７．木構造

- ７－１．データ構造としての木
  - グラフ理論での木の定義
  - 根付き木
- ７－２．２分探索木
- ７－３．高度な木（平衡木）
  - AVL木
  - B木

７－1.データ構造としての木

木構造

- 配列を用いて木構造を表すデータ構造としてヒープがある。しかし、ヒープでは、要素数で木の形状が一通りにさだまってしまった。

- ここでは、再帰的なデータ構造を用いることにより、より柔軟な木構造が構築可能なことを見ていく。

グラフ理論における木

- グラフ理論では、木は以下のように定義される。

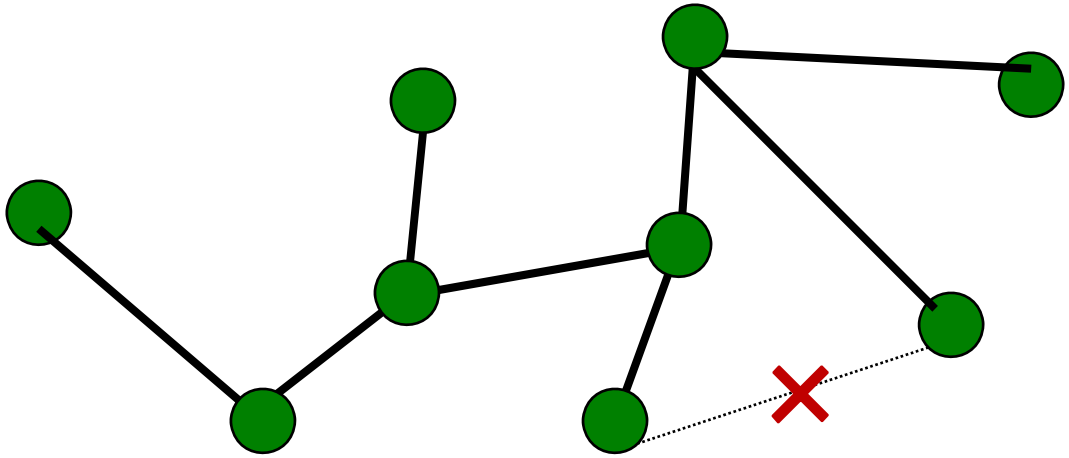

定義：（グラフ理論での）木

閉路のない連結なグラフ。

木の性質

- Ｎ点からなる木の辺数はＮ－１である。
- 木に１辺を加えると、閉路ができる。（閉路の無い連結グラフで辺数が最大である。）
- 木から１辺を削除すると、非連結になる。（木は、連結グラフで辺数が最小である。
- 任意の２点からなる道は唯一に定まる。

特に、最後の性質は、ファイルシステムに利用されている。

木の用語定義

- 木の各頂点をノードという。
- 木の特別な1つの頂点を根といい、根の指定された木を根付き木という。
- （根以外の）次数1の点を葉という。
- 根からの道の長さを深さという。
- 最大の道の長さを高さという。
- ある頂点vに対して、根に向かう道で、一番近い頂点をvの親という。
- 頂点vを親とする頂点wを、頂点vの子という。
- ある頂点vに対して、vの子孫からなる部分グラフを頂点vにおける部分木という。

木に関する用語1

- 深さ:根までの道の長さ
- 高さ:木中の最大の深さ

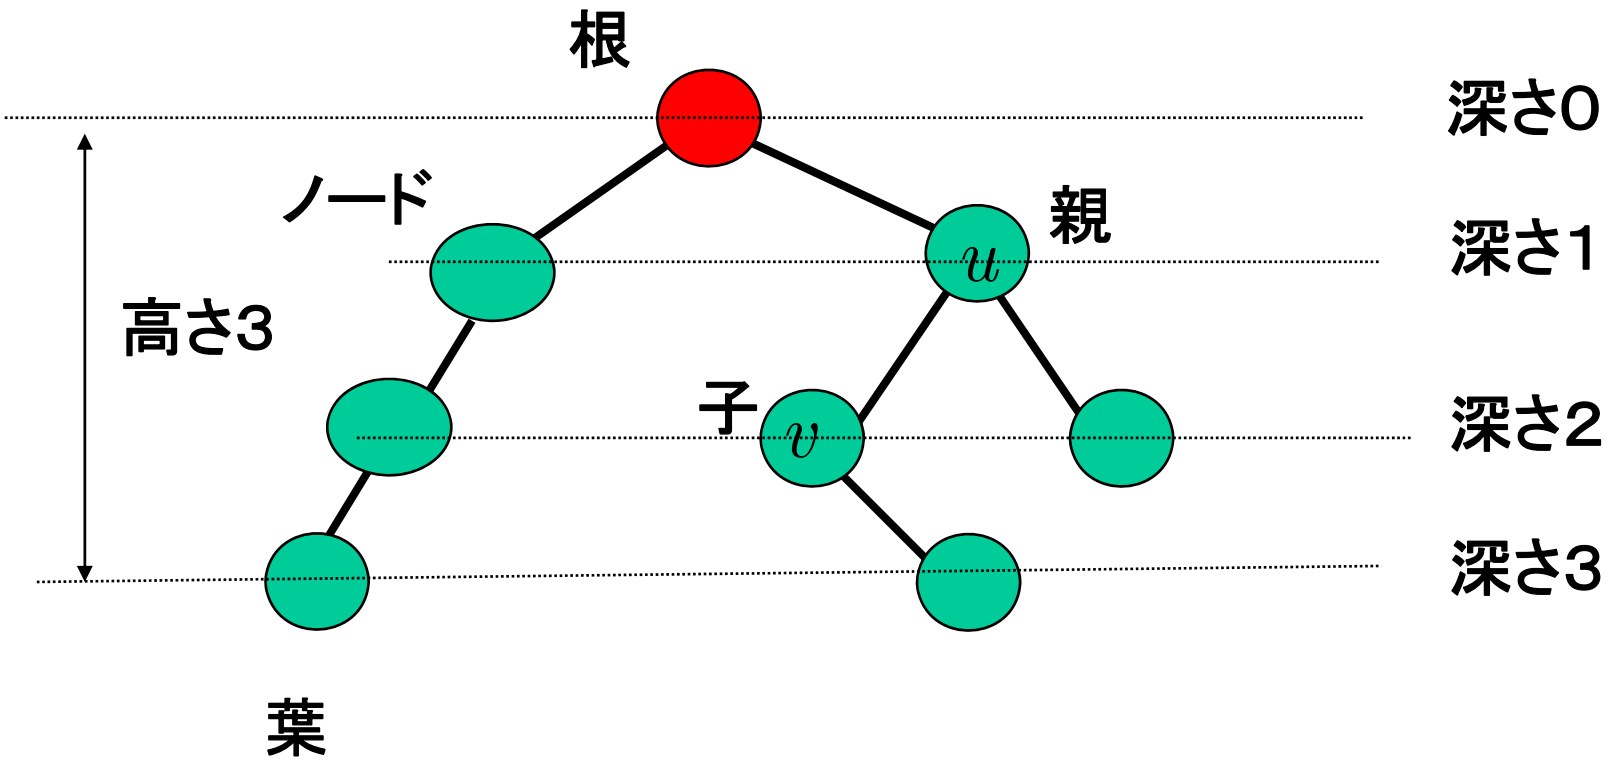

木に関する用語2

部分木：ある頂点の子孫からなる部分グラフ

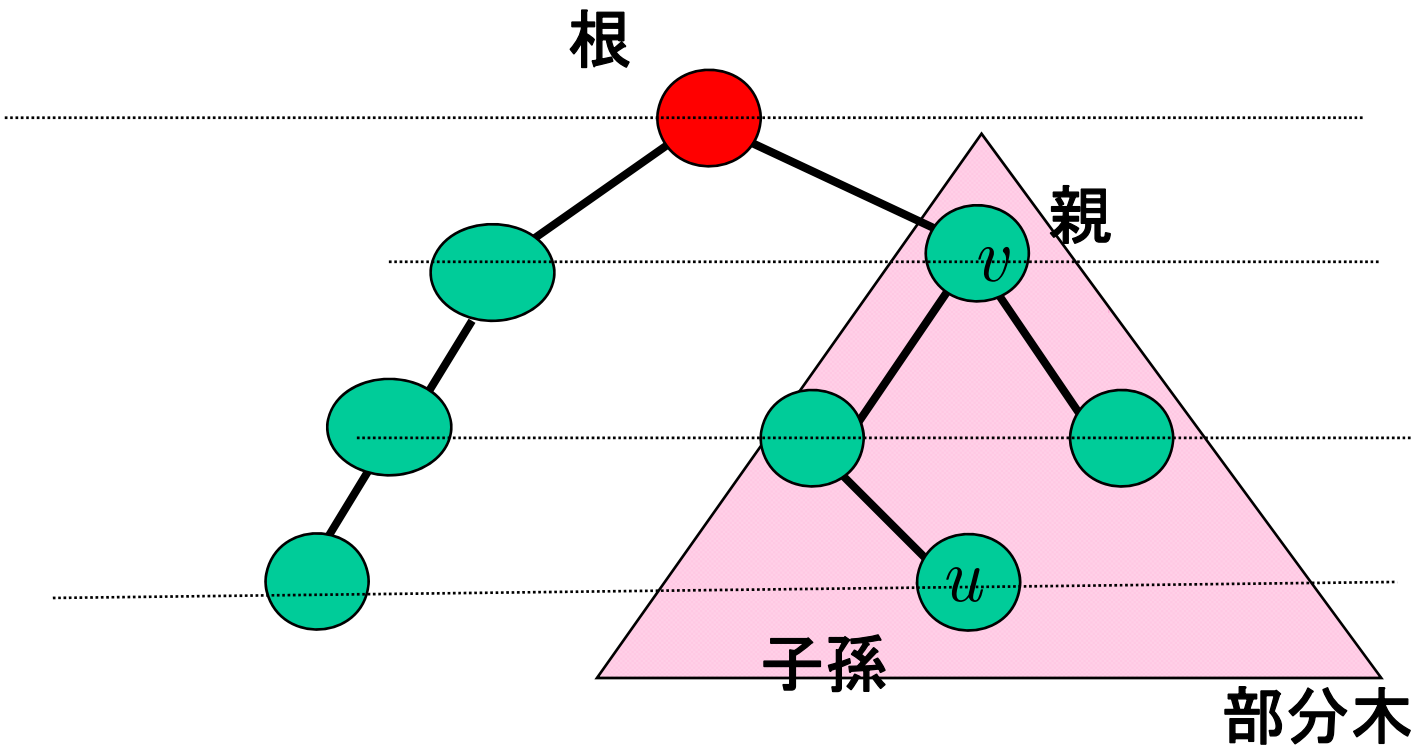

2分木

- 高々2つの子しかない木。
- 左と右の子を区別する。

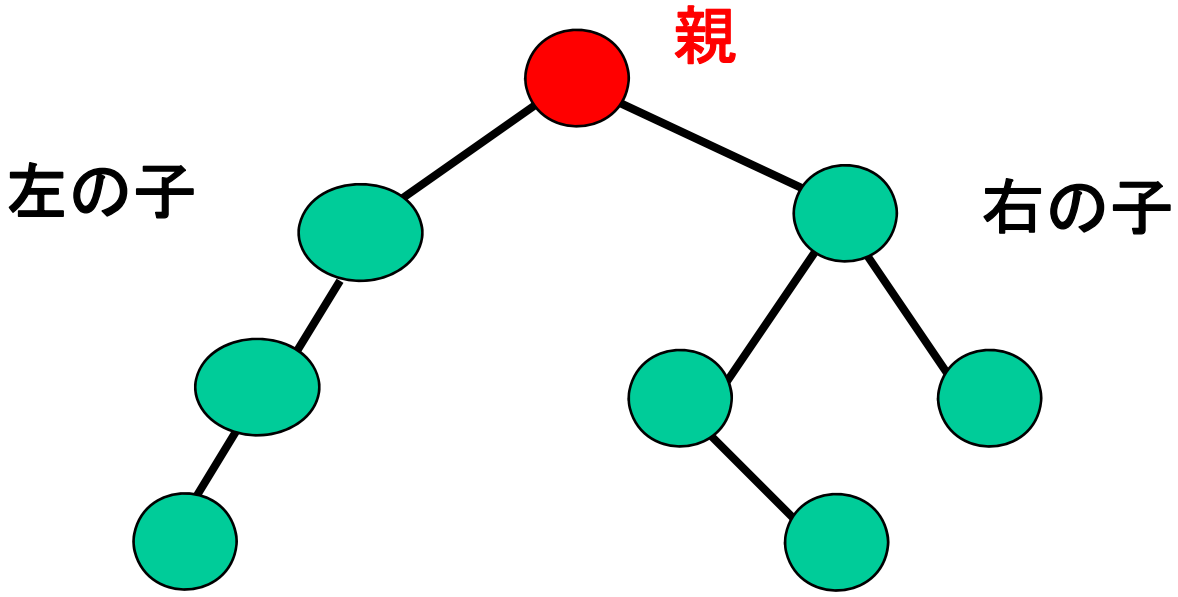

データ構造としての木

- 2つの子供を直接ポインタで指すようにする。
- ノードを再帰的なデータ構造として定義する。
- 葉では、子供を指すポインタ2つに対して、双方ともNULLにする。

データ構造の基本単位（ノード）

- 自己参照構造体を用いる。

```
 struct  node
{
        double  data;
        struct node * left;/*左の子供を指す。*/
        struct node * right;/*右の子供を指す*/
};
```

イメージ

strcut node型

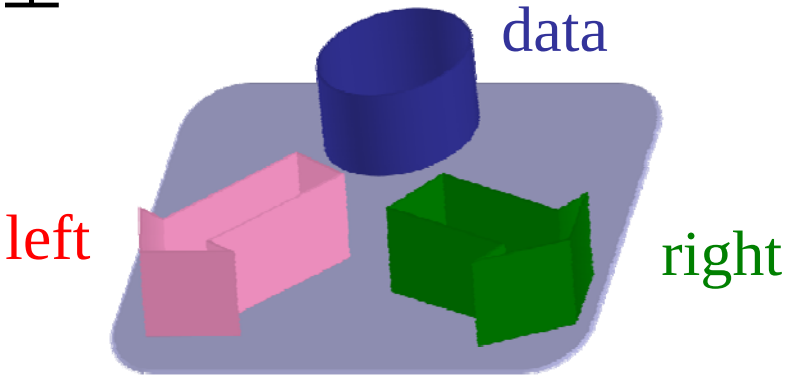

strcut node型

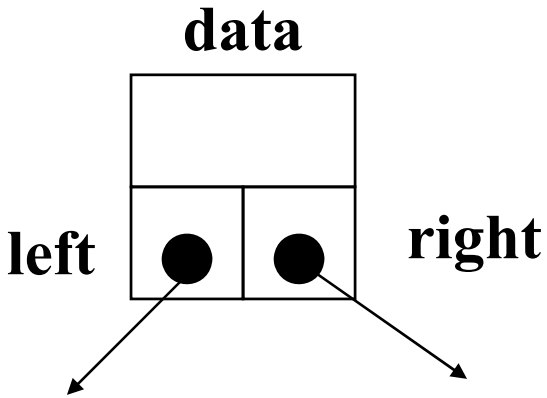

ノード型の定義

```
typedef  strcuct node   Node;
```

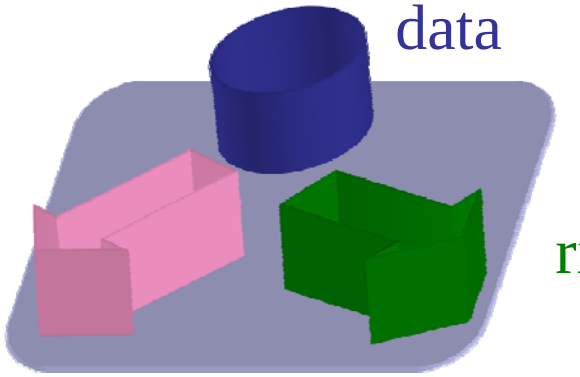

Node型

Node ＊ 型

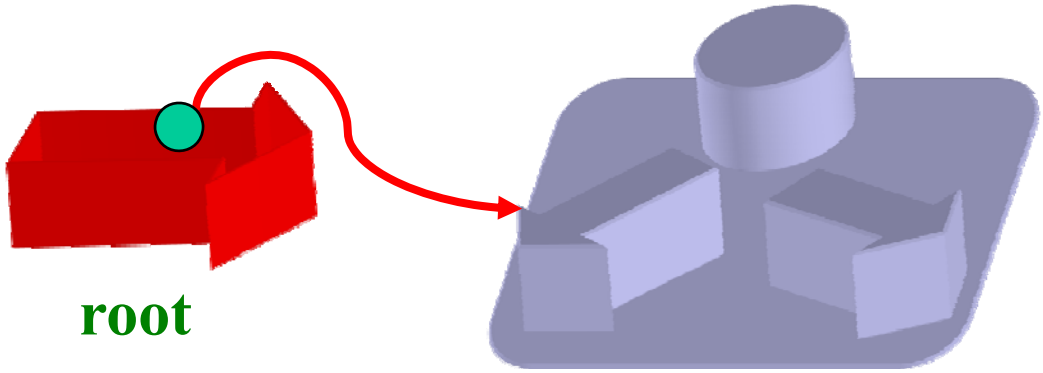

データ構造としての2分木

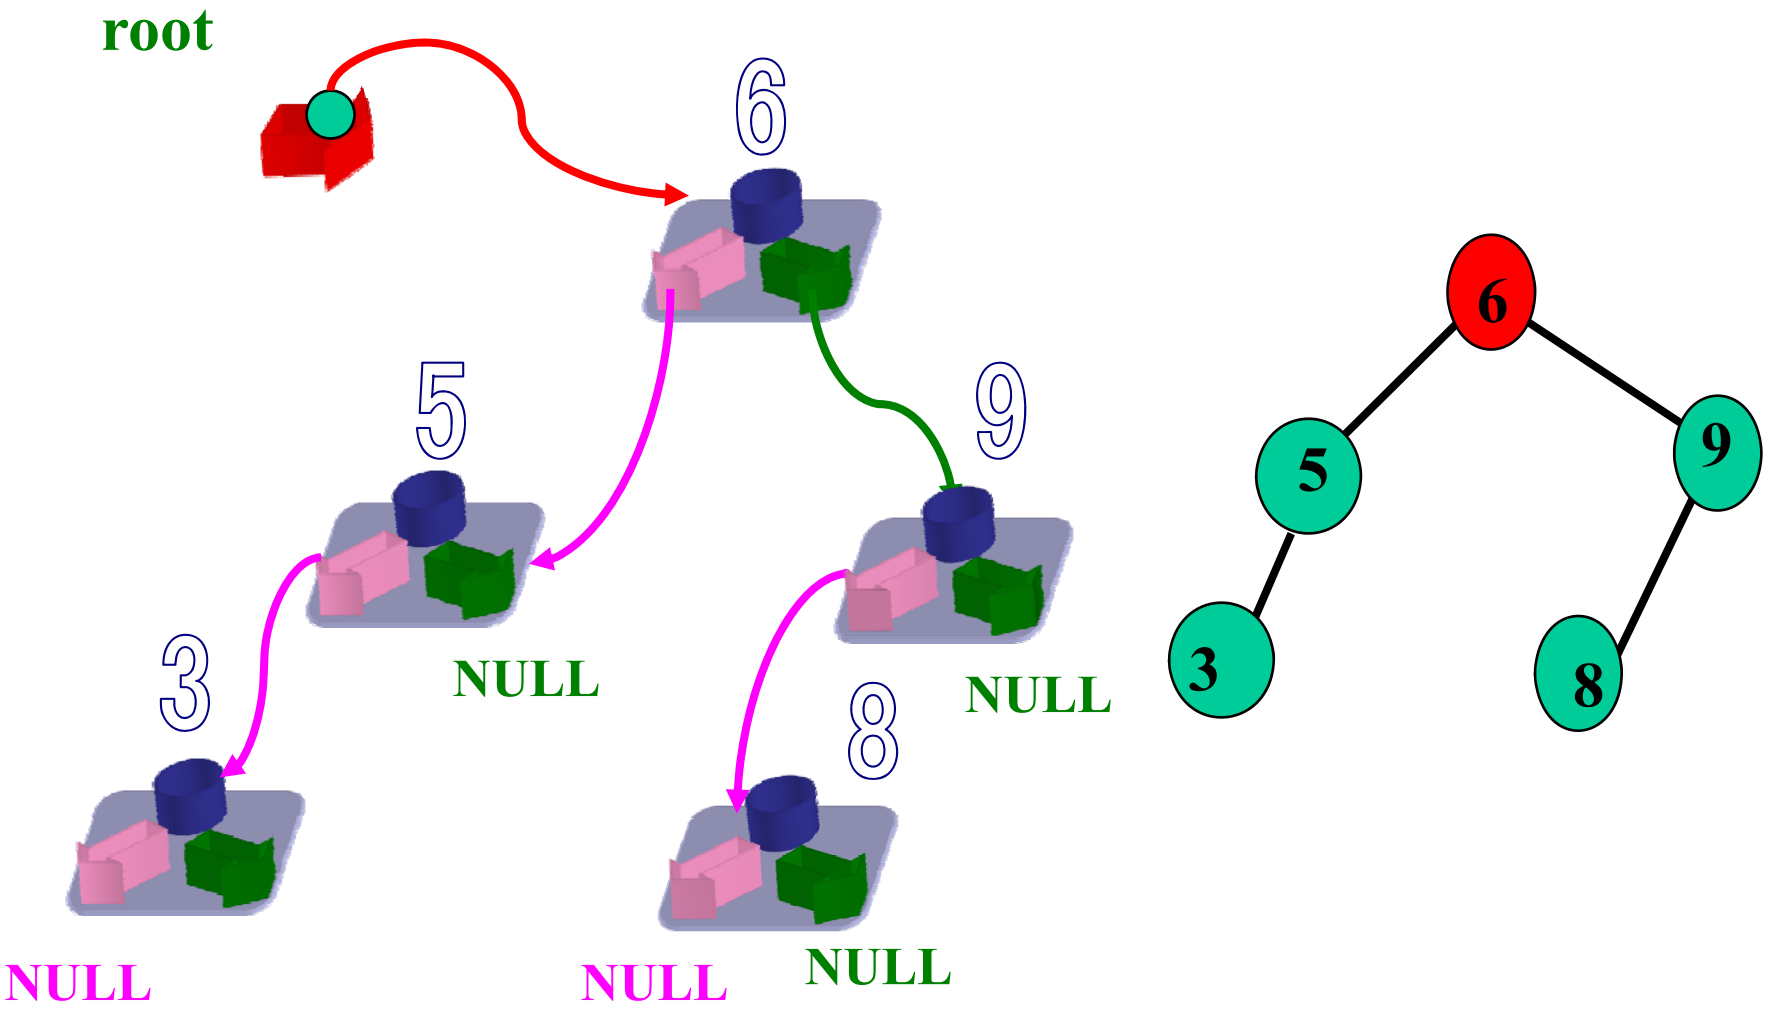

データ構造としての2分木2

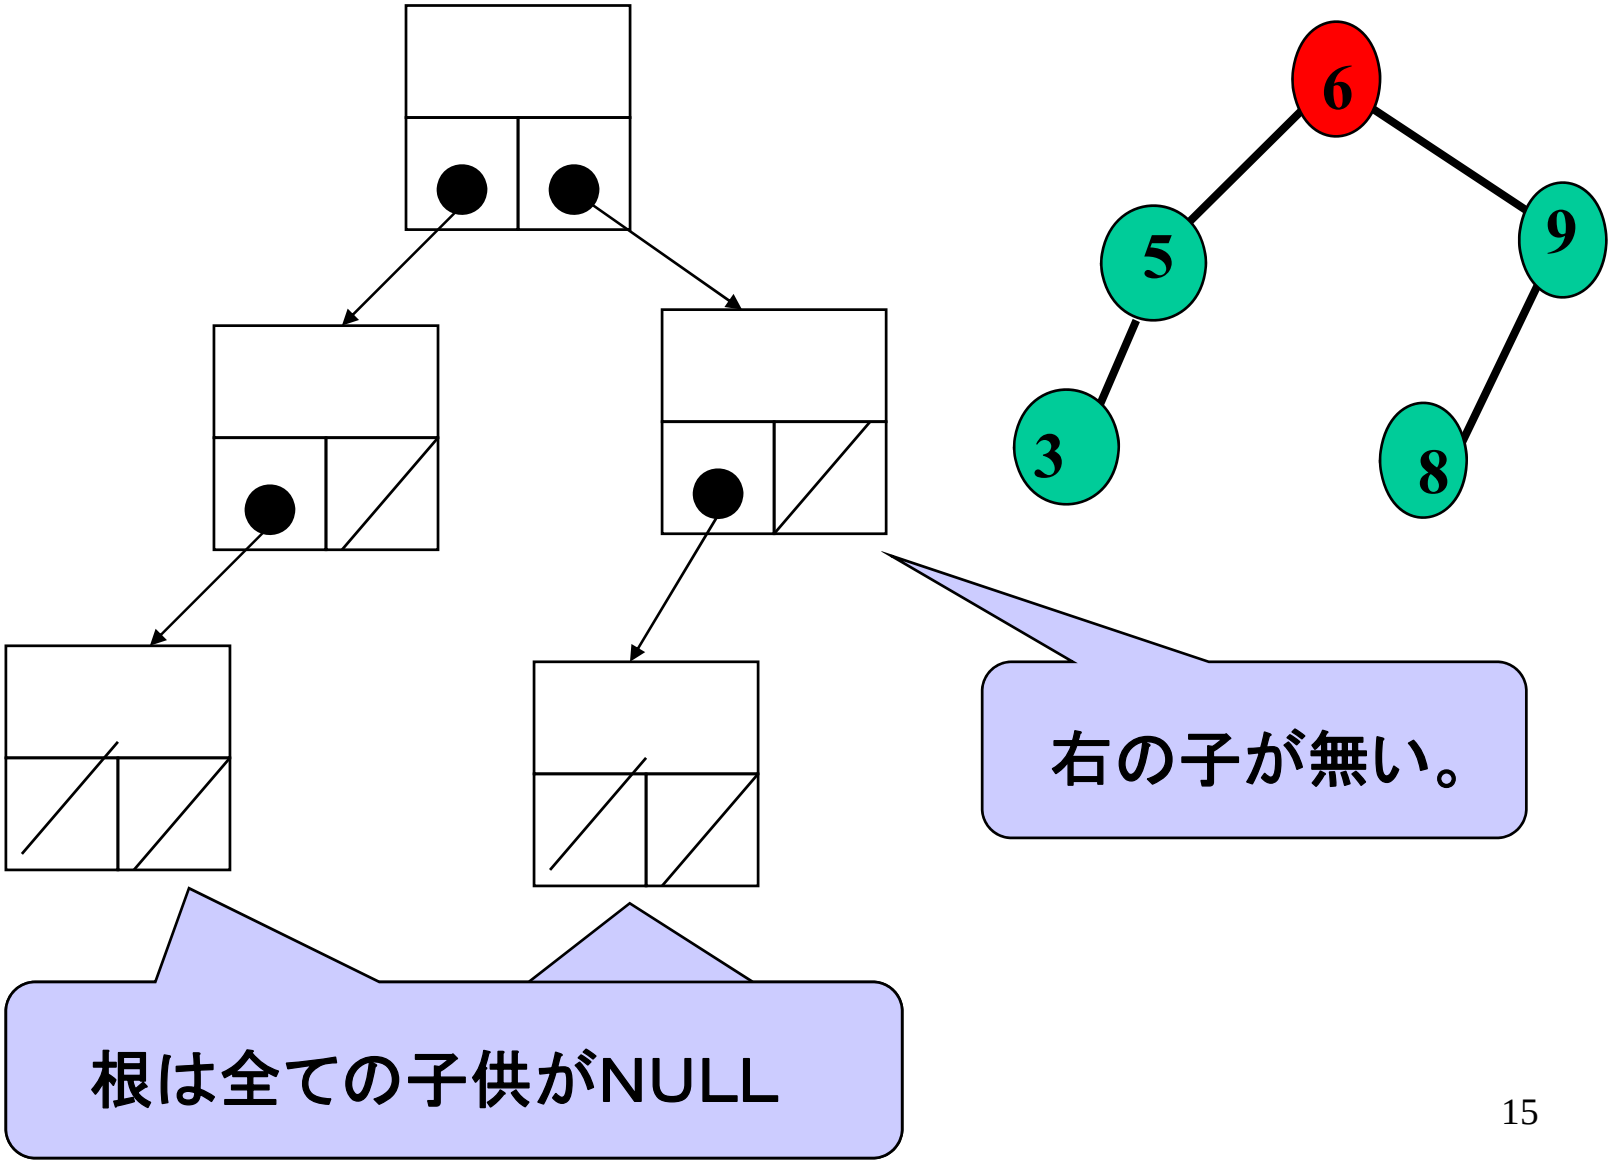

７－２．２分探索木

- ２分木
- 各頂点vに対して、
  - 左の子を根とする部分木（左の子孫）のデータは頂点vのデータ未満
  - 右の子を根する部分木（右の子孫）のデータは頂点vのデータ以上

