

Teemu Salonen

**TUNNETILOJEN VAIKUTUS VIREYSTILAAN
YLIOPISTOMATEMATIIKAN
OPPIMISTILANTEISSA**

Diplomityö
Tekniikan ja luonnontieteiden tiedekunta
Marraskuu 2023

TIIVISTELMÄ

Teemu Salonen: Tunnetilojen vaikutus vireystilaan yliopistomatematiikan oppimistilanteissa
Diplomityö
Tampereen yliopisto
Matemaattisten aineiden DI-opettajankoulutus
Marraskuu 2023

Tässä työssä tutkittiin millaisia tunnetiloja ja vireystiloja yliopistomatematiikan oppimistilanteissa esiintyy. Lisäksi haluttiin selvittää eroavatko oppimistilanteissa mitatut vireystilat ja havaitut tunnetilat käänteisen opetuksen ja luentopainotteisen opetuksen välillä. Tutkimuksessa haluttiin myös saada selville voidaanko tunnetilojen avulla ennustaa vireystilaa. Aiemmat tutkimukset ovat osoittaneet, että tunnetilat ja vireystila vaikuttavat ihmisen suorituskykyyn ja oppimiseen, joten niiden tutkiminen on oppimisen ja opetuksen kannalta tärkeää.

Tutkimusaineisto kerättiin Tampereen yliopistolla syksyllä 2019. Tutkimukseen osallistui 75 opiskelijaa, joista 37 suoritti opintojakson flippaustoteutusta, jossa opetus tapahtui käänteisellä opetuksella, kun taas loput 38 osallistuivat luentopainotteiselle toteutukselle. Tutkimuksessa opiskelijoiden vireystilaa mitattiin älysormuksella ja matematiikan oppimistilanteiden aikana koetut tunnetilat kysyttiin opiskelijoilta LearningTracker-sovelluksen avulla ennen oppimistilanteita ja niiden päätyttyä.

Kerätystä datasta tarkasteltiin oppimistilanteiden aikaisia vireystiloja ja tunnetiloja. Oppimistilanteen ajalta mitatut keskimääräiset vireystilat jaettiin viiteen luokkaan suuruuden mukaan. Tutkimuksessa havaittiin että yli 44%:ssa oppimistilanteista keskimääräinen vireystila kuului korkeimpaan luokkaan, joka luokittelussa tarkoitti erittäin kiihtynyttä. Vireystilan havaittiin myös olevan keskimäärin korkeampi itsenäisissä, kuin ohjatuissa oppimistilanteissa. Myös käänteisessä opetuksessa havaittiin keskimäärin korkeampia vireystiloja, kuin luentopainotteisella toteutuksella. Oppimistilanteiden aikana havaituista tunnetiloista suurin osa oli positiivisia tunteita. Toisaalta deaktivoivat tunnetilat olivat aktivoivia tunnetiloja yleisempiä. Havaituissa tunnetiloissa ei ollut suuria eroja opintojakson flippaustoteutuksen ja luentototeutuksen välillä.

Mitattujen vireystilojen ja havaittujen tunnetilojen välistä yhteyttä tutkittiin lineaaristen mallien avulla. Mittausdatasta muodostettiin lineaarisia malleja, joissa havaittuja tunnetiloja käytettiin prediktoreina vireystilan suuruudelle. Tätä varten tunnetilat oli jaoteltu positiivisiin ja negatiivisiin tunnetiloihin sekä aktivoiviin ja deaktivoiviin tunnetiloihin. Saatujen tulosten perusteella ei voitu osoittaa positiivisten ja negatiivisten tunnetilojen sekä vireystilan välille yhteyttä. Toisaalta tutkimustulosten perusteella myöskään aktivoivien ja deaktivoivien tunnetilojen ja vireystilan välillä ei olisi yhteyttä, vaikka aktivoivat aktivoivat tunnetilat tarkoittavat juuri korkean vireystilan tunnetiloja ja vastaavasti deaktivoivat tunnetilat matalamman vireystilan tunnetiloja. Myös osa muistakin tutkimusatuloksista oli ristiriidassa aiempien tutkimusten kanssa, mutta näitä eroja voidaan perustella esimerkiksi tutkittavien ryhmien välisillä eroilla. Tämä kuitenkin jättää hieman epävarmuutta saatujen tutkimustulosten ylle, mutta varmasti kannustaa jatkotutkimuksille aiheeseen liittyen.

Avainsanat: vireystila, tunnetila, lineaarinen malli, matematiikka, oppiminen

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -ohjelmalla.

ABSTRACT

Teemu Salonen: Emotions' effect on general arousal when learning university mathematics
Master of Science Thesis
Tampere University
Master's Degree Programme in Science and Engineering
November 2023

In this thesis we investigate what kind of emotions and general arousal are present while studying university level mathematics in different type of situations. We also want to find out if there is a difference in observed emotions and arousal between flipped learning and lecture-based learning situations. One of the goals of the research was also finding out if general arousal in different learning situations can be predicted using emotions. Earlier studies show that emotions and general arousal have effect on both performance and learning of a human so research on them is really important for better understanding of learning and teaching.

Research data was collected at Tampere university in 2019. 75 students in total participated in this research. Students were sorted into two groups which both had different teaching methods. 37 of them studied the course using flipped learning while the rest of them had lecture-based teaching. In research, general arousal was measured using smart ring and the information about students emotions during different learning situations was collected using LearningTracker-application.

General arousal and emotions during learning situations were studied from collected data. Values of arousal were divided into five groups based on their magnitude. We found out that the average arousal level during learning situation was in the highest group over 44% of the time. Highest group was labeled as very agitated. We also found out that on average arousal was higher during independent study sessions compared to heavily guided learning situations like lectures. Average arousal was also higher in flipped learning than on lecture-based studying. Most of the emotions during studying situations were positive. Although deactivating emotions were more common than activating emotions. When comparing positive and negative emotions and activating and deactivating emotions between flipped learning and lecture-based studying, there were no significant differences.

The possible connection between emotions and arousal was analysed using linear models. Linear models that were formed tried to predict general arousal using positive and negative emotions and activating and deactivating emotions from data. As a result, no connection between emotions and general arousal was found. The fact the there was no connection between activating and deactivating emotions and arousal was surprising. Activating emotions are defined as high arousal emotions while deactivating emotions are supposed to be low arousal emotions. Some other results also didn't match with the predictions made based on earlier studies, but those differences can be explained with the differences between this study and the earlier studies. However this leaves some doubt on the accuracy of the results in this study, but that should just motivate people into continuing studying on this subject.

Keywords: arousal, general arousal, emotion, linear model, mathematics, learning

The originality of this thesis has been checked using the Turnitin OriginalityCheck service.

SISÄLLYSLUETTELO

1.	Johdanto	1
2.	Vireystila	3
2.1	Vireystilan mittaaminen	4
2.2	Vireystila oppimistilanteissa.	5
3.	Tunnetilat.	7
3.1	Tunnetilojen jaottelu.	7
3.2	Tunnetilat oppimistilanteissa	9
3.3	Tunnetilat yhteydessä vireystilaan	9
4.	Lineaariset mallit.	11
4.1	Lineaariset mallit	11
4.2	Lineaariset monitasomallit	16
4.3	Lineaaristen mallien arvioiminen ANOVA-funktiolla	17
4.4	Lineaarisen monitasomallin muodostaminen R-ohjelmistossa	19
5.	Tutkimusmenetelmät	23
5.1	Tutkimuskysymykset	23
5.2	Tutkimusaineisto	24
5.3	Aineiston valmistelu.	24
5.4	Data-analyysi	26
6.	Tulokset	27
6.1	Vireystila oppimistilanteissa.	27
6.2	Tunnetilat oppimistilanteissa	29
6.3	Vireystila ja tunnetilat oppimistilanteissa.	34
7.	Johtopäätökset	41
7.1	Vastaukset tutkimuskysymyksiin	41
7.2	Tulosten arviointi	43
	Lähteet	46
	Liite A: Tulokset tunnetilakysymyksistä	48

LYHENTEET JA MERKINNÄT

AIC	'Akaike information criterion', kuvaa mallin laatua
BIC	'Bayesian information criterion', kuvaa mallin laatua
CI	'Confidence interval' eli regressiokertoimen luottamusväli
EDA	'Electrodermal activity' eli sähkönjohtavuuden muutos
ICC	'Intraclass correlation coefficient', kuvaa korrelaatiota klusterin sisällä
LTR	'Likelihood-ratio test' eli todennäköisyysuhdetesti
R^2	Kertoo kuinka suuri osuus ennustettavan muuttujan varianssista voidaan selittää valittujen prediktorien avulla
σ^2	Varianssi

1. JOHDANTO

Niin oppiessa kuin opettaessa on tärkeä ymmärtää oppimiseen liittyviä ja vaikuttavia tekijöitä. Tunnetilojen vaikutuksista ihmisen oppimiseen on tehty useita tutkimuksia. Esimerkiksi Forsblomin ja kumppaneiden tutkimuksessa [8] on havaittu selkeä yhteys tunnetilojen ja oppimistulosten välille matematiikassa. Positiiviset tunnetilat johtavat positiivisiin tuloksiin ja positiiviset tulokset saavat aikaan positiivisia tunnetiloja. Toisaalta vastaavasti myös negatiiviset tunnetilat heikentävät tuloksia.

Vireystila sen sijaan vaikuttaa ihmisen suorituskykyyn. Yleensä vireystilaa, jossa saavutetaan paras suorituskyky, kutsutaan optimivireydeksi ja tätä korkeammat tai matalammat vireystilat heikentävät suorituskykyä [16]. Matematiikan oppimisen kannalta suorituskyvyllä voidaan tarkoittaa esimerkiksi kuinka hyvin opiskelija kykenee ratkomaan tehtäviä. Sopivan vireystilan taso riippuu myös tehtävän vaikeudesta [16]. Esimerkiksi helpot tehtävät onnistuvat tehokkaasti vireystilan ollessa korkeampi, mutta tällöin vaikeisiin tehtäviin on hankalampi keskittyä.

Koska vireystilalla ja tunnetiloilla on suuri merkitys oppimisen ja suorituskyvyn kannalta, on tärkeää tuntea millaisia tunnetiloja ja vireystiloja matematiikan opetuksessa esiintyy. Opiskelijoiden tunnetiloihin ja vireystiloihin vaikuttamalla voidaan myös yrittää parantaa suorituksia sekä esimerkiksi kasvattaa opiskelijoiden motivaatiota positiivisten tunnetilojen kautta.

Toinen motivoiva tekijä tutkimukselle on pitkittäisdatan puute tutkittavalta aihealueelta. Pitkittäisdata tarkoittaa, että esimerkiksi samalta henkilöltä mitataan samoja asioita pidemmällä aikavälillä. Pitkittäisdatassa on monia etuja [29]. Pitkittäisdatan avulla voidaan helposti seurata muutosta. Koska mittaukset tehdään aina samoille henkilöille, voidaan henkilöiden väliset erot karsia pois tuloksista, jolloin tuloksista voidaan helpommin löytää muut vaikuttavat tekijät. Kuten Sørlien ja kumppaneiden artikkelissa [27] kerrotaan, tutkimuksia, joissa pitkittäisdataa on kerätty, on vain vähän ja näissäkin mittausvälit ovat pitkiä. Tästäkin syystä tehty tutkimus oli tärkeää.

Tässä tutkimuksessa haluttiin selvittää millaisia tunnetiloja ja vireystiloja yliopistomatematiikan oppimistilanteissa esiintyy. Tämän lisäksi tutkittiin eroavatko käänteisessä opetuksessa ('flippauksessa') olleiden opiskelijoiden tunnetilat ja vireystilat perinteisellä luentototeutuksella olleiden opiskelijoiden tunnetiloista ja vireystiloista. Tutkimuksessa haluttiin

myös selvittää voidaanko tunnetilojen avulla ennustaa vireystilaa. Tutkimukseen liittyvät mittaukset suoritettiin Tampereen yliopistolla syksyllä 2019. Tunnetiloista kerättiin dataa LearningTracker-sovelluksella ja vireystilaa mitattiin älysormuksen avulla. Tutkimukseen osallistuneilta opiskelijoilta kerättiin aineistoa noin kahden viikon ajalta.

Työssä käsitellään ensimmäisenä vireystilaa ja sen vaikutuksia. Samalla esitellään kuinka vireystilaa voidaan mitata sekä tutustutaan lyhyesti muihin tutkimuksiin, joissa vireystilaa on tarkasteltu oppimistilanteissa. Luvussa 3 käsitellään tunnetiloja ja niiden jaottelua. Lisäksi tarkastellaan, millaisia tunnetiloja oppimistilanteissa yleensä havaitaan, sekä tutustutaan tunnetiloihin ja vireystilaan oppimistilanteissa. Luvussa 4 käsitellään lineaarisia malleja alkaen yksinkertaisista lineaarisista malleista lineaarisiin monitasomalleihin saakka. Tämän jälkeen tutustutaan lineaaristen mallien muodostamiseen ja niiden vertailuun R-ohjelmistokielen avulla. Luvussa 5 esitellään tarkemmin työssä tehtävää tutkimusta muun muassa esittelemällä tutkimuskysymykset ja hypoteesit, sekä esittelemällä tutkimusaineiston ja tutkimusmenetelmät. Luvussa 6 esitellään tutkimustulokset. Luvussa 7 analysoidaan tutkimustuloksia ja esitetään vastaukset tutkimuskysymyksiin tulosten perusteella. Lopuksi vielä pohditaan tulosten luotettavuutta.

2. VIREYSTILA

Vireystila (arousal) voidaan määritellä fysiologiseksi reaktioksi psyykkisen tilan muutokseen [17]. Vireystilan voidaan eräällä tavalla ajatella kuvaavan ihmisen olotilaa. Korkeampi vireystila kertoo ihmisen olevan valppaampi erilaisille ärsykkeille. Tällöin ihminen on myös tunteikkaampi ja motorisesti aktiivisempi. [21] Vireystilaan vaikuttavat monet tekijät ja sillä on suuri vaikutus ihmisen olotilaan ja käytökseen. Vireystilat voidaan jakaa karkeasti ylivireyteen, optimivireyteen ja alivireyteen, jotka kaikki vaikuttavat eri tavoin ihmisen toimintaan ja suorituskykyyn. [13]

Ylivireys tarkoittaa tavallisesta poikkeavaa korkeampaa vireystilaa. Psykologi Hanna Markukselan [13] mukaan tämä aiheutuu useasti esimerkiksi kiireisestä aikataulusta, huolista tai uhkan tunteesta. Ylivireystilassa kehoon erittyy stressihormonina tunnettua kortisolia ja pidempiaikainen ylivireys aiheuttaakin stressiä ja mahdollisesti ahdistuneisuutta sekä ärtyneisyyttä. Muita fyysisiä vaikutuksia ylivireydellä on esimerkiksi kohonnut syke ja pinnallinen hengitys. Ylivireystilassa ihmisen on vaikea keskittyä yhteen asiaan ja nukahtaminen on yleensä vaikeampaa. Ylivireystilassa ihminen on vilkkaampi ja energisempi, joka voi lyhyellä jaksolla jopa parantaa hänen suorituskykyään, jolloin ulkopuolisen voi olla vaikeaa havaita ongelmia. Pidemmällä jaksolla jatkuva ylienergisyys kuitenkin uuvuttaa ja altistaa muille ongelmille. Ylivireystilassa ihminen monesti sivuuttaa omia tarpeitaan, mikä voi toimia esimerkiksi alkuna syömishäiriön syntymiselle.

