

Temat: Struktury drzewiste

1. Struktura słownika

Struktura danych = system relacyjny $\langle U, \{r_i\}_{i \in I} \rangle$

U – uniwersum systemu

$\{r_i\}_{i \in I}$ - zbiór relacji (operacji) na strukturze danych

Formalna definicja struktury danych składa się z :

- sygnatury systemu relacyjnego,
- sygnatur wszystkich operacji struktury
- specyfikacji (opisu) operacji struktury

Def. Strukturą słownika nazywamy system:

$$\langle E \cup D, search, insert, delete \rangle$$

gdzie:

E - niepusty zbiór możliwych danych

D - niepusty zbiór zwany zbiorem słowników

$$search: E \times D \rightarrow Boolean$$

$$insert: E \times D \rightarrow D$$

$$delete: E \times D \rightarrow D$$

(*Boolean* – typ logiczny o wartościach *true* i *false*)

Specyfikacja operacji słownikowych

1. Operacja $search(e, d)$ –zwraca wartość *true*, gdy element e znajduje się w słowniku d , a *false* w przypadku przeciwnym.
2. Operacja $insert(e, d)$ – wstawia element e do słownika d , o ile $search(e, d) = false$.
3. Operacja $delete(e, d)$ – usuwa element e ze słownika d , o ile $search(e, d) = true$.

2. Implementacje słownika w strukturach liniowych

a) Implementacja tablicowa – tablica nieuporządkowana

- n - rozmiar słownika:
- operacja elementarna - porównania

Koszt pesymistyczny:

$$T_{\max}^{search}(n) = T_{\max}^{insert}(n) = T_{\max}^{delete}(n) = \Theta(n)$$

Koszt średni:

$$T_{\acute{s}r}^{search}(n) = T_{\acute{s}r}^{insert}(n) = T_{\acute{s}r}^{delete}(n) = \Theta(n)$$

b) Implementacja tablicowa – tablica uporządkowana

- n - rozmiar słownika:
- operacja elementarna - porównania

Koszt pesymistyczny:

$$T_{\max}^{search}(n) = T_{\max}^{insert}(n) = T_{\max}^{delete}(n) = \Theta(\log n)$$

Koszt średni:

$$T_{\acute{s}r}^{search}(n) = T_{\acute{s}r}^{insert}(n) = T_{\acute{s}r}^{delete}(n) = \Theta(\log n)$$

Ale !!! Trzeba przyjąć, że operacją elementarną przy realizacji operacji *insert* oraz *delete* są przestawienia elementów tablicy.

Wówczas:

$$T_{\max}^{search}(n) = \Theta(\log n), T_{\max}^{insert}(n) = T_{\max}^{delete}(n) = \Theta(n)$$

$$T_{\acute{s}r}^{search}(n) = \Theta(\log n), T_{\acute{s}r}^{insert}(n) = T_{\acute{s}r}^{delete}(n) = \Theta(n)$$

c) Implementacja listowa

- operacja elementarna: porównania

Koszt pesymistyczny:

$$T_{\max}^{\text{search}}(n) = T_{\max}^{\text{insert}}(n) = T_{\max}^{\text{delete}}(n) = \Theta(n)$$

Koszt średni:


$$T_{\text{śr}}^{\text{search}}(n) = T_{\text{śr}}^{\text{insert}}(n) = T_{\text{śr}}^{\text{delete}}(n) = \Theta(n)$$

3. Drzewo BST (z ang. *Binary Search Tree*)

Def. Drzewo BST to drzewo binarne z relacją porządku symetrycznego

Def. Drzewo binarne to graf skierowany, bez cykli, z wyróżnionym węzłem zwanym korzeniem drzewa. Każdy z węzłów drzewa ma stopień równy co najwyżej dwa. Do każdego z węzłów oprócz korzenia dochodzi dokładnie jedna krawędź.

