalselt. Tulevikus võiks treeningu läbiviimisel kaaluda masinõppele pühendatud andmekeskuste kasutamist, mis võimaldaks laiemat ja süsteemsemat katsetamist.

Lisaks tasub märkida (ilma tehnilistesse detailidesse laskumata), et CoverHunteri lähtekoodi uurimisel tekkisid mul mõningad kahtlused selle suhtes, kui tõhusalt suudab süsteem käsitleda helistiku invariantsust (st erineva helikõrgusega esituste samasuse tuvastamist). Sarnaseid kahtlusi kinnitas mulle ka CoverHunteri edasiarenduse autor Alan Ng (25.02.2025 e-kirjas), kes on enda sõnul välja töötanud parema lahenduse treeningu ajal toimuva helikõrguse nihutamise jaoks. Ajapuuduse tõttu ei ole mul veel olnud võimalust seda täiendust meetodiliselt katsetada, kuid plaanin seda teha edaspidises töös.

3.2.5. Mudeli efektiivsus erinevate treeningandmetike põhjal


CoverHunteri projektiga kaasnes eeltreenitud mudel, mille treeningandmeteks oli laialdaselt kasutatav popmuusika andmestik **SHS100K**²⁴. Tegemist on ligikaudu 100 000 loost koosneva andmekorpusega, mille eesmärk on toetada kaverlugude tuvastamise algoritmide arendamist ja hindamist muusika andmeanalüütika valdkonnas. Käesolevas töös kasutasin nimetatud eeltreenitud mudelit esmaseks võrdlusaluseks, et hinnata selle rakendatavust rahvamuusikaga seotud ülesannetes.

Mudeli hindamisel **folk150_testset** testandmestiku põhjal sain tulemuseks klasterkaardi (Joonis 11) ning kvantitatiivsete mõõdikutena $mAP = 0,508$ ja $MRI = 5,881$. Klasterkaardi loomist kirjeldan täpsemalt jaotises 3.4. Ehkki tulemused on kaugel ideaalist, on jooniselt näha, et osa klastritest on siiski selgelt eristatavad. Neid tulemusi käsitlesin edasiste eksperimentide lävendtasemena (*baseline*), mille ületamine oli töö järgnev eesmärk. Lävendtaseme määramise järel alustasin mudeli nullist treenimist, eesmärgiga uurida, kui võrd suudab CoverHunter klasterdada rahvapillimuusikat sõltuvalt kasutatavast treeningandmestikust. Treenimisel kasutasin rakenduse vaikimisi konfiguratsiooni v.a partii suurus (*batch_norm*) ehk korruga töödeldavate salvestuste arv, mida suurendasin 32-lt 64-ni.

²⁴ <https://github.com/NovaFrost/SHS100K>

Selle eesmärk oli paremini ära kasutada olemasolevat graafikakaardi mälu ning kiirendada treeningprotsessi.

Joonis 11. Eeltreenitud mudeliga loodud klasterkaart. Iga andmepunkt kaardil on individuaalne esitus, erinevad viisitüübid koonduvad kindla värvi ja märgitüübi alla. Antud juhul on mõningad klastrid eristatavad. Andmete visualiseerimiseks kasutasin Plotly-nimelist tarkvarateeki.




Esmalt rakendasin kaasasolevat näidisandmestikku **covers80**²⁵, mis sisaldab 80 tuntud pop- ja rokkmuusika loo kahte kaverit. Kuigi **covers80** on laialdaselt kasutusel võrdlusandmestik, on see oluliselt väiksem kui **SHS100K**, mis kajastus ka tulemustes: mõõdiku *mAP* väärtus oli vaid 0,120.

Seejärel kasutasin treenimiseks andmestikku **folk150_trainset**, mille põhjal saavutatud *mAP* väärtus 0,232 ületas küll eelneva, ent jäi siiski oluliselt alla eeltreenitud mudeli lävendtasemele (vt joonist 12). Sellele tulemusele võib olla mitu seletust. Esiteks on **folk150_trainset** sarnaselt **cover80** andmestikuga oluliselt väiksema mahuga kui **SHS100K**, piirates seeläbi mudeli võimet üldistatavaid mustreid omandada. Teiseks ei pruugi CoverHunteri vaikekonfiguratsiooni hüperparameetrid sobida rahvamuusika iseloomuga. Kuigi katsetasin sadu hüperparameetrite kombinatsioone (vt jaotist 3.2.4), ei olnud otstarbekas kõiki võimalikke valikuid läbi proovida, kuna, nagu eelnevalt juba rõhutatud, kasvab parameetrite lisandumisel kombinatsioonide arv eksponentsiaalselt.

²⁵ <http://labrosa.ee.columbia.edu/projects/coversongs/covers80/>

Joonis 12. Ainult rahvamuusika andmestiku **folk150_trainset** peal treenitud mudeli koostatud klasterkaart. Eristatavad klastrid sisuliselt puuduvad.




Võttes arvesse eeltreenitud mudeli paremaid tulemusi ning arvestades treeningandmete piiratud mahtu, jõudsin arusaamani, et otstarbekas oleks proovida ülekandeõppe (*transfer learning*) lähenemist, mille puhul olemasolevat mudelit täiendatakse ehk järeltreenitakse rahvamuusika andmestiku põhjal. Selline lähenemine eeldas aga teatud hüperparameetrite kohandamist, eelkõige õppemäära (*learning rate*) osas.

Õppemäär on oluline hüperparameeter, mis määrab, kui suurte sammudega mudel treeningu käigus oma parameetreid kohandab. Madal õppemäär (nt 0,0001) tagab aeglase, ent stabiilse õppeprotsessi, samas kui kõrge väärtus (nt 0,01) võimaldab kiiremat õppimist, kuid muudab veafunktsiooni optimeerimisprotsessi ebastabiilseks ehk suurendab riski "üle hüpata" optimaalsest lahendusest. Sageli kasutatakse õppemäära puhul ajas kahanevat funktsiooni, mille kohaselt treenimise alguses on väärtus suurem ning väheneb järk-järgult kuni määratud minimaalse tasemeni, võimaldades mudelil lõppfaasis teostada peenemaid kohandusi.

CoverHunteri vaikimisi seadistus näeb ette õppemäära algväärtusena 0,001, mis väheneb kuni 0,0001-ni. Arvestades, et eeltreenitud mudel oli juba ulatuslikult optimeeritud, otsustasin järeltreenimise käigus kasutada kohe väikest õppemäära väärtusega 0,0001. Lihtsustatult öeldes tähendas see olemasoleva, popmuusikal baseeruva mudeli peenhäälestamist rahvapillimuusika andmestiku kaudu.

Sellise järeltreenimise strateegiaga – st olemasoleva, popmuusikal baseeruva eeltreenitud mudeli täiendamisega rahvapillimuusika andmestiku abil ja väikese õppemäära rakendamisega – õnnestus saavutada võrreldes lävendtasemega märkimisväärselt paremad tulemused (vt joonist 13). Mudelit hinnates **folk150_testset** andmestiku peal sain mõõdikuteks $mAP = 0,704$ ja $MRI = 3,610$.

Joonis 13. Andmestike shs100k ja folk150_trainset peal treenitud mudeli koostatud klasterkaart. Erinevad klasterid on mõningate mõõndustega üsna selgelt eristatavad.



Võrreldes varasemate katsetega, kus **eeltreenitud** mudeli kasutamisel saavutasin $mAP = 0,508$ ning **folk150_trainset** põhjal nullist trennides $mAP = 0,232$, näitab järeltreenitud mudeli tulemus selget arengut (Tabel 2). See kinnitab, et ülekandeõppe rakendamine osutus tõhusaks valikuks olukorras, kus treeningandmestik on piiratud mahuga.

Tabel 2. CoverHunter mudeli efektiivsus erinevate treeningandmete lõikes. Kõik katsed kasutasid hindamiseks ühte ja sama testandmestikku **folk150_testset**.

Treeningandmed	Testandmed	MR1	mAP	Vahe (mAP)
SHS100K (eeltreenitud)	folk150_testset	5.881	0.508	0.00%
covers80	folk150_testset	20.331	0.120	-76.36%
folk150_trainset	folk150_testset	8.923	0.232	-54.34%
SHS100K + folk150_trainset	folk150_testset	3.610	0.704	+38.58%

3.3. Kogu andmestiku kasutamine mudeli treenimisel

Pärast hüperparameetrite testimist ja sobiva konfiguratsiooni valimist treenisin mudelit kasutades kogu **folk150** andmestikku. Erinevalt varasemast lähenemisest, kus osa esitusi oli reserveeritud testimiseks, kaasasin nüüd treeningusse ka kõik need salvestused, mida olin varem kasutanud eraldi testandmetena. Seda põhjusel, et töö selleks etapiks ei keskendunud ma enam mudeli üldistamisvõime testimisele, vaid võimalikult hea esitustaseme saavutamisele kogu olemasoleva andmestiku piires. Selline lähenemine võimaldas mudelil kasutada kogu andmestiku potentsiaali ning õppida muusikalisi seoseid kõigi märgendatud salvestuste põhjal võimalikult terviklikult.

Lisaks jaotises 3.2.4. kirjeldatud andmete rikastamise viisidele kasutab CoverHunter vaikimisi ka tempomuutust: iga salvestuse kohta genereeritakse automaatselt neli täiendavat versiooni erinevate tempodega (-20%, -10%, +10%, +20%), mis suurendab mudeli vastupidavust esituste vahelistele tempovariatsioonidele. Seeläbi viidi tegelik treenimine läbi mitte 2400, vaid 12 000 helisisendi põhjal, mis suurendas oluliselt treeningandmestiku ulatust.

Treeningprotsess toimus olemasoleva eeltreenitud mudeli baasil, kuna selline lähenemisviis osutus varasemate katsetuste põhjal kõige tõhusamaks (vt eelmist jaotist). Treenimisel kasutasin 5-kordset ristvalideerimist (*5-fold cross-validation*), mis on meetod andmestiku süstemaatiliseks jagamiseks viieks võrdseks osaks. Igas tsüklis kasutatakse neli osa treeninguks ja üks osa valideerimiseks, seejuures vahetuvad need rollid viiel järjestikusel ringil. Selline lähenemine aitab maksimaalselt ära kasutada piiratud andmehulka ning annab usaldusväärsema ülevaate mudeli stabiilsusest ja toimimisest erinevates andmejaotustes.

Kogu treening kestis ligikaudu 97 minutit ning viidi läbi sama hüperparameetrite konfiguratsiooniga, mille olin eelnevate katsetuste põhjal sobivaimaks tunnistanud. Kuna treenimiseks kasutati kõiki märgendatud salvestusi, suurenes nii andmemaht kui ka muusikaline varieeruvus, mis omakorda võimaldas mudelil õppida mustreid mitmekesisemalt ja täpsemalt. Samas eeldas kogu andmestiku kasutamine ka kriitilist tähelepanu andmekvaliteedile. Treeningu eel märkasid mõningaid vigu andmete märgendamisel – näiteks olin esialgu määratlenud lood "Tarvastu polka" ja "Äiapapa polka" kaheks erinevaks palaks,

kuigi tegemist on tegelikult sama viisiga. Sellised vastuolud parandasin ma käsitsi enne lõplikku treeninguprotsessi, et tagada sisendandmete kvaliteet ja usaldusväärus²⁶.

Selle treeningu tulemusel arvutati kauguste maatriks (vt jaotist 3.1.2), mille alusel oli võimalik tuvastada salvestustevahelist muusikalist sarnasust ning mudeli õppimisel kujunenud jaotust hõlmanguruumis.


3.4. Visuaalse klasterkaardi loomine

Nagu jaotises 3.1.2 kirjeldatud, loob CoverHunteri mudel iga helisalvestuse jaoks 128-mõõtmelise hõlmanguvektori, mis peegeldab selle muusikalisi omadusi kompaktsel ja võrreldaval kujul. Kuna hõlmanguvektorid paiknevad kõrgemõõtmelises ruumis, ei ole nende omavaheliste kauguste otsene ja geomeetiline visualiseerimine võimalik, sest inimese ruumitaju piirdub kolmemõõtmelise ruumiga. Seetõttu on vaja mõõtmete vähendamist, mis võimaldab salvestuste sarnasussuhteid uurida visuaalselt.

Üheks levinud lähenemiseks on mõõtmete vähendamise meetod t-SNE (van der Maaten ja Hinton, 2008), mis projitseerib kõrgemõõtmelised andmed kahemõõtmelisse ruumi, püüdes säilitada eelkõige punktidevahelisi lokaalseid kaugussuhteid. Selle teisenduse tulemusena koostasin kahemõõtmeliste koordinaatide põhjal visuaalse klasterkaardi (Joonis 14), kus iga punkt tähistab ühte helisalvestust. Punktide omavaheline kaugus annab ligikaudse ettekujutuse salvestuste muusikalisest sarnasusest, mis põhineb algsete hõlmanguvektorite koosinuskaugetel. Kaardil tähistavad monokromaatilised ehk hallid punktid neid salvestusi, mis kuuluvad **folk150** andmestikku ning mida kasutasin mudeli treenimiseks; punased punktid tähistavad uusi, treeningusse mittekuulunud salvestusi. Viimaste paiknemine kaardil näitab, kuidas mudel üldistab uute näidete põhjal nende sarnasust olemasolevate rühmitustega.

²⁶ Täpsustuseks olgu öeldud, et andmete märgendamisel esinenud üksikud ebatäpsused ei mõjuta mudeli lõpptulemust märkimisväärselt, kuna iga salvestus moodustab vaid väikese osa tervikust. Mudeli üldine jõudlus kujuneb akumuleeruvalt kõigi salvestuste põhjal, mistõttu on üksikute andmepunktide mõju marginaalne.

Joonis 14. CoverHunteri mudeli koostatud kauguste maatriksi põhjal loodud klasterkaart. Monokromaatilised märgised viitavad märgendatud salvestustele, mille alusel loodi treenimisel klastrid. Punased aga märgendamata salvestused, mida treenimisel ei kasutatud. Visualiseerimise implementeerisin tarkvarateegi Plotly abil ning see on osa loodud pillilugude infosüsteemist (Lisa 1).



