



# SUOMEN TILASTOSEURAN VUOSIKIRJA 2024

ÅRSBOK FÖR STATISTISKA SAMFUNDET  
I FINLAND 2024

THE YEARBOOK OF  
THE FINNISH STATISTICAL SOCIETY 2024

2024

---

# Sisällys

<b>Puheenjohtajan palsta: A.D. 2024</b>	<b>3</b>
PEKKA PERE	
<b>Sihteerin ja rahastonhoitajan palsta</b>	<b>11</b>
ROOPE RIHTAMO, ARVI TOLVANEN	
<b>Toimittajan palsta</b>	<b>16</b>
TOMMI HÄRKÄNEN	
<b>Laatumenetelmien kehitys tilastojärjestelmässä</b>	<b>19</b>
 KARI DJERF	
<b>Verkkokyselyt: Käytäntö ja data-analyysi</b>	
<b>Suomen Tilastoseuran iltapäiväseminaari 10.9.2024</b>	<b>31</b>
Avauspuheenvuoro	32
JUHA ALHO	
Verkkokyselyt puoluekannatuksen mittauksessa ja presidentinvaaleissa	34
SAKARI NURMELA	
Vastauskato kuluttajien luottamus -tilastossa	39
TARA JUNES	
Yksityiskohtaisten taustatietojen käyttömahdollisuuksista kyselyaineistojen analyysissä	42
RISTO LEHTONEN	
Kun vastauksiin pitää keksiä kysymyksiä – kokemuksia sosiaalisten verkkoaineistojen kesyttämisestä yhteiskuntatieteelliseen tutkimukseen	48
MIKA PANTZAR	
<b>Suomen Tilastoseuran hallitus vuonna 2023</b>	<b>56</b>
<b>Suomen Tilastoseuran hallitus vuonna 2024</b>	<b>57</b>
<b>Gunnar Modeen -minnesmedaljen</b>	<b>58</b>
<b>Scandinavian Journal of Statistics</b>	<b>60</b>
<b>Myönnetyt palkinnot</b>	<b>61</b>
Leo Törnqvist -palkinnot	61
Väitöskirjapalkinnot	63
<b>Suomen Tilastoseuran julkaisuja</b>	<b>64</b>

---

Tilastotieteellisiä tutkimuksia	65
Suomen Tilastoseuran vuosikirja	66
Muita julkaisuja	67

---

# Puheenjohtajan palsta: A.D. 2024

PEKKA PERE

PEKKA.J.PERE@AALTO.FI

MATEMATIIKAN JA SYSTEEMIANALYYSIN LAITOS  
AALTO-YLIOPISTO

Tilastollinen elämä palasi vuonna 2024 arkisempiin uomiin Tilastoseuran 100+-juhlavuoden 2023 jälkeen. Tiedevuosi 2024 alkoi Tieteiden yö –tapahtumalla Helsingissä 25.1. Seuran hallituksen puheenjohtaja 2018–2021 PAULIINA ILMONEN (Aalto-yliopisto) esitelmöi “Tavallisista tallaaajista ja huippuyksilöistä” seuran Tieteiden yö –tapahtumassa. Seuran sihteeri ROOPE RIHTAMO ja rahastonhoitaja ARVI TOLVANEN kertovat tapahtumasta ja osuudestaan siinä tarkemmin toisaalla Vuosikirjassa.

## Kursseja

Vuosi jatkui webinaarilla “Datajournalismin pikakurssi” 13.2. Seura järjesti sen yhteistyössä Suomen Syöpärekisterin ja Tilastokeskuksen kanssa.<sup>1</sup> Pikakurssilla käsiteltiin tilastollisen ajattelun ja satunnaisuuden perusteita, datan visualisointia ja toimittajille avoimia tietolähteitä. Webinaari oli AAPELI NEVALAN (Suomen Syöpärekisteri) ideoima. Kurssille ilmoittautui 101 datajournalismista kiinnostunutta.

Tilastoseura järjesti yhteistyössä Suomen Biostatistiikan Seuran kanssa valtakunnallisen tilastotieteen jatkokoulutuskurssin “Topics in Statistical Inference” 27.-31.5.<sup>2</sup> Kurssi pidettiin FDNSS:n (Finnish Summer School on Probability and Statistics) yhteydessä Lammilla. Luennoija oli professori RYAN MARTIN (North Carolina State University). Seuran hallituksesta kurssille otivat osaa Roope Rihtamo ja Arvi Tolvanen. He kuvaavat kurssia tarkemmin artikkelissaan Vuosikirjassa. Ilahduttavasti kurssi on poikimassa uutta päätteilyn teoriaa soveltavan pro gradu –tutkielman, ja tekijä haluaisi jatkaa aiheesta väitöskirjaan. Kurssi toi uusia näkemyksiä ja ajatuksia Suomeen.

Olin aloittaa edellisen kappaleen maininnalla seuralle uudenlaisesta toiminnasta. Tilastotieteen kurssin järjestäminen ei kuitenkaan ole seuralle aivan uusi asia: Tuleva seuran esimies 1925–1926 EINO SAARI esitelmöi seurassa 1924 “Matemaattisesta tilastosta”. Saarta pyydettiin esitelmänsä jälkeen järjestämään

---

<sup>1</sup><https://stat.fi/ajk/tapahtumat.html/datajournalismin-pikakurssi>.

<sup>2</sup><https://fdnss.fi/fdnss-intensive-course-topics-in-statistical-inference>.

kurssi “matemaattisesta tilastosta”. Osanottajia kurssille ilmoittautui kahdeksan, mitä ei pidetty riittävänä määränä. Seura päätti, että kurssin sijaan sopivampi tapa “matemaattisen tilaston harrastuksen levittämiseksi” on saada aikaiseksi “matemaattista tilastoa” käsittelevä oppikirja. Tilastoseura pyysi muita tieteellisiä seuroja mukaan hankkeeseen oppikirjan laatimiseksi. Seurojen muodostama valiokunta kysyi JARL WALDEMAR LINDEBERGIä kirjan tekijäksi. Lindeberg teki oppikirjan ja esitelmöi siitä Tilastoseurassa 1927. (Tudeer 1946.) Tilastoseuran aikoma kurssi poiki näin ensimmäisen suomenkielisen matemaattisen tilastotieteen oppikirjan “Todennäköisyyslasku ja sen käytäntö tilastotieteessä. Alkeellinen esitys” (Lindeberg 1927). Tilastoseura oli sata vuotta sitten ja on edelleen luonteva toimija valtakunnallisesti merkittävien tilastotieteellisten hankkeiden edistämiseen. Hyvä on huomata, että sata vuotta sitten kuten tänäänkin tieteellisten seurojen yhteistyössä on voimaa.

## Tilastopäivät Aalto-yliopistossa Espoossa 3.6.2024

Opiskelijoiden valintakokeiden takia vuoden päätapahtuma, Tilastopäivät<sup>3</sup>, pidettiin yksipäiväisinä. Ohjelma oli seuraavanlainen:

09.00–10.00	<b>Rekisteröityminen (aula)</b>	
10:00–10:15	<b>Pekka Pere</b> Tilastoseuran hallituksen puheenjohtaja	Tilastopäivien avaus
10.15–11.30	<b>Istunto 1</b>	
10:15–11:00	<b>Ryan Martin</b> North Carolina State University	Imprecise probability in statistical inference: why it’s needed, where it comes from, and how it’s beneficial
11:00–11:30	<b>Pauliina Ilmonen</b> Aalto-yliopisto	On modeling rare phenomena
11:30–13:00	<b>Lounastauko ja posterinäyttely</b>	
13.00–14.30	<b>Istunto 2: Tutkimuksen näyteikkuna</b>	
13:00–13:30	<b>Matti Pajari</b> Berakon	Definition-based quantile estimation
13:30–14:00	<b>Mari Myllymäki</b> Luke	The power of visualizing distributional differences: Formal graphical permutation tests and global quantile regression
14:00–14:30	<b>Joni Virta</b> Turun yliopisto	Poisson PCA for matrix count data
14:30–15:30	<b>Iltapäiväkahvi ja posterinäyttely</b>	
15.30–17.00	<b>Istunto 3: Tilastoalan uudet tuulet</b>	
15:30–16:00	<b>Ville Vertanen</b> Ylijohtaja Tilastokeskus	Tietotuotannon tulevaisuus - tietovarannot yhteiskunnan käyttöön

<sup>3</sup><https://tilastoseura.fi/tilastopaivat2024>

16:00–16:30	<b>Heikki Pursiainen</b> Kaupunkitieto- palveluiden päällikkö, Helsingin kaupunki	Kaupunkien tietotarpeet vs. uudet tietolähteet – case datahuonepilotti
16:30–17:00	<b>Timo Ståhl</b> Johtava asiantuntija, THL	Yritysten ja järjestöjen data julkisen sektorin käyttöön - haasteet ja mahdollisuudet: case THL:n PUHTI-hanke
17:15–18:00		
17:15–17:45		Posterikilpailun voittajan ja Leo Törnqvist –palkinnon voittajan julkistaminen
17:45–18:00	<b>Pekka Pere</b> Tilastoseuran hallituksen puheenjohtaja	Puheenvuoro
20:00–23:00	<b>Konferenssi-illallinen</b> ravintola Dylan Marmoripiha, Helsinki	

Pääpuhuja oli North Carolina State –yliopiston tilastotieteen professori Ryan Martin (kuva 1). Hän esitelmöi uudenlaisesta tilastollisen päättelyn teoriasta.<sup>4</sup> Avausistunnon toinen puhuja oli Pauliina Ilmonen (Aalto–yliopisto).

Posterikilpailun voitti Aapeli Nevalan (Suomen Syöpärekisteri) “Accelerated failure rates and regression for latent outcomes in cancer screening”. Leo Törnqvist –palkinto erityisen ansiokkaasta pro gradu –tutkielmasta myönnettiin ANTTI YLÄJÄRVELLE. Hän oli tehnyt tutkielmansa “Transformer –neuroverkon robustisuuden parantaminen Gaussisen prosessin ja neuroverkon yhdistävillä menetelmillä” Jyväskylän yliopistossa.

Tämänkertaisten Tilastopäivien erikoisuus oli pienimuotoinen näyttely seuraran hallituksen puheenjohtajan 1973 (silloisin termein esimiehen) LARS-ERIK ÖLLERIN piirustuksista suomalaisista tilastotieteilijöistä (mm. Elja Arjas, Anders Ekholm, Lasse Koskinen, Hannu Niemi, Kenneth Nordström, Jukka Nyblom, Markku Rahiala, Pentti Saikkonen, Timo Seppäläinen, Timo Teräsvirta, Yrjö Vartia ja Lars-Erik Öller; kuva 2). Päivillä oli osanottajia yli ja illallisella lähes neljäkymmentä.

Kiitän Tilastopäivien taloudellisia tukijoita: Aalto–yliopisto, Aalto Science Institute, SAS Institute Oy, Tieteellisten seurain valtuuskunta ja Suomalaisen Tiedeakatemian matematiikan rahasto. Kiitän myös Tilastopäivien 2024 valmistelyryhmää, jossa oli allekirjoittaneen lisäksi ARI JAAKOLA, REIJA HELENIUS, TOMMI HÄRKÄNEN, JYRKI MÖTTÖNEN ja ROOPE RIHTAMO.

<sup>4</sup>Esitelmä löytyy Martinin kotisivulta: <https://www4.stat.ncsu.edu/~rgmarti3//finland2024.pdf>.



Kuva 1: Ryan Martin esitelmöi 3.6.2024.

## Iltapäiväseminaari “Verkkokyselyt: käytäntö ja data-analyysi” Tieteiden talossa Helsingissä 10.9.2024

Aloite iltapäiväseminaariin<sup>5</sup> tuli JUHA ALHolta, joka myös kokosi esitelmöijät ja avasi tilaisuuden. Tilaisuuden ohjelma ja esiintyjien kirjoitukset löytyvät Vuosikirjan sivuilta 31–55.

## Yhteistyötä muiden järjestöjen kanssa

Tieteellisten seurain valtuuskunnan hallituksen jäsenistä neljä oli vaihtovuorossa 23.9. Tilastoseura, Suomen Biostatistiikan Seura ja Suomen matemaattinen yhdistys nimesivät tilastotieteen professori JUHA KARVASEN (Jyväskylän yliopisto) ja matematiikan professori PEKKA PANKAN (Helsingin yliopisto) seurojen ehdokkaiksi hallituksen jäseneksi ja varajäseneksi. Tieteellisten seurojen edustajia oli paikalla ennätysmäärä seitsemänkymmentä. Ehdokkaamme eivät valitettavasti tulleet valituiksi.

Yhteistyö Suomen Biostatistiikan Seuran kanssa jatkui – aiempien vuosien tapaan – tilaisuudella Finnish Young Statisticians Workshop (nuorten tilastotieteilijöiden työpaja) 12.11.2024 Aalto-yliopistossa Espoossa. Väitöskirjatutkija JAAKKO PERE (Aalto-yliopisto) vastasi tapahtuman konkreettisesta toteutuksesta. Paikalla oli kolmetoista nuorta tilastotieteilijää kuudesta eri yliopistosta, ja yksitoista osallistujaa piti esitelmän.

Edustin edelleen Tilastoseuraa ECAS-organisaation (European Courses in Advanced Statistics, <https://ecas.fenstats.eu/>) kokouksissa (26.3., 7.11.

<sup>5</sup><https://tilastoseura.fi/fi/iltapaivaseminaarit>.





ja 18.11.). REIJA HELENIUS (Tilastokeskus) edusti seuraamme FENStatS-organisaatiossa (The Federation of European National Statistical Societies, <https://www.fenstats.eu>).

Tilastoseura edistää tilastojen luku- ja käyttötaitoa yhteiskunnassa mukaan lukien nuorten keskuudessa. Seuran siipien suojassa toimii kattojärjestömme International Statistical Institutun alajärjestö International Statistical Literacy Project. Maailmanlaajuista projektia koordinoi hallituksemme jäsen Reija Helenius. Kilpailussa on sarjoja alakoulusta yliopistotasoon. Edelliseen kilpailuun otti osaa yli 20 000 nuorta. Vuonna 2024 projekti käynnisti jo kahdeksannen nuorten tilastojulistekilpailun.

## Tilastoseuran julkaisut

Tilastoseuran kirja tilastotieteen historiasta Suomessa etenee. Kirjoittajakunta ja lukujen aiheet ovat osin vaihtuneet projektin aikana. Moni luku on jo vertais-arvioitu, mutta moni on vielä keskeneräinen. Tieteen historian kirjoittaminen on työläämpää kuin saattaisi kuvitella, eivätkä kaikki kirjoittajat – mukaan lukien allekirjoittanut – ole löytäneet riittävästi aikaa kirjoittamiselle. Kirja tulee silti. Kirjoittajat kokoontuivat kaksitoista kertaa vuoden aikana. Työ kiehtovan paljolti tutkimattoman aiheen parissa jatkuu.

Tilastoseuran sanastotyöryhmä — emeritusprofessori ESA LÄÄRÄ (Oulun yliopisto), professori Juha Karvanen (Jyväskylän yliopisto), professori LASSE LESKELÄ (Aalto-yliopisto) ja allekirjoittanut — kokoontui neljä kertaa vuoden aikana. Ryhmä on pohtinut Tilastoseuran Tilastosanasto-sivun<sup>6</sup> kautta jätettyjä ehdotuksia ja toiveita tilastotieteellisten termien uusiksi suomennoksiksi. Ryhmä on myös itse kerännyt uusia suomennettavia termejä. Ryhmä jatkaa toimintaansa vuonna 2025 ja tulee tekemään vuonna 2025 Tilastosanastohakukoneen ensimmäisen päivityksen. Ryhmä on kiitollinen monista lähetetyistä ehdotuksista suomennettaviksi termeiksi. Lähettäkää ehdotuksia edelleen, kiitos!

Sanasto on osoittanut hyvin suosituksi. Tätä kirjoitettaessa viimeisellä täydellä viikolla, jolta on kirjattu haut, sivustolla asioitiin arkipäivinä keskimäärin 1236 kertaa päivässä. Viikonloppuna hakuja oli keskimäärin 872 päivässä. Numerot ovat suuntaa antavia, sillä sivuilla käy epäilemättä hakurobotteja. On tavattoman kannustavaa, että sanasto on otettu näin aktiiviseen käyttöön ja hienoa, että Tilastoseura on näin hyvin osannut palvella jäsenkuntaansa ja muita tilastotieteen käyttäjiä Suomessa ja ehkä ulkomaillaakin.

Kertaan tässä ohjeet (vuodelta 2023) sanaston linkittämiseksi pikakuvakkeella omaan Android-puhelimeen. Niin sanastosta voi helposti ja nopeasti tarkistaa suomennokset ja englanninnokset tilastotieteen termeille missä liikkeukaan:

Mene kännykän selaimella sivulle <https://sanasto.tilastoseura.fi/>. Puhelimen näytön ylä- tai alalaidassa on kolme pistettä päällekkäin. Paina niitä, ja valitse avautuvasta valikosta Lisää aloitusnäyttöön. Ohjelmisto ehdottaa linkin otsikoksi Tilastotieteen sanaston verkkoversio. Hyväksy se, tai lyhennä esimerkiksi muotoon Tilastotieteen sanasto, ja hyväksy. Lopuksi valitse Lisää. Nyt sanaston hakukone on kännykkäsi avausnäytöllä sormennäpäytyksesi päässä käytettävissä. Vierittämällä näyttöä alaspäin saat esille sanaston pdf-version, josta voit lukea perusteluja termivalinnoille.

---

<sup>6</sup><https://sanasto.tilastoseura.fi>.

Suomen tiedekustantajien liitto ry ja Kopiosto solmivat kollektiivisen arki-  
tolupalisenssin vuonna 2024. Yritimme saada Tilastoseuran ennen vuotta 1999  
julkaistut Vuosikirjat sen piiriin, mutta se ei onnistunut. Vanhat digitoidut Vuo-  
sikirjamme ovat silti edelleen luettavissa kirjastoissa, joissa on vapaakappaletyö-  
asema (ks. Pere 2023). Vuosikirjasta 2013–2014 lähtien Vuosikirjat ovat vapaasti  
luettavissa Tilastoseuran kotisivuilta. Uudet Vuosikirjat saavuttavat näin mah-  
dollisimman laajan lukijakunnan.

Tämä on kolmas Vuosikirja, jossa on vertaisarvioitu artikkeli – nyt jo kah-  
desti Tieteellisten seurain valtuuskunnan vertaisarviointitunnuksella vahvistet-  
tuna. Kiitän päätoimittajan puolesta kirjoittajia ja vertaisarvioijia. Tarjotkaa  
käsikirjoituksia Vuosikirjaan! Aiheet voivat olla moninaisempia kuin perintei-  
sessä tieteellisessä aikakauskirjassa, ja kieleksi sopii erinomaisesti myös suomi.  
Vertaisarviointi parantaa kirjoitusten tasoa ja avaa uusia rahoitusväyliä Vuosi-  
kirjan toimittamiseen.

## Muuta merkittävää

Jäsenemme voivat edelleen hyödyntää Cambridge University Pressin, CRC Pres-  
sin ja Wileyn kirja-alennuksia. Viimeksi mainittu on erityisen suuri 35 %. Ox-  
ford University Pressiltä saamme niin ikään edelleen Royal Statistical Society, ja  
American Statistical Associationin ja Statistical Society of Australian julkai-  
seman Significance-lehden vuositilauksen edullisesti. Käyttäkää jäsenetujam-  
me, niin niiden tarjoajat haluavat jatkaa niitä. Sihteerimme antaa lisätietoja  
(sihteeri@tilastoseura.fi).

Seuran sääntöjä uudistettiin vuoden 2024 aikana.<sup>7</sup> Roope Rihtamo ja Arvi  
Tolvanen perustelevat sääntöuudistusta artikkelissaan. Myös hallitus uudistui  
jäsenkokouksessa 29.2.2024 ja lisää uudistettujen sääntöjen mukaisessa syysko-  
kouksessa 21.11.2024. Hallituksessa on nyt uutena jäsenenä dosentti, yliopis-  
tonlehtori PEKKA NIEMINEN (Turun yliopisto) ja uutena varajäsenenä entinen  
sihteerimme (1985–1988) YTL KARI DJERF (Tilastokeskus 1984–2020). Kiitän  
lopuksi jälleen hallitusta ahkeruudesta tilastotieteen eteen työskentelemisessä.  
Kuulen erittäin mieluusti kaikista, joita toiminta perinteikkäässä tieteellisessä  
seurassa kiinnostaa. Nykyiset etätyökalut mahdollistavat vaivattomasti täysipai-  
noisen osallistumisen kaikkialta Suomea. Olkaa yhteydessä! Tulkaa tutustumaan  
ja osallistumaan toimintaan vaikkapa seuraavilla Tilastopäivillä Tampereen yli-  
opistossa 9.–10.6.2025.

Seura toimii erittäin aktiivisesti ja tuloksellisesti monella tavalla vuonna 2024.  
Kiitän kaikkia toiminnan ja tapahtumien eteen työtä tehneitä ja kaikkia osallis-  
tuvia.

Tiedevuosi 2024 päättyi upeasti. Yrjö Jahnssonin säätiö osoitti 16.12. jo-  
ka toinen vuosi myönnettävän tiedepalkintonsa 20 000 euroa seuran hallituksen  
jäsenelle professori MIKA GISSLERille.<sup>8</sup> Palkinto myönnettiin “urauurtavasta  
kansallisten rekisterien, kuten syntymä- ja terveysrekisterien, käytöstä tervey-  
den tutkimuksessa sekä laajasta yhteistyöstään yliopistojen ja sairaaloiden kans-  
sa”. Yhdymme epäilemättä kaikki seurassa onnitteluihini Mikalle!

<sup>7</sup>Uusiin sääntöihin voi tutustua osoitteessa <https://tilastoseura.fi/fi/saannot>.

<sup>8</sup><https://www.yjs.fi/yjsn-tiedepalkinnot-mika-gisslerille-ja-unt-o-hakkiselle>.

## Viitteet

Lindeberg, J. W. 1927. *Todennäköisyyslasku ja sen käytäntö tilastotieteessä. Alkeellinen esitys*. Otava.

Pere, P. 2023. Puheenjohtajan palsta: Tehdään tästä numero. *Suomen Tilastoseuran vuosikirja 2019–2022*. Suomen Tilastoseura.

Tudeer, A. E. 1946. *Suomen Tilastoseura 1920–1945*. Suomen Tilastoseura.

---

# Sihteerin ja rahastonhoitajan palsta

ROOPE RIHTAMO, ARVI TOLVANEN

Vuosi 2024 oli monella tapaa erilainen, erityisesti Tilastoseuran sihteerin ja rahastonhoitajan näkökulmasta. Vuosi piti sisällään niin sääntöuudistuksen kuin ensimmäistä kertaa yhdessä Suomen Biostatistiikan Seuran kanssa järjestetyn tilastotieteen kansallisen jatkokoulutuskurssin. Kerromme tällä palstalla, millä näiden parissa työskentely sekä kurssille osallistuminen ja seuran toiminta näyttävät seuran toimihenkilöiden näkökulmasta

## Tieteiden yö

Tilastoseura on esitellyt toimintaansa Tieteellisten seurain valtuuskunnan järjestämässä ja koordinoimassa Tieteiden yössä ensimmäistä kertaa vuonna 2024 ja nyt toistamiseen vuonna 2025. Tieteiden yö on tieteen oma kaupunkitapahtuma Helsingissä koostuen luennoista, osallistavista työpajoista sekä tieteellisten yhdistysten esittelypöydistä Tieteen talolla. Tapahtuma levittäytyy ympäri Helsinkiä, keskittyen kantakaupunkiin.

