



Ryhmittelyanalyysi uskonnontutkijan työkaluna

Teemu Pauha
Helsingin yliopisto

Johdanto¹

Ryhmittely- eli klusterianalyysi (*cluster analysis*) on verrattain vähän tunnettu tilastollinen analyysimenetelmä, jota ei esitellä edes kaikissa tilastotieteen perusteiden oppikirjoissa. Se on kuitenkin huomattavan monipuolinen työkalu, joka soveltuu monien uskontotieteilijöitäkin kiinnostavien kysymysten selvittelyyn.

Kuten menetelmän nimestä voi päätellä, ryhmittelyanalyysin avulla pyritään tunnistamaan käytetystä aineistosta alaryhmiä, joiden jäsenet muistuttavat tiettyjen ominaisuuksien osalta toisiaan ja samalla eroavat muiden ryhmien jäsenistä (Toivonen 1999, 341). Ryhmiteltävät asiat voivat olla melkein mitä tahansa: ihmisiä, seurakuntia, valtioita ja niin edelleen. Yleinen edellytys on kuitenkin se, että ryhmittelyn perusteena käytetyt ominaisuudet ovat määrällisiä eli niitä voidaan mitata numeroin.

Käsittelen tässä katsauksessa kahta yleisintä ryhmittelyanalyysin muotoa: hierarkkista klusterianalyysia (*hierarchical cluster analysis*) ja K-means-klusterianalyysia (*K-means cluster analysis*). Esittelen lyhyesti menetelmien yleiset periaatteet ja niiden käyttöön liittyvät rajoitukset. Lisäksi pohdin mahdollisuuksia yhdistää ryhmittelyanalyysia laadullisiin menetelmiin ja annan esimerkin omasta tutkimuksestani, jossa on tehty näin.

Muuttujakeskeisyys vs. henkilökeskeisyys

Tilastollinen tutkimus on perinteisesti keskittynyt kartoittamaan kahden tai useamman muuttujan välisiä yhteyksiä aineistossa. Esimerkiksi regressioanalyysin tarkoituksena on selvittää, riippuvatko yhden muuttujan arvot toisesta muuttujasta (eli ennustaako esimerkiksi uskonnollisuus suvaitsemattomia asenteita seksuaalivähemmistöjä kohtaan). Tällaisen tutkimuksen ongelmana on kuitenkin niin sanottu homogeenisyysoletus (*homogeneity assumption*): lähtökohdiana on, että muuttujien välinen yhteys on samanlainen koko aineistossa (Bravo, Pearson & Stevens 2016, 167). Tyypillinen oletus on esimerkiksi, että uskonnollisuus vaikuttaa yhtenäisellä tavalla ihmisten asenteisiin seksuaalivähemmistöjä kohtaan. Jos siis henkilö tiedetään uskonnolliseksi, voidaan jo sen perusteella tehdä joitain päätelmiä siitä, kuinka hän todennäköisesti suhtautuu seksuaalivähemmistöihin.

¹ Kiitän psykometriikan yliopisto-opettaja Jari Lipsasta tekstin lukemisesta ja kommentoinnista.

Ei kuitenkaan ole vaikea keksiä esimerkkejä tilanteista, joissa homogeenisyysoletus ei välttämättä toteudu; jotkut perustelevat uskonnolla kielteisiä asenteita seksuaalivähemmistöjä kohtaan, kun taas toisille uskonto päinvastoin oikeuttaa heteronormista poikkeavat seksuaalisuudet. Muuttujakeskeisen (*variable-centered*) lähestymistavan rinnalle onkin ehdotettu henkilökeskeisiä² (*person-centered*) menetelmiä, joiden tarkoituksena on tunnistaa aineistosta erilaisia sisäisesti homogeenisiä alaryhmiä (ks. esim. Bravo, Pearson & Stevens 2016; Laursen & Hoff 2006; Meeusen ym. 2018). Ryhmittely tapahtuu aina joidenkin valikoitujen ominaisuuksien perusteella. Ihmisiä voisi ryhmitellä esimerkiksi iän, pituuden tai painon mukaan. Uskonnontutkija on kuitenkin yleensä kiinnostunut ennen muuta uskonnollisista ominaisuuksista: konservatiivisuudesta, uskonnollisesta aktiivisuudesta, uskonnollisesta sitoutuneisuudesta ja niin edelleen.

Ryhmittelyanalyysin eri muodot ovat yksinkertaistettuna algoritmeja, jotka vertailevat tilastoyksiköiden (esim. kyselyn vastaajien) välisiä etäisyyksiä ja etsivät lyhimät etäisyydet. Tutkijan tehtävänä on määritellä, minkä ominaisuuksien suhteen vertailu tapahtuu. Kun algoritmia toistetaan tarpeeksi pitkään, aineisto jakautuu alaryhmiin, joiden jäsenet ovat tiettyjen ominaisuuksien suhteen lähellä toisiaan ja kaukana muiden alaryhmien jäsenistä.

Ryhmittelyanalyysin peruseriaatteiden ymmärtämisessä voi auttaa, jos ajattelee tilastoyksiköt (esimerkiksi kyselylomakkeen vastaajat) pisteinä P-ulotteisessa avaruudessa, missä P on ryhmittelyssä käytettävien muuttujien määrä. Jos siis halutaan etsiä tilastoyksiköitä, jotka muistuttavat toisiaan kahden eri ominaisuuden suhteen, tilastoyksiköt voi ajatella pisteiksi tavallisessa kaksiulotteisessa koordinaatistossa (vrt. kuva 1 alla). Tällöin ryhmittelyanalyysi on periaatteessa matemaattinen tapa niputtaa yhteen toisiaan lähellä olevia pisteitä. Periaate pysyy samana silloinkin, kun ryhmittelyssä käytetään yli kahta muuttujaa, mutta geometrisen mielikuvan tavoittaminen käy muuttujien lisääntyessä nopeasti vaikeaksi; ihmismielen on hankala hahmottaa, millaista on etsiä lähimpiä pisteitä esimerkiksi 14-ulotteisessa avaruudessa.

Hierarkkisen klusterianalyysin peruseriaate



Kuten menetelmän nimestä voi jo arvata, hierarkkinen klusterianalyysi etenee vaiheittain. Ensimmäisessä vaiheessa jokainen aineiston tilastoyksikkö muodostaa oman ryhmänsä. N:n tilastoyksikön aineistossa on siis yhteensä N ryhmää, joista jokaisessa on tasan yksi jäsen. Menetelmä etsii ne kaksi ryhmää, jotka ovat määrättyjen muuttujien suhteen lähimpänä toisiaan, ja liittää nämä kaksi yhteen. Nyt aineistossa on enää (N - 1) ryhmää, joista yhteen kuuluu kaksi tilastoyksikköä ja loppuihin yksi tilastoyksikkö. Tämän jälkeen etsitään taas ne kaksi ryhmää, jotka ovat lähimpänä toisiaan, ja liitetään ne yhteen. Näin jatketaan kunnes koko aineisto muodostaa yhden suuren ryhmän. (Toivonen 1999, 341; Xu & Wunsch 2009, 32–33.)

