

Wnioskowanie przyczynowe przez pryzmat modelu Neymana-Rubina

Seminarium: Informatyka politycznie poprawna

Mateusz Maciejewski, Piotr Ostropolski-Nalewaja

Instytut Informatyki Uniwersytetu Wrocławskiego

19 stycznia 2021

"Validity of causal models" (fairml s. 110)

Główny, lecz dotychczas nieporuszany problem, odnosi się do pytania, czy dany model przyczynowy (graf), jakkolwiek modeluje rzeczywistość.

"Validity of causal models" (fairml s. 110)

Główny, lecz dotychczas nieporuszany problem, odnosi się do pytania, czy dany model przyczynowy (graf), jakkolwiek modeluje rzeczywistość.

Diagramy przyczynowe są schematami wierzchołków i krawędzi, które podsumowują istniejącą wiedzę naukową.^a

^aPearl, Mackenzie, „The Book of Why”

"Validity of causal models" (fairml s. 110)


Główny, lecz dotychczas nieporuszany problem, odnosi się do pytania, czy dany model przyczynowy (graf), jakkolwiek modeluje rzeczywistość.

Diagramy przyczynowe są schematami wierzchołków i krawędzi, które podsumowują istniejącą wiedzę naukową.^a

^aPearl, Mackenzie, „The Book of Why”

Niestety autorzy sami przyznają, że *granica pomiędzy matematyczną fikcją a naukowo poprawnym modelem jest często rozmyta.*

Rozważania na temat poprawności modelu




E - Wykształcenie

R - Religia

A - Jakiś atrybut (np. przyjęcie do pracy w firmie A)

Rozważania na temat poprawności modelu





E - Wykształcenie

R - Religia

A - Jakiś atrybut (np. przyjęcie do pracy w firmie A)

Rozważania na temat poprawności modelu



As you surely know by now, mistaking a mediator for a confounder is one of the deadliest sins in causal inference and may lead to the most outrageous error.^a

^aPearl, Mackenzie, „The Book of Why”

Czym w ogóle jest rasa?

- Jak badać wpływ czegoś, co nie ma dobrej definicji?

Czym w ogóle jest rasa?

- Jak badać wpływ czegoś, co nie ma dobrej definicji?
- Czy przypisywanie ludziom ras to nie rasizm?

Czym w ogóle jest rasa?

- Jak badać wpływ czegoś, co nie ma dobrej definicji?
- Czy przypisywanie ludziom ras to nie rasizm?
- Czy „rasy” w ogóle istnieją?

Czym w ogóle jest rasa?

- Jak badać wpływ czegoś, co nie ma dobrej definicji?
- Czy przypisywanie ludziom ras to nie rasizm?
- Czy „rasy” w ogóle istnieją?
- Może to tylko *konstrukt społeczny*? Jak wtedy to badać?

Czym w ogóle jest rasa?

- Jak badać wpływ czegoś, co nie ma dobrej definicji?
- Czy przypisywanie ludziom ras to nie rasizm?
- Czy „rasy” w ogóle istnieją?
- Może to tylko *konstrukt społeczny*? Jak wtedy to badać?

... i inne pytania bez odpowiedzi.

Modularność

- Problem intersekcjonalności.

Modularność

- Problem intersekcjonalności.
- Zbyt obszerny model jest niepraktyczny.

Modularność

- Problem intersekcjonalności.
- Zbyt obszerny model jest niepraktyczny.
- Zbyt mały model nie uchwyci istotnych aspektów problemu.

Czy istnieją inne podejścia?

One school of thought in causal inference aligns with the mantra: *no causation without manipulation*, a view expressed by Holland in an influential article from 1986.

Czy takie podejście ma sens i co to w ogóle znaczy *no causation without manipulation*?

