

Tartu Ülikool
sotsiaalteaduste valdkond
psühholoogia instituut

Kairit Sirts

DEPRESSIOONI JA ÄREVUSE AUTOMAATNE TUVASTAMINE
SPONTAANSE KIRJALIKU KEELE ALUSEL: ANDMETE
KOGUMISE PILOOTUURING

Uurimustöö

Juhendaja: Kirsti Akkermann, PhD

Jooksev pealkiri: Depressiooni ja ärevuse tuvastamine teksti alusel

Tartu 2019

Depressiooni ja ärevuse automaatne tuvastamine spontaanselt kirjalikust keelest: andmete kogumise pilootuuring

Kokkuvõte

Uurimistöö eesmärgiks oli välja töötada meetod tekstilise andmestiku kogumiseks, mille alusel saaks hiljem arendada masinõppel põhinevaid meetodeid depressiooni ja ärevuse riski automaatseks hindamiseks. Töö käigus koostati ankeet, mille abil koguti tekstilist materjali ligi 300-st vabatahtlikust koosnevalt mugavusvalimilt. Kogutud tekstid sisaldasid nii etteantud pildi kirjeldust kui ka vabalt valitud sündmuse või mälestuse kirjeldust. Valimis osalenute emotsionaalset seisundit mõõdeti EEK-2 skriiningtesti abil. Ligi 42% isikutest ületas depressiooni ning ligi 30% isikutest ärevuse alaskaala riskiläveni. Esialgsed eksperimendid masinõppe mudelitega, mis püüdsid ennustada, kas inimese EEK-2 skoor ületab depressiooni ja/või ärevuse riskiläveni, edukaid tulemusi ei andnud. Kokkuvõttes tundub, et etteantud pildi kirjeldamine ei ole sobivaim viis soovitud andmestiku kogumiseks ja pigem peaks kasutama selliseid kirjutamise ülesandeid, mis oleks inimese endaga rohkem seotud.

Märksõnad: arvutuslik kliiniline psühholoogia, depressioon, ärevus, loomuliku keele töötlus, masinõppe

**Automatic prediction of depression and anxiety from spontaneous written
language: data collection pilot study**

Abstract

The aim of this research was to develop a method for collecting textual data that could be used to develop machine-learning based methods for automatic risk assessment of depression and anxiety. During work, a questionnaire was prepared that was used to collect textual material from ca 300 volunteers. The collected text included picture descriptions as well descriptions of freely chosen event or memory. The participants' emotional status was measured using the EST-Q screening test. Nearly 42% of individuals exceeded the depression risk threshold and nearly 30% of exceeded the anxiety risk threshold. Preliminary experiments with machine-learning models which attempted to predict whether the EST-Q score of a subject exceeds the risk threshold did not produce satisfactory results. Overall, the picture description task does not seem to be the most suitable paradigm for collecting the desired data. Instead, more personal writing tasks should be used.

Keywords: computational clinical psychology, depression, anxiety, natural language processing, machine learning

Sissejuhatus

Käesoleva töö eesmärgiks on välja töötada meetod spontaanse kirjaliku keele andmestiku kogumiseks, mille alusel saaks hiljem arendada masinõppepõhiseid meetodeid inimese psüühilise seisundi hindamiseks automaatse tekstianalüüsi alusel.

Idee automaatsete tekstipõhiste meetodite kasutamiseks psüühiliste häirete riski hindamiseks ei ole uus. Juba 1980ndatel uurisid James Pennebaker koos kolleegidega, kuidas kirjalikes tekstides avalduvad tekstimustrid korreleeruvad inimeste psüühilise seisundiga, kasutades selleks LIWC (*Linguistic Inquiry and Word Count*) vahendit (Chung & Pennebaker, 2007; Pennebaker, Boyd, Jordan, & Blackburn, 2015; Pennebaker, Mehl, & Niederhoffer, 2003; Tausczik & Pennebaker, 2010). LIWC aluseks on leksikon, mis jagab sõnad mitmekümnesse erinevasse kategooriasse, nagu näiteks positiivse ja negatiivse emotsionaalsusega sõnad, suhetega seotud sõnad, erinevat tüüpi asesõnad jne. Need tööd baseeruvad eeldusel, et inimese valitud sõnad ei edasta mitte ainult soovitud semantilist tähendust, vaid annab edasi infot ka inimese psühholoogilise seisundi kohta (Pennebaker et al., 2003). LIWC leksikoni abil on võimalik loendada erinevatesse kategooriatesse kuuluvate sõnade sagedust tekstis. Seeläbi on võimalik võrrelda erinevatesse gruppidesse kuuluvate inimeste sõnakasutuse mustreid. Näiteks on leitud, et depressiooni all kannatavate inimeste fookus on rohkem iseendal, mis väljendub selles, et nad kasutavad rohkem ainsuse esimese isiku asesõnu (mina, minu jne), samuti esineb depressiivsete inimeste tekstides rohkem negatiivse emotsionaalsusega seotud sõnu (Tausczik & Pennebaker, 2010). Pennebakeri ja kolleegide töödes kasutatav andmestik koosnes tüüpiliselt vaba kirjutamise ülesandest, kus inimestel paluti kirjutada kas oma sügavatest emotsionaalsetest probleemidest (Pennebaker, Kiecolt-Glaser, & Glaser, 1988) või mõnel etteantud pealiskaudsemal teemal (Pennebaker, 1997).

Viimastel aastatel üsna palju uuritud võimalusi hinnata inimeste psühholoogilist seisundit sotsiaalmeedia andmete alusel, mis on saanud näiteks facebookist (Schwartz et al., 2014), twitterist (Benton, Mitchell, & Hovy, 2017; Coppersmith, Dredze, & Harman, 2014; De Choudhury, Gamon, Counts, & Horvitz, 2013; Loveys, Crutchley, Wyatt, & Coppersmith, 2017) või redditist (Ive, Gkotsis, Dutta, Stewart, & Velupillai, 2018; Yates, Cohan, & Goharian, 2017). Kuigi sotsiaalmeedia andmete kasutamine on atraktiivne, sest neid on võimalik automaatselt hankida suures mahus, võib arvata, et sotsiaalmeedia platvormidelt hangitud andmed on mitmes mõttes kallutatud (Ernala et al., 2019). Esiteks on

sotsiaalmeediat aktiivselt kasutav inimgrupp ilmselt üsna eristuv alamgrupp kogu populatsioonist. Psüühilise häire diagnoos tuletatakse sotsiaalmeedia andmeid kasutatavates töödes sageli postitustest endast (st inimesed ise raporteerivad, mis häirete all nad kannatavad). Võib arvata, et oma psüühilistest häiretest avalikult sotsiaalmeedias kirjutavad inimesed moodustavad veel omakorda spetsiifilise alamgrupi kõigist vaimsete häirete all kannatavatest inimestest. Teiseks, kuivõrd inimesed sotsiaalmeedias ilmselt kirjutavad põhiliselt neile olulistel teemadel, siis võib tekkida kahtlus, et sotsiaalmeedia andmete põhjal loodud mudelid ei õpi mitte niivõrd eristama mingi konkreetse häirega isikuid tervetest inimestest, vaid pigem teksti enda teemat. Teiste sõnadega, kui inimene raporteerib sotsiaalmeedias, et tal on depressioon, siis ta tõenäoliselt kirjutab sellest ka oma postitustes ja seega mudel võib lihtsalt õppida eristama depressiooni teemat käsitlevaid postitusi mingitel muudel teemadel kirjutatud postitustest. Kolmandaks, sotsiaalmeedia andmeid kasutades on üsna kergesti võimalik hankida inglisekeelseid andmeid, aga teiste keelte puhul on sobivate sotsiaalmeedia andmestike kättesaadavus üsna piiratud.

