

Sortowanie przez porównywanie

Działanie poznanych dotychczas algorytmów sortowania oparte było na porównywaniu elementów. W omawianych przykładach sortowanymi elementami były liczby, ale w ogólności mogły to być dowolne elementy, które daje się porównać: napisy tekstowe sortowane alfabetycznie, dane o miastach sortowane liczbą ludności, dane o statkach sortowane wypornością, itp. Najlepsze poznane algorytmy sortowania przez porównywanie działają w czasie $\Theta(n \log n)$, i można udowodnić, że dowolny algorytm sortujący przez porównywanie ma czas działania w najgorszym przypadku $\Omega(n \log n)$.

Jednak w pewnych przypadkach można uzyskać lepsze czasy sortowania. Dzieje się tak w sytuacjach kiedy nie ma potrzeby porównywania ze sobą wszystkich elementów. W tych sytuacjach można osiągnąć sortowanie w czasie liniowym $\Theta(n)$.

Typowa sytuacją tego typu zachodzi na przykład, gdy sortowaniu podlega zbiór liczb z określonego, znanego przedziału. Ich posortowanie nie wymaga porównywania każdej wartości z każdą, ponieważ sprawdzenie pojedynczego elementu dostarcza już dość konkretnej informacji o jej położeniu w docelowej sekwencji.

Sortowanie przez zliczanie

Algorytm **sortowania przez zliczanie** (*counting sort*) zakłada, że elementy do posortowania są liczbami całkowitymi w przedziale $[0..k]$. Algorytm działa w czasie $\Theta(n + k)$, a więc gdy k jest ograniczoną liczbą, nieprzekraczającą $O(n)$ to algorytm działa w czasie $\Theta(n)$.

Algorytm najpierw oblicza, dla każdego elementu x ciągu wejściowego, ile elementów nie przekracza wartości x . Na tej podstawie wyznaczana jest pozycja każdego elementu w docelowej sekwencji.

Na przykład, jeśli wiemy, że 17 elementów jest mniejsze lub równe wartości x , to x powinno znaleźć się na pozycji 17-tej.

Ta idea działania algorytmu wymaga pewnego uzupełnienia dla uwzględnienia przypadku, że wiele elementów może mieć tę samą wartość. Te szczegóły ilustruje pseudokod algorytmu.

COUNTING-SORT(A, n, k)

```
1  let  $B[1 : n]$  and  $C[0 : k]$  be new arrays
2  for  $i = 0$  to  $k$ 
3       $C[i] = 0$ 
4  for  $j = 1$  to  $n$ 
5       $C[A[j]] = C[A[j]] + 1$ 
6  //  $C[i]$  now contains the number of elements equal to  $i$ .
7  for  $i = 1$  to  $k$ 
8       $C[i] = C[i] + C[i - 1]$ 
9  //  $C[i]$  now contains the number of elements less than or equal to  $i$ .
10 // Copy  $A$  to  $B$ , starting from the end of  $A$ .
11 for  $j = n$  downto 1
12      $B[C[A[j]]] = A[j]$ 
13      $C[A[j]] = C[A[j]] - 1$  // to handle duplicate values
14 return  $B$ 
```

W kroku 12 algorytm umieszcza wartość $A[j]$ na swoim właściwym miejscu w tablicy B zgodnie z ideą z poprzedniej strony. Następnie w kroku 13 dekrementuje ten numer pozycji, aby następna instancja wartości $A[j]$, jeśli taka istnieje w tablicy A , znalazła się na wcześniejszej pozycji w B .

Przykład wykonania algorytmu COUNTING-SORT: (a) tablica A i zawartość tablicy C po wykonaniu kroków 4-5, (b) zawartość tablicy C po wykonaniu kroków 7-8, (c),(d),(e) zawartości tablic B i C po jedno-, dwu-, i trzykrotnym wykonaniu pętli w krokach 11-13, (f) zawartość tablicy B po zakończeniu pracy algorytmu.

