


⟨packt⟩

# Wnioskowanie i związki przyczynowe w Pythonie

---

Nowoczesne uczenie maszynowe  
z wykorzystaniem bibliotek DoWhy, EconML,  
PyTorch i nie tylko



ALEKSANDER MOLAK

Tytuł oryginału: Causal Inference and Discovery in Python – Machine Learning and Pearlian Perspective: Unlock the secrets of modern causal machine learning with DoWhy, EconML, PyTorch and more

Tłumaczenie: Radosław Meryk

ISBN: 978-83-289-0832-1

Copyright © Packt Publishing 2023. First published in the English language under the title 'Causal Inference and Discovery in Python' – (9781804612989).

Polish edition copyright © 2024 by Helion S.A.

All rights reserved. No part of this book may be reproduced or transmitted in any form or by any means, electronic or mechanical, including photocopying, recording or by any information storage retrieval system, without permission from the Publisher.

Wszelkie prawa zastrzeżone. Nieautoryzowane rozpowszechnianie całości lub fragmentu niniejszej publikacji w jakiegokolwiek postaci jest zabronione. Wykonywanie kopii metodą kserograficzną, fotograficzną, a także kopiowanie książki na nośniku filmowym, magnetycznym lub innym powoduje naruszenie praw autorskich niniejszej publikacji.

Wszystkie znaki występujące w tekście są zastrzeżonymi znakami firmowymi bądź towarowymi ich właścicieli.

Autor oraz wydawca dołożyli wszelkich starań, by zawarte w tej książce informacje były kompletne i rzetelne. Nie biorą jednak żadnej odpowiedzialności ani za ich wykorzystanie, ani za związane z tym ewentualne naruszenie praw patentowych lub autorskich. Autor oraz wydawca nie ponoszą również żadnej odpowiedzialności za ewentualne szkody wynikłe z wykorzystania informacji zawartych w książce.

Drogi Czytelniku!

Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres

<https://helion.pl/user/opinie/wnizwi>

Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Helion S.A.

ul. Kościuszki 1c, 44-100 Gliwice

tel. 32 230 98 63

e-mail: [helion@helion.pl](mailto:helion@helion.pl)

WWW: <https://helion.pl> (księgarnia internetowa, katalog książek)

Printed in Poland.

- Kup książkę
- Poleć książkę
- Oceń książkę

- Księgarnia internetowa
- Lubię to! » Nasza społeczność

# Spis treści |

<b>O autorze</b> .....	<b>15</b>
<b>O recenzentach</b> .....	<b>16</b>
<b>Podziękowania</b> .....	<b>17</b>
<b>Słowo wstępne</b> .....	<b>19</b>
<b>Przedmowa</b> .....	<b>21</b>

## **CZĘŚĆ 1. Przyczynowość — wprowadzenie**

### **ROZDZIAŁ 1**

#### **Związki przyczynowe? Przecież jest uczenie maszynowe, więc po co zawracać sobie tym głowę?** .....

<b>Związki przyczynowe? Przecież jest uczenie maszynowe, więc po co zawracać sobie tym głowę?</b> .....	<b>29</b>
Krótka historia przyczynowości .....	30
Dlaczego przyczynowość? Zapytaj dzieci! .....	31
Interakcje ze światem .....	31
Zakłócenia — związki, które nie są prawdziwe .....	32
Jak nie stracić pieniędzy... i ludzkich istnień .....	35
Dylemat marketera .....	35
Pobawmy się w doktora! .....	36
Asocjacje w realnym świecie .....	37
Podsumowanie .....	37
Bibliografia .....	38

### **ROZDZIAŁ 2**

#### **Judea Pearl i drabina przyczynowości** .....

<b>Judea Pearl i drabina przyczynowości</b> .....	<b>39</b>
Od asocjacji do logiki i wyobraźni. Drabina przyczynowości .....	39
Asocjacje .....	42
Ćwiczenie .....	44
Czym są interwencje? .....	47
Zmienianie świata .....	48
Korelacja i przyczynowość .....	50

Czym są kontrfakty? .....	52
Zanurzmy się w dziwactwa (zapis formalny) .....	53
Podstawowy problem wnioskowania przyczynowego .....	54
Obliczanie kontrfaktów .....	54
Czas na kodowanie! .....	56
Dodatek. Czym jest uczenie maszynowe z perspektywy przyczynowości? ...	57
Przyczynowość a uczenie ze wzmocnieniem .....	57
Przyczynowość a uczenie półnadzorowane i nienadzorowane .....	58
Podsumowanie .....	58
Bibliografia .....	59

## ROZDZIAŁ 3

<b>Regresja, obserwacje i interwencje .....</b>	<b>61</b>
Wprowadzenie. Dane obserwacyjne a regresja liniowa .....	61
Regresja liniowa .....	62
Wartości p i istotność statystyczna .....	65
Interpretacja geometryczna regresji liniowej .....	66
Odwrocenie kolejności .....	67
Czy zawsze należy kontrolować wszystkie dostępne współzmiennie? .....	69
Poruszanie się po labiryncie .....	69
Jeśli nie wiesz, dokąd zmierzasz, możesz trafić gdzie indziej .....	70
Pójdźmy dalej! .....	73
Kontrolować czy nie kontrolować? .....	73
Modele regresyjne a modele strukturalne .....	73
Modele SCM .....	73
Regresja liniowa a modele SCM .....	74
Szukanie powiązania .....	74
Regresja a skutki przyczynowe .....	76
Podsumowanie .....	78
Bibliografia .....	78

## ROZDZIAŁ 4

<b>Modele grafów .....</b>	<b>79</b>
Grafy, grafy, grafy .....	79
Rodzaje grafów .....	80
Reprezentacje grafów .....	83
Grafy w Pythonie .....	85
Czym jest model grafów? .....	87
Skierowane grafy acykliczne w świecie związków przyczynowych .....	88
Definicje przyczynowości .....	88
Grafy DAG a przyczynowość .....	89
Formalna definicja grafów DAG .....	90
Ograniczenia grafów DAG .....	90

Źródła grafów przyczynowych w świecie rzeczywistym .....	91
Odkrywanie związków przyczynowych .....	91
Wiedza ekspercka .....	91
Połączenie technik odkrywania związków przyczynowych i wiedzy eksperckiej .....	92
Dodatek. Czy można opisywać związki przyczynowe bez grafów DAG? .....	92
Układy dynamiczne .....	92
Cykliczne modele SCM .....	92
Podsumowanie .....	93
Bibliografia .....	93

## ROZDZIAŁ 5

<b>Rozwidlenia, łańcuchy i kolidery .....</b>	<b>95</b>
Grafy i rozkłady oraz sposoby mapowania między nimi .....	95
Jak opisywać niezależność? .....	96
Wybór właściwego kierunku .....	97
Warunki i założenia .....	98
Łańcuchy, rozwidlenia i kolidery .....	102
łańcuch zdarzeń .....	102
łańcuchy .....	103
Rozwidlenia .....	104
Kolidery lub struktury $v$ .....	106
Przypadki niejednoznaczne .....	108
Rozwidlenia, łańcuchy, kolidery i regresja .....	109
Tworzenie zbioru danych dla łańcucha .....	110
Tworzenie zestawu danych dla rozwidlenia .....	112
Tworzenie zbioru danych dla kolidera .....	112
Dopasowanie modeli regresji .....	113
Podsumowanie .....	116
Bibliografia .....	116

# CZĘŚĆ 2. Wnioskowanie związków przyczynowych

## ROZDZIAŁ 6

<b>Węzły, krawędzie i statystyczna (nie)zależność .....</b>	<b>119</b>
Zadbaj o separację $d$ ! .....	120
Trening czyni mistrza — separacja $d$ .....	121
Najpierw estymandy! .....	124
Żyjemy w świecie estymatorów .....	124
Czym są estymandy? .....	124

Kryterium back-door .....	126
Czym jest kryterium back-door? .....	127
Kryterium back-door a estymandy równoważne .....	127
Kryterium front-door .....	130
Czy GPS może nas wyprowadzić na manowce? .....	130
Londyńskie taksówki i magiczny kamień .....	131
Otwarcie frontowych drzwi .....	132
Trzy proste kroki w kierunku kryterium front-door .....	134
Kryterium front-door w praktyce .....	134
Czy są jakieś inne kryteria? Zastosujmy rachunek do! .....	140
Trzy zasady rachunku do .....	141
Zmienne instrumentalne .....	142
Podsumowanie .....	144
Odpowiedź .....	144
Bibliografia .....	145

