

アルゴリズムとデータ構造

第9回: ソーティング(1)

担当: 上原隆平(uehara)

2014/05/13

ソーティング (Sorting)

- 与えられたデータを順序よく並べる

- 数値データ: 昇順、降順

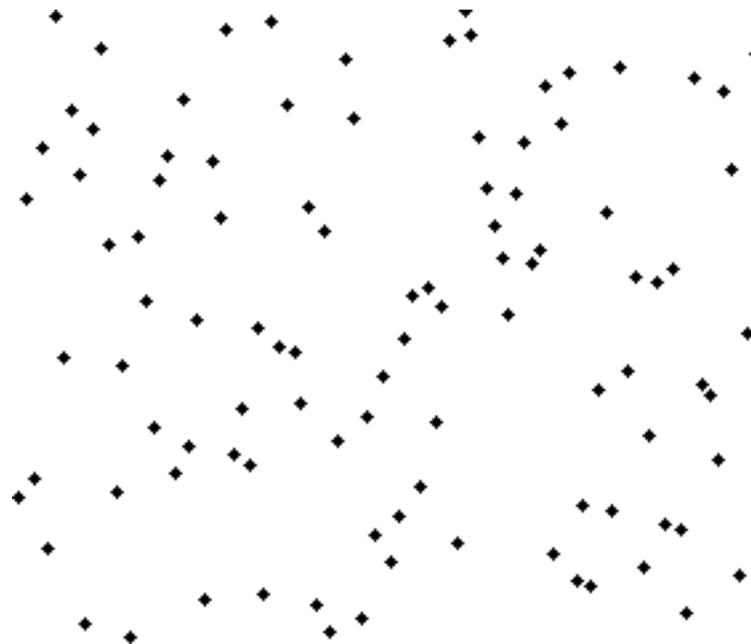
65	12	46	97	56	33	75	53	21	入力データ
12	21	33	46	53	56	65	75	93	昇順ソート
93	75	65	56	53	46	33	21	12	降順ソート

- 文字列データ: 辞書式順序

e.g., aaa, aab, aba, abb, baa, bab, bbc, bcb

- ソーティングアルゴリズム

- バブルソート, インサージョンソート, シェルソート, ヒープソート, クイックソート, マージソート, トポロジカルソート

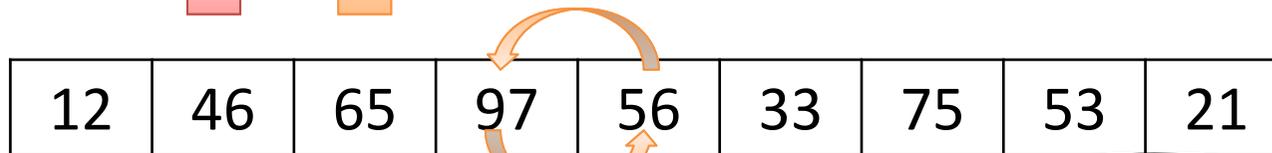
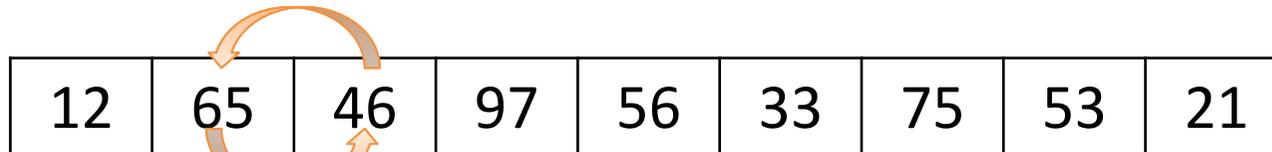
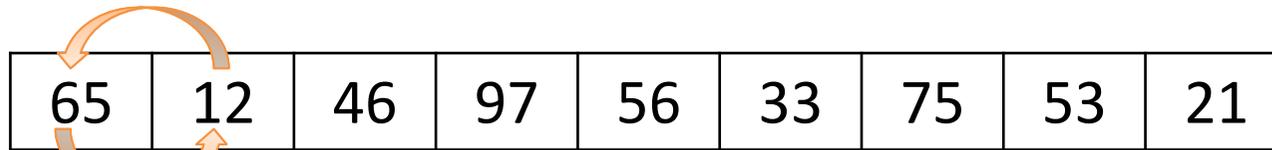


BUBBLE SORT

バブルソート

バブルソート (基本交換法)