Nazewnictwo:



r - korzeń drzewa –węzeł, który nie ma poprzednika (ojca)

s - lewy potomek (syn) węzła r

v – prawy potomek (syn) węzła r

t -liść-węzeł, który nie ma ani lewego ani prawego potomka (syna)

s - korzeń lewego poddrzewa węzła r

v – korzeń prawego poddrzewa węzła r

głębokość węzła – numer poziomu, na którym leży węzeł w drzewie.

ozium korzenia ma numer 0. Węzły s i v leżą na poziomie numer 1.

r-s-t – przykład ścieżki w drzewie

długość ścieżki – numer poziomego liścia w ścieżce

wysokość drzewa – numer poziomego liścia w najdłuższej ścieżce.

Wysokość drzewa na rysunku wynosi 2.

Def. Porządek symetryczny polega na tym, że dla każdego węzła drzewa x drzewa jest spełniony następujący warunek:

Jeżeli y leży w lewym poddrzewie x , to $key(y) \leq key(x)$.

Jeżeli y leży w prawym poddrzewie x , to $key(x) \leq key(y)$.



Relacja \leq jest relacją porządku liniowego, a $key(x)$ – jest wartością pola (klucza) danych, na którym relacja \leq jest określona.

Będziemy zakładali w dalszych rozważaniach, że dane umieszczane w drzewie to liczby całkowite.

Przykład

Węzeł drzewa BST to adres na strukturę (rekord) z polami:

- *dane* – pole do przechowywania danych,
- *left*, *right* – adresy węzłów potomnych



r – korzeń drzewa

4. Algorytmy operacji słownikowych na drzewie BST

a) Operacja *search*

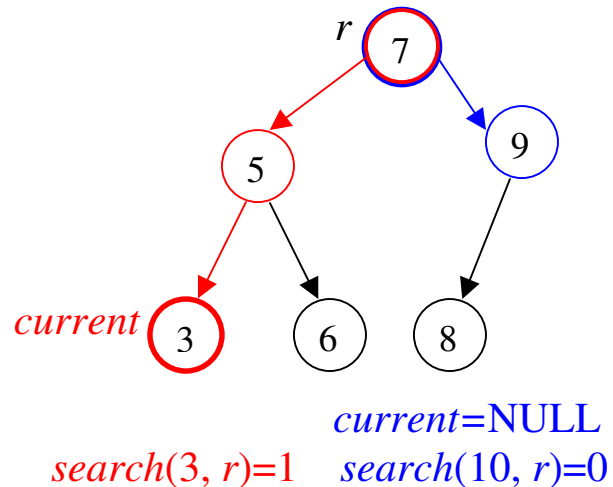
$search(e, r)$; e – liczba szukana, r – korzeń drzewa

$search(e, r) = 1$, gdy e jest w słowniku,
 $search(e, r) = 0$, gdy e nie należy do słownika

```

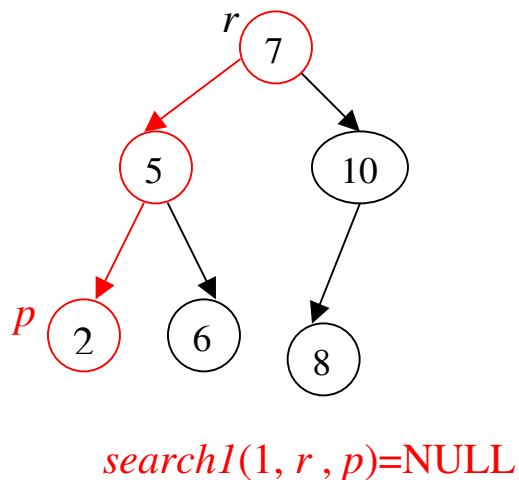

current=r;
while (current!=NULL)
  if (current->dane==e)
    return 1;
  else
    if (current->dane>e)
      current=current->left
    else current=current->right
if (current==NULL) return 0;

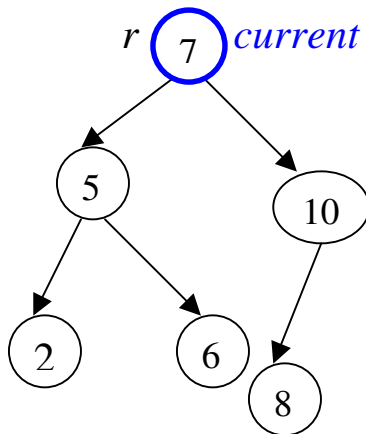
```