Tilastoseuran esittelypisteellä on esitelty seuran toimintaa sekä osallistettu Tieteen talon vieraita tilastollisiin aktiviteetteihin. Jälkimmäiseen lukeutuu mm. seuralle hankitun Galtonin koneen esittely ja siitä syntyneet keskustelut tilastojen ja todennäköisyyksien tulkintaan ympäröivää maailmaa tutkittaessa. Lisäksi seuralla oli vuonna 2024 ajankohtaisia presidentinvaaleja koskeva otantateoreettinen simulointiesimerkki. Sen avulla havainnollistettiin kävijöille otannan haasteita mm. otoskoon vaikutuksesta kyselytutkimuksen tuloksiin sekä virhemarginaalien tulkintaan. Vuonna 2025 esittelimme jälleen otantateoriaa, mutta tällä kertaa internetistä löytyvällä simulointiesimerkillä. Kyseisen simulointiesimerkin löytää helposti verkosta googlettamalla sanat “Rock ‘n Poll”.

Tilastoseura on myös kutsunut Tieteiden talolle tilastotieteen tutkijoita pitämään esitelmiä ajankohtaisista aiheista. Vuonna 2024 seura kutsui professori PAULIINA ILMOSEN, joka piti esitelmän otsikolla “Tavallisista tallaaajista ja huipputyksilöistä”.

## Tilastotieteen jatkokoulutuskurssi

Suomen Tilastoseura ja Suomen Biostatistiikan Seura päättivät vuonna 2023, että järjestämme jatkossa kansallisen tilastotieteen jatkokoulutuskurssin. Tavoite on järjestää kurssi vuosittain niin, että kurssin aiheena toimii vuorovuosin

tilastollinen päättely ja jokin uudempi tilastotieteen ala, joka on kulloinkin ajan-kohtainen.



Kuva 1: Professori Ryan Martin luennoi jatkokoulutuskurssin “Topics in Statistical Inference” Lammilla.

Kurssin ensimmäinen toteutuskerta kuului näistä ensimmäiseen. North Carolina State Universityn tilastotieteen professori RYAN MARTIN luennoi kurssin, aiheenaan “Topics in Statistical Inference”, eli kurssilaiset pääsivät syventymään hyvinkin keskeisiin aiheisiin tilastotieteen teoriassa. Kurssi järjestettiin osana FDNSS:n (Finnish Doctoral Education Network in Stochastics and Statistics) perinteistä kesäkoulua, joka järjestetään vuosittain Helsingin yliopiston biologisella asemalla Lammilla.

Kurssille ilmoittautui 16 osallistujaa, joka oli linjassa seuran odotusten kans-

sa. Osallistujat olivat niin tilastotieteen maisteri- tai tohtoriopiskelijoita kuin myös tilastollisella alalla työskenteleviä alan ammattilaisia. Tavoiteltu kohdeyleisö siis saavutettiin. Martin onnistui kohdentamaan kurssin sisällön niin, että jokainen osallistuja sai siitä irti itselleen uusia ja mielenkiintoisia oppeja.

Biologisen aseman puitteet olivat kurssin kannalta ihanteelliset: majoittuminen tapahtui kahden hengen huoneissa, ravintola tarjosi maukasta ruokaa kolmesti päivässä ja päivittäin saunottiin ja uitiin rantasaunalla. Näiden lisäksi Lammilla oli mielenkiintoisia luontopolkuja ja muuta puuhaa, kuten esimerkiksi vuokrapyöriä, joilla pääsi helposti Lammin keskustaan nauttimaan suomalaisen maalaiskylän tunnelmasta.

Kiitämme seuran ja osallistujien puolesta kurssin sponsoreita: Estimates, Radiometer, SAS Institute Oy ja STAT.

Toimivuonna 2025 tilastotieteen kansallinen jatkokurssi järjestetään Tampereen yliopiston keskustakampuksella. Tänä vuonna aiheeksi on valikoitunut usealla eri sovellusalalla ajankohtainen kausaalipäätely. Jyväskylän yliopiston tilastotieteen professori JUHA KARVANEN luennoi kurssin.

## Tilastoseuran sääntöuudistus

Menneen toimikauden aikana toteutettiin Tilastoseuran sääntöuudistus. Idea uudistukseen lähti seuran monivuotisten toiminnantarkastajien TOPIAS TOLOSEN ja LEENA KALLIOVIRRRAN toiminnantarkastuskertomusten kommentteista.

Ongelma, jonka sääntöuudistus korjaa, liittyi seuran toimi- ja tilikausien poikkeaviin vuosiakatauluihin. Aiempien sääntöjen mukaan vuosikokous pidettiin vuosittain alkuvuodesta, jolloin myönnettiin myös edellisen kauden hallitukselle vastuuvapaus. Tilikausi sen sijaan oli, ja on edelleen, kalenterivuoden mittainen.

Toiminnantarkastajat tarkistavat seuran edellisen toimikauden toiminnan niin kirjanpidon kuin hallituksen kokousten ja vuosikokousten pöytäkirjojen avulla. Seuran hallituksen toimikausi ulottui vanhojen sääntöjen perusteella maaliskuun alusta seuraavan vuoden helmikuun loppuun, kun seuran tilikausi on kalenterivuosi, ulottuen vuoden vaihteesta seuraavaan. Täten seuran alkuvuoden toiminta oli vastuuvapauden myöntämisen kannalta eräänlaista katvealuetta. Kirjanpito suoritetaan kalenterivuositain, joten tammi-helmikuun osalta tarkastettava kirjanpito sijoittui edellisen hallituksen toimikaudelle. Toisin sanoen, tarkastettava kirjanpitoaineisto ulottui ajallisesti tarkistettavaa toimikautta edeltäneen hallituksen toimikaudelle. Tämä johti siihen, että mikäli toiminnantarkastajat suosittelivat vastuuvapauden myöntämistä edellisen toimikauden hallitukselle, perustuu tämä suositus osaltaan tarkastettua toimintaa edeltäneen hallituksen taloudelliselle toimikaudelle. Tämän ajallisen epäjohtomukaisuuden vuoksi ei ollut aina täysin selvää, kenelle vastuuvapautta ollaan myöntämässä.

Allekirjoittaneet ryhtyivät sääntöuudistuksen valmistelijoiksi hallituksen päätöksellä. Erityisen mieleenpainuva muisto yhdistää sääntöuudistuksen Lammille tilastotieteen jatkokoulutuskurssin yhteyteen. Majoitustilojen oleskelutilassa luonnostelimme ensimmäistä sääntöuudistusehdotusta, jonka innoittajana toimi mm. Suomen matemaattisen yhdistyksen ja muutaman muun vastaavaa toimintaa harjoittavan tieteellisen seuran säännöt. Lopulta päädyimme muuttamaan seuran sääntöjä kokonaisvaltaisesti, mm. ottamalla käyttöön perinteisen pykälänotaation.



Kuva 2: Roope Rihtamo ja Arvi Tolvanen.

Jatkossa Tilastoseuran toimikausi yhtyy tilikauteen, molempien ollessa kalenterivuoden mittaisia. Lisäksi seuralla on jatkossa kaksi vuosikokousta, kevät- ja syyskokous. Näistä ensin mainitussa esitellään edellisen toimikauden tilintai toiminnantarkastuskertomus ja päätetään tilinpäätöksen vahvistamisesta ja vastuuvapauden myöntämisestä. Toisin sanoen, jatkossa yhden hallituksen toimikausi täsmää ajallisesti seuran tilikauteen, joten toimintaa tarkastettaessa ja vastuuvapautta myönnettäessä ei ole aiemmin mainittua kirjanpidollista katvealuetta ja on täten selvää, kenelle vastuuvapaus myönnetään.

Kevätkokouksen lisäksi syksyisin järjestetään seuran varsinainen vuosikokous, jossa mm. valitaan seuraavan toimikauden hallitus sekä päätetään jäsenmaksuista ja toimihenkilöiden palkkioista. Uutena asiana varsinaisen vuosikokouksen asialistalle lisättiin seuran talousarviosta päättäminen.

Sääntöuudistuksen tekeminen oli erittäin antoisa kokemus. Sitä tehdessä pääsi perehtymään tarkemmin yhdistysten toimintaa ohjaavaan lainsäädäntöön sekä pohtimaan yleisellä tasolla tarkemmin Tilastoseuran osalta sitä, miten säännöt

voidaan kirjoittaa niin, että ne ohjaavat seuran toimintaa. Opimme myös, että yhdistyksen toiminnan liiallinen sääntely tiukoilla säännöillä voi sekin olla liian tukahduttavaa. Toivomme, että sääntöuudistus on onnistunut niin, että uusien sääntöjen avulla jäsenenä on helpompi seurata seuran toimintaa, toiminnan-tarkastajana tarkastaa sitä sekä hallituksen jäsenenä hoitaa tehtäviään. Tulevat toimikaudet näyttävät, miten sääntöuudistus onnistui. Osaltamme olemme iloisia päästessämme jatkamaan tehtävissä seuran hallituksessa myös kuluvana toimikautena.



---

# Toimittajan palsta

TOMMI HÄRKÄNEN

TOMMI.HARKANEN@THL.FI

TERVEYDEN JA HYVINVOINNIN LAITOS (THL)

**Matkakertomus: Suomen tiedekustantajien liiton ryhmämatka Lontoon kirjamesuille 12.-15.3.2024**



Kuva 1: Olympia London.

## Messut

Lontoon kirjamesut järjestettiin Olympia London -messukeskuksessa. Suurten kustantajien lisäksi messuilla olivat edustettuina monet maat. Kiinan ja arabimaiden osastot olivat suurimpia ja näyttävimpiä. Myös Virolla oli oma osasto, mutta Suomella ei. Aihealueita oli laajasti tiedekustantamisesta lastenkirjallisuuteen. Messuilla oli myös oma osastonsa kustantajien ja kirjailijoiden tapaa- mista varten.

Yleisiä aiheita messuilla näytti olevan tekoälyn hyödyntäminen ja siihen liittyvät haasteet. Kirjoittajien ja tekijänoikeuksien haltijoiden kannalta voi olla järkevää estää omien materiaalien käyttäminen tekoälyn koulutusmateriaalina

– myös Creative commons -lisenssien käyttämistä kannattaa selvittää huolellisesti. Luultavasti suurten kustantajien, joilla on suuri määrä aiemmin julkaistuja artikkeleita ja kirjoja sekä arvioijien lausuntoja tekoölyn opetusmateriaalina, mahdollisuudet hyödyntää tekoölyä ovat selvästi suuremmat kuin pienten tieteellisten seurojen. Tekoölyä käsiteltiin useissa esitelmissä ja paneelikeskusteluissa, mutta kuulijoiden määrää rajoitti esiintymistilojen pienuus, joten muutama mielenkiintoinen tilaisuus jäi kuulematta.

Lohkoketjut esitettiin mahdollisuutena kirjoittajille kontrolloida paremmin omia tekijänoikeuksia ja jakaa teoksia ilman kustantajaa, mutta oma seuramme julkaisee teoksensa lähinnä avoimesti saataviksi. Monia muitakin työkaluja esiteltiin esim. opetuskäyttöön.

Seuramme julkaisee matemaattisia kaavoja useimmissa julkaisuissaan, ja olemme käyttäneet ilmaista L<sup>A</sup>T<sub>E</sub>X-taitto-ohjelmaa. Kirjoittajat usein toimittavat kirjoituksensa tässä formaatissa, mikä helpottaa taittajamme työtä ja säästää kustannuksia. Messuilla oli muutama yritys, jotka esittelivät L<sup>A</sup>T<sub>E</sub>X-työkaluja. Prosessi käsikirjoitusten lähettämisestä, vertaisarvioinnista taittamiseen eri formaatteihin (pdf, epub). Toinen yritys tarjosi saavutettavuuden parantamiseksi alt-tekstin automaattisen tuottamisen matemaattisille kaavoille.

## Teemapäivä tieteellisestä kustantamisesta

Päivän aikana kuulumme useita paneelikeskusteluja. Keskustelijat olivat enimmäkseen suurten kustantajien edustajia.

### Strategies and trends in academic publishing

Teknologia kehittyy nopeasti, ja työkalut muuttuvat tehokkaammiksi. Hyödyllisiä työkaluja voisivat olla tulevaisuudessa esim. saavutettavuutta automaattisesti parantavat työkalut. Tilastoseuran näkökulmasta esim. matemaattiset kaavat voisivat olla tällaisia, koska esim. kuviin voi jo nykyisin liittää alt-tekstin melko helposti. Muita kiinnostavia tavoitteita voisivat olla esim. multimedian laajempi käyttö (ääni ja videot Tilastoseuran seminaariesityksistä, animaatiot osana seuran verkkosivustoa tilastotieteen popularisointia varten, vuosikirjaa ja muita julkaisuja) ja tekstitysten liittäminen näihin.

Yhtenä kehittämiskohteena nähtiin julkaisujen muuttaminen vuorovaikutteisemmiksi, kuten keskustelupalstojen lisääminen verkkosivuille. Meillä tilastosanasto toimii jo interaktiivisena verkkosovelluksena, jonne lukijat voivat lähettää lisäspyyntöjä, -ehdotuksia ja kommentteja, jolloin sisältö on aina ajan tasalla.

Avoin julkaisu on meillä jo käytössä, eli kaupallisilla kustantajilla tuntuu olevan paljon työtä, että tieteelliset julkaisut olisivat laajasti saatavilla ilman korkeita kustannuksia. Tieteellisen tiedon tiivistäminen, taittaminen ja hiilijalanjäljen pienentäminen olivat myös esillä.

Vertaisarviointiprosessissa mm. viitteiden automaattinen tarkistaminen ja arviointiprosessin laadun parantaminen olivat esillä, mutta selviä ratkaisuja ei tuntunut olevan.

### Political changes

Tekoölyn kehittämisen mahdollisuudet ja sen tarvitsemat aineistot nähtiin osittain vastakkaisina verrattuna tekijänoikeuksien suojeluun ja lainsäädännön aiheuttamiin rajoituksiin. Tässä on tarpeen arvioida, pitäisikö esim. Vuosikirjan

osalta tarkentaa tekijänoikeuksien merkitsemistä verkossa oleviin Vuosikirjoihin ja muihin julkaisuihin. Näkökulma oli brittiläinen, eli UK vs. EU, ja tulevien vaalien vaikutuksesta keskusteltiin. Myös tiedon luotettavuus nostettiin esiin suhteessa sananvapauteen.

### **Transformative influence of AI on academic publishing**

Pienten kustantajien mahdollisuudet ottaa tekoäly käyttöönsä nähtiin ongelmallisena tarvittavien taloudellisten resurssien takia. Luultavasti myös tekoälyn tarvitseman opetusmateriaalin rajallisuus voi olla usein ongelma. Yleinen tietämys keskeisestä AI-terminologiasta on puutteellista. Tekoälyä voidaan käyttää väärin esim. viittausmäärien peukaloinnissa, mutta voi pienentää kielimuurin vaikutuksia. Tämä helpottaa tulevaisuudessa informaation löytämistä omalla kielellä, jolloin esim. suomen käyttö Vuosikirjassa voi olla vähemmän tärkeää.

### **Open access, evolving role**

Taloudelliset resurssit sekä kirjoittajille että lukijoille voivat olla ongelmallisia. Preprint-palveluissa julkaistujen käsikirjoitusten laatu on ollut puutteellista, eli vertaisarvioinnin saaminen myös vuosikirjaan on tärkeää.

### **Muu kulttuuriohjelma**

Opastettu kierros British Libraryssa esitteli hyvin kansalliskirjaston toimintaa. Näytteillä oli monia historiallisia teoksia. Mieleenpainuvien opetus oli tietoturvasta huolehtiminen: edes kansalliskirjastot eivät ole välttämättä turvassa. Myös tieteellisten seurojen on syytä huolehtia mm. verkkosivujensa tietoturvapäivityksistä. Kävimme nopeasti myös British Museumissa.

Kirjakauppakierros osoitti konkreettisesti, miten valtavan monipuolinen tarjonta englanninkielisessä kirjallisuudessa on myös harvinaisten tutkimusalojen osalta. Suomenkielisen tarjonnan lisäämiseksi on ponnistettava ja löydettävä tapoja kannustaa kirjoittajia ja arvioijia tekemään työnsä pienillä kustannuksilla – taloudellinen tuki tuskin lisääntyy lähiaikoina.

Perjantai-aamuna ehdin vielä käydä Tate Britain -taidemuseossa ihastelemaan maalauksia eri aikakausilta, japanilaista puutarhaa hotellin lähellä olevassa Holland Parkissa ja vielä nopeasti kirjakaupassa ennen lentokentälle siirtymistä.

Kiitän lämpimästi Suomen Tiedekustantajien liittoa mahdollisuudesta osallistua kiinnostavalle opintomatkalle!

# Laatumenetelmien kehitys tilastojärjestelmässä

KARI DJERF  
KARI.DJERF@GMAIL.COM



## Tiivistelmä

Artikkelissa kuvataan virallisen tilastotoimen laatujärjestelmän kehittymistä. Alkuvaiheena voidaan pitää väestölaskentoja ja niissä esiintyneitä virhetyyppisiä, mutta laadunvalvonta oli pitkään epäsystemaattista. Kun otantamenetelmät kehittyivät 1900-luvun alkupuolella, niihin liittyvät laatumittarit, kuten keskivirheet, tulivat luonnollisesti mukaan. Systemaattiset laaturaportoinnit kehitettiin Yhdistyneiden Kansakuntien puitteissa niin väestölaskentoihin kuin otantatutkimuksiinkin 1950-luvun alussa. 1900-luvun lopulla käyttöön on tullut kokonaislaadun hallintamenetelmät. Niistä esitetään kahden yleisen menetelmän (ISO 9001 ja EFQM) yleispiirteet sekä kokonaislaadun hallintaan perustuvat Euroopan tilastojärjestelmän käytäntönsäännöt.

## Johdanto

Suomen tilastojärjestelmä arvioitiin Maailmanpankin mittauksessa maailman parhaaksi toisen kerran peräkkäin (Tilastokeskus 2024). Saavutus on hieno, mutta tällaiset sijoitusvertailut eivät välttämättä kerro koko kuvaa tilastoihin liittyvästä laatuajattelusta. Tässä artikkelissa kuvataan laatuasioiden kehitystä alkuvaiheista nykytilanteeseen. Samaa aihepiiriä on aiemmin käsitelty kirjoittajan lyhyessä artikkelissa (Djerf 2008), mutta tähän versioon on lisätty paljon historiaa sekä tietoja viime vuosina tapahtuneista suurehkoista muutoksista, erityisesti Euroopan unionin puitteissa.

## Juuret väestölaskennoissa ja otantateoriassa

Tilastojen laatuun liittyvä kuvaus sai alkunsa väestölaskennoista: laskennan kattavuutta ja erilaisten virhelähteiden vaikutusta tuloksiin on arvioitu luultavasti

hyvin pitkältä aikaa ja varmuudella 1800-luvulta alkaen, mutta epäsystemaattisesti. Steckel (1991) kuvaa artikkelissaan useita erilaisia virhelähteitä Yhdysvaltojen 1800-luvun väestölaskennoissa, esim. mustan väestön alipeiton tai merkitseminen vähäjärkisiksi (rotuerottelun lopettamista vastustaakseen). Mutta mukaan mahtuu myös olennaisia laadunvarmistuksia, kuten uudelleenlaskennat New Yorkissa ja Philadelphiassa v. 1870.

Menetelmät alkoivat vakioitua vasta 1950-luvun puolivälissä YK:n tilastokomitean suosituksista. Sitten väestölaskentojen laadunvarmistus ja laatukuvaus ovat hyvin standardoituja (United Nations 2017, 2022).

Otantateoriassa on tarve arvioida estimaattoreiden ominaisuuksia sekä aineistoista saatujen estimaattien luotettavuutta, usein keskivirheiden avulla. Varsinaiset todennäköisyysotannan menetelmät kehittyivät 1900-luvun alkupuolella, kehittäjinä Bowley, Neyman ym. 1920- ja 1930-luvuilla. Niiden soveltaminen käynnistyi suuressa mittakaavassa mm. Yhdysvalloissa ja Intiassa 1930-luvun lopulta alkaen, muualla hiukan myöhemmin. Otantatutkimusten laatua raportoitiin pääasiassa tarkkuuden näkökulmasta, ensin otantavirheen avulla, myöhemmin arvioitiin myös muiden virhelähteiden kuten mittausvirheiden vaikutusta.

Otantatutkimusten ensimmäinen laatua koskeva kansainvälinen standardi on YK:n tilastokomitean julkaisema ”The Preparation of Sampling Survey Reports” (United Nations 1950). Siinä suositetaan raportoitavan seitsemää pääaluetta:

1. Tutkimuksen yleiskuvaus
2. Tutkimuksen asetelma
3. Otosyksiköiden valintamenetelmä
4. Henkilöstö ja työvälineet
5. Tilastollinen analyysi ja tiedonkäsittely
6. Kustannusanalyysi
7. Tutkimuksen tarkkuus

Jokaiseen pääalueeseen sisältyy tarkennuksia, mitä kaikkea raporttiin on syytä sisällyttää. Alkuvaiheen raportoinnin suunnittelussa tilastotieteilijöillä oli keskeinen asema. Suosituksen täydennetty versio julkaistiin v. 1964. Siinä oli kehitetty terminologiaa keskeisen sisällön pysyessä ennallaan.

## Laadun raportointi Suomessa

Vuoden 1950 Suomen ensimmäisen suoraan tiedonkeruuseen perustuneen ja koko maan kattaneen väestölaskennan tietoja lienee tarkistettu monella tapaa. Luther (1993, 243) toteaa, että tiedot tarkistettiin paikallisesti. Varsinaisista julkaisuista ei ilmene kuvauksia virhelähteiden arvioinnista. Erilaisia tarkistuksia on varmasti tehty, mutta menetelmistä ei ole säilynyt julkaistua tietoa. Seuraavista väestölaskennoista v. 1960 alkaen tietoja on julkaistu.

Kattavien virallisen tilaston otantaperusteisten sosiaalitutkimusten historiasta löytyy monenlaista laadunkuvausta: osassa menetelmistä ja virheistä on raportoitu hyvin, osasta ei lainkaan. Tilastokeskus laati ensimmäisen yleisen ohjeistuksensa v. 1987, kun käsikirja ”Tilastojen laadun kuvaaminen” ilmestyi. Ajan käytännön mukaisesti se keskittyi otostutkimuksiin. Julkaisusta alkoi hitaan siirtymän vaihe kohti vakiointia, ensin laadun kuvaamisessa, myöhemmin

menetelmissä ja toimintatavoissa. Sosiaalitilastot olivat kärjessä, sen sijaan otospohjaisten yritystilastojen osalta laadun kuvaaminen alkoi huomattavasti myöhemmin.

## Tilastoalan laatukäsikirjat

Useat tilasto-organisaatiot ryhtyivät laatimaan erilaisia ohjeistuksia 1980-luvulla, mutta yhden parhaana pidetyn organisaation julkistuksesta tuli käännekohta: Kanadan tilastoviraston käsikirja ”Quality Guidelines” (Statistics Canada 1985). Käsikirjassa oli hyvin kokonaisvaltainen ote laadun hallintaan erilaisissa tilastosysteemeissä. Nykyinen ohjeistus on versio kuusi vuotta vanha 2019. Vastaavia yleisiä ohjeistuksia on laadittu useissa maissa.

Suomessa Tilastokeskuksen piirissä laadunhallinta oli myös noussut merkittäväksi kohteeksi 1990-luvulla ja Kanadan mallia vastaava ajatus kattavasta tilastosysteemistä koskevasta laatuohjeistuksesta sai tuulta purjeisiin. Ensimmäinen versio ohjekirjasta ”Laatua tilastoissa” valmistui v. 2002. Seuraava, huomattavasti syvällisempi laatukuvauksia koskeva versio laadittiin viisi vuotta myöhemmin. Ajatuksena oli, että tietoja päivitetäisiin verkossa tarpeen mukaan. Niin ei valitettavasti ole tapahtunut.

