



Kuidas koguda ja analüüsida Facebooki postitusi?

Online-kogukondade hoiakute kaardistamise juhend

Sander Salvet, Tartu Ülikool



RITA-RÄNNE projekt aitab välja töötada teaduslikult põhjendatud innovaatilisi lähenemisi rände ja lõimumise protsesside juhtimiseks Eestis, eesmärgiga aidata kaasa majanduse arengule ja ühiskonna sidususe suurenemisele

SISUKORD

SISSEJUHATUS	2
1. ETTEVALMISTAVAD SAMMUD	3
1.1. Uurijabrauseri loomine	3
1.2. Otsimootori päringu abil avalike Facebooki lehtede kaardistamine	7
1.3. Andmekogumis- ja andmeanalüüsitarvvara allalaadimine ja paigaldamine	9
2. ANDMEKOGUMINE FACEPAGERIGA	9
2.1. JSON-formaadis eelsätete loomine	10
2.2. Andmekogumine	12
3. MEELESTATUSANALÜÜS JA TEEMA MUDELDAKSE ÕPETOUS	15
3.1. Eeltöölus (Python)	16
3.1.1. Teksti puhastamine ja lemmatiseerimine	16
3.1.2. Andmestiku osadeks jagamine ja postituste käsitsi märgendamine	20
3.1.3. Teksti vektoriseerimine	20
3.2. Postituste meelestatuse tuvastamine (Python)	21
3.3. Postituste teemade tuvastamine (Python)	22
3.4. Jooniste ja tabelite tegemine, statistiline analüüs (R)	24
KASUTATUD KIRJANDUS	26

SISSEJUHATUS


Käesolev *online*-kogukondade hoiakute kaardistamise juhend, annab praktilisi juhtnööre hoiakute uurimiseks migrantide suhtes avalike eestikeelsete Facebooki lehtede postitustes. Juhend koosneb kolmest osast: 1) ettevalmistavatest sammudest andmekogumiseks ja -analüüsiks ning 2) andmekogumise ja 3) andmeanalüüsiga õpetusest. Mõned juhendis väljapakutud analüüsimeetodid, nagu meelestatusanalüüs ja teema mudeldamine, on mõeldud vaid väga suurte tekstikorpuste uurimiseks. Pisut väiksema, nt mõnesajast postitusest koosneva valimi korral on otstarbekam kasutada meelestatusanalüüsiga ja teema mudeldamise asemel nt standardiseeritud kontentanalüüsiga (vt [Kalmus, 2015](#)). Lisaks siinse juhendiga tutvumisele, läheb uurijal hoiakute kaardistamiseks vaja ka eelteadmisi sotsiaalteaduslike uuringute läbiviimisest (vt [Sotsiaalse..., 2014](#)), päringupõhisest uuringudisainist (vt [Rogers, 2019](#)), meelestatusanalüüsist (vt [Liu, 2015](#)) ja teema mudeldamisest (vt [Alghamdi & Alfalqi, 2015](#)) ning andmetöölusest Pythoni (vt [TÜ..., 2017](#)) ja R-iga (vt [Kolnes, 2020](#)). Juhendi kasutamise puhul tuleb arvestada sedagi, et nii digimeetodite kui sotsiaalmeediauuringute valdkond muutub kiiresti ning mõned antud nõuannetest ei pruugi enam mõne kuu või aasta pärast kehtida.

1. ETTEVALMISTAVAD SAMMUD

Enne andmekogumist tuleb kaardistada huvipakkuvad avalikud Facebooki lehed ja tuvastada nende unikaalsed ID-koodid. Facebooki lehtede kaardistamiseks on soovitatav kasutada nt Google'i, Bingi vm otsimootri päringut. Reeglinä annab otsimootori päring rohkemaid ja mitmekesisemaid tulemusi kui Facebooki enda otsing. Selleks, et vähendada otsimootori algoritmide personaliseerivat mõju tulemustele, tuleb aga uuringu jaoks ette valmistada uurijabrauser. Samuti on tarvis enne andmekogumist ja -analüüsiga paigaldada arvutisse vajalik tarkvara. See peatükki annabki näpunäiteid uuringuks valmistumisel: uurijabrauseri loomiseks, otsimootori päringu abil Facebooki lehtede kaardistamiseks ning tarkvara paigaldamiseks.

1.1. Uurijabrauseri loomine

- ❖ Paigaldage Mozilla Firefoxi veebilehitseja. Mozilla Firefoxi saab alla laadida leheküljelt <https://www.mozilla.org/et/> (vt joonist 1).



Joonis 1. Mozilla Firefoxi allalaadimine, valides "Laadi Firefox alla"

- ❖ Pärast Firefoxi paigaldamist muutke veebilehitseja privaatsussätteid:
 - keelake veeblehtedel teie jälgimine ("Sätted" > "Privaatsus ja turvalisus" > "Saitidele saadetakse signaal, et sa ei soovi olla jälitatud: alati"), vt joonist 2;

Brauserit haldab sinu organisatsioon.

Otsi sätetest

- Üldine
- Avalaht
- Otsing
- Privaatsus ja turvalisus
- Sync

Saitidele saadetakse signaal, et sa ei soovi olla jälitatud [Rohkem teavet](#)

alati

kui Firefox on seadistatud tundud jälitajaid blokkima

Küpsised ja saidi andmed

Salvestatud küpsised, saitide andmed ja vahemälu kasutavad praegu 24,7 MiB salvestuspindala. [Rohkem teavet](#)

Firefoxi sulgemisel kustutatakse küpsised ja saitide andmed

[Kustuta andmed...](#)

[Halda andmeid...](#)

[Halda õigusi...](#)

Joonis 2. Veeblehtedepoolse jälgimise keelamine

- lülitage välja asukohaandmete edastamine ("Sätted" > "Privaatsus ja turvalisus" > "Asukoht" > "Sätted" > "Bloki uued asukohateabe saamise soovid") ja salvestage muudatused ("Salvesta muudatused"), vt joonist 3;

Sätted - asukoha õigused

Järgmised saidid on avaldanud soovi ligipääsuks sinu asukohale. Siin saad määrata, millistel saitidel on ligipääs sinu asukohale. Samuti saad blokkida uusi soove pääseda ligi sinu asukohateabele.

Otsi saiti

Sait	Olek


Eemalda sait Eemalda kõik saidid

Bloki uued asukohateabe saamise soovid
See takistab kõigil ülal mitte välja toodud saitidel asukohateabele ligipääsu kohta soovi avaldada. Asukohateabele ligipääsu blokkimine võib põhjustada probleeme mõne saidi töötamises.

Loobu Salvesta muudatused

Joonis 3. Asukohaandmete edastamise väljalülitamine

- lülitage välja veeblehtede küllastamise ajalugu ("Sätted" > "Privaatsus ja turvalisus" > "Ajalugu" > "Firefox: ei säilita ajalugu"; seejärel nõustuge brauseri taaskäivitamisega), vt joonist 4.



