hyväksymispäivä arvosana

arvostelija

Käsitteellistä johdatusta kausaalimallinnukseen

Petri Kivenheimo

Helsinki 5. maaliskuuta 2003
Kausaalisten mallien tutkimusseminaari, kevät 2003
HELSINGIN YLIOPISTO
Tietojenkäsittelytieteen laitos

1. Esipuhe

Tämä tutkimusseminaariesitelmäteksti on syntynyt olennaisesti kahdesta pyrkimyksestä: yhtäältä esitellä mahdollisimman ymmärrettävästi (että itsekin voisi paremmin ymmärtää) Judea Pearlin artikkelia "Causal Inference in the Health Sciences: A Conceptual Introduction" ja toisaalta antaa paras mahdollinen panoksensa itse tutkimusseminaarin hyväksi. Tällöin seminaarin avaustilaisuudessa annetun ohjeen mukaan on syytä asettaa sanottavansa aiemmin sanotun jatkoksi ja pyrkiä viemään seminaarin kokonaiskeskustelua eteenpäin siitä pisteestä, mihin oli aiemmin päästy.

Tuloksena on teksti, joka ei sisällä kaikkea kiinnostavaa Pearlin n. 30-sivuisesta artikkelista, mutta toisaalta sisältää kiinnostavaksi arvioitua ainesta sen ulkopuolelta. Tarkoituksena on osaltaan viritellä keskustelua siitä, ovatko asiat niin kuin olen ne ymmärtänyt. Tekstin virheistä ja hölmöyksistä olen tietenkin yksin vastuussa.

2. Johdanto

Kausaalimallinnus on vielä lapsenkengissä. Peruskäsitteetkin ovat tutkijoiden valtaenemmistölle toistaiseksi tuntemattomia. Esitetyt ideat ovat joka tapauksessa kiinnostavia ja voivat parhaassa tapauksessa osoittautua uuden hedelmällisen tutkimusparadigman ensi askeliksi.

Asioiden ymmärtämiseksi on yleensä paras aloittaa perustavista käsitteistä ja rakentaa niiden varaan vähä vähältä laajentaen ja syventäen. Niinpä käsittelemme ensin yleisesti kausaliteetin käsitettä ja kausaalimallinnuksen suhdetta eräisiin entuudestaan tunnettuihin mallinnustapoihin. Sitten etenemme kausaaliverkkojen ominaisuuksiin ja siihen, miten ne mallittavat kohdealueitaan. Loppuvaiheessa katsomme mahdollisuuksien mukaan, miten niitä käytetään ja millaisia tuloksia näin voidaan saavuttaa.

3. Kausaliteetti käsitteenä ja käytäntönä

Kausaliteettia, kuten mitä hyvänsä muutakin aihetta, käsiteltäessä on ensinnäkin suureksi hyödyksi, että kaikilla asianosaisilla olisi jonkinlainen mielikuva (tai "working knowledge") siitä, mistä puhutaan. Tilanne on yhä parempi, jos nämä käsitykset ovat keskenään yhteensopivia tai jopa jotakuinkin yhteneviä. Siksi kiinnitämme seuraavassa huomiota kausaliteetin käsitteeseen ja pyrimme saamaan siitä otteen jonkinlaisen yleisymmärteisen lähestymistavan kautta.

Luvun loppuosassa käsittely laajenee suuntaa-antavaan (ja poleemisehkoonkin) selvitykseen kausaalimallien asemasta tieteellisten (ja esitieteellisten) mallinnuskeinojen hierarkiassa ja esittelee kausaalimallinnuksen leviämistä estäviä tai hidastavia tekijöitä.

3.1. Arkipäivän kausaalipäättelyä

Kausaliteetti on ihmisen perustava tapa hahmottaa omaa ja ympäristön tilaa ja laatia toimintasuunnitelmia näiden parantamiseksi. Sitä voisi pitää jopa jonkinlaisena inhimillisen ajattelun äidinkielenä: jo lapsen itku kertoo tukalaksi koetusta tilanteesta ja muutoksen tarpeesta ja viestii esiverbaalisesti äidille, että johonkin olisi ryhdyttävä. Itkun tyyntyminen antaa palautteen korjaustoimenpiteiden onnistumisesta. Tämä on kommunikaatiota, jonka mahdollistaa se, että sekä äiti että vauva mieltävät ympäristöään ja omaa tilaansa ja äiti pystyy samaistumaan lapsensa tarpeisiin oman kokemuksensa pohjalta luonnostaan niin hyvin, että sanoja ei (vielä) tarvita.