## Siirtymä kohti kokonaislaadun hallintaa: suuruudet peliin

Laadunhallinnan tarve oli ollut teollisuusprosesseissa keskeistä hyvin pitkään. Siirtyminen käsityöperinteestä manufaktuurien kautta tehdasteollisuuteen 1700-luvun lopulta alkaen merkitsi suurta muutosta. Teollisuusprosesseissa oli alkuvaiheessa ongelmia, osin väkivaltaisia varsinkin Britanniassa. Jotta prosessi olisi ollut sujuva, sen piti olla nopeampi suhteessa käsityöhön ja tuotteiden laadun olla hyväksyttävää, ts. laatua tuli valvoa. Tällä tavoin mm. Henry Ford loi USAssa 1900-luvun alussa autoteollisuuden imperiuminsa ja Winslow Taylor opasti useita teollisuudenhaaroja tuotannon systematisoinnissa (taylorismi). He olivat osa uranuurtajista teollisen laadunvalvonnan alalla.

Seuraavat laadunhallintajärjestelmien kehittäjät olivat merkittäviä tilastotieteilijöitä – joskin kumpikin fyysikkoja peruskoulutukseltaan. Walter Shewhart kehitti tuotantoprosesseihin mm. kontrollikortit, joissa tuotteiden ominaisuuksia, läpimenoaika tms. seurattiin rajojen puitteissa. Kullekin mittarille piti määrittellä luottamusvälit, joissa mitattavan ominaisuuden piti pysyä tehokkuuden ja laadun ylläpitämiseksi.

Varsinaisena laadunhallinnan guruna pidetään William Edwards Demingiä, joka oli myös Shewhartin työtoveri jo 1930-luvulta alkaen. Deming työskenteli tilastotieteen, erityisesti otantamenetelmien parissa mm. USAn väestölaskentavirastossa (U.S Bureau of the Census) ja kirjoitti myöhemmin yhden ensimmäisistä kokonaisvaltaisista otantateorian oppikirjoista. Toisen maailmansodan lopulla hän ja Shewhart osallistuivat USAn puolustusteollisuuden projekteihin, jotta sotatarvikkeiden laatu olisi pysynyt korkeana. Sodan jälkeen tuli noususuhdanne ja laatutyöhön ei USAssa ollut kiinnostusta, joten Deming kutsuttiin konsultoimaan Japanin sodasta nousevaa teollisuutta 1950-luvun alussa. Japanin vuosina kehittyi ajatus kokonaislaadun hallinnasta (Total Quality Management, TQM). Sen olennaisena osana on ns. PDCA-sykli tuotantoprosesseihin: suunnittele-toteuta-tarkista-korjaa (Plan-Do-Check-Act). Toimintaperiaate tarkoittaa jatkuvaa kehittämistä. PDCA on edelleen perusosa prosessien ohjauksessa. Se on olennaiselta osin Shewhartin suunnittelema, mutta Deming pys-

tyi toteuttamaan mallin teollisessa tuotannossa. Prosessien ohella hän kiinnitti huomiota yritysten hallintoon ja toimintakulttuuriin.

Huolimatta siitä, että Shewhart ja Deming ym. olivat kehittäneet kokonaislaadun hallinnan perusteet, ei USAssa eikä Euroopassa herätty laatua koskeviin ongelmiin ennen kuin 1970-1980 –lukujen taitteessa kansainvälisen kilpailun kiristyttyä. Vastauksia alkoi tulla vähin erin. Kansainvälinen standardointijärjestö ISO on ottanut TQM:n osaksi omaa standardeja koskevaa sarjaansa (ISO 9000) ja Eurooppaan perustettiin v. 1989 erityinen säätiö EFQM (the European Foundation for Quality Management), jonka tarkoitus on edistää kokonaislaadun hallintaa. Sekä ISolla että EFQM:llä on oma kriteeristönsä, jonka toimivuutta seurataan auditoinneilla. ISON auditoinnit ovat yleensä kahden vuoden välein, siinä kyse on varmistusvierailusta, jossa tarkistetaan organisaation vastausten pohjalta, kuinka vastaukset tutkittavan asioiden ominaisuuksista vastaavat ennalta määriteltä aseikkoa ja sovittua kehitystä. EFQM:n suhteen auditoitava organisaatio määrittelee ajan itse, mutta tarkistus koskee periaatteessa koko alkuperäistä toimintatapaa. Vastaavia laadun tarkistusorganisoiteja ja -malleja on myös muilla mantereilla ja organisaatioilla, kuten LEAN SIX SIGMA ym. Mutta peruseriaatteet ovat hyvin samanlaiset.

Osa Euroopan tilastovirastoista on sertifioinnut itsensä TQM-mielessä joko ISO-standardin 9001 tai EFQM:n ”erinnomaisuusvaatimuksen” suhteen. Osalla sertifiointi voi koskea vain osaa toiminnasta, esim. markkina-, mielipide- ja sosiaalitutkimuksia (ISO 20527/2017), taikka tietojenkäsittelyä (ISolla useita standardeja). Kummankin keskeisen laatustandardin pääpiirteet esitetään seuraavaksi.<sup>1</sup>

## **ISO 9001:2015 -standardi**

Standardi koskee laadunhallinnan järjestelmiä. Siinä on kymmenen pääkohtaa:

1. Tarkoitus
2. Normatiiviset referenssit
3. Terminologia ja määritelmät
4. Organisaation toimintaympäristö
5. Johtajuus
6. Suunnittelu
7. Tukitoiminnot
8. Toiminta
9. Suorituskyvyn arviointi
10. Parantaminen

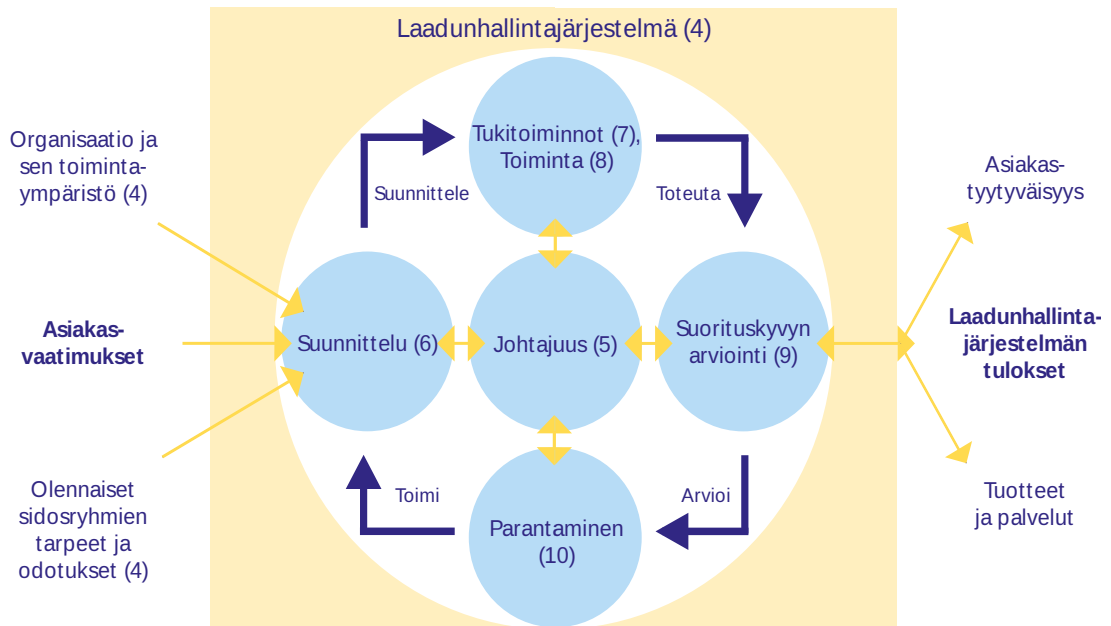
(Ks. tarkemmin SFS-EN ISO 9001, 2015).

---

<sup>1</sup> Sekä ISO- että EFQM-standardien tarkat laatumääritykset ovat lisensoituja, joten niitä ei esitellä tarkemmin. Kirjoittajalla on luvat yleisesitykseen.

## ISO 9001 -standardin prosessimalli

PDCA-mallia (suunnittele, toteuta, arvioi, toimi) voidaan soveltaa kaikkiin prosesseihin ja koko laadunhallintajärjestelmään.



Kuvassa on esitetty, kuinka standardin kohdat 4–10 luokitellaan PDCA-mallin mukaisesti.

Kuva 1: ISO 9001 -standardin prosessimalli. (SFS 2019, ss. 10-11.)

## European Foundation for Quality Management (EFQM) erinomaisuusmalli

EFQM-malli perustuu kolmeen pääalueeseen, joita tarkennetaan seitsemällä kriteerillä ja edelleen 25 osakriteerillä.

Pääalueet ja kriteerit:

### Suunta

**Kriteeri 1.** Perustehtävä, visio ja strategia

**Kriteeri 2.** Organisaatiokulttuuri, edelläkävijyys ja johtajuus

### Toiminta

**Kriteeri 3.** Sidosryhmien sitoutuminen

**Kriteeri 4.** Kestävän arvon luominen

**Kriteeri 5.** Suorituskyvyn ohjaaminen ja uudistuminen

### Tulokset

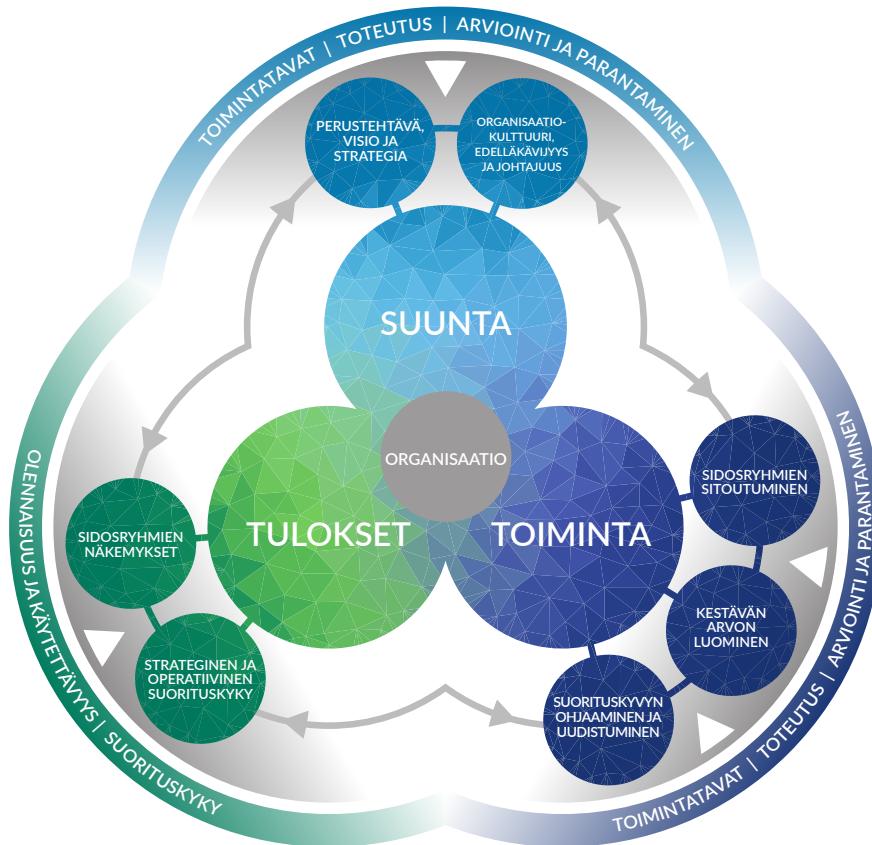
**Kriteeri 6.** Sidosryhmien näkemykset

**Kriteeri 7.** Strateginen ja operatiivinen suorituskyky

Suomen Laatuokeskus kuvaa mallia yleisesti (Kuva 2, versio 2020).

Vaikka PDCA-mallia ei edellä olevasta kuviosta suoraan näe, se on kuitenkin syvällä EFQM-mallin rakenteessa. Arviointi tapahtuu nk. Tutka-työkalulla (Radar), ts. se tarkastelee mallin toimivuutta kokonaisuutena.





Kuva 2: EFQM-malli. (Suomen Laatuokeskus 2019.)

## Kokonaislaadun hallinta Euroopan tilastojärjestelmään käytännesääntöjen kautta

Ajatus tuoda Demingin ym. kehittämiä laadunhallinnan metodeja tilastotoimeen (ts. osin juurilleen) lienee syntynyt monessa paikassa. Yksi keskeisiä puolestapuhujia Euroopassa oli prof. Lars Lyberg 1990-luvun puolivälissä. Hän toimi tuolloin Ruotsin tilastovirastossa SCB:ssä ja sai perustetuksi EU-tason työryhmän ”Leadership on Quality”, joka hahmotteli 21+1 suositusta laadun kehittämiseksi kokonaislaadun hallinnan menetelmillä. Tulokset esitettiin v. 2001 pidetyssä ensimmäisessä Euroopan tilastoalan laatukonferenssissa.<sup>2</sup>

Työryhmän perusteella käynnistettiin hankkeita toteuttamaan muita ehdotuksia, mutta sitten kohtalo astui kuvaan Kreikan ja vähän myöhemmin koko EU:n talustilastoja koskeneesta manipulaatiosta (2003-2004). Se vaikutti voimakkaasti EU:n tilastotoimistoon Eurostatiin ja muuhun EU:n komissioon. Sen tähden talous- ja valtiovarainministereistä koostuva ECOFIN-neuvosto vaati komissiota laatimaan ”minimiohjeistuksen koskien itsenäisyyttä, rehellisyyttä ja vastuullisuutta niin kansallisten kuin koko yhteisönkin tilastoviranomaisten suhteen”. Työryhmäksi kutsuttiin nk. tilasto-ohjelmakomitea<sup>3</sup>, joka laati ehdotuksen Euroopan tilastojen käytännesäännöiksi v. 2005. Ehdotus hyväksyttiin ja niin käytännesäännöistä tuli vahva laatua koskeva väline. Se on periaatteessa itsehallinnollinen työkalu, mutta siihen viitataan myös EU:n tilastoasetuksessa

<sup>2</sup>Viimeinen suositus (+1) koski laatukonferenssien järjestämistä. Niitä on sittemmin järjestetty yleensä kahden vuoden välein.

<sup>3</sup>Tilasto(-ohjelma)komitea koostuu sekä Eurostatin että eri maiden tilastovirastojen pääjohtajista.

(artikla 11, EU-tilastoasetus 2009).

Käytännėsäännöt perustuvat kokonaislaadun hallintaan, erityisesti EFQM-malliin. Sen kolme pääaihetta ovat:

1. Institutionaalinen ympäristö (ts. toimintaympäristö)
2. Tilastoprosessit
3. Tilastotuotteet

Kolme pääaihetta jakautuu yhteensä 16 periaatteeseen (ks. liite 1). Niiden sisällä on vaihteleva määrä mitattavia indikaattoreita, yhteensä 84. (Eurostat 2018). Aihetta on syvennetty nk. laadunhallintakehikolla (Quality assessment framework), jossa on paljon yksityiskohtaisia indikaattoreita.

Virallisesti käytännėsäännöt koskevat vain Euroopan tilasto-ohjelmaan kuuluvia tilastoja, mutta käytännössä niitä sovelletaan kaikkien EU-jäsenmaiden, EEA-alueen sekä jäsenyyttä hakevien maiden (kandidaattimaiden) viralliseen tilastotoimeen.

## Käytännėsääntöjen seuranta

Käytännėsääntöjen seuranta on päätetty toteuttaa vertaisarvioinneilla. Tähän mennessä arviointikierroksia on järjestetty kolme, ensimmäinen heti käytännėsääntöjen synnyttyä (2006-2008), ja kaksi seuraavaa 6-7 vuoden välein. Viimeisin toteutettiin v. 2021-2023. Alla oleva kuvaus koskee juuri viimeisintä kierrosta.

Vertaisarviointia varten kansallisille tilastovirastoille lähetettiin ensin sängen vaativa itsearviointilomake. Muille virallisen tilaston tuottajille itsearviointi oli huomattavasti kevennetty. Itsearviointi piti täyttää määräajassa. Vastauksiin vaadittiin dokumentaatio toimien todentamiseksi sekä riittävästi muuta materiaalia, jotta varsinainen arviointi voitiin suunnitella ja suorittaa. Arviointia varten valittiin runsaat 30 asiantuntijaa, jotka jaettiin kahdeksan arviointiryhmään. Jokaisessa ryhmässä oli kolme edustajaa eri maista ja yksi Eurostatin korkea virkamies. Ja maiden jako tehtiin niin, ettei kukaan arvioinut kotimaataan.

Eurostat oli valmistanut rungon vertaisarviointien sisällöksi ja ohjelmaksi. Itsearviointi- ja muun materiaalin perehtymisen jälkeen ryhmät tekivät alustavan ohjelman sekä pyynnön mahdollisista lisätiedoista, jotka lähetettiin kunkin maan kansalliselle koordinaattorille. Ohjelma sovittiin yhteisesti samoin kuin mukaan kutsuttavien sidosryhmien kokoonpano. Sidosryhminä oli mm. valtionhallintoa, tutkijoita, perusaineistojen toimittajia, muita tilastojen käyttäjiä ja mediaa. Sidosryhmäyhteydet kuuluivat luonnollisesti kunkin maan edustajille.

Varsinainen vertaisarviointi kesti työviikon, viisi päivää, joista neljänä haastateltiin eri mukaan kutsuttuja tahoja. Kansallisen tilastoviraston osuus oli kaksi päivää, muita mukaan valittuja tilastontuottajia haastateltiin n. puoli päivää ja loppuaika koski eri sidosryhmiä. Sidosryhmähaastattelujen avulla pyrittiin varmistamaan ja syventämään jo saatuja tietoja. Viimeinen päivä oli varattu raporttiluonnoksen tekoon sekä johtopäätösten ja suositusten esittämiselle kunkin maan tilastoviraston ja muiden mukana olleiden tilastoviranomaisten edustajille.

Varsinainen raportti kirjoitettiin neljän viikon kuluessa arviointikäynnin jälkeen. Raportin täytyi noudattaa tiettyä rakennetta ja siinä suuri paino oli eri asioihin liittyvissä suosituksissa ja parannusehdotuksissa (jotka oli jo aiemmin

esitetty alustavina). Kun arvioitu maa oli hyväksynyt raportin ja Eurostat oli vielä tarkistanut sen, raportti julkaistiin sekä Eurostatin että kansallisen tilastoviraston kotisivuilla.

Vertaisarviointiraportin jälkeen maiden tuli laatia kehittämissuositukset, jotka perustuivat em. arviointiryhmän suosituksiin. Kehittämissuosituksissa tuli olla myös aikataulu, yleensä enintään viiden vuoden aikajänteellä. Menettely perustuu TQM:n jatkuvan parantamisen periaatteeseen.

Vertaisarviointiraportit ja kehittämissuositukset ovat julkisia, mutta niiden perusteella ei laadita maiden tai järjestelmien vertailuja. Syynä on vertaisarvioinnissa käytetty menetelmä, joka perustuu osin suoriin vastauksiin (”indikaattoreihin”), osin auditointityyppiseen luotaamiseen. Auditointi on aina tapauskohtaista kussakin maassa ja organisaatiossa, joten se porautuu syvemmälle kuin suorat vastaukset. Sen tähden organisaatioiden tai maiden vertailuja ei ole syytä tehdä.

## Perinteinen laaturaportointi Euroopan unionin puitteissa

Euroopan tilastoasetukseen sisältyy erillinen artikla 12, jossa määritellään laadun raportoinnissa noudatettavat kriteerit:

- (a) Relevanssi
- (b) Tarkkuus
- (c) Ajantasaisuus
- (d) Oikea-aikaisuus
- (e) Saatavuus ja selkeys
- (f) Vertailukelpoisuus
- (g) Yhtenäisyys

(EU-tilastoasetus 2009)

Käytännössä tietoa kerätään useiden tilastojen osalta EU:n vahvistaman metatietostandardin SIMSin (Single Integrated Metadata Structure) avulla. Se sisältää kaikki yllä mainitut laatukriteerit ja niiden ohella paljon muuta tietoa tilastojen käytön tueksi, mm. osia käytännössä olevista indikaattoreista. SIMS v. 2:ssa on päätasolla kaikkiaan 19 metatietoelementtiä (Eurostat 2021).

## Muita kansainvälisiä tilastoja koskevia laatukriteerejä

Laatuajattelu on laajentunut paljon viimeisten 25 vuoden aikana. Käytännössä kaikilla suurilla tilastoja tuottavilla tai käytävillä kansainvälisillä organisaatioilla on omat laatukehikkonsa. Tähän on listattu muutamia eniten viralliseen tilastotoimeen vaikuttavia organisaatioita, joten kaikki erityisalojen ns. pieniä kansainvälisiä yhteisöjä ei ole sisällytetty, vaikka niissä olisi aivan vastaavia järjestelmiä käytössä.

Euroopan keskuspankkijärjestelmälle on kehitetty hyvin samankaltainen laatukehikko kuin edellä esitetty Euroopan tilastojen käytännössä, nimeltään ”ECB Statistics Quality Framework” (SQF).

(European Central Bank 2024)

Kansainvälisen valuuttarahaston (IMF) laatukehikko on laajasti käytössä, koska IMF:lle toimitetaan paljon tilastotietoa: ”Data Quality Assurance Framework” (DQAF). IMF suorittaa myös säännöllisiä tarkistuskäyntejä eri tietojen toimittajille, tyypillisesti kansallisille tilastovirastoille ja keskuspankeille. Lisäksi IMF:llä on erityinen laadunhallintaan perustuva tiedon jakelustandardi SDDS ja sen vaativampi versio SDDS+ (Special Data Dissemination Standard). (International Monetary Fund 2024)

YK:lla on useita erilaisia suosituksia ja laatumalleja. Perusdokumentti on ”Fundamental Principles of Official Statistics”, jonka ensimmäinen versio hyväksyttiin 1994. Nämä perusperiaatteet on otettu huomioon kaikkien kansallisten ja kansainvälisten organisaatioiden laatu järjestelmien ja käsikirjojen pohjana. Sen ohella on vastaavat periaatteet erilaisille kansainvälisille tilastojen tuottajille ”Principles Governing International Statistical Activities”, tilastojärjestelmien käsikirja ”The Handbook on Management and Organization of National Statistical Systems”, varsinainen laadunvarmistuskehikko ”United Nations National Quality Assurance Framework” (NQAF) ym. (United Nations Statistics Division 2024)

YK:n alainen Euroopan talouskomissio (ECE tai UNECE) on erikoistunut tilastoalan prosessimalleihin. Varsinainen prosessimalli ”Generic Statistical Process Model” (GSPM) on kehitetty v. 2008, nykyversio on jo viides. Viime vuosina ECE on laatinut myös yleisempää tilastoalan kehittämismallia ”General Activity Model for Statistical Organisations” (GAMSO), lähinnä kehittyvien maiden tarpeisiin ja toimintatapojen modernisointiin. (UNECE 2023)

Taloudellisen yhteistyön ja kehityksen järjestö OECD:llä on myös oma laatukehikkonsa (OECD Quality Framework and Guidelines for OECD Statistical Activities), joka on johdettu Kanadan tilastoviraston laatuohjeistuksesta. (OECD 2024)

Maailmanpankin aiemmin mainittu tilastoindikaattorien vertailu perustuu pankin oman sekä muiden kansainvälisten järjestöjen kautta saatujen tietojen analysointiin. Vuoden 2022 vertailussa oli mukana 186 maata. Kaikkiaan vertailu koostuu 51 indikaattorin tiedoista. Indikaattorit kootaan 22 dimensioon, joista edelleen johdetaan viisi pääpilaria: tiedon käyttö, tietopalvelut, tilastotuotteet, tiedon lähteet ja infrastruktuuri. Näiden perusteella estimoidaan lopullinen suoritusindeksi (Statistical Performance Indicator). Vertailuja tehdään myös pääpilarien tasolla. (World Bank 2024)

## Suomen virallisen tilaston laatustandardi(t)

Suomen virallinen tilasto (SVT) on järjestelmä, johon kuuluvat kaikki valtion virallisia tilastoja laativat organisaatiot, tätä kirjoitettaessa 13 organisaationa (<https://stat.fi/meta/svt/index.html>). SVT:llä on oma suosituksensa laatu-kriteereistä ja -standardeista, jotka perustuvat YK:n virallisen tilaston periaatteille. Laatu-kriteerit ovat hyvin samankaltaiset kuin EU:n tilastoasetuksen laatu-kriteerit:

1. Puolueettomuus ja läpinäkyvyys
2. Laadun hallinta
3. Tietosuoja

4. Tehokkuus
5. Relevanssi
6. Tarkkuus ja luotettavuus
7. Ajantasaisuus ja oikea-aikaisuus
8. Yhtenäisyys ja vertailukelpoisuus
9. Saatavuus ja selkeys

Laaturaportoinnissa sovelletaan SIMS-mallin mukaista metatietorakennetta sekä kansallisissa että EU-tason tilastoissa. Sen ohella joihinkin tutkimustyyppiin tilastoihin voi sisältyä huomattavasti laajempi laaturaportti. Muille kansainvälisille järjestöille tehtävissä tilastotoimituksissa noudatetaan aina kyseisen tilaston vaatimaa laatukriteeristöä.

