O'REILLY®

Wydanie II

# Uczenie maszynowe w Pythonie

## Receptury

### Od przygotowania danych do deep learningu

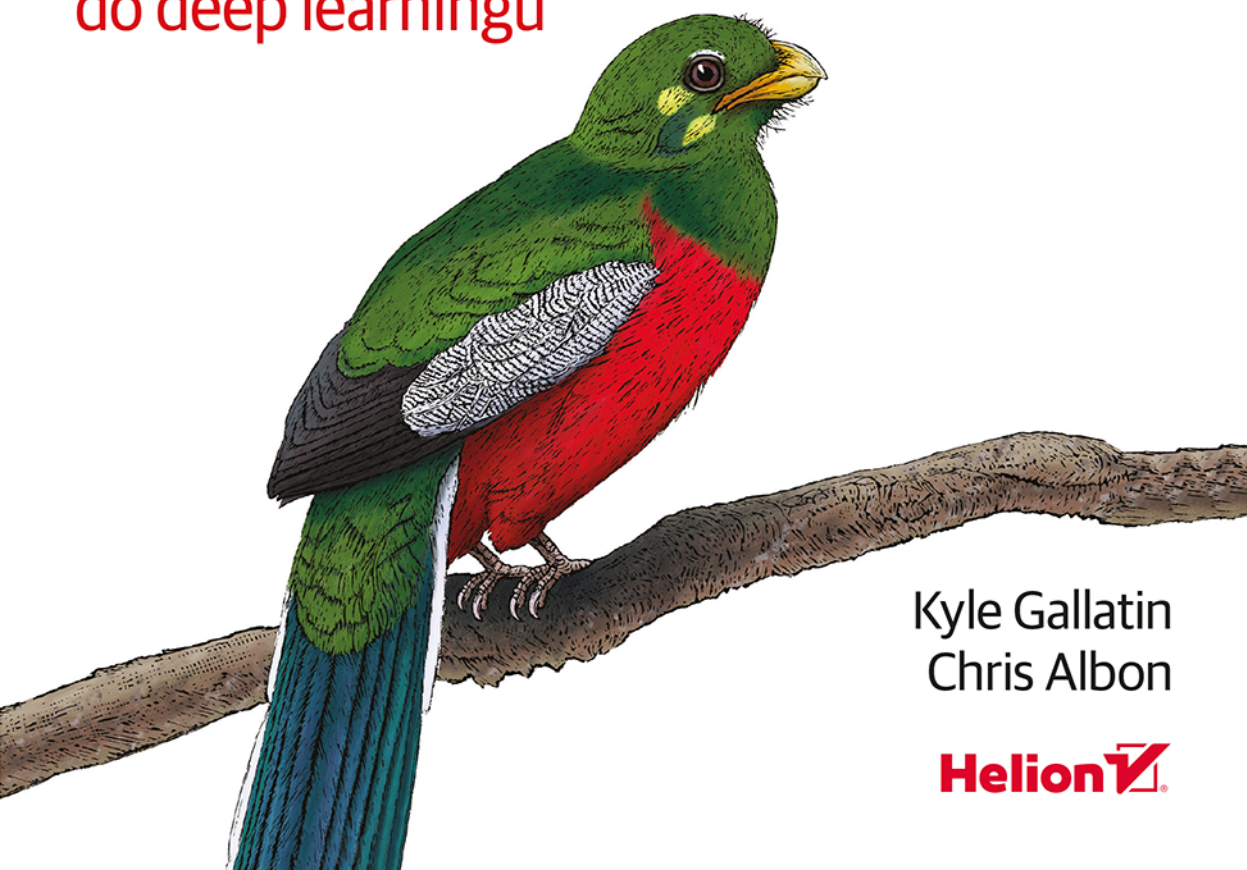

Kyle Gallatin
Chris Albon

Helion

Tytuł oryginału: Machine Learning with Python Cookbook: Practical Solutions from Preprocessing to Deep Learning, 2nd Edition

Tłumaczenie: Robert Górczyński

ISBN: 978-83-289-0811-6



Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
*https://helion.pl/user/opinie/uczma2*
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:
*https://ftp.helion.pl/przyklady/uczma2.zip*

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)

Printed in Poland.

# Spis treści

ROZDZIAŁ 3.

# Przygotowywanie danych

## 3.0. Wprowadzenie

**Przygotowywanie danych** (ang. *data wrangling*) to dość często używane pojęcie, najczęściej w celu opisania procesu przekształcenia niezmodyfikowanych danych na postać czystego i zorganizowanego formatu informacji gotowych do użycia. Dla nas to tylko jeden — choć zarazem niezwykle ważny — krok na etapie wstępnego przetwarzania danych.

Najczęściej wykorzystywaną strukturą stosowaną do przygotowywania danych jest tzw. ramka danych, która jest intuicyjna w użyciu i jednocześnie niezwykle elastyczna. Ramka danych ma postać tabelaryczną, co oznacza, że została oparta na wierszach i kolumnach, podobnie jak dane przechowywane w arkuszu kalkulacyjnym. Oto przykład ramki danych utworzonej na podstawie informacji o pasażerach Titanica:

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Umieszczenie wczytanych informacji w ramce danych.
dataframe = pd.read_csv(url)

# Wyświetlenie pierwszych pięciu wierszy.
dataframe.head(5)
```

Oto tabela pokazująca przykładowe dane wejściowe wczytane z pliku CSV:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.00 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.00 | female | 0 | 1 |
| **2** | Allison, Mr Hudson Joshua Creighton | 1st | 30.00 | male | 0 | 0 |
| **3** | Allison, Mrs Hudson JC (Bessie Waldo Daniels) | 1st | 25.00 | female | 0 | 1 |
| **4** | Allison, Master Hudson Trevor | 1st | 0.92 | male | 1 | 0 |

Trzeba zwrócić uwagę na trzy ważne kwestie dotyczące tej ramki danych.

Po pierwsze, każdy wiersz ramki danych odpowiada jednej obserwacji (tutaj jednemu pasażerowi), natomiast każda kolumna przedstawia jedną cechę — płeć, wiek itd. Na podstawie informacji zawartych w pierwszej obserwacji można powiedzieć, że panna Elisabeth Walton Allen podróżowała pierwszą klasą, w chwili katastrofy Titanica miała 29 lat, była kobietą i przeżyła katastrofę.

Po drugie, każda kolumna zawiera tytuł (na przykład `Name`, `PClass` i `Age`), zaś każdy wiersz ma numer indeksu (na przykład `0` dla panny Elisabeth Walton Allen, której dopisało szczęście). Dzięki tym danym można pobierać, a następnie przeprowadzać operacje na obserwacjach i cechach.

Po trzecie, dwie kolumny, `Sex` i `SexCode`, zawierają te same informacje, ale zapisane w różnych formatach. W kolumnie `Sex` płeć kobiety została zapisana jako `female`, natomiast w kolumnie `SexCode` kobieta została oznaczona liczbą całkowitą `1`. Ponieważ chcemy, aby wszystkie cechy były unikatowe, trzeba będzie usunąć jedną z tych kolumn.

W rozdziale przedstawię różne techniki przeznaczone do przeprowadzania operacji na ramkach danych za pomocą biblioteki pandas. Celem tych działań jest przygotowanie zbioru obserwacji o doskonałej strukturze, gotowego do dalszego wstępnego przetwarzania.

# 3.1. Tworzenie ramki danych

## Problem

Chcesz utworzyć nową ramkę danych.

## Rozwiązanie

Biblioteka pandas oferuje wiele metod przeznaczonych do tworzenia nowych ramek danych, czyli obiektów typu `DataFrame`. Jedna z nich pozwala na łatwe utworzenie ramki danych za pomocą słownika Pythona. W słowniku każdy klucz jest nazwą kolumny, zaś wartość listą. Poszczególne elementy słownika odpowiadają wierszom.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie słownika.
dictionary = {
    "Name": ['Jacky Jackson', 'Steven Stevenson'],
    "Age": [38, 25],
    "Driver": [True, False]
}

# Utworzenie obiektu typu DataFrame.
dataframe = pd.DataFrame(dictionary)

# Wyświetlenie obiektu DataFrame.
dataframe
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | Age | Driver |
|---|---|---|---|
| **0** | Jacky Jackson | 38 | True |
| **1** | Steven Stevenson | 25 | False |

Po utworzeniu obiektu `DataFrame` można na jego końcu dodawać nowe dane, używając do tego listy wartości, jak pokazałem w kolejnym fragmencie kodu.

