

Spis treści

Przedmowa	13
-----------------	----

Część I. Podstawy uczenia maszynowego	21
--	-----------

1. Krajobraz uczenia maszynowego	23
Czym jest uczenie maszynowe?	24
Dlaczego warto korzystać z uczenia maszynowego?	24
Rodzaje systemów uczenia maszynowego	27
Uczenie nadzorowane/nienadzorowane	28
Uczenie wsadowe/przyrostowe	34
Uczenie z przykładów/z modelu	37
Główne problemy uczenia maszynowego	42
Niedobór danych uczących	42
Niereprezentatywne dane uczące	43
Dane kiepskiej jakości	45
Nieistotne cechy	45
Przetrenowanie danych uczących	45
Niedotrenowanie danych uczących	47
Podsumowanie	48
Testowanie i ocenianie	48
Ćwiczenia	50
2. Nasz pierwszy projekt uczenia maszynowego	53
Praca z rzeczywistymi danymi	53
Przeanalizuj całokształt projektu	55
Określ zakres problemu	55
Wybierz metrykę wydajności	57
Sprawdź założenia	59

Zdobądź dane	59
Stwórz przestrzeń roboczą	59
Pobierz dane	62
Rzut oka na strukturę danych	63
Stwórz zbiór testowy	67
Odkrywaj i wizualizuj dane, aby zdobywać nowe informacje	71
Wizualizowanie danych geograficznych	71
Poszukiwanie korelacji	73
Eksperymentowanie z kombinacjami atrybutów	76
Przygotuj dane pod algorytmy uczenia maszynowego	77
Oczyszczanie danych	78
Obsługa tekstu i atrybutów kategoryjnych	80
Niestandardowe transformatory	81
Skalowanie cech	82
Potoki transformujące	83
Wybór i uczenie modelu	85
Trenowanie i ocena modelu za pomocą zbioru uczącego	85
Dokładniejsze ocenianie za pomocą sprawdzianu krzyżowego	86
Wyreguluj swój model	88
Metoda przeszukiwania siatki	88
Metoda losowego przeszukiwania	90
Metody zespołowe	91
Analizuj najlepsze modele i ich błędy	91
Oceń system za pomocą zbioru testowego	92
Uruchom, monitoruj i utrzymuj swój system	92
Teraz Twoja kolej!	93
Ćwiczenia	94
3. Klasyfikacja	95
Zbiór danych MNIST	95
Uczenie klasyfikatora binarnego	97
Miary wydajności	98
Pomiar dokładności za pomocą sprawdzianu krzyżowego	98
Macierz pomyłek	100
Precyzja i pełność	101
Kompromis pomiędzy precyzją a pełnością	102
Wykres krzywej ROC	106
Klasyfikacja wieloklasowa	108
Analiza błędów	111
Klasyfikacja wieloetykietowa	114
Klasyfikacja wielowyjściowa	115
Ćwiczenia	117

4. Uczenie modeli	119
Regresja liniowa	120
Równanie normalne	121
Złożoność obliczeniowa	123
Gradient prosty	124
Wsadowy gradient prosty	127
Stochastyczny spadek wzdłuż gradientu	130
Schodzenie po gradiencie z minigrupami	132
Regresja wielomianowa	133
Krzywe uczenia	135
Regularyzowane modele liniowe	139
Regresja grzbietowa	139
Regresja metodą LASSO	141
Metoda elastycznej siatki	143
Wczesne zatrzymywanie	144
Regresja logistyczna	145
Szacowanie prawdopodobieństwa	146
Funkcje ucząca i kosztu	146
Granice decyzyjne	148
Regresja softmax	150
Ćwiczenia	153
 5. Maszyny wektorów nośnych	 155
Liniowa klasyfikacja SVM	155
Klasyfikacja miękkiego marginesu	156
Nieliniowa klasyfikacja SVM	158
Jądro wielomianowe	159
Dodawanie cech podobieństwa	160
Gaussowskie jądro RBF	161
Złożoność obliczeniowa	163
Regresja SVM	163
Mechanizm działania	165
Funkcja decyzyjna i prognozy	165
Cel uczenia	166
Programowanie kwadratowe	168
Problem dualny	169
Kernelizowane maszyny SVM	170
Przyrostowe maszyny SVM	172
Ćwiczenia	173

