
DEVOXX
FRANCE
2015
Hashons peu, mais hashons bien
#HPHB
@OlivierBourgain & @OlivierCroisier

DEVOXX France

Olivier BOURGAIN

Freelance

OBMG

@OlivierBourgain

Olivier CROISIER

Freelance

Moka Technologies

@OlivierCroisier

thecodersbreakfast.net

Plan

- Identité
- Hashcode
- Hashcode en action
- Performances

DEVOXX France

Classes de complexité

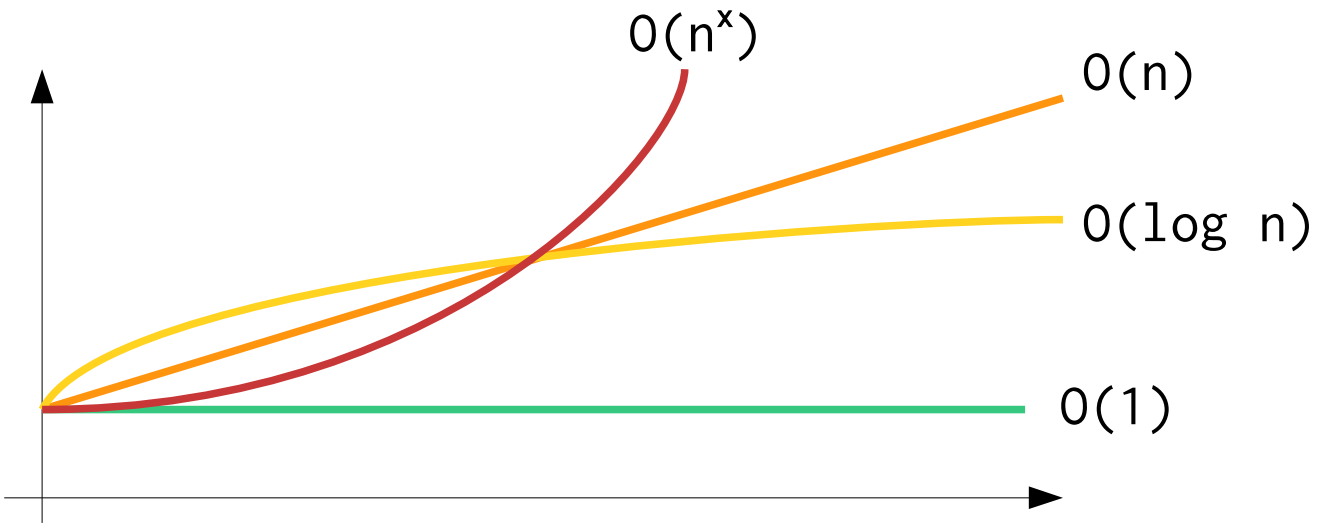

2 identités

- Identité *physique*
  - Adresse mémoire
  - Opérateur ==
- Identité *logique*
  - Modélisation métier
  - Méthode `equals()`

Contrat

- Réflexif
- Symétrique
- Transitif
- Stable
- Non-null

- Cf. javadoc

Guide d'implémentation

- Test ==
- Test `instanceof`
- Conversion
- Comparaison

- `java.util.Objects.equals()`

Guide d'implémentation

```
public class BankAccount {

    private final String bankId;
    private final long accountId;
    private BigDecimal amount;

    public boolean equals(Object o) {
        if (this == o) return true;
        if (!(o instanceof BankAccount)) return false;
        BankAccount other = (BankAccount) o;
        return Objects.equals(this.bankId, other.bankId)
            && this.accountId == other.accountId;
    }
}
```

Identité immuable

- Champs `final`

- Autre identité, autre instance
- Construction cohérente

Identité composite

- Classe dédiée
- Immuable

- Value-type
- Atomicité

Identité composite

```
public class BankAccount {

    private final BankAccountId id;
    private BigDecimal amount;

    public boolean equals(Object o) {
        if (this == o) return true;
        if (!(o instanceof BankAccount)) return false;
        BankAccount other = (BankAccount) o;
        return this.id.equals(other.id);
    }
}
```

Recherche

- Opération fréquente
  - Insertion dans les `Sets` & `Maps`
- Recherche linéaire en `O(n)`
- Optimisation ?

