



Algorytm Knutha-Morrisa-Pratta w języku Python

- [Wprowadzenie](#)
- [Przeczytaj](#)
- [Symulacja interaktywna](#)
- [Sprawdź się](#)
- [Dla nauczyciela](#)



Algorytm Knutha-Morrisa-Pratta w języku Python

Źródło: Wallace Chuck, domena publiczna.

W e-materiale [Algorytm Knutha-Morrisa-Pratta](#) przeanalizowaliśmy algorytm wyszukiwania wzorca w tekście. Zdobyte w ten sposób informacje teoretyczne spróbujemy teraz zastosować w praktyce. Dlatego w tym e-materiale zapoznamy się z implementacją algorytmu KMP w języku Python.

Implementację tego algorytmu w pozostałych językach programowania znajdziesz w e-materiałach:

- [Algorytm Knutha-Morrisa-Pratta w języku C++](#),
- [Algorytm Knutha-Morrisa-Pratta w języku Java](#).

Więcej zadań? Przejdź do e-materiału [Algorytm Knutha-Morrisa-Pratta – zadania naturalne](#).

Twoje cele

- Przeanalizujesz metodę tworzenia tablicy częściowych dopasowań dla algorytmu KMP.
- Zaimplementujesz funkcję realizującą wyszukiwanie wzorca w tekście za pomocą algorytmu KMP.
- Rozwiążesz przykładowe zadania programistyczne z wykorzystaniem algorytmu KMP.

Przeczytaj

Algorytm KMP – implementacja w języku Python

Przykład 1

W [materiale omawiającym algorytm Knutha-Morrisa-Pratta](#) możemy znaleźć zapisany za pomocą pseudokodu algorytm oraz dokładną analizę jego działania. W tym e-materiale stworzymy implementację tego algorytmu. Najpierw napiszemy funkcję, której zadaniem będzie zbudowanie tablicy częściowych dopasowań. Tablicy tej potrzebujemy, aby efektywnie przeprowadzać próby dopasowań wzorca w tekście:

```
1 def budowa_tablicy_KMP(worzec):
2     rozmiar_tablicy = len(worzec) + 1
3     tablica = [0] * rozmiar_tablicy                                # d
4     poz = tablica[0] = -1                                         # n
5
6     for i in range(1, rozmiar_tablicy):                            # i
7
8         while poz > -1 and worzec[poz] != worzec[i - 1]:         # d
9             poz = tablica[poz]
10        poz += 1
11
12        if i == rozmiar_tablicy - 1 or worzec[i] != worzec[po
13            tablica[i] = poz                                       # z
14                                                                    # k
15                                                                    # j
16        else:
17            tablica[i] = tablica[poz]                             # z
18                                                                    # n
19    return tablica
```

Następnie zdefiniujemy funkcję, która, używając tablicy, będzie realizowała wyszukiwanie wzorca w tekście. Korzysta ona z wyżej zdefiniowanej funkcji do budowania tablicy częściowych dopasowań. W kodzie użyjemy funkcji `enumerate` w celu iterowania po znakach w tekście:

```
1 def szukaj_algorytmem_KMP(tekst, wzorzec):
```

```

2
3     tablica_T = budowa_tablicy_KMP(wzorzec)
4     dop = 0
5     wynikowy_indeks = -1
6     for indeks, znak_S in enumerate(tekst):
7         while dop > -1 and wzorzec[dop] != znak_S:
8             dop = tablica_T[dop]
9             dop += 1
10
11         if dop == len(wzorzec):
12             wynikowy_indeks = indeks - len(wzorzec) + 1
13             break
14     return wynikowy_indeks