	1	2	3	4	5	6	7	8
A	2	5	3	0	2	3	0	3

	0	1	2	3	4	5
C	2	0	2	3	0	1

(a)

	0	1	2	3	4	5
C	2	2	4	7	7	8

(b)

	1	2	3	4	5	6	7	8
B							3	

	0	1	2	3	4	5
C	2	2	4	6	7	8

(c)

	1	2	3	4	5	6	7	8
B		0					3	

	0	1	2	3	4	5
C	1	2	4	6	7	8

(d)

	1	2	3	4	5	6	7	8
B		0				3	3	

	0	1	2	3	4	5
C	1	2	4	5	7	8

(e)

	1	2	3	4	5	6	7	8
B	0	0	2	2	3	3	3	5

(f)

Ćwiczenie: przedstaw zawartość tablic B i C po dalszych wykonaniach pętli w krokach 11-13.

Własności sortowania przez zliczanie

Jak powiedzieliśmy na początku, algorytm COUNTING-SORT działa w czasie $\Theta(n + k)$, co widać w zapisie algorytmu, który wykonuje dwie pętle n razy i dwie pętle k razy. W praktycznych przypadkach wartość k jest często ograniczona, a więc przyjmując $k = O(n)$ czas działania wynosi $\Theta(n)$.


Ten liniowy czas działania wynika z braku porównań. Algorytm nie musi wykonywać wielu operacji dla każdego elementu sekwencji wejściowej, a więc może działać w czasie liniowym.

COUNTING-SORT jest również algorytmem **stabilnym**, to znaczy, równe elementy ciągu wejściowego znajdą się w ciągu wyjściowym w tej samej kolejności. Ta własność może mieć znaczenie dla niektórych zastosowań, i zobaczymy przykład wykorzystania tej własności algorytmu jako procedury użytej w kolejnym algorytmie sortowania (sortowaniu pozycyjnym).

Sortowanie pozycyjne

Rozważmy zadanie sortowania zbioru trzycyfrowych liczb jak na rysunku po lewej. Moglibyśmy wykorzystać ideę sortowania zbioru liczb o małym zakresie wartości aby sortować te liczby kolejno po cyfrach w kolejnych pozycjach. (Zakres wartości cyfr na kolejnych pozycjach jest 0..9.)

Jednak po posortowaniu pierwszej, najbardziej znaczącej, cyfry, otrzymamy dziesięć podzbiorów do dalszego posortowania, a po posortowaniu po drugiej cyfrze, już sto oddzielnych podzbiorów do sortowania, i tak dalej.



Zamiast tego, algorytm **sortowania pozycyjnego** sortuje cyfry w kolejności **od najmniej do najbardziej znaczącej pozycji**, a więc jakby trochę nielogicznie.

Gdy jednak do tego sortowania wykorzystamy stabilny algorytm sortowania, to po presortowaniu zbioru po najmniej znaczącej cyfrze, sortowanie po drugiej z kolei przemiesza tylko wartości różniące się drugą cyfrą, ale te o równej drugiej cyfrze pozostaną w już ustalonej kolejności.

Zapis algorytmu realizującego tę ideę jest dość trywialny:

```
RADIX-SORT( $A, n, d$ )
```

```
1  for  $i = 1$  to  $d$ 
```

```
2      use a stable sort to sort array  $A[1 : n]$  on digit  $i$ 
```


Jeśli w roli wewnętrznej procedury sortowania stabilnego zostanie użyte sortowanie przez zliczanie, to można dokonać dodatkowej optymalizacji współpracy tych algorytmów. W czasie pracy COUNTING-SORT alokuje dwie tablice robocze: $B[1 : n]$ i $C[0 : k]$. Tablica C może być prealokowana na wszystkie kolejne wywołania sortowania stabilnego, aczkolwiek ta tablica jest normalnie mniejsza, oraz i tak wymaga wyzerowania przy każdym wywołaniu, więc ta prealokacja zaoszczędzi niewiele.

