



**TURUN  
YLIOPISTO**  
Kauppakorkeakoulu

# **Kausaaliset viitekehykset ja kausaalipäättely ekonometriassa**

Taloustieteen  
pro gradu -tutkielma

Laatija:  
Kristian Martiskainen

Ohjaaja:  
Professori Mika Kortelainen

28.2.2025  
Turku

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -järjestelmällä.

Pro gradu -tutkielma

**Oppiaine:** Taloustiede

**Tekijä:** Kristian Martiskainen

**Otsikko:** Kausaaliset viitekehukset ja kausaalipäätely ekonometriassa

**Ohjaaja:** Mika Kortelainen

**Sivumäärä:** 58

**Päivämäärä:** 28.2.2025

Kausaalipäätely on keskeinen osa vaikuttavuusarvioinneissa toteutettavaa kausaalista analyysia. Kausaalipäätely nojaa aina kuitenkin taustalla vallitsevaan teoreettiseen kausaaliseen viitekehukseen. Erilaiset kausaaliset viitekehukset vastaavat kausaalisiin kysymyksiin yleensä eri tavoin.

Tässä pro gradu -tutkielmassa tarkastellaan ekonometrian kontekstissa hyödynnettyjä kausaalisia viitekehkyksiä sekä niiden mahdollistamaa kausaalipäätelyä. Tutkielmassa esitellään kolme hyvin erilaista kausaalista viitekehystä: Trygve Haavelmon (1944), James Heckmanin ja Rodrigo Pinton (2015) rakennemallien kausaalinen viitekehys, Donald Rubinin kausaalinen viitekehys (1974, 1983, 2015) sekä Judea Pearl (2000/2009) DAG -mallien kausaalinen viitekehys. Tutkielmassa on tavoitteena esitellä sekä vertailla näiden kausaalisten viitekehysten käsitteellisiä perustuksia sekä niiden mahdollistamaa kausaalipäätelyä. Tutkielma on luonteeltaan teoreettinen kirjallisuuskatsaus.

Haavelmon, Heckmanin ja Pinton rakennemallien kausaalisesta viitekehuksesta, Rubinin kausaalisesta viitekehuksesta ja DAG -mallien kausaalisesta viitekehuksesta sekä viitekehysten mahdollistamasta kausaalipäätelystä havaitaan monia yhtymäkohtia mutta myös merkittäviä eroavaisuuksia. Merkittävimmät eroavaisuudet viitekehysten välillä koskevat kausaalisten mekanismien sekä kausaalisten parametrien asemaa viitekehyksissä. Merkittävin yhtymäkohta viitekehysten välillä koskee kausaalipäätelyä; kaikissa viitekehyksissä kausaalipäätely nojaa jonkinlaisen hypoteettisen skenaarion tai kontrafaktuaalin olemassaoloon.

**Avainsanat:** Kausaalinen viitekehys, kausaalipäätely, potentiaaliset lopputulemat, rakenteellinen ekonometria, DAG

# SISÄLLYS

1	Johdanto	6
2	Historiallinen viitekehys	9
3	Rakennemallit sekä Haavelmon, Heckmanin ja Pinton kausaalinen viitekehys	14
	3.1 Rakennemallit	14
	3.2 Haavelmon, Heckmanin ja Pinton kausaalinen viitekehys	17
	3.3 Tinbergen ja kausaalisten rakennemallien muodostaminen	21
4	Rubinin kausaalinen viitekehys	24
	4.1 <i>Potential outcomes</i> -malli	25
	4.2 SUTVA ja jakomekanismi	26
	4.3 Kausaalipäätely satunnaistetuissa kontrollikokeissa	28
	4.4 Kausaalipäätely havaintotutkimuksissa	32
5	Pearlen DAG -viitekehys	36
	5.1 Bayesilaiset verkot	36
	5.2 Kausaaliset bayesilaiset verkot ja <i>Do</i> -laskenta	40
	5.3 Kausaalipäätely DAG -malleissa	43
6	Pohdinta	46
	6.1 Kausaalisista mekanismeista	47
	6.2 Kausaalisista vaikutuksista	49
	6.3 Metafyysiset ja epistemologiset perustukset	52
	Lopuksi	53
	Lähteet	55

## KUVIOT

Kuvio 1. a) Graafi, jossa suunnattuja sekä kaksisuuntaisia linkkejä, b) Suunnattu asyklinen graafi (DAG) (Mukaillen Pearl 2000/2009, 13).

Kuvio 2. Graafi ilman ulkoista interventiota ja graafi ulkoisella interventiolla (Mukaillen Pearl 2000/2009, 15–23).

Kuvio 3. Graafi ja takaovikriteeri (Mukaillen Pearl 2000/2009, 80).

# 1 Johdanto

Tieteellinen, mutta myös jokapäiväinen arki ajattelu perustuvat pitkälti olettamukseen, että ilmiöille ja tapahtumille, joita todellisuudesta havaitsemme, on syynsä. Kun pelaamme biljardia, lyömme valkoisen numeroimattoman lyöntipallon aloituspakkaan ja aloituspakka hajoaa. Tällöin ajattelemme, että kiven lyöminen, sen kulkeminen kohti aloituspakkaa sekä kosketus aloituspakkaan hajotti aloituspakan. Tällöin puhumme syystä ja seurauksesta sekä niiden välillä olevasta suhteesta, eli kausaliteetista.

Filosofit ovat yli kahden tuhat vuoden ajan yrittäneet saada selkoa tästä niinkin yksinkertaiselta kuulostavasta entiteetistä kuin kausaliteetti. Kysymyksiä ovat herättäneet sen yleinen luonne sekä se, miten siitä on mahdollista saada tietoa, jos se oletetaan olemassa olevaksi. Tieteellisen maailmankuvan vahvistuttua pohdinnat kausaliteetista herättivät yhä enenevässä määrin kysymyksiä erityisesti siitä, miten tästä kausaalista suhteesta on mahdollista saada tietoa. Tällöin kausaliteetin metafyyminen olemus ja siihen liittyvät pohdiskelut väistyivät enenevässä määrin kausaalipäätelyyn liittyvien teorioiden ja mallien tieltä. (Pearl 2000/2009, epilogi; Hoover 2008, 1–11.)

Kausaliteettiin ja kausaalipäätelyyn liittyvät kysymykset levisivät 1900-luvulla myös taloustieteen ja ekonometrian piiriin. Tinbergenin (1951/2005) mukaan ekonometria voidaan määritellä tilastolliseksi havaitsevaksi tutkimukseksi, jolla on teoreettinen käsitteellinen perusta tai matemaattiseksi taloustieteeksi, joka toimii mitatun aineiston parissa. Hänen mukaansa taloustieteessä on tarvetta konkreettiselle mallien formuloinnille, mittaukselle sekä myös intensiiviselle tilastolliselle tutkimukselle. Ekonometria, jossa on vaikutteita sekä teoreettisesta taloustieteestä että tilastotieteestä, pyrkii realisoimaan tämän tarpeen. (Tinbergen 1951/2005, 3–11.)

Tässä pro gradu -tutkielmassa kausaliteettia ja kausaalipäätelyä tarkastellaan ekonometrian kontekstissa. Näin ollen tämän pro gradun aihepiiriin voidaan katsoa kuuluvan teoreettiseen ekonometriaan. Tavoitteena on esitellä sekä vertailla ekonometrian piirissä hyödynnettyjä teoreettisia kausaalisia viitekehystyksiä<sup>1</sup> sekä niihin kuuluvaa kausaalipäätelyä. Tutkielmassa käsitellään kolmea erilaista kausaalista viitekehystä: Ronald Fisherin (1925, 1926, 1935/1949) ja Jerzy Neymanin (1923/1990) inspiroimien RCT (Randomized Controlled Trials) -mallien pohjalta kehitettyä Donald Rubinin jalostamaa Rubinin kausaalista viitekehystä (1974, 1983, 2005, 2015),

---

<sup>1</sup> Viitekehyksellä tarkoitetaan tässä tutkielmassa niitä käsitteellisiä teoriakehikkoja, jotka voivat sisältää (kausaali)mallin, mutta joissakin tapauksissa myös samaistuvat (kausaali)malliin. Käsitettä kausaalinen viitekehys käytetään hyvin samaan tapaan kuin James Heckman ja Rodrigo Pinto (2024) artikkelissaan *Econometric causality: The central role of thought experiments*.

1900-luvun puolivälissä Trygve Haavelmon (1943/1995, 1944) kehittämää rakennemallien kausaalista viitekehystä sekä James Heckmanin ja Rodrigo Pinton (2015) uudempaa muotoilua siitä, sekä viime vuosituhaten vaihteessa kehittynyttä Judea Pearlén (1995a, 1995b, 2000/2009) DAG (Directed Acyclic Graphs) -mallien kausaalista viitekehystä.

Tutkimuskysymykset tutkielmassa ovat seuraavat: mihin Rubinin kausaalinen viitekehys, rakennemallien kausaalinen viitekehys sekä Pearlén DAG -viitekehys käsitteellisesti perustuvat? Mihin edellä mainittujen kausaalisten viitekehysten kausaalipäätely perustuu? Huomiota kiinnitetään myös viitekehysissä käytettyyn empiiriseen identifiointiin sekä sen mahdollisuuteen ja siihen liittyvään problematiikkaan. Lähestymistapa tässä pro gradu -tutkielmassa kausaalisiin viitekehysiin ja kausaalipäätelyyn on teoreettinen. Näin ollen tutkielmassa on mahdotonta välttyä matemaattisilta notaatioilta. Matemaattisia notaatioita käytetään kuitenkin harkiten ja vain tarpeen mukaan. Pro gradu -tutkielma on kuitenkin rakennettu teoreettisluonteiseksi kirjallisuuskatsaukseksi.

Näin ollen tutkielma rajautuu kolmeen kausaaliseen viitekehykseen sekä niihin kuuluvaan kausaalipäätelyyn. Muita kausaalisia malleja sekä viitekehyskiä, joita tässä tutkielmassa ei ole resurssien puolesta mahdollista käsitellä, ovat muun muassa Clive Grangerin (ks. esim. Granger 2001) prosessianalyttinen lähestymistapa sekä niin kutsuttu Grangerin kausaliteetti. Grangerin kausaliteettia on hyödynnetty esimerkiksi makroekonometriassa erilaisissa VAR-malleissa (Vector-Autoregression). Myös Christopher Simsillä (ks. esim. Sims 1980) oli prosessianalyysin perustuva lähestymistapa omassa SVAR-ohjelmassaan (Structural Vector-Autoregression). (Hoover 2008.) Lisäksi Herbert Simon (1957) kehitti omaa rakenteellisiin yhtälöihin perustuvaa kausaalimalliaan (Fennell 2005, 16–24).

Kausaalimalleja ja kausaalipäätelyä ekonometrian kontekstissa on käsitelty myös lukuisissa muissa tieteellisissä julkaisuissa. Kausaliteettia ja kausaalipäätelyä ovat tutkineet muun muassa Kevin D. Hoover (2008), joka on tarkastellut tutkimuksissaan, sekä mikroekonometriassa että makroekonometriassa hyödynnettyjä kausaalimalleja. Lisäksi yhdessä Selva Demiralpin (Demiralp & Hoover 2003) kanssa hän on soveltanut graafiteoreettisia kausaalimalleja myös makroekonometriaan. James Heckman ja Rodrigo Pinto (2015, 2024) sekä Guido Imbens (2022) ovat syvällisesti tarkastelleet Haavelmon, Rubinin sekä Pearlén viitekehysten perustuksia ekonometrian kontekstissa. Sen sijaan muun muassa Tobias Henschen (2022), Christopher Clarke (2022) sekä Damien James Fennell (2005) ovat lähestyneet ekonometrian kontekstissa hyödynnettyjä kausaalimalleja filosofisesti. Lisäksi Achim Ahrens, Christopher Aitken, Mark E.

Schaffer, Songsak Sriboonchitta, Woraphon Yamaka, Vladik Kreinovich (2021) ovat tarkastelleet koneoppimisen mahdollisuuksia kausaalipäätelyyn.

Tutkielman rakenne pyrkii noudattamaan kausaalisten viitekehysten kronologista järjestystä. Tutkielman toisessa luvussa tehdään katsaus kausaliteetin ja kausaalipäätelyn historialliseen viitekehykseen. Historiallinen viitekehys luo kontekstia ymmärtää eri kausaalisten viitekehysten sijoittumista historialliseen jatkumoonsa. Kolmannessa luvussa tarkastellaan rakennemalleja sekä Haavelmon, Heckmanin ja Pinton kausaalista viitekehystä. Neljännessä luvussa siirrytään Rubinin kausaalimalliin ja siihen kuuluvaan kausaalipäätelyyn. Viidennessä luvussa edetään bayesilaisten verkkojen kautta Pearlén DAG (Directed Acyclic Graphs) -viitekehykseen ja siihen kuuluvaan *Do*-laskentamalliin sekä kausaalipäätelyyn. Kuudennessa luvussa pohditaan sekä vertaillaan kausaalisten viitekehysten käsitteellisiä perustuksia sekä niiden mahdollistamaa kausaalipäätelyä.

Tieto kausaalisista vaikutuksista on tarpeellista kaikille toimijoille, jotka joutuvat tekemään yhtään minkäänlaisia päätöksiä. Se on olennaista niin suurille organisaatioille ja instituutiolle, kuten esimerkiksi valtiot ja yritykset, kuin myös yksittäisille ihmisillekin. Kausaalisten vaikutusten sekä niiden suuruuden arviointi voi olla haasteellista ilman tarkkaa tuntemusta kausaalisista mekanismeista. (Imbens 2022, 1–2.) Tietoa kausaalisista vaikutuksista onkin mahdollista saada erityisesti kausaalipäätelyn avulla ja eri kausaaliset viitekehukset tarjoavatkin erilaisia lähestymistapoja kausaalipäätelyyn. Näin ollen kausaalisten viitekehysten ja niihin kuuluvan kausaalipäätelyn tunteminen on olennaista kaikkialla eri päätöksenteon tasoilla sekä perusteltu osa empiirisen taloustieteilijän ymmärrystä. Tämän tutkielman tehtävänä onkin tarjota välineitä ymmärtää tätä teoreettisen ekonometrian osa-aluetta, jonka keskiössä ovat kausaaliset viitekehukset sekä niihin kuuluva kausaalipäätely.

## 2 Historiallinen viitekehys

Kevin D. Hooverin (2008) mukaan 1700-luvulla elänyt filosofi sekä varhainen taloustieteilijä David Hume sävytti merkittävästi myöhempää kausaliiteettia koskevaa ajattelua taloustieteessä. Hooverin mukaan Humella oli merkittävä vaikutus siihen, kuinka varovaisesti tieteiden piirissä puhutaan kausaalista analyysistä. Hume suhtautuikin epäilevästi mahdollisuuteen saada tietoa kausaalista suhteista. Humeen jälkeen syntyi eräänlainen jännite sen välille, mikä on kausaalisten suhteiden epistemologinen asema sekä toisaalta niiden rooli käytännöllisen politiikan toteuttamisessa. (Hoover 2008.)

Hooverin mukaan minkä tahansa kausaliiteettia koskevan analyysin on täytettävä kaksi ydinominaisuutta: syiden asymmetrisyyden ja syiden vaikuttavuuden. David Humella asymmetrisyys näkyy ajallisen peräkkäisyyden vaatimuksessa. Jos A aiheuttaa B:n, on A:n tapahduttava ennen B:tä. Jos A tapahtuu B:n jälkeen, ei A voi aiheuttaa B:tä. Vaikuttavuus näkyy taas Humeen vaatimuksessa tilallisesta vierekkäisyydestä ja vaatimuksessa yhteyden välttämättömyydestä. Nämä vaatimukset erottavat syysuhteet vahingollisista korrelaatioista ja syyt todella aiheuttavat vaikutuksen. (Hoover 2008, 2.)

Teoksessaan *An Enquiry Concerning Human Understanding* (1748/2001) Hume käsitteli sitä, mihin koko idea kausaalista suhteesta perustuu. Hän hylkäsi heti ensi alkuun kausaalisen suhteen idean perustumisen *a priori* tietoon. Sen sijaan idea kausaalista suhteesta perustuu hänen mukaansa pitkän ajan kokemukseen (tottumukseen) siitä, kuinka eri oliot esiintyvät alituisesti yhdessä. Tästä hän päätyy vakioisen konjunktion käsitteeseen (constant conjunction). (Hume 1748/2001.) Hume kuitenkin ymmärsi, ettei induktiivinen päättely voi koskaan tarjota tietoa välttämättömästä yhteydestä, jota kausaalisen suhteen osoittaminen vaatisi. Näin hän osoitti kausaalisen suhteen idean olevan varsin hataralla pohjalla. (Hoover 2008, 2.)

John Stuart Mill käsitteli kausaalipäätelyä sekä induktiivista päätelyä teoksessaan *System of Logic* (1843). Mill oli Humeen verrattuna vähemmän skeptinen suhteessa kausaalipäätelyyn, mutta skeptisempi sovellettaessa sitä taloustieteeseen. Millillä esiintyykin varhainen ajatus kausaalipäätelystä kontrolloidussa kokeessa: jos on olemassa kahdet eri olosuhteet, jotka vastaavat toisiaan kaikissa muissa suhteissa paitsi asiassa Q, ja toisessa olosuhteessa tapahtuu ilmiö W, niin Q oli syynä ilmiölle W. (Hoover 2008, 2–3.) Millin mukaan taloudellisten ilmiöiden taustalla toimii monien eri selittävien tekijöiden sekoitus, joka vaihtelee ympäristöittäin sekä ajassa. Taloudellisessa maailmassa on Millin mukaan niin vähän ajassa ja paikassa kestäviä säännöllisiä yhteyksiä, että ne

voisivat toimia perustana induktiiviselle päättelylle. Mill jatkoi, että vaikka näistä eri tekijöiden sekoituksista ja niiden säännöllisistä yhteyksistä olisi mahdollista saada tietoa, niin se ei kertoisi kuinka yksittäiset komponentit toimivat taloudessa toisistaan erillään. (Cartwright 2001, 279–280.) Millin mukaan taloustiede on aina alisteinen *ceteris paribus* ehdoille ja yleiset periaatteet voidaan tuntea ainoastaan *a priori*. (Hoover 2008, 3.)

Mill vaikuttikin moniin myöhempiin taloustieteilijöihin apriorismillaan. Esimerkiksi Ludwig von Misesin mukaan taloustiede ei voi olla empiirinen tiede ollenkaan. Kaikki taloustieteilijät eivät 1800-luvulla suhtautuneet kausaalipäättelyn mahdollisuuteen taloudellisesta aineistosta kuitenkaan yhtä epäillen kuin John Stuart Mill. (Mises 2007, 867–869; Hoover 2008, 3.) Esimerkiksi William Stanley Jevons pyrki osoittamaan teoksessaan *A Serious Fall in the Value of Gold* (1863), että inflaation vaihtelun syynä olivat 1800-luvun puolivälissä olleet kunnan tarjonnan vaihtelut. Menetelmänä hän hyödynsi Adam Smithin sekä myöhemmin myös John Stuart Millin kehittämää jäännös menetelmää. (Hoover & Dowell 2001.)

Tilastotieteen kehityksellä 1700- ja 1800-luvuilla oli huomattava vaikutus myös kausaalipäättelyn kehittymiseen. Todennäköisyyslaskennan teoria oli ottanut merkittäviä edistysaskeleita jo Jacob Bernoullin myötä 1600-luvulla ja Thomas Bayes sekä Pierre Simon Laplace kehittivät teoriaa eteenpäin 1700-luvulla sekä 1800-luvun alussa. Bernoulli yritti osoittaa jo 1600-luvulla, kuinka havaintojen määrän kasvu vähensi tilastollisen päättelyn epävarmuutta. Thomas Simpsonilla oli jo 1700-luvun puolivälissä idea suurten lukujen laista. Ajatus keskeisestä raja-arvolauseesta kehittyi erityisesti Pierre Simon de Laplacen ja Abraham de Moivren myötä. 1800-luvun alussa Adrien Marie Legendre sekä Carl Friedrich Gauss rakensivat mallin pienimmän neliösumman menetelmästä. (Stigler 1986.) Regressiomallin kehittyessä ymmärrettiin pian sen mahdollisuudet kausaalipäättelyn soveltamiseen. Toisin kuin symmetrisellä korrelaatiolla, regressiolla on eräänlainen suunta selittäjästä selitettävään. Ymmärrettiin, että regression suunnan täytyisi noudattaa kausaalista järjestystä. (Hoover 2008, 3.)

Vuosisadan vaihtuessa 1900-luvulle, kehittyneen tilastotieteen menetelmiä alettiin yhä enemmän hyödyntää kausaalipäättelyssä. Imbensin mukaan 1900-luvun alkupuolella kausaalipäättelyn alalle muodostui kaksi toisistaan eroavaa suuntausta: tilastotieteellinen suuntaus ja ekonometrinen suuntaus. Sanonta ”korrelaatio ei tarkoita kausaliteettia” hillitsi kuitenkin kausaliteettikäsitteen käyttöä satunnaistettujen kontrollikoeasetelmien, eli niin sanottujen RCT (Randomized Controlled Trials) -asetelmien ulkopuolella. Erityisesti tilastotieteen piirissä alettiin korostaa puhdasta sattumaa käsittelyn määrätymismekanismina. Näin RCT -asetelmat nousivat kausaalipäättelyn keskiöön.

