

MACHINE LEARNING I NATURAL LANGUAGE PROCESSING W PROGRAMOWANIU

Piotr Wróblewski

Podręcznik z ćwiczeniami w Pythonie

Helion 

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.

Redaktor prowadzący: Małgorzata Kulik

Projekt okładki: Studio Gravite/Olsztyn
Obarek, Pokoński, Pazdrijowski, Zaprucki

Materiały graficzne na okładce zostały wykorzystane za zgodą Shutterstock.

Helion S.A.
ul. Kościuszki 1c, 44-100 Gliwice
tel. 32 230 98 63
e-mail: helion@helion.pl
WWW: <https://helion.pl> (księgarnia internetowa, katalog książek)

Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
<https://helion.pl/user/opinie/szinpy>
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

ISBN: 978-83-289-1580-0

Copyright © Helion S.A. 2024

Printed in Poland.

- [Kup książkę](#)
- [Poleć książkę](#)
- [Oceń książkę](#)

- [Księgarnia internetowa](#)
- [Lubię to! » Nasza społeczność](#)

Spis treści

	Wstęp	7
ROZDZIAŁ 1.	O technikach ML, NLP oraz AI bez zbędnej teorii	17
	Bać się czy nie bać AI?	18
	Zastosowania sztucznej inteligencji	20
	Systemy eksperckie	22
	Sieci neuronowe	24
	Uczenie maszynowe	27
	Modelowanie problemów w Pythonie	28
	Tablice — podstawowa struktura w przetwarzaniu danych	29
	Grafy — modelowanie stanów i przejść	31
	Klasy — modelowanie rzeczywistości	33
	Modelem jestem	38
	Z nauczycielem czy bez?	39
	Nauczanie nadzorowane	39
	Nauczanie nienadzorowane	40
	Techniki mieszane	40
	Ważniejsze biblioteki AI/ML i NLP w Pythonie	41
	Pakiety uniwersalne	41
	Pakiety przydatne w ML i NLP	42
	Na deser — Noam Chomsky o AI	44
ROZDZIAŁ 2.	Niezbędnik warsztatowy programisty Pythona	46
	Testujemy poprawność instalacji Pythona	49
	Instalator pip i biblioteki Pythona	52
	Edytory do Pythona	53
	Środowiska IDE	54
	IDLE	54
	PyCharm	58
	Visual Studio Community	64
	Notatniki Jupyter	65
	Dokumentacja Pythona	67
	Używanie zasobów GitHuba	69
ROZDZIAŁ 3.	NLP — przybornik	71
	Odczyt plików i katalogów	71
	Rodzaje plików	72
	Otwieranie plików	72
	Klasa Path	78

Napisy — na co zwrócić uwagę	81
Napisy to nie tablice	81
Konwersje	83
Wyrażenia regularne	84
Pobieranie tekstu z plików PDF	89
Instalacja i konfiguracja spaCy	92
Instalacja i konfiguracja NLTK	93
Podstawowe techniki NLP	94
Tokenizacja bez zadyszki	94
NER, czyli nazwy własne	99
NER w spaCy	99
Czas na pomiar	103
Stop word — co z tym fantem zrobić?	104
NLTK i spaCy — co dalej?	105
ROZDZIAŁ 4. NLP — zastosowania	108
Powtórka z NumPy	108
Tablice i macierze	112
Deklarowanie tablic i macierzy w pigułce	113
Funkcje tablicowe	115
Zmiany układu i rozmiaru tablic	118
Wycinki, czyli opanuj dwukropek	120
Powtórka z Pandas	122
Model danych w bibliotece Pandas	123
Obiekty Pandas Series	124
Obiekty Pandas DataFrame	126
Import danych zewnętrznych	128
Czyszczenie danych	132
Analiza jądłospisu pandy	138
Nauczanie nadzorowane w pigułce	141
Macierz konfuzji	143
Ewaluacja modeli klasyfikacji	144
Wstępniak z scikit-learn	148
Klasyfikacja na przykładzie	150
Analiza podobieństwa	157
Wektoryzacja w spaCy	159
Techniczne aspekty wektoryzacji	161
Klasyfikacja — ciąg dalszy	163
Klasyfikacja dla liczby klas większej niż 2	168
Analiza sentymentu	169
VADER	170
TextBlob	174

ROZDZIAŁ 5.	ChatGPT to... nie tylko chat!	176
	Czym jest ChatGPT?	176
	Wektory słów i word embeddings	180
	Nie tylko chat	182
	Podłączamy się do serwisu OpenAI przez API	184
	Tworzenie konta w usłudze OpenAI	184
	Klucz API do komunikacji z usługą GPT	186
	Bezpieczeństwo klucza API	188
	Konwersacja z ChatGPT przez API	188
	Szablon zapytania do ChatGPT API	189
	Dłuższe sesje z ChatGPT API	190
	Podłączamy ChatGPT do internetu	192
	Naucz się web scrappingu	195
	Analiza sentymentu recenzji internetowych	198
	Interfejs embeddings serwisu OpenAI	199
ROZDZIAŁ 6.	Szybka analiza danych przy użyciu Matplotlib	204
	Wykresy punktowe i liniowe	205
	Modyfikacje wyglądu wykresu	207
	Wykresy wielokrotne	209
	Popularne miary statystyczne	211
	Rozkład normalny warto znać!	212
	Popularne wykresy analizy danych	213
	Wykresy słupkowe	213
	Histogramy	215
	Wykres skrzypcowy	216
	Wykres pudełkowy	218
	Mapa cieplna	219
	Podręcznik Matplotlib na bezludną wyspę?	221
ROZDZIAŁ 7.	Czy można przewidzieć nieznane?	222
	Zastosowania regresji liniowej	226
	Kiedy regresja działa, a kiedy nie?	227
	Wstępna analiza statystyczna danych	232
	Regresja z użyciem biblioteki scikit-learn	241
ROZDZIAŁ 8.	Podział klasowy bez złych skojarzeń	247
	Metody skalowania cech	247
	Skalowanie cech — przykład	249
	Analiza wartości odstających	251
	Klasyfikacja bez standaryzacji i ze standaryzacją	254
	Zmienne kategoryczne — co z tym fantem zrobić?	257
	Preprocesowanie danych przy użyciu ColumnTransformer	263
	Gdy klas jest więcej niż dwie	265
	Klasyfikacja obrazów	268

ROZDZIAŁ 9.	Dziel i rządź, czyli klasteryzacja	269
	Niebo gwiaździste nade mną... ..	269
	Popularne algorytmy realizujące klasteryzację	272
	Pierwsze klastrowanie w Pythonie	273
	Klastrowanie hierarchiczne	274
	Algorytm centroidów (K-Means)	280
	Więcej wymiarów	283
	Kłopotliwe dane katagoryczne	285
	K-modes	287
	K-prototypes	288
	A może dwa wróble w garści?	289
	Podsumowanie	291
	Skorowidz	293

ROZDZIAŁ 6.

Szybka analiza danych przy użyciu Matplotlib

Powtórka z Matplotlib • Rozkład normalny • Popularne miary statystyczne
• Interakcja NumPy i Pandas z Matplotlib • Narysować oznacza zrozumieć!

W wielu zadaniach programistycznych wizualizacja danych stanowi uwiecznienie żmudnej pracy wykonywanej przez program, w nauczaniu maszynowym jest często wymagana jeszcze przed zbudowaniem modeli ML. Dlatego każdy, kto poważnie podchodzi do nauki ML, prędzej czy później będzie potrzebował wykresów graficznych, które pomogą lepiej zrozumieć dane, wykryć anomalie, wstępnie zidentyfikować pewne korelacje itp.