Ylivireys voi aiheutua myös positiivisten tekijöiden, kuten esimerkiksi innostumisen takia. Erityisesti positiivisten tekijöiden aiheuttama ylivireys voi kasvattaa ihmisen suorituskykyä. Ylivireydestä aiheutuu kuitenkin samoja ongelmia pitkällä aikavälillä riippumatta siitä, oliko aiheuttajana positiivinen tekijä kuten innostus vai negatiivinen tekijä kuten uhan tunne. Tästä syystä ylivireyteen on hyvä puuttua mahdollisimman nopeasti, kun sen oireita, kuten unettomuutta tai keskittymisvaikeuksia on havaittavissa. [13]

Vastaavasti kuten ylivireys, alivireys tarkoittaa tavallisesta poikkeavaa matalampaa vireystilaa. Alivireys aiheutuu usein siitä, että ihminen on ajanut itsensä loppuun, esimerkiksi pitkän ylivireysjakson takia. Myös pitkäaikainen passiivisuus voi aiheuttaa alivireyttä. Alivireystilassa ihminen on monesti väsynyt ja vaikuttaa poissaolevalta. Uusien tehtävien aloittaminen on vaikeaa ja arkistenkin askareiden läpivienti voi tuntua lähes mahdottomalta. [13]

Optimivireys tarkoittaa optimaalista vireystilaa, jolloin tehtävistä ja askareista suoriutuminen onnistuu parhaiten. Ihminen on tällöin tehokas ja pystyy keskittymään tehtäviinsä. Optimivireyden ylläpitäminen on tärkeää niin ihmisen suorituskyvyn, kuin oman hyvinvointinsa kannalta. Esimerkiksi terveelliset elämäntavat, kuten säännöllinen unirytmii ja säännölliset ruokailurytmit auttavat vireystilan säätelyssä. [13]

2.1 Vireystilan mittaaminen

Nykyään ihmisen vireystilaa pystytään mittaamaan, mittaamalla ihon sähkönjohtavuuden muutosta. Mittauksessa iholle johdetaan sähkövirtaa, yleensä tasavirtaa, jolloin iho tulee osaksi virtapiiriä, josta sähkönjohtavuus voidaan mitata. Erilaisia menetelmiä ihon sähkönjohtavuuden mittaamiseen on esitelty tarkemmin esimerkiksi Wolfram Boucseinin kirjan 'Electrodermal Activity' [5] toisessa luvussa.

Yksi merkittävimmistä ihon sähkönjohtavuuden muutokseen vaikuttavista tekijöistä on ihon pinnassa olevan hien määrän muutos. Ihon sähkönjohtavuuteen vaikuttavat muutkin tekijät, kuten esimerkiksi ihon kuivuminen ikääntymisen seurauksena, mutta näiden vaikutukset eivät ole yhtä merkittäviä, kun mitataan sähkönjohtavuuden muutosta lyhyemmällä aikavälillä. Hikoillessa hikirauhaset nostavat hikeä ihon pintakerrokseen. Koska hien sähkönjohtavuus on parempi kuin kuivan ihon, ihon sähkönjohtavuus kasvaa hien määrän kasvaessa. Hien määrän kasvamista tai vähenemistä voidaan pitää myös merkinä vireystilan muutokselle. Vireystila voidaan ajatella kuvaavan elimistön ja kehon aktiivisuutta. Vireystila on usein alimmillaan nukkuessa, jolloin koko keho, mukaan lukien hikirauhaset, lepäävät. Sen sijaan esimerkiksi stressi, joka on merkki korkeasta vireystilasta, voi kasvattaa hikoilun määrää. Näin ollen vireystilan ja ihon sähkönjohtavuuden välille saadaan selkeä yhteys. [5]

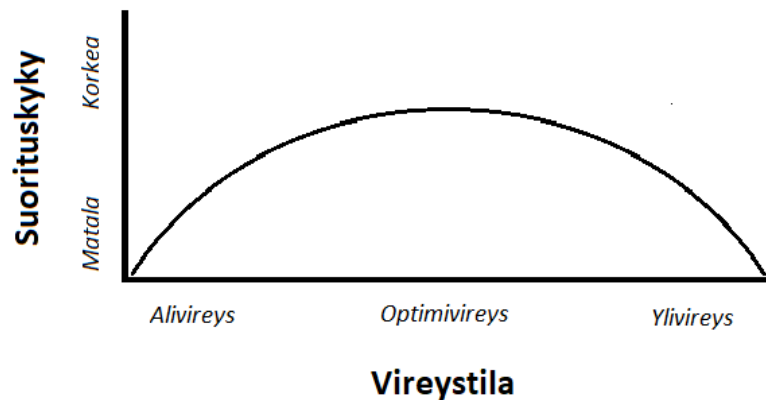
Tässä työssä vireystilaa mitattiin käyttämällä Moodmetric-älysormusta. Käytännössä Moodmetric-älysormus mittaa ihon sähkönjohtavuuden muutosta. Ihon sähkönjohtavuus riippuu ihon pinnalla olevan hien määrästä, joka taas on verrattavissa vallitsevaan stressitasoon ja vireystilaan. Mitatut sähkönjohtavuudet lähetetään sormuksesta puhelimen Moodmetric-sovellukseen, jossa datasta lasketaan 'Moodmetric-taso', joka saa arvoja yhden ja sadan väliltä. Sormus kalibroidaan jokaiselle käyttäjälle niin, että arvo yksi tarkoittaa käyttäjän alinta mahdollista arvoa ja sata vastaavasti korkeinta. Moodmetric-tasot lasketaan, jotta eri käyttäjien saamat arvot ovat vertailukelpoisia [30].

Sormuksen käyttöohjeissa [14] Moodmetric-tasot on jaettu viiteen eri luokkaan. Alin luokka on lukemat 0-20, joka tarkoittaa rauhallista. Käyttäjä voi saavuttaa tällaisia arvoja esimerkiksi nukkuessa. Seuraava luokka on arvot 21-40, joka tarkoittaa tyyntä. Tällaisia arvoja voi saavuttaa jonkin kevyen tekemisen, kuten esimerkiksi kävelyn parissa. Keskimäinen luokka on arvot 41-60, joka tarkoittaa aktiivista. Tämä luokka vastaa tavallista vireyttä päivän aikana ja pitää yleensä sisällään tavallisten arkisten askareiden aikana mi-

tatut arvot. Neljäs luokka saa arvoja väliltä 61-80 ja tarkoittaa kiihtynyttä. Tällaisia arvoja voi saada esimerkiksi paineen alla työskennellessä. Korkein luokka saa arvoja 81-100 ja tarkoittaa erittäin kiihtynyttä. Tällaisia arvoja voidaan saada esimerkiksi käyttäjän ollessa innostunut tai ahdistunut. Arvoista ei siis voida suoraan päätellä ovatko ne seurausta positiivisista vai negatiivisista tekijöistä.

2.2 Vireystila oppimistilanteissa

Yleisesti voidaan ajatella vireystilan ja suorituskyvyn välinen yhteys ylösalaisin olevan U:n muotoisena käyränä, kuten kuvassa 2.1 nähdään [16]. Tämä tarkoittaa siis sitä, että optimivireystilassa suorituskyyky on parhaimmillaan ja liian korkea tai matala vireystila heikentää suorituskyykyä.



Kuva 2.1. Vireystilan yhteys suorituskyykyyn (mukailtu lähteestä [16])

Vireystilan ja suorituskyyvyn väliseen vaikuttavat kuitenkin myös yksilölliset erot ja esimerkiksi se, millaisesta tehtävästä on kyse. Yleensä yksinkertaiset tehtävät voivat onnistua jopa tehokkaammin vireystilan ollessa optimivireyttä korkeampi, sillä tällöin aktiivisuus on korkealla ja yksinkertainen tehtävä onnistuu rutiininomaisesti ilman raskasta ajatustyötä. Vastaavasti vaikeat tehtävät onnistuvat paremmin vireystilan ollessa hieman matalampi, sillä ihmisen ollessa rauhallisempi, ajatustyö ja keskittyminen onnistuvat paremmin. Tätä tukee myös Yerkes–Dodson laki, jonka mukaan helpommat tehtävät onnistuvat tehokkaimmin korkeammalla vireystilalla ja vaikeammat tehtävät taas matalammalla vireystilalla tai optimivireydellä. [16]

Yhteys voidaan havaita myös toiseen suuntaan. Esimerkiksi opetustilanteessa erilaiset tehtävät voivat vaikuttaa opiskelijan vireystilaan. Tästä hyvänä esimerkkinä on Bliksteinin ja kumppaneiden tutkimus [4], jossa havaittiin, että oppilaiden saadessa yksityiskohtaiset ohjeet tehtäviin heidän vireystilansa noudattivat pääsääntöisesti U-käyrää, eli korkeimmat

vireystilan arvot saatiin alussa ja lopussa. Kun ohjeet olivat vain yleisiä, vireystilaa kuvasi laskeva suora tehtävän aikana. Tutkimukseen oli osallistunut 21 lukiolaista Kaliforniassa. Tutkimuksen perusteella voidaan ennustaa, että meidän tutkimuksessamme:

H1 Ohjatuissa opetustilanteissa vireystila on korkeimmillaan opetustilanteen alussa ja lopussa.

H2 Itsenäisissä oppimistilanteissa vireystila laskee oppimistilanteen aikana.

Ohjattuja opetustilanteita ovat esimerkiksi luennot, pienryhmätillaisuudet ja laskuharjoitukset. Itsenäisiksi oppimistilanteiksi voidaan luokitella muun muassa itsenäinen työskentely, sekä reenaamo- ja laskutupavuorot, jotka ovat vapaaehtoisia tilaisuuksia opiskelijoiden tueksi.

Pijeira-Díaz ja kumppaneiden artikkelissa [22] tutkittiin 24 lukiolaisen vireystilaa lukion fysiikan tunneilla. Tutkimuksessa vireystilat oli jaettu matalaan, keskitason ja korkeaan vireyteen. Tutkimus suoritettiin syventävällä fysiikan kurssilla, joka on oppilaille vapaaehtoinen, joten oppilaiden oletettiin tutkimuksessa olevan motivoituneita. Siitä huolimatta tutkimuksessa havaittiin, että oppilaiden vireystila oli matalalla keskimäärin noin 60% oppitunnin ajasta. Tämän tutkimustuloksen perusteella voidaan ennustaa, että meidän tutkimuksessamme:

H3 Matala vireystila on yleisin vireystila oppimistilanteessa.

3. TUNNETILAT

Tunnetila (emotion tai emotional state) voidaan määritellä monitahoiseksi ilmiöksi, johon liittyy useita koordinoituja psykologisia prosesseja. [19] Tunnetilat sekoittuvat helposti tunteen (feeling) tai mielialan (mood) käsitteiden kanssa, vaikka kyseessä ovatkin eri asiat. Tunteet ja tunnetilat ovat usein hyvin lähellä toisiaan, mutta kaikki tunteet eivät kuitenkaan ole tunnetiloja. Ihminen voi esimerkiksi tuntea fyysistä kipua, mutta keho ei pysty toistamaan tätä tuntemusta kokematta fyysistä kipua uudelleen. Voidaan siis puhua kivun tunteesta, mutta ei kivusta tunnetilana. Kivun tunteminen voi kuitenkin herättää ihmisessä muita tunnetiloja, kuten esimerkiksi pelkoa. [6] Tunnetilan ja mielialan selkein ero on sen sijaan niiden kesto. Mieliala on pitkäkestoinen, kun taas tunnetila on lyhytaikainen, jonka lisäksi se voi vaihdella ja olla hyvinkin voimakas verrattuna mielialaan. [28] Koska erilaisia tunnetiloja on paljon, on helpompaa, ja tulosten kannalta miellekkäämpää luokitella tunnetiloja. Tällöin voidaan tarkastella samankaltaisia tunnetiloja yhtenä luokkana yksittäisten tunnetilojen sijaan.

3.1 Tunnetilojen jaottelu

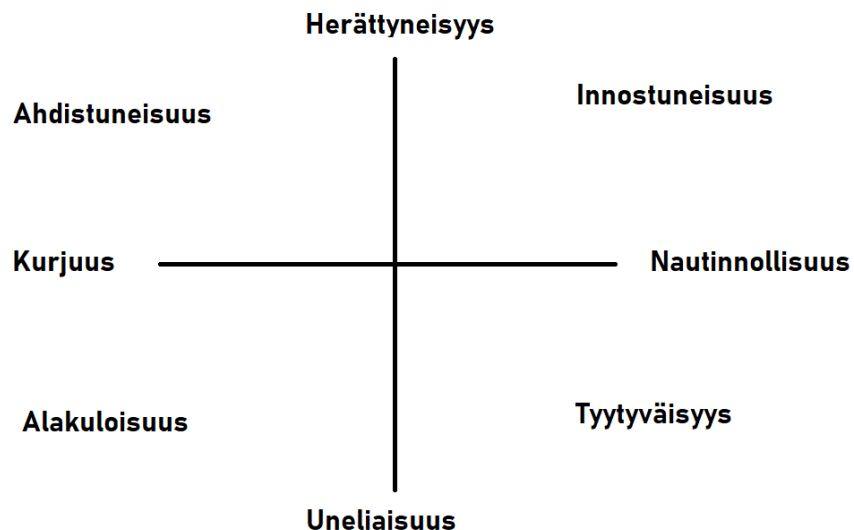
Eräs yksinkertainen tapa luokitella tunnetilat on jakaa ne positiivisiin ja negatiivisiin tunnetiloihin. Esimerkiksi ilo on selkeä positiivinen tunne ja suru taas on selkeästi negatiivinen. Tätä luokittelua voidaan lähteä laajentamaan. Esimerkiksi Pekrunin ja kumppaneiden artikkelissa [20] tunnetilat on luokiteltu myös aktiivisuuden mukaan joko aktivoiviksi tai deaktivoiviksi tunnetiloiksi. Aktivoiva tunnetila tarkoittaa vireystilaa nostattavaa tai korkean vireystilan tunnetilaa. Vastaavasti deaktivoivien tunnetilojen ajatellaan laskevan vireystilaa tai olevan yleisesti matalan vireystilan tunnetiloja. Tässä tutkimuksessa vastausvaihtoehtoina olleet tunnetilat on jaoteltu kyseisen luokittelun mukaisesti kuvassa 3.1.

	Positiivinen	Negatiivinen
Aktivoiva	Toiveikkaus Ilo Kiitollisuus Nauttiminen Ylpeys	Häpeä Viha Ahdistus
Deaktivoiva	Tyytyväisyys Rentoutuminen Helpotus	Tylsistyminen Turhautuminen Toivottomuus Suru Pettymys

Kuva 3.1. Tunnetilojen jaottelua positiivisiin ja negatiivisiin sekä aktivoiviin ja deaktivoiviin tunnetiloihin (mukailtu lähteestä [20])

Kuten kuvasta 3.1 nähdään, kaikki positiiviset tunnetilat eivät ole aktivoivia, kuten esimerkiksi helpotus, joka on positiivinen, mutta rauhoittava tunnetila. Vastaavasti kaikki negatiiviset tunnetilat eivät ole deaktivoivia, kuten esimerkiksi viha, joka aktivoi ihmistä ollen samalla voimakkaasti negatiivinen tunnetila.

Myös Russellin kaksiulotteisessa emootioteoriassa [25] on esitetty samankaltainen jaottelu. Tämä Russellin malli on esitetty kuvassa 3.2.



Kuva 3.2. Tunnetilojen luokittelu Russellin kaksiulotteisen emootioteorian mukaan (mukailtu lähteestä [25])

Kuten kuvasta 3.2 nähdään ympyrän muotoinen malli on jaettu kahdeksaan luokkaan, mutta selvästi pystyakseli kuvaa tunnetilan aktiivisuutta, kun taas vaaka-akseli tunnetilan

positiivisuutta tai negatiivisuutta, kuten myös aiemmin esitetystä jaottelusta. Russellin mukaan neljä muuta merkittävää tunnetilaa kuvaavat alueita akseleiden välissä. Mallin avulla voitaisiin jaotella muut tunnetilat eri kohdille ympyrän kehälle.

3.2 Tunnetilat oppimistilanteissa

Matematiikan oppimistilanteissa voi esiintyä hyvinkin erilaisia tunnetiloja. Esimerkiksi laskuharjoituksissa voi esiintyä niin negatiivisia kuin positiivisiakin tunnetiloja. Tähän voivat vaikuttaa yksilölliset syyt tai esimerkiksi se, kuinka hyvin tehtävät ovat onnistuneet. [18]

Niculescun ja kumppaneiden artikkelissa [15] tutkitaan oppimiseen liittyviä tunnetiloja. Kohderyhmänä on toimineet Hollantilaisen yliopiston ensimmäisen vuoden taloustieteen sekä kansainvälisen liiketalouden opiskelijoita. Tutkimus suoritettiin kolmen vuoden aikana kvantitatiiviset menetelmät -kurssilla, jossa opiskelijat vastasivat tunnetiloihin liittyviin kysymyksiin kyselylomakkeella. Artikkelissa oppimiseen liittyvät tunnetilat oli jaettu neljään osaan: nautinto, ahdistus, tylsistyminen sekä toivottomuus. Kuvan 3.1 avulla voidaan jaotella kyseiset tunnetilat positiivisiin ja negatiivisiin sekä aktivoiviin ja deaktivoiviin tunnetiloihin. Tutkimuksen tuloksista nähdään, että yleisin tunnetila on ollut nautinto ja toiseksi yleisin ahdistus. Tämän perusteella voidaan siis sanoa, että positiiviset ja aktivoivat tunnetilat ovat olleet yleisimpiä opiskelijoiden keskuudessa. Tuloksista voidaan myös huomioda, että matematiikkaa pääaineena opiskelevat opiskelijat kokivat kurssilla enemmän positiivisia tunnetiloja, kuin sivuaineena matematiikkaa opiskelevat opiskelijat. Meidän tutkimuksessamme kohderyhmä on ollut hyvin samankaltainen, joten tulokset ovat hyvinkin vertailukelpoisia. Tämän perusteella voidaan ennustaa, että meidän tutkimuksessamme:

- H4 Positiiviset tunnetilat ovat yleisempiä kuin negatiiviset tunnetilat matematiikan oppimistilanteissa.
- H5 Aktivoivat tunnetilat ovat yleisempiä kuin deaktivoivat tunnetilat matematiikan oppimistilanteissa.