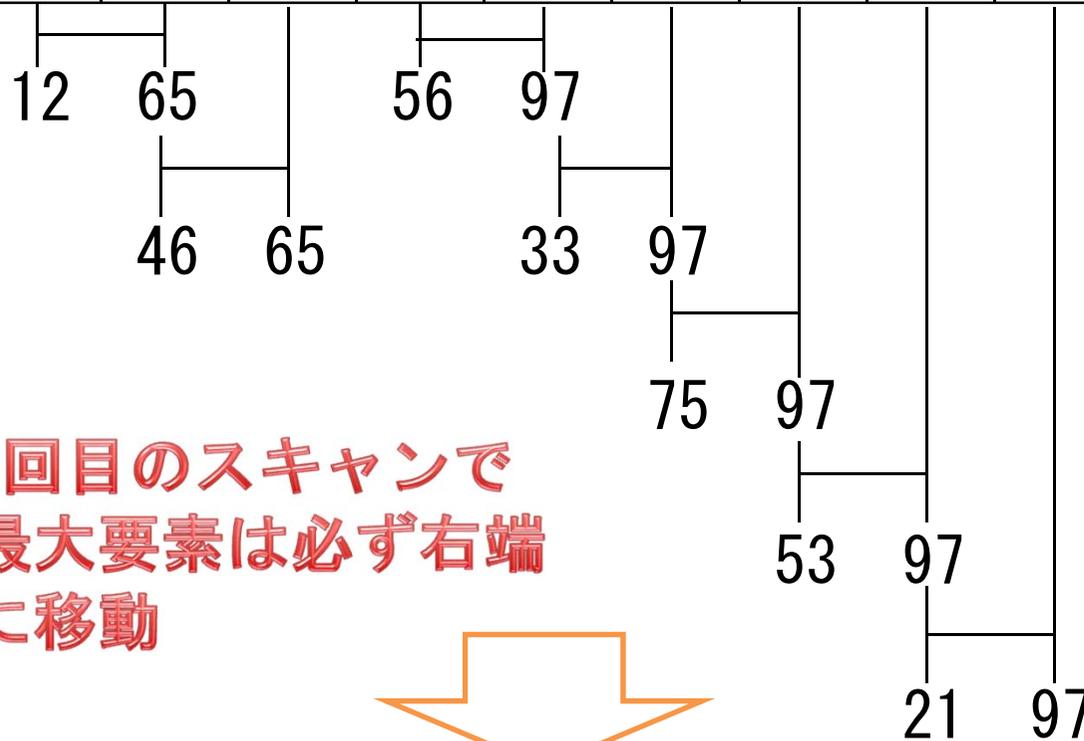
- 左から右にデータを見て、逆順になっているペアがあれば交換する



完全にソートされてはいない

バブルソート: 1回目のスキャン

65	12	46	97	56	33	75	53	21
----	----	----	----	----	----	----	----	----



1回目のスキャンで
最大要素は必ず右端
に移動

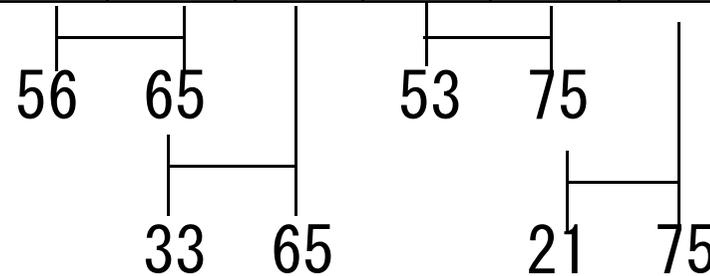


12	46	65	56	33	75	53	21	97
----	----	----	----	----	----	----	----	----

最大値

バブルソート: 2回目のスキャン

12	46	65	56	33	75	53	21	97
----	----	----	----	----	----	----	----	----



ソート済み

12	46	56	33	65	53	21	75	97
----	----	----	----	----	----	----	----	----



ソートしきれしていない → 次のスキャンへ

バブルソート: スキャン回数

- k回のスキャンでk個のデータがソートされる
→ 全要素のソートに要するスキャンはn-1回

65	12	46	97	56	33	75	53	21	: k=0	入力
12	46	65	56	33	75	53	21	97	: k=1	
12	46	56	33	65	53	21	75	97	: k=2	
12	46	33	56	53	21	65	75	97	: k=3	
12	33	46	53	21	56	65	75	97	: k=4	
12	33	46	21	53	56	65	75	97	: k=5	
12	33	21	46	53	56	65	75	97	: k=6	
12	21	33	46	53	56	65	75	97	: k=7	
12	21	33	46	53	56	65	75	97	: k=8	ソート完了

ソートを完了した部分

バブルソート: 計算量

- プログラム

```
for(k=1; k<n; k=k+1)
  for(i=0; i<n-k; i=i+1)
    if(data[i] > data[i+1])
      swap(&data[i], &data[i+1]);
```

- 比較回数: $\sum_{k=1}^{n-1} (n-k) = n(n-1)/2 \in \Theta(n^2)$

- ソート済みデータでも n^2 に比例する比較回数
- 逆順のデータだと, データ交換回数も n^2 に比例

バブルソート: 直接選択法

データ交換の回数を少なくする

- Q. データ交換(swap)を高々n回に改善したい

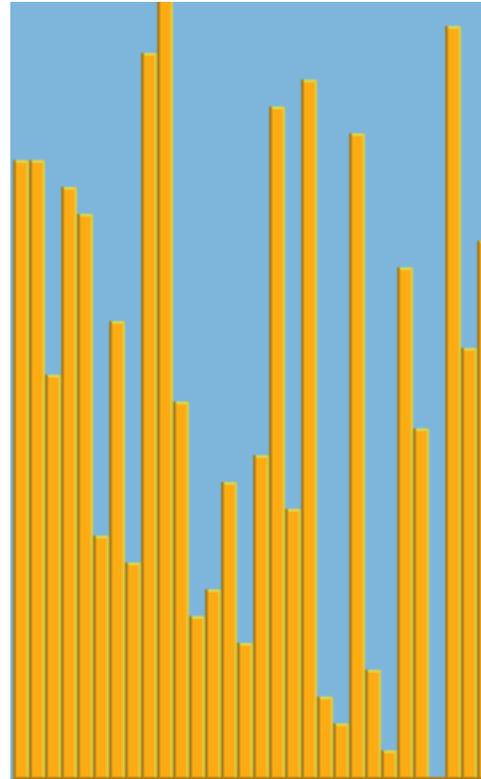
```
for(k=1; k<n; k=k+1)
    for(i=0; i<n-k; i=i+1)
        if(data[i] > data[i+1])
            swap(&data[i], &data[i+1]);
```

- A. 最大値を探して右端のデータと交換する

```
for(k=n-1; k>0; k=k-1){
    m=0;
    for(i=1; i<=k; i=i+1)
        if(data[i] > data[m]) m=i;
    swap(&data[k], &data[m]);
}
```