W celu analizy informacji, jakie skrywają w sobie „surowe” serie danych, można podejść do tematu „matematycznie”, tj. wykorzystać biblioteki, które nam to ułatwią, pomagając w oczyszczaniu danych i umożliwiając wszechstronne analizy statystyczne. Bezcenne są tu mechanizmy oferowane przez NumPy i Pandas (zob. rozdział 4.). Czasem to nie wystarcza i może nam coś ważnego umknąć — i tu właśnie mogą pomóc typowe wizualizacje stosowane w analizie danych: wykresy liniowe, punktowe, słupkowe, histogramy i wiele innych. Nawet takie proste realizacje często pozwalają wykryć zaburzenia, anomalie, nieoczywiste korelacje — czasem na pierwszy rzut oka.

O tym właśnie opowiem w bieżącym rozdziale i przekonasz się, że nie są to trudne zagadnienia. Do budowy wykresów użyjemy biblioteki Matplotlib, co wymaga jej zaimportowania do środowiska Pythona (`pip3 install matplotlib`, w Windowsie użyj polecenia `pip`) lub dodania do projektu PyCharma. Oprócz Matplotlib analitycy danych często używają biblioteki seaborn (<https://seaborn.pydata.org>), ale jej przestudiowanie pozostawiam już Tobie — w książce użyję jej kilka razy i zalecam wykonanie instalacji (`pip3 install seaborn`, w systemie Windows `pip`).

Matplotlib oferuje bogaty zestaw klas pozwalających na tworzenie wizualizacji w Pythonie, i to nie tylko statycznych, lecz także dynamicznych, a nawet interaktywnych, jeśli połączymy ją z narzędziami interaktywnymi, takimi jak IPython Widgets. Umożliwi to tworzenie interaktywnych wykresów, które użytkownik może modyfikować, np. dokładając klasyczne formy interakcji, takie jak suwaki, pola tekstowe czy przyciski, aby zmieniać parametry wykresów w czasie rzeczywistym, podobnie jak np. w PowerBI.

Podczas instalacji Matplotlib wgrywane są dodatkowe moduły, których ona wymaga (*pyparsing*, *numpy*, *kiwisolver*, *fonttools*, *cycler*, *contourpy*). NumPy już znasz z poprzednich rozdziałów, jest to specjalistyczna biblioteka ułatwiająca obsługę dużych, wielowymiarowych tablic i macierzy, które mogą stanowić źródła danych dla wykresów tworzonych z użyciem Matplotlib. Autorami biblioteki są John D. Hunter i Michael Droettboom. Gdy już zapoznasz się z omówieniem zawartym w tym rozdziale, koniecznie odwiedź stronę zawierającą źródłowe informacje referencyjne opisujące wszystkie metody zawarte w tej bibliotece: <https://matplotlib.org>.



Jeśli używasz systemu Windows i podczas testowania przykładowych programów uruchomienie nie powiedzie się, np. otrzymasz komunikat podobny do `from matplotlib._path import ImportError: DLL load failed while importing _path`: Nie można odnaleźć określonego modułu, to zainstaluj dodatek o nazwie Microsoft Visual C++ Redistributable. Zawiera on biblioteki, które są wymagane do uruchomienia aplikacji w języku C++ skompilowanych przy użyciu programu Visual Studio 2015. Dodatek jest dostępny pod adresem: <https://www.microsoft.com/pl-PL/download/details.aspx?id=48145>. W czasie pisania tej książki dla systemu Windows 11 Pro nie zaobserwowałem już tego błędu, ale podaję tę wskazówkę na wszelki wypadek.

Wykresy punktowe i liniowe

Nawet bez wczytywania się w obszerną dokumentację¹⁹ można szybko i bez wysiłku utworzyć prosty program rysujący wykresy. Załóżmy, że interesuje nas stworzenie wykresu funkcji, dla której znamy dziewięć wartości (pary x, y), które w kodzie Pythona są umieszczone w listach o nazwach `osX` i `osY`. Taki zestaw można zwizualizować, pokazując wykres punktowy (inna nazwa to wykres rozrzutu, ang. *scatter plot*), lub też jako wykres liniowy, uznając, że punkty danych są częścią wykresu liniowego.

Skrypt, który tworzy taki wykres, jest wyjątkowo zwięzły (*matplotlib0.py*):

```
from matplotlib import pyplot as plt
osX = [10, 20, 30, 40, 50, 60, 70, 80, 90, 100]
osY = [5, 5.6, 8, 9, 11, 20, 14, 12, 10, 9.5]
plt.plot(osX, osY) # Wykres liniowy
# Dodanie pogrubionych kropek w punktach danych
plt.scatter(osX, osY, color='grey', s=50) # Wykres punktowy, s — rozmiar kropki
plt.savefig('wykresik.pdf')
plt.show()
```

Mimo że skrypt zajmuje raptem kilka linijek, wykonuje sporo pracy:


- Wyświetla miniprogram graficzny zawierający wykres i kontrolki pozwalające nim operować (skalowanie, nawigacja w zakresie osi X , Y).

¹⁹ Określenie „obszerna” to eufemizm: podręcznik użytkownika zajmuje 4917 stron w PDF-ie dla wersji 3.8.3 i ciągle rośnie z kolejnymi aktualizacjami.

- W ramach prezentu pożegnalnego na dysku w katalogu roboczym zostanie zapisany plik o nazwie *wykresik.pdf*, będący kopią wykresu w jego układzie pierwotnym.

Dane liczbowe na osi X celowo dobrałem tak, aby były posortowane i w miarę w równych odstępach, by uzyskać ładny wykres linii ciągłej (funkcja `plot()`), gdyż linia jest rysowana punkt po punkcie i chciałem uniknąć efektu cofania kreski. Na linię są nałożone też kropki punktów danych (funkcja `scatter()`).

Rysunek 6.1 pokazuje okienko, które zobaczysz na ekranie po uruchomieniu skryptu. Jest to wersja macOS-a, natomiast dla Windowsa lub w Linuksie styl okna będzie nieco inny.



RYСУNEK 6.1. Wykres wygenerowany przez moduł pyplot (Matplotlib)

Okno oferuje kilka przycisków nawigacyjnych:

- — powrót do układu pierwotnego (reset);
- strzałki — powrót do poprzedniego / przywrócenie cofniętego widoku;
- — skalowanie lub przesunięcie z użyciem myszy (np. lewy klawisz przesuwaj wykres, prawy skaluje);
- — zaznacz obszar z przyciśniętym lewym klawiszem myszy i puść, aby wejść w tryb zoom obszaru;
- — marginesy i pozycja wykresu względem okna (zob. osobne okno *Subplot configuration tool*);
- — zapis grafiki na dysk w formacie PNG.

Wykonaj kilka ćwiczeń, gdyż przeznaczenie niektórych kontrolerek może nie być zbyt intuicyjne. Przycisk resetu (symbol domku) pozwala wrócić do pierwotnego układu wykresu przed ewentualnymi zmianami skali lub przesunięciami, które użytkownik wykonał za pomocą myszy po wciśnięciu przycisku pozwalającego na skalowanie wykresu (zoom) lub zmianę widocznego obszaru w ramach osi X , Y .