Joonis 4. Veeblehtede külastamise ajaloo väljalülitamine

- ❖ Kustutage küpsised (“Sätted” > “Privaatsus ja turvalisus” > “Küpsised ja saidi andmed” > “Kustuta andmed...”), vt joonist 5.



Joonis 5. Küpsiste ja veeblehtede andmete kustutamine

- ❖ Logige välja kõigist keskkondadest, mis võivad otsimootoriga seotud olla, nt Google'i otsimootori puhul Google'i kontolt, Bingi otsimootori puhul Microsofti kontolt.
- ❖ Google'i otsimootori korral kontrollige otsitulemuste personaliseerimise sätteid. Selleks avage lehekülg www.google.com/history/optout ja veenduge, et väljalogitud kasutaja otsingutegevuse jälgimine oleks välja lülitatud (vt joonist 6).



Joonis 6. Google'i kontolt väljalogitud kasutaja otsingegevuse jälgimise väljalülitamine

- ❖ Google'i otsimootori korral määarakse sätetes asukoht ("Eelistused" > "Otsinguseaded" > "Piirkonna seaded"; vt jooniseid 7 ja 8) ja tulemuste keel ("Eelistused" > "Otsinguseaded" > "Keeled"; vt joonist 9) (Digital Methods Initiative, 2015).



Joonis 7. Google'i otsimootori otsinguseadete avamine

Piirkonna seaded

- | | | | |
|---|--|--|----------------------------------|
| <input type="radio"/> Praegune piirkond | <input type="radio"/> Ameerika Ühendriigid | <input type="radio"/> Araabia Ühendemiraadid | <input type="radio"/> Austria |
| <input type="radio"/> Afganistan | <input type="radio"/> Andorra | <input type="radio"/> Argentina | <input type="radio"/> Bahama |
| <input type="radio"/> Albaania | <input type="radio"/> Angola | <input type="radio"/> Armeenia | <input type="radio"/> Bahrein |
| <input type="radio"/> Alžeeria | <input type="radio"/> Anguilla | <input type="radio"/> Aserbaidžaan | <input type="radio"/> Bangladesh |
| <input type="radio"/> Ameerika Samoa | <input type="radio"/> Antigua ja Barbuda | <input type="radio"/> Austraalia | <input type="radio"/> Belgia |

Näita rohkem ▾

Salvesta

Tühista

Mis tahes eelmiste seadete kasutamiseks logige sisse. Lisateave

Joonis 8. Piirkonna seadete määramine (nt klõpsake “Näita rohkem”, valige “Eesti” ja vajutage “Salvesta”)



Otsinguseaded

Otsingutulemused

Keeded

Abi

Mis keelt peaksid Google'i töötada kasutama?

- | | | | |
|---|--|--|-------------------------------|
| <input type="radio"/> Deutsch | <input type="radio"/> hrvatski | <input type="radio"/> português (Portugal) | <input type="radio"/> ຖໍານາ |
| <input type="radio"/> English | <input type="radio"/> italiano | <input type="radio"/> Tiếng Việt | <input type="radio"/> 한국어 |
| <input type="radio"/> español | <input type="radio"/> Nederlands | <input type="radio"/> Türkçe | <input type="radio"/> 中文 (简体) |
| <input type="radio"/> español (Latinoamérica) | <input type="radio"/> polski | <input type="radio"/> русский | <input type="radio"/> 中文 (繁體) |
| <input type="radio"/> français | <input type="radio"/> português (Brasil) | <input type="radio"/> العربية | <input type="radio"/> 日本語 |

Näita rohkem ▾

Praegu kuvatakse otsingutulemusi järgmistes keeltes:

eesti Muuda

Salvesta

Tühista

Joonis 9. Otsingutulemuste keele valimine (nt klõpsake “Näita rohkem”, valige “eesti” ja vajutage “Salvesta”)

1.2. Otsimootori päringu abil avalike Facebooki lehtede kaardistamine

- ❖ Päringu otsisõnadena kasutage kas: a) uurimisteeema kontekstis universaalseid, üldtuntud sõnu (nt “sisserändaja”, “immigrant”, “pagulane”), või b) võimalikult erineva tähendusvarjundiga sõnu (nt “abivajaja”, “pagulane”, “sissetungija”) (Rogers, 2019).
- ❖ Pärast esimese päringu läbiviimist, tuleks otsitulemustega tutvuda ja päringu sõnastust selle põhjal täiustada. Sama protsessi tuleks korrrata, kuni päring on võimalikult täpne.
- ❖ Päringu täiustamisel kasutage ka operaatoreid, nt:

- "" ehk jutumärgid on vajalikud, kui te ei soovi, et otsimootor nt parandaks võtmesõna kirjapilti, kasutaks sünönüüme või muid sarnaseid sõnu, kasutaks võtmesõna tüve või jätkaks osa võtmesõnu välja (nt "pagulane");
 - * ehk tärn markeerib teadmata tähti või sõnu (nt *pagul**)
 - *site:* võimaldab määrata kindla veebilehe, millelt otsimootor tulemusi otsib (nt "*pagulane*" *site:facebook.com*);
 - - ehk miinusmäärk võimaldab määrata sõnad või veebilehed, mille soovite päringu tulemustest välja jäätta (nt "*migrant*" -"*emigrant*").
- ❖ Määrase otsitulemuste ajaline piirang (nt Google'i otsimootori korral klöpsake valikul "*Tööriistad*", valige "*Igal ajal*" asemel "*Kohandatud valik...*" ja sisestage täpne kuupäevade vahemik, vt joonist 10). Näiteks RITA-RÄNNE projekti raames läbiviidud sotsiaalmeediauringus on kasutatud päringut *site:facebook.com pagulane OR põgenik OR sisserändaja OR varjupaigataotleja OR asüülitaaotleja*, mille ajaliseks piiranguks märgiti *1/1/2014 – 12/31/2018* (Salvet, 2020).

site:facebook.com pagulane OR põgenik OR sisserändaja OR varjupaigataotleja OR asüülitaaotleja

Otsi eesti lehti ▾ 1. jaan 2014–31. dets 2018 ▾ Köik tulemused ▾ Tühjenda

[m.facebook.com › muudamaailma › posts](#)

Pagulane - Facebook

20. juuni 2017 - Täna on ülemaailmne pagulaspäev. Kuigi Eestis võib viimastel aastatel jäädva mulje, et "pagulane" on justkui sõimusõna, on täna see hetk, kus vaadata...

[www.facebook.com › pagulasabi › posts › eesti-päevale... ▾](#)

Eesti Päevaleht on pannud kokku... - Eesti Pagulasabi ...