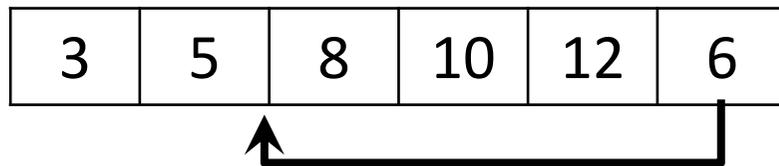
INSERTION SORT

插入法

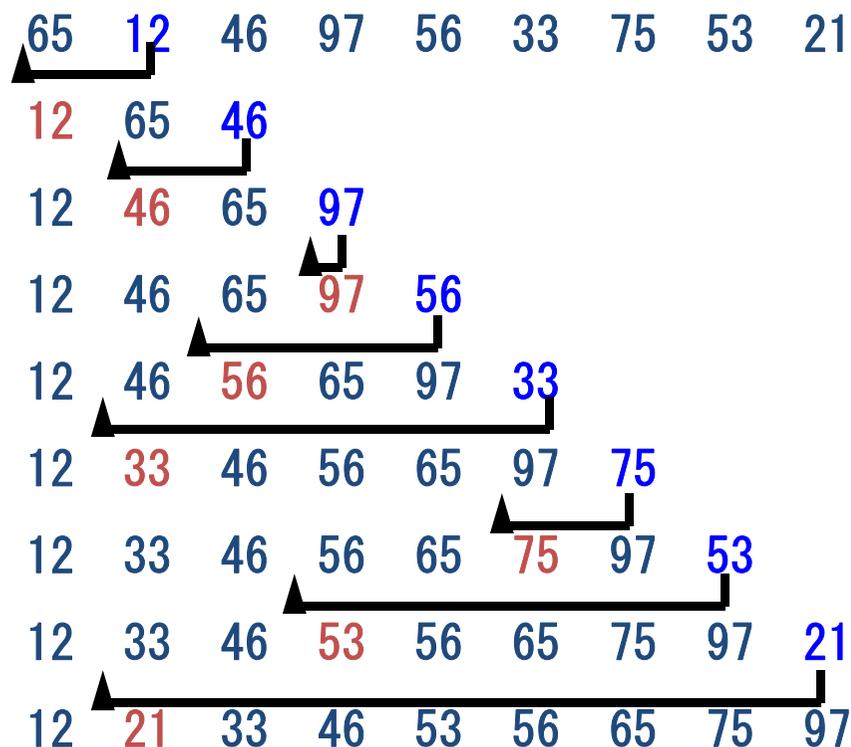


挿入法 (insertion sort)

- 毎回1個の要素をソート列に加えてゆく



挿入すべき要素より大きい要素を右にずらす必要がある



```
for(i=1; i<n; i=i+1){  
  x = data[i]; j=i;  
  while(data[j-1]>x &&  
    j>0){  
    data[j] = data[j-1];  
    j=j-1;  
  }  
  data[j] = x;  
}
```

Q. 挿入場所を求めるのに2分探索法を使わないのは何故?

挿入法: 計算時間

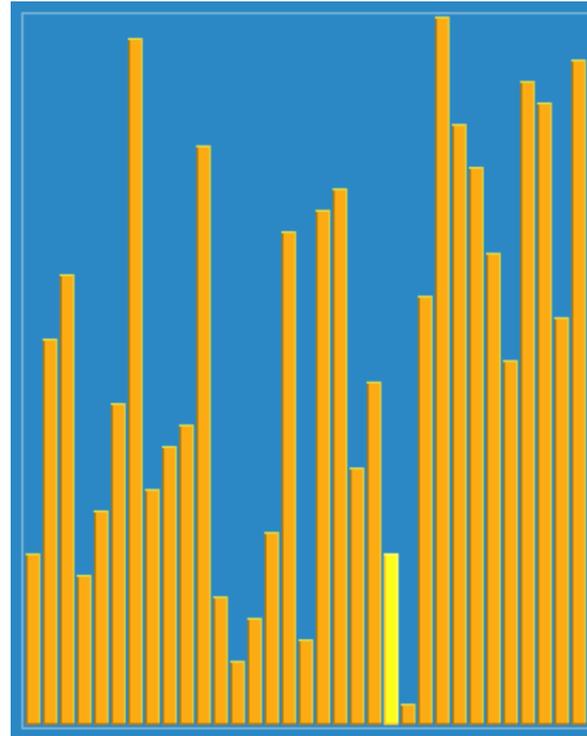
- 最良の場合: $\Theta(n)$
 - ソート済みのデータが入力
- 最悪の場合: $\Theta(n^2)$
 - 逆順にソートされたデータが入力
 - 毎回全ての要素と比較して移動
- 平均的な場合: $\Theta(n^2)$
 - 新たに挿入する要素がソート済みの m 個の要素の中で k 番目に大きい要素のとき k 回の比較
 - k 番目に大きい要素である確率は $1/m$



Donald L. Shell
1924–

SHELL SORT

改良挿入法



D.L. Shell, “A high-speed sorting procedure”.
Communications of the ACM 2 (7): 30–32 (1959)

改良挿入法 (shell sort)

- 挿入法の反省
 - 利点: ほぼソートされた列のソートは速い
 - 欠点: あまりソートされていない列に対して遅い
- ➔ 前処理で“ほぼソートされた”列を作る
- 挿入法に対する改良: h-整列
 - h要素分離れた要素の集合を整列させる
 - e.g., 3-整列の場合



同じ色の要素間でソート

改良挿入法: アルゴリズムの概観

1. 適当な h を定める
2. h -整列な列を作る
3. h の値を小さくして
 - $h \neq 1$ のとき: 2を実行
 - Otherwise: 普通の挿入法を実行

