


# DEEP LEARNING

PRAKTYCZNE WPROWADZENIE  
Z ZASTOSOWANIEM ŚRODOWISKA PYTHONA

RONALD T. KNEUSEL



Helion 



Tytuł oryginału: Practical Deep Learning A Python-Based Introduction

Tłumaczenie: Krzysztof Sawka

ISBN: 978-83-283-8859-8

Copyright © 2021 by Ronald T. Kneusel. Title of English-language original: Practical Deep Learning: A Python-Based Introduction, ISBN 9781718500747, published by No Starch Press Inc. 245 8th Street, San Francisco, California United States 94103. The Polish-language edition Copyright © 2022 by Helion S.A. under license by No Starch Press Inc. All rights reserved.

The following images are reproduced with permission. Figure 4-2: the middle image is licensed under the Creative Commons Attribution 2.0 Generic license ([https://commons.wikimedia.org/wiki/File:Border\\_Collie\\_liver\\_portrait.jpg](https://commons.wikimedia.org/wiki/File:Border_Collie_liver_portrait.jpg)) and the right image is licensed under the Creative Commons Attribution-Share Alike 3.0 Unported license ([https://commons.wikimedia.org/wiki/File:Lynn-red\\_merle\\_Aussie\\_12\\_Months.jpg](https://commons.wikimedia.org/wiki/File:Lynn-red_merle_Aussie_12_Months.jpg)).

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.

Wszystkie znaki występujące w tekście są zastrzeżonymi znakami firmowymi bądź towarowymi ich właścicieli.

Autor oraz wydawca 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 wydawca 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

<https://helion.pl/user/opinie/delepw>

Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:

<https://ftp.helion.pl/przyklady/delepw.zip>

Helion S.A.

ul. Kościuszki 1c, 44-100 Gliwice

tel. 32 231 22 19, 32 230 98 63

e-mail: [helion@helion.pl](mailto:helion@helion.pl)

WWW: <https://helion.pl> (księgarnia internetowa, katalog książek)

Printed in Poland.

- Kup książkę
- Poleć książkę
- Oceń książkę

- Księgarnia internetowa
- Lubię to! » Nasza społeczność

# Spis treści

<b>PRZEDMOWA</b> .....	<b>13</b>
<b>PODZIĘKOWANIA</b> .....	<b>16</b>
<b>WSTĘP</b> .....	<b>17</b>
<b>1</b>	
<b>PIERWSZE KROKI</b> .....	<b>24</b>
Środowisko operacyjne .....	24
NumPy .....	25
scikit-learn .....	25
Keras i TensorFlow .....	25
Instalacja narzędzi .....	26
Podstawy algebry liniowej .....	27
Wektory .....	27
Macierze .....	28
Mnożenie wektorów i macierzy .....	28
Statystyka i prawdopodobieństwo .....	30
Statystyka opisowa .....	30
Rozkłady prawdopodobieństwa .....	31
Testy statystyczne .....	32
Procesory graficzne (GPU) .....	33
Podsumowanie .....	33
<b>2</b>	
<b>KORZYSTANIE Z PYTHONA</b> .....	<b>34</b>
Interpreter Pythona .....	34
Instrukcje i białe znaki .....	35
Zmienne i podstawowe struktury danych .....	36
Przedstawianie liczb .....	37
Zmienne .....	37
łańcuchy znaków .....	38
Listy .....	38
Słowniki .....	42

Struktury sterowania .....	43
Instrukcje if-elif-else .....	43
Pętle for .....	44
Pętle while .....	46
Instrukcje break i continue .....	47
Instrukcja with .....	48
Obsługa błędów za pomocą bloków try-except .....	48
Funkcje .....	49
Moduły .....	51
Podsumowanie .....	53
<b>3</b>	
<b>BIBLIOTEKA NUMPY .....</b>	<b>54</b>
Dlaczego NumPy? .....	54
Tablice a listy .....	55
Testowanie szybkości tablic i list .....	56
Podstawowe tablice .....	58
Definiowanie tablicy za pomocą funkcji, np. array .....	59
Definiowanie tablic wypełnionych zerami i jedynekami .....	62
Dostęp do elementów tablicy .....	64
Indeksowanie tablicowe .....	64
Uzyskiwanie wycinków tablicy .....	65
Wielokropek .....	68
Operatory i rozgłaszanie .....	69
Dane wejściowe i wyjściowe tablic .....	72
Liczby losowe .....	75
Biblioteka NumPy i obrazy .....	76
Podsumowanie .....	78
<b>4</b>	
<b>PRACA Z DANYMI .....</b>	<b>79</b>
Klasy i etykiety .....	79
Cechy i wektory cech .....	80
Rodzaje cech .....	81
Dobór cech i kłątwa wymiarowości .....	83
Własności dobrego zestawu danych .....	86
Interpolacja i ekstrapolacja .....	86
Główny rozkład prawdopodobieństwa .....	89
Rozkład a priori .....	89
Przykłady mylące .....	90
Rozmiar zestawu danych .....	91
Przygotowanie danych .....	92
Skalowanie cech .....	92
Brakujące cechy .....	97

Dane uczące, walidacyjne i testowe .....	98
Trzy podzbiory .....	98
Dzielenie zestawu danych .....	99
k-krotny sprawdzian krzyżowy .....	105
Analiza danych .....	107
Wyszukiwanie problemów z danymi .....	107
Opowieści ku przestrodze .....	112
Podsumowanie .....	113
<b>5</b>	
<b>BUDOWANIE ZESTAWÓW DANYCH .....</b>	<b>114</b>
Kosańce (zestaw danych Iris) .....	114
Nowotwory piersi (zestaw danych Breast Cancer) .....	117
Cyfry zapisane pismem odręcznym (zestaw danych MNIST) .....	119
Różne obrazy (zestaw danych CIFAR-10) .....	122
Rozszerzanie danych .....	124
Dlaczego należy rozszerzać dane uczące? .....	125
Sposoby rozszerzania danych .....	126
Rozszerzanie zestawu danych Iris .....	127
Rozszerzanie zestawu danych CIFAR-10 .....	133
Podsumowanie .....	138
<b>6</b>	
<b>KLASYCZNE UCZENIE MASZYNOWE .....</b>	<b>139</b>
Algorytm najbliższego centroidu .....	140
Algorytm k najbliższych sąsiadów .....	144
Naiwny klasyfikator Bayesa .....	146
Drzewa decyzyjne i lasy losowe .....	150
Rekurencja .....	153
Budowanie drzew decyzyjnych .....	154
Lasy losowe .....	155
Maszyny wektorów nośnych .....	157
Marginesy .....	157
Wektory nośne .....	159
Optymalizacja .....	160
Jądra .....	160
Podsumowanie .....	161
<b>7</b>	
<b>EKSPERYMENTOWANIE Z KLASYCZNYMI MODELAMI .....</b>	<b>162</b>
Eksperymenty z użyciem zestawu danych Iris .....	162
Testowanie klasycznych modeli .....	163
Implementacja klasyfikatora najbliższego centroidu .....	167

Eksperymenty z użyciem zestawu danych Breast Cancer .....	168
Dwa pierwsze przebiegi testowe .....	169
Skutek losowych podziałów .....	172
Dodawanie k-krotnego sprawdzianu krzyżowego .....	174
Poszukiwanie hiperparametrów .....	179
Eksperymenty z użyciem zestawu danych MNIST .....	185
Testowanie klasycznych modeli .....	185
Analiza czasu działania .....	192
Eksperymenty z głównymi składowymi analizy PCA .....	195
Tasowanie zestawu danych .....	197
Podsumowanie klasycznych modeli .....	199
Algorytm najbliższego centroidu .....	199
Algorytm k najbliższych sąsiadów .....	200
Naiwny klasyfikator Bayesa .....	200
Drzewa decyzyjne .....	201
Lasy losowe .....	201
Maszyny wektorów nośnych .....	202
Kiedy używać klasycznych modeli? .....	202
Korzystanie z małych zestawów danych .....	202
Ograniczone zasoby obliczeniowe .....	203
Dostęp do wyjaśnialnych modeli .....	203
Praca z danymi wektorowymi .....	203
Podsumowanie .....	204

## 8

<b>WPROWADZENIE DO SIECI NEURONOWYCH .....</b>	<b>205</b>
Anatomia sieci neuronowej .....	206
Neuron .....	207
Funkcje aktywacji .....	208
Architektura sieci .....	212
Warstwy wyjściowe .....	214
Wagi i obciążenia .....	216
Implementacja prostej sieci neuronowej .....	217
Przygotowanie zestawu danych .....	217
Implementacja sieci neuronowej .....	219
Uczenie i testowanie sieci neuronowej .....	221
Podsumowanie .....	223

## 9

<b>UCZENIE SIECI NEURONOWEJ .....</b>	<b>224</b>
Ogólny opis .....	224
Algorytm gradientu prostego .....	225
Wyszukiwanie minimów .....	227
Aktualizowanie wag .....	229

Stochastyczny spadek wzdłuż gradientu .....	230
Grupy i minigrupy .....	230
Funkcje wypukłe i niewypukłe .....	232
Kończenie uczenia .....	233
Aktualizowanie współczynnika uczenia .....	234
Momentum .....	235
Propagacja wsteczna .....	235
Propagacja wsteczna — ujęcie pierwsze .....	236
Propagacja wsteczna — ujęcie drugie .....	240
Funkcje straty .....	243
Błąd bezwzględny i błąd średniokwadratowy .....	244
Entropia krzyżowa .....	245
Inicjalizowanie wag .....	246
Przetrenowanie i regularyzacja .....	248
Przetrenowanie .....	248
Regularyzacja .....	251
Regularyzacja L2 .....	251
Porzucanie .....	253
Podsumowanie .....	255