```
# Dodanie kolumny opisującej kolor oczu.
dataframe["Eyes"] = ["Brown", "Blue"]

# Wyświetlenie obiektu DataFrame.
dataframe
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | Age | Driver | Eyes |
|---|---|---|---|---|
| **0** | Jacky Jackson | 38 | True | Brown |
| **1** | Steven Stevenson | 25 | False | Blue |

## Analiza

Można odnieść wrażenie, że biblioteka pandas oferuje niemal nieograniczoną liczbę sposobów na tworzenie obiektu typu `DataFrame`. W rzeczywistości do utworzenia pustego obiektu `DataFrame`, a następnie wypełnienia go danymi niemal nigdy nie dochodzi. Zamiast tego obiekt jest tworzony na podstawie rzeczywistych danych wczytanych z innego źródła, na przykład pliku CSV lub bazy danych.

# 3.2. Opisywanie danych

## Problem

Chcesz wyświetlić pewne cechy charakterystyczne obiektu `DataFrame`.

## Rozwiązanie

Jedną z najprostszych czynności, którą można wykonać po wczytaniu danych, jest wyświetlenie kilku pierwszych wierszy za pomocą metody `head()`.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Wyświetlenie dwóch pierwszych wierszy.
dataframe.head(2)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.00 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.00 | female | 0 | 1 |

Można też sprawdzić liczbę istniejących wierszy i kolumn.

```
# Wyświetlenie wielkości danych.
dataframe.shape
```

```
(1313, 6)
```

Metoda `describe()` dostarcza opisowe dane statystyczne dotyczące kolumn zawierających dane liczbowe.

```
# Wyświetlenie pewnych danych statystycznych.
dataframe.describe()
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Age | Survived | SexCode |
|---|---|---|---|
| **Count** | 756.000000 | 1313.000000 | 1313.000000 |
| **Mean** | 30.397989 | 0.342727 | 0.351866 |
| **Std** | 14.259049 | 0.474802 | 0.477734 |
| **Min** | 0.170000 | 0.000000 | 0.000000 |
| **25%** | 21.000000 | 0.000000 | 0.000000 |
| **50%** | 28.000000 | 0.000000 | 0.000000 |
| **75%** | 39.000000 | 1.000000 | 1.000000 |
| **Max** | 71.000000 | 1.000000 | 1.000000 |

Z kolei metoda `info()` wyświetla zwięzłe podsumowanie dotyczące wskazanego obiektu `DataFrame`:

```
# Wyświetlenie informacji.
dataframe.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1313 entries, 0 to 1312
Data columns (total 6 columns):
 #   Column    Non-Null Count  Dtype
---  ------    --------------  -----
 0   Name      1313 non-null   object
 1   PClass    1313 non-null   object
 2   Age       756 non-null    float64
 3   Sex       1313 non-null   object
 4   Survived  1313 non-null   int64
 5   SexCode   1313 non-null   int64
dtypes: float64(1), int64(2), object(3)
memory usage: 61.7+ KB
```

## Analiza

Po wczytaniu danych warto się zapoznać z ich strukturą i rodzajem przechowywanych w nich informacji. W idealnym świecie bezpośrednio przeglądane byłyby rzeczywiste dane. Jednak w większości sytuacji te dane mogą się składać z dziesiątek tysięcy, setek tysięcy lub nawet milionów wierszy i kolumn. Dlatego też trzeba pobrać jedynie próbki pozwalające na wyświetlanie niewielkich wycinków i obliczanie podsumowania danych statystycznych dotyczących tych informacji.

W omawianym tutaj rozwiązaniu użyłem niewielkiego zbioru danych przedstawiającego pasażerów Titanica znajdujących się na pokładzie w trakcie jego ostatniego rejsu. Metoda `head()` pozwala na przejrzenie kilku pierwszych (domyślnie pięciu) wierszy danych. Ewentualnie można użyć metody `tail()` do wyświetlenia kilku ostatnich wierszy. Wynikiem działania metody `shape()` jest liczba wierszy i kolumn przechowywanych we wskazanym obiekcie `DataFrame`. Z kolei metoda `describe()` dostarcza wybrane podstawowe dane statystyczne dotyczące wszystkich kolumn zawierających dane liczbowe. Natomiast metoda `info()` wyświetla pewną liczbę użytecznych informacji na temat wskazanego obiektu `DataFrame`, m.in. typy indeksu i kolumn danych, liczbę wartości innych niż null oraz poziom użycia pamięci.

Warto w tym miejscu dodać, że podsumowanie danych statystycznych nie zawsze przedstawia prawdziwy obraz przetwarzanych danych. Na przykład biblioteka pandas traktuje kolumny `Survived` i `SexCode` jako liczbowe, ponieważ zawierają one dane w postaci zer i jedynek. Jednak w omawianym przykładzie te wartości liczbowe przedstawiają kategorie. Dlatego też jeśli wartość kolumny `Survived` wynosi 1, to oznacza, że dany pasażer przeżył katastrofę Titanica. Pewne wygenerowane wartości w podsumowaniu danych statystycznych nie mają więc sensu — przykładem jest tutaj odchylenie standardowe dla kolumny `SexCode` określającej płeć pasażera.

# 3.3. Poruszanie się po ramce danych

## Problem

Musisz wybrać pojedyncze dane lub wycinek ramki danych.

## Rozwiązanie

Do pobrania jednego lub dwóch wierszy wartości użyj metody `loc()` lub `iloc()`.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Pobranie pierwszego wiersza.
dataframe.iloc[0]
```

```
Name        Allen, Miss Elisabeth Walton
PClass                              1st
Age                                  29
Sex                              female
Survived                              1
SexCode                               1
Name: 0, dtype: object
```

Dwukropek może zostać wykorzystany do zdefiniowania wycinka składającego się z żądanych wierszy. W kolejnym poleceniu pokazałem przykład wycinka obejmującego wiersze od drugiego do czwartego.

```
# Pobranie trzech wierszy.
dataframe.iloc[1:4]
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **1** | Allison, Miss Helen Loraine | 1st | 2.00 | female | 0 | 1 |
| **2** | Allison, Mr Hudson Joshua Creighton | 1st | 30.00 | male | 0 | 0 |
| **3** | Allison, Mrs Hudson JC (Bessie Waldo Daniels) | 1st | 25.00 | female | 0 | 1 |

Dwukropek może również zostać użyty do pobrania wszystkich wierszy do pewnego miejsca. W następnym przykładzie pokazałem przykład wycinka obejmującego wiersze od początku do czwartego włącznie.

```
# Pobranie wierszy do czwartego włącznie.
dataframe.iloc[:4]
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.00 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.00 | female | 0 | 1 |
| **2** | Allison, Mr Hudson Joshua Creighton | 1st | 30.00 | male | 0 | 0 |
| **3** | Allison, Mrs Hudson JC (Bessie Waldo Daniels) | 1st | 25.00 | female | 0 | 1 |

Ramki danych nie muszą być indeksowane liczbowo. Indeksem może być dowolna wartość unikatowa w poszczególnych wierszach. Na przykład jako indeksu można użyć nazwiska pasażera, a następnie pobierać wiersze za pomocą tego nazwiska.

```
# Zdefiniowanie indeksu.
dataframe = dataframe.set_index(dataframe['Name'])

# Wyświetlenie podanego wiersza.
dataframe.loc['Allen, Miss Elisabeth Walton']
```

```
Name        Allen, Miss Elisabeth Walton
PClass                              1st
Age                                  29
Sex                              female
Survived                              1
SexCode                               1
Name: Allen, Miss Elisabeth Walton, dtype: object
```

## Analiza

Wszystkie wiersze w obiekcie typu `DataFrame` biblioteki pandas muszą mieć indeks o unikatowej wartości. Domyślnie tym indeksem jest liczba całkowita wskazująca położenie danego wiersza w obiekcie. Można jednak zdefiniować zupełnie inny indeks. Może nim być unikatowy ciąg tekstowy lub liczba. Aby pobierać poszczególne wiersze i wycinki, biblioteka pandas oferuje dwie wymienione tutaj metody:

- `loc()` okazuje się użyteczna, gdy indeksem obiektu `DataFrame` jest etykieta, czyli na przykład ciąg tekstowy;
- `iloc()` działa przez wyszukanie położenia w obiekcie `DataFrame`. Dlatego też wywołanie `iloc[0]` zwróci pierwszy wiersz niezależnie od tego, jaką postać ma jego indeks.

