O'REILLY®

# Python i Excel

## Nowoczesne środowisko do automatyzacji i analizy danych

Helion

Felix Zumstein

Tytuł oryginału: Python for Excel: A Modern Environment for Automation and Data Analysis

Tłumaczenie: Leszek Sagalara

ISBN: 978-83-289-3095-7



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

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

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

Printed in Poland.

# Spis treści

ROZDZIAŁ 5.

# Analiza danych z biblioteką pandas

Ten rozdział jest wprowadzeniem do pandas (*Python Data Analysis Library* — biblioteka Pythona do analizy danych) lub — jak to lubię określać — opartego na Pythonie arkusza kalkulacyjnego z supermocami. Ma on tak potężne możliwości, że niektóre firmy, z którymi współpracowałem, zdołały całkowicie pozbyć się Excela, zastępując go połączeniem notatników Jupyter i pandas. Zakładam jednak, że jako czytelnik tej książki zachowasz Excela, a wtedy pandas posłuży Ci jako interfejs do wprowadzania i pobierania danych z arkuszy kalkulacyjnych. Biblioteka pandas sprawia, że zadania, które są szczególnie uciążliwe w Excelu, stają się łatwiejsze, zajmują mniej czasu i są bardziej odporne na błędy. Niektóre z tych zadań obejmują pobieranie dużych zbiorów danych z zewnętrznych źródeł oraz pracę z danymi statystycznymi, szeregami czasowymi i interaktywnymi wykresami. Najważniejsze atuty pandas to wektoryzacja i wyrównywanie danych. Jak już widzieliśmy w poprzednim rozdziale przy omawianiu tablic NumPy, wektoryzacja umożliwia pisanie zwięzłego kodu opartego na tablicach, podczas gdy wyrównywanie danych zapewnia, że nie dojdzie do niezgodności podczas pracy z wieloma zbiorami danych.

W tym rozdziale przedstawię całą procedurę analizy danych: zacznę od oczyszczania i przygotowywania danych, a następnie pokażę, jak wydobyć sens z większych zbiorów danych za pomocą agregacji, statystyki opisowej i wizualizacji. Na końcu rozdziału zobaczymy, jak można importować i eksportować dane za pomocą pandas. Ale na początek zapoznajmy się z głównymi strukturami danych w pandas: DataFrame i Series!

## DataFrame i Series

DataFrame i Series są podstawowymi strukturami danych w pandas. Przedstawię je w tym podrozdziale, skupiając się na głównych komponentach DataFrame: indeksie, kolumnach i danych. **DataFrame** przypomina dwuwymiarową tablicę NumPy, ale ma etykiety kolumn i wierszy, a każda kolumna może zawierać różne typy danych. Wyodrębniając pojedynczą kolumnę lub wiersz z DataFrame, otrzymujemy jednowymiarowy obiekt **Series**, który przypomina jednowymiarową tablicę NumPy z etykietami. Gdy spojrzymy na strukturę DataFrame na rysunku 5.1, nie potrzeba wiele wyobraźni, aby zauważyć, że obiekty DataFrame będą naszymi arkuszami kalkulacyjnymi opartymi na Pythonie.

Aby zobaczyć, jak łatwo można przejść z arkusza kalkulacyjnego na DataFrame, spójrzmy na tabelę Excela widoczną na rysunku 5.2, która przedstawia uczestników kursu online wraz z ich wynikami. Odpowiedni plik *course_participants.xlsx* znajdziesz w folderze *xl* w repozytorium towarzyszącym książce.

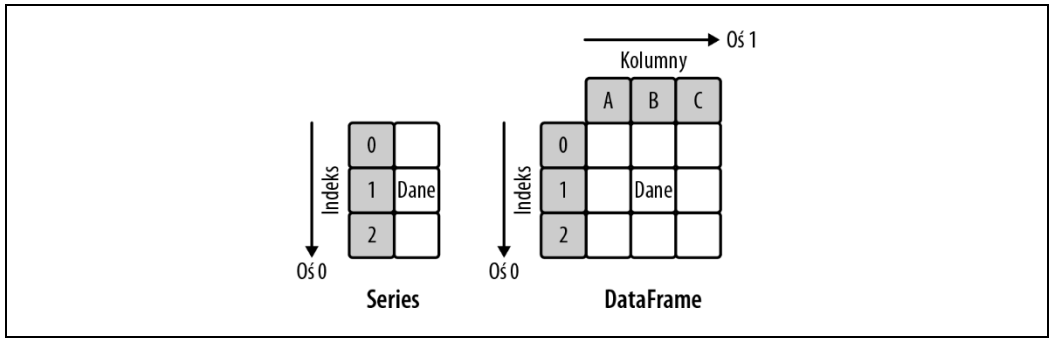


*Rysunek 5.1. Series i DataFrame w pandas*

| | A | B | C | D | E | F |
|---|---|---|---|---|---|---|
| 1 | numer | imię | wiek | kraj | ocena | kontynent |
| 2 | 1001 | Mark | 55 | Włochy | 4,5 | Europa |
| 3 | 1000 | John | 33 | USA | 6,7 | Ameryka |
| 4 | 1002 | Tim | 41 | USA | 3,9 | Ameryka |
| 5 | 1003 | Jenny | 12 | Niemcy | 9 | Europa |

*Rysunek 5.2. course_participants.xlsx*

Aby udostępnić tę tabelę Excela w Pythonie, zacznij od zaimportowania biblioteki pandas, a następnie użyj jej funkcji `read_excel`, która zwraca obiekt DataFrame:

```
In [1]: import pandas as pd
In [2]: pd.read_excel("xl/course_participants.xlsx")
Out[2]:      numer   imię  wiek     kraj  ocena kontynent
        0     1001   Mark    55   Włochy    4.5    Europa
        1     1000   John    33      USA    6.7   Ameryka
        2     1002    Tim    41      USA    3.9   Ameryka
        3     1003  Jenny    12   Niemcy    9.0    Europa
```

### Funkcja read_excel w Pythonie 3.9

Jeśli uruchamiasz `pd.read_excel` z Pythonem w wersji 3.9 lub wyższej, upewnij się, że używasz pandas w wersji co najmniej 1.2, w przeciwnym razie podczas odczytu plików *xlsx* pojawi się błąd.

Jeśli uruchomisz ten kod w notatniku Jupyter, DataFrame będzie ładnie sformatowany jako tabela HTML, co jeszcze bardziej zbliży go do wyglądu tabeli w Excelu. Odczytywanie i zapisywanie plików Excela za pomocą pandas będzie tematem całego rozdziału 7., to był tylko wstępny przykład, aby pokazać, że arkusze kalkulacyjne i DataFrame są bardzo podobne. Utwórzmy teraz ponownie DataFrame od podstaw, bez odczytywania danych z pliku Excela: jednym ze sposobów utworzenia DataFrame jest dostarczenie danych w postaci listy zagnieżdżonej wraz z wartościami dla kolumn (`columns`) i indeksu (`index`):

```
In [3]: data=[["Mark", 55, "Italy", 4.5, "Europa"],
              ["John", 33, "USA", 6.7, "Ameryka"],
```

```
              ["Tim", 41, "USA", 3.9, "Ameryka"],
              ["Jenny", 12, " Niemcy", 9.0, "Europa"]]
        df = pd.DataFrame(data=data,
                          columns=["imię", "wiek", "kraj",
                                   "ocena", "kontynent"],
                          index=[1001, 1000, 1002, 1003])
        df
Out[3]:       imię  wiek     kraj  ocena kontynent
       1001   Mark    55   Włochy    4.5    Europa
       1000   John    33      USA    6.7   Ameryka
       1002    Tim    41      USA    3.9   Ameryka
       1003  Jenny    12   Niemcy    9.0    Europa
```

Wywołując metodę `info`, uzyskasz kilka podstawowych informacji, przede wszystkim liczbę punktów danych oraz typy danych dla każdej kolumny:

```
In [4]: df.info()
<class 'pandas.core.frame.DataFrame'>
Int64Index: 4 entries, 1001 to 1003
Data columns (total 5 columns):
 #   Column     Non-Null Count  Dtype
---  ------     --------------  -----
 0   imię       4 non-null      object
 1   wiek       4 non-null      int64
 2   kraj       4 non-null      object
 3   ocena      4 non-null      float64
 4   kontynent  4 non-null      object
dtypes: float64(1), int64(1), object(3)
memory usage: 192.0+ bytes
```

Jeśli interesuje Cię tylko typ danych w Twoich kolumnach, uruchom zamiast tego `df.dtypes`. Kolumny zawierające łańcuchy znaków lub mieszane typy danych będą miały typ danych `object`[1]. Przyjrzyjmy się teraz bliżej indeksowi i kolumnom DataFrame.

## Indeks

Etykiety wierszy DataFrame są nazywane **indeksem**. Jeśli nie masz sensownego indeksu, pomiń go podczas konstruowania DataFrame, a pandas automatycznie utworzy wtedy indeks oparty na liczbach całkowitych, zaczynając od zera. Widzieliśmy to w pierwszym przykładzie, kiedy odczytywaliśmy DataFrame z pliku Excela. Indeks umożliwia bibliotece pandas szybsze wyszukiwanie danych i jest niezbędny do wielu typowych operacji, np. łączenia dwóch obiektów DataFrame. Dostęp do indeksu uzyskujemy w następujący sposób:

```
In [5]: df.index
Out[5]: Int64Index([1001, 1000, 1002, 1003], dtype='int64')
```

Jeśli ma to znaczenie, nadaj indeksowi nazwę. Podążając za przykładem tabeli w Excelu, nadajmy mu nazwę `numer`:

```
In [6]: df.index.name = "numer"
        df
```

[1] W pandas 1.0.0 wprowadzono wyspecjalizowany typ danych `string`, aby ułatwić niektóre operacje i uczynić je bardziej spójnymi z tekstem. Ponieważ jest on wciąż eksperymentalny, nie zamierzam go wykorzystywać w tej książce.

```
Out[6]:           imię  wiek     kraj  ocena kontynent
       numer
       1001       Mark    55   Włochy    4.5    Europa
       1000       John    33      USA    6.7   Ameryka
       1002        Tim    41      USA    3.9   Ameryka
       1003      Jenny    12   Niemcy    9.0    Europa
```

W odróżnieniu od klucza głównego bazy danych indeks DataFrame może mieć duplikaty, ale wyszukiwanie wartości może być w takim przypadku wolniejsze. Aby przekształcić indeks w zwykłą kolumnę, użyj metody `reset_index`, a aby ustawić nowy indeks, użyj `set_index`. Jeśli nie chcesz stracić istniejącego indeksu podczas ustawiania nowego, upewnij się, że najpierw go zresetowałeś:

```
In [7]: # Metoda "reset_index" przekształca indeks w kolumnę, zastępując
        # indeks indeksem domyślnym. Odpowiada to pierwszemu DataFrame,
        # który wczytaliśmy z Excela.
        df.reset_index()
Out[7]:      numer   imię  wiek     kraj  ocena kontynent
       0     1001   Mark    55   Włochy    4.5    Europa
       1     1000   John    33      USA    6.7   Ameryka
       2     1002    Tim    41      USA    3.9   Ameryka
       3     1003  Jenny    12   Niemcy    9.0    Europa
In [8]: # Metoda "reset_index" zmienia "numer" w zwykłą kolumnę,
        # a "set_index" zmienia kolumnę "imię" w indeks.
        df.reset_index().set_index("imię")
Out[8]:         numer  wiek     kraj  ocena kontynent
        imię
        Mark     1001    55   Włochy    4.5    Europa
        John     1000    33      USA    6.7   Ameryka
         Tim     1002    41      USA    3.9   Ameryka
       Jenny     1003    12   Niemcy    9.0    Europa
```

Wykonując `df.reset_index().set_index("name")`, stosujesz **łańcuchowanie metod**: ponieważ `reset_index()` zwraca DataFrame, możesz bezpośrednio wywołać inną metodę DataFrame bez konieczności uprzedniego wypisywania wyniku pośredniego.

### Metody DataFrame zwracają kopie

Za każdym razem, gdy na DataFrame wywołasz metodę w postaci `df.`*`nazwa_metody`*`()`, otrzymasz w wyniku kopię tego DataFrame z zastosowaną metodą, natomiast oryginalny obiekt DataFrame pozostanie nietknięty. Właśnie to zrobiliśmy poprzez wywołanie `df.reset_index()`. Gdybyś chciał zmienić oryginalny DataFrame, musiałbyś przypisać zwróconą wartość z powrotem do pierwotnej zmiennej, jak poniżej:

```
df = df.reset_index()
```

Ponieważ tego nie robimy, oznacza to, że nasza zmienna `df` nadal przechowuje swoje pierwotne dane. Następne przykłady również wywołują metody DataFrame, tzn. nie zmieniają oryginalnego obiektu DataFrame.