Alla olevissa kuvissa 1–4 on esitetty hyvin yksinkertainen esimerkki hierarkkisen klusterianalyysin etenemisestä. Kuvat esittävät viiden tilastoyksikön (A, B, C, D ja E) suuruista aineistoa, jota ryhmitellään kahden muuttujan saamien arvojen perusteella. Olkoon tilastoyksiköt tässä tapauksessa vaikka ihmisiä ja muuttujat puolestaan vastauksia uskonnonharjoitusta koskeviin kysymyksiin ”Kuinka usein rukoilette?” ja ”Kuinka usein luette Raamattua”. Vastausvaihtoehdot 1 tarkoittaa tässä ”päivittäin” ja vastausvaihtoehdot 7 puolestaan ”en lainkaan viime vuosina”.³


² Henkilökeskeisyyden sijasta voitaisiin tosin puhua myös ”tilastoyksikkökeskeisyydestä”, koska esimerkiksi ryhmittelyanalyysillä voidaan analysoida myös muita kuin ihmisistä koostuvia aineistoja.

³ Kysymykset ja vastausvaihtoehdot on lainattu Gallup Ecclesiastica -kyselyistä.

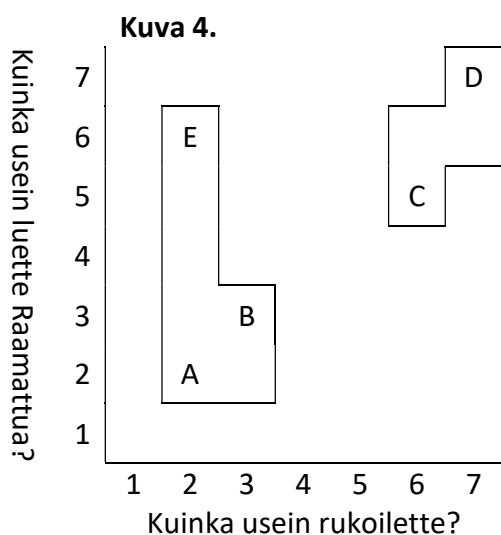
Ryhmittelyanalyysin ensimmäisessä vaiheessa jokainen vastaaja muodostaa oman ryhmänsä (Kuva 1). Seuraavaksi algoritmi liittää samaan ryhmään ne kaksi vastaajaa, jotka ovat uskonnonharjoituksen suhteen lähimpänä toisiaan (Kuva 2). Tässä tapauksessa nämä kaksi ovat vastaajat A ja B, joista kumpikin sekä rukoilee että lukee Raamattua säännöllisesti.




Tämän jälkeen algoritmi etsii ne kaksi ryhmää, jotka ovat nyt lähimpänä toisiaan, ja liittää ne uudeksi ryhmäksi (Kuva 3). Esimerkkiaineistossa nämä kaksi ovat yhden vastaajan ryhmät {C} ja {D}. C:tä ja D:tä yhdistää epäsäännöllinen uskonnonharjoitus; molemmat rukoilevat ja lukevat Raamattua vain vähän, D ei tällä hetkellä ollenkaan.



Seuraavaksi pienin etäisyys on ryhmän {A, B} ja yhden vastaajan ryhmän {E} välillä. Näistä muodostetaan ryhmä {A, B, E} (kuva 4), jonka jäsenille on yhteistä säännöllinen rukoileminen. Toisin kuin A ja B, vastaaja E ei kuitenkaan juuri lue Raamattua.



Analyysin viimeisessä vaiheessa algoritmi yhdistää ryhmät {A, B, E} ja {C, D} yhdeksi suureksi ryhmäksi (kuva 5). Kaikki aineiston tilastoyksiköt kuuluvat nyt yhteen suureen ryhmään ja hierarkkinen klusterianalyysi päättyy.



Kuten esimerkkikuvista 1–5 voi nähdä, hierarkkinen klusterianalyysi ei tuota yhtä ryhmittelyä vaan suuren määrän erilaisia ryhmittelyvaihtoehtoja. Hierarkkinen klusterianalyysi ei kuitenkaan kerro, mikä vaihtoehdoista on ”oikea” tai ”paras”, vaan lopullisen ryhmittelyn valinta jää tutkijan tehtäväksi (King 2015, 34; Toivonen 1999, 342). Tutkijan tehtävänä on myös antaa valitulle ryhmittelylle järkevä sisällöllinen tulkinta. Esimerkkiaineistomme tapauksessa toimiva ryhmittely voisi olla esimerkiksi kuvassa 4 esitetty kahden ryhmän ratkaisu. Aineistosta erottuvat tällöin omiksi ryhmikseen ne, jotka rukoilevat säännöllisesti (A, B ja E), ja ne, jotka eivät rukoile (C ja D). Kuvan 3 jako kolmeen ryhmään voisi niin ikään olla käyttökelpoinen ratkaisu. Kolme ryhmää voitaisiin nimetä esimerkiksi ”uskonnollisesti passiivisiksi” (C ja D), ”monipuolisesti aktiivisiksi” (A ja B) ja ”pelkästään rukoileviksi” (E).

Vastaajien A–E muodostaman esimerkkiaineiston jakaminen ryhmiin on niin yksinkertaista, ettei siihen tarvita tilasto-ohjelmia. Samaa periaatetta käyttäen voidaan kuitenkin ryhmitellä myös satojen tai tuhansien tilastoyksiköiden kokoisia aineistoja ja käyttäen ryhmittelyperusteena suurta joukkoa eri muuttujia. Tällöin ryhmittelyn vaatimat laskutoimitukset käyvät niin työläiksi, että ne on parasta antaa tietokoneen tehtäväksi.

Mikä ryhmistä on lähin?

