

École Polytechnique

CSC_41011

Les bases de la programmation et de l'algorithmique

Jean-Christophe Filliâtre

arbres (1/2)

le **mardi de 18h45 à 20h45** en salle info 31, avec Lola Mallordy

- mardi 24 septembre (**demain**)
- mardi 1er octobre
_____pale machine 8 octobre
- mardi 8 octobre
- mardi 15 octobre
- mardi 22 octobre
- mardi 5 novembre
_____contrôle classant 13 novembre

Inscrivez-vous ! (par mail à tutorat.1a-2a@polytechnique.fr)

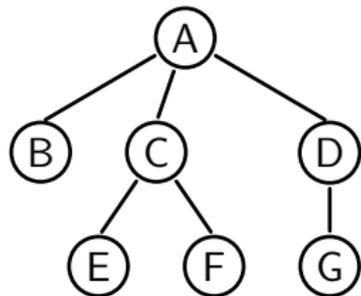
1. arbres
2. arbres binaires de recherche
 - réalisation
 - encapsulation
 - efficacité
3. équilibrage
4. code générique, bibliothèque Java

arbres



vocabulaire introduit en INF361

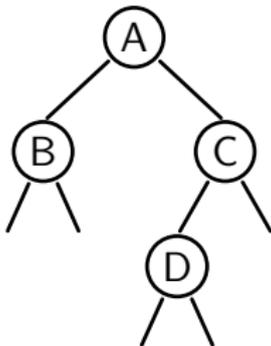
- racine (ici A)
- nœuds
- feuilles (ici B, E, F, G)
- hauteur (ici 3)



(si besoin voir le poly page 75)

un **arbre binaire** est

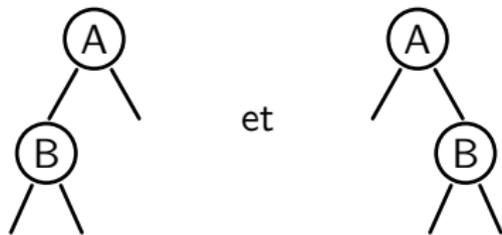
- soit vide
- soit un nœud avec deux sous-arbres qui sont des arbres binaires



les deux sous-arbres sont appelés

sous-arbre gauche et **sous-arbre droit**

les deux arbres binaires



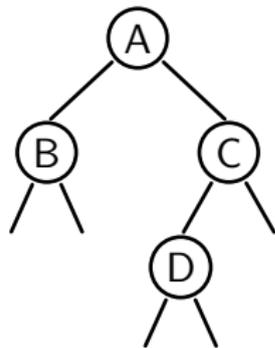
sont **différents**

(on parle d'arbre **positionnel**)

la **hauteur** d'un arbre binaire est le plus grand nombre de nœuds le long d'un chemin de la racine à une feuille

en particulier, l'arbre vide a la hauteur 0

exemple : l'arbre ci-contre a la hauteur 3



Propriété

Pour tout arbre binaire possédant N nœuds et de hauteur h , on a

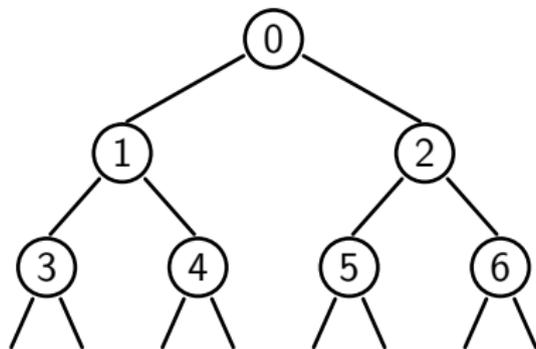
$$h \leq N \leq 2^h - 1.$$

par récurrence forte sur h

- pour $h = 0$ c'est clair
- pour $h > 0$, on a deux sous-arbres de hauteurs $h_1, h_2 < h$, l'un des deux étant de hauteur $h - 1$, donc au moins $h - 1 + 1$ nœuds et au plus

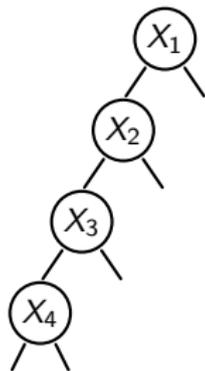
$$\begin{aligned} & 1 + 2^{h_1} - 1 + 2^{h_2} - 1 \\ \leq & 1 + 2^{h-1} - 1 + 2^{h-1} - 1 \\ = & 2^h - 1 \end{aligned}$$

atteint pour un arbre binaire **parfait**

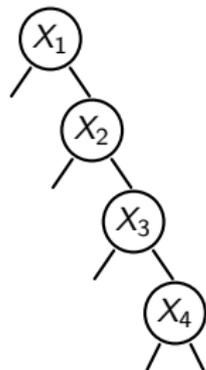
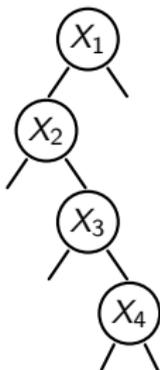


(toutes les feuilles sont à la même distance de la racine)

atteint pour un arbre **linéaire**



arbre linéaire gauche



arbre linéaire droit

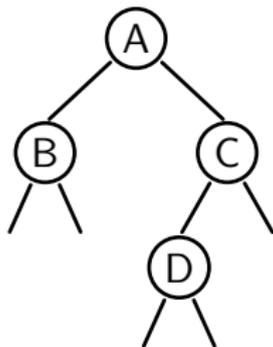
un arbre linéaire gauche ou droit est aussi appelé un **peigne**

```
class Tree {
    String value;          // noeud étiqueté ici par une chaîne
    Tree left, right;
```

et un constructeur

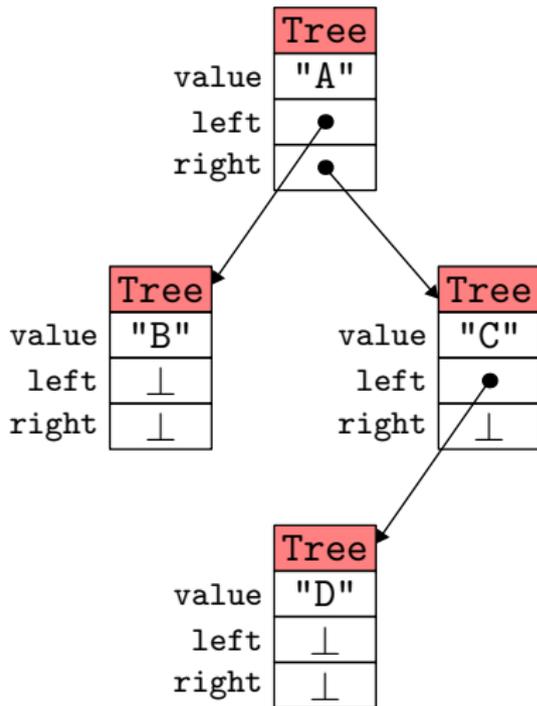
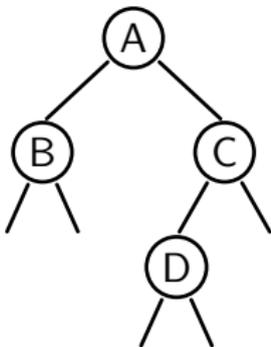
```
Tree(Tree left, String value, Tree right) { ... }
```

l'arbre vide est ici représenté par null

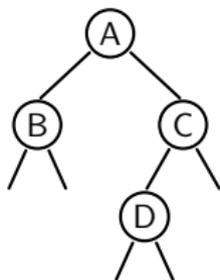


```
Tree t =  
  new Tree(new Tree(null, "B", null),  
           "A",  
           new Tree (new Tree(null, "D", null),  
                    "C",  
                    null));
```

```
class Tree {
  String value;
  Tree left, right;
}
```



```
static void inorderTraversal(Tree t) {  
    if (t == null) return;  
    inorderTraversal(t.left);  
    System.out.println(t.value); // infixe  
    inorderTraversal(t.right);  
}
```



