




Inštitut za ekonomska raziskovanja
Institute for Economic Research



Metode ocenjevanja vzročnih učinkov ukrepov (causal inference)


Dr. Andrej Srakar

Inštitut za ekonomska raziskovanja, koordinator
projekta YoungStatS



Načrt predstavitve

- Kratko o podatkih SHARE
- Uvod v vzročnost
- Pristop potencialnih izidov
- Pristop grafičnih modelov (DAG)
- Nekaterne temeljne metode obeh pristopov
- Sodobnejši napredki
- Sklep



SHARE – Raziskava o zdravju, procesu staranja in upokojevanju v Evropi (The Survey of Health, Ageing and Retirement in Europe)

- **SHARE** je mednarodna multidisciplinarna longitudinalna raziskava, ki ugotavlja ekonomske, zdravstvene in socialne razmere prebivalstva starejšega od 50 let
- **Raziskovalna infrastruktura – zbirka mikropodatkov o posameznikih, starih 50 let in več**, v 27 evropskih državah in Izraelu (cca. 60.000–70.000 posameznikov oz. 3.000–4.000 v Sloveniji).
- **Od leta 2004** do danes je bilo izvedenih 9 valov raziskave; približno vsaki dve leti;
- **Vzorec je panelni**: anketiramo iste posameznike (+ osvežitev panela)
- **Slovenija** se je priključila v 4. valu (leta 2011) – Načrt razvoja raziskovalnih infrastruktur 2011–2020.

- 2004 – Začetek raziskave; poziv Evropske komisije k vzpostavitvi longitudinalne ankete o staranju v državah članicah EU
- 2008 – Raziskava SHARE je uvrščena v Evropski strateški forum raziskovalnih infrastruktur (ESFRI)
- 2011 – SHARE postane prvi Evropski raziskovalni infrastrukturni konzorcij (ERIC): SHARE-ERIC & **začetek SHARE v Sloveniji**
- 2016 – Evropski strateški forum za raziskovalne infrastrukture (ESFRI) uvrsti SHARE-ERIC med ESFRI „landmark“.
- 2022 – Svet SHARE-ERIC potrdi nadaljevanje raziskave SHARE po letu 2024

- **Longitudinalna zasnova:** dveletna zasnova panela omogoča zajetje dinamičnosti procesa staranja.
- **Multidisciplinarnost:** povezovanje ekonomskih, socialnih in zdravstvenih kazalnikov zagotavlja širšo sliko procesa staranja.
- **Primerljivost med državami:** predhodno harmonizirana mednarodna zasnova (vzorčni načrt, vprašalnik, zbiranje podatkov) zagotavlja primerljivost podatkov za vse vključene države.
- **Mednarodna razsežnost:** Podatki so harmonizirani tudi z ameriško raziskavo Health and Retirement Study (HRS) in angleško raziskavo English Longitudinal Study of Ageing (ELSA); SHARE postal model za zasnovo številnih drugih raziskav o staranju po svetu.



Dostop do podatkov

- Podatki so dostopni raziskovalcem, profesorjem in študentom oziroma **v raziskovalne namene** ob predhodni registraciji: <https://share-eric.eu/data/data-access>
- Podatki so na voljo **brezplačno**
- Uporaba podatkov v druge namene, ki niso raziskovalni, ni dovoljena
- Podatkovna zbirka SHARE je na voljo v statističnih programskih paketih **Stata** in **SPSS** (*easySHARE* tudi v **R**).

SHARE-ERIC: www.share-eric.eu

SHARE Slovenija: www.share-slovenija.si




Vsebina podatkovne zbirke SHARE

Kontekst

Ekonomski kazalniki

Trenutna delovna aktivnost, značilnosti zaposlitve, viri in sestava dohodka, premoženje, potrošnja, bivalne razmere, izobrazba ...



Socialni kazalniki

Zakonski stan, otroci, socialno omrežje, neformalna pomoč, finančni in materialni transferji

Zdravstveni kazalniki

Fizično in duševno zdravje, biomarkerji, kognitivne funkcije, zdravju tvegano vedenje, zdravstvena oskrba ...

