

Drzewa sufiksowe

referat z seminarium *zaawansowane struktury danych*
mgr Paweł Rzechonek, II UWR 2012/2013

Borys Dyczko

29 stycznia 2013

Spis treści

1	Wstęp	3
1.1	Historia	3
1.2	Definicje	3
1.3	Opis	3
1.4	Reprezentacja węzła	3
2	Operacje	4
2.1	Wyszukiwanie wzorca, ilość wystąpień	4
2.2	Pierwsze k wystąpień	5
2.3	Najdłuższe powtarzające się podśłowo	5
2.4	Wiele tekstów	5
2.4.1	Najdłuższy wspólny podciąg	5
2.4.2	Liczba tekstów zawierających wzorzec	6
3	Konstrukcja drzew sufiksowych	6
3.1	Definicje	6
3.2	Algorytm McCreighta	6
3.2.1	Algorytm	7
3.2.2	Złożoność	7
3.3	Algorytm Ukkonena	8
3.3.1	Algorytm	8
3.3.2	Złożoność	9
4	Podsumowanie	9
4.1	Zastosowania	9

1 Wstęp

Wyszukiwanie wzora w tekście jest popularnym problemem algorytmicznym. Istnieją algorytmy, które w szybkim czasie potrafią odpowiedzieć na pytanie o występowanie wzorca, np. Boyera-Moore’a, Morrisa-Pratta, Knutha-Morrisa-Pratta. Jednak gdy interesują nas pytania o wiele wzorców zawartych w jednym tekście, powyższe algorytmy się nie sprawdzają. Aby otrzymać lepszą złożoność czasową, możemy skorzystać z takich struktur danych jak tablice lub drzewa sufiksowe. Wykorzystują one preprocessing głównego tekstu do budowy swojej struktury, aby w czasie liniowym odpowiedzieć na pytanie o wzorzec.

1.1 Historia

Koncepcję drzew sufiksowych (nazwanych wtedy drzewami pozycyjnymi) wprowadził Weiner w 1973 roku. Konstrukcja została uproszczona przez McCreighta w 1976. Ukkonen w 1995 podał pierwszy liniowy algorytm konstrukcji drzewa sufiksowego online, znany jako Algorytm Ukkonena.

1.2 Definicje

Σ - alfabet

$|w|$ - długość słowa w

$T = t_0t_1t_2\dots t_{n-1}$ - tekst długości n

$T_i = t_it_{i+1}t_{i+2}\dots t_{n-1}$ - i -ty sufix T

n - długość tekstu

m - długość wzorca

Aby ustalić ścisły porządek na sufiksach danego tekstu, będzie wygodnie dołożyć na koniec tekstu znak $\#$. Przyjmujemy, że jest leksykograficznie większy od dowolnego symbolu z Σ .

1.3 Opis

Drzewo sufiksowe jest drzewem, w którym każda ścieżka jest etykietowana kolejnymi symbolami pewnego sufiksu, oraz każdy sufix T jest obecny w drzewie. Każdej krawędzi jest przypisane jako etykieta pewne podśłowo T . Krawędzie wychodzące z tego samego węzła, różnią się pierwszymi symbolami swoich etykiet.

Etykiety są kodowane przedziałami w tekście T : para liczb $[i, j]$ reprezentuje podśłowo $t_it_{i+1}\dots t_j$. Dzięki temu reprezentacja ma rozmiar $O(n)$. Wagą krawędzi jest długość odpowiadającego jej słowa.

Przykładowe drzewo sufiksowe znajduje się na rysunku 1.

1.4 Reprezentacja węzła

Różne struktury wykorzystane do reprezentacji węzłów, dają różne złożoności czasowe i pamięciowe. Wybrane struktury są przedstawione w tabeli 1. Idealnym rozwiązaniem wydaje się być tablica haszująca, jednak przy jej wykorzystaniu reprezentacja węzła nie zachowuje porządku. Jest to potrzebne w

Rysunek 1: Drzewo sufiksowe dla słowa BANANA




Tabela 1: Reprezentacja węzłów, a złożoność

struktura	czas	pamięć
tablica	$O(m)$	$O(n * \Sigma)$
BST	$O(m * \log \Sigma)$	$O(n)$
tablica haszująca	$O(m)$	$O(n)$
drzewo Van Emde Boas	$O(m * \log\log \Sigma)$	$O(n)$

niektórych operacjach, np. podczas szukania poprzednika, następnika. Prosty rozwiązaniem w implementacji z małym narzutem na pamięć, jest drzewo BST.

