

TARTU ÜLIKOOL
MATEMAATIKA-INFORMAATIKATEADUSKOND
Arvutiteaduse instituut
Infotehnoloogia eriala

Elinor Toodo

Rokkmuusika alastiilide klassifitseerimine tugivektormasinatega

Bakalaureusetöö (6 EAP)

Juhendaja: Sven Aller

Juhendaja: Margus Niitsoo

Autor: “.....” mai 2013
Juhendaja: “.....” mai 2013
Juhendaja: “.....” mai 2013
Lubatud kaitsmisele
Professor: “.....” mai 2013

Tartu 2013

Sisukord

Sissejuhatus	3
Muusikastiilid	5
1.1 Muusikastiilidest üldiselt	5
1.2 Rokkmuusika alastiilid	6
Automaatne klassifitseerimine	9
2.1 Klassifitseerimisest üldiselt	9
2.2 Tugivektormasinad	11
Metoodika ja töövahendid	14
3.1 Muusikakorpus	14
3.2 Töövahendid	15
3.3 Tunnused	16
Tulemused ja järeldused	19
4.1 Tulemuste analüüs	19
4.2 Kvartiilhaardega testide tulemuste analüüs	22
4.3 Võimalused töö edasi arendamiseks	24
Kokkuvõte	25
Subgenre classification of rock music using support vector machines	26
Viidatud materjalid	27
Lisad	29
Lisa 1 Joonised tunnuste väärtuste jaotumisest	29
Lisa 2 Segaduste tabelid	43
Lisa 3 Muusika nimekiri	43

Sissejuhatus

Tänapäeval areneb muusikatööstus tohutu kiirusega. Väga erinevaid muusikateoseid tuleb juurde suures hulgas ja pidevalt kasvavas infohulgas orienteerumiseks on vaja lood mingil viisil kategoriseerida. Selleks kasutatakse stiilideks liigitamist, mis aitab lihtsamalt omale meelepäraseid lugusid leida. Teoste stiilideks jagamine on aga väga subjektiivne ning seega ei ole erinevate stiilide eristamine selgepiiriline ega ka alati mitte ühene. Samuti kasutavad erinevad muusikaga tegelevad ettevõtted erinevat liigitust. Sellest tulenevalt peab kõigepealt paika panema käesolevas kontekstis kasutatavad stiilid ja seejärel saab kogu olemasoleva muusika nende vahel ära jagada. Kuna muusikapalasisid on väga palju, siis oleks hea seda tööd automatiseerida.

Muusikastiilide automaatse tuvastamisega on tegeletud juba rohkem kui kümme aastat ja selleks on kasutatud hulgaliselt erinevaid algoritme, sealhulgas ka selles töös käsitletud tugivektormasinaid (*support vector machine* - SVM) [1] [2]. Klassifitseerimisel kasutatakse enamasti väga üldisi ja omavahel selgelt eristuvaid stiile nagu näiteks jazz, klassikaline muusika, elektrooniline muusika, rokk jt. Kuna need stiilid on väga erinevad, saavad algoritmid nende eristamisega juba edukalt hakkama. Selle kõrval ei tohiks unustada, et ka ühe sellise üldise stiili alastiilid võivad üksteisest oma helikeele ja olemuse poolest väga erineda ning nende liigitamine võiks paremini aidata sobivaid lugusid välja valida. Alastiilide eristamine on aga keerulisem kui üldiste stiiligruppide eristamine, peamiselt seetõttu, et alastiilid on palju vähem selgepiirilised ning rohkemal määral omavahel segunenud.

Käesoleva töö eesmärgiks on katsetada tugivektormasinate algoritmi rokkmuusika alastiilide peal ja näha, kui hästi see meetod töötab ning kas sellisel alastiilide liigitamisel on edasist potentsiaali. Kirjanduse põhjal on tugivektormasinaid üks parimatest ja enim kasutatud meetoditest muusikastiilide liigitamiseks ja seetõttu oli just see algoritm valitud täitmaks spetsiifilisemat liigitamise ülesannet. Rokkmuusika oli valitud pidades silmas selle stiili väga suurt mitmekesisust, üldist populaarsust ja selle stiili alla kuuluvate segunenud alastiilide rohkust. Lisaks sellele on autoril rokkmuusika vastu isiklik huvi.

Kogu töö on jagatud neljaks osaks. Esimeses peatükis on selgitatud muusikastiilide olemust ja seejärel kirjeldatud valitud stiilide eripärasid. Järgmises peatükis on antud ülevaade muusika automaatselt klassifitseerimisest ja täpsemalt tugivektormasinast. Seejärel on kirjeldatud ülesande lahendamiseks kasutatud vahendeid ja meetodeid. Nende alla kuuluvad muusikapalade korpus, lugudest välja võetavad tunnused ja üldised töövahendid. Viimases peatükis on näidatud tulemused.

Lisana on esitatud täiendavad joonised treeningkogumi andmete kohta. Lisadesse on pandud ka kasutatud lugude nimekiri, mis on jagatud vastavatesse stiiligruppidesse.

Peatükk 1

Muusikastiilid

See peatükk kirjeldab muusikastiile. Peatüki esimeses osas on selgitatud muusikastiilide olemust ning sellest tulenevaid probleeme. Peatüki teises pooles on välja toodud need alastiilid ja stiiligrupid, mis on olulised käesoleva töö seisukohalt.

1.1 Muusikastiilidest üldiselt

Muusika kategoriseerimise ja kirjeldamise eesmärgil on kasutusel stiilid. Need aitavad inimestel kiiremini leida neile sobivat muusikat ning samuti annavad ettekujutuse lugudest enne nende kuulamist. Veel kasutatakse stiile, et koondada kokku sarnase muusika austajaid sotsiaalses mõttes (foorumid, liikumised, kogukonnad). Jagatakse infot ja arutatakse neile huvi pakkuva muusika teemadel. Popmuusikas nimetatakse muusikastiile tihtipeale ka žanriteks.

Muusikastiilid jagunevad erinevate põhimõtete alusel. Kõige üldisemateks stiilideks on näiteks klassikaline muusika, pop, jazz, rokk jt. Nende alla käivad mitmete tasemetena teised stiilid, mis sellest alamosa täpsemalt kirjeldavad. Ometi on kõiki muusikastiile raske panna ühtsesse kindlasse struktuuri, sest liigitamise subjektiivsuse tõttu on neid keeruline järjepidevalt kirjeldada. Põhjusi on mitmeid. Üheks nendest on muusikastiilide hula pidev muutumine ajas: uusi stiile tekib juurde ja vanu kaob. See toimub sujuvalt ansamblitele täpsemate ja just neid paremini kirjeldatavate stiilide leidmise tulemusena [3]. Uusi stiile tekib juurde ka juba olemasolevate stiilide omavahelise segunemise teel (*fusion genres*), võttes elemente mitmest stiilist [4].

Samuti on stiilide piirid subjektiivsed, sest reeglid ja tunnused, mis stiile üksteisest eraldavad, on suuresti ebamäärased. Selle tagajärjel toimub ka juba olemasolevates stiilides teatud muutumine. Aja jooksul jagavad ansambleid ja lugusid stiilidesse nii muusika kuulajad, muusikud ise, edasimüüjad kui ka kriitikud. Kuna puuduvad aga üldised kriteeriumid selle tegemiseks, siis ei ole see ühtne. Mõjuteguriks on nii muutuv ühiskond, nägemus nendest stiilidest kui ka võrdlus eelneva loominguga [5].

Veel üheks põhjuseks, miks muusikastiile on raske ühtsesse süsteemi panna, on nende ebamäärane liigitamine/nimetamine ja omavaheline suhe. Stiile nimetatakse väga mitme erineva põhimõtte alusel: põlvnemisel (*neo-progressive*, *post-grunge*), geograafilistel alustel (Armeenia rokk), ajalooliste perioodide järgi (keskaja rokk), segunenud stiilide järgi (*deathgrind* on segu *death metal* ja *grindcore* stiilidest), muusika temaatika järgi (*christian rock*, *viking metal*) jne [5]. Seetõttu ei ole stiilide hulk ka lõplikult piiritletud ning mingil määral võivad mitmed stiilid muusikalises mõttes kattuda.

1.2 Rokkmuusika alastiilid

Üldiselt on rokkmuusika aluseks traditsiooniline 4/4 taktimõõt ning instrumentidest kasutatakse löökpille, vähemalt ühte elektrikitarr ja basskitarr. Mõnevõrra levinud on ka erinevad klahvpillid ja muud keelpillid (eriti sümfooniliste stiilide puhul). Instrumendid häälestatakse tihti madalamaks. Põhiliseks osaks rokkmuusika juures on siiski elektrikitarr, mida kasutatakse nii harmoonia-, rütmi- kui ka sooloinstrumendina. Enamasti kasutatakse kitarridega koos ka efektiseadmeid, et tekitada helis moonutusi (*distortion*) [4]. Kuna need elemendid on olemas peaaegu kõigis rokkmuusika alastiilides, siis on neid alastiile selle võrra raskem üksteisest eristada.

Ühtse stiilide süsteemi puudumise tõttu oli vaja automaatse klassifitseerimise jaoks luua mingitele kriteeriumitele vastav süsteem. Alastiilide rohkuse ja segunemise tõttu ei ole kõiki alastiile võimalik eraldi liigitada ja seega tuli moodustada sarnaste alastiilide grupid. Sarnasust hinnati muusika iseloomu ja kasutatavate muusikaliste elementide järgi. Käesoleva töö mahuliste piirangute tõttu tuli suurest alastiilidest hulgast teha väiksem valik. Stiiligruppide koostamisel peeti ka silmas, et grupid oleksid omavahel eristuvad. Selle tulemusena pandi kokku viis rokkmuusika alastiilide gruppi. Nendeks gruppideks olid:

- klassikaline rokkmuusika (*rock*)
- *metal*-muusika (*metal*)
- ekstreemne *metal*-muusika (*extreme metal*)
- punkrokk (*punk rock*)
- progressiivne rokk (*progressive rock*)

Koostatud klassikalise rokkmuusika grupp sisaldab suures osas modernsest rokkmuusikast, kuid olemas on ka vanemat rokki. Valitud lugude stiilideks on üldiselt märgitud *hard rock*, *grunge*, *post-grunge* või *alternative rock*. Nende stiilide puhul kehtivad kõik roki üldised tunnused. Trummidega mängitakse läbivat rütmi (*driving rhythm*) ning rõhutatakse teist ja neljandat lööki. Basskitarr toetab üldjuhul trumme ja mängib rütmi- ja soolokitarrile korduvat tausta [4]. Laulud on enamasti tavalise salm-refraän ülesehitusega, mistõttu on lugudel selged ning korduvad meloodiad ja kitarrikäigud. Lauldakse nii tavalisel viisil kui ka karjudes (*screaming*) või mõnel juhul ka urisedes (*growl*). Edasipidi nimetatakse seda stiilide gruppi lihtsalt roki grupiks.

Metal-muusika grupp sisaldab lugusid, mille stiilideks olid *heavy metal*, *nu-metal*, *alternative metal*, *gothic metal*, *industrial metal*, *symphonic metal*, *power metal* ja *metalcore* (sealhulgas ka *melodic metalcore*). *Metal*-laulude meloodiad, harmoonia ja rütm on üldiselt sarnased rokkmuusika grupis olevatele. Lood ise on aga valjemad ning rohkema kitarriefektide kasutamise tõttu ka karmima ja „raskema“ kõlaga. Samuti on basskitarr, mida enamasti kasutatakse rütmi instrumendina, rohkem võimendatud kui rokkmuusika stiiligrupi lugudes. Kitarrisoolod on olulisel kohal ja neid võib vaadelda kui eraldiseisvaid meloodiaid [6]. Võrreldes klassikalise rokkmuusikaga on *metal*-lauludes ka rohkem karjumist ja urisemist.