Vsebina - socialni dejavniki

- **Demografski podatki (DN):** starost, spol, država rojstva, državljanstvo, izobrazba, zakonski stan, podatki o starših, bratih in sestrah, stiki s starši
- **Otroci (CH):** Podatki o otrocih (spol, leto rojstva, zakonski stan, zaposlitev, izobrazba, bivališče)
- **Bivalni pogoji (HO):** Vrsta in značilnosti bivališča, lastništvo, stroški najemnine, lastništvo nepremičnin in dohodki iz tega naslova, hipoteka
- **Socialna opora (SP):** Neformalna pomoč, ki jo je oseba prejela od članov družine ali prijateljev oz. jo je nudila tem osebam (komu /od koga, kako pogosto)
- **Socialna omrežja / 4., 6., 8., 9. val (SN):** pogostost stikov, čustvena bližina, geografska bližina, zadovoljstvo z omrežjem
- **Aktivnosti (AC):** prostovoljstvo, prostočasne aktivnosti, zadovoljstvo z življenjem
- **Pričakovanja (EX):** pričakovana življenjska doba, upanje za prihodnost
- **Uporaba računalnika & interneta, 5. val → (IT):** uporaba računalnika pri delu, računalniška pismenost, uporaba interneta (dodatna vprašanja v 10. valu)
- **Poraba časa, 8., 9. val → (TE) :** dnevna poraba časa za različne aktivnosti

Vsebina - ekonomski kazalniki

- **Zaposlitveni položaj, pokojnine (EP):** zaposlitveni položaj, vrsta zaposlitve, značilnosti zaposlitve, spremembe zaposlitve, leto in razlogi za upokožitev, višina letnega dohodka, vrsta in višina pokojnine, čas prejemanja pokojnine, morebitni prejemki iz javnih virov/socialni prejemki, druga izplačila ali transferji (življenj. zavar., preživitnine, dodatno pokojninsko zavar.)
- **Dohodki gospodinjstva (HH):** razpoložljiv dohodek gospodinjstva, morebitne podpore
- **Premoženje:** Vrste in višina prihrankov in naložb (individualni pokojninski račun, delnice in obveznice, pogodbeno varčevanje, hranilne vloge, življenj. zavarov., lastništvo podjetij, vrednost vozil, vrednost dolgov)
- **Potrošnja (CO):** izdatki gospodinjstva za prehrano, shajanje z dohodkom, opustitev potrošnje določenih dobrin zaradi potrebe po znižanju stroškov (dodatne spremenljivke v 5. valu)
- **Finančni in materialni transferji (FT):** Dajanje in prejemanje materialnih ali finančnih daril ali podpore (komu/od koga, znesek)
- **Obžalovanje varčevalnih navad, 8. val (SR):** Finančna presenečenja v življenju, potrošnja in varčevanje po 45. letu

- **Fizično zdravje (PH):** Samoocena zdravja, število in vrsta kroničnih bolezni, kdaj je bila bolezen diagnosticirana, druge zdravstvene težave, zdravila, ki jih jemlje R, stanje vida in sluha, zdravje zob, vrste težav pri opravljanju vsakodnevnih aktivnosti
- **Vedenjska tveganja (BR):** Kajenje, pitje alkohola, fizična aktivnost, prehrana
- **Duševno zdravje (MH):** Znaki depresije po Evropski lestvici depresivnosti (EURO-D), velikih pet faktorjev osebnosti (BFI-10)
- **Zdravstveno varstvo (HC):** Obiski pri zdravniku in zobozdravniku, bivanja v bolnišnici ali na negovalnem oddelku doma za starejše, oskrba na domu, jemanje zdravil, izdatki iz žepa za zdravstveno oskrbo (5. val), opustitev zdravstvene oskrbe zaradi finančnih težav ali nedostopnosti storitve
- **Kognitivne funkcije (CF):** Orientacija v času, spomin, verbalne sposobnosti in računske sposobnosti; kognitivni testi (risanje, poimenovanje stvari, štetje nazaj)

1. Fizične meritve:

- Moč stiska pesti (vsi valovi)
- Hitrost hoje (1. val)
- Moč izdiha (merjenje pljučne kapacitete (2. in 4. val)
- Vstajanje s stola (2. in 5. val)
- Meritve gibanja (Axivity ax3) (8. val), (10 držav vključno s Slovenijo)



2. Biomarkerji – vzorci posušenih kapljic krvi

- 4. val, Nemčija
- 6. val, vzorci posušenih kapljic krvi (10 držav vključno s Slovenijo)