## Yhteenveto

Laadunhallinta ja standardointi on tullut merkittäväksi osaksi nykyistä tilastotuotantoa. Euroopan alueella tärkein yleinen laatukehikko on Euroopan tilastojen käytännesäännöt. Ne muodostavat perustan pitkäjänteiseen kehittämiseen. Niiden ohella virallisessa tilastotoimessa pitää noudattaa montaa muutakin kansainvälistä standardia, mutta onneksi yleisimmät kokonaislaadun hallintaan perustuvat järjestelmät ovat hyvin suurelta osin toisensa kattavia erilaisista käsitteiden nimityksistä riippumatta. Joka tapauksessa yleiset kokonaislaadun hallintaan keskittyvät järjestelmät luovat vankan pohjan organisaatioiden ja niiden sisällä yksittäisten tilastojen kehittämiseen niin tuotantoprosessin kuin valmiiden tilastotuotteidenkin suhteen.

Kansainväliset vertailut ja maiden väliset sijoitusvertailut antavat luonnollisesti lisäarvoa edellä mainitulle pohjatyölle. Ja jos indikaattorien valinta sekä mallitus perustuu vankkaan teoriapohjaan (kuten Maailmanpankin tapauksessa), niin toki niitä kannattaa hyödyntää. Mutta varsinainen laatutyö lähtee koko tilastoprosessin hallinnasta ja vain sitä kautta pystytään saavuttamaan kestäviä ja jatkuvasti parantuvia tuloksia.

## Lähteet

K. Djerf. Survey Quality and Survey Ethics, in *Encyclopedia of Statistics in Quality and Reliability*, F. Ruggeri, R. Kennett, and F.W. Faltin (eds). Chichester: John Wiley and Sons, p. 1955-1958. 2008.

European Central Bank. The ECB Quality Framework and quality assurance procedures. 2024

[https://www.ecb.europa.eu/stats/ecb\\_statistics/governance\\_and\\_quality\\_framework/html/ecb\\_statistics\\_quality\\_framework.en.html](https://www.ecb.europa.eu/stats/ecb_statistics/governance_and_quality_framework/html/ecb_statistics_quality_framework.en.html) .

(Viitattu 30.8.2024)

Eurostat. Euroopan tilastoja koskevat käytännesäännöt. 2018. [https://stat.fi/media/uploads/org/periaatteet/euroopan\\_tilastojen\\_kaytannesaannot\\_fi\\_2017.pdf](https://stat.fi/media/uploads/org/periaatteet/euroopan_tilastojen_kaytannesaannot_fi_2017.pdf) .

(Viitattu 20.8.2024)

Eurostat. European Statistical System Handbook for Quality and Metadata Reports. 2021 re-edition.

<https://ec.europa.eu/eurostat/documents/3859598/13925930/KS-GQ-21-021-EN-N.pdf/143394de-e5a0-31ac-2c90-2aa9c15803f0?t=1639042312202> .

(Viitattu 26.8.2024)

EU-tilastoasetus, Euroopan parlamentin ja neuvoston asetus (EY) N:o 223/2009 (muutoksineen)

<https://eur-lex.europa.eu/legal-content/FI/TXT/PDF/?uri=CELEX:02009R0223-20150608&from=EN> (Viitattu 20.8.2024)

International Monetary Fund. Data Quality Reference Site.

<https://dsbb.imf.org/dqrs/DQAF> .

(Viitattu 26.8.2024)

ISO. ISO 9001:2015

<https://www.iso.org/standard/62085.html#amendment> .

(Viitattu 30.8.2024)

G. Luther. Suomen tilastotoimen historia vuoteen 1970. Tilastokeskus, 1993.

OECD. Data – Methods. 2024.

<https://www.oecd.org/en/data/methods.html>

(Viitattu 30.8.2024)

SFS-EN ISO 9001. 2015. 5. painos. Laadunhallintajärjestelmät. Vaatimukset. Helsinki: SFS Suomen Standardit.

SFS 2019. ISO 9000 -sarjan valinta ja käyttö (esite). Helsinki: SFS Suomen standardit.

(Ei julkinen, SFS-Suomen standardit -organisaatio).

R.A. Steckel. The Quality of Census Data for Historical Inquiry: A Research Agenda. Social Science History Vol. 15, No. 4 (Winter, 1991), pp. 579-599

Suomen Laatukeskus. EFQM-malli (versio 2020). 2019.

Lisätiedot: [www.excellencefinland.fi](http://www.excellencefinland.fi); [www.efqm.org](http://www.efqm.org).

(Viitattu 30.8.2024)

Suomen virallinen tilasto. <https://stat.fi/meta/svt/index.html>

(Viitattu 27.11.2024)

Statistics Canada. Quality Guidelines, Sixth edition.

<https://www150.statcan.gc.ca/n1/pub/12-539-x/12-539-x2019001-eng.htm>

(viitattu 20.8.2024)

Tilastokeskus. Tilastojen laadun kuvaaminen. Käsikirjoja 23. Helsinki: Valtion painatuskeskus. 1987.

Tilastokeskus. Laatu tilastoissa, 2. uudistettu painos. Käsikirjoja 43. Helsinki: Yliopistopaino, 2007.

Tilastokeskus. Suomen tilastot valittu jälleen maailman parhaiksi. Uutisia 16.2.2024. <https://stat.fi/uutinen/suomen-tilastot-valittu-jalleen-maailman-parhaiksi>

(Viitattu 20.8.2024)

UNECE. GAMSO.

<https://unece.org/statistics/documents/2023/01/presentations/3c-project-proposal-roadmap-implementing-standards-gsbpm> .

(Viitattu 30.8.2024)

United Nations. The Preparation of Sampling Survey Reports. Statistical Papers, Series C, No. 1. (Revised), New York, 1950.

[https://unstats.un.org/unsd/demographic-social/Standards-and-Methods/files/Handbooks/surveys/SeriesC\\_1\\_revised-E.pdf](https://unstats.un.org/unsd/demographic-social/Standards-and-Methods/files/Handbooks/surveys/SeriesC_1_revised-E.pdf)

(Viitattu 20.8.2024)

United Nations. Principles and Recommendations for Population and Housing Censuses. Revision 3.

Statistics Division. New York. 2017.

[https://unstats.un.org/unsd/demographic-social/Standards-and-Methods/files/Principles\\_and\\_Recommendations/Population-and-Housing-Censuses/Series\\_M67rev3-E.pdf](https://unstats.un.org/unsd/demographic-social/Standards-and-Methods/files/Principles_and_Recommendations/Population-and-Housing-Censuses/Series_M67rev3-E.pdf)

(Viitattu 26.8.2024)

United Nations. Handbook on Registers-Based Population and Housing Censuses. Statistical Commission Background document. Second draft – subject to final substantive and copy editing.

<https://unstats.un.org/unsd/statcom/53rd-session/documents/BG-3e-Handbook-E.pdf>

(Viitattu 26.8.2024)

United Nations Statistics Division.

<https://unstats.un.org/UNSDWebsite/>

(Viitattu 30.8.2024)

World Bank. Statistical Performance Indicators. 2024.

<https://www.worldbank.org/en/programs/statistical-performance-indicators>

(Viitattu 30.8.2024)

## Liite 1. Euroopan tilastojen käytäntesäännöt ja niihin liittyvät periaatteet, v. 2017 hyväksytty versio

---

Institutionaalinen ympäristö		
1		Ammatillinen riippumattomuus
1bis		Koordinointi ja yhteistyö
2		Tiedonkeruuvaltuudet ja tiedonsaanti
3		Riittävät voimavarat
4		Laatuun sitoutuminen
5		Tilastollinen tietosuoja (tilastosalaisuus) ja tietoturva
6		Puolueettomuus ja objektiivisuus
<hr/>		
Tilastoprosessit		
7		Pätevät menetelmät
8		Ajanmukaiset tilastolliset menettelytavat
9		Kohtuullinen vastausrasite
10		Kustannustehokkuus
<hr/>		
Tilastotuotteet		
11		Relevanssi
12		Tarkkuus ja luotettavuus
13		Oikea-aikaisuus ja täsmällisyys
14		Johdonmukaisuus ja vertailukelpoisuus
15		Saatavuus ja selkeys

---

# Verkkokyselyt: Käytäntö ja data-analyysi

## Suomen Tilastoseuran iltapäiväseminaari 10.9.2024

### Ohjelma

13.00-13.05	<b>Juha Alho</b> emeritusprofessori, Helsingin yliopisto	Tilaisuuden avaus
13.05-13.35	<b>Sakari Nurmela</b> Verian	Verkkokyselyt puoluekannatuksen mittauksessa ja presidentinvaaleissa
13.35-14.05	<b>Tara Junes</b> Tilastokeskus	Vastauskato kuluttajienluottamustilastossa
14.05-14.10	<b>Pekka Pere</b> Tilastoseuran hallituksen puheenjohtaja	Tilastoseuran tervehdys
14.10-14.40	<b>Kahvitauko</b>	
14.40-15.10	<b>Risto Lehtonen</b> emeritusprofessori, Helsingin yliopisto	Yksityiskohtaisten taustatietojen käyttömahdollisuuksista kyselyaineistojen analyysissä
15.10-15.40	<b>Mika Pantzar</b> Helsingin yliopisto	Kommenttipuheenvuoro: tietojen käyttäjän näkökulma
15.40-16.00	<b>Yleisökeskustelu</b>	



# Avauspuheenvuoro

JUHA ALHO

EMERITUSPROFESSORI, HELSINGIN YLIOPISTO  
SENIOR FELLOW, ETLA

## Verkkokyselyt: käytäntö ja data-analyysi Avauspuheenvuoro

Helsingin Sanomat ja The New York Times ovat esimerkkejä mediataloista, jotka julkaisevat nettikyselyiden tuloksia. Tyypillisiä tutkimuskohteita ovat puoluekannatus ja kuluttajienluottamus. Internetin käyttö voi merkittävästi nopeuttaa kyselyn suoritusta, vähentää vastaajan kuormaa ja alentaa tiedonkeruun kustannuksia.

Näiden tekijöiden ohella verkkokyselyiden suosiota on kasvattanut todennäköisyysotantaan perustuvien väestöluotausten vastauskato. Euroopassa on jo pitkään oltu tilanteessa, jossa vastausprosentit ovat voineet olla 10 % tai alle. Otannan kehikon mahdollisten puutteiden ohella kato johtaa siihen, että tuloksia joudutaan korjaamaan esimerkiksi vastauksien täydennyksiä mallittamalla tai marginaalit kalibroimalla. Nämä keinot toimivat hyvin, kun vastausprosentit olivat korkeampia. Nyt tilanne on toinen.

Verkkokyselyiden toteuttamistavat voivat vaihdella paljonkin. On tavallista, että netin kautta kerätään vähintään tuhansien henkilöiden kokoinen paneeli, johon kuuluvista kerätään demografisia perustietoja ja joiden vastaamishistoriasta pidetään lukua. Määrätarkoitusta varten valituille paneelin jäsenille tarjotaan mahdollisuutta vastata kiinnostuksen kohteena oleviin kysymyksiin. Vastauksen analyysissä pyritään varmistamaan, että vastaajat ovat jakautuneet valittujen taustamuuttujien suhteen samalla tavalla kuin kohdepopulaatiokin. Kyse on siis ns. kiintiöpoiminnasta.

Nettiä käytettäessä vastaajan yksilöllisten piirteiden rooli tutkimukseen valikoitumisessa voi olla merkittävästi suurempi kuin todennäköisyysotannassa. Tällä voi olla vaikutusta tuloksiin, jos valikoitumisprosessi ja tutkittava ilmiö ovat tilastollisesti assosioituneita keskenään. Tästä syystä satunnaisotantaan perustuvat arviot tulosten tarkkuudesta eivät sellaisenaan päde. Esimerkiksi vaalikyselyiden tarkkuutta voidaan tuki jälkikäteen arvioida ja siten luoda käsitys niiden luotettavuudesta.

Esimerkkinä tarkastelen The New York Timesin tilaamaa USA:n presidentinvaalikyselyä, joka julkaistiin lehdessä 08.09.2024.<sup>1</sup> Haastattelu suoritettiin puhelimitse. Kyselyn kehikkona toimi eri osavaltioissa vaaliluetteloihin rekisteröityneistä äänestäjistä koostettu lista. (USA:ssa ei ole väestörekisteriä. Äänestämistä varten on erikseen rekisteröidyttävä. Listojen sisältö vaihtelee osavaltiosta toiseen.) Kyselyn tuoteselosteesta käy ilmi, että vastaajia oli 1 695. Erityistä huomiota kiinnittää se, että saadakseen kasaan vastaajat, kyselyorganisaatio oli soittanut 104 000:lle henkilölle yhteensä 194 000 kertaa. Valtavaa puhelumäärää selittänee se, että kun vastaamisalttius on matala, niin on vaikeaa saada kiinni riittävä määrä vastaajia kaikista pienistä väestöositteista, joita kiintiöpoi-

---

<sup>1</sup>You Ask, We Answer: How The Times/Siena Poll Is Conducted <https://www.nytimes.com/article/times-siena-poll-methodology.html?searchResultPosition=1>

minnassa kuitenkin tarvitaan. Vastaukset kalibroidaan vastaamaan äänestäjien väestön tunnettuja reunajakaumia. Ottaen huomioon USA:n presidentinvaalien maailmanlaajuisen merkityksen, on hätkähdyttävää, miten ongelmallisen aineiston avulla käsitys ehdokkaiden kannatuksesta on muodostettava.

Iltapäivätilaisuuden tarkoituksena on valottaa suomalaisten esimerkkien avulla verkkokyselyn käytännön suorittamista. Suomen väestörekisterin ja laajojen rekisteriaineistojen avulla meillä olisi periaatteessa mahdollista sekä mallittaa valikoitumistodennäköisyyksiä yksilötasolla että tehostaa aineiston jälkiositusta tarkemmin kuin esimerkiksi Yhdysvalloissa. Näihin tarkoituksiin on kehitetty työkaluja esim. Kanadan tilastokeskuksessa. Vastaaajien tietosuojasta huolehtiminen on tietysti keskeinen haaste, jotta taustatietojen käytölle saataisiin yleinen hyväksyntä.

# Verkkokyselyt puoluekannatuksen mittauksessa ja presidentinvaaleissa

SAKARI NURMELA  
VERIAN

Amerikkalaista George H. Gallupia pidetään yleisesti otantatutkimusmenetelmään perustuvan mielipidemittauksen isänä.

Hän on myös antanut nimensä tälle tutkimustavalle. Englannin kielessä käytetään termiä Gallup Poll. Vastaavasti Suomessa puhutaan hyvin yleisesti gal-lupeista, kun tarkoitetaan otantaan perustuvia, erityisesti yhteiskunnallisia teemoja käsitteleviä mielipidetutkimuksia.

George Gallup sai kuuluisuutta, koska näki tutkimustensa perusteella Franklin D. Rooseveltin uudelleenvalinnan todennäköisyyden vuoden 1936 presidentinvaaleissa.

Vähemmän tunnettu henkilö tässä prosessissa oli Rooseveltin hallinnon neuvonantajana työskennellyt Emil Hurja, jota voi pitää yhteiskunnallisten gallup-tutkimusten ensimmäisenä hyödyntäjänä.

Hurja oli syntyperältään suomalainen. Hänen vanhempansa olivat Evijärveltä Yhdysvaltoihin Michiganiin 1880-luvulla muuttaneita Pitkäkankaita. Amerikan raitilla nimi muutettiin Hurjaksi, mutta Emilin kotikieli oli suomi.

Artturi Raula puolestaan perusti maahamme ensimmäisen mielipidetutkimusyri-tyksen, Suomen Gallup Oy:n vuonna 1945. Raula oli George Gallupin ystävä, ja Gallup myönsi Raulalle kirjallisesti luvan käyttää nimeään uudessa yhtiössään.

Erinäisten omistus- ja nimenmuutosten jälkeen Suomen Gallupin yhteiskunnalliset tutkimukset tunnetaan nykyisin nimellä Verian.

Verianin näkyvin osa ovat politiikkaan liittyvät, etenkin Helsingin Sanomien politiikan ja talouden toimitukselle tehtävät mielipidekyselyt ja kannatusmitaukset.

Yhtä lailla töitä kuitenkin tehdään poliittisille puolueille, ammatillisille etujärjestöille sekä monille muillekin niin kolmannen kuin yksityisenkin sektorin toimijoille.

## Tieteellisellä ja kaupallisella tutkimuksella on paljon yhtymäkohtia

Akateemisesta maailmasta kaupallisen tutkimuksen erottaa eniten se, ettei siinä vedota samalla tavalla teoreettisiin lähtökohtiin, vaan tutkimusten perustana ovat poikkeuksetta käytännön elämästä lähtevät asiakkaiden ratkaisua vailla olevat ongelmat tai erilaiset toiminnalliset tavoitteet.

Tekemisen näkökulmasta erot ovat vähäisemmät.

Kaupallisessakin maailmassa tutkimusongelma pyritään ensin operationalisoimaan laajemmiksi tutkimuskysymyksiksi ja keksimään mittareita.

Niihin saadut vastaukset palautetaan erilaisten tilastollisten analyysien avulla käsitteellisesti ylemmälle tasolle ja usein tarinaksi, joka auttaa mielipideyritysten asiakkaita tekemään omassa työssään oikeita päätöksiä ja viestimään niistä heille edullisella tavalla.

Varsinainen aineiston kerääminen tulee kaupallisille mielipideyrityksille yleensä annettuna. Esimerkiksi Verian on valinnut itselleen yhteistyökumppaneiksi eräitä hyvälaatuisten aineistojen keräämiseen erikoistuneita yrityksiä, ja pitää vaatimustasoa mahdollisimman tiukkana.

Ilman korkealuokkaista aineistoa on mahdotonta yleistää tuloksia luotettavasti. Hyvä edustavuus ja kyvykäs otanta ovat kuitenkin vain osa laadukasta tutkimusta. Tarvetta on myös sisällölliselle ja raportointiin liittyvälle osaamiselle.

## **Luovuus on tutkimuksissa aliarvostettu ominaisuus**

Luovuus on mielipidetutkijan ammatissa jotain äärimmäisen tarpeellista mutta monesti ylenkatsottua.

Yllättävän usein joku sivullinen toteaa valmiita kysymyksiä katsoessaan, että lapsikin pystyisi sellaiseen. Hän ei ymmärrä sitä, että parhaat mittarit näyttävät usein todella yksinkertaisilta eikä ajattele, että kysymysten kokonaisuuden rakentaminen on vaatinut hurjasti luovuutta.

Vastaajien pitää ymmärtää lomakkeen kysymykset samalla tavalla. Jos niihin on helppo vastata, ne mittaavat usein hyvinkin tarkasti asiaa, josta ollaan kiinnostuneita. Kun aineisto lisäksi on edustava, tuloksista saa luotettavan perustan isoillekin päätöksille.

Pyrkimys ehdottomaan objektiivisuuteen on tosi tärkeää, eikä läheskään kaikilla ole siihen kykyä. Varsinkin operationalisointivaiheessa ja silloin kun saaduista tuloksista vedetään johtopäätöksiä, tutkijan arvomaailma ja ajattelun rajoittuneisuus saattavat muodostaa riskin.

Sama koskee asiakkaiden ajattelua. Tosin yleisesti ymmärretään, ettei oikeastaan mikään ole yhtä mukavaa kuin saattaa julkisuuteen itselle edullisia tuloksia, jotka perustuvat objektiiviseen ja ammattitaitoisesti toteutettuun tutkimukseen.

## **Puoluekannatus ja presidentinvaaligallupit perustuvat erilaisiin menettelytapoihin**

Tekemisen kannalta puoluekannatusarviot ja presidentinvaaligallupit ovat kaksi eri asiaa.

Puoluekannatusmittauksissa kysytään, minkä puolueen ehdokasta vastaaja äänestäisi, jos vaalit järjestettäisiin nyt.

Tähän kysymykseen annettujen vastausten suora jakautuma on kuitenkin vasta lähtökohta arvion tekemiselle, eikä siitä voi vielä vetää johtopäätöksiä. Lisäksi on esitettävä kysymys äänestyskäyttäytymisestä edellisissä vaaleissa.

Puoluekannatusarviossa on nimittäin kyse siitä, että kyselytulosten avulla arvioidaan, kuinka puolueiden kannatus on muuttunut edellisistä kunta- tai eduskuntavaaleista. Koska se on tiedossa, subjektiiviset kyselyvastaukset saadaan sidottua objektiivisesti määräytyvään tietoon.

Presidentinvaaligallupeissa taas tehdään valintoja henkilöiden välillä. Siinä yksinkertainen kysymystyyppi toimii hyvin ja kannatusluvut syntyvät, kun kantaluksena pidetään mielipiteensä ilmaisemisen lukumäärää eli jätetään vailla mielipidettä olevat huomiotta.

Samaa menetelmää käytetään ensimmäisellä ja toisella kierroksella tai kuten virallisesti sanotaan ensimmäisessä ja toisessa vaalissa.

## **Puoluekannatusarviot eivät ole ennusteita**

Puoluekannatusarviot eivät ole vaaliennusteita, vaan mahdollisimman tarkkoja kuvauksia tilanteesta sinä ajankohtana, kun aineisto on kerätty.

Jos mitään ihmeellistä ei tapahdu aineiston keräämisen ja vaalipäivän välillä, liittyy niihin silloin tiettyä ennustearvoakin.

Nykypolitiikkaan olennaisesti liittyvät ”jytkyt” kuitenkin syntyvät tyypillisesti usein aivan vaalikamppailun viime metreillä. Ratkaisevassa asemassa ovat ihmiset, jotka tekevät äänestämistään päätöksen aivan kalkkiviivoilla.

Rooseveltin vaalivoiton ennakoiti 1936 teki George Gallupista sankarin. Vuoden 1948 vaaleissa hän sai lokaa niskaansa, kun ”ei osannut ennustaa” Harry S. Trumanin voittavan.

Silloisessa tilanteessa oli paljon yhtymäkohtia tähän päivään. Huomattavan moni äänestäjä panttasi päätöstään aivan viime tinkaasti. Gallupin aineistonkeruu lopetettiin kaksi viikkoa ennen vaaleja.

Näin Trumanin ”jytky” ei voinut vielä näkyä tuloksissa. Silti ei ole epäilystäkään, etteikö Gallupin arvio olisi kuvannut todella hyvin tilannetta vaalikampanjoinnin loppusuoran alkamishetkellä.

## **Jälkiviisaus on harmillisen yleistä, eikä aina oikeassa**

Kannatusarvioihin liittyy intohimoja ja valittavasti myös ylilyöntejä. Mitä lähemmäksi vaalien H-hetkeä tullaan, sitä helpommin mikä tahansa asia poliitsoituu ja karpäsistä alkaa tulla härkäsiä.

Vaalien alla tuodaan julkisuuteen kaikenlaisia tutkimustuloksia. Kun tilanne näyttää oman porukan osalta hyvältä, kyseenalaista tietoa laitetaan surutta jakoon.