Ihmisten jokapäiväinen elämä on kulttuurista ja historian vaiheesta riippumatta tulvillaan tapahtumia ja tilanteita, joihin ihmiset puuttuvat ja joiden tarjoamia mahdollisuuksia hyödyntävät, koska heillä on sisäinen taju siitä, millainen tilanne on, millaiseksi sen tahtoisi kehittyvän ja mitä on tehtävissä tämän kehityksen hyväksi. Jos joku esim. seisoo suljetun oven edessä ja tahtoo päästä sen toiselle puolelle, hän voi esim. yrittää vetää ovea (rivasta tai vastaavasta), työntää sitä, vääntää kahvasta, painaa avausnapista, kääntää ovikelloa, kokeilla avaimia, koputtaa, huutaa tai ampua konepistoolilla lukon irti, tilanteesta ja käytettävissä olevista välineistä riippuen. Meidän on ihmisinä helppo ymmärtää kaikki nämä tavat ja tajuta, miten ne voivat auttaa oven taakse pyrittäessä. Tekoälyn filosofiasta tuttu kehysongelma (frame problem) osoittaa, että tämä inhimillinen kyky ei ole triviaali asia: pelkän symbolimanipulaatiokyvyn varassa toimivan agentin on todella vaikeaa löytää käytettävissä olevasta keinovalikoimastaan oikeaa etenemisreittiä johonkin tavoitteeseen pääsemiseksi.

3.2. Tieteellisiä mallinnusmenetelmiä

Mallinnuksella tarkoitetaan lyhyesti sanoen pyrkimystä laatia tutkittavasta kohteesta sellainen kuvaus, jonka avulla on mahdollista saada riittävän luotettavia vastauksia tätä kohdetta koskeviin kysymyksiin nopeammin ja helpommin kuin mitä kohteen suora havainnointi tai sillä tehdyt empiiriset kokeet mahdollistaisivat.

Suuntaa-antava mallinnusmenetelmähierarkia voisi olla seuraavanlainen:

a) kaoottinen: ei voi ymmärtää, täytyy haparoida
b) kvalitatiivinen: ei voi varsinaisesti mallittaa, mutta sentään luokitella ja nimetä kiinnostuksen kohteita
c) hypoteettinen: voi esittää oletuksia, joista voi keskustella mutta jotka eivät ole tutkittavissa kokeellisesti
d) deterministinen: jotain voi laskea tarkasti ja verrata tuloksia mitattuihin arvoihin, muu sivuutetaan

e) klassinen probabilistiikka: toistuvia ilmiöitä voi mallittaa niiden keskimääräisen (odotusarvoisen) käyttäytymisen pohjalta silloinkin, kun tarkka laskenta on mahdotonta
f) bayesläinen probabilistinen: sisäisesti johdonmukainen toiminta on mahdollista tilannearvion ja havaintojen pohjalta silloinkin, kun ei ole kyse toistuvista ilmiöistä; mallia voi tarkentaa säätämällä sen parametreja nähdyn datan perusteella
g) kausaalinen: intuitio mahdollistaa mallintamisen yli datasta oppimisen tarjoamien mahdollisuuksien.

Tässä siis kieli tulee mukaan kuvaan kohdassa b), jonkinlainen mallinnus kohdassa c), matematiikka kohdassa d), todennäköisyyslaskenta kohdassa e), sen käyttömahdollisuuksia laajentava subjektiivinen tulkinta kohdassa f) ja ihmisen luontaisen kausaali-intuition hyödyntämismahdollisuus viimeisessä kohdassa g).

Toinen tapa luonnehtia esitettyä on katsoa, että varsinainen tiede on mahdollista vasta kohdassa d) ja siitä eteenpäin, ja kiinnittää huomio mallinnuksen onnistumisedellytyksiin kussakin kohdassa. Ensin päästään käsiksi vain sangen tarkoin samanlaisina toistuviin ilmiöihin (omenat putoavat puusta aina alaspäin, vesi jäätyy tietyssä lämpötilassa jne.), sitten voidaan hallita ilmiöitä, joiden yksityiskohtia ei pystytä laskemaan (jos kolme henkilöä heittää kahdella kolikolla tiskaajaksi joutujan eikä yksi näistä tiskaa mielellään, hänen kannattaa valita tiskivuoronsa ehdoksi mieluummin kaksi kruunaa tai kaksi klaavaa kuin yksi kumpaakin lajia). Bayesläisyys pystyy sanomaan jotain mielekästä silloinkin, kun dataa on vähän ja siinä on aukkoja. Kausaalimallinnuksella taas pitäisi oleman pääsy ihmisten kausaali-intuition tarjoamiin mahdollisuuksiin: ei tarvitse toivoa, että malli pystyisi päättelemään, että taudit aiheuttavat oireita eikä (periaatteessa) päinvastoin, vaan tämän tiedon voi ottaa jo lähtökohdaksi.