Warto nabrać wprawy w pracy z obiema omówionymi tutaj metodami, ponieważ bardzo pomagają one podczas oczyszczania danych.

# 3.4. Pobieranie wierszy na podstawie pewnych warunków

## Problem

Chcesz pobrać wiersze ramki danych na podstawie pewnych warunków.

## Rozwiązanie

Ten problem można niezwykle łatwo rozwiązać za pomocą biblioteki pandas. Spójrz na przykład pokazujący, jak pobrać informacje o wszystkich kobietach znajdujących się na Titanicu.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Wyświetlenie dwóch pierwszych wierszy, w których kolumna 'Sex' ma wartość 'female'.
dataframe[dataframe['Sex'] == 'female'].head(2)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.00 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.00 | female | 0 | 1 |

Zatrzymaj się na chwilę i przyjrzyj formatowi użytemu w rozwiązaniu. Mamy tutaj polecenie warunkowe, `dataframe['Sex'] == 'female'`, opakowane konstrukcją `dataframe[]`. W ten sposób

nakazujemy bibliotece pandas pobranie wszystkich wierszy w ramce danych, których wartością `dataframe['Sex']` jest `'female'`. W wyniku otrzymujemy serię wartości boolowskich.

Równie łatwo można zastosować większą liczbę wyrażeń warunkowych. Na przykład zobacz, jak pobrać wiersze wszystkich pasażerów przedstawiające kobietę w wieku przynajmniej 65 lat.

```
# Filtrowanie wierszy.
dataframe[(dataframe['Sex'] == 'female') & (dataframe['Age'] >= 65)]
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **73** | Crosby, Mrs Edward Gifford (Catherine Elizabeth… | 1st | 69.0 | female | 1 | 1 |

## Analiza

Warunkowe pobieranie i filtrowanie danych to jedno z podstawowych zadań wykonywanych podczas przygotowywania danych. Bardzo rzadko zależy nam na tym, by otrzymać niezmodyfikowane dane pochodzące ze źródła. Najczęściej będziesz zainteresowany jedynie ich podzbiorem. Na przykład być może chcesz otrzymać informacje o sklepach znajdujących się w podanych województwach lub rekordy pacjentów w określonym wieku.

# 3.5. Sortowanie wartości

## Problem

Musisz posortować ramkę danych według wartości kolumny.

## Rozwiązanie

Skorzystaj z oferowanej przez bibliotekę pandas funkcji `sort_values()`.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Sortowanie ramki danych według kolumny Age i wyświetlenie dwóch pierwszych wierszy.
dataframe.sort_values(by=["Age"]).head(2)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **763** | Dean, Miss Elizabeth Gladys (Millvena) | 3rd | 0.17 | female | 1 | 1 |
| **751** | Danbom, Master Gilbert Sigvard Emanuel | 3rd | 0.33 | male | 0 | 0 |

## Analiza

Podczas analizy danych i ich eksploracji bardzo często użyteczne okazuje się sortowanie ramki danych według określonej kolumny bądź zbioru kolumn. Argument `by` funkcji `sort_values()` pobiera listę kolumn, według których ma być sortowany obiekt `DataFrame`. Następnie operacja sortowania jest przeprowadzana w kolejności nazw kolumn wymienionych na liście.

Domyślnie argument `ascending` ma wartość `True`, więc sortowanie odbywa się w kolejności od najmniejszej do największej wartości. Jeżeli chcesz na przykład najpierw wyświetlić najstarszych pasażerów, argumentowi `ascending` powinieneś przypisać wartość `False`.

# 3.6. Zastępowanie wartości

## Problem

Musisz zastąpić wartość w ramce danych.

## Rozwiązanie

Oferowana przez bibliotekę pandas metoda `replace()` pozwala na bardzo łatwe wyszukiwanie i zastępowanie wartości. Spójrz na przykład pokazujący, jak prosta jest operacja zastąpienia wystąpienia słowa `female` w kolumnie `Sex` wszystkich wierszy słowem `Woman`.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Zastąpienie wartości, wyświetlenie dwóch pierwszych wierszy.
dataframe['Sex'].replace("female", "Woman").head(2)
```

```
0    Woman
1    Woman
Name: Sex, dtype: object
```

Można też zastąpić wiele wartości jednocześnie.

```
# Zastąpienie słów "female" i "male" słowami "Woman" i "Man".
dataframe['Sex'].replace(["female", "male"], ["Woman", "Man"]).head(5)
```

```
0    Woman
1    Woman
2      Man
3    Woman
4      Man
Name: Sex, dtype: object
```

Operację wyszukiwania i zastępowania można przeprowadzać w całym obiekcie `DataFrame`. Wystarczy wskazać całą ramkę danych zamiast pojedynczej kolumny.

```
# Zastąpienie wartości, wyświetlenie dwóch pierwszych wierszy.
dataframe.replace(1, "One").head(2)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.00 | female | One | One |
| **1** | Allison, Miss Helen Loraine | 1st | 2.00 | female | 0 | One |

Metoda `replace()` akceptuje również wyrażenie regularne.

```
# Zastąpienie wartości, wyświetlenie dwóch pierwszych wierszy.
dataframe.replace(r"1st", "First", regex=True).head(2)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | First | 29.00 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | First | 2.00 | female | 0 | 1 |

## Analiza

Metoda `replace()` to proste, choć jednocześnie oferujące potężne możliwości narzędzie przeznaczone do zastępowania wartości. Pozwala na podanie argumentu w postaci wyrażenia regularnego.

# 3.7. Zmiana nazwy kolumny

## Problem

Chcesz zmienić nazwę kolumny w obiekcie `DataFrame` biblioteki pandas.

## Rozwiązanie

Aby zmienić nazwę kolumny, użyj metody `rename()`.

```
# Wczytanie biblioteki.
import pandas as pd
```

```
# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Zmiana nazwy kolumny, wyświetlenie dwóch pierwszych wierszy.
dataframe.rename(columns={'PClass': 'Passenger Class'}).head(2)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | Passenger Class | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.0 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.0 | female | 0 | 1 |

Metoda `rename()` może przyjąć argument w postaci słownika, za pomocą którego istnieje możliwość jednoczesnej zmiany nazw wielu kolumn.

```
# Zmiana nazwy kolumn, wyświetlenie dwóch pierwszych wierszy.
dataframe.rename(columns={'PClass': 'Passenger Class', 'Sex': 'Gender'}).head(2)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | Passenger Class | Age | Gender | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.0 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.0 | female | 0 | 1 |

## Analiza

Użycie metody `rename()` wraz z argumentem w postaci słownika dla parametru `columns` jest preferowanym rozwiązaniem podczas zmiany nazw kolumn, ponieważ pozwala na przeprowadzenie operacji na dowolnej liczbie kolumn. Jeżeli chcesz jednocześnie zmienić nazwy wszystkich kolumn, ten użyteczny fragment kodu tworzy słownik wraz z kluczami w postaci dotychczasowych nazw kolumn i wartościami w postaci pustych ciągów tekstowych.

```
# Wczytanie biblioteki.
import collections

# Utworzenie słownika.
column_names = collections.defaultdict(str)

# Utworzenie kluczy.
for name in dataframe.columns:
    column_names[name]

# Wyświetlenie słownika.
column_names

defaultdict(str,
            {'Age': '',
             'Name': '',
```

```
'PClass': '',
'Sex': '',
'SexCode': '',
'Survived': ''})
```

# 3.8. Znajdowanie wartości minimalnej, maksymalnej, sumy, średniej i liczby elementów w kolumnie

## Problem

Chcesz odszukać wartość minimalną, maksymalną, sumę, średnią lub liczbę elementów w kolumnie.