Recherche

- Les structures de données à la rescousse !
  - Arbres
  - Tables de hachage
  - Heaps
  - ...

Hashcode

- Fonction de classification
- Méthode `hashCode()`

- Recherche par identité au sein du groupe

- Performance en `O(1)`
  - Sensible à la qualité de la fonction

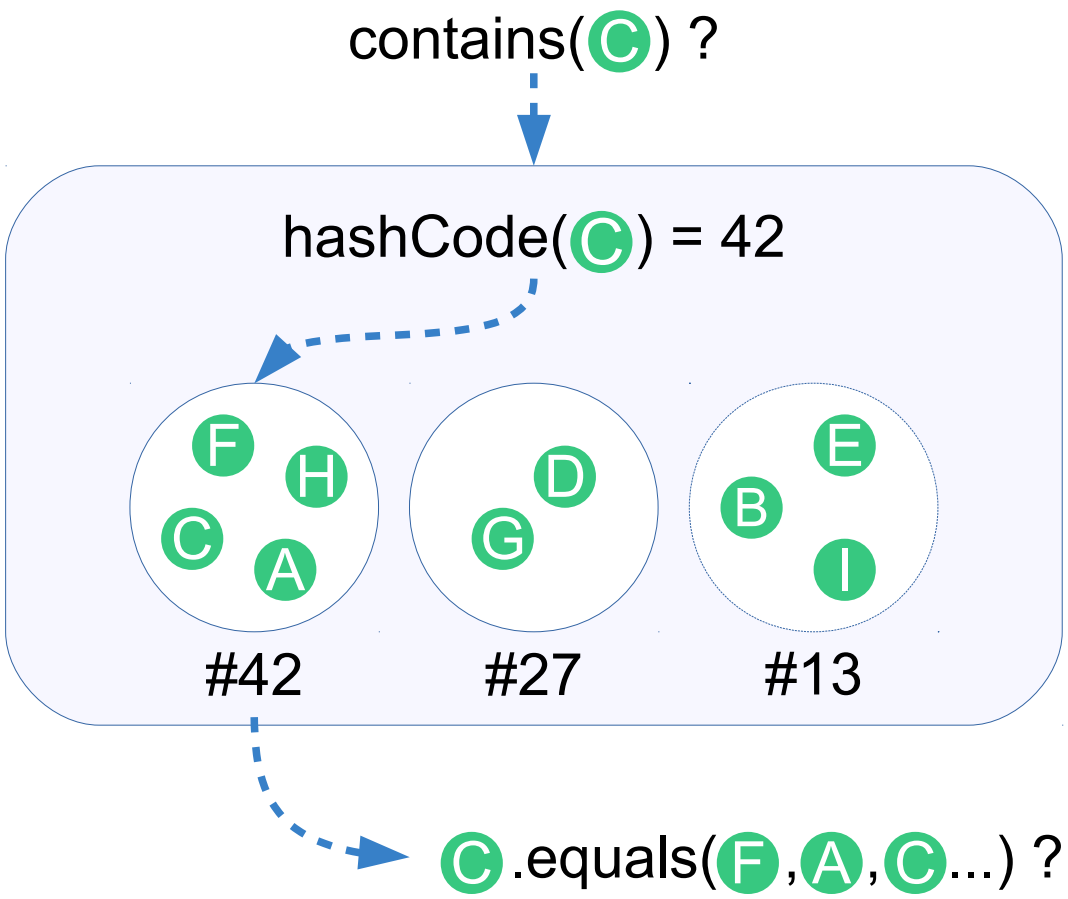
contains(C) ?
hashCode(C) = 42
F
H
C
A
D
G
E
B
I
#42
#27
#13
C.equals(F,A,C...) ?

Contrat

- Stable
- Cohérente avec l'identité

- Cf. javadoc

Contrat

- Sous-ensemble de l'identité
  - Cohérence avec `equals()`

- `BankAccount (id, balance)`

```
equals()    : id
hashCode()  : id + balance
```

- `account(42, 1000€)` → groupe A
  `account(42, 2000€)` → groupe B !