4. aug 2015 - Eesti Päevaleht on pannud kokku infograafikud ümberpaigutamise ja -asustamise raames Eestisse saabuvate pagulaste kohta. Kust nad tulevad ja mis neist...

Joonis 10. Otsingutulemuste ajalise piirangu määramine

- ❖ Kui olete sõnastanud piisavalt täpse päringu, koostage otsitulemustest (st veebiaadressidest) kas käsitsi või kraapija abil nimekiri.
- ❖ Toimetage otsitulemuste nimekirja. Nt eemaldage korduvad veebiaadressid, kontrollige, kas tegu on avaliku Facebooki lehe aadressiga (kui mitte, siis eemaldage nimekirjast), viige veebiaadressid standardsele kujule (nt facebook.com/leheaadress).
- ❖ Kasutades veebiaadresside nimekirja, tuvastage iga Facebooki lehe unikaalne ID-kood. Vastavaid päringuid saab läbi viia nt veebilehel <https://findmyfbid.com/>. Koostage Facebooki lehtede ID-koodidest nimekiri.

1.3. Andmekogumis- ja andmeanalüüsitarvvara allalaadimine ja paigaldamine

- ❖ Andmekogumiseks paigaldage arvutisse Facepageri tarkvara. Facepager on mõeldud veebilehtedelt avalike andmete kogumiseks kas rakendusliidest kaudu, kraapimise või failide allalaadimise teel (Jünger & Keyling, 2020).
 - Laadige Facepager alla siit: <https://github.com/strohne/Facepager>.
 - Facepageri kasutusjuhend: <https://github.com/strohne/Facepager/wiki>.
- ❖ Meelestatusanalüüs ja teema mudeldamise jaoks paigaldage värskeim Pythoni Anaconda versioon. Python on vabavaraline programmeerimiskeel, millele on loodud arvukalt teeke, mis pakuvad mitmekesiseid võimalusi andmeanalüüsiks (Python Software Foundation, 2020). Võrreldes nt R-iga on Pythonis eestikeelsete tekstide eeltöötuseks avaramad võimalused, seda eeskätt tänu estnltk teegile. Pärast Pythoni installimist looge vähemalt Pythoni 3.5 või uuemal versioonil põhinev keskkond, kuhu paigaldage koodi hõlpsamaks muutmiseks, salvestamiseks ja käivitamiseks [Jupyter Notebooki](#) tarkvara ning analüüsiks vajalikud teegid: [pandas](#), [numpy](#), [re](#), [langdetect](#), [estnltk](#), [sklearn](#) ja [gensim](#).
 - Laadige Pythoni Anaconda versioon alla siit: <https://www.anaconda.com/products/individual>.
 - Sissejuhatus Pythonisse: <https://progeopik.cs.ut.ee/>.
- ❖ Jooniste-tabeliste tegemiseks ja statistilise andmeanalüüs jaoks paigaldage R ja RStudio. R on vabavaraline programmeerimiskeel, mis pakub häid võimalusi nii andmeanalüüsiks kui jooniste tegemiseks, ning RStudio on kasutajaliides, mis hõlbustab R-i kasutamist (Kolnes, 2020).
 - Laadige R alla siit: <https://cran.r-project.org/>.
 - Laadige RStudio alla siit: <https://rstudio.com/products/rstudio/>.
 - Sissejuhatus R-i ja RStudiosse: <http://samm.ut.ee/sissjuhatus-r-i-ja-rstudiosse>.

2. ANDMEKOGUMINE FACEPAGERIGA


Facepageri kogub Facebookist andmeid suheldes Facebooki Graphi rakendusliidesega (vt [Facebook, 2020a](#)). See, milliseid andmeid Graphi rakendusliidese kaudu koguda saab, on sageli muutunud ning lisanduvateks piiranguteks tuleks valmis olla ka edaspidi. Näiteks tuleb arvestada, et Graphi rakendusliides ei võimalda koguda iga avaliku Facebooki lehe kõiki postitusi, vaid ligikaudu 600 postitust aasta kohta (Facebook, 2020b). Seda, milliseid andmeid soovite Facepageri abil Facebookist koguda, tuleks aga täpsustada eelsätetes, mida on soovitatav talletada JSON-formaadis. JSON on andmehetetusvorming, mis hõlbustab andmehetust erinevate programmeerimiskeelte vahel ning koosneb nimi-väärtus-paaridest ja järjestatud jadadest (Ecma International, 2017). Käesolev peatükk annab põgusa ülevaate, kuidas kirjutada JSON-formaadis Facepageri eelsätted, samad eelsätted Facepageris laadida, luua andmebaasifail, lisada Facebooki ligipääsuvõti (*access token*), käivitada andmekogumine ning kogutud andmed CSV-failina eksportida.

2.1. JSON-formaadis eelsätete loomine

- ❖ Allpool on JSON-kood, mis sisaldb eelsätteid Facebooki postituste kogumiseks Facepageriga. Nende eelsätete järgi kogutakse andmeid järgmiste tunnuste lõikes: Facebooki lehe ID-kood ja nimi, postituse sisu, avaldamise ja viimase muutmise aeg, postituse püsiliink, laikide, kommentaaride, jagamiste ja erinevate reaktsioonide arv. Kopeerige alljärgnev JSON-kood, avage Notepad või mõni muu analoogne tekstitöötlusprogramm ja kleepige see sinna:


```
{  
    "description": "Avalike Facebooki lehtede postitused koos laikide, kommentaaride, jagamiste ja reaktsioonide arvuga. Samuti sisaldavad andmed Facebooki lehe ID-koodi ja nime, postituse avaldamise ja muutmise aega ning püsiliinki.",  
    "module": "Facebook",  
    "speed": 200,  
    "options": {  
        "params": {  
            "fields": "from, message, created_time, updated_time, permalink_url,  
            likes.limit(0).summary(true), comments.limit(0).summary(true), shares.limit(0).summary(true),  
            reactions.type(LOVE).limit(0).summary(1).as(reactions_love),  
            reactions.type(WOW).limit(0).summary(1).as(reactions_wow),  
            reactions.type(HAHA).limit(0).summary(1).as(reactions_haha),  
            reactions.type(SAD).limit(0).summary(1).as(reactions_sad),  
            reactions.type(ANGRY).limit(0).summary(1).as(reactions_angry)",  
            "<page>": "<Object ID>",  
            "since": "2020-01-01",  
            "until": "2020-03-31"  
        },  
        "basepath": "https://graph.facebook.com/v2.12/",  
        "resource": "<page>/feed",  
        "pages": 50000,  
        "scope": ""  
    },  
    "columns": [  
        "from.id",  
        "from.name",  
        "message",  
        "created_time",  
        "updated_time",  
        "permalink_url",  
        "likes.summary.total_count",  
        "comments.summary.total_count",  
        "shares.count",  
        "reactions_love.summary.total_count",  
        "reactions_wow.summary.total_count",  
        "reactions_haha.summary.total_count",  
        "reactions_sad.summary.total_count",  
        "reactions_angry.summary.total_count"  
    ],  
    "name": "Facebooki postitused"
```