Wspierane funkcje skalowania lub przesunięć:

- Możesz chwytać wykres myszą i przesuwając w lewo i w prawo, np. aby przejść poniżej osi X , w stronę ujemnych wartości Y .
- Wciśnij klawisz *Ctrl* i przytrzymując wciśnięty *prawy* klawisz myszy, przesuвай ją w górę (powiększanie) lub w dół (pomniejszanie).
- Wciśnij klawisz *Ctrl* i przytrzymując wciśnięty *lewy przycisk* myszy, przesuвай ją w górę i w dół (przesuwanie się na osi X) lub w lewo i prawo (przesuwanie się na osi Y).

Ponowne wciśnięcie przycisku pozwala powrócić do klasycznego ekranu i zachowanego stanu wykresu.

Modyfikacje wyglądu wykresu

Prosty wykres z domyślnymi ustawieniami rzadko spełnia nasze oczekiwania i może okazać się nieczytelny. Modyfikacje wyglądu wykresu wprowadzamy jako dodatkowe parametry metody rysującej wykres, którym u nas jest linia oferowana przez funkcję `plot()`, wzbogacona kropkami punktów danych. Dla takiego prostego wykresu dwuwymiarowego można łatwo zmodyfikować kolor, grubość oraz styl linii, można też zmienić sposób wyświetlania punktów danych.

W tym celu funkcję `plot()` wzbogacamy o parametry:

- `marker` — styl punktu danych;
- `ms` — rozmiar markera (ang. *marker size*);
- `linestyle` — styl linii;
- `color` — kolor;
- `linewidth` — grubość linii.

Tabela 6.1 zawiera listę kolorów dostępnych w ramach podstawowej palety RGB. Oprócz takich kodów można podawać też kolory, używając notacji kodowej RGB w konwencji `'#rrggbb'` (np. `'#67e210'` pozwoli uzyskać piękny, wiosenny odcień zieleni).

TABELA 6.1. Kody kolorów palety podstawowej rozróżniane przez funkcję wykreślającą `plot`

CECHA	KOLOR	CECHA	KOLOR
'm'	Purpurowy (ang. <i>purple</i>), magenta	'r'	Czerwony (ang. <i>red</i>)
'y'	Żółty (ang. <i>yellow</i>)	'g'	Zielony (ang. <i>green</i>)
'k'	Czarny (ang. <i>black</i>)	'b'	Niebieski (ang. <i>blue</i>)
'w'	Biały (ang. <i>white</i>)	'c'	Niebieskozielony (ang. <i>cyan</i>)

Tabela 6.2 zawiera listę popularnych kodów pozwalających zmodyfikować *styl kreślowania*, co jest bardzo przydatne podczas rysowania wykresów wielokrotnych i ułatwia rozróżnianie, która linia odpowiada określonej serii danych.

TABELA 6.2. Typy kreskowania w Matplotlib

KOD	STYL
'-'	____ (linia ciągła)
':'	 (linia kropkowana)
'--'	--- (linia kreskowana)
'-.'	- . - . (linia kropkowano-kreskowana)

Tabela 6.3 zawiera kilka wybranych kodów, których można użyć do oznaczenia punktu danych tworzącego wykres.

TABELA 6.3. Wybrane style markerów

KOD	STYL	KOD	STYL
'o'	Kółko 	'P'	Duży pogrubiony plus 
's'	Kwadrat 	's'	Gwiazdka 
'*'	Gwiazdka 	'D'	Diamant równomierny 
'x'	Symbol X 	'1'	Drzewko 
'X'	Symbol X wypełniony 	'p'	Pięciobok 
'+'	Plus 	'H'	Sześciobok 
'v'	Trójkąt w dół 	'^'	Trójkąt w górę 
'<'	Trójkąt w lewo 	'>'	Trójkąt w prawo 

Popatrz na przykładowe zastosowanie wybranej kombinacji tych parametrów. Użyjemy tu nieco zmodyfikowanego zbioru danych, który nie jest posortowany „parami”. Dlatego w celu uzyskania ładnego wykresu, narysowanego jednym pociągnięciem kreski „od lewej do prawej”, przerzucimy się na tablice NumPy, które posortujemy przed użyciem (*matplotlib.py*):


```
import numpy as np
from matplotlib import pyplot as plt
# Tablice par wartości do wykresu, nieposortowane
osX = np.array([10, -20, -30, 20, 34, 45, 60, 70, 90, 100])
osY = np.array([5, -5.6, -8, 9, 11, 20, 10, 12, 10, 9.5])
posortowane_indeksy = np.argsort(osX) # Sortowanie indeksów
# Sortowanie osX i osY za pomocą posortowanych indeksów:
x_sort = osX[posortowane_indeksy]
y_sort = osY[posortowane_indeksy]
plt.scatter(x_sort, y_sort, color='grey', s=50) # s — rozmiar kropki
plt.plot(x_sort, y_sort,
         marker='*', # Styl markera (tu: symbol gwiazdki)
         linestyle='--', # Styl linii (tu: kreskowana)
         color='k', # Kod koloru (tu: czarny)
         ms=10, # Rozmiar markera
         linewidth = '1') # Grubość linii
```

```
plt.axhline(0, color='c', linestyle='--') # Dodatkowa linia pozioma dla Y = 0
plt.axvline(0, color='g', linestyle='--') # Dodatkowa linia pionowa dla X = 0
plt.show()
```

Wykres dodatkowo wzbogaciłem liniami: poziomą (dla $Y = 0$) i pionową (dla $X = 0$). Taki zabieg ułatwi odczyt wartości.

Rysunek 6.2 pokazuje wynik uruchomienia programu.

RYSUNEK 6.2.
Style linii i markery
w akcji



Wykresy wielokrotne

Wiele wykresów komponuje się w celu porównania kilku serii danych, co oczywiście jest wspierane przez Matplotlib. Możliwość dołożenia nowego wykresu do poprzedniego polega na *kolejnym wywołaniu funkcji kreślącej plot()*. Warto w tym momencie dodać kilka ozdobników, których użycie pokażę na prostym przykładzie:

- własny tytuł wykresu,
- etykiety osi,
- legenda,
- znormalizowanie wartości na osi X (zamiast wypisywać wszystkie liczby, utworzymy pięć etykiet w zakresie od wartości *min* do *max*).

A zatem do dzieła (*matplot2.py*)!

```
from matplotlib import pyplot as plt
osX=[10, 20, 30, 40, 50, 60, 70, 80, 90, 100]
osY =[5, 5.6, 8, 9, 11, 20, 14, 12, 10, 9.5]
osY2=[2, 3, 6, 9, 12, 13, 16, 14, 12, 12]
serial1=plt.plot(osX, osY, marker='*', linestyle='--', color='k',
                 ms=10, linewidth = '1', label='Seria 1.') # Seria 1.
serial2=plt.plot(osX, osY2, marker='o', linestyle='-', color='k',
                 ms=10, linewidth = '1', label='Seria 2.') # Seria 2.
```

```
plt.legend(handles=[serial1, serial2])
plt.title("Pomiary napięcia")
plt.xlabel("[t] - czas")
plt.ylabel("[V] - napięcie")
# Znormalizowana lista z pięcioma wartościami od min(osX) do max(osX)
lista_do_etykiet_X = np.linspace(min(osX), max(osX), 5) # (*)
# Zaokrąglanie do liczb całkowitych:
lista_do_etykiet_X = np.around(lista_do_etykiet_X).astype(int)
plt.xticks(lista_do_etykiet_X) # Normalizacja wartości na osi X
plt.show()
```

Dość specyficzna składnia użyta powyżej (przecinek po nazwie zmiennej `serial1`) wynika z konstrukcji klasy `pyplot` w `Matplotlib` i wymagań wobec określonych typów danych używanych do przekazywania wartości koniecznych do zbudowania tekstu legendy. Chcemy bowiem zwrócić typ `tuple` zamiast pojedynczej wartości. Ponieważ `plt.plot` zwraca pojedynczą zmienną dla linii wykresu, to dodając przecinek po nazwie zmiennej, uzyskamy `tuple` z jednym elementem, co jest konwencją często stosowaną w Pythonie. W naszym kodzie bowiem `plt.legend()` oczekuje argumentów w formie `tuple`li.