Eeltoodud probleemide adresseerimiseks on töö autoril kavas koguda andmestik, mis sisaldab temaatiliselt kontrollitud spontaanset eestikeelset kirjalikku kõnet nii verifitseeritud kliiniliselt valimilt kui ka tervetelt kontrollsubjektidelt. Käesolev uurimustöö on selle suurema eesmärgi esimene etapp täpsema andmekogumisprotokolli välja töötamiseks. Töö käigus koostati veebipõhine ankeet vabatahtlikelt osalejatelt spontaanset kirjaliku teksti kogumiseks. Ankeedi abil kogutud tekstiandmed sisaldavad pildikirjeldusi, mis tagab kontrolli kirjutatava teema üle. Lisaks paluti uuringus osalejatel kirjeldada ka mõnda vabalt valitud mälestust või sündmust. Osalejate psüühilist enesetunnet ankeedi täitmise hetkel mõõdeti nii emotsionaalse enesetunde küsimustikuga (EEK-2) (Aluoja, Shlik, Vasar, Luuk, & Leinsalu, 1999) kui ka etteantud emotsioonisõnade nimekirja abil. Kuna uurimustöö eesmärgiks on andmete kogumise meetoodika väljatöötamine, siis otseselt ühtegi kontrollitavat hüpoteesi ei püstitata. Sellegipoolest saab sõnastada uurimustöö eesmärgid, milleks on vähemalt osaliselt leida vastused järgmistele küsimustele:

1. *Kas pildi kirjeldamine on sobiv ülesanne soovitud andmestiku kogumiseks?* Sellele küsimusele vastamiseks palutakse inimestel kirjeldada ühte pilti, mille nad saavad vabalt valida nelja pakutud pildi seast.
2. *Kui pikalt inimesed pilte kirjeldavad, kui neile anda üsna üldine tegevusjuhis?* Selle küsimuse eesmärgiks on välja selgitada, kas inimesed produtseerivad spontaanselt

piisavalt tekstilist materjali (vähemalt paarsada sõna) või tuleb neid selleks spetsiifiliselt instrueerida.

3. *Kas ja kuidas mõjutab valitud pilt emotsionaalse sündmuse valikut?* Sellele küsimusele võib läheneda nii kvalitatiivselt kui ka kvantitatiivselt. Kvantitatiivse lähenemise puhul võib kasutada näiteks masinõppe meetodeid treenides mudeli, mis emotsionaalse sündmuse teksti alusel püüab ennustada valitud pilti.
4. *Kumb, kas pildi või vabalt valitud sündmuse kirjeldus, võimaldab paremini ennustada inimese emotsionaalset seisundit?* Sellele küsimusele vastamiseks on vaja kasutada masinõppemudeleid, mis õpiksid tekstilise sisendi alusel ennustama isiku raporteeritud emotsionaalset seisundit.

Uuringu käigus õnnestus koguda andmeid ligi 300-lt vabatahtlikult. Kuigi plaanitud valim ei olnud kliiniline, siis selgus, et ligi 42% isikutest ületasid riski lävendi EEK-2 depressiooni alaskaalal ning ligi 30% ärevuse alaskaalal. See ei tähenda, et kõik need inimesed kannataksid kliinilise depressiooni või ärevuse all, aga on tõenäoline, et valimis leidis ka kliinilisi juhtumeid.

Meetod

Andmestiku kogumine

Ankeet. Andmestiku kogumiseks koostati veebis täidetav ankeet, mis koosnes järgmistest osadest:

- Demograafilised andmed (vanus, sugu, haridustase, emakeel, perekonnaseis);
- Emotsionaalse enesetunde küsimustik (EEK-2);
- Oma hetke emotsionaalse enesetunde kirjeldamine emotsioonisõnade nimekirja abil;
- Ühe pildi valimine nelja variandi hulgast (vt joonis 1) ning valitud pildi kirjeldamine vähemalt 100 sõna abil;
- Vabalt valitud sündmuse või mälestuse kirjeldamine vähemalt 50 sõna abil;
- Uuesti oma emotsionaalse enesetunde kirjeldamine emotsioonisõnade nimekirja abil;



(a) Pilt A



(b) Pilt B



(c) Pilt C



(d) Pilt D

Joonis 1. Andmestiku kogumisel kasutatud pildid.

Pildi ja vabalt valitud sündumuse/mälestuse kirjeldus. Esialgu oli plaanis anda inimestele väga üldine instruksioon tekstiloomeks ning vaadata, kui palju sõnu osalejad ise spontaanselt kirjutavad. Enne andmete kogumise alustamist testiti ankeeti väikese hulga testkasutajate peal ning selle käigus selgus, et ilma minimaalset sõnade arvu ette andmata kirjutavad inimesed tõenäoliselt liiga vähe sõnu selleks, et teksti alusel saaks hiljem mingeidki ennustusi teha. Seetõttu pandi pildikirjeldusele minimaalse 100 sõna piirang ning sündumuse/mälestuse kirjeldusele 50 sõna piirang.

Emotsioonisõnad. Uuringus osalejatel paluti anda hinnangud oma emotsioonidele kahel korral: esimene kord vahetult pealt EEK-2 testi täitmist ja enne pildi valimist ja kirjeldamist ning teine kord peale vabalt valitud sündumuse või mälestuse kirjeldust. Kummalgi juhul oli ette antud nimekiri emotsioonisõnadest, mille hulgast vastaja sai valida need, mis tema enestunde või emotsioonidega parajasti kõige paremini sobisid. Nimekiri sisaldas 32 erinevat sõna, millest 15 olid seotud positiivsete emotsioonidega ning 17 olid seotud negatiivsete sõnadega. Kasutatud sõnade nimekiri on ära toodud tabelis 1. Piiratud arvu emotsioonisõnade valimine ankeeti ei olnud lihtne ülesanne, sest kuigi baas-

Tabel 1

Ankeedis kasutatud emotsioonisõnad.

Positiivsed		Negatiivsed	
energiline	rahulolev	hirmunud	tunnen piinlikkust
enesekindel	rõõmus	kurb	tunnen süüd
entusiastlik	uhke	pettunud	tusane
erutunud	vaimustunud	põlglik	tüdinud
kaastundlik	õnnelik	rahulolematu	vihane
kindlameelne	ülevas meeleolus	rusutud	ärev
lõbus	üllatunud	segaduses	ärritunud
põnevil		tunnen häbi	üksildane

emotsioone on sõltuvalt autorist identifitseeritud kas kuus (Ekman, 1992), kaheksa (Plutchik, 2001) või mõni muu arv, siis emotsioonide ja tunnete erinevaid varjundeid väljendavaid sõnu on väga palju. Hea ülevaate eestlaste poolt kasutatavatest emotsioonisõnadest saab näiteks Ene Vainiku magistritööst (Vainik, 2001).

Kuigi eesti keele jaoks on kohandatud positiivsete ja negatiivsete afektide skaala PANAS (Allik & Realo, 1997), mis sisaldab 20 emotsioonisõna, ei tundunud selle skaala kasutamine käesolevas töös sobiv, sest seal on puudu mitmed olulised emotsioonid, nagu kurbus ja süü, mida sagedasti seostatakse depressiooni ja ärevusega (Orth, Berking, & Burkhardt, 2006; Stanton & Watson, 2014). Samuti esinesid PANAS nimekirjas mitmed sõnad, mis autori meelest tähistasid üsna sarnaseid emotsioone (näiteks *tujust ära* ja *tusane* ning *aktiivne*, *elav* ja *energiline*). Seetõttu kasutati emotsioonisõnade nimekirja koostamisel ainult osaliselt eestikeelse PANAS skaala sõnu, need on tabelis 1 tähistatud paksus kirjjas. Ülejäänud tabelis esitatud sõnad valiti nii, et positiivsed ja negatiivsed sõnad oleksid ligikaudu tasakaalus, et oleks nii kõrget kui ka madalat erutuse taset iseloomustavaid sõnu ning et seejuures ei saaks sõnade nimekiri liiga pikk.