## ROZDZIAŁ 7

<b>Czteroe etapowy proces wnioskowania przyczynowego .....</b>	<b>146</b>
Wprowadzenie do bibliotek DoWhy i EconML .....	147
Ekosystem analizy przyczynowej Pythona .....	147
Dlaczego DoWhy? .....	149
Czym jest pakiet DoWhy? .....	150
A co z biblioteką EconML? .....	150
Krok 1. Modelowanie problemu .....	151
Utworzenie grafu .....	151
Tworzenie obiektu CausalModel .....	153
Krok 2. Identyfikacja estymand .....	154
Krok 3. Wyznaczanie oszacowań .....	156
Krok 4. Zestaw walidacyjny. Testy obalające .....	156
Jak walidować modele przyczynowe? .....	157
Wprowadzenie do testów obalających .....	158
Pełny przykład .....	160
Krok 1. Zakodowanie założeń .....	161
Krok 2. Wyznaczenie estymandy .....	163
Krok 3. Wyznaczenie oszacowania .....	163
Krok 4. Obalenie oszacowania .....	165
Podsumowanie .....	169
Bibliografia .....	169

**ROZDZIAŁ 8**

<b>Modele przyczynowe. Założenia i wyzwania .....</b>	<b>170</b>
Jestem królem świata! Czy rzeczywiście tak jest? .....	170
Gdzieś pośrodku .....	171
Identyfikowalność .....	172
Brak grafów przyczynowych .....	172
Za mało danych .....	173
Nieweryfikowalne założenia .....	175
Słów w pokoju — nadzieja czy beznadzieja? .....	175
Zjedźmy słonia .....	175
Dodatniość .....	177
Wymiennność .....	179
Podmioty wymienne .....	180
Wymiennność a zakłócenia .....	180
...i inne .....	181
Modułowość .....	181
SUTVA .....	183
Spójność .....	183
Nazywaj mnie po imieniu — relacje pozorne .....	184
Nazwy, nazwy, nazwy .....	184
Czy powinienem zapytać Ciebie, czy kogoś, kogo tu nie ma? .....	185
Stwórzcie graf DAG! .....	185
Dodatkowe informacje o stronniczości wyboru .....	187
Podsumowanie .....	189
Bibliografia .....	189

**ROZDZIAŁ 9**

<b>Wnioskowanie związków przyczynowych i uczenie maszynowe — od dopasowywania do metalearnerów .....</b>	<b>191</b>
Podstawy I. Dopasowywanie .....	192
Rodzaje dopasowywania .....	192
Efekty interwencji — ATE w porównaniu z ATT i ATC .....	193
Estymatory dopasowywania .....	194
Implementacja dopasowywania .....	196
Podstawy II. Współczynniki skłonności .....	201
Dopasowywanie w praktyce .....	201
Zmniejszenie wymiarowości za pomocą współczynników skłonności ...	202
Dopasowywanie współczynników skłonności (PSM) .....	203
Odwrotne ważenie prawdopodobieństwa (IPW) .....	204
Wiele twarzy współczynników skłonności .....	204
Formalizacja techniki IPW .....	205
Implementacja IPW .....	205
IPW — względy praktyczne .....	206

S-Learner — samotny stróż .....	207
Diabeł tkwi w szczegółach .....	207
Mamo, tato, poznajcie CATE .....	208
Żarty na bok. Pozdrowienia dla heterogenicznego tłumu .....	209
Machanie flagą założeń .....	210
Jesteś jedyny. Modelowanie z wykorzystaniem techniki S-Learner .....	211
Dane o niewielkiej objętości .....	217
Słabe punkty modelu S-Learner .....	218
T-Learner. Razem możemy więcej .....	218
Wymuszenie właściwego podziału zmiennych .....	219
T-Learner w czterech krokach i wzory .....	219
Implementacja modelu T-Learner .....	220
X-Learner. Krok dalej .....	222
Wyciskanie cytryny .....	222
Rekonstrukcja modelu X-Learner .....	223
X-Learner. Formuła alternatywna .....	225
Implementacja X-Learner .....	226
Podsumowanie .....	230
Bibliografia .....	231

## ROZDZIAŁ 10

### Wnioskowanie związków przyczynowych i uczenie maszynowe — zaawansowane estymatory, eksperymenty, oceny i nie tylko ..... 233

Metody DR. Spróbujmy uzyskać więcej! .....	234
Czy potrzebujemy czegoś więcej? .....	234
Podwójnie wzmocniony nie oznacza niezniszczalny... .....	236
...ale pozwala wiele zyskać .....	236
Sekretny, podwójnie mocny sos .....	236
Estymator DR a założenia .....	238
DR-Learner. Przechodzenie nad przepaścią .....	238
Modele DR-Learner — opcje dodatkowe .....	242
Ukierunkowany estymator maksymalnego prawdopodobieństwa .....	242
Jeśli uczenie maszynowe jest fajne, to co powiesz na podwójne uczenie maszynowe? .....	246
Dlaczego DML i co jest w nim podwójnego? .....	246
Implementacja DML za pomocą bibliotek DoWhy i EconML .....	249
Dostrajanie hiperparametrów za pomocą bibliotek DoWhy i EconML ...	252
Czy DML jest srebrną kulą? .....	256
Techniki DR a DML .....	258
Co z tego będę miał? .....	259



Lasy przyczynowe i nie tylko .....	260
Drzewa przyczynowe .....	260
Przepętnienia lasów .....	260
Zalety lasów przyczynowych .....	260
Lasy przyczynowe z wykorzystaniem bibliotek DoWhy i EconML .....	261
Niejednorodne efekty interwencji z danymi eksperymentalnymi — odyseja upliftingu .....	263
Dane .....	263
Wybór frameworka .....	268
Nie znamy połowy tej historii .....	268
Wyzwanie Kevina .....	269
Otwarcie skrzynki z narzędziami .....	270
Modele uplift a wydajność .....	274
Inne wskaźniki dla wyników ciągłych z wieloma interwencjami .....	279
Przedziały ufności .....	279
Zwycięski wynik w wyzwaniu Kevina .....	280
Kiedy należy stosować estymatory CATE dla danych eksperymentalnych? .....	280
Wybór modelu. Uproszczony przewodnik .....	281
Dodatek. Objaśnienia kontrfaktyczne .....	283
Zła wola czy nieodpowiednia technologia? .....	283
Podsumowanie .....	284
Bibliografia .....	285

## ROZDZIAŁ 11

### **Wnioskowanie związków przyczynowych i uczenie maszynowe — uczenie głębokie, przetwarzanie języka naturalnego i inne techniki .... 288**

Wykorzystanie technik uczenia głębokiego do wyznaczania heterogenicznych efektów interwencji .....	289
Wskaźniki CATE sięgają głębiej .....	289
SNet .....	291
Transformatory i wnioskowanie związków przyczynowych .....	299
Teoria znaczenia w pięciu akapitach .....	299
Co zrobić, by komputery rozumiały język naturalny? .....	300
Od filozofii do kodu Pythona .....	301
Modele LLM a przyczynowość .....	301
Trzy scenariusze .....	303
CausalBert .....	306
Przyczynowość i szeregi czasowe, czyli kiedy ekonometryk przechodzi na Bayesa .....	312
Metody quasi-eksperymentalne .....	312
Przejęcie Twittera i wzorce googlowania .....	313

Logika syntetycznych kontroli .....	313
Wizualne wprowadzenie do logiki kontroli syntetycznej .....	314
Na początek dane .....	317
Kontrola syntetyczna w kodzie .....	317
Wyzwania .....	322
Podsumowanie .....	323
Bibliografia .....	324

## CZĘŚĆ 3. Odkrywanie związków przyczynowych

### ROZDZIAŁ 12

<b>Czy można prosić o graf przyczynowy? .....</b>	<b>329</b>
Źródła wiedzy przyczynowej .....	329
Zalew informacji .....	330
Siła zaskoczenia .....	330
Spostrzeżenia naukowe .....	331
Logika nauki .....	331
Hipotezy są gatunkiem .....	332
Jedna logika, wiele dróg .....	333
Eksperymenty kontrolowane .....	333
Randomizowane badania kontrolowane .....	334
Od eksperymentów do grafów .....	334
Symulacje .....	335
Osobiste doświadczenia i wiedza dziedzinowa .....	335
Osobiste doświadczenia .....	336
Wiedza dziedzinowa .....	337
Uczenie się struktury przyczynowej .....	337
Podsumowanie .....	338
Bibliografia .....	339

