

TARTU ÜLIKOOL  
Arvutiteaduse instituut  
Informaatika õppekava

**Regita Luukas**  
**Tartu Ülikooli õppeainete tagasiside**  
**meelsusanalüüs**  
**Bakalaureusetöö (9 EAP)**

Juhendaja: Sven Aller, MSc

Tartu 2023

## **Tartu Ülikooli õppeainete tagasiside meelsusanalüüs**

### **Lühikokkuvõte:**

Lõputöö peamine eesmärk on luua algoritm meelsuse analüüsimiseks Tartu Ülikooli õppeinfosüsteemis (ÕIS) tudengite poolt jäetaval tagasisidel, seda rakendada ning täpsust hinnata. Töös antakse ülevaade meelsusanalüüsi vajalikkusest ja kasutusest, analüüsi meetoditest, probleemidest ning seni Eestis tehtud töödest. Lisaks tutvustatakse selles töös meelsusanalüüsi tegemiseks kasutatud töövahendeid. Viimaks kirjeldatakse lähemalt kasutuses olevaid andmeid, kasutatud meetodeid ning analüüsitakse saadud tulemusi.

### **Võtmesõnad:**

meelsusanalüüs, loomuliku keele töötlus, leksikonipõhine meetod, õppeainete tagasiside

### **CERCS:**

P170 Arvutiteadus, arvutusmeetodid, süsteemid, juhtimine (automaatjuhtimisteooria)

## **Sentiment analysis of feedback on subjects at the University of Tartu**

### **Abstract:**

The main objective of this thesis is to create a sentiment analysis algorithm for the feedback written by students in the study information system (ÕIS) of the University of Tartu, to implement it and evaluate its accuracy. The paper provides an overview of the necessity and use of sentiment analysis, analysis methods, problems and the work done in Estonia so far. In addition, the main tools used for sentiment analysis are introduced. Finally, the datasets, the methods used, and the results are analyzed in more detail.

### **Keywords:**

sentiment analysis, natural language processing, lexicon-based approach, courses' feedback

### **CERCS:**

P170 Computer science, numerical analysis, systems, control

## Sisukord

Sissejuhatus.....	4
1. Meelsusanalüüs.....	5
1.1 Tähtsus ja kasutusvaldkonnad.....	5
1.2 Meetodid.....	6
1.3 Peamised probleemid.....	7
1.4 Meelsusanalüüs Eestis.....	8
1.4.1 Varem tehtud tööd.....	9
2. Kasutatud tehnoloogilised vahendid.....	11
2.1 Python.....	11
2.2 EstNLTK.....	11
2.3 NumPy ja Pandas.....	12
3. Üliõpilaste tagasiside analüüs.....	13
3.1 Andmed.....	13
3.1.1 Tagasisidekorpus.....	13
3.1.2 Valentsisõnastik.....	14
3.2 Meetodi ja algoritmi kirjeldus.....	14
3.3 Analüüs.....	16
3.3.1 Soovituste ja kirjelduste eraldamise tulemused.....	16
3.3.2 Meelusanalüüsi tulemused.....	17
3.4 Edasiarendamise võimalused.....	19
Kokkuvõte.....	21
Viidatud kirjandus.....	22
Lisad.....	24
I. Litsents.....	24

## Sissejuhatus

Iga inimene omab arvamust erisuguste eluvaldkondade, inimeste või muude objektide kohta, mida ka teksti või kõne kaudu teistele edastatakse. Sellised arvamused võivad olla nii positiivse, negatiivse kui ka neutraalse hoiakuga. Meelsusanalüüs ehk hoiakute analüüs, sentimentaalne analüüs või ka arvamuskäve on valdkond, mis ühendab endas arvutiteadust ja lingvistikat, et automatiseerida meelsust sisaldavate tekstide analüüsimist [1]. Sellel sajandil aina populaarsust koguv ala on heaks vahendiks internetis leiduvate arvamusalalduste kohta kokkuvõtete tegemiseks ja inimeste seisukohtade leidmiseks erinevate teemade kohta. Meelsusanalüüsi kasutatakse nii poliitilistel eesmärkidel rahva seisukoha teada saamiseks kui ka ettevõtluses tarbijate arvamuste uurimiseks. Analüüsi tulemusena määratakse tekstid kas positiivseks või negatiivseks, küllaltki levinud on lisaks veel hinnangute liigitamine neutraalseteks ja vastuolulisteks.

Antud lõputöö peamine eesmärk on luua algoritm meelsuste analüüsimiseks Tartu Ülikooli õppeinfosüsteemis tudengite poolt jäetaval tagasisidel, seda rakendada ning täpsust hinnata. Teine eesmärk on rakendada algoritmi tagasisidekorpuse peal ning välja tuua, kuidas jaotuvad meelsused sõltuvalt ainevaldkonnast. Viimane eesmärk on luua viis kirjelduste ja soovitude eristamiseks meelsuste paremaks analüüsiks.

Töö teoreetilises osas antakse ülevaade meelsusanalüüsi vajalikkusest ja kasutusest, analüüsi meetoditest, probleemidest ning seni Eestis tehtud töödest. Samuti tutvustatakse töös meelsusanalüüsi tegemiseks kasutatud töövahendeid. Praktilises osas kirjeldatakse lähemalt kasutuses olevaid andmeid, kasutatud meetodeid ning analüüsitakse tehtud tööd ning saadud tulemusi.

# 1. Meelsusanalüüs

Esimeses peatükis tutvustatakse meelsusanalüüsi üldisemalt. Esmalt seletatakse lahti mõiste tähendus ning selgitatakse, miks ja kus on selle kasutamine vajalik. Seejärel kirjeldatakse meelsusanalüüsi meetodeid ning nendega kaasnevaid probleeme. Samuti antakse ülevaade analüüsi kasutamisest Eestis.

