

# Algorytmy i Struktury Danych

## Wyszukiwanie

(c) Marcin Sydow

# Zawartość tego wykładu:

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej

K-ty element

Partition

Algorytm  
Hoare'a

Podsumowanie

- reguła “dziel i rządź”
- wyszukiwanie
- **algorytm wyszukiwania binarnego**
- statystyki pozycyjne
- 2. najmniejsza wartość w ciągu  
(algorytm “turniejowy” - idea)
- algorytm Hoare'a  
(wyszukiwanie k-tej statystyki pozycyjnej)

# “Dziel i rządź”

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej  
K-ty element  
Partition  
Algorytm  
Hoare'a

Podsumowanie

Jest to jedna z najskuteczniejszych **technik projektowania algorytmów**. Dzielimy problem na podproblemy (czyli dane wejściowe na mniejsze części) i wyjaśniamy jak z rozwiązań tych podproblemów otrzymać rozwiązanie oryginalnego problemu.

Często jest implementowana za pomocą rekursji, czyli **techniki programowania** polegającej na wywołaniu przez funkcję jej samej dla mniejszych danych wejściowych.

Nazwa reguły zapożyczona jest z identycznie brzmiącej nazwy strategii w polityce polegającej na podzieleniu sił przeciwnika na mniejsze części, czyniąc go słabszym i bardziej podatnym na wewnętrzne konflikty.

Przypisywana oryginalnie Filipowi II Macedońskiemu, królowi Macedonii (382-336 przed Chrystusem) jest permanentnie stosowana w polityce, nie wyłączając czasu obecnego.

# Problem wyszukiwania

`search(S, len, key)`

**Input:**  $S$  - ciąg liczb całkowitych;  $len$  - długość ciągu;  $key$  (klucz) - liczba całkowita (wyszukiwana w ciągu  $S$ )

**Output:** indeks (liczba naturalna mniejsza od  $len$ ), pod którą w ciągu  $S$  znajduje się liczba  $key$  ( $S[index] == key$ ) albo  $-1$  jeśli klucz jest nieobecny w  $S$

Przykład:  $S = (3, 5, 8, 2, 1, 8, 4, 2, 9)$ :

- `search(S, 9, 2)` powinno zwrócić: 3
- `search(S, 9, 7)` powinno zwrócić: -1

# Wyszukiwanie, c.d.

Naturalnym kandydatem na **operację dominującą** w algorytmach implementujących problem wyszukiwania jest **porównanie** (pomiędzy kluczem a elementami w ciągu  $S$ ), natomiast **rozmiar danych** zawiera długość ciągu  $len$  (może też obejmować inne parametry, np. algorytm skoku  $co\ k$ )

Wyszukiwanie sekwencyjne:

Najprościej jest zrealizować algorytm wyszukiwania przez przeglądanie wszystkich indeksów np. od 0 do  $len-1$ . Taka realizacja skutkuje **liniową** pesymistyczną złożonością czasową  $W(len) = len$ .

UWAGA: Zauważmy, że pesymistycznej złożoności czasowej **nie można poprawić** zmieniając porządek przeglądania indeksów (gdyż zawsze może się zdarzyć, że np. szukany element jest pod ostatnim sprawdzanym indeksem).

# Bardziej efektywne wyszukiwanie?

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

**Posortowanie**

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej

K-ty element

Partition

Algorytm  
Hoare'a

Podsumowanie

Jaka **dotatkowa własność** ciągu mogłaby umożliwić szybsze wyszukiwanie?

# Bardziej efektywne wyszukiwanie?

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

**Posortowanie**

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej

K-ty element

Partition

Algorytm  
Hoare'a

Podsumowanie

Jaka **dotatkowa własność** ciągu mogłaby umożliwić szybsze wyszukiwanie?

**Uporządkowanie** wartości ciągu wejściowego (np. od najmniejszej do największej)

Zmienimy więc nieco specyfikację problemu, żeby opracować bardziej efektywne algorytmy.