## Rozwiązanie

Biblioteka pandas zawiera pewne wbudowane metody, m.in. `min()`, `max()`, `mean()`, `sum()` i `count()`, przeznaczone do obliczania niektórych najczęściej używanych danych statystycznych.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Obliczenie danych statystycznych.
print('Maksimum:', dataframe['Age'].max())
print('Minimum:', dataframe['Age'].min())
print('Średnia:', dataframe['Age'].mean())
print('Suma:', dataframe['Age'].sum())
print('Liczba elementów:', dataframe['Age'].count())
```

```
Maksimum: 71.0
Minimum: 0.17
Średnia: 30.397989417989415
Suma: 22980.879999999997
Liczba elementów: 756
```

## Analiza

Poza danymi statystycznymi, które wykorzystałem w omawianym rozwiązaniu, biblioteka pandas oferuje również znalezienie wariancji (`var()`), odchylenia standardowego (`std()`), kurtozy (`kurt()`), współczynnika skośności (`skew()`), błędu standardowego średniej arytmetycznej (`sem()`), dominanty (`mode()`), mediany (`median()`), liczby wystąpień poszczególnych wartości oraz wielu innych wartości.

Co więcej, wymienione metody można stosować dla całego obiektu `DataFrame`.

```
# Wyświetlenie liczby elementów w kolumnach.
dataframe.count()
```

```
Name        1313
```

```
PClass      1313
Age          756
Sex         1313
Survived    1313
SexCode     1313
dtype: int64
```

# 3.9. Znajdowanie unikatowych wartości

## Problem

Chcesz pobrać wszystkie unikatowe wartości w kolumnie.

## Rozwiązanie

Za pomocą metody `unique()` można wyświetlić tablicę wszystkich unikatowych wartości w kolumnie.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Pobranie unikatowych wartości.
dataframe['Sex'].unique()

array(['female', 'male'], dtype=object)
```

Z kolei metoda `value_counts()` wyświetla wszystkie unikatowe wartości i podaje liczbę wystąpień każdej z nich.

```
# Wyświetlenie liczby elementów w kolumnach.
dataframe['Sex'].value_counts()

male      851
female    462
Name: Sex, dtype: int64
```

## Analiza

Metody `unique()` i `value_counts()` okazują się użyteczne podczas przeprowadzania operacji i analizowania kolumn kategoryzujących. Bardzo często w takich kolumnach znajdują się klasy wymagające obsługi na etapie przygotowywania danych. Na przykład w zbiorze danych o pasażerach Titanica kolumna `PClass` określa, którą klasą podróżowała dana osoba. Na Titanicu były trzy klasy; po użyciu metody `value_counts()` będzie można dostrzec problem.

```
# Wyświetlenie liczby elementów w kolumnach.
dataframe['PClass'].value_counts()
```

```
3rd    711
1st    322
2nd    279
*        1
Name: PClass, dtype: int64
```

Wprawdzie zgodnie z oczekiwaniami praktycznie wszyscy pasażerowie należeli do jednej z tych trzech klas, ale jeden pasażer miał klasę *. Do obsługi takich problemów istnieje wiele strategii, które przedstawię w rozdziale 5. W tym miejscu wystarczy wiedzieć, że te „dodatkowe" klasy są często spotykane w danych kategoryzujących i nie powinny być ignorowane.

Jeżeli zachodzi potrzeba ustalenia po prostu liczby unikatowych wartości, wówczas można skorzystać z metody `nunique()`.

```
# Wyświetlenie liczby unikatowych wartości.
dataframe['PClass'].nunique()
```

```
4
```

# 3.10. Obsługa brakujących wartości

## Problem

Chcesz ustalić, czy w obiekcie `DataFrame` brakuje jakichkolwiek wartości.

## Rozwiązanie

Metody `isnull()` i `notnull()` zwracają wartość boolowską, określającą, czy brakuje danej informacji.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Pobranie i wyświetlenie dwóch wierszy, w których brakuje wartości.
dataframe[dataframe['Age'].isnull()].head(2)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **12** | Aubert, Mrs Leontine Pauline | 1st | NaN | female | 1 | 1 |
| **13** | Barkworth, Mr Algernon H | 1st | NaN | male | 1 | 0 |

## Analiza

Brakujące wartości to często pojawiający się problem podczas przygotowywania danych, a wielu programistów nie zdaje sobie sprawy z trudności podczas pracy z niekompletnymi danymi. Biblioteka pandas używa znanej z NumPy wartości `NaN` (ang. *not a number* — to nie jest liczba) do zaznaczenia braku wartości. Trzeba w tym miejscu koniecznie dodać, że wartość `NaN` nie została w pełni natywnie zaimplementowana w bibliotece pandas. Dlatego też jeśli chcesz zastąpić wszystkie ciągi tekstowe `male` wartością `NaN`, wynikiem takiej operacji będzie błąd.

```
# Próba zastąpienia wartości przez NaN.
dataframe['Sex'] = dataframe['Sex'].replace('male', NaN)

---------------------------------------------------------------------------

NameError                                 Traceback (most recent call last)

<ipython-input-7-5682d714f87d> in <module>()
      1 # Próba zastąpienia wartości przez NaN.
----> 2 dataframe['Sex'] = dataframe['Sex'].replace('male', NaN)

NameError: name 'NaN' is not defined
---------------------------------------------------------------------------
```

Aby zapewnić pełną funkcjonalność `NaN`, najpierw trzeba zaimportować bibliotekę NumPy.

```
# Wczytanie biblioteki.
import numpy as np

# Zastąpienie wartości przez NaN.
dataframe['Sex'] = dataframe['Sex'].replace('male', np.nan)
```

Bardzo często zdarza się, że do oznaczenia brakującej obserwacji w zbiorze danych używa się pewnej wartości, na przykład `NONE`, `-999` lub kropki. Metoda `read_csv()` biblioteki pandas zawiera parametr pozwalający na określenie wartości używanych do wskazania brakujących wartości.

```
# Wczytanie danych, przypisanie brakujących wartości.
dataframe = pd.read_csv(url, na_values=[np.nan, 'NONE', -999])
```

Istnieje również możliwość użycia funkcji `fillna()` do przypisania brakujących wartości kolumny. W kolejnym fragmencie kodu pokazałem, jak można użyć funkcji `isna()` do znalezienia wierszy, w których wartością kolumny `Age` jest `null`, a następnie zastąpić ją wartością przedstawiającą średni wiek pasażera Titanica.

```
# Pobranie pojedynczego rekordu, w którym brakuje wartości kolumny Age.
null_entry = dataframe[dataframe["Age"].isna()].head(1)

print(null_entry)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **12** | Aubert, Mrs Leontine Pauline | 1st | NaN | female | 1 | 1 |

```
# Przypisanie kolumnie o wartości null wartości przedstawiającej średni wiek pasażera Titanica.
null_entry.fillna(dataframe["Age"].mean())
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **12** | Aubert, Mrs Leontine Pauline | 1st | 30.397989 | female | 1 | 1 |

# 3.11. Usuwanie kolumn

## Problem

Chcesz usunąć kolumnę z obiektu `DataFrame`.

## Rozwiązanie

Najlepszym sposobem na usunięcie kolumny jest użycie metody `drop()` wraz z parametrem `axis=1` (np. określającym oś kolumny).

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Usunięcie kolumny.
dataframe.drop('Age', axis=1).head(2)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Sex | Survived | SexCode |
|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | female | 0 | 1 |

Lista nazw kolumn może zostać użyta jako argument główny, co pozwala na jednoczesne usunięcie wielu kolumn.

```
# Usunięcie kolumn.
dataframe.drop(['Age', 'Sex'], axis=1).head(2)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Survived | SexCode |
|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 0 | 1 |

Jeżeli kolumna nie ma nazwy, co się czasami zdarza, można ją usunąć przez podanie indeksu kolumny za pomocą atrybutu `dataframe.columns`, jak pokazałem w kolejnym poleceniu.

```
# Usunięcie kolumny.
dataframe.drop(dataframe.columns[1], axis=1).head(2)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 29.0 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 2.0 | female | 0 | 1 |

## Analiza

Metoda `drop()` jest przeznaczona do usunięcia kolumny. Alternatywną metodą jest `del`, na przykład `del dataframe['Age']`, która działa w większości przypadków, ale nie jest zalecana ze względu na sposób jej wywoływania w bibliotece pandas (związane z tym szczegóły wykraczają poza zakres tematyczny książki).

Szczerze odradzam używanie argumentu `inplace=True`. Wiele metod biblioteki pandas zawiera parametr `inplace`, którego wartość `True` oznacza bezpośrednią edycję obiektu `DataFrame`. To może prowadzić do problemów w bardziej złożonych potokach przetwarzania danych, ponieważ obiekt `DataFrame` będzie traktowany jako modyfikowalny (formalnie rzecz biorąc, należy go za taki uznać). Gorąco zachęcam do używania `DataFrame` jak obiektu niemodyfikowalnego. Spójrz na przedstawiony tutaj przykład.

```
# Utworzenie nowego obiektu typu DataFrame.
dataframe_name_dropped = dataframe.drop(dataframe.columns[0], axis=1)
```

W tym przykładzie nie mamy do czynienia ze zmianą obiektu typu `DataFrame`, ale z utworzeniem nowego obiektu tego typu będącego alternatywną wersją `dataframe` o nazwie `dataframe_name_dropped`. Jeżeli będziesz traktować `DataFrame` jako obiekt niemodyfikowalny, unikniesz wielu kłopotów.