Mõlemad nimekirjad (nii enne kui pärast) olid sisuliselt identsed, kuid vormiliselt olid nad erinevalt esitatud. Esimesel korral oli küsimus ankeedis püstitatud nii, et vastaja peaks valima, kuidas ta end parasjagu tunneb ning sõnad olid esitatud omadussõnadena, nii nagu nad on ära toodud tabelis 1. Teisel korral oli küsimus püstitatud nii: “Milliseid tundeid see sündmus sinus praegu esile kutsub?” ning sõnad olid antud nimisõna vormis

(*õnnelikkus, üllatus, rõõm* jne). Mingisugust teoreetilist põhjendust emotsioonisõnade nimekirjade erinevaks esitamiseks ei olnud - ankeedi koostamisel tundus lihtsalt parem täpset sõnade kordamist vältida. Andmete analüüsi käigus käsitleti nii omadussõna kui ka nimisõna vormis emotsioonisõna ühe ja samana.

Ankeedis esitati sõnad igale vastajale juhuslikus järjekorras. Etteantud emotsioonisõnade valimine ei olnud ankeedis piiratud - vastaja võis valida nii palju sobivaid sõnu kui soovis või jätta üldse valimata. Lisaks oli antud võimalus kirjutada sobivaid emotsioonisõnu tekstikasti, kui vastaja ei leidnud nimekirjast tema emotsionaalset seisundit kirjeldavaid sõnu.

Valim. Valimiks oli mugavusvalim üliõpilastest ja teistest isikutest, kes vabatahtlikult olid nõus ankeeti täitma. Kutset ankeeti täitma levitati nii TÜ psühholoogiainstituudi tudengite ja töötajate seas kui ka TÜ arvutiteaduste instituudi üliõpilaste seas. Lisaks levitati ankeeti veebifoorumis perekool.ee ning eestlastele suunatud reddit keskkonnas r/Eesti¹.

Andmete kogumine toimus ajavahemikus november 2018 kuni veebruar 2019. Kõigi soovijate vahel, kes osalesid novembris 2018, loositi välja kolm 20-eurost Apollo kinkekaarti. Kõigile soovijatele saadeti e-kirja teel nende EEK-2 tulemuste kokkuvõte. Isikutele, kes ületasid vähemalt ühel EEK-2 alaskaalal riski lävendi, anti soovitus pöörduda olukorra täpsemaks diagnoosimiseks kliinilise psühholoogi poole. Isikud, kes vastasid küsimusele, kas neil on olnud korduvaid surma- või enesetapumõtteid, vastusega *sageli* või *pidevalt*, anti lisaks info kiire abi kontaktide kohta peaasi.ee lehel ning soovitus jätkuvate suitsiidimõtete puhul mõnega neist ühendust võtta.

Andmestiku analüüs

EEK-2 küsimustik sisaldab alaskaalasid kuue erineva psühholoogilise häire riski hindamiseks: depressioon, ärevus, paanikahäire, sotsiaalärevus, asteenia ja unehäired. Etteantud löikepunktide alusel on võimalik andmestik jagada iga alaskaala osas riski läve ületavate ja läve alla jäävate skooridega isikute grupiks. Käesolevas töös pakuvad huvi eelkõige depressiooni ja ärevuse alaskaalad. Nende alusel on võimalik koostada kaks erinevat sõltumatute gruppidega andmestikku:

- depressiooni andmestik, kus üks grupp moodustub depressiooni riski läve ületanud

¹<https://www.reddit.com/r/Eesti/>

skooridega isikutest ja teine grupp riski läve alla jäänud skooridega isikutest;

- ärevuse andmestik, kus üks grupp moodustub ärevuse riski läve ületanud skooridega isikutest ja teine grupp riski läve alla jäänud skooridega isikutest;

Statistiliste analüüside jaoks kasutati programmeerimiskeele *python* teaduslike arvutuste teeki *scipy*.² Valimite võrdlemiseks kasutati võimalusel t-testi (kui mõlemad grupid olid ligikaudu normaalsed).³ Enne t-testi rakendamist kontrolliti dispersioonide võrdsust Bartletti testi abil. Normaalsusest oluliselt hälbivate valimite korral kasutati mitteparameetrilist Mann-Whitney-U testi (sõltumatute gruppide puhul) või Wilcoxon'i astakmärgi testi (sõltuvate gruppide puhul).

Kuna samal andmestikul korduvate statistiliste testide tegemisega suureneb I tüüpi vea tegemise tõenäosus, siis kasutati p-väärtuse korrigeerimiseks Bonferroni meetodit (Bland & Altman, 1995), mille puhul soovitud p-väärtus jagatakse testimiste arvuga. Näiteks, kui null-hüpoteesi tagasilükkamise p-väärtuseks valitakse 0.05 ning samal andmestikul tehakse 10 erinevat statistilist testi, siis Bonferroni korrigeerimise alusel tuleb null-hüpoteesi tagasi lükata siis, kui leitud p-väärtus on väiksem kui $0.05/10 = 0.005$. Käesolevas töös tehti kokku 30 statistilist testi keskmiste võrdlemiseks, nominaalsete väärtuste jaotuste sõltumatus testimiseks ning korrelatsioonide olulisuse hindamiseks. Seega, võttes baasolulisusnivooks $p = 0.05$, loetakse statistiliselt oluliseks seosed, mille puhul $p < 0.05/30 = 0.0016$.

Protseduur

Andmete töötlus sisaldab ka esmaseid eksperimente masinõppe abil. Detailne masinõppe meetodite kirjeldamine ei mahu paraku käesoleva töö skoopi. Selleks aga, et töö oleks iseseisva kirjatükina loetav, kirjeldatakse järgnevalt väga põgusalt logistilise regressiooni mudelit (Bishop, 2006), mis on üks kõige lihtsamatest ning loomuliku keele töötluses ka sageli kasutatavatest masinõppe meetoditest. Logistilise regressiooni abil on võimalik modelleerida binaarset klassifitseerijat, mis igale andmepunktile ennustab, kas ta kuulub klassi 1 või 0, mis võivad vastata näiteks kliinilisele ja kontrollgrupile. Tegemist on lineaarse mudeliga, kus igale tunnusele x_i seatakse vastavusse kaal w_i . Tunnuste ja kaalude väärtuste abil arvutakse igale andmepunktile $\mathbf{x} = \{x_1, \dots, x_m\}$ skoor z :

²<https://www.scipy.org/scipylib/index.html>

³<https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.normaltest.html>

$$z = \sum_{i=1}^m x_i w_i \quad (1)$$

Gruppi kuuluvuse c tõenäosus arvutatakse seejärel kasutades logistilist funktsiooni:

$$p(c = 1|\mathbf{x}) = \frac{1}{1 + \exp(-z)} \quad (2)$$

Mudelit treenitakse gradientmeetodite abil minimeerides treeningandmestiku negatiivset logaritmilist tõepära:

$$\mathcal{L} = - \sum_{j=1}^N \log p(c_j|\mathbf{x}_j), \quad (3)$$

kus N on andmepunktide arv treeningandmestikus.

Selleks, et rakendada logistilist regressiooni tekstandmetele, on vaja tekstid kõigepealt transformeerida tunnusvektorite kujule. Tekstiliste andmete puhul on üheks kõige lihtsamaks tunnusteks transformeerimise viisiks sõnakoti meetod (*bag-of-words*) (Goldberg, 2017). Sõnakoti representatsiooni kasutamiseks moodustatakse kõigepealt sõnastik kõigist treeningandmestikku kuuluvatest sõnadest. Need moodustavad mudelile teadaolevad tunnused. Igale sõnale määratakse indeks, mis määrab tema asukoha tunnusvektoris. Seejärel saab transformeerida iga teksti tunnusvektori kujule nii, et selles konkreetse tekstis esinenud sõnade positsioonide väärtuseks saab 1 ning tekstist puuduvate sõnade positsioonide väärtuseks on 0. Näiteks lause “mina olin siin” sõnakoti representatsioonis koosneb tunnuste vektor valdavalt nullidest ja väärtus 1 esineb ainult kolmes positsioonis - neis, mis vastavad sõnadele *mina*, *olin* ja *siin*.

