

---

# Spis treści

Przedmowa .....	15
-----------------	----

---

## Część I. Podstawy uczenia maszynowego 25

<b>1. Krajobraz uczenia maszynowego .....</b>	<b>27</b>
Czym jest uczenie maszynowe?	28
Dlaczego warto korzystać z uczenia maszynowego?	28
Przykładowe zastosowania	31
Rodzaje systemów uczenia maszynowego	33
Uczenie nadzorowane i uczenie nienadzorowane	34
Uczenie wsadowe i uczenie przyrostowe	40
Uczenie z przykładów i uczenie z modelu	43
Główne problemy uczenia maszynowego	48
Niedobór danych uczących	50
Niereprezentatywne dane uczące	50
Dane kiepskiej jakości	51
Nieistotne cechy	52
Przetrenowanie danych uczących	52
Niedotrenowanie danych uczących	54
Podsumowanie	54
Testowanie i ocenianie	55
Strojenie hiperparametrów i dobór modelu	55
Niezgodność danych	56
Ćwiczenia	57

<b>2. Nasz pierwszy projekt uczenia maszynowego .....</b>	<b>59</b>
Praca z rzeczywistymi danymi	59
Przeanalizuj całokształt projektu	61
Określ zakres problemu	61
Wybierz metrykę wydajności	63
Sprawdź założenia	65
Zdobądź dane	65
Stwórz przestrzeń roboczą	66
Pobierz dane	68
Rzut oka na strukturę danych	70
Stwórz zbiór testowy	74
Odkrywaj i wizualizuj dane, aby zdobywać nowe informacje	78
Wizualizowanie danych geograficznych	78
Poszukiwanie korelacji	80
Eksperymentowanie z kombinacjami atrybutów	83
Przygotuj dane pod algorytmy uczenia maszynowego	84
Oczyszczanie danych	84
Obsługa tekstu i atrybutów kategoryjnych	87
Niestandardowe transformatory	89
Skalowanie cech	90
Potoki transformujące	90
Wybór i uczenie modelu	92
Trenowanie i ocena modelu za pomocą zbioru uczącego	92
Dokładniejsze ocenianie za pomocą sprawdzianu krzyżowego	93
Wyreguluj swój model	96
Metoda przeszukiwania siatki	96
Metoda losowego przeszukiwania	98
Metody zespołowe	98
Analizuj najlepsze modele i ich błędy	98
Oceń system za pomocą zbioru testowego	99
Uruchom, monitoruj i utrzymuj swój system	100
Teraz Twoja kolej!	103
Ćwiczenia	103
<b>3. Klasyfikacja .....</b>	<b>105</b>
Zbiór danych MNIST	105
Uczenie klasyfikatora binarnego	107
Miary wydajności	108
Pomiar dokładności za pomocą sprawdzianu krzyżowego	108
Macierz pomyłek	110
Precyzja i pełność	111

Kompromis pomiędzy precyzją a pełnością	112
Wykres krzywej ROC	116
Klasyfikacja wieloklasowa	119
Analiza błędów	121
Klasyfikacja wieloetykietowa	124
Klasyfikacja wielowyjściowa	125
Ćwiczenia	127
<b>4. Uczenie modeli .....</b>	<b>129</b>
Regresja liniowa	130
Równanie normalne	131
Złożoność obliczeniowa	134
Gradient prosty	135
Wsadowy gradient prosty	138
Stochastyczny spadek wzdłuż gradientu	141
Schodzenie po gradiencie z minigrupami	143
Regresja wielomianowa	145
Krzywe uczenia	146
Regularyzowane modele liniowe	150
Regresja grzbietowa	150
Regresja metodą LASSO	153
Metoda elastycznej siatki	155
Wczesne zatrzymywanie	156
Regresja logistyczna	157
Szacowanie prawdopodobieństwa	158
Funkcje ucząca i kosztu	159
Granice decyzyjne	160
Regresja softmax	162
Ćwiczenia	166
<b>5. Maszyny wektorów nośnych .....</b>	<b>167</b>
Liniowa klasyfikacja SVM	167
Klasyfikacja miękkiego marginesu	168
Nieliniowa klasyfikacja SVM	170
Jądro wielomianowe	171
Cechy podobieństwa	172
Gaussowskie jądro RBF	173
Złożoność obliczeniowa	175
Regresja SVM	175
Mechanizm działania	177
Funkcja decyzyjna i prognozy	177
Cel uczenia	178

