OCTO Technology
There is a better way

Les secrets de la JVM pour les algorithmes à haute fréquence

Version : 1.1
PerfUG – 27 Aout 2015

50, avenue des Champs-Elysées
75008 Paris - FRANCE

Tél : +33 (0)1 58 56 10 00
Blog.octo.com
www.octo.com

- Philippe PRADOS
- Manager équipe « Architecture Réactive »

Reactive

- +PhilippePrados
- @pprados
- in/pprados/fr
- BrownBagLunch.fr

- Conférences:
  - Solution Linux
  - MISC
  - Devoxx
  - PAUG
  - Scala IO
  - …

Attention, pour Barbus !!!

- Un algorithme à haute fréquence doit **exploiter au mieux les architectures des processeurs** pour obtenir un maximum de performance

- L'objectif est triple :
  - Exploiter au maximum la mémoire
  - Éviter les verrous. Il faut qu'à tout moment, l'algorithme puisse poursuivre son exécution
  - Exploiter au maximum les caches des processeurs pour l'accès à la mémoire

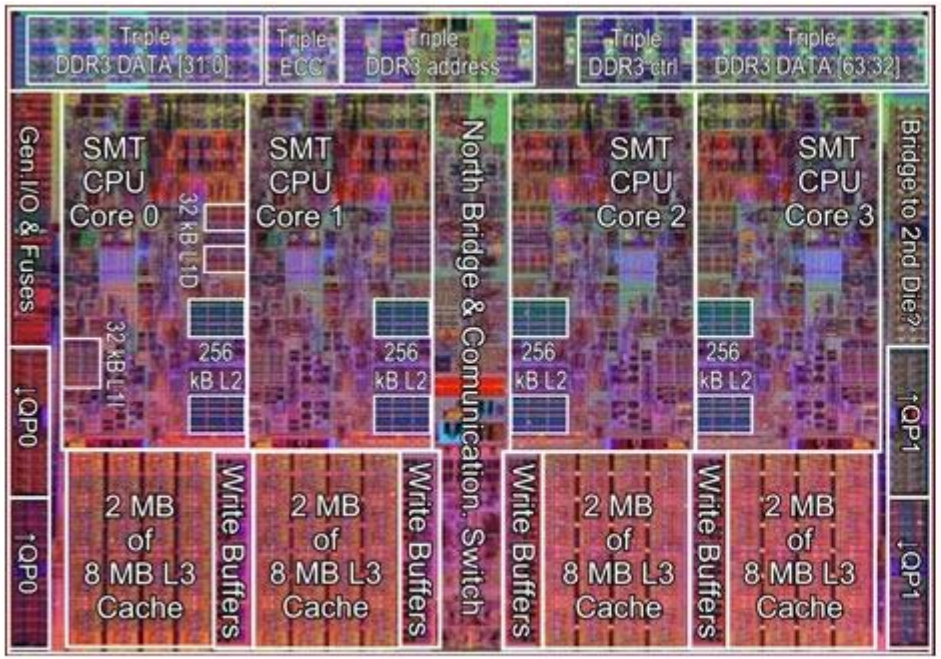

Socket 1

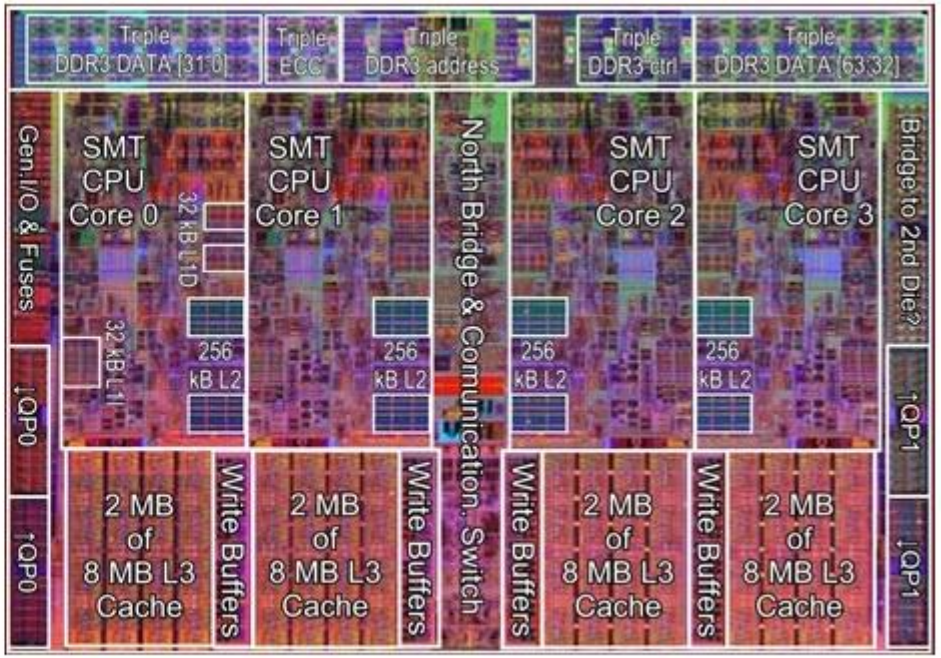

Socket 2

- Un *node* est une machine physique possédant de la RAM.
- Un *socket* est un support où installer un processeur.
- Un *core* est un sous-ensemble du processeur physique, capable d'exécuter des traitements indépendamment des autres *cores* du *socket*.
- Les *virtuals cores* sont des traitements exécutés en parallèle par un seul *core*

- **Softs-threads** : threads **simulant le multi-tâches** par un partage du temps d'un *core* par l'OS (Context switch périodique)

- **Hard-threads** :threads **réellement multi-tâches**, distribué dans les *core* et *virtual core* des différents sockets

- De nombreuses astuces sont utilisées dans la JVM
- Des API spécifiques permettent de les utiliser
- Nous avons identifié **14 secrets** dans 6 familles que nous souhaitons vous révéler

1. L'ASSEMBLEUR
2. EXPLOITATIONS DES CACHES
3. COMPARE AND SET
4. FRAMEWORK
5. AUTRES
6. CONTENEURS LOCK-FREE

L’assembleur

Le constat

- Les registres des processeurs sont les zones mémoire les plus rapides

1. Utiliser autant que possible les registres du processeur

Pseudo Assembleur

```
1 Cell[] as=cells;
```