B, A, D, C

(on écrit de même un parcours préfixe ou postfixe)

et si on ne veut pas afficher, mais renvoyer le résultat du parcours ?

par exemple

```
static LinkedList<String> inorder(Tree t) { ... }
```

une écriture directe, récursive

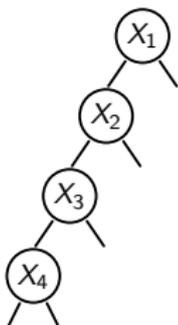
```
static LinkedList<String> inorder(Tree t) {  
    LinkedList<String> c = new LinkedList<String>();  
    if (t == null) return c;  
    c.addAll(inorder(t.left));  
    c.add(t.value);  
    c.addAll(inorder(t.right));  
    return c;  
}
```

on se sert ici de `c.addAll(l)`

qui ajoute tous les éléments de la liste `l` à la liste `c`

c'est naïf, car `addAll(1)` coûte $O(1.size())$

le coût total sur un peigne est $O(N^2)$



$$\begin{aligned}
 C_N &= C_{N-1} + \underbrace{N-1}_{\text{addAll}} + \underbrace{1}_{\text{add}} \\
 &= 1 + 2 + \dots + N \\
 &= O(N^2)
 \end{aligned}$$

une méthode qui **accumule** dans une unique liste c

```
static void inorder(Tree t, LinkedList<String> c) {  
    if (t == null) return;  
    inorder(t.left, c);  
    c.add(t.value);  
    inorder(t.right, c);  
}
```

il suffit de l'appeler initialement avec une liste vide

```
static LinkedList<String> inorder(Tree t) {  
    LinkedList<String> c = new LinkedList<String>();  
    inorder(t, c);  
    return c;  
}
```

note : une seule liste est manipulée

arbres binaires de recherche

pour obtenir une **structure d'ensemble** telle que

```
class Set<E> {
    Set()
    boolean contains(E x)
    void add(E x)
    void remove(E x)
}
```

on connaît déjà plusieurs solutions

	add	contains	remove
tableau non trié	$O(1)$	$O(N)$	$O(N)$
liste	$O(1)$	$O(N)$	$O(N)$
tableau trié	$O(N)$	$O(\log N)$	$O(N)$
table de hachage	$O(1)$	$O(1)$	$O(1)$

(idem pour un dictionnaire)

on dispose parfois d'un **ordre total** sur les éléments

exemples

- ordre usuel sur \mathbb{Z}
- ordre lexicographique sur les chaînes de caractères
- événements triés par date
- etc.

dans ce cas, on peut attendre d'**autres opérations** sur les ensembles

```
class Set<E> {  
    ...  
    E getMin()  
    E getMax()  
    E floor(E x)  
    E ceiling(E x)  
    int rank(E x)  
    E select(int i)  
    Collection<E> range(E lo, E hi)  
}
```

un **agenda** est un dictionnaire qui associe des événements à des dates

on veut pouvoir

- ajouter/modifier/supprimer des entrées
- trouver les entrées correspondant à une période donnée (par exemple pour afficher une semaine ou un mois donné)

une structure de données ensemble/dictionnaire où les opérations

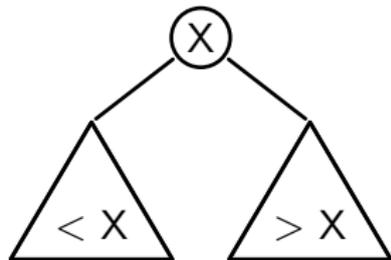
add, contains, remove, getMin, getMax,
floor, ceiling, rank, select

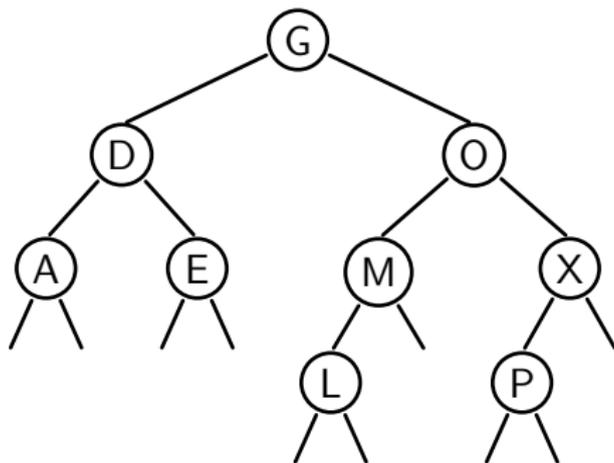
sont toutes de complexité au pire $O(\log N)$

un **arbre binaire de recherche** (en anglais *binary search tree*)
est un arbre binaire où

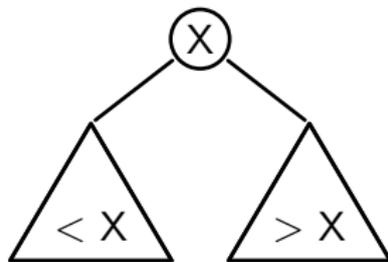
pour tout nœud X

- les éléments du sous-arbre gauche sont $< X$
- les éléments du sous-arbre droit sont $> X$

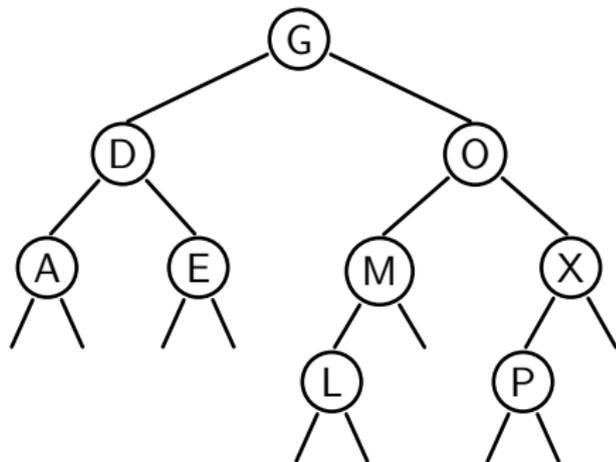




pour chercher / ajouter / supprimer / etc.
on ne considère qu'**un seul côté** de l'arbre

