

Kandidaatin tutkielma
Rikoksenuusinnan ennustaminen kausaalipäättelyllä

Riku Laine
Valtiotieteellinen tiedekunta, Sosiaalitieteden laitos, Helsingin yliopisto

11. maaliskuuta 2019

Sisältö

1	Esipuhe ja kiitokset	3
2	Tiivistelmä - Kypsyysnäyte?	4
3	Johdanto	5
3.1	Takuukäsittely prosessina	5
3.2	Yhteiskunnallinen merkitys	5
3.3	”Kausaalipäätely uutena paradigmana”	5
4	Data	6
4.1	COMPAS	6
4.2	Synteettinen	6
4.3	”Selective labels”	6
5	Metodit	7
5.1	Aiemmat tutkimukset	7
5.2	Validointimetodit	7
5.3	Kausaalipäätely	7
5.3.1	Johdanto	7
5.3.2	Merkinnät	7
5.3.3	Määritelmät	7
5.3.4	Malli	7
6	Tulokset	8
6.1	Synteettinen	8
6.2	Compas	8
7	Diskussio	10
	Kirjallisuutta	11

Liitteet	12
A Abstract in English	12

Luku 1

Esipuhe ja kiitokset

Tämä kandidaatin tutkielma on tehty yhteistyössä Helsingin yliopiston tietojenkäsittelytieteen osaston apulaisprofessorien \leftarrow TARKISTA Michael Mathioudakiksen ja Antti Hyttisen kanssa. He tarjosivat minulle aiheen ja merkittävää tukea tämän tutkielman tekoon.

Tämän tutkielman on tarkastanut XYZ.

Helsingissä XX.XX.2019

Luku 2

Tiivistelmä - Kypsyysnäyte?

Johdanto-luvussa esittelen ongelman asettelun ja tilanteen yleisen viitekeshyksen. Keskustelemme rikoksenuusinnan ennustamisesta yhdysvaltalaisessa oikeusjärjestelmässä. Esitän kappaleessa yleisen kuvauksen takuukäsittelyn etenemisestä oikeusprosessina, jonka jälkeen pohdin hieman takuukäsittelyn yhteiskunnallista merkitystä ja motivaatiota hyvään ennusteeseen. Kappaleen lopussa kirjoitan hieman kausaalipäätelystä uutena (?) paradigmana [3].

Kappaleessa *Data* esittelen käyttämäni datalähteet ja niiden ominaispiirteet. Esittelen kuinka COMPAS-datasetti (ref?) on luotu ja *jotain muuta*. Esitän myös kuinka olen luonut analyyseissä myöhemmin käytettävän synteettisen datasetin hyödyntäen Lakkarajun vuoden 2017 julkaisua [2].

Metodit-kappaleessa esitän käyttämäni mallit ja metodit. Esitän lyhyen katasauksen aikaisempaan kirjallisuuteen ja tukimuksiin tällä sovellusalalla. Käyn lisäksi läpi tässä tutkielmassa myöhemmin käytettäviä matemaattisia merkintöjä ja määritelmiä. Teen joitakin osoituksia ja osoitan kuinka mallimme ei riipu havaitsemattomista (unobservables) muuttujista.

Luvussa *Tulokset* esitän algoritmillani saavuttamani tulokset ja vertailen niitä Lakkarajun [2] saavuttamiin. Olen eritellyt erillisiin alalukuihin synteettisellä ja COMPAS-dataseteilla saavutetut tulokset.

Viimeisessä kappaleessa *Diskussio* esitän mallien ja tutkielmani virhelähteet ja muut ongelmat sekä keskustelen tulosten mahdollisesta vaikutuksesta, sikäli niitä sovellettaisiin sikkäläisen oikeuslaitoksen toimintaan.

Luku 3

Johdanto

Tämän tutkielman tavoitteena on muodostaa koneoppimisalgoritmi, jolla voidaan ennustaa yhdysvaltalaisen rikollisten rikoksen uusimisriskiä kausaalipäättelyä hyödyntävällä mallilla. Kausaalipäättelyä hyödyntämällä voimme rakentaa todennäköisyyslaskennallisen (probabilistic framework) kehyksen rikosten uusijoiden ennustamiseksi. Esitän tarvittavat merkinnät kappaleessa *Merkinnät* ja itse mallin tarkemmin kappaleessa *Malli*.

Onnkelma mallia selective labels.

3.1 Takuukäsittely prosessina

Yhdysvalloissa voi päästä vapaaksi rahaa vastaan. Tuomari arvioi rikollisen rikoksen uusimismahdollisuuden ja tekee siitä päätökseen takuu (bail) asetetaan ja kun se maksaa, niin pääsee pois. Takuu maksetaan kun palaa oikeuteen väliajan jälkeen.

Ongelmana tässä on se, millä perusteilla tuomarit tekevät päätöksen bailille pääsemisestä on käynyt ilmi (linkkaa propublica), että vaikka he käyttävät yhdysvaltalaisen yhtiön North

Vuokaavio oikeuskäsittelyn kulusta??