イメージ（2分探索木）

- 条件が再帰的になっていることに注意する。

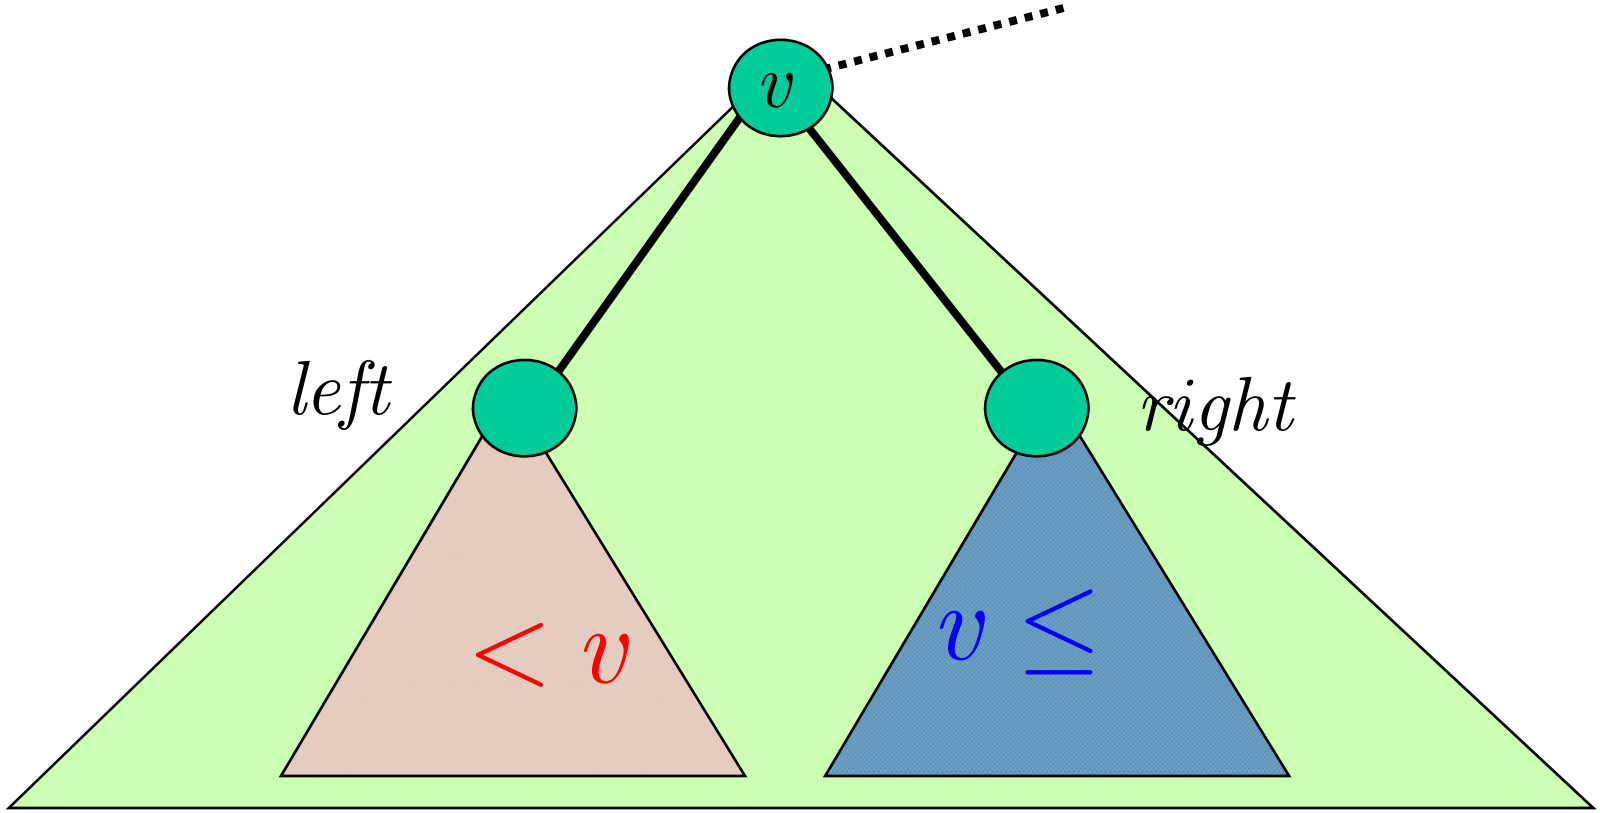

様々な2分探索木

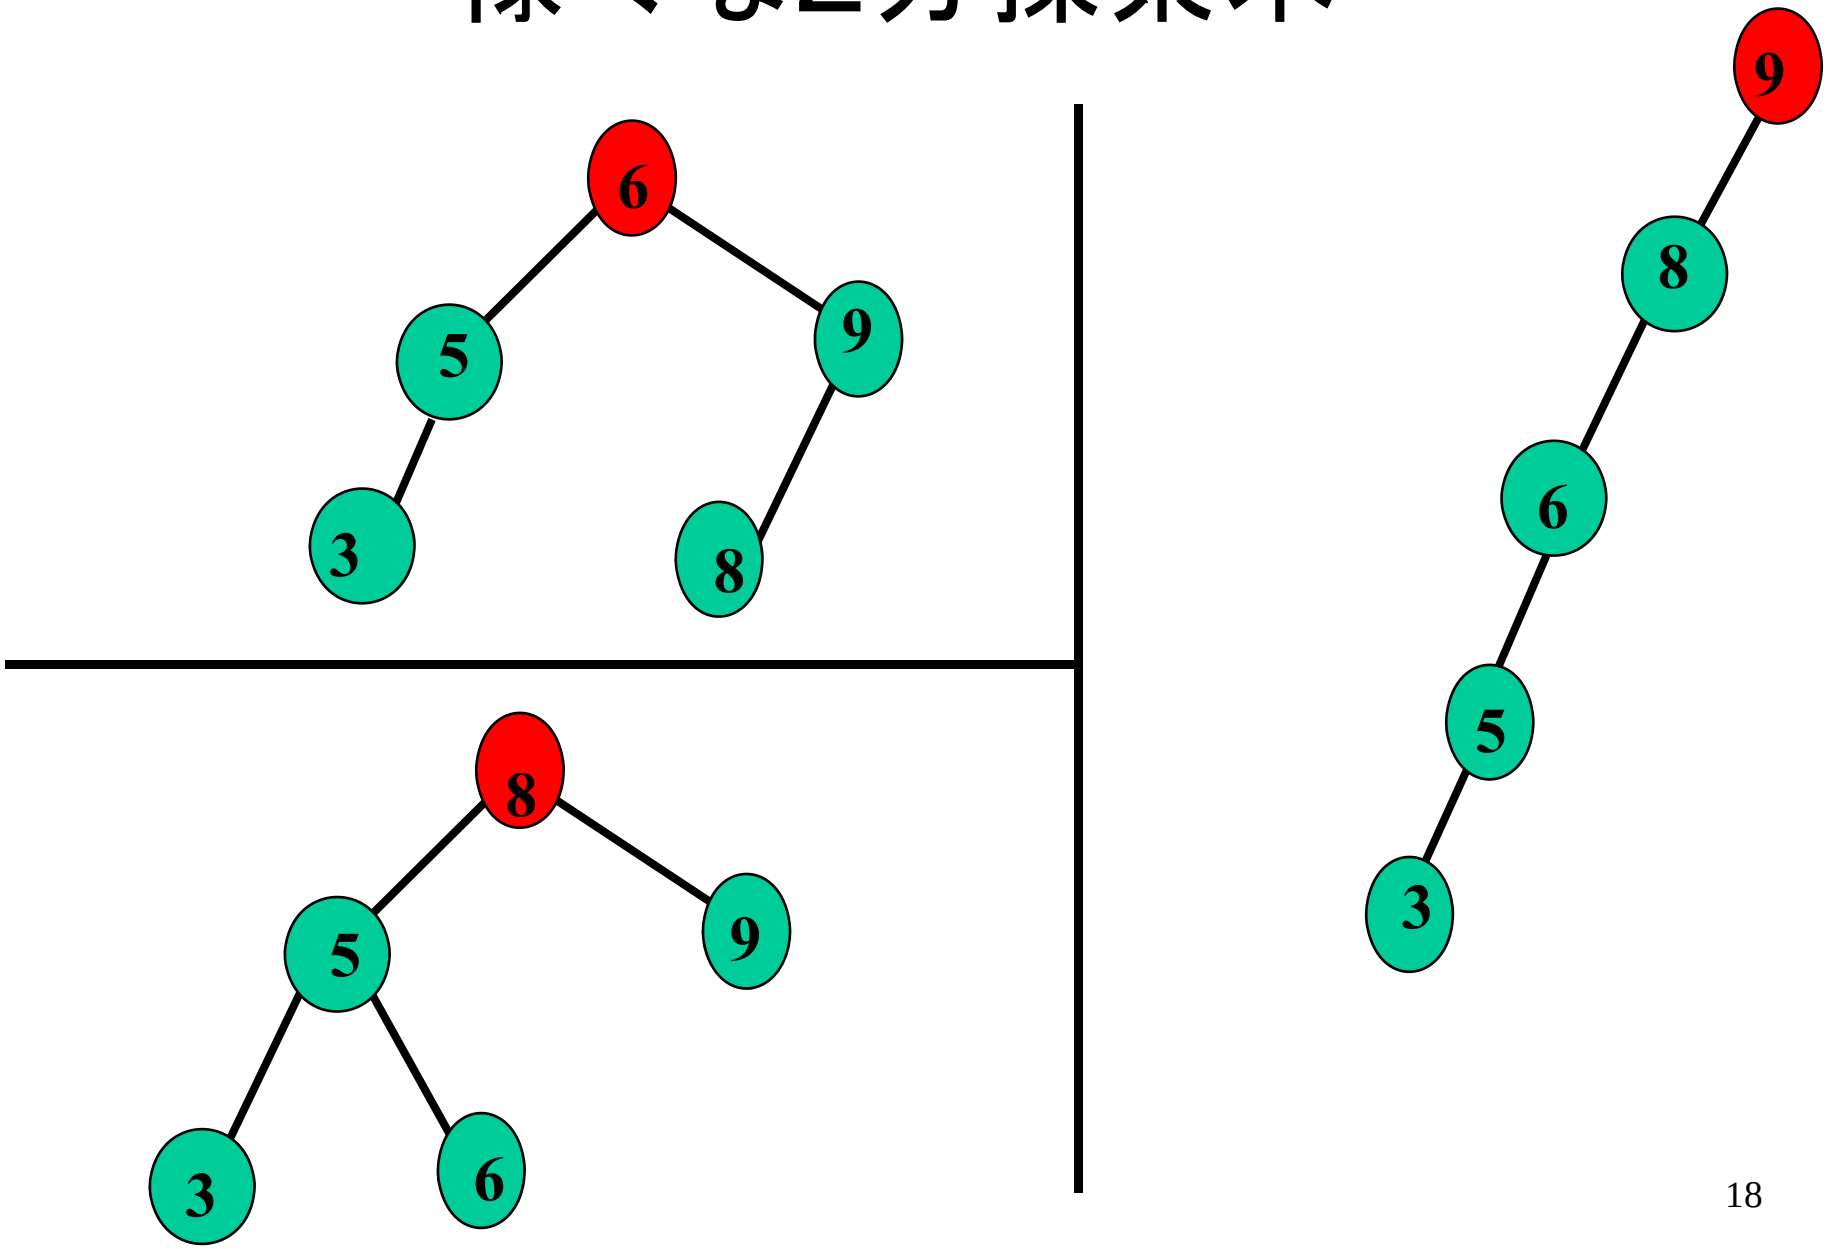

2分探索木ではない木

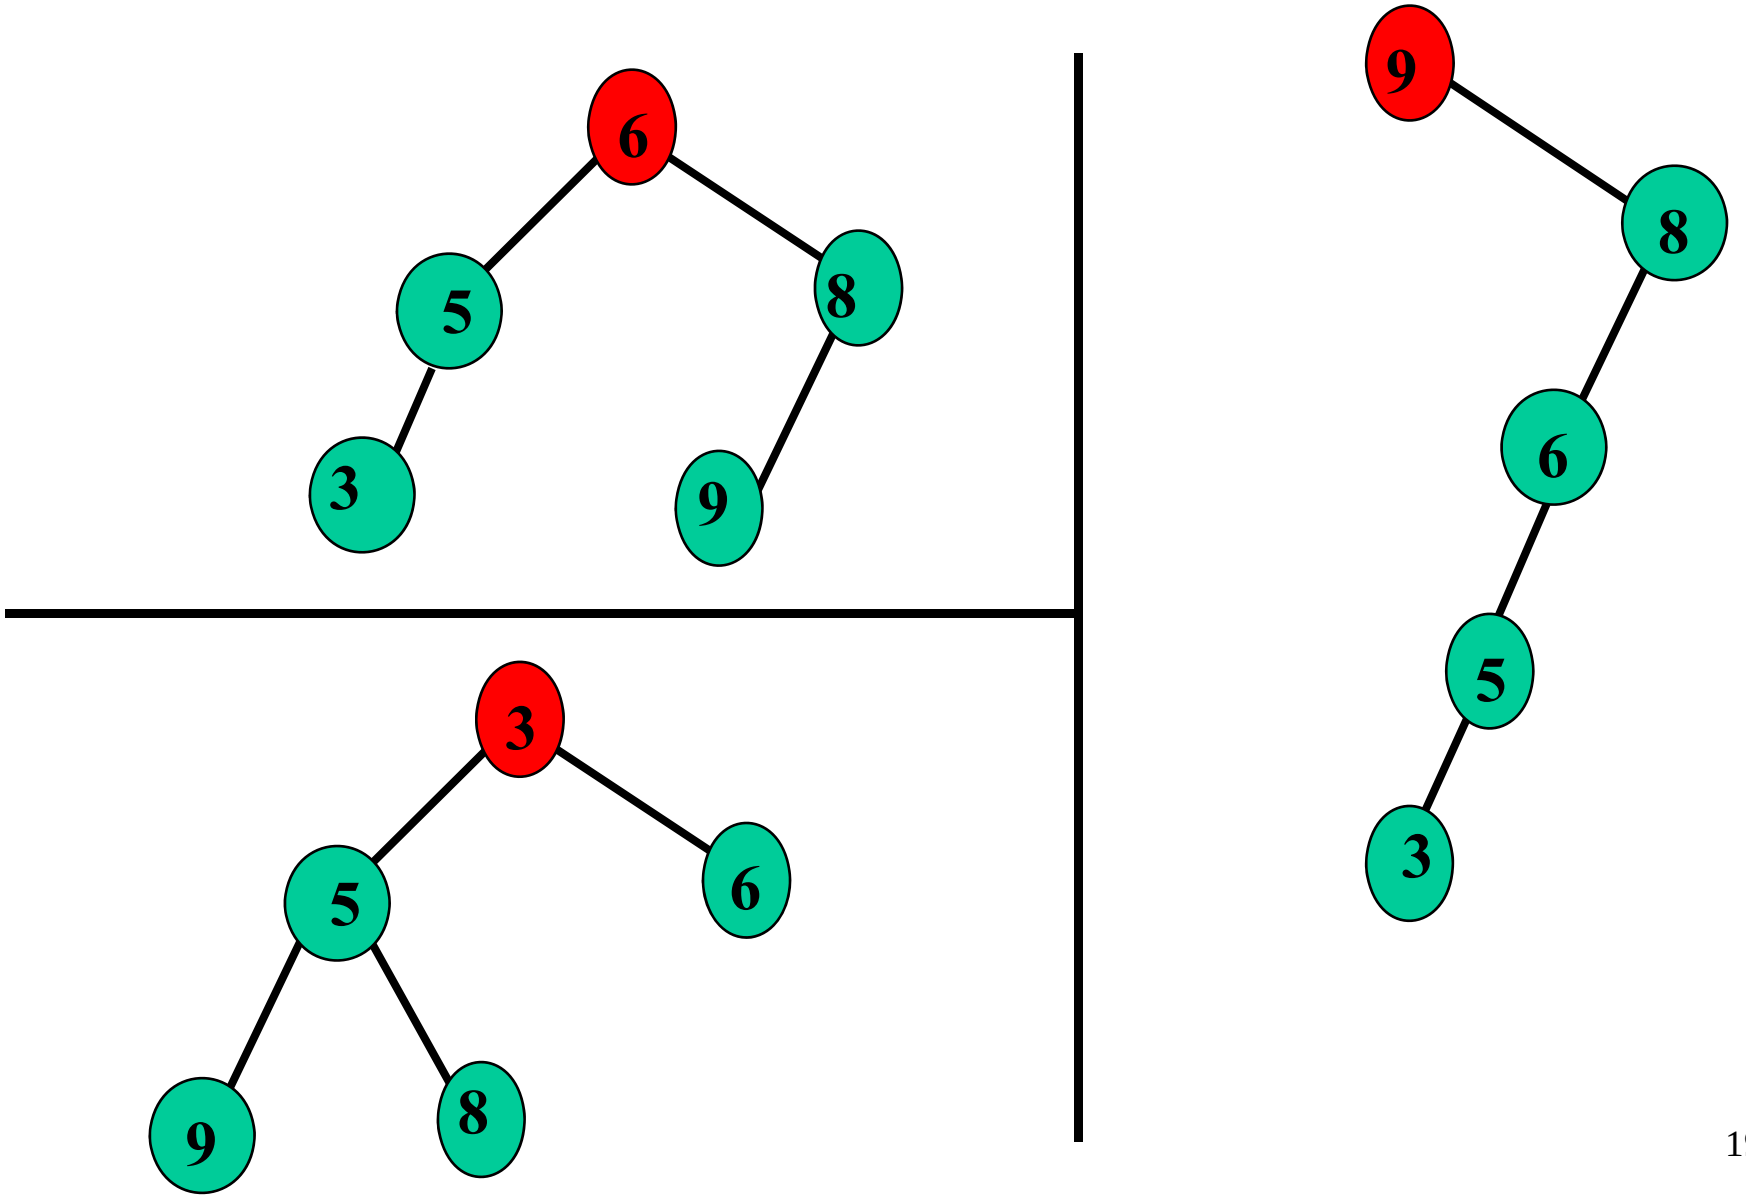

練習次の木が2分探索木であるか答えよ。

（1）

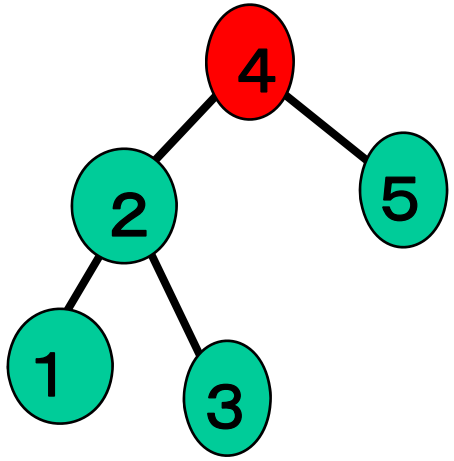

（2）

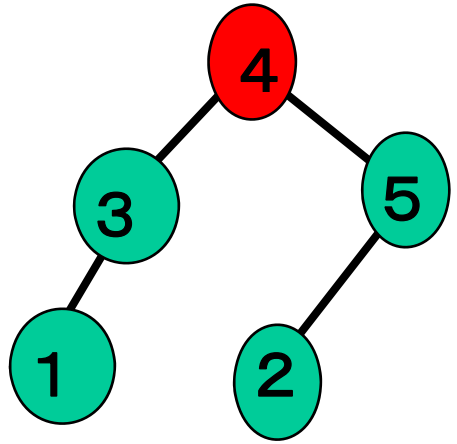

（3）

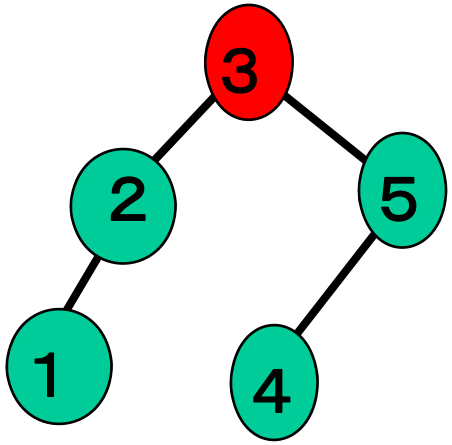

（4）

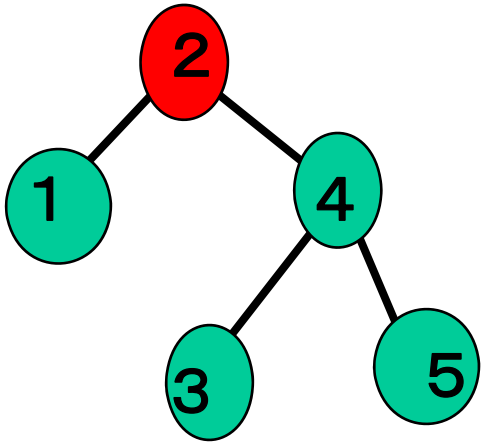

練習

- $\{1,2,3\}$ の3つのデータを2分探索木に保存するとき、2分探索木の形状を全て示せ。

２分探索木における探索

- ２分探索木の性質を利用する。
- ある頂点vのデータと、キーの値の大小関係を調べる。
- キーが小さければ、左の子孫を調べる。
  （左の子に再帰的に探索を繰り返す。）
  キーが大きければ、右の子孫を調べる。
- 根から探索を開始する。

（探索の概略は、配列における2分探索との類似点がある。）

2分探索木を用いた探索の実現

```
/*  2分探索木による探索*/
1. Node*  search(Node* node,double  key){
2.     if(node==NULL)return NULL;/*基礎*/
3.     else{ /*     帰納   */
4.         if(node->data==key)return node;/*発見*/
5.         else if(key<node->data){/*小さい方*/
6.             return search(node->left,key);
7.         }else if(node->data<key){/*大きい方*/
8.             return search(node->right,key);
9.         }
10.    }
11.}
```

呼び出し方

```
Node *pos;
pos=search(root,key);
```

参考2分探索の実現(再帰版)

```
/*  再帰版2分探索*/
1. int search(double k,int left,int right){
2.     int mid;
3.     if(left>right)return -1;/*基礎*/
4.     else{ /*     帰納   */
5.         mid=(left+right)/2;
6.         if(A[mid]==k)return mid;/*発見*/
7.         else if(k<A[mid]){/*小さい方*/
8.             return search(k,left,mid-1);
9.         }else if(A[mid]<k){/*大きい方*/
10.            return search(k,mid+1,right);
11.        }
12.    }
13.}
```

探索の動き1

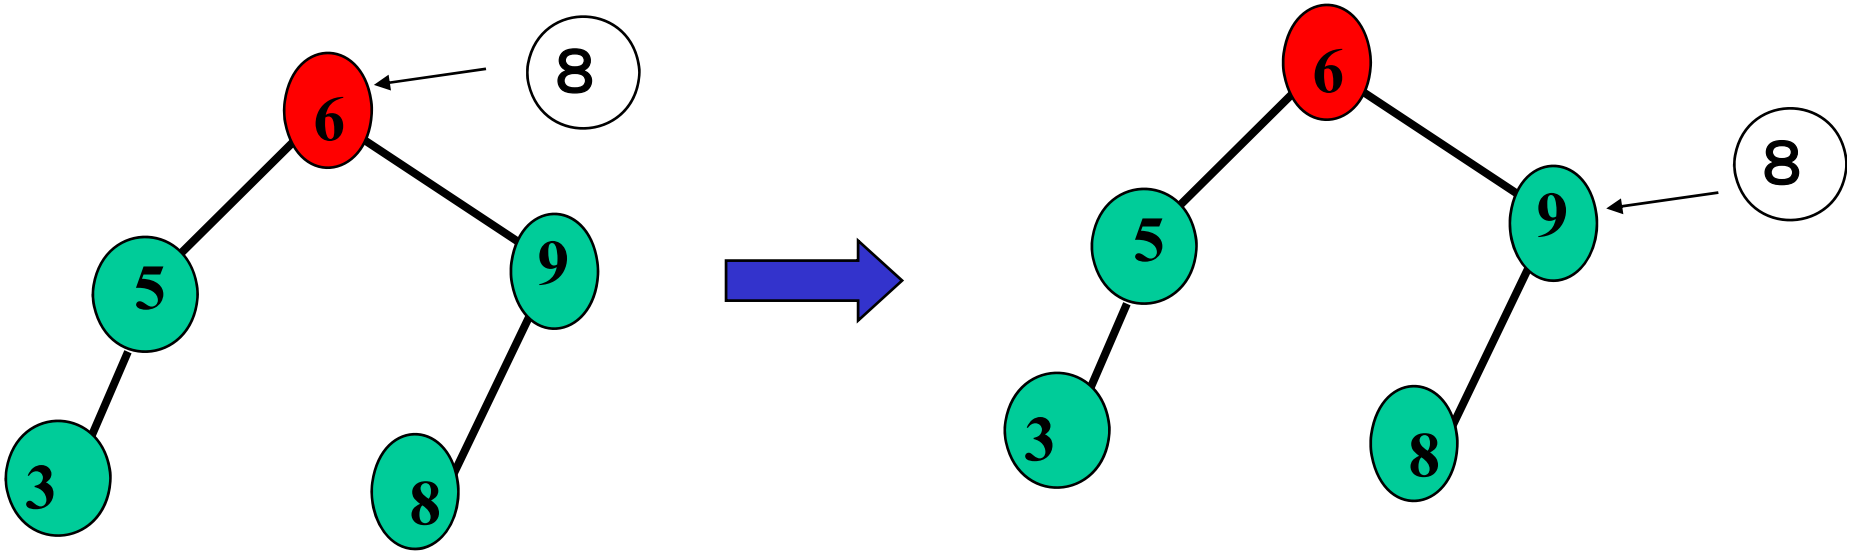

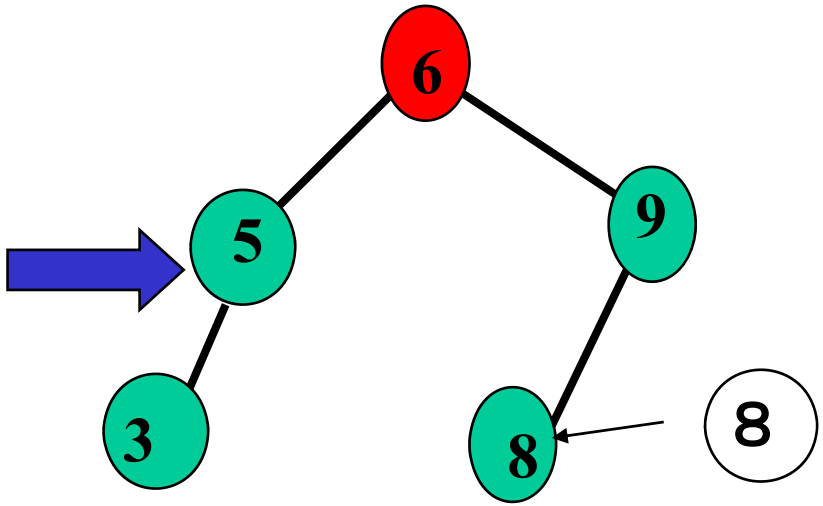

探索の動き2

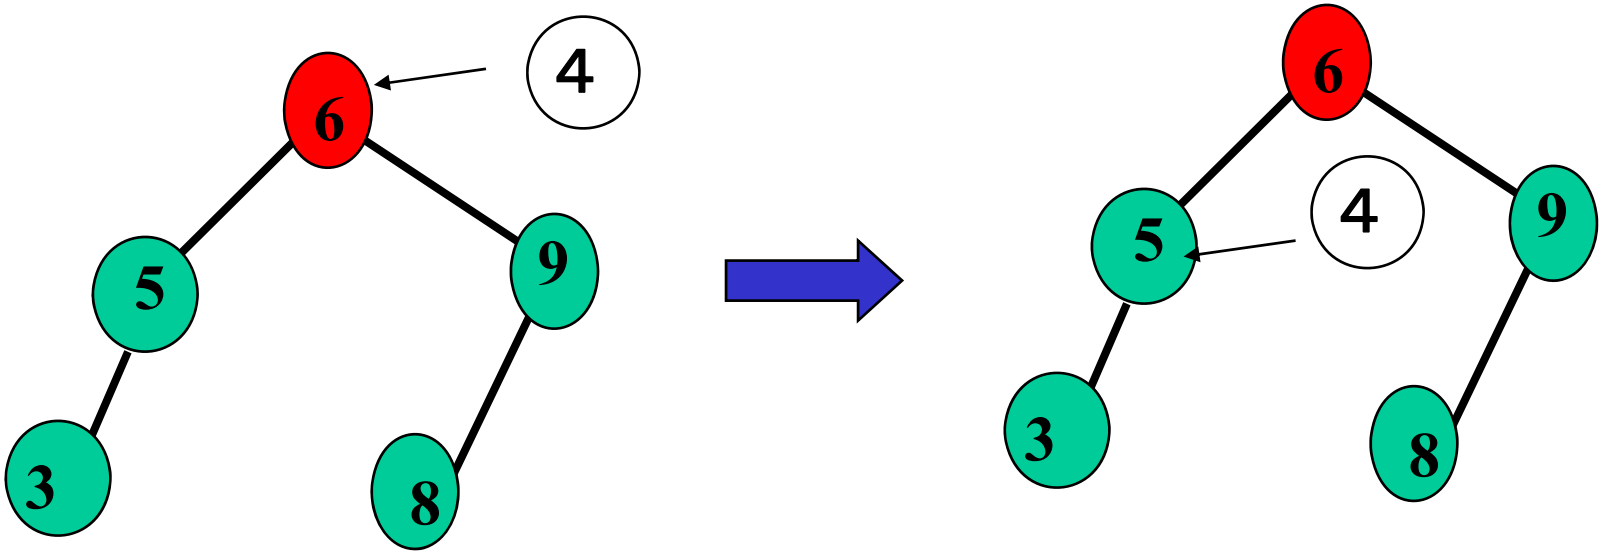

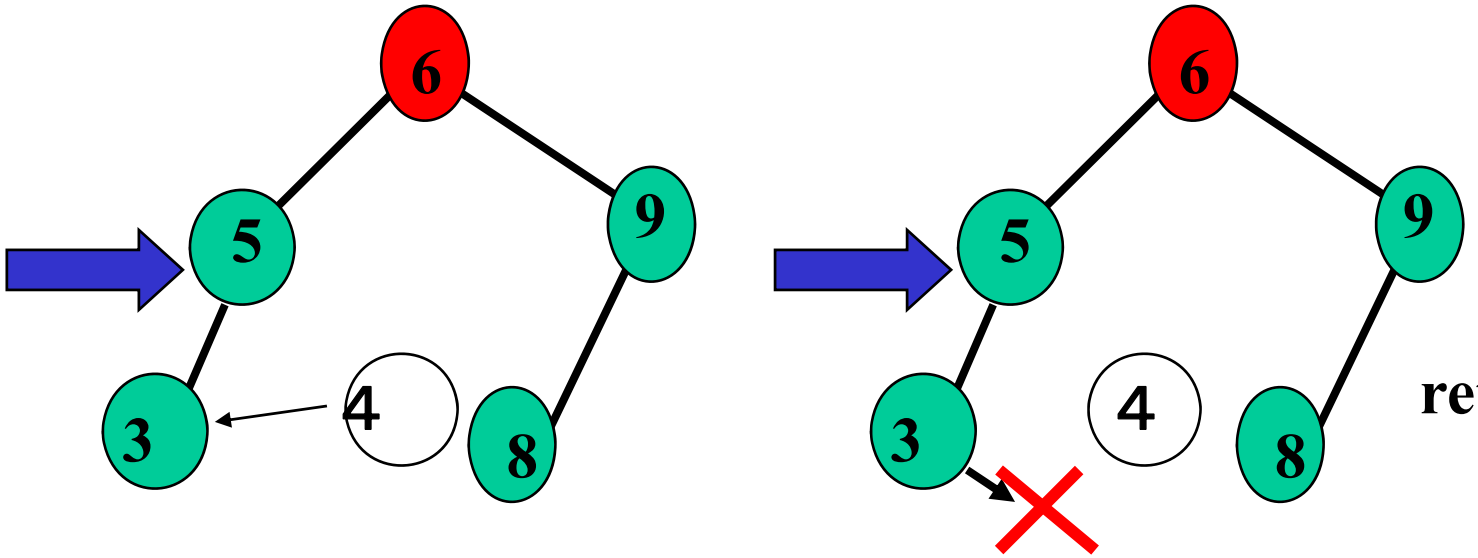

return NULL;