- **Zaključna anketa/end-of-life interview (XT):** vprašalnik o zadnjem letu življenja pokojnega respondenta; odgovarja oseba iz „bližnje“ socialne mreže umrlega anketiranca; vprašamo o zdravju v zadnjem letu življenja, okoliščinah smrti (čas, kraj in vzrok smrti), premoženju in razdelitvi premoženja.
- **Vprašalniki za samoizpolnjevanje/drop-off (dropoff):** izbirni, nacionalno specifični vprašalnik
 - Slovenija: tematika dolgotrajne oskrbe (6. – 9. val), poraba časa za dnevne aktivnosti (7. val), poznavanje pokojninskega sistema, mnenja o potrebnih spremembah, upokojevanje; telemedicina (9. val)

Uvod v vzročnost

Chamberlain Seminar
Home
Past Seminars
Feedback and Speaker/Discussion Suggestions



The Gary Chamberlain Online Seminar in Econometrics

A regular open online international inter-institutional econometrics seminar in honor of Gary Chamberlain (1948-2020). You can find Gary Chamberlain's doctoral dissertation here, as well as a set of lecture notes here for a graduate econometrics class taught at Harvard in 2010, courtesy of Paul Goldsmith-Pinkham. Here is a [link to a paper](#) by Gary recently published in the journal of Econometrics.

Mailing List

To stay up to date about upcoming presentations please [join our mailing list](#)

Upcoming Seminar Presentations

All seminars are Fridays at noon ET (5pm London / 11am CT / 9am PT).
The Chamberlain Seminar is on summer break and will return in September.

Seminar Calendar

Monday 19 June
Displaying events after 19th. [Link for earlier events](#)
Displaying events until 31/7. [Link for later](#)

Format and Rules

The seminars are held on Zoom and last 90 minutes:

- 60 minutes of presentation
- 15 minutes total of comments and questions by two or three designated panelists

OCIS

Home Past Talks and Recordings Instructions for Attendees Opportunities in Causal Inference Credits and Links

Online Causal Inference Seminar

A regular international causal inference seminar.

Mailing List

To stay up-to-date about upcoming presentations and receive Zoom invitations please [join our mailing list](#). You will receive an email to confirm your subscription. If you are already subscribed to our mailing list and would like to unsubscribe, you may [unsubscribe here](#).

Suggest a speaker

If there is anyone you would like to hear at the Online Causal Inference Seminar, you may let us know [here](#).

Opportunities in Causal Inference

Please check out our [opportunities in causal inference](#) page for conferences, workshops, and job listings! If you would like us to list an opportunity, please email us at onlinecausalinferenceseminar@gmail.com.

Youtube channel

Follow us on [youtube](#)

Upcoming Seminar Presentations

All seminars are on Tuesdays at 8:30 am PT / 11:30 am ET / 4:30 pm London / 5:30 pm Berlin / 11:30 pm Beijing.

Stay tuned for our fall schedule after the summer break!

One World Project
About
Mailing List
One World Probability Seminar
One World School
Our Goals
Other Worlds



One World Probability project

Welcome to the One World Probability project!

The One World Probability project is an online platform for research seminars, workshops and schools in probability theory. Started during the Covid-19 epidemic in 2020, the project intends to bring together researchers from all over the world in a virtual and inclusive environment. The project is a community-wide initiative supported by the [Bernoulli Society](#) and the [Institute of Mathematical Statistics](#). It runs the regular online One World Probability Seminar, and supports online workshops and schools.

The project has an experimental character. We will need to understand how to work with online tools and learn how to deal with the vulnerabilities and bottlenecks of online traffic. Please join us in the long journey ahead!

The project benefits from many volunteers from all over the world that help to chair seminar talks, organize schools, design websites (thanks to András Gábori and others), etc.

**Bernoulli Society**
for Mathematical Statistics
and Probability

Advances in Difference-in-Differences in Econometrics

**Clement**

**Andrej Srakar**


**Lihua Lei**

**Jonathan Roth**

**Pedro Sant'Anna**


**Brantly Callaway**

zoom



O korelaciji, regresiji in vzročnosti



Regresija (desno: Francis Galton):
Regresijska analiza se ukvarja s preučevanjem odvisnosti ene spremenljivke od ene ali več drugih spremenljivk z namenom ocenjevanja in/ali napovedovanja povprečne vrednosti spremenljivke v populaciji ali povprečne vrednosti prve spremenljivke glede na znane vrednosti druge.



O korelaciji, regresiji in vzročnosti


Primer regresije:

- Napovedovanje povprečne višine sinov ob poznavanju višine njihovih očetov




O korelaciji, regresiji in vzročnosti

Regresija proti Vzročnosti




Vzročna zveza kaže na razmerje med dvema spremenljivkama, kjer na eno spremenljivko vpliva druga.



