



# ROZDZIAŁ 1.

## Związki przyczynowe?


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



**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**




**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))**




Rysunek 1.3. Zależności między zmiennymi a, b i c

## ROZDZIAŁ 2.


### Judea Pearl i drabina przyczynowości




Rysunek 2.1. Drabina przyczynowości. Zdjęcie autora na podstawie fotografii Laurie Shaw (<https://www.pexels.com/photo/brown-wooden-door-frame-804394/>)




**Rysunek 2.2. Reprezentacja strukturalnego modelu przyczynowego w formie grafu**



**Rysunek 2.3. Model grafu przedstawiający przykład księgarni**



**Rysunek 2.4. Wykres punktowy uzyskany na podstawie przyczynowego procesu generowania danych**



**Rysunek 2.5. Wykres punktowy danych z próbkowaniem selektywnym**



## ROZDZIAŁ 3.


### Regresja, obserwacje i interwencje

OLS Regression Results						
=====						
Dep. Variable:	y	R-squared:	0.771			
Model:	OLS	Adj. R-squared:	0.771			
Method:	Least Squares	F-statistic:	1.681e+04			
Date:	Sun, 05 Jun 2022	Prob (F-statistic):	0.00			
Time:	16:44:06	Log-Likelihood:	-3615.0			
No. Observations:	5000	AIC:	7234.			
Df Residuals:	4998	BIC:	7247.			
Df Model:	1					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]
-----						
const	1.1243	0.007	159.391	0.000	1.110	1.138
x1	0.9212	0.007	129.669	0.000	0.907	0.935
=====						
Omnibus:	0.129	Durbin-Watson:	1.986			
Prob(Omnibus):	0.938	Jarque-Bera (JB):	0.163			
Skew:	0.002	Prob(JB):	0.922			
Kurtosis:	2.972	Cond. No.	1.02			
=====						

Notes:

[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

**Rysunek 3.1. Podsumowanie wyników prostego modelu regresji liniowej**




**Rysunek 3.2. Wygenerowane dane i dopasowana linia regresji**

OLS Regression Results						
=====						
Dep. Variable:	y	R-squared:	0.771			
Model:	OLS	Adj. R-squared:	0.771			
Method:	Least Squares	F-statistic:	1.681e+04			
Date:	Sun, 05 Jun 2022	Prob (F-statistic):	0.00			
Time:	19:16:00	Log-Likelihood:	-3375.0			
No. Observations:	5000	AIC:	6754.			
Df Residuals:	4998	BIC:	6767.			
Df Model:	1					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]
-----						
const	-0.9441	0.010	-96.048	0.000	-0.963	-0.925
x1	0.8368	0.006	129.669	0.000	0.824	0.849
=====						
Omnibus:	0.590	Durbin-Watson:	1.994			
Prob(Omnibus):	0.745	Jarque-Bera (JB):	0.582			
Skew:	-0.026	Prob(JB):	0.748			
Kurtosis:	3.003	Cond. No.	2.83			
-----						


Notes:

[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.


**Rysunek 3.3. Zestawienie wyników dla modelu odwróconego**



**Rysunek 3.4. Wizualizacja odwróconego modelu regresji**



**Rysunek 3.5. Przykład modelu SCM z różnymi wzorcami prowadzącymi do fałszywych asocjacji**



**Rysunek 3.6. Graficzna reprezentacja przykładowego modelu SCM**

OLS Regression Results						
=====						
Dep. Variable:	y	R-squared:	0.882			
Model:	OLS	Adj. R-squared:	0.882			
Method:	Least Squares	F-statistic:	7477.			
Date:	Thu, 09 Jun 2022	Prob (F-statistic):	0.00			
Time:	19:40:09	Log-Likelihood:	-1062.2			
No. Observations:	1000	AIC:	2128.			
Df Residuals:	998	BIC:	2138.			
Df Model:	1					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]
-----						
const	-0.0204	0.022	-0.918	0.359	-0.064	0.023
x1	0.9472	0.011	86.468	0.000	0.926	0.969
=====						
Omnibus:	4.922	Durbin-Watson:	1.870			
Prob(Omnibus):	0.085	Jarque-Bera (JB):	3.922			
Skew:	0.038	Prob(JB):	0.141			
Kurtosis:	2.703	Cond. No.	2.02			


Notes:

[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.


**Rysunek 3.7. Wyniki modelu z członem nieliniowym**

## ROZDZIAŁ 4.


### Modele grafów



Rysunek 4.1. Grafy skierowane (a) i nieskierowane (b)




Rysunek 4.2. Graf acykliczny (a) i cykliczny (b)




Rysunek 4.3. Graf spójny (a) i częściowo spójny (b)

$$\begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}$$




Rysunek 4.4. Macierz przyległości  $2 \times 2$  i odpowiadający jej graf

$$\begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 0 \\ 1 & 1 & 0 \end{bmatrix}$$



Rysunek 4.5. Macierz przyległości  $3 \times 3$  i odpowiadający jej graf



Rysunek 4.6. Macierz przyległości 4×4 i odpowiadający jej graf

```
sample_gml = ""graph [
  directed 1


  node [
    id 0
    label "0"
  ]

  node [
    id 1
    label "1"
  ]

  node [
    id 2
    label "2"
  ]


  edge [
    source 0
    target 1
  ]

  edge [
    source 2
    target 1
  ]
]
```




Rysunek 4.7. Definicja grafu w języku GML i odpowiadający jej graf

```
adj_matrix = np.array([
    [0, 1, 0],
    [0, 0, 0],
    [0, 1, 0]
])
```