練習

下記のデータ構造に対して、7を探索するときの動作
および10を探索するときの動作を示せ。

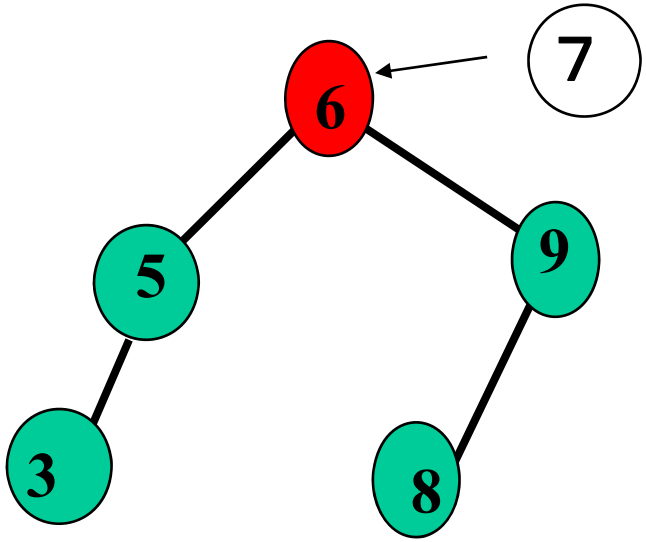

高さの高い2分探索木

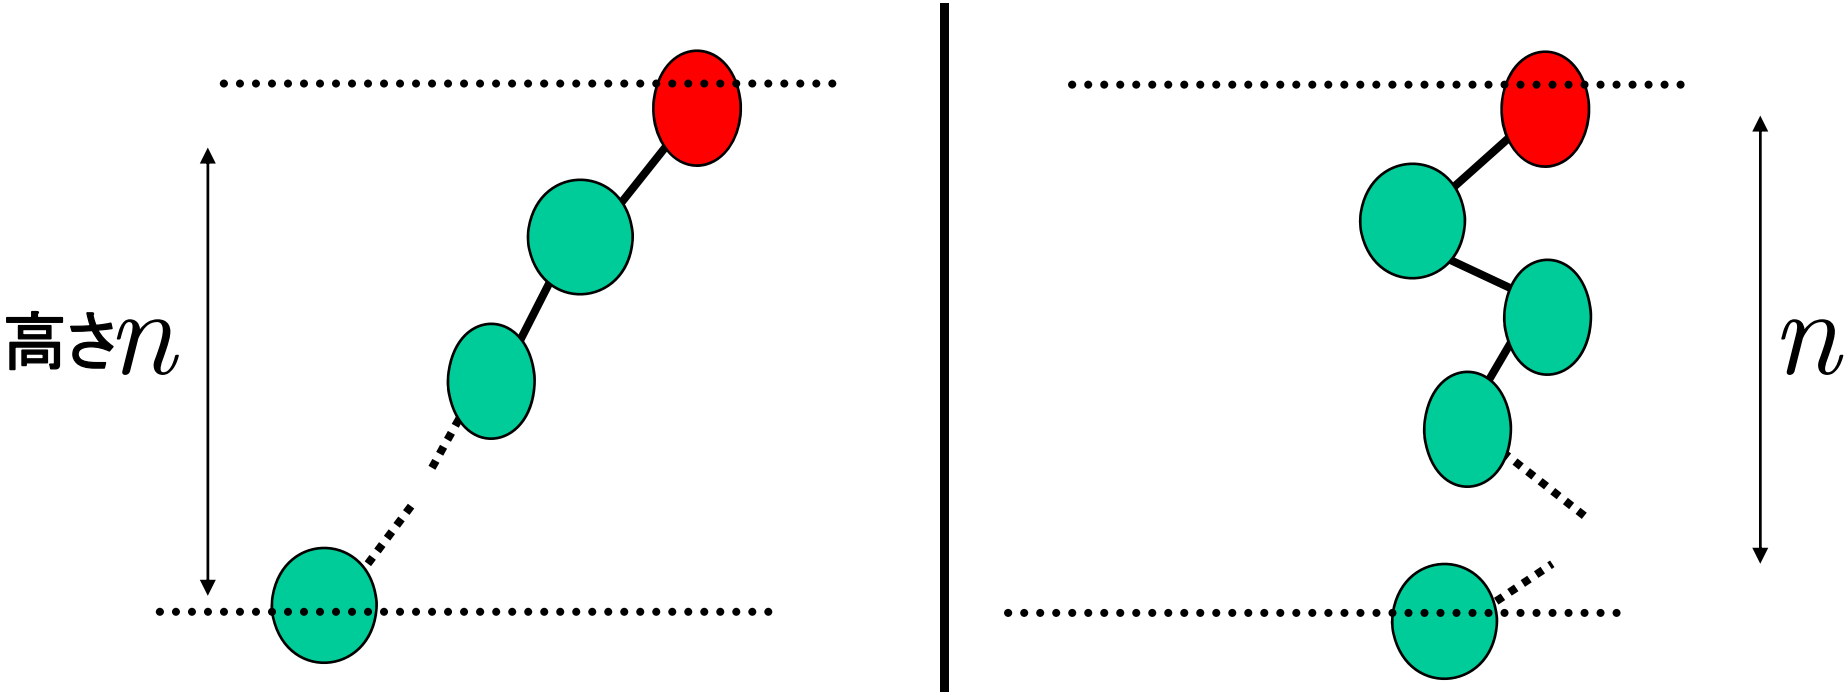

2分探索木の高さは、 n になるこもある。

高さの低い2分探索木

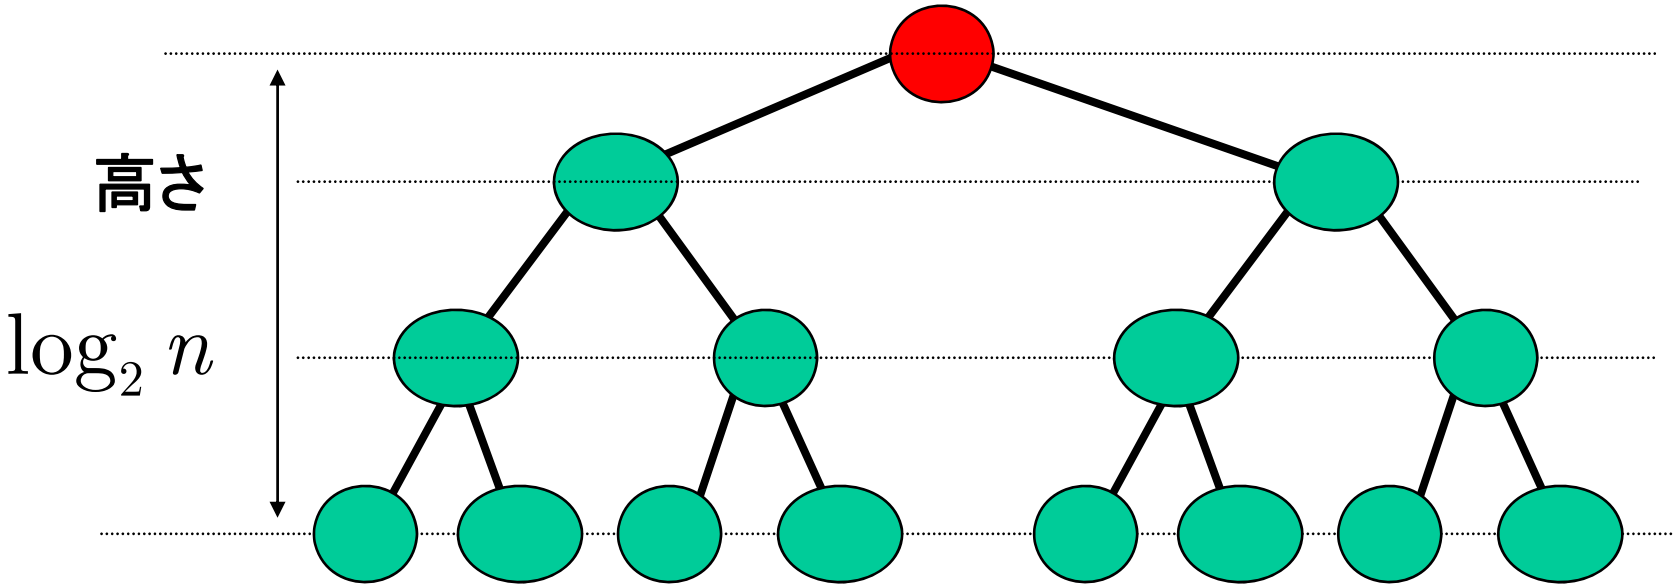

完全2分木状になれば、2分探索木の高さは
$\log_2 n$ である。

2分探索木における探索計算量

2分探索木における探索では、高さに比例した時間計算量が必要である。最悪の場合を考慮すると、高さが n の場合が存在する。
したがって、2分探索木における探索の最悪時間計算量は、

$$O(n)$$ 時間

である。この場合は線形探索と同じように探索される。

２分探索木への挿入

- 探索と同様に、挿入データvの２分探索木での位置を求める。
- 子供がない位置に、新しくvを子供として追加する。

2分探索木への挿入の実現1

```
/*  2分探索木への挿入位置を求める。親を返す（概略）*/
1. Node* find_pos(Node* node,double  value){
2.     if(value< node->data){/*左部分木への挿入*/
3.           if(node->left==NULL){/*左子が挿入場所*/
4.                 return node;
5.           }
6.           else  return find_pos(node->left,value);
7.     }
8.     else{/*左部分木への挿入*/
9.           if(node->right==NULL){/*右子が挿入場所*/
10.                return node;
11.          }
12.          else retrun find_pos(node->right,value);
13.    }
14.}
```

2分探索木への挿入の実現2

```
/*  2分探索木への挿入する。      */
1.  void insert(Node* root,double  value){
2.      Node* pos;/*挿入位置*/
3.      Node* new;/*挿入点*/
4.      new=(Node*)malloc(sizeof(Node));
5.      new->data=value;
6.      new->left=NULL;
7.      new->right=NULL;
8.      pos=find_pos(root,value);
9.     if((value< pos->data)&&(pos->left==NULL))
10.             pos->left=new;
11.    }
12.    else if((pos->data<value)&&(pos->right==NULL))
13.             pos->right=new;
14.    }
15.    return;
16. }
```

