O'REILLY®

Wydanie III

Python w analizie danych

Przetwarzanie danych za pomocą pakietów pandas i NumPy oraz środowiska Jupyter

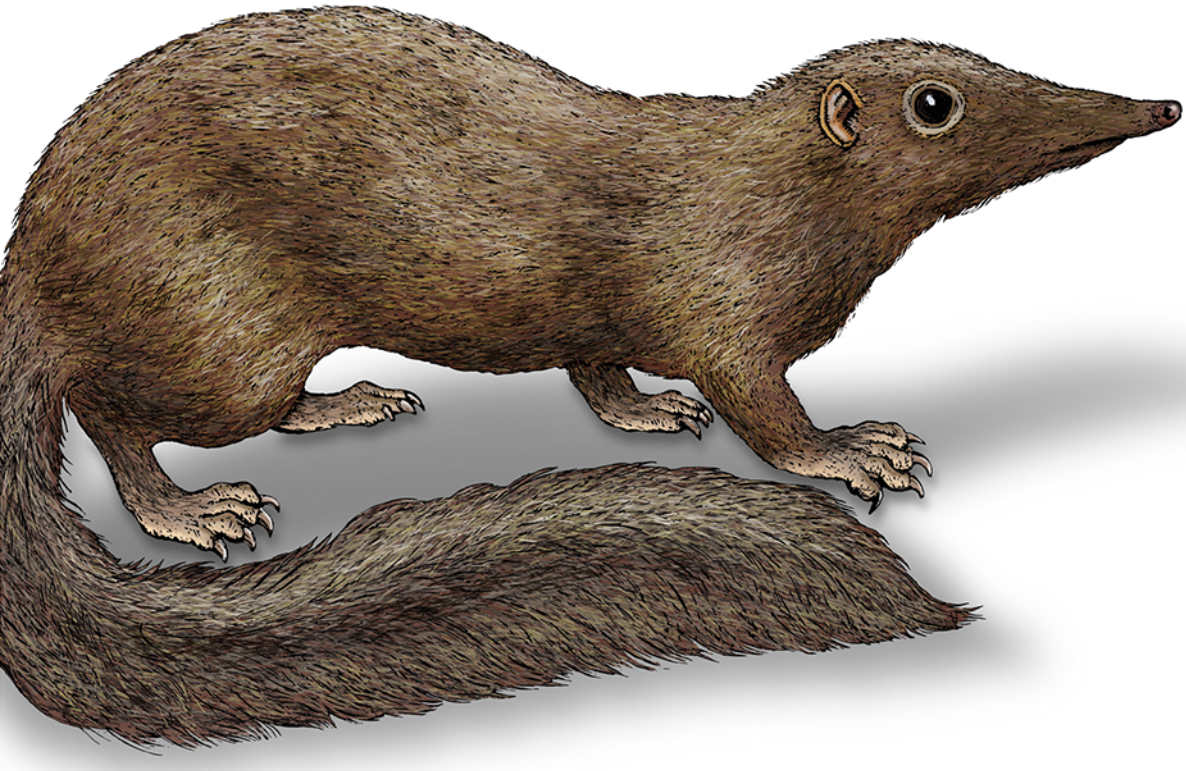

Helion

Wes McKinney

Tytuł oryginału: Python for Data Analysis: Data Wrangling with pandas, NumPy, and Jupyter, 3rd Edition

Tłumaczenie: Andrzej Watrak

ISBN: 978-83-8322-323-0

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

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:
https://ftp.helion.pl/przyklady/pyanda.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 7.

Czyszczenie i przygotowywanie danych

Podczas analizowania i modelowania danych znaczną część czasu poświęca się na przygotowanie danych: ładowanie, czyszczenie, przekształcanie i przekładanie. Wykonywanie tego typu zadań zajmuje nawet 80% czasu pracy analityka. Czasami sposób przechowywania danych w pliku lub w bazie danych jest niewłaściwy z punktu widzenia zadania, które ma wykonać analityk. Wielu badaczy decyduje się na doraźne przetwarzanie danych z jednej formy na drugą za pomocą języka programowania ogólnego przeznaczenia, takiego jak Python, Perl, R, Java, lub narzędzi systemu Unix przeznaczonych do przetwarzania danych tekstowych, takich jak sed lub awk. Na szczęście pakiet pandas oraz elementy wbudowane w Pythona tworzą zestaw uniwersalnych i szybkich wysokopoziomowych narzędzi, które umożliwiają przekształcenie danych do właściwej formy.

Jeżeli potrafisz zdefiniować operację przekształcania danych, która nie została uwzględniona w tej książce lub nie jest obsługiwana w żaden sposób przez bibliotekę pandas, to podziel się nią, a także jej zastosowaniem na jednej z list mailingowych Pythona lub na stronie pakietu pandas znajdującej się w serwisie GitHub. Większość elementów pakietu pandas została zaprojektowana i zaimplementowana z myślą o potrzebie rozwiązywania realnych problemów.

W tym rozdziale zajmę się narzędziami przeznaczonymi do rozwiązywania problemów dotyczących brakujących czy zduplikowanych danych, a także narzędziami przetwarzającymi łańcuchy i wykonującymi inne przekształcenia zbioru danych. W kolejnym rozdziale skupię się na zagadnieniach dotyczących łączenia i modyfikowania zbiorów danych.

7.1. Obsługa brakujących danych

Z problemem brakujących danych spotykamy się w wielu zbiorach danych. Jednym z celów istnienia pakietu pandas jest maksymalne uproszczenie obsługi brakujących danych poprzez np. domyślne odrzucanie brakujących danych przez większość funkcji obliczających parametry statystyki opisowej.

Sposób reprezentacji brakujących danych zaimplementowany w pakiecie pandas można uznać za nieidealny, ale z punktu widzenia wielu użytkowników jest on praktyczny. W przypadku danych numerycznych pakiet pandas korzysta ze zmiennoprzecinkowej wartości `NaN` (nie-liczba) w celu oznaczenia brakujących danych. Jest to tzw. **wartość zastępcza**, której występowanie można łatwo wykryć:

```
In [14]: float_data = pd.Series([1.2, -3.5, np.nan, 0])

In [15]: float_data
```

```
Out[15]:
0    1.2
1   -3.5
2    NaN
3    0.0
dtype: float64
```

Metoda `isna` zwraca serię wartości logicznych, w której `True` oznacza brak wartości w oryginalnej serii:

```
In [16]: float_data.isna()
Out[16]:
0    False
1    False
2     True
3    False
dtype: bool
```

W pakiecie pandas przyjęliśmy konwencję zaczerpniętą z języka R — brakujące wartości określamy mianem wartości **NA** (wartości **niedostępnych**, z ang. *not available*). W zastosowaniach statystycznych dane niedostępne mogą być danymi, które nie istnieją, lub danymi, które istnieją, ale nie zostały zaobserwowane (np. z powodu problemu wynikającego ze sposobu zbierania danych). Podczas oczyszczania danych przed przeprowadzeniem ich analizy często warto przeprowadzić analizę samych brakujących wartości. Pozwoli to zidentyfikować problemy wynikające z techniki zbierania danych lub potencjalne tendencje spowodowane brakiem pewnych wartości.

W tablicach za wartość NA przyjmuje się wbudowaną w standardową bibliotekę Pythona wartość `None`:

```
In [17]: string_data = pd.Series(["aardvark", np.nan, None, "avocado"])

In [18]: string_data
Out[18]:
0    aardvark
1         NaN
2        None
3     avocado
dtype: object

In [19]: string_data.isna()
Out[19]:
0    False
1     True
2     True
3    False
dtype: bool

In [20]: float_data = pd.Series([1, 2, None], dtype='float64')

In [21]: float_data
Out[21]:
0    1.0
1    2.0
2    NaN
dtype: float64

In [22]: float_data.isna()
Out[22]:
0    False
```

```
1    False
2     True
dtype: bool
```

Twórcy projektu pandas starają się ujednolicić obsługę brakujących danych różnych typów. Funkcje takie jak `pandas.isna` ukrywają przed użytkownikiem wiele skomplikowanych szczegółów implementacyjnych. W tabeli 7.1 wymieniono wybrane funkcje przydatne podczas pracy z brakującymi danymi.

Tabela 7.1. Metody przydatne podczas obsługi brakujących danych

Argument	Opis
`dropna`	Filtruje etykiety osi na podstawie występowania brakujących danych; możliwe jest zdefiniowanie zmiennych wartości progowych określających liczbę tolerowanych brakujących danych.
`fillna`	Wypełnia brakujące dane jakimiś wartościami lub robi to za pomocą metody interpolacji, takiej jak np. `"ffill"` lub `"bfill"`.
`isna`	Zwraca wartości logiczne określające miejsce występowania brakujących wartości.
`notna`	Negacja `isna`. Zwraca `True`, jeżeli wartość istnieje, a `False` w przeciwnym wypadku.

Filtrowanie brakujących danych

Istnieje kilka technik umożliwiających odfiltrowanie brakujących danych. Możesz to zrobić ręcznie za pomocą funkcji `pandas.isna` i indeksowania wartości logicznych, ale łatwiej jest skorzystać z funkcji `dropna`. W przypadku obiektu typu `Series` funkcja ta zwraca tylko dane o wartości innej niż `null` i indeksy odwołujące się jedynie do tych danych:

```
In [23]: data = pd.Series([1, np.nan, 3.5, np.nan, 7])

In [24]: data.dropna()
Out[24]:
0  1.0
2  3.5
4  7.0
dtype: float64
```

Jest to odpowiednik następującego kodu:

```
In [25]: data[data.notna()]
Out[25]:
0  1.0
2  3.5
4  7.0
dtype: float64
```

Sprawy nieco komplikują się podczas pracy z obiektami `DataFrame`. Możesz chcieć odrzucić wiersze lub kolumny, które zawierają tylko wartości NA, lub takie, które zawierają chociażby jedną wartość NA. Funkcja `dropna` domyślnie odrzuca wiersze zawierające przynajmniej jedną brakującą wartość:

```
In [26]: data = pd.DataFrame([[1., 6.5, 3.], [1., np.nan, np.nan],
   ....:                      [np.nan, np.nan, np.nan], [np.nan, 6.5, 3.]])

In [27]: data
Out[27]:
0  1  2
```

```
0  1.0  6.5  3.0
1  1.0  NaN  NaN
2  NaN  NaN  NaN
3  NaN  6.5  3.0

In [28]: data.dropna()
Out[28]:
     0    1    2
0  1.0  6.5  3.0
```

Przekazanie parametru `how='all'` spowoduje odrzucenie tylko wierszy, które zawierają same wartości NA:

```
In [29]: data.dropna(how='all')
Out[29]:
     0    1    2
0  1.0  6.5  3.0
1  1.0  NaN  NaN
3  NaN  6.5  3.0
```

Pamiętaj, że opisane funkcje domyślnie zwracają nowe obiekty, tj. nie modyfikują zawartości oryginalnych obiektów.