Tekstiliste andmete puhul võib tunnuste (sõnastiku sõnade) arv olla suurem kui andmepunktide (tekstide) arv treeningandmestikus, mis toob kaasa probleemi, et logistilise regressiooni lahend on defineerimatu ning seega pole optimaalset kaalude vektorit võimalik leida. Üks lihtsamaid lahendusi sellele probleemile on mudeli regulariseerimine. Selle puhul lisatakse minimeeritavale kulufunktsioonile juurde regularisatsioonifaktor, mis ärgitab treenimisalgoritmi leidma lahendit, mille puhul kaalude väärtused on võimalikult väikesed. Regulariseeritud logistilise regressiooni puhul omandab valem (3) kuju:

$$\mathcal{L} = - \sum_{j=1}^N \log p(c_j|\mathbf{x}_j) + \lambda \sum_{i=1}^m w_i^2, \quad (4)$$

kus λ on valitav parameeter, mis määrab regulariseerimise tugevuse.

Masinõppe mudeleid treenitakse ja hinnatakse tavapäraselt nii, et andmestik jaotatakse kaheks: treeningandmestikuks ja testandmestikuks. Treeningandmestikku kasutatakse mudeli kaalude treenimiseks, testandmestikku kasutatakse treenitud mudeli ennustava täpsuse hindamiseks. Vahel eraldatakse ka kolmas osa, valideerimisandmestik, mida kasutatakse mudeli erinevate mitte-treenitavate parameetrite väärtuste määramiseks.

Väikeste andmestike puhul kasutatakse sageli ristvalideerimist. Ristvalideerimise metoodika puhul jagatakse andmed näiteks viieks (5-kordne ristvalideerimine) ning treenitakse viis mudelit, võttes igal treenimiskorral neli osa treeningandmestikuks ning jättes ühe osa testandmestikuks. Igal korral jäetakse erinev osa testandmestikuks. Iga mudel treenitakse treeningandmestiku peal ning tema täpsust hinnatakse vastava testandmestiku peal. Lõpliku täpsuse saamiseks keskmistatakse kõigi viie mudeli testimistäpsused. Sellisel viisil on võimalik väikest andmestikku eksperimenteerimisel efektiivsemalt ära kasutada.

Kuna käesolevas töös kogutud andmestik on üsna väike, siis kasutati ka siin 5-kordset ristvalideerimist. Iga mudel treeniti vastava treeningandmestiku peal, mis koosnes 80% koguandmestikust. Mudeli täpsust hinnati testandmestiku peal, mis koosnes 20% koguandmestikust. Õigeks vastuseks loeti need testandmestiku juhud, mille puhul mudeli ennustatud gruppi kuuluvus oli sama, mis EEK-2 skooride aluselt määratud - kas riski lävend oli ületatud (grupp 1) või ei olnud (grupp 0). Raporteeritud täpsus on keskmine õigete ennustuste protsent üle kõigi viie mudeli.

Sõnakoti tunnusvektorite loomiseks ning logistilise regressiooni mudelite treenimiseks ristvalideerimise abil kasutati programmeerimiskeele *python* masinõppe teeki *scikit-learn*.⁴ Tekstide eeltöötluks kasutati *stanfordnlp* teegi⁵ (Qi, Dozat, Zhang, & Manning, 2018) eesti keele jaoks eeltreenitud mudeleid, mis muuhulgas võimaldavad eestikeelset teksti lauseteks ja sõnadeks tükeldada ning lemmatiseerida.

Tulemused

Ülevaade andmestikust

Kokku täitis ankeedi 295 isikut, neist täisealisi vanusevahemikus 18-80 oli 292 (naisi 240). Kolme alaealise vanus pole täpselt teada, seetõttu jäeti nad edasistest analüüsistest välja. Eesti keel oli emakeeleks 283 isikul (naised 232). Ülejäänud 9 isiku emakeeleks oli

⁴<https://scikit-learn.org>

⁵<https://stanfordnlp.github.io/stanfordnlp/>

Tabel 2

Ülevaade valimist vanuse ning EEK-2 alaskaalade skooride osas.

	Kokku	Naised	Mehed
N	292	240	52
Keskmine vanus (SD)	30.8 (11.7)	31.4 (11.7)	28.3 (11.3)
Mediaanvanus (min,maks)	26 (18,73)	27 (18,72)	24 (18,73)
Depressioon (SD)	10.8 (6.5)	10.7 (6.3)	11.4 (7.3)
Ärevus (SD)	9.2 (4.9)	9.5 (4.8)	8.1 (5.0)
Paanika (SD)	1.4 (2.4)	1.6 (2.5)	0.7 (1.8)
Sotsiaalfobia (SD)	1.9 (2.1)	2.0 (2.1)	1.4 (1.8)
Asteenia (SD)	8.4 (4.0)	8.4 (4.0)	8.1 (4.0)
Unehäired (SD)	4.5 (3.1)	4.5 (3.1)	4.4 (3.3)

vene keel (naisi 8). Tabelis 2 on ära toodud ülevaade valimis osalejate vanuse ning EEK-2 alaskaalade skooride kohta. Kuigi mehed on keskmiselt natuke nooremad kui naised, siis erinevus meeste ja naiste vanuste vahel ei olnud statistiliselt oluline ($t\text{-stat}=1.737$, $p=0.08$). Depressiooni ja ärevuse alaskaalade skoorides meeste ja naiste vahel statistiliselt olulisi erinevusi ei leitud: depressiooni puhul $U\text{-stat}=6001.5$, $p=0.33$, ärevuse puhul $t\text{-stat}=1.798$, $p=0.07$. Ülejäänud alaskaalade puhul erinesid mehed ja naised vaid paanikahäire osas, mille puhul naiste skoorid olid meeste omadest oluliselt kõrgemad.

Enamus osalejatest olid keskharidusega (kokku 117, naisi 88), järgnesid bakalaureusekraadiga kõrgharidusega isikud (kokku 82, naisi 74) ja vähemalt magistrikraadiga kõrgharidusega isikud (kokku 75, naisi 68), vähem oli kutseharidusega inimesi (kokku 15, naisi 9), põhiharidusega isikuid oli ainult 2 (naisi 1).

Perekonnaseisu osas oli kõige rohkem vallalisi isikuid (kokku 117, naisi 88), seejärel kooselus või abielus olevaid inimesi (kokku 96, naisi 85) ning suhtes olevaid inimesi (kokku 64, naisi 53). Lahutatud isikuid oli 10 (naisi 9) ning lesestaatuses oli 5 inimest (kõik naised). Üleüldiselt võib eelnevast lähtuvalt öelda, et valimis domineerivad noored üliõpilased ning kõrgharitud naised.

Tabelis 3 on ära toodud statistika iga EEK-2 alaskaala puhul riski lävendi ületanud ja selle alla jäänud isikute skoorid kogu valimi osas ning meeste ja naiste lõikes eraldi. Selgub, et depressiooni riski lävendi ületas tervelt 41.8% isikutest ning ärevuse riski lävendi

Tabel 3

EEK-2 skaalade statistika meeste ja naiste lõikes.

