

4. ソート問題とアルゴリズム

4-1. ソート問題について

4-2. 簡単なソートアルゴリズム

4-3. 高度なソートアルゴリズム

4-4. 比較によらないソートアルゴリズム

4-5. ソート問題の下界(高速化の限界)

4－1：ソート問題

- 入力：データ数 n と n 個の数

$n, a_0, a_1, \dots, a_{n-1}$

(ここで、入力サイズは、 n とします。)

- 出力：

a_0, a_1, \dots, a_{n-1} を小さい順にならべたもの

$a'_0, a'_1, \dots, a'_{n-1} (a'_0 \leq a'_1 \leq \dots \leq a'_{n-1})$

ここで、 $(a'_0, a'_1, \dots, a'_{n-1})$ は、
 $(a_0, a_1, \dots, a_{n-1})$ の置換

ソートの問題例 (問題インスタンス)

データ

5, 3, 8, 1, 6, 21, 11



ソートアルゴリズム



1, 3, 5, 6, 8, 11, 21

データ

k,a,l,c,d,s

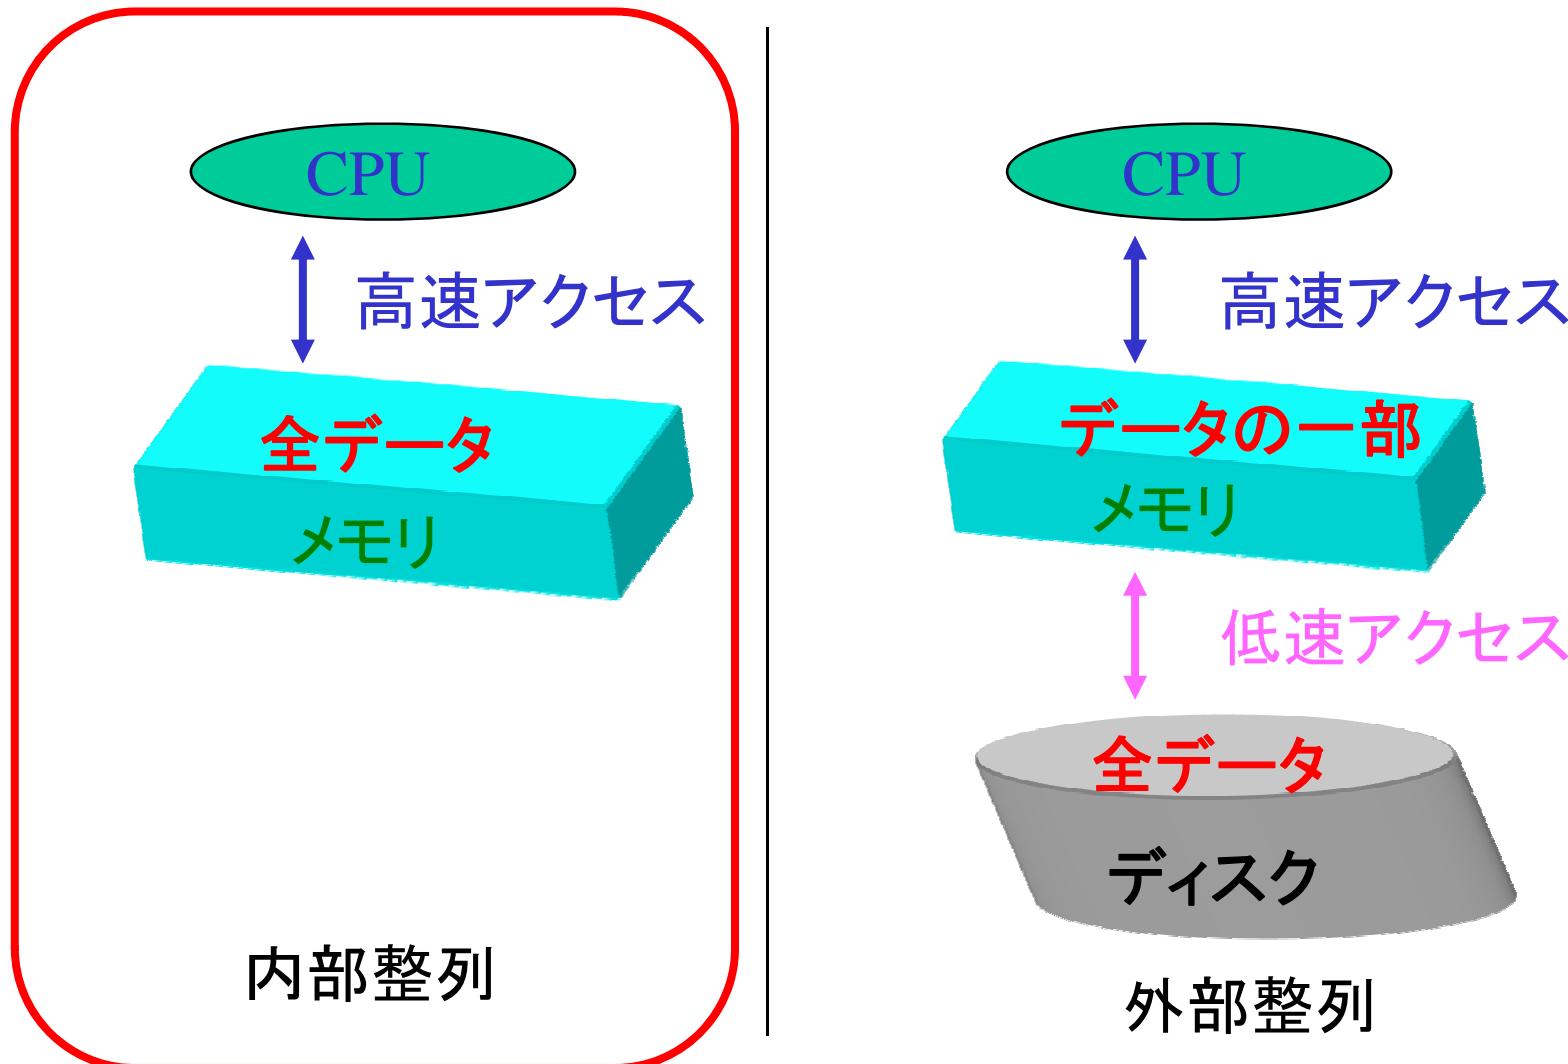


ソートアルゴリズム



a,c,d,k,l,s

内部整列と外部整列



仮定と要求

内部整列

- どのデータにも均等な時間でアクセスできる。
できるだけ高速に整列したい。

(理想的な計算機上のアルゴリズムではこっち)

外部整列

- CPU—メモリ間のデータ転送速度より、
ディスク—メモリ間のデータ転送速度が極端に遅い。
全体の整列をできるだけ高速にしたい。
(ディスク—メモリ間のデータ転送をあまり行わないよう
する。現実的な問題だが、より複雑な解析が必要であ
る。)

ソート問題の重要性

- 実際に頻繁に利用される。
- アルゴリズム開発の縮図
 - 繰り返しアルゴリズム(バブルソート、挿入ソート等)
 - アルゴリズムの組み合わせ(選択ソート、マージソート等)
 - 分割統治法(マージソート、クイックソート等)
 - データ構造の利用(ヒープソート、2分探索木等)
- 十分な理論解析が可能。
 - 最悪計算量と平均計算量の違い(クイックソート)
- 豊富なアイディア

ソートアルゴリズムの種類

バブルソート

選択ソート

挿入ソート

クイックソート

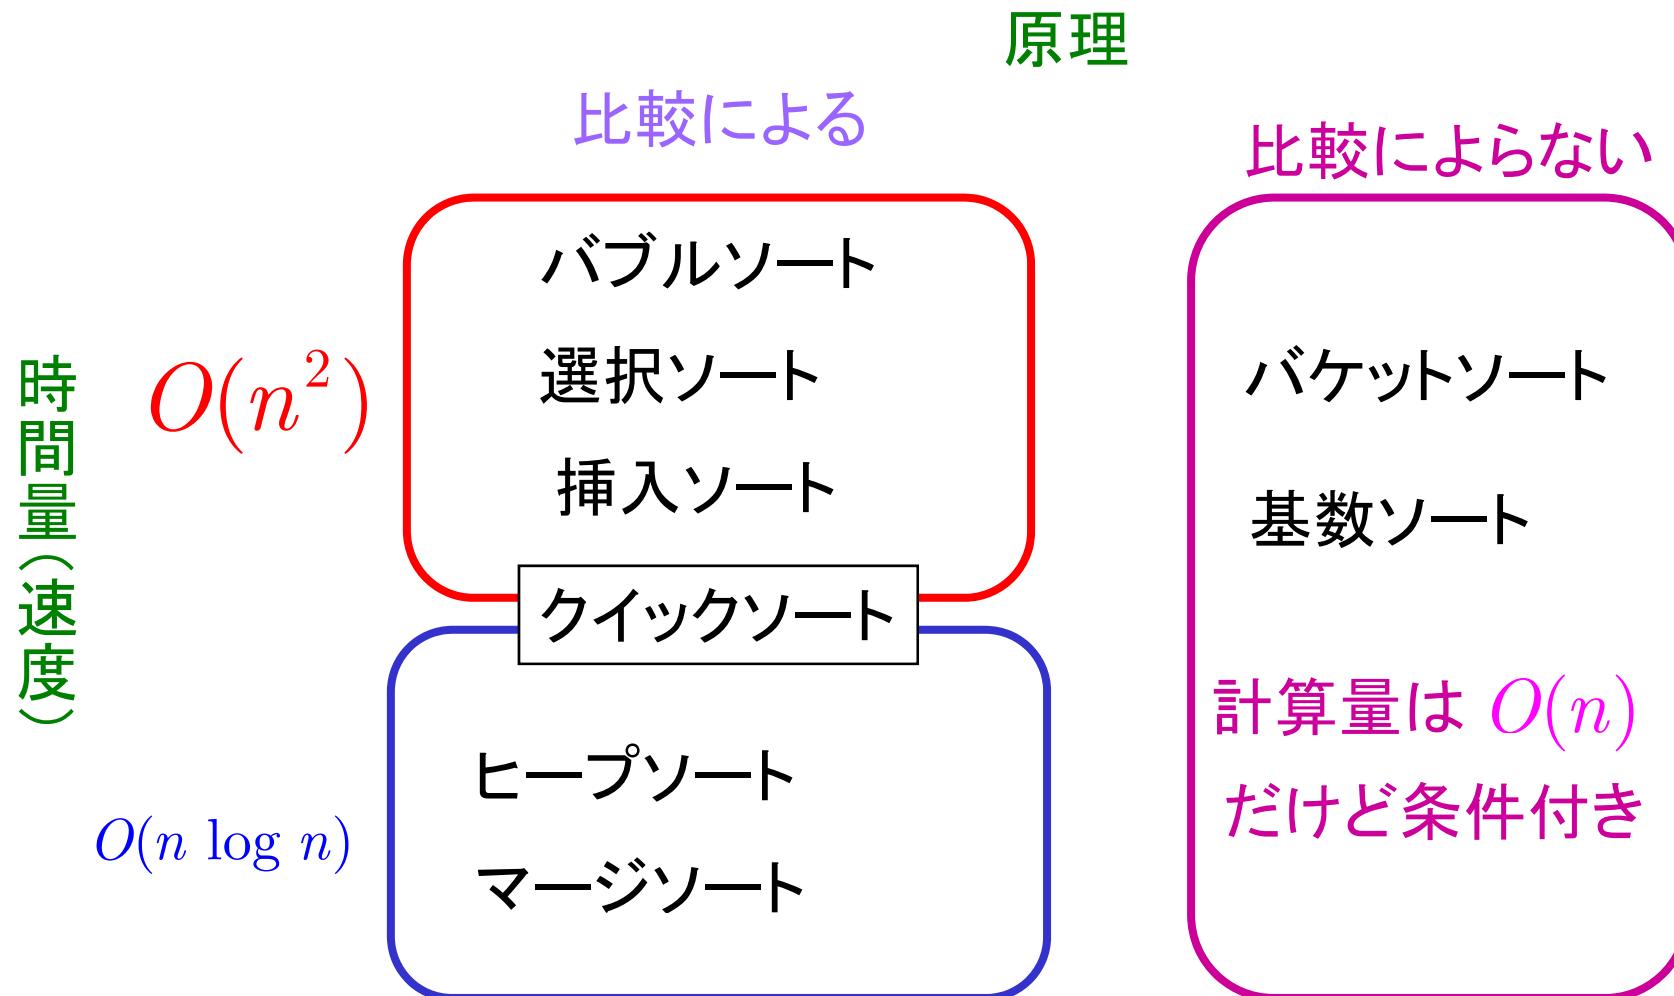
マージソート

ヒープソート

バケットソート

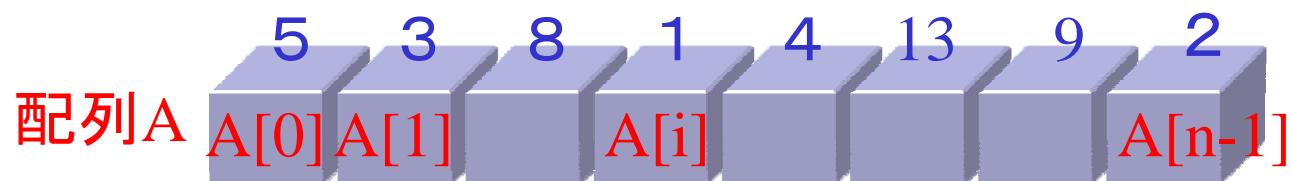
基數ソート

ソートアルゴリズムの分類

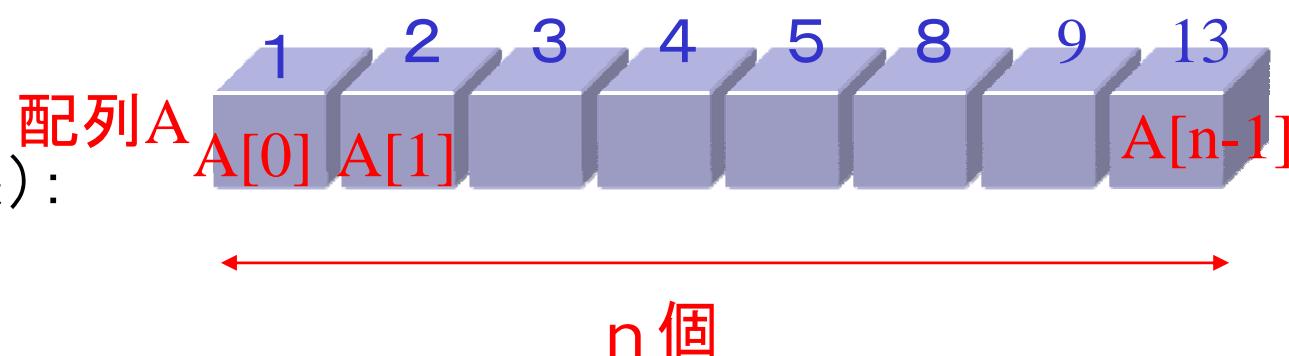


入出力形態

入力:



出力
(終了状態):



入力は配列で与えられるとする。

交換関数(準備)

```
/* 交換用の関数。  
swap(&a,&b)で呼び出す。  
*/  
1. void swap(double *a,double *b)  
2. {  
3.     double    tmp; /* データの一次保存用 */  
4.  
5.     tmp=*a;  
6.     *a=*b;  
7.     *b=tmp;  
8.  
9.     return;  
10.}
```

参照渡しにする
必要があること
に注意すること。

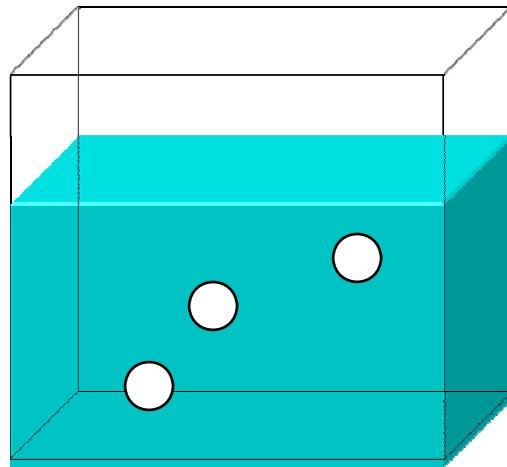
4-2: 簡単なソートアルゴリズム

バブルソート

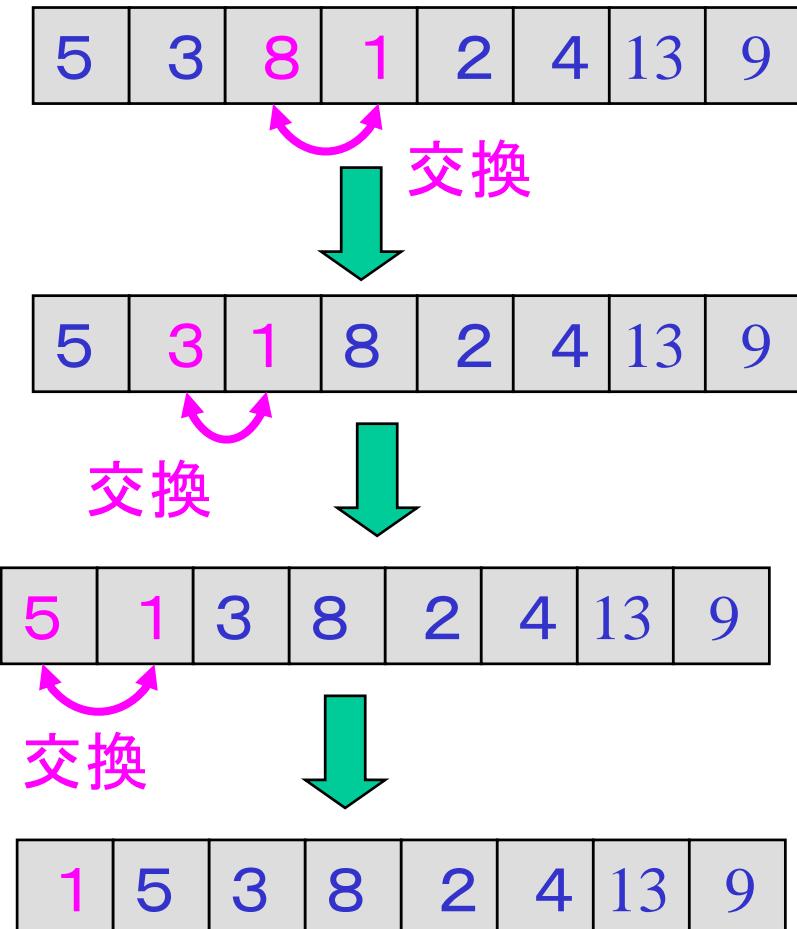
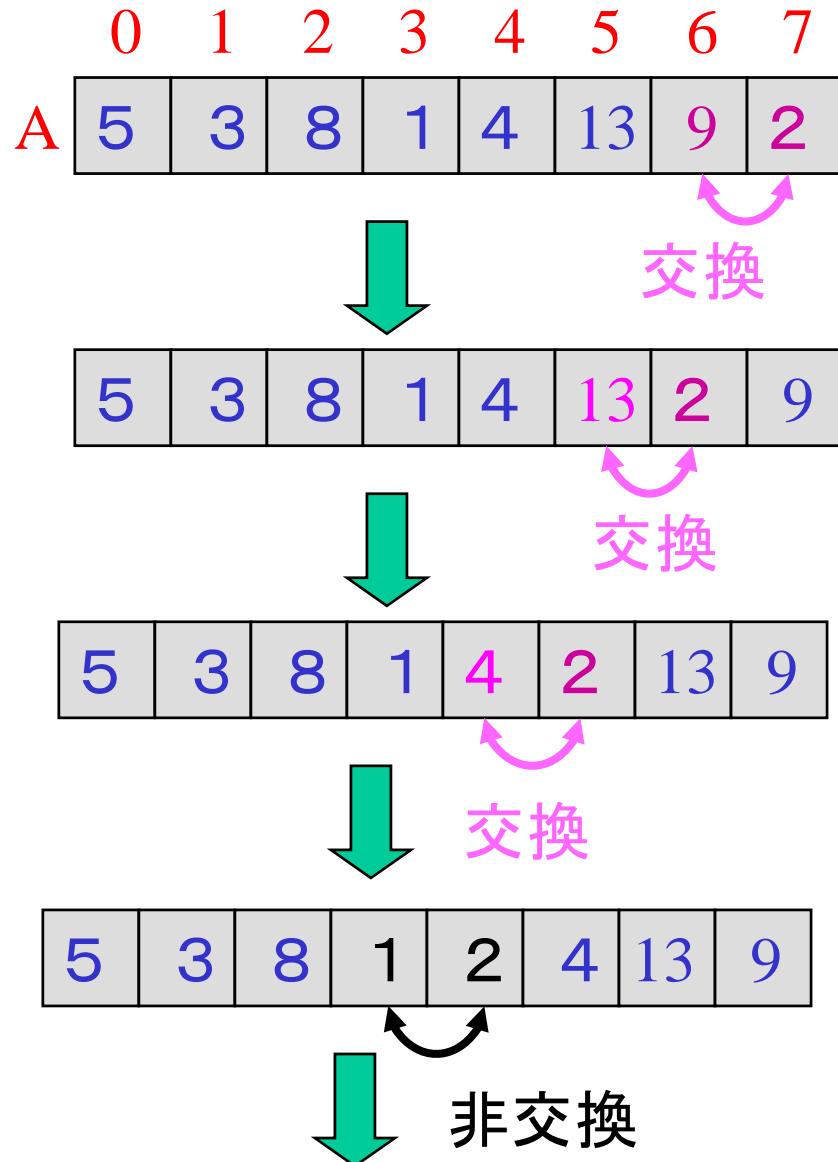
バブルソートの方針

方針

- 隣同士比べて、小さいほうを上(添字の小さい方)に順にもっていく。
- 先頭の方は、ソートされている状態にしておく。
- これらを繰り返して、全体をソートする。

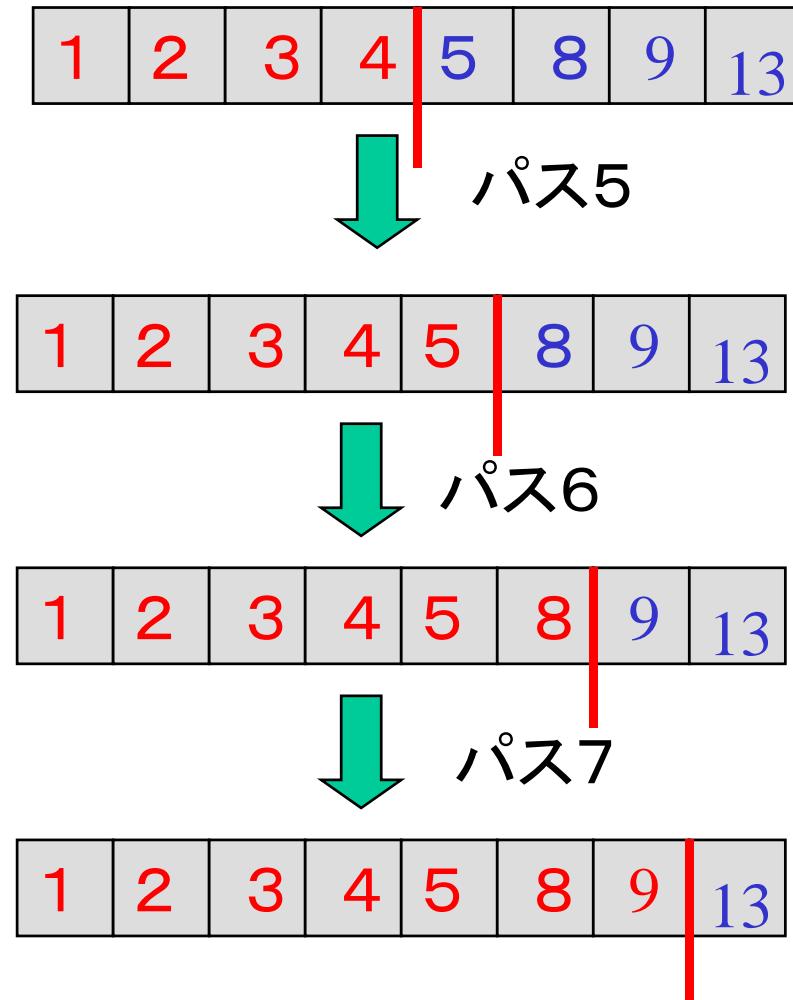
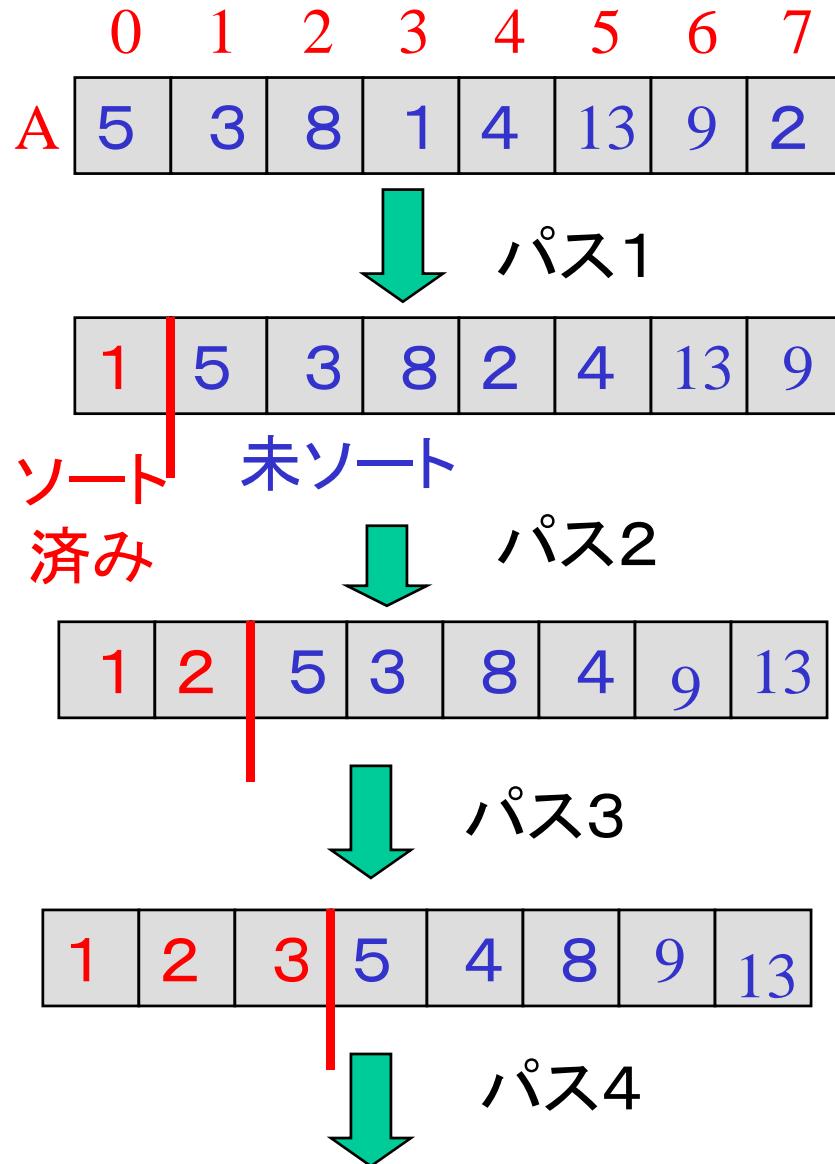


バブルソートの動き1



この一連の動作をバブルソートの
「パス」といいます。

バブルソートの動き2



$n - 1$ パスでソートできる。₁₅

練習

次の配列を、バブルソートでソートするとき、
全てのパスの結果を示せ。

11	25	21	1	8	3	16	5
----	----	----	---	---	---	----	---

バブルソートの実現

```
/* バブルソート*/
1. void bubble()
2. {
3.     int i,j; /* カウンタ*/
4.     for(i=0;i<n-1;i++)
5.     {
6.         for(j=n-1;j>i;j--)
7.         {
8.             if(A[j-1]>A[j])
9.             {
10.                 swap(&A[j-1],&A[j]);
11.             }
12.         }
13.     }
14.     return;
15. }
```

j>0としてもいい
が時間計算量が
約2倍になる

命題B1(bubbleの正当性1)

内側のforループ(ステップ6)がk回繰り返されたとき、
A[n-k]からA[n-1]までの最小値が
A[n-k]に設定される。

証明

k-1回の繰り返しによって、

A[n-k-1]にA[n-k-1]からA[n-1]までの最小値が
保存されているこのに注意する。

したがって、k回目の繰り返しにより、

$$\min\{A[n - k], A[n - k - 1]\}$$

$$= \min\{A[n - k], \min\{A[n - k - 1], \dots, A[n - 1]\}\}$$

がA[n-k]に設定される。

(より厳密な数学的帰納法で証明することもできるが、
ここでは省略する。)

QED 18

命題B2(bubbleの正当性2)

4. のforループが k 回繰り返されたとき、
(すなわち、パス k まで実行されたとき、)
前半の k 個($A[0]-A[k-1]$)
は最小の k 個がソートされている。

証明

各パス k においては、 $A[k-1]$ から $A[n-1]$ の最小値が、
 $A[k-1]$ に設定される。(命題B1より)
このことに注意すると、数学的帰納法により、
証明できる。(厳密な証明は省略する。)

QED 19

バブルソートの計算量

パス1で、n-1回の比較と交換

パス2で、n-2

▪

▪

▪

パスn-1で、1回の比較と交換

$$\text{よって、 } (n-1) + (n-2) + \cdots + 1 = \sum_{i=1}^{n-1} i = \frac{n(n-1)}{2}$$

時間計算量 $O(n^2)$ のアルゴリズム

領域計算量は $O(n)$ 。

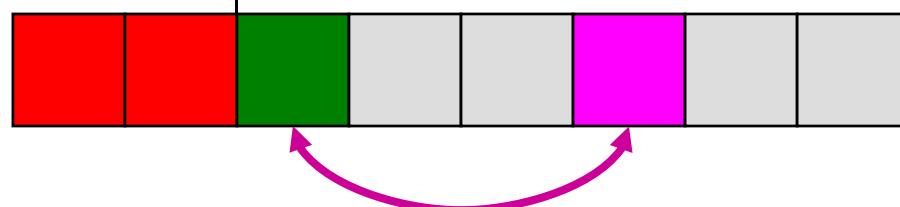
選択ソート

選択ソートの方針

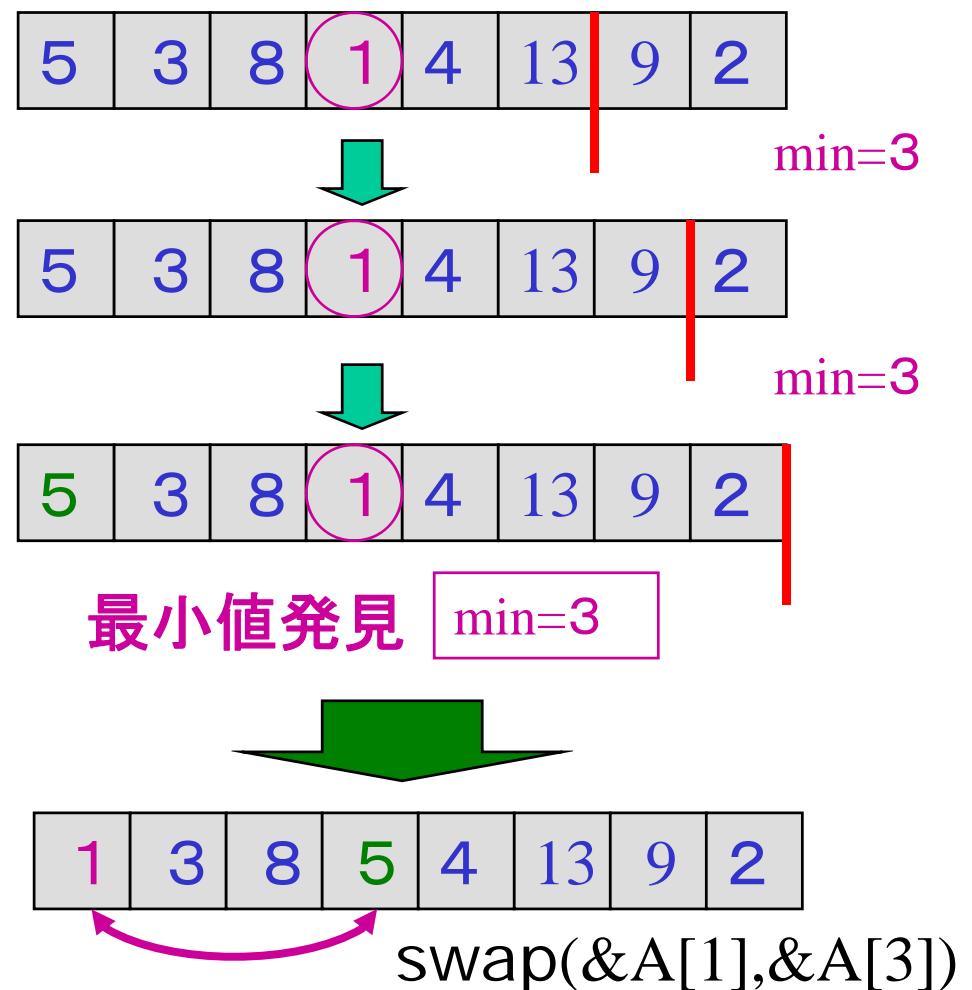
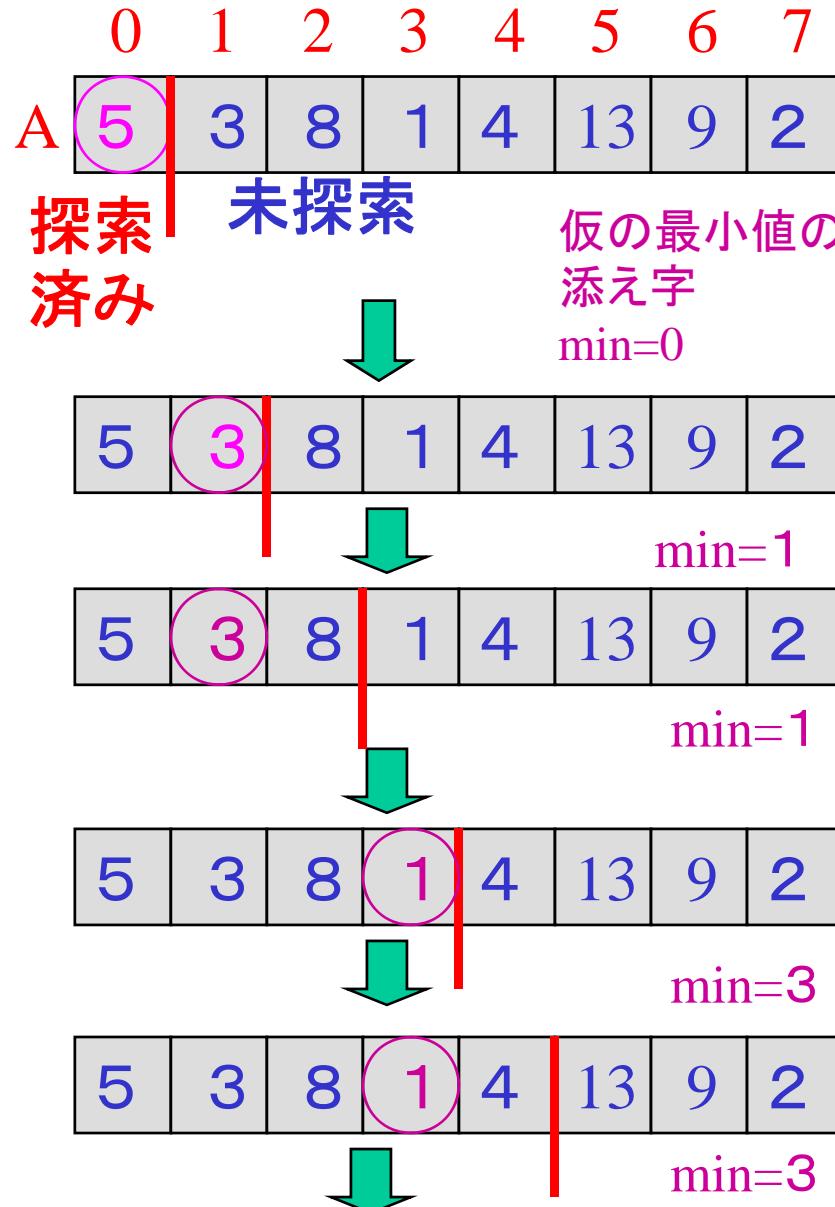
方針

- 先頭から順に、その位置に入るデータを決める。
(最小値を求める方法で選択する。)
- その位置のデータと選択されたデータを交換する。
- これらを繰り返して、全体をソートする。