Aby odrzucić w ten sam sposób kolumny, należy skorzystać z parametru `axis="columns"`:

```
In [30]: data[4] = np.nan

In [31]: data
Out[31]:
     0    1    2   4
0  1.0  6.5  3.0 NaN
1  1.0  NaN  NaN NaN
2  NaN  NaN  NaN NaN
3  NaN  6.5  3.0 NaN

In [32]: data.dropna(axis="columns", how="all")
Out[32]:
     0    1    2
0  1.0  6.5  3.0
1  1.0  NaN  NaN
2  NaN  NaN  NaN
3  NaN  6.5  3.0
```

Załóżmy, że chcesz zachować tylko wiersze zawierające określoną liczbę obserwacji. Możesz to zrobić za pomocą argumentu `thresh`:

```
In [33]: df = pd.DataFrame(np.random.randn(7, 3))

In [34]: df.iloc[:4, 1] = np.nan

In [35]: df.iloc[:2, 2] = np.nan

In [36]: df
Out[36]:
          0         1         2
0 -0.204708       NaN       NaN
1 -0.555730       NaN       NaN
2  0.092908       NaN  0.769023
```

```
3  1.246435       NaN -1.296221
4  0.274992  0.228913  1.352917
5  0.886429 -2.001637 -0.371843
6  1.669025 -0.438570 -0.539741

In [37]: df.dropna()
Out[37]:
          0         1         2
4  0.274992  0.228913  1.352917
5  0.886429 -2.001637 -0.371843
6  1.669025 -0.438570 -0.539741

In [38]: df.dropna(thresh=2)
Out[38]:
          0         1         2
2  0.092908       NaN  0.769023
3  1.246435       NaN -1.296221
4  0.274992  0.228913  1.352917
5  0.886429 -2.001637 -0.371843
6  1.669025 -0.438570 -0.539741
```

Wypełnianie brakujących danych

Zamiast filtrować brakujące dane (i narażać się na jednoczesne usunięcie również innych danych), czasami lepiej jest w jakiś sposób te „dziury" wypełnić. Najczęściej robi się to za pomocą funkcji `fillna`. Wywołanie funkcji `fillna` wraz ze stałą spowoduje wstawienie zadeklarowanej wartości w miejsce brakujących danych:

```
In [39]: df.fillna(0)
Out[39]:
          0         1         2
0 -0.204708  0.000000  0.000000
1 -0.555730  0.000000  0.000000
2  0.092908  0.000000  0.769023
3  1.246435  0.000000 -1.296221
4  0.274992  0.228913  1.352917
5  0.886429 -2.001637 -0.371843
6  1.669025 -0.438570 -0.539741
```

Wywołując `fillna` wraz ze słownikiem, możesz wypełnić brakujące elementy poszczególnych kolumn różnymi wartościami:

```
In [40]: df.fillna({1: 0.5, 2: 0})
Out[40]:
          0         1         2
0 -0.204708  0.500000  0.000000
1 -0.555730  0.500000  0.000000
2  0.092908  0.500000  0.769023
3  1.246435  0.500000 -1.296221
4  0.274992  0.228913  1.352917
5  0.886429 -2.001637 -0.371843
6  1.669025 -0.438570 -0.539741
```

Metody interpolacji dostępne podczas wykonywania operacji uaktualniania indeksu (patrz tabela 5.3) mogą być również użyte wraz z funkcją `fillna`:

```
In [41]: df = pd.DataFrame(np.random.standard_normal((6, 3)))

In [42]: df.iloc[2:, 1] = np.nan

In [43]: df.iloc[4:, 2] = np.nan

In [44]: df
Out[44]:
          0         1         2
0  0.476985  3.248944 -1.021228
1 -0.577087  0.124121  0.302614
2  0.523772       NaN  1.343810
3 -0.713544       NaN -2.370232
4 -1.860761       NaN       NaN
5 -1.265934       NaN       NaN

In [45]: df.fillna(method='ffill')
Out[45]:
          0         1         2
0  0.476985  3.248944 -1.021228
1 -0.577087  0.124121  0.302614
2  0.523772  0.124121  1.343810
3 -0.713544  0.124121 -2.370232
4 -1.860761  0.124121 -2.370232
5 -1.265934  0.124121 -2.370232

In [46]: df.fillna(method='ffill', limit=2)
Out[46]:
          0         1         2
0  0.476985  3.248944 -1.021228
1 -0.577087  0.124121  0.302614
2  0.523772  0.124121  1.343810
3 -0.713544  0.124121 -2.370232
4 -1.860761       NaN -2.370232
5 -1.265934       NaN -2.370232
```

Funkcja `fillna` wykonuje również inne operacje, na przykład interpoluje dane przy użyciu mediany lub średniej:

```
In [47]: data = pd.Series([1., np.nan, 3.5, np.nan, 7])

In [48]: data.fillna(data.mean())
Out[48]:
0  1.000000
1  3.833333
2  3.500000
3  3.833333
4  7.000000
dtype: float64
```

W tabeli 7.2 wymieniono argumenty funkcji `fillna`.

Tabela 7.2. Argumenty funkcji fillna

Argument	Opis
`value`	Wartość skalarna lub słownik — element używany do wypełnienia miejsc występowania brakujących danych.
`method`	Interpolacja: `"bfill"` (wypełnianie wstecz) lub `"ffill"` (w przód); domyślnie `None`.
`axis`	Wypełniana oś: `"index"` (domyślnie) lub `"columns"`.
`limit`	W przypadku wypełniania w przód i w tył określa maksymalną liczbę kolejnych wypełnianych okresów.

7.2. Przekształcanie danych

Dotychczas zajmowaliśmy się tylko tematem obsługi brakujących danych. Filtrowanie, czyszczenie i inne przekształcenia tworzą kolejną klasę ważnych operacji.

Usuwanie duplikatów

Istnieje wiele powodów pojawiania się zduplikowanych wierszy w ramkach danych. Oto przykład takiej sytuacji:

```
In [49]: data = pd.DataFrame({'k1': ['one', 'two'] * 3 + ['two'],
   ....:                      'k2': [1, 1, 2, 3, 3, 4, 4]})

In [50]: data
Out[50]:
    k1 k2
0  one  1
1  two  1
2  one  2
3  two  3
4  one  3
5  two  4
6  two  4
```

Metoda `duplicated` ramki danych zwraca serię wartości logicznych określającą, czy poszczególne wiersze ramki danych są duplikatami, tj. czy wartości w kolejnych kolumnach są identyczne z zawartymi w poprzednim wierszu:

```
In [51]: data.duplicated()
Out[51]:
0  False
1  False
2  False
3  False
4  False
5  False
6   True
dtype: bool
```

Metoda `drop_duplicates` zwraca ramkę danych, w przypadku której metoda `duplicated` zwraca same wartości `False`:

```
In [52]: data.drop_duplicates()
Out[52]:
    k1 k2
```

```
0  one  1
1  two  1
2  one  2
3  two  3
4  one  3
5  two  4
```

Obie z zaprezentowanych metod biorą pod uwagę wszystkie kolumny, ale możesz wybrać podzbiór kolumn, które mają zostać wzięte pod uwagę podczas wykrywania duplikatów. Załóżmy, że mamy dodatkową kolumnę wartości i chcemy dokonać operacji filtrowania duplikatów tylko na podstawie kolumny `k1`:

```
In [53]: data['v1'] = range(7)

In [54]: data
Out[54]:
    k1  k2  v1
0  one   1   0
1  two   1   1
2  one   2   2
3  two   3   3
4  one   3   4
5  two   4   5
6  two   4   6

In [55]: data.drop_duplicates(subset=["k1"])
Out[55]:
     k1  k2  v1
0  one    1   0
1  two    1   1
```

Metody `duplicated` i `drop_duplicates` domyślnie zachowują pierwszą znalezioną kombinację wartości. Parametr `keep='last'` spowoduje zwrócenie ostatniej takiej kombinacji:

```
In [56]: data.drop_duplicates(['k1', 'k2'], keep='last')
Out[56]:
    k1  k2  v1
0  one   1   0
1  two   1   1
2  one   2   2
3  two   3   3
4  one   3   4
6  two   4   6
```

Przekształcanie danych przy użyciu funkcji lub mapowania

W przypadku wielu zbiorów danych może zachodzić konieczność wykonania pewnych przekształceń na podstawie wartości umieszczonych w tablicy, serii lub kolumnie ramki danych. Przyjrzyj się poniższemu hipotetycznemu zbiorowi danych opisującemu różne rodzaje mięsa:

```
In [57]: data = pd.DataFrame({'food': ['bacon', 'pulled pork', 'bacon',
   ....:                               'Pastrami', 'corned beef', 'Bacon',
   ....:                               'pastrami', 'honey ham', 'nova lox'],
   ....:                      'ounces': [4, 3, 12, 6, 7.5, 8, 3, 5, 6]})

In [58]: data
```

```
Out[58]:
          food  ounces
0        bacon     4.0
1  pulled pork     3.0
2        bacon    12.0
3     Pastrami     6.0
4  corned beef     7.5
5        Bacon     8.0
6     pastrami     3.0
7    honey ham     5.0
8     nova lox     6.0
```

Załóżmy, że chciałbyś dodać kolumnę określającą zwierzę, z którego zrobiony jest każdy z produktów spożywczych. Utwórzmy mapowanie każdego typu mięsa do zwierzęcia:

```
meat_to_animal = {
   'bacon': 'pig',
   'pulled pork': 'pig',
   'pastrami': 'cow',
   'corned beef': 'cow',
   'honey ham': 'pig',
   'nova lox': 'salmon'
}
```

Metoda `map` używana na obiektach `Series` (opisana w rozdziale 5., w podrozdziale „Funkcje apply i map") przyjmuje funkcję lub słownik — element definiujący mapowanie:

```
In [60]: data['animal'] = lowercased.map(meat_to_animal)

In [61]: data
Out[61]:
          food  ounces  animal
0        bacon     4.0     pig
1  pulled pork     3.0     pig
2        bacon    12.0     pig
3     Pastrami     6.0     cow
4  corned beef     7.5     cow
5        Bacon     8.0     pig
6     pastrami     3.0     cow
7    honey ham     5.0     pig
8     nova lox     6.0  salmon
```

Istnieje również możliwość przekazania funkcji wykonującej wszystkie operacje:

```
In [62]: def get_animal(x):
   ....:     return meat_to_animal[x]

In [63]: data["food"].map(get_animal)
Out[63]:
0     pig
1     pig
2     pig
3     cow
4     cow
5     pig
6     cow
7     pig
8  salmon
Name: food, dtype: object
```

Korzystanie ze słowa kluczowego `map` to wygodny sposób na wykonywanie przekształceń element po elemencie oraz innych operacji związanych z czyszczeniem danych.

Zastępowanie wartości

Wypełnianie brakujących danych za pomocą metody `fillna` to specjalny przypadek zastosowania bardziej uniwersalnego mechanizmu zastępowania wartości. W poprzedniej sekcji dowiedziałeś się, że słowo kluczowe `map` może zostać użyte w celu zmodyfikowania podzbioru wartości obiektu, ale funkcja `replace` pozwala na wykonanie tego w bardziej elastyczny i prostszy sposób. Oto przykładowy obiekt typu `Series`:

```
In [64]: data = pd.Series([1., -999., 2., -999., -1000., 3.])

In [65]: data
Out[65]:
0      1.0
1   -999.0
2      2.0
3   -999.0
4  -1000.0
5      3.0
dtype: float64
```

Wartości –999 mogą zastępować brakujące dane. W celu zastąpienia ich wartością `NaN` możemy skorzystać z funkcji `replace`, która wygeneruje nowy obiekt typu `Series`:

```
In [66]: data.replace(-999, np.nan)
Out[66]:
0      1.0
1      NaN
2      2.0
3      NaN
4  -1000.0
5      3.0
dtype: float64
```

Jeżeli chcesz za jednym zamachem zastąpić wiele wartości, możesz przekazać do tej funkcji listę wartości, które mają zostać zastąpione:

```
In [67]: data.replace([-999, -1000], np.nan)
Out[67]:
0  1.0
1  NaN
2  2.0
3  NaN
4  NaN
5  3.0
dtype: float64
```

W celu zastąpienia każdej z wartości inną należy przekazać listę elementów zastępujących:

```
In [68]: data.replace([-999, -1000], [np.nan, 0])
Out[68]:
0  1.0
1  NaN
```

```
2  2.0
3  NaN
4  0.0
5  3.0
dtype: float64
```

Przekazany argument może być również słownikiem:

```
In [69]: data.replace({-999: np.nan, -1000: 0})
Out[69]:
0  1.0
1  NaN
2  2.0
3  NaN
4  0.0
5  3.0
dtype: float64
```

Metoda `data.replace` działa inaczej niż metoda `data.str.replace` wykonująca podmienianie łańcuchów element po elemencie. Użycie metod łańcucha na obiekcie typu Series zostanie opisane w dalszej części tego rozdziału.