## 10

### **EKSPERYMENTOWANIE Z SIECIAMI NEURONOWYMI .....257**

Nasz zestaw danych .....	257
Klasa MLPClassifier .....	258
Struktura sieci i funkcje aktywacji .....	259
Kod .....	259
Wyniki .....	263
Rozmiar grupy .....	267
Podstawowy współczynnik uczenia .....	271
Rozmiar zbioru uczącego .....	274
Regularyzacja L2 .....	275
Momentum .....	278
Inicjalizacja wag .....	279
Kolejność cech .....	284
Podsumowanie .....	286

## 11

### **OCENIANIE MODELI .....287**

Definicje i założenia .....	287
Dlaczego dokładność jest niewystarczająca? .....	288
Macierz pomyłek 2×2 .....	290
Wskaźniki wyprowadzane z macierzy pomyłek .....	293
Wyprowadzanie wskaźników na podstawie macierzy pomyłek .....	294
Interpretowanie modeli za pomocą wskaźników .....	297

Zaawansowane wskaźniki .....	299
Informatywność i nacechowanie .....	300
Wskaźnik F1 .....	300
Współczynnik kappa Cohena .....	301
Współczynnik korelacji Matthews'a .....	302
Implementacja zaawansowanych wskaźników .....	302
Krzywa charakterystyki operacyjnej odbiornika .....	304
Dobór modeli .....	304
Rysowanie wykresu wskaźników .....	306
Analiza krzywej ROC .....	307
Porównywanie modeli za pomocą analizy ROC .....	310
Generowanie krzywej ROC .....	312
Krzywa precyzji-czułości .....	314
Przypadki wieloklasowe .....	315
Rozszerzanie macierzy pomyłek .....	315
Obliczanie dokładności ważonej .....	318
Wieloklasowy współczynnik korelacji Matthews'a .....	321
Podsumowanie .....	322
<b>12</b>	
<b>WPROWADZENIE DO SPLOTOWYCH SIECI NEURONOWYCH .....</b>	<b>323</b>
Dlaczego splotowe sieci neuronowe? .....	324
Splot .....	325
Skanowanie za pomocą jądra .....	325
Splot w przetwarzaniu obrazów .....	328
Anatomia splotowej sieci neuronowej .....	329
Różne typy warstw .....	330
Przepuszczanie danych przez sieć splotową .....	332
Warstwy splotowe .....	333
Mechanizm działania warstwy splotowej .....	333
Korzystanie z warstwy splotowej .....	336
Wielokrotne warstwy splotowe .....	339
Inicjalizacja warstwy splotowej .....	340
Warstwy łączące .....	340
Warstwy w pełni połączone .....	343
Pełne warstwy splotowe .....	344
Krok po kroku .....	346
Podsumowanie .....	349
<b>13</b>	
<b>EKSPERYMENTOWANIE Z BIBLIOTEKĄ KERAS I ZESTAWEM DANYCH MNIST .....</b>	<b>351</b>
Budowanie sieci splotowych w bibliotece Keras .....	352
Wczytywanie danych MNIST .....	352
Budowanie modelu .....	354



Uczenie i ocena modelu .....	356
Tworzenie wykresu funkcji błędu .....	358
Podstawowe eksperymenty .....	360
Eksperymenty na architekturze .....	361
Rozmiar zbioru uczącego, minigrup oraz liczba epok .....	365
Optymalizatory .....	369
Pełne sieci splotowe .....	371
Budowa i trenowanie modelu .....	371
Przygotowanie obrazów testowych .....	374
Testowanie modelu .....	375
Potasowane cyfry MNIST .....	383
Podsumowanie .....	384
<b>14</b>	
<b>EKSPERYMENTOWANIE Z ZESTAWEM DANYCH CIFAR-10 .....</b>	<b>386</b>
Zestaw CIFAR-10 — przypomnienie .....	386
Praca na pełnym zestawie CIFAR-10 .....	387
Budowanie modeli .....	388
Analizowanie modeli .....	392
Zwierzę czy pojazd? .....	395
Model binarny czy wieloklasowy? .....	400
Uczenie transferowe .....	405
Strojenie modelu .....	411
Przygotowanie zestawów danych .....	412
Dostosowanie modelu do strojenia .....	415
Testowanie modelu .....	418
Podsumowanie .....	420
<b>15</b>	
<b>STUDIUM PRZYPADKU: KLASYFIKOWANIE PRÓBEK DŹWIĘKOWYCH .....</b>	<b>421</b>
Budowanie zestawu danych .....	422
Rozszerzanie zestawu danych .....	423
Wstępne przetwarzanie danych .....	427
Klasyfikowanie cech dźwiękowych .....	430
Modele klasyczne .....	430
Tradycyjna sieć neuronowa .....	432
Splotowa sieć neuronowa .....	433
Spektrogramy .....	439
Klasyfikowanie spektrogramów .....	443
Inicjalizacja, regularyzacja i normalizacja wsadowa .....	445
Analiza macierzy pomyłek .....	448
Zespoły .....	449
Podsumowanie .....	454

<b>16</b>	
<b>DALSZE KROKI .....</b>	<b>456</b>
Co dalej z sieciami splotowymi? .....	456
Uczenie przez wzmacnianie i uczenie nienadzorowane .....	457
Generatywne sieci przeciwstawne .....	458
Rekurencyjne sieci neuronowe .....	459
Zasoby internetowe .....	459
Konferencje .....	460
Książka .....	462
Cześć i dzięki za ryby .....	462
<b>SKOROWIDZ .....</b>	<b>463</b>



# 1

## Pierwsze kroki



ROZDZIAŁ TEN STANOWI WPROWADZENIE DO NASZEGO ŚRODOWISKA OPERACYJNEGO ORAZ ZAWIERA SZCZEGÓŁY JEGO KONFIGURACJI. ZNAJDZIESZ TU TAKŻE POWTÓRZENIE PEWNYCH ELEMENTÓW MATEMATYKI, z których będziemy korzystać w dalszej części książki. Ostatni podrozdział został poświęcony krótkiemu omówieniu procesorów graficznych (ang. graphic processing unit — GPU), które mają duże znaczenie w uczeniu głębokim. Na szczęście w naszym przypadku nie odgrywają istotnej roli, dlatego nie musisz się martwić; korzystanie z tej książki nie będzie wiązało się z niespodziewanymi olbrzymimi kosztami.

### Środowisko operacyjne

W tym podrozdziale zajmiemy się opisem środowiska, z którego będziemy korzystać aż do końca książki. Zakładamy tu, że używasz 64-bitowego Linuksa. Rodzaj dystrybucji nie jest zbyt istotny, ale żeby dodatkowo ułatwić wybór, przyjmijmy także, że korzystamy z Linuksa Ubuntu 20.04. Mając na uwadze znakomite wsparcie dystrybucji Ubuntu, uważamy, że nowsza wersja nie powinna powodować problemów. Python jest naszym *lingua franca*, powszechnym językiem uczenia maszynowego. Dokładniej mówiąc, będziemy używać Pythona w wersji 3.8.2; jest to wersja dostępna w Ubuntu 20.04.

Przyjrzyjmy się pokrótce używanym przez nas narzędziom Pythona.

## NumPy

**NumPy** jest biblioteką Pythona dodającą do środowiska przetwarzanie tablicowe. Listy Pythona można wykorzystywać jako jednowymiarowe tablice, jednak w praktyce są zbyt powolne i ograniczone. Biblioteka NumPy dodaje funkcje tablicowe, których brakuje Pythonowi; są one niezbędne w wielu zastosowaniach naukowych. NumPy stanowi bibliotekę bazową wykorzystywaną przez wszystkie pozostałe biblioteki, z których będziemy korzystać.

## scikit-learn

Wszystkie omówione w tej książce tradycyjne modele uczenia maszynowego dostępne są w znakomitej bibliotece **scikit-learn** (czyli `sklearn`, jak jest nazywana po wczytaniu do Pythona). Zwróć uwagę, że zapis nazwy pozbawiony jest dużych liter, gdyż takiej właśnie notacji używają konsekwentnie sami twórcy w dokumentacji biblioteki. Biblioteka ta wykorzystuje tablice NumPy. Implementuje ona interfejs ustandaryzowany dla wielu różnych modeli uczenia maszynowego, a także całe mnóstwo funkcji, o których nie zdążę nawet wspomnieć. Bardzo polecam zapoznanie się z oficjalną dokumentacją `sklearn` (<https://scikit-learn.org/stable/index.html>) w miarę ustawicznego zapoznawania się z uczeniem maszynowym i narzędziami służącymi do projektowania modeli.

## Keras i TensorFlow

Samo w sobie zrozumienie uczenia głębokiego nie jest łatwe, nie wspominając nawet o jego wydajnej oraz poprawnej implementacji, dlatego zamiast próbować rozpisywać od podstaw splotową sieć neuronową, skorzystamy z popularnego, aktywnie rozwijanego narzędzia. Od samego początku społeczność uczenia głębokiego wspiera rozwój narzędzi ułatwiających korzystanie z sieci głębokich i udostępnia otwarte narzędzia objęte bardzo przyjaznymi licencjami. W czasie pisania tej książki dostępnych jest wiele popularnych narzędzi przygotowanych z myślą o Pythonie. Są to między innymi:

- Keras,
- PyTorch,
- Caffe,
- Caffe2,
- Apache MXnet.

Niektóre z tych narzędzi są prężnie rozwijane, o innych stopniowo zapominamy. Obecnie jednak jednym z mających najbardziej oddaną społeczność jest biblioteka Keras, wykorzystująca z kolei bibliotekę TensorFlow, dlatego będziemy z niej korzystać w tej książce.

**Keras** (<https://keras.io/>) jest biblioteką uczenia głębokiego wykorzystującą do działania bibliotekę **TensorFlow** (<https://www.tensorflow.org/>). Z kolei TensorFlow to otwarty produkt firmy Google, implementujący kluczowe funkcje głębokich sieci neuronowych na wielu różnych platformach. Wybraliśmy bibliotekę

Keras nie tylko z powodu popularności i błyskawicznego rozwoju, lecz także dlatego, że jest prosta w obsłudze. Naszym celem jest zrozumienie uczenia głębokiego w stopniu umożliwiającym implementowanie modeli, a następnie korzystanie z nich przy minimum złożoności programistycznej.