ソート済み | 残りのデータで最小値を選択

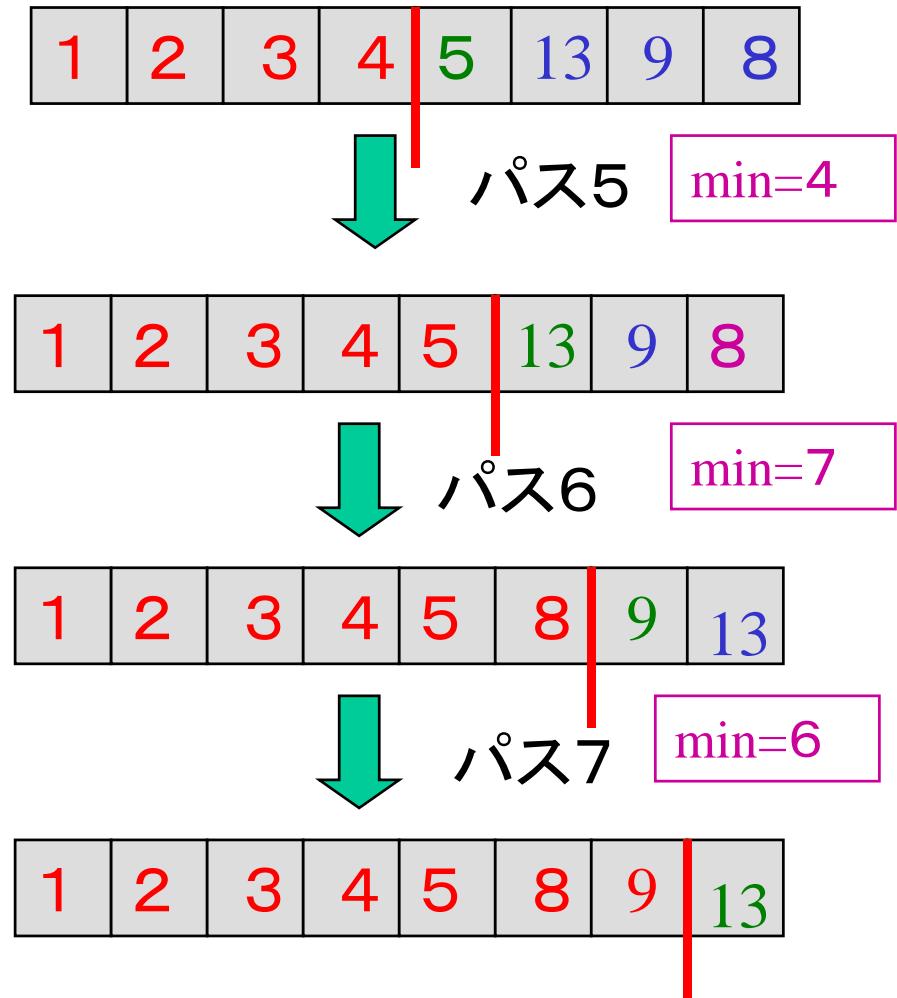
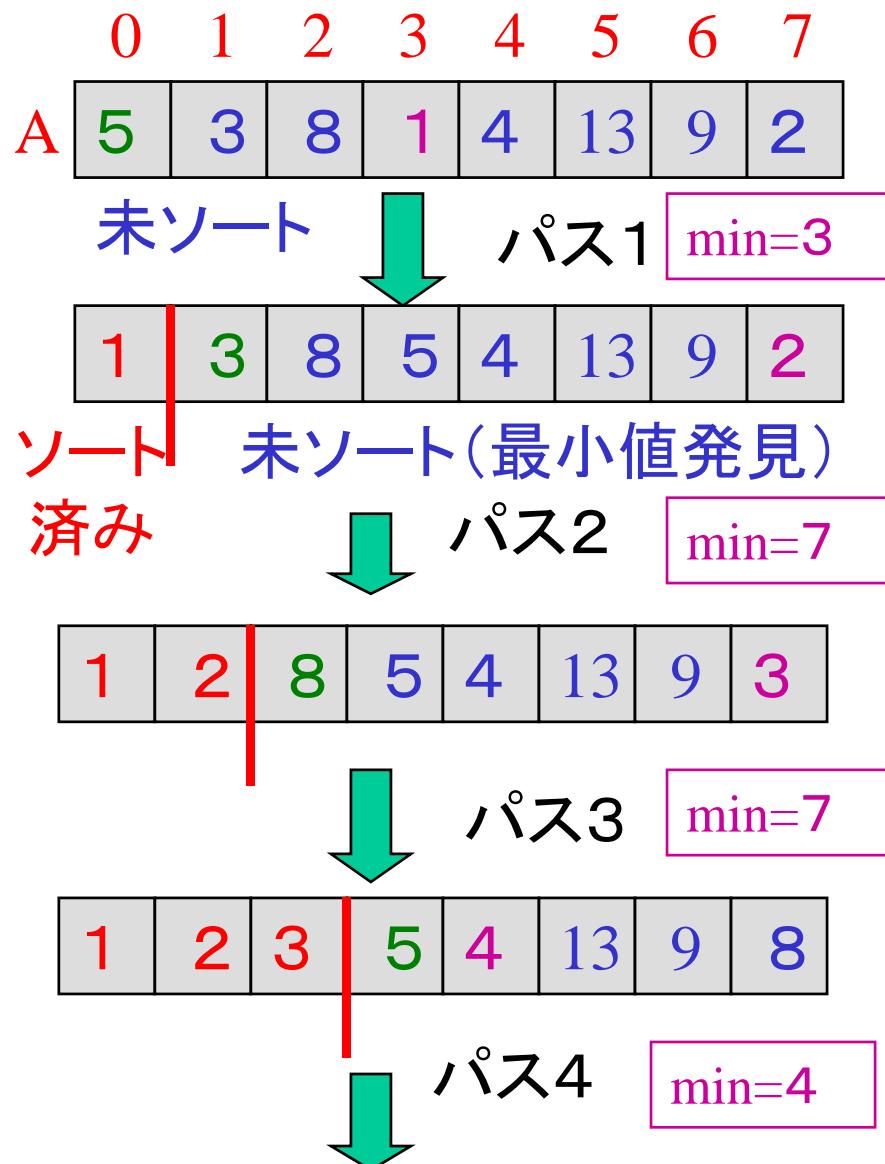


選択ソートの動き1(最小値発見)



この一連の動作を選択ソートの「パス」といいます。

選択ソートの動き2



$n - 1$ パスでソートできる。₂₄

練習

次の配列を、選択ソートでソートするとき、
全てのパスの結果を示せ。

11	25	21	1	8	3	16	5
----	----	----	---	---	---	----	---

選択ソートの実現1 (最小値を求めるアルゴリズム)

```
/*選択用の関数、A[left]からA[right]
までの最小値を求める*/
1. int find_min(int left,int right)
2. {
3.     int min=left; /* 仮の最小値の添字 */
4.     int j=left; /* カウンタ */
5.
6.     min=left;
7.     for(j=left+1;j<=right;j++)
8.     {
9.         if(a[min]>a[j]){min=j; }
10.    }
11.    return min;
12.}
```

選択ソートの実現2

```
/* 選択ソート*/
1. void slection_sort()
2. {
3.     int i; /* カウンタ */
4.     int min; /* 最小値の添字 */
5.     for(i=0;i<n-1;i++)
6.     {
7.         min=find_min(i,n-1);
8.         swap(&A[i],&A[min]);
9.     }
10.    return;
11.}
```

なお、説明の都合上、関数find_minを作ったが、
関数呼び出しで余分に時間がとられるので、
実際は2重ループにするほうが速いと思われる。
(でも、オーダーでは、同じ。)

命題S1(選択ソートの正当性1)

`find_min(left,right)`は、 $A[left]-A[right]$ 間の最小値を添え字を求める。

証明

1回目の資料の命題1と同様に証明される。

QED 28

命題S2(選択ソートの正当性2)

5. のforループが $i+1$ 回繰り返されたとき、
(パス*i*まで実行されたとき、)
 $A[0]-A[i]$ には、小さい方から $i+1$ 個の要素が
ソートされてある。

証明

先の命題S1を繰り返して適用することにより、
この命題S2が成り立つことがわかる。
(厳密には数学的帰納法を用いる。)

QED 29

選択ソートの計算量

パス1 find_minで、n-1回の比較

パス2 n-2

▪

▪

▪

パスn-1のfind_minで、1回の比較

よって、 $(n-1) + (n-2) + \dots + 1 = \sum_{i=1}^{n-1} i = \frac{n(n-1)}{2}$ 回の比較

交換は、n-1回

時間計算量 $O(n^2)$ のアルゴリズム

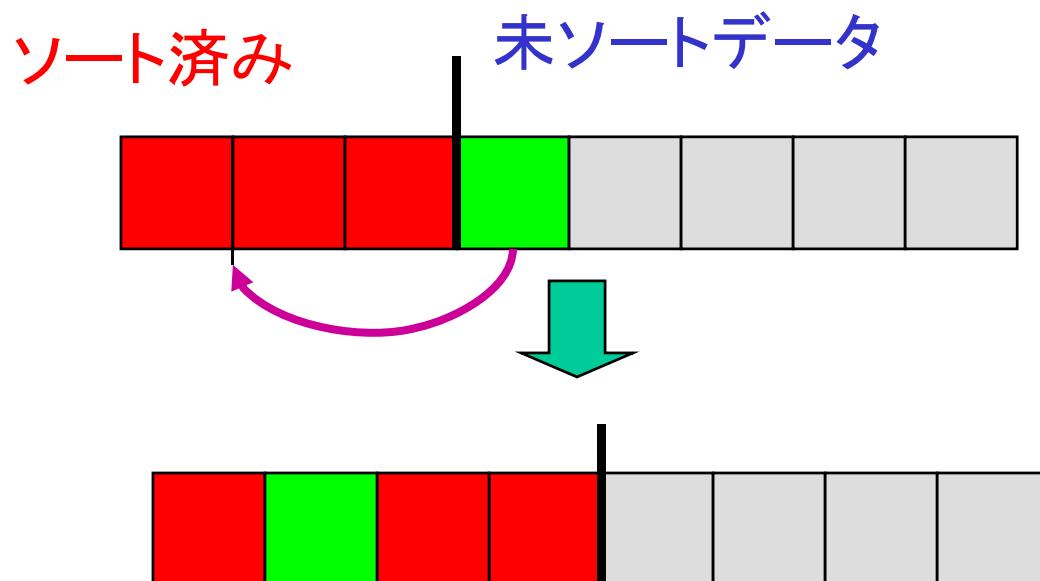
領域計算量は $O(n)$ 。

挿入ソート

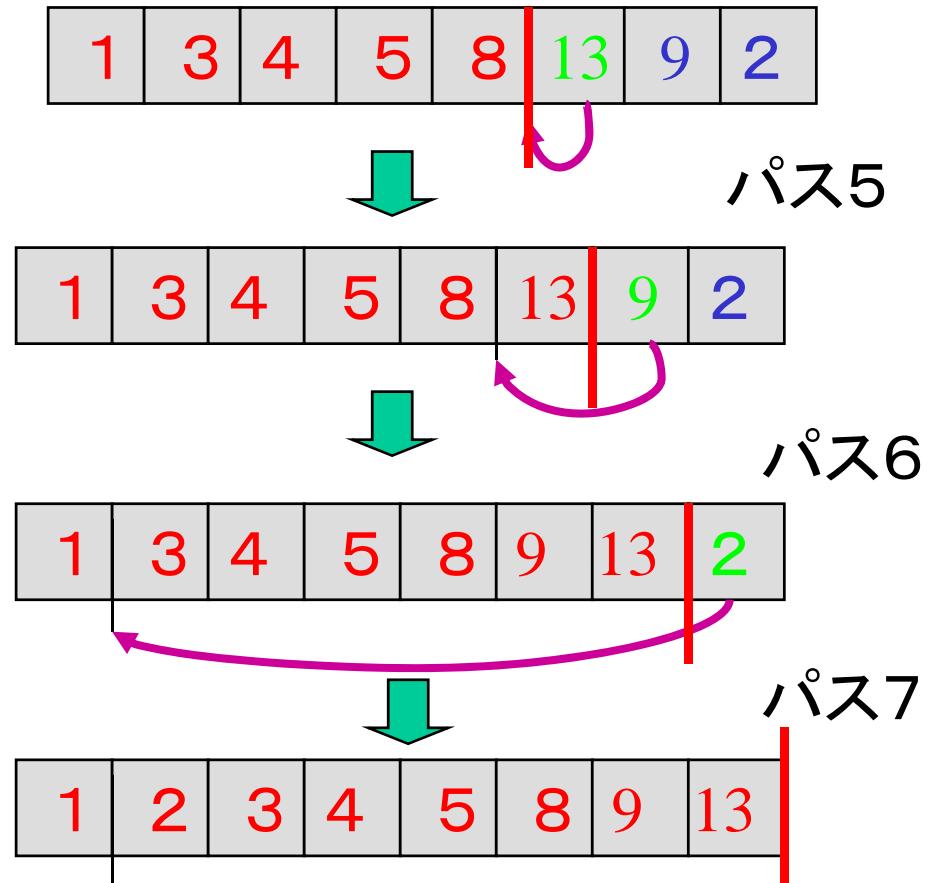
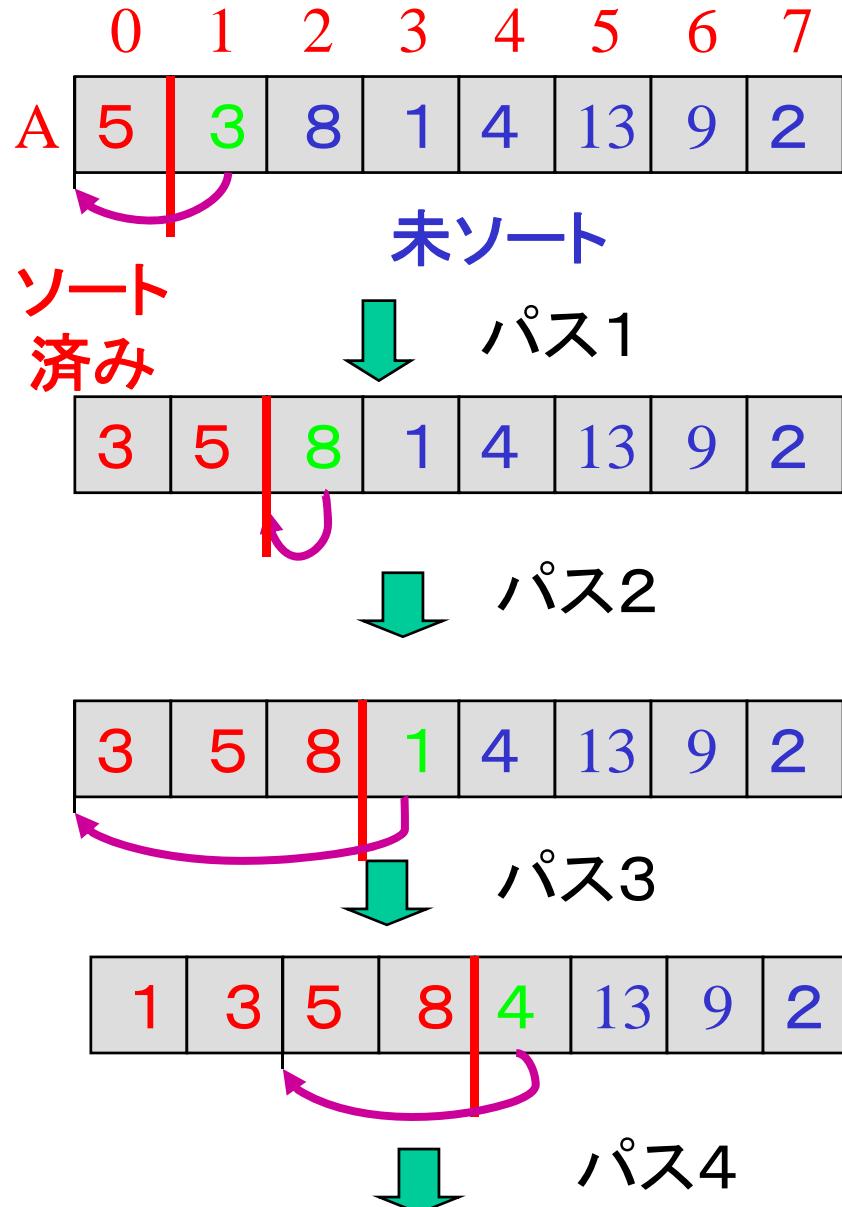
挿入ソートの方針

方針

- 先頭の方は、ソート済みの状態にしておく。
- 未ソートのデータを、ソート済みの列に挿入し、ソート済みの列を1つ長くする。
- これらを繰り返して、全体をソートする。



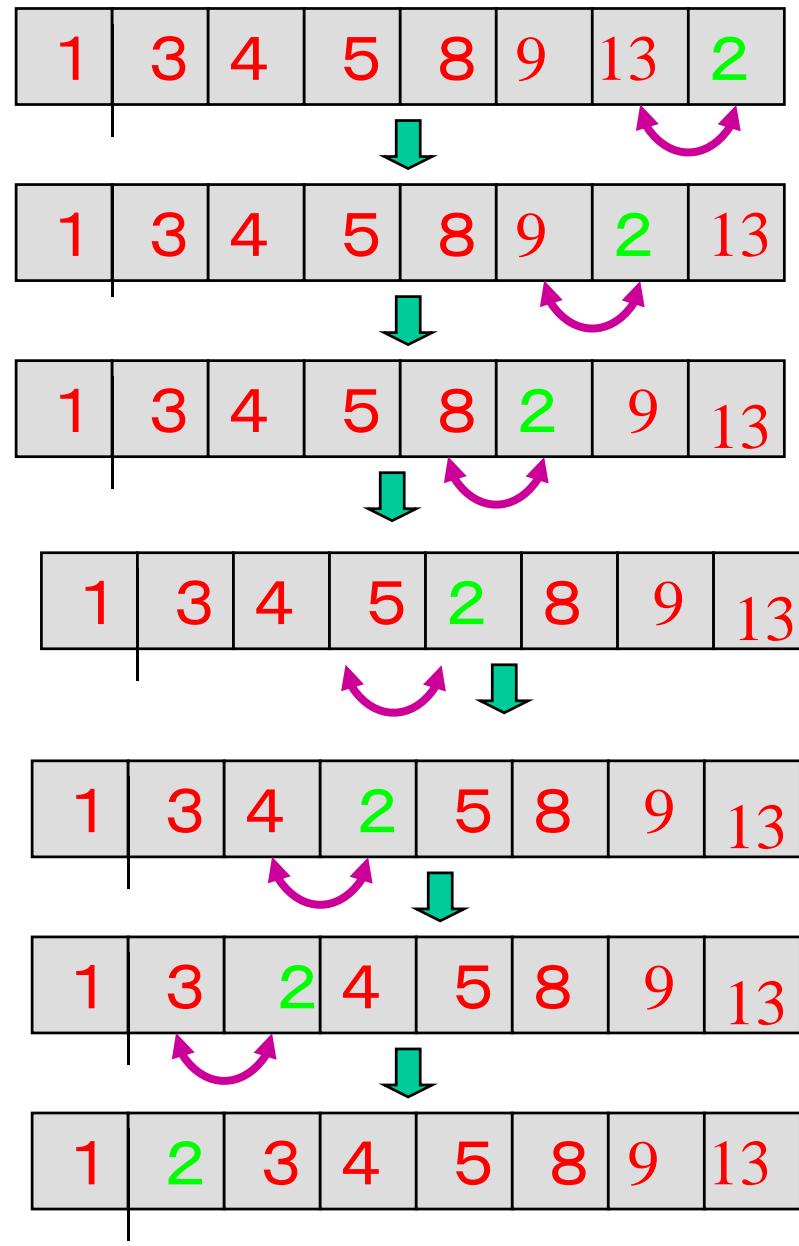
挿入ソートの動き1



この各回の挿入操作を、
挿入ソートの「パス」といいます。
 $n-1$ パスで挿入ソートが実現できる。

挿入ソートの動き2(挿入動作詳細)

1	3	4	5	8	9	13	2



練習

次の配列を、挿入ソートでソートするとき、
全てのパスの結果を示せ。

11	25	21	1	8	3	16	5
----	----	----	---	---	---	----	---

挿入ソートの実現1 (挿入位置を求める)

```
/*挿入位置を見つける関数、  
A[left]からA[right-1]までソート済みのとき、  
A[right]の順番を求める。*/  
1. int find_pos(int left,int right)  
2. {  
3.     int j=left;      /* カウンタ */  
4.     ...  
5.     for(j=left;j<=right;j++)  
6.     {  
7.         if(A[j]>A[right]){break; }  
8.     }  
9.     return j;  
10.}
```

挿入ソートの実現2(挿入)

```
/* 挿入(A[right]をA[pos]に挿入する。) */
1. void insert(int pos,int right)
2. {
3.     int k=right-1; /* カウンタ */
4.     for(k=right-1;k>=pos;k--)
5.     {
6.         pos=find_pos(i,A);
7.         for(j=n-1;j<pos;j--)
8.         {
9.             swap(&A[k],&A[k+1]);
10.        }
11.    }
12.    return;
13.}
```

挿入ソートの実現3(繰り返し挿入)

```
/* 挿入ソート*/
1. void insertion_sort()
2. {
3.     int i=0; /* カウンタ(パス回数) */
4.     int pos=0; /*挿入位置*/
5.     for(i=1;i<n;i++)
6.     {
7.         pos=find_pos(0,i);
8.         insert(pos,i);
9.     }
10.    return;
11.}
```

命題I1(挿入ソートの正当性)

5. のforループが*i*回繰り返されたとき、
(パス*i*まで実行されたとき、)
 $A[0]$ から $A[i]$ はソートされてある。

証明

挿入`find_pos`によって、挿入位置を適切に見つけている
また、`insert`によって、すでにソート済みの列を崩すことなく
ソート済みの列を1つ長くしている。
したがって、*i*回の繰り返しでは、*i*+1個のソート列が構成され
る。これらのソート列は、 $A[0]$ - $A[i]$ に保持されるので、命題
は成り立つ。

QED 39

命題I2(挿入ソートの停止性)

`insertion_sort`は停止する。

証明

各繰り返しにおいて、ソート列が一つづつ長くなる。
入力データは n 個であるので、 $n-1$ 回の繰り返しにより、必ず停止する。

QED 40

挿入ソートの計算量

パス1で、1回の比較あるいは交換

パス2で、2回の

・

・

・

パスn-1で、n-1の比較あるいは交換

よって、比較と交換回数の合計は、

$$1 + 2 + \dots + (n-1) = \sum_{i=1}^{n-1} i = \frac{n(n-1)}{2}$$

時間計算量 $O(n^2)$ のアルゴリズム

領域計算量は $O(n)$ 。

(挿入ソートを元に高速化した、シェルソートっていうものもあるが省略。)

簡単なソートのまとめ (最悪時間計算量)

方法	比較	交換	合計
バブルソート	$\frac{n(n-1)}{2} = O(n^2)$	$\frac{n(n-1)}{2} = O(n^2)$	$n(n-1) = O(n^2)$
選択ソート	$\frac{n(n-1)}{2} = O(n^2)$	$n-1 = O(n)$	$\frac{(n-1)(n+2)}{2} = O(n^2)$
挿入ソート	$\frac{n(n-1)}{2} = O(n^2)$	$\frac{n(n-1)}{2} = O(n^2)$	$\frac{n(n-1)}{2} = O(n^2)$

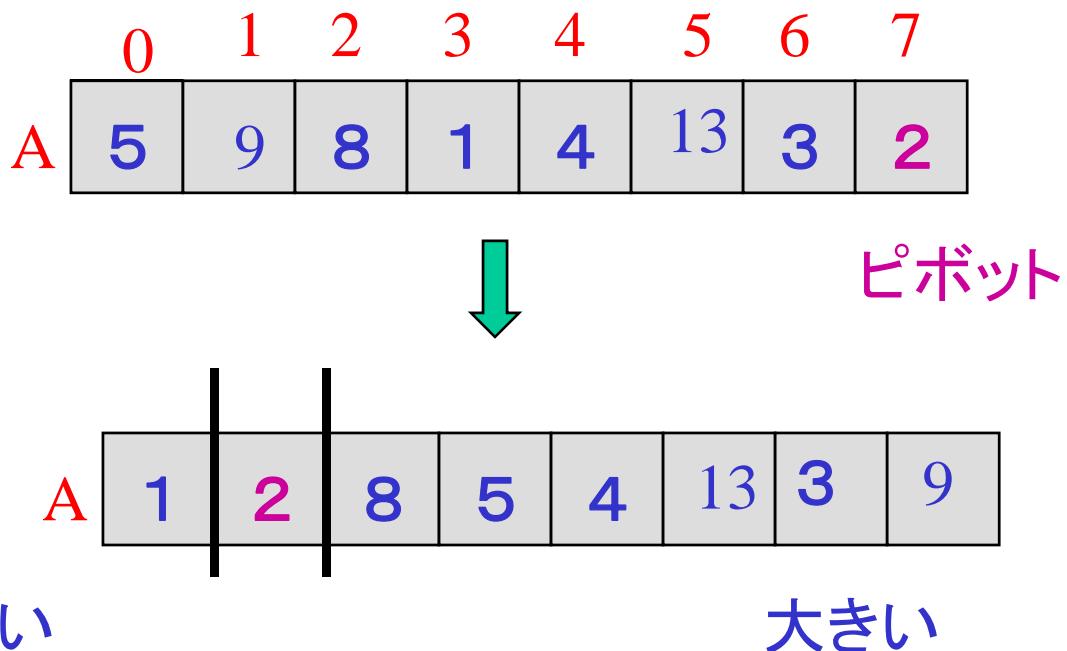
4-3: 高度なソートアルゴリズム① (分割統治法にもとづくソート)

クイックソート

クイックソートの方針

方針

- 問題を小分けにして、あとで組み合わせる。(分割統治法)
- 前半部分に特定要素(ピボット)より小さい要素を集め、後半部分にピボットより大きく要素を集める。
- ピボットの位置を確定し、小分けした問題は、再帰的にソートする。

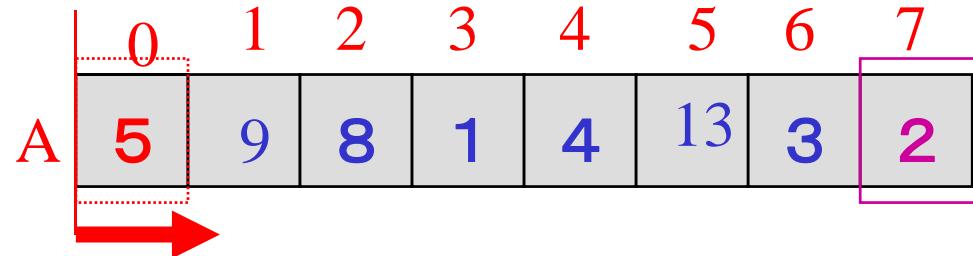


説明上の注意

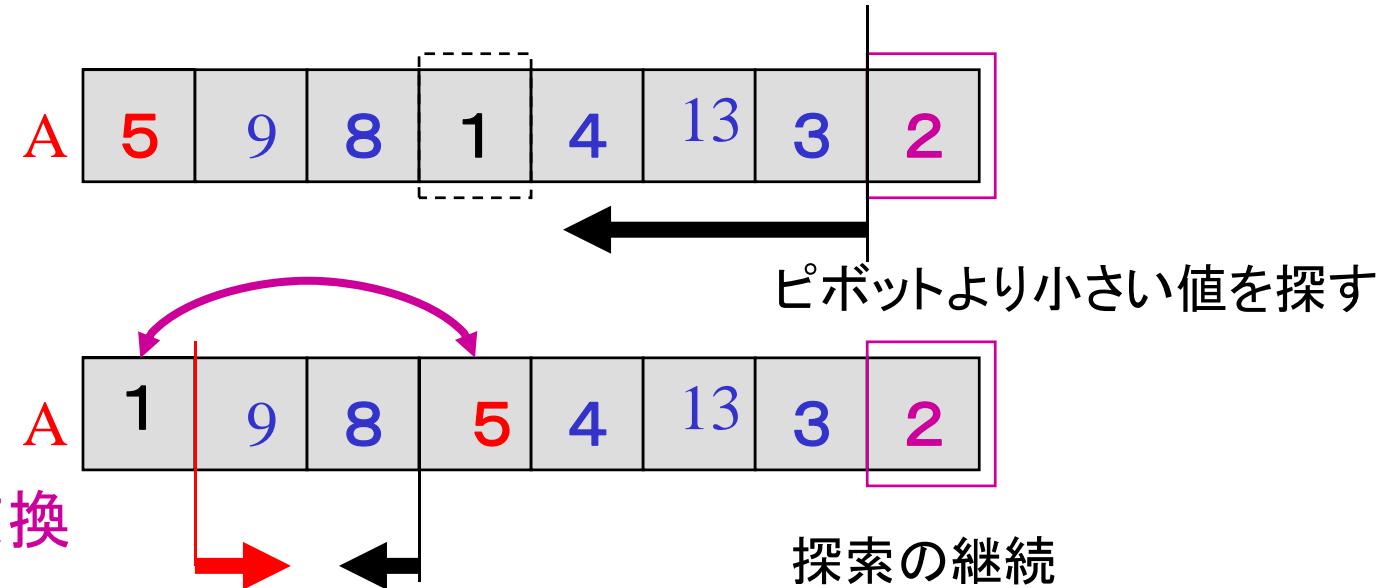
- 全てのデータが異なるとして、説明します。
- クイックソートのアルゴリズムでは、ピボットの選び方にあいまいさがあります。
(自由度といったほうがいいかも。)
ここでは、ソート範囲の最後の要素をピボットとして説明します。

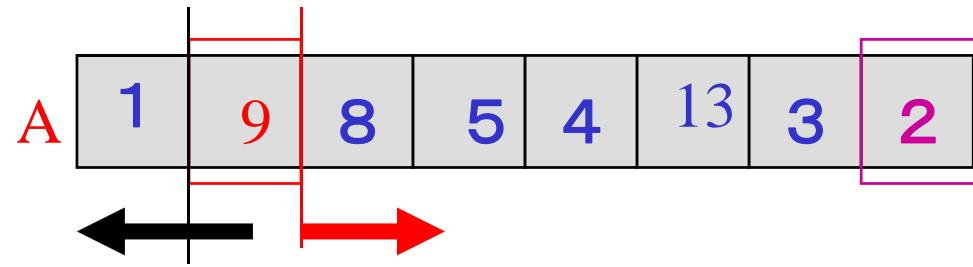
実際に、
プログラミングするときは、
もっといろんな状況を考えましょう。

クイックソートの動き前半(分割1)

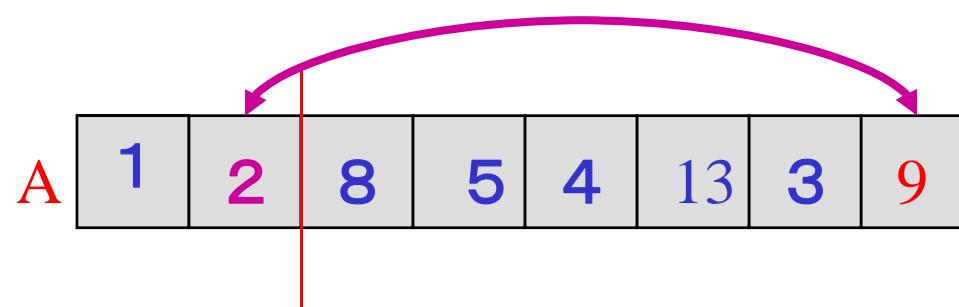


ピボットより大きい値を探す

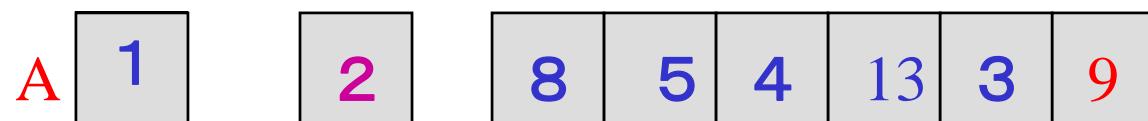




探索が交差したら分割終了。

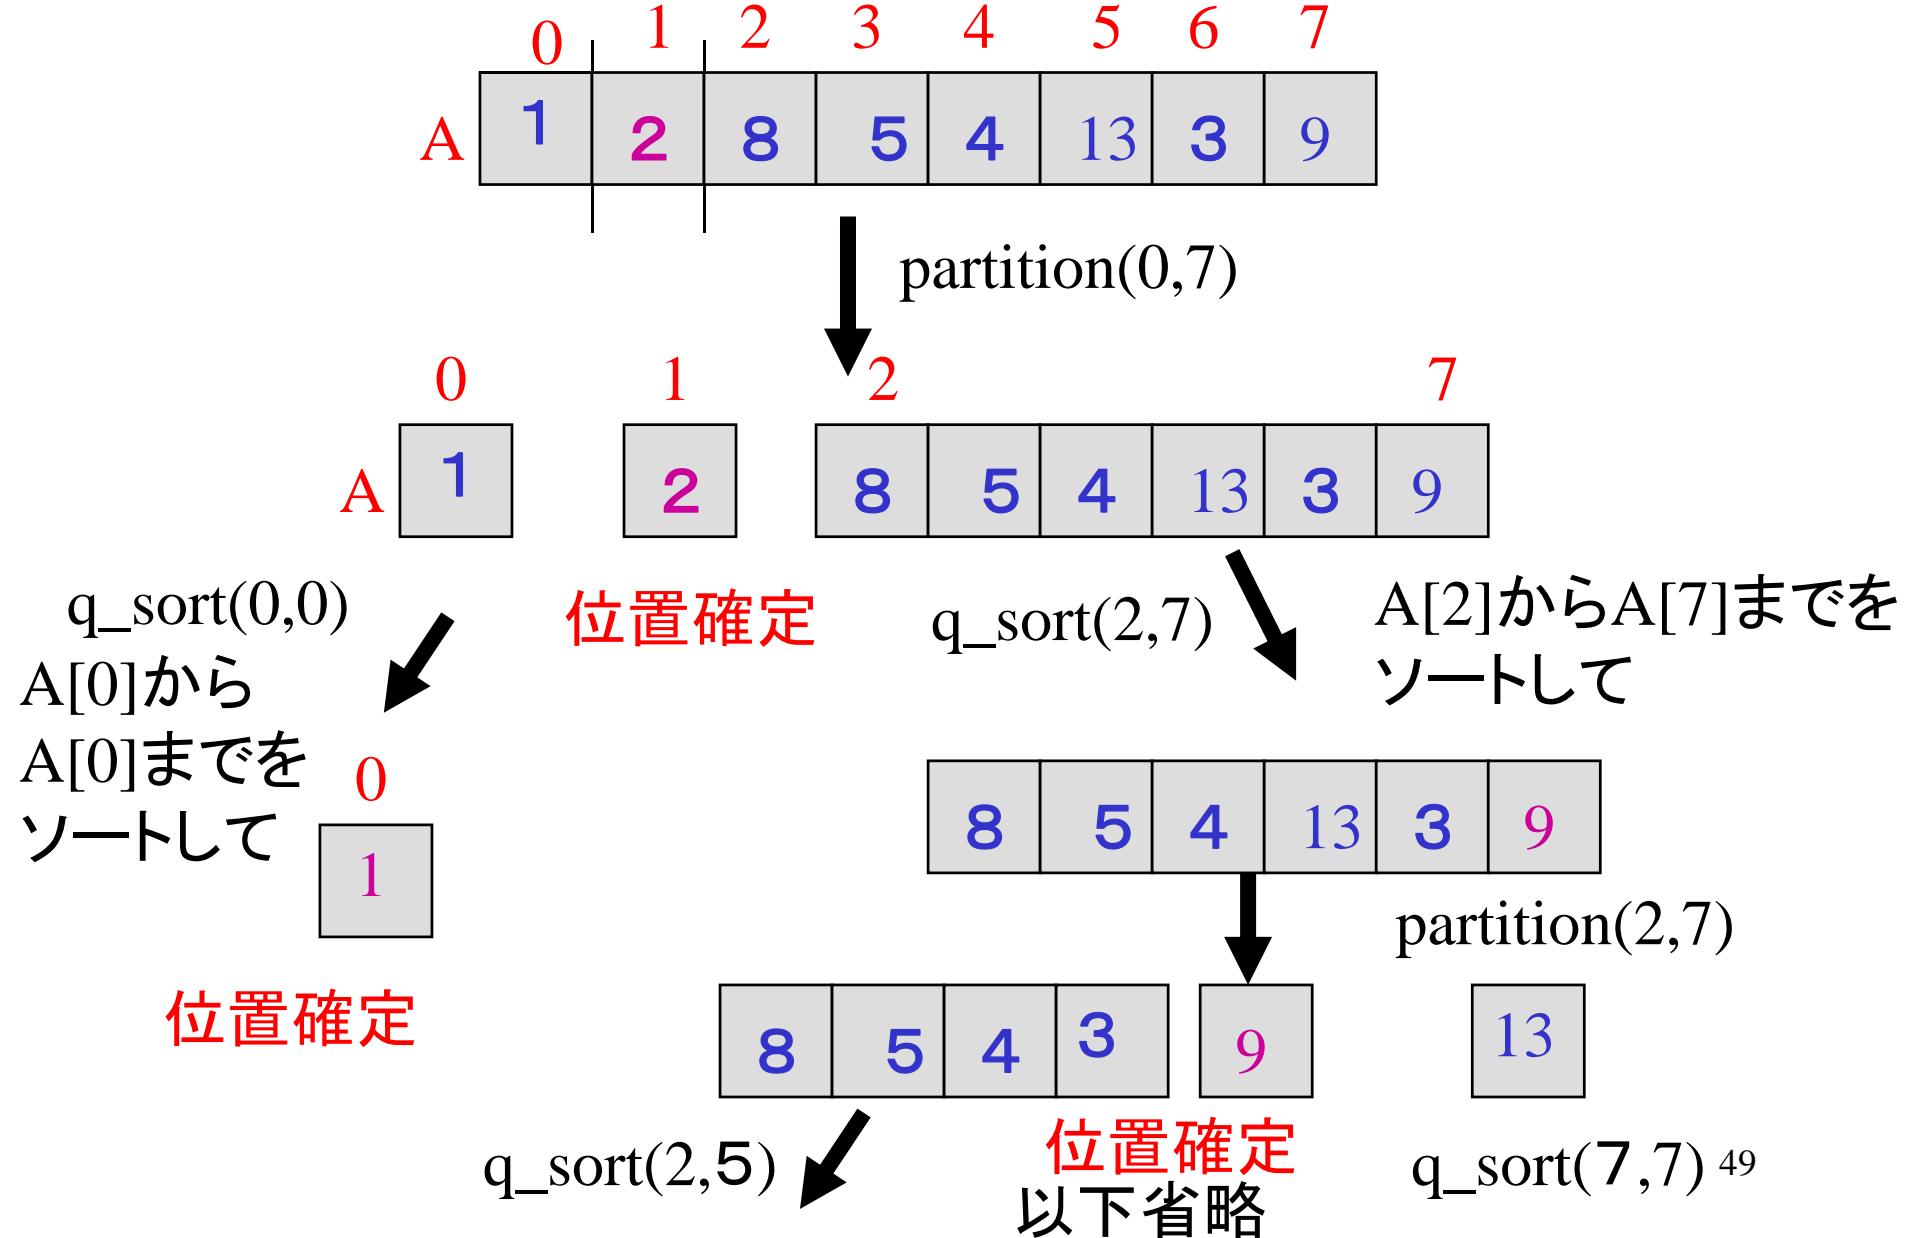


ピボットと前半最後の要素を交換し、
あとは再帰呼び出し。



ピボットは位置確定

クイックソートの動き後半(再帰)



