

W prostocie tkwi siła

Wydanie II

Statystyka

DLA
BYSTRZAKÓW™

Dowiedz się, jak:

- zrozumieć koncepcje statystyczne, techniki, wzory i obliczenia
- interpretować diagramy i wykresy, określać prawdopodobieństwo oraz ustalać przedziały ufności
- weryfikować i analizować dane z eksperymentów i sondaży



septem
septem.pl

Deborah J. Rumsey

adiunkt na Wydziale Statystyki Uniwersytetu Stanowego Ohio

Tytuł oryginału: Statistics For Dummies, 2nd Edition

Tłumaczenie: Leszek Sielicki

ISBN: 978-83-283-2770-2

Original English language edition Copyright © 2011 by Wiley Publishing, Inc., Indianapolis, Indiana
All rights reserved including the right of reproduction in whole or in part in any form.
This translation published by arrangement with John Wiley & Sons, Inc.

Oryginalne angielskie wydanie Copyright © 2011 by Wiley Publishing, Inc., Indianapolis, Indiana
Wszelkie prawa, włączając prawo do reprodukcji całości lub części w jakiegokolwiek formie, zarezerwowane.
Tłumaczenie opublikowane na mocy porozumienia z John Wiley & Sons, Inc.

Translation copyright © 2016 by Helion SA

Wiley, the Wiley Publishing Logo, For Dummies, Dla Bystrzaków, the Dummies Man logo, A Reference for the Rest of Us!, The Dummies Way, Dummies Daily, The Fun and Easy Way, Dummies.com, Making Everything Easier, and related trade dress are trademarks or registered trademarks of John Wiley & Sons, Inc. and/or its affiliates in the United States and/or other countries. Used by permission.

Wiley, the Wiley Publishing Logo, For Dummies, Dla Bystrzaków, the Dummies Man logo, A Reference for the Rest of Us!, The Dummies Way, Dummies Daily, The Fun and Easy Way, Dummies.com, Making Everything Easier, i związana z tym szata graficzna są markami handlowymi John Wiley and Sons, Inc. i/lub firm stowarzyszonych w Stanach Zjednoczonych i/lub innych krajach. Wykorzystywane na podstawie licencji.

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.

Autor oraz Wydawnictwo HELION 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 Wydawnictwo HELION 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

<http://dlabystrzakow.pl/user/opinie/staby2>

Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Wydawnictwo HELION

ul. Kościuszki 1c, 44-100 Gliwice

tel. 32 231 22 19, 32 230 98 63

e-mail: dlabystrzakow@dlabystrzakow.pl

WWW: <http://dlabystrzakow.pl>

Printed in Poland.

- Kup książkę
- Poleć książkę
- Oceń książkę

- Księgarnia internetowa
- Lubię to! » Nasza społeczność

Spis treści

| | |
|---|-----------|
| O autorce | 15 |
| Podziękowania od autorki | 17 |
| Wstęp | 19 |
| O książce | 20 |
| Konwencje zastosowane w książce | 20 |
| Czego nie czytać | 21 |
| Naiwne założenia | 21 |
| Jak podzielona jest książka | 21 |
| Część I: Istotne statystyki dotyczące statystyki | 21 |
| Część II: Podstawy wykonywania obliczeń | 22 |
| Część III: Rozkłady i centralne twierdzenie graniczne | 22 |
| Część IV: Przewidywanie i hipotetyzowanie z przekonaniem | 22 |
| Część V: Badania statystyczne i pogoń za znaczącą relacją | 23 |
| Część VI: Dekalogi | 23 |
| Ikony użyte w książce | 23 |
| Co dalej | 24 |

Część I: Istotne statystyki dotyczące statystyki 25

| | |
|---|-----------|
| Rozdział 1: Statystyka w pigułce | 27 |
| Powodzenie w statystycznym świecie | 27 |
| Projektowanie odpowiednich badań | 28 |
| Sondáže | 29 |
| Eksperymenty | 29 |
| Gromadzenie wartościowych danych | 30 |
| Dobór właściwej próby | 30 |
| Unikanie tendencyjności danych | 31 |
| Tworzenie skutecznych podsumowań | 32 |
| Statystyki opisowe | 32 |
| Wykresy i grafy | 33 |
| Ustalanie rozkładów | 34 |
| Prowadzenie właściwych analiz | 34 |
| Błąd statystyczny i przedziały ufności | 35 |
| Testowanie statystyczne | 36 |
| Korelacja, regresja i tabele krzyżowe | 37 |

6 Statystyka dla bystrzaków ---

| | |
|--|-----------|
| Wyciąganie wiarygodnych wniosków | 38 |
| Podawanie zawyżonych wyników | 38 |
| Kwestionowanie twierzeń o przyczynie i skutku | 38 |
| Jak być detektywem, a nie sceptykiem | 39 |
| Rozdział 2: Statystyka w codziennym życiu | 41 |
| Statystyka i media — więcej pytań niż odpowiedzi? | 41 |
| Sondowanie problemów z popcornem | 42 |
| Walka z wirusami | 42 |
| Ustalanie przyczyn wypadków | 43 |
| Rozważania nad pomyłkami lekarskimi | 44 |
| Kwestie utraty gruntów | 44 |
| Kontrolowanie szkół | 44 |
| Problematyka sportowa | 45 |
| Wiadomości ekonomiczne | 46 |
| Informacje turystyczne | 46 |
| Badanie statystyk seksualnych | 47 |
| Dywagacje nad prognozami pogody | 47 |
| Rozmyślania o filmach | 48 |
| Prześwietlanie horoskopów | 48 |
| Wykorzystywanie statystyki w pracy | 48 |
| Odbieranie porodów — oraz udzielanie informacji | 49 |
| Pozowanie do zdjęć | 49 |
| Gromadzenie danych o pizzy | 50 |
| Statystyki w biurze | 50 |
| Rozdział 3: Przejmujemy kontrolę — tak wiele liczb i tak mało czasu | 51 |
| Wykrywanie błędów, przesady i zwykłych kłamstw | 52 |
| Sprawdzanie obliczeń | 52 |
| Wykrywanie mylących statystyk | 53 |
| Poszukiwanie kłamstw we właściwych miejscach | 59 |
| Skutki mylących statystyk | 59 |
| Rozdział 4: Narzędzia pracy | 61 |
| Statystyka — więcej niż tylko liczby | 61 |
| Poznajemy podstawy statystycznego żargonu | 63 |
| Dane | 63 |
| Zbiór danych | 64 |
| Zmienna | 65 |
| Populacja | 65 |
| Próba losowa czy inna? | 66 |
| Statystyka | 67 |
| Parametr | 68 |
| Tendencyjność | 68 |
| Średnia (przeciętna) | 69 |
| Mediana | 69 |
| Odchylenie standardowe | 69 |
| Percentyl | 70 |

| | |
|---------------------------------------|----|
| Wynik standaryzowany | 70 |
| Rozkład i rozkład normalny | 71 |
| Centralne twierdzenie graniczne | 72 |
| Wartości z | 73 |
| Eksperymenty | 73 |
| Sondaże (ankiety) | 74 |
| Błąd statystyczny | 75 |
| Przedział ufności | 76 |
| Testowanie statystyczne | 77 |
| Wartości p | 77 |
| Istotność statystyczna | 78 |
| Korelacja kontra przyczynowość | 79 |

Część II: Podstawy wykonywania obliczeń 81

Rozdział 5: Średnie, mediany i nie tylko 83

| | |
|--|-----|
| Podsumowywanie danych z wykorzystaniem statystyk opisowych | 83 |
| Obliczenia danych kategoriycznych — tabele i wartości procentowe | 84 |
| Badanie środka za pomocą średniej i mediany | 86 |
| Uśrednianie do średniej | 87 |
| Podział danych według mediany | 88 |
| Porównywanie średnich i median — histogramy | 89 |
| Pojęcie rozproszenia | 91 |
| Ustalanie odchylenia standardowego | 91 |
| Poza zakresem | 95 |
| Badanie reguły trzech sigm | 95 |
| Pomiar pozycji względnej za pomocą percentyli | 97 |
| Obliczanie percentyli | 98 |
| Interpretacja percentyli | 99 |
| Zestawianie podsumowania pięcioliczbowego | 101 |
| Badanie rozstępu ćwiartkowego | 103 |

Rozdział 6: Właściwy obraz — wykresy danych kategoriycznych 105

| | |
|--|-----|
| Kawalki układanki — wykresy kołowe | 105 |
| Podział wydatków osobistych | 106 |
| Dochody z loterii | 107 |
| Jedzenie z dostawą do domu | 108 |
| Analiza trendów struktury wiekowej | 109 |
| Podnoszenie poprzeczki na wykresach słupkowych | 110 |
| Śledzenie kosztów transportu | 110 |
| Zyski z loterii | 112 |
| Kwestia skali na wykresie słupkowym | 113 |
| Rozmyślenia nad najbardziej irytującymi sytuacjami w miejscu pracy | 114 |

Rozdział 7: Krok po kroku — wykresy danych liczbowych 117

| | |
|---|-----|
| Histogramy | 117 |
| Tworzenie histogramu | 117 |
| Interpretacja histogramu | 120 |
| Obrazy i liczby | 124 |
| Wykrywanie mylących histogramów | 125 |
| Badanie wykresów pudełkowych | 128 |
| Tworzenie wykresu pudełkowego | 128 |
| Interpretacja wykresu pudełkowego | 130 |
| Tworzenie wykresów czasowych | 135 |
| Interpretacja wykresów czasowych | 135 |
| Kwestia zróżnicowania — wykresy czasowe kontra histogramy | 136 |
| Wyszukiwanie mylących wykresów czasowych | 136 |