## Instalacja narzędzi

Nie jesteśmy w stanie opisać procesu instalacji narzędzi na wszystkich systemach operacyjnych i na wszystkich konfiguracjach sprzętowych. Zamiast tego zaprezentujemy instrukcje opisujące krok po kroku proces instalacji dla określonego systemu operacyjnego będącego naszym systemem referencyjnym. Etapy te, wraz z minimalnymi wymaganymi wersjami bibliotek, powinny wystarczyć większości czytelników do przygotowania działającego środowiska roboczego.

Pamiętaj, że zakładamy pracę w środowisku linuxowym, dokładniej w dystrybucji Ubuntu 20.04. Ubuntu jest szeroko rozpowszechnioną dystrybucją Linuksa i działa na niemal każdym nowym komputerze. Inne dystrybucje Linuksa również sprawdzą się jako środowisko pracy, podobnie jak system macOS, ale podane tu instrukcje są przeznaczone dla dystrybucji Ubuntu. Społeczność uczenia maszynowego raczej nie korzysta z systemu Windows. Istnieją jednak narzędzia przystosowane do tego systemu; zatem odważny czytelnik może spróbować także tam swych sił<sup>1</sup>.

Świeżo zainstalowana dystrybucja Ubuntu 20.04 zawiera domyślnie środowisko Python 3.8.2. W celu zainstalowania pozostałych pakietów musimy wejść do powłoki i wpisać poniższe polecenia w podanej kolejności:

---

```
$ sudo apt-get update
$ sudo apt-get install python3-pip
$ sudo apt-get install build-essential python3-dev
$ sudo apt-get install python3-setuptools python3-numpy
$ sudo apt-get install python3-scipy libatlas-base-dev
$ sudo apt-get install python3-matplotlib
$ pip3 install scikit-learn
$ pip3 install tensorflow
$ pip3 install pillow
$ pip3 install h5py
$ pip3 install keras
```

---

Po zakończeniu instalacji będziemy dysponować następującymi wersjami narzędzi i bibliotek:

---

<sup>1</sup> Nie jest to do końca prawda. System Windows jest dobrze wspierany pod względem środowiska Python i bibliotek uczenia maszynowego. Osoby zainteresowane mogą chcieć zainstalować środowisko **Anaconda**, a następnie dołączyć wymagane biblioteki; opisane w książce przykłady działają zarówno w Linuksie, jak i w systemie Windows — *przyp. tłum.*

---

```
NumPy 1.17.4
sklearn 0.23.2
keras 2.4.3
tensorflow 2.2.0
pillow 7.0.0
h5py 2.10.0
matplotlib 3.1.2
```

---

Biblioteka `pillow` służy do przetwarzania obrazów, `h5py` pozwala na pracę z plikami w formacie `HDF5`, natomiast `matplotlib` umożliwia tworzenie wykresów. `HDF5` to ogólny, hierarchiczny format plików służący do przechowywania danych naukowych. Biblioteka `Keras` przechowuje w tym formacie parametry modelu.

W dwóch następnych podrozdziałach znajdziesz łagodne wprowadzenie do pewnych pojęć matematycznych spotykanych w dalszej części książki.

## Podstawy algebry liniowej

Przyjrzyjmy się teraz wektorom i macierzom. Opisujący te twory dział matematyki nazywany jest **algebrą liniową** lub teorią macierzy. Jak można się domyślić, algebra liniowa jest całkiem skomplikowaną dziedziną. Nam wystarczy wiedzieć, czym jest wektor oraz macierz, a także jak mnożymy dwa wektory, dwie macierze lub wektor przez macierz. Przekonamy się później, że dzięki temu uzyskujemy bardzo przydatny mechanizm implementowania określonych modeli, zwłaszcza sieci neuronowych.

Zacznijmy od wektorów.

### Wektory

**Wektor** (ang. *vector*) jest jednowymiarową listą wartości liczbowych. W ujęciu matematycznym może przybierać on następującą postać:

$$a = [0,1,2,3,4]$$

Trzeci element jest zapisywany jako  $a_2 = 2$ . Zwróć uwagę, że korzystamy z konwencji programistycznej, zgodnie z którą indeksy wyznaczamy od wartości 0, zatem  $a_2$  daje nam trzeci element wektora.

Powyższy wektor zapisaliśmy poziomo, dlatego nazywamy go **wektorem wierszowym** (ang. *row vector*). Jednak wektory stosowane w wyrażeniach matematycznych zazwyczaj są zapisywane w pionie:

$$a = \begin{bmatrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \end{bmatrix}$$

Wektor zapisywany w pionie nazywany jest **wektorem kolumnowym** (ang. *column vector*). W naszym przykładzie zawiera on pięć elementów, dlatego mówimy, że jest pięcioelementowym wektorem kolumnowym. W tej książce wektor symbolizuje pojedynczą **próbę** (ang. *sample*), czyli jeden zestaw cech wprowadzanych na wejściu modelu.

W ujęciu matematycznym wektory służą do reprezentowania punktów w przestrzeni. Jeżeli weźmiemy dwuwymiarową płaszczyznę kartezjańską, to wyznaczamy położenie danego punktu za pomocą dwuelementowego wektora  $(x, y)$ , gdzie  $x$  stanowi odległość wzdłuż osi  $x$ , natomiast  $y$  jest odległością wzdłuż osi  $y$ . Wektor taki określa punkt w dwóch wymiarach, mimo że sam jest jednowymiarowy. Gdybyśmy mieli punkt w trzech wymiarach, musielibyśmy użyć wektora trójelementowego  $(x, y, z)$ .

W uczeniu maszynowym wektory służą często do symbolizowania sygnałów wejściowych do modelu, dlatego pracujemy z dziesiątkami, a nawet setkami wymiarów. Oczywiście nie jesteśmy w stanie zaznaczać ich na wykresie jako punktów w przestrzeni, ale tym właśnie są w ujęciu matematycznym. Jak się przekonamy, niektóre modele, na przykład algorytm  $k$  najbliższych sąsiadów, wykorzystują wektory cech właśnie jako punkty w wielowymiarowej przestrzeni.

## Macierze

**Macierz** (ang. *matrix*) jest dwuwymiarową tablicą zawierającą wartości liczbowe, w której dany element określamy za pomocą numeru wiersza i kolumny. Poniżej widzimy przykładową macierz:

$$a = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix}$$

Jeżeli odnosimy się do liczby 6, to zapisujemy  $a_{1,2} = 6$ . Ponownie indeksujemy tu od wartości 0. Macierz  $a$  zawiera po trzy wiersze i kolumny, dlatego nazywamy ją macierzą  $3 \times 3$ .

## Mnożenie wektorów i macierzy

Mnożenie dwóch wektorów jest niezmiernie proste; wystarczy pomnożyć elementy znajdujące się na tych samych pozycjach. Na przykład:

$$[1,2,3] \cdot [4,5,6] = [4,10,18]$$

Jest to najczęściej spotykany sposób mnożenia tablicy podczas używania biblioteki NumPy i będziemy z niego bardzo często korzystać w kolejnych rozdziałach. Jednak w typowej matematyce nie jest on zbyt często używany.

W przypadku klasycznie matematycznego iloczynu wektorów musimy brać pod uwagę fakt, czy są one wierszowe, czy kolumnowe. Będziemy pracować na dwóch wektorach:  $A = (a, b, c)$  i  $B = (d, e, f)$ , które, zgodnie z przyjętą matematyczną konwencją, są domyślnie kolumnowe. Dodanie indeksu górnego  $T$



przekształca wektor kolumnowy w wierszowy. Matematycznie dopuszczalnymi sposobami mnożenia  $A$  i  $B$  są:

$$AB^T = \begin{bmatrix} a \\ b \\ c \end{bmatrix} [d \quad e \quad f] = \begin{bmatrix} ad & ae & af \\ bd & be & bf \\ cd & ce & cf \end{bmatrix}$$

Operacja ta nazywana jest **iloczynem zewnętrznym** (ang. *outer product*). Z kolei operacja

$$A^T B = [a \quad b \quad c] \begin{bmatrix} d \\ e \\ f \end{bmatrix} = ad + be + cf$$

jest **iloczynem wewnętrznym** (ang. *inner product*), znanym także jako **iloczyn skalarny** (ang. *dot product*). Zwróć uwagę, że w wyniku iloczynu zewnętrznego otrzymujemy macierz, a rezultatem iloczynu wewnętrznego jest pojedyncza liczba (**skalar**).

Podczas mnożenia macierzy i wektora ten drugi zazwyczaj znajduje się po prawej stronie macierzy. Operację można przeprowadzić tylko wtedy, gdy liczba kolumn macierzy jest równa liczbie elementów wektora (który również w tym przypadku powinien być kolumnowy). W konsekwencji otrzymujemy wektor o liczbie elementów równej liczbie wierszy macierzy ( $ax + by + cz$  jest jednym elementem).

Na przykład:

$$\begin{bmatrix} a & b & c \\ d & e & f \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} ax + by + cz \\ dx + ey + fz \end{bmatrix}$$

Pomnożyliśmy tu macierz  $2 \times 3$  przez wektor kolumnowy  $3 \times 1$ , dzięki czemu otrzymaliśmy wektor  $2 \times 1$ . Zwróć uwagę, że liczba kolumn macierzy i wierszy wektora musi być taka sama, w przeciwnym razie nie można wykonać operacji mnożenia. Ponadto wartości w wektorze wynikowym są sumami iloczynów macierzy i wektora. Ta sama reguła dotyczy iloczynu dwóch macierzy:

$$\begin{bmatrix} a & b & c \\ d & e & f \end{bmatrix} \begin{bmatrix} A & B \\ C & D \\ E & F \end{bmatrix} = \begin{bmatrix} aA + bC + cE & aB + bD + cF \\ aA + eC + fE & dB + eD + fF \end{bmatrix}$$

Iloczyn macierzy  $2 \times 3$  przez macierz  $3 \times 2$  dał nam macierz  $2 \times 2$ .