E.g., h の値を $n/2, n/4, n/8, \dots, 1$ と変化させる

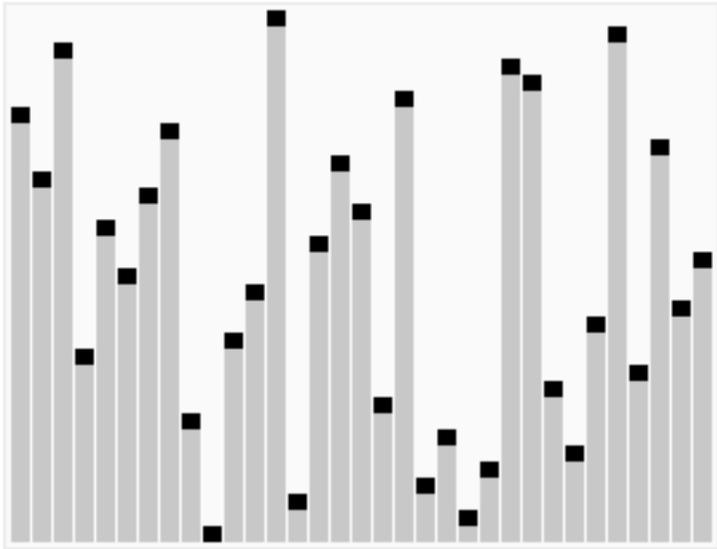
65	12	46	97	56	33	75	53	21	$h=4$
21	12	46	53	56	33	75	97	65	$h=2$
21	12	46	33	56	53	65	97	75	$h=1$
12	21	33	46	53	56	65	75	97	完了

改良挿入法: プログラムと計算量

- プログラム

```
for(gap=n/2; gap>0;gap=gap/2)
  for(i=gap; i<n; i=i+1)
    for(j=i-gap; j>=0 && a[j]>a[j+gap]; j=j-gap)
      swap(&a[j], &a[j+gap]);
```

- 計算量: $O(n^2)$ よりは良い
 - 正確に計算量を見積もるのは難しい
 - ギャップの取り方によって, $\Theta(n \log^2 n)$ にできる



HEAP SORT

ヒープソート

ヒープソート (heap sort)

- データ構造 ヒープ
 - データ追加: $\Theta(\log n)$
 - 最大要素の取り出し: $\Theta(\log n)$
- ソートの方法
 - Step 1: n 個のデータを順にヒープに入れる
 - Step 2: ヒープから最大要素を取り出して, 配列の右端から順に格納
- 計算時間: Step 1, 2 とともに $\Theta(n \log n)$ 時間

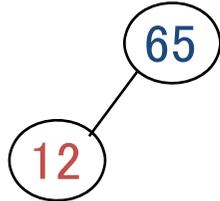
ヒープソート: 実行例@Step 1

Data = 65 12 46 97 56 33 75 53 21

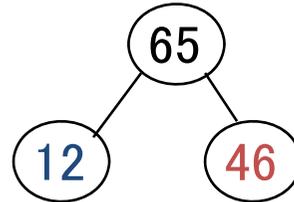
(1)add 65



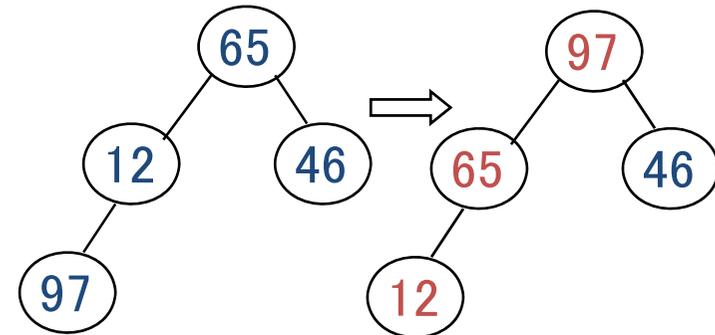
(2)add 12



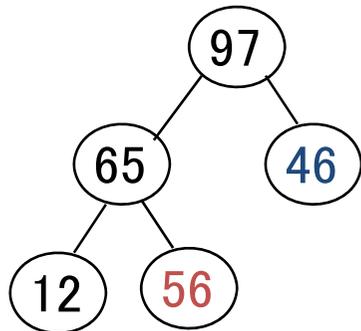
(3)add 46



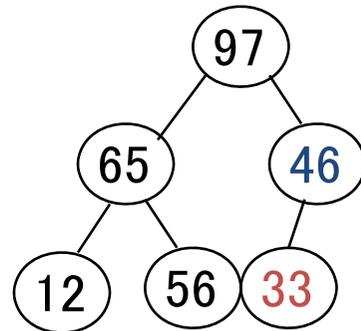
(4)add 97



(5)add 56



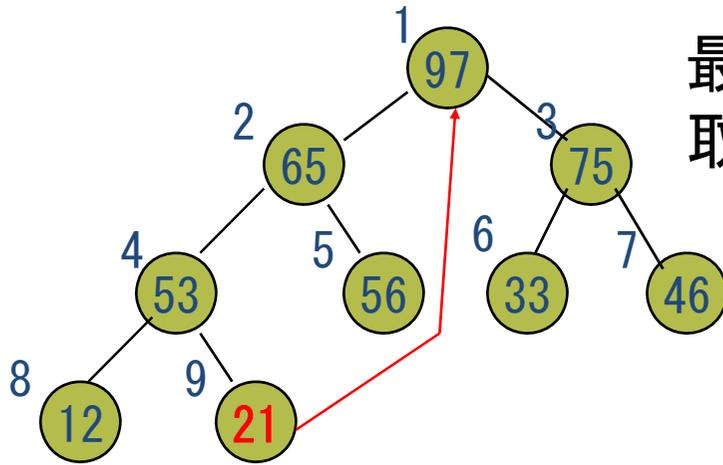
(6)add 33



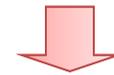
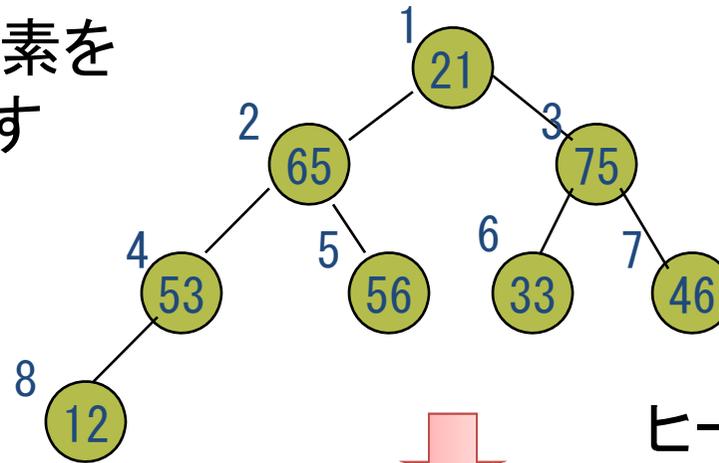
以下, 同様にヒープにデータを順に加えていく