# 3.12. Usuwanie wiersza

## Problem

Chcesz usunąć jeden lub większą liczbę wierszy z obiektu `DataFrame`.

## Rozwiązanie

Użyj wyrażenia boolowskiego do utworzenia nowego obiektu typu `DataFrame` niezawierającego wierszy, które chciałeś usunąć.

```
# Wczytanie biblioteki.
import pandas as pd
```

```
# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Usunięcie wierszy, wyświetlenie dwóch pierwszych wierszy danych wyjściowych.
dataframe[dataframe['Sex'] != 'male'].head(3)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.0 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.0 | female | 0 | 1 |
| **3** | Allison, Mrs Hudson JC (Bessie Waldo Daniels) | 1st | 25.00 | female | 0 | 1 |

## Analiza

Mimo że formalnie rzecz biorąc, możliwe jest użycie metody `drop()`, na przykład `dataframe.drop([0, 1], axis=0)`, aby usnąć dwa pierwsze wiersze, to jednak znacznie praktyczniejszym rozwiązaniem będzie umieszczenie wyrażenia boolowskiego w wywołaniu `dataframe[]`. Dzięki temu można wykorzystać potężne możliwości wyrażeń boolowskich do usunięcia pojedynczego wiersza lub (co bardziej prawdopodobne) jednocześnie wielu wierszy.

Wyrażenia boolowskiego można używać, aby w łatwy sposób usunąć jeden wiersz dopasowany dzięki unikatowej wartości.

```
# Usunięcie wiersza, wyświetlenie dwóch pierwszych wierszy danych wyjściowych.
dataframe[dataframe['Name'] != 'Allison, Miss Helen Loraine'].head(2)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.0 | female | 1 | 1 |
| **2** | Allison, Mr Hudson Joshua Creighton | 1st | 30.0 | male | 0 | 0 |

Pojedynczy wiersz można również usunąć, podając jego indeks, jak pokazałem w kolejnym poleceniu.

```
# Usunięcie wiersza, wyświetlenie dwóch pierwszych wierszy danych wyjściowych.
dataframe[dataframe.index != 0].head(2)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **1** | Allison, Miss Helen Loraine | 1st | 2.0 | female | 0 | 1 |
| **2** | Allison, Mr Hudson Joshua Creighton | 1st | 30.0 | male | 0 | 0 |

# 3.13. Usuwanie powielonych wierszy

## Problem

Z obiektu `DataFrame` chcesz usunąć powielone wiersze.

## Rozwiązanie

Możesz skorzystać z metody `drop_duplicates()`, ale powinieneś pamiętać o dostępnych parametrach.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Usunięcie powielonych wierszy, wyświetlenie dwóch pierwszych wierszy danych wyjściowych.
dataframe.drop_duplicates().head(2)
```

Oto dane po wykonaniu przedstawionego kodu:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.0 | female | 1 | 1 |
| **1** | Allison, Miss Helen Loraine | 1st | 2.0 | female | 0 | 1 |

## Analiza

Uważny czytelnik dostrzeże, że przedstawione tutaj rozwiązanie w rzeczywistości nie spowodowało usunięcia żadnych wierszy.

```
# Wyświetlenie liczby wierszy.
print("Liczba wierszy w początkowym obiekcie DataFrame:", len(dataframe))
print("Liczba wierszy po przeprowadzeniu operacji:", len(dataframe.drop_duplicates()))

Liczba wierszy w początkowym obiekcie DataFrame: 1313
Liczba wierszy po przeprowadzeniu operacji: 1313
```

Domyślnie działanie metody `drop_duplicates()` polega na usunięciu jedynie wierszy idealnie dopasowanych we wszystkich kolumnach. W takim przypadku każdy wiersz w użytym tutaj obiekcie typu `DataFrame` jest faktycznie unikatowy. Jednak bardzo często zachodzi potrzeba sprawdzenia pod kątem powielonych wierszy tylko podzbioru kolumn. Wówczas należy skorzystać z parametru `subset`.

```
# Usunięcie powielonych wierszy.
dataframe.drop_duplicates(subset=['Sex'])
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **0** | Allen, Miss Elisabeth Walton | 1st | 29.0 | female | 1 | 1 |
| **2** | Allison, Mr Hudson Joshua Creighton | 1st | 30.0 | male | 0 | 0 |

Spójrz uważnie na wygenerowane dane wyjściowe: metoda `drop_duplicates()` uznaje za duplikaty przeznaczone do usunięcia dwa dowolne wiersze o takiej samej wartości kolumny Sex. Po wykonaniu tej operacji mamy obiekt typu `DataFrame`, zawierający tylko dwa wiersze przedstawiające kobietę i mężczyznę. Być może zadajesz sobie pytanie, dlaczego metoda `drop_duplicates()` pozostawiła akurat te dwa wiersze. Odpowiedź okazuje się prosta: metoda pozostawia pierwsze wystąpienie powielonego wiersza i usuwa pozostałe. To zachowanie można kontrolować za pomocą parametru `keep`, jak pokazałem w kolejnym przykładzie.

```
# Usunięcie powielonych wierszy.
dataframe.drop_duplicates(subset=['Sex'], keep='last')
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **1307** | Zabour, Miss Tamini | 3rd | NaN | female | 0 | 1 |
| **1312** | Zimmerman, Leo | 3rd | 29.0 | male | 0 | 0 |

Istnieje metoda o nazwie `duplicated()`, podobna do omawianej tutaj `drop_duplicates()`. Wartością zwrotną metody `duplicated()` jest seria wartości boolowskich, wskazujących, czy wiersz jest powielony. Użycie tej metody jest dobrym rozwiązaniem, jeśli nie chcesz usunąć powielonych wierszy.

```
dataframe.duplicated()

0       False
1       False
2       False
3       False
4       False
        ...
1308    False
1309    False
1310    False
1311    False
1312    False
Length: 1313, dtype: bool
```

# 3.14. Grupowanie wierszy według wartości

## Problem

Chcesz pogrupować poszczególne wiersze według pewnej wartości współdzielonej.

## Rozwiązanie

Metoda `groupby()` to jedna z najpotężniejszych funkcji oferowanych przez bibliotekę pandas.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Grupowanie wierszy według wartości kolumny 'Sex'
# i obliczenie średniej w poszczególnych grupach.
dataframe.groupby('Sex').mean(numeric_only=True)
```

Oto dane po wykonaniu przedstawionego kodu:

| Sex | Age | Survived | SexCode |
|---|---|---|---|
| **Female** | 29.396424 | 0.666667 | 1.0 |
| **Male** | 31.014338 | 0.166863 | 0.0 |

## Analiza

Użycie metody `groupby()` powoduje, że dane zaczynają nabierać kształtu. Bardzo często zdarza się, że chcemy grupować poszczególne wiersze obiektu `DataFrame` przedstawiające osobę lub zdarzenie według pewnego kryterium, aby następnie wygenerować wybrane dane statystyczne. Na przykład wyobraź sobie istnienie obiektu typu `DataFrame`, którego wiersze przedstawiają wartość pojedynczych transakcji we wszystkich lokalach danej sieci restauracji, a Twoim zadaniem jest obliczenie wartości wszystkich transakcji w poszczególnych lokalach. To zadanie można wykonać poprzez zgrupowanie wierszy określających poszczególne restauracje, a następnie obliczenie sumy całej grupy.

Początkujący mają tendencję do używania metody `groupby()` w pokazany tutaj sposób, a następnie są zdziwieni otrzymanym wynikiem.

```
# Grupowanie wierszy.
dataframe.groupby('Sex')
```

```
<pandas.core.groupby.DataFrameGroupBy object at 0x10efacf28>
```

Dlaczego przedstawione polecenie nie zwróciło bardziej użytecznego wyniku? Wywołanie metody `groupby()` trzeba po prostu połączyć z pewną operacją, która ma być przeprowadzona na każdej grupie, na przykład z obliczeniem zagregowanych danych statystycznych, takich jak średnia, mediana, suma itd. Kiedy mówi się o grupowaniu, często słyszy się określenie „grupowanie według płci”, ale to nie do końca odpowiednie stwierdzenie. Aby grupowanie było użyteczne, konieczne jest grupowanie pewnych wartości i następnie przeprowadzenie operacji na poszczególnych grupach.

