

Algorithmes de hachage




Fonctions de Hachage

fonction de hachage

- **fonction de hachage** (hash : hash function) ,
une fonction particulière qui, à partir d'une donnée
fournie en entrée, calcule une empreinte servant à
identifier rapidement la donnée initiale, au même
titre qu'une signature pour identifier une personne.
- Les fonctions de hachage sont utilisées en
informatique et en cryptographie notamment pour
reconnaître rapidement des fichiers ou des mots
de passe.


fonction de hachage



fonction de hachage

Input


Hash sum



Résistance à la préimage

- Une fonction h est résistante à la préimage s'il est difficile de trouver à partir d'une empreinte donnée p un message m tel que $h(m) = p$.
- Une fonction h est résistante à la seconde préimage s'il est difficile de trouver à partir d'un message m donné un autre message m' tel que $h(m) = h(m')$
- Une fonction de hachage h est résistante aux collisions s'il est difficile de trouver deux messages m et m' tel que $h(m) = h(m')$

Processus de vérification




fonction de hachage

- Très importante dans l'échange de messages
- MITM (Man-In-The-Middle)
- Recevoir une paire <message, empreinte> n'assure aucune garantie sur l'origine du message



fonction de hachage

.Utiliser une clé secrète



Utilisation

Pour vérifier l'intégrité d'un message

Si le message et son empreinte ne correspondent plus, il y a eu une manipulation du message.

Pour la signature numérique


Afin de permettre de signer un message de longueur arbitrairement long, l'empreinte du message est signée au lieu du message proprement dit.

MD5

MD2, MD4 et MD5

- Message Digest: 1989, 1990 et 1991 par Ronald Rivest (MIT)
- Empreintes de 128 bits.
- Vulnérables aux collisions: messages différents avec une même empreinte.

MD5



SHA

- SHA

- Secure Hashing Algorithm

- National Institute of Standards and Technology (NIST)

- SHA-1 (160 bits)

- Vulnérable aux collisions.

- Publiée en 1995. Des vulnérabilités publiées en 2005.

SHA

- SHA- 2
- 4 versions: 224, 256, 384 et 512 bits
- Publiée en 2001
- Non affectée par les vulnérabilités SHA-1!
- SHA-256 vulnérable aux collisions

Table de hachage

Table de hachage

- Une table hachage(**hash table**) est une structure de données qui permet une association clé-élément
- On accède à chaque élément de la table via sa clé.
- L'accès à un élément se fait en transformant la clé en une valeur de hachage (ou simplement hachage) par l'intermédiaire d'une fonction de hachage.
- Le hachage est un nombre qui permet la localisation des éléments dans le tableau, typiquement le hachage est l'index de l'élément dans le tableau.
- Une case dans le tableau est appelée alvéole(**bucket/slot**).

Table de hachage

- **insérer**(H,elt,clé) : insère dans la table de hachage H un élément elt dont la clef est clé
- **elt recherche**(H,clé) : recherche dans la table de hachage H si un élément est associé à la clef clé et renvoie cet élément

Table de hachage





Table de hachage

- Les tables de hachage permettent
 - un accès en $O(1)$ en moyenne, mais
 - le temps d'accès dans le pire des cas peut être de $O(n)$.
- Une table de hachage n'est pas ordonnée
- Le fait de créer un hash à partir d'une clé peut engendrer un problème de collision
 - accès à la même position dans le "tableau"
- Pour minimiser les risques de collisions, il faut donc choisir soigneusement sa fonction de hachage.

Collision




Résolution des collisions

- Les Collisions sont fréquentes
- De nombreuses stratégies de résolution des collisions existent mais les plus connues et utilisées sont
 - le chaînage
 - l'adressage ouvert.

Chainage

- Méthode la plus simple.
- Chaque case de la table est en fait une liste chaînée d'éléments dont les clés ont le même hachage.


Chainage



Adressage Ouvert

- Adressage ouvert: L'adressage ouvert consiste, dans le cas d'une collision, à stocker les valeurs de hachage dans d'autres alvéoles vides.
- Soit $h(k,i)$ une fonction de sondage. Une méthode de sondage consiste à essayer les alvéoles d'indice $h(k,0)$, $h(k,1)$, ..., jusqu'à ce qu'on trouve une alvéole vide.

Adressage ouvert



Adressage Ouvert (Open addressing)

.Sondage linéaire (Linear probing):

$$h(k, i) = (H(k) + i) \bmod N, \quad 0 \leq i < N$$

.Sondage quadratique(Quadratic probing)

$$h(k, i) = (H(k) + c_1 \cdot i + c_2 \cdot i^2) \bmod N, \quad c_2 \neq 0$$

.Double hachage

- H1, H2 deux fonctions de hachage. Il faudra faire en sorte que H2 ne soit jamais égal à 0.

$$h(k, i) = (H_1(k) + i \cdot H_2(k)) \bmod N$$

Adressage Ouvert

.Recherche :

.Lors d'une recherche, si l'alvéole obtenue par hachage direct ne permet pas d'obtenir la bonne clé, une recherche sur les cases obtenues par une méthode de sondage est effectuée jusqu'à trouver la clé, ou tomber sur une alvéole vide, ce qui indique qu'aucune clé de ce type n'appartient à la table.