## 1.1 Tähtsus ja kasutusvaldkonnad

Arvamuste omamine ja nende avaldamine on inimestele alati omane olnud. Tänapäeval on arvamuste jagamine levinud ka interneti ning selline sotsiaalmeedias kommenteerimine ja arvustuste jätmine on loonud suure kõigile kättesaadavate arvamustekstide hulga. Kuigi tänu sellele on hea leida infot teiste nägemuste kohta, siis mida rohkem on erinevaid arvamusi, seda keerulisem on lugejal teha nendest ka kokkuvõtvaid järeldusi ning see võib viia info ülekülluseni. Selliste andmete arusaadavamaks tegemiseks saab kasutada meelsusanalüüsi, mille peamine eesmärk on tekstilistest andmetest saada automaatselt kätte meelsus või seisukoht, mida autor kirjutatuga väljendada soovis. Bing Liu [1] kirjutas oma töös, et veebis saadaval oleva teksti andmestiku kasv langeb suuresti kokku meelsusanalüüsi populaarsuse ja vajalikkuse tõusuga alates 2000. aastatest. Liu toob ka välja, et esmakordselt mainiti väljendit *sentiment analysis* ehk meelsusanalüüs aastal 2003, kuid uurimistöid meelsuste uurimiseks tehti ka juba aastal 2001.

Meelsusanalüüsi saab kasutada erinevates valdkondades, selles lõigus tuuakse välja mõned neist, tuginedes Liule [1]. Huviorbiiti on tõusnud meelsuste analüüsimine ettevõtluses, kus toodete ning teenuste plussidest ja miinustest on huvitatud nii ettevõtted kui ka ostjad. Selle jaoks on mitmed suured ettevõtted nagu Google ja Microsoft loonud asutusesisesed süsteemid. Samuti on meelsusanalüüsi kasutatud valitsuse tasemel, et teada saada, milline on rahva meelsus poliitikute suhtes või kodanike üldisi murekohti valitsuse suhtes. Selline jälgimine on väga levinud näiteks Hiinas. Kui varem küsiti arvamust selliste teemade kohta perelt või tuttavatelt, siis sotsiaalmeedia kasvuga pole arvamustest teada saamine enam nii limiteeritud. Tänu meelsusanalüüsile on firmadel vähenenud vajadus koostada kulukaid arvamusküsitlus või fookusgrupi uuringuid.

## 1.2 Meetodid

Meelsusanalüüsi meetodid saab kategoriseerida algoritmi või tekstiliigi järgi. Algoritmiliselt lähenedes jagasid Vohra ja Teraiya 2013. aastal kirjutatud artiklis [2] meelsusanalüüsi meetodid suures pildis kaheks: leksikoni- ja masinõppepõhiseks. Tekstiliigiti jagunevad meetodid dokumentidest, lausetest ja tunnustest lähtuvateks [1].

Järgnevas lõigus tutvustatakse leksikonipõhist meetodit, tuginedes Liule [1]. Leksikonipõhise meetodi jaoks on lisaks tekstandmetele, mille pealt meelsust hakatakse hindama, vaja eelnevalt koostatud leksikoni, kus on kirjas nii meelsust välja näitavad sõnad kui ka nende meelsus, näiteks „huvitav: positiivne, igav: negatiivne“. Leksikoni koostamiseks on kolm viisi. Esimeseks on manuaalne koostamine, mis võtab palju inimressurssi ja aega. Teine, korpusepõhine lähenemine kasutab sõnade saamiseks märgendatud andmestikku, millest otsitakse süntaktilisi mustreid. See meetod on väga hea valdkonnaspetsiifilise sõnavara saamiseks. Kolmandal sõnastikupõhisel lähenemisel võetakse lähteandmeteks väike manuaalselt koostatud sõnastik ning seejärel suurendatakse seda läbi sünonüümide ja antonüümide automaatse lisamise, näiteks kasutades leksikosemantilist andmebaasi *wordnet*.

Võttes aluseks Annetti ja Kondrako töös [3] välja toodud sammud leksikonipõhise meetodi kasutamiseks blogipostituste analüüsil, on siin välja toodud mugandatud ja veidi täiendatud variant igat liiki andmete jaoks. Sammud näevad välja sellised:

1. Teksti eeltöötlus, näiteks kirjavahemärkide ja muu ebavajaliku märgenduse eemaldamine.
2. Iga analüüsitava tekstiosa algskoori 0-ks määramine.
3. Teksti sõnestamine/tokeniseerimine ning iga sõne meelsusleksikonist otsimine.
  - 3.1. Kui sõne on meelsusleksikonis olemas, siis tuleb sõne skoor liita algskoorile positiivse meelsuse korral ja lahutada negatiivse puhul.
    - 3.1.1. Kui lauses esineb sõnest eespool eitus, siis positiivse korral skoor lahutada ja vastupidi.
4. Kui teksti üldskoor on alla 0, siis saab selle liigitada negatiivseks, ning kui suurem kui 0, siis positiivseks.

Selles lõigus antakse ülevaade masinõppe meetodist, kasutades Vohra ja Teraiya artiklit [2]. Masinõppeks on vaja treeningandmeid ning testandmeid. Treeningandmete põhjal õpib klassifitseerija ära erinevad tekstitunnused ning testandmetega kontrollitakse, kui hästi klassifitseerija toimib. Selliste andmete saamiseks on vaja eelnevalt kokku koguda hulk meelsusega tekste ning nende meelsus määrata. Tähtis on ka andmete tunnuste valik, mille põhjal klassifitseerija õppima hakkab. Peamised sellised tunnused on korduvad väljendid ja nende esinemishulk (väljendid võivad olla näiteks unigrammid ja bigrammid), sõnaliikide info, eitused ja meelsussõnad (selle jaoks oleks taaskord vaja luua eelnevalt mainitud meelsussõnade leksikon). Kaks peamist masinõppe mudelit, mida analüüsil kasutatakse, on naiivne Bayes (ingl *Naive Bayes*) ja tugivektorklassifitseerija (ingl *support vector machines*) meetodid.

Tekstiliigi järgi on Liu [1] jaganud meelsusanalüüsi meetodid kolmeks:

1. Dokumendipõhine, kus analüüsitakse tervet dokumenti ja leitakse sellele kokkuvõttev meelsus.
2. Lausepõhine, kus analüüsitakse korraga ühte lauset ja leitakse meelsus lause kaupa.
3. Tunnuste põhine, kus otsitakse meelsust kogu teksti asemel konkreetse üksuse kohta.

Vohra ja Teraiya [2] on välja toonud, et juhendatud masinõppe meetodid on andnud paremaid tulemusi kui mittejuhendatud leksikonipõhised meetodid, kuid mõlemal on siiski meelsusanalüüsis tähtis koht.