Podczas omawiania sieci spłotowych będziemy pracować z tablicami trój-, a nawet czterowymiarowymi. Obiekty takie są nazywane **tensorami** (ang. *tensor*). Jeśli wyobrazisz sobie stos macierzy mających takie same rozmiary, otrzymasz tensor trójwymiarowy; w takim przypadku pierwszy indeks służy do określenia interesującej nas macierzy, a za pomocą dwóch pozostałych wyznaczamy interesujący nas element tejże macierzy. Z kolei jeżeli ułożysz stos trójwymiarowych tensorów,

to otrzymasz tensor czterowymiarowy, w którym pierwszy indeks wyznacza interesujący nas tensor trójwymiarowy.

Główne wnioski z tego podrozdziału są takie, że wektory mają jeden wymiar, macierze mają dwa wymiary, istnieją pewne reguły mnożenia tych obiektów, a także że nasze biblioteki będą korzystać w pewnym momencie z czterowymiarowych tensorów. Jeszcze wrócimy do tych wniosków w dalszej części książki.

## Statystyka i prawdopodobieństwo

Działy statystyki i probabilistyki są tak rozległe, że często można jedynie wspomnieć o nich zaledwie kilka słów albo od razu napisać poświęconą im całą książkę czy dwie. Z tego powodu wspomnę tu jedynie o niektórych kluczowych aspektach i pozostawię Ci dokończanie się w tych tematach zależnie od Twoich potrzeb. Zakładam, że na podstawie rzutów monetą i kostką pozyskałeś pewną elementarną wiedzę na temat prawdopodobieństwa.

### Statystyka opisowa

Podczas przeprowadzania eksperymentów musimy zgłaszać wyniki w jakiś znaczący sposób. W naszym przypadku oznacza to zazwyczaj określanie wartości średniej plus minus wartość znana jako **błąd standardowy średniej** (ang. *standard error of the mean* — *SE*). Zdefiniujmy ten błąd na przykładzie.

W przypadku dużej liczby pomiarów  $x$ , na przykład długości określonej części kwiatu, możemy obliczyć średnią ( $\bar{x}$ ) przez dodanie wszystkich wartości i podzielenie tej sumy przez liczbę wszystkich dodanych wartości. Po otrzymaniu średniej możemy obliczyć średnią rozpiętość poszczególnych wartości wokół średniej poprzez odjęcie każdej wartości od średniej, podniesienie wyniku do kwadratu, a następnie zsumowanie tak otrzymanych wartości i podzielenie otrzymanej sumy przez liczbę elementów minus jeden. W ten sposób uzyskujemy **wariancję** (ang. *variance*). Pierwiastek kwadratowy z wariancji nazywany jest **odchyleniem standardowym** ( $\sigma$ , ang. *standard deviation*), do którego powrócimy za chwilę. Za pomocą odchylenia standardowego możemy policzyć błąd standardowy jako  $SE = \sigma/\sqrt{n}$ , gdzie  $n$  jest liczbą wartości użytych do obliczenia średniej. Im mniejsza jest wartość  $SE$ , tym wartości są ściślej upakowane wokół średniej. Możemy interpretować tę wartość jako niepewność dotyczącą średniej. Zgodnie z nią przewidujemy, że rzeczywista wartość średnia (której nie znamy) mieści się w przedziale między  $\bar{x} - SE$  a  $\bar{x} + SE$ .

Czasami zastępujemy średnią medianą. **Mediana** (ang. *median*) jest wartością środkową, poniżej której znajduje się dokładnie połowa prób. Aby określić medianę danego zestawu wartości, najpierw sortujemy je numerycznie, a następnie wyznaczamy wartość środkową. W przypadku nieparzystej liczby elementów próby wartość tę wyznacza środkowy element, natomiast jeżeli mamy parzystą liczbę elementów, medianą jest wartość średnia między dwoma środkowymi elementami. Mediana czasami okazuje się lepsza od średniej, jeżeli próby nie mają

dobrego, równomiernego rozrzutu wokół średniej. Klasycznym przykładem są dochody. Kilka najbogatszych osób tak przesuwają średnią do góry, że przestaje ona mieć większe znaczenie. Rozsądniejszym rozwiązaniem okazuje się mediana, która ukazuje jedną połowę osób zarabiających mniej i drugą zawierającą ludzi o wyższych dochodach.

W późniejszych rozdziałach będziemy zajmować się **statystyką opisową** (ang. *descriptive statistics*). Są to wartości obliczone dla zestawu danych, pomagające zrozumieć jego własności. Przed chwilą wymieniałem trzy takie wartości: średnią, medianę i odchylenie standardowe. Nauczmy się je interpretować i zaznaczać na wykresach w celu lepszego zrozumienia zestawów danych.

## Rozkłady prawdopodobieństwa

W tej książce będziemy korzystać z pojęcia **rozkładu prawdopodobieństwa** (ang. *probability distribution*). Można traktować go jako swoistą wyrocznię, która, zapytana, przepowie jakąś liczbę lub zbiór liczb. Na przykład podczas uczenia modelu korzystamy z liczb lub zbiorów liczb, które mierzymy; liczby te biorą się z danego rozkładu prawdopodobieństwa. Jest to tak zwany **rozkład główny** (ang. *parent distribution*). Możemy traktować go jako generator danych dostarczanych do modelu; w bardziej filozoficznym ujęciu jest to idealny zestaw danych, którego przybliżenie stanowią nasze dane.

Istnieje wiele różnych rozkładów prawdopodobieństwa; niektóre z nich mają nawet własne nazwy. Dwoma najpowszechniejszymi są rozkład jednostajny i normalny. Niewątpliwie miałeś już do czynienia z rozkładem jednostajnym: ma on miejsce podczas rzucania kostką do gry. Skoro kostka ma sześć ścian, to wiemy, że prawdopodobieństwo wyrzucenia dowolnej wartości od 1 do 6 jest jednakowe. Jeżeli rzucimy kostką sto razy i spisujemy otrzymywane wyniki, to zauważymy, że każdy numer został wyrzucony w przybliżeniu jednakową liczbę razy oraz że na dłuższą metę łatwo uwierzyć, że wartości te się wyrównają.

**Rozkład jednostajny** (ang. *uniform distribution*) jest wyrocznią, która z jednakowym prawdopodobieństwem może udzielić nam każdej z dopuszczalnych odpowiedzi. W ujęciu matematycznym zapisujemy go jako  $U(a, b)$ , gdzie litera  $U$  oznacza rozkład jednostajny (od ang. *uniform*), natomiast  $a$  i  $b$  wyznaczają zakres wartości losowanych z tego rozkładu. Dopuszczalne są liczby rzeczywiste, chyba że jawnie wymusimy losowanie wyłącznie liczb całkowitych. Symbolicznie zapisujemy  $x \sim U(0, 1)$ , co oznacza, że  $x$  jest wartością zwracaną przez wyrocznię losującą z jednakowym prawdopodobieństwem dane z zakresu liczb rzeczywistych w przedziale  $(0, 1)$ . Nawiasy otwarte („(” i „)”) przy oznaczaniu przedziałów oznaczają przedział otwarty, czyli taki, w którym wartości graniczne są wykluczone z przedziału, natomiast nawiasy zamknięte („[” i „]”) wyznaczają przedział domknięty, uwzględniający w przedziale wartość graniczną oznaczoną takim nawiasem. Zatem  $U[0, 1)$  zwraca wartości w przedziale od 0 do 1, gdzie wartość 0 jest uwzględniona w przedziale, natomiast wartość 1 zostaje pominięta.

Wykres **rozkładu normalnego** (ang. *normal distribution*), zwanego także **rozkładem Gaussa** (ang. *Gaussian distribution*) przybiera kształt dzwonowaty; w takim

przypadku jedna wartość ma największe prawdopodobieństwo wystąpienia, natomiast prawdopodobieństwo wystąpienia innych wartości maleje wraz z oddalaniem się od tego punktu. Najbardziej prawdopodobną wartością jest średnia  $\bar{x}$ , natomiast parametrem określającym szybkość redukcji prawdopodobieństwa do zera (które jednak zawsze pozostaje niezerowe) jest odchylenie standardowe  $\sigma$  (sigma). W naszym przypadku jeżeli chcemy losować próbę z rozkładu normalnego, zapiszemy  $x \sim N(\bar{x}, \sigma)$ , co oznacza, że  $x$  jest losowana z rozkładu normalnego o średniej  $\bar{x}$  i odchyleniu standardowym  $\sigma$ .

## Testy statystyczne

Kolejnym zagadnieniem, które będzie pojawiać się od czasu do czasu, jest koncepcja **testu statystycznego** (ang. *statistical test*), czyli pomiaru służącego do określania prawdziwości danej hipotezy. Zazwyczaj hipoteza odnosi się do zbiorów pomiarów; mianowicie hipoteza zakłada, że dwa zbiory pomiarów wywodzą się z tego samego rozkładu głównego. Jeżeli statystyka obliczona na podstawie testu wykracza poza pewien określony zakres, to odrzucamy hipotezę i stwierdzamy, że mamy dowód na pochodzenie obydwu zestawów danych z dwóch *różnych* rozkładów.

Tutaj będziemy zazwyczaj używać **testu t**, powszechnego testu statystycznego, w którym przyjmujemy rozkład normalny danych. Skoro zakładamy, że rozkład danych jest normalny, co może, ale nie musi być prawdą, to test ten nazywamy **testem parametrycznym** (ang. *parametric test*).

Czasami będziemy korzystać z **testu U Manna-Whitneya**, który przypomina test t, gdyż pomaga określić, czy dane dwie próby pochodzą z tego samego rozkładu głównego, nie zakładamy tu jednak odgórnie określonego rozkładu danych. Jest to przykład **testu nieparametrycznego** (ang. *nonparametric test*).