```

Pełna wersja programu wraz z kilkoma przykładami wykonania funkcji:

```

1 def budowa_tablicy_KMP(wzorzec):
2     rozmiar_tablicy = len(wzorzec) + 1
3     tablica = [0] * rozmiar_tablicy
4     poz = tablica[0] = -1
5
6     for i in range(1, rozmiar_tablicy):
7         while poz > -1 and wzorzec[poz] != wzorzec[i - 1]:
8             poz = tablica[poz]
9             poz += 1
10
11         if i == rozmiar_tablicy - 1 or wzorzec[i] != wzorzec[po
12             tablica[i] = poz
13         else:
14             tablica[i] = tablica[poz]
15
16     return tablica
17
18
19 def szukaj_algorytmem_KMP(tekst, wzorzec):
20
21     tablica_T = budowa_tablicy_KMP(wzorzec)
22     dop = 0
23     wynikowy_indeks = -1
24     for indeks, znak_S in enumerate(tekst):
25         while dop > -1 and wzorzec[dop] != znak_S:

```

```

26         dop = tablica_T[dop]
27     dop += 1
28     if dop == len(wzorzec):
29         wynikowy_indeks = indeks - len(wzorzec) + 1
30         break
31     return wynikowy_indeks
32
33
34 # Działanie funkcji budującej tablicę dla przykładowych wzorców
35 print(budowa_tablicy_KMP("ADCDADC"))
36 # [-1, 0, 0, 0, -1, 0, 0, 3]
37
38 print(budowa_tablicy_KMP("AAAAAAAAA"))
39 # [-1, -1, -1, -1, -1, -1, -1, -1, -1, 8]
40
41 print(budowa_tablicy_KMP("ASDGORKASDF"))
42 # [-1, 0, 0, 0, 0, 0, 0, 0, -1, 0, 0, 3, 0]
43
44 print(budowa_tablicy_KMP("ASDFORKASDF0"))
45 # [-1, 0, 0, 0, 0, 0, 0, 0, -1, 0, 0, 0, 0, 5]
46
47 # Szukanie dopasowań wzorca w tekście
48 szukany_W = "ADCDADC"
49 lancuch_S = "ADC ADCDAD ADCDADCADCE"
50 print(szukaj_algorytmem_KMP(lancuch_S, szukany_W))
51 # 11
52
53 # przykład sprawdzenia za pomocą wbudowanej metody find
54 print(lancuch_S.find(szukany_W))
55 # 11

```

Dla zainteresowanych

Metoda `find()` w języku Python realizuje wyszukiwanie tekstu za pomocą zmodyfikowanego algorytmu [Boyer-Moor-Horspool](#) – więcej informacji na ten temat można znaleźć w kodzie źródłowym CPython.

Słownik

`enumerate()`

funkcja w języku Python służąca do generowania indeksu i wartości odpowiadającej temu indeksowi w liście

metoda naiwna

określana również jako *brute force*; sprawdza wszystkie możliwe dopasowania wzorca w tekście

algorytm Boyer-Moore-Horsepool

jest to ulepszenie algorytmu Boyera-Moore'a; podobnie jak algorytm KMP analizuje wzorzec w celu znalezienia maksymalnego skoku w analizie tekstu po nieudanym dopasowaniu; porównanie wzorca z fragmentem tekstu odbywa się od końca wzorca; średnia złożoność czasowa tego algorytmu to $O = \left(\frac{\text{długość wzorca}}{\text{alfabet}} \right)$ i w praktyce jest on znacznie szybszy od rozwiązania naiwnego

Symulacja interaktywna

Problem 1

W języku Python napisz program, który wyszuka w tekście pierwszy fragment o zadanej długości, złożony jedynie z cyfr. Użyj algorytmu KMP. Program powinien zwrócić indeks początku znalezionej wzorca w tekście. Działanie programu przetestuj dla przykładowych danych:

```
1 tekst = "ab3def45ab12345hijk"
2 dlugosc_wzorca = 5
```

Specyfikacja:

Dane:

- tekst – przeszukiwany tekst; łańcuch znaków
- dlugosc_wzorca – długość szukanego fragmentu w tekście; dodatnia liczba całkowita

Wynik:

- wynikowy_indeks – indeks wskazujący w danym tekście na pierwszy znak znalezionej wzorca; jeżeli wzorzec nie został znaleziony, indeks jest równy -1; liczba całkowita