Toisaalta kysymys on siitä, että probabilistiikan piirissä on mahdollista saada aikaan kunnollisia malleja vain sillä edellytyksellä, että mallinnettava data on peräisin jostain (samana pysyvästä) jakaumasta, kun taas kausaalimallinnuksella päästään käsittelemään dynaamisia tilanteita, joissa jakauma vaihtuu kesken kaiken. Pearl vertaa tätä eroa siihen, että geometrisilla menetelmillä voidaan laskea jonkin kappaleen projektio vapaavalintaiseen suuntaan, mutta ne eivät kerro, miltä sama kappale näyttää (tai näyttäisi) törmättyään toiseen kappaleeseen.

3.3. Kausaalikynnys

Kausaalimallinnuksen omaksumista vaikeuttamassa on ensinnäkin se, ettei ymmärretä, mikä on periaatteellinen ero pelkän reaktiivisen havaitsemisen ja proaktiivisen kokeiden tekemisen välillä. Havaitsijan data nimittäin tulee yhdestä jakaumasta, mutta koejärjestelyt muuttavat datan tuottavaa jakaumaa. Siksi näiden kahden erilaisen tilanteen samaistaminen johtaa virhepäätelmiin, jopa naurettavuuksiin. Sairaaloihin potilaiksi menevät ihmiset esimerkiksi ovat keskimäärin sairaampia kuin muut, mutta sairaaloiden sulkeminen (niin ettei niihin voisi enää kukaan mennä potilaaksi) ei kuitenkaan olisi kansanterveydellisesti hyvä ratkaisu.

Toinen ongelma on ollut matemaattisen koneiston riittämättömyys kausaliteettimallinnuksen tarpeisiin. Kuten sanottu, todennäköisyyslaskennan ilmaisuvoima on kausaalimallinnuksen tarpeisiin riittämätön, sillä kaikkea ei enää voidakaan käsitellä saman

yhteistodennäköisyysjakauman puitteissa.

Ehkä suurin kynnys kausaalimallinnuksen tiellä on kuitenkin se, että siinä joutuu rakentamaan mallin, joka ei periaatteessakaan ole datasta generoitavissa. Bayesläisyydessäkin on priorit (todennäköisyysjakauma-arviot, joita käytetään ensimmäisinä estimaatteina tutkittavasta tilanteesta ja joita päivitetään saadun datan perusteella), mutta näiden epätarkkuus korjautuu mallissa automaattisesti sitä mukaa kuin dataa saadaan lisää. Kausaalimallit sitä vastoin jäävät laatijansa alkuperäisintuition varaan: tietyillä edellytyksillä kausaalimallin voi osoittaa vääräksi (datan kanssa yhteensopimattomaksi), mutta ei koskaan lopullisesti oikeaksi. Kausaalisuhteita ei myöskään voi mallissa päivittää pikkuhiljaa: nuoli on yhteen suuntaan tai toiseen tai molempiin tai ei kumpaankaan, ja tämä on mallissa kvalitatiivinen piirre. Kausaalimallinnuksen automatisointi taas edellyttäisi ilmeisesti (edellämainitun) kehysongelman ratkaisemista tähänastista ratkaisevasti paremmalla tavalla, jotta tekoälyn varassa operoivilla agenteilla voisi olla kykyä mielekkääseen kausaalisuhteiden tunnistamiseen.

Taas kerran käy siis niin, että uuden oppiminen osoittaa aiemman tiedon pahan puutteellisuuden.

4. Pearlilaisen kausaalimallinnuksen välineitä

Kausaliteetin idea on yleisluontoinen eikä sellaisena tarjoa vielä mitään konkreettisia menetelmiä mallinnukseen. Kaliforniassa vaikuttava tutkija Judea Pearl on tehnyt uraauurtavaa työtä kausaalimallinnuksen teorian ja tekniikan kehittämisessä, ja tarkoitus onkin seuraavaksi saada otetta hänen rakentamaansa kausaalimallinnuksen menetelmään. Käsittely etenee niin, että ensin selvitämme menetelmän perusrakenteen ja katsomme sitten sen kumpaakin keskeistä komponenttia (kausaaliverkkoja ja niihin liittyviä algebrallisia elementtejä) hieman lähemmin.

4.1. Kaksoiskuvaus

Pearlin käyttämä kausaalimallien esitystapa rakentaa aikaisempien ideoiden ja menetelmien varaan mutta yhdistelee niiden tarjoamia mahdollisuuksia uusilla tavoilla, jolloin saadaan entisiä ilmaisuvoimaisempi kuvauskieli. Olennaista on kausaaliverkosta ilmenevän vaikutussuhteiden topologian ja rakenneyhtälöiden ilmaiseman vaikutusten voiman ja luonteen yhteys: molempia tarvitaan ja käytetään kausaalipäättelyn ja -laskennan mahdollistamiseksi.