Joskus toimittajat menevät retkuun ja julkisuuteen pääsee sellaisia tietoja, jotka eivät välttämättä kovinkaan hyvin vastaa todellisuutta.

Jälkiviisauskin kukkii ihailtavasti vaalien jälkeen, erityisesti silloin, kun mielipidetutkimukset julistetaan virheellisiksi.

Esimerkiksi Donald Trumpin voitettua Hilary Clintonin vuoden 2016 presidentinvaaleissa kansainvälinen lehdistö omaksui erittäin nopeasti näkemyksen, jonka mukaan gallupit olisivat epäonnistuneet.

Totuus oli kuitenkin paljon monimuotoisempi. Itse asiassa viimeisimmät, juuri vaalien alla toteutetut valtakunnalliset mielipidetiedustelut olivat varsin hyvin ”hajulla” siitä, kuinka äänet prosentuaalisesti olivat jakaantumassa ehdokaiden välillä.

## **Kannatusarviot ovat osa poliittista agenda**

Kannatusarvioita, kuten poliittisia mielipidetutkimuksia yleensäkin, tehdään nykyisin aika paljon ja ne ovat muodostuneet kiinteäksi osaksi poliittista elämää.

Vaalien alla toteutettavien lisäksi tehdään kuukausittaisia mittauksia. Verianin lisäksi asialla on Taloustutkimus. Näin katsaus puolueiden kannatukseen saadaan yleisön tietoisuuteen kahden viikon välein.

Mittauksista on tullut osa poliittisen journalismin dramaturgiaa. Poliitikot ja politiikan ammattilaiset odottavat lukuja innokkaasti tai hieman peloissaan, riippuen siitä, mitä saattaa olla odotettavissa.

Ja kyllä muutkin seuraavat niitä ja joskus mielipidetutkimukset vaikuttavat. Ajatellaanpa vaikka viime eduskunta- ja presidentinvaaleja ja kumpaankin liittynyttä taktista äänestämistä. Kyllä siihen ryhdyttiin nimenomaan kannatusarvioiden perusteella.

## Tiedonkeräyksen murros on jo alkanut

Vastaajapaneelit ovat tänä päivänä Suomessa ja monessa muussakin maassa ylivoimaisesti käytetyin tapa kerätä aineistoja.

Paneeleissa niihin rekrytoidut henkilöt vastaavat kyselyihin. Heille lähetetyt sähköpostikutsut sisältävät linkin, jota pitkin he siirtyvät vastaamaan kyselyn järjestävän tahon tietojärjestelmässä sijaitsevalle sähköiselle lomakkeelle.

Tähän asti puoluekannatusarviot on kerätty Suomessa puhelinhaastatteluin. Muutos on kuitenkin jo lähellä. Ruotsissa ja monessa muussakin maassa puoluekannatusarviot perustuvat ainakin osittain vastaajapaneeleissa kerättyihin aineistoihin.

Tämän vuoden presidentinvaali oli ensimmäinen, jossa Verian teki kaikki aiheeseen liittyvät tutkimuksensa paneelissa.

Kokemukset olivat hyviä. Koska tilanne toisella kierroksella stabiloitui jo hyvissä ajoin, viimeiset tutkimustulokset ennakoivat erittäin hyvin vaalin tuloksen.

Julkisuudessa esitettävät kannatusmittaukset ovat loppujen lopuksi vain jäävuoren huippu. Varsinainen vaaleihin liittyvä tutkimustyö tehdään paljon aikaisemmin.

Tätä kirjoitettaessa on puoli vuotta aikaa kunta- ja aluevaaleihin. Puolueet tekevät tutkimuksia, joiden avulla ne yrittävät sovittaa sanomansa potentiaalisille äänestäjilleen sopivaksi.

Moni poliitikko joutuu usein hyvinkin läheisesti tekemisiin ns. äänekkään vähemmistön vaatimusten kanssa. Edustava ja laadukas tutkimus auttaa heitä pääsemään perille hiljaisen enemmistön toiveista ja huolista. Näin tutkimukset voivat omalla tavallaan edistää kansan tahdon toteutumista.

## Suomen Gallup oli paneelitoiminnan uranuurtaja

Verianin edeltäjä Suomen Gallup Oy pystytti jo 1980-luvun lopussa sähköisen vastaajapaneelin, Gallup Kanavan.

Kanavan ideana oli, että rekrytoitiin suomalaisia edustava joukko ihmisiä vastaamaan tutkimuksiin viikoittain.

Silloin ei vielä ollut internetiä, joten panelistien koteihin toimitetut mikrotietokoneet toimivat vastauslaitteina ja tieto siirtyi linjoja pitkin Suomen Gallupin keskustietokoneelle.

Gallup Kanava oli sähköisen tiedonkeräyksen lähtölaulus Suomessa ja Pohjoismaissa. Itse asiassa vain hollantilainen tutkimusyhtiö Nipo ehti rakentaa oman paneelinsa ennen Suomen Gallupia.

Nykyisin paneeleita on runsaasti ja melkein kaikki kehuvat olevansa hyviä ja halpoja. Todellisuudessa on erittäin hankalaa, työlästä ja kallistakin rakentaa korkealaatuinen paneeli ja ylläpitää sitä.

Niinpä paneeleihin pätee sama totuus kuin muihinkin tuotteisiin: hyvää saa harvoin halvalla.

## Hyvät paneelit ovat ratkaisevassa asemassa

Hyvässä paneelissa on liuta valmiiksi kysytyjä ja säännöllisesti päivitettäviä sosioekonomisia taustamuuttujia. Panelisteja ”häiritään” sopivin väliajoin ja heidän tyytyväisyyttään sekä motiivejaan selvitetään.

Hyvän paneelin ei tarvitse olla täysin yksi yhteen väestön kanssa, mutta olisi hyvä, jos se olisi sitä suurin piirtein. Kokoa saisi olla riittävästi, jotta eri vastaajat osallistuisivat eri tutkimuksiin. Itsekrytoitumista ei saisi sallia, vaan panelistien suostumus pitäisi saada väestöedustavissa yhteyksissä. Lisäksi kaikenlaisten huijareiden perässä pitäisi olla aktiivisesti ja heidät tulisi poistaa paneelista välittömästi, kun filunki havaitaan.

Hyvissä paneeleissa on myös teknistä osaamista, kuten otantoihin, painottamiseen ja datantekoon liittyvää ohjelmallista taitoa. Laatu on lisäksi hyvä auditoida ja sertifioida, jotta varmasti toimitaan kaikissa tilanteissa mahdollisimman laadukkaasti.

Sinänsä mikään tiedonkeräystapa ei ole täydellinen. Katoa syntyy aina. Yhteiskuntaan heikosti kiinnittyneitä ei tahdo saada millään kiinni. Nuorten ja erityisesti nuorten miesten tavoittaminen on aina ollut ongelma riippumatta siitä, miten aineistoja on kerätty.

Nykyisin väestökyselyillä ei ole enää yläikärajaa, mikä on demokratian kannalta hienoa. Silti voi kysyä, että kuinka hyvin kyselyihin vastaavat iäkkäimmät edustavat kaltaisiaan ihmisiä.

Toisaalta paneelit voivat tarjota parempaa edustavuutta kuin muut tavat joissakin muissa väestöryhmissä.

Vielä muutama vuosi sitten paneelien hyödyntäminen puoluekannatusarvioissa ei olisi tullut kyseeseen. Laatupaneelien edustavuus on kuitenkin yleensä ottaen parantunut paljon. Niistä on mahdollista saada yhä parempia ja parempia otoksia.

Etenkin kun otantatutkimusten vastausprosentit ovat yleensä ottaen muuttuneet yhä heikommiksi, näyttää siltä, että ainakin lähitulevaisuus on paneelien.

# Vastauskato kuluttajien luottamus -tilastossa

TARA JUNES  
TARA.JUNES@STAT.FI  
YLIAKTUAARI  
TILASTOKESKUS

Kuluttajien luottamus -tilasto kuvaa kuluttajien taloudellisia mielialoja eli arvioita ja odotuksia oman ja Suomen yleisen talouden kehityksestä. Lisää tietoa kuluttajien luottamus -tilastosta löytyy tilaston dokumentaatiosta.<sup>2</sup> Tilaston tiedot perustuvat otostutkimukseen, jonka tavoiteperusjoukon muodostavat 18–74-vuotiaat Suomessa asuvat henkilöt. Tilaston tiedot kerätään itse täytettävän verkkolomakkeen ja puhelinhaastattelujen avulla kerran kuukaudessa. Tulokset julkaistaan pääsääntöisesti tutkimuskuukauden 27. päivä.

Tilaston kuukausittainen otoskoko on 2 200 henkilöä. Otanta tehdään systemaattisena satunnaisotantana (SYS) Tilastokeskuksen ylläpitämästä väestötietokannasta. Poimintaa varten otoskehikko lajitellaan kuntakohtaisten asunto- ja huoneistotietojen perusteella. Tutkimusalueena on koko maa. Käytössä on rotatoiva paneeliasetelma: vastaajat osallistuvat tiedonkeruuseen kaksi kertaa puolen vuoden sisällä, ja joka kuukausi puolet otoksesta on täysin uusia vastaajia.

## Tutkimuksen tiedot saadaan pääosin verkkolomakkeelta

Kaikille tutkimukseen valituille lähetetään saatekirje postitse. Verkkovastaaminen on mahdollista heti ensimmäisestä tiedonkeruupäivästä alkaen aivan kaikille otokseen poimituille. Puhelinhaastatteluja aletaan tehdä vasta muutama päivä tiedonkeruun käynnistymisen jälkeen keskittyen ensin iäkkäämpiin otoshenkilöihin.

Verkkotiedonkeruuta alettiin hyödyntää puhelinhaastattelujen rinnalla toukokuussa 2019, jolloin verkossa vastasi noin 60 % vastaajista. Muutamassa vuodessa verkossa vastanneiden osuus kuitenkin nousi jo lähelle 80:tä % ja vuonna 2024 verkkovastaajien osuus onkin pysytellyt joka kuukausi 80 %:n tuntumassa. Nuoremmissa ikäryhmissä verkkovastaaminen on selvästi yleisempää kuin vanhemmissa ikäryhmissä, mutta vanhimmissa ikäryhmissä (45–54-vuotiaat, 55–64-vuotiaat ja 65–74-vuotiaat) verkkovastausten osuus on kuitenkin noussut merkittävästi. Esimerkiksi 65–74-vuotiaista vastaajista 48 % vastasi verkossa vuonna 2019, mutta vuonna 2024 vastaava osuus oli jo noin 66 %.

## Yli puolet otokseen poimituista osallistui tutkimukseen vuonna 2024

Tutkimuksen vastausaste on vaihdellut kuukausittain viimeisten vuosien aikana jonkin verran. Ajanjaksolla 5/2019–7/2023 otokseen poimituista keskimäärin 47 % vastasi tutkimukseen. Vastauskadossa tapahtui kuitenkin merkittävä myönteinen käänne elokuussa 2023, kun Tilastokeskus sai käyttöönsä Kelalta henki-

<sup>2</sup><https://stat.fi/tilasto/dokumentaatio/kbar>



löiden yhteystietoja: keskimääräinen vastausaste ajanjaksolla 8/2023–8/2024 oli 55 %.

Merkittävin kadon syy on tavoittamattomuus. Vuonna 2022 lähes puolet, eli 46 %, otokseen poimituista jäi tavoittamatta ja vain noin 7 % kieltäytyi osallistumasta. Kelan yhteystietojen saamisen myötä tavoittamatta jääneiden osuus otokseen poimituista kuitenkin väheni selvästi ja esimerkiksi vuonna 2024 tavoittamatta jäi enää vain 34 % otokseen poimituista. Kieltäytyneiden määrään ei Kelan yhteystiedoilla ole ollut vaikutusta.

## **Koulutus, ikä, sosioekonominen asema ja tulot vaikuttavat tutkimukseen osallistumiseen**

Kaikille otokseen poimituille voidaan yhdistää Tilastokeskuksen rekistereistä demografiset taustatiedot sekä muita rekisteritietoja esimerkiksi tuloista ja sosioekonomisesta asemasta. Demografiset taustatiedot (sukupuoli, ikä, koulutus) tiedot voidaan poimia kaikille haastatteluhetken mukaan, mutta rekisteritiedot tuloista ja sosioekonomisesta asemasta valmistuvat haastatteluhetken nähden viiveellä.

Koulutuksen suhteen innokkaimpia vastaajia ovat korkeasti koulutetut. Vuonna 2024 korkeasti koulutetuista otokseen poimituista 68 % osallistui tutkimukseen, kun taas vain perusasteen tutkinnon suorittaneista 39 % osallistui.

Ikäryhmittäisessä tarkastelussa eläkeikäiset ovat innokkaimpia vastaajia, sillä 65–74-vuotiaiden ryhmässä 64 % otokseen poimituista osallistui vuonna 2024 tutkimukseen. Vastaava osuus oli esimerkiksi nuorten 18–24-vuotiaiden ikäryhmässä selvästi pienempi, eli 43 %.

Sosioekonomisen aseman ja tulojen vaikutusta vastaamiseen oli mahdollista tutkia vuoden 2023 loppuun sijoittuvalla ajanjaksolla (7/2023–12/202). Kysyisten kuukausien otokselle oli mahdollista yhdistää Tilastokeskuksen rekisteripohjaisen työssäkäyntitilaston tieto henkilön sosioekonomisesta asemasta vuonna 2022. Samaan tapaan ajanjaksolle oli mahdollista yhdistää Tilastokeskuksen tulonjakotilaston tieto tuloviidenneksestä vuonna 2022.

Tehtyjen tarkastelujen perusteella osoittautui, että vuoden 2023 loppupuolella (7/2023–12/202) vastaaminen oli yleisintä ylemmillä toimihenkilöillä: 68 % otokseen poimituista ylemmistä toimihenkilöistä vastasi tutkimukseen. Sen sijaan osallistuminen oli heikointa työntekijöiden joukossa, sillä vain 43 % otokseen poimituista työntekijöistä vastasi tutkimukseen. Tulojen suhteen tarkasteltaessa vastausinnokkuus kasvoi tulotason kasvaessa: suuritoisimpaan viidennekseen kuuluvista otokseen poimituista 62 % osallistui tutkimukseen, kun taas pienituloisimpaan viidennekseen kuuluvista otokseen poimituista 42 % osallistui tutkimukseen.

## **Vastaukset korjataan suhteessa väestörakenteeseen**

Kaikki tilaston vastaustiedot korotetaan perusjoukon tasolle painokertoimien avulla. Ensin muodostetaan katokorjatut asetelmapainot. Analyysipainot saadaan kalibrointimenetelmällä (Calmar<sup>3</sup>) niin, että valittujen taustamuuttujien (henkilön sukupuolen, ikäryhmän, koulutusasteen ja asuinalueen) estimoidut reunajakaumat vastaavat koko perusjoukosta saatua reunajakaumia eli väestörakennetta.

---

<sup>3</sup><https://www150.statcan.gc.ca/n1/en/catalogue/11-522-X20030017713>

Vastauskadon korjaaminen etenkin koulutuksen suhteen on tärkeää, sillä tutkimukseen vastanneiden joukossa on selvästi yliedustusta korkeasti koulutetuissa ja aliedustusta vain perusasteen tutkinnon suorittaneissa.

Esimerkiksi elokuussa 2024 tutkimuksen perusjoukkoon kuuluvista 22 % oli suorittanut vain perusasteen tutkinnon. Kun rajataan tarkastelu tutkimukseen vastanneisiin, vain 15 % heistä oli sellaisia, joiden korkein suoritettu tutkinto oli perusasteen tutkinto. Näin ollen vain perusasteen tutkinnon suorittaneiden aliedustus vastanneiden joukossa oli melko suuri.

Samaan aikaan elokuussa 2024 korkeasti koulutettujen yliedustus vastanneiden joukossa oli melko suuri: perusjoukkoon kuuluvista 35 % oli suorittanut korkea-asteen tutkinnon, kun vastanneista peräti 44 % oli suorittanut korkea-asteen tutkinnon.

# Yksityiskohtaisten taustatietojen käyttömahdollisuuksista kyselyaineistojen analyysissä

RISTO LEHTONEN

RISTO.LEHTONEN@HELSINKI.FI

EMERITUSPROFESSORI

JYVÄSKYLÄN YLIOPISTO

**Avainsanoja:** MRP-menetelmä; Valikoituminen; Pienalue-estimointi

## Johdanto

Tässä esityksessä tarkastellaan populaatioyksikköjä koskevien yksityiskohtaisten tietojen käyttöä taustatietoina pienalue-estimoinnissa. Päähuomio on MRP-menetelmän kyvyssä reagoida tietojen avulla kyselyyn osallistujaksi valikoitumiseen. Suppea esitys perustuu Juha Alhon järjestämässä Tilastoseuran iltapäiväseminaarissa pidettyyn suomenkieliseen esitelämään syyskuulta 2024.

## MRP-menetelmä: Yleistä

Andrew Gelmanin ja Rod Littlen (1997) monitasoisen regressiomallinnuksen ja jälkiosituksen yhdistelmä *Multilevel regression and post-stratification*, MRP, on yleistymässä alueellisten vaaliennusteiden laatimisessa mielipidemittausten avulla. Britannian parlamenttivaalit perustuvat niin sanottuun First past the post -järjestelmään, jossa alahuoneeseen valitaan 650 jäsentä yhtä monesta vaalipiiristä. Kussakin vaalipiirissä järjestetään erilliset vaalit, ja eniten ääniä saanut ehdokas valitaan parlamenttiin. Asetelma voidaan nähdä pienalue-estimointina (*Small area estimation*; Rao 2003), johon MRP on tarjonnut vaihtoehdon perinteisille menetelmille. Britanniassa MRP-menetelmää on käytetty YouGovin vaalikyselyissä vuosina 2017 ja 2019, ja vuoden 2024 vaaleissa mukaan tuli muita toimijoita. Otokset ovat yleensä suuria verrattuna perinteisiin valtakunnallisiin mielipidemittauksiin, jotta voidaan tuottaa alueellisia vaaliennusteita. YouGovin kyselyssä kesäkuussa 2024 otoskoko oli lähes 40 000 ihmistä. Yhdysvalloissa YouGovin viimeinen ennen vaaleja tehty MRP-kysely (55 000 osallistujaa) lopulta ennusti Kamala Harrisin voittoa.

YouGovin Britannian ja Yhdysvaltojen yksiköiden avoimessa dokumentaatiossa on selostettu yleisellä tasolla vaalikyselyiden metodiikkaa, kuten harkintaperusteista otantaa yhtiön omasta online-paneelistä, ulkoisen informaation lähteitä ja estimointia MRP:n jälkiositusmenetelmällä. Kirjallisuuden selaaminen paljastaa, että MRP:n tietolähteet voivat vaihdella paljon. Lähteenä voi olla kyselytutkimus, joka on tehty otokselle äänioikeutetusta väestöstä, tai jokin täysin erilainen tietolähde. Jälkimmäistä aineistolähdettä Wang, Rothschild, Goel ja Gelman (2015) demonstroivat tunnetussa artikkelissaan US:n presidentinvaalien 2012 ennustamisesta MRP-menetelmällä, kun lähteenä ovat Xbox-pelialustan tiedot käyttäjien äänestysaikomuksista.

Morris Hansenin, William Madowin ja Benjamin Teppingin klassisen artikkelin (1983) ja sen kommenttien argumentti, että minkä tahansa tutkimustuloksia koskevan mallin tulisi perustua kaikkiin tietoihin, jotka ennustavat osallistumistodennäköisyyksiä, on edelleen ajankohtainen.

## Valikoituminen

Todennäköisyysotannassa kyselyyn valikoitumisen todennäköisyys on tunnettu, tai osittain tunnettu, jos kyselyssä on vastauskatoa. Avoimissa nettikyselyissä (*online opt-in polls*) valikoitumismekanismeja ei tunneta. Eri tilanteisiin on laaja kirjallisuus; ensin mainittua, jossa valikoituminen perustuu otantamenetelmään, tarkastelee esimerkiksi Lehtonen, Särndal ja Veijanen (2005). Valikoitumista MRP-menetelmän yhteydessä käsitellään harvoin kontekstissa, jossa estimoinnin tarkentuvuus valikoitumisasetelman suhteen (*design consistency*) on preferoitu ominaisuus. Yajuan Si (2023) tarjoaa poikkeuksen. Hänen teoriansa yksi kriittinen ehto on, että populaatioyksiköiden lisätiedon (*Auxiliary information*) avulla muodostettu jälkiosituksen solurakenne reagoi täysimääräisesti asetelmainformaatioon ja valikoitumismekanismiin (Si 2023, 7–8). Kun oletus on voimassa, MRP-estimaattori on asetelman suhteen tarkentuva kuten perinteinen jälkiositettu estimaattori, joka asetelmaperusteisena estimaattorina on tarkentuva määritelmänsä perusteella.

Tässä esityksessä tutkitaan MRP:n tarkentuvuusominaisuuksia pienalueestimoinnissa. Esitys perustuu kongressiesitelmiin Lehtonen ja Veijanen (2022).

Ensimmäinen kysymys koskee MRP:n kykyä reagoida valikoitumiseen, kun todennäköisyysotannan menetelmä on tiedossa. Esimerkiksi Poisson-otannassa otokseen valikoituminen on verrannollinen lisämuuttujan arvoon, joka tiedetään kaikille populaation yksiköille. Tutkitaan MRP:n reagointia otantamenetelmään regressiomallin spesifiointivaiheessa ja jälkiosituksen solurakenteen määrittämisessä, kun kokomuuttuja korreloi tutkimusmuuttujan kanssa.

Toinen aihe on lisätiedon merkitys, kun valintamekanismeja ei tunneta. Voi olla hyödyllistä, jos käytettävissä on valikoitumiseen ja tutkittavaan ilmiöön korreloivaa tietoa. Mitä hyötyä tietojen käyttämisestä estimointiin on, ja mitä menetetään, jos tietoja ei käytetä? Tässä jaksossa tarkastellaan simulaatioon perustuvaa tutkimusasetelmaa ja tehdään alustavia havaintoja.

## Estimointiasetelma ja estimaattori

Estimoitavana parametrina on binäärisen muuttujan  $Y$  suhteellinen osuus  $p_d$  äärellisen  $N$  alkion populaation  $U$  kohdealueilla  $U_d \subset U, d = 1, \dots, D$ :

$$p_d = \frac{t_d}{N_d} = \frac{\sum_{k \in U_d} Y_k}{N_d}, d = 1, \dots, D,$$

missä  $Y_k$  on muuttujan  $Y$  arvo alkiolle  $k \in U$  ja  $N_d$  on alueen  $U_d$  tunnettu koko,  $\sum_{d=1}^D N_d = N, d = 1, \dots, D$ . Käytännön tilanteissa kohdealueita on usein lukuisia; esimerkiksi Britannian parlamenttivaaleissa populaatio koostuu äänioikeutetusta väestöstä ja kohdealueita on 650.

Oletetaan vektori  $\mathbf{x}_k = (x_{1k}, \dots, x_{Jk})'$  tunnetuksi kaikille  $k \in U$ . Vektori  $\mathbf{x}_k$  edustaa populaation yksiköistä saatavilla olevaa, tutkimukselle relevanttia lisätietoa, esimerkiksi yksiköiden demografisia, sosioekonomisia ja alueellisia rekisteritietoja. Oletetaan lisäksi, että populaation yksiköt ovat yksikäsitteisesti identifioitavissa, eikä puuttuvia tietoja ole.