Esimerkiksi Ronald Fisher käsitteli laajasti RCT-asetelmia teoksessaan *The Design of Experiments* (1935/1949) sekä esitteli asetelmille nollahypoteesitestin. Fisher esitteli teoksessaan, kuinka tilastollisia testistatistiikkoja voidaan hyödyntää hypoteesien testaamisessa käsittelystatuksen mukaan sekä kuinka p-arvoja lasketaan. Imbensin mukaan Fisher (1935/1949) käsitteli teoksessaan kausaalisten vaikutusten hypoteesitestejä, vaikka Fisher itse viittasi vain harvoin käsitteeseen kausaalinen. Imbensin mukaan Fisherin esittelemä malli hypoteesien testaamiselle RCT-olosuhteissa voi osoittaa kausaalisten vaikutusten olemassaolon, mutta se ei ole kuitenkaan riittävä vastaamaan kausaalisten vaikutusten suuruutta (magnitudia) koskevaan kysymykseen. (Imbens 2022.)

Fisherin ohella myös toinen tilastotieteilijä ja matemaatikko Jerzy Neyman (1923/1990) työskenteli satunnaistettujen kokeiden parissa. Hän näki tiukkojen nollahypoteesitestien olevan riittämättömiä ja esitteli luottamusvälit hypoteesien testaamisen tueksi. (Imbens 2022.) Jerzy Neyman esitteli myös perustan myöhemmälle Rubinin kausaalimallille, joka perustuu potentiaaliin lopputulemiin (potential outcomes). Neyman esitteli mallinsa aikanaan puolalaisessa *oczniki Nauk Rolniczych* lehdessä, mutta julkaisu on nykyään löydettävissä myös D. M. Dabrowskan ja T. P. Speedin (1923/1990) englanniksi kääntämänä. Neyman esitteli mallissaan, kuinka satunnaistettua kenttäkoeasetelmaa voidaan soveltaa potentiaaliin satojen tuottoihin eri kasvilajikkeiden vaikutuksesta. (Splawa-Neyman 1923/1990.)

Sen sijaan Imbensin erottama ekonometrinen suuntaus korosti talousteoreettista viitekehystä kausaalisten vaikutusten päättelyyn. Ekonometrisen suuntauksen mukaan, jonka varhaisiin edustajiin voi laskea kuuluvan ainakin Ragnar Frisch, Jan Tinbergen sekä Trygve Haavelmo, talousteoria muodostaa eräänlaisen lähtökohdan tutkimukselle. (Imbens 2022.) Ekonometrisen suuntauksen korostamisessa rakennemalleissa on ensin formuloitava rakenneyhtälöt, jonka jälkeen ratkaistaan mahdolliset tasapainot. Parametrien estimointi on rakenteellisessa ekonometriassa oma monimutkainen työvaiheensa. (Low & Meghir 2017.) James Heckmanin mukaan Trygve Haavelmo teki perustavanlaatuisen myötävaikutuksen kausaalisten mallien muotoilulle sekä identifioinnille. Heckmanin mukaan hän myös formalisoi eron korrelaatiolle sekä kausaaliiteetille, loi perustan kontrafaktuaaleihin perustuvalle politiikka-analyysille sekä erotti käsitteen *fixing* tilastotieteellisestä ehdollistamisen käsitteestä. (Heckman & Pinto 2015.)

Haavelmon kausaalisen viitekehysten perusidea on panosten variaation vaikutus tuotokseen hypoteettisessa mallissa. Heckmanin ja Pinton mukaan viitekehys perustuu näin ollen eräänlaiseen ajatuskokeeseen, jossa variaatio panoksiin tapahtuu ainoastaan hypoteettisessa mallissa riippumatta

siitä, tapahtuuko variaatiota itse datassa. Kausaalinen viitekehys onkin Heckmanin ja Pinton mukaan eräänlainen idea Frischin ajatuksesta, jonka mukaan kausaalisuus olisi vain mielessä tapahtuva todellisuuden abstraktio. (Heckman & Pinto 2015; Frisch 2010.) Modernit dynaamiset stokastiset rakennemallit ovat kehittyneet huomattavasti Haavelmon ajoista ja nykyaikaiset tietokoneet myös mahdollistavat tehokkaamman kontrafaktuaalien simuloinnin tutkittaessa eri politiikkapäätösten vaikutuksia sekä lyhyellä että pitkällä aikavälillä. (Ks. esim. Low & Meghir 2017.)

Imbensin mukaan ekonometrinen suuntaus alkoi kärsiä uskottavuuskriisistä rakenteellisten mallien monimutkaistuksessa 1900-luvun jälkipuolella. Samaan aikaan Donald Rubin (1974) kehitti omaa kausaalista viitekehystään, joka mahdollisti kausaalipäätelyn myös ei-kokeellisissa havaintotutkimusasetelmissä. Rubinin viitekehys perustui ajatukseen potentiaalisista lopputulemista (potential outcomes). Viitekehyksessä kausaalinen vaikutus on kahden eri potentiaalisen lopputuleman erotus samalle havaintoyksikölle. Rubinin viitekehyksessä kausaalipäätelyn keskeisimmäksi ongelmaksi muodostuu puuttuvan datan ongelma; samalta havaintoyksiköltä ei koskaan havaita molempia potentiaalisia lopputulemia. (Imbens 2022.)

Imbensin mukaan Rubinin sekä monien hänen kollegoidensa myötä kausaalipäätelyssä on tapahtunut eräänlainen uskottavuuden vallankumous. Sen myötä tutkimuksessa on korostunut yhä enemmän läpinäkyvyys kriittisten olettamuksien taustalla, ymmärrys datassa olevista rajoitteista sekä tavoite tehdä tutkimus saavutettavaksi laajemmalle tiedeyleisölle. Uusien ekonometristen menetelmien keskiössä on David Cardin Nobel-luennollaan käsittelemä *Design*-perustainen näkökulma. Uusien menetelmien myötä tilastotieteellinen ja ekonometrinen kausaalipäätelyn traditio ovat lähentyneet toisiaan. Uusissa menetelmissä korostuvat myös uudet käsitteet ja ideat, kuten esimerkiksi LATE (Local Average Treatment Effect) sekä moniarvoiset ja jatkuvat käsittelymuuttujat. (Imbens 2022; Imbens 2010.) *Design* -perustaisessa kausaalipäätelyssä keskeistä on erilaiset luonnolliset koeasetelmat ja kvasikokeelliset menetelmät, kuten ero-eroissa- (Differences-in-Differences), instrumenttimuuttuja- ja regressioepäjatkuvuusmenetelmät. Erityisesti 2010-luvulla on käyty paljon keskustelua *Design* -perustaisen kausaalipäätelyn asemasta ekonometriassa suhteessa satunnaistettuihin koeasetelmiin sekä rakenteelliseen ekonometriaan. (Ks. esim. Imbens 2010; Angrist & Pischke 2010; Heckman & Urzúa 2010; Deaton 2010.)

Vuosisadan loppua kohden ja uuden vuosituhannen alkaessa myös tietojenkäsittelytieteen piiristä alkoi syntyä uusia varteenotettavia ideoita kausaalimallien ja kausaalipäätelyn alalle. Vaikka graafimalleja oli jo aikaisemminkin kehitetty, nosti tietojenkäsittelytieteilijä Judea Pearl

kollegoineen ne kuitenkin kausaalimallien sekä kausaalipäättelyn keskiöön. Imbensin mukaan Pearlén ja hänen kollegojensa kehittämät DAG (Directed Acyclic Graphs) -mallit ovat keskeisiä erityisesti kausaalisen analyysin identifikaation tarkastelussa. Imbensin mukaan DAG-mallit voivat hyödyttää tutkijoita myös ekonometrian piirissä muotoilemalla kriittiset oletukset kausaalisista suhteista. Lisäksi DAG -viitekehukseen kuuluva *Do* -laskentamalli voi Imbensin mukaan vastata kausaaliin kysymyksiin uudella tavalla. (Imbens 2022.) Pearlén DAG -viitekehysten perustana ovat bayesilaisiin verkkoihin perustuva päättely, jotka tietyin ehdoin muodostavat myös kausaalisia bayesilaisia verkkoja. Toisin kuin Markovin verkkoihin perustuva symmetrisiä ja tilallisia relaatioita kuvaava suuntaamaton graafi, Pearlén suunnattua graafia voidaan soveltaa erityisesti kausaaliin ja temporaalisiin relaatioihin. Kausaalipäättelyn idea perustuu pitkälti hypoteettisten interventioiden toteuttamiseen graafimallin sisällä *Do* -laskennan sääntöjä noudattaen. (Pearl 2000/2009.)

### 3 Rakennemallit sekä Haavelmon, Heckmanin ja Pinton kausaalinen viitekehys

Ekonometrian luonne ajateltiin 1900-luvun puolivälissä tutkimukseksi, jossa talousteoria sekä numeerisen ja institutionaalisen datan analyysi yhdistetään (Hood & Koopmans 1953, xv). Peter C. Reissin ja Frank A. Wolakin (2007) mukaan, nykyään malleja, joissa yhdistellään talousteoriaa sekä tilastotieteellisiä malleja, kutsutaan rakenteellisen ekonometrian malleiksi (Reiss & Wolak 2007, 4281). Ekonometriaksi katsottu piiri on siis toisaalta laajentunut, mutta rakenteelliset ekonometrian mallit muodostavat kuitenkin vieläkin merkittävän osan ekonometrisesta tutkimuksesta.

Nykyään rakennemalleja hyödynnetään erityisen paljon esimerkiksi toimialan taloustieteessä, työn taloustieteessä sekä huutokauppojen tutkimuksessa (ks. esim. Low & Meghir 2017; Reiss & Wolak 2007, 4281). Rakenteellisilla ekonometrian malleilla on monia vahvuuksia suhteessa ei-rakenteelliseen analyysiin. Niiden avulla voidaan vastata joihinkin sellaisiin kysymyksiin, mihin ei-rakenteelliset mallit eivät kykene vastaamaan. Rakenteellisilla ekonometrian malleilla voidaan esimerkiksi simuloida sellaisia politiikkapäätöksiä, joita ei ole ennen nähty. Lisäksi näitä politiikkapäätöksiä voidaan simuloida aktuaalisiin, mutta myös muihin potentiaalisiin ympäristöihin. (Nevo & Whinston 2010; Heckman 2024.)

Tässä luvussa rakenteellisia ekonometrian malleja tarkastellaan suhteessa Haavelmon, Heckmanin ja Pinton kausaaliseen viitekehukseen. Vaikka rakennemalleille voidaan kehittää sekä soveltaa myös toisenlaisia kausaalisia viitekehysjä, on Trygve Haavelmon, James Heckmanin ja Rodrigo Pinton kausaalinen viitekehys mielekäs tapa tarkastella rakennemallien suhdetta kausaaliteettiin ja kausaalipäätelyyn. Tieteenfilosofisesti Haavelmon, Heckmanin ja Pinton kausaalinen viitekehys eroakin huomattavasti esimerkiksi tilastotieteen piirissä kehitetystä Rubinin viitekehuksesta. Tässä luvussa tehdään ensin yleinen katsaus rakennemalleihin, jonka jälkeen tarkastellaan Haavelmon, Heckmanin ja Pinton kehittämää kausaalista viitekehystä, viitekehysten oletuksia sekä siihen kuuluvaa kausaalipäätelyä. Lopuksi tarkastellaan Jan Tinbergenin ideaa siitä, kuinka kausaalisia rakennemalleja voidaan muodostaa.

#### 3.1 Rakennemallit

Rakenteellisissa ekonometrian malleissa käytetään yleensä käsitteitä endogeenisistä (havaittavista riippuvista) muuttujista sekä eksogeenisistä (havaittavista riippumattomista) muuttujista. Lisäksi

rakennemalleissa on yleensä myös havaitsemattomia muuttujia ja tuntemattomia parametreja. Näiden endogeenisten, eksogeenisten sekä muiden muuttujien määrittely perustuu lähtökohtaisesti talousteoriaan. Myös funktiomuoto, jolla endogeeniset, eksogeeniset ja havaitsemattomat muuttujat määritellään, perustuu talousteoriaan. Talousteoriassa ei kuitenkaan kerrota, kuinka rakennemallin tuntemattomat parametrit estimoidaan. Tämän takia määritellään myös empiirinen malli, johon tehdään tiettyjä lisäoletuksia. Lisäoletukset koskevat esimerkiksi muuttujien yhteisjakaumaa. Lopulta mallin tuntemattomat parametrit voidaan estimoida esimerkiksi log-uskottavuusfunktion tai momenttimenetelmän avulla. (Reiss & Wolak 2007, 4282–4285.)

Reissin ja Wolakin mukaan kausaaliset väittämät endogeenisten ja riippumattomien muuttujien suhteesta vaativat talousteoriaa taakseen. Talousteoria voi koostua esimerkiksi siitä kuinka taloudelliset ja institutionaaliset olosuhteet vaikuttavat endogeenisten ja riippumattomien muuttujien suhteisiin. Reiss ja Wolak antavat esimerkin huutokauppojen tutkimuksesta: Oletetaan, että tutkija havaitsee huutokauppa-aineistossaan voittavat tarjoukset suuresta määrästä huutokauppoja  $y = \{y_1, \dots, y_T\}'$ . Lisäksi tutkija havaitsee tarjoajien määrän jokaisesta huutokaupasta  $x = \{x_1, \dots, x_T\}'$ , joissa  $T$  viittaa huutokauppojen määrään. Tutkijaa kiinnostaa tarjoajien määrän suhde voittaviin tarjouksiin. Jos tutkija tekee regressioanalyysin, jossa hän selittää voittavia tarjouksia tarjoajien määrällä ja estimaatiksi muodostuu \$100, niin voidaanko väittää, että kausaalinen vaikutus yhdestä lisätarjoajasta tulevaan huutokauppaan on 100 dollaria? Reissin ja Wolakin arvion mukaan tällaiselle väitteelle ei riitä perusteita ja kausaalisen vaikutuksen tutkiminen vaatii tietoa institutionaalisista ja taloudellisista mekanismeista. (Reiss & Wolak 2007, 4282–4285.)

Rakennemallien historia ulottuu 1900-luvun alkupuolelle. Jan Tinbergenin työ ensimmäisten rakennemallien parissa, Trygve Haavelmon tuoma tilastotieteellinen vaikutus sekä Cowlesin komission<sup>2</sup> toteuttama tekninen viimeistely identifikaatiosta muodosti perustan rakenteelliselle ekonometrialle. (Hoover 2008, 3–4.) Mary S. Morganin mukaan nykyään identifikaatiolla viitataan rakenteellisen ekonometrian kontekstissa kysymykseen siitä, voidaanko oikeaksi oletetun mallin parametrit yksiselitteisesti määrittää, mutta 1900-luvun alkupuolella identifikaatiolla viitattiin hyvin vaihtelevasti eri asioihin. Silloin identifikaatiota ei oltu vielä kunnolla määritelty ja sillä viitattiinkin (mallin) vastaavuuteen taloudellisen aktiviteetin kanssa, aineistoon, jonka taloudellinen toimeliaisuus tuottaa, talousteoreettiseen malliin sekä estimoituihin suhteisiin. Usein ongelma koski

---

<sup>2</sup> Cowlesin komissio oli taloustieteen teorian, matematiikan ja tilastotieteen yhdistämiseen keskittynyt taloustieteellinen instituutti, joka perustettiin Colorado Springsissä vuonna 1932 Alfred Cowlesin toimesta (ks. esim. Christ 1994).

yhtäältä identifikaatiota tulkinnallisena ongelmana estimoidusta suhteesta talousteoriaan liittyen ja toisaalta identifikaatiota ongelmana paikallistaa suhde dataan. (Morgan 1990, 162–189.) Identifikaation käsitettä käytetään vielä nykyäänkin eri yhteyksissä eri tavoin. Soveltavassa ekonometrisessä tutkimuksessa ja erityisesti niin kutsuttujen luonnollisten koeasetelmien yhteydessä identifikaatiostrategialla kuvataan strategiaa, jolla tutkija hyödyntää dataa approksimoidakseen satunnaistettua koeasetelmaa (Angrist & Pischke 2009, 7). Tässä tutkielmassa nojataan kuitenkin lähinnä Morganin määritelmään identifikaatiosta, mutta käsiteltäessä kausaalisten vaikutusten identifioimista, käsitettä käytetään hieman vapaammin.

Identifikaation ohella, sekä siihen liittyen, simultaanisten yhtälöiden mallit ovat saaneet paljon huomiota osakseen 1900-luvulla. Erityisesti Cowlesin komissio keskittyi ratkaisemaan simultaanisiin yhtälöihin liittyviä ongelmia. (Hoover 2008, 3–4; Reiss & Wolak 2007, 4293.) Reissin ja Wolakin mukaan simultaanisten yhtälöiden avulla pyrittiin rakentamaan mallikehikko, jolla voitaisiin kuvata talousteoreettisesti keskeistä ilmiötä: taloudellista tasapainoa. Simultaanisten yhtälöiden malleihin kuului ominaisuus, että yhtälöjärjestelmän toisissa yhtälöissä vasemmalla olevat muuttujat saattoivat esiintyä toisissa yhtälöissä oikealla puolella. Simultaanisten yhtälöiden mallien myötä sellaisia mallikehikkoja, joissa riippuvaiset muuttujat kuvataan suoraan riippumattomien ja havaitsemattomien muuttujien funktiona, alettiin kutsuaan *reduoidun muodon malleiksi*. Reissin ja Wolakin mukaan käsitettä *reduoidun muodon malli* käytetään yleensä liian heppoisin perustein. Heidän mukaansa *reduoidun muodon mallilla* viitataan tosiasiaassa malliin, joka on johdettu rakenteellisesta ekonometrian mallista. (Reiss & Wolak 2007, 4293–4295.) Tarkastellaan Reissin ja Wolakin esimerkkiä reduoidun muodon mallin johtamisesta yksinkertaisesta rakenteellisesta kysyntä-tarjonta kehikosta:

$$q_t^s = \beta_{10} + \gamma_{12}p_t + \beta_{11}x_{1t} + \varepsilon_{1t}, \quad (1.)$$

$$p_t = \beta_{20} + \gamma_{22}q_t^d + \beta_{22}x_{2t} + \varepsilon_{2t} \quad (2.)$$

$$q_t^s = q_t^d \quad (3.)$$

jossa  $q_t^s$  viittaa määrään, jota yritykset ovat valmiita tuottamaan annetulla hinnalla ja ehdolla muut tarjontaan vaikuttavat tekijät ja  $q_t^d$  viittaa määrään, jota kuluttajat ovat valmiita ostamaan, annetulla hinnalla ja ehdolla muut kysyntään vaikuttavat tekijät. Yhtälöjärjestelmän voi esittää matriisimuodossa:

$$[q_t \quad p_t] \begin{bmatrix} 1 & -\gamma_{22} \\ -\gamma_{12} & 1 \end{bmatrix} - [1 \quad x_{1t} \quad x_{2t}] \begin{bmatrix} \beta_{10} & \beta_{20} \\ \beta_{11} & 0 \\ 0 & \beta_{22} \end{bmatrix} = [\varepsilon_{1t} \quad \varepsilon_{2t}], \quad (4.)$$

$$y_t' \Gamma - x_t' B = \epsilon_t'. \quad (5.)$$

Nyt  $\Gamma$  ja  $B$  viittaavat tuntemattomia parametreja sisältäviin matriiseihin, jotka kuvaavat kuluttajien ja tuottajien käyttäytymistä.  $q_t$  ja  $p_t$  viittaa tasapainomäärään sekä tasapainohintaan hetkellä  $t$ .  $y_t$  ja  $\epsilon_t$  viittaavat vektoreihin, joiden molempien dimensio on kaksi. Eksogeenisten muuttujien vektori  $x_t$  sisältää vakiotermin sekä kysyntään ja tarjontaan vaikuttavia eksogeenisiä komponentteja  $x_{2t}$  ja  $x_{1t}$ . (Reiss & Wolak 2007, 4293–4295.) Kun yhtälö (5.) kerrotaan puolittain oikealta (kyseessä on matriisilaskuoperaatio)  $\Gamma^{-1}$ :lla ja sitä uudelleen järjestellään, saadaan redusoidun muodon yhtälö, jossa tasapainohinta sekä tasapainomäärä on lineaarinen funktio kysyntään ja tarjontaan vaikuttavista eksogeenisistä muuttujista sekä kysyntään ja tarjontaan kytkeytyvistä virhetermeistä:

$$y_t' = x_t' \Pi + v_t'. \quad (6.)$$

Yhtälöjärjestelmät ja niistä johdetut redusoidun muodon mallit muodostavat perustan rakenteelliselle ekonometrialle. Siirrytään seuraavaksi tarkastelemaan Trygve Haavelmon sekä James Heckmanin ja Rodrigo Pinton kehittämää kausaalista viitekehystä rakennemallien avulla tapahtuvalle kausaalipäätelylle.