O korelaciji, regresiji in vzročnosti

Regresija proti Korelaciji


Korelacija	Regresija
Korelacija je statistična mera, ki določa soodnos ali povezanost dveh spremenljivk.	Regresija opisuje, kako je neodvisna spremenljivka številčno povezana z odvisno spremenljivko.
Za predstavitev linearne povezave med dvema spremenljivkama.	Prilagoditi najboljšo črto in oceniti eno spremenljivko na podlagi druge spremenljivke.
Ni razlike med odvisnimi in neodvisnimi spremenljivkami.	Obe spremenljivki sta različni.
Korelacijski koeficient kaže, v kolikšni meri se dve spremenljivki gibljeta skupaj.	Regresija kaže vpliv spremembe enote znane spremenljivke (x) na ocenjeno spremenljivko (y).
Iskanje številske vrednosti, ki izraža odnos med spremenljivkami.	Oceniti vrednosti slučajne spremenljivke na podlagi vrednosti fiksne spremenljivke.




O korelaciji, regresiji in vzročnosti

Navidezne korelacije


**MORE IPHONES MEANS
MORE PEOPLE DIE FROM
FALLING DOWN STAIRS**



**LET'S CHEER ON
THE TEAM, AND
WE'LL LOSE WEIGHT**




**TO INCREASE AUTO
SALES, MARKET TRIPS
TO UNIVERSAL ORLANDO**




Osnove vzročnosti



Correlation = 0.95



Kaj želimo oceniti?



Dejanski „svet“




Zakaj zna biti ocenjevanje zapleteno?




To je največkrat razlog, da nastopijo težave „korelacija ni enako vzročnost“ (t.i. confounding)

A TEH TEŽAV JE LAHKO VEČ!





Denimo, da nas zanima spodnje





Valovanje




Nevretenčarji
(denimo
mehkužci,
spužve, iglokožci)



Opraviti pa imamo s spodnjim vzročnim diagramom



Naš cilj je razmišljanje „nasprotnih dejstev“: Kaj bi se zgodilo, če ... za celotno preučevano okolje!





Sedanjšost




Bližnja prihodnost



Oddaljena prihodnost




Preprosto razmišljanje v bistvu razumevanja vzročnosti



- Želimo oceniti **Povprečni vzročni učinek** valovanja na nevretenčarje
- Opazujemo *Nevretenčarje ob prisotnosti valov* vs. *Nevretenčarje brez prisotnosti valov*
- Zanima nas pojav na ravni POPULACIJE – **Povprečni učinek tretmaja**
- Iz naših opazovanj lahko vidimo samo kaj se dogodi z in brez prisotnosti valov v vzorcu, ki nam je na voljo
- Kaj bi se dogodilo, če bi naša kontrolna opazovanja imela kot protipol „tretmaje“? Ali bi naša opažanja še vedno veljala?

Povprečni učinki tretmaja so več kot opažene „razlike“



- ATE = [Opazovanje s tretmajem –


Kaj bi se dogodilo s tretiranimi opazovanji, če tretmaja ne bi prejela]

+

[Kaj bi se dogodilo s tretiranimi opazovanji, če tretmaja ne bi prejela –


Opazovanje brez tretmaja]

- Slednje poznamo pod imenom **pristranost izbora** (angl. selection bias)
- Gre za ogrodje pristopa **Potencialnih izidov**





Povprečni vzročni učinek: razlika med dejansko resničnostjo in potencialnim izidom

Opazovanje nevretenčarjev na valovitem mestu – Kaj bi bilo tam brez valov




—



Priistranost izbora: razlika med potencialnim izidom in dejansko resničnostjo

Opazovanje nevretenčarjev na mestu brez valov – Kaj bi bilo tam brez valov

Imagined



Sites 1 and 2




Dejansko



Sites 3 and 4




Brez pristranosti izbora



Priistranost izbora: razlika med potencialnim izidom in dejansko resničnostjo

Opazovanje nevretenčarjev na mestu brez valov – Kaj bi bilo tam brez valov

Imagined




Sites 1 and 2




Dejansko




Sites 3 and 4



Nekaj pristranosti izbora




Povprečni učinki tretmaja so več kot opažene „razlike“




- $ATE = \text{Povprečni vzročni učinek} + \text{Pristranost izbora}$
- Naša naloga je odpraviti pristranost izbora
- S pomočjo **eksperimentov** lahko odpravimo pristranost izbora tako, da odpravimo vzvode pristranosti
- S pomočjo **opazovalnih študij** lahko odpravimo pristranost izbora s pozornim oblikovanjem vzročnega modela