Osuuden  $p_d$  MRP estimaattori alueella  $U_d$  on muotoa:

$$\hat{p}_d = \sum_{c=1}^{C_d} \frac{N_{dc}}{N_d} \hat{\theta}_{dc}, d = 1, \dots, D,$$

missä  $\hat{\theta}_{dc} = \sum_{k \in U_{dc}} \hat{y}_k / N_{dc}$ ,  $c = 1, \dots, C_d$ , on mallilla estimoitu alueen  $d$  jälkiositteen  $c$  osuusestimaattori,  $N_{dc}$  on tunnettu jälkiositteen  $c$  koko alueella  $U_d$ ,  $\sum_{c=1}^{C_d} N_{dc} = N_d$ . Tärkeä huomio on, että kun tavallisessa jälkiosituksessa  $\hat{y}_k$ :n tilalla ovat otosarvot  $y_k$ , joiden lukumäärä on  $n_{dc}$  eli jälkiositteen otoskoko, niin vastaavia  $\hat{y}_k$ -arvoja on  $N_{dc}$ , eli lukumäärä populaatiossa.

Mallilla estimoitu sovite  $\hat{y}_k$  alkion  $k$  perustuu tässä esityksessä logistiseen sekamalliin:

$$\hat{y}_k = \frac{\exp(\hat{\eta}_k)}{1 + \exp(\hat{\eta}_k)} = \frac{\exp(\mathbf{x}'_k \hat{\beta} + \hat{\mathbf{u}}_d)}{1 + \exp(\mathbf{x}'_k \hat{\beta} + \hat{\mathbf{u}}_d)}, k \in U,$$

missä  $\hat{\beta}$  on mallin estimoitujen kiinteiden vaikutusten vektori ja  $\hat{\mathbf{u}}_d$  ovat satunnaisvaikutuksia alueelle  $U_d$ .

## Otanta-asetelma tunnetaan

Lehtosen ja Veijasen (2022) Monte Carlo simulointiasetelmassa  $N = 10000$  alkion hierarkkinen populaatio koostuu 5 alueesta  $U_r$  ja 15 osa-alueesta  $U_t$ . Binäärisen  $Y_k$ :n keskiarvo populaatiossa on 0.0988, eli ilmiö ei ole kovin yleinen. Pienalue-estimoinnissa on perusteita käyttää logistista mallia.

Populaatio luodaan logistisella sekamallilla, joten populaation generointimekanismi on tunnettu:

$$\eta_k = \text{logit}(E(Y_k)) = \beta_0 + \sum_{i=1}^2 \beta_{1i} x_{1ik} + \sum_{i=1}^2 \beta_{2i} x_{2ik} + \beta_3 x_{3k} + \beta_4 x_{4k} + \gamma z_k + u_{r[k]} + v_{t[k]}, u_r \sim N(0, \sigma_u^2), v_t \sim N(0, \sigma_v^2)$$

missä  $x_{1i}$  ja  $x_{2i}$ ,  $i = 1, 2$ , ovat kolmiluokkaisten muuttujien  $x_1$  ja  $x_2$  luokkaindikaattoreita,  $x_3$  on jatkuva yksikkötasoinen muuttuja ja  $x_4$  on jatkuva osa-alueitasoinen muuttuja. Muuttuja  $z$  on Poisson-otannassa käytetty lisämuuttuja, jonka korrelaatio sovituksen kanssa on  $\text{cor}(\eta, z) = 0.8$ . Termit  $u_r$  ja  $v_t$  ovat osa-aluekohtaisia satunnaisia päävaikutuksia.

Kiinnostuksen kohteena olevia kohdealueita  $U_d$  on kaikkiaan  $D = 45$ , jotka on luotu ristiintaulukoimalla alueet  $U_t$  ( $t = 1, \dots, 15$ ) kolmiluokkaisen muuttujan  $x_1$  kanssa. Pieniksi alueiksi kutsutaan niitä, joissa on alle 20 alkion.

Simulointikokeissa poimitaan  $K = 1000$  kokoa  $n = 1000$  olevaa riippumattonta Poisson-otosta  $s_j$  ( $j = 1, \dots, 1000$ ). Tarkastellaan kahta skenaariota:

**Skenaario 1** Muuttujan  $z$  kvartiilimuuttuja  $z_q$  ei ole mukana MRP-mallissa eikä jälkiosituksessa. Jälkiositteita luodaan 135, eli 3 solua muuttujan  $x_2$  mukaan kussakin kohdealueessa  $U_d$ .

**Skenaario 2** Muuttujan  $z$  kvartiilimuuttuja  $z_q$  on MRP-mallissa ja jälkiosituksessa. Saadaan 540 jälkiositetta, eli 12 solua muuttujien  $x_2$  ja  $z_q$  mukaan kussakin kohdealueessa  $U_d$ .

Otospoiminnoissa sovitteet  $\hat{y}_k = \exp(\hat{\eta}_k) / (1 + \exp(\hat{\eta}_k))$ ,  $k \in U$ , MRP-estimointia varten lasketaan kahdella mallilla, joista ensimmäinen on skenaariolle 1 ja toinen skenaariolle 2:

**Malli 1**  $\hat{\eta}_k = \hat{\beta}_0 + \hat{\beta}_4 x_{4k} + \hat{\alpha}_{i[k]}^{x_1} + \hat{\alpha}_{j[k]}^{x_2} + \hat{u}_{d[k]}$ ,  $k \in s_j$  ( $j = 1, \dots, 1000$ )

**Malli 2**  $\hat{\eta}_k = \hat{\beta}_0 + \hat{\beta}_4 x_{4k} + \hat{\alpha}_{i[k]}^{x_1} + \hat{\alpha}_{j[k]}^{x_2} + \hat{\alpha}_{l[k]}^{z_q} + \hat{u}_{d[k]}$ ,  $k \in s_j$  ( $j = 1, \dots, 1000$ )

missä  $\alpha^{x_1} \sim N(0, \sigma_{x_1}^2)$ ,  $\alpha^{x_2} \sim N(0, \sigma_{x_2}^2)$ ,  $\alpha^{z_q} \sim N(0, \sigma_{z_q}^2)$  ja  $u_d \sim N(0, \sigma_u^2)$ , ja  $z_q$  ovat Poisson-lisämuuttujan  $z$  kvartiileja. Estimoinnissa käytettiin R-ohjelmaa autoMrP (Broniecki, Leemann and Wuest 2022).

Alla olevassa taulukossa esitetään skenaarioiden mukaiset tulokset (harha ja variaatio (%)) 45 kohdealueella. Simulaatioissa on 1000 riippumatonta 1000 alkion Poisson-otosta, lisämuuttujana on  $z$  (Lehtonen and Veijanen 2022).

	Harha		Variaatio	
	ARB mediaani (%)		RRMSE mediaani (%)	
	Pienet < 20 (30 aluetta)	Suuret ≥ 20 (15 aluetta)	Pienet < 20 (30 aluetta)	Suuret ≥ 20 (15 aluetta)
Skenaario 1				
135 jälkiositetta z ei mukana	29.4	31.5	65.9	54.9
Skenaario 2				
540 jälkiositetta z on mukana	15.6	8.2	47.0	37.7

missä absoluuttinen suhteellinen virhe (*Absolute relative error ARB*) on:

$$ARB(\hat{p}_d) = \frac{1}{1000} \sum_{j=1}^{1000} |\hat{p}_d(s_j) - p_d| / p_d$$

ja keskineliövirhe MSE:n neliöjuuren suhde parametriin (*Relative root mean squared error RRMSE*; vastaa käsitettä suhteellinen keskivirhe) on:

$$RRMSE(\hat{p}_d) = \sqrt{(1/1000) \sum_{j=1}^{1000} (\hat{p}_d(s_j) - p_d)^2 / p_d}$$

Taulukon mukaan otokseen valikoitumistieto (otanta-asetelma) mallissa ja jälkiosituksessa pienentää selvästi asetelmaharhaa ja estimointitarkkuutta. Jos tietoon ei reagoida, harha saattaa jopa kasvaa kohdealueen otoskoon kasvaessa, toisin kuin toisessa skenaariossa, jossa harha pienenee, mikä viittaa mahdollisuuksien asetelmatarkentuvuudesta ja siten osaltaan voi tarkasteltujen tyyppisissä tilanteissa tukea Yajuan Si:n teoriaa (Si 2023). Lisäksi estimoinnin tehokkuus paranee molemmissa skenaarioissa siirryttäessä pienistä kohdejoukoista suuriin, ja estimointi on tehokkaampaa skenaariossa 2, mikä johtuu valikoitumisen korrelaatiosta tutkimusmuuttujan kanssa.

## Huomioita, kun valikoitumismekanismia ei tunneta

Kyselyn vastaajaksi valikoitumisen mekanismin ollessa tuntematon voidaan pyrkiä pienalue-estimointia varten mallintamaan valikoitumista siihen mahdollisesti yhteydessä olevien taustatietojen avulla. Tässä esitetään simulointiperusteisen tutkimusasetelman pääpiirteitä, jossa on osin samoja elementtejä kuin edellisessä esimerkissä, kun valikoituminen tunnettiin. Binäärisen tutkimusmuuttujan keskiarvo populaatiossa on 25% ja (käytännössä tuntematon) vastausalttius on  $R = 50\%$ , eli puolet kustakin poimitusta Bernoulli-otoksesta osallistuu. Oletetaan lisäksi, että tuntematon osallistumistodennäköisyys korreloi tutkimusmuuttujan kanssa, mikä on käytännössä yleistä erilaisissa avoimissa online-optin mielipidekyselyissä.

Käytettävissä on muuttuja  $z$ , joka korreloi sekä vastausalttiuteen että tutkimusmuuttujaan, jolle  $\text{cor}(z, \eta) = 0.48$ . Populaatio luodaan vastaavalla sekamallilla kuin edellisessä esimerkissä, paitsi että muuttuja  $x_4$  ei ole mukana. Sovitteet  $\eta_k$  lasketaan poimituista Bernoulli-otoksista kaikille  $k \in U$  vastaavan tyyppisillä supistetuilla malleilla kuin edellisessä esimerkissä.

Tarkasteltavista skenaarioista ensimmäisessä muuttujalla  $z$  ei ole roolia MRP-mallissa eikä jälkiosituksessa, jolloin jälkiositteita on kaikkiaan 135 kuten edellä. Toisessa skenaariossa muuttujan  $z$  kvartiilimuuttuja  $z_q$  laitetaan MRP-malliin ja jälkiositukseen, jolloin saadaan 180 jälkiositetta.

Simulointien perusteella MRP-estimaattorin suhteellinen virhe (*Relative error*)  $\text{RE}(\hat{p}_d) = \frac{1}{1000} \sum_{j=1}^{1000} (\hat{p}_d(s_j) - p_d) / p_d$   $K = 1000$  riippumattomaan 1000 alkion Bernoulli-otannassa skenaarioille 1 ja 2 viittaa siihen, että valikoitumiseen reagointi voi parantaa estimointia (harha pienenee), mutta selviä merkkejä tarkentuvuudesta valikoitumisasetelman suhteen ei ole toistaiseksi voitu todeta.

## Diskussio

Tulokset osoittivat, että jos kyselyyn valikoitumiseen ei reagoida, voi MRP-estimaattorin harha pienillä alueilla kasvaa otoskoon kasvaessa, jolloin harhasta voi tulla MSE:n hallitseva komponentti, eikä tarkentuvuus toteudu. Harhaa on mahdollista vähentää sisällyttämällä jälkiosituksen solurakenteeseen valikoitumiseen liittyvää tietoa, minkä osoitti ensimmäinen esimerkki.

Tässä esitetty rajallinen empiirinen harjoitus suosittelee lisätutkimuksia monitasoiseen regressiomallinnukseen ja jälkiositukseen perustuvan MRP-lähestymistavan rajoituksista ja mahdollisuuksista suhteessa muihin alueellisten tarkastelujen tilastollisiin menetelmiin.

## Kiitokset

Kiitos Ari Veijaselle huomioista, jotka paransivat kirjoitusta.

## Viitteet

Broniecki P., Leemann L. and Wuest R. (2022) Improved multilevel regression with poststratification through Machine Learning (autoMrP). *The Journal of Politics*, 84, 1, 597–601.

Gelman A. and Little T. C. (1997) Poststratification into many categories using hierarchical logistic regression. *Survey Methodology*, 23, 2, 127–35.

Hansen M. H., Madow W. G. and Tepping B. J. (1983) An evaluation of model-dependent and probability-sampling inferences in sample surveys. (With discussion.) *Journal of the American Statistical Association*, 78, 776–793.

Lehtonen R., Särndal C.-E. and Veijanen A. Does the model matter? Comparing model-assisted and model-dependent estimators of class frequencies for domains. *Statistics in Transition*, 7, 649–673.

Lehtonen R. and Veijanen A. (2022) Model-assisted calibration and MRP methods for small area estimation: an empirical comparison. ITACOSM Conference, Perugia 2022; Workshop of the Baltic-Nordic Network on Survey Statistics, Tartu 2022.

Si Y. (2023) On the use of auxiliary variables in multilevel regression and poststratification.

<https://arxiv.org/abs/2011.00360v4> (Thu, 2 Mar 2023)

Wang W., Rothschild D., Goel S. and Gelman A. (2015) Forecasting elections with non-representative polls. *International Journal of Forecasting* 31, 3, 980–991.



# Kun vastauksiin pitää keksiä kysymyksiä – kokemuksia sosiaalisten verkkoaineistojen kesyttämisestä yhteiskuntatieteelliseen tutkimukseen

MIKA PANTZAR

EMERITUSPROFESSORI

KULUTTAJATUTKIMUSKESKUS, HELSINGIN YLIOPISTO

## Tiivistelmä

Tässä artikkelissa kuvaan omasta henkilökohtaisesta (ja Helsingin yliopiston Kuluttajatutkimuskeskuksen) näkökulmasta 70 miljoonan kommentin Suomi24 -aineiston saatamista tutkijoiden käyttöön. Osallistuimme Helsinki Challenge tiedekilpailuun hankkeella, jolle annoimme nimen Citizen Mindscapes. Kymmenen vuoden aikana mukaan on tullut useita eri tieteenalojen tutkijoita eri puolelta Suomea. Artikkelissa keskityn kuvaamaan erilaisia jännitteitä, joita tämän kaltaiseen hankkeeseen liittyy. Monitieteiseen yhteistyöhön jälkensä ovat jättäneet esimerkiksi tilastotiede, tietojenkäsittelytiede, digitaalinen humanismi, datatiede, laskennallinen yhteiskuntatiede, kielitiede, tekoälytutkimus ja lukuisat yhteiskuntatieteet. “Big datan” ympärille muodostuneita tiedetraditioita kutsun metaforisesti “mantereiksi”, joissa on omat sääntönsä, jotka kuitenkin tarvitsevat kehittyäkseen myös keskinäistä “kaupankäyntiä”. Kaupallisena käsitteenä Big Data syntyi uuden vuosituhannen ensimmäisiä vuosina. Akateemiseen tutkimukseen se juurtui Big Data & Society -lehden myötä vuodesta 2014. Samaan aikaan saivat alkunsa sellaiset käsitteet kuin dataismi ja kriittinen datatutkimus.

## Kansan ja yhteiskunnan tutkimuksen kolme sukupolvea

Empiiristen yhteiskuntatutkimuksen aineistojen historia voidaan ranskalaisen sosiologin Dominique Boullierin (2016) mukaan yksinkertaistaa kolmeen aaltoon. 1700-luvulla alkunsa saivat rekisteripohjaiset väestötilastot ja ne palvelivat lähinnä poliittisia ja kansallisia intressejä. Toista sukupolvea Boullier kutsuu ”mielipidetutkimuksen ajaksi” (”age of opinion”). 1900-luvun alkupuoliskolla käynnistynyt mielipidetutkimuksen taustalla oli sekä kaupallisia että poliittisia intressejä. Gallup-tutkimukset lienevät tunnetuimpia. Tilastotieteellä oli merkittävä rooli: Otokset ja edustavuus olivat tärkeitä käsitteitä.

Institutionaaliset toimijat, valtiot ja yritykset esittävät kysymykset kahdessa ensimmäisessä empiirisen tutkimuksen aallossa. Uusimmassa eli kolmannessa aallossa olemassa oleviin vastauksiin eli kansalaisten tuottamiin teksteihin täytyy pikemminkin keksiä relevantteja kysymyksiä. Boullier kutsuu tätä aikakautta datan, ennustemallien ja korrelaatioiden ajaksi (”age of data and predictive correlations”). Uudenlaiset digitaaliset mittarit ja sosiaalinen media tuottavat aineistoja, jotka mahdollistivat kansalaisten monimuotoisten jälkien seuraamisen, ja niistä päättämisen.

Vuosituhanen vaihteessa Wired -lehdessä esitettiin End of Science-otsikolla, että tiede on väistyvä käytäntö: Big datan tarjoamat korrelaatiot kertovat kaiken tarpeellisen yhteiskunnasta (Anderson 2008). Tällainen käsitys googlen kaltaisten jättien vykkyksistä ilman teoreettista tai tulkitsevaa otetta ei kuitenkaan ole osoittautunut paikkaansa pitäväksi. Kolmijako ei tietenkään merkitse sitä, että rekisteritutkimusta tai mielipidetutkimusta ei enää tehtäisi.

Suomi 24 aineiston avaamisesta on nyt kymmenen vuotta ja seuraavassa esitän oman näkemykseni kolmannen aallon tutkimuksesta. Kirjoituksen lopussa palaan yleisempiin kriittisiin huomioihin, jotka liittyvät 2010-luvulla alkunsa saaneeseen big data-myyttiin. Haluan korostaa, että isojen aineistojen käsittely ja analysointi, tässä tapauksessa vajaan sadan miljoonan kommentin Suomi24, vaatii lukuisia toimijoita ja komplementaarista osaamista.

## Suomi 24 aineiston avaaminen akateemiselle tutkimukselle

Tutkimusrahoituksen haussa itseni kaltaiset senioritutkijat syyllistyvät helposti erilaisiin liioitteluihin esimerkiksi datan suuruuden, käyttökelpoisuuden tai luotettavuuden merkityksestä. Näin kävi itselleni, kun olin aloitteentekijä Suomi 24-aineiston avaamisessa tutkijakäyttöön elokuussa 2014. Oma roolini oli lähinnä hankkeen ideointi, mahdollistaja, ja tutkimuslupausten laatiminen. Rahoitusta saimme muun muassa Teke-sistä, Suomen Akatemiasta ja Teknologiateollisuuden 100-vuotissäätiöstä.

Ensimmäisen palaverin pidimme Helsingin Kauppatorin kahviteltassa elokuussa 2014. Olin kutsunut keskustelemaan Suomi 24-aineiston avaamisesta (akateemisille tutkijoille) aineiston omistajan edustajana Allerin toimitusjohtaja Pauli Aalto-Setälän ja psykologian emeritusprofessori Göte Nymanin. Kolmantena mukaan tuli Teknisessä korkeakoulussa kieliteknologiasta väitellyt Krista Lagus, joka oli toiminut akateemikko Teuvo Kohosen itseorganisoituvia karttoja kehittävässä tutkijaryhmässä. Yhdessä päätimme aineiston avaamisesta ja osallistumisesta Helsingin yliopiston Challenge-tiedekilpailuun. Citizen Mindscapes nimen hankkeellemme ehdotti antropologi Minna Ruckenstein. Uskoimme avaavamme melkein reaaliaikaisen väylän kansakunnan mielialoihin ja tunnelmiin.

Suomi24 on yksi maailman pitkäikäisimpiä ja laajimpia verkkokeskusteluaineistoja, joka oli saanut alkunsa juuri ennen vuosituhanen vaihdetta. Siinä vaiheessa sosiaalisen median käsitettä ei tunnettu ja verkkomedia oli vain harvojen aktivistien käytössä. Citizen Mindscapes hankkeen toimijoiden määrä kasvoi nopeasti. Kiinnostuksesta kertoo se, kuinka vuonna 2015 perustamassamme Facebook-ryhmässä oli 295 jäsentä. Krista Laguksen kanssa kuvasimme perustamaamme Facebook-ryhmää seuraavasti: ”Tunnistamme dynaamisesti kansalaisten mielenliikkeitä, intentioita, ja yhteiskunnallisia murroskohtia ja jakolinjoja. Mitä jakolinjoja on, ja miten ne muuttuvat ajan myötä? Miten näitä mielenliikkeitä voidaan visualisoida ymmärrettävästi poliitikoille, medialle, ja kansalaisille? Miten kieliteknologia, tekstianalyysi ja koneoppiminen voivat auttaa löytämään, tunnistamaan ja nimeämään näitä liikkeitä? Miten voidaan vahvistaa rauhanomaisia, positiivisia ja yhteisymmärrystä lisääviä kehityskulkuja näiden jakolinjojen tuntumassa, ja välttää konfliktien kärjistymisen väkivallaksi?”

Vuosina 2014-2024 Helsingin yliopiston HELDA tietokannasta löytyy 174 julkaisua, joissa viitataan Suomi24-aineistoon. Samaan aikaan GoogleScholarista löytyy 2000 viittausta samaan datalähteeseen. Citizen mindscapes - otsikkoon viitataan 84 kertaa.

Virikkeen isojen tekstiaineistojen avaamisesta tutkijakäyttöön olin saanut akateemikko Teuvo Kohosen kollegalta ja oppilaalta Timo Honkelalta. Lukuisten golfkierostemme aikana jaoimme tietoa toistemme töistä. Kehitimme myös innostavia yhteisiä hankkeita kansalaisten hyvinvoinnin ja terveyden mittarointiin yhdessä Vierumäen urheiluopiston kanssa. Vakuutuin, että big data -analytiikka, esimerkiksi itseorganisoituvat kartat ja aihehallinnukset, tulevat vahvasti yhteiskuntatieteisiin massiivisten tekstiaineistojen myötä.

Vuosituhanen ensimmäisellä vuosikymmenellä Big Data-käsitettä tekivät tunnetuiksi IBM:n kaltaiset tietotekniikkajätit, O'Reilly Media ja McKinseyn konsultit. Toimijat viittasivat uudenaikaiseen liiketoimintaan, joka on syntymässä jättiläismäisten ja monimuotoisten ('unstructured data') aineistojen kertyessä yritysten rekistereihin. Oxford English Dictionary:iin käsite tuli ensimmäisen kerran vuonna 2013. Tätä ennen käsitettä oli käytetty myös mm. kirjastotieteessä viittaamaan informaatoräjähdykseen. Käsitteiden luominen on osa nykyaikaista liiketoimintaa. O'Reilly Media on ollut ehkä kaikkein aktiivisin digitaalijalan sanaston luoja. Big datan lisäksi mediatoimisto on luonut julkisuuteen muun muassa Web 2.0 -käsitteen kuten myös 'Open source'-termin.

Itse olin tutustunut big data-tematiikkaan 2000-luvun alkupuolella New Yorkissa järjestetyssä seminaarissa, jossa kaupalliset toimijat väittivät mahdolliseksi seurata lähes reaaliaikaisesti yhteiskunnan muutoksia. Samoihin aikoihin olin tutustunut kuuluisan tieteen ja teknologian tutkija Bruno Latourin ajatuksiin, joiden mukaan digitalisaation myötä lähes kaikkea ihmismailman ilmiötä voidaan seurata reaaliaikaisesti. Tutkimuskäytännöissä voidaan tämän näkökulman myötä luopua erottelemasta mikro- ja makrotasoa toisistaan (kts. 'flat ontology', Schatzki 2016). Yhteiskuntaa voidaan vihdoinkin kuvata muuta kuin menneisyyden aggregaattien avulla. Mittavat tekstivirrat mahdollistavat yhteiskunnan kuvaamisen reaaliaikaisesti ja kokonaisuina.

Käynnistysryhmämme aloite siirtyi yliopiston Challenge tiedekilpailun myötä isomalle joukolle, johon kuuluivat torilla kokoontuneiden lisäksi antropologi Minna Ruckenstein, tilastotieteilijät Reijo Sund ja Juha Alho, sekä kulttuurintutkija Jussi Pakkasvirta. Jokaisella oli omanlaisensa kiinnostuksen kohteet. Toimitusjohtaja Pauli Aalto-Setälä kysyi: Voiko isoilla online-aineistoilla lisätä asiakasymmärrystä ja mallintaa empatiaa tai vihapuhetta? Ruckensteinia kiinnosti se, miten tehdä suurilla aineistoilla tutkimusta, joka on sekä refleksiivistä että ontologisesti moninaista. Kognitiotieteilijä Göte Nyman pohti sitä, miten sosiaalisessa mediassa kommunikointi kiinnittyy ihmisten omaan havainto- ja elinympäristöön.