練習

次の配列を、クイックソートでソートするとき、
前のスライドに対応する図を作成せよ。

11	25	21	1	8	3	16	5
----	----	----	---	---	---	----	---

クイックソートの実現1(分割)

```
/*概略です。細かい部分は省略*/
1. int partition(int left,int right)
2. {  double
3.     int i,j;          /*カウンタ*/
4.     i=left;
5.     j=right-1;
6.     while(TRUE){
7.         while(A[i]<pivot){i++;}
8.         while(A[j]>pivot){j--;}
9.         if(i>=j){break;}
10.        swap(&A[i],&A[j]);
11.    }
12.    swap(&A[i],&A[right]);
13.    return(i);
14.}
```

クイックソートの実現2(再帰)

```
/*概略です。細かい部分は省略*/
1. void q_sort(int left,int right)
2. {
3.     int pos;      /*分割位置 */
4.     if(left>=right)
5.     {
6.         return;
7.     }
8.     else
9.     {
10.         pos=partition(left,right);
11.         q_sort(left,pos-1);
12.         q_sort(pos+1,right);
13.         return;
14.     }
15. }
```

命題Q1(クイックソートの停止性)

$q_sort(left, right)$ は必ず停止する。

証明

$left \leq pos \leq right$ が常に成り立つことに注意する。

$k \equiv right - left$ に関する帰納法で証明する。

基礎: $k \leq 0$ のとき。

このときは、明らかにステップ6により終了する。

帰納: $k \geq 1$ のとき。

$0 \leq k' < k$ なる全ての整数に対して、 $q_sort(left, left+k')$ が終了すると仮定する。(帰納法の仮定。)

$q_sort(left, left+k)$ の停止性を考える。

このとき、else節(10-13)が実行される。

ステップ10で得られる pos の値に対して、

$$left \leq pos \leq left + k$$

が成り立つ。

ステップ11で呼び出す $q_sort(left, pos-1)$ において、
その適用される列の長さは

$$pos - 1 - left \leq left + k - 1 - left = k - 1 < k$$

である。

したがって、帰納法の仮定より、
 $q_sort(left, pos-1)$ は停止する。

ステップ12で呼び出す $q_sort(pos+1, left+k)$ において、
その適用される列の長さは

$$left + k - (pos + 1) \leq left + k - left - 1 = k - 1 < k$$

である。

したがって、帰納法の仮定より、
 $q_sort(pos+1, left+k)$ は停止する。

以上より、ステップ10-13の全ての行において、
かく再帰式は停止する。

したがって、アルゴリズム $q_sort(left, right)$ は停止する。

停止しないクイックソート

例えば、次のようなクイックソート(?)は、
停止するとは限らない。

```
1. if(left>=right)
2. {
3.     return;
4. }
5. else
6. {
7.     pos=partition(left,right);
8.     q_sort(left,pos);
9.     q_sort(pos,right);
10.    return;
11. }
12. }
```

サイズが小さくなる
とは限らない。

命題Q2(クイックソートの正当性1)

ピボットに選択された値は、partition実行により、ソート済みの順列と同じ位置に設定される。

証明 ソート済みの順列を L_S とし、アルゴリズムの途中の順列を L とする。また、ピボット p の各順列における順位をそれぞれ、 $L_S(p)$ 、 $L(p)$ と表すものとする。

このとき、 L_S において、 p 未満の要素数は $L_S(p) - 1$ であり、 p より大きい要素数は $n - L_S(p) - 1$ である。

一方、 L における p 未満の要素数は $L(p) - 1$ であるが、これは $L_S(p) - 1$ と同じはずである。
したがって、

$$L_S(p) = L(p)$$

QED 57

命題Q3(クイックソートのの正当性2)

全ての要素はピボットに選択されるか、あるいは
列の長さ1の再帰呼び出しにより位置が決定される。

証明

再帰呼び出しにおいて、サイズが減少することに
注意すると、ピボットとして選ばれるか、サイズが
1の再帰呼び出しされる。

QED

クイックソートの計算量

クイックソートは、
最悪時の計算量と平均の計算量が異なります。
これらは、
ピボットの選び方にもよりますが、
どんな選び方によっても最悪のデータ初期配置があります。

ここでは、最悪計算量と、平均計算量の両を考えます。

クイックソートの最悪計算量

まず、関数partition(i,j)の1回の時間量は、
 $j-i+1$ に比例した時間量です。

再帰の同じ深さで、partition()の時間量を
総計すると $O(n)$ になります。

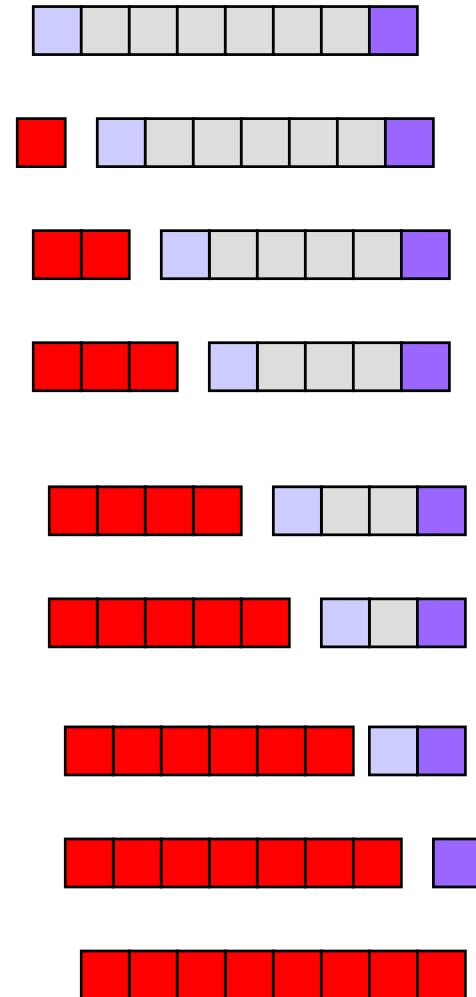
いつも0個、ピボット、残りのように
分割されるのが最悪の場合です。
つまり、ピボットとしていつも最小値が
選択されたりするのが最悪です。

(他にも最悪の場合はあります。)

このときでも、partition(i,j)の実行に
は、 $j-i+1$ 回の演算が必要です。

これは、結局選択ソートの実行と同じ
ようになります。

最悪時間計算量 $O(n^2)$ のアルゴリズム。



クイックソートの平均時間計算量

- ・ クイックソートの平均時間の解析は、複雑である。
- ・ 順を追って解析する。

漸化式の導出

初期状態として、 $n!$ 通りの並びがすべて等確率だとしましょう。

クイックソートの時間量を $T(n)$ とします。

ピボットが i 番目のときには、以下の漸化式を満たす。

$$T(n) \leq T(i-1) + T(n-i) + c_1(n-1)$$

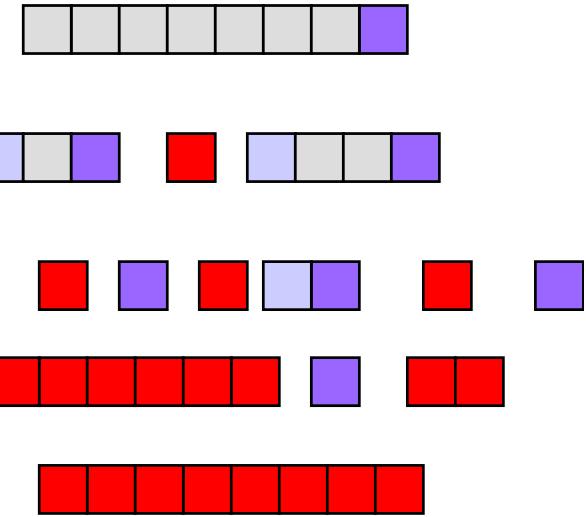
小さい方の分割を
再帰的にソートする分

大きい方の分割を
再帰的にソートする分

partition()分

ピボットの順位は、 n 通り全て均等におこるので、それらを総和して、 n で割ったものが平均時間量

$$T(n) \leq \frac{1}{n} \sum_{i=1}^n \{T(i-1) + T(n-i) + c_1(n-1)\}$$



したがって、入力順列がすべて均等に起こるという仮定では、クイックソートの平均時間計算量は、次の漸化式を満たす。

$$\begin{cases} T(0) = c_2 & n = 0 \\ T(n) \leq \frac{1}{n} \sum_{i=1}^n \{T(i-1) + T(n-i) + c_1(n-1)\} & n > 0 \end{cases}$$

漸化式の解法

漸化式における再帰式を個々に分解して調べる。

$$\begin{aligned} & \frac{1}{n} \sum_{i=1}^n \{T(i-1) + T(n-i) + c_1(n-1)\} \\ &= \frac{1}{n} \sum_{i=1}^n \{T(i-1)\} + \frac{1}{n} \sum_{i=1}^n \{T(n-i)\} + \frac{c_1}{n} \sum_{i=1}^n \{(n-1)\} \end{aligned}$$

まず、

$$\begin{aligned} \frac{c_1}{n} \sum_{i=1}^n \{(n-1)\} &= \frac{c_1}{n} \left(\underbrace{(n-1) + (n-1) + \cdots + (n-1)}_n \right) \\ &= \frac{c_1}{n} \{n(n-1)\} \\ &= c_1(n-1) \end{aligned}$$

次に、

$$\sum_{i=1}^n \{T(i-1)\} = T(0) + T(1) + \cdots + T(n-1)$$

$$\sum_{i=1}^n \{T(n-i)\} = T(n-1) + T(n-2) + \cdots + T(0)$$

$$\therefore \sum_{i=1}^n \{T(i-1)\} = \sum_{i=1}^n \{T(n-i)\}$$

したがって、

$$T(n) \leq \frac{2}{n} \sum_{i=0}^{n-1} \{T(i)\} + c_1(n-1)$$

$$\therefore nT(n) \leq 2 \sum_{i=0}^{n-1} \{T(i)\} + c_1 n(n-1)$$

n に $n-1$ を代入して、

$$(n-1)T(n-1) \leq 2 \sum_{i=0}^{n-2} \{T(i)\} + c_1(n-1)(n-2)$$

両辺の差をとる。

$$nT(n) - (n-1)T(n-1) \leq 2T(n-1) + c_1 n(n-1) - c_1(n-1)(n-2)$$

$$\therefore nT(n) - (n+1)T(n-1) \leq c_1 2(n-1)$$

両辺を $n(n+1)$ で割る。

$$\frac{T(n)}{n+1} - \frac{T(n-1)}{n} \leq c_1 2 \frac{(n-1)}{n(n+1)} \leq 2c_1 \frac{n+1}{n(n+1)} = 2c \frac{1}{n}$$

この式を辺々加える。

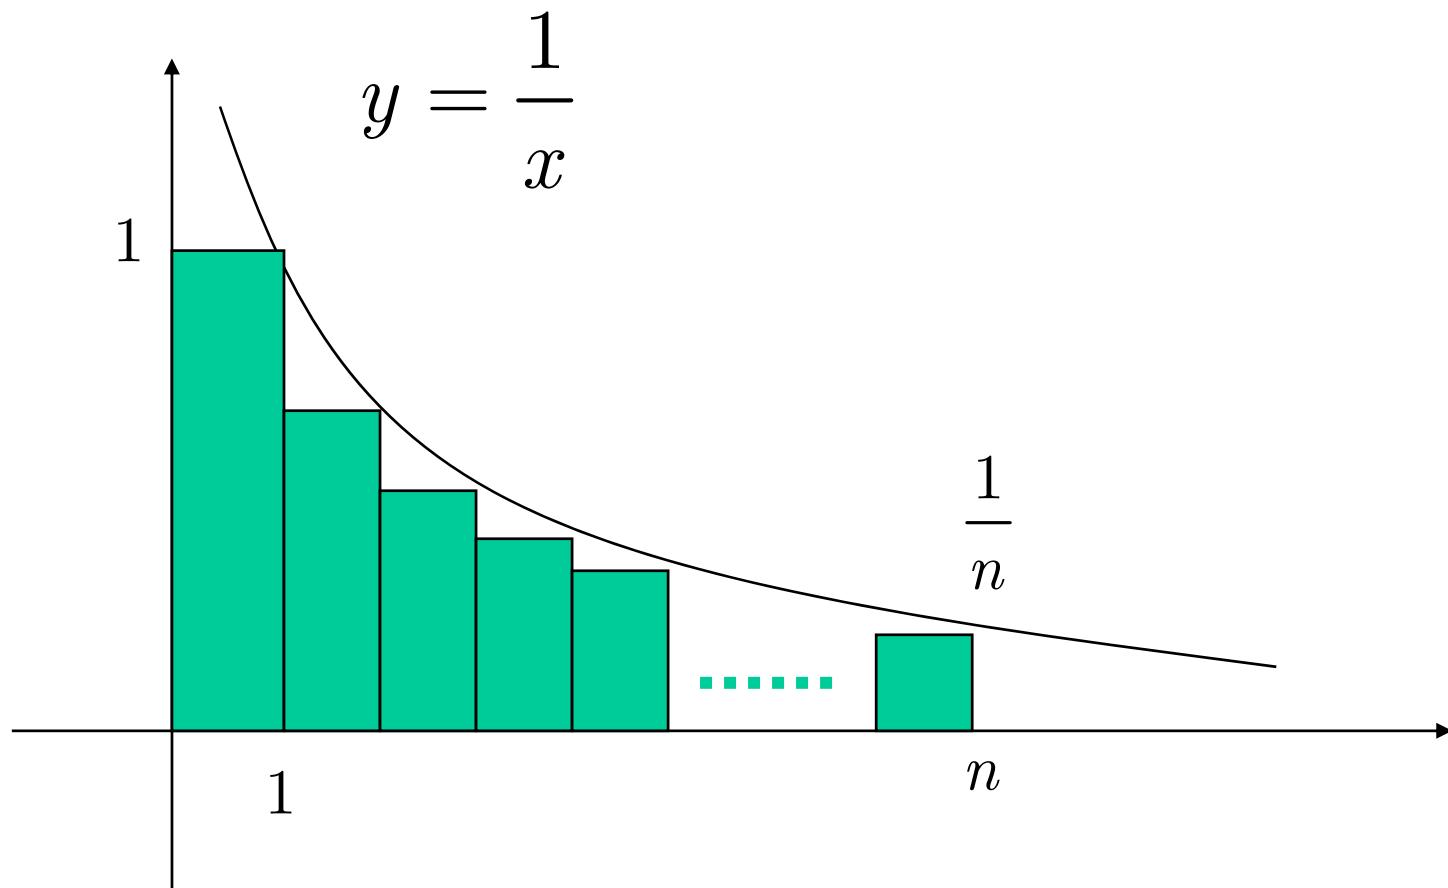
$$\begin{aligned}
 & \frac{T(n)}{n+1} - \frac{\cancel{T(n-1)}}{\cancel{n}} && \leq 2c_1 \frac{1}{n} \\
 & \cancel{\frac{T(n-1)}{n}} - \frac{\cancel{T(n-2)}}{\cancel{n-1}} && \leq 2c_1 \frac{1}{n-1} \\
 & & \vdots & \\
 & \cancel{\frac{T(3)}{4}} - \cancel{\frac{T(2)}{3}} && \leq 2c_1 \frac{1}{3} \\
 +) & \cancel{\frac{T(2)}{3}} - \frac{T(1)}{2} && \leq 2c_1 \frac{1}{2} \\
 \hline
 & \therefore \frac{T(n)}{n+1} - \frac{c_2}{2} \leq 2c_1 \left(\frac{1}{n} + \frac{1}{n-1} + \cdots + \frac{1}{2} \right) = 2c_1(H_n - 1)
 \end{aligned}$$

ここで、

$$H_n = 1 + \frac{1}{2} + \frac{1}{3} + \cdots + \frac{1}{n}$$

調和級数
(Harmonic Series)

調和級数の見積もり



$$H_n - 1 < \int_{x=1}^n \frac{1}{x} dx = \log_e n$$

$$\therefore \frac{T(n)}{n+1} - \frac{c_2}{2} \leq 2c_1(H_n - 1) < 2c_1 \log_e n$$

$$\therefore T(n) \leq 2c_1(n+1) \log_e n + \frac{c_2}{2}(n+1)$$

$$\therefore T(n) = O(n \log n)$$

以上より、クイックソートの平均計算時間量は、

$$O(n \log n)$$

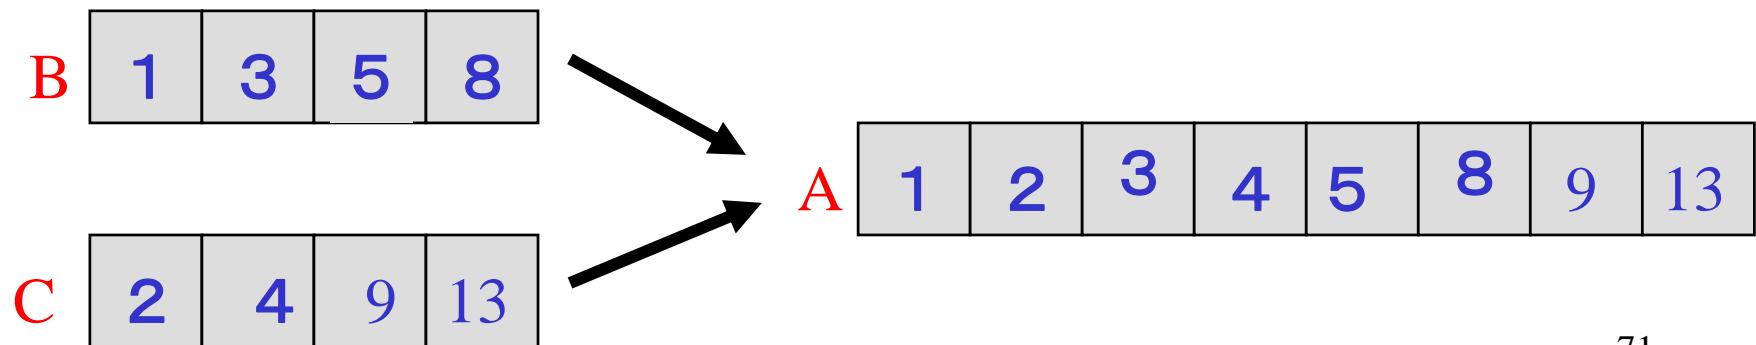
である。

マージソート

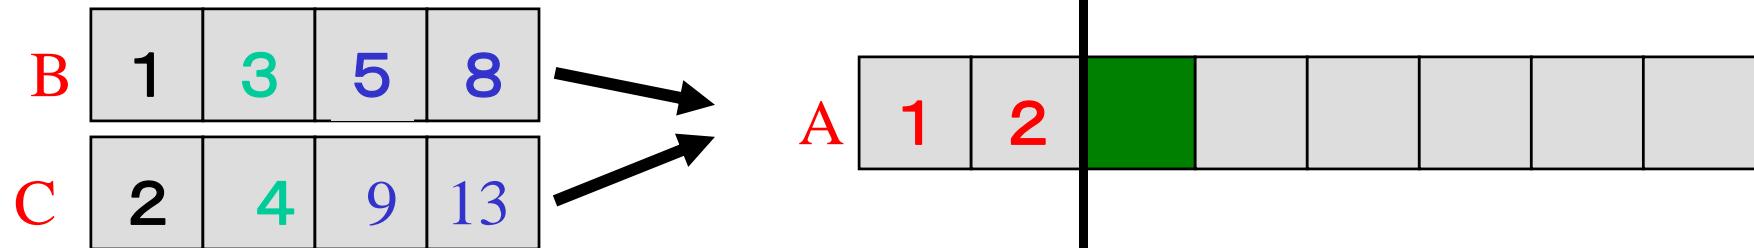
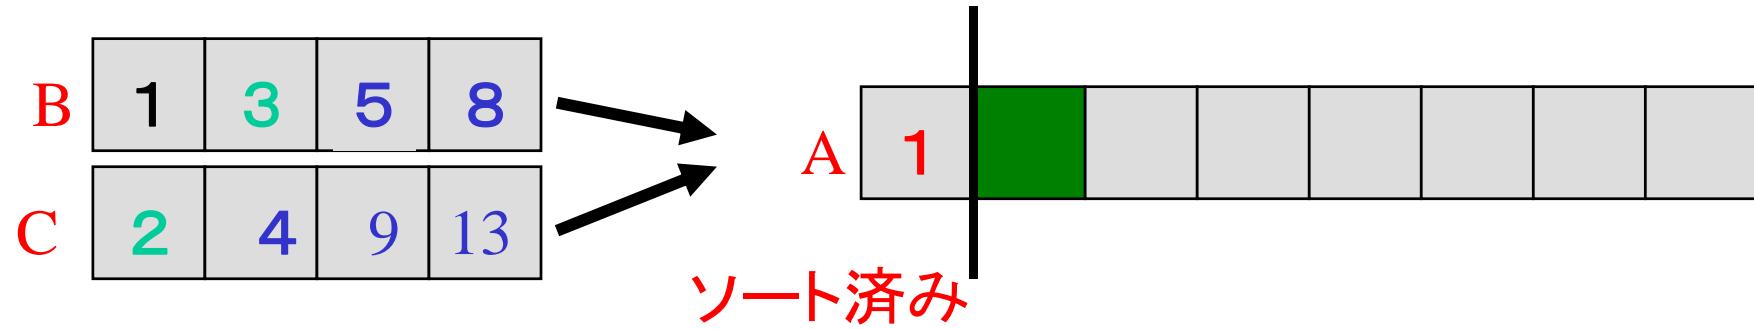
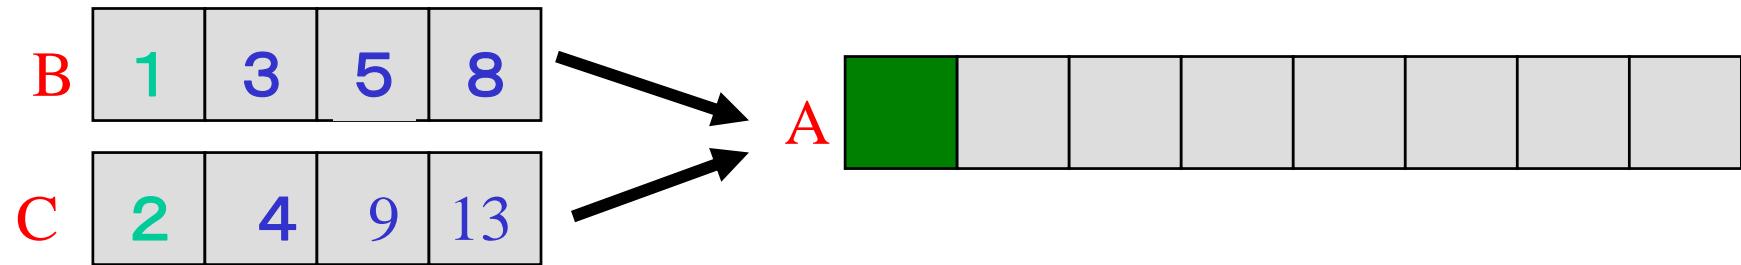
マージソートの方針

方針

- 問題を小分けにして、あとで組み合わせる。(分割統治法)
- 小分けした問題は、再帰的にソートする。
- もしソートされた2つの配列があれば、
それらのそれらを組み合わせて、
大きいソートの列をつくる。(マージ操作)
- 1要素だけの列はソート済みとみなせる。

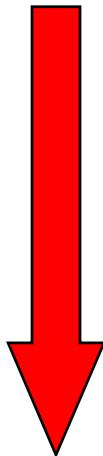


マージの動き



分割

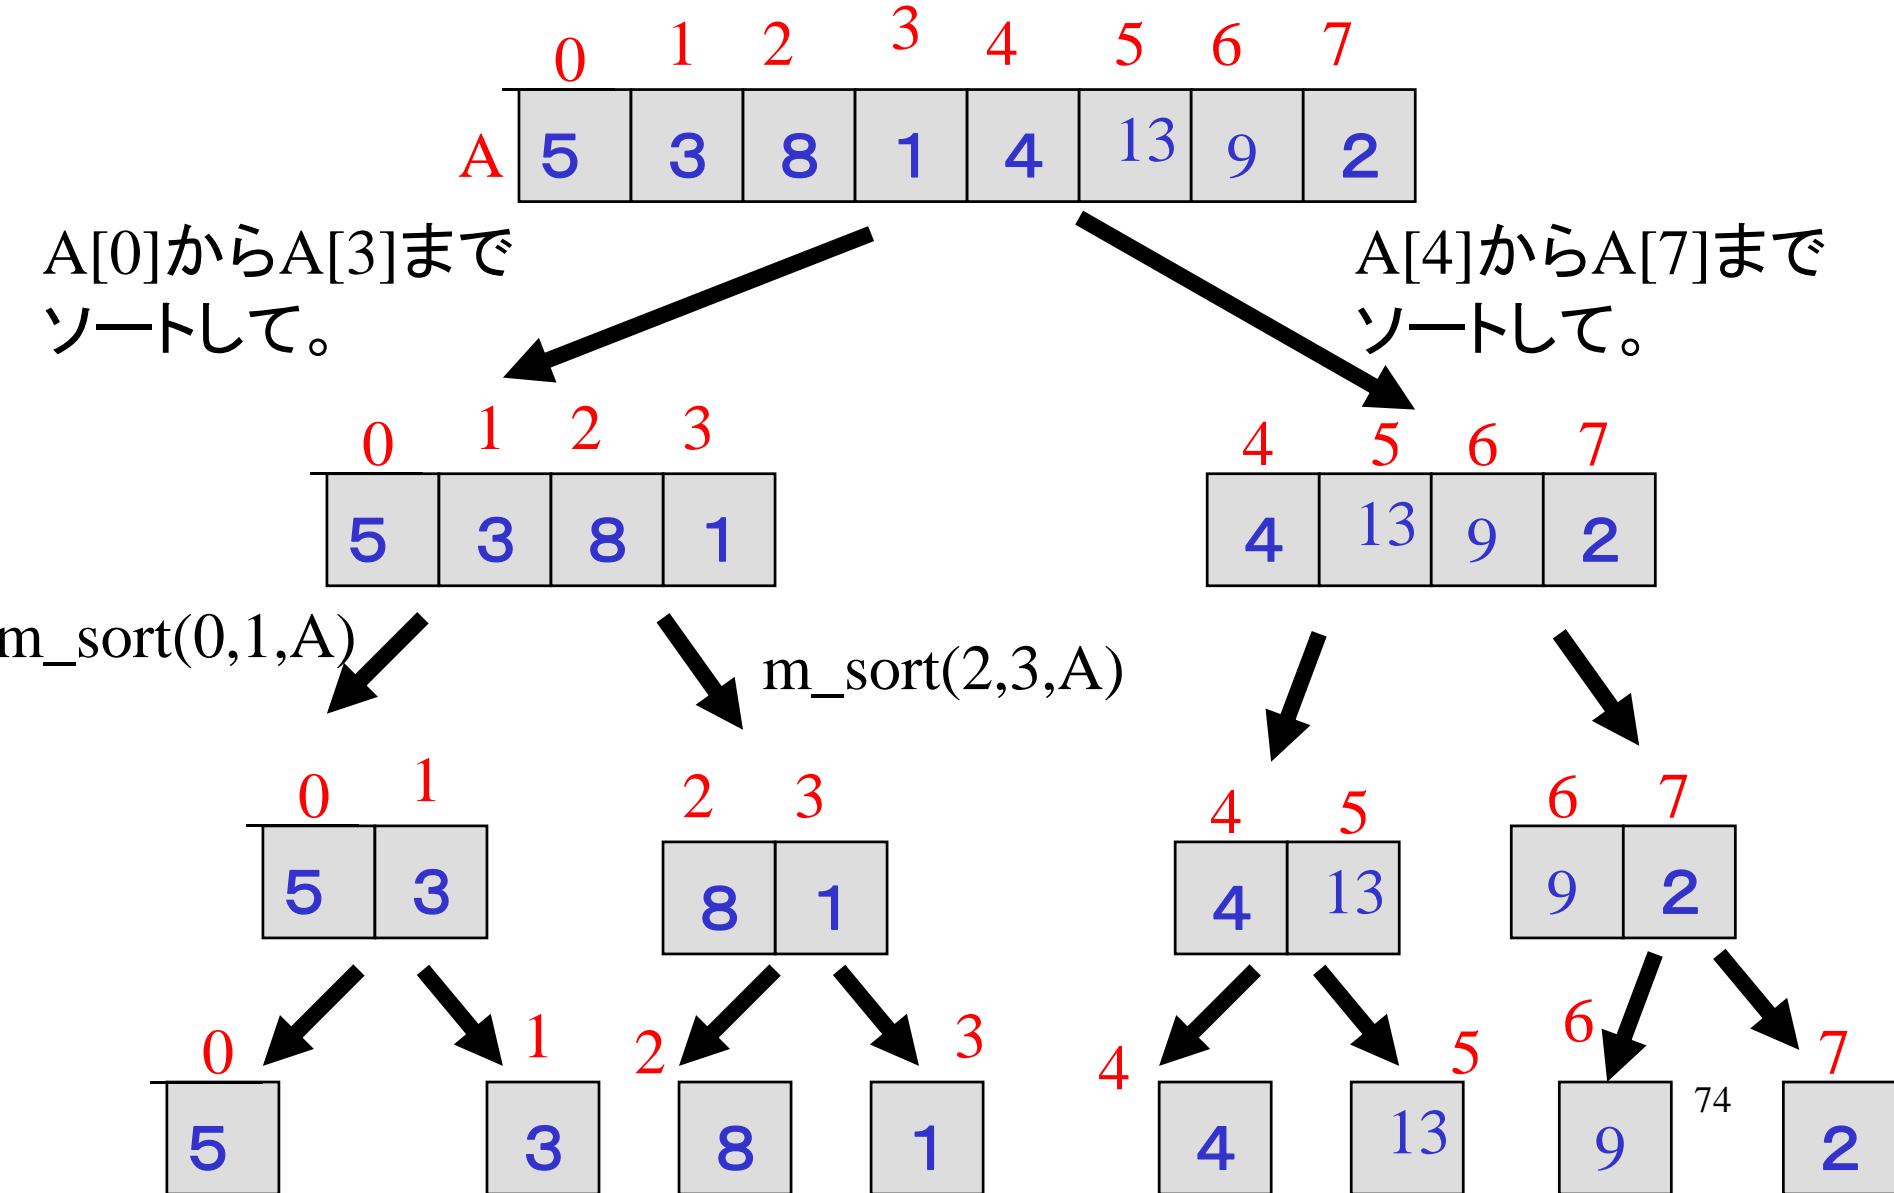
- もし2つのソート列があったら、マージ操作によって、長いソート列がえられることがわかった。
- どうやって、2つのソート列を作るのか？



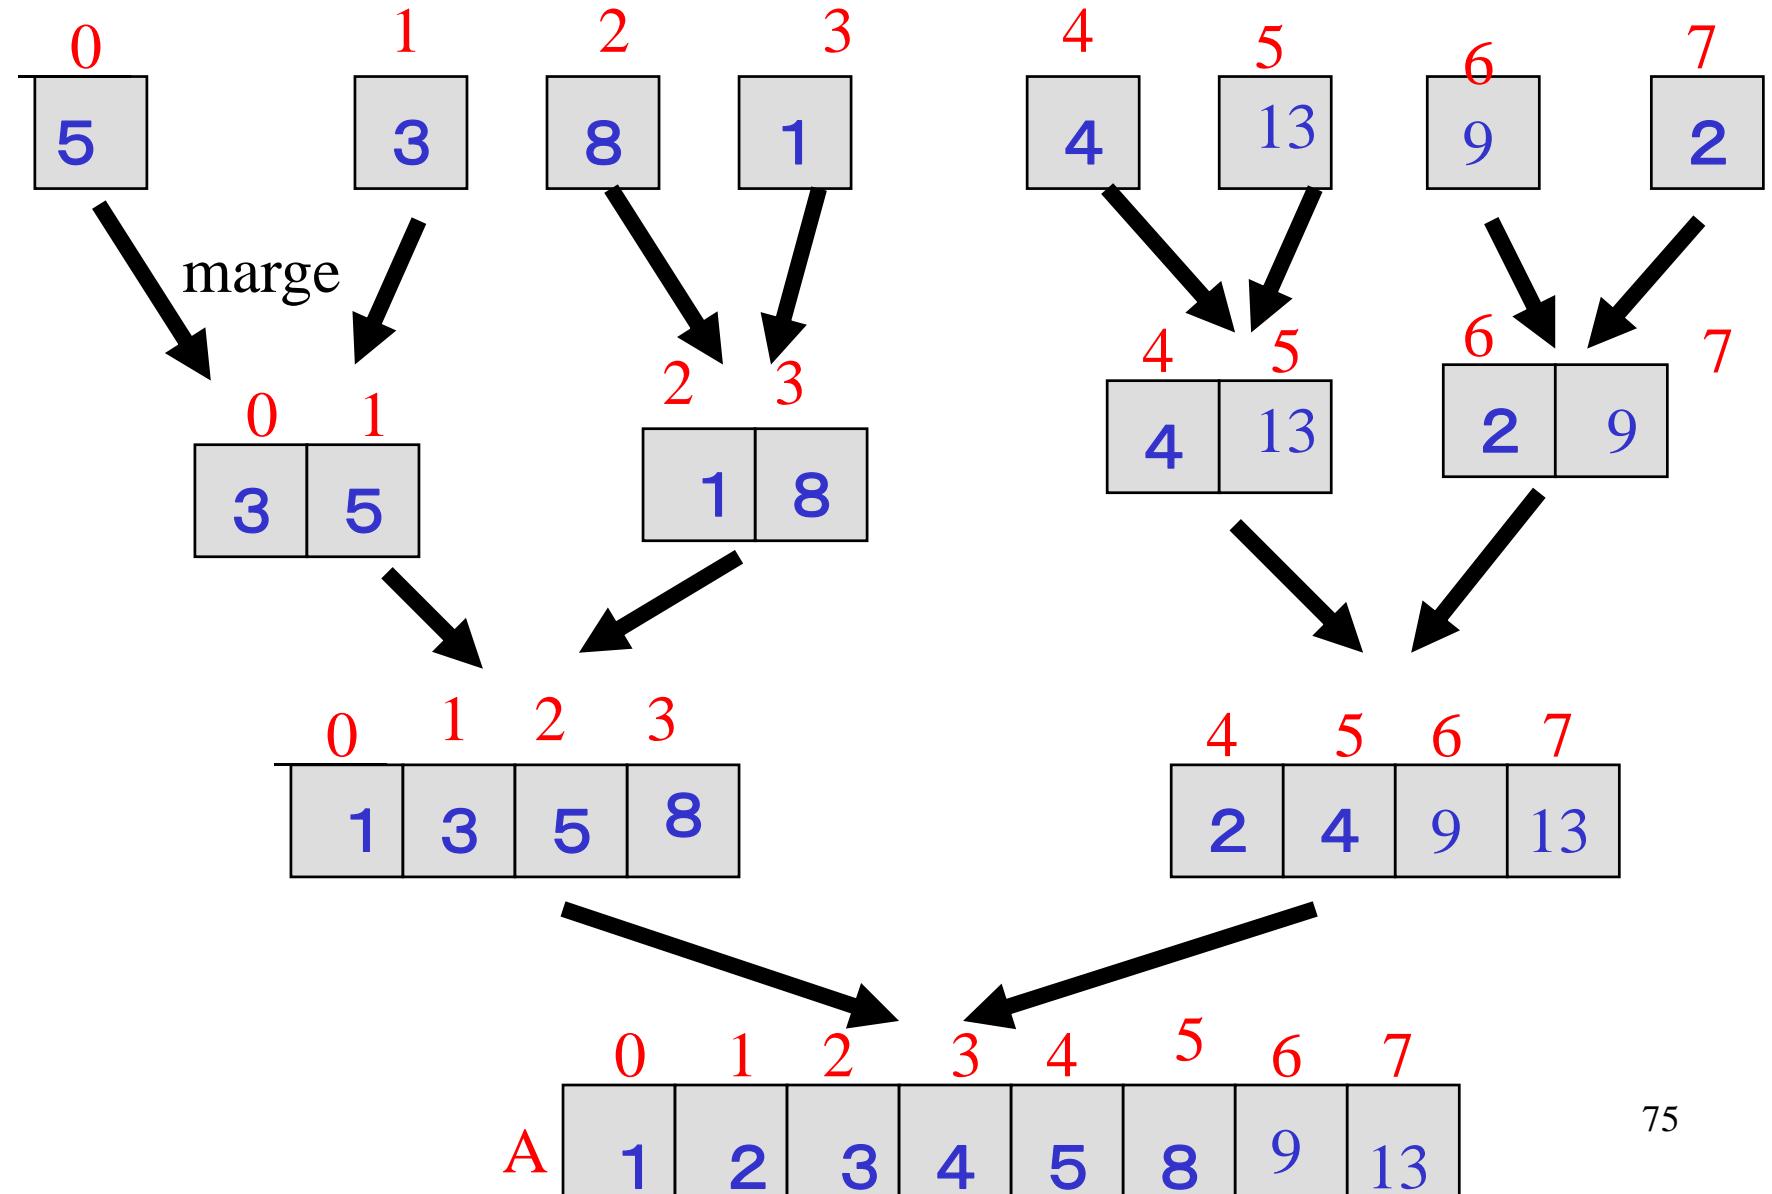
おなじ問題で、問題のサイズが小さくなっていることに注意する。

列を二等分にして、再帰的にソートする。

マージソート動き前半(分割)



マージソート動き後半(マージ)