1	2	3	4	5	6	7	8	9
97	65	75	53	56	33	46	12	21

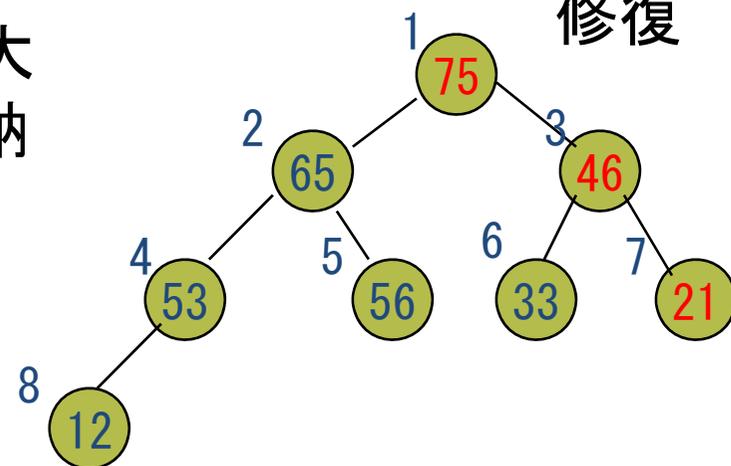
ヒープソート: データの取り出し@Step 2



最大要素を
取り出す



ヒープを
修復



右端に最大
要素を格納



75	65	46	53	56	33	21	12	97
----	----	----	----	----	----	----	----	----

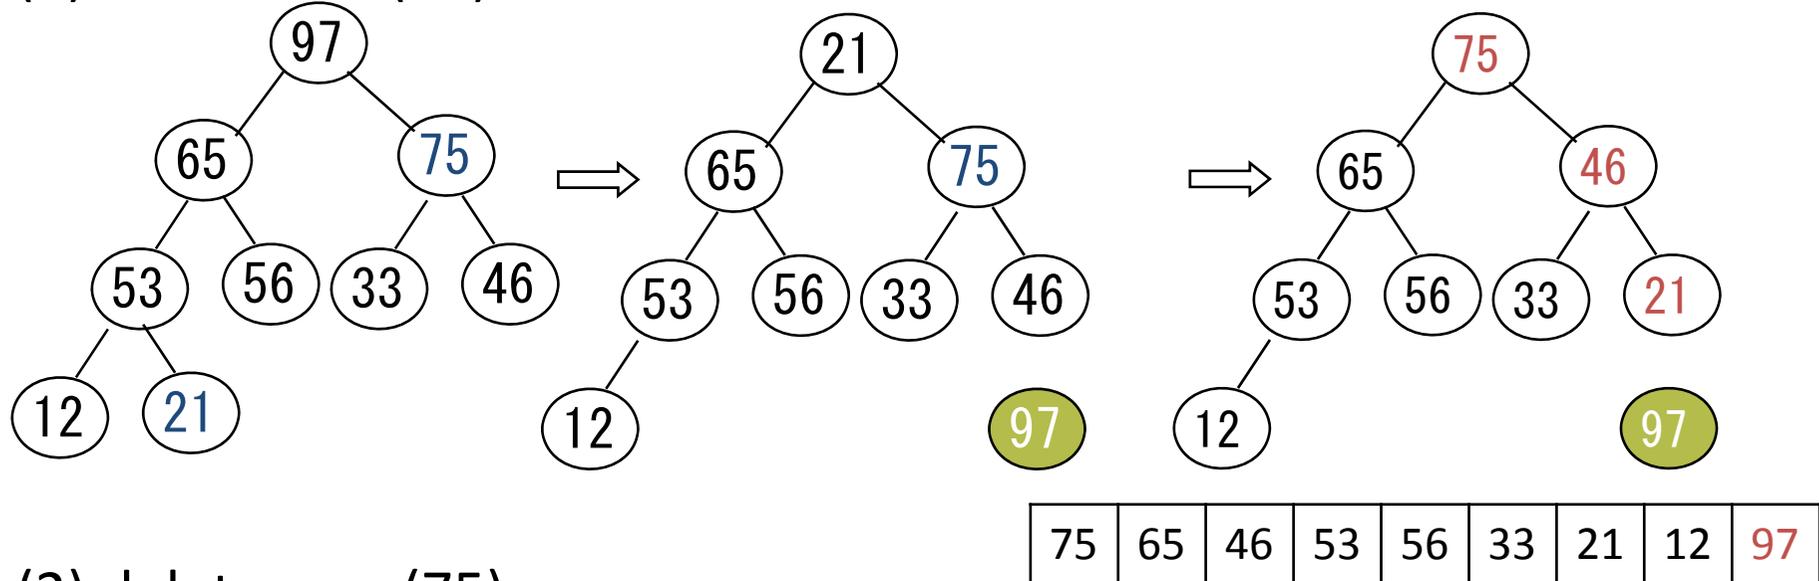
75	65	46	53	56	33	21	12	20
----	----	----	----	----	----	----	----	----