Wiersz oznaczony (*) zastępuje dziesięć wartości występujących na osi *X*:

```
osX=[10, 20, 30, 40, 50, 60, 70, 80, 90, 100]
```


ich mniejszą liczbą (pięć), na dodatek są one rozłożone równomiernie, zaczynając od wartości najmniejszej (10) i kończąc na największej (100), co czyni wykres bardziej czytelnym. Ta sztuczka może się też przydać do opisowej zmiany jednostek. Ponadto wartości są zaokrąglone do liczb całkowitych.

Możliwość modyfikacji etykiet na osiach jest bardzo użyteczna. Na przykład gdyby wartości osi *X* były znacznikami daty i czasu, to zamiast nich można by dać czytelne etykiety zakresu, np. nazwy dni tygodnia, kwartały.

Dla naszych danych efekt końcowy jest bardzo czytelny i miejmy nadzieję, że (jak by to powiedział ktoś z młodszego pokolenia Polaków) *aesthetic* (rysunek 6.3).

RYSUNEK 6.3.

Wykresy wielokrotne



Popularne miary statystyczne

Zanim przystąpisz do jakiegokolwiek próby analizy danych, koniecznie odśwież sobie poniższe pojęcia. Nie są one zbyt skomplikowane, ale warto je dobrze rozumieć.

- **Mediana** to środkowy punkt całego zakresu danych, gdybyśmy je posortowali w kolejności.
- **Średnia arytmetyczna** to suma wszystkich wartości podzielona przez ich liczbę.
- **Moda** nie ma nic wspólnego z pokazami w Paryżu; w statystyce to po prostu liczba najczęściej występująca w zbiorze danych.

Przykład dla zbioru 13 liczb [5, 6, 10, **12, 12, 14, 14**, 18, 20, 22, 25, 30, 40]:

Mediana: środkową wartością jest liczba 14. W przypadku parzystej liczby wartości mediana byłaby średnią arytmetyczną dwóch wartości w środku, np. dla serii 10, 12, 14, 20 byłoby to $(12+14):2 = 13$.

Średnia arytmetyczna: $(5+6+10+12+12+14+14+18+20+22+25+30+40):13 = 19$.

Moda: 12 i 14.

- **Wariancja** to średnia arytmetyczna kwadratów różnic między każdą wartością a średnią.
- **Odchylenie standardowe (σ)** to pierwiastek kwadratowy z wariancji. Odchylenie standardowe (ang. *standard deviation*) jest popularną miarą rozproszenia danych wokół średniej. Oznacza ono średnią odległość punktów danych od średniej arytmetycznej całego zestawu danych. Im większe odchylenie standardowe, tym dane są bardziej skoncentrowane wokół średniej. Liczymy je w następujący sposób: dysponując ciągiem n wartości i umawiając się, że x_i to poszczególne wartości, a μ to średnia arytmetyczna, otrzymamy urokliwy wzorek:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}}$$

Hm, a miało być mało wzorów... Ale ten jest naprawdę prosty i warto go znać, chyba nawet bardziej niż $E = mc^2$ (Albercie, wybacz mi tę profanację!).

Oto przykład obliczeniowy:

Zbiór: [4, 10, 12, 14, 20, 30].

Średnia: $(4 + 10 + 12 + 14 + 20 + 30) : 6 = 15$.

Wariancja: $(4 - 15)^2 + (10 - 15)^2 + (12 - 15)^2 + (14 - 15)^2 + (20 - 15)^2 + (30 - 15)^2 = 121 + 25 + 9 + 1 + 25 + 225 = \frac{406}{6} \approx 67,67$.

Odchylenie standardowe dla powyższych danych to pierwiastek kwadratowy z wariancji, czyli ok. 8,23.


Rozkład normalny warto znać!

Z premedytacją unikam w tej książce nadmiaru aparatu matematycznego i używania pojęć o zacięciu naukowym, ale termin **rozkład normalny** przewija się często w ML i powinniśmy go dobrze rozumieć.

Otóż rozkład normalny, zwany też rozkładem Gaussa, jest jednym z najważniejszych rozkładów prawdopodobieństwa w statystyce i analizie danych. Na wykresie charakteryzuje się cechami podsumowanymi na rysunku 6.4.

RYSUNEK 6.4.

Co to jest rozkład normalny?



W takim rozkładzie większość obserwacji skupiona jest wokół średniej, a rozkład danych jest symetryczny względem średniej (kształt zbliżony do dzwonu, z gładko opadającymi skrzydłami po obu stronach). Jest on zbudowany po wcześniejszym określeniu dwóch parametrów zbioru (zob. poprzedni podpunkt):

- Średnia (μ , *mikro*) — gdzie znajduje się szczyt krzywej?
- Odchylenie standardowe (σ , *mała sigma*) — jak „zbity” lub „rozciągnięty” jest rozkład wokół średniej?

Co ciekawe, mimo że jest to model matematyczny, zaobserwowano, że pasuje on też do wielu zjawisk występujących w naturze lub w danych empirycznych. Metryki tego rozkładu określają, że np. 68% obserwacji znajduje się w obrębie jednego odchylenia standardowego od średniej, 95% mieści się w dwóch odchyleniach standardowych, a 99,7% mieści się w trzech odchyleniach standardowych. Do tej interesującej właściwości jeszcze powrócimy.

Popularne wykresy analizy danych

Matplotlib oferuje nie tylko wykresy liniowe lub punktowe. Podczas pracy z dużymi tablicami, liczącymi setki lub tysiące wierszy, zachodzi często potrzeba przeprowadzenia nieskomplikowanych analiz rozkładu danych, co wymaga np. wyliczania sum częściowych wyników zebranych w danej kategorii. Analityka danych zainteresują też wizualizacje rozkładów statystycznych. Zapoznajmy się więc ze sposobami tworzenia kilku charakterystycznych typów wykresów, które doskonale nadają się do takich celów (słupkowe, histogramy i inne).

Wykresy słupkowe

W tym punkcie omówię sposób prezentowania danych w formie wykresu słupkowego (ang. *bar chart*). Analizując ten przykład, nauczysz się następujących elementów:

- używania innych serii danych niż liczbowe;
- definiowania wykresu słupkowego i ustalania stylu słupków;
- normalizowania wartości na osi Y.

W przypadku wykresu słupkowego do każdej kategorii musi być przypisana jedna wartość lub zestaw wartości (seria danych) — taki właśnie przykład pokażę dalej. Będziemy używali pięciu kategorii i trzech serii danych, każda z nich będzie zawierała pięć wartości, które będą reprezentowane przez słupki w każdej z pięciu kategorii. Oprócz kolorów, w bibliotece Matplotlib dostępne są różne desenie, które można wykorzystać do wypełnienia słupków poprzez ustawienie parametru `hatch` (tabela 6.4).


