Collection

Rémi Forax
forax@univ-mlv.fr

Structures de données

En Java, il existe 3 sortes de structures de données

Les tableaux

- Structure de taille fixe, accès direct aux élements

Les Collections

- Structure modifiable, différents algorithmes de stockage

Les Map

- Structure modifiable, stocke des couples clé -> valeur

Contrats !

Tous les algorithmes sur les structures données pré-suppose que les classes des objets stockés respect un certain contrat

Il vous faudra peut-être pour cela implanter correctement equals, hashCode, toString et/ou compareTo sur les objets de la collection

Si ce n'est pas le cas, cela fait n'importe quoi (avec pas mal de chance une exception est levée)

Exemple

```
public class StupidInteger {
  private final int value;
  public StupidInteger(int value) {
    this.value = value;
  }
}

StupidInteger[] array = new StupidInteger[1];
array[0] = new StupidInteger(1);
Arrays.sort(array);                    // ClassCastException

HashSet<StupidInteger> set = new HashSet<>();
set.add(new StupidInteger(1));
set.contains(new StupidInteger(1));  // renvoie false !
```

Null comme valeur d'une collection

Stocker null dans une collection n'est pas une bonne idée car cela plantera qund on sortira l'élement de la collection

De plus, en fonction des versions du JDK, null est accepté ou non

- 1.0, 1.1, null est pas accepté
  - HashTable, Vector, Stack
- 1.2, 1.3, 1.4, null est accepté
  - HashMap, ArrayList, etc
- 1.5 ..., null est pas accepté
  - PriorityQueue, ArrayDeque, etc)

Null comme Collection

On utilise **jamais** null lorsque l'on s'attend à avoir un tableau ou une Collection

```
public Collection<String> getFoo() {
   return null;  // ahhh, utiliser Collections.emptyCollection()
}
public String[] getBar() {
  return null;   // ahhhh, utiliser NULL_ARRAY
}
private static final String[] NULL_ARRAY = new String[0];
```

Il existe des collections vide qui sont des constantes, Collections.**emptySet**(), Collections.**emptyList**(), etc.

Les tableaux

Ils ont une taille fixe définie à l'initialisation et sont toujours mutable (copie défensive!)

Les tableaux sont spécialisés pour les types primitifs

- byte[], int[], long[], double[]
- Ils n'héritent pas de Object[] mais de Object

Algos classiques (java.util.Arrays)

fill() remplie un tableau (memset en C)

copie

- System.arrayCopy (memcopy en C)
- Arrays.copyOf() (créé et recopie un tableau + grand ou + petit)

toString, deepToString, equals, hashCode, etc

Quand utiliser des tableaux

On utilise rarement des tableaux dans le code utilisateur

- demande à connaître la taille à l'avance
- marche pas bien avec les types paramétrés

    new ArrayList<String>[3] compile pas !

Les tableaux sont utiles principalement lorsque l'on veut s'écrire sa propre structure de données

Collection

L'interface java.util.Collection est l'interface de base de toutes les structures de donnée qui stocke des éléments

Il existe 4 sous-interfaces

- Set, ensemble sans doublon
- List, les listes ordonées et indexées
- Queue, les files (FIFO)
- Deque, les files “*double ended*”