ヒープソート: 実行例@Step 2

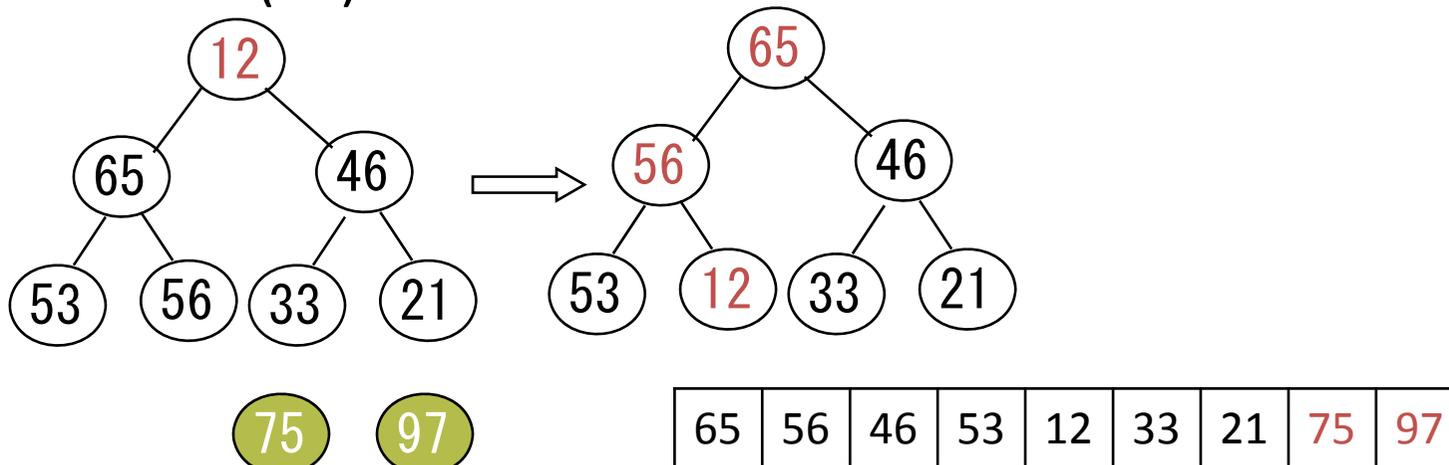
配列 =

97	65	75	53	56	33	46	12	21
----	----	----	----	----	----	----	----	----

(1) delete max (97)



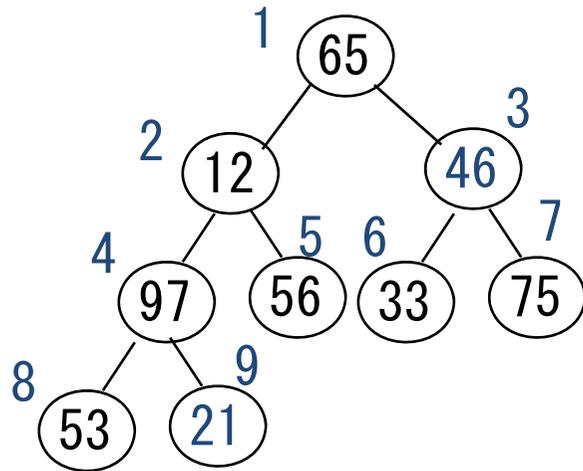
(2) delete max (75)



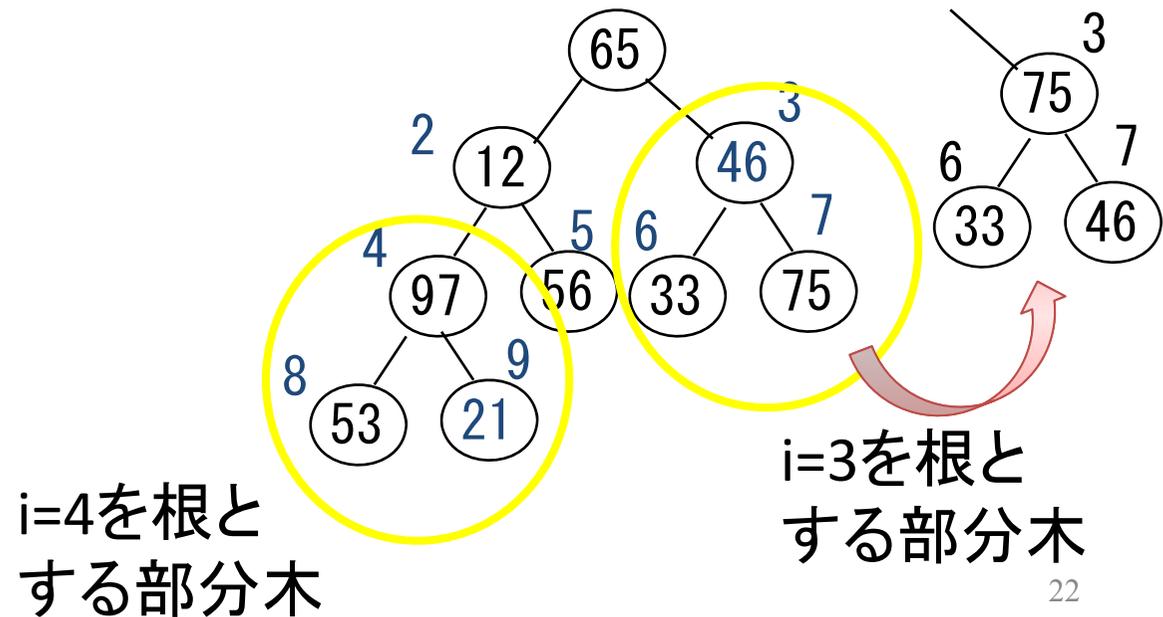
ヒープソートの改善

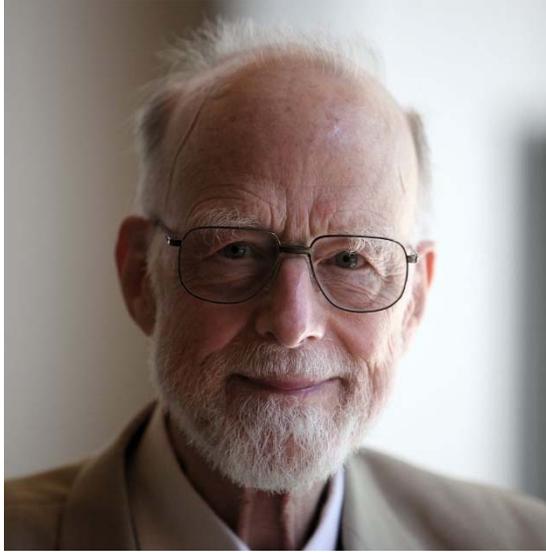
- Step 1 は, $\Theta(n)$ にできる
 - 与えられた順に配列にデータを格納する
 - 下から順に, 親子節点のデータを交換

