

- 1/ Rappels et compléments Java.
- 2/ Tableaux, boucles et invariants.
- 3/ Notions élémentaires de complexité. **ICI**
- 4/ Récursion.
- 5/ Structures de données et introduction aux types abstraits de données.
- 6/ Quelques compléments Java.

## 3/ Notions élémentaires de complexité.

## Évaluer un algorithme

Quels sont les critères pour caractériser un **bon algorithme** , un **bon programme** ?

## Evaluer un algorithme

Quels sont les critères pour caractériser un **bon algorithme**, un **bon programme** ?

## Réponses intuitives

- L'algorithme est **correct** et est bien programmé (sans bugs, bien commenté, lisible, modulable, ...).
- Il peut s'exécuter **rapidement** ou en un temps **raisonnable** en utilisant **peu de ressource en mémoire** même si on augmente la taille des données à traiter : ce sont des thèmes centraux en **théorie de la complexité** des algorithmes.

## Evaluer un algorithme

Quels sont les critères pour caractériser un **bon algorithme**, un **bon programme** ?

## Réponses intuitives

- L'algorithme est **correct** et est bien programmé (sans bugs, bien commenté, lisible, modulable, ...).
- Il peut s'exécuter **rapidement** ou en un temps **raisonnable** en utilisant **peu de ressource en mémoire** même si on augmente la taille des données à traiter : ce sont des thèmes centraux en **théorie de la complexité** des algorithmes.

## Deux critères en complexité

En fonction de la taille des données en entrée, on a deux questions fondamentales.

**1/ Temps d'exécution.** Quel est le temps d'exécution de l'algorithme ?

**2/ Place mémoire.** Quelle est la place mémoire nécessaire pour son exécution ?

## Un programme de recherche d'un élément

```
public static int recherche(int[] tab, int x) {
  /** méthode pour rechercher l'indice d'un élément
  * ENTRÉES : tab est un tableau d'entiers distincts,
  *           x est un entier
  * SORTIE : renvoie i si  $\text{tab}[i] == x$ ,
  *           -1 si  $x$  n'est pas dans le tableau
  */
  int i=0;
  while(i<tab.length && x!=tab[i])
    /* A1 :  $\forall 0 \leq j \leq i, \text{tab}[j] \neq x$  */
    i++;
  if (i==tab.length)
    /* A2 :  $x$  n'est pas dans le tableau. */
    return -1;
  else return i; /* A3 :  $x$  est à l'indice  $i$  */
}
```

- **A1 est vrai** en rentrant dans la boucle ( $i = j = 0$ ).

- **A1 est vrai** en rentrant dans la boucle ( $i = j = 0$ ).
- **A1 est vrai** à chaque passage dans la boucle car on rentre quand  $\text{tab}[i] \neq x$  et  $i$  a été incrémenté.



- **A1 est vrai** en rentrant dans la boucle ( $i = j = 0$ ).
- **A1 est vrai** à chaque passage dans la boucle car on rentre quand  $\text{tab}[i] \neq x$  et  $i$  a été incrémenté.
- **A2 est vrai** puisque A1 est vrai à chaque étape de la boucle si  $i == \text{tab.length}$  alors  $\forall 0 \leq j \leq \text{tab.length} \text{ tab}[j] \neq x$ , donc  $x$  n'est pas dans le tableau.

- **A1 est vrai** en rentrant dans la boucle ( $i = j = 0$ ).
- **A1 est vrai** à chaque passage dans la boucle car on rentre quand  $\text{tab}[i] \neq x$  et  $i$  a été incrémenté.
- **A2 est vrai** puisque A1 est vrai à chaque étape de la boucle si  $i == \text{tab.length}$  alors  $\forall 0 \leq j \leq \text{tab.length} \text{ tab}[j] \neq x$ , donc  $x$  n'est pas dans le tableau.
- **A3 est vrai** car si  $i < \text{tab.length}$  alors on est sorti de la boucle avec  $x == \text{tab}[i]$  et donc le  $x$  recherché est à l'indice  $i$ .