# Wyszukiwanie w ciągu posortowanym

Zmodyfikowana specyfikacja problemu:

**Input:**  $S$  - ciąg **niemalejąco posortowanych** (tzn. mogą być powtarzające się wartości) liczb całkowitych (indeksowanych od 0);  $len$  - naturalna liczba będąca długością ciągu  $S$ ;  $key$  (klucz) - wyszukiwana liczba całkowita

**Output:** indeks (liczba naturalna mniejsza od  $len$ ), pod którą w ciągu  $S$  znajduje się liczba  $key$  albo  $-1$  jeśli klucz jest nieobecny w  $S$ .

Przy tak zmienionej specyfikacji (uporządkowanie ciągu wejściowego) można pokusić się o algorytmy o pesymistycznej złożoności czasowej lepszej niż  $W(len) = len$ .



# Algorytm skoków co k; idea i analiza

Jeśli ciąg wejściowy jest posortowany, to możliwe jest wyszukiwanie poprzez sprawdzanie co k-tego indeksu (pomijając k-1 elementów podczas każdego “skoku”). W przypadku znalezienia pierwszego elementu większego od wyszukiwanego klucza, wystarczy sprawdzić jedynie ostatnio “przeskoczone” k-1 elementów.

Zauważmy, że dla  $len \rightarrow \infty$  taki algorytm jest w przeciętnym przypadku *asymptotycznie k razy szybszy* w przeciętnym przypadku niż “normalny” algorytm sekwencyjny (dla niewielkich wartości k).

Również, przy odpowiednim doborze  $k^1$ , pesymistyczna złożoność czasowa tego algorytmu jest odpowiednio niższa:  $W(len) = \frac{1}{k} \cdot \Theta(len)$ , a więc też **k razy szybciej** niż sekwencyjnego.

Jest więc poprawa. Jednak wciąż jest to złożoność **liniowa**, czyli o tym samym **rzędzie złożoności** (czyli jeśli dane wzrosną x razy, algorytm będzie działał x razy dłużej, etc.).

Czy możliwe jest uzyskanie **niższej niż liniowa** złożoności czasowej?

<sup>1</sup>ćwiczenie: udowodnić, że zachodzi to dla  $k = \sqrt{len}$

# Algorytm Wyszukiwania Binarnego - idea

Przykład zastosowania “dziel i rządź” w wyszukiwaniu.  
`search(S, len, key)`

(wciąż zakładamy tu, że ciąg wejściowy jest posortowany niemalejąco)

Algorytm **wyszukiwania binarnego**:

- 1 dopóki długość ciągu jest dodatnia:
- 2 porównaj klucz ze środkowym elementem ciągu
- 3 jeśli jest równość, to zwróć wynik (bieżący indeks)
- 4 jeśli jest niższy niż element - ogranicz dalsze poszukiwania tylko do lewego podciągu (na lewo od bieżącego indeksu)
- 5 jeśli jest wyższy niż element - ogranicz dalsze poszukiwania tylko do prawego podciągu (na prawo od bieżącego indeksu)
- 6 wróć do kroku 1
- 7 jeśli długość ciągu spadła do zera, to nie ma klucza w ciągu

# Kod algorytmu wyszukiwania binarnego

```
search(S, len, key){  
  
    l = 0  
    r = len - 1  
  
    while(l <= r){  
        m = (l + r)/2  
        if(S[m] == key) return m  
        else  
            if(S[m] > key) r = m - 1  
            else l = m + 1  
    }  
  
    return -1  
}
```

Uwaga: zakłada się, że cały ciąg mieści się w szybkiej pamięci RAM (ang. random access memory), czyli pamięci o dostępie swobodnym, czyli, że sprawdzenie dowolnego indeksu  $S[m]$  ma czas stały (jest szybkie) i nie zależy od  $m$ .

# Analiza algorytmu wyszukiwania binarnego

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej  
K-ty element  
Partition  
Algorytm  
Hoare'a

Podsumowanie

**rozmiar danych:** długość ciągu -  $len$

**operacja dominująca:** porównanie -  $(S[m]==key)$   
(zakładamy, że cały ciąg jest w RAM)

Zauważmy, że z każdą iteracją bieżący ciąg staje się **2 razy krótszy**. Algorytm zatrzymuje się, gdy długość bieżącego ciągu spadnie do 0 (lub wcześniej znajdziemy klucz).

$$W(len) = \Theta(\log_2(len))$$

$$A(len) = \Theta(\log_2(len))$$

$$S(len) = O(1)$$

(założenie o pamięci RAM jest istotne dla faktu, że każda operacja  $S(m)==key$  ma czas stały, w przeciwieństwie do sytuacji, gdyby np. dane były na "wolnym" dysku)

# Statystyki pozycyjne

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej  
K-ty element  
Partition  
Algorytm  
Hoare'a

Podsumowanie

K-ta statystyka pozycyjna w ciągu to po prostu k-ty najmniejszy (lub największy) element w tym ciągu.