3.3 Tunnetilat yhteydessä vireystilaan

Yleisesti voidaan olettaa, että tunnetilojen ja vireystilan välillä on yhteys. Esimerkiksi niin Pekrunin ja kumppaneiden [20] kuin Russellinkin [25] tavoissa jaotella tunnetiloja huomioidaan eräänlainen aktiivisuus tai vireys. Näin ollen ainakin teoriassa voidaan ajatella aktivoivien ja deaktivoivien tunnetilojen, sekä vireystilan välille suora yhteys, sillä on vaikea kuvitella rentoutuvan ihmisen olevan kovin korkealla vireystilalla, kun taas erittäin vihasen ihmisen vireystila tuskin pysyy matalana. Tämän perusteella voidaan ennustaa, että meidän tutkimuksessamme:

- H6 Aktivoivien ja deaktivoivien tunnetilojen avulla voidaan ennustaa vireystilan suu-

ruutta.

Villanuevan ja kumppaneiden artikkelissa [31] taas on tutkittu ensimmäisen vuoden insinööriopiskelijoita grafiikka ja suunnittelu kurssilla. Opiskelijoilta tutkittiin EDA:ta, eli sähkönjohtavuuden muutosta, jonka jo aiemmin todettiin kuvaavan vireystilaa, sekä positiivisia ja negatiivisia tunnetiloja. Tutkimuksessa ei havaittu korrelaatiota positiivisten ja negatiivisten tunnetilojen sekä vireystilan välillä. Tämän perusteella voidaan ennustaa, että meidän tutkimuksessamme:

H7 Positiivisten ja negatiivisten tunnetilojen avulla ei voida ennustaa vireystilaa.

Saatuja hypoteeseja tarkastellaan tutkimusaineiston avulla luvussa 7. Sitä ennen kuitenkin tutustutaan tarkemmin tutkimusmenetelmiin ja tutkittavaan aineistoon.

4. LINEAARISET MALLIT

Lineaarisia malleja hyödynnetään tutkimuksissa monilla eri aloilla, kuten esimerkiksi taloustieteessä, politiikassa ja lääketieteessä [10]. Lineaarisia malleja hyödynnetään erityisesti lineaarisessa regressioanalyysissä. Tämän menetelmän avulla pystytään tutkimaan tietyn muuttujan tai useiden muuttujien riippuvuutta tarkasteltavaan muuttujaan. Tilanteesta pyritään luomaan lineaarinen malli, joka kuvaa tutkittavaa muuttujaa muiden tunnettujen muuttujien avulla. Tässä tutkimuksessa lineaarisia malleja hyödynnetään tutkimusaineiston analysointiin. Aineistosta muodostetaan lineaarisia malleja, joita vertailemalla voidaan havaita esimerkiksi muuttujien välisiä yhteyksiä.

4.1 Lineaariset mallit

Yksinkertaisessa lineaarisessa mallissa valittua muuttujaa pyritään ennustamaan vain yhden muuttujan avulla. Tätä muuttujaa kutsutaan myös prediktoriksi. Tarkoituksena on siis muodostaa kaava, johon prediktorin arvoja sijoittamalla voidaan arvioida ennustettavan muuttujan arvoja. Määritellään seuraavaksi yksinkertainen lineaarinen malli.

Määritelmä 4.1. Yksinkertainen lineaarinen malli on muotoa [24]

$$y = \beta_0 + \beta_1 x + \epsilon, \quad (4.1)$$

missä

y = muuttuja, jota pyritään ennustamaan mallin avulla

x = prediktori, eli muuttuja, jonka avulla pyritään ennustamaan muuttujan y arvoja

β_0 = mallin vakiotermin (regressiovakio)

β_1 = prediktorin kerroin (regressiokerroin)

ϵ = virhetermi, joka kuvaa esimerkiksi niitä vaikuttavia tekijöitä, joita mallissa ei ole muuten huomioitu.[10]

Tilanteesta riippuen ennustettavan muuttujan arvoon voi vaikuttaa useampi kuin yksi tekijä. Esimerkiksi auton huippunopeuteen vaikuttaa moottorin tehon lisäksi muun muassa

auton massa ja ilmanvastus. Tällöin tarvitaan lineaarinen malli, jossa on useampi prediktori. Määritellään yleinen lineaarinen malli, jossa prediktorien määrää ei ole rajattu.

Määritelmä 4.2. Yleinen lineaarinen malli voidaan esittää muodossa [9]

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \epsilon_i, \quad (4.2)$$

missä

$i = 1, 2, \dots, n$ on havaintojen indeksointi

n = havaintojen lukumäärä

Y_i = muuttujan eräs havaittu arvo, jota mallilla pyritään kuvaamaan

x_{ij} = muuttujaa Y_i vastaavat prediktorien arvot, joilla pyritään ennustamaan tulosta

$j = 1, 2, \dots, k$ on prediktorien indeksointi

k = prediktorien lukumäärä

β_0 = mallin vakio-termi (regressiovakio)

β_j = prediktorien kertoimet (regressiokertoimet)

ϵ_i = havaintoa vastaava virhetermi, joka kuvaa esimerkiksi niitä vaikuttavia tekijöitä, joita mallissa ei ole muuten huomioitu.

Lauseke 4.2 voidaan myös esittää matriisimuodossa jos ykkösvektori lisätään predikto-reista muodostettuun matriisiin X ensimmäiseksi sarakkeeksi. Tällöin voidaan sisällyttää vakio-termi β_0 kerroinvektoriin β ja saadaan [9]

$$\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & \dots & x_{1k} \\ 1 & x_{21} & \dots & x_{2k} \\ 1 & \vdots & & \vdots \\ 1 & x_{n1} & \dots & x_{nk} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{pmatrix}.$$

Tämä voidaan esittää myös muodossa

$$Y = X\beta + \epsilon, \quad (4.3)$$

missä

Y = vektori, joka sisältää ennustettavan muuttujan havaitut arvot

X = matriisi, joka sisältää kaikkien prediktorien havaitut arvot

β =vektori, joka pitää sisällään prediktorien kertoimet

ϵ = vektori, joka pitää sisällään havaintoja vastaavat virhetermit.

Jotta lineaarista mallia voidaan hyödyntää, on selvitettävä prediktorien kertoimet β . Malli on sitä parempi, mitä pienemmäksi virhetermien arvot saadaan. Kertoimien selvittämiseen voidaan käyttää esimerkiksi pienimmän neliösumman menetelmää.

Lause 4.1. *Jos matriisin X aste on sama kuin matriisin sarakkeiden määrä, pienimmän neliösumman menetelmällä regressiokertoimiksi saadaan*

$$b = (X'X)^{-1}X'Y. \quad (4.4)$$

[9]

Todistus. Lähdetään liikkeelle lausekkeesta 4.3, jossa regressiokerrointen vektori β on korvattu niiden estimaattorien vektorilla b ja virhetermit sisältävä vektori ϵ on korvattu jäännösvirheet (residuaalit) sisältävällä vektorilla e . Regressiokerrointen estimaattorit ovat arvioita vielä tuntemattomista regressiokerrointen arvoista. Tässä tapauksessa pyritään ratkaisemaan mahdollisimman hyvä arvio regressiokertoimille pienimmän neliösumman avulla. Jäännösvirhe taas tarkoittaa eroa mallin antaman arvon ja todellisen havaitun arvon välillä. Näillä merkinnöillä saadaan

$$Y = Xb + e.$$

Vastaavasti lauseke 4.2 voidaan kirjoittaa muodossa

$$Y_i = b_0 + b_1x_{i1} + b_2x_{i2} + \dots + b_kx_{ik} + e_i,$$

mistä voidaan ratkaista residuaali

$$e_i = Y_i - b_0 - b_1x_{i1} - b_2x_{i2} - \dots - b_kx_{ik}.$$

Saatu lauseke voidaan myös esittää matriisimuodossa

$$e = Y - Xb.$$

Jotta lineaariseen malliin saadaan mahdollisimman hyvät estimaattorit, halutaan minimoida residuaalit. Koska residuaaleja on yleensä useita, tarkastellaan residuaalien summaa $\sum e_i$. Jäännösvirheet voivat kuitenkin olla positiivisia tai negatiivisia, jolloin niiden summan minimoiminen ei takaa parhaita estimaattoreita. Tästä syystä käytetään pienimmän neliösumman menetelmää, jossa halutaan minimoida ennemmin residuaalien neliöiden

summa, jolloin kaikki termit ovat positiivisia ja vastaavaa ongelmaa ei synny. Residuaalien neliöiden summa voidaan kirjoittaa muodossa

$$\sum e_i^2 = \sum (Y_i - b_0 - b_1x_{i1} - b_2x_{i2} - \dots - b_kx_{ik})^2.$$

Sama voidaan esittää matriisimuodossa

$$\sum e_i^2 = e'e = (Y - Xb)'(Y - Xb),$$

mikä kerrottuna auki

$$e'e = Y'Y - Y'Xb - b'X'Y + b'X'Xb.$$

Koska $Y'Xb$ on skalaari, se on yhtä suuri, kuin sen transpoosi $b'X'Y$ ja tällöin lauseke voidaan sieventää muotoon

$$e'e = Y'Y - 2bX'Y + b'X'Xb.$$

Derivoidaan lauseke estimaattorien b suhteen ja asetetaan derivaatta nolaksi, jolloin saadaan

$$\frac{\partial e'e}{\partial b} = -2X'Y + 2X'Xb = 0.$$

Tämä voidaan sieventää muotoon, joka tunnetaan normaaliyhtälönä

$$X'Xb = X'Y.$$

Matriisitulo $X'X$ on neliömatriisi. Jos sillä on käänteismatriisi, voidaan lauseke kertoa puolittain matriisilla $(X'X)^{-1}$, jolloin saadaan

$$(X'X)^{-1}(X'X)b = (X'X)^{-1}X'Y,$$

mistä sieventämällä saadaan

$$b = (X'X)^{-1}X'Y,$$

koska matriisitulosta $(X'X)^{-1}(X'X)$ saadaan identiteettimatriisi I ja $Ib = b$. [10]

□

Esimerkki 4.2. Taulukkoon 4.1 on kerätty Suomen jääkiekkomaajoukkueen pisteet, tehdyt maalit ja päästetyt maalit maailmanmestaruuskilpailujen alkulohkossa. Lisäksi taulukossa on Suomen lopullinen sijoitus turnauksessa.

Vuosi	Pisteet	Tehdyt maalit	Päästetyt maalit	Lopullinen sijoitus
2012	15	21	14	4.
2013	16	23	14	4.
2014	11	18	15	2.
2015	16	22	9	6.
2016	21	29	6	2.
2017	11	20	22	4.
2018	16	38	11	5.
2019	16	22	11	1.
2021	17	19	10	2.
2022	19	25	5	1.

Taulukko 4.1. Suomen jääkiekkomaajoukkueen tilastoja maailmanmestaruuskilpailujen alkulohkosta vuosilta 2012-2022, sekä turnausten lopulliset sijoitukset. [26]

Muodostetaan lineaarinen malli, jonka avulla voidaan ennustaa turnauksen lopullista sijoitusta alkulohkon tilastojen perusteella. Tämä malli on määritelmän 4.2 mukaisesti muotoa

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \epsilon_i, \quad (4.5)$$

missä

i = vuosiluku

Y_i = Suomen lopullinen sijoitus jääkiekon maailmanmestaruuskilpailuissa vuonna i

x_{i1} = Suomen pisteiden määrä alkulohkossa vuonna i

x_{i2} = Suomen tekemien maalien määrä alkulohkossa vuonna i

x_{i3} = Suomen päästämien maalien määrä alkulohkossa vuonna i

β_0 = regressiovakio

β_j = regressiokertoimet

$j = 1, 2, 3$ on prediktorien indeksointi

ϵ_i = havaintoa vastaava virhetermi.

Malli voidaan esittää lausekkeen 4.3 mukaisesti matriisimuodossa

$$Y = X\beta + \epsilon, \quad (4.6)$$

mistä saadaan

$$\begin{pmatrix} 4 \\ 4 \\ 2 \\ 6 \\ 2 \\ 4 \\ 5 \\ 1 \\ 2 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 & 15 & 21 & 14 \\ 1 & 16 & 23 & 14 \\ 1 & 11 & 18 & 15 \\ 1 & 16 & 22 & 9 \\ 1 & 21 & 29 & 6 \\ 1 & 11 & 20 & 22 \\ 1 & 16 & 38 & 11 \\ 1 & 16 & 22 & 11 \\ 1 & 17 & 19 & 10 \\ 1 & 19 & 25 & 5 \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \end{pmatrix} + \begin{pmatrix} \epsilon_{2012} \\ \epsilon_{2013} \\ \vdots \\ \epsilon_{2022} \end{pmatrix},$$

sijoittamalla taulukon 4.1 arvot matriisiin X ja vektoriin Y .

Lasketaan regressiokertoimet lauseen 4.1 avulla Matlab:lla. Regressiokertoimiksi saadaan

$$b = (X'X)^{-1}X'Y = \begin{pmatrix} 0.1809 \\ -0.0996 \\ 0.1315 \\ 0.1176 \end{pmatrix}.$$

Näin ollen tilannetta kuvaava lineaarinen malli on

$$Y_i = 0.1809 - 0.0996 \cdot x_{i1} + 0.1315 \cdot x_{i2} + 0.1176 \cdot x_{i3}. \quad (4.7)$$

Kun malliin sijoitetaan alkulohkon pisteet sekä tehdyt ja päästetyt maalit, voidaan arvioida Suomen lopullista sijoitusta maailmanmestaruuskilpailuissa. Jos siis Suomi saisi jonakin vuonna alkusarjassa esimerkiksi 18 pistettä, tekisi 20 maalia ja päästäisi 17 maalia, niin mallin mukaan saadaan lopulliseksi sijoitukseksi

$$Y_i = 0.1809 - 0.0996 \cdot 18 + 0.1315 \cdot 20 + 0.1176 \cdot 17 = 3.0179.$$

Tämän perusteella voitaisiin odottaa Suomen sijoittuvan kolmanneksi.

4.2 Lineaariset monitasomallit

Lineaarisen mallin tapauksessa regressiokertoimet oletetaan kiinteiksi. Kertoimet voivat kuitenkin olla myös satunnaisia. Kutsutaan satunnaisia kertoimia satunnaisvaikutuksiksi. Tämä ei kuitenkaan tarkoita kertoimiksi valitaan satunnaisia lukuja, vaan sitä, että jos ai-

neisto voidaan jakaa erilaisiin ryhmiin tai luokkiin, voivat kertoimet vaihdella eri ryhmien välillä. Kertoimia voidaan siis käsitellä satunnaisvaikutuksina, mikäli havaintojen välillä on korrelaatiota. Esimerkiksi jos tarkastellaan erään koulun kaikkia matematiikan koearvosanoja, voidaan luultavasti havaita korrelaatiota yksittäisen oppilaan koearvosanoissa eri kokeissa. Tällaisessa tapauksessa voitaisiin ajatella yhden oppilaan koearvosanoja yhtenä ryhmänä, ja satunnaisvaikutukset voisivat saada eri arvoja eri oppilaille. [11]

Tässä tutkimuksessa käytettävä data on pitkittäisdataa. Tämä tarkoittaa, että samat mittaukset tai tutkimuskysymykset toistetaan samoille henkilöille tai asioille useilla eri ajanhetkillä. [29] Tällöin tuloksia voidaan tarkastella niin yksilön näkökulmasta, eli tarkastella yhdestä oppilaasta kerättyä dataa, kuin yleisestä näkökulmasta, eli verrata eri opiskelijoista kerättyä dataa toisiinsa. Käytetty data on näin ollen myös kaksitasoista, jolloin tavallinen yksitasoinen lineaarinen malli ei sovellu datan analysoimiseen, vaan tarvitaan monitasomallia.