- ❖ Kui olete JSON-koodi tekstitöötlusprogrammi kleepinud, tuleks koodis kindlasti muuta kogutavate postituste avaldamisperioodi. Selleks muutke perioodi algus- ("since") ja lõppkuupäeva ("until"), järgides kuupäeva vormingut "AAAA-KK-PP". Soovi korral on võimalik täpsustada ka kogutavaid tunnuseid, kuid selleks tuleb koodis muuta nii andmevälju ("fields") kui ka andmestiku veergusid ("columns"). Andmeväljade ja veergude muutmisel on näidistena abiks Facepageri vaike-eelsätete kaustast ("C:\Users\Username\Facepager\DefaultPresets") leitavad JSON-failid, samuti Facepageri kasutusjuhend ([Jünger & Keyling, 2020](#)) ja Facebooki Graphi rakendusliidese dokumentatsioon ([Facebook, 2020a](#)).
- ❖ Eelsätete JSON-formaadis salvestamiseks vali Notebookis kõigepealt "Fail" > "Salvesta" (vt joonis 11).



Joonis 11. Eelsätete salvestamine: "Fail" > "Salvesta"


- ❖ Seejärel valige faili salvestamise asukohaks Facepageri eelsätete kaust ("C:\Users\Username\Facepager\Presets"). Määra faili nimi, järgides vormingut *failinimi.3_9.json*. Salvestage fail, klõpsates "Salvesta" (vt joonist 12). Pärast salvestamist sulgege loodud JSON-fail.



Joonis 12. Eelsätete salvestamine: faili asukoha ja nime valimine


2.2. Andmekogumine

- ❖ Avage Facepager ja alustage uue andmebaasi loomist, valides “New Database” (vt joonist 13).




Joonis 13. Uue andmebaasi loomine: valik “New Database”

- ❖ Valige andmebaasile asukoht kõvakettal ja nimi ning kinnitage need, klõpsates “Salvesta” (vt joonist 14).




Joonis 14. Uue andmebaasi loomine: faili asukoha ja nime valimine

- ❖ Logige Facepageri kaudu enda Facebooki kontole sisse. Sisselogimine on vajalik ligipääsuvõtme (*access token*) saamiseks. Selleks klõpsake valikul “*Login to Facebook*” ja sisestage hüpinknas enda meiliaadress ja salasõna (vt joonist 15).




Joonis 15. Facepageri kaudu Facebooki sisselogimine

- ❖ Sisestage nende avalike Facebooki lehtede ID-koodid, mille andmeid soovite koguda (vt [alapeatükki 1.3](#)). Selleks valige “*Add Nodes*”, sisestage ID-koodid uues aknas nii, et iga ID-kood on eraldi real, ja klõpsake “*OK*” (vt joonist 16). Mahukamate andmehulkade korral on soovitatav koguda andmeid väiksemate osadena ja jaotada päringud pikema aja peale, et tulenevalt ühistest andmekogumispiorangutest arvestada ka Facepageri tarkvara teiste kasutajatega.




Joonis 16. Avalike Facebooki lehtede ID-koodide lisamine

- ❖ Laadige eelnevalt loodud päringu eelsätted. Selleks valige „Presets“ > „Facebook“ > „Facebooki postitused“ ning kinnitage valik, klõpsates „Apply“ (vt joonist 17).




Joonis 17. Eelsätete laadimine

- ❖ Hoides all vasakut hiireklahvi märgistage kõik Facepageris kuvatud Facebooki lehtede ID-koodid. Seejärel vajutage „Fetch Data“, et alustada päringut Facebooki Graphi rakendusliidese kaudu (vt joonist 18).



Joonis 18. Andmekogumise käivitamine

- ❖ Kogutud andmete salvestamiseks CSV-failina kõvakettale vajutage "Export Data", valige failile asukoht ja nimi ning kinnitage valikud klõpsates "Save" (vt joonist 19).



Joonis 19. Kogutud andmete salvestamine CSV-failina

3. MEELESTATUSANALÜÜS JA TEEMA MUDELDAKSE PYTHONI JA R-IGA

Meelestatusanalüüs (*sentiment analysis*) kasutatakse hoiakute automaatseks tuvastamiseks tekstides, kui on vaja uurida mahukaid tekstikorpuseid (vt [Liu, 2015](#)). Meelestatusanalüüs koosneb mitmest etapist: eeltöötlusest (nt suurtähtede asendamine väiketähtedega, numbrite ja kirjavahemärkide eemaldamine, kirjavigade parandamine, lemmatiserimine ehk sõnade algvormis

esitamine, sõnade vektoriseerimine), juhendatud masinõppe korral ka klassifitseerija treenimisest, klassifitseerija täpsuse hindamisest, teksti meelestatuse automaatsest tuvastamisest.

Käesolev juhend näpunäiteid juhendatud masinõppel põhinevaks meelestatusanalüüsiks. Juhendatud masinõpe tähendab, et statistilist mudelit, mille alusel tekstides hoiakuid tuvastatakse, on vaja eelnevalt treenida ja mudeli täpsust testida. Selleks tuleb uurijal valida juhuslikult teatud arv tekste (nt 1000 Facebooki postitust), lisada andmestikule käsitsi meelestatusandmed (nt kas postituses on väljendatud positiivset või negatiivset hoiakut), ning jagada tekstdid kaheks osaks: treening- (nt 800 postitust) ja testandmestikuks (nt 200 postitust). Treeningandmestikkku kasutatakse klassifitseerija treenimiseks ja testandmestikkku klassifitseerija täpsuse hindamiseks. Seejärel tuvastatakse treenitud klassifitseerija abil ülejäänuud tekstile meelestatus.

Teema mudeldamine (*topic modeling*) võimaldab seevastu kaardistada suurtes tekstikorpustes esinevaid teemasid (vt [Alghamdi & Alfalqi, 2015](#)). Sarnaselt meelestatusanalüüsile koosneb ka teema mudeldamine mitmest etapist, sealhulgas on vajalik tekstile eeltöötlus. Käesolev peatükk keskendub juhendamata masinõppel põhinevale teema mudeldamisele. Juhendamata masinõpe tähendab, et teemad tuvastatakse statistilise mudeli alusel, mis võimaldab tekstides esinevaid sõnu klasterdada, ning erinevalt juhendatud masinõppest pole mudeli eelnev treenimine vajalik. Väljundiks on teemad kui teatud koosesinevate sõnade kogumikud. Mudeli sobivust tuleks hinnata nii koherentsusnäitaja kui teemade sisulise interpreteeritavuse põhjal. Loodud teema mudelit on võimalik seejärel kasutada ka postituste klassifitseerimiseks tekstis esinevate teemade alusel.

