

HashSet et HashMap: Tableaux de hachage


Principes

- On veut stocker et récupérer rapidement des données dans un tableau (par exemple des Strings)
- idée : on calcule une valeur entière à partir des données. Cette valeur donne la case du tableau où les données sont supposées se trouver
- cette valeur entière s'appelle fonction de hachage

Exemple simplifié

- On veut implanter un ensemble de Strings dans un tableau de 1000 cases
- fonction de hachage possible : somme des codes unicodes des caractères de la String

«le»
code de «l» = 108 + code de «e» = 101 = 209

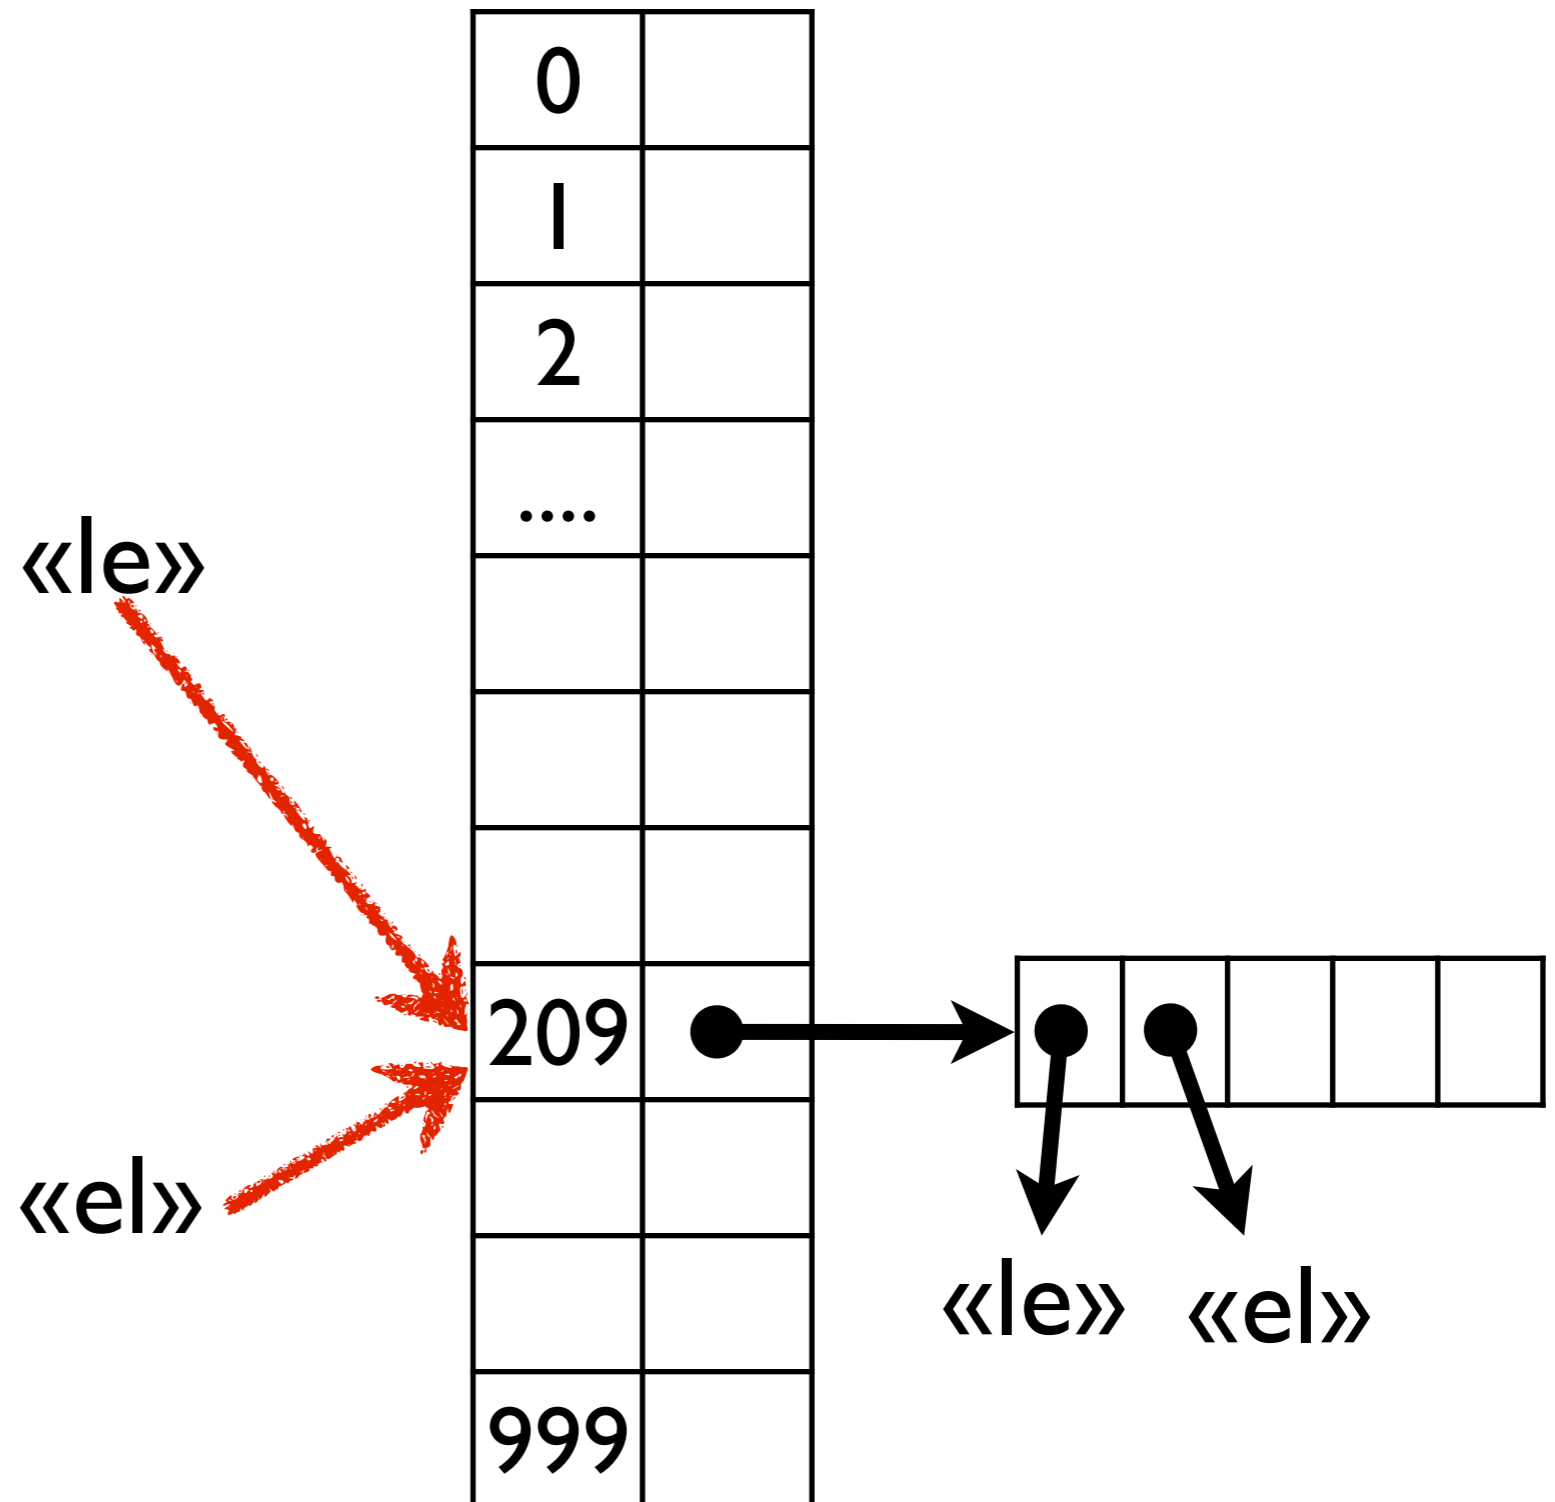


Problèmes

- Que se passe-t-il si la fonction de hachage est plus grande que la taille du tableau :
 - ▶ on prend le modulo
- Que se passe-t-il si (quand !) deux chaînes ont le même code de hachage («le» et «el» dans notre exemple ?)
 - ▶ collision. Plusieurs systèmes possibles...

Collision

Solution la plus simple :
les cases du tableau
contiennent
des listes de
valeurs et
non pas les
valeurs
directement



Algorithme de recherche

- soit s à chercher dans une table de hachage t
- on calcule h le `<<hashcode>>` de s
- on prend sa valeur modulo $t.length$
- ça nous donne une case i où s est supposé se trouver
- dans la case i : parcourir la liste en comparant avec equals, pour voir si on trouve s

Algorithme d'insertion

- soit s à ajouter dans une table de hachage t
- on calcule h le hashcode de s
- on prend sa valeur modulo $t.length$
- ça nous donne une case i où s est supposé se trouver : $i = s.hashCode() \% t.length$
- on parcourt la liste l qui est dans la case i , en comparant avec equals, pour voir si on trouve s
- si s n'est pas trouvée, on l'ajoute à l .

Conclusions Partielles

- pour 100000 valeurs dans un tableau de taille 1000 : en moyenne 100 valeurs par case
- intéressant si la fonction de hachage répartit uniformément les valeurs
- la classe Object fournit les méthodes hashCode() et equals() : on peut utiliser des HashSet avec toutes les classes java !
- Par défaut (dans Object) : hashCode dépend de l'adresse de l'objet. Les classes peuvent redéfinir la méthode si nécessaire.