Yhtä olennaista on menetelmään sisältyvä kyky epätäydellisen tiedon käsittelyyn: paljon on pääteltävissä silloinkin, kun vaikutuksen tarkemmasta luonteesta ei tiedetä mitään, vaan lähtökohtana on vain tieto (tai oletus), että tietty tekijä vaikuttaa (tai voi vaikuttaa) tiettyyn toiseen tekijään. Samaten malleissa voi olla (ja usein onkin) mukana muuttujia, jotka eivät ole suoraan havaittavissa (tai joita koskevia havaintoja ei ole käytettävissä). Näiden vaikutuksia kuvataan katkonuolilla. Tällaisia vaikutuksia pidetään tyypillisesti häiriötekijöinä, sillä mallintajan kiinnostuksen varsinaisia kohteita kuvaavien muuttujien arvoista on tietenkin oltava käytettävissä mittaustuloksia, jotta kvantitatiivinen mallinnus olisi mahdollista. Tällöin on luontevaa ajatella

häiriötekijät kollektiivisina muuttujina, joihin on keskitetty kaikki (eri tekijöistä aiheutuvat) häiriöt tai sivuvaikutukset, jotka vaikeuttavat tutkittavan vaikutussuhteen tarkkaa selvittämistä.

4.2. Kausaaliverkko

Kausaaliverkko koostuu, kuten suunnatut verkot yleensäkin, solmuista ja niiden välisistä nuolista. Solmut kuvaavat mallin muuttujia (tutkittavia kohteita), nuolet niiden keskinäisten vaikutusten suuntia. Verkon tulkinnassa on olennaista ymmärtää, että mallia eivät rajoita siihen piirretyt nuolet (niiden välittämä vaikutus voisi jäädä nollatehoiseksi) vaan ne, jotka on jätetty siitä pois: "vanha verkko ei opi uusia nuolia", eli jos tutkimuskohdetta kuvaavien muuttujien välillä olikin malliin sisältymättömiä vaikutuksia, malli pysyy niille sokeana datasta riippumatta. Toisaalta juuri pois jätetyt nuolet antavat mahdollisuuksia mallin onnistumiselle: kaikki mahdolliset nuolet sisältävillä malleilla olisi tuskin mahdollista laskea mitään skenaarioita, sillä kaikki olisi niissä mahdollista eikä siksi mikään varmaa (tai edes todennäköistä).

Yhtenäisiä nuolia piirretään vain mallin sisäisiä (endogenous), havaittuja muuttujia kuvaavien solmujen välille. Muut tilanteeseen vaikuttavat tekijät mallinnetaan mallin ulkoisilla (exogenous) muuttujilla, joista lähtee vain katkonuolia. Nämä kulkevat tyypillisesti joko ulkoisesta muuttujasta sisäiseen muuttujaan päin (häiriövaikutus) tai sitten kahden ulkoisen muuttujan välille on piirretty kaksikärkinen katkonuoli. Ellei sellaista ole piirretty joidenkin ulkoisten muuttujien väliin, nämä on oletettu keskenään riippumattomiksi (vrt. Bayes-verkkojen rakenteella kuvatut mallin riippumattomuusoletukset).

4.3. Kovarianssit ja rakenneyhtälöt

Kaksikärkisiä katkonuolia vastaavien ulkomuuttujien välisten riippuvuuksien voimakkuudet kuvataan näihin nuoliin liittyvillä kovarianssiarvoilla. Kuhunkin verkon sisäistä muuttujaa kuvaavaan solmuun liittyy vastaavasti rakenneyhtälö, joka kuvaa siihen osoittavien nuoleten ilmaisemaa kausaalivaikutusta. Geneetikko Sewall Wright otti jo 1920-luvulla käyttöön suunnatun verkon ja rakenneyhtälöt kausaalivaikutusten kuvaamiseksi. Hänen malleissaan rakenneyhtälöt olivat lineaarisia: vaikutuksenalaisen muuttujan arvoksi sijoitettiin vaikutuskerroin kertaa vaikuttavan muuttujan arvo plus häiriötekijän vaikutus. Näin yksinkertainen lauseke ei tyypillisesti ole käytännössä realistinen, mutta mahdollistaa mallinnettujen kausaalivaikutusten helpon algebrallisen manipulaation. Mallithan ovat joka tapauksessa likimääräisiä.

