

Wyznaczanie sekwencji akcji

Wybrane rozwiązania programistyczne

Marzena Nowakowska

Wydział Zarządzania i Modelowania Komputerowego

Politechnika Świętokrzyska

Budynek C, p. 3.21

spimn@tu.kielce.pl

Metoda apply

Funkcja `apply()` aplikuje określoną funkcję do zbioru wartości – kolumny lub wiersza ramki danych (DataFrame) lub do całej serii (Series):

Dla ramki: `df.apply(funkc, axis=0 lub 1)`

`funkc` – funkcja, która ma być zastosowana

`axis = 0` – gdy funkcja `funkc` ma pracować dla każdej kolumny ramki

`axis = 1` – gdy funkcja `funkc` ma pracować dla każdego wiersza ramki

Dla serii: `s.apply(func)`

funkcja `funkc` zostanie **wykonana dla każdego elementu serii**

Funkcja `apply()` działa poprzez iterację po elementach zbioru wartości.

```
import pandas as pd
df = pd.DataFrame({
    'A': [1, 5, 3],
    'B': [4, 2, 6] })
result = df.apply(max, axis=1)
print(result)
```

```
import pandas as pd
s = pd.Series([-5, 3, -1, 0, 7])
result = s.apply(abs)
print(result)
```

Index	A	B
0	1	4
1	5	2
2	3	6

Index	0
0	-5
1	3
2	-1
3	0
4	7

Metoda apply w sekwencjach

Grupowanie wg jednego atrybutu

```
kseqs = df_sorted.groupby("CUSTOMER")["ACTION"].apply(list)
```

`df_sorted.groupby("CUSTOMER")`

Grupowanie wierszy ramki danych `df_sorted` według kolumny `CUSTOMER`; wszystkie wiersze należące do tego samego klienta będą traktowane jako jedna grupa.

`[ACTION]`

W każdej grupie jest wybierana kolumna `ACTION`. Efektem jest grupowana seria (`SeriesGroupBy`), która nie udostępnia bezpośrednio konkretnych danych, ale pozwala wykonywać różne operacje na każdej grupie osobno (np. `.sum()`, `.mean()`, `.first()`, `.last()`, `apply(list)` itd.).

`.apply(list)`

Dla każdej grupy, wszystkie wartości z kolumny `"ACTION"` są zamieniane na listę. Dzięki temu otrzymuje się listę zawierającą sekwencję akcji dla każdego klienta. Każdy element listy to koszyk.

Wynikiem całej instrukcji jest seria danych zawierająca identyfikatory klientów (kolumna indeksu) oraz listy ich koszyków (kolumna wartości mająca nazwę `ACTION`).

Metoda apply w sekwencjach

Grupowanie wg dwóch atrybutów

```
df_tst = (df_org.groupby(['CUSTOMER', 'TIME'])['ACTION']  
          .apply(lambda x: ', '.join(sorted(x)))  
          .reset_index() )
```

Dzięki nawiasom Python wie,
że całe kilkulinijkowe
wyrażenie to jedna instrukcja.

```
df_org.groupby(['CUSTOMER', 'TIME'])['ACTION']
```

Grupowanie wierszy ramki danych `df_org` według dwóch kolumn `CUSTOMER` i `TIME`; wszystkie wiersze należące do tego samego klienta i tego samego momentu czasowego będą traktowane jako jedna grupa.

`[ACTION]`

W każdej grupie jest wybierana kolumna `ACTION`. Efektem jest grupowana seria (`SeriesGroupBy`), której działanie jest podane na poprzednim slajdzie).

```
.apply(lambda x: ', '.join(sorted(x)))
```

Dla każdej grupy (rekordy z tym samym klientem i tym samym czasem) działa mała jednorazowa funkcja `lambda` (anonimowa - nie ma nazwy), której argument jest zastępowany przez elementy grupy. Funkcja najpierw porządkuje te elementy automatycznie – `sorted` (dlaczego to ważne) a następnie łączy je wszystkie w jeden tekst separując je znakami przecinka i spacji. Stąd, każdy klient w swoich momentach czasu ma przypisane działania (koszyki).

```
.reset_index()
```

Wynik jest serią danych i ma indeksy wielopoziomowe (`CUSTOMER, TIME`), a kolumna z połączonymi akcjami nie ma jeszcze nazwy. Operacja `.reset_index()` zamienia indeksy w kolumny i powstaje ramka danych (`reset_index()` zawsze zwraca ramkę danych, niezależnie od tego, czy pracuje na serii czy ramce danych).