La hiérarchie des collections

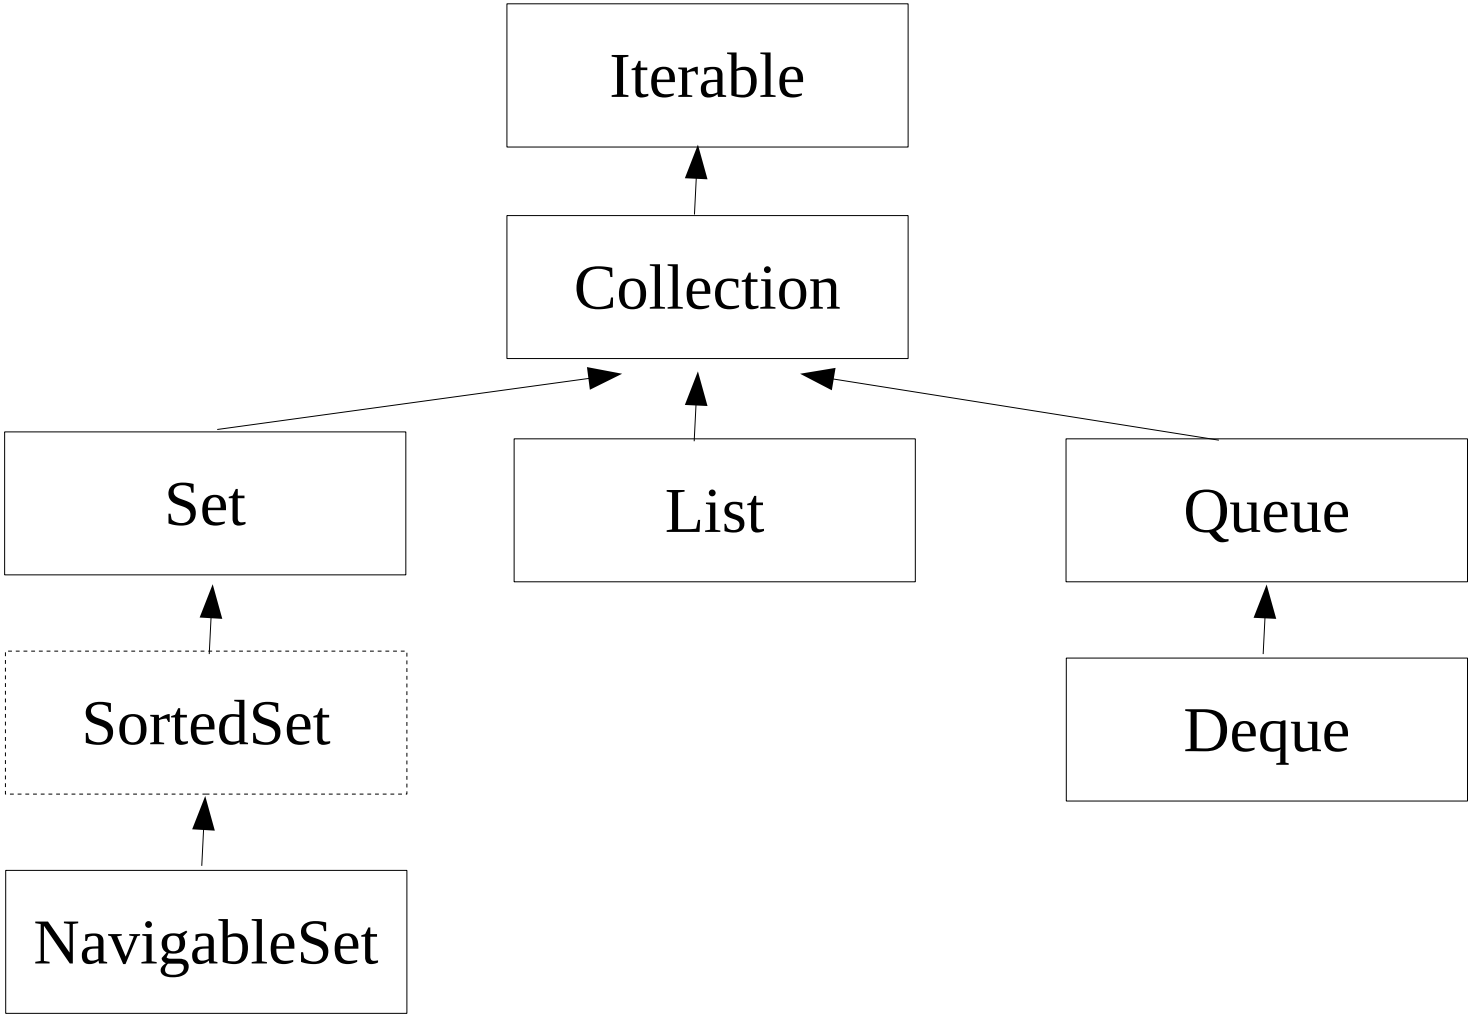

Collection<E> paramétrée

Les collections sont homogénes, elle contiennent des élements qui ont le même type (pas forcément la même classe)

donc elles sont paramétrés par une variable de type, souvent nommée E pour type d'un élement