Määritelmä 4.3. Yleinen lineaarinen monitasomalli voidaan esittää muodossa [11]

$$Y = X\beta + Z\alpha + \epsilon, \quad (4.8)$$

missä

Y = vektori, joka sisältää ennustettavan muuttujan havaitut arvot

X = matriisi, joka sisältää kaikkien prediktorien havaitut arvot

β =vektori, joka pitää sisällään regressiokertoimet

Z = tunnettu matriisi, johon on valittu osa prediktoreista

α = vektori, joka sisältää satunnaisvaikutukset

ϵ = vektori, joka pitää sisällään havaintoja vastaavat virhetermit.

Kuten määritelmästä selvästi huomataan, lineaarinen monitasomalli on rakennettu lineaarisen mallin pohjalta. Lineaariseen malliin on lisätty $Z\alpha$ -termi, jolla huomioidaan havaintojen välisiä korrelaatioita.

4.3 Lineaaristen mallien arvioiminen ANOVA-funktiolla

Mallit muodostetaan nykyään yleensä tietokoneella esimerkiksi R-ohjelmistossa. Mallit muodostetaan yleensä vaiheittain ja aina kun malliin tehdään muutoksia, on hyvä verrata uutta mallia edellisiin malleihin. Tämä onnistuu R-ohjelmistossa esimerkiksi ANOVA-funktiolla [23]. ANOVA-funktion avulla voidaan verrata malleja keskenään niin, että nähdään kumpi malleista kuvaa paremmin mallinnettavaa dataa.

Jotta ANOVA-funktion antamia arvoja voidaan ymmärtää paremmin, on tunnettava todennäköisyysfunktion maksimi, eli 'maximum likelihood'. Mallin todennäköisyysfunktio kuvaa sitä, kuinka todennäköisiä mallin parametrejä, kuten esimerkiksi regressiokertoimet, ovat tunnetuilla ennustettavan muuttujan arvoilla. Lineariselle mallille todennäköisyysfunktio on

$$f(Y | \beta, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_i - x_i'\beta)^2}{2\sigma^2}\right),$$

missä

Y = vektori, joka pitää sisällään ennustettavan muuttujan arvot y_i

β = vektori, joka sisältää regressiokertoimet

x_i' = vektori, joka sisältää y_i :tä vastaavat prediktorien arvot

σ^2 = varianssi.

Tämän funktion maksimia, eli suurinta arvoa merkitään $\hat{\tau}$ ja sitä käytetään monissa menetelmissä, joilla malleja arvioidaan. [29]

Yksi ANOVA-funktion antamista arvoista on 'Akaike information criterion' eli AIC.

Määritelmä 4.4. Akaike information criterion eli AIC, voidaan määritellä seuraavasti:

$$AIC = -2\log(\hat{\tau}) + 2k,$$

jossa

$\hat{\tau}$ = todennäköisyysfunktion maksimi

k = erikseen säädettyjen parametrien määrä mallissa. [1][32]

Kahta mallia voidaan verrata, vertailemalla niiden AIC-arvoja. Mitä pienempi AIC-arvo mallille saadaan, sen parempi mallin kuuluisi AIC-arvon mukaan olla.

Toinen ANOVA-funktion antamista arvoista on 'Bayesian information criterion' eli BIC.

Määritelmä 4.5. Bayesian information criterion eli BIC voidaan määritellä seuraavasti:

$$BIC = -2\log(\hat{\tau}) + k \cdot \log(N),$$

jossa

$\hat{\tau}$ = todennäköisyysfunktion maksimi

k = erikseen säädettyjen parametrien määrä mallissa

N = havaintojen määrä datassa, jota mallilla kuvataan. [32]

Kuten AIC-arvoille, myös BIC-arvoille pienempi arvo tarkoittaa yleensä parempaa mallia.

Näiden lisäksi ANOVA-funktio antaa aiemmissä määritelmissäkin esiintyvät logaritmit todennäköisyysfunktioiden maksimeista $\log(\hat{\tau})$ (log-likelihood), todennäköisyysuhdetestin tuloksen (Likelihood-ratio test), p-arvon ja vapausasteet (degrees of freedom). Määritellään seuraavaksi likelihood-ratio test, eli LTR, kun verrataan uutta mallia aiempaan malliin.

Määritelmä 4.6. Likelihood-ratio test voidaan määritellä kahden mallin vertailuun seuraavasti:

$$LTR = -2\log\left(\frac{\hat{\tau}_1}{\hat{\tau}_2}\right),$$

jossa

$\hat{\tau}_1$ = todennäköisyysfunktion maksimi yksinkertaisemmalle mallille

$\hat{\tau}_2$ = todennäköisyysfunktion maksimi mallille, jossa on enemmän prediktoreja.[12]

Logaritmien laskusääntöjä hyödyntämällä voidaan lauseke esittää myös muodossa

$$LTR = 2(\log(\hat{\tau}_2) - \log(\hat{\tau}_1)),$$

jolloin LTR on mallien todennäköisyysfunktioiden maksimeiden erotus kerrottuna kahdella. Saatu arvo noudattaa χ^2 -jakaumaa ja sitä vastaava p-arvo saadaan taulukosta, kun käytetään vapausasteena mallien vapausasteiden erotusta. [12]

P-arvo on todennäköisyys, jolla käytetty data olisi voinut syntyä nollahypoteesin ollessa totta. Tässä tapauksessa nollahypoteesi on se, että LTR:n määritelmässä oleva yksinkertaisempi malli on parempi, kuin malli johon on lisätty prediktori tai prediktoreja. [3]

4.4 Lineaarisen monitasomallin muodostaminen R-ohjelmistossa

Dataa analysoitaessa voidaan hyödyntää lineaarisia malleja ja nykypäivänä tämä toteutetaan yleensä tietokoneella jotakin ohjelmistoa hyödyntäen. R-ohjelmistossa lineaarinen monitasomalli, jota kutsutaan myös lineaariseksi sekamalliksi (linear mixed model), voidaan luoda lme funktion [2] avulla. Funktiolle syötetään ennustettavan muuttujan arvot, havaitut prediktorien arvot halutuille prediktoreille, halutut satunnaisvaikutukset sekä haluttu aineiston ryhmittely. Lme-funktio laskee β , α ja ϵ arvot, kun taas x , Y ja Z ovat valmiiksi tunnettuja. Tämä tarkoittaa siis sitä, että β , α ja ϵ arvot vaihtelevat mallien välillä, sillä ohjelma laskee uudet arvot jokaiselle mallille.

Käytännössä mallin muodostaminen kannattaa tehdä vaiheittain. Paljon satunnaisvaikutuksia sisältävä malli on monimutkainen ja muodostamalla mallia vaiheittain nähdään myös hyvin miten mikäkin prediktori vaikuttaa malliin. [7] Käydään seuraavaksi läpi, kuin-

ka kaksitasoinen malli luodaan pitkittäisdatalle R-ohjelmistossa esimerkkien avulla. Esimerkkinä käytetään tässä työssä tehtyä data-analyysiä ja sen vaiheita.

Ensimmäistä mallia kutsutaan nollamalliksi, koska se ei sisällä lainkaan prediktoreja. Kuvassa 4.1 on esitetty esimerkkinä tämän työn analyysissä tehty nollamalli.

```
m0.1 <- lme(KA ~ 1,
            random = ~ 1 | alt_id,
            data = analyysidata,
            na.action = na.omit,
            method = "ML")
```

Kuva 4.1. Esimerkki nollamallista R-ohjelmistossa

Kuvassa malli luodaan lme funktiolla ja tallennetaan nimellä 'm0.1'. Ensimmäisellä rivillä on ensin muuttuja, jonka arvoja mallilla pyritään ennustamaan. Tässä tapauksessa ennustettavana muuttujana toimii 'KA'. Aaltoviivan oikealla puolella on prediktorit. Koska nollamallissa prediktoreja ei ole, merkitään vain 1 vakiotermiä varten. Toisella rivillä on listattu satunnaisvaikutukset. Niitäkään ei nollamallissa ole, joten sijoitetaan niiden paikalle vain 1. Lisäksi pystyviivan jälkeen on merkitty minkä muuttujan suhteen ryhmittely halutaan tehdä. Kolmannelle riville on merkitty mistä ohjelma löytää käytettävät muuttujien arvot. Esimerkissä kaikki data on tallennettu datatiedostosta ohjelmistoon nimelle 'analyysidata'. Neljännelle riville merkitty 'na.action' kohtaan kerrotaan ohjelmalle, miten toimia, jos datasta puuttuu arvoja. Tässä tapauksessa tyhjät datapisteet on jätetty pois mallista, joka onnistuu komennolla 'na.omit'. Lopuksi on vielä valittu käytettävä menetelmä, joka on esimerkissä ollut 'ML' eli 'maximum likelihood'. Matemaattisesti kuvan 4.1 nollamalli on

$$Y_i = \beta_0 + \epsilon_i,$$

missä

β_0 = mallin vakiotermi

Y_i = muuttujan 'KA' eräs havaittu arvo

ϵ_i = muuttujan arvoa vastaava jäännösvirhe.

Tämän jälkeen malliin lisätään prediktoreja. Koska analyysissä käytetty data on pitkittäistä, voidaan tarkastelua tehdä kahdella eri tasolla: yksilön sisäistä tarkastelua ja yksilöiden välistä tarkastelua. Voidaan siis ajatella, että data on jaettu klustereihin, jossa yksi klusteri on yksi opiskelija. Ensimmäisen tason prediktoreiksi ja vastaavasti vain klustereiden välillä vaihtelevia prediktoreja toisen tason prediktoreiksi. Prediktorit voi lisätä yksi kerrallaan,

jolloin yksittäisen prediktorin vaikutuksia on helpompi seurata. Kuvassa 4.2 on esitetty malli, johon on lisätty yksitasoisia prediktoreja.

```
m1.0 <- lme(KA ~ 1 + time_id + flipped,
            random = ~ 1 | alt_id,
            data = analyysidata,
            na.action = na.omit,
            method = "ML")
```

Kuva 4.2. Kuvan 4.1 malliin on lisätty prediktoreja

Kuten kuvasta nähdään, prediktorit 'time_id' ja 'flipped' on lisätty ensimmäiselle riville, jossa nollamallissa oli vain vakiotermi 1. Prediktorin 'time_id' arvot vaihtelevat klusterin sisällä, sillä se kuvaa havaintojen aikajärjestystä klusterin sisällä. 'Flipped' taas kertoo, millä opintojakson toteutuskerralla opiskelija on ollut, jolloin arvot pysyvät vakioina klusterin sisällä, mutta voivat vaihdella niiden välillä. Tämä malli on matemaattisesti muotoa

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \epsilon_i,$$

mihin on nollamalliin verrattuna lisätty

x_{i1} = muuttujan arvoa Y_i vastaava muuttujan 'time_id' arvo

β_1 = muuttujalle 'time_id' laskettu regressiokerroin

x_{i2} = muuttujan arvoa Y_i vastaava muuttujan 'flipped' arvo

β_2 = muuttujalle 'flipped' laskettu regressiokerroin.

Seuraavaksi kokeillaan paraneeko malli, jos ensimmäisen tason prediktoreja käsitellään satunnaisina. Tässäkin tapauksessa tarkastelu kannattaa tehdä yksi prediktori kerrallaan. Kuvassa 4.3 on esitetty malli, jossa prediktori 'time_id' käsitellään satunnaisena.

```
m1.1 <- lme(KA ~ 1 + time_id + flipped,
            random = ~ time_id | alt_id,
            data = analyysidata,
            na.action = na.omit,
            method = "ML")
```

Kuva 4.3. Mallin 4.2 prediktoria 'time_id' käsitellään satunnaisena

Tämä malli voidaan esittää matemaattisesti muodossa

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + Z_i \alpha + \epsilon_i,$$

mihin on lisätty edelliseen malliin verrattuna

Z_i = muuttujan arvoa Y_i vastaava muuttujan 'time_id' arvo

α = muuttujalle 'time_id' laskettu satunnaisvaikutus.

Lopuksi malliin lisätään loput prediktorit yksi kerrallaan. Mallia heikentäviä prediktoreja ei pidetä mukana mallissa, vaan malliin otetaan yleensä mukaan vain ne prediktorit, jotka parantavat mallia. Tällä tavalla voidaan etsiä mallia, joka kaikkein parhaiten kuvaa tutkittavaa dataa ja näin ollen nähdään minkä prediktorien avulla voidaan parhaiten ennustaa ennustettavan muuttujan arvoja. Kuvassa 4.4 on esitetty malli 4.3, johon on lisätty yksi uusi prediktori, sekä näiden vertailu ANOVA funktion avulla.

```
m1.2 <- lme(KA ~ 1 + time_id + flipped + pre_em_act_pos_neg,
            random = ~ time_id | alt_id,
            data = analyysidata,
            na.action = na.omit,
            method = "ML")

anova(m1.1, m1.2)
...

```

Description: df [2 x 8]

	Model <int>	df <dbl>	AIC <chr>	BIC <chr>	logLik <chr>
m1.1	1	7	3172.830	3200.356	-1579.415
m1.2	2	8	3174.504	3205.962	-1579.252

2 rows

Kuva 4.4. Uuden prediktorin lisääminen malliin 4.3 ja näiden mallien vertailu

Kuvan malli m1.2 voidaan on matemaattisesti muotoa

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + Z_i \alpha + \epsilon_i,$$

mihin on lisätty edelliseen malliin verrattuna

x_{i3} = muuttujan arvoa Y_i vastaava muuttujan 'pre_em_act_pos_neg' arvo

β_3 = muuttujalle 'pre_em_act_pos_neg' laskettu regressiokerroin.

Kuvasta 4.4 nähdään, että uuden mallin AIC arvo, eli 'Akaike information criterion' on suurempi kuin aiemman mallin. AIC arvo kuvaa sitä, kuinka hyvin malli kuvaa dataa ja mitä suurempi arvo, sen huonompi malli. Tässä tapauksessa uuteen malliin lisätty prediktori huonontaa mallia ja se voidaan jättää pois seuraavasta mallista. Tätä prosessia jatketaan, kunnes kaikkia prediktoreja on kokeiltu malliin ja niin sanottu 'paras malli' on saatu muodostettua.

5. TUTKIMUSMENETELMÄT

5.1 Tutkimuskysymykset

Tutkimuksen tavoitteena oli tutkia erilaisia tunnetiloja ja vireystilaa yliopistomatematiikan oppimistilanteissa. Haluttiin selvittää, onko erilaisten tunnetilojen, joita opiskelijat kokevat matematiikan oppimistilanteissa, ja oppimistilanteiden aikana mitatun vireystilan välillä yhteyttä. Tunnetilat jaettiin positiivisiin ja negatiivisiin tunnetiloihin, sekä aktivoiviin ja deaktivoiviin tunnetiloihin, jotta tarkastelu olisi helpompaa ja tulokset selkeämpiä. Tämän perusteella tutkimuskysymyksiksi valittiin:

- Millaisia vireystiloja havaitaan yliopistomatematiikan oppimistilanteissa?
 - H1 Ohjatuissa opetustilanteissa vireystila on korkeimmillaan opetustilanteen alussa ja lopussa.
 - H2 Itsenäisissä oppimistilanteissa vireystila laskee oppimistilanteen aikana.
 - H3 Matala vireystila on yleisin vireystila oppimistilanteissa.
- Miten erilaiset tunnetilat näyttäytyvät yliopistomatematiikan oppimistilanteissa?
 - H4 Positiiviset tunnetilat ovat yleisempiä kuin negatiiviset tunnetilat matematiikan oppimistilanteissa.
 - H5 Aktivoivat tunnetilat ovat yleisempiä kuin deaktivoivat tunnetilat matematiikan oppimistilanteissa.
- Miten havaitut tunnetilat ja vireystilat vertautuvat perinteisen opetuksen ja flipatun opetuksen välillä?
- Miten aktivoivilla ja deaktivoivilla tunnetiloilla voidaan selittää vireystilaa yliopistomatematiikan oppimistilanteissa?
 - H6 Aktivoivien ja deaktivoivien tunnetilojen avulla voidaan ennustaa vireystilan suuruutta.
- Miten positiivisilla ja negatiivisilla tunnetiloilla voidaan selittää vireystilaa yliopistomatematiikan oppimistilanteissa?
 - H7 Positiivisten ja negatiivisten tunnetilojen avulla ei voida ennustaa vireystilaa.