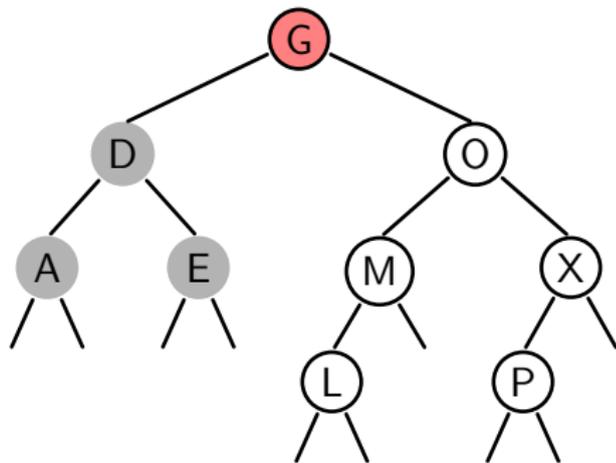


on compare M et G



$G < M \Rightarrow$ on va à droite

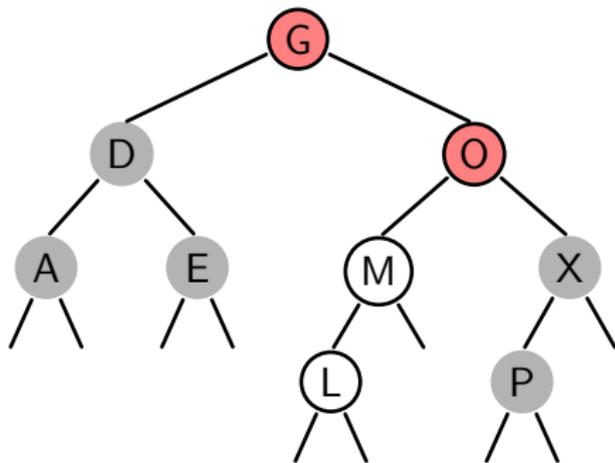
on compare M et O



$G < M \Rightarrow$ on va à droite

$M < O \Rightarrow$ on va à gauche

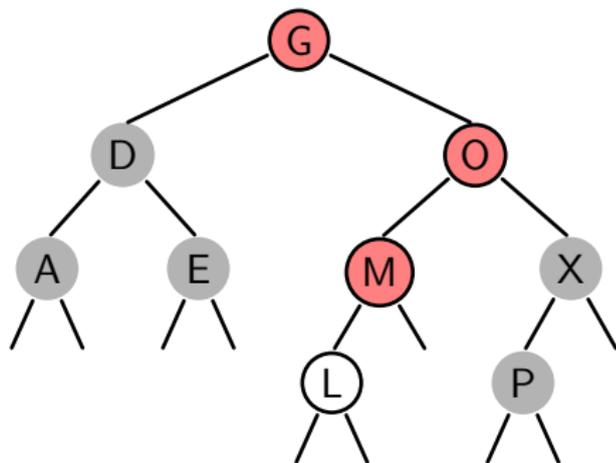
on compare M et M



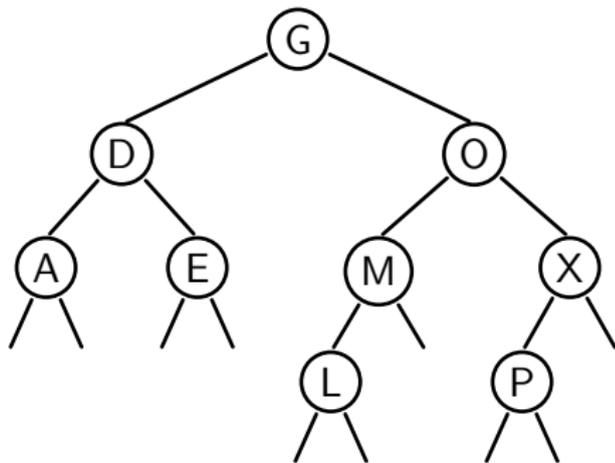
$G < M \Rightarrow$ on va à droite

$M < O \Rightarrow$ on va à gauche

$M = M \Rightarrow$ succès

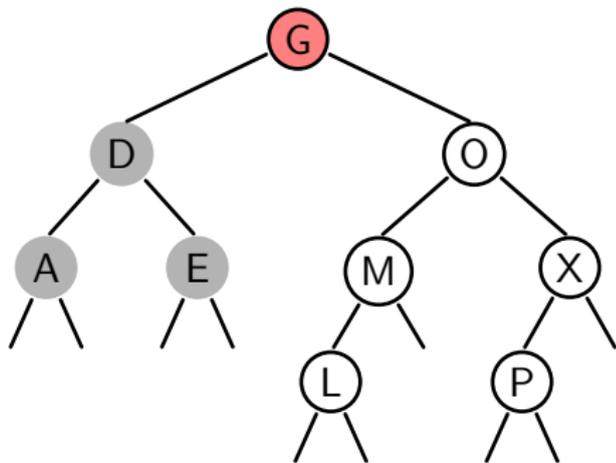


on compare N et G



$G < N \Rightarrow$ on va à droite

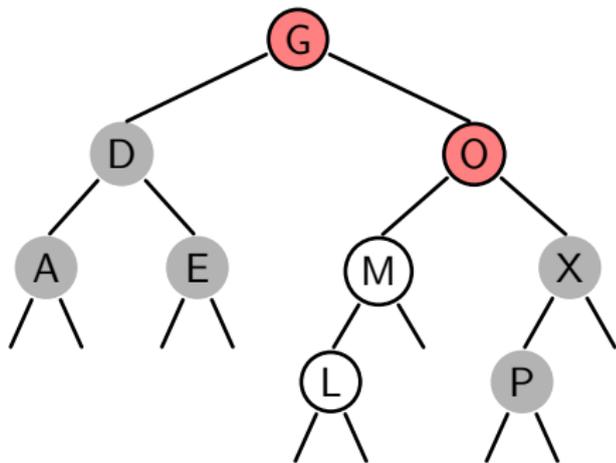
on compare N et O



$G < N \Rightarrow$ on va à droite

$N < O \Rightarrow$ on va à gauche

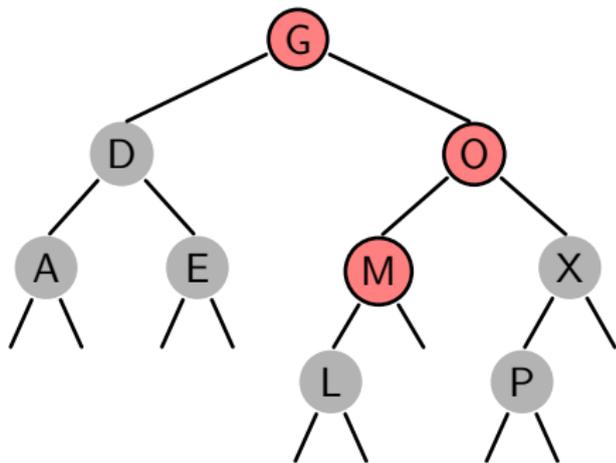
on compare M et N



$G < N \Rightarrow$ on va à droite

$N < O \Rightarrow$ on va à gauche

$M < N \Rightarrow$ on va à droite

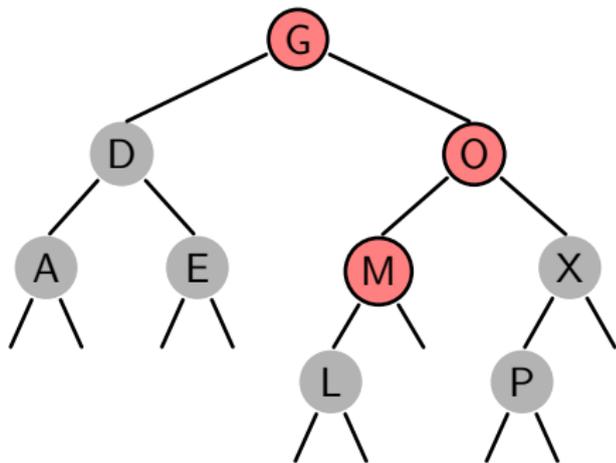


$G < N \Rightarrow$ on va à droite

$N < O \Rightarrow$ on va à gauche

$M < N \Rightarrow$ on va à droite

arbre vide \Rightarrow échec



pour des éléments de type `String` pour l'instant

ordonnés lexicographiquement avec `compareTo`

s1	s2	s1.compareTo(s2)
"bar"	"foo"	< 0
"foo"	"foo"	= 0
"foo"	"fool"	< 0
"small"	"big"	> 0
etc.		