### ROZDZIAŁ 13

<b>Odkrywanie związków przyczynowych i uczenie maszynowe — od założeń do zastosowań .....</b>	<b>340</b>
Odkrywanie związków przyczynowych — przypomnienie informacji o założeniach .....	341
Przygotowania .....	341
Należy zawsze dążyć do zapewnienia wierności... ..	341
...ale czasami to jest trudne .....	341
Minimalizm jest cnotą .....	342
Cztery (i pół) rodziny .....	342
Cztery strumienie .....	343

Wprowadzenie do pakietu gCastle .....	344
Witaj, gCastle! .....	344
Dane syntetyczne w gCastle .....	345
Dopasowywanie pierwszego modelu odkrywania związków przyczynowych .....	348
Wizualizacja modelu .....	349
Wskaźniki oceny modelu .....	350
Odkrywanie związków przyczynowych oparte na ograniczeniach .....	353
Ograniczenia i niezależność .....	353
Wykorzystanie struktury niezależności w celu odtworzenia grafu .....	354
Algorytm PC — ukryte wyzwania .....	357
Algorytm PC dla danych kategoryalnych .....	358
Odkrywanie związków przyczynowych na podstawie punktacji .....	359
Tabula rasa — zaczynamy od nowa .....	359
GES — punktacja .....	359
Algorytm GES w bibliotece gCastle .....	360
Funkcyjne odkrywanie związków przyczynowych .....	361
Błogosławieństwa asymetrii .....	361
Model ANM .....	362
Ocena niezależności .....	365
Czas na LiNGAM .....	366
Odkrywanie związków przyczynowych oparte na gradientach .....	372
Czym jest ten gradient? .....	372
Proszę nie ronić łez! .....	374
Nie płacz, GOLEM! .....	374
Porównanie .....	375
Kodowanie wiedzy eksperckiej .....	377
Czym jest wiedza ekspercka? .....	378
Wiedza ekspercka w bibliotece gCastle .....	378
Podsumowanie .....	379
Bibliografia .....	379

## ROZDZIAŁ 14

<b>Odkrywanie związków przyczynowych i uczenie maszynowe — zaawansowane uczenie głębokie i nie tylko .....</b>	<b>382</b>
Zaawansowane odkrywanie związków przyczynowych za pomocą uczenia głębokiego .....	383
Od modeli generatywnych do przyczynowości .....	384
Spójrz wstecz, aby dowiedzieć się, kim jesteś .....	384
Elementy składowe frameworka DECI .....	385
Implementacja DECI .....	386
DECI to rozwiązanie kompleksowe .....	398

Odkrywanie związków przyczynowych w wypadku występowania ukrytych zakłóceń .....	398
Algorytm FCI .....	398
Inne podejścia do danych z zakłóceniami .....	403
Dodatek. Nie tylko obserwacje .....	404
ENCO .....	404
ABCI .....	404
Odkrywanie związków przyczynowych — praktyczne zastosowania, wyzwania i otwarte problemy .....	405
Podsumowanie .....	406
Bibliografia .....	407

## ROZDZIAŁ 15

<b>Epilog .....</b>	<b>409</b>
Czego nauczyłeś się z tej książki? .....	409
Pięć kroków do jak najlepszego wykorzystania projektów przyczynowych .....	410
Zadaj pytanie .....	410
Zdobądź wiedzę ekspercką .....	411
Wygeneruj hipotetyczny graf (grafy) .....	412
Sprawdź identyfikowalność .....	412
Dokonaj falsyfikacji hipotez .....	413
Przyczynowość w biznesie .....	414
Jak eksperci analizy przyczynowej przechodzą od wizji do implementacji? .....	414
Przyszłość przyczynowego uczenia maszynowego .....	416
Gdzie jesteśmy dziś i dokąd zmierzamy? .....	417
Wskaźniki przyczynowe .....	418
Fuzja danych przyczynowych .....	418
Agenty interwencji .....	419
Uczenie się struktury przyczynowej .....	419
Uczenie się przez naśladowanie .....	420
Studiowanie przyczynowości .....	421
Pozostajemy w kontakcie .....	422
Podsumowanie .....	422
Bibliografia .....	423
<b>Skorowidz .....</b>	<b>425</b>

# Związki przyczynowe? Przecież jest uczenie maszynowe, więc po co zawracać sobie tym głowę?

Rozdział

1

Tutaj zaczyna się nasza podróż.

W tym rozdziale zadam kilka pytań dotyczących analizy związków przyczynowych.

Czym ona jest? Czy wnioskowanie przyczynowe różni się od wnioskowania statystycznego? Jeśli tak, to czym?

Czy analiza przyczynowa w ogóle jest potrzebna? Uczenie maszynowe wydaje się wystarczająco dobre.

Jeśli śledziłeś szybko zmieniający się krajobraz uczenia maszynowego przez ostatnie 5 – 10 lat, prawdopodobnie zauważyłeś wiele przykładów — jak lubimy to nazywać w społeczności uczenia maszynowego — *irracjonalnej skuteczności* nowoczesnych algorytmów uczenia maszynowego w dziedzinach rozpoznawania obrazów, przetwarzania języka naturalnego i innych.

Takie algorytmy jak DALL-E 2 czy GPT-3/4 trafiły do świadomości nie tylko środowiska naukowców, ale także ogółu społeczeństwa.

Mógłbyś zadać sobie pytanie — jeśli te algorytmy tak dobrze się sprawdzają, to po co w ogóle zawracać sobie głowę czymś innym?

Ten rozdział rozpocznę krótkim omówieniem historii przyczynowości. Następnie podam kilka powodów stosowania w modelowaniu podejścia przyczynowego zamiast czysto statystycznego i wprowadzę pojęcie zakłóceń (ang. *confounding*).

Na koniec zaprezentuję przykłady zastosowania podejścia przyczynowego do rozwiązywania problemów związanych z marketingiem i medycyną. Po zakończeniu lektury tego rozdziału czytelnik powinien mieć jasny obraz obszarów, w których może być przydatne wnioskowanie przyczynowe, oraz powodów tego stanu. Powinien umieć wyjaśnić, czym jest zakłócanie i dlaczego jest ono ważne.

W tym rozdziale omówię następujące zagadnienia:

- Krótka historia przyczynowości.
- Motywacje do stosowania przyczynowego podejścia do modelowania.
- Jak nie stracić pieniędzy... i ludzkich istnień.

## Krótka historia przyczynowości

**Przyczynowość** (ang. *causality*) ma długą historię. Była przedmiotem zainteresowania większości znanych kultur. Jeden z najpłodniejszych filozofów starożytnej Grecji, Arystoteles, twierdził, że zrozumienie przyczynowej struktury procesu jest niezbędnym elementem wiedzy o tym procesie. Ponadto argumentował, że istotą wyjaśniania naukowego jest umiejętność odpowiadania na pytania w rodzaju *dlaczego* (Falcon, 2006, 2022). Arystoteles wyróżnił cztery typy przyczyn (materialne, formalne, sprawcze i ostateczne). O ile taka klasyfikacja pozwala uwzględnić w równym stopniu pewne interesujące aspekty rzeczywistości, o tyle dla współczesnego czytelnika może sprawiać wrażenie sprzecznej z intuicją.

Słynny szkocki filozof z XVIII wieku, David Hume, zaproponował bardziej ujednoczone ramy związków przyczynowo-skutkowych. Hume wyszedł z założenia, że w rzeczywistym świecie nigdy nie obserwujemy związków przyczynowo-skutkowych. Jedyne, czego doświadczamy, to obserwacja, że niektóre zdarzenia są ze sobą powiązane:

*„Dostrzegamy jedynie fakt, że jedno zdarzenie wynika z drugiego. Uderzenie jednej kuli bilardowej powoduje ruch drugiej. To wszystko, co ukazuje się zewnętrznym zmysłom. Umysł nie odczuwa ani żadnego uczucia, ani wewnętrznego wrażenia wynikających z tego następstwa zdarzeń. W związku z tym nie ma, w żadnym pojedynczym, konkretnym przypadku przyczyny i skutku, niczego co mogłoby sugerować ideę mocy lub koniecznego związku”* (Hume i Millican, 2007; pierwotnie opublikowany w 1739 r.).

Jedną z interpretacji teorii przyczynowości Hume’a (tu uproszczona dla zachowania przejrzystości) brzmi następująco:

- Dostrzegamy jedynie to, że ruch lub pojawienie się obiektu *A* poprzedza ruch lub pojawienie się obiektu *B*.
- Jeśli zaobserwujemy takie następstwo zdarzeń wystarczającą liczbę razy, rozwija się w nas poczucie oczekiwania.
- To poczucie oczekiwania jest sednem pojmowania przyczynowości (nie dotyczy świata, lecz uczucia, które rozwijamy).

