O'REILLY®

Wydanie II

Python Data Science

Niezbędne narzędzia do pracy z danymi

Helion

Jake VanderPlas

Tytuł oryginału: Python Data Science Handbook: Essential Tools for Working with Data, 2nd Edition

Tłumaczenie: Filip Kamiński

ISBN: 978-83-289-0068-4

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

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

Printed in Poland.

Spis treści

ROZDZIAŁ 23.

Praca z szeregami czasowymi

Początkowo Pandas zaprojektowano z myślą o modelowaniu finansowym, więc jak możesz się spodziewać, zawiera on obszerny zbiór narzędzi do pracy z datami, godzinami i danymi indeksowanymi czasowo. Dane dotyczące czasu występują w kilku wariantach, które omówię w tym rozdziale:

Znaczniki czasu

Określone momenty w czasie (np. 4 lipca 2021 r., godz. 7:00).

Przedziały czasu i okresy

Przedział pomiędzy określonym punktem początkowym i końcowym; na przykład czerwiec 2021 r. Okresy to zazwyczaj specjalne przypadki przedziałów, w których każdy przedział ma jednakową długość, a poszczególne przedziały nie zachodzą na siebie (np. 24-godzinne okresy obejmujące dni).

Czasy trwania lub odstępy czasu

Dokładny czas (np. 22,56 sekundy).

W tym rozdziale pokażę Ci, jak pracować z każdym z tych typów daty czy czasu w Pandas. Rozdział ten nie jest w żadnym wypadku kompletnym przewodnikiem po narzędziach do pracy z szeregami czasowymi, które są dostępne w Pythonie lub Pandas. Jest to jedynie ogólny przegląd tego, w jaki sposób użytkownik Pandas powinien podejść do pracy z danymi czasowymi. Zacznę od krótkiego omówienia narzędzi do obsługi dat i godzin dostępnych w Pythonie. Następnie przejdę do bardziej szczegółowego omówienia narzędzi z Pandas. Na koniec pokażę Ci kilka krótkich przykładów pracy z szeregami czasowymi w Pandas.

Daty i godziny w Pythonie

Python oferuje wiele sposobów reprezentacji dat i godzin oraz odstępów i przedziałów czasu. Podczas gdy narzędzia do pracy z szeregami czasowymi dostępne w Pandas zazwyczaj najlepiej sprawdzają się w analizie danych, warto przenalizować ich związek z innymi narzędziami wykorzystywanymi w Pythonie.

Daty i godziny w Pythonie — datetime i dateutil

Wbudowany w Pythona moduł *datetime* zawiera podstawowe obiekty do pracy z datami i godzinami w tym języku. Moduł ten wraz z modułem *dateutil* możesz wykorzystać do szybkiego wykonania wielu operacji na datach i godzinach. Na przykład do stworzenia daty możesz wykorzystać typ `datetime`:

```
In [1]: from datetime import datetime
        datetime(year=2021, month=7, day=4)
Out[1]: datetime.datetime(2021, 7, 4, 0, 0)
```

Za pomocą modułu `dateutil` możesz przekonwertować daty zapisane w łańcuchach znaków w różnych formatach na obiekty typu `datetime`:

```
In [2]: from dateutil import parser
        date = parser.parse("4th of July, 2021")
        date
Out[2]: datetime.datetime(2021, 7, 4, 0, 0)
```

Gdy masz już obiekt `datetime`, możesz na przykład wyświetlić dzień tygodnia:

```
In [3]: date.strftime('%A')
Out[3]: 'Sunday'
```

W powyższym przykładzie do wyświetlenie dnia tygodnia wykorzystałem jeden ze standardowych kodów formatu (`'%A'`). Więcej na ich temat znajdziesz w dokumentacji pakietu *datetime* (*https://oreil.ly/AGVR9*) w sekcji *strftime* (*https://oreil.ly/bjdsf*). Informacje o innych przydatnych w pracy z datami narzędziach znajdziesz też w dokumentacji pakietu *dateutils* (*https://oreil.ly/Y5Rwd*). Powiązanym z nimi pakietem, którego nazwę warto zapamiętać, jest *pytz* (*https://oreil.ly/DU9Jr*). Pakiet ten zawiera narzędzia do pracy z powodującym najwięcej bólów głowy elementem danych czasowych, jakim jest obecność stref czasowych.

Siła *datetime* i *dateutil* leży w ich elastyczności i łatwej składni. Możesz wykorzystać te obiekty i ich metody, aby z łatwością wykonać prawie każdą operację, która może Cię zainteresować. Narzędzia te nie sprawdzają się wtedy, gdy chcesz pracować z dużymi tablicami dat i godzin. Tak jak tablice NumPy są zoptymalizowaną wersją list liczb zmiennoprzecinkowych, tak samo typowane tablice zakodowanych dat to zoptymalizowane odpowiedniki list obiektów typu `datetime`.

Typowane tablice znaczników czasu — datetime64 z NumPy

Typ `datetime64` dostępny w NumPy pozwala zapisać daty w postaci 64-bitowych liczb całkowitych i tym samym umożliwia kompaktową reprezentację tablic znaczników czasu i ich wydajną obsługę. Stworzenie obiektu typu `datetime64` wymaga podania daty w określonym formacie wejściowym:

```
In [4]: import numpy as np
        date = np.array('2021-07-04', dtype=np.datetime64)
        date
Out[4]: array('2021-07-04', dtype='datetime64[D]')
```

Po zapisaniu dat we właściwej formie możemy wykonać na nich szybkie zwektoryzowane operacje:

```
In [5]: date + np.arange(12)
Out[5]: array(['2021-07-04', '2021-07-05', '2021-07-06', '2021-07-07',
               '2021-07-08', '2021-07-09', '2021-07-10', '2021-07-11',
               '2021-07-12', '2021-07-13', '2021-07-14', '2021-07-15'],
              dtype='datetime64[D]')
```

Ze względu na jednorodność typu w tablicach NumPy operacje tego rodzaju możemy wykonać znacznie szybciej, niż gdybyśmy pracowali bezpośrednio z obiektami `datetime` z Pythona. Różnica staje się widoczna zwłaszcza podczas pracy z dużymi tablicami (wektoryzację operacji na tablicach omówiłem w rozdziale 6.).

Jedną z cech obiektów typu `datetime64` i pokrewnych im obiektów typu `timedelta64` jest to, że wykorzystują one *bazową jednostkę czasu*. Ponieważ obiekt typu `datetime64` jest zapisywany na 64 bitach, maksymalny możliwy do zapisania w nim przedział czasu to 2^{64} razy bazowa jednostka. Innymi słowy, w typie `datetime64` występuje kompromis między *rozdzielczością czasową* a *maksymalnym przedziałem czasu*.

Na przykład, jeśli chcesz uzyskać rozdzielczość 1 nanosekundy, to w typie tym możesz zapisać zakres 2^{64} nanosekund, czyli nieco mniej niż 600 lat. NumPy wywnioskuje rodzaj użytej jednostki na podstawie danych wejściowych; na przykład w poniższym kodzie jednostką bazową jest jeden dzień.

```
In [6]: np.datetime64('2021-07-04')
Out[6]: numpy.datetime64('2021-07-04')
```

Oto znacznik czasu bazujący na minutach:

```
In [7]: np.datetime64('2021-07-04 12:00')
Out[7]: numpy.datetime64('2021-07-04T12:00')
```

Za pomocą jednego z wielu kodów formatu możesz wymusić użycie konkretnej jednostki bazowej. Na przykład w poniższym kodzie wymusiłem użycie czasu opartego na nanosekundach:

```
In [8]: np.datetime64('2021-07-04 12:59:59.50', 'ns')
Out[8]: numpy.datetime64('2021-07-04T12:59:59.500000000')
```

W tabeli 23.1 (pochodzącej z dokumentacji NumPy) znajdziesz listę kodów formatów wraz ze względnymi i bezwzględnymi przedziałami czasu, które można zapisać przy użyciu danej jednostki bazowej.

W przypadku rzeczywistych danych użyteczną wartością domyślną jest `datetime64[ns]`, która pozwala zakodować użyteczny zakres współczesnych dat z odpowiednio dużą precyzją.

Zauważ, że chociaż typ `datetime64` pozwala ominąć niektóre wady wbudowanego w Pythona typu `datetime`, brakuje w nim wielu wygodnych metod i funkcji znanych z `datetime` oraz `dateutil`. Więcej informacji znajdziesz w sekcji na temat typu `datetime64` w dokumentacji NumPy (*https://oreil.ly/XDbck*).