Programowanie kwadratowe	180
Problem dualny	181
Kernelizowane maszyny SVM	182
Przyrostowe maszyny SVM	185
Ćwiczenia	186
<b>6. Drzewa decyzyjne .....</b>	<b>187</b>
Uczenie i wizualizowanie drzewa decyzyjnego	187
Wyliczanie prognoz	188
Szacowanie prawdopodobieństw przynależności do klas	190
Algorytm uczący CART	191
Złożoność obliczeniowa	192
Wskaźnik Giniego czy entropia?	192
Hiperparametry regularyzacyjne	193
Regresja	194
Niestabilność	196
Ćwiczenia	197
<b>7. Uczenie zespołowe i losowe lasy .....</b>	<b>199</b>
Klasyfikatory głosujące	199
Agregacja i wklejanie	202
Agregacja i wklejanie w module Scikit-Learn	203
Ocena OOB	205
Rejony losowe i podprzestrzenie losowe	206
Losowe lasy	206
Zespół Extra-Trees	207
Istotność cech	207
Wzmacnianie	209
AdaBoost	209
Wzmacnianie gradientowe	212
Kontaminacja	217
Ćwiczenia	219
<b>8. Redukcja wymiarowości .....</b>	<b>223</b>
Kłątwa wymiarowości	224
Główne strategie redukcji wymiarowości	225
Rzutowanie	225
Uczenie różnorodnościowe	227
Analiza PCA	228
Zachowanie wariancji	229
Główne składowe	230

Rzutowanie na d wymiarów	231
Implementacja w module Scikit-Learn	232
Współczynnik wariancji wyjaśnionej	232
Wybór właściwej liczby wymiarów	232
Algorytm PCA w zastosowaniach kompresji	233
Losowa analiza PCA	234
Przyrostowa analiza PCA	235
Jądrowa analiza PCA	236
Wybór jądra i strojenie hiperparametrów	236
Algorytm LLE	239
Inne techniki redukowania wymiarowości	241
Ćwiczenia	241
<b>9. Techniki uczenia nienadzorowanego .....</b>	<b>243</b>
Analiza skupień	244
Algorytm centroidów	246
Granice algorytmu centroidów	255
Analiza skupień w segmentacji obrazu	256
Analiza skupień w przetwarzaniu wstępnym	257
Analiza skupień w uczeniu półnadzorowanym	259
Algorytm DBSCAN	262
Inne algorytmy analizy skupień	265
Mieszanki gaussowskie	266
Wykrywanie anomalii za pomocą mieszanin gaussowskich	271
Wyznaczanie liczby skupień	273
Modele bayesowskie mieszanin gaussowskich	275
Inne algorytmy służące do wykrywania anomalii i nowości	279
Ćwiczenia	280

---

## **Część II. Sieci neuronowe i uczenie głębokie** **283**

<b>10. Wprowadzenie do sztucznych sieci neuronowych i ich implementacji z użyciem interfejsu Keras .....</b>	<b>285</b>
Od biologicznych do sztucznych neuronów	286
Neurony biologiczne	287
Operacje logiczne przy użyciu neuronów	288
Perceptron	289
Perceptron wielowarstwowy i propagacja wsteczna	293
Regresyjne perceptrony wielowarstwowe	297
Klasyfikacyjne perceptrony wielowarstwowe	298