**Część III: Rozkłady i centralne
twierdzenie graniczne 141****Rozdział 8: Zmienne losowe i rozkład dwumianowy 143**

| | |
|--|-----|
| Definiowanie zmiennej losowej | 143 |
| Zmienne dyskretne i ciągłe | 144 |
| Rozkłady prawdopodobieństw | 145 |
| Średnia i wariancja dyskretnej zmiennej losowej | 146 |
| Identyfikacja dwumianu | 146 |
| Sprawdzanie warunków rozkładu dwumianowego krok po kroku | 147 |
| Brak ustalonej liczby prób | 148 |
| Więcej niż sukces lub porażka | 148 |
| Próby nie są niezależne | 148 |
| Prawdopodobieństwo sukcesu (p) ulega zmianie | 149 |
| Znajdowanie prawdopodobieństw dwumianowych z wykorzystaniem wzoru | 149 |
| Znajdowanie prawdopodobieństw dwumianowych z wykorzystaniem tablicy dwumianowej | 151 |
| Znajdowanie prawdopodobieństw dla określonych wartości X | 152 |
| Znajdowanie prawdopodobieństw dla X większego lub mniejszego od określonej wartości oraz dla znajdującego się pomiędzy dwiema wartościami | 152 |
| Sprawdzanie średniej i odchylenia standardowego zmiennej o rozkładzie dwumianowym | 153 |

Rozdział 9: Rozkład normalny 155

| | |
|--|-----|
| Badanie podstaw rozkładu normalnego | 155 |
| Spotkanie ze standardowym rozkładem normalnym (rozkładem Z) | 158 |
| Sprawdzanie Z | 158 |
| Standaryzacja X do Z | 159 |
| Znajdowanie prawdopodobieństw dla Z z wykorzystaniem tablicy Z | 160 |
| Znajdowanie prawdopodobieństw dla rozkładu normalnego | 161 |
| Znajdowanie X , gdy znamy wartość procentową | 164 |
| Ustalanie percentyli dla rozkładu normalnego | 164 |
| Podchwytliwe sformułowania w zadaniach z percentylami | 166 |
| Aproksymacja rozkładu dwumianowego rozkładem normalnym | 167 |

| | |
|---|----------------|
| Rozdział 10: Rozkład t-Studenta | 169 |
| Podstawy rozkładu t-Studenta | 169 |
| Porównanie rozkładów Z i t-Studenta | 169 |
| Ustalanie wpływu zróżnicowania na rozkłady t-Studenta | 170 |
| Korzystanie z tablicy t-Studenta | 171 |
| Znajdowanie prawdopodobieństw z wykorzystaniem tablicy rozkładu t-Studenta | 172 |
| Ustalanie percentyli dla rozkładu t-Studenta | 172 |
| Określanie wartości t^* dla przedziałów ufności | 173 |
| Badanie zachowań z wykorzystaniem tablicy t-Studenta | 173 |
| Rozdział 11: Rozkłady z prób i centralne twierdzenie graniczne | 175 |
| Definiowanie rozkładu z próby | 175 |
| Średnia rozkładu z próby | 177 |
| Pomiar błędu standardowego | 177 |
| Liczebność próby a błąd standardowy | 178 |
| Odchylenie standardowe a błąd standardowy dla populacji | 179 |
| Kształt rozkładu z próby | 181 |
| Przypadek 1.: rozkład X jest normalny | 181 |
| Przypadek 2.: rozkład X nie jest normalny — pojawia się centralne twierdzenie graniczne | 181 |
| Znajdowanie prawdopodobieństw dla średniej z próby | 184 |
| Rozkład z próby dla odsetka z próby | 185 |
| Znajdowanie prawdopodobieństw dla odsetka z próby | 187 |
| Część IV: Przewidywanie i hipotetyzowanie z przekonaniem | 189 |
| Rozdział 12: Miejsce na błąd statystyczny | 191 |
| Istotność plusa i minusa | 191 |
| Ustalanie błędu statystycznego — wzór ogólny | 193 |
| Pomiar zróżnicowania próby | 193 |
| Obliczanie błędu statystycznego dla odsetka z próby | 194 |
| Ogłaszanie wyników | 196 |
| Obliczanie błędu statystycznego dla średniej z próby | 196 |
| Przekonanie, że mamy rację | 198 |
| Ustalanie znaczenia liczebności próby | 198 |
| Liczebność próby a błąd statystyczny | 198 |
| Więcej nie zawsze znaczy (o wiele) lepiej! | 199 |
| Utrzymanie błędu statystycznego w odpowiedniej perspektywie | 199 |
| Rozdział 13: Przedziały ufności — trafne oszacowania | 201 |
| Nie wszystkie oszacowania są sobie równe | 201 |
| Łączenie statystyki z parametrem | 202 |
| Kwestie nazewnictwa | 203 |
| Interpretacja wyników | 204 |
| Problematyka zakresu | 204 |

| | |
|--|------------|
| Wybór poziomu ufności | 205 |
| Uwzględnianie liczebności próby | 207 |
| Ocena zróżnicowania populacji | 208 |
| Obliczanie przedziału ufności dla średniej z populacji | 209 |
| Przypadek 1.: odchylenie standardowe populacji jest znane | 209 |
| Przypadek 2.: odchylenie standardowe populacji nie jest znane i/lub wartość n jest niewielka | 210 |
| Ustalanie pożądanej wartości liczebności próby | 211 |
| Ustalanie przedziału ufności dla pojedynczego odsetka populacji | 213 |
| Określanie przedziału ufności dla różnicy dwóch średnich | 214 |
| Przypadek 1.: odchylenia standardowe populacji są znane | 215 |
| Przypadek 2.: odchylenia standardowe populacji są nieznanne i/lub liczebności prób są niewielkie | 216 |
| Szacowanie różnicy dwóch odsetków | 217 |
| Znajdowanie mylących przedziałów ufności | 219 |
| Rozdział 14: Twierdzenia, testy i wnioski | 221 |
| Formułowanie hipotez | 222 |
| Definiowanie zera | 222 |
| Jaka jest alternatywa? | 222 |
| Gromadzenie dowodów (danych) | 223 |
| Zestawianie dowodów — statystyka testowa | 224 |
| Gromadzenie statystyk z prób | 224 |
| Pomiar rozproszenia z wykorzystaniem błędów standardowych | 224 |
| Pojęcie wyników standaryzowanych | 225 |
| Obliczanie i interpretacja statystyki testowej | 225 |
| Ocena dowodów i podejmowanie decyzji — wartości p | 226 |
| Łączenie statystyk testowych i wartości p | 226 |
| Definiowanie wartości p | 227 |
| Obliczanie wartości p | 227 |
| Wyciąganie wniosków | 228 |
| Określanie granic dla odrzucenia H_0 | 229 |
| Testowanie zylaków | 230 |
| Ocena prawdopodobieństwa złej decyzji | 230 |
| Fałszywe alarmy — błędy pierwszego rodzaju | 231 |
| Brak wykrycia — błędy drugiego rodzaju | 231 |
| Rozdział 15: Popularne testy statystyczne — wzory i przykłady | 233 |
| Testowanie jednej średniej z populacji | 233 |
| Małe próby i nieznanne odchylenia standardowe — test t-Studenta | 235 |
| Stosowanie testu t-Studenta | 236 |
| Związek pomiędzy t i Z | 237 |
| Postępowanie z ujemnymi wartościami t | 237 |
| Badanie opcji „nie równa się” | 238 |
| Testowanie pojedynczego odsetka z populacji | 238 |
| Porównywanie dwóch (niezależnych) średnich z populacji | 240 |
| Testowanie średniej z różnicy (test t-Studenta dla zmiennych zależnych) | 242 |
| Porównywanie dwóch odsetków z populacji | 245 |

Część V: Badania statystyczne i pogoń za znaczącą relacją 249

Rozdział 16: Sondáže, sondáže i jeszcze raz sondáže251

| | |
|--|-----|
| Znaczenie sondáže | 252 |
| Docieranie do źródła | 252 |
| Gorące tematy sondáže | 254 |
| Wpływ sondáže na ludzi | 254 |
| Za kulisami — tajniki sondáže | 256 |
| Planowanie i projektowanie sondáže | 256 |
| Wybór próby | 260 |
| Prowadzenie sondáže | 262 |
| Interpretacja wyników i wyszukiwanie problemów | 264 |

Rozdział 17: Eksperymenty — przełomy w medycynie czy mylące wyniki?267

| | |
|---|-----|
| Sprowadzanie badań do podstaw | 268 |
| Podstawowe terminy badawczego żargonu | 268 |
| Obserwacja badań obserwacyjnych | 269 |
| Badanie eksperymentów | 269 |
| Projektowanie dobrego eksperymentu | 270 |
| Projektowanie eksperymentu, aby możliwe było dokonywanie porównań | 270 |
| Wybór liczebności próby | 273 |
| Wybór obiektów | 274 |
| Przypisywanie losowe | 274 |
| Kontrola zmiennych zakłócających | 275 |
| Poszanowanie kwestii etycznych | 277 |
| Gromadzenie dobrych danych | 278 |
| Prawidłowa analiza danych | 280 |
| Wyciąganie właściwych wniosków | 280 |
| Podejmowanie świadomych decyzji | 282 |

Rozdział 18: Szukanie powiązań — korelacja i regresja285

| | |
|---|-----|
| Przedstawianie zależności za pomocą wykresu rozrzutu | 286 |
| Tworzenie wykresu rozrzutu | 287 |
| Interpretacja wykresu rozrzutu | 287 |
| Ustalanie istnienia zależności liniowych za pomocą korelacji | 288 |
| Obliczanie korelacji | 289 |
| Interpretacja korelacji | 290 |
| Badanie właściwości korelacji | 292 |
| Pojęcie regresji liniowej | 292 |
| Ustalanie, która zmienna to X, a która Y | 292 |
| Sprawdzanie warunków | 293 |
| Poszukiwanie linii regresji | 293 |
| Interpretacja linii regresji | 295 |
| Zestawienie wszystkiego razem — linia regresji dla świerszczy | 296 |
| Dokonywanie właściwych prognoz | 297 |
| Wyjaśnienie zależności — korelacja kontra przyczyna i skutek | 298 |