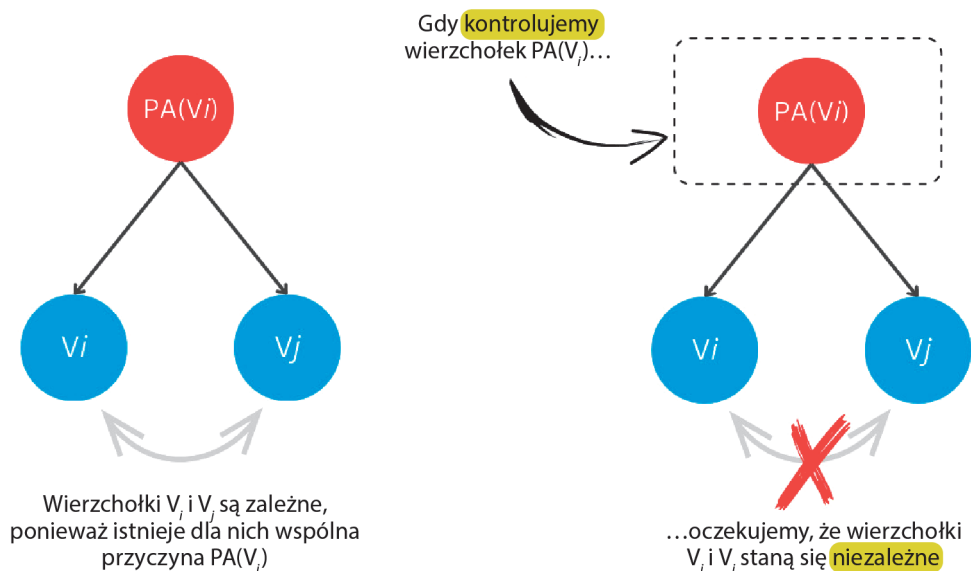
Rysunek 4.8. Macierz przyległości grafu i odpowiadający jej graf



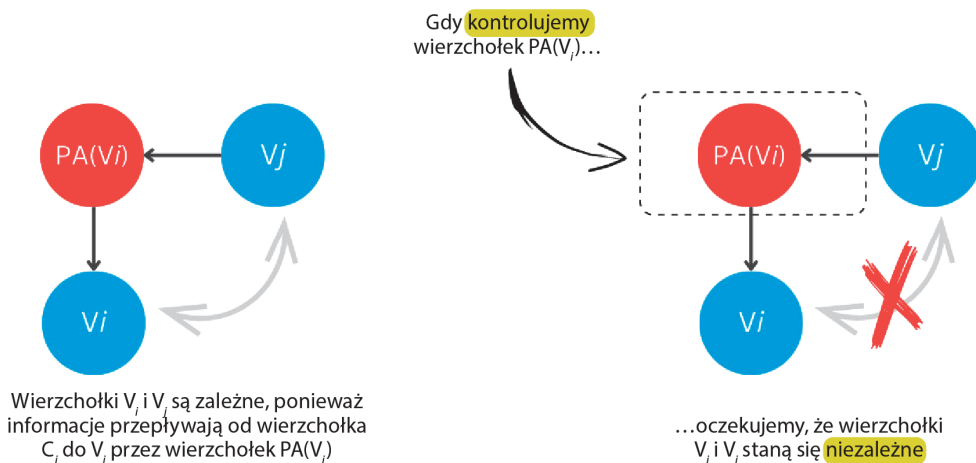
Rysunek 4.9. Wynikowy graf

## ROZDZIAŁ 5.

### Rozwidlenia, łańcuchy i kolidery




Rysunek 5.1. Warunek przyczynowości Markowa. Pierwszy przykład




Rysunek 5.2. Warunek przyczynowości Markowa. Drugi przykład






**Rysunek 5.3. DAG reprezentujący system ostrzegania o kolizji**




Łańcuch 

**Rysunek 5.4. Struktura łańcucha**



Rozwidlenie 

**Rysunek 5.5. Struktura rozwidlenia**




Kolider 

**Rysunek 5.6. Struktura kolidera**





Rysunek 5.7. Wizualna reprezentacja struktur niezależności w przykładzie kolidera




