



Rakenneyhtälömallinnuksen menetelmällisiä ja käsitteellisteoreettisia lähtökohtia käyttäytymistieteellisessä tutkimuksessa

Kiinnostus rakenneyhtälömalleja kohtaan on kasvanut käyttäytymistieteellisessä tutkimuksessa. Rakenneyhtälömalleja käyttävä tutkija voi laatia teoriaperusteisen tilastollisen mallin, joka yhdistää suorien havaintojemme ulkopuolella olevat teoreettiset käsitteet tutkijan keräämään aineistoon, ja testata, vastaako malli aineistoa. Tällaisen konfirmatorisen analyysin lisäksi aineistoa on mahdollista tutkia myös eksploratiivisesti. Tällöin tutkija voi esimerkiksi mallintaa aineiston heterogeenisyyttä etsimällä aineistossa piileviä ryhmiä. Rakenneyhtälömallinnuksen monipuolisuutta kuvaa se, että konfirmatorisia ja eksploratiivisia analyyseja voidaan tehdä muuttuja- tai henkilökeskeisesti tai niitä yhdistelemällä. Rakenneyhtälömallinnuksen yleistyksessä on kasvanut tarve ymmärtää, miten teoreettiset käsitteet yhdistetään malliin ja mitä tieteenfilosofisia oletuksia tähän sisältyy. Tämän artikkelin päätarkoituksena on esitellä käsitteellinen malli, jonka avulla käyttäytymistieteen tutkija voi tarkastella mallinnettavan teoreettisen käsitteen (ilmiön), aineiston, tilastollisen mallin ja sisältöteorian välisiä suhteita. Käsitteellisen mallin taustalla on tieteellinen realismi. Sen mukaan todellisuudessa on sekä suoraan havaittavia että mielistämme riippumattomia, suoran havainnon saavuttamattomissa olevia ilmiöitä, joita on mahdollista ja mielekäästä tutkia. Artikkelin lopuksi esittelemme, miten empiiristä tutkimusta laadittaessa tehdyt tutkimukselliset ratkaisut kytkeytyvät käsitteelliseen malliimme.

Avainsanat: rakenneyhtälömallit, tieteellinen realismi, ilmiö, aineisto, tilastollinen malli, sisältöteoria

JOHDANTO

Kiinnostus rakenneyhtälömalleja (*structural equation modeling*, SEM) kohtaan on kasvanut käyttäytymistieteellisessä tutkimuksessa (esim. Kline, 2016). Tutkimuksia, joiden tulokset perustuvat rakenneyhtälömalleihin, julkaistaan lukuisissa vaikutusvaltaisissa tiedejulkaisuissa, ja rakenneyhtälömallien keskustelufoorumilla SEMNETillä on yli 3 000 tilaajaa (Bollen & Pearl, 2013)¹. Rakenneyhtälömallien kasvava suosio perustuu paitsi niiden joustavuuteen ja monipuolisuuteen myös tietokoneiden laskentakapasiteetin nousemiseen. Nopea metodologinen ja tietotekninen kehitys

on antanut tutkijoille välineitä laatia malleja, joilla on mahdollista tutkia teoreettisesti moniulotteisia ja kiinnostavia ilmiöitä. Rakenneyhtälömalleja käyttävä tutkija voi laatia sisältöteoriaperusteisen tilastollisen mallin ja testata, vastaako malli aineistoa. Teoreettista mallia testaavan konfirmatorisen analyysin lisäksi aineistoa on mahdollista tutkia myös eksploratiivisesti. Tällöin tutkija voi esimerkiksi mallintaa aineiston heterogeenisyyttä etsimällä aineistossa piileviä latentteja ryhmiä. Rakenneyhtälömallinnuksen monipuolisuutta kuvaa se, että konfirmatorisia ja eksploratiivisia analyyseja voidaan tehdä muuttuja- tai henkilökeskeisesti tai niitä yhdistelemällä.

Rakenneyhtälömallinnuksen yleistyessä on kasvanut tarve ymmärtää, miten teoreettiset käsitteet yhdistetään malliin ja mitä tieteenfilosofisia oletuksia tähän sisältyy. Tämän artikkelin tarkoituksena on esitellä rakenneyhtälömallinnukseen liittyviä menetelmällisiä ja käsitteellisiä lähtökohtia. Esittelemme käsitteellisen mallin, jonka avulla käyttäytymistieteen tutkija voi tarkastella mallinnettavan ilmiön, aineiston, tilastollisen mallin ja sisältöteorian välisiä suhteita. Käsitteellinen malli pohjautuu realistiseen ontologiaan² ja se soveltuu käyttäytymistieteelliselle tutkimukselle tyypillisten reflektiivisten faktorien yhteyteen. Näkökulmamme painottuu ensisijaisesti kasvatuksen ja oppimiseen. Erityisenä painopisteenä ovat mittavirheettömät latentit piilomuuttujat³, jotka ovat peräisin tutkijan teoriasta, mutta joista aineistossa ei ole suoraan mitattuja havaintoarvoja (esim. Bollen & Diamantopoulos, 2017; Bollen & Pearl, 2013). Artikkelin lopuksi esittelemme, miten empiiristä tutkimusta laadittaessa tehdyt tutkimukselliset ratkaisut kytkyvät käsitteelliseen malliimme. Olemme koonneet rakenneyhtälömallinnukseen liittyvää sanastoa Liitteeseen A.


RAKENNEYHTÄLÖMALLINNUKSEN MENETELMÄLLISIÄ LÄHTÖKOHTIA

Rakenneyhtälömallinnus (*structural equation modeling*, SEM) on joukko tilastollisia aineiston analyysimenetelmiä, joiden keskeisenä tavoitteena on tutkia havaittujen ja latenttien muuttujien välisiä kausaalisia yhteyksiä. Rakenneyhtälömallit kattavat muun muassa seuraavat menetelmät: latenttien kasvukäyrien mallinnus (*latent growth curve modeling*), latenttien luokkien analyysi (*latent class analysis*), Bayes-estimointi, monitasomallinnus (*multilevel SEM models*), meta-analyysi, useiden perusjoukkojen eli populaatioiden parametrien vertailu (*multi-group SEM models*) ja eksploratiivinen rakenneyhtälömallinnus (ESEM). Tietokoneiden laskentakapasiteetin nousemisen myötä markkinoille on tullut useita rakenneyhtälömallinnukseen sopivia ohjelmistoja. Ohjelmistoja, joiden avulla haluttu malli voidaan sovittaa kerättyyn aineistoon, ovat muun muassa LISREL (Jöreskog & Sörbom, 2015), EQS (Bentler &

Wu, 2002), R ("sem" package: R Core Team, 2013; lavaan: Rosseel, 2012; blavaan: Merkle & Rosseel, 2018), AMOS (Byrne, 2010) ja Mplus (Muthén & Muthén, 1998–2017) (Tarka, 2018). Rakenneyhtälömallinnus tarjoaa tutkijalle myös mahdollisuuden perinteisen nollahypoteesin testaamisen sijaan testata sisällöllisesti kiinnostavia informatiivisia hypoteeseja (*informative hypotheses*). Tällöin tutkijalla on ennakkokäsitys parametrien arvoista ja efektien suunnista esimerkiksi siten, että molemmat muuttujat A ja B selittävät vastemuuttujaa Y siten, että A on tärkeämpi Y:n selittäjä kuin muuttuja B ($H: \beta_A > \beta_B > 0$, ks. Kluytmans, van de Schoot, Mulder & Hoijtink, 2012). Tavoitteena on testata, mikä informatiivisista hypoteeseista on paras eli toisin sanoen mitä hypoteesia aineisto tukee eniten⁴.

Hoyle (2011) kuvaa SEM-metodien kehitystä alkaen *t*-testistä, korrelaatiokertoimesta ja ristiintaulukoinnista (Kuvio 1). Kuviossa vasemmalla oleva menetelmä on sitä seuraavaa edeltänyt, rajoittuneempi menetelmä (ks. Stigler, 1986). SEM ei aina sisällä mixturemallinnusta, joten katkoviivalla kuvatut yhteydet ovat omia lisäyksiämme⁵. Matsueda (2015) sijoittaa mallintamisen historian polkuanalyysin kehitykseen. Sewal Wright julkaisi ensimmäisen polkuanalyysin vuonna 1918. Tutkimuksen kohteena oli kanien luiden koko. Faktorianalyysin kehityksen käynnistäjäksi nimetään tavallisesti Charles Spearman, jonka älykkyyttä koskeva tutkimus on vuodelta 1904. Faktorianalyysi ja polkuanalyysi yhdistettiin 1970-luvulla (K. G. Jöreskog, J. W. Keesling ja D. Wiley). Ensimmäinen julkisesti tarjolla oleva sovellus oli jo edellä mainittu LISREL (Linear Structural RELations), jonka julkaisivat Jöreskog ja Sörbom vuonna 1974. SEM-analyysit yleistyivät erityisesti 1980-luvulta alkaen (Kline, 2016). Nummenmaan, Konttisen, Kuusisen ja Leskisen (1996) katsaus kovarianssirakennemalleihin (LISREL- ja SIMPLEX-malli) ja Bymannin (2001) väitöskirja ovat suositeltavia suomalaisia esityksiä.

Rakenneyhtälömallinnuksen keskeinen idea on se, että samaan analyysiin on mahdollista yhdistää mittamalli eli jatkuva latentti muuttuja selittämässä havaittujen muuttujien eli indikaattorien (esim. kyselyn väittämien) välisiä suhteita tai kategorinen latentti muuttuja kuvaamassa



KUVIO 1. SEM-menetelmien kehityspolut Hoylea (2011) mukaillen.

useita perusjoukkoja ja rakennemalli, joka sisältää muuttujien väliset kausaaliyhteydet. Tutkija kerää aineiston, jossa olevat muuttujien väliset yhteydet muodostavat kovarianssimatriisin. Kovarianssimatriisia mallinnetaan joukolla estimoitavia parametrejä, jotka ovat perusjoukkoa kuvaavia tunnuslukuja. Jatkuvien latenttien muuttujien muuttujakeskeisen rakenneyhtälömallin yleinen muoto voidaan ilmaista tilastollisesti kolmella perusyhtälöllä (Wang & Wang, 2012, s. 7):⁶

- (1) $\eta = B\eta + \Gamma\xi + \zeta$
- (2) $Y = \Lambda y\eta + \varepsilon$
- (3) $X = \Lambda x\xi + \delta$

Ensimmäinen yhtälö kuvaa latenttien muuttujien rakennemallin. Endogeeniset (selitettävät, eeta η) ja eksogeeniset (selittävät, ksii ξ) latentit muuttujat yhdistetään toisiinsa beeta (B)- ja gamma (Γ)-regressio-kerroinmatriiseilla ja jäännösvektorilla (jäännöstermi, zeeta ζ). Yhtälössä B edustaa endogeenisten muuttujien (kausaalista) vaikutusta toisiin endogeenisiin muuttujiin ja Γ eksogeenisten muuttujien vaikutusta endogeenisiin muuttujiin. Toinen yhtälö on mittamallia

varten. Siinä havaittujen y-muuttujien ja latenttien η -muuttujien välisiä regressioita kuvataan latausmatriisin Λ (lambda) avulla. Havaittujen selitettävien y-muuttujien selittämättä jäänyttä varianssia kuvataan termillä ε (epsilon). Kolmas yhtälö on myös mittamallia varten. Siinä havaitut eksogeeniset selittävät muuttujat (x) kytketään eksogeenisiin latentteihin muuttujiin ja mittavirhettä edustaa x-muuttujien virhetermi δ (delta). Tutkija määrittelee teoreettisen mallin, jossa osa parametreista estimoidaan vapaasti ja osa kiinnitetään johonkin ennalta määrättyyn arvoon (Bollen & Pearl, 2013). Tyypillisiä ennalta määrättyjä kiinnitettyjä arvoja ovat 0 (esim. mittamallin havaittujen muuttujien mittavirheden välinen korrelaatio) ja 1 (esim. mittamallin ensimmäisen havaitun muuttujan lataus yhdelle ennalta määrättylle faktorille). Kiinnitykset ovat välttämättömiä mallin identifioituvuuden – eli sen, että kullekin estimoitavalle parametrille on löydettävissä vain yksi arvo – kannalta. Tällainen parametrin tiettyyn arvoon kiinnittäminen edellyttää vahvaa kausaali oletusta (Bollen & Pearl, 2013)⁷. Rakenneyhtälömallinnuksessa tyypillisiä ovat myös parametrin yhtäsuuruuskiinnitykset

kahden eri populaation välillä (ryhmävertailut; ks. Byrne & Stewart, 2006). Teoreettisen mallin perusteella kiinnitettyjen arvojen ja empiirisen aineiston vastaavuutta on mahdollista testata tilastollisten testien ja niin sanottujen sopivuusindeksien (*fit indices*) avulla (Hooper, Coughlan & Mullen, 2008; Kline, 2016). Tilanteessa, jossa malli sopii täydellisesti aineistoon, havaittujen muuttujien perusjoukon kovarianssimatriisi Σ on yhtenevä mallin tuottaman kovarianssimatriisin $\Sigma(\theta)$ kanssa parametrien arvoilla θ ($\Sigma = \Sigma(\theta)$). Toisin sanoen sisältöteorian perusteella laaditun estimoidun mallin sopiessa hyvin aineistoon Σ :n ja $\Sigma(\theta)$:n välinen ero on pieni, eivätkä jäännökset eroa tilastollisesti nollasta. Jos taas estimoitu malli ei sovi aineistoon, nollahypoteesi $\Sigma = \Sigma(\theta)$ hylätään ja tutkijan on etsittävä mallistaan mallin hylkäämiseen johtanut määrittelyvirhe ja määriteltävä malli uudelleen (Bollen & Pearl, 2013). Virhe voi olla myös sisältöteoriassa. Koska Σ ja $\Sigma(\theta)$ ovat tuntemattomia, käytännössä toisiinsa verrataan otoskovarianssimatriisia (S) ja mallin tuottamaa kovarianssimatriisia $\Sigma(\theta)$ (Wang & Wang, 2012).