	Lävend	Riskiga				Riskita		
		N	(%)	Keskväärtus	(SD)	N	Keskväärtus	(SD)
Depressioon	11	122	(41.8)	17.1	(4.3)	170	6.3	(3.2)
<i>Naised</i>		98	(40.8)	16.9	(4.1)	142	6.4	(3.2)
<i>Mehed</i>		24	(46.2)	17.9	(4.9)	28	5.8	(3.1)
Ärevus	11	85	(29.1)	15.2	(2.7)	207	6.8	(3.2)
<i>Naised</i>		72	(30.0)	15.2	(2.8)	168	7.0	(3.1)
<i>Mehed</i>		13	(25.0)	14.8	(2.1)	39	5.9	(3.5)
Paanika	6	17	(5.8)	8.8	(2.0)	275	1.0	(1.5)
<i>Naised</i>		16	(6.7)	8.6	(2.0)	224	1.1	(1.6)
<i>Mehed</i>		1	(1.9)	11.0	(-)	51	0.5	(1.1)
Sotsiaalloobia	3	57	(19.5)	5.4	(1.3)	235	1.0	(1.1)
<i>Naised</i>		50	(20.8)	5.5	(1.3)	190	1.0	(1.1)
<i>Mehed</i>		7	(13.5)	5.0	(1.4)	45	0.9	(1.0)
Asteenial	6	195	(66.8)	10.6	(2.8)	97	3.9	(1.7)
<i>Naised</i>		161	(69.2)	10.6	(2.7)	79	3.9	(1.7)
<i>Mehed</i>		34	(65.4)	10.3	(3.1)	18	4.1	(1.7)
Unehäired	5	107	(36.6)	7.9	(1.8)	185	2.5	(1.6)
<i>Naised</i>		86	(35.8)	7.9	(1.8)	154	2.6	(1.6)
<i>Mehed</i>		21	(40.4)	7.9	(1.8)	31	2.0	(1.5)

ületas 29.1% valimist. See loomulikult ei tähenda, nagu kannataksid vastavalt üle 40% ja pea 30% valimis osalenud isikutest tingimata kliinilise depressiooni ja ärevuse all, sest EEK-2 test päris inimese seisundi kohta viimase kuu jooksul ning igaühel tuleb ette paremaid ja halvemaid perioode. Natuke ootamatu ja üllatav oli riski lävendi ületanud isikute hulk siiski, seda enam, et tegemist oli üsna tavapärase üliõpilastest ja professionaalidest koosneva mugavusvalimiga. Samuti torkab silma väga suur hulk asteenial (ehk kroonilise väsimuse) riski lävendi ületanud isikute hulk, mis oli lausa 66.8%. Samas ei ole selline tulemus ehk üllatav arvestades, et enamuse andmestikku koguti novembris, mis on Eestis üks kõige pimedamaid kuid, mil talveväsimus hakkab võimust võtma. Samuti tuleb arves-

Tabel 4

Piltide valik sugude ning depressiooni ja ärevuse lõikes.


	N	Pilt A (%)	Pilt B (%)	Pilt C (%)	Pilt D (%)
Kokku	292	41 (14.0)	38 (13.0)	139 (47.6)	74 (25.3)
<i>Depressioon</i>	122	16 (13.1)	12 (9.8)	66 (54.1)	28 (23.0)
<i>Riskita</i>	170	25 (14.7)	26 (15.3)	73 (42.9)	46 (27.1)
<i>Ärevus</i>	85	7 (8.2)	12 (14.1)	46 (54.1)	20 (23.5)
<i>Riskita</i>	207	34 (16.4)	26 (12.6)	93 (44.9)	54 (26.1)
Naised	240	36 (15.0)	26 (10.8)	116 (48.3)	62 (25.8)
<i>Depressioon</i>	98	14 (14.3)	7 (7.1)	52 (53.1)	25 (25.5)
<i>Riskita</i>	142	22 (15.5)	19 (13.4)	64 (45.1)	37 (26.1)
<i>Ärevus</i>	72	7 (9.7)	7 (9.7)	40 (55.6)	18 (25.0)
<i>Riskita</i>	168	29 (17.3)	19 (11.3)	76 (45.2)	44 (26.2)
Mehed	52	5 (9.6)	12 (23.1)	23 (44.2)	12 (23.1)
<i>Depressioon</i>	24	2 (8.3)	5 (20.8)	14 (58.3)	3 (12.5)
<i>Riskita</i>	28	3 (10.7)	7 (25.0)	9 (32.1)	9 (32.1)
<i>Ärevus</i>	13	0 (0.0)	5 (38.5)	6 (46.2)	2 (15.4)
<i>Riskita</i>	39	5 (12.8)	7 (17.9)	17 (43.6)	10 (25.6)

se võtta ka seda, et lõviosa valimist moodustasid üliõpilased, kelle jaoks selleks hetkeks oli tõenäoliselt sügissemestri väsimus juba jõudnud akumuldeeruda. Kõige vähem oli paa-nikahäire ning sotsiaalfobia riski lävendit ületavaid isikuid (vastavalt 5.8% ja 19.5%). Üllatavalt suur hulk inimesi (36.6%) ületas ka unehäirete riski lävendit.

Edasi vaadeldakse töös ainult depressiooni ja ärevuse alaskaalades skooore. Kuigi riski läve ületanute seas oli depressiooni alaskaala keskmine skoor meeste puhul natuke kõrgem kui naistel ning ärevuse puhul naistel natuke kõrgem kui meestel, siis statistiliselt olulisi erinevusi meeste ja naiste vahel ei leitud ei depressiooni (U-stat=1051.5, p=0.21) ega ärevuse (U-stat=464, p=0.48) puhul.

Piltide valik

Tabelis 4 on ära toodud statistika selle osas, milliseid pilte kui palju valiti nii üleüldiselt, naiste ja meeste lõikes ning ka depressiooni ja ärevuse lävendi ületanute ning selle alla



Joonis 2. Piltide valik sugude lõikes.


jäänute lõikes. Üleüldiselt valiti kõige rohkem pilti C (koeraga esiplaanil), sageduselt järgmine valik oli pilt D (tütarlaps kohvikus).

Joonisel 2 on näidatud piltide valik kokku ning sugude lõikes. Kuigi protsentuaalselt valisid naised meestest oluliselt rohkem pilti A ning oluliselt vähem pilti B ning mõnevõrra rohkem pilte C ja D, siis sugude ja piltide valiku vahel statistiliselt olulist seost ei leitud ($\chi^2=6.085$, $p=0.11$, $dof=3$).

Joonistel 3a ja 3b on näha piltide valik vastavalt depressiooni ja ärevuse riski lävendi ületanud ning lävendi alla jäänud skooridega isikute vahel. Protsentuaalselt valisid nii depressiooni kui ärevuse riskiga isikud oluliselt rohkem pilti C (koeraga) ning mõnevõrra vähem pilti D (tüdruk kohvikus). Depressiooni riskiga isikud valisid tunduvalt vähem pilti B (kokk noaga), samas kui ärevuse riskiga isikud valisid märgatavalt vähem pilti A (sõit kõrgel atraktsioonil!). Hoolimata nendest protsentuaalsetest erinevustest hii-ruut test riski lävendi ületanute ja selle alla jäänute ning pildivaliku vahel statistiliselt olulisi seoseid ei leidnud ei depressiooni ($\chi^2=4.084$, $p=0.25$, $dof=3$) ega ärevuse puhul ($\chi^2=4.215$, $p=0.24$, $dof=3$).

Emotsioonide hinnangud

Käesolevas töös analüüsiti emotsioonide hinnanguid ainult positiivse/negatiivse emotsionaalsuse dimensioonil. See tähendab, et iga inimese poolt valitud tema emotsionaalset seisundit kirjeldavad emotsioonisõnad teisendati numbrilisele skaalale, mille nullpunkt



(a) Depressiooni riskiga ja riskita.

(b) Ärevuse riskiga ja riskita.

Joonis 3. Piltide valik depressiooni või ärevuse riskiga ja riskita isikute lõikes.

tähistab neutraalset emotsiooni ning positiivsed ja negatiivsed väärtused vastavalt positiivset ja negatiivset emotsionaalset seisundit.

Kõige lihtsam viis kogutud andmete sellisele numbrilisele skaalale teisendamiseks on anda igale emotsioonisõnale väärtus: positiivsele emotsioonisõnale väärtus +1, negatiivsele emotsioonisõnale väärtus -1 ning neutraalsele emotsioonisõnale väärtus 0. Seejärel summeerida iga vastaja puhul kokku tema poolt valitud/kirjutatud emotsioonisõnade väärtused. Tulemuseks on täisarvuline skoor, mis kajastab inimese emotsionaalset meeleseisundit antud hetkel.