練習

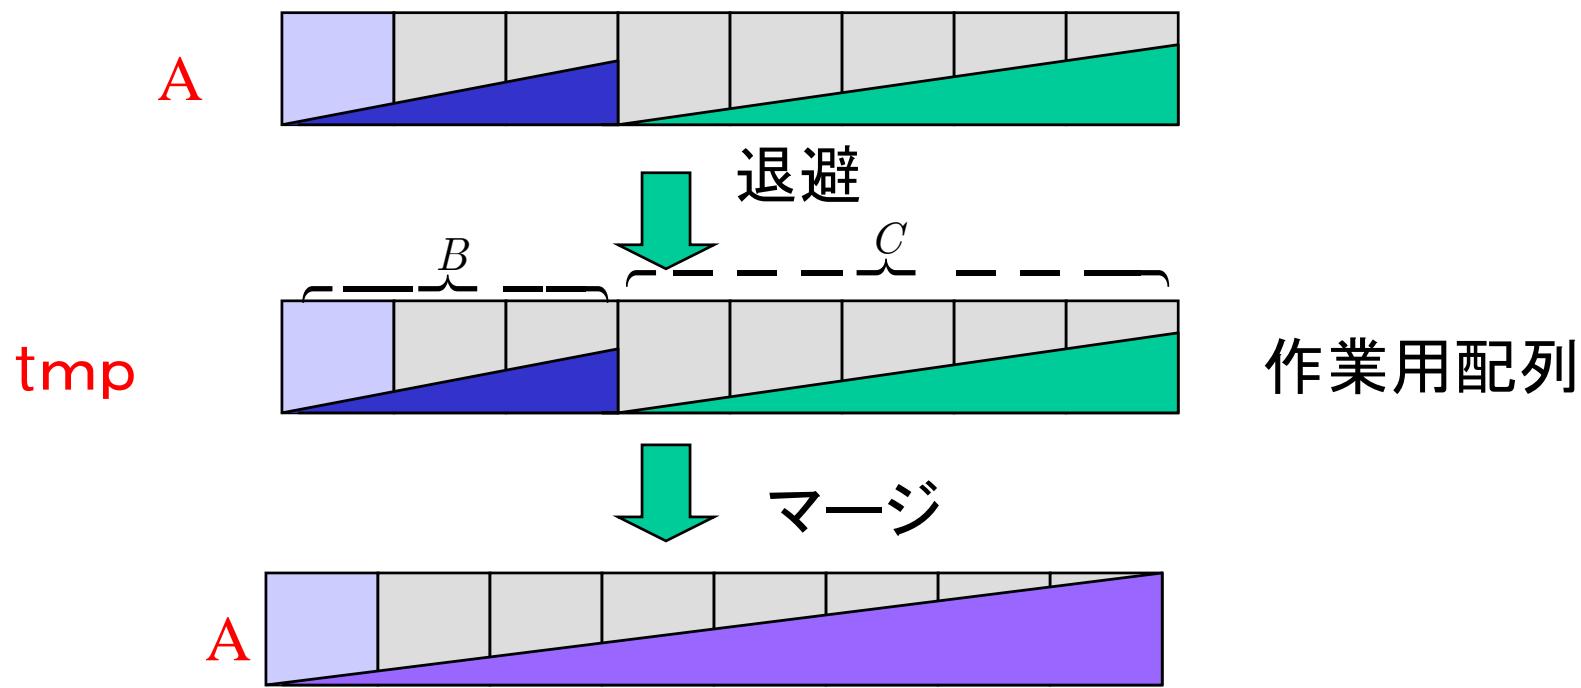
次の配列を、マージソートでソートするとき、
前のスライドに対応する図を作成せよ。

11	25	21	1	8	3	16	5
----	----	----	---	---	---	----	---

マージに関する注意

マージでは、配列の無いようをいったん別の作業用配列に蓄える必要がある。

作業用の配列が必要



データ退避の実現

```
/* A[left]-A[right]をtmp[left]-tmp[right]に書き出す。*/
void write(int left,int right)
{
    int i;
    for(i=left;i<=right;i++){
        tmp[i]=a[i];
    }
    return;
}
```

マージの実現

```
/* tmp[left]-tmp[mid]とtmp[mid+1]-tmp[right]を
A[left]-A[right]にマージする。(細かい部分は省略)*/
void marge(int)
{
    int l=left,r=mid+1; /*tmp走査用*/
    int i=left; /*A走査用*/
    for(i=left;i<=right;i++){
        if(tmp[l]<=tmp[r] && l<=mid){
            A[i]=tmp[l];l++;
        }else if(tmp[r]<tmp[l] && r<=right){
            A[i]=tmp[r];r++;
        }else if(l>mid){
            A[i]=tmp[r];r++;
        }else if(r>right){
            A[i]=tmp[l];l++;
        }
    }
    return;
}
```

マージソートの実現

```
/*概略です。細かい部分は省略*/
void merge_sort(int left,int right)
{
    int mid;      /*中央*/
    if(left>=right){
        return;
    }else{
        mid=(left+right)/2;

        merge_sort(left,mid);
        merge_sort(mid+1,right);

        write(left,right);
        merge(left,mid,right);
        return;
    }
}
```

命題M1(マージの正当性)

マージにより、2つの短いソート列から、
一つの長いソート列が得られる。

証明

配列Aの走査用のカウンタに関する帰納法で
証明することができる。(厳密な証明は省略)

QED 81

命題M2(マージソートの正当性)

マージソートにより、配列が昇順にソートされる。

証明

再帰の深さに関する帰納法や、
あるいはソートされている部分列の長さに関する帰納法
で証明できる。(厳密な証明は省略。)

命題M3(マージソートの停止性)

マージソートは停止する。

証明

再帰呼び出しにおいて、必ずサイズが小さくなる(約半分)
ことに注意する。

また、要素数が1以下の時には、停止することにも注意する。
これらの考察から、帰納法で証明できる。
(厳密な証明は省略。)

マージソートの計算量

まず、マージの計算量 $M(n)$ を考えます。

明らかに、出来上がるソート列の長さに比例した時間量です。

$$\therefore M(n) = O(n)$$

マージソートの時間量を $T(n)$ とします。

以下の再帰式を満たします。

$$\begin{cases} T(1) = c_1 \\ T(n) \leq T\left(\frac{n}{2}\right) + T\left(\frac{n}{2}\right) + M(n) = 2T\left(\frac{n}{2}\right) + c_2 n \end{cases}$$

解析を簡単にするため、データを $n = 2^k$ 個あると仮定します。

$$\begin{cases} T(1) = c_1 \\ T(n) \leq 2T\left(\frac{n}{2}\right) + c_2 n \end{cases} \quad \xrightarrow{\text{ }} \quad \begin{cases} T'(0) = c_1 \\ T'(k) \leq 2T'(k-1) + c_2 2^k \end{cases}$$

$$\begin{aligned} T'(k) &\leq 2T'(k-1) + c_2 2^k \\ &\leq 2(2T'(k-2) + c_2 2^{k-1}) + c_2 2^k = 4T'(k-2) + 2c_2 2^k \\ &\leq 4(2T'(k-3) + c_2 2^{k-2}) + 2c_2 2^k = 8T'(k-3) + 3c_2 2^k \\ &\vdots \\ &\leq 2^k T'(0) + c_2 k 2^k = (c_1 + c_2 k) 2^k \end{aligned}$$

$$\therefore T(n) \leq n(c_2 \log n + c_1) = c_2 n \log n + c_1 n$$

$$\therefore T(n) = O(n \log n)$$

$n \neq 2^k$ であるような一般的な入力サイズに対しては、
もう一段階解析の途中を考察する。

任意の n に対して、 $2^l \leq n < 2^{l+1}$ を満たす l が必ず存在する。

よって、 $T(2^l) \leq T(n) < T(2^{l+1})$

$$\therefore T(n) \leq T(2^{l+1}) = \{c_1 + c_2(l+1)\} 2^{l+1}$$

一方 $l \leq \log n < l+1$

$$\therefore \log n - 1 < l \leq \log n$$

したがって、 $\therefore T(n) \leq \{c_1 + c_2(\log n + 1)\} 2^{\log n + 1}$

$$= 2c_1n + 2c_2n \log n + 2c_2n$$
$$= 2c_2n \log n + 2n(c_1 + c_2)$$
$$\therefore T(n) = O(n \log n)$$

結局、どのような入力に対しても、マージソートの最悪時間計算量は、

$$O(n \log n)$$

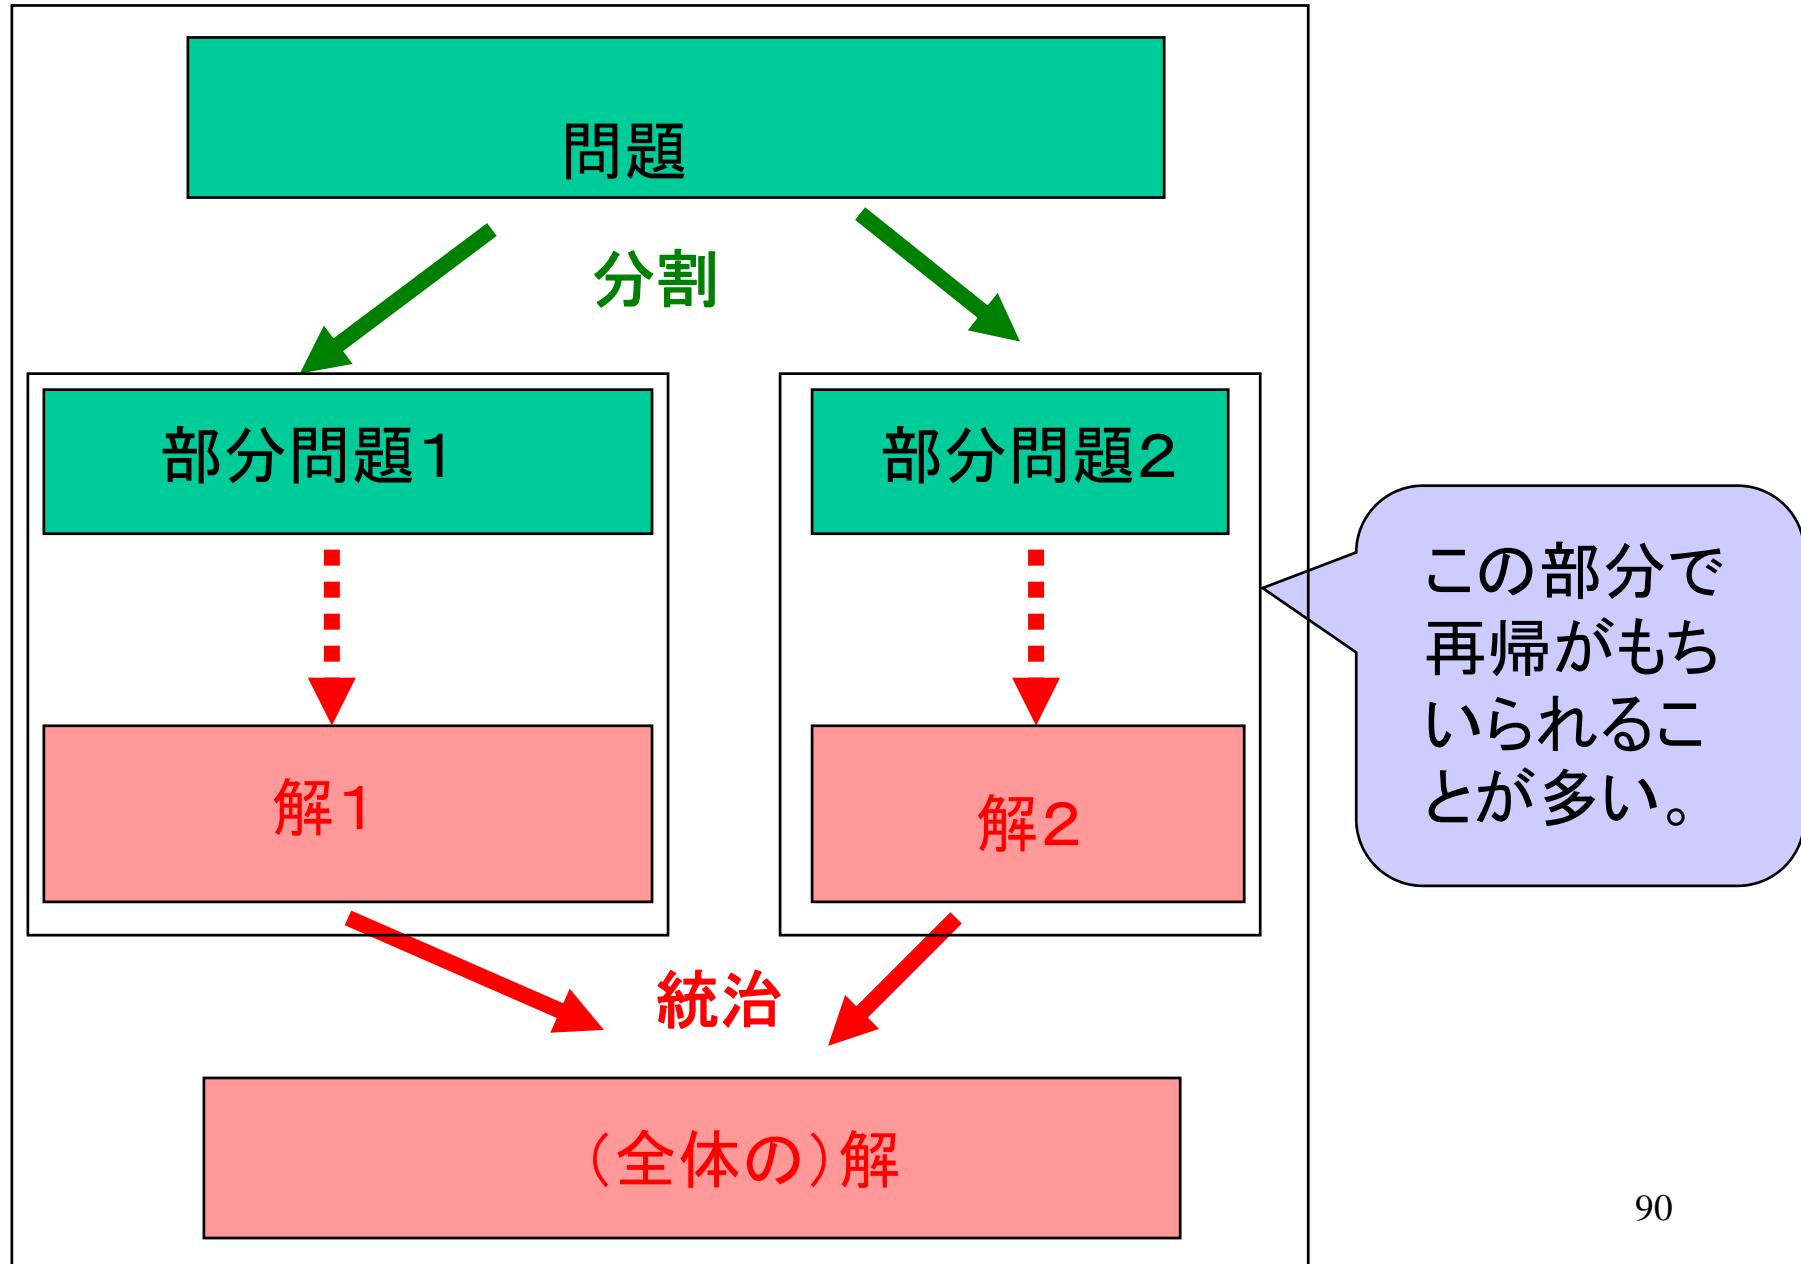
である。

分割統治法について

分割統治法とは

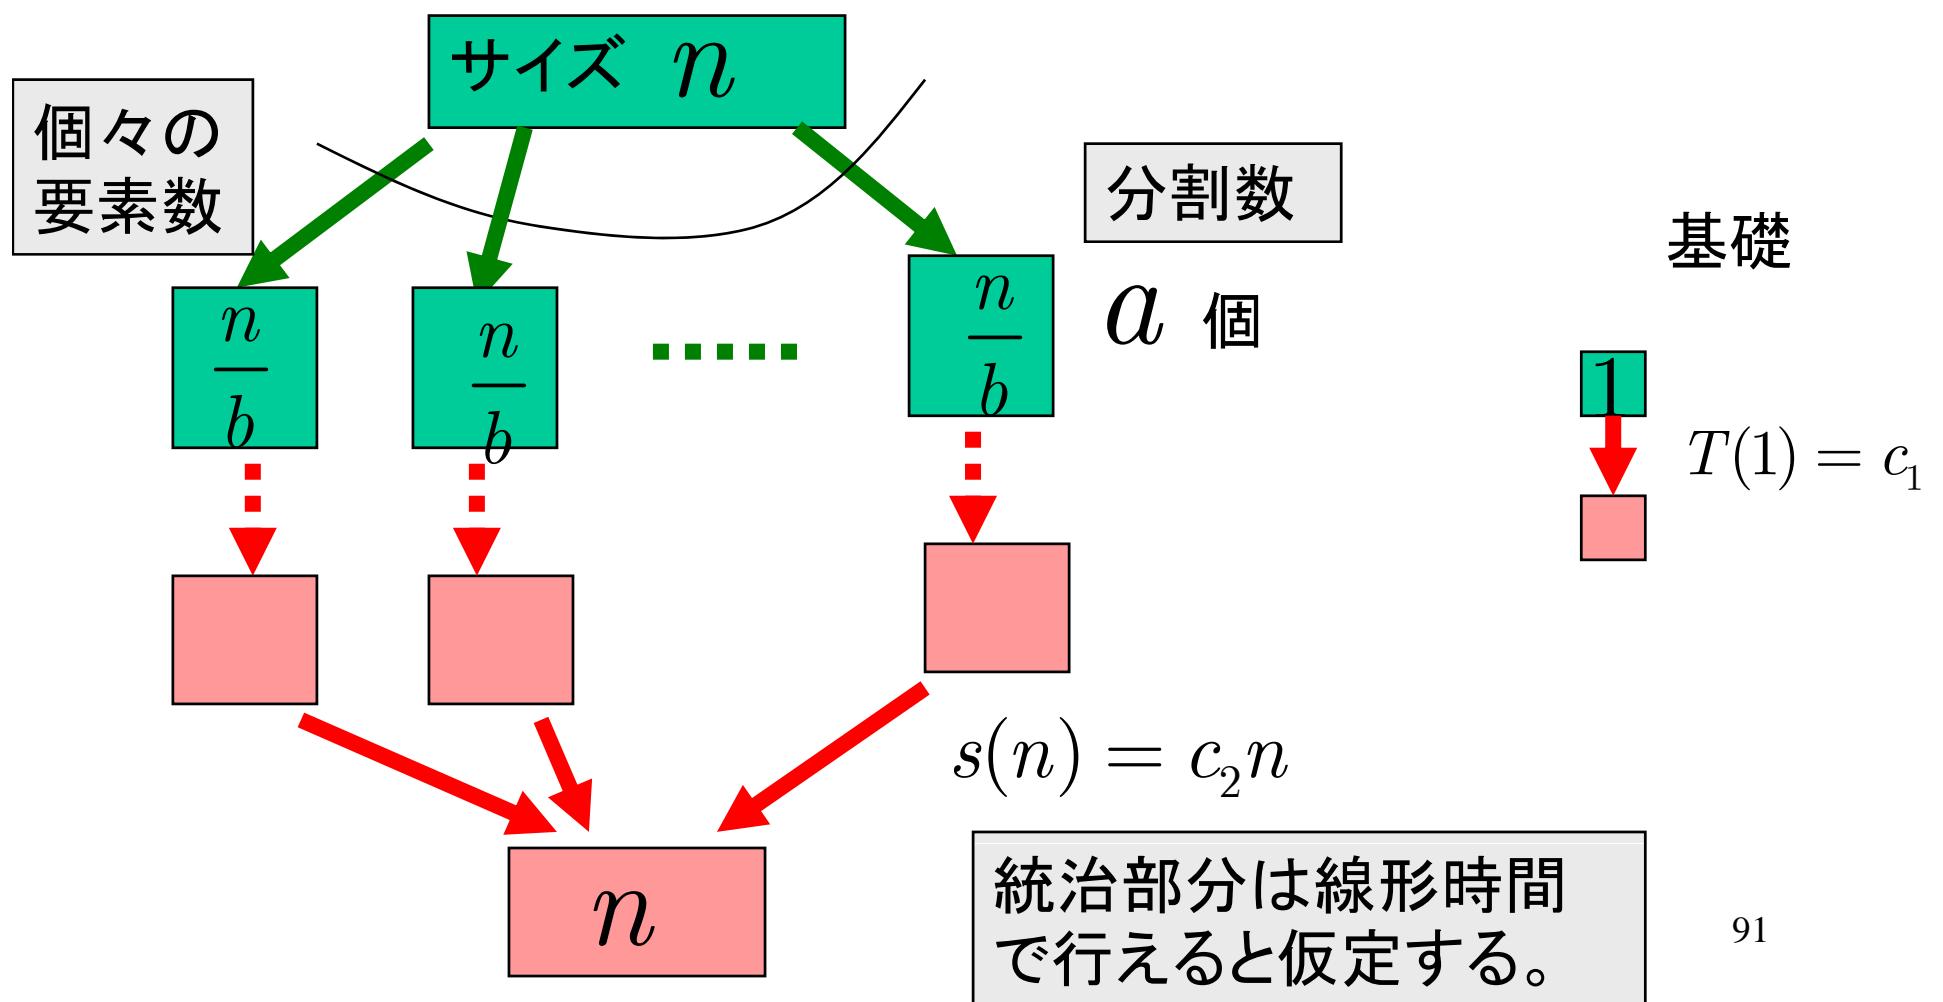
- 元の問題をサイズの小さいいくつかの部分問題に分割し、
- 個々の部分問題を何らかの方法で解決し、
- それらの解を統合することによって、元の問題を解決する方法のことである。
- (分割統治法に基づくアルゴリズムは、再帰を用いると比較的容易に記述することができる。)

分割統治法のイメージ



分割統治法の時間計算量

ここでは、より一般的な分割統治法における計算量を考察する。



一般的な分割統治法における時間計算量 $T(n)$ は、次の漸化式で表されることが多い。

$$\begin{cases} T(1) = c_1 & (n = 1) \\ T(n) = aT\left(\frac{n}{b}\right) + c_2 n & (n > 1) \end{cases}$$

この漸化式を解く。

$$T(n) = aT\left(\frac{n}{b}\right) + c_2 n$$

$\frac{n}{b}$ を代入して次式を得る。

$$T\left(\frac{n}{b}\right) = aT\left(\frac{n}{b^2}\right) + c_2 \frac{n}{b}$$

この式を上式に代入する。

$$\begin{aligned}
T(n) &= aT\left(\frac{n}{b}\right) + c_2 n \\
&= a \left\{ aT\left(\frac{n}{b^2}\right) + c_2 \frac{n}{b} \right\} + c_2 n = a^2 T\left(\frac{n}{b^2}\right) + c_2 n \left(1 + \frac{a}{b}\right) \\
&= a^2 \left\{ aT\left(\frac{n}{b^3}\right) + c_2 \frac{n}{b^2} \right\} + c_2 n \left(1 + \frac{a}{b}\right) = a^3 T\left(\frac{n}{b^3}\right) + c_2 n \left\{ 1 + \frac{a}{b} + \left(\frac{a}{b}\right)^2 \right\} \\
&\vdots \\
&= a^k T\left(\frac{n}{b^k}\right) + c_2 n \left\{ 1 + \frac{a}{b} + \cdots + \left(\frac{a}{b}\right)^k \right\} = a^k T\left(\frac{n}{b^k}\right) + c_2 n \sum_{i=0}^{k-1} \left(\frac{a}{b}\right)^i
\end{aligned}$$

a と b の大小関係で式が異なる。

等比級数の和

ここで、 $n = b^k$ と仮定する。 $k = \log_b n$
(一般の n でもほぼ同様に求めることができる。)

場合1: $a < b$ すなわち $\frac{a}{b} < 1$ のとき

$$\begin{aligned} T(n) &= a^k T\left(\frac{n}{b^k}\right) + c_2 n \sum_{i=0}^{k-1} \left(\frac{a}{b}\right)^i \\ &= a^k T(1) + c_2 n \frac{1 - \left(\frac{a}{b}\right)^k}{1 - \frac{a}{b}} \\ &\leq c_1 b^k + c_2 n \frac{1}{1 - \frac{a}{b}} = (c_1 + c_2 \frac{b}{b-a})n \end{aligned}$$
$$\therefore T(n) = O(n)$$

この場合は線形時間アルゴリズムが得られる。

場合2: $a = b$ すなわち $\frac{a}{b} = 1$ のとき

$$\begin{aligned} T(n) &= a^k T\left(\frac{n}{b^k}\right) + c_2 n \sum_{i=0}^{k-1} \left(\frac{a}{b}\right)^i \\ &= a^k T(1) + c_2 n \sum_{i=0}^{k-1} 1 \\ &= c_1 b^k + c_2 n k \\ &= c_1 n + c_2 n \log_b n \end{aligned}$$

$$\therefore T(n) = O(n \log n)$$

この場合は、典型的な $O(n \log n)$ 時間のアルゴリズムが得られる。

場合3: $a > b$ すなわち $\frac{a}{b} > 1$ のとき

$$\begin{aligned}
 T(n) &= a^k T\left(\frac{n}{b^k}\right) + c_2 n \sum_{i=0}^{k-1} \left(\frac{a}{b}\right)^i \\
 &= a^k T(1) + c_2 n \frac{\left(\frac{a}{b}\right)^k - 1}{\frac{a}{b} - 1} \\
 &= c_1 a^k + c_2 \frac{b}{a-b} (a^k - n) \quad (\because n = b^k) \\
 &\leq \left(c_1 + c_2 \frac{b}{a-b}\right) a^k = \left(c_1 + c_2 \frac{b}{a-b}\right) n^{\log_b a}
 \end{aligned}$$

ここで、 $p \equiv \log_b a > 1$ とおく。

$$\therefore T(n) = O(n^p)$$

この場合は指数時間アルゴリズムになってしまう。

分割統治法の計算時間のまとめ

- 分割数(a)がサイズ縮小(b)より小さい場合には、線形時間アルゴリズム
- 分割数(a)とサイズ縮小(b)が等しい場合には、 $O(n \log n)$ 時間のアルゴリズム
(マージソートがこの場合に相当する。)
- 分割数(a)がサイズ縮小(b)より大きい場合
指数時間アルゴリズムになってしまう。

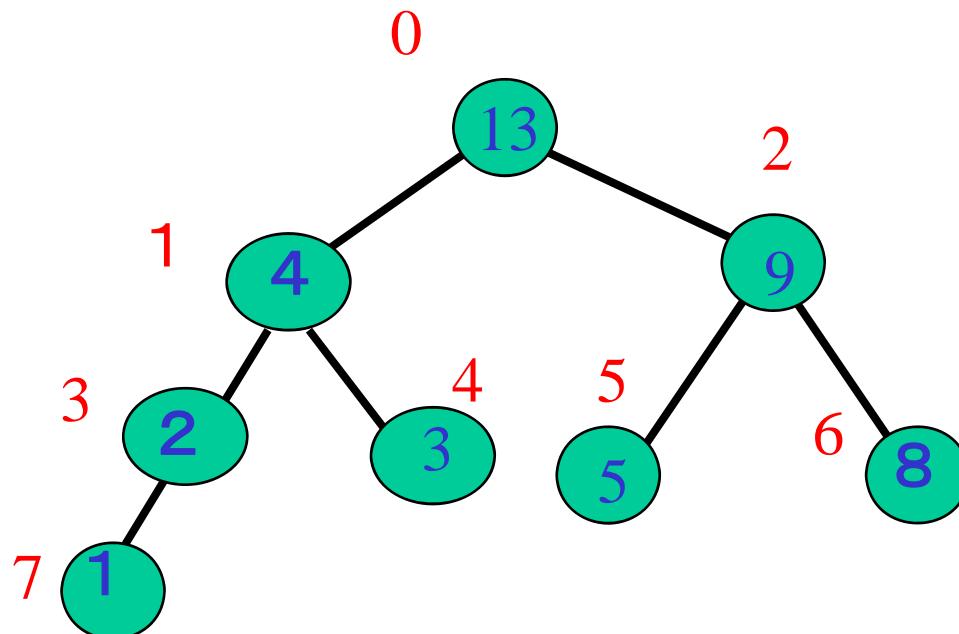
4-3: 高度なソートアルゴリズム② (データ構造にもとづくソート)

ヒープソート

ヒープソートの方針

方針

- ヒープを使ってソートする。
- 先頭から順にヒープに挿入し、データ全体をヒープ化する。
- 最大値を取り出して、最後のデータにする。



ヒープとは

データ構造の一種。

(最大や、最小を効率良く見つけることができる。)

n 点からなるヒープとは、次の条件を満足する2分木。

● 深さ $\lfloor \log_2 n \rfloor - 1$ までは、完全2分木。

● 深さ $\lfloor \log_2 n \rfloor$ では、要素を左につめた木。

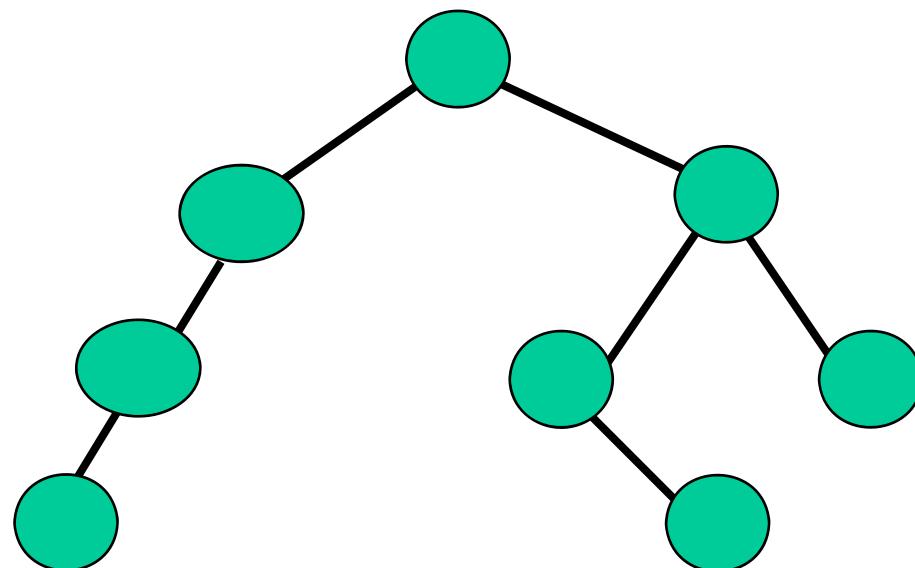
● 全ての節点において、
親の値が子の値より小さい(大きい。)

この条件は、ある
節点の値は、そ
の子孫の節点全
ての値より、小
さい(大きい)とす
ることもできる。

まず、このデータ構造(ヒープ)に関するこことを順に見ていく。

2分木

- 高々2つ子しかない木。
- 左と右の子を区別する。

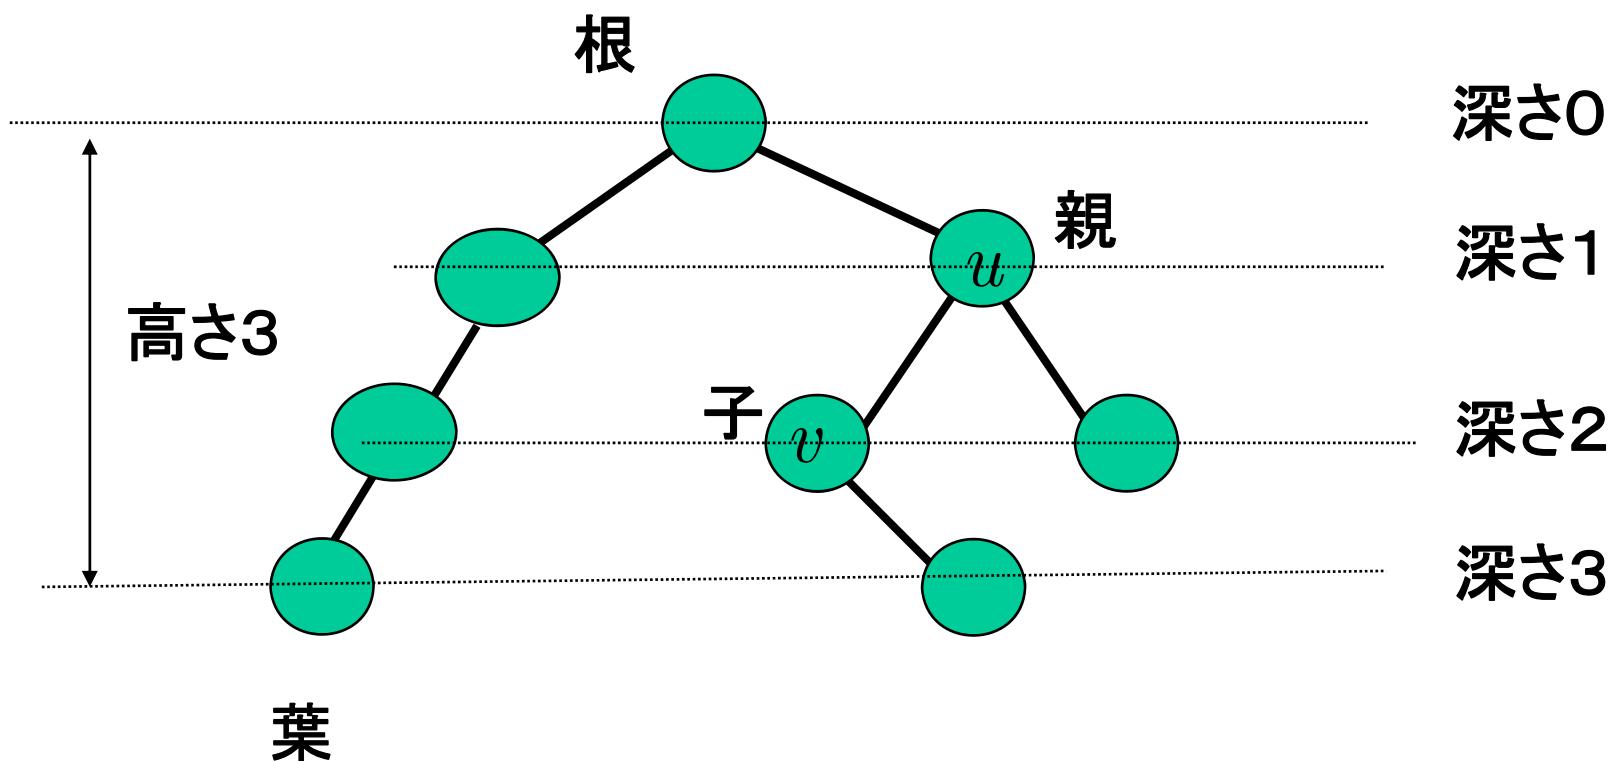


2分木においては、左と右の子を区別するので、
次の2つの2分木は同一ではない。

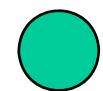


木に関する用語

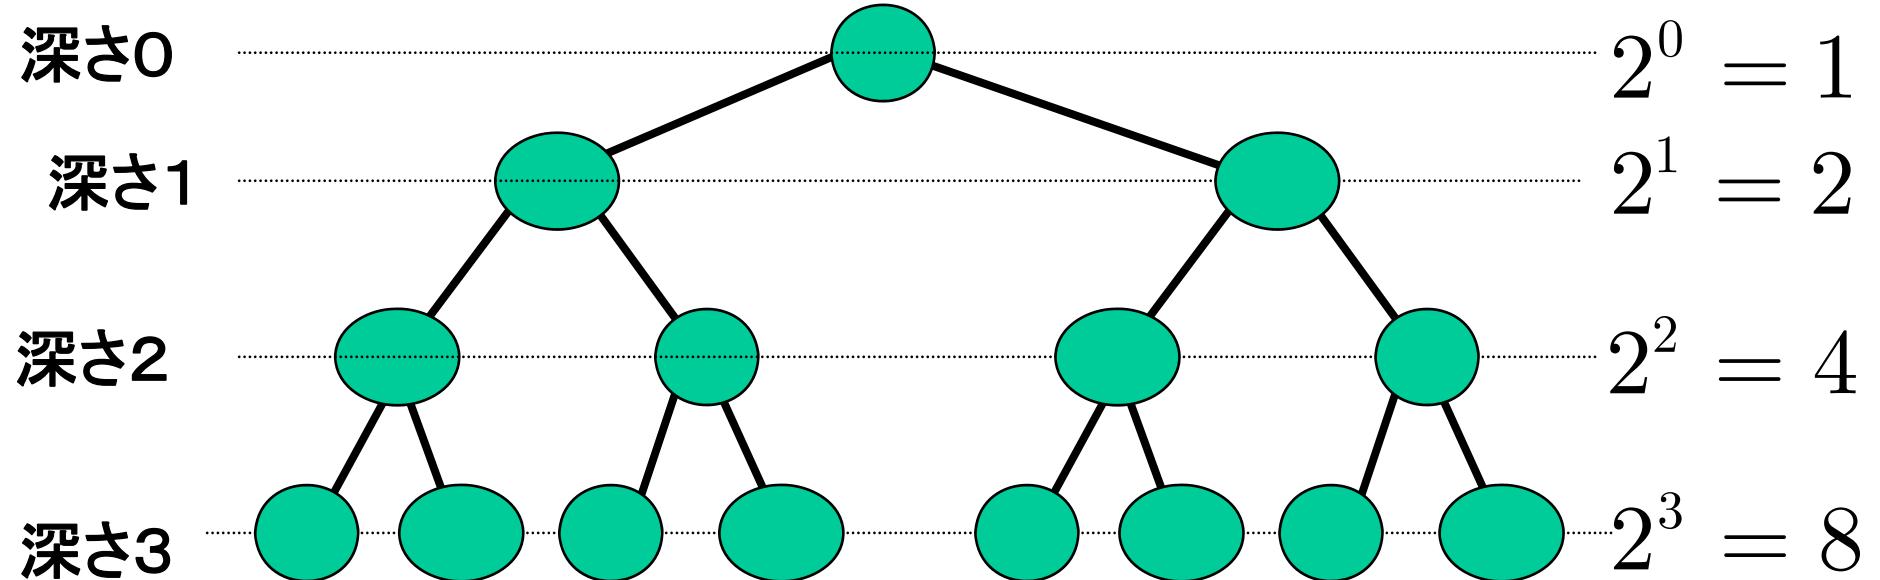
- ・ 深さ: 根までの道の長さ
- ・ 高さ: 木中の最大の深さ



完全2分木



全ての内部節点(葉以外の節点)が、すべて2つの子を持つ2分木。



命題HP1(完全2分木と節点数)