### **1.3 Peamised probleemid**

Meelsusanalüüsiga kaasnevad mitmed raskused, mida tuleb analüüsi tegemisel arvestada. Ühena tuleb kindlasti välja tuua meelsuse hindamise üleüldist subjektiivsust. Inimesed hindavad asju erinevalt ning sellepärast ei saa kunagi kõike päris üheselt määrata positiivseks või negatiivseks. Ka erinevad kultuurid hindavad emotsioone erinevalt. Seetõttu saab teistes riikides loodud emotsioonidetektoritest võtta vaid eeskuju, sest ei saa eeldada, et muus riigis tehtu suudaks tuvastada ka eestikeelseid emotsioone [4].

Lisaks tuleb sõnade subjektiivsus probleemiks ka lausete automaatsel hindamisel, sest sõnad võivad ühes kontekstis olla ühe meelsusega ja teises kontekstis teisega [5]. Näiteks lause „Loengud olid väga igavad“ saab lugeda negatiivseks meelsussõna „igav“ tõttu, aga lauses

„Loengud olid kõike muud kui igavad“ hoopis positiivseks, kuigi taaskord on kasutatud väljendit „igav“. Selle probleemi lahendamiseks tuleks lähemalt uurida lausete sõnajärge ning süntaksit, kuid see teeb ka analüüsi algoritmiliselt palju keerukamaks. Suureks probleemiks on ka see, et automaatsel meelsusanalüüsil on pea võimatu arvestada sarkasmi ja irooniaga, kuid tihti just sellistes lausetes muutub sõnade määratud meelsus vastupidiseks [1].

## **1.4 Meelsusanalüüs Eestis**

Eestis on tegelenud meelsusanalüüsiga Eesti Keele Instituut eesotsas Hille Pajupuuga, kes lõi riiklikult rahastatud projekti raames eestikeelse emotsioonidetektori, meelsusmärgenditega leksikoni ja tekstikorpuse. H. Pajupuu jt artiklis [6] tuuakse välja, et projekti põhieesmärkideks oli luua valdkonnast sõltumatu kirjaliku teksti polaarsuse määraja, et hinnata, kuidas loetud tekst võiks lugejale mõjuda. See on mõnevõrra erinev tavapärasest meelsusanalüüsist, kus keskendutakse tavaliselt kirjutaja seisukohale, mitte lugeja omale. Teine eesmärk oli edendada inimkõne emotsionaalsuse hindamist ja seeläbi muuta masina vastuseid kõnele loomulikumaks.

Esimese eesmärgi täideviimiseks katsetati nii leksikonipõhist meetodit kui ka masinõpet. Leksikonipõhise meetodi jaoks loodi valentsileksikon, mille kohandatud versiooni kasutatakse ka selle lõputöö praktilise osa teostamisel. Valentsileksikoni jaoks koguti kokku sagedasemased eestikeelsed sõnad ning siis lasti nende meelsust hinnata neljal inimesel, kes määrasid sõnad kas neutraalseks, positiivseks või negatiivseks. Peale sõnadele meelsuse määramist suurendati sõnastikku antonüümide ja tuletistega. Esialgu saadi sõnastikku 617 positiivset ja 730 negatiivset sõne ning nende käänete ja pöörete lisamisega tuli lõpuks leksikoni kokku ligi 38 628 üksust.

Masinõppe jaoks loodi märgendatud tekstikorpus, mis koosnes ajalehtede erinevate rubriikide lõikudest. Korpus koosneb 4086 märgendatud lõigust, märgendajateks olid seekord kolm inimest ja kokkuvõttes määrati meelsusteks neutraalne, negatiivne, positiivne ja vastuoluline. Masinõppe klassifitseerijaks kasutati naiivse Bayesi meetodit ja tugivektorklassifitseerijate meetodeid. Vastuolulised lõigud otsustati ennustuse täpsuse parandamiseks välja võtta nii, et ennustatavaks väärtuseks jäid vaid positiivne, negatiivne ja neutraalne.



Tulemuseks loodud emotsioonidetektor [7] on kasutatav Google Chrome'i või Exceli laiendusena ja ka veebirakendusena. Emotsioonidetektor toob tekstis välja võtmesõnad ja nende meelsuse (positiivne, negatiivne või ekstreemne) ja ka terve etteantud lõigu meelsuse (positiivne, negatiivne, vastuoluline, neutraalne või ekstreemne).

### **1.4.1 Varem tehtud tööd**

Eestis on meelsusanalüüsi tehtud ka mitme lõputöö raames. Aastal 2012 kirjutas Siim-Toomas Marran [8] töö teemal „Sentimentaalne analüüs eestikeelse peavoolumeedia veebiartiklite kommentaaride baasil“, kus hindas veebiuudiste kommentaare positiivseks või negatiivseks, kasutades leksikonipõhist meetodit ja vabavaralist ingliskeelset meelsusanalüüsi rakendust phpInsight [9], mille kohandas ümber eesti keelele.

Ka masinõppega meelsusanalüüsi on tehtud mitmes lõputöös. Üheks neist on 2017. aastal tehtud Olha Shepelenko [10] töö „Opinion Mining and Sentiment Analysis using Bayesian and Neural Networks Approaches“, kus hinnati Twitteri postituste meelsust kasutades naiivse Bayesi meetodit ning tehismärgivõrke. Ott Koik [11] kasutas 2018. aastal kirjutatud töös „Skriptimisvahendid teksti lokaliseerimiseks ja asukohapõhiseks analüüsiks Eesti asulate meediakuvandi tuvastamise näitel“ eelmises peatükis mainitud EKI loodud tööriista Valence, mille abil märgendas asukohaga seotud artiklite meelsuse hindamine.

2018. aastal tegi Gerth Jaanimäe [12] oma magistritöös „Eesti Wordnet ja meelestatuse analüüs“ uue keeleressursi, mis lõi võimaluse rakendada meelestatuse analüüsi Eesti Wordneti abil. Selleks lisas ta Eesti Wordneti sünohulkadele meelestatuse skoorid ning uuris, meelestatuse seost sõnade vahel, mis asuvad samas sünohulgas.

Birgitta Ojamaa [13] kirjutas aastal 2014 lõputöö „Tartu Ülikooli üliõpilaste tagasiside hoiakute analüüs“, mis analüüsib samuti meelsust tudengite jäetud tagasisidel. Ojamaa kasutas meelsuse määramiseks samuti leksikonipõhist meetodit, kusjuures tundesõnade leksikoni lõi autor ise. Ojamaa jagas võimalikud meelsused positiivseks, negatiivseks, neutraalseks ja vastuoluliseks ning algoritmi hinnanguks võrdles saadud tulemusi 100 käsitsi märgendatud tagasisidega. Autor tõi välja, et arvuti leidis hoiakuid sisaldavad tekste üle kümne protsendi vähem kui inimene, ja põhjenduseks mainis, et programmil polnud õigeid vahendeid kaudsemate emotsioonide ning lausekonstruktsioonide määramiseks. Samuti üritas

autor kommentaarid jagada soovitusteks ja olukorra kirjeldusteks, aga regulaaravaldisega seda saavutada ei suutnud.