Model Rubina — jako podejście przeciwstawne

Będziemy się głównie skupiać na tej pracy:

Statistics and Causal Inference, Paul W. Holland, 1986

Model Rubina — jako podejście przeciwstawne

Będziemy się głównie skupiać na tej pracy:

Statistics and Causal Inference, Paul W. Holland, 1986

Poświęcimy jej dużo czasu, mimo tego, że została ona przytoczona w książce właściwie tylko po to, by ją skrytykować.

Model Rubina — wstęp

- Początkiem modelu jest populacja U .

Model Rubina — wstęp

- Początkiem modelu jest populacja U .
- Jednostka populacji będzie oznaczona jako u .

Model Rubina — wstęp

- Początkiem modelu jest populacja U .
- Jednostka populacji będzie oznaczona jako u .
- Y — badany atrybut, główny bohater.

Model Rubina — wstęp

- Początkiem modelu jest populacja U .
- Jednostka populacji będzie oznaczona jako u .
- Y — badany atrybut, główny bohater.
- A — atrybut, postać drugoplanowa.

Model Rubina — eksperyment

- S — zmienna z U w $\{t, c\}$.

Model Rubina — eksperyment

- S — zmienna z U w $\{t, c\}$.
- t — *treatment* group.

Model Rubina — eksperyment

- S — zmienna z U w $\{t, c\}$.
- t — *treatment* group.
- c — *control* group.

Model Rubina — eksperyment

- S — zmienna z U w $\{t, c\}$.
- t — *treatment* group.
- c — *control* group.
- Y_S — *response* variable.

Model Rubina — eksperyment

- S — zmienna z U w $\{t, c\}$.
- t — *treatment* group.
- c — *control* group.
- Y_S — *response* variable.
- Zmienne to funkcje z U w \mathbb{R} .

Model Rubina — eksperyment

- S — zmienna z U w $\{t, c\}$.
- t — *treatment* group.
- c — *control* group.
- Y_S — *response* variable.
- Zmienne to funkcje z U w \mathbb{R} .
- $Y_c(u)$ — wartość Y po wystawieniu u na c

Model Rubina — eksperyment

- S — zmienna z U w $\{t, c\}$.
- t — *treatment* group.
- c — *control* group.
- Y_S — *response* variable.
- Zmienne to funkcje z U w \mathbb{R} .
- $Y_c(u)$ — wartość Y po wystawieniu u na c
- $Y_t(u)$ — wartość Y po wystawieniu u na t

Model Rubina — eksperyment

- $Y_c(u)$ — wartość Y po wystawieniu u na c
- $Y_t(u)$ — wartość Y po wystawieniu u na t

Model Rubina — eksperyment

- $Y_c(u)$ — wartość Y po wystawieniu u na c
- $Y_t(u)$ — wartość Y po wystawieniu u na t

Mówimy wtedy że efektem działania t na u jest:

Model Rubina — eksperyment

- $Y_c(u)$ — wartość Y po wystawieniu u na c
- $Y_t(u)$ — wartość Y po wystawieniu u na t

Mówimy wtedy że efektem działania t na u jest:

$$Y_t(u) - Y_c(u)$$

Model Rubina — eksperyment

- $Y_c(u)$ — wartość Y po wystawieniu u na c
- $Y_t(u)$ — wartość Y po wystawieniu u na t

Mówimy wtedy że efektem działania t na u jest:

$$Y_t(u) - Y_c(u)$$

Efekt ten jest **zawsze** zdefiniowany *względnie* do c !

Korelacja vs. przyczynowość

Przydatne jest porównanie w języku powyższego modelu wnioskowania na temat korelacji i przyczynowości.

Korelacja vs. przyczynowość

Przydatne jest porównanie w języku powyższego modelu wnioskowania na temat korelacji i przyczynowości.

- Korelacja — Obserwujemy (A, B) . Na podstawie ich rozkładu w populacji wnioskujemy na temat powiązania zmiennych.

Korelacja vs. przyczynowość

Przydatne jest porównanie w języku powyższego modelu wnioskowania na temat korelacji i przyczynowości.