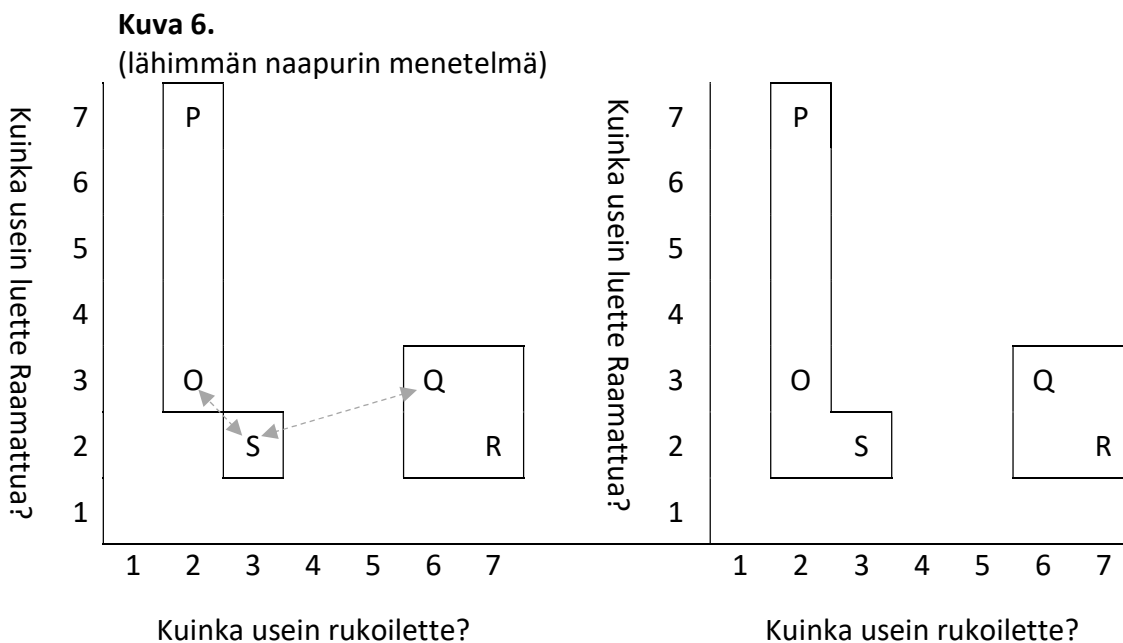
Lähintä ryhmää etsittäessä kahden ryhmän välinen etäisyys voidaan määritellä eri tavoilla. Eräs yleinen ratkaisu on käyttää niin sanottua ”kaukaisimman naapurin menetelmää” (*farthest neighbour clustering* tai *complete-linkage clustering*). Tällöin kahden ryhmän välinen etäisyys ajatellaan samaksi kuin pisin etäisyys niiden jäsenten välillä. Kuvan 3 tilanteessa ryhmien {A, B} ja {C, D} välinen etäisyys olisi tällöin sama kuin henkilöiden A ja D vastausten välinen etäisyys. ”Kaukaisimman naapurin menetelmän” sijaan voidaan kuitenkin käyttää myös ”lähimmän naapurin menetelmää” (*nearest neighbour clustering* tai *single-linkage clustering*), jolloin ryhmien välinen etäisyys on sama kuin lyhin etäisyys niiden jäsenten välillä. Kuvan 3 ryhmien {A, B} ja {C, D} välinen etäisyys olisi siis tässä tapauksessa sama kuin henkilöiden B ja C vastausten välinen etäisyys. Kolmas vaihtoehto on laskea kahden ryhmän välinen etäisyys ryhmän jäsenten keskimääräisenä etäisyytenä toisen ryhmän jäsenistä. Tällöin on kyseessä niin sanottu *average linkage* -klusterointi. (Holopainen 2012, 17; Xu & Wunsch 2009, 34–35.) Näiden kolmen


lisäksi on muitakin menetelmiä, mutta niiden osalta suosittelen tutustumista taustakirjallisuuteen (ks. esim. Xu & Wunsch 2009, 33–37.).

Eri menetelmillä on omat hyvät ja huonot puolensa. Lähimmän naapurin menetelmässä ryhmien yhdistämiseen riittää se, jos yksi ainoa ryhmän jäsen on lähellä yhtä ainoaa jäsentä toisessa ryhmässä. Ryhmien loput jäsenet voivat olla hyvinkin kaukana toisistaan, ja lähimmän naapurin menetelmä tuottaakin helposti varsin hajanaisia ryhmiä, joissa ryhmän jäsenten keskinäiset erot ovat suuret. Kaukaisimman naapurin menetelmä puolestaan varmistaa, ettei samaan ryhmään päädy liian kaukana toisistaan olevia tilastoyksiköitä. Muodostetut ryhmät ovat tällöin suhteellisen selvärajaisia ja yhdenmukaisia. Menetelmän heikkous on kuitenkin se, että jotkin tilastoyksiköt voivat olla lähempänä joitain yksittäisiä toisen ryhmän jäseniä kuin osaa oman ryhmänsä jäsenistä (vrt. kuva 7 alla). (Holopainen 2012, 17–19.)

Menetelmän valinta riippuu viime kädessä siitä, millaisia ryhmiä halutaan saada aikaan. Jos halutaan sisäisesti mahdollisimman yhdenmukaisia ryhmiä, jotka tosin voivat olla lähellä toisiaan, kaukaisimman naapurin menetelmä on hyvä valinta. Jos taas toivotaan selvästi toisistaan erottuvia ryhmiä, joissa sisäinen vaihtelu voi kuitenkin olla suurta, kannattaa ehkä mieluummin valita lähimmän naapurin menetelmä. *Average linkage* -klusterointi puolestaan on eräänlainen kompromissiratkaisu kahden edellisen menetelmän väliltä. (Aldenderfer & Blashfield 1984, 39–40.)

Alla olevat kuvat 7 ja 8 havainnollistavat, kuinka vastaaja S saattaa päätyä aivan eri ryhmiin riippuen siitä, kuinka ryhmien väliset etäisyydet määritetään. S:n vastaukset ovat huomattavan lähellä henkilön O vastauksia, joten lähimmän naapurin menetelmää käytettäessä S päätyy ryhmään {O, P} (ks. kuva 6). Jos taas yhdistämisen kriteerinä käytetään kaukaisinta naapuria, tilanne muuttuu: vaikka S:n vastaukset ovat lähellä O:n vastauksia, ne ovat samalla kaukana O:n kanssa samaan ryhmään kuuluvan henkilön P vastauksista ja itse asiassa lähempänä Q:n ja R:n vastauksia. Siksi S liitetäänkin ryhmään {Q, R} (ks. kuva 7).