### Teoria przyczynowości Hume’a

Interpretacja Hume’owskiej teorii przyczynowości, którą podałem powyżej, nie jest jedyna. Warto zauważyć, że nawet Hume w swoim późniejszym dziele *An Inquiry Concerning the Human Understanding* (1758) podał inną definicję przyczynowości. Co więcej, nie wszyscy naukowcy podzielają moją wizję (na przykład Archie, 2005).

Teoria Hume’a jest bardzo interesująca z co najmniej dwóch punktów widzenia.

Po pierwsze elementy jego teorii wykazują duże podobieństwo do bardzo ważnego terminu w psychologii zwanego warunkowaniem (ang. *conditioning*). **Warunkowanie** jest formą uczenia się. Choć istnieje wiele rodzajów warunkowania, wszystkie opierają się na wspólnym fundamencie — mianowicie na skojarzeniach, nazywanych również **asocjacjami** (stąd nazwa tego typu uczenia się — **uczenie asocjacyjne**). W każdym typie warunkowania bierzemy jakieś zdarzenie lub obiekt (zwykle nazywane bodźcem) i kojarzymy je z pewnym zachowaniem lub reakcją. Uczenie asocjacyjne obserwuje się w przyrodzie u różnych gatunków. Jest właściwe ludziom, małpom człekokształtnym, psom i kotom, ale także występuje u znacznie prostszych organizmów, takich jak ślimaki (Alexander, Audesirk i Audesirk, 1985).

### Warunkowanie

Więcej informacji na temat różnych rodzajów warunkowania znajdziesz na stronie <https://bit.ly/MoreOnConditioning>. Możesz również poszukać na przykład frazy *warunkowanie klasyczne* kontra *warunkowanie instrumentalne* i nazwisk, np. Ivan Pavlov i Burrhus Skinner.

Po drugie asocjacje są również podstawą większości klasycznych algorytmów uczenia maszynowego. Kiedy szkolimy sieć neuronową z wykorzystaniem uczenia nadzorowanego, staramy się znaleźć funkcję, która przekształca określone wejście na określone wyjście. Aby zrobić to skutecznie, trzeba ustalić, które elementy danych wejściowych są przydatne do prognozowania wyników. W większości przypadków asocjacje są wystarczające do osiągnięcia tego celu.

## Dlaczego przyczynowość? Zapytaj dzieci!

Czy Hume'owskiej teorii przyczynowości czegoś brakuje? Choć na to pytanie próbowało odpowiedzieć wielu innych filozofów, w tej książce skupię się na jednej szczególnie interesującej odpowiedzi, która pochodzi od... dzieci.

### Interakcje ze światem

Alison Gopnik to amerykańska psycholog dziecięca zajmująca się badaniami nad rozwijaniem modeli świata przez dzieci. Alison Gopnik pomaga również informatykom w zrozumieniu sposobu budowania zdroworozsądkowego rozumienia przez dzieci świata zewnętrznego. Dzieci korzystają z uczenia asocjacyjnego w jeszcze większym stopniu niż dorośli, ale są także nienasyconymi eksperymentatorami.

Czy widziałeś kiedyś rodzica próbującego przekonać swoje dziecko, aby przestało rzucać zabawką? Niektórzy rodzice interpretują tego typu zachowanie jako *niegrzeczne*, *destrukcyjne* lub *agresywne*, ale dzieci często kierują się innymi motywacjami. Prowadzą systematyczne eksperymenty, które pozwalają im poznać prawa fizyki i zasady społecznych interakcji (Gopnik, 2009). Już 11-miesięczne niemowlęta wolą przeprowadzać eksperymenty z przedmiotami, które wykazują nieprzewidywalne właściwości (na przykład sprawiają wrażenie przechodzenia przez ścianę), niż z obiektami, które zachowują się przewidywalnie (Stahl i Feigenson, 2015). Ta preferencja pozwala im budować skuteczne modele świata.

Od dzieci możemy się nauczyć, że nie powinniśmy ograniczać się, jak sugerował Hume, do obserwacji świata. Możemy także wchodzić z nim w interakcje. W kontekście wnioskowania przyczynowego te interakcje są nazywane **interwencjami**. Więcej informacji na ich temat można znaleźć w rozdziale 2. Interwencje stanowią sedno tego, co wielu uważa za Świętego Graala metody naukowej: **randomizowanych badań kontrolowanych** (ang. *randomized controlled trial* — RCT).

## Zakłócenia — związki, które nie są prawdziwe

Zdolność przeprowadzania eksperymentów poszerza paletę możliwości w stosunku do tego, o czym myślał Hume. Eksperymenty stwarzają wielkie możliwości! Chociaż nie pozwalają rozwiązać wszystkich problemów filozoficznych związanych ze zdobywaniem nowej wiedzy, mogą rozwiązać część z nich. Bardzo ważną cechą odpowiednio zaprojektowanego, randomizowanego eksperymentu jest możliwość unikania **zakłóceń** (ang. *confounding*). Dlaczego to jest ważne?

**Zmienna zakłócająca** wpływa na dwie lub więcej innych zmiennych i generuje pomiędzy nimi *fałszywe* powiązanie. Z czysto statystycznego punktu widzenia takie powiązania są nie do odróżnienia od tych wynikających z mechanizmu przyczynowego. Dlaczego to stwarza problemy? Przyjrzyjmy się przykładowi.

Wyobraź sobie, że pracujesz w instytucie badawczym i próbujesz zrozumieć przyczyny tonięcia ludzi. Twoja organizacja udostępniła Ci ogromną bazę danych zmiennych społeczno-ekonomicznych. Aby przewidzieć liczbę dziennych utonięć w obszarze zainteresowania, zdecydowałeś się na skorzystanie z modelu regresji na obszernym zbiorze tych zmiennych. Po sprawdzeniu wyników okazało się, że największy uzyskany współczynnik dotyczy dziennej sprzedaży lodów. To bardzo interesujące! Lody zwykle zawierają duże ilości cukru, więc być może cukier wpływa na koncentrację lub kondycję fizyczną ludzi przebywających w wodzie.

Ta hipoteza może mieć sens, ale zanim przejdziemy dalej, zadajmy kilka pytań. Co z innymi zmiennymi, których nie uwzględniliśmy w modelu? Czy w celu opisania wszystkich istotnych aspektów problemu dodaliśmy do modelu wystarczającą liczbę predyktorów? A co, jeśli dodaliśmy ich za dużo? Czy dodanie do modelu tylko jednej zmiennej może całkowicie zmienić wynik?


### **Dodanie zbyt wielu predyktorów**

Dodanie do modelu *zbyt wielu* predyktorów może być szkodliwe zarówno z punktu widzenia statystycznego, jak i przyczynowego. Więcej na ten temat dowiemy się w rozdziale 3.

Okazuje się, że jest to możliwe.

Pozwólcie, że przedstawię *czynnik zakłócający* — średnią dobową temperaturę. Wyższa dzienna temperatura sprawia, że ludzie chętniej kupują lody i chętniej pływają. Im więcej osób pływa, tym częściej dochodzi do wypadków. Spróbujmy zobrazować tę zależność (rysunek 1.1):






**Rysunek 1.1.** Graficzna reprezentacja modeli z dwiema (a) i trzema zmiennymi (b). Linie przerywane przedstawiają powiązanie, linie ciągłe przedstawiają związek przyczynowy. **LODY = sprzedaż lodów, WYPADKI = liczba wypadków, TMP = temperatura**

Na rysunku 1.1 widać, że dodanie do modelu średniej dziennej temperatury usuwa związek między sprzedażą lodów a dzienną liczbą utonięć. Dla niektórych czytelników może to być zaskakujące, dla innych nie. Więcej o mechanizmie tego efektu dowiemy się w rozdziale 3.

Zanim przejdę dalej, zwrócę szczególną uwagę na ważną rzecz: zakłócanie jest *pojęciem ściśle przyczynowym*. Co to znaczy? Chodzi o to, że nie da się wiele powiedzieć o zakłóceniach, posługując się językiem czysto statystycznym (zauważmy, że to oznacza, iż definicja Hume'a w takiej formie, w jakiej ją przedstawiłem, *nie jest w stanie tego uchwycić*). Aby to wyraźnie zobaczyć, spójrzmy na rysunek 1.2:




**Rysunek 1.2.** Wykresy punktowe relacji parami pomiędzy zmiennymi a, b i c. Kod umożliwiający odtworzenie poprzedniego wykresu można znaleźć w notatniku `Chapter_01.ipynb` ([https://github.com/PacktPublishing/Causal-Inferenceand-Discovery-in-Python/blob/main/Chapter\\_01.ipynb](https://github.com/PacktPublishing/Causal-Inferenceand-Discovery-in-Python/blob/main/Chapter_01.ipynb))

Niebieskie punkty na rysunku 1.2 oznaczają związek przyczynowy, czerwone oznaczają związek pozorny, a zmienne  $a$ ,  $b$  i  $c$  są powiązane w następujący sposób:

- $b$  powoduje  $a$  i  $c$ ,
- $a$  i  $c$  są przyczynowo niezależne.