on va procéder en deux temps

1. on commence par une classe BST

- représente un nœud de l'arbre et `null` est l'arbre vide
- les méthodes sont **statiques**, pour faciliter la manipulation de `null`

2. on construit ensuite une classe Set

- encapsule un arbre, pour cacher la représentation
- les méthodes sont **dynamiques**, pour faciliter l'utilisation

```
class BST {  
    String value;  
    BST    left, right;  
    ...  
}
```

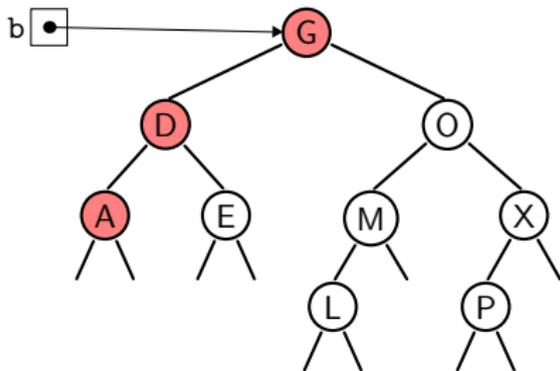
et un constructeur

```
BST(BST left, String value, BST right) { ... }
```

plus petit élément

le plus petit élément est tout en bas à gauche

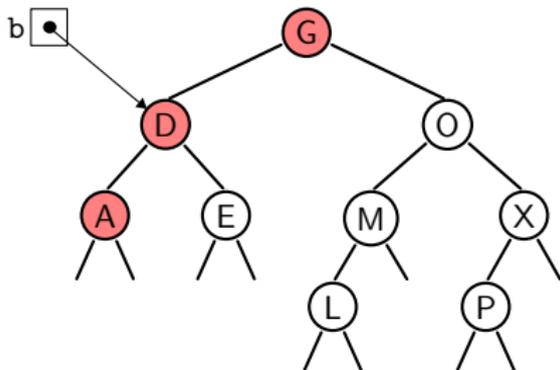
```
// suppose b != null
static String getMin(BST b) {
    while (b.left != null)
        b = b.left;
    return b.value;
}
```



note : on ne modifie que la **variable b locale** à getMin

le plus petit élément est tout en bas à gauche

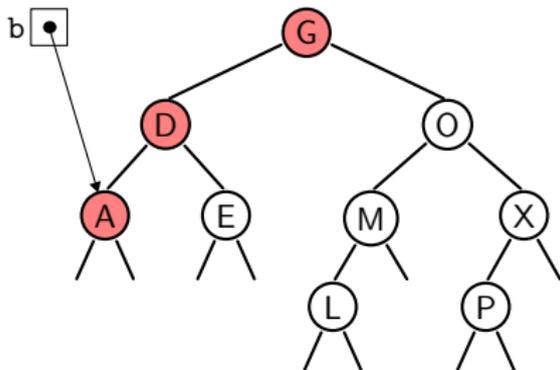
```
// suppose b != null
static String getMin(BST b) {
    while (b.left != null)
        b = b.left;
    return b.value;
}
```



note : on ne modifie que la **variable b locale** à getMin

le plus petit élément est tout en bas à gauche

```
// suppose b != null
static String getMin(BST b) {
    while (b.left != null)
        b = b.left;
    return b.value;
}
```

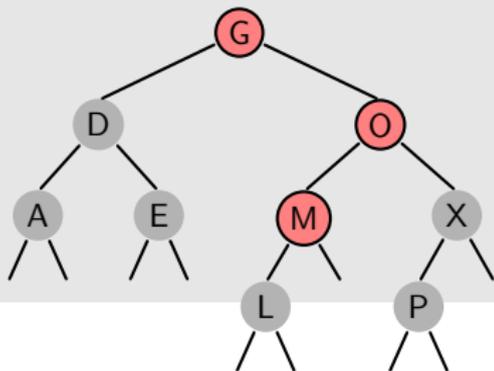


note : on ne modifie que la **variable b locale** à getMin

rechercher un élément

on descend dans l'arbre

```
static boolean contains(BST b, String x) {  
    while (b != null) {  
        int c = x.compareTo(b.value);  
        if (c == 0) return true;  
        b = (c < 0) ? b.left : b.right;  
    }  
    return false;  
}
```

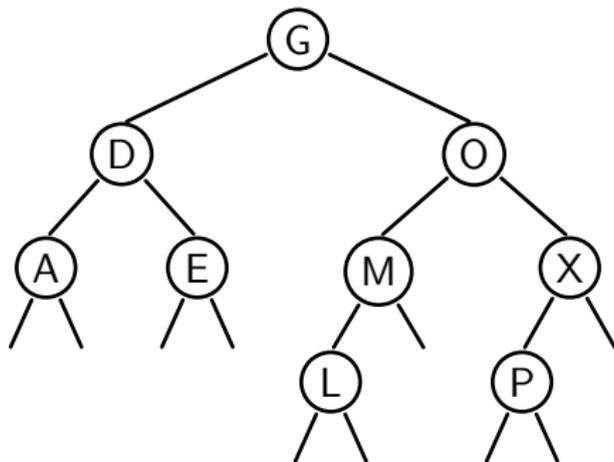


(exercice : l'écrire comme une méthode récursive)

ajouter un élément

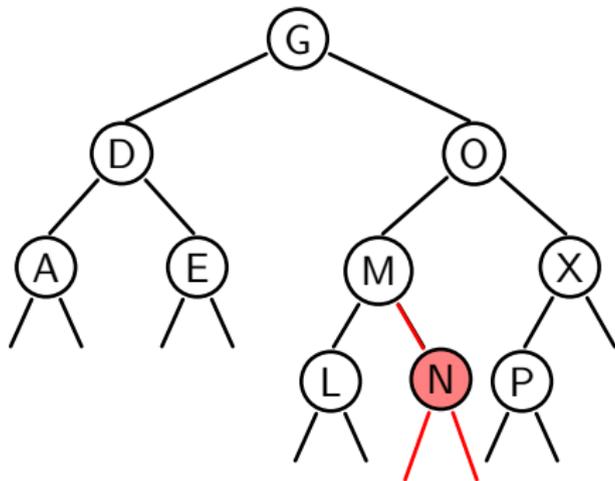
on descend dans l'arbre pour ajouter une nouvelle feuille au bon endroit

exemple : ajout de N



on descend dans l'arbre pour ajouter une nouvelle feuille au bon endroit

exemple : ajout de N



on crée **un** nouveau nœud N et on **modifie** le pointeur droit de M

comment écrire un tel code,
qui doit pouvoir insérer en particulier dans l'arbre vide `null` ?

solution retenue ici : une méthode récursive

```
static BST add(BST b, String x)
```

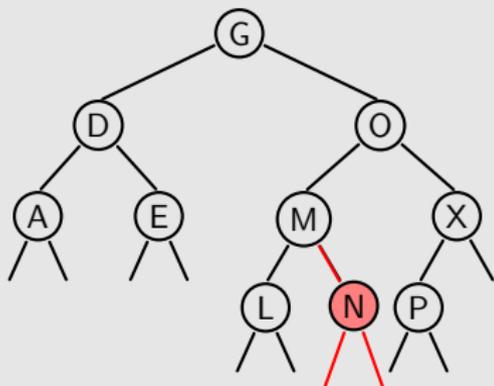
qui renvoie la racine de l'arbre une fois l'insertion réalisée

(ce n'est pas la seule solution ; voir l'exercice 39 dans le poly)

```

static BST add(BST b, String x) {
    if (b == null)
        return new BST(null, x, null);
    int c = x.compareTo(b.value);
    if (c < 0)
        b.left = add(b.left, x);
    else if (c > 0)
        b.right = add(b.right, x);
    return b;
}