Twoje zadania

1. Program zwraca indeks wskazujący na początek znalezionej wzorca lub -1, jeżeli nie został on znaleziony w tekście.

```
1 def szukaj_algorytmem_KMP(tekst, dlugosc_wzorca):
2     wynikowy_indeks = -1
3
4     # tutaj dodaj swój kod
5
6     return wynikowy_indeks
7
8 tekst = "ab3def45ab12345hijk"
```

```
9 dlugosc_wzorca = 5
10
11 print(szukaj_algorytmem_KMP(tekst, dlugosc_wzorca))
```

```
1
```

Polecenie 1

Porównaj swoje rozwiązanie z prezentacją.

Program będzie modyfikacją implementacji algorytmu KMP, którą przedstawiliśmy w sekcji „Przeczytaj”. W przypadku aktualnie rozwiązywanego problemu wzorzec posiada jednak ogólniejszą formę – jest ciągiem dowolnych cyfr. Zaczynamy od zdefiniowania funkcji, która przyjmuje dwa parametry:

1

przeszukiwany tekst – tekst oraz długość wzorca – `dlugosc_wzorca`. Zadeklarujemy również zmienną `wynikowy_indeks`, która będzie przechowywać zwracany indeks:

```
1 def
  szukaj_algorytmem_KMP(tekst, dlugosc_wzorca):
2     wynikowy_indeks = -1
3
```

2

Następnie zajmiemy się kwestią tablicy częściowych dopasowań. Algorytm KMP używa tej tablicy, aby trzymać w niej informacje o budowie szukanego wzorca. Dzięki tablicy może określić, od którego indeksu wzorca powinien rozpocząć kolejną próbę dopasowania do tekstu, po wcześniejszym znalezieniu niedopasowania.

Rozpatrujemy wzorzec, który składa się z dowolnego ciągu cyfr o zadanej długości. Dlatego nie potrzebujemy go analizować. Jeżeli podczas próby dopasowania napotkamy na znak `c` niebędący cyfrą, to dowolna próba dopasowania, zawierająca `c`, będzie również niedopasowaniem. To znaczy, że możemy rozpocząć kolejną próbę dopasowania w tekście od znaku następującego po `c` i zaczniemy dopasowywanie wzorca od jego początkowego indeksu.

Takie działanie daje tablica częściowych dopasowań, która posiada na pierwszej pozycji wartownika `-1` oraz jest wypełniona w całości `0` – zawsze zaczniemy dopasowywanie od początku wzorca. Skoro jednak każda próba dopasowania będzie rozpoczynała się tak samo, możemy zastąpić tablicę pojedynczą liczbą, czyli `-1`. Nie musimy tego robić, jednak dla klarowności zadeklarujemy zmienną

początek_wzorca, która będzie spełniała tę rolę.

```
1 def
  szukaj_algorytmem_KMP(tekst, dlugosc_wzorca):
2     wynikowy_indeks = -1
3     poczatek_wzorca = -1
4
```

Kolejny fragment programu wygląda dokładnie tak samo, jak w implementacji algorytmu KMP. Deklarujemy zmienną `dop` wskazującą na kolejny element wzorca, dla którego ma zostać sprawdzone dopasowanie (więc początkowa wartość 0). Tworzymy również pętlę `for`, w której będzie odbywała się iteracja po znakach w tekście.

```
1 def
  szukaj_algorytmem_KMP(tekst, dlugosc_wzorca):
2     wynikowy_indeks = -1
3     poczatek_wzorca = -1
4     dop = 0
5     for indeks, znak_S in
      enumerate(tekst):
6         pass
7
```

4

W następnym fragmencie kodu weryfikujemy, czy obecny `znak_S` pasuje do wzorca – w przypadku tego problemu sprawdzamy, czy jest cyfrą. Jeżeli nie jest, to znaleźliśmy niedopasowanie i cofamy się we wzorcu do miejsca, od którego zaczniemy kolejną próbę