Zmiana nazw indeksów osi

Etykiety osi mogą być przekształcone podobnie jak wartości obiektu `Series`. W celu uzyskania nowych obiektów o innych etykietach można skorzystać z funkcji lub mapowania. Osie mogą być również modyfikowane w miejscu — bez tworzenia nowych struktur danych. Oto prosty przykład:

```
In [70]: data = pd.DataFrame(np.arange(12).reshape((3, 4)),
   ....:                     index=['Ohio', 'Colorado', 'New York'],
   ....:                     columns=['one', 'two', 'three', 'four'])
```

Indeksy osi, podobnie jak obiekty `Series`, obsługują metodę `map`:

```
In [71]: def transform(x):
   ....:     return x[:4].upper()

In [72]: data.index.map(transform)
Out[72]: Index(['OHIO', 'COLO', 'NEW '], dtype='object')
```

Przypisywanie do obiektu `index` może modyfikować ramkę danych w miejscu:

```
In [73]: data.index = data.index.map(transform)

In [74]: data
Out[74]:
     one  two  three  four
OHIO   0    1      2     3
COLO   4    5      6     7
NEW    8    9     10    11
```

Jeżeli chcesz utworzyć przekształconą wersję zbioru danych bez modyfikowania oryginalnego zbioru, to warto skorzystać z metody `rename`:

```
In [75]: data.rename(index=str.title, columns=str.upper)
Out[75]:
    ONE  TWO  THREE  FOUR
```

```
Ohio  0    1      2     3
Colo  4    5      6     7
New   8    9     10    11
```

Metoda `rename` może być używana w połączeniu z obiektem będącym słownikiem zawierającym nowe wartości podzbioru etykiet osi:

```
In [76]: data.rename(index={'OHIO': 'INDIANA'},
   ....:             columns={'three': 'peekaboo'})
Out[76]:
          one  two  peekaboo  four
INDIANA  0    1         2     3
COLO     4    5         6     7
NEW      8    9        10    11
```

Korzystanie z metody `rename` zwalnia z obowiązku ręcznego kopiowania ramki danych i przypisywania jej atrybutów `index` i `columns`.

Dyskretyzacja i podział na koszyki

Ciągłe dane są często poddawane dyskretyzacji lub dzielone w inny sposób na „koszyki" umożliwiające ich dalszą analizę. Załóżmy, że dysponujesz danymi dotyczącymi osób wchodzących w skład grupy badawczej i chcesz dokonać ich podziału na koszyki w zależności od ich wieku:

```
In [77]: ages = [20, 22, 25, 27, 21, 23, 37, 31, 61, 45, 41, 32]
```

Dokonajmy podziału na koszyki 18 – 25, 26 – 36, 36 – 60 i 61+. W tym celu możemy skorzystać z funkcji `pandas.cut`:

```
In [78]: bins = [18, 25, 35, 60, 100]

In [79]: age_categories = pd.cut(ages, bins)

In [80]: age_categories
Out[80]:
[(18, 25], (18, 25], (18, 25], (25, 35], (18, 25], ..., (25, 35], (60, 100], (35, 60], (35,
60], (25, 35]]
Length: 12
Categories (4, interval[int64]): [(18, 25] < (25, 35] < (35, 60] < (60, 100]]
```

Obiekt zwrócony przez pandas jest specjalnym obiektem kategorycznym (typu `Categorical`). Zaprezentowane dane wyjściowe opisują koszyki wygenerowane za pomocą funkcji `pandas.cut`. Każdy koszyk jest identyfikowany przez specjalny, charakterystyczny dla biblioteki pandas interwał, opisujący dolną i górną granicę:

```
In [81]: age_categories.codes
Out[81]: array([0, 0, 0, 1, 0, 0, 2, 1, 3, 2, 2, 1], dtype=int8)

In [82]: age_categories.categories
Out[82]: IntervalIndex([(18, 25], (25, 35], (35, 60], (60, 100]], dtype='interval[int64,
right]')

In [83]: age_categories.categories[0]
Out[83]: Interval(18, 25, closed='right')

In [84]: pd.value_counts(age_categories)
```

```
Out[84]:
(18, 25]     5
(25, 35]     3
(35, 60]     3
(60, 100]    1
dtype: int64
```

Zauważ, że polecenie `pd.value_counts(categories)` zwraca liczby elementów znajdujących się w poszczególnych koszykach będących wynikiem funkcji `pandas.cut`.

Zgodnie z matematycznym zapisem interwałów nawias okrągły oznacza **otwarcie** zbioru, a nawias kwadratowy jego **domknięcie** (wartość graniczna zalicza się do zbioru). Zmiany otwartej strony zbioru możesz dokonać za pomocą argumentu `right=False`:

```
In [85]: pd.cut(ages, bins, right=False)
Out[85]:
[[18, 26), [18, 26), [18, 26), [26, 36), [18, 26), ..., [26, 36), [61, 100), [36, 61), [36, 61),
[26, 36)]
Length: 12
Categories (4, interval[int64]): [[18, 26) < [26, 36) < [36, 61) < [61, 100)]
```

Możesz zdefiniować własne nazwy koszyków. Wystarczy przekazać nazwę listy lub tablicę nazw za pomocą opcji `labels`:

```
In [86]: group_names = ['Youth', 'YoungAdult', 'MiddleAged', 'Senior']

In [87]: pd.cut(ages, bins, labels=group_names)
Out[87]:
[Youth, Youth, Youth, YoungAdult, Youth, ..., YoungAdult, Senior, MiddleAged, MiddleAged,
YoungAdult]
Length: 12
Categories (4, object): [Youth < YoungAdult < MiddleAged < Senior]
```

Jeżeli funkcji `pandas.cut` przekażesz liczbę całkowitą koszyków zamiast jawnych definicji krawędzi koszyków, to polecenie to zwróci koszyki o równej długości na podstawie minimalnej i maksymalnej wartości znajdującej się w dzielonym zbiorze danych. Oto przykład danych o równym rozkładzie podzielonych na cztery koszyki:

```
In [88]: data = np.random.rand(20)

In [89]: pd.cut(data, 4, precision=2)
Out[89]:
[(0.34, 0.55], (0.34, 0.55], (0.76, 0.97], (0.76, 0.97], (0.34, 0.55], ..., (0.34, 0.55],
(0.34, 0.55], (0.55, 0.76], (0.34, 0.55], (0.12, 0.34]]
Length: 20
Categories (4, interval[float64]): [(0.12, 0.34] < (0.34, 0.55] < (0.55, 0.76] < (0.76, 0.97]]
```

Opcja `precision=2` ogranicza precyzję wartości zmiennoprzecinkowych do dwóch miejsc po przecinku.

Funkcja `pandas.qcut` działa podobnie, ale dzieli dane na kwartyle. Zwykle funkcja `pandas.cut` nie dzieli zbioru na koszyki o takiej samej liczbie elementów (zależy to od rozkładu danych). Funkcja `pandas.qcut` korzysta z kwartyli, a więc wygenerowane przez nią koszyki będą charakteryzowały się zbliżoną liczbą elementów:

```
In [90]: data = np.random.standard_normal(1000)

In [91]: quartiles = pd.qcut(data, 4, precision=2)
```

```
In [92]: quartiles
Out[92]:
[(-0.026, 0.62], (0.62, 3.93], (-0.68, -0.026], (0.62, 3.93], (-0.026, 0.62], ...
, (-0.68, -0.026], (-0.68, -0.026], (-2.96, -0.68], (0.62, 3.93], (-0.68, -0.026]
]
Length: 1000
Categories (4, interval[float64, right]): [(-2.96, -0.68] < (-0.68, -0.026] < (-0
.026, 0.62] <(0.62, 3.93]]

In [93]: pd.value_counts(quartiles)
Out[93]:
(-2.96, -0.68]     250
(-0.68, -0.026]    250
(-0.026, 0.62]     250
(0.62, 3.93]       250
dtype: int64
```

Do funkcji `pandas.cut` możesz przekazać definicje własnych kwartyli (liczby z zakresu od 0 do 1 — przedział obustronnie domknięty):

```
In [94]: pd.qcut(data, [0, 0.1, 0.5, 0.9, 1.])
Out[94]:
(-2.9499999999999997, -1.187]     100
(-1.187, -0.0265]                 400
(-0.0265, 1.286]                  400
(1.286, 3.928]                    100
dtype: int64
```

Do funkcji `pandas.cut` i `pandas.qcut` wrócimy w dalszej części rozdziału przy okazji agregacji i operacji przeprowadzanych na grupach. Wymienione funkcje dyskretyzacji są szczególnie przydatne podczas analizy kwartyli i grup.

Wykrywanie i filtrowanie elementów odstających

Filtrowanie i przekształcanie elementów odstających polega głównie na przeprowadzaniu operacji tablicowych. Oto przykładowa ramka danych z wartościami charakteryzującymi się rozkładem normalnym:

```
In [95]: data = pd.DataFrame(np.random.standard_normal((1000, 4)))

In [96]: data.describe()
Out[96]:

                0            1            2            3
count  1000.000000  1000.000000  1000.000000  1000.000000
mean      0.049091     0.026112    -0.002544    -0.051827
std       0.996947     1.007458     0.995232     0.998311
min      -3.645860    -3.184377    -3.745356    -3.428254
25%      -0.599807    -0.612162    -0.687373    -0.747478
50%       0.047101    -0.013609    -0.022158    -0.088274
75%       0.756646     0.695298     0.699046     0.623331
max       2.653656     3.525865     2.735527     3.366626
```

Załóżmy, że chcesz znaleźć elementy, których wartość bezwzględna jest większa od 3:

```
In [97]: col = data[2]

In [98]: col[np.abs(col) > 3]
Out[98]:
41   -3.399312
136  -3.745356
Name: 2, dtype: float64
```

W celu wybrania wszystkich wierszy z wartościami przekraczającymi 3 lub –3 należy skorzystać z metody `any` obiektu `DataFrame`:

```
In [99]: data[(data.abs() > 3).any(axis="columns")]
Out[99]:
           0         1         2         3
41   0.457246 -0.025907 -3.399312 -0.974657
60   1.951312  3.260383  0.963301  1.201206
136  0.508391 -0.196713 -3.745356 -1.520113
235 -0.242459 -3.056990  1.918403 -0.578828
258  0.682841  0.326045  0.425384 -3.428254
322  1.179227 -3.184377  1.369891 -1.074833
544 -3.548824  1.553205 -2.186301  1.277104
635 -0.578093  0.193299  1.397822  3.366626
782 -0.207434  3.525865  0.283070  0.544635
803 -3.645860  0.255475 -0.549574 -1.907459
```

Nawiasy obejmujące wyrażenie `data.abs() > 3` są niezbędne, aby wynik porównania można było przetworzyć za pomocą metody `any`.