```

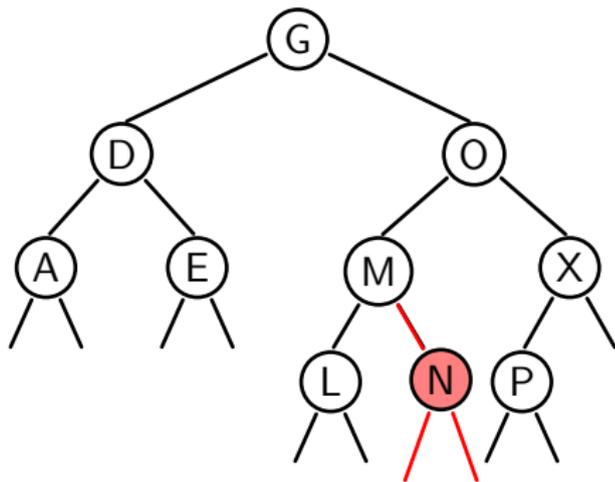


(pas de doublons : c'est un ensemble, pas un multi-ensemble)

on a fait trois affectations

- le sous-arbre droit de G
- le sous-arbre gauche de O
- le sous-arbre droit de M

seule la dernière a vraiment
modifié l'arbre



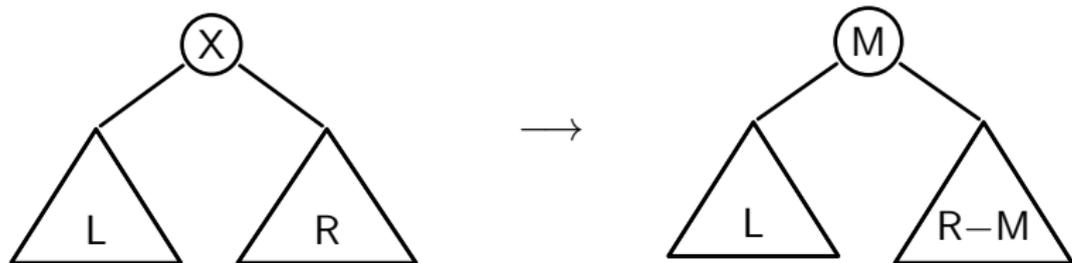
supprimer un élément

commence exactement comme l'insertion

```
static BST remove(BST b, String x) {
    if (b == null)
        return null; // rien à faire
    int c = x.compareTo(b.value);
    if (c < 0) // suppression à gauche
        b.left = remove(b.left, x);
    else if (c > 0) // suppression à droite
        b.right = remove(b.right, x);
    else { // suppression de la racine
        ...?...
    }
}
```

que faire quand il faut supprimer la racine ?

remplacer X par $M = \min(R)$



nous ramène au problème de la suppression du minimum,

plus simple

en effet

```
static BST removeMin(BST b) { // b != null
    if (b.left == null) // on supprime racine
        return b.right;
    b.left = removeMin(b.left);
    return b;
}
```

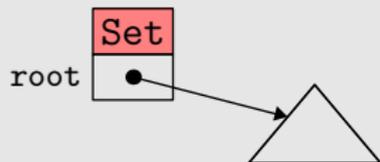
on peut maintenant terminer remove

```
static BST remove(BST b, String x) {  
    ...  
    else { // suppression de la racine  
        if (b.right == null) // cas simple  
            return b.left;  
        b.value = getMin(b.right);  
        b.right = removeMin(b.right);  
    }  
    return b;  
}
```

encapsulation

comme pour les listes (cf amphi 1), on termine en **encapsulant** l'arbre binaire de recherche dans une classe

```
class Set {  
    private BST root;  
  
    Set() { this.root = null; }  
  
    boolean isEmpty() {  
        return this.root == null;  
    }  
  
    boolean contains(String x) {  
        return BST.contains(this.root, x);  
    }  
    ...  
}
```

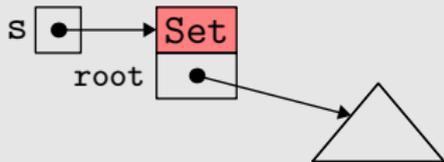


en particulier, les méthodes `add` et `remove` ne renvoient plus rien

```
class Set {  
    ...  
  
    void add(String x) {  
        this.root = BST.add(this.root, x);  
    }  
  
    void remove(String x) {  
        this.root = BST.remove(this.root, x);  
    }  
}
```

l'utilisation n'est pas différente de celle de HashSet

```
Set s = new Set();  
...  
s.add("foo");  
...  
if (s.isEmpty()) // et non s == null  
    ...
```



en particulier, l'utilisateur ignore la représentation interne (*i.e.* l'existence de la classe BST et le rôle joué par null)

complexité

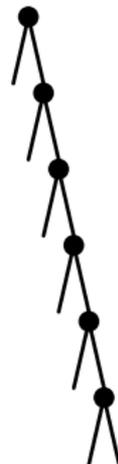
on peut décompter les comparaisons effectuées

cas de figure considéré

1. insertion successive de N éléments dans un arbre initialement vide
2. recherche dans cet arbre

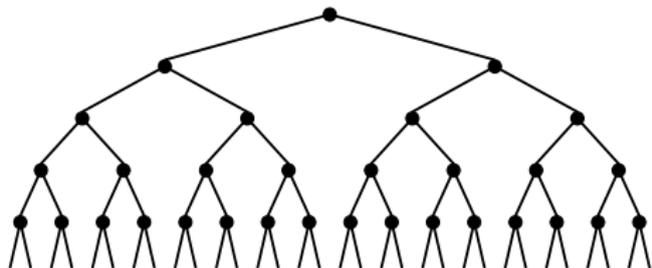
si on est malchanceux
l'arbre peut être un peigne
(éléments insérés dans l'ordre)

k -ième add en $O(k)$
construction totale en $O(N^2)$
contains en $O(N)$



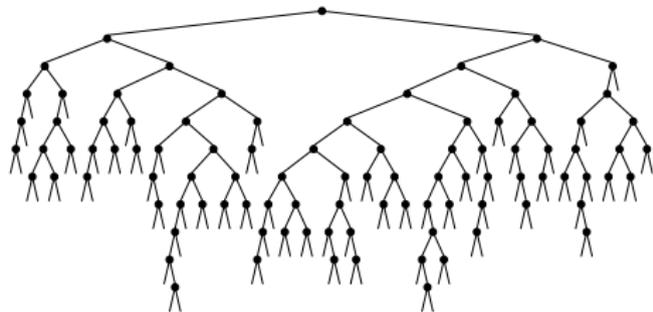
si on est (très) chanceux
l'arbre peut être parfait

chaque add en $O(\log N)$
construction totale en $O(N \log N)$
contains en $O(\log N)$