Implementowanie perceptronów wielowarstwowych za pomocą interfejsu Keras	300
Instalacja modułu TensorFlow 2	301
Tworzenie klasyfikatora obrazów za pomocą interfejsu sekwencyjnego	302
Tworzenie regresyjnego perceptronu wielowarstwowego za pomocą interfejsu sekwencyjnego	311
Tworzenie złożonych modeli za pomocą interfejsu funkcyjnego	312
Tworzenie modeli dynamicznych za pomocą interfejsu podklasowego	316
Zapisywanie i odczytywanie modelu	318
Stosowanie wywołań zwrotnych	318
Wizualizacja danych za pomocą narzędzia TensorBoard	320
Dostrajanie hiperparametrów sieci neuronowej	323
Liczba warstw ukrytych	326
Liczba neuronów w poszczególnych warstwach ukrytych	327
Współczynnik uczenia, rozmiar grupy i pozostałe hiperparametry	328
Ćwiczenia	330
<b>11. Uczenie głębokich sieci neuronowych .....</b>	<b>333</b>
Problemy zanikających/eksplodujących gradientów	334
Inicjalizacja wag Glorota i He	334
Nienasycające funkcje aktywacji	336
Normalizacja wsadowa	340
Obcinanie gradientu	346
Wielokrotne stosowanie gotowych warstw	347
Uczenie transferowe w interfejsie Keras	348
Nienadzorowane uczenie wstępne	350
Uczenie wstępne za pomocą dodatkowego zadania	350
Szybsze optymalizatory	352
Optymalizacja momentum	352
Przyspieszony spadek wzdłuż gradientu (algorytm Nesterova)	353
AdaGrad	355
RMSProp	356
Optymalizatory Adam i Nadam	357
Harmonogramowanie współczynnika uczenia	359
Regularyzacja jako sposób zapobiegania przetrenowaniu	364
Regularyzacja $\ell_1$ i $\ell_2$	364
Porzucanie	365
Regularyzacja typu Monte Carlo (MC)	368
Regularyzacja typu max-norm	370
Podsumowanie i praktyczne wskazówki	371
Ćwiczenia	372

<b>12. Modele niestandardowe i uczenie za pomocą modułu TensorFlow .....</b>	<b>375</b>
Krótkie omówienie modułu TensorFlow	375
Korzystanie z modułu TensorFlow jak z biblioteki NumPy	379
Tensory i operacje	379
Tensory a biblioteka NumPy	381
Konwersje typów	381
Zmienne	381
Inne struktury danych	382
Dostosowywanie modeli i algorytmów uczenia	383
Niestandardowe funkcje straty	383
Zapisywanie i wczytywanie modeli zawierających elementy niestandardowe	384
Niestandardowe funkcje aktywacji, inicjalizatory, regularyzatory i ograniczenia	386
Niestandardowe wskaźniki	387
Niestandardowe warstwy	389
Niestandardowe modele	392
Funkcje straty i wskaźniki oparte na elementach wewnętrznych modelu	394
Obliczanie gradientów za pomocą różniczkowania automatycznego	396
Niestandardowe pętle uczenia	399
Funkcje i grafy modułu TensorFlow	402
AutoGraph i kreślenie	404
Reguły związane z funkcją TF	405
Ćwiczenia	406
<b>13. Wczytywanie i wstępne przetwarzanie danych za pomocą modułu TensorFlow .....</b>	<b>409</b>
Interfejs danych	410
Łączenie przekształceń	410
Tasowanie danych	412
Wstępne przetwarzanie danych	415
Składanie wszystkiego w całość	416
Pobieranie wstępne	417
Stosowanie zestawu danych z interfejsem tf.keras	418
Format TFRecord	419
Skompresowane pliki TFRecord	420
Wprowadzenie do buforów protokołów	420
Bufory protokołów w module TensorFlow	422
Wczytywanie i analizowanie składni obiektów Example	423
Obsługa list za pomocą bufora protokołów SequenceExample	424
Wstępne przetwarzanie cech wejściowych	425
Kodowanie cech kategoryalnych za pomocą wektorów gorącojedynkowych	426
Kodowanie cech kategoryalnych za pomocą wektorów właściwościowych	428
Warstwy przetwarzania wstępnego w interfejsie Keras	431