W implementacji operacji *insert* i *delete* niezwykle przydatna okazuje się zmodyfikowana funkcja *search1*, która zwraca adres węzła, w którym znajduje się poszukiwany element e oraz dodatkowo adres p – ojca węzła z daną e . W szczególności, gdy wynikiem funkcji jest korzeń drzewa r , to p jest adresem pustym. Gdy danych e nie ma w słowniku, to zwracany jest adres pusty, a p ustawia się na adresie „potencjalnego ojca” węzła z daną e .

$search1(e, r, p)$;





$current=search1(7, r, p)$


$p=NULL$

b) Operacja *insert*

$insert(e, r);$


Przypadki:

- drzewo jest puste,



$insert(7, r)$

- dana e już jest w słowniku – wówczas drzewo się nie zmienia
- dana e jeszcze nie znajduje się w słowniku – wówczas nowy węzeł z daną e jest “podwiązywany do drzewa” jako liść i odpowiedni (lewy albo prawy) potomek węzła p zwróconego w funkcji *search1*.



c) operacja *delete*


delete (*e*, *r*);

Przypadki:

- Element *e* nie należy do słownika.
Wywołanie funkcji *search1*(*e*, *r*, *p*) zwraca wówczas adres pusty.
Słownik w tym przypadku nie zmienia się po wykonaniu operacji *delete*.
- Element *e* znajduje się w korzeniu drzewa i korzeń drzewa jest jedynym węzłem drzewa. Wywołanie funkcji *search1*(*e*, *r*, *p*) zwraca wówczas adres *r* i adresy *left* i *right* w korzeniu *r* są puste.
Słownik w tym przypadku staje się pusty do wykonaniu operacji *delete*.

Przed *delete*(7, *r*)


Po *delete*(7, *r*)

r 


r = NULL

- Element e znajduje się w węźle o adresie v i węzeł v ma puste lewe albo prawe podrzewo. Wywołanie funkcji $\text{search1}(e, r, p)$ zwraca wtedy adres niepusty v i albo adres left albo right w węźle v jest pusty. Ustalmy, że adres right w węźle v jest pusty. Wówczas nowym potomkiem węzła p będzie lewy potomek usuwanego węzła v .
Może się zdarzyć, że korzeń drzewa musi być uaktualniony w tym przypadku. Zachodzi to wtedy, gdy $v=r$.

Przed $\text{delete}(7, r)$



Po $\text{delete}(7, r)$




- Element e znajduje się w węźle o adresie v i węzeł v ma niepuste lewe albo prawe poddrzewo. Wywołanie funkcji $search1(e, r, p)$ zwraca wtedy adres niepusty v adresy $left$ i $right$ w węźle v są niepuste.


Ustalamy wówczas adres takiego węzła, który zawiera największy element lewego poddrzewa węzła v albo najmniejszy element prawego poddrzewa węzła v . Oznaczmy znaleziony węzeł przez f . Dane z węzła f kopiujemy do węzła v , a sam węzeł f usuwamy wg algorytmu z poprzedniego przypadku, gdyż ma on na pewno puste co najmniej jedno z poddrzew.

Może się zdarzyć, że korzeń drzewa musi być uaktualniony w tym przypadku. Zachodzi to wtedy, gdy $v=r$.

Przed $delete(7, r)$



Po $delete(7, r)$



5. Koszt operacji słownikowych na drzewie BST

Operacja elementarna: porównania między elementem wstawianym, wyszukiwanym lub usuwanym, a elementami słownika.

Rozmiar zadania: n – ilość danych w słowniku przed realizacją operacji słownikowej.

Koszt operacji słownikowych zasadniczo zależy od kosztu operacji $search$ ($search1$):


Koszt $search$:

- pesymistyczny $T_{\max}(n) = n = \Theta(n)$ - przypadek drzewa zdegenerowanego
- średni $O(\log n)$ – określony na podstawie wyników eksperymentów, ale nie udowodniony.