Selles lõputöös kasutatakse samal viisil saadud korpust nagu Ojamaa tööski, kuid teiste aastate lõikes. Kuna eesti keele keeletehnoloogilised analüüsimismeetodid on üheksa aastaga palju arenenud, on lootust ära lahendada mitu Ojamaa poolt välja toodud edasiarendamise võimalust: tingivas kõneviisis lausete leidmine ning kindlate teemadega seotud arvamuste leidmine. Samuti katsetatakse siin töös, kui hästi sobib meelsusanalüüsiks EKI loodud valentsisõnastik tagasiside andmete puhul.

## 2. Kasutatud tehnoloogilised vahendid

Selles peatükis antakse ülevaade töös kasutatud vahenditest. Tööriistad said valitud keeletehnoloogia ning andmeteaduse standardeid arvestades.

### 2.1 Python

Töös kasutati programmeerimiskeele Python versiooni 3.8. VanderPlas [14] kirjutab, et Python on andmeteaduses laialt levinud peamiselt tänu väga suurele hulgale teekidele. Erinevaid teeke saab kasutada mitmesugustes ülesannetes: andmehulkade analüüs, visualiseerimine, masinõpe ning keeletöötlus, üheks selliseks on näiteks eesti keele töötlemiseks mõeldud EstNLTK..

### 2.2 EstNLTK

Põhiliseks lõputöös kasutatud tehnoloogiliseks vahendiks oli vabavaraline Pythoni teek EstNLTK [15], mis on loodud Tartu Ülikooli teadlaste poolt. EstNLTK on eestikeelne keeletehnoloogia vahend, mille abil saab teostada peamisi keeletötluse ülesandeid: tekstide tokeniseerimine, morfoloogiline analüüs ning lemmatiseerimine. Omakorda rakendati töös veel EstNLTK tõenäosuslikku sõltuvuspuude süntaksianalüsaatorit MaltParser [16], mis võtab sisendiks CoNLL formaadis sisendi ning tagastab lause sõltuvuspuu. CoNLL formaadis on lisaks sõnadele olemas ka näiteks nende lemmad, sõnavormid ja morfoloogilised tunnused.

```
kommentaar = "Loengud olid huvitavad."  
text = Text(kommentaar).tag_layer()  
conll_tagger = ConllMorphTagger(output_layer='conll_morph',morph_extended_layer='morph_analysis',no_visl=True)  
conll_tagger.tag(text)  
text.conll_morph
```

Layer

layer	name	attributes									parent	enveloping	ambiguous	span	count	
conll_morph		id, form, lemma, upostag, xpostag, feats, head, deprel, deps, misc	morph_analysis										None	True		4
	text	id	form	lemma	upostag	xpostag	feats	head	deprel	deps	misc					
	Loengud	1	Loengud	loeng	S	S	pl n	_	_	_	_					
	olid	2	olid	olema	V	V	sid	_	_	_	_					
	huvitavad	3	huvitavad	huvitama	V	V	vad	_	_	_	_					
	.	4	.	.	Z	Z	_	_	_	_	_					

Joonis 1. Tekst CoNLL formaadis.

```

kommentaär = "Loengud olid huvitavad."
text = Text(kommentaär).tag_layer()
conll_tagger = ConllMorphTagger(output_layer='conll_morph', morph_extended_layer='morph_analysis', no_visl=True)
conll_tagger.tag(text)
maltparser_tagger = MaltParserTagger(input_type='morph_analysis', version='conllu')
maltparser_tagger.tag(text)
text.maltparser_syntax

```

Layer

layer name		attributes										parent	enveloping	ambiguous	span	count
maltparser_syntax		id, lemma, upostag, xpostag, feats, head, deprel, deps, misc, parent_span, children											None	None	False	4
text	id	lemma	upostag	xpostag	feats	head	deprel	deps	misc	parent_span		children				
Loengud	1	loeng	S	S	{'pl': '', 'n': ''}	3	nsubj:cop	None	None	Span('huvitavad', [{'id': 3, 'lemma': 'huvitama', 'upostag': 'V', 'xpostag': 'V' ...}], type: <class 'estnltk_core.layer.span.Span'>		(0)				
olid	2	olema	V	V	{'sid': ''}	3	cop	None	None	Span('huvitavad', [{'id': 3, 'lemma': 'huvitama', 'upostag': 'V', 'xpostag': 'V' ...}], type: <class 'estnltk_core.layer.span.Span'>		(0)				
huvitavad	3	huvitama	V	V	{'vad': ''}	0	root	None	None	None		("Span('Loengud', [{'id': 1, 'lemma': 'loeng', 'upostag': 'S', 'xpostag': 'S', ' ...', type: <class 'tuple', length: 3				
.	4	.	Z	Z	None	3	punct	None	None	Span('huvitavad', [{'id': 3, 'lemma': 'huvitama', 'upostag': 'V', 'xpostag': 'V' ...}], type: <class 'estnltk_core.layer.span.Span'>		(0)				

Joonis 2. Tekst peale MaltParseri kasutust.

Joonisel 1 on näha väljund peale lause “Loengud olid huvitavad.” CoNLL formaadile viimist. Maltparseriga saadud formaadis on lisaks välja toodud, kuidas etteantud teksti sõnad on omavahel seotud. Joonisel 2 on välja toodud, milline näeb välja MaltParseri väljund joonisel 1 leitud sisendi puhul.

## 2.3 NumPy ja Pandas

NumPy [17] ja Pandas [18] on mõlemad Pythoni teegid, mis lihtsustavad tööd suurte andmehulkadega ning nende analüüsimisega. Esimene neist võimaldab kasutada fikseeritud pikkusega järjendeid ning teine on heaks abivahendiks andmeraamidega (ingl *DataFrame*) töötamisel. Selles töös kasutati Pandase teeki näiteks andmete eemaldamiseks ja lisamiseks ning andmete seas kõige rohkem esinenud väärtuste leidmiseks. Lisaks saab teeki kasutada andmete puhastamiseks, sorteerimiseks ja statistiliseks analüüsiks.