- Korelacja — Obserwujemy (A, B) . Na podstawie ich rozkładu w populacji wnioskujemy na temat powiązania zmiennych.
- Przyczyna — Obserwujemy (S, Y_S) . Na podstawie **pojedynczych obserwacji** próbujemy ustalić efekt działania.

Fundamentalny Problem Rzeczywistości

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Fundamentalny Problem Rzeczywistości

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

I w związku z tym:

Fundamentalny Problem Rzeczywistości

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednoczesne poznanie $Y_c(u)$ oraz $Y_t(u)$.

I w związku z tym:

Jest całkowicie niemożliwym poznanie wpływu t na u .

Fundamentalny Problem Rzeczywistości

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednoczesne poznanie $Y_c(u)$ oraz $Y_t(u)$.

I w związku z tym:

Jest całkowicie niemożliwym poznanie wpływu t na u .

Stan kontrfaktyczny (counterfactual)

Stan, który mógłby się wydarzyć (przeciwny do rzeczywistości).

Odpowiedź na pytanie „co by było, gdyby..?”.

Fundamentalny Problem — przykłady

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Fundamentalny Problem — przykłady

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Przykład Czwartoklasisty

u — pewien czwartoklasista

Fundamentalny Problem — przykłady

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Przykład Czwartoklasisty

u — pewien czwartoklasista

Y — sprawność ucznia na sprawdzianie z matematyki

Fundamentalny Problem — przykłady

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Przykład Czwartoklasisty

u — pewien czwartoklasista

Y — sprawność ucznia na sprawdzianie z matematyki

c/t — stary/nowy program nauczania

Fundamentalny Problem — przykłady

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Przykład Czwartoklasisty

u — pewien czwartoklasista

Y — sprawność ucznia na sprawdzianie z matematyki

c/t — stary/nowy program nauczania

Przykład z Pstryczkiem

u — pewien pstryczek na ścianie, połączony z lampą

Fundamentalny Problem — przykłady

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Przykład Czwartoklasisty

u — pewien czwartoklasista

Y — sprawność ucznia na sprawdzianie z matematyki

c/t — stary/nowy program nauczania

Przykład z Pstryczkiem

u — pewien pstryczek na ścianie, połączony z lampą

Y — czy świeci światło?

Fundamentalny Problem — przykłady

The Fundamental Problem of Causal Inference

Jest całkowicie niemożliwym jednocześnie poznanie $Y_c(u)$ oraz $Y_t(u)$.

Przykład Czwartoklasisty

u — pewien czwartoklasista

Y — sprawność ucznia na sprawdzianie z matematyki

c/t — stary/nowy program nauczania

Przykład z Pstryczkiem

u — pewien pstryczek na ścianie, połączony z lampą

Y — czy świeci światło?

t/c — pstryknięcie pstryczka/brak działania

Omijanie Fundamentalnego Problemu

Podejście „Naukowe”

Omijanie Fundamentalnego Problemu

Podejście „Naukowe”

- Założenie o niezmienności

Omijanie Fundamentalnego Problemu

Podejście „Naukowe”

- Założenie o niezmienności
- Założenie o jednorodności

Omijanie Fundamentalnego Problemu

Podejście „Naukowe”

- Założenie o niezmienności
- Założenie o jednorodności

„By careful work he may *convince* himself and other that the assumption is right, but he can **never** be absolutely *certain*.”