TABELA 6.4. Style deseni dostępne w Matplotlib

KOD	STYL
'/'	Linie ukośne
'\'	Linie ukośne w przeciwnym kierunku
' '	Linie pionowe
'-'	Linie poziome
'+'	Krzyżyki
'x'	Krzyżyki skośne
'o'	Kropki
'.'	Małe kropki
'*'	Gwiazdki
'0'	Duże kropki
'//'	Linie podwójne ukośne
'\\ '	Linie podwójne pionowe

Spójrzmy na przykładowy program. Użyta w kodzie funkcja `tight_layout()` automatycznie dostosowuje rozmiar elementów na wykresie, tak aby zapewnić, że nie nachodzą one na siebie, i aby całość była czytelna. Pomaga to uniknąć sytuacji, w której elementy (tytuły, etykiety osi itp.) są przycięte lub nachodzą na siebie, co może pogorszyć czytelność wykresu (*matplotlib3.py*).

```
import matplotlib.pyplot as plt
# Dane do wykresu
kategorie = ['A', 'B', 'C', 'D', 'E']
seria_1 = [13, 40, 56, 80, 34]
seria_2 = [20, 32, 60, 68, 32]
seria_3 = [12, 28, 40, 55, 20]
szer = 0.25 # Szerokość słupka
# Słupki dla pierwszej serii danych
plt.bar([x - szer for x in range(len(kategorie))], seria_1, width=szer, label='Seria 1.',
        hatch='\\', color='grey')
# Słupki dla drugiej serii danych
plt.bar(range(len(kategorie)), seria_2, width=szer, label='Seria 2.', hatch='|',
        color='green')
# Słupki dla trzeciej serii danych
plt.bar([x + szer for x in range(len(kategorie))], seria_3, width=szer, label='Seria 3.',
        hatch='/', color='pink')
# Dodanie tytułu i etykiet osi
plt.title('Wykres słupkowy dla trzech serii danych i pięciu kategorii')
plt.xlabel('Kategorie')
plt.ylabel('Wartości')
plt.xticks(range(len(kategorie)), kategorie) # Ustawienie etykiet na osi X (*)
plt.legend()
plt.tight_layout()
plt.show() # Wyświetlenie wykresu
```

Efekt końcowy jest bardzo czytelny (rysunek 6.5).



RYСУNEK 6.5. Wykres słupkowy

Jak łatwo zauważyć, funkcję umownej osi *X* pełni tu zbiór etykiet, czyli nazwy kategorii testów, a wyniki na osi *Y* są wyśrodkowane względem tych etykiet.

Jeśli uruchomisz program bez wiersza oznaczonego gwiazdką, to na osi pionowej zostaną wyświetlone liczby 0, 1, 2, 3 i 4 (indeksy kategorii). Stąd zastosowana normalizacja etykiet na tej osi (metoda `xticks()`).

Histogramy

Histogram dzieli zakres wartości danych na kilka równych przedziałów i przedstawia *liczbę obserwacji* należących do każdego przedziału za pomocą słupków. Histogramy zbliżają nas jeszcze bardziej do analizy statystycznej, pomagając zrozumieć dystrybucję (rozkład) danych według ich wartości. O ile w przypadku małych zbiorów danych łatwo to zobaczyć, analizując surowe dane, gdzie widać, które wartości są bardziej popularne, a które występują rzadziej, o tyle w przypadku tabeli z np. tysiącem wartości ocena na trybie „na oko” mogłaby prowadzić do błędów i konieczności wizyty u optyka!

Podsumowując, w histogramie:

- oś *X* reprezentuje zakres wartości danych podzielony na przedziały (tzw. kubelki, ang. *bin*);
- oś *Y* reprezentuje liczbę obserwacji w każdym przedziale.

Histogramy są intuicyjnie łatwe do przyswojenia i bardzo przydatne do zrozumienia rozkładu danych oraz występujących w nich wzorców (kształt, tendencje do grupowania, obecność wartości odstających — ang. *outlier*). Histogramy dobrze uwypuklają wszelkie asymetrie rozkładu.


Popatrzmy zatem, jak tworzy się wykres typu histogram przy użyciu biblioteki Matplotlib. Założmy, że mamy zebranych 17 wyników dość podobnych do siebie i chcemy utworzyć histogram, który je przanalizuje i pokaże, które z nich występują częściej, a które rzadziej — niech wykres rozrzuci te podsumowania na dziesięć umownych „kubelków” (*matplotlib4.py*).

```
from matplotlib import pyplot as plt
import numpy as np
t=np.array([10,10,10,10,30,40,40,50,70,70,80,80,80,80,100,100, 100])
# Tworzenie histogramu i pobranie informacji o krotnościach
counts,bins,_=plt.hist(t, bins=10, color='orange', edgecolor='black')
# Obliczanie środków kubelków
bin_centers = 0.5 * (bins[:-1] + bins[1:])
# Ustawienie etykiet na osi X na granicach kubelków
plt.xticks(bins)
# Ustalanie zakresu etykiet na osi Y zgodnie z rzeczywistymi krotnościami
plt.yticks(np.arange(0, max(counts) + 1, step=1))
plt.xlabel('Wartość zmiennej')
plt.ylabel('Liczba wystąpień')
plt.show() # Wyświetlenie histogramu
```

Efekt końcowy pokazuje rysunek 6.6.

RYSUNEK 6.6.

Histogram ułatwia analizę rozkładu wartości danych w serii



Jak łatwo zauważyć, funkcję umownej osi X pełni tu z góry ustalona liczba „kubelków”, czyli zakresów wartości, natomiast na osi Y możemy odczytać liczbę wartości zliczonych dla bieżącego kubelka (np. 4 wartości dla pierwszego zakresu, 3 dla ostatniego).

Wykres skrzypcowy

Wykres skrzypcowy (ang. *violin plot*) jest podobny do histogramu, ale daje dodatkowe informacje o gęstości rozkładu danych, czyli stanowi połączenie informacji, które można odczytać z histogramu i z wykresu pudełkowego. Wykres ten pokazuje rozkład danych w sposób zbliżony do histogramu i gęstość prawdopodobieństwa w różnych przedziałach wartości.


Wynikowy wykres skrzypcowy pokaże rozkład wartości danych zbioru wejściowego i można go wyświetlić pionowo lub poziomo. Każdy „skrzypek” reprezentuje rozkład wartości w danym przedziale. Użyjmy teraz nieco innego zbioru danych o odmiennym rozkładzie (*matplotlib5.py*):

```
import numpy as np
import matplotlib.pyplot as plt
t=np.array([-10,-5,0,10,12,15,17,60,65,70,80,80,80,80,85,86,90])
plt.violinplot(t, vert=True)
plt.ylabel('Wartości')
plt.title('Wykres skrzypcowy')
plt.show()
```

Popatrz, co wyświetli program po uruchomieniu (rysunek 6.7).

Kreski na początku i końcu obszaru skrzypcowego oznaczają minimalną i maksymalną wartość w tym przedziale danych.

RYСУNEK 6.7.
Wykres skrzypcowy




W układzie pionowym (`vert=True`) oś Y reprezentuje wartości zmiennych w analizowanym zbiorze danych, a nie gęstość rozkładu wartości. Im wyższy punkt na osi Y w danym obszarze, tym wyższe są wartości danych w tym przedziale. Natomiast szerokość obszaru dla danej wartości na osi Y pokazuje na osi X, jak gęsto są skupione wartości danych wokół tej wartości. U nas występują dwa główne skupiska wartości. Pierwsze skupisko, które jest szersze, występuje w okolicach wartości 80, drugie, mniejsze skupisko znajduje się nieco niżej i również jest szerokie, co oznacza gęste skupienie danych wokół tej niższej wartości. Zawężenie skrzypiec w okolicach 40 sugeruje mniejszą gęstość danych w tym przedziale.