### **3. Üliõpilaste tagasiside analüüs**

Kolmandas peatükis antakse ülevaade praktilise osa käigust: esmalt kirjeldatakse andmeid, mida töös kasutati, siis seletatakse lahti rakendatud meetodid ja algoritmid. Viimaks analüüsitakse saadud tulemusi ja tuuakse välja, milliseid võimalusi oleks edasiarenduseks.

#### **3.1 Andmed**

Töös kasutati kahte põhilist andmestikku: tagasiside korpus ning valentsisõnastik. Selles peatükis tutvustatakse mõlemat lähemalt.

##### **3.1.1 Tagasisidekorpus**

Õppeainete õpetamise parandamiseks ning ainete olukorrast ülevaate saamiseks kogub Tartu Ülikool õppeinfosüsteemi kaudu iga semestri lõpus ainele registreerunud tudengitelt tagasisidet [19]. Selles töös kasutatakse meelsusanalüüsi korpusena just sel viisil saadud tagasiside kirjalikke kommentaare.

Suunavaks küsimuseks tudengitele tagasiside jätmisel on „Õppimissoovitused tulevastele õppijatele“ ehk otseselt on palutud tagasiside asemel soovitusi. Küsimuse püstitusest hoolimata on aastate jooksul õpilaste poolt jäetud tagasiside sisuks olnud nii aine kirjeldused kui ka soovitused. Seetõttu oli ka üks töö eesmärk morfoloogiliselt analüüsida tagasiside kommentaare, et teha kindlaks, kas tegemist on soovituse või kirjeldusega, et meelsussõnu paremini arvestada.

Töös kasutati nelja semestri, 2020. aasta sügise kuni 2022. aasta kevade, eestikeelsete ainekavade andmeid. Andmetabelis oli kokku viis tulpa: indeks, ainekood, õppeaasta, semester ja tagasiside kommentaar. Tagasiside kommentaaride pikkused varieerusid ühest sõnast rohkem kui 8 lauseni. Kokku oli tabelis kirjeid 37 212, iga andmerida sisaldas endas ühe inimese jäetud tagasisidet ühele ainele.

Kuna andmed on küsitud otse õppeosakonnalt ning ei ole internetis vabalt saadavad, siis ei ole võimalik neid tööle lisada. Andmetega tutvumiseks koos või ilma saadud tulemusteta tuleb pöörduda Tartu Ülikooli õppeosakonna poole.

### 3.1.2 Valentsisõnastik

Teise andmehulgana kasutati meelsusanalüüsi tegemiseks 1.4. peatükis mainitud Eesti Keele Instituudi poolt loodud valentsisõnastikku ehk leksikoni hoiakut näitavatest sõnadest ning neile määratud meelsute väärtusest (positiivne või negatiivne). Töö raames kohandati sõnastikku tagasisidekorpuse jaoks sobivamaks.

Esiteks korrastati sõnastiku andmeid, näiteks eemaldati küsimärgid sõnade juurest, mille meelsust võib kaheti mõista. Peale tagasisidekorpuse levinumate sõnade uurimist sai sõnastikku juurde lisatud 2 positiivset sõna: „lihtne“ ja „kerge“, mis esinesid tagasisides enamasti kirjeldamaks ainete raskusastet. Sõnastikust eemaldati negatiivselt märgendatud väljend „kohustuslik“, sest korpust uurides ilmnes, et väljendit kasutati tagasisidet andes rohkem neutraalse ainekorralduse kirjeldusena kui meelsuse näitajana. Samuti eemaldati jõudluse parandamiseks mitmeid sõnu, mida tagasisides ei kasutatud või kasutati taas ainult aine teemade kirjeldamiseks. Sellisteks sõnadeks olid näiteks „mõrv“ ja „abielluma“.

Kokku tuli 34 802 sõnast koosnev kaalumata sõnastik ehk kõik negatiivsed sõned omasid väärtust -1 ja positiivsed sõned 1. Kokku oli sõnastikus negatiivse väärtusega sõnu 19 904 ja positiivse väärtusega 14 897. Kuna andmestikus olid olemas ka kõikide sõnade erinevad pöörd- ja käändevormid, siis kadus vajadus korpuse sõnade lemmatiseerimiseks. Valentsileksikon on leitav GitHubi repositooriumis<sup>1</sup>.

### 3.2 Meetodi ja algoritmi kirjeldus

Esmalt enne meelsusanalüüsiga alustamist jagati andmed kaheks selle põhjal, kas need kirjeldasid olukorda või sisaldasid endas ka soovitusi või soovi. Selleks kasutati EstNLTK morfoloogilise analüüsi meetodit *morph\_analysis\_est*, et kätte saada kõigi tagasisides olevate sõnade vormid ning lemmad. Kui kommentaaris leidis kas käskivas kõneviisis tegusõna, mingis vormis väljendid „soovitama“ või „soovima“ või kui kogu kommentaar koosnes vaid ühest sõnast „edu“, kategoriseeriti see soovituseliseks ning kõik ülejäänud loeti kirjeldusteks. Väljendid „soovitama“ ja „soovima“ valiti selle järgi, et just neid sisaldavad kommentaarid väljendasid enamasti soovitusi või soovide edasi andmist, kuigi leidis ka erandeid.

---

<sup>1</sup> <https://github.com/regitaluukas/Meelsusanaluus>

Töö põhiosaks, meelsusanalüüsiks, kasutati leksikonipõhist lähenemist. Kõik tagasisidekorpuse read käidi ükshaaval läbi ning esimese sammuna määrati iga rea skooriks 0. Kommentaarid sõnestati ning igat sõne, mis oli pikem kui üks tähemärk, võrreldi kõikide valentsileksikoni sõnadega. Tähemärkide alumine piir sai lisatud arvestades seda, et kõige lühem sõnastikus esinev sõna oli 2 tähemärgi pikkune ning algoritmi kiiruse suurendamiseks oli optimaalsem teha iga sõna juures üks lisavõrdlus pikkuse kontrolliks kui igat ühetähemärgilist sõne võrrelda 34 802 sõnastikus oleva sõnaga.