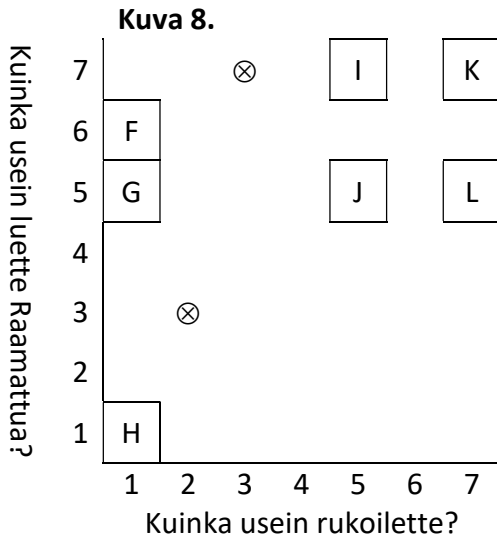


K-means-klusterianalyysin peruseriaate

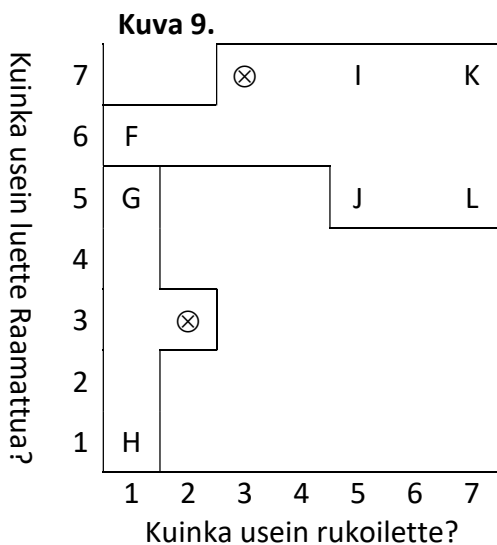
Hierarkkinen klusterianalyysi on eräs yleisimmistä ryhmittelyanalyysin muodoista, mutta se ei suinkaan ole ainoa. Toinen verrattain paljon käytetty menetelmä on niin sanottu K-means-klusterianalyysi. Toisin kuin hierarkkinen klusterianalyysi, K-means-klusterointi edellyttää, että tutkija määrää etukäteen, kuinka monta ryhmää haluaa lopputulokseksi (Toivonen 1999, 341). Kuten edellä todettiin, ryhmittelyanalyysin voi ajatella tavaksi etsiä toisiaan lähellä olevia pisteitä P-ulotteisessa avaruudessa, kun P on ryhmittelyssä käytettävien muuttujien määrä. K-means-klusterianalyysi perustuu siihen, että kullekin ryhmälle määritellään keskipiste siten, että jokainen tilastoyksikkö on mahdollisimman lähellä oman ryhmänsä keskipistettä. Analyysin aluksi K-means-algoritmi sijoittaa ryhmäkeskipisteet P-ulotteiseen avaruuteen joko sattumanvaraisesti tai käyttäjän määräämällä tavalla. Tämän jälkeen algoritmi määrittää jokaista tilastoyksikköä lähimpänä olevan ryhmäkeskipisteen ja liittää kaikki samaa keskipistettä lähellä olevat tilastoyksiköt samaan ryhmään. Sitten algoritmi laskee, mikä on kunkin ryhmittelyssä käytettävän muuttujan keskiarvo kussakin ryhmälle. Ryhmäkohtaiset keskiarvot määrittävät uudet ryhmäkeskipisteet. Alkuperäiset ryhmäkeskipisteet korvataan uusilla ja algoritmi tarkistaa, vaikuttaako tämä siihen, mihin ryhmään kukin tilastoyksikkö kuuluu. On nimittäin mahdollista, että ryhmäkeskipisteiden vaihduttua oman ryhmän keskipiste ei enää olekaan tilastoyksikköä lähimpänä oleva ryhmäkeskipiste. Ryhmät muodostetaan uudelleen niin, että kaikki samaa ryhmäkeskipistettä lähellä olevat tilastoyksiköt muodostavat yhden ryhmän. Jos ryhmien kokoonpano tämän seurauksena muuttuu, muuttujien keskiarvot lasketaan uudelleen kullekin ryhmälle. Näin saadaan taas uudet ryhmäkeskipisteet. Näin jatketaan, kunnes ryhmäkeskipisteet eivät enää muutu. (Aldenderfer & Blashfield 1984, 45; King 2015, 59; Xu & Wunsch 2009, 67–68.)

Esimerkki havainnollistaa K-means-algoritmin toimintaa. Oletetaan seitsemän vastaajan (F, G, H, I, J, K ja L) aineisto, joka halutaan jakaa kahteen ryhmään K-means-klusterianalyysillä. Ryhmittely perustuu samoihin kahteen muuttujaan kuin hierarkkista klusterianalyysistä koskevissa esimerkeissä, joten vastaajat voidaan ajatella pisteiksi kaksiulotteiseen koordinaatistoon.

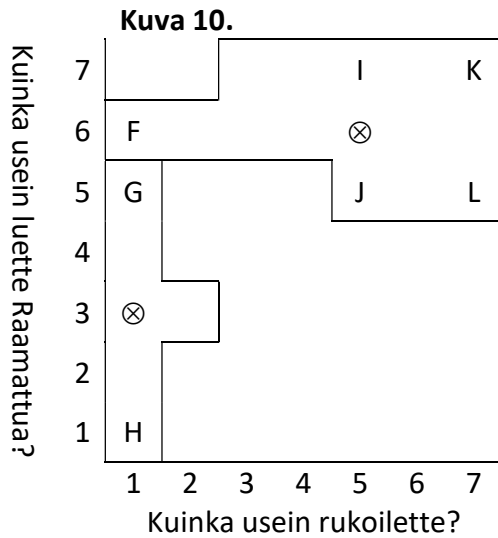
Aivan ensimmäiseksi K-means-algoritmi sijoittaa koordinaatistoon kaksi satunnaista ryhmäkeskipistettä (merkitty symbolilla ⊗) (kuva 8).




Tämän jälkeen algoritmi määrittää kutakin tilastoyksikköä lähimpänä olevan ryhmäkeskipisteen ja liittää kaikki samaa ryhmäkeskipistettä lähellä olevat tilastoyksiköt samaan ryhmään. Syntyy kaksi ryhmää: {G, H} ja {F, I, J, K, L} (kuva 9). Ryhmän {G, H} jäseniä yhdistää päivittäinen rukoilu. Ryhmän {F, I, J, K, L} kaikki jäsenet puolestaan lukevat Raamattua vain harvoin.



Seuraavaksi algoritmi laskee analyysissä käytettyjen muuttujien keskiarvot erikseen kummallekin ryhmälle. Kysymykseen "Kuinka usein rukoillette?" annettujen vastausten keskiarvo on ryhmässä {G, H} $\frac{1+1}{2} = 1$. Ryhmässä {F, I, J, K, L} keskiarvo on $\frac{1+5+5+7+7}{5} = 5$. Kysymykseen "Kuinka usein luette Raamattua?" annettujen vastausten keskiarvo puolestaan on ryhmässä {G, H} $\frac{5+1}{2} = 3$ ja ryhmässä {F, I, J, K, L} $\frac{7+7+6+5+5}{5} = 6$. Keskiarvoista saadaan uudet ryhmäkeskipisteet: ryhmän {G, H} keskipisteeksi tulee piste (1, 3), ryhmän {F, I, J, K, L} keskipisteeksi puolestaan piste (5, 6) (kuva 10).




Ryhmiä keskipisteet ovat vaihtuneet, joten algoritmi tarkistaa, vaikuttaako tämä ryhmien koostumukseen. Osoittautuu, että vastaaja F on lähempänä ryhmän {G, H} keskipistettä (1, 3) kuin oman ryhmänsä keskipistettä (5, 6), joten F vaihtaa ryhmää (kuva 11).



Ryhmiä kokoonpano on vaihtunut, joten klusterointialgoritmi laskee uudet ryhmäkeskiarvot ryhmittelyssä käytetyille muuttujille. "Kuinka usein rukoilette?" -osion keskiarvo on ryhmässä {F, G, H} $\frac{1+1+1}{3} = 1$ ja ryhmässä {I, J, K, L} $\frac{5+5+7+7}{4} = 6$. "Kuinka usein luette Raamattua?" -osion keskiarvo puolestaan on ryhmässä {F, G, H} $\frac{6+5+1}{3} = 4$ ja ryhmässä {I, J, K, L} $\frac{7+5+7+5}{4} = 6$. Ryhmän {F, G, H} uudeksi keskipisteeksi tulee täten piste (1, 4) ja ryhmän {I, J, K, L} keskipisteeksi piste (6, 6) (kuva 12).

Tämän jälkeen algoritmi tarkistaa uudelleen, onko kukin vastaaja lähempänä oman vai jonkin toisen ryhmän keskipistettä. Koska oman ryhmän keskipiste on kutakin vastaajaa lähin ryhmäkeskipiste, ryhmien kokoonpano ei enää muutu ja K-means-klusterointialgoritmi päättyy. Klus-

teroinnin lopputuloksena on muodostunut kaksi ryhmää: Ryhmän {F, G, H} kaikki jäsenet rukoilevat päivittäin, mutta lukevat Raamattua eri verran. Ryhmän { I, J, K, L } jäsenet puolestaan sekä rukoilevat että lukevat Raamattua vähänlaisesti.