Rakenneyhtälömallinnus vaatii riittävän suuren aineiston, jotta mallin estimointi on luotettavaa. Tyypillisesti otoskooksi suositellaan vähintään 200 tapausta, mutta tarvittava otoskoko riippuu monista eri tekijöistä. Näitä tekijöitä ovat mallin monimutkaisuus (havaittujen muuttujien tai estimoitavien parametrien määrä), muuttujien normaalijakautuneisuus ja reliabiliteetti, puuttuvan tiedon määrä sekä tutkimusasetelma (poikileikkaus, pitkittäistutkimus, ryhmävertailut) (ks. Wang & Wang, 2012, myös malliperustaiset menetelmät riittävän otoskoon arviointiin). Kyse on tilastollisesta voimasta (*power*), joka kasvaa otoskoon kasvaessa mallin ja muuttujien ominaisuuksien pysyessä muuttumattomina.

MUUTTUJA- JA HENKILÖKESKEISET ANALYYSIT SEKÄ NIIDEN YHDISTELMÄT

Muuttujakeskeiset analyysit

Muuttujakeskeisissä analyysissä, kuten konfirmatorisessa faktorianalyysissä (CFA), latentti muuttuja on mitta-asteikoltaan jatkuva muut-

tua. Tyypillisesti analyysi kohdistuu aineiston kovarianssi- ja/tai keskiarvorakenteeseen, missä keskiarvorakenteen analysoinnilla tarkoitetaan latenttien muuttujien keskiarvojen estimointia (Kline, 2016). CFA:ssa kukin havaittu muuttuja saa faktorilatauksen yhdelle teoreettisesti perustellulle latentille muuttujalle sen mukaan, kuinka paljon faktori selittää havaitun muuttujan vaihtelusta (Bollen, 2002). Ajatus on, että tutkittavat saavat latentin muuttujan jatkumolla erisuuruisia arvoja (Borsboom, 2008)⁸. Tällöin ilmiö aiheuttaa havaintoyksiköiden välistä (*between-subjects*) variaatiota⁹, jota estimoidaan latentilla muuttujalla (ks. Bollen, 1989). Jos tutkittavien älykkyyttä arvioidaan älykkyydestillä, tutkittavien testissä saamat pistemäärät ovat saman ilmiön, älykkyyden, aiheuttamia. Koska latentin ja havaittujen muuttujien välisen suhteen suunta on faktorista havaittuihin muuttujiin, havaitut muuttujat ovat latentin muuttujan reflektiivisiä indikaattoreita (Bollen, 2002), ja tällainen malli on reflektiivinen malli (Kruis & Maris, 2016)¹⁰. Esimerkiksi ilmiötä *oppilaan kouluun kiinnittymättömyys* heijastavat reflektiiviset indikaattorit, kuten apatia, passiivisuus, vastarinta ja uupumus (Skinner & Pitzer, 2012).

Kuviossa 2 on esitetty reflektiivinen faktori-malli. Kuviossa soikio edustaa latenttia muuttujaa eli faktoria (eeta η), jonka ajatellaan selittävän havaittujen indikaattorimuuttujien välisen kovarianssin siten, että faktorin selittämättä jäänyt mittavirhevarianssi on satunnaista. Tällöin latentti muuttuja selittää havaittujen muuttujien välisen kovarianssirakenteen tyhjentävästi (nk. *local independence* -oletus; ks. Vermunt & Magidson, 2004/2011), jolloin havaittujen muuttujien mittavirheet ovat keskenään korreloimattomia (Ketokivi, 2009; Kruis & Maris, 2016). Kannattaa huomata, että mittavirhevarianssien korreloimattomuus tekee faktorin ja sen indikaattorien välisestä suhteesta mielekkään. Virhevarianssien korreloimattomuus viittaa yhteiseen selittävään syyhyn (ilmiöön), jota estimoidaan latentin muuttujan eli faktorin avulla. Korreloivat mittavirheet puolestaan eivät edellytä realistiselle ontologialle tyypillistä yhteistä selittävää syytä, vaan ne osoittavat, että muuttujat ovat empiirisessä yhteydessä toisiinsa. Suorakulmaiset laatikot edustavat faktorin havaittuja indikaattoreita (y), joiden välistä


suhdetta latentti muuttuja selittää (yksisuuntaiset nuolet, latentti muuttuja eli faktori on havaittujen indikaattorien yhteinen syy). Lambdat (λ) viittaavat faktorilatauksiin ja epsilonit (ϵ) havaittujen muuttujien mittavirhevariansseihin. Virhevarianssit ovat latenteja muuttujia, koska niistä ei ole aineistossa suoraan mitattuja arvoja, vaan ne päätellään aineistosta epäsuorasti.

Muuttujakeskeiset analyysit voidaan yleistää poikkileikkausaineistoista myös pitkittäisaineistoihin. Pitkittäisaineistoa voidaan analysoida esimerkiksi kasvukäyrämallinnuksella, jossa tarkastellaan ilmiön kehittymistä ja kehityksessä olevaa yksilöllistä vaihtelua tietyn ajanjakson aikana latenttien kasvufaktoreiden (tason ja muutoksen) avulla (ks. esim. Aunola, 2005). Rakenneyhtälömallinnus tarjoaa mahdollisuuden tarkastella ilmiön mitatun rakenteen (mittamalli) tai mallinnettujen ilmiöiden välisten suhteiden (rakennemalli) samankaltaisuutta eri ryhmissä tai eri ajankohdissa. Tätä kutsutaan invarianssiksi. Pitkittäisaineistojen analysoinnissa on keskeistä selvittää, missä määrin mitattu rakenne on sama mittauskerrasta toiseen. Tarkoitus on osoittaa, että ilmiöiden väliset yhteydet eivät johdu mittauksen tuottamista eroista. Käytännössä tätä niin kutsuttua aikainvarianttisuutta arvioidaan ryh-

mävertailujen tapaan parametrien yhtäsuuruuskiinnitysten avulla, jolloin mittauskertoja käsitellään ikään kuin erillisinä ryhminä (ks. Byrne & Stewart, 2006; Wang & Wang, 2012).

Henkilökeskeiset analyysit

Henkilökeskeisillä analyyseilla (ks. Bergman & Magnusson, 1997) ei tarkastella käyttäytymistieteellisiä ilmiöitä jatkumoina. Sen sijaan, että tutkimukseen osallistuva henkilö saa jonkin arvon latentin ilmiön jatkumolla, itse ilmiö voikin olla kategorinen (Leiter & Maslach, 2016). Pienet arvot eivät tällöin heijasta tutkittavan ilmiön heikkoutta tai matalaa tasoa, vaan käsitteellisesti kokonaan eri ilmiötä (esim. Martin, 2007). Perusajatus on, että aineisto on muodostunut useista jakaumista yhden sijaan eli niin sanotuista sekoitetuista jakaumista (vrt. *mixed*, *mixture* = sekoitettu) – tästä nimitys mixturemalli ja sen suomenkielinen vastine sekajakaumamalli. Koska jakaumia on useita, on mahdollista tarkastella havaintoyksiköiden ryhmiiin kuulumisen ehdollisia todennäköisyyksiä. Jokaisen havaintoyksikön, kuten tutkimukseen osallistuneen oppilaan, sijoittuminen latenttiin ryhmään voidaan määritellä korkeimman ryh-



KUVIO 2. Reflektiivinen faktorimalli.

mään kuulumisen todennäköisyyden perusteella (Muthén & Muthén, 1998–2017).

Henkilökeskeisissä analyyseissa latentti muuttuja on kategorinen ryhmien lukumäärää kuvaava muuttuja. Yksinkertaisimmillaan ryhmien sisäinen samankaltaisuus on havaintoyksiköiden populaatioarvojen samankaltaisuutta. Esimerkiksi latentissa profiilianalyyseissa ryhmien muodostuminen perustuu ensisijaisesti tutkittavien keskiarvoprofiilien samankaltaisuuteen. Latentin kategorisen ryhmämuuttujan selittäessä havaittujen muuttujien välisiä suhteita muuttujat ovat lokaalisti riippumattomia toisistaan. Toisin sanoen kunkin ryhmän sisällä havaittujen muuttujien mittavirheet ovat korreloimattomia (Bauer & Shanahan, 2007). Henkilökeskeinen analyysitapa on kuitenkin joustava; ryhmien voi sallia poikkeavan toisistaan ilmiössä havaittavan vaihtelun määrän suhteen tai laajemminkin aineistoon sovitettavan mallin osalta. Mallinnus on luonteeltaan eksploratiivista, joskin myös konfirmatorista henkilökeskeistä mallinnusta on kehitetty (ks. Finch & Bronk, 2011).

Tyypillisesti latenttien ryhmien lukumäärää tai ryhmiin jakautumisen perusteita ei tunneta eikä päätetä ennalta (vrt. keskihajontoihin, mediaaniin tai persentileihin perustuvat katkaisurajat). Erityisen hyödyllinen henkilökeskeinen lähestymistapa on silloin, kun tarkastellaan moniulotteisia ilmiöitä, kuten oppilaan kouluun kiinnittymistä (Virtanen, Lerkkanen, Poikkeus & Kuorelahti, 2018) tai työuupumusta (Leiter & Maslach, 2016). Tällöin aineistosta löydettävät ryhmät voivat olla hyvin erilaisia tarkasteltavien ulottuvuuksien suhteen. Ja vaikka ryhmät eivät olisikaan laadullisesti erilaisia, analyysi voi paljastaa erilaisten tasoryhmien koot.

Henkilökeskeiset analyysit voidaan laajentaa pitkittäisanalyyseiksi. Yksi tällainen analyysitapa on latentti siirtymäanalyysi (*transition analysis*). Latentissa siirtymäanalyyseissa ollaan kiinnostuneita tutkimukseen osallistuneiden henkilöiden latentista statuksesta kussakin mittapisteessä ja siitä, vaihtuuko status ajan kuluessa (Kaplan, 2008). Tällöin henkilön status edellisessä mittapisteessä vaikuttaa hänen statukseensa seuraavassa mittapisteessä (Muthén, 2008). Ryhmiä, joissa ilmiössä ajan kuluessa tapahtuva muutos on erilaista, voidaan löytää toistomittausten

latenttien luokkien analyyseilla (*repeated latent class analysis*; ks. esim. Hyvönen ym., 2017).