- **A1 est vrai** en rentrant dans la boucle ( $i = j = 0$ ).
- **A1 est vrai** à chaque passage dans la boucle car on rentre quand  $\text{tab}[i] \neq x$  et  $i$  a été incrémenté.
- **A2 est vrai** puisque A1 est vrai à chaque étape de la boucle si  $i == \text{tab.length}$  alors  $\forall 0 \leq j \leq \text{tab.length} \text{ tab}[j] \neq x$ , donc  $x$  n'est pas dans le tableau.
- **A3 est vrai** car si  $i < \text{tab.length}$  alors on est sorti de la boucle avec  $x == \text{tab}[i]$  et donc le  $x$  recherché est à l'indice  $i$ .
- ET le programme est **bien commenté**.

### L'algorithme termine!

Au pire  $i$  croît de 0 à `tab.length` qui est une **valeur finie**.

### L'algorithme termine!

Au pire  $i$  croît de 0 à `tab.length` qui est une **valeur finie**.

### Temps d'exécution : cas pire, analyse en moyenne et meilleur des cas

- Dans le pire des cas, on doit parcourir tout `tab`,  $n$  itérations.
- Dans le meilleur des cas, on trouve  $x$  de suite, 1 itération.
- Si  $p$  est la probabilité que  $x$  se trouve dans le tableau, le nombre moyen d'itérations sera (sous l'hypothèse que tous les nombres sont équiprobables)

$$n\left(1 - \frac{p}{2}\right) + \frac{p}{2}.$$

### L'algorithme termine!

Au pire  $i$  croît de 0 à `tab.length` qui est une **valeur finie**.

### Temps d'exécution : cas pire, analyse en moyenne et meilleur des cas

- Dans le pire des cas, on doit parcourir tout `tab`,  $n$  itérations.
- Dans le meilleur des cas, on trouve  $x$  de suite, 1 itération.
- Si  $p$  est la probabilité que  $x$  se trouve dans le tableau, le nombre moyen d'itérations sera (sous l'hypothèse que tous les nombres sont équiprobables)

$$n\left(1 - \frac{p}{2}\right) + \frac{p}{2}.$$

### Mémoire

La place nécessaire pour stocker  $x$ , `tab` et l'indice  $i$ . Si `tab` contient  $n$  éléments on aura besoin de place pour  $n + 2$  entiers.

## Un second exemple

Dans le premier programme, on a pris comme hypothèse des *entiers distincts*. Dans ce second exemple, on suppose de plus que le tableau `tab` donné en entrée est **déjà trié!** Il s'agit toujours de savoir si l'élément `x` est dans `tab`.

## Un second exemple

Dans le premier programme, on a pris comme hypothèse des *entiers distincts*. Dans ce second exemple, on suppose de plus que le tableau `tab` donné en entrée est **déjà trié!** Il s'agit toujours de savoir si l'élément `x` est dans `tab`.

### Solution force brute

On utilise l'algorithme précédent et on trouve soit l'indice de `x` soit `-1` si `x` n'est pas dans `tab`.



## Un second exemple

Dans le premier programme, on a pris comme hypothèse des *entiers distincts*. Dans ce second exemple, on suppose de plus que le tableau `tab` donné en entrée est **déjà trié!** Il s'agit toujours de savoir si l'élément `x` est dans `tab`.

### Solution force brute

On utilise l'algorithme précédent et on trouve soit l'indice de `x` soit `-1` si `x` n'est pas dans `tab`.

### Solution dichotomique

On profite du fait que les éléments sont **ordonnés** pour appliquer le paradigme "DIVISER POUR RÉGNER". Le principe est le suivant:

- on compare `x` à l'élément `m` qui est celui du milieu du (sous-)tableau considéré.
- Si `x = m` alors renvoyer l'indice de `m`.
- Si `x < m` alors on va travailler dans la partie gauche du tableau (la partie `< m`).
- Si `x > m` alors *idem* mais avec la partie droite.