Rozdział 19: Tabele krzyżowe i niezależność 301

| | |
|--|-----|
| Tworzenie tabeli krzyżowej | 302 |
| Budowa komórek | 303 |
| Ustalanie sum | 303 |
| Interpretacja tabel krzyżowych | 304 |
| Wydodrębnianie zmiennych za pomocą rozkładów brzegowych | 305 |
| Badanie wszystkich grup — rozkład łączny | 308 |
| Porównywanie grup za pomocą rozkładów warunkowych | 310 |
| Sprawdzanie niezależności i opis zależności | 313 |
| Sprawdzanie istnienia niezależności | 313 |
| Opis relacji zależnej | 316 |
| Ostrożna interpretacja wyników | 317 |
| Sprawdzanie istnienia uzasadnionego związku przyczyny i skutku | 317 |
| Przełożenie z próby na populację | 318 |
| Tworzenie rozważnych prognoz | 319 |
| Opieranie się pokusie wyciągania pochopnych wniosków | 320 |

Część VI: Dekalogi 321**Rozdział 20: Dziesięć porad dla statystycznych detektywów 323**

| | |
|---|-----|
| Wskazywanie mylących wykresów | 323 |
| Wykresy kołowe | 325 |
| Wykresy słupkowe | 325 |
| Wykresy czasowe | 326 |
| Histogramy | 326 |
| Wykrywanie tendencyjnych danych | 327 |
| Poszukiwanie błędu statystycznego | 328 |
| Identyfikowanie prób nielosowych | 328 |
| Ustalanie brakujących liczebności prób | 329 |
| Wykrywanie błędnie interpretowanych korelacji | 330 |
| Ujawnianie zmiennych zakłócających | 331 |
| Sprawdzanie liczb | 332 |
| Selektywne raportowanie | 332 |
| Kwestia anegdoty | 333 |

Rozdział 21: Dziesięć niezawodnych porad egzaminacyjnych 335

| | |
|--|-----|
| Dowiedz się, czego nie wiesz, i zrób coś z tym | 336 |
| Unikanie pułapek „tak-tak” | 337 |
| Pułapka „tak-tak” nr 1 | 337 |
| Pułapka „tak-tak” nr 2 | 338 |
| Zaprzyjżnij się z wzorami | 339 |
| Zrób listę „jeżeli-to-jak” | 341 |
| Ustal, o co chodzi w poleceniu | 342 |
| Oznacz dane | 343 |

| | |
|--|------------|
| Zrób rysunek | 345 |
| Stwórz powiązanie i rozwiąż zadanie | 346 |
| Wykonaj obliczenia dwa razy | 347 |
| Analizuj swoje odpowiedzi | 347 |
| Dodatek A: Tablice statystyczne | 349 |
| Tablica Z | 349 |
| Tablica t-Studenta | 352 |
| Tablica dwumianowa | 354 |
| Skorowidz | 359 |

Rozdział 1

Statystyka w pigułce

.....

W tym rozdziale:

- ▶ Ustalamy, o co chodzi w procesie statystycznym.
 - ▶ Odnosimy sukcesy statystyczne w codziennym życiu, w pracy i w szkole.
-

Współczesny świat tonie w danych do takiego stopnia, że każdy (nawet ja!) może się czuć przytłoczony. Nie winię Cię, jeśli do tej pory z niedowierzaniem podchodziłeś do statystyk prezentowanych w mediach — mnie też czasem się to zdarza. Mam jednak dobrą wiadomość: chociaż czyha na Ciebie bardzo wiele mylących i błędnych informacji, to powstaje także wiele świetnych rzeczy; na przykład, wiele różnorodnych badań i technik związanych z danymi pomaga poprawiać jakość naszego życia. Twoim zadaniem jest umiejętnie oddzielać ziarno od plew i być pewnym swoich umiejętności w tym zakresie. Dzięki dogłębnemu zrozumieniu statystyki i procedur statystycznych zaczniesz pewnie radzić sobie z liczbami w życiu codziennym, w pracy czy w szkole. O tym właśnie opowiada ta książka.

W tym rozdziale przyglądam się roli, jaką statystyka odgrywa we współczesnym społeczeństwie, opartym na danych. Wyjaśniam, co należy robić, aby nie tylko w nim przetrwać, ale móc się rozwijać. Abyś mógł zyskać szersze spojrzenie na statystykę, wspólnie zastosujemy metodę naukową — projektowanie efektywnych obserwacji, gromadzenie użytecznych danych, organizowanie i analizowanie informacji, interpretację wyników oraz wyciąganie odpowiednich wniosków. (A Ty myślałeś, że statystyka to tylko obliczenia!).

Powodzenie w statystycznym świecie

Trudno jest ujarzmić powódź statystyk, które w mniejszym lub większym stopniu wpływają na nasze codzienne życie. Wszystko zaczyna się w chwili, gdy budzisz się rano, sprawdzasz wiadomości i słuchasz pogodyni przedstawiającej prognozę opartą na analizach statystycznych danych historycznych i aktualnych warunków pogodowych. Podczas śniadania studiujesz informacje o wartościach odżywczych na pudełku płatków zbożowych. W pracy wykorzystujesz liczby z wykresów i tabel, wprowadzasz dane do arkusza kalkulacyjnego, przeprowadzasz diagnostykę, wykonujesz pomiary, prowadzisz obliczenia, szacujesz wydatki, podejmujesz decyzje, wykorzystując statystyczne punkty odniesienia, oraz zamawiasz towary na podstawie danych historycznych dotyczących poziomu sprzedaży.

Na obiad idziesz do restauracji, która zajęła pierwsze miejsce w ankiecie przeprowadzonej wśród 500 osób. Spożywasz posiłek, którego cenę ustalono na podstawie danych marketingowych. Idziesz do lekarza, mierzą Ci ciśnienie, temperaturę, wagą i robią badanie krwi; po zebraniu wszystkich informacji otrzymujesz swoje wyniki i informację, jak wypadasz na podstawie norm statystycznych.

Jedziesz do domu samochodem, który jest obsługiwany przez komputer prowadzący diagnostykę statystyczną. Po powrocie do domu włączasz wiadomości i poznajesz najnowsze statystyki dotyczące przestępczości, sprawdzasz, co się działo na giełdzie, i dowiadujesz się, ile osób odwiedziło w zeszłym tygodniu zoo.

Wieczorem myjesz zęby pastą, która, co zostało statystycznie dowiedzione, redukuje ubytki, czytasz kilka stron książki (uznanej za bestseller na podstawie statystycznych szacunków sprzedaży) i idziesz spać — a następnego ranka zaczynasz wszystko od nowa. Czy jednak możesz mieć pewność, że wszystkie statystyki, które każdego dnia napotykasz i na których polegasz, są prawidłowe? W rozdziale 2. omawiam bardziej szczegółowo kilka przykładów tego, w jaki sposób statystyka uczestniczy w naszym życiu i pracy, jaki wpływ na nas wywiera i jak należy być bardziej świadomym jej obecności.



Istnieją dane statystyczne, które są niejasne, niewłaściwe albo po prostu błędne. Musisz bardziej świadomie postrzegać statystyki, które napotykasz każdego dnia, i tak wytrenować swój umysł, abyś potrafił się zatrzymać, powiedzieć „momencik!”, zweryfikować informacje, zadać pytania i podnieść czerwoną flagę, jeżeli coś będzie nie tak. Z rozdziału 3. dowiesz się, w jaki sposób można zostać wyprowadzonym w pole przez nieprawidłowe statystyki, i rozwiniesz w sobie umiejętności krytycznego myślenia i identyfikowania problemów, zanim bez refleksji uwierzysz w wyniki.

Statystyka, jak każda inna dziedzina, posiada swój charakterystyczny żargon, którego szereg najczęściej stosowanych terminów przedstawiam i wyjaśniam w rozdziale 4. Znajomość fachowego słownictwa zwiększa zdolność rozumienia kwestii statystycznych i komunikowania się z innymi na wyższym poziomie i bez poczucia zastraszania. To, że posługujesz się precyzyjną terminologią, opisując, co jest nie tak z danym wynikiem statystycznym (i dlaczego), podnosi Twoją wiarygodność. A Twoje prezentacje z wykorzystaniem tablic statystycznych, grafów, wykresów i analiz także będą zawierać więcej informacji i będą skuteczniejsze. (Kurczę, jeśli nie ma nawet żadnego innego powodu, to ten żargon będzie Ci potrzebny, bo ja się nim posługuję w tej książce; ale nie przejmuj się, wszystko wyjaśniam).

W kolejnych podrozdziałach przekonasz się, w jaki sposób statystyka bierze udział we wszystkich etapach metody naukowej.

Projektowanie odpowiednich badań

Pytania zadają wszyscy: firmy farmaceutyczne i biologowie; analitycy marketingowi i rząd. I w ostatecznym rozrachunku wszyscy wykorzystują statystykę, aby uzyskać odpowiedzi na swoje pytania. Zwłaszcza wiele badań medycznych i psychologicznych prowadzi się, bo ktoś chce poznać odpowiedź na jakieś pytanie, na przykład:

- ✓ Czy za sprawą tej szczepionki zapobieganie grypie będzie skuteczne?
- ✓ Jakie jest zdanie obywateli o stanie gospodarki?
- ✓ Czy wzrost poziomu wykorzystywania sieci społecznościowych powoduje depresję u nastolatków?

Pierwszym krokiem po sformułowaniu pytania badawczego jest zaprojektowanie efektywnej obserwacji w celu zebrania danych, które pomogą odpowiedzieć na postawione pytanie. Oznacza to ustalenie, jakiego procesu należy użyć, aby uzyskać potrzebne dane. W tym podrozdziale prezentuję przegląd dwóch głównych typów badań — sondaży i eksperymentów — i sprawdzam, dlaczego tak ważne jest zweryfikowanie sposobu, w jaki badanie zostało zaprojektowane, zanim damy wiarę jego wynikom.

Sondaże

Badanie obserwacyjne to badanie, w którym dane od konkretnych osób są gromadzone bez oddziaływania na te osoby. Najczęstszym badaniem obserwacyjnym jest sondaż.

Sondaże to kwestionariusze przekazywane osobom, które zostały wybrane z interesującą badacza populacji. Sondaże mogą przybierać różne formy: sondaży w formie papierowej przesyłanych za pośrednictwem poczty, kwestionariuszy na stronach internetowych, głosowań audiotele prowadzonych przez stacje telewizyjne, ankiet telefonicznych itd.



Prawidłowo przeprowadzone sondaże mogą być bardzo użytecznym narzędziem do pozyskiwania informacji. Jeżeli jednak prowadzone są niewłaściwie, mogą doprowadzić do zgromadzenia informacji nieprawdziwych. Problemem mogą tu być niewłaściwie sformułowane, wprowadzające w błąd pytania, brak odpowiedzi od osób wybranych do udziału w sondażu albo nieuwzględnienie reprezentatywnej grupy należącej do danej populacji. Te potencjalne problemy oznaczają, że zanim sondaż zostanie przeprowadzony, należy go dobrze przemyśleć.



Wielu badaczy poświęca sporo czasu i pieniędzy, aby prowadzone przez nich sondaże były użyteczne, a Ty (na podstawie kryteriów, które omawiam w rozdziale 16.) będziesz wiedział, że można im zaufać. Miewając jednak do czynienia z wieloma różnymi rodzajami sondaży, obecnymi w mediach, w pracy czy na różnych zajęciach w szkole, sam musisz być w stanie szybko sprawdzać i weryfikować sposoby projektowania i prowadzenia sondaży, a także umieć w dobrze przemyślany sposób wskazywać konkretne problemy. Narzędzia potrzebne do oceny ankiet znajdziesz w rozdziale 16.

Eksperymenty

Eksperyment zakłada poddanie jego uczestników jednemu lub większej liczbie działań w taki sposób, aby można było dokonać jednoznacznych porównań.

Po przeprowadzeniu działań rejestrowane są reakcje. Aby na przykład zbadać wpływ określonej dawki leku na ciśnienie krwi, jednej grupie uczestników możemy podać 10 mg leku, a drugiej 20 mg. Zazwyczaj istnieje także grupa kontrolna, której członkowie otrzymują placebo (np. pigułki z cukru) albo leczeni są z wykorzystaniem leków standardowych, a nie eksperymentalnych (jak w przypadku podawania już istniejących leków pacjentom z AIDS).



Skuteczne i wiarygodne eksperymenty projektowane są tak, aby zminimalizować tendencyjność, zebrać wiele użytecznych danych i dokonać odpowiednich porównań (grupy doświadczalnej z grupą kontrolną). Potencjalne problemy związane z eksperymentami to między innymi sytuacje, w których badacze i/lub badani wiedzą, jakiego rodzaju kuracji zostali poddani, czynniki nieuwzględnione w badaniu, które mają wpływ na wynik (takie jak waga uczestnika podczas badania poziomu dawek leku), lub brak grupy kontrolnej (brak punktu odniesienia, z którym można porównać wyniki).

Gdy jednak eksperyment zostanie zaprojektowany poprawnie, to może pomóc badaczowi w ustaleniu związku przyczynowo-skutkowego, jeśli różnica w reakcji pomiędzy grupą eksperymentalną i grupą kontrolną jest statystycznie istotna (czyli jest mało prawdopodobne, że zaistniała wyłącznie przez przypadek).



Eksperymenty są stosowane w celu wspomaganie tworzenia i testowania leków, ustalania dobrych praktyk w zakresie wytwarzania i przygotowywania żywności oraz badania, czy jakaś nowa kuracja może wyleczyć chorobę albo przynajmniej ograniczyć jej skutki. Dzięki przeprowadzaniu dobrze zaprojektowanych eksperymentów jakość naszego życia z pewnością staje się coraz wyższa. Nie wszystkie eksperymenty bywają jednak dobrze zaprojektowane, a zdolność do określenia, które wyniki są wiarygodne, a które niewiarygodne (gra słów całkowicie zamierzona), ma kluczowe znaczenie, zwłaszcza gdy wyniki są dla nas bardzo istotne. Wszystkie niezbędne informacje o eksperymentach i sposobach ich oceny znajdziesz w rozdziale 17.

Gromadzenie wartościowych danych

Po zaprojektowaniu badania — niezależnie od tego, czy jest to sondaż, czy eksperyment — należy wybrać uczestników i przeprowadzić obserwację statystyczną, aby zgromadzić dane. Ten etap procesu ma kluczowe znaczenie dla pozyskania wiarygodnych danych, a w tym podrozdziale zajmiemy się jego najistotniejszymi szczegółami.

Dobór właściwej próby



Statystycy mają takie powiedzenie: „Śmieci na wejściu — śmieci na wyjściu”. Jeśli wybierzesz swoje *obiekty* (osoby, które będą uczestniczyć w badaniu) w sposób *tendencyjny* — czyli faworyzując pewne osoby lub grupy osób — wtedy wyniki będą tendencyjne. To proste jak drut.

Załóżmy, że Bolek chce poznać opinie mieszkańców miasta na temat planowanej budowy kasyna. Idzie do centrum handlowego z kartką i prosi przechodzące osoby o wyrażanie opinii. Co tu jest nie tak? No cóż, Bolek pozyska wyłącznie opinie:
a) osób, które robią zakupy w tym centrum handlowym; b) w tym konkretnym dniu;
c) w tej konkretnej chwili; d) tylko tych, które zechcą odpowiedzieć.

Te okoliczności są zbyt restrykcyjne — napotykać ludzie nie reprezentują przekroju społeczności miasta. Podobnie, Bolek mógłby zorganizować ankietę internetową i poprosić o głosy. Danych dostarczą mu jednak tylko osoby, które będą wiedziały o stronie z ankietą i zechcą odpowiedzieć, a taki trud zadają sobie zwykle wyłącznie

posiadacze skrajnych opinii. Ostatecznie Bolek będzie dysponował tylko pakietem tendencyjnych danych od osób całkowicie niereprezentatywnych z punktu widzenia społeczności miasta.



Aby zminimalizować tendencyjność w sondażu, kluczowe znaczenie ma *losowość*. Musisz wybrać próbę jednostek losowo — czyli w procesie, który można określić jako „wyciąganie nazwisk z kapelusza”. Badacze wykorzystują różne metody wybierania uczestników losowo, a jak to robią, dowiesz się z rozdziału 16.

Zauważ, że podczas projektowania eksperymentu zestawianie losowej próby i zapraszanie do udziału często bywa nieetyczne, bo eksperyment oznacza określone oddziaływanie na obiekty. Zamiast tego należy ogłosić nabór ochotników. Następnie powinniśmy się upewnić, że ochotnicy wybrani z grupy reprezentują populację będącą przedmiotem naszego zainteresowania oraz że dane dotyczące tych osób zostały zebrane prawidłowo, więc można będzie dokonać projekcji wyników na większą grupę. Jak to się robi, przekonasz się w rozdziale 17.

Po przeczytaniu rozdziałów 16. i 17. będziesz wiedział, jak należy analizować metody doboru prób. Nauczysz się także opracowywać plan, którym sam będziesz mógł się posłużyć do przeprowadzenia wyboru próby. Wtedy dowiesz się także, kiedy można stwierdzić, że mamy „śmieci na wejściu — śmieci na wyjściu”.

Unikanie tendencyjności danych

Tendencyjność to systematyczne faworyzowanie pewnych osób lub reakcji. Tendencyjność to zbrodnia statystyków, którzy robią wszystko, co mogą, aby ją zminimalizować. Mam podać przykład tendencyjności? Załóżmy, że prowadzisz telefoniczną ankietę dotyczącą zadowolenia z pracy; jeśli będziesz dzwonił na numery domowe w ciągu dnia, między godziną 8:00 a 16:00, to pominiesz wszystkie osoby pracujące właśnie w dzień. A może osoby pracujące w dzień są bardziej zadowolone niż pracujące w nocy?

Na tendencyjność trzeba uważać podczas gromadzenia danych do sondaży. Niektóre sondaże bywają na przykład zbyt długie — co będzie, jeśli ktoś przestanie odpowiadać na pytania w połowie? A co się stanie, jeśli ktoś zechce podać nieprawdziwe informacje i odpowie, że zarabia rocznie 100 000 zł, a nie 45 000? Co zrobisz, jeśli otrzymasz odpowiedzi, które nie znajdują się na Twojej liście możliwych odpowiedzi? Podczas gromadzenia danych do sondażu mogą wystąpić liczne problemy, a Ty musisz być w stanie je zidentyfikować.



W kwestii tendencyjności i gromadzenia danych eksperymenty mogą czasem stanowić nawet większe wyzwanie. Załóżmy, że chcemy przeprowadzić test ciśnienia krwi; co będzie, jeżeli instrument, którego używasz, zepsuje się w trakcie eksperymentu? Co zrobisz, jeżeli ktoś zrezygnuje w połowie eksperymentu? A jeżeli podczas eksperymentu stanie się coś, co rozproszy obiekt lub badacz? Albo nie będzie można znaleźć żyły, a badanie krwi powinno zostać przeprowadzone dokładnie godzinę po podaniu dawki leku? Te problemy to tylko kilka przykładowych kwestii, które mogą się pojawić podczas gromadzenia danych do eksperymentów i które trzeba umieć dostrzegać.

Po przeczytaniu rozdziału 16. (o próbach i sondażach) i rozdziału 17. (o eksperymentach) będziesz potrafił dobierać próby i gromadzić dane w wolny od tendencyjności sposób, poświęcając uwagę drobiazgom, które mogą mieć faktyczny wpływ na wyniki. Nabędziesz także umiejętność oceny wiarygodności wyników statystycznych i zdobędziesz posłuch, ponieważ będziesz wiedział, o czym mówisz.

Tworzenie skutecznych podsumowań

Po zgromadzeniu prawidłowych danych kolejnym krokiem jest podsumowanie ich w celu uzyskania możliwości spojrzenia z szerszej perspektywy. Statystycy opisują dane na dwa podstawowe sposoby: liczbowo (tzw. *statystyki opisowe*) oraz za pomocą rysunków (czyli wykresów i grafów).

Statystyki opisowe

Statystyki opisowe to liczby opisujące zbiór danych pod względem jego istotnych cech:

- ✓ Jeżeli dane mają charakter **kategoryczny** (gdy jednostki są umieszczane w grupach, takich jak płeć czy przynależność polityczna), ich podsumowaniem jest zazwyczaj liczba osób w każdej z grup (zwana **liczebnością**) lub odsetek osób w każdej z grup (zwany **częstością**).
- ✓ **Dane liczbowe** oznaczają pomiary lub zliczenia, w ramach których konkretne liczby coś oznaczają (na przykład wzrost i wagę). Z danych liczbowych można pozyskać więcej informacji niż tylko liczba lub odsetek w każdej z grup. Niektóre z tych informacji to:
 - Miary średnie (innymi słowy, gdzie jest „środek” danych?).
 - Miary rozproszenia (na ile różnorodne lub na ile skoncentrowane są dane wokół środka?).
 - Jeżeli jest to potrzebne, liczby, które mierzą wartość relacji pomiędzy dwiema zmiennymi (takimi jak wzrost i waga).

Pewne statystyki opisowe są w niektórych sytuacjach bardziej odpowiednie niż inne; na przykład średnia nie zawsze bywa najlepszą miarą środka zbioru danych; często lepszym wyborem jest mediana. Także odchylenie standardowe nie jest jedyną istniejącą miarą zmienności; rozstęp ćwiartkowy ma też doskonałe właściwości. Musisz być w stanie rozpoznawać, interpretować i oceniać rodzaje statystyk opisowych, z którymi codziennie się stykasz, i wiedzieć, które są w określonych sytuacjach najlepsze.

Interpretacje, porównania i oceny najczęściej spotykanych statystyk opisowych znajdziesz w rozdziale 5. Powszechnie stosowane statystyki opisowe obejmują liczebności i częstości (zliczenia i odsetki) dla danych kategorycznych oraz średnie, mediany, odchylenie standardowe, percentyle i ich kombinacje dla danych liczbowych.



Wykresy i grafy

Dane podsumowuje się w sposób wizualny za pomocą wykresów i/lub grafów. Są to prezentacje zorganizowane w ten sposób, aby w jednej chwili umożliwić nam szersze spojrzenie na dane i/lub przybliżyć konkretny wynik, który znaleziono. W dzisiejszym świecie szybkiej informacji i miniplików dźwiękowych grafy i wykresy występują powszechnie. Większość z nich prezentuje to, czego dotyczy, jednoznacznie, skutecznie i rzetelnie; może się jednak zdarzać, że pozostawiają one nieco zbyt wiele miejsca na *licentia poetica* i w konsekwencji narażają nas na błędne interpretacje zawartych w nich informacji.



W rozdziałach 6. i 7. omawiam główne typy grafów i wykresów wykorzystywanych do podsumowywania danych, zarówno kategorycznych, jak i liczbowych (patrz poprzedni podrozdział na temat tych rodzajów danych). Dowiesz się, jak je tworzyć, jakie są ich cele oraz jak interpretować ich wyniki. Wskazuję także wiele możliwych sposobów tworzenia grafów i wykresów tak, aby wprowadzały one odbiorcę w błąd, i pomagam szybko dostrzegać tego rodzaju problemy. Chodzi o stwierdzenie: „Chwileczkę! Tu chyba jest błąd!”, gdy wiemy, skąd się on wziął. Oto najistotniejsze kwestie:

- ✓ Jednymi z podstawowych wykresów stosowanych dla danych kategorycznych są wykresy kołowe oraz wykresy słupkowe, które rozkładają takie zmienne jak płeć lub aplikacje wykorzystywane przez nastolatków w telefonach komórkowych. Wykres słupkowy może na przykład prezentować opinie na temat określonego zagadnienia z wykorzystaniem pięciu słupków oznaczonych w kolejności od „zdecydowanie się nie zgadzam” po „zdecydowanie się zgadzam”. W rozdziale 6. znajdziesz wszystkie istotne informacje na temat tworzenia, interpretowania i, co najważniejsze, oceny wykresów i grafów z punktu widzenia ich wiarygodności. Będziesz zaskoczony, widząc, ile można zrobić błędów w prostym wykresie słupkowym.
- ✓ W odniesieniu do danych liczbowych, takich jak wzrost, waga, czas lub ilość, konieczne jest stosowanie innego rodzaju wykresów. Grafy zwane histogramami i wykresami pudełkowymi służą do podsumowywania danych liczbowych i mogą być niezwykle pouczające, doskonale zestawiając wszystkie informacje dotyczące zbioru danych. Oczywiście, one także mogą być mylące, przez przypadek, a nawet celowo. (Więcej na ten temat w rozdziale 7.).



Wykresy i grafy widzimy codziennie — wystarczy, że otworzysz gazetę, a najprawdopodobniej znajdziesz co najmniej kilka wykresów, nawet bez szczególnie długich poszukiwań. Niezbędne jest tutaj posiadanie statystycznego „szkła powiększającego”, które pomaga zinterpretować informacje tak, abyś mógł dostrzec wprowadzające w błąd wykresy, zanim wyciągniesz błędne wnioski i być może zaczniesz działać na ich podstawie. Wszystkie niezbędne do tego narzędzia znajdziesz w rozdziale 6. (dla danych kategorycznych) i w rozdziale 7. (dla danych liczbowych).

Ustalanie rozkładów

Zmienna to cecha, którą można obliczyć, zmierzyć lub przypisać do określonej kategorii. Przykładami mogą być płeć, wiek, wzrost, waga czy liczba posiadanych zwierząt. **Rozkład** to zestawienie możliwych wartości zmiennej (lub przedziałów wartości) i tego, jak często (lub z jaką gęstością) one występują. Na przykład, w Stanach Zjednoczonych rozkład płci przy urodzeniu szacuje się na 52,4% mężczyzn i 47,6% kobiet.

Dla różnych zmiennych istnieją różne rodzaje rozkładów. Trzy rozkłady przedstawione poniżej są najczęściej spotykane w ramach kursu wprowadzającego do zagadnień statystyki. Mają także wiele zastosowań w świecie rzeczywistym:

- ✓ Jeżeli zmienna jest zliczeniem liczby sukcesów w pewnej liczbie prób (jak liczba osób, które wyzdrowiały, przyjmując określony lek), to ma ona rozkład **dwumianowy**.
- ✓ Jeżeli zmienna przyjmuje wartości występujące zgodnie z „krzywą w kształcie dzwonu”, jak wyniki egzaminów maturalnych, to zmienna ta ma rozkład **normalny**.
- ✓ Jeżeli zmienna opiera się na średnich z prób i dysponujemy ograniczonymi danymi, jak w teście ograniczonym do dziesięciu obiektów, którego celem jest sprawdzenie skuteczności określonej diety, odpowiedni może być rozkład **t-Studenta**.

W przypadku rozkładów powinieneś wiedzieć, jak ustalić rodzaj rozkładu przyjmowanego przez konkretną zmienną, jak znaleźć jego prawdopodobieństwa oraz jak określić średnią i odchylenie standardowe wyników. Aby Ci to ułatwić, służę trzema rozdziałami, po jednym dla każdego rozkładu: rozdział 8. traktuje o rozkładzie dwumianowym, rozdział 9. o normalnym, a rozdział 10. poświęcam rozkładowi t-Studenta.

Osoby uczestniczące w kursach wprowadzających do statystyki (lub w ogóle dowolnych kursach statystyki) wiedzą, że jednym z najtrudniejszych do zrozumienia zagadnień są rozkłady z prób i centralne twierdzenie graniczne (te dwie kwestie idą w parze). W rozdziale 11. poznasz te kwestie krok po kroku, co pozwoli Ci zrozumieć, czym jest rozkład z próby, do czego służy i w jaki sposób tworzy podstawę takich analiz danych jak testowanie hipotez i przedziały ufności (więcej informacji na temat analizowania danych znajdziesz w kolejnym podrozdziale). Gdy zrozumiesz centralne twierdzenie graniczne, będziesz w stanie rozwiązywać skomplikowane problemy znacznie łatwiej, a wszystkie kluczowe informacje na ten temat przedstawiam w rozdziale 11.

Prowadzenie właściwych analiz

Po zgromadzeniu i opisaniu danych za pomocą liczb i obrazów zaczyna się zabawa: znajdowanie drogi w ciemnym pomieszczeniu o nazwie *analiza statystyczna*. Jeżeli badanie zostało właściwie zaprojektowane, to można odpowiedzieć na postawione na początku pytania, stosując odpowiednią analizę — kluczowy jest tutaj wyraz *odpowiednia*.





Istnieje wiele rodzajów analiz, a kluczowe znaczenie mają wybór odpowiedniej analizy dla konkretnej sytuacji, prawidłowa interpretacja jej wyników i znajomość ograniczeń. Podobnie istotna jest umiejętność oceny wyboru analiz przez innych oraz wniosków, jakie na ich podstawie wyciągnęli.

W tej książce znajdziesz wszelkie informacje i narzędzia niezbędne do analizy danych przy użyciu najpowszechniejszych metod statystycznych: przedziałów ufności, testów hipotez, korelacji i regresji oraz analizy tabel krzyżowych. W tym podrozdziale prezentuję podstawowy przegląd tych metod.

Błąd statystyczny i przedziały ufności

Często obserwujemy statystyki, które próbują szacować wartości odnoszące się do całej populacji; prawdę mówiąc, widujemy je niemal codziennie w postaci wyników sondaży. Media informują nas, jaka jest średnia cena benzyny, co obywatele sądzą o działaniach prezydenta lub ile godzin tygodniowo spędzamy w internecie. Nikt jednak nie może podać określonego konkretną liczbą wyniku i stwierdzić, że jest to dokładne oszacowanie dla całej populacji, chyba że zbierze dane na temat każdego członka społeczeństwa. Mógłbyś na przykład usłyszeć, że 60% obywateli popiera stanowisko prezydenta dotyczące opieki zdrowotnej, ale wiesz, że Ciebie nie pytano, więc jak to możliwe, że zapytano wszystkich? A ponieważ nie zapytano wszystkich, wiesz, że odpowiedź określona jedną liczbą nie będzie prawidłowa.

Fakty są takie, że dane gromadzi się na podstawie próby z populacji (na przykład Instytut Gallupa stosuje próby składające się z 2500 losowo wybieranych osób), wyniki z tej próby są analizowane i na podstawie wyników dla próby wyciąga się wnioski odnoszące się do całej populacji (na przykład do wszystkich Amerykanów).



Najważniejsze jest to, że wyniki z prób różnią się w zależności od próby i wartość tej różnicy powinna być ogłaszana (często jednak się tego nie robi). Statystyka wykorzystywana do pomiaru i raportowania poziomu precyzji w wynikach czyichś prób nazywana jest **błędem statystycznym**. W tym kontekście słowo *błąd* nie oznacza, że ktoś popełnił pomyłkę; chodzi o to, że skoro nie próbkowaliśmy całej populacji, to pojawi się rozdzwiek między naszymi wynikami a rzeczywistą wartością, którą próbujemy oszacować dla populacji.

Ktoś może na przykład twierdzić, że 60% z 1200 ankietowanych osób popiera podejście prezydenta do opieki zdrowotnej, i podaje wyniki z błędem statystycznym plus minus 2%. Wynik końcowy, za pomocą którego przedstawiamy nasze ustalenia jako prawdopodobne wartości w przedziale pomiędzy 58% a 62%, nazywany jest **przedziałem ufności**.



Każdy z nas miewa do czynienia z wynikami zawierającymi błąd statystyczny i przedziały ufności, a przy współczesnym natłoku danych wiele osób wykorzystuje je także w pracy. Musisz wiedzieć, jakie czynniki wpływają na błąd statystyczny (np. liczebność próby), jakie cechy posiada prawidłowo określony przedział ufności i jak je rozpoznać. Powinieneś także umieć znajdować przedziały ufności, gdy będzie to konieczne.

Z rozdziału 12. dowiesz się wszystkiego, co powinieneś wiedzieć o błędzie statystycznym. Poznasz wszystkie jego składniki, dowiesz się, co mierzy, a czego nie i jak go obliczać w różnych sytuacjach. W rozdziale 13. poznasz krok po kroku wzory, obliczenia i interpretacje przedziałów ufności dla średniej z populacji, odsetka z populacji oraz różnicy między dwiema średnimi i odsetkami.

Testowanie statystyczne

Jeden z głównych obszarów badań naukowych nosi nazwę testowania statystycznego.

Test statystyczny jest techniką wykorzystywania danych, aby przyjąć lub odrzucić twierdzenie dotyczące populacji. Pewien polityk mógłby na przykład twierdzić, że 80% społeczeństwa się z nim zgadza — ale czy to prawda? Jakaś firma mogłaby twierdzić, że dostarcza pizzę w czasie najwyżej 30 minut, ale czy tak jest rzeczywiście? Naukowcy prowadzący badania medyczne stale wykorzystują testy statystyczne, aby sprawdzać, czy dany lek jest skuteczny, porównywać nowe leki z istniejącymi pod względem skutków ubocznych albo badać, jaka dieta jest najbardziej efektywna dla określonych grup ludzi.



Najczęściej testowanymi cechami populacji są:

- ✓ Średnia z populacji (Czy przeciętny czas dostawy wynoszący 30 minut naprawdę taki jest?).
- ✓ Odsetek z populacji (Czy to prawda, że 80% wyborców popiera tego kandydata, czy też jest ich mniej?).
- ✓ Różnica między dwiema średnimi lub odsetkami z populacji (Czy to prawda, że przeciętny spadek masy ciała w ramach nowej diety jest o 10 kilogramów większy niż w przypadku najpopularniejszego programu odchudzania? Albo czy to prawda, że nowy lek obniża ciśnienie krwi o 10% skuteczniej niż obecnie stosowany?).



Testy statystyczne stosuje się w wielu dziedzinach, które mają wpływ na nasze codzienne życie, takich jak badania medyczne, reklama czy dane wyborcze, i praktycznie wszędzie, gdzie dokonuje się porównań na podstawie średnich lub odsetków. Jeżeli zaś chodzi o konkretne branże, testy statystyczne są intensywnie wykorzystywane w takich branżach jak marketing, gdy chcemy ustalić, czy dana reklama jest skuteczna lub czy pewna grupa osób nabywa obecnie mniej, czy więcej naszych produktów w porównaniu z zeszłym rokiem.

Często poznajemy wyłącznie wnioski z testów statystycznych (na przykład: „Ten lek jest znacznie bardziej skuteczny i ma mniej skutków ubocznych niż lek, który stosujemy obecnie”); nie mamy jednak dostępu do metod, które doprowadziły do wyciągnięcia tych wniosków. W rozdziale 14. analizuję podstawy i szczegóły testów statystycznych, abyś mógł przeprowadzać je i weryfikować z przekonaniem. W rozdziale 15. przechodzę do sedna sprawy i prezentuję szczegółowe instrukcje dotyczące konfigurowania i przeprowadzania testów statystycznych w wielu konkretnych sytuacjach (jedna średnia z populacji, jeden odsetek z populacji, różnica dwóch średnich z populacji itd.).

Po przeczytaniu rozdziałów 14. i 15. poczujesz się znacznie pewniej, gdy będziesz musiał się dowiedzieć, do której grupy klientów należy skierować działania marketingowe związane z określonym produktem, jakiej marki opony są najtrwalsze albo czy określona dieta jest skuteczna. Będziesz mógł także odpowiedzieć na poważniejsze pytania, na przykład jaki zabieg chirurgiczny należy wybrać.

Korelacja, regresja i tabele krzyżowe

Jednym z najczęstszych celów badań jest znajdowanie związków między zmiennymi, na przykład:

- ✓ Jakie zachowania związane ze stylem życia zwiększają lub zmniejszają ryzyko zachorowania na raka?
- ✓ Jakie działania niepożądane wywołuje nowy lek?
- ✓ Czy nowy ziołowy suplement diety obniża poziom cholesterolu?
- ✓ Czy spędzanie znacznej ilości czasu w internecie może prowadzić do przybierania na wadze?

Znajdowanie powiązań między zmiennymi pomaga naukowcom zajmującym się medycyną projektować lepsze leki i kuracje, dostarcza specjalistom od marketingu informacji o tym, kto chętnie kupi ich produkty, oraz informuje polityków, jakimi powinni posługiwać się argumentami, aby poprzeć określone działania lub się im sprzeciwić.



W sferze wielkiego biznesu związanego z poszukiwaniem zależności między zmiennymi można znaleźć niewiarygodną liczbę wyników statystycznych — ale czy można stwierdzić, które są prawidłowe, a które nie? Na podstawie takich badań podejmuje się wiele istotnych decyzji i ważne jest, aby mieć świadomość, jakie warunki muszą zostać spełnione, żeby ich wyniki można było uznać za wiarygodne. Dotyczy to zwłaszcza sytuacji, gdy stwierdza się istnienie związku przyczynowo-skutkowego.

W rozdziale 18. opisuję szczegóły i niuanse analizy danych pochodzących z zestawień dwóch zmiennych liczbowych (takich jak poziom dawkowania leku i ciśnienie krwi), omawiam kwestie znajdowania i interpretowania **korelacji** (siły i kierunku relacji liniowej pomiędzy zmiennymi x i y), prezentuję sposoby znajdowania równania prostej, która najlepiej dopasowuje się do danych (i informuję, kiedy można to robić), oraz przedstawiam sposoby wykorzystywania uzyskanych wyników w celu prognozowania wartości danej zmiennej na podstawie innej (co nazywa się **regresją**). Przedstawiam także narzędzia umożliwiające ustalenie, kiedy linia jest dobrze dopasowana do danych, a kiedy nie i jakie wnioski można wyciągnąć (a jakich nie można) w sytuacjach, gdy linia rzeczywiście pasuje.

Metody wykorzystywane do poszukiwania i opisywania powiązań pomiędzy dwiema zmiennymi kategorycznymi (takimi jak liczba dawek leku przyjmowanych dziennie i obecność lub brak nudności) opisuję szczegółowo w rozdziale 19. Prezentuję także informacje o gromadzeniu i zestawianiu danych w **tabelach krzyżowych** (w których możliwe wartości jednej zmiennej tworzą wiersze, a możliwe wartości drugiej zmiennej tworzą kolumny), o interpretacji wyników, analizie danych z tabel krzyżowych w poszukiwaniu zależności, a także o sprawdzaniu wyników pod kątem niezależności. Dodatkowo, podobnie jak w całej książce, prezentuję strategię krytycznej oceny wyników tego rodzaju analiz z punktu widzenia ich wiarygodności.

Wyciąganie wiarygodnych wniosków



Do przeprowadzania analiz statystycznych badacze używają oprogramowania statystycznego, które opiera się na wzorach. Wzory nie wiedzą jednak, czy są wykorzystywane właściwie, i nie ostrzegą Cię, gdy wyniki będą nieprawidłowe. Co więcej, komputery nie są w stanie stwierdzić, co oznaczają wyniki; sam musisz to ustalić. Z tej książki dowiesz się, jakiego rodzaju wnioski możesz, a jakich nie możesz wyciągać po przeprowadzeniu analizy. Poniższe podrozdziały stanowią wstęp do wyciągnięcia odpowiednich wniosków.

Podawanie zawyżonych wyników

Jednym z najczęstszych błędów popełnianych podczas wnioskowania jest zawyżanie wyników lub uogólnianie ich dla większej grupy niż rzeczywiście reprezentowana w badaniu. Pani profesor mogłaby na przykład chcieć ustalić, które reklamy nadawane podczas finału Super Bowl najbardziej podobają się widzom. Gromadzi więc setkę swoich studentów w finałową niedzielę i prosi ich, aby oceniali pojawiające się reklamy. Studenci tworzą listę pięciu najlepszych i pani profesor stwierdza, że wszystkim widzom Super Bowl te pięć reklam podobało się najbardziej. Ale wie przecież tylko, które z nich najbardziej podobały się *jej studentom* — nie badała innych grup, więc nie może wyciągać wniosków dotyczących wszystkich widzów.

Kwestionowanie twierdzeń o przyczynie i skutku

Łatwo wyciągnąć nieprawidłowe wnioski w sytuacji, gdy badacze stwierdzają, że dwie zmienne są ze sobą powiązane (za pośrednictwem analizy takiej jak regresja; zob. wcześniejszy podrozdział „Korelacja, regresja i tabele krzyżowe”, aby uzyskać więcej informacji), a następnie automatycznie dochodzą do wniosku, że te dwie zmienne łączy związek przyczynowo-skutkowy.

Zalóżmy na przykład, że naukowiec przeprowadził ankietę dotyczącą zdrowia i odkrył, że osoby, które przyjmowały codziennie witaminę C, zgłaszają mniej przeziębień niż takie, które tej witaminy codziennie nie przyjmowały. Po ustaleniu wyników, wykorzystując te dane jako dowód, badacz pisze referat i publikuje informację prasową, zgodnie z którą witamina C zapobiega przeziębieniom.

Otóż, chociaż może być prawdą, że witamina C zapobiega przeziębieniom, badanie tego naukowca nie może tego stwierdzić. Badanie było obserwacyjne, co oznacza, że nie kontrolowano żadnych innych czynników, które mogą być związane zarówno z witaminą C, jak i przeziębieniami. Być może na przykład osoby, które przyjmują codziennie witaminę C, są ogólnie bardziej świadome w kwestiach zdrowotnych, częściej myją ręce, więcej ćwiczą i lepiej się odżywiają; wszystkie te zachowania mogą być pomocne w zmniejszaniu ich skłonności do przeziębień.

Dopóki nie przeprowadzimy kontrolowanego eksperymentu, nie możemy wyciągać wniosków przyczynowo-skutkowych na podstawie relacji, które znaleźliśmy. (Eksperymenty omawiam bardziej szczegółowo we wcześniejszej części tego rozdziału).



Jak być detektywem, a nie sceptykiem

Statystyka to znacznie więcej niż liczby. Aby naprawdę „załapać” statystykę, musisz zrozumieć, jak wyciągać odpowiednie wnioski na podstawie badania danych i mieć na tyle oleju w głowie, aby nie wierzyć we wszystko, co usłyszysz lub przeczytasz, zanim nie ustalisz, skąd wzięły się dane informacje, co z nimi robiono i w jaki sposób wyciągano wnioski. Omawiam te kwestie w całej książce, ale koncentruję się na nich w rozdziale 20., w którym przedstawiam dziesięć sposobów umożliwiających nabycie umiejętności detektywa w sferze statystyki dzięki rozpoznawaniu typowych błędów popełnianych przez naukowców i media.



Informacja dla uczniów i studentów: w rozdziale 21. omawiam przydatne na egzaminie praktyki statystyczne i doradzam, jak poprawić swoje wyniki. Większość moich porad opiera się na zrozumieniu ogólnych założeń omawianych zagadnień oraz szczegółów związanych z prawidłowym rozwiązywaniem problemów statystycznych.



Zajmowanie sceptycznego czy też cynicznego stanowiska wobec statystyki jest bardzo łatwe, zwłaszcza po tym, gdy dowiemy się, co ma miejsce za kulisami badań; nie pozwól jednak, żeby przytrafiło się to Tobie. Dzięki statystykom można znaleźć wiele przydatnych informacji, które mogą w pozytywny sposób wpłynąć na nasze życie. Skanalizuj swój sceptycyzm, stawiając sobie dwa cele:

- ✓ Zostań dobrze poinformowanym konsumentem informacji statystycznych, z którymi stykasz się na co dzień.
- ✓ Ustal swoją pozycję w pracy jako kogoś, kogo inni radzą się w kwestiach statystycznych i kto wie, kiedy i jak może pomóc innym, a kiedy powinien poszukać statystyka.

Czytając i wykorzystując informacje zawarte w tej książce, zyskasz pewność, że potrafisz podejmować prawidłowe decyzje dotyczące wyników statystycznych. Nauczysz się w rzetelny sposób prowadzić własne badania statystyczne i będziesz gotów zająć się kolejnym projektem w pracy, krytycznie ocenić irytującą reklamę polityczną lub z wyróżnieniem zdać kolejny egzamin!

Skorowidz

A

analiza
 danych, 280
 statystyczna, 34
 trendów, 109
ankieta, 74
aproksymacja rozkładu dwumianowego, 167

B

badanie
 eksperymentów, 269
 obserwacyjne, 29, 268
 podstaw rozkładu normalnego, 155
 środką danych, 86
 właściwości korelacji, 292
 wykresów pudełkowych, 128, 132
 wyników testu ACT, 100
 zachowań, 173
 rozstępu ćwiartkowego, 103
błąd
 standardowy, 177, 178, 193
 dla populacji, 179
 statystyczny, 35, 75, 191, 328
 dla odsetka z próby, 194
 dla średniej z próby, 196
błędne korelacje, 330
błędy
 drugiego rodzaju, 231
 pierwszego rodzaju, 231
 próbekowania, 75

C

cechy populacji, 36
cel sondażu, 257
centralne twierdzenie graniczne, 72, 181, 185

centrum, 132
ciągłe zmienne losowe, 144
częstość, 32
czynnik, 268

D

dane, 63
 ciągłe, 64
 dwuwymiarowe, 286
 dyskretne, 64
 ilościowe, 64
 jakościowe, 64, 84
 kategoryczne, 64, 84, 105
 liczbowe, 32, 64, 117
 obiektywne, 279
 poprawne, 278
 porządkowe, 64
 symetryczne, 90
 tendencyjne, 327
 wiarygodne, 278
definiowanie
 liczebności próby, 273
 populacji docelowej, 257
 rozkładu z próby, 175
 wartości p , 227
dobór właściwej próby, 30
dwumian, 146
dyskretne zmienne losowe, 144

E

efekt
 marginalny, 247
 placebo, 74, 271
eksperymenty, 29, 268, 270
 podwójnie ślepe, 74
 ślepe, 74

ekstrapolacja, 298
etapy
 badania, 62
 znajdowania prawdopodobieństwa, 161

F

formułowanie hipotez, 222

G

grafy, 33
gromadzenie
 dobrych danych, 278
 dowodów, 223
 statystyk z prób, 224
 wartościowych danych, 30
grupa, 125
 doświadczalna, 74
 kontrolna, 74

H

hipoteza, 222
 alternatywna, 77
 zerowa, 77, 222, 234
histogram, 89, 117, 326
 lewoskośny, 124
 mylący, 125
 prawoskośny, 124
 zbliżony do symetrycznego, 124

I

identyfikowanie
 dwumianu, 146
 prób nielosowych, 328
interpretacja
 histogramu, 120
 korelacji, 290
 linii regresji, 295
 nachylenia, 295
 odchylenia standardowego, 93
 percentyli, 99
 punktu przecięcia, 296
 statystyki testowej, 225
 tabel krzyżowych, 304
 wykresu czasowego, 135

 wykresu pudełkowego, 130, 134
 wykresu rozrzutu, 287
 wyników, 204, 317
istotność
 statystyczna, 78
 testu, 228

K

kontrola zmiennych zakłócających, 275
korelacja, 37, 79, 288, 292
krzywa dzwonowa, 71
kształt danych, 120

L

liczba
 grup, 125
 prób, 148
liczebność próby, 32, 57, 178, 198, 207
 mała, 236
 ustalanie, 329
 ustalanie pożądanej wartości, 211
 wybór, 273
linia regresji, 292, 293
losowe generowanie numerów, 67
losowość, 66, 143

M

małe próby, 235
mediana, 69, 88, 125
metoda najmniejszych kwadratów, 294
moc testu, 232
mylące
 histogramy, 125
 przedziały ufności, 219
 statystyki, 59
 wykresy, 323
 wykresy czasowe, 136
 wyniki, 267

N

nadmiar danych, 137
niezależność próby, 148, 315
nieznane odchylenia standardowe, 235

0

obiekty, 268
 obliczanie, 81
 błędu statystycznego, 194
 dla średniej z próby, 196
 danych kategorycznych, 84
 korelacji, 289
 liczebności próby, 212
 odchylenia standardowego, 91
 percentyli, 98
 prawdopodobieństwa, 149
 przedziału ufności, 209
 rozkładów
 brzegowych, 305
 łącznych, 308
 warunkowych, 310
 statystyki testowej, 225
 wartości p , 227
 obserwacja
 badań obserwacyjnych, 269
 skali, 127, 136
 ocena
 dowodów, 226
 prawdopodobieństwa złej decyzji, 230
 odchylenie standardowe, 69, 91, 179
 interpretacja, 93
 populacji
 nieznane, 209, 216
 znane, 210, 215
 właściwości, 93
 zmiennej o rozkładzie
 dwumianowym, 153
 odrzucanie hipotezy zerowej, 229
 odsetek
 z populacji, 36, 185
 z próby, 185, 187
 ogłaszanie wyników, 196
 określenie celu sondażu, 257
 opis
 relacji zależnej, 316
 zależności, 313

P

parametr, 68, 202
 percentyle, 70, 97, 165
 dla rozkładu normalnego, 164

planowanie sondażu, 256
 podejmowanie decyzji, 226, 282
 podsumowanie pięcioliczbowe, 101
 pomiar
 błędu standardowego, 177
 pozycji względnej, 97
 rozproszenia, 224
 zróznicowania próby, 132, 193
 populacja, 36, 65
 docelowa, 256, 257
 porady, 323, 335
 porażka, 148
 porównywanie
 dwóch niezależnych średnich, 240
 dwóch odsetków z populacji, 245
 grup, 310
 rozkładów, 169, 315
 poszukiwania błędu statystycznego, 328
 poziom, 268
 alfa, 228
 istotności testu, 228
 realizacji próby, 263
 ufności, 193, 203
 pozycja względna, 97
 prawdopodobieństwo, 145
 dwumianowe, 149
 porażki, 149
 sukcesu, 149
 testowe, 226
 złej decyzji, 230
 prawidłowa analiza danych, 280
 prognoza, 297, 319
 projektowanie
 eksperymentu, 270
 sondażu, 256
 prowadzenie sondażu, 262
 próba, 260
 kliniczna, 277
 losowa, 66, 260
 nielosowa, 66, 328
 podwójnie ślepa, 279
 przedział ufności, 35, 72, 76, 173, 201
 dla różnicy dwóch średnich, 214
 dla odsetka z populacji, 213
 dla różnicy dwóch odsetków z populacji,
 217
 dla różnicy średnich, 216
 dla średniej z populacji, 209
 przyczyna i skutek, 38, 269, 298, 317

przyczynowość, 79
przypisywanie losowe, 274
pułapka tak-tak, 337
punkt
końcowy, 127
początkowy, 127
przebieg, 71