### 3.2 Haavelmon, Heckmanin ja Pinton kausaalinen viitekehys

James Heckmanin ja Rodrigo Pinton mukaan Trygve Haavelmon viitekehyksessä kausaaliset vaikutukset määritetään hypoteettisessa mallissa, joka kuitenkin pyrkii kuvaamaan empiiristä mallia. Empiirinen malli taas pyrkii kuvaamaan todellista dataa generoivaa prosessia. Todellinen dataa generoiva prosessi voi olla Haavelmon mukaan ajallisesti vakaa, mutta myös epävakaa. Vakaudella Haavelmo viittaa ajalliseen muuttumattomuuteen. (Haavelmo 1944, 9–26; Heckman & Pinto 2015, 115–116.) Heckmanin ja Pinton mukaan Haavelmon viitekehyksessä tämän hypoteettisen mallin panoksiin (input) tehdään hypoteettista variaatiota tai manipulaatiota ja kausaalinen vaikutus syntyy panosten variaation vaikutuksesta tuotokseen (output). Näin ollen Haavelmon viitekehyksessä tehdään ero hypoteettisessa mallissa tehtyihin hypoteettisiin manipulointeihin ja niiden aikaansaamiin vaikutuksiin sekä mahdollisten muuttujien välisten korrelaatioiden välille, jotka ilmenevät itse aineistossa. Kausaalinen vaikutus ei siis Haavelmon viitekehyksessä riipu datassa mahdollisesti muuttujien välillä olevista riippuvuuksista. (Heckman & Pinto 2015, 115–116.)

Haavelmo myöntää teoksensa *The probability approach in econometrics* (1944) alussa saaneensa huomattavasti vaikutteita kollegaltaan Ragnar Frischiltä työskennellessään Oslon taloustieteellisessä instituutissa (Haavelmo 1944). Heckmanin ja Pinton mukaan Haavelmon kausaalinen vaikutus ilmentääkin Frischin ajatusta siitä, kuinka kausaalinen vaikutus olisi vain mielessä. Väittämät kausaalisista vaikutuksista eivät näin ollen olisi myöskään empiirisiä väittämiä. Viitekehyksessä huomio kiinnitetään erityisesti keskimääräiseen kausaaliseen vaikutukseen (Mean Causal Effect). Lisäksi viitekehyksessä tehdään monia yksinkertaistavia oletuksia, kuten lineaarisuusoletuksia sekä oletetaan vasteiden yhdenmukaisuus suhteessa toimijoihin. Lisäksi viitekehyksessä keskitytään jatkuviin muuttujiin. Heckmanin ja Pinton mukaan Haavelmon malli on kuitenkin tarkka ja intuitiivinen viitekehys kausaalisille vaikutuksille. Heidän mukaansa mallin etuna verrattuna tilastotieteen piirissä hyödynnettyihin kausaaliin viitekehyksiin, on mahdollisuus tarkastella esimerkiksi simultaanista kausaalisuuta yleisemmällä tasolla. (Heckman & Pinto 2015, 116–118; Haavelmo 1944, 12–39.)

Heckmanin ja Pinton mukaan Haavelmon kausaalinen viitekehys on rakenteellisten yhtälöiden yhtälöjärjestelmä. Järjestelmässä yhtälöt määrittelevät ja olettavat muuttujien väliset kausaaliset suhteet. Nämä rakenteelliset yhtälöt, tai relaatiot, ovat autonomisia mekanismeja, jotka pysyvät invariantteina tilanteessa, jossa argumentteja manipuloidaan ulkoisesti. Relaation autonomisuudella Haavelmo viittaa relaation riippumattomuuteen muista relaatiosta. Autonomisten relaatioiden järjestelmän rakentaminen on Haavelmon mukaan taidetta, johon tarvitaan intuitiota sekä faktuaalista tietoa. Funktiot, jotka kuvaavat näitä relaatioita, eli rakenteellisia yhtälöitä, tuottavat (määräävät) aina samat lopputulokset, jos panoksille asetetaan kiinteät arvot. Rakenteellisissa yhtälöissä oletetaan tietty kausaalinen järjestys muuttujien välillä ja yhtälöissä olevien argumenttien oletetaan vastaavan kaikista syistä suhteessa tuotos muuttujaan. Haavelmo itse hyödynsi esimerkkinään Wicksellin korkoteoriaa havainnollistaessaan kausaalimalliansa. Tarkastellaan seuraavaksi kuitenkin modernimpaa Heckmanin ja Pinton muotoilemaa versiota Haavelmon kausaalisesta viitekehyksestä. (Heckman & Pinto 2015, 116–118; Haavelmo 1944, 12–39.)

Oletetaan muuttujat  $X, Y$  ja  $U$ . Oletetaan myös edellisiin muuttujiin liittyvät teoreettiset virhetermit  $\epsilon = (\epsilon_U, \epsilon_X, \epsilon_Y)$ , jotka ovat yhdessä riippumattomia kertymäfunktioilla  $Q_\epsilon$ . Muuttujat  $X, Y$  voidaan havaita, mutta  $U$  on havaitsematon sekoittava muuttuja, joka vaikuttaa muuttujiin  $X$  ja  $Y$ . (Heckman & Pinto 2015, 116–118.) Oletetaan rakenteellisen mallin yhtälöt seuraavasti:

$$Y = f_Y(X, U, \epsilon_Y), \quad (1.)$$

$$X = f_X(U, \epsilon_X), \quad (2.)$$

$$U = f_U(\epsilon_U). \quad (3.)$$

Jos muuttujat  $X, Y$  ja  $U$  saavat arvot  $x, y$  ja  $u$ , niin  $Y$  saa arvon:

$$y = f_Y(x, u, \epsilon_Y). \quad (4.)$$

Kaikki muuttujat on mahdollista kuvata  $\epsilon$  funktiona. Virhetermien yhteisriippumattomuusoletuksen myötä  $\epsilon_Y$  on riippumaton  $(X, U)$ :sta, eli  $(X, U) \perp\!\!\!\perp \epsilon_Y$  ja  $\epsilon_X \perp\!\!\!\perp U$  (Vaikka  $X$  ei ole kuitenkaan riippumaton  $\epsilon_U$ :sta). Heckmanin ja Pinton mukaan Haavelmon kausaalisisessa viitekehyksessä keskeinen käsite on *fixing*, joka viittaa muuttujan arvon kiinnittämiseen. Haavelmon mallissa tapahtuva hypoteettinen manipulaatio toteutetaan muuttujan  $X$  arvon kiinnittämällä siten, ettei se vaikuta arvoihin, joita  $U$  ja  $\epsilon$  saavat. (Heckman & Pinto 2015, 116–118; Haavelmo 1944, 12–39.)

Jos muuttujan  $X$  arvo kiinnitetään arvoon  $x$ , voidaan Heckmanin ja Pinton (2015) notaatiolla kirjoittaa lopputulos (outcome) muotoon:

$$Y(x) = f_Y(x, U, \epsilon_Y). \quad (5.)$$

Tällöin sen odotusarvo voidaan vastaavasti kirjoittaa:

$$\mathbb{E}_{(U, \epsilon_Y)}(Y(x)) = \mathbb{E}(f(x, U, \epsilon_Y)), \quad (6.)$$

joka viittaa odotusarvoon satunnaismuuttujien  $U$  ja  $\epsilon_Y$  jakauman yli. Kun toteutetaan Haavelmon hypoteettinen manipulaatio ja muuttuja  $X$  saa hypoteettiset arvot  $x$  ja  $x'$ , voidaan määritellä keskimääräinen kausaalinen vaikutus (Heckman & Pinto 2015, 116–118; Haavelmo 1944, 12–39):

$$\mathbb{E}_{(U, \epsilon_Y)}(Y(x)) - \mathbb{E}_{(U, \epsilon_Y)}(Y(x')). \quad (7.)$$

Heckmanin ja Pinton mukaan Haavelmon mallia voidaan havainnollistaa lineaarisen regression avulla (Heckman & Pinto 2015, 118). Kuvataan dataa generoivaa prosessia muuttujalle  $Y$  seuraavalla lineaarisella regressiomallilla:

$$Y = X\beta + U + \epsilon_Y, \quad (8.)$$

jossa virhetermin odotusarvo on nolla. Lopputuloksen  $Y$  odotusarvo on tällöin:

$$\mathbb{E}(Y(x)) = x\beta + \mathbb{E}(U), \quad (9.)$$

jos muuttuja  $X$  kiinnitetään arvoon  $x$ . Toisaalta lopputuloksen  $Y$  odotusarvo on seuraava, jos muuttuja  $X$  ehdollistetaan arvoon  $x$ :

$$\mathbb{E}(Y|X = x) = x\beta + \mathbb{E}(U|X = x) \quad (10.)$$

koska  $\epsilon_Y$  ja  $X$  ovat tilastollisesti riippumattomia ja virhetermin  $\epsilon_Y$  ehdollinen odotusarvo ehdolla  $X = x$  on nolla. Pienimmän neliösumman malli identifioi parametrin  $\beta$  ja tekee siitä Heckmanin ja Pinton mukaan *kausaalisen parametrin*, jos havaitsemattoman sekoittavan muuttujan  $U$ :n ehdollinen odotusarvo ehdolla  $X = x$  on nolla, eivätkä  $X$ :n komponentit ole kollineaarisia. (Heckman & Pinto 2015, 118.) Haavelmo käsitteli parametrin estimointia ja jakaumaoletuksia tarkemmin sekä yleisemmin teoksessaan *The Statistical Implications of a System of Simultaneous Equations* (1943/1995). Haavelmo ei itse kuitenkaan suoraan käyttänyt käsitettä *kausallinen parametri*, mutta hän puhui kuitenkin *kausalisista tekijöistä* (causal factors), joihin nämä parametrit ovat kytkeytyneet. (Heckman & Pinto 2015, 118–119; Haavelmo 1944; Haavelmo 1943/1995.) Näiden ehtojen vallitessa saadaan:

$$\mathbb{E}(Y|X = x) = \mathbb{E}(Y(x)) = x\beta. \quad (11.)$$

Heckmanin ja Pinton mukaan  $\beta$  kuvaa tällöin keskimääräistä käsittelyvaikutusta muuttujan  $X$  muutoksesta  $Y$ :hyn ja  $(x - x')\beta$  kuvaa keskimääräistä eroa lopputuloksen  $Y$  odotusarvossa muuttujan  $X$  eri kiinnitetyillä arvoilla  $x$  ja  $x'$ . Haavelmon malli perustuu kuitenkin Heckmanin ja Pinton mukaan tiettyihin vahvoihin oletuksiin. Jos tavoitteena on kausaalisten vaikutusten identifiointi todellisesta dataa generoivasta prosessista, joudutaan tiettyihin käytännön ongelmiin. Kuten aikaisemmin määriteltiin,  $U$  on havaitsematon sekoittava muuttuja, joka vaikuttaa sekä muuttujiin  $X$  että  $Y$ . Keskimääräisten kausaalisten vaikutusten identifiointi vaikeutuu, jos havaitsemattoman sekoittavan muuttujan  $U$  ehdollinen odotusarvo ehdolla  $X$  ei olekaan nolla ja näin ollen  $Y$ :n ehdollinen odotusarvo ehdolla  $X = x$  ei ole yhtä suuri kuin  $\mathbb{E}(Y(x))$ . Tällöin pienimmän neliösumman menetelmällä ei päästä käsiksi autonomiseen kausaaliseen parametriin. Heckmanin ja Pinton mukaan, ilman sekoittavia tekijöitä  $U$ , muuttujan kiinnittäminen on kuitenkin ekvivalentti tilastollisen ehdollistamisoperaation kanssa. Toisaalta Haavelmon mallissa on oletettu myös lineaarisuus. Ilman sen toteutumista tarvitaan vahvempia oletuksia johtaa (11.) kuin pelkkä vaatimus siitä, kuinka havaitsemattoman sekoittavan muuttujan  $U$  ehdollinen odotusarvo ehdolla  $X$  on nolla. (Heckman & Pinto 2015, 119.)

Haavelmon kausaalinen viitekehys muodosti perustan myöhemmille rakennemalleihin perustuville kausaalisille analyyseille. Tarkastellaan seuraavaksi Jan Tinbergenin ideaa siitä, kuinka kausaalisen rakennemallin rakenteelliset yhtälöt tulisi muodostaa.

### 3.3 Tinbergen ja kausaalisten rakennemallien muodostaminen

Jan Tinbergen jatkoi teoksessaan *Econometrics* (1951/2005) siitä mihin Trygve Haavelmo jäi edellisellä vuosikymmenellä. Haavelmon tapaan Tinbergenkin ajatteli rakennemallien olevan ekonometrian keskiössä. Tinbergen määritteli ekonometrian tilastolliseksi empiiriseksi tutkimukseksi teoreettisella käsitteellisellä perustalla ja matemaattiseksi taloustieteeksi, joka toimii mitatun aineiston parissa. Määritelmässä korostuvatkin Tinbergenin ajatukset talousteorian keskeisyydestä ekonometriassa. Tinbergen kuitenkin vertasi ekonometriaa tennikseen, jossa pelaajina toimivat sekä taloustieteilijä että tilastotieteilijä ja jossa molemmat osallistuvat tutkimuksen tekemiseen vuorollaan. Tinbergenin mukaan talousteorian rakentamisen ja siitä johdettujen relaatioiden muodostamisen jälkeen on teorian tilastollisen testauksen vuoro. Testauksen jälkeen teoriasta voidaan johtaa uusia päätelmiä tai teoria voidaan kerta kaikkiaan hylätä. (Tinbergen 1951/2005, 3–13.) Tässä alaluvussa kuitenkin tarkastellaan Tinbergenin ideaa siitä, kuinka kausaalisia rakennemalleja voidaan muodostaa esimerkiksi talousteoriaa hyödyntäen.

Tinbergen viittaa kausaalisiin suhteisiin Haavelmoa useammin. Tinbergenin mukaan tavoitteena on usein selittää toisen muuttujan suuruudessa tapahtuvia muutoksia toisten muuttujien suuruuksissa tapahtuvilla muutoksilla. Nämä muuttujat, joiden magnitudimuutokset selittävät kiinnostuksen kohteena olevan muuttujan magnitudimuutoksia, kutsutaan kiinnostuksen kohteena olevan muuttujan syiksi (causes). Lisäksi Tinbergenin mukaan kausaalisten suhteiden identifioiminen tarvitsee talousteoriaan yhden lisäkomponentin: ajan. Tinbergenin mukaan kaikkia kausaalisia suhteita ei ole mahdollista identifioida staattisissa malleissa. (Tinbergen 1951/2005, 14–15.) Tinbergenin (1951/2005) mukaan esimerkiksi seuraavat tapaukset olisivat kausaalisten suhteiden osalta staattisessa mallissa samoja, mutta dynaamisessa mallissa ne voitaisiin erottaa.

1. Annetulla hinnalla  $y$ , tuottaja määrittää tuottamansa määrän  $x$ , siten, että rajakustannus vastaa hintaa.
2. Annetulla tilausten määrällä, määrittäen tuottajan tarjonnan  $x$ , tuottaja kiinnittää hinnan  $y$ , siten, että se kattaa rajakustannuksen.

Tinbergenin mukaan talousteoria siis kertoo mitkä muuttujat rakenteelliseen malliin täytyisi valita. Hän kuitenkin myönsi, että talousteoria vain harvoin kertoo tarkasta matemaattisesta funktiomuodosta eri muuttujien välillä. Talousteoria ei aina myöskään kerro tarkasti siitä, kuinka pitkällä ajallisella viiveellä muuttujat vaikuttavat toisiin muuttujiin. Joissakin tapauksissa on hänen mukaansa mahdollista päätellä funktion tarkempia ominaisuuksia pidemmälle menevillä perusteluilla, mutta näistä perusteluista hän antoi vain vähän esimerkkejä. Lisäksi hän nojasi teoreemaan, jonka mukaan mitä tahansa funktiota voidaan approksimoida lineaarisella funktiolla, jos variaatio on riittävän vähäistä. (Tinbergen 1951/2005, 18–29.) Tinbergen perustikin rakennemallien muotoilemisen osittain kunkin taloustieteilijän oman harkinnan ja intuition varaan.

Tinbergenin mukaan rakennemallin muodostamista varten olisikin tärkeää ymmärtää systemaattisesti koko kausaalirakenteen verkko tarkasteltavana olevalta alalta. Tinbergen esittikin graafiesimerkin systemaattisesta kausaalirakenteen verkostosta, jossa hän havainnollisti eri muuttujien välisiä ”kausaalisia” yhteyksiä nuolien avulla. Hän otti esimerkissään huomioon myös aikaulottuvuuden, jossa eri muuttujat saattoivat vaikuttaa toisiinsa tietyllä ajallisella viiveellä. Tinbergenin esimerkissä kausaaliset suhteet olivat ajallisesti vakaita ja ne toistuivat eräänlaisina sykleinä. Hänen mukaansa tutkimalla perusteellisesti ilmiöön vaikuttavia syitä, saadaan kausaaliseen verkostoon (ja kausaaliketjuihin) yhä lisää kausaalisia relaatioita. (Tinbergen 1951/2005, 37–40.)

Lopulta kun kausaalisen verkoston tutkimus on edennyt pisteeseen, jossa aluksi tarkasteltava ilmiö löytyy uudelleen jonkin ilmiön syynä tarkasteltavassa kausaaliketjussa, voidaan kausaalisen verkoston tutkiminen Tinbergenin mukaan päättää. Tällöin siitä voidaan rakentaa järjestelmän looginen rakenne, josta nähdään ilmiöön vaikuttavat syyt, ilmiöön vaikuttavien syiden syyt sekä mihin asti syitä ei ole enää johdettu. Toisaalta loogisesta rakenteesta voidaan nähdä myös vaikutukset, jotka syyt saavat aikaiseksi. Kausaalista verkostoa kuvaavan loogisen rakenteen nuolia voidaan Tinbergenin mukaan tarkastella kahdella tavalla. Kun tarkastellaan erikseen kaikkia niitä nuolia, jotka päättyvät johonkin pisteeseen, saadaan ilmiölle syyt. Kun toisaalta valitaan kaikki nuolet, jotka lähtevät jostain tietystä pisteestä, saadaan vaikutukset jostakin ilmiöstä joihinkin toisiin ilmiöihin. Ensimmäinen tapa tarkastella loogisen rakenteen nuolia on Tinbergenin mukaan hyödyllisempi muodostettaessa rakennemallin yhtälöitä. Tinbergenin viitekehyksessä rakennemalli rakennetaan suorista kausaalisisista suhteista, eli niistä muuttujien välisistä suhteista, joiden välissä loogisen rakenteen verkostossa on vain yksi nuoli. (Tinbergen 1951/2005, 38–43.) Hän antoi esimerkin kolmen yhtälön rakennemallista periodille  $t$ :

$$u_t = v_1 Y_{t-1} + v_2 p_{t-1} + v_3 T_{t-1} + R_t^u \quad (1.)$$

$$Y_t = \eta_1 u_t + \eta_2 p_t + R_t^Y \quad (2.)$$

$$p_t = \pi_1 Y_{t-1} + \pi_2 q_{t-1} + R_t^p \quad (3.)$$

jossa esiintyy muuttujia hetkeltä  $t$ , muuttujia aikaisemmilta hetkiltä sekä muita datassa olevia komponentteja. Ensimmäinen yhtälö kuvaa hyödykkeiden ja palvelujen kysyntää. Toinen yhtälö kuvaa määritelmää kansan kokonaistuloille ja kolmas yhtälö kuvaa hintojen muodostumista. Kyseisessä esimerkissä  $u_t$  viittaa hyödykkeiden sekä muiden palvelujen kysytyyn määrään hetkellä  $t$ ,  $p_t$  viittaa näiden hyödykkeiden ja palvelujen keskimääräiseen hintaan hetkellä  $t$ ,  $Y_t$  viittaa kokonaistuloihin hetkellä  $t$ ,  $T_t$  viittaa lämpötilaan hetkellä  $t$  ja  $q_t$  viittaa satoon hetkellä  $t$ . Kun yhtälöjärjestelmä ratkaistaan periodin  $t$  muuttujille, saadaan mallin redusoitu muoto. (Tinbergen 1951/2005, 38–43.)

## 4 Rubinin kausaalinen viitekehys

Tilastotieteen alalla kausaalimalleilla ja kausaalipäätelyllä on pitkä historia. Erityisesti satunnaistettujen kontrollikoeasetelmien, eli niin sanottujen RCT (Randomized Controlled Trials) -asetelmien kehittyminen 1900-luvun alussa Ronald Fisherin ja Jerzy Neymanin vaikutuksesta rakensi pohjaa myöhemmille kausaalimalleille. Jerzy Neymanin väitöskirja *On the Application of Probability Theory to Agricultural Experiments* vuodelta 1923 oli käännteentekevä teos kausaalipäätelyn alalla, vaikka saikin aikanaan vähemmän huomiota kuin Ronald Fisherin (1925, 1926, 1935/1949) teokset vuosia myöhemmin. Jerzy Neyman suunnitteli väitöskirjassaan hypoteettisen maatalouskenttäkokeen. Kokeessa hän jakoi maan erillisiin maapalstoihin, jotka vastasivat kokeen havaintoyksikköjä. Väitöskirjassaan hän käytti käsitteitä maapalstojen potentiaalisista tuotoista, jotka vastasivat Donald Rubinin potentiaalisia lopputuloksia (potential outcomes). Donald Rubinin mukaan Neyman käytti väitöskirjassaan ensimmäistä kertaa Rubinin tunnetussa kausaalimallissa käytettyä *potential outcomes* -notaatiota. Lisäksi Neyman käsitteli satunnaistettuja kenttäkokeita Fisheriäkin aikaisemmin, vaikka Fisher perusteli RCT-asetelmien käytön Neymania huolellisemmin. (Rubin 2005, 324–325; Imbens 2022; Rubin & Imbens 2015, 23; Fisher 1935/1949; Splawa-Neyman 1923/1990.)