```
# Grupowanie wierszy, a następnie ich zliczenie.
dataframe.groupby('Survived')['Name'].count()
```

```
Survived
0    863
1    450
Name: Name, dtype: int64
```

Zwróć uwagę na dodanie `Name` po wywołaniu metody `groupby()`. Wynika to z tego, że podsumowanie określonych danych statystycznych ma sens jedynie dla pewnych typów danych. Na przykład obliczanie średniego wieku według płci ma sens, natomiast obliczanie sumy lat według płci nie ma żadnego sensu. W omawianym przypadku zostały zgrupowane dane dotyczące osób, które przeżyły i nie przeżyły katastrofy Titanica, a następnie zliczana jest liczba pasażerów w poszczególnych grupach.

Istnieje również możliwość grupowania według pierwszej kolumny, a następnie według drugiej, jak pokazałem w kolejnym fragmencie kodu.

```
# Grupowanie wierszy, obliczenie średniej.
dataframe.groupby(['Sex','Survived'])['Age'].mean()
```

```
Sex     Survived
female  0           24.901408
        1           30.867143
male    0           32.320780
        1           25.951875
Name: Age, dtype: float64
```

# 3.15. Grupowanie wierszy według czasu

## Problem

Musisz pogrupować pojedyncze wiersze według czasu.

## Rozwiązanie

Użyj oferowanej przez bibliotekę pandas metody `resample()` do grupowania wierszy według czasu.

```
# Wczytanie bibliotek.
import pandas as pd
import numpy as np

# Utworzenie przedziału czasu.
time_index = pd.date_range('06/06/2017', periods=100000, freq='30S')

# Utworzenie obiektu typu DataFrame.
dataframe = pd.DataFrame(index=time_index)

# Utworzenie kolumny losowo wybranych wartości.
dataframe['Sale_Amount'] = np.random.randint(1, 10, 100000)

# Grupowanie wierszy według tygodnia, obliczenie sumy dla danego tygodnia.
dataframe.resample('W').sum()
```

Oto dane po wykonaniu przedstawionego kodu:

| | Sale_Amount |
|---|---|
| **2017-06-11** | 86423 |
| **2017-06-18** | 101045 |
| **2017-06-25** | 100867 |
| **2017-07-02** | 100894 |
| **2017-07-09** | 100438 |
| **2017-07-16** | 10297 |

## Analiza

Wykorzystywany dość często w rozdziale zbiór danych dotyczących pasażerów Titanica nie ma kolumny z wartościami czasu. Dlatego też w tej recepturze wygenerowałem prosty obiekt typu `DataFrame`, którego wiersze przedstawiają pojedyncze transakcje. Znamy datę i godzinę oraz wyrażoną w złotówkach wartość każdej transakcji. (Te dane nie są zbyt rzeczywiste, ponieważ transakcje odbyły się w odstępach 30 sekund i wartość każdej z nich jest kwotą wyrażoną w pełnych złotych, ale na potrzeby omawianego tutaj rozwiązania jest to w zupełności wystarczające).

Niezmodyfikowane dane w trzech pierwszych wierszach przedstawiają się następująco:

```
# Wyświetlenie trzech pierwszych wierszy.
dataframe.head(3)
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Sale_Amount |
|---|---|
| **2017-06-06 00:00:00** | 7 |
| **2017-06-06 00:00:30** | 2 |
| **2017-06-06 00:01:00** | 7 |

Zwróć uwagę na to, że data i godzina poszczególnych transakcji to indeks w obiekcie typu `DataFrame`. Metoda `resample()` wymaga indeksu dla wartości przedstawiających datę i godzinę.

Za pomocą tej metody można grupować wiersze według różnych przedziałów czasu, a następnie przeprowadzać pewne obliczenia w tych grupach, jak pokazałem w dwóch kolejnych poleceniach.

```
# Grupowanie według dwóch tygodni, obliczenie średniej.
dataframe.resample('2W').mean()
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Sale_Amount |
|---|---|
| **2017-06-11** | 5.001331 |
| **2017-06-25** | 5.007738 |

| | Sale_Amount |
|---|---|
| **2017-07-09** | 4.993353 |
| **2017-07-23** | 4.950481 |

```
# Grupowanie według miesiąca, obliczenie liczby wierszy.
dataframe.resample('M').count()
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Sale_Amount |
|---|---|
| **2017-06-30** | 72000 |
| **2017-07-31** | 28000 |

Zwróć uwagę na wygenerowanie dwóch elementów danych wyjściowych indeksu daty i godziny, pomimo że grupowanie odbywa się według — odpowiednio — tygodni i miesięcy. Domyślnie metoda `resample()` zwraca etykietę prawej „krawędzi" (ostatnia etykieta) grupy daty i godziny. To zachowanie można kontrolować za pomocą parametru `label`.

```
# Grupowanie według miesiąca, obliczenie liczby wierszy.
dataframe.resample('M', label='left').count()
```

Oto dane po wykonaniu przedstawionego polecenia:

| | Sale_Amount |
|---|---|
| **2017-05-31** | 72000 |
| **2017-06-30** | 28000 |

## Zobacz również

- Lista aliasów biblioteki pandas związanych z wartościami daty i godziny na stronie *https://pandas.pydata.org/pandas-docs/stable/user_guide/timeseries.html*.

# 3.16. Agregowanie operacji i danych statystycznych

## Problem

Chcesz przeprowadzić agregację operacji w poszczególnych kolumnach (lub w zbiorze kolumn) ramki danych.

## Rozwiązanie

Skorzystaj z oferowanej przez bibliotekę pandas metody `agg()`. Zobacz, jak łatwo można pobrać wartość minimalną każdej kolumny.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Pobranie wartości minimalnej każdej kolumny.
dataframe.agg("min")
```

```
Name        Abbing, Mr Anthony
PClass                       *
Age                       0.17
Sex                     female
Survived                     0
SexCode                      0
dtype: object
```

Czasami zachodzi potrzeba zastosowania określonych funkcji dla pewnego zbioru kolumn.

```
# Wartość średnia kolumny Age oraz wartości minimalna i maksymalna kolumny Sex.
dataframe.agg({"Age":["mean"], "SexCode":["min", "max"]})
```

Oto dane po wykonaniu przedstawionego kodu:

| | Age | SexCode |
|---|---|---|
| **mean** | 30.397989 | NaN |
| **min** | NaN | 0.0 |
| **max** | NaN | 1.0 |

Funkcje agregacji można stosować także dla grup, aby w ten sposób otrzymać znacznie dokładniejsze i bardziej opisowe dane statystyczne.

```
# Liczba pasażerów w poszczególnych klasach, którzy przeżyli i nie przeżyli katastrofy Titanica.
dataframe.groupby(
    ["PClass","Survived"]).agg({"Survived":["count"]}
  ).reset_index()
```

Oto dane po wykonaniu przedstawionego kodu:

| | PClass | Survived | Count |
|---|---|---|---|
| **0** | * | 0 | 1 |
| **1** | 1st | 0 | 129 |
| **2** | 1st | 1 | 193 |
| **3** | 2nd | 0 | 160 |
| **4** | 2nd | 1 | 119 |
| **5** | 3rd | 0 | 573 |
| **6** | 3rd | 1 | 138 |

## Analiza

Funkcje agregacji okazują się szczególnie użyteczne podczas eksploracyjnej analizy danych, ponieważ pozwalają poznać informacje o różnych podpopulacjach danych i relacjach zachodzących między zmiennymi. Dzięki grupowaniu danych i zastosowaniu agregacji danych statystycznych można poznać wzorce w danych, które okażą się przydatne podczas wykonywania zadań związanych z uczeniem maszynowym bądź w trakcie procesu wyodrębniania cech. Wprawdzie wykresy graficzne również są pomocne, ale często wystarczające będzie posiadanie takich konkretnych, opisowych danych statystycznych, które pomogą w jeszcze lepszym zrozumieniu danych.

## Zobacz również

- Dokumentacja funkcji `agg()` biblioteki pandas *https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.agg.html*.

# 3.17. Iterowanie przez kolumnę

## Problem

Chcesz przeprowadzić iterację przez wszystkie elementy kolumny i wykonać na nich jakieś działanie.

## Rozwiązanie

Kolumnę w strukturze danych biblioteki pandas można potraktować jak każdą inną sekwencję Pythona.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Wyświetlenie wielkimi literami imienia i nazwiska dwóch pierwszych pasażerów.
for name in dataframe['Name'][0:2]:
    print(name.upper())
```

```
ALLEN, MISS ELISABETH WALTON
ALLISON, MISS HELEN LORAINE
```

## Analiza

Poza pętlami (często określanymi mianem pętli `for`) można również użyć listy składanej, jak pokazałem w kolejnym przykładzie.

```
# Wyświetlenie wielkimi literami imienia i nazwiska dwóch pierwszych pasażerów.
[name.upper() for name in dataframe['Name'][0:2]]
```

```
['ALLEN, MISS ELISABETH WALTON', 'ALLISON, MISS HELEN LORAINE']
```

Wprawdzie rozwiązaniem awaryjnym jest pętla `for`, ale bardziej zgodnym ze stylem „Pythonic" podejściem jest użycie oferowanej przez bibliotekę pandas metody `apply()`, co przedstawię w następnej recepturze.