Oluline on aga rõhutada, et t-SNE on visualiseerimisvahend, mitte klasterdamisalgoritm. Kahemõõtmelisel kaardil nähtavad kaugused ja rühmitused ei pruugi täpselt peegeldada kõrgemõõtmelise ruumi tegelikku struktuuri. Näiteks võivad kaks salvestust paista 2D-kaardil lähestikku, kuigi nende vaheline kaugus kõrgemõõtmelises hõlmanguruumis on suur – ja vastupidi. Selline geomeetiline moonutus tuleneb t-SNE algoritmi eripärast: see keskendub peamiselt lähestikke asuvate andmepunktide ehk kohalike sarnasuste säilitamisele. See tähendab, et kuigi lähestikku olevad salvestused jäävad enamasti ka 2D-kaardil lähestikku, võivad kaugemad suhted olla tugevalt moonutatud. Tulemuseks on visuaalselt haaratav, kuid geomeetriselt osaliselt ebatäpne ülevaade kogu andmestiku struktuurist. Seeläbi ei pruugi Joonisel 14 esitatud klasterkaart peegeldada salvestustevahelisi *tegelikke* sarnasussuhteid.

Metoodiliselt oleks täpsem teostada klasterdamine otse kõrgemõõtmelises ruumis, mitte selle kahemõõtmelise projektsiooni alusel. Üheks sobivaks lähenemiseks on näiteks tiheduspõhine algoritm DBSCAN²⁷, mis ei eelda ette klastrite arvu ega kuju ning võimaldab tuvastada salvestuste loomulikke rühmi, lähtudes nende asukohast kõrgemõõtmelises hõlmanguruumis.

²⁷ Vt näiteks: <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.DBSCAN.html>

Käesolevas töös ma sellist klasterdamist siiski ei rakendanud, kuna see ei ole osa CoverHunteri vaikumisi pakutavast funktsionaalsusest. Kuna aga salvestuste rühmitamine otse hõlmanguvektorite alusel võimaldaks vältida t-SNE visualiseerimisest tulenevaid geomeetrilisi moonutusi, on selle rakendamine kavandatud edasise uurimistöö üheks arengusuunaks. Peatükis 4.3 pöördun siiski osaliselt sellise lähenemise poole, kui kasutan otse kõrgemõõtmelisi hõlmanguvektoreid selleks, et koostada sarnasuse põhjal järjestatud pingeread uute salvestuste ja uurimiskorpuse kuuluvate salvestuste vahel. Kuigi tegemist ei ole otseselt klasterdamisega, säilivad sellises järjestamises hõlmanguvektorite kaugussuhted, võimaldades hinnata, kui võrd suudab mudel siduda uusi salvestusi juba olemasolevate, viisitüübilt sarnaste salvestustega. Samas tuleb rõhutada, et salvestuste klasterdamine ei ole eesmärk omaette, vaid vahend, mille kaudu toetada käesoleva töö põhieesmärki: tuvastada ühe ja sama rahvaviisi erinevaid esitusi.

Sarnaselt jaotises 2.2.3 kirjeldatud käsitsi tehtud andmete märgendamisele – kus salvestused tuli kuulamise teel viisitüüpideks rühmitada – vajasin ka siin tõhusat ja sujuvat töövahendit, mis võimaldaks kiiresti hinnata mudeli väljundite kvaliteeti ning avastada võimalikke seoseid salvestuste vahel. Kuigi kahemõõtmeline klasterkaart ei kajasta täielikult kõrgemõõtmelise hõlmanguruumi struktuuri, pakub see siiski esmase visuaalse ülevaate, mille abil on võimalik tuvastada kandidaatsalvestusi, mis võiksid kuuluda sama viisitüübi alla või olla omavahel muusikaliselt seotud.

Selleks täiendasin olemasolevat pillilugude infosüsteemi (vt Lisa 1), lisades võimaluse kuvada interaktiivset klasterkaarti ja kuulata igat salvestust otse vastavale andmepunktile klikkides. See võimaldas mul valideerida mudeli poolt tuvastatud sarnasusi kuuldeliselt – sarnaselt käsitsi tehtud märgendusele –, kuid märksa kiiremini ja süsteemsemalt. Tulemuseks on töövahend, mis toetab arhiivisalvestuste kiiret ja sihipärast läbivaatust, ühendades mudeli pakutud sarnassuhted vahetu kuuldelise kontrolliga.

Visuaalse klasterkaardi analüüsi ja selle põhjal ühe ja sama muusikapala erinevate esituste tuvastamist käsitlen järgnevas peatükis.

4. Analüüs ja tulemused

Eelmises peatükis kirjeldatud visuaalse töövahendi – klasterkaardi – abil on võimalik uurida, milliseid mustreid ja rühmitusi ilmneb helisalvestuste vahel, kui mudeli poolt genereeritud hõlmanguvektorid projitseeritakse kahemõõtmelisse ruumi t-SNE abil. Käesolevas peatükis analüüsin, milliseid seoseid selline visualiseerimine esile toob ning kuivõrd saab selle põhjal tuvastada nii ühe ja sama viisitüübi erinevaid esitusi kui ka võimalikke ebatäpsusi arhiivandmetes. Lisaks kahemõõtmelise klasterkaardi analüüsile käsitlen ka mudeli suutlikkust hinnata sarnasust täiesti uute sisendsalvestuste ja olemasolevate salvestuste vahel, tuginedes otse kõrgemõõtmeliste hõlmanguvektoritele.

4.1. “Kaverite” leidmine klasterkaardil

Visuaalne klasterkaart ei ole pelgalt vahend mudeli sisemiste seoste illustreerimiseks, vaid toetab ka sisulist analüüsi, võimaldades suunata tähelepanu salvestustele, mis võivad esindada sama viisitüübi erinevaid esitusi (ehk olla “kaverid”). Kuigi kaardil nähtavad rühmitused põhinevad t-SNE algoritmi abil projitseeritud kahemõõtmelisel ruumil, peegeldavad need siiski teatud määral ka kõrgemõõtmelises hõlmanguruumis kehtivaid sarnassuhteid. Seeläbi võib salvestuste lähestikune paiknemine 2D-kaardil viidata nende lähedusele ka mudeli algse esitusruumis.

Sellest lähtuvalt avas klasterkaart võimaluse oletada viisitüübiga seotust ka nende salvestuste puhul, millel puudus varasem märgendus. Kui märgendamata salvestus paiknes samas rühmas koos juba märgendatud näidetega, viitas see potentsiaalsele muusikalisele sarnasusele ning võimalikule kuuluvusele samasse viisitüüpi.

Selliste seoste kontrollimiseks kujunes välja järgmine tööprotsess: tuvastasin konkreetse viisitüübi klatri asukoha üldisel kaardil, suurendasin vastavat ala ning keskendusin selles piirkonnas paiknevatele salvestustele. Seejärel kuulasin läbi kõik märgendamata salvestused, mis paiknesid klattris või selle vahetus läheduses, ja võrdlesin neid kuuldeliselt samas rühmas olevate juba märgendatud salvestustega. Kui muusikaline sisu kattus olemasoleva viisitüübiga, määrasin salvestusele vastava märgendi; kui mitte, jätsin selle kõrvale.

Nagu on märkinud ka Ingrid Rüütel, võivad analüüsi tulemusel moodustuvad klastrid erineda näiteks viiside arvu, homogeensuse ja kompaktsuse poolest (Rüütel 2006: 86). Käesolevas töös ilmnes sarnane mitmekesisus ka mudeli loodud klastrites, mis erinesid märgatavalt nii täpsuse kui ka kasutusväärtuse poolest. Mõned rühmad võimaldasid tuvastada rohkesti uusi esitusi, teised sisaldasid mitut viisitüüpi või jagunesid sama tüübi puhul mitmeks eraldiseisvaks klastriks. Nende erinevuste alusel jaotasin klastrid viide kategooriasse, lähtudes nende sidususest ja praktilisest rakendatavusest uute viisitüüpide määramisel (vt Tabel 3).

Tabel 3. Klasterkaardil esinevad klastrid sõltuvalt nende sidususest ja praktilisest rakendatavusest.

Tüüp	Nimetus	Kirjeldus
I	Kõrge täpsusega klastrid	Klastrid, milles valdav osa salvestusi on õigesti paigutatud.
II	Segatäpsusega klastrid	Klastrid, milles õiged ja valed ennustused esinevad ligikaudu võrdselt.
III	Poolitatud klastrid	Sama viisitüübi esitused on paigutatud geomeetriliselt mitmesse erinevasse klastrisse.
IV	Uustekkelised klastrid	Klastrid, milles leiduvate salvestuste viisitüüpe ei olnud eelnevalt märgendatud.
V	Täiendamata klastrid	Klastrid, kuhu ei paigutunud uusi, määramata esitusi.


Järgnevalt toon välja klastrite detailsemad kirjeldused koos neid illustreerivate näidetega.

4.1.1. Kõrge täpsusega klastrid

Kõrge tuvastustäpsusega klastrid on selgepiirilised ja ühtsed rühmad, kus valdav osa mudeli määrangutest osutus õigeks. Valed määratlused on üksikud ja paiknevad tavaliselt klastri servaaladel, jättes keskosa puhtaks ja usaldusväärseks. Sellised klastrid olid eriti tõhusad uute “kaverite” leidmisel.

Üheks selgeks näiteks on viisitüüp “Roosiaias” (Joonis 15). Klaster sisaldas suurel hulgal korrektseid määratlusi – märgendamata salvestusi, mille mudel õigesti paigutas juba teadaolevasse “Roosiaia” viisitüübiga klastri piirkonda. Rohelised andmepunktid tähistavad neid uusi, õigesti määratud salvestusi. Punased punktid viitavad ekslikele ennustustele, mis antud viisitüübi alla kuuluma ei peaks.

Joonis 15. (a) Viisitüübi “Roosiaias” sisse suurendatud klaster. Suur osa mudeli ennustustest on korrektsed (tähistatud rohelisega) ning üksikud võltspositiivsed paiknevad klasteri ääres (tähistatud punasega). Hallid märgised tähistavad viisitüübiga “Roosiaias” märgendatud salvestusi. (b) Antud klasteri paiknemine üldisel klasterkaardil.




Sarnase ülesehitusega kõrgtäpsusega klastrid ilmnesid ka järgmiste viisitüüpide puhul: “Ma tahaksin kodus olla”, “Tule aga tule”, “Kui kodunt ma laia maailma”, “Vengerka (sitikad ja satikad)”, “Suboota”, “Hulkuri valss” jt.

4.1.2. Segatäpsusega klastrid

Segatäpsusega klastrid on võrreldes kõrgtäpsusega klastritega vähem ühtlased: ligikaudu pool mudeli ennustustest osutus õigeks, kuid teine pool osutus ekslikuks. Nende klastrite abil on võimalik tuvastada uusi esitusi, kuid nõuavad hoolikamat selekteerimist ja sagedast kontrollkuulamist. Neid võib käsitleda ka kui *"hit or miss"* tüüpi klastreid, kus mudeli ennustustel esineb nii märkimisväärset täpsust kui ka märgatavat müra.

Sellised klastrid esinesid sagedamini suuremate rühmitustena, kus märgendatud salvestuste arv oli juba eos suur. Joonisel 16 on illustreeritud viisitüübi „Perekonnavalss“ klaster, mis kuulub iseloomulikult sellesse kategooriasse.

Joonis 16. (a) Viisitüübi “Perekonnavalss” klaster. Õigete ennustuste hulgas on hulgaliselt ka valesid ennustusi ehk salvestusi, mis tegelikult “Perekonnavalsi” viisitüübi alla ei kuulu. (b) Antud klasteri paiknemine üldisel klasterkaardil.

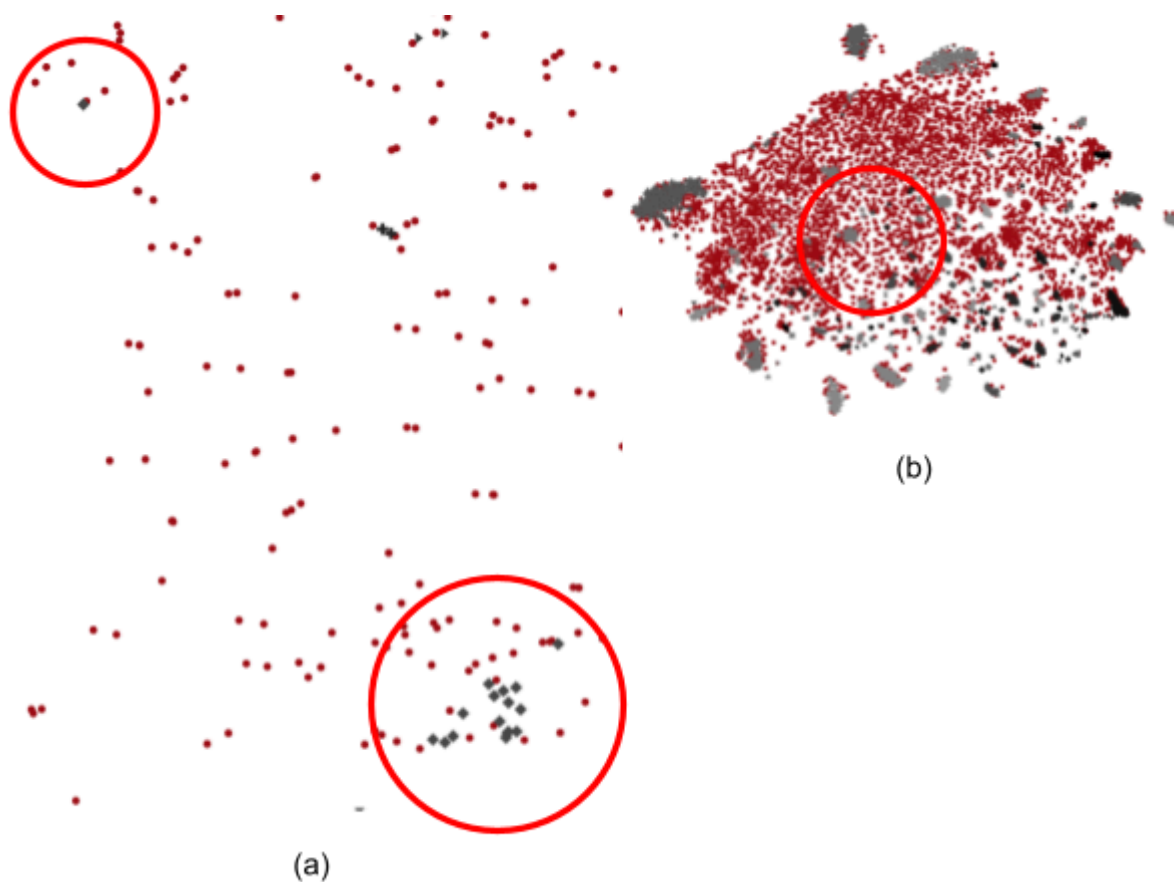


4.1.3. Poolitatud klastrid

Poolitatud klastrid tähistavad juhtumeid, kus sama viisitüübiga salvestused, mille kuuluvus on märgendamisel kinnitatud, paiknevad t-SNE klasterkaardil mitmes eraldi piirkonnas, moodustades kaks või enam visuaalselt isoleeritud klastrit. See viitab sellele, et mudel ei suutnud nende salvestuste vahelisi sarnasusi 2D-projektsioonis ühtsesse klastrisse koondada, ehkki need kuuluvad samasse viisitüüpi. Poolitus võib olla põhjustatud esituste erinevast stiilist, salvestuskvaliteedist või mudeli piiratud üldistusvõimest. Samas tuleb arvestada, et t-SNE vähendab kõrgemõõtmelise hõlmanguruumi mõõtmeid ning võib selle käigus sarnasussuhteid visuaalselt moonutada (vt jaotist 3.4). Seega ei pruugi klasterkaardil ilmnev eraldatus alati viidata tegelikule sisulisele kaugusele.