Omijanie Fundamentalnego Problemu

Podejście „Statystyczne”

- Próbować badać średni wpływ t na u

$$E(Y_t - Y_c) = E(Y_t) - E(Y_c) = T$$

Omijanie Fundamentalnego Problemu

Podejście „Statystyczne”

- Próbować badać średni wpływ t na u

$$E(Y_t - Y_c) = E(Y_t) - E(Y_c) = T$$

Uwaga

Oczywiście wartość T jest również niepoznawalna co wynika z Fundamentalnego Problemu

Omijanie Fundamentalnego Problemu

Podejście „Statystyczne”

- Próbować badać średni wpływ t na u

$$E(Y_t - Y_c) = E(Y_t) - E(Y_c) = T$$

Uwaga

Oczywiście wartość T jest również niepoznawalna co wynika z Fundamentalnego Problemu

„[...] statistical solution replaces the impossible-to-observe causal effect of t on a specific unit with the possible-to-estimate *average* causal effect of t over a population of units”

Sposoby na poradzenie sobie z problemem

- Widzimy, że bez dodatkowych założeń trudno praktycznie wykorzystać model Rubina.

Sposoby na poradzenie sobie z problemem

- Widzimy, że bez dodatkowych założeń trudno praktycznie wykorzystać model Rubina.
- Założenia, które będziemy dodawać, muszą wynikać z już posiadanej wiedzy na temat procesu, który opisujemy.

Stabilność w czasie i krótkotrwałość przyczynowa (Temporal Stability and Causal Transience)

Wprowadzamy następujące założenia:

Stabilność w czasie i krótkotrwałość przyczynowa (Temporal Stability and Causal Transience)

Wprowadzamy następujące założenia:

- $Y_t(u)$ nie zależy od momentu (w czasie) wystawienia u na działanie t i następnie zmierzenia Y .

Stabilność w czasie i krótkotrwałość przyczynowa (Temporal Stability and Causal Transience)

Wprowadzamy następujące założenia:

- $Y_t(u)$ nie zależy od momentu (w czasie) wystawienia u na działanie t i następnie zmierzenia Y .
- $Y_t(u)$ nie zmienia się w wyniku wcześniejszego wystawienia u na działanie c .

Stabilność w czasie i krótkotrwałość przyczynowa (Temporal Stability and Causal Transience)

Wprowadzamy następujące założenia:

- $Y_t(u)$ nie zależy od momentu (w czasie) wystawienia u na działanie t i następnie zmierzenia Y .
- $Y_t(u)$ nie zmienia się w wyniku wcześniejszego wystawienia u na działanie c .

Przy takich założeniach, możemy dokonać pomiaru zarówno $Y_c(u)$ jak i $Y_t(u)$!

Stabilność w czasie i krótkotrwałość przyczynowa (Temporal Stability and Causal Transience)

Wprowadzamy następujące założenia:

- $Y_t(u)$ nie zależy od momentu (w czasie) wystawienia u na działanie t i następnie zmierzenia Y .
- $Y_t(u)$ nie zmienia się w wyniku wcześniejszego wystawienia u na działanie c .

Przy takich założeniach, możemy dokonać pomiaru zarówno $Y_c(u)$ jak i $Y_t(u)$!

Przykład z pstryczkiem: nie dotykamy niczego i obserwujemy, że światło się nie pali. Włączamy pstryczek, obserwujemy że światło się pali.

Jednorodność (Unit Homogeneity)

Na podstawie posiadanej wiedzy stwierdzamy, że dwie (lub więcej) jednostki są identyczne pod każdym interesującym nas względem.

Jednorodność (Unit Homogeneity)

Na podstawie posiadanej wiedzy stwierdzamy, że dwie (lub więcej) jednostki są identyczne pod każdym interesującym nas względem.

Dla u_1, u_2 zakładamy:

Jednorodność (Unit Homogeneity)

Na podstawie posiadanej wiedzy stwierdzamy, że dwie (lub więcej) jednostki są identyczne pod każdym interesującym nas względem.

Dla u_1, u_2 zakładamy:

- $Y_t(u_1) = Y_t(u_2)$

Jednorodność (Unit Homogeneity)

Na podstawie posiadanej wiedzy stwierdzamy, że dwie (lub więcej) jednostki są identyczne pod każdym interesującym nas względem.