Przykład: szukanie minimum jest szczególnym przypadkiem, dla  $k=1$

W przypadku, gdy ciąg jest posortowany zadanie byłoby trywialne: wynik byłby po prostu na k-tej pozycji posortowanego ciągu.

Dlatego, w dalszej części tego wykładu powrócimy znowu do wersji wyszukiwania dla ciągów nieuporządkowanych.

# Wyszukiwanie 2-giego najmniejszego elementu w ciągu nieuporządkowanym

Algoritmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej

K-ty element

Partition

Algorytm

Hoare'a

Podsumowanie

`second(S, len)`

(uwaga: nie ma już założenia o uporządkowaniu ciągu wejściowego, ale dla uproszczenia zakładamy, że wszystkie elementy są różne)

**Input:**  $S$  - ciąg liczb całkowitych;  $len$  - długość ciągu

**Output:** drugi najmniejszy element w ciągu  $S$

Rozmiar danych:  $len$ ; operacja dominująca: porównanie

Rozwiązanie proste: znajdź minimum, usuń je z ciągu, i znajdź ponownie minimum (wymaga  $2 \cdot len - 1$  porównań)

# Wyszukiwanie 2-giego najmniejszego elementu w ciągu nieuporządkowanym

Algoritmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej

K-ty element

Partition

Algorytm

Hoare'a

Podsumowanie

`second(S, len)`

(uwaga: nie ma już założenia o uporządkowaniu ciągu wejściowego, ale dla uproszczenia zakładamy, że wszystkie elementy są różne)

**Input:**  $S$  - ciąg liczb całkowitych;  $len$  - długość ciągu

**Output:** drugi najmniejszy element w ciągu  $S$

Rozmiar danych:  $len$ ; operacja dominująca: porównanie

Rozwiązanie proste: znajdź minimum, usuń je z ciągu, i znajdź ponownie minimum (wymaga  $2 \cdot len - 1$  porównań)

Jak zrobić to używając mniejszej liczby porównań?  
(z mniejszą złożonością czasową)

# Algorytm “turniejowy” - idea

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

**Turniej**  
K-ty element  
Partition  
Algorytm  
Hoare'a

Podsumowanie

Zastosujmy regułę “dziel i rządź”:

Spójrzmy na ten problem jak na “turniej” rozgrywany przez elementy ciągu.

W każdej fazie turnieju bieżący zbiór elementów jest dzielony jest na pary elementów, które rozgrywają “grę”: mniejszy element “wygrywa” i przechodzi do następnej fazy turnieju. W ten sposób w każdej fazie pozostaje tylko ok. połowy elementów z poprzedniej fazy, dopóki nie pozostanie jeden element (“zwycięzca”) - jest to najmniejszy element w ciągu.

Gdzie jest 2-gi najmniejszy element? (którego szukamy)



# Algorytm “turniejowy” - idea

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

**Turniej**  
K-ty element  
Partition  
Algorytm  
Hoare'a

Podsumowanie

Zastosujmy regułę “dziel i rządź”:

Spójrzmy na ten problem jak na “turniej” rozgrywany przez elementy ciągu.

W każdej fazie turnieju bieżący zbiór elementów jest dzielony jest na pary elementów, które rozgrywają “grę”: mniejszy element “wygrywa” i przechodzi do następnej fazy turnieju. W ten sposób w każdej fazie pozostaje tylko ok. połowy elementów z poprzedniej fazy, dopóki nie pozostanie jeden element (“zwycięzca”) - jest to najmniejszy element w ciągu.

Gdzie jest 2-gi najmniejszy element? (którego szukamy)

Odpowiedź: pomiędzy elementami, które grały (i przegrały) ze “zwycięzcą” (tylko z nim mógł przegrać). Wystarczy więc w drugiej fazie przeszukać te elementy aby znaleźć wynik.