Üheks selliseks näiteks on “Karoobuška” viisitüübi salvestused, mis asuvad klasterkaardil kahes eraldiseisvas piirkonnas (Joonis 17) – esitus **RKM, Mgn. II 2000 d** paikneb teistest “Karoobuška” salvestustest eraldi. Nagu selgub jaotises 4.3, on need vastavad salvestused mudeli kujundatud kõrgemõõtmelises ruumis siiski omavahel lähestikku, mis viitab sellele, et selline visuaalne poolitus on põhjustatud just andmete kahemõõtmeliseks teisendamise, mitte nende sisulisest erinevusest.


Joonis 17. (a) Viisitüübi “Karoobuška” klaster. Mudel grupeeris sama viisitüübi salvestused kahte erinevasse ehk “poolitatud” klastrisse. (b) Antud klasteri paiknemine üldisel klasterkaardil.



4.1.4. Uustekkelised klastrid

Uustekkelised klastrid on mudeli loodud rühmad, millel puudus eelnev viisitüübi märgend ja mis ei moodustunud treeningprotsessi käigus. Need klastrid osutavad potentsiaalsetele uutele viisitüüpidele. Näiteks kuulub sellesse tüüpi viisitüüp “Koduküla nõmmed” (Joonis 18), mis eristus üksnes mudeli ennustuste põhjal ja mille puhul ei olnud varasemat käsitsi määratud seost.

Joonis 18. (a) Viisitüübi “Koduküla nõmmed” klaster. Mudel grupeeris salvestused, mis moodustavad uue viisitüübi rühma “Koduküla nõmmed” (rohelised ringid). (b) Antud klastri paiknemine üldisel klasterkaardil.



4.1.5. Täiendamata klastrid

Selle kategooria moodustavad klastrid, mille puhul mudel paigutas sinna vaid juba eelnevalt tuntud ja märgendatud salvestusi. Ehkki klaster ise oli sisemiselt ühtne ja korrektne, ei tuvastatud selle kaudu ühtegi uut võimalikku esitust. Selliseid klastreid võib nimetada ilma uute määranguteta klastriteks, ning nende esinemine viitab kas sellele, et kõik esitused olid juba teada, või et mudel ei suutnud uusi esitusi välja pakkuda.

Ühtekokku oli selliseid klastreid 38 (150-st).

4.1.6. Mudeli rakendatavuse hindamine

Mudeli genereeritud hõlmanguvektorite põhjal loodud kahemõõtmelise klasterkaardi alusel õnnestus mul määrata viisitüüp kokku 663 varem märgendamata salvestusele. Need jagunesid 112 erineva viisitüübi vahel, moodustades märkimisväärse osa kogu uurimiskorpusest. Viisitüüpide jaotust illustreerib koondstatistika Lisas 3.

Tulemused näitavad, et klasterkaart on tõhus vahend seni märgendamata arhiivisalvestuste süstemaatiliseks liigitamiseks. Salvestuste ruumiline paigutus kaardil lõi eeldused

sihipäraseks kuuldeliseks kontrolliks, mille abil oli võimalik hinnata, kas mudeli lähestikku asetatud salvestused tõepoolest kuulusid samasse viisitüüpi.

Kõige suuremat lisaväärtust pakkusid kõrge täpsusega ja uustekkelised klastrid (vt Tabel 3), mis võimaldasid leida nii uusi esitusi olemasolevate viisitüüpide seast kui ka tuvastada seni märgendamata tüüpe. Samas ilmsid ka juhud, kus sama viisitüübiga salvestused paiknesid kaardil mitmes eraldiseisvas piirkonnas (vt 4.1.3). See tõi esile, et t-SNE kaardil põhinev analüüs saab toimida eeskätt suunava abivahendina, kuid sarnasussuhete usaldusväärsem hindamine eeldab analüüsi kõrgemõõtmelises hõlmanguruumis.


Viisitüüpide määramisel jäi keskseks salvestuste kuuldeline hindamine, kuid t-SNE algoritmi abil projitseeritud klasterkaart osutus seejuures oluliseks töövahendiks. Visualiseerimine võimaldas kiiresti esile tuua salvestustevahelisi seoseid, mida ei olnud metaandmete põhjal võimalik tuvastada, ning suunas tähelepanu rühmadele, mille liikmete viisitüüpi sai kuuldeliselt valideerida. Selline lähenemine loob aluse arhiivikorpuse sisupõhiseks täiendamiseks viisil, mis tugineb otseselt helisisu sarnasusele, mitte üksnes olemasolevale märgendusele.

4.2. Arhiivivigade tuvastamine

Lisaks muusikaliste seoste ja sarnaste esituste leidmisele võimaldab klasterkaart tuvastada ka vigu arhiivandmetes, näiteks duplikaate või valesti märgendatud salvestusi. Kui mudel paigutab kaks erinevate metaandmetega salvestust klasterkaardil väga lähestikku, võib see viidata olukorrale, kus tegemist on kas sama esitaja kordusvõtetega või koguni tehniliste duplikaatidega. Sellised juhtumid väärivad lähemat kuulamist ja kontrolli.

Töö käigus õnnestuski tuvastada mõningaid selliseid duplikaate. Ühe konkreetse näitena võib tuua juhtumi, kus kaks erineva viitega salvestust – **RKM, Mgn. II 2630 n** ja **RKM, Mgn. ER 2 (4)** – asusid klasterkaardil vahetus läheduses (Joonis 19). Kuigi salvestuste metaandmed (sh pealkiri, esitaja, kihelkond ja kogumisaasta) olid erinevad, osutus helifailide sisu kuulamisel identseks. Tõenäoliselt on tegemist digiteerimisprotsessis tekkinud veaga, kus üks ja sama salvestus on ekslikult seotud kahe erineva arhiivikirjega. Kuna erinevused ilmsid ainult metaandmetes, mitte aga helisisus, oleks selline viga ilma kuuldelise kontrollita jäänud märkamatuks.

Joonis 19. Mudel paigutas kokku kaks lugu: **RKM, Mgn. II 2630 n** ja **RKM, Mgn. ER 2 (4)**. Metaandmed on kirjetel üksteisest täiesti erinevad, kuid helifailid on identsed.



Kuna käesoleva uurimistöo fookus oli suunatud eelkõige viisitüüpide tuvastamisele ja salvestuste grupeerimisele, ei olnud mul võimalik klasterkaardi abil tuvastatud potentsiaalsete duplikaatide ja muude anomaaliade kontrollimiseks kõiki vastavaid salvestusi süstemaatiliselt läbi kuulata. See eeldaks eraldi ajamahukat ettevõtmist, mis võiks tulevikus kujuneda omaette uurimissuunaks. Siiski illustreerib antud näide, kuidas masinõppepõhisel mudelil võib olla praktiline rakendus arhiivimaterjalide kvaliteedikontrollis ning arhiivivigade tuvastamisel.

4.3. Uute salvestuste viisitüübi tuvastamine

Kui jaotises 4.1 tuginesin ühe ja sama viisitüübi erinevate esituste tuvastamiseks projitseeritud klasterkaardile, siis käesolevas jaotises lähenen ülesandele otse mudeli genereeritud kõrgemõõtmeliste hõlmanguvektorite kaudu. Eesmärk on ka hinnata, kuivõrd suudab mudel määrata viisitüübi täiesti uute salvestuste puhul, ilma mõõtmete vähendamise või visuaalse rühmitamise vahendusega.

Kuna eelneva analüüsi käigus õnnestus mul määrata viisitüüp enam kui 600 varem märgendamata salvestusele (vt jaotist 4.1), mis lisandusid juba varasemalt olemasolevale 2400 salvestusest koosnevale andmestikule, koostasid nende põhjal uue ja mitmekesisema

treeningkorpuse. Selle tulemusel treenisin mudelit uuesti²⁸, kasutades enam kui 3000 salvestust. Selline täiendus suurendas mudeli võimet tuvastada muusikalisi mustreid ning parandas selle üldistusvõimet – st suutlikkust ära tunda sarnasusi ka varem nägemata esitustes.

Katse eesmärk ei olnud testida üksnes mudeli täpsust, vaid ka seda, kuivõrd suudab mudel siduda uued sisendsalvestused olemasolevate arhiivisalvestustega, tuginedes ainuüksi nende helilisele sarnasusele. Valisin katseks viis viisitüüpi, mille esinemissagedus treeningandmestikus varieerus: osa neist oli seal esindatud rohkesti, osa vähesel määral (vt Tabel 4). Iga valitud viis mängiti uuesti sisse neljal erineval pillil – lõõtsal, karmoškal, viiulil ja vilepillil. Lõõtsal, karmoškal ja vilepillil esitasin lood ise, viiulil mängis Krista Sildoja. Selline lähenemine võimaldas uurida, kuidas mõjutavad tuvastustulemusi nii konkreetse viisi kui ka pilli varasem esindatus treeningandmetes.

Tabel 4. Uute salvestuste viisitüübi lõikes ja vastavate salvestuste arv treeningandmetes.

Viis	Salvestusi
Padespaan	215
Savikoja venelane	51
Aleksandra valss	23
Maikuu päevad	9
Tule mulle, mu neiu	3

4.3.1. Sarnasusel põhineva pingerea koostamine

Uute salvestuste tuvastamiseks kasutasin mudeliga kaasnevat käsurea tööriista²⁹, mille abil sai sisendina kasutada üksikut helifaili ning genereerida selle põhjal pingerea n kõige sarnasemast salvestusest olemasolevast andmestikust. Käesolevas töös määrasin $n = 10$, kuna kümme esimest vastet annavad piisava ülevaate mudeli järjestustulemustest, ilma et analüüs muutuks liigselt koormavaks või ebauhtlaseks. Sellest mahust piisab, et hinnata, kas mudel paigutab viisitüübilt sarnased salvestused pingerea algusesse ning kuivõrd need kattuvad sisendsalvestuse tegeliku viisitüübiga.

²⁸ Treenimine toimus sama konfiguratsiooni alusel nagu varem.

²⁹ <https://github.com/alannngnet/CoverHunterMPS/blob/main/tools/identify.py>

Tööriist genereeris esmalt sisendsalvestusest hõlmanguvektori, kasutades sama CQT-põhist spektraalanalüüsi nagu treeningu käigus, ning arvutas seejärel koosinuskauguste põhjal kaugused kõigi andmestikus olevate salvestuste hõlmanguvektorite suhtes. Tulemuseks oli pingereastatud loend arhiivisalvestustest, mille kaudu oli võimalik hinnata, kuivõrd täpselt suudab mudel määrata salvestuse kuuluvuse viisitüübi alusel.

Tabelis 5 on esitatud näide, kus sisendsalvestusena kasutasin karmoškaga mängitud viisi “Maikuu päevad”. Tabelis on välja toodud kümme salvestust, mida mudel hindas sisendsalvestusega kõige sarnasemaks. Neist üheksa kuulusid samasse viisitüüpi nagu sisendsalvestus, kusjuures seitsmendal kohal olev **FAM 61 (6)** ei olnud varem märgendatud. See tähendab, et mudel suutis lisaks juba teadaolevatele tüübiseostele osutada ka uutele vastavustele. Terviklikult on sarnasuste pingeread sisendsalvestuste lõikes välja toodud Lisas 5.

Tabel 5. Karmoškale mängitud “Maikuu päevad” (*maikuu_g_karmoška.wav*) kümme kõige sarnasemat vastet. Kümnest üheksa vastet on õiged ehk nende viisitüüp kattub sisendsalvestuse viisitüübiga. *Kauguse* veerg tähistab salvestuse suhtelist kaugust sisendsalvestusest hõlmanguruumis – mida väiksem väärtus, seda sarnasemaks hindab mudel vastet. Tärniga tähistatud viisitüüp viitab uuele tuvastusele, mida ei olnud eelnevalt märgendatud.