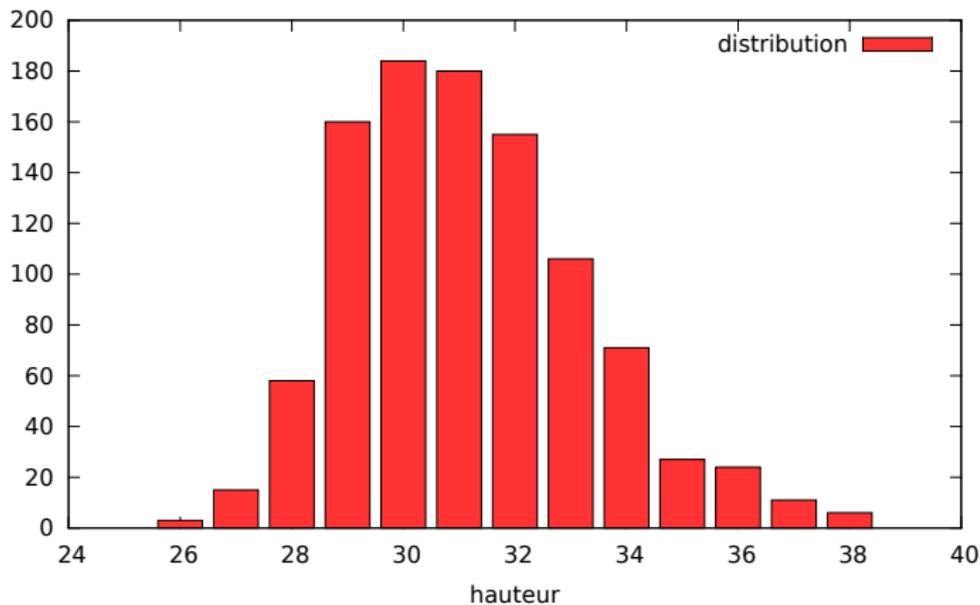
N valeurs aléatoires

on observe la hauteur obtenue



$N = 100$, hauteur 11

résultats pour $N = 10\,000$ (répété 1000 fois)



on peut montrer que

l'insertion et la recherche dans un ABR construit avec N valeurs aléatoires coûte **en moyenne** $2 \ln N$ comparaisons

les valeurs ne suivent pas toujours une distribution aléatoire

comment éviter les cas pathologiques ?

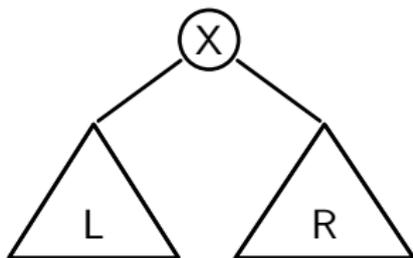
arbres binaires de recherche **équilibrés**

garantir une hauteur **logarithmique**

un arbre contenant N valeurs a une hauteur $\leq C \cdot \log N$

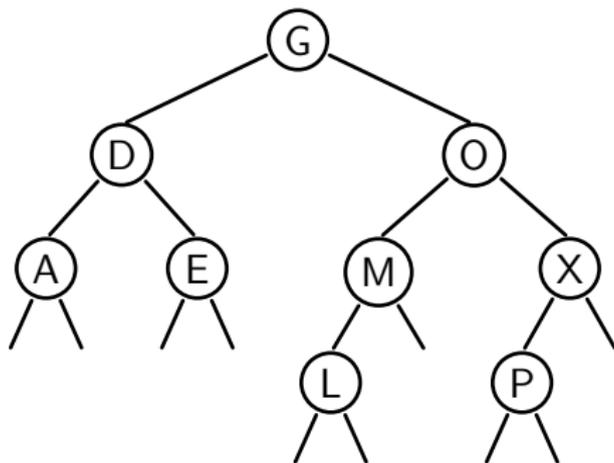
solution présentée ici : les arbres **AVL**
(de leurs auteurs **A**delson-**V**elsky et **L**andis)

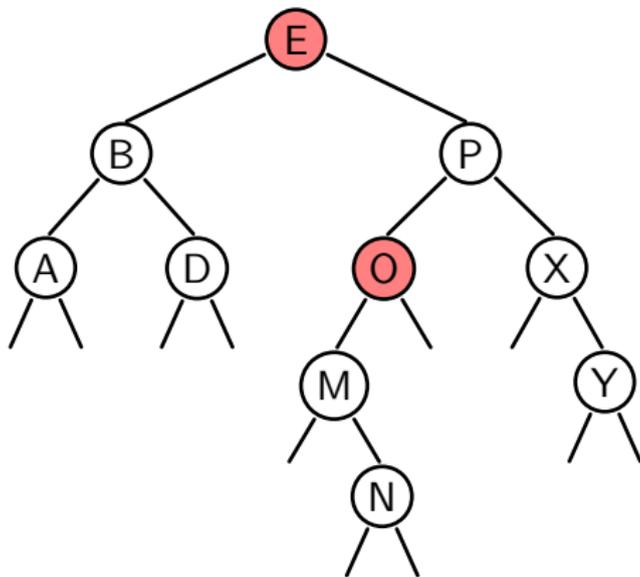
un arbre binaire de recherche est un **AVL** si,
pour tout nœud



on a

$$|\text{hauteur}(L) - \text{hauteur}(R)| \leq 1$$





quelle est la hauteur maximale d'un AVL contenant N nœuds ?

posons le problème inversement :

quel est le nombre minimal N_h de nœuds dans un AVL de hauteur h ?

N_h = nombre minimal de nœuds dans un AVL de hauteur h

$$\begin{cases} N_1 = 1 \\ N_2 = 2 \\ N_h = 1 + N_{h-1} + N_{h-2} \end{cases}$$

en ajoutant 1, on reconnaît la suite de Fibonacci (0, 1, 1, 2, 3, 5, 8, ...)

$$\begin{cases} N_1 + 1 = 2 \\ N_2 + 1 = 3 \\ N_h + 1 = (N_{h-1} + 1) + (N_{h-2} + 1) \end{cases}$$

c'est-à-dire

$$N_h + 1 = F_{h+2}$$

or on a l'inégalité $F_i > \phi^i / \sqrt{5} - 1$ avec $\phi = \frac{1+\sqrt{5}}{2}$ (nombre d'or)

donc

$$N \geq N_h = F_{h+2} - 1 > \phi^{h+2} / \sqrt{5} - 2$$

d'où finalement

$$\begin{aligned} h &< \frac{1}{\log_2 \phi} \log_2(N+2) + \frac{\log_2 \sqrt{5}}{\log_2 \phi} - 2 \\ &\approx 1,44 \log_2(N+2) - 0,328 \end{aligned}$$

la hauteur d'un AVL est bien **logarithmique**

mise en œuvre en Java

la classe BST devient une classe AVL
avec un champ supplémentaire contenant la hauteur

```
class AVL {  
    String value;  
    AVL left, right;  
    int height;
```

et une méthode pour la renvoyer

```
static int height(AVL a) {  
    return (a == null) ? 0 : a.height;  
}
```

le constructeur calcule la hauteur (en temps constant!)

```
AVL(AVL left, String value, AVL right) {  
    this.left = left;  
    this.value = value;  
    this.right = right;  
    this.height = 1 + Math.max(height(left), height(right));  
}
```

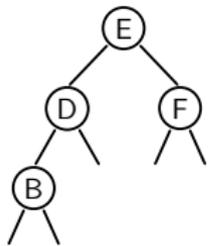
(pas de circularité : left et right sont déjà construits)

un AVL est un arbre binaire de recherche

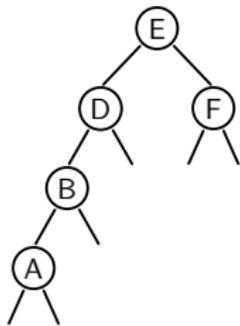
⇒ certaines méthodes sont inchangées

```
static boolean contains(AVL a, String x) { ... }  
static String  getMin  (AVL a          ) { ... }
```

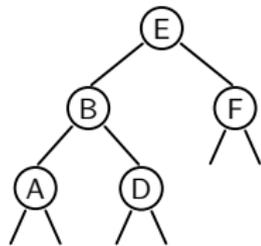
pour les méthodes qui construisent des arbres, en revanche,
il va falloir **équilibrer**