Tutkimuskysymysten vastausten lisäksi tarkoituksena oli nostaa esille myös muita kiinnostavia huomioita tutkimusaineistosta.

5.2 Tutkimusaineisto

Tutkimus suoritettiin Tampereen yliopistolla syksyllä 2019. Tutkimukseen osallistui 75 opiskelijaa saman opintojakson kahdella eri toteutuskerralla. Opiskelijoista 37 osallistui opintojakson flipatululle toteutuskerralle ja loput 38 luentopohjaiselle toteutukselle.

Tutkimuksessa kerättiin dataa kahdella eri tavalla. Tutkimuksen aikana opiskelijoilla oli käytössään Moodmetric-älyormukset [30], jotka mittasivat opiskelijoiden vireystiloja minuutin välein silloin, kun sormusta pidettiin sormessa. Lisäksi opiskelijat vastasivat tunnetiloihin liittyviin kysymyksiin Tampereen yliopiston LearningTracker-sovelluksessa. Sovellus kysyi opiskelijoilta oppimistilanteen alussa, mitä he odottivat tuntevansa oppimistilanteen aikana ja mitä he tuntevat, kun he ajattelevat oppimistilanteessa tapahtuvaa oppimista. Näitä kysymyksiä vastaavat kysymykset kysyttiin myös oppimistilanteen loppuun. LearningTracker-sovellukseen opiskelijat kirjoittivat myös itse, mistä oppimistilanteesta on kyse, esimerkiksi luento tai laskuharjoitus.

LearningTracker-sovellukseen kirjattuja oppimistilanteita oli yhteensä 584, eli keskimäärin hieman alle kahdeksan oppimistilannetta yhtä opiskelijaa kohti. Määrä kuitenkin vaihteli opiskelijakohtaisesti kolmen ja 20:n välillä. Älyormuksilla sen sijaan tehtiin yli 547000 vireystilamittausta ja myös näissä oli suuria opiskelijakohtaisia eroja.

5.3 Aineiston valmistelu

Jotta tutkimusdataa voitiin analysoida, oli ensin yhdistettävä kahdella eri tavalla kerätty data, ja tämän jälkeen muokata yhdistetty data analyysiin sopivaksi. Datan valmistelu suoritettiin käyttäen Microsoftin Microsoft Excel-ohjelmaa ja Mathworksin MATLAB-ohjelmaa. Datan yhdistäminen tehtiin ajan mukaan. Aikaleimojen vertailemistä varten ajat muutettiin Unix-ajoina, joka kuvaa kuluneita sekunteja vuoden 1970 alusta. Tällöin aikoja oli helppo vertailla keskenään, koska aikaa voitiin merkitä yksittäisellä numerolla. Lisäksi aineisto pseudonymisoitiin antamalla jokaiselle opiskelijalle yksilöllinen numero.

Varsinainen yhdistäminen tapahtui Matlabin avulla. Yhdistämiseen käytetty Matlab-koodi kävi jokaisen LearningTracker-sovellukseen merkityn oppimistilanteen kohdalla läpi kaikki mitatut vireystilat ja keräsi niiden joukosta ne, joiden opiskelijaa vastaava numero on sama ja aikaleima osuu oppimistilanteen alun ja lopun välille. Koska mitattuja vireystiloja oli pääsääntöisesti useita yhdellä aikavälillä, laskettiin yhden oppimistilanteen ajalta kerätyistä vireystiloista keskiarvot. Tämän lisäksi laskettiin keskiarvot aikavälin ensimmäisestä viidestä vireystilasta ja viidestä viimeisestä vireystilasta. Lasketut vireystiloiden keskiarvot jokaiselle oppimistilanteelle lisättiin LearningTrackerillä kerättyyn dataan.

Tämän jälkeen tarkasteltiin puuttuvan datan määrää. Opiskelijat pitivät älysormusta muulloinkin kuin oppimistilanteissa ja vastaavasti oppimistilanteen aikana opiskelijalla ei välttämättä ollut sormusta käytössä lainkaan. Tästä johtuen joidenkin oppimistilanteiden ajalta puuttui vireystilan arvoja, tai niitä ei löytynyt lainkaan. Puuttuvan datan määrä laskettiin Matlabin avulla vähentämällä oppimistilanteen ajalta odotettujen datapisteiden määrästä mitattujen datapisteiden määrää. Odotettujen datapisteiden määrä oli yksi jokaista oppimistilanteen kestämää minuuttia kohti. Jokaiselle oppimistilanteelle laskettiin puuttuvan datan määrä prosentteina, sekä kaikkien oppimistilanteiden ajalta puuttuvan datan määrä yhteensä prosentteina. Yhteensä puuttuvaa dataa oli noin 55 %. Tämän lisäksi laskettiin oppimistilanteiden, joiden ajalta ei ole lainkaan vireystilan arvoja, osuus kaikista oppimistilanteista, sillä niitä oppimistilanteita ei voida hyödyntää datan analysoinnissa. Näiden oppimistilanteiden osuus oli noin 32 %.

Jotta eri matematiikan oppimistilanteiden vaikutuksia vireystilaan voitiin tarkastella, oli opiskelijoiden kuvaukset oppimistilanteista jaettava luokkiin. Oppimistilanteet jaettiin kahdeksaan eri tilannetyyppiin: luento, laskuharjoitus, prime time, tehtävien teko, itsenäinen työskentely, reenaamo, laskutupa ja tentti. Prime time -tilaisuus on opettajajohtoinen pienryhmätilaisuus, jossa keskustellaan viikon aiheesta ja tehdään tehtäviä. Reenaamo ja laskutupa ovat opiskelijoille vapaaehtoisia tukitilaisuuksia. Jokaista luokkaa laitettiin vastaamaan numerot yhdestä kahdeksaan. Luokittelu jouduttiin tekemään manuaalisesti Excelissä, sillä opiskelija olivat itse kirjoittaneet selitykset siitä, mikä oppimistilanne on kyseessä ja näin ollen vastauksia oli kirjoitettu hieman eri tavoilla.

Tämän jälkeen LearningTracker-sovellukseen vastatut tunnetilat luokiteltiin positiivisiin ja negatiivisiin tunteisiin sekä aktivoiviin ja deaktivoiviin tunteisiin. Tämä onnistui Matlabkoodin avulla. Koodiin oli määritetty mitkä tunteista ovat positiivisia ja mitkä tunteista ovat aktivoivia kuvan 3.1 mukaisesti. Koodi kävi läpi kaikki oppimistilanteet ja merkitsi positiivisia sekä aktivoivia tunteita ykkösellä, jättäen negatiivisille ja deaktivoiville tunteille nollan. Lisäksi muodostettiin uudet muuttujat, jolla kuvattiin tunnetilan jatkuvuutta oppimistilanteen aikana. Nämä muuttujat saivat neljää eri arvoa riippuen oppimistilanteen alussa ja lopussa valituista tunnetiloista. Tunnetila voi joko pysyä negatiivisena, pysyä positiivisena, muuttua positiivisesta negatiiviseksi tai muuttua negatiivisesta positiiviseksi. Jokaista vaihtoehtoa merkittiin eri numerolla ja vastaava tarkastelu toteutettiin aktivoiville ja deaktivoiville tunnetiloille.

Seuraavana vireystilan alussa ja lopussa -arvot luokiteltiin kolmeen eri luokkaan suuruuden mukaan, jotta myös vireystilan muutosta voidaan tarkastella. Alimmassa luokassa olivat arvot 10:stä 40:een, seuraavassa luokassa 40:stä 70:een ja tätä suuremmat arvot kuuluivat ylimpään luokkaan. Arvot, jotka olivat pienempiä kuin 10, hylättiin tässä tarkastelussa, koska oppimistilanteita tarkasteltaessa erittäin matalat vireystilan arvot eivät ole realistisia. Näiden avulla voitiin tarkastella, oliko vireystilan luokka pysynyt samana, noussut yhdellä, noussut kahdella, laskenut yhdellä vai laskenut kahdella kun verrattiin

vireystilan luokkaa oppimistilanteen alussa ja lopussa. Tarkastelu tehtiin Matlab-koodin avulla. Tarkastelussa otettiin huomioon vain ne oppimistilanteet joiden aikana oli mitattu vähintään 70% odotetusta älysormusdatasta. Tämä oli otettu huomioon Matlab-koodissa.

Lopuksi muodostettiin vielä aikaa kuvaava muuttuja. Data laitettiin Excel:ssä aikajärjestykseen opiskelijakohtaisesti. Tämän jälkeen jokainen oppimistilanne sai opiskelijakohtaisen järjestysnumeron, esimerkiksi, jos opiskelijalla oli merkittynä seitsemän oppimistilannetta, saivat oppimistilanteet numerot yhdestä seitsemään kronologisessa järjestyksessä. Sama toistettiin kaikkien opiskelijoiden kohdalla. Tämän jälkeen data oli valmis analyysiä varten.

5.4 Data-analyysi

Tutkimusdataa tutkittiin ensin yleisellä tasolla hyödyntäen Matlab ja Excel-ohjelmia. Tässä vaiheessa tarkasteltiin millaisia vireystilan arvoja opiskelijoilta oli mitattu matematiikan oppimistilanteiden aikana ja millaisia tunnetiloja oppimistilanteissa esiintyi. Matlab-koodin avulla voitiin eritellä saatuja tuloksia halutulla tavalla, jolloin esimerkiksi pystyttiin vertailemaan havaittuja tunnetiloja flippaustoteutuksen ja luentototeutuksen oppimistilanteiden välillä. Tärkeimmät tulokset kerättiin havainnollistaviin taulukoihin ja kuvaajiin Excel:ssä.

Tämän jälkeen tutkimusdataa analysoitiin R-Studio -ohjelmalla. Datan analysoinnissa pyrittiin etsimään mahdollista yhteyttä erityisesti tunnetilojen ja vireystilojen välillä matematiikan oppimistilanteissa. Analyysissä käytettiin pääosin lme [2] ja anova [23] funktioita. Lme funktiolla luodaan lineaarinen malli jossa vireystilan arvoja pyritään selittämään valituilla prediktoreilla. Ensimmäinen malli oli yksinkertainen malli, joka sisälsi vain vireystilan arvot. Tämän jälkeen prediktoreja alettiin lisäämään yksi kerrallaan, kuten kappaleessa 4.4 kerrottiin.

Anova funktion avulla pystyttiin vertailemaan kahta, tai useampaa mallia toisiinsa. Jos vertailusta selviää, että uusi malli on parempi kuin edellinen, käytetään tätä mallia seuraavan mallin pohjana. Jos taas edellinen malli olikin parempi, voidaan uusimpana lisätty prediktori jättää pois seuraavasta mallista. Mallien vertailuun käytettiin anova funktion antamaa 'Akaike information criterion', eli AIC arvoa, joka arvioi sitä, kuinka hyvin malli kuvaa dataa.

6. TULOKSET

6.1 Vireystila oppimistilanteissa

Tutkimuksessa havaittiin paljon erilaisia vireystiloja matematiikan oppimistapahtumissa, ja ne vaihtelivat myös oppimistilanteiden aikana. Koska vireystilamittauksia on paljon, käytetään tulosten esittelyssä pääosin keskiarvoja tulosten selkeyttämiseksi. Lisäksi vireystilaa tutkittaessa on otettu tuloksiin mukaan vain ne oppimistilanteet, joissa vireystilan mittaus-tuloksia on kerätty vähintään 70% oppimistilanteen kestosta. Tämän seurauksena 584:stä oppimistilanteesta jäi tutkittavaksi 224 kappaletta.

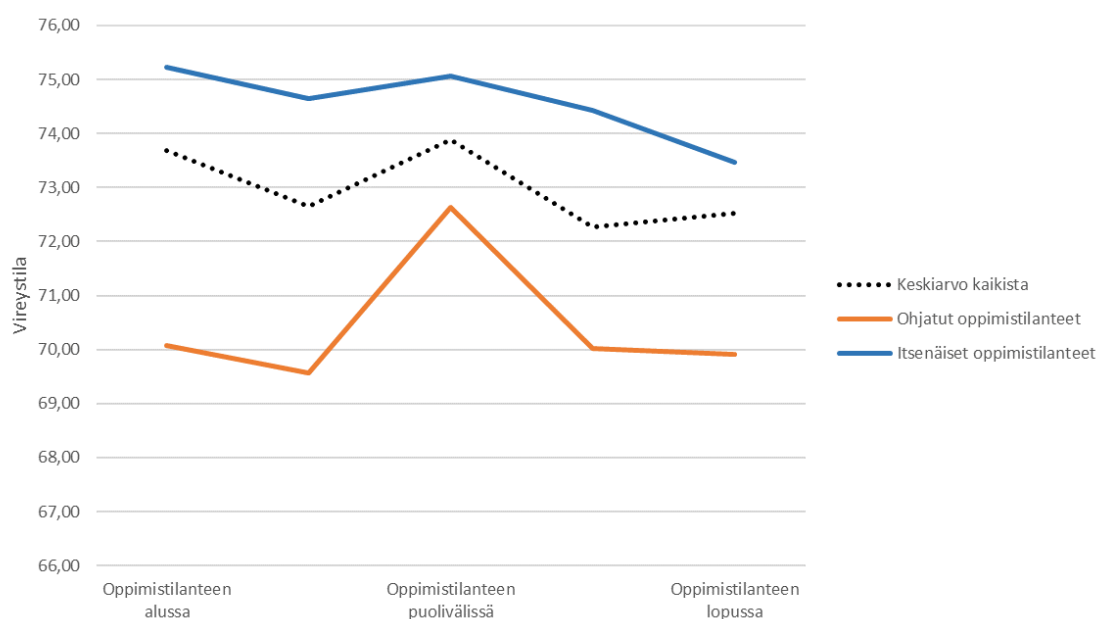
Kuten kappaleessa 2.1 kerrotaan, tässä tutkimuksessa vireystilaa mitattiin Moodmetric-älysoormuksen avulla. Soormuksen käyttöohjeissa vireystilat on luokiteltu viiteen eri luokkaan. Taulukossa 6.1 on jaoteltu tutkittavat oppimistilanteet näihin luokkiin oppimistilanteen ajalta mitatun vireystilan keskiarvon perusteella. Taulukkoon on listattu oppimistilanteiden määrä jokaisessa luokassa, sekä niiden osuudet kaikista tutkittavista oppimistilanteista. Taulukosta 6.1 huomataan, että korkeammat vireystilat ovat olleet matematiikan oppimistilanteissa kaikkein yleisimpiä.

Vireystila	Oppimistilanteiden määrä	Osuus kaikista (%)
Erittäin kiihtynyt (80-100)	99	44,20
Kiihtynyt (60-80)	64	28,57
Aktiivinen (40-60)	47	20,98
Tyyne (20-40)	11	4,91
Rauhallinen (0-20)	3	1,34

Taulukko 6.1. Keskimääräisten vireystilojen määriä oppimistilanteissa luokiteltuna viiteen kategoriaan

Vireystilaa voidaan tutkia myös erikseen erilaisissa oppimistilanteissa. Yksinkertainen tapa jaotella oppimistilanteita on jakaa ne ohjattuihin oppimistilanteisiin kuten esimerkiksi luennot ja laskuharjoitukset ja itsenäisiin oppimistilanteisiin, kuten esimerkiksi tehtävien tekeminen kotona. Vireystilaa ohjattujen ja itsenäisten oppimistilanteiden aikana on eritelty kuvassa 6.1. Vireystilan arvoja on kuvattu viidellä eri ajan hetkellä oppimistilanteiden

aikana. Yksittäistä oppimistilannetta vastaavina vireystilan arvoina käytettiin kolmen peräkkäisen mittapisteen keskiarvoa. Esimerkiksi siis vireystilan arvo oppimistilanteen alussa tarkoittaa kolmen ensimmäisen mitatun vireystilan arvon keskiarvoa. Lopuksi kaikkien oppimistilanteiden tiettyä ajanhetkeä vastaavista arvoista otettiin keskiarvot kuvaajaa varten. Tätä kuvaajaa varten karsittiin myös ne oppimistilanteet, joissa oppimistilanteen tyyppiä, esimerkiksi luento tai itsenäinen työskentely, ei oltu merkitty. Myös tenttitilanteet jätettiin huomioimatta, sillä ne ovat hyvin eri tyyppisiä oppimistilanteita. Tällöin jäljelle jäi 176 tutkittavaa oppimistilannetta, joista 89 oli ohjattuja oppimistilanteita ja 87 itsenäisiä oppimistilanteita.