Adressage Ouvert

.Suppression

.Dans un adressage ouvert, la suppression d'un élément de la table de hachage est délicate. . La manière la plus simple de s'en sortir est de ne pas vider l'alvéole , mais d'y placer le mot « Supprimé ». On distinguera ainsi les alvéoles vides des alvéoles où un nom a été effacé « lazy deletion »,

Performance du cache

- Separate Chaining:

- Les nœuds d'une liste chaînée peuvent être dispersés en mémoire, causant des défauts de cache.

- Open Addressing:

- Meilleure. La sondage s'effectue dans des emplacements mémoire contigus, ce qui est favorable au cache.

Hash Table

Language	Hash Table Name(s)	Collision Strategy	Notes
Java	HashMap Hashtable ConcurrentHashMap	Separate Chaining	Uses linked lists, converts to tree when buckets get large (Java 8+)
C++	std::unordered_map std::unordered_set	Separate Chaining	Standard specifies buckets, implementations use linked lists
Python	dict set	Open Addressing	Uses "perturbation" probing scheme (modified linear probing)
C#	Dictionary<T,K> HashSet<T>	Open Addressing	Uses linear probing

Fonction de hachage

- Une fonction de hachage permet de transformer une clé en une valeur de hachage (un index), donnant ainsi la position d'un élément dans le tableau
- Si la clé n'est pas un entier naturel, il faut trouver un moyen de la considérer comme un entier naturel.
- si la clé est de type Chaîne de caractères, on peut ajouter la position dans l'alphabet de chaque lettre pour obtenir un entier naturel. Il suffit ensuite de transformer cet entier en index par différentes façons. Par exemple, en prenant le reste de la division de l'entier par le nombre d'éléments dans le tableau.

Fonction de hachage

.Fonction de hachage de Daniel J. Bernstein :

```
entier hash(str[]) { // str est une chaine de
caractères
    hash = 5381
    i ← 0
    tant que(str[i] ≠ '\0') {
        // hash=hash*33+str[i]
        hash ← ((hash << 5)+hash)+str[i]
        i ← i + 1
    }
    renvoyer hash
}
```

Facteur de charge(Load factor)

•Le facteur de compression (load factor) qui est la proportion d'alvéoles utilisées dans une table de hachage est une indication critique de ses performances.

$$\text{Load factor} = \frac{n}{m},$$

- n est le nombre de paires clé–valeur ;
- m est le nombre d'alvéoles(slots).

Facteur de charge(Load factor)

Un facteur de charge faible (par exemple, $\alpha < 0,5$) signifie plus d'espace, moins de collisions et des opérations plus rapides.

Un facteur de charge élevé (par exemple, $\alpha > 0,8$) signifie moins d'espace, plus de collisions et des opérations plus lentes.

Facteur de charge(Load factor)

La plupart des implémentations de tables de hachage redimensionnent automatiquement le tableau lorsque le facteur de charge dépasse un certain seuil (par exemple, 0,75). Il s'agit d'une opération coûteuse en $O(n)$, mais elle est effectuée rarement pour maintenir la performance moyenne en $O(1)$.

Python - dict & set

.Dictionary (key-value pairs)

```
student_grades = {"alice": 95, "bob": 87}

student_grades["charlie"] = 92      # Insert

grade = student_grades["alice"]     # Lookup

if "bob" in student_grades:         # Check
    print("Found!")
```

.Set (unique elements)

```
unique_names = {"alice", "bob"}

unique_names.add("charlie")          # Insert

if "alice" in unique_names:          # Check
    print("Exists!")
```

Java - HashMap & HashSet

. HashMap (key-value pairs)

```
HashMap<String, Integer> studentGrades = new HashMap<>();  
  
studentGrades.put("alice", 95);    // Insert  
  
studentGrades.put("bob", 87);  
  
int grade = studentGrades.get("alice"); // Lookup  
  
if (studentGrades.containsKey("bob")) { // Check  
    System.out.println("Found!");}
```

.HashSet (unique elements)

```
HashSet<String> uniqueNames = new HashSet<>();  
  
uniqueNames.add("alice");    // Insert  
  
.uniqueNames.add("bob");  
  
if (uniqueNames.contains("alice")) { // Check  
    System.out.println("Exists!");}
```

Hash Tabale

Django :request.POST

```
def view(request):
```

```
    username = request.POST["username"] # Hash table lookup!
```

```
    email = request.POST["email"]      # Hash table lookup!
```

Flask :session

```
@app.route("/")
```

```
def home():
```

```
    session["user_id"] = 123 # Hash table storage!
```

JavaScript : objects!

```
localStorage.setItem("token", "abc123"); // Hash table
```