6. Drzewa AVL

Nazwa drzewo AVL pochodzi od nazwisk dwóch specjalistów teorii algorytmów i struktur danych: Adelsona-Velskii i Landisa.

Def. Drzewo AVL to wyważone drzewo BST. Drzewo jest wyważone, kiedy dla każdego wierzchołka, wysokości dwóch jego poddrzew różnią się co najwyżej o jeden.



Drzewo wyważone



Drzewo, które nie jest wyważone

7. Wysokość drzewa AVL

Lemat

Wysokość drzewa AVL o n wierzchołkach ($n \geq 1$) jest nie większa niż $2 \log_2 n$.

Dowód:

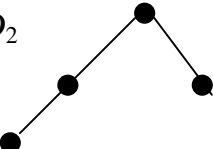
Niech D_h będzie drzewem AVL o wysokości h , które ma najmniejszą, możliwą liczbę wierzchołków wśród drzew AVL o wysokości h .

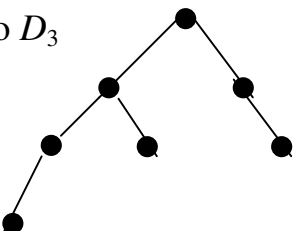
Niech n_h będzie liczbą wierzchołków w drzewie D_h .

Gdy:


$h = 0$, to D_0 ● $n_0 = 1$

$h = 1$, to D_1  $n_1 = 2$

$h = 2$, to D_2  $n_2 = 4$

$h = 3$, to D_3  $n_3 = 7$

Ogólnie:



$$n_h = n_{h-1} + n_{h-2} + 1$$

Udowodnimy przez indukcję, że:

$$n_h \geq 2^{\frac{h}{2}} \quad \text{dla } h > 1$$

Założenie indukcyjne:

$$n_{h-1} \geq 2^{\frac{h-1}{2}}$$


$$n_h = n_{h-1} + n_{h-2} + 1 \geq 2^{\frac{h-1}{2}} + 2^{\frac{h-2}{2}} + 1 = 2^{\frac{h}{2}} \cdot 2^{-\frac{1}{2}} + 2^{\frac{h}{2}} \cdot 2^{-1} + 1 = 2^{\frac{h}{2}} \left(\frac{1}{\sqrt{2}} + \frac{1}{2} \right) + 1 \geq 2^{\frac{h}{2}}$$

Czyli $\log_2 n_h \geq \frac{1}{2}h$


Stąd $h \leq 2 \log_2 n_h$

8. Budowa węzła drzewa AVL

Struktura węzła drzewa AVL jest wzbogacona o wagę w taką, że: $w(\text{drzewo_puste}) = -1$, $w(v) = h(L) - h(P)$, gdzie $h(L)$ i $h(P)$ to odpowiednio wysokość lewego i prawego poddrzewa węzła v .



Przykład wartości wagi w dla węzłów drzewa o korzeniu r




9. Operacje słownikowe na drzewie AVL

- $search(e, d)$ - operacja realizowana tak samo jak dla drzewa BST
- $insert(e, d)$ - operacja realizowana w pierwszej fazie tak samo jak dla drzewa BST. Druga faza to ewentualne wyważenie powstałego drzewa.
- $delete(e, d)$ - operacja realizowana w pierwszej fazie tak samo jak dla drzewa BST. Druga faza to ewentualne wyważenie powstałego drzewa.

Podczas realizacji pierwszej fazy operacji $insert$ i $delete$ należy na stosie odłożyć adresy węzłów ze ścieżki, którą „odwiedza” wywołanie funkcji $search1$. Stos jest niezbędny do zrealizowania drugiej fazy algorytmu, tj. sprawdzenia warunku wyważenia na podstawie wag węzłów ze stosu. Zatem funkcja $search1$ zwracać powinna, w przypadku drzew AVL, adres wierzchołka takiego stosu, zamiast adresu p .