Kuten ylläolevasta esimerkistä ilmenee, yksi tilastoyksikkö voi K-means-analyysin aikana siirtyä ryhmästä toiseen aina sen mukaan, minkä ryhmän keskipiste on kulloinkin sitä lähimpänä. Hierarkkisessa klusterianalyysissä on toisin: Hierarkkinen klusterointialgoritmi yhdistelee muodostettuja ryhmiä, mutta ei muuten puutu niiden koostumukseen. Kun siis hierarkkinen klusterointialgoritmi on liittänyt kaksi tilastoyksikköä samaan ryhmään, ne ovat ja pysyvät samassa ryhmässä analyysin loppuun asti (Toivonen 1999, 342).

Tutkimusesimerkki

Olen itse soveltanut ryhmittelyanalyysia muun muassa iranilaisten ex-muslimien uskosta-luopumiskertomusten analyysissä, jonka tein yhdessä Atefeh Aghaen kanssa (ks. Pauha & Aghaee 2018). Uskosta-luopumiskertomukset oli kerätty internetistä, eräästä persiankielisestä Google Plus -yhteisöstä. Kertomuksia ei alun perin oltu kirjoitettu tutkimuskäyttöön, mutta yhteisön jäsenet antoivat meille luvan käyttää niitä tutkimuksessamme. Ennen varsinaista analyysia kanssakirjoittajani käänsi kaikki 52 kertomusta englanniksi, minkä jälkeen aloimme koodata niitä laadullisesti, Grounded Theory -periaatteiden mukaisesti.

Grounded Theory -analyysi alkaa niin sanotulla avoimella koodauksella (*open coding*). Avoimessa koodauksessa aineistoa luetaan ja jokaiseen tekstiriviin liitetään koodi, joka jollain tavalla kuvaa rivin sisältöä. Koodauksen edistyessä koodeja vertaillaan toisiinsa ja aineistoon. Tarkoituksena on näin löytää useita eri koodeja yhdistäviä ylemmän abstraktiotason sisältöluokkia. (Charmaz 2003, 96; Charmaz 2000, 515; Corbin & Strauss 2008, 159–160.)

Käytimme alustavassa koodauksessamme yhteensä yli 70 koodia. Annoimme esimerkiksi lauseelle ”Kiitos tieteen, tätä nykyä on olemassa vastaus kaikkiin niihin kysymyksiin, jotka alkuaan synnyttivät uskonnot” koodin ”Tiede korvaa uskonnon”. Lause ”Uskoa voidaan seurata tietämättömästi ja sokeasti, kun taas epäusko ja uskosta luopuminen edellyttävät perusteellista ajattelua” puolestaan sai koodin ”Usko on ajattelun puutetta”. Koodauksen edetessä muodostimme yleisemmän sisältöluokan ”Ateismin rationaalisuus / uskonnon irrationaalisuus”, johon yhdistimme muun muassa molemmat edellä mainituista koodeista.

Avoimen koodauksen lopputuloksena syntyi yhteensä 20 sisältökategorian luokitus. Esimerkkejä aineistosta ja muutamista sen sisältöluokista on esitetty taulukossa 1.

Taulukko 1. Esimerkkejä aineiston jakamisesta sisältöluokiiin		
Sisältöluokka ja sen LYHENNE	Kuvaus	Aineistoesimerkki
Ateismin RATIONAALISUUS / uskonnon irrationaalisuus	Viittaukset uskonnon irrationaalisuuteen, taikauskoiuuteen ja typeryyteen; viittaukset ateismin rationaalisuuteen, loogisuuteen ja tieteellisyyteen	”Lupasin itselleni, että niin kauan kuin tiede ja logiikka eivät todista Jumalan olemassaoloa, en ajattele häntä.”
Asteittainen EPÄILY	Viittaukset uskon ailahteluihin ja epävarmuuteen uskonnollisista totuuksista	”Rukoilin, mutta epäilin kaikkea sanomaani.”
KAUNA yhteiskuntaa tai auktoriteetteja kohtaan	Viittaukset kaunan ja katkeruuden tunteisiin yhteiskuntaa ja auktoriteetteja kohtaan	”Vaalien jälkeen näin, että hallinto johon uskoin oli valetta, joten miksi uskoisin muuhunkaan, mitä minulle väitetään.”
Uskonnon YHDENTEKEVYYS	Viittaukset siihen, miten uskonto (tai Jumala) ei pysty auttamaan hädässä tai on muuten merkityksetöntä	”Mitä väliä minulle on Jumalalla, joka ei voi muuttaa mitään?”
Uskonnottomat VAIKUTTEET	Viittaukset ateistisiin tai uskontokriittisiin kirjoihin tai henkilöihin, jotka ovat vaikuttaneet uskosta luopumiseen	”Luin Dawkinsin <i>Jumalharhan</i> ja varmistuin siitä, että olen oikealla tiellä, enkä uskonut Jumalaa enää.”
Uskonnon tuottama haitta ja VAHINKO	Viittaukset fyysisiin ja psyykkisiin vaurioihin tai yhteiskunnallisiin haittoihin, joita uskonto ja uskovat ovat aiheuttaneet	”Uskonnon pahin pitkäaikaisvaikutus minuun oli masennus ja syyllisyys.”
Vastausten ETSINTÄ	Viittaukset totuuden, merkityksen ja vastauksien tietoiseen etsintään	”Opiskelin enemmän ja etsin enemmän.”

Ateismin tutkijat ovat toisinaan tehneet eron filosofisen ja käytännöllisen ateismin välillä (ks. esim. Sillfors 2017). Keskeinen näitä kahta erottava tekijä on se, millä perusteella Jumala ja uskonto viime kädessä hylätään: Filosofinen ateisti on järkeilyn kautta päätenyt siihen, että Jumalaa ei ole olemassa. Käytännöllinen ateisti taas torjuu uskonnon, koska se on ristiriidassa hänen arvomaailmansa kanssa tai haitallista yhteiskunnalle. Kärjistäen voisi sanoa, että filosofiselle ateistille uskonto on tyhmää ja käytännölliselle ateistille puolestaan vaarallista.

Nämä kaksi tapaa suhtautua uskontoon erottuivat selvästi myös omassa aineistossamme. Ja oimmekin tutkimamme kertomukset kahteen ryhmään sen mukaan, edustivatko ne filosofista vai käytännöllistä ateismia. Meitä kiinnosti tietää, voisimmeko todentaa tekemämme jaottelun myös tilastollisesti. Luokittelisiko tilastollinen ryhmittelyalgoritmi kertomukset samalla tavalla kuin me?

Sisältöluokat RATIONAALISUUS ja EPÄILY tuntuivat olevan erityisen tyypillisiä filosofisille ateisteille, KAUNA ja VAHINKO puolestaan käytännöllisille. Annoimmekin hierarkkisen klusterointialgoritmin jakaa kertomukset ryhmiin sen perusteella, kuinka suuri osa niiden sisällöstä kuului kuhunkin näistä neljästä sisältöluokasta. Oletuksena oli, että aineisto jakautuisi kahteen ryhmään, joista toisessa käytetään runsaasti sisältöluokkia RATIONAALISUUS ja EPÄILY ja toisessa puolestaan sisältöluokkia KAUNA ja VAHINKO. Näin kävikin. Hierarkkinen ryhmittelyanalyysi tuotti kahden klusterin ratkaisun, joka vastasi alustavasti tekemääme jakoa filosofiisiin ja käytännöllisiin ateisteihin.