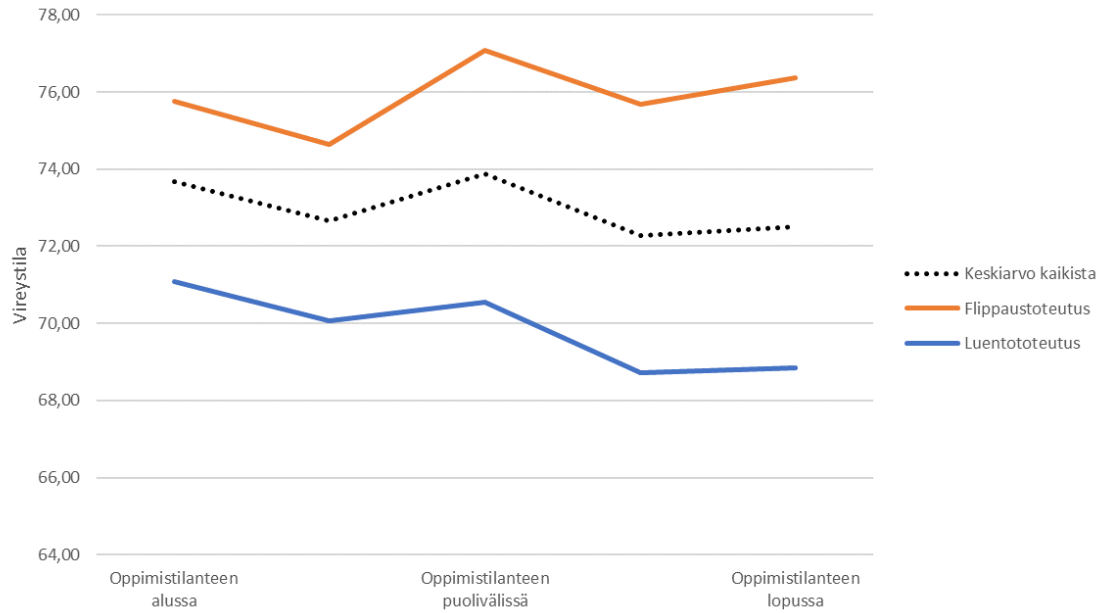


Kuva 6.1. Vireystila ohjatun ja itsenäisen oppimistilanteen aikana

Kuvasta 6.1 nähdään, että yleisesti itsenäisissä oppimistilanteissa vireystila on korkeampi, vaikkakin myös ohjatuissa oppimistilanteissa vireystila vastaa tasoa 'kiihtynyt' jos käytetään samaa luokittelua kuin taulukossa 6.1. Itsenäisissä oppimistilanteissa vireystila pääosin laskee oppimistilanteen aikana. Ohjatuissa oppimistilanteissa sen sijaan korkein vireystilan arvo saavutetaan oppimistilanteen puolivälissä, kun taas alussa ja lopussa vireystila on matalampi.

Vireystilaa voidaan vertailla myös eri opintojaksototeutusten välillä. Tutkimukseen osallistuneita opiskelijoita oli 75, joista 37 osallistui flippatululle toteutuskerralle ja loput 38 luentototeutukselle. Myös näistä tuloksista jätettiin tentit huomioimatta, jolloin tutkittavia oppimistilanteita oli 94 flippaustoteutukselle ja 119 luentototeutukselle, eli yhteensä 213 oppimistilannetta. Saadut tulokset on esitetty kuvassa 6.2.

Kuvasta 6.2 nähdään, että flippaustoteutuksella vireystila on ollut keskimäärin korkeampi, kuin luentototeutuksella. Flippaustoteutuksella vireystila on keskimäärin korkeampi oppi-

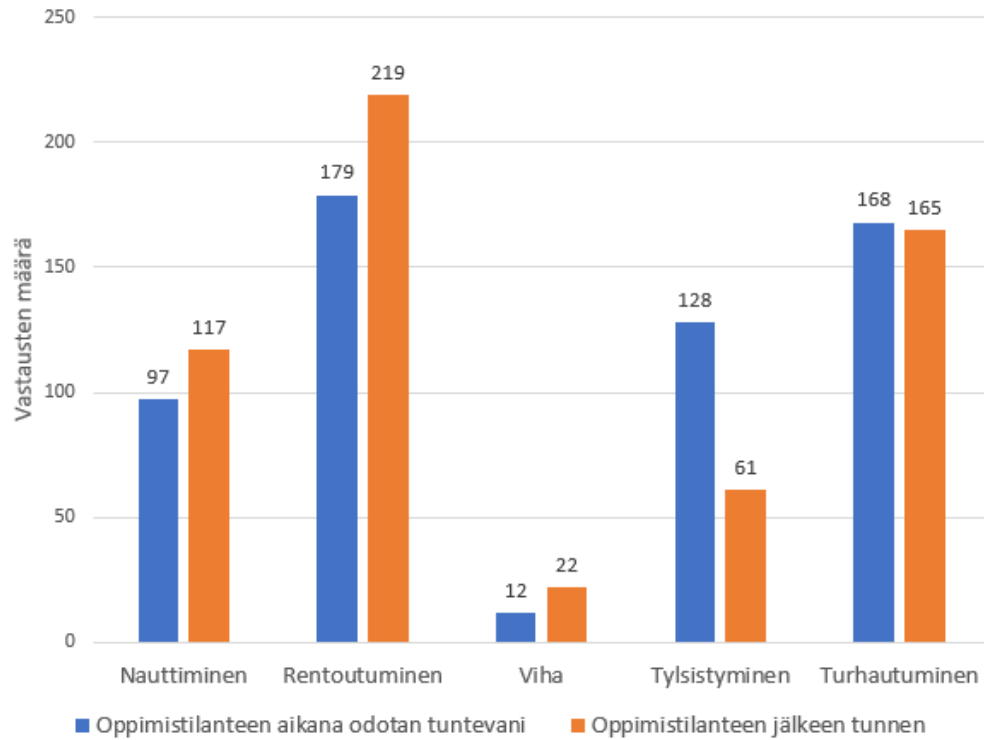


Kuva 6.2. Vireystila luentototeutuksen ja flippaustoteutuksen oppimistilanteissa

mistilanteen lopussa kuin alussa, kun taas luentototeutuksella vireystila on korkeammalla alussa, kuin lopussa.

6.2 Tunnetilat oppimistilanteissa

Tutkimuksessa opiskelijoiden tunnetiloihin liittyen kysyttiin neljä kysymystä, joista kaksi kysyttiin ennen oppimistilannetta ja kaksi sen jälkeen. Kysymyksistä kaksi liittyi yleisesti opiskelijoiden tuntemuksiin oppimistilanteessa, johon opiskelijat vastasivat parhaiten kuvaavan tunnetilan. Näin saadut tulokset on esitetty kuvassa 6.3. Tulokset löytyvät myös taulukkoina liitteestä A.




Kuva 6.3. *Opiskelijoiden tuntemat tunnetilat ennen oppimistilannetta ja sen jälkeen*

Kuvasta 6.3 nähdään, että yleisimmät tunnetilat opiskelijoilla ovat olleet rentoutuminen ja turhautuminen. Lisäksi huomataan, että erityisesti tylsistymisen määrä on vähentynyt merkittävästi kun tunnetilaa kysytään oppimistilanteen jälkeen verrattuna ennen oppimistilannetta kysytyyn odotukseen tulevasta tunnetilasta.


Vaihtoehtoina olleet tunnetilat voidaan lisäksi jaotella positiivisiin ja negatiivisiin tunnetiloihin sekä aktivoiviin ja deaktivoiviin tunnetiloihin kuvan 3.1 mukaisesti. Näin saadut suhteet on esitetty kuvassa 6.4.

Opetustilanteen aikana odotan tuntevani




■ Positiivisia tunnetiloja
■ Negatiivisia tunnetiloja

Opetustilanteen aikana odotan tuntevani




■ Aktivoivia tunnetiloja
■ Deaktivoivia tunnetiloja

Oppimistilanteen jälkeen tunnen



■ Positiivisia tunnetiloja
■ Negatiivisia tunnetiloja

Oppimistilanteen jälkeen tunnen




■ Aktivoivia tunnetiloja
■ Deaktivoivia tunnetiloja

Kuva 6.4. Opiskelijoiden vastaukset jaoteltuna positiivisiin ja negatiivisiin sekä aktivoiviin ja deaktivoiviin tunnetiloihin

Kuvasta 6.4 nähdään, että oppimistilanteen jälkeen opiskelijat ovat kokeneet enemmän positiivisia tunnetiloja, kuin mitä he ovat odottaneet tuntevansa oppimistilanteen aikana. Opiskelijat ovat tunteneet merkittävästi enemmän deaktivoivia tunnetiloja, kuin aktivoivia tunnetiloja oppimistilanteen aikana ja sen päätyttyä. Aktivoivien tunnetilojen määrä on kuitenkin kasvanut oppimistilanteen jälkeen.

Toisissa kahdessa kysymyksessä kysyttiin erityisesti oppimiseen liittyviä tunnetiloja oppimistilanteen aikana ja sen jälkeen. Saadut tulokset on esitetty kuvassa 6.5.




Kuva 6.5. *Opiskelijoiden oppimisesta tuntemat tunnetilat ennen oppimistilannetta ja sen jälkeen*

Kuvasta 6.5 nähdään, että toiveisuus on ollut selkeästi yleisin tunnetila, kun opiskelijoilta kysyttiin oppimisesta ennen oppimistilanteen alkua. Kysyttäessä oppimistilanteen jälkeen yleisin tunnetila oli helpotus.


Kuten aiemmissa kysymyksissä, saadut tulokset voidaan jaotella kuvan 3.1 mukaisesti. Positiivisten ja negatiivisten sekä aktivoivien ja deaktivoivien tunnetilojen määrät on esitetty kuvassa 6.6.

Kun ajattelen oppimista
oppimistilanteen
aikana, tunnen




■ Positiivisia tunnetiloja
■ Negatiivisia tunnetiloja

Kun ajattelen oppimista
oppimistilanteen
aikana, tunnen




■ Aktivoivia tunnetiloja
■ Deaktivoivia tunnetiloja

Kun ajattelen
oppimistani
oppimistilanteen
jälkeen, tunnen



■ Positiivisia tunnetiloja
■ Negatiivisia tunnetiloja

Kun ajattelen
oppimistani
oppimistilanteen
jälkeen, tunnen



■ Aktivoivia tunnetiloja
■ Deaktivoivia tunnetiloja

Kuva 6.6. Opiskelijoiden vastaukset jaoteltuna positiivisiin ja negatiivisiin, sekä aktivoiviin ja deaktivoiviin tunnetiloihin

Kuvasta 6.6 nähdään, että positiiviset tunnetilat ovat negatiivisia selkeästi yleisempiä ajateltaessa oppimista oppimistilanteen aikana ja sen jälkeen. Kun oppimiseen liittyviä tunnetiloja kysyttiin ennen oppimistilannetta, aktivoivat tunnetilat olivat huomattavasti yleisempiä, kuin deaktivoivat tunnetilat. Toisaalta oppimistilanteen jälkeen deaktivoivat tunnetilat ovat merkittävästi yleisempiä.

Tunnetiloja voidaan verrata myös eri toteutuskertojen välillä. Flippaustoteutukselta ja luentototeutukselta kerätyt vastaukset kaikkiin kysymyksiin on jaoteltu positiivisiin ja negatiivisiin sekä aktivoiviin ja deaktivoiviin tunnetiloihin taulukossa 6.7.

		Flippaustoteutus		Luentototeutus	
		Vastauksia (kpl)	Osuus kaikista (%)	Vastauksia (kpl)	Osuus kaikista (%)
Opetustilanteen aikana odotan tuntevani	Positiivisia tunnetiloja	116	45,67	160	48,48
	Negatiivisia tunnetiloja	138	54,33	170	51,52
	Aktivoivia tunnetiloja	44	17,32	65	19,70
	Deaktivoivia tunnetiloja	210	82,68	265	80,30
Kun ajattelen oppimista oppimistilanteen aikana, tunnen	Positiivisia tunnetiloja	168	66,14	214	64,85
	Negatiivisia tunnetiloja	86	33,86	116	35,15
	Aktivoivia tunnetiloja	178	70,08	241	73,03
	Deaktivoivia tunnetiloja	76	29,92	89	26,97
Oppimistilanteen jälkeen tunnen	Positiivisia tunnetiloja	137	53,94	199	60,30
	Negatiivisia tunnetiloja	117	46,06	131	39,70
	Aktivoivia tunnetiloja	57	22,44	82	24,85
	Deaktivoivia tunnetiloja	197	77,56	248	75,15
Kun ajattelen oppimistani oppimistilanteen jälkeen, tunnen	Positiivisia tunnetiloja	186	73,23	237	71,82
	Negatiivisia tunnetiloja	68	26,77	93	28,18
	Aktivoivia tunnetiloja	84	33,07	93	28,18
	Deaktivoivia tunnetiloja	170	66,93	237	71,82

Kuva 6.7. Tunnetilojen vertailua flippaustoteutuksen ja luentototeutuksen oppimistilanteiden välillä

Taulukosta 6.7 nähdään, että tuloksissa ei ole kovin suuria eroja flippaustoteutuksen ja luentototeutuksen välillä, vaan opiskelijoiden vastaukset ovat saman suuntaisia. Suurin ero tunnetiloissa on oppimistilanteen jälkeen, jolloin luentototeutuksen opiskelijat ovat tunteneet noin 60% positiivisia tunnetiloja, kun taas flippaustoteutuksella vastaava luku on vain noin 54%.

6.3 Vireystila ja tunnetilat oppimistilanteissa

Tutkimuksen eräänä tarkoituksena oli tutkia vireystilan ja tunnetilojen välistä yhteyttä yliopistomatematiikan oppimistilanteissa. Tätä tutkittaessa kaikista 584 oppimistilanteesta on jätetty pois ne, joissa vireystilan arvot puuttuvat kokonaan tai vireystilan keskiarvoksi oppimistilanteen ajaksi on saatu nolla, joka ei ole realistinen mittaustulos. Näin ollen jäljelle jäi yhteensä 377 tutkittavaa oppimistilannetta. Kymmeneltä opiskelijalta vireystilan arvot oppimistilanteiden ajalta puuttuivat, jolloin tutkittavia opiskelijoita jäi 65. Lisäksi tunnetiloihin liittyvät prediktorit keskitettiin jokaiselle opiskelijalle tulosten laadun parantamiseksi.

Mittaustuloksista muodostettiin lineaarisia malleja luvussa 4.4 esitetyn mukaisesti ja erilaisia malleja verrattiin toisiinsa Anova-funktion avulla. Saadut tulokset kerättiin taulukkoihin. Kuvissa 6.8 ja 6.9 on käytetty prediktoreina tunnetiloja, jotka on jaoteltu aktivoiviin ja deaktivoiviin tunnetiloihin.

Predictors	m0 _{KA} ~ I			m1 _{KA} ~ time + flip			m2 _{KA} ~ time + flip + pread			m3 _{KA} ~ time + flip + pread + postad		
	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p
(Intercept)	70.81	66.63 – 74.99	<0.001	63.02	56.97 – 69.07	<0.001	64.08	58.09 – 70.08	<0.001	64.13	58.13 – 70.12	<0.001
time id				0.65	0.16 – 1.14	0.009	0.55	-0.21 – 1.30	0.157	0.54	-0.21 – 1.29	0.159
flipped				10.22	2.18 – 18.27	0.014	8.82	0.95 – 16.69	0.029	8.78	0.91 – 16.66	0.030
pre em act deact cwc							-0.87	-5.02 – 3.28	0.682	-0.81	-4.96 – 3.35	0.704
post em act deact cwc										-0.94	-4.59 – 2.71	0.616
Random Effects												
σ^2		193.01			189.92			170.26			170.33	
τ_{00}		244.71 alt_id			215.13 alt_id			208.70 alt_id			208.01 alt_id	
τ_{11}								2.60 alt_id.time_id			2.55 alt_id.time_id	
ρ_{01}								-0.20 alt_id			-0.20 alt_id	
ICC								0.60			0.60	
N		65 alt_id			65 alt_id			65 alt_id			65 alt_id	
Observations		377			377			377			377	
Marginal R ² / Conditional R ²		0.000 / NA			0.122 / NA			0.044 / 0.616			0.044 / 0.615	

Kuva 6.8. Yhteenveto mittaustuloksista muodostetuista lineaarisista malleista

Kuvassa 6.8 on esitetty neljä mallia, joista 'm0' ei sisällä yhtäkään prediktorilla, 'm1' sisältää yleisiä prediktoreja kuten aikaa kuvaavan prediktorin 'time id' sekä opiskelijan opin-tojakson toteutustavan kertova prediktori 'flipped'. Kuvassa esiintyvät tunnetilaprediktorit sisältävät tiedon siitä, onko opiskelijan vastaus kysymyksiin 'opetustilanteen aikana odotan tuntevani' ja 'oppimistilanteen jälkeen tunnen' ollut aktivoiva vai deaktivoiva tunneti-la. 'Estimates' kertoo jokaisessa mallissa jokaisella prediktorilla lasketun regressiokertoimen, kun taas 'CI' kertoo regressiokertoimen luottamusvälin. Lisäksi taulukosta nähdään p-arvot, joista tilastollisesti merkitsevät on merkattu tummennettuna.