Ekstreemse *metal*-muusika (lihtsuse mõttes edasipidi ekstreemmuusika) gruppi kuuluvad stiilidest *thrash metal*, *speed metal*, *death metal* (sealhulgas ka *technical death metal* ja *melodic death metal*), *groove metal* (ehk *post-thrash*) ja *black metal*. Sellest tööst on välja jäetud *doom metal*, mis defineeritakse üldiselt samuti ekstreemmuusika alla. Selles grupis olevate lugude tunnuseks on tavatu ülesehitus, mis tihtipeale tähendab, et need stiilid ei kasuta levinud salm-refraän vormi. Helikeelelt on nad veelgi agressiivsemad ja „raskemad“ kui teised *metal*-muusika stiilid. Kõige eristuvamaks tunnuseks on kiire tempo, ulatudes kuni kolmesaja löögini minutis. Trummarid kasutavad keerukate ja kiirete trummipartiide mängimiseks näiteks *blast beat* tehnikat, kahte suurt trummi või ka kaksikpedaalnuia. Selle stiiligrupi puhul on meloodial vähemtähtis roll ja tihtipeale see isegi puudub, kuid teatud harmoonia on lugudes siiski olemas. Samuti on lugudes palju atonaalsust, dissonantse ja tritoone. Laulmise asemel on tihti karjumine, urisemine (eriti *death metal* lugudes) või ka kriiskamine (*shrieking*, eriti *black metal* lugudes) [7].

Punkroki grupis on lood, mille stiilideks on *punk rock*, *hardcore*, *post-hardcore* ja ka *pop punk*. Laulud kasutavad enamjaolt rokile tüüpilist 4/4 taktimõõtu ning salm-refraän vormi. Lood on keskmiselt lühemad kui teistes rokkmuusika stiilides ning neis on vähe intonatsiooni ja dünaamika muutusi. Trummipartiid on pigem lihtsad ja minimalistlikud. Laulusõnad öeldakse tihti välja hõigates, kuid palju on ka klassikalises mõttes laulmist. Kitarridel mängitakse enamjaolt kvintakorde. Keerulisi instrumentaalsed soolosisid esineb harva [8].

Progressiivse roki grupis on lood, mille stiilideks on nii *progressive rock* kui ka *art rock*, mida kasutatakse enamasti sünonüümina. Need stiilid on kombinatsioon klassikalisest muusikast ja rokist [4]. Progressiivse roki omapäraks on pikemad lood kui teistes rokkmuusika stiilides ja paljudel juhtudel moodustavad mitmed lood kokku ühtse teema. Lood sisaldavad tihti väga pikki instrumentaalseid vahemänge ja enamasti ei kasuta traditsioonilist salm-refraän ülesehitust. Lugudel on vahelduv tempo ning tihtipeale kasutatakse rokkmuusikas vähemlevinud taktimõõte nagu näiteks 5/8, 7/4, 11/8, 9/4. Mõnel juhul võib kindel meetrum isegi puududa, mis teeb progressiivse muusika rütmiliselt palju vabamaks kui teised rokkmuusika stiilid. Rokkmuusikas laialt levinud muusikariistade kõrval on progressiivse muusikaga tihedalt seostatud ka Hammondi orel, Moogi süntesaator ja mellotron. Meloodiliselt on progressiivne muusika keerulisem ja meloodiad on pikad [9].

Stiiligrupid koostati nii, et neis sisalduvad lood oleksid eristatavad teiste stiiligruppide lugudest. Teoreetiliselt on stiiligruppidel märgatavad erinevused, praktikas ei ole need piirid aga alati nii selged. Lood sisaldavad elemente mitmetest erinevatest stiilidest ning lugudele stiilide omistamine ei ole ühene. Seega võib osutada raskeks näiteks tänapäevase progressiivse roki ja pop-pungi eristamine alternatiivrokist või ka *hard rock*'i ja vanema ekstreemmuusika eristamine traditsiooniliselt *heavy metal*'ist.

Enamasti on töös esitajatena viidatud ansamblitele, kuna rokkmuusikas on valdav osa esitajaid just ansamblid. Samuti on lugude puhul enamasti viidatud lauludele, sest rokkmuusika puhul on enamus lood just laulud ning tööse ei kaasatud ühtegi täiesti instrumentaalset helitoest.

Peatükk 2

Automaatne klassifitseerimine

Selles peatükis on üldiselt kirjeldatud automaatset klassifitseerimist. Peatüki esimeses alaosas on üldine ülevaade automaatseks klassifitseerimiseks kasutatavatest meetoditest ja klassifitseerimise sammudest. Peatüki teises pooles on lähemalt kirjeldatud tugi-vektormasinade meetodit ja selle üldisi põhimõtteid, mis on olulised käesoleva töö kontekstis.

2.1 Klassifitseerimisest üldiselt

Muusikastiilide klassifitseerimine on ülesanne, mille eesmärgiks on leida kasutatavatele stiilidele iseloomulikud tunnused ja tuginedes nendele tunnustele hinnata mingi antud muusikapala kuuluvust ühte neist stiilidest. Automaatne klassifitseerimine kuulub masinõppe alla. Põhiliselt jagatakse meetodid juhendatud ja juhendamata õppeks.

Juhendamata õppe puhul jagatakse laulud stiilidesse ilma eelnevalt klasse defineerimata. Klassifikaator vaatab ainult iga laulu positsiooni tunnuste ruumis. Seega need meetodid ei jaga lugusid otseselt stiilidesse, vaid mõõdavad lugude sarnasust [2]. See tähendab, et ühe stiili lood ei pruugi sattuda samasse gruppi ja saadavad grupid võivad sisaldada mitmeid stiile. Nii võib juhtuda, et masina poolt koostatavad grupid ei vasta ajalooliselt tekkinud stiilidele ja seetõttu ei pruugi nad inimeste jaoks piisavalt tähendusrikkad olla. Sellest tulenevalt kasutatakse juhendamata õppega meetodeid stiilide tuvastamiseks vähem.

Juhendatud õppega süsteemid on stiilide tuvastamiseks enam levinud moodus, mille puhul treenitakse süsteemi käsitsi märgendatud lugudega. Märgendamine selles kontekstis tähendab lugudele nende kohta käiva info lisamist. Seega jagab juhendatud õpe lood etteantud klasside (stiilide) vahel ja nii on need inimestele tähendusrikkamad. Kui treenitud süsteemile antakse ette uus lugu, siis ta oskab selle paigutada ühte olemasolevatest stiilidest [2].

Automaatne klassifitseerimine koosneb mitmest sammust. Kõigepealt on vaja koostada muusikakorpus, mis esindaks võrdselt kõiki stiile, ning seejärel kõik laulud käsitsi märgendada vastavate stiilitähistega. Selleks, et muusikapalasid saaks omavahel paremini võrrelda, tuleb leida mingi teatud hulk arvulisi näitajaid ehk tunnuseid (*feature*) ja nendele vastav info lauludest eraldada. Tunnused peavad olema valitud nii, et nende peal tehtud klassifitseerimine annaks arvestatava tulemuse. Tunnuste valik (*feature selection*) tähendab seda, et kogu tunnuste hulgast eemaldatakse need tunnused, mis ei anna piisavalt infot klassifitseerimiseks. See aitab vähendada töödeldava info hulka ja kiirendada treeningmudeli tööd. Hästi valitud tunnuste puhul suureneb ka klassifitseerimise täpsus, sest andmetes on vähem müra [10].

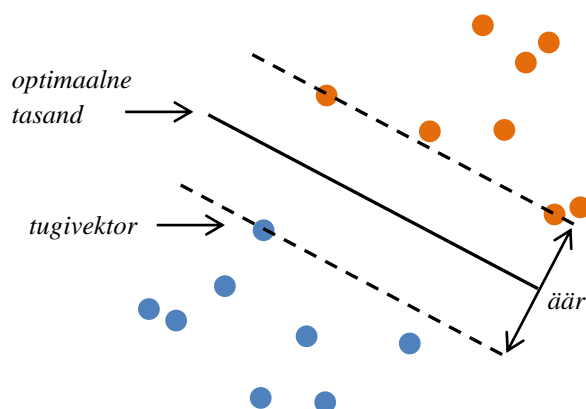
Seejärel tuleb valida klassifikaator, mille peale ehitatakse mudel. Mudelit saab hakata treenima ja kasutama. Muusikastiilide tuvastamiseks sobivad paljud klassifikaatorid. Kasutatud on näiteks naiivse Bayesi meetodit (*naive Bayes*) [11], tugivektormasinaid [12] [13] ja tehisnärvivõrke (*neural networks*) [14]. Igal kasutataval meetodil on omad eelised ja puudused.

Näidetena välja toodud meetodite puhul saavutavad tugivektormasinaid ja tehisnärvivõrgud tihti paremaid tulemusi, kui tegemist on kõrgedimensionaalse andmehulgaga ning kui tunnuste väärtused on pidevad. Samas vajavad need meetodid parema klassifitseerimise täpsuse saavutamiseks suuremat andmehulka kui naiivse Bayesi meetod. Andmetes olevate erindite suhtes on aga tugivektormasinaid oluliselt vähem tundlikud kui näiteks tehisnärvivõrgud. Puuduvate väärtuste suhtes on naiivse Bayesi meetod tolerantsem kui tugivektormasinaid. Tänu tuumade kasutusele on tugivektormasinaid ja tehisnärvivõrgud suutelised andmetega paremini toime tulemiseks koostama keerulisi mudeleid. Selle halvemaks küljeks on aga suurem ülesobitumise (*overfitting*) oht. Samuti on nende algoritmide halvemaks küljeks parameetrite rohkus, sest õigete väärtuste valimine on aeganõudev ja vajab suuremaid teadmisi. Kirjanduse põhjal on aga üldiselt üheks edukamaks üksikuks meetodiks olnud tugivektormasinaid, mida on seetõttu kasutatud ka käesolevas töös [15] [16].

2.2 Tugivektormasinad


Tugivektormasinad (SVM) on juhendatud masinõppe meetod, mis kuulub lineaarsete klassifikaatorite hulka. Tugivektormasinaid kasutatakse nii klassifitseerimisel kui ka regressioonis ja nende eesmärgiks on moodustada treeningandmete alusel mudel, mille põhjal saab uued lood (käesoleva töö kontekstis) eelnevalt defineeritud stiilgruppidesse paigutada.

Binaarsete ülesannete juures üritab SVM konstrueerida tasandi, mis jaotab andmed kahte klassi: ühele poole jääb ühte ja teisele poole teise klassi kuuluv osa. Selle saavutamiseks leitakse kõige optimaalsem tasand, mis tähendab, et tasandi kaugus kõige lähemast elemendist ehk vektorist on suurim. Seega on mõlema klassi elemendid üksteisest maksimaalsel kaugusel. See ala, mis jääb tasandi ja mõlemal pool tasandit lähimate elementide vahele nimetatakse ääreks (*margin*). Need elemendid, mis jäävad ääre peale, on tugivektorid [17] [18]. Seda võib näha jooniselt 1.



Joonis 1 Optimaalne tasand lineaarselt eralduval juhul.

Tihti on andmete struktuur aga keerulisem ja sellist tasandit, mis nii selgelt klasse eraldaks, ei pruugi leiduda. Nendel juhtudel tuleb vähendada iga üksiku vektori mõju tasandi leidmisel nii, et leiduks selline tasand, mis jagab antud ruumi klassideks parimal viisil ja samas vähima vigade arvuga [18]. Ka niisuguse tasandi leidmiseks tuleb leida maksimaalne kaugus klassi elementidest, kuid samal ajal lubada mõnel punktil olla valel pool tasandit. Selle illustreerimiseks on joonis 2.



Joonis 2 Optimaalne tasand lineaarselt mitte-eralduval juhul koos nihkemuutujatega.

Selle saavutamiseks on kasutusel uued muutujad: ääre laiust määrav positiivne konstant C ja nihkemuutujad $\xi = (\xi_1, \xi_2, \dots, \xi_N)$. Mida suurem on C väärtus, seda väiksem on äär ja paljudel juhtudel seda suurem on klassifitseerimise täpsus. Väikese C väärtuste korral on äär laiem, mis tähendab, et ka tugivektorite arv on suurem ja klassifitseerimise täpsus kahaneb. Väikese C väärtuse juures on positiivne see, et see vähendab klassifikatsiooni mudeli ülesobitumist treeningmaterjalil. Nihkemuutujad näitavad punktide kaugust nende klassile lähema ääre piirist. Kui nihkemuutuja on 0, siis on tegemist õigesti klassifitseerimisega [19] [16].