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.176785	ERA, DAT 36 (44)	Reilender.	Maikuu päevad
2	0.195684	ERA, DAT 85 (14)	Reilender.	Maikuu päevad
3	0.19817	ERA, DAT 36 (22)	Reinlender "Kevade, kui maikuu päevad, siis kõik õied õitsma läävad".	Maikuu päevad
4	0.219032	RKM, Mgn. II 4158 (7)	Omaloominguline (reinlender)	Maikuu päevad
5	0.222021	ERA, DAT 38 (28)	Reinlender.	Maikuu päevad
6	0.226924	RKM, Mgn. ER 68 (7)	Võru reilender	Maikuu päevad
7	0.227469	FAM 61 (6)	Reilender.	<i>Maikuu päevad*</i>
8	0.229257	KKI, RLH 83:9 (9)	Siis tuli vasta peremees...Leilender.	Maikuu päevad
9	0.237131	RKM, Mgn. II 2646 c	Polka - Pisikene Ants, mis nutad sa	
10	0.238278	ERA, DAT 39 (41)	Kevadel, kui maikuu päevad... (Vestlus + "Reindender")	Maikuu päevad

Sarnasuste tuvastamise põhimõtte sarnaneb klasterkaardil kasutatule (vt jaotist 4.1) – eesmärk on leida salvestused, mis paiknevad hõlmanguruumis lähestikku. Kuid erinevalt t-SNE visualiseerimisest, mille käigus osa kõrgemõõtmelist teavet võib kaduma minna, põhineb siin kasutatud pingereastamine otseselt hõlmanguvektorite vahelisel kaugusel. Seetõttu säilivad salvestuste omavahelised kaugused kadudeta, ilma mõõtmete vähendamisest tulenevate moonutusteta, võimaldades seeläbi usaldusväärsemat ja meetoodiliselt täpsemat analüüsi.

Heaks näiteks on “Karoobuška” viisitüübi juhtum (vt jaotist 4.1.3), kus üks selle viisitüübi salvestus – RKM, Mgn. II 2000 d – paiknes klasterkaardil teistest eraldi, moodustades visuaalselt isoleeritud klatri. Kui aga koostada sarnasuse alusel pingerida, tuginedes otseselt hõlmanguvektoritele, hindab mudel selle salvestuse sarnasust ülejäänud “Karoobuška” esitustega kõrgeks ning asetab selle pingerea etteotsa (vt Lisa 5). See kinnitab, et kõrgemõõtmelises ruumis toimuv analüüs võimaldab tuvastada sisulisi seoseid ka juhul, kui need jäävad kahemõõtmelisel klasterkaardil varjatuks.

4.3.2. Tulemuste kvantitatiivne hindamine täpsusmõõdikute alusel

Mudeli tõhususe kvantitatiivseks hindamiseks kasutasin kahte mõõdikut: *AP* (*average precision* ehk keskmine täpsus) ja *RI* (*rank of first relevant item* ehk esimese asjakohase vaste järjestusnumber pingereas). Need mõõdikud erinevad jaotistes 3.2.1 ja 3.2.2 kirjeldatud mõõdikutest *mAP* ja *MRI* selle poolest, et siin hinnatakse täpsust iga üksiku sisendsalvestuse lõikes, mitte keskmist kõigi päringute lõikes. Samuti piirdusid arvutused ainult esimese kümne vastusega³⁰, mis võimaldab mõõta mudeli täpsust just pingerea ülemises osas – praktikas kõige olulisemas osas. Viisitüüpide „Maikuu päevad“ ja „Tule mulle, mu neiu“ puhul oli andmestikus aga vähem kui kümme salvestust, mistõttu arvutati täpsus vastavalt olemasoleva arvu vastete põhjal.

Tabel 6 koondab tulemused mõõdiku *AP* põhjal ehk näitab, kui suur osa mudeli tagastatud kümnest esimesest vastest kuulus samasse viisitüüpi kui sisendsalvestus. Täpsustuseks olgu öeldud, et mõõdik *AP* arvestab mitte ainult õigete vastete koguarvu, vaid ka nende järjestust pingereas. Näiteks ei pruugi 10-st 9 õige tulemuse korral täpsus olla automaatselt 90% – kui õiged vasted paiknevad järjestuse eesotsas, siis on mõõdiku väärtus kõrgem kui juhul, kui need paiknevad tagapool.

³⁰ Seeläbi võiks kasutatud mõõdikuid tähistada ka kui: *AP@10* ja *RI@10*.

Tabel 6. Mudeli poolt tagastatud 10 esimese vaste mõõdik *AP* ehk keskmine täpsus pillide löikes, väljendatud protsentides. Väärtus 100% tähendab, et kõik 10 (või maksimaalselt võimalikud) vastet olid õiged; väärtus 0% tähendab, et kõik olid valed.

Viis	Salvestusi	Lööts	Karmoška	Viiul	Vilepill
Padespaan	215	100%	100%	100%	100%
Savikoja venelane	51	100%	100%	100%	100%
Aleksandra valss	23	100%	100%	100%	0%
Maikuu päevad	9	100%	98,9%	55,3%	0%
Tule mulle, mu neiu	3	100%	0	0	91,7%

Tabel 7 koondab tulemused täiendava mõõdiku *RI* alusel, mis näitab esimese korrektse vaste positsiooni pingereas – see võimaldab hinnata, kui kõrgele asetab mudel kõige sarnasemat salvestust ning kuivõrd on järjestuse algus usaldusväärne.

Tabel 7. Mudeli poolt tagastatud 10 esimese vaste mõõdik *RI* ehk esimese korrektselt tuvastatud vaste positsioon pingereas. Väärtus 1 tähendab, et esimene vaste oli õige; X tähistab, et ühtki õiget vastet kümne esimese seas ei leidunud.

Viis	Salvestusi	Lööts	Karmoška	Viiul	Vilepill
Padespaan	215	1	1	1	1
Savikoja venelane	51	1	1	1	1
Aleksandra valss	23	1	1	1	X
Maikuu päevad	9	1	1	2	X
Tule mulle, mu neiu	3	1	X	X	1

Katsete tulemused näitavad, et mudeli täpsus sõltub olulisel määral nii viisi kui ka pilli varasemast esindatusest treeningandmestikus. Kõige järjekindlamad ja kõrgeima täpsusega tulemused ilmsid löötspillil, mille puhul tuvastati kõik viisid 100% täpsusega – kõigi sisendsalvestuste kümme esimest vastet kuulusid vastavasse viisitüüpi. Üheks võimalikuks põhjuseks võib pidada asjaolu, et treeningandmestikus oli just löötspillil esitusi kõige rohkem (ligikaudu 1300 salvestust), mistõttu oli mudel selle pilli puhul ilmselt paremini "häälestatud" ja suutis sarnasusi kindlamalt hinnata. Sama kõrge täpsus saavutati ka viiside "Padespaan" ja "Savikoja venelane" puhul, mille suhteliselt suurem esindatus treeningandmetes – sarnaselt löötspilliga – võis samuti soodustada mudeli suuremat täpsust sarnasuste järjestamisel.

Viiuli ja karmoška puhul olid tulemused samuti üldjoontes head, kuigi mitte päris nii järjekindlad kui lõõtspillil. Mõlema pilli puhul õnnestus enamik viisitüüpe õigesti järjestada, kuid esines juhtumeid, kus korrektsed vasted ei olnud esimeste hulgas (“Maikuu päevad”) või puudusid sootuks („Tule mulle, mu neiu“). See viitab sellele, et kuigi mudel on suuteline ka nende pillide puhul edukalt sarnasusi hindama, võib täpsus olla madalam, kui treeningandmetes on vastava pilli esituse oluliselt vähem – näiteks sisaldas treeningkorpus 269 viiuli- ja 63 karmoškaesitust, samas kui lõõtspilliesituse oli tunduvalt rohkem. Huvipakkuv on seejuures asjaolu, et karmoška tulemused olid mõnevõrra paremad kui viiuli omad, hoolimata sellest, et karmoška esituse oli treeningandmetes vähem. Ühe võimaliku seletusena võib oletada, et karmoška tämbriline sarnasus lõõtspilliga aitas kaasa mudeli paremale üldistusvõimele just selle pilli puhul.

Võrreldes teiste pillidega, andis vilepill üldiselt nõrgemaid tulemusi. Üheks tõenäoliseks põhjuseks on selle pilli väga piiratud esindatus treeningandmetes (ainult 2 esitust), mistõttu jäi mudelil vähem võimalusi vilepillil esitatud lugude struktuursete tunnuste üldistamiseks. Lisaks võib mõju avaldada ka vilepilli akustiline iseloom: võrreldes lõõtsaliste ja viiuliga koondub vilepillil sagedusenergia suuremas osas ülemhelidesse, mitte fundamentaalsagedusse (Müller 2015: 48), mis võib mõjutada seda, millisel määral salvestuse heliomadused kajastuvad mudeli poolt töödeldavas hõlmanguvektoris ning seeläbi ka sarnasuste hindamises. Huvipakkuv on aga asjaolu, et just vilepilli puhul õnnestus mudelil väga edukalt tuvastada viisi “Tule mulle, mu neiu” esitused. Viiul ja karmoška sama katsega toime ei tulnud, kuigi need andsid teiste viiside puhul vilepillist üldiselt paremaid tulemusi. See osutab, et mudeli suutlikkus eristada viisitüüpe ei sõltu üksnes vastavate esituste ja konkreetsete pillide arvulisest esindatusest treeningandmestikus, vaid ka heliallikate spetsiifilisest spektraalstruktuurist.

Kokkuvõttes näitavad tulemused, et mudel suudab küllaltki edukalt järjestada sarnaseid salvestusi ning tuvastada viisitüübi ka arhiivivälise uute salvestuste puhul. See kinnitab, et mudel on rakendatav mitte ainult olemasoleva arhiivimaterjali analüüsiks, vaid ka uue materjali kiireks võrdlemiseks ja tüübiseoste kontrollimiseks. Samas ilmnes, et mudeli tõhusus võib sõltuda konkreetsete viisitüüpide ja pilliliikide esindatusest treeningandmestikus – näiteks lõõtspillil, mille salvestusi oli kõige rohkem, olid tulemused kõige stabiilsemad.

Seetõttu võib eeldada, et treeningkorpuse laiendamine ja mitmekesistamine aitaks veelgi parandada mudeli täpsust ja üldistusvõimet ka vähem esindatud viisitüüpide ja pillide puhul.

Kokkuvõte

Käesoleva magistritöö eesmärk oli uurida, kuidas saab muusika andmeanalüütika meetodeid rakendada eesti rahvapillimuusika helisalvestuste võrdlemiseks ja sarnasuste tuvastamiseks ilma, et oleks vaja kasutada noodistusi. Töö keskmes oli küsimus, kas tänapäevased masinõppepõhised kaverituvastuse mudelid suudavad toetada folkloorse muusikamaterjali analüüsi, kus esitused on varieeruvad ning metaandmed sageli ebajärjekindlad või koguni ebatäpsed. Eesmärk oli leida praktiline, muusika andmeanalüütikal põhinev lähenemine, mis vähendaks vajadust helisalvestusi üksikhaaval läbi kuulata ja transkribeerida ning toetaks seeläbi rahvapillimuusika ulatuslikumat ja efektiivsemat analüüsi.

Andmestik pärines Eesti Rahvaluule Arhiivi 20. sajandi pillilugudest, mille koondamine ühtseks ja korrastatud uurimiskorpuseks kujunes käesoleva töö oluliseks osaks. Loodud korpus sisaldab enam kui 9000 pilliloo põhilisi metaandmeid ja viiteid helifailidele, kusjuures ligikaudu kolmandikule salvestustest määrati töö käigus ka vastav viisitüüp. See teeb korpusest väärtusliku lähteandmestiku mitte ainult käesoleva töö, vaid ka võimalike edasiste andme- ja muusikateaduslike uurimuste jaoks. Korpus on avalikult kättesaadav ning seda saavad soovi korral kasutada ka teised rahvamuusikauurijad.

CoverHunteri masinõppemudelil põhinev metoodika õigustas end ning osutus sobivaks rahvapillimuusika analüüsimiseks andmeteanduslikul viisil. Folkloristika seisukohalt on märkimisväärne, et algselt popmuusika kaverlugude tuvastamiseks välja töötatud mudel suutis leida muusikalisi seoseid ka rahvapillimuusika salvestuste vahel. Mudeli abil õnnestus määrata viisitüüp enam kui 600 arhiivisalvestusele, mis näitab selle praktilist rakendatavust rahvamuusikakorpuse korrastamisel. Lisaks aitas mudel tuvastada mõningaid vigu ja ebatäpsusi arhiivimaterjali metaandmetes, kuigi nende süsteemsemaks avastamiseks on vajalik edasine, sihipärasem uurimine. Tähelepanu väärib ka asjaolu, et CoverHunter suutis tuvastada viisitüübi ka täiesti uute salvestuste puhul, tuginedes üksnes nende sarnasusele uurimiskorpuses olevate näidistega ühises kõrgemõõtmelises hõlmanguruumis, ilma eelneva klasterdamiseta.

Tulemused viitavad siiski sellele, et mudeli jõudlus sõltub suuresti nii konkreetsete pillide kui ka viisitüüpide esindatusest treeningandmestikus. Näiteks saavutati parim täpsus lõõtspillil põhinevate salvestuste puhul, tõenäoliselt seetõttu, et neid leidis treeningandmetes kõige

rohkem. Samuti ilmnes, et viisitüübid, mille esindatus treeningandmestikus oli suurem – näiteks “Padespaan” ja “Savikoja venelane” –, andsid märgatavalt paremaid tulemusi kui need, mille esitusi oli vähem. Sellest võib järeldada, et korpuse laiendamine nii pillide kui ka viisitüüpide lõikes võiks aidata veelgi parandada mudeli üldistusvõimet ning suurendada sarnasuste hindamise täpsust ka harvemini esinevate juhtumite korral.