Jaottelussamme oli kuitenkin myös tiettyjä ongelmia. Ehkä keskeisin näistä oli se, että eräät tarinat aineistossamme eivät tuntuneet sopivan oikein kumpaankaan kahdesta luokastamme. Koska hierarkkinen klusterianalyysi tuottaa koko joukon erilaisia ryhmittelyvaihtoehtoja, päätimmekin kahden klusterin ratkaisun lisäksi tutustua lähemmin myös muihin tapoihin luokitella aineistoa. Erityisesti kiinnostuimme neljän klusterin ratkaisusta, jossa yksi ryhmä käytti paljon KAUNA- ja VAHINKO-sisältöluokkia, toinen EPÄILY-sisältöluokkia ja kolmas RATIONAALISUUS-sisältöluokkia. Neljäs ryhmä puolestaan ei suosinut mitään edellä mainituista sisältöluokista. Vaikutti siis siltä, että neljän klusterin ratkaisu säilytti käytännölliset ateistit omana ryhmänään, mutta jakoi filosofiset ateistit kahteen alaryhmään, joista toisen tarinoissa korostui ateismin rationaalisuus tai uskonnon irrationaalisuus ja toisen tarinoissa puolestaan asteittain kasvava epävarmuus. Neljänneksi ryhmäksi jäivät ne, jotka eivät tuntuneet edustavan sen enempää filosofista kuin käytännöllistäkään ateismia.

Neljän klusterin ratkaisu vaikutti lupaavalta, joten aloimme lukea aineistoa uudelleen sen valossa. Yksi toimivan luokittelun merkki on se, että muodostetuille ryhmille on helppo keksiä kuvaavat nimet. Tässä tapauksessa osuvat nimet tuntuivat syntyvän aineistoa lukiessa kuin itsestään: "Etsijöiden" tarinoissa korostui EPÄILY. He olivat tyypillisesti olleet vakaumuksellisia uskovia, mutta ajautuneet uskonkriisiin avointen kysymysten ja ratkaisemattomien ristiriitojen vuoksi. "Rationalistien" kertomuksille puolestaan oli tyypillistä sisältöluokka RATIONAALISUUS, uskonnon ja tieteen välisen ristiriidan korostaminen sekä uskonnon pitäminen naiivina. "Kapinallisille" uskonto oli yhteiskunnallisesti haitallinen ilmiö, josta vapautuminen tekisi maailmasta paremman paikan. Heidän kertomuksissaan painottuivat sisältöluokat KAUNA ja VAHINKO. "Välinpitämättömät" sen sijaan eivät perustelleet uskosta luopumistaan sen enempää älyllisin, moraalisin kuin yhteiskunnallisinkaan syin. Heille uskonto oli lähinnä hyödytöntä tai yhdentekevää, koska siitä ei ollut apua arjen haasteissa tai elämän kipukohdissa.

Alla olevassa kuvassa 13 näkyy, kuinka suuri osuus kunkin kertomustyyppin sisällöstä kuului muutamiin esimerkkikategorioiden. Kuten kuvasta käy ilmi, näkemys uskonnosta haitallisena tai vahingollisena ilmiönä oli hyvin tyypillinen Kapinallisten kertomuksille; jopa yksi neljäsosa niiden sisällöstä kuului sisältöluokkaan VAHINKO. Kyseinen sisältöluokka puuttui kuitenkin lähes kokonaan Etsijöiden teksteistä. Heille uskonto oli ollut myönteinen asia, josta luopuminen oli tuntunut kivuliaalta.

Vaikka eri kertomustyyppit suosivat eri sisältökategorioita, niillä oli myös yhdistäviä piirteitä. Kaikissa kertomustyypeissä oli esimerkiksi melko paljon VAIKUTTEET-kategorian sisältöjä – siis viittauksia ateistisiin tai uskontokriittisiin henkilöihin, kirjoihin, Internet-sivuihin ja muihin lähteisiin, jotka olivat vaikuttaneet uskosta luopumiseen.

Kuva 13. Eräiden sisältöluokkien osuus neljäntyyppisten uskotaluopumiskertomusten sisällöstä



Avoimen koodauksen lisäksi Grounded Theory -analyysiin sisältyy myös kaksi muuta vaihetta: pitkittäiskoodaus (*axial coding*) ja valikoiva koodaus (*selective coding*). Näiden koodausvaiheiden tarkoituksena on syventää tehtyä luokittelua esimerkiksi erittelemällä eri sisältöluokkien välisiä suhteita ja yhteyksiä. (Ks. esim. Luomanen 2010.) Teimme pitkittäiskoodauksen ja valikoivan koodauksen erikseen kullekin klusterianalyysissä muodostetulle ryhmälle ja toteimmme, että ryhmät erosivat toisistaan myös tyypillisen kertomusrakenteen osalta. Uskon menettäminen oli esimerkiksi ollut kova pala etsijöille ja he kuvasivatkin usein ateismia uskonnollisuutta raskaampana tapana elää. Rationalisteille uskon menetyks oli sitä vastoin ollut vapautus ikeen alta: yksiselitteisen positiivinen asia ja muutos kohti parempaa. Pitkittäiskoodauksen ja valikoivan koodauksen tulokset olivat mielenkiintoisia, mutta ne eivät juuri auta havainnollistamaan klusterianalyysia tai sen käyttöä. Siksi en esittele koodausvaiheita tämän enempää, vaan suosittelen kiinnostuneita tutustumaan minun ja Aghaen alkuperäiseen artikkeliin (Pauha & Aghaee 2018).

Lopuksi

Ryhmittelyanalyysin eräs etu on se, että se asettaa monia muita menetelmiä vähemmän vaatimuksia aineistolle ja muuttujille. Moni tilastollinen menetelmä edellyttää esimerkiksi, että analyysissä käytetyt muuttujat noudattavat normaalijakaumaa eli niin sanottua Gaussin käyrää. Ryhmittelyanalyysin kannalta tämä ei ole oleellista. Sen sijaan on yleensä tärkeää, että ryhmit-

telyanalyysissä käytetyt muuttujat on mitattu samalla mitta-asteikolla. Koska klusterointialgoritmi tarkastelee ainoastaan lukujen suuruuseroja, se ei huomioi mittayksikön merkitystä. Algoritmi ei esimerkiksi ymmärrä, että 180 senttimetriä ja 1.8 metriä ovat sama asia; algoritmille on oleellista vain se, että 180 on sata kertaa suurempi luku kuin 1.8. Tästä syystä on pidettävä huolta, että ryhmittelyssä käytetyt luvut ovat keskenään vertailukelpoisia. Jos muuttujia ei alun alkaen ole mitattu samalla mitta-asteikolla, yleinen käytäntö on standardoida muuttujat eli skaalata ne uudelleen niin, että kukin muuttuja saa keskiarvon 0 ja keskihajonnan 1. (Toivonen 1999, 343.) Tilasto-ohjelma tekee standardoinnin tutkijan puolesta muutamalla napinpainalluksella.