Hybridimallit

Eleganteimmin jatkuvan latentin faktorin ja kategorisen latentin muuttujan ominaisuudet tulevat esiin latenteissa hybridimalleissa (*latent hybrid models*; Muthén, 2008), joihin viitataan usein yleisnimityksellä faktorimixturemallit (*factor mixture models*; ks. esim. Lubke & Muthén, 2007). Faktorimixturemallit yhdistävät latenttien luokkien analyysin ja faktorianalyysin, sillä aineiston rakennetta kuvataan yhtä aikaa sekä heterogeenisyyttä mallintavan latentin ryhmittelyn että ilmiötä likiarvoistavien (approksimoivien) latenttien faktorien avulla. Toisin sanoen hybridimallit sallivat sekä tutkimukseen osallistuneiden henkilöiden profiloinnin kategorisiin latentteihin ryhmiin että jatkuvien muuttujien latenttien populaatioarvojen määrittelyn henkilöille näiden ryhmien sisällä (Muthén, 2008). Oletus on, että sama faktorimalli sopii aineiston rakenteen kuvaamiseen kaikilla populaatioilla (Lubke & Muthén, 2007). Faktorimixturemallien yleistäminen pitkittäisaineistoihin tapahtuu GMM-malleilla (*growth mixture models*; ks. Muthén, 2008).

RAKENNEYHTÄLÖMALLINNUKSEN KÄSITTEELLISTEOREETTISIA LÄHTÖKOHTIA

Rakenneyhtälömallinnukseen ja tieteelliseen realismiin liittyviä keskeisiä käsitteitä

Kuten edellä olemme kuvanneet, rakenneyhtälömallissa latenteilla muuttujilla on keskeinen rooli. Latentilla muuttujalla ei ole tutkijan aineistossa suoraan mitattuja havaittuvia arvoja, vaan ilmiön, jonka likiarvo latentti muuttuja on, ajatellaan olevan yhteinen syy havaittujen arvojen välisille yhteyksille. Näin ollen ilmiöiden olemassaolo voidaan päätellä epäsuorasti havaintojemme piirissä olevien asioiden välisistä yhteyksistä (Alvesson & Sköldbäck, 2009; Borsboom, 2005). Havaitut muuttujat ja niiden väliset yhteydet ovat ikään kuin todistusaineistoa ilmiön olemassaololle. Ilmiön ja latentin muuttujan välistä suhdetta on mahdollista lähestyä tieteellisen realismin

näkökulmasta. Tieteelliseen realismiin liittyy käsitteitä, joiden voidaan ajatella muodostavan viitekehityksen rakenneyhtälömallinnukselle. Näitä käsitteitä ovat totuudenkaltaisuus, kausaliteetti, teorioiden empiirinen alimääräytyneisyys, yleistettävyyden parsimonisuus (yksinkertaisuus) ja abduktiivinen päättely. Käsitteellisteoreettinen mallimme perustuu näihin käsitteisiin.

Totuudenkaltaisuus

Realistisesti orientoitunut tutkija olettaa tutkimuksen kohteella olevan jokin todellinen ominaisuus, joka ei yleensä ole suoraan pääteltävissä aineistosta. Koska tutkijalla on käytettävissään vain havaittu aineisto, hän joutuu myöntymään ajatukseen, että tuon ominaisuuden mittaaminen on epätarkkaa. Tästä syystä realistisesti orientoitunut tieteellinen tutkimus pyrkii likiarvoistamaan (karkeistamaan) todellisuutta, toisin sanoen tiede tavoittelee totuudenkaltaisuutta (esim. Ketokivi, 2009; *truthlikeness*: Niiniluoto, 1999; *verisimilitude*: Meehl, 1990). Hyvät teoriat likiarvoistavat empiirisesti havaittavaa ja havaitsematonta todellisuutta (Niiniluoto, 1999).

Yhtenä esimerkkinä totuudenkaltaisuudesta ovat aineistosta epäsuorasti pääteltävät latentit piilomuuttujat¹¹. Tyypillisesti rakenneyhtälömallilla analysoidaan aineiston kovarianssimatriisia, joka sisältää sekä mallinnusvirhettä (*model error*) että otosvirhettä (*sampling error*). Näin ollen myös aineistosta estimoidut perusjoukkoa kuvaavat tilastolliset tunnusluvut (populaatioparametrit), kuten faktorilataukset sekä kovarianssi- ja jäänösmatriisit, sisältävät virhettä. Tässä mielessä ne toimivat tosi-ilmiöiden parhaina mahdollisina estimaatteina. Itse asiassa jo käsite 'estimointi' viittaa totuudenkaltaisuuteen, sillä sitä, mikä on varmaa, ei tarvitse estimoida eli arvioida. Toisaalta populaatioarvojen estimointi on mielekästä ainoastaan silloin, kun populaatiossa on jotakin estimoitavaa! Klassinen testiteoria ilmaisee tämän kaavalla $X = T + e$, jossa X on muuttujan havaittu arvo, T on populaatioarvo ja e ilmaisee mittavirhettä. Se, kuinka totuudenkaltaisen malli on, nähdään mallin ja totuuden vastaavuutena (MacCallum, 2003). Tieteelliselle realistille mallin epätäydellisyys ei ole ongelma, sillä hänelle riittää se, että mallit ovat vähintään teoreettisesti hyödyllisiä (Box, 1979).

Kausaliteetti

Tiukassa mielessä rakenneyhtälömallien avulla ei voida päätellä kausaalisuutta. Kyse on tutkijan asettamista kausaalioletuksista, jotka perustuvat tutkimusasetelmaan, aikaisempien tutkimusten tuloksiin, tieteelliseen tietoon, loogisiin argumentteihin, tapahtumien aikajärjestykseen ja muihin kausaalioletuksia tukeviin todisteisiin. Hyvin aineistoon sopiva sisältöteorian perusteella laadittu malli ei todista kausaalioletuksia lopullisesti oikeiksi, mutta antaa niille tukea osoittamalla, että kausaaliolemukset ovat yhdenmukaisia aineiston kanssa (Bollen & Pearl, 2013). Borsboomin (2005; myös Bollen, 2002) mukaan latentit muuttujat on mielekästä tulkitta havaittujen indikaattoriensa aikaansaajina tai aiheuttajina (muista selityksistä havaittujen seurausten välisille yhteyksille ks. Jonas & Markon, 2016; Kruis & Maris, 2016). Itse näemme, että latentit pikemminkin selittävät indikaattoreitaan kuin aiheuttavat niitä, sillä latentit muuttujat ovat tilastomatematisia entiteettejä. Ne eivät aiheuta mitään. Ajallisesti latentti muuttuja edeltää aina indikaattoreita, koska latenttia muuttujaa ei voida mitata indikaattoreillaan ilman käsitystä ilmiön luonteesta (Bollen & Diamantopoulos, 2017)¹². Tästä syystä muutokset latentin muuttujan arvoissa heijastuvat latenttia muuttujaa mittaavien havaittujen muuttujien arvoihin (Bollen & Diamantopoulos, 2017). Esimerkiksi jos interventio parantaa oppilaan kouluun kiinnittymistä, oppilaan arvosanat, joita on käytetty kiinnittymisen indikaattorina, paranevat (Bollen & Diamantopoulos, 2017; Bollen & Pearl, 2013). Kausaliteetti edellyttää synn ja seurauksen riippumattomuuden siinä mielessä, että yksiulotteisen latentin muuttujan indikaattorit ovat periaatteessa vaihdettavissa. Toisin sanoen samaa latenttia muuttujaa voidaan mitata usealla toisistaan poikkeavalla sarjalla teoreettisesti relevantteja indikaattoreita (Bollen & Lennox, 1991).

Möttus (2016) korostaa, että ilmiön (persoonallisuuspiirteen) yhteys vastemuuttujaan, jota ilmiö selittää, on kausaalinen ainoastaan tilanteissa, joissa kyseisen ilmiön mahdolliset alulottuvuudet ovat samansuuruisessa yhteydessä vastemuuttujaan kuin itse ilmiö. Lisäksi yhteyden pitää olla samansuuruinen riippumatta valituista teoreettisesti relevanteista alulottuvuuksista.

sien indikaattoreista. Tällaisessa tilanteessa on mielekästä olettaa, että vaihtelu sekä indikaattoreissa että vastemuuttujassa on tietyn näistä riippumattoman ilmiön aiheuttamaa. Oppimisen tutkimukseen liitettynä tämä tarkoittaa sitä, että esimerkiksi kouluun kiinnittymisen latentin muuttujan korrelaatio koulumenestyksen kanssa pitää olla suurin piirtein samaa kokoluokkaa kuin kiinnittymisen alaulottuvuuksien (tunneperäinen, toiminnallinen ja kognitiivinen) korrelaatiot koulumenestyksen kanssa riippumatta alaulottuvuuksia mittaavista indikaattoreista.

Kausaliteetti käsitetään muuttujakeskeisissä ja henkilökeskeisissä analyyseissä eri tavoin. Muuttujakeskeisissä menetelmissä latentti muuttuja selittää muuttujien välisen kovarianssirakenteen ryhmätasolla, jolloin kausaliteetti ilmenee yksilöiden välisissä eroissa. Henkilökeskeisissä lähestymistavoissa ajatellaan, että ilmiössä esiintyvää vaihtelua selitetään populaatiossa olevien sisäisesti samankaltaisten, mutta toisiinsa nähden heterogeenisten ryhmien avulla. Varianssi ilmenee niinä todennäköisyyksinä, joilla kukin havaintoyksikkö kuuluu latentteihin ryhmiin. Koska yksittäiset havainnot latenteissa ryhmissä ovat keskenään homogeenisia, kausaliteetti mixtureympäristössä on yksilötason kausaliteettia. Tällä on merkitystä muun muassa interventioiden laatimisen ja yksilön kehityksen tutkimuksen näkökulmista. Koska yksilöt ryhmän sisällä ovat samankaltaisia, heille voidaan tarjota sama tuki tai interventio. Kausaalisuhteiden osoittaminen henkilökeskeisillä menetelmillä voi auttaa resurssien suuntaamisessa. Muuttujakeskeiset menetelmät tuottavat keskimääräistä informaatiota, johon perustuvat interventiot saattavat olla tehottomia, koska ne eivät kohdennu yksittäisten henkilöiden tarpeisiin. Esimerkiksi regressiosuoran ylä- tai alapuolella olevat havainnot näyttävät muuttujakeskeisen mallin selittämättömänä jäännöksenä, vaikka todellisuudessa ne voivat muodostaa merkityksellisen latentin ryhmän, jolle interventiot nimenomaan tulisi kohdentaa (ks. myös Leiter & Maslach, 2016).

Teorioiden empiirinen alimääräytyneisyys

Teorioiden empiirinen alimääräytyneisyys viittaa tilanteeseen, jossa havaittu evidenssi tukee useita kilpailevia teorioita. Tämä on ominaista raken-

neyhtälömalleille, koska mallinnus perustuu tyypillisesti kovarianssimatriisiin. Kovarianssimatriisi voi antaa tukea useille aineistoon yhtä hyvin sopiville (data-ekvivalenteille) vaihtoehtoisille malleille (MacCallum, Wegener, Uchino & Fabrigar, 1993). Useat prosessit voivat tuottaa mallin mukaisen kovarianssirakenteen (Ben-Menahem, 2006; Borsboom, 2005). Tämän vuoksi aineistoon huonosti sopiva sisältöteoriaan perustuva rakenneyhtälömalli informoi tutkijaa tarpeesta määrittellä malli uudelleen, mutta aineistoon hyvin sopiva malli ei todista, että malli vastaa todellisuutta (Bollen, 1989). Rakenneyhtälömallinnus onkin pikemmin malleja hylkäävä (*disconfirmatory*) kuin vahvistava menetelmä (Kline, 2016). Voidaan sanoa, että teorioiden empiirinen alimääräytyneisyys on tyypillinen piirre käyttäytymistieteellisille teorioille, koska käyttäytymistieteellisten teorioiden verifioiminen tai falsifioiminen on erittäin vaikea tehtävä. Tilaa jää monille taustaoletuksille, koska mikään yksittäinen teoria ei selitä selvästi muita teorioita paremmin aineistossa havaittavaa vaihtelua. Pahimmillaan tieteellinen tieto ei kumuloidu ja alkuinnostuksen jälkeen teoria saatetaan unohtaa tieteilijöiden menettäessä kiinnostuksensa siihen (Meehl, 1978). Jos aineisto tukee useita erilaisia selitysmalleja, metodologista kriteeriä parhaan selityksen valinnalle ei ole olemassa. Tulosten teoreettinen tulkittavuus onkin ensiarvoisen tärkeää (Töttö, 2004). Malli tulee myös toistaa useissa toisistaan riippumattomissa aineistoissa, ja se tulee altistaa muiden tutkijoiden vaihtoehtoisille malleille (Bollen & Pearl, 2013). Vaihtoehtoisten mallien käsittelemättä jättäminen lisää niin kutsuttua vahvistus-harhaa (*confirmation bias*): tutkijat kiinnittävät huomionsa yhteen malliin, jonka tueksi haetaan todistusaineistoa ja jota tästä syystä aletaan pitää totuudenmukaisimpana mallina (Kline, 2016).