Edasine uurimistöö keskendub nii mudeli arendamisele kui ka uurimiskorpuse laiendamisele. Üheks oluliseks suunaks on rahvalaulude helisalvestuste kaasamine. Kui käesolev töö keskendus pillimuusikale, siis edaspidi võiks sarnast lähenemist rakendada ka rahvalaulude meloodiate analüüsil. Masinõppel põhinev klasterdamine ja sarnasuspõhine järjestamine võimaldaksid tuvastada meloodiliselt sarnaseid laule ka juhtudel, kus metaandmetes puuduvad otsesed seosed. Selline lähenemine looks eeldused traditsioonilise rahvamuusika laiemapõhjaliseks analüüsiks ning toetaks selle mitmekesise pärandi sügavamalt mõistmist.

Teise olulise edasiarendusena on kavas rakendada klasterdamist otse kõrgedimensionaalses hõlmanguruumis, mitte üksnes visualiseerimiseks. Käesolevas töös piirduti sarnasuspõhise järjestamise ja t-SNE abil loodud kaardipõhise visualiseerimisega, kuid edaspidi on eesmärk kasutada tihedusel põhinevaid klasterdamisalgoritme (nt DBSCAN), mis võimaldavad rühmitada salvestusi täpsemalt nende hõlmangupõhise muusikalise sarnasuse järgi. Selline lähenemine looks aluse senisest täpsemaks ja automaatsemaks kaverite tuvastamiseks ning oleks loogiline täiendus CoverHunteri senisele töövoole.

Ühtlasi on kavas jätkata CoverHunteri mudeli hüperparameetrite süstemaatilist testimist, et leida konfiguratsioon, mis sobib kõige paremini rahvapillimuusika esituste varieeruvuse ja akustiliste iseärasustega. Samuti on plaanis rakendada Alan Ng’ poolt väljatöötatud helistiku invariantsuse meetodit, mis võib võimaldada mudelil paremini tuvastada meloodilisi sarnasusi lugude vahel, mis on esitatud erinevates helistikes.

Kokkuvõttes osutab käesolev uurimus, et muusika andmeanalüütika meetodid võivad kujuneda väärtuslikuks töövahendiks rahvamuusika uurimisel. Need võimaldavad ühelt poolt toetada arhiivimaterjali korrastamist, teisalt aga soodustada esituste vaheliste seoste tuvastamist suurtes ja muusikaliselt mitmekesistes helikogudes. Käesolevat tööd võib seeläbi käsitleda kui üht võimalikku lähenemisviisi, mis võiks toetada valdkonna edasist arengut. Eriti oluline on see rahvapillimuusika klassifitseerimise ja süstematiseerimise seisukohalt,

kus suur andmemaht ja esituste varieeruvus on seni takistanud tervikliku tüpologia kujunemist. Loodetavasti tähistab antud uurimus sammu lähemale selle eesmärgi saavutamisele.

Summary

This thesis investigates how computational methods from the field of Music Information Retrieval (MIR) can be applied to the analysis of Estonian folk instrumental music, with a particular focus on identifying different performances of the same tune directly from audio recordings, without relying on symbolic notation or manual transcription. The study addresses both methodological and disciplinary challenges, proposing a semi-automated approach for comparing and organizing archival recordings where metadata is often inconsistent, incomplete, or inaccurate.

The central research questions were as follows:

- What methods can be used to compare and group instrumental folk music recordings without symbolic notation?
- How well do current state-of-the-art cover song identification models perform when applied to Estonian traditional instrumental music?
- How effective is automatic clustering in detecting different performances of the same tune?
- Can such methods also help identify duplicates or cataloging errors in archival metadata?

While the study is contextually related to earlier folkloristic work by Ingrid Rüütel on the classification of Estonian folk tunes, it proposes a different approach based on direct audio comparison rather than symbolic transcription. Traditional methods have typically relied on notated melodies and manual clustering, which are time-consuming and limited in scale. In contrast, audio-based MIR techniques enable large-scale comparative analysis of musical material without the need for prior transcription. This is particularly important for historical field recordings, where transcription can be difficult due to variable performance styles, non-standard intonation, or low recording quality.

A research corpus of over 9,000 instrumental recordings from the Estonian Folklore Archives was compiled and preprocessed. These 20th-century field recordings, often collected using mechanical or low-fidelity equipment, were curated into a structured dataset with standardized metadata and references to the original audio files. For approximately one-third

of the recordings, melodic types were manually assigned during the course of the project to serve as reference points for evaluation.

At the core of the analysis lies a machine learning model called CoverHunter, originally developed for identifying cover versions in popular music. The model was adapted to Estonian folk music and evaluated based on its ability to group together different performances of the same melodic type. The system was able to detect musical similarity directly from audio embeddings and produced promising results, particularly for well-represented instruments like the diatonic accordion. In addition to clustering related tunes, the method also revealed some cataloging inconsistencies and potential duplicates in the archive.

The findings suggest that MIR techniques – when carefully adapted – can support both the analytical and curatorial aspects of ethnomusicological work. The proposed approach enables scalable, data-driven analysis of musical similarity that reduces reliance on manual labor and makes it possible to handle large, diverse collections of traditional music. This opens up new pathways for typological classification, error detection, and musical pattern discovery in digital folk archives. In a broader perspective, the study contributes to the growing field of computational folkloristics by showing how machine learning can augment traditional research practices in the study of intangible cultural heritage.

Kasutatud kirjandus

Aassalu, Heino (koost); Pill Luht (toim) ja Kristjan Torop. 1997. *Valimik XX sajandi I poole seltskonnatantse*. Rahvakultuuri Arendus- ja Koolituskeskus.

Acoustical Society of America. Standard Terms – “Timbre”, <https://asastandards.org/terms/timbre/> (vaadatud 08.08.2025).

Aljanaki, Anna. 2024. Muusika andmeanalüütika (LTAT.02.015) kursus Tartu Ülikoolis 2024. aasta kevadel.

Dong, Mingwen. 2018. Convolutional Neural Network Achieves Human-Level Accuracy in Music Genre Classification. *Conference on Cognitive Computational Neuroscience*. Philadelphia, Pennsylvania, USA: Cognitive Computational Neuroscience. <https://doi.org/10.32470/CCN.2018.1153-0>.

Du, Xingjian; Zhesong Yu, Bilei Zhu, Xiaou Chen ja Zejun Ma. 2021. Bytecover: Cover Song Identification Via Multi-Loss Training. In *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 551–55. Toronto, Kanada. <https://doi.org/10.1109/ICASSP39728.2021.9414128>.

Eikmeier, Claus; Ernani Volpe ja Carlos Chaves. 2021. FWI cycle skipping mitigation with an intermediate data approach based on dynamic time warping.

ERA heliarhiiv. Eesti Rahvaluule Arhiivi koduleht, <https://www.folklore.ee/era/leidmine/heli.htm> (vaadatud 24.03.2025)

Gholamy, Afshin; Vladik Kreinovich ja Olga Kosheleva. 2018. *Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation*. Raport UTEP-CS-18-09. Texase Ülikooli Arvutiteaduste osakond.

Hachmeier, Simon ja Robert Jäschke. 2025. On the Robustness of Cover Version Identification Models: A Study Using Cover Versions from YouTube. *Information Research an International Electronic Journal* 30: 1103–22. <https://doi.org/10.47989/ir30iConf47077>.

Hernandez-Olivan, Carlos; Ignacio Zay Pinilla, Carlos Hernandez-Lopez ja Jose R. Beltran. 2021. A Comparison of Deep Learning Methods for Timbre Analysis in Polyphonic

Automatic Music Transcription. *Electronics* 10, 7: 810.

<https://doi.org/10.3390/electronics10070810>.

Hoffer, Elad ja Nir Ailon. 2015. Deep Metric Learning Using Triplet Network.

Similarity-Based Pattern Recognition: Third International Workshop, SIMBAD 2015, 84–92.

Berlin: Springer. https://doi.org/10.1007/978-3-319-24261-3_7.

Jamshidi, Farzaneh; Grace Pike, Arpan Das ja Raymond Chapman. 2024. *Machine Learning Techniques in Automatic Music Transcription: A Systematic Survey*. arXiv:2406.15249.

<https://arxiv.org/abs/2406.15249>.

Jang, Byeong-Yong; Woon-Haeng Heo, Jung-Hyun Kim ja Oh-Wook Kwon. 2019. Music Detection from Broadcast Contents Using Convolutional Neural Networks with a Mel-Scale Kernel. *EURASIP Journal on Audio, Speech, and Music Processing*. 2019, 1: 11.

<https://doi.org/10.1186/s13636-019-0155-y>.

Kivikese veebipõhine juhend. 2025. Kivikese koduleht,

https://kivike.kirmus.ee/index.php?dok_id=24&module=2 (vaadatud 24.03.2025)

Kõmmus, Helen (koost). 2017. Hiiumaa rahvalaulud, pillilood ja tantsud – Helisalvestusi Eesti Rahvaluule Arhiivist.

Liu, Feng; Deyi Tuo, Yinan Xu ja Xintong Han. 2023. CoverHunter: Cover Song Identification with Refined Attention and Alignments. *IEEE International Conference on Multimedia and Expo (ICME)*, 1080–85. Brisbane, Austraalia
<https://doi.org/10.1109/ICME55011.2023.00189>.

Louro, Pedro Lima; Hugo Redinho, Ricardo Malheiro, Rui Pedro Paiva, ja Renato Panda. 2024. A Comparison Study of Deep Learning Methodologies for Music Emotion Recognition. *Sensors* 24, 7: 2201. <https://doi.org/10.3390/s24072201>.

Manning, Christopher D., Prabhakar Raghavan ja Hinrich Schütze. 2008. *An Introduction to Information Retrieval*. Cambridge: Cambridge University Press.

Müller, Meinard. 2015. *Fundamentals of Music Processing: Audio, Analysis, Algorithms, Applications*. Cham: Springer International Publishing, 2015.
<https://doi.org/10.1007/978-3-319-21945-5>.

Olagunju, Kazeem; Olufemi Ojo ja Oyediran Mayowa. 2023. Detection of Musical Keys Using Music Information Retrieval Toolbox in MATLAB. *Journal of Computer Science and Its Application*. 30. 115–122.

Oras, Janika. 2008. Viie 20. sajandi naise regilaulumaailm: Arhiivitekstid, kogemused ja mälestused. Väitekiri. Tartu: Tartu Ülikool, 2008.

Ozaki, Yukiko; James McBride, Emmanouil Benetos, Peter P. Pfordresher, Jérôme Six, Alexander T. Tierney, Shigeki Sagayama ja Patrick E. Savage. 2021. Reliability of Automated and Human Transcriptions of Non-Western Music. In *Proceedings of the 22nd International Society for Music Information Retrieval Conference (ISMIR 2021)*, 56–63.

Peeters, Geoffroy; Gabriel Meseguer-Brocal, Alain Riou ja Stefan Lattner. 2024. Deep Learning 101 for Audio-based MIR. ISMIR 2024 veebipõhine õpperaamat. <https://doi.org/10.5281/zenodo.14049461>.

Põldmäe, Rudolf ja Herbert Tampere. 1938. *Valimik eesti rahvatantse*. Tartu: Eesti Rahvaluule Arhiiv.

Rüütel, Ingrid. 1969. Rahvalaulu-terminoloogia probleeme. *Keel ja Kirjandus*, 2, 95–104.

Rüütel, Ingrid. 2006. Eesti regivärsiliste rahvalaulude muusikaline tüpoloogia. *Võim ja kultuur* 2, 83–102. <https://doi.org/10.7592/VK2.2006.RYYTEL>

Rüütel, Ingrid ja Koit Haugas. 1990. A Method for Distinguishing Melody Types and Establishing Typological Groups (on the Material of Estonian Runo Songs). *Musikometrika* 2. Quantitative Linguistics 43. Bochum: Universitätsverlag Dr. N. Brockmeyer.

Schroff, Florian; Dmitry Kalenichenko ja James Philbin. 2015. FaceNet: A Unified Embedding for Face Recognition and Clustering. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 815–23. Boston, USA: IEEE, 2015. <https://doi.org/10.1109/CVPR.2015.7298682>.

Torop, Kristjan. 2008. *Viron vakka: 105 eesti rahvatantsu*. Eesti Rahvatantsu ja Rahvamuusika Selts.

Uppin, Juhan. 2022. Teppo-tüüpi lõõtspilli traditsioonilise mängustiili kujunemine 20. sajandil ja traditsiooniteadliku esituspraktika loomine (dokoritöö).

van der Maaten, Laurens ja Geoffrey Hinton. 2008. *Journal of Machine Learning Research*, 86 (9): 2579-2605.

Lisad

Lisa 1. Loodud pillilugude infosüsteemi prototüüp

Vastavalt jaotises 2.2.3 kirjeldatud probleemidele ja vajadustele tekkis vajadus välja töötada uus tarkvaraline lahendus pillilugude haldamiseks. Väljatöötatud infosüsteem on realiseeritud kaasaegsete veebitehnoloogiate abil: programmeerimiskeelena on kasutusel TypeScript ning rakendus tugineb Reacti (liidese loomiseks) ja Node.js-i (taustateenuste haldamiseks) raamistikele. Infosüsteemi lähtekood on avatud ja hallatud GitHubi platvormil³¹.

Kasutajate halduseks ja autentimiseks on süsteemis rakendatud Postgres andmebaas. Pillilugude andmestik ise on aga praegusel hetkel hoiustatud CSV-vormingus failis. Selline lahendus on ajutine ning tingitud praktilistest kaalutlustest: nimelt toimub paralleelselt andmete töötlemine ja täiendamine ka Google Spreadsheetsi formaadis, mille kaudu on CSV-failide import ja eksport märksa lihtsam. Edasises arendusetapis on plaan kogu andmestik migreerida ühtsesse Postgres andmebaasi, et tagada suurem andmete terviklus, päringute efektiivsus ja süsteemi skaleeritavus.

Väljatöötatud rakendus võimaldab pillilugudega seotud infot tabeli kujul vaadata, võimaldades salvestust otse tabelis ka kuulata. Lisaks pakub see erinevaid viise andmete filtreerimiseks ja järjestamiseks. Olulise osana pakub võimaldab rakendus kuvada ka pillilugude statistikat nii viiside, esitajate, aastate, kihelkondade kui ka pillitüüpide lõikes. Kihelkondade statistikat saab kuvada ka otse kaardil. Ekraanitõmmised antud tarkvarast on välja toodud joonistel 6, 7 ja 8.