```
Ldr r1, cells
Sto as,r1
```

```
2 if (as != null ) // Moins efficace
3 {
4 …
5 }
```

```
Ldr r1,as
Cmp r1,0
```

- Une écriture comme celle-ci est plus efficace et permet un meilleur contrôle des caches

```
1 Cell[] as;
2 if ((as = cells) != null ) // Tous reste dans les registres
3 {
4 …
5 }
```

```
Ldr r1, cells
Sto as,r1
Cmp r1,0
```

- **Exemple JVM** : La méthode **add()** de la classe **LongAdder**.

```
// LongAdder
86 if ((as = cells) != null || !casBase(b = base, b + x)) {
87   boolean uncontended = true;
88   if (as == null || (m = as.length - 1) < 0 ||
89     (a = as[getProbe() & m]) == null ||
90     !(uncontended = a.cas(v = a.value, v + x)))
91       longAccumulate(x, null, uncontended);
92 }
```

http://goo.gl/QdihyC

Le constat

- Les instructions câblées sont plus efficaces que les micro-codes

Division binaire de 1010001b (81) par 11b (3) = 11011b (27)
reste 0b

```
 1 0 1 0 0 0 1 | 1 1
-  1 1        |
   1 0 0      | 1 1 0 1 1
 -   1 1      |
       1 0    |
       1 0 0  |
     -   1 1  |
           1 1|
         -  1 1
              0
```

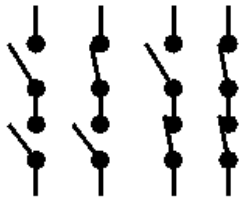

```
AND   0 1 0 1
      0 0 1 1
      0 0 0 1
```

2. Sélectionner les instructions assembleurs les plus rapides

- La taille des tableaux de hashtable est un multiple de 2 (et non un nb premier)

```
// ConcurrentHashMap.java
692 private static final int tableSizeFor(int c) {
693     int n = c - 1;
694     n |= n >>> 1;
695     n |= n >>> 2;
696     n |= n >>> 4;
697     n |= n >>> 8;
698     n |= n >>> 16;
699     return (n < 0) ? 1 : (n >= MAXIMUM_CAPACITY) ? MAXIMUM_CAPACITY :
n + 1;
700 }
```

http://goo.gl/Oon94e

- Permet d'utiliser les opérations binaires (&) à la places des modulo (%)

```
// Striped64.java
226 if ((a = as[(n - 1) & h]) == null) {
227 if (cellsBusy == 0) { // Try to attach new Cell
```

http://goo.gl/WkrRRp

- Avec éventuellement une amélioration du hash (généralement pauvre)

```
// ConcurrentHashMap.java
684    static final int spread(int h) {
685        return (h ^ (h >>> 16)) & HASH_BITS;
686    }
```