Aby zmienić indeks, użyj metody `reindex`:

```
In [9]: df.reindex([999, 1000, 1001, 1004])
Out[9]:          imię  wiek    kraj  ocena kontynent
        numer
        999       NaN   NaN     NaN    NaN       NaN
        1000     John  33.0     USA    6.7   Ameryka
```

```
1001     Mark  55.0  Włochy    4.5    Europa
1004      NaN   NaN     NaN    NaN       NaN
```

Jest to pierwszy przykład wyrównywania danych: metoda `reindex` przejmie wszystkie wiersze, które pasują do nowego indeksu, i wprowadzi wiersze z brakującymi wartościami (`NaN`), dla których nie ma żadnych informacji. Pominięte elementy indeksu zostaną usunięte. Wartość `NaN` omówię nieco później w tym rozdziale. Na koniec, aby posortować indeks, użyj metody `sort_index`:

```
In [10]: df.sort_index()
Out[10]:          imię  wiek    kraj  ocena kontynent
         numer
         1000     John    33     USA    6.7   Ameryka
         1001     Mark    55  Włochy    4.5    Europa
         1002      Tim    41     USA    3.9   Ameryka
         1003    Jenny    12  Niemcy    9.0    Europa
```

Jeśli zamiast tego chcesz posortować wiersze według jednej kolumny (lub kilku), użyj `sort_values`:

```
In [11]: df.sort_values(["kontynent", "wiek"])
Out[11]:          imię  wiek    kraj  ocena kontynent
         numer
         1000     John    33     USA    6.7   Ameryka
         1002      Tim    41     USA    3.9   Ameryka
         1003    Jenny    12  Niemcy    9.0    Europa
         1001     Mark    55  Włochy    4.5    Europa
```

Przykład pokazuje, jak posortować najpierw według kolumny `kontynent`, a następnie według kolumny `wiek`. Jeśli chcesz sortować tylko według jednej kolumny, możesz również podać nazwę kolumny jako łańcuch znaków:

```
df.sort_values("kontynent")
```

W ten sposób poznaliśmy podstawy działania indeksów. Zwróćmy teraz naszą uwagę na ich poziomy odpowiednik, czyli kolumny DataFrame!

## Kolumny

Aby uzyskać informacje o kolumnach DataFrame, uruchom następujący kod:

```
In [12]: df.columns
Out[12]: Index(['imię', 'wiek', 'kraj', 'ocena', 'kontynent'], dtype='object')
```

Jeśli przy konstruowaniu DataFrame nie podasz żadnych nazw kolumn, pandas ponumeruje je za pomocą liczb całkowitych, zaczynając od zera. W przypadku kolumn zwykle nie jest to dobry pomysł, ponieważ reprezentują one zmienne i dlatego są łatwe do nazwania. Nazwy do nagłówków kolumn przypisujemy w ten sam sposób, jak robiliśmy to z indeksem:

```
In [13]: df.columns.name = "cechy"
         df
Out[13]: cechy    imię  wiek    kraj  ocena kontynent
         numer
         1000     John    33     USA    6.7   Ameryka
         1001     Mark    55  Włochy    4.5    Europa
         1002      Tim    41     USA    3.9   Ameryka
         1003    Jenny    12  Niemcy    9.0    Europa
```

Jeśli nie odpowiadają Ci nazwy kolumn, możesz je zmienić:

```
In [14]: df.rename(columns={"imię": "Imię", "wiek": "Wiek"})
Out[14]: cechy    Imię  Wiek    kraj  ocena kontynent
         numer
         1000     John    33     USA    6.7   Ameryka
         1001     Mark    55  Włochy    4.5    Europa
         1002      Tim    41     USA    3.9   Ameryka
         1003    Jenny    12  Niemcy    9.0    Europa
```

Jeśli chcesz usunąć kolumny, użyj następującej składni (przykład pokazuje, jak usunąć jednocześnie kolumny i indeksy):

```
In [15]: df.drop(columns=["imię", "kraj"],
                 index=[1000, 1003])
Out[15]: cechy    wiek   ocena kontynent
         numer
         1001       55     4.5    Europa
         1002       41     3.9   Ameryka
```

Kolumny i indeks DataFrame są reprezentowane przez obiekt `Index`, tak więc możesz zamienić kolumny na wiersze (i odwrotnie) poprzez transpozycję DataFrame:

```
In [16]: df.T # Skrót od df.transpose()
Out[16]: numer         1001    1000     1002    1003
         cechy
         imię          Mark    John      Tim   Jenny
         wiek            55      33       41      12
         kraj        Włochy     USA      USA  Niemcy
         ocena          4.5     6.7      3.9       9
         kontynent  Europa  Ameryka  Ameryka  Europa
```

Warto przy tym pamiętać, że nasz obiekt DataFrame `df` jest wciąż niezmieniony, ponieważ nigdy nie przypisywaliśmy DataFrame zwracanego z wywołania metody z powrotem do oryginalnej zmiennej `df`. Jeżeli chciałbyś zmienić kolejność kolumn DataFrame, mógłbyś użyć metody `reindex`, której użyliśmy z indeksem, ale wybieranie kolumn w pożądanej kolejności jest często bardziej intuicyjne:

```
In [17]: df.loc[:, ["kontynent", "kraj", "imię", "wiek", "ocena"]]
Out[14]: cechy  kontynent    kraj   imię  wiek  ocena
         numer
         1001      Europa  Włochy   Mark    55   4.5
         1000     Ameryka     USA   John    33   6.7
         1002     Ameryka     USA    Tim    41   3.9
         1003      Europa  Niemcy  Jenny    12   9.0
```

Ten ostatni przykład wymaga kilku wyjaśnień; metodę `loc` i działanie selekcji danych omówię w następnym podrozdziale.

# Operowanie danymi

Dane pochodzące ze świata rzeczywistego raczej nie są podawane na srebrnej tacy, więc zanim zaczniesz z nimi pracować, musisz je oczyścić i przekształcić w strawną formę. Zaczniemy od tego, jak wybierać dane z DataFrame, jak je zmieniać oraz jak sobie radzić z brakującymi i zduplikowanymi danymi. Następnie wykonamy kilka obliczeń z wykorzystaniem obiektów DataFrame i zobaczymy, jak pracować z danymi tekstowymi. Na zakończenie tego podrozdziału dowiemy się, kiedy pandas zwraca widok, a kiedy kopię danych. Sporo koncepcji zawartych w tym podrozdziale jest powiązanych z tym, z czym mieliśmy już do czynienia przy okazji tablic NumPy w poprzednim rozdziale.

## Wybieranie danych

Zacznijmy od dostępu do danych na podstawie etykiety i pozycji, a następnie przyjrzyjmy się innym metodom, w tym indeksowaniu logicznemu i wybieraniu danych poprzez MultiIndex.

### Wybór na podstawie etykiety

Najczęstszym sposobem dostępu do danych DataFrame jest odwołanie się do etykiet. Aby określić, które wiersze i kolumny chcesz pobrać, użyj atrybutu `loc` (skrót od ang. *location* — położenie):

```
df.loc[wybór_wierszy, wybór_kolumn]
```

Atrybut `loc` obsługuje notację wycinków i dlatego akceptuje dwukropek, aby wybrać odpowiednio wszystkie wiersze lub wszystkie kolumny. Dodatkowo możesz podać listy z etykietami, jak również pojedynczą nazwę kolumny lub wiersza. Spójrz na tabelę 5.1, w której przedstawiono kilka przykładów wybierania różnych części z naszego przykładowego DataFrame `df`.

*Tabela 5.1. Wybieranie danych na podstawie etykiet*

| Wybór | Typ zwracanych danych | Przykład |
|---|---|---|
| Pojedyncza wartość | Skalar | `df.loc[1000, "kraj"]` |
| Jedna kolumna (1 wymiar) | Series | `df.loc[:, "kraj"]` |
| Jedna kolumna (2 wymiary) | DataFrame | `df.loc[:, ["kraj"]]` |
| Wiele kolumn | DataFrame | `df.loc[:, ["kraj", "wiek"]]` |
| Zakres kolumn | DataFrame | `df.loc[:, "imię":"kraj"]` |
| Jeden wiersz (1 wymiar) | Series | `df.loc[1000, :]` |
| Jeden wiersz (2 wymiary) | DataFrame | `df.loc[[1000], :]` |
| Wiele wierszy | DataFrame | `df.loc[[1003, 1000], :]` |
| Zakres wierszy | DataFrame | `df.loc[1000:1002, :]` |

#### Przy wycinaniu etykiet przedziały są zamknięte

Używanie notacji wycinków z wykorzystaniem etykiet jest niespójne z tym, jak działa wszystko inne w Pythonie i pandas: końcowa wartość jest *uwzględniania* w wycinku.

Wykorzystując naszą wiedzę z tabeli 5.1, zastosujmy atrybut `loc` do wybrania skalarów, obiektów Series i DataFrame:

```
In [18]: # Użycie skalarów do wyboru zarówno wierszy, jak i kolumn, zwraca skalar
         df.loc[1001, "imię"]
Out[18]: 'Mark'
In [19]: # Użycie skalara do wyboru wiersza lub kolumny zwraca obiekt Series
         df.loc[[1001, 1002], "wiek"]
Out[19]: numer
         1001    55
         1002    41
         Name: wiek, dtype: int64
In [20]: # Wybranie wielu wierszy i kolumn zwraca obiekt DataFrame
         df.loc[:1002, ["imię", "kraj"]]
Out[20]: cechy   imię    kraj
         numer
```

```
1001    Mark  Włochy
1000    John    USA
1002     Tim    USA
```

Ważne jest, abyś zrozumiał różnicę pomiędzy DataFrame z jedną lub wieloma kolumnami a Series: nawet z jedną kolumną, obiekty DataFrame są dwuwymiarowe, podczas gdy Series są jednowymiarowe. Zarówno DataFrame, jak i Series mają indeks, ale tylko DataFrame ma nagłówki kolumn. Kiedy wybierzesz kolumnę jako Series, nagłówek kolumny staje się nazwą obiektu Series. Wiele funkcji i metod będzie działać zarówno na obiektach Series, jak i na DataFrame, ale podczas wykonywania obliczeń arytmetycznych zachowanie będzie różne: w przypadku obiektów DataFrame pandas wyrównuje dane zgodnie z nagłówkami kolumn — więcej na ten temat w dalszej części tego rozdziału.

### Skrót do wyboru kolumn

Ponieważ wybieranie kolumn jest bardzo powszechną operacją, pandas oferuje skrót. Zamiast:

```
df.loc[:, wybór_kolumn]
```

możesz napisać:

```
df[wybór_kolumn]
```

Przykładowo `df["kraj"]` zwraca Series z naszego przykładowego DataFrame, a `df[["imię", "kraj"]]` zwraca DataFrame z dwiema kolumnami.

## Wybór na podstawie pozycji

Wybieranie podzbioru DataFrame na podstawie pozycji odpowiada temu, co robiliśmy na początku tego rozdziału z tablicami NumPy. W przypadku obiektów DataFrame musisz jednak użyć atrybutu `iloc` (skrót od ang. *integer location* — położenie całkowite):

```
df.iloc[wybór_wierszy, wybór_kolumn]
```

Używając wycinków, mamy do czynienia ze standardowymi przedziałami półotwartymi. Tabela 5.2 przedstawia te same przypadki, którym przyglądaliśmy się wcześniej w tabeli 5.1.

*Tabela 5.2. Wybieranie danych na podstawie pozycji*

| Wybór | Typ zwracanych danych | Przykład |
|---|---|---|
| Pojedyncza wartość | Skalar | `df.iloc[1, 2]` |
| Jedna kolumna (1 wymiar) | Series | `df.iloc[:, 2]` |
| Jedna kolumna (2 wymiary) | DataFrame | `df.iloc[:, [2]]` |
| Wiele kolumn | DataFrame | `df.iloc[:, [2, 1]]` |
| Zakres kolumn | DataFrame | `df.iloc[:, :3]` |
| Jeden wiersz (1 wymiar) | Series | `df.iloc[1, :]` |
| Jeden wiersz (2 wymiary) | DataFrame | `df.iloc[[1], :]` |
| Wiele wierszy | DataFrame | `df.iloc[[3, 1], :]` |
| Zakres wierszy | DataFrame | `df.iloc[1:3, :]` |

Oto przykłady użycia atrybutu `iloc` — ponownie z tymi samymi próbkami, których używaliśmy wcześniej z `loc`:

```
In [21]: df.iloc[0, 0] # Zwraca skalar
Out[21]: 'Mark'
In [22]: df.iloc[[0, 2], 1] # Zwraca Series
Out[22]: numer
         1001    55
         1002    41
         Name: wiek, dtype: int64
In [23]: df.iloc[:3, [0, 2]] # Zwraca DataFrame
Out[23]: cechy  imię    kraj
         numer
          1001  Mark  Włochy
          1000  John    USA
          1002   Tim    USA
```

Wybieranie danych na podstawie etykiety lub pozycji nie jest jedynym sposobem dostępu do podzbioru DataFrame. Innym ważnym rozwiązaniem jest użycie indeksowania logicznego; zobaczmy, jak to działa!