Collection et type primitif

Les collections ne sont pas spécialisées pour les types primitfs, ce sont des collections d'objet

On utilise le boxing/unboxing si il n'y a pas d'exigence de performance

```
ArrayList<Integer> list = new ArrayList<>();
list.add(1);  // boxing en Integer.valueOf(1)
int value = list.get(0); // unboxing avec .intValue()
```

attention si on stocke null dans la list,
il y aura un NullPointerException

Collection et taille

A l'exception des collections concurrentes, toutes les collections maintiennent une taille accessible en temps constant (O(1))

int **size**()

permet d'obtenir la taille (sur 31 bits)

boolean **isEmpty**()

permet de savoir si la collection est vide

Collection & mutabilité

Les Collections sont mutables par défaut

boolean **add**(E)

- Ajoute un élement, renvoie vrai si la collection est modifiée

boolean **remove**(Object)

- Supprime un élement, renvoie vrai si la collection est modifiée

boolean **removeIf**(Predicate<? super E> predicate)

- Supprime un élement si le predicate est vrai, renvoie vrai si la collection est modifiée

void **clear**()

- Supprime tous les élements d'une collection (peu utilisée)

Operations optionnelles

Les opérations de mutations (add, remove, clear, addAll, etc) peuvent levées l'exception UnsupportedOperationException pour dire que dire que l'opération n'est pas supportée

Cela permet de représenter des collections non-mutable

Collection non mutable

Collections.unmodifiable*Collection*() permet de créer un proxy implantant seulement les opération non-optionnel devant une collection modifiable

```
ArrayList<String> list = new ArrayList<>();
List<String> list2 = Collections.unmodifiableList(list);
list2.add("hello");   // UnsupportedOperationException
list.add("hello");    // ok
list2.size();         // renvoie 1
```

Cela permet d'éviter les copie défensive !

Object ou E ?

Pourquoi remove(**Object**) et add(**E**) ?

A cause des interfaces

```
interface I {}
interface J {}
class A implements I, J {}

public static void main(String[] args) {
  Collection<I> collection = ...
  A a = new A();
  collection.add(a);  // ok, A est un sous-type de I
  J j = a;
  collection.remove(j); // doit pouvoir compiler !
```

Recherche

java.util.Collection possède une méthode de recherche

- boolean **contains**(Object)
  - Renvoie vrai si l'objet est stocké dans la collection

Note sur la complexité:

- contains (ou add, remove, etc.) a une complexité différente suivant la structure de donnée
  - contains pour une HashSet est O(1), pour un TreeSet est O(ln n) et pour une ArrayList O(n)

Les méthodes de object

equals, hashCode et toString sont implantés et délègue à l'implantation des élements de la collection

Cela permet d'ajouter une collection à une collection mais dans ce cas la collection ajoutée ne doit pas être modifiée à postériori !

- Ajouter des objets mutables à une collection est poetentiellement dangereux !

Exemple

```
ArrayList<String> list = new ArrayList<>();
HashSet<List<String>> set = new HashSet<>();
set.add(list);
list.add("hello");
set.contains(list);  // false :(
```

note, si on a pas de chance, set.contains(list) peut renvoyer vrai car même si la valeur de hashCode a changé, la liste peut être rangée dans la même case de la table de hachage :((

Bulk (opérations groupées)

Les méthodes groupés

- boolean **addAll**(Collection<? extends E>)
  - ajoute tous les élements de la collection dans this
- boolean **removeAll**(Collection<?>)
  - supprime les élements de this qui sont aussi dans la collection
- boolean **retainAll**(Collection<?>)
  - retient dans this les élements qui appartiennent à this et à la collection (intersection)
- boolean **containAll**(Collection<?>)
  - renvoie vrai si this contient tous les élements de la collection