DEVOXX France

Cas du hashcode constant

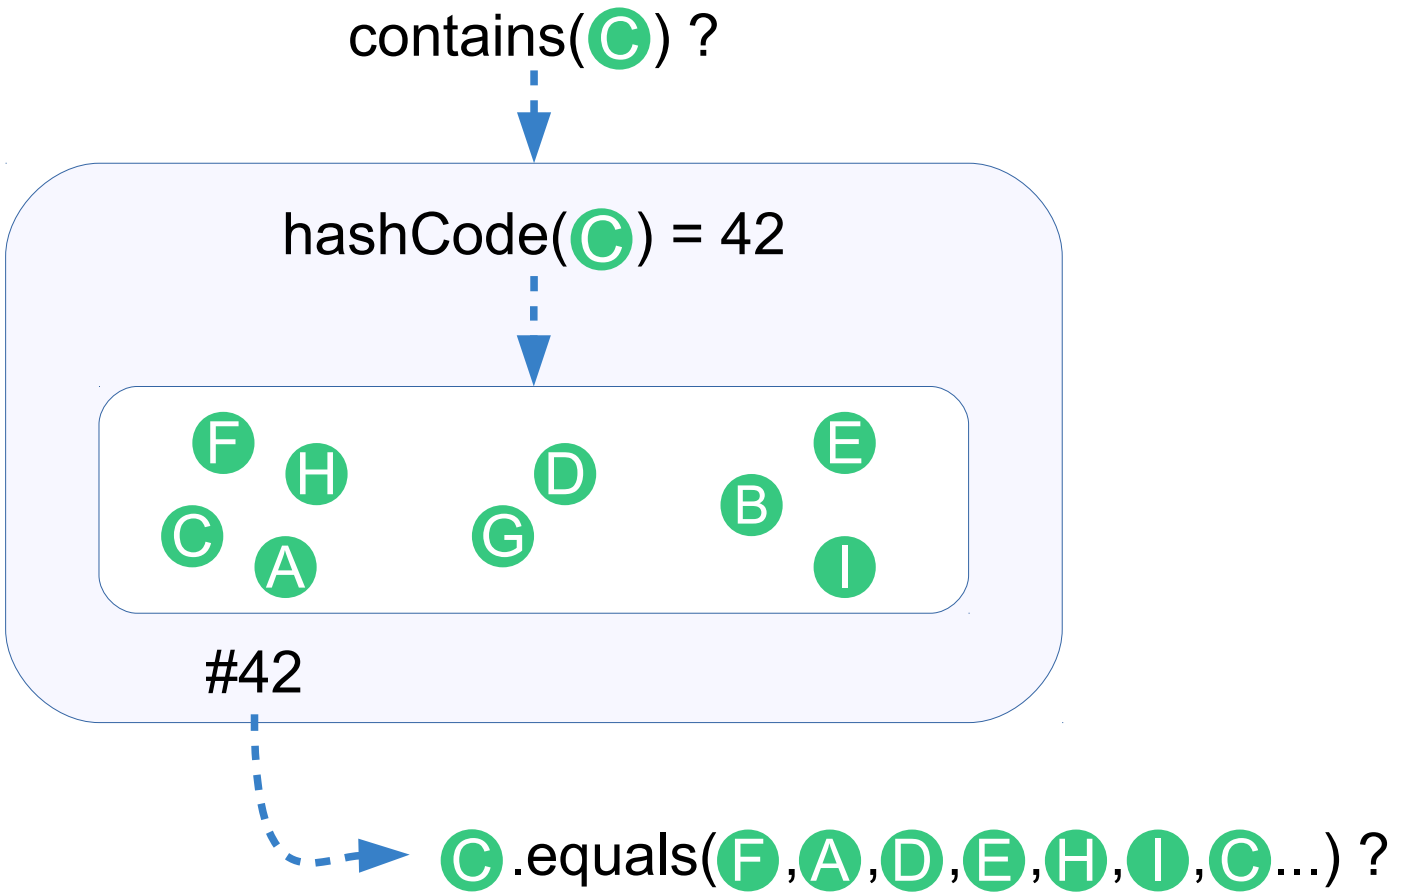

Guide d'implémentation (Java 7+)

- java.util.Objects.hashCode()
- java.util.Objects.hash(Object… fields)

```
public int hashCode() {
    return Objects.hash(bankId, accountId);
}
```