Wartości mogą być określane na podstawie tych kryteriów. Oto kod wyszukujący wartości poza zakresem od –3 do 3:

```
In [100]: data[np.abs(data) > 3] = np.sign(data) * 3

In [101]: data.describe()
Out[101]:
                0            1            2            3
count  1000.000000  1000.000000  1000.000000  1000.000000
mean      0.050286     0.025567    -0.001399    -0.051765
std       0.992920     1.004214     0.991414     0.995761
min      -3.000000    -3.000000    -3.000000    -3.000000
25%      -0.599807    -0.612162    -0.687373    -0.747478
50%       0.047101    -0.013609    -0.022158    -0.088274
75%       0.756646     0.695298     0.699046     0.623331
max       2.653656     3.000000     2.735527     3.000000
```

Instrukcja `np.sign(data)` generuje wartości 1 i –1 w zależności od tego, czy wartości obiektu `data` są dodatnie, czy ujemne:

```
In [102]: np.sign(data).head()
Out[102]:
     0    1    2    3
0 -1.0  1.0 -1.0  1.0
1  1.0 -1.0  1.0 -1.0
2  1.0  1.0  1.0 -1.0
3 -1.0 -1.0  1.0 -1.0
4 -1.0  1.0 -1.0 -1.0
```

Permutacje i próbkowanie losowe

Permutację (czyli losową zmianę kolejności) obiektu typu `Series` lub wiersza ramki danych można przeprowadzić z łatwością za pomocą funkcji `numpy.random.permutation`. Wywołanie funkcji `permutation` i przekazanie jej w roli argumentu długości osi, która ma zostać poddana permutacji, powoduje wygenerowanie tablicy wartości całkowitoliczbowych określających nową kolejność:

```
In [103]: df = pd.DataFrame(np.arange(5 * 7).reshape((5, 7)))

In [104]: df
Out[104]:
    0   1   2   3   4   5   6
0   0   1   2   3   4   5   6
1   7   8   9  10  11  12  13
2  14  15  16  17  18  19  20
3  21  22  23  24  25  26  27
4  28  29  30  31  32  33  34

In [105]: sampler = np.random.permutation(5)

In [106]: sampler
Out[106]: array([3, 1, 4, 2, 0])
```

Tablica ta może być następnie użyta w indeksowaniu opartym na funkcji `iloc` lub podobnej funkcji `take`:

```
In [107]: df.take(sampler)
Out[107]:
    0   1   2   3   4   5   6
3  21  22  23  24  25  26  27
1   7   8   9  10  11  12  13
4  28  29  30  31  32  33  34
2  14  15  16  17  18  19  20
0   0   1   2   3   4   5   6

In [108]: df.iloc[sampler]
Out[108]:
    0   1   2   3   4   5   6
3  21  22  23  24  25  26  27
1   7   8   9  10  11  12  13
4  28  29  30  31  32  33  34
2  14  15  16  17  18  19  20
0   0   1   2   3   4   5   6
```

Wywołując metodę `take` z argumentem `axis="columns"`, można uzyskać wynik permutacji kolumn:

```
In [109]: column_sampler = np.random.permutation(7)

In [110]: column_sampler
Out[110]: array([4, 6, 3, 2, 1, 0, 5])

In [111]: df.take(column_sampler, axis="columns")
Out[111]:
    4   6   3   2   1   0   5
0   4   6   3   2   1   0   5
1  11  13  10   9   8   7  12
```

```
2  18  20  17  16  15  14  19
3  25  27  24  23  22  21  26
4  32  34  31  30  29  28  33
```

W celu wybrania losowego podzbioru bez zastępowania (tj. tak, aby żaden wiersz nie pojawił się dwukrotnie) możesz skorzystać z metody `sample` obiektu `Series` lub `DataFrame`:

```
In [112]: df.sample(n=3)
Out[112]:
    0   1   2   3   4   5   6
2  14  15  16  17  18  19  20
4  28  29  30  31  32  33  34
0   0   1   2   3   4   5   6
```

W celu wygenerowania próbki *z* zastępowaniem (elementy mogą być wybierane więcej niż raz) skorzystaj z funkcji `sample` z argumentem `replace=True`:

```
In [113]: choices = pd.Series([5, 7, -1, 6, 4])

In [114]: choices.sample(n=10, replace=True)
Out[114]:
2   -1
0    5
3    6
1    7
4    4
0    5
4    4
0    5
4    4
4    4
dtype: int64
```

Przetwarzanie wskaźników i zmiennych zastępczych

Innym rodzajem transformacji przydatnej podczas modelowania statystycznego lub uczenia maszynowego jest konwersja zmiennej kategorycznej na macierz „elementów zastępczych" lub „wskaźników". Jeżeli w kolumnie ramki danych znajduje się *k* odmiennych wartości, to można utworzyć na jej podstawie macierz pochodną zawierającą *k* kolumn wypełnionych jedynkami i zerami. Służy do tego funkcja `pandas.get_dummies`, ale funkcję taką można z łatwością napisać samemu. Wróćmy do zaprezentowanego wcześniej przykładu ramki danych:

```
In [115]: df = pd.DataFrame({'key': ['b', 'b', 'a', 'c', 'a', 'b'],
   .....:                    'data1': range(6)})

In [116]: df
Out[116]:
  key  data1
0   b      0
1   b      1
2   a      2
3   c      3
4   a      4
5   b      5

In [117]: pd.get_dummies(df['key'])
```

```
Out[117]:
   a  b  c
0  0  1  0
1  0  1  0
2  1  0  0
3  0  0  1
4  1  0  0
5  0  1  0
```

Czasami zachodzi potrzeba dodania prefiksu do nazw kolumn wygenerowanej ramki danych, które można następnie połączyć z innymi danymi. Do tego właśnie służy argument `prefix` funkcji `pandas.get_dummies`:

```
In [118]: dummies = pd.get_dummies(df['key'], prefix='key')

In [119]: df_with_dummy = df[['data1']].join(dummies)

In [120]: df_with_dummy
Out[120]:
  data1  key_a  key_b  key_c
0     0      0      1      0
1     1      0      1      0
2     2      1      0      0
3     3      0      0      1
4     4      1      0      0
5     5      0      1      0
```

Metoda `DataFrame.join` zostanie dokładniej opisana w następnym rozdziale.

Jeżeli wiersz ramki danych należy do wielu kategorii, należy zmienne zastępcze utworzyć w inny sposób. Przyjrzyjmy się zbiorowi danych MovieLens 1M, który zostanie przeanalizowany w sposób bardziej szczegółowy w rozdziale 13.:

```
In [121]: mnames = ['movie_id', 'title', 'genres']

In [122]: movies = pd.read_table('dane/movielens/movies.dat', sep='::',
   .....:                        header=None, names=mnames)

In [123]: movies[:10]
Out[123]:
  movie_id                               title                        genres
0        1                    Toy Story (1995)   Animation|Children's|Comedy
1        2                      Jumanji (1995)  Adventure|Children's|Fantasy
2        3             Grumpier Old Men (1995)                Comedy|Romance
3        4            Waiting to Exhale (1995)                  Comedy|Drama
4        5  Father of the Bride Part II (1995)                        Comedy
5        6                         Heat (1995)         Action|Crime|Thriller
6        7                      Sabrina (1995)                Comedy|Romance
7        8                 Tom and Huck (1995)          Adventure|Children's
8        9                 Sudden Death (1995)                        Action
9       10                    GoldenEye (1995)     Action|Adventure|Thriller
```

Obiekt `Series` posiada specjalną metodę `str.get_dummies` (metody o nazwach rozpoczynających się od `str` będą dokładniej opisane w podrozdziale „Operacje przeprowadzane na łańcuchach”), przystosowaną do sytuacji, w których przynależność do wielu grup jest zakodowana za pomocą ciągu ich nazw oddzielonych separatorem:

```
In [124]: dummies = movies["genres"].str.get_dummies("|")

In [125]: dummies.iloc[:10, :6]
Out[125]:
   Action  Adventure  Animation  Children's  Comedy  Crime
0       0          0          1           1       1      0
1       0          1          0           1       0      0
2       0          0          0           0       1      0
3       0          0          0           0       1      0
4       0          0          0           0       1      0
5       1          0          0           0       0      1
6       0          0          0           0       1      0
7       0          1          0           1       0      0
8       1          0          0           0       0      0
9       1          1          0           0       0      0
```

Teraz tak jak wcześniej możemy połączyć ten wynik z obiektem `movies` podczas dodawania za pomocą metody `add_prefix` prefiksu `"Genre_"` do nazw kolumn zawartych w obiekcie `DataFrame`:

```
In [126]: movies_windic = movies.join(dummies.add_prefix('Genre_'))

In [127]: movies_windic.iloc[0]
Out[127]:
movie_id                                   1
title                          Toy Story (1995)
genres             Animation|Children's|Comedy
Genre_Action                               0
Genre_Adventure                            0
Genre_Animation                            1
Genre_Children's                           1
Genre_Comedy                               1
Genre_Crime                                0
Genre_Documentary                          0
Genre_Drama                                0
Genre_Fantasy                              0
Genre_Film-Noir                            0
Genre_Horror                               0
Genre_Musical                              0
Genre_Mystery                              0
Genre_Romance                              0
Genre_Sci-Fi                               0
Genre_Thriller                             0
Genre_War                                  0
Genre_Western                              0
Name: 0, Length: 21, dtype: object
```

Przedstawiona metoda tworzenia zmiennych wskazujących działa dość wolno przy dużych zbiorach danych. W takich przypadkach lepiej jest napisać niskopoziomową funkcję zapisującą dane bezpośrednio w tablicy NumPy, a następnie obudować wynik jej pracy obiektem DataFrame.

W zastosowaniach statystycznych warto połączyć `pandas.get_dummies` z funkcją dyskretyzacji `pandas.cut`:

```
In [128]: np.random.seed(12345)  # Aby przykład był powtarzalny

In [129]: values = np.random.uniform(size=10)
```

```
In [130]: values
Out[130]:
array([ 0.9296,  0.3164,  0.1839,  0.2046,  0.5677,  0.5955,  0.9645,  0.6532,  0.7489,
0.6536])

In [131]: bins = [0, 0.2, 0.4, 0.6, 0.8, 1]

In [132]: pd.get_dummies(pd.cut(values, bins))
Out[132]:
  (0.0, 0.2]  (0.2, 0.4]  (0.4, 0.6]  (0.6, 0.8]  (0.8, 1.0]
0          0           0           0           0           1
1          0           1           0           0           0
2          1           0           0           0           0
3          0           1           0           0           0
4          0           0           1           0           0
5          0           0           1           0           0
6          0           0           0           0           1
7          0           0           0           1           0
8          0           0           0           1           0
9          0           0           0           1           0
```

Do funkcji `pandas.get_dummies` wrócimy jeszcze w podrozdziale „Tworzenie fikcyjnych zmiennych używanych podczas modelowania”.

7.3. Rozszerzone typy danych

Temat tego rozdziału jest nowy i bardziej zaawansowany, więc wielu użytkownikom biblioteki pandas może nie być dobrze znany. Przedstawiam go tutaj dla kompletności opisu, jak również dlatego, że w wielu miejscach w następnych rozdziałach będę odwoływał się do rozszerzonych typów danych.

Biblioteka pandas została pierwotnie zbudowana na bazie funkcjonalności obecnie dostępnych w NumPy — macierzowej bibliotece obliczeniowej, używanej głównie do pracy z danymi liczbowymi. Wiele z tych funkcjonalności, na przykład obsługa brakujących danych, zostało zaimplementowanych z myślą o maksymalnej kompatybilności z bibliotekami, które wykorzystują jednocześnie NumPy i pandas.

Bazowanie na bibliotece NumPy jest przyczyną wielu mankamentów biblioteki pandas, takich jak na przykład:

- Niepełna obsługa brakujących danych całkowitoliczbowych i logicznych. W efekcie biblioteka pandas używa do reprezentowania brakujących danych obiektu `np.nan`, a istniejące wartości przekształca w liczby zmiennoprzecinkowe, co w wielu algorytmach skutkuje subtelnymi błędami.
- Operacje wykonywane na dużych zbiorach danych tekstowych są kosztowne obliczeniowo i zajmują dużo pamięci.
- Niektóre typy danych, m.in. szeregi czasowe, interwały i znaczniki z identyfikatorami stref nie mogą być wydajnie przetwarzane bez użycia kosztownych obliczeniowo tablic obiektów Pythona.

Ostatnio biblioteka pandas została rozbudowana o *rozszerzone typy* danych, dzięki którym można przetwarzać nowe typy, nieobsługiwane natywnie przez bibliotekę NumPy. Wraz z tablicami można je traktować jako typy pierwszoklasowe.