Tugivektormasinad oskavad ära kasutada tuumasid (*kernel*), mistõttu on võimalik konstrueerida ka mitte-lineaarseid süsteeme. Selleks on kasutusel tuumameetodid, millega saab andmed teisendada suuremamõõtmelisse ruumi. Antud töös ei ole oluline seda kirjeldada, sest töö tegemisel kasutati ainult lineaarset tuuma.

SVM on algselt binaarne meetod, kuid muusika klassifitseerimiseks on vaja eristada rohkem kui kahte stiili või stiiligrupi. Üks levinuim viis mitmeklassilise SVM-i tegemiseks jagab mitmeklassilise ülesande mitmeks binaarseks ülesandeks. Kui klasside arv on M , siis üks *versus* kõik meetodi (*winner-takes-all* strateegia) puhul konstrueeritakse M binaarset klassifikaatorit. Iga klassifikaator on loodud eristama ühe klassi elemente kogu ülejäänud $M-1$ klassi elementide hulgast. Klassifikaatorit C_{ij} treenitakse elementidega, mis on võetud klassidest ω_i ja ω_j . Andes ette uue elemendi x , leitakse selle elemendi kaugus lineaarselt eraldavast tasandist iga klassifikaatori puhul. Kõige suurema kauguse tagastanud klassifikaatori klass võidab [17] [20].

Teine levinud viis moodustada mitmeklassilisi tugivektormasinaid on kasutada 1 *versus* 1 meetodit (*max-wins voting* strateegia). Selle puhul jagatakse olemasolevad klassid kõikideks võimalikeks paarideks. Klasside arvu M korral on paaride arv $M(M-1)/2$. Seejärel konstrueeritakse iga sellise paari jaoks binaarne klassifikaator. Klassifikaatorit C_{ij} treenitakse elementidega, mis on võetud klassidest ω_i ja ω_j . Andes ette uue elemendi x , valib klassifikaator kummasse klassi see element kuuluda võiks ja annab vastavale klassile ühe hääle. Kui kõik $M(M-1)/2$ binaarset klassifikaatorit on oma hääled andnud, võidab see klass, mis sai enim hääli [20].

Käesolevas töös on kasutusel 1 *versus* 1 meetod mida nimetatakse paarikaupa ühendamiseks (*pairwise coupling*) [21]. Erinevus tavalisest 1 *versus* 1 meetodist on selles, et klassi hinnangu asemel tegeleb see meetod tõenäosuste kasutusega. Tõenäosused $p_i = P(\omega_i | x)$ kui $i=1, \dots, M$ genereeritakse kõigepealt kõigi 1 *versus* 1 meetodi klassifikaatorite vastustest. Seejärel ühendatakse need tõenäosused paarikaupa ühendamise meetodit kasutades. Võidab klass, millel on suurim tõenäosus.

Peatükk 3

Metoodika ja töövahendid

Järgnevas peatükis on välja toodud töö praktiliseks pooleks vajaminevad vahendid ja meetodid. Alustuseks on kirjeldatud andmete kogu, mille alusel kogu testimine toimus. Seejärel on kirjeldatud neid vahendeid, mida on kasutatud töö eesmärgi saavutamiseks. Peatüki viimases osas on ülevaade tunnustest, mis selle töö eesmärgil sai andmetest välja võetud.

3.1 Muusikakorpus

Üheks kõige tähtsamaks osaks töö juures oli koostatud muusikakorpus, sest kogu praktiline töö toimus selle põhjal. Korpuse koostamisel oli eesmärgiks valimisse lisatud laulude esinduslikkus ja stiiligruppide omavaheline tasakaal. Seega oli laulude valikul määrav osa.

Korpus sisaldas võrdset arvu lugusid kõigist valitud alastiilide gruppidest. Kokku oli 500 lugu, seega igast stiiligrupist 100. Koguhulgast 80% kasutati mudeli treenimiseks. Selleks kasutati ristvalideerimise meetodit (*cross validation*), mis jagas treeningkogumi kümneks osaks ning igas faasis kasutas üheksat osa sellest treenimiseks ja ühte osa kontrollimiseks. Mudeli testimiseks uute andmete peal kasutati eraldiseisvat testkogumit, mis moodustas tervest kogumist ülejäänud 20%.

Laulud valiti 160 esitaja repertuaarist. Seega oli keskmiselt kolm laulu esitaja kohta, et iga esitaja oma stiil oleks üldgrupis esindatud rohkem kui ühe lauluga. Seda peeti vajalikuks, sest igal esitajal on stiilidest oma nägemus ja ainult ühe laulu lisamisega võib jääda see nägemus liiga erandlikuks, et mudel seda oluliseks peaks.

Nimekiri ansamblitest koostati mitmeid erinevaid kriteeriume silmas pidades, et tulemus oleks mitmekülgsem. Esindatud olid nii nende stiilide algusaastate ansamblid kui ka tänapäevased esitajad. Samuti olid esindatud nende stiilide edukaimatel aegadel olnud ansamblid. Näiteks progressiivse roki puhul on enim ansambleid kuuekümnendatest ja seitsmekümnendatest aastatest. Samuti lisati nimekirja nende stiiligruppide kuulajate

arvates märkimist väärivad ansamblid. Selle valikul lähtus töö autor nii enda teadmistest kui ka vastavate muusikastiilide austajatest enda lähikonnas ja internetis. Lisaks leiti mitmed ansamblid plaadifirmade Inside Out Music (peamiselt progressiivne muusika), Century Media (igasugune rokkmuusika) ja Nuclear Blast (peamiselt *metal*-muusika) kaudu.

Ansambelite geograafiline mitmekesisus ei olnud eesmärgiks. Kõige rohkem muusikat on üldiselt nendest piirkondadest, kus valitud alastiilid alguse said. Üheks põhjuseks on see, et nendes piirkondades on selle stiili viljelemine kõige aktiivsem. Näiteks progressiivse muusika puhul oli enamus valikusse sattunud esitajaid Inglismaalt. Ekstreemmuusika puhul olid ülekaalus Ameerika ja Skandinaavia maade ansamblid. Põhjuseks oli jällegi see, et gruppi kuuluvad stiilid on nendest piirkondadest alguse saanud ja sealt tuleb siiani enim esitajaid. Eesti muusika jäi selle töö koostamisel vaatluse alt välja.

Kuna rokkmuusika on väga mitmekesine, alastiile on palju ning selget vahet nende vahel on raske teha, siis paigutatakse ka ansambleid üldjuhul väga mitmetesse kategooriatesse. Samuti ei ole võõras ka olukord, et ühe ansambli stiil muutub karjääri jooksul märkimisväärselt ning ka lood samas kogumikus võivad tegelikult olla erinevas stiilis. Seetõttu ei ole üheselt võimalik väita, et kõiki valitud alastiile on stiiligruppides võrdsel hulgal.

Enamasti jaotatakse laule aga stiilidesse nende esitajate üldiste siltide järgi. See tähendab, et laulud võivad saada märke stiili kohta, mis iseloomustab seda ansamblit või kogumikku üldiselt, aga mitte kõiki üksikuid laule. Seetõttu on stiiligruppidesse valitud lugude puhul jälgitud pigem nende lugude endi stiile, mitte ansambelite üldist stiili. See oli oluline juhul, kui ühele kogumikule või ansamblile oli omistatud mitmeid stiilmärkeid (kasutades erinevaid muusikat vahendavaid veebilehti), millest osa sobis ühte koostatud stiiligruppi ja osa teise. Sellisel juhul sai määravaks autori subjektiivne arvamus, millisesse stiiligruppi see laul paremini sobis. Seetõttu võis sama ansambel olla esindatud ka mitmes stiiligrupis. Lisa 3 sisaldab nimekirja kõigist töös kasutatud lauludest.

3.2 Töövahendid

Muusika klassifitseerimine toimus programmiga Weka v3.6.8 (Waikato Environment for Knowledge Analysis) [22]. See on vabavaraline masinõppe tarkvara, mida arendatakse

Waikato ülikoolis. Weka sisaldab paljusid masinõppe ja andmekaevega seotud algoritme, sealhulgas ka tugivektormasinaid. Programm on väga paindlik ja kõiki algoritme saab vastavalt vajadusele seadistada.

Weka kasutab tugivektormasinate algoritmina SMO (*Sequential Minimal Optimization*) implementatsiooni, mille autoriks on J. Platt [23]. See implementatsioon asendab automaatselt puuduvad väärtused ja normaliseerib andmed.

Lauludest tunnuste eraldamiseks kasutati programmi jAudio v1.0.4 [24]. See on vabavaraline programm, mille autoriteks on D. McEnnis ja C. McKay. See programm võimaldab lauludest eraldada suurt hulka tunnuseid ning salvestada need Weka ARFF formaati. Tunnuseid saab eraldada nii lühikeste lõikude kaupa kui ka üle terve failide. Selle töö eesmärgil eraldati tunnused üle tervikfailide.

Kõik muusikafailid konverteeriti MP3 formaadist WAV formaati, kasutades selleks programmi Free MP3 WMA Converter v2.1 [25]. See vabavaraline programm on välja töötatud Koyotesoft poolt, mis on paljude vabavaraliste audio ja video töötlemisega seotud programmide looja. Programm suudab töötada mitmete tuntud audiofailiformaatidega, kaasa arvatud MP3 ja WAV. Lood viidi üle 16kHz sãmplimissagedusele (*sampling rate*).

3.3 Tunnused

Parimaid tulemusi näidanud tunnuste kogum sisaldas 14 tunnust. See tunnuste kogum pandi kokku Weka vastavaid vahendeid kasutades. Kasutusel oli SVMAttributeEval tunnuste hindaja, mis põhineb I. Guyon, J. Weston, S. Barnhill ja V. Vapniku ideedel [26].

Kõik tunnused on arvatud üle terve muusikateose, et lauludes olevaid muutusi paremini hinnata. Näiteks progressiivse roki puhul oleks raske leida ühte lühikest lõiku, mis esindaks laulu kõige paremini, sest laulud on pikad ning koosnevad eri teemadest ja pikkadest instrumentaalsetest osadest. Samas on ka stiile, kus selliseid muutusi ja erinevusi on vähem (näiteks punkrokk). Lisa 1 sisaldab diagramme kõigi kasutatud tunnuste kohta, kust on võimalik võrrelda tunnuste väärtuste jaotumist klasside kaupa. Järgnevalt on kirjeldatud kõiki neid tunnuseid, mida töös kasutati.

Spektraalne kese (*spectral centroid*) on suurus, mis iseloomustab võimsusspektrit (*power spectrum*) ja näitab selle keskmist väärtust. Mida suurem on keskme väärtus, seda rohkem on signaalis kõrgemaid sagedusi [24]. Tunnusena on kasutusel spektraalse keskme keskmine väärtus.

Spektraalne üleminek (*spectral rolloff*) on suurus, mis iseloomustab võimsusspektri paremkaldelist asümmeetriat (*right-skewedness*). See näitab madalaimat sagedust, mille puhul kumulatiivne sageduste summa moodustab 85% kogu spektri sageduste summast. Seda kasutatakse kõne eristamiseks instrumentaalsest muusikast. Instrumentaalse muusika puhul on spektraalse ülemineku väärtus suurem, sest selle puhul jaotub energia ühtlasemalt [24] [27]. Tunnustena on kasutusel sellest üldine keskmine ja tuletis.

Spektraalvoog (*spectral flux*) on suurus, mis iseloomustab ulatusspektri (*magnitude spectrum*) muutumist. See arvutatakse analüüsiakende kaupa, võrreldes käesolevat akent sellele eelnevaga. See aitab samuti eristada kõne muusikast [24]. Tunnustena on kasutusel sellest üldine keskmine ja standardhälve.

Kompaktsus (*compactness*) on suurus, mis iseloomustab signaali mürataset. See leitakse võrreldes ühe akna ulatusspektrit selle kõrval olevate akende ulatusspektriga [24]. Tunnustena on kasutusel sellest üldine keskmine ja standardhälve.

Spektraalne varieeruvus (*spectral variability*) on suurus, mis iseloomustab kui palju signaali ulatusspekter muutub. See on spektri standardhälve [24]. Tunnustena on kasutusel üldine keskmine ja standardhälve.