Dla u_1, u_2 zakładamy:

- $Y_t(u_1) = Y_t(u_2)$
- $Y_c(u_1) = Y_c(u_2)$

Jednorodność (Unit Homogeneity)

Na podstawie posiadanej wiedzy stwierdzamy, że dwie (lub więcej) jednostki są identyczne pod każdym interesującym nas względem.

Dla u_1, u_2 zakładamy:

- $Y_t(u_1) = Y_t(u_2)$
- $Y_c(u_1) = Y_c(u_2)$

Wtedy efekt działania t obliczamy jako $Y_t(u_1) - Y_c(u_2)$

Jednorodność (Unit Homogeneity)

Na podstawie posiadanej wiedzy stwierdzamy, że dwie (lub więcej) jednostki są identyczne pod każdym interesującym nas względem.

Dla u_1, u_2 zakładamy:

- $Y_t(u_1) = Y_t(u_2)$
- $Y_c(u_1) = Y_c(u_2)$

Wtedy efekt działania t obliczamy jako $Y_t(u_1) - Y_c(u_2)$

Przykład: podgrzanie jednej z dwóch identycznych próbek jakiejś substancji.

Niezależność (Independence)

Zakładamy następujące rzeczy:

Niezależność (Independence)

Zakładamy następujące rzeczy:

- Populacja U jest w jakimś sensie duża.

Niezależność (Independence)

Zakładamy następujące rzeczy:

- Populacja U jest w jakimś sensie duża.
- S jest niezależne od wszelkich innych atrybutów na U (w tym Y_t, Y_c).

Niezależność (Independence)

Zakładamy następujące rzeczy:

- Populacja U jest w jakimś sensie duża.
- S jest niezależne od wszelkich innych atrybutów na U (w tym Y_t, Y_c).

$$\underbrace{E(Y_S|S = t) - E(Y_S|S = c)}_{T_{PF}} = E(Y_t) - E(Y_c) = T$$

Niezależność (Independence)

Zakładamy następujące rzeczy:

- Populacja U jest w jakimś sensie duża.
- S jest niezależne od wszelkich innych atrybutów na U (w tym Y_t, Y_c).

$$\underbrace{E(Y_S|S = t) - E(Y_S|S = c)}_{T_{PF}} = E(Y_t) - E(Y_c) = T$$

Przykład: dowolne randomizowane kontrolowane badanie kliniczne (na przykład szczepionki na COVID-19).

Stały efekt (Constant Effect)

Zakładamy:

$$\forall u \in U T = Y_t(u) - Y_c(u)$$

Stały efekt (Constant Effect)

Zakładamy:

$$\forall u \in U T = Y_t(u) - Y_c(u)$$

Wtedy:

$$E(Y_t|S = t) = T + E(Y_c|S = t)$$

Stały efekt (Constant Effect)

Zakładamy:

$$\forall_{u \in U} T = Y_t(u) - Y_c(u)$$

Wtedy:

$$E(Y_t | S = t) = T + E(Y_c | S = t)$$

$$T_{PF} = T + (E(Y_c | S = t) - E(Y_c | S = c))$$

Wyraz w nawiasach wynosi zero przy istnieniu niezależności.

Quasi-eksperymenty

- Z przyczyn praktycznych, etycznych lub innych nie zawsze możemy przeprowadzić porządnny eksperyment.

Quasi-eksperymenty

- Z przyczyn praktycznych, etycznych lub innych nie zawsze możemy przeprowadzić porządny eksperyment.
- Możemy próbować odnaleźć strukturę eksperymentu w obserwacjach.

Quasi-eksperymenty

- Z przyczyn praktycznych, etycznych lub innych nie zawsze możemy przeprowadzić porządnny eksperyment.
- Możemy próbować odnaleźć strukturę eksperymentu w obserwacjach.
- Atrybuty przed wpływem na jednostkę mogą pozwolić na zamianę założenia niezależności na „warunkową niezależność”.