Wykres skrzypcowy nadaje się do wizualizacji tzw. zbiorów wielomodalnych, w których występują grupy danych i dla każdej z nich osobno można zidentyfikować parametry rozkładu i najczęściej występujące wartości.

Przykład zawarłem w pliku *matplotlib6.py* (musisz mieć zainstalowaną bibliotekę *seaborn*):

```
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
t = np.array([-80, -50, 0, 10, 12, 15, 17, 60, 65, 70, 80, 80, 80, 180, 185, 186, 190,
200, 220, 250, 200, 320, 350, 370, 600, 650, 700, 800, 800, 800, 800, 850, 960, 1200])
fig, axes = plt.subplots(1, 2, figsize=(14, 6)) # Podwykresy
axes[0].scatter(np.arange(len(t)), t, color='green', label='Wykres punktowy')
axes[0].set_title('Wykres punktowy')
axes[0].set_xlabel('X')
axes[0].set_ylabel('Wartość')
axes[0].legend()
sns.violinplot(ax=axes[1], data=t, inner='quartile') # Wykres skrzypcowy w seaborn
axes[1].set_title('Wykres skrzypcowy')
axes[1].set_xlabel('Rozkład')
axes[1].set_ylabel('Wartość')
plt.tight_layout() # Wyświetlenie wykresów
plt.show()
```

Efekt zobaczymy na rysunku 6.8, na którym wyświetliłem obok siebie wykresy punktowy i skrzypcowy dla danych zawartych w skrypcie. Wykrycie w takim zestawie, zwłaszcza jeśli jest bardzo liczny, zbioru bi- lub N-modalnego jest łatwiejsze na wykresie skrzypcowym (wystarczy zidentyfikować dwa „pagórki” danych).



RYСУNEK 6.8. Połączenie wykresu punktowego ze skrzypcowym wzbogaca możliwość analizy zbiorów danych

Wykres pudełkowy

Wykres pudełkowy (ang. *boxplot*) wygląda na wyższą szkołę jazdy, z nieujawnionej jeszcze przez serwisy streamingowe serii „Szybcy i wściekli analitycy danych”, ale po przyjrzeniu się okazuje się możliwy do opanowania także przez laików.

Spójrz na kod z przykładu *matplotlib7.py*:


```
import matplotlib.pyplot as plt
import numpy as np
# Przykładowe dane
t = np.array([-35, -30, 10, 10, 35, 40, 40, 50, 70, 70, 80, 80, 80, 80, 100, 100, 100,
190, 200])
# Tworzenie wykresu pudełkowego
plt.boxplot(t)
# Dodanie tytułu i etykiety osi
plt.title('Wykres pudełkowy')
plt.ylabel('Wartości')
plt.axhline(0, color='c', linestyle='--') # Linia pozioma dla Y = 0
plt.show() # Wyświetlenie wykresu
```

Ten nieskomplikowany skrypt wyświetli wykres pokazany na rysunku 6.9.

Jak go zinterpretować?

- Prostokątna skrzynka (pudełko) oraz linie (wąsy) reprezentują rozkład wartości obserwacji w zbiorze danych.
- Dolna krawędź pudełka reprezentuje pierwszy kwartył (Q1), czyli 25. percentyl danych. (Percentyl to miara pozycji w rozkładzie statystycznym, która określa, jaki procent danych znajduje się poniżej danej wartości).

RYСУNEK 6.9.
Wykres pudełkowy



- Środkowa linia pudełka reprezentuje medianę (drugi kwartył, Q2), czyli 50. percentyl danych (50% danych znajduje się poniżej wartości mediany).
- Górna krawędź pudełka reprezentuje trzeci kwartył (Q3), czyli 75. percentyl danych.
- Wysokość pudełka to zakres między pierwszym a trzecim kwartylem (ang. *interquartile range*, IQR), czyli odległość między dolną a górną krawędzią pudełka.
- Dolny wąs reprezentuje dolną granicę danych (niebędących outlierami), zazwyczaj $1,5 \cdot \text{IQR}$ poniżej pierwszego kwartyła.
- Górny wąs reprezentuje górną granicę danych (niebędących outlierami), zazwyczaj $1,5 \cdot \text{IQR}$ powyżej trzeciego kwartyła.
- Wartości poza granicami wąsów są potencjalnymi outlierami.
- Punkty znajdujące się poza granicami wąsów są uważane za odstające (outliery) i mogą wskazywać na wartości nietypowe lub błędy pomiarowe w danych.

Uff... Ale pomijając już pierwszy szok poznawczy, na pewno zgodzisz się, że ten wykres w interesujący sposób prezentuje rozkład danych i ułatwia analizę pod kątem anomalii rozkładu (zbyt duże koncentracje) oraz identyfikację wartości odstających, tzw. *outlierów*. To właśnie nietypowe, odstające wartości mogą łatwo popsuć jakość modelu ML (np. regresji).

Mapa cieplna

Wykres zwany mapą cieplną (ang. *heatmap*) wykorzystywany jest do prezentacji macierzy danych wizualizujących wartości numeryczne za pomocą kolorów. Jest to przydatne do analizy korelacji między zmiennymi. Każdy wiersz w macierzy danych odpowiada jednej serii danych. Każdy element wiersza reprezentuje wartość w danej serii w konkretnym punkcie danych.


Popatrzmy na przykład (*matplotlib8.py*):

```
import numpy as np
import matplotlib.pyplot as plt
# Przykładowe serie po 10 wartości
data = np.array(
    [[1, 2, 2, 3, 5, 5, 5, 5, 6, 7],
     [6, 6, 7, 7, 8, 9, 15, 15, 15, 20],
     [11, 11, 13, 14, 15, 15, 15, 15, 16, 25],
     [2, 3, 3, 4, 5, 6, 11, 12, 13, 15],
     [11, 12, 13, 14, 15, 16, 17, 18, 19, 20]]
)
# Tworzenie mapy cieplnej
plt.imshow(data, cmap='hot', interpolation='nearest')
# Dodanie deseni do poszczególnych punktów danych
for i in range(data.shape[0]):
    for j in range(data.shape[1]):
        plt.text(j, i, str(data[i, j]), ha='center', va='center', color='white')
# Dodanie kolorowej skali
plt.colorbar()
plt.xlabel('Punkty danych')
plt.title('Mapa cieplna (ang. heatmap)')
plt.show() # Wyświetlenie mapy cieplnej
```

Nasz skrypt wyświetli wykres pokazany na rysunku 6.10.

RYСУNEK 6.10.

Mapa cieplna



Widać, że dla pierwszej serii danych wartości są niskie (ciemne kolory), a dla ostatniej są wyraźnie cieplejsze. Na wykresie, oprócz samej kolorowej mapy cieplnej, dodałem też desenie do każdej jej komórki, wyświetlając wartość danej liczbowej w środku każdej komórki (nie zawsze się to sprawdza i w swoich programach możesz pominąć ten element szablonu kodu). Desenie są białe, co pomaga je czytelnie wyświetlić na tle kolorowego tła mapy cieplnej.

Podręcznik Matplotlib na bezludną wyspę?

Tak jak wspomniałem, dokumentacja Matplotlib jest olbrzymia i nie da się jej powielić w sposób racjonalny. Dlatego aby wytłumaczyć filozofię używania tej biblioteki, postanowiłem zaznajomić Cię z kilkoma schematami tworzenia i upiększania wykresów. Autorzy oferują też podręcznik PDF, który znajdziesz pod adresem <https://matplotlib.org/Matplotlib.pdf> — załaduj na dysk dokument zajmujący już niemal 5000 stron (to nie jest żart).