### Wybieranie przy użyciu indeksowania logicznego

Indeksowanie logiczne (ang. *boolean indexing*) odnosi się do wyboru podzbiorów DataFrame za pomocą obiektów Series lub DataFrame, których dane składają się tylko z wartości `True` lub `False`. Obiekty Series typu logicznego są używane do wybierania określonych kolumn i wierszy DataFrame, podczas gdy obiekty DataFrame typu logicznego są używane do wybierania określonych wartości w całym DataFrame. Najczęściej indeksowanie logiczne jest używane do filtrowania wierszy DataFrame. Potraktuj to jak funkcję Autofiltru w Excelu. Oto przykład użycia tej funkcji do filtrowania obiektu DataFrame w taki sposób, aby widoczne były tylko osoby, które mieszkają w USA i mają więcej niż 40 lat:

```
In [24]: tf = (df["wiek"] > 40) & (df["kraj"] == "USA")
         tf # To jest obiekt Series zawierający wyłącznie wartości True lub False
Out[24]: numer
         1001 False
         1000 False
         1002 True
         1003 False
         dtype: bool
In [25]: df.loc[tf, :]
Out[25]: cechy  imię  wiek  kraj  ocena  kontynent
         numer
          1002   Tim    41   USA    3.9    Ameryka
```

Są dwie rzeczy, które muszę tu wyjaśnić. Po pierwsze, z powodu ograniczeń technicznych nie można używać operatorów logicznych Pythona z rozdziału 3. z obiektami DataFrame. Zamiast tego należy użyć symboli, jak pokazano w tabeli 5.3.

*Tabela 5.3. Operatory logiczne*

| Podstawowe operatory logiczne Pythona | DataFrames i Series |
|---|---|
| `and` | `&` |
| `or` | `\|` |
| `not` | `~` |

Po drugie, jeśli masz więcej niż jeden warunek, upewnij się, że umieściłeś każde wyrażenie logiczne w nawiasach, aby nie przeszkodziło Ci pierwszeństwo operatorów: np. `&` ma wyższy priorytet niż `==`. Tak więc bez nawiasów wyrażenie z naszego przykładowego kodu zostałoby zinterpretowane jako:

```
df["wiek"] > (40 & df["kraj"]) == "USA"
```

Jeśli chcesz filtrować indeks, możesz się do niego odwołać poprzez `df.index`:

```
In [26]: df.loc[df.index > 1001, :]
Out[26]: cechy    imię  wiek     kraj  ocena  kontynent
         numer
          1002    Tim     41     USA     3.9    Ameryka
          1003  Jenny     12  Niemcy     9.0     Europa
```

W tych przypadkach, w których użyłbyś operatora `in` z podstawowymi strukturami danych Pythona, takimi jak listy, z Series użyj `isin`. W ten sposób można przefiltrować DataFrame, wybierając uczestników z Włoch i Niemiec:

```
In [27]: df.loc[df["kraj"].isin(["Włochy", "Niemcy"]), :]
Out[27]: cechy   imię  wiek    kraj  ocena  kontynent
         numer
          1001   Mark    55  Włochy    4.5     Europa
          1003  Jenny    12  Niemcy    9.0     Europa
```

Choć obiekty Series typu logicznego są przekazywane za pomocą atrybutu `loc`, obiekty DataFrame oferują specjalną składnię bez `loc`, umożliwiającą wybranie wartości z DataFrame zawierającego wartości logiczne:

```
df[logiczny_df]
```

Jest to szczególnie przydatne, jeżeli masz obiekty DataFrame, które zawierają tylko liczby. Przekazanie DataFrame z wartościami logicznymi zwraca DataFrame z wartościami `NaN` wszędzie tam, gdzie DataFrame typu logicznego ma wartość `False`. Wartość `NaN` omówię bardziej szczegółowo za chwilę. Zacznijmy od stworzenia nowego przykładowego DataFrame o nazwie `rainfall`, który składa się tylko z liczb:

```
In [28]: # Może to być roczna suma opadów w milimetrach
         rainfall = pd.DataFrame(data={"Miasto 1": [300.1, 100.2],
                                       "Miasto 2": [400.3, 300.4],
                                       "Miasto 3": [1000.5, 1100.6]})
         rainfall
Out[28]:    Miasto 1  Miasto 2  Miasto 3
         0     300.1     400.3    1000.5
         1     100.2     300.4    1100.6
In [29]: rainfall < 400
Out[29]:    Miasto 1  Miasto 2  Miasto 3
         0      True     False     False
         1      True      True     False
In [30]: rainfall[rainfall < 400]
Out[30]:    Miasto 1  Miasto 2  Miasto 3
         0     300.1       NaN       NaN
         1     100.2     300.4       NaN
```

Zauważ, że w tym przykładzie użyłem słownika do skonstruowania nowego obiektu DataFrame — jest to często wygodne, jeśli dane istnieją już w tej formie. Taki sposób pracy z wartościami logicznymi jest najczęściej używany do odfiltrowania określonych wartości, takich jak elementy odstające.

Na zakończenie części poświęconej selekcji danych przedstawię specjalny typ indeksu określany mianem MultiIndex.

### Wybieranie poprzez MultiIndex

**MultiIndex** to indeks, który ma więcej niż jeden poziom. Umożliwia on hierarchiczne grupowanie danych i zapewnia łatwy dostęp do podzbiorów. Dla przykładu, jeśli ustawisz indeks naszego przykładowego obiektu DataFrame `df` jako połączenie etykiet `kontynent` i `kraj`, możesz łatwo wybrać wszystkie wiersze z określonym kontynentem:

```
In [31]: # MultiIndex trzeba posortować
         df_multi = df.reset_index().set_index(["kontynent", "kraj"])
         df_multi = df_multi.sort_index()
         df_multi
Out[31]:           cechy  numer   imię  wiek  ocena
         kontynent  kraj
         Ameryka     USA   1000   John    33    6.7
                     USA   1002    Tim    41    3.9
         Europa   Niemcy   1003  Jenny    12    9.0
                  Włochy   1001   Mark    55    4.5
In [32]: df_multi.loc["Europa", :]
Out[32]:  cechy  numer   imię  wiek  ocena
           kraj
         Niemcy   1003  Jenny   12     9.0
         Włochy   1001   Mark   55     4.5
```

Zauważ, że MultiIndex jest nieco upiększony na wyjściu dzięki temu, że pandas nie powtarza najbardziej lewego poziomu indeksu (kontynenty) dla każdego wiersza. Zamiast tego wypisuje kontynent tylko wtedy, gdy ten się zmienia. Wybór pomiędzy wieloma poziomami indeksu odbywa się poprzez przekazanie krotki:

```
In [33]: df_multi.loc[("Europa", "Włochy"), :]
Out[33]:             cechy  numer  imię  wiek  ocena
         kontynent    kraj
            Europa  Włochy   1001  Mark    55    4.5
```

Jeśli chcesz wybiórczo zresetować część MultiIndeksu, podaj poziom jako argument. Zero to pierwsza kolumna od lewej:

```
In [34]: df_multi.reset_index(level=0)
Out[34]:  cechy  kontynent  numer   imię  wiek  ocena
           kraj
            USA    Ameryka   1000   John    33    6.7
            USA    Ameryka   1002    Tim    41    3.9
         Niemcy     Europa   1003  Jenny    12    9.0
         Włochy     Europa   1001   Mark    55    4.5
```

Chociaż w tej książce nie będziemy ręcznie tworzyć MultiIndeksu, istnieją pewne operacje, takie jak `groupby`, które spowodują, że pandas zwróci obiekt DataFrame z MultiIndeksem, więc warto wiedzieć, co to jest. Z `groupby` spotkamy się w dalszej części tego rozdziału.

Teraz, gdy znasz już różne sposoby *wybierania* danych, nadszedł czas, aby dowiedzieć się, jak *zmieniać* dane.

## Ustawianie danych

Najprostszym sposobem zmiany danych w DataFrame jest przypisanie wartości do określonych elementów za pomocą atrybutów `loc` lub `iloc`. To jest punkt wyjścia tej sekcji, zanim przejdziemy do innych sposobów operowania na istniejących obiektach DataFrame: zastępowania wartości i dodawania nowych kolumn.

### Ustawianie danych na podstawie etykiety lub pozycji

Jak wspomniano wcześniej w tym rozdziale, jeśli wywołamy metodę DataFrame, taką jak `df.reset_index()`, zostanie ona zawsze zastosowana do kopii, pozostawiając oryginalny obiekt DataFrame nietknięty. Jednakże przypisywanie wartości za pomocą atrybutów `loc` i `iloc` zmienia oryginalny DataFrame. Ponieważ nie chcę zmieniać naszego DataFrame `df`, pracuję tutaj na kopii, którą nazwałem `df2`. Jeśli chcesz zmienić pojedynczą wartość, wykonaj poniższy kod:

```
In [35]: # Najpierw skopiuj DataFrame, aby oryginał pozostał nietknięty
         df2 = df.copy()
In [36]: df2.loc[1000, "imię"] = "JOHN"
         df2
Out[36]: cechy   imię  wiek    kraj  ocena  kontynent
         numer
          1001   Mark    55  Włochy    4.5     Europa
          1000   JOHN    33     USA    6.7    Ameryka
          1002    Tim    41     USA    3.9    Ameryka
          1003  Jenny    12  Niemcy    9.0     Europa
```

Możesz także zmieniać wiele wartości jednocześnie. Jednym ze sposobów na zmianę oceny użytkowników o numerach identyfikacyjnych 1000 i 1001 jest użycie listy:

```
In [37]: df2.loc[[1000, 1001], "ocena"] = [3, 4]
         df2
Out[37]: cechy   imię  wiek    kraj  ocena  kontynent
         numer
          1001   Mark    55  Włochy    4.0     Europa
          1000   JOHN    33     USA    3.0    Ameryka
          1002    Tim    41     USA    3.9    Ameryka
          1003  Jenny    12  Niemcy    9.0     Europa
```

Zmiana danych na podstawie pozycji poprzez `iloc` działa w ten sam sposób. Zobaczmy teraz, jak można zmienić dane za pomocą indeksowania logicznego.

### Ustawianie danych przy użyciu indeksowania logicznego

Indeksowanie logiczne, którego używaliśmy do filtrowania wierszy, może być również użyte do przypisywania wartości w DataFrame. Wyobraź sobie, że potrzebujesz zanonimizować wszystkie dane osobowe uczestników, którzy mają mniej niż 20 lat lub pochodzą z USA:

```
In [38]: tf = (df2["wiek"] < 20) | (df2["kraj"] == "USA")
         df2.loc[tf, "imię"] = "xxx"
         df2
Out[38]: cechy  imię  wiek    kraj  ocena  kontynent
         numer
          1001  Mark    55  Włochy    4.0     Europa
          1000   xxx    33     USA    3.0    Ameryka
```

```
 1002   xxx    41     USA    3.9    Ameryka
 1003   xxx    12  Niemcy    9.0     Europa
```

Czasem masz zbiór danych, w którym musisz zastąpić określone wartości dla całego zbioru, a nie tylko dla określonych kolumn. W takim przypadku ponownie użyj specjalnej składni i przekaż cały obiekt DataFrame z wartościami logicznymi w poniższy sposób (w przykładzie ponownie wykorzystano DataFrame `rainfall`):

```
In [39]: # Najpierw skopiuj DataFrame, aby oryginał pozostał nietknięty
         rainfall2 = rainfall.copy()
         rainfall2
Out[39]:    Miasto 1  Miasto 2  Miasto 3
         0     300.1     400.3    1000.5
         1     100.2     300.4    1100.6
In [40]: # Ustaw 0 wszędzie tam, gdzie wartości są poniżej 400
         rainfall2[rainfall2 < 400] = 0
         rainfall2
Out[39]:    Miasto 1  Miasto 2  Miasto 3
         0       0.0     400.3    1000.5
         1       0.0       0.0    1100.6
```

Jeśli chcesz po prostu zastąpić jakąś wartość inną, jest na to prostszy sposób, który pokażę Ci za chwilę.

### Ustawianie danych poprzez zamianę wartości

Jeżeli chcesz zastąpić określoną wartość w całym DataFrame lub w wybranych kolumnach, użyj metody `replace`:

```
In [41]: df2.replace("USA", "Stany Zjednoczone")
Out[41]: cechy  imię  wiek              kraj  ocena  kontynent
         numer
          1001  Mark    55            Włochy    4.0     Europa
          1000   xxx    33  Stany Zjednoczone    3.0    Ameryka
          1002   xxx    41  Stany Zjednoczone    3.9    Ameryka
          1003   xxx    12            Niemcy    9.0     Europa
```

Jeśli zamiast tego chciałbyś działać tylko na kolumnie `kraj`, mógłbyś użyć następującej składni:

```
df2.replace({"kraj": {"USA": "Stany Zjednoczone"}})
```

W tym przypadku, ponieważ wartość `USA` pojawia się tylko w kolumnie `kraj`, daje to taki sam wynik jak w poprzednim przykładzie. Na koniec tej sekcji zobaczymy, jak można dodać dodatkowe kolumny do DataFrame.