- (1) 完全2分木の、深さ d には 2^d 個の節点がある。
- (2) 高さ h の完全2分木には $2^{h+1} - 1$ 個の節点がある。

証明

(1)

深さ d に関する数学的帰納法で証明できる。

基礎:

このときは、深さ 0 の頂点は根ただ一つなので、命題は成り立つ。

帰納:

深さ d の節点が 2^d 個あると仮定する。

このとき、これらの節点すべてが、2つの子を持つので、

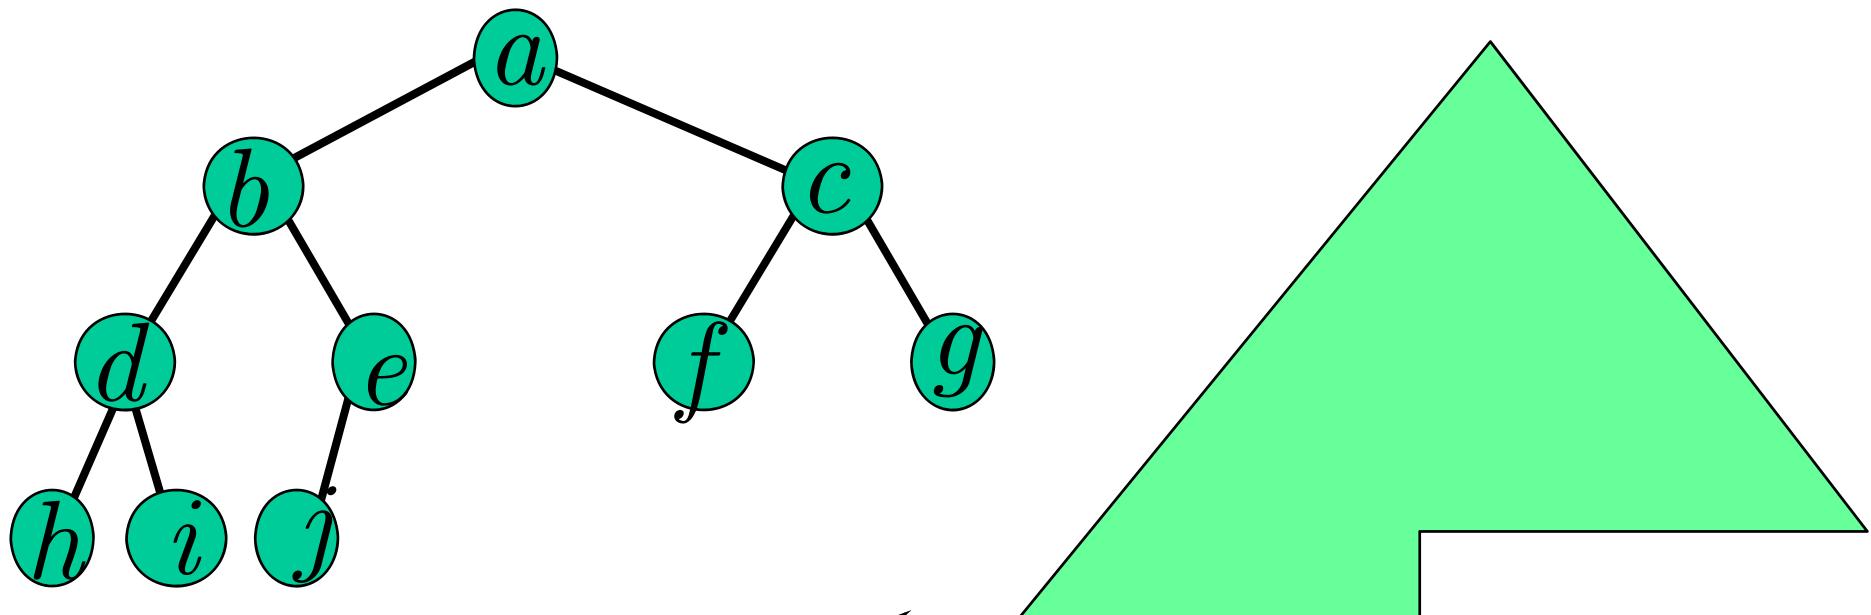
深さ $d + 1$ の節点数は、 $2 \times 2^d = 2^{d+1}$ あり、命題は成り立つ。

(2) (1)より、節点の総数は、次式で表される。

$$\sum_{d=0}^h 2^d = \frac{2^{h+1} - 1}{2 - 1} = 2^{h+1} - 1$$

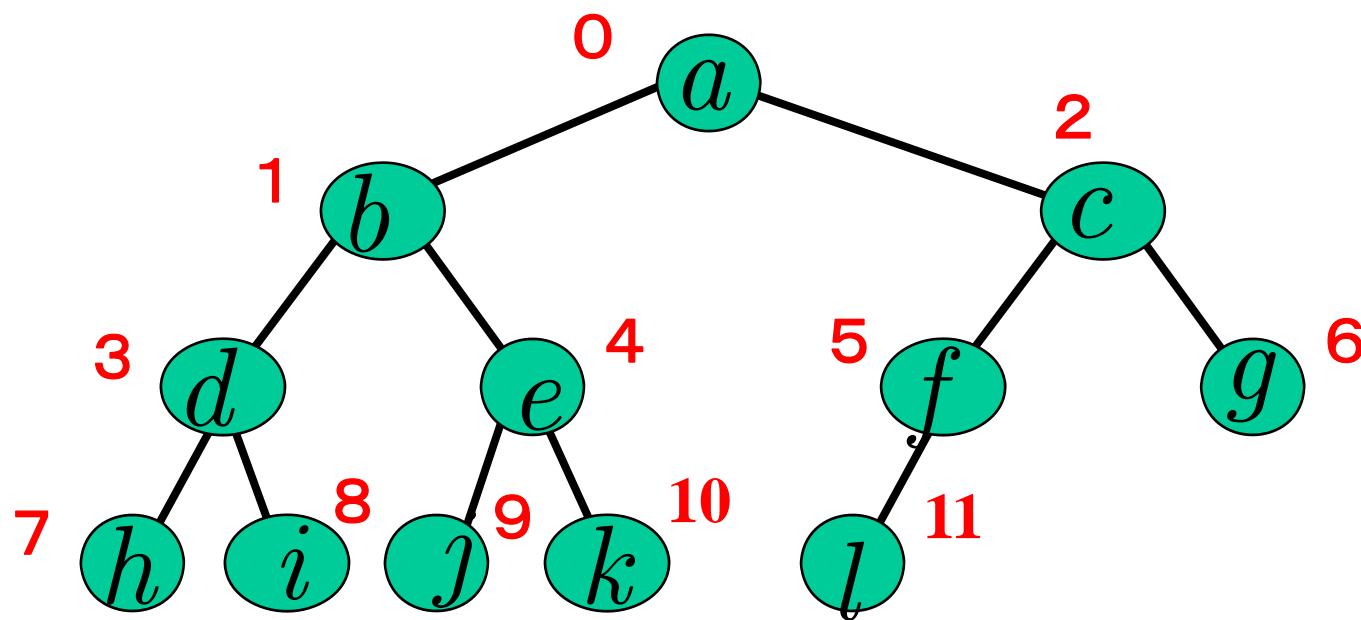
QED

ヒープの形



このような形で、
イメージするとよい。

ヒープ番号と配列での実現



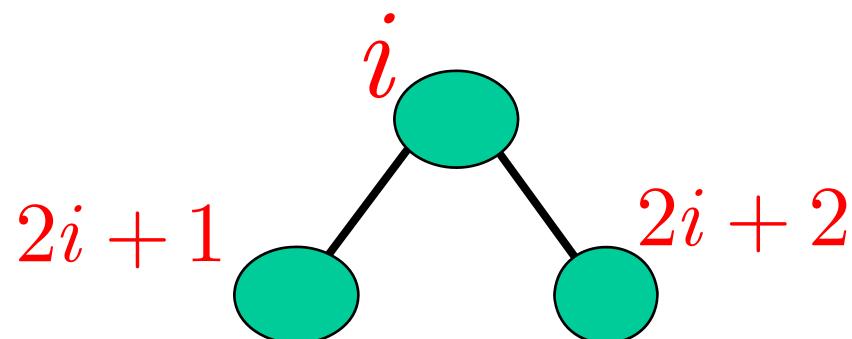
配列

0	1	2	3	4	5	6	7	8	9	10	11
a	b	c	d	e	f	g	h	i	j	k	l

ヒープにおける親子関係

命題HP2(ヒープにおける親子関係)

ヒープ番号 i の節点に対して、
左子のヒープ番号は $2i + 1$ であり、
右子のヒープ番号は $2i + 2$ である。



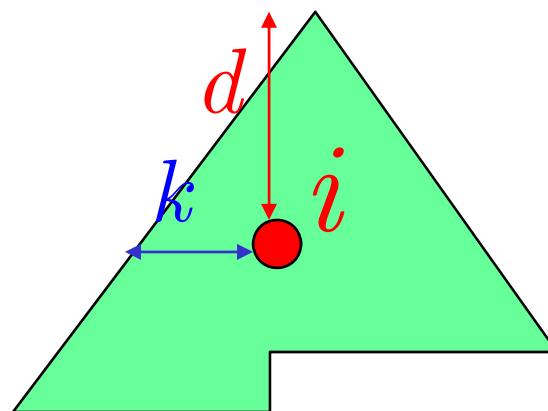
証明

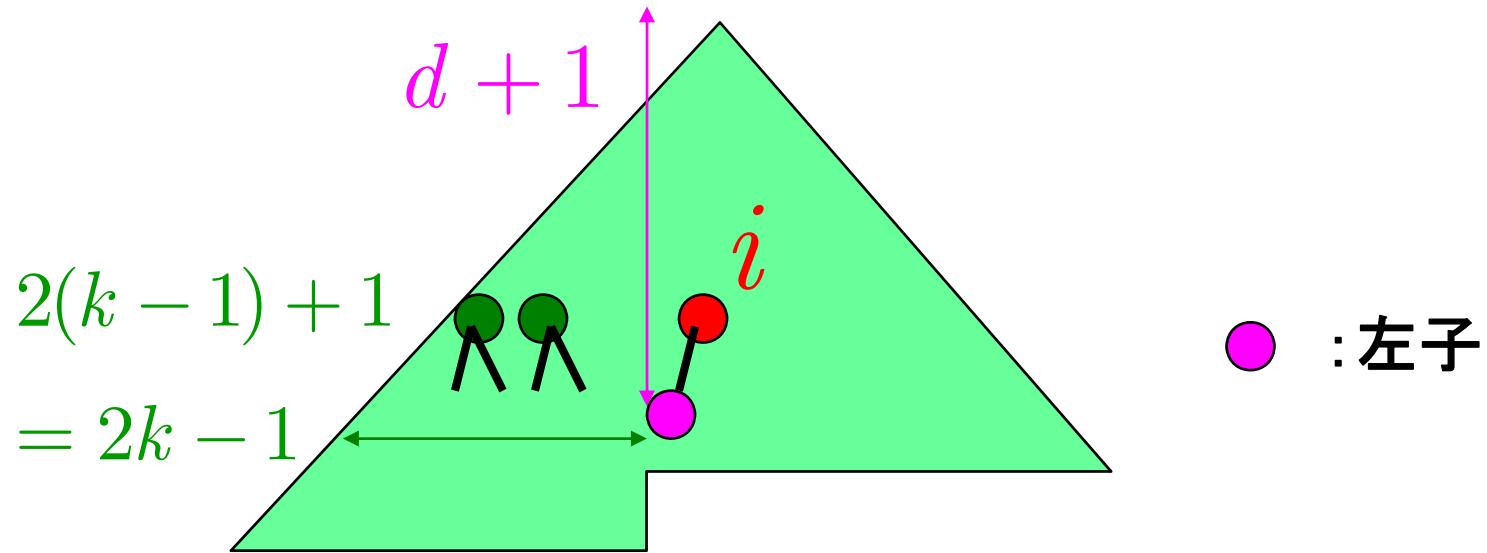
右子は、左子より1大きいヒープ番号を持つことはあきらかなので、左子が $2i + 1$ であることだけを示す。

今、節点 i の深さを d とし、左から k 番目であるとする。
すなわち、

$$i = (2^d - 1) + (k) - 1 = 2^d + k - 2$$

が成り立つ。





このとき、左子は、深さ $d + 1$ で左から $2k - 1$ 番目の節点である。

今、左子のヒープ番号を h_l とすると次の式がなりたつ。

$$h_l = 2^{d+1} + 2k - 1 - 2$$

$$= 2(d^d + k - 2) + 1$$

$$= 2i + 1$$

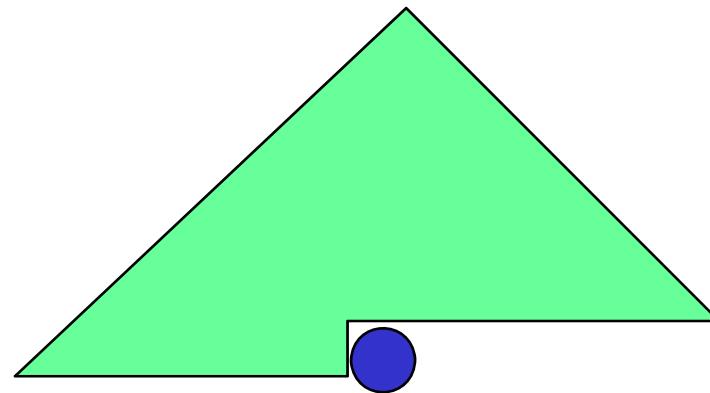
QED

ヒープにおける挿入

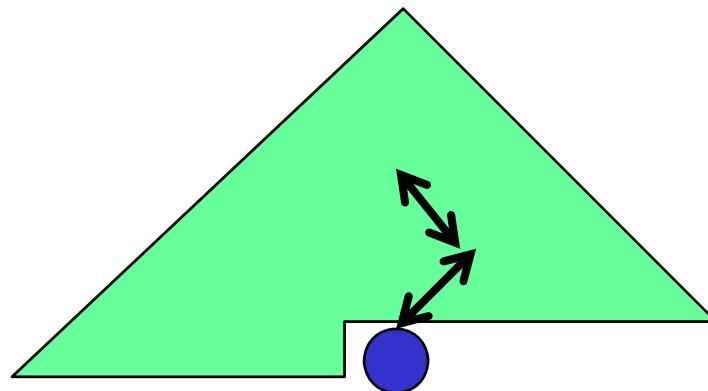
（ヒープ条件）

全ての節点において、親の値が子の値より小さい

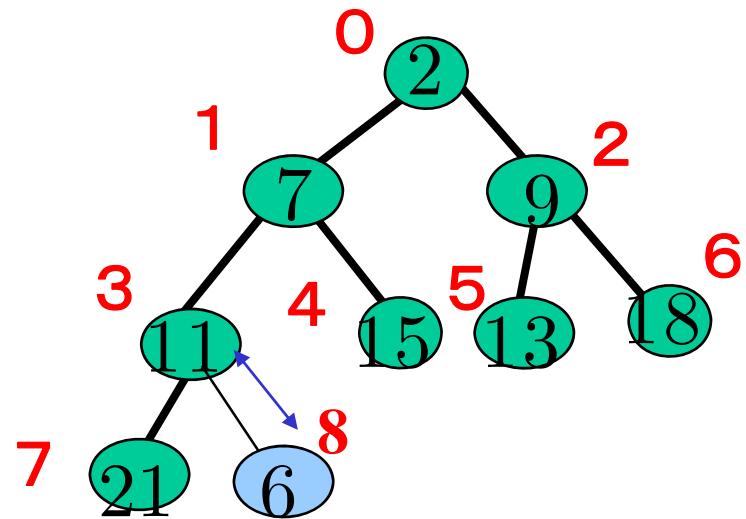
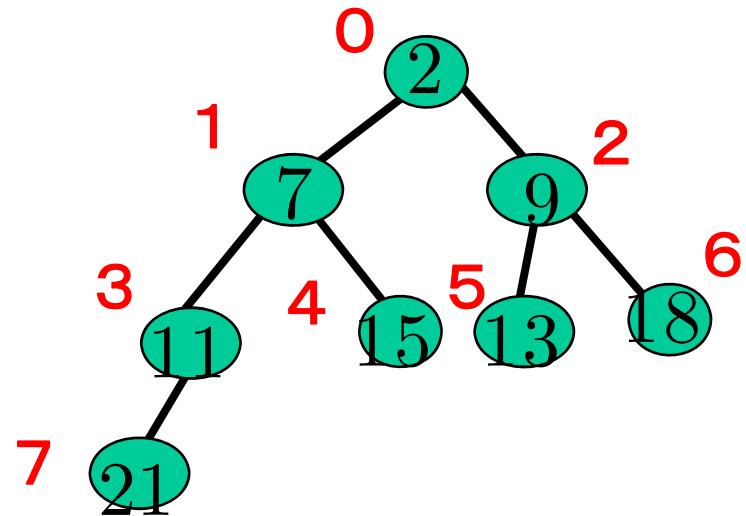
n 点保持しているヒープに新たに1点挿入することを考える。このとき、ヒープの形より、ヒープ番号 $n + 1$ の位置に最初におかれる。



しかし、これだけだと、ヒープ条件を満たさない可能性があるので、根のほうに向かって条件がみたされるまで交換を繰り返す。(アップヒープ)



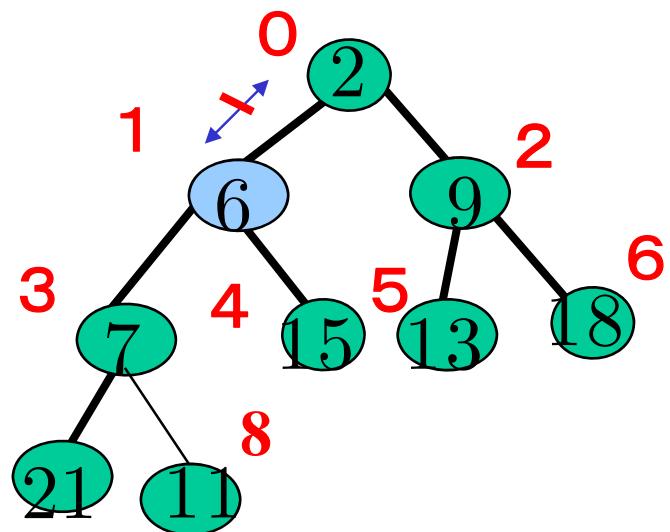
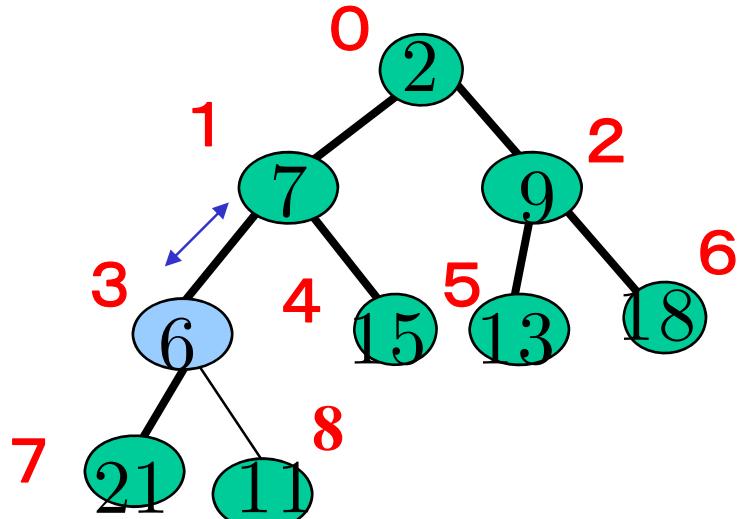
挿入の例



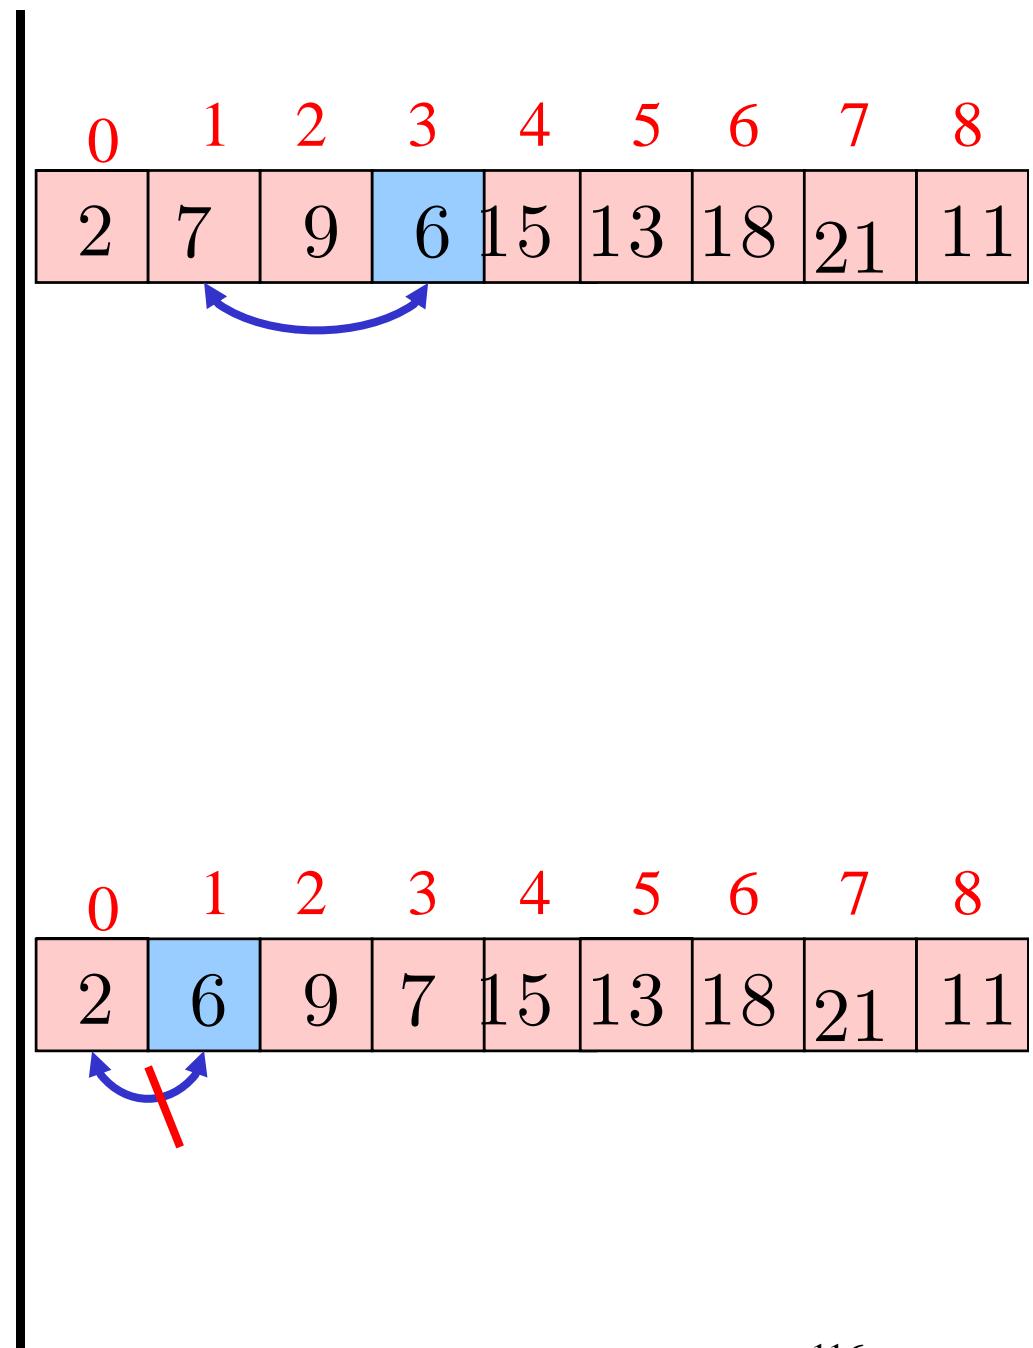
配列 HP

0	1	2	3	4	5	6	7
2	7	9	11	15	13	18	21

0	1	2	3	4	5	6	7	8
2	7	9	11	15	13	18	21	6



挿入終了



練習

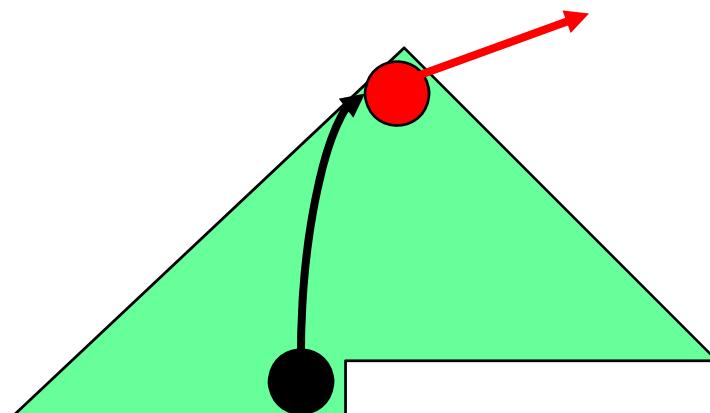
前のスライドのヒープに新たに、3を挿入し、
その動作を木と、配列の両方で示せ。

ヒープにおける削除

（ヒープ条件）

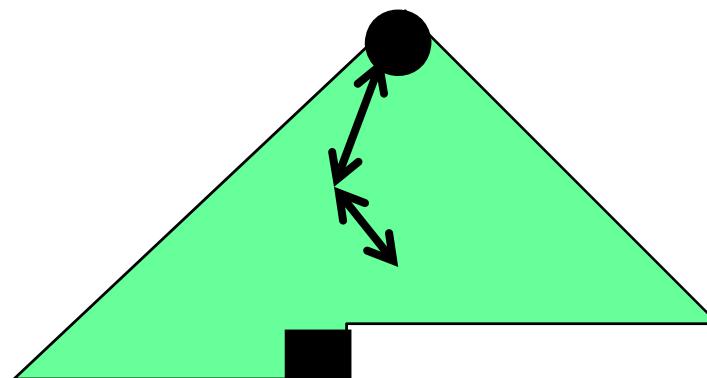
全ての節点において、親の値が子の値より小さい

ヒープにおいては、先頭の最小値のみ削除される。
削除の際には、ヒープの形を考慮して、
ヒープ番号 n の節点の値を根に移動する。

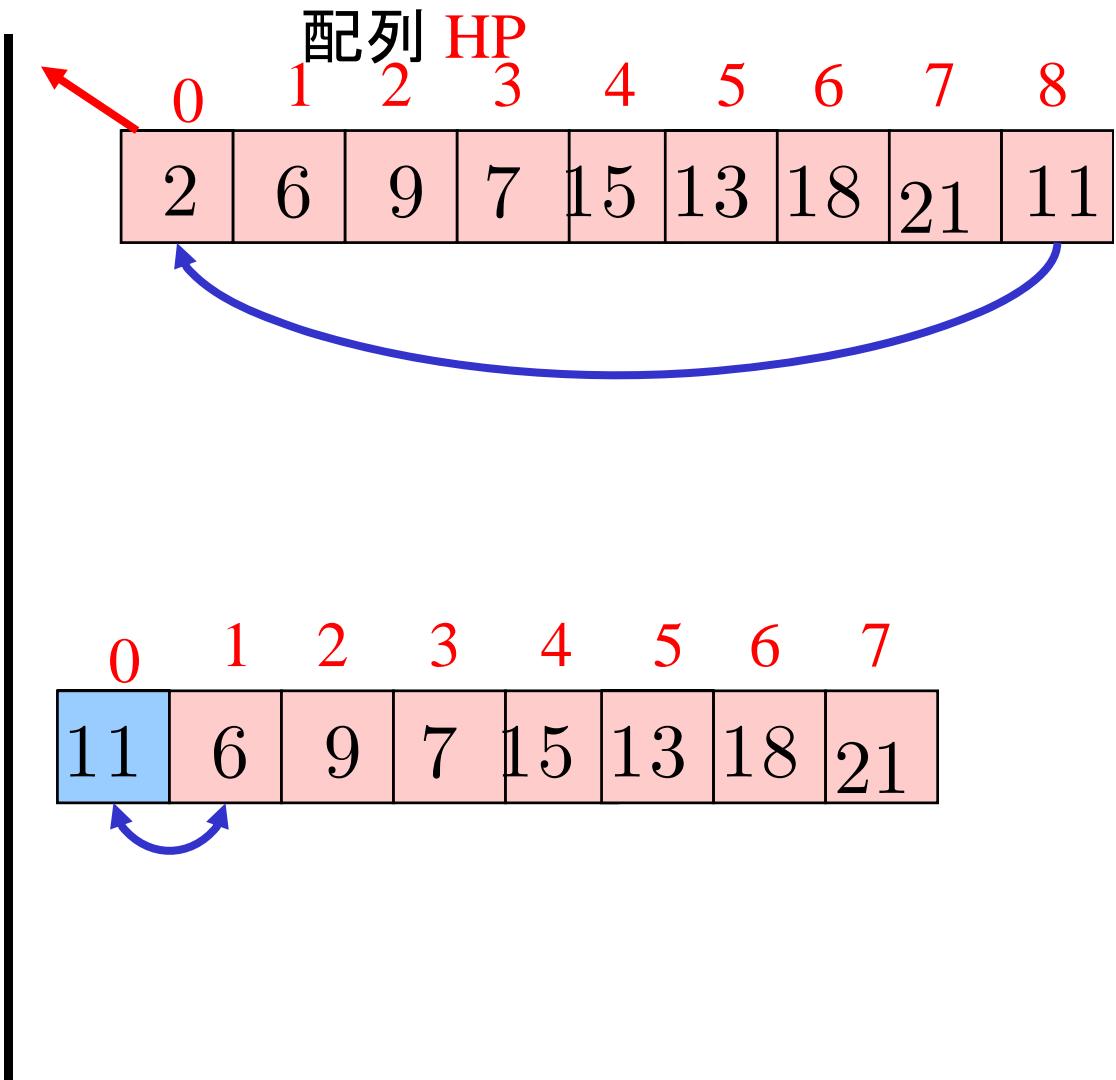
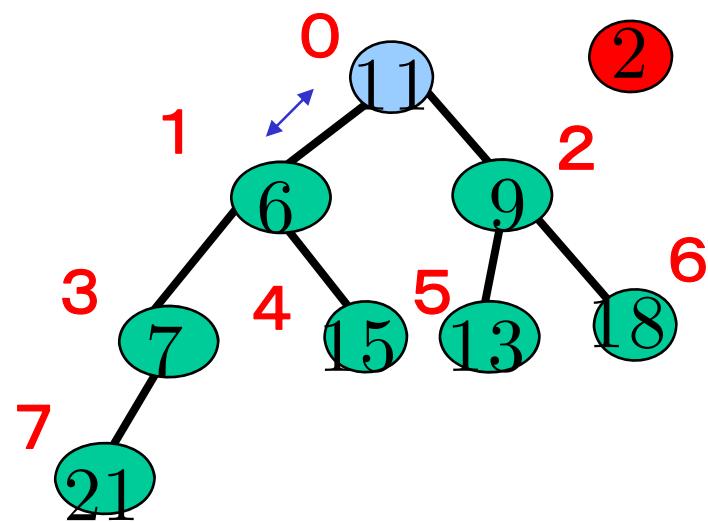
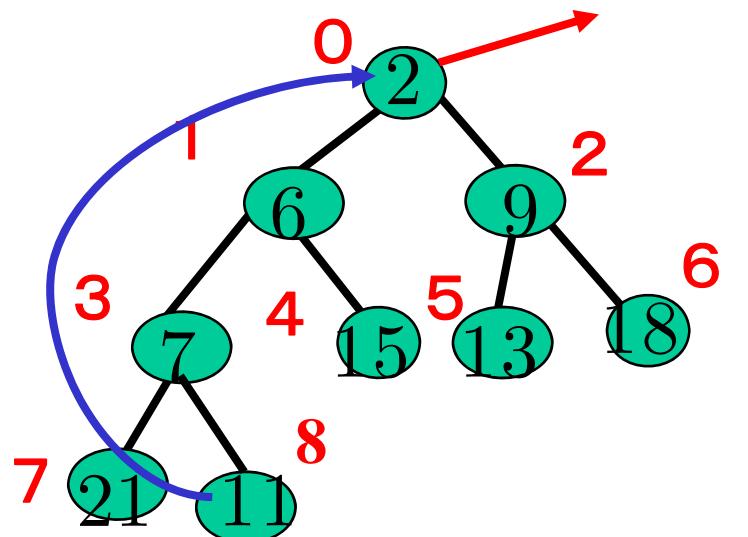


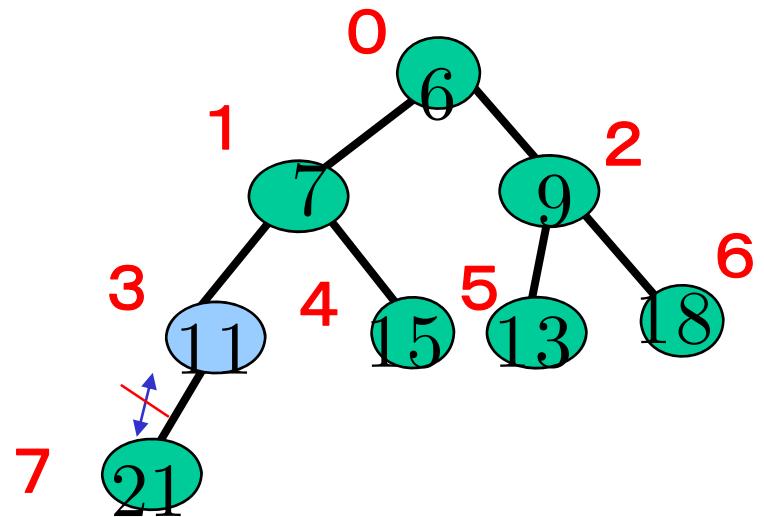
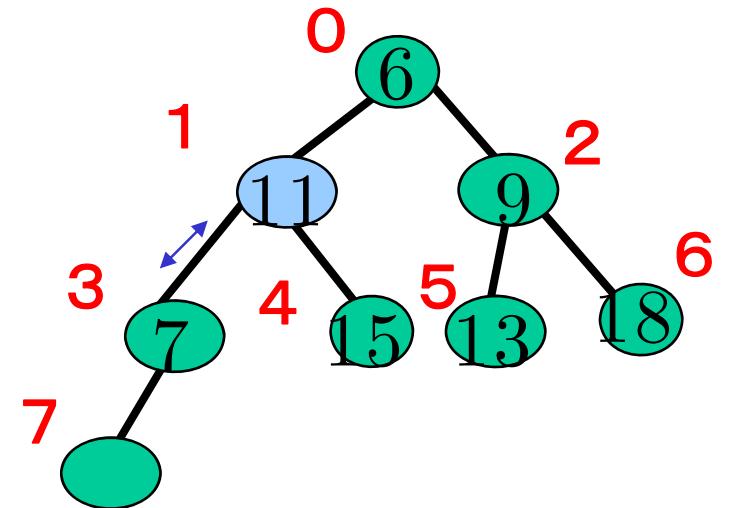
しかし、これだけだと、ヒープ条件を満たさない可能性があるので、葉のほうに向かって条件がみたされるまで交換を繰り返す。(ダウンヒープ)

交換は、値の小さい子供の方と交換する。
これをヒープ条件が満たされるまで繰り返す。

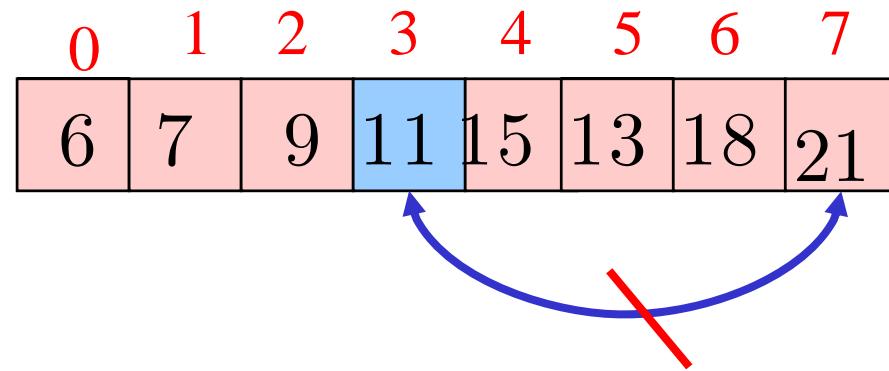
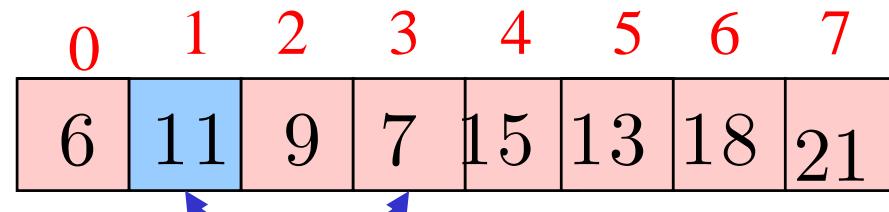


削除の例





削除終了



ヒープソートの動き前半 (ヒープへ値挿入)

配列

0	1	2	3	4	5	6	7	
A	5	3	8	1	4	13	9	2

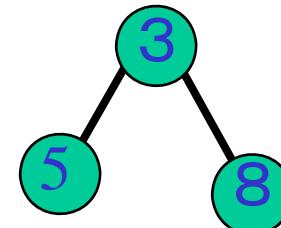
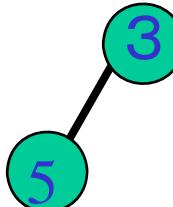
5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---

5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---

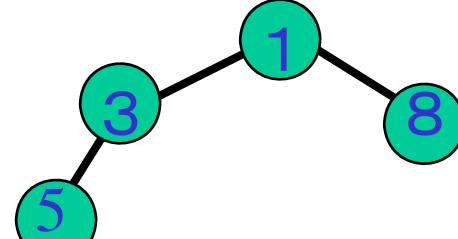
ヒープ

ϕ

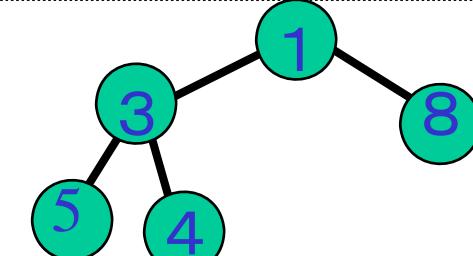
5



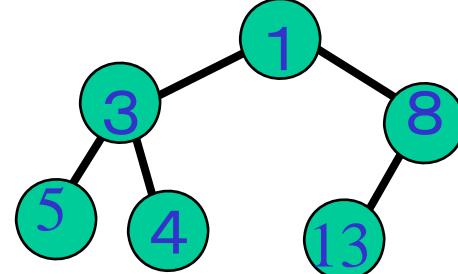
5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---