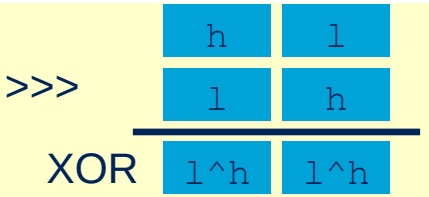

http://goo.gl/vKbhhY

- Ou, plus sérieuse, via l'algo Jenkins qui modifie chaque bit de sortie suivant tous les bits d'entrée

```
// NonBlockingHashMap.java
112   private static final int hash(final Object key) {
113     int h = key.hashCode();     // The real hashCode call
114     // Spread bits to regularize both segment and index locations,
115     // using variant of single-word Wang/Jenkins hash.
116     h += (h <<  15) ^ 0xffffcd7d;
117     h ^= (h >>> 10);
118     h += (h <<   3);
119     h ^= (h >>>  6);
120     h += (h <<   2) + (h << 14);
121     return h ^ (h >>> 16);
122   }
```

http://goo.gl/dZaJaV

Le constat

- Il existe des instructions assembleur spécialisées, plus efficaces qu'un code classique équivalent

3. Injection de code assembleur

- La classe Unsafe est connue du JIT et génère l'équivalent assembleur

```
// atomic_linux_x86.inline.hpp
86 inline jint Atomic::cmpxchg(jint exchange_value,   volatile jint* dest,
                               jint compare_value) {
87   int mp = os::is_MP();
88   __asm__ volatile (LOCK_IF_MP(%4) "cmpxchgl %1,(%3)"
89                     : "=a" (exchange_value)
90                     : "r" (exchange_value), "a" (compare_value), "r" (dest), "r" (mp)
91                     : "cc", "memory");
92   return exchange_value;
93 }
```

http://goo.gl/7hS4T7

- En x86, **AtomicLong.incrementAndGet()** est compilé en **LOCK INC**. **AtomicLong.getAndIncrement()** est compilé en **LOCK XADD**, etc.
- Le préfixe **LOCK** devant une instruction assembleur permet de demander le *flush* des caches mémoire après l'exécution de l'instruction.
- Les implémentations des classes du package **java.util.concurrent** utilisent abondamment cette approche.