Jednak tablica B jest z założenia większa, i jest tworzona dla przechowania kolejno otrzymywanych wyników. Zamiast więc pozwolić procedurze COUNTING-SORT każdorazowo tworzyć tablicę wynikową B i w każdym kolejnym wywołaniu przekopiowywać wyniki B z poprzedniego wywołania do tablicy A w nowym wywołaniu, można prealokować obie tablice A i B w procedurze RADIX-SORT, i w kolejnych wywołaniach COUNTING-SORT zamieniać tablice wejściową i wyjściową.

Sortowanie kubełkowe

Sortowanie kubełkowe zakłada, że wartości do sortowania są liczbami losowo wybranymi z pewnego przedziału w rozkładzie równomiernym. Dla uproszczenia można założyć, że będzie to przedział $[0..1)$ (wartość 1 jest wyłączona).

Algorytm rozdziela liczby ze zbioru wejściowego do n równych przedziałów, zwanych **kubełkami** (*buckets*). Gdyby liczby były rzeczywiście równomiernie rozłożone, to do każdego kubełka trafiłaby dokładnie jedna liczba. Jednak przy losowym wyborze sytuacja może być taka jak na przykładowym rysunku:



Po podziale, wszystkie kubełki są indywidualnie sortowane dowolnym algorytmem porównującym (np. INSERT-SORT), i ich zawartości są kolejno wysyłane na wyjście.

Pseudokod algorytmu:

```
BUCKET-SORT( $A, n$ )
1  let  $B[0 : n - 1]$  be a new array
2  for  $i = 0$  to  $n - 1$ 
3      make  $B[i]$  an empty list
4  for  $i = 1$  to  $n$ 
5      insert  $A[i]$  into list  $B[\lfloor n \cdot A[i] \rfloor]$ 
6  for  $i = 0$  to  $n - 1$ 
7      sort list  $B[i]$  with insertion sort
8  concatenate the lists  $B[0], B[1], \dots, B[n - 1]$  together in order
9  return the concatenated lists
```

Jest niemal oczywiste, że w najgorszym wypadku algorytm działa w czasie $\Theta(n^2)$. Może się bowiem zdarzyć, że wszystkie liczby trafią do jednego kubeczka, i potrzeba będzie $\Omega(n^2)$ czasu by je posortować.

Jednak interesujący jest przypadek średni. Można udowodnić, że przy losowym, równomiernym rozkładzie liczb, wartość oczekiwana czasu pracy algorytmu jest $\Theta(n)$.

Ponieważ sortowanie przez wstawianie jest stabilne, sortowanie kubełkowe jest również.

Krótkie podsumowanie — pytania sprawdzające

1. Wzorując się na rysunkach z przykładu na stronie 5, przedstaw kolejne kroki wykonania algorytmu COUNTING-SORT na tablicy $A = \{6, 0, 2, 0, 1, 3, 4, 6, 3, 2\}$.
2. Wzorując się na rysunkach z przykładu na stronie 7, przedstaw kolejne etapy wykonania algorytmu RADIX-SORT na ciągu słów: COW, DOG, SEA, RUG, ROW, MOB, BOX, TAB, BAR, EAR, TAR, DIG, BIG, TEA, NOW, FOX.
3. Wzorując się na rysunkach z przykładu na stronie 9, przedstaw działanie algorytmu BUCKET-SORT na tablicy $A = \{0.79, 0.13, 0.16, 0.64, 0.39, 0.20, 0.89, 0.53, 0.71, 0.42\}$.

Literatura i materiały pomocnicze

1. Thomas H. Cormen, Charles E. Leiserson, Ronald L Rivest, Clifford Stein:
Wprowadzenie do algorytmów, PWN, 2024, rozdział 8.