Guide d'implémentation (Java 7+)

```
Arrays#hashCode

public static int hashCode(Object a[]) {
    if (a == null) return 0;

    int result = 1;

    for (Object element : a) {
        result = 31 * result +
          (element == null ? 0 : element.hashCode());
    }
    return result;
}
```

Guide d'implémentation (autres)

- Génération par un IDE ou une librairie

- Bien choisir les champs utilisés
- Attention aux performances
  - Apache Commons ReflectionHashCode

Dans le JDK

- Collections `Hash*`

- 2 types de structures
  - En buckets (`HashMap`)
  - Open addressing (`IdentityHashMap`)

HashMap

- Structure interne : tableau de buckets

- Bucket de destination
  - Re-hash & bit-shifting

```
int reHash = 0;
if (key != null) {
    int hash = key.hashCode();
    reHash = hash ^ (hash >>> 16);
}
int pos = (size - 1) & reHash;
```

HashMap

- Structure d'un bucket
  - 0-7 éléments : liste chaînée (`Nodes`)
  - 8+ éléments : arbre binaire (`TreeNodes`)

- Transformation bi-directionnelle

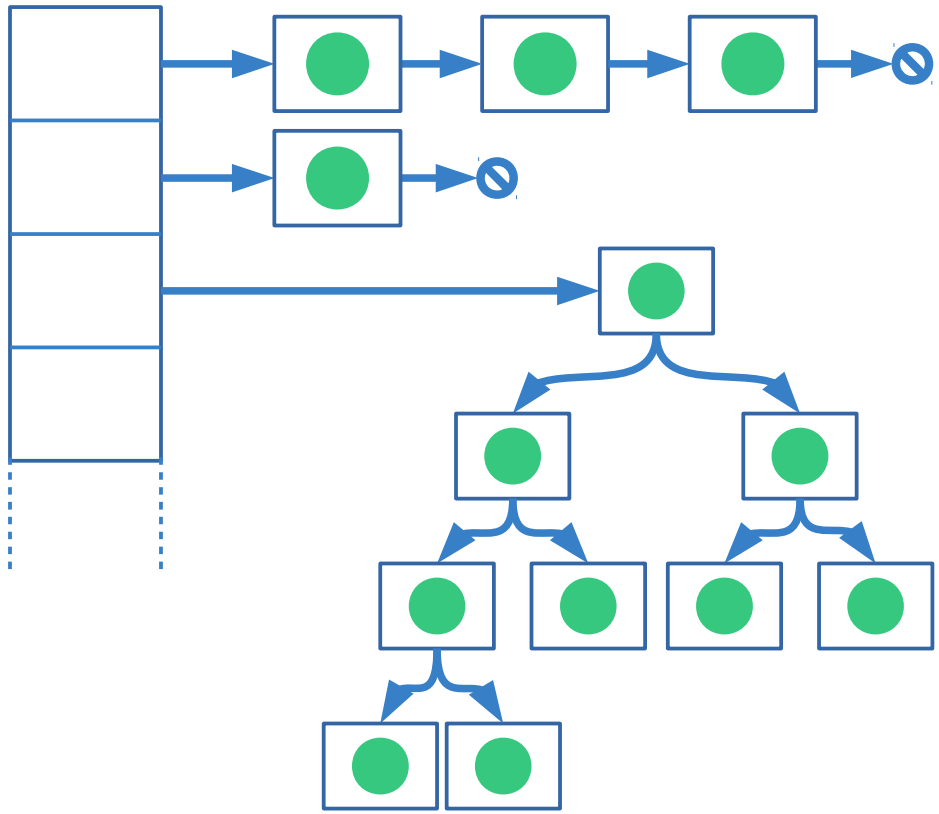

HashMap

- 16 buckets initiaux
- Load factor 0.75

- Redimensionnement
  - Taille x 2
  - Re-hachage

HashMap

- Performance moyenne en `O(1)`
  - Insertion, recherche
- Dégradée en `O(n)` ou `O(log n)`
- Parcours ∝ capacité

IdentityHashMap

- Distinction physique des instances

- Egalité avec ==
- Hashcode avec `System.identityHashCode()`

IdentityHashMap

- Structure interne : tableau d'éléments
  - (clé,valeur) aux indices (N,N+1)