Bez względu na to, czy test jest parametryczny, czy nieparametryczny, zawsze otrzymujemy ostatecznie tak zwaną **wartość p** (ang. *p-value*). Stanowi ona prawdopodobieństwo wystąpienia obliczonej wartości testu w przypadku, gdyby hipoteza o pochodzeniu prób z tego samego rozkładu głównego była prawdziwa. Mała wartość  $p$  stanowi dowód na nieprawdziwość hipotezy.

Zazwyczaj granicą wartości  $p$  jest 0,05, co oznacza, że w 1 na 20 przypadków możemy zmierzyć daną wartość testu statystycznego (testu  $t$  lub U Manna-Whitneya), nawet gdyby próby pochodziły z tego samego rozkładu głównego. Ostatnie lata udowodniły jednak, że taki próg jest zbyt łagodny. Gdy wartość  $p$  jest bliska granicy 0,05, ale jej nie przekracza, to zaczynamy uznawać, że może istnieć jakiś dowód zaprzeczający hipotezie. Jeżeli wartość  $p$  wynosi, powiedzmy, 0,001 lub nawet mniej, to uzyskujemy mocny dowód na pochodzenie prób z dwóch różnych rozkładów. W takim przypadku mówimy, że różnica jest **statystycznie istotna/znacząca** (ang. *statistically significant*).

# Procesory graficzne (GPU)

Jedną z technologii umożliwiających rozwój współczesnego uczenia głębokiego są potężne **procesory graficzne** (ang. *graphics processing unit* — *GPU*). Są to miniaturowe komputery stanowiące część karty graficznej. Pierwotnie zostały zaprojektowane z myślą o grach komputerowych, ale potężne możliwości równoległego przetwarzania operacji zostały dostosowane do skrajnych wymogów obliczeniowych modeli głębokich sieci neuronowych. Mnóstwo postępów z ostatnich lat nie byłoby możliwych bez niesamowitych możliwości obliczeniowych układów GPU, które są dostępne nawet na prostych komputerach stacjonarnych. Liderem w tworzeniu układów GPU przeznaczonych do uczenia głębokiego jest firma NVIDIA, a dzięki technologii **CUDA** (ang. *Compute Unified Device Architecture*) odegrała kluczową rolę w sukcesie uczenia głębokiego. Nie byłoby przesadą stwierdzenie, że bez układów GPU uczenie głębokie w ogóle nie miałyby miejsca, a z pewnością nie byłoby tak rozpowszechnione.

Skoro o tym mowa, nie oczekujemy, że w omawianych modelach muszą być wykorzystywane układy GPU. Będziemy używać na tyle małych zestawów danych i modeli, że do ich uczenia w rozsądnie krótkim czasie wystarczy zwyczajny procesor komputera. Wymusiłoby zresztą ten wybór na etapie instalowania pakietów, ponieważ wybraliśmy wersję biblioteki TensorFlow działającą jedynie na zwykłym procesorze.

Jeżeli dysponujesz kartą graficzną wyposażoną w architekturę CUDA i chcesz skorzystać z niej podczas pracy nad przykładami opisującymi uczenie głębokie, to możesz to zrobić, jeśli jednak nie masz takiego układu graficznego, nie planuj jego zakupu wyłącznie w tym celu. Jeśli korzystasz z układu GPU, przed instalacją pakietów zainstaluj najpierw prawidłowo architekturę CUDA, a następnie bibliotekę TensorFlow obsługującą karty graficzne. Biblioteka scikit-learn korzysta wyłącznie ze zwykłego procesora.

## Podsumowanie

W niniejszym rozdziale zapoznaliśmy się z naszym środowiskiem operacyjnym. Następnie omówiliśmy kluczowe biblioteki Pythona, z których będziemy korzystać w dalszej części książki, a także przygotowaliśmy instrukcję instalacji tych narzędzi przy założeniu, że będziesz używać dystrybucji Ubuntu 20.04. Jak już wspomnieliśmy, narzędzia te działają równie dobrze w innych dystrybucjach Linuksa oraz systemach operacyjnych. Przeszliśmy dalej do krótkiego omówienia aparatu matematycznego, który będzie nam później potrzebny, a rozdział zakończyliśmy opisem znaczenia układów GPU oraz wyjaśnieniem, dlaczego nie są wymagane podczas pracy na omawianych tu modelach.

Następny rozdział został poświęcony podstawom Pythona.



# Skorowidz

## A

aktywacja/pobudzenie, 346  
warstwy gęstej, 349  
algebra liniowa, 27  
macierz, 28  
mnożenie  
macierzy, 29  
macierzy przez wektor, 29  
wektorów, 28  
tensor, 29  
wektor, 27  
iloczyn wewnętrzny, 29  
iloczyn zewnętrzny, 29  
kolumnowy, 28  
wierszowy, 27  
algorytm  
Adadelta, 356, 369  
Adagrad, 356  
budowania drzew  
decyzyjnych, 154  
Glorota, 279  
gradientu prostego, 225, 229  
aktualizowanie wag, 229  
znajdowanie minimów,  
227  
inicjalizacji wag, 445  
k najbliższych sąsiadów,  
k-NN, 144  
hiperparametr, 179  
wady, 200  
zalety, 199

najbliższego centroidu, 140  
wady, 199  
zalety, 199  
propagacji wstecznej, 235  
rozwiązujący, solver, 260  
SGD, 230–235, 391  
aktualizowanie  
współczynnika uczenia,  
234  
funkcje niewypukłe, 232  
funkcje wypukłe, 232  
grupy, 230  
liczba etapów, 269  
minigrupy, 230  
momentum, 235  
z propagacją wsteczną,  
236  
sortowania bąbelkowego,  
191  
tworzenia drzewa  
decyzyjnego, 156  
wizualizacji t-SNE, 349  
algorytmy  
rekurencyjne, 153  
zachłanne, 155  
analiza  
czasu działania, 192  
danych, 106  
elementy odstające, 107  
wyszukiwanie  
problemów, 107  
złe oznakowanie, 107

głównych składowych, PCA,  
127, 128, 190, 194  
zestaw danych MNIST,  
195  
AUC, area under curve, 311, 398

## B

biblioteka, *Patrz także* moduł  
h5py, 27  
Keras, 25, 119, 351, 406  
librosa, 424  
math, 52  
matplotlib, 27  
NumPy, 25, 54–78  
pillow, PIL, 27, 76  
scikit-learn, 25  
sklearn, 25, 76, 115, 163, 409  
TensorFlow, 25  
blok try-except, 48  
błąd, error, 241, 242  
bezwzględny, 244  
bieżącej warstwy, 243  
dla danych  
niepotasowanych, 384  
potasowanych, 384  
walidacyjnych, 359  
dla zbioru uczącego, 359  
dla zestawu MNIST, 365  
kwadratowy, 238  
model głęboki, 394  
model płytki, 394  
parametr  $\alpha$ , 277  
parametr  $\mu$ , 279

błąd, error  
różne schematy inicjalizacji,  
283  
standardowy, 58, 108  
standardowy średniej, SE, 30  
średniokwadratowy, 244  
tasowanie pikseli, 286  
Breast Cancer, 117, 168,  
*Patrz* zestaw danych  
budowanie  
drzew decyzyjnych, 154  
etykiet, 401  
map cieplnych, 379  
modelu CIFAR-10  
głębokiego, 389  
płytkiego, 389  
modelu MNIST, 354  
sieci spłotowych, 352  
spektrogramów, 441  
zestawu danych, 114  
CIFAR-10, 123  
ESC-10, 422  
MNIST, 120  
prostego, 217  
z obrazami, 413

## C

cechy, feature, 20, 80  
brakujące, 97  
dobór, feature selection, 83  
kolejność, 284  
centroidy klas, 143  
CIFAR-10, 122, 386, *Patrz*  
zestaw danych  
CNN, convolutional neural  
network, 323  
CSV, comma-separated  
values, 73  
CUDA, Compute Unified  
Device Architecture, 33  
czas uniksowy, epoch time, 51  
czułość, sensitivity, recall, hit  
rate, *Patrz* wskaźnik TPR,  
294, 397  
czystość, purity, 155

## D

dane  
testowe, test data, 98, 172  
uczące, training data, 98, 172  
walidacyjne, validation data,  
98  
wejściowe, input, 86  
wektorowe, 203  
definiowanie  
funkcji, 49  
tablicy, 59  
typu danych, 59  
dobór cech, feature selection, 83  
dokładność, accuracy, 288, 367  
ważona, 318  
dopasowanie krzywej, curve  
fitting, 248  
drzewo  
decyzyjne, decision tree,  
150  
algorytm, 154  
wady, 201  
zalety, 201  
zestaw danych Iris, 152  
kd, k-d tree, 194  
metryczne, ball tree, 194  
uczenia maszynowego, 21  
dynamiczny język  
programowania, 37

## E

efektywne pole recepcyjne,  
effective receptive field, 339  
ekstrapolacja, extrapolation, 86  
entropia krzyżowa, 245  
epoka, epoch, 230, 268  
liczba, 365  
ESC-10, 422, *Patrz* zestaw  
danych  
etykieta, label, 79, 80

## F

filtr, 334  
Lanczosa, 337  
format pliku, *Patrz* pliki  
funkcja, 49  
arrange, 65, 67  
argsort, 102  
array, 59, 60  
confusion\_matrix, 315  
ctime, 52  
dot, 71, 72  
enumerate, 45  
epoch, 276  
fit, 276  
load, 74  
loadtxt, 73  
make\_classification, 100  
ones, 62  
pitch\_shift, 427  
random.normal, 76  
random.random, 76  
random.seed, 76  
range, 44  
save, 74  
savetxt, 74  
savez, 74  
savez\_compressed, 75  
score, 276  
shape, 61  
sqrt, 52  
time, 57  
zeros, 62  
funkcje  
aktywacji, activation  
function, 208, 241, 259,  
261, 263  
h, 216  
liniowa, linear function, 208  
logistyczna, *Patrz*  
sigmoidalna  
ReLU, 210, 212, 242, 264  
sigmoidalna, sigmoid,  
210, 211, 264  
tangensa hiperbolicznego,  
hyperbolic tangent,  
210, 211, 264