挿入の動き1

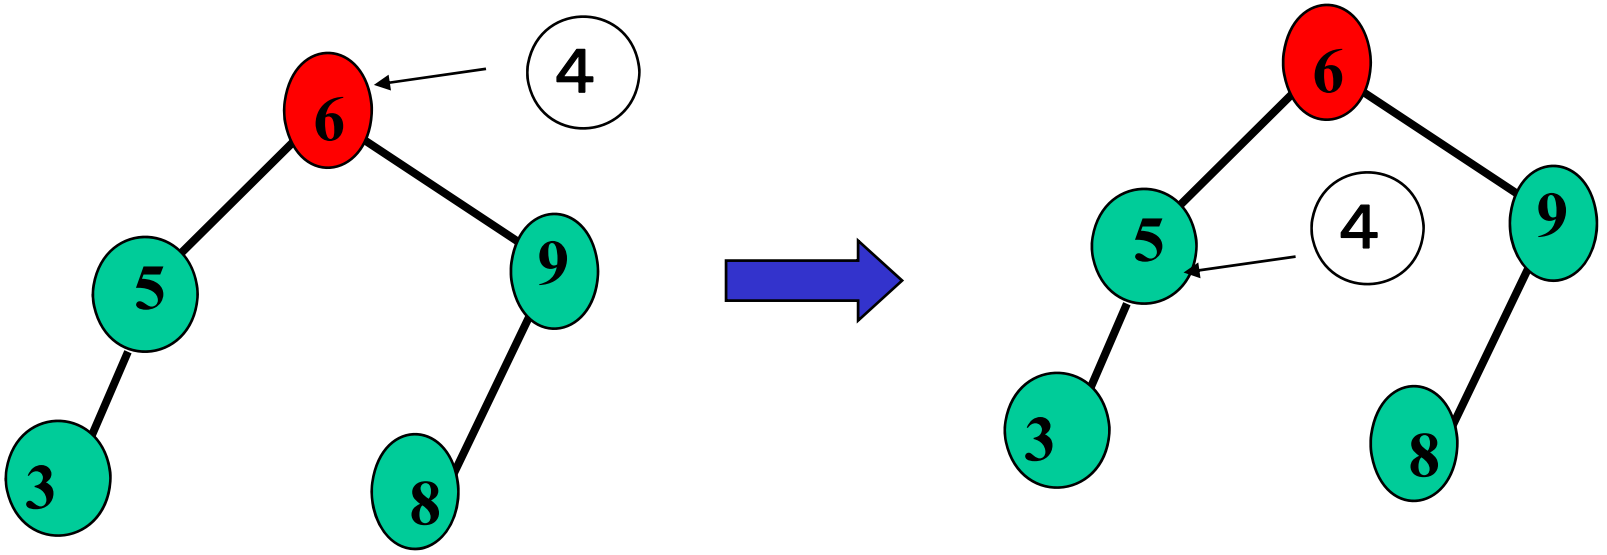

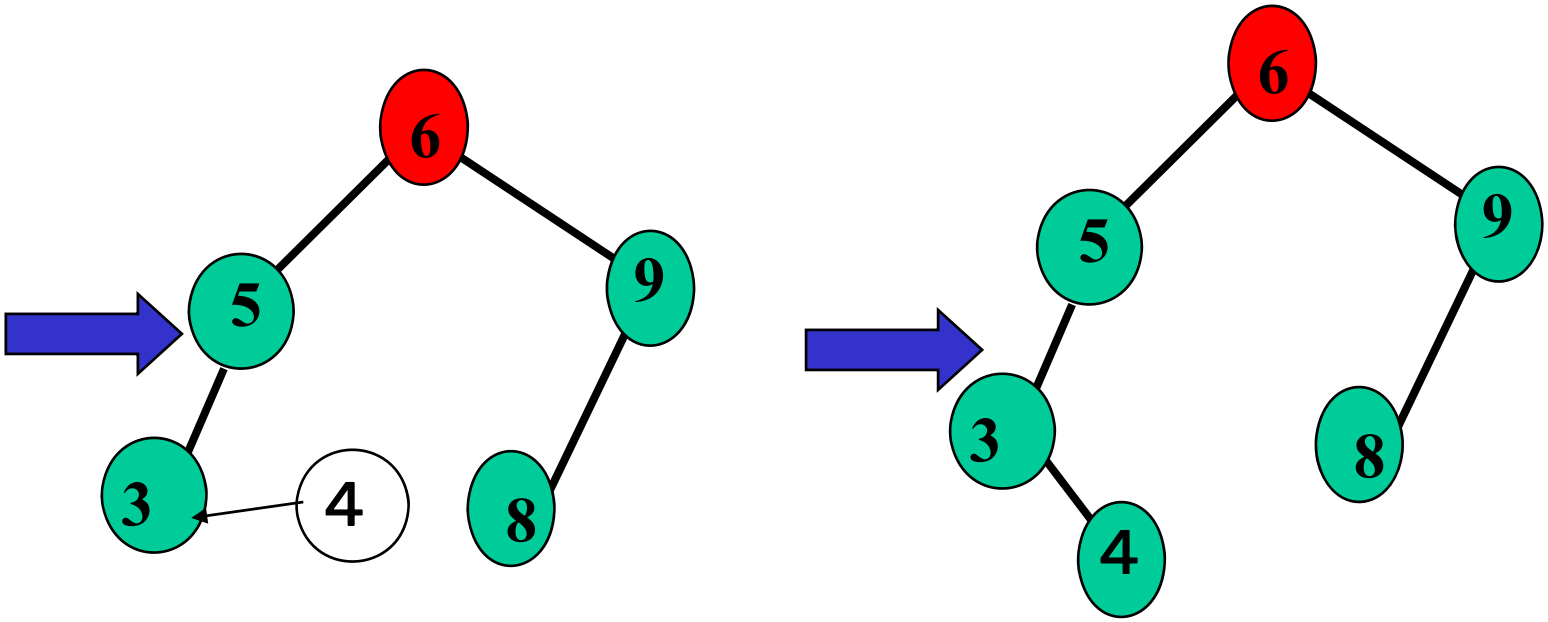

挿入の動き2

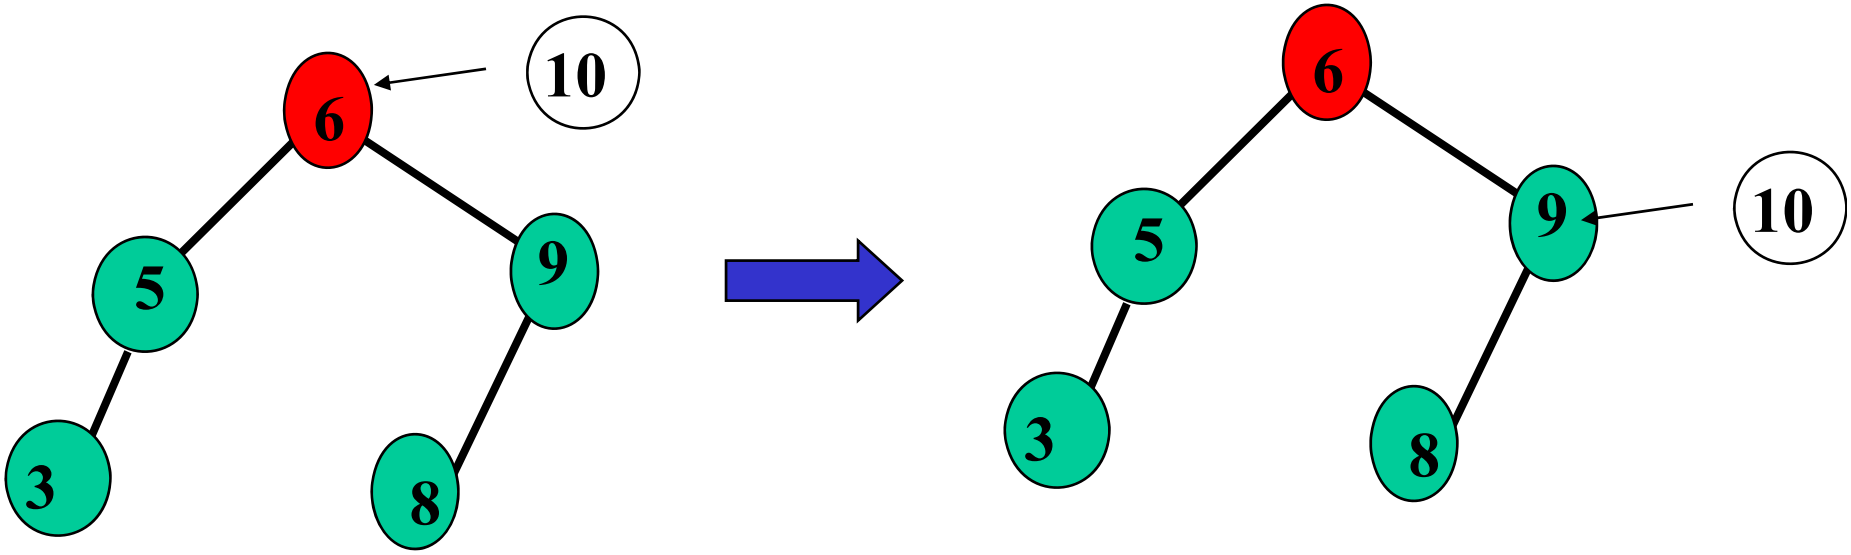

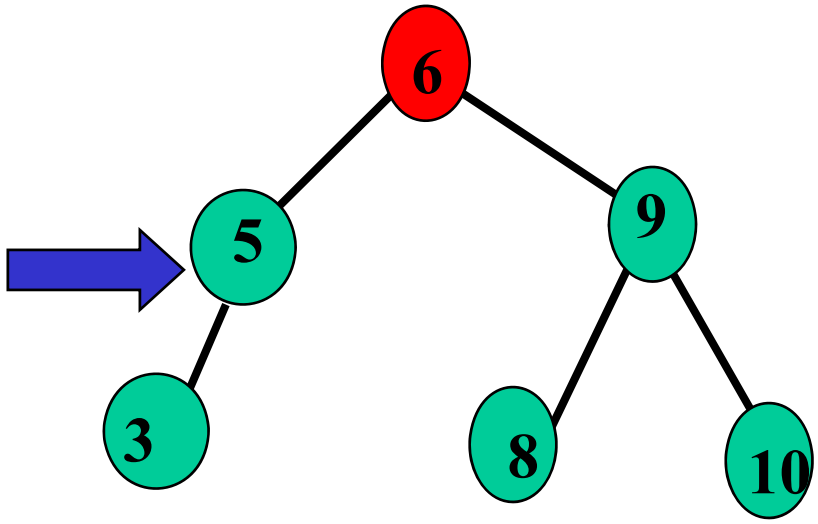

挿入の最悪時間計算量

挿入には、最悪、2分探索木の高さ分の時間
計算量が必要である。したがって、

$O(n)$ 時間

である。

練習

次の2分探索木に以下で示す要素を順に挿入せよ。

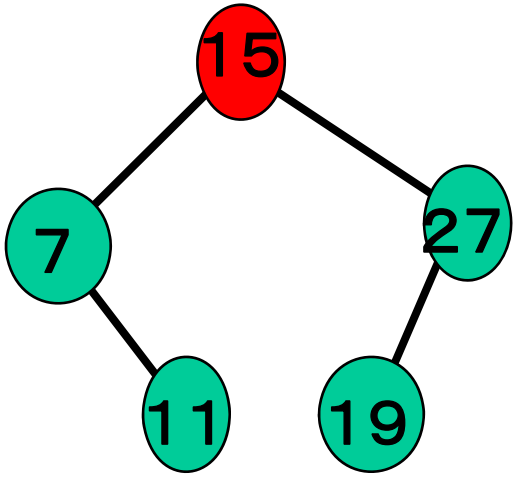

5→12→20→23→10

２分探索木からの削除

- 削除する点を根とする部分木中の、最大値あるいは最小値で置き換える。
- 削除は、少し煩雑なので、コードは示さずに、動作だけを示す。

削除動作１（葉の削除）

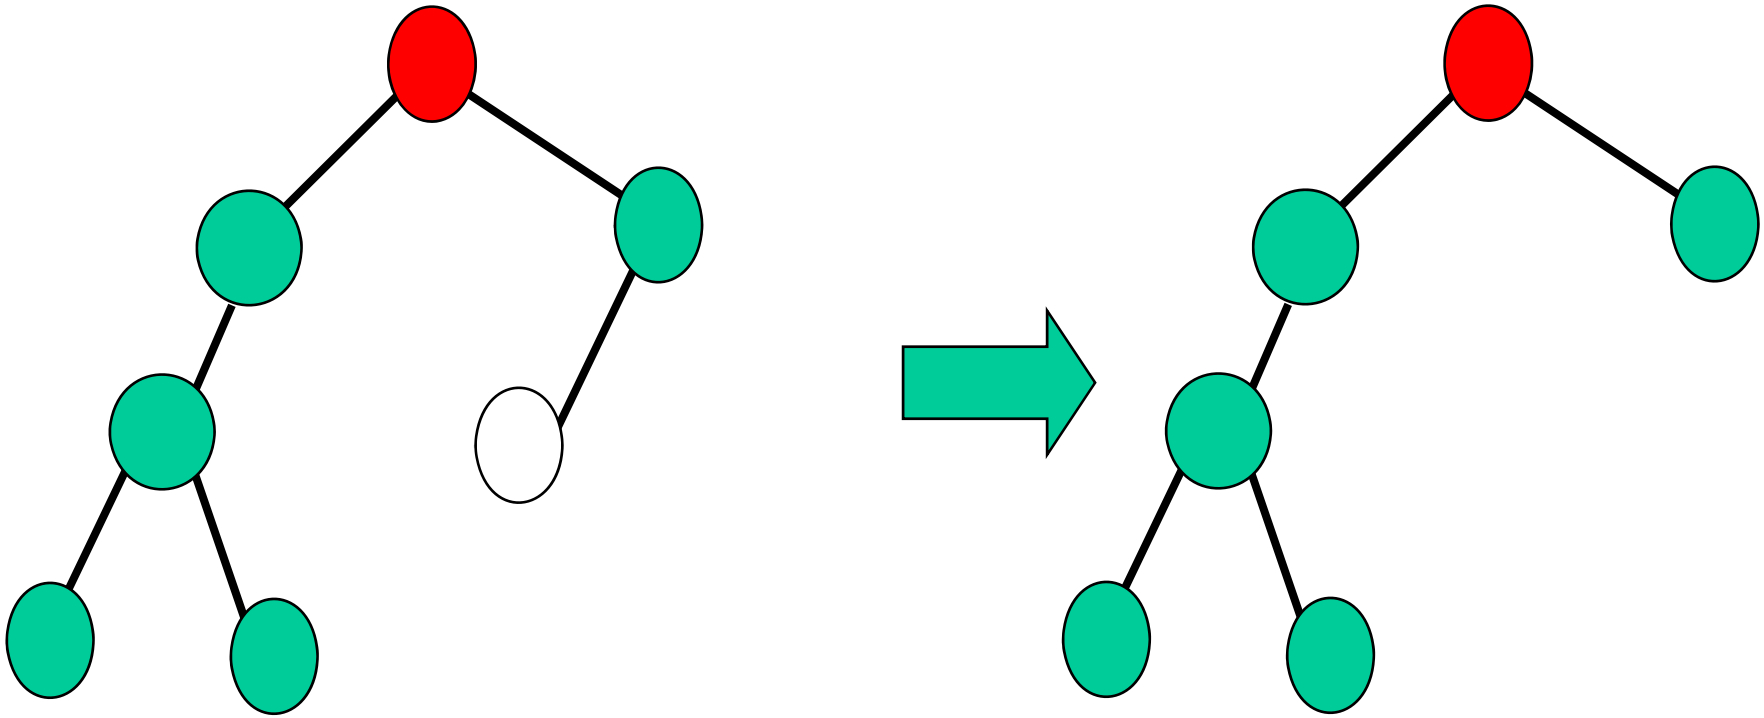

単に削除すればよい。

削除動作２（子供が一つの場合の削除）

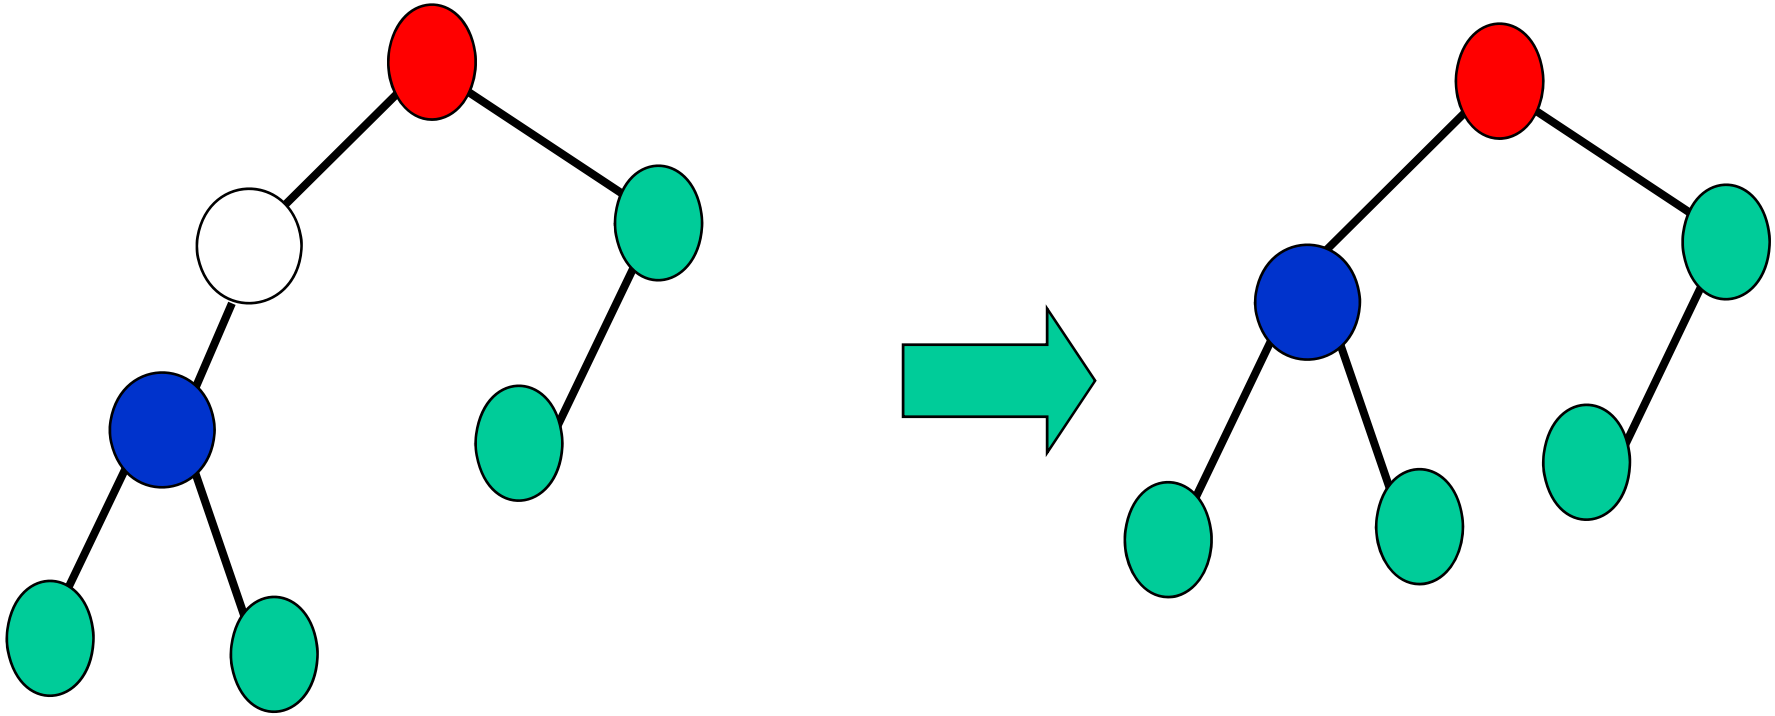

唯一の子供を、親にリンクする。

削除動作3（子供が2つの場合の削除）

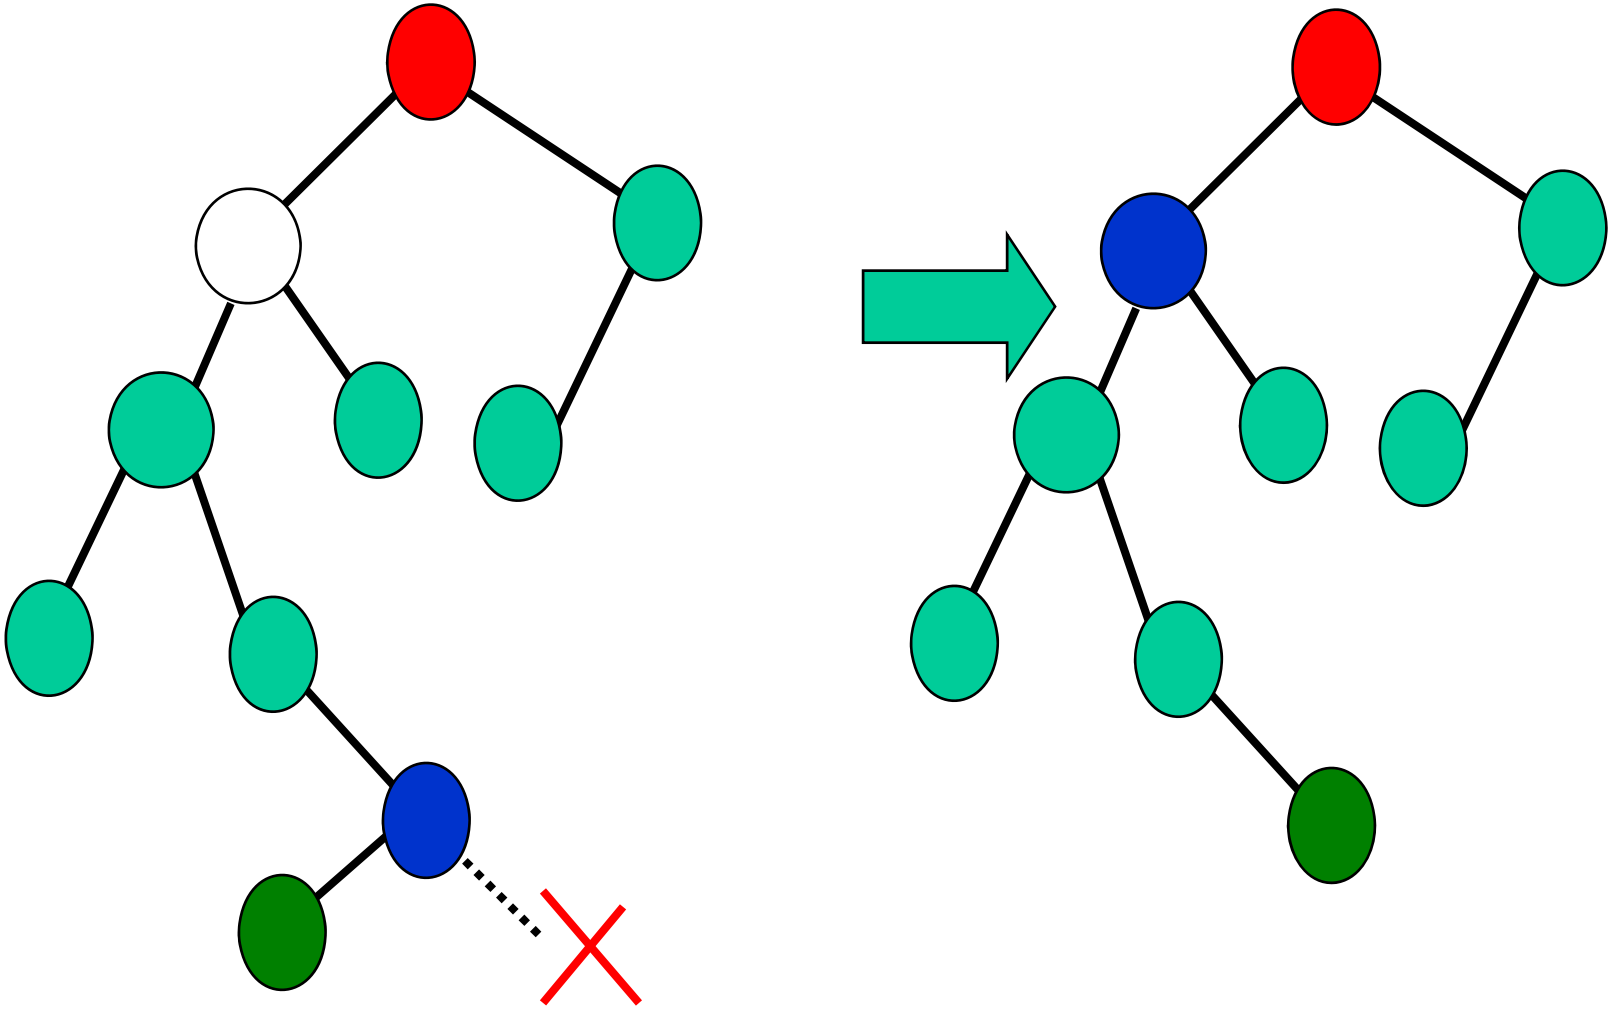

左部分木の最大値（あるいは右部分木最小値）を求め更新する。

練習

次のから2分探索木から、以下で示す順序に要素を削除せよ。
ただし、2つの子がある点が削除される場合には、
右部分木の最小値を用いて更新すること。

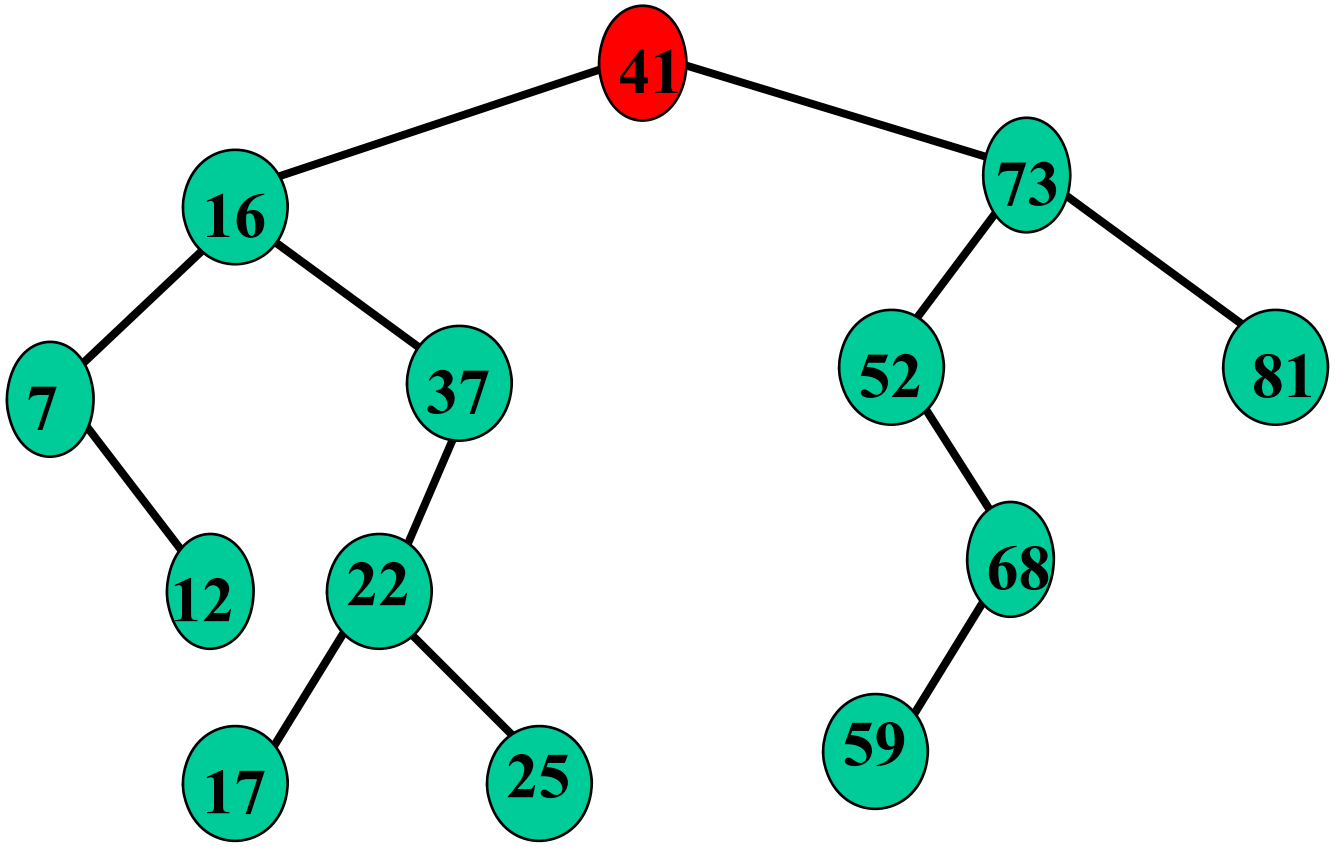

12→37→73→68→22

削除の最悪時間計算量

挿入には、最悪、2分探索木の高さ分の時間
計算量が必要である。したがって、

$O(n)$ 時間

である。

2分探索木における各操作の平均時間量解析

- 各操作は、2分探索木の高さに比例する時間量で行える。
- ここでは、空木（データの無い木）からはじめて、n 個のデータをランダムに挿入して作成される2分探索木の高さ（平均の深さ）を評価する。

ここでのランダムとは、$n!$ 個の順列が均等におきると仮定して、その順列に従って挿入することである。

次のように記号を定義する。

$D(n) = (n$要素の２分探索木の平均の深さ$)$

この $D(n)$ を求めるために、ランダムに挿入する際の比較回数 $C(n)$ を考察する。ここで、

$C(n) = (n$要素の２分探索木を構成するときの平均比較回数$)$

である。

このとき、各頂点vに対して、作成時に深さ－１回の比較を行っていることに注意すると、次の関係が成り立つ。

$$D(n) - 1 \simeq \frac{1}{n} C(n)$$

平均の深さ

作成時の平均比較総数

イメージ

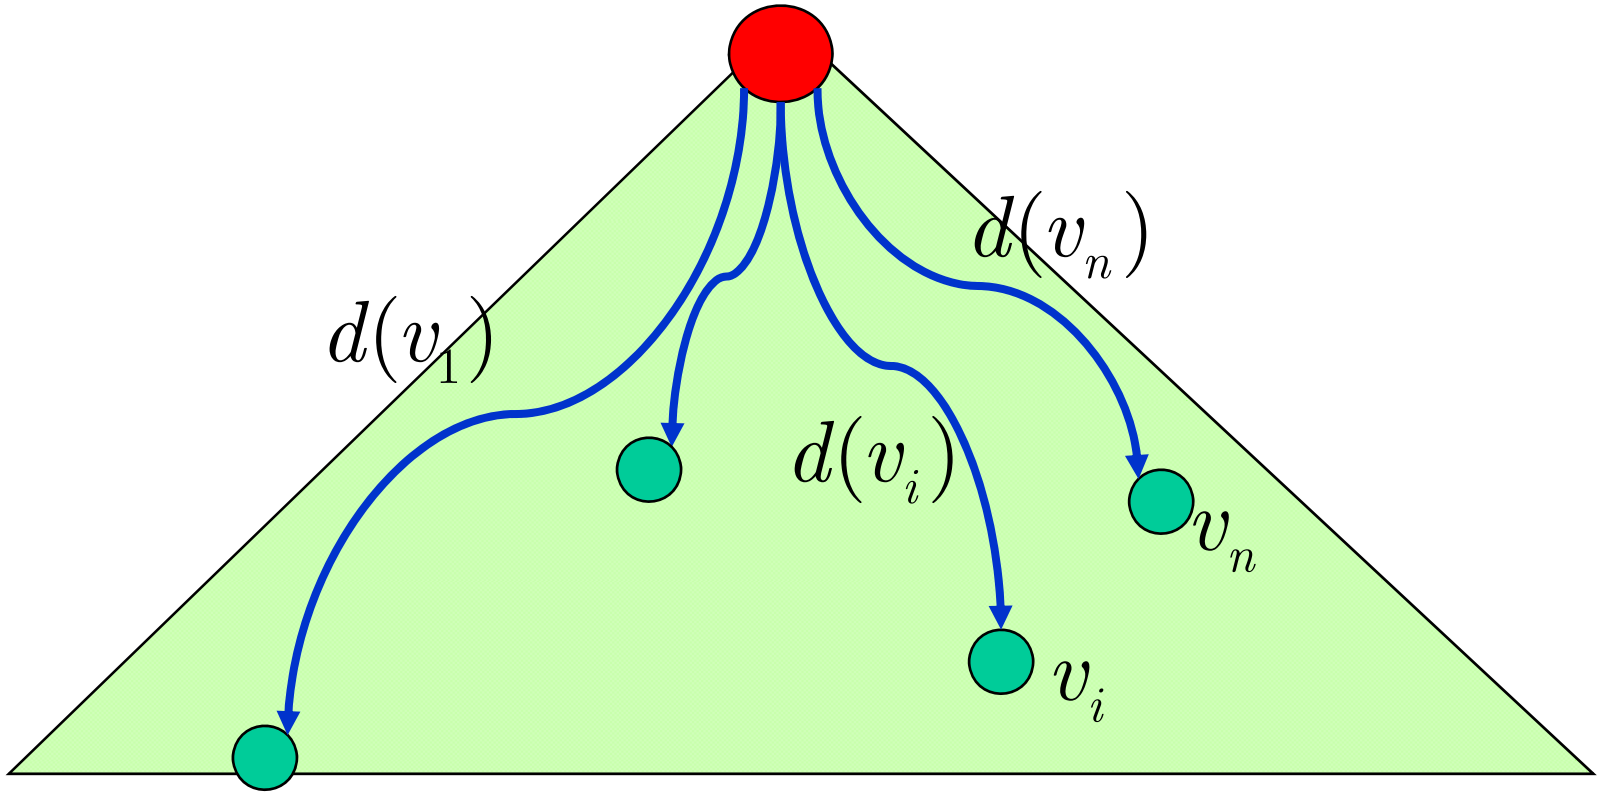

$d(v_i)$：点v_iにおける深さ

$$D(n) = \frac{1}{n}\sum_{i=1}^{n} d(v_i)$$

$$D(0) = 0, D(1) = 0$$

次にデータの挿入される順に、$x_1, x_2, \cdots, x_n$
と定める。

このとき、x_1 は根におかれ、2分探索木完成までには、
$n-1$ 回の比較が行われる。

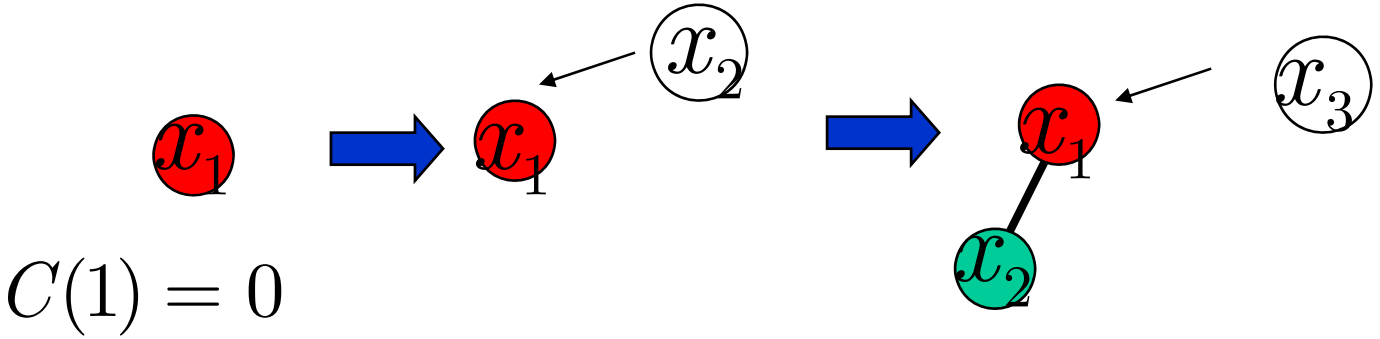

$C(1) = 0$

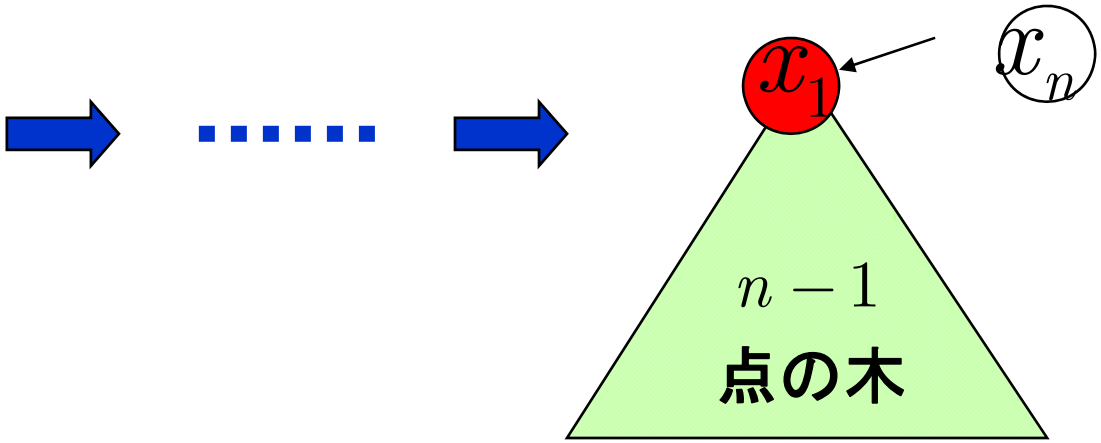

一方、 x_1 の大きさが i 番目であるとする。

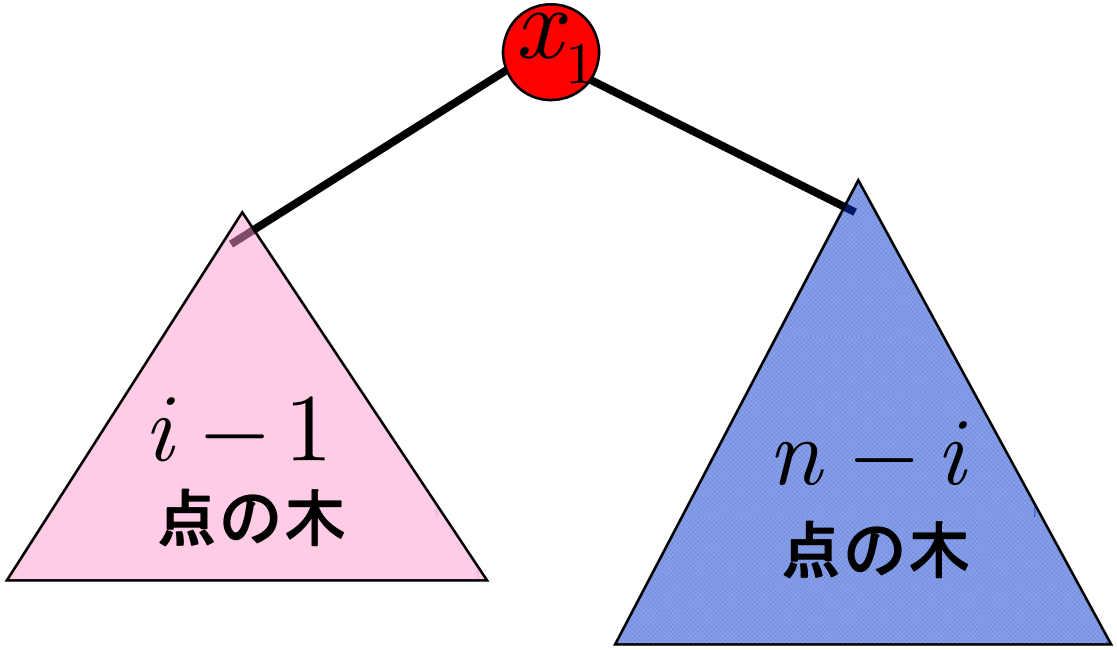

ランダムなので、順位 i は1からnの全て均等におきる
ことに注意する。

これらのことを考慮すると、2分探索木の構成時における
平均の総比較回数は、次の漸化式を満たす。

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

根との比較数

左部分木の
平均比較総数

右部分木の
平均比較総数

ランダムなので、全ての順位が
均等に起こる。全ての場合の
総和を求めて、nで割れば、平
均比較総数となる。

クイックソートの平均
時間計算量が満たす
べき漸化式とまったく
同じである。

忘れた人のために、もう一度解く。

$$C(n) = \frac{1}{n}\sum_{i=1}^{n}\left(n-1+C(i-1)+C(n-i)\right)$$

$$\therefore\ nC(n) = n(n-1) + 2\sum_{i=0}^{n-1} C(i) \quad \cdots\cdots①$$

①に、$n-1$　を代入して、

$$(n-1)C(n-1) = (n-1)(n-2) + 2\sum_{i=0}^{n-2} C(i) \quad \cdots\cdots②$$

①－②

$$nC(n) - (n-1)C(n-1)$$

$$= n(n-1) - (n-1)(n-2) + 2C(n-1)$$

$$\therefore\ nC(n) - (n+1)C(n-1) = n(n-1) - (n-1)(n-2) \quad \cdots\cdots③$$

③のすべての項を $n(n+1)$ で割ってまとめる。

$$\therefore \frac{C(n)}{n+1} - \frac{C(n-1)}{n} = \frac{n(n-1)}{n(n+1)} - \frac{(n-1)(n-2)}{n(n+1)}$$

$$\therefore \frac{C(n)}{n+1} - \frac{C(n-1)}{n} \leq \frac{2}{n}$$

辺々加えてまとめる。

$$\therefore \frac{C(n)}{n+1} \leq 2(H_{n-1} - 1)(\because C(1) = 0)$$

$$\therefore C(n) \leq 2n \log_e n$$

以上、より n 点をランダムにして2分探索木を構築するための総比較回数（平均時間計算量）は、 $O(n \log n)$ である。

ここで、n 点の2分探索木における各頂点の平均深さと、
n 点の2分探索木構築する平均比較総数の関係を思い出す。

$$D(n) - 1 \simeq \frac{1}{n} C(n)$$

この関係式より、

$$D(n) = O(\log n)$$

である。

2分探索木における各操作に必要な平均時間計算量は、
平均深さ $D(n)$ に比例すると考えられる。したがって、
n 点からなる2分探索木における「探索」「挿入」「削除」の
各操作を行うための平均時間計算量は、

$$O(\log n)$$

である。

2分探索木のまとめ

	最悪 時間計算量	平均 時間計算量
探索	$O(n)$	$O(\log n)$
挿入	$O(n)$	$O(\log n)$
削除	$O(n)$	$O(\log n)$
構築	$O(n^2)$	$O(n \log n)$

n : データ数

2分探索木と整列

2分探索木を用いても、ソートを行うことができる。

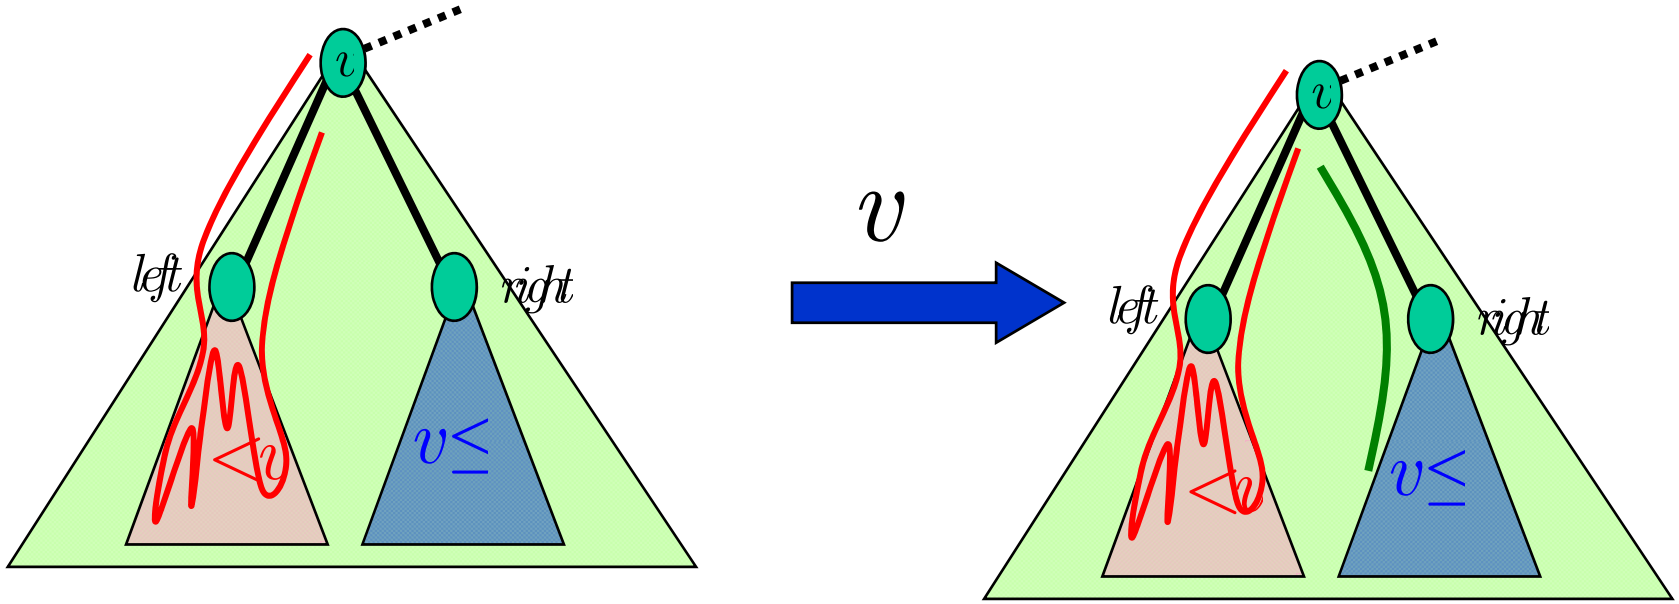

左優先で木をなぞったとき、
点 v において　v の左部分木のすべてをなぞったら、
v を出力し、右の部分木をなぞるようにすればよい。

２分探索木と整列

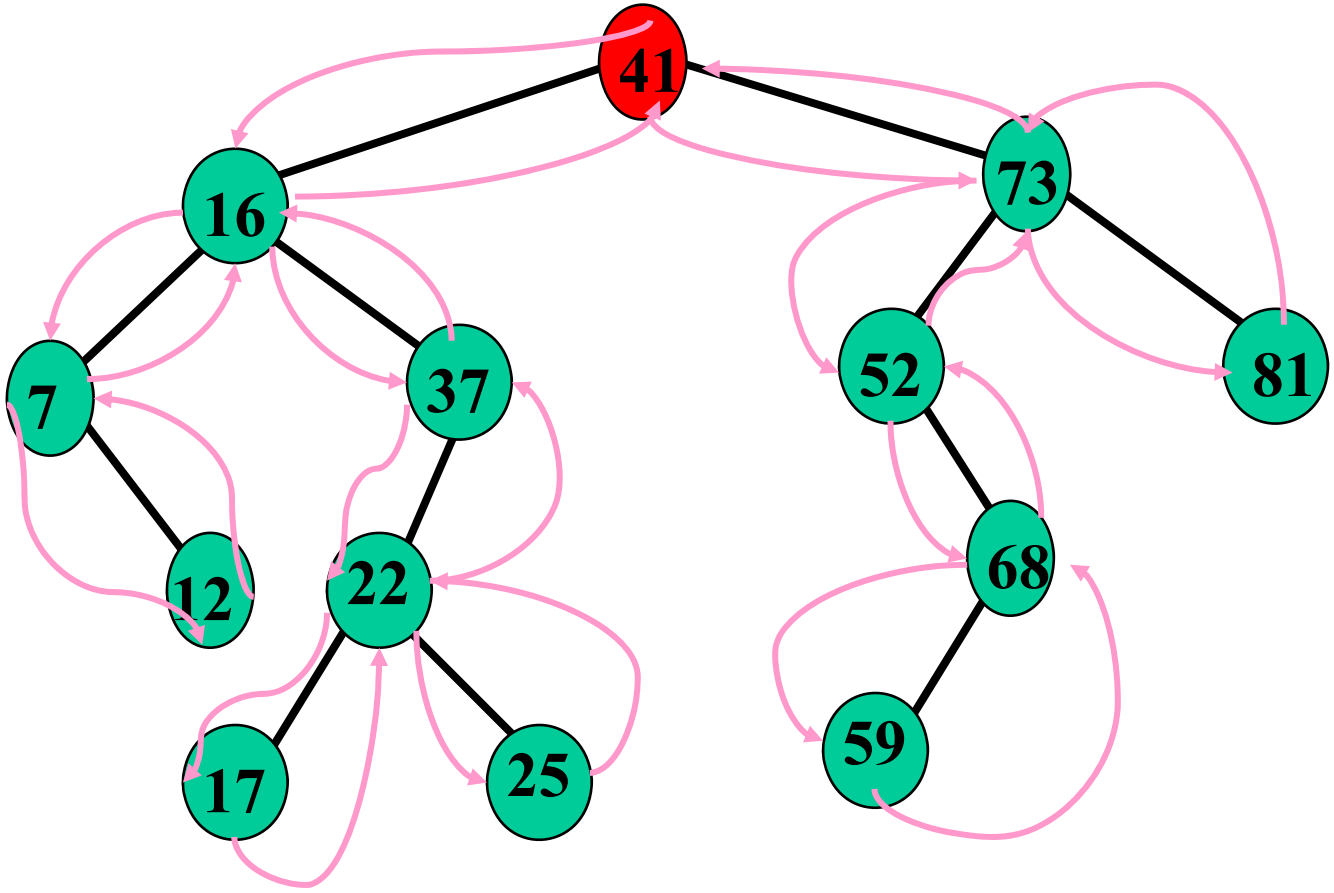

２分探索木とヒープ（イメージ）

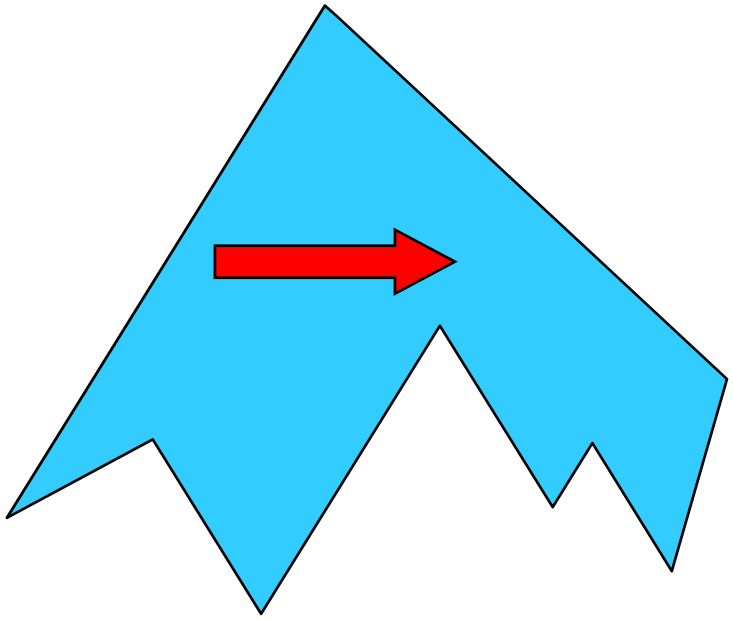

２分探索木

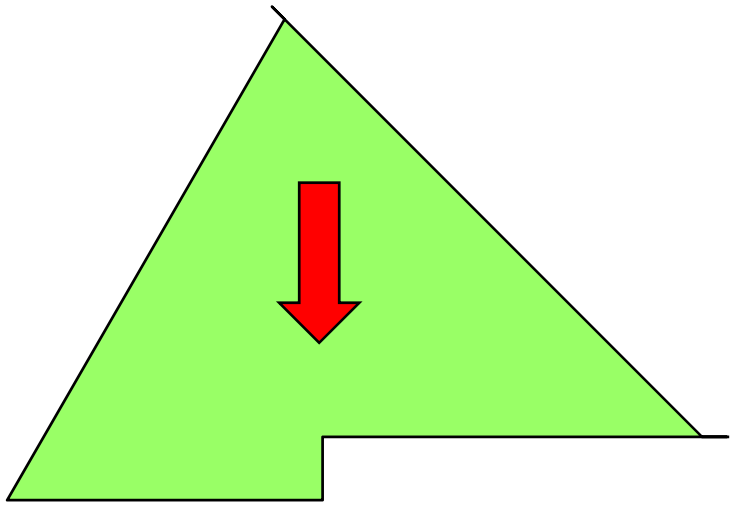

ヒープ

大きくなる方向

７－３．高度な木
（平衡木）

- ＡＶＬ木

  平衡2分木。回転操作に基づくバランス回復機構により平衡を保つ。

- Ｂ木

  平衡多分木。各ノードの分割、併合操作により平衡を保つ。

2分探索木の問題点

- 高さが $O(n)$ になることがある。
- 各操作の最悪計算量は、 $O(n)$ 時間になってしまう。

（平均計算量は、$O(\log n)$ 時間である。）

最悪計算時間でも$O(\log n)$ 時間にしたい。

n：保存データ数

平衡木とは

- 根から、葉までの道の長さが、どの葉に対してもある程度の範囲にある。

  （厳密な定義は、各々の平衡木毎に定義される。概して、平衡木の高さは、$O(\log n)$である。）
- 平衡木に対する各操作は、最悪計算時間で　$O(\log n)$　時間にできることが多い。