Tässä luvussa tarkastellaan Rubinin kausaalista viitekehystä, sen oletuksia ja perusteita sekä sen avulla tehtävää kausaalipäätelyä. Aluksi tarkastelemme lyhyesti Rubinin viitekehysten perusajatuksen, jonka jälkeen siirrymme viitekehysten oletuksiin ja perustuksiin. Lopuksi tarkastelemme Rubinin kausaalisen viitekehysten mahdollistamaa kausaalipäätelyä sekä satunnaistetuissa asetelmissä että havaintotutkimusasetelmissä. Rubinin kausaalimalli on inspiroinut monia tutkijoita niin kutsuttuun *design* -perustaiseen kausaalipäätelyyn ja eräänlaisiin luonnollisiin koeasetelmiin, joissa hyödynnetään esimerkiksi ero-eroissa (Differences-in-Differences) -menetelmiä, regressioepäjatkuvuusmenetelmiä ja instrumenttimuuttujamenetelmiä. Tällaiset luonnolliset koeasetelmat tai kvasikokeelliset tutkimusasetelmat kausaalipäätelyyn on kuitenkin jouduttu rajaamaan ulos tämän tutkielman tarkastelemasta alueesta. Kausaalipäätelyä kvasikokeellisissa asetelmissä on tarkasteltu laajasti esimerkiksi teoksessa *Causal Inference - The Mixtape* (Cunningham 2021; Ks. myös Angrist & Pischke 2009; Angrist & Pischke 2010; Imbens 2010; Kortelainen & Salokangas 2023).

#### 4.1 *Potential outcomes* -malli

Donald Rubin julkaisi tunnetun kausaalimallinsa alun perin lehdessä *Journal of educational psychology* artikkelillaan *Estimating causal effects of treatments in randomized and nonrandomized studies* (1974). Häntä motivoi erityisesti psykologian ja kasvatustieteen alalla noussut kritiikki siitä, kuinka ainoastaan oikein satunnaistetut kokeet (eli niin kutsutut RCT-asetelmat) mahdollistavat kausaalipäätelyn. Rubinin mukaan erityisesti yhteiskuntatieteet joutuisivat suuriin vaikeuksiin kausaalipäätelyn saralla, koska lähes kaikki aineisto on saatavilla ainoastaan ei-satunnaistetussa muodossa. Satunnaistetut kenttäkokeet eivät ole myöskään kovinkaan usein mahdollisia johtuen erilaisista kustannuksista, etiikkaan ja ajallisiin viiveisiin liittyvistä syistä. (Rubin 1974, 688–701.) Eettiset kysymykset huomioidaan vaikutusarvioiden toteuttamisessa yhä huolellisemmin (ks. esim. Gertler 2011, 153–154). Rubinin mukaan monissa tilanteissa on parempi yrittää estimoida kausaalisia vaikutuksia ei-satunnaistetusta aineistosta (Rubin 1974, 688–701).

Keskeinen ero satunnaistettujen ja ei-satunnaistettujen tutkimusasetelmien välillä liittyy siihen mekanismiin, joka ikään kuin määrittää, kuuluuko havaintoyksikkö käsittelyjoukkoon vai kontrollijoukkoon ja mitkä potentiaaliset lopputulokset havaintoyksiköille realisoituvat (ks. esim. Rubin & Imbens 2015). Tämä havaintoyksikön joukon määrittävä mekanismi voi olla esimerkiksi sellainen, joka satunnaisesti ”arpoo”, kuuluuko yksikkö käsittelyjoukkoon vai kontrollijoukkoon. Jos jokaisella yksiköllä on yhtä suuri todennäköisyys päätyä niin käsittelyjoukkoon kuin kontrollijoukkoonkin, kutsutaan tällaista yksikön joukon määrittävää mekanismia yleensä satunnaistetuksi. Jos yksikön joukon määrittävä mekanismi ei ole tällä tavoin täysin satunnainen, puhutaan yleensä ei-satunnaistetuista tutkimusasetelmista tai havaintotutkimuksista.

Rubinin mukaan kausaalisia vaikutuksia onkin mahdollista estimoida myös ei-satunnaistetuista tutkimusasetelmista, eli niin sanotuista havaintotutkimusasetelmista. Tätä varten on kuitenkin ensin määriteltävä kausaalimalli. Rubinin mukaan kausaalinen vaikutus voidaan määrittellä kahden eri hypoteettisen tilanteen erona samalle yksikölle. Rubinin notaatiolla malli voidaan määrittellä seuraavasti:  $E$  ja  $C$  viittaavat jonkinlaisiin erilaisiin käsittelyihin ajanjaksolla  $t_1, t_2$  ( $t_1 < t_2$ ), jossa käsittelyn  $E$  aloittamisen ajankohta on  $t_1$  ja kiinnostuksen kohteena olevan muuttujan  $Y$  mittauksen ajankohta on  $t_2$ . Näin ollen oletetaan, että käsittelyn aloittamisen ajankohta voidaan yksiselitteisesti määrittää ja että käsittelyt  $C$  ja  $E$  ovat toisensa poissulkevia. Nyt voidaan määrittellä, että  $y(E)$  viittaa selitettävän muuttujan arvoon hetkellä  $t_2$  jos yksikkö sai kokeellisen käsittelyn hetkellä  $t_1$  ja  $y(C)$  viittaa selitettävän muuttujan arvoon hetkellä  $t_2$ , jos yksikkö sai kontrollikäsittelyn hetkellä

$t_1$ . (Rubin 1974, 688–701.) Rubinin mukaan kausaalinen vaikutus hypoteettisista käsittelyistä  $E$  ja  $C$ , yksikölle  $j$  voidaan määrittellä tarkasteltavalla ajanjaksolla  $t_1, t_2$  seuraavasti:

$$y_j(E) - y_j(C). \quad (1.)$$

Vaikka molemmat lopputulemat voivat olla havaittavissa, molempia lopputulemia ei koskaan havaita aineistosta samalle yksikölle. Donald Rubinin kollega Paul W. Holland (1986) kutsui tätä kausaalipäätelyn fundamentaaliseksi ongelmaksi. Tieto kausaalisista vaikutuksista vaatii pääsyä dataan, johon ei ole koskaan mahdollista päästä käsiksi. Rubinin kausaalimallissa puhutaankin potentiaalisista lopputulemista, eli siitä, mitä samalle yksikölle olisi tapahtunut, jos se olisi saanut käsittelyn  $E$ , sen sijaan, että se olisi saanut käsittelyn  $C$ . Kyse on täysin hypoteettisesta tilanteesta, eräänlaisesta kontrafaktuaalista, hyvin samaan tapaan kuin Haavelmon kausaalimallissakin. Eroja Haavelmon viitekehykseen on kuitenkin löydettävissä esimerkiksi sen suhteen, kuinka *kausaalisiin parametreihin* suhtaudutaan. Imbensin ja Rubinin mukaan kausaliteetti on myös eräänlaisesti sidottu toimintaan, kuten manipulaatioon, käsittelyyn tai interventioon. Kausaalisessa viitekehysessä oletetaan, että yksikkö, kuten esimerkiksi jokin henkilö, voisi toimia tavalla A tai tavalla B. Hän voisi esimerkiksi ottaa pääkipuunsa aspiriinia tai olla ottamatta, mutta lopputuloksena kuitenkin realisoituu joko päänsäryn katoaminen tai päänsäryn jatkuminen. (Rubin 1974, 688–701; Rubin 2005, 323; Holland 1986, 947; Imbens & Rubin 2015, 4; Cunningham 2021.)

## 4.2 SUTVA ja jakomekanismi

Kuten Haavelmon, Heckmanin ja Pinton rakennemallien kausaalinen viitekehys, myös Rubinin viitekehys perustuu tiettyihin vahvoihin oletuksiin. Kausaalisen viitekehysten oletukset ovat keskeisiä ratkaistaessa kausaalipäätelyn fundamentaalista ongelmaa – potentiaalisista lopputuloksista havaitaan aina vain yksi, jolloin on hyödynnettävä dataa muilta yksiköiltä tai pääteltävä puuttuva data jollakin toisella tavalla. Donald Rubin muotoili viitekehysten keskeiset oletukset yhdessä kollegansa Guido W. Imbensin kanssa teokseen *Causal Inference for Statistics, Social, and Biomedical Sciences* (2015). Rubinin viitekehysten keskeiset oletukset koskevat niin kutsuttua SUTVA:a (Stable Unit Treatment Value Assumption) sekä jakomekanismia (Assignment Mechanism).

Rubinin viitekehyksessä oletettu SUTVA voidaan jakaa kahteen keskeiseen oletukseen tai ehtoon. Ensimmäisen ehdon mukaan jonkun yksikön  $i$  käsittely ei vaikuta jonkun toisen yksikön  $p$  saamaan lopputulokseen. Esimerkiksi jonkinlaisessa maatalouskenttäkokeessa jonkin tietyn maapalstan saama lannoite ei vaikuta jonkin toisen maapalstan kasvien kasvuun. SUTVA:n toisen ehdon mukaan yksikön saadessa tietyn käsittelyn, ei tämä yksilö voi saada eri muotoja tästä kyseisestä käsittelystä. Esimerkiksi edellä mainitussa maatalouskenttäkokeessa tutkittaessa jonkin lannoitteen tehoa (joka toimii tutkimusasetelman käsittelynä), kyseisen lannoitteen täytyy toimia yhtä hyvin jokaisen maapalstan kohdalla. (Rubin & Imbens 2015, 9–12.)

Taloustieteen piirissä huolta ovat herättäneet niin kutsutut yleisen tasapainon vaikutukset joissakin tutkimusasetelmissa. Esimerkiksi työn taloustieteessä tutkittaessa jonkinlaisen koulutuksen vaikutusta tarkasteltavien henkilöiden työllisyystilanteeseen ja ansioihin, voidaan joutua ottamaan huomioon vaikutus, jossa useiden henkilöiden sijoittuminen tiettyyn koulutukseen vaikuttaa työmarkkinoiden tasapainovaikutusten kautta myös henkilöiden potentiaalsiin ansioihin sekä työllistymiseen. Tällaiset vaikutukset vaarantaisivat SUTVA:n ensimmäisen ehdon. (Rubin & Imbens 2015, 9–12; Ks. myös Heckman & Pinto 2024.)

Rubinin viitekehysten oletusten keskiössä on SUTVA:n lisäksi myös jakomekanismiin (Assignment Mechanism) liittyvät oletukset. Jakomekanismilla tarkoitetaan abstraktia mekanismia, joka määrittää, mitkä yksiköt saa minkäkin käsittelyn ja mitkä potentiaaliset lopputulokset yksiköille lopulta realisoituvat (Rubin & Imbens 2015, 13–15). Jakomekanismin voidaan siis sanoa määrittävän yksiköiden käsittelyiden toimeksiannot sekä potentiaaliset lopputulemat. Esimerkiksi jakomekanismi satunnaistetussa kokeessa, jossa kaikkien toimeksiantojen todennäköisyys on yhtä suuri ja jossa on kaksi yksikköä, on Rubinin notaatiolla seuraava (Rubin & Imbens 2015, 31–43):

$$\Pr(\mathbf{W}|\mathbf{X}, \mathbf{Y}(0), \mathbf{Y}(1)) = \frac{1}{4}, \quad \text{jokaiselle } \mathbf{W} \in \left\{ \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \end{pmatrix} \right\},$$

jossa  $\mathbf{Y}(0)$  ja  $\mathbf{Y}(1)$  ovat  $N$  komponentista koostuvia vektoreita potentiaalisista lopputulemista ja  $\mathbf{W}$  viittaa  $N$  komponentista koostuvaan toimeksiantovektoriin, joka saa arvon 1 jos yksikkö saa tietyn käsittelyn ja arvon 0, jos yksikkö saa toisen käsittelyn. Lisäksi  $\mathbf{X}$  viittaa  $N \times K$  matriisiin, jossa  $K$  viittaa kovariaattivektoriin. Edellä määritelty jakomekanismi määrittää saman todennäköisyyden kaikille mahdollisille käsittelyiden toimeksiannoille kahden havaintoyksikön tapauksessa. (Rubin & Imbens 2015, 31–43.)

Rubin määrittää jakomekanismeille kolme kriteeriä sekä kaksi muuta ominaisuutta, joiden perusteella jakomekanismeja on mahdollista luokitella riippuen siitä täyttääkö jakomekanismi kyseisen kriteerin ja ominaisuuden vai ei: individualistisuus- (Individualistic assignment), probabilistisuus- (Probabilistic assignment) ja sekoittamattomuuskriteeri (Unconfounded assignment). Lisäksi jakomekanismeja voidaan jakaa yhtäältä sen perusteella, onko jakomekanismin funktiomuoto tunnettu vai tuntematon ja toisaalta, onko jakomekanismi tutkijan kontrollissa vai ei. Individualistisuuskriteeri rajoittaa kunkin yksikön toimeksiantotodennäköisyyden riippumattomuutta muiden yksilöiden kovariaateista ja potentiaalisista lopputulemist. Probabilistisuuskriteeri vaatii, että jokaisen havaintoyksikön jokaisen mahdollisen käsittelyn todennäköisyys on nolaa suurempi. Sekoittamattomuuskriteeri kieltää jakomekanismin toimeksiantojen riippuvaisuuden potentiaalisista lopputulemist. (Rubin & Imbens 2015, 31–43.)

Rubinin määrittämien jakomekanismien kriteerit kytkeytyvät suoraan siihen, kuinka kausaalipäätelyä voidaan toteuttaa erilaisissa tutkimusasetelmissä. Esimerkiksi klassisessa satunnaistetussa kokeessa jakomekanismi toteuttaa kaikki Rubinin määrittämät kriteerit. Kun siirrytään havaintotutkimuksiin (Observational Study), jakomekanismin tarkka funktionaalinen muoto jää tuntemattomaksi. Tällöin sekoittamattomuuskriteeri voi muodostua merkittäväksi huolenaiheeksi. Jakomekanismi voi olla kuitenkin havaintotutkimuksissakin säännöllinen, toteuttaen melkein kaikki Rubinin jakomekanismiin liittyvät kriteerit. Rubinin mukaan erilaisissa *Design* -tason omaavissa tutkimuksissa voidaan päästä säännölliseen jakomekanismiin, kunhan kovariaattien jakaumaan suhteessa käsittelyryhmiin tehdään aluksi tasapainotuksia. Rubinin mukaan kaikista oleellisimpien kovariaattien löytämisellä onkin mahdollista päästä ainakin lähelle säännöllisen jakomekanismin tilannetta. (Rubin & Imbens 2015, 31–47.)

### 4.3 Kausaalipäätely satunnaistetuissa kontrollikokeissa

Paul W. Hollandin (1986) mukaan kausaalipäätelyn fundamentaalinen ongelma on potentiaalisia lopputulemia koskeva puuttuvan datan ongelma (Holland 1986, 945–960). Näin ollen, jotta kausaalimalleilla olisi minkäänlaista käyttöä tutkimustyössä, on jotenkin pääteltävä näitä puuttuvia potentiaalisia lopputulemia. Rubin ehdotti ratkaisuja kausaalipäätelyn fundamentaaliseen ongelmaan jo ensimmäisessä mallia käsittelevässä artikkelissaan vuodelta 1974, mutta laajensi ratkaisuvaihtoehtoja myöhemmin yhdessä Guido Imbensin kanssa vuonna 2015. Tässä alaluvussa

kausaalipäätelyä tarkastellaan satunnaistettujen kontrollikokeiden asetelmissa, eli asetelmissa, joissa jakomekanismi on tunnettu, eikä vaatimus sekoittamattomuudesta muodosta huolenaihetta. Aluksi käsittelemme tarkemmin kausaalisen vaikutuksen määritelmiä Rubinin kausaalissa viitekehysessä, jonka jälkeen tarkastelemme kausaalisen vaikutuksen identifiointia ja estimointia.

Rubin (1974) mukaan kausaalinen vaikutus voidaan määrittää *tyypillisenä kausaalisenä vaikutuksena* (typical causal effect) saatavilla olevasta aineistosta. Esimerkiksi jos oletetaan  $M$  yksikköä, niin Rubinin notaatiolla tyypillinen kausaalinen vaikutus saadaan  $E$  ja  $C$  käsittelyistä keskimääräisenä kausaalisenä vaikutuksena  $M$  määrälle *kokeita* (Rubin 1974, 688–701; Rubin 2005, 323):

$$\frac{1}{M} \sum_{j=1}^M [y_j(E) - y_j(C)]. \quad (2.)$$

Rubin mainitsi artikkelissaan lyhyesti myös muita vaihtoehtoisia tapoja laskea aineistosta tyypillistä kausaalista vaikutusta, esimerkiksi mediaani kausaalisen vaikutuksen. Hänen mukaansa muut määritelmät monimutkaistavat analyysia kuitenkin liikaa. Rubinin mukaan keskimääräinen kausaalinen vaikutus onkin monilta osin sovelias määritelmä tyypilliselle kausaalille vaikutukselle. (Rubin 1974, 688–701.) Esimerkiksi kahden havaintoyksikön ja *kokeen* tapauksessa, saataisiin:

$$\frac{1}{2} [y_1(E) - y_1(C)] + \frac{1}{2} [y_2(E) - y_2(C)]. \quad (3.)$$

Kun oletetaan, että toinen yksikkö sijoittui käsittelyryhmään  $E$  ja toinen yksikkö käsittelyryhmään  $C$ , niin estimaateiksi saadaan joko (4.) tai (5.) (Rubin 1974, 688–701). Molemmat skenaariot eivät voi realisoitua:

$$y_1(E) - y_2(C) \quad (4.)$$

$$y_2(E) - y_1(C) \quad (5.)$$

Ongelmaksi yhtälöiden (4.) ja (5.) kanssa muodostuu, etteivät niistä kumpikaan vastaa Rubinin määrittelemää kausaalista vaikutusta, jossa kausaalinen vaikutus lasketaan samalta yksiköltä  $j$ . Lisäksi on vaikea arvioida, kuinka lähellä yhtälöt (4.) ja (5.) ovat suhteessa todelliseen kausaaliseen vaikutukseen (1.). (Rubin 1974, 688–701.) Yhdessä Paul R. Rosenbaumin kanssa vuonna 1983 Rubin määritteli kausaalille vaikutukselle varsin hyödyllisen määritelmän: keskimääräisen käsittelyvaikutuksen (Cunningham 2021; Rosenbaum & Rubin 1983, 42). Keskimääräinen

käsittelyvaikutus (Average Treatment Effect) voidaan estimoida kahden odotusarvon erotuksena potentiaalisista lopputulemista:

$$\mathbb{E}(Y_i(1)) - \mathbb{E}(Y_i(0)). \quad (6.)$$

Odotusarvot samaistetaan usein (super) populaatiotason käsitteenä Rubinin määrittelemään kausaaliseen vaikutukseen. Myöhemmin yhdessä Guido Imbensin kanssa Rubin käsitteli aihetta huomattavasti systemaattisemmin. Vuonna 2015 julkaistussa teoksessaan *Causal Inference for Statistics, Social, and Biomedical Sciences* Rubin ja Imbens systemaattisesti kytkevät puuttuvan datan ongelman erilaisiin jakomekanismeihin sekä luovat kattavan ohjekirjan kausaalimallissaan tapahtuvalle kausaalipäätelylle. Rubinin ja Imbensin mukaan keskeistä onkin ymmärtää erilaiset jakomekanismit ratkaistessa kausaalipäätelyn fundamentaalista ongelmaa (Rubin & Imbens 2015).

Tarkastellessaan kausaalipäätelyä potentiaalisten lopputulemien viitekehyksessä klassisissa satunnaistetuissa kokeissa Rubin ja Imbens tekivät aluksi selkeän jaon erityyppisille satunnaistettujen kokeiden jakomekanismeille. He käsitelivät klassisista satunnaistetuista jakomekanismeista erityisesti Bernoullin kokeita, täysin satunnaistettuja kokeita, stratifioituja satunnaistettuja kokeita sekä parillisesti satunnaistettuja kokeita. Erilaisista jakomekanismeista täysin satunnaistettujen kokeiden jakomekanismi, lyhyesti CRE (Completely Randomized Experiments), rakensi vahvan perustan Rubinin ja Imbensin myöhemmälle kausaalipäätelyn analyysille. Täysin satunnaistettujen kokeiden jakomekanismit perustuvat parilliseen määrään yksikköjä, jotka satunnaisesti jaetaan kahteen ryhmään siten, että ryhmistä tulee samankokoiset. (Rubin & Imbens 2015, 31–56.)

Rubin ja Imbens käsitelivät teoksessaan (2015) Fisherin ja Neymanin tarkastelutapoja, regressioperustaista päätelyä sekä *model* -perustaista päätelyä suhteessa puuttuvan datan ongelmaan klassisten satunnaistettujen kokeiden kontekstissa. He keskittyivät pääosin täysin satunnaistettujen kokeiden asetelmiin, mutta tarkastelivat lyhyesti myös stratifioituja ja pareittain satunnaistettuja kokeita. Tarkastellaan seuraavaksi kuitenkin ainoastaan regressio- ja *model* -perustaiset menetelmät suhteessa kausaalipäätelyn fundamentaaliseen ongelmaan – puuttuvan datan ongelmaan.