Exploitation des caches

Rappel de l'architecture processeur

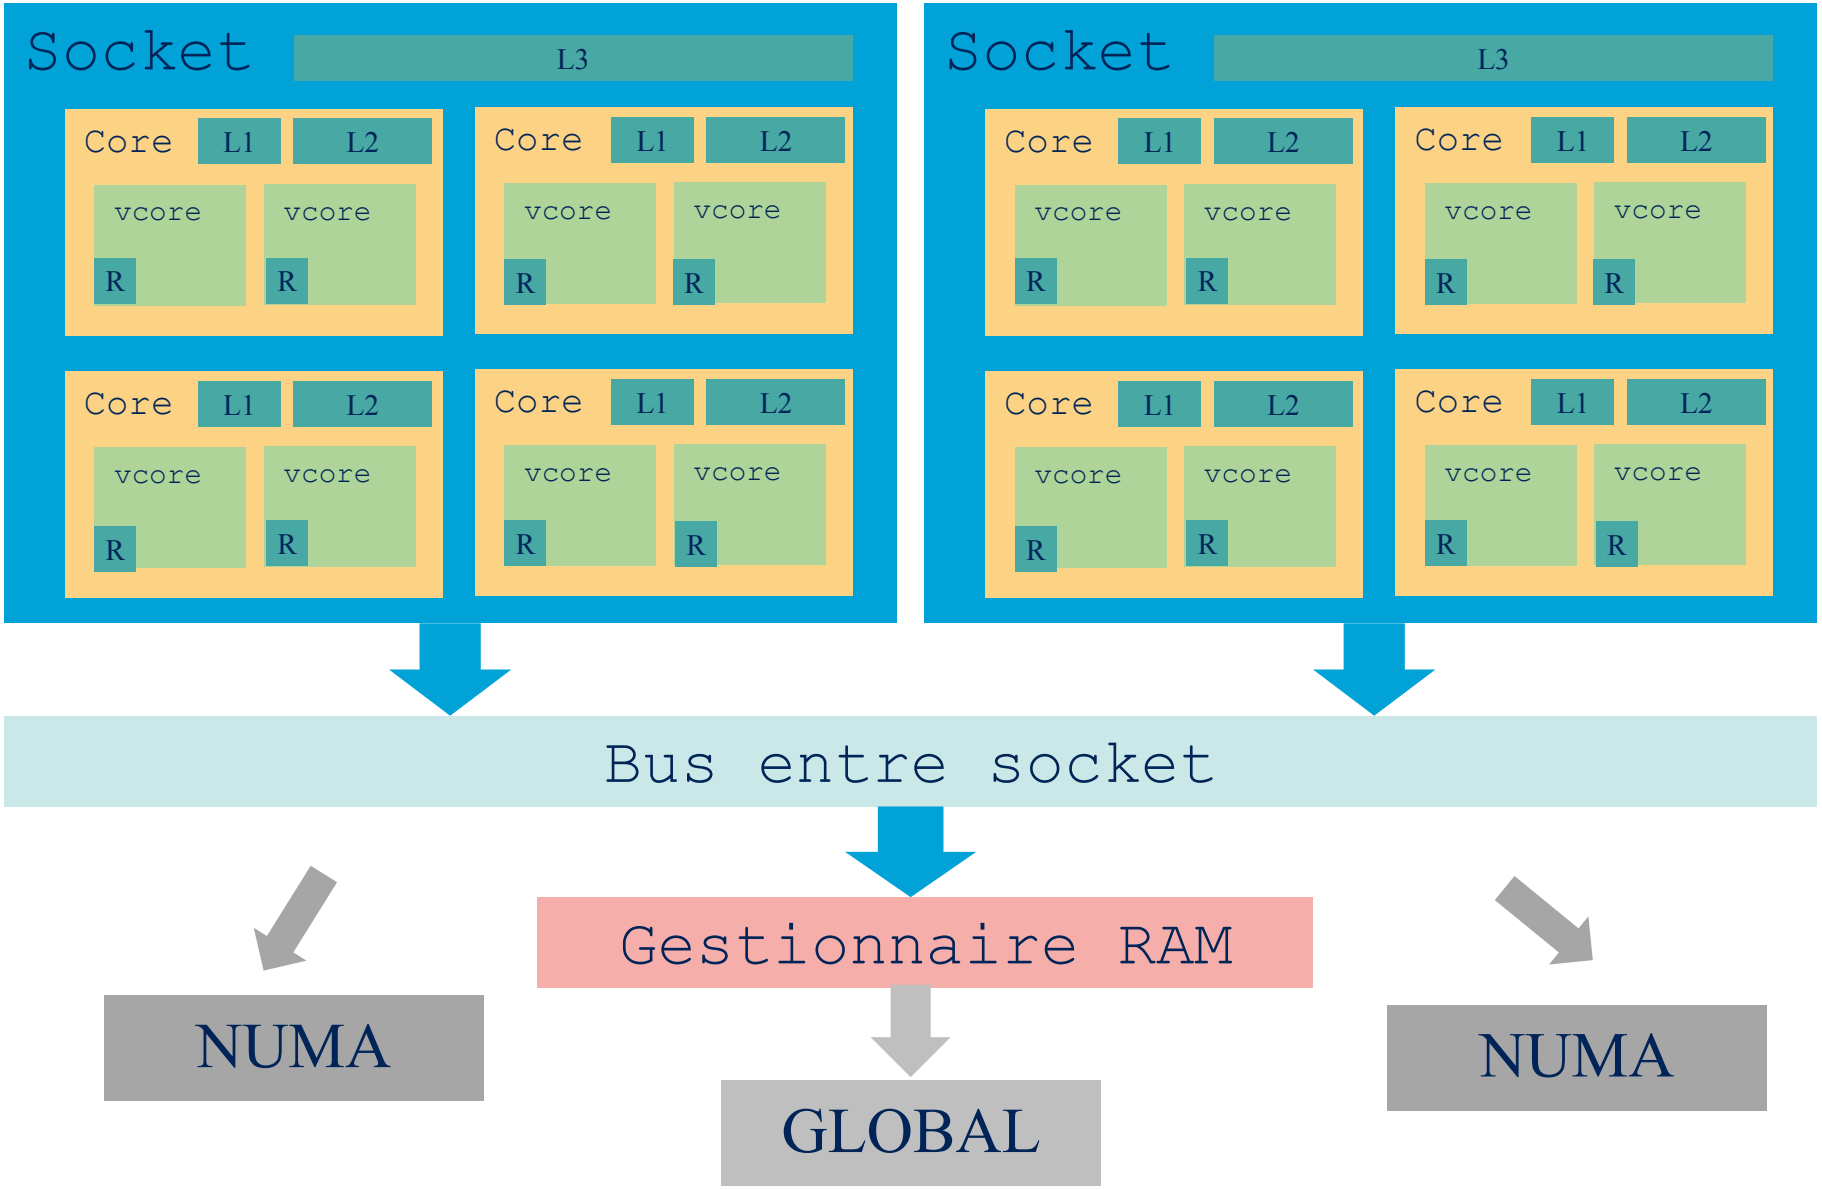