Tabela 23.1. Opis kodów formatów daty i czasu

Kod	Znaczenie	Zakres czasu (względny)	Zakres czasu (bezwzględny)
Y	Rok	± 9,2e18 lat	[9,2e18 p.n.e. – 9,2e18 n.e.]
M	Miesiąc	± 7,6e17 lat	[7,6e17 p.n.e. – 7,6e17 n.e.]
W	Tydzień	± 1,7e17 lat	[1,7e17 p.n.e. – 1,7e17 n.e.]
D	Dzień	± 2,5e16 lat	[2,5e16 p.n.e. – 2,5e16 n.e.]
h	Godzina	± 1,0e15 lat	[1,0e15 p.n.e. – 1,0e15 n.e.]
m	Minuta	± 1,7e13 lat	[1,7e13 p.n.e. – 1,7e13 n.e.]
s	Sekunda	± 2,9e12 lat	[2,9e9 p.n.e. – 2,9e9 n.e.]
ms	Milisekunda	± 2,9e9 lat	[2,9e6 p.n.e. – 2,9e6 n.e.]
us	Mikrosekunda	± 2,9e6 lat	[290301 p.n.e. – 294241 n.e.]
ns	Nanosekunda	± 292 lat	[1678 n.e. – 2262 n.e.]
ps	Pikosekunda	± 106 dni	[1969 n.e. – 1970 n.e.]
fs	Femtosekunda	± 2,6 godzin	[1969 n.e. – 1970 n.e.]
as	Attosekunda	± 9,2 sekund	[1969 n.e. – 1970 n.e.]

Daty i godziny w Pandas — najlepsze elementy z obu światów

Pandas bazuje na wszystkich omówionych wcześniej narzędziach i zawiera obiekt typu `Timestamp`, który łączy w sobie łatwość użycia `datetime` i `dateutil` z wydajnym sposobem zapisu i zwektoryzowanym interfejsem `numpy.datetime64`. Z grupy obiektów typu `Timestamp` Pandas potrafi skonstruować `DatetimeIndex`, który można wykorzystać do indeksowania danych w obiektach typu `Series` lub `DataFrame`.

W poniższym kodzie wykorzystam narzędzia z Pandas do odtworzenia treści poprzednich przykładów. Poniżej pokazano, jak za pomocą Pandas można przekształcić datę zapisaną w łańcuchu znaków w obiekt typu `Timestamp` i jak wykorzystać kody formatów do wyświetlenia dnia tygodnia:

```
In [9]: import pandas as pd
        date = pd.to_datetime("4th of July, 2021")
        date
Out[9]: Timestamp('2021-07-04 00:00:00')

In [10]: date.strftime('%A')
Out[10]: 'Sunday'
```

Dodatkowo bezpośrednio na tym samym obiekcie możemy wykonać zwektoryzowane operacje w stylu NumPy:

```
In [11]: date + pd.to_timedelta(np.arange(12), 'D')
Out[11]: DatetimeIndex(['2021-07-04', '2021-07-05', '2021-07-06', '2021-07-07',
                        '2021-07-08', '2021-07-09', '2021-07-10', '2021-07-11',
                        '2021-07-12', '2021-07-13', '2021-07-14', '2021-07-15'],
                       dtype='datetime64[ns]', freq=None)
```

W następnym podrozdziale przyjrzymy się bliżej przekształcaniu szeregów czasowych za pomocą narzędzi dostępnych w Pandas.

Szeregi czasowe w Pandas — indeksowanie według czasu

Narzędzia do obsługi szeregów czasowych dostępne w Pandas stają się naprawdę przydatne, gdy chcemy indeksować dane według znaczników czasu. Możemy na przykład skonstruować obiekt typu `Series` zawierający dane indeksowane za pomocą czasu:

```
In [12]: index = pd.DatetimeIndex(['2020-07-04', '2020-08-04',
                                   '2021-07-04', '2021-08-04'])
         data = pd.Series([0, 1, 2, 3], index=index)
         data
Out[12]: 2020-07-04    0
         2020-08-04    1
         2021-07-04    2
         2021-08-04    3
         dtype: int64
```

Po umieszczeniu danych w obiekcie typu `Series` możemy go zaindeksować za pomocą dowolnej z metod indeksowania omówionych w poprzednich rozdziałach. W miejsce indeksów wystarczy po prostu wstawić daty:

```
In [13]: data['2020-07-04':'2021-07-04']
Out[13]: 2020-07-04    0
         2020-08-04    1
         2021-07-04    2
         dtype: int64
```

Istnieją również specjalne metody indeksowania dostępne jedynie dla dat, takie jak możliwość przekazania roku w celu uzyskania wycinka zawierającego wszystkie pochodzące z niego dane:

```
In [14]: data['2021']
Out[14]: 2021-07-04    2
         2021-08-04    3
         dtype: int64
```

W dalszej części rozdziału zobaczysz kolejne przykłady użycia dat w roli indeksów, ale najpierw przyjrzyjmy się bliżej dostępnym w Pandas strukturom danych do przechowywania szeregów czasowych.

Struktury danych do przechowywania szeregów czasowych w Pandas

W tym podrozdziale przedstawię podstawowe struktury danych do pracy z szeregami czasowymi dostępne w Pandas:

- Do przechowywania *znaczników czasu* można wykorzystać typ `Timestamp`. Jak już wspomniałem, jest to zamiennik natywnego typu `datetime` z Pythona oparty na bardziej wydajnym typie `numpy.datetime64`. Powiązany z nim typ indeksu to `DatetimeIndex`.
- Dla *przedziałów czasowych* Pandas zawiera typ `Period`. Pozwala on zapisać interwał o stałej częstotliwości i jest oparty na `numpy.datetime64`. Powiązany z nim typ indeksu to `PeriodIndex`.
- Do przechowywania *czasów trwania lub odstępów czasu* dostępny jest typ `Timedelta`. Jest on wydajniejszym zamiennikiem natywnego typu `datetime.timedelta` z Pythona, bazującym na typie `numpy.timedelta64`. Powiązany z nim typ indeksu to `TimedeltaIndex`.

Najbardziej podstawowymi z tych obiektów są obiekty typów `Timestamp` i `DatetimeIndex`. Chociaż można je utworzyć za pomocą konstruktorów, częściej wykorzystuje się do tego celu funkcję `pd.to_datetime`, która potrafi sparsować dane zapisane w wielu formatach. Przekazanie do `pd.to_datetime` pojedynczej daty daje w wyniku obiekt typu `Timestamp`, a przekazanie serii dat — obiekt typu `DatetimeIndex`:

```
In [15]: dates = pd.to_datetime([datetime(2021, 7, 3), '4th of July, 2021',
                                 '2021-Jul-6', '07-07-2021', '20210708'])
         dates
Out[15]: DatetimeIndex(['2021-07-03', '2021-07-04', '2021-07-06', '2021-07-07',
                        '2021-07-08'],
                       dtype='datetime64[ns]', freq=None)
```

Dowolny obiekt typu `DatetimeIndex` można przekonwertować na `PeriodIndex` za pomocą funkcji `to_period`, której należy przekazać kod częstotliwości. W poniższym przykładzie wykorzystałem kod `'D'`, aby wskazać, że interesuje mnie częstotliwość dzienna:

```
In [16]: dates.to_period('D')
Out[16]: PeriodIndex(['2021-07-03', '2021-07-04', '2021-07-06', '2021-07-07',
                      '2021-07-08'],
                     dtype='period[D]')
```

Obiekt typu `TimedeltaIndex` powstaje na przykład, gdy odejmujemy od siebie dwie daty:

```
In [17]: dates - dates[0]
Out[17]: TimedeltaIndex(['0 days', '1 days', '3 days', '4 days', '5 days'],
          > dtype='timedelta64[ns]', freq=None)
```

Regularne sekwencje dat — pd.date_range

Pandas zawiera kilka metod ułatwiających tworzenie sekwencji regularnych dat. Są to: `pd.date_range` dla znaczników czasu, `pd.period_range` dla okresów i `pd.timedelta_range` dla odstępów czasu. Wiesz już, że funkcje `range` z Pythona oraz `np.arange` z NumPy przyjmują punkt początkowy, punkt końcowy i opcjonalnie rozmiar kroku oraz zwracają sekwencję wartości. Podobnie funkcja `pd.date_range` przyjmuje datę początkową, datę końcową i opcjonalny kod częstotliwości oraz zwraca regularną sekwencję dat:

```
In [18]: pd.date_range('2015-07-03', '2015-07-10')
Out[18]: DatetimeIndex(['2015-07-03', '2015-07-04', '2015-07-05', '2015-07-06',
                        '2015-07-07', '2015-07-08', '2015-07-09', '2015-07-10'],
                       dtype='datetime64[ns]', freq='D')
```

Zakres dat można określić nie tylko za pomocą punktu początkowego i końcowego, ale również za pomocą punktu początkowego i liczby okresów:

```
In [19]: pd.date_range('2015-07-03', periods=8)
Out[19]: DatetimeIndex(['2015-07-03', '2015-07-04', '2015-07-05', '2015-07-06',
                        '2015-07-07', '2015-07-08', '2015-07-09', '2015-07-10'],
                       dtype='datetime64[ns]', freq='D')
```