- Indice de destination
  - Re-hash
  - Indice suivant si collision (*linear probing*)

```
int hash = System.identityHashCode(element);
int pos = ((hash << 1) - (hash << 8)) & (length - 1);
```

IdentityHashMap

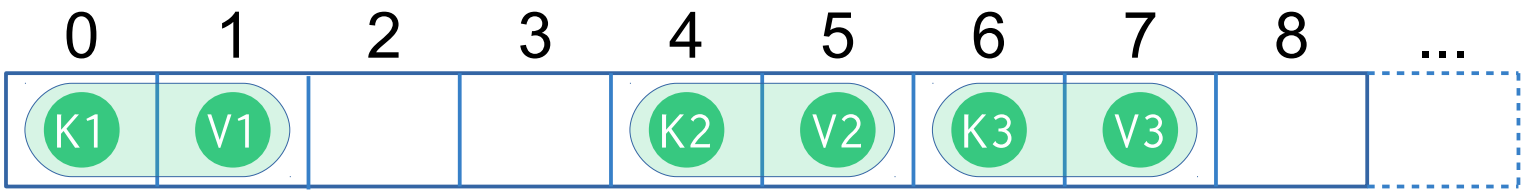

IdentityHashMap

- Tableau initial de 32 cases (16 éléments)
- Load factor 0.66

- Redimensionnement
  - Taille x 2
  - Re-hachage

IdentityHashMap

- Performance en `O(1)`
  - Insertion, recherche
- Dégradée en `O(n)`
- Parcours ∝ capacité

Performances des tables de hachage

- Directement liées à la qualité de la fonction
- Fonction idéale
  - Dispersion importante
  - Très rapide à calculer
- A éviter : constante