Le constat

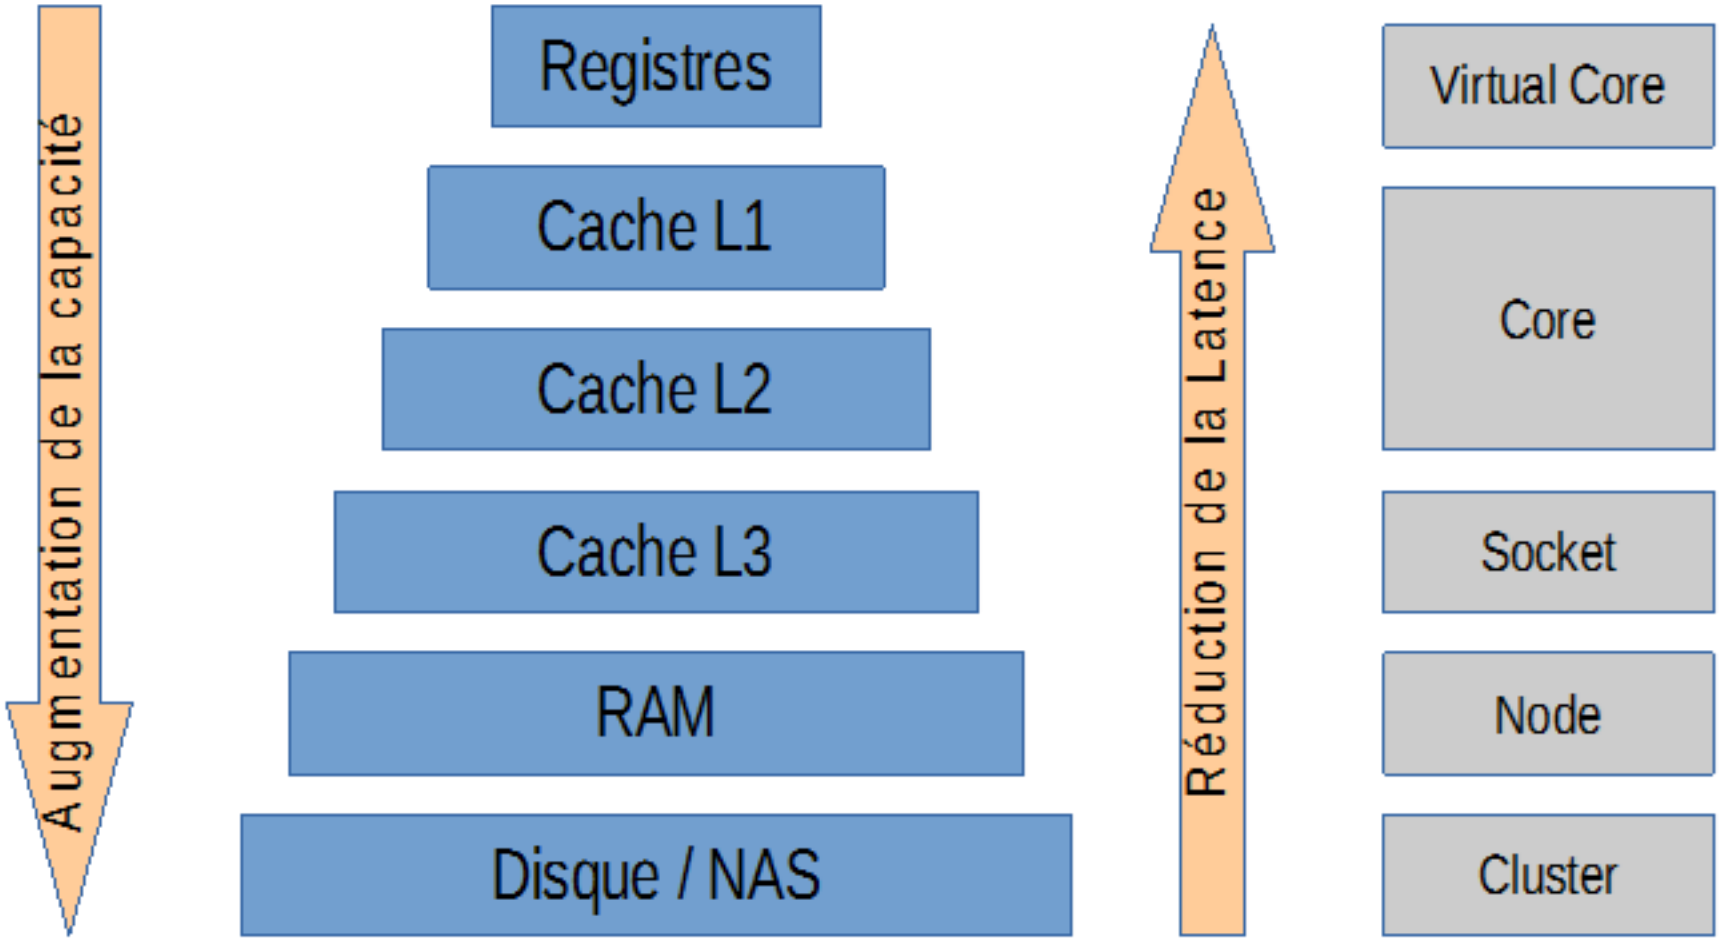
Augmentation de la capacité
Registres
Cache L1
Cache L2
Cache L3
RAM
Disque / NAS
Réduction de la Latence
Virtual Core
Core
Socket
Node
Cluster