- przesłane,
  - transcendental function, 209
- trygonometryczne,
  - trigonometric function, 209
- niewypukłe, 232
- straty, loss function, 225, 238, 243, 245, 392
  - błąd bezwzględny, 244
  - błąd średniokwadratowy, 244
  - dla zbioru uczącego, 439, 446
  - dla zbioru walidacyjnego, 439, 446
  - entropia krzyżowa, 245
  - znajdowanie minimum, 227
- wielomianowe, 249
- wypukłe, 232

## G

- GAN, generative adversarial network, 458
- generowanie
  - liczb pseudolosowych, 46, 75
  - sztucznego zestawu danych, 102
  - wartości macierzy pomylek, 292
- Glorot Xavier, 247, 279
- główne składowe, principal component, 128
- gradient prosty, gradient descent, 225
- graf, graph, 206
- grupa, 230

## H

- h5py, 27
- He Kaiming, 247

- hiperparametr,
  - hyperparameter, 160, 179
- hiperpłaszczyzna, hyperplane, 157

## I

- iloczyn
  - Hadamarda, Hadamard product, 242
  - skalarny, dot product, 29, 71
  - wewnętrzny, inner product, 29, 160
  - zewewnętrzny, outer product, 29
- indeksowanie tablicowe, array indexing, 64
- informatywność, informedness, 300
- inicjalizowanie wag, 246, 281
  - Glorota, Glorot initialization, 247
  - He, 247
- instrukcja
  - break, 47
  - continue, 47
  - if-elif-else, 43
  - with, 48
- interpolacja, interpolation, 86
- interpreter Pythona, 34
- Iris, 114, 162, *Patrz* zestaw danych

## J

- jądro, kernel, 161, 325
  - Gausa, Gaussian kernel, 161, 182
  - liniowe, 161
  - RBF, *Patrz* Gausa
  - rezultat użycia, 338
  - skanowanie, 325
- jednostajny główny rozkład prawdopodobieństwa, 89

## K

- kanal alfa, 76
- Keras, 25, 119, 351, 406
  - moduł mnist, 353
  - obliczanie wskaźników, 396
  - optymalizatory, 369
  - sieci spłotowe, 352
  - strojenie modelu, 416
  - usuwanie warstwy, 417
  - zestaw danych
    - CIFAR-10, 122
    - MNIST, 119
- k-krotny sprawdzian krzyżowy, 105, 106
  - implementacja, 174
  - zestaw Breast Cancer, 176
- klasa, class, 79
  - DecisionTreeClassifier, 152
  - LinearSVC, 186, 191
  - MLPClassifier, 234, 247, 258, 261
    - konstruktor, 258, 259
    - obiekt, 268
  - RandomForestClassifier, 180
  - SVC, 166, 186, 191, 192
  - SVM, 160
- klasyfikacja, classification, 79
- klasyfikator
  - binarny, 291
  - k-NN, 144, 145
    - strojenie, 179
  - najbliższego centroidu, 143
    - implementacja, 167
    - zestaw danych Iris, 167
  - najbliższego sąsiada, 144
  - typu jeden przeciw reszcie, one versus rest, 400
  - wieloklasowy, 404
- klasyfikowanie
  - cech dźwiękowych
    - modele klasyczne, 430
    - sieć CNN, 434
    - sieć neuronowa, 432
    - spektrogramów, 443

kłątwa wymiarowości, curse of dimensionality, 83, 84  
kodowanie gorącojedynkowe, one-hot encoding, 83  
kopiowanie listy, 40  
korzeń, root, 153  
krawędź, edge, 206  
krotka, tuple, 42  
krzywa  
  charakterystyki operacyjnej odbiornika, ROC, 304, 398  
  analiza, 307  
  generowanie, 312  
  porównywanie modeli, 310  
  wskaźnik AUC, 311  
  precyzji-czułości, PR, 314

## L

las losowy, random forest, 155, 156  
  strojenie, 180  
  wady, 201  
  zalety, 201  
librosa, 424  
liczby  
  całkowite, integer, 37, 81  
  losowe, random number, 75  
  zmiennoprzecinkowe, floating-point number, 37, 81  
lista, list, 38, 56  
  dodawanie elementów, 39  
  kopiowanie, 40  
  zwracanie elementów, 40  
liść, leaf node, 152  
losowanie prób, 102  
LSTM, long short-term memory, 459

## ł

łańcuch znaków, string, 38

## M

macierz, matrix, 28, 56, 71  
  mnożenie, 28, 71, 242  
  mnożenie przez wektor, 29  
  transpozycja, 242  
macierze  
  dokładności, accuracy matrix, 317  
  pomylęk  
    10×10, 315  
    2×2, 290  
  analiza, 448  
  generowanie wartości, 292  
  modelu lasu losowego, 410  
  przypadki wieloklasowe, 315  
  rozszerzanie, 315  
  wskaźniki, 293, 294  
  wykrywanie patologicznych modeli, 317  
  wyniki, 293, 452, 453  
  wyświetlanie, 403  
mapa  
  cech, feature map, 331  
  ciepłna, heatmap, 379, 382  
margins, margin, 158  
  maksymalny, 159  
  współczynnik tolerancji, 160  
maszyna wektorów nośnych, SVM, 157, 159  
  hiperparametr, 160  
  jądra, 160, 183  
  marginesy, 157  
  ocena uczenia, 184  
  optymalizacja, 160  
  strojenie, 181  
  wady, 202  
  zalety, 202  
  zestaw danych Breast Cancer, 185  
math, 52  
matplotlib, 27

MCC, Matthews correlation coefficient, 302  
mediana, median, 30  
metoda  
  append, 39  
  keys, 42  
  show, 77  
minigrupa, minibatch, 230, 231  
  rozmiar, 365  
minimum  
  funkcji straty, 227  
  lokalne, local minimum, 228  
MNIST, 119, 185, 189, 192, 351, *Patrz* zestaw danych  
mnożenie  
  macierzy, 28, 71, 242  
  wektorów, 28  
model, 20  
  binarny, 400  
  CIFAR-10  
    analizowanie modeli, 392  
    budowanie etykiet, 401  
    dokładność, 391  
    etykiety klas, 399  
    głęboki, deep model, 387, 389  
    obliczanie wskaźników, 396  
    płytki, shallow model, 387, 389  
    rozdzielanie kategorii, 395  
    testowanie, 390  
    uczenie, 390  
klasyczny, 139  
  algorytm k najbliższych sąsiadów, k-NN, 144, 199  
  algorytm najbliższego centroidu, 140, 199  
  drzewo decyzyjne, 150, 200  
  las losowy, 155, 201  
  maszyna wektorów nośnych, SVM, 157, 202  
  naiwny klasyfikator Bayesa, 146, 200

klasyfikujący obrazy, 417  
MNIST, 354  
modyfikowanie  
architektury, 362  
ocena, 356  
uczenie, 356  
wynik uczenia, 357  
wieloklasowy, 400  
modele, 20  
analiza czasu działania, 192  
cechy, 80  
brakujące, 97  
dobór, 83  
czas uczenia, 368  
dokładność, 195  
maksymalna, 197  
dostosowanie do strojenia,  
415  
etykiety, 79  
interpolacja, 86  
k-krotny sprawdzian  
krzyżowy, 174  
klasy, 79  
klasyczne, 139  
dane wektorowe, 203  
ograniczona moc  
obliczeniowa, 203  
testowanie, 163  
używanie, 202  
wektory osadzeń, 408  
zestaw danych Breast  
Cancer, 170–172, 177,  
180, 181  
zestaw danych MNIST,  
186, 187, 356  
kłująca wymiarowości, 83  
mylące przykłady danych, 91  
ocena uczenia, 170–172,  
177, 180, 181  
parametry, 86  
pojemność, 91  
przygotowanie zestawu  
danych, 79  
rozmiar zestawu danych, 91  
strojenie, 411  
testowanie, 163, 375, 418

trenowanie, 81, 86, 105,  
412, 417  
uczenia maszynowego,  
139–161  
uczenie  
nadzorowane, 20  
nienadzorowane, 20  
wektor cech, 80, 92  
zestaw danych, 86  
Breast Cancer, 169, 172,  
174  
Iris, 163  
MNIST, 189, 198  
modulo, 46  
moduł, module, 51  
copy, 41  
decomposition, 129  
metrics, 314, 315  
mnist, 353  
pdb, 49  
pickle, 220  
random, 75  
time, 51  
wavfile, 424  
momentum, 235, 278

## N

nacechowanie, markedness,  
300  
nadmierne dopasowania,  
overfitting, 156  
naiwny klasyfikator Bayesa, 146  
wady, 200  
zalety, 200  
najbliższy  
centroid, nearest centroid,  
143  
sąsiad, nearest neighbor,  
144  
neuron, 207  
niezmienniczość przestrzenna,  
spatial invariance, 324  
normalizacja, normalizing, 95  
wsadowa, 445, 447  
zestawu danych, 169

notacja dużego O, 191  
NPV, negative predictive  
value, 295  
NumPy, 25, 54–78  
liczby losowe, 75  
obrazy, 76  
operatory, 69  
rozgłaszanie, 69  
szybkość biblioteki, 56  
tablice, 59  
typy danych, 60  
wykrawanie wycinków, 68  
zestaw danych MNIST, 120

## O

obciążenie, bias, 208, 216  
obiekt PIL, 77, 137  
obliczanie pochodnej  
cząstkowej, 238  
obraz, 76  
odbicie lustrzane, 135  
odwrócenie, 134  
przycięcie symetryczne, 135  
rotacja, 134  
obrazy testowe, 374  
obsługa błędów, 48  
odchylenie standardowe,  
standard deviation, 30, 58,  
169, 246  
jednostkowe, 94  
odległość, distance, 142  
euklidesowa, Euclidean  
distance, 142, 252  
odsetek  
fałszywie negatywnych,  
FNR, 397  
fałszywie pozytywnych,  
FPR, 397  
operacja  
łączenia, 341  
maksymalizująca, max  
pooling, 341  
softmax, 214  
plotu, 325  
symbol \*, 335

operacje  
  macierzowe, 71  
  na wektorach, 71  
operator, 69  
  dzielenia całkowitego, 70  
  T, 242  
optymalizator, 369  
  czas uczenia, 370  
  dokładność, 370  
osadzenie, embedding, 405