Graficzną reprezentację tych zależności przedstawia rysunek 1.3:



Rysunek 1.3. Zależności między zmiennymi  $a$ ,  $b$  i  $c$

Czarna linia przerywana z czerwonym krzyżykiem oznacza, że pomiędzy zmiennymi  $a$  i  $c$  nie ma związku przyczynowego w żadnym kierunku

Ale przecież na rysunku 1.2 widać pewną zależność! Spróbujmy się jej przyjrzeć!

Przedstawione na rysunku 1.2 zależności niefałszywe (niebieskie) i fałszywe (czerwone) wyglądają dość podobnie, a ich współczynniki korelacji są podobnie duże. W praktyce w większości przypadków po prostu nie można ich rozróżnić na podstawie wyłącznie kryteriów statystycznych. Do takiego rozróżnienia potrzebna jest wiedza przyczynowa.

### Asymetrie i odkrywanie przyczyn

W gruncie rzeczy, aby dowiedzieć się, który kierunek jest przyczynowy, w niektórych przypadkach można wykorzystać rozkład szumów lub funkcjonalne asymetrie. Informacje te można wykorzystać do odtworzenia struktury przyczynowej na podstawie danych obserwacyjnych, ale wymagają one również pewnych założeń dotyczących procesu generowania tych danych. Więcej informacji na ten temat podam w części III „Odkrywanie związków przyczynowych” (rozdział 13.).

Napisałem, że w danych naszego eksperymentu niektóre relacje były fałszywe. Następnie dodałem do modelu kolejną zmienną, co zmieniło generowany przez niego wynik. Mimo tego byłem w stanie wykonać użyteczne prognozy bez tej zmiennej. Jeśli to prawda, dlaczego miałyby mnie obchodzić, czy związek jest fałszywy, czy nie? Dlaczego miałyby mnie interesować, czy związek jest przyczynowy, czy nie?

# Jak nie stracić pieniędzy... i ludzkich istnień

Dowiedziałeś się, że problemów wynikających z zakłóceń można uniknąć dzięki eksperymentom randomizowanym. Niestety, nie zawsze są one dostępne. Czasami wykonanie takich eksperymentów może być zbyt kosztowne, nieetyczne lub praktycznie niemożliwe (na przykład przeprowadzenie eksperymentu polegającego na migracji dużej grupy jakiejś populacji). W tym podrozdziale omówię kilka scenariuszy, w których pożądane jest wyciąganie wniosków przyczynowych mimo dysponowania wyłącznie danymi obserwacyjnymi. Te przykłady stworzą solidną podstawę do kolejnych rozdziałów.

## Dylemat marketera

Wyobraź sobie, że jesteś marketerem znającym się na technologii i chcesz efektywnie alokować swój budżet na marketing bezpośredni. Jak podszedłbyś do tego zadania? Gdy alokujesz budżet na kampanię marketingu bezpośredniego, chciałbyś wiedzieć, jakiego zwrotu możesz oczekiwać, jeśli wydasz na daną osobę określoną kwotę. Mówiąc inaczej, chcesz oszacować wpływ swoich działań na wyniki niektórych klientów (Gutierrez, Gérardy, 2017). Być może, w celu rozwiązania problemu można by skorzystać z technik uczenia nadzorowanego? Aby odpowiedzieć na to pytanie, przyjrzyjmy się bliżej temu, co chcemy prognozować.

Interesuje nas reakcja konkretnej osoby na prezentowane jej treści. Spróbujmy zakodować to w następującym wzorze:

$$\tau_i = Y_i(1) - Y_i(0)$$

Oto opis poszczególnych elementów powyższego wzoru:

- $\tau_i$  to efekt eksperymentu na osobę  $i$ ;
- $Y_i(1)$  to wynik dla osoby  $i$ , kiedy została poddana eksperymentowi  $T$  (w tym przykładzie otrzymała od Ciebie treści marketingowe);
- $Y_i(0)$  to wynik dla tej samej osoby przy założeniu, że nie została poddana eksperymentowi  $T$ .

Zgodnie z powyższym wzorem od wyniku  $Y_i$  osoby  $i$ , gdy ta osoba nie została poddana eksperymentowi  $T$ , chcesz odjąć wynik uzyskany w przypadku, gdyby osobę tę poddano eksperymentowi  $T$ .

Interesujące jest to, że aby rozwiązać to równanie, trzeba wiedzieć, która odpowiedź osoby  $i$  została uzyskana po przeprowadzeniu eksperymentu, a która bez jego przeprowadzenia. W rzeczywistości nigdy nie można obserwować tej samej osoby w dwóch wzajemnie wykluczających się warunkach jednocześnie. Aby rozwiązać równanie z poprzedniego wzoru, potrzebne są kontryfakty (ang. *counterfactuals*).

**Kontryfakty** to szacunki wyników po zmianie wartości jednej lub większej liczby zmiennych, gdyby wszystkie inne pozostały niezmiennione. Ponieważ kontryfaktów nie można zaobserwować, prawdziwy skutek przyczynowy  $\tau$  jest nieznan. Jest to jeden z powodów, dla których wyżej sformułowanego problemu nie da się rozwiązać z wykorzystaniem

klasycznych technik uczenia maszynowego. Rodzina technik przyczynowych zwykle stosowanych do takich problemów nazywa się **modelowaniem różnicowym** (ang. *uplift modelling*), które omówię dokładnie w rozdziałach 9. i 10.

## Pobawmy się w doktora!

Spróbuję posłużyć się innym przykładem. Wyobraź sobie, że jesteś lekarzem. Jedna z Twoich pacjentek, Joanna, cierpi na rzadką chorobę *D*. Dodatkowo zdiagnozowano u niej wysokie ryzyko wystąpienia zakrzepów krwi. Przystudiowałeś informacje dotyczące dwóch najpopularniejszych leków na chorobę *D*. Obydwa leki mają praktycznie identyczną skuteczność na *D*, ale na podstawie diagnozy postawionej Joannie nie masz pewności, który lek będzie dla niej bezpieczniejszy. Przeglądasz dane badawcze przedstawione w tabeli 1.1:

Tabela 1.1. Dane dla leków A i B

Lek	A		B	
Zakrzepy	Tak	Nie	Tak	Nie
Razem	27	95	23	99
Procent	22%	78%	19%	81%

Liczby w tabeli 1.1 przedstawiają liczbę pacjentów, u których zdiagnozowano chorobę *D*, poddanych leczeniu za pomocą specyfików *A* lub *B*. Wiersz 2 (**zakrzepy**) zawiera informacje o tym, czy u pacjentów wykryto zakrzepy krwi, czy nie. Warto zwrócić uwagę, że wyniki procentowe są zaokrąglone. Który lek byś wybrał na podstawie tych danych? Odpowiedź wydaje się dość oczywista. U 81% pacjentów, którzy otrzymali lek *B*, nie wystąpiły zakrzepy krwi. To samo dotyczyło jedynie 78% pacjentów, którzy otrzymali lek *A*. Ryzyko powstania zakrzepów krwi jest o około 3% niższe u pacjentów otrzymujących lek *B* w porównaniu z pacjentami otrzymującymi lek *A*.

To wygląda na dobry wniosek, ale jesteś sceptyczny. Wiesz, że zakrzepy krwi mogą być bardzo ryzykowne i chcesz dowiedzieć się więcej. Znalazłeś bardziej szczegółowe dane, które uwzględniają płeć pacjenta. Spójrzmy na tabelę 1.2:

Tabela 1.2. Dane dla leku A i leku B z dodanymi wynikami dla płci. K = kobieta, M = mężczyzna. Dla ułatwienia interpretacji dodano kodowanie kolorami, lepsze wyniki zaznaczono na zielono, a gorsze na pomarańczowo

Lek	A		B	
Zakrzepy	Tak	Nie	Tak	Nie
Kobiety	24	56	17	25
Mężczyźni	3	39	6	74
Razem	27	95	23	99
Procent	22%	78%	18%	82%
Procent (K)	30%	70%	40%	60%
Procent (M)	7%	93%	7,5%	92,5%

Stało się tu coś dziwnego. Uzyskane liczby są takie same jak poprzednio: lek *B* nadal jest preferowany dla wszystkich pacjentów. Wydaje się jednak, że lek *A* działa lepiej w przypadku i kobiet, i mężczyzn! Czy właśnie znaleźliśmy medycznego kota Schrödingera ([https://en.wikipedia.org/wiki/Schr%C3%B6dinger%27s\\_cat](https://en.wikipedia.org/wiki/Schr%C3%B6dinger%27s_cat)), który odwraca działanie leku, gdy zaobserwuje płęć pacjenta?