Kuigi infosüsteem on hetkel veel aktiivses arendusetapis ja ei ole avalikult kasutatav, on sellel potentsiaal areneda terviklikuks rahvamuusika andmehalduse platvormiks. Tulevikuvisioonis nähakse süsteemi laienemist selliselt, et see hõlmaks lisaks pillilugudele ka teisi rahvamuusika žanre, sealhulgas regiviise.

³¹ <https://github.com/taneltorn/folkera>

Lisa 2. Treening- ja testandmete jaotuse tabel

Andmestiku **folk150** algne jaotus treening- ja testandmeteks, mida kasutasin mudeli tõhususe hindamisel (Jaotis 3.2). Jagamise viisin läbi 80:20 suhte alusel, järgides seda nii esituste kui ka lugude lõikes. Hilisemad mudeli treenimised viisin läbi juba korrigeeritud andmetega, kus kõrvaldasin mõningad andmete märgendamisel esinenud ebatäpsused.

Lugu	Andmestik	Tantsutüüp	Esitusi
Krakovjak	folk150_trainset	polka	241
Padespaan	folk150_trainset	valss	199
Perekonnavalss	folk150_trainset	valss	122
Kaerajaan / Kaaratsimm	folk150_trainset	polka	95
Sepp / Papiljon	folk150_trainset	polka	83
Läksin mina läbi külatänava	folk150_trainset	reinlender	69
Vengerka (Sitikad ja satikad)	folk150_testset	reinlender	63
Tuustepp (Kas tahad tulla minuga)	folk150_trainset	polka	56
Kui naine minu pahandab / Kuldne kodumaa	folk150_testset	polka	54
Savikoja venelane	folk150_testset	polka	48
Mäletad kevadet õites	folk150_testset	valss	44
Tõmba Jüri	folk150_trainset	polka	39
Roosiaias	folk150_trainset	valss	40
Ma tahaksin kodus olla	folk150_testset	valss	39
Ma vaatan paadist kiikriiga	folk150_trainset	valss	39
Tinna / Musta peaga plika	folk150_trainset	polka	36
Hulkuri valss	folk150_trainset	valss	36
Viljandi paadimees	folk150_trainset	valss	35
Litsu pääle	folk150_trainset	polka	32
Mets mühiseb	folk150_trainset	valss	32
Kilu-Mari polka	folk150_trainset	polka	31
Läänemere lained	folk150_trainset	valss	31
Üle lainete	folk150_testset	valss	30
Postipoiss	folk150_testset	fokstrott	29
Jooksupolka	folk150_trainset	reinlender	27
Kui kodunt ma laia maailma / Sõduri truudus	folk150_trainset	valss	27
Laias laanes	folk150_trainset	valss	22
Piusa jõe kaldal	folk150_trainset	valss	19
Karobushka	folk150_trainset	polka	17
Meremehe seiklus	folk150_trainset	valss	17

Mu meelen kuldne kodukotus	folk150_testset	valss	17
Meil lilled õitsvad aasadel	folk150_trainset	valss	17
Oirah	folk150_trainset	polka	16
Vanad sõbrad	folk150_trainset	marss	16
Kikapuu	folk150_trainset	polka	16
Lutika Viiu	folk150_trainset	valss	16
Kaugel, kaugel, kus on minu kodu	folk150_trainset	fokstrott	16
Saksad surevad / Kuldimuna lõikaja	folk150_testset	reinlender	15
Mu isamaa armas	folk150_testset	reinlender	15
Oh, saja lumeke	folk150_testset	valss	14
Kolm lille	folk150_trainset	valss	14
Kupparimuori	folk150_trainset	polka	13
Suboota	folk150_trainset	reinlender	13
Pühajärve valss	folk150_trainset	valss	13
Aleksandra valss	folk150_trainset	valss	13
Tüdruk	folk150_testset	valss	13
Vengerka (Teised naised) / Ropp reinlender	folk150_trainset	reinlender	12
Sonny boy	folk150_testset	fokstrott	12
Talgupolka	folk150_testset	polka	12
Metsas vaikselt	folk150_trainset	valss	11
Löötspill naljatab	folk150_trainset	polka	11
Sangaste polka	folk150_trainset	polka	11
Õllepruulija	folk150_trainset	valss	10
Vanaisa polka	folk150_testset	polka	10
Neemisküla polka	folk150_trainset	polka	10
Sõduri kutse	folk150_trainset	valss	10
Nukrad silmad	folk150_trainset	valss	10
Üks jahimees läks metsa	folk150_testset	muu	9
Aissa	folk150_trainset	polka	9
Sinililled	folk150_trainset	valss	9
Vahtra polka	folk150_trainset	polka	9
See Mäeotsa talu	folk150_trainset	polka	9
Mu süda mul kerkib ja keeb	folk150_trainset	valss	8
Tarvastu polka / Äiapapa polka	folk150_trainset	polka	15
Emajõe jutustus	folk150_trainset	valss	8
Miks elus on alati nõnda / Miks tähti nii palju on taevas	folk150_trainset	valss	8
Kui lapsena lustilla luhal	folk150_trainset	valss	8
Joo, sõbrake, joo / Ei joomist ei jäta ma maha	folk150_testset	valss	8
Kalamies	folk150_testset	polka	7

Loobeni polka	folk150_trainset	polka	7
Kõndis neiu mööda metsa	folk150_trainset	valss	7
Terve vald / Tuljak	folk150_testset	polka	6
Nõiduslik öö	folk150_trainset	valss	6
Ämmamoori maja	folk150_trainset	polka	6
Kodu metsa all	folk150_trainset	valss	6
Ei me ette tea	folk150_trainset	valss	6
Vändra polka	folk150_trainset	polka	5
Tsingle polka	folk150_trainset	polka	5
Kord elas mölder veski peal	folk150_trainset	polka	5
Väike Ants	folk150_trainset	polka	5
Süda see ihaldab laineid	folk150_trainset	valss	5
Ära ilmas valu kaeba	folk150_trainset	valss	5
Tule ääres istun mina	folk150_trainset	valss	5
Sügistuultes	folk150_trainset	fokstrott	5
Kurtutetsi	folk150_trainset	polka	5
Lõolugu	folk150_testset	labajalg	5
Karjala polka / Soome polka	folk150_trainset	polka	5
Valged roosid	folk150_trainset	valss	5
Palupõhja valss	folk150_trainset	valss	5
Tuisu polka	folk150_testset	polka	5
Üks, kaks, kolm...	folk150_trainset	reinlender	4
Tursapolka / Aala-ilja	folk150_trainset	polka	4
Jõua ju kaugelta / Minjoon	folk150_trainset	valss	4
Laeva tõstis purjed	folk150_trainset	fokstrott	4
Marupini polka	folk150_trainset	polka	4
Õrn ööbik	folk150_trainset	fokstrott	4
Neiu armas, neiu kallis	folk150_testset	fokstrott	4
Võru valss	folk150_trainset	valss	2
Kevade polka	folk150_trainset	polka	4
Mind kutsuti pulma	folk150_testset	labajalg	4
Suhkrutükk	folk150_trainset	fokstrott	4
Abruka valss	folk150_trainset	valss	4
Meremeeste valss / Ei lind, ei laul	folk150_trainset	valss	4
Las jääda nii kuis oli	folk150_trainset	valss	4
Seal, kus Emajõgi voolab	folk150_trainset	valss	4
Vana längus rehetare	folk150_trainset	valss	4
Kungla rahvas	folk150_testset	polka	4
Mustlasepolka	folk150_trainset	polka	3
Sõrmõlugu	folk150_testset	valss	3

Tuustepp (Setumaa)	folk150_trainset	polka	2
Pargi valss	folk150_trainset	valss	4
Neiukene, noorukene	folk150_trainset	fokstrott	3
Tule mulle, mu neiu	folk150_trainset	valss	3
Küünla polka	folk150_trainset	polka	3
Uisumeeste polka	folk150_trainset	polka	3
Kolmepuari	folk150_trainset	polka	3
Kord läksid kolm sõpra	folk150_trainset	valss	3
Saadab mind minu vari	folk150_trainset	valss	3
Maali polka	folk150_trainset	polka	3
Arglik armastus	folk150_trainset	valss	3
My Bonnie Lies over the Ocean	folk150_trainset	valss	3
Mul ialgi elus ei vea	folk150_trainset	polka	3
Maikuu päevad	folk150_trainset	reinlender	3
Saaremaa valss	folk150_trainset	valss	3
Tule aga tule	folk150_trainset	valss	3
Kingissepa polka	folk150_trainset	polka	2
Kõik roosid ma kingiksin sulle	folk150_trainset	valss	2
Must kleit	folk150_trainset	valss	2
Pisikene titt ja titevoodi	folk150_testset	polka	2
Eesti metsad	folk150_trainset	valss	2
Kord ma Peipsi piiril käisin	folk150_testset	muu	2
Sitsikleit	folk150_trainset	valss	2
Üks kask meil kasvas õues	folk150_trainset	valss	2
Tuustepp (Kui teil soov on kuulda)	folk150_trainset	polka	2
Neljapuari	folk150_trainset	polka	2
Võru polka	folk150_trainset	polka	2
Maamehe reinlender	folk150_testset	reinlender	2
Valss Saaremaalt	folk150_trainset	valss	2
Sangaste polka II	folk150_trainset	polka	2
Vares ja varblane	folk150_trainset	polka	2
Järvakandi reilender	folk150_trainset	reinlender	2
Kuldne õhtupäike	folk150_testset	polka	2
Aisakell	folk150_trainset	polka	2
Kui aasadel hõljumas udu	folk150_trainset	valss	2
Purjesportlaste valss	folk150_trainset	valss	2
Aeg annab kõik	folk150_trainset	valss	2
Vanapoiisi polka	folk150_trainset	polka	2
Veski polka	folk150_trainset	polka	2
Labajalavalss I	folk150_testset	labajalg	2

Kajaka labajalg	folk150_trainset	labajalg	2
-----------------	------------------	----------	---

Lisa 3. Tuvastatud viisitüüpide statistika

Joonisel 14 välja toodud klasterkaardi abil tuvastatud esituste arv viisitüübi lõikes.

Viis	Tuvastatud esitusi
Abruka valss	2
Aeg annab kõik	1
Aissa	1
Aleksandra valss	10
Arglik armastus	3
Eesti metsad	3
Emajõe jutustus	2
Hulkuri valss	8
Joo, joo, sõbrake, joo	13
Jõua ju kaugelta / Minjoon	2
Kaerajaan / Kaaratsimm	4
Kalamies	4
Karjala polka / Soome polka	3
Karobushka	18
Kaugel, kaugel, kus on minu kodu	3
Kevade polka	1
Maikuu päevad	6
Kiigadi-kaagadi	2
Kikapuu	4
Kilu-Mari polka	1
Kodu metsa all	6
Koduküla nõmmed	6
Kodunurmed	3
Kõndis neiu mööda metsa	2
Kord elas mölder veski peal	3
Krakovjak	14
Kui aasadel hõljumas udu	2
Kui kodunt ma laia maailma / Sõduri truudus	6
Kui lapsena lustilla luhal	6
Kui naine minu pahandab / Kuldne kodumaa	18
Kuldne õhtupäike	3
Kungla rahvas	1
Läänemere lained	6
Laev tõstis purjed	1
Laias laanes	5

Läksin mina läbi külatänava	23
Las jääda nii kuis oli	1
Litsu pääle / Tarvastu polka / Äiapapa polka	36
Loobeni polka	2
Lõolugu	1
Lutika Viiu	5
Ma tahaksin kodus olla	7
Ma vaatan paadist kiikriga	7
Maali valss	3
Maamehe reinlender	8
Mäletad kevadet õites	12
Meremehe seiklus	21
Mets mühiseb	5
Metsas vaikselt	8
Miks elus on alati nõnda / Miks tähti nii palju on taevas	1
Mu isamaa armas	3
Mu meelen kuldne kodukotus	1
Mu süda mul kerkib ja keeb	1
My Bonnie Lies over the Ocean	1
Neemisküla polka	5
Nõiduslik öö	1
Nukrad silmad	1
Oh, saja lumeke	2
Õrn kevade / Meil lilled õitsvad aasadel	19
Padespaan	16
Pargi valss	4
Perekonnavalss	10
Piusa jõe kaldal	4
Postipoiss	4
Pühajärve valss	5
Reinlender 1	2
Roosiaias	10
Saksa galopp	2
Saksad surevad / Kuldimuna lõikaja	4
Sambla Anu	2
Sangaste polka	3
Sangaste polka II	2
Savikoja venelane	3
See Mäeotsa talu	2
See vene riigi säädus	2

Sepp / Papiljon	45
Sinililled	1
Sitsikleit	5
Sõduri kutse / Kuramaa rannal	13
Sõitsin üle Soome silla	2
Sonny boy	8
Sõrmõlugu	1
Suboota	5
Süda see ihaldab laineid	10
Südame valu / Sangaste valss	2
Sügistuultes	1
Talgupolka	7
Tinna / Musta peaga plika	4
Tõmba, Jüri!	3
Tsingle polka	1
Tüdruk	2
Tuisu polka	3
Tule ääres istun mina	1
Tule aga tule	25
Tuustepp	29
Tuustepp (Setumaa)	1
Uisumeeste polka	1
Üks jahimees läks metsa	3
Üks, kaks, kolm...	1
Üle lainete	19
Vahtra polka	3
Väike Ants	12
Valss 1	2
Valss 2	2
Vana längus rehetare	8
Vanad sõbrad	1
Vanaisa polka	1
Vanas kambris	3
Vändra polka	1
Vengerka (Sitikad ja satikad)	11
Vengerka (Teised naised) / Ropp reinlender	1
Viljandi paadimees	3

Lisa 4. Skript helifailide konverteerimiseks

Bashi skript, mis konverteerib sisendkaustas olevad salvestused ühekanalisteks 16 kHz diskreetimissagedusega helifailideks.

```
#!/bin/bash

input_folder="wav_original"
file_list="filelist.txt"
output_folder="wav_16k"

mkdir -p "$output_folder"

while IFS= read -r file; do
    input_file="$input_folder/$file"

    if [ -f "$input_file" ]; then
        output_file="$output_folder/$file"
        mkdir -p "$(dirname "$output_file")"

        sox "$input_file" -r 16000 -c 1 "$output_file"
        if [ $? -eq 0 ]; then
            echo "Converted and saved: $output_file"
        else
            echo "Failed to convert: $input_file"
        fi
    else
        echo "File not found: $input_file"
    fi
done < "$file_list"
```

Lisa 5. Sarnaste salvestuste pingeread sisendsalvestuste kaupa

Lisa sisaldab iga sisendsalvestuse kohta koostatud pingeread arhiivisalvestustest, mille mudel järjestas sarnasuse alusel. Pingeread illustreerivad mudeli suutlikkust leida kõige sarnasemad viisitüübid või esitused vastavalt sisendsalvestusele. Tärn (*) viisitüübi lahtris viitab olukorrale, kus viisitüüp ei olnud eelnevalt märgendatud, vaid tuvastati sarnasuspõhise pingerea alusel.