Odstępy można modyfikować za pomocą argumentu `freq`, który domyślnie przyjmuje wartość `'D'`. W poniższym kodzie tworzę zakres godzinowych znaczników czasu:

```
In [20]: pd.date_range('2015-07-03', periods=8, freq='H')
Out[20]: DatetimeIndex(['2015-07-03 00:00:00', '2015-07-03 01:00:00',
                        '2015-07-03 02:00:00', '2015-07-03 03:00:00',
                        '2015-07-03 04:00:00', '2015-07-03 05:00:00',
                        '2015-07-03 06:00:00', '2015-07-03 07:00:00'],
                       dtype='datetime64[ns]', freq='H')
```

Do utworzenia regularnych sekwencji wartości typu `Period` lub `Timedelta` można wykorzystać analogiczne funkcje `pd.period_range` i `pd.timedelta_range`. Oto przykład stworzenia miesięcznych okresów:

```
In [21]: pd.period_range('2015-07', periods=8, freq='M')
Out[21]: PeriodIndex(['2015-07', '2015-08', '2015-09',
                      '2015-10', '2015-11', '2015-12',
                      '2016-01', '2016-02'],
                     dtype='period[M]')
```

oraz sekwencja kolejnych czasów trwania różniących się o godzinę:

```
In [22]: pd.timedelta_range(0, periods=6, freq='H')
Out[22]: TimedeltaIndex(['0 days 00:00:00', '0 days 01:00:00', '0 days 02:00:00',
                         '0 days 03:00:00', '0 days 04:00:00', '0 days 05:00:00'],
                        dtype='timedelta64[ns]', freq='H')
```

Zrozumienie tych przykładów wymaga poznania kodów częstotliwości Pandas, które przedstawię w kolejnym podrozdziale.

Częstotliwości i przesunięcia

Podstawowym elementem niezbędnym w pracy z narzędziami do obsługi szeregów czasowych w Pandas są koncepcje **częstotliwości** (ang. *frequency*) i **przesunięcia** (ang. *date offset*). W tabeli 23.2 podsumowano podstawowe kody częstotliwości. Kody te, tak jak kody `'D'` (dzień) i `'H'` (godzina) z poprzednich przykładów, pozwalają określić interesujące nas odstępy w czasie.

Tabela 23.2. Lista kodów częstotliwości dostępnych w Pandas

Kod	Opis	Kod	Opis
D	Rok kalendarzowy	B	Dzień roboczy
W	Tydzień		
M	Koniec miesiąca	BM	Koniec miesiąca obrotowego
Q	Koniec kwartału	BQ	Koniec kwartału obrotowego
A	Koniec roku	BA	Koniec roku obrotowego
H	Godziny	BH	Godziny robocze
T	Minuty		
S	Sekundy		
L	Milisekundy		
U	Mikrosekundy		
N	Nanosekundy		

Miesięczne, kwartalne i roczne częstotliwości reprezentują końce danego okresu. Dodanie sufiksu `S` do dowolnego z nich spowoduje odniesienie się do ich początków (tabela 23.3).

Tabela 23.3. Lista kodów częstotliwości rozpoczynających się od początku danej jednostki

Kod	Opis	Kod	Opis
MS	Początek miesiąca	BMS	Początek miesiąca obrotowego
QS	Początek kwartału	BQS	Początek kwartału obrotowego
AS	Początek roku	BAS	Początek roku obrotowego

Dodatkowo możesz zmienić miesiąc używany do oznaczania dowolnego kodu kwartalnego lub rocznego, dodając do niego trzyliterowy sufiks zawierający kod miesiąca:

- `Q-JAN`, `BQ-FEB`, `QS-MAR`, `BQS-APR` itp.
- `A-JAN`, `BA-FEB`, `AS-MAR`, `BAS-APR` itp.

W ten sam sposób możesz zmienić punkt podziału częstotliwości tygodniowej, dodając do litery `W` trzyliterowy kod dnia tygodnia, na przykład `W-SUN`, `W-MON`, `W-TUE`, `W-WED` itp.

Ponadto kody można łączyć z liczbami, aby określić inne częstotliwości. Na przykład, aby uzyskać częstotliwość 2 godzin i 30 minut, możesz połączyć ze sobą kody reprezentujące godziny (`H`) i minuty (`T`):

```
In [23]: pd.timedelta_range(0, periods=6, freq="2H30T")
Out[23]: TimedeltaIndex(['0 days 00:00:00', '0 days 02:30:00', '0 days 05:00:00',
                         '0 days 07:30:00', '0 days 10:00:00', '0 days 12:30:00'],
                        dtype='timedelta64[ns]', freq='150T')
```

Wszystkie te krótkie kody odnoszą się do konkretnych przypadków przesunięcia czasu w szeregach czasowych Pandas, które można znaleźć w module `pd.tseries.offsets`. Na przykład przesunięcie o dzień roboczy można utworzyć w następujący sposób:

```
In [24]: from pandas.tseries.offsets import BDay
         pd.date_range('2015-07-01', periods=6, freq=BDay())
Out[24]: DatetimeIndex(['2015-07-01', '2015-07-02', '2015-07-03', '2015-07-06',
                        '2015-07-07', '2015-07-08'],
                       dtype='datetime64[ns]', freq='B')
```

Więcej informacji na temat częstotliwości i przesunięć znajdziesz w sekcji *DateOffset* dokumentacji Pandas (*https://oreil.ly/J6JHA*).

Ponowne próbkowanie, przesuwanie i okna

Możliwość wykorzystania dat i godzin w roli indeksów do intuicyjnego organizowania i uzyskiwania dostępu do danych jest ważną cechą narzędzi do pracy z szeregami czasowymi dostępnych w Pandas. Pozwala ona wykorzystać ogólne zalety indeksowanych danych (automatyczne wyrównywanie podczas wykonywania operacji, intuicyjny dostęp do danych i wycinków itp.) podczas pracy z danymi czasowymi. Pandas zawiera też kilka innych operacji stworzonych specjalnie z myślą o szeregach czasowych.

W tym podrozdziale przyjrzymy się kilku z nich. W przykładach wykorzystam niektórych dane o cenach akcji. Ponieważ Pandas został stworzony głównie z myślą o analizie danych finansowych, znajdziesz w nim kilka bardzo specyficznych narzędzi do tego celu. Na przykład pakiet *pandas-datareader* (możesz go zainstalować za pomocą polecenia `pip install pandas-datareader`) potrafi importować dane z różnych źródeł dostępnych w sieci. W poniższym kodzie pobieram za jego pomocą historyczne dane na temat cen akcji spółek indeksowanych przez S&P 500:

```
In [25]: from pandas_datareader import data
         import yfinance as yf
         yf.pdr_override()

         sp500 = data.get_data_yahoo('^GSPC', start='2018-01-01', end='2022-01-01')
         sp500.head()
Out[25]:                    High          Low         Open        Close      Volume \
         Date
         2018-01-02  2695.889893  2682.360107  2683.729980  2695.810059  3367250000
         2018-01-03  2714.370117  2697.770020  2697.850098  2713.060059  3538660000
         2018-01-04  2729.290039  2719.070068  2719.310059  2723.989990  3695260000
         2018-01-05  2743.449951  2727.919922  2731.330078  2743.149902  3236620000
         2018-01-08  2748.510010  2737.600098  2742.669922  2747.709961  3242650000

                      Adj Close
         Date
         2018-01-02  2695.810059
         2018-01-03  2713.060059
         2018-01-04  2723.989990
         2018-01-05  2743.149902
         2018-01-08  2747.709961
```

Dla uproszczenia wykorzystam jedynie ceny zamknięcia:

```
In [26]: sp500 = sp500['Close']
```

Ceny można zwizualizować za pomocą metody `plot`, którą należy wywołać po przeprowadzeniu wstępnej konfiguracji Matplotlib (część IV). Otrzymany wykres pokazano na rysunku 23.1.

```
In [27]: %matplotlib inline
         import matplotlib.pyplot as plt
         plt.style.use('seaborn-whitegrid')
         sp500.plot();
         plt.xlabel('Data');
```

Ponowne próbkowanie i zmiana częstotliwości

Podczas pracy z szeregami czasowymi często pojawia się potrzeba ponownego próbkowania danych (ang. *resampling*) z wyższą lub niższą częstotliwością. W Pandas można to zrobić za pomocą metody `resample` lub znacznie prostszej w użyciu metody `asfreq`. Podstawowa różnica pomiędzy nimi polega na tym, że `resample` przeprowadza *agregację danych*, a `asfreq` jedynie ich *selekcję*.