Rysunek 5.8. Przykład klasy MEC

Łańcuch 




Rozwidlenie 



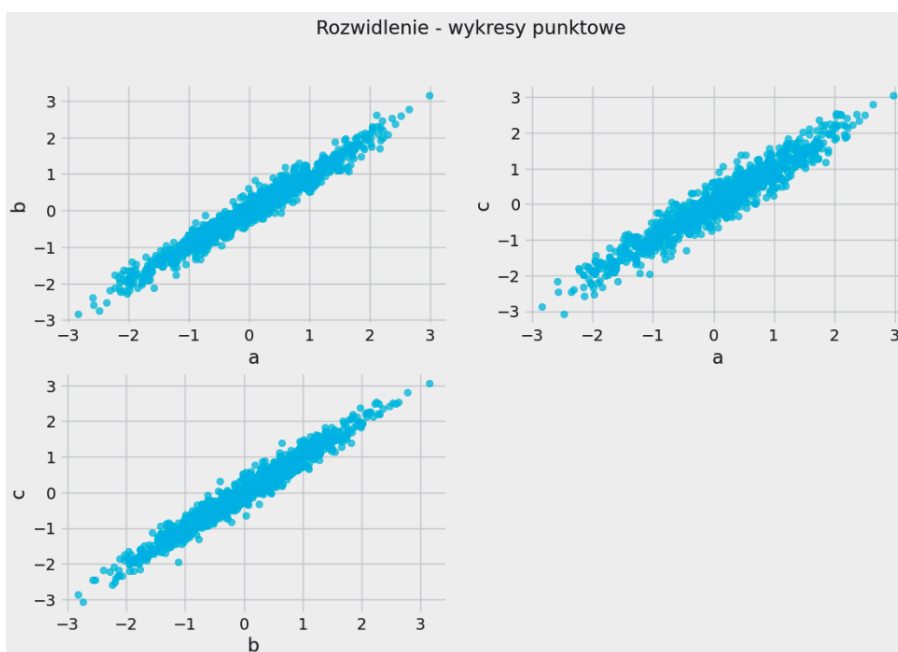
Kolider 



Rysunek 5.9. Graficzne reprezentacje struktur łańcucha, rozwidlenia i kolidera



**Rysunek 5.10. Wykresy punktowe par dla zestawu danych wygenerowanego zgodnie z grafem o strukturze łańcucha**




**Rysunek 5.11. Wykresy punktowe par dla zestawu danych wygenerowanego zgodnie z grafem o strukturze rozwidlenia**




**Rysunek 5.12. Wykresy punktowe par dla zestawu danych wygenerowanego zgodnie z grafem o strukturze kolidera**

Łańcuch 

	coef	std err	t	P> t	[0.025	0.975]
const	-0.0086	0.007	-1.320	0.187	-0.021	0.004
A	-0.0238	0.033	-0.729	0.466	-0.088	0.040
B	1.0217	0.032	31.645	0.000	0.958	1.085

Rozwidlenie 

	coef	std err	t	P> t	[0.025	0.975]
const	0.0077	0.006	1.241	0.215	-0.004	0.020
A	0.0090	0.031	0.292	0.770	-0.052	0.070
B	0.9938	0.032	31.372	0.000	0.932	1.056

Kolider 

	coef	std err	t	P> t	[0.025	0.975]
const	2.082e-17	1.35e-17	1.536	0.125	5.77e-18	4.74e-17
A	-1.0000	2.01e-17	-4.97e+16	0.000	-1.000	-1.000
B	1.0000	1.39e-17	7.19e+16	0.000	1.000	1.000


**Rysunek 5.13. Wyniki analizy regresji dla trzech podstawowych struktur warunkowej niezależności**

## ROZDZIAŁ 6.

### Węzły, krawędzie i statystyczna (nie)zależność




Rysunek 6.1. Pierwsze dwa grafy DAG w grze „Zadbaj o separację d”



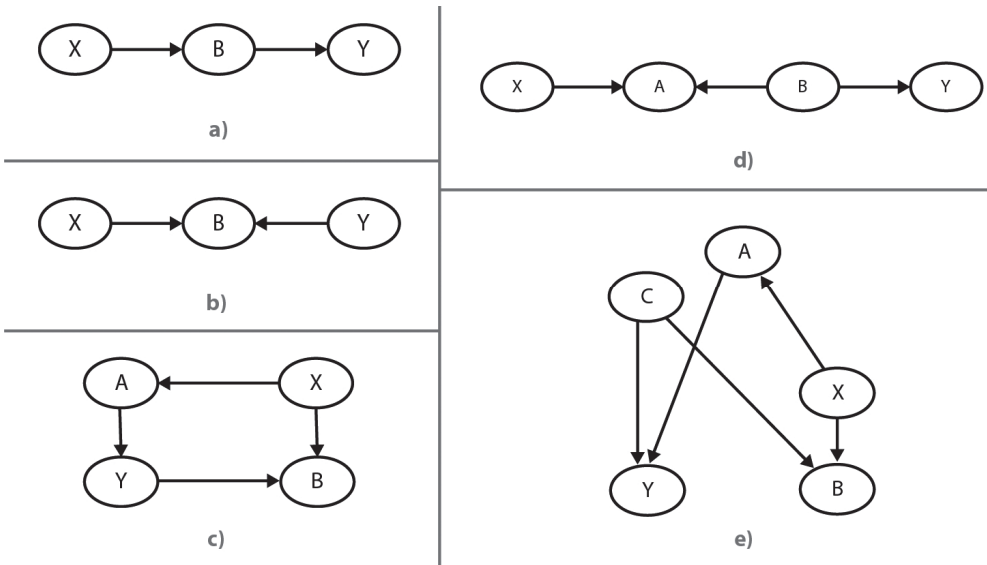
Rysunek 6.2. Graf DAG numer 3 w grze „Zadbaj o separację d”




Rysunek 6.3. Graf DAG numer 4 w grze „Zadbaj o separację d”




Rysunek 6.4. Ostatni graf DAG w grze „Zadbaj o separację d”




Rysunek 6.5. Wszystkie grafy DAG pochodzące z gry „Zadbaj o separację d”