Tilasto-ohjelmat tekevät myös varsinaisen klusteroinnin tutkijan puolesta, mutta sekä hierarkkinen että K-means-klusterianalyysi edellyttävät tutkijalta etukäteisvalintoja, joilla on vaikutusta lopputulokseen (Holopainen 2012, 23). Hierarkkisen klusterianalyysin tapauksessa tutkijan on päätettävä, millä perusteella algoritmi määrittää toisiaan lähimpänä olevat ja siten keskenään yhdistettävät ryhmät. Kuten edellä todettiin, erilaiset tavat määrittää ryhmien etäisyyksiä voivat johtaa huomattavan erilaisiin klusteriratkaisuihin. Tällä on erityistä merkitystä siksin, että hierarkkisen klusterianalyysin yhdessä vaiheessa tehdyt ratkaisut vaikuttavat myös kaikissa myöhemmissä vaiheissa: Hierarkkinen klusterianalyysi etenee yhdistämällä ryhmiä, eikä se enää korjaa kertaalleen muodostettujen ryhmien kokoonpanoa. Kun tilastoyksiköt on kerran sijoitettu samaan ryhmään, niitä ei enää jaeta eri ryhmiin, vaikka analyysin myöhemmät vaiheet antaisivatkin aihetta siihen. K-means-algoritmi sitä vastoin tarkistaa analyysin joka vaiheessa, onko kukin tilastoyksikkö parhaassa mahdollisessa ryhmässä, ja päivittää tehtyä ryhmäjakoja, kunnes optimaalinen ratkaisu on löytynyt. Toisin kuin hierarkkinen klusterianalyysi, K-means-klusterianalyysi kuitenkin edellyttää, että tutkija päättää etukäteen, montako ryhmää hän haluaa lopputulokseksi.

On tärkeää huomata, että ryhmittelyanalyysi itsessään on eksploraatiivinen menetelmä, joka sopii käytettäväksi ennen kaikkea silloin, kun tutkijalla ei ole vahvaa ennakkokäsitystä aineiston mahdollisesti sisältämistä ryhmistä (Xu & Wunsch 2009, 2). Jos tutkijalla on jo käytössään jokin valmis ryhmäjako, on muista menetelmistä usein enemmän hyötyä: Varianssianalyysillä (*analysis of variance* eli ANOVA) voi testata, ovatko ennalta määrätty ryhmät samanlaisia vai erilaisia joidenkin tiettyjen ominaisuuksien suhteen. Erotteluanalyysi (*discriminant analysis*) puolestaan paljastaa, mitkä ovat keskeisimmät joitain tiettyjä ryhmiä erottavat tekijät. Alla olevassa taulukossa 2 on annettu esimerkkejä kysymyksistä, joihin eri menetelmillä voi vastata.

Taulukko 2. Menetelmiä ryhmien analysoimiseen	
Menetelmä	Mahdollisia tutkimuskysymyksiä
Ryhmittelyanalyysi	”Millaisia ryhmiä on?” (esim. ”Millaisiin ryhmiin seurakuntia voi jakaa?”)
Varianssianalyysi	”Onko ryhmillä eroa?” (esim. ”Ovatko maalais- vai kaupunkiseurakunnat keskimäärin varakkaampia?”)
Erotteluanalyysi	”Mikä ryhmiä erottaa?” (esim. ”Mitkä ovat suurimmat erot maalais- ja kaupunkiseurakuntien välillä?”)

Ryhmittelyanalyysi ei eksploraatiivisena menetelmänä kerro, onko jokin tietty ryhmittely ”oikea”. Menetelmän tarkoituksena ei olekaan todentaa jotain annettua ryhmittelyä, vaan pikemminkin avata uusia tutkimussuuntia. (Xu & Wunsch 2009, 3.) Klusterointialgoritmit eivät myöskään itsessään tuota p-arvoja tai muita tunnuslukuja, jotka kertovat tulosten yleistettävyydestä johonkin tutkimusaineistoa laajempaan perusjoukkoon.

Klusteriratkaisun pätevyyden ja yleistettävyyden arvioimiseen on tarjolla erilaisia tilastollisia menetelmiä (ks. esim. Aldenderfer & Blashfield 1984, 62–75; Holopainen 2012, 23–30; King 2015, 179–228; Xu & Wunsch 2009, 263–278). Yksi tapa arvioida klusteriratkaisun pätevyyttä (*validity*) on testata, tuottavatko erilaiset klusterointialgoritmit samankaltaisia tuloksia. Toinen tapa puolestaan on tutkia, eroavatko ryhmät toisistaan myös muiden kuin ryhmittelyssä käytettyjen muuttujien osalta (Aldenderfer & Blashfield 1984, 66). Jos ryhmien välillä on tällaisia eroja, on aihetta olettaa, että ryhmittelyanalyysin tulokset heijastelevat jotain todellisen maailman ryhmäjakoja.

Eräässä tutkimuksessa analysoimme kyselyvastauksia noin 760 ihmiseltä, joita yhdisti se, etteivät he uskoneet Jumalaan. Käytimme klusterianalyysia jakamaan vastaajat neljään ryhmään sen mukaan, kuinka uskonnollisina ja henkisinä he pitivät itseään. Kuten oli odotettavaa, enemmistö (noin 60 %) vastaajista ei pitänyt itseään lainkaan uskonnollisina tai henkisinä. Noin joka kuudes vastaaja kuitenkin piti itseään ainakin vähän uskonnollisena mutta ei juuri lainkaan henkisenä ja vastaavasti noin joka kuudes pikkuisen henkisenä mutta ei yhtään uskonnollisena. Lisäksi aineistosta erottui pieni ryhmä vastaajia, jotka kokivat olevansa sekä varsin uskonnollisia että varsin henkisiä. (Pauha ym. 2019.)

Klusterianalyysin tuottama neljän ryhmän ratkaisu muistutti varsin paljon aiemmissä tutkimuksissa tehtyä jakoa ”uskonnollisiin ja henkisiin”, ”uskonnollisiin mutta ei henkisiin”, ”henkisiin mutta ei uskonnollisiin” sekä ”ei-uskonnollisiin ja ei-henkisiin” (ks. esim. Good & Willoughby 2006; Jang & Franzen 2013; Keller ym. 2016; Nadal, Hardy & Barry 2018). Aiemmissä tutkimuksissa on myös todettu, että ateistien enemmistö on miehiä (Schnabel ym. 2016), kun taas organisoitumattoman henkisyyden piirissä toimii etupäässä naisia (ks. esim. Sointu & Woodhead 2008; Taylor 2010). Kuten alla olevasta taulukosta 3 käy ilmi, vastaavia sukupuolieroja ilmeni myös omassa aineistossamme: Miehet olivat enemmistönä sekä klusterianalyysin avulla muodostetuissa ryhmissä että aineistossa yleensä. Ainoa poikkeus oli ”henkisten mutta ei uskonnollisten” ryhmä, jonka jäsenistä suurin osa (noin 60 %) oli naisia. Vaikka ryhmät oli muodostettu pelkästään uskonnollisten ja henkisten identiteettien perusteella, niiden välillä oli siis myös muita eroja. Tämä puolestaan tukee olettamusta siitä, että ryhmäjako ei ole pelkästään algoritmin tuottama harha, vaan se kuvastaa jotain todellista jakoa ateistien keskuudessa.