Regressiomalli on yksi mikroekonometrian keskeisimmistä työkaluista ja sen suhde kausaalipäätelyyn onkin herättänyt kiinnostusta jo 1800- ja 1900-lukujen vaihteessa (Hoover 2008, 3). Imbensin ja Rubinin mukaan pienimmän neliösumman regressiomalli voikin tarjota kausaalisen tulkinnan CRE asetelmissä. Imbensin ja Rubinin mukaan regressioperustaisissa menetelmissä

potentiaalisten lopputulemien lähtökohtana on rajaton super-populaatio. Regressioperustaisessa päättelyssä myös potentiaaliset lopputulemat ovat satunnaisia, kun taas esimerkiksi fisheriläisessä ja neymanilaisessa tarkastelussa potentiaaliset lopputulemat ovat muuttumattomia ja jakomekanismi ainoa satunnaisuuden perusta. Imbensin ja Rubinin mukaan regressiomallin oikeutus perustuu havaitun lopputuleman ehdollisen odotusarvon representointiin kun selittävät muuttujat on annettu. Ehdollisen odotusarvon representoinnin oikeutus ei Imbensin ja Rubinin mukaan horju tai riipu satunnaistamisesta, jos mallissa on muitakin selittäviä muuttujia (kovariaatteja) kuin käsittelyindikaattori. (Rubin & Imbens 2015, 113–134.) Oletetaan yksinkertainen PNS (Pienimmän neliösumman, eng. OLS, Ordinary Least Squares) regressiomalli Rubinin ja Imbensin notaatiolla ilman lisäkovariaatteja:

$$Y_i^{obs} = \alpha + \tau \cdot W_i + \varepsilon_i$$

Jossa  $Y_i^{obs}$  viittaa havaittuun lopputulosmuuttujaan yksikölle  $i$ ,  $\alpha$  viittaa vakioon,  $\tau$  viittaa käsittelyvaikutukseen,  $W_i$  viittaa käsittelyindikaattoriin ja  $\varepsilon_i$  viittaa havaitsemattomaan residuaaliin yksikölle  $i$ . Havaitsematon residuaali vastaa havaitsemattomista tekijöistä, jotka determinoivat lopputulosta. (Rubin & Imbens 2015, 113–134.) PNS estimaattorit  $\widehat{\alpha}^{ols}$  ja  $\widehat{\tau}^{ols}$  saadaan minimoimalla neliöityjen residuaalien summaa ja uudelleenjärjestelemällä saadaan lopulta:

$$\widehat{\tau}^{ols} = \bar{Y}_t^{obs} - \bar{Y}_c^{obs} = \widehat{\tau}^{dif}, \quad (7.)$$

jossa  $\widehat{\tau}^{dif}$  viittaa keskimääräisten lopputulosten erotukseen eri käsittelyryhmistä,

$$\bar{Y}_t^{obs} = \sum_{i:W_i=1} Y_i^{obs} / N_t,$$

ja

$$\bar{Y}_c^{obs} = \sum_{i:W_i=0} Y_i^{obs} / N_c.$$

Käsittelyvaikutuksen PNS estimaatti  $\tau$  tulkitaan yleensä käsittelyn kausaalisen vaikutuksen estimaatiksi. Rubinin ja Imbensin mukaan tämä tulkinta on yhtälön (7.) nojalla oikeutettu heidän kausaalimallinsa kontekstissa. Rubinin ja Imbensin mukaan tämä perustuu estimaatin osoitettuun harhattomuuteen sekä suhteessa rajallisen otoksen keskimääräiseen käsittelyvaikutukseen että super-populaation keskimääräiseen käsittelyvaikutukseen. (Rubin & Imbens 2015, 113–134.) Näin ollen regressioperustainen päättely mahdollistaakin menetelmän estimoida keskimääräistä käsittelyvaikutusta, eli yhtälöä (6.).

Rubinin viitekehyksessä regressioperustaisille menetelmille vaihtoehdoksi on esitetty niin kutsuttua *model* – perustaista päättelyä. Kun regressioperustaisessa päättelyssä nojaututtiin keskimääräisten lopputulosten erotukseen eri käsittelyryhmistä, *model* – perustaisessa päättelyssä tarkastellaan potentiaalisia lopputuloksia jokseenkin fisheriläisittäin, määrittäen jokainen puuttuva potentiaalinen lopputulos erikseen. Toisaalta menetelmissä on myös paljon yhtymäkohtia, esimerkiksi molemmissa menetelmissä potentiaaliset lopputulemat ovat satunnaisia. *Model* – perustaisessa päättelyssä jokaisen puuttuvan potentiaalisen lopputuloksen määrittäminen perustuu tiettyihin jakaumaoletuksiin. Esimerkiksi bayesilaisessa *model* – perustaisessa päättelyssä tutkijan on ensin täsmennettävä potentiaalisten lopputulemien yhteisjakauma, joka perustuu priorijakauman valintaan sekä selitettävien muuttujien ja kovariaattien jakaumaan. Vaikka jokainen lopputulos on määriteltävä erikseen tiettyjen jakaumaoletusten vallitessa, voidaan potentiaalisten lopputulemien määrittämistä helpottaa esimerkiksi erilaisilla simulaatiomenetelmillä. *Model* – perustaista päättelyä voi kuitenkin varsin helposti soveltaa myös täysin satunnaistettujen asetelmien ulkopuolelle, kuten havaintotutkimuksiin. (Rubin & Imbens 2015, 141–177.)

#### 4.4 Kausaalipäättely havaintotutkimuksissa

Keskeinen ero satunnaistettujen kontrollikoeasetelmien ja havaintotutkimusasetelmien välillä koskee jakomekanismia. RCT-asetelmissä jakomekanismi oli tunnettu, mutta havaintotutkimuksissa sen tarkka funktionaalinen muoto jää tuntemattomaksi. Lisäksi tulokset harhattomuudesta eivät enää päde havaintotutkimuksissa. (Rubin & Imbens 2015, 257–265.)

Havaintotutkimusasetelmissä suureksi huolenaiheeksi kausaalipäättelyn kannalta nousee vaatimus sekoittamattomuudesta (unconfoundedness). Rubinin ja Imbensin mukaan sillä tarkoitetaan jakomekanismin toimeksiantotodennäköisyyksien riippumattomuutta potentiaalisista lopputulemista. Yhdessä individualistisuus- ja probabilistisuuskriteerien kanssa sekoittamattomuuskriteeri voisi tarjota kausaalisen tulkinnan potentiaalisten lopputulemien vertailulle kovariaattimuuttujien eri kiinnitetyillä tai ehdollistetuilla arvoilla. Vaatimus sekoittamattomuudesta onkin suoraan kytkeytynyt kysymykseen kausaalisesta tulkinnasta. (Rubin & Imbens 2015, 257–265.)

Satunnaistetuissa jakomekanismeissa käsittelyn toimeksianto määräytyi satunnaistetusti, eivätkä muut tekijät voineet sekoittaa toimeksiantoa. Kun jakomekanismi ei ole enää tunnettu tai tutkijan kontrollissa, jotkin muut tekijät saattavat vaikuttaa käsittelyn toimeksiantoon. Lisäksi taustalla

vaikuttavat muut tekijät saattavat vaikuttaa myös potentiaalsiin lopputulemiin. (Rubin & Imbens 2015, 257–265.) Jos sekoittamattomuus olisi voimassa, rajattomassa super-populaatiossa jakomekanismin antamat toimeksiannotodennäköisyydet yksinkertaistuisivat, koska toimeksiannot olisi riippumaton potentiaalisista lopputulemistä ehdolla kovariaatit  $X_i$ :

$$\Pr(W_i = 1 | X_i, Y_i(0), Y_i(1)) = \Pr(W_i = 1 | X_i). \quad (1.)$$

Lisäksi sekoittamattomuuden voimassa ollessa Rubinin ja Imbensin notaatiolla:

$$(Y_i(0) | W_i = 1, X_i) \sim (Y_i(0) | W_i = 0, X_i), \text{ kaikille } i, \dots, N, \quad (2.)$$

ja

$$(Y_i(1) | W_i = 0, X_i) \sim (Y_i(1) | W_i = 1, X_i), \text{ kaikille } i, \dots, N, \quad (3.)$$

jossa  $\sim$  viittaa jakauman yhtäsuuruuteen. Eli potentiaalisen lopputuleman  $Y_i(1)$  jakauma on molemmilla käsittelyn toimeksiannoilla sama, ehdolla kovariaatti  $X_i$ . Sama pätee myös potentiaaliselle lopputulemalle  $Y_i(0)$ . Näin ollen myös puuttuvien potentiaalisten lopputulemien jakauma vastaa havaittavien lopputulemien jakaumaa. Ongelma sekoittamattomuuden kanssa on kuitenkin siinä, ettei sitä voida testata. (Rubin & Imbens 2015, 257–265.)

Vaatimuksella sekoittamattomuudesta on kuitenkin myös varsin intuitiivinen perusta. Kun kiinnitetään jokin tietty kovariaattimuuttujan  $X$  arvo johonkin tiettyyn arvoon  $x$ , saadaan vertailtavista yksilöistä ainakin pykälän verran samankaltaisemmat. Esimerkiksi jos haluamme tutkia jonkin koulutuksen vaikutuksia henkilön tuleviin ansioihin, olisi tutkimus toteutettava siten, että henkilö A (joka saa koulutuksen) ja henkilö B (joka ei saa koulutusta) olisivat mahdollisimman samankaltaisia ominaisuuksiltaan. Jos henkilö A on 45-vuotias pitkäaikaistyötön, joka on suorittanut ainoastaan peruskoulun ja henkilö B on 30-vuotias työssä oleva korkeakoulutettu, eivät yksilöt ole tutkimuksessa ominaisuuksiltaan kovinkaan samankaltaisia. Kun tutkija ei määritä henkilöiden käsittelyä eri koulutuksiin, näiden henkilöiden koulutuksesta saatavat (arvioidut) potentiaaliset ansiot määräävät heidän saamaansa käsittelyä, eli potentiaaliset lopputulokset ja käsittelyn toimeksiannot eivät ole riippumattomia. Teoreettinen tarkastelu kausaalipäätelmästä havaintotutkimusasetelmissä koskeekin pitkälti sitä, kuinka voidaan päästä tilanteeseen, jossa sekoittamattomuus on voimassa. Kuinka voidaan tasoittaa kovariaattien jakaumaa käsittely- ja kontrolliryhmien välillä siten, että kausaalipäätelmä mahdollistuu?

Yksinkertainen ratkaisu olisi vain vertailla sellaisia käsittely- ja kontrolliryhmiä, joissa kovariaatit saavat samat arvot harhan poistamiseksi. Ongelmaksi usein kuitenkin muodostuu se, että jatkuva-arvoisten kovariaattien määrän kasvaessa rajallisella otoksella, tarkasteltavat osapopulaatiot menevät luotettavan kausaalipäätelyn kannalta liian pieniksi. Jatkuva-arvoiset kovariaatit voivat yksinkertaisesti saada liian paljon erilaisia arvoja suhteessa tarkasteltavan otoksen kokoon. Tällöin estimointiin sisältyy huomattavaa epävarmuutta. Usein onkin parempi tasapainottaa kovariaatteja esimerkiksi tasapainottavilla funktioilla, *matching* -menetelmällä sekä estimoinnista erillisellä *design* -vaiheella. (Rubin & Imbens 2015, 266–268.)

Kun yksi vaihtoehto on sisällyttää malliin kaikki relevantit kovariaatit, tasapainottavat funktiot tarjoavat harhan poistamiseen usein paremman ratkaisun. Tasapainottavat funktiot, kuten niin kutsuttu *propensity score* voi olla dimensioltaan ensimmäistä vaihtoehtoa huomattavasti pienempi. (Rubin & Imbens 2015, 266–268.) Formaalisti tasapainottavan funktion olisi täytettävä seuraava ehto:

$$W_i \perp\!\!\!\perp X_i \mid b(X_i), \quad (4.)$$

jossa  $b(X_i)$  viittaa tasapainottavaan funktioon. Tasapainottavat funktiot ovat kovariaateista rakennettuja funktioita, joiden myötä todennäköisyydestä saada käsittely, annettuna kovariaatit, tulee riippumaton suhteessa kovariaatteihin, annettuna tasapainottava funktio. (Rubin & Imbens 2015, 266–268.) Ongelmaksi esimerkiksi *propensity score* kanssa kuitenkin muodostuu se, ettei sen muotoa tunneta. Näin ollen myös *propensity score* on estimoitava. (Rubin & Imbens 2015, 281.)

Rubinin ja Imbensin mukaan regressioperustaiset menetelmät soveltuvat huonosti havaintotutkimusasetelmiin, joissa käsittely- ja kontrolliryhmien kovariaattien jakaumassa voi olla huomattavia eroja. Regressioperustaisten menetelmien hyödyntäminen voikin Rubinin ja Imbensin mukaan johtaa voimakkaaseen ekstrapolointiin. Rubinin ja Imbensin mukaan kausaalipäätelyssä voidaan vaihtoehtoisesti hyödyntää esimerkiksi *model* -perustaista päätelyä tai *weighting*-, *blocking*- tai *matching* -menetelmiä. Näistä *model* -perustaista päätelyä tarkasteltiin jo edellisessä alaluvussa. Sen sijaan *weighting*- ja *blocking* -menetelmät nojaavat vahvasti *propensity score* -estimointiin. Ensin mainitussa *propensity score* voidaan hyödyntää luomalla painot yksiköiden lopputulemien odotusarvolle super-populaatiossa ja lopputulemien keskiarvolle saadussa otoksessa. Jälkimmäisessä sitä voidaan taas hyödyntää ryhmittelemällä yksiköt eräänlaisiin blokkeihin, joissa

yksiköt saavat suurin piirtein samanarvoisia *propensity scoren* arvoja. (Rubin & Imbens 2015, 272–276.)

Yksi vaihtoehtoinen menetelmä on Rubinin ja Imbensin mukaan niin kutsuttu *matching*. Siinä tavoitteena on suoraan verrata toisiinsa sellaisia yksikköjä, jotka saavat täysin samat kovariaattien arvot, mutta eri käsittelyn arvot. Usein joudutaan kuitenkin tilanteeseen, jossa suoria verrokkeja ei ole saatavilla. Esimerkiksi jos havaintoja ei ole löydettävissä riittävästi suhteessa jatkuva-arvoisiin kovariaatteihin. Tällöin joudutaan punnitsemaan eri kovariaatteja toisiinsa. Esimerkiksi jos 45-vuotiaalle pitkäaikaistyöttömälle ja peruskoulupohjaiselle henkilölle ei ole löydettävissä suoraa verrokkaa, saatetaan valita henkilö, joka on 42-vuotias pitkäaikaistyötön sekä peruskoulupohjainen. *Matching* -menetelmässä joudutaan usein turvautumaan jonkinlaiseen etäisyysmittaan, jonka avulla eri käsittelyryhmien yksikköjä sovitetaan toisiinsa suorien verrokkien puuttuessa. (Rubin & Imbens 2015, 275–276, 401–431.)

Havaintotutkimusasetelmissä olisi luotettavan kausaalipäätelyn kannalta suotavaa käydä läpi eräänlainen *design* -vaihe. *Design* -vaiheessa tarkastellaan kovariaattien jakaumaa käsittely- ja kontrolliryhmissä sekä vertaillaan näitä jakaumia. Kovariaattien vertailu käsittely- ja kontrolliryhmissä voidaan suorittaa yksinkertaisella keskiarvon vertailulla keskihajonnalla skaalattuna tai *propensity scoren* jakaumien vertailulla. Jälkimmäinen tapa on myöhemmän kausaalisten vaikutusten estimoinnin kannalta luotettavampi, koska *propensity scorella* on suora viittaus super-populaation kovariaattijakaumaan. *Propensity score* on kuitenkin ensin estimoitava. (Rubin & Imbens 2015, 276–278.)

Tässäkin vaiheessa tavoitteena on aikaansaada kovariaateiltaan mahdollisimman tasapainoinen otos kausaalisten vaikutusten estimoimiseksi. *Design* -vaiheessa onkin tyypillistä rakentaa suuremmasta otoksesta eräänlainen osaotos, jossa kovariaatit ovat jakautuneet tasapainoisemmin. Osaotos voidaan rakentaa esimerkiksi *propensity score* sovituksella tai Mahalanobiksen mitan sovitusmenetelmällä, joissa molemmissa rakennetaan kontrolliotos sovittamalla kontrolliyksikköjä käsiteltyihin yksikköihin. Esimerkiksi ensin mainitussa menetelmässä yksikköjä sovitetaan toisiinsa etäisyysmittana *propensity score* tai jokin sen monotoninen transformaatio. Lisäksi *design* -vaiheeseen saattaa usein kuulua sekoittamattomuusoletuksen tarkastelu. *Design* -vaiheessa lopputulemadata pidetään kuitenkin muusta datasta erillään, jotta se ei häiritse *design* -vaiheen analyysia ja osaotoksen rakentamista. (Rubin & Imbens 2015, 276–278, 337–338.)

## 5 Pearlen DAG -viitekehys

Tilastotiede ja ekonometria eivät suinkaan ole olleet ainoita tieteenaloja, joissa kausaalinen analyysi ja sen kehitystyö ovat aiheuttaneet suurta päänvaivaa. Myös tietojenkäsittelytieteen alalla alettiin kehittämään kausaalisia viitekehyskiä 1900-luvun lopulla. Erityisesti tietojenkäsittelytieteilijä Judea Pearl (1995a, 1995b, 2000) sekä hänen kehittämänsä DAG (Directed Acyclic Graphs) -viitekehys on nostettu esimerkkinä kausaalisesta viitekehuksesta, joka voi vastata kausaalipäättelyn kysymyksiin aivan uudella tavalla.

Graafimalleja oli kehitetty kausaalisten rakenteiden tarkasteluun jo ennen Judea Pearlen DAG -viitekehystäkin. Esimerkiksi Sewall Wright (1921) kehitti jo 1920-luvulla eräänlaista kausaalista graafimalliaan, niin kutsuttua polkuanalyysia, genetiikan tutkimuksiinsa. Myös Jan Tinbergen pyrki havainnollistamaan kausaalisten rakenteiden verkkoja graafeilla, jossa muuttujien välisiä kausaalisia yhteyksiä kytketään toisiinsa nuolien avulla. (Cunningham 2021; Imbens 2022; Matsueda 2012; Tinbergen 1951/2005.) Pearl rakensi kuitenkin systemaattisen kausaalisen viitekehysten bayesilaiseen todennäköisyyslaskennan teoriaan nojaten. Vaikka Pearlen DAG-mallien kausaalinen viitekehys ei ole saanut ekonometrian kontekstissa vielä kovinkaan merkittävää suosiota, on kuitenkin löydettävissä joitakin makroekonometriaan kytkeytyviä tutkimuksia, joissa DAG -malleja on hyödynnetty (ks. esim. Demiralp & Hoover 2003). Lisäksi DAG-mallien kausaalisesta viitekehuksesta ja sen hyödyntämisestä on kirjoitettu varsin paljon (ks. esim. Imbens 2022; Cunningham 2021; Hernán & Robins 2020).

### 5.1 Bayesilaiset verkot

Judea Pearlen kehittämä kausaalinen viitekehys nojaa teoriassaan vahvasti bayesilaiseen päättelyyn. Kausaalisen viitekehysten keskiössä ovat ehdolliset todennäköisyydet sekä niiden avulla tapahtuva päättely. Keskeinen komponentti on ehdollinen todennäköisyys:  $P(A|B)$ , joka viittaa  $A$ :n todennäköisyyteen (tai uskomukseen  $A$ ), kun  $B$  tiedetään varmuudella. Jos  $P(A|B) = P(A)$ , niin  $A$  ja  $B$  ovat tilastollisesti riippumattomia ja merkitään  $A \perp B$ . Lisäksi jos  $P(A|B, C) = P(A|C)$ , niin  $A$  ja  $B$  ovat ehdollisesti riippumattomia, ehdolla  $C$ . Tässä  $C$  on siis jokin kolmas muuttuja sekä ehto, jonka tietäminen muuttaa asetelmaa siten, ettei asian  $B$  oppiminen enää muuta uskomustamme asiasta  $A$ . (Pearl 2000/2009, 1–5.) Ehdollisten todennäköisyyksien määritelmiä uudelleenjärjestelemällä saadaan lisäksi tunnettu Bayesin kaava:


$$P(H|e) = P(e|H)P(H)/P(e),$$

jossa  $H$  viittaa hypoteesiin ja  $e$  viittaa saatuun evidenssiin. Kaava tarjoaa menetelmän käsitellä hypoteesiin  $H$  liittyvää uskomusta, sillä evidenssillä, joka tähän mennessä on saatu. Bayesilaiset filosofit ajattelevat näiden ehdollisten todennäköisyyksien mahdollistavan sofistikoituneen tavan järjestellä inhimillistä tietoa. (Pearl 2000/2009, 1–5.)

Pearlen kausaaliossa viitekehysessä näistä ehdollisista todennäköisyyskomponenteista sekä niistä koostuvista lauseista voidaan tietyin ehdoin rakentaa graafimalleja. Ehdollisissa todennäköisyyskomponenteissa esiintyvät satunnaismuuttujat viittaavat graafeissa esiintyviin solmuihin. Jokainen satunnaismuuttuja voi saada usean eri mahdollisen arvon, joiden realisoitumista merkitään pienillä kirjaimilla. Näin ollen myös jokainen graafissa esiintyvä solmu voi saada usean eri mahdollisen arvon. Näiden graafeissa olevien solmujen välille voidaan lisäksi tietyin ehdoin muodostaa linkkejä, jotka kuvaavat kausaalisia suhteita. Nämä kausaalisia suhteita kuvaavat linkit perustuvatkin myös ehdollisten jakaumien ominaisuuksiin. (Pearl 2000/2009, 6–12.)

