

PÄÄKIRJOITUS

Tekoäly yleiskäyttöisenä teknologiana ja taloustieteellisen tutkimuksen välineenä

Ari Hyytinen

Teknologia on yleiskäyttöistä, kun sillä on hyvin monenlaisia sovelluskohteita useilla eri toimialoilla. Yleiskäyttöisen teknologian ajatellaan tyypillisesti myös kiihdyttävän teknologista kehitystä laajemmin, useilla talouden osaluueilla. Tämä perustuu siihen, että yleiskäyttöinen teknologia sekä lisää monilla erilaisilla toimialoilla uusien tavaroiden ja palveluiden markkinoille tuloa että tehostaa erilaisten jo olemassa olevien tuotteiden tuotantoa.

Kolmas yleiskäyttöisen teknologian ominaisuus on, että sen edelleen kehittäminen voi jatkua pitkäänkin – siis samanaikaisesti kun teknologia on jo eri muodoissaan levinnyt melko laajastikin käyttöön yhteiskunnassa.

Esimerkkejä yleiskäyttöisistä teknologioista ovat esimerkiksi höyrykone, sähkö, puolijohdet, tietokoneet ja tieto- ja viestintäteknologia. Niillä kaikilla on edellä kuvattuja piirteitä.

Koneoppiminen (*machine learning*) on yksi tekoälyn osa-alue. Ohjatulla koneoppimisella (*supervised learning*) tarkoitetaan sitä, että tietokoneohjelma opetetaan tunnistamaan laajan tilastollisen opetusaineiston avulla säännönmukaisuuksia ja yhdistämään niitä lopputuloksiin, jotka ovat ennalta tiedossa. Kun ohjelma on oppinut riittävän hyvin opetusaineistossa olevat säännönmukaisuudet ja kun sen toimivuutta on tutkittu testiaineiston avulla, opetettua ohjelmaa voidaan soveltaa myös aineistoihin, joissa lopputulemat eivät (vielä) ole tiedossa. Tämä tarkoittaa, että koneoppimistehtävä on varsin usein ajateltavissa ennusteongelmana.

Esimerkiksi maksuvälinepetosten estämiseen tähtäävä ohjelmisto voidaan opettaa tunnistamaan ostostapahtumista ominaisuuksia, joiden perusteella se voi ennustaa, että kyseessä on todennäköisesti maksutapahtuma, jota

esimerkiksi luottokortin haltija ei tee itse. Vastaavan kaltaista koneoppimista sovelletaan muun muassa uusien lääkkeiden ja hoitomuotojen suunnittelussa, sairausdiagnoosien teossa, puheen- ja kuvantunnistuksessa, robottien ja kulkuneuvojen ohjaamisessa, roskapostien tunnistamisessa ja vaikkapa tekstien tai dokumenttien luokittelussa.

Toinen koneoppimisen muoto on ohjaamaton oppiminen (*unsupervised learning*). Hieman yksinkertaistaen tällä tarkoitetaan sitä, että tietokoneohjelma opetetaan opetusaineiston avulla esimerkiksi ryhmittelemään havaintoyksiköitä niiden havaittavien ominaisuuksien perusteella ilman, että näitä havaintoyksiköitä on opetusaineistossa yhdistetty mihinkään tiettyihin ennalta tiedossa oleviin lopputuloksiin. Tämän kaltaisen mallinnuksen tavoitteena on tyypillisesti moniulotteisen tilastoaineiston pelkistäminen tiiviimpään ja siten ehkä ymmärrettävämpään muotoon.

Koneoppimisella on jo nyt nähtävissä monia yleiskäyttöisen teknologian piirteitä. Ensinnäkin sillä vaikuttaa jo nyt olevan monia eri sovelluskohteita useilla toimialoilla. Toiseksi vaikka tarkempia tutkimustuloksia ei vielä olekaan saatavilla, on todennäköistä, että koneoppiminen on eri muodoissaan nopeuttanut teknologista kehitystä yhteiskunnan eri osa-alueilla. Ainakin siihen liittyvää uudenlaista yritystoimintaa on paljon. Kolmanneksi koneoppimismenetelmiä parannetaan koko ajan jatkuvasti, vaikka ne ovatkin jo alkaneet levitä erilaisten sovelluksien kautta yhä laajempaan käyttöön.