平衡木のイメージ

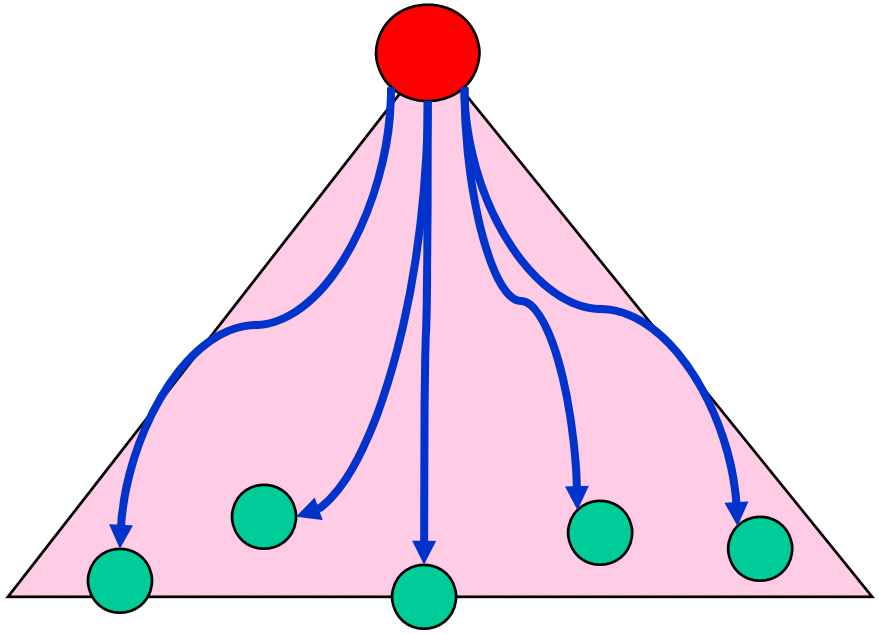

ほぼ完全（2分）木に近い形状をしている。

葉までの経路長がほぼ等しい。

AVL木

- Adel'son-Vel'skiiとLandisが考案したデータ構造
- 探索、挿入、削除の操作が最悪でも、
  $O(\log n)$時間で行える2分探索木の一種。
- 全てのノードにおいて、左部分木と右部分木の高さの差が1以内に保つ。