## Un programme de recherche dichotomique

```
/** ENTRÉES : tab est un tableau d'entiers
 * distincts ordonnés par ordre croissant, x est un entier
 * SORTIE : renvoie i si  $\text{tab}[i] == x$ ,
 *          -1 si  $x$  n'est pas dans le tableau */
public int rechercheDichotomique(int[] tab, int x) {
    int gauche = 0;
    int droite = tab.length - 1;
    int milieu;
    while (gauche <= droite) {
        /* A1 :  $\forall j < \text{gauche} \text{ tab}[j] \neq x \ \forall j > \text{droite} \text{ tab}[j] \neq x$  */
        milieu = (gauche + droite) / 2 ;
        if (x==tab[milieu])
            /* A2 :  $x$  est à l'indice milieu */
            return milieu;
        if (x<tab[milieu]) droite = milieu - 1;
        else gauche = milieu + 1;
    }
    /* A3 :  $x$  n'est pas dans le tableau */
    return -1;
}
```

### L'algorithme termine!

Pour tout  $n$ , il existe  $k$  tel que  $2^k \leq n < 2^{k+1}$ . Intuitivement, dans le pire des cas on va toujours diviser la taille du (sous)tableau à traiter en 2 jusqu'à ce que la condition de la boucle `gauche <= droite` ne soit plus satisfaite.

### L'algorithme termine!

Pour tout  $n$ , il existe  $k$  tel que  $2^k \leq n < 2^{k+1}$ . Intuitivement, dans le pire des cas on va toujours diviser la taille du (sous)tableau à traiter en 2 jusqu'à ce que la condition de la boucle `gauche <= droite` ne soit plus satisfaite.

### Temps d'exécution : cas pire, analyse en moyenne et meilleur des cas

- Dans le pire des cas, on doit toujours traiter tous les sous-tableaux. Soit  $k$  tel que  $2^k \leq n < 2^{k+1}$  on va traiter en gros au plus  $k + 1 = \lfloor \log_2 n \rfloor + 1$  sous-tableaux! On parle de complexité **logarithmique!**
- Dans le meilleur des cas, on trouve  $x$  de suite, **1 itération.**
- Si  $p$  est la probabilité que  $x$  se trouve dans le tableau, **le nombre moyen d'itérations** sera (sous l'hypothèse que tous les nombres sont équiprobables) aussi **logarithmique** :  $(\lfloor \log_2 n \rfloor + 1)(1 - p) + \dots$

## Temps d'exécution et place mémoire pour le second exemple

### L'algorithme termine!

Pour tout  $n$ , il existe  $k$  tel que  $2^k \leq n < 2^{k+1}$ . Intuitivement, dans le pire des cas on va toujours diviser la taille du (sous)tableau à traiter en 2 jusqu'à ce que la condition de la boucle `gauche <= droite` ne soit plus satisfaite.

### Temps d'exécution : cas pire, analyse en moyenne et meilleur des cas

- Dans le pire des cas, on doit toujours traiter tous les sous-tableaux. Soit  $k$  tel que  $2^k \leq n < 2^{k+1}$  on va traiter en gros au plus  $k + 1 = \lfloor \log_2 n \rfloor + 1$  sous-tableaux! On parle de complexité **logarithmique!**
- Dans le meilleur des cas, on trouve  $x$  de suite, **1 itération.**
- Si  $p$  est la probabilité que  $x$  se trouve dans le tableau, **le nombre moyen d'itérations** sera (sous l'hypothèse que tous les nombres sont équiprobables) aussi **logarithmique** :  $(\lfloor \log_2 n \rfloor + 1)(1 - p) + \dots$

### Mémoire : $n + 4$ entiers pour tab, $x$ , milieu gauche et droite

## Attention!!!

En algorithmique, on s'intéresse aux ordres de grandeur du temps d'exécution et/ou de l'espace mémoire nécessaire à un algorithme en fonction de la taille des données en entrée  $n$ . On s'intéresse aux grandes valeurs de  $n$  ( $n \rightarrow \infty$ ).

## Attention!!!

En algorithmique, on s'intéresse aux ordres de grandeur du temps d'exécution et/ou de l'espace mémoire nécessaire à un algorithme en fonction de la taille des données en entrée  $n$ . On s'intéresse aux grandes valeurs de  $n$  ( $n \rightarrow \infty$ ).

Soit  $f$  et  $g$  deux fonctions.