Rysunek 6.6. Przedstawienie problemu z rozdziału 1. (rysunek 1.1) w formie grafu




Rysunek 6.7. Graf ze wzorcem zakłócającym




**Rysunek 6.8. Graf przedstawiający wzorzec z zakłóceniami i jedną nieobserwowaną zmienną**



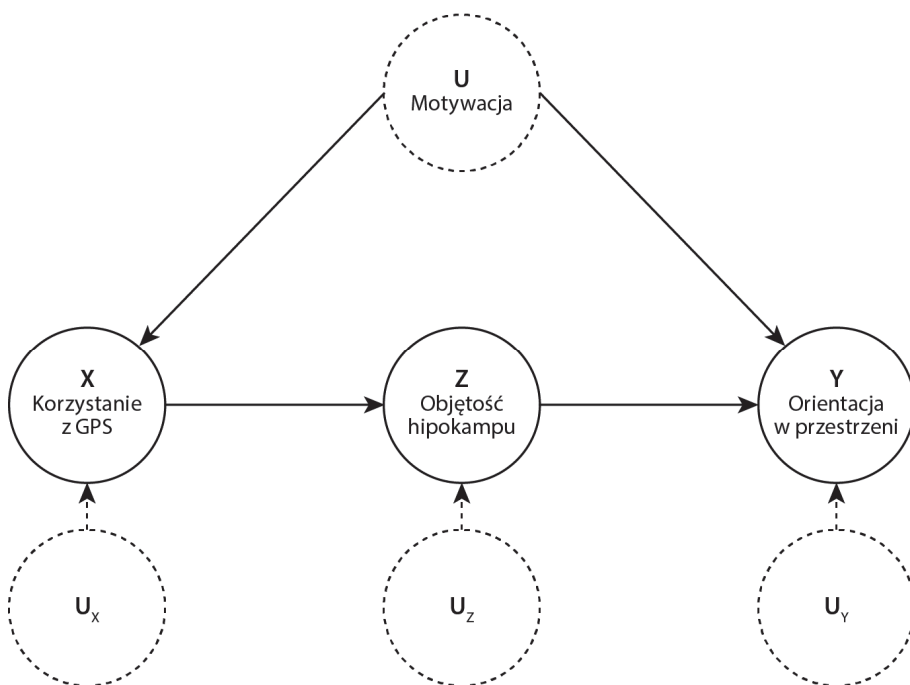
**Rysunek 6.9. Model przedstawiający hipotezę Zuzanny (a) i „pełną” hipotezę (b)**



**Rysunek 6.10. Zaktualizowany model, w którym objętość hipokampu występuje jako mediator**




**Rysunek 6.11. Model ze zaktualizowanymi nazwami zmiennych**




**Rysunek 6.12. Kompletny model łącznie ze zmiennymi egzogenicznymi**






**Rysunek 6.13. Wykresy punktowe pokazujące zależność między korzystaniem z GPS i zmianą orientacji w przestrzeni**




**Rysunek 6.14. Wykres punktowy rozkładu interwencji oraz dwie dopasowane linie regresji**




**Rysunek 6.15. Przykład grafu DAG do zastosowania techniki zmiennych IV**

## ROZDZIAŁ 7.

### Czteroeetapowy proces wnioskowania przyczynowego




Rysunek 7.1. Model z rozdziału 6. w formie grafu




Rysunek 7.2. Wizualizacja przykładowego modelu

Iteracja 1				
Iteracja 2				
Iteracja 3				
Iteracja 4				
Iteracja 5				


Rysunek 7.3. Schemat pięciokrotnego CV



Rysunek 7.4. Model grafu dla przykładów z tego podrozdziału




Rysunek 7.5. Wizualizacja modelu utworzonego za pomocą biblioteki DoWhy



Rysunek 7.6. Reprezentacja grafu w formacie pakietu networkx

## ROZDZIAŁ 8.


### Modele przyczynowe. Założenia i wyzwania




Rysunek 8.1. Model w formie grafu, którego używamy w eksperymencie




Rysunek 8.2. Wyniki eksperymentu z wielkością próby




Rysunek 8.3. Przykład naruszenia warunku dodatniości




Rysunek 8.4. Możliwe trajektorie ekstrapolacji (linie)




Rysunek 8.5. Spełniony warunek dodatniości




**Rysunek 8.6. Przykład modelu SCM modułowości  $\mathcal{S}$**




**Rysunek 8.7. Zmodyfikowany model SCM  $\mathcal{S}_M$**




**Rysunek 8.8. Reprezentacja problemu Walda w postaci modelu SCM**



**Rysunek 8.9. Histogram uszkodzeń samolotów w zależności od C**



**Rysunek 8.10. Przykład stronniczości wyboru**



**Rysunek 8.11. Przykład stronniczości wyboru bez krawędzi między T i C**



## ROZDZIAŁ 9.

### Wnioskowanie związków przyczynowych i uczenie maszynowe — od dopasowywania do metalearnerów

$$\hat{\tau}_{ATE} = \frac{1}{N} \sum_i (2T_i - 1)(Y_i - Y_{j(i)})$$

Jednostka A  $(2 \times 1 - 1)(9 - 1.5) = 1 \times 7.5 = 7.5$

Jednostka B  $(2 \times 0 - 1)(1.5 - 9) = -1 \times -7.5 = 7.5$

$$\hat{\tau}_{ATE} = \frac{1}{2}(7.5 + 7.5) = \frac{1}{2} \times 15 = 7.5$$


Rysunek 9.1. Wizualna reprezentacja obliczeń wzoru dopasowywania dla danych z tabeli 9.1

	age	took_a_course	earnings
0	19	False	110579.0
1	28	False	142577.0
2	22	True	130520.0
3	25	True	142687.0
4	24	False	127832.0


Rysunek 9.2. Pierwsze pięć wierszy zbioru danych o zarobkach

35	False	172134.250000
	True	180404.500000
36	False	175240.666667
37	False	181514.000000
	True	187627.000000
38	False	185546.333333
39	False	187253.666667