Oczywiście nie musisz go drukować w celu zabrania na bezludną wyspę, jeśli takie masz plany życiowe. Wystarczy, że wyspa znajduje się w zasięgu internetu — wówczas wystarczy zapisać w przeglądarce zakładkę <https://matplotlib.org> i sięgać tam w razie potrzeby do wersji bieżącej (odsyłacze *Tutorials*, *User guide*). Alternatywnie zajrzyj na stronę <https://matplotlib.org/stable/users/index> i przeanalizuj gotowe wzorcowe skrypty budujące wykresy różnych typów. Do czego gorąco zachęcam, bo efekty mogą się okazać spektakularne!

Skorowidz

`_add_`, 37
`_mul_`, 37
`_sub_`, 37
`_truediv_`, 37

A

accuracy_score, 290
add(), 117
AI, 7
Alexa, 17
algorytm centroidów, 272, 280
Anakonda, 46
analiza
 anomalii, 269
 danych, 122
 obrazów, 271
 podobieństwa, 157
 skupień, 39, 269
ankieta.xlsx, 266
ankieta-gracze.xlsx, 287
ankieta-gracze.xlsx, 287
ankieta-gracze-wiek.xlsx, 288
Anscombe, Francis J., 227
API, 27, 184
apply(), 137
arange(), 114
autokorelacja, 231
autoupdate.log, 86

B

Bard, 44
Barnard, Frederick R., 270
BeautifulSoup, 196
BERT, 12
bezpieczeństwo klucza, 188
bin, *Patrz* kubełek
Blade Runner, 18
błąd I rodzaju, 144

błąd II rodzaju, 144
Brackets, 53
breakpoint, 54

C

Cao, 288
CBOW, *Patrz* Continuous Bag of Words
CCTV, 20
cecha, 149
cechy, 141
chatbot, 20
ChatGPT
 rola, 179
 dłuższe sesje, 190
ChatGPT0.py, 189
ChatGPT1.py, 191
ChatGPT2.py, 198
ChatGPT3.py, 200
ChatGPT4.py, 202
Chomski, Noam, 44
color, 207
ColumnTransformer, 263
complex128, 115
complex64, 115
Continuous Bag of Words, 160
Copilot, 17
count(), 138
CSV, 110, 128
cyberbezpieczeństwo, 271

D

dane katagoryczne, 285
dane2D.xlsx, 275
dane3.csv, 138
dane3D.xlsx, 283
DataFrame, 123, 126
datetime64, 126
DBSCAN, 273

debugger, 54
DecisionTreeClassifier, 265
deep learning, 43
dekorator, 36
dendrogram, 278
describe(), 251
description_stats.csv, 251
dir, 50
divide(), 117
dokumentacja Pythona, 67
drop_duplicates(), 133
dtype, 114, 126

E

edytory do Pythona, 53
egzamin.xlsx, 255
embedding, 162
embeddings, 180
estymator, 150, 242
ETL, 91
etykieta, 149
Excel, 128
 import do Pandas, 131

F

F1 (wskaźnik), 146
false negative, 144
false positive, 144
Fastai, 44
fillna(), 134
findstr, 85
fit (metoda), 150
fit(), 242
float16, 115
float32, 115
float64, 115
folium, 240

G

Galton, Francis, 222
 Gemini, 44
 GenAI, 176
 generatywna AI, 7
 generowanie treści, 39
 Gensim, 42
 GET, 184
 get_dummies(), 260, *Patrz też* one-hot (kodowanie)
 git, 69
 GitHub, 69
 GMM, 273
 GPT, 12, 177
 GPT-4o, 193
 GPU, 7, 25
 grafy, 31
 grep, 85
 groupby(), 138
 grupowanie, 39
 gry komputerowe, 21

H

halucynacja w GenAI, 180
 heatmap, 219
 histogram, 215
 homoscedastyczność, 231
 hstack(), 119
 HTTP, 184
 Huang, 288

I

IDLE, 54
 iloczyn skalarny, 182
 import, 37
 danych, 128
 info(), 129
 instalowanie pakietów, 52
 int16, 115
 int32, 115
 int64, 115
 inteligencja, 19
 intercept, *Patrz* wyraz wolny
 interfejs programistyczny, 27
 inżynieria zapytań, 179
 IQR, 219
 IterativeImputer, 261

K

Kant, Immanuel, 269
 kategor.py, 286
 kategoriyczne (cechy), 257, 285
 KDE, 235
 Keras, 43, 268
 klasa.py, 34
 klast0.py, 275
 klast1.py, 280, 290
 klast2.py, 284, 290
 klast3.py, 287
 klast4.py, 289
 klasteryzacja, 39, 269
 klastrowanie hierarchiczne, 272, 274
 klasy, 33
 klasyf0.py, 249
 klasyf1.py, 251
 klasyf2.py, 253
 klasyf3.py, 255
 klasyf4.py, 261
 klasyf5.py, 263
 klasyf6.py, 266
 klasyfikacja, 39, 163
 binarna, 141
 wieloklasowa, 141, 168, 265
 klasyfikacja0.py, 151, 154
 klasyfikacja1.py, 165
 klasyfikacja2.py, 166
 klasyfikacja3.py, 169
 klucz API, 186
 K-Means, 272, 280
 K-modes, 272, 287
 K-najbliższych sąsiadów, 261
 KNNImputer, 261
 konstruktor, 35
 kontroler wyводу, 23
 korekta typów danych, 135
 korpus językowy, 92, 162
 K-prototypes, 272, 288
 kubełek, 215
 kwartet Anscombe'a, 227
 kwartył, 218

L

Label Encoding, 285
 Large Language Model, 21
 LightGBM, 43

LinearSVC, 165
 linestyle, 207
 linewidth, 207
 listy, 29
 LLaMa, 12
 LlamaIndex, 195
 LLM, 106, 178, *Patrz też* Large Language Model
 LogisticRegression, 150, 222, 265
 ls, 50

M

machine learning, 17
 macierz konfuzji, 143, 244
 macierz.py, 146
 mapa (wykres Python), 240
 mapa cieplna, 219
 marker, 207
 matplotlib0.py, 205
 matplotlib1.py, 208
 matplotlib2.py, 209
 matplotlib3.py, 214
 matplotlib4.py, 215
 matplotlib5.py, 216
 matplotlib6.py, 217
 matplotlib7.py, 218
 matplotlib8.py, 220
 Matplotlib, 42
 Matrix, 18
 matryca-konfuzji.xlsx, 146
 max(), 115, 138
 mean(), 116, 138
 Mean-shift, 273
 median(), 138
 mediana, 211
 metody, 33
 Elbow, 274
 Łokcia, 274
 miara
 Hamminga, 287
 Levenshteina, 287
 Microsoft Bing, 44
 Microsoft Visual Studio, 64
 min(), 115, 138
 ML, *Patrz* machine learning
 MNIST, 268
 moda, 211
 mode(), 138
 model, 38, 150
 językowy, 160
 modelowanie prob, 28

MultinomialNB, 167
 multiply(), 117
 MYCIN, 23

N

nagroda Loebnera, 22
 najmniejszych kwadratów, 224
 NaN, 124, 130
 nauczanie
 maszynowe, 17
 nadzorowane, 39, 141
 nienadzorowane, 40, 271
 ndarray, 112
 negative(), 117
 niepodobieństwo, 287
 NLP, *Patrz* przetwarzanie języka naturalnego
 NLTK, 42, 93
 NLTK1.py, 98
 NLTK2.py, 102
 NLTK3.py, 173
 normalizacja min-max, 248
 normalizowanie osi wykresu, 209
 nowe-dane-SMS.csv, 156
 nowe-dane-SMS2.csv, 167
 NumPy, 41
 numpy1.py, 117, 119
 numpy2.py, 120
 numpy3.py, 121