Przyjrzyjmy się przykładowi utworzenia serii liczb całkowitych z brakującą wartością:

```
In [133]: s = pd.Series([1, 2, 3, None])

In [134]: s
Out[134]:
0    1.0
1    2.0
2    3.0
3    NaN
dtype: float64

In [135]: s.dtype
Out[135]: dtype('float64')
```

Głównie ze względu na kompatybilność wsteczną typ Series wykorzystuje standardowy typ `float64` i obiekt `np.nan` oznaczający brakujące wartości. Tego rodzaju serię można również utworzyć, używając metody `pandas.Int64Dtype`:

```
In [136]: s = pd.Series([1, 2, 3, None], dtype=pd.Int64Dtype())

In [137]: s
Out[137]:
0       1
1       2
2       3
3    <NA>
dtype: Int64

In [138]: s.isna()
Out[138]:
0    False
1    False
2    False
3     True
dtype: bool

In [139]: s.dtype
Out[139]: Int64Dtype()
```

Ciąg `<NA>` oznacza brak wartości w tablicy zawierającej dane rozszerzonego typu. Jest to specjalny obiekt zastępczy `pandas.NA`:

```
In [140]: s[3]
Out[140]: <NA>

In [141]: s[3] is pd.NA
Out[141]: True
```

Zamiast metody `pd.Int64Dtype` można użyć krótkiego oznaczenia rozszerzonego typu `"Int64"`. Ważna jest wielkość liter. Jeżeli zostanie użyta inna, typ zostanie potraktowany jako nierozszerzony, właściwy dla biblioteki NumPy:

```
In [142]: s = pd.Series([1, 2, 3, None], dtype="Int64")
```

Biblioteka pandas zawiera również rozszerzony typ danych tekstowych, który nie wykorzystuje tablic obiektów NumPy (wymaga natomiast biblioteki pyarrow, którą trzeba zainstalować osobno):

```
In [143]: s = pd.Series(['one', 'two', None, 'three'], dtype=pd.StringDtype())

In [144]: s
Out[144]:
0      one
1      two
2     <NA>
3    three
dtype: string
```

Duże tablice danych tego typu zazwyczaj zajmują znacznie mniej pamięci, a operacje na nich są bardziej wydajne.

Innym ważnym typem rozszerzonym jest `Categorical`, który będzie dokładniej opisany w podrozdziale „Dane kategoryczne”. Tabela 7.3 przedstawia pełną listę rozszerzonych typów dostępnych w chwili pisania tego tekstu.

Tabela 7.3. Rozszerzone typy danych w bibliotece pandas

Typ wyrażenia	Opis
`BooleanDtype`	Wartość logiczna, dopuszczone wartości puste, oznaczenie tekstowe `"boolean"`.
`CategoricalDtype`	Wartość kategoryczna, oznaczenie tekstowe `"category"`.
`DatetimeTZDtype`	Data i czas z oznaczeniem strefy.
`Float32Dtype`	32-bitowa liczba zmiennoprzecinkowa, dopuszczone wartości puste, oznaczenie tekstowe `"Float32"`.
`Float64Dtype`	32-bitowa liczba zmiennoprzecinkowa, dopuszczone wartości puste, oznaczenie tekstowe `"Float64"`.
`Int8Dtype`	8-bitowa liczba całkowita ze znakiem, dopuszczone wartości puste, oznaczenie tekstowe `"Int8"`.
`Int16Dtype`	16-bitowa liczba całkowita ze znakiem, dopuszczone wartości puste, oznaczenie tekstowe `"Int16"`.
`Int32Dtype`	32-bitowa liczba całkowita ze znakiem, dopuszczone wartości puste, oznaczenie tekstowe `"Int32"`.
`Int64Dtype`	64-bitowa liczba całkowita ze znakiem, dopuszczone wartości puste, oznaczenie tekstowe `"Int64"`.
`UInt8Dtype`	8-bitowa liczba całkowita bez znaku, dopuszczone wartości puste, oznaczenie tekstowe `"UInt8"`.
`UInt16Dtype`	16-bitowa liczba całkowita bez znaku, dopuszczone wartości puste, oznaczenie tekstowe `"UInt16"`.
`UInt32Dtype`	32-bitowa liczba całkowita bez znaku, dopuszczone wartości puste, oznaczenie tekstowe `"UInt32"`.
`UInt64Dtype`	64-bitowa liczba całkowita bez znaku, dopuszczone wartości puste, oznaczenie tekstowe `"UInt64"`.

Oznaczenia rozszerzonych typów można umieszczać w argumencie metody `astype` obiektu `Series`, co ułatwia przekształcanie danych w procesie ich oczyszczania:

```
In [145]: df = pd.DataFrame({"A": [1, 2, None, 4],
   .....:                    "B": ["one", "two", "three", None],
   .....:                    "C": [False, None, False, True]})
```

```
In [146]: df
Out[146]:
     A      B      C
0  1.0    one  False
1  2.0    two   None
2  NaN  three  False
3  4.0   None   True

In [147]: df["A"] = df["A"].astype("Int64")

In [148]: df["B"] = df["B"].astype("string")

In [149]: df["C"] = df["C"].astype("boolean")

In [150]: df
Out[150]:
      A      B      C
0     1    one  False
1     2    two   <NA>
2  <NA>  three  False
3     4   <NA>   True
```

7.4. Operacje przeprowadzane na łańcuchach

Popularność Pythona jako języka przeznaczonego do manipulowania nieprzetwarzanymi wcześniej danymi wynika między innymi z łatwości wykonywania operacji na łańcuchach i przetwarzania tekstu. Większość operacji tekstowych można wykonać prosto za pomocą wbudowanych metod obiektu typu `string`. W celu bardziej złożonych operacji dobierania wzorców i obróbki tekstu może zachodzić konieczność korzystania z wyrażeń regularnych. Pakiet pandas umożliwia stosowanie operacji łańcuchowych i wyrażeń regularnych na całych tablicach danych i dodatkowo pozwala rozwiązać problem występowania brakujących danych.

Metody obiektu typu string

Wbudowane metody łańcuchów wystarczają do przeprowadzania wielu operacji przetwarzania łańcuchów i tworzenia skryptów. Np. metoda `split` dzieli na fragmenty łańcuch, w którym rolę separatora pełni przecinek:

```
In [151]: val = 'a,b, guido'

In [152]: val.split(',')
Out[152]: ['a', 'b', ' guido']
```

Metoda `split` jest często używana w połączeniu z metodą `strip`, która usuwa białe znaki (w tym również znaki końca wiersza):

```
In [153]: pieces = [x.strip() for x in val.split(',')]

In [154]: pieces
Out[154]: ['a', 'b', 'guido']
```

Podłańcuchy można połączyć za pomocą podwójnego dwukropka i operacji dodawania:

```
In [155]: first, second, third = pieces

In [156]: first + '::' + second + '::' + third
Out[156]: 'a::b::guido'
```

Nie jest to jednak praktyczne rozwiązanie. Można to zrobić szybciej, przekazując listę lub krotkę do metody `join` łańcucha `'::'`:

```
In [157]: '::'.join(pieces)
Out[157]: 'a::b::guido'
```

Pozostałe metody są przeznaczone do szukania podłańcuchów. Podłańcuchy najlepiej jest wyszukiwać za pomocą słowa kluczowego `in`, ale można korzystać również z metod `index` i `find`:

```
In [158]: 'guido' in val
Out[158]: True

In [159]: val.index(',')
Out[159]: 1

In [160]: val.find(':')
Out[160]: -1
```

Zapamiętaj, że różnicą pomiędzy metodą `find` i `index` jest to, że metoda `index` generuje wyjątek w razie nieznalezienia łańcucha (metoda `find` zwraca wtedy wartość –1):

```
In [161]: val.index(':')
---------------------------------------------------------------------------
ValueError   Traceback (most recent call last)
<ipython-input-144-280f8b2856ce> in <module>()
----> 1 val.index(':')
ValueError: substring not found
```

Metoda `count` zwraca liczbę wystąpień określonego podłańcucha:

```
In [162]: val.count(',')
Out[162]: 2
```

Metoda `replace` zastępuje miejsca występowania jednego ciągu znaków innym ciągiem znaków. Jest ona często używana do kasowania podłańcuchów (wystarczy przekazać do niej pusty łańcuch):

```
In [163]: val.replace(',', '::')
Out[163]: 'a::b:: guido'

In [164]: val.replace(',', '')
Out[164]: 'ab guido'
```

W tabeli 7.4 znajdziesz listę wybranych metod obiektów typu `string`.

W kontekście wielu tych operacji można również stosować wyrażenia regularne (wkrótce przedstawię przykłady takich rozwiązań).

Tabela 7.4. Wbudowane metody obiektu string

Argument	Opis
`count`	Zwraca liczbę nienakładających się wystąpień danego ciągu znaków w łańcuchu.
`endswith`	Zwraca `True`, jeżeli łańcuch kończy się sufiksem.
`startswith`	Zwraca `True`, jeżeli łańcuch rozpoczyna się prefiksem.
`join`	Używa łańcucha w roli elementu rozdzielającego inne łączone ze sobą łańcuchy.
`index`	Zwraca pozycję pierwszego znaku ciągu znaków znalezionego w łańcuchu; w razie nieznalezienia ciągu generowany jest błąd `ValueError`.
`find`	Zwraca pozycję pierwszego znaku *pierwszego* wystąpienia ciągu znaków w łańcuchu; działa jak metoda `index`, ale w razie nieznalezienia ciągu zwraca wartość –1.
`rfind`	Zwraca pozycję pierwszego znaku *ostatniego* wystąpienia ciągu znaków w łańcuchu; w razie nieznalezienia ciągu zwraca wartość –1.
`replace`	Zastępuje ciąg znaków innym ciągiem znaków.
`strip`, `rstrip`, `lstrip`	Usuwa białe znaki, w tym znaki końca wiersza odpowiednio z obu końców, z lewej i prawej strony ciągu.
`split`	Dzieli łańcuch na podłańcuchy przy użyciu przekazanego znaku rozdzielającego.
`lower`	Konwertuje znaki na małe litery.
`upper`	Konwertuje znaki na wielkie litery.
`casefold`	Konwertuje wielkie litery na małe, a także konwertuje wszelkie kombinacje znaków specjalnych charakterystycznych dla niektórych języków na standardowe znaki, które mogą być porównywane.
`ljust`, `rjust`	Justowanie do lewej lub prawej; dodaje spacje lub inne znaki wypełnienia po przeciwnej stronie łańcucha w celu zwrócenia łańcucha o minimalnej szerokości.

Wyrażenia regularne

Stosowanie **wyrażeń regularnych** to uniwersalny sposób wyszukiwania lub dobierania (często złożonych) ciągów znaków w tekście. Pojedyncze wyrażenie regularne określa się mianem wyrażenia **regex**. Jest to łańcuch utworzony zgodnie ze składnią języka wyrażeń regularnych. Wbudowany moduł Pythona `re` jest używany do obsługi wyrażeń regularnych w kontekście łańcuchów. W dalszej części tej sekcji przedstawię dużo przykładów zastosowania takich wyrażeń.

Na temat tworzenia wyrażeń regularnych można napisać oddzielny rozdział, ale zagadnienie to wykracza nieco poza zakres tematyczny tej książki. W innych książkach, a także w internecie można znaleźć wiele dobrych poradników dotyczących obsługi wyrażeń regularnych.

Funkcje modułu `re` można podzielić na trzy kategorie: dopasowywanie ciągu, zastępowanie i dzielenie. Oczywiście wszystkie te operacje są ze sobą związane. Wyrażenie regularne opisuje wzorzec, który ma zostać znaleziony w tekście, a więc można je stosować w celu wykonania różnych operacji. Przyjrzyj się następującemu przykładowi: załóżmy, że chcemy podzielić łańcuch zawierający zmienną liczbę białych znaków (spacji, tabulacji, znaków nowego wiersza). Wyrażenie regularne `\s+` jest symbolem zastępczym przynajmniej jednego białego znaku:

```
In [165]: import re

In [166]: text = "foo bar\tbaz  \tqux"

In [167]: re.split('\s+', text)
Out[167]: ['foo', 'bar', 'baz', 'qux']
```

Po uruchomieniu funkcji `re.split('\s+', text)` wyrażenie regularne jest najpierw *kompilowane*, a następnie na przekazanym tekście wywoływana jest metoda `split`. Możesz samodzielnie skompilować wyrażenie regularne za pomocą funkcji `re.compile`, co pozwala na uzyskanie obiektu wyrażenia regularnego, który może być użyty wielokrotnie:

```
In [168]: regex = re.compile('\s+')

In [169]: regex.split(text)
Out[169]: ['foo', 'bar', 'baz', 'qux']
```

Gdybyś natomiast chciał uzyskać listę wszystkich wzorców pasujących do wyrażenia regularnego, możesz skorzystać z metody `findall`:

```
In [170]: regex.findall(text)
Out[170]: [' ', '\t', '  \t']
```

Aby uniknąć korzystania w wyrażeniach regularnych z sekwencji specjalnej rozpoczynającej się od znaku \, korzystaj z surowych literałów łańcuchowych, takich jak `r'C:\x'`, zamiast z ich odpowiedników w postaci `'C:\\x'`.