DAG-i nam pomagajo pogledati možne vire pristranosti v vzorčenju




- Kaj bi izpustili, če bi izbrali samo mesta/lokacije, kjer se nahajajo haluge?
- Kaj bi izpustili, če bi izbrali samo mesta/lokacije, kjer se nahajajo redke alge?
- Če imamo pristrano vzorčenje, kaj moramo vključiti v naše modele, da bodo točni in da preprečimo upadanja/nihanja učinkov?




DAG-i nam pokažejo možna odprta „zadnja vrata“ do pristranosti izbora



DAG-i + Nasprotna dejstva=Jasno sklepanje





- Z DAG-om lahko vidimo, da v našem primeru ni nobenih zunanjih vzvodov pristranosti izbora
- Razmišljanje nasprotnih dejstev lahko uporabimo, da razumemo učinke spreminjajočih se valov skozi preučevani sistem
- Na primeru lahko tudi vidimo, katere spremenljivke lahko izkrivijo (vplivajo na) naša sklepanja iz nasprotnih dejstev



Randomizirani vzorčni dizajn



Poskus repliciranja eksperimentov

Odpraviti pristranost izbora preko randomiziranja lokacij/mest





Stratificirani randomizirani vzorčni dizajn (SRD)

Naključno izberemo položaj glede na višino
Sprehod skozi naklon/gradient dolžine



Številne oblike SRD




Rubinov vzročni model – pristop potencialnih izidov

- Kot osnovo formalnejše razlage ocenjevanja vzročnih učinkov bomo uporabili vzročni model Donald B. Rubina (1974 – osnove temeljijo na magistrski tezi Jerzyja Neymana iz 1923, ime pa je dal Paul W. Holland v članku iz 1986) oziroma pristop potencialnih izidov (potential outcomes)
- Ključne točke:
 - Vzročnost je vezana na dejanje (intervencijo/tretma)
 - Vzročni učinek ocenjujemo kot primerjavo potencialnih rezultatov/izidov
 - Modeliranje mehanizma dodelitve tretmaja
- Kakšen je učinek tretmaja na izid?
- Kako bi se izid razlikoval, če bi prejeli „nasprotni“ tretma?




Rubinov vzročni model – pristop potencialnih izidov

- Primeri vzročnih vprašanj:
 - Kakšen je učinek študija na rezultate izpitov?
 - Ali pošiljanje sporočil med vožnjo povzroča nesreče?
 - Ali vam jutranja vadba daje več energije čez dan?
 - Se učenci bolje učijo v manjših razredih?
 - Je do razmerja prišlo, ker je bil vpleten alkohol?



Rubinov vzročni model – pristop potencialnih izidov

- Ključno vprašanje: kaj bi se zgodilo v primeru nasprotne situacije?
- Potencialni izid je vrednost spremenljivke izida (angl. outcome) za dano vrednost tretmaja
- Spremenljivka rezultata: Y
 - Y (tretma): rezultat/izid tretmaja
 - Y (kontrolna skupina): rezultat/izid v kontrolni skupini brez tretmaja
- Vzročni učinek je primerjava potencialnega izida skupine s tretmajem s potencialnim izidom v kontrolni skupini
- Za izračun učinka največkrat upoštevamo osnovno enačbo:
- Vzročni učinek = Y (tretma) – Y (kontrolna skupina)



Rubinov vzročni model – pristop potencialnih izidov

- Povprečni učinek tretmaja v populaciji (PATE):

$$\tau_P = \mathbb{E}[Y_i(1) - Y_i(0)]$$

- Povprečni učinek tretmaja na vzorcu (SATE):

$$\tau_S = \frac{1}{n} \sum_{i=1}^n [Y_i(1) - Y_i(0)]$$

- Ključna predpostavka – Stable Unit Treatment Value Assumption (SUTVA): za vsako enoto imajo vsi tretmaji enake možne vrednosti; tretma ene enote nima vpliva na tretma druge enote (če je to kršeno: treatment effects with network interference).
- Če imamo opravka z opazovalnimi študijami, je izziv, da so mehanizmi določanja tretmaja neznani, zato se lahko posamezniki v različnih skupinah (tretma in kontrolna skupina) razlikujejo v pomembnih neopazovanih značilnostih. Zato navadno potrebujemo še izpolnjeni predpostavki »uncounfoundedness« (da v modelu ni spremenljivk, ki pomembno vplivajo na rezultate, v model pa niso vključene) ter »pozitivnost« (verjetnost vsake enote, da je vključena bodisi v tretma ali kontrolno skupino je večja od 0 in manjša od 1).