# 3.18. Wywoływanie funkcji dla wszystkich elementów kolumny

## Problem

Chcesz wywołać pewną funkcję dla wszystkich elementów kolumny.

## Rozwiązanie

Użyj metody `apply()`, aby dla każdego elementu kolumny wywołać funkcję wbudowaną lub niestandardową.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Utworzenie funkcji.
def uppercase(x):
    return x.upper()

# Wywołanie funkcji, wyświetlenie dwóch pierwszych wierszy.
dataframe['Name'].apply(uppercase)[0:2]
```

```
0    ALLEN, MISS ELISABETH WALTON
1     ALLISON, MISS HELEN LORAINE
Name: Name, dtype: object
```

## Analiza

Metoda `apply()` sprawdza się doskonale podczas oczyszczania i przygotowywania danych. Bardzo często tworzy się funkcje przeznaczone do przeprowadzania pewnych użytecznych operacji (rozdzielenia imienia i nazwiska, konwersji ciągu tekstowego na liczbę itd.), a następnie wywołuje się tę funkcję dla każdego elementu kolumny.

# 3.19. Wywoływanie funkcji dla grupy

## Problem

Masz utworzone za pomocą metody `groupby()` grupy wierszy i chcesz w nich wywołać pewną funkcję.

## Rozwiązanie

Najlepszym rozwiązaniem będzie połączenie wywołań metod `groupby()` i `apply()`.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie adresu URL.
url = 'https://raw.githubusercontent.com/chrisalbon/sim_data/master/titanic.csv'

# Wczytanie danych.
dataframe = pd.read_csv(url)

# Grupowanie wierszy, wywołanie funkcji w grupach.
dataframe.groupby('Sex').apply(lambda x: x.count())
```

Oto dane po wykonaniu przedstawionego kodu:

| Sex | Name | PClass | Age | Sex | Survived | SexCode |
|---|---|---|---|---|---|---|
| **female** | 462 | 462 | 288 | 462 | 462 | 462 |
| **male** | 851 | 851 | 468 | 851 | 851 | 851 |

## Analiza

W recepturze 3.18 wspomniałem o metodzie `apply()`. Ta metoda okazuje się szczególnie użyteczna, gdy chcesz wywołać pewną funkcję w grupie elementów. Dzięki połączeniu wywołań metod `groupby()` i `apply()` można wygenerować niestandardowe dane statystyczne lub wykonywać dowolne funkcje w poszczególnych grupach.

# 3.20. Konkatenacja obiektów typu DataFrame

## Problem

Chcesz przeprowadzić konkatenację dwóch obiektów typu `DataFrame`.

## Rozwiązanie

Do przeprowadzenia konkatenacji obiektów typu `DataFrame` na podstawie wierszy użyj metody `concat()` wraz z argumentem `axis=0`.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie obiektu typu DataFrame.
data_a = {'id': ['1', '2', '3'],
          'first': ['Alex', 'Amy', 'Allen'],
          'last': ['Anderson', 'Ackerman', 'Ali']}
dataframe_a = pd.DataFrame(data_a, columns = ['id', 'first', 'last'])

# Utworzenie obiektu typu DataFrame.
data_b = {'id': ['4', '5', '6'],
          'first': ['Billy', 'Brian', 'Bran'],
          'last': ['Bonder', 'Black', 'Balwner']}
dataframe_b = pd.DataFrame(data_b, columns = ['id', 'first', 'last'])

# Konkatenacja obiektów DataFrame na podstawie wierszy.
pd.concat([dataframe_a, dataframe_b], axis=0)
```

Oto dane po wykonaniu przedstawionego kodu:

| | id | first | last |
|---|---|---|---|
| **0** | 1 | Alex | Anderson |
| **1** | 2 | Amy | Ackerman |
| **2** | 3 | Allen | Ali |
| **0** | 4 | Billy | Bonder |
| **1** | 5 | Brian | Black |
| **2** | 6 | Bran | Balwner |

Konkatenacja na podstawie kolumny odbywa się po użyciu argumentu `axis=1` w wywołaniu metody `concat()`.

```
# Konkatenacja obiektów DataFrame na podstawie kolumn.
pd.concat([dataframe_a, dataframe_b], axis=1)
```

Oto dane po wykonaniu przedstawionego kodu:

| | id | first | last | id | first | last |
|---|---|---|---|---|---|---|
| **0** | 1 | Alex | Anderson | 4 | Billy | Bonder |
| **1** | 2 | Amy | Ackerman | 5 | Brian | Black |
| **2** | 3 | Allen | Ali | 6 | Bran | Balwner |

## Analiza

Konkatenacja to nie jest słowo, które zbyt często pada w informatyce i programowaniu. Dlatego też nie przejmuj się, jeśli wcześniej go nie słyszałeś. Nieformalna definicja **konkatenacji** to połączenie dwóch obiektów. W omawianym tutaj rozwiązaniu pokazałem połączenie dwóch małych obiektów typu `DataFrame` za pomocą parametru `axis`, wskazującego, czy dwa obiekty mają być ułożone jeden na drugim, czy obok siebie.

# 3.21. Złączanie obiektów typu DataFrame

## Problem

Chcesz złączyć ze sobą dwa obiekty typu `DataFrame`.

## Rozwiązanie

Do przeprowadzenia złączenia wewnętrznego należy użyć metody `merge()` wraz z parametrem `on` wskazującym kolumnę, na podstawie której zostanie przeprowadzona operacja.

```
# Wczytanie biblioteki.
import pandas as pd

# Utworzenie obiektu typu DataFrame.
employee_data = {'employee_id': ['1', '2', '3', '4'],
                 'name': ['Amy Jones', 'Allen Keys', 'Alice Bees',
                 'Tim Horton']}
dataframe_employees = pd.DataFrame(employee_data, columns = ['employee_id',
                                                             'name'])

# Utworzenie obiektu typu DataFrame.
sales_data = {'employee_id': ['3', '4', '5', '6'],
              'total_sales': [23456, 2512, 2345, 1455]}
dataframe_sales = pd.DataFrame(sales_data, columns = ['employee_id',
                                                      'total_sales'])

# Złączenie obiektów typu DataFrame.
pd.merge(dataframe_employees, dataframe_sales, on='employee_id')
```

Oto dane po wykonaniu przedstawionego kodu:

| | employee_id | name | total_sales |
|---|---|---|---|
| **0** | 3 | Alice Bees | 23456 |
| **1** | 4 | Tim Horton | 2512 |

Domyślnie metoda `merge()` przeprowadza złączenie wewnętrzne. Jeżeli chcesz przeprowadzić złączenie zewnętrzne, możesz to określić za pomocą parametru `how`.

```
# Złączenie obiektów typu DataFrame.
pd.merge(dataframe_employees, dataframe_sales, on='employee_id', how='outer')
```

Oto dane po wykonaniu przedstawionego polecenia:

| | employee_id | name | total_sales |
|---|---|---|---|
| **0** | 1 | Amy Jones | NaN |
| **1** | 2 | Allen Keys | NaN |
| **2** | 3 | Alice Bees | 23456.0 |
| **3** | 4 | Tim Horton | 2512.0 |

| | employee_id | name | total_sales |
|---|---|---|---|
| **4** | 5 | NaN | 2345.0 |
| **5** | 6 | NaN | 1455.0 |

Ten sam parametr może zostać użyty do określenia złączenia lewego i prawego.