- **Grand O.** On note  $f(n) = O(g(n))$  si il existe une constante  $c > 0$  et un entier  $n_0$  tel que

$$\forall n \geq n_0, |g(n)| \leq cf(n).$$

On dit alors que  $f$  **domine**  $g$  à partir d'un certain rang. Par exemple,  $f(n) = 2n + \sqrt{n}$  et  $g(n) = n$ . Autre exemple,  $f(n) = \sin\left(\frac{n\pi}{3}\right)$  et  $g(n) = 1$ .

## Attention!!!

En algorithmique, on s'intéresse aux ordres de grandeur du temps d'exécution et/ou de l'espace mémoire nécessaire à un algorithme en fonction de la taille des données en entrée  $n$ . On s'intéresse aux grandes valeurs de  $n$  ( $n \rightarrow \infty$ ).

Soit  $f$  et  $g$  deux fonctions.

- **Grand O.** On note  $f(n) = O(g(n))$  si il existe une constante  $c > 0$  et un entier  $n_0$  tel que

$$\forall n \geq n_0, |g(n)| \leq cf(n).$$

On dit alors que  $f$  **domine**  $g$  à partir d'un certain rang. Par exemple,  $f(n) = 2n + \sqrt{n}$  et  $g(n) = n$ . Autre exemple,  $f(n) = \sin\left(\frac{n\pi}{3}\right)$  et  $g(n) = 1$ .

- **Theta.** On note  $f(n) = \Theta(g(n))$  s'il existe deux constantes  $c_1 > 0$  et  $c_2 > 0$  telles que

$$c_1 \leq \lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} \leq c_2$$



## Attention!!!

En algorithmique, on s'intéresse aux ordres de grandeur du temps d'exécution et/ou de l'espace mémoire nécessaire à un algorithme en fonction de la taille des données en entrée  $n$ . On s'intéresse aux grandes valeurs de  $n$  ( $n \rightarrow \infty$ ).

Soit  $f$  et  $g$  deux fonctions.

- **Grand O.** On note  $f(n) = O(g(n))$  si il existe une constante  $c > 0$  et un entier  $n_0$  tel que

$$\forall n \geq n_0, |g(n)| \leq cf(n).$$

On dit alors que  $f$  **domine**  $g$  à partir d'un certain rang. Par exemple,  $f(n) = 2n + \sqrt{n}$  et  $g(n) = n$ . Autre exemple,  $f(n) = \sin\left(\frac{n\pi}{3}\right)$  et  $g(n) = 1$ .

- **Theta.** On note  $f(n) = \Theta(g(n))$  s'il existe deux constantes  $c_1 > 0$  et  $c_2 > 0$  telles que

$$c_1 \leq \lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} \leq c_2$$

- **Omega.** On note  $f(n) = \Omega(g(n))$  si  $f(n)$  est minorée par  $cg(n)$  avec  $c > 0$  quand  $n \rightarrow \infty$ .

- Le Grand O est transitif : si  $h(n) = O(g(n))$  et  $g(n) = O(f(n))$  alors  $h(n) = O(f(n))$ .

- Le Grand O est transitif : si  $h(n) = O(g(n))$  et  $g(n) = O(f(n))$  alors  $h(n) = O(f(n))$ .
- La règle des sommes : si  $g_1(n) = O(f_1(n))$  et  $g_2(n) = O(f_2(n))$  alors  $g_1(n) + g_2(n) = O(\max(f_1(n), f_2(n)))$ .

- Le Grand O est transitif : si  $h(n) = O(g(n))$  et  $g(n) = O(f(n))$  alors  $h(n) = O(f(n))$ .
- La règle des sommes : si  $g_1(n) = O(f_1(n))$  et  $g_2(n) = O(f_2(n))$  alors  $g_1(n) + g_2(n) = O(\max(f_1(n), f_2(n)))$ .
- La règle des produits : si  $g_1(n) = O(f_1(n))$  et  $g_2(n) = O(f_2(n))$  alors  $g_1(n)g_2(n) = O(f_1(n)f_2(n))$ .