最後の、性質を保つために、バランス回復操作を行う。
また、この性質より、高性能となる。

様々なAVL木

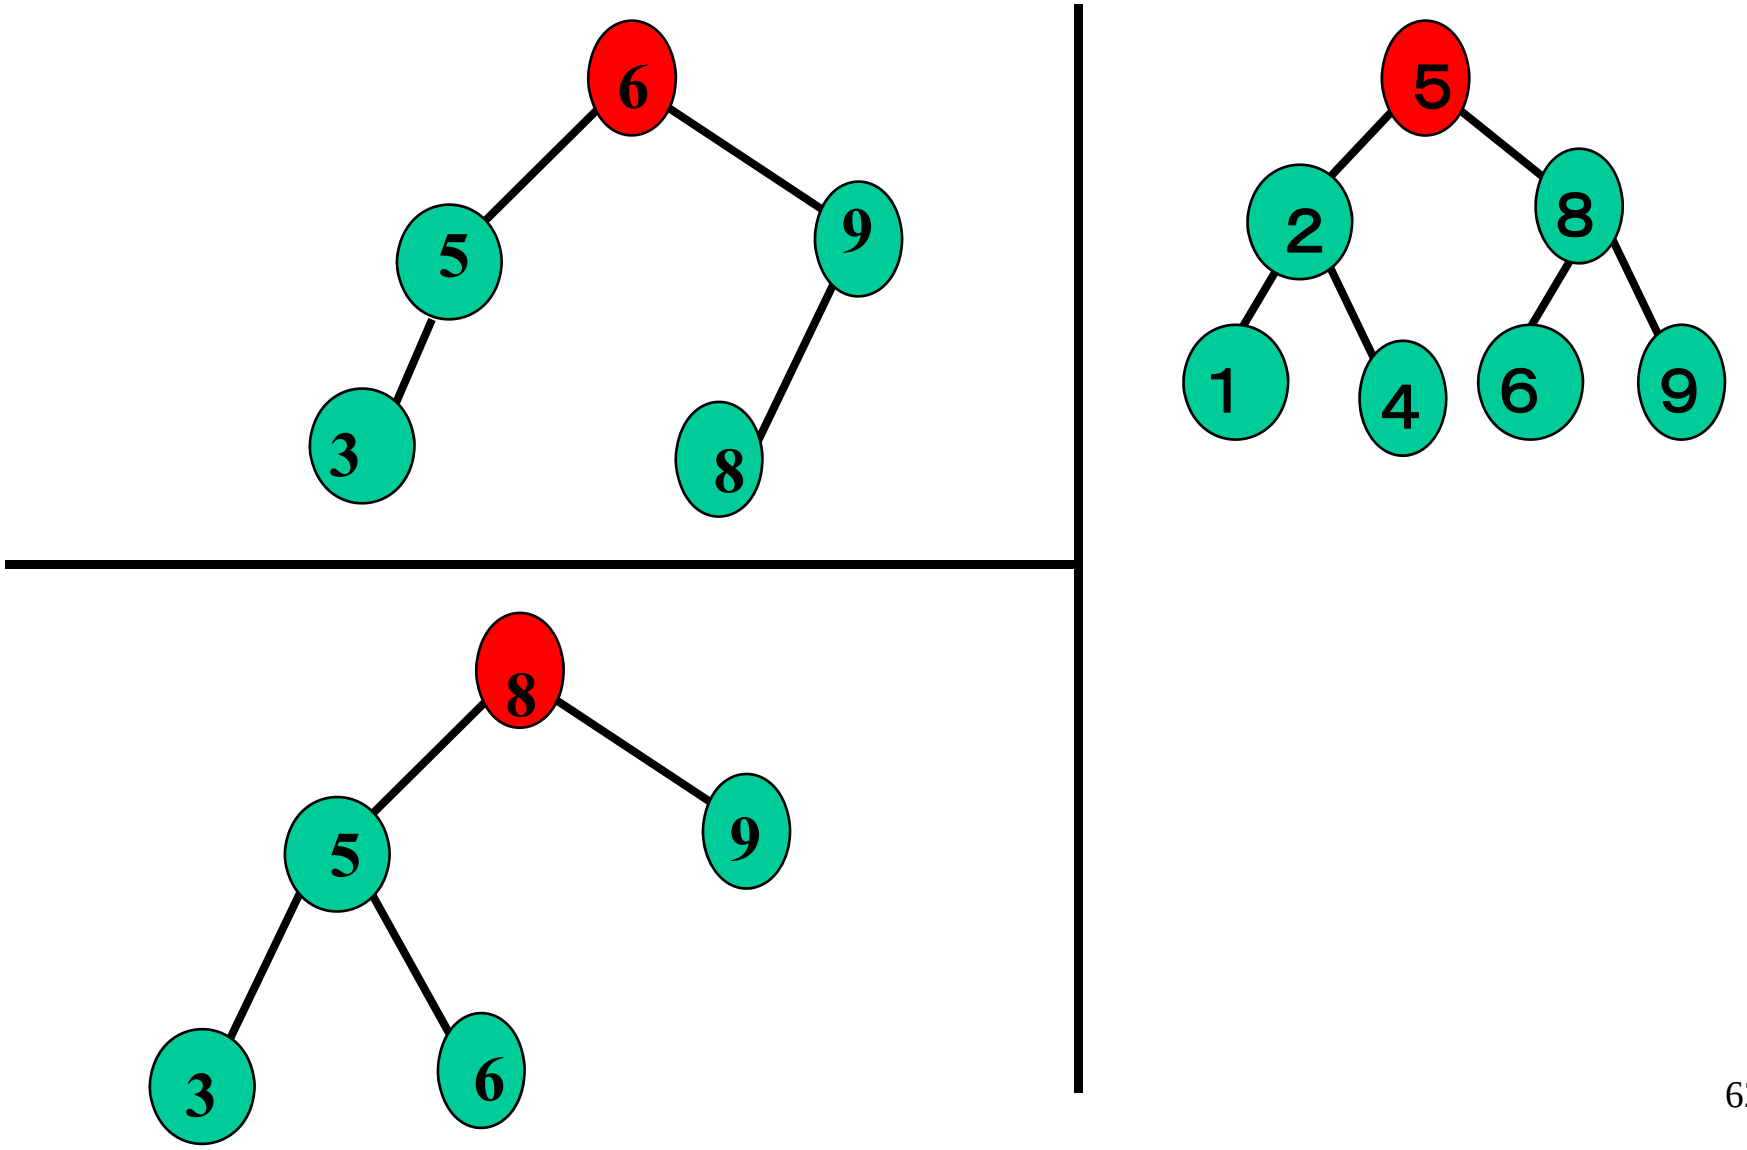

AVL木でない例

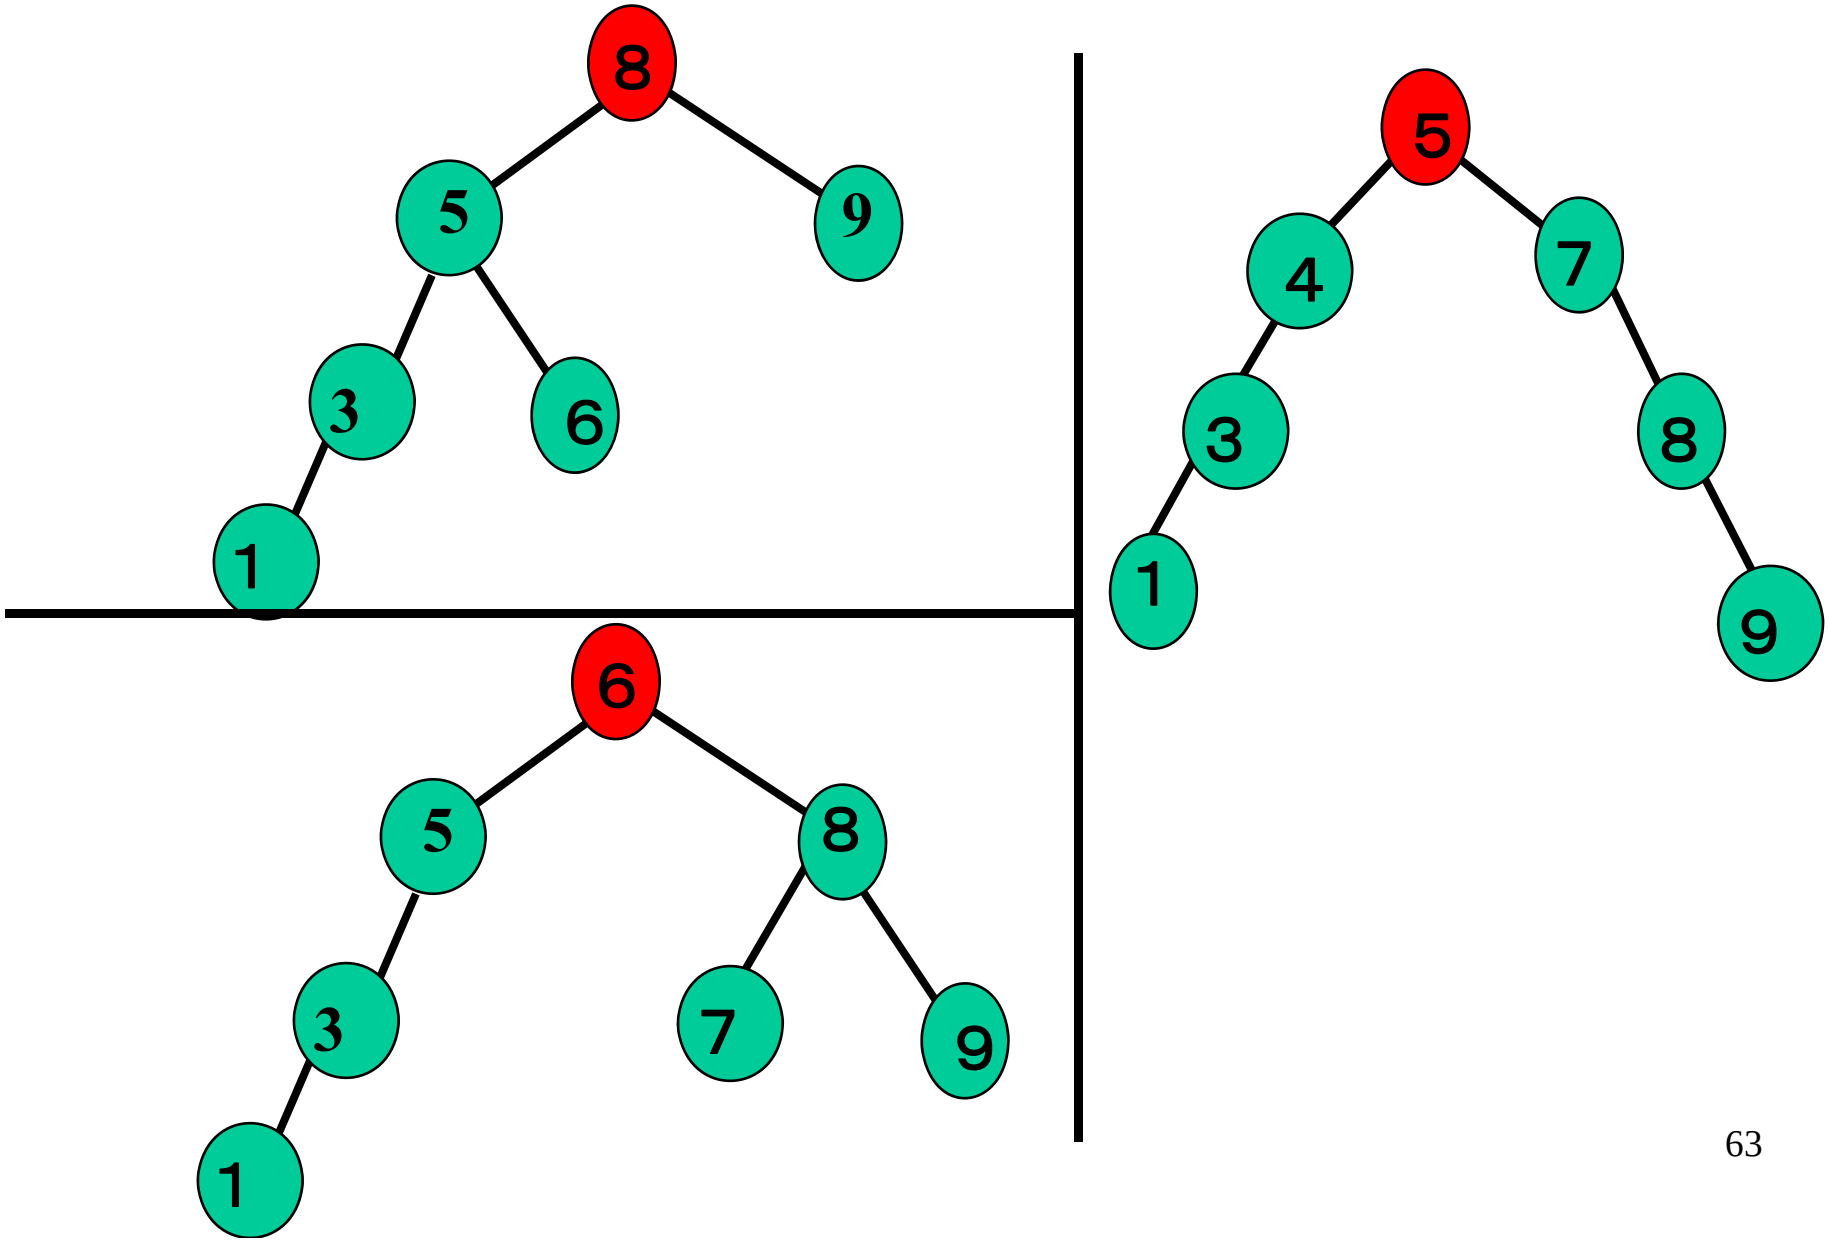

AVL木の高さの導出

- 「各ノードにおいて、右部分木の高さと左部分木の高さの差が高々１」

という条件からAVL木の高さが、

$$O(\log n)$$

になることが導かれる。

AVL木の
バランス条件

ここでは、できるだけ少ないノードで、
高さを増加させることを考える。

少ないノードのAVL木１

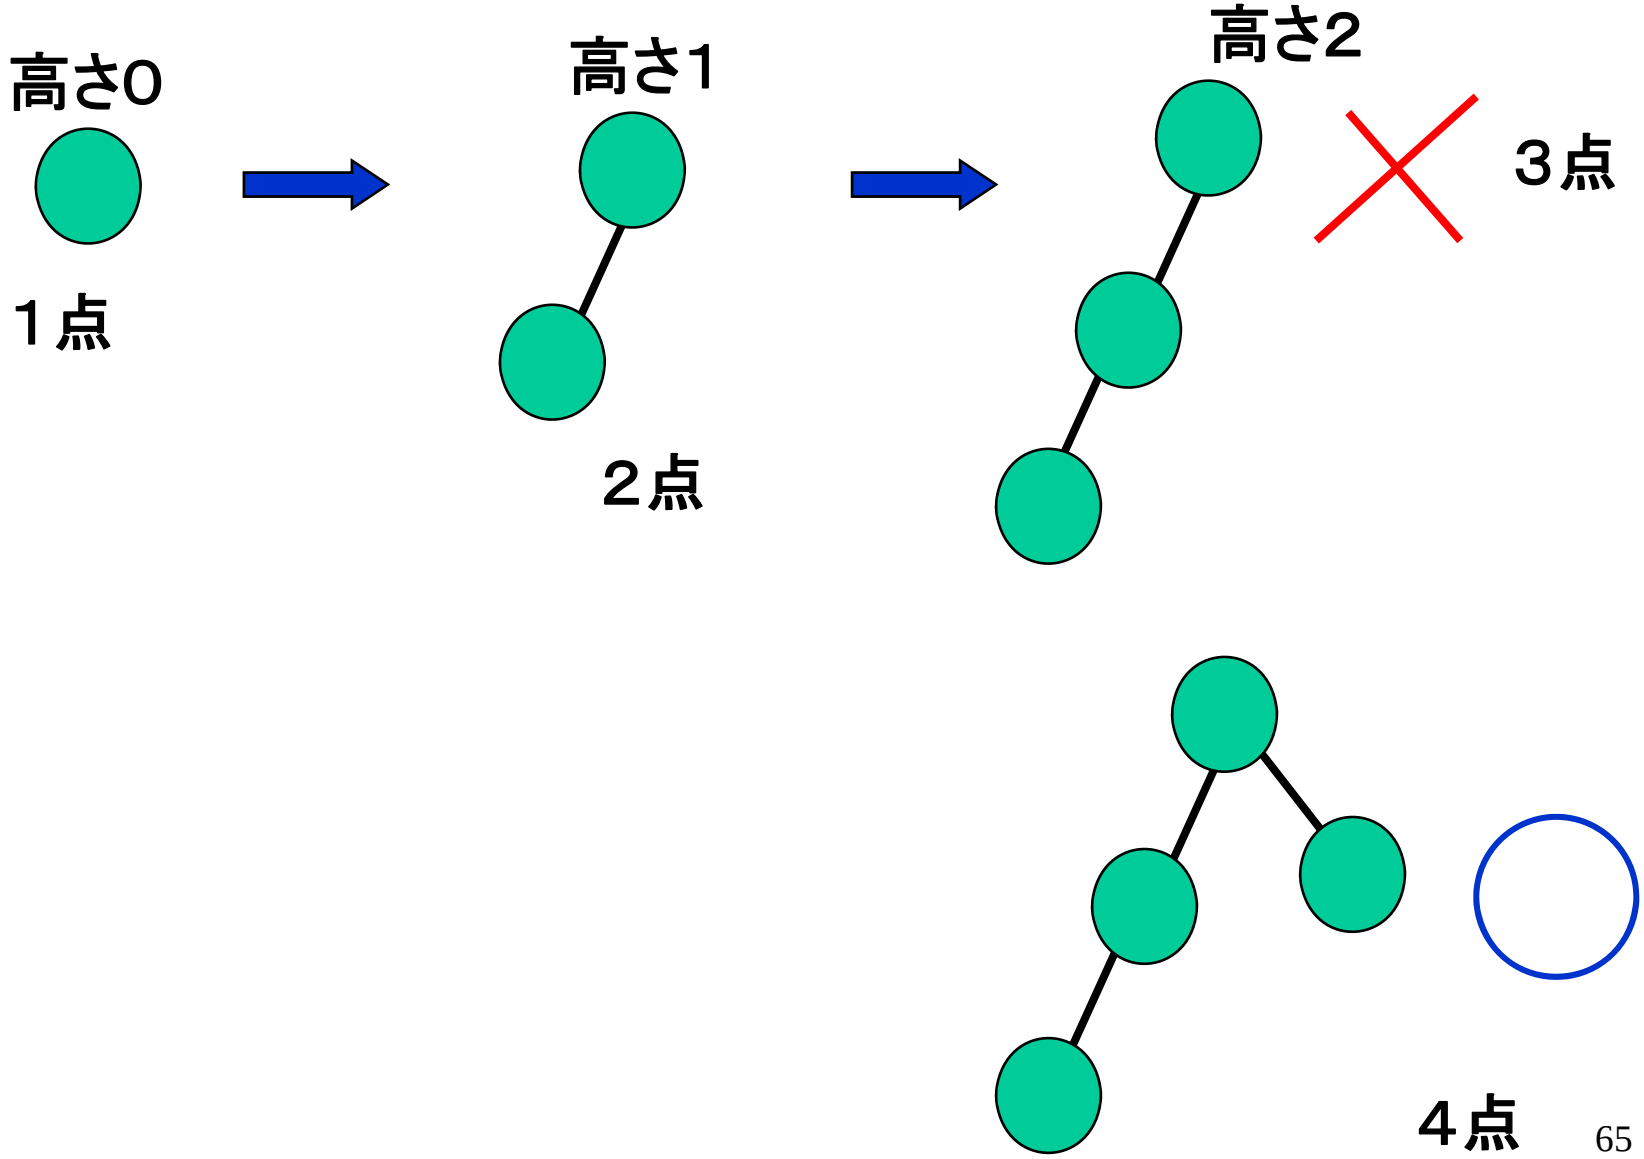

少ないノードのAVL木2

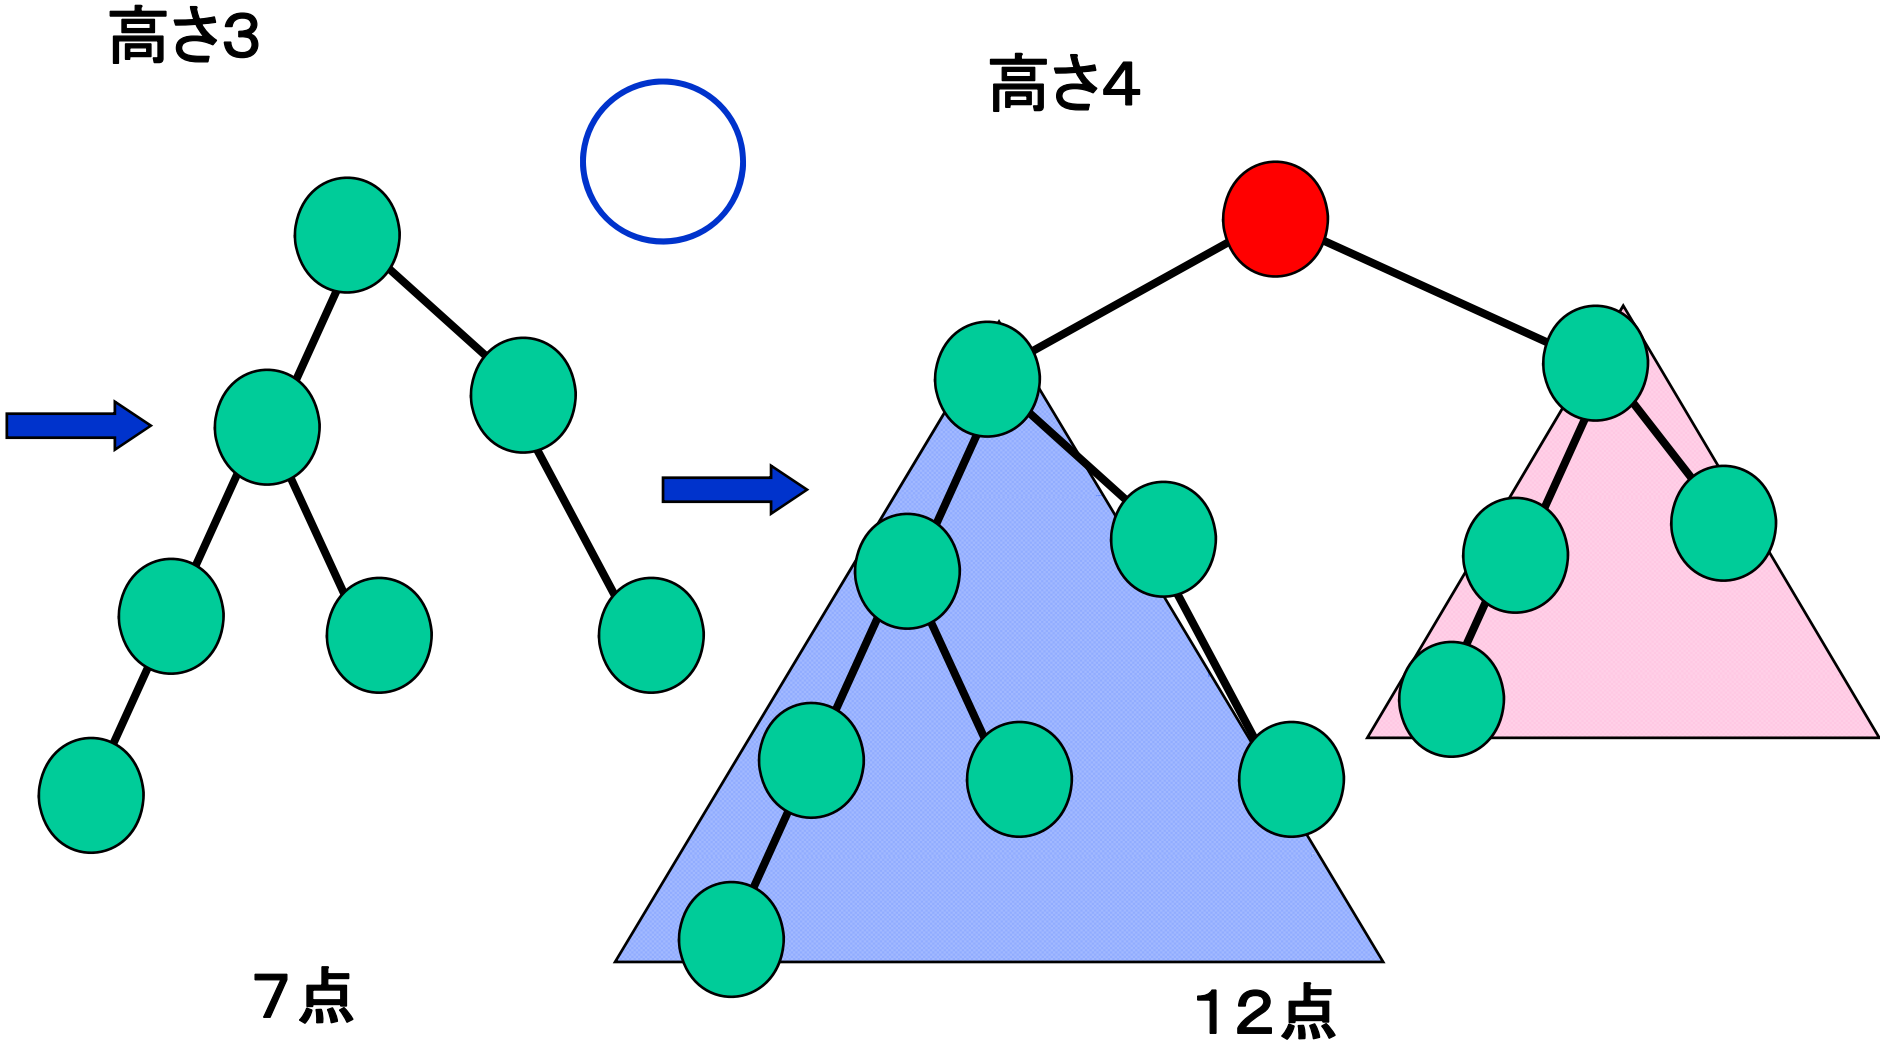

高さ h のAVL木を実現する最小のノード数を $N(h)$ と表す。

例より、

$$N(0) = 1, N(1) = 2, N(3) = 4, N(4) = 7, \cdots$$

という数列になるはずである。

ここで、この数列 $N(h)$ が満たすべき漸化式を導く。

高さ h を実現する最小ノード数のAVL木

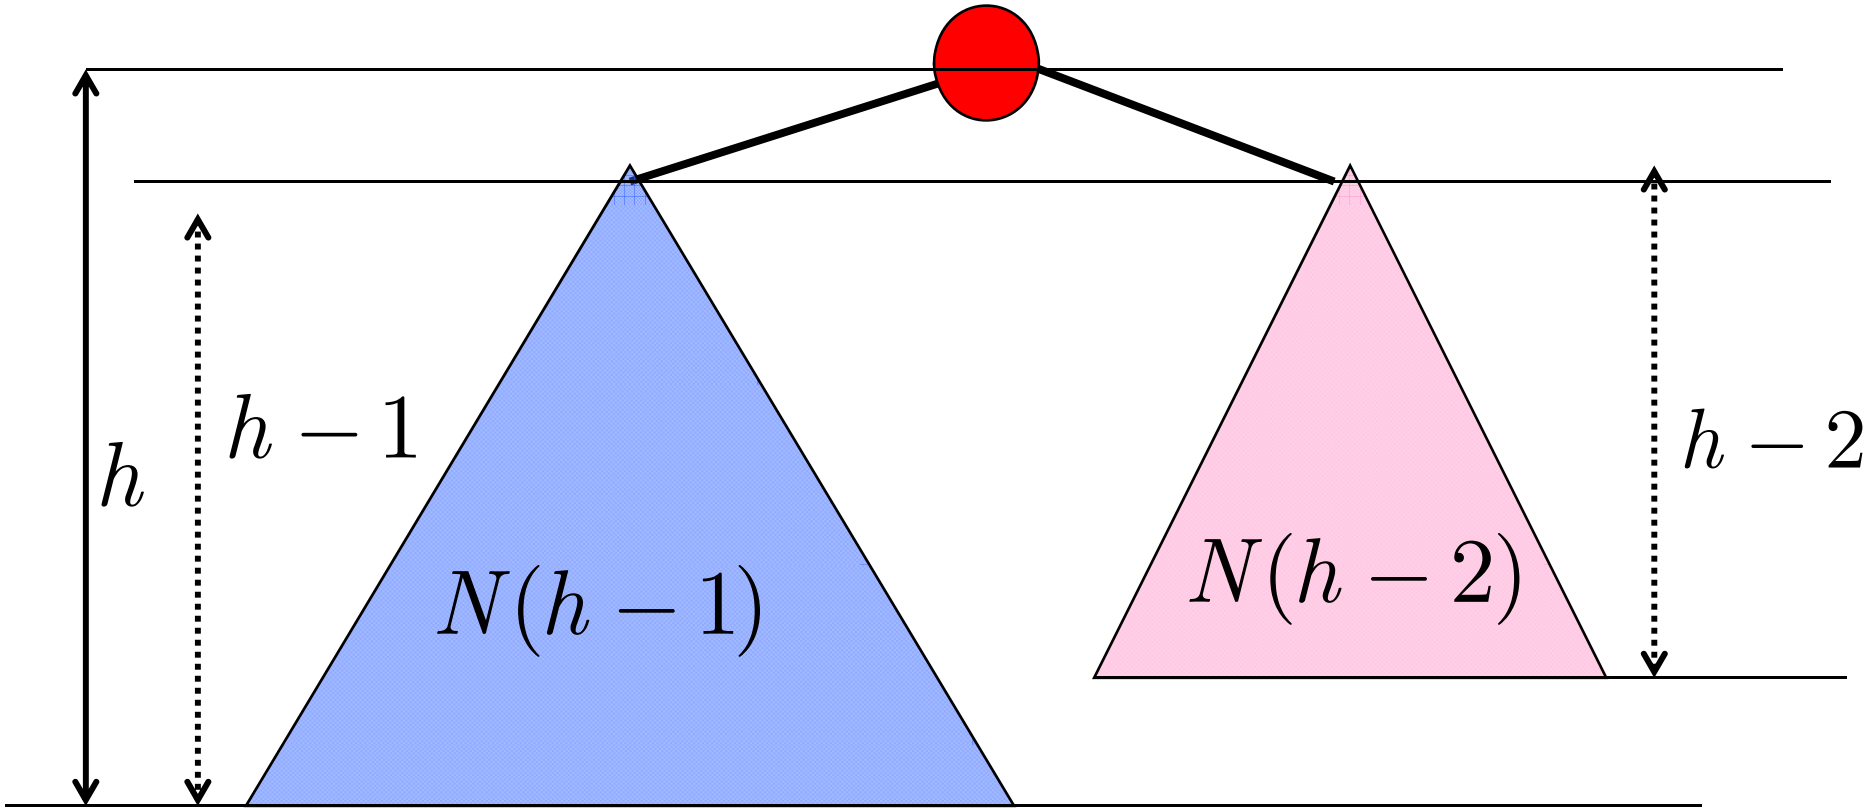

$$\therefore N(h) = N(h-1) + N(h-2) + 1$$

左部分木の点数
（右部分木の点数）

右部分木の点数
（左部分木の点数）

根

以上の考察より、次の漸化式が成り立つ。

$$\begin{cases} N(0) = 1 & h = 0 \\ N(1) = 2 & h = 1 \\ N(h) = N(h-1) + N(h-2) + 1 & h \geq 2 \end{cases}$$

この漸化式を解けば、高さ h を実現する最小のノード数 $N(h)$ が求められる。

特殊解を N とする。

再帰式より、

$$N = N + N + 1$$

$$\therefore N = -1$$

この同次解を求める。
すなわち、以下の漸化式を満たす解を求める。

$$\widetilde{N}(h) - \widetilde{N}(h-1) - \widetilde{N}(h-2) = 0$$

特性方程式を解く。

$$x^2 - x - 1 = 0$$

$$\therefore x = \frac{1 \pm \sqrt{5}}{2}$$

よって、

$$\alpha \equiv \frac{1+\sqrt{5}}{2}, \beta \equiv \frac{1-\sqrt{5}}{2}$$

と置くと、任意定数 c_1, c_2 を持ちいて、次のようにあらわせる。

$$N(h) = c_1\alpha^h + c_2\beta^h + N = c_1\alpha^h + c_2\beta^h - 1$$

$$N(0) = c_1 + c_2 - 1 = 1$$

$$N(1) = c_1 \frac{1+\sqrt{5}}{2} + c_2 \frac{1-\sqrt{5}}{2} - 1 = 2$$

これを解いて、

$$c_1 = \frac{2+\sqrt{5}}{\sqrt{5}} = \frac{1}{\sqrt{5}}\alpha^3, c_2 = -\frac{2-\sqrt{5}}{\sqrt{5}} = \frac{-1}{\sqrt{5}}\beta^3$$

$$\therefore N(h) = c_1\alpha^h + c_2\beta^h + N = \frac{1}{\sqrt{5}}\left(\alpha^{h+3} - \beta^{h+3}\right) - 1$$

これより、n 点のAVL木の高さは、次式を満たす。

$$\therefore N(h) \leq n$$

これより、

$$h = O(\log n)$$

と高さを導くことができる。
（この評価は、最悪時も考慮されていることに注意する。）

AVLへの挿入

- 挿入によっても、AVLのバランス条件を満足していれば、通常の2分探索木の挿入をおこなう。
- 挿入によりバランス条件を破ってしまったとき、挿入状況により、バランス回復操作をおこなう。
  - １重回転操作
  - ２重回転操作

バランスを崩す挿入

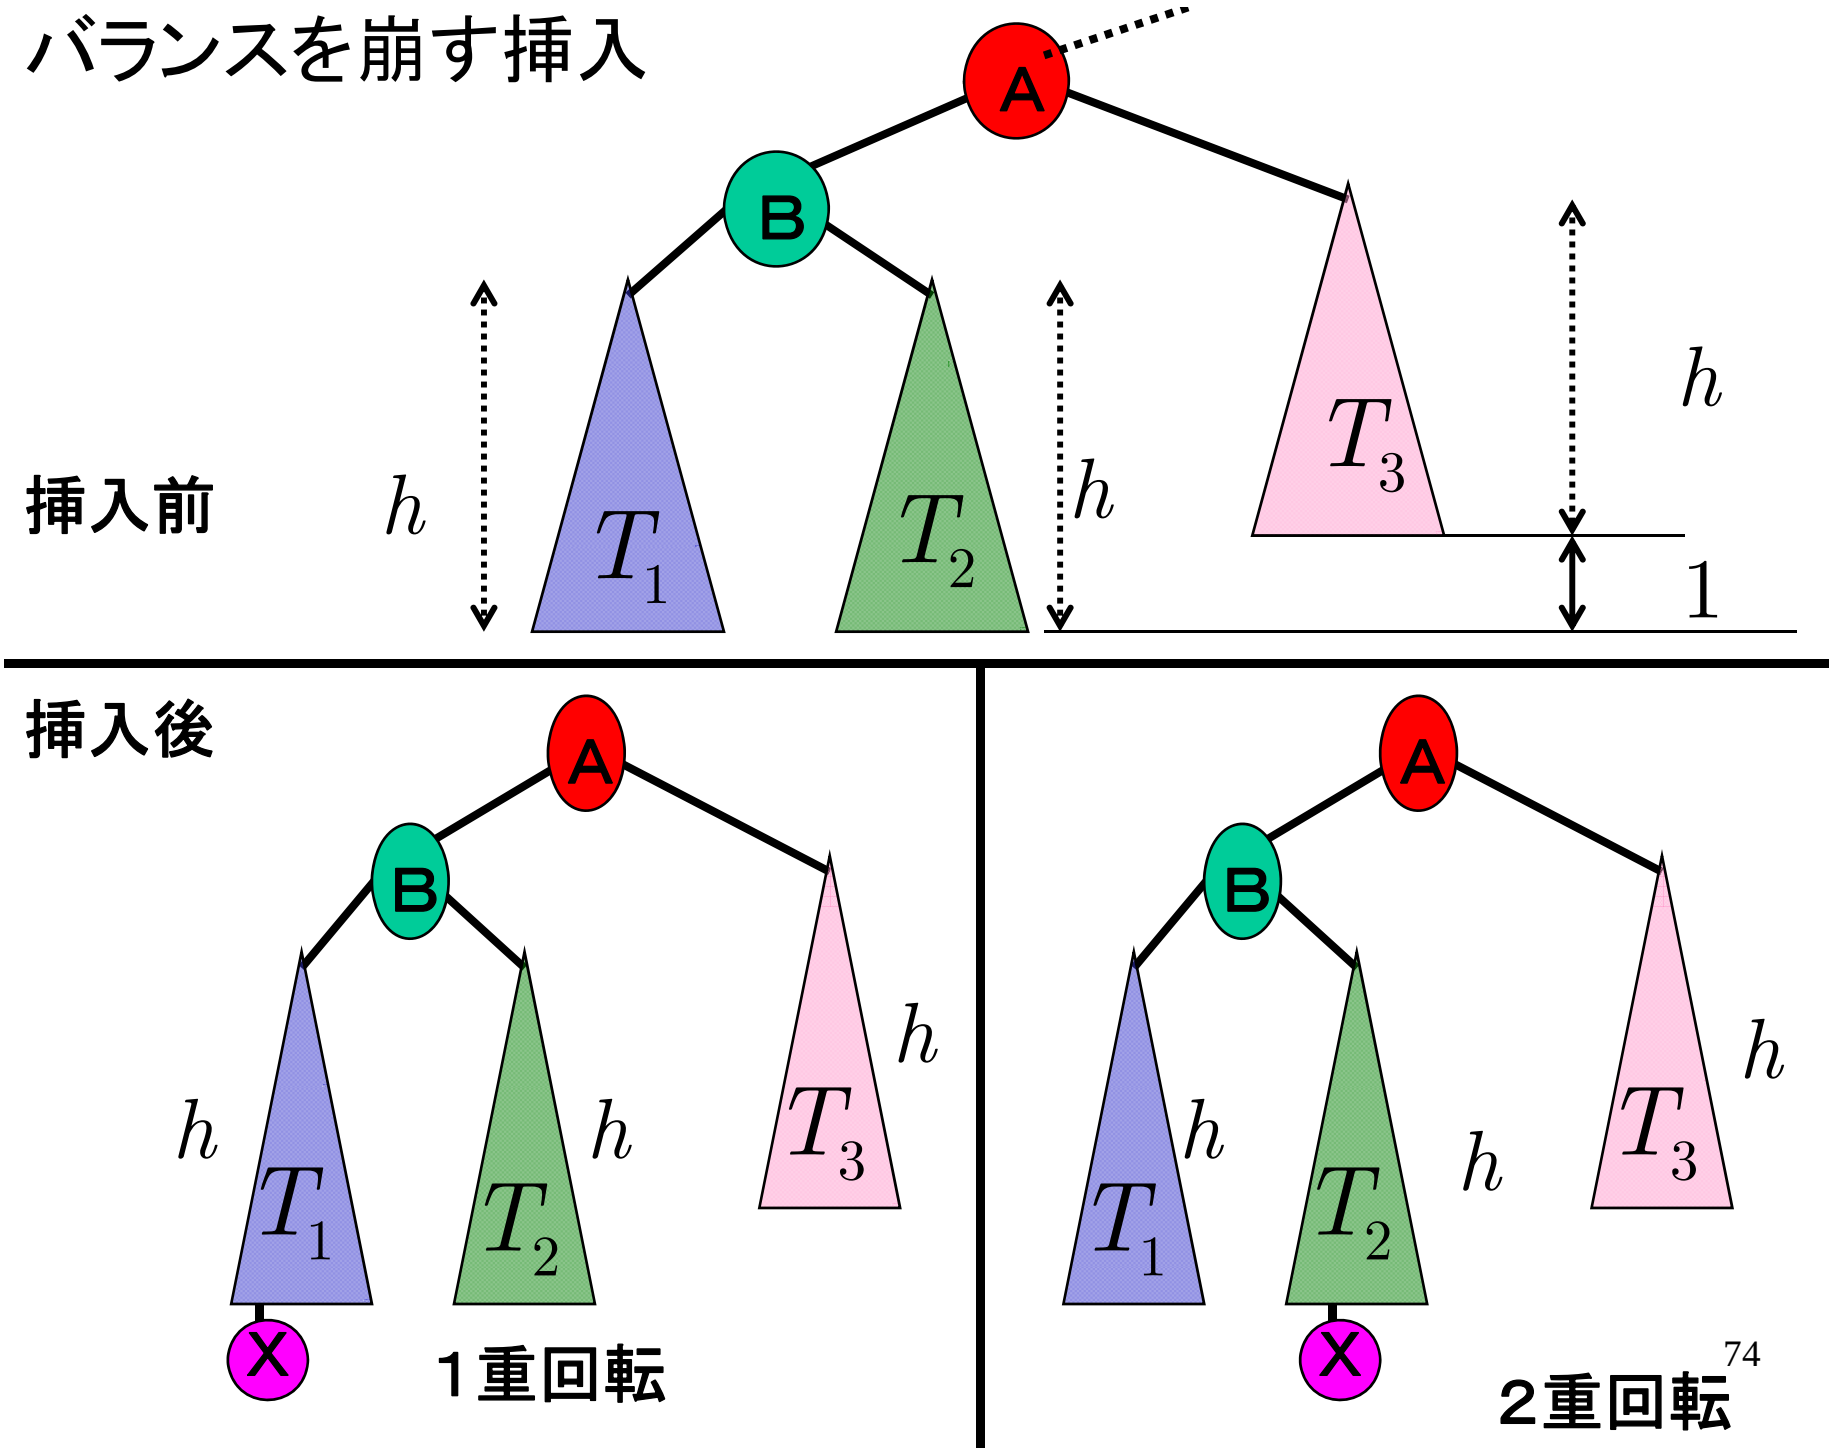
挿入前
A
B
T_1
T_2
T_3
h
h
h
1
挿入後
A
B
X
T_1
T_2
T_3
h
h
h
1重回転
A
B
X
T_1
T_2
T_3
h
h
h
2重回転