TF Transform	433
Projekt TensorFlow Datasets (TFDS)	435
Ćwiczenia	436
<b>14. Głębokie widzenie komputerowe za pomocą spłotowych sieci neuronowych .....</b>	<b>439</b>
Struktura kory wzrokowej	440
Warstwy spłotowe	441
Filtry	443
Stosy map cech	444
Implementacja w module TensorFlow	446
Zużycie pamięci operacyjnej	448
Warstwa łącząca	449
Implementacja w module TensorFlow	451
Architektury spłotowych sieci neuronowych	452
LeNet-5	454
AlexNet	455
GoogLeNet	458
VGGNet	461
ResNet	461
Xception	465
SENet	466
Implementacja sieci ResNet-34 za pomocą interfejsu Keras	468
Korzystanie z gotowych modeli w interfejsie Keras	469
Gotowe modele w uczeniu transferowym	471
Klasyfikowanie i lokalizowanie	473
Wykrywanie obiektów	474
W pełni połączone sieci spłotowe	476
Sieć YOLO	478
Segmentacja semantyczna	481
Ćwiczenia	484
<b>15. Przetwarzanie sekwencji za pomocą sieci rekurencyjnych i spłotowych .....</b>	<b>487</b>
Neurony i warstwy rekurencyjne	488
Komórki pamięci	490
Sekwencje wejść i wyjść	491
Uczenie sieci rekurencyjnych	492
Prognozowanie szeregów czasowych	493
Wskaźniki bazowe	494
Implementacja prostej sieci rekurencyjnej	494
Głębokie sieci rekurencyjne	496
Prognozowanie kilka taktów w przód	497

Obsługa długich sekwencji	500
Zwalczanie problemu niestabilnych gradientów	501
Zwalczanie problemu pamięci krótkotrwałej	503
Ćwiczenia	511
<b>16. Przetwarzanie języka naturalnego za pomocą sieci rekurencyjnych i mechanizmów uwagi .....</b>	<b>513</b>
Generowanie tekstów szekspirowskich za pomocą znakowej sieci rekurencyjnej	514
Tworzenie zestawu danych uczących	515
Rozdzielanie zestawu danych sekwencyjnych	515
Dzielenie zestawu danych sekwencyjnych na wiele ramek	516
Budowanie i uczenie modelu Char-RNN	518
Korzystanie z modelu Char-RNN	519
Generowanie sztucznego tekstu szekspirowskiego	519
Stanowe sieci rekurencyjne	520
Analiza sentymentów	522
Maskowanie	526
Korzystanie z gotowych reprezentacji właściwościowych	527
Sieć typu koder – dekodek służąca do neuronowego tłumaczenia maszynowego	529
Dwukierunkowe warstwy rekurencyjne	532
Przeszukiwanie wiązkowe	533
Mechanizmy uwagi	534
Mechanizm uwagi wizualnej	537
Liczy się tylko uwaga, czyli architektura transformatora	539
Współczesne innowacje w modelach językowych	546
Ćwiczenia	548
<b>17. Uczenie reprezentacji za pomocą autokoderów i generatywnych sieci przeciwstawnych .....</b>	<b>551</b>
Efektywne reprezentacje danych	552
Analiza PCA za pomocą niedopełnionego autokodera liniowego	554
Autokodery stosowe	555
Implementacja autokodera stosowego za pomocą interfejsu Keras	556
Wizualizowanie rekonstrukcji	557
Wizualizowanie zestawu danych Fashion MNIST	558
Nienadzorowane uczenie wstępne za pomocą autokoderów stosowych	558
Wiązanie wag	560
Uczenie autokoderów pojedynczo	561
Autokodery spłotowe	562
Autokodery rekurencyjne	563
Autokodery odzsumiające	564
Autokodery rzadkie	566