5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---



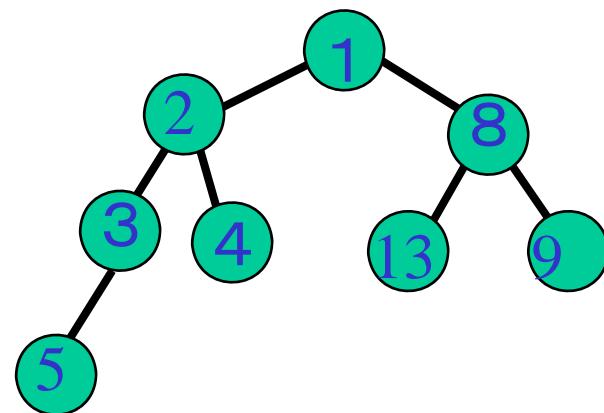
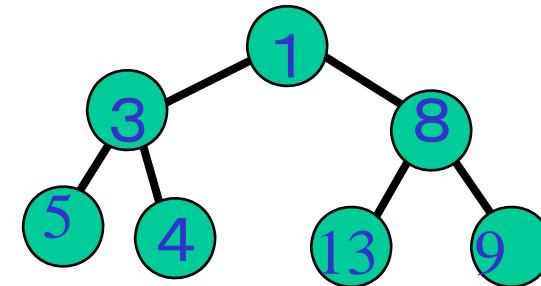
5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---



5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---

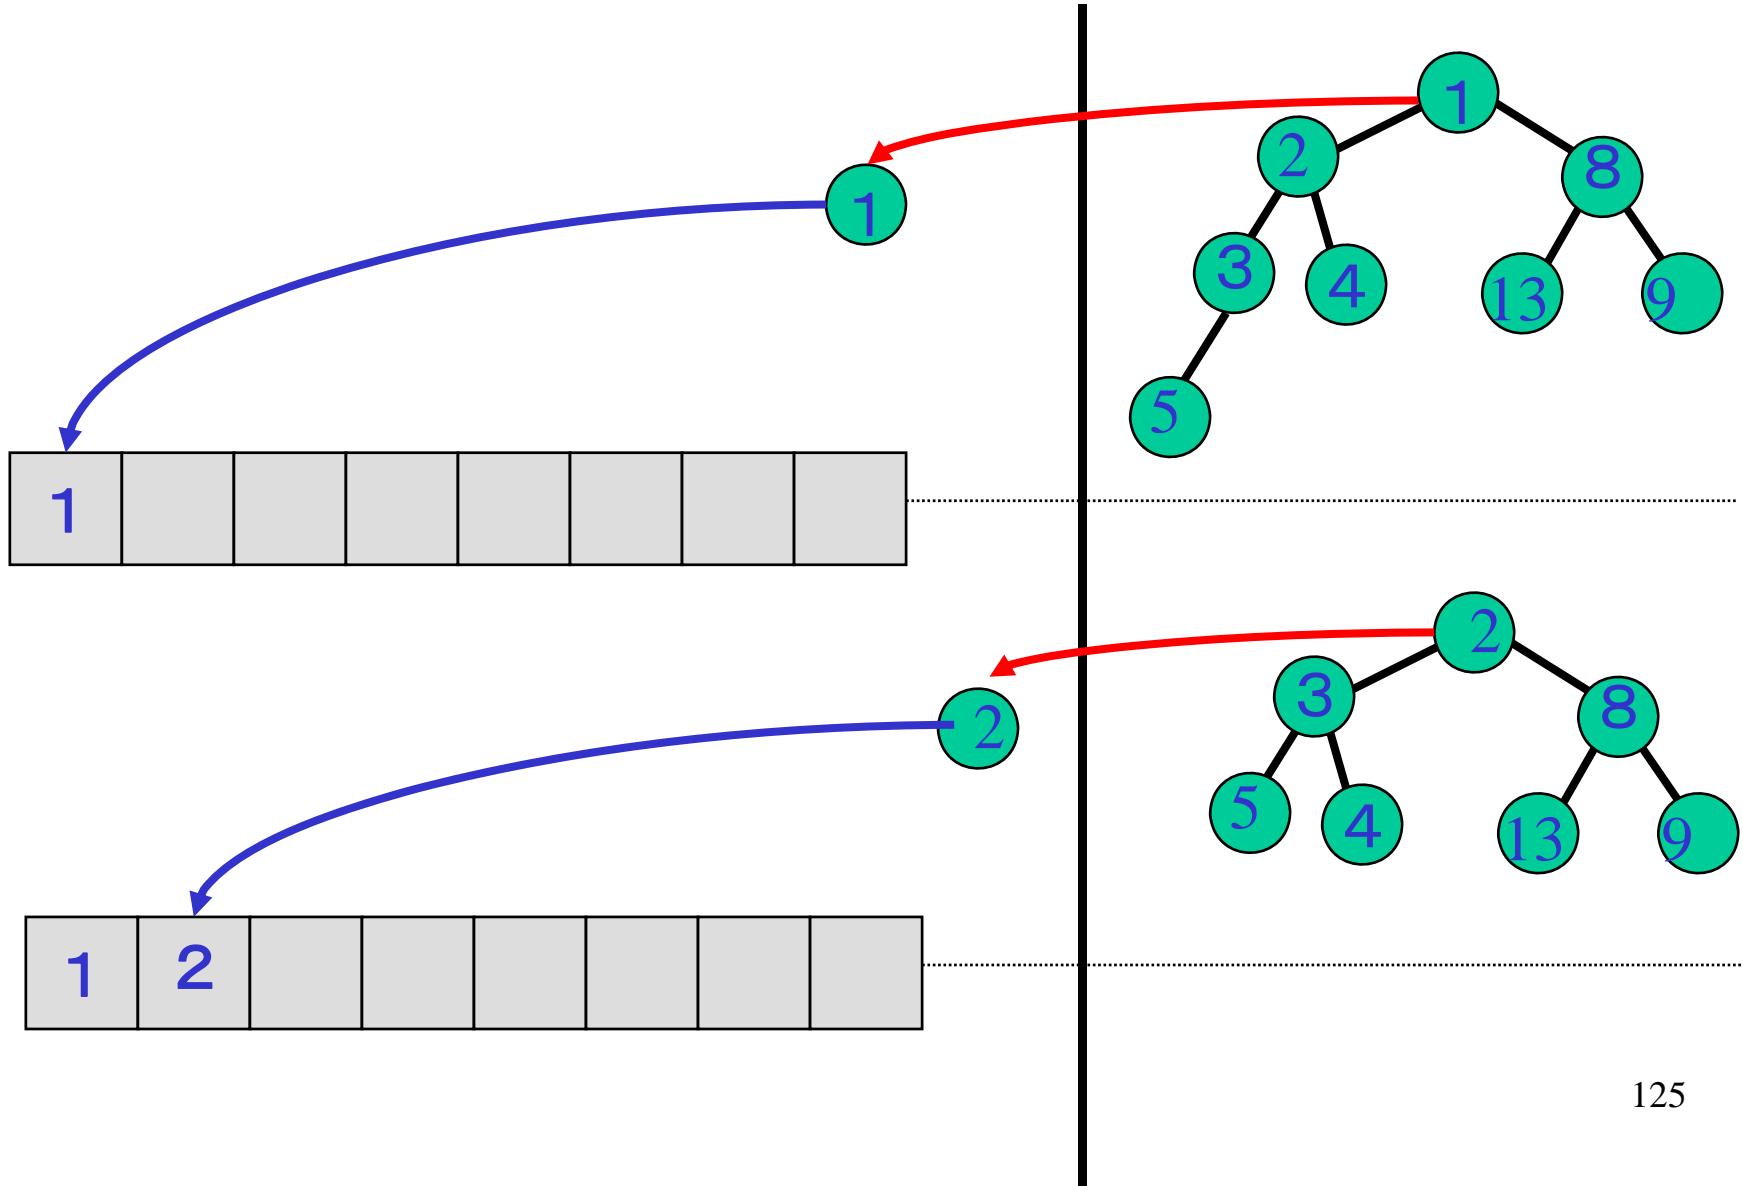
123

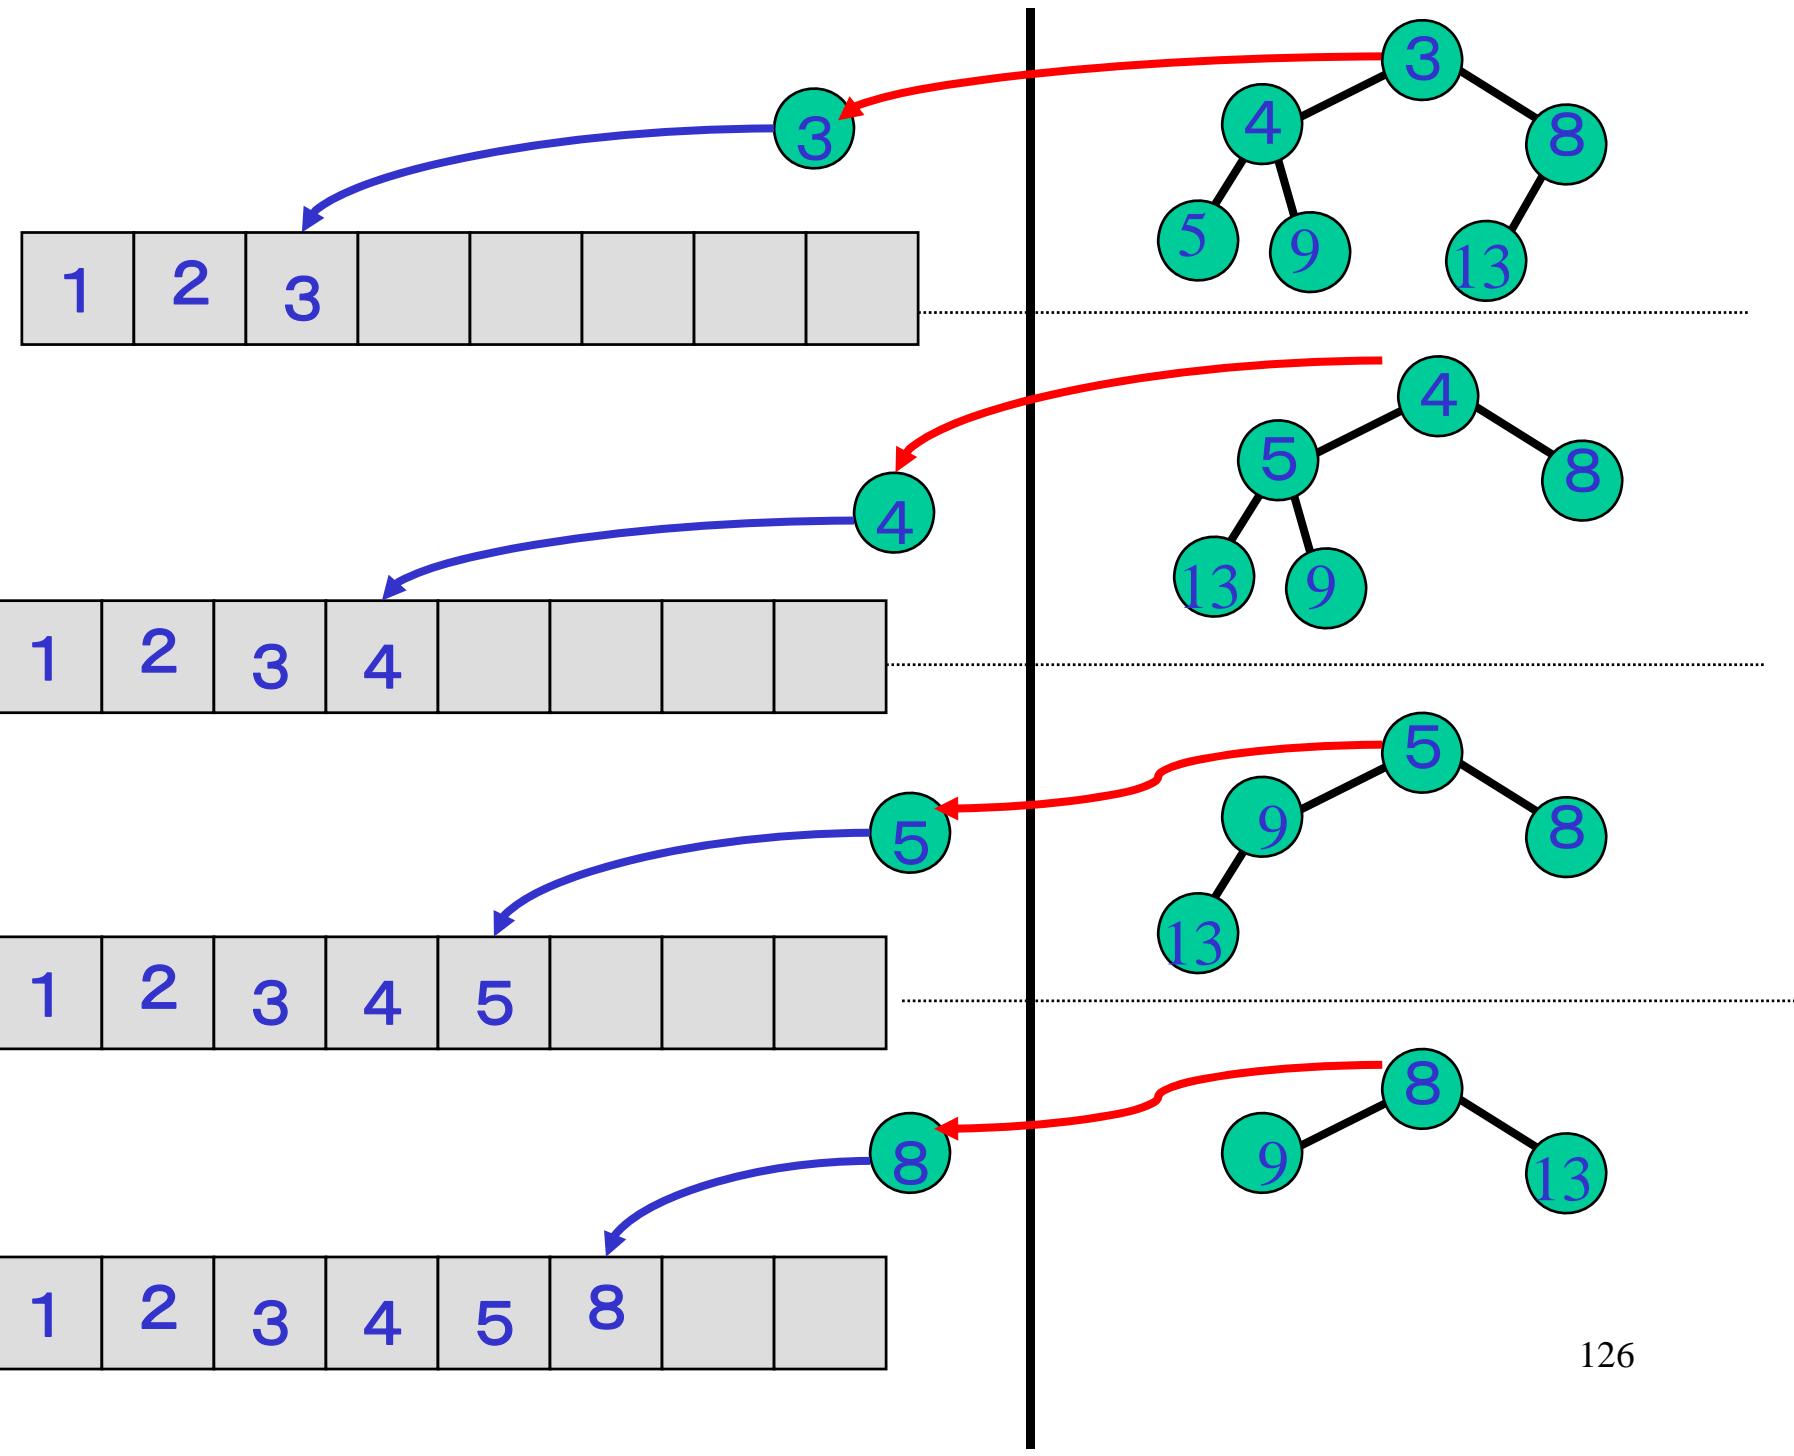
5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---

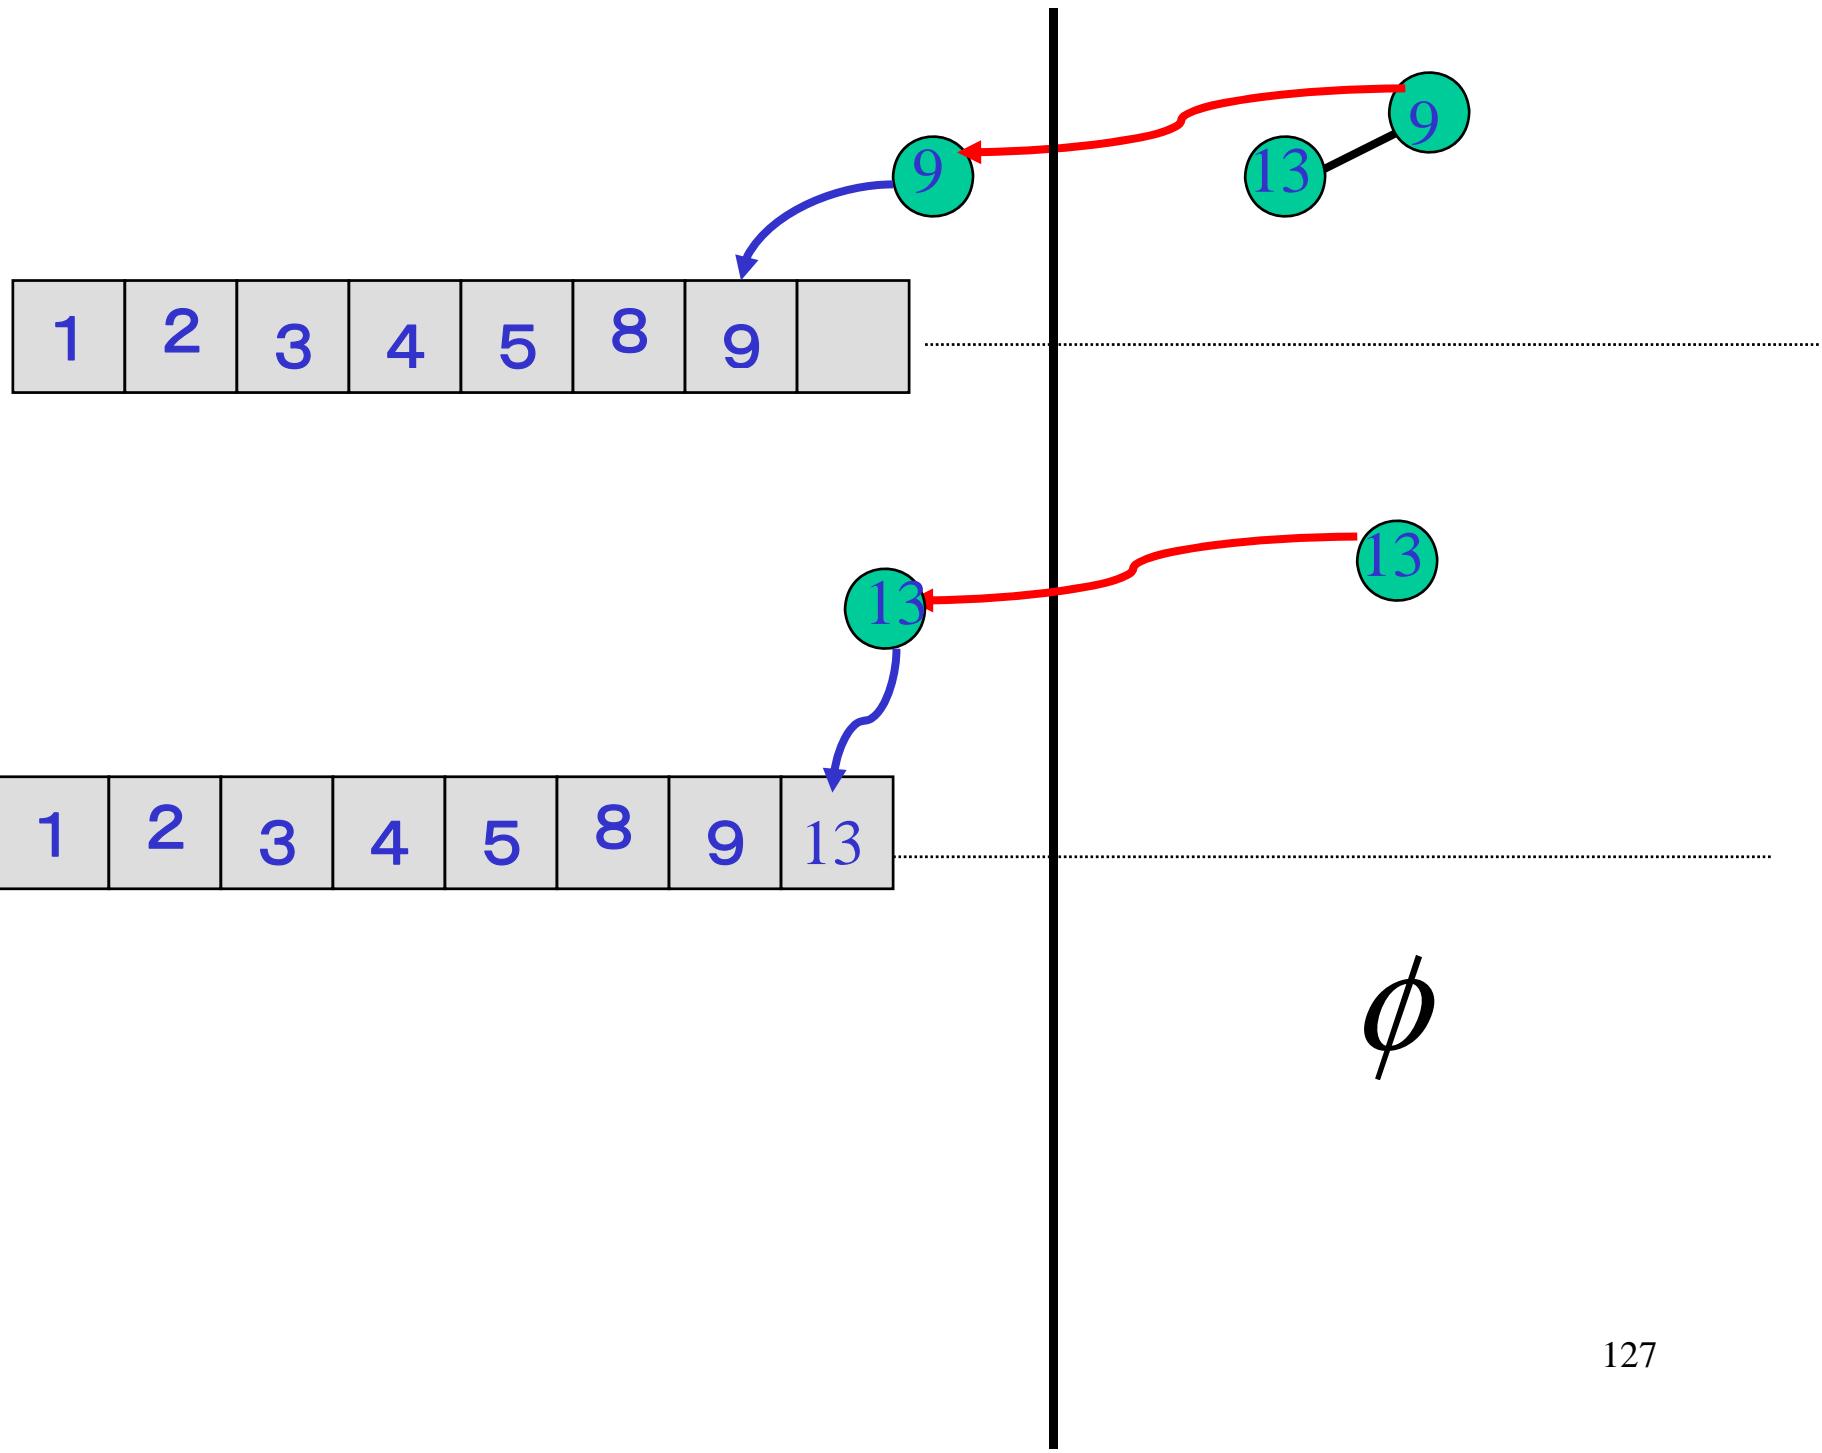


ヒープソートの動き後半 (ヒープからの最小値削除)

ヒープ







練習

次の配列を、ヒープソートでソートするとき、
ヒープの動作と配列の動きをシミュレートせよ。

11	25	21	1	8	3	16	5
----	----	----	---	---	---	----	---

ヒープソートの実現

```
1. void heap_sort()
2. {
3.     int i;      /* カウンタ */
4.     make_heap();/* 空のヒープの作成 */
5.     /* ヒープ挿入 */
6.     for(i=0;i<n;i++){
7.         insert_heap(A[i]);
8.     }
9.
10.    /*ヒープからのデータの取り出し*/
11.    for(i=0;i<n;i++){
12.        A[i]=get_min();
13.    }
14.    return ;
15.}
```

細かい部分
は省略します。

命題HP3(ヒープソートの正当性)

ヒープソートにより、配列はソートされる。

証明

ヒープの削除(get_min())により、
繰り返し最小値を求められることに注意すれば、
帰納法により証明できる。

QED
130

ヒープソートの計算量

ヒープへのデータ挿入

操作insert_heap(A) 1回あたり、時間量 $O(\log n)$

n回行うので、時間量 $O(n \log n)$

整列(最小値の削除の反復)

操作get_min() 1回あたり、時間量 $O(\log n)$

n回行うので、時間量 $O(n \log n)$

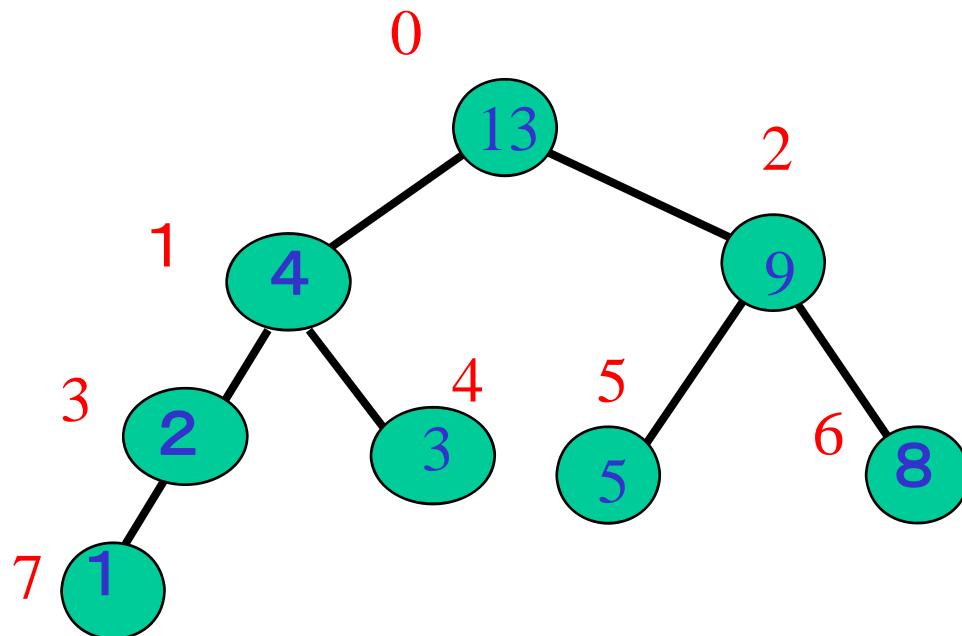
最悪時間量 $O(n \log n)$ のアルゴリズム

単一配列でのヒープソート

単一配列に変更する方針

方針

- 根が最大値になるように変更する。
- 先頭から順にヒープに挿入し、データ全体をヒープ化する。
- 最大値を取り出して、最後のデータにする。



ヒープ条件の変更

(ヒープ条件) —

全ての節点において、親の値が子の値より大きい

ヒープ化(ヒープソート前半)

配列

0	1	2	3	4	5	6	7	
A	5	3	8	1	4	13	9	2

ヒープ

5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---

ヒープ 未ヒープ

ヒープ

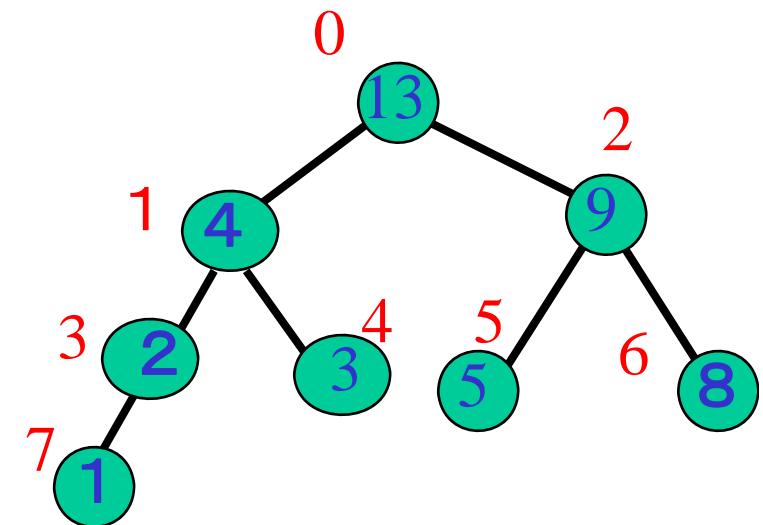
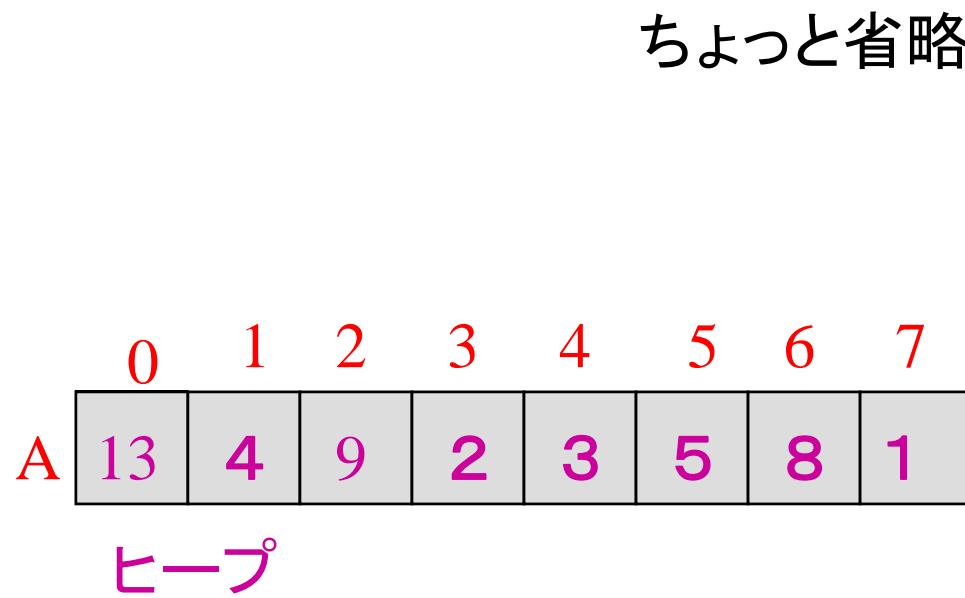
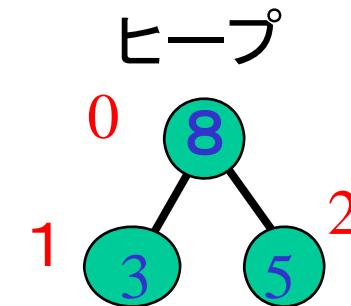
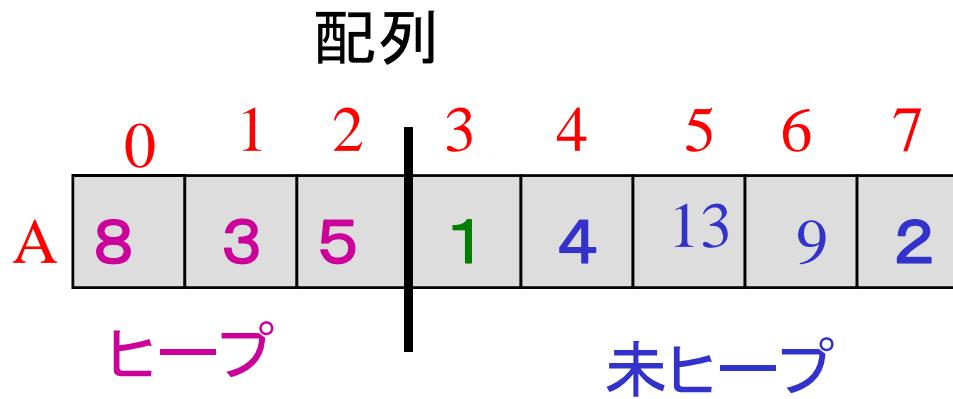
5	3	8	1	4	13	9	2
---	---	---	---	---	----	---	---

ヒープ 未ヒープ

ヒープ
 ϕ

0
5

0
1
5
3



最大値の削除とソート

0	1	2	3	4	5	6	7	
A	13	4	9	2	3	5	8	1

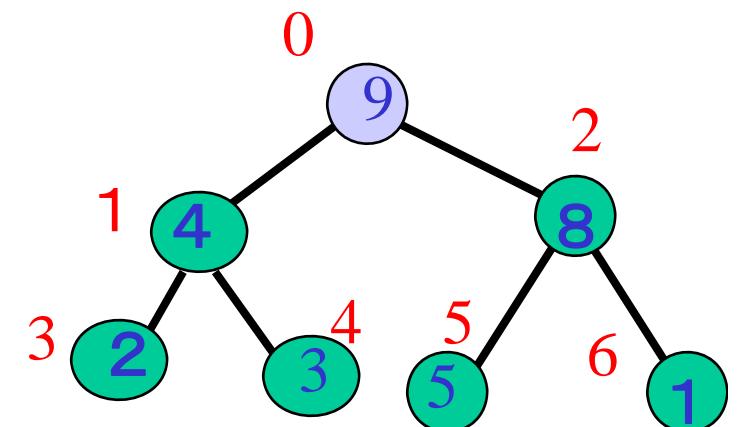
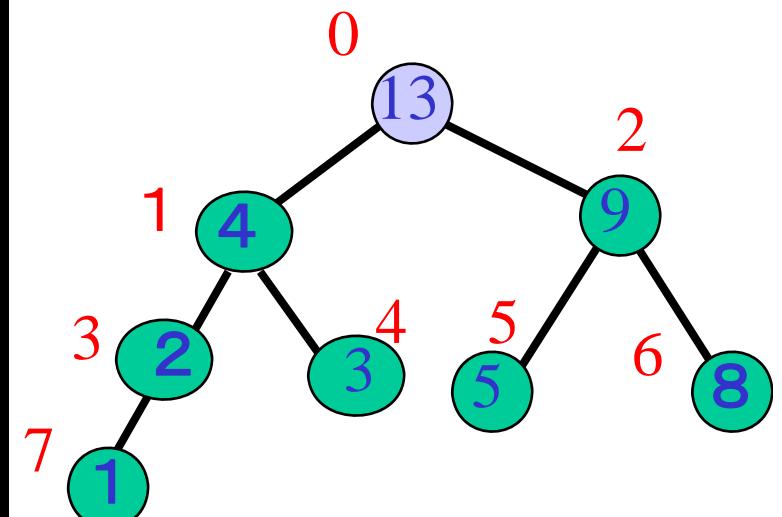
ヒープ

最大要素を、ヒープから削除し
後に挿入

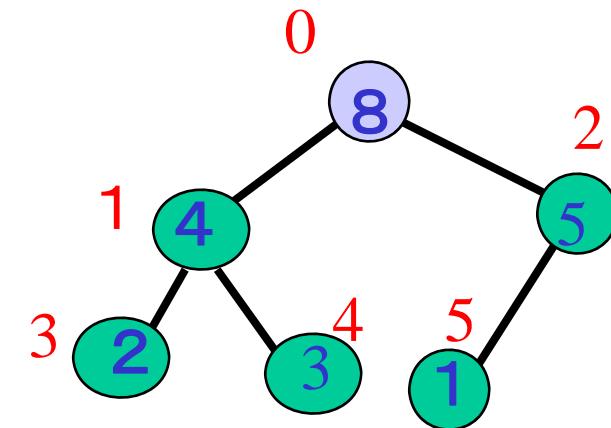
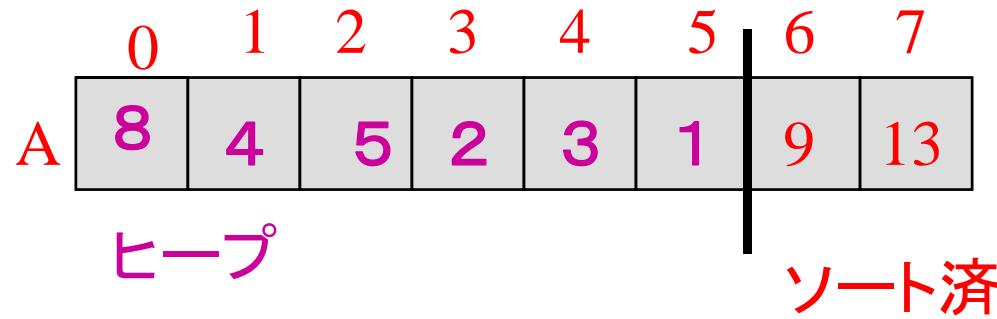
0	1	2	3	4	5	6	7	
A	9	4	8	2	3	5	1	13