## Quelques propriétés du grand O

- Le Grand O est transitif : si  $h(n) = O(g(n))$  et  $g(n) = O(f(n))$  alors  $h(n) = O(f(n))$ .
- La règle des sommes : si  $g_1(n) = O(f_1(n))$  et  $g_2(n) = O(f_2(n))$  alors  $g_1(n) + g_2(n) = O(\max(f_1(n), f_2(n)))$ .
- La règle des produits : si  $g_1(n) = O(f_1(n))$  et  $g_2(n) = O(f_2(n))$  alors  $g_1(n)g_2(n) = O(f_1(n)f_2(n))$ .
- Supposons que la limite  $\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = L$  existe avec  $L \in \mathbb{R} \cup \{\infty\}$  alors
  - 1 si  $L = 0$  alors  $f(n) = O(g(n))$
  - 2 si  $0 < L < \infty$  alors  $f(n) = \Theta(g(n))$
  - 3 si  $L = \infty$  alors  $f(n) = \Omega(g(n))$ .

- $f(n) = \Theta(g(n)) \Leftrightarrow f(n) = O(g(n))$  et  $g(n) = O(f(n))$

- $f(n) = \Theta(g(n)) \Leftrightarrow f(n) = O(g(n))$  et  $g(n) = O(f(n))$
- $f(n) = O(g(n))$  n'implique pas  $f(n) = \Theta(g(n))$ . Ex:  $f(n) = \log n$  et  $g(n) = n$ .
- Les indications en “Theta” sont plus précises que les “Grand O”.

Quand on écrit que le temps d'exécution  $T(n) = \Omega(g(n))$  d'un algorithme avec des entrées de taille  $n$ , au delà du fait mathématique que “  $T(n)$  est minorée à un facteur près par  $g(n)$  ”, en algorithmique cela a un sens fort.



Quand on écrit que le temps d'exécution  $T(n) = \Omega(g(n))$  d'un algorithme avec des entrées de taille  $n$ , au delà du fait mathématique que “  $T(n)$  est minorée à un facteur près par  $g(n)$  ”, en algorithmique cela a un sens fort.

### Remarque

$g(n)$  est une borne inférieure (à un facteur constant près) de  $T(n)$ . Ce qui implique qu'il existe des instances sur lesquelles l'algorithme nécessitera un temps d'exécution d'au moins  $g(n)$ .

Quand on écrit que le temps d'exécution  $T(n) = \Omega(g(n))$  d'un algorithme avec des entrées de taille  $n$ , au delà du fait mathématique que “  $T(n)$  est minorée à un facteur près par  $g(n)$  ”, en algorithmique cela a un sens fort.

### Remarque

$g(n)$  est une borne inférieure (à un facteur constant près) de  $T(n)$ . Ce qui implique qu'il existe des instances sur lesquelles l'algorithme nécessitera un temps d'exécution d'au moins  $g(n)$ .

### Exemple

Le temps d'exécution d'une multiplication de deux matrices carrées d'ordre  $n$  nécessite  $\Omega(n^2)$  opérations (au moins on doit calculer les  $n^2$  termes de la nouvelle matrice)!

Que ce soit en **temps d'exécution**  $T(n)$  et/ou en **espace mémoire**  $M(n)$ , on parle de complexité

- **logarithmique** si  $T(n) = \Theta(\log n)$  (resp. pour la mémoire  $M(n) = \Theta(\log n)$ )
- **linéaire** si  $T(n) = \Theta(n)$  (resp. pour la mémoire  $M(n) = \Theta(n)$ )
- **quadratique** si  $T(n) = \Theta(n^2)$  (resp. pour la mémoire  $M(n) = \Theta(n^2)$ )
- **traitable** ou **polynomial** si  $T(n) = O(n^\alpha)$  pour  $\alpha > 0$  constante (idem pour  $M(n)$ )
- **intraitable** si  $T(n) = \Theta(n^{\omega(n)})$  où  $\lim_{n \rightarrow \infty} \omega(n) = +\infty$ .

### Algorithme linéaire

Si un algorithme linéaire s'exécute en  $\Theta(n)$  traite 10 données par **minute**, il peut en traiter 14 400 par **jour**, 5 260 000 par **an** ...