Rysunek 9.3. Wybrane wiersze danych pogrupowane według wieku



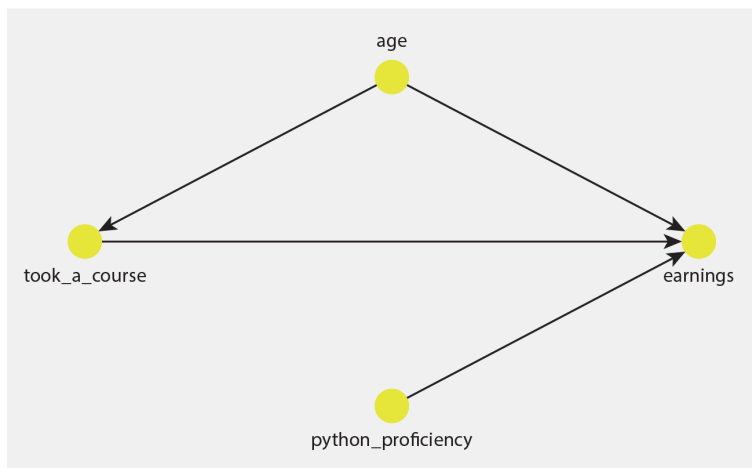
Rysunek 9.4. Reprezentacja modelu danych zarobków w formie grafu



**Rysunek 9.5. Prawdopodobieństwo znalezienia dokładnego dopasowania w zależności od wymiarowości zbioru danych**

		Kupuje bez interwencji	
		Tak	Nie
Kupuje po poddaniu interwencji	Tak	Ależ oczywiście	Perswazyjni
	Nie	Nie przeszkadzać	Przegrana sprawa

**Rysunek 9.6. Macierz modelu interwencji**




**Rysunek 9.7. Graf przyczynowy (DAG) dla rozszerzonego zbioru danych o zarobkach**

	age	python_proficiency	took_a_course	earnings
0	23	0.632318	True	139267.0
1	20	0.602551	False	115569.0
2	21	0.518225	False	119142.0
3	25	0.945161	False	130291.0
4	30	0.636251	True	164209.0


**Rysunek 9.8. Pierwsze pięć wierszy rozszerzonego zbioru danych o zarobkach (dane szkoleniowe)**

	age	python_proficiency	took_a_course	true_effect
0	30	0.223877	True	11120.0
1	23	0.394152	True	11970.0
2	37	0.214638	True	11073.0
3	21	0.869069	True	14345.0
4	41	0.833934	True	14169.0


**Rysunek 9.9. Pierwsze pięć wierszy rozszerzonego zbioru danych o zarobkach (dane testowe)**




**Rysunek 9.10. Rzeczywisty efekt (oś x) w porównaniu z przewidywanym efektem (oś y) dla mechanizmu S-Learner przeszkolonego na pełnych danych**




**Rysunek 9.11. Wyniki dla mechanizmu S-Learner przeszkolonego na 100 obserwacjach**




**Rysunek 9.12. Graficzna prezentacja zasad podziału w modelu T-Learner**



**Rysunek 9.13. Wyniki modelu T-Learner przeszkolonego na pełnych danych**




**Rysunek 9.14. Wyniki dla modelu X-Learner**



**Rysunek 9.15. Wyniki estymatora X-Learner na małym zbiorze danych**

## ROZDZIAŁ 10.

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




Rysunek 10.1. Dwa modele: bez współczynnika skłonności i z uwzględnieniem tego współczynnika

Obliczanie średniej


$$\hat{\tau}_{ATE} = \frac{1}{N} \sum_i \left( \underbrace{\left( \frac{T_i(Y_i - \mu_1(X_i))}{\hat{e}(X_i)} + \mu_1(X_i) \right)}_{\mu_1 = \text{model z interwencją}} \right) - \frac{1}{N} \sum_i \left( \underbrace{\left( \frac{(1 - T_i)(Y_i - \mu_0(X_i))}{1 - \hat{e}(X_i)} + \mu_0(X_i) \right)}_{\mu_0 = \text{model bez interwencji}} \right)$$

Rysunek 10.2. Oznaczony kolorami wzór estymatora DR







**Rysunek 10.3. Rzeczywisty i prognozowany efekt dla liniowego modelu DR-Learner**




**Rysunek 10.4. Rzeczywisty i prognozowany efekt dla nieliniowego modelu DR-Learner**




**Rysunek 10.5. Efekt rzeczywisty a prognozowany efekt dla liniowego estymatora DML**



**Rysunek 10.6. Rzeczywisty i prognozowany efekt dla liniowego estymatora DML z mniej złożonymi modelami i czterema fałdami dopasowania krzyżowego**



**Rysunek 10.7. Wyniki DML po dostrzeżeniu hiperparametrów**




**Rysunek 10.8. Wyniki dla lasu przyczynowego z wykorzystaniem modelu DML (bez dostrajania)**


	recency	history	mens	womens	newbie	visit	conversion	spend	zip_code_rural
0	10	142.44	1	0	0	0	0	0.0	0
1	6	329.08	1	1	1	0	0	0.0	1
2	7	180.65	0	1	1	0	0	0.0	0
3	9	675.83	1	0	1	0	0	0.0	1
4	2	45.34	1	0	0	0	0	0.0	0

zip_code_surburban	zip_code_urban	channel_multichannel	channel_phone	channel_web	treatment
1	0	0	1	0	1
0	0	0	0	1	0
1	0	0	0	1	1
0	0	0	0	1	2
0	1	0	0	1	1