Edellä sanottu huomioon ottaen ei ole yllättävää, että myös taloustieteellisessä tutkimuksessa hyödynnetään ja tutkitaan yhä enemmän koneoppimista. Esimerkiksi Susan Athey (2018) on nostanut esiin sen, että taloustieteel-

linen ja ekonometrinen tutkimus voi myös myötävaikuttaa koneoppimismenetelmien kehitykseen. Näin on jo hieman tapahtunutkin.

Mikroekonometrinen tutkimus keskittyy usein syy-seuraussuhteiden tunnistamiseen, kuten esimerkiksi tietyn politiikan tai toimenpiteen vaikuttavuutta mittaavien malliparametrien identifioitiin ja harhattomaan estimointiin. Tämä tapahtuu tyypillisesti ainakin osin ekonometrisen mallin ennustekyvyn kustannuksella. Ohjatulla koneoppimisella ja mikroekonometrisella tutkimuksella on siten ainakin tietyssä määrin eri tavoite.

Athey (2017) on lisäksi korostanut eroa jonkin taloudellisen valintakäyttäytymisen ennustettavuuden ja sen välillä, miten kyseessä olevaan käyttäytymiseen voidaan jollakin toimenpiteellä vaikuttaa. Ennustettava käyttäytyminen ei tarkoita, että siihen kohdistettu toimenpide olisi automaattisesti vaikuttava.

Ekonometrisen tutkimuksen ja koneoppimisen välisestä yhteydestä voidaan tehdä muutama tarkentava havainto. Ensinnäkin koneoppimisessa laajasti hyödynnetyt laskentapohjaiset menetelmät voivat olla eri tavoin hyödyksi empiirisessä taloustieteellisessä tutkimuksessa. Ohjaamattomalla koneoppimisella voidaan esimerkiksi tuottaa ja pelkistää numeeriseen muotoon laajoja taloustieteellisesti mielenkiintoisia tekstiaineistoja ja muita alkujaan ei-määrällisiä aineistoja. Näin saadaan kokonaan uusia taloudellisen tarkastelun kannalta mielenkiintoisia kvantitatiivisia mittareita. Toisaalta näillä menetelmillä voidaan tuottaa hyvin suurista tilastoaineistoista helpommin ymmärrettäviä ja aineistoa tiiviistäviä muuttujia. Ohjaamattomalla koneoppimisella tuotettuja määrällisiä muuttujia voidaan sitten hyödyntää selittävänä ja selittävinä muuttujina ekonometrisessä tutkimuksessa (Athey 2018).

Empiirinen taloustieteellinen tutkimus voi hyöttyä oivalluksista, joita on tehty ohjatun koneoppimisen kehitystyössä. Yksi esimerkki osa-alueista, joissa ekonometrikoilla voi olla opittavaa, on järjestelmällinen (so. tiettyihin sääntöihin perustuva) aineistovetoinen ekonometrisen mallin valinta. Koneoppimisessa hyödynnetyt sääntöpohjaiset menetelmät ovat läpinäkyvämpiä ja ne kenties suojaavat tutkijaa muun muassa ylisovittamisen riskiltä paremmin kuin nykyiset ekonometrikkojen mallivalintamenettelyt. Yksi ohjatun koneoppimismenetelmien kiistaton etu on niiden kyky tunnistaa laajoista tilastoaineistoista ennalta tuntemattomia mutta yleistettävissä olevia säännön mukaisuuksia (Mullainathan ja Spiess 2017).

Toiseksi, ekonometrisella tutkimuksella voidaan laajentaa ja parantaa koneoppimismenetelmiä. Tässä voidaan mainita esimerkkinomaisesti kolme osa-aluetta, joilla tätä voidaan odottaa tapahtuvan. Ekonometrisen perustutkimuksen avulla voidaan ensinnäkin selvittää, onko koneoppimismenetelmien avulla mahdollista tunnistaa aikaisempaa luotettavammin tai monipuolisemmin taloudellisia ja muita syy-seuraussuhteita? Esimerkkejä tämän luonteisista tutkimuksista ovat Chernozhukov ym. (2017) ja Chernozhukov ym. (2018). Ekonometrisen ja tilastollisen perustutkimuksen avulla voidaan myös pyrkiä mittaamaan koneoppimismalleihin ja niiden ennusteisiin liittyvää tilastollista epävarmuutta. Lisäksi koneoppimismenetelmistä on löydettävissä yhtymäkohdita rakenteelliseen ekonometriseen (*structural econometrics*) tutkimukseen (Athey 2018 ja Igarashi 2018).