Peatükist võib leida Pythoni koodi Facebooki postituste eeltöötluseks ning meelestatuse ja teema alusel klassifitseerimiseks, samuti R-i koodi näited tabelite ja jooniste tegemiseks ning statistilise analüüsi läbiviimiseks (nt Crameri V seosekordaja arvutamiseks ja dispersioonanalüüsiks).

3.1. Eeltöötlus (Python)

Eeltöötluse juhised on jagatud kolmeks osaks: 1) teksti puastamine ja lemmatiseerimine (vajalik nii meelestatusanalüüs kui teema mudeldamise jaoks), 2) andmestiku osadeks jagamine ja käsitsi märgendamine (vajalik ainult meelestatusanalüüs jaoks), 3) teksti vektoriseerimine (vajalik ainult meelestatusanalüüs jaoks).

3.1.1. Teksti puastamine ja lemmatiseerimine

Tuvastage postituste keel ja filtreerige postitusi keele alusel (mõningatel Facebooki lehtedel võib esineda erinevates keeltes postitusi), eemaldage postitustest URLid, teemaviited, mainimised, numbrid, kirjavahemärgid, üleliigsed tühikud ja sagedesed, kuid väheinformatiivsed sõnad, asendage suurtähed väiketähtedega, parandage kirjavead ja lemmatiseerige tekstdid ehk esitada sõnad algormis.

```
# Teekide ja moodulite importimine
import pandas as pd
import re
from langdetect import detect
from estnltk import Text
from estnltk import Disambiguator
from estnltk.names import TEXT, ANALYSIS, ROOT, POSTAG, FORM
```

```

# CSV-formaadis andmestiku sisselugemine
df = pd.read_csv('/home/sander/Documents/Uuring/andmed.csv', encoding = 'utf-8')

# Postituste keele tuvastamine
posts = df['message'].tolist()

languages = []
for x in posts:
    try:
        language = detect(x)
    except:
        language = "error"
    languages.append(language)

# Keeleandmete salvestamine andmestikku
df['language'] = languages

# Võõrkeelseste postituste eemaldamine
df = df[df.language == 'et']

# URLide eemaldamine
posts = df['message'].tolist()
posts =
[re.sub('^(http(s)?:\/\/.)?(www\.)?[-a-zA-Z0-9@:%._\+~#=]{0,}}\.[a-z]{2,4}\b([-a-zA-Z0-9@;%_\+.\~#?\&\\=\\(\()]*|", x) for x in posts]

# Hashtag'ide ehk teemaviidete eemaldamine (nt #ränne)
posts = [re.sub('#\w+', '', x) for x in posts]

# Maninimiste eemaldamine (nt @Mari_Tamm)
posts = [re.sub('@\w+', '', x) for x in posts]

# Kirjavigade automaatne parandamine
corrected_posts = []
for text_str in posts:
    text = Text(text_str)
    corrections = text.fix_spelling()
    corrected_posts.append(corrections)

# Kirjavigade parandamise käigus tekkinud andmestruktuuri muutuse
korrigeerimine, ettevalmistamine lemmatiseerimiseks
corr_p = []
for x in corrected_posts:
    temp = list(x.values())

```

```

corr_p.append(temp)

corrected_posts = []
for x in corr_p:
    for i in x:
        temp = re.sub('\s+', ' ', i)
        temp = [temp.strip()]
    corrected_posts.append(temp)

# Teksti lemmatiseerimine ehk sõnade esitamine algvormis, tulemuste salvestamine listi.
Mugandatud versioon Kristel Uiboaia (2017) koodist
disamb = Disambiguator()
lemmas = []
for x in corrected_posts:
    text = disamb.disambiguate(x)
    for analysis in text:
        temp_lemmas = []
        for word in analysis.words:
            first_analysis = word[TEXT], word[ANALYSIS][0][ROOT], word[ANALYSIS][0][POSTAG],
word[ANALYSIS][0][FORM]
            if first_analysis[2] == 'V' and first_analysis[1] != "ei" and first_analysis[1] != "ära":
                temp_lemmas.append(re.sub("[=_]", "", first_analysis[1]) + 'ma')
            elif first_analysis[2] == 'Y':
                temp_lemmas.append(re.sub("[=_]", "", first_analysis[1]))
            else:
                temp_lemmas.append(re.sub("[=_]", "", first_analysis[1]))
        lemmas.append(temp_lemmas)

# Lemmade ühendamine sõnedeks
lemmas = [' '.join(x) for x in lemmas]

# Suurtähed väketähitedeks
lemmas = [x.lower() for x in lemmas]

# Kirjavahemärkide eemaldamine
lemmas = [re.sub('[^\w\s]', '', x) for x in lemmas]

# Numbrite eemaldamine
lemmas = [re.sub('\d+', '', x) for x in lemmas]

# Sagedaste, kuid ebainformatiivsete sõnade eemaldamine (nt asesõnad, sidesõnad, verbid
'olema', 'saama', 'hakkama')
lemmas =
[re.sub('(?<![a-z])(mina|sina|tema|teie|see|too|ja|ning|ega|ehk|või|kui|ka|ehkki|kuigi|kuid|a
ga|ent|est|seepärast|toopärast|sestap|küllap|kuna|et|kui|siis|vaid|kes|mis|millal|mil|kas|k

```

```

uidas|kus|kuhu|kust|miks|millepärist|milleks|nagu|justkui|otsekui|missugune|milline|selline|
niisugune|mitmes|olema|saama|hakkama)(?[a-z])', ', x) for x in lemmas]

# Üleliigsete tühikute eemaldamine
lemmas = [re.sub('\s+', ' ', x.strip()) for x in lemmas]

# Puhastatud postituste salvestamine andmestikku
df['message_clean'] = lemmas

# Andmestiku salvestamine kövakettale
df.to_csv('/home/sander/Documents/Uuring/puhastatud_andmed.csv', encoding = 'utf-8', index =
False)

```

Valikuline: eeltöötuse eri etappides, nt filtersõnade ja eemaldatavate sagedaste sõnade valikul, võib olla abi sõnade esinemissageduse analüüsist. Sõnade esinemissagedusi saab uurida alamklassi *Counter* abil. Alljärgnevas näites on kasutatud sama listi *lemmas*, mida ülalpoolgi. Eemaldatavate sõnade valikul võib abi olla ka eesti kirjakeele sagedussõnastikust ([Kaalep & Muischnek, 2002](#)).

```

# Alamklassi Counter importimine
from collections import Counter

# Sõnede ühendamine
tokenized_words = ' '.join(lemmas)

# Lemmade tokeniseerimine
tokenized_words = tokenized_words.split()

# Lemmade sagedusanalüüs
counter = Counter(tokenized_words)

# Kõige sagedasemate lemmade kuvamine (sulgudes märgitud arv määrab ekraanil kuvatavate lemmade arvu)
top_lemmas = counter.most_common(100)
print(top_lemmas)

# Kõige vähem kasutatud lemmade kuvamine (esimene kandilistes sulgudes olev arv määrab kuvatavate lemmade arvu)
rare_lemmas = counter.most_common()[:-50000-1:-1]
print(least_common)

# Kui huvipakkuvaid tulemusi on palju, on otstarbekam salvestada need CSV-faili ja uurida lähemalt tabelarvutusprogrammis (nt Microsoft Excelis, LibreOffice Calcis)
rare_lemmas = pd.DataFrame(rare_lemmas)
rare_lemmas.to_csv('/home/sander/Documents/Uuring/harvaesinevad_lemmad.csv', encoding =
'utf-8', index = False)