Yleistettävyyys

Koska kvantitatiivisen tutkimuksen tavoitteena on saada totuudenkaltaista tietoa populaatiosta eli perusjoukosta, tutkimustulosten yleistettävyyks otoksesta perusjoukkoon on kriittinen kysymys. Yleistettävyyteen liittyvää epävarmuutta voidaan hallita, mutta sen kokonaan poistamiseksi tarvittaisiin otantaperustaisen tutkimuksen sijasta kokonaistutkimus. Tällöin voitaisiin tutkia kaikki

perusjoukon havaintoyksiköt eivätkä tutkimustulokset perustuisi enää todennäköisyyksiin. Tutkimustuloksiin liittyvää epävarmuutta voidaan pienentää keräämällä hyvä aineisto. Useimmat tilastolliset mallit edellyttävät havaintoyksiköiden riippumattomuuden. Käyttäytymistieteellisessä tutkimuksessa tämä ei ole useinkaan tilanne, sillä havainnot (esim. oppilaat) ovat tyypillisesti ryvästyneet jonkin ylemmän tason yksikön suhteen (koulun, luokan). Ryvästeisyyden vuoksi oppilaat ovat "altistuneet" samoille opettajille, vertaisille, koulun ilmapiirille ja niin edelleen, jolloin oppilasta A koskevat tutkimustulokset informoivat myös oppilasta B koskevia tutkimustuloksia. Rakenneyhtälömallinnuksessa aineiston ryvästeisyys voidaan huomioida monitasomalleilla (ks. esim. Heck & Thomas, 2009).

Yleistettävyyttä liittyy perusjoukkojen lukumäärään. Jos oletetaan, että perusjoukkoja on yksi, kaikki tutkittavat henkilöt sijoittuvat samalle jakaumalle tarkasteltavan ilmiön suhteen. Tämä on riski tutkimustulosten yleistämisen kannalta tilanteissa, joissa perusjoukkoja onkin useampia kuin yksi. Näissä tilanteissa henkilökeskeiset menetelmät tuottavat täsmällisempiä tutkimustuloksia, sillä niiden avulla voidaan mallintaa aineistosta useita sisäisesti samankaltaisia ja toisistaan poikkeavia perusjoukkoja.

Parsimonisuus

Parsimonisuudella eli yksinkertaisuudella viitataan *simplicity is the sign of truth* -periaatteeseen. Ajatellaan tilanne, jossa tutkija estimoi n -määrän parametreja. Kun n on suuri, jäljelle jäävien vapausasteiden (*degrees of freedom*, df^3) määrä on pieni ja malli on vähemmän parsimoninen eli monimutkaisempi. Jos taas n on pieni, vapausasteiden määrä on suuri eli malli on parsimonisempi, yksinkertaisempi ja rajoitetumpi. Popperin (1992) mukaan parsimonisia malleja on helpompi testata ja falsifoida (eli kumota), koska ne ovat yleispätevämpiä kuin monimutkaiset mallit¹⁴. Informatiivisuudessaan ja yleispätevyydessään niillä on monimutkaisempia malleja useampia mahdollisuuksia poiketa aineistosta (ks. myös MacCallum, Browne & Cai, 2006). Parsimoniset mallit, joita ei ole kyetty kumoamaan, ovat siten suositeltavia malleja. Tavoitteena on valita aineistoa riittävän hyvin kuvaavista malleista yksinkertaisin ja sa-

malla teoreettisesti perusteltavissa oleva malli. Tähän sisältyy myös sisältötulkinta: mitä yksinkertaisempi malli on, sitä todennäköisemmin se sopii kuvaamaan myös muita aineistoja ja auttaa selittämään ilmiöiden välisiä suhteita (Popper, 1992). Tutkimustulosten yleistettävyyttä useaan aineistoon eli toistettavuus kertoo tulosten reliabiliteetista eli luotettavuudesta. Mitä useammin malli toistaa tulokset, sitä luotettavampana sekä mallia että tuloksia voidaan pitää.

Mallin parsimonisuutta arvioidaan rakenneyhtälömallissa tilastollisesti muun muassa RMSEA-approksimointivirheindeksillä. RMSEA (Root Mean Square Error of Approximation) sisältää sakkofunktion (χ^2 -arvon suhde vapausasteiden lukumäärään), joka suosii yksinkertaisia malleja monimutkaisten sijaan¹⁵. Mixturemallien yhteydessä parsimonisuusperiaatteella voidaan viitata siihen, että malli, jossa on vähemmän latentteja ryhmiä, on suositeltavampi kuin malli, jossa ryhmiä on enemmän.

Abduktiivinen päättely

Abduktiivinen päättely on tyypillinen päättelytapa tieteellisessä realismissa (Haig & Evers, 2016). Abduktiivinen päättely on päättelyä parhaaseen mahdolliseen tutkimushavaintojen selitykseen; se on päättelyä havaitun evidenssin ja sitä selittävän teorian tai hypoteesin välisestä suhteesta. Abduktiivisen päättelyn suunta on havaitusta havaitsemattomaan (Walton, 2013). Kouluympäristössä opettaja voisi käyttää abduktiivista päättelyä tilanteessa, jossa oppilaat ovat haluttomia työskentelemään oppitunnilla. Havaitusta evidenssistä (oppilaiden haluttomuus työskennellä) opettaja voi ikään kuin päätellä taaksepäin hyvän selityksen oppilaiden työskentelyhaluttomuudelle. Tällainen työskentelyhaluttomuutta selittävä ilmiö voi olla esimerkiksi luokan oppilaiden kouluun kiinnittymättömyys. Kriittinen kysymys on, millä kriteereillä paras mahdollinen selitys valitaan (Haig & Evers, 2016). On ilmeistä, että empiirisen evidenssin ja teorian välistä yhteyttä ei voida arvioida empiirisin perustein. Ratkaisuksi parhaan mahdollisen selityksen valinnalle on esitetty muun muassa seuraavia super-empiirisiä kriteerejä: johdonmukaisuus, yksinkertaisuus ja selitysvaiva (Churchland, 1985). Kilpailevista selityksistä tai teorioista tulee valita sellainen, a)

jonka osat eivät ole keskenään ristiriitaisia, b) jos-
sa ei ole teorian pelastamista varten laadittuja *ad hoc*-
väitteitä ja c) joka kykenee selittämään mah-
dollisimman vähillä väitteillä mahdollisimman
monia ilmiöitä (ks. parsimonisuus).


Käsitteellinen malli

Kuviossa 3 esittelemme käsitteellisen mallin ra-
kenneyhtälömallinnuksen ymmärtämiseksi käyt-
tätymistieteellisessä tutkimuksessa. Näkökul-
mana on tieteellinen realismi. Käsitteellinen mal-
limme koostuu neljästä osasta: ilmiö, aineisto, ti-
lastollinen malli ja sisältäteoria.

Ilmiö

Ilmiö on mielistämme riippumaton ontologinen
entiteetti, jonka vaikutukset ilmenevät säännölli-
sesti havaittavina tapahtumina tai asioina todel-
lisuudessa. Ilmiö ei ole mieleemme luomus. Ilmiö
”sijaitsee” perusjoukossa, joten se on löydettävissä
kaikista perusjoukosta satunnaisesti valituista

otoksista. Ilmiössä ei ole mittavirhettä. Tyypilli-
sesti ilmiö eristetään aineistosta tilastollisin tut-
kimusmenetelmin, kuten eksploraatiivisen faktori-
analyysin avulla (Haig & Evers, 2016). Tilastol-
listen tutkimusmenetelmien näkökulmasta ilmiö
on paitsi tilastomatemaaattinen myös sisällöllistä
harkintaa edellyttävä entiteetti. Sisällöllinen
harkinta vaikuttaa siihen, mitä aineistosta etsi-
tään ja mitä mittareita käytetään. Nämä valinnat
ovat luonteeltaan subjektiivisia. Olennaista on,
että ilmiö on kausaalisuhteessa aineistoon. Tässä
mielessä ilmiö tuottaa aineiston sisällön. Ilmiö ei
ole kuitenkaan ekvivalentti aineiston kanssa, sillä
aineistossa on mittavirhettä (MacCallum, 2003).
Suomalaisessa käyttäytymistieteellisessä tutki-
muksessa on tarkasteltu rakenneyhtälömallin-
nuksen keinoin muun muassa seuraavia ilmiöitä:
minäpystyvyys (Malinen & Savolainen, 2016),
koulu-uupumus (Salmela-Aro, Muotka, Alho,
Hakkarainen & Lonka, 2016) ja kouluun kiinnit-
tyminen (Virtanen, Kiuru, Lerkkanen, Poikkeus
& Kuorelahti, 2016).



KUVIO 3. Rakenneyhtälömallinnus käyttäytymistieteellisessä tutkimuksessa: ilmiön, aineiston, tilastollisen mallin ja sisältäteorian väliset suhteet.

Aineisto

Jos havaitusta aineistosta on löydettävissä ilmiö, aineisto on sellainen kuin se on siksi, että ilmiö on ontologisessa mielessä olemassa tutkijasta riippumattomassa todellisuudessa ja aineisto on ilmiön kausaalisesti tuottama. Kausaalisuhde edellyttää sen, että syy ja sen seuraus ovat erotettavissa toisistaan; esimerkiksi latentti muuttuja (syy) tulisi voida tunnistaa erillisenä indikaattoreistaan (seuraus). Aineiston ja ilmiön välinen suhde on kuitenkin vastavuoroinen, sillä aineistosta päätellään ilmiö abduktiivisen päättelyn avulla (katkonuoli Kuviossa 3). Tässä on ilmiselvää ristiriitaa, sillä ilmiö yhtäältä tuottaa aineiston, mutta toisaalta ilmiö päätellään aineiston perusteella. Lisäksi aineiston syntyyn vaikuttavat teoreettiset oletukset ja niiden perusteella aineiston keräämiseen valitut mittarit. Tutkimusaineisto on siten tutkijan mielestä riippumattoman todellisuuden ja tutkijan teoreettisten oletusten vuorovaikutuksen tulos.

Tilastollinen malli

Tilastollinen malli kuvaa ja tiivistää aineiston mahdollisimman parsimonisesti ja totuudenkaltaisesti. Toisaalta malli voidaan spesifioida ainoastaan aineiston määrittämissä rajoissa; mallintamisen on tapahduttava niiden muuttujien avulla, joita aineistossa on. Mallin ei ole tarkoitus kuvata aineistoa täydellisesti ($df > 0$), koska silloin malli olisi otos-spesifi ja sen yleistäminen muihin otoksiin vaarantuisi. Perusajatushan on esitimoida perusjoukon parametrejä otoksen tunnuslukujen avulla. Lisäksi täydellinen (saturoitu, $df = 0$) malli ei olisi kovinkaan hyödyllinen (Box, 1979), sillä se sisältäisi paljon estimoitua parametrejä ja olisi siksi sangen monimutkainen. Rakenneyhtälömallilla ja teorialla on vastavuoroinen suhde. Teoria perustelee mallin valinnan, ja mallin avulla testataan teoriaa. Tyypillisesti mallia testataan eli validoidaan uuteen aineistoon. Tällöin mallia käytetään ennustamaan uutta, mallin luomiseen käytetystä aineistosta riippumatonta aineistoa.