Jeśli sądzisz, że mogłem pomylić się w obliczeniach, nie wierz mi na słowo, po prostu samodzielnie sprawdź dane. Można je znaleźć w pliku `data/ch_01_drug_data.csv` ([https://github.com/PacktPublishing/Causal-Inference-and-Discovery-in-Python/blob/main/data/ch\\_01\\_drug\\_data.csv](https://github.com/PacktPublishing/Causal-Inference-and-Discovery-in-Python/blob/main/data/ch_01_drug_data.csv)).

To, czego właśnie doświadczyliśmy, nazywa się **paradoksem Simpsona** (znanym również jako **efekt Yule-Simpsona**). Paradoks Simpsona występuje wtedy, gdy podział danych uwzględniający dodatkowe zmienne w ustawieniach regresji znacząco zmienia wynik analizy. W rzeczywistym świecie zwykle istnieje wiele sposobów partycjonowania danych. Mógłbyś zapytać: skąd więc mam wiedzieć, który podział jest właściwy?

Można by spróbować odpowiedzieć na to pytanie ściśle z punktu widzenia uczenia maszynowego: przeprowadzić selekcję cech z walidacją krzyżową i wybrać zmienne, które w znaczący sposób wpływają na wynik. To rozwiązanie w niektórych sytuacjach jest wystarczająco dobre. Sprawdzi się np. wtedy, gdy zależy nam jedynie na prognozowaniu (a nie na podejmowaniu decyzji) i gdy wiadomo, że dane produkcyjne będą niezależne i równomiernie rozłożone. Innymi słowy, dane produkcyjne muszą mieć rozkład praktycznie identyczny (lub przynajmniej wystarczająco podobny) do rozkładu danych szkoleniowych i walidacyjnych. Jeśli chcesz czegoś więcej, będziesz potrzebować jakiegoś (przyczynowego) modelu świata.

## Asocjacje w realnym świecie

Niektórzy uważają, że relacje czysto asocjacyjne (skojarzeniowe) rzadko występują w prawdziwym świecie lub że zazwyczaj są słabe, więc nie mogą zbyt mocno wpływać na uzyskiwane wyniki. Aby przekonać się, jak zaskakująco silne i spójne mogą być fałszywe relacje w prawdziwym świecie, odwiedź stronę Tylera Vigena: <https://www.tylervigen.com/spurious-correlations>. Warto zauważyć, że zależności pomiędzy wieloma zmiennymi są czasami bardzo silne i utrzymują się przez długi czas! Osobiście podoba mi się przykład ze startami kosmicznymi i doktoratami z socjologii. Często wykorzystuję go podczas moich wykładów i prezentacji. Który jest Twoim ulubionym? Udostępnij go innym i oznacz mnie na LinkedIn, Twitterze (aby nawiązać kontakt, zapoznaj się z punktem „Pozostańmy w kontakcie” w rozdziale 15.). Możemy o tym porozmawiać!

## Podsumowanie

„Niech przemówią dane” to chwytliwe i mocne hasło, ale jak można się było przekonać podczas lektury tego rozdziału, same dane nie zawsze wystarczą. Warto pamiętać, że w wielu przypadkach „dane nie mówią same za siebie” (Hernán, Robins, 2020) i że do odpowiedzi na niektóre pytania mogą być potrzebne dodatkowe informacje poza obserwacjami.

W tym rozdziale dowiedziałeś się, że gdy myślisz o przyczynowości, nie powinieneś, wbrew temu, co uważał David Hume, ograniczać się do obserwacji. Możesz też eksperymentować, zupełnie jak dzieci.

Niestety, eksperymenty nie zawsze są dostępne. W takiej sytuacji możesz spróbować wykorzystać dane obserwacyjne do wyciągnięcia wniosku przyczynowego, jednak same dane zwykle nie wystarczą do osiągnięcia tego celu. Potrzebujesz także modelu przyczynowego. W następnym rozdziale przedstawię *drabinę przyczynowości* — zaproponowaną przez Judeę Pearla zgrabną metaforę pozwalającą zrozumieć trzy poziomy przyczynowości.

## Bibliografia

- Alexander J.E., Audesirk T.E., Audesirk G.J. *Classical Conditioning in the Pond Snail *Lymnaea stagnalis**. „The American Biology Teacher”, 47(5), 1985, s. 295 – 298.  
<https://doi.org/10.2307/4448054>.
- Archie L., *Hume’s Considered View on Causality*. [Preprint]: <http://philsci-archive.pitt.edu/id/eprint/2247>, 2005 (dostęp 23.04.2022).
- Falcon A. „Aristotle on Causality”, *The Stanford Encyclopedia of Philosophy* (wydanie wiosna 2022), pod red. Edwarda N. Zalta,  
<https://plato.stanford.edu/archives/spr2022/entries/aristotle-causality/>. Dostęp 23.04.2022.
- Gopnik A., *The philosophical baby: What children’s minds tell us about truth, love, and the meaning of life*, Nowy Jork, Farrar, Straus and Giroux, 2009.
- Gutierrez P., Gérardy, J., *Causal Inference and Uplift Modelling: A Review of the Literature*, materiały z 3rd International Conference on Predictive Applications and APIs, opublikowane w „Proceedings of Machine Learning Research”, 67, 2017, s. 1 – 13.
- Hernán M.A., Robins J.M., *Causal Inference: What If*. Boca Raton: Chapman & Hall/CRC, 2020.
- Hume D., Millikan P.F., *An enquiry concerning human understanding*. Oxford: Oxford University Press, 2007.
- Kahneman D., *Thinking, Fast and Slow*, Farrar, Straus and Giroux, 2011.
- Lorkowski C.M., <https://iep.utm.edu/hume-causation/>. Dostęp 23.04.2022.
- Stahl A.E., Feigenson L., *Cognitive development. Observing the unexpected enhances infants’ learning and exploration*. „Science”, 348(6230), 2015, s. 91 – 94.  
<https://doi.org/10.1126/science.aaa3799>.

# Skorowidz |

## A

ABCI, Active Bayesian Casual Inference, 404  
abdukcja, 54  
addytywne modele szumów, ANM, 168  
agenty interwencji, 419  
algorytm  
  CORTH, 403  
  DECI, 390  
  DR-Learner, 270  
  FCI, 398  
  GES, 360  
  GOLEM, 374  
  liniowy DML, 270  
  NOTEARS, 372  
  PC, 348, 355, 357  
    dla danych kategoryalnych, 358  
    wyniki, 379  
  S-Learner, 270  
  T-Learner, 270  
  word2vec, 301  
  X-Learner, 270  
algorytmy identyfikacji, 412  
analiza  
  czułości, sensitivity analysis, 176  
  przyczynowa, 414  
  przyczynowa w Pythonie, 147  
  regresji, 75  
  składowych niezależnych, ICA, 367  
ANM, Additive Noise Model, 168, 361, 362  
API GCM, 166  
asocjacje, 31, 37, 42  
  nieliniowe, 63  
ATC, average treatment effect on the control, 191, 193  
ATE, average treatment effect, 191, 193

## B

badania kontrolowane randomizowane, RCT, 41, 312, 334  
bazowe mechanizmy uczenia, 211  
biblioteka  
  CATENets, 292, 293  
  DoWhy, 149, 249  
  EconML, 150, 249  
  gCastle, 344  
  statsmodels, 63  
błąd  
  nadmiernego dopasowania, 247  
  regularyzacji, 248

## C

CATE, conditional average treatment effects, 191, 207, 208  
CATENets, 292  
CausalBert, 306  
  architektura, 307  
  implementacja, 308  
  używanie modelu, 308  
CausalForestDML, 282  
ChatGPT, 301  
  rozumowanie kontrfaktyczne, 302  
CV, cross-validation, 157  
cykliczne modele SCM, 92

## D

DAG, directed acyclic graphs, 84  
dane  
  eksperymentalne, 263  
  gaussowskie i niegaussowskie, 367  
  kategoryalne, 358  
  syntetyczne, 345  
  z zakłóceniami, 403