6. Drzewa decyzyjne	175
Uczenie i wizualizowanie drzewa decyzyjnego	175
Wyliczanie prognoz	176
Szacowanie prawdopodobieństw przynależności do klas	178
Algorytm uczący CART	179
Złożoność obliczeniowa	180
Wskaźnik Giniego czy entropia?	180
Hiperparametry regularyzacyjne	181
Regresja	182
Niestabilność	184
Ćwiczenia	185
7. Uczenie zespołowe i losowe lasy	187
Klasyfikatory głosujące	187
Agregacja i wklejanie	190
Agregacja i wklejanie w module Scikit-Learn	191
Ocena OOB	192
Rejony losowe i podprzestrzenie losowe	194
Losowe lasy	194
Zespół Extra-Trees	195
Istotność cech	195
Wzmacnianie	197
AdaBoost	197
Wzmacnianie gradientowe	200
Kontaminacja	204
Ćwiczenia	207
8. Redukcja wymiarowości	209
Kłątwa wymiarowości	210
Główne strategie redukcji wymiarowości	211
Rzutowanie	211
Uczenie rozmaitościowe	213
Analiza PCA	215
Zachowanie wariancji	215
Główne składowe	215
Rzutowanie na d wymiarów	217
Implementacja w module Scikit-Learn	217
Współczynnik wariancji wyjaśnionej	217
Wybór właściwej liczby wymiarów	218
Algorytm PCA w zastosowaniach kompresji	219
Przyrostowa analiza PCA	220
Losowa analiza PCA	220

Jądrowa analiza PCA	221
Wybór jądra i strojenie hiperparametrów	221
Algorytm LLE	224
Inne techniki redukowania wymiarowości	225
Ćwiczenia	226

Część II. Sieci neuronowe i uczenie głębokie

229

9. Instalacja i używanie modułu TensorFlow	231
Instalacja	234
Tworzenie pierwszego grafu i uruchamianie go w sesji	234
Zarządzanie grafami	236
Cykl życia wartości w węźle	236
Regresja liniowa przy użyciu modułu TensorFlow	237
Implementacja metody gradientu prostego	238
Ręczne obliczanie gradientów	238
Automatyczne różniczkowanie	239
Korzystanie z optymalizatora	240
Dostarczanie danych algorytmowi uczącemu	241
Zapisywanie i wczytywanie modeli	242
Wizualizowanie grafu i krzywych uczenia za pomocą modułu TensorBoard	243
Zakresy nazw	246
Modułowość	247
Udostępnianie zmiennych	250
Ćwiczenia	253
10. Wprowadzenie do sztucznych sieci neuronowych	255
Od biologicznych do sztucznych neuronów	255
Neurony biologiczne	256
Operacje logiczne przy użyciu neuronów	257
Perceptron	259
Perceptron wielowarstwowy i propagacja wsteczna	262
Uczenie sieci MLP za pomocą zaawansowanego interfejsu API modułu TensorFlow	265
Uczenie głębokiej sieci neuronowej za pomocą standardowego interfejsu TensorFlow	266
Faza konstrukcyjna	266
Faza wykonawcza	270
Korzystanie z sieci neuronowej	271
Strojenie hiperparametrów sieci neuronowej	271
Liczba ukrytych warstw	271
Liczba neuronów tworzących warstwę ukrytą	272
Funkcje aktywacji	273
Ćwiczenia	273

11. Uczenie głębokich sieci neuronowych	275
Problemy zanikających/eksplodujących gradientów	275
Inicjacje wag Xaviera i He	276
Nienasycające funkcje aktywacji	278
Normalizacja wsadowa	281
Obcinanie gradientu	285
Wielokrotne stosowanie gotowych warstw	286
Wielokrotne stosowanie modelu TensorFlow	287
Wykorzystywanie modeli utworzonych w innych środowiskach	288
Zamrażanie niższych warstw	289
Zapamiętywanie warstw ukrytych	290
Modyfikowanie, usuwanie lub zastępowanie górnych warstw	291
Repozytoria modeli	291
Nienadzorowane uczenie wstępne	291
Uczenie wstępne za pomocą dodatkowego zadania	293
Szybsze optymalizatory	293
Optymalizacja momentum	294
Przyspieszony spadek wzdłuż gradientu (algorytm Nesterova)	295
AdaGrad	296
RMSProp	298
Optymalizacja Adam	298
Harmonogramowanie współczynnika uczenia	300
Regularyzacja jako sposób unikania przetrenowania	302
Wczesne zatrzymywanie	302
Regularyzacja ℓ_1 i ℓ_2	303
Porzucanie	304
Regularyzacja typu max-norm	306
Dogenerowanie danych	308
Praktyczne wskazówki	309
Ćwiczenia	310
12. Rozdzielanie operacji TensorFlow pomiędzy urządzenia i serwery	313
Wiele urządzeń na jednym komputerze	314
Instalacja	314
Zarządzanie pamięcią operacyjną karty graficznej	316
Umieszczanie operacji na urządzeniach	318
Przetwarzanie równoległe	321
Zależności sterujące	322
Wiele urządzeń na wielu serwerach	323
Otwieranie sesji	324
Usługi nadrzędna i robocza	325