Teoria

Teorian rooli on keskeinen realistisesti orientoituneessa tutkimusperinteessä. Viime kädessä teorian perusteella siirrytään aineiston kuvaamisesta

mallin avulla perusjoukossa esiintyvän ilmiön kuvaamiseen (Töttö, 2004). Tilastollisten perusteiden lisäksi mallin ja aineiston yhteensovituksen arviointiin tarvitaan aina sisältöteoriaa (Nylund, Asparouhov & Muthén, 2007). Toisin sanoen teorian avulla havaitulle evidenssille annetaan todellisuutta kuvaava teoreettinen selitys (vrt. abduktiivinen päättely). Teoria on yksinkertaistettu kuva siitä ilmiön rakenteesta tai niistä ilmiöiden välisistä yhteyksistä, joita arvelemme todellisuudessa esiintyvän. Teoriasta johdetaan tutkimuskysymykset, joihin tutkija haluaa tutkimuksellaan vastata, sekä mahdolliset *a priori* hypoteesit, jotka määrittelevät, mitkä parametrit kiinnitetään tiettyyn arvoon ja mitkä estimoidaan. Hypoteesien pitävyyttä kerätyssä aineistossa testataan laaditun tilastollisen mallin avulla. Mallin testaaminen on täten hypoteettis-deduktiivinen prosessi (Tarka, 2018). Mikäli mallin avulla kytetään osoittamaan teorian implikoimat havaitut vaikutukset, kuten kausaalioletukset (Bollen & Pearl, 2013), teoria, jonka pohjalta tilastollinen malli on laadittu, on kestänyt falsifioimisyrityksen (Popper, 1992). Se saa siten tuekseen yhden lisänäytön pätevyystään. Malli ilman teoriaa on ainoastaan tapa tiivistää empiirinen aineisto.

Seuraavassa luvussa esittelemämme empiirinen esimerkki sisältää sekä muuttuja- että henkilökeskeistä analyysia. Latenttien muuttujien luonnetta ja kausaaliteettia on pohdittu kattavasti edellä, joten tässä vedetään yhteen muita käsitteellisiä ja menetelmällisiä seikkoja, jotka liittyvät erityisesti henkilökeskeisiin analyysimenetelmiin. Mixturemallinnuksella voidaan selvittää, onko aineisto muodostunut havaintoyksiköistä, jotka kuuluvat useisiin erillisiin populaatioihin. Mixturemallinnuksen yksi keskeisimmistä päätöksistä koskee latenttien ryhmien määrää (Nylund ym., 2007). Aineiston koko ja keskenään kilpailevien tilastollisten mallien (eri määrä ryhmiä) tunnusluvut luovat puitteet tälle päätökselle, jossa sisältöteorialla on vahva rooli. Mallin parsimonisuudella ja ryhmäratkaisun toistettavuudella on paljon merkitystä tulosten pätevyuden ja yleistettävyyden kannalta. Karkeasti ottaen mitä suurempi aineisto on, sitä useampi latentti ryhmä siitä on tilastollisesti eroteltavissa. Tämä asettaa tutkijalle erilaisia haasteita erikokoisten aineistojen kanssa: pienestä aineistosta voi olla tilastollisesti vaikea

erotella luotettavasti erilaisia alaryhmiä, vaikka ne olisivat todellisuudessa olemassa. Toisaalta suuren aineiston kohdalla on suuri riski yliarvioida latenttien ryhmien määrä. Kuten edellä on todettu, ryhmien teoreettisen ja käytännöllisen mielekkyyden arviointi tulee apuun tässä (esim. ryhmien eroavuus mallinnettavan ilmiön suhteen ja ryhmäkokojen merkitys käytännön työssä). Parsimonisuusperiaatteen mukaisesti vähemmän latentteja ryhmiä sisältävä malli on suositeltavampi kuin enemmän ryhmiä sisältävä. Näin malli pysyy myös todennäköisemmin yleistettävänä sen sijaan, että se kuvaa yhtä otosta. Latenttien ryhmien lukumäärän määrittäminen on erityisen haastavaa tilanteessa, jossa sopivuusindeksit eivät yksiselitteisesti osoita, mikä estimoiduista malleista vastaa aineistoa parhaiten. Mallin valintaan on kehitetty uusia ristiinvalidointitekniikoita, joiden tarkoituksena on helpottaa oikean mallin valintaa ja parantaa mallin yleistettävyyttä aineistosta, jonka perusteella malli luotiin, toisiin aineistoihin (ks. Grimm, Mazza & Davoudzadeh, 2017). Tällaisen yhden tutkimuksen sisäisen toistettavuuden lisäksi mallia tulee testata uusissa aineistoissa. Ryhmäratkaisun toistettavuus on erityisen tärkeää silloin, kun se perustuu pieneen otokseen tai kun mixturemallinnuksen tuloksia käytetään interventioiden suunnittelemiseen ja kohdentamiseen.

Kouluun kuulumisen kehityskulkujen mallintamisen metodologiaa

Havainnollistamme rakenneyhtälömallinnuksen käsitteelliseen malliin liittyvää ajattelua empiirisen esimerkin avulla. Kaksi tämän artikkelin kirjoittajista tarkasteli tutkimuksessaan kahta ilmiötä: oppilaiden kouluun kuulumista ja käytöshäiriöitä. Tutkimustehtävä oli analysoida oppilaiden kouluun kuulumisen (hyväksytyksi, arvostetuksi ja tuetuksi tulemisen kokemukset koulussa yhtenä tunneperäisen kouluun kiinnittymisen alaulottuvuutena) kehityskulkuja ja kehityskulkujen yhteyttä oppilaiden käytöshäiriöihin yläkoulun alussa (Virtanen, Malinen & Haverinen, 2016). Kouluun kuulumisen aineistomme koostui oppilaiden itsearvioinneista Suomessa validoidun kouluun kiinnittymisen mittarin osioihin (Virtanen, Kiuru ym., 2016).

Käytöshäiriötä koskeva aineisto kerättiin laajasti käytetyllä Strengths and Difficulties -mittarin (Youthinmind Ltd, 2014) käytöshäiriöitä mittaavalla asteikolla. Kouluun kiinnittymisen teorian (ks. Fredricks, Blumenfeld & Paris, 2004), sosiaalisen kontrollin teorian (Hirschi, 1969) ja partisipaatio-identifikaatio-mallin (Finn, 1989) perusteella oletimme kouluun kuulumisen ja käytöshäiriöiden ilmiöiden olevan olemassa tarkasteltavassa perusjoukossa (suomenkieliset yläkoulun alkuvaiheen opiskelijat) ja myös jonkinlaisessa suhteessa toisiinsa. Teoreettiset käsityksemme mielistämme riippumattoman todellisuuden luonteesta vaikuttivat siihen, että päädyimme keräämään aineistoa kouluun kuulumisesta ja käytöshäiriöistä ja edelleen etsimään näitä ilmiöitä ja niiden välisiä suhteita aineistosta. Toisin sanoen, vaikka ilmiö tuottaa aineiston, teoria vaikuttaa siihen, mistä asioista ylipäättään keräämme aineistoa ja millä mittareilla. Aineisto kerättiin viisi kertaa samoilta oppilailta seitsemännen luokan alusta kahdeksannen luokan alkuun ulottuvana ajanjaksona.


Tutkimuksessa päähuomion kohteena oli kouluun kuulumisen kokemusten kehittyminen ajan kuluessa ja yksilöiden välinen vaihtelu kouluun kuulumisen tasossa ja muutoksessa. Tutkimuskysymykset olivat: a) Kuinka monia ja millaisia kouluun kuulumisen kehityskulkuja on tunnistettavissa peruskoulun seitsemännen luokan alusta kahdeksannen luokan alkuun ulottuvasta oppilasaineistosta? b) Millaisia yhteyksiä kehityskuluilla on oppilaiden käytösoireisiin seitsemännen luokan alku- ja loppuvaiheissa, kun sukupuolen ja perheen sosioekonomisen taustan vaikutus on kontrolloitu? Sosiaalisen kontrollin teorian (Hirschi, 1969) ja partisipaatio-identifikaatio-mallin (Finn, 1989) pohjalta esitimme hypoteesiksi, että oppilaan kouluun kuulumisen kokemusten vaihtelu on yhteydessä oppilaan käytöshäiriöiden vaihteluun siten, että myönteiset kehityskulut liittyvät vähäiseen häiriökäyttäytymiseen ja kielteiset kehityskulut runsaaseen häiriökäyttäytymiseen. Lisäksi hypotetisoimme, että oppilaan kouluun kuulumisen kehityskuluissa on vaihtelua, minkä vuoksi aineistosta löytyy enemmän kuin yksi kouluun kuulumisen kehityskulku.

Sisältöteorioiden ja tutkimustehtävämme perusteella valitsimme tilastolliseksi malliksi

muuttujakeskeisen analyysin latentin kasvukäyrämallin (Kuvio 4), jota testasimme aineistollamme (komentojono Mplus-ohjelmistolle on esitetty Liitteessä B). Aikaisemman tutkimuksen perusteella oli mielekästä kysyä aineistolta, muodostavatko kaikki oppilaat yhden perusjoukon kouluun kuulumisen suhteen vai onko perusjoukkoja useampia joko kuulumisen tason tai erilaisten kehityskulkujen johdosta. Näin ollen täydensimme latenttia kasvukäyrämallia henkilökeskeisellä latentilla ryhmittelyllä. Tähän pitkittäisaineistomme oli riittävän iso ($n_{T1} = 450$, $n_{T2} = 443$, $n_{T3} = 411$, $n_{T4} = 375$ ja $n_{T5} = 296$) niin, että siitä oli mahdollista tunnistaa useita perusjoukkoja edustavia latentteja ryhmiä luotettavammin kuin pienestä joukosta. Myös kouluun kuulumisen ryhmien ja käytöshäiriöiden suhdetta analysoitaessa aineisto asetti reunaehtoja analyysitavan valinnalle: muuttujien vinous ja

latenttien ryhmien koot johtivat epäparametrisen testin valintaan. Parsimonisuuden vuoksi mallissa mitattiin kouluun kuulumista havaitulla keskiarvomuuttujalla latentteja muuttujia sisältävän mittamallin sijaan. Mallin estimoinnissa käytettiin Mplus-ohjelmistoa (versio 7.3; Muthén & Muthén, 1998–2012). Analyysitavan valinnasta ja kilpailevien mallien vertailusta voi lukea tarkemmin alkuperäisestä empiirisestä artikkelista sekä sen liitemateriaalista (Virtanen, Malinen & Haverinen, 2016).

Kehityksen muotoa mallinnettiin muutamalla erilaisella tavalla. Lopulta parhaiten ja parsimonisimmin aineiston kuvasi ja tiivistä paraabelimuotoinen (kvadraattinen) kehityksen kuvaus, jota täydensi kahden latentin ryhmän ratkaisu. Toinen ryhmistä (94 % oppilaista) raportoi tasaisen korkeaa kouluun kuulumista ja toinen (6 % oppilaista) nopeasti heikkenevää kouluun kuu-



KUVIO 4. Kouluun kuulumisen latenttien kasvukäyrien mixturemalli (Virtanen, Malinen & Haverinen, 2016 mukailen).

lumisen kokemusten tasoa. Erillisellä muuttujakeskeisellä analyysillä latenttien luokkien välisistä keskiarvoeroista saatoimme havaita, että nopeasti heikkenevän kouluun kuulumisen ryhmän oppilaat raportoivat enemmän käytöshäiriöitä kuin tasaisen korkean kouluun kuulumisen ryhmän oppilaat¹⁶. Näin ollen tutkimuksen tilastollisen mallin tuottamat tulokset tukivat sisältöteoriaa, jonka pohjalta malli alun perin laadittiin: kouluun kuulumisen kehityskuluissa oli vaihtelua ja myönteiset kehityskulut liittyivät vähäiseen häiriökäyttäytymiseen, kun taas kielteiset kehityskulut liittyivät runsaaseen häiriökäyttäytymiseen. Malli antoi myös uutta tietoa ilmiöstä. Joillakin oppilailla kouluun kuulumisen kokemukset alkativat heiketä nopeasti yläkoulun alettua, mutta nousivat jonkin verran kahdeksannen luokan alussa. Ontologisessa mielessä tulokset tukevat ajatusta siitä, että mielistämme riippumattomassa todellisuudessa on kouluun kuulumisen ja käytöshäiriöiden ilmiöt, jotka olivat kausaalisia syitä niille kyselylomakkeen arvoille, joita oppilaat tutkimuksessa kyselylomakkeeseen raportoivat. Mallin sopivuusindekseistä saatoimme päätellä, että vaikka malli sopi aineistoon hyvin, osa aineiston sisältämästä vaihtelusta jäi selittämättä. Selittämättä jäänyt vaihtelu (jäännösvarianssi) informoi mallin totuudenkaltaisuudesta (Kotkivi, 2009; Meehl, 1990; Niiniluoto, 1999). Tieteellisen realismin näkökulmasta totuudenkaltaisuus ei ole ongelma, sillä parhaimmillaan malli voi kuitenkin olla hyödyllinen (Box, 1979). Tässä kuvatus tutkimuksen lopuksi tekijät pohtivatkin tulosten pedagogisia seurauksia.