Quasi-eksperymenty

- Z przyczyn praktycznych, etycznych lub innych nie zawsze możemy przeprowadzić porządny eksperyment.
- Możemy próbować odnaleźć strukturę eksperymentu w obserwacjach.
- Atrybuty przed wpływem na jednostkę mogą pozwolić na zamianę założenia niezależności na „warunkową niezależność”.
- W pewnym sensie badamy korelację między A i S .

Co może być przyczyną?

- Według Hollanda – wszystko to, co może być działaniem w eksperymencie, niekoniecznie konwencjonalnym.

Co może być przyczyną?

- Według Hollanda – wszystko to, co może być działaniem w eksperymencie, niekoniecznie konwencjonalnym.
- Musi istnieć możliwość *potencjalnego* wystawienia jednostki na działanie.

Co może być przyczyną?

- Według Hollanda – wszystko to, co może być działaniem w eksperymencie, niekoniecznie konwencjonalnym.
- Musi istnieć możliwość *potencjalnego* wystawienia jednostki na działanie.

„No causation without manipulation”

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”
- 2 „Dostała się do Google'a, bo się przygotowała.”

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”
- 2 „Dostała się do Google'a, bo się przygotowała.”
- 3 „Dostała się do Google'a, bo przygotował ją mentor.”

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”
- 2 „Dostała się do Google'a, bo się przygotowała.”
- 3 „Dostała się do Google'a, bo przygotował ją mentor.”

Co tak naprawdę znaczą te zdania?

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”
- 2 „Dostała się do Google'a, bo się przygotowała.”
- 3 „Dostała się do Google'a, bo przygotował ją mentor.”

Co tak naprawdę znaczą te zdania?

- 1 „Google dyskryminuje mężczyzn.”

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”
- 2 „Dostała się do Google'a, bo się przygotowała.”
- 3 „Dostała się do Google'a, bo przygotował ją mentor.”

Co tak naprawdę znaczą te zdania?

- 1 „Google dyskryminuje mężczyzn.”
- 2 „Dobrze przygotowała się do rozmowy rekrutacyjnej.”

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”
- 2 „Dostała się do Google'a, bo się przygotowała.”
- 3 „Dostała się do Google'a, bo przygotował ją mentor.”

Co tak naprawdę znaczą te zdania?

- 1 „Google dyskryminuje mężczyzn.”
- 2 „Dobrze przygotowała się do rozmowy rekrutacyjnej.”
- 3 „Dzięki temu, że została przygotowana przez mentora, dostała się do Google.”

Co może być przyczyną? cd.

- 1 „Dostała się do Google'a, bo jest kobietą.”
- 2 „Dostała się do Google'a, bo się przygotowała.”
- 3 „Dostała się do Google'a, bo przygotował ją mentor.”

Co tak naprawdę znaczą te zdania?

- 1 „Google dyskryminuje mężczyzn.”
- 2 „Dobrze przygotowała się do rozmowy rekrutacyjnej.”
- 3 „Dzięki temu, że została przygotowana przez mentora, dostała się do Google.”

Tylko w ostatnim przypadku możemy mówić o przyczynowości w rozumieniu Hollanda. Mamy tu jasno zdefiniowaną jednostkę (kobietę), działanie (przygotowanie przez mentora) i skutek (ofertę pracy).

Powrót do grafów

Little work has been done to relate Rubin's model to those used in the causal modeling literature [...]

Powrót do grafów

Little work has been done to relate Rubin's model to those used in the causal modeling literature [...]

[...] some diagrams are meaningful and some are not.

Powrót do grafów

Little work has been done to relate Rubin's model to those used in the causal modeling literature [...]

[...] some diagrams are meaningful and some are not.

Ten diagram nie ma sensu:

$$A \rightarrow Y$$

Powrót do grafów

Little work has been done to relate Rubin's model to those used in the causal modeling literature [...]

[...] some diagrams are meaningful and some are not.

Ten diagram nie ma sensu:

$$A \rightarrow Y$$

Ale ten już ma:

$$S \rightarrow Y_S$$

Powrót do grafów – dalsze przypadki

Pomyślmy, gdzie można dodać trzecią zmienną.