```

3.1.2. Andmestiku osadeks jagamine ja postituste käsitsi märgendamine

Enne teksti käsitsi märgendamist tuleks andmestik jagada juhuslikkuse alusel kaheks osaks: üks osa (nt 1000 postitust) käsitsi märgendamiseks ja teine osa automaatse analüüsiga jaoks. Kui mõlemad failid on kövakettale salvestatud, tuleks avada esimene fail *kodeerimiseks.csv* mõnes tabelarvutusprogrammis, nt Excelis või LibreOffice Calcis, seejärel luua uus tulp *sentiment*, kuhu märkida iga postituse meelestatus, ning muudatused salvestada.

```
# Postituste järjekorra muutmine andmestikkus juhuslikkuse alusel
df = df.sample(frac = 1).reset_index(drop = True)

# Andmestiku jagamine kaheks uueks andmestikuks:
# 1) ühes andmestikus ('df1') 1000 postitust käsitsi märgendamise jaoks,
# 2) teises andmestikus ('df2') kõik ülejäänud postitused automaatse analüüsiga jaoks.
df1 = df.iloc[:1000]
df2 = df.iloc[1000:]

# Mõlema andmestiku salvestamine kövakettale
df1.to_csv('/home/sander//Documents/Uuring/kodeerimiseks.csv', encoding = 'utf-8', index = False)
df2.to_csv('/home/sander/Documents/Uuring/mittekodeerimiseks.csv', encoding = 'utf-8', index = False)
```

Käesolevat juhendit luues andis kõige täpsemaaid tulemusi märgendamisviisi, mis eristab meelestatuse kolme kategooriat:

- ❖ -1 = tugevalt negatiivne hoiak;
- ❖ 0 = nõrgalt negatiivne, nõrgalt positiivne või neutraalne hoiak;
- ❖ 1 = tugevalt positiivne hoiak.

Tugevalt negatiivne või tugevalt positiivne hoiak iseloomustab postitusi, milles on avaldatud arvamust kõigi migrantide (nt "sisserändajad") või väga suure rühma migrantide kohta (nt "aafriklased") ning väljendatud seejuures kas tugevat vastuseisu või tugevat poolehoidu. Nõrgalt negatiivsete või nõrgalt positiivsete postituste korral on käsitletud mõnd üksikjuhtumit (nt "Vao pagulaskeskuses elav pagulane") või väikest hulka migrante (nt "Tallinnas elavad sisserändajad"), samuti on avaldatud arvamust nt migrantide üldise sobivuse ja kohanemisvõime kohta sihtriigi ühiskonnas. Neutraalsete postituste puhul pole aga selget meelestatust migrantide suhtes võimalik tuvastada.

3.1.3. Teksti vektoriseerimine

Järgmiseks vektoriseerige tf-idf tehnika abil postitustes esinevad sõnad. Tf-idf vektoriseerimistehnika võimaldab omistada igale sõnale kaalu, mis näitab sõna olulisust postituses, võttes arvesse ka selle esinemissagedust tekstikorpuses üldiselt (What..., [2020]).

```

# Teekide ja moodulite importimine
import pandas as pd
from sklearn.feature_extraction.text import TfidfVectorizer

# CSV-formaadis andmestike sisselugemine:
# 1) 'df' sisaldab kogu andmestikku,
# 2) 'df1' sisaldab kätsi märgendatud andmeid (meelestatus lisatud),
# 3) 'df2' sisaldab märgendamata andmeid (ülejäänud andmed, kus meelestatus puudu)
df = pd.read_csv('/home/sander/Documents/Uuring/puhastatud_andmed.csv', encoding = 'utf-8')
df1 = pd.read_csv('/home/sander/Documents/Uuring/kodeerimiseks.csv', encoding = 'utf-8')
df2 = pd.read_csv('/home/sander/Documents/Uuring/mittekodeerimiseks.csv', encoding = 'utf-8')

# Kätsi märgendatud andmestiku jagamine treening- (800 postitust) ja testandmestikuks (200
postitust)
df1 = df1.sample(frac = 1).reset_index(drop = True)
train = df1.iloc[:800]
test = df1.iloc[800:]

# Uuritavate postituste tekstide ja meelestatusandmete salvestamine listidesse
posts = df['message_clean'].tolist() # Kõik postitused
train_posts = train['message_clean'].tolist() # Treeningandmestiku postitused
train_sentiments = train['sentiment'] # Treeningandmestiku postituste meelestatus
test_posts = test['message_clean'] # Testandmestiku postitused
test_sentiments = test['sentiment'] # Testandmestiku postituste meelestatus
analysis_posts = df2['message_clean'] # Ilma meelestusandmeteta postitused, mida automaatselt
# analüüsida

# TF-IDF tunnuste maatriksi loomine ja normaliseerimine, kasutades kõiki postitusi
tfidf_vect = TfidfVectorizer(max_features=300)
tfidf_vect.fit_transform(posts)

# Treiningandmestiku postituste vektoriseerimine
train_X_tfidf = tfidf_vect.transform(train_posts)

# Testandmestiku postituste vektoriseerimine
test_X_tfidf = tfidf_vect.transform(test_posts)

# Ilma meelestusandmeteta postituste vektoriseerimine
analysis_X_tfidf = tfidf_vect.transform(analysis_posts)

```

3.2. Postituste meelestatuse tuvastamine (Python)

Treenige klassifitseerija, hinnake selle täpsus ning määrase automaatselt ka märgendamata postituste meelestatus.