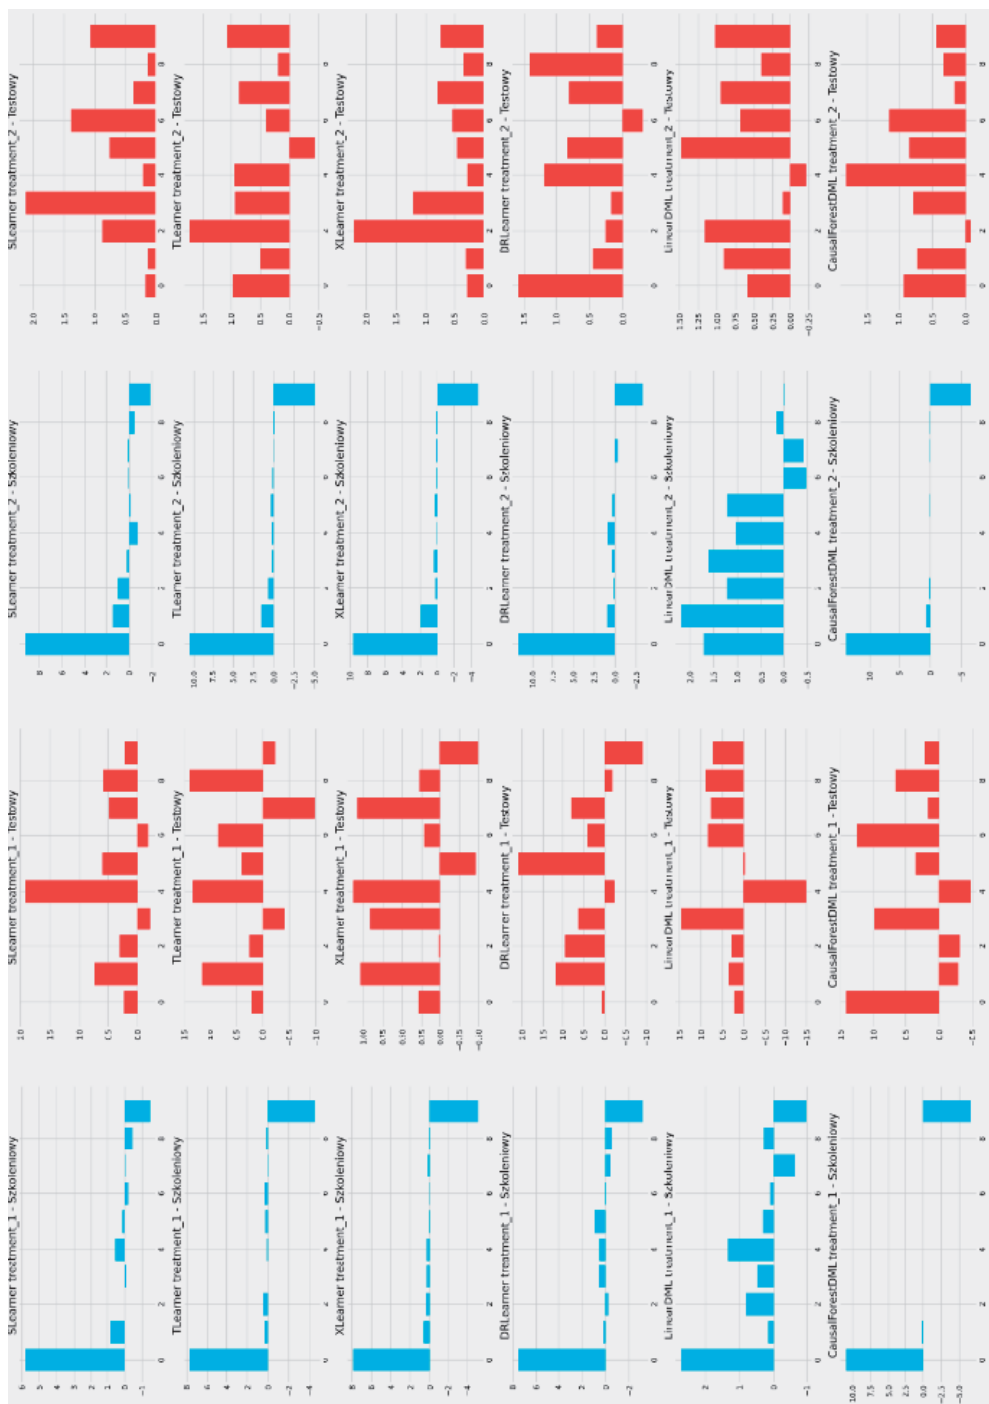
Rysunek 10.9. Pierwsze pięć wierszy zbioru danych Hillstroma