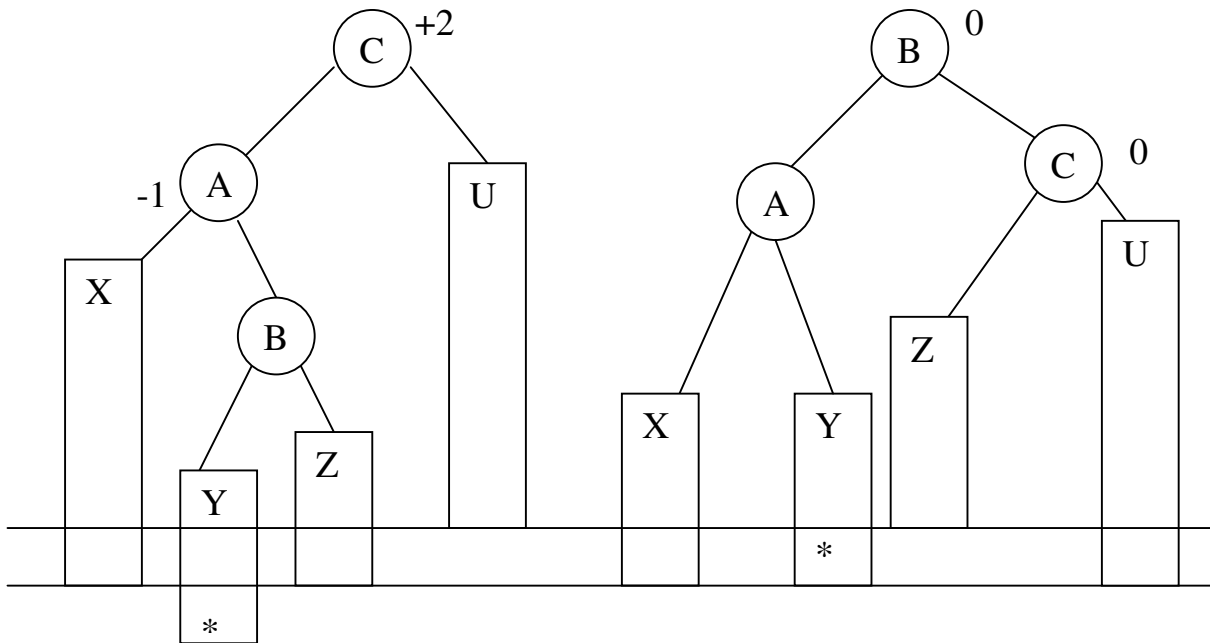
10. Rotacje prowadzące do wyważenia drzewa po usunięciu albo wstawieniu elementu

Rotacje w prawo



pojedyncza rotacja w prawo względem B


+2; -1



podwójna rotacja w prawo: rotacja pojedyncza w lewo względem A i pojedyncza w prawo względem C


Rotacje w lewo

-2; -1



pojedyncza rotacja w lewo względem B

-2; +1



rotacja podwójna w lewo: pojedyncza w prawo względem A
i pojedyncza w lewo względem C

Uwaga

Rotacje w procesie wyważania wykonywane są tylko na jednej ścieżce w drzewie.

- Operacja *delete* realizowana na drzewie AVL wymaga wykonania co najwyżej $2\log_2 n$ rotacji.
- Operacja *insert* realizowana na drzewie AVL wymaga wykonania co najwyżej jednej rotacji.
- Może się zdarzyć, że po zrealizowaniu pierwszej fazy operacji *delete* znajdzie konieczność wykonania rotacji o układzie wag $+2;0$ albo $-2;0$. Wykonujemy wówczas odpowiednio pojedyncza rotacje w lewo albo prawo względem węzła z wagą odpowiednio $+2$ albo -2 .

Wniosek

Ponieważ drzewo AVL ma pesymistyczną wysokość $O(\log n)$, a ewentualne rotacje wykonywane podczas wstawiania albo usuwania elementów realizowane są kosztem $O(\log n)$, to operacje słownikowe zrealizowane na drzewie AVL mają koszt pesymistyczny $O(\log n)$.