Porównajmy, co zwracają te dwie metody w przypadku zmniejszenia częstotliwości (ang. *downsampling*) próbkowania cen zamknięcia z indeksu S&P 500. W poniższym przykładzie dokonam ponownego próbkowania danych na końcu roku obrotowego. Wyniki pokazano na rysunku 23.2.

```
In [28]: sp500.plot(alpha=0.5, style='-')
         sp500.resample('BA').mean().plot(style=':')
         sp500.asfreq('BA').plot(style='--');
         plt.legend(['dane wejściowe', 'metoda resample', 'metoda asfreq'],
           loc='upper left');
         plt.xlabel('Data');
```

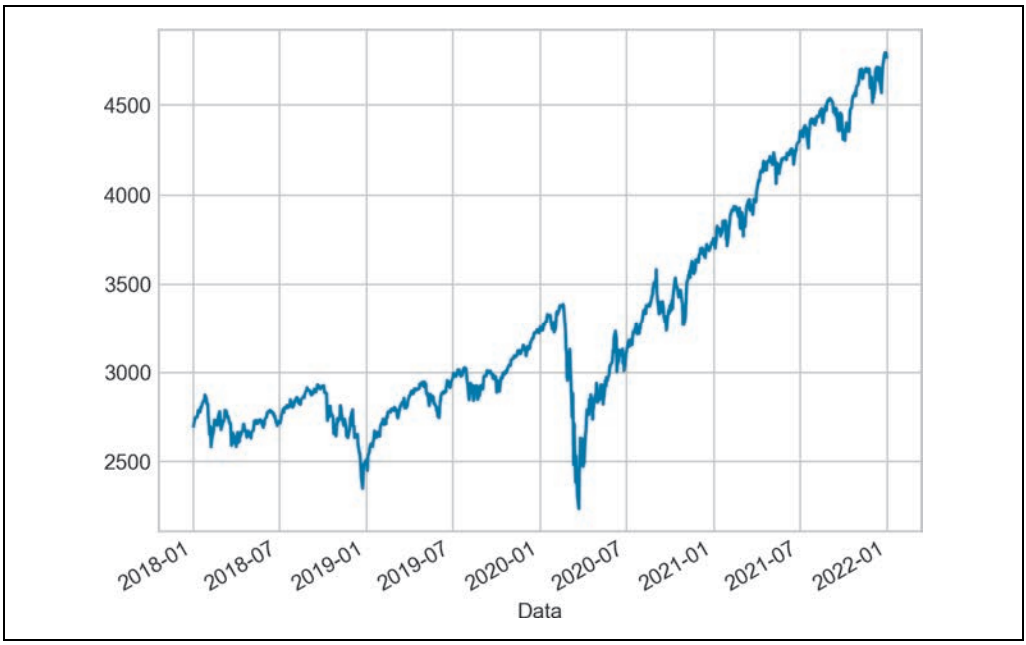

Rysunek 23.1. Ceny zamknięcia S&P500 w czasie

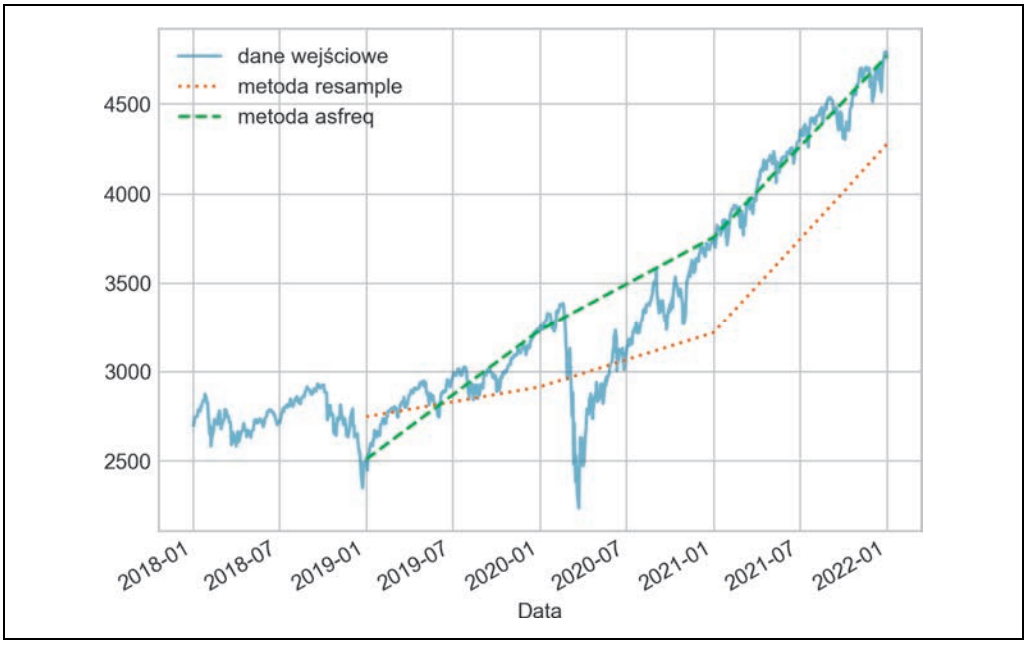

Rysunek 23.2. Ponowne próbkowanie cen zamknięcia S&P500

Zwróć uwagę na różnicę w wyniku. Metoda `resample` umieściła w każdym punkcie *średnią cenę z poprzedniego roku*, natomiast `asfreq` *cenę z końca roku*.

W przypadku zwiększania częstotliwości (ang. *upsampling*) `resample` i `asfreq` działają podobnie, ale `resample` ma więcej opcji. W tym przypadku w nowo powstałych punktach danych obie metody domyślnie umieszczają wartości typu *null*. Tak jak `pd.fillna` (omówiona w rozdziale 16.), `asfreq` również przyjmuje argument `method`, który pozwala określić sposób tworzenia nowych wartości. W poniższym przykładzie przeprowadzę ponowne próbkowanie danych z częstotliwością dzienną (tj. z uwzględnieniem weekendów, oryginalne dane zawierają jedynie ceny z dni roboczych). Wyniki tej operacji pokazano na rysunku 23.3.

```
In[29]: import locale
        locale.setlocale(locale.LC_TIME, "pl_PL")

        fig, ax = plt.subplots(2, sharex=True)
        data = sp500.iloc[:20]

        data.asfreq('D').plot(ax=ax[0], marker='o')

        data.asfreq('D', method='bfill').plot(ax=ax[1], style='-o')
        data.asfreq('D', method='ffill').plot(ax=ax[1], style='--o')
        ax[1].legend(["wypełnianie wstecz", "wypełnianie w przód"]);
        plt.xlabel('Data');
```

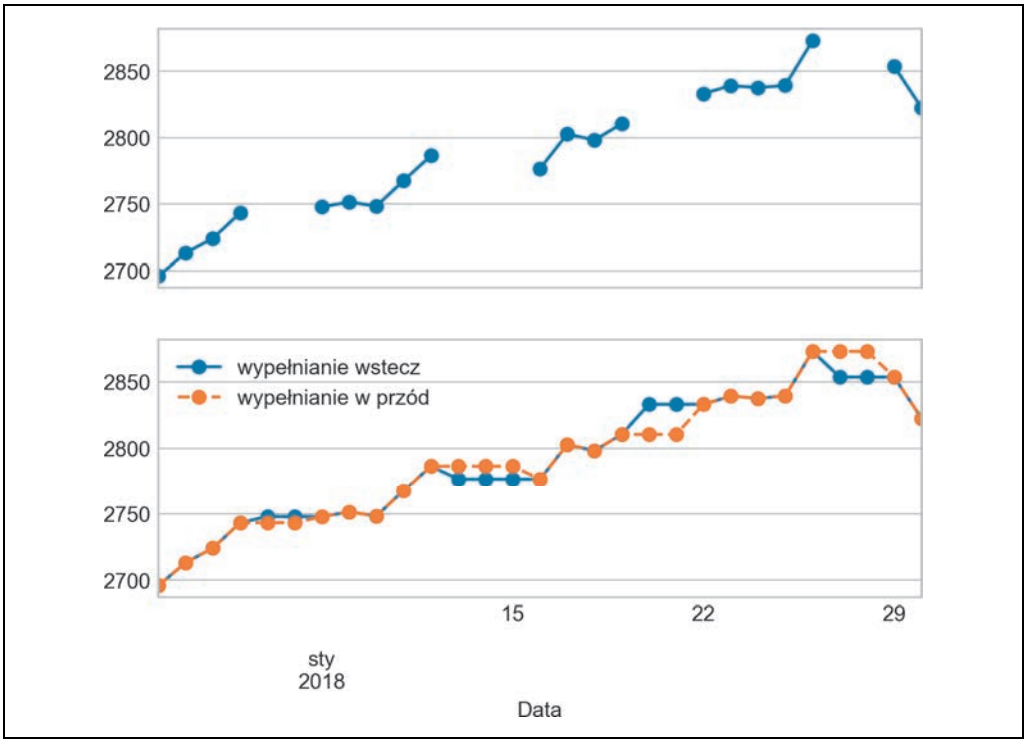

Rysunek 23.3. Interpolacja z użyciem metody wypełniania wstecz oraz wypełniania w przód

Ponieważ dane na temat indeksu S&P 500 zawierają jedynie ceny w dniach roboczych, pierwszy wykres z rysunku 23.3 zawiera przerwy reprezentujące braki cen w innych dniach. Na dolnym wykresie pokazano różnice między dwiema strategiami uzupełniania braków: wypełnianiem metodą w przód oraz wstecz.