Kui leiti kattuvus sõnastiku ja korpuse sõnaga, liideti selle väärtus skoorile. Juhul kui kommentaaris leidis eitus (sõnad „ei“, „mitte“, „pole“, „polnud“, „ega“), siis liitmise asemel väärtus lahutati. Täpsuse suurendamiseks prooviti arvestada eitust osalause te kaupa (selle järgi said valitud ka vastavad eitust näitavad sõnad) ehk kui leiti meelsust näitav sõna, siis otsiti eitust alates kommentaari esimesest sõnest kuni ühe sõneni peale seda sõna, et leida üles ka need eitused, mis asetsevad kohe peale meelsussõna. Kui kommentaaris leidis mitu meelsust näitavat sõna, siis piirati otsingut veel alates eelmisest meelsussõnast kuni üks koht peale järgmist meelsussõna. Näiteks lauses „Ei olnud kasulik aine, aga õppejõud oli abivalmis“ otsitakse eitust sõna „kasulik“ puhul lausest „Ei olnud kasulik aine,“ ning kui algoritm jõuab sõnani „abivalmis“, siis otsitakse eitust „aine, aga õppejõud oli abivalmis“ lauseosast. See otsimise viis pole täiuslik ja võib siiski arvesse võtta eitusi, mis ei käi sõna kohta, kuid kuna selliseid lauseid esines korpuses vähe, otsustati algoritmi keerukamaks mitte muuta.

Meelsusanalüüsi juures teostati ka kohandatud versioon tunnusepõhisest analüüsist. Iga kord, kui kommentaarist leiti meelsust näitav sõna, prooviti lisaks kindlaks teha, kas see sõna võib kirjeldada loengut, eksamit või õppejõudu. Selle kaudu saadi kätte väljendid, mida kõige rohkem nende kolme tunnuse kohta kasutati. Selliseks analüüsiks kasutati MaltParser süntaksianalüsaatorit, mis teisendas laused sõltuvuspuudeks. Kõigi leitud meelsussõnade puhul kontrolliti, kas puus on selle sõna otseseks naabriks üks mainitud kolmest tunnusest. Juhul, kui tunnus leiti, lisati meelsussõna vastava tunnuse järjendisse, lauses esineva eituse korral lisati sõna ette ka miinus.

Peale kommentaari kõigi sõnade läbi vaatamist hinnati meelsust nende reeglite järgi:

- kui skoor on suurem kui 0, siis on hinnang positiivne,

- kui skoor on väiksem kui 0, siis on hinnang negatiivne,
- kui skoor on võrdne nulliga ja tagasisidereast on leitud võrdne arv negatiivse ja positiivse meelsusega sõnu, siis on hinnang vastuoluline,
- kui skoor on võrdne nulliga ja ühtegi meelsust näitavat sõne pole leitud, siis neutraalne.

Nende kahe algoritmi tulemusena saadi 5 erinevat järjendit: üks soovitus/kirjelduse jaotuse jaoks, kolm iga tunnuse (õppejõud, eksam, loeng) meelsussõnade kohta ning viies kommentaari meelsusest. Kõik järjendid lisati tulbana algsele andmetabelile, et kommentaari ja selle kohta leitud tulemused saaks vastavusse viia ning järeldusi teha. Mõlemad algoritmid koos selgitavate kommentaaridega on leitavad GitHubi repositooriumis<sup>2</sup>.

### 3.3 Analüüs

Analüüsisiosas näidatakse saadud tulemusi, seletatakse, mida tuleks analüüsimisel arvesse võtta ning kui täpselt tehtud meelsusanalüüsi algoritmi hinnatakse.

#### 3.3.1 Soovituste ja kirjelduste eraldamise tulemused

Kõigist tagasiside kommentaaridest 66.4% sisaldasid endas soovitusi või soovi ning 33.6% ainult olukorra kirjeldust. Peamine eesmärk selliseks eraldamiseks oli see, et nii nagu kirjeldavad tagasiside kommentaaridki, võivad soovitused endas sisaldada meelsussõnu, aga ei pruugi anda hinnangut ainele ja seetõttu oleks neid hea ka meelsusanalüüsi tulemuste analüüsis eraldada. Näiteks lause „Soovitan lihtsamad teemad esimesena selgeks teha, siis on hiljem kergem.“ sisaldab meelsussõnu „lihtsamad“ ja „kergem“ ja kommentaarina loetakse positiivseks, kuigi tegelikult on neutraalne.

Seejuures tuleb arvestada, et väga paljud kommentaarid väljendasid nii soovitusi kui ka kirjeldust, sel juhul loeti ka need soovituste alla. Samuti loeti soovituste alla soovid (nt. „Edu!“), mis otseselt ei anna ei kirjeldust ega soovitusi. Selline arvestus tehti samuti seetõttu, et ka soovid tihtipeale ei anna edasi arvamust. Üks süntaktiline probleem, mis sellist eraldust tehes ilmsiks tuli, oli see, et automaatselt on raske teha vahet lausel „Soovitan seda ainet võtta!“ ja „Soovitan praktikumides kohal käia!“, aga meelsusanalüüsi silmas pidades omab

---

<sup>2</sup> <https://github.com/regitaluukas/Meelsusanaluus>



esimene neist otsest positiivset hinnangut ja on soovitus ja kirjelduse vahepealne, kuid teine lause on olemuselt neutraalne soovitus.

Teise murekohana tuli soovitude ja kirjelduste eraldamisel välja, et morfoloogiline analüsaator ei suutnud alati õigesti sõnavorme määrata. Näiteks lause „Ei ütle midagi“ loeti soovituseks, sest analüsaator luges väljendi „ütle“ käskivas kõneviisis sõnaks, mis võib mõne lauseehituse puhul küll õige olla selle sõna puhul, kuid mitte antud lauses.


### **3.3.2 Meelusanalüüsi tulemused**

Esmalt tuuakse välja, kuidas jaotusid meelsused ainevaldkondade (humanitaarteaduste ja kunstide valdkond, sotsiaalteaduste valdkond, meditsiiniteaduste valdkond ja loodus- ja täppisteaduste valdkond) lõikes ning seejärel kogu tagasiside seas kokku. Hinnatakse ka algoritmi täpsust ja seletatakse, mis olid kõige suuremad probleemid, mida tuleks andmete analüüsil arvesse võtta. Tähtis asi, mida rõhutada enne analüüsi, on see, et töös leitud meelsustest ei saa teha mingeid otseseid järeldusi ainevaldkondade õpetamise kvaliteedi kohta. Tagasiside, mille põhjal meelsused leiti, on kirjutatud subjektiivselt ning mis võib meeldida ühele tudengile, võib olla vastumeelne teisele. Lisaks võib erinevus tulla sellest, kas aine on võetud vabaainena või kohustuslikus korras. Õppeosakonna palvel on kommentaaridest eemaldatud õppejõudude nimed ning käesolevas lõputöös ei mainita otseselt ka õppeaineid, millele kommentaar jäeti.