**DECI**

- elementy frameworka, 385
- implementacja, 386
- konfiguracja, 389
- moduły modelu, 392
- przygotowanie danych, 390
- szkolenie modelu, 395
- wiedza ekspercka, 390
- wyniki, 396

dotatniość, 177

dopasowywanie, matching, 192

- dokładne, 203
- estymatory, 194
- implementacja, 196
- modeli regresji, 113
- nadmierne, 247
- krzyżowe, cross-fitting, 238
- prawie dokładne, 203
- przybliżone, 203
- wielowymiarowe, 201
- współczynników skłonności, PSM, 203

dostrajanie hiperparametrów, 252, 254

DR, double robust, 233

drabina przyczynowości, ladder of causation, 39

DR-Learner, 238, 282

- opcje, 242
- wyniki, 240, 241

drzewa przyczynowe, 260

dylemat marketera, 35

**E**

efekt Yule-Simpsona, 37

eksperyment z wielkością próby, 174

eksperymenty kontrolowane, 333

ENCO, Efficient Neural Causal Discovery, 404

estymandy, estimands, 124

- identyfikowanie, 154
- równoważne, 127

estymator, 124

- CATE, 280
- dopasowywania, 194
- DR, 237, 238
- kontroli syntetycznej, 314, 317
- TMLE, 242
- ukierunkowany prawdopodobieństwa, 242

**F**

falsyfikacja hipotez, 413

FCI, 398

- implementacja, 399
- wiedza ekspercka, 402

framework

- DECI, 385
- potencjalnych wyników, 180
- TCDF, 405

funkcja

- uciążliwości, 249
- wpływu, influence function, 244
- wskaźnikowa, 45

fuzja danych przyczynowych, 418

**G**

gCastle, 344

- algorytm GES, 360
- algorytm PC, 348
- dane syntetyczne, 345
- wiedza ekspercka, 378
- wizualizacja modelu, 349
- wskaźniki oceny modelu, 350

GCM, graphical causal models, 87

generowanie hipotetycznego grafu, 412

GES, 359

globalna własność Markowa, 100

GML, graph modeling language, 85, 146

GOLEM, 374

gradient, 372

graf

- CPDAG, 109
- modelu SCM, 43
- przyczynowy, 212
- z czynnikiem zakłócającym, 400

grafy

- acykliczne, 81
- CPDAG, 80
- cykliczne, 81
- hipotetyczne, 412
- język GML, 85
- macierze przyległości, 83
- modele GCM, 87
- nieskierowane, 80
- niespójne, 82
- nieważone, 82
- niezależność, 98
- okałeczanie, 89, 182
- przyczynowe, 91, 172
- skierowane, 80
- skierowane acykliczne, DAG, 8, 84, 88, 90, 234
  - a przyczynowość, 89
  - ograniczenia, 90
- spójne, 82



- struktura  
kolidera, 106  
łańcucha, 103  
rozwidlenia, 104  
ważone, 82
- H**
- hipoteza  
falsyfikowalna, 332  
zerowa, 65
- HSIC, Hilbert-Schmidt independence  
criterion, 51
- HTE, heterogeneous treatment effects, 207
- I**
- ICA, independent component analysis, 367
- identyfikowalność, identifiability, 171, 172, 412
- implementacja  
algorytmu FCI, 399  
DECI, 386  
DML, 249  
dopasowywania, 196  
estymatora TMLE, 243  
IPW, 205  
modelu T-Learner, 220  
obliczeń kontrfaktów, 56  
X-Learner, 226
- indywidualny efekt interwencji, ITE, 207
- interakcja, 63
- interfejs API GCM, 166
- interwencje, 40, 47
- IPW, inverse probability weighing, 204,  
206, 236  
implementacja, 205
- istotność statystyczna, 65
- ITE, individualized treatment effects, 207
- IV, instrumental variables, 142
- J**
- jednostka  
ELU, 296  
kontrolna syntetyczna, 316  
SELU, 296
- język  
DOT, 86  
GML, 85, 146  
naturalny, 300
- K**
- klasy równoważności Markowa, MEC, 108,  
109, 158
- kolidera, 106, 109  
tworzenie zbioru danych, 112
- kontrfakty, 35, 41, 52  
deterministyczne, 55  
obliczanie, 54  
probabilistyczne, 55
- kontrola  
statystyczna, 69  
syntetyczna, 314  
implementacja, 317
- korelacja, 50
- kryterium  
back-door, 126, 127  
front-door, 134  
niezależności Hilberta-Schmidta, HSIC,  
51, 365  
tylnych drzwi, 57
- kwantyfikacja związków przyczynowych, 191
- L**
- lasy przyczynowe, 260, 261  
wyniki, 262
- learnery bazowe drugiej fazy, 224
- LinearDML, 282
- LiNGAM, 361, 366  
wyniki, 369, 370
- LLM, large language models, 301
- Ł**
- łańcuchy, 103, 109  
tworzenie zbioru danych, 110  
zdarzeń, 102
- M**
- macierz  
modelu interwencji, 209  
przyległości, 83  
sąsiedztwa, 83
- maksymalny współczynnik informacji, MIC, 51
- metauczenie, 211

## metody

- oparte na gradiencie, 343
- oparte na ograniczeniach, 343, 353
- oparte na punktacji, 343
- podwójnie niezawodne, DR, 233
- porównanie wydajności, 375
- RCT, 312

MIC, maximal information coefficient, 51

minimalizm, minimality, 341, 342

## model

- ANM, 362
- CausalBert, 306
- DirectLINGAM, 376
- DR-Learner, 242
- GCM, 87
- GES, 376
- GOLEM, 376
- LiNGAM, 366
- LLM
  - a przyczynowość, 301
- NotearsNonlinear, 376
- PC, 376
- SCM, 44, 70, 73, 92, 134, 181, 186
  - graficzna reprezentacja, 75
- szumów addytywnych CCANM, 403

## modele

- interwencji, treatment models, 234
- porównawcze
  - wyniki, 297
- przyczynowe, 170
- regresji
  - dopasowanie, 113
- regresyjne, 73
- strukturalne, 73
- uczenia głębokiego
  - wyniki, 297
- uplift, 263, 274
- różnicowe, uplift modelling, 36
- wyników, outcome models, 234

## modelowanie

- użycie techniki S-Learner, 211
- heterogenicznych efektów interwencji, 263, 289
- problemu
  - tworzenie grafu, 151
  - tworzenie obiektu CausalModel, 153

modułowość, 181

modyfikacja, 54

## N

- niezależność, 353
  - kryteria, 365
  - przyczynowa, 71
    - w grafie, 98
  - warunkowa, 97, 120
  - zmiennych, 96
- NLP, natural language processing, 288
  - scenariusze, 303
- norma Frobeniusa, 385
- NOTEARS, 372

## O

- obliczanie kontrfaktów, 54
- odkrywanie związków przyczynowych, 91, 98, 100, 329
  - ABCI, 404
  - DECI, 398
  - ENCO, 404
  - funkcyjne, 343, 361
  - na podstawie punktacji, 359
  - oparte na gradientach, 372
  - oparte na ograniczeniach, 100, 353
  - osobiste doświadczenia, 335
  - pakiety gCastle, 344
  - problemy, 405
  - spostrzeżenia naukowe, 331
  - uczenie głębokie, 383
  - ukryte zakłócenia, 398
  - założenia, 341
  - zastosowania, 405
  - źródła wiedzy przyczynowej, 329
- odległość
  - euklidesowa, 192
  - Mahalanobisa, 192
  - Minkowskiego, 192
- odwrotne ważenie prawdopodobieństwa, IPW, 204, 236
- odwrócony model regresji, 67
- ograniczenia, 353
- operator
  - do, 129
  - morsa, 44
  - przypisania, 44
  - wartości oczekiwanej, 62
- optymalizator Lagrangiana, 386
- ortogonalizacja, 238
- oszacowania, estimates, 124
  - obliczanie, 156

**P**

pakiet gCastle, 344  
paradoks Simpsona, 37  
paradygmat RLFH, 301  
parametr  
  fluktuacji, 244  
  uciążliwości, nuisance parameter, 249  
polisemia, 301  
porównanie wydajności metod, 375  
prawdopodobieństwo warunkowe, 42  
prawo Twymana, 255  
problem  
  cocktail party, 367  
  Walda, 186  
proces wnioskowania przyczynowego, 146  
prognoza, 54  
przedziały ufności, 279  
przetwarzanie języka naturalnego, NLP, 288  
przyczynowe uczenie maszynowe, 416  
przyczynowość, causality, 30, 50, 88, 312, 421  
  a modele LLM, 301  
  a uczenie nienadzorowane, 58  
  a uczenie półnadzorowane, 58  
  a uczenie ze wzmocnieniem, 57  
  w biznesie, 414  
PSM, propensity score matching, 203  
punktacja, 359  
Python  
  ekosystem analizy przyczynowej, 147