Kasutage klassifitseerimiseks multiklassilist tugivektormasinat (SVM): tugivektormasina mudel võimaldab jagada andmeid kahe kategooria vahel (nt “positiivne” ja “negatiivne”), multiklassilist

mudelit kasutatakse kui kategooriaid on rohkem kui kaks (nt “tugevalt negatiivne”, “nõrgalt positiivne / nõrgalt negatiivne / neutraalne”, “tugevalt positiivne”). Viimasel juhul klassifitseerib mudel tekste n-ö üks-ühe-vastu-põhimõttel: nt kõigepealt jaotab tekstdid kategooriate “tugevalt negatiivne” ja “tugevalt positiivne” vahel, siis “tugevalt negatiivne” ja “nõrgalt positiivne / nõrgalt negatiivne / neutraalne” jne.

```
# Teekide ja moodulite importimine
from sklearn import svm
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_recall_fscore_support

# Klassifitseerija treenimine
svm_model = svm.SVC()
svm_model = svm_model.fit(X = train_X_tfidf, y = train_sentiments)

# Klassifitseerija testimine
y_pred = svm_model.predict(test_X_tfidf)

# Tulemuste täpsuse hindamine
accuracy_score(test_sentiments, y_pred)

# Ülejäänud postituste meelestatuse automaatne tuvastamine
y_analysis = svm_model.predict(analysis_X_tfidf)

# Meelestatusandmete salvestamine andmestikku
df2['sentiment'] = y_analysis

# Kätsitsi ja automaatselt määratud meelestatusega andmestike ühendamine üheks andmestikuks
sentiment_data = df1.append(df2, sort = False)

# Andmestiku salvestamine kövakettale
sentiment_data.to_csv('/home/sander/Documents/Uuring/meelestatusandmed.csv', encoding =
'utf-8', index = False)
```

3.3. Postituste teemade tuvastamine (Python)

Teema mudeldamise läbiviimiseks looge hierarhilise Dirichlet’ protsessi (HDP) mudel. HDP-mudeli üks eripärasid on, et mudeli loomiseks pole uurijal endal vaja määrata korpuses esinevate teemade arvu (vt ka [Wang, Paisley & Blei, 2011](#)). HDP-mudeli loomise järel hinnake mudeli koherentsust ja teemade sisulist interpreteeritavust ning kasutage mudelit postituste klassifitseerimiseks neis esinevate teemade alusel.

```
# Teekide ja moodulite importimine
import pandas as pd
import numpy as np
from gensim.corpora.dictionary import Dictionary
from gensim.models.hdpmodel import HdpModel
```

```

from gensim.models import CoherenceModel

# Andmestiku sisselugemine
sentiment_data = pd.read_csv('/home/sander/Documents/Uuring/meelestatusandmed.csv',
encoding = 'utf-8')

# Postituste salvestamine listi
posts = sentiment_data['message_clean'].tolist()

# Sõnade tokeniseerimine postitustes
prepared_posts = []
for x in posts:
    temp = x.split(' ')
    prepared_posts.append(temp)

# Tekstikorpuse loomine
posts_dictionary = Dictionary(prepared_posts)
posts_corpus = [posts_dictionary.doc2bow(text) for text in prepared_posts]

# HDP mudeli loomine
hdp = HdpModel(corpus = posts_corpus, id2word = posts_dictionary, random_state = 1234)

# Kõige sagestdasemate teemade kuvamine ekraanil ('num_topics' näitab kuvatavate teemade arvu ja 'num_words' iga teema juures kuvatavate sõnade arvu)
hdp_topics = hdp.print_topics(num_topics = 200, num_words = 5)
for topic in hdp_topics:
    print(topic)

# Teemade koherentsuse arvutamine
hdp_cm = CoherenceModel(model = hdp, corpus = posts_corpus, dictionary = posts_dictionary,
texts = prepared_posts, coherence = 'c_v')
HDP_cm = hdp_cm.get_coherence()
HDP_cm

# Iga postituse peamise teema tuvastamine (teema n-ö nimena on kasutatud nimekirja viiest kõige iseloomulikumast sõnast). Mugandatud versioon Animesh Pandey (2013) koodist.
topics = []
for text_vec in posts_corpus:
    topic_vec = []
    topic_vec = hdp[text_vec]
    word_count_array = np.empty((len(topic_vec), 2), dtype = np.object)
    for i in range(len(topic_vec)):
        word_count_array[i, 0] = topic_vec[i][0]
        word_count_array[i, 1] = topic_vec[i][1]
    idx = np.argsort(word_count_array[:, 1])

```

```

idx = idx[::-1]
word_count_array = word_count_array[idx]
final = []
final = hdp.print_topic(word_count_array[0, 0], 5)
topics.append(final)

# Postituste peamiste teemade salvestamine andmestikku
sentiment_data['topic'] = topics

# Andmestikku salvestamine kõvakettale
sentiment_data.to_csv('/home/sander/Documents/Uuring/meelestatusandmed.csv', encoding =
'utf-8', index = False)

```

3.4. Jooniste ja tabelite tegemine, statistiline analüüs (R)

Alljärgnev R-i kood sisaldab näiteid, kuidas luua uusi tunnuseid, tabelleid ja joonised, arvutada Crameri V seosekordaja väärtsusi ja viia läbi dispersioonanalüüs. Crameri V seosekordaja on hii-ruut-statistikust edasi arendatud seosekordaja, mille väärtsus näitab kahe nominaal- või järjestustunnuse vahelise seose tugevust ja võib olla vahemikus 0–1 (vt [Rootalu, 2014](#)). Dispersioonanalüüs ehk ANOVA võimaldab võrrelda kahe tunnuse lõikes rühmade keskmisi ja hinnata keskmiste erinevuse statistilist olulisust (vt [Tooding, 2014](#)).

```

# Pakettide laadimine
library('readr')
library('questionr') # Vajab eelnevat paigaldamist: install.packages('questionr')

# Andmestiku sisselugemine
df = read_csv('/home/sander/Documents/Uuring/meelestatusandmed.csv')

# Uue tunnuse loomine tulemuste filtreerimise teel: postitamisaasta (nt '2015-07-23 06:47:28'
# asemel '2015')
df$year = NA # Uue tunnuse 'year' loomine
df$year[grep('2014', df$created_time) == TRUE] = '2014' # Kui tunnus 'created_at' väärtsus
# sisaldab fragmenti '2014', siis on tunnuse 'year' väärtsus '2014'
df$year[grep('2015', df$created_time) == TRUE] = '2015' # Kui tunnus 'created_at' väärtsus
# sisaldab fragmenti '2015', siis on tunnuse 'year' väärtsus '2015'
df$year[grep('2016', df$created_time) == TRUE] = '2016' # Kui tunnus 'created_at' väärtsus
# sisaldab fragmenti '2016', siis on tunnuse 'year' väärtsus '2016'
df$year[grep('2017', df$created_time) == TRUE] = '2017' # Kui tunnus 'created_at' väärtsus
# sisaldab fragmenti '2017', siis on tunnuse 'year' väärtsus '2017'
df$year[grep('2018', df$created_time) == TRUE] = '2018' # Kui tunnus 'created_at' väärtsus
# sisaldab fragmenti '2018', siis on tunnuse 'year' väärtsus '2018'

# Uue tunnuse loomine olemasolevate tunnuste kokkuliitmise teel: interaktsioonide arvu
# (jagamiste, kommentaaride, laikide ja reaktsioonide summa) leidmine
df$interactions = NA # Uue tunnuse 'interactions' loomine