Przesunięcia w czasie

Inną typową dla szeregów czasowych operacją jest przesuwanie danych w czasie. W Pandas służy do tego metoda `shift`, która pozwala przesunąć dane w czasie o określoną liczbę wpisów. W przypadku szeregów czasowych próbkowanych z równomierną częstotliwością metoda ta pozwala na zbadanie trendów w czasie.

W poniższym przykładzie ponownie próbkuję dane z częstotliwością jednego dnia i przesuwam je o 364 dni, aby obliczyć roczny zwrot z inwestycji na S&P 500 w czasie (wyniki pokazano na rysunku 23.4).

```
In [30]: sp500 = sp500.asfreq('D', method='pad')

         ROI = 100 * (sp500.shift(-365) - sp500) / sp500
         ROI.plot()
         plt.ylabel('% zwrot z inwestycji po roku');
         plt.xlabel('Data');
```

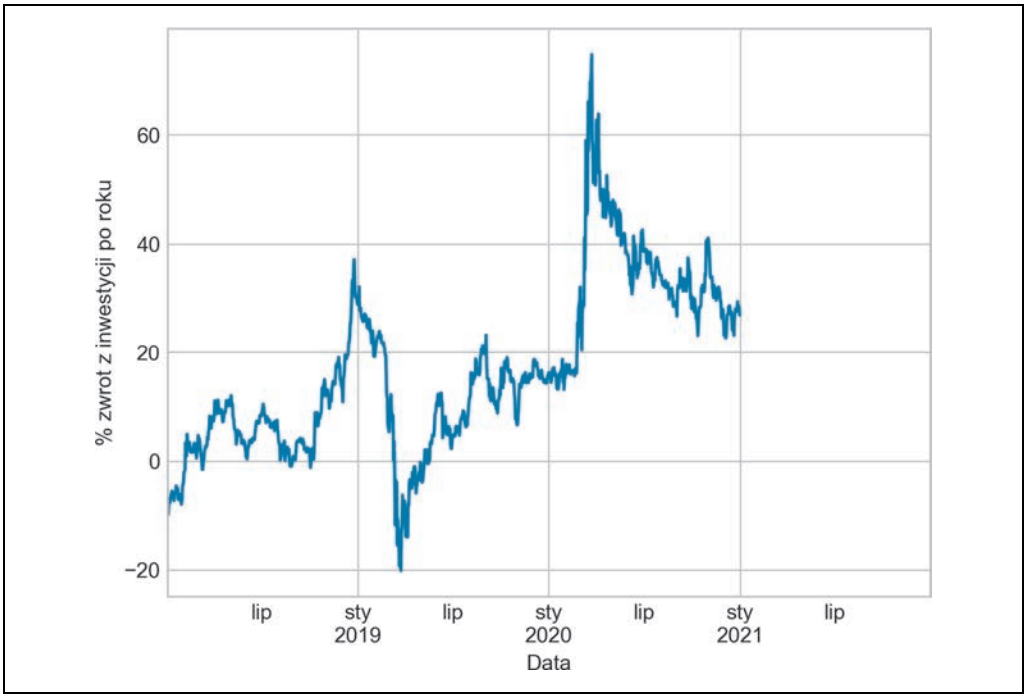

Rysunek 23.4. Zwrot z inwestycji po roku

Najgorszy roczny zwrot charakteryzuje akcje zakupione w okolicach marca 2019 r. Jest to związane z krachem spowodowanym pandemią koronawirusa, która rozpoczęła się dokładnie rok później. Jak można się spodziewać, najwyższy roczny zwrot dotyczył akcji kupionych w marcu 2020 r. Osoby, które je wtedy tanio kupiły, wykazały się dużą dalekowzrocznością lub miały po prostu szczęście.

Ruchome okna

Obliczanie statystyk kroczących jest trzecim rodzajem operacji specyficznych dla szeregów czasowych, które znajdziemy w Pandas. Statystyki te można obliczyć za pomocą atrybutu `rolling` obiektów typu `Series` i `DataFrame`. Atrybut ten zwraca widok podobny do tego, który widzieliśmy w przypadku operacji grupowania (rozdział 20.). Na tym widoku można wywołać wiele typowych funkcji agregujących.

Możemy na przykład przeanalizować roczną średnią kroczącą i odchylenie standardowe cen akcji (rysunek 23.5).

```
In [31]: rolling = sp500.rolling(365, center=True)

         data = pd.DataFrame({'input': sp500,
                              'roczna średnia ruchoma': rolling.mean(),
                              'roczna mediana ruchoma': rolling.median()})
         ax = data.plot(style=['-', '--', ':'])
         ax.lines[0].set_alpha(0.3)
         plt.xlabel('Data');
```

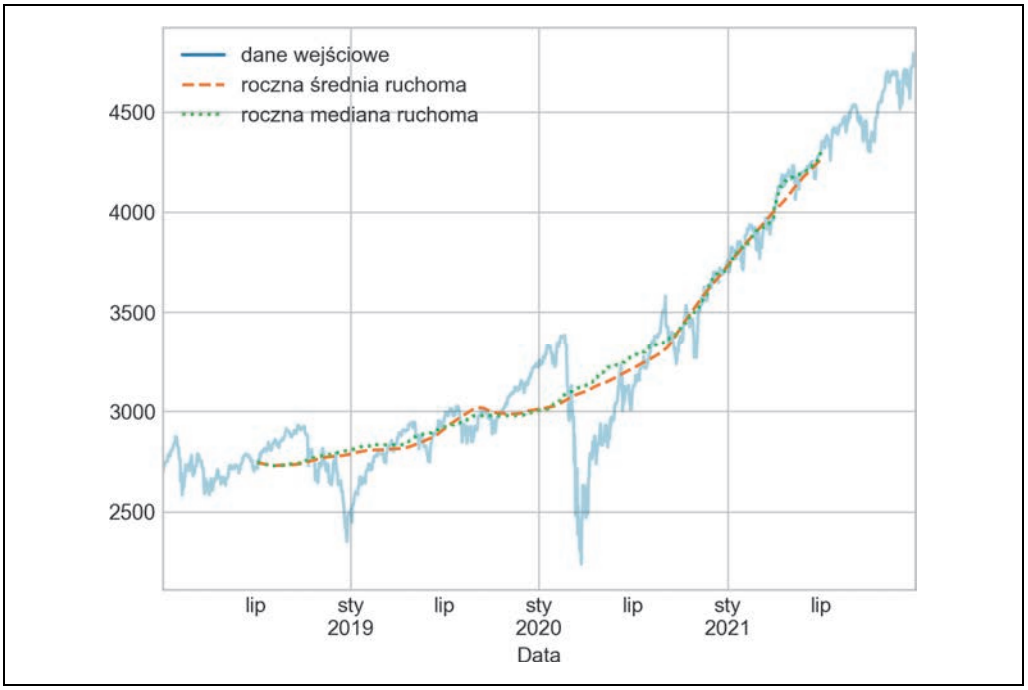

Rysunek 23.5. Statystyki kroczące dla indeksu S&P500

Tak jak w przypadku grupowania, również do przeprowadzenia niestandardowych obliczeń możesz wykorzystać metody `aggregate` i `apply`.

Skąd dowiedzieć się więcej

W tym rozdziale zamieściłem jedynie krótkie podsumowanie niektórych najważniejszych narzędzi Pandas do pracy z szeregami czasowymi. Bardziej szczegółowe omówienie znajdziesz w sekcji *Time series/date functionality* w internetowej dokumentacji Pandas (*https://oreil.ly/uC3pB*).

Innym doskonałym źródłem informacji jest książka *Python w analizie danych. Przetwarzanie danych za pomocą pakietów Pandas i NumPy oraz środowiska IPython. Wydanie II* Wesa McKinneya (Helion). Jest to nieocenione źródło informacji na temat Pandas. W książce tej położono nacisk na wykorzystanie narzędzi do analiz szeregów czasowych w kontekście biznesowym i finansowym. Znajdziesz w niej też dokładniejsze omówienie związanych z nimi szczegółów, w tym kalendarza biznesowego, stref czasowych i pokrewnych zagadnień.

Jak zawsze, możesz również skorzystać z pomocy wbudowanej w IPythona, aby zbadać i wypróbować inne opcje omówionych w tym rozdziale funkcji i metod. Moim zdaniem często jest to najlepszy sposób na poznanie nowego pakietu Pythona.

Przykład: wizualizacja danych o liczbie rowerów w Seattle

W ramach bardziej złożonego przykładu pracy z szeregami czasowymi przyjrzyjmy się liczbie rowerów przejeżdżających przez most Fremont Bridge w Seattle (*https://oreil.ly/6qVBt*). Dane te pochodzą z automatycznego licznika rowerów zainstalowanego pod koniec 2012 roku. Licznik składa się z czujników indukcyjnych zainstalowanych po wschodniej i zachodniej stronie mostu. Godzinowe dane zawierające informacje o liczbie rowerów, które przejechały przez most, można pobrać ze strony *http://data.seattle.gov*. Zbiór danych *Fremont Bridge Bicycle Counter* znajduje się w kategorii *Transportation*.