Rubinov vzročni model – pristop potencialnih izidov

- Stopnja nagnjenja (angl. propensity score) je definirana kot pogojna verjetnost tretmaja glede na dane kontrolne spremenljivke:

$$e(x) = \Pr(W = 1|X)$$

- Zelo pogosto so v uporabi »utežene« cenilke vzročnih učinkov, ki uravnotežijo učinke v posameznih vzročnih skupinah. Primeri so Inverse Propensity Weighting (IPW), dvojno-robustna/augmented IPW (AIPW), Horvitz-Thompson ter Hajekova cenilka.


$$\hat{t}_{IPW} = \hat{t}_{IPW,1} - \hat{t}_{IPW,0} = \frac{1}{n} \sum_{i=1}^n \frac{Z_i Y_i^{obs}}{\hat{e}(X_i)} - \frac{1}{n} \sum_{i=1}^n \frac{(1 - Z_i) Y_i^{obs}}{1 - \hat{e}(X_i)}$$

$$\hat{t}_{DR} = \hat{t}_{DR,1} - \hat{t}_{DR,0} = \frac{1}{n} \sum_{i=1}^n [\hat{\mu}_1(X_i) - \hat{\mu}_0(X_i)] + \frac{1}{n} \sum_{i=1}^n \left[Z_i \frac{Y_i^{obs} - \hat{\mu}_1(X_i)}{\hat{e}(X_i)} - (1 - Z_i) \frac{Y_i^{obs} - \hat{\mu}_0(X_i)}{1 - \hat{e}(X_i)} \right]$$

$$\pi_k = \frac{nx_k}{\sum_{i=1}^N x_i}$$

$$\hat{t}_{HT} = \sum_{k \in S} y_k / \pi_k$$


$$\hat{t}_{Hajek} = n \frac{\sum_{k \in S} y_k / \pi_k}{\sum_{k \in S} 1 / \pi_k}$$



Rubinov vzročni model – pristop potencialnih izidov

- Pri pristopih instrumentalnih spremenljivk, kot sta Local Average Treatment Effects (LATE) in splošnejši IV pristopi, modeliramo tudi dejansko prejemanje tretmaja.
- Vsaka enota je povezana z dvema potencialnima izidoma glede na prejeti tretma, $W_i(0)$ in $W_i(1)$. Enote lahko sedaj razdelimo v podskupine na strinjajoče (compliers), nikoli pristajajoče (nevertakers), odklonilne (defiers) ter vedno pristajajoče (alwaystakers). Formalneje lahko zapišemo kot spodaj:

$$C_i = \begin{cases} \text{Nevertakers (nt)} & W_i(0) = 0, W_i(1) = 0 \\ \text{Compliers} & W_i(0) = 0, W_i(1) = 1 \\ \text{Defiers} & W_i(0) = 1, W_i(1) = 0 \\ \text{Alwaystakers} & W_i(0) = 1, W_i(1) = 1 \end{cases}$$



Osnove grafičnih modelov

- Naj bo naključni vektor $X_{[p]} = (X_1, \dots, X_p)$. Linearni sistem strukturnih enačb potem sestoji iz enačb oblike:

$$X_i = \beta_{0i} + \sum_{j \in pa(X_i)} \beta_{ji} X_j + \epsilon_i, \quad i = 1, 2, \dots, p$$


- kjer $pa(X_i)$ označuje nabor spremenljivk, ki so očetje (neposredni predhodniki) X_i , $\epsilon_1, \dots, \epsilon_p$ pa so vzajemno neodvisne slučajne napake s pričakovano vrednostjo 0, β_{ji} pa označujejo vzročne učinke spremenljivke X_j na X_i .
- Kovarianco med posameznima spremenljivkama lahko zapišemo kot:

$$Cov(X_i, X_j) = \sum_{(d_0, \dots, d_m) \in D(i, j)} \prod_{k=1}^m \beta_{d_{k-1} d_k}$$

- kjer je $D(i, j)$ nabor d -povezanih poti med i in j .
- Prav tako lahko zapišemo vzročni učinek X_i na X_j kot:

$$c(X_i \rightarrow X_j) = \sum_{(d_0, \dots, d_m) \in G(i, j)} \prod_{k=1}^m \beta_{d_{k-1} d_k}$$

- kjer je $G(i, j)$ nabor usmerjenih poti med i in j .
- Korelacija med X_i in X_j pomeni vzročno povezavo le če velja $D(i, j) = G(i, j)$, t.j. če so vse d -povezane poti med i in j tudi usmerjene poti.