Bulk

addAll(), par exemple, est équivalent à

```
public boolean addAll(Collection<? extends E> c) {
    boolean result = false;
    for(E element: c) {
        result |= this.add(element);
    }
    return result;
}
```

mais peut être écrite de façon plus efficace en fonction de l'implantation

java.util.Set

Ensemble d'élements **sans doublons**

Par ex. les options de la ligne de commande

Exactement la même interface que Collection, la sémantique des méthodes est pas la même

par ex, add() renvoie false si doublons

Implantations de Set

HashSet

table de hachage

Ensemble sans ordre, add/remove en O(1)

LinkedHashSet

Table de hachage + list chainée

Ordre d'insertion (ou d'accès), add/remove en O(1)

TreeSet

Arbre rouge/noir (ordre de comparaison)

Ordre par un comparateur, add/remove en O(ln n)

Exemple

Détecter des doublons dans les arguments de la ligne de commande

```
public static void main(String[] args) {
    HashSet<String> set = new HashSet<>();
    for(String arg: args) {
        if (!set.add(arg)) {
            System.err.println("argument " + arg + " specified twice");
            return;
        }
    }
}
```

java.util.List

Liste d'élement **indexé** conservant l'**ordre d'insertion**

Par ex, la liste des vainqueurs du tour de France

Méthodes supplémentaires

E **get**(int index), E **set**(int index, E element)

- accès en utilisant un index

int **indexOf**(E element), **lastIndexOf**(E element)

- comme contains mais qui renvoie un index ou -1

void **sort**(Comparator<? Super E>)

- Trie en fonction d'un ordre de comparaison

Exemples

Trier en fonction de la première lettre

```
void sortByFirstLetter(List<String> list) {
  list.sort((s1, s2) -> s1.charAt(0) – s2.charAt(0));
}
```

Attention aux problèmes d'overflow!

```
void sortByAge(List<Person> list) {
  list.sort((p1, p2) -> p1.getAge() - p2.getAge());
}  // marche pas !!
```

```
void sortByAge(List<Person> list) {
  list.sort(
    (p1, p2) -> Integer.compare(p1.getAge(), p2.getAge()));
} // ok
```

```
void sortByAge(List<Person> list) {
  list.sort(Comparator.comparingInt(Person::getAge));
} // et peut aussi utiliser les comparateurs déjà écrit
```

Implantations de List

ArrayList

Tableau dynamique

Ajout à la fin en 0(1), ajout au début en O(n), accès indexé en O(1)

LinkedList

List doublement chaînée

Ajout à la fin en 0(1), ajout au début en O(1), accès indexé en O(n)

Problème de l'interface List

java.util.List est pas une interface dangereuse en terme de complexité

- Accès indexé à une LinkedList est en O(n)
- ajouter un élement en tête d'une ArrayList est en O(n)

On accède pas de façon indexée à une java.util.List, pas de problème si c'est une ArrayList

java.util.RandomAccess

Les listes à accès indexées en tant constant doivent implanter java.util.Random (marker interface)

Il est possible de tester à l'exécution l'accès indexée est en temps constant

```
list instanceof RandomAccess
```

pas très beau mais on a pas mieux :(

Note: ce n'est pas exactement ce que dit la doc de l'interface RandomAccess mais c'est vrai en pratique

Exemple

```
private static int sum(List<Integer> list) {
  int sum = 0;
  for(int i = 0; i < list.size(); i++) {
    sum += list.get(i);
  }
  return sum;
}
public static void main(String[] args) {
  List<Integer> list;
  if (args[0].equals("linked")) {
    list = new LinkedList(1_000_000);
  } else {
    list = new ArrayList(1_000_000);
  }
  for(int i = 0; i < 1_000_000; i++) {
    list.add(i);  // boxing !
  }
  System.out.println(sum(list));    // si list est une LinkedList, c'est long !
}
```