Pipeline des caches

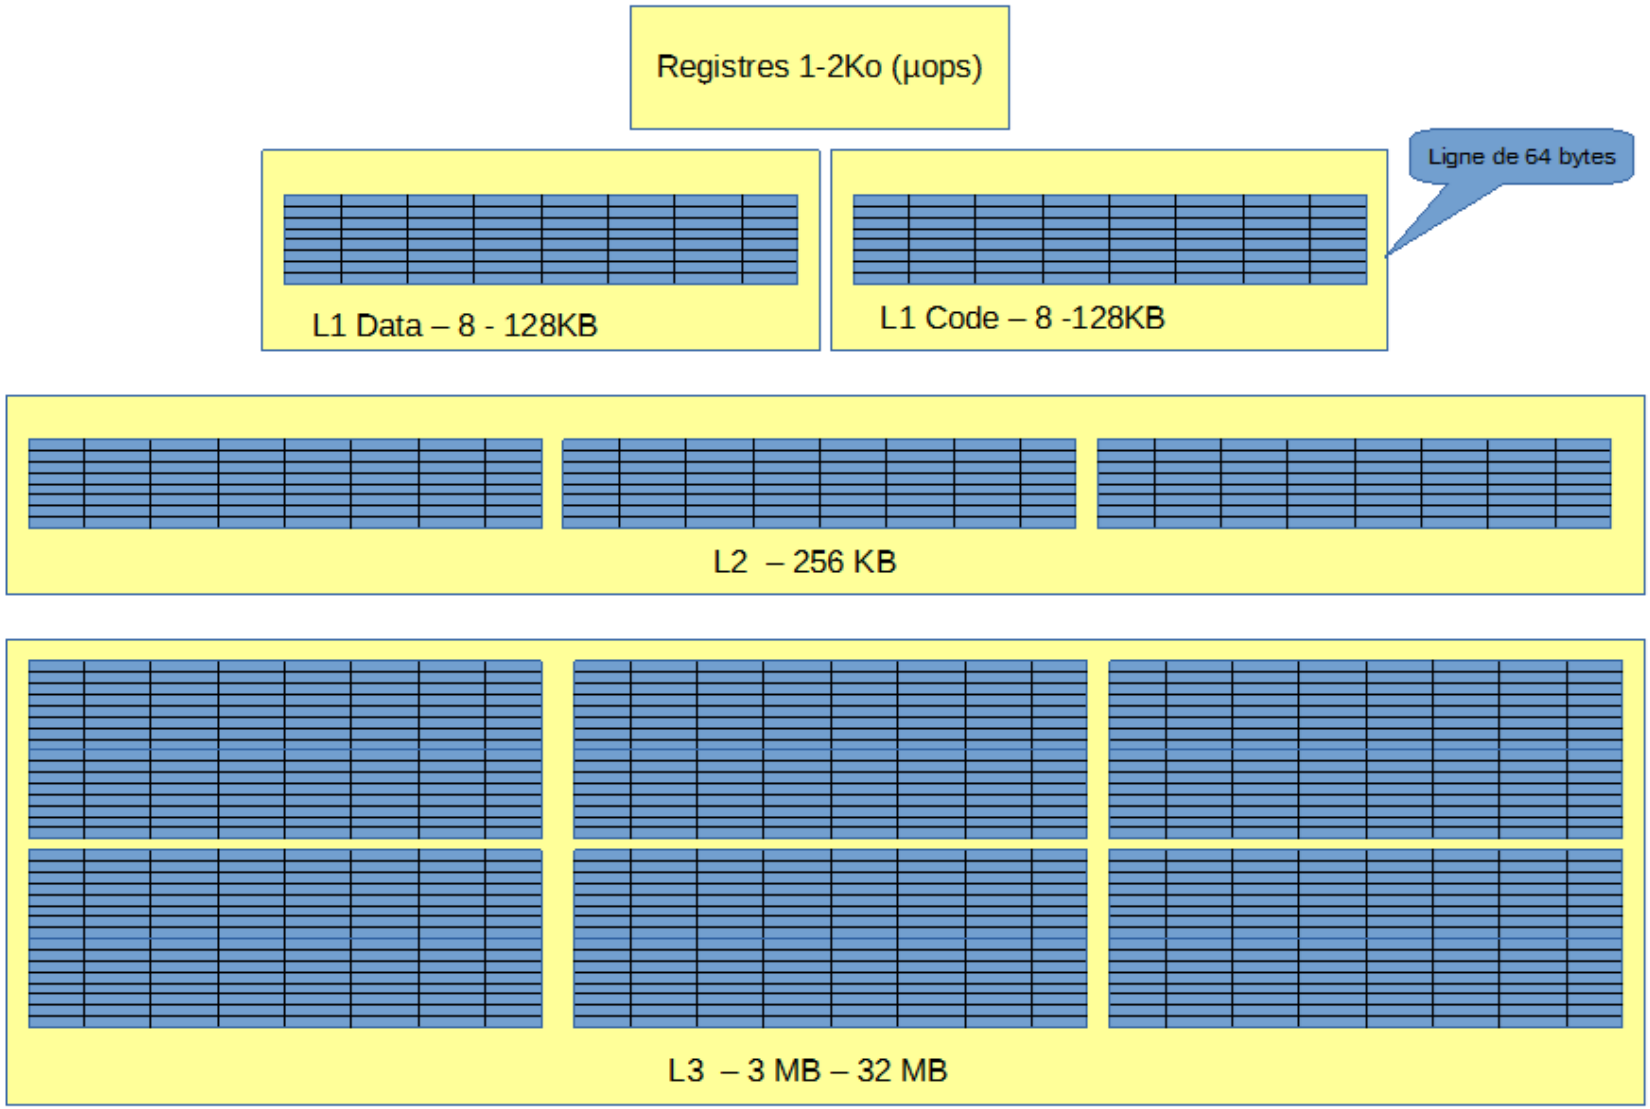

Performances des caches

Niveau de cache	Taille	Temps d'accès en cycle	Concurrence	Technologie	Géré par
Registre	1/2 KB	µ	virtual core	Custom CMOS	Compilateur
Niveau 1	8KB – 128 KB	1	core	SRAM	Hardware
Niveau 2	256 KB	3	core	SRAM	Hardware
Niveau 3	3 MB – 32 MB	10 – 20	Socket	SRAM	Hardware
RAM	4 MB – 4 TB	200+	Chaque région séparément	Variable	OS