Autokodery wariacyjne	569
Generowanie obrazów Fashion MNIST	572
Generatywne sieci przeciwstawne	574
Problemy związane z uczeniem sieci GAN	577
Głębokie splotowe sieci GAN	579
Rozrost progresywny sieci GAN	582
Sieci StyleGAN	585
Ćwiczenia	587
<b>18. Uczenie przez wzmacnianie .....</b>	<b>589</b>
Uczenie się optymalizowania nagród	590
Wyszukiwanie strategii	591
Wprowadzenie do narzędzia OpenAI Gym	593
Sieci neuronowe jako strategie	597
Ocenianie czynności: problem przypisania zasługi	598
Gradienty strategii	600
Procesy decyzyjne Markowa	604
Uczenie metodą różnic czasowych	607
Q-uczenie	609
Strategie poszukiwania	610
Przybliżający algorytm Q-uczenia i Q-uczenie głębokie	611
Implementacja modelu Q-uczenia głębokiego	612
Odmiany Q-uczenia głębokiego	616
Ustalone Q-wartości docelowe	616
Podwójna sieć DQN	617
Odtwarzanie priorytetowych doświadczeń	618
Walcząca sieć DQN	618
Biblioteka TF-Agents	619
Instalacja biblioteki TF-Agents	620
Środowiska TF-Agents	620
Specyfikacja środowiska	621
Funkcje opakowujące środowisko i wstępne przetwarzanie środowiska Atari	622
Architektura ucząca	625
Tworzenie Q-sieci głębokiej	627
Tworzenie agenta DQN	629
Tworzenie bufora odtwarzania i związanego z nim obserwatora	630
Tworzenie wskaźników procesu uczenia	631
Tworzenie sterownika	632
Tworzenie zestawu danych	633
Tworzenie pętli uczenia	636
Przegląd popularnych algorytmów RN	637
Ćwiczenia	639

<b>19. Wielkoskalowe uczenie i wdrażanie modeli TensorFlow .....</b>	<b>641</b>
Eksploatacja modelu TensorFlow	642
Korzystanie z systemu TensorFlow Serving	642
Tworzenie usługi predykcyjnej na platformie GCP AI	650
Korzystanie z usługi prognozowania	655
Wdrażanie modelu na urządzeniu mobilnym lub wbudowanym	658
Przyspieszanie obliczeń za pomocą procesorów graficznych	661
Zakup własnej karty graficznej	662
Korzystanie z maszyny wirtualnej wyposażonej w procesor graficzny	664
Colaboratory	665
Zarządzanie pamięcią operacyjną karty graficznej	666
Umieszczanie operacji i zmiennych na urządzeniach	669
Przetwarzanie równoległe na wielu urządzeniach	671
Uczenie modeli za pomocą wielu urządzeń	673
Zrównoleglanie modelu	673
Zrównoleglanie danych	675
Uczenie wielkoskalowe za pomocą interfejsu strategii rozpraszania	680
Uczenie modelu za pomocą klastra TensorFlow	681
Realizowanie dużych grup zadań uczenia	
za pomocą usługi Google Cloud AI Platform	684
Penetracyjne strojenie hiperparametrów w usłudze AI Platform	686
Ćwiczenia	688
Dziękuję!	688
<b>A Rozwiązania ćwiczeń .....</b>	<b>691</b>
<b>B Lista kontrolna projektu uczenia maszynowego .....</b>	<b>725</b>
<b>C Problem dualny w maszynach wektorów nośnych .....</b>	<b>731</b>
<b>D Różniczkowanie automatyczne .....</b>	<b>735</b>
<b>E Inne popularne architektury sieci neuronowych .....</b>	<b>743</b>
<b>F Specjalne struktury danych .....</b>	<b>751</b>
<b>G Grafy TensorFlow .....</b>	<b>757</b>