Pearl käyttää enimmäkseen yleistä muotoa olevia rakenneyhtälöitä: vaikutetun muuttujan arvoksi tulee jonkin tarkemmin yksilöimättömän funktion arvo. Tämä funktio saa argumenteikseen ko. muuttujaa kuvaavan solmun vanhempien kuvaamien mallin sisäisten muuttujien arvot ja katkonuolella vaikuttavan ulkoisen muuttujan arvon. Tällöin kausaalimalli on realistisempi mutta myös epäinformatiivisempi, ellei näistä funktioista ole tietoa. Mallin rakenne voi kuitenkin mahdollistaa konkreettisen kausaalilaskennan (datan avulla) myös tilanteissa, joissa vaikutusfunktio jätetään kiinnittämättä.

5. Välineistön käytöstä

Saatuamme käsityksen siitä, minkä tyyppisistä komponenteista Pearlin kausaalimallinnusapparaatti perimmältään koostuu siirrymme nyt käsittelemään sen käyttötapoja ja niiden yhteydessä esiin nousevia kysymyksiä, erityisesti sellaisilta osin, joiden voi ajatella olevan tarkemman selvittelyn tarpeessa. Vaikka tälle käsittelylle onkin annettu käsillä olevasta tekstistä huomattava osa, on silti selvää, että asioihin tutustuminen jää varsin pintapuoliseksi. Yksityiskohtiin palattaneen keskeisissä kysymyksissä kuitenkin muissa yhteyksissä.

Pearlilaista kausaalimallinnusta ei voine ymmärtää ilman tässä luvussa tarkasteltavia intervention ja identifikaation käsitteitä. Myös interventiota ilmaiseva do()-operaattori ja suoraviivaisen identifikaation mahdollistavat markovilaiset kausaaliverkot nousevat käsittelyssä esiin. Sekoittumisen hallinnastakin puhutaan, mutta vain viitteenomaisesti.

5.1. Interventio ja do()-operaattori

Kausaalimallinnuksen olennainen uusi piirre probabilistiseen mallinnukseen verrattuna on siis kyky laskea todennäköisyyksiä tilanteissa, joissa alkuasetelmaa vastaava yhteisjakauma on muuttunut. Muutoksen ajatellaan tapahtuneen intervention kautta: jollekin tai joillekin mallin (sisäisille) muuttujille on yksinkertaisesti vain asetettu haluttu arvo. Tällöin tämä arvo ei olekaan määräytynyt kyseiseen muuttujaan (normaalisti) vaikuttavien (sisäisten ja ulkoisten) muuttujien arvoista intervention kohdemuuttujan rakenneyhtälöiden mukaan. Näin yhteistodennäköisyysjakauma on muuttunut (kaikki ehdolliset todennäköisyydet eivät enää ole samat kuin ilman interventiota). Toisaalta verkon ajatellaan olevan muilta osin ennallaan, siis intervention kohteeksi joutumattomat sisämuuttujat riippuvat ympäristöstään alkuperäistilanteen mukaisilla tavoilla.

Intervention ilmaisemiseen ei tavallisen todennäköisyyslaskennan ilmaisuvoima riitä. Pearl on siksi tehnyt intervention probabilistiseen formalismiin ja lisännyt siihen do()-operaattorin (jossain lähteessä lienee samaa semanttista lokeroa täyttämässä set()-niminen operaattori, kun sellainenkin ohimennen mainitaan). (Do()-operaattorihan on tietysti ulkoasultaan tietojenkäsittelijälle tutunomainen aliohjelmankutsunoloinen otus, mutta en toisaalta ihmettelisi, vaikka sen epämatemaattistyylinen habitus olisi yhdelle ja toiselle muodostunut lisäkannoksi kausaalimallinnuksen ihanuudesta vakuuttumisen kaskessa: sehän ei ole mikään matemaattinen funktio, jonka ajatellaan noin vain korvautuvan lausekkeissa lasketulla arvollaan, vaan ikään kuin häkkeröity identiteettifunktio, joka palauttaa arvonaan argumenttinsa, mutta jonka suorituksen sivuvaikutuksena koko laskennan perustana oleva yhteistodennäköisyysjakauma onkin muuttunut toiseksi ennen kuin lausekkeen loppuosan arvo evaluoidaan. Siis eräänlainen Troijan hevonen matematiikan maaperälle rantautuneena.)

5.2. Identifikaatio

Pearlin laskentatekniikassa olennaista näyttäisikin olevan tämän itseaiheutetun häiriön hygieeninen hävittäminen: kun rakenneyhtälöt ovat epäinformatiivisia, ei voida tietää, mikä on mallin tila intervention jälkeen. Poikkeuksena tästä säännöstä ovat tapaukset, joissa onnistutaan jotenkin ovelasti päättelemään, että nytpä kyseessä onkin tilanne, jossa intervention aiheuttama sivuvaikutus ei päässyt sotkemaan kokonaiskuviota vaan interventoituun arvoon ehdollistettu todennäköisyysjakauma pysyy samana kuin jos sama arvo olisi tullut ko. muuttujalle "luonnollista tietä". Tällöin do()-operaattori voidaan sanitoida tiehensä ja kiinnostavat arvot saadaan lasketuiksi datasta suhteellisina frekvensseinä. Tätä do()-operaattorin ignoroimismahdollisuutta tarkoittavana teknisenä terminä kausaaliteoreetikot käyttävät identifikaatio-sanaa.