**R**

rachunek do, 140  
  zasady, 141  
RCT, Randomized Controlled Trials, 41,  
  312, 334  
regresja, 67, 109  
  a skutki przyczynowe, 76  
  liniowa, 62, 74  
  interpretacja geometryczna, 66  
  wielozmienna, 113  
  ważonych najmniejszych kwadratów,  
  WLS, 205  
  wielozmienna, multiple regression, 6, 692  
regularyzacja, 248  
reguła  
  front-door, 133  
  potęgi, 77  
  wpływu przyczynowego, 126  
relacje  
  parami, 33  
  pozorne, 184

RL, reinforcement learning, 57  
rozwidlenia, 104, 109  
  tworzenie zestawu danych, 112

**S**

SCM, structural causal model, 42, 70, 342  
separacja d, d-separation, 120  
skojarzenia, 40  
S-Learner, 207, 211, 282  
  słabe punkty, 218  
  szkolenie modelu, 213, 217  
  wyniki, 217  
SNet, 291  
  architektura, 291  
spójność, 183  
sprytna zmienna kowariantowa, clever  
  covariate, 244  
strategia „dziel i zwyciężaj”, 132  
stronniczość  
  ocalałych, survivorship bias, 185  
  wyboru, selection bias, 185, 187  
strukturalne modele przyczynowe, SCM, 42,  
  70, 342  
struktury  $v$ , 106  
SUTVA, 183  
symulacje, 335  
szeregi czasowe, 312  
szkielet grafu, 109

**T**

TARNet, 290  
  architektura, 290  
TCDF, Temporal Causal Discovery  
  Framework, 405  
tekst  
  jako czynnik zakłócający, 305  
  jako interwencja, 304  
  jako wynik, 304  
teoria znaczenia, 299  
teorie Poppera, 158  
testy  
  dwóch próbek klasyfikatora, 268  
  obalające, refutation tests, 156, 158  
  porównawcze CRASS, 303  
T-Learner, 218, 282  
  implementacja modelu, 220  
  wyniki, 221  
TMLE  
  implementacja, 243  
transformatory, 299

## twierdzenie

- Frischa-Waugh-Lovella, 248
- o współczynnikach skłonności, 235

**U**

## uczenie

- asocjacyjne, 31
- głębokie, 289, 383
- maszynowe podwójne, DML, 173, 246, 256
  - a estymator DR-Learner, 258
- implementacja, 249
- wyniki, 251–254
- się przez naśladowanie, 420
- się struktury przyczynowej, 337, 419
- ze wzmocnieniem, RL, 57

## uplift, 263

- według decyla, 274

**W**

## walidacja

- krzyżowa, CV, 157
- modeli przyczynowych, 157

## wartość

- oczekiwana, 62
- p, 65

## warunek przyczynowości Markowa, 98, 99

## warunkowanie, conditioning, 31

## wiedza

- dziedzinowa, 337
- ekspercka, 378, 390, 402, 411
- przyczynowa
  - osobiste doświadczenia, 335
  - źródła, 329

## wielkość próby, 173

## wierność, faithfulness, 341

## WLS, weighted least squares, 205

## wnioskowanie

- kontrafaktyczne, 41
- przyczynowe, 54, 97, 98, 191
- modelowanie problemu, 151
- obalenie oszacowania, 165
- testy obalające, 156
- wyznaczanie estymand, 154, 163
- wyznaczanie oszacowań, 156, 163
- zakodowanie założeń, 161

## wskaźnik

- CATE, 211, 289
- MAPE, 227, 239
- oczekiwanej odpowiedzi, 277
- rzadkości, sparsity score, 385

## wskaźniki przyczynowe, 418

## współczynnik

- AUUC, 274
- korelacji, 315
- MAPE, 216
- Qini, 274
- skłonności, propensity scores, 201, 202, 204, 234

## wybór modelu, 281

## wydajność, 274

## wykorzystanie projektów przyczynowych, 410

## wykres

- linii regresji, 66, 138
- modelu odwróconego, 68
- punktowy, 111, 112
- danych z próbkowaniem selektywnym, 51
- nieliniowego zbioru danych, 363
- relacji parami, 33
- rozzrutu danych nieliniowych, 364
- wartości reszt, 365
- upliftu według decyli, 275, 276

## wymienność, 179

- a zakłócenia, 180

## wynik kontrafaktyczny, 193

## wystarczalność przyczynowa, causal sufficiency, 341

**X**

## X-Learner, 222, 225, 282

- implementacja, 226
- rekonstrukcja modelu, 223
- wyniki, 228, 229

**Z**

## zakłócenia, confounding, 32, 184

- ukryte, 398, 403

## założenie

- braku ukrytych zakłóceń, 101
- dotatniości, 177
- minimalności przyczynowej, 101, 342
- modułowości, 181
- spójności, 183
- SUTVA, 181
- wierności, faithfulness assumption, 100, 341
- wymienności, 179

## zasada wspólnej przyczyny Reichenbacha, 314

## zmienne

- egzogeniczne, 135
- heterogeniczny wpływ na wynik, 77
- instrumentalne, IV, 142, 175
- kontrolne, 70
- niezależne, 96
- szumów, 43
- zależne, 67
- zakłócające, 32

## związki

- pozorne, spurious relationships, 115
- przyczynowe, 91, 92



# PROGRAM PARTNERSKI

— GRUPY HELION —



1. ZAREJESTRUJ SIĘ
2. PREZENTUJ KSIĄŻKI
3. ZBIERAJ PROWIZJĘ

Zmień swoją stronę WWW w działający bankomat!

**Dowiedz się więcej i dołącz już dzisiaj!**

<http://program-partnerski.helion.pl>

GRUPA  
**Helion** 

# Przyczyna i skutek, nic więcej. Pomyłki jako takie nie istnieją...

José Antonio Cotrina, hiszpański pisarz science fiction

W uczeniu maszynowym odkrywanie związków przyczynowych daje możliwości, jakich nie można uzyskać tradycyjnymi technikami statystycznymi. Najnowsze trendy w programowaniu pokazują, że przyczynowość staje się kluczowym zagadnieniem dla generatywnej sztucznej inteligencji. Niezbędna okazuje się więc znajomość grafów przyczynowych i zapytań konfrontacyjnych.

Dzięki tej książce łatwo przyswoisz teoretyczne podstawy i zaczniesz je płynnie wdrażać w rzeczywistych scenariuszach. Dowiesz się, w jaki sposób myślenie przyczynowe ułatwia rozwiązywanie problemów, i poznasz pojęcia Pearla, takie jak strukturalny model przyczynowy, interwencje, kontryfakty itp. Każde zagadnienie zostało dokładnie wyjaśnione i opatrzone zbiorem praktycznych ćwiczeń z kodem w Pythonie. Nauczysz się także implementować poszczególne modele i zrozumiesz, czym się kierować przy wyborze technik i algorytmów do rozwiązywania konkretnych scenariuszy przyczynowych. To przewodnik, który docenią szczególnie inżynierowie uczenia maszynowego i analitycy danych.

## W książce:

- wnioskowanie związków przyczynowych
- budowa i działanie strukturalnych modeli przyczynowych
- czteroetapowy proces wnioskowania związków przyczynowych w Pythonie
- techniki modelowania efektu interwencji
- nowoczesne metody odkrywania związków przyczynowych za pomocą Pythona
- korzystanie z wnioskowania związków przyczynowych

**ALEKSANDER MOLAK** jest niezależnym badaczem i konsultantem w dziedzinie uczenia maszynowego. Współpracował z licznymi firmami w Europie, USA i Izraelu, gdzie uczestniczył w tworzeniu wielkoskalowych systemów uczenia maszynowego. Jest też współzałożycielem firmy *Lespire.io*, dostawcy szkoleń z zakresu sztucznej inteligencji dla zespołów korporacyjnych.

	<b>KOD KORZYŚCI</b> Sięgnij po więcej! ▶	
 <a href="https://helion.pl">helion.pl</a>	ISBN 978-83-289-0832-1	
 <b>HELION SA</b> ul. Kościuszki 1c 44-100 Gliwice tel.: 32 230 98 63 helion@helion.pl	 9 788328 908321	
<b>Cena: 109,00 zł</b>		