Plik CSV wykorzystany w tej książce można pobrać w następujący sposób:

```
In [32]: # url = ('https://raw.githubusercontent.com/jakevdp/'
         #       'bicycle-data/main/FremontBridge.csv')
         # !curl -O {url}
```

Po pobraniu danych możemy wykorzystać Pandas do wczytania zawartości pliku CSV do ramki danych. Za pomocą argumentów `read_csv` określam, że daty mają być sparsowane w sposób automatyczny oraz że indeksem ramki ma być kolumna `Date`:

```
In [33]: data = pd.read_csv('data/FremontBridge.csv', index_col='Date', parse_dates=True)
         data.head()
Out[33]:              Fremont Bridge Total   Fremont Bridge East Sidewalk  \
Date
2019-11-01 00:00:00                  12.0                           7.0
2019-11-01 01:00:00                   7.0                           0.0
2019-11-01 02:00:00                   1.0                           0.0
2019-11-01 03:00:00                   6.0                           6.0
2019-11-01 04:00:00                   6.0                           5.0

                     Fremont Bridge West Sidewalk
```

```
Date
2019-11-01 00:00:00                    5.0
2019-11-01 01:00:00                    7.0
2019-11-01 02:00:00                    1.0
2019-11-01 03:00:00                    0.0
2019-11-01 04:00:00                    1.0
```

Dla wygody skracam nazwy kolumn:

```
In [34]: data.columns = ['Total', 'East', 'West']
```

Przyjrzyjmy się teraz statystykom podsumowującym te dane:

```
In [35]: data.dropna().describe()
Out[35]:                Total           East           West
         count  147255.000000  147255.000000  147255.000000
         mean      110.341462      50.077763      60.263699
         std       140.422051      64.634038      87.252147
         min         0.000000       0.000000       0.000000
         25%        14.000000       6.000000       7.000000
         50%        60.000000      28.000000      30.000000
         75%       145.000000      68.000000      74.000000
         max      1097.000000     698.000000     850.000000
```

Wizualizacja danych

Pewien wgląd w ten zbiór danych można uzyskać poprzez wizualizację jego zawartości. Zaczynam od wykreślenia surowych danych (wynik pokazano na rysunku 23.6).

```
In [36]: data.plot()
         plt.ylabel('Liczba rowerów przejeżdżających przez most w ciągu godziny');
         plt.xlabel('Data');
         plt.legend(['Łącznie', 'Ze wschodu', 'Z zachodu']);
```

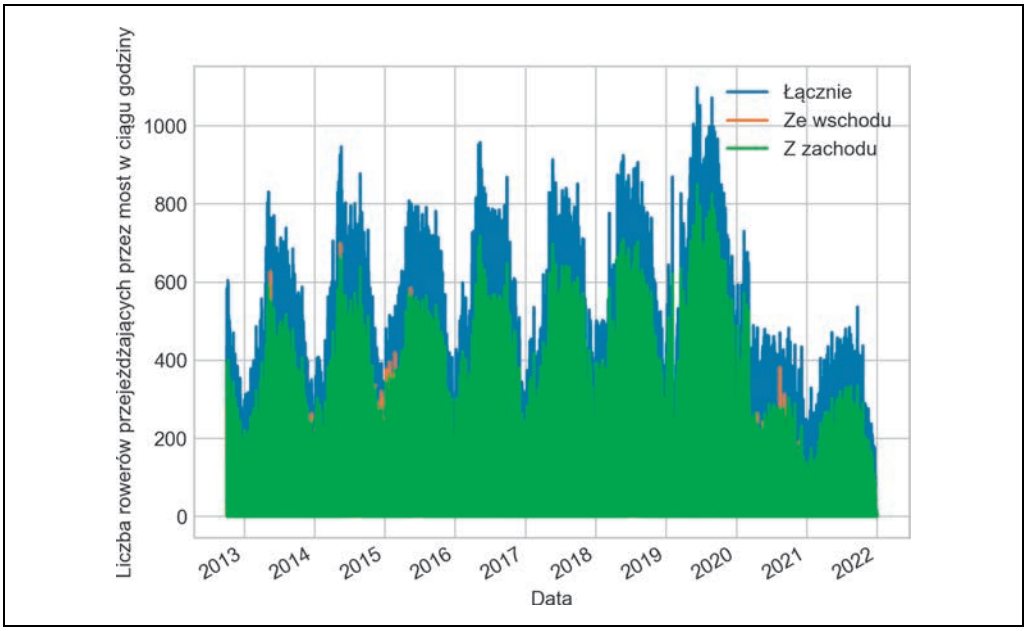

Rysunek 23.6. Godzinowe liczby rowerów przejeżdżających przez most Fremont Bridge w Seattle

Około 150 000 próbek to zbyt dużo, aby dało się im przyjrzeć na wykresie. Więcej informacji na temat tych danych można uzyskać za pomocą ponownego próbkowania z mniejszą częstotliwością. Na poniższym listingu przeprowadzam ponowne próbkowanie z tygodniową częstotliwością (rysunek 23.7).

```
In [37]: weekly = data.resample('W').sum()
         weekly.plot(style=[':', '--', '-'])
         plt.ylabel('Liczba rowerów przejeżdżających przez most w ciągu tygodnia');
         plt.xlabel('Data');
         plt.legend(['Razem', 'Ze wschodu', 'Z zachodu']);
```

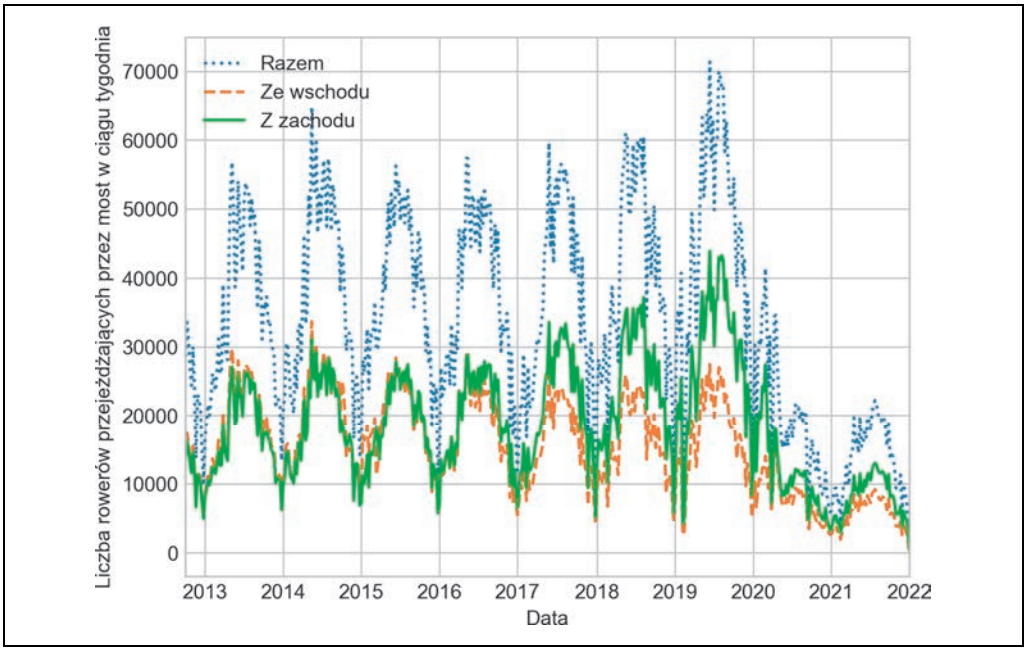

Rysunek 23.7. Tygodniowa liczba przejazdów rowerem przez most Fremont Bridge w Seattle

Ponowne próbowanie ujawniło pewne trendy. Jak można się było spodziewać, ludzie częściej jeżdżą na rowerze latem niż zimą, a liczba rowerów w każdej porze roku zmienia się z tygodnia na tydzień (prawdopodobnie w zależności od pogody; zajrzyj do rozdziału 42., w którym dokładniej przyjrzymy się tej kwestii). Co więcej, od początku 2020 roku w danych widoczny jest wpływ pandemii COVID-19 na zmianę zwyczajów dotyczących dojazdów do pracy.