Rysunek 10.10. Empiryczny rozkład losowych modeli a dokładność modelu




Rysunek 10.11. Przykład wykresu uplift według decyli



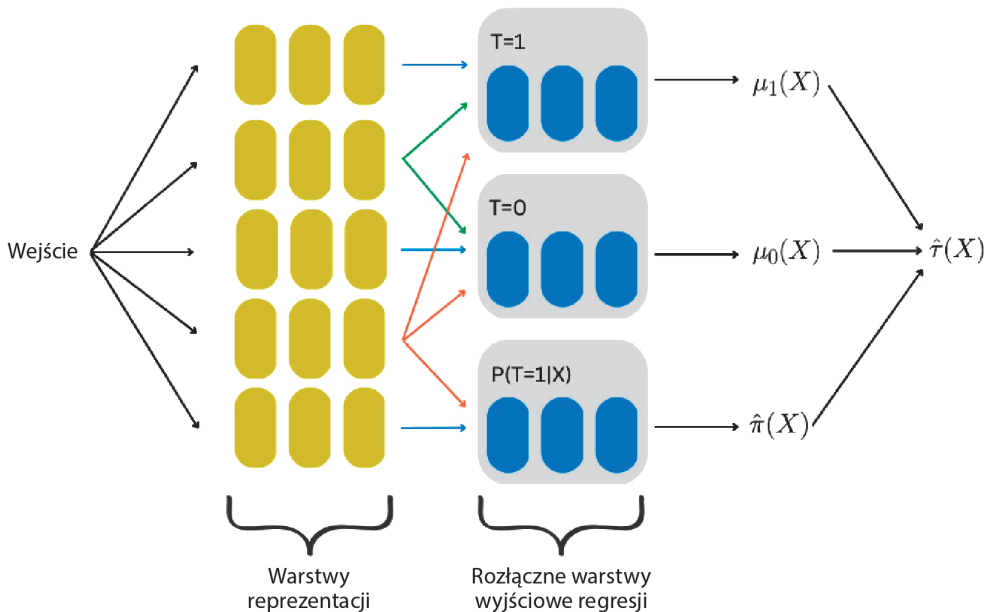
Rysunek 10.12. Wykresy upliftu według decyli

## ROZDZIAŁ 11.

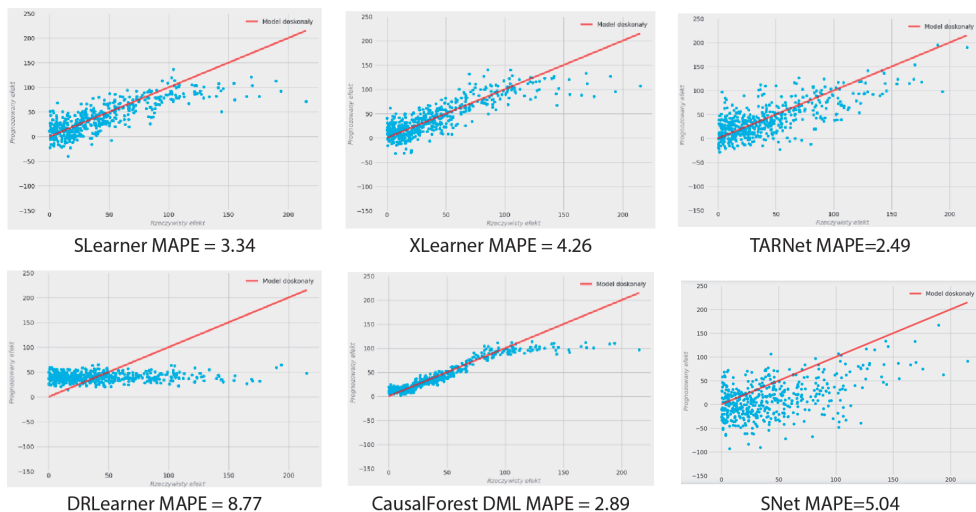
### Wnioskowanie związków przyczynowych i uczenie maszynowe — uczenie głębokie, przetwarzanie języka naturalnego i inne techniki



Rysunek 11.1. Uproszczona architektura TARNet



Rysunek 11.2. Uproszczona architektura SNet



**Rysunek 11.3. Wyniki dla modeli porównawczych i modeli uczenia głębokiego (TARNet i SNet)**

RA

Jan jest wrażliwy na kawę. Wypił rano kawę i teraz boli go brzuch.

✎


Czy bolałby go brzuch, gdyby rano nie wypił kawy?

GPT

Jeśli Jan jest wrażliwy na kawę i wypił ją rano, co spowodowało ból brzucha, to można zakładać, że gdyby rano nie wypił kawy, to jego brzuch nie bolałby z tego konkretnego powodu. Jednak ból brzucha może mieć wiele różnych przyczyn, więc nie można całkowicie wykluczyć innych możliwych źródeł bólu. W każdym przypadku, aby dokładnie określić przyczynę bólu brzucha i ewentualne czynniki wpływające na jego wystąpienie, zaleca się skonsultowanie się z lekarzem.


📄 👍 👎

**Rysunek 11.4. Rozumowanie kontrfakcyjne systemu ChatGPT**




**Rysunek 11.5. Wydajność modeli i ludzi w kontrfakcyjnym teście porównawczym CRASS**






**Rysunek 11.6. Graf DAG serwisu Reddit**




**Rysunek 11.7. Architektura CausalBert**

	text	subreddit	female_avatar	has_photo	upvote
0	What's your favorite romance manga with a fema...	manga	1	0	1
1	As a woman, I find 'Nana' to be a very empower...	manga	1	0	0
2	Can we talk about how badass the female charac...	manga	1	0	0
3	Any other ladies here obsessed with 'Ouran Hig...	manga	1	1	0
4	Just finished reading 'Skip Beat!' and I'm in ...	manga	1	1	1


**Rysunek 11.8. Zestaw danych pseudo-Reddit dotyczący mangi**




**Rysunek 11.9. Zmienna wynikowa (cel) i zbiór potencjalnych zmiennych dawców**



**Rysunek 11.10. Rzeczywisty cel i prognoza na podstawie zmiennych dawców**




**Rysunek 11.11. Zmienna wynikowa (cel), zestaw potencjalnych zmiennych dawcy i interwencja**



**Rysunek 11.12. Rzeczywisty cel i prognoza na podstawie zmiennych z puli dawcy w okresie przed interwencją i po niej**


	date	twitter	linkedin	tiktok	instagram
0	2022-05-15	55	9	23	59
1	2022-05-16	54	18	20	59
2	2022-05-17	54	20	23	57
3	2022-05-18	54	20	21	55
4	2022-05-19	49	23	21	52