Tilastollisessa tutkimuksessa on syytä arvioida myös tulosten yleistettävyyttä ja vähintäänkin tiedostaa jokaisen tieteellisen teorian alimääräytyneisyys. Empiirisen esimerkin tutkimukssamme aineisto ei ollut täysin satunnaisesti valittu ja tutkimusaineistoa kerättyäessä myöhemmissä mittapisteissä tapahtui oppilaskatoa, joka ei ollut täysin satunnaista. Tulosten yleistämiseen populaatioon on siis suhtauduttava varauksin. Tämä on sangen yleinen piirre käyttäytymistieteellisessä tutkimuksessa, jossa otokset ovat usein harkinnanvaraisia (*convenience sample*). Tällöin tutkittavat eivät ole satunnaisesti valittuja, mikä saattaa vähentää aineiston varianssia ja vääristää muuttujien keskivirheitä ja tilastollista merkitsevyyttä.

Teorian alimääräytyneisyys aineiston perusteella viittaa tutkittavan ilmiön ja aineiston välisen suhteen epäsuoruuteen. Tällöin on mahdollista ajatella, että abduktiivisen päättelyn perusteella tehty johtopäätös latentin ilmiön ja havaitun aineiston välisestä kausaaliyhteydestä voitaisiinkin selittää jonkin muun teoreettisen käsitteen kuin kouluun kuulumisen avulla.

Vaihtoehtoisia käsityksiä ilmiöistä ja niiden välisistä suhteista

Tässä artikkelissa esitelty käsitteellinen malli perustuu tieteelliseen realismiin, jonka lähtökohtana on se, että käyttäytymistieteiden piirissä tutkittavat teoreettiset ilmiöt ovat olemassa mielistämme riippumatta. Ilmiöitä voidaan lähestyä myös muista käsitteellisteoreettisista ja mallintamiseen liittyvistä lähtökohdista. Friedin (2017) mukaan ilmiö voi olla tieteellistä realismia mukaillen paitsi luonnollinen (*natural kind*) myös sosiaalinen (*social kind*), käytännöllinen (*practical kind*) tai kompleksinen (*complex kind*) entiteetti. Sosiaalisena entiteettinä ilmiö on sosiaalinen konstruktio, mikä viittaa konstruktivistiseen ontologiaan, kun taas käytännöllisenä entiteettinä se on ennen kaikkea hyödyllinen fiktio (instrumentalismi, pragmatismi). Olennaista on, että sosiaalisena ja käytännöllisenä entiteettinä ilmiö on kielellinen rakenne, jolla ei ole mielistämme ja mittauksistamme riippumatonta vastinetta todellisuudessa. Ilmiötä kuvaava latentti muuttuja voidaan mieltää yksinkertaisesti analyttisenä työkaluna, joka helpottaa analyyseja vähentämällä muuttujien lukumäärää (Borsboom ym., 2003).

Kompleksisena entiteettinä ilmiö ei välttämättä edellytä latenttia muuttujaa lainkaan, vaan havaittu tapahtuma A aiheuttaa havaitun tapahtuman B todennäköisyyden kasvun (esim. oppitunneilta pinnaaminen kasvattaa heikkojen arvosanojen saamisen todennäköisyyttä). Tällaisissa verkostomalleissa (*network models*) havaittujen indikaattorien (pinnaaminen, heikot arvosanat) liittyminen toisiinsa nähdään systeemisena interaktioiden – kausaalisena tai ei-kausalisena – kokonaisuutena, jossa indikaattorien välitä yhteyttä ei välttämättä aiheuta yhteinen syytekijä, kuten kouluun kiinnittymättömyys (van Bork, van Borkulo, Waldorp, Cramer & Bors-

boom, 2018; Borsboom & Cramer, 2013). Verkostomallien puitteissa on mahdollista tunnistaa muuttujien verkostosta keskeisin muuttuja, joka on suurin riskitekijä esimerkiksi häiriön syntymiselle (ks. van Bork ym., 2018) tai tekijä, joka on yhteydessä useaan muuhun työntekijän ammatilliseen kasvuun liittyvään muuttujaan (Nokelainen, Silander, Ruohotie & Tirri, 2007). Kouluun kiinnittymättömyyden tutkimuksessa kiinnittymättömyyden indikaattoreista a) heikko suoriutuminen standardoiduissa testeissä, b) koulupoissaoloa vähintään 20 prosenttia koulupäivistä kuluvaan kouluvuonna, c) heikko menestys vähintään yhdessä välineaineessa, kuten matematiikka ja äidinkieli, d) vähintään yksi koulusta erottaminen ja e) vuosiluokan kertaaminen (Henry, Knight & Thornberry, 2012) koulupoissaolot saattaisi olla vahvassa yhteydessä useisiin muihin muuttujiin. Tällöin koulupudokkuuden ehkäisemiseen tähtäävissä interventioissa pääpaino voidaan kohdistaa koulupoissaolojen ehkäisemiseen.

Verkostomalleja on mahdollista yleistää myös latentteihin muuttujiin (*latent network models*, LNM) ja indikaattorien jäännöksiin (*residual network models*, RNM) (Epskamp, Rhemtulla & Borsboom, 2017). Tällöin LNM mahdollistaa aineiston latentin verkostorakenteen eksploratiivisen analyysin ja samalla mittavirheen kontrolloinnin. RNM puolestaan mahdollistaa latenttien mallien ja verkostomallien hybridit: mahdollisimman parsimonisen verkostorakenteen eksploratiivinen analyysi voidaan tehdä ilman oletusta indikaattorien lokaalista riippumattomuudesta. Samalla voidaan huomioida se, että osa indikaattorien välisistä interaktioista voi olla yhteisen syytekijän aiheuttamia. LNM on ratkaisu myös useiden data-ekvivalenttien vaihtoehtoisten mallien (MacCallum ym., 1993) ongelmaan, koska tiettyjen muuttujien otoskovarianssimatriisi tuottaa ainoastaan yhden latentin verkostomallin (Epskamp ym., 2017). Sekä LNM että RNM ovat käyttökelpoisia myös konfirmatorisessa analyysissä. Toistaiseksi verkostomalleja on käytetty pääasiassa psykiatristen häiriöiden tutkimuksessa (van Bork ym., 2018), mutta niiden voidaan olettaa yleistävän myös oppimisen ja kasvatuksen tutkimuksen piirissä. Tiedossamme ei ole verkostomallien käsitteellis-ontologista tarkastelua, mutta verkostomallit tuntuvat ontologisesti luontevasti

integroivan empirismin ja realismin. Empirismin näkökulmasta havaittujen muuttujien interaktiot voidaan nähdä humelaisittain kausaliteettina, jota luonnehtii asioiden säännöllinen samanaikainen esiintyminen (ks. Raatikainen, 2004). Latentit muuttujat verkostomalleissa tuntuvat puolestaan viittaavaan tieteelliseen realismiin ja sen edellyttämään mielistämme riippumattoman maailman olemassaoloon.

On kiinnostavaa, että erot ilmiöiden mitaamisessa saattavat olla ainakin osittain eroja filosofis-teoreettisissa selityksissä sille, miksi havaitut muuttujat ovat yhteydessä toisiinsa. Kruis ja Maris (2016) vertasivat kolmenlaisten tyypillisten tilastollisten mallien lähtökohtien teoreettisia ja matemaattisia perusteita. Lähtökohdat olivat: yhteinen syy (*common cause framework*), vastavuoroiset vaikutukset (*reciprocal affect framework*) ja yhteinen vaikutus (*common effect framework*). Näistä lähtökohdista yhteinen syy on käsitteellisen mallimme taustalla. Ajatus on, että havaittujen reflektiivisten indikaattorien välisen yhteyden aiheuttaa yhteinen syy, ilmiö. Jos mallinnuksen lähtökohtana on vastavuoroiset vaikutukset, yhteistä syytä havaittujen yhteyksien taustalle ei oleteta, vaan muuttujien väliset yhteydet ovat seurausta niiden vastavuoroisista vaikutuksista toisiinsa. Tällaiset mallit ovat verkostomalleja (Epskamp ym., 2017). Yhteinen vaikutus -lähtökohta perustuu ajatukseen siitä, että toisistaan riippumattomien muuttujien yhteinen tila aiheuttaa ilmiön olemassaolon tai sen, että sitä ei ole. Erotuksena formatiiviselle mittaukselle, jossa riippumattomat muuttujat voivat korreloida keskenään, yhteinen vaikutus edellyttää riippumattomien muuttujien korreloimattomuuden ehdolla yhteinen vaikutus, jonka ne kausaalisesti aiheuttavat. Kruis ja Maris (2016) osoittivat, että edellä mainitut kolme tilastollisten mallien lähtökohtaa ovat matemaattisesti toisistaan erottamattomia. Ne selittävät havaittujen muuttujien väliset yhteydet matemaattisesti yhteneväisesti, mutta teoreettisesti eri tavalla. Näin ollen kyseessä on matemaattisesti yksi ja sama malli, jonka erilaiset filosofis-teoreettiset selitykset johtuvat tieteenalojen välisistä eroista antaa teoreettinen selitys muuttujien välisille yhteyksille.

LOPUKSI

Tässä artikkelissa esittelimme käsitteellisen mallin, jonka tarkoituksena on auttaa käyttäytymistieteiden parissa työskenteleviä tutkijoita ymmärtämään rakenneyhtälömallinnusta tieteellisen realismin viitekehyksessä. Käsitteellinen mallimme perustuu neljään osatekijään: mallinnettavaan ilmiöön, tutkijan keräämään aineistoon, tilastolliseen malliin ja sisältöteoriaan. Johtoajatuksenamme oli todellisuuden jakautuminen mielestämme riippumattomaan todellisuuteen ja todellisuuteen, jossa tutkijan subjektiivisilla valinnoilla on vaikutusta tutkimuksen suorittamiseen ja siten

tutkimustuloksiin. Tavoitteenamme on auttaa käyttäytymistieteiden tutkijoita asemoimaan rakenneyhtälömallinnus laajempaan käsitteelliseen kokonaisuuteen.

Artikkeli on saatu toimitukseen 27.2.2018 ja hyväksytty julkaistavaksi 19.9.2018.

Kiitokset

Kiitämme FT Eija Räikköstä, KM Jukka Utraiasta ja KT Olli-Pekka Malista käsikirjoitukseen liittyvistä huomioista.

LIITE A. Rakenneyhtälömallinnuksen sanastoa suomeksi.

Englanniksi	Suomeksi	Selitys
Structural equation modeling	Rakenneyhtälömallinnus	Tilastollisten analyysitekniikoiden joukko
Variable-centered methods	Muuttujakeskeiset menetelmät	Muuttujien välisiä yhteyksiä analysoivat menetelmät (kuten konfirmatorinen faktorianalyysi, polkuanalyysi)
Person-centered methods	Henkilökeskeiset menetelmät	Tiettyjen ominaisuuksien tai muuttujien välisten yhteyksien perusteella tutkimukseen osallistuvia henkilöitä ryhmittelevät menetelmät (kuten latenttien luokkien analyysi)
Mixture models	Sekajakaumamallit	Mallit, jotka kohdistuvat populaatiossa oleviin alaryhmiin
Latent growth (curve) models	Kasvukäyrämallit	Tutkimukseen osallistuvien henkilöiden välisiä eroja yksilöllisessä muutoksessa tarkastelevat toistomittausmallit
Multilevel modeling	Monitasomallit	Ryvästyneiden aineistojen analysointiin tarkoitetut mallit
Multigroup modeling	Ryhmävertailut	Mallinnus, joka kohdistuu esimerkiksi parametrin yhtäsuuruuden testaamiseen useassa havaitussa tai latentissa ryhmässä
Fit indices	Sopivuusindeksit	Ryhmä indeksejä, joiden perusteella voidaan arvioida malliin määritettyjen parametrien kiinnitysten ja kerätyn aineiston välistä vastaavuutta (usein mallin tuottaman ja havaitun varianssi-kovarianssimatriisin samankaltaisuutta)
Local independence	Lokaali riippumattomuus	Esimerkiksi tilanne, jossa havaitut muuttujat ovat keskenään korreloimattomia mitatessaan samaa faktoria

LIITE B. Artikkelissa käytetyn empiirisen esimerkkimallin estimoinnissa käytetty komentojono Mplus-ohjelmistolle.