Loeteluna antud emotsioonisõnade jaotumine positiivseteks ja negatiivseteks on ära toodud tabelis 1. Lisaks tuli ära klassifitseerida ka vabatekstina sisestatud emotsioonide kirjeldused - võimalus, mida mitmed isikud ka kasutasid. Osad inimesed sisestasid vabatekstina lihtsalt nimekirjast puuduolevaid emotsioonisõnu, teised aga väljendasid oma emotsiooni pikema kirjeldusega, näiteks “ammu juba ei saa millestki aru”. Vabatekstina sisestatud emotsioonisõnu ja kirjeldusi eeltöödeldi nii, et iga sõna ja kirjelduse puhul seostati ta mingi konkreetse emotsioonisõnaga, mis kas võis juba eelnevalt nimekirjas olemas olla või siis lisati sinna. Näiteks eeltoodud näide “ammu juba ei saa millestki aru” seostati sõnaga “segaduses”. Sellisel viisil tekkis juurde hulk nii positiivseid, negatiivseid kui neutraalseid emotsioonisõnu, mis on kajastatud tabelis 5. Kui enamus sõnade puhul oli nende jaotuvus positiivseks või negatiivseks üsna selge, siis osade sõnade (näiteks *ootusärev*) puhul oli raskem otsutada, kas tegemist on pigem positiivse või negatiivset emotsioonisõnaga. Kahtluste puhul konsulteeriti Ene Vainiku magistritööga (Vainik, 2001), mis kirjeldab, milliseid sõnu eestlased üldiselt peavad positiivse emotsionaalsusega

Tabel 5

Ankeedis vabatekstina esitatud emotsioonisõnad.

	Positiivsed		Negatiivsed		Neutraalsed
Enne	hetkes viibiv		ebamugav	ükskõikne	hajameelne
	rahulik		igavlev	ülekoormatud	mõtlik
	sitke		jõuetu	valu	neutraalne
	tänulik		laisavõitu		tavaline
	tasane		loid		tõine
	tüüne		murelik		tõsine
	unistav		ootusärev		väsinud
Pärast	igatsev	ootus	kahetsev		imestunud
	kannatlik	rahulolev	kahjurõõmus		neutraalne
	kergendus	sentimentaalne	rahutu		väsinud
	lootusrikas	tänulik	ükskõikne		
	muhelev	unistav	vastumeelsus		
	naljakas	uudishimulik			
	nostalgiline				

ning milliseid loetakse pigem negatiivseks. Siiski tuleb leppida sellega, et lõplik jaotus on paratamatult mõnevõrra subjektiivne.

Tabelis 6 on esitatud ülalkirjeldatud viisil saadud emotsioonide skooride keskmised väärtused erinevad gruppide (mehed vs naised, depressiooni riskiga vs riskita, ärevuse riskiga vs riskita) lõikes nii enne kui pärast pildi ja sündmuse/mälestuse kirjeldust. Tabelist on näha, et esmakordsel emotsioonide nimetamisel on emotsioonide üldine keskmine skoor nullilähedane ehk ligikaudu neutraalne ning see ei erine meeste ja naiste lõikes ($t\text{-stat}=0.162$, $p=0.87$).

Samas on selgelt näha, et nii depressiooni kui ka ärevuse riskiga isikute esimene keskmine skoor on negatiivne ja oluliselt madalam kui riski lävendit mitte ületanud isikute oma ning see erinevus oli statistiliselt oluline nii depressiooni ($t\text{-stat}=-9.865$, $p<0.0001$) kui ka ärevuse ($t\text{-stat}=-7.483$, $p<0.0001$) puhul.

Pärast vabalt valitud sündmuse/kogemuse kirjutamist raporteerisid inimesed oluliselt rohkem positiivseid emotsioone, mida kajastab ka üleüldine keskmine skoori tõus pea-


Tabel 6

Emotsioonide skooride keskmised väärtused erinevate gruppide lõikes.


	Emotsioonid enne Keskvärtus (SD)	Emotsioonid pärast Keskvärtus (SD)
Kokku	0.05 (3.29)	1.92 (4.15)
Naised	0.06 (3.32)	1.98 (4.17)
Mehed	-0.02 (3.12)	1.65 (4.10)
Depressiooni riskiga	-1.89 (2.93)	1.16 (4.51)
Depressiooni riskita	1.44 (2.79)	2.48 (3.80)
Ärevuse riskiga	-2.01 (3.16)	0.98 (4.33)
Ärevuse riskita	0.89 (2.95)	2.31 (4.03)

aegu kahe punkti võrra. Meeste ja naiste vahel jällegi skoorides olulist erinevust ei leitud (U-stat=5710, $p=0.17$). Samas erinevus enne ja pärast skooride vahel oli statistiliselt oluline (Wilcoxon statistik=8897.0, $p<0.0001$). See kehtis eraldi nii naistele (Wilcoxon statistik=6413.0 $p<0.0001$) ja meestele (t -stat=-3.376, $p=0.0014$), depressiooni riski lävendi ületanutele (t -stat=-6.925, $p<0.0001$) ja depressiooni riskita isikutele (t -stat=-3.321, $p=0.0011$) kui ka ärevuse riski lävendi ületanutele (t -stat=-5.679, $p<0.0001$) ning ärevuse riskita isikutele (Wilcoxon statistik=4691.0, $p<0.0001$). Sellest võib järeldada, et inimesed üldiselt kirjeldasid meeldivaid sündmusi ja mälestusi, mis vähemalt hetkel tõstsid nende meeleolu. Seda iseloomustab näiteks ka asjaolu, et pärast sündmuse/mälestuse kirjeldust küsitud emotsioonide hulgas raporteeriti vabatekstina üsna sageli ka nostalgiat. Võrreldes emotsioonide erinevust pärast oli keskväärtuste erinevus depressiooni riskiga ja riskita inimeste vahel vähenenud ning korrigeeritud olulisusnivooga ($p=0.0016$) enam statistilist olulisust ei saavutanud (t -stat=-2.709, $p=0.009$). Samasugune keskmiste erinevuste vähenemine on näha ka ärevuse puhul (U-stat=7176.0, $p=0.0065$).


Enne ja pärast emotsioonide vahel oli nõrk kuid statistiliselt oluline korrelatsioon (pearsoni $r=0.28$, $p<0.0001$). Seda seost illustreeriv hajuvusdiagramm on esitatud joonisel 4a. Joonistel 4b-4e on esitatud hajuvusdiagrammid korrelatsioonide kohta enne ja pärast emotsioonide skooride ning depressiooni ja ärevuse alaskaalade skooride vahel. Esialgsete emotsioonide ning depressiooni vahel on tugev negatiivne korrelatsioon (pearsoni $r=-0.60$, $p<0.0001$). Esialgsete emotsioonide ning ärevuse alaskaala skooride vahel on




(a) Emotsioonid enne ja pärast.




(b) Emotsioonid enne ja depressioon.



(c) Emotsioonid pärast ja depressioon.



(d) Emotsioonid enne ja ärevus.



(e) Emotsioonid pärast ja ärevus.

Joonis 4. Korrelatsioonid emotsioonide ning depressiooni ja ärevuse alaskaalade vahel.

Tabel 7

Kogutud andmestiku tekstilise osa statistilised näitajad.

	Pildi kirjeldus		Vaba kirjeldus	
Keskmine lausete arv (SD)	10.0	(3.9)	7.2	(4.6)
Keskmine sõnade arv (SD)	134.1	(41.3)	105.1	(58.8)
Sõnastiku suurus	7029		7862	
Lemmade arv	4206		4691	

korrelatsioon absoluutväärtuselt natuke väiksem, kuid siiski mõõdukalt tugev (pearsoni $r=-0.47$, $p<0.0001$).

Ilmselt ei ole esitatud korrelatsioonikordajad kuigi üllatavad - tundub loogiline, et inimesed, kes raporteerivad rohkem depressiivseid ja ärevaid sümptomeid, kogevad ka rohkem negatiivseid emotsioone. Pigem on kõik toodud võrdlused emotsiooniskooride ja depressiooni ning ärevuse riskiskooride vahel kasulikud veendumaks, et välja pakutud protseduur emotsioonide hinnangute numbrilisteks skoorideks konverteerimiseks on mõistlik ja et seda võib ka edasises töös kasutada.