### Ustawianie danych poprzez dodanie nowej kolumny

Aby dodać nową kolumnę do DataFrame, należy przypisać wartości do nazwy nowej kolumny. Możesz na przykład dodać nową kolumnę do DataFrame za pomocą skalara lub listy:

```
In [42]: df2.loc[:, "rabat"] = 0
         df2.loc[:, "cena"] = [49.9, 49.9, 99.9, 99.9]
         df2
Out[42]: cechy  imię  wiek    kraj  ocena  kontynent  rabat  cena
         numer
          1001  Mark    55  Włochy    4.0     Europa      0  49.9
```

```
1000   xxx    33     USA    3.0    Ameryka      0  49.9
1002   xxx    41     USA    3.9    Ameryka      0  99.9
1003   xxx    12  Niemcy    9.0     Europa      0  99.9
```

Dodanie nowej kolumny często wymaga obliczeń wektorowych:

```
In [43]: df2 = df.copy() # zacznijmy od nowej kopii
         df2.loc[:, "rok urodzenia"] = 2021 - df2["wiek"]
         df2
Out[43]: cechy   imię  wiek    kraj  ocena  kontynent  rok urodzenia
         numer
          1001   Mark    55  Włochy    4.5     Europa           1966
          1000   John    33     USA    6.7    Ameryka           1988
          1002    Tim    41     USA    3.9    Ameryka           1980
          1003  Jenny    12  Niemcy    9.0     Europa           2009
```

Za chwilę przedstawię więcej szczegółów na temat obliczeń z wykorzystaniem obiektów DataFrame, ale zanim do tego dojdziemy — czy pamiętasz, że już kilka razy użyłem wartości `NaN`? W następnej części dowiesz się więcej na temat brakujących danych.

## Brakujące dane

Brakujące dane mogą stanowić problem, ponieważ mogą potencjalnie wpłynąć na wyniki analizy danych, co sprawi, że wnioski będą mniej wiarygodne. Niemniej jednak bardzo często zdarzają się braki w zbiorach danych, z czym będziesz musiał sobie poradzić. W Excelu zwykle masz do czynienia z pustymi komórkami lub błędami `#N/D`, ale pandas dla brakujących danych używa stałej NumPy `np.nan`, wyświetlanej jako `NaN`. `NaN` jest standardową wartością typu zmiennoprzecinkowego oznaczającą *Not-a-Number* (nie-liczba). Dla znaczników czasu używane jest `pd.NaT`, a dla tekstu pandas używa `None`. Używając `None` lub `np.nan`, można wprowadzić brakujące wartości:

```
In [44]: df2 = df.copy()# zacznijmy od nowej kopii
         df2.loc[1000, "ocena"] = None
         df2.loc[1003, :] = None
         df2
Out[44]: cechy  imię  wiek    kraj  ocena  kontynent
         numer
          1001  Mark  55.0  Włochy    4.5     Europa
          1000  John  33.0     USA    NaN    Ameryka
          1002   Tim  41.0     USA    3.9    Ameryka
          1003  None   NaN    None    NaN       None
```

Aby oczyścić DataFrame, często chcemy usunąć wiersze z brakującymi danymi. Jest to bardzo proste:

```
In [45]: df2.dropna()
Out[45]: cechy  imię  wiek    kraj  ocena  kontynent
         numer
          1001  Mark  55.0  Włochy    4.5     Europa
          1002   Tim  41.0     USA    3.9    Ameryka
```

Jeśli jednak chcesz usunąć tylko te wiersze, w których brakuje *wszystkich* wartości, użyj parametru `how`:

```
In [46]: df2.dropna(how="all")
Out[46]: cechy  imię  wiek    kraj  ocena  kontynent
         numer
          1001  Mark  55.0  Włochy    4.5     Europa
          1000  John  33.0     USA    NaN    Ameryka
          1002   Tim  41.0     USA    3.9    Ameryka
```

Aby uzyskać DataFrame lub Series z wartościami logicznymi w zależności od tego, czy występuje wartość NaN, czy nie, użyj isna:

```
In [47]: df2.isna()
Out[47]: cechy   imię   wiek   kraj  ocena  kontynent
         numer
          1001  False  False  False  False      False
          1000  False  False  False   True      False
          1002  False  False  False  False      False
          1003   True   True   True   True       True
```

Aby uzupełnić brakujące wartości, użyj fillna. Przykładowo, aby zastąpić wartości NaN w kolumnie ocena ich średnią (za chwilę wprowadzę statystyki opisowe takie jak mean), wpisz:

```
In [48]: df2.fillna({"ocena": df2["ocena"].mean()})
Out[48]: cechy  imię  wiek    kraj  ocena  kontynent
         numer
          1001  Mark  55.0  Włochy    4.5     Europa
          1000  John  33.0     USA    NaN    Ameryka
          1002   Tim  41.0     USA    3.9    Ameryka
          1003  None   NaN    None    4.2       None
```

Brakujące dane nie są jedynym przypadkiem, który wymaga od nas oczyszczenia zbioru danych. To samo dotyczy zduplikowanych danych, zobaczmy więc, jakie mamy możliwości!

## Zduplikowane dane

Podobnie jak brakujące dane, duplikaty negatywnie wpływają na wiarygodność analizy. Aby się pozbyć zduplikowanych wierszy, użyj metody drop_duplicates. Opcjonalnie jako argument możesz podać podzbiór kolumn:

```
In [49]: df.drop_duplicates(["kraj", "kontynent"])
Out[49]: cechy   imię  wiek    kraj  ocena  kontynent
         numer
          1001   Mark    55  Włochy    4.0     Europa
          1000   John    33     USA    3.0    Ameryka
          1003  Jenny    12  Niemcy    9.0     Europa
```

Domyślnie pozostawia to pierwsze wystąpienie. Aby sprawdzić, czy dana kolumna zawiera duplikaty lub aby uzyskać jej unikatowe wartości, użyj następujących dwóch poleceń (użyj df.index zamiast df["kraj"], jeśli chcesz uruchomić to na indeksie):

```
In [50]: df["kraj"].is_unique
Out[50]: False
In [51]: df["kraj"].unique()
Out[51]: array(['Włochy', 'USA', 'Niemcy'], dtype=object)
```

I w końcu, aby dowiedzieć się, które wiersze są duplikatami, użyj metody duplicated, która zwraca obiekt Series z wartościami logicznymi: domyślnie używa ona parametru keep="first", który zachowuje pierwsze wystąpienie i oznacza tylko duplikaty jako True. Przy ustawieniu parametru keep=False metoda zwróci wartość True dla wszystkich wierszy z duplikatami, łącznie z pierwszym wystąpieniem, dzięki czemu łatwo jest uzyskać DataFrame ze wszystkimi zduplikowanymi wierszami. W poniższym przykładzie szukamy duplikatów w kolumnie kraj, ale w rzeczywistości często sprawdza się indeks lub całe wiersze. W takim przypadku musiałbyś użyć df.index.duplicated() lub df.duplicated():

```
In [52]: # Domyślnie jako True oznaczane są tylko duplikaty
         # (bez pierwszego wystąpienia)
         df["country"].duplicated()
Out[52]: numer
         1001  False
         1000  False
         1002   True
         1003  False
         Name: kraj, dtype: bool
In [53]: # Aby uzyskać wszystkie wiersze, w których "kraj" jest zduplikowany,
         # użyj keep=False
         df.loc[df["kraj"].duplicated(keep=False), :]
Out[53]: cechy  imię  wiek  kraj  ocena  kontynent
         numer
          1000  John  33     USA    6.7    Ameryka
          1002   Tim  41     USA    3.9    Ameryka
```

Po oczyszczeniu DataFrame poprzez usunięcie brakujących i zduplikowanych danych, być może będziesz chciał wykonać pewne operacje arytmetyczne — następna sekcja zawiera wprowadzenie do tego tematu.

## Operacje arytmetyczne

Podobnie jak tablice NumPy, obiekty DataFrame i Series wykorzystują wektoryzację. Na przykład, aby dodać liczbę do każdej wartości DataFrame `rainfall`, wystarczy wprowadzić następujący kod:

```
In [54]: rainfall
Out[54]:    Miasto 1  Miasto 2  Miasto 3
         0     300.1     400.3    1000.5
         1     100.2     300.4    1100.6
In [55]: rainfall + 100
Out[55]:    Miasto 1  Miasto 2  Miasto 3
         0     400.1     500.3    1100.5
         1     200.2     400.4    1200.6
```

Jednak prawdziwa siła pandas tkwi w mechanizmie automatycznego **wyrównywania danych**: gdy stosujesz operatory arytmetyczne z więcej niż jednym obiektem DataFrame, pandas automatycznie wyrównuje je na podstawie ich indeksów kolumn i wierszy. Utwórzmy drugi DataFrame z tymi samymi etykietami wierszy i kolumn. Następnie utworzymy sumę:

```
In [56]: more_rainfall = pd.DataFrame(data=[[100, 200], [300, 400]],
                                       index=[1, 2],
                                       columns=["Miasto 1", "Miasto 4"])
         more_rainfall
Out[56]:  Miasto 1  Miasto 4
        1      100       200
        2      300       400
In [57]: rainfall + more_rainfall
Out[57]:  Miasto 1  Miasto 2  Miasto 3  Miasto 4
        0      NaN       NaN       NaN      NaN
        1    200.2       NaN       NaN      NaN
        2      NaN       NaN       NaN      NaN
```

Indeks i kolumny wynikowego DataFrame są połączeniem indeksów i kolumn dwóch składowych obiektów DataFrame: pola, które w obu DataFrame zawierają wartość, pokazują sumę, podczas gdy w pozostałej części DataFrame pojawia się wartość `NaN`. To coś, do czego musisz się przyzwyczaić,

jeśli pracowałeś wcześniej w Excelu, gdzie puste komórki są automatycznie zamieniane na zera, gdy używasz ich w operacjach arytmetycznych. Chcąc uzyskać takie samo zachowanie jak w Excelu, użyj metody `add` z parametrem `fill_value`, aby zastąpić wartości `NaN` zerami:

```
In [58]: rainfall.add(more_rainfall, fill_value=0)
Out[58]:  Miasto 1  Miasto 2  Miasto 3  Miasto 4
        0    300.1     400.3    1000.5       NaN
        1    200.2     300.4    1100.6     200.0
        2    300.0       NaN       NaN     400.0
```

Analogicznie działa to również dla innych operatorów arytmetycznych, jak pokazano w tabeli 5.4.

*Tabela 5.4. Operatory arytmetyczne*

| Operator | Metoda |
|---|---|
| * | mul |
| + | add |
| - | sub |
| / | div |
| ** | pow |

Jeśli w swoich obliczeniach używasz DataFrame i Series, domyślnie obiekt Series jest rozgłaszany wzdłuż indeksu:

```
In [59]: # Obiekt Series pobrany z wiersza
         rainfall.loc[1, :]
Out[59]: Miasto 1     100.2
         Miasto 2     300.4
         Miasto 3    1100.6
         Name: 1, dtype: float64
In [60]: rainfall + rainfall.loc[1, :]
Out[60]:    Miasto 1  Miasto 2  Miasto 3
         0     400.3     700.7    2101.1
         1     200.4     600.8    2201.2
```

Dlatego, aby dodać obiekt Series z uwzględnieniem położenia kolumn, musisz użyć metody `add` z jawnym argumentem osi (`axis`):

```
In [61]: # Obiekt Series pobrany z kolumny
         rainfall.loc[:, "Miasto 2"]
Out[61]: 0    400.3
         1    300.4
         Name: Miasto 2, dtype: float64
In [62]: rainfall.add(rainfall.loc[:, "Miasto 2"], axis=0)
Out[62]:    Miasto 1  Miasto 2  Miasto 3
         0     700.4     800.6    1400.8
         1     400.6     600.8    1401.0
```

Omówiliśmy już obiekty DataFrame z liczbami i ich zachowanie w operacjach arytmetycznych, natomiast w następnej części poznamy możliwości związane z przetwarzaniem tekstu w DataFrame.

## Praca z kolumnami tekstowymi

Jak widzieliśmy na początku tego rozdziału, kolumny z tekstem lub mieszanymi typami danych mają typ danych `object`. Aby wykonywać operacje na kolumnach z łańcuchami znaków, należy użyć atrybutu `str`, który daje dostęp do metod łańcuchów znaków w Pythonie. Kilka z tych metod poznaliśmy już w rozdziale 3., ale nie zaszkodzi zajrzeć do dostępnych metod w dokumentacji Pythona (*https://oreil.ly/-e7SC*). Dla przykładu, aby usunąć wiodący i końcowy znak niedrukowalny, należy użyć metody `strip`; aby zmienić wszystkie pierwsze litery na wielkie, należy użyć metody `capitalize`. Połączenie tych metod pozwoli oczyścić kolumny z niechlujnego tekstu, który często jest wynikiem ręcznego wprowadzania danych:

```
In [63]: # Utwórzmy nowy obiekt DataFrame
         users = pd.DataFrame(data=[" mArk ", "JOHN ", "Tim", " jenny"],
         columns=["imię"])
         users
Out[63]:    imię
         0  mArk
         1  JOHN
         2   Tim
         3 jenny
In [64]: users_cleaned = users.loc[:, "imię"].str.strip().str.capitalize()
         users_cleaned
Out[64]: 0     Mark
         1     John
         2      Tim
         3    Jenny
         Name: imię, dtype: object
```

Możemy też wyszukać wszystkie imiona, które zaczynają się na literę „J”:

```
In [65]: users_cleaned.str.startswith("J")
Out[65]: 0    False
         1     True
         2    False
         3     True
         Name: imię, dtype: bool
```

Metody łańcuchów znaków są łatwe w użyciu, ale czasami może zajść konieczność przetworzenia DataFrame w sposób, który nie jest wbudowany. W takim przypadku możesz stworzyć własną funkcję i zastosować ją do DataFrame, co zostanie pokazane w następnej sekcji.