Le constat

- Un *flush* excessif des caches est préjudiciable aux performances

4. Contrôler le vidage des caches des processeurs

- Les variables **volatiles** entraînent une notification sur le bus pour invalider les caches des autres *sockets*
- Garantie que la donnée sera en mémoire physique (la RAM)
- Tous les threads de tous les *sockets* en sont informés
- **Cela a un impact important sur les performances**

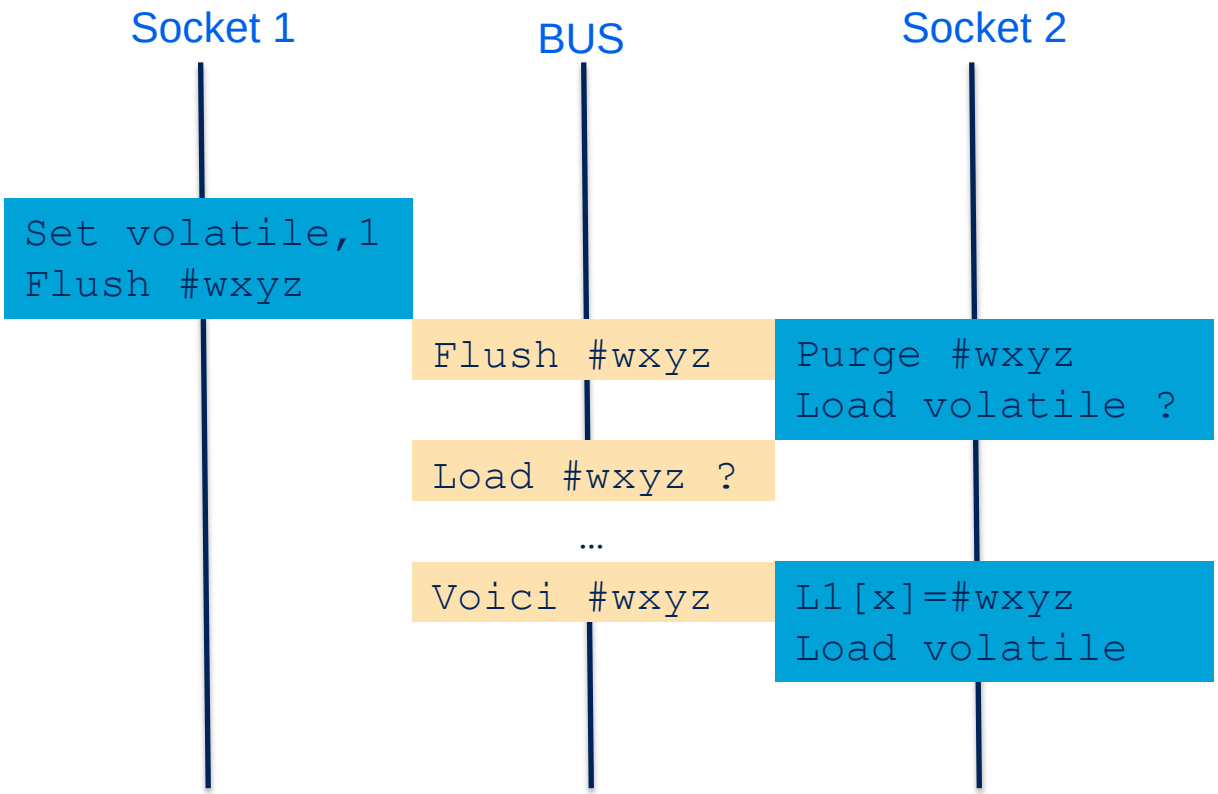

- La classe Unsafe du JDK offre des méthodes pour contrôler les flushs des caches

Vidage du cache (3/3)

- Au début de la classe, des offsets vers les attributs sont obtenus

```
// ConcurrentHashMap.java
6287    static {
6288        try {
6289            U = sun.misc.Unsafe.getUnsafe();
6290            Class<?> k = ConcurrentHashMap.class;
6291            SIZECTL = