

Spis treści

Podziękowaniaxv
O autorachxvii
Wstęp xix

Część I Podstawy uczenia maszynowego

1 Jak uczą się ludzie 3

 Ku myślącym maszynom 4

 Świt rozumowania mechanicznego 4

 Twierdzenia Gödla o niekompletności 5

 Formalizacja maszyn liczących 5

 Formalizacja ludzkiego myślenia 6

 Narodziny sztucznej inteligencji jako dyscypliny 7

 Biologia uczenia się 8

 Czym właściwie jest inteligentne oprogramowanie? 8

 Jak działają neurony 10

 Podejście kija i marchewki 15

 Przystosowywanie się do zmian 17

 Sztuczne formy inteligencji 18

 Prymitywna inteligencja 18

 Systemy eksperckie 19

 Systemy autonomiczne 22

 Sztuczne formy sentymentu 24

 Podsumowanie 25

2 Inteligentne oprogramowanie 27

 Stosowana sztuczna inteligencja 28

 Ewolucja inteligencji oprogramowania 28

 Systemy eksperckie 29

 Ogólna sztuczna inteligencja 31

 Uczenie nienadzorowane 32

 Uczenie nadzorowane 34

 Podsumowanie 37

3	Problemy z odwzorowywaniem i algorytmy	39
	Podstawowe problemy	40
	Klasyfikowanie obiektów	40
	Przewidywanie wyników	43
	Grupowanie obiektów	45
	Bardziej złożone problemy	48
	Klasyfikacja obrazów	48
	Wykrywanie obiektów	49
	Analiza tekstu	50
	Zautomatyzowane uczenie maszynowe	51
	Aspekty platformy AutoML	51
	Korzystanie z platformy AutoML Model Builder	54
	Podsumowanie	57
4	Ogólne kroki rozwiązania uczenia maszynowego	59
	Zbieranie danych	60
	Kultura firmy sterowana danymi	60
	Opcje magazynu	62
	Przygotowanie danych	63
	Podnoszenie jakości danych	64
	Czyszczenie danych	64
	Inżynieria cech	66
	Finalizowanie treningowego zbioru danych	68
	Wybieranie i trenowanie modelu	70
	Ściągawka z algorytmów	71
	Przypadek sieci neuronowych	74
	Ewaluacja wydajności modelu	75
	Wdrażanie modelu	77
	Wybór odpowiedniej platformy hostingowej	77
	Eksponowanie API	78
	Podsumowanie	79
5	Czynnik danych	81
	Jakość danych	81
	Ważność danych	82
	Zbieranie danych	83
	Integralność danych	85
	Kompletność	85

Unikatowość	85
Terminowość	86
Dokładność	86
Spójność	86
Kim właściwie jest analityk danych?	86
Praca analityka danych	87
Przybornik analityka danych	88
Analitycy danych i programiści	88
Podsumowanie	90

Część II **Uczenie maszynowe w .NET**

6 Sposób .NET	93
Dlaczego (nie) Python?	94
Dlaczego Python jest tak popularny w uczeniu maszynowym?	94
Taksonomia bibliotek Pythona wykorzystywanych w uczeniu maszynowym	96
Kompleksowe rozwiązania wykorzystujące modele Pythona	99
Wstęp do ML.NET	101
Tworzenie i używanie modeli w ML.NET	102
Elementy kontekstu uczenia	104
Podsumowanie	109
7 Implementacja potoku ML.NET	111
Dane początkowe	111
Eksploracja zbioru danych	112
Stosowanie typowych transformacji danych	113
Uwarunkowania zbioru danych	114
Etap treningowy	114
Wybór algorytmu	115
Pomiar rzeczywistej wartości algorytmu	115
Planowanie fazy testowej	116
Rzut oka na miary	117
Przewidywanie cen z poziomu aplikacji klienckiej	118
Pobieranie pliku modelu	118
Konfigurowanie aplikacji ASP.NET	118
Przewidywanie opłat za przejazd taksówką	119
Opracowanie odpowiedniego interfejsu użytkownika	121
Wątpliwości dotyczące danych i podejścia do problemu	122

Podsumowanie	123
8 Zadania i algorytmy ML.NET	125
Ogólna architektura ML.NET	125
Wykorzystywane typy i interfejsy	126
Reprezentacja danych	127
Obsługiwane katalogi	130
Zadania klasyfikacji	132
Klasyfikacja binarna	132
Klasyfikacja wieloklasowa	138
Zadania grupowania w klastry	145
Przygotowanie danych do pracy	145
Trenowanie modelu	146
Ocena modelu	148
Przeniesienie uczenia	151
Etapy tworzenia klasyfikatora obrazów	151
Stosowanie niezbędnych transformacji danych	152
Tworzenie i trenowanie modelu	154
Dodatkowe uwagi o przeniesieniu uczenia	156
Podsumowanie	157

Część III Podstawy uczenia płytkiego

9 Matematyczne podstawy uczenia maszynowego	161
Pod parasolem statystyki	162
Średnia w statystyce	163
Dominanta w statystyce	165
Mediana w statystyce	166
Obciążenie i wariancja	169
Wariancja w statystyce	169
Obciążenie w statystyce	172
Reprezentacja danych	173
Podsumowanie pięcioliczbowe	173
Histogramy	174
Wykresy punktowe	175
Macierze wykresu punktowego	176
Tworzenie wykresu na odpowiedniej skali	177
Podsumowanie	178

10 Miary uczenia maszynowego	179
Statystyka a uczenie maszynowe	179
Ostateczny cel uczenia maszynowego	180
Od modeli statystycznych do modeli uczenia maszynowego	181
Ocena modelu uczenia maszynowego	184
Od zbioru danych do prognoz	184
Mierzenie precyzji modelu	185
Przygotowanie danych do przetwarzania	191
Skalowanie	192
Standaryzacja	193
Normalizacja	193
Podsumowanie	193
11 Proste prognozy: Regresja liniowa	195
Problem	195
Zgadywanie wyników na podstawie danych	196
Tworzenie hipotez o relacji	197
Algorytm liniowy	199
Ogólna idea	200
Znajdowanie funkcji straty	201
Algorytm najmniejszych kwadratów	202
Algorytm spadku gradientu	205
Jak dobry jest algorytm?	209
Ulepszanie rozwiązania	210
Trasa wielomianowa	210
Regularyzacja	211
Podsumowanie	212
12 Złożone przewidywania i decyzje: drzewa	213
Problem	214
Czym właściwie jest drzewo?	214
Drzewa w uczeniu maszynowym	215
Przykładowy algorytm oparty na drzewie	215
Zasady projektowania algorytmów opartych na drzewach	217
Drzewa decyzyjne a systemy eksperckie	217
Odmiany algorytmów opartych na drzewach	218
Drzewa klasyfikacyjne	220
Działanie algorytmu CART	220

Algorytm ID3	224
Drzewa regresji	227
Działanie algorytmu	227
Przycinanie drzewa	228
Podsumowanie	229
13 Jak podejmować lepsze decyzje: metody grupowe	231
Problem	231
Technika bagging	232
Algorytmy lasów losowych	233
Kroki algorytmów	235
Zalety i wady	236
Technika wzmacniania (boosting)	238
Możliwości wzmacniania	238
Wzmacnianie gradientowe	241
Zalety i wady	245
Podsumowanie	246
14 Metody probabilistyczne: naiwny klasyfikator bayesowski	247
Szybkie wprowadzenie do statystyki bayesowskiej	247
Wstęp do prawdopodobieństwa Bayesa	248
Wstęp do notacji	249
Twierdzenie Bayesa	251
Praktyczny przykład recenzji kodu	252
Wykorzystanie statystyki bayesowskiej w klasyfikacji	253
Wstępne sformułowanie problemu	253
Uprozczone (lecz skuteczne) sformułowanie	254
Praktyczne aspekty klasyfikatorów bayesowskich	256
Naiwne klasyfikatory bayesowskie	256
Ogólny algorytm	257
Wielomianowy naiwny klasyfikator bayesowski	258
Naiwny klasyfikator bayesowski Bernoulliego	261
Naiwny klasyfikator bayesowski Gaussa	262
Naiwna regresja bayesowska	265
Podstawy liniowej regresji bayesowskiej	265
Zastosowanie bayesowskiej regresji liniowej	266
Podsumowanie	267

15 Grupowanie danych: klasyfikacja i klastry	269
Podstawowe podejście do klasyfikacji nadzorowanej	270
Algorytm k najbliższych sąsiadów	270
Kroki algorytmu	273
Scenariusze biznesowe	275
Maszyna wektorów nośnych	276
Ogólny opis algorytmu	276
Szybka powtórka z matematyki	280
Kroki algorytmu	282
Klasteryzacja nienadzorowana	287
Przypadek biznesowy: redukcja zbioru danych	287
Algorytm K-średnich	288
Algorytm K-medoidów	290
Algorytm DBSCAN	291
Podsumowanie	294

Część IV Podstawy uczenia głębokiego

16 Jednokierunkowe sieci neuronowe	299
Krótka historia sieci neuronowych	299
Neuron McCullocha-Pittsa	300
Sieci jednokierunkowe	300
Bardziej wyrafinowane sieci	301
Typy sztucznych neuronów	301
Perceptron	301
Neuron logistyczny	305
Trenowanie sieci neuronowej	307
Ogólna strategia uczenia	308
Algorytm propagacji wstecznej	309
Podsumowanie	316
17 Projekt sieci neuronowej	317
Aspekty sieci neuronowej	317
Funkcje aktywacji	318
Ukryte warstwy	322
Warstwa wyjściowa	326
Budowanie sieci neuronowej	327
Dostępne platformy	327

Pierwsza sieć neuronowa za pomocą Keras	330
Sieci neuronowe kontra inne algorytmy	333
Podsumowanie	336
18 Inne typy sieci neuronowych	337
Typowe problemy jednokierunkowych sieci neuronowych	337
Rekurencyjne sieci neuronowe	338
Anatomia sieci neuronowej ze stanem	339
Sieci neuronowe LSTM	342
Konwolucyjne sieci neuronowe	345
Klasyfikacja i rozpoznawanie obrazów	345
Warstwa konwolucyjna	346
Warstwa typu pooling	349
W pełni połączona warstwa	351
Dalszy rozwój sieci neuronowych	352
Generatywne sieci neuronowe z przeciwnikiem	352
Sieci typu autoencoder	353
Podsumowanie	355
19 Analiza sentymentu: kompleksowe rozwiązanie	357
Przygotowanie danych treningowych	358
Formalizowanie problemu	358
Uzyskiwanie danych	359
Manipulowanie danymi	360
Uwarunkowania dotyczące formatu pośredniego	361
Trenowanie modelu	362
Wybieranie ekosystemu	362
Budowanie słownika wyrazów	363
Wybieranie trenera	364
Inne aspekty sieci	369
Aplikacja kliencka	371
Pobieranie danych wejściowych dla modelu	372
Uzyskiwanie prognoz z modelu	373
Przekształcanie odpowiedzi w przydatne informacje	374
Podsumowanie	375

Część V Finalne uwagi

20 Usługi w chmurze oferujące AI	379
Azure Cognitive Services	380
Azure Machine Learning Studio	381
Azure Machine Learning Service	384
Maszyny DSVM	387
Usługi lokalne	387
SQL Server Machine Learning Services	387
Machine Learning Server	388
Microsoft Data Processing Services	388
Azure Data Lake	388
Azure Databricks	389
Azure HDInsight	390
.NET dla Apache Spark	390
Azure Data Share	391
Azure Data Factory	391
Podsumowanie	391
21 Biznesowe postrzeganie AI	393
Postrzeganie AI w branży	393
Wykorzystanie potencjału	394
Do czego można wykorzystać sztuczną inteligencję	394
Wyzwania czające się tuż za rogiem	396
Kompleksowe rozwiązania	398
Nazwijmy to po prostu konsultingiem	399
Granica między oprogramowaniem a analizą danych	399
Zwinna AI	402
Podsumowanie	405
<i>Indeks</i>	407