## P

PCA, principal component analysis, 127  
perceptron wielowarstwowy, multi-layer perceptron, MLP, 208, *Patrz sieć neuronowa*  
pętla  
  for, 44  
  while, 46  
    z oddolnym sprawdzaniem, 46  
    z odgórnym sprawdzaniem, 46  
pillow, PIL, 27, 76  
plik  
  bc\_experiments.py, 169, 292  
  bc\_kfold.py, 174, 176  
  bc\_rbf\_svm\_search.py, 183  
  box\_plot.py, 109  
  cifar10\_cnn\_SGD.py, 388  
  cifar10\_augment.py, 135  
  cifar10\_cnn.py, 388  
  cifar10\_cnn\_cat\_dog\_fine\_ ↪tune\_3.py, 416  
  cifar10\_cnn\_model.h5, 406  
  cifar10\_cnn\_vehicles.py, 414  
  cifar10\_cnn\_vehicles\_ ↪model.h5, 415  
  feature\_stats.py, 109  
  iris\_centroids.py, 167  
  iris\_data\_augmentation.py, 130

iris\_experiments.py, 163  
make\_shifted\_mnist\_ ↪dataset.py, 381  
mnist\_2x2\_tables.py, 297  
mnist\_even\_odd.py, 306  
mnist\_experiments.py, 186, 187, 297  
mnist\_experiments\_base\_ ↪lr.py, 272  
mnist\_nn\_experiments.py, 259, 261  
mnist\_nn\_experiments\_ ↪init.py, 280  
mnist\_nn\_experiments\_ ↪L2.py, 276  
mnist\_nn\_experiments\_ ↪momentum.py, 278  
mnist\_nn\_experiments\_ ↪samples.py, 274  
mnist\_pca.py, 195  
multilayer\_perceptron.py, 267  
nn\_iris\_dataset.py, 217  
nn\_iris\_evaluate.py, 219  
nn\_iris\_mlpclassifier.py, 221  
numpy\_speed\_test.py, 56  
transfer\_learning.py, 406  
pliki  
  .csv, 73, 74  
  .npy, 74  
  dźwiękowe, 423, 427  
    .wav, 421, 425  
  graficzne, 77  
    .jpeg, 76  
    .png, 76  
  HDF5, 27, 357  
  płaszczyzna, plane, 157  
    maksymalnego marginesu, 160  
  pochodna, derivative, 227  
    cząstkowa, partial derivative, 237  
    obliczanie, 238  
    funkcji ReLU, 242  
  podział danych, 172  
  pojemność, capacity, 91  
  pole recepcyjne, receptive field, 339

porzucanie, dropout, 253  
PPV, positive predictive value, 295  
PR, precision-recall curve, 314  
prawdopodobieństwo, *Patrz także* rozkład prawdopodobieństwa rotacji obrazu, 137  
  wystąpienia cechy, 149  
precyzja, precision, 249, 397  
procesory graficzne, graphics processing unit, GPU, 33  
programowanie kwadratowe, quadratic programming, 160  
propagacja wsteczna, backpropagation, 225, 235, 236, 240  
próbna, sample, 28  
  samowsporna, bootstrap sample, 156  
przekształcenia  
  obrazu, 134  
  obrazu PIL w tablicę, 137  
  tablicy NumPy w obiekt, 137  
przestrzeń  
  cech, 141, 142, 143  
  nazw, namespace, 51  
przesunięcie czasowe, time shifting, 424  
przetrenowanie, 156, 248  
przykłady mylące, confuser, 91  
punkt siodłowy, saddle point, 233  
Python, 34, *Patrz także* NumPy  
  białe znaki, 35  
  funkcje, 49  
  idiomy, 137  
  instrukcje, 35  
  struktury  
    danych, 36  
    sterowania, 43  
  zmiennne, 36

## R

radialna funkcja bazowa, RBF, 161, 182  
regresja liniowa, linear regression, 87  
regularyzacja, regularization, 126, 225, 248, 251, 445  
    L2, L2 regularization, 252, 275  
reguła łańcuchowa, 237, 238  
    dla pochodnych, 236  
rekurencja, recursion, 153  
RGB, red, green, blue, 76  
RNN, recurrent neural networks, 459  
ROC, receiver operating characteristics curve, 304  
rozgłaszanie, broadcasting, 69  
rozkład prawdopodobieństwa, probability distribution, 31  
    a posteriori, 146  
    a priori, 89, 146  
    Gausa, Gaussian distribution, 31  
    główny, parent distribution, 31, 89  
    jednostajny, uniform distribution, 31, 89, 246  
    normalny, normal distribution, 31  
    wspólny, joint probability, 148  
rozmiar  
    grupy, 267  
    minigrupy, 365  
    zbioru uczącego, 365  
rozstęp ćwiartkowy, 111  
rozszerzanie/dogenerowanie danych, data augmentation, 124  
    analiza  
        głównych składowych, 130  
    zestaw CIFAR-10, 133  
    zestaw Iris, 127  
równanie liniowe, 226

## S

scikit-learn, 25, *Patrz* sklearn  
segmentacja semantyczna, semantic segmentation, 346  
SGD, stochastic gradient descent, 230  
sieć neuronowa  
    aktualizowanie współczynnika uczenia, 234  
    algorytm gradientu prostego, 225, 229  
    algorytm rozwiązujący, 260  
    architektura, 212, 259  
    funkcje aktywacji, 207, 216, 259  
    implementacja, 217  
    neuron, 207  
    obciążenie, bias, 208, 216  
    ocena uczenia w zależności od funkcji aktywacji, 264  
    liczby parametrów, 266  
    rozmiaru minigrupy, 270  
    rozmiaru zbioru uczącego, 275  
    współczynnika uczenia, 273  
pełna, 213  
przetrenowanie, 248  
regularyzacja, 251  
softmax, 214  
testowanie, 221  
uczenie, 221, 224–56  
    aktualizowanie wag, 229  
    algorytm gradientu prostego, 225  
    algorytm SGD, 230  
    dobór wartości początkowych, 229  
    epoka, 230  
    funkcje aktywacji, 259, 261  
    funkcje straty, 243

inicjalizowanie wag, 246, 279  
kończenie uczenia, 233  
klasa MLPClassifier, 258  
kolejność cech, 284  
porzucanie, 253, 254  
propagacja wsteczna, 235, 236  
przetrenowanie, 248  
regularyzacja, 248  
regularyzacja L2, 275  
rozmiar grupy, 267  
rozmiar zbioru uczącego, 274  
struktura, 259  
wsadowe, 230, 231  
współczynnik uczenia, 271  
wyniki, 263  
znajdowanie minimów, 227  
wagi, 208, 216  
warstwa wyjściowa, 214  
warstwy ukryte, 216  
węzeł, 207, 208  
zestaw danych, 217  
    Iris, 219, 221  
    MNIST, 257  
sieć neuronowa spłotowa, CNN, 323  
    aktywacja/pobudzenie, 346  
    architektura, 329  
    budowanie modelu MNIST, 354  
model  
    binarny, 400  
    głęboki, 389  
    płytki, 389  
    wieloklasowy, 400  
niezmienniczość przestrzenna, 324  
operacja spłotu, 325  
    jądro, 325  
    krok, 325  
    przetwarzanie obrazów, 328  
tryb zerowy, 327  
uzupełnianie zerami, 327

sieć neuronowa spłotowa,  
CNN  
segmentacja semantyczna,  
346  
strojenie, 411  
tasowanie danych, 383  
uczenie transferowe, 405  
w pełni spłotowa, 345, 346  
mapa cieplna, 378, 382  
testowanie, 374, 375  
trenowanie, 371  
zestaw MNIST, 371  
warstwy  
gęste, 331  
łączące, 331, 340  
ReLU, 330  
spłotowe, 331, 333, 336,  
340  
spłotowe pełne, 344  
spłotowe wielokrotne,  
339  
spłaszczające, 331  
tablice  
czterowymiarowe, 331  
w pełni połączone, 343  
wczytywanie danych, 352  
wyznaczanie klas pojazdów  
i zwierząt, 395  
zestaw danych CIFAR-10,  
386  
sieci  
generatywne sieci  
przeciwstawne, GAN, 458  
rekurencyjne sieci  
neuronowe, RNN, 459  
skalar, 29  
sklearn, 25, 76, 115, 163, 409  
drzewo decyzyjne, 152  
ostrzeżenia, 263  
wizualizacja, 349  
współczynnik tolerancji, 160  
zestaw danych  
Breast Cancer, 117  
Iris, 114  
słownik, dictionary, 42  
softmax, 214

spektrogram dźwięku, 440  
spłot, convolution, 325  
jądra z obrazem, 325  
standaryzacja, standardization,  
95  
statystyka opisowa, descriptive  
statistics, 30, 31  
statystyki, 109  
stochastyczny spadek wzdłuż  
gradientu, *Patrz* algorytm  
SGD, 230  
strategia  
jeden na jednego, 192  
jeden na resztę, 192  
strojenie, fine-tuning, 412  
klasyfikatora k-NN, 179  
lasu losowego, 180  
maszyny SVM, 181  
modelu, 416  
struktura  
danych  
krotka, 42  
lista, 38  
słownik, 42  
tablica, 55  
sieci neuronowej, 212, 259  
sterowania, control  
structures, 43  
studium przypadku, 421  
klasyfikowanie cech  
dźwiękowych, 430  
modele klasyczne, 430  
sieć CNN, 434  
sieć neuronowa, 432  
klasyfikowanie  
spektrogramów, 443  
spektrogramy, 439  
styczna, tangent, 227  
SVM, support vector machine,  
157  
swoistość, specificity, *Patrz*  
wskaźnik TNR, 294, 397  
sygnały, 208  
symbol  
sumy, 148  
iloczynu, 148  
sztuczna inteligencja, SI, 20