2 Operacje

Wszystkie operacje wykonywane na drzewach sufiksowych są stosunkowo proste, opierają się na umiejętnym przejściu drzewa, z paroma drobnymi modyfikacjami.

Dany jest wzorzec $P = p_0p_1p_2...p_{m-1}$.

2.1 Wyszukiwanie wzorca, ilość wystąpień

Wyszukiwanie wzorca P zaczynamy od korzenia. Za każdym razem przechodzimy po krawędziach w dół drzewa, aż napotkamy miejsce w którym nie ma krawędzi odpowiadających literom wzorca. Jeśli podczas przechodzenia drzewa przeczytamy cały wzorzec, oznacza to, że występuje on w tekście. Ilość wystąpień wzorca P odpowiada ilości liści w poddrzewie w którym zakończyliśmy przechodzenie drzewa.

Łatwo udowodnić złożoność czasową $O(m)$ powyższej operacji. Przejść po krawędziach będzie maksymalnie tyle, ile liter ma wzorzec, czyli m . Wykorzystując tablice haszujące, odszukanie krawędzi w węźle zajmuje $O(1)$. Całość sumuje się oczywiście do $O(m)$.

2.2 Pierwsze k wystąpień

Wprowadzenie modyfikacji:

- dodanie do każdego wężła wskaźnika, na lewego, skrajnego syna
- połączenie wszystkich liści w listę cykliczną

Modyfikacje nie podnoszą złożoności, a jedyne stałą podczas budowy drzewa sufikсового, o czym jest w dalszej części pracy.

Aby znaleźć pierwsze k wystąpień, należy odszukać odpowiedni węzeł tak samo jak w rozdziale 2.1. Następnie przeglądnąć listę liści. Daje to oczywiście złożoność $O(k + m)$.

2.3 Najdłuższe powtarzające się pod słowo

Operacja polega na znalezieniu najgłębszego węzła który nie jest liściem.
Czas operacji $O(n)$.

Dlaczego jest to poprawne? Węzeł o etykiecie x , który posiada 2 liście, świadczy o istnieniu 2 sufiksów w tekście, których prefiksem jest x . Korzystając z tego, że szukamy najgłębszego węzła, dostajemy, że 2 takie prefiksy x są najdłuższe.


2.4 Wiele tekstów

Danych jest z tekstów $T^0, T^2, T^3 \dots T^{z-1}$. Wprowadzamy modyfikacje w reprezentacji drzewa:

- do każdego tekstu T^i i dołączamy na koniec $\$i$
- każdy węzeł posiada informację o liczbie unikalnych wystąpień $\$$ w jego poddrzewie

Przykładowe drzewo sufiksowe dla kilku teksów znajduje się na rysunku 2.

Rysunek 2: Drzewo sufiksowe dla 3 słów: ABAB, BABA, ABBA.



2.4.1 Najdłuższy wspólny podciąg

Znalezienie węzła o największej głębokości, który posiada wszystkie s_i . Dowód podobny jak w rozdziale 2.3. Złożoność $O(\sum_{i=0}^{z-1} |T^i|)$.

2.4.2 Liczba tekstów zawierających wzorzec

Przejście drzewa zgodnie z literami wzorca i odczytanie ilości unikalnych \$. Sytuacja analogiczna jak w rozdziale 2.1.

3 Konstrukcja drzew sufiksowych

3.1 Definicje

$Label(v)$ = słowo otrzymane podążając po drzewie od korzenia do węzła v .

$Suf(v)$ (dowiązanie sufiksowe) = v' takie że

$$Label(v) = y_0 y_1 y_2 \dots y_k$$

$$Label(v') = y_1 y_2 \dots y_k$$

$$Suf(root) = root.$$

$$parent(v) = \text{rodzic } v \text{ w drzewie } T$$

$$parent(root) = root$$

3.2 Algorytm McCreighta

Algorytm buduje skompresowane drzewo sufiksowe w kolejności od najdłuższego sufiksu do najkrótszego. Ogólny schemat algorytmu jest następujący:

- W fazie pierwszej inicjujemy drzewo najdłuższym sufiksem, czyli pojedynczą krawędzią reprezentującą cały tekst T .
- Załóżmy, że jesteśmy w fazie $k > 1$ i dodajemy do drzewa $sufiks_k$.
- Przedstawmy słowo $sufiks_k$ jako konkatenację dwóch słów pq takich, że słowo p jest najdłuższym prefiksem $sufiks_k$, który można utworzyć podążając ścieżką od korzenia w dół drzewa. Taki rozkład jest jednoznaczny.
- Definiujemy głowę $head_k$ k -tego sufiksu jako taki węzeł v (być może niejawnym) w drzewie, że $Label(v) = p$.
- Dodajemy do drzewa krawędź reprezentującą słowo q w węźle $head_k$.