ヒープ

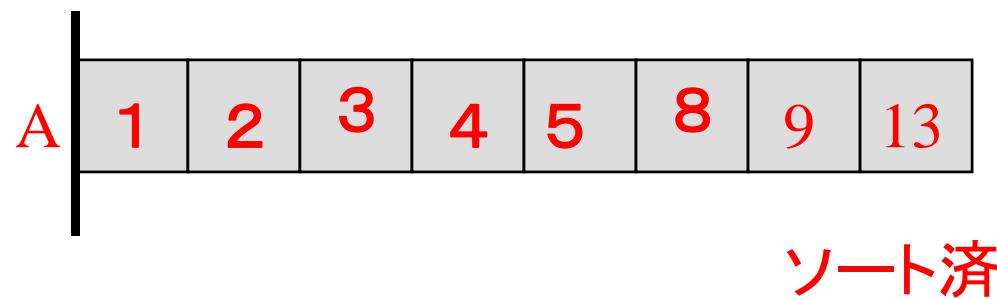
ソート済



ヒープソート2の動き後半2



ちょっと省略



ϕ

練習

次の配列を、単一配列ヒープソートを用いてソートするとき、配列の動きをシミュレートせよ。

11	25	21	1	8	3	16	5
----	----	----	---	---	---	----	---

単一配列ヒープの実現

```
1. void heap_sort()
2. {
3.     int i;      /* カウンタ */
4.     make_heap();/*空のヒープの作成*/
5.     /* ヒープ化 */
6.     for(i=0;i<n;i++){
7.         insert_heap(A[i]);
8.     }
9.
10.    /*ヒープからのデータの取り出し*/
11.    for(i=n-1;i>=0;i--){
12.        A[i]=get_max();
13.    }
14.    return ;
15.}
```

仔細省略、
ヒープの動作
も変更する
必要がある。

単一配列ヒープソートの計算量

ヒープ化

操作`insert_heap(A)` 1回あたり、時間量 $O(\log n)$

n回行うので、時間量 $O(n \log n)$

整列(最小値の削除の反復)

操作`get_max()` 1回あたり、時間量 $O(\log n)$

n回行うので、時間量 $O(n \log n)$

ヒープ化、整列は、1回づつ行われるので、

最悪時間量 $O(n \log n)$ のアルゴリズム

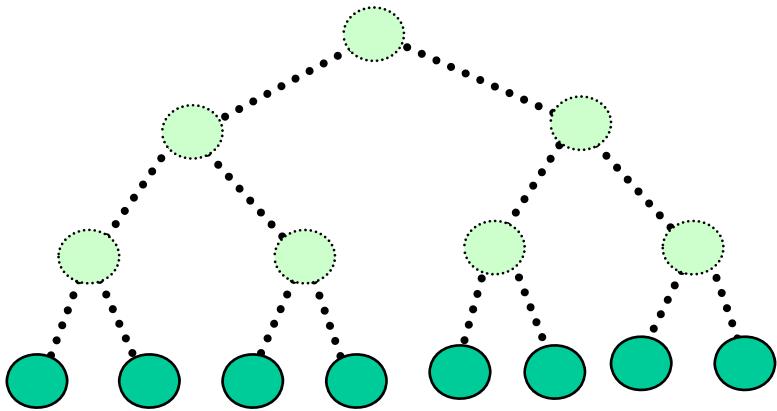
ヒープ化の高速化

ヒープ化の高速化におけるアイディア

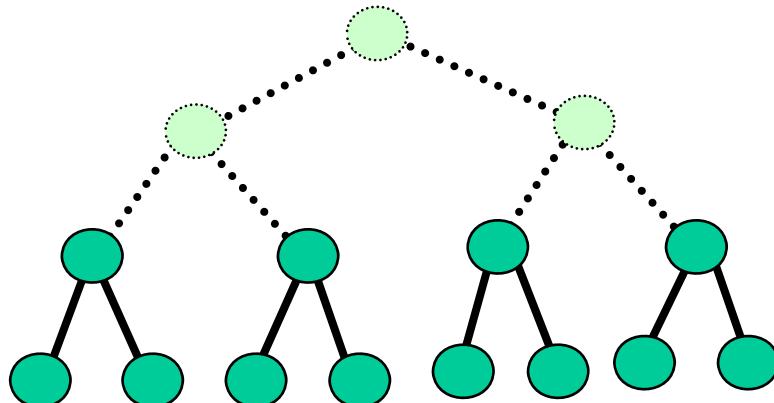
方針

- ヒープをボトムアップに生成する。
- 各接点では、2つの部分木を結合しながら、
ダウンヒープで修正を繰り返す。

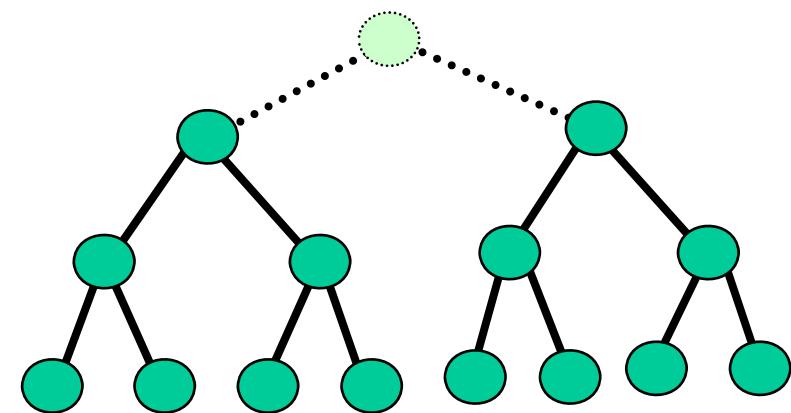
イメージ



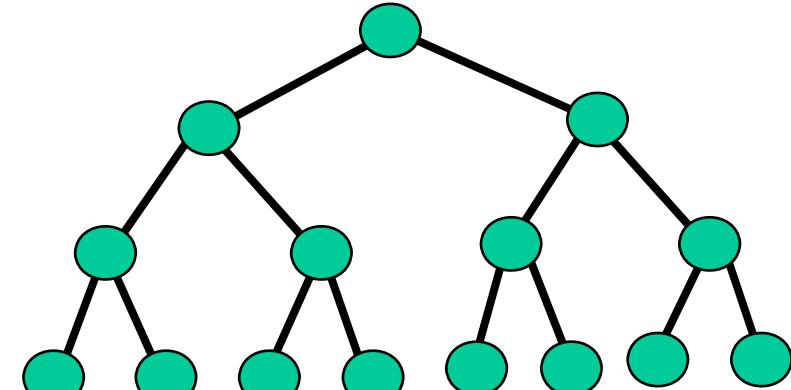
1点だけからなる 約 $n/2$ 個のヒープがあると考えてもよい。



3点のヒープが約 $n/4$ 個



7点のヒープが約 $n/8=2$ 個



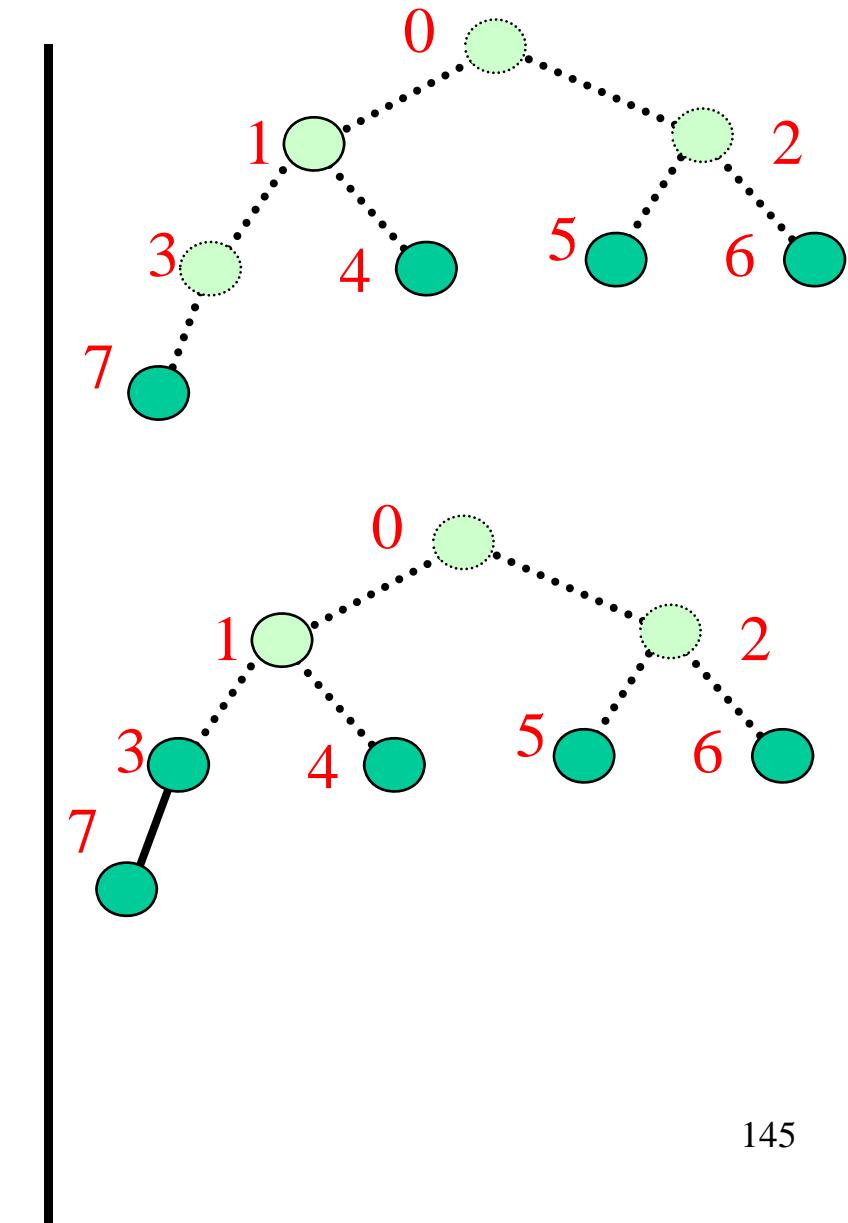
$2^h - 1 = 15$ 点のヒープが1個

高速ヒープ化の動き

配列

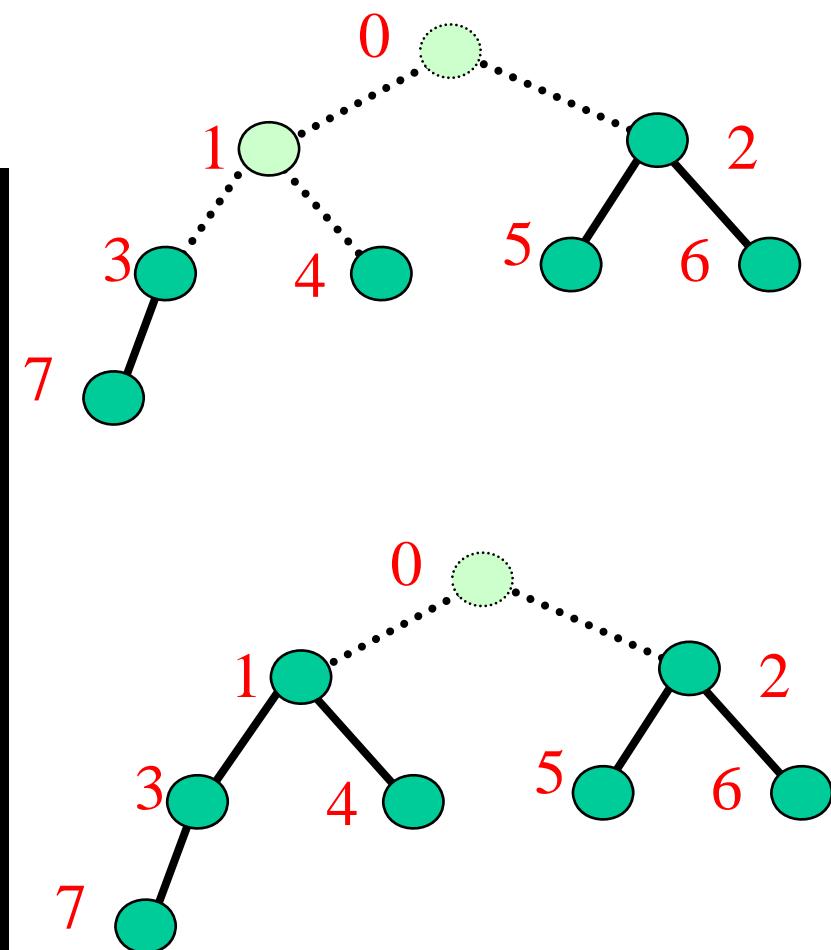
0	1	2	3	4	5	6	7
5	3	8	1	4	13	9	2

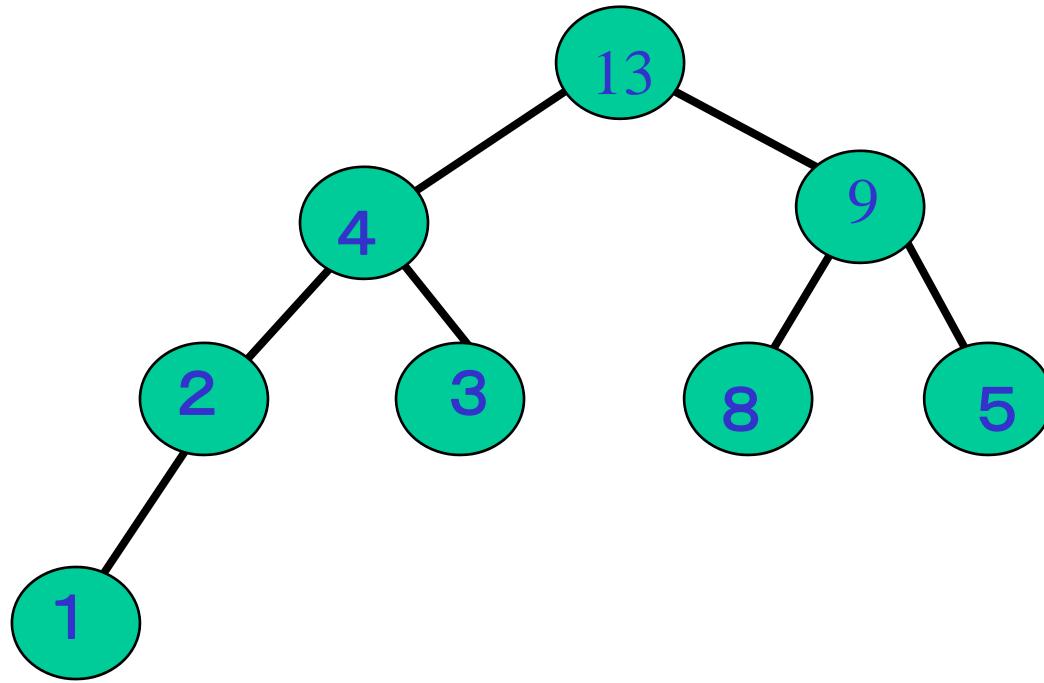
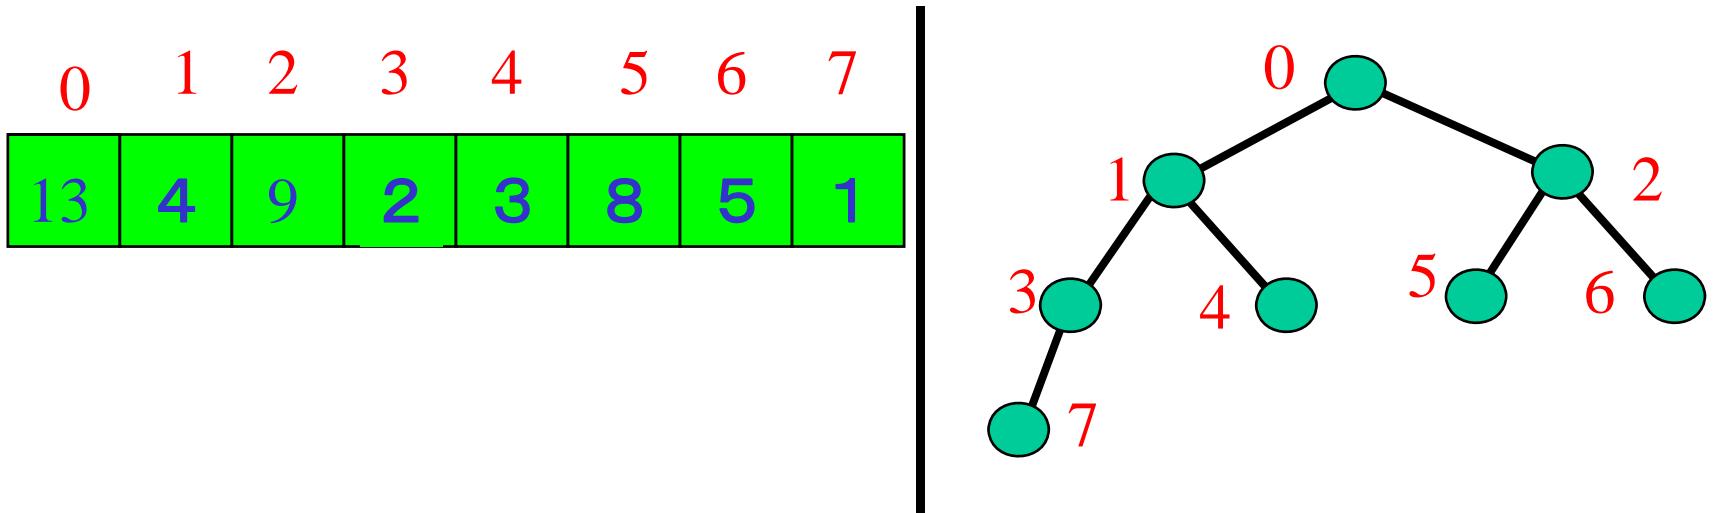
0	1	2	3	4	5	6	7
5	3	8	2	4	13	9	1



	0	1	2	3	4	5	6	7
	5	3	13	2	4	8	9	1

	0	1	2	3	4	5	6	7
	5	4	13	2	3	8	9	1





```
1. void heap_sort()
2. {
3.     int i;      /* カウンタ */
4.     make_heap();/* 空のヒープの作成 */
5.     /* ヒープ化 */
6.     for(i=n/2; i>=; i--){
7.         down_heap(A[i]);
8.     }
9.
10.    /* ヒープからのデータの取り出し */
11.    for(i=n-1; i<=0; i--){
12.        A[i]=get_max();
13.    }
14.    return ;
15.}
```

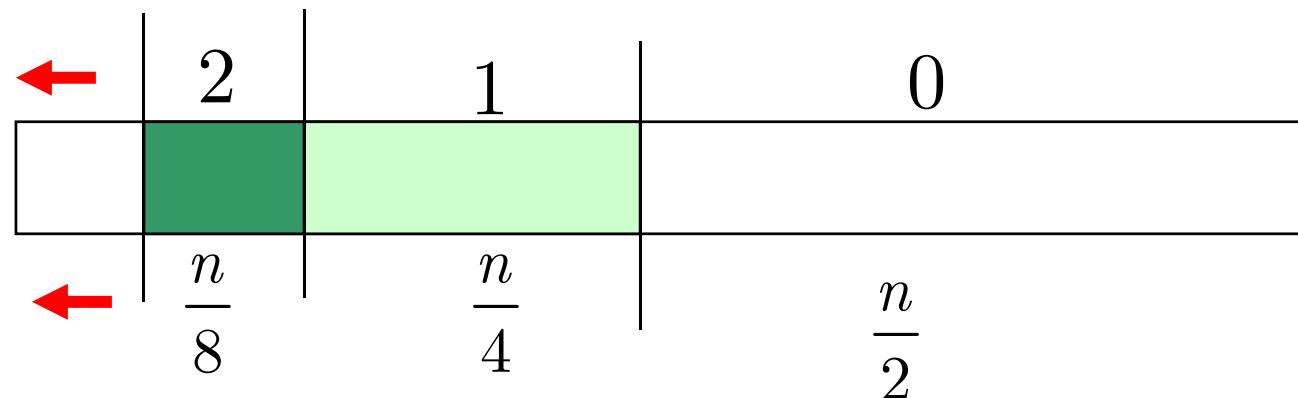
命題HP4(高速ヒープ化の最悪時間計算量)

高速ヒープ化の最悪計算時間計算量は、
 $O(n)$ である。

証明

交換回数

添え字範囲



このことより、ヒープ化に必要な最悪計算時間量を

$$T_h(n)$$

と書くと次式が成り立つ。

$$T_h(n) \leq \frac{n}{4} \times 1 + \frac{n}{8} \times 2 + \frac{n}{16} \times 3 \dots$$

$$= \frac{1}{2} \sum_{i=1}^{\log_2 n - 1} \frac{i}{2^i}$$

$$2T_h(n) \leq \frac{n}{2} \times 1 + \frac{n}{4} \times 2 + \frac{n}{8} \times 3 \dots$$

$$-\left) \quad T_h(n) \leq \frac{n}{4} \times 1 + \frac{n}{8} \times 2 + \frac{n}{16} \times 3 \dots$$

$$T_h(n) \leq \frac{n}{2} \times 1 + \frac{n}{4} \times 1 + \frac{n}{8} \times 1 \dots + 1$$

$$\leq n \frac{\frac{1}{2} \left(1 - \frac{1}{2^{\log_2 n}} \right)}{1 - \frac{1}{2}} \leq n$$

ヒープソートの計算量

ヒープ化の部分 $O(n)$

最大値発見と移動の部分

操作`delete_max(A)` 1回あたり、時間量 $O(\log n)$
n回行うので、時間量 $O(n \log n)$

結局

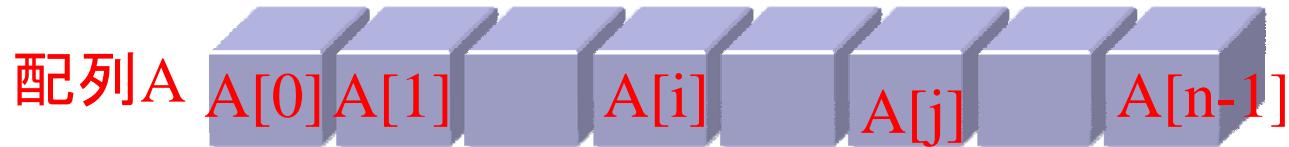
最悪時間計算量 $O(n \log n)$ のアルゴリズム

4-4: 比較によらないソート

準備：容量の大きいデータの処理

ちょっと寄り道

(一個一個が大きいデータを処理する工夫)



A[i]

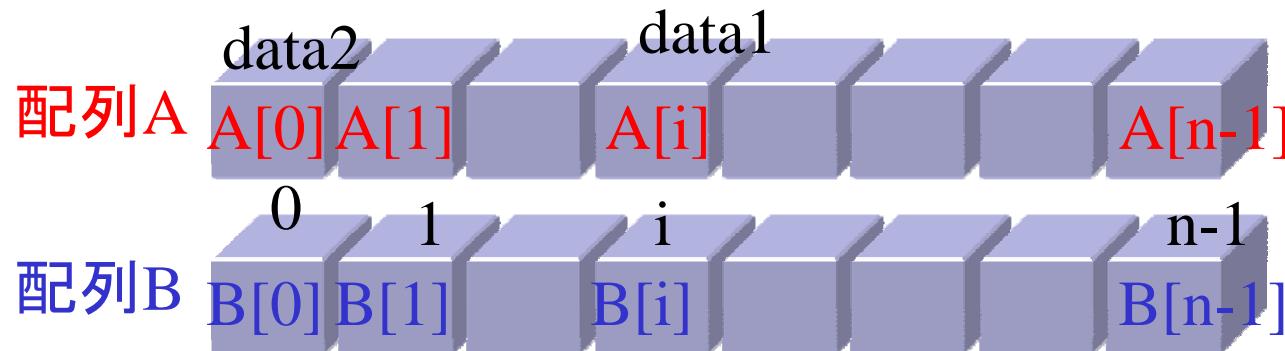
名前、
生年月日、
住所、
経歴、
趣味

A[j]

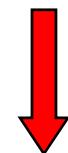
交換は大変

大きいデータを処理する工夫2

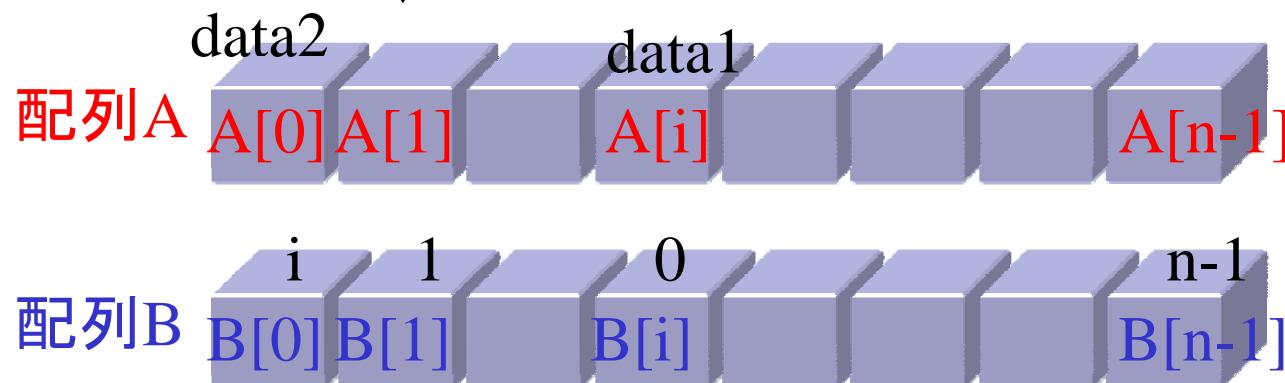
工夫: 大きいデータは動かさずに、
たどり方だけがわかれればいい。



添字の配列Bだけを操作して、配列Aは動かさない。

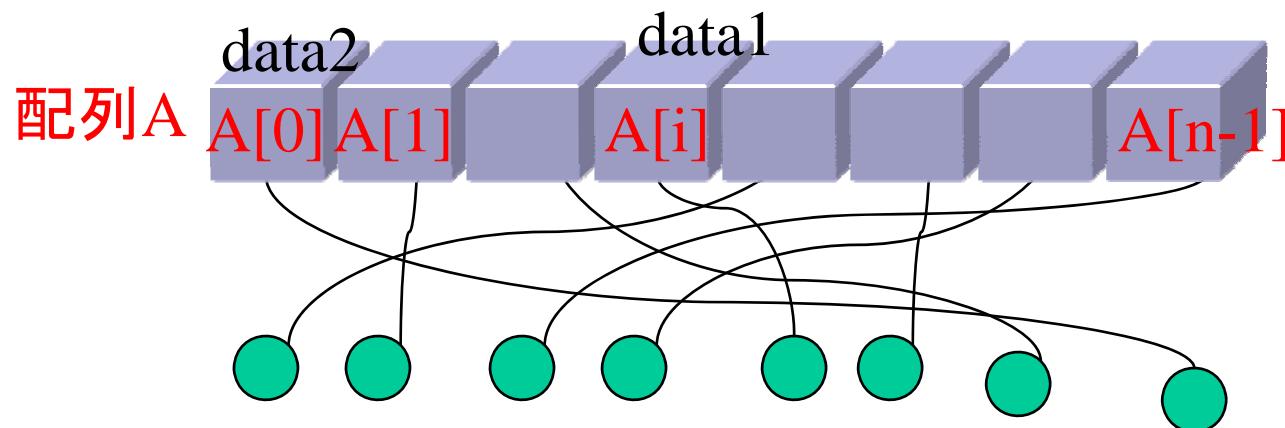
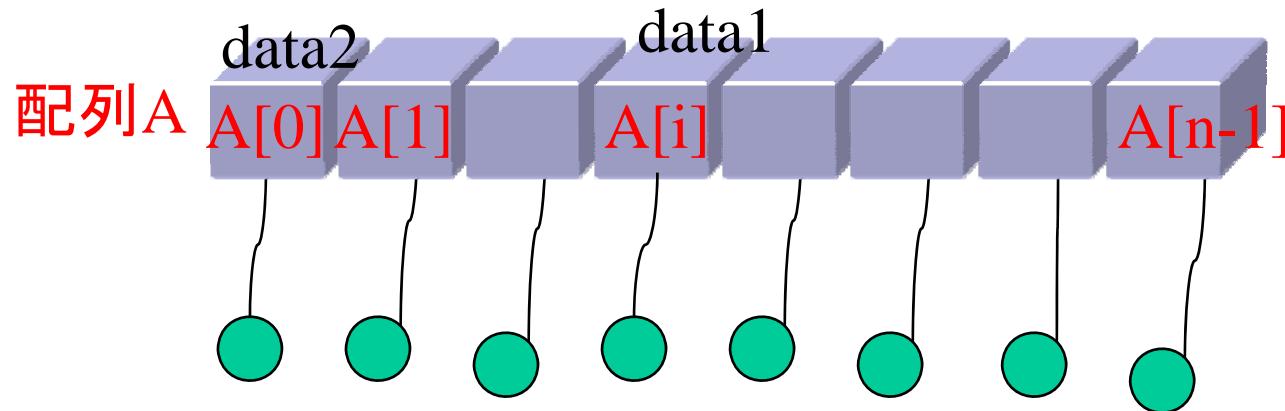


`swap(&B[0],&B[i]);` (data1が最小値のとき。)



大きいデータを処理する工夫3

イメージ



ソート順は、下の情報からえられる。

(配列の添字の利用だけでなく、ポインタでも同様のことができる。)¹⁵⁷

実現

細かい部分は省略します。

```
1. void selection_sort(struct data A[]){
2.     int B[N]; /*配列Aの要素を指す*/
3.     int i,j; /*カウンタ*/
4.     for(i=0;i<N;i++){
5.         B[i]=i;
6.     }
7.     for(i=0;i<N;i++){
8.         min=i;
9.         for(j=i+1;j<N;j++){
10.             if(A[B[min]].item>A[B[j]].item){
11.                 min=j;
12.             }
13.             swap(&B[i],&B[min]);
14.         }
15.         return;
16.     }
```

比較によらないソート

● バケットソート

データが上限のある整数のような場合に用いる。
データの種類が定数種類しかない場合には、
関数で整数に写像してから用いてもよい。
(ハッシュ関数)

● 基数ソート

大きい桁の数に対して、
桁毎にバケットソートをしてソートする。

バケットソート

バケットソートの方針

とりあえず、簡単のために、
データは、

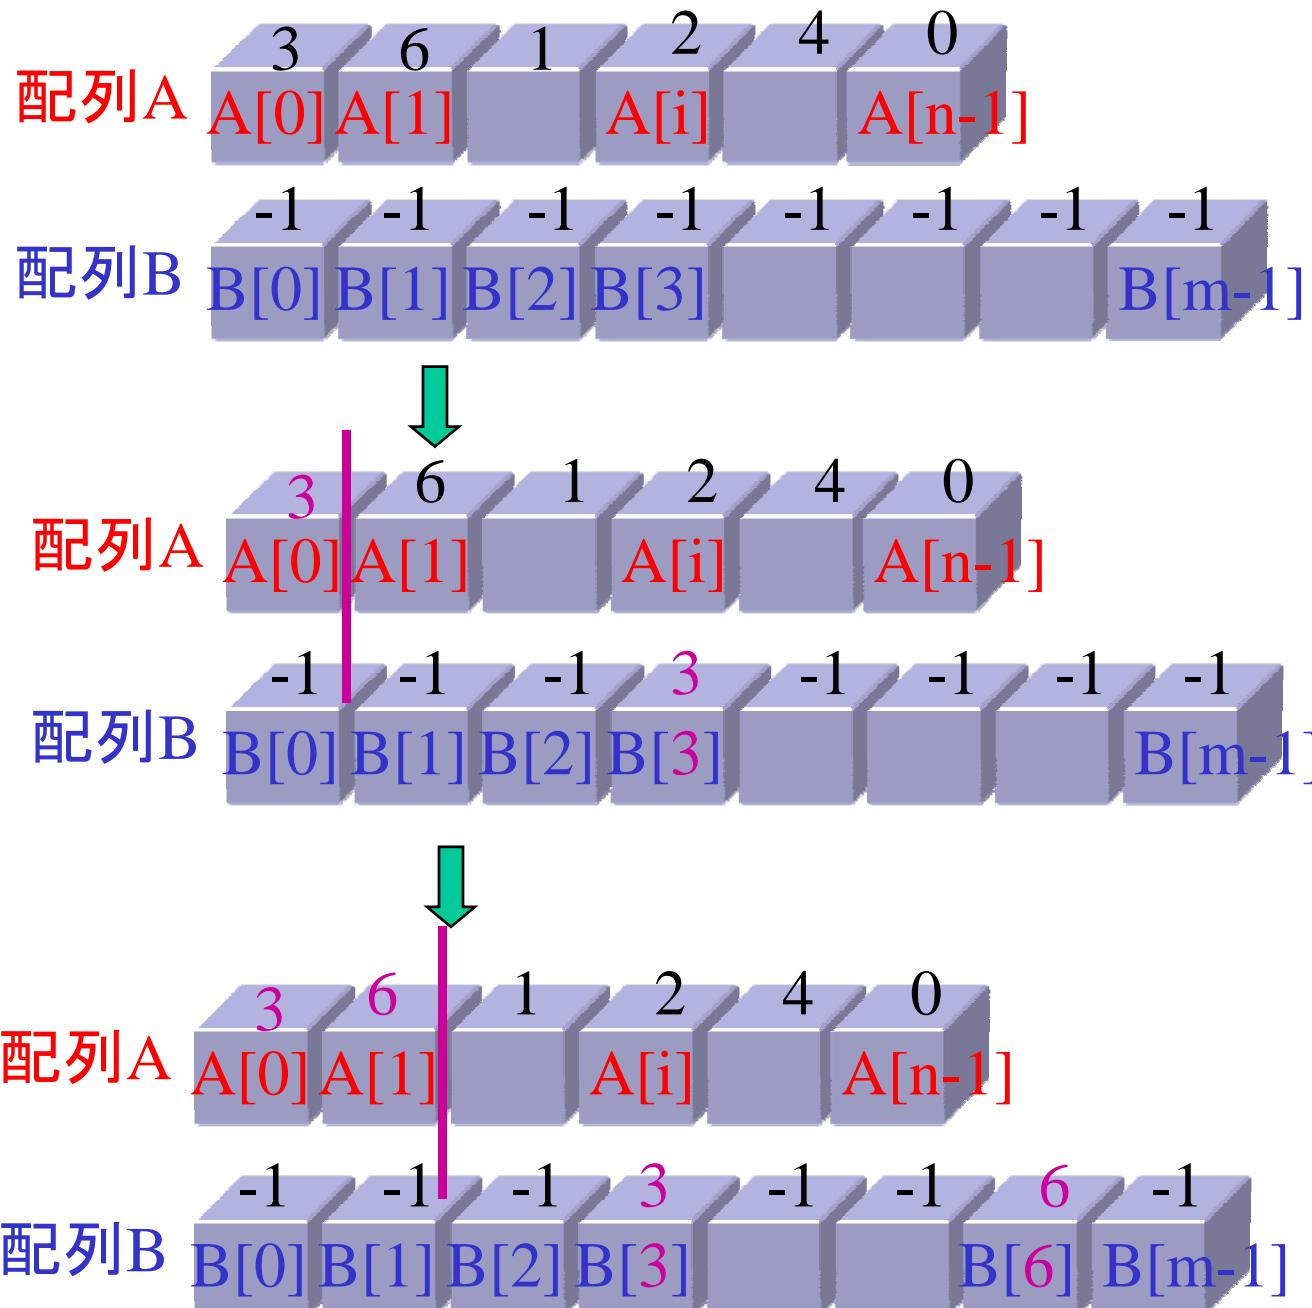
1. 重複がなく、
2. 0から $m-1$ の整数

という性質を満足するとしましょう。
(例えば、学籍番号の下2桁とか。)