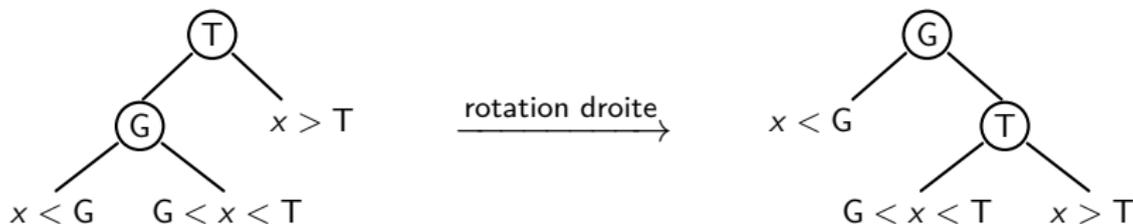
add("A")
→



rot. B
→

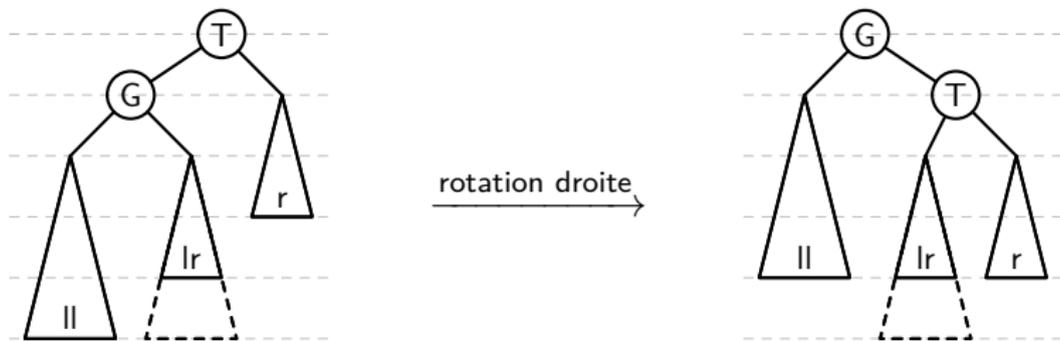


une **rotation à droite** conserve la propriété d'ABR

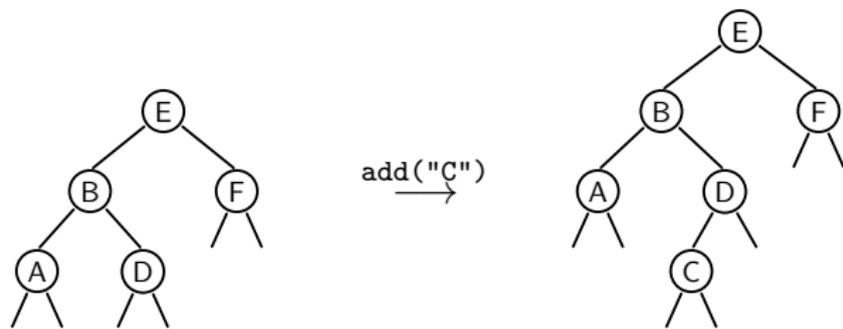


(de même pour une **rotation à gauche**)

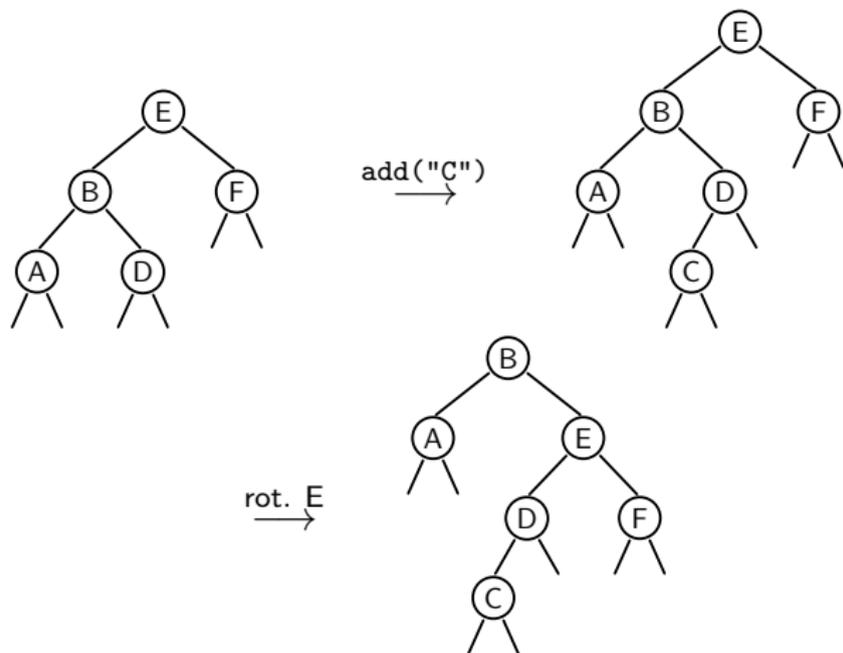
la rotation permet de rétablir la propriété d'AVL
quand le déséquilibre provient du sous-arbre gauche du sous-arbre gauche



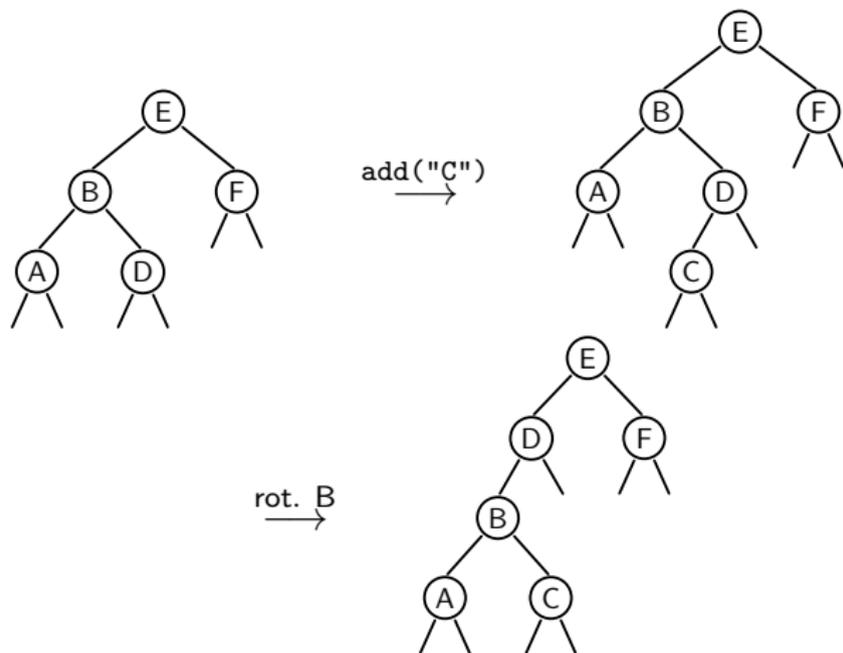
une seule rotation ne suffit pas toujours