# Analiza algorytmu turniejowego

Turniej może być naturalnie przedstawiony w postaci drzewa binarnego, gdzie na najniższym poziomie (liście) są wszystkie elementy oryginalnego ciągu a na górze (korzeń) jest zwycięzca. Każdy poziom odpowiada kolejnej fazie turnieju. Ile jest poziomów (jako funkcja  $n$ )?

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

**Turniej**

K-ty element

Partition

Algorytm  
Hoare'a

Podsumowanie

# Analiza algorytmu turniejowego

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

**Turniej**

K-ty element

Partition

Algorytm

Hoare'a

Podsumowanie

Turniej może być naturalnie przedstawiony w postaci drzewa binarnego, gdzie na najniższym poziomie (liście) są wszystkie elementy oryginalnego ciągu a na górze (korzeń) jest zwycięzca. Każdy poziom odpowiada kolejnej fazie turnieju. Ile jest poziomów (jako funkcja  $len$ )?

$\Theta(\log_2(len))$  (bo każdy poziom zawiera 2 razy mniej elementów niż niższy)

**Rozmiar danych:**  $len$

**Operacja dominująca:** porównanie między 2 elementami

Ile jest wszystkich porównań w pierwszej fazie turnieju?

# Analiza algorytmu turniejowego

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

**Turniej**

K-ty element

Partition

Algorytm

Hoare'a

Podsumowanie

Turniej może być naturalnie przedstawiony w postaci drzewa binarnego, gdzie na najniższym poziomie (liście) są wszystkie elementy oryginalnego ciągu a na górze (korzeń) jest zwycięzca. Każdy poziom odpowiada kolejnej fazie turnieju. Ile jest poziomów (jako funkcja  $len$ )?

$\Theta(\log_2(len))$  (bo każdy poziom zawiera 2 razy mniej elementów niż niższy)

**Rozmiar danych:**  $len$

**Operacja dominująca:** porównanie między 2 elementami

Ile jest wszystkich porównań w pierwszej fazie turnieju?

**$len-1$**  (dlaczego?)

# Analiza algorytmu turniejowego

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

**Turniej**  
K-ty element  
Partition  
Algorytm  
Hoare'a

Podsumowanie

Turniej może być naturalnie przedstawiony w postaci drzewa binarnego, gdzie na najniższym poziomie (liście) są wszystkie elementy oryginalnego ciągu a na górze (korzeń) jest zwycięzca. Każdy poziom odpowiada kolejnej fazie turnieju. Ile jest poziomów (jako funkcja  $len$ )?

$\Theta(\log_2(len))$  (bo każdy poziom zawiera 2 razy mniej elementów niż niższy)

**Rozmiar danych:**  $len$

**Operacja dominująca:** porównanie między 2 elementami

Ile jest wszystkich porównań w pierwszej fazie turnieju?

**$len-1$**  (dlaczego?) (bo z każdym porównaniem odpada dokładnie jeden element, a na końcu zostaje 1 element)

W drugiej fazie należy jeszcze wyszukać najmniejszy element spośród tych, które przegrały ze zwycięzcą (jest ich tyle ile poziomów turnieju)  
Ostatecznie:  $W(len) = len - 1 + \Theta(\log_2(len))$  - jest to więc asymptotycznie 2 razy szybciej niż dwukrotne szukanie minimum.

# K-ta statystyka pozycyjna - Algorytm Hoare'a (idea)

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej

**K-ty element**

Partition

Algorytm  
Hoare'a

Podsumowanie

`kthSmallest(S, len, k)`

(nic nie zakładamy o ciągu  $S$ , może być nieuporządkowany)

**Input:**  $S$  - ciąg liczb całkowitych;  $len$  - długość ciągu;  $k$  - liczba naturalna dodatnia ( $k \leq len$ ) (

**Output:** element  $s$ , który jest  $k$ -tym najmniejszym elementem w ciągu  $S$

Rozwiązanie naiwne:  $k$  razy wyszukujemy element minimalny oznacza to ok.  $k \cdot len$  porównań.