Salvestused on leitavad aadressil:

https://drive.google.com/drive/folders/1hV83BEC857tyRhhYqFFHz_FnAOCF9zIP

Padespaan, lõõtsal, D helistikus, esitanud Tanel Torn (padespaan_d_loots.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.042	RKM, Mgn. ER 71 (27)	Padespaan	Padespaan
2	0.043	RKM, Mgn. II 2344 n	Reilender	Padespaan
3	0.050	ERA, DAT 33 (17)	Padispaan.	Padespaan
4	0.052	ERA, DAT 36 (43)	Padespaan "Nadinunnadi".	Padespaan
5	0.053	RKM, Mgn. II 3303 (4)	Padespaan	Padespaan
6	0.053	RKM, Mgn. II 3574 (3)	Padespaan ("Nadinunnadi")	Padespaan
7	0.055	RKM, Mgn. II 4070 (10)	Krakuljak	Padespaan
8	0.056	RKM, Mgn. II 4148 (9)	t. Padespaan "Nadi-nunadi"	Padespaan
9	0.057	RKM, Mgn. II 4316 (21)	Padispaan	Padespaan
10	0.057	RKM, Mgn. II 3850 (5)	Padespaan	Padespaan

Padespaan, karmoškak, G helistikus, esitanud Tanel Torn (padespaan_g_karmoška.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.032	RKM, Mgn. II 3303 (4)	Padespaan	Padespaan
2	0.037	ERA, DAT 36 (43)	Padespaan "Nadinunnadi".	Padespaan
3	0.038	RKM, Mgn. ER 63 (31)	Padespaan	Padespaan
4	0.041	RKM, Mgn. II 3574 (3)	Padespaan ("Nadinunnadi")	Padespaan
5	0.042	RKM, Mgn. II 3855 (1)	Padespaan	Padespaan
6	0.045	RKM, Mgn. ER 71 (27)	Padespaan	Padespaan

7	0.045	RKM, Mgn. II 3337 (1)	"Anna andeks, anna andeks" pillil + seletus: pulmas ja pidudel pilli mängimine, pulmas tantsimine, Pühajärve valss	Padespaan
8	0.045	RKM, Mgn. II 3159 (5)	Padispaan: Kui mamma mind sõidab	Padespaan
9	0.046	ERA, DAT 73 (25)	Padispaan (Nadinunnadi)	Padespaan
10	0.047	ERA, DAT 33 (17)	Padispaan.	Padespaan

Padespaan, vilepillil, D helistikus, esitanud Tanel Torn (padespaan_d_vile.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.082	RKM, Mgn. II 3855 (1)	Padespaan	Padespaan
2	0.085	RKM, Mgn. II 3977 (11)	Valss	Padespaan
3	0.093	RKM, Mgn. ER 18 (5)	Padespaan	Padespaan
4	0.094	RKM, Mgn. II 2795 b	Padespaan	Padespaan
5	0.098	RKM, Mgn. II 3077 (15)	Padispaan	Padespaan
6	0.099	RKM, Mgn. II 1379 b	Padespaan	Padespaan
7	0.100	RKM, Mgn. II 3561 (1)	Padespaan	Padespaan
8	0.101	KKI, RLH 67:7 (7)	Padespaan (Nadi-nunnadi).	Padespaan
9	0.104	RKM, Mgn. II 2386 i	Padispaan: Nadinunnadi	Padespaan
10	0.104	RKM, Mgn. II 4012 (17)	Padespaan (Anna andeks)	Padespaan

Padespaan, viiulil, D ja Bm helistikes, esitanud Krista Sildoja (padespaan_d_viiul.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.070	RKM, Mgn. II 3912 (21)	Padespaan	Padespaan
2	0.077	ERA, DAT 15 (22)	Padispaan.	Padespaan
3	0.078	RKM, Mgn. II 2928 (16)	Padespaan	Padespaan
4	0.079	RKM, Mgn. II 3576 (1)	Padespaan "Nadinunnadi"	Padespaan
5	0.081	RKM, Mgn. II 2953 (15)	Padespaan: Minu papa oli mammale alati truu	Padespaan
6	0.081	RKM, Mgn. II 3303 (4)	Padespaan	Padespaan
7	0.083	RKM, Mgn. II 576 b	Padespaan	Padespaan
8	0.085	RKM, Mgn. ER 10 (2)	Padespaan	Padespaan
9	0.085	RKM, Mgn. II 3609 (20)	Padispaan "Anna andeks"	Padespaan

10	0.086	RKM, Mgn. II 3855 (1)	Padespaan	Padespaan
----	-------	-----------------------	-----------	-----------

Savikoja venelane, lõõtsal, D, G ja C helistikes, esitanud Tanel Torn
(savikoja_dgc_loots.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.077	RKM, Mgn. II 1518 b	Savikua venelane	Savikoja venelane
2	0.081	RKM, Mgn. II 2345 e1	Savikoja sakslane	Savikoja venelane
3	0.083	RKM, Mgn. ER 64 (7)	Savikoja venelane	Savikoja venelane
4	0.084	RKM, Mgn. II 95 b	Savikua veneläne	Savikoja venelane
5	0.084	RKM, Mgn. II 2123 b	Savikoja venelane	Savikoja venelane
6	0.090	RKM, Mgn. II 2943 (18)	Savikoa venelase	Savikoja venelane
7	0.092	RKM, Mgn. II 4455 (20)	Savikoja veneläne	Savikoja venelane
8	0.094	RKM, Mgn. ER 16 (15)	Savikoja venelane	Savikoja venelane
9	0.094	KKI, RLH 51:1 (3)	Savikoja venelane	Savikoja venelane
10	0.095	RKM, Mgn. II 4098 (23)	"Savikoja venelane"	Savikoja venelane

Savikoja venelane, karmoškala, G helistikus, esitanud Tanel Torn
(savikoja_g_karmoška.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.044	RKM, Mgn. ER 64 (7)	Savikoja venelane	Savikoja venelane
2	0.046	RKM, Mgn. II 2345 e1	Savikoja sakslane	Savikoja venelane
3	0.048	RKM, Mgn. II 4097 (42)	Savikoja venelane	Savikoja venelane
4	0.050	RKM, Mgn. II 1380 c	Savikoja venelane	Savikoja venelane
5	0.050	RKM, Mgn. II 1518 b	Savikua venelane	Savikoja venelane
6	0.053	KKI, RLH 51:4 (2)	Savikoja venelane	Savikoja venelane
7	0.055	KKI, RLH 51:1 (3)	Savikoja venelane	Savikoja venelane
8	0.056	RKM, Mgn. II 2943 (17)	Savikoa venelane	Savikoja venelane
9	0.057	RKM, Mgn. II 2029 a	Savikoja venelane	Savikoja venelane
10	0.059	ERA, DAT 9 (30)	Savikoja venelane	Savikoja venelane

Savikoja venelane, vilepillil, D helistikus, esitanud Tanel Torn (savikoja_d_vile.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.048	RKM, Mgn. II 922 a	Savipoti venelane	Savikoja venelane
2	0.051	ERA, DAT 39 (26)	"Savikoja venelane"	Savikoja venelane
3	0.054	RKM, Mgn. II 1308 a	Savikoti venelane	Savikoja venelane
4	0.064	ERA, Pl. 34 A1	Savikua veneläse	Savikoja venelane
5	0.067	RKM, Mgn. I 45 (15)	Savikoja venelane.	Savikoja venelane
6	0.069	KKI, RLH 51:4 (2)	Savikoja venelane	Savikoja venelane
7	0.077	RKM, Mgn. II 761 d	Savikoja venelane	Savikoja venelane
8	0.080	RKM, Mgn. II 4097 (42)	Savikoja venelane	Savikoja venelane
9	0.082	KKI, RLH 51:1 (3)	Savikoja venelane	Savikoja venelane
10	0.082	RKM, Mgn. ER 64 (7)	Savikoja venelane	Savikoja venelane

Savikoja venelane, viiulil, G ja C helistikes, esitanud Krista Sildoja (savikoja_gc_viiul.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.080	RKM, Mgn. II 1308 a	Savikoti venelane	Savikoja venelane
2	0.099	KKI, RLH 51:4 (2)	Savikoja venelane	Savikoja venelane
3	0.107	RKM, Mgn. II 2029 a	Savikoja venelane	Savikoja venelane
4	0.113	RKM, Mgn. ER 16 (15)	Savikoja venelane	Savikoja venelane
5	0.114	ERA, DAT 39 (26)	Savikoja venelane	Savikoja venelane
6	0.120	RKM, Mgn. II 1818 b	Savikoja venelane	Savikoja venelane
7	0.122	RKM, Mgn. II 4097 (42)	Savikoja venelane	Savikoja venelane
8	0.123	RKM, Mgn. II 2943 (18)	Savikoa venelase	Savikoja venelane
9	0.124	RKM, Mgn. II 2345 e1	Savikoja sakslane	Savikoja venelane
10	0.124	RKM, Mgn. ER 64 (7)	Savikoja venelane	Savikoja venelane

Aleksandra valss, lõõtsal, C ja G helistikes, esitanud Tanel Torn (aleksandra_cg_loots.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.071	ERA, DAT 44 (25)	Valss lõõtsal	Aleksandra valss
2	0.078	FAM 791 (23)	Pillimäng – padespaan	Aleksandra valss

3	0.083	KKI, RLH 72:32 (5)	Aleksandra valss	Aleksandra valss
4	0.083	RKM, Mgn. II 2633 a	Aleksandre valss	Aleksandra valss
5	0.085	FAM 784 (21)	Pillimäng, aleksandra valss	Aleksandra valss
6	0.086	RKM, Mgn. II 3565 (21)	Valss - Oh, neiuke, tule sa	Aleksandra valss
7	0.087	ERA, DAT 37 (1)	Aleksandria valss.	Aleksandra valss
8	0.088	RKM, Mgn. ER 46 (4)	Aleksandra valss	Aleksandra valss
9	0.088	RKM, Mgn. ER 53 (10)	Aleksandri valss.	Aleksandra valss
10	0.093	RKM, Mgn. II 2949 (12)	Aleksandri (ei ole valss)	Aleksandra valss

Aleksandra valss, karmoškai, G helistikus, esitanud Tanel Torn (aleksandra_g_karmoška.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.074	ERA, DAT 44 (25)	Valss lõõtsal	Aleksandra valss
2	0.083	RKM, Mgn. II 2949 (12)	Aleksandri (ei ole valss)	Aleksandra valss
3	0.091	KKI, RLH 72:32 (5)	Aleksandra valss	Aleksandra valss
4	0.093	FAM 784 (21)	Pillimäng, aleksandra valss	Aleksandra valss
5	0.093	RKM, Mgn. II 2633 a	Aleksandre valss	Aleksandra valss
6	0.094	RKM, Mgn. II 3565 (21)	Valss - Oh, neiuke, tule sa	Aleksandra valss
7	0.094	ERA, DAT 37 (1)	Aleksandria valss.	Aleksandra valss
8	0.094	FAM 226 (17)	Aleksandra valss.	Aleksandra valss
9	0.096	RKM, Mgn. ER 46 (4)	Aleksandra valss	Aleksandra valss
10	0.102	ERA, DAT 21 (12)	Valss	Aleksandra valss

Aleksandra valss, vilepillil, G helistikus, esitanud Tanel Torn (aleksandra_g_vile.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.196	RKM, Mgn. II 2061 e	Padispaan	Padespaan
2	0.203	RKM, Mgn. II 3077 (15)	Padispaan	Padespaan
3	0.209	RKM, Mgn. II 3868 (1)	Valsilugu	
4	0.214	RKM, Mgn. II 3719 (18)	Valss "Ma lähen sinna orgu"	
5	0.216	FAM 150 (4)	Valss "Saare rannikul ma kõnnin üksinda".	
6	0.218	RKM, Mgn. II 3318 (1)	Valss "Esmaspäeval Tartu linnas" (lauldi laulu saateks)	

7	0.221	ERA, Pl. 7 B1	Eesti neli ehk Seesam	
8	0.222	RKM, Mgn. II 2193 k	Valss	
9	0.222	RKM, Mgn. II 1784 g	Polka "Juulit, Maalit ma ei taha"	
10	0.223	RKM, Mgn. II 4012 (17)	Padespan (Anna andeks)	Padespaan