Taulukko 3. Neljänlaiset ateistit (Pauha ym. 2019)

	”Ei-uskonnolliset ja ei-henkiset”	”Uskonnolliset mutta ei henkiset”	”Henkiset mutta ei uskonnolliset”	”Uskonnolliset ja henkiset”	Koko aineisto
Lkm	466	120	118	54	758
(%)	(61.5 %)	(15.8%)	(15.6 %)	(7.1 %)	(100 %)
Uskonnollinen identiteetti: keskiarvo (1–7)	1.05	2.25	1.22	3.81	1.46
Henkinen identiteetti: keskiarvo (1–7)	1.09	1.79	2.85	4.01	1.69
Naisia	41.4 %	44.2 %	61.0 %	48.1 %	45.4 %

Vaikka klusteriratkaisun toimivuutta voi arvioida tilastollisin perustein, tutkijan sisällöllisen asiantuntemuksen rooli on myös ensiarvoisen tärkeä. Klusteriratkaisun arvo ei viime kädessä riipu siitä, ”onko p alle 0.05”, vaan siitä, auttaako ratkaisu ymmärtämään tutkittavaa ilmiötä entistä syvällisemmin ja toimiiko ratkaisu hyödyllisenä lähtökohtana tuleville tutkimuksille. Tässäkin tapauksessa puu tunnetaan hedelmistään.

Kirjallisuus

Aldenderfer, Mark S. & Roger K. Blashfield

1984 *Cluster Analysis*. London: Sage.

<https://doi.org/10.4135/9781412983648>

Bravo, Adrian J., Matthew R. Pearson & Leah E. Stevens

2016 Making Religiosity Person-Centered: A Latent Profile Analysis of Religiosity and Psychological Health Outcomes. *Personality and Individual Differences* 88: 160–169.

<https://doi.org/10.1016/j.paid.2015.08.049>

Charmaz, Kathy

2003 Grounded theory. – Jonathan A. Smith (toim.), *Qualitative Psychology: A Practical Guide to Research Methods*, 81–110. London: Sage.

Charmaz, Kathy

2000 Grounded Theory: Objectivist and Constructivist Methods. – Norman K. Denzin & Yvonna S. Lincoln (toim.), *Handbook of Qualitative Research*, 509–535. Thousand Oaks: Sage.

Corbin, Juliet & Anselm Strauss

2008 *Basics of Qualitative Research: Techniques and Procedures of Developing Grounded Theory*. Los Angeles: Sage.

<https://doi.org/10.4135/9781452230153>

Good, Marie & Teena Willoughby

2006 The Role of Spirituality Versus Religiosity in Adolescent Psychosocial Adjustment. *Journal of Youth and Adolescence* 35(1): 41–55.

<https://doi.org/10.1007/s10964-005-9018-1>

Holopainen, Teemu

2012 *Klusterointi hierarkkisilla ja kombinatorisilla menetelmillä - sovelluksena tilastomenetelmien peruskurssiaineisto*. Pro gradu -tutkielma: Jyväskylän yliopisto, matematiikan ja tilastotieteen laitos, tilastotiede.

Jang, Sung Joon & Aaron B. Franzen

2013 Is Being “Spiritual” Enough Without Being Religious? A Study of Violent and Property Crimes among Emerging Adults. *Criminology: An Interdisciplinary Journal* 51(3): 595–627.

<https://doi.org/10.1111/1745-9125.12013>

Keller, Barbara, Ramona Bullik, Constantin Klein & Sally B. Swanson

2018 Profiling Atheist World Views in Different Cultural Contexts: Developmental Trajectories and Accounts. *Psychology of Religion and Spirituality* 10(3): 229–243.

<https://doi.org/10.1037/rel0000212>

King, Ronald S.

2015 *Cluster Analysis and Data Mining: An Introduction*. Dulles: Mercury Learning and Information.

Laursen, Brett & Erika Hoff

2006. Person-Centered and Variable-Centered Approaches to Longitudinal Data. *Merrill-Palmer Quarterly* 52(3): 377–389.

<https://doi.org/10.1353/mpq.2006.0029>

Luomanen, Jari

2010 Straussilainen grounded theory -menetelmä. – Johanna Ruusuvoori, Pirjo Nikander & Matti Hyvärinen (toim.), *Haastattelun analyysi*, 351–371. Tampere: Vastapaino.

Meeusen, Cecil, Bart Meuleman, Koen Abts & Robin Bergh

2018 Comparing a Variable-Centered and a Person-Centered Approach to the Structure of Prejudice. *Social Psychological and Personality Science* 9(6): 645–655.

<https://doi.org/10.1177/1948550617720273>

Nadal, Amber, Sam A. Hardy & Carolyn McNamara Barry

2018 Understanding the Roles of Religiosity and Spirituality in Emerging Adults in the United States. *Psychology of Religion and Spirituality* 10(1): 30–43.

<https://doi.org/10.1037/rel0000104>

Pauha, Teemu & Atefeh Aghaee

2018 “God Never Existed, and I Was Looking for Him Like Crazy!” *Muslim Stories of Deconversion*. – Karin van Nieuwkerk (toim.), *Moving In and Out of Islam*, 333–359. Austin: Texas University Press.

Pauha, Teemu, Viivi Eskelinen, Inga Jasinskaja-Lahti, Jolanda Jetten, Jonas Kunst, Jolanda van der Noll, Tuuli Anna Renvik, Anette Rohmann & Antti Räsänen

2019 *Varieties of Atheist Identity*. Julkaisematon käsikirjoitus.

Schnabel, Landon, Matthew Facciani, Ariel Sincoff-Yedid & Lori Fazzino

2016 Gender and Atheism: Paradoxes, Contradictions, and an Agenda for Future Research. *Annual Review of the Sociology of Religion* 7: 75–97.

https://doi.org/10.1163/9789004319301_006

Sillfors, Mikko

2017 *Jumalattomuus ja hyvä elämä: Ateistinen henkisyys vaihtoehtona monoteistiselle uskonnolle 2000-luvun länsimaissa*. Väitöskirja: Helsingin yliopisto, Maailman kulttuurien laitos, Uskontotiede.

Sointu, Eeva & Linda Woodhead

2008 Spirituality, Gender, and Expressive Selfhood. *Journal for the Scientific Study of Religion* 47(2): 259–276.

<https://doi.org/10.1111/j.1468-5906.2008.00406.x>

Taylor, Scott

2010 Gendering in the Holistic Milieu: A Critical Realist Analysis of Homeopathic Work. *Gender, Work and Organization* 17(4): 454–474.

<https://doi.org/10.1111/j.1468-0432.2009.00478.x>

Toivonen, Timo

1999 *Empiirinen sosiaalitutkimus: Filosofia ja metodologia*. WSOY, Porvoo.

Xu, Rui & Donald C. Wunsch

2009 *Clustering*. Oxford: Wiley.

<https://doi.org/10.1002/9780470382776>