3.2 Yhteiskunnallinen merkitys

3.3 ”Kausaalipäättely uutena paradigmana”

Haluamme siirtyä assosiatiiivisesta päättelystä kausaalipäättelyyn, koska defnitiivisten päätösten tekeminen muuten hankalaa. Lisäksi on ylitettävä korrelaatio ei ole kausaatiota -kynnys, erityisesti [3].

Luku 4

Data

Tässä luvussa kuvaillaan käytetyt datasetit ja niiden ominaispiirteet.

4.1 COMPAS

4.2 Synteettinen

Synteettinen data luodaan, kuten Lakkaraju selostaa [2]. Ensinn koostettiin.

4.3 ”Selective labels”

Luku 5

Metodit

Tässä kappaleessa selostan analyyseissa, mallinnuksessa ja validoinnissa käyttämäni menet.

5.1 Aiemmat tutkimukset

Aiemmat tutkimukset ovat lähestyneet monesta näkökulmasta, mutta ilman kausaatio-

5.2 Validointimetodit

Ristiin taulukoinnit yms.

5.3 Kausaalipäätely

Erityisesti [3]

5.3.1 Johdanto

5.3.2 Merkinnät

5.3.3 Määritelmät

5.3.4 Malli

Luku 6

Tulokset

6.1 Synteettinen

6.2 Compas

Määritelmä 6.1. Jos X on diskreetti satunnaismuuttuja, joka saa arvokseen luonnollisia lukuja, niin X :n *todennäköisyysgeneroiva funktio* on

$$(6.2) \quad G_X(t) = \sum_{k=0}^{\infty} P(X = k)t^k = \sum_{k=0}^{\infty} p_k t^k.$$

Mikäli X :n arvojoukko on äärellinen ja arvojoukon jäsenten todennäköisyydet ovat nolasta poikkeavia, G_X on määriteltä kaikilla reaaliluvuilla t . Muutoin G_X on määriteltä ainoastaan niille $t \in \mathbb{R}$, joilla G_X suppenee. Koska pistetodennäköisyydet $p_k = P(X = k)$ ovat ei-negatiivisia ja summautuvat ykkäseksi, sarja suppenee ainakin suljetulla välillä $t \in [-1, 1]$.

Generoiva funktio voidaan odotusarvon avulla ilmaista muodossa

$$(6.3) \quad G_X(t) = E(t^X).$$

Lause 6.4. Jos X on diskreetti satunnaismuuttuja, joka saa arvokseen luonnollisia lukuja, niin X :n todennäköisyysgeneroiva funktio määrää X :n jakauman yksikäsitteisesti.

Todistus. Koska määritelmän mukaan G_X on ainakin välillä $[-1, 1]$ suppeneva potenssi-sarja, niin sillä on kaikkien kertalukujen derivaatat ainakin välillä $(-1, 1)$ ja

$$p_k = \frac{G_X^{(k)}(0)}{k!}, \quad k \in \mathbb{N}.$$

Tästä näemme, että G_X määrää luvut p_k ja täten X :n jakauman yksikäsitteisesti. □

Seuraavaksi esittelemme tutuimpien diskreettien jakaumien todennäköisyysgeneroivat funktiot. Jne. . .

Luku 7

Diskussio

Määritelmä 7.1. Jos X on satunnaismuuttuja ja odotusarvo $E(e^{tX})$ on olemassa, kun $|t| < \delta$, $\delta > 0$, niin X :n *momenttigeneroiva funktio* on

$$(7.2) \quad M_X(t) = E(e^{tX}).$$

Todennäköisyys- ja momenttigeneroivilla funktioilla on seuraava yhteys:

Lause 7.3. Jos X on diskreetti satunnaismuuttuja, jonka arvojoukko sisältyy joukkoon $\{0, 1, 2, \dots\}$, niin

$$M_X(t) = G_X(e^t)$$

edellyttäen, että G_X on olemassa, kun $|t| < 1 + \delta$, $\delta > 0$.

Todistus. Nyt

$$M_X(t) = E(e^{tX}) = E((e^t)^X) = G_X(e^t). \quad \square$$

Ja niin edelleen...

Kirjallisuutta

- [1] De-Arteaga, Maria, Artur Dubrawski ja Alexandra Chouldechova: *Learning under selective labels in the presence of expert consistency*. CoRR, abs/1807.00905, 2018. <http://arxiv.org/abs/1807.00905>.
- [2] Lakkaraju, Himabindu, Jon Kleinberg, Jure Leskovec, Jens Ludwig ja Sendhil Mullainathan: *The Selective Labels Problem: Evaluating Algorithmic Predictions in the Presence of Unobservables*. Teoksessa *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '17, sivut 275–284, New York, NY, USA, 2017. ACM, ISBN 978-1-4503-4887-4. <http://doi.acm.org.libproxy.helsinki.fi/10.1145/3097983.3098066>.
- [3] Pearl, J.: *An introduction to causal inference*. Int J Biostat, 6(2):Artikkeli 7, Helmikuu 2010. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2836213/>.

Liite A

Abstract in English

The contents...