Inną opcją, którą warto wykorzystać podczas agregacji danych, jest użycie średniej kroczącej. Można ją obliczyć za pomocą funkcji `pd.rolling_mean`. Za pomocą poniższego kodu zbadam 30-dniową średnią kroczącą. Upewniam się też, że okno zostało wyśrodkowane (wyniki pokazano na rysunku 23.8).

```
In [38]: daily = data.resample('D').sum()
         daily.rolling(30, center=True).sum().plot(style=['-', ':', '--'])
         plt.ylabel('Średnia liczba rowerów w ciągu godziny');
         plt.xlabel('Data');
         plt.legend(['Razem', 'Ze wschodu', 'Z zachodu']);
```

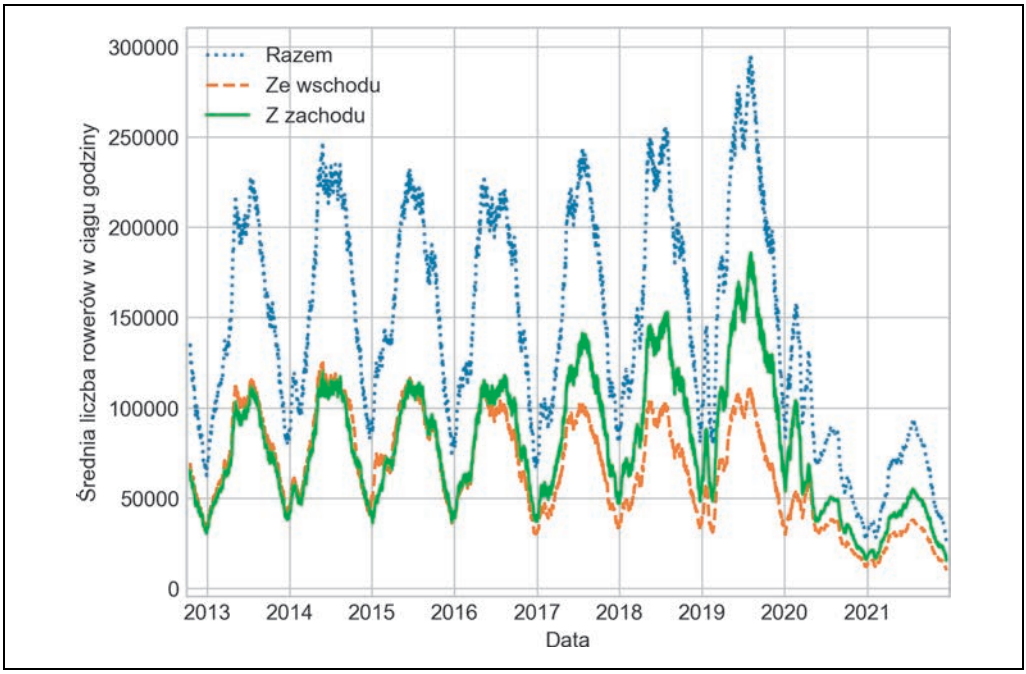

Rysunek 23.8. Średnia krocząca z tygodniowych danych na temat liczby rowerów

„Postrzępiony" kształt wykresu wynika ze sposobu odcinania wartości przez okno. Gładszą wersję średniej kroczącej można uzyskać, korzystając z innego okna, na przykład okna Gaussa (rezultat pokazano na rysunku 23.9). W poniższym kodzie ustalam zarówno szerokość całego okna (50 dni), jak i szerokość okna Gaussa (10 dni):

```
In [39]: daily.rolling(50, center=True,
                       win_type='gaussian').sum(std=10).plot(style=[':', '--', '-']);
         plt.xlabel('Data');
         plt.legend(['Razem', 'Ze wschodu', 'Z zachodu']);
```

Zagłębianie się w dane

Chociaż wygładzona wersja danych pozwala zaobserwować ich ogólny trend, operacja wygładzania eliminuje znaczną część ich struktury. Moglibyśmy na przykład chcieć spojrzeć na średni ruch w funkcji pory dnia. Możemy to zrobić za pomocą funkcji `groupby`, którą omówiłem w rozdziale 20. (wyniki grupowania pokazano na rysunku 23.10).

```
In [40]: by_time = data.groupby(data.index.time).mean()
         hourly_ticks = 4 * 60 * 60 * np.arange(6)
         by_time.plot(xticks=hourly_ticks, style=['-', ':', '--']);
         plt.xlabel('Godzina');
         plt.legend(['Razem', 'Ze wschodu', 'Z zachodu']);
```

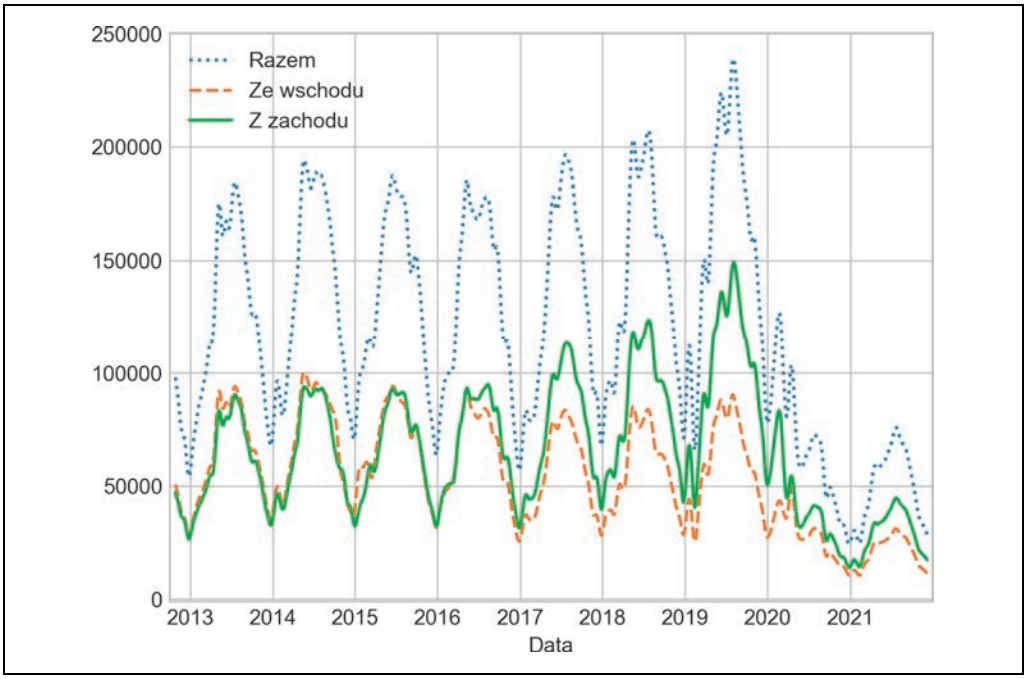

Rysunek 23.9. *Tygodniowe liczby rowerów po zastosowaniu wygładzania za pomocą okna Gaussa*

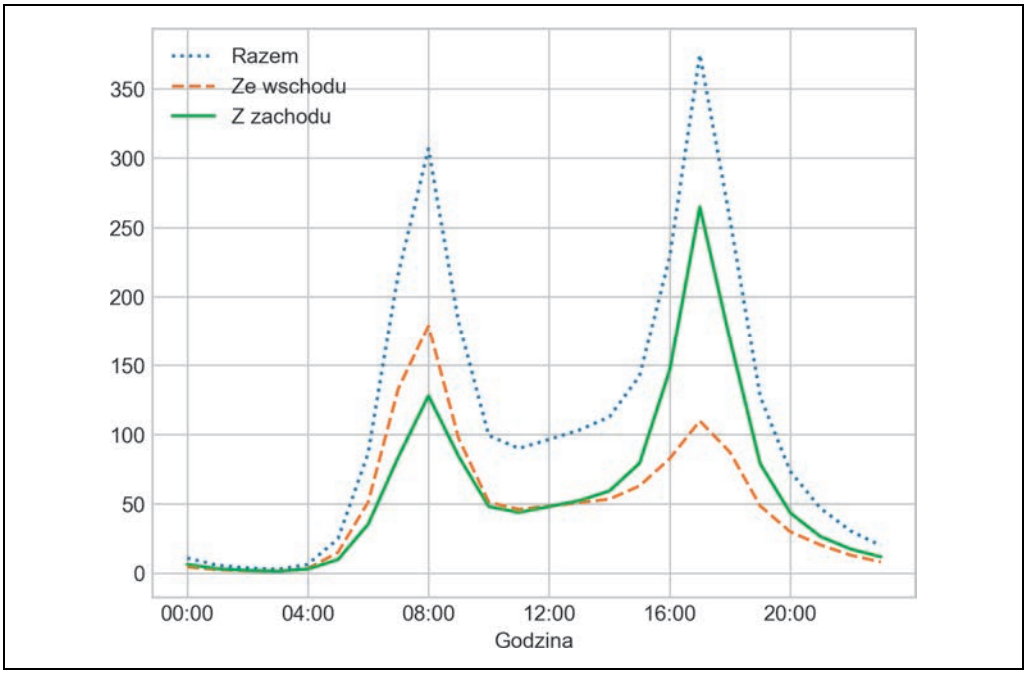

Rysunek 23.10. *Średnia liczba rowerów przejeżdżających przez most o określonej godzinie*

Ruch godzinowy ma silnie bimodalny charakter i osiąga maksima około 8:00 i 17:00. Jest to prawdopodobnie spowodowane dużą liczbą osób dojeżdżających przez most do pracy. Istnieje również komponent kierunkowy. Z danych wynika, że wschodni chodnik jest częściej wykorzystywany podczas porannych dojazdów do pracy, a zachodni podczas popołudniowych powrotów do domu.