Joonisel 3 on välja toodud, kuidas jaotuvad valdkonniti nende tagasiside kommentaaride meelsused, mis kategoriseeriti soovitude ja kirjelduste eraldamisel kirjeldavateks. Joonisel 4 on arvesse võetud kogu tagasiside ehk soovitusi ja kirjeldusi ei eraldata. Meelsuste jagunemine on sarnane mõlema arvestuse korral ning ka erinevate valdkondade samade meelsuste osakaalud ei erine üksteisest palju.


Kokkuvõtlikult ilmneb, et tagasisidest üle poole moodustasid positiivse meelsusega kommentaarid. Järgmisel kohal olid neutraalsed, siis negatiivsed ja kõige vähem oli vastuolulisi. Tunnustepõhiselt leiti, et kõige rohkem kasutati loengute kirjeldamiseks meelsussõnu „huvitama“, „aitama“, „põnev“, „aktiivne“ ja „kasulik“, eksamit kirjeldati enim väljenditega „lihtsam“, „raske“, „mitte raske“, „aitama“ ja „lihtne“ ning õppejõude sõnadega „tore“, „toetav“, „hea“, „toetama“ ja „sõbralik“.

### Kirjeldava tagasiside meelsuste jaotus valdkonniti



Joonis 3. Kirjeldava tagasiside meelsuste jaotus valdkonniti.

### Kogu tagasiside meelsuste jaotus valdkonniti



Joonis 4. Kogu tagasiside meelsuste jaotus valdkonniti.

Algoritmi täpsuse hindamiseks võeti 100 juhuslikku kommentaari kogu tagasiside seast, määrati nende meelsused käsitsi ning seejärel võrreldi neid arvuti poolt leitudetega. Sedasi hinnates selgus, et arvuti oli hinnanud meelsust õigesti 67% kommentaaridest. Tulemusi

võrreldes ilmnes, et suurim erinevus oli tulnud soovitud sisaldavate kommentaaridega, mis käsitsi hinnates liigitati neutraalse alla, kuid arvuti hindas enamasti positiivseks. Seetõttu otsustati teha sama protsess läbi ka ainult kirjeldust sisaldavate tagasiside kommentaaride peal, sel viisil tuli täpsuseks 71%.

Hinnates tuli välja, et suurel hulgal kommentaarides oli tehtud kirjavigu, mis ei sega küll käsitsi hindamisel, aga on probleemiks automaatsel märgendamisel. Samuti leidis mitmeid vene- ja ingliskeelseid kommentaare, mis hinnati automaatselt neutraalseks, sest algoritm oskas arvestada vaid eesti keelega.

Peamised probleemkohad, mis täpsust alla viisid, olid meelsussõnade mitte leidmine ning eituste valesti arvestamine. Meelsussõnade leidmine oli tingitud valentsisõnasastikust, mis sisaldas küll paljusid, kuid siiski mitte kõiki sõnu, mis kommentaarides esinesid. Eituste valesti arvestamine väljendus peamiselt positiivsete kommentaaride negatiivseks jaotamisel, mis oli tingitud sellest, et algoritm ei suutnud meelsussõna ja tema kohta käivat eitust väga täpselt kokku viia. Arvestati küll meelsussõnadest lähtuvate osalauseetega, aga näiteks lauses „Ei tea, kas kõik minuga nõustuks, aga minu meelest oli aine huvitav.“ pole „ei“ ja „huvitav“ kuidagi seotud, kuid eituse esinemise tõttu loeti lause siiski negatiivseks. Lahendusi selliste vigade vältimiseks tutvustatakse järgmises peatükis.

### **3.4 Edasiarendamise võimalused**

Selles peatükis antakse mõni võimalik idee töö edasiarendamiseks. Üks edasiarenduse suund on täpsuse tõstmiseks algoritmi täiustamine. Esiteks võiks MaltParserTaggeri lausete sõltuvussuhteid kasutades viia paremini kokku, mis meelsussõna kohta käib lauses esinev eitus, mitte lihtsalt arvestada sõnade paiknemist lauses. Samuti saaks uurida veelgi rohkem korpuses levinud sõnu näiteks *bag-of-words* meetodit kasutades ja seejärel meelsusõnastikku andmetele sobivamaks teha.

Tunnusepõhist meelsusanalüüsi saaks edasi arendada, kasutades rohkemaid tunnuseid. Näiteks lisaks õppejõule,ksamile ja loengule saaks sisse tuua ka tunnused praktikum, seminar ja juhendajad. Soovituste ja kirjelduste eraldamise algoritmi saaks täpsemaks muuta tuues sisse lisaks käskiva kõneviisi otsimisele ka sellised väljendid, mis vastavad küsimusele “mida teha?”.

Nii selles kui ka 2014. aastal tehtud Ojamaa [13] lõputöös kasutati tagasiside meelsuse leidmiseks leksikonipõhist meetodit. Sellest tulenevalt oleks üks edasiarendamise võimalus kasutada tagasisidekorpuse meelsuste analüüsimiseks masinõppe meetodit. Kuna EKI poolt märgendatud artiklite korpus on vabalt kättesaadav, siis oleks hea võimalus katsetada, kas see toimib ka ainete tagasiside andmetel.

Ka analüüsi saaks laiendada valdkondade meelsuste võrdlemisest edasi. Üks võimalustest oleks uurida meelsuste muutumist semestrite või aastate lõikes. Samuti saaks võrrelda ainete meelsuste erinevust mitmesuguste tunnuste järgi, näiteks hindamise skaala (eristav või mitte-eristav) või õppevormi (distantsope või kohapeal toimuv).

## Kokkuvõte

Lõputöö peamine eesmärk oli luua algoritm meelsuse analüüsimiseks Tartu Ülikooli õppeinfosüsteemis (ÕIS) tudengite poolt jäetaval tagasisidel, seda rakendada ning täpsust hinnata. Töö eesmärk sai täidetud. Loodi leksikonipõhine algoritm tagasiside kommentaaride kategoriseerimiseks positiivseks, negatiivseks, neutraalseks ning vastuoluliseks. Algoritmi täpsuseks saadi 67%. Samuti viidi ühe eesmärgina täide algoritm kommentaaride jaotamiseks soovitus sisaldavaks või kirjeldavaks. Ainult kirjeldavaks märgitud kommentaare arvestades tuli meelsusanalüüsi algoritmi täpsuseks 71%.