Taulukosta löytyy myös satunnaisvaikutuksiin liittyviä arvoja. Taulukossa

σ^2 = varianssi

τ_{00} = mallin virhetermin varianssi

τ_{11} = satunnaisvaikutusten varianssi

ρ_{01} = korrelaatio virhetermin ja satunnaisvaikutusten välillä.

ICC = korrelaatio klusterin sisällä (tarkoittaa tässä tapauksessa korrelaatiota yksittäisen opiskelijan omien tulosten välillä).

Lisäksi R^2 kertoo kuinka suuri osuus ennustettavan muuttujan varianssista voidaan selittää valittujen prediktorien avulla. 'Marginal R^2 ' arvoa laskettaessa ei huomioida satunnaisvaikutuksia lainkaan, mutta 'Conditional R^2 ' arvossa myös satunnaisvaikutukset on huomioitu.

Kuvassa 6.9 on myös esitetty neljä mallia kuten aiemmassakin taulukossa. Tunnetilaprediktorit ovat vaihtuneet ja sisältävät nyt tiedon siitä, onko opiskelijan vastaus kysymyksiin 'kun ajattelen oppimista oppimistilanteen aikana, tunnen' ja 'kun ajattelen oppimistani oppimistilanteen jälkeen, tunnen' ollut aktivoiva vai deaktivoiva tunnetila.

Taulukoista 6.8 ja 6.9 nähdään, että kaikilla tunnetilaprediktoreilla on malleissa korkeat p-arvot, jolloin ei voida varmuudella sanoa, että niillä olisi yhteys vireystilaan. Sen sijaan esimerkiksi se, että onko opiskelija kuulunut flippaustoteutukselle vai luentototeutukselle on todennäköisesti vaikuttanut opiskelijan vireystilaan.

Kuvissa 6.10 ja 6.11 on esitetty vastaavat taulukot, kuin aiemmissa kuvissa. Tällä kertaa prediktoreina on käytetty tunnetiloja, jotka on jaoteltu positiivisiin ja negatiivisiin tunnetiloihin.

Predictors	m0 _{KA} ~ I			m1 _{KA} ~ time + flip			m2 _{KA} ~ time + flip + prelad			m3 _{KA} ~ time + flip + prelad + postlad		
	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p
(Intercept)	70.81	66.63 – 74.99	<0.001	63.02	56.97 – 69.07	<0.001	64.11	58.13 – 70.09	<0.001	64.15	58.17 – 70.13	<0.001
time id				0.65	0.16 – 1.14	0.009	0.54	-0.21 – 1.30	0.161	0.53	-0.22 – 1.29	0.170
flipped				10.22	2.18 – 18.27	0.014	8.83	0.97 – 16.69	0.029	8.82	0.95 – 16.68	0.030
pre em learn act deact cwc							-1.73	-5.21 – 1.76	0.334	-1.79	-5.29 – 1.70	0.316
post em learn act deact cwc										1.06	-2.27 – 4.38	0.535
Random Effects												
σ^2		193.01			189.92			169.81			169.53	
τ_{00}		244.71 alt_id			215.13 alt_id			206.85 alt_id			207.09 alt_id	
τ_{11}							2.64 alt_id,time_id				2.65 alt_id,time_id	
ρ_{01}							-0.20 alt_id				-0.20 alt_id	
ICC							0.60				0.60	
N		65 alt_id			65 alt_id			65 alt_id			65 alt_id	
Observations		377			377			377			377	
Marginal R ² / Conditional R ²		0.000 / NA			0.122 / NA			0.045 / 0.617			0.045 / 0.618	

Kuva 6.9. Yhteenveto mittaustuloksista muodostetuista lineaarisista malleista

Predictors	m0 _{K_A} ~ 1			m1 _{K_A} ~ time + flip			m2 _{K_A} ~ time + flip + prepn			m3 _{K_A} ~ time + flip + prepn + postpn		
	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p
(Intercept)	70.81	66.63 – 74.99	<0.001	63.02	56.97 – 69.07	<0.001	64.20	58.20 – 70.19	<0.001	64.20	58.20 – 70.19	<0.001
time id				0.65	0.16 – 1.14	0.009	0.54	-0.22 – 1.30	0.165	0.53	-0.23 – 1.29	0.174
flipped				10.22	2.18 – 18.27	0.014	8.73	0.88 – 16.58	0.031	8.80	0.95 – 16.66	0.030
pre em act pos neg cwc							1.17	-2.09 – 4.42	0.483	1.07	-2.21 – 4.35	0.523
post em act pos neg cwc										0.77	-2.28 – 3.83	0.620
Random Effects												
σ^2		193.01			189.92			170.13			169.79	
τ_{00}		244.71 alt_id			215.13 alt_id			207.93 alt_id			208.76 alt_id	
τ_{11}								2.65 alt_id.time_id			2.71 alt_id.time_id	
ρ_{01}								-0.21 alt_id			-0.22 alt_id	
ICC								0.60			0.60	
N		65 alt_id			65 alt_id			65 alt_id			65 alt_id	
Observations		377			377			377			377	
Marginal R ² / Conditional R ²		0.000 / NA			0.122 / NA			0.044 / 0.615			0.045 / 0.616	

Kuva 6.10. Yhteenveto mittaustuloksista muodostetuista lineaarisista malleista

Predictors	m0 _{KA} ~ 1			m1 _{KA} ~ time + flip			m2 _{KA} ~ time + flip + prelpn			m3 _{KA} ~ time + flip + prelpn + postipn		
	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p	Estimates	CI	p
(Intercept)	70.81	66.63 – 74.99	<0.001	63.02	56.97 – 69.07	<0.001	64.14	58.14 – 70.13	<0.001	64.16	58.17 – 70.16	<0.001
time id				0.65	0.16 – 1.14	0.009	0.55	-0.21 – 1.31	0.158	0.54	-0.21 – 1.30	0.162
flipped				10.22	2.18 – 18.27	0.014	8.78	0.93 – 16.63	0.030	8.82	0.97 – 16.67	0.029
pre em learn pos neg cwc							1.20	-2.18 – 4.59	0.487	1.10	-2.29 – 4.50	0.525
post em learn pos neg cwc										1.37	-2.01 – 4.75	0.429
Random Effects												
σ^2		193.01			189.92			169.91			169.71	
τ_{00}		244.71 alt_id			215.13 alt_id			209.10 alt_id			209.70 alt_id	
τ_{11}							2.69 alt_id,time_id				2.66 alt_id,time_id	
ρ_{01}							-0.21 alt_id				-0.22 alt_id	
ICC							0.60				0.60	
N		65 alt_id			65 alt_id		65 alt_id				65 alt_id	
Observations		377			377		377				377	
Marginal R ² / Conditional R ²		0.000 / NA			0.122 / NA		0.044 / 0.616				0.046 / 0.616	

Kuva 6.11. Yhteenveto mittaustuloksista muodostetuista lineaarisista malleista

Taulukossa 6.10 on käytetty tunnetilaprediktoreina vastauksia kysymyksiin 'opetustilanteen aikana odotan tuntevani' ja 'oppimistilanteen jälkeen tunnen', niin että vastaukset on jaoteltu positiivisiin ja negatiivisiin tunnetiloihin kuvan 3.1 mukaisesti. Taulukossa 6.11 sen sijaan on käytetty tunnetilaprediktoreina vastauksia kysymyksiin 'kun ajattelen oppimista oppimistilanteen aikana, tunnen' ja 'kun ajattelen oppimistani oppimistilanteen jälkeen, tunnen' vastaavasti kuin edellisessä taulukossa.

Myös taulukoista 6.10 ja 6.11 voidaan havaita samat tulokset kuin aiemmista taulukoista. Kaikki tunnetilaprediktorit saavat korkeita p-arvoja, jolloin ei voida olettaa positiivisten ja negatiivisten tunnetilojen sekä vireystilan välillä olevan yhteyttä.

7. JOHTOPÄÄTÖKSET

Tässä osiossa pohditaan vastauksia tutkimuskysymyksiin tulosten perusteella. Lisäksi verrataan tuloksia aiempiin tutkimuksiin. Lopuksi pohditaan tulosten luotettavuutta.

7.1 Vastaukset tutkimuskysymyksiin

Ensimmäinen tutkimuskysymys oli 'millaisia vireystiloja havaitaan yliopistomatematiikan oppimistilanteissa?' Yleisesti tämän tutkimuksen tuloksista nähdään, että korkeammat vireystilat olivat yleisimpiä oppimistilanteiden aikana. Taulukosta 6.1 nähdään, että keskimääräinen vireystila saavutti korkeimman luokan oppimistilanteen aikana yli 44%:ssa tutkituista oppimistilanteista. Kuvasta 6.1 nähdään, että itsenäisissä oppimistilanteissa vireystila oli korkeampi kuin ohjatuissa oppimistilanteissa. Lisäksi kuvasta 6.2 voidaan huomata, että flippaustoteutuksen oppimistilanteissa vireystila oli keskimäärin korkeampi kuin luentototeutuksella.

Bliksteinin ja kumppaneiden tutkimuksessa [4] havaittiin vireystilan käyttäytyvän eri tavoin ohjatuissa ja itsenäisissä oppimistilanteissa. Kyseisen tutkimuksen perusteella muodostettiin hypoteesit H1 ja H2.

H1 Ohjatuissa opetustilanteissa vireystila on korkeimmillaan opetustilanteen alussa ja lopussa.

Tuloksista nähdään täysin päinvastainen ilmiö, eli vireystila on keskimäärin korkeimmillaan oppimistilanteen keskivaiheella ja selvästi matalammalla alussa ja lopussa. Tämä havaitaan hyvin kuvasta 6.1. Tämän tutkimuksen tulosten perusteella hypoteesi H1 hylätään.

H2 Itsenäisissä oppimistilanteissa vireystila laskee oppimistilanteen aikana.

Tuloksista voidaan havaita, että keskimäärin vireystila laskee itsenäisten oppimistilanteiden aikana. Tämä nähdään hyvin kuvasta 6.1. Tämän tutkimuksen tulosten perusteella hypoteesi H2 hyväksytään.

Pijeira-Díazin ja kumppaneiden tutkimuksessa [22] havaittiin vireystilojen olleen matalia oppimistilanteissa. Tämän perusteella muodostettiin hypoteesi H3.

H3 Matala vireystila on yleisin vireystila oppimistilanteessa.

Tuloksista voidaan havaita, että korkeammat vireystilat olivat selvästi yleisempiä kuin matalammat vireystilat. Tämä nähdään taulukosta 6.1, jonka mukaan yli 44%:lla tutkittuja oppimistilanteita erittäin kiihtynyt kuvasi parhaiten keskimääräistä vireystilaa. Tämän tutkimuksen tulosten perusteella hypoteesi H3 hylätään.

Toiseksi tutkimuskysymykseksi valittiin 'miten erilaiset tunnetilat näyttäytyvät yliopistomatematiikan oppimistilanteissa?' Tämän tutkimuksen tuloksista havaittiin, että opiskelijat kokivat oppimistilanteissa enemmän positiivisia kuin negatiivisia tunnetiloja. Toisaalta deaktivoivia tunnetiloja havaittiin enemmän kuin aktivoivia tunnetiloja. Yleisimmin havaitut tunnetilat olivat toiveikkuus ja rentoutuminen. Negatiivisista tunnetiloista yleisimmät olivat ahdistus ja turhautuminen.

Niculescun ja kumppaneiden tutkimuksessa [15] tutkittiin oppimiseen liittyviä tunnetiloja. Kyseisen tutkimuksen tulosten perusteella muodostettiin hypoteesit H4 ja H5.

H4 Positiiviset tunnetilat ovat yleisempiä kuin negatiiviset tunnetilat matematiikan oppimistilanteissa.

Tuloksista voidaan havaita, että positiiviset tunnetilat ovat oppimistilanteissa yleisempiä kuin negatiiviset oppimistilanteet. Kuvista 6.4 ja 6.6 nähdään, että kolmeen neljästä kysymyksestä oli vastattu enemmän positiivisia kuin negatiivisia tunnetiloja. Lisäksi kysymykseen 'Opetustilanteen aikana odotan tuntevani' oli vastattu yli 47% positiivisia tunnetiloja, joten ero positiivisten ja negatiivisten tunnetilojen välillä on ollut pieni muihin kysymyksiin verrattuna. Tämä nähdään helposti liitteen A taulukoista. Tämän tutkimuksen tulosten perusteella hypoteesi H4 hyväksytään.

H5 Aktivoivat tunnetilat ovat yleisempiä kuin deaktivoivat tunnetilat matematiikan oppimistilanteissa.

Tuloksista nähdään, että deaktivoivat tunnetilat ovat yleisempiä oppimistilanteissa kuin aktivoivat tunnetilat. Kuvista 6.4 ja 6.6 nähdään, että kolmeen neljästä kysymyksestä oli vastattu enemmän deaktivoivia tunnetiloja kuin aktivoivia tunnetiloja. Toisaalta kysymykseen 'Kun ajattelen oppimista oppimistilanteen aikana, tunnen' on vastattu lähes 72% aktivoivia tunnetiloja, joka poikkeaa selvästi muiden kysymysten vastauksista. Muissa kysymyksissä deaktivoivat tunteet ovat kuitenkin olleet selkeästi yleisempiä. Tämän tutkimuksen tulosten perusteella hypoteesi H5 hylätään.

Kolmanneksi tutkimuskysymykseksi valittiin 'miten havaitut tunnetilat ja vireystilat vertautuvat perinteisen opetuksen ja flipatun opetuksen välillä?' Kuten aiemmin mainittiin, flippaustoteutuksella mitatut vireystilat olivat keskimäärin korkeampia kuin luentototeutuksella. Lisäksi kuvasta 6.2 nähdään, että luentototeutuksella vireystila on keskimäärin lopussa matalampi kuin alussa, kun taas flippaustoteutuksella vireystila on hieman korkeampi lopussa kuin alussa. Flippaustoteutuksella korkein vireystila saavutetaan kuitenkin keskimäärin oppimistilanteen puolivälissä.

Kuten taulukosta 6.7 nähdään, mitään suuria eroja tunnetiloissa flippaustoteutuksen ja luentototeutuksen välillä ei ole. Opiskelijälähtöisessä opetuksessa, jota flippaus suurimaksi osaksi on, voisi kuvitella aktivoivien tunteiden olevan yleisempiä kuin luentototeutuksen opettajajohtoisessa opetuksessa. Tuloksista tällaista ei kuitenkaan voida havaita. Suurin ero nähdään kysymyksen 'Oppimistilanteen jälkeen tunnen' kohdalla, jossa luentototeutuksella on vastattu enemmän positiivisia tunnetiloja hieman yli kuuden prosenttiyksikön verran verrattuna flippaustoteutukseen.

Neljäs tutkimuskysymys oli 'miten aktivoivilla ja deaktivoivilla tunnetiloilla voidaan selittää vireystilaa yliopistomatematiikan oppimistilanteissa?' Tuloksista taulukoissa 6.8 ja 6.9 havaittiin, että tutkimustulosten perusteella ei voida vahvistaa yhteyttä aktivoivien ja deaktivoivien tunnetilojen sekä vireytilan välille. Saadut p-arvot olivat liian suuria, jotta niistä olisi voitu vetää luotettavia johtopäätöksiä.

Muun muassa Pekrunin ja kumppaneiden esittelemän tunnetilojen jaottelun [20] perusteella muodostettiin hypoteesi:

H6 Aktivoivien ja deaktivoivien tunnetilojen avulla voidaan ennustaa vireystilan suuruutta.