W przypadku stosowania tego samego wyrażenia do wielu łańcuchów zaleca się tworzenie obiektu wyrażenia regularnego za pomocą funkcji `re.compile`. Dzięki temu zmniejszona zostanie liczba użytych cykli procesora.

Metody `match` i `search` są związane z metodą `findall`. Metoda `findall` zwraca wszystkie przypadki dopasowania znalezione w łańcuchu, a metoda `search` zwraca *tylko* pierwsze dopasowanie, a dokładnie rzecz biorąc, zwraca ona początek wyszukiwanego ciągu znaków. Przyjrzyjmy się przykładowi wyrażenia regularnego mogącego zidentyfikować większość adresów poczty elektronicznej umieszczonych w bloku tekstu:

```
text = """Dave dave@google.com
Steve steve@gmail.com
Rob rob@gmail.com
Ryan ryan@yahoo.com
"""
pattern =r'[A-ZO-9._%+-]+@[A-ZO-9.-]+\.[A-Z]{2,4}'

# Flaga re.IGNORECASE sprawia, że wyrażenie regularne nie zwraca uwagi na wielkość liter.
regex = re.compile(pattern, flags=re.IGNORECASE)
```

Użycie metody `findall` na tekście zwraca listę adresów:

```
In [172]: regex.findall(text)
Out[172]:
['dave@google.com',
 'steve@gmail.com',
 'rob@gmail.com',
 'ryan@yahoo.com']
```

Metoda `search` zwraca specjalny obiekt dopasowania dla pierwszego adresu znalezionego w tekście. W przypadku zaprezentowanego wcześniej wyrażenia regularnego obiekt dopasowania może tylko poinformować nas o początku i końcu wzorca znalezionego w łańcuchu:

```
In [173]: m = regex.search(text)

In [174]: m
Out[174]: <_sre.SRE_Match object; span=(5, 20), match='dave@google.com'>

In [175]: text[m.start():m.end()]
Out[175]: 'dave@google.com'
```

Metoda `regex.match` zwraca `None`, ponieważ jest ona w stanie znaleźć wzorzec tylko wtedy, gdy znajduje się on na początku łańcucha:

```
In [176]: print(regex.match(text))
None
```

Metoda `sub` zwróci nowy łańcuch, w którym miejsca wystąpień wzorca zostaną zastąpione nowym łańcuchem:

```
In [177]: print(regex.sub('REDACTED', text))
Dave REDACTED
Steve REDACTED
Rob REDACTED
Ryan REDACTED
```

Załóżmy, że chcesz znaleźć adres e-mail i jednocześnie dokonać segmentacji każdego adresu na trzy komponenty: nazwę użytkownika, nazwę domeny i sufiks domeny. W tym celu musisz umieścić nawiasy okrągłe wokół części wzorca, które mają być poddane segmentacji:

```
In [178]: pattern =r'([A-ZO-9._%+-]+)@([A-ZO-9.-]+)\.([A-Z]{2,4})'

In [179]: regex = re.compile(pattern, flags=re.IGNORECASE)
```

Obiekt dopasowania wygenerowany przez to zmodyfikowane wyrażenie regularne zwraca krotkę z komponentami wzorca (w celu uzyskania do niej dostępu należy skorzystać z metody `groups`):

```
In [180]: m = regex.match('wesm@bright.net')

In [181]: m.groups()
Out[181]: ('wesm', 'bright', 'net')
```

Gdy wzorzec zawiera grupy, metoda `findall` zwraca listę krotek:

```
In [182]: regex.findall(text)
Out[182]:
[('dave', 'google', 'com'),
 ('steve', 'gmail', 'com'),
 ('rob', 'gmail', 'com'),
 ('ryan', 'yahoo', 'com')]
```

Metoda `sub` umożliwia uzyskanie dostępu do grup każdego dopasowania za pomocą symboli w rodzaju `\1` i `\2`. Symbol `\1` odwołuje się do pierwszej dopasowanej grupy, symbol `\2` odwołuje się do drugiej dopasowanej grupy itd.:

```
In [183]: print(regex.sub(r'Username: \1, Domain: \2, Suffix: \3', text))
Dave Username: dave, Domain: google, Suffix: com
Steve Username: steve, Domain: gmail, Suffix: com
Rob Username: rob, Domain: gmail, Suffix: com
Ryan Username: ryan, Domain: yahoo, Suffix: com
```

Python obsługuje o wiele więcej wyrażeń regularnych, ale korzystanie z większości z nich wykracza poza zakres tematyczny tej książki. W tabeli 7.5 podsumowano wybrane metody wyrażeń regularnych.

Tabela 7.5. Metody wyrażeń regularnych

Metoda	Opis
`findall`	Zwraca wszystkie nienakładające się dopasowania w formie listy.
`finditer`	Działa jak metoda `findall`, ale zwraca iterator.
`match`	Dopasowuje wzorzec na początku łańcucha i opcjonalnie dzieli komponenty wzorca na grupy; w przypadku dopasowania wzorca zwraca obiekt dopasowania, a w przeciwnym wypadku zwraca `None`.
`search`	Skanuje łańcuch w poszukiwaniu wzorca; w przypadku znalezienia go zwraca obiekt dopasowania; w przeciwieństwie do metody `match` wzorzec może być znaleziony nie tylko na początku przeszukiwanego łańcucha.
`split`	Dzieli łańcuch na kawałki w miejscu wystąpienia określonego wzorca.
`sub`, `subn`	Zastępuje wszystkie (`sub`) lub n wystąpień (`subn`) wzorca w łańcuchu wyrażeniem zastępczym; w celu odwołania się do grup elementów w łańcuchu zastępczym korzystaj z symboli `\1`, `\2`...

Funkcje tekstowe w pakiecie pandas

Oczyszczanie zbioru danych przed analizą często wiąże się z koniecznością przekształcania łańcuchów. Sprawę komplikują dodatkowo brakujące dane kolumny z łańcuchami:

```
In [184]: data = {'Dave': 'dave@google.com', 'Steve': 'steve@gmail.com',
   .....:         'Rob': 'rob@gmail.com', 'Wes': np.nan}

In [185]: data = pd.Series(data)

In [186]: data
Out[186]:
Dave   dave@google.com
Rob      rob@gmail.com
Steve  steve@gmail.com
Wes                NaN
dtype: object

In [187]: data.isna ()
Out[187]:
Dave   False
Rob    False
Steve  False
Wes     True
dtype: bool
```

W celu zastosowania metod łańcucha lub wyrażenia regularnego na każdej wartości (przekazując funkcję `lambda` lub inną funkcję), można skorzystać z notacji `data.map`, ale w przypadku wartości NA (`null`) wywoła to komunikat błędu. W związku z tym obiekt `Series` dysponuje metodami tablicowymi

przeznaczonymi do przetwarzania łańcuchów, które pomijają brakujące wartości. Dostęp do tych metod uzyskuje się za pomocą atrybutu `str` obiektu typu `Series`. Za pomocą metody `str.contains` możemy np. sprawdzić, czy każdy adres e-mail zawiera ciąg znaków `'gmail'`:

```
In [188]: data.str.contains('gmail')
Out[188]:
Dave  False
Rob    True
Steve  True
Wes     NaN
dtype: object
```

Zwróć uwagę, że wynikiem tej operacji jest obiekt. Biblioteka pandas implementuje *rozszerzone typy* danych, umożliwiające wykonywanie na ciągach znaków, liczbach całkowitych i wartościach logicznych specjalnych operacji, z którymi do niedawna były pewne problemy, jeżeli brakowało wartości:

```
In [189]: data_as_string_ext = data.astype('string')

In [190]: data_as_string_ext
Out[190]:
Dave     dave@google.com
Steve    steve@gmail.com
Rob        rob@gmail.com
Wes                 <NA>
dtype: string

In [191]: data_as_string_ext.str.contains("gmail")
Out[191]:
Dave     False
Steve     True
Rob       True
Wes       <NA>
dtype: boolean
```

Wspomniane typy zostały opisane w podrozdziale „Rozszerzone typy danych”.

Możliwe jest również zastosowanie wyrażeń regularnych oraz innych opcji modułu `re`, takich jak `IGNORECASE`:

```
In [192]: pattern
Out[192]: '([A-ZO-9._%+-]+)@([A-ZO-9.-]+)\\.([A-Z]{2,4})'

In [193]: data.str.findall(pattern, flags=re.IGNORECASE)
Out[193]:
Dave   [(dave, google, com)]
Rob      [(rob, gmail, com)]
Steve  [(steve, gmail, com)]
Wes                      NaN
dtype: object
```

Istnieje kilka sposobów przeprowadzenia wektorowego wyszukiwania elementów. Można to zrobić za pomocą funkcji `str.get` lub poprzez przekazanie indeksu do funkcji `str`:

```
In [194]: matches = data.str.findall(pattern, flags=re.IGNORECASE).str[0]

In [195]: matches
```

```
Out[195]:
Dave     (dave, google, com)
Steve    (steve, gmail, com)
Rob        (rob, gmail, com)
Wes                      NaN
dtype: object

In [196]: matches.str.get(1)
Out[196]:
Dave                  google
Steve                  gmail
Rob                    gmail
Wes                      NaN
dtype: object
```

Łańcuch możesz również pociąć za pomocą następującej składni:

```
In [197]: data.str[:5]
Out[197]:
Dave   dave@
Rob    rob@g
Steve  steve
Wes      NaN
dtype: object
```

Metoda `str.extract` zwraca obiekty `DataFrame` zawierające grupy wyodrębnione za pomocą wyrażenia regularnego:

```
In [198]: data.str.extract(pattern, flags=re.IGNORECASE)
Out[198]:
           0       1    2
Dave    dave  google  com
Steve  steve   gmail  com
Rob      rob   gmail  com
Wes      NaN     NaN  NaN
```

Więcej metod obiektów typu `string` obsługiwanych przez bibliotekę pandas znajdziesz w tabeli 7.6.

Tabela 7.6. Wybrane metody obiektu Series

Metoda	Opis
`Cat`	Łączy łańcuchy element po elemencie, stosując opcjonalny łańcuch rozdzielający.
`Contains`	Zwraca tablicę wartości logicznych informujących o tym, czy każdy z łańcuchów zawiera określony wzorzec lub wyrażenie regularne.
`Count`	Określa liczbę wystąpień wzorca.
`Extract`	Korzysta z wyrażenia regularnego z grupami w celu wyciągnięcia jednego lub więcej łańcuchów z obiektu `Series` zawierającego łańcuchy; wynik będzie miał postać ramki danych, której poszczególne kolumny będą zawierały po jednej grupie.
`Endswith`	Odpowiednik notacji `x.endswith(pattern)` dla każdego elementu.
`Startswith`	Odpowiednik notacji `x.startswith(pattern)` dla każdego elementu.
`Findall`	Zwraca listę wszystkich wystąpień wzorca lub wyrażenia regularnego w każdym łańcuchu.
`get`	Indeksuje każdy element (pobiera *i*-ty element).
`isalnum`	Odpowiednik wbudowanej metody `str.alnum`.