Viimane eesmärk oli rakendada algoritmi tagasisidekorpuse peal ning välja tuua, kuidas jaotuvad meelsused sõltuvalt ainevaldkondadest. Ka see eesmärk täideti ning tulemuseks saadi, et meelsused jaotuvad eri valdkondades sarnaselt: tagasisidest üle poole moodustasid positiivse meelsusega kommentaarid, järgmisel kohal olid neutraalsed, siis negatiivsed ning kõige vähem oli vastuolulisi. Kuigi erinevused olid väga väikesed,

Lisaks leksikonipõhisele lähenemisele tehti ka tunnustepõhine meelsusanalüüs, mille kaudu leiti, missuguseid meelsussõnu kasutatakse tunnuste „loeng“, „eksam“ ja „õppejõud“ kohta. Tulemuseks saadi, et kõige rohkem kasutati loengute kirjeldamiseks meelsussõnu „huvitama“, „aitama“, „põnev“, „aktiivne“ ja „kasulik“, eksamit kirjeldati enim väljenditega „lihtsam“, „raske“, „mitte raske“, „aitama“ ja „lihtne“ ning õppejõude sõnadega „tore“, „toetav“, „hea“, „toetama“ ja „sõbralik“.

Teoreetilises osas anti lõputöös ülevaade meelsusanalüüsi vajalikkusest nii ettevõtluses kui poliitikas, kirjeldati analüüsi meetodite jaotumisest algoritmi ja tekstiliigi järgi, arutleti probleemidest tekstide meelsuse määramisel ning toodi välja seni Eestis tehtud tööd. Samuti kirjeldati töös kasutatud tehnoloogilisi vahendeid ning analüüsiks kasutatud valentsileksikoni ning tagasisidekorpust.

Meelsusanalüüs on aina populaarsust koguv ala ja sellega tasub kindlasti ka edaspidi edasi tegeleda, et eestikeelseid analüüsi võimalusi järjest uurida ja edendada. Tulevikus saaks algoritmi edasi arendada, parandades tulemuse täpsust või katsetades sarnaste andmete peal ka teisi meelsusanalüüsi meetodeid.

## Viidatud kirjandus

- [1] Liu, B. „Sentiment Analysis: Mining Opinions, Sentiments, and Emotions“. Cambridge University Press. 2015.
- [2] Vohra S. M.; Teraiya J. B. „A Comparative Study of Sentiment Analysis Techniques“. 2013. <http://www.ejournal.aessangli.in/ASEEJournals/CE63.pdf> (05.03.2023)
- [3] Annett, M. Kondrak, G.. „A Comparison of Sentiment Analysis Techniques: Polarizing Movie Blogs“. 2008.  
[https://www.researchgate.net/publication/221442023\\_A\\_Comparison\\_of\\_Sentiment\\_Analysis\\_Techniques\\_Polarizing\\_Movie\\_Blogs](https://www.researchgate.net/publication/221442023_A_Comparison_of_Sentiment_Analysis_Techniques_Polarizing_Movie_Blogs) (17.03.2023)
- [4] Vainik, E. „Kuidas õpetada kõnesüntesaatorile empaatiat? Emotsiooni automaatse tuvastuse võimalustest eestikeelses kirjalikus lauses sisalduva info põhjal.“ Eesti Rakenduslingvistika Ühingu aastaraamat, 2010, nr 6, lk 327–347.
- [5] Pang, B; Lee, L. „Opinion mining and sentiment analysis“. 2008.  
<https://www.cs.cornell.edu/home/llee/omsa/omsa.pdf> (05.03.2023)
- [6] Pajupuu, H jt. „Identifying Polarity In Different Text Types“. Folklore. Electronic Journal of Folklore, 2016, nr 64, lk 25–42. <https://www.folklore.ee/folklore/vol64/polarity.pdf> (05.03.2023)
- [7] Emotsioonidetektor. <http://peeter.eki.ee:5000/applications/list> (05.03.2023).
- [8] Marran, S.-T. „Sentimentaalne analüüs eestikeelse peavoolumeedia veebiartiklite kommentaaride baasil“ TÜ arvutiteaduse instituudi bakalaureusetöö. 2012.
- [9] phpInsight. <https://github.com/JWHennessey/phpInsight> (05.03.2023).
- [10] Shepelenko, O. „Opinion Mining and Sentiment Analysis using Bayesian and Neural Networks Approaches“ TÜ arvutiteaduse instituudi magistr töö. 2017.
- [11] Koik, O. „Skriptimisvahendid teksti lokaliseerimiseks ja asukohapõhiseks analüüsiks Eesti asulate meediakuvandi tuvastamise näitel“ TÜ ökoloogia ja maateaduste instituudi magistr töö. 2018.
- [12] Jaanimäe, G. „Eesti Wordnet ja meelestatuse analüüs“ TÜ eesti ja üldkeeleteaduse instituudi magistr töö. 2018.
- [13] Ojamaa, B. „Tartu Ülikooli üliõpilaste tagasiside hoiakute analüüs“ TÜ eesti ja üldkeeleteaduse instituudi bakalaureusetöö. 2014.
- [14] VanderPlas, J. „Python Data Science Handbook“. O'Reilly Media, Inc. 2016.

- [15] Orasmaa, S; Petmanson, T; Tkachenko, A.; Laur, S. Kaalep, H-J. „ESTNLTk - NLP Toolkit for Estonian“, Proceedings of the Tenth International Conference on Language Resources and Evaluation, 2016, lk 2460-2466
- [16] MaltParser. <https://www.maltparser.org/> (04.04.2023)
- [17] Harris, C.R., Millman, K.J., van der Walt, S.J. jt. „Array programming with NumPy.“. Nature, 2020, nr 585, lk 357–362.
- [18] pandas. <https://pandas.pydata.org/> (17.03.2023)
- [19] Tartu Ülikool. <https://ut.ee/et/sisu/oppeaine-tagasiside-kusitlus> (07.05.2023)

## Lisad

### I. Litsents

#### **Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks**

Mina, Regita Luukas,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose **Tartu Ülikooli õppeainete tagasiside meelsusanalüüs**, mille juhendaja on Sven Aller, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada digitaalarhiivi DSpace kuni autoriõiguse kehtivuse lõppemiseni.
2. Annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi DSpace kaudu Creative Commons'i 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.

*Regita Luukas*

**09.05.2023**