Ruutkeskmine (*root mean square*) on suurus, mis iseloomustab signaali võimsust. See arvutatakse akende kaupa. Tulemuse arvutamiseks pannakse iga aknas olev väärtus ruutu, leitakse nendest väärtustest aritmeetiline keskmine ja võetakse sellest tulemusest ruutjuur. Tulemus on detsibellides [24] [28]. Tunnustena on kasutusel üldine keskmine ja standardhälve.

Madal energia (*fraction of low energy*) on suurus, mis iseloomustab signaalis oleva vaikuse hulka. Selle arvutamiseks võetakse 100 viimase ruutkeskmise akna keskmine

väärtus. Madal energia näitab, kui suur osa akende väärtustest jääb alla selle keskmise [24]. Tunnustena on kasutusel sellest tuletis ja standardhälve.

Nullkohtade ületus (*zero crossings*) on suurus, mis iseloomustab signaali mürasust. See on arv, mis näitab kui mitu korda signaal ületab või puutub null punkti [24]. Tunnustena on kasutusel sellest tuletis ja standardhälve.

Tugevaim tempo (*strongest beat*) leitakse rütmi diagrammist (*beat histogram*), mis esitab signaalis olevate erinevate regulaarsete rütmiliste mustrite tugevust. Diagrammist võetakse välja kõige suurema tugevusega tempo. Tulemus on löökides minuti kohta (*beats per minute*) [24]. Tunnustena on kasutusel sellest üldine keskmine ja tuletis.

Löökide summa (*beat sum*) on rütmide diagrammi kõikide väärtuste summa. See iseloomustab regulaarsete löökide ja rütmide tähtsust heliteoses [24]. Tunnustena on kasutusel sellest üldine keskmine ja standardhälve.

Tugevaim sagedus (*strongest frequency*) on suurus, mis näitab kõige tugevamat sagedust (hertsides). Neid leitakse nii spektraalse keskme, nullkohtade ületuse kui ka võimsusspektri kaudu [24]. Spektraalse keskme kaudu leitud tunnusest on üldine keskmine, nullkohtade ületuse kaudu leitud tunnusest on üldine keskmine ja tuletis ning võimsusspektri kaudu leitud tunnusest on üldine keskmine ja standardhälve.

Mel-sageduse kepstri kordajad (*Mel-frequency cepstral coefficients*) on spektri koondatud esitused, mis kasutavad Mel-skaalat (*mel scale*) ja viimane põhineb helikõrguste võrdlusel. Enim kasutatakse neid kepstri kordajaid kõnetuvastuses [29]. Tunnustena on kasutusel esimese viie kordaja kohta eraldi üldine keskmine ja standardhälve.

Momentide meetod (*method of moments*) on statistiline meetod, mis kirjeldab spektrograafi. Tunnustena on kasutusel esimesed viis statistilist momenti: ala (*area*), keskmine, võimsusspektri tihedus (*power spectrum density*), spektraalne kalle (*spectral scaw*) ja spektraalne järsakus (*spectral kurtosis*) [28]. Tunnustena on kasutusel nendest üldine keskmine ja standardhälve.

Lisatunnusena on kasutusel laulude **pikkus** sekundites.

Tulemused ja järeldused

Järgnevalt on kirjeldatud praktilise töö tulemusi. Esimeses ja teises osas on välja toodud tööks kasutatud tingimused ja seejärel saadud tulemuste analüüs ning järeldused. Tulemuste osa lõpus on välja toodud järelduste põhjal tekkinud ideed, kuidas tööd saaks edasi arendada.

4.1 Tulemuste analüüs

Algoritmi testiti rokkmuusika stiiligruppide peal. Järelduste tegemisel oli aluseks ainult kõige paremaid tulemusi näidanud tunnuste kogum. Mudeli treenimiseks kasutatud SVM-i nihkemuutuja jäeti vaikeväärtuse juurde ($1,0E-12$) ning konstandi C väärtuseid valiti 1 kuni 10. Suuremate C väärtuste puhul toimus mudeli ülesobitumine ja klassifitseerimise täpsus vähenes.

Parim klassifitseerimise tulemus oli 71,0%, mis saavutati, kui muutja C väärtuseks valiti 1. Segaduste maatriksist (*confusion matrix*, tabel 1) võib näha, et testkogumil saadud tulemus on üsna ühtlane. See tähendab, et ei ole stiilide gruppi, mille puhul klassifitseerimise tulemus oleks teistega võrreldes väga suuresti erinenud.

Tabel 1 Segaduste maatriks testkogumi tulemustest. Ridades on klassid, millesse lood kuulusid. Tulpades on klassid, kuhu mudel laulud klassifitseeris.

	Ekstr.	Metal	Rokk	Punk	Prog.
Ekstr.	15	5	0	0	0
Metal	1	14	2	2	1
Rokk	0	2	14	1	3
Punk	1	3	3	13	0
Prog.	0	1	2	2	15

Segaduste maatriksi põhjal koostatud segaduste tabelist (*table of confusion*, lisa 2) võib aga näha teistsuguseid tulemusi. Et need paremini näha oleksid, arvutati selle tabeli põhjal välja tundlikkus (*sensitivity*) ja spetsiifilisus (*specificity*) klasside kaupa (Tabel 2). Tundlikkus näitab, kui mitu protsenti uuritava sündmuse toimumisest ennustab mudel

õigesti. Spetsiifilisus näitab, kui mitu protsenti uuritava sündmuse mittetoimumisest ennustab mudel õigesti.

Tabel 2 põhjal on näha, et tegelikult on kõige paremini klassifitseeruvaks stiiligrupiks ekstreemmuusika. Seda nii seetõttu, et õigesti klassifitseeritud laulude hulk on 75,0%, kui ka seetõttu, et 97,5% olukordadest sai mudel aru, et tegemist ei ole selle klassiga. Põhjuseks on see, et ekstreemse *metal*-muusika klass on teistest oma olemuse ja helikeele poolest kõige rohkem eristuvam. Nendest tulemustest saab järeldada, et see stiiligrupp ei ole muusikalises mõttes laialivalguv ning seega eristub selgelt teistest stiiligruppidest.

Tabel 2 Mudeli tundlikkus ja spetsiifilisus testgrupi peal.

	Tundlikkus	Spetsiifilisus
Ekstr.	75,0 %	97,5 %
Metal	70,0 %	86,3 %
Rokk	70,0 %	91,3 %
Punk	65,0 %	93,8 %
Prog.	75,0 %	95,0 %

25,0% ekstreemmuusika lauludest klassifitseeriti valesti *metal*-muusika gruppi. See võib olla seotud sellega, et vanemad ansamblid, just *thrash* ja *groove* stiilidest, kõlavad oluliselt vähem agressiivselt võrreldes nii nende stiilide tänapäevaste esindajatega kui ka teiste ekstreemmuusika stiilidega. Seega on tulemused üsnagi ootuspärased.

Progressiivse roki tulemus on (ka tundlikkust ja spetsiifilisust vaadates) siiski üks parimaid. Nagu ka juba eelnevalt mainitud, tundis 75,0% kordadest mudel õigesti ära, et tegemist on progressiivse rokiga. Ekstreemmuusika tulemusest mõnevõrra madalam on spetsiifilisuse näitaja: 95,0% kordadest sai mudel õigesti aru, et tegemist ei ole progressiivse rokiga. Jällegi on tulemus ootuspärane, kuna progressiivne rokk on samuti üsna erinev teistest stiiligruppidest.

Need 25,0% lauludest, mis progressiivse roki puhul valesti klassifitseeriti, võivad tuleneda sellest, et mitmed ansamblid koondavad oma muusikas elemente *hard rock* ja *heavy metal* stiilidest. Siin on tegu stiilide ebamäärasuse probleemiga. Seda, miks osa lugusid pakuti punkroki alla, võib ilmselt selgitada sellega, et mudelil oli üldiselt kõige rohkem raskusi punkroki õigesti klassifitseerimisega.

Klassikalise roki grupi tulemused on ekstreemmuusika ja progressiivse roki omadest ka tundlikkust ja spetsiifilisust vaadates madalamad. Roki grupi puhul klassifitseeriti 70,0% lauludest õigesti ja 91,3% kordadest sai mudel õigesti aru, et tegemist ei ole roki grupi lauluga. Mudel klassifitseeris rokkmuusika laule valesti kõige rohkem progressiivse roki alla. Põhjus võib olla alternatiivrokis, sest enamuse laule, mis liigitatakse selle stiili alla, on vähem „raske“ kõlaga kui muu rokk. Elektrikitarrid on vaiksema kõlaga ning suhteliselt palju kasutatakse ka akustilist kitarr. Samuti liigitas mudel paar laulu roki grupi asemel *metal*-muusika gruppi. Selle põhjus võib olla *hard rock*, mis on oma kõlalt väga lähedane *metal*-muusika stiilidele ning mitmetel juhtudel ei ole võimalik üheselt väita, kummale poole need laulud rohkem sobivad.

Punkrokil oli kõige madalam klassifitseerimise tulemus: 65,0%. Mõnevõrra üllatav on aga see, et spetsiifilisus on parem kui rokkmuusika grupi puhul: 93,8%. See tähendab seda, et mudel ei suuda küll aru saada, kas punkroki laul sobib sellesse gruppi, aga saab paremini aru, kui mõne muu grupi laul sinna ei sobi. Kõige madalam klassifitseerimise tulemus punkroki puhul on ilmselt tingitud selle grupi suurematest sarnasustest roki ja *metal*-lauludele. Need laulud, mis klassifitseeriti roki gruppi, võivad olla seotud sellega, et punkroki grupis on ka *pop-punk* stiil, mis on lähedane alternatiivrokile. Need laulud, mis klassifitseeriti valesti *metal*-muusika gruppi, võivad olla seotud *post-hardcore* stiiliga, sest sellel stiilil on mõnevõrra suurem kiirus ja valjem basskitarr. Nendest tulemustest saab järeldada, et punkroki klassifitseerimiseks on vaja uut lähenemist kas siis teistsuguste tunnuste näol või koostada see stiiligrupp teiste põhimõtete alusel.

Mõnes mõttes kõige üllatavam tulemus on *metal*-laulude grupi puhul. Mudel klassifitseeris õigesti 70,0% lauludest, kuid samas spetsiifilisuse poolest oli *metal*-muusika grupp kõige madalama tulemusega. Ainult 86,3% laulude puhul sai mudel korrektselt aru, et tegemist ei ole üldise *metal*-muusika grupi kuuluvate lauludega. *Metal*-muusika grupp oli ainuke, mille puhul klassifitseeriti selle lugusid kõigisse ülejäänud gruppidesse. See oli ka ainus stiiligrupp, kuhu klassifitseeris mudel lugusid valesti kõigist ülejäänud gruppidest. *Metal*-muusika grupp on ka sellesse lisatud alastiilide hulga ning koosluse poolest üks suurimaid. Sellest võib järeldada, et antud grupp jääb muusikalises mõttes siiski veel liialt mitmekesiseks selle valitud muusikakorpuse suuruse kohta.

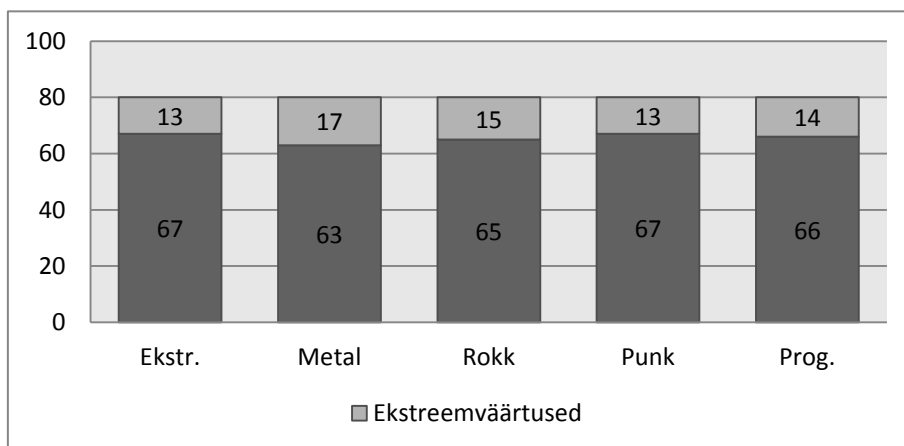
4.2 Kvartiilhaardega testide tulemuste analüüs

Sama tunnustegrupi testiti ka kvartiilhaaret (*interquartile range*) kasutades, mis näitas mõnevõrra paremat tulemust. Samas väga suurt klassifitseerimise täpsuse kasvu ei tulnud. Kvartiilhaardega juhul treeniti mudelit samadel tingimustel. Parim tulemus saavutati seegi kord C=1 puhul. Kvartiilhaarde ekstreemväärtuste (*extreme value*) kordaja E väärtused olid vahemikus 2 kuni 10. Võõrväärtuste (*outlier*) kordaja O jäi vahemikku 1 kuni 6. Parim tulemus saavutati kui E=4 ja O=10. Parimaks klassifitseerimise tulemuseks saavutati 74,0% täpsust. Selle tulemuse segaduste maatriks on välja toodud tabelis 3.