Osnove grafičnih modelov




Figure 2: An Example of a DAG









Figure 3: An Example of a Collider in a DAG






Nekatere najbolj znane metode – pristopi instrumentalnih spremenljivk



Nekatere najbolj znane metode – metode regresijske prekinitve



Nekatere najbolj znane metode – pristopi razlike-v-razlikah



Nekatere najbolj znane metode – metode sintetičnih kontrol






Figure 2: Predictions for per capita smoking rates for selected states, using as training data all years prior to the year indicated on the x-axis. The true yearly per-capita smoking $Y_{i,t}$ is in black. SDID estimates are in red. SC estimates are in blue. DID estimates are in teal.



Nekatere najbolj znane metode – vzročna analiza posredovanosti



To estimate natural indirect and direct effects, since treatment A is randomized, estimating $E(Y^{(1)})$ and $E(Y^{(0)})$ is standard. We focus on $E(Y^{(1,M^{(0)})})$. Under strong conditions, with C all pre-treatment common causes of mediator M and outcome Y , the **Mediation Formula**³ holds:

$$E(Y^{(1,M^{(0)})}) = \int_{(m,c)} E[Y|M=m, C=c, A=1] f_{M|C=c, A=0}(m) f_C(c) dm dc. \quad (1)$$



(1) was proven under cross-worlds (see Introduction) assumptions. In addition, most causal mediation approaches^{2–12} need many counterfactual outcomes: not only $Y^{(1,M^{(0)})}$, also all $Y^{(a,m)}$: the outcomes under treatment a with the mediator set to m .

Under linear models and outcome models without exposure-mediator interaction, the resulting estimators for the indirect and direct effect are the same as in the original mediation approach,¹ and thus add a causal interpretation. Natural and randomized indirect and direct effects include all outcome types, with causal interpretations.


3.2 Organic indirect and direct effects: an intervention-based approach avoiding cross-worlds counterfactuals/assumptions




Nekatere najbolj znane metode – Bayesova omrežja



Maximally oriented Partially Directed Acyclic Graph (MPDAG) $\mathcal{G}$.




Nekatere najbolj znane metode – pristopi večkrakih banditov in adaptivni vzročni dizajni



Nekatere najbolj znane metode – vzročni naključni gozdovi

Inference in CATE for young and older households from the Moroccan microcredit dataset, [frans from Jacob \(2021\)](#)




```
11 df_yf = pd.DataFrame(yf, columns=['yf'])
12 df_of = pd.DataFrame(of, columns=['of'])
13
```


Nekatere najbolj znane metode – Bayesova aditivna regresijska drevesa (BART)

Iteration 4


Tree 1




Tree 2



Tree 3



Tree 4



Nekateri sodobnejši trendi razvoja

- Vzročnost za podatke časovnih vrst






Figure 4: NonStGM selection with node-wise regression for a $p = 10$ dimensional system. [Left]: True graph structure. [Middle]: Heat map of $\hat{W}_{self}$ showing conditional noncorrelation captured by the edges. [Right]: Heat map of $\hat{W}_{other}$ showing conditional nonstationarity of node 5. Results are aggregated over 20 replicates.

Nekateri sodobnejši trendi razvoja

- Vzročnost za visokodimenzionalne podatke – matrično in tenzorsko dopolnjevanje podatkov



Nekateri sodobnejši trendi razvoja

- Vzročnost za podatke analize omrežij





Figure 1: An example of a Network Granger causal model with two non-overlapping groups observed over $T = 4$ time points



Nekateri sodobnejši trendi razvoja

- Vzročnost v strojnem učenju in podatkovni znanosti: causal AI





Figure 5.2: The benefit of SSL depends on the causal structure. Each column of points corresponds to a benchmark data set from the UCI repository and shows the performance of six different base classifiers augmented with self-training, a generic method for SSL. Performance is measured by percentage decrease of error relative to the base classifier, that is, $(\text{error}(\text{base}) - \text{error}(\text{self-train})) / \text{error}(\text{base})$. Self-training overall does not help for the causal data sets, but it does help for some of the anticausal/confounded data sets [from Schölkopf et al., 2012].