Tabela 7.6. Wybrane metody obiektu Series (ciąg dalszy)

Metoda	Opis
`isalpha`	Odpowiednik wbudowanej metody `str.isalph`.
`isdecimal`	Odpowiednik wbudowanej metody `str.isdecimal`.
`isdigit`	Odpowiednik wbudowanej metody `str.isdigit`.
`islower`	Odpowiednik wbudowanej metody `str.islower`.
`isnumeric`	Odpowiednik wbudowanej metody `str.isnumeric`.
`isupper`	Odpowiednik wbudowanej metody `str.isupper`.
`join`	Łączy łańcuchy w każdym elemencie obiektu `Series` przy użyciu przekazanego separatora.
`len`	Określa długość każdego łańcucha.
`lower, upper`	Zmiana wielkości liter; odpowiedniki funkcji `x.lower()` i `x.upper()` przetwarzających wszystkie elementy.
`match`	Korzysta z modułu `re.match`, przekazując za jego pomocą wyrażenia regularne w celu przetworzenia każdego elementu; w zależności od wyniku dopasowania zwraca wartość `True` lub `False`.
`pad`	Dodaje białe znaki po lewej lub prawej stronie łańcuchów; znaki mogą być również dodawane po obu stronach łańcuchów.
`center`	Odpowiednik `pad(side='both')`.
`repeat`	Duplikuje wartości (np. notacja `s.str.repeat(3)` jest odpowiednikiem operacji `x * 3` wykonanej dla każdego łańcucha).
`replace`	Zastępuje wystąpienia wzorca lub wyrażenia regularnego innym łańcuchem.
`slice`	Tnie łańcuchy wchodzące w skład serii.
`split`	Rozdziela łańcuchy na określonym znaku lub wyrażeniu regularnym.
`strip`	Ucina białe znaki po obu stronach łańcucha (dotyczy to również znaków nowego wiersza).
`rstrip`	Ucina białe znaki po prawej stronie.
`lstrip`	Ucina białe znaki po lewej stronie.

7.5. Dane kategoryczne

W tej sekcji wprowadzę typ `Categorical` obsługiwany przez pakiet pandas. Dowiesz się, jak można z niego korzystać w celu uzyskania lepszej wydajności i zmniejszenia zużycia pamięci podczas wykonywania niektórych operacji. Ponadto przedstawię wybrane narzędzia przeznaczone do używania danych kategorycznych w zastosowaniach związanych ze statystyką i uczeniem maszynowym.

Kontekst i motywacja

Często kolumna tabeli zawiera powtarzające się instancje mniejszego zbioru różnych wartości. Podczas lektury poprzednich rozdziałów poznałeś już funkcje `unique` i `calue_counts`, które wyciągają odmienne wartości z tablicy i określają częstotliwości ich występowania:

```
In [199]: values = pd.Series(['apple', 'orange', 'apple',
   ....:                      'apple'] * 2)

In [200]: values
Out[200]:
0   apple
```

```
1  orange
2   apple
3   apple
4   apple
5  orange
6   apple
7   apple
dtype: object

In [201]: pd.unique(values)
Out[201]: array(['apple', 'orange'], dtype=object)

In [202]: pd.value_counts(values)
Out[202]:
apple   6
orange  2
dtype: int64
```

Wiele systemów obsługujących dane (składujących je, przetwarzających w celach statystycznych itd.) korzysta ze specjalnych technik przedstawiania danych zawierających powtarzające się wartości, co pozwala na zmniejszenie objętości danych i przyśpieszanie ich przetwarzania. Najlepszą praktyką stosowaną w przypadku hurtowni danych jest korzystanie z *tablic wymiaru* zawierających unikalne wartości. W takim przypadku pierwotne obserwacje są zapisywane w postaci kluczy numerycznych odwołujących się do tabeli wymiaru:

```
In [203]: values = pd.Series([0, 1, 0, 0] * 2)

In [204]: dim = pd.Series(['apple', 'orange'])

In [205]: values
Out[205]:
0  0
1  1
2  0
3  0
4  0
5  1
6  0
7  0
dtype: int64

In [206]: dim
Out[206]:
0   apple
1  orange
dtype: object
```

W celu przywrócenia początkowej struktury serii łańcuchów możemy skorzystać z metody `take`:

```
In [207]: dim.take(values)
Out[207]:
0   apple
1  orange
0   apple
0   apple
0   apple
```

```
1  orange
0   apple
0   apple
dtype: object
```

Przedstawienie danych za pomocą wartości liczbowych określamy mianem reprezentacji **kategorycznej** lub **kodowanej słownikowo**. Tablicę unikalnych wartości określamy mianem **kategorii**, **słownika** lub **poziomów** danych. W tej książce będę posługiwał się terminami *reprezentacja kategoryczna* i *kategorie*. Wartości liczbowe odwołujące się do kategorii określamy mianem **kodów kategorii** lub po prostu **kodów**.

Reprezentacja kategoryczna pozwala na znaczne zwiększenie wydajności przeprowadzania procesów analitycznych. Ponadto umożliwia przeprowadzanie transformacji kategorii bez modyfikowania kodów. Transformacje, które można przeprowadzić względnie niskim kosztem, to:

- zmiana nazw kategorii;
- dodanie nowej kategorii bez zmieniania kolejności i położenia utworzonych wcześniej kategorii.

Rozszerzony typ Categorical w bibliotece pandas

Biblioteka pandas oferuje specjalny, rozszerzony typ danych `Categorical` przeznaczony do przechowywania danych, w których kategorie są przedstawiane (*zakodowane*) przy użyciu wartości liczbowych. Jest to popularna technika kompresji danych, w których wielokrotnie występują podobne wartości. Zapewnia znacznie wyższą wydajność przy mniejszym zużyciu pamięci, zwłaszcza w przypadku danych łańcuchowych. Przyjrzyjmy się jeszcze raz użytemu wcześniej obiektowi typu `Series`:

```
In [208]: fruits = ['apple', 'orange', 'apple', 'apple'] * 2

In [209]: N = len(fruits)

In [210]: rng = np.random.default_rng(seed=12345)

In [211]: df = pd.DataFrame({'fruit': fruits,
   ....:                     'basket_id': np.arange(N),
   ....:                     'count': np.random.randint(3, 15, size=N),
   ....:                     'weight': np.random.uniform(0, 4, size=N)},
   ....:                    columns=['basket_id', 'fruit', 'count', 'weight'])

In [212]: df
Out[212]:
   basket_id   fruit  count    weight
0          0   apple     11  1.564438
1          1  orange      5  1.331256
2          2   apple     12  2.393235
3          3   apple      6  0.746937
4          4   apple      5  2.691024
5          5  orange     12  3.767211
6          6   apple     10  0.992983
7          7   apple     11  3.795525
```

W zaprezentowanym przykładzie `df['fruit']` jest tablicą obiektów typu `string` (łańcuchów). Możemy dokonać jej konwersji na typ kategoryczny za pomocą następującej funkcji:

```
In [213]: fruit_cat = df['fruit'].astype('category')

In [214]: fruit_cat
Out[214]:
0   apple
1  orange
2   apple
3   apple
4   apple
5  orange
6   apple
7   apple
Name: fruit, dtype: category
Categories (2, object): [apple, orange]
```

Teraz wartościami parametru `fruit_cat` są instancje typu `pandas.Categorical`, do których można się odwoływać za pomocą atrybutu `array`:

```
In [215]: c = fruit_cat.array

In [216]: type(c)
Out[216]: pandas.core.categorical.Categorical
```

Obiekt `Categorical` ma atrybuty `categories` (kategorie) i `codes` (kody):

```
In [217]: c.categories
Out[217]: Index(['apple', 'orange'], dtype='object')

In [218]: c.codes
Out[218]: array([0, 1, 0, 0, 0, 1, 0, 0], dtype=int8)
```

Do tych danych można się łatwiej odwoływać za pomocą atrybutu dostępowego `cat`, który będzie wkrótce opisany w podrozdziale „Metody obiektu kategorycznego”.

Powiązania pomiędzy kodami a kategoriami można uzyskać, stosując następującą przydatną sztuczkę:

```
In [219]: dict(enumerate(c.categories))
Out[219]: {0: 'apple', 1: 'orange'}
```

Możliwe jest wykonanie konwersji kolumny obiektu `DataFrame` na obiekt typu `Categorical` poprzez operację przypisania:

```
In [220]: df['fruit'] = df['fruit'].astype('category')

In [221]: df['fruit']
Out[221]:
0   apple
1  orange
2   apple
3   apple
4   apple
5  orange
6   apple
7   apple
Name: fruit, dtype: category
Categories (2, object): [apple, orange]
```

Instancje obiektów `pandas.Categorical` mogą być tworzone bezpośrednio na podstawie innych typów sekwencji Pythona:

```
In [222]: my_categories = pd.Categorical(['foo', 'bar', 'baz', 'foo', 'bar'])

In [223]: my_categories
Out[223]:
[foo, bar, baz, foo, bar]
Categories (3, object): [bar, baz, foo]
```

W przypadku uzyskania danych zakodowanych kategorycznie z innego źródła możesz skorzystać z alternatywnego konstruktora `from_codes`:

```
In [224]: categories = ['foo', 'bar', 'baz']

In [225]: codes = [0, 1, 2, 0, 0, 1]

In [226]: my_cats_2 = pd.Categorical.from_codes(codes, categories)

In [227]: my_cats_2
Out[227]:
[foo, bar, baz, foo, foo, bar]
Categories (3, object): [foo, bar, baz]
```

Jeśli kolejność kategorii nie zostanie określona w sposób jawny, to podczas konwersji nie przyjmuje się żadnego konkretnego sposobu sortowania kategorii. W związku z tym kolejność elementów tablicy `categories` zależy od kolejności danych wejściowych. Podczas korzystania z `from_codes` lub innego konstruktora możesz określić konieczność ustawienia kategorii w sposób uporządkowany:

```
In [228]: ordered_cat = pd.Categorical.from_codes(codes, categories,
   ....:                                          ordered=True)

In [229]: ordered_cat
Out[229]:
[foo, bar, baz, foo, foo, bar]
Categories (3, object): [foo < bar < baz]
```

Wygenerowany komunikat `[foo < bar < baz]` informuje o tym, że element `'foo'` znajduje się przed elementem `'bar'` itd. Kolejność instancji obiektu typu `Categorical` można określić później za pomocą metody `as_ordered`:

```
In [230]: my_cats_2.as_ordered()
Out[230]:
[foo, bar, baz, foo, foo, bar]
Categories (3, object): [foo < bar < baz]
```

Dane kategoryczne nie muszą być łańcuchami (mimo że we wszystkich przytoczonych przeze mnie przykładach są one właśnie łańcuchami). Tablica kategoryczna może zawierać dowolne wartości typu niemodyfikowalnego.

Obliczenia na obiektach typu Categorical

Ogólnie rzecz biorąc, obiekty typu `Categorical` i ich odpowiedniki pozbawione kodowania kategorii działają tak samo. Niektóre funkcje pakietu pandas działają sprawniej z obiektami kategorycznymi (dotyczy do np. funkcji `groupby`). Niektóre funkcje mogą również korzystać z flagi `ordered`.