Dispersion

- Insertion de 2M `Strings` dans un `HashSet`

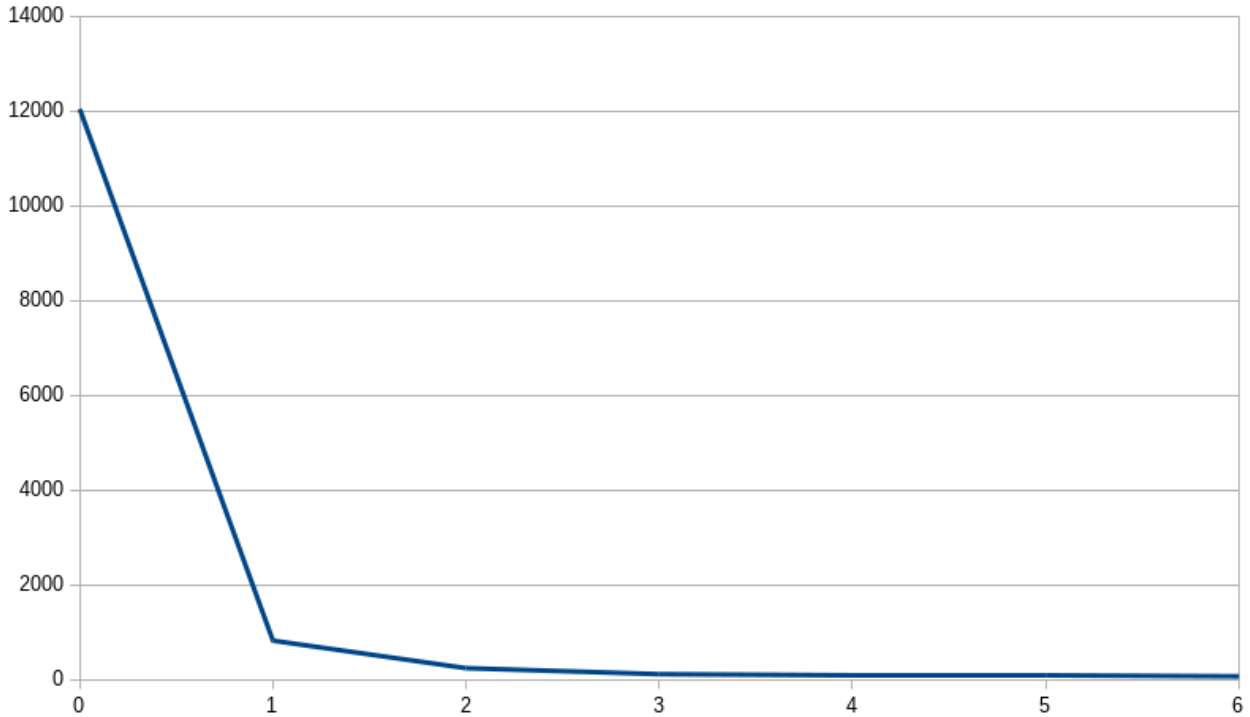

chars	time(s)
0	12046
1	828
2	247
3	122
4	92
5	82
6	75

Hashcode par défaut

- `Object.hashCode()`
  - Méthode native

- Mythe : Adresse mémoire ?
  - 6 algorithmes dans OpenJDK 8
  - `-XX:hashCode={0-5}`
  - Par défaut : `-XX:hashCode=5`

Hashcode par défaut

- 0 : Random
- 1 : Manipulation des bits de l'adresse xor random
- 2 : Constante : 1
- 3 : Séquence
- 4 : Adresse mémoire
- 5 : Marsaglia xor-shift

Hashcode par défaut

- Est écrit dans le header de l'objet de manière thread-safe

- A des impacts sur la synchronisation
  - Biased locking
  - `System.identityHashCode()`

Pré-dimensionnement

- Minimise les collisions
  - Dégradation ∝ taux de collision
- Evite le redimensionnement
  - Garbage
  - Re-hachage

Pré-dimensionnement

- Estimer par excès
  - Eviter le redimensionnement
- Tenir compte des implémentations
  - Load factor
  - Alignement aux puissances de 2