R

reakcja, 268
regresja, 37
liniowa, 292
reguła trzech sigm, 70, 95
relacja zależna, 316
reszta, 298
rozkład, 34, 71, 175, 304
brzegowy, 305
dwumianowy, 34, 147, 149
odchylenie standardowe, 153
średnia, 153
wariancja, 153
łączny, 308
normalny, 34, 70, 71, 155
prawdopodobieństwa, 145, 151
t-Studenta, 34, 169
warunkowy, 310
X
normalny, 181
nie jest normalny, 181
Z, 71, 158
z próby, 175, 181, 185
rozproszenie, 91
rozstęp ćwiartkowy, 132

S

selektywne raportowanie, 332
skała, 55
na wykresie, 113
skośność
lewostronna, 90
prawostronna, 90
sondaże, 29, 74, 251
formułowanie pytań, 259
gromadzenie danych, 262
interpretacja wyników, 264
określenie celu, 257
poziom realizacji próby, 263

wybór próby, 260
wybór rodzaju, 258
spis powszechny, 68
sprawdzanie
kształtu danych, 120
liczb, 332
niezależności, 313, 315
obliczeń, 52
źródeł, 57
standardowy rozkład normalny, 71, 73, 158
standaryzacja, 159, 163
X do Z, 159
statystyka, 27, 67, 202
myląca, 59
opisowa, 32, 83
testowa, 224
dla pojedynczego odsetka, 238
w miejscu pracy, 48
w życiu codziennym, 41
stopnie swobody, 170
stosowanie testu t-Studenta, 236
sukces, 148
suma
kwadratów błędów, 294
łączna, 304
sumy brzegowe
kolumn, 303
wierszy, 303
szacowanie różnicy dwóch odsetków, 217
szacunki, 68

Ś

średnia, 87, 125
z populacji, 36, 69
z próby, 69, 177, 184
zmiennej losowej, 146

T

tabela krzyżowa, 37, 84, 302
tablica
dwumianowa, 151, 354
t-Studenta, 172, 236, 352
Z, 160, 349
tendycyjność
danych, 31, 68, 327
odpowiedzi, 262

- test
 ACT, 100
 statystyczny, 36, 77, 233
 t-Studenta, 235, 236
 dla zmiennych zależnych, 242
- testowanie
 jednej średniej z populacji, 233
 pojedynczego odsetka z populacji, 238
 statystyczne, 221
 średniej z różnicy, 242
- trend, 109
- tworzenie
 grupy, 119
 histogramu, 117
 rozważnej prognozy, 319
 tabeli krzyżowej, 302
 wykresu czasowego, 135
 wykresu pudełkowego, 128
 wykresu rozrzutu, 287
- U**
- upraszczanie nadmiaru danych, 137
- ustalanie
 błędu statystycznego, 193
 brakujących liczebności prób, 329
 istnienia zależności liniowych, 288
 percentyli dla rozkładu t-Studenta, 172
 położenia centrum, 132
 pożądanej wartości liczebności próby,
 211
 przedziału ufności, 213
 znaczenia liczebności próby, 198
- uśrednianie do średniej, 87
- uwzględnianie liczebności próby, 207
- W**
- wariancja zmiennej losowej, 146
- wartości
 graniczne, 120
 odstające, 133
 percentyli
 niskie, 165
 wysokie, 165
 ujemne t, 237
- wartość
 p, 77, 226, 227
 t, 236
- t^* , 173
 z, 73, 158
 z^* , 194, 206
- weryfikacja hipotezy, 222
- właściwości
 odchylenia standardowego, 93
 współczynnika korelacji, 292
- wnioski, 228, 280, 320
- wskazywanie mylących wykresów, 323
- wskaźnik, 54
- współczynnik korelacji, 289, 292
 Pearsona, 289
- wybór
 liczebności próby, 273
 obiektów, 274
 poziomu ufności, 205
 próby, 260
- wyciąganie wniosków, 38, 228, 280
- wykres, 33
 czasowy, 135, 326
 kołowy, 105, 325
 pudełkowy, 128
 słupkowy, 110, 325
 słupkowy skumulowany, 311
- wykresy
 danych kategorycznych, 105
 danych liczbowych, 117
 rozkładów
 brzegowych, 306
 łącznych, 309
 warunkowych, 311
 rozrzutu, 286, 287
 rozrzutu z korelacjami, 291
- wykrywanie
 błędów, 52
 mylących statystyk, 53
 tendencyjnych danych, 327
- wynik
 standaryzowany, 70, 225
 statystycznie istotny, 78, 2069
- wyniki sondażu, 264
- wyodrębnianie zmiennych, 305
- wzór, 339
 konwersji, 184
 na błąd statystyczny
 dla odsetka z próby, 194
 dla średniej z próby, 196
 na liczebność próby, 211

wzór

na prawdopodobieństwo dwumianowe,
149

na przedział ufności dla różnicy dwóch
średnich, 215

na standaryzację wartości, 159

na średnią rozkładu dwumianowego, 153

na wariancję rozkładu dwumianowego,
153

na wartość t , 236

Z

zabieg, 268

zadania z percentylami, 166

zakres, 95, 204

zależność, 316

liniowa, 288

zbiór

bimodalny, 126

danych, 64

zestawianie dowodów, 224

zmienna, 34, 65

kategoryczna, 301

niezależna, 313

losowa, 143, 175

ciągła, 144

dyskretna, 144

objaśniająca, 293

odpowiedzi, 293

zakłócająca, 276, 331

znaczenie sondaży, 252

znajdowanie

linii regresji, 293

mylących przedziałów ufności, 219

prawdopodobieństw

dla odsetka z próby, 187

dla rozkładu normalnego, 161

dla średniej z próby, 184

dla Z , 160

dla X o dowolnej wartości, 152

dla X o określonej wartości, 152

dwumianowych, 149, 151

X , 164

zróżnicowanie, 170

populacji, 208

próby, 193

związek

pomiędzy t i Z , 237

przyczynowo-skutkowy, 38, 269, 298, 317

Ź

źródła informacji

medialne, 51

pierwotne, 51

PROGRAM PARTNERSKI

GRUPY WYDAWNICZEJ 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 WYDAWNICZA

 **Helion SA**

Prosty sposób na statystykę

Czujesz się bezradny w obliczu statystyki? Bez obaw! Dzięki temu przystępnemu przewodnikowi dowiesz się, jak gromadzić i weryfikować dane oraz prezentować je na wykresach, a także jak rozszyfrowywać rozkłady, obliczać przedziały ufności i weryfikować hipotezy oraz analizować dane, wykorzystując korelację, regresję, tabele krzyżowe — i wiele więcej.

- **Świat statystyki** — naucz się weryfikować w kontekście ilościowym i jakościowym statystyki życia codziennego.
- **Spoglądaj z szerokiej perspektywy** — badaj dane z wykorzystaniem grafów i wykresów, opisz je za pomocą średnich, median, wyników standardowych, percentyli i nie tylko.
- **Wyniki mogą się różnić** — poznaj powszechnie stosowane rozkłady statystyczne i dowiedz się, jak należy postępować ze zmiennymi losowymi z błędem standardowym oraz centralnym twierdzeniem granicznym.
- **Szacuj z przekonaniem** — wykorzystuj błąd standardowy, przedziały ufności i testy statystyczne do wyciągania wniosków dotyczących populacji.
- **Finansowa strona zarządzania** — planowanie i realizacja budżetu.
- **Wkrocz w sferę badań statystycznych i ich analiz** — poznaj tajniki sondaży, eksperymentów, korelacji, regresji liniowej, tabel krzyżowych i niezależności.

Dr Deborah J. Rumsey jest adiunktem na Wydziale Statystyki i specjalistką ds. nauczania statystyki na Uniwersytecie Stanowym Ohio. Jest także autorką książek: *Statistics Workbook For Dummies*, *Statistics II For Dummies* i *Probability For Dummies*.



W książce znajdziesz:

- proste objaśnienia terminów statystycznych
- informacje o zestawianiu i weryfikacji danych oraz ich prezentacjach graficznych
- wszystko, co chciałbyś wiedzieć o zmiennych losowych, rozkładach — dwumianowym, normalnym i t-Studenta, rozkładach z prób oraz centralnym twierdzeniu granicznym
- wskazówki dotyczące przeprowadzania, interpretowania oraz weryfikacji sondaży i eksperymentów
- narzędzia analizy danych dla badań regresji, przedziałów ufności, testów statystycznych i tabel krzyżowych,
- mnóstwo przykładów i rysunków ilustrujących istotne koncepcje i metody

PO ROZUM NA...

www.dlabystszakow.pl

Zamówienia telefoniczne:

☎ 0 801 339900 📠 0 601 339900

septem
septem.pl

Sprawdź najnowsze promocje: <http://dlabystszakow.pl/promocje>
Książki najchętniej czytane: <http://dlabystszakow.pl/bestsellery>
Zamów informacje o nowościach: <http://dlabystszakow.pl/nowosci>

Helion SA: ul. Kościuszki 1c, 44-100 Gliwice, tel.: 32 230 98 63
e-mail: rady@dlabystszakow.pl <http://dlabystszakow.pl>

Cena 39,90 zł

ISBN 978-83-283-2770-2



9 788328 327702