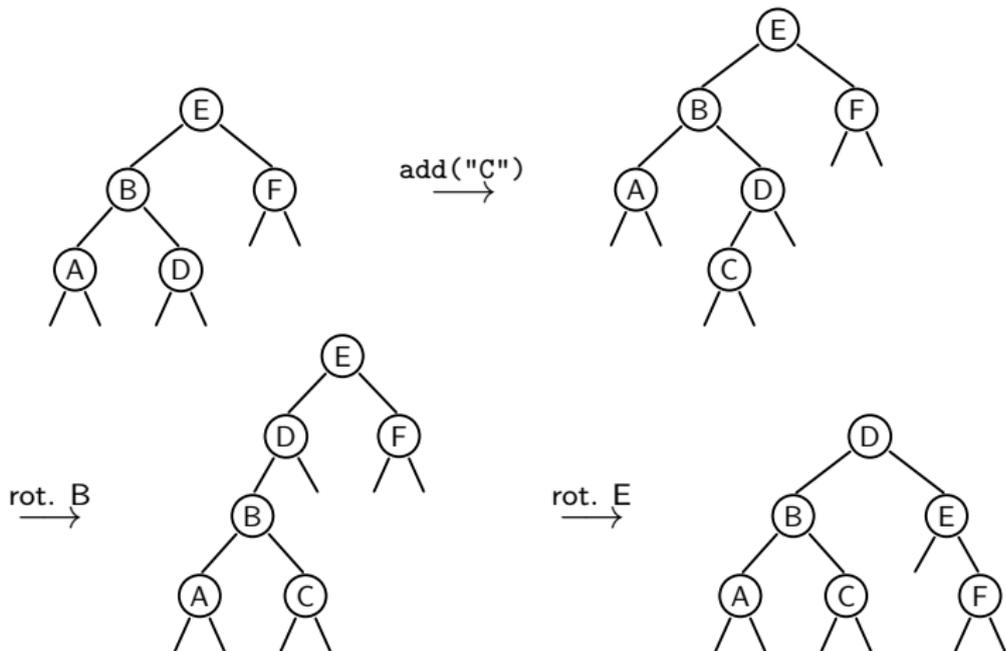
une seule rotation ne suffit pas toujours



une seule rotation ne suffit pas toujours



une seule rotation ne suffit pas toujours



la rotation gauche-droite permet de rétablir la propriété d'AVL
 quand le déséquilibre provient du sous-arbre droit du sous-arbre gauche



de manière symétrique,
on peut rétablir l'équilibre en cas d'insertion à droite

(soit par une rotation gauche, soit par une rotation droite-gauche)

écrivons une méthode

```
static AVL balance(AVL t) {  
    ...  
}
```

qui se comporte comme l'identité,
en rétablissant l'équilibrage à la racine si nécessaire

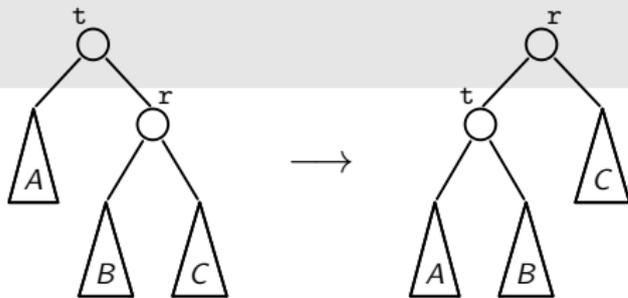
```

private static AVL balance(AVL t) { // t != null
    AVL l = t.left, r = t.right;
    int hl = height(l), hr = height(r);
    if (hl > hr + 1) { // déséquilibre à gauche
        AVL ll = l.left, lr = l.right;
        if (height(ll) >= height(lr))
            return rotateRight(t);
        else {
            t.left = rotateLeft(t.left);
            return rotateRight(t);
        }
    } else if (hr > hl + 1) { // déséquilibre à droite
        ... // symétrique
    } else {
        t.height = 1 + Math.max(hl, hr);
        return t;
    }
}
}

```

principe : une méthode de rotation renvoie la nouvelle racine

```
private static AVL rotateLeft(AVL t) {
    assert t != null && t.right != null;
    AVL r = t.right;
    t.right = r.left;
    r.left = t;
    t.height = 1 + Math.max(height(t.left), height(t.right));
    r.height = 1 + Math.max(height(r.left), height(r.right));
    return r;
}
```



de même pour la rotation droite (cf poly)

le **même code** qu'auparavant, avec `balance` ajouté dans la dernière instruction

```
static AVL add(AVL b, String x) {  
    ...  
    return balance(b);  
}  
static AVL removeMin(AVL b) {  
    ...  
    return balance(b);  
}  
static AVL remove(AVL b, String x) {  
    ...  
    return balance(b);  
}
```

l'encapsulation dans une classe Set reste exactement la même
(en remplaçant partout BST par AVL)

on a vu que la hauteur est inférieure à $1,44 \log_2(N)$

⇒ chaque recherche, insertion ou suppression a un coût en $O(\log N)$

il existe d'autres techniques pour équilibrer les arbres binaires de recherche
notamment les arbres **rouges et noirs**

code générique

et si les éléments ne sont pas des chaînes ?

```
class BST<E> {  
    E      value;  
    BST<E> left, right;  
    ...  
}
```

on a besoin de pouvoir **comparer** les valeurs de type E

on veut pouvoir écrire `x.compareTo(y)` pour deux valeurs de type `E`

dans la bibliothèque Java, on trouve

```
interface Comparable<T> {  
    int compareTo(T k);  
}
```

on exige de E qu'elle implémente l'interface Comparable<E>

```
class BST<E extends Comparable<E>> {  
    E    value;  
    BST<E> left, right;  
    ...  
}
```

dans BST, on doit écrire

```
static<E extends Comparable<E>>  
boolean contains(BST<E> b, E x) {  
    ...  
}
```

```
BST<Integer> bi = null;  
bi = BST.add(bi, 42);  
...
```

```
BST<String> bs = null;  
bs = BST.add(bs, "foo");  
...
```

car `Integer` et `String` implémentent `Comparable`

note : l'argument `E` de `BST.add` est inféré

mais

```
class U { ... }  
class Main { BST<U> b = ... }
```

est refusé

Bound mismatch: The type U is not a valid substitute for the bounded parameter <E extends Comparable<E>> of the type BST<E>

U doit implémenter l'interface Comparable

```
class U implements Comparable<U> {  
    ...  
    public int compareTo(U o) { ... }  
    ...  
}  
class Main { BST<U> b = ... }
```

on trouve

- `java.util.TreeSet<E>` (ensemble)
- `java.util.TreeMap<K, V>` (dictionnaire)

(ce sont des arbres rouges et noirs)

- soit l'ordre naturel sur les éléments / clés si la classe implémente Comparable (comme on vient de le faire)
- soit un **comparateur** fourni au constructeur

```
TreeSet(Comparator<E> comparator)  
TreeMap(Comparator<K> comparator)
```

avec

```
interface Comparator<T> {  
    int compare(T o1, T o2);  
}
```

- sur `data.gouv.fr`, on récupère la consommation électrique en France toutes les demi-heures
- on se donne une classe pour `date+heure`

```
class Date implements Comparable<Date> {  
    // date et heure  
    @Override  
    public int compareTo(Date that) { ... }  
}
```

- on remplit un dictionnaire avec les informations de consommation
`TreeMap<Date, Integer> map = new TreeMap<>();`
- on interroge avec des requêtes comme
`...map.subMap(from, to)...`

les arbres binaires de recherche

- sont adaptés quand l'**ordre** sur les éléments importe
- fournissent des opérations en $O(\log N)$

on les implémente

- avec des pointeurs possiblement `null`
- une encapsulation qui cache cette représentation

une variante des ABR : les arbres k -dimensionnels

permet de trouver le plus proche voisin dans un ensemble de points de \mathbb{R}^k
(utilisé notamment en IA dans l'algorithme des k plus proches voisins)

application : sélection d'une palette de 256 couleurs parmi les 16777216 couleurs possibles pour compresser une image



- **lire le poly**, chapitre 6 Arbres

il y a des **exercices** dans le poly
suggestions : ex 37 p 79, ex 40 p 91

- **bloc 6** : encore des arbres, mais différents