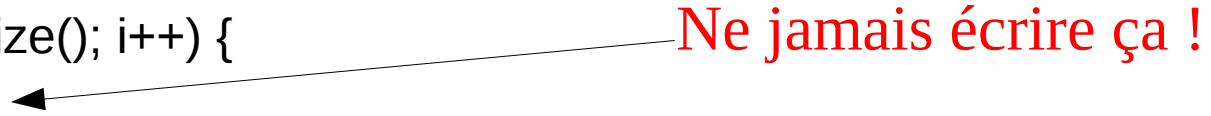

Map

Appelée aussi table associative ou dictionnaire, une map fonctionne avec deux élements

- un élement clé (de type K) et
- un élement valeur (de type V)

Les clés insérées n'ont pas de doublons

Il est possible d'avoir des doublons au niveau des valeurs

java.util.Map<K,V>

méthodes

- V **put**(K key, V value)

  insére un couple clé/valeur et supprime si il existe le couple clé/valeur précédent ayant la même clé, renvoie l'ancienne valeur ou null

- V **get**(Object key)

  renvoie la valeur correspondant à une clé ou null si il n'y a pas de couple clé/valeur ayant la clé key

- **isEmpty**() et **size**()

  renvoie si la map est vide/le nombre de couples clé/valeur

Obtenir un couple

en plus de get(), il existe les méthodes

V **getOrDefault**(V defaultValue)

permet de renvoyer une valeur par défaut au lieu de null comme pour get

V **computeIfAbsent**(K key, Function<K,V> fun)

renvoie la valeur associée à la clé, si il n'y a pas de valeur, appel la fonction pour obtenir valeur et enregistre le couple clé/valeur (pratique pour un cache)

boolean **containsKey**()

permet de savoir si la clé existe, très peut utilisé car

- soit cela veut dire que l'on veut un Set
- soit que l'on va faire un get() derrière dans ce cas autant faire un get() uniquement

Insérer/supprimer un couple

en plus de put(), il existe les méthodes

V **putIfAbsent**(K key,V value)

comme put mais n'ajoute pas un couple existe déjà

V **remove**(Object key)
boolean **remove**(Object key, Object value)

supprime un couple (à partir de la clé, ou du couple)

V **replace**(K key, V value)
boolean **replace**(K key, V oldValue, V newValue)

remplace un couple (à partir de la clé, ou du couple)

Bulk operations

Opérations groupées

void **putAll**(Map<? extends K, ? extends V> map)

insére tous les élements de map dans this

void **replaceAll**(BiFunction<? super K, ? super V, ? extends V> fun)

remplace toutes les valeurs des couples existant dans la Map par de nouvelles fournies pas la fonction

Il n'y a pas de removeAll(map) car cela peut être fait sur l'ensemble des clés (cf suite du cours)

Implantations

HashMap

Table de hachage sur les clés

Les couples ne sont pas ordonées, insertion/accès/suppression en O(1)

LinkedHashMap

Table de hachage sur les clés + liste doublement chaînée

Couples ordonnées par ordre d'insertion (ou d'accès), insertion/accès/suppression en O(1)

TreeMap

Arbre rouge noir (ordre de comparaison)

Couple ordonée suivent l'ordre de comparaison, insertion/accès/suppression en O(ln n)

Vues et ponts entre les structures

Pont et vue entre les collections

Il existe deux types méthodes de “conversions”

- Copier les données d'une structure vers une nouvelle

  les données sont dupliquer dans la nouvelle structure

- Voir une structure de donnée comme une autre

  les données reste dans la structure initiale et sont aussi vue dans la nouvelle structure, on parle de vue

Interopération par copie

Collection vers les tableaux

Object[] Collection.toArray()

Créer un tableau d'Object

<T> T[] Collection.toArray(T[] array)

Utilise le tableau pris en paramètre, ou crée un nouveau tableau si le tableau est trop petit

- si le tableau est trop grand, on met null après le dernier élement ??