Przypinanie operacji w wielu zadaniach	325
Rozdzielanie zmiennych pomiędzy wiele serwerów parametrów	326
Udostępnianie stanu rozproszonych sesji za pomocą kontenerów zasobów	327
Komunikacja asynchroniczna za pomocą kolejek	328
Wczytywanie danych bezpośrednio z grafu	333
Przetwarzanie równoległe sieci neuronowych w klastrze TensorFlow	339
Jedna sieć neuronowa na każde urządzenie	339
Replikacja wewnętrzgrafowa i międzygrafowa	341
Zrównoleglanie modelu	343
Zrównoleglanie danych	345
Ćwiczenia	349
13. Splotowe sieci neuronowe	351
Architektura kory wzrokowej	352
Warstwa splotowa	353
Filtry	354
Stosy map cech	356
Implementacja w module TensorFlow	357
Zużycie pamięci operacyjnej	359
Warstwa łącząca	360
Architektury splotowych sieci neuronowych	362
LeNet-5	362
AlexNet	364
GoogLeNet	366
ResNet	369
Ćwiczenia	373
14. Rekurencyjne sieci neuronowe	377
Neurony rekurencyjne	378
Komórki pamięci	380
Sekuencje wejść i wyjść	380
Podstawowe sieci RSN w module TensorFlow	381
Statyczne rozwijanie w czasie	382
Dynamiczne rozwijanie w czasie	384
Obsługa sekwencji wejściowych o zmiennej długości	385
Obsługa sekwencji wyjściowych o zmiennej długości	386
Uczenie rekurencyjnych sieci neuronowych	386
Uczenie klasyfikatora sekwencji	387
Uczenie w celu przewidywania szeregów czasowych	389
Twórcza sieć rekurencyjna	392

Głębokie sieci rekurencyjne	393
Rozmieszczanie głębokiej sieci rekurencyjnej pomiędzy wiele kart graficznych	394
Wprowadzanie metody porzucania	395
Problem uczenia w sieciach wielotaktowych	396
Komórka LSTM	397
Połączenia przeziernie	400
Komórka GRU	400
Przetwarzanie języka naturalnego	401
Reprezentacje wektorowe słów	402
Sieć typu koder-dekoder służąca do tłumaczenia maszynowego	403
Ćwiczenia	406
15. Autokodery	407
Efektywne reprezentacje danych	407
Analiza PCA za pomocą niedopełnionego autokodera liniowego	409
Autokodery stosowe	410
Implementacja w module TensorFlow	411
Wiązanie wag	412
Uczenie autokoderów pojedynczo	413
Wizualizacja rekonstrukcji	415
Wizualizowanie cech	416
Nienadzorowane uczenie wstępne za pomocą autokoderów stosowych	417
Autokodery odsumiające	419
Implementacja w module TensorFlow	420
Autokodery rzadkie	420
Implementacja w module TensorFlow	422
Autokodery wariacyjne	423
Generowanie cyfr	426
Inne autokodery	427
Ćwiczenia	427
16. Uczenie przez wzmacnianie	431
Uczenie się optymalizowania nagród	432
Wyszukiwanie polityki	433
Wprowadzenie do narzędzia OpenAI gym	435
Sieci neuronowe jako polityki	438
Ocenianie czynności — problem przypisania zasługi	440
Gradienty polityk	441
Procesy decyzyjne Markowa	446

Uczenie metodą różnic czasowych i algorytm Q-uczenia	449
Polityki poszukiwania	451
Przybliżający algorytm Q-uczenia	451
Nauka gry w Ms. Pac-Man za pomocą głębokiego Q-uczenia	452
Ćwiczenia	459
Dziękuję!	460

Dodatki **461**

A Rozwiązania ćwiczeń	463
B Lista kontrolna projektu uczenia maszynowego	487
C Problem dualny w maszynach wektorów nośnych	493
D Różniczkowanie automatyczne	497
Skorowidz	513