Powrót do grafów – dalsze przypadki

Pomyślmy, gdzie można dodać trzecią zmienną.

Jeżeli A jest atrybutem, to jest obserwowane przed lub po wystawieniu na działanie (*pre/post-exposure*).

Powrót do grafów – dalsze przypadki

Pomyślmy, gdzie można dodać trzecią zmienną.

Jeżeli A jest atrybutem, to jest obserwowane przed lub po wystawieniu na działanie (*pre/post-exposure*).

$$A \quad S \rightarrow Y$$

Powrót do grafów – dalsze przypadki

Pomyślmy, gdzie można dodać trzecią zmienną.

Jeżeli A jest atrybutem, to jest obserwowane przed lub po wystawieniu na działanie (*pre/post-exposure*).

$$A \quad S \rightarrow Y$$

$$S \rightarrow (A_S, Y_S)$$

Powrót do grafów – dalsze przypadki

Nowa zmienna może być kolejną przyczyną.

Powrót do grafów – dalsze przypadki

Nowa zmienna może być kolejną przyczyną.

Mogą one być od siebie niezależne:

$$(R, S) \longrightarrow Y_{RS}$$


Powrót do grafów – dalsze przypadki

Nowa zmienna może być kolejną przyczyną.

Mogą one być od siebie niezależne:

$$(R, S) \longrightarrow Y_{RS}$$

Lub od siebie zależeć:



Powrót do grafów

The essential point I wish to make about these diagrams is that they are easily interpreted in terms of Rubin's model when they are not causally meaningless.

Powrót do książki

Atrybut nie może być powodem, mimo to chcemy dyskutować o przyczynach dyskryminacji.

Powrót do książki

Atrybut nie może być powodem, mimo to chcemy dyskutować o przyczynach dyskryminacji.

Autorzy książki wspominają o „triku” – badaniu „percepcji rasy” zamiast „wpływu rasy”. Jednostkami są decydenci, działanie to „ekspozycja” na rasę.

Powrót do książki

Atrybut nie może być powodem, mimo to chcemy dyskutować o przyczynach dyskryminacji.

Autorzy książki wspominają o „triku” – badaniu „percepcji rasy” zamiast „wpływu rasy”. Jednostkami są decydenci, działanie to „ekspozycja” na rasę.

Nie zadowala ich to:

We now have to sort out all the different ways in which we think that race could possibly be perceived: through names, speech, style [...]

Poszukiwanie przyczyny

Dostała się do Google'a, bo jest kobietą.

Poszukiwanie przyczyny

Dostała się do Google'a, bo jest kobietą.

Kupuje czerwone jabłka, bo jest kobietą.

Dalsza krytyka (krytyki)

„Chcielibyśmy wnioskować o hipotetycznych erupcjach wulkanów bez konieczności manipulowania wulkanami.”

Dalsza krytyka (krytyki)

„Chcielibyśmy wnioskować o hipotetycznych erupcjach wulkanów bez konieczności manipulowania wulkanami.”

„Potrafimy wyjaśnić skąd biorą się pływy, a nie potrafimy poruszyć księżycem.”

Dalsza krytyka (krytyki)

„Chcielibyśmy wnioskować o hipotetycznych erupcjach wulkanów bez konieczności manipulowania wulkanami.”

„Potrafimy wyjaśnić skąd biorą się pływy, a nie potrafimy poruszyć księżycem.”

Czy te zarzuty mają sens?

Warto rozmawiać, czyli kwestie do dyskusji

- Czy model Rubina jest istotnie ograniczony, czy po prostu szczyry?
- Czy szukanie „działań” w modelu dyskryminacji nie pozwala na identyfikację istoty rzeczy? Czy poznawszy je nie jest prościej jej przeciwdziałać?

Dziękujemy za uwagę i zapraszamy do dyskusji.