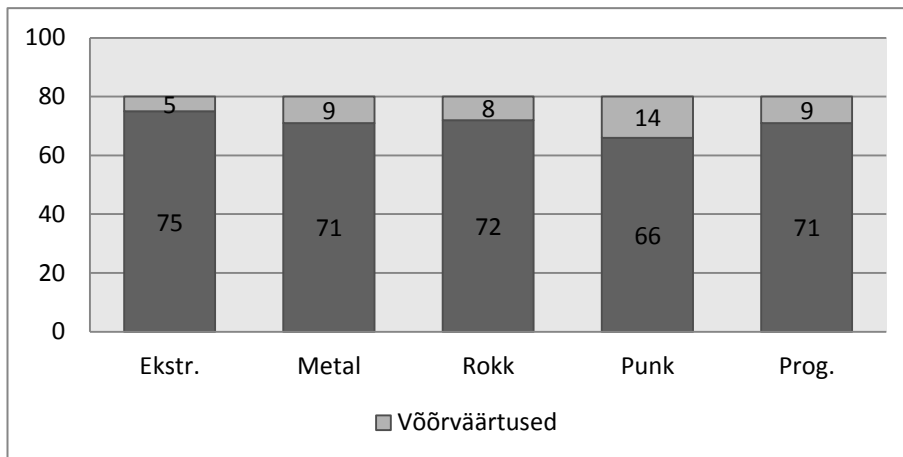
Tabel 3 Segaduste maatriks testkogumi tulemustest koos kvartiilhaardega. Ridades on klassid, millesse lood kuulusid. Tulpades on klassid, kuhu mudel laulud klassifitseeris.

	Ekstr.	Metal	Rokk	Punk	Prog.
Ekstr.	15	5	0	0	0
Metal	0	15	3	1	1
Rokk	1	1	15	1	2
Punk	1	2	3	14	0
Prog.	0	1	3	1	15

Ekstreemmuusika grupp oli ainus, mille puhul kvartiilhaarde kasutamine ei andnud võrreldes eelnevaga erinevat tulemust. Klassifitseerimise täpsus jäi 75,0% juurde ja ülejäänud 25,0% klassifitseeriti valesti *metal*-muusika gruppi. Järelikult on võõrväärtuste ja ekstreemväärtuste hulk piisavalt madal, et need ei muuda mudeli arusaamist klassist. Seda on näha ka jooniselt 3 ja jooniselt 4. Samuti leiab kinnitust eelnev järeldus, et see stiiligrupp ei ole muusikalises mõttes laialivalguv ja on selgelt teistest eristuv.



Joonis 3 Ekstreemväärtuste hulk treeningkogumis.



Joonis 4 Võõrväärtuste hulk treeningkogumis.

Progressiivse roki grupi puhul jäi klassifitseerimise täpsus samale tasemele – 75,0%. Segaduste maatriksi põhjal koostati ka nendest tulemustest segaduste tabel (Lisa 2) ning arvutati tundlikkus ja spetsiifilisus. Neid saab näha tabelis 4. Sealt selgub ka, et teiste stiiligruppide laule klassifitseeritakse progressiivse roki gruppi vähem. Eelneva 95,0% asemel on spetsiifilisuse tulemuseks 96,3%.

Tabel 4 Mudeli tundlikkus ja spetsiifilisus kvartiilhaardega testkogmi peal.

	Tundlikkus	Spetsiifilisus
Ekstr.	75,0 %	97,5 %
Metal	75,0 %	88,8 %
Rokk	75,0 %	88,8 %
Punk	70,0 %	96,3 %
Prog.	75,0 %	96,3 %

Klassikalise roki grupi puhul suurendas kvartiilhaarde kasutamine õigesti klassifitseeritud laulude hulka 5,0% võrra. Samas oli roki grupp ainus, mille puhul selle meetodi kasutamine alandas spetsiifilisuse näitu, mis langes 88,8%-le. See tähendab, et need laulud, mis osutusid testides ekstreem- ja võõrväärtusteks, olid siiski mõnevõrra olulised selle stiiligrupi eristamiseks. Järelikult on selle grupi kooslus samuti mõnevõrra laialivalguv.

Punkroki puhul tõusis klassifitseerimise täpsus võrreldes eelnevaga samuti 5,0%. Üldiselt jäi antud stiiligrupi klassifitseerimise täpsus siiski teistest madalamaks. Punkroki puhul oli aga kvartiilhaarde kasutamisel kõige suurem spetsiifilisuse kasv, milleks oli 2,5%. See võib tuleneda sellest, et punkroki grupis on kõige enam võõrväärtusi. Ekstreemväärtusi on küll teiste stiiligruppidega võrreldes vähem, kuid kokku tähendab see seda, et selle klassi

puhul on tunnuste väärtused üsna laiali. Sellele leiab kinnitust ka vaadates võõrväärtuste hulka treeningkogumis (Joonis 4). See on ilmselt ka põhjuseks, miks punkroki grupi klassifitseerimise täpsus jääb kõige madalamaks – seal on kõige rohkem laule, mis oma tunnuste poolest oluliselt erinevad teistest selles grupis olevatest lauludest. Selle järelaluseni jõuti ka eelnevalt kvartiilhaaret kasutamata.

Metal-muusika grupi puhul suurenes õigesti klassifitseerimiste hulk samuti 5,0% võrra võrreldes eelneva tulemusega. 88,8% kordadest sai mudel aru, et tegemist ei ole *metal*-grupi lauluga, mis on 2,5% parem tulemus kui varasem 86,3%. See tulemus aga jääb kõige madalamaks. Kuna *metal*-muusika grupis on kõige enam ekstreemväärtusi (Joonis 3) ja üsna palju võõrväärtusi, siis võib arvata, et seal on terveid alastiile, mis oma muusikaga ülejäänutest oluliselt erinevad. Sellest tulenevalt leiab varasem järelalus veekord kinnitust, et antud grupi muusikaline mitmekesisus on valitud muusikakorpuse suuruse kohta liialt suur.

4.3 Võimalused töö edasi arendamiseks

Nendest tulemustest võib järelalusda, et ekstreemse *metal*-muusika ja progressiivse rokkmuusika automaatne klassifitseerimine on kindlasti sellisel moel võimalik. Üldisemate stiiligruppide (*metal*-muusika ja rokk) ülesehitust võiks aga mõnevõrra muuta. Ideeks on alastiilide paigutamine täpsematesse gruppidesse, näiteks võiks eraldada selle osa *nu metal* stiilist, mis võtab elemente *rap metal* stiilist ning seejuures lisada töösse ka *rap metal* ise.

Punkroki automaatseks klassifitseerimiseks tuleks muuta tunnuste vektorit. Tuleks leida uusi tunnuseid, mis seda stiili paremini iseloomustaksid, sest kasutatud tunnused ei andnud eristamiseks piisavalt infot. Selle saavutamiseks võiks tunnuseid eraldada mitmete erinevate programmide ja vahenditega. Seda võiks teha põhjusel, et neis pakutavad võimalused on mõneti erinevad ja seega saaks koostada mitmekülgsema tunnuste vektori.

Töö andis autorile lisaks veel klassifitseerimise täpsuse parandamiseks ideid. Üheks neist võiks olla vähemalt mõnede tunnuste eraldamine väiksemate, neid laule iseloomustavate osadele tuginedes. Kindlasti võiks lisada ka mitte-lineaarsete tuumade kasutuse. Suuremaks ambitsiooniks võiks olla alastiilide klassifitseerimine kasutades peale rokkmuusika veel mitmeid teisi üldisi stiile samas süsteemis.

Kokkuvõte

Selles töös on kirjeldatud tugivektormasinate algoritmi katsetamist rokkmuusika korpuse peal, mis koostati spetsiaalselt selle töö raames. Eesmärgiks oli näha kui hästi ühe üldise stiili alastiilide automaatne klassifitseerimine töötab ning kas sellisel liigitamisel on edasist potentsiaali. Probleemi lahendamiseks kasutatud meetodite kõrvalt on tehtud ülevaade ka stiilide ja klassifitseerimisega seotud teooriast.

Selle töö eesmärgil koostatud muusikakorpus sisaldas viit alastiilide gruppi: ekstreemne *metal*-muusika, üldine *metal*-muusika, klassikaline rokkmuusika, progressiivne rokk ja punkrokk. Korpuse koostamine oli üks olulisematest ja seega ka üks aega nõudvamatest osadest.

Muusikakorpus jagati treening- ja testosaks. Alustuseks eraldati digitaalsel kujul olevast muusikast seda muusikat iseloomustavad tunnused. Seejärel rakendati tugivektormasinate treeningkogumil ning hinnati tulemusi testkogumil. Töö käigus tehti ka tunnustest valim, mis oli teiseks tähtsaimaks ning aeganõudvaimaks osaks. Tugivektormasinaid katsetati ainult lineaarse tuumaga ning erinevate C väärtustega. Lisaks oli kasutusel kvartiilhaare, et hinnata võõrväärtuste ja ekstreemväärtuste hulka ning näha nende mõju testi tulemustele.

Parimaks tulemuseks oli 71% klassifitseerimise täpsust. Kõigi stiiligruppide puhul jäi klassifitseerimise täpsus 65-75% vahele. Kõige paremini sai mudel hakkama ekstreemse *metal*-muusika ja progressiivse roki lauludega. *Metal*-muusika klassifitseerimise täpsus oli küll kõrge, aga mudel klassifitseeris teiste gruppide laule selle alla kõige enam. Punkroki puhul oli tulemus vastupidine – teiste stiiligruppide laule klassifitseeriti selle alla vähem, aga üldine klassifitseerimise täpsus oli kõige madalam. Kvartiilhaarde kasutamine ei andnud suurt täpsuse kasvu ning tulemuseks jäi 74%. Stiiligruppide kaupa jäi klassifitseerimise täpsus 70-75% vahele. Seega ei olnud andmehulgas liialt erineid ning need ei vähendanud oluliselt tugivektormasinate efektiivsuset.

Järeldusena võib öelda, et rokkmuusika alastiilide automaatne klassifitseerimine on kindlasti võimalik. Samuti on paremate tulemuste saavutamiseks potentsiaali. Selleks pakuti välja mitmeid ideid kuidas tööd edasi arenada.

Subgenre classification of rock music using support vector machines

Bachelor thesis

Elinor Toodo

Summary

Music industry is growing rapidly and the amount of music increases with great speed. Artists are looking for new ways to create music by exploring different techniques and incorporating different styles in their work. It becomes harder to find specific kind of music since the genres are expanding and subgenres are being created. Just saying one likes to listen to classical, electronic or rock music does not describe the music very well anymore. Music genre automatic classification in general deals with those global genres so there is a need for something more specific. The purpose of this work was to try to classify subgenres of rock music using support vector machines and to see how well this method works.

In this paper there is a brief overview of genres in general, characteristics of the chosen subgenres and short description of the ideas behind automatic classification and support vector machines. Besides the theoretical part there is also a description of the approach to the issue and an analysis of the achieved results.

For the purpose of this work a new dataset was constructed which consisted of five groups of rock music subgenres. The groups of subgenres were: extreme metal, general metal, progressive rock, punk rock and general rock. The classification accuracy of the constructed model was 71%. With the use of interquartile ranges the accuracy reached 74%. The model was most accurate with extreme metal and progressive rock groups while punk rock group had the least accurate classifications. Overall, the differences between classification accuracies of the sub-genre groups were still fairly small.