## Stosowanie funkcji

DataFrames oferują metodę `applymap`, która zastosuje funkcję do każdego pojedynczego elementu, co jest przydatne, jeśli nie ma dostępnych funkcji uniwersalnych NumPy. Przykładowo nie ma funkcji uniwersalnych dla formatowania łańcuchów znaków, więc możemy sformatować każdy element DataFrame, jak poniżej:

```
In [66]: rainfall
Out[66]:    Miasto 1  Miasto 2  Miasto 3
         0     300.1     400.3    1000.5
         1     100.2     300.4    1100.6
In [67]: def format_string(x):
         return f"{x:,.2f}"
```

```
In [68]: # Zauważ, że przekazujemy funkcję bez jej wywołania,
         # czyli format_string, a nie format_string()!
         rainfall.applymap(format_string)
Out[68]:    Miasto 1  Miasto 2  Miasto 3
         0    300.10    400.30  1,000.50
         1    100.20    300.40  1,100.60
```

Rozkładając to na czynniki pierwsze: sformatowany literał łańcucha (*f-string*) `f"{x}"` zwraca `x` jako łańcuch znaków. Aby dodać formatowanie, dołącz do zmiennej dwukropek, a następnie łańcuch formatujący `,.2f`. Przecinek jest tu separatorem tysięcy, a `.2f` oznacza *zapis stałoprzecinkowy z dwiema cyframi po separatorze dziesiętnym*. Aby uzyskać więcej szczegółów na temat formatowania łańcuchów, zapoznaj się z sekcją *Format Specification Mini-Language* (*https://oreil.ly/NgsG8*), która jest częścią dokumentacji Pythona.

### Wyrażenia lambda

Python pozwala na zdefiniowanie funkcji w pojedynczym wierszu za pomocą **wyrażeń lambda**. Wyrażenia lambda są funkcjami anonimowymi, co oznacza, że nie mają nazwy. Rozważmy taką funkcję:

```
def nazwa_funkcji(arg1, arg2, ...):
    return zwracana_wartość
```

Ta funkcja może zostać przepisana jako wyrażenie lambda w następujący sposób:

```
lambda arg1, arg2, ...: zwracana_wartość
```

Krótko mówiąc, zastępujesz `def` przez `lambda`, pomijasz słowo kluczowe `return` i nazwę funkcji i umieszczasz wszystko w jednym wierszu. W tym przypadku, jak widzieliśmy na przykładzie metody `applymap`, może to być naprawdę wygodne, ponieważ nie musimy definiować funkcji dla czegoś, co jest używane tylko raz.

W tego typu przypadkach często używa się *wyrażeń lambda* (patrz ramka), ponieważ umożliwiają one zapisanie tego samego w pojedynczym wierszu, bez konieczności definiowania osobnej funkcji. Dzięki wyrażeniom lambda możemy przepisać poprzedni przykład w następujący sposób:

```
In [69]: rainfall.applymap(lambda x: f"{x:,.2f}")
Out[69]:    Miasto 1  Miasto 2  Miasto 3
         0    300.10    400.30  1,000.50
         1    100.20    300.40  1,100.60
```

Wymieniłem już wszystkie najważniejsze metody operowania na danych, ale zanim przejdziemy dalej, ważne jest, aby zrozumieć, kiedy pandas używa widoku DataFrame, a kiedy kopii.

## Widok a kopia

Być może pamiętasz z poprzedniego rozdziału, że wycinanie tablic NumPy zwraca widok. W przypadku obiektów DataFrame jest to niestety bardziej skomplikowane: nie zawsze można łatwo przewidzieć, czy atrybuty `loc` i `iloc` zwracają widok, czy kopię, co sprawia, że jest to jeden z bardziej zagmatwanych tematów. Ponieważ istnieje duża różnica, czy zmieniasz widok, czy kopię DataFrame, pandas regularnie zgłasza następujące ostrzeżenie, gdy myśli, że ustawiasz dane w niezamierzony sposób: `SettingWithCopyWarning`. Oto kilka rad, jak obejść to dość zagadkowe ostrzeżenie:

Ustawiaj wartości w oryginalnym DataFrame, a nie w takim, które zostało wycięte z innego DataFrame.

Jeśli po operacji wycinania chcesz mieć niezależny obiekt DataFrame, utwórz jawnie jego kopię:

```
selection = df.loc[:, ["kraj", "kontynent"]].copy()
```

Choć z `loc` i `iloc` sprawa jest skomplikowana, warto pamiętać, że wszystkie metody DataFrame, takie jak `df.dropna()` lub `df.sort_values("nazwa_kolumny")`, zawsze zwracają kopię.

Do tej pory pracowaliśmy głównie z jednym obiektem DataFrame naraz. W następnym podrozdziale przedstawione zostaną różne sposoby łączenia wielu obiektów DataFrame w jeden, co jest bardzo częstym zadaniem, do którego pandas oferuje wydajne narzędzia.

# Łączenie obiektów DataFrame

Łączenie różnych zbiorów danych w Excelu może być uciążliwym zadaniem i zazwyczaj wiąże się z dużą ilością formuł `WYSZUKAJ.PIONOWO`. Na szczęście łączenie obiektów DataFrame to jedna z najbardziej atrakcyjnych funkcji pandas, która znacznie ułatwia życie i zmniejsza możliwość popełniania błędów. Obiekty DataFrame można łączyć i scalać na różne sposoby; w tym podrozdziale przyjrzymy się tylko najczęstszym przypadkom, w których stosuje się funkcje `concat`, `join` i `merge`. Chociaż funkcje te pokrywają się, każda z nich bardzo upraszcza określone zadanie. Zacznę od funkcji `concat`, następnie wyjaśnię różne opcje funkcji `join`, a na koniec przedstawię `merge`, najbardziej ogólną funkcję z tych trzech.

## Konkatenacja

Jeśli chcesz po prostu skleić ze sobą wiele obiektów DataFrame, najlepszym rozwiązaniem jest funkcja `concat`. Jak można wywnioskować z jej nazwy, przeprowadza ona proces zwany technicznie **konkatenacją**. Domyślnie funkcja `concat` skleja obiekty DataFrame wzdłuż wierszy i automatycznie wyrównuje kolumny. W poniższym przykładzie tworzę kolejny DataFrame o nazwie `more_users` i dołączam go do dolnej części naszego przykładowego DataFrame `df`:

```
In [70]: data=[[15, "Francja", 4.1, "Becky"],
               [44, "Kanada", 6.1, "Leanne"]]
         more_users = pd.DataFrame(data=data,
                                   columns=["wiek", "kraj", "ocena", "imię"],
                                   index=[1000, 1011])
         more_users
Out[70]:       wiek     kraj  ocena    imię
         1000    15  Francja    4.1   Becky
         1011    44   Kanada    6.1  Leanne
In [71]: pd.concat([df, more_users], axis=0)
Out[71]:         imię  wiek     kraj  ocena  kontynent
         1001    Mark    55   Włochy    4.5     Europa
         1000    John    33      USA    6.7    Ameryka
         1002     Tim    41      USA    3.9    Ameryka
         1003   Jenny    12   Niemcy    9.0     Europa
         1000   Becky    15  Francja    4.1        NaN
         1011  Leanne    44   Kanada    6.1        NaN
```

Zauważ, że masz teraz zduplikowane elementy indeksu, ponieważ `concat` skleja dane na wskazanej osi (wiersze) i tylko wyrównuje dane na drugiej osi (kolumny), automatycznie dopasowując nazwy

kolumn — nawet jeśli nie występują one w tej samej kolejności w dwóch DataFrame! Jeśli chcesz skleić dwa obiekty DataFrame wzdłuż kolumn, ustaw `axis=1`:

```
In [72]: data=[[3, 4],
               [5, 6]]
         more_categories = pd.DataFrame(data=data,
                                        columns=["testy", "logowania"],
                                        index=[1000, 2000])
         more_categories
Out[72]:       testy logowania
         1000      3         4
         2000      5         6
In [73]: pd.concat([df, more_categories], axis=1)
Out[73]:         imię  wiek     kraj  ocena  kontynent  testy  logowania
         1000    John  33.0      USA    6.7    Ameryka    3.0        4.0
         1001    Mark  55.0   Włochy    4.5     Europa    NaN        NaN
         1002     Tim  41.0      USA    3.9    Ameryka    NaN        NaN
         1003   Jenny  12.0   Niemcy    9.0     Europa    NaN        NaN
         2000     NaN   NaN      NaN    NaN        NaN    5.0        6.0
```

Szczególną i bardzo użyteczną cechą funkcji `concat` jest to, że akceptuje ona więcej niż dwa obiekty DataFrame. Skorzystamy z tego w następnym rozdziale, aby utworzyć pojedynczy DataFrame z wielu plików CSV:

```
pd.concat([df1, df2, df3, ...])
```

Z kolei funkcje `join` i `merge`, jak zobaczymy za chwilę, działają tylko z dwoma obiektami DataFrame.

## Operacje join i merge

Wykonując operację `join`, łączysz kolumny każdego z dwóch obiektów DataFrame w nowy DataFrame, decydując jednocześnie o tym, co stanie się z wierszami, w oparciu o teorię zbiorów. Jeśli pracowałeś wcześniej z relacyjnymi bazami danych, jest to ta sama koncepcja, która występuje przy klauzuli `JOIN` w zapytaniach SQL. Rysunek 5.3 przedstawia działanie czterech typów operacji łączenia (wewnętrznej, lewej, prawej i zewnętrznej) na przykładzie dwóch przykładowych obiektów DataFrame, `df1` i `df2`.

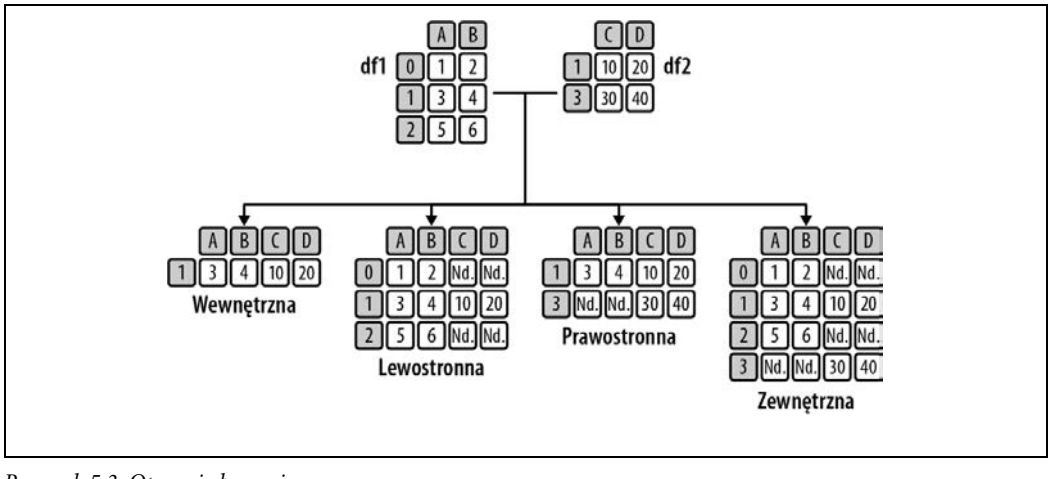


*Rysunek 5.3. Operacje łączenia*

Przy stosowaniu funkcji `join` pandas wykorzystuje indeksy obu obiektów DataFrame do wyrównania wierszy. **Wewnętrzna operacja łączenia** (ang. *inner join*) zwraca obiekt DataFrame zawierający tylko te wiersze, których indeksy się pokrywają. **Lewostronna operacja łączenia** (ang. *left join*) pobiera wszystkie wiersze z lewego DataFrame (`df1`) i dopasowuje wiersze z prawego DataFrame (`df2`) zgodnie z indeksem. Tam, gdzie `df2` nie ma pasującego wiersza, pandas wypełni pola wartościami `NaN`. Lewostronna operacja łączenia odpowiada formule `WYSZUKAJ.PIONOWO` w Excelu. **Prawostronna operacja łączenia** (ang. *right join*) pobiera wszystkie wiersze z prawej tabeli `df2` i dopasowuje je do wierszy z `df1` zgodnie z indeksem. I wreszcie **zewnętrzna operacja łączenia** (ang. *outer join*, pełna nazwa to *full outer join*) tworzy sumę indeksów z obu obiektów DataFrame i dopasowuje wartości tam, gdzie jest to możliwe. Tabela 5.5 jest odpowiednikiem rysunku 5.3 w formie tekstowej.