Funkcja Counter

`seq_counts = Counter(tuple(seq) for seq in kseqs)`

Funkcja zwraca obiekt typu `Counter`, działający jak słownik, w którym kluczem jest sekwencja akcji, a wartością krotność wystąpienia tej sekwencji

`tuple(seq) for seq in kseqs`

Wyrażenie generatora, które tworzy obiekt typu *generator*. Generator nie przechowuje danych, tylko tworzy je w trakcie - nie da się powiedzieć, że jego zawartość jest mutowalna lub niemutowalna. To „strumień”, nie struktura danych.

Każdy element, który ww. generator zwraca, jest krotką (tuple) — a krotka w Pythonie jest niemutowalna. Może więc być wykorzystana jako klucz w kolekcji liczników.

`Counter(tuple(seq) for seq in kseqs)`

Counter z modułu collections działa jak słownik (dict), w którym kluczem jest sekwencja, a wartością liczba jego wystąpień. W Pythonie taki klucz musi być hashowalny.

Pętla działająca jak Counter

```
# Utworzenie pustego słownika do zliczania krotności sekwencji (słownik liczników)
seq_counts = {}

# Zamiana listy zawierającej sekwencje na krotkę (tuple)
# Lista nie może być kluczem, bo nie jest hashowalna
# W petli:
# Sprawdzenie, czy bieżąca krotka już jest w słowniku
# Jeżeli tak, to zwiększenie licznika o 1
# Jeśli nie, to dodanie krotki do słownika jako klucza z wartością 1
for seq in kseqs:
    seq_tuple = tuple(seq)
    if seq_tuple in seq_counts:
        seq_counts[seq_tuple] += 1
    else:
        seq_counts[seq_tuple] = 1

# Wyświetlenie wartości słownika
print(seq_counts)
```

Funkcja zip

`zip(iterable1, iterable2, ...)`

Funkcja `zip()` w Pythonie grupuje elementy z wielu iterowalnych obiektów (jak listy, krotki) w pary, trójki, itp. Działa jak "zamek błyskawiczny", (stąd nazwa *zip*), łącząc pierwszy element z pierwszego obiektu z pierwszym elementem z drugiego obiektu itd., a następnie tworzy krotki z odpowiadających elementów z każdego obiektu.

Funkcja łączy elementy o tych samych pozycjach z obu obiektów.

```
names = ['Ala', 'Ola', 'Jan']  
ages = [10, 12, 9]  
pairs = zip(names, ages)  
print(list(pairs))
```

Wynik:

`[('Ala', 10), ('Ola', 12), ('Jan', 9)]`

Metoda join

```
patterns = [' → '.join(p[0]) if len(p[0]) > 1 else str(p[0][0]) for p in wzorce]
```

for p in wzorce	iteruje po elementach kolekcji wzorce
p[0]	pierwszy element każdego p (np. lista znaków)
len(p[0]) > 1	sprawdza, czy lista ma więcej niż 1 element
' → '.join(p[0])	łączy elementy listy w jeden tekst, oddzielone strzałką
else str(p[0][0])	jeśli jest tylko jeden element, zamienia go na string

Złączenie (comprehension) tworzy listę napisów, w której każdy element to połączone elementy poszczególnych wierszy ze wzorca p[0], oddzielone " → ". Jeśli p[0] ma tylko jeden element, zostaje on przekształcony do tekstu bez strzałek.

```
elementy = ['Ala', 'Ola', 'Tomek']  
zdanie1 = ' → '.join(elementy)
```

Ala → Ola → Tomek

```
wyrazy = ["tomek", "lubi", "lody", "pistacjowe"]  
zdanie2 = " ".join([el.capitalize() if el == wyrazy[0] else el for el in wyrazy])
```

Tomek lubi lody pistacjowe