```

```

df$interactions = df$likes + df$comments + df$shares + df$reactions_love + df$reactions_wow +
df$reactions_haha + df$reactions_sad + df$reactions_angry # Tunnuste kokkuliitmine

# Sagedustabeli loomine: postituste arv aastate lõikes
table(df$year)

# Sagedustabeli põhjal joonise loomine: postituste arv aastate lõikes; plot() funktsioon joonise
loomiseks ja text() punktide juurde väärustuse lisamiseks
plot(names(table(df$year)), # Aastad (tabelist eraldamiseks vajalik names() funktsioon)
      as.vector(table(df$year)), # Postituste arv (tabelist eraldamiseks vajalik as.vector() funktsioon)
      main = 'Postituste arv', # Joonise pealkiri
      ylab = ' ', # X-telje nimi
      xlab = ' ', # Y-telje nimi
      xlim = c(2014, 2018), # X-telje miinimum- ja maksimumväärus
      ylim = c(0, 4500), # Y-telje miinimum- ja maksimumväärus
      type = 'b', # Joonise tüüp
      pch = 17, # Punktide kuju
      cex = 1.2, # Punktide suurus
      col = 'dodgerblue', # Joonise värv
      bty = 'L') # Joonise raami kuju
text(names(table(df$year)), # Aastad (tabelist eraldamiseks vajalik names() funktsioon)
      as.vector(table(df$year)), # Postituste arv (tabelist eraldamiseks vajalik as.vector() funktsioon)
      labels = as.vector(table(df$year)), # N-ö tekst (postituste arv) punktide juurde lisamiseks
      pos = 3, # Teksti asukoht punktide suhtes
      col = 'dodgerblue', # Teksti värv
      cex = 1, # Teksti suurus
      font = 1, # Šrift (püstkiri)
      family = 'sans') # Kirjatüüp

# Risttabeli loomine: meeestatus ja Facebooki lehe tüüp (absoluutarvud)
table(df$page_type, df$sentiment)

# Risttabeli loomine: meeestatus ja Facebooki lehe tüüp (reaprotsendid, ümardatud sajandikeni)
round(prop.table(table(df$page_type, df$sentiment), 1) * 100, 2)

# Seosekordaja Crameri V ja p-väärtuse arvutamine: seos Facebooki lehe tüibi ja meeestatuse
vahel
round(cramer.v(table(df$page_type, df$sentiment)), 2) # Crameri V, ümardatud sajandikeni
chisq.test(table(df$page_type, df$sentiment)) # p-väärtus

# Dispersioonanalüs ehk ANOVA: interaktsioonide arv ja meeestatus
tulemus1 = aov(interactions ~ factor(sentiment), data=df)
summary(tulemus1)

# Tukey HSD test

```

KASUTATUD KIRJANDUS

Alghamdi, R., & Alfalqi, K. (2015). A Survey of Topic Modeling in Text Mining. *International Journal of Advanced Computer Science and Applications* 6(1), 147–153. Kasutatud:

https://www.researchgate.net/publication/276327703_A_Survey_of_Topic_Modeling_in_Text_Mining

Digital Methods Initiative (2015). *The research browser*. Kasutatud:

<https://www.youtube.com/watch?v=bj65Xr9GkJM>

Ecma International (2017). *Standard ECMA-404. The JSON data interchange syntax*. Kasutatud:

<http://www.ecma-international.org/publications/files/ECMA-ST/ECMA-404.pdf>

Facebook (2020a). *Graph API*. Kasutatud: <https://developers.facebook.com/docs/graph-api>

Facebook (2020b). *Page feed*. Kasutatud:

<https://developers.facebook.com/docs/graph-api/reference/v7.0/page/feed>

Jünger, J., & Keyling, T. (2020). *What is Facepager?* Kasutatud:

<https://github.com/strohne/Facepager/wiki>

Kaalep, H.-J., & Muischnek, K. (2002). *Eesti kirjakeele sagedussõnastik*. Tartu: Tartu Ülikooli Kirjastus.

Kasutatud: <https://www.cl.ut.ee/ressursid/sagedused/index.php?lang=et>

Kalmus, V. (2015). Standardiseeritud kontentanalüüs. *Sotsiaalse analüüsi meetodite ja metodoloogia õpibaas*. Kasutatud: <http://samm.ut.ee/kontentanalyys>

Kolnes, M. (2020). Sissejuhatus R-i ja RStudiosse. *Sotsiaalse analüüsi meetodite ja metodoloogia õpibaas*. Kasutatud: <http://samm.ut.ee/sissjuhatus-r-i-ja-rstudiosse>

Liu, B. (2015). *Sentiment analysis: Mining opinions, sentiments, and emotions*. Cambridge: Cambridge University Press.

Pandey, A. (2013). *How to predict the topic of a new query using a trained LDA model using gensim?* Kasutatud:

<https://stackoverflow.com/questions/16262016/how-to-predict-the-topic-of-a-new-query-using-a-trained-lda-model-using-gensim/29218397>

Python Software Foundation (2020). *About*. Kasutatud: <https://www.python.org/about/>

Rogers, R. (2019). *Doing digital methods*. London: Sage.

Rootalu, K. (2014). Risttabelid ja seosekordajad. *Sotsiaalse analüüsi meetodite ja metodoloogia õpibaas*. Kasutatud: <http://samm.ut.ee/risttabelid-ja-seosekordajad>

Salvet, S. (2020). Hoiakud rände ja migrantide suhtes eestikeelsetes sotsiaalmeediapostitustes. RITA-RÄNNE projekt.

Sotsiaalse analüüsi meetodite ja metodoloogia õpibaas. (2014). Kasutatud:
<http://samm.ut.ee/avaleht>

Tooding, L.-M. (2014) Dispersioonanalüüs. *Sotsiaalse analüüsi meetodite ja metodoloogia õpibaas*. Kasutatud: <http://samm.ut.ee/dispersioonanalyys>

TÜ arvutiteaduse instituudi programmeerimise algkursuse õpik. (2017). Kasutatud: <https://progeopik.cs.ut.ee/index.html>

Uiboaed, K. (2017). *Lemmatize txt-files in the working directory. Output only the first analysis*. Kasutatud: <https://github.com/kristel-/Tekstikoolitus-2017/blob/master/15-02-praktikum/lemmatizeFiles.py>

Wang, C., Paisley, J., & Blei, D. M. (2011). Online variational inference for the hierarchical Dirichlet process. *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS)*, Fort Lauderdale, FL, USA, pp. 752–760. Kasutatud: <http://proceedings.mlr.press/v15/wang11a/wang11a.pdf>

What does tf-idf mean? [2020]. Kasutatud: <http://www.tfidf.com/>