Teistkordselt mõõdetud emotsioonide ning depressiooni- ja ärevuse alaskaalade vahelised korrelatsioonid on väiksemad: depressiooni puhul pearsoni $r=-0.20$ ($p=0.0007$), ärevuse puhul pearsoni $r=-0.13$ ning see seos ei olnud enam statistiliselt oluline ($p=0.03$).

Üldjoontes võib öelda, et kuigi tundus keeruline koostada ankeeti emotsionaalse seisundi pärimiseks, mis sisaldaks piisavalt representatiivset hulka emotsioonisõnu, aga samas ei pakuks liiga pikka nimekirja, mille hindamine oleks inimestele kurnav, siis esitatud analüüside põhjal on alust arvata, et kogutud emotsioonide andmed sisaldavad potentsiaalselt kasulikku infot. Detailsem raporteeritud emotsioonisõnade analüüs aga käesoleval hetkel antud töö skooopi ei mahu ning jääb edasiseks tööks.

Ennustavad mudelid masinõppe abil

Tabelis 7 on ära toodud statistika andmestiku tekstiliste osade kohta. Pildi kirjelduse keskmine lausete ja sõnade arv on suurem kui vabalt valitud sündmuse või mälestuse kirjeldusel. See on ka oodatav, sest pildi kirjelduse minimaalne sõnade arvu piirang oli 100, vabal teemal kirjutatud teksti puhul aga 50. Kui vaba kirjelduse puhul on keskmine teksti pikkus minimaalselt nõutust suurem rohkem kui kaks korda, siis pildi kirjelduse

Tabel 8

Masinõppe mudelite ennustuste tulemused.

	Pildi kirjeldus	Vaba kirjeldus
Valitud pilt	93.5 (0.01)	47.6 (0.006)
Depressioon	61.0 (0.03)	57.9 (0.01)
Ärevus	70.9 (0.002)	70.9 (0.002)

puhul ületatati nõutavat miinimumi keskmiselt vähem. See statistika viitab, et inimestel on lihtsam kirjutada vabalt valitud ning nende endiga seotud teemadel ning ette antud pilti kirjeldada nõutud arvu sõnade abil on keerulisem. Erinevate sõnade arv on vabal kirjeldusel mõnevõrra suurem kui piltide kirjelduste puhul, kuigi mõlemal juhul on sõnas-
tiku suurus arvestades andmestiku väiksust üllatavalt suur. Seetõttu eeltöödeldi tekste edasi rakendades lemmatiseerimist, mis muudab suurtähe lause alguses väiketäheks ning asendab iga käänatud või pööratud sõnavormi tema algvormiga. Seeläbi õnnestus sõnas-
tiku suurus nii piltide kirjelduse kui vabateksti korral vähendada pea kaks korda.

Edasi treeniti järgmised ennustavad masinõppe mudelid kasutades regulariseeritud logis-
tilist regressiooni:

- Vaba kirjelduse alusel valitud pildi ennustamine.
- Pildi kirjelduse alusel valitud pildi ennustamine.
- Vaba kirjelduse alusel depressiooni klassi kuuluvuse ennustamine.
- Vaba kirjelduse alusel ärevuse klassi kuuluvuse ennustamine.
- Pildi kirjelduse alusel depressiooni klassi kuuluvuse ennustamine.
- Pildi kirjelduse alusel ärevuse klassi kuuluvuse ennustamine.

Esialgsete eksperimentide tulemused on ära toodud tabelis 8. Igas tabeli lahtris on ära toodud viie ristvalideerimise mudeli keskmine ennustuse täpsus, sulgudes on standard-
hälve. Tabelist on näha, et pildi kirjelduse alusel õnnestub päris hästi ennustada, millist pilti kirjeldati. See tulemus ei ole üllatav, sest ilmselt kasutati iga nelja pildi kirjelda-
miseks üsna erinevat sõnavara. Vaba kirjelduse alusel pildi ennustamine aga väga hästi ei õnnestunud. Saavutatud keskmine täpsus 47.6% on täpselt võrdne täpsusega, mida on

võimalik saada, kui alati ennustada kõige sagedasemat pilti C. Vaba kirjelduse alusel pilti ennustama õppinud mudel paraku seda tegigi - lihtsalt ennustas alati pilti C.

Depressiooni ennustamine pildi kirjelduse alusel õnnestus natuke täpsemalt kui vaba kirjelduse alusel. Pildi kirjelduse alusel saavutatud tulemus 61.0% on ka natuke kõrgem alati klassi 0 (ilma riskita) ennustavast baasmudelist, mille täpsus oleks olnud 58%. Selle info valguses on huvitav näha, et vaba kirjelduse alusel treenitud mudel ennustab isegi natuke kehvemini kui baasmudel. Ärevuse ennustamise täpsus nii pildi kirjelduse kui ka vaba kirjelduse alusel oli täpselt identne ning paraku jällegi võrdne enamusklassi ennustava baasmudeli täpsusega.

Sooritatud eksperimentide alusel võib öelda, et tegemist on keerulise andmestikuga, mille alusel lihtsate optimeerimata lineaarsete meetodite abil täpselt ennustavat masinõppe mudelit treenida ei ole võimalik.

Arutelu ja järeldused

Käesoleva töö eemärgiks oli välja töötada metoodika, mida saaks tulevikus rakendada tekstiliste andmete kogumiseks nii kliiniliselt (depressiooni ja ärevuse diagnoosiga isikud) kui tervetelt kontrollsubjektidelt. Planeeritud andmestiku kogumise eesmärgiks on hiljem kasutada neid andmeid teksti alusel depressiooni ja ärevuse riski hindavate masinõppe mudelite loomiseks. Tööst võib teha mitmeid edasist tegevust suunavaid kasulikke järeldusi.

Esiteks, kuigi käesolevas töös kasutatud valim ei olnud plaanitud kliiniline, siis sattus sellesse päris suur hulk inimesi, kes EEK-2 skriiningtesti alusel ületasid depressiooni ja/või ärevuse riski lävendeid. See ei tähenda, et riski lävendi ületanud inimesed kannataksid kliinilise depressiooni või ärevuse all, kuigi andmestiku jagamisel gruppideks neid töös niimoodi käsitleti. Praktiliselt tähendab see seda, et töös kasutatud depressiooni ja ärevuse gruppidest teadmata protsent inimesi tegelikult kliinilist depressiooni ega ärevust ei põe ning see võis mõjutada erinevaid analüüse ning eksperimentide tulemusi. Teiseks tähendab antud tulemus aga ka seda, et tegelikult on võimalik leida inimesi kliinilise gruppi ka mugavusvalimi vabatahtlike seast, kuigi nende täpne diagnoos või selle puudumine tuleks üle kontrollida kliinilise psühholoogi poolt.

Teiseks jäi mulje, et inimestel oli üsna keeruline produtseerida nõutud arv sõnu pildi kirjeldamiseks. Motiiv pildi kirjelduse ülesande kasutamiseks oli võtta kirjutatava teksti

teemad kontrolli alla, et välistada sotsiaalmeedia andmestikke kasutades ähvardavat ohtu, et ennustav mudel õpib tegema vahet erinevate teemade vahel ja mitte näiteks depressiooni all kannatavate ja tervete isikute vahel. Tundub, et pildi kirjeldamise paradigma end siiski ei õigusta. Pigem oleks vaja leida ülesanne, mida inimestel on kergem täita ja mille puhul nad on valmis ja võimelised kergemini rohkem sõnu kirjutama. Vabalt valitud sündmuse või mälestuse kirjeldamine oli inimestele ilmselt kergem. Samas tundub masinõppe eksperimentide alusel, et keskmiselt 100 sõna isiku kohta on natuke liiga vähe andmeid, et ennustavaid mudeleid treenida. Seega on vaja tulevikus disainida ülesanne, mis oleks oma raskus- (või pigem kergusastmelt) sarnane vaba teema kirjeldusele, aga mis õhutaks ja võimaldaks inimestel kirjutada korduvalt ja pikemalt.