```
# Złączenie obiektów typu DataFrame.
pd.merge(dataframe_employees, dataframe_sales, on='employee_id', how='left')
```

Oto dane po wykonaniu przedstawionego polecenia:

| | employee_id | name | total_sales |
|---|---|---|---|
| **0** | 1 | Amy Jones | NaN |
| **1** | 2 | Allen Keys | NaN |
| **2** | 3 | Alice Bees | 23456.0 |
| **3** | 4 | Tim Horton | 2512.0 |

Istnieje również możliwość podania w poszczególnych obiektach typu `DataFrame` nazwy kolumny, na podstawie której odbędzie się łączenie.

```
# Złączenie obiektów typu DataFrame.
pd.merge(dataframe_employees,
         dataframe_sales,
         left_on='employee_id',
         right_on='employee_id')
```

Jeżeli zamiast złączenia na podstawie dwóch kolumn chcesz przeprowadzić złączenie na podstawie indeksów poszczególnych obiektów typu `DataFrame`, parametry `left_on` i `right_on` możesz zastąpić parametrami `right_index=True` i `left_index=True`.

Oto dane po wykonaniu przedstawionego kodu:

| | employee_id | name | total_sales |
|---|---|---|---|
| **0** | 3 | Alice Bees | 23456 |
| **1** | 4 | Tim Horton | 2512 |

## Analiza

Bardzo często dane konieczne do użycia są skomplikowane i nie zawsze będą dostępne w postaci jednego bloku. W rzeczywistych projektach zwykle mamy oddzielne zbiory danych pochodzące z wielu plików bądź zapytań do różnych baz danych. Aby zebrać razem wszystkie dane, można najpierw umieścić w oddzielnych obiektach typu `DataFrame` dane pochodzące z poszczególnych źródeł, a następnie połączyć je ze sobą w jeden obiekt `DataFrame`.

Ten proces powinien być znany programistom, którzy mają doświadczenie w pracy z SQL, czyli popularnym językiem zapytań pozwalającym między innymi na operacje łączenia danych (w SQL są one określane mianem **złączeń**). Wprawdzie konkretne parametry wykorzystywane przez bibliotekę

pandas będą inne, ale ogólna zasada działania złączenia jest taka sama jak w innych narzędziach i językach programowania.

W trakcie operacji złączenia należy zwrócić uwagę na trzy aspekty. Po pierwsze, konieczne jest podanie dwóch obiektów typu `DataFrame` przeznaczonych do złączenia. W omawianym rozwiązaniu mają one nazwy `dataframe_employees` i `dataframe_sales`. Po drugie, trzeba podać nazwę kolumny (lub kolumn), na podstawie której zostanie przeprowadzone złączenie. To będzie kolumna, której wartość jest współdzielona przez dwa obiekty `DataFrame`. Na przykład w omawianym przykładzie oba obiekty mają kolumnę o nazwie `employee_id`. Aby połączyć oba obiekty, trzeba w nich dopasować wartości wymienionej kolumny. Jeżeli obie kolumny mają tę samą nazwę, można użyć parametru `on`. Natomiast w przeciwnym razie należy skorzystać z parametrów `left_on` lub `right_on`.

Który obiekt `DataFrame` jest uznawany za lewy, a który za prawy? To proste — lewym jest obiekt `DataFrame` podany jako pierwszy w wywołaniu metody `merge()`, natomiast prawym jest obiekt `Data` ↪`Frame` podany jako drugi. Ta koncepcja pojawia się ponownie w następnym zestawie parametrów.

Trzeci aspekt złączenia jest jednocześnie najtrudniejszy — to konieczność wskazania typu przeprowadzanej operacji złączenia. Do określenia typu używamy parametru `how`. Metoda `merge()` obsługuje cztery podstawowe typy złączeń.

*Wewnętrzne*

Zwracane są jedynie wiersze dopasowane w obu obiektach `DataFrame`. W omawianym przykładzie zwrócony będzie każdy wiersz, którego wartość `employee_id` występuje zarówno w obiekcie `dataframe_employees`, jak i `dataframe_sales`.

*Zewnętrzne*

Zwracane są wszystkie wiersze w obu obiektach `DataFrame`. Jeżeli wiersz istnieje tylko w jednym obiekcie, wówczas brakujące wartości są zastępowane przez `NaN`. W omawianym przykładzie zwrócone będą wszystkie wiersze znajdujące się w obiektach `dataframe_employees` i `dataframe_sales`.

*Lewe*

Z lewego obiektu `DataFrame` zwracane są wszystkie wiersze, natomiast z prawego tylko te, które zostały dopasowane do wierszy w lewym obiekcie. Brakujące wartości są zastępowane przez `NaN`. W omawianym przykładzie zwrócone będą wszystkie wiersze obiektu `dataframe_employees`, zaś z obiektu `dataframe_sales` tylko te, których wartość `employee_id` została dopasowana do wartości tej samej kolumny w `dataframe_employees`.

*Prawe*

Z prawego obiektu `DataFrame` zwracane są wszystkie wiersze, natomiast z lewego tylko te, które zostały dopasowane do wierszy w prawym obiekcie. Brakujące wartości są zastępowane przez `NaN`. W omawianym przykładzie zwrócone będą wszystkie wiersze obiektu `dataframe_sales`, zaś z obiektu `dataframe_employees` tylko te, których wartość `employee_id` została dopasowana do wartości tej samej kolumny w `dataframe_sales`.

Nie przejmuj się, jeżeli to wyjaśnienie nie jest do końca jasne. Zachęcam Cię do eksperymentów z parametrem `how` w kodzie i obserwacji efektu, jaki ten parametr ma na dane wyjściowe zwracane przez metodę `merge()`.

## Zobacz również

- Artykuł *A Visual Explanation of SQL Joins* opublikowany na stronie *https://blog.codinghorror.com/a-visual-explanation-of-sql-joins/*.
- Dokumentacja biblioteki pandas dotycząca złączeń na stronie *https://pandas.pydata.org/pandas-docs/stable/user_guide/merging.html*.

Długo szukałam książki, która spójnie przedstawiałaby algorytm ANN, hiperpłaszczyzny i wybór cech za pomocą losowego lasu. I wtedy pojawiła się ta pozycja!

**Vicki Boykis,** inżynier uczenia maszynowego w Duo

W ciągu ostatnich lat techniki uczenia maszynowego rozwijały się z niezwykłą dynamiką, rewolucjonizując pracę w różnych branżach. Obecnie do uczenia maszynowego najczęściej używa się Pythona i jego bibliotek. Znajomość najnowszych wydań tych narzędzi umożliwia efektywne tworzenie wyrafinowanych systemów uczących się.

Oto zaktualizowane wydanie popularnego przewodnika, dzięki któremu skorzystasz z ponad dwustu sprawdzonych receptur bazujących na najnowszych wydaniach bibliotek Pythona. Wystarczy, że skopiujesz i dostosujesz kod do swoich potrzeb. Możesz też go uruchamiać i testować za pomocą przykładowego zbioru danych. W książce znajdziesz receptury przydatne do rozwiązywania szerokiego spektrum problemów, od przygotowania i wczytania danych aż po trenowanie modeli i korzystanie z sieci neuronowych. W ten sposób wyjdziesz poza rozważania teoretyczne czy też matematyczne koncepcje i zaczniesz tworzyć aplikacje korzystające z uczenia maszynowego.

## Poznaj receptury dotyczące:

- pracy z danymi w wielu formatach, z bazami i magazynami danych
- redukcji wymiarowości, jak również oceny i wyboru modelu
- regresji liniowej i logistycznej, drzew i lasów, a także najbliższych sąsiadów
- maszyn wektorów nośnych (SVM), naiwnej klasyfikacji bayesowskiej i klasteryzacji
- udostępniania wytrenowanych modeli za pomocą wielu frameworków

**Kyle Gallatin** jest inżynierem oprogramowania na platformie uczenia maszynowego w Etsy. Przez wiele lat pracował jako analityk danych, naukowiec i inżynier uczenia maszynowego.

**Chris Albon** jest dyrektorem do spraw uczenia maszynowego w Wikimedia Foundation.

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 978-83-289-0811-6
9 788328 908116
Cena: 89,00 zł