Taloustietelijät työskentelevät parhaillaan myös monien muiden koneoppimiseen liittyvien kysymysten parissa. Yksi esimerkki näistä on kysymys siitä, miten koneoppimiseen perus-

tuvat algoritmit saadaan sellaisiksi, että ne eivät syrji mitään ihmisryhmää, kun niitä käytetään päätöksenteossa tai sen tukena (Kleinberg ja muut 2018a). Toinen esimerkki se, milloin ja missä olosuhteissa koneoppimista voidaan ja kannattaa hyödyntää inhimillisen päätöksen tukena (Kleinberg ym. 2018b). Agrawal ym. (2018a, 2018b) ovat puolestaan pohtineet sitä, minkälaista aineistoa koneoppiminen tarvitsee, jotta sen avulla voitaisiin vastata elinkeinoelämää kiinnostaviin liiketaloudellisiin kysymyksiin.

Hyviä katsauksia koneoppimisen taloudellisiin ulottuvuuksiin ovat sekä NBER:n järjestämän tekoälyseminaarin pohjalta toimitettu monipuolinen ja ajatuksia herättävä kokoomateos *The Economics of Artificial Intelligence: An Agenda* että Agrawalin ym. kirjoittama (2018b) kirja, joka pohtii koneoppimisen mikro- ja liiketaloudellisia ulottuvuuksia. □

Kirjallisuus

- Agrawal, A., Gans, J. ja Goldfarb, A. (2018a), "Is your company's data actually valuable in the AI era?", *Harvard Business Review*, January 17, 2018.
- Agrawal, A., Gans, J. ja Goldfarb, A. (2018b), *Prediction Machines: The Simple Economics of Artificial Intelligence*, Harvard Business Review Press.
- Athey, S. (2017), "Beyond prediction: Using big data for policy problems", *Science* 355: 483–485, DOI: 10.1126/science.aal4321.
- Athey, S. (2018), "The impact of machine learning on economics", teoksessa Agrawal, A., Gans, J. ja Goldfarb, A. (toim.), *The Economics of Artificial Intelligence: An Agenda*, University of Chicago Press (tulossa).

- Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C., Newey, W. ja Robins, J. (2017), “Double/debiased machine learning for treatment and structural parameters”, *Econometrics Journal* 21: C1–C69, doi: 10.1111/ectj.12097.
- Chernozhukov, V., emirer, M., Duflo, E. ja Fernandez-Val, (2018), “Generic machine learning inference on heterogenous treatment effects in randomized experiments”, NBER Working Paper 24678.
- Igami, M. (2018), “Artificial intelligence as structural estimation: Economic interpretations of Deep Blue, Bonanza, and AlphaGo”, arXiv:1710.10967 [econ.EM], <https://arxiv.org/abs/1710.10967> (haettu 5.11.2018).
- Kleinberg, J., Ludwig, J., Mullainathan, S. ja Rambachan, A. (2018a), “Algorithmic fairness”, *American Economic Review, Papers & Proceedings* 108: 22–27, DOI: 10.1257/pandp.20181018.
- Kleinberg, J., Ludwig, J., Mullainathan, S. ja Rambachan, A. (2018b), “Human decisions and machine predictions”, *Quarterly Journal of Economics* 133: 237–293, doi.org/10.1093/qje/qjx032.
- Mullainathan, S. ja Spiess, J. (2017), “Machine learning: an applied econometric approach”, *Journal of Economic Perspectives* 31: 78–106, DOI: 10.1257/jep.31.2.87.
- Agrawal, A., Gans, J. ja Goldfarb, A. (toim.) (2018), *The Economics of Artificial Intelligence: An Agenda*, University of Chicago Press (tulossa).