Jednak zadanie może być znowu rozwiązane efektywniej za pomocą podejścia “dziel i rządź”

# Procedura Partition

Algotymy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej  
K-ty element

**Partition**  
Algorytm  
Hoare'a

Podsumowanie

Przedstawimy teraz pewną pomocniczą procedurę:

`partition(S, l, r)`

**input:**  $S$  - ciąg liczb całkowitych;  $l, r$  - lewy i prawy skrajny indeks aktualnie przetwarzanego podciągu ciągu  $S$ .

**output:**  $i$  - finalna pozycja elementu "medianowego" (opis poniżej)

Działanie procedury: bierze dowolny (pierwszy) element ciągu  $m$ ,  $i$  przestawia wszystkie elementy ciągu tak, że wszystkie elementy na lewo od elementu  $m$  są niewiększe (ale niekoniecznie posortowane) od niego a na prawo niemniejsze. Zwraca ostateczną pozycję  $i$  elementu  $m$ .

# Wykorzystanie procedury Partition

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie

Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej

K-ty element

**Partition**

Algorytm  
Hoare'a

Podsumowanie

Uwaga: dzięki powyższej specyfikacji, jeśli zwrócony indeks wynosiłby dokładnie  $k$ , to musi on zawierać  $k$ -ty najmniejszy element ciągu. (założmy dla uproszczenia, że indeksujemy ciąg od 0)

Jeśli natomiast indeks  $i$  jest mniejszy od  $k$ , to należy powtórzyć działanie partition na części podciągu na prawo od  $i$  a w przeciwnym wypadku na lewo od  $i$  (“dziel i rządź”).

Jest to nieco podobny pomysł do wyszukiwania binarnego, ale tym razem  $i$  nie musi być ( $i$  rzadko jest) dokładnie w połowie ciągu.



# Analiza procedury partition

Algorytmy i  
Struktury  
Danych

(c) Marcin  
Sydow

Dziel i rządź

Wyszukiwanie

Posortowanie  
Algorytm  
skoków

Wyszukiwanie  
Binarne

Statystyki  
pozycyjne

Turniej  
K-ty element

**Partition**  
Algorytm  
Hoare'a

Podsumowanie

Kod procedury podany będzie w innym wykładzie (przy okazji algorytmu QuickSort, gdzie również jest wykorzystywana).

Natomiast ważne jest, że przy założeniach:

- **Operacja dominująca:** porównanie 2 elementów
- **Rozmiar danych:** długość oryginalnego ciągu  
$$n = (r - l + 1)$$

Procedura partition może być nietrudno zaprojektowana ze złożonością  $W(n) = n + O(1)$  (i  $S(n) = O(1)$ )

# Algorytm Hoare'a

(szybkie znajdowanie  $k$ -tego najmniejszego elementu w ciągu)

- wykonaj `partition` na ciągu
- jeśli zwrócony indeks  $i$  jest równy  $k$ , to koniec (zwróć:  $S[k]$ )
- w przeciwnym wypadku kontynuuj, na podciągu na lewo lub prawo (w zależności od porównania  $i$  z  $k$ ) od wartości  $k$ , dopóki zwrócony indeks nie wyniesie dokładnie  $k$

Dzięki liniowej złożoności procedury `partition`, *przeciętna* złożoność algorytmu Hoare'a jest liniowa ( $\Theta(n)$ ) **niezależnie od wartości  $k$** .

Uwaga: procedura `partition` ma jeszcze ważniejsze zastosowanie w innym algorytmie: sortowania szybkiego (QuickSort), omawianym w innym wykładzie.

# Przykładowe pytania/problemy:

- podaj specyfikację problemu wyszukiwania klucza w ciągu
- algorytm skoków co k: podaj specyfikację, opisz działanie, dokonaj analizy poprawności i złożoności czasowej i zasymuluj jego działanie na danych wejściowych
- algorytm **wyszukiwania binarnego**: podaj specyfikację, opisz działanie, napisz z pamięci kod (wersja z wykładu), dokonaj analizy poprawności i złożoności, zasymuluj działanie na danych wejściowych.
- co to jest statystyka pozycyjna?
- algorytm turniejowy: specyfikacja, opis działania, analiza złożoności
- podaj specyfikację i złożoność czasową procedury Partition
- opisz ideę algorytmu Hoare'a.
- dlaczego algorytm Hoare'a ma **kwadratową** pesymistyczną złożoność czasową?

Dziękuję za uwagę