DEVOXX France

Pré-dimensionnement

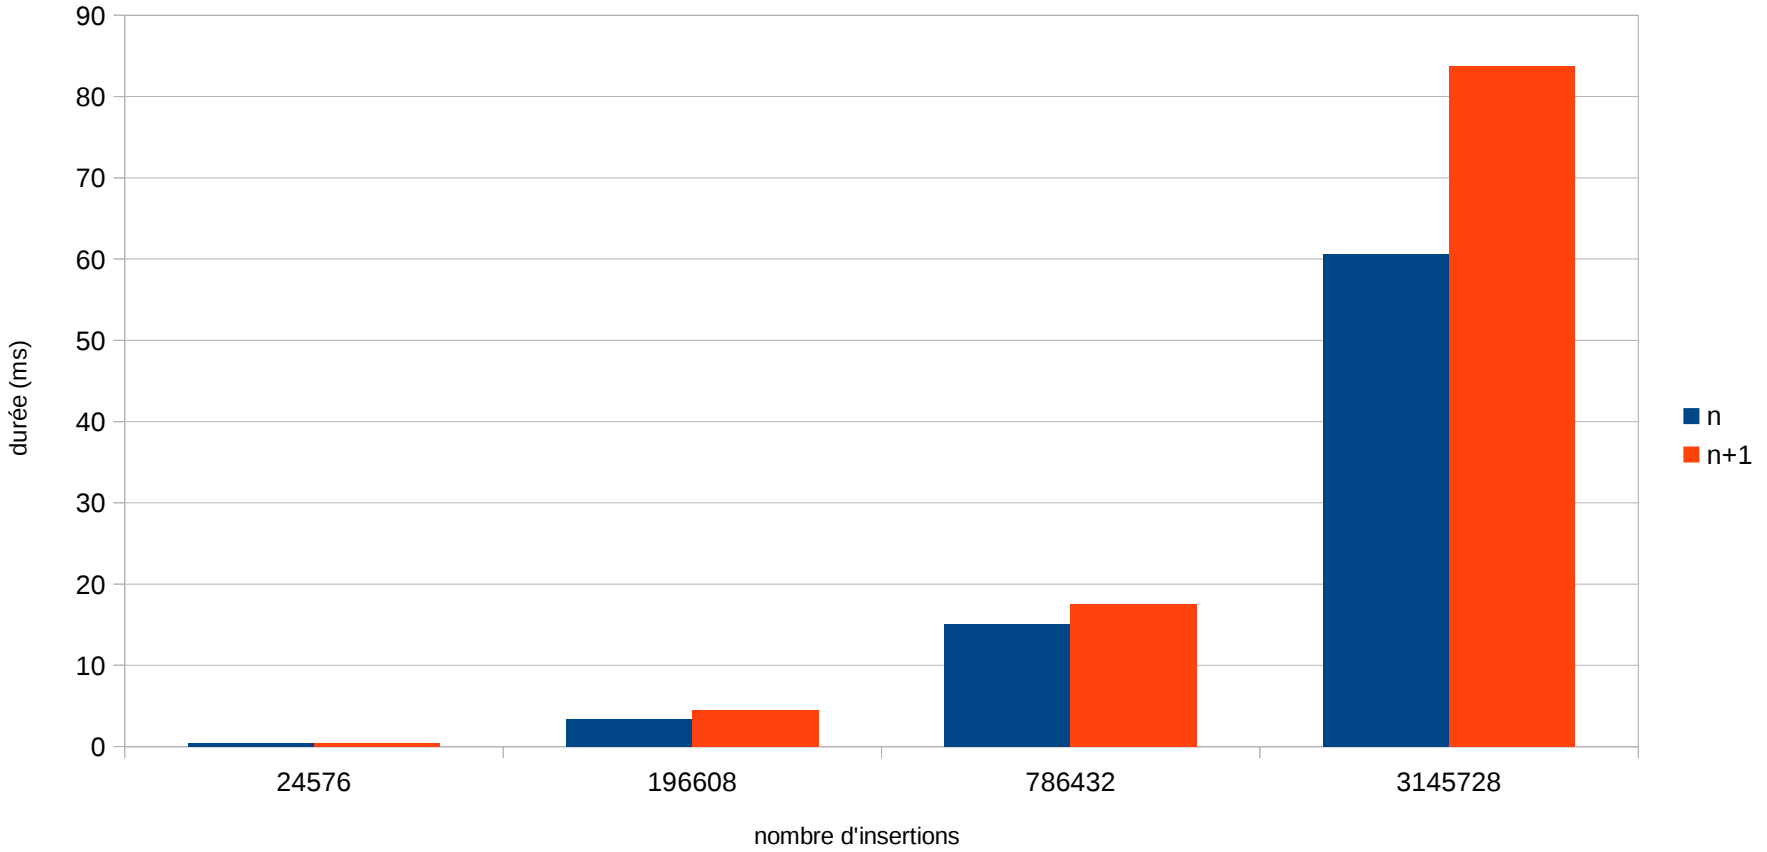

DEVOXX France

Pré-dimensionnement

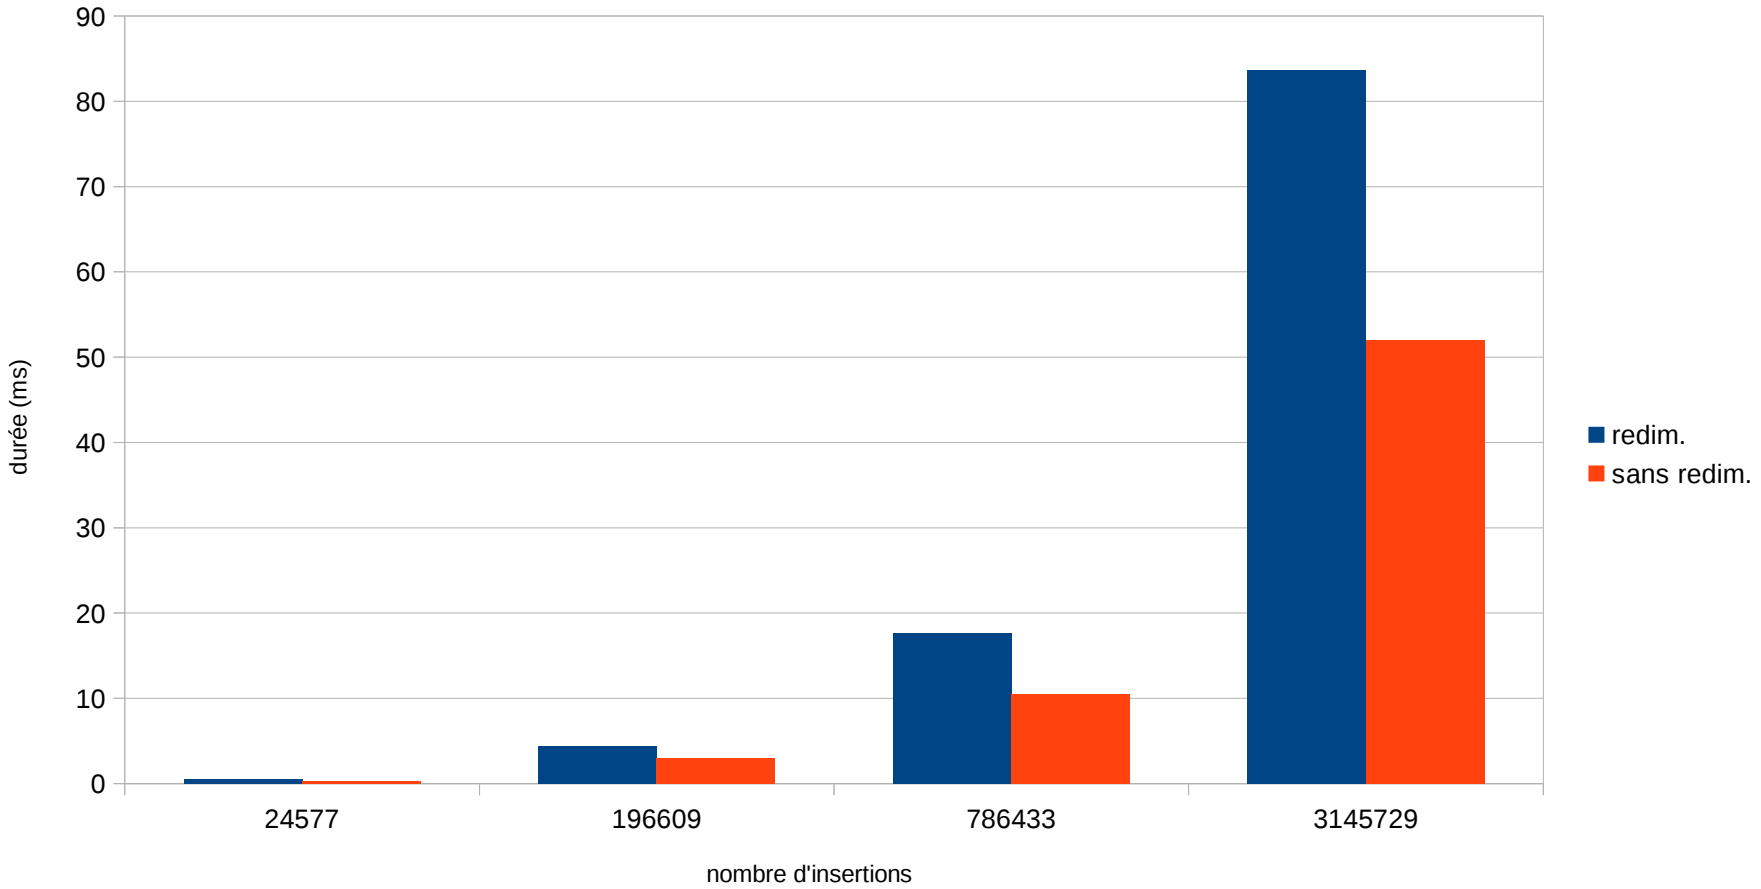

Résolution des collisions

- Chaînage
  - Avec ou sans nœud initial
- Open addressing
  - Linear / quadratic probing
  - Double hashing
- Cuckoo hashing...

DEVOXX France

Conclusion

- Les méthodes `equals()` et `hashCode()` sont importantes
  - Identité métier
  - Performance et cohérence des collections
- Respectez les contrats
- Etudiez les structures de données
  - Dans le JDK et en-dehors

DEVOXX FRANCE 2015

Olivier BOURGAIN
Freelance
OBMG
@OlivierBourgain

Olivier CROISIER
Freelance
Moka Technologies
@OlivierCroisier

Questions ?

Hashons peu, mais hashons bien