As a result of this work it can be said that classification of subgenres is more problematic than using global genres but still pretty good classification results can be achieved. Multiple ideas were proposed for future research to increase the classification accuracy.

Viidatud materjalid


- [1] Y. Yaslan, Z. Cataltepe, „Audio Music Genre Classification Using Different Classifiers and Feature Selection Methods,“ *18th International Conference on Pattern Recognition*, 2.2006, 573-376.
- [2] M.-L. Chu, „Automatic Music Genre Classification,“ National Taiwan University, 2010.
- [3] C. McKay, „Issues in Automatic Musical Genre Classification,“ *McGill Graduate Students Society Symposium*, 2004.
- [4] C. Ammer, „The Facts on File Dictionary of Music,“ 2004, 251-253 & 154.
- [5] F. Patchet, D. Cazaly, „A Taxonomy of Musical Genres,“ *Content-Based Multimedia Information Access Conference*, 2000.
- [6] D. Weinstein, „Heavy Metal: The Music and Its Culture“ 2000, 23-25.
- [7] „Extreme Metal - Wikipedia, the free encyclopedia,“ 2006.
http://en.wikipedia.org/wiki/Extreme_metal [Kasutatud 19.04.2013].
- [8] „Punk Rock - Wikipedia, the free encyclopedia,“ 2002.
http://en.wikipedia.org/wiki/Punk_rock [Kasutatud 19.04.2013].
- [9] „What is progressive rock?“ 2004.
<http://www.progarchives.com/Progressive-rock.asp>. [Kasutatud 17 04 2013].
- [10] Y. Kim, W. N. Street, F. Menczer, „Feature selection in Data Mining,“ *Data Mining: Opportunities and Challenges*, 2003, 80-105.
- [11] A. Semyonova, „Music Genre Detection Using The Naive Bayes Classifier,“ Tartu, 2009.
- [12] T. Li, M. Ogihara, „Towards Intelligent Music Information Retrieval,“ *IEEE Transactions on Multimedia*, 8.2006:3, 564-574
- [13] T. Lidy, R. Mayer, J. M. Inesta Quereda et al., „A Cartesian Ensemble of Feature Subspace Classifiers for Music Categorization,“ *11th International Society for Music Information Retrieval Conference*, 2010, 279-284.
- [14] M. Haggblade, Y. Hong, K. Kao, „Music Genre Classification,“ CS229, 2011.
- [15] S. B. Kotsiantis, „Supervised Machine Learning: A Review of Classification Techniques,“ University of Peloponnese, 2007.
- [16] L. Auria, R. A. Moro, „Support Vector Machines (SVM) as a technique for solvency analysis,“ German Institute for Economic Research, 2008.

- [17] M. Pal, „Multiclass Approaches for Support Vector Machine Based Land Cover Classification,“ *MapIndia 2005*, 2005.
- [18] K. C. West, „Novel Techniques for Audio Music Classification and Search,“ University of East Angalia, 2008.
- [19] T. Hastie, r. Tibshirani, J. Friedman, „Support Vector Machines and Flexible Discriminants,“ *The Elements of Statistical Learning*, 2009, 417-419.
- [20] K.-B. Duan, S. S. Keerethi, „Which Is the Best Multiclass SVM Method? An Empirical Study,“ *Multiple Classifier Systems*, 2005, 278-285.
- [21] T. Hastie, R. Tibshirani, „Classification By Pairwise Coupling,“ *Advances in Neural Information Processing Systems 10*, 1998, 507-513.
- [22] I. H. Witten, E. Frank, L Trigg et al., „Weka Practical Machine Learning Tools and Techniques With Java Implementation,“ 1999.
- [23] J. C. Platt, „Fast Training Of Support Vector Machines Using Sequential Minimal Optimization,“ *Advances in kernel method*, 1999, 185-208.
- [24] C. McKay, „jAudio: Towards a Standardized Extensible Audio Music Feature Extraction System,“ McGill University, 2005.
- [25] „Free MP3 WMA Converter,“ 2011.
<http://www.koyotesoft.com/audio-software/free-mp3-wma-converter.html>
 [Kasutatud 19 04 2013].
- [26] I. Guyon, V. Vapnik, J. Weston et al., „Gene Selection for Cancer Classification Using Support Vector Machines,“ *Machine Learning*, 46.2002:1-3, 389-422.
- [27] K. Tanghe, S. Degroeve, B. De Daets, „An Algorithm For Detecting And Labeling Drum Events In Polyphonic Music,“ *First Annual Music Information Retrieval Evaluation eXchange*, 2005.
- [28] D. McEnnis, C McKay, I. Fujinaga et al., „jAudio: A Feature Extraction Library,“ *6th International Conference on Music Information Retrieval*, 2005.
- [29] H. Subramanian, „Audio Signal Classification,“ *M.Tech Credit Seminar Report*, 2004.


Lisad

Lisa 1


Joonised tunnuste väärtuste jaotumisest




Joonis 5 Laulude pikkuste jaotumine treeningkogumis klasside kaupa.




Joonis 6 Spektraalkeskme keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 7 Spektraalse ülemineku keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 8 Spektraalse ülemineku tuletiste väärtuste jaotumine treeningkogumis.




Joonis 9 Spektraalvoo keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 10 Spektraalvoo standardhälbe väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 11 Kompaktsuse keskmise väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 12 Kompaktsuse standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.



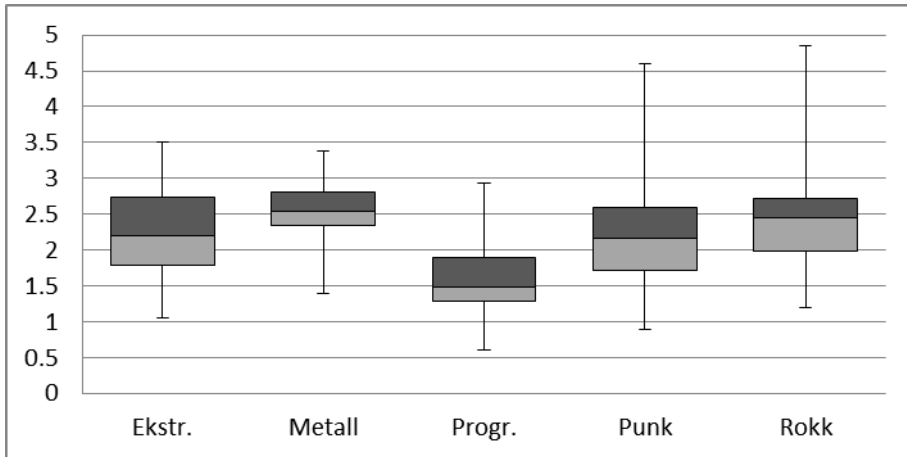
Joonis 13 Spektraalse varieeruvuse keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.



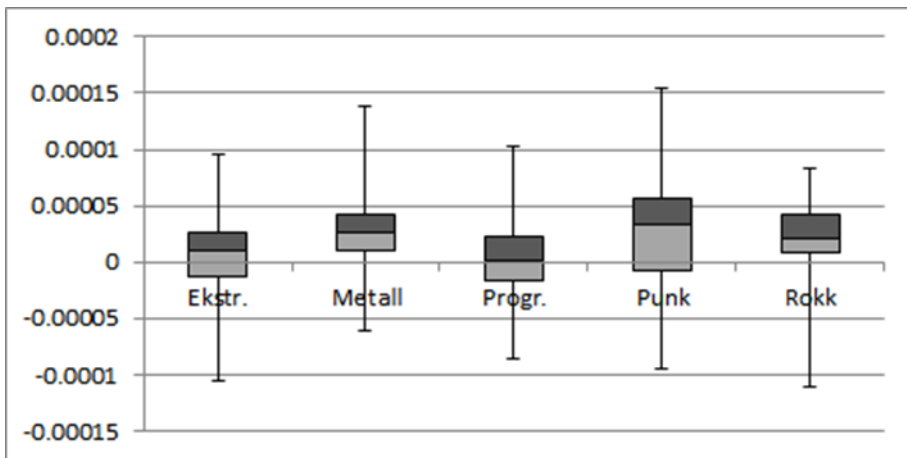
Joonis 14 Spektraalse varieeruvuse standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 15 Ruutkeskmiste keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 16 Ruutkeskmiste standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 17 Madala energia tuletiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 18 Madala energia standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 19 Nullkohtade üleminekute tuletiste väärtuste jaotumine treeningkogumis.




Joonis 20 Nullkohtade üleminekute standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 21 Tugevaimate löökide keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.



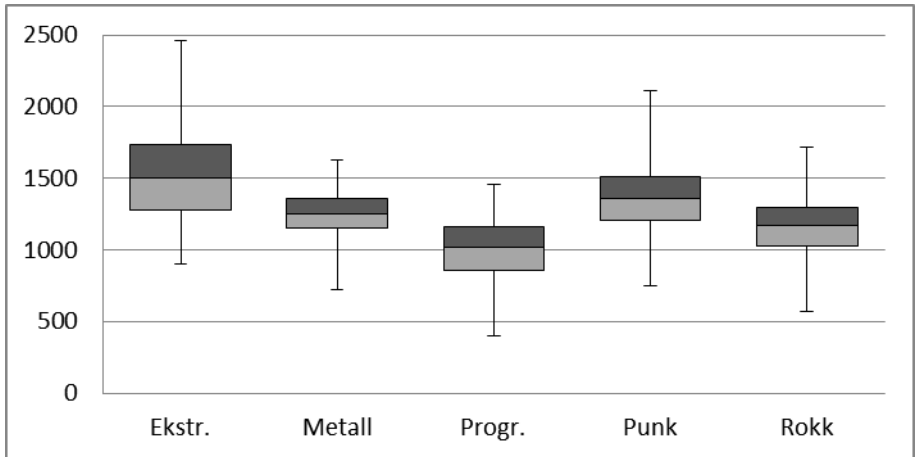
Joonis 22 Tugevaimate löökide tuletiste väärtuste jaotumine treeningkogumis.




Joonis 23 Löökide summa keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 24 Löökide summa standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 25 Nullkohtade ületuste kaudu saadud tugevaima sageduse keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 26 Nullkohtade ületuste kaudu saadud tugevaima sageduse tuletiste väärtuste jaotumine treeningkogumis.




Joonis 27 Spektraalkeskme kaudu saadud tugevaima sageduse keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 28 Võimsusspektri kaudu saadud tugevaima sageduse keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 29 Võimsusspektri kaudu saadud tugevaima sageduse standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 30 Mel-sageduse kepstri esimese kordaja keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 31 Mel-sageduse kepstri teise kordaja keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 32 Mel-sageduse kepstri kolmanda kordaja keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 33 Mel-sageduse kepstri neljanda kordaja keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 34 Mel-sageduse keptri viienda kordaja keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.



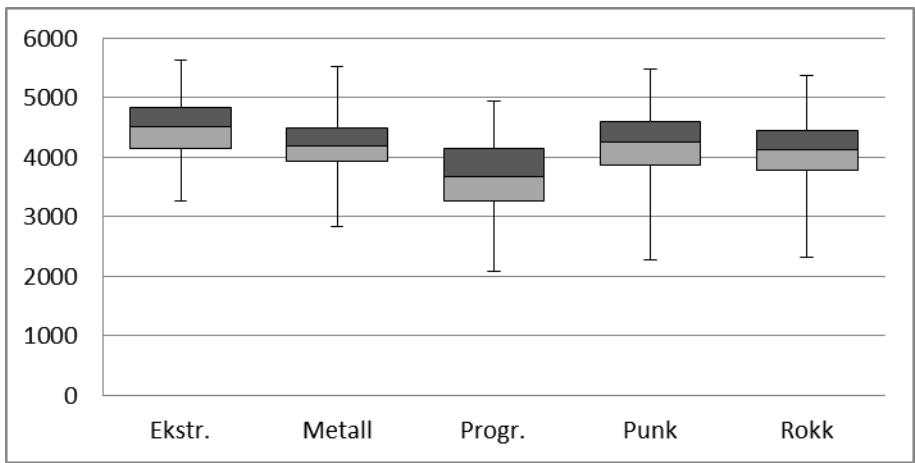
Joonis 35 Mel-sageduse keptri esimese kordaja standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 36 Momentide meetodi esimese momendi keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 37 Momentide meetodi teise momendi keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 38 Momentide meetodi kolmanda momendi keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 39 Momentide meetodi neljanda momendi keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 40 Momentide meetodi viienda momendi keskmiste väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 41 Momentide meetodi esimese momendi standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.