### Algorithme linéaire

Si un algorithme linéaire s'exécutant en  $\Theta(n)$  traite 10 données par **minute**, il peut en traiter 14 400 par **jour**, 5 260 000 par **an** ...

### Intraitable

Pour un algorithme s'exécutant en  $\Theta(2^n)$ , il va aussi traiter 10 données en quelques **minutes** mais déjà il est limité à quelques 20 données par **jour** et à une **trentaine** par **siècle** !

# Un cas d'étude : LE TRI FUSION (mergesort)

Nous avons en entrée un tableau  $T$  à trier. L'idée est d'appliquer le paradigme **diviser pour régner** récursivement :

### Le tri fusion

**Conditions d'arrêt.** Si la taille du tableau  $T$  est  $\leq 1$  alors il est trié.

**Corps de la récursion.** Sinon on le **partitionne** en **DEUX** (sous)tableaux  $T_1$  et  $T_2$  qu'on **trie** (**appels récursifs**)  $T_1$  puis  $T_2$  et on **fusionne** les deux tableaux triés obtenus.

Le tri-fusion a besoin d'un algorithme de fusion de deux tableaux  $T_1$  et  $T_2$  triés et dont le résultat ( $T_3$ ) sera la fusion triée de ces deux tableaux.



Le tri-fusion a besoin d'un algorithme de fusion de deux tableaux  $T_1$  et  $T_2$  triés et dont le résultat ( $T_3$ ) sera la fusion triée de ces deux tableaux.

Il suffit pour cela d'utiliser deux indices  $i$  et  $j$  indiquant respectivement les éléments de  $T_1$  et de  $T_2$  que l'on compare. L'élément le plus petit est copié dans  $T_3$  et l'indice du tableau correspondant est incrémenté.

On utilise plusieurs faits :

- L'algorithme de fusion de deux tableaux  $T_1$  et  $T_2$  triés (de taille resp.  $n_1$  et  $n_2$ ) nécessite  $n = n_1 + n_2$  itérations (quelque soit le cas).

On utilise plusieurs faits :

- L'algorithme de fusion de deux tableaux  $T_1$  et  $T_2$  triés (de taille resp.  $n_1$  et  $n_2$ ) nécessite  $n = n_1 + n_2$  itérations (quelque soit le cas).
- Soit  $T(n)$  le temps nécessaire pour l'exécution d'un tri fusion sur un tableau de taille  $n$ . Pour simplifier, on va supposer que  $n$  est une puissance de 2. On a

$$T(n) = n + 2T\left(\frac{n}{2}\right)$$

On utilise plusieurs faits :

- L'algorithme de fusion de deux tableaux  $T_1$  et  $T_2$  triés (de taille resp.  $n_1$  et  $n_2$ ) nécessite  $n = n_1 + n_2$  itérations (quelque soit le cas).
- Soit  $T(n)$  le temps nécessaire pour l'exécution d'un tri fusion sur un tableau de taille  $n$ . Pour simplifier, on va supposer que  $n$  est une puissance de 2. On a

$$T(n) = n + 2T\left(\frac{n}{2}\right)$$

- Donc

$$\frac{T(n)}{n} = 1 + 2\frac{T\left(\frac{n}{2}\right)}{n}$$

On utilise plusieurs faits :

- L'algorithme de fusion de deux tableaux  $T_1$  et  $T_2$  triés (de taille resp.  $n_1$  et  $n_2$ ) nécessite  $n = n_1 + n_2$  itérations (quelque soit le cas).
- Soit  $T(n)$  le temps nécessaire pour l'exécution d'un tri fusion sur un tableau de taille  $n$ . Pour simplifier, on va supposer que  $n$  est une puissance de 2. On a

$$T(n) = n + 2T\left(\frac{n}{2}\right)$$

- Donc

$$\frac{T(n)}{n} = 1 + 2\frac{T\left(\frac{n}{2}\right)}{n}$$

- Posons  $u_n = \frac{T(n)}{n}$ , on a donc  $u_n = 1 + u_{n/2} = 2 + u_{n/4} = \dots$  et au final  $T(n) = O(n \log n)$ .