方針

- m 個のバケット(配列)を用意して、
データを振り分けていく。
- データそのものを配列の添字として使う。

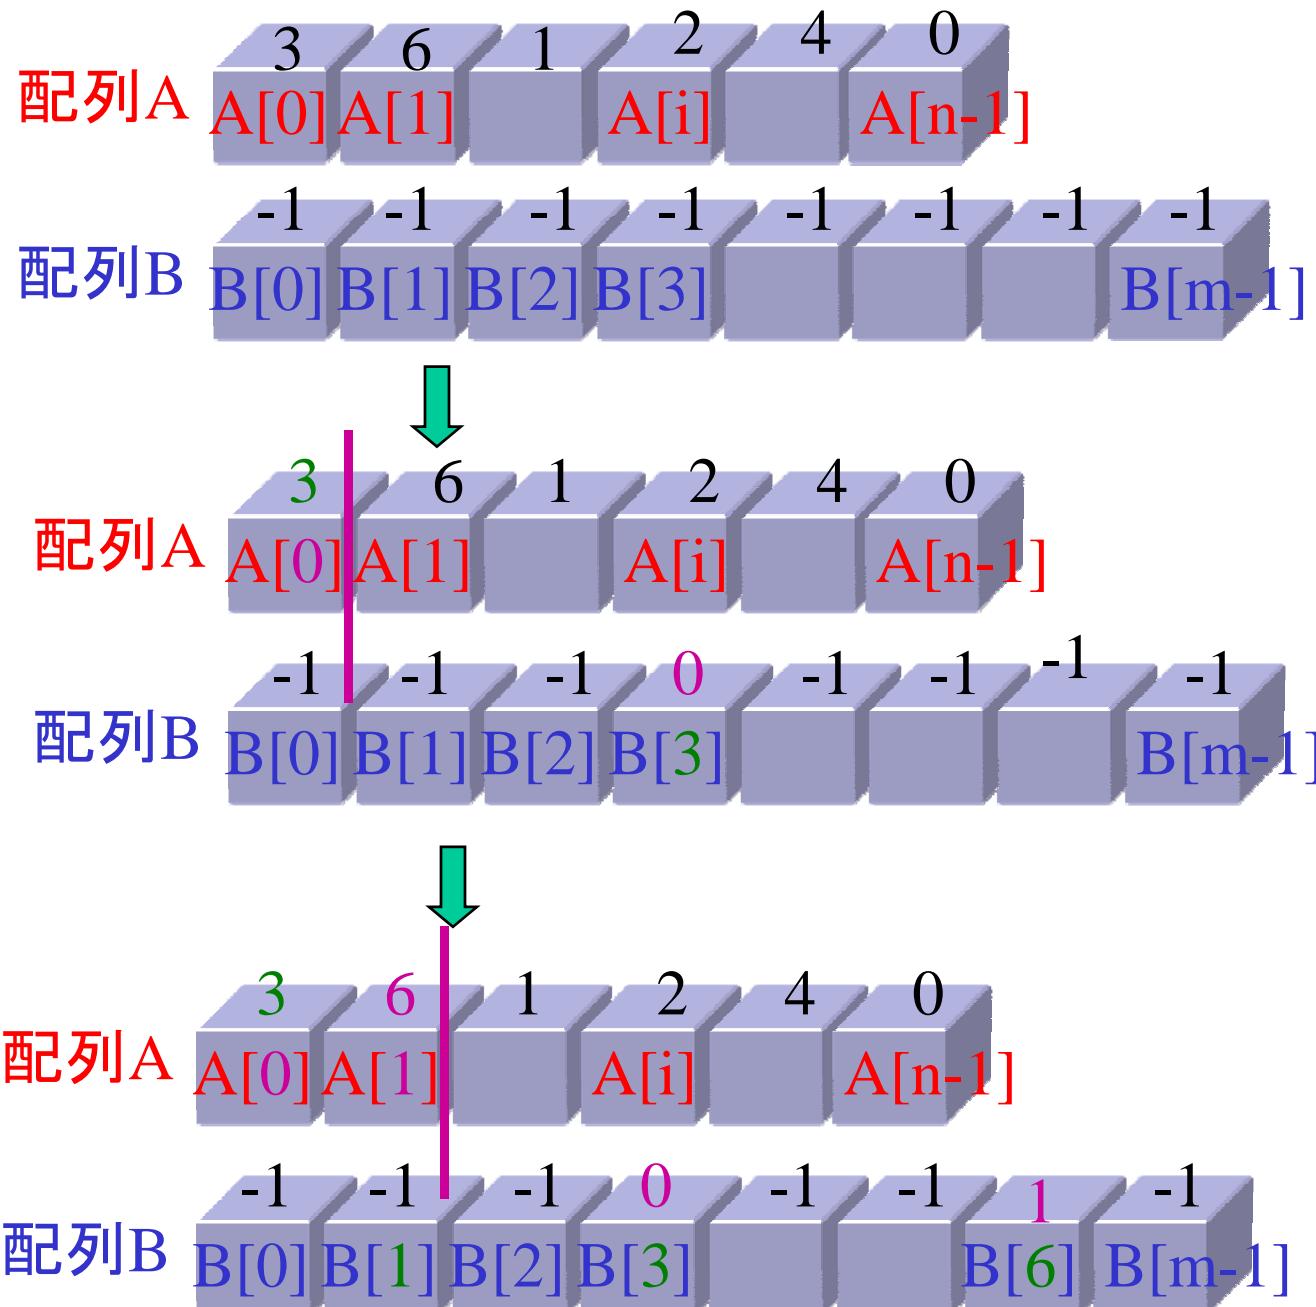
バケットソートの動き1



バケットソートの実現

```
/*概略です。細かい部分は省略  
入力データの配列の型がintであることに注意*/  
void bucket_sort(int A[],int B[])  
{  
    int i;          /*カウンタ*/  
  
    for(i=0;i<n;i++)  
    {  
        B[A[i]]=A[i];  
    }  
    return;  
}
```

バケットソートの動き2(添字を用いた場合)



バケットソートの実現2

```
/* 配列の添字を用いて、間接的にソート*/
void bucket_sort(int A[],int B[])
{
    int i;          /*カウンタ*/
    for(i=0;i<n;i++)
    {
        B[A[i]]=i;
    }
    return;
}
```

i番目のデータの参照は、A[B[i]]で行う。

バケットソートの計算量

配列1回のアクセスには、定数時間で実行できる。

繰り返し回数は、明らかにデータ数n回です。

また、

配列Bの準備や、走査のために、 $O(m)$ の時間量必要です。

最悪時間量 $O(m + n)$ のアルゴリズムです。

基数ソート

基数ソート

方針

- 大きい桁の数に対して、
桁毎にバケットソートをしてソートする。
- 下位桁から順にバケットソートする。

基数ソートの動き(3桁)

A	0	221
1	1	650
2	2	23
3	3	2
4	4	106
5	5	226
6	6	250
7	7	126
8	8	372
9	9	47
10	10	215
11	11	33

0桁で
ソート



A	0	650
1	1	250
2	2	221
3	3	2
4	4	372
5	5	23
6	6	33
7	7	215
8	8	106
9	9	226
10	10	126
11	11	47

1桁で
ソート



A	0	2
1	1	106
2	2	215
3	3	221
4	4	23
5	5	226
6	6	126
7	7	33
8	8	47
9	9	650
10	10	250
11	11	372

2桁で
ソート



A	0	2
1	1	23
2	2	33
3	3	47
4	4	106
5	5	126
6	6	215
7	7	221
8	8	226
9	9	250
10	10	372
11	11	650

練習

次の配列に基数ソートを適用したときの動作を示せ。

A
0 123
1 32
2 612
3 4
4 821
5 621
6 100
7 754
8 253
9 558
10 56
11 234

基数ソートの実現

```
/* 細かい実現は省略*/
void radix_sort(int A[])
{
    int i,j;          /* カウンタ */

    for(k=0;k<max_k;k++)
    {
        bucket_sort(A,k);
        /* 第k桁を基にして、バケットソートでソートして、
         もとの配列に戻すように拡張する。 */
    }

    return;
}
```

基数ソートの計算量

バケットソートを桁数分行えはよいので、
k桁数を基数ソートするには、

最悪時間量 $O(k(m+n))$ のアルゴリズムです。

また、

N 種類のデータを区別するには、 $k = \log_m N$ 桁必要です。

$N \approx n$ のときには、 結局

$O(m \log n + n \log n)$ の時間量を持つアルゴリズムです。

だから、バケットソートや基数ソートは、
データ範囲mや、桁数kに注意しましょう。

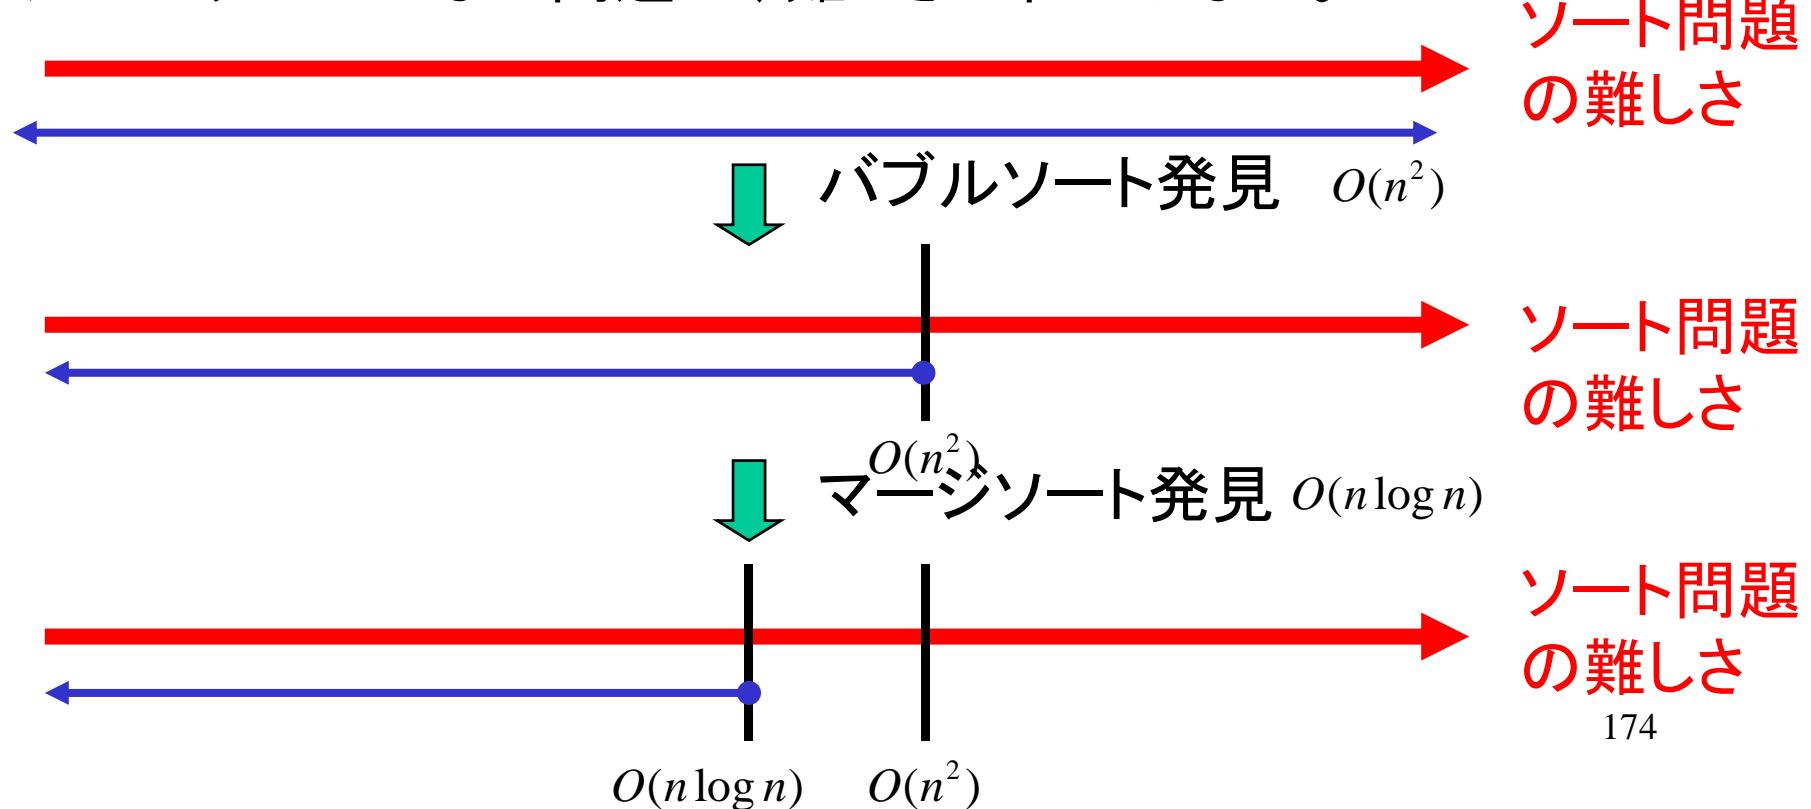
4-5:ソート問題の下界

問題とアルゴリズム

具体的なアルゴリズムを作ることは、
問題の難しさ(問題固有の計算量)の上界を与えています。

最適なアルゴリズムの存在範囲

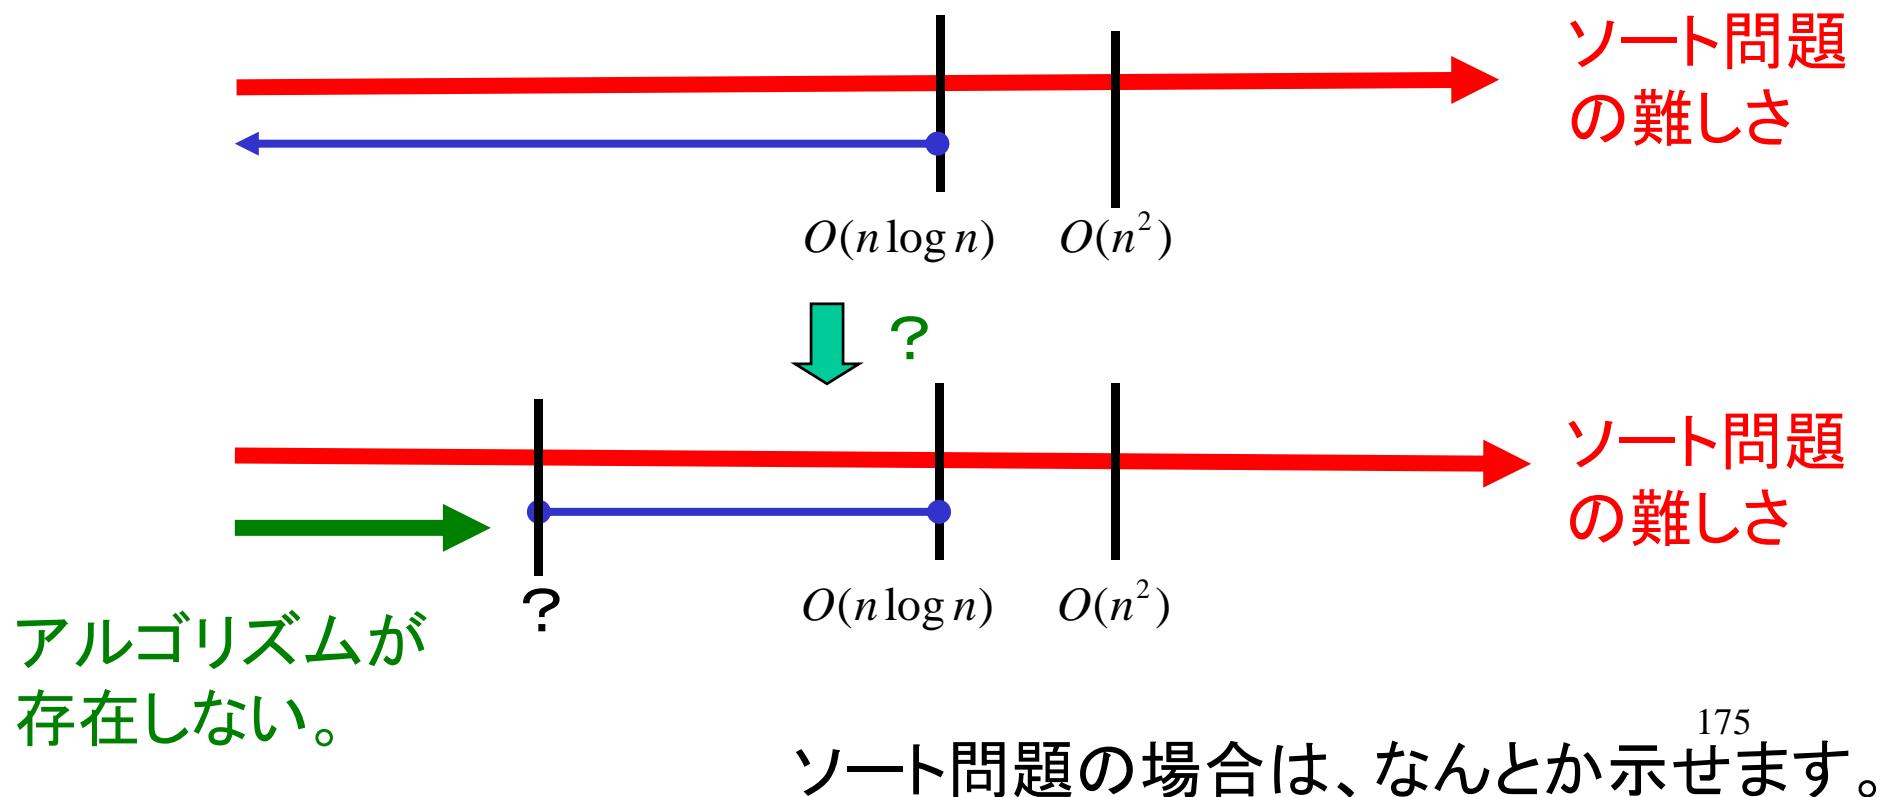
アルゴリズムがない問題は、難しさがわからない。



問題と下界

一方、問題の難しさの範囲を下の方から狭めるには、問題を解くアルゴリズムが無いことを示さないといけない。実は、1つのアルゴリズムを作ることより、アルゴリズムが存在しないことを示すことの方が難しい。

最適なアルゴリズムの存在範囲



アルゴリズムと決定木 (比較によるソートの下界証明の準備)

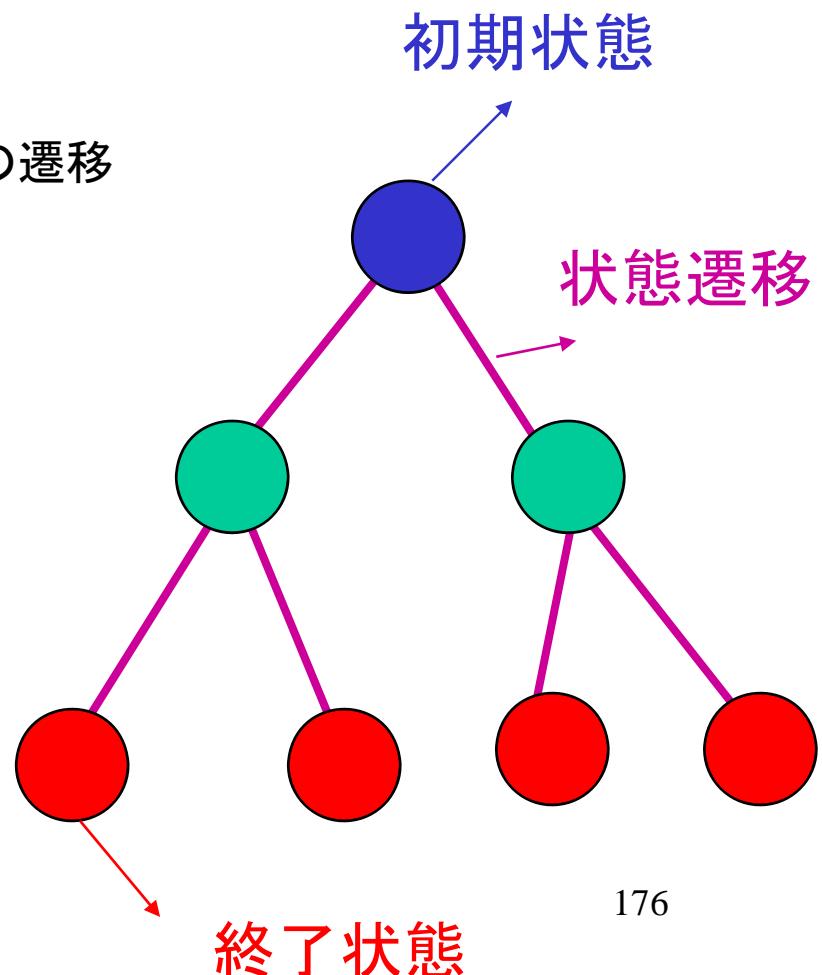
決定木の根:初期状態

決定木の節点:それまでの計算の状態

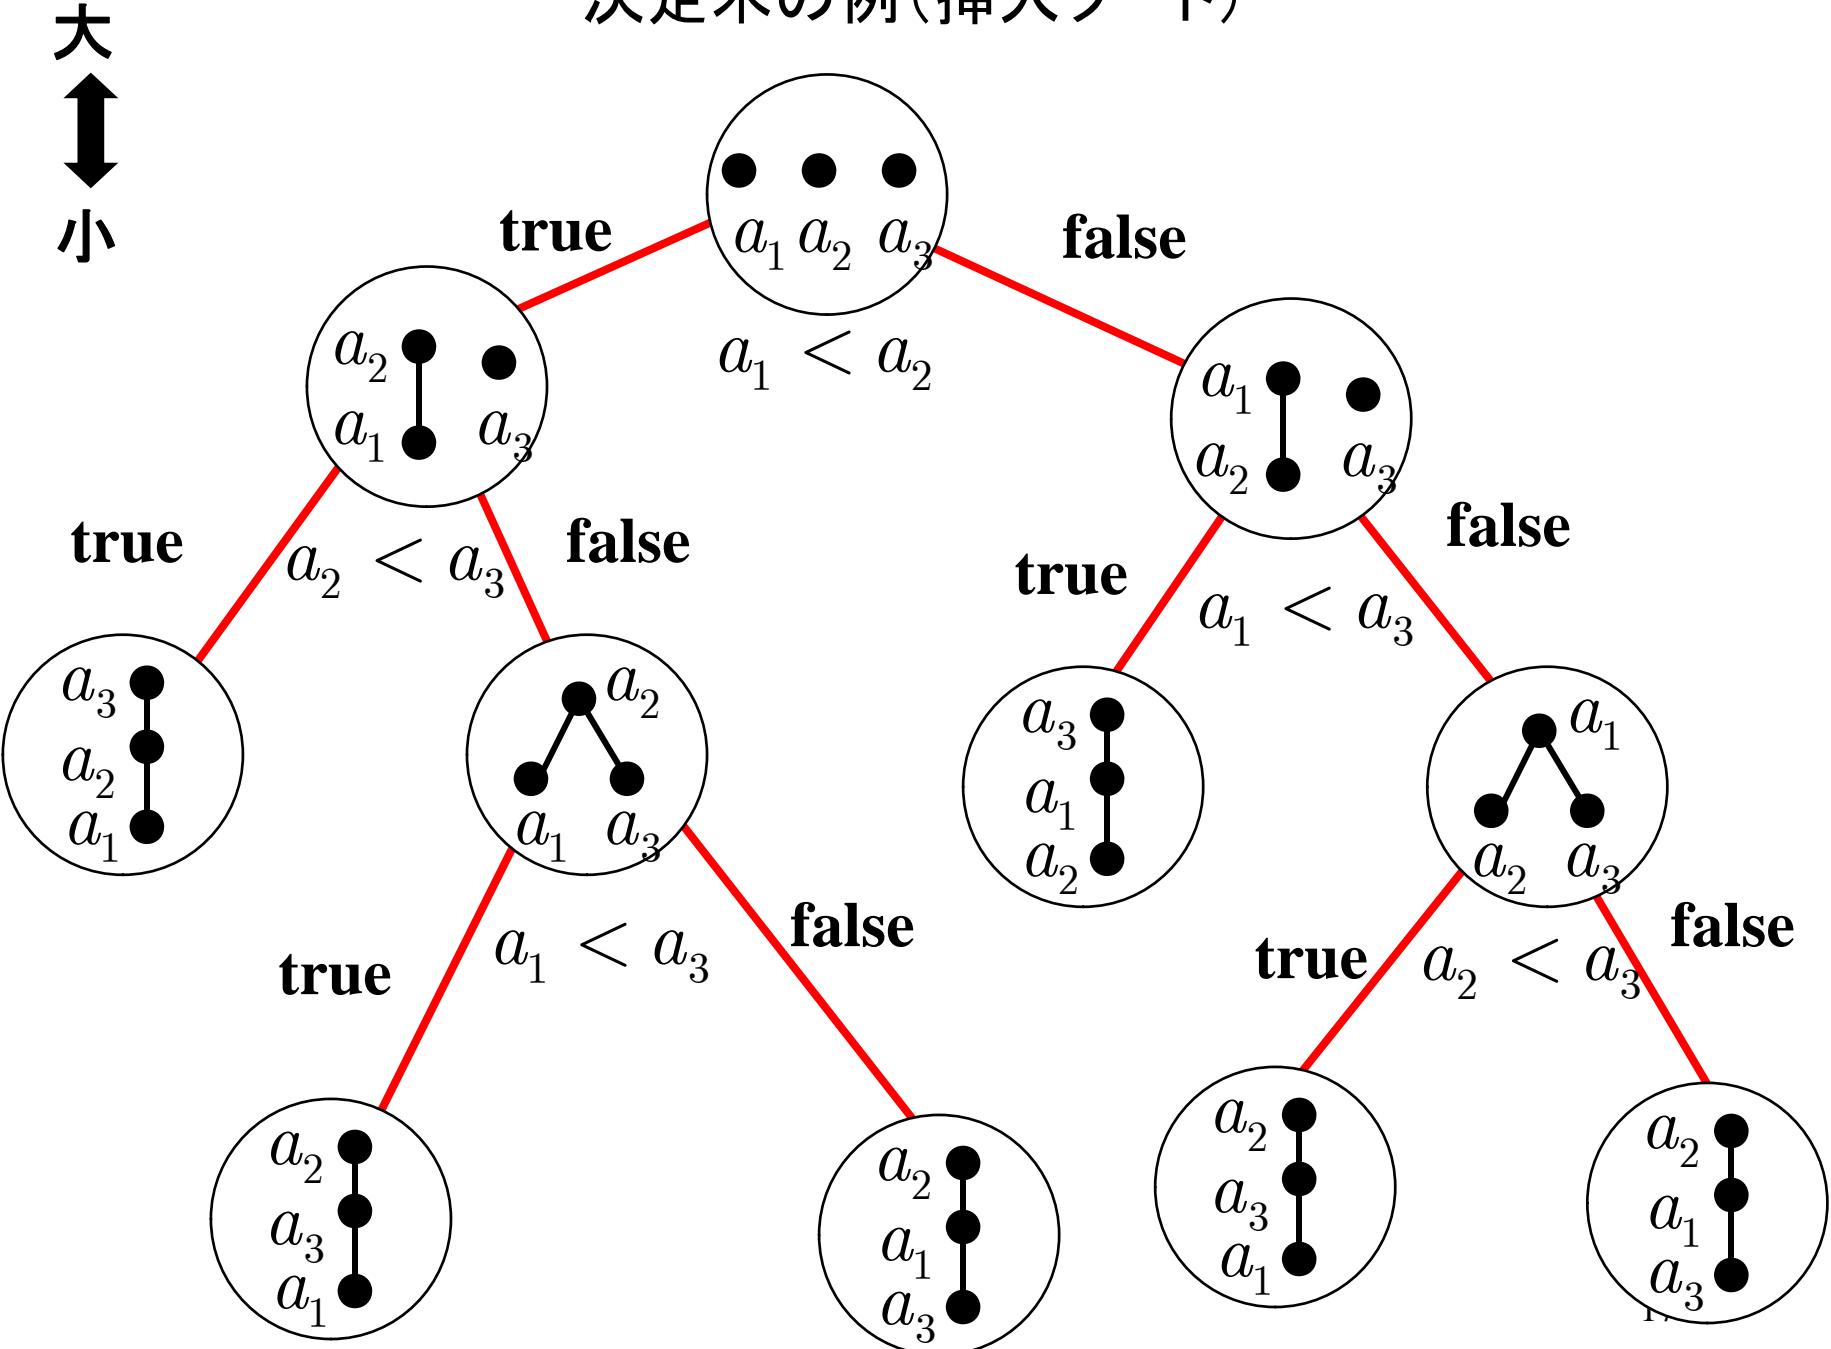
決定木の枝 : アルゴリズムの進行による状態の遷移

決定木の葉:終了状態

(ヒープのような)データ構造の木ではなくて、
概念的、抽象的なもの。
根がアルゴリズムの初期状態に対応し、
葉がアルゴリズム終了状態に対応し、
根からの道がアルゴリズムの実行順に対応し、
根から葉までの道の長さが時間量に対応する。

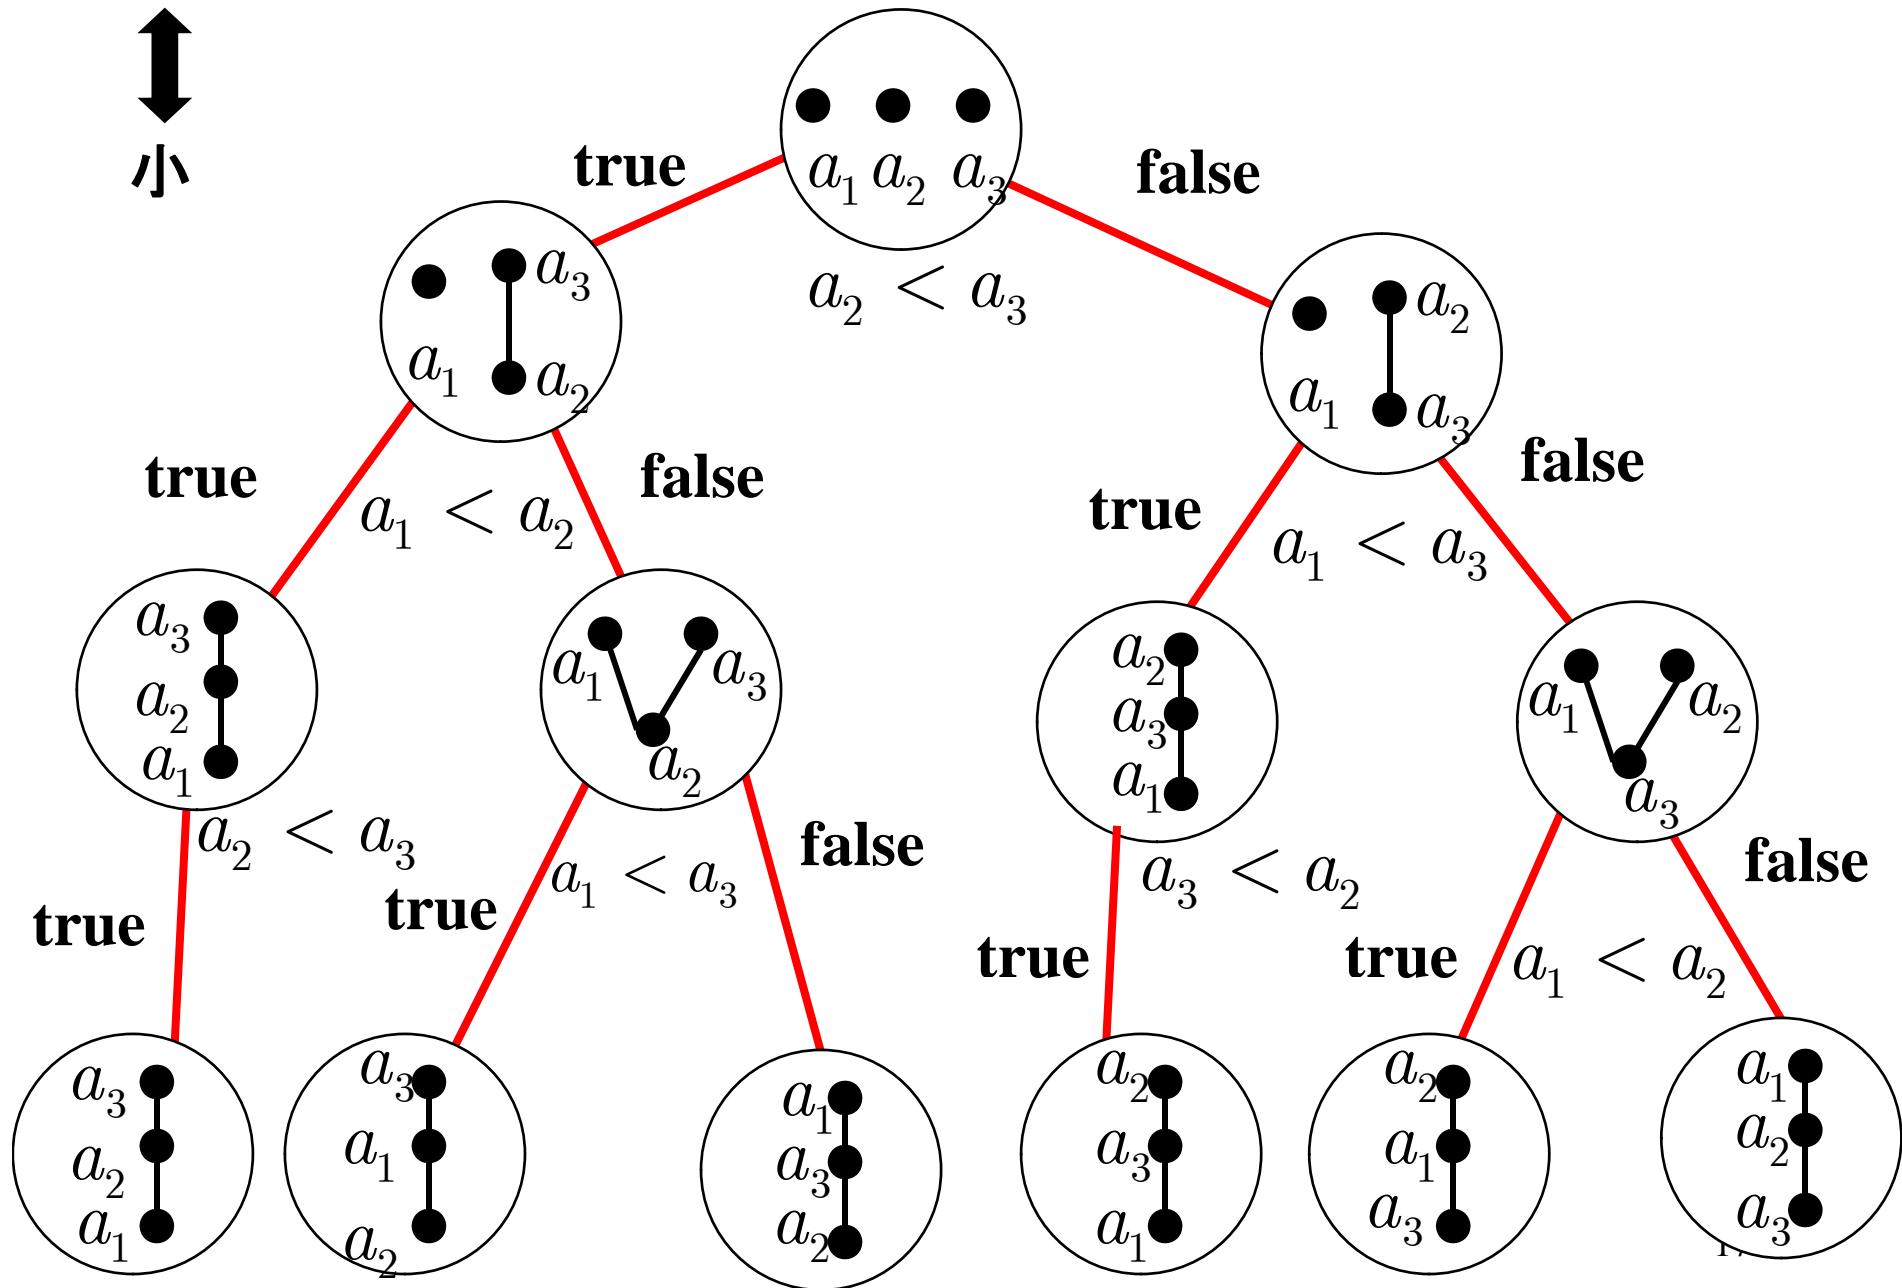


決定木の例(挿入ソート)



決定木の例(バブルソート)

大
↑
小



練習

(1) 3要素の選択ソートのアルゴリズムに対応する
決定木を作成せよ。

(2) 4要素の決定木を作成せよ。
(どんなアルゴリズムを用いても良い。)

ソート問題の下界

どんな入力でもきちんとソートするには、
決定木に $n!$ 個以上の葉がなければならない。
それで、アルゴリズムの比較回数は、
決定木の高さで定まる。

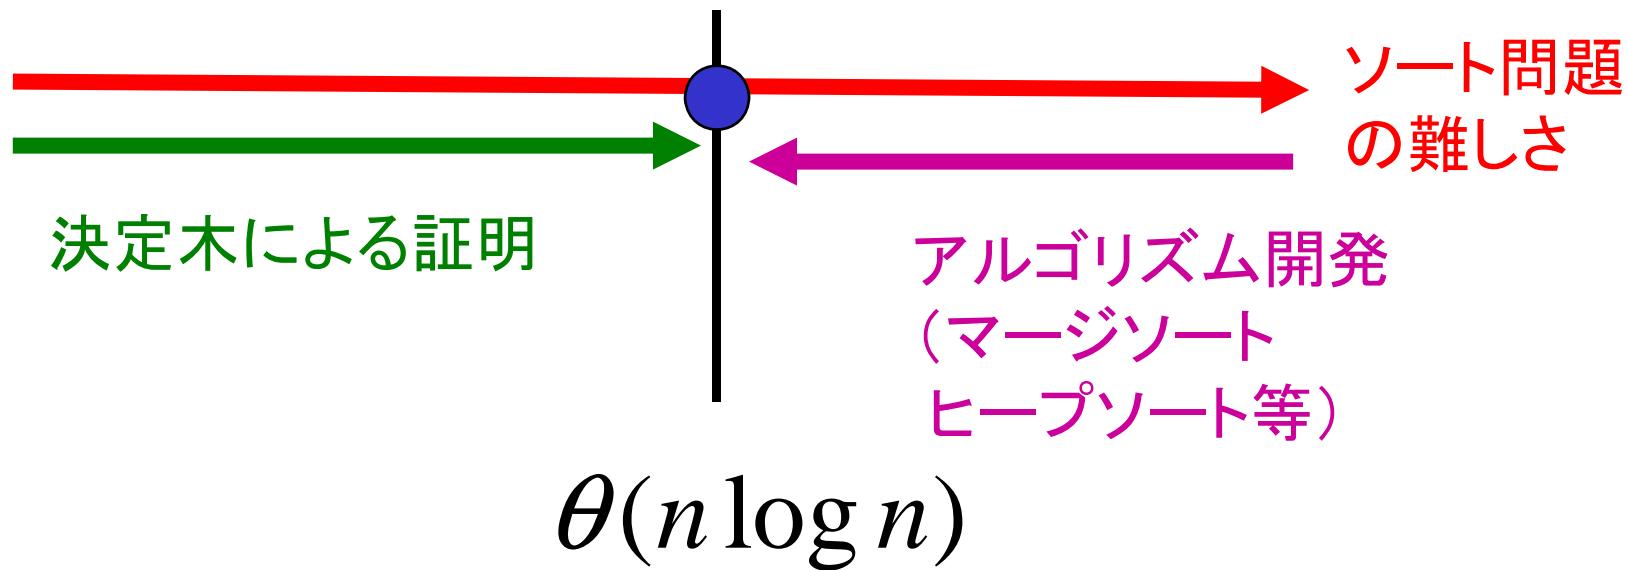
最悪時間が良いアルゴリズムは高さが低く、
悪いアルゴリズムは高さが高い。

高さが h の決定木では、高々 2^h 個の葉しかない。

よって、 $h \geq \log_2 n! \geq n \log n$

よって、ソートアルゴリズムでは少なくとも
 $\Omega(n \log n)$ の時間量が必要である。

ソート問題の難しさ



こんなことを考えるのが、
計算量理論の分野です。