3

dopasowania. Jak już ustaliliśmy, będzie to zawsze początek wzorca, więc dop przyjmie wartość `poczatek_wzorca`. W związku z tym możemy użyć instrukcji `if` zamiast pętli `while`, jak było to zrobione w przypadku implementacji algorytmu KMP.

```
1
2 def
   szukaj_algorytmem_KMP(tekst, dlugosc_wzorca):
3     wynikowy_indeks = -1
4     poczatek_wzorca = -1
5     dop = 0
6     for indeks, znak_S in
       enumerate(tekst):
7         if dop > -1 and
           not znak_S.isdigit():
8             dop =
               poczatek_wzorca
9
```

Następnie zwiększamy indeks `dop` o 1 i sprawdzamy, czy długość dopasowanej części wzorca jest równa długości całego wzorca. Jeżeli tak jest, to znaleźliśmy dopasowanie i możemy zapisać w zmiennej `wynikowy_indeks` pozycję, od której zaczyna się wystąpienie wzorca w tekście.

```
1 def
   szukaj_algorytmem_KMP(tekst, dlugosc_wzorca):
2     wynikowy_indeks = -1
3     poczatek_wzorca = -1
4     dop = 0
5     for indeks, znak_S in
       enumerate(tekst):
6         if dop > -1 and
           not znak_S.isdigit():
```

```

7         dop =
początek_wzorca
8         dop += 1
9         if dop ==
długość_wzorca:
10
wynikowy_indeks = indeks -
długość_wzorca + 1
11

```

6

Na koniec implementujemy wyjście z pętli for w przypadku, kiedy znaleźliśmy dopasowanie oraz zwrócenie wartości wynikowy_indeks. Jeżeli wyjście z pętli nie nastąpiło przez instrukcję break, to dopasowanie nie zostało znalezione i wynikowy_indeks ma wartość -1.

```

1 def
szukaj_algorytmem_KMP(tekst, długość_wzorca):
2     wynikowy_indeks = -1
3     początek_wzorca = -1
4     dop = 0
5     for indeks, znak_S in
enumerate(tekst):
6         if dop > -1 and
not znak_S.isdigit():
7             dop =
początek_wzorca
8             dop += 1
9             if dop ==
długość_wzorca:
10
wynikowy_indeks = indeks -
długość_wzorca + 1
11                 break
12     return wynikowy_indeks
13

```

Źródło: Contentplus.pl sp. z o.o., licencja: CC BY-SA 3.0.

Polecenie 2

Uruchom aplet realizujący wyszukiwanie wzorca w tekście. W aplecie znaki indeksowane są od 0 (czyli pierwszy znak ciągu ma indeks 0).

Źródło: Contentplus.pl sp. z o.o., licencja: CC BY-SA 3.0.

Sprawdź się

Pokaż ćwiczenia:   

Ćwiczenie 1



Uzupełnij tekst brakującymi informacjami.

Algorytm KMP wymaga liczby niezbędnych porównań niż algorytm naiwny, więc zapewnia wydajność wyszukiwania pierwszego wystąpienia ciągu w tekście. W tablicy częściowych dopasowań wartość pełniąca rolę wartownika to . W języku Python wbudowana funkcja wyszukująca indeks pierwszego wystąpienia wzorca w łańcuchu znaków to .

Nazwiska autorów algorytmu KMP to kolejno: , , .

Peter

mniej

0

Pratt

mniej

Kevin

wię

-1

Maurice

in

Knuth

super

wię

szybki

1

Morris

find

search

Ćwiczenie 2



Uzupełnij tablicę częściowych dopasowań dla wzorca ABCABCDDEABC zgodnie z funkcją budowy tablicy dla algorytmu KMP:

Wartość	A	B	C	A	B	C	D	D	E	A	B	C
-1					0				-1			

Ćwiczenie 3



Napisz program, który zliczy w przekazanym tekście wszystkie wystąpienia wzorca. Wzorzec jest dowolnym ciągiem znaków o długości określonej przez zmienną `długosc_wzorca`, spełniającym następujące warunki:

- jeżeli `długosc_wzorca` jest parzysta, wzorzec składa się z dowolnych małych liter i dowolnych dwóch wielkich liter pośrodku, np. `we rTTsug`,
- jeżeli `długosc_wzorca` jest nieparzysta, wzorzec składa się z dowolnych małych liter oraz jednej dowolnej wielkiej litery pośrodku, np. `reWsd`.