Pearlen mukaan, jos kaksi graafin muuttujaa (solmua) ovat kytkeytyneet toisiinsa linkillä, muuttujia kutsutaan *vierekkäisiksi* ja muuttujat ovat toisiinsa *kytketty*. Jos sarja solmuja ja linkkejä muodostaa katkeamattoman reitin, sanotaan reittiä *poluksi* ja jos lisäksi jokainen polun linkki on nuoli, jonka suunta on aina ensimmäisestä solmusta seuraavaan solmuun, sanotaan reittiä *suunnatuksi poluksi*. Näiden graafeissa olevien solmujen välillä olevat linkit voivatkin olla suuntaamattomia tai suunnattuja. Jos kaikki linkit ovat suuntaamattomia, kyseistä graafia kutsutaan yleensä *Markovin verkoksi* (DAG-mallien kontekstissa usein myös *luurangoksi*). Suunnattujen linkkien graafeja kutsutaan kuitenkin yleensä *bayesilaisiksi verkoiksi*. Joissakin graafeissa voi olla kaksisuuntaisia linkkejä, jossa kaksisuuntaiset linkit viittaavat esimerkiksi sekoittaviin tekijöihin. Näiden linkkien suunta, jota merkitään graafissa yleensä nuolilla, määräytyy yleensä joko ajallisten tai kausaalisten järjestysten perusteella. Lisäksi suunnatut graafit voivat pitää sisällään syklejä, joissa sykliä kuvaavat jonkinlaisia palauteprosesseja. (Pearl 2000/2009, 12–14.)

Pearlen DAG (Directed Acyclic Graphs) -mallit keskittyvät kuitenkin tarkastelemaan vain suunnattuja (directed) asyklisiä (acyclic) graafeja. Kuviossa 1. on havainnollistettu kahta yksinkertaista graafia. Graafissa a) on havainnollistettu verkkoa, jossa on sekä suunnattuja että kaksisuuntaisia linkkejä solmujen välillä. Sen sijaan graafissa b) on havainnollistettu suunnattua asyklistä graafia, eli DAG -mallia. (Pearl 2000/2009, 12–14.)



**Kuvio 1. a) Graafi, jossa suunnattuja sekä kaksisuuntaisia linkkejä, b) Suunnattu asyklinen graafi (DAG) (Mukaillen Pearl 2000/2009, 13).**

Ennen siirtymistä bayesilaisten verkkojen oletuksiin ja perustuksiin, on hyödyllistä tarkastella lisää Pearlén käyttämää terminologiaa. Pearl hyödyntää kausaalisisessa viitekehysessään paljon erilaisia sukulaisuuskäsitteitä kuvattaessaan graafeissa vallitsevia relaatioita. Esimerkiksi kuvion 1. graafissa a) muuttuja  $Z$  määritellään muuttujan  $W$  lapseksi. Näin ollen muuttuja  $W$  on muuttujan  $Z$  vanhempi. Muuttujat  $Z$  ja  $X$  ovat molemmat muuttujan  $Y$  vanhempia. Muuttuja  $X$  on taas muuttujan  $Z$  puoliso. Muuttujan  $Y$  esivanhemmat ovat  $Z, X$  sekä  $W$  ja muuttujan  $W$  jälkeläiset ovat  $Z$  ja  $Y$ . Perheeksi kutsutaan sellaisia joukkoja, jotka sisältävät muuttujan itse, sekä hänen vanhempansa. Jos muuttujalla (solmulla) ei ole vanhempia, sitä kutsutaan juureksi. Kytkeyty DAG on puu, jos sen jokaisella muuttujalla on enintään yksi vanhempi ja ketju, jos sen jokaisella muuttujalla on enintään yksi lapsi. Jos graafin kaikki mahdolliset muuttujaparit on kytkeyty toisiinsa, on kyseinen graafi täysi. (Pearl 2000/2009, 12–14.)

Bayesilaiset verkot ovat siis graafeja, jotka kuvaavat muuttujien välillä olevia riippuvuussuhteita, jotka voivat olla luonteeltaan yksinkertaisia tilastollisia yhteyksiä tai jotakin kausaalista. Ne kuvaavat tutkimuksessa tehtäviä kriittisiä oletuksia muuttujien välillä olevista suhteista sekä mahdollistavat tehokkaan tavan tehdä (kausaalisia) päätelmiä. Kausaalisisista bayesilaisista verkoista puhutaan silloin kun voidaan tehdä bayesilaisille verkoille kausaalinen tulkinta. Pearlén mukaan nämä ehdolliset todennäköisyyskomponentit, joista koko kausaalinen viitekehys viimekädessä rakentuu, kätkevät sisälleen paljon tietoa vallitsevista kausaalisisista suhteista. (Pearl 2000/2009, 13–22; Pearl 1995a.) Tarkastellaan seuraavaksi sitä, kuinka näistä ehdollisisista todennäköisyyskomponenteista on mahdollista rakentaa DAG -malleja.

Oletetaan yhteisjakauma  $P = P(x_1, \dots, x_n)$ , jossa on  $n$  dikotomista muuttujaa. Pearlén mukaan on usein taloudellista kuvata yhteisjakauma siten, että jokainen muuttuja riippuu huomattavasti pienemmästä määrästä muita muuttujia. Pearlén mukaan tämä yhteisjakauma kannattaakin dekomponoida useisiin pieniin jakaumiin esimerkiksi graafeja hyödyntäen. Pearlén mukaan tämä yhteisjakauman dekomponointi voidaan toteuttaa tietyin oletuksin. (Pearl 2000/2009, 13–22.) Todennäköisyyslaskennan ketjusäännön mukaan yhteisjakauma  $P(x_1, \dots, x_n)$  voidaan dekomponoida tuloksi  $n$  ehdollisesta jakaumasta:

$$P(x_1, \dots, x_n) = \prod_j P(x_j | x_1, \dots, x_{j-1}). \quad (1.)$$

Lisäksi jos voidaan löytää jonkinlainen joukko muuttujan  $X_j$  *edeltäjiä*, jotka riittävät tavoittamaan  $X_j$ :n kaiken vaihtelun, voidaan Pearlén mukaan kirjoittaa:

$$P(x_j | x_1, \dots, x_{j-1}) = P(x_j | pa_j), \quad (2.)$$

jossa joukko  $PA_j$  viittaa muuttujan  $X_j$  *Markovin vanhempiin*, jonka ehdolla muuttuja  $X_j$  on riippumaton sen kaikista muista *edeltäjä* muuttujista. (Pearl 2000/2009, 13–22; Pearl 1995a.) Pearlén mukaan joukko  $PA_j$  kuvataan graafeissa siis muuttujan  $X_j$  *vanhempina*. Kaikki muut muuttujat jäisivät graafissa redundanteiksi, kun  $PA_j$ :n arvot  $pa_j$  on tunnettu. Kun lisäksi voidaan kirjoittaa (yhtälöstä 2. käyttäen ketjusääntöä uudelleen):

$$P(x_1, \dots, x_n) = \prod_i P(x_i | pa_i), \quad (3.)$$

jossa esimerkiksi kuvion 1. b) tapauksessa:

$$P(x, y, z, w) = P(w|z)P(z)P(y|z)P(x|y, z),$$

niin DAG  $G$  on sopusoinnussa (*Markov yhteensopiva*) yhteisjakauman  $P(x_1, \dots, x_n)$  kanssa ja  $G$  representoi yhteisjakaumaa. (Pearl 2000/2009, 13–22; Pearl 1995a.) Pearlén mukaan muuttujien väliset riippumattomuudet voidaan sulkea DAG -mallista pois niin kutsutulla *d-separaatio* -kriteerillä. Sen avulla voidaan testata, onko esimerkiksi muuttuja  $X$  riippumaton muuttujasta  $Y$ , jos on lisäksi tietoa jostakin muuttujasta  $Z$ . Pearlén mukaan graafin  $G$  polku  $p$  on *d-separoitu* jollakin muuttujajoukolla  $Z$ , jos ja vain jos polussa  $p$  on *ketju*  $i \rightarrow m \rightarrow j$  tai *haarukka*  $i \leftarrow m \rightarrow j$ , siten että, solmu  $m$  kuuluu joukkoon  $Z$  tai polussa on *käänteinen haarukka* tai *kollideri*  $i \rightarrow m \leftarrow j$ , siten että, solmu  $m$  tai mikään sen *jälkeläinen* ei kuulu joukkoon  $Z$ . *D-separaatio* toimii siis päinvastoin *haarukan* ja *käänteisen haarukan (kolliderin)* tapauksissa. (Pearl 2000/2009, 13–22; Pearl 1995a.)

Jos muuttujat (tai muuttujajoukot)  $X$  ja  $Y$  ovat *d-separoituja* muuttujalla (tai muuttujajoukolla)  $Z$ , niin  $X$  on riippumaton  $Y$ :stä jokaisessa DAG  $G$ :n kanssa yhteensopivassa jakaumassa ehdolla  $Z$ . Toisaalta jos muuttujat eivät ole *d-separoituja*  $Z$ :lla DAG  $G$ :ssä, niin  $X$  ja  $Y$  ovat ehdolla  $Z$  riippuvaisia toisistaan melkein kaikissa  $G$ :n kanssa yhteensopivissa jakaumissa. *D-separaation* idea perustuu ehdollistamiseen keskimmäisellä muuttujalla tai solmulla kahden muuttujan välissä. Pearlén mukaan ehdollistaminen ikään kuin tukkii informaation kulkua polulla. (Pearl 2000/2009, 13–22.) *D-separaatiota* voisi verrata Rubinin kausaalisen viitekehyksen sekoittamattomuuskriteeriin (2015) sekä Lechnerin (1999) ja Angristin sekä Pischken (2009) käyttämään ehdolliseen riippumattomuusoletukseen.

Kun lisäksi DAG  $G$  täyttää niin kutsutun *järjestetyn Markovin ehdon* (Ordered Markov Condition) sekä niin kutsutun *paikallisen Markovin ehdon* (local/parental Markov condition<sup>3</sup>), voidaan yhteisjakaumaa  $P$  pitää *Markovin sukulaisena* DAG  $G$ :lle. Ehdot eroavat toisistaan vain hieman, mutta hieman vahvemman ehdon, *paikallisen Markovin ehdon* mukaan, jokaisen muuttujan täytyy olla riippumaton kaikista sen *ei-jälkeläisistä*  $G$ :ssä ehdolla sen omat *vanhemmat*. Nämä ehdot kuitenkin seuraavat *D-separaatiosta*. Lisäksi *D-separaatiosta* seuraa niin kutsuttu havainnollinen vastaavuus, jossa kaksi DAG -mallia vastaavat havainnollisesti toisiaan, jos ja vain jos niillä on samat *luurangot* sekä *v-rakenteet*. (Pearl 2000/2009, 13–22.)

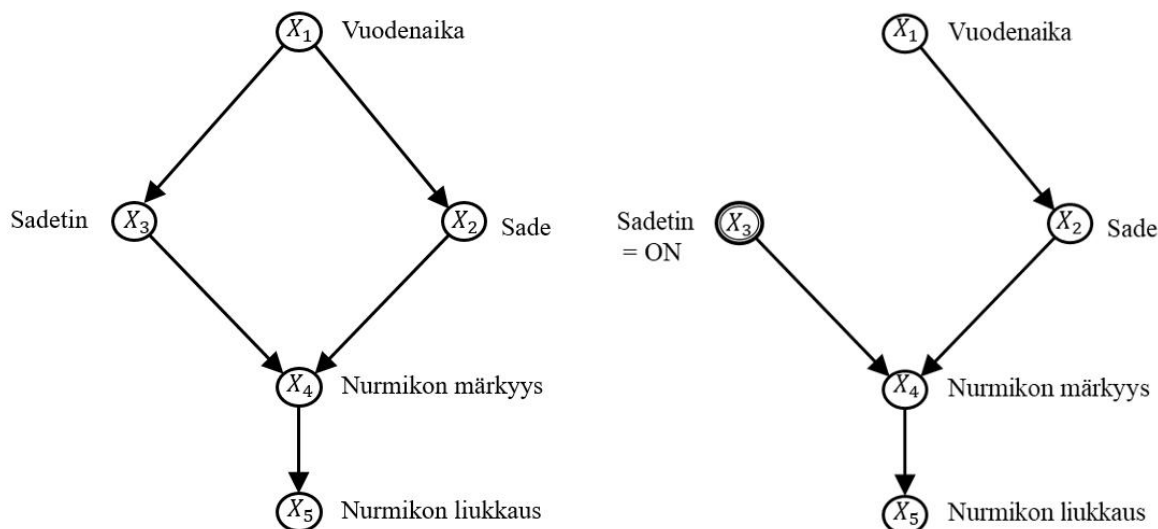
## 5.2 Kausaaliset bayesilaiset verkot ja Do -laskenta

Jotta bayesilaisille verkoille saataisiin kausaalinen tulkinta, Pearlén mukaan verkot olisi rakennettava oletettujen kausaalisten suhteiden pohjalta. Lisäksi niiden käyttö kausaalissa analyysissä vaatii interventioiden suorittamisen mahdollisuutta. Pearlén mukaan DAG -malliin on voitava tehdä ulkoisia interventioita, jotta pääsemme tarkastelemaan erilaisten päätösten aikaansaamaa kausaalista vaikutusta. Nämä ulkoiset interventiot ovatkin Pearlén DAG-mallien kausaalisen analyysin keskiössä. Niiden avulla analyysin ei tarvitse perustua yksinkertaiseen mallin sisäiseen bayesilaiseen todennäköisyyslaskentaan, vaan voidaan tarkastella, kuinka tapahtumien todennäköisyydet muuttuisivat ulkoisten muutosten seurauksena. Interventiot perustuvat verkoissa vallitsevien *lapsi-vanhempi* relaatioiden autonomisuuteen sekä vakauteen. Jos jotakin relaatiota manipuloidaan ulkoisesti, muut relaatiot pysyvät ennallaan. (Pearl 2000/2009, 21–26.) Tätä voikin

---

<sup>3</sup> Pearl käyttää käsitteitä *Parental Markov Condition* ja *Local Markov Condition* synonyymeina ja loogisesti ekvivalentteina (ks. Pearl 2000/2009, 19).

verrata Haavelmon kausaalisen viitekehysten rakenteellisten yhtälöiden autonomisuuteen muista rakenteellisista yhtälöistä. Käytetään seuraavaa Pearl'n esimerkkiä havainnollistamaan verkoissa tapahtuvia interventioita:



**Kuvio 2. Graafi ilman ulkoista interventiota ja graafi ulkoisella interventiolla (Mukailleen Pearl 2000/2009, 15–23).**

Kuviossa 2. oletamme viiden muuttujan (solmun) kausaalisen bayesilaisen verkon, jossa  $X_1$  viittaa vuodenaikaan,  $X_2$  viittaa sateeseen,  $X_3$  viittaa sadettimeen,  $X_4$  viittaa nurmikon märkyyteen ja  $X_5$  viittaa nurmikon liukkauteen. Vasemmanpuoleisessa kuviossa havainnollistetaan tätä kausaalista bayesilaista verkkoa, johon ei ole tehty ulkoista interventiota ja oikeanpuoleisessa kuviossa ulkoisen intervention myötä sadettaja on laitettu päälle. On kuitenkin huomattava, ettei vasemmanpuoleisessa kuviossa ole täsmennetty, että sadettaja olisi myöskään poissa päältä. Vasemmanpuoleisessa kuviossa ei yksinkertaisesti ole määritelty interventiota eikä verkolle ole tehty minkäänlaista ulkoista manipulaatiota. Edellä oleville bayesilaisille verkoille on löydettävissä yhteensopivat yhteisjakaumat. Vasemmanpuoleisen graafin kanssa sopusoinnussa olevaa yhteisjakaumaa voidaan kuvata lausekkeella:

$$P(x_1, x_2, x_3, x_4, x_5) = P(x_1)P(x_2|x_1)P(x_3|x_1)P(x_4|x_2, x_3)P(x_5|x_4).$$

Sen sijaan intervention alaisen oikeanpuoleisen graafin kanssa sopusoinnussa olevaa yhteisjakaumaa voidaan kuvata seuraavalla Pearl'n notaatiolla:

$$P_{X_3=On}(x_1, x_2, x_4, x_5) = P(x_1)P(x_2|x_1)P(x_4|x_2, X_3 = On)P(x_5|x_4).$$

Graafeista huomataan, että oikeanpuoleisessa intervention alaisessa graafissa linkki muuttujien  $X_1$  ja  $X_3$  välillä on poistunut. (Pearl 2000/2009, 21–26.) Tämän linkin poistumisen taustalla on ajatus siitä, että mikä tahansa suhde muuttujien välillä aikaisemmin vallitsi, se suhde on nyt intervention tai toiminnan myötä kadonnut. Sadettaja on nyt joka tapauksessa päällä, vuodenaikasta riippumatta. Uusi mekanismi määrää nyt sadettajaa. Samalla uuteen yhteisjakaumaa kuvaavaan lausekkeeseen on ilmestynyt merkintä  $X_3 = On$ . Pearl käyttääkin uudenlaista notaatiota kausaalisen viitekehyksensä kontekstissa. Tässä  $X_3 = On$  viittaakin nyt Pearlen käyttämään *Do*-laskentaan. Tässä kohtaa on tehtävä ero *toiminnan*  $Do(X_3 = On)$  sekä *ehdollistamisen*  $P(x_1, x_2, x_3, x_4|X_3 = On)$  välille. Kun kyseessä on *toiminta* Pearlen mallin kontekstissa, graafimalliin on tehty interventio, jossa linkki muuttujien välillä on poistettu ja muuttujan arvo on määrätty ulkoisesti. Ehdollistamisessa on kyse ainoastaan havaitsemisesta  $X_3 = On$  (voidaan päätellä, että sadettaja on päällä, koska kyseessä on kuiva vuodenaika). (Pearl 2000/2009, 21–26.)

Formaalisti kausaalisen bayesilaisen verkon yhteensopivuus todennäköisyysjakaumafunktion  $P(v)$  kanssa määritellään kolmen ehdon tai rajoitteen avulla. Jos  $V$  viittaa yhteisjakauman muuttujiin,  $P_x(v)$  viittaa edelliseen jakaumaan, johon on tehty interventio  $Do(X = x)$  ja  $\mathbf{P}_*$  viittaa kaikkiin mahdollisiin interventiojakaumiin  $P_x(v)$ ,  $X \subseteq V$ , niin DAG  $G$  on  $\mathbf{P}_*$ :n kanssa sopusoinnussa oleva kausaalinen bayesilainen verkko, jos ja vain jos jokaiselle  $P_x \in \mathbf{P}_*$  pätee (Pearl 2000/2009, 23–24):

- (i)  $P_x(v)$  on *Markovin sukulainen* DAG  $G$ :lle,
- (ii)  $P_x(v_1) = 1$  kaikille  $V_i \in X$  silloin kun  $v_1$  on yhteensopiva  $X = x$  kanssa, ja
- (iii)  $P_x(v_i|pa_i) = P(v_i|pa_i)$  kaikille  $V_i \notin X$  silloin kun  $pa_i$  on yhteensopiva  $X = x$  kanssa (eli  $P(v_i|pa_i)$  säilyy muuttumattomana sellaisille interventioille, jotka eivät sisällä  $V_i$ :tä).

Pearlen (2000/2009) mukaan näiden ehtojen tai rajoitteiden vallitessa voidaan mikä tahansa intervention alainen jakauma  $P_x(v)$ , jossa  $Do(X = x)$ , kirjoittaa *katkaistuna faktorisaationa* (truncated factorization):

$$P_x(v) = \prod_{\{i|V_i \notin X\}} P(v_i|pa_i) \quad (4.)$$

jokaiselle  $x$  kanssa sopusoinnussa olevalle  $v$ :lle. Lisäksi ehtojen myötä jokaisesta joukosta  $PA_i$  muodostuu eksogeeninen suhteessa sen *lapsiin* eivätkä mitkään muut interventiot vaikuta todennäköisyyteen  $V_i$ , jos suorat syyt  $PA_i$  ovat kontrolloitu. (Pearl 2000/2009, 23–24.)

### 5.3 Kausaalipäätely DAG -malleissa

Kausaalisten bayesilaisten verkkojen rakentamiselle on kehitetty useita hyödyllisiä algoritmeja, jotka perustuvat ehdollisiin todennäköisyyksiin ja vaatimuksiin mallin minimaalisuudesta sekä suhteiden vakaudesta (Pearl 2000/2009, 41–67). Kausaalisia bayesilaisia verkkoja on kuitenkin mahdollista ja perusteltua rakentaa joskus myös perustuen pelkkään subjektiiviseen ymmärrykseen syy-seuraussuhteista. Esimerkiksi subjektiivisen ymmärryksen perusteella muodostetut tai algoritmien avulla rakennetut bayesilaiset verkot ja DAG -mallit mahdollistavat kausaalipäätelyn suorittamisen *Do* -laskentaan perustuen. Kausaalipäätely bayesilaisilla verkoilla ja DAG -malleilla käsittää kuitenkin varsin laaja-alaisen joukon erilaisia menetelmiä ja poikkeustapauksia. Näin ollen tässä tutkielmassa on mahdollista tarkastella ainoastaan perusteet DAG -viitekehyksen mahdollistamasta kausaalipäätelystä.