Andmestik sisaldab ka emotsioonisõnade nimekirja abil kogutud emotsionaalse enesetunde hinnanguid, mida küsiti kaks korda. Seda andmestiku osa käesolevas töös väga põhjalikult ei analüüsitud ning tulevikus on võimalik seda põhjalikumalt uurida. Praegusel hetkel selgus ainult, et emotsioonisõnade baasil arvutatud emotsiooniskoor korreleerus tugevalt EEK-2 depressiooni alaskaala skooriga ning mõõdukalt ärevuse alaskaala skooriga. Samuti selgus, et vabalt valitud sündmuseks valisid inimesed tüüpiliselt midagi meeldivat, mis tõstis keskmist teistkordselt mõõdetud emotsiooniskoori oluliselt. Samas oli korrelatsioon enne ja pärast mõõdetud skooride vahel pigem nõrk, mis viitab sellele, et kui osade inimeste emotsionaalne enesetunne vabalt valitud sündmuse/mälestuse kirjeldamise tagajärel paranes, siis teistel hoopis langes.

Töös sooritati ka esialgsed eksperimendid ennustavate masinõppe mudelite abil. Üldiselt need eksperimendi häid tulemusi ei andnud ja enamik treenitud mudeleid ennustas sama hästi, kui lihtsalt kõige sagedasemat kategooriat valiv triviaalne mudel. See ei tähenda, et masinõppe rakendamine kogutud andmestikule oleks lootusetu ettevõtmine, kuigi kergesti väga häid tulemusi ilmselt loota ei tasu. Kasutatud mudel, regulariseeritud logistiline regressioon, on üks lihtsamaid võimalikke ning ka sel lihtsal mudelil on mõningaid valitavaid hüperparameetreid, mis võivad mudeli tulemust oluliselt mõjutada, aga mida käesolevates esialgsetes eksperimentides süstemaatiliselt ei valitud. Lisaks on võimalik, et kasutades keerukamaid representatsioone õppivaid tehishälvõrke (Kim, 2014; Yang et al., 2016), mis oskavad kasutada suurtel tekstimahtudel eeltreenitud sõnade representatsioone, on võimalik saavutada kõrgemaid klassifitseerimistäpsusi ka sellel andmestikul.

Kirjanduse loetelu

- Allik, J., & Realo, A. (1997). Emotional experience and its relation to the Five-Factor Model in Estonian. *Journal of Personality*, 65(3), 625–647.
- Aluoja, A., Shlik, J., Vasar, V., Luuk, K., & Leinsalu, M. (1999). Development and psychometric properties of the Emotional State Questionnaire, a self-report questionnaire for depression and anxiety. *Nordic Journal of Psychiatry*, 53(6), 443–449.
- Benton, A., Mitchell, M., & Hovy, D. (2017). Multitask learning for mental health conditions with limited social media data. In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: Volume 1, Long Papers* (pp. 152–162).
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Bland, J. M., & Altman, D. G. (1995). Multiple significance tests: the Bonferroni method. *British Medical Journal*, 310(6973), 170.
- Chung, C., & Pennebaker, J. W. (2007). The psychological functions of function words. *Social communication*, 1, 343–359.
- Coppersmith, G., Dredze, M., & Harman, C. (2014). Quantifying mental health signals in Twitter. In *Proceedings of the workshop on computational linguistics and clinical psychology: From linguistic signal to clinical reality* (pp. 51–60).
- De Choudhury, M., Gamon, M., Counts, S., & Horvitz, E. (2013). Predicting depression via social media. In *Seventh international AAAI conference on weblogs and social media* (pp. 1–10).
- Ekman, P. (1992). Are there basic emotions? *American Psychological Association*.
- Ernala, S. K., Birnbaum, M. L., Candan, K. A., Rizvi, A. F., Sterling, W. A., Kane, J. M., & De Choudhury, M. (2019). Methodological Gaps in Predicting Mental Health States from Social Media: Triangulating Diagnostic Signals. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems* (pp. 134:1–134:16).
- Goldberg, Y. (2017). Neural network methods for natural language processing. *Synthesis Lectures on Human Language Technologies*, 10(1), 1–309.
- Ive, J., Gkotsis, G., Dutta, R., Stewart, R., & Velupillai, S. (2018). Hierarchical neural model with attention mechanisms for the classification of social media text related to mental health. In *Proceedings of the Fifth Workshop on Computational Linguistics*

- and Clinical Psychology: From Keyboard to Clinic* (pp. 69–77).
- Kim, Y. (2014). Convolutional neural networks for sentence classification. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing* (pp. 1746–1751).
- Loveys, K., Crutchley, P., Wyatt, E., & Coppersmith, G. (2017). Small but mighty: affective micropatterns for quantifying mental health from social media language. In *Proceedings of the Fourth Workshop on Computational Linguistics and Clinical Psychology—From Linguistic Signal to Clinical Reality* (pp. 85–95).
- Orth, U., Berking, M., & Burkhardt, S. (2006). Self-conscious emotions and depression: Rumination explains why shame but not guilt is maladaptive. *Personality and social psychology bulletin*, *32*(12), 1608–1619.
- Pennebaker, J. W. (1997). Writing about emotional experiences as a therapeutic process. *Psychological science*, *8*(3), 162–166.
- Pennebaker, J. W., Boyd, R. L., Jordan, K., & Blackburn, K. (2015). *The development and psychometric properties of LIWC2015* (Tech. Rep.).
- Pennebaker, J. W., Kiecolt-Glaser, J. K., & Glaser, R. (1988). Disclosure of traumas and immune function: health implications for psychotherapy. *Journal of consulting and clinical psychology*, *56*(2), 239.
- Pennebaker, J. W., Mehl, M. R., & Niederhoffer, K. G. (2003). Psychological aspects of natural language use: Our words, our selves. *Annual review of psychology*, *54*(1), 547–577.
- Plutchik, R. (2001). The nature of emotions: Human emotions have deep evolutionary roots, a fact that may explain their complexity and provide tools for clinical practice. *American scientist*, *89*(4), 344–350.
- Qi, P., Dozat, T., Zhang, Y., & Manning, C. D. (2018). Universal dependency parsing from scratch. In *Proceedings of the CoNLL 2018 shared task: Multilingual parsing from raw text to universal dependencies* (pp. 160–170).
- Schwartz, H. A., Eichstaedt, J., Kern, M. L., Park, G., Sap, M., Stillwell, D., . . . Ungar, L. (2014). Towards assessing changes in degree of depression through facebook. In *Proceedings of the Workshop on Computational Linguistics and Clinical Psychology: From Linguistic Signal to Clinical Reality* (pp. 118–125).
- Stanton, K., & Watson, D. (2014). Positive and negative affective dysfunction in psych-

- hopathology. *Social and Personality Psychology Compass*, 8(9), 555-567.
- Tausczik, Y. R., & Pennebaker, J. W. (2010). The psychological meaning of words: LIWC and computerized text analysis methods. *Journal of language and social psychology*, 29(1), 24–54.
- Vainik, E. (2001). Eestlaste emotsioonisõnavara. *Tartu Ülikooli magistr töö*.
- Yang, Z., Yang, D., Dyer, C., He, X., Smola, A., & Hovy, E. (2016). Hierarchical attention networks for document classification. In *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies* (pp. 1480–1489).
- Yates, A., Cohan, A., & Goharian, N. (2017). Depression and self-harm risk assessment in online forums. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing* (pp. 2968–2978).

Käesolevaga kinnitan, et olen korrektelt viidanud kõigile oma töös kasutatud teiste autorite poolt loodud kirjalikele töödele, lausetele, mõtetele, ideedele või andmetele.

Olen nõus oma töö avaldamisega Tartu Ülikooli digitaalarhiivis DSpace.

Kairit Sirts