Aleksandra valss, viiulil, G helistikus, esitanud Krista Sildoja (aleksandra_g_viiul.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.106	ERA, DAT 37 (1)	Aleksandria valss.	Aleksandra valss
2	0.112	RKM, Mgn. II 2949 (12)	Aleksandri (ei ole valss)	Aleksandra valss
3	0.119	ERA, DAT 85 (13)	Valss.	Aleksandra valss
4	0.120	FAM 784 (21)	Pillimäng, aleksandra valss	Aleksandra valss
5	0.124	RKM, Mgn. II 2933 (9)	Amori valss - I õpitud lugu + vestl.	Aleksandra valss
6	0.125	RKM, Mgn. II 3565 (21)	Valss - Oh, neiuke, tule sa	Aleksandra valss
7	0.127	RKM, Mgn. ER 46 (4)	Aleksandra valss	Aleksandra valss
8	0.128	FAM 785 (18)	Pillilugu, tants - aleksandra valss	Aleksandra valss
9	0.129	KKI, RLH 72:32 (5)	Aleksandra valss	Aleksandra valss
10	0.132	RKM, Mgn. II 2633 a	Aleksandre valss	Aleksandra valss

Maikuu päevad, lõõtsal, G helistikus, esitanud Tanel Torn (maikuu_g_loots.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.146	ERA, DAT 85 (14)	Reilender.	Kevadel, kui maikuu päevad
2	0.182	ERA, DAT 36 (44)	Reilender.	Kevadel, kui maikuu päevad
3	0.191	ERA, DAT 39 (41)	Kevadel, kui maikuu päevad... (Vestlus + "Reindender")	Kevadel, kui maikuu päevad
4	0.192	ERA, DAT 36 (22)	Reinlender "Kevade, kui maikuu päevad, siis kõik õied õitsma läävad".	Kevadel, kui maikuu päevad
5	0.205	KKI, RLH 83:9 (9)	Siis tuli vasta peremees...Leilender.	Kevadel, kui maikuu päevad
6	0.207	ERA, DAT 38 (28)	Reinlender.	Kevadel, kui maikuu päevad

7	0.214	RKM, Mgn. ER 68 (7)	Võru reilender	Kevadel, kui maikuu päevad
8	0.236	FAM 61 (6)	Reilender.	*Kevadel, kui maikuu päevad
9	0.245	RKM, Mgn. II 4158 (7)	Omaloominguline (reinlender)	Kevadel, kui maikuu päevad
10	0.249	RKM, Mgn. ER 64 (46)	Reilender	Kevadel, kui maikuu päevad

**Maikuu päevad, karmoškai, G helistikus, esitanud Tanel Torn
(maikuu_g_karmoška.wav)**

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.177	ERA, DAT 36 (44)	Reilender.	Kevadel, kui maikuu päevad
2	0.196	ERA, DAT 85 (14)	Reilender.	Kevadel, kui maikuu päevad
3	0.198	ERA, DAT 36 (22)	Reinlender "Kevade, kui maikuu päevad, siis kõik õied õitsma läävad".	Kevadel, kui maikuu päevad
4	0.219	RKM, Mgn. II 4158 (7)	Omaloominguline (reinlender)	Kevadel, kui maikuu päevad
5	0.222	ERA, DAT 38 (28)	Reinlender.	Kevadel, kui maikuu päevad
6	0.227	RKM, Mgn. ER 68 (7)	Võru reilender	Kevadel, kui maikuu päevad
7	0.227	FAM 61 (6)	Reilender.	*Kevadel, kui maikuu päevad
8	0.229	KKI, RLH 83:9 (9)	Siis tuli vasta peremees...Leilender.	Kevadel, kui maikuu päevad
9	0.237	RKM, Mgn. II 2646 c	Polka - Pisikene Ants, mis nutad sa	
10	0.238	ERA, DAT 39 (41)	Kevadel, kui maikuu päevad... (Vestlus + "Reindender")	Kevadel, kui maikuu päevad

Maikuu päevad, vilepillil, G helistikus, esitanud Tanel Torn (maikuu_g_vile.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.165	RKM, Mgn. II 957 f	Jahvaata	

2	0.166	RKM, Mgn. II 4209 (24)	Mäe otsas kaljulossis (rmngl)	
3	0.167	RKM, Mgn. II 137 h	Valts (Ei ole ma neiule andnud suud) 2 tuuriga	
4	0.167	RKM, Mgn. II 3913 (6)	Tõmba Jüri polka	
5	0.174	ERA, CD 4 (21)	Kallis sõber soovin sulle ma (sünnipäevalaul)	
6	0.175	KKI, RLH 57:5 (2)	Polka kõigile	
7	0.175	RKM, Mgn. II 4178 (12)	EÜE-s ei ole muud... + selet.	
8	0.175	RKM, Mgn. II 2027 b	Valts	
9	0.176	FAM 150 (4)	Valss "Saare rannikul ma kõnnin üksinda".	
10	0.176	RKM, Mgn. ER 79 (2)	Pillilugu + seletus järgmise loo kohta.	

Maikuu päevad, viiulil, G helistikus, esitanud Krista Sildoja (maikuu_g_viiul.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.207	RKM, Mgn. II 201 d	Eha vaata	
2	0.213	ERA, DAT 36 (22)	Reinlender "Kevade, kui maikuu päevad, siis kõik õied õitsma läevad".	Kevadel, kui maikuu päevad
3	0.218	ERA, DAT 85 (14)	Reilender.	Kevadel, kui maikuu päevad
4	0.227	RKM, Mgn. II 3372 (8)	Üks imelik pisike laululind + andmed	
5	0.229	RKM, Mgn. II 4158 (7)	Omaloominguline (reinlender)	Kevadel, kui maikuu päevad
6	0.230	ERA, DAT 73 (47)	Reinlender (Lõuna-Eestist)	
7	0.230	ERA, Pl. 7 B1	Eesti neli ehk Seesam	
8	0.230	RKM, Mgn. II 3644 (7)	Padispaan (kannel serviti üles)	Padespaan
9	0.233	RKM, Mgn. ER 68 (7)	Võru reilender	Kevadel, kui maikuu päevad
10	0.234	RKM, Mgn. ER 68 (36)	Polka "Õpetaja salakaval"	

Tule mulle, mu neiu, lõõtsal, G helistikus, esitanud Tanel Torn (neiu_g_loots.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.115	ERA, DAT 36 (23)	Valss "Jää mulle, mu neid".	Tule mulle, mu neiu

2	0.169	RKM, Mgn. II 461 d	Valts "Tule mulle, tule mulle, mu neiu"	Tule mulle, mu neiu
3	0.195	RKM, Mgn. II 463 h	Valts: "Tule mulle, tule mulle, mu neiu"	Tule mulle, mu neiu
4	0.204	KKI, RLH 62:23 (9)	Valss	
5	0.212	RKM, Mgn. II 4005 (7)	Nooriku tantsitamine, Hulkurivalss	
6	0.213	RKM, Mgn. II 2934 (8)	Juudi Valgast tulliva	
7	0.215	RKM, Mgn. II 3578 (1)	Valss - Jaaniöö (Tauli valss)	
8	0.220	RKM, Mgn. II 3573 (1)	Valss - Kas tead ka, mu kallike kaugel	
9	0.222	RKM, Mgn. II 3574 (4)	Valss - Me istusime kahekesi pingil	
10	0.224	RKM, Mgn. ER 8 (17)	Reinlender "Sulane küsis tüdrukult musi"	

Tule mulle, mu neiu, karmoškale, G helistikus, esitanud Tanel Torn (neiu_g_karmoška.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.152	KKI, RLH 62:23 (9)	Valss	
2	0.174	KKI, RLH 63:24 (28)	Valss.	
3	0.176	RKM, Mgn. II 4005 (7)	Nooriku tantsitamine, Hulkurivalss	
4	0.177	RKM, Mgn. I 56 (2)	Nooriku tants peiupoisiga + ul. "Neiukene, noorukene"	
5	0.188	KKI, RLH 62:21 (15)	Ma istusin õunapuu all	
6	0.189	RKM, Mgn. II 3552 (13)	Valss - Mu maja Mardi uulitsas	
7	0.190	RKM, Mgn. II 3449 (11)	Padespaan - Nadi-nunnadi	Padespaan
8	0.197	RKM, Mgn. II 4240 (5)	Valss	
9	0.197	ERA, DAT 32 (61)	Päike on õhtule läinud...	
10	0.197	RKM, Mgn. II 3578 (1)	Valss - Jaaniöö (Tauli valss)	

Tule mulle, mu neiu, vilepillil, D helistikus, esitanud Tanel Torn (tule_d_vile.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.136	RKM, Mgn. II 461 d	Valts "Tule mulle, tule mulle, mu neiu"	Tule mulle, mu neiu
2	0.161	RKM, Mgn. II 463 h	Valts: "Tule mulle, tule mulle, mu neiu"	Tule mulle, mu neiu
3	0.200	RKM, Mgn. II 4210 (34)	Mu isamaa, mu õnn ja rõõm	
4	0.202	ERA, DAT 36 (23)	Valss "Jää mulle, mu neid".	Tule mulle, mu neiu
5	0.215	RKM, Mgn. II 2197 c	Marss (popurii)	
6	0.221	RKM, Mgn. II 3485 (11)	Rootsimaa valss	
7	0.225	ERA, DAT 39 (13)	R. Valgre "Veel viivuks jää..."	
8	0.230	KKI, RLH 67:1.3 (25)	Üleskutsumise viiulilugu + loo seletus.	
9	0.231	RKM, Mgn. II 2913 (9)	Laul mustlaskeelne fragm.	
10	0.234	KKI, RLH 51:1 (5)	Valss "Pikk tee"	

Tule mulle, mu neiu, viiulil, G helistikus, esitanud Krista Sildoja (neiu_g_viiul.wav)

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.156	RKM, Mgn. II 1920 a	Valss: Mu hurmav neiu	
2	0.159	RKM, Mgn. II 3552 (13)	Valss - Mu maja Mardi uulitsas	
3	0.169	RKM, Mgn. II 3577 (16)	Pekripoiste polka	
4	0.175	RKM, Mgn. II 2197 c	Marss (popurii)	
5	0.178	ERA, PI. 131 B3	Pienon karjalapsen itkü	
6	0.179	RKM, Mgn. II 3717 (8)	Valss "All hämarduvas metsas"	
7	0.181	RKM, Mgn. II 3485 (11)	Rootsimaa valss	
8	0.187	KKI, RLH 65:12 (11)	Kaugel venes metsas suures...	
9	0.189	RKM, Mgn. II 2193 j	Valss: Õunapuu all	
10	0.190	RKM, Mgn. II 3578 (1)	Valss - Jaaniõöl (Tauli valss)	

Karobuška, lõõtsal, esitanud Jegor Tuulik (RKM, Mgn. II 2000 d)

Salvestus **RKM, Mgn. II 2000 d** esineb pingereas esimese 30 salvestuse hulgas, mis 2D-klasterkaardil paiknes vastavast klastrist kaugel (vt jaotist 4.3.1).

Jrk	Kaugus	Viide	Sisukirjeldus	Viisitüüp
1	0.017	RKM, Mgn. II 2903 (4)	Karobuška	Karobushka
2	0.095	RKM, Mgn. II 3179 (13)	Korobuška	Karobushka
3	0.098	ERA, DAT 9 (32)	Karabeinik	Karobushka
4	0.104	RKM, Mgn. ER 46 (6)	Korobuška	Karobushka
5	0.109	RKM, Mgn. ER 51 (9b)	Korobuška.	Karobushka
6	0.111	ERA, DAT 23 (58)	Karobotška	Karobushka
7	0.111	RKM, Mgn. ER 46 (8)	Tustepp	
8	0.112	EKRK, Fon. 88 (b4)		Karobushka
9	0.113	FAM 226 (15)	Korobuska.	Karobushka
10	0.113	ERA, DAT 23 (51)	Tustepp	Karobushka
11	0.118	ERA, Fon. 87 f	Karobotška	Karobushka
12	0.119	RKM, Mgn. II 2417 c	Karobuska	Karobushka
13	0.119	ERA, DAT 43 (15)	Karobuska	Karobushka
14	0.120	RKM, Mgn. II 4475 (15)	Tantsulugu	
15	0.128	RKM, Mgn. II 3850 (16)	Vene karobuška	Karobushka
16	0.129	FAM 791 (16)	Pillimäng, karoobuška, taustal jutt	Karobushka
17	0.130	ERA, CD 92 (17)	Davai vai lõõme kasaku maha	Karobushka
18	0.132	RKM, Mgn. ER 74 (5)	Lõõtsalugu [viis: "Милый мой дедочек"/"Сизая голубка"] + tants Tustepp.	Karobushka
19	0.132	RKM, Mgn. II 2633 g	Karobuška	Karobushka
20	0.134	FAM 10 (66)	Karabeinik	Karobushka
21	0.134	KKI, RLH 78:6 (29)	Pesenka.	Karobushka
22	0.137	RKM, Mgn. II 2089 d	Karoobuška	Karobushka
23	0.139	RKM, Mgn. ER 74 (6)	Lõõtsalugu + tants Korobuška.	Karobushka
24	0.141	RKM, Mgn. ER 53 (16)	Karobuška.	Karobushka
25	0.141	RKM, Mgn. II 3179 (1)	Vanaaegne korobuška	Karobushka
26	0.142	RKM, Mgn. II 2007 h	Karobuška	Karobushka
27	0.145	ERA, CD 92 (12)	Karobuška (vene lugu)	Karobushka

28	0.146	ERA, CD 405 (11)	Vene karobotška	Karobushka
29	0.146	RKM, Mgn. II 2000 d	Karobotška	Karobushka
30	0.153	FAM 791 (29)	Pillilugu – valss	Karobushka

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Tanel Torn,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose “Muusika andmeanalüütika rakendamine rahvapillimuusika uurimisel Eesti Rahvaluule Arhiivi helisalvestuste põhjal”, mille juhendajad on Taive Särg ja Anna Aljanaki, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada Tartu Ülikooli digitaalarhiivi kuni autoriõiguse kehtivuse lõppemiseni;
2. annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi kaudu Creative Commonsi litsentsiga CC BY NC ND 4.0, mis lubab autorile viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni
3. olen teadlik, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autorile;
4. kinnitan, et lihtlitsentsi andmisega ei riku ma teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

Tanel Torn

26.05.2025