Tarkastellaan seuraavaksi kausaalisten vaikutusten identifiointia DAG -mallien kausaalissa viitekehysessä. Kuten aikaisemmasta alaluvusta nähtiin, interventioiden alaiset jakaumat on mahdollista saavuttaa *katkaistulla faktorisaatio* -yhtälöllä niistä jakaumista, jotka eivät ole intervention alaisia. Tämä yhtälö mahdollistaakin kausaalisten vaikutusten identifioinnin ja estimoinnin eri interventioista. (Pearl 2000/2009, 70–73.) Pearlén kausaalisen viitekehyksen kausaaliset vaikutukset voidaan ajatella ehdollisten odotusarvojen erotuksena keskimääräisenä käsittelyvaikutuksena eri interventioista  $Do(X = x')$  ja  $Do(X = x'')$  (Pearl 2000/2009, 70–73):

$$\mathbb{E}(Y|Do(x')) - \mathbb{E}(Y|Do(x'')), \quad (5.)$$


jotka voidaan kirjoittaa hyödyntäen funktiota  $P(y|Do(x))$ . Intervention  $Do(X_i = x'_i)$  vaikutukseen suhteessa muuttujaan  $Y$  päästään taas käsiksi Pearlén mukaan seuraavalla yhtälöllä (Pearl 2000/2009, 70–73):

$$P(y|\hat{x}'_i) = \sum_{pa_i} P(y|x'_i, pa_i)P(pa_i), \quad (6.)$$

jossa  $P(y|x'_i, pa_i)$  ja  $P(pa_i)$  viittaavat jakaumiin ennen interventiota (Pearl 2000/2009, 70–73). Ehdollisten odotusarvojen erotus onkin samaistettu kausaaliseen vaikutukseen myös muissa kausaalissa viitekehysissä, kuten Rubinin mallin viitekehysessä (Rosenbaum & Rubin 1983). Pearlén kausaalinen viitekehys tarjoaa erityisesti havaintotutkimusasetelmiin varsin hyödyllisiä työkaluja kausaalipäätelyä ajatellen.

Kuten muistamme myös Rubinin mallin kausaalista viitekehystä, havaintotutkimusasetelmien suurin huolenaihe liittyy vaatimukseen sekoittamattomuudesta. Pearlén DAG -mallien viitekehyksessä sekoittavat tekijät voivat myös asettua suureksi ongelmaksi. Sekoittavien tekijöiden sekoittavaa vaikutusta on kuitenkin mahdollista kontrolloida erilaisin menetelmin, esimerkiksi regressiomallissa lisäämällä kovariaatteja estimoitavaan malliin (ks. esim. Cunningham 2021). Pearlén DAG-mallien viitekehys tarjoaa kuitenkin myös ratkaisun siihen, kuinka nämä kovariaattimuuttujat tulisi valita.

Pearlén mukaan niin kutsuttu *takaovikriteeri* on keskeinen vaatimus kausaalisten vaikutusten identifioinnissa. Pearlén mukaan takaovikriteeri tarjoaa menetelmän valita malliin sellaiset kovariaattimuuttujat, joiden avulla on mahdollista irrottaa kausaalinen vaikutus sekoittavista tekijöistä. Formaalisti takaovikriteeri määritellään siten, että muuttujat  $Z$  toteuttavat takaovikriteerin järjestetylle muuttujaparijoukolle  $(X_i, X_j)$  DAG  $G$ :ssä jos: i) mikään muuttujajoukon  $Z$ :n solmu ei ole muuttujan  $X_i$  jälkeläinen ja ii)  $Z$  tukkii jokaisen polun  $X_i, X_j$  välillä, joissa nuoli kohdistuu muuttujaan  $X_i$ . Kriteerin nimi viittaa erityisesti jälkimmäiseen ehtoon, joka vaatii ainoastaan sellaisten polkujen kontrollointia, joissa nuoli kohdistuu solmuun  $X_i$ . (Pearl 2000/2009, 79–80.)



**Kuvio 3. Graafi ja takaovikriteeri (Mukaillen Pearl 2000/2009, 80).**

Kuviossa 3. on havainnollistettu Pearlén takaovikriteeriä. Jos tavoitteena on estimoida kausaalista vaikutusta muuttujasta  $X_i$  muuttujaan  $X_j$ , niin muuttujat  $X_3$  ja  $X_4$  tai muuttujat  $X_4$  ja  $X_5$  olisi kontrolloitava. Tukkimalla informaatiovirran muuttujista  $X_3$  ja  $X_4$ , eli esimerkiksi sisällyttämällä ne estimoitavaan regressiomalliin, identifioisi kausaalisen vaikutuksen muuttujasta  $X_i$  muuttujaan  $X_j$ . Takaovikriteerin lisäksi Pearl on kehittänyt myös etuovikriteerin täydentämään takaovikriteeriä. Pearlén etuovikriteerin mukaan, jos muuttujat  $X_1, X_2, X_3, X_4, X_5$  olisivat havaitsemattomia, niin

hyödyntämällä muuttujan  $X_6$  informaatiota, kausaalinen vaikutus muuttujasta  $X_i$  muuttujaan  $X_j$  olisi tietyin ehdoin identifioitavissa. (Pearl 2009/2009, 79–82; Cunningham 2021.)

## 6 Pohdinta

Tässä tutkielmassa on käsitelty kolmea hyvin erilaista kausaalista viitekehystä sekä niiden avulla tapahtuvaa kausaalipäättelyä. Kausaalisisissa viitekehyksissä sekä niiden avulla tapahtuvalla kausaalipäättelyllä on huomattavia eroavaisuuksia, mutta niistä on löydettävissä myös merkittäviä yhtymäkohtia. Kausaaliset viitekehukset vastaavat kausaalisiin kysymyksiin myös monilta osin eri tavalla. Tässä luvussa käsitellään merkittävimmät eroavaisuudet ja yhtäläisyydet tutkielmassa käsitellyistä kausaalisisista viitekehyksistä sekä niiden pohjalta tapahtuvasta kausaalipäättelystä. Lisäksi tässä luvussa pohditaan sekä vertaillaan kausaalisten viitekehysten vahvuuksia ja heikkouksia suhteessa kausaalisten viitekehysten perustuksiin ja kausaalipäättelyyn.

Ensin on kuitenkin tehtävä tietty käsitteellinen ero, jota tässä tutkielmassa ei ole aikaisemmin vielä kovinkaan tarkkaan käsitelty. On tehtävä ero kausaalisten mekanismien ja kausaalisten vaikutusten välille. Kausaaliset mekanismit viittaavat taustalla vallitseviin rakenteisiin tai kausaalisiin suhteisiin, joiden puitteissa esimerkiksi koko fyysikaalinen tai taloudellinen maailma toimii. Kausaalisten viitekehysten ja kausaalimallien kontekstissa nämä kausaaliset mekanismit yleensä oletetaan ensin *a priori*. Vaikka mekanismien mallintamiseen on kehitetty myös tehokkaita algoritmeja (ks. esim. Pearl 2000/2009, 41–67; Ahrens et al. 2021), on mekanismit sekä niissä olevat rakenteet ja kausaaliset suhteet, kuitenkin aina ensin tavalla tai toisella oletettava (ks. esim. Keane 2010; Deaton 2010). Oletukset voivat ekonometrian kontekstissa perustua esimerkiksi talousteoriaan. Sen sijaan kausaaliset vaikutukset ovat jossain määrin rakenteita vähemmän pysyviä. Kausaaliset vaikutukset kytkeytyvät mahdollisiin tai potentiaalisiin skenaarioihin, tai niiden lopputulemiin, sekä niistä laskettuihin suhteisiin.

James Heckmanin ja Rodrigo Pinton mukaan (2024) kausaalisisessa analyysissa on kolme vaihetta: mallin rakentaminen, kausaalisten parametrien identifiointi sekä estimointi. Kausaaliset mekanismit oletetaan ja määritetään niin sanotussa mallin rakennusvaiheessa. Kausaaliset vaikutukset määritetään sen sijaan kausaalisen analyysin identifiointi- ja estimointivaiheessa. Heckmanin ja Pinton mukaan identifiointivaiheessa kausaaliset parametrit identifioidaan hypoteettisista populaatioista todennäköisyyslaskennan teoriaan nojaten. Lopuksi kausaaliset parametrit voidaan estimoida todellisesta datasta. Kausaalisten parametrien osuus kausaalisisessa analyysissa on mielenkiintoinen kokonaisuus, joka luo siltaa kausaalisten mekanismien määrittämisen ja kausaalisten vaikutusten estimoinnin välille. (Heckman & Pinto 2024.) Tässä tutkielmassa ei kuitenkaan tarkastella näiden kausaalisten parametrien ja niiden identifioimisen filosofiaa kovinkaan tarkasti.

## 6.1 Kausaalisista mekanismeista

Tutkielmassa tarkastelluista kausaalisista viitekehysistä löytyy huomattavia eroja erityisesti Heckmanin määrittämän kausaalisen analyysin ensimmäisen vaiheen osalta. Kausaalisista viitekehysistä on löydettävissä huomattavia eroavaisuuksia sen suhteen, kuinka paljon niissä painotetaan kausaalisten mekanismien määrittämistä ja kausaalisia mekanismeja koskevia oletuksia. Haavelmon sekä myöhemmin Heckmanin ja Pinton muotoilema rakenteellisten mallien kausaalinen viitekehys korostaakin viitekehysistä kaikista eniten kausaalisten mekanismien määrittämistä sekä niitä koskevien oletuksien esille tuomista. Heidän kausaalisen analyysinsä perustukset koostuvatkin rakenneyhtälöistä, joita voisi helposti kuvailla taloudellisen maailman lainalaisuuksiksi. Välillä rakenneyhtälöihin sisällytetään tosin myös stokastisia komponentteja, jolloin niitä ei voida tulkita kuitenkaan puhtaan deterministisiksi.

Myös Pearlen DAG -mallien kausaalinen viitekehys korostaa taustalla vaikuttavien kausaalisten mekanismien määrittämistä sekä kausaalisia mekanismeja koskevia oletuksia. Pearlen DAG -mallien kausaalisten mekanismien määrittämiselle on lisäksi kehitetty monia hyödyllisiä ja tehokkaita algoritmeja (ks. esim. Pearl 2000/2009, 41–67). Pearlen DAG -mallien kausaaliset mekanismit eroavat Haavelmon, Heckmanin ja Pinton kausaalisista mekanismeista kuitenkin indeterministisemmän luonteensa osalta. Mekanismit kuvataan DAG -malleissa graafeina, mutta graafien perustana ovat kuitenkin ehdollisten todennäköisyyksien yhteisjakaumat. DAG -mallien sisältämät linkit eri solmujen välillä ovat pohjimmiltaan ehdollisia todennäköisyyksiä. Näin ollen Pearlen DAG -mallien mallintamia kausaalisia mekanismeja ei voida myöskään tulkita deterministisiksi.

Rubinin kausaalinen viitekehys korostaa tässä tutkielmassa käsitellyistä kausaalisista viitekehysistä vähiten kausaalisten mekanismien määrittämistä sekä kausaalisia mekanismeja koskevia oletuksia. Rubinin viitekehys eroaa tässä suhteessa merkittävästi muista kausaalisista viitekehysistä. Rubinin viitekehyksessäkin tehdään vahvoja oletuksia, mutta ne koskevat kuitenkin erityisesti viitekehyksessä oletettua jakomekanismia sekä SUTVA -ehtoja. Jakomekanismi voi tosin kertoa jotain myös taustalla vaikuttavista kausaalisista mekanismeista, mutta kuitenkin vain hyvin rajoitetusti. Jakomekanismilla kuitenkin viitataan abstraktiin mekanismiin, joka määrittää, mitkä yksiköt saa minkäkin käsittelyn ja mitkä potentiaaliset lopputulokset yksiköille lopulta realisoituvat

(Rubin & Imbens 2015, 13–15). Kausaaliset mekanismit determinoivatkin myös tätä yksiköiden käsittelyiden määräytymistä ja potentiaalisten lopputulosten realisoitumista.

Kausaalisten mekanismien määrittäminen ja mallintaminen voi koostua pelkästään endogeenisia-, eksogeenisia- ja havaitsemattomia muuttujia sekä virhetermejä koskevista valinnoista, mutta yleensä joudutaan tekemään myös funktionaaliin muotoihin liittyviä vahvoja oletuksia. Aina ei myöskään mallinneta kokonaista rakenteellisten yhtälöiden yhtälöjärjestelmää, vaan tyydytään vain yhteen keskeiseen kausaaliseen relaatioon. Jonkinlaisia oletuksia kausaalisesta mekanismista on kuitenkin tehtävä viimeistään estimointivaiheessa. Kausaalisia mekanismeja koskeva osuus kausaalisesta analyysistä onkin Haavelmon, Heckmanin ja Pinton kausaalisen viitekehyksen ja DAG - viitekehyksen merkittävin vahvuus. Rakennemalleja puolustetaan myös usein sillä, että niissä tehdyt oletukset ovat läpinäkyvämpiä ja selkeämmin muotoiltuja (ks. esim. Low & Meghir 2017).

Jotkut ekonometrian tutkijat näkevät vahvat oletukset vahvuutena, mutta toiset taas heikkoutena. Niin kutsutun uskottavuuden vallankumouksen myötä erityisesti soveltavassa kausaalipäätelyssä vahvat rakenteelliset oletukset ovat saaneet myös kritiikkiä. Monet soveltavan ekonometrian tutkijat ajattelevatkin, että esimerkiksi instrumenttimuuttujamenetelmä riittää rakenteellisten ekonometrian mallien huomioimien ilmiöiden, kuten simultaanisen kausaalisuuden analysointiin. (Keane 2010; Blundell 2010; Deaton 2010.) Heckmanin ja Pinton mukaan simultaanista kausaalisuutta ei voida kuitenkaan käsitellä esimerkiksi Rubinin viitekehyksessä SUTVA -ehtoja rikkomatta (Heckman 2024).

Jotta kausaalisen analyysin uskottavuus sekä epistemologinen oikeutus säilyisi, olisi tavalla tai toisella määritetyn kausaalisen mekanismin myös representoitava todellisuudesta löytyviä kausaalisia suhteita. Välillä rakenteelliset mallit ja DAG -mallit rakennetaankin perusteettomille oletuksille. Usein parhaan mahdollisen kuvauksen aikaansaamiseksi on kuitenkin tyydyttävä valistuneeseen ymmärrykseen esimerkiksi taloudellisista ja institutionaalisista olosuhteista. Tässä kohtaa niin talousteoreettinen valistuneisuus kuin myös historian, yhteiskuntatieteiden, psykologian ja monista muistakin tieteistä koostuvan ymmärryksen rooli on keskeisessä osassa.

## 6.2 Kausaalisista vaikutuksista

Kausaalisten vaikutusten määrittämisen osalta tutkielmassa käsitellyt viitekehykset eroavat toisistaan jonkin verran, mutta kaikissa esiintyy kuitenkin sama perustavanlaatuinen ajatus. Kaikissa viitekehysissä kausaalisten vaikutusten määrittäminen perustuu tavalla tai toisella hypoteettisten skenaarioiden tai kontrafaktuaalien olemassaoloon. Kausaaliset vaikutukset viittaavat kausaalisten viitekehysten kontekstissa aina eri hypoteettisten skenaarioiden välillä oleviin suhteisiin.

Kausaaliset vaikutukset edellyttävät aina jonkinlaisen vaihtoehdon tai kontrafaktuaalin olemassaoloa. Jos jokin ilmiö kehittyy loogisella välttämättömyydellä, ilman vaihtoehtoa, jollakin tavalla, jonka lopputulos on A, ei kausaalista vaikutusta ole mahdollista määrittää. Sen sijaan, jos jokin ilmiö olisi voinut kehittyä tavalla A ja tavalla B, ainakin edes hypoteettisesti, voidaan kausaalinen vaikutus määrittää näiden kahden eri skenaarion lopputuloksen erotuksena.

Käytännössä skenaarioiden lopputulemat esitetään kuitenkin odotusarvo-operaattorin avulla. Odotusarvo kytketään kausaalisessa ajattelussa usein jonkinlaiseen äärettömästä populaatiosta määritettyyn suureeseen, esimerkiksi Rubinin viitekehyksessä super-populaatiosta määritettyyn kuvitteelliseen suureeseen. Odotusarvon estimoitu vastine on keskiarvo, jonka estimointiin kausaalipäätelyssä usein pyritään. Rubinin viitekehyksessä kausaalinen vaikutus identifioidaankin keskimääräisenä käsittelyvaikutuksena samalle yksikölle (Rosenbaum & Rubin 1983)

$$\mathbb{E}(Y_i(1)) - \mathbb{E}(Y_i(0)),$$

Haavelmolla, Heckmanilla ja Pintolla keskimääräisenä kausaalisena vaikutuksena eri hypoteettisilla kiinnitetyillä arvoilla (Haavelmo 1944; Heckman & Pinto 2015)

$$\mathbb{E}_{(U, \epsilon_Y)}(Y(x)) - \mathbb{E}_{(U, \epsilon_Y)}(Y(x')),$$

sekä Pearlilla ehdollisten odotusarvojen erotuksena keskimääräisenä käsittelyvaikutuksena eri interventioista *Do* -operaatiota hyödyntäen (Pearl 2000/2009, 70–73)

$$\mathbb{E}(Y|do(x')) - \mathbb{E}(Y|do(x'')).$$

Kaikki edellä esitetyt kausaalisten vaikutusten määritelmät nojaavat jonkinlaiseen odotusarvojen erotukseen kahden erilaisen skenaarion lopputulemasta. Merkittävin ero niissä koskee sitä, mitä odotusarvo-operaatio sisältää. Rubinin viitekehyksessä odotusarvo määritetään samalta datassa olevalta yksiköltä, kun yksikölle tehdään kaksi erilaista käsittelyä. Haavelmon, Heckmanin ja Pinton viitekehysessä ei kausaalisten vaikutusten määrittämisen osalta viitata mihinkään

yksikköön, vaan kausaalinen vaikutus määritetään hypoteettisesti varioimalla jotakin yhtälön tai yhtälöjärjestelmän panosuuttujaa varioinnin aiheuttaessa muutosta tuotosmuuttujiin. Itse variointi tai manipulointi tapahtuu Haavelmon, Heckmanin ja Pinton viitekehyksessä datasta riippumatta ja aiheuttaa muutoksen tuotosmuuttujiin myös datasta riippumatta. Datan rooli kausaalisen vaikutuksen määrittelemiselle paljastuu vasta datasta määritetyn *kausaalisen parametrin* avulla, joka liittyy hypoteettisesti manipuloituihin muuttujiin. Haavelmon, Heckmanin ja Pinton viitekehyksessä on keskeistä ymmärtää tämän kausaalisen parametrin vakioisuus ja autonomisuus sekä riippumattomuus muuttujien manipuloinnista (Haavelmo 1944; Heckman & Pinto 2015; Heckman & Pinto 2024). Rubinin viitekehyksessä kausaalilla parametrilla ei ole samanlaisia ominaisuuksia.

Pearlen DAG -mallien viitekehyksessä kausaalinen vaikutus määritetään myös eräänlaisen manipulaation tai intervention toteuttamisen avulla. Interventio toteutetaan DAG -mallien viitekehyksessä rakennetulle kausaalille bayesilaiselle verkolle *Do* -laskennan sääntöjä noudattaen. Tällä onkin yhtäläisyyksiä erityisesti Haavelmon, Heckmanin ja Pinton viitekehykseen, jossa interventio toteutetaan jonkinlaiseen kausaaliseen järjestelmään. On kuitenkin huomattava, että Pearlen DAG -viitekehyksessä intervention tai manipulaation toteuttaminen oikeastaan luo uuden kausaalisen järjestelmän. DAG -mallien *Do* -operaatiossa jokin muuttuja kiinnitetään ulkoisesti johonkin muuttujan mahdolliseen arvoon ja sen *vanhempiin* kytkeytyvät linkit poistetaan. Kun muuttujalle on toteutettu *Do* -operaatio, uusi mekanismi määrittää sen toimintaa. Tässä suhteessa Pearlen viitekehys kuitenkin eroaa Haavelmon, Heckmanin ja Pinton viitekehyksestä. Haavelmon, Heckmanin ja Pinton viitekehyksessä kausaalista järjestelmää ei muuteta manipuloinnin seurauksena, vaan järjestelmä pysyy ennallaan manipuloinnin jälkeenkin. Pearlen viitekehyksen kausaalisten vaikutusten määrittäminen eroaa myös Rubinin viitekehyksen kausaalisten vaikutusten määrittämisestä huomattavasti. Myöskään DAG -viitekehyksessä kausaalista vaikutusta määritettäessä ei viitata mihinkään yksikköön, vaan kausaalinen vaikutus syntyy ehdollisten todennäköisyyksien yhteisjakaumaan perustuvan kausaalisen järjestelmän manipuloinnista.

Heckmanin ja Pinton (2024) mukaan Rubinin viitekehyksessä eri kausaalisen analyysin vaiheet sekoittuvat keskenään ja viitekehyksessä keskeisempää on estimointivaihe. Sen sijaan muissa viitekehyksissä kausaalisen mekanismin määrittäminen sekä identifiointivaihe pidetään tarkemmin erillään ja kausaalisen vaikutuksen määrittäminen tapahtuu tilastotieteen ulkopuolella olevilla menetelmillä, kuten *Do*-operaatiolla tai hypoteettisella varioinnilla. (Heckman & Pinto 2024.)