Joonis 42 Momentide meetodi teise momendi standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.



Joonis 43 Momentide meetodi kolmanda momendi standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.



Joonis 44 Momentide meetodi neljanda momendi standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.



Joonis 45 Momentide meetodi viienda momendi standardhälvete väärtuste jaotumine treeningkogumis klasside kaupa.

Lisa 2

Segaduste tabelid

Tabel 5 Testkogumi tulemuste segaduste tabel segaduste maatriksi alusel.

	Tõeselt positiivne	Tõeselt negatiivne	Vale-positiivne	Vale-negatiivne
Ekstr.	15	78	2	5
Metal	14	69	11	6
Rokk	14	73	7	6
Punk	13	75	5	7
Prog.	15	76	4	5

Tabel 6 Testkogumi kvartiilhaardega tulemuste segaduste tabel segaduste maatriksi alusel.

	Tõeselt positiivne	Tõeselt negatiivne	Vale-positiivne	Vale-negatiivne
Ekstr.	15	78	2	5
Metal	15	71	9	5
Rokk	15	71	9	5
Punk	14	77	3	6
Prog.	15	77	3	5

Lisa 3

Muusika nimekiri

Laulud on jagatud vastavatesse stiiligruppidesse ja järjestatud pealkirjade jägi. Pealkirjade järel on (viimastes) sulgudes esitaja nimi.

Ekstreem-metal laulude grupp

1. 666 Voices Inside (Dark Funeral)
2. Adjusting The Sun (Hypocrisy)
3. Aesthetics Of Hate (Machine Head)
4. All Hope Is Gone (Slipknot)
5. All Shall Fall (Immortal)
6. Ancient Skin (Mayhem)
7. Angel Of Death (Slayer)
8. Antichrist (Venom)
9. Arctic Swarm (Immortal)
10. Arise (Sepultura)
11. As Tyrants Fall (Fleshgod Apocalypse)
12. Battery (Metallica)
13. Becoming (Pantera)
14. Behind Silence And Solitude (All That Remains)
15. Blacken The Cursed Sun (Lamb Of God)
16. Bleed (Meshuggah)
17. Blessed Dead (Venom)

18. Blood And Confusion (Cadaveria)
19. Blood For Blood (Machine Head)
20. Coffin Fodder (Cradle Of Filth)
21. Corporal Jigsore Quandary (Carcass)
22. Crown Of Horns (Cryptopsy)
23. Cry My Name (Bloodbath)
24. Cry Of The Black Birds (Amon Amarth)
25. Dead But Dreaming (Deicide)
26. Dead Eternity (In Flames)
27. Death In Fire (Amon Amarth)
28. Death Metal (Possessed)
29. Denial Of Life (Death)
30. Disciple (Slayer)
31. Disposable Heroes (Metallica)
32. Divided We Stand (Darkthrone)
33. Eaten (Bloodbath)
34. Fall From Grace (Morbid Angel)
35. Fallen Angel (Possessed)
36. Follow (All That Remains)
37. Food For The Gods (In Flames)
38. Fucking Hostile (Pantera)
39. Funeral Fog (Mayhem)
40. Future Breed Machine (Meshuggah)
41. Gematria (The Killing Name) (Slipknot)
42. Gilded Cunt (Cradle Of Filth)
43. Hades Rising (Bloodbath)
44. Hammer Smashed Face (Cannibal Corpse)
45. Heart Of Ice (Dark Funeral)
46. Heartwork (Carcass)
47. Holy Wars... The Punishment Due
(Megadeth)
48. Homo Sum (Decapitated)
49. I Will Kill You (Cannibal Corpse)
50. Illuminati (Kataklysm)
51. Immortal Rites (Morbid Angel)
52. Imperium (Machine Head)
53. In The Kingdom Where Everything Dies, The
Sky Is Mortal (Cryptopsy)
54. Incarnated Solvent Abuse (Carcass)
55. Iron Will (Kataklysm)
56. Ithyphallic (Nile)
57. Jesus Dod (Burzum)
58. Killing Is My Business... And Business Is Good
(Megadeth)
59. Lack Of Comprehension (Death)
60. Left To Rot (Hypocrisy)
61. Lost Wisdom (Burzum)
62. Maddening Disdain (Arsis)
63. Make Them Suffer (Cannibal Corpse)
64. Master Of Puppets (Metallica)
65. My Funeral (Dark Funeral)
66. Nemesis (Venom)
67. Noctambulant (Immortal)
68. Post Organic (Decapitated)
69. Progenies Of The Great Apocalypse (Dimmu
Borgir)
70. Quintessence (Darkthrone)
71. Raining Blood (Slayer)
72. Rapture (Morbid Angel)
73. Redneck (Lamb Of God)
74. Refuse-Resist (Sepultura)
75. Regurgitated Guts (Death)
76. Retrieving My Carcass (Fleshgod Apocalypse)
77. Roots Bloody Roots (Sepultura)
78. Sickening (Meshuggah)
79. Spell (Cadaveria)
80. Stien (Dimmu Borgir)
81. Stormblast (Dimmu Borgir)
82. Taking The World By Storm (Kataklysm)
83. The Empty Throne (Decapitated)
84. The Exorcist (Possessed)
85. The Face Of My Innocence (Arsis)
86. The Magic Rebirth (Cadaveria)
87. The Violation (Fleshgod Apocalypse)
88. The Watchtower (Darkthrone)
89. This Cold Black (Slipknot)

90. This Darkened Heart (All That Remains)
91. To Hell With God (Deicide)
92. Twilight Of The Thunder God (Amon Amarth)
93. Two-Pound Torch (Cryptopsy)
94. Unas Slayer Of The Gods (Nile)
95. User Maat Re (Nile)
96. Walk With Me In Hell (Lamb Of God)
97. War (Burzum)
98. War (Hypocrisy)
99. We Are The Nightmare (Arsis)
100. Worthless Misery (Deicide)

Üldine metal-muusika grupp

1. Affliction (Sonic Syndicate)
2. Afterlife (Avenged Sevenfold)
3. All Your Hate (Black Veil Brides)
4. Amerika (Rammstein)
5. Any Means Necessary (Hammerfall)
6. Asking Too Much (All That Remains)
7. Benzin (Rammstein)
8. Bodies (Drowning Pool)
9. Brackish (Kittie)
10. Bring Me To Life (Evanescence)
11. Broken Home (Papa Roach)
12. Charlotte (Kittie)
13. Coat Of Arms (Sabaton)
14. Coming Down (Five Finger Death Punch)
15. Coming Undone (Korn)
16. Critical Acclaim (Avenged Sevenfold)
17. Cross My Heart (Sentenced)
18. Defenders Of The Faith (Judas Priest)
19. Deliver Us (In Flames)
20. Denied (Sonic Syndicate)
21. Diary Of Jane (Breaking Benjamin)
22. Down With The Sickness (Disturbed)
23. Drown Together (Sentenced)
24. Duality (Slipknot)
25. Everybodys Fool (Evanescence)

26. Exile (Tristania)
27. Fear Is The Weakness (In Flames)
28. Fragile (Lacuna Coil)
29. From The Inside (Linkin Park)
30. Gehenna (Slipknot)
31. Going Under (Evanescence)
32. Halo (Soil)
33. Hard To See (Five Finger Death Punch)
34. Hatelove (Poisonblack)
35. Here It Comes Again (Korn)
36. I Will Not Bow (Breaking Benjamin)
37. Iceheart Fragment (The Unguided)
38. I'm Alive (Disturbed)
39. I'm Not Jesus (Apocalyptica Ft Corey Taylor)
40. Inherit The Earth (The Unguided)
41. Invincible (Static-X)
42. Judas Rising (Judas Priest)
43. Karma (Sevendust)
44. Kill The Light (Lacuna Coil)
45. Killin' Me (Drowning Pool)
46. Killing Me Killing You (Sentenced)
47. Last Resort (Papa Roach)
48. Left Behind (Slipknot)
49. Lost In Forever (P.O.D.)
50. Love Infernal (Poisonblack)
51. Lying From You (Linkin Park)
52. Nowhere (Sevendust)
53. Obsession (Soil)
54. One More Time (Hammerfall)
55. One Step Closer (Linkin Park)
56. Paperdoll (Kittie)
57. Parasite (Disturbed)
58. Path Vol2 (Apocalyptica Ft Sandra Nasic)
59. Perfect Weapon (Black Veil Brides)
60. Polyamorous (Breaking Benjamin)
61. Power Shift (Sonic Syndicate)
62. Primo Victoria (Sabaton)
63. Protection (Tristania)

64. Rebel Inside (Hammerfall)
65. Rebel Love Song (Black Veil Brides)
66. Redefine (Soil)
67. Rein Raus (Rammstein)
68. Revolution (Judas Priest)
69. Rush (Poisonblack)
70. S.O.S. (Apocalyptica Ft Christina Scabbia)
71. Sanguine Sky (Tristania)
72. See Who I Am (Within Temptation)
73. Shadow Zone (Static-X)
74. She Is My Sin (Nightwish)
75. Slaying The Dreamer (Nightwish)
76. Sleeping Awake (P.O.D.)
77. Sounds Of A Playground Fading (In Flames)
78. St. Anger (Metallica)
79. Stand My Ground (Within Temptation)
80. Step Up (Drowning Pool)
81. Swamped (Lacuna Coil)
82. The End Is Coming (Sevendust)
83. The God That Failed (Metallica)
84. The Only (Static-X)
85. The Pride (Five Finger Death Punch)
86. The Waiting One (All That Remains)
87. Throw Me Away (Korn)
88. Time And Time Again (Papa Roach)
89. Two Weeks (All That Remains)
90. Unbound (The Wild Ride) (Avenged Sevenfold)
91. Watch Us Die (Macbeth)
92. Where Is The Edge (Within Temptation)
93. Where The Dead Ships Dwell (In Flames)
94. Where The Frost Rose Withers (The Unguided)
95. Whoever Brings The Night (Nightwish)
96. Will You (P.O.D.)
97. Wish I Had An Angel (Nightwish)
98. Wiskey In The Jar (Metallica)
99. Without You (Macbeth)

100. Wolfpack (Sabaton)

Progressiivse roki grupp

1. 10000 Days (Pt 2) (Tool)
2. 10000 Days (Saga)
3. A Boy's Life (Camel)
4. All Is Not Equal (Jadis)
5. All That's Left (Spock's Beard)
6. Aspirations (Gentle Giant)
7. Better Days (Emerson, Lake & Palmer)
8. Bird Of Prey (Uriah Heep)
9. Black Moon (Emerson, Lake & Palmer)
10. Blue Planet (The Flower Kings)
11. Close To The Edge (Part One) (Yes)
12. Cold Fire (Rush)
13. Come Back To Me (Ayreon)
14. Deep Inside (Sylvan)
15. Down And Out In Paris And London (The Tangent)
16. Edge Of The In-Between (Spock's Beard)
17. EFM (The Tangent)
18. Eleven (Pain F Salvation)
19. Endlessly (Von Hertzen Brothers)
20. Experience (Gentle Giant)
21. Fearless (Pink Floyd)
22. Fly From Here Part III (Yes)
23. For Today (Camel)
24. Force Of Gravity (Sylvan)
25. Four Chords That Made A Million (Porcupine Tree)
26. Freedom Fighter (Von Hertzen Brothers)
27. Given Away (Iluvatar)
28. Gypsy (Uriah Heep)
29. Happiness Is The Road (Marillion)
30. Haze (Iluvatar)
31. Heaven In My Heart (Neal Morse)
32. Heavy Horses (Jethro Tull)
33. Here I Am (Unitopia)