Tämän tutkimuksen tulosten perusteella aktivoivien ja deaktivoivien tunnetilojen avulla ei voida ennustaa vireystilan suuruutta. Näin ollen hypoteesi H6 hylätään.

Viimeiseksi tutkimuskysymykseksi valittiin 'miten positiivisilla ja negatiivisilla tunnetiloilla voidaan selittää vireystilaa yliopistomatematiikan oppimistilanteissa?' Taulukoiden 6.10 ja 6.11 tulosten perusteella nähtiin, että tunnetilaprediktorit, jotka kuvasivat positiivisia ja negatiivisia tunnetiloja, saivat suuria p-arvoja muodostetuissa lineaarisissa malleissa. Näin ollen ei voida osoittaa luotettavasti, että positiivisten ja negatiivisten tunnetilojen sekä vireystilan välillä olisi yhteyttä.

Villanuevan ja kumppaneiden tutkimuksessa [31] ei havaittu korrelaatiota positiivisten ja negatiivisten tunnetilojen, sekä vireystilan välillä. Tämän perusteella muodostettiin hypoteesi:

H7 Positiivisten ja negatiivisten tunnetilojen avulla ei voida ennustaa vireystilaa.

Tämän tutkimuksen tulosten perusteella positiivisilla ja negatiivisilla tunnetiloilla ei voida ennustaa vireystilan suuruutta. Tästä syystä hypoteesi H7 hyväksytään.

7.2 Tulosten arviointi

Kuten luvussa 7.1 havaittiin, seitsemästä muodostetusta hypoteesista neljä hylättiin ja loput kolme hyväksyttiin. Muodostetut hypoteesit perustuvat aiempiin tutkimuksiin ja teorioihin, joten tutkimustulokset hyväksytyjen hypoteesien H2, H4 ja H7 osalta ovat linjassa aiempien tutkimusten kanssa. Tällöin myös tässä tutkimuksessa saadut tulokset vaikutta-

vat luotettavilta, koska nyt usean tutkimuksen tuloksista on voitu tehdä samoja johtopäätöksiä.

Pohditaan seuraavaksi syitä sille, miksi osa tutkimustuloksista on ristiriidassa aiempien tutkimusten kanssa. Hypoteesin H1 mukaan ohjatuissa opetustilanteissa korkeimmat viireystilan arvot saadaan opetustilanteen alussa ja lopussa, kun taas tämä tutkimus näytti täysin päinvastaista tulosta. Hypoteesi H1 muodostettiin Bliksteinin ja kumppaneiden tutkimuksen [4] pohjalta. Tutkimusten välillä on kuitenkin jonkin verran eroja, joiden avulla voidaan ainakin osittain perustella eriäviä tuloksia. Esimerkiksi Bliksteinin ja kumppaneiden tutkimukseen osallistui lukiolaisia, joiden viireystilaa tutkittiin tietyn annetun tehtävän aikana, kun taas tässä tutkimuksessa tutkittiin yliopisto-opiskelijoita laajemmin useissa eri yliopistomatematiikan oppimistilanteissa. Lisäksi molemmissa tutkimuksissa tutkittavat ryhmät olivat suhteellisen pieniä, jos tuloksia haluttaisiin yleistää esimerkiksi kaikkiin opiskelijoihin, koska tällöin myös sattuma voi vaikuttaa tuloksiin. Mahdollista virhettä tämän tutkimuksen viireystilamittauksiin voi vaikuttaa esimerkiksi puutteelliset viireystilan arvot joidenkin oppimistilanteiden ajalta. Opiskelijoilla ei aina ollut älysormus päällä oppimistilanteen aikana tai sitä käytettiin vain osan ajasta. Tässä tutkimuksessa huomioitiin oppimistilanteet, joiden ajalta oli mitattu vähintään 70% viireystilan arvoista. Kun oppimistilanteen ajalta mitattua viireystilaa hyödynnetään tulosten laskennassa, puuttuvat arvot luovat mahdollista virhettä tuloksiin. Toisaalta, jos kaikki oppimistilanteet, joista arvoja puuttuu olisi jätetty huomiotta, otoskoko olisi pientynyt ja tulosten luotettavuus olisi heikentynyt myös siinä tapauksessa.

Hypoteesin H3 mukaan matala viireystila on yleisin viireystila oppimistilanteissa. Tämä hypoteesi muodostettiin Pijeira-Díazin ja kumppaneiden tutkimuksen [22] perusteella. Tämän tutkimuksen tulokset taas olivat päinvastaiset Pijeira-Díazin ja kumppaneiden tutkimuksen tuloksiin verrattuna, sillä korkeat viireystilan arvot olivat kaikkein yleisimpiä. Jälleen eroja tuloksissa voidaan osittain perustella tutkittavien ryhmien välisillä eroilla, kuten esimerkiksi tutkittavien oppilaiden ja opiskelijoiden välinen ikäero. Lisäksi Pijeira-Díazin ja kumppaneiden tutkimus suoritettiin fysiikan kurssilla, kun taas tässä tutkimuksessa tutkittiin matematiikan oppimistilanteita. Myös Pijeira-Díazin ja kumppaneiden tutkimuksessa tutkittava ryhmä oli suhteellisen pieni, joten jälleen myös sattumalla voi olla vaikutusta. Eroja tuloksissa on voinut syntyä myös mahdollisissa virheissä tämän tutkimuksen viireystilamittausten tuloksissa, kuten edellisessä kappaleessa kerrottiin.

Hypoteesin H5 mukaan aktivoivat tunnetilat ovat oppimistilanteissa yleisempiä, kuin deaktivoivat tunnetilat. Tämän hypoteesi perustuu Niculescun ja kumppaneiden tutkimukseen [15]. Tämän tutkimuksen ovat lähes päinvastaisia Niculescun ja kumppaneiden tutkimuksen tulosten kanssa. Niculescun ja kumppaneiden tutkimuksessa aineisto tunnetiloista kerättiin kyselylomakkeiden avulla, joka on menetelmänä verrannollinen tässä tutkimuksessa käytettyyn LearningTracker-sovellukseen. Kyselylomakkeiden avulla kerätyn datan luotettavuus perustuu monesti kysymysten laatuun ja mahdollisiin vastausvaihtoehtoihin.

Tulokset ovat myös riippuvaisia siitä, että opiskelijat vastaavat kysymyksiin huolella. Koetua tunnetilaa voi olla myös vaikea arvioida, erityisesti silloin, jos vastausvaihtoehdoista ei löydy täydellistä vastausta kuvaamaan koettua tunnetilaa. Näistä syistä tutkimustulosten välille voi syntyä eroja eri tutkimusten välillä.

Hypoteesin H6 mukaan aktivoivien ja deaktivoivien tunnetilojen avulla voidaan ennustaa vireystilan suuruutta. Tämän tutkimuksen tulosten perusteella näin ei kuitenkaan ollut. Muista hypoteeseistä poiketen, hypoteesia ei muodostettu suoraan yksittäisen tutkimuksen perusteella vaan hypoteesia voidaan perustella suoraan aktivoivien ja deaktivoivien tunnetilojen määrittelyn avulla. Luvussa 3 aktivoivat tunnetilat määriteltiin korkean vireystilan tunnetiloiksi ja vastaavasti deaktivoivat tunnetilat määriteltiin matalan vireystilan tunnetiloiksi. Tästä syystä on vaikea kuvitella, ettei aktivoivien ja deaktivoivien tunnetilojen sekä vireystilan välillä olisi yhteyttä. Edellisissä kolmessa kappaleessa esitetyt mahdolliset virhetekijät niin vireystilan arvoissa, kuin havaituissa tunnetiloissa ovat luultavasti vaikuttaneet erityisesti tähän tulokseen. Toisaalta myös mallinnusmenetelmä on voinut olla väärä. Yhteyttä erilaisten tunnetilojen ja vireystilan välillä yritettiin havaita lineaaristen mallien avulla. Lineaaristen mallien avulla ei välttämättä havaita riippuvuutta, jos aktivoivien ja deaktivoivien tunnetilojen sekä vireystilan välillä oleva riippuvuus onkin jotain muuta kuin lineaarinen.

Vaikka kaikki tuloksista eivät vaikuta kovin luotettavilta, tutkimus on täyttänyt johdannossa 1 asetetut tavoitteet saavutettu. Tulokset antavat hyvän yleiskuvan yliopistomatematiikan oppimistilanteissa esiintyvistä tunnetiloista ja vireystilasta. Kaikkea tutkimusdatasta ei kuitenkaan vielä tässä tutkimuksessa saatu irti, jolloin mahdollisuus jatkotutkimuksille jää avoimeksi.

LÄHTEET

- [1] Hirotugu Akaike. "A new look at the statistical model identification". *IEEE transactions on automatic control* 19.6 (1974), s. 716–723.
- [2] Douglas Bates et al. "Fitting Linear Mixed-Effects Models Using lme4". *Journal of Statistical Software* 67.1 (2015), s. 1–48.
- [3] Rebecca Bevans. *Understanding P-values | Definition and Examples*. 2018. URL: <https://www.scribbr.com/statistics/p-value/> (viitattu 19. 03. 2023).
- [4] Paulo Blikstein et al. "The Effect of Highly Scaffolded Versus General Instruction on Students' Exploratory Behavior and Arousal". *Technology, knowledge and learning* 22.1 (2017), s. 105–128.
- [5] Wolfram Boucsein. *Electrodermal activity: Second edition*. Springer, 2012.
- [6] Lawrence James Cookson. "Differences between feelings, emotions and desires in terms of interactive quality". *Advances in social sciences research journal* 2.7 (2015).
- [7] Noora Ellonen ja Markus Kaakinen. *Monitasomallit*. URL: <https://www.fsd.tuni.fi/fi/palvelut/menetelmaopetus/kvanti/regressio/monitasomallit/> (viitattu 27. 02. 2023).
- [8] Lara Forsblom et al. "Cognitive Appraisals, Achievement Emotions, and Students' Math Achievement: A Longitudinal Analysis". *Journal of educational psychology* 114.2 (2022), s. 346–367.
- [9] John Fox. *Applied regression analysis and generalized linear models*. SAGE, 2016.
- [10] Damodar N. Gujarati. *Linear regression : a mathematical introduction*. SAGE Publications, 2019.
- [11] Jiming Jiang. *Linear and Generalized Linear Mixed Models and Their Applications*. Springer, 2007.
- [12] *Likelihood-Ratio Tests (Probability and Mathematical Statistics)*. URL: <https://www.statisticshowto.com/likelihood-ratio-tests/> (viitattu 19. 03. 2023).
- [13] Hanna Markuksela. *Suorituskyvyn salaisuus : vireystilan säätelyn avulla huipputuloksiin*. Tammi, 2021.
- [14] *Moodmetric®– Käyttäjän opas*. Moodmetric. 2020. URL: https://moodmetric.com/wp-content/uploads/sites/22/2020/04/Moodmetric-V7AC_2-opas_1.4.pdf (viitattu 31. 03. 2023).
- [15] Alexandra C. Niculescu et al. "Feelings and performance in the first year at university: Learning-related emotions as predictors of achievement outcomes in mathematics and statistics". *Revista electrónica de investigación psicoeducativa y psicopedagógica* 13.3 (2015), s. 432–462.

- [16] Jeanne Ellis Ormrod. *Human learning*. Pearson, 2016.
- [17] Tomppa Pakarinen, Julia Pietila ja Hannu Nieminen. "Prediction of Self-Perceived Stress and Arousal Based on Electrodermal Activity". *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (2019), s. 2191–2195.
- [18] Reinhard Pekrun. "The Control-Value Theory of Achievement Emotions: Assumptions, Corollaries, and Implications for Educational Research and Practice". *Educational psychology review* 18.4 (2006), s. 315–341.
- [19] Reinhard Pekrun ja Lisa Linnenbrink-Garcia. *International Handbook of Emotions in Education*. Routledge, 2014.
- [20] Reinhart Pekrun et al. *The Control-Value Theory of Achievement Emotions: An Integrative Approach to Emotions in Education*. Teoksessa Paul A. Schutz ja Reinhard Pekrun *Emotion in education*. Amsterdam: Academic Press, 2007, s. 13–26.
- [21] Donald Pfaff. *Brain Arousal and Information Theory : Neural and Genetic Mechanisms*. Cambridge: Harvard University Press, 2009.
- [22] Héctor J. Pijera-Díaz et al. "Profiling sympathetic arousal in a physics course: how active are students?" *Journal of Computer Assisted Learning* 34.4 (2018), s. 397–408.
- [23] R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria, 2022. URL: <https://www.R-project.org/>.
- [24] Alvin C. Rencher ja G. Bruce Schaalje. *Linear models in statistics*. Wiley-Interscience, 2008.
- [25] James A. Russell. "A Circumplex Model of Affect". *Journal of Personality and Social Psychology* 39.6 (1980), s. 1161–1178.
- [26] *Suomen jääkiekkomaajoukkue*. URL: https://fi.wikipedia.org/wiki/Suomen_j%C3%A4%C3%A4kiekkomaajoukkue (viitattu 21. 04. 2023).
- [27] Henrik O. Sørli et al. "Daily autonomy and job performance: Does person-organization fit act as a key resource?" *Journal of vocational behavior* 133 (2022).
- [28] Robert E. Thayer. *The biopsychology of mood and arousal*. Oxford University Press Incorporated, 1990.
- [29] Robert E. Weiss. *Modeling Longitudinal Data*. Springer New York, 2005.
- [30] Niina Venho. *OSA 4: Moodmetric-älysoormuksen toiminta ja mittaustietojen tulkinta*. 2018. URL: https://moodmetric.com/fi/mittaus_data_opas/ (viitattu 31. 03. 2023).
- [31] Idalis Villanueva et al. "A Multimodal Exploration of Engineering Students Emotions and Electrodermal Activity in Design Activities". *Journal of engineering education* 107.3 (2018), s. 414–441.
- [32] Scott I Vrieze. "Model selection and psychological theory: A discussion of the differences between the Akaike information criterion (AIC) and the Bayesian information criterion (BIC)". *Psychological methods* 17.2 (2012), s. 228–243.

LIITE A: TULOKSET TUNNETILAKYSYMYKSISTÄ

Luvussa 6.2 esiintyvät kuvaajat ovat tehty taulukoiden A.1 ja A.2 pohjalta. Taulukoissa esiintyy kuinka monta kertaa mitäkin tunnetilaa on vastattu kuhunkin kysymykseen. Lisäksi taulukoissa on tehty jaottelu positiivisten ja negatiivisten sekä aktiivien ja deaktiivien tunnetilojen välillä.

	Opetustilanteen aikana odotan tuntevani		Oppimistilanteen jälkeen tunnen	
	Vastauksia (kpl)	Osuus kaikista (%)	Vastauksia (kpl)	Osuus kaikista (%)
Nauttiminen	97	16,61	117	20,03
Rentoutuminen	179	30,65	219	37,50
Viha	12	2,05	22	3,77
Tylsistyminen	128	21,92	61	10,45
Turhautuminen	168	28,77	165	28,25
Positiivisia tunnetiloja	276	47,26	336	57,53
Negatiivisia tunnetiloja	308	52,74	248	42,47
Aktivoivia tunnetiloja	109	18,66	139	23,80
Deaktivoivia tunnetiloja	475	81,34	445	76,20

Kuva A.1. Opiskelijoiden vastauksia tunnetilakysymyksiin

	Kun ajattelen oppimista oppimistilanteen aikana, tunnen		Kun ajattelen oppimistani oppimistilanteen jälkeen, tunnen	
	Vastauksia (kpl)	Osuus kaikista (%)	Vastauksia (kpl)	Osuus kaikista (%)
Toiveikkuus	231	39,55		
Ilo	51	8,73	71	12,16
Kiitollisuus			20	3,42
Helpotus	100	17,12	154	26,37
Häpeä			11	1,88
Viha			28	4,79
Ahdistus	137	23,46		
Toivottomuus	65	11,13		
Suru			29	4,97
Pettymys			93	15,92
Ylpeys			47	8,05
Positiivisia tunnetiloja	382	65,411	423	72,4315
Negatiivisia tunnetiloja	202	34,589	161	27,5686
Aktivoivia tunnetiloja	419	71,7466	177	30,3082
Deaktivoivia tunnetiloja	165	28,2534	407	69,6919

Kuva A.2. Opiskelijoiden vastauksia tunnetilakysymyksiin