TITLE: Kouluun kuulumisen LGMM-malli

DATA:

FILE IS Oppilaat_T1-T5.dat;

VARIABLE:

NAMES ARE id_opp okS11 okS12 okS13 okS14 okS15 okS16 okS17 okS18 okS19
okS110 okS111 okS112 okS113 okS114 okS115 okS21 okS22 okS23 okS24 okS25
okS26 okS27 okS28 okS29 okS210 okS211 okS212 okS213 okS214 okS215 okS31
okS32 okS33 okS34 okS35 okS36 okS37 okS38 okS39 okS310 okS311 okS312
okS313 okS314 okS315 okS41 okS42 okS43 okS44 okS45 okS46 okS47 okS48
okS49 okS410 okS411 okS412 okS413 okS414 okS415 okS51 okS52 okS53 okS54
okS55 okS56 okS57 okS58 okS59 okS510 okS511 okS512 okS513 okS514 okS515;

MISSING ARE ALL (-999);

USEVARIABLES ARE BELONG1 BELONG2 BELONG3 BELONG4 BELONG5;

CLASSES C(2);

DEFINE:

BELONG1 = MEAN(okS11 okS12 okS13 okS15 okS16 okS19 okS110 okS111 okS113);
BELONG2 = MEAN(okS21 okS22 okS23 okS25 okS26 okS29 okS210 okS211 okS213);
BELONG3 = MEAN(okS31 okS32 okS33 okS35 okS36 okS39 okS310 okS311 okS313);
BELONG4 = MEAN(okS41 okS42 okS43 okS45 okS46 okS49 okS410 okS411 okS413);
BELONG5 = MEAN(okS51 okS52 okS53 okS55 okS56 okS59 okS510 okS511 okS513);

ANALYSIS:

TYPE = MIXTURE;
ESTIMATOR IS MLR;
ITERATIONS = 1000;
CONVERGENCE = 0.00005;

STARTS = 5000 500;
STITERATIONS = 250;
LRTSTARTS = 5000 500 5000 500;

MODEL:

%OVERALL%

i s q | BELONG1@0 BELONG2@2 BELONG3@4 BELONG4@7 BELONG5@12.5;
!kasvukäyrämallin määrittely koko aineistossa

I S Q; !kasvukäyrän latenttien komponenttien varianssit estimoidaan

%C#1% !mallin määrittely latentissa ryhmässä nro 1

i (1);

s (2);

q (3);

!kasvukäyrän taso-, lineaarinen muutos- ja kvadraattinen muutos
-komponenttien

!varianssit on kiinnitetty yhtä suuriksi latenteissa ryhmissä 1 ja 2

%C#2% !mallin määrittely latentissa ryhmässä nro 2

i (1);

s (2);

q (3);

OUTPUT: SAMPSTAT STDYX MOD(8) TECH1 TECH4 TECH10 TECH11 TECH14;

Viitteet

- ¹The Structural Equation Modeling Discussion Network internetissä: <http://www2004.lsoft.se/scripts/wl.exe?SL1=SEMNET&H=LISTSERV.UA.EDU>.
- ²Tieteellinen realismi sisältää useita tieto- ja yhteiskunta-teoreettisia suuntauksia. Käytämme tässä artikkelissa käsitettä 'tieteellinen realismi' erotuksena esimerkiksi Roy Baskharin kriittisestä realismista. Edustamamme tieteenfilosofinen näkemys vastaa lähinnä niin kutsuttua malttilista realismia (ks. Raatikainen, 2004).
- ³Läpi tämän artikkelin käsitteellä latentti muuttuja (faktori) tarkoitamme psykometristä käsitettä (*psychometric construction*). Sen sijaan latentti piirre (*latent trait*; esimerkiksi oppilaan kouluun kiinnittyminen) on tutkimuksen kohteena oleva ilmiö. Havaitut muuttujat eli indikaattorit mittaavat latenttia muuttujaa eli faktoria, joka puolestaan on ilmiön indikaattori (Zumbo & Rupp, 2004). Toisin kuin ilmiöllä, psykometrisellä käsitteellä ei ole kausaalisuhdetta havaittuihin tapahtumiin ja asioihin. Faktorit ovat tilastomatemattisia entiteettejä. Faktorin indikaattoriluonne – toisin sanoen se, että se on estimaatti tai likiarvo havaintojemme ulkopuolella olevasta ilmiöstä – mahdollistaa kuitenkin johtopäätösten tekemisen tutkimuksen kohteena olevasta kiinnostavasta ilmiöstä.
- ⁴Siinä missä frekventistisessä nollahypoteesin testaamisessa arvioidaan aineiston todennäköisyyttä tilanteessa, jossa nollahypoteesi oletetaan todeksi $P(D | H_0)$, informatiivisia hypoteeseja testaava bayesilainen estimointi arvioi sitä, kuinka paljon aineisto tukee kutakin informatiivista hypoteesia $P(H | D)$ (Kluytmans ym., 2012; van de Schoot, Hoijtink & Jan-Willem, 2011). Tarkemmin kritiikistä nollahypoteesin testaamista kohtaan katso Gigerenzer (2000) ja Gigerenzer, Krauss ja Vitouch (2004). On myös syytä korostaa, että SEM ylipäättään edustaa muutosta perinteisestä yksittäisten parametrien tilastollisen merkitsevyyden testaamisesta kohti koko mallin aineistoon sopivuuden testaamista (Kline, 2016).
- ⁵Emme käytä tässä 'mixture model' -termistä käännöstä sekajakaumamallinnus, vaan pitäydymme teknisessä ilmauksessa 'mixture model' (esim. faktorimixturemalli).
- ⁶Yhtälössä (1) B on $M \times M$ regressiokerroinmatriisi endogeenisille ja Γ eksogeenisille latenteille muuttujille (M = latenttien muuttujien lukumäärä). Yhtälössä (2) $\Lambda\eta$ on $P \times M$ latausmatriisi endogeenisille muuttujille, ja yhtälössä (3) $\Lambda\xi$ on $P \times M$ latausmatriisi eksogeenisille muuttujille (P = havaittujen muuttujien lukumäärä).
- ⁷Esimerkki heikosta kausaaliotuksesta on yksisuuntainen nuoli kahden muuttujan välillä. Tällöin tutkijan ainoa oletus on, että parametrin arvo poikkeaa nollasta (Bollen & Pearl, 2013).
- ⁸Kannattaa huomata, että tutkittavat voivat saada toisistaan poikkeavia latentin muuttujan arvoja ainoastaan, jos voidaan olettaa, että jokaisella tutkittavalla on olemassa tositarvo, jota voidaan estimoida. Tämä oletus jo sinänsä vaatii mielistämme riippumattoman todellisuuden olemassaolon ja siten realistisen ontologian (Borsboom, 2005).
- ⁹Toistomittausten tapaustutkimuksilla on mahdollista tutkia intraindividuaalista (*within-subjects*) kausaliteettia.
- ¹⁰Formatiivisissa malleissa kausaalis-formatiiviset indikaattorit vaikuttavat latenttiin muuttujaan (ks. Bollen & Diamantopoulos, 2017). Formatiiviset mallit ovat yhdenmukaisia konstruktivistisen, operationalistisen tai instrumentalistisen ontologian kanssa; ne eivät ole itseenäisiä mittauksesta riippumattomia kausaalisia faktoreita, jotka selittävät havaittuja indikaattoreita (Borsboom ym., 2003; formatiivisten mallien kritiikistä, ks. Edwards, 2011). Kaikki tutkijat (Bollen & Diamantopoulos, 2017) eivät jaa Borsboomin ja kollegoiden (2003) näkemystä siitä, ettei formatiivista mittausta – eikä täten mitattavaa käsitettä – voi irrottaa valituista indikaattoreista.
- ¹¹On myös puolustettu näkemystä, jonka mukaan ontologista eroa havaittujen ja latenttien (ei-havaittujen piilomuuttujien) muuttujien välillä ei ole olemassa. Tämän näkemyksen mukaan havaitut muuttujat ovat latentteja muuttujia, jotka on mitattu täydellisen reliabelisti. Tällöin mitattavan todellisuuden ilmiön ja aineiston välinen kausaalisuhde on deterministinen ja mittavirheetön sen sijaan, että se olisi probabilistinen ja sisältäisi selittämättä jäänyttä varianssia (Borsboom, 2008).
- ¹²Bollenin ja Diamantopoulosin (2017) mukaan tämä pätee myös kausaalis-formatiivisiin indikaattoreihin.
- ¹³ df = vapausaste: tilastollisessa mallissa ennalta määräämättömästi toisistaan riippumatta vaihtelevien parametrien lukumäärä.
- ¹⁴Popper oli teoriarealisti, sillä mallin falsifoinnin mahdollisuus implikoi tosiamallin olemassaolon (Borsboom, 2005).
- ¹⁵RMSEA liittyy myös totuudenkaltaisuuden käsitteeseen, sillä toisin kuin pelkkä χ^2 -arvo, RMSEA testaa mallin likimääräistä soveltuvuutta (*close fit*) aineistoon.
- ¹⁶Kannattaa huomioida, että ryhmien keskiarvoja on mielekasta vertailla ainoastaan tilanteessa, jossa ryhmät ovat vertailtavan ilmiön suhteen skalaari-invariantteja (ks. Steinmetz, 2013).

Lähteet

- Alvesson, M. & Skoldberg, K. (2009). *Reflexive methodology: New vistas for qualitative research* (2. painos). Los Angeles, CA: Sage.
- Aunola, K. (2005). Latentin kasvukäyräanalyysin avulla muutoksen mallintamisesta kehityksellisten ilmiöiden parempaan ymmärtämiseen. *Psykologia*, 40(5–6), 502–514.
- Bauer, D. J. & Shanahan, M. J. (2007). Modeling complex interactions: Person-centered and variable-centered approaches. Teoksessa T. D. Little, J. A. Bovaird & N. A. Card (toim.), *Modeling contextual effects in longitudinal studies* (s. 255–283). Mahwah, NJ: Lawrence Erlbaum Associates.
- Ben-Menahem, Y. (2006). *Conventionalism*. Cambridge: Cambridge University Press.
- Bentler, P. M. & Wu, E. J. C. (2002). EQS 6 for Windows user's guide. Multivariate Software, Inc.
- Bergman, L. R. & Magnusson, D. (1997). A person-oriented approach in research on developmental psychopathology. *Development and Psychopathology*, 9(2), 291–319.
- Bollen, K. A. (1989). *Structural equations with latent variables*. New York: Wiley.
- Bollen, K. A. (2002). Latent variables in psychology and the social sciences. *Annual Review of Psychology*, 53(1), 605–634.
- Bollen, K. A. & Diamantopoulos, A. (2017). In defense of causal-formative indicators: A minority report. *Psychological Methods*, 22(3), 581–596.
- Bollen, K. & Lennox, R. (1991). Conventional wisdom on measurement: A structural equation perspective. *Psychological Bulletin*, 110(2), 305–314.
- Bollen, K. A. & Pearl, J. (2013). Eight myths about causality and structural equation models. Teoksessa S. L. Morgan (toim.), *Handbook of causal analysis for social research* (s. 301–328). New York: Springer.
- van Bork, R., van Borkulo, C. D. (jaettu pääkirjoittajuus), Waldorp, L. J., Cramer, A. O. J. & Borsboom, D. (2018). Network models for clinical psychology. Teoksessa J. T. Wixted & E.-J. Wagenmakers (toim.), *Stevens' handbook of experimental psychology and cognitive neuroscience* (s. 693–728). Wiley. doi:10.1002/9781119170174.epcn518.
- Borsboom, D. (2005). *Measuring the mind: Conceptual issues in contemporary psychometrics*. Cambridge: Cambridge University Press.
- Borsboom, D. (2008). Latent variable theory. *Measurement: Interdisciplinary Research and Perspectives*, 6(1–2), 25–53.
- Borsboom, D. & Cramer, A. O. (2013). Network analysis: An integrative approach to the structure of psychopathology. *Annual Review of Clinical Psychology*, 9, 91–121.
- Borsboom, D., Mellenbergh, G. J. & van Heerden, J. (2003). The theoretical status of latent variables. *Psychological Review*, 110(2), 203–219.
- Box, G. E. P. (1979). Robustness in the strategy of scientific model building. Teoksessa R. L. Launer & G. N. Wilkinson (toim.), *Robustness in statistics: Proceedings of a workshop (on robustness in statistics) held at Army research office, Weiss building, (North Carolina), April 11–12, 1978* (s. 201–236). New York: Academic Press.
- Byman, R. (2001). *Curiosity and exploration: A conceptual overview and structural modeling*. Kasvatustieteen tutkimuksia 5. Turku: Suomen kasvatustieteellinen seura.
- Byrne, B. M. (2010). *Structural equation modeling with AMOS. Basic concepts, applications, and performing*. New York: Routledge.
- Byrne, B. M. & Stewart, S. M. (2006). Teacher's corner: The MACS approach to testing for multigroup invariance of a second-order structure: A walk through the process. *Structural Equation Modeling: A Multidisciplinary Journal*, 13(2), 287–321.
- Churchland, P. (1985). The ontological status of observables: In praise of the superempirical virtues. Teoksessa P. Churchland & C. Hooker (toim.), *Images of science: Essays on realism and empiricism* (s. 35–47). Chicago: University of Chicago Press.
- Edwards, J. R. (2011). The fallacy of formative measurement. *Organizational Research Methods: ORM*, 14(2), 370–388.
- Epskamp, S., Rhemtulla, M. & Borsboom, D. (2017). Generalized network psychometrics: Combining network and latent variable models. *Psychometrika*, 82(4), 904–927.
- Finch, W. H. & Bronk, K. C. (2011). Conducting confirmatory latent class analysis using Mplus. *Structural Equation Modeling*, 18(1), 132–151.
- Finn, J. D. (1989). Withdrawing from school. *Review of Educational Research*, 59(2), 117–142.
- Fredricks, J. A., Blumenfeld, P. C. & Paris, A. H. (2004). School engagement: Potential of the concept, state of the evidence. *Review of Educational Research*, 74(1), 59–109.
- Fried, E. I. (2017). What are psychological constructs? On the nature and statistical modelling of emotions, intelligence, personality traits and mental disorders. *Health Psychology Review*, 11(2), 130–134.