Nekateri sodobnejši trendi razvoja

- Razvoj grafičnih modelov vzročnosti




Figure 9.3: Starting with an SCM on the left-hand side, the three graphs on the right encode the set of conditional independences ($A \perp\!\!\!\perp C$). Due to an erroneous causal interpretation, the DAG is not desirable as an output of a causal learning method. In this example, the IPG and the latent projection (ADMG) are equal to the MAG.





Figure 9.4: This example is taken from Richardson and Spirtes [2002, Figure 2(i)]. It shows that DAGs are not closed under marginalization. There is no DAG over nodes $\mathbf{O} = \{A, B, C, D\}$ that encodes all conditional independences from the graph including H .



Nekateri sodobnejši trendi razvoja

- Pomen Bayesovih pristopov v analizi vzročnosti

Choice of nonparametric priors: A toy example






Figure: Estimates of counterfactuals and CATE and corresponding uncertainty band as a function of the single covariate 'Age' by: linear model (LM), Gaussian Process (GP), BART. ×: treated; ○: control.



Posebej – vzročnost in strojno učenje: TMLE (ciljano ocenjevanje največjega verjetja)



Posebej – vzročnost in strojno učenje: DDML (dvojno nepristrano ocenjevanje ML)

DMLDiD : Chang (2020)

$$\theta^{DMLDiD} =$$

$$\frac{1}{n} \sum_{i \in I_k} \left(Y_i(1) - Y_i(0) - \hat{\ell}_{1k}(X_i) \right) \times \frac{D_i - \hat{g}_k(X_i)}{\hat{p}_k(1 - \hat{g}_k(X_i))}$$

Predictive model
(supervised learning)

Label = Diff.

$$\hat{\ell}_{1k} = \arg \min \left[\frac{1}{M_k} \sum_{i \in I_k^c} (1 - D_i) (Y_i(1) - Y_i(0) - \ell_{1k}(X_i))^2 \right]$$

Cross fitting

separates samples for "fitting" and "prediction" as in Chernozhukov (2018)

Learning with control group only

Definition 3.1.

(a) Take a K -fold random partition $(I_k)_{k=1}^K$ of observation indices $[N] = \{1, \dots, N\}$. For simplicity, assume that each fold I_k has the same size $n = N/K$. For each $k \in [K] = \{1, \dots, K\}$, define the auxiliary sample $I_k^c \equiv \{1, \dots, N\} \setminus I_k$. (b) For each k , construct the intermediate ATT estimators,



Sklep

- Področje vzročnega sklepanja je od moje pretekle, lanskoletne predstavitve *precej zraslo* v smislu metodološkega razvoja in števila raziskovanj in raziskovalcev v matematični statistiki, ekonometriji in podatkovni znanosti
- Tvori enega od ogrodij napovedanega eksplozivnega razvoja umetne inteligence oziroma „dobe AI“, v kateri naj bi se po nekaterih trenutnih izjavah nahajali z razvojem velikih jezikovnih modelov (ChatGPT)
- Trenutno je razpeto med dva med seboj rivalska pristopa – *potential outcome* ter *directed acyclic graphs* (poznamo tudi dve alternativni temu: Philip Dawid; in predvsem T. Richardson in J. Robins: Single World Intervention Graphs/SWIG, ki kot *edini doslej povezuje oba nasprotna pristopa*)
- Različni pogledi na vzročnost v statistiki in ekonometriji: opazovalni vs. eksperimentalni podatki – ključno za analize politik!!
- Trenuten razvoj grafičnih modelov, ki so prišli bolj v ospredje raziskovanj (npr. MPDAG, CPDAG, PAG, MAG, pomembne nove teme, kot je *vzročnost ob prisotnosti premika porazdelitev* in mnoge druge, povezane s causal AI)
- Trenutno osrednje teme pristopa potencialnih izidov: multivalued treatments; metode sintetičnih kontrol; povezave z Bayesovimi pristopi in strojnim učenjem
- *Trenutno osrednje teme prihodnjega razvoja področja*: vzročnost za časovne podatke; vzročnost za podatke omrežij; vzročnost za nizkodimenzionalne reprezentacije visokodimenzionalnih podatkov (denimo matrix in tensor completion)

NAJLEPŠA HVALA ZA POSLUŠANJE
(IN VPRAŠANJA)!

srakara@ier.si