Szukanie głowy w sposób naiwny - $O(n^2)$

Aby obniżyć złożoność, skorzystamy z dowiązań sufiksowych. Aby szybko znajdować głowę k -tego sufiksu, korzystamy z następujących własności drzew sufiksowych:

- $head_i$ jest potomkiem $Suf(head_{i-1})$
- $Suf(v)$ jest potomkiem $Suf(parent(v))$, $\forall v \in T$

Skorzystamy z 2 sposobów schodzenia w dół drzewa:

slowFind - przemieszczanie się znak po znaku. Używane, gdy nie wiemy wystarczająco wiele o szukanym słowie, aby przemieszczać się w sposób szybki.

fastFind - gdy wyszukujemy w drzewie słowo, o którym wiemy, że na pewno je znajdziemy, a bardziej interesuje nas gdzie (w jakim węźle jawnym lub

niejawnym) je znajdziemy. Pozwala to w czasie stałym omijać całe krawędzie drzewa.

Funkcje dla argumentów (v, y) zwracają węzeł (być może niejawnym), na którym kończy się zejście w dół drzewa zapoczątkowane w węźle v , w poszukiwaniu słowa y .

3.2.1 Algorytm

Pseudokod algorytmu został zaprezentowany jako algorytm 1.

Algorithm 1 Algorytm McCreighta - konstrukcja offline

```

 $T \leftarrow$  inicjalne drzewo, zbudowane z jednej krawędzi etykietowanej całym tekstem  $x$  o długości  $n$ 
 $head_1 \leftarrow root$ 
 $leaf_1 \leftarrow$  jedyny liść drzewa
for  $i = 2 \rightarrow n$  do
     $p \leftarrow$  etykieta na krawędzi  $parent(head_{i-1}) \rightarrow head_{i-1}$ 
     $q \leftarrow$  etykieta na krawędzi  $head_{i-1} \rightarrow leaf_{i-1}$ 
    if  $head_{i-1} = root$  then
        Usuń pierwszy znak z  $q$ 
         $head_i \leftarrow slowfind(root, q)$ 
    else
         $u \leftarrow parent(head_{i-1})$ 
        if  $u = root$  then
            Usuń pierwszy znak z  $p$ 
             $v \leftarrow fastfind(root, p)$ 
        else
             $v \leftarrow fastfind(Suf(u), p)$ 
        end if
        if  $v$  jest węzłem niejawnym then
             $head_i \leftarrow v$ 
        else
             $head_i \leftarrow slowfind(v, q)$ 
        end if
    end if
     $Suf(head_{i-1}) \leftarrow v$ 
    Stwórz węzeł  $leaf_i$ 
    if  $head_i$  jest węzłem niejawnym then
        rozbij krawędź, na której znajduje się  $head_i$  na dwie krawędzie
    end if
    Stwórz krawędź  $head_i \rightarrow leaf_i$  o odpowiedniej etykietce
end for

```

3.2.2 Złożoność

Twierdzenie 1. Algorytm McCreighta buduje drzewo sufiksowe tekstu o długości n w czasie $O(n)$, przy założeniu $|\Sigma| = O(1)$.

Dowód. Rozważmy oddzielnie czas działania wszystkich wykonań *slowFind* i *fastFind*. Wszystkie pozostałe operacje działają w czasie stałym. Niech $depth(v)$

oznacza głębokość węzła v w drzewie sufikсовym, tzn. liczbę węzłów w skompresowanym drzewie na ścieżce od korzenia do v .

Operacja *fastFind* zwiększa głębokość, na której przebywamy. Przejście do rodzica oraz przejście dowiązaniem sufikсовym zmniejsza tę głębokość. Zachodzi $depth(v) \leq depth(Suf(v)) + 1$. Oznacza to, że w każdej iteracji algorytmu najpierw zmniejszamy głębokość o co najwyżej 2, a następnie zwiększamy tę głębokość. Nie możemy jej zwiększać w nieskończoność, bo liczba węzłów drzewa jest w danej fazie liniowa względem numeru iteracji, zatem po wszystkich iteracjach wykonamy co najwyżej liniowo wiele przemieszczeń po węzłach drzewa w trakcie *fastfind*.