(1) データを格納



(2) 親子関係の節点のデータを交換

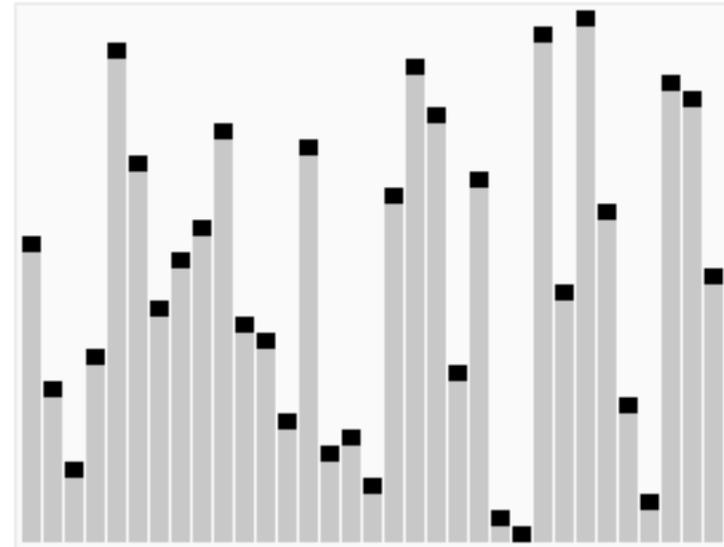




Tony Hoare
1934–

QUICK SORT

クイックソート



C.A.R. Hoare, “Algorithm 64: Quicksort”.
Communications of the ACM 4 (7): 321 (1961)

クイックソート (quick sort)

- 特徴: 平均的に最も速い
- ソートの仕方:
 - Step 1: 配列中の任意の要素 x を選ぶ
 - Step 2: x 未満の要素を配列の左から
 x 以上の要素を配列の右から詰める