Do rozwiązania użyj implementacji algorytmu KMP, która została przedstawiona w sekcji „Przeczytaj” (przydatne może być również przeanalizowanie symulacji interaktywnej).

Przetestuj kod dla danych:

```
1 tekst = "72048agfds3423abcDDefg5902341asdfaweEEgafsd fawRRgdf sasc  
2 dlugosc_wzorca = 8
```

Specyfikacja:

Dane:

- `tekst` – tekst dla poszukiwań wystąpień wzorca; łańcuch znaków
- `długosc_wzorca` – długość poszukiwanego wzorca; dodatnia liczba całkowita

Wynik:

- `wystapienia` – zliczone wystąpienia wzorca w tekście; nieujemna liczba całkowita

Twoje zadania

1. Program zlicza wszystkie wystąpienia wzorca w tekście.

```
1 def szukaj_algorytmem_KMP(tekst, dlugosc_wzorca):
2     wystapienia = 0
3
4     # tutaj dodaj kod
5
6     return wystapienia
7
8
9 tekst =
10 "72048agfds3423abcDDefg5902341asdfaweEEgafsdFawRRgdfsasd"
11 dlugosc_wzorca = 8
12 print(szukaj_algorytmem_KMP(tekst, dlugosc_wzorca))
```

```
1
```

Dla nauczyciela

Autor: Adam Jurkiewicz

Przedmiot: Informatyka

Temat: Algorytm Knutha-Morrisa-Pratta w języku Python

Grupa docelowa:

Liceum ogólnokształcące i technikum, liceum ogólnokształcące, technikum, zakres rozszerzony

Podstawa programowa:

Cele kształcenia – wymagania ogólne

- I. Rozumienie, analizowanie i rozwiązywanie problemów na bazie logicznego i abstrakcyjnego myślenia, myślenia algorytmicznego i sposobów reprezentowania informacji.
- II. Programowanie i rozwiązywanie problemów z wykorzystaniem komputera oraz innych urządzeń cyfrowych: układanie i programowanie algorytmów, organizowanie, wyszukiwanie i udostępnianie informacji, posługiwanie się aplikacjami komputerowymi.

Treści nauczania – wymagania szczegółowe

- I. Rozumienie, analizowanie i rozwiązywanie problemów.

Zakres rozszerzony. Uczeń spełnia wymagania określone dla zakresu podstawowego, a ponadto:

- 3) objaśnia dobrany algorytm, uzasadnia poprawność rozwiązania na wybranych przykładach danych i ocenia jego efektywność;

- II. Programowanie i rozwiązywanie problemów z wykorzystaniem komputera i innych urządzeń cyfrowych.

Zakres rozszerzony. Uczeń spełnia wymagania określone dla zakresu podstawowego, a ponadto:

- 3) sprawnie posługuje się zintegrowanym środowiskiem programistycznym przy pisaniu, uruchamianiu i testowaniu programów;

- I + II. Zakres rozszerzony. Uczeń spełnia wymagania określone dla zakresu podstawowego, a ponadto:

3) objaśnia, a także porównuje podstawowe metody i techniki algorytmiczne oraz struktury danych, wykorzystując przy tym przykłady problemów i algorytmów, w szczególności:

g) metodę haszowania (wyszukiwanie wzorca w tekście),

Kształtowane kompetencje kluczowe:

- kompetencje cyfrowe;
- kompetencje osobiste, społeczne i w zakresie umiejętności uczenia się;
- kompetencje matematyczne oraz kompetencje w zakresie nauk przyrodniczych, technologii i inżynierii.