Exemple

```
ArrayList<Object> list = ...
// on supprime tous ce qui n'est pas des Strings
list.removeIf(e -> !(e instanceof String));
// puis on met le résultat dans un tableau de String
String[] array = list.toArray(new String[0]);
```

Le code est bizarre mais idiomatique

Interopération par copie

Collection vers Collection

Toutes les collections ont un constructeur qui prend une Collection<? extends E>

Sur une collection addAll(Collection<? extends E>) permet d'ajouter

Tableau vers Collection

<T> Collections.addAll(
Collection<? super T> coll,T... array)

Interopération par vue

Tableau vers List

<T> List<T> Arrays.asList(T... array)

List vers List

list.subList(int start, int end) permet d'obtenir une sous-liste d'une liste

Map vers Set

Set<E> Collections.newSetFromMap(
Map<E, Boolean> map)

Queue vers Queue

Queue<T> Collections.asLifoQueue(
Deque<T> deque)

Exemple

Il n'existe pas de méthode contains() ou shuffle() qui prend en paramètre un tableau dans java.util.Arrays mais en utilisant une vue ...

```
public static void main(String[] args) {
  List<String> list = Arrays.asList(args);
  list.contains("bingo");
              // search if "bingo" is contained in args
  Collections.shuffle(list);
             // the array args is now suffled
}
```

Interopération par vue

Map vers l'ensemble des clés

Set<K> map.keySet()

Map vers la collection des valeurs

Collection<V> map.values()

Map vers l'ensemble des couples clé/valeur

Set<Map.Entry<K,V>> map.entrySet()

Map.Entry<K,V>

interface interne de l'interface Map, représente des couples clé/valeur mutable

Opérations

K **getKey**()

renvoie la clé du couple

V **getValue**()

renvoie la valeur du couple

V **setValue**(V value)

change la valeur du couple (opération mutable optionelle)

Exemple

Parcours des couples clés-valeurs

```
HashMap<String, Integer> map = ...
for(Map.Entry<String,Integer> entry: map.entrySet()) {
  System.out.println("key " + entry.getKey());
  System.out.println("value " + entry.getValue());
}
```

en fait il existe une façon plus simple d'écrire le même code (cf chapitre suivant)

Itération

Itération Interne vs Externe

Il existe deux types d'itération sur une collection

- Itération interne

  On envoie du code (sous forme de lambda) à exécuter par la structure de donnée, la structure parcours sa structure et pour chaque élement appel la lambda avec l'élement en paramètre

- Itération externe

  On demande à la collection un curseur (un Iterator) qui va servir à parcourir la collection en retournant un élement à chaque appel

java.util.Iterable sert d'interface pour les 2 façons d'itérer

Itération interne

Iterable.**forEach**(Consumer<? super E> consumer)

avec

```
@FunctionalInterface
public interface Consumer<T> {
   public void accept(T t);
}
```

exemple :

```
List<String> list = ...
list.forEach(e -> System.out.println(e));
```

Itération interne sur une Map

Map.**forEach**(BiConsumer<? super K, ? super V> bc)

avec

```
@FunctionalInterface
public interface BiConsumer<T, U> {
   public void accept(T t, u u);
}
```

exemple :

```
HashMap<String, Integer> map = ...
map.forEach((key, value) -> {
  System.out.println("key: " + key + " value: " + value);
});
```

Iteration externe

Iterator<E> Iterable.iterator()

avec

```
public interface Iterator<E> {
  public boolean hasNext();
  public E next();
}
```

existe t'il un élement suivant ?
la méthode n'a pas d'effet de bord

renvoie l'élement courant et passe au suivant ou NoSuchElementException

exemple :

```
List<String> list = ...
Iterator<String> it = list.iterator(); // on récupère le 'parcoureur'
while(it.hasNext()) {
  System.out.println(it.next());
}
```

Position de l'itérateur

A la création :