- Step 3: x 未満の列および x 以上の列を再帰的にソート
 - 列が十分に短くなったら素朴なソート

クイックソート: 実行例

Step 1. 任意の要素xを選ぶ

- 以下の配列のソートを考える

65	12	46	97	56	33	75	53	21
----	----	----	----	----	----	----	----	----

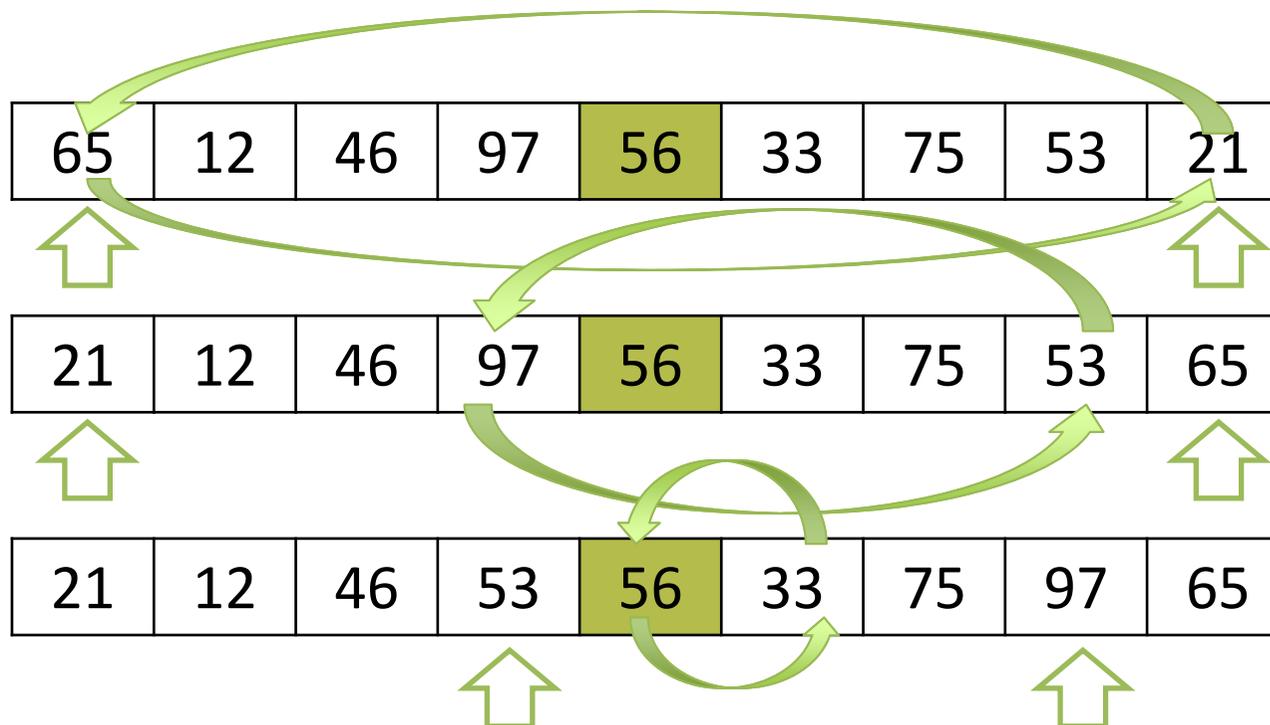
- $x=56$ を選んだとする

65	12	46	97	56	33	75	53	21
----	----	----	----	----	----	----	----	----

クイックソート: 実行例

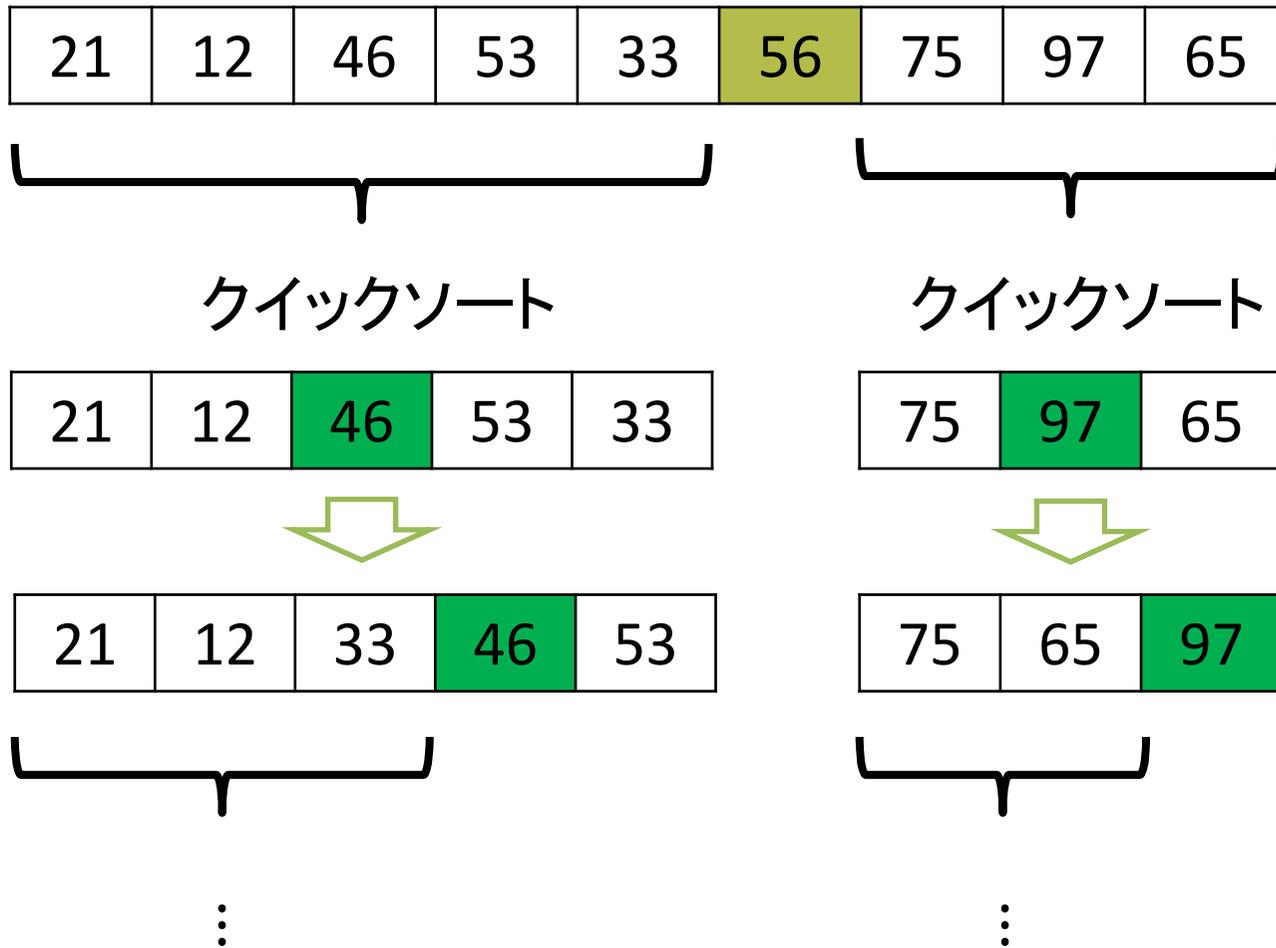
Step 2. x未満とx以上の列にわけ

- | | |
|-----|-----|
| x未満 | x以上 |
|-----|-----|
- $[l, r] = [0, n-1]$ から始めて, l, r を動かす,
 $a[l] \geq x \ \&\& \ a[r] < x \Rightarrow a[l]$ と $a[r]$ を交換



クイックソート: 実行例

Step 3. x 未満と x 以上の列をソート



クイックソート: プログラム

```
qsort(int a[], int left, int right){
    int i, j, x;
    if(right <= left) return;
    i = left; j = right; x = a[(i+j)/2];
    while(i<=j){
        while(a[i]<x) i=i+1;
        while(a[j]>x) j=j-1;
        if(i<=j){
            swap(&a[i], &a[j]); i=i+1; j=j-1;
        }
    }
    qsort(a, left, j); qsort(a, i, right);
}
```

クイックソート: 計算時間(1/2)

最悪の場合

- 毎回 x として, 列の最大値/最小値を選ぶ
長さ n の列 \rightarrow 長さ 1 の列 : 長さ $n-1$ の列
- 長い方の列が長さ 2 になるまでの繰り返し
- よって比較回数は $\sum_{k=2}^n k \in \Theta(n^2)$

クイックソート: 計算時間(2/2)

平均的な場合

- n 個の要素の中から任意の要素 x を選ぶとき,
 x が列の中で k 番目の要素である確率: $1/n$
- x が k 番目の要素:
長さ n の列 \rightarrow 長さ k の列 : 長さ $n-k$ の列

- 全体の比較回数

$$C(n) = \sum_{k=1}^n \frac{1}{n} (n + C(k) + C(n-k))$$

$$\approx n + \frac{2}{n} \sum_{k=1}^n C(k)$$

$$\implies C(n) = 1.36n \log n + O(n)$$

ミニ演習

- 前述の qsort に対して, 計算時間が最悪となる入力を作れ(入力の長さは10程度)