Itseäni kiinnosti keskustelujen evoluutio eli se, miten keskustelun eteneminen muuttaa keskustelujen luonnetta ja kielen rakennetta. Voisiko olla mahdollista tunnistaa suuresta määrästä keskusteluja ja metadatan yleistä logiikkaa samalla tavalla kuin 1800-luvulla opittiin tunnistamaan ihmiselle näkymätöntä infrapuna- tai kuuloaistin ulottumattomissa olevaa ultraääntä. Verkkokeskusteluista käytyä julkista puhetta leimaavat usein silmiin pistävät anekdootit, joiden pohjalta tehdään stereotyyppisiä yleistyksiä esimerkiksi vihapuheesta. Olemme leikkimielisesti todenneet, että helpoin tapa rajoittaa Suomi24-vihapuhetta olisi sulkea Internet yöaikaan.

Hankkeen edetessä erilaiset kysymyksenasettelut ja tiedetraditiot ovat tuottaneet kiinnostavia ja hedelmällisiä jännitteitä. Eriäviä tiedenäkemyksiä voidaan ajatella mantereiksi, joissa on omat lainalaisuutensa ja sääntönsä. Tieteen kehitys edellyttää sekä mantereiden sisäistä opillista koherenssia, että mantereiden välistä vuorovaikutusta. Seuraavassa on kuvaus mantereiden välisestä kaupankäynnistä ja suoranaisestä protektionismista. Kielikuvat voivat olla petollisia, mutta niiden avulla uskon Citizen Mindscape – hankkeen avautuvan parhaiten.

## **Verkkoaineistot mannerten välisessä kanssakäymisessä**

Ensimmäisessä akateemisessa kokouksessamme tilastotieteilijä Reijo Sund varoitti liian induktiivisen otteen ja nopean etenemisen riskeistä. Ensisijaista olisi "jäädättää aineisto", jotta voidaan tehdä toistettavia kokeiluja. Akateemiset tuotokset vaativat tätä. Keskeinen innoittajamme Timo Honkela, varhainen tekoälytutkija, kielitieteilijä ja adaptiivisen informatiikan moniottelija, oli jyrkästi eri mieltä. Tilastotieteen manner kohtasi yhteiskunnallisen tietotekniikan mantereen.

Timo Honkelan mukaan tarvittiin nopeaa etenemistä erilaisten luovien aineistokokeilujen kautta. Opettajansa akateemikko Teuvo Kohosen henkeen "joka aamu pitää keksiä mitä tänään tutkittaisiin". Itse olin aikaisemmin hieman vierastanut Timon

ja hänen kollegoidensa riipeyttä hankkeissa, joissa mallitettiin esimerkiksi vaalikäytäytymistä itseorganisoituvien mallien avulla. Kysyin kriittisesti, eikö teitä lainkaan kiinnosta vuosikymmenien aikana tehty vaalitutkimus ja sen tulokset. Kokeiluista ja ripeästä etenemisestä ja olin kuitenkin nyt samaa mieltä Honkelan kanssa.

Saadaksemme nuorille tutkijoille rahoitusta piti tehdä isoja lupauksia ja jopa liioitella aineiston laadukkuutta. Tiedekilpailussa ja rahahakemuksissa käytimme erilaisia kielikuvia. Iso ja helposti tutkijoiden käytettävissä oleva aineisto oli ”hunajapurkki”, jolla houkuttelimme tutkijoita kehittämään ”kansakunnan henkistä ilmapuntaria post-disiplinäärisessä hengessä”. Yliopisto oli palkannut konsultteja opettamaan meille kilpailijoille start-up kielioppia. Akateemisina ihmisinä toki vierastimme kilpailuun vaatimaa pitchaus-kieltä. Omalle taustaryhmällemme mainostimme hankettamme ja aineistoa Tieteessä tapahtuu -lehdessä (Lagus, Pantzar, Ruckenstein 2015). Tämä oli tärkeää myös Kuluttajatutkimuskeskukselle, joka oli juuri liitetty osaksi Helsingin yliopistoa. Siirtyminen ministeriöiden alaisesta virastosta akateemiseen maailmaan vaati uudenlaisia toimintatapoja ja mielikuvia.

Käynnistysvaiheessa datan laatuun ja tuotantoon liittyi paljon kriittisiä kysymyksiä. Juha Alho on tehnyt ansiokasta työtä tutkimalla noin 70 miljoonan kommentin ajallisia anomaliaita ja puutteita. Tätä työtä teimme myös kirjoittamalla valtiotieteellisen tiedekunnan sarjassa aineistoraportin (Lagus, Pantzar, Ruckenstein & Ylisiurua 2016). Juha Alhon johdolla tilastotieteilijät jatkoivat kunnianhimoisesti luomalla Suomi24-aineistolle MySQL-tietokannan Tieteellisen Laskennan (CSC) koneille. Lukemiseen ja analytiikkaan tarvittiin R-ohjelmointikieltä. Useimmat meistä tutkijoista eivät kuitenkaan käyttäneet näitä hieman työläiksi kokemiamme työkaluja. Halusimme edetä nopeammin.

Voisi yksinkertaistuksena sanoa, että ”tilastotieteen vanhaa mannerta” leimasivat hankkeessamme sellaiset perinteiset käsitteet kuten validointi, verifiointi ja hypoteesien testaaminen. Aineisto pitää puhdistaa, järjestää ja sen tuottamiseen pitää tutustua, jotta toistettavuus toteutuu. Timo Honkelan ja Reijo Sundin melkein päriittäisä keskustelu ensimmäisessä kokouksessamme kertoi uuden ja vanhan mantereen, tietoteknisen datatieteen ja laskennallisen yhteiskuntatieteen, jännitteestä. Uuden mantereen edustajat eivät puhuneet otoskoosta tai aineiston edustavuudesta. Tutkimuksen kohteena ovat aineistot kokonaisuudessaan.

Vanhan mantereen edustajat olivat oikeassa: Melkein mitä tahansa voidaan osoittaa dataa kiduttamalla. He korostivat oikeutetusti tieteenfilosofista keskustelua havaintojen teoriapitoisuudesta ja puhtaan empirismin rajoitteista. Uudella mantereella oli kuitenkin kiire edetä luovasti eteenpäin soutuena. Paul diMaggio (2015) on kuvannut vanhan ja uuden mantereen eroa seuraavasti: ”... computer scientist seem to devote more attention to designing models and less on statistical validation (at least in the social-scientific sense) ... Ultimately, however the computer science perspective is liberating, as it forces us to recognize real interpretive uncertainty and seek out appropriate and substantively relevant forms of validation fitted to specific research goals.” (DiMaggio 2015, 2)

## Uuden mantereen vapaudet

Tekniikan tohtorit Timo Honkela ja Krista Lagus edustivat hankkeessamme uuden mantereen vapautunutta ja ennakkoluulotonta ajattelutapaa. Heidän taustallaan oli kielitieteellistä osaamista. Mukaan saimmeikin varhaisessa vaiheessa kielipankin ja kieliteknologian tiedetraditiot. Suomalaisten yliopistojen, CSC:n ja Kotimaisten kielten keskuksen muodostama FIN-CLARIN kielipankki ja konsortio auttoi sekä sopimusteknisissä asioissa että aineistojen muokkaamisessa kielitieteelle ominaiseen pelkistettyyn perusmuotoon. Itse opin ”skreippaamisen”, ”lemmatsoinnin” ja ”tokenisoinnin” kaltaisia uusia käsitteitä. Nykyään KORP-tietokantaa käytetään yleisesti kielitutkimuksessa. Krister Linden, HY:n kieliteknologian tutkimusjohtaja ja Kielipankin johtaja tuki alusta asti hankettamme.

Aineistoa jaettaessa oleellista oli myös pohtia juridisia ja teknisiä kysymyksiä. Aivan ratkaisevaa oli se, että mukaan tuli Salla-Maaria Laaksosen ja Marjoriikka Ylisiuruan tapaisia nuoria aktiivisia tutkijoita. He olivat myös perustamassa informaatioteknologian ja yhteiskuntatieteellisen tutkimuksen keskittyvää Rajapinta yhdistystä vuonna 2017.

Tutkimushankkeidemme johtoryhmiin ja yhteistyöhön saimme mukaan monia kauppallisia toimijoita. Samalla aineistomme laajeni. Esimerkiksi Futusomen verkkokeskusteluaineistot olivat monin verroin suurempia kuin Suomi 24. Futusome käyttöliittymä oli riittävän yksinkertainen hyvin laajaan käyttöön. Itsekin käytin sitä. Tässä vaiheessa mukaan tuli tutkijoita yhteiskunta- ja taloustieteiden eri suunnista. Markkinoinnin tutkija Essi Pöyry ja ravitsemussosiologit Pia Jallinoja ja Mikko Jauho tekivät työtä Kuluttajatutkimuskeskuksessa. Tutkimuskohteiksi valikoituivat muun muassa kuluttajasentimentit, televisio-ohjelmien vaikutus ruokatottumuksiin (karppaaminen), kansalliset stereotyyppit sekä kansalaisten energiankäyttökokemukset.

Isojen aineistojen osaaminen kehittyi, kun tutkijat oppivat käyttämään uusia aihehallinnuksen ('topic model') kaltaisia metodeja. Itse olin mukana kokeilussa, jossa selvitimme ilojen ja surujen vuosi-, viikko- ja päivärytmiä (Lagus, Pantzar, Ruckenstein 2018). Tulokset olivat odotettuja. Yöaikaan on enemmän synkkyyttä ja kesälomien aikaan viesteissä painottuvat positiiviset mielialat.

Pohdin, eikö Suomi24-aineistosta saisi irti jotain tähdellisempää. Tärkeää olisi kyetä liittämään massiiviset keskusteluaineistot erilaisiin konkreettisiin tapahtumiin. Niinpä tutkimme esimerkiksi sosiaalisen median valtionvelkaa koskevia keskusteluja (Lillqvist, Kavonius, Pantzar 2020). Oli hieman paradoksaalista, että samaan aikaan, kun kansalaiskeskustelu tarjosi hyvin yksiselitteisen ja triviaalin uhkakuvan velkaantumisesta, virallinen tilastodata näytti tarjoavan hyvin erilaisia ja jopa optimistia vaihtoehtoja tulkita Suomen valtionvelkaa.

## Läaketutka

Omasta mielestäni Citizen Mindscapes -hankkeen kehittämisessä ja tuotteistamisessa pisimmälle menivät Krista Lagus ja Minna Ruckenstein Läaketutka (Medicine Radar) -käyttöliittymän myötä. Suomi24-aineistoon perustuvan tutkan avulla voi selvittää eri lääkkeitä käytäviä kansalaiskeskusteluja (Lagus, Ruckenstein, Juvonen & Rajani 2018). Ruckensteinin (2019) masennuslääkkeitä (esim. Mirzapin) koskeva analyysi kertoi työkalun potentiaalista tunnistaa jaettuja kokemuksia. Monet kokemukset niin lääkekuurin aloittamisesta, jatkamisesta kuin lopettamisestakin ovat yhteisiä. Sivuvaiikutukset, kuten lihominen, kuvataan suorastaan lääkkeen ensisijaisiksi vaikutuksiksi, siis suorastaan 'elämänvaikutuksiksi'. Välillä jaetaan yrityksen ja erehdyksen kautta opittua. Omakohtaiset viestit yksittäisten masennuslääkkeiden käytöstä Suomi24-palstoilla paljastavat samankaltaisuuksia eri ihmisten ja tilanteiden välillä mutta toisaalta myös osoittavat kokemusten erilaisuuden.

Keskustelu masennuslääkkeistä muistuttaa niin sanottujen biohakkereiden oppivaa keskustelua ja tutkivaa elämänasennetta. Vastoin lääketieteellisen tutkimuksen vakiintuneita eettisiä normeja biohackerit tekevät kokeita omalla kehollaan, ja näitä kokemuksia jaetaan vertaisverkossa. On vaikea kuvitella, että tällainen kollektiivikokemus, jossa oma tilanne näyttäytyy osana isompaa ja yleisempää kokemusmaailmaa, voisi edes toteutua ilman verkkokeskusteluja. Kollektiivisen kokemusasiantuntijuuden myötä potilaat eivät enää olekaan passiivisia lääkemääräysten vastaanottajia vaan aktiivisia kokeilijoita, jotka oppivat muiden kokemuksista.

Lääketehteen perinteiset kliiniset tutkimustavat eivät yleensä pääse kiinni näihin kollektiivisiin kokemuksiin. Läaketutkan avulla voidaan täydentää ymmärrystä siitä, miten eri tavoilla masennuspotilaat voivat suhtautua omaan rooliinsa: uhrina, aktiivisena toimijana, toisten samaa tautia sairastavien lohduttajana, kokemusasiantuntijana tai passiivisena hoidon vastaanottajana.

## Monitieteisen yhteistyön kompastuskiviä

Lopulta mantereita oli paljon useampia kuin edellä kuvatut vanha ja uusi manner. Työtä tehtiin esimerkiksi Jyväskylän ja Tampereen yliopistossa. Suomen Akatemian hankkeessamme Turun tutkijat kehittivät hyvin itsenäisesti ja irrallaan meistä kieli-tekniologiaa. Suomenkielisen tekoälyn opetusaineistona toimi Suomi 24 -aineisto.

Citizen Mindscapesin alkuvaiheessa yksi vaikeus oli yhteisen kielen puute ja myös vieraan pelko. Tieteet elävät omissa tyhjiöissään ja protektionismi vallitsee. Tieteena-loilla on omanlaisensa menestyksen kriteerit. Esimerkiksi Timo Honkelan maailmassa ideat ja kokeilut olivat tärkeämpiä kuin julkaisut, jotka puolestaan taisivat olla enemmän tilastotieteilijöiden tavoitteena. Yksi ongelma laajoissa monitieteisissä hakkeissa on ”vientikauppiaiden” ja ”tuontiagenttien” vähäisyys. Miksi kukaan haluaisi olla generalisti tai kielenkääntäjä tai kauppamatkustaja? Tiedemaailma suosi spesialisoitumista. Vain juhlapuheissa kannustetaan löytöretkiä vieraiden tieteiden mantereille. Kuten oikeilla löytöretkillä riskit, mutta myös tuotot ovat mittakaavaltaan suuria.

Omat kokemukseni kymmenen vuoden ajalta ovat myönteisiä, vaikka julkaisujen määrässä tai laadussa en muille pärjännyt. Opin että Allerin kaltaisille yrityksille voi olla edullista tarjota akateemiselle yhteisölle ”hunajapurkkeja”, aineistoja ja metodeja. Akateemiset kunnianhimoiset hankkeet ovat mainosta yritysten omille markkinointiponnisteluille ja aineistoille.

Citizen Mindscape kertoi sen, kuinka määrällisen ja laadullisen tutkimuksen erotte-  
lu on ehkä menettämässä merkitystään. Kvantitatiivinen tutkimus tarvitsee rinnalleen tulkinnallista osaamista ja päinvastoin. Puhtaasti induktiivisen ja deduktiivisen väli-  
maastossa vahvistuu abduktiivinen iteraatioita korostava tutkimusote, jossa teoriat, metodit ja aineistot luovat yhdessä kuvaa maailmasta.

Riskinä näen, että valmiiden, helppokäyttöisten ja isojen tekstiaineistojen myötä yhä harvempi tutkija tunnistaa helppokäyttöisten työkalujen ja aineistojen loogisia perusteita. Vanhan mantereen hyve oli tunnistaa aineistojen tuottamisen lähtökohdat, puutteet ja rajoitteet. Epäilen että nyt tuotetaan ja julkaistaan ”kevyellä kädellä” artikkeleita, joissa metodit tai isot aineistot ovat kyseenalaistamattomasti itseisarvoisia fetissejä. Sama ilmiö koettiin aikoinaan sosiologiassa faktorianalyysin ja taloustieteessä regressioanalyysin yleistyessä. Onko esimerkiksi aihemallinnus (topic model) tällainen fetissi?

## Big datan myytti

Citizen Mindscapes -hanke voidaan asettaa osaksi myös yleisempää big data keskustelu, joka aktivoitui samoina vuosina. Kaupallisessa käytössä alkunsa saanut big data-käsite tuli voimakkaasti akateemiseen maailmaan 2010-luvulla (esim. Bates, Goodale 2016; Boyd, Crawford 2012; Fricke 2016; Gehl 2015; Knox 2018; Symons, Alvarado 2016). Omaa hankettamme käynnistäessämme näitä julkaisuja ja tätä kriittistä keskustelua ei vielä käyty tai ainakaan itse en sitä tuntenut. Hieman naiivi käsitykseni ison datan tuottamista mahdollisuuksista selittyy osittain tällä. Enemmän oli kuitenkin kysymys myös rahoituksen ja suurien lupauksien maailmasta: ”maailman pitkäikäisin, yhtenäisin, laajin ja kansallisesti kattavin verkkokeskusteluaineisto”. Näin saattoi olla, mutta varmuutta meillä ei voinut olla. Liioittelevaa ajattelutapaa voisi kutsua yleisemmin big data-myyttiksi.

Niin sanottu kriittinen datatutkimus korostaa, että data ei koskaan ole ”annettua” vaan se vaatii aina tekemistä ja tuotantoprosessia, jossa on runsaasti virhemahdollisuuksia ja ideologisia intressejä (Frické, 2015; Symons&Alvarado 2016). Data myös kulkee paikasta toiseen (”datajourney”; Bates jne. 2016) muuttaen muotoaan. Esimerkiksi säädatan liike ja muuntumiset vaativat monenlaisia toimijoita ja myös materiaalisia elementtejä ennen kuin data voi muuttua kaupalliseksi tuotteeksi esimerkiksi vakuutusyhtiöiden tarpeisiin.

Hieman jälkiviisaasti voisi sanoa, että monitieteisessä hankkeessamme olisi ehkä pi-

tänyt korostaa enemmän sitä, että kompleksisia ajassa muuttuvia ilmiöitä ei voi tutkia triviaaleilla malleilla, jotka perustuvat triviaalisti suuriin aineistoihin. Eksploraatiiviset moniaineisten aineistojen tulkinnat etenevät iteroiden aineistoja ja niihin liittyvien teoreettisia näkökulmia. Tähän meillä ei aluksi ollut aikaa.

Hyödyllisen näkökulman tällaiseen monitieteiseen ja -aineeksiseen työhön tarjoavat Halford ja Savage (2017) artikkelissaan "Speaking sociologically with big data: Symphonic social science and the future for big data research". Sinfoninen yhteiskuntatiede on kiinnostunut pitkistä aikasarjoista ja laaja-alaisten yhteiskunnallisten kysymysten pohdinnasta hyvin erilaisten aineistojen ja tiedetraditioiden valottamana. Big data -analytiikka on toistaiseksi perustunut liian vähän teoreettisiin lähtökohtiin. Datalähteen valinnan ja datan pitää olla teoreettisten perusteluiden varassa. Myönteisinä esimerkkeinä Halford ja Savage tarjoavat yksinäisyyttä monipuoliesti tutkineen Robert Putnamin (2000) ja varallisuuseroja selvittäneen Thomas Pikettyn (2014) tutkimuksia. Molemmat käyttävät hyvin heterogeenisiä aineistoja rohkeiden tulkintojensa tueksi. Tulkinnat nousevat kuitenkin teoreettisten pohdintojen virittämänä. Kummallakin visualisaatioilla on keskeinen rooli sekä tulkintoja tehtäessä että niitä esiteltäessä. (Putnam käyttää usein käänteistä U:n muoto ('inverted U-shaped curve'), kun taas Piketty kuvaa monia ilmiöitä U:n muotoisena.)

## Opetus

Kymmenen vuotta hankkeemme käynnistymisen jälkeen voi kysyä miten onnistuimme. Vaikuttavuusarvion sijaan haluan nostaa esiin periaatteita ja oppeja, joita olemme saaneet. Omasta mielestäni ylivoimaisesti tärkein saavutuksemme oli uuden oppimisen ja laajassa yhteistyössä, voisi melkein sanoa yhteishengessä, jolla etenimme. Edellä korostin ongelmia. Ensimmäisistä mieleeni on kuitenkin jäänyt lukuisten kohtaamisten hedelmällisyys ja myös suvaitsevaisuus toisenlaista työtä kohtaan.

Kaikki aineistot ovat tavalla tai toisella hyödyllisiä. Aineiston suuruus ei ole riittävä peruste uskoa tutkimuksen pätevyYTEEN. Ei ole lainkaan yhdentekevää, miten aineistot syntyvät ja elävät. Tämän opimme Citizen Mindscapes-hankkeen edetessä. Yhtälailla havahduimme siihen, että tekstit sinänsä eivät ole välttämättä kiinnostavia, jos niitä ei kontekstualisoida aikaan ja paikkaan esimerkiksi karppaamista käsitteleviin televisio-ohjelmiin tai valtionvelkaa kuvaaviin tilastoihin. Itse pidän selkeästi merkittävimpänä saavutuksemme uuden tutkijasukupolven ja suurten tekstiaineistojen osaamisen kehittymistä.

## Lähteet:

Anderson, C. (2008). The end of theory: The data deluge makes the scientific method obsolete. *Wired magazine*, 16(7), 16-07.

Anderson, K., Nafus, D., Rattenbury, T., & Aipperspach, R. (2009, August). Numbers have qualities too: Experiences with ethno-mining. In *Ethnographic praxis in industry conference proceedings* (Vol. 2009, No. 1, pp. 123-140). Oxford, UK: Blackwell Publishing Ltd.

Bates, J., Lin, Y. W., & Goodale, P. (2016). Data journeys: Capturing the socio-material constitution of data objects and flows. *Big Data & Society*, 3(2), 2053951716654502.

Boullier, D. (2016). Big Data challenges for the social sciences: from society and opinion to replications. *arXiv preprint arXiv:1607.05034*.

Boyd, D., & Crawford, K. (2012). Critical questions for big data: Provocations for a cultural, technological, and scholarly phenomenon. *Information, communication & society*, 15(5), 662-679

DiMaggio, P. (2015). Adapting computational text analysis to social science (and vice versa). *Big Data & Society*, 2(2), 2053951715602908.

Frické, M. (2015). Big data and its epistemology. *Journal of the association for information science and technology*, 66(4), 651-661.

Gehl, R. W. (2015). Sharing, knowledge management and big data: A partial genealogy of the data scientist. *European journal of cultural studies*, 18(4-5), 413-428

Halford, S., & Savage, M. (2017). Speaking sociologically with big data: Symphonic social science and the future for big data research. *Sociology*, 51(6), 1132-1148.

Knox, H. (2018). Baseless data?: Modelling, ethnography and the challenge of the anthropocene. In *Ethnography for a data-saturated world* (pp. 128-150). Manchester University Press.

Lagus, K., Pantzar, M., & Ruckenstein, M. (2015). Keskustelun tunneaallot-Suomi24-hanke. *Tieteessä tapahtuu*, 33(6).

Lagus, K., Pantzar, M., & Ruckenstein, M. (2018). Kansallisen tunnemaiseman rakentuminen: Pelon ja ilon rytmit verkkokeskusteluissa. *Kulutustutkimus. Nyt: Kulutustutkimuksen seuran julkaisu.*, 12(1-2), 62-83.

Lagus, K. H., M. Pantzar, M. S. Ruckenstein & M. J. Ylisiurua (2016). *Suomi24. Muodonantaa aineistolle*. Valtiotieteellisen tiedekunnan julkaisuja 10. Helsinki: Helsingin yliopisto.

Lagus, K. H., M. S. Ruckenstein, A. Juvonen & C. Rajani (2018). Medicine radar. A tool for exploring online health discussions. *Proceedings of the Digital Humanities in the Nordic Countries. 3rd Conference. Helsinki, Finland, March 7-9, 2018*, 460-468. <http://ceur-ws.org/Vol-2084/>

Lillqvist, E., Kavonius, I. K., & Pantzar, M. (2020). "Velkakello tikittää": Julkisyhteisöjen velka suomalaisessa mielikuvastossa ja tilastoissa 2000-2020. *Kansantaloudellinen aikakauskirja*, 116(4), 581-607.