*Tabela 5.5. Operacje łączenia*

| Typ | Opis |
|---|---|
| `inner` | Tylko wiersze, których indeks występuje w obu obiektach DataFrame |
| `left` | Wszystkie wiersze z lewego DataFrame, pasujące wiersze z prawego DataFrame |
| `right` | Wszystkie wiersze z prawego DataFrame, pasujące wiersze z lewego DataFrame |
| `outer` | Suma indeksów wierszy z obu obiektów DataFrame |

Zobaczmy, jak to działa w praktyce, wprowadzając w życie przykłady z rysunku 5.3:

```
In [74]: df1 = pd.DataFrame(data=[[1, 2], [3, 4], [5, 6]],
                             columns=["A", "B"])
         df1
Out[74]:    A  B
         0  1  2
         1  3  4
         2  5  6
In [75]: df2 = pd.DataFrame(data=[[10, 20], [30, 40]],
                             columns=["C", "D"], index=[1, 3])
         df2
Out[75]:     C   D
         1  10  20
         3  30  40
In [76]: df1.join(df2, how="inner")
Out[76]:    A  B   C   D
         1  3  4  10  20
In [77]: df1.join(df2, how="left")
Out[77]:    A  B     C     D
         0  1  2   NaN   NaN
         1  3  4  10.0  20.0
         2  5  6   NaN   NaN
In [78]: df1.join(df2, how="right")
Out[78]:      A    B   C   D
         1  3.0  4.0  10  20
         3  NaN  NaN  30  40
In [79]: df1.join(df2, how="outer")
Out[79]:      A    B     C     D
         0  1.0  2.0   NaN   NaN
         1  3.0  4.0  10.0  20.0
         2  5.0  6.0   NaN   NaN
         3  NaN  NaN  30.0  40.0
```

Jeśli chcesz dołączyć co najmniej jedną kolumnę DataFrame, zamiast polegać na indeksie, użyj `merge` zamiast `join`. Funkcja `merge` przyjmuje argument `on`, aby podać co najmniej jedną kolumnę jako **warunek łączenia** (ang. *join condition*): kolumny te, które muszą występować w obu obiektach DataFrame, zostaną wykorzystane do dopasowania wierszy:

```
In [80]: # Dodaj kolumnę o nazwie "kategoria" do obu obiektów DataFrame
         df1["kategoria"] = ["a", "b", "c"]
         df2["kategoria"] = ["c", "b"]
In [81]: df1
Out[81]:    A  B  kategoria
         0  1  2          a
         1  3  4          b
         2  5  6          c
In [82]: df2
Out[82]:     C   D  kategoria
         1  10  20          c
         3  30  40          b
In [83]: df1.merge(df2, how="inner", on=["kategoria"])
Out[83]:    A  B  kategoria   C   D
         0  3  4          b  30  40
         1  5  6          c  10  20
In [84]: df1.merge(df2, how="left", on=["kategoria"])
Out[84]:    A  B  kategoria     C     D
         0  1  2          a   NaN   NaN
         1  3  4          b  30.0  40.0
         2  5  6          c  10.0  20.0
```

Ponieważ funkcje `join` i `merge` akceptują sporo opcjonalnych argumentów, aby uwzględnić bardziej złożone scenariusze, zapraszam do zapoznania się z oficjalną dokumentacją (*https://oreil.ly/OZ4WV*), z której dowiesz się na ten temat więcej.

Wiesz już, jak operować na jednym lub kilku obiektach DataFrame, co prowadzi nas do kolejnego zagadnienia w naszej podróży po analizie danych: jak sprawić, aby dane były zrozumiałe?

# Statystyka opisowa i agregacja danych

Jednym ze sposobów ułatwiających zrozumienie dużych zbiorów danych jest obliczanie statystyk opisowych, takich jak suma bądź średnia, dla całego zbioru danych lub dla jego znaczących podzbiorów. W tym podrozdziale przyjrzymy się, jak to działa w pandas, a następnie zaprezentuję dwa sposoby agregacji danych w podzbiory: metodę `groupby` i funkcję `pivot_table`.

## Statystyka opisowa

**Statystyka opisowa** pozwala na podsumowanie zbiorów danych za pomocą miar ilościowych. Dla przykładu prostą statystyką opisową jest liczba punktów danych. Innymi popularnymi przykładami są średnie, mediany lub dominanty. Obiekty DataFrame i Series zapewniają wygodny dostęp do statystyk opisowych za pomocą metod takich jak `sum`, `mean` i `count`, by wymienić tylko kilka. Wiele z nich spotkasz w tej książce, a pełna lista jest dostępna w dokumentacji pandas (*https://oreil.ly/t2q9Q*). Domyślnie zwracają one obiekt Series wzdłuż osi 0 (`axis=0`), co oznacza, że otrzymujemy statystyki dotyczące kolumn:

```
In [85]: rainfall
Out[85]:    Miasto 1  Miasto 2  Miasto 3
         0     300.1     400.3    1000.5
         1     100.2     300.4    1100.6
In [86]: rainfall.mean()
Out[86]: Miasto 1     200.15
         Miasto 2     350.35
         Miasto 3    1050.55
         dtype: float64
```

Jeśli chcesz uzyskać statystyki dla każdego wiersza, podaj argument `axis`:

```
In [87]: rainfall.mean(axis=1)
Out[87]: 0    566.966667
         1    500.400000
         dtype: float64
```

Brakujące wartości nie są domyślnie uwzględniane w statystykach opisowych, takich jak suma (`sum`) czy średnia (`mean`). Jest to zgodne z tym, jak Excel traktuje puste komórki, więc użycie formuły `ŚREDNIA` w Excelu na zakresie z pustymi komórkami da taki sam wynik, jak metoda `mean` zastosowana na obiekcie Series zawierającym te same liczby i wartości `NaN` zamiast pustych komórek.

Czasami nie wystarczą statystyki dla wszystkich wierszy DataFrame i potrzebne są bardziej szczegółowe informacje — na przykład średnia dla kategorii. Zobaczmy, jak to się robi!

## Grupowanie

Używając ponownie naszego przykładowego DataFrame `df`, znajdźmy średnią ocen dla każdego kontynentu! Aby to zrobić, najpierw pogrupuj wiersze według kontynentów, a następnie zastosuj metodę `mean`, która obliczy średnią dla grupy. Wszystkie kolumny nieliczbowe są automatycznie wykluczane:

```
In [88]: df.groupby(["kontynent"]).mean()
Out[88]:     cechy  wiek  ocena
         kontynent
           Ameryka  37.0   5.30
            Europa  33.5   6.75
```

Jeśli dołączasz więcej niż jedną kolumnę, wynikowy DataFrame będzie miał indeks hierarchiczny — MultiIndex, który poznaliśmy wcześniej:

```
In [89]: df.groupby(["kontynent", "kraj"]).mean()
Out[89]:             cechy   wiek  ocena
         kontynent    kraj
           Ameryka     USA     37    5.3
            Europa  Niemcy     12    9.0
                    Włochy     55    4.5
```

Zamiast `mean` możesz zastosować większość statystyk opisowych, które oferuje pandas, a jeśli chcesz użyć własnej funkcji, użyj metody `agg`. Dla przykładu oto sposób uzyskania różnicy między maksymalną i minimalną wartością na grupę:

```
In [90]: df.groupby(["kontynent"]).agg(lambda x: x.max() - x.min())
Out[90]:     cechy  wiek  ocena
         kontynent
           Ameryka     8    2.8
            Europa    43    4.5
```

Popularnym sposobem na uzyskanie statystyk dla poszczególnych grup w Excelu jest użycie tabel przestawnych. Wprowadzają one drugi wymiar i pozwalają spojrzeć na dane z różnych perspektyw; pandas również dysponuje funkcjonalnością tabel przestawnych, o czym przekonamy się za chwilę.

## Funkcje pivot_table i melt

Jeśli korzystasz z tabel przestawnych w Excelu, nie będziesz miał problemów z zastosowaniem funkcji pandas `pivot_table`, ponieważ działa ona niemal w ten sam sposób. Dane w poniższym DataFrame są zorganizowane w podobny sposób jak rekordy przechowywane w bazie danych; każdy wiersz przedstawia transakcję sprzedaży określonych owoców w danym regionie:

```
In [91]: data = [["Pomarańcze", "Północ", 12.30],
                 ["Jabłka", "Południe", 10.55],
                 ["Pomarańcze", "Południe", 22.00],
                 ["Banany", "Południe", 5.90],
                 ["Banany", "Północ", 31.30],
                 ["Pomarańcze", "Północ", 13.10]]

         sales = pd.DataFrame(data=data,
                              columns=["Owoce", "Region", "Przychód"])
         sales
Out[91]:         Owoce    Region  Przychód
         0  Pomarańcze    Północ     12.30
         1      Jabłka  Południe     10.55
         2  Pomarańcze  Południe     22.00
         3      Banany  Południe      5.90
         4      Banany    Północ     31.30
         5  Pomarańcze    Północ     13.10
```

Aby utworzyć tabelę przestawną, przekazujesz DataFrame jako pierwszy argument funkcji `pivot_table`. Argumenty `index` i `columns` definiują, które kolumny DataFrame staną się odpowiednio etykietami wierszy i kolumn tabeli przestawnej. Wartości z kolumny wskazywanej przez argument `values` zostaną zagregowane w części danych wynikowego DataFrame za pomocą `aggfunc`, funkcji, która może być przekazana jako łańcuch znaków lub funkcja uniwersalna NumPy. I wreszcie argument `margins` odpowiada opcji *Sumy końcowe* w Excelu, tzn. jeśli pominiesz `margins` i `margins_name`, kolumna i wiersz `Ogółem` nie będą wyświetlane:

```
In [92]: pivot = pd.pivot_table(sales,
                                index="Owoce", columns="Region",
                                values="Przychód", aggfunc="sum",
                                margins=True, margins_name="Ogółem")
         pivot
Out[92]:      Region  Południe  Północ  Ogółem
              Owoce
             Banany       5.90    31.3   37.20
             Jabłka      10.55     NaN   10.55
         Pomarańcze      22.00    25.4   47.40
             Ogółem      38.45    56.7   95.15
```

Podsumowując, przestawienie danych oznacza pobranie unikatowych wartości z kolumny (w naszym przypadku `Region`) i przekształcenie ich w nagłówki kolumn tabeli przestawnej, a tym samym zagregowanie wartości z innej kolumny. W ten sposób można łatwo odczytać informacje sumaryczne dotyczące interesujących nas wymiarów. W naszej tabeli przestawnej od razu widać, że w regionie

północnym nie sprzedano żadnych jabłek, a w regionie południowym większość przychodów pochodzi z pomarańczy. Jeśli chcesz zrobić to na odwrót i zamienić nagłówki kolumn w wartości pojedynczej kolumny, użyj funkcji `melt`. W tym znaczeniu funkcja `melt` jest przeciwieństwem funkcji `pivot_table`:

```
In [93]: pd.melt(pivot.iloc[:-1,:-1].reset_index(),
                 id_vars="Owoce",
                 value_vars=["Północ", "Południe"], value_name="Przychód")
Out[93]:         Owoce    Region  Przychód
         0      Banany    Północ     31.30
         1      Jabłka    Północ       NaN
         2  Pomarańcze    Północ     25.40
         3      Banany  Południe      5.90
         4      Jabłka  Południe     10.55
         5  Pomarańcze  Południe     22.00
```

Tutaj rolę danych wejściowych pełni nasza tabela przestawna, ale używam metody `ilocto`, aby pozbyć się wiersza i kolumny z sumami łącznymi. Resetuję również indeks, aby wszystkie informacje były dostępne jako zwykłe kolumny. Następnie przekazuję argumenty `id_vars`, aby wskazać identyfikatory, oraz `value_vars`, aby zdefiniować kolumny, dla których chcę „odwrócić przestawienie". Funkcja `melt` może być przydatna, jeśli chcesz przygotować dane w taki sposób, aby można je było zapisać z powrotem do bazy danych, która oczekuje takiego formatu.

Agregowanie danych statystycznych uławia ich zrozumienie, ale nikt nie lubi czytać stron wypełnionych liczbami. Jeśli chcesz, aby informacje były łatwo zrozumiałe, nie ma nic lepszego niż utworzenie wizualizacji, co jest naszym następnym tematem.

# Tworzenie wykresów

Tworzenie wykresów pozwala na wizualizację wyników analizy danych i może być najważniejszym krokiem w całym procesie. Do tworzenia wykresów użyjemy dwóch bibliotek: na początku przyjrzymy się Matplotlib, domyślnej bibliotece pandas do tworzenia wykresów, a następnie skupimy się na Plotly, nowoczesnej bibliotece, która pełni tę samą rolę, ale zapewnia większą interaktywność w notatnikach Jupyter.

## Matplotlib

Matplotlib jest pakietem do tworzenia wykresów, który istnieje od dłuższego czasu i jest zawarty w dystrybucji Anaconda. Dzięki niemu można generować wykresy w różnych formatach, w tym jako grafikę wektorową do wydruków o wysokiej jakości. Gdy wywołasz metodę `plot` na DataFrame, pandas domyślnie wygeneruje wykres Matplotlib.

Aby używać Matplotlib w notatniku Jupyter, musisz najpierw uruchomić jedno z dwóch magicznych poleceń (zobacz ramkę „Magiczne polecenia"): `%matplotlib inline` lub `%matplotlib notebook`. Konfigurują one notatnik w taki sposób, że wykresy mogą być wyświetlane w samym notatniku. To drugie polecenie dodaje nieco więcej interaktywności, umożliwiając zmianę rozmiaru lub współczynnika powiększenia wykresu. Zacznijmy od utworzenia pierwszego wykresu przy użyciu pandas i Matplotlib (patrz rysunek 5.4):

```
In [94]: import numpy as np
         %matplotlib inline
         # lub %matplotlib notebook
In [95]: data = pd.DataFrame(data=np.random.rand(4, 4) * 100000,
                             index=["I kw.", "II kw.", "III kw.", "IV kw."],
                             columns=["Wschód", "Zachód", "Północ", "Południe"])
         data.index.name = "Kwartały"
         data.columns.name = "Region"
         data
Out[95]:   Region         Wschód        Zachód        Północ       Południe
         Kwartały
            I kw.   94650.974948   49456.118583   71981.667429   32033.826642
           II kw.   80155.219825   93212.096993   11024.224588   52949.961643
          III kw.   39825.387582   89669.923274   95266.653859   84131.561450
           IV kw.     584.966373   82841.321963   79006.649491   12015.042632
In [96]: data.plot()  # Skrót od data.plot.line()
Out[96]: <AxesSubplot:xlabel='Kwartały'>
```

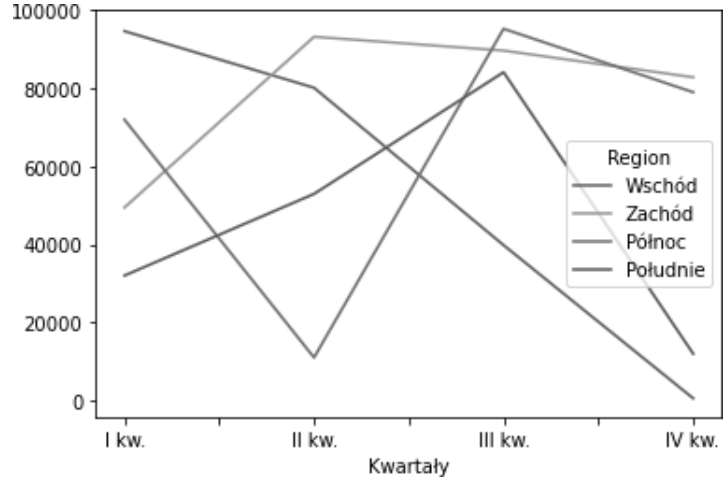


*Rysunek 5.4. Wykres Matplotlib*

## Magiczne polecenia

Polecenie `%matplotlib inline`, którego użyliśmy, aby Matplotlib działał poprawnie z notatnikami Jupyter, to tzw. **magiczne polecenie**. Magiczne polecenia to zestaw prostych poleceń, które powodują, że komórka notatnika Jupyter zachowuje się w określony sposób, lub sprawiają, że uciążliwe zadania stają się tak proste, iż wydaje się to niemal magią. Magiczne polecenia zapisuje się w komórkach podobnie jak kod Pythona, ale zaczynają się one albo od znaków `%%`, albo `%`. Polecenia, które mają wpływ na całą komórkę, zaczynają się od `%%`, a te, które mają wpływ tylko na pojedynczy wiersz w komórce, zaczynają się od znaku `%`.

W następnych rozdziałach zobaczymy więcej tego rodzaju poleceń, ale jeśli chcesz wyświetlić listę wszystkich aktualnie dostępnych magicznych poleceń, uruchom `%lsmagic`, a aby uzyskać szczegółowy opis, uruchom `%magic`.

Zauważ, że w tym przykładzie do skonstruowania obiektu DataFrame biblioteki pandas użyłem tablicy NumPy. Przekazanie tablic NumPy pozwala na wykorzystanie konstruktorów NumPy, które poznaliśmy w ostatnim rozdziale; tutaj używamy NumPy do wygenerowania obiektu DataFrame biblioteki pandas w oparciu o liczby pseudolosowe. Dlatego też uruchamiając ten przykład u siebie, otrzymasz inne wartości.

Nawet jeśli użyjesz magicznego polecenia `%matplotlib notebook`, prawdopodobnie zauważysz, że Matplotlib został pierwotnie zaprojektowany do wykresów statycznych, a nie do wprowadzania interaktywności na stronie internetowej. Dlatego właśnie zamierzamy użyć Plotly, biblioteki do tworzenia wykresów zaprojektowanej z myślą o sieci WWW.

## Plotly

Plotly jest pakietem opartym na JavaScript i od wersji 4.8.0 może być używany jako silnik tworzenia wykresów biblioteki pandas, oferując przy tym dużą interaktywność: można łatwo powiększać, klikać na legendę, aby wybrać lub odznaczyć kategorię, a także wyświetlać podpowiedzi z dodatkowymi informacjami na temat punktu danych, na który najedziemy kursorem. Plotly nie jest dołączony do Anacondy, więc jeśli jeszcze go nie zainstalowałeś, zrób to teraz, wykonując poniższe polecenie:

```
(base)> conda install plotly
```

Po uruchomieniu poniższej komórki silnik tworzenia wykresów w całym notatniku zostanie ustawiony na Plotly i jeśli ponownie uruchomisz poprzednią komórkę, ona również zostanie wyświetlona jako wykres Plotly. W przypadku Plotly zamiast uruchamiania magicznego polecenia, wystarczy wprowadzić poniższe ustawienie, aby móc wykreślić wykresy widoczne na rysunkach 5.5 i 5.6:

```
In [97]: # Ustaw silnik tworzenia wykresów na Plotly
         pd.options.plotting.backend = "plotly"
In [98]: data.plot()

In [99]: # Wyświetl te same dane jako wykres słupkowy
         data.plot.bar(barmode="group")
```

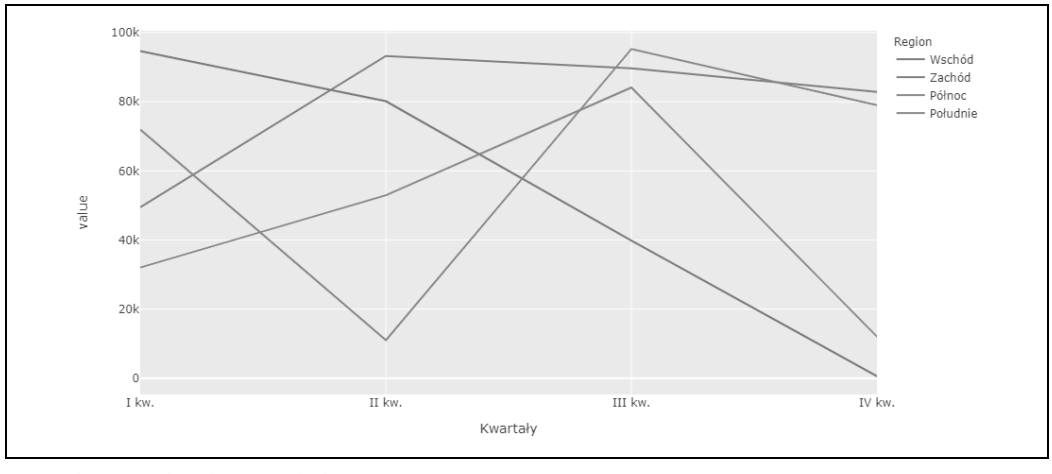


*Rysunek 5.5. Wykres liniowy Plotly*

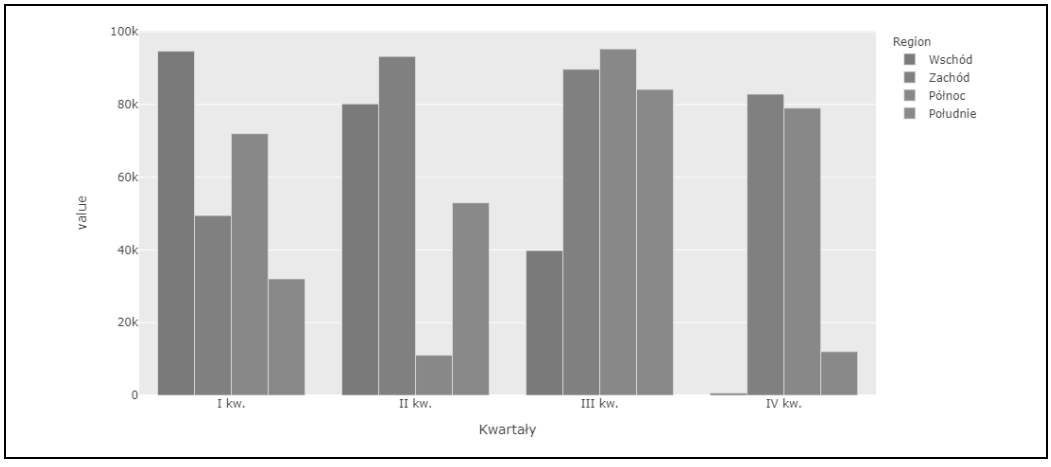


*Rysunek 5.6. Wykres słupkowy Plotly*

### Różnice w silnikach tworzenia wykresów

Jeśli używasz Plotly jako silnika tworzenia wykresów, będziesz musiał sprawdzić akceptowane argumenty metod dotyczących wykresów bezpośrednio w dokumentacji Plotly. Dla przykładu, aby uzyskać więcej informacji na temat argumentu `barmode=group`, możesz zajrzeć do dokumentacji wykresów słupkowych Plotly (*https://oreil.ly/Ekurd*).

Pakiet pandas i powiązane z nim biblioteki do tworzenia wykresów oferują mnóstwo typów wykresów i opcji umożliwiających ich formatowanie w niemal dowolny sposób. Możliwe jest również ułożenie wielu wykresów w serię podwykresów. Tabela 5.6 zawiera przegląd dostępnych typów wykresów.

*Tabela 5.6. Typy wykresów pandas*

| Typ | Opis |
|---|---|
| `line` | Wykres liniowy, domyślny po uruchomieniu `df.plot()` |
| `bar` | Pionowy wykres słupkowy |
| `barh` | Poziomy wykres słupkowy |
| `hist` | Histogram |
| `box` | Wykres pudełkowy |
| `kde` | Wykres gęstości, można go również użyć poprzez `density` |
| `area` | Wykres warstwowy |
| `scatter` | Wykres punktowy |
| `hexbin` | Wykresy przedziałów heksagonalnych |
| `pie` | Diagram kołowy |

Oprócz tego pandas oferuje pewne zaawansowane narzędzia i techniki tworzenia wykresów, które składają się z wielu pojedynczych komponentów. Aby uzyskać szczegółowe informacje, zapoznaj się z dokumentacją dotyczącą wizualizacji w pandas (*https://oreil.ly/FxYg9*).

### Inne biblioteki do tworzenia wykresów

Środowisko wizualizacji naukowych w Pythonie jest bardzo aktywne; oprócz Matplotlib i Plotly do wyboru mamy wiele innych wysokiej jakości rozwiązań, które w niektórych przypadkach mogą się okazać lepsze:

**Seaborn**

Seaborn (*https://oreil.ly/a3U1t*) jest zbudowany na bazie biblioteki Matplotlib. Poprawia domyślny styl i wprowadza dodatkowe wykresy, takie jak mapy cieplne, które często ułatwiają pracę: możesz tworzyć zaawansowane wykresy statystyczne za pomocą zaledwie kilku wierszy kodu.

**Bokeh**

Bokeh (*https://docs.bokeh.org*) jest podobny do Plotly pod względem technologii i funkcjonalności: jest oparty na JavaScript i dlatego świetnie nadaje się również do tworzenia interaktywnych wykresów w notatnikach Jupyter. Bokeh jest dołączony do Anacondy.

**Altair**

Altair (*https://oreil.ly/t06t7*) jest biblioteką do wizualizacji statystycznych opartą na projekcie Vega (*https://oreil.ly/RN6A7*). Altair jest również oparty na JavaScript i oferuje pewną interaktywność, np. powiększanie.

**HoloViews**

HoloViews (*https://holoviews.org*) to kolejny pakiet oparty na JavaScript, który koncentruje się na ułatwieniu analizy i wizualizacji danych. Za pomocą kilku wierszy kodu możesz uzyskać złożone wykresy statystyczne.

W następnym rozdziale utworzymy więcej wykresów do analizy szeregów czasowych, ale zanim to zrobimy, zakończymy ten rozdział nauką importowania i eksportowania danych za pomocą pandas!