Milloin tämä on mahdollista? Edellytyksenä on, että malli on markovilainen: (suunnatusti) syklitön ja sellainen, että kaikki virhetermit (ulkoisten muuttujien vaikutukset) ovat täysin riippumattomia (jointly independent). Tässä kohtaa (s. 12 alaosassa) Pearl näyttää puhuvan outoja: hän lupaa ehtoja sille, miten epämarkovilaisenkin mallin identifikaatio voisi tietyillä ehdoilla onnistua, mutta teoreemat, joissa nämä ehdot on määrä antaa, puhuvat vain markovilaisista malleista.

Markovilaisten mallien tapauksessa idenfikoituvuuden nyt ainakin pitäisi olla selvää. Ensimmäinen lause (kausaalinen Markov-ehto) toteaa, että kaikki markovilaisen mallin tuottamat jakaumat voidaan esittää sellaisten ehdollisten todennäköisyyksien tulona, joissa kunkin mallin sisäisen muuttujan todennäköisyys on ehdollistettu sen omien vanhempien arvoihin. Mallia vastaavan kausaaliverkon rakenne siis määrää kunkin solmun vanhemmat (syklittömyyden vuoksi joidenkin solmujen vanhempien joukon täytyy olla tyhjä, jolloin niiden osalta tuloon otetaan ehdollistamaton todennäköisyys), joiden arvoihin ehdollistettujen jakaumien tulo antaa koko verkon muuttujien yhteisjakauman.

Edellisen lauseen pätiessä saadaan korollaarina kaava interventiojakauman laskemiselle havaitusta jakaumasta (tämä korollaari tunnetaan myös nimillä "katkaistu tekijöihinjako" [truncated factorization] ja "käsittelylause" [manipulation theorem]): tälläkin kertaa otetaan vanhempiensa arvoilla ehdollistettujen muuttujakohtaisten jakaumien tulo, paitsi että tulontekijöistä on ensinäkin jätetty pois ne muuttujat, joihin interventio on kohdistunut (näitä voi siis olla haluttu määrä): niiden arvothan on kiinnitetty ja tiedetään todennäköisyydellä yksi. Toisena modifikaationa on, että ehdolliset todennäköisyydet on laskettu käyttäen intervention mukaisia vanhempien arvoja niiden muuttujien ehdollisia jakaumia laskettaessa, joiden vanhempia on intervention kohteiksi joutuneiden muuttujien joukossa.

Korollaari pätee siksi, että interventio ei vaikuta verkon Markov-ominaisuuteen. Lisäksi on huomionarvoista, että tulos on riippumaton sekä rakenneyhtälöissä esiintyvistä funktioista että häiriötekijöiden (ulkoisten muuttujien vaikutusten) jakaumista. Kaikki seuraa pelkästä kausaaliverkon rakenteesta.

5.3. Kausaalivaikutusten laskeminen markovilaisittain

Kausaalivaikutuksen (causal effect) eli hallitun jakaumafunktion (controlled distribution function)

käsite liittyy kausaalimallinnuksen kannalta perustavaan asetelmaan, jossa kiinnostuksen kohteena on tietyn muuttujan arvon hallinnalla aikaansaatu vaikutus tietyyn toiseen muuttujaan, johon ensinmainittu muuttuja on (suorassa tai epäsuorassa) vaikutussuhteessa. (Tässä voi ajatella vaikka Simpsonin paradoksia käsiteltäessä esillä ollutta lääkevaikutusesimerkkiä: haluttaisiin vaikuttaa potilaiden toipumiseen [myönteisesti] antamalla näille lääkettä. Lääkkeen käyttöä ajatellaan siis voitavan haluttaessa suoraan hallita, ja kiinnostavaa on, mitä vaikutusta tällä on potilaiden toipumisen kannalta.)