Interesująca może być również zmienność w zależności od dnia tygodnia. Do jej zbadania ponownie wykorzystam operację grupowania (wyniki pokazano na rysunku 23.11).

```
In [41]: by_weekday = data.groupby(data.index.dayofweek).mean()
         by_weekday.index = ['pon.', 'wt.', 'śr.', 'czw.',
                             'pt.', 'sob.', 'niedz.']
         by_weekday.plot(style=[':', '--', '-']);
         plt.xlabel('Godzina');
         plt.legend(['Razem', 'Ze wschodu', 'Z zachodu']);
```

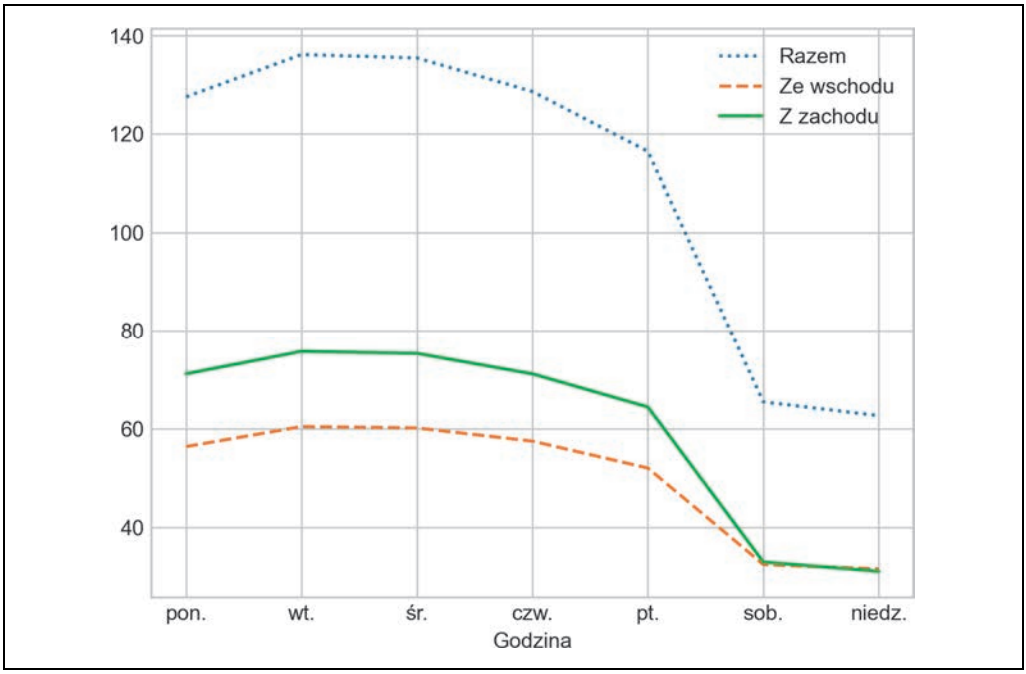

Rysunek 23.11. Średnia dzienna liczba rowerów

Na rysunku widoczne są duże różnice pomiędzy ruchem w dni powszednie i w ciągu weekendu. Od poniedziałku do piątku przez most przejeżdża około dwa razy więcej rowerzystów niż w soboty i niedziele.

Mając to na uwadze, wykorzystam grupowanie do przyjrzenia się trendom godzinowym w dni powszednie oraz w weekendy. Zaczynam od pogrupowania danych według flag reprezentujących weekend i porę dnia:

```
In [42]: weekend = np.where(data.index.weekday < 5, 'Weekday', 'Weekend')
         by_time = data.groupby([weekend, data.index.time]).mean()
```

Następnie wykorzystam niektóre z narzędzi dostępnych w pakiecie Matplotlib (omawiam je w rozdziale 31.) do umieszczenia dwóch wykresów obok siebie. Otrzymany wykres pokazano na rysunku 23.12.

```
In [43]: import matplotlib.pyplot as plt
         fig, ax = plt.subplots(1, 2, figsize=(14, 5))
         by_time.loc['Weekday'].plot(ax=ax[0], title='Dni tygodnia',
                                     xticks=hourly_ticks, style=[':', '--', '-'])
         ax[0].set_xlabel('Godzina');
         ax[0].legend(['Razem', 'Ze wschodu', 'Z zachodu']);

         by_time.loc['Weekend'].plot(ax=ax[1], title='Dni tygodnia',
                                     xticks=hourly_ticks, style=[':', '--', '-']);
         ax[1].set_xlabel('Godzina');
         ax[1].legend(['Razem', 'Ze wschodu', 'Z zachodu']);
```

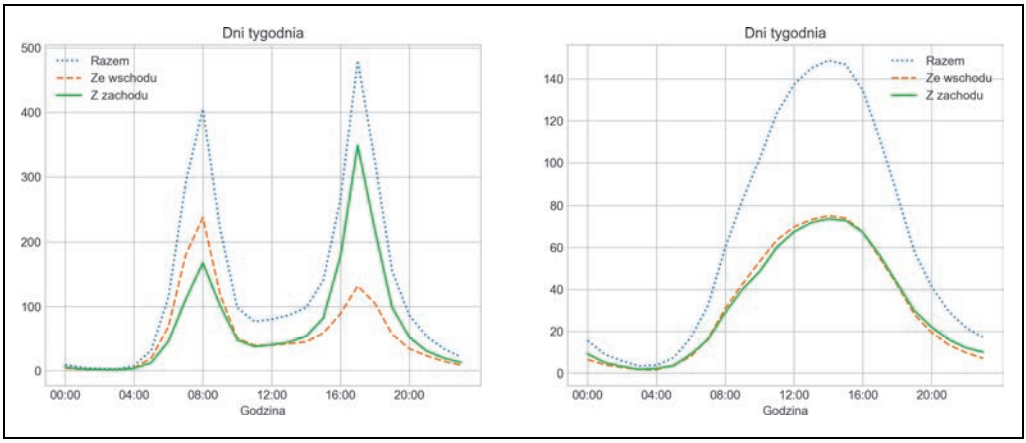

Rysunek 23.12. Średnia godzinowa liczba rowerów w dni powszednie i weekendy

Wyniki pokazują widoczny w dni robocze bimodalny wzorzec dojazdów do pracy oraz jednomodalny wzorzec weekendowy związany z rekreacyjną jazdą na rowerze. Interesująca może być dalsza analiza tych danych i zbadanie wpływu pogody, temperatury, pory roku i innych czynników na wzorce dojazdów do pracy. Więcej informacji na ten temat znajdziesz we wpisie *Is Seattle Really Seeing an Uptick In Cycling?* na moim blogu (*https://oreil.ly/j5oEI*). Do jego przygotowania wykorzystałem podzbiór z tego zbioru danych. Do danych tych powrócę raz jeszcze w rozdziale 42., w którym spróbujemy dopasować do nich model.

Wydobywaj z danych mądre odpowiedzi na trudne pytania!

Python udostępnia pierwszorzędne narzędzia i biblioteki przeznaczone specjalnie do pracy z danymi. Zdobyły one uznanie wielu naukowców i ekspertów, ceniących ten język za wysoką jakość rozwiązań służących do wydobywania wiedzy z danych. Aby uzyskać najlepsze możliwe efekty, trzeba dobrze poznać zarówno poszczególne biblioteki Pythona, jak i zasady pracy z nimi.

Ta książka stanowi wszechstronne omówienie wszystkich bibliotek Pythona potrzebnych naukowcom i specjalistom pracującym z danymi. Znalazł się tu dokładny opis IPythona, NumPy, Pandas, Matplotlib, Scikit-Learn i innych narzędzi. Podręcznik uwzględnia przede wszystkim ich aspekty praktyczne, dzięki czemu świetnie się sprawdzi w rozwiązywaniu codziennych problemów z manipulowaniem, przekształcaniem, oczyszczaniem i wizualizacją różnych typów danych, a także jako pomoc podczas tworzenia modeli statystycznych i modeli uczenia maszynowego. Doceni go każdy, kto zajmuje się obliczeniami naukowymi w Pythonie.

Nauczysz się:

- pracować w naukowym środowisku obliczeniowym IPythona
- korzystać ze specjalistycznych bibliotek przeznaczonych do pracy z danymi
- stosować typy ndarray i DataFrame do przechowywania i przetwarzania danych
- tworzyć różnego rodzaju wizualizacje danych za pomocą Matplotlib

Jake VanderPlas jest inżynierem oprogramowania w Google Research. Współtworzy i rozwija narzędzia do przetwarzania dużych ilości danych, w tym pakiety Scikit-Learn, SciPy, Astropy, Altair i JAX. Jest także twórcą samouczków, często występuje jako prelegent na branżowych konferencjach.

To wydanie zawiera jasne przykłady, które pomogą Ci skonfigurować i wykorzystać narzędzia do nauki o danych i uczenia maszynowego.

Anne Bonner, założycielka i dyrektor generalna Content Simplicity

---

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

KOD KORZYŚCI
Sięgnij po więcej!

ISBN 978-83-289-0068-4

9 788328 900684

Cena: 129,00 zł