**Rysunek 11.13. Pierwsze pięć wierszy zbioru danych dotyczących liczby wyszukiwań w mediach społecznościowych**



**Rysunek 11.14. Dane dotyczące liczby wyszukiwań na platformach mediów społecznościowych**


Pre-intervention Bayesian  $R^2$ : 0.386  
(std = 0.020)




**Rysunek 11.15. Wyniki dopasowanego modelu**

## ROZDZIAŁ 13.


### Odkrywanie związków przyczynowych i uczenie maszynowe — od założeń do zastosowań




Rysunek 13.1. Graf reprezentujący macierz przyległości  $g$




Rysunek 13.2. Rzeczywisty graf DAG kontra graf wyuczony




**Rysunek 13.3. Mapy termiczne reprezentujące wyuczone i rzeczywiste macierze przyległości**




**Rysunek 13.4. Trzy podstawowe struktury grafów**




**Rysunek 13.5. Przykładowy graf, którego będziemy używać w tym podrozdziale**



Rysunek 13.6. Algorytm PC krok po kroku




Rysunek 13.7. Porównanie grafu DAG wyuczony przez algorytm PC (po lewej) z rzeczywistym (po prawej)



Rysunek 13.8. Wyniki działania algorytmu GES




**Rysunek 13.9. Trzy słynne struktury wykorzystujące symetrię: Tadź Mahal w Indiach (u góry po lewej; zdjęcie autorstwa Maahid Photos), piramidy w Egipcie (u dołu po lewej; zdjęcie autorstwa Diego Ferrari), Notre Dame we Francji (po prawej; zdjęcie autorstwa Maksa Avansa) — wszystkie zdjęcia można znaleźć w serwisie Pexels.com**




**Rysunek 13.10. Wykres punktowy nieliniowego zbioru danych**

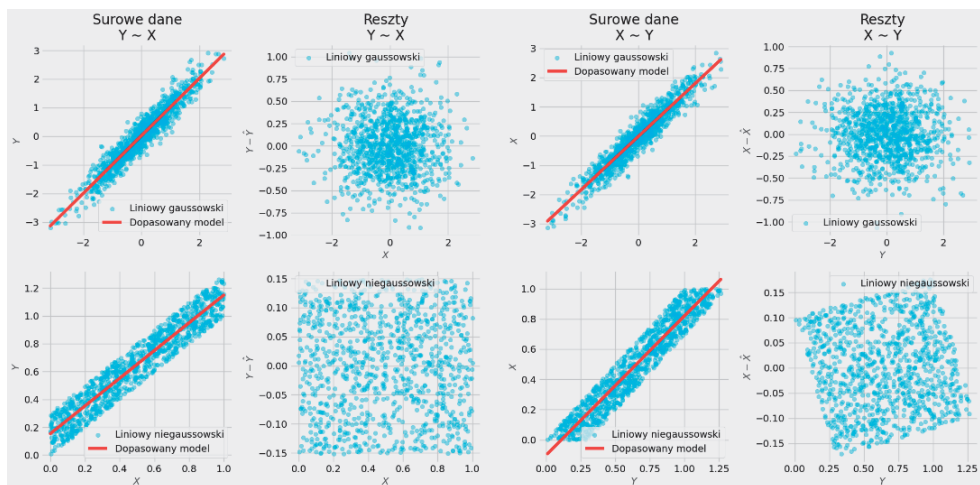





**Rysunek 13.11. Wykres punktowy rozrzutu danych nieliniowych z dwiema dopasowanymi krzywymi regresji**




**Rysunek 13.12. Wykresy punktowe reszt dla modelu przyczynowego i antyprzyczynowego**




Rysunek 13.13. Dane gaussowskie i niegaussowskie z dopasowanymi liniami regresji




Rysunek 13.14. Wyniki modelu LiNGAM




Rysunek 13.15. Wyniki modelu LiNGAM dla danych niegaussowskich



**Rysunek 13.16. Wyniki modelu LiNGAM (po prawej) w porównaniu z początkowym grafem DAG (po lewej) i wyjściowe równania strukturalne (u góry)**



**Rysunek 13.17. Graf wykorzystany w eksperymencie porównawczym**



Bez wcześniejszej wiedzy

Z wcześniejszą wiedzą



SHD: 5  
FDR: 0.2  
F1: 0.75

Liczba nieskier. krawędzi: 1




SHD: 5  
FDR: 0.2  
F1: 0.75

Liczba nieskier. krawędzi: 1


Rysunek 13.18. Wyniki dla algorytmu PC przed dodaniem wiedzy i po tym fakcie

## ROZDZIAŁ 14.


### Odkrywanie związków przyczynowych i uczenie maszynowe — zaawansowane uczenie głębokie i nie tylko




Rysunek 14.1. Wygenerowany graf DAG



Rysunek 14.2. Rzeczywista macierz przyległości z zaznaczonymi krawędziami pochodzącymi z wcześniejszej wiedzy




Rysunek 14.3. Macierz odtworzona za pomocą modelu DECI i macierz rzeczywista



Rysunek 14.4. Graf z nieobserwowanym czynnikiem zakłócającym

## ROZDZIAŁ 15.

### Epilog



**Rysunek 15.1. Nauka przyczynowości według Quentina Gallei**