Koska muiden muuttujien arvojen jakaumat eivät tässä asetelmassa ole kiinnostavia, ne häivytetään kuvasta marginalisoimalla. (Marginalisointi on toimenpide, jossa kaikkien muuttujien yhteisjakaumaa käsitellään siten, että ne osatodennäköisyydet, joihin liittyvässä muuttujien arvojen valikoimassa kiinnostavilla muuttujilla on keskenään samat arvot, lasketaan yhteen vähemmän kiinnostavien muuttujien arvoista riippumatta. Näin saadaan jakauma, jonka eri tapauksia erottavat toisistaan ainoastaan kiinnostaviksi katsottujen muuttujien arvot ja jossa näiden mahdollisilla kombinaatioilla on samat todennäköisyydet kuin alkuperäisessä yhteisjakaumassakin. Vähemmän kiinnostavien muuttujien kaikki arvokombinaatiot ovat nyt implisiittisesti mukana kunkin yhdistämällä saadun yksittäistapauksen sisällä [ja näiden yksittäistapausten todennäköisyyksien summa on yksi eli koko todennäköisyysmassa].)

Saadaan siis periaatteessa kahden muuttujan yhteistodennäköisyysjakauma, mutta koska toinen näistä oli asetettu interventiolla, kyseessä on oikeastaan vain yhden muuttujan jakauma, ja tämä kertoo intervention tuottaman tuloksen kiinnostavan muuttujan arvojen interventiomuuttujalle asetettuun arvoon ehdollistettuna. Yksi tällainen jakauma saadaan siis periaatteessa kutakin mahdollista interventiomuuttujalle asetettavissa olevaa arvoa kohti.

Kausaalimallinnustilanteissa kiinnostava asetelma on usein vielä sellainen, jossa ideana on, että sekä interventiomuuttujan että kiinnostavan muuttujan arvot ovat vähintään ordinaaliasteikolla (on siis mielekästä puhua niiden suuruusjärjestyksestä), ja tutkimusasetelmana on sen seikan selvittäminen, millä interventiomuuttujan arvolla saadaan kiinnostavan muuttujan jakauma lähimmäksi tavoitetilaa (siis esim., paljonko lääkettä pitää antaa, että mahdollisimman monet potilaat toipuisivat).

Markovilaisessa mallissa pystytään selvittämään tämä kysymys suoraan katkaistua tekijöihinjakoa käyttäen. Kun siis käytettävissä on markovilainen kausaaliverkko ja sen sisäisten muuttujien relevanttia yhteisjakaumadataa, kausaalivaikutuksia voidaan laskea näiden perusteella ilman muita tietoja. (Tulosten laatu riippuu tietenkin mallin osuvuudesta ja datan laadusta.)

5.4. Sekoittumisen hallinnasta (takaovikriteerillä ja ilman)

Tästä on puhuttu muussa yhteydessä, joten riittäköön tässä yhteydessä maininta, että markovilaiset mallit ovat määritelmänsä mukaan sellaisia, joissa sekoittajia (confounders) ei ole eikä sekoittumista (confounding) näin ollen pääse tapahtumaan. Sekoittuminen on siis ongelma, johon markovilaisuus ei tuo apua.

Takaovikriteeri taas antaa kausaaliverkon rakenteen tarkasteluun perustuvan säännön siitä, miten

mallista on valittava muuttujat, joiden arvot on otettava huomioon kausaalivaikutuksia laskettaessa, jotta tulosten vääristymiseltä vältyttäisiin. Kaikissa tapauksissa tällaisia muuttujia ei kuitenkaan ole löydettävissä.

Sekoittumisen hallinta voi tällöinkin olla mahdollista. Jos vaikutussuhde interventiomuuttujasta kiinnostavaan muuttujaan on välillinen, niin kausaalisuhteen voi laskea paloissa: mikäli on mahdollista laskea luotettavasti interventiomuuttujan arvon vaikutus välittävän muuttujan arvoon ja välittävän muuttujan arvon vaikutus kiinnostavaan muuttujaan erikseen, nämä tulokset voidaan yhdistää kertomalla ne keskenään ja marginalisoimalla välittävä muuttuja pois, jolloin on kausaalivaikutus on saatu lasketuksi. (Tässä sekoittuminen siis vaikutti interventiomuuttujan ja kiinnostavan muuttujan arvoihin, muttei välittävään muuttujaan.)

5.5. Yleinen identifioituvuusehto

Jälkimmäinen lause (Tianin ja Pearlin käsialaa vuodelta 2001) on hieman vaikeaselkoisesti muotoiltu (ainakin tätä kirjoitettaessa vallinneessa vireystilassa selvitettäväksi), mutta seuraava tulkinta vaikutti uskottavimmalta: riittävä ehto X:ään tehtävän intervention Y:hyn kohdistuvan kausaalivaikutuksen identifioimiseksi on, että jokaisella sellaisella X:n lapsella, jonka kautta kulkee vaikutuspolku Y:hyn asti, on vähintään yksi tämän X:n lapsen kautta X:stä Y:hyn kulkevalla vaikutuspolulla sijaitseva sellainen solmu, jonka arvo on datasta selvitettävissä (on siis mitattu dataa kerättäessä ja talletettu).