１重回転

回転前

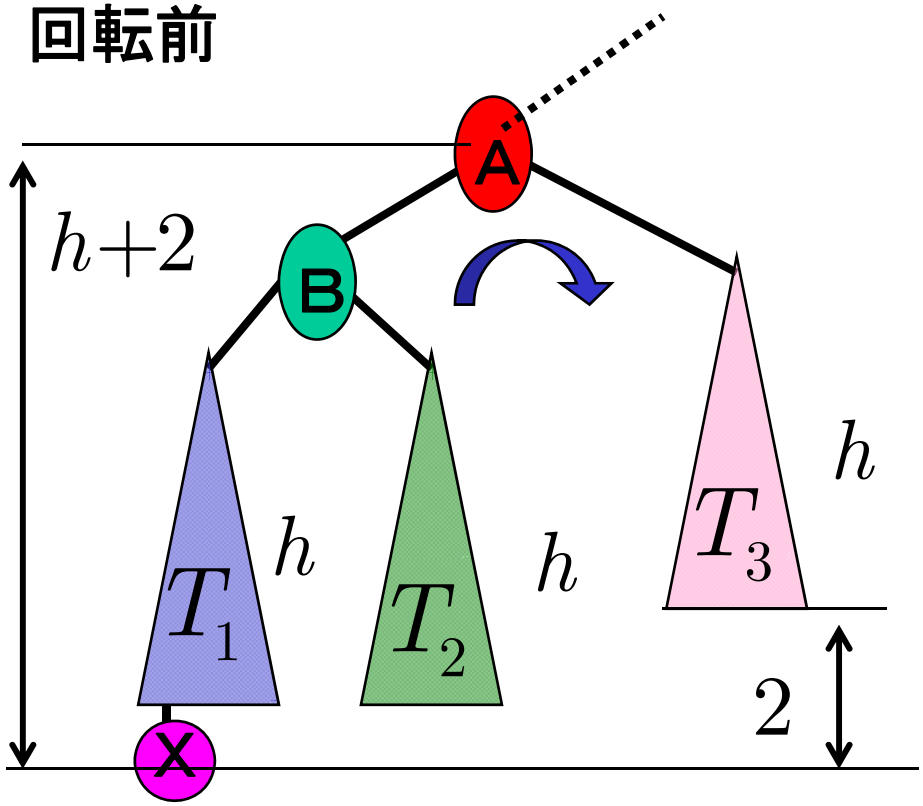

回転後

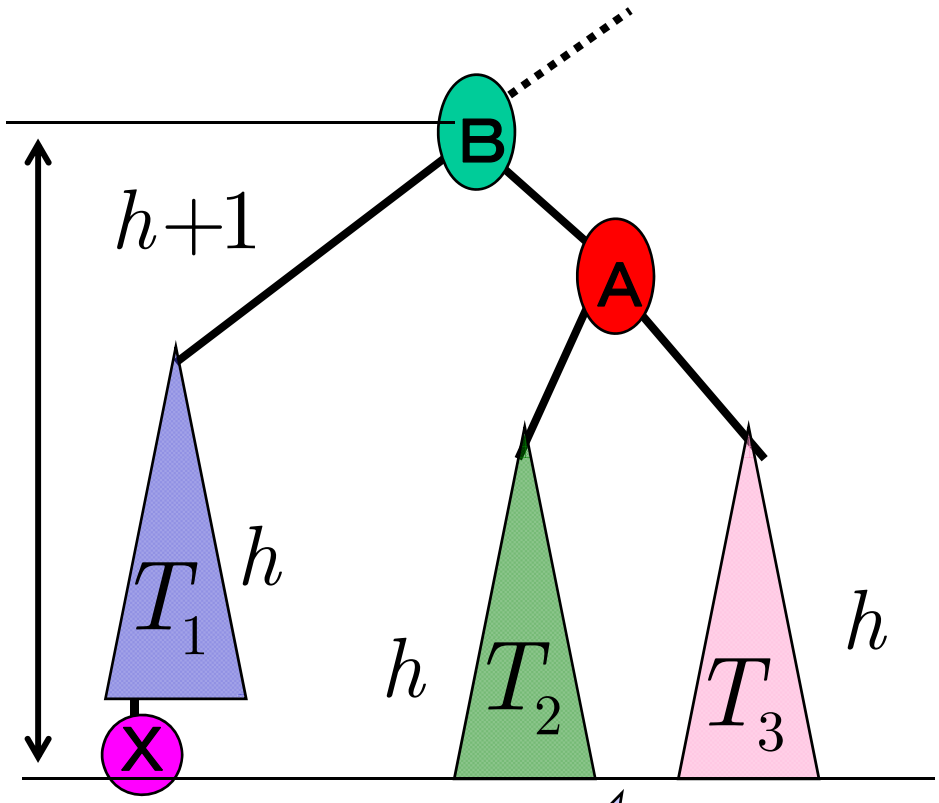

高さの差は0

２重回転１

回転前

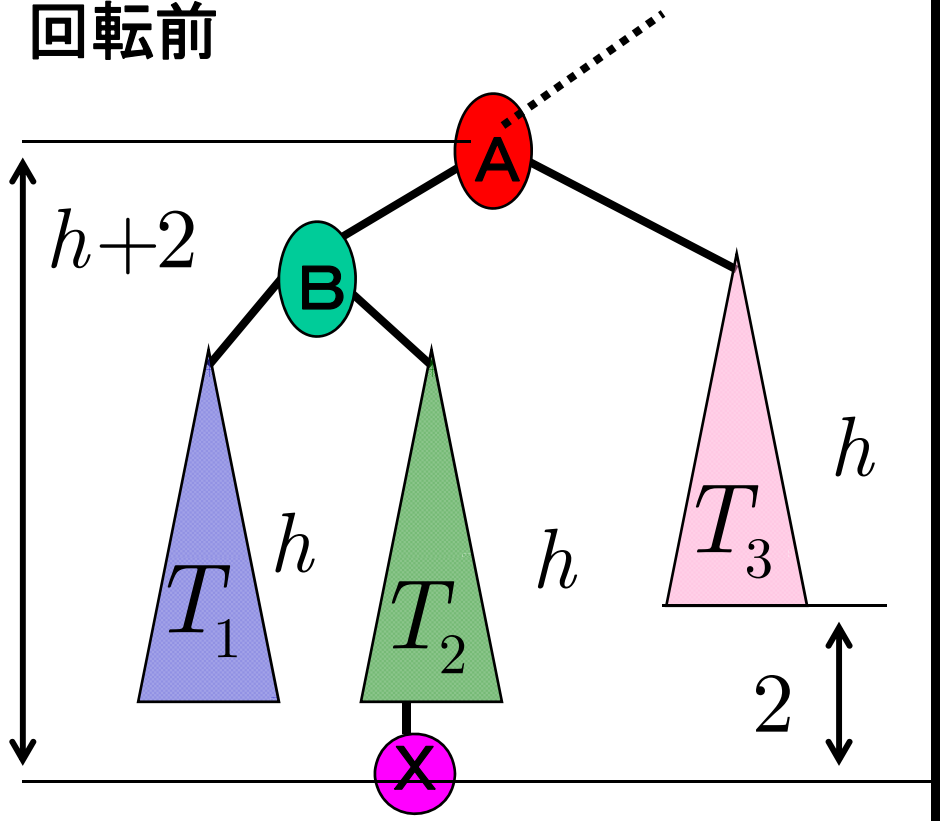

詳細化

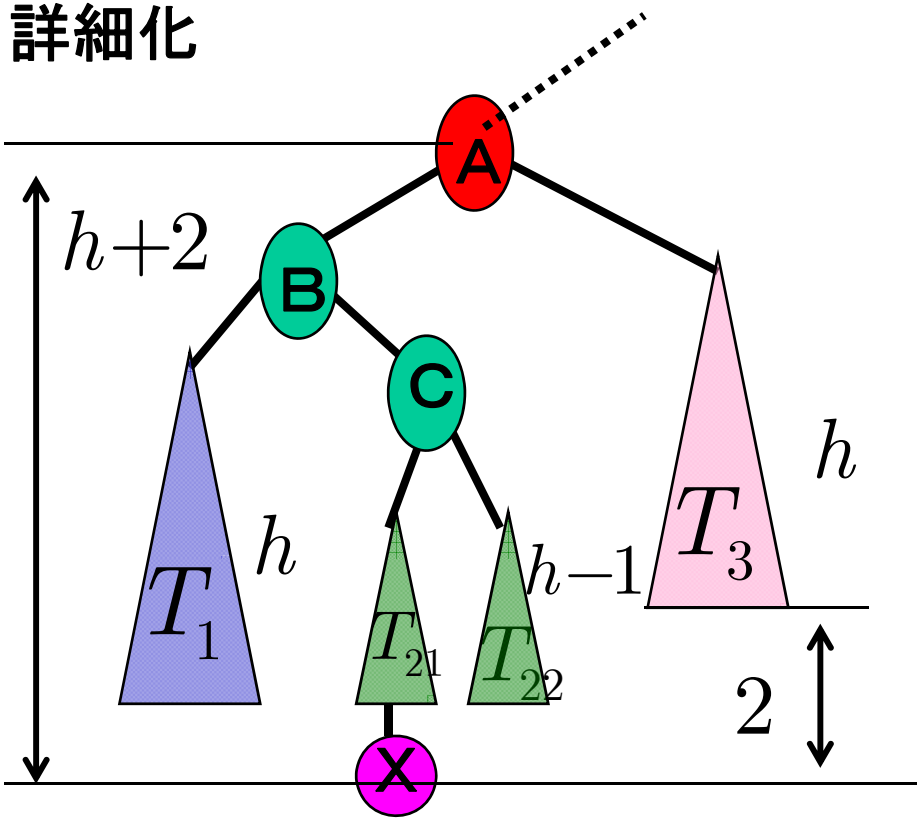

２重回転2

回転前

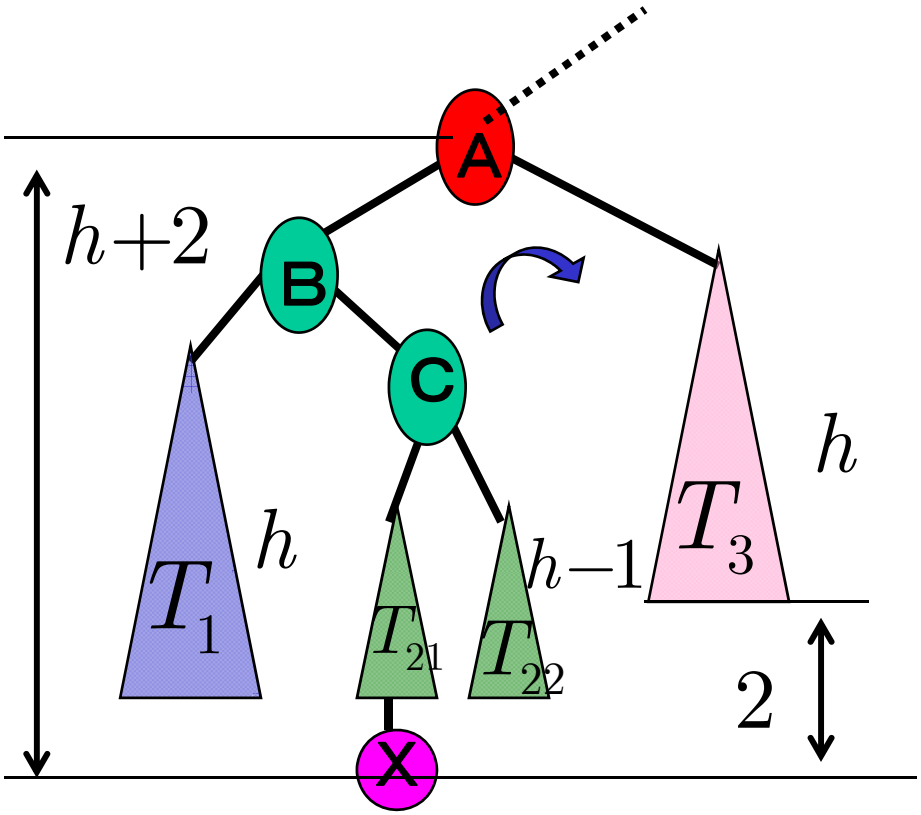

回転後

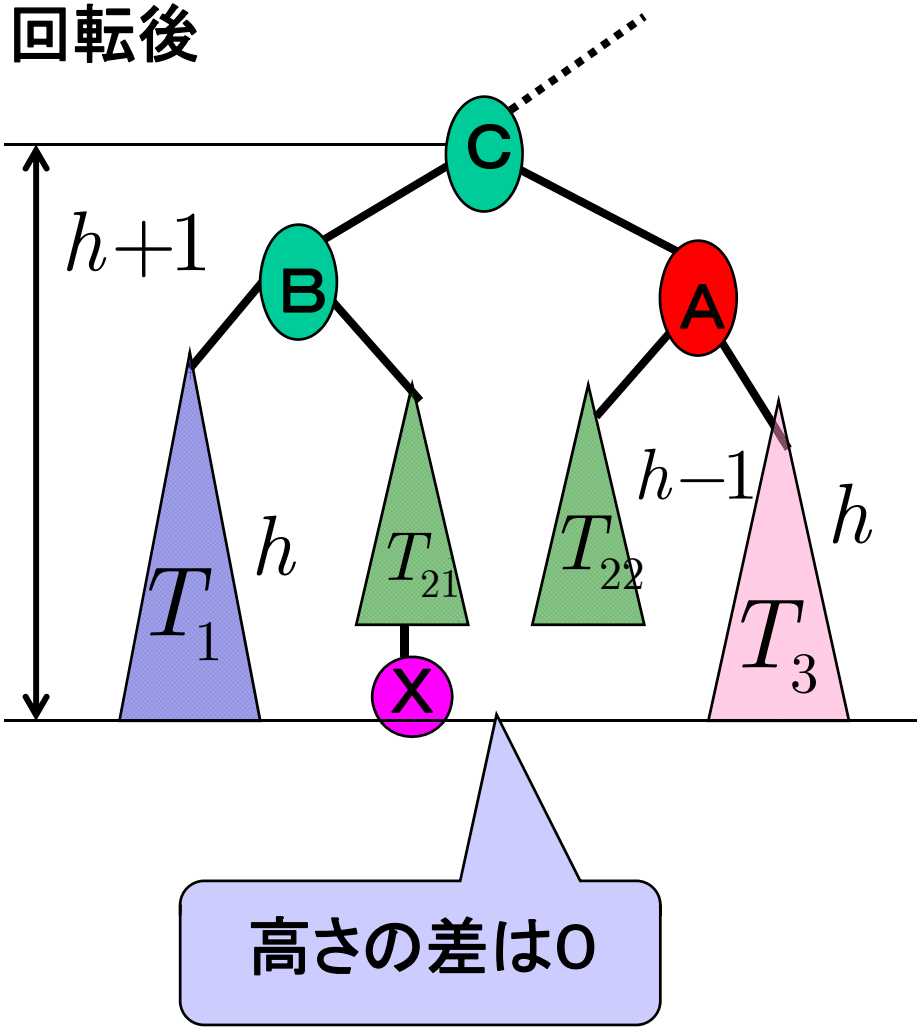

１重回転2回での２重回転の実現

回転前

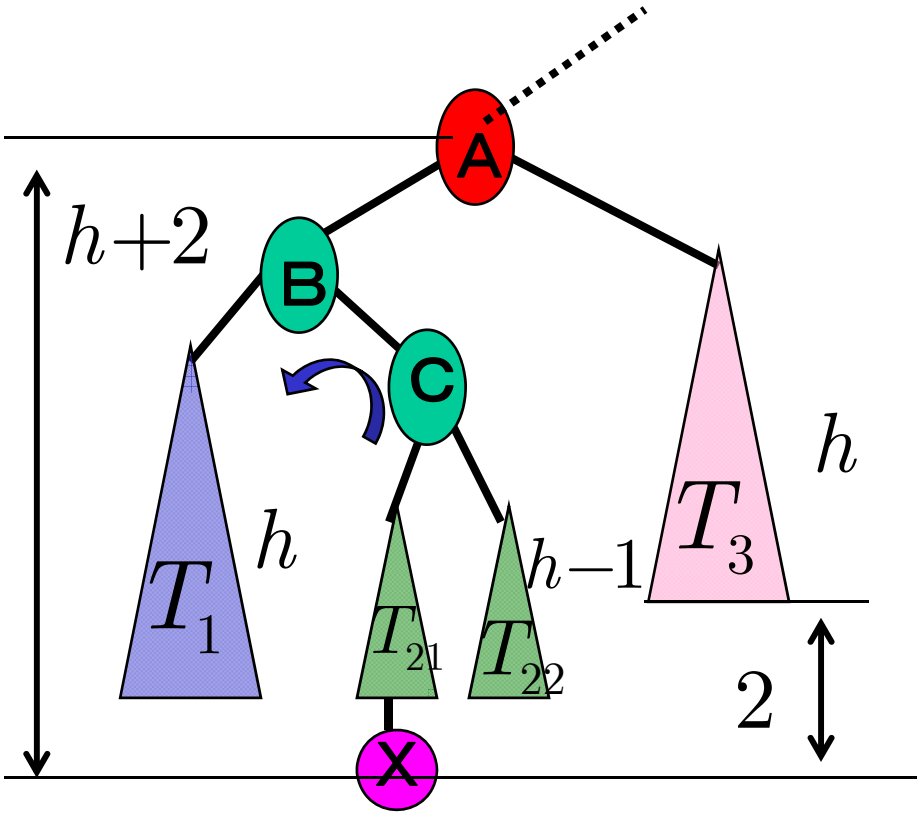

１回転後

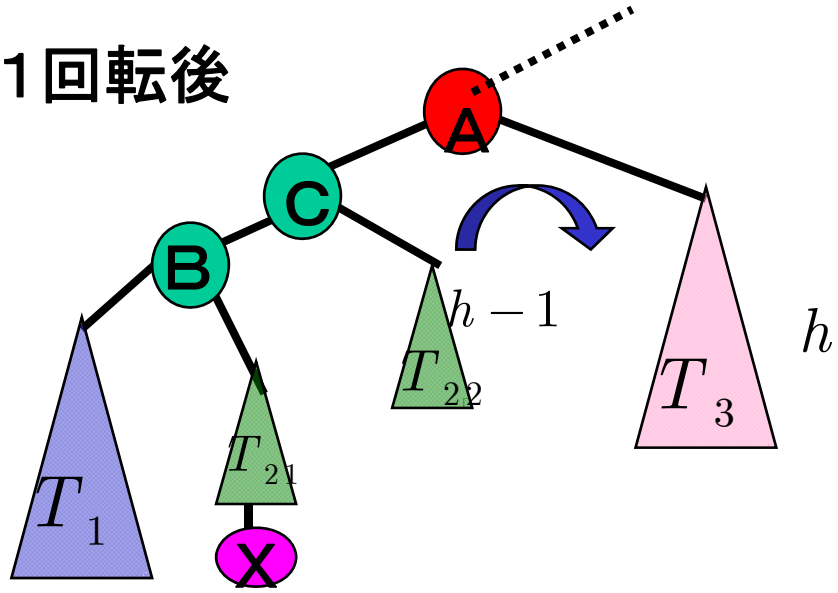

２回転後

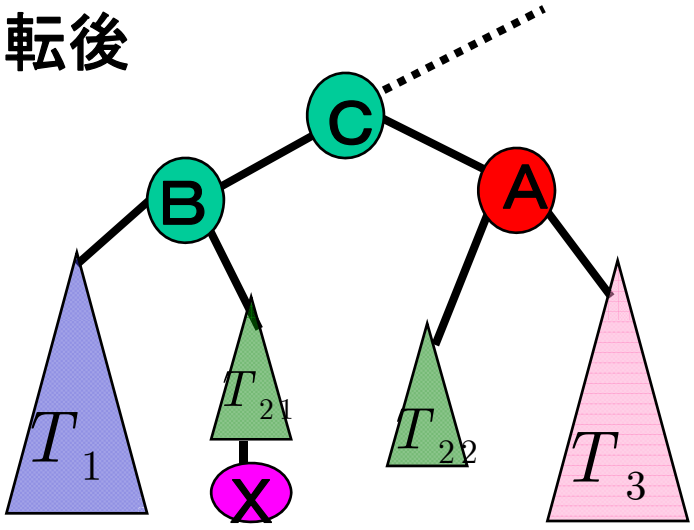

AVL木への挿入例1

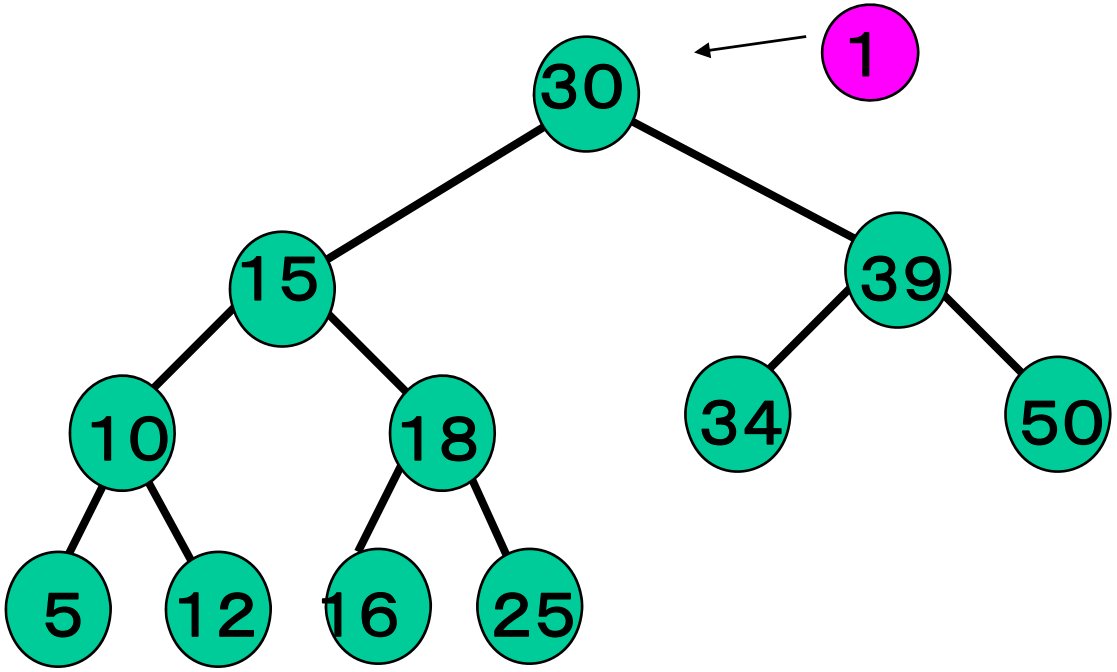

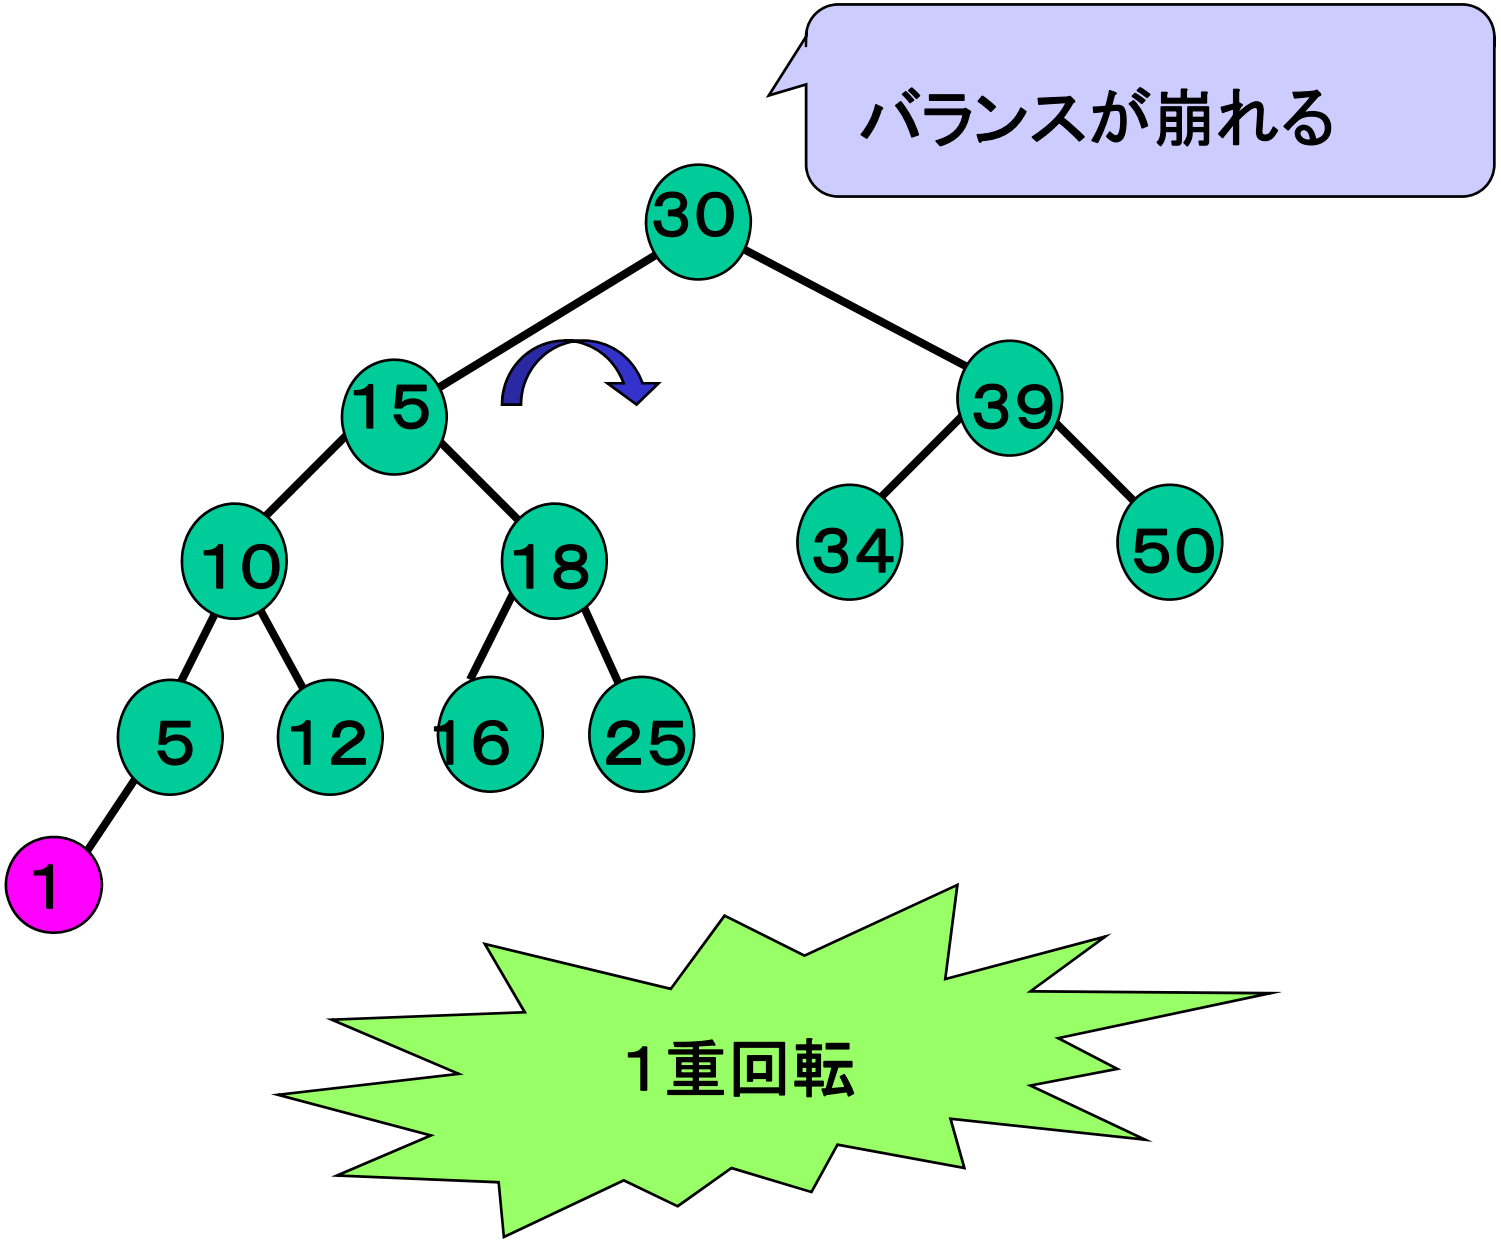
バランスが崩れる
30
15
39
10
18
34
50
5
12
16
25
1
１重回転

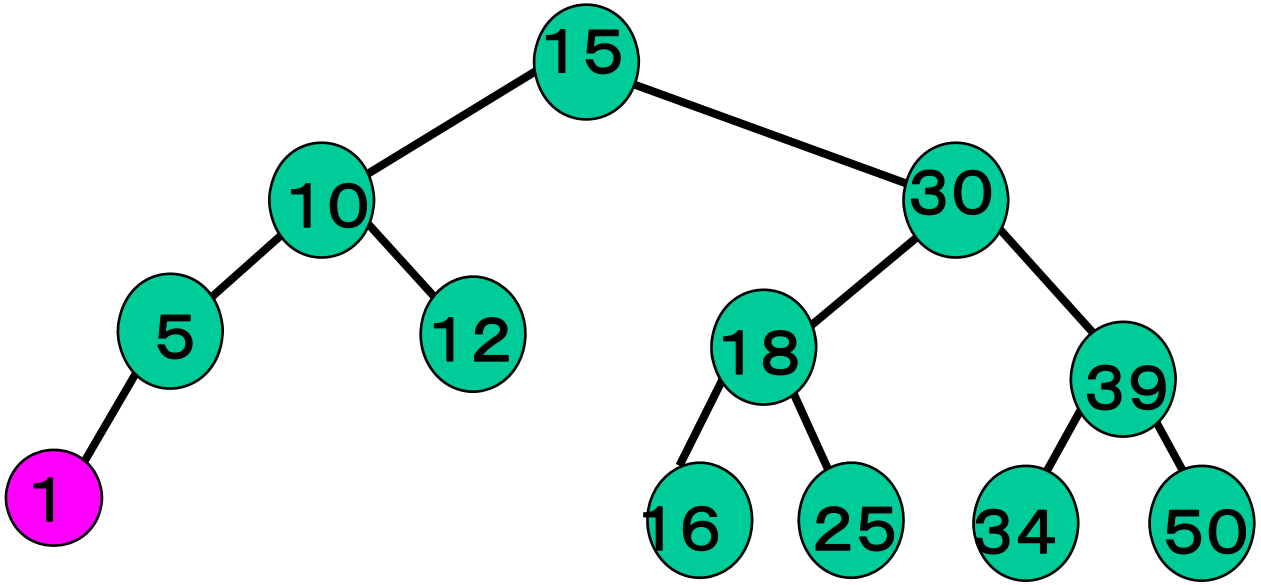

１重回転後

AVL木への挿入例2

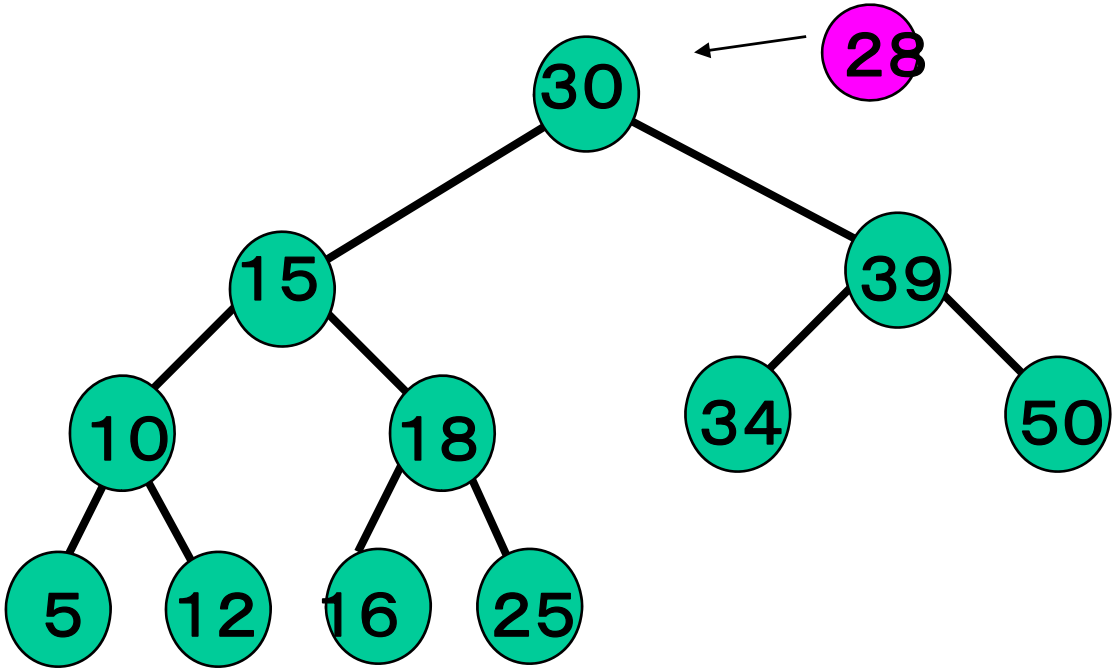

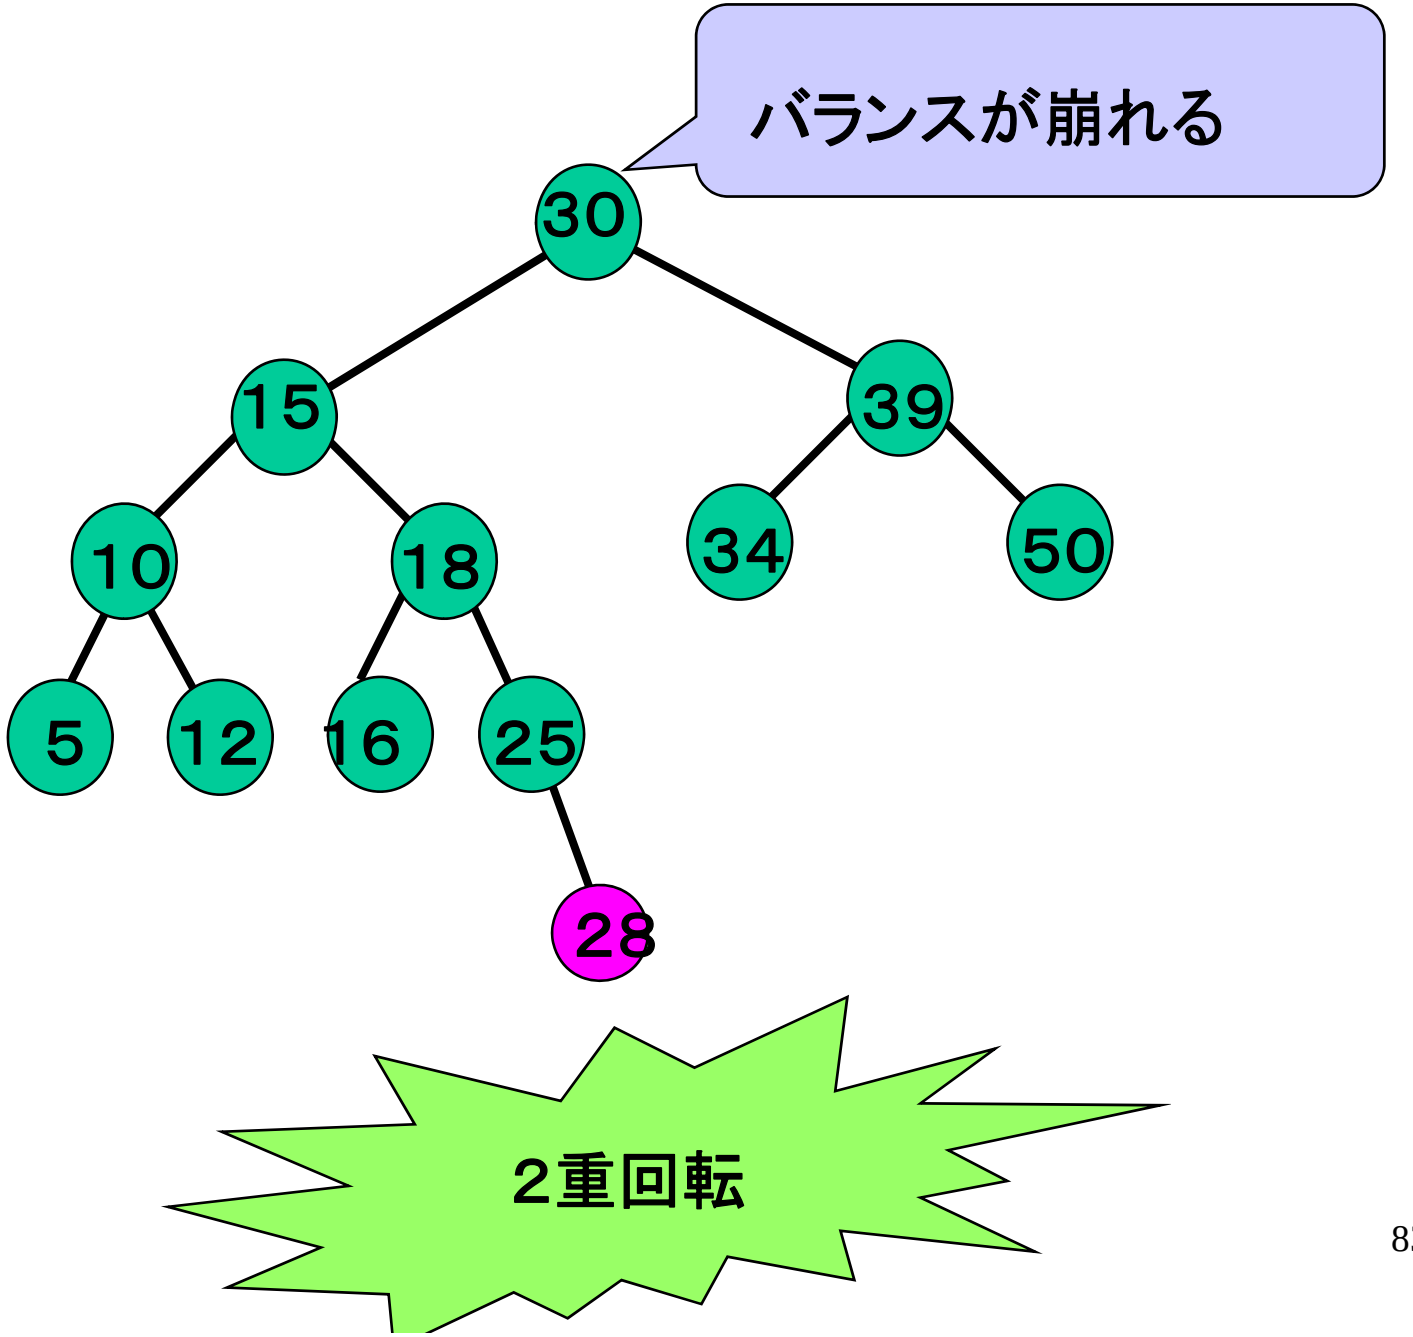
バランスが崩れる
30
15
39
10
18
34
50
5
12
16
25
28
2重回転

バランスが崩れる

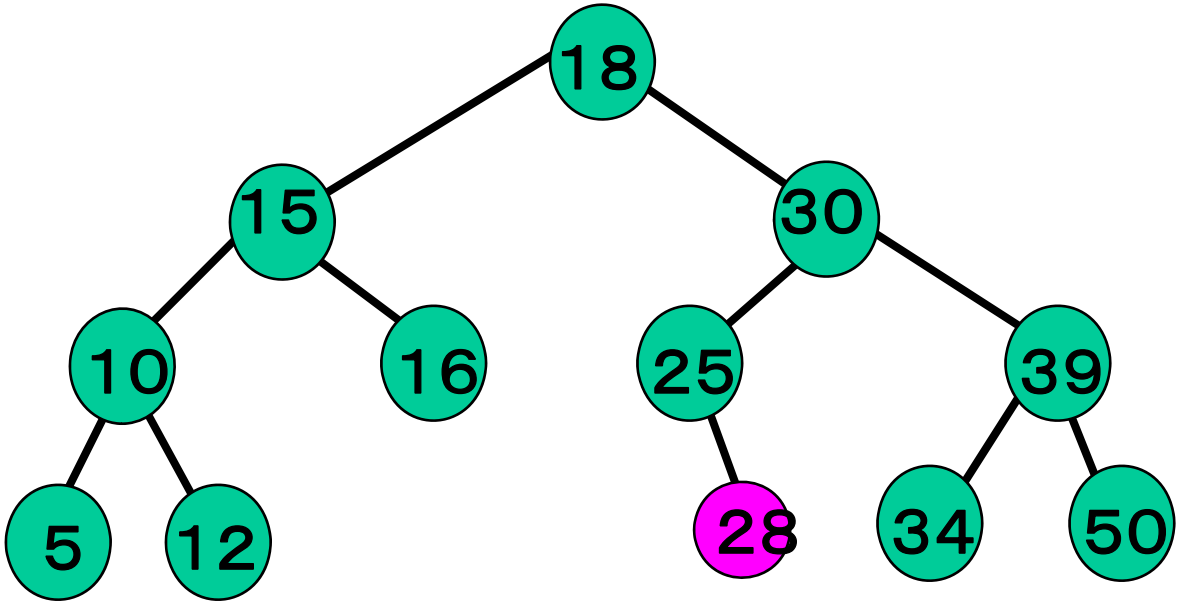

2重回転後

練習

次のAVL木に、各要素を順に挿入した結果を示せ。

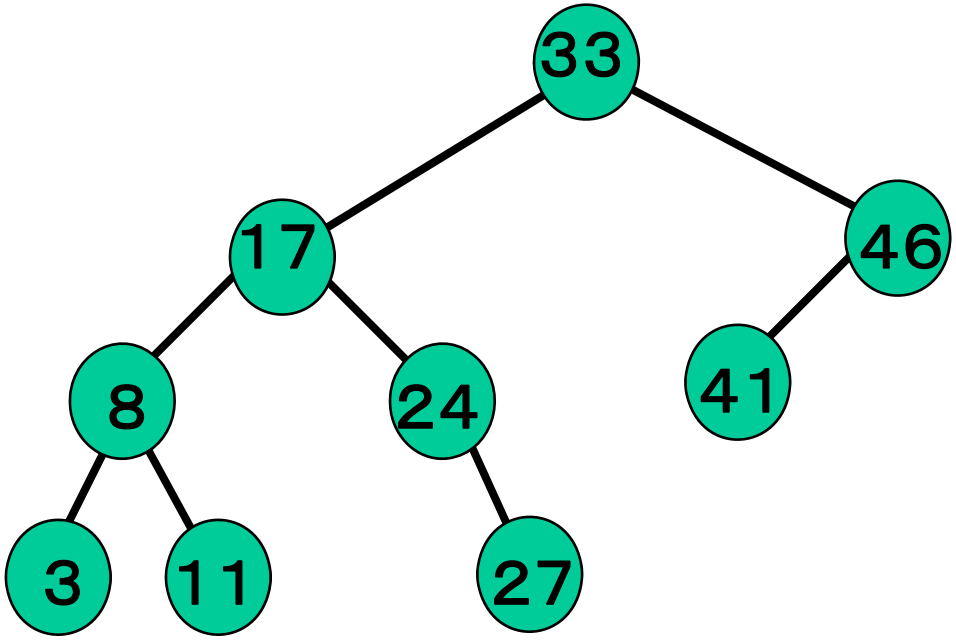

$$28 \rightarrow 10 \rightarrow 35 \rightarrow 23$$

AVLへの挿入の計算量

- 挿入位置の確認とバランス条件のチェックに、木の高さ分の時間計算量が必要である。
- また、回転操作には、部分木の付け替えだけであるので、定数時間（ $O(1)$ 時間）で行うことができる。
- 以上より、挿入に必要な最悪時間計算量は、

$$O(\log n)$$

である。

AVLへの削除の計算量

- 削除時に、バランス条件が崩された場合も、挿入時と同様に、回転操作によって、バランスを回復することができる。
- 削除位置を求めることと、バランス条件のチェックに、木の高さ分の時間計算量が必要である。
- 以上より、削除に必要な最悪時間計算量も、

$$O(\log n)$$

である。

B木の概略

- 多分木（ d 分木）を基にした平衡木
- 各ノードには、データそのものと、部分木へのポインタを交互に蓄える。
- 各葉ノードまでの道は全て等しい。

  （したがって、明らかに平衡木である。）
- 部分木中の全てのデータは、親ノードのデータで範囲が限定される。

B木の満たすべき条件

- ①根は、葉になるかあるいは $2 \sim m$ 個の子を持つ。
- ②根、葉以外のノードは、$\left\lceil \frac{m}{2} \right\rceil \sim m$ 個の子を持つ。
- ③根からすべての葉までの道の長さは等しい。
- ④部分木全てのデータは、その部分木へのポインタを“はさんでいる”データにより、制限される。