Cele operacyjne (językiem ucznia):

- Przeanalizujesz metodę tworzenia tablicy częściowych dopasowań dla algorytmu KMP.
- Zaimplementujesz funkcję realizującą wyszukiwanie wzorca w tekście za pomocą algorytmu KMP.
- Rozwiążesz przykładowe zadania programistyczne z wykorzystaniem algorytmu KMP.

Strategie nauczania:

- konstruktywizm;
- konektywizm.

Metody i techniki nauczania:

- dyskusja;
- rozmowa nauczająca z wykorzystaniem multimediu i ćwiczeń interaktywnych;
- ćwiczenia praktyczne.

Formy pracy:

- praca indywidualna;
- praca w parach;
- praca w grupach;
- praca całego zespołu klasowego.

Środki dydaktyczne:

- komputery z głośnikami, słuchawkami i dostępem do internetu;
- zasoby multimedialne zawarte w e-materiale;
- tablica interaktywna/tablica, pisak/kreda;
- oprogramowanie dla języka Python 3 (lub nowszej wersji), w tym PyCharm lub IDLE.

Przebieg lekcji

Przed lekcją:

1. **Przygotowanie do zajęć.** Nauczyciel loguje się na platformie i udostępnia e-materiał: „Algorytm Knutha–Morrisa–Pratta w języku Python”. Uczniowie zapoznają się z treściami w sekcji „Przeczytaj”.

Faza wstępna:

1. Nauczyciel wyświetla temat i cele zajęć zawarte w sekcji „Wprowadzenie”. Następnie wspólnie z uczniami ustala kryteria sukcesu.

Faza realizacyjna:

1. **Praca z tekstem.** Jeśli przygotowanie uczniów do lekcji jest niewystarczające, nauczyciel prosi uczniów o zapoznanie się z sekcją „Przeczytaj”. Następnie uczniowie wykonują polecenie 1. Chętna lub wybrana osoba przedstawia swoje rozwiązanie i wyjaśnia otrzymany rezultat. Pozostali uczniowie weryfikują poprawność rozwiązania lub przedstawiają alternatywne.
2. **Praca z multimediami.** Nauczyciel wyświetla zawartość sekcji „Symulacja interaktywna”, czyta treść problemu 1. Uczniowie indywidualnie wypracowują swoje rozwiązania, a następnie porównują je z przedstawionym w prezentacji.
3. **Ćwiczenie umiejętności.** Uczniowie wykonują ćwiczenia nr 1 i 2 z sekcji „Sprawdź się”. Nauczyciel sprawdza poprawność wykonanych zadań, omawiając je wraz z uczniami.
4. Uczniowie wykonują w parach ćwiczenie 3 z sekcji „Sprawdź się”. Po zakończeniu zadania porównują swoje rozwiązanie z wynikiem innej grupy.

Faza podsumowująca:

1. Nauczyciel inicjuje dyskusję na temat praktycznego wykorzystania algorytmu KMP.
2. Nauczyciel wyświetla na tablicy temat lekcji i cele zawarte w sekcji „Wprowadzenie”. W kontekście ich realizacji podsumowuje przebieg zajęć, a także wskazuje mocne i słabe strony pracy uczniów.

Praca domowa:

1. Uczniowie wykonują polecenie 2 z sekcji „Symulacja interaktywna”.

Materiały pomocnicze:

- Oficjalna dokumentacja techniczna dla języka Python 3 (lub nowszej wersji).
- Oficjalna dokumentacja techniczna dla oprogramowania PyCharm lub IDLE.

Wskazówki metodyczne:

- Nauczyciel może wykorzystać multimediami w sekcji „Symulacja interaktywna” do pracy przed lekcją. Uczniowie zapoznają się z jego treścią i przygotowują do pracy na

zajęciach w ten sposób, żeby móc samodzielnie rozwiązać zadania dołączone do e-materiału „Algorytm Knutha-Morrisa-Pratta w języku Python”.