34. If Only You Knew (Yes)
35. In My Time Of Need (Opeth)
36. In The End (Von Herten Brothers)
37. In The Wake Of Poseidon (King Crimson)
38. Inside The Power (Unitopia)
39. Karn Evil 9 (Emerson, Lake & Palmer)
40. Kayleigh (Marillion)
41. Lady In Black (Uriah Heep)
42. Lifeline (Saga)
43. Mad Man Moon (Genesis)
44. More Than A Dream (Unitopia)
45. My Friend (Saga)
46. Never Ending Night (Arena)
47. Never Let Go (Camel)
48. No Way (Pain Of Salvation)
49. One For The Vine (Genesis)
50. One Last Au Revoir (Arena)
51. Pane Of Truth (Sylvan)
52. Peel The Paint (Gentle Giant)
53. People (King Crimson)
54. Power (Marillion)
55. Prints In The Stone (Mostly Autumn)
56. Pure Narcotic (Porcupine Tree)
57. Red Barchetta (Rush)
58. Road In My Mind (Kaipa)
59. Road Salt Two (Pain Of Salvation)
60. Saline (Frost*)
61. Set The Kingdom (Neal Morse)
62. Shining Star (Spock's Beard)
63. Shout (Camel)
64. Since We've Been Wrong (The Mars Volta)
65. Song For Tomorrow (Panic Room)
66. Sounds That Can't Be Made (Marillion)
67. Starless (King Crimson)
68. Storms Over Still Water (Mostly Autumn)
69. Summer '68 (Pink Floyd)
70. Tantalus (Arena)
71. Telegraph Road (Dire Straits)
72. The Beginning And The End (Jadis)
73. The Company Car (The Tangent)
74. The Court Of The Crimson King (King Crimson)
75. The Dark Before The Dawn (Mostly Autumn)
76. The Fleeting Existence Of Time (Kaipa)
77. The Garden Part 2 (Unitopia)
78. The Perfect Element (Pain F Salvation)
79. The Pot (Tool)
80. The Solution (Yes)
81. The Trees (Rush)
82. Thela Hun Ginjeet (King Crimson)
83. Thick As A Brick (Jethro Tull)
84. Tightrope Walking (Panic Room)
85. Time (Pink Floyd)
86. Time Flies (Porcupine Tree)
87. To Rid The Disease (Opeth)
88. Touch (Jadis)
89. Trading My Soul (The Flower Kings)
90. Turn The Stone (The Flower Kings)
91. Upon The Door (Neal Morse)
92. Watcher Of The Skies (Genesis)
93. Welcome To Nowhere (Frost*)
94. What Do You Want From Me (Pink Floyd)
95. What Goes Around (Jadis)
96. What If (Arena)
97. Where's The Captain (Kaipa)
98. Windowpane (Opeth)
99. Wonderland (Frost*)
100. Your Darkest Hour (Iluvatar)

Punkroki grupp

1. (I'm) Stranded (The Saints)
2. A Praise Chorus (Jimmy Eat World)
3. Anarchy In The Uk (Sex Pistols)
4. Angels With Dirty Faces (Sham 69)
5. As One (Dropkick Murphys)
6. Below The Drop (The Effigies)

7. Big Apple Heartbreak (Yellowcard)
8. Blitzkrieg Bop (The Ramones)
9. Bloodstains (Agent Orange)
10. Blue Funk (The Effigies)
11. Born Frustrated (Rancid)
12. Bro Hymn (Pennywise)
13. Call Me (Blondie)
14. Caveman (Jimmy Eat World)
15. Come Out And Play (The Offspring)
16. Complete Control (The Clash)
17. Corruption (Rancid)
18. Creatures (Adolescents)
19. Damclub Hooligan (Heideroosjes)
20. Dammit (Blink 182)
21. Dance Dance (Fall Out Boy)
22. Dead On Arrival (Fall Out Boy)
23. Disconnect (Pennywise)
24. Don't Take Me For Granted (Social Distortion)
25. Down With The Ship (Nofx)
26. Everything Sux (Descendents)
27. Everything Turns Grey (Agent Orange)
28. First Date (Blink 182)
29. Forming (The Germs)
30. Girlfriend (Avril Lavigne)
31. Give It All (Rise Against)
32. God Save The Queen (Sex Pistols)
33. Headfirst For Halos (My Chemical Romance)
34. Heart Attack (Sum 41)
35. Help Is On The Way (Rise Against)
36. Hey Little Rich Boy (Sham 69)
37. Holiday In The Sun (Sex Pistols)
38. I Just Want To Have Something To Do (The Ramones)
39. I Wanna Be Sedated (The Ramones)
40. I Wanna Be Your Dog (The Stooges)
41. I Write Sins, Not Tragedies (Panic! At The Disco)
42. Iedereen Is Gek! (Heideroosjes)
43. I'm The One (Descendents)
44. In My Eyes (Minor Threat)
45. Inspiration (Adolescents)
46. Jesus Of Suburbia (Green Day)
47. Just One More Day (Pennywise)
48. Kids Of The Black Hole (Adolescents)
49. Legend Of Finn McMumhail (Dropkick Murphys)
50. Lekker Belangrijk (Heideroosjes)
51. Lexicon Devil (The Germs)
52. Lifestyles Of The Rich And Famous (Good Charlotte)
53. Light Up The Sky (Yellowcard)
54. London Calling (The Clash)
55. Los Angeles Is Burning (Bad Religion)
56. Love Song (The Damned)
57. Margin Walker (Fugazi)
58. Merchandise (Fugazi)
59. Million Miles Away (The Offspring)
60. Minority (Green Day)
61. Misery Business (Paramore)
62. Never Alone (Dropkick Murphys)
63. New Rose (The Damned)
64. No Fun (The Stooges)
65. Nothing With You (Descendents)
66. Ocean Avenue (Yellowcard)
67. One More Day (Descendents)
68. One Way Or Another (Blondie)
69. Panik (Metal Urbain)
70. Paris Maquis (Metal Urbain)
71. Pressure (Paramore)
72. Reach For The Sky (Social Distortion)
73. Ring Of Fire (Social Distortion)
74. Ruby Soho (Rancid)
75. Satellite (Rise Against)
76. Saturday (Fall Out Boy)
77. Search And Destroy (The Stooges)

78. Security (The Effigies)
79. Seek & Destroy (Agent Orange)
80. Should I Stay Or Should I Go (The Clash)
81. Skin And Bone (Sham 69)
82. Smash It Up (The Damned)
83. Sorrow (Bad Religion)
84. Still Waiting (Sum 41)
85. Stuck With Me (Green Day)
86. Suits And Ladders (Nofx)
87. Teenagers (My Chemical Romance)
88. The Anthem (Good Charlotte)
89. The Chronicles Of Life And Death (Good Charlotte)
90. The Irrationality Of Rationality (Nofx)
91. The Quitter (Nofx)
92. The Rock Show (Blink 182)
93. Time Bomb (Rancid)
94. Waiting Room (Fugazi)
95. Walking Disaster (Sum 41)
96. Want You Bad (The Offspring)
97. We Must Bleed (The Germs)
98. What's My Age Again (Blink 182)
99. Wurst & Käse (Heideroosjes)
100. X Offender (Blondie)
13. Burning Bright (Shinedown)
14. By The Way (Red Hot Chili Peppers)
15. Californication (Red Hot Chili Peppers)
16. Casual Sex (My Darkest Days)
17. Comes And Goes (Default)
18. Crashed (Daughtry)
19. Don't Cry (Guns N' Roses)
20. Double Or Nothing (Nine Lashes)
21. Downfall (Matchbox Twenty)
22. Everybody Hurts (REM)
23. Everything Changes (Staind)
24. Fake It (Seether)
25. Falls On Me (Fuel)
26. Far Away (Nickelback)
27. Far From Home (Five Finger Death Punch)
28. Forgiven (Skillet)
29. Given To Fly (Pearl Jam)
30. Halfway Gone (Lifehouse)
31. Hangin' Around (Fuel)
32. Heaven Beside You (Alice In Chains)
33. Here And Now (Seether)
34. Here Without You (3 Doors Down)
35. Higher (Creed)
36. I Don't Wanna Miss A Thing (Aerosmith)
37. I Will Be There (Art Of Dying)
38. If Everyone Cared (Nickelback)
39. If Only (Hoobastank)
40. If Only You Knew (Shinedown)
41. In My Head (Queens Of The Stone Age)
42. It Only Hurts (Default)
43. Janie'S Got A Gun (Aerosmith)
44. Just Like You (Three Days Grace)
45. Life Wasted (Pearl Jam)
46. Lips Of An Angel (Hinder)
47. Long Day (Matchbox Twenty)
48. Losing My Religion (REM)
49. Lost In The Sun (Hinder)
50. Lost In You (Three Days Grace)

Klassikalise roki grupp

1. Afterglow (Nine Lashes)
2. Alive (Pearl Jam)
3. All Apologies (Nirvana)
4. All Or Nothing (Theory Of A Deadman)
5. Angels Take A Soul (Fuel)
6. Away In Silence (Creed)
7. Bad Girlfriend (Theory Of A Deadman)
8. Believe (Staind)
9. Best Of You (Foo Fighters)
10. Breaking Inside (Shinedown)
11. Broken (Lifehouse)
12. Broken Wings (Alter Bridge)

51. Lucy (Skillet)
53. No One Knows (Queens Of The Stone Age)
54. Oh What A Night (Guano Apes)
55. One Day Too Late (Skillet)
56. One In A Million (Guns N' Roses)
57. Open Your Eyes (Alter Bridge)
58. Over You (Daughtry)
59. Porn Star Dancing (My Darkest Days)
60. Push With Lyrics (Matchbox Twenty)
61. Rain (Creed)
62. Raining (Art Of Dying)
63. Raining Again (Staind)
64. Renegade (Daughtry)
65. Roadside (Rise Against)
66. Same Direction (Hoobastank)
67. Show Me (Default)
68. Sky Is Falling (Lifehouse)
69. Smells Like Teen Spirit (Nirvana)
70. Snuff (Slipknot)
71. So Happy (Theory Of A Deadman)
72. So I Need You (3 Doors Down)
73. Someone Who Cares (Three Days Grace)
74. Sorry (Art Of Dying)
75. Speed Of Sound (Coldplay)
76. Street Of Dreams (Guns N' Roses)
77. Sunday Lover (Guano Apes)
78. Swing Life Away (Rise Against)
79. The Gift (Seether)
80. The One I Love (REM)
81. The Past (Sevendust)
82. The Reason (Hoobastank)
83. The Void (Nine Lashes)
84. These Days (Foo Fighters)
85. This Life (Sevendust)
86. This Time (Guano Apes)
87. Too Bad (Nickelback)
88. Violet Hill (Coldplay)
89. Wait For Me (Rise Against)
52. My Friends (Red Hot Chili Peppers)
90. Walk Away (Five Finger Death Punch)
91. Walking After You (Foo Fighters)
92. Watch Over You (Alter Bridge)
93. What It Is To Burn (Finch)
94. What It Takes (Aerosmith)
95. When You'Re Young (3 Doors Down)
96. Without You (Hinder)
97. Without You (My Darkest Days)
98. Would (Alice In Chains)
99. You Know You'Re Right (Nirvana)
100. Your Decision (Alice In Chains)

Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks

Mina _____ Elinor Toodo _____
(*autori nimi*)

(sünnikuupäev: _____ 04.02.1989 _____)

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) enda loodud teose
_____ Rokkmuusika alastiilide klassifitseerimine tugivektormasinatega _____

(*lõputöö pealkiri*)

mille juhendaja on _____ Sven Aller, Margus Niitsoo _____,
(*juhendaja nimi*)

- 1.1. reprodutseerimiseks säilitamise ja üldsusele kättesaadavaks tegemise eesmärgil, sealhulgas digitaalarhiivi DSpace-is lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;
 - 1.2. üldsusele kättesaadavaks tegemiseks Tartu Ülikooli veebikeskkonna kaudu, sealhulgas digitaalarhiivi DSpace'i kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.
2. olen teadlik, et punktis 1 nimetatud õigused jäävad alles ka autorile.
 3. kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest tulenevaid õigusi.

Tartus/~~Tallinnas~~/~~Narvas~~/~~Pärnus~~/~~Viljandis~~, ____ 13.05.2013 _____ (kuupäev)