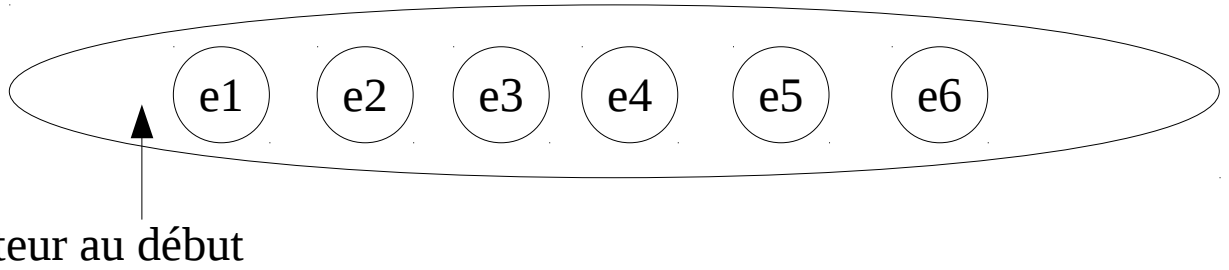

Après un appel à iterator.next() :

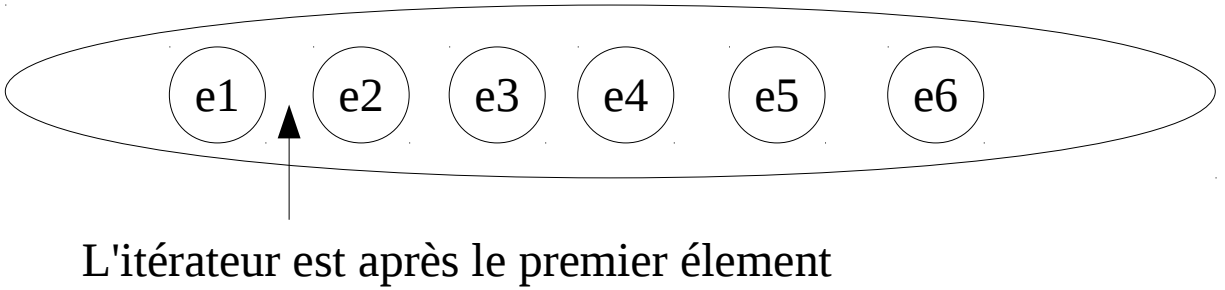

Si hasNext() renvoie false :

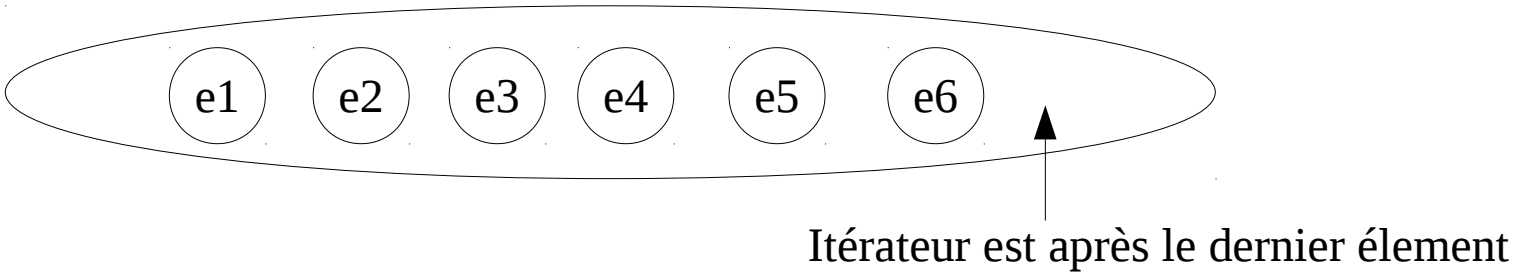

Syntaxe pour l'itération externe

La boucle for(type var: iterable) sur un **Iterable** est transformé en

```
Iterator<type> it = iterable.iterator();
while (it.hasNext()) {
  type var = it.next();
  ...
}
```

Attention à ne pas confondre avec for(type var: array) qui parcours le **tableau** avec des index

Mutation de la collection et itération

Il est **interdit** d'effectuer une **mutation** sur la structure de donnée **durant l'itération** !