Przyjrzyjmy się przykładowi losowych danych numerycznych przetwarzanych za pomocą funkcji tworzącej koszyki danych — `pandas.qcut`. W wyniku zaprezentowanej operacji zwrócony zostanie obiekt `pandas.Categorical`. W zaprezentowanych wcześniej fragmentach kodu korzystałem z funkcji `pandas.cut`, ale nie opisywałem szczegółów działania kategorii:

```
In [231]: rng = np.random.default_rng(seed=12345)

In [232]: draws = rng.standard_normal(1000)

In [233]: draws[:5]
Out[233]: array([-1.4238, 1.2637, -0.8707, -0.2592, -0.0753])
```

Podzielmy dane na koszyki określające kwartyle i obliczmy kilka parametrów statystycznych:

```
In [234]: bins = pd.qcut(draws, 4)

In [235]: bins
Out[235]:
[(-3.121, -0.675], (0.687, 3.211], (-3.121, -0.675], (-0.675, 0.0134], (-0.675, 0.0134],
...,
(0.0134, 0.687], (0.0134, 0.687], (-0.675, 0.0134], (0.0134, 0.687], (-0.675, 0.0134]]
Length: 1000
Categories (4, interval[float64, right]): [(-3.121, -0.675] < (-0.675, 0.0134] <
(0.0134, 0.687] < (0.687, 3.211]]
```

Dokładne granice kwartyli są przydatne, ale w raportach lepiej jest używać ich nazw. Można w tym celu użyć argumentu `labels` metody `qcut`:

```
In [236]: bins = pd.qcut(draws, 4, labels=['Q1', 'Q2', 'Q3', 'Q4'])

In [237]: bins
Out[237]:
['Q1', 'Q4', 'Q1', 'Q2', 'Q2', ..., 'Q3', 'Q3', 'Q2', 'Q3', 'Q2']
Length: 1000
Categories (4, object): ['Q1' < 'Q2' < 'Q3' < 'Q4']

In [238]: bins.codes[:10]
Out[238]: array([0, 3, 0, 1, 1, 0, 0, 2, 2, 0], dtype=int8)
```

Oznaczone etykietami kategorie `bins` nie zawierają informacji o krawędziach koszyków danych, więc w celu obliczenia parametrów statystycznych skorzystamy z funkcji `groupby`:

```
In [239]: bins = pd.Series(bins, name='quartile')

In [240]: results = (pd.Series(draws)
   ....:             .groupby(bins)
   ....:             .agg(['count', 'min', 'max'])
   ....:             .reset_index())

In [241]: results
Out[241]:
  quartile  count       min       max
0       Q1    250 -3.119609 -0.678494
1       Q2    250 -0.673305  0.008009
2       Q3    250  0.018753  0.686183
3       Q4    250  0.688282  3.211418
```

Kolumna `'quartile'` obiektu wyjściowego zawiera informacje o kategoriach koszyków, w tym między innymi określa ich kolejność:

```
In [242]: results['quartile']
Out[242]:
0  Q1
1  Q2
2  Q3
3  Q4
Name: quartile, dtype: category
Categories (4, object): ['Q1' < 'Q2' < 'Q3' < 'Q4']
```

Obiekty kategoryczne a zwiększenie wydajności

Na początku tego podrozdziału wspomniałem, że typy kategoryczne poprawiają wydajność operacji i zajmują mniej pamięci. Przeanalizujmy więc kilka przykładów. Przyjrzyjmy się obiektowi `Series` zawierającemu 10 milionów elementów należących do małej liczby unikalnych kategorii:

```
In [243]: N = 10_000_000

In [244]: labels = pd.Series(['foo', 'bar', 'baz', 'qux'] * (N // 4))
```

Teraz dokonam konwersji etykiet (`labels`) na dane kategoryczne:

```
In [245]: categories = labels.astype('category')
```

Obiekt `labels` zajmuje o wiele więcej miejsca w pamięci od obiektu `categories`:

```
In [246]: labels.memory_usage(deep=True)
Out[246]: 600000128

In [247]: categories.memory_usage(deep=True)
Out[247]: 10000540
```

Konwersja na dane kategoryczne wymaga również pewnych kosztów, ale są one ponoszone jednorazowo:

```
In [248]: %time _ = labels.astype('category')
CPU times: user 469 ms, sys: 106 ms, total: 574 ms
Wall time: 577 ms
```

Operacje grupowania mogą zostać znacznie przyśpieszone w wyniku zastosowania danych kategorycznych, ponieważ algorytm tego typu operacji korzysta z tablic zawierających kody w postaci liczb zastępujących łańcuchy znaków. Porównajmy wydajność metody `value_counts`, która wewnętrznie korzysta z algorytmu funkcji `groupby`:

```
In [249]: %timeit labels.value_counts()
840 ms +- 10.9 ms per loop (mean +- std. dev. of 7 runs, 1 loop each)

In [250]: %timeit categories.value_counts()
30.1 ms +- 549 us per loop (mean +- std. dev. of 7 runs, 10 loops each)
```

Metody obiektu kategorycznego

Obiekt typu `Series` zawierający dane kategoryczne dysponuje kilkoma specjalnymi metodami podobnymi do specjalnych metod `Series.str` przeznaczonych bo obsługi łańcuchów znaków. Metody te umożliwiają również wygodne uzyskanie dostępu do kategorii i kodów. Przyjrzyj się następującemu przykładowi obiektu typu `Series`:

```
In [251]: s = pd.Series(['a', 'b', 'c', 'd'] * 2)

In [252]: cat_s = s.astype('category')

In [253]: cat_s
Out[253]:
0  a
1  b
2  c
3  d
4  a
5  b
6  c
7  d
dtype: category
Categories (4, object): [a, b, c, d]
```

Specjalny *atrybut* `cat` umożliwia uzyskanie dostępu do metod kategorycznych:

```
In [254]: cat_s.cat.codes
Out[254]:
0  0
1  1
2  2
3  3
4  0
5  1
6  2
7  3
dtype: int8

In [255]: cat_s.cat.categories
Out[255]: Index(['a', 'b', 'c', 'd'], dtype='object')
```

Załóżmy, że wiemy o tym, że rzeczywisty zbiór kategorii tych danych wykracza poza cztery zaobserwowane wartości. W celu zmodyfikowania zbioru kategorii możemy skorzystać z metody `set_categories`:

```
In [256]: actual_categories = ['a', 'b', 'c', 'd', 'e']

In [257]: cat_s2 = cat_s.cat.set_categories(actual_categories)

In [258]: cat_s2
Out[258]:
0  a
1  b
2  c
3  d
4  a
5  b
6  c
7  d
dtype: category
Categories (5, object): ['a', 'b', 'c', 'd', 'e']
```

Dane wydają się niezmodyfikowane, ale nowe kategorie zostaną odzwierciedlone w korzystających z nich operacjach. Funkcja `value_counts` jest przykładem funkcji biorącej pod uwagę obecne kategorie:

```
In [259]: cat_s.value_counts()
Out[259]:
d  2
c  2
```

```
b  2
a  2
dtype: int64

In [260]: cat_s2.value_counts()
Out[260]:
d  2
c  2
b  2
a  2
e  0
dtype: int64
```

W przypadku dużych zbiorów danych konwersja na dane kategoryczne może być wygodnym narzędziem pozwalającym na zmniejszenie zapotrzebowania na pamięć i przyśpieszenie przetwarzania danych. Po przefiltrowaniu dużego obiektu typu `DataFrame` lub `Series` wiele kategorii może nie wystąpić w danych. W celu rozwiązania tego problemu poprzez usunięcie kategorii, do których nie należy żadna obserwacja, możemy skorzystać z metody `remove_unused_categories`:

```
In [261]: cat_s3 = cat_s[cat_s.isin(['a', 'b'])]

In [262]: cat_s3
Out[262]:
0  a
1  b
4  a
5  b
dtype: category
Categories (4, object): ['a', 'b', 'c', 'd']

In [263]: cat_s3.cat.remove_unused_categories()
Out[263]:
0  a
1  b
4  a
5  b
dtype: category
Categories (2, object): ['a', 'b']
```

Listę obsługiwanych metod kategorycznych znajdziesz w tabeli 7.7.

Tabela 7.7. Metody kategoryczne obiektu Series obsługiwane przez pakiet pandas

Metoda	Opis
`add_categories`	Dołącza nowe (nieużywane) kategorie do końca listy istniejących kategorii.
`as_ordered`	Sprawia, że kategorie są uporządkowane.
`as_unordered`	Sprawia, że kategorie są nieuporządkowane.
`remove_categories`	Usuwa kategorie, przypisując wszelkim usuniętym elementom wartość `null`.
`remove_unused_categories`	Usuwa wszelkie wartości kategorii, które nie pojawiają się w danych.
`rename_categories`	Zastępuje kategorie wskazanym zestawem nowych nazw kategorii; zmiana numerów kategorii nie jest możliwa.
`reorder_categories`	Działa jak metoda `rename_categories`, ale może dodatkowo zmodyfikować obiekt wyjściowy w celu uporządkowania kategorii.
`set_categories`	Zastępuje kategorie wskazanym zestawem nowych kategorii; umożliwia dodawanie i usuwanie kategorii.

Tworzenie fikcyjnych zmiennych używanych podczas modelowania

Podczas korzystania z narzędzi statystycznych i przeznaczonych do uczenia maszynowego bardzo często przeprowadza się konwersję danych kategorycznych na **zmienne fikcyjne** (ang. *dummy variable*) — jest to tzw. kodowanie *one hot*. Wymaga ono utworzenia ramki danych zawierającej kolumny dla wszystkich unikalnych kategorii. Kolumny te są wypełniane wartością 1 w przypadku wystąpienia danej kategorii, a wartością 0, gdy dana kategoria nie występuje.

Przyjrzyjmy się jeszcze raz temu przykładowi:

```
In [264]: cat_s = pd.Series(['a', 'b', 'c', 'd'] * 2, dtype='category')
```

Jak wspomniałem wcześniej w tym rozdziale, funkcja `pandas.get_dummies` dokonuje konwersji jednowymiarowych danych kategorycznych na obiekt `DataFrame` zawierający zmienną fikcyjną:

```
In [265]: pd.get_dummies(cat_s)
Out[265]:
   a  b  c  d
0  1  0  0  0
1  0  1  0  0
2  0  0  1  0
3  0  0  0  1
4  1  0  0  0
5  0  1  0  0
6  0  0  1  0
7  0  0  0  1
```

7.6. Podsumowanie

Skuteczne przygotowanie danych może znacznie poprawić produktywność, pozwalając na poświęcenie większej ilości czasu na analizę danych poprzez skrócenie czasu spędzonego na przygotowaniu danych do analizy. Podczas lektury tego rozdziału poznałeś różne narzędzia, ale pamiętaj o tym, że nie są to wszystkie dostępne narzędzia przeznaczone do wstępnej obróbki danych. W kolejnym rozdziale opiszę zagadnienia związane z funkcjami pakietu pandas przeznaczonymi do łączenia i grupowania.

Wes McKinney zaktualizował swoją książkę, aby była podstawowym źródłem informacji o wszystkich zagadnieniach związanych z analizą danych przy użyciu języka Python i biblioteki pandas. Gorąco polecam tę pozycję!

Paul Barry, wykładowca i autor książek

Wprawny analityk danych potrafi z nich uzyskać wiedzę ułatwiającą podejmowanie trafnych decyzji. Od kilku lat można do tego używać nowoczesnych narzędzi Pythona, które zbudowano specjalnie do tego celu. Praca z nimi nie wymaga głębokiej znajomości statystyki czy algebry. Aby cieszyć się uzyskanymi rezultatami, wystarczy się wprawić w stosowaniu kilku pakietów i środowisk Pythona.

Ta książka jest trzecim, starannie zaktualizowanym wydaniem wyczerpującego przewodnika po narzędziach analitycznych Pythona. Uwzględnia Pythona 3.0 i bibliotekę pandas 1.4. Została napisana w przystępny sposób, a poszczególne zagadnienia bogato zilustrowano przykładami, studiami rzeczywistych przypadków i fragmentami kodu. W trakcie lektury nauczysz się korzystać z możliwości oferowanych przez pakiety pandas i NumPy, a także środowiska IPython i Jupyter. Nie zabrakło wskazówek dotyczących używania uniwersalnych narzędzi przeznaczonych do ładowania, czyszczenia, przekształcania i łączenia zbiorów danych. Pozycję docenią analitycy zamierzający zacząć pracę w Pythonie, jak również programiści Pythona, którzy chcą się zająć analizą danych i obliczeniami naukowymi.

Dzięki książce nauczysz się:

- eksplorować dane za pomocą powłoki IPython i środowiska Jupyter
- korzystać z funkcji pakietów NumPy i pandas
- używać pakietu matplotlib do tworzenia czytelnych wizualizacji
- analizować i przetwarzać dane regularnych i nieregularnych szeregów czasowych
- rozwiązywać rzeczywiste problemy analityczne

Wes McKinney

twórca oprogramowania open source, autor projektu pandas i współtwórca Apache Arrow. Członek The Apache Software Foundation, a także PMC Apache Parquet. Obecnie pełni funkcję dyrektora technicznego Voltron Data, gdzie zajmuje się przyspieszonymi technologiami obliczeniowymi opartymi na Apache Arrow.

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 978-83-8322-323-0
9 788383 223230
Cena: 119,00 zł