B木の例

$$d = \left\lceil \frac{m}{2} \right\rceil$$

$$d = 2, m = 3$$

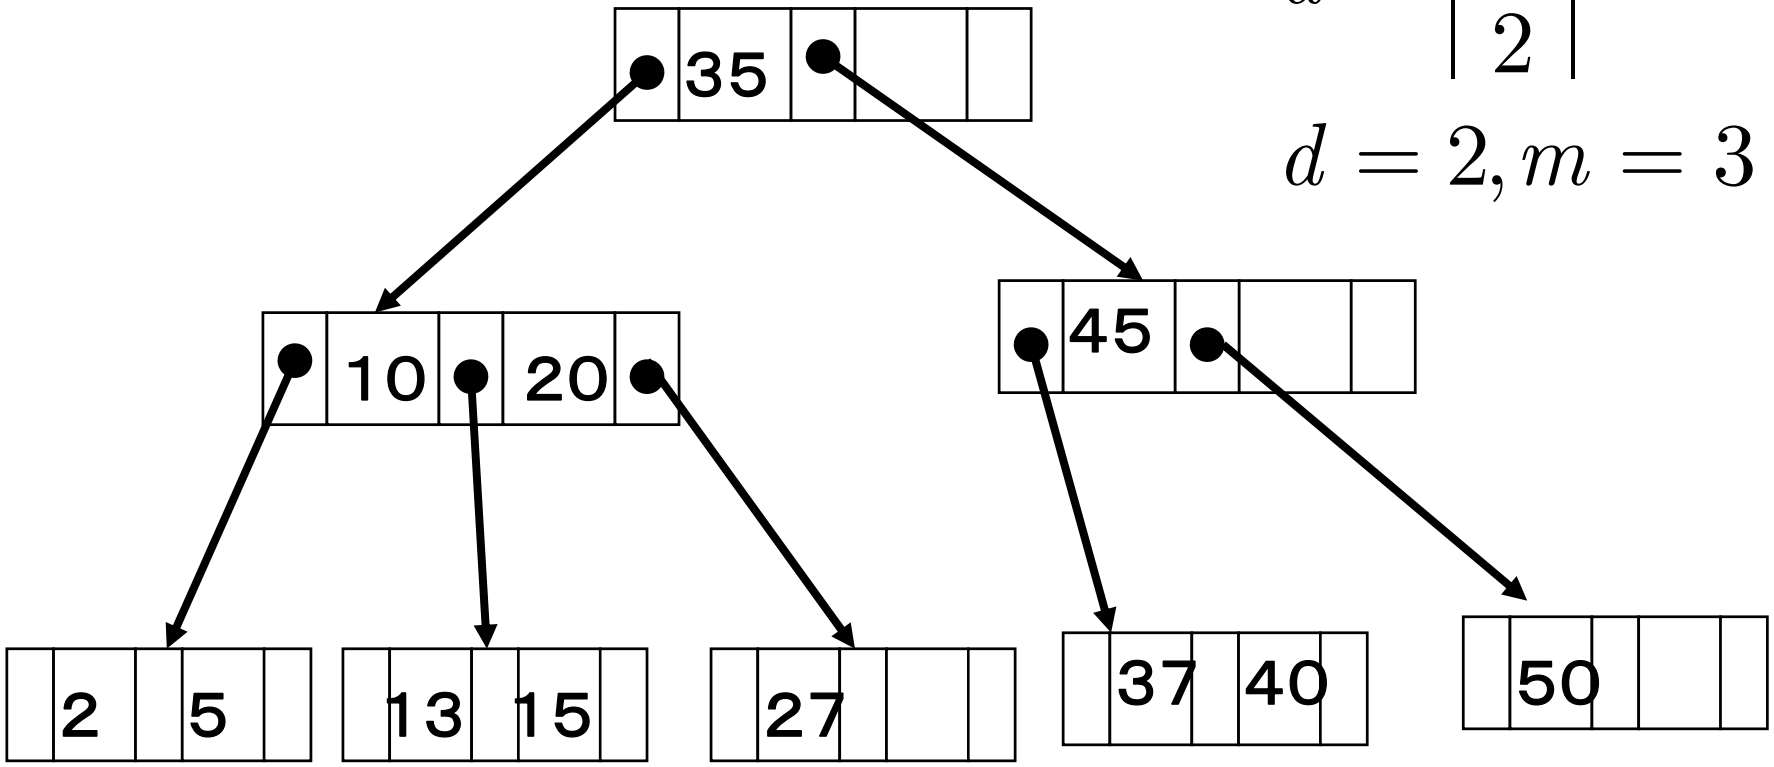

B木の高さ

簡単のため、根以外は、 d 個以上の個があるとする。

このとき、高さ h のB木に含まれるノード数
を $N(h)$ とする。このとき、次が成り立つ。

$$n = N(h) \geq \sum_{i=0}^{h} d^i = \frac{d^{h+1} - 1}{d - 1}$$

$$\therefore h = O(\log_d n)$$

B木への挿入

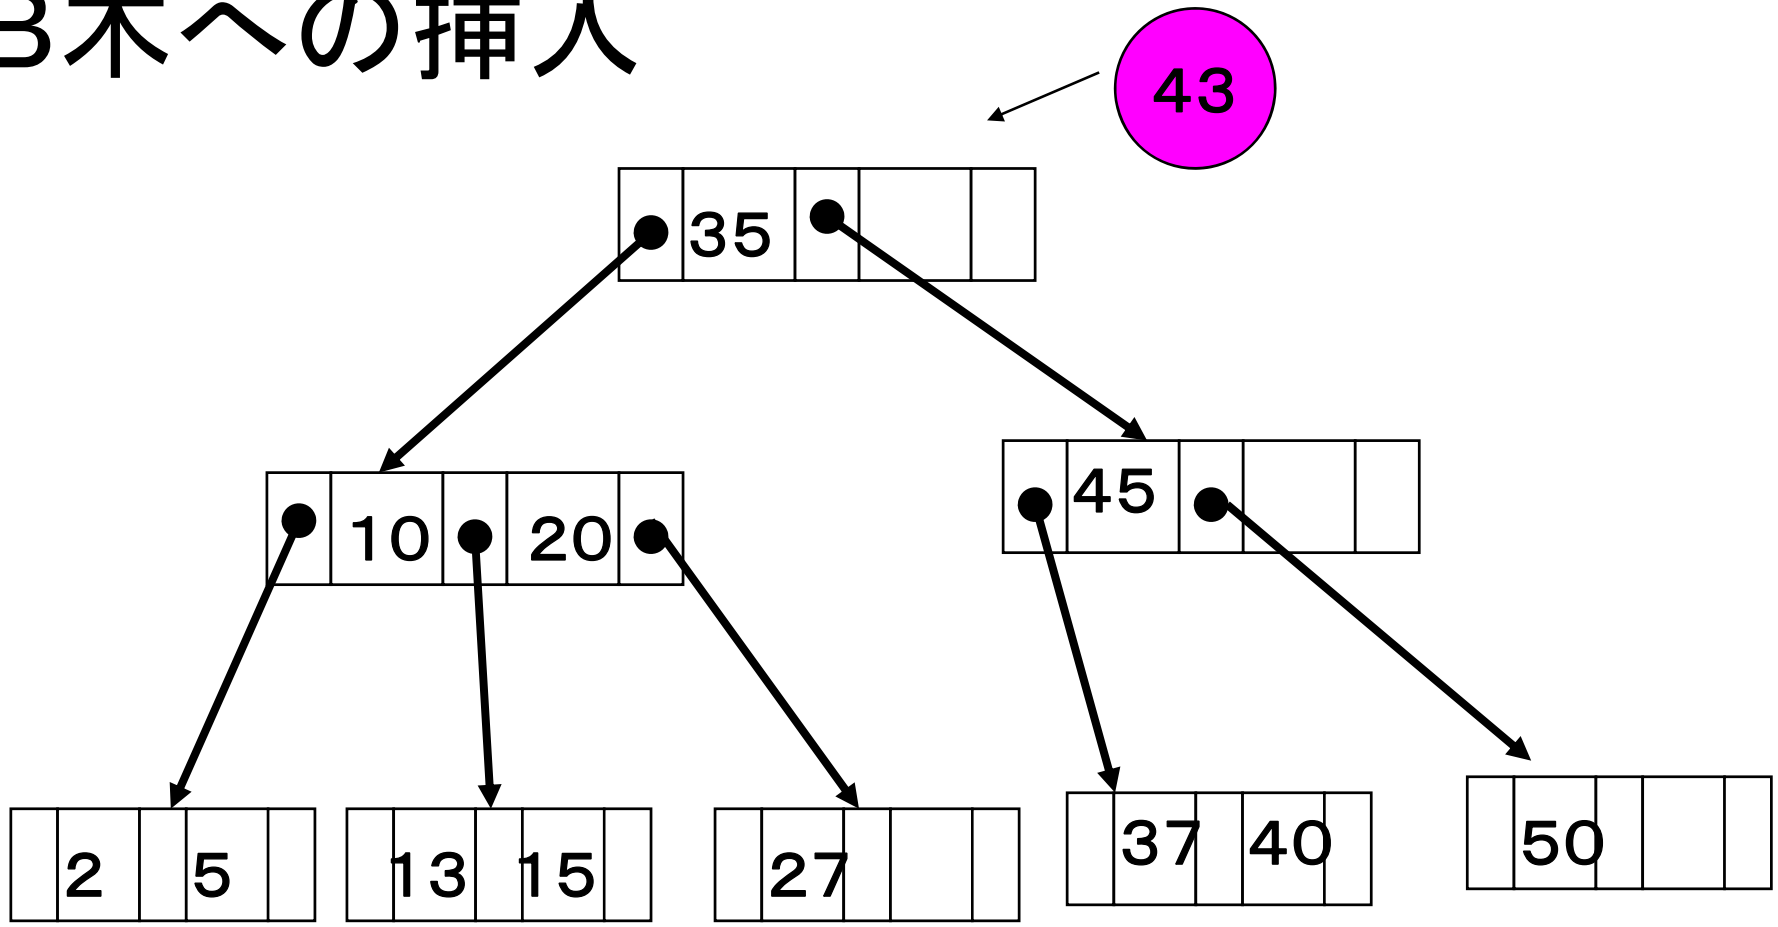

オーバーフロー時のノード分割1

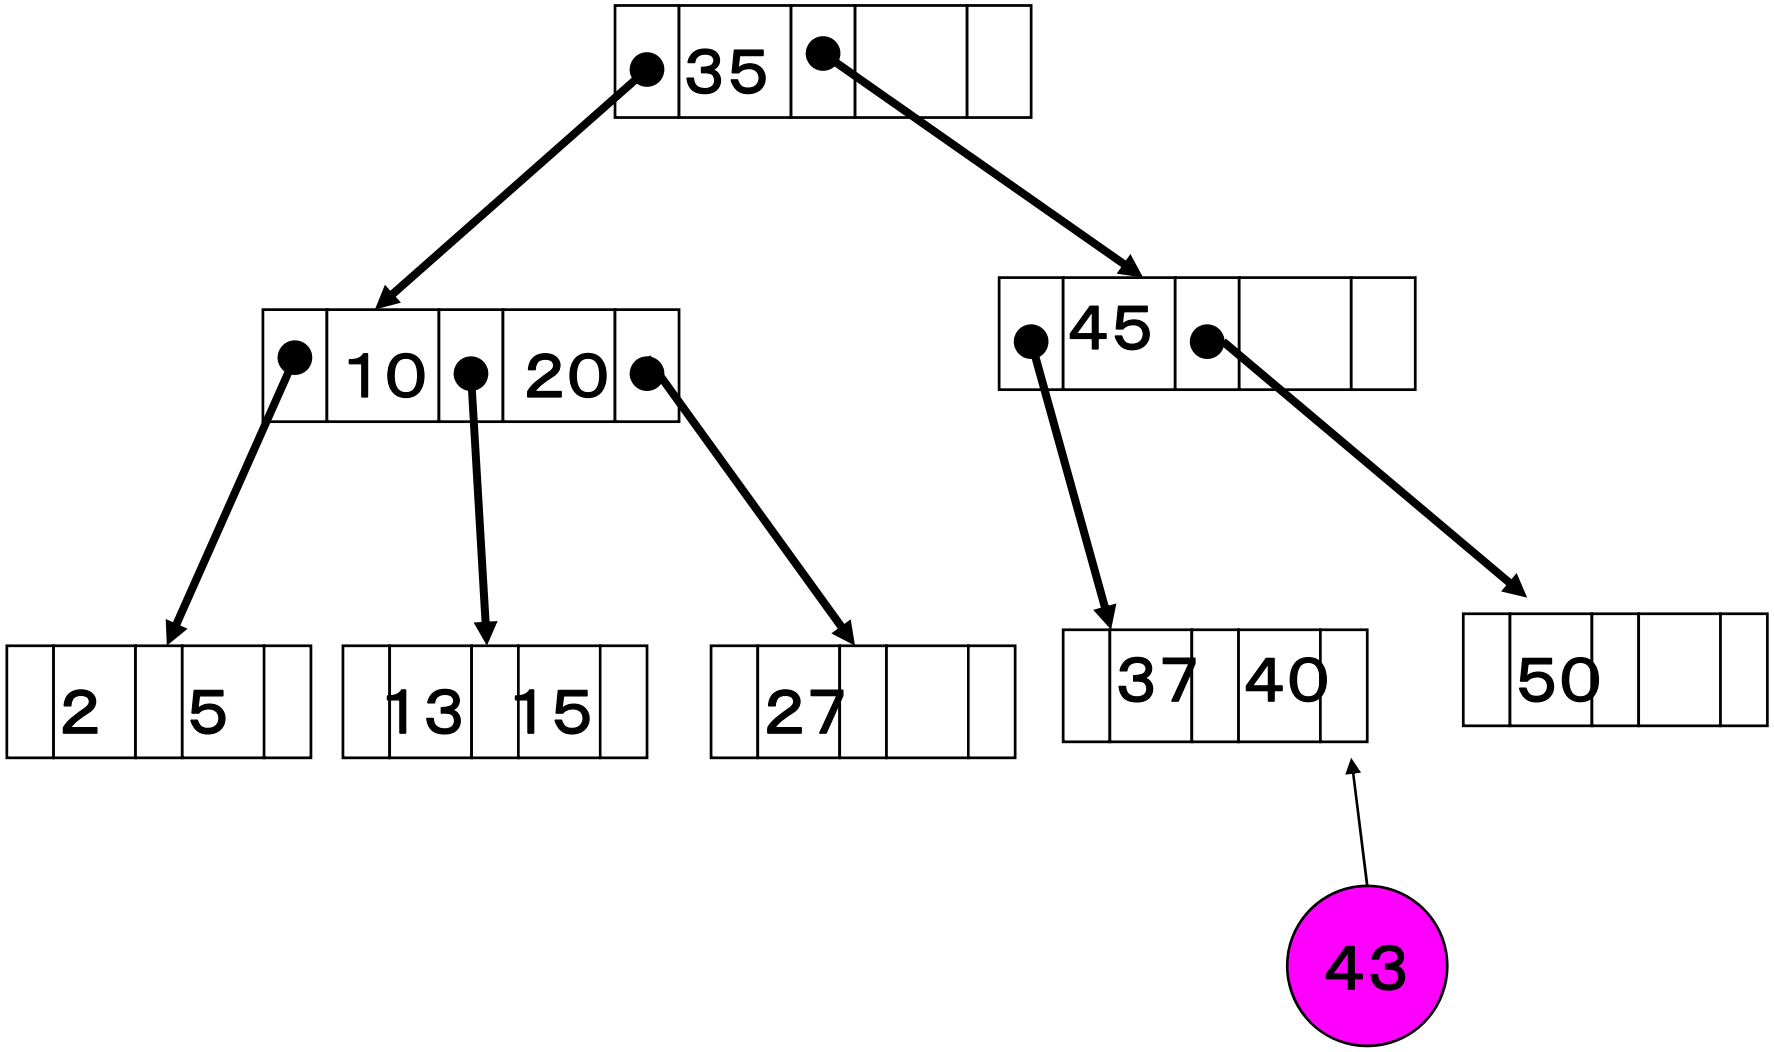

オーバーフロー時のノード分割2

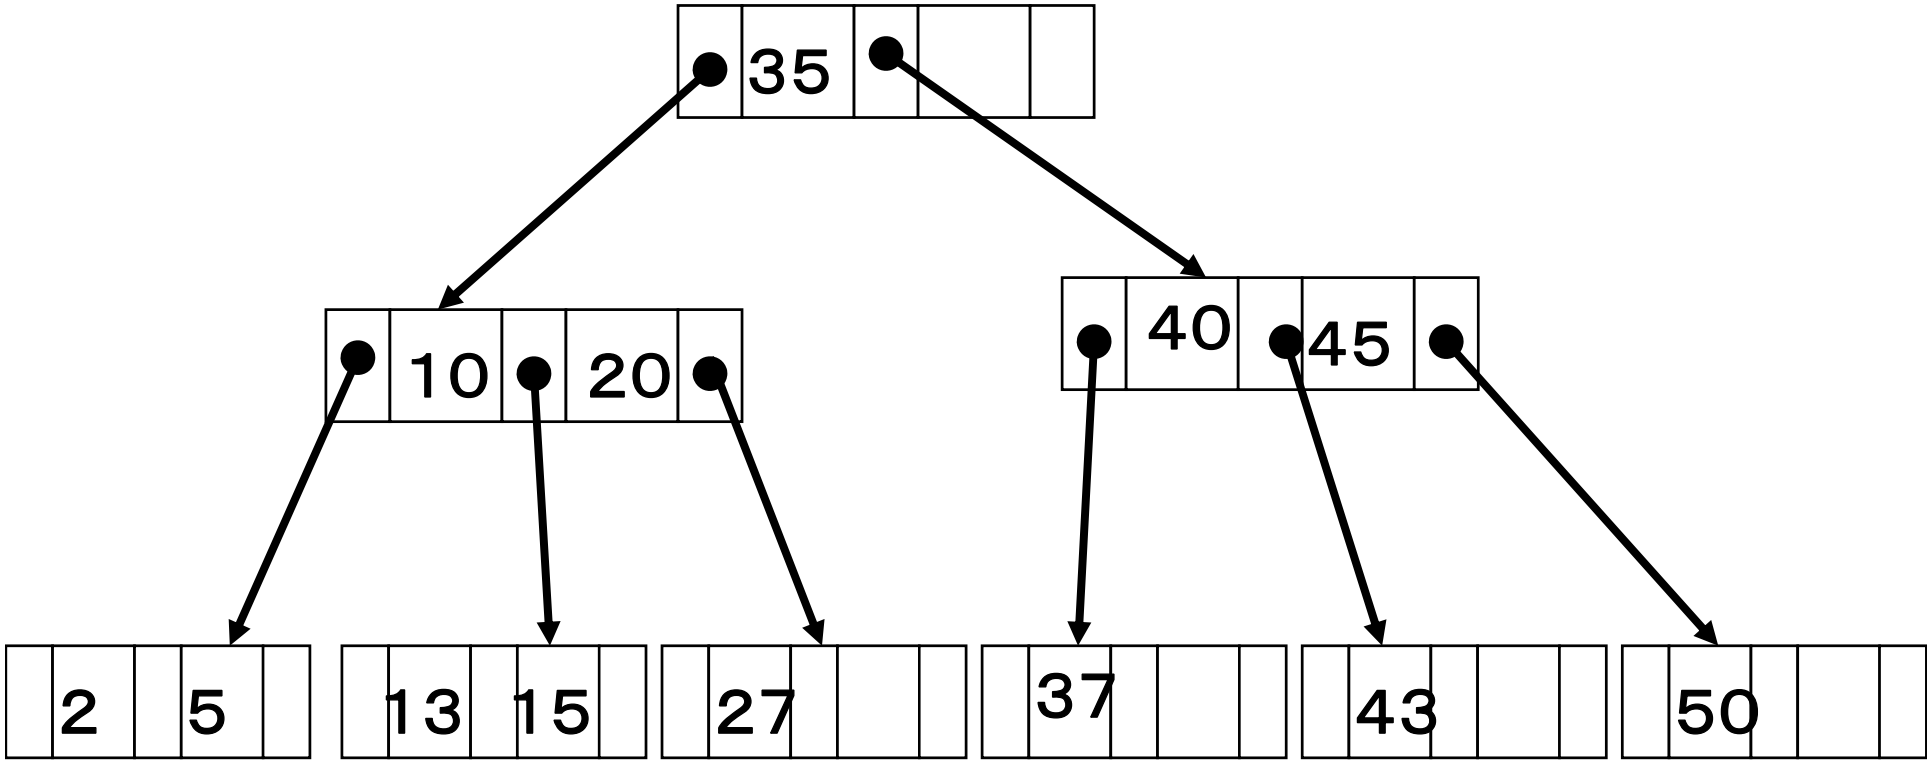

オーバーフローが起きたときには、ノードを分割して、親に向かって
再帰的にB木の条件を満足するように更新していく。

B木からの削除

delete(50)

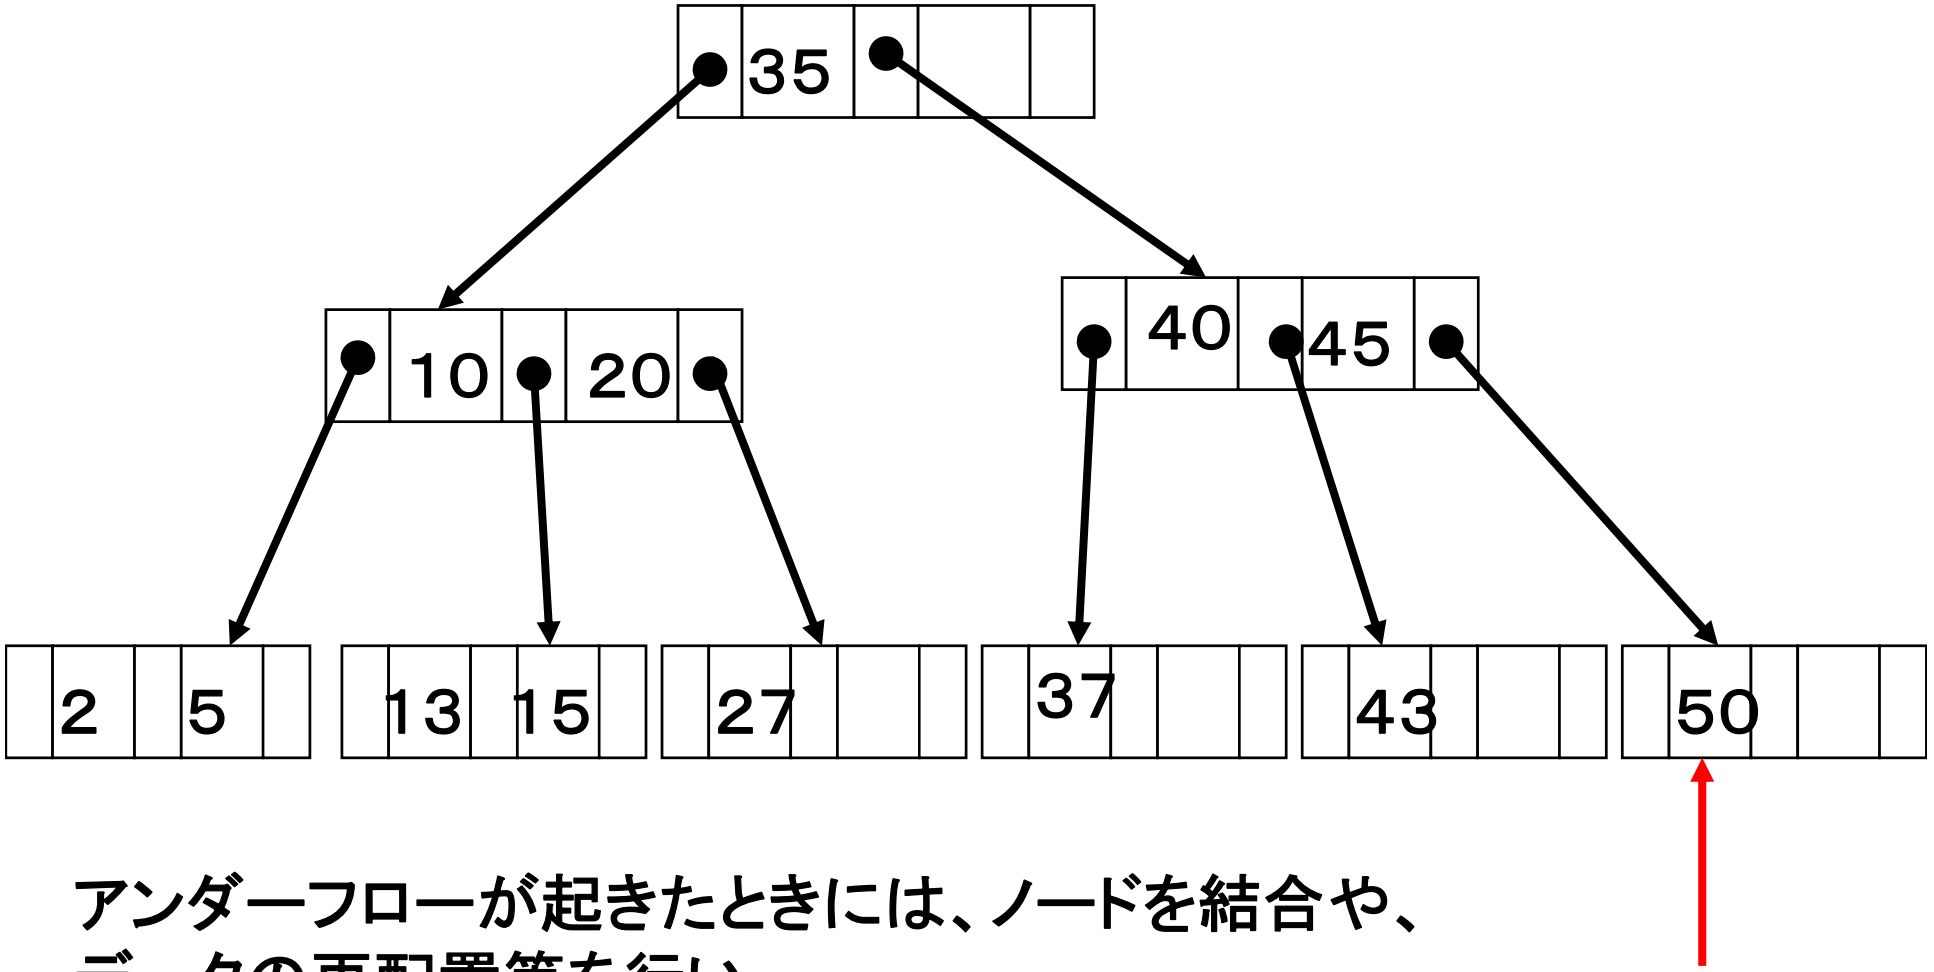

アンダーフローが起きたときには、ノードを結合や、
データの再配置等を行い、
再帰的にB木の条件を満足するように更新していく。

アンダーフローにおけるデータの再配置

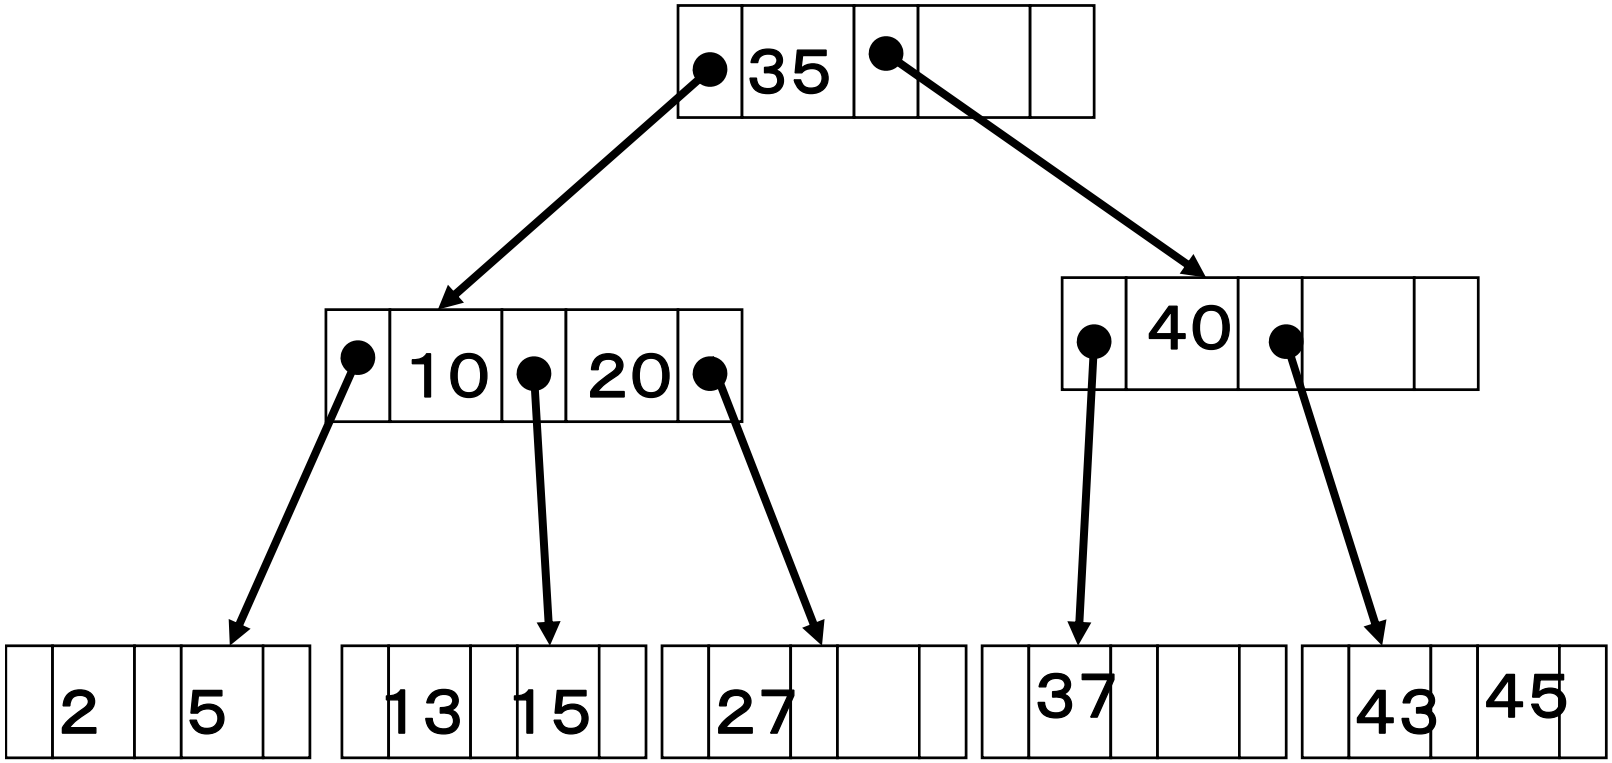

アンダーフローが起きたときには、ノードを結合や、
データの再配置等を行い、
再帰的にB木の条件を満足するように更新していく。

B木の最悪計算量

- B木の高さが、$O(\log_d n)$ であることに注意する。
- また、1つのノードを処理するために、$O(m)$時間必要である。
- 以上より、各操作は、最悪時間計算量として、

$$O(m + \log_{\lfloor \frac{m}{2} \rfloor} n)$$

時間である。パラメータ m の値により性能に違いが生じる。$m = \Omega(n)$ とすると高速に動作しない

B木の応用

- ディスクアクセスは、メモリアクセスに比べて極端に遅い。したがって、ある程度もまとまったデータを1度の読み込んだ方が全体として高速に動作することが多い。
- よって、B木の各ノードに蓄えられているデータを、一度に読み込むようにすれば、ディスクアクセスの回数が軽減される。
- 各ノード内の処理は、メモリ上で効率よく実現できる。

平衡木のまとめ

- 平衡木の高さは、

$$O(\log n)$$

  となる。
- 平衡を実現するための条件により、各種平衡木が定義される。
- 平衡状態を満足するために、各種バランス回復処理が行われる。