## Ś

średnia, 30, 94  
harmoniczna, harmonic  
mean, 301  
środkowanie wokół średniej,  
mean centering, 94

## T

tablica, array, 55, 58  
dane wejściowe, 72  
dane wyjściowe, 72  
definiowanie, 59  
indeksowanie, 64  
trójwymiarowa, 61  
użycie wielokropka, 68  
wykrawanie wycinków, 65,  
68  
technologia CUDA, 33  
tensor, tensor, 29  
TensorFlow, 25  
test  
parametryczny, parametric  
test, 32  
nieparametryczny,  
nonparametric test, 32  
statystyczny, statistical test,  
32  
U Manna-Whitneya, 32  
testowanie  
modeli klasycznych, 163  
modelu, 418  
TNR, true negative rate, 294,  
397  
TPR, true positive rate, 294,  
397  
transformata Fouriera, Fourier  
transform, 439  
transpozycja, 160, 242  
t-SNE, 349  
twierdzenie Bayesa, 146  
typy danych NumPy, 60

## U

- Ubuntu, 26
- uczenie
  - bezprzykładowe, zero-shot learning, 202
  - głębokie, deep learning, 14, 20
  - kilkuprzykładowe, few-shot learning, 202
  - kompleksowe, end-to-end training, 349
  - maszynowe, 20, 139–61
    - algorytm k najbliższych sąsiadów, k-NN, 144
    - algorytm najbliższego centroidu, 140
    - drzewa decyzyjne, 150
    - lasy losowe, 155
    - maszyny wektorów nośnych, SVM, 157
    - naiwny klasyfikator Bayesa, 146
  - nadzorowane, supervised learning, 20, 86
  - nienadzorowane, unsupervised learning, 20, 458
  - przez wzmacnianie, reinforcement learning, 20, 458
  - transferowe, transfer learning, 202, 405
  - wsadowe, batch training, 230, 231

## W

- waga, weight, 208, 216
  - aktualizowanie, 229
  - inicjalizacja, 279
    - Glorota, 247
    - He, 247
    - schematy, 281
  - zanik, 252

- wariancja, variance, 30
- warstwa
  - gęsta, 331, 349
  - łącząca, 331, 340
  - ReLU, 330
  - splotowa, 331, 333, 336, 340
    - inicjalizacja, 340
    - poła recepcyjne, 339
    - pełna, 344
    - wielokrotna, 339
  - splaszczająca, 331
  - w pełni połączona, 343
  - wyjściowa, 214
- warstwy
  - ukryte, 216
  - usuwanie, 417
- wartości
  - dyskretne, 81
  - kategoryzujące, 82
  - logiczne, 40
  - porządkowe, 82
  - przedziałowe, 81
- wartość
  - None, 40
  - NULL, 40
  - p, p-value, 32
- wektor, 27, 56, 70
  - cech, feature vector, 81, 84, 92
  - cech dźwięku, 429
  - wierszowy, row vector, 27, 161
  - kolumnowy, column vector, 28
  - nośny, 159
  - osadzeń, 408
- wektory
  - dodawanie, 216
  - iloczyn
    - skalarny, 71
    - wewnętrzny, 29
    - zewewnętrzny, 29
  - mnożenie, 28
- węzeł, node, 206, 207
  - sygnał wejściowy, 208
  - sygnał wyjściowy, 208
  - wagi, weight, 208

- wiarygodność, likelihood, 146
- widmo mocy, power spectrum, 439
- wielokropek, 69
- wielomian, 249
- wskaźnik, metric, 287
  - AUC, area under curve, 311
  - F1, F1 score, 300
  - Giniego, Gini index, 155
  - informatywność, informedness, 300
  - nacechowanie, markedness, 300
  - odsetek prawdziwie negatywnych, TNR, 294, 397
  - odsetek prawdziwie pozytywnych, TPR, 294, 397
  - wartość predykcyjna dodatnia, PPV, 295
  - wartość predykcyjna ujemna, NPV, 295
  - współczynnik kappa Cohena, 301
  - współczynnik korelacji Matthews'a, MCC, 302
  - wieloklasowy, 320
  - współczynnik uczenia, 234, 271
    - aktualizowanie, 234
- wskaźniki
  - interpretowanie modeli, 297
  - obliczanie, 396
  - wykresy, 306, 310
  - wyniki, 298
  - zaawansowane, 299
    - implementacja, 302
    - wyniki, 303
- wycinek tablicy, array slice, 63
- wygładzanie Laplace'a, Laplace smoothing, 150
- wykrawanie wycinków, slicing, 65, 68

wykres  
analiza PCA, 128  
dwuwymiarowa przestrzeń  
cech, 141–143  
funkcja błędu, 358  
pudełkowy, box plot, 109,  
110, 116  
punktowy cech, 127  
t-SNE, 408  
wyrażenie listowe, list  
comprehension, 46

## Z

zanik wagi, weight decay, 252  
zbiór uczący, training set, 20  
rozmiar, 274, 365  
zdarzenia niezależne, 148  
zespół, ensemble, 156, 449  
zestaw cech, feature, 20, 28  
zestaw danych, dataset, 86  
Breast Cancer, 117, 168  
k-krotny sprawdzian  
krzyżowy, 174  
macierz pomyłek  $2 \times 2$ ,  
293, 296  
oceny modeli, 170–172,  
177  
randomizacja, 172

cechy, 80  
CIFAR-10, 122, 386  
przygotowanie, 388  
rozszerzenie zestawu,  
133, 135, 412  
ESC-10, 422  
budowanie, 422  
rozszerzenie, 423–426  
wstępne przetwarzanie,  
427  
zmniejszanie liczby  
próbek, 428  
etykiety, 79  
Iris, 114, 162  
analiza PCA, 128  
drzewo decyzyjne, 152  
klasyfikator najbliższego  
centroidu, 167  
modele klasyczne, 163  
rozszerzenie zestawu,  
127, 130  
sieć neuronowa, 221  
klasy, 79  
MNIST, 119, 185, 189, 192,  
351  
analiza czasu działania,  
192  
analiza PCA, 195  
dokładność modelu, 197  
krzywe ROC, 311  
oceny modeli, 189, 198

pełne sieci splotowe, 371  
przetwarzanie wstępne,  
189  
sieć neuronowa  
tasowanie, 197, 198, 383  
tworzenie obrazów  
testowych, 374  
uczenie klasycznych  
modeli, 185–187  
wskaźniki  
zaawansowane, 303  
znormalizowany, 186  
podział, 99  
rozmiar, 91  
skalowanie cech, 92  
wektory cech, 80  
własności, 86  
znormalizowany, 168, 186  
zmiana  
stosunku podziału danych,  
172  
tonacji, pitch shifting, 424  
zmiennie, variable, 37  
znak  
\*, 335  
procentu, 46  
tabulatora, \t, 73  
wielokropka, 68



# PROGRAM PARTNERSKI

— GRUPY 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  
**Helion** 

UCZENIE  
GŁĘBOKIE:  
PRZYSZEDŁ CZAS  
NA TWÓJ PIERWSZY  
MODEL!



Uczenie głębokie fascynuje wielu inżynierów i praktyków. Mimo że systemy oparte na uczeniu maszynowym stosuje się w rozlicznych branżach, wciąż są uważane za niepokojącą technologię. Istotnie, w wypadku na przykład sieci neuronowych nie wiemy, czego dokładnie uczy się model. Możemy tylko ocenić, czy dobrze realizuje swoje zadanie. Wydaje się, że w sposobie pracy algorytmów uczenia głębokiego tkwi magia. Właśnie dlatego dobrze jest zająć się faktami i dowiedzieć się, na czym w rzeczywistości polega uczenie maszynowe, a zwłaszcza uczenie głębokie.

Ta książka jest przystępnym przewodnikiem po uczeniu maszynowym. Aby zrozumieć zawartą w niej treść, wystarczy podstawowa umiejętność programowania i znajomość matematyki na poziomie szkoły średniej. Znalazło się tu omówienie podstawowych pojęć i wyjaśnienie mechanizmów rządzących uczeniem głębokim. Dzięki lekturze dowiesz się, czym się charakteryzuje dobry zbiór danych uczących, jak ocenić skuteczność modelu i jak korzystać z takich modeli jak najbliższych sąsiadów, lasy losowe czy maszyna wektorów nośnych. Sporo miejsca poświęcono również sieciom neuronowym, mechanizmom ich działania i technikom treningu. I chociaż nie znajdziesz tutaj gotowych receptur, to zdobędziesz wiedzę potrzebną, by od podstaw zaprojektować działający model uczenia głębokiego.

### W książce między innymi:

- budowanie dobrego zestawu danych uczących
- praca z bibliotekami scikit-learn i Keras
- klasyczne modele uczenia maszynowego
- mechanizm działania i uczenia sieci neuronowych
- modele wykorzystujące splotowe sieci neuronowe
- przygotowanie od podstaw działającego modelu

**Dr Ronald T. Kneusel** uczeniem maszynowym zajmuje się zawodowo od 2003 roku, specjalizuje się w dziedzinie przetwarzania obrazów. Jego fascynacja komputerami jednak trwa znacznie dłużej, bo od 1981 roku. Obecnie pracuje w spółce L3Harris Technologies, gdzie buduje systemy uczenia głębokiego. Jest autorem popularnych książek na temat pisania kodu i uczenia głębokiego.

**Helion**



helion.pl



HELION SA  
ul. Kościuszki 1c  
44-100 Gliwice  
tel.: 32 230 98 63  
helion@helion.pl

KOD KORZYŚCI  
Sięgnij po więcej ▶



ISBN 978-83-283-8859-8



9 788328 388598

Cena: 99,00 zł