# Importowanie i eksportowanie obiektów DataFrame

Do tej pory konstruowaliśmy obiekty DataFrame od podstaw, używając zagnieżdżonych list, słowników lub tablic NumPy. Są to ważne techniki, które warto znać, ale zazwyczaj dane są już dostępne i trzeba je po prostu przekształcić w DataFrame. W tym celu pandas oferuje różne funkcje wczytujące. Ale nawet jeśli potrzebujesz dostępu do zastrzeżonego systemu, dla którego pandas nie oferuje wbudowanego czytnika, często dysponujesz pakietem Pythona, aby połączyć się z tym systemem, a kiedy masz już dane, wystarczy zamienić je w DataFrame. W Excelu import danych jest rodzajem operacji, które zazwyczaj wykonuje się za pomocą Power Query.

Po przeanalizowaniu i zmodyfikowaniu zbioru danych możesz chcieć przenieść wyniki z powrotem do bazy danych, wyeksportować je do pliku CSV lub — mając na uwadze tytuł tej książki — przedstawić je w skoroszycie Excela swojemu przełożonemu. Aby wyeksportować obiekty DataFrame biblioteki pandas, należy użyć jednej z metod eksportu, które oferują DataFrame. Tabela 5.7 przedstawia przegląd najczęściej stosowanych metod importu i eksportu.

*Tabela 5.7. Importowanie i eksportowanie obiektów DataFrame*

| Format (system) danych | Import: funkcja pandas (pd) | Eksport: metoda DataFrame (df) |
|---|---|---|
| Pliki CSV | `pd.read_csv` | `df.to_csv` |
| JSON | `pd.read_json` | `df.to_json` |
| HTML | `pd.read_html` | `df.to_html` |
| Schowek | `pd.read_clipboard` | `df.to_clipboard` |
| Pliki Excela | `pd.read_excel` | `df.to_excel` |
| Bazy danych SQL | `pd.read_sql` | `df.to_sql` |

Z funkcjami `pd.read_sql` i `pd.to_sql` spotkamy się w rozdziale 11., gdzie wykorzystamy je jako część studium przypadku. A ponieważ cały rozdział 7. zamierzam poświęcić tematowi odczytu i zapisu plików Excela za pomocą pandas, w tym podrozdziale skupię się na imporcie i eksporcie plików CSV. Zacznijmy od wyeksportowania istniejącego obiektu DataFrame!

## Eksportowanie plików CSV

Jeśli musisz przekazać obiekt DataFrame koledze, który może nie używać Pythona lub pandas, zazwyczaj dobrym pomysłem jest przekazanie go w formie pliku CSV: prawie każdy program wie, jak importować takie pliki. Aby wyeksportować nasz przykładowy DataFrame `df` do pliku CSV, użyj metody `to_csv`:

```
In [100]: df.to_csv("course_participants.csv")
```

Jeśli plik ma być przechowywany w innym katalogu, należy podać pełną ścieżkę dostępu jako surowy łańcuch znaków, np. `r"C:\ścieżka\do\żądanej\lokalizacji\msft.csv"`.

### Używanie surowych łańcuchów znaków dla ścieżek dostępu do plików w systemie Windows

W łańcuchach znaków lewy ukośnik (ang. *backslash*) służy do modyfikacji określonych znaków. Dlatego przy zapisie ścieżek dostępu do plików w systemie Windows trzeba albo użyć podwójnych lewych ukośników (`C:\\ścieżka\\do\\pliku.csv`), albo poprzedzić ciąg znaków literą `r`, aby przekształcić go w surowy ciąg znaków (ang. *raw string*), gdzie znaki są interpretowane dosłownie. Nie stanowi to problemu w systemach macOS i Linux, ponieważ tam w ścieżkach dostępu stosowane są prawe ukośniki.

Jeśli podasz tylko nazwę pliku, tak jak ja to zrobiłem, program utworzy w tym samym katalogu co notatnik plik *course_participants.csv* z następującą zawartością:

```
numer,imię,wiek,kraj,ocena,kontynent
1001,Mark,55,Włochy,4.5,Europa
1000,John,33,USA,6.7,Ameryka
1002,Tim,41,USA,3.9,Ameryka
1003,Jenny,12,Niemcy,9.0,Europa
```

Skoro już wiesz, jak używać metody `df.to_csv`, zobaczmy, jak zaimportować plik CSV!

## Importowanie plików CSV

Importowanie lokalnego pliku CSV jest niezwykle proste — wystarczy przekazać jego ścieżkę dostępu do funkcji `read_csv`. *MSFT.csv* to plik CSV, który pobrałem z portalu Yahoo! Finance, zawierający dzienne historyczne ceny akcji firmy Microsoft — znajdziesz go w repozytorium towarzyszącym książce, w folderze *csv*:

```
In [101]: msft = pd.read_csv("csv/MSFT.csv")
```

Często oprócz nazwy pliku będziesz musiał przekazać do funkcji `read_csv` jeszcze kilka innych parametrów. Przykładowo parametr `sep` pozwala poinformować pandas, jakiego separatora lub delimitera używa plik CSV w przypadku, gdy nie jest to domyślny przecinek. W następnym rozdziale użyjemy jeszcze kilku innych parametrów, ale aby zapoznać się z ich pełną listą, zajrzyj do dokumentacji pandas (*https://oreil.ly/2GMhW*).

Teraz, gdy mamy do czynienia z dużymi obiektami DataFrame zawierającymi wiele tysięcy wierszy, zazwyczaj pierwszą rzeczą jest uruchomienie metody `info`, aby uzyskać podsumowanie DataFrame. Następnie możesz chcieć spojrzeć na kilka pierwszych i ostatnich wierszy DataFrame, używając metod `head` i `tail`. Metody te zwracają domyślnie pięć wierszy, ale można to zmienić, podając żądaną liczbę wierszy jako argument. Możesz również uruchomić metodę `describe`, aby uzyskać kilka podstawowych statystyk:

```
In [102]: msft.info()
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 8622 entries, 0 to 8621
Data columns (total 7 columns):
 #   Column     Non-Null Count  Dtype
---  ------     --------------  -----
 0   Date       8622 non-null   object
 1   Open       8622 non-null   float64
 2   High       8622 non-null   float64
 3   Low        8622 non-null   float64
 4   Close      8622 non-null   float64
 5   Adj Close  8622 non-null   float64
 6   Volume     8622 non-null   int64
dtypes: float64(5), int64(1), object(1)
memory usage: 471.6+ KB
In [103]: # Z powodu braku miejsca wybieram tylko kilka kolumn
          # Możesz też po prostu uruchomić: msft.head()
          msft.loc[:, ["Date", "Adj Close", "Volume"]].head()
Out[103]:          Date  Adj Close      Volume
          0  1986-03-13   0.062205  1031788800
          1  1986-03-14   0.064427   308160000
          2  1986-03-17   0.065537   133171200
          3  1986-03-18   0.063871    67766400
          4  1986-03-19   0.062760    47894400
In [104]: msft.loc[:, ["Date", "Adj Close", "Volume"]].tail(2)
Out[104]:            Date   Adj Close    Volume
          8620  2020-05-26  181.570007  36073600
          8621  2020-05-27  181.809998  39492600
In [105]: msft.loc[:, ["Adj Close", "Volume"]].describe()
Out[105]:          Adj Close        Volume
          count  8622.000000  8.622000e+03
           mean    24.921952  6.030722e+07
             std    31.838096  3.877805e+07
```

```
min      0.057762  2.304000e+06
25%      2.247503  3.651632e+07
50%     18.454313  5.350380e+07
75%     25.699224  7.397560e+07
max    187.663330  1.031789e+09
```

`Adj Close` oznacza **skorygowaną cenę zamknięcia** (ang. *adjusted close price*) i koryguje cenę akcji o działania korporacyjne, takie jak podziały akcji. Wolumen to liczba akcji, które były przedmiotem obrotu. Podsumowanie różnych metod eksploracji DataFrame, które widzieliśmy w tym rozdziale, przedstawiłem w tabeli 5.8.

*Tabela 5.8. Metody i atrybuty eksploracji DataFrame*

| Metoda lub atrybut DataFrame (df) | Opis |
|---|---|
| `df.info()` | Podaje liczbę punktów danych, typ indeksu, typ danych oraz użycie pamięci. |
| `df.describe()` | Udostępnia podstawowe statystyki, w tym liczebność, średnią, odchylenie standardowe, minimum, maksimum i percentyle. |
| `df.head(n=5)` | Zwraca pierwsze *n* wierszy DataFrame. |
| `df.tail(n=5)` | Zwraca ostatnie *n* wierszy DataFrame. |
| `df.dtypes` | Zwraca typ danych każdej kolumny. |

Funkcja `read_csv` akceptuje również adres URL zamiast lokalnego pliku CSV. Oto sposób wczytania pliku CSV bezpośrednio z repozytorium towarzyszącego oryginalnemu wydaniu książki:

```
In [106]: # Adres URL został podzielony na wiersze, aby zmieścił się na stronie.
          url = ("https://raw.githubusercontent.com/fzumstein/"
                 "python-for-excel/1st-edition/csv/MSFT.csv")
          msft = pd.read_csv(url)
In [107]: msft.loc[:, ["Date", "Adj Close", "Volume"]].head(2)
Out[107]:          Date  Adj Close      Volume
          0  1986-03-13   0.062205  1031788800
          1  1986-03-14   0.064427   308160000
```

Pracę z tym zbiorem danych i funkcją `read_csv` będziemy kontynuować w następnym rozdziale o szeregach czasowych, gdzie przekształcimy kolumnę `Date` w `DatetimeIndex`.

# Podsumowanie

Ten rozdział obfitował w nowe koncepcje i narzędzia do analizy zbiorów danych w pandas. Dowiedzieliśmy się, jak wczytywać pliki CSV, jak radzić sobie z brakującymi lub zduplikowanymi danymi oraz jak korzystać ze statystyk opisowych. Zobaczyliśmy również, jak łatwo można przekształcić obiekty DataFrame w interaktywne wykresy. Choć może trochę potrwać, zanim to wszystko przetrawisz, prawdopodobnie nie minie wiele czasu, nim zrozumiesz, ile zyskujesz, dodając pandas do swoich narzędzi. Po drodze porównywaliśmy pandas z następującymi funkcjonalnościami Excela:

**Funkcja Autofiltru**

Patrz punkt „Wybieranie przy użyciu indeksowania logicznego”.

**Formuła `WYSZUKAJ.PIONOWO`**

Patrz punkt „Operacje join i merge”.

**Tabela przestawna**

Patrz punkt „Funkcje pivot_table i melt”.

**Power Query**

Jest to połączenie podrozdziałów „Importowanie i eksportowanie obiektów DataFrame”, „Operowanie danymi” i „Łączenie obiektów DataFrame”.

Kolejny rozdział poświęcony jest analizie szeregów czasowych, czyli funkcjonalności, która doprowadziła do szerokiego zaadoptowania pandas przez branżę finansową. Zobaczmy, dlaczego ten element pandas ma taką przewagę nad Excelem!

# Użyj Pythona, a pokochasz Excela!

Bez Excela trudno sobie wyobrazić wykonywanie różnych złożonych zadań — to ulubione narzędzie naukowców, finansistów, analityków danych, a także profesjonalistów z innych branż. Każda z tych dziedzin ma swoje stale rosnące wymagania wobec Excela. Firma Microsoft wciąż rozwija ten kultowy arkusz kalkulacyjny, jednak język VBA nie nadąża za potrzebami wielu użytkowników. Osoby te często w codziennej pracy korzystają z Pythona do automatyzacji zadań, stąd integracja Excela i Pythona wydaje się naturalnym i wyjątkowo obiecującym rozwiązaniem.

Nie musisz dłużej czekać na włączenie Pythona jako języka skryptowego Excela — ta książka wyjaśnia, jak je połączyć i wyciągnąć z tej integracji maksimum korzyści. To wydanie przeznaczone dla zaawansowanych użytkowników Excela, którzy nie mają głębokiej wiedzy o Pythonie. Pokazuje, w jaki sposób manipulować danymi zawartymi w plikach Excela bez Excela, a także jak znakomicie zwiększać możliwości tego programu poprzez budowanie interaktywnych narzędzi do analizy danych. Niezależnie od tego, czy interesuje Cię praca z samymi arkuszami Excela, czy też chcesz tworzyć aplikacje Excela, znajdziesz tu mnóstwo wyczerpujących, jasnych i praktycznych wskazówek, popartych zrozumiałymi przykładami przydatnego kodu.

## W książce między innymi:

- gruntowne podstawy Pythona i korzystania z notatników Jupyter i Visual Studio Code
- stosowanie biblioteki pandas do zastępowania typowych obliczeń w Excelu
- automatyzacja konsolidacji skoroszytów Excela i tworzenia raportów w Excelu
- tworzenie interaktywnych narzędzi Excela za pomocą xlwings
- współpraca Excela z bazą danych i plikami CSV
- stosowanie Pythona do zastąpienia VBA, Power Query i Power Pivot

**Felix Zumstein** jest ekspertem w dziedzinie zastosowania Excela w biznesie i w rozwiązywaniu problemów z tym programem w różnych branżach. Napisał i rozwija xlwings, popularny pakiet open source służący do automatyzacji pracy w Excelu za pomocą kodu Pythona.

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 978-83-289-3095-7

9 788328 930957

Cena: 87,00 zł