Toisin sanoen tämän tulkinnan mukaan X:stä ei saa kulkea Y:hyn yhtään sellaista vaikutuspolkua, että siitä X:n lapsesta, jonka kautta kyseinen polku kulkee, ei Y:hyn johtaisi mitään sellaista vaikutuspolkua, jolla sijaitsisi yhtään mitattua muuttujaa. Tai vielä toisella tavoin ilmaisten: X:stä saa kulkea Y:hyn sellaisia vaikutuspolkuja, joiden varrella ei ole yhtään mitattua muuttujaa, ja näitä saa vieläpä olla mielivaltaisen monia, kunhan vain jokaista sellaista X:n lapsisolmua kohti, joka välittää yhden tai useamman tällaisen polun, on myös vähintään yksi sellainen vaikutuspolku Y:hyn, että sillä sijaitsee vähintään yksi mitattu muuttuja.

6. Hieman kontrafaktuaaleista

Kausaliteetin syvällisessä käsittelyssä halutaan vastauksia muunkintyyppisiin kysymyksiin kuin vain edellä käsiteltyihin. Esitellyn kaltainen kausaalivaikutusten laskeminen ei riitä, kun halutaan selvittää, mitkä syyt ovat olleet kuinkakin merkittäviä tiettyjen tulosten kannalta (eli mikä osuus seurauksesta johtui mistäkin syystä) tai mitä olisi tapahtunut, jos vaikkapa jonkin lääkkeen koejärjestelyä olisi muutettu niin, että koeryhmästä olisi tehty verrokkiryhmä (plasebolääkityksellä) ja verrokkiryhmästä koeryhmä. Nämä kysymyksenasettelut ovat luonteeltaan sellaisia, ettei niihin voitaisi vastata millään koejärjestelylläkään (sillä samaa tapausta ei voi testata kahdesti: ei voi esim. palata jo lääkettä saaneen potilaan elämässä uudestaan vaiheeseen, jossa hän ei ollut vielä kertaakaan saanut ko. lääkettä ja katsoa, miten hän pärjää, kun lääkettä ei hänelle tällä kertaa annetakaan.

Tällaisia kysymyksiä, joiden käsittely edellyttää pääsemistä jollain tavoin käsiksi koejärjestelyiden ulottumattomiin jääviin tapauksiin, kutsutaan kontrafaktuaalisiksi eli tosiasioiden (tai faktojen) vastaisiksi, ja itse tapahtumattomia tapauksia kontrafaktuaaleiksi (counterfactuals). Niidenkin käsittelyyn liittyvästä matematiikasta Pearlilla on sanottavaa. Itse asiassa hänellä on lähtökohtanaan jo valmiiksi olemassa olevaa matematiikkaa, joka seurailee läheisesti normaalia todennäköisyyslaskentaa varovaisenoloisin laajennuksin. Pearlin pääteesi on, että näistäkin analyyseistä tulee entistä ymmärrettävämpiä, kun ne liitetään hänen hahmottamansa kausaaliverkkomallin ja sen intuitiivisesti ymmärrettävämmän käsitteistön puitteisiin. Voisi sanoa, että hän näiltä osin lainaa matematiikan muilta mutta parantelee sen tulkintaa.

7. Loppupäätelmä

Olemme kahlanneet ja osittain rynnänneet Pearlin lääketieteen harjoittajille suunnatun kausaalipäättelyn käsitteellisen johdatuksen läpi. Kuten otsikoinnistakin voi päätellä, teksti todella esittelee lukuisia käsitteitä (tässä mainittujen lisäksikin), ja ainesta olisi ollut pitempäänkin selvittelyyn. Joka tapauksessa tavoite on ollut, että tämä käsittely olisi osaltaan auttamassa kausaalimallinnuksen ja -päättelyn syvempään ymmärtämiseen, ja tuntuu vaikealta uskoa, että tässä olisi pystytty täysin epäonnistumaankaan.

Tämän tekstin pahimpiin puutteisiin voinee laskea esimerkkien ja yleensäkin havainnoittamisen vähäisyyden. Pearlilla on tekstissään muutama esimerkki, joiden avulla hän auttaa sisäistämään kausaalimallinnuksen teoriaa, mutta ne eivät ole mahtuneet mukaan tähän selontekoon. Seminaariesitelmän yhteydessä olisi tietysti mahdollista pyrkiä paikkaamaan ko. puutetta. Saa nähdä, kuinka siltä osin (ja muutoinkin) käy.

8. Jälkipuhe

Muodollisesti(kaan) tämä teksti ei selvästikään ole mallikelpoinen. Älköötmyöhemmät seminaarin osanottajat seuratko huonoja esimerkkejä, vaan hyviä.

Vaan saatiinpahan silti jakeluun!