Czas spędzony na wykonywaniu *slowFind* także jest liniowy, co zakończy dowód. Przez zapis $|head_i|$ rozumiemy odległość węzła $head_i$ od korzenia w sensie nieskompresowanego drzewa sufikсового.

Używamy *slowFind* aby znaleźć $head_i$ rozpoczynając od $Suf(head_{i-1})$. Ponieważ początkowych $|head_{i-1}|$ znaków znajdujemy przy pomocy *fastFind*, praca wykonana przez *slowFind* wynosi $|head_i| - |head_{i-1}| + O(1)$. Zatem łącznie wykonamy liniowo wiele operacji. $\square$

3.3 Algorytm Ukkonena

Motywacja - ulepszenie algorytmu naiwnego. Budujemy nieskompresowane drzewo sufikсовe dla słowa $T = t_0t_1t_2\dots t_{n-1}$. W k -tej fazie dodajemy do drzewa T_{k-1} krawędzie z etykietą t_k , tak aby otrzymać drzewo T_k . Trzymamy listę miejsc gdzie kończą się sufiksy i przedłużamy je o t_k .

Algorytm korzysta z 3 własności:

- Za każdym razem gdy przedłużamy sufiks dodając nowy liść do drzewa sufikсового, możemy o tym sufiksie już zapomnieć. Przy założeniu opisu krawędzi skompresowanych za pomocą dwóch liczb (początek i koniec jakiegoś pod słowa w T) możemy jako drugiej liczby użyć $+\infty$. Zachowamy własność online algorytmu. Taka krawędź reprezentować będzie dowolny tekst zaczynający się w określonym punkcie.
- Jeśli rozważając kolejne sufiksy natrafimy na taki, którego nie musimy przedłużać, bo odpowiednia krawędź znajduje się już w drzewie, to nie musimy też przeglądać dalszych, ponieważ dla nich także odpowiednia krawędź występuje.
- Aby w razie potrzeby namierzyć kolejne miejsce wymagające rzeczywistej aktualizacji, tzn. dodania krawędzi-liścia, można zastosować w tym celu ten sam trik, co w algorytmie McCreighta. Zapamiętujemy jedynie dowiązania sufikсовe wierzchołków jawnych, a jeśli chcemy znaleźć dowiązanie wierzchołka niejawnego, to najpierw przechodzimy po dowiązaniu sufikсовym jego (jawnego) rodzica w drzewie, a następnie wykonujemy operację *fastFind*.

3.3.1 Algorytm

Pseudokod algorytmu został zaprezentowany jako algorytm 2.

Algorithm 2 Algorytm Ukkonena - konstrukcja online

```
 $T \leftarrow root$   
 $L \leftarrow root$   
for  $i = 1 \rightarrow n$  do  
  for  $j = 1 \rightarrow n$  do  
     $v \leftarrow L[j]$   
    if nie istnieje krawędź w drzewie  $T$  o etykiecie  $x_i$  wychodząca z  $v$  then  
      dodaj taką krawędź  
       $L[j] \leftarrow v'$ , gdzie  $v'$  jest wierzchołkiem docelowym krawędzi wychodzącej z  $v$  etykietowanej  $x_i$ ;  
    end if  
  end for  
   $L.push(root)$   
end for
```

3.3.2 Złożoność

Twierdzenie 2. Algorytm Ukkonena buduje drzewo sufiksowe tekstu o długości n w czasie $O(n)$, przy założeniu $|\Sigma| = O(1)$.

Dowód. Obrotów wewnętrznej pętli while mamy liniowo wiele - każdy obieg odpowiada dodaniu jednego liścia, a tych jest $O(n)$. Wszystkie operacje w pętli poza *fastFind* wykonujemy w czasie stałym. Należy zatem rozważyć łączną pracę wykonaną przez wszystkie wywołania *fastFind*. $\square$

4 Podsumowanie

4.1 Zastosowania

Drzewa sufiksowe znajdują zastosowanie między innymi w bioinformatyce, gdzie służą do analizy łańcuchów DNA i sekwencji aminokwasów w białkach, oraz w kompresji danych (modyfikacje kompresji LZW).

Literatura

- [1] Prof. Erik Demaine, <http://courses.csail.mit.edu/6.851/spring12/scribe/lec16.pdf>
- [2] http://wazniak.mimuw.edu.pl/index.php?title=Algorytmy_i_struktury_danych