- Gigerenzer, G. (2000). *Adaptive thinking: Rationality in the real world*. Oxford: Oxford University Press.
- Gigerenzer, G., Krauss, S. & Vitouch, O. (2004). The null ritual: What you always wanted to know about significance testing but were afraid to ask. Teoksessa D. Kaplan (toim.), *The SAGE handbook of quantitative methodology for the social sciences* (s. 391–408). Thousand Oaks, CA: Sage.
- Grimm, K. J., Mazza, G. L. & Davoudzadeh, P. (2017). Model selection in finite mixture models: A *k*-fold cross-validation approach. *Structural Equation Modeling: A Multidisciplinary Journal*, 24(2), 246–256.
- Haig, B. D. & Evers, C. W. (2016). *Realist inquiry in social science*. London: Sage.
- Heck, R. H. & Thomas, S. L. (2009). *An introduction to multilevel modeling techniques* (2. painos). New York, NY: Routledge.
- Henry, K. L., Knight, K. E. & Thornberry, T. P. (2012). School disengagement as a predictor of dropout, delinquency, and problem substance use during adolescence and early adulthood. *Journal of Youth and Adolescence*, 41(2), 156–166.
- Hirschi, T. (1969). *Causes of delinquency*. Berkeley: University of California.
- Hooper, D., Coughlan, J. & Mullen, M. (2008). Structural equation modelling: Guidelines for determining model fit. *Electronic Journal of Business Research Methods*, 6(1), 53–60.
- Hoyle, R. H. (2011). *Structural equation modeling for social and personality psychology*. London: Sage. doi:10.4135/9781446287965.
- Hyvönen, K., Räikkönen, E., Feldt, T., Mauno, S., Dragano, N. & Matthewman, L. (2017). Long-term reward patterns contribute to personal goals at work among Finnish managers. *Journal of Career Development*, 44, 394–408.
- Jonas, K. G. & Markon, K. E. (2016). A descriptivist approach to trait conceptualization and inference. *Psychological Review*, 123(1), 90–96.
- Jöreskog, K. G. & Sörbom, D. (2015). *LISREL 9.20 for Windows* [Computer software]. Skokie, IL: Scientific Software International, Inc.
- Kaplan, D. (2008). An overview of Markov chain methods for the study of stage-sequential developmental processes. *Developmental Psychology*, 44(2), 457–467.
- Ketokivi, M. (2009). *Tilastollinen päättely ja tieteellinen argumentointi*. Helsinki: Gaudeamus.
- Kline, R. B. (2016). *Principles and practice of structural equation modeling* (4. painos). New York: Guilford Press.
- kluytmans, A., van de Schoot, R., Mulder, J. & Hoijtink, H. (2012). Illustrating Bayesian evaluation of informative hypotheses for regression models. *Frontiers in Psychology*, 3(2), 1–11.
- Kruis, J. & Maris, G. (2016). Three representations of the Ising model. *Scientific Reports*, 6, 34175.
- Leiter, M. P. & Maslach, C. (2016). Latent burnout profiles: A new approach to understanding the burnout experience. *Burnout Research*, 3(4), 89–100.
- Lubke, G. & Muthén, B. O. (2007). Performance of factor mixture models as a function of model size, covariate effects, and class-specific parameters. *Structural Equation Modeling: A Multidisciplinary Journal*, 14(1), 26–47.
- MacCallum, R. C. (2003). 2001 presidential address: Working with imperfect models. *Multivariate Behavioral Research*, 38(1), 113–139.
- MacCallum, R. C., Browne, M. W. & Cai, L. (2006). Testing differences between nested covariance structure models: Power analysis and null hypotheses. *Psychological Methods*, 11(1), 19–35.
- MacCallum, R. C., Wegener, D. T., Uchino, B. N. & Fabrigar, L. R. (1993). The problem of equivalent models in applications of covariance structure analysis. *Psychological Bulletin*, 114(1), 185–199.
- Malinen, O.-P. & Savolainen, H. (2016). The effect of perceived school climate and teacher efficacy in behavior management on job satisfaction and burnout: A longitudinal study. *Teaching and Teacher Education*, 60, 144–152.
- Martin, A. J. (2007). Examining a multidimensional model of student motivation and engagement using a construct validation approach. *British Journal of Educational Psychology*, 77(2), 413–440.
- Matsueda, R. L. (2015). Key advances in the history of structural equation modeling. Teoksessa R. H. Hoyle (toim.), *Handbook of structural equation modeling* (s. 17–42). New York: The Guilford Press.
- Meehl, P. E. (1978). Theoretical risks and tabular asterisks: Sir Karl, Sir Ronald, and the slow progress of soft psychology. *Journal of Consulting and Clinical Psychology*, 46(4), 806–834.
- Meehl, P. E. (1990). Appraising and amending theories: The strategy of Lakatosian defense and two principles that warrant it. *Psychological Inquiry*, 1, 108–141.
- Merkle, E. C. & Rosseel, Y. (2018). blavaan: Bayesian structural equation models via parameter expansion. *Journal of Statistical Software*, 85(4), 1–30. Haettu osoitteesta <http://www.jstatsoft.org/v85/i04/>.
- Muthén, B. (2008). Latent variable hybrids: Overview of old and new models. Teoksessa G. R. Hancock & K. M. Sam-

- uelsen (toim.), *Advances in latent variable mixture models* (s. 1–24). Charlotte, NC: Information Age Publishing.
- Muthén, L. K. & Muthén, B. O. (1998–2012). *Mplus user's guide* (7. painos). Los Angeles, CA: Muthén & Muthén.
- Muthén, L. K. & Muthén, B. O. (1998–2017). *Mplus user's guide* (8. painos). Los Angeles, CA: Muthén & Muthén.
- Möttus, R. (2016). Towards more rigorous personality trait–outcome research. *European Journal of Personality*, 30, 292–303.
- Niiniluoto, I. (1999). *Critical scientific realism*. Oxford: Oxford University Press.
- Nokelainen, P., Silander, T., Ruohotie, P. & Tirri, H. (2007). Investigating the number of non-linear and multi-modal relationships between observed variables measuring a growth-oriented atmosphere. *Quality & Quantity*, 41(6), 869–890.
- Nummenmaa, T., Konttinen, R., Kuusinen J. & Leskinen, E. (1996). Tutkimusaineiston analyysi. Helsinki: WSOY.
- Nylund, K. L., Asparouhov, T. & Muthén, B. O. (2007). Deciding on the number of classes in latent class analysis and growth mixture modeling: A Monte Carlo simulation study. *Structural Equation Modeling*, 14(4), 535–569.
- Popper, K. (1992). *The logic of scientific discovery* (2. painos). London: Routledge.
- R Core Team (2013). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Haettu osoitteesta <http://www.r-project.org/>.
- Raatikainen, P. (2004). *Ihmistieteet ja filosofia*. Helsinki: Gaudeamus.
- Rosseel, Y. (2012). lavaan: An R package for structural equation modeling. *Journal of Statistical Software*, 48(2), 1–36.
- Salmela-Aro, K., Muotka, J., Alho, K., Hakkarainen, K. & Lonka, K. (2016). School burnout and engagement profiles among digital natives in Finland: A person-oriented approach. *European Journal of Developmental Psychology*, 13(6), 704–718.
- van de Schoot, R., Hoijtink, H. & Jan-Willem, R. (2011). Moving beyond traditional null hypothesis testing: Evaluating expectations directly. *Frontiers in Psychology*, 24(2), 1–5.
- Skinner, E. A. & Pitzer, J. R. (2012). Developmental dynamics of student engagement, coping, and everyday resilience. Teoksessa S. L. Christenson, A. L. Reschly & C. Wylie (toim.), *Handbook of research on student engagement* (s. 21–44). New York: Springer.
- Steinmetz, H. (2013). Analyzing observed composite differences across groups: Is partial measurement invariance enough? *Methodology*, 9(1), 1–12.
- Stigler, S. M. (1986). *The history of statistics. The measurement of uncertainty before 1900*. Cambridge, MA: Harvard University Press.
- Tarka, P. (2018). An overview of structural equation modeling: Its beginnings, historical development, usefulness and controversies in the social sciences. (Report). *Quality and Quantity*, 52(1), 313–354.
- Töttö, P. (2004). *Syvällistä ja pinnallista: teoria, empiria ja kausaalisuus sosiaalitutkimuksessa*. Tampere: Vastapaino.
- Vermunt, J. K. & Magidson, J. (2004/2011). Local independence. Teoksessa M. S. Lewis-Beck, A. Bryman & T. Futing Liao (toim.), *The SAGE encyclopedia of social science research methods*. Thousand Oaks, CA: Sage Publications Ltd. doi:10.4135/9781412950589.n505.
- Virtanen, T., Kiuru, N., Lerkkanen, M.-K., Poikkeus, A.-M. & Kuorelahti, M. (2016). Assessment of student engagement among junior high school students and associations with self-esteem, burnout, and academic achievement. *Journal for Educational Research Online*, 8(2), 136–157.
- Virtanen, T., Lerkkanen, M.-K., Poikkeus, A.-M. & Kuorelahti, M. (2018). Student engagement and school burnout in Finnish lower-secondary schools: Latent profile analysis. *Scandinavian Journal of Educational Research*, 62(4), 519–537.
- Virtanen, T., Malinen, O.-P. & Haverinen, K. (2016). Yläkouluoppilaiden kouluun kuulumisen kehityskulut 7. luokan alusta 8. luokan alkuun: kehityskulkujen yhteys oppilaiden käytösoireisiin. *Oppimisen ja oppimisvaikeuksien erityislehti NMI-Bulletin*, 26(2), 56–74.
- Walton, D. (2013). *Abductive reasoning*. Tuscaloosa, AL: University of Alabama Press.
- Youthinmind Ltd (2014). SDQ: Information for researchers and professionals about the Strengths & Difficulties Questionnaires, Finnish. Haettu 21.6.2018 osoitteesta <http://www.sdqinfo.org/py/sdqinfo/b3.py?language=Finnish>.
- Wang, J. & Wang, X. (2012). *Structural equation modeling: Applications using Mplus*. New York: John Wiley.
- Zumbo, B. D. & Rupp, A. A. (2004). Responsible modeling of measurement data for appropriate inferences: Important advances in reliability and validity theory. Teoksessa D. Kaplan (toim.), *The SAGE handbook of quantitative methodology for the social sciences* (s. 73–92). Thousand Oaks, CA: Sage.