Piketty, T. (2014). Capital in the twenty-first century. *Trans. Arthur Goldhammer/Belknap*.

Putnam, R. D. (2000). Bowling alone: The collapse and revival of American community. *Simon Schuster*.

Ruckenstein, M. (2019). Tracing medicinal agencies. Antidepressants and life-effects. *Social Science & Medicine* 235, 112368.

Schatzki, T. (2016). Practice theory as flat ontology. In *Practice theory and research* (pp. 44-58). Routledge.

Symons, J., & Alvarado, R. (2016). Can we trust Big Data? Applying philosophy of science to software. *Big Data & Society*, 3(2), 2053951716664747.



---

# Suomen Tilastoseuran hallitus vuonna 2023

BOARD MEMBERS OF THE FINNISH STATISTICAL SOCIETY IN 2023

## Hallitus 28.2.2023 jälkeen

Puheenjohtaja Chair	Pekka Pere	Doctor of Philosophy DPhil
Varapuheenjohtaja Vice Chair	Ari Jaakola	Filosofian maisteri MSc
Sihteeri Secretary	Roope Rihtamo	Valtiotieteiden maisteri MSocSci
Rahastonhoitaja Treasurer	Tuuli Kauppala	Filosofian maisteri MSc
Jäsen Member	Tommi Härkänen	Filosofian tohtori PhD
Jäsen Member	Reija Helenius	Yhteiskuntatieteiden maisteri MSocSci
Jäsen Member	Mika Gissler	Filosofian tohtori PhD
Jäsen Member	Arvi Tolvanen	Luonnontieteiden kandidaatti BSc
Jäsen Member	Jyrki Möttönen	Filosofian tohtori PhD
Varajäsen Deputy member	Elisa Falck	Valtiotieteiden kandidaatti BSocSci
Varajäsen Deputy member	Tapani Linnaluoto	Luonnontieteiden ylioppilas student (Nat sci)
Varajäsen Deputy member	Tommi Mäklin	Filosofian tohtori PhD
Klubimestari	Henrik Törmi	Filosofian kandidaatti BSc

---

# Suomen Tilastoseuran hallitus vuonna 2024

BOARD MEMBERS OF THE FINNISH STATISTICAL SOCIETY IN 2024

## Hallitus 29.2.2024 jälkeen

Puheenjohtaja Chair	Pekka Pere	Doctor of Philosophy DPhil
Varapuheenjohtaja Vice Chair	Ari Jaakola	Filosofian maisteri MSc
Sihteeri Secretary	Roope Rihtamo	Valtiotieteiden maisteri MSocSci
Rahastonhoitaja (19.6. asti) Treasurer	Henrik Törmi	Filosofian kandidaatti BSc BSc
Rahastonhoitaja (19.6. alkaen) Treasurer	Arvi Tolvanen	Luonnontieteiden kandidaatti  BSc
Jäsen Member	Mika Gissler	Filosofian tohtori PhD
Jäsen Member	Reija Helenius	Yhteiskuntatieteiden maisteri MSocSci
Jäsen Member	Tommi Härkänen	Filosofian tohtori PhD
Jäsen Member	Jyrki Möttönen	Filosofian tohtori PhD
Jäsen (19.6. alkaen) Member	Pekka Nieminen	Filosofian tohtori  PhD
Varajäsen Deputy member	Kari Djerf	Valtiotieteiden lisensiaatti LicSocSci
Varajäsen Deputy member	Elisa Falck	Valtiotieteiden kandidaatti BSocSci
Varajäsen Deputy member	Tapani Linnaluoto	Luonnontieteiden ylioppilas student (Nat sci)
Klubimestari Club steward	Arvi Tolvanen	Luonnontieteiden kandidaatti BSc

---

# Gunnar Modeen -minnesmedaljen

JUKKA HOFFRÉN  
TILASTOKESKUS

Statistiska Samfundet i Finland r.f. har i samband med de nordiska statistikdagarna traditionsenligt delat ut Gunnar Modeen -minnesmedaljen till särskilt meriterade statistiker. Praxisen har varit att dela ut medaljen till en representant för det land där statistikdagarna hålls.

Gunnar Modeen -minnesmedaljen beviljas för en betydande livsgärning inom statistikbranschen. Meningen är att den person som belönas är en framstående senior expert inom statistikbranschen, som uttryckligen utmärkt sig i det praktiska statistikerarbetet och som uppskattas av sina kolleger.

Styrelsen för Statistiska Samfundet väljer den person som får medaljen och medaljen överläts i samband med ett nordiskt statistikermöte. Enligt fondens stadga överläts medaljen till en betydande nordisk statistiker från det land som respektive år arrangerar mötet. Den första medaljen överläts vid det nordiska statistikermöte som hölls i Finland år 1989.

## Bakgrunden till och kriterier för GM-minnesmedaljen

Efter Gunnar Modeens bortgång år 1988 grundades en medaljfond till hans minne. Medaljen utarbetades på basis av den medaljong som Gunnar Modeens familj gett konstnären Matti Haupt i uppdrag att utforma till Modeens 70-årsdag år 1965. Mottagaren av medaljen väljs av styrelsen för Statistiska Samfundet i Finland och medaljen överläts i samband med ett nordiskt statistikermöte. Enligt fondens stadga överläts medaljen till en betydande nordisk statistiker från det land som respektive år arrangerar mötet. Den första medaljen överläts vid Nordiska Statistikermetet i Finland år 1989. Priset utdelas vart tredje år till en meriterad statistiker från det land där Nordiska Statistikermetet anordnas.

Allmänna kriterier för Gunnar Modeen -minnesmedaljen:

- priset beviljas för en betydande livsgärning inom statistikbranschen.

Den person som tilldelas medaljen:

- är en expert inom statistikbranschen, som uttryckligen utmärkt sig i det praktiska statistikerarbetet

- 
- är en nordisk, framstående senior expert som uppskattas av sina kolleger,
  - har akademisk examen (magister, licentiat eller doktor) och
  - är villig att ta emot GM-medaljen

## Mottagare av GM-minnesmedaljen

Den första medaljen tilldelades Mauno Koivisto, Finlands dåvarande president, som en särskild hedersbetygelse. År 1989 var han beskyddare av Nordiska Statistiker mötet i Finland som firade 100-årsjubileum för nordisk statistik. Ytterligare en medalj delades ut på mötet och mottagare var professor Eino H. Laurila. Övriga mottagare av medaljen:

- År 1992 tilldelades medaljen inte.
- År 1995 direktör Poul Jensen, Danmarks Statistik.
- År 1998 professor Sven Nordbotten, Universitetet i Bergen.
- År 2001 professor Emeritus Gunnar Kulldorf, Umeå universitet.
- År 2004 direktör Asta Manninen, Helsingfors stads faktacentral.
- År 2007 generaldirektör Hallgrímur Snorrason, Hagstofa, Island.
- År 2010 direktör Lars Thygesen, Danmarks Statistik.
- År 2013 Liv Hobbestad Simpson, pensionerad från Statistisk sentralbyrå (SSB) som Head of National accounts och past chair of IARIW
- År 2016 Eva Elvers, PhD, pensionerad från Design and Plan & Build and Test som Process owner
- År 2019 professor Risto Lehtonen, Helsingfors universitet
- År 2022 tilldelades medaljen inte.

---

# Scandinavian Journal of Statistics

Recognised as a leading journal in its field, the *Scandinavian Journal of Statistics* is an international publication devoted to reporting significant and innovative original contributions to statistical methodology — both theory and applications. The journal specializes in statistical modelling, showing particular appreciation of the underlying substantive research problems. *Scandinavian Journal of Statistics* is published on behalf of the Danish Society for Theoretical Statistics, the Finnish Statistical Society, the Norwegian Statistical Society, and the Swedish Statistical Society. The journal is currently edited by professors Peter Dalgaard and Niels Richard Hansen. The national editor for Finland is Jukka Corander (University of Helsinki, Finland), and the other national editors are Jacob von Bornemann Hjelmberg (University of Southern Denmark, Denmark), Geir Olve Storvik (University of Oslo, Norway), and Jimmy Olsson (KTH Royal Institute of Technology, Sweden). The chairman of the board is Thomas Scheike (University of Copenhagen, Denmark) and the board members are Juha Karvanen (University of Jyväskylä, Finland), Hans Karlson (University of Bergen, Norway), and Sara Sjöstedt de Luna (Umeå University, Sweden).

*Scandinavian Journal of Statistics* is published quarterly in March, June, September and December by Wiley-Blackwell Publishers, 108, Cowley Road, Oxford OX4, 1JF, UK or 238 Main Street, Cambridge, MA 02142, USA.

Members of the Finnish Statistical Society are entitled to discount prices when ordering the *Scandinavian Journal of Statistics*. For further information, please see the webpage at <http://www.wiley.com/bw/subs.asp?ref=0303-6898&site=1>

**ISI Journal Citation Reports® Ranking:** 2022: 97/125 (Statistics & Probability).

**Impact Factor:** 1.040 (2021).

**Online ISSN:** 1467-9469.

---

# Myönnettyt palkinnot

## Leo Törnqvist –palkinnot

- 1978 Rene Tigerstedt, Helsingin yliopisto. En modell för valbeteende i trafiken.
- 1979 Pirkko Kirjavainen, Turun kauppakorkeakoulu. Mallin rakentaminen ja ennusteen laatiminen Suomen sähkön kulutukselle kahta aikasarja-analyysimenetelmää käyttäen.
- 1980 Esa Läärä, Helsingin yliopisto. Ikä-, aika- ja kohorttitekijöiden vaikutukset Suomen miesten keuhkosityöpäsairastavuudessa vuosina 1953–76.
- 1981 Arvi Suvanto, Tampereen yliopisto. Kausivaihtelu aikasarjamalleissa.
- 1982 Maija Salo, Helsingin yliopisto. Yritys prioritetiedon käytöstä alkoholijuomien kulutusta selittävän kysyntämallin tukena. Jamel Boucelham, Jyväskylän yliopisto: Tunnustuspalkinto.
- 1983 Vesa Vihriälä, Helsingin yliopisto. Aikasarjojen välisen riippuvuuden mittausta ja testaus: sovellus suomalaisiin rahatalouden sarjoihin. Pirkko Welin, Tampereen yliopisto: Tunnustuspalkinto.
- 1984 Jari Palsio, Turun kauppakorkeakoulu. Skenaarioiden rakentaminen ristivaikutusanalyysimallia käyttäen.
- 1985 Kenneth Nordström, Helsingin yliopisto. Gauss-Markov-mallien erikoisongelmista.
- 1986 Tapio Nummi, Tampereen yliopisto. APL-pohjainen ohjelmisto GMANOVA-mallille.
- 1987 Ari Veijanen, Helsingin yliopisto. Pickardin kentän soveltamisesta kuva-analyysissä. Kari Nissinen, Jyväskylän yliopisto: Tunnustuspalkinto.
- 1988 Jaason Haapakoski, Helsingin yliopisto. Binomijakautuneiden muuttujien muutospisteongelma.
- 1989 Pasi Korhonen, Helsingin yliopisto. Kemometrian tilastollisista menetelmistä.
- 1990 Päivi Partanen, Jyväskylän yliopisto. Suljetun populaation koon estimointi merkintä-takaisinpyynti-menetelmällä: log-lineaarinen lähestymistapa. Markku Nurhonen, Tampereen yliopisto: Tunnustuspalkinto.
- 1991 Elina Järvinen, Helsingin yliopisto. Rajoitettujen, stokastisten ja konveksien estimaattoreiden käytöstä polynomisen viipymämallin parametrien estimoinnissa simulointikokeiden valossa.
- 1992 Jouni Kuha, Helsingin yliopisto. Binääristen regressiomallien selittäjien mittausvirheet ja parametriestimaattien mittausvirhekorjaukset. Juha Heikkinen, Jyväskylän yliopisto: Tunnustuspalkinto.
- 1993 Palkintoa ei jaettu (yhtään ehdotusta ei saatu).

- 
- 1994 Ilkka Taskinen, Jyväskylän yliopisto. Äärelliset Markovin ketjut ja annelointi.
- 1995 Mika Rautakorpi, Teknillinen korkeakoulu. Application of Markov chain techniques in certification of software. Tuija Jäppilä, Jyväskylän yliopisto: Tunnustus-palkinto.
- 1996 Veli-Matti Suppola, Jyväskylän yliopisto. Robustit menetelmät. Jakaumien vinouden vaikutuksesta korrelaatiomatriisin estimointiin.
- 1997 Albert Höglund, Teknillinen korkeakoulu. An Anomaly Detection System for Computer Networks.
- 1998 Samuli Visuri, Oulun yliopisto. Robustista kovarianssimatriisin estimoinnista ja sen sovelluksista signaalinkäsittelyssä.
- 1999 Jani Raitanen, Tampereen yliopisto. Jalkapallo-ottelun lopputuloksen tilastollinen mallintaminen.
- 2000 Reijo Sund, Helsingin yliopisto. Tilastollisia menetelmiä dynaamisten potilaspopulaatioiden mallintamiseen. Tapahtumahistoria-analyysia hoitoilmoitusrekisterin skitsofreenikoille.
- 2001 Samu Mäntyniemi, Oulun yliopisto. A Hierarchical Bayes Model for Assessing Salmon (*Salmo salar* L.) Parr and Smolt Populations.
- 2002 Ilmari Juutilainen, Oulun yliopisto. Teräslevyjen lujuuden ennustaminen regressio- ja neuroverkkomalleilla.
- 2003 Leena Kalliovirta, Helsingin yliopisto. Mar-malli.
- 2004 Mikko Myrskylä, Jyväskylän yliopisto. Estimation of Class Frequencies with Micro Level Auxiliary Information.
- 2005 Antti Liski, Tampereen yliopisto. Lonkkamurtumapotilaiden hoitokustannusten vertailu vastaavuuspistemäärään perustuvalla menetelmällä.
- 2006 Karri Seppä, Oulun yliopisto. Suomalaisten paksusuolisyöpäpotilaiden ennusteen analyysi suhteellisen elossapysymisen ja syykohtaisen kuolleisuuden malleilla käyttämällä suurimman uskottavuuden ja Bayesin menetelmiä.
- 2006 Jukka Siren, Helsingin yliopisto. Populaatioiden geneettisen rakenteen spatiaalinen mallintaminen.
- 2007 Outi Ahti-Miettinen, Helsingin yliopisto. Kaksivaiheisen potenssiikiintiöinnin käyttö otoksen tehostamisessa - Esimerkkinä otoksen suunnittelu työvoimakustanusindeksin tietojen keruulle.
- 2008 Paul Catani, Svenska handelshögskolan. Enhetsrottest och initialvärdet Tillämpning på arbetslösheten i Finland
- 2009 Elina Ahola, Jyväskylän yliopisto. Eksponenttisen perheen tila-avaruusmallien sovellus alkoholikuolleisuusaineistoon Matias Leppisaari, Aalto yliopiston teknillinen korkeakoulu: Tunnustus-palkinto.
- 2010 Sanna Peltomäki, Tampereen yliopisto. Estimation of Below Threshold Intra-EU Trade.
- 2011–2012 Tytti Pasanen, Tampereen yliopisto. Two-Level Structural Equation Modeling with Non-Normal Observed Variables for Assessing Poverty in Laos.
- 2013–2014 Joni Virta, Turun yliopisto. Some tools for linear dimension reduction.
- 2015-2016 Niko Lietzén, Aalto-yliopisto. New Approach to Complex Valued ICA: From FOBI to AMUSE
- 2015-2016 Santtu Tikka, Jyväskylän yliopisto. Kausaalivaikutusten identifiointi algoritmisesti.
- 2017-2018 Savi Virolainen, Helsingin yliopisto. GMAR- ja StMAR-mallin yleistäminen G-StMAR-malliksi.

---

2021-2022 Topi Halme, Quickest Detection under False Discovery Rate and Communication Constraints.

2023 Antti Yläjärvi, Transformer -neuroverkon robustisuuden parantaminen Gaussisen prosessin ja neuroverkon yhdistävillä menetelmillä.

## Väitöskirjapalkinnot

2009-2012 Jukka Sirén, Helsingin yliopisto. Statistical models for inferring the structure and history of populations from genetic data.

2013-2016 Johan Pensar, Åbo Akademi. Structure Learning of Context-Specific Graphical Models.

2017-2020 Anna-Kaisa Ylätälo, Jyväskylän yliopisto. Statistical inference for eye movement sequences using spatial and spatiotemporal point processes.

2017-2020 Santtu Tikka, Jyväskylän yliopisto. Improving identification algorithms in causal inference.



---

# Suomen Tilastoseuran julkaisuja

PUBLIKATIONER UTGIVNA AV STATISTISKA SAMMANFUNDET

PUBLICATIONS ISSUED BY THE FINNISH STATISTICAL SOCIETY

1. *Monikielinen väestötieteen sanakirja*, suomenkielinen laitos, Helsinki 1962.  
*Multilingual Demographic Dictionary*, Finnish section, Helsinki 1962.
2. *Suomen Tilastoseura – Statistiska Sammanfundet i Finland 1920-1970*, Porvoo - Borgå 1970.
3. *Pohjoismainen tilastosanasto*, toinen tarkistettu laitos.  
*Nordisk statistik nomenklatur*, andra reviderade upplagan.  
*Nordic statistical nomenclature*, 2nd revised edition. Jyväskylä 1975
4. *Aikasarja-analyysin menetelmiä*, Helsinki 1977.
5. Pekka Tavaila: *Leo Törnqvist Posti- ja lennätinhallituksen liiketaloudellisen tutkimuslaitoksen esimiehenä 1949–1977*, Helsinki 1982.
6. Vesa Kuusela ja Leif Nordberg (toim.): *Otanta teoriassa ja käytännössä*. Helsinki 1986.
7. *Suomen Tilastoseura 70 vuotta. Statistiska Sammanfundet i Finland 70 år.*  
*The Finnish Statistical Society 70 years*. Helsinki 1991.
8.
  - Juha Alho, Elja Arjas, Esa Läärä ja Pekka Pere: *Tilastotieteen sanasto*. Suomen Tilastoseuran julkaisuja no. 8. Suomen Tilastoseura. 1. laitos, Helsinki 2021.
  - Juha Alho, Elja Arjas, Esa Läärä ja Pekka Pere: *Tilastotieteen sanasto*. Suomen Tilastoseuran julkaisuja no. 8. Suomen Tilastoseura. 2. laitos, Helsinki 2023.
  - Juha Alho, Elja Arjas, Juha Karvanen, Lasse Leskelä, Esa Läärä ja Pekka Pere: *Tilastotieteen sanasto*. Suomen Tilastoseuran julkaisuja no. 8. Suomen Tilastoseura. Verkossa <https://sanasto.tilastoseura.fi/>.

---

# Tilastotieteellisiä tutkimuksia

STATISTISKA UNDERSÖKNINGAR

STATISTICAL RESEARCH REPORTS

**ISSN 0356-3499**

1. Pentti Manninen: Puolueiden kannatusosuuksien estimoinnin tarkkuus Demingin vyöhykepoiminnassa. (The Accuracy of Party Support Estimation in Deming Zone Selection. In Finnish with English Summary.) Helsinki 1976.
2. Timo Hakulinen: On Competing Risks of Death. Helsinki 1977.
3. Lars-Erik Öller: Time Series Analysis of Finnish Foreign Trade. Helsinki 1978.
4. Pekka Laippala: The Empirical Bayes Two-Action Rules with Floating Optimal Sample Size and Exponential Conditional Distributions. Helsinki 1980.
5. Markku Nurminen: Some Developments in Quantitative Methods of Epidemiology. Helsinki 1982.
6. Pentti Saikkonen: Comparing Asymptotic Properties of Some Tests Used in the Specification of Time Series Models. Helsinki 1985.
7. Lauri Tarkkonen: On Reliability of Composite Scales. Helsinki 1987.
8. Juni Palmgren: Models for Categorical Data with Errors of Observation. Helsinki 1987.
9. Ari Veijanen: On Estimation of Parameters of Partially Observed Random Fields and Mixing Processes. Helsinki 1989.
10. Ritva Luukkonen: On Linearity Testing and Model Estimation in Non-Linear Time Series Analysis. Helsinki 1990.
11. Hely Salomaa: Factor Analysis of Dichotomous Data. Helsinki 1990.
12. Kenneth Nordström: Contributions to the Comparison of Linear Models and to the Löwner-Ordering Antitonicity of Generalized Inverses. Helsinki 1990.
13. Seppo Laaksonen: Handling Household Survey Nonresponse Data. Helsinki 1992.
14. Mervi Eerola: On Predictive Causality in the Statistical Analysis of a Series of Events. Helsinki 1993.
15. Mikael Linden: Studies in Integrated and Co-Integrated Economic Time Series. Helsinki 1995.
16. Tadeusz Dyba: Precision of Cancer Incidence Predictions Based on Poisson Distributed Observations. Helsinki 2000.
17. Kimmo Vehkalahti: Reliability of Measurement Scales. Helsinki 2000.
18. Sirpa Heinävaara: Modelling survival of patients with multiple cancers. Helsinki 2003.

---

# Suomen Tilastoseuran vuosikirja

ÅRSBOK FÖR STATISTISKA SAMMANFUNDET I FINLAND

THE YEARBOOK OF THE FINNISH STATISTICAL SOCIETY

**ISBN 0355-5941**

1975 Helsinki 1976	1997 Helsinki 1998
1976 Helsinki 1977	1998 Helsinki 1999
1977 Helsinki 1978	1999–2000 Helsinki 2000
1978 Helsinki 1979	2001 Helsinki 2002
1979 Helsinki 1980	2002 Helsinki 2003
1980 Helsinki 1981	2003 Helsinki 2004
1981 Helsinki 1982	2004 Helsinki 2005
1982 Helsinki 1983	2005 Helsinki 2006
1983 Helsinki 1984	2006 Helsinki 2007
1984 Helsinki 1985	2007 Helsinki 2008
1985 Helsinki 1986	2008 Helsinki 2009
1986 Helsinki 1987	2009 Helsinki 2010
1987 Helsinki 1988	2010 Helsinki 2011
1988–1989 Helsinki 1990	2011–2012 Helsinki 2012
1990 Helsinki 1991	2013–2014 Helsinki 2014
1991 Helsinki 1992	2015–2016 Helsinki 2017
1992 Helsinki 1993	2017–2018 Helsinki 2018
1993 Helsinki 1994	2019–2022 Helsinki 2023
1994 Helsinki 1995	2023 Helsinki 2024
1995 Helsinki 1996	2024 Helsinki 2025
1996 Helsinki 1997	

Tilastoseuran julkaisuja voi tiedustella sihteeriltä sähköpostitse osoitteesta [suomentilastoseura@gmail.com](mailto:suomentilastoseura@gmail.com). Joidenkin julkaisujen painokset ovat tosin jo loppuneet.

---

# Muita julkaisuja

ANDRA PUBLIKATIONER

OTHER PUBLICATIONS

*Suomen Tilastoseura 1920–1945, Helsinki 1946*

*Statistiska Sammanfundet i Finland 1920–1945, Helsingfors 1946.*

*Pohjoismainen tilastosanasto – Nordisk statistisk nomenklatur, Kööpenhamina 1954.*

*13:e Nordiska statistikermötet i Helsingfors 14–16 juni 1973, Jyväskylä 1974*

*The 13th Joint Meeting of the Nordic Statistical Societies in Helsinki June 1973, Jyväskylä 1974.*

*Det 18:e nordiska statistikmötet i Esbo, Hundraårsjubileum, Helsingfors 1990.*

*The Joint Conference of the Nordic Statisticians in Espoo, Finland 1989, Helsinki 1990.*



ISSN 0355 – 5941 (painettu)  
ISSN 2953 – 9307 (verkossa)