Rubinin kausaaliosessa viitekehysessä kausaalisten mekanismien sivuuttaminen tukisikin tulkintaa, että tavoitteena olisi määrittää kausaalisia vaikutuksia kausaaliosista mekanismeista riippumatta.

Kausaalisten vaikutusten määrittämiseen kytkeytyy myös yksi kausaalisia viitekehysia olennaisella tavalla yhdistävä piirre, johon viitataan yleensä käsitteellä *sekoittavat tekijät*. Jotta syiden aikaansaamat vaikutukset ja niiden suuruus voitaisiin uskottavalla sekä epistemologisesti vahvalla tavalla määrittää, olisi identifiointi- ja estimointivaiheissa otettava huomioon myös muut tekijät, jotka liittyvät sekä syyhyn että vaikutukseen. Kausaalisten viitekehysten kielenkäyttö vaihtelee tässä jonkin verran, mutta kaikissa viitekehysissä tämmöiset sekoittavat tekijät kuitenkin huomioidaan tavalla tai toisella.

Rubinin kausaaliosessa viitekehysessä nämä sekoittavat tekijät nousevat kaikista keskeisimpään rooliin. Rubinin viitekehysessä nämä sekoittavat tekijät liittyvät keskeisellä tavalla jakomekanismin yhteen ominaisuuteen; vaatimukseen sekoittamattomuudesta. Tämä vaatimus sekoittamattomuudesta tai sekoittamattomuuskriteeri on ominaisuus, jonka perusteella jakomekanismeja voidaan jaotella. Se myös Rubinin viitekehysessä määrittää, millaisen tutkimusasetelman tutkija joutuu rakentamaan identifioidessaan ja estimoidessaan kausaalisia vaikutuksia. Sekoittamattomuus on kuitenkin ominaisuus, jota ei voida testata. Sekoittamattomuus nousee suureksi huolenaiheeksi erityisesti RCT (Randomized Controlled Trials) -asetelmien ulkopuolella, niin sanotuissa havaintotutkimuksissa, jossa jakomekanismin tarkka funktionaalinen muoto jää tuntemattomaksi. Huomattava osa Rubinin ja Imbensin kirjoittamasta laajasta teoksesta *Causal Inference for Statistics, Social, and Biomedical Sciences* (2015) käsittelee erilaisia menetelmiä ratkaista tätä sekoittamattomuuskriteeristä nousevaa huolenaihetta.

Haavelmon, Heckmanin ja Pinton (Haavelmo 1944; Heckman & Pinto 2015) kausaaliosessa viitekehysessä nämä sekoittavat tekijät mallinnettiin osaksi empiiristä mallia, joka pyrkii kuvaamaan todellista dataa generoivaa prosessia. Havaitsematon sekoittava tekijä  $U$ , joka liittyy annetun esimerkin rakenteellisessa mallissa kiinnostuksen kohteena olevaan lopputulosmuuttujaan  $Y$  ja selittävään muuttujaan  $X$ , hankaloitti kausaalisen vaikutuksen identifiointia tilanteessa, jossa  $U$ :n ehdollinen odotusarvo ehdolla  $X$  ei ole nolla ja näin ollen  $Y$ :n ehdollinen odotusarvo ehdolla  $X = x$  ei ole  $\mathbb{E}(Y(x))$ . Tällöin autonomisen kausaalisen parametrin määrittäminen vaikeutui. Pearl (2000/2009) DAG -mallien kausaaliosessa viitekehysessä sekoittavat tekijät toimivat myös keskeisessä roolissa. Myös DAG -viitekehysessä sekoittavat tekijät estävät kausaalisten vaikutusten identifioinnin ja estimoinnin. DAG -viitekehysessä takaovikriteeri kuitenkin

mahdollistaa menetelmän, jonka avulla taustalla vaikuttavia sekoittavia tekijöitä voidaan kontrolloida.

### 6.3 Metafyysiset ja epistemologiset perustukset

Lopuksi voidaan pohtia myös kausaalisten viitekehysten metafyysisiä ja epistemologisia perustuksia ja sitä kautta myös tarkastella viitekehysten uskottavuutta. Tutkielmassa käsitellyistä kausaalisisista viitekehysistä Haavelmon, Heckmanin ja Pinton viitekehys nojaa kaikista voimakkaimmin ideaan, jossa kausaalisuus olisi vain mielessä tapahtuva todellisuuden abstraktio. Lopputulosten hypoteettinen vertailu oletetussa kausaalisisessa järjestelmässä ilmentää vahvasti tätä Frischin (2010) kehittämää ideaa. Idealla on myös selkeitä yhtymäkohtia kanttilaiseen (Kant 1997) ajatteluun, jossa kausaliteetti kytkeytyisi ensisijaisesti ymmärryksen tai ajattelun rakenteisiin. Idea voi monelle kuulostaa varsin radikaalille ja harva lieneekin valmis käsittämään kausaliteetin ainoastaan mielen abstraktioksi. Pearlén DAG -mallien kausaalisisessa viitekehyksessä kausaaliset vaikutukset voidaan tulkita pitkälti samalla tavalla, perustuhan kausaalisten vaikutusten määrittäminen siinäkin ensisijaisesti hypoteettisten rakenteiden hypoteettisiin manipulointeihin.

Rubinin kausaalisisessa viitekehyksessä kausaliteetin filosofinen luonne ei ole yhtä selkeä. Viitekehys keskittyy kausaalisten vaikutusten identifiointiin ja estimointiin pyrkimällä pääsemään käsiksi jokaisen yksikön erilaisiin potentiaalsiin lopputulemiin käsittelystatuksen mukaan. Kausaalipäättelyn fundamentaalisen ongelman nimissä viitekehys joutuu kuitenkin tarjoamaan erilaisia ratkaisuja puuttuvan datan ongelmaan, joista yksi ratkaisu on puuttuvan datan simulointi. Kausaalinen vaikutus määritetään kuitenkin eri tavalla verrattuna Haavelmon, Heckmanin sekä Pinton ideaan. Rubinin viitekehyksessä kausaalisten vaikutusten määrittämisen osalta keskeistä on datassa (mahdollisesti simuloitussa) olevat riippuvuussuhteet, eikä hypoteettisen mallin hypoteettinen manipulointi. Tämä tukisi tulkintaa, jonka mukaan Rubinin kausaalisisessa viitekehyksessä pyrittäisiin pääsemään käsiksi mielen abstraktioiden ulkopuolella mahdollisesti oleviin kausaalisiin vaikutuksiin. Jos kausaliteetti on jotain muutakin kuin mielessä tapahtuva todellisuuden abstraktio ja Rubinin viitekehysten pohjalta toteutettu kausaalipäättely perustuu uskottavaan ja epistemologisesti oikeutettuun kausaalisten vaikutusten identifiointiin ja estimointiin, saadaan estimoiduille kausaalisisille vaikutuksille ainakin hieman intuitiivisempi tulkinta verrattuna Frischin ideaan.

## Lopuksi

Kausaaliset viitekehukset voivat johdattaa tutkijan hyvinkin syvälle epistemologian ja teoreettisen ekonometrian rajamaille, jossa kaikki konkretia hämärtyy. Kausaalisten viitekehysten ja kausaalipäätelyn syvälinen tarkastelu on monilta osin monimutkaisten, abstraktien ja filosofisten käsitteiden sekä niiden välillä olevin suhteiden ymmärtämistä ja ajattelun prosessien aikaansaamien tulosten esille tuomista. Kausaaliset viitekehukset kytkeytyvät kuitenkin loppujen lopuksi kausaalipäätelyyn ja sitä kautta esimerkiksi politiikkapäätösten aikaansaamien vaikutusten vaikutusarviointiin.

Jotta päätöksiä tekevät toimijat nojaisivat kaikista valistuneimpiin arvioihin erilaisten päätösten aikaansaamista, odotetuista ja ennustetuista vaikutuksista, kannattaisi heidän kuunnella tutkijoita, joiden analyysi perustuu uskottavaan ja epistemologisesti oikeutettuun kausaaliseen analyysiin. Kausaalisen analyysin ei aina tarvitse perustua tiukkoihin kausaalisten viitekehysten edellyttämiin oletuksiin ja reunaehtoihin. Usein myös kausaalimallien ja kausaalipäätelyn perusteidenkin ymmärtäminen voi riittää. Niukkojen resurssien vallitessa kaikkialla eri yhteiskunnan osa-alueilla talouteen kytkeytyvät vaikutusarviot ovat erittäin keskeisessä roolissa. Tältä osin jokaisen empiiristä taloustiedettä tekevän tutkijan olisikin hyvä ymmärtää ainakin kausaalipäätelyn perusteet.

Tämän tutkielman tavoitteena oli esitellä sekä muotoilla tunnetuimpien ekonometrian alalla hyödynnettyjen kausaalisten viitekehysten käsitteelliset perustukset sekä tarkastella, mihin näiden viitekehysten mahdollistama kausaalipäätely perustuu. Lisäksi tutkielman tavoitteena oli vertailla näiden kausaalisten viitekehysten perustuksia ja niiden mahdollistamaa kausaalipäätelyä. Tutkielman luvut 3.–5. keskittyivät erityisesti esittelemään sekä muotoilemaan näiden kausaalisten viitekehysten perustuksia sekä niiden mahdollistamaa kausaalipäätelyä. Tutkielman luku 6. keskittyi vertailemaan näiden viitekehysten käsitteellisiä perustuksia ja niissä tapahtuvaa kausaalipäätelyä sekä suhteuttamaan kausaalisia viitekehyksiä toisiinsa.

Tutkielma muotoutui kuitenkin varsin tiiviiksi ja teoreettiseksi esitykseksi kausaalista viitekehysistä ja niiden mahdollistamasta kausaalipäätelystä. Tutkielman käsittelemästä alueesta olikin jätettävä pois monia ekonometrian kontekstiin keskeisellä tavalla sisältyviä kausaalipäätelyn menetelmiä, malleja sekä konkreettisia esimerkkejä. Tutkielmassa jouduttiinkin täysin sivuuttamaan laaja-alainen joukko erilaisia luonnollisia koeasetelmia, joita kausaalipäätelyssä on yhä enenevässä määrin hyödynnetty 1990-luvulta lähtien. Myös monia muita tunnettuja kausaalisia viitekehyksiä,

kuten esimerkiksi Clive Grangerin kausaliteetti ja Herbert Simonin kausaalimalli jouduttiin sivuuttamaan. Teoreettinen ekonometria on myös nykypäivänä lähentynyt eri kausaalisten viitekehysten suhteen. Kausaalisisessa analyysissa haetaankin usein vaikutteita myös oman viitekehysten ulkopuolisista viitekehyksistä.

Tutkielma antaa aihetta myös jatkotutkimukselle. Jatkotutkimuksen olisi hyvä tarkastella myös näitä ekonometrian kontekstissa suosioon nousseita luonnollisia koeasetelmia. Lisäksi jatkotutkimuksen tulisi tarkastella erilaisista kausaalisisista viitekehyksistä rakentuneita hybridiviitekehysiksi. Aihepiiristä onkin löydettävissä paljon tutkittavaa kausaalisisista viitekehyksistä ja kausaalipäätelyä kiinnostuneelle teoreettisen ekonometrian tutkijalle.

## Lähteet

- Ahrens, Achim; Aitken, Christopher; Schaffer, Mark E.; Sriboonchitta, Songsak; Yamaka, Woraphon & Kreinovich, Vladik (2021) Using Machine Learning Methods to Support Causal Inference in Econometrics. *Behavioral Predictive Modeling in Economics*, Vol. 897, 23–52, Springer, Cham.
- Angrist, Joshua David & Pischke, Jörn–Steffen (2009) *Mostly harmless econometrics: an empiricist's companion*. Princeton University Press, Princeton.
- Angrist, Joshua David & Pischke, Jörn–Steffen (2010) The Credibility Revolution in Empirical Economics: How Better Research Design is Taking the Con out of Econometrics. *Journal of Economic Perspective*. Vol. 24 (2), 3–30.
- Blundell, Richard (2010) Comments on: Michael P. Keane ‘Structural vs. atheoretic approaches to econometrics’. *Journal of Econometrics*, Vol. 156 (1), 25–26.
- Cartwright, Nancy (2001) Ceteris paribus laws and socio-economic machines. *The Economic World View - Studies in the Ontology of Economics*. Toim. Mäki, Uskali. Cambridge University Press, Cambridge.
- Christ, Carl F. (1994) The Cowles Commission's Contributions to Econometrics at Chicago. *Journal of Economic Literature*, Vol. 32 (1), 30–59.
- Clarke, Christopher (2022) Causality and Probability. Teoksessa *The Routledge handbook of the philosophy of economics*. Routledge, New York.
- Cunningham, Scott (2021) *Causal Inference – The Mixtape*. Yale University Press, New Haven.
- Deaton, Angus (2010) Instruments, Randomization, and Learning about Development. *Journal of Economic Literature*. Vol. 48, 424–455.
- Demiralp, Selva & Hoover, Kevin D. (2003) Searching for the Causal Structure of a Vector Autoregression. *Oxford Bulletin of Economics and Statistics*, Vol. 65 (1), 745–767.
- Fennell, Damien J. (2005) *A Philosophical Analysis of Causality in Econometrics*. Väitöskirja, London School of Economics and Political Science, ProQuest LLC, Ann Arbor.
- Fisher, Ronald (1925) *Statistical Methods for Research Workers*. Oliver & Boyd, Lontoo.
- Fisher, Ronald (1926) The Arrangement of Field Experiments. *Journal of the Ministry of Agriculture of Great Britain*, Vol. 33, 503–513, Lontoo.
- Fisher, Ronald (1935/1949) *The Design of Experiments*, Oliver & Boyd, Lontoo.
- Frisch, Ragnar (2010) A Dynamic Approach to Economic Theory: The Yale Lectures of Ragnar Frisch, 1930. Toim. Bjerkholt, Olav, & Qin, Duo. *Routledge Studies in the History of Economics Series*, Vol. 118, Taylor & Francis Group, New York.

- Gertler, Paul (2011) *Impact evaluation in practice*. World Bank, Washington DC.
- Granger, Clive W. J. (2001) Testing for Causality: A Personal Viewpoint. *Essays in Econometrics*, 48–70. *Alkuperäisteos: Journal of Economic Dynamics and Control*, (1980), 2.
- Haavelmo, Trygve (1944) The Probability Approach in Econometrics. *Econometrica*, Vol. 12 (1), 1–115, Cambridge University Press.
- Haavelmo, Trygve (1943/1995) The Statistical Implications of a System of Simultaneous Equations. *Econometrica*. Vol. 11 (1), 1–12, Cambridge University Press.
- Heckman, James & Pinto, Rodrigo (2015) Causal Analysis after Haavelmo. *Econometric theory*, Vol. 31 (1), 115–151, Cambridge University Press, New York.
- Heckman, James & Pinto, Rodrigo (2024) Econometric causality: The central role of thought experiments. *Journal of Econometrics*, Vol. 243 (1–2).
- Heckman, James & Sergio, Urzúa (2010) Comparing IV with structural models: What simple IV can and cannot identify. *Journal of Econometrics*. Vol. 156, 27–37.
- Henschen, Tobias (2022) Causality and Probability. Teoksessa *The Routledge handbook of the philosophy of economics*. Routledge, New York.
- Hernán, Miguel A. & Robins, James M. (2020) *Causal Inference: What If*. Chapman & Hall/CRC, Boca Raton.
- Holland, Paul. W. (1986) Statistics and Causal Inference. *Journal of the American Statistical Association*, Vol. 81, 945–960.
- Hoover, Kevin D. (2008) Causality in Economics and Econometrics. *The New Palgrave Dictionary of Economics*, Palgrave Macmillan, Lontoo.
- Hoover, Kevin D. & Dowell Michael E. (2001) Measuring causes: Episodes in the quantitative assessment of the value of money. *History of Political Economy*, Vol. 33, 137–161, Duke University Press, Durham.
- Hume, David (1748/2001) *An Enquiry Concerning Human Understanding*. Informotions, Inc, South Bend.
- Imbens, Guido W. (2010) Better LATE Than Nothing: Some Comments on Deaton (2009) and Heckman and Urzua (2009). *Journal of Economic Literature*. Vol. 48, 399–423.
- Imbens, Guido W. (2022) Causality in Econometrics: Choice vs Chance. *Econometrica*, Vol. 90, No. 6, 2541–2566.
- Jevons, William Stanley (1863) *A Serious Fall in the Value of Gold Ascertained, and Its Social Effects Set Forth*, Edward Stanford, Lontoo.
- Kant, Immanuel (1997) *Prolegomena to any Future Metaphysics*. Kääntänyt ja toimittanut alkuperäisteoksesta (1783) *Prolegomena zu einer jeden künftigen Metaphysik die als*

- Wissenschaft wird auftreten können* Hatfield Gary. Cambridge University Press, Cambridge.
- Keane, Michael P. (2010) Structural vs. atheoretic approaches to econometrics. *Journal of Econometrics*, Vol. 156, 3–20.
- Koopmans, Tjalling C. & Hood, Wm. C. (1953) *Studies in Econometric Method*, Cowles Commission for Research in Economics – Monograph No. 14. John Wiley & Sons, Inc., New York.
- Kortelainen, Mika & Salokangas, Henri (2023) Kvasikokeelliset menetelmät terveydenhuollon ja terveystaloustieteen vaikutusarvioinneissa. *Sosiaalilääketieteellinen Aikakauslehti*, Vol. 60 (3).
- Lechner, Michael (1999) Earnings and Employment Effects of Continuous Off-the-job Training in East Germany After Unification. *Journal of Business and Economic Statistics*, Vol. 17 (1), 74–90.
- Low, Hamish & Meghir, Costas (2017) The Use of Structural Models in Econometrics. *The Journal of economic perspectives*, Vol. 31 (2), 33–57, American Economic Association, Nashville.
- Matsueda, Ross L. (2012) Key Advances in the History of Structural equation Modeling. *Handbook of Structural Equation Modeling*. Toim. Hoyle, Rick H. The Guilford Press, New York.
- Mill, John Stuart (1843) *System of Logic – Ratiocinative and Inductive, being a connected view of the principles of evidence and the methods of scientific investigation*. Harrison and Co., Lontoo.
- Mises, Ludwig von (2007) *Human Action – A Treatise on Economics*. Toim. Greaves Bettina Bien. Liberty Fund, Indianapolis.
- Morgan, Mary S. (1990) *The History of Econometric Ideas*. Cambridge University Press, Cambridge.
- Nevo, Aviv & Whinston, Michael D. (2010) Taking the Dogma out of Econometrics: Structural Modeling and Credible Inference, *The Journal of Economic Perspectives*, Vol. 24 (2), 69–81.
- Pearl, Judea (1995a) Causal diagrams for empirical research. *Biometrika*, Vol. 82 (4), 669–688, Oxford University Press, Lontoo.
- Pearl, Judea (1995b) From Bayesian networks to causal networks. *Probabilistic reasoning and Bayesian belief networks*. Toim. Gammerman, Alexander. Alfred, Waller Limited, 1–31, Orchards, Fawley.
- Pearl, Judea (2000/2009) *Causality: models, reasoning, and inference*. Cambridge University Press, Cambridge.

- Reiss, Peter C. & Wolak, Frank A. (2007) Chapter 64 Structural Econometric Modeling: Rationales and Examples from Industrial Organization. *Handbook of Econometrics*. Vol. 6 (A), 4277–4415, North-Holland, Amsterdam.
- Rosenbaum, Paul R. & Rubin, Donald B. (1983) The Central Role of the Propensity Score in Observational Studies for Causal Effects. *Biometrika*, Vol. 70 (1), 41–55.
- Rubin, Donald (1974) Estimating Causal Effects of Treatments in Randomized and Nonrandomized Studies. *Journal of Educational Psychology*, Vol. 66 (5), 688–701.
- Rubin, Donald (2005) Causal Inference Using potential outcomes: Design, Modeling, Decisions. *Journal of the American Statistical Association*, Vol. 100 (469), 322–333.
- Rubin, Donald & Imbens, Guido W. (2015) *Causal inference for statistics, social, and biomedical sciences: An Introduction*. Cambridge University Press, New York.
- Simon, Herbert (1957) *Models of Man – Social and Rational*. John Wiley & Sons, Inc., New York.
- Sims, Christopher A. (1980) Macroeconomics and Reality. *Econometrica*, Vol. 48 (1), 1–48, The Econometric Society, Oxford.
- Splawa-Neyman, Jerzey (1923/1990) On the Application of Probability Theory to Agricultural Experiments. Essay on Principles. Section 9. *Statistical Science*, Vol. 5, 465–472. Kääntänyt Dabrowska D. M. ja Speed T. P. alkuperäisteoksesta *Roczniki Nauk Rolniczych Tom X* (1923) 1–51. Institute of Mathematical Statistics.
- Stigler, Stephen (1986) *The History of Statistics – The Measurement of Uncertainty before 1900*. The Belknap press of Harvard university press, Cambridge.
- Tinbergen, Jan (1951/2005) *Econometrics*. Routledge, New York.
- Wright, Sewall (1921) Correlation and causation. *Journal of Agricultural Research*, Vol. 20, 557–585.