O

object, 126
 odchylenie standardowe, 211, 248
 odległość kosinusowa, 180
 one-hot (kodowanie), 260, 285
 OOP, 33
 Open AI
 interfejs embeddings, 199
 konto, 184
 rodzaje kont, 185
 tuning modelu, 194
 openpyxl, 129, 234
 outlier, 215, 219, 237,
 Patrz też wartość odstająca
 outliers.xlsx, 252

P

Pandas, 41, 122
 import danych, 128
 pandas0.py, 124
 pandas1.py, 127, 128
 pandas2.py, 129, 131
 pandas3.py, 133
 pandas4.py, 139
 PDF1.py, 90
 PDF2.py, 91
 pdfplumber, 89
 percentyl, 218
 performance, 244
 pip, 49
 Pipeline(), 166
 pliki
 binarne, 72
 tekstowe, 72
 tryby otwarcia, 73
 pliki-wersja1.py, 75
 pliki-wersja2.py, 78
 pliki-wersja3.py, 80
 plot(), 111, 207, 209
 poprawność klasyfikacji, 144
 POST, 184
 power(), 117
 precyzja, 145
 predict (metoda), 150
 predict(), 242
 predyktor, 230, 243, *Patrz też* zmienna niezależna
 procesor graficzny, 7
 prognozowanie, 227
 prompt, 177
 prompt engineering, 179
 przekodowanie.xlsx, 286
 przetwarzanie języka naturalnego, 7
 punkt (NLTK), 173
 PyCharm, 58
 instalacja pakietów, 62, 63
 PyPDF2, 89
 PyTorch, 43, 268

Q

Quételet, Adolphe, 222

R

RAG, *Patrz* Retrieval-augmented generation
 random, 288
 RandomForestClassifier, 265
 ravel(), 119
 Real estate valuation data set.xlsx, 233
 reg0.py, 225
 reg1.py, 228
 reg2.py, 229
 reg3.py, 234
 reg4.py, 242
 regex1.py, 86
 regex2.py, 88
 regresja, 39, 141
 liniowa, 222
 logistyczna, 222
 reshape(), 118
 resize(), 119
 REST, 184
 Retrieval-augmented generation, 195
 RGB, 207
 Rozdział 1.ipymb, 66
 rozkład normalny, 212, 232
 rozkład Gaussa, *Patrz* rozkład normalny
 R-squared, *Patrz* współczynnik determinacji

S

scatter(), *Patrz* wykres punktowy
 scikit-learn, 148
 Scikit-learn, 43
 scikit-TF-TF-IDF.py, 164
 ScipPy, 226
 SciPy, 42
 seaborn, 204, 234
 segmentacja klientów, 271
 Series, 123
 setter, 36
 sieci neuronowe, 24
 similarity(), 157, 183
 Siri, 17
 skalowanie cech, 247
 Skip-gram, 160
 skorygowany współczynnik determinacji, 245

SMSSpamCollection-
-rozszerzony.csv, 152
SMS-wyniki2.csv, 167
solver (scikit-learn), 154
sort(), 116
sort_values(), 138
spaCy, 42, 92
Spacy1.py, 95
Spacy2.py, 100
Spacy3.py, 101
Spacy4.py, 103
Spacy5.py, 104
Spacy6.py, 157, 202
Spacy7.py, 161
Spectral Clustering, 273
specyficzność, 145
sqrt(), 117
standaryzacja, 248
stemming, 95
stop-word, 104, 173, 203
Sublime Text, 53
subtract(), 117
sum(), 115, 138
system ekspercki, 22
sztuczna inteligencja, 7
zastosowania, 20

Ś

średnia arytmetyczna, 211

T

tablice, 29
tablice0.py, 108
tablice1.py, 109
TensorFlow, 43, 268
Terminator, 18
test Turinga, 22
TextBlob, 170
TextBlob.py, 174
TF, 164
TF-IDF, 164

The 100 (film), 18
timedelta, 126
tokenizacja, 94, 182
towary.xlsx, 200
towary-analiza.xlsx, 200, 202
towary-indeksy.xlsx, 201
train_test_split(), 150, 242
transform(), 242
transpose(), 120
true negative, 143
true positive, 143
Twórca, 18

U

UC Irvine Machine
Learning Repository, 150, 232
uint16, 115
uint32, 115
uint64, 115
uint8, 115, 135
unfunc, 117

V

VADER, 170
VADER.py, 172
Vim, 53
vstack(), 120

W

walidacja krzyżowa, 146
wariancja, 211
wartość odstająca, 219, 229, 237, 251, *Patrz też*
outlier

WCSS, 276, 280
web scrapping, 195
wektor
osadzeń, 162, 180
słów, 180
wektoryzacja, 159
współczynnik
błędów, 144
czułości, 145
determinacji, 245
WWW.py, 197
wydajność modelu, 244
wykres, 205
liniowy, 205
pudełkowy, 218, 253
punktowy, 205, 223
skrzypcowy, 216, 253
słupkowy, 213
wielokrotny, 209
wyraz wolny, 223

X

XGBoost, 43

Z

zakresy.py, 121
zbiór szkoleniowy, 142
zespólone.py, 38
zespólone-main.py, 38
zestaw testowy, 142
zmiana układu tabeli, 136
zmienna
niezależna, 223, 230
zależna, 223

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

Wejść na nowy poziom programowania z ML i NLP

Sztuczna inteligencja stale się rozwija. Właściwie codziennie słyszymy o jej rosnących możliwościach, nowych osiągnięciach i przyszłości, jaką nam przyniesie. Jednak w tej książce skupiamy się nie na przyszłości, a na teraźniejszości i praktycznym obliczu AI — na usługach, które świadczy już dziś. Większość najciekawszych zastosowań sztucznej inteligencji bazuje na ML (uczenie maszynowe, ang. *machine learning*), NLP (przetwarzanie języka naturalnego, ang. *natural language processing*) i architekturze RAG (ang. *retrieval augmented generation*) zwiększającej możliwości tzw. dużych modeli językowych (LLM, ang. *large language model*). Stanowią one podwaliny budowy systemów AI, bez których te systemy często wcale nie mogłyby powstać.

Do niedawna ML i NLP pozostawały domeną badaczy i specjalistów — znajdowały się poza zasięgiem praktyków programowania. Aktualnie jest inaczej, szybkie komputery, pojemne pamięci RAM i zaawansowane procesory pozwalają stosować te technologie w codziennej pracy programisty. Szczególnie programisty języka Python, do którego są one niemal „naturalnie” przypisane. Mało tego, od kodujących w Pythonie coraz częściej wręcz wymaga się umiejętności znajomości obszaru AI.

Tym bardziej warto sięgnąć po ten podręcznik z ćwiczeniami, dzięki któremu między innymi:

- Dowiesz się, jak używać Pythona do rozwiązywania problemów AI
- Poznasz tajniki analizy tekstów, analizy sentymentu
- Zrozumiesz, jak skutecznie używać algorytmów klasyfikacji, regresji i grupowania do rozwiązywania problemów biznesowych
- Pokonwersujesz z ChatGPT — i to bez wchodzenia na stronę internetową tego serwisu

Helion 



helion.pl



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

KOD KORZYŚCI

Sięgnij po więcej! ▶



ISBN 978-83-289-1580-0



Cena: 79,00 zł