Itération interne :

```
Set<String> set = ...
set.forEach(e -> set.add(e));
   // throws ConcurrentModificationException
```

Itération externe :

```
Set<String set = ...
for(String e: set) {
  set.add(e);
} //  throws ConcurrentModificationException
```

ConcurrentModificationException

Exception levée lorsque durant le parcours, on modifie la structure de donnée sur laquelle on itére

- L'exception est **mal nommée**
- Concurrent veut dire normalement accéder par différents fils d'exécution (thread) mais ce n'est pas le cas ici :(

La technique qui consiste lors du parcours à regarder si une mutation a été effectuée ou pas est appelée fail-fast.

Mutations lors du parcours

Il est possible d'éviter la lévée de ConcurrentModificationException dans le cas d'une itération externe, car il est possible de faire les mutations directement sur l'itérateur

- **Iterator** possède une méthode **remove**()
- **ListIterator** qui est une version spécialiser de l'itérateur (et donc hérite de Iterator) pour les listes possèdes en plus les méthodes **add**() et **set**()

Iterator.remove

Supprime l'élement qui a été renvoyer précédemment par next()

- donc next() doit être appelé d'abord
- Il n'est donc pas possible de faire 2 removes de suite sans appeler next() entre les deux
- Lève IllegalStateException si next pas appelé avant

Exemples

Exemple qui ne marche pas (CME) :

```
LinkedList<String> list = ...
for(String s: list) {
  if (s.length() % 2 == 0) {
    list.remove(s);  // la complexité est affreuse aussi :(
  }
}
```

Exemple qui marche :

```
Iterator<String> it = list.iterator();
while(it.hasNext()) {
  String s = it.next();
  if (s.length() % 2 == 0) {
    it.remove();
  }
}
```

Exemples (suite)

il y a une façon plus simple, au lieu d'utiliser l'itérateur:

```
Iterator<String> it = list.iterator();
while(it.hasNext()) {
  String s = it.next();
  if (s.length() % 2 == 0) {
    it.remove();
  }
}
```

On peut aussi utiliser removeIf !

```
list.removeIf(s -> s.length() % 2 == 0);
```

Iteration à l'envers

Sur une List, il est possible de parcourir celle-ci du dernier élement au premier en utilisant le ListIterator

Exemple:

```
List<String> list = ...
ListIterator<String> it = list.listIterator(list.size);
                                        // on place l'itérateur à la fin
while(it.hasPrevious()) {
  String s = it.previous();
  ...
}
```

Parcours indexé

Attention, le parcours indexé peut être **mortel**

Exemple :

```
List<String> list = ...
for(int i = 0, i < list.size(); i++) {
  String s = list.get(i);
  ...
}
```

Si list.get() est pas en temps constant,
alors la complexité est $O(n^2)$

L'itération external ce se fait avec l'Iterator à part si on est sûre que la liste implante RandomAccess.

ltération interne vs externe

L'itération interne est souvent plus efficace mais comme on envoie une lambda à iterable.forEach(), on est limité par le fait qu'une lambda n'est pas une closure

- il n'est pas possible d'effectuer des mutations sur les variables locales à l'intérieur d'une lambda

De plus, l'itération externe permet aussi la composition d'itérateurs

Legacy Collections

Legacy collection

java.util existe depuis 1.0 mais API des collections existe que depuis la version 1.2

Vector, Stack, Hashtable et Enumeration sont des anciennes classes

- qui ne doivent plus utilisé à part pour discuter avec du code legacy
- Les 3 premières ont des problèmes de performance car leurs méthodes sont synchronized

Classe de remplacement

Les classes de remplacement ont la même API (ou une API très similaire) que les classes legacy

Vector	->	ArrayList
Stack	->	ArrayDeque
Hashtable	->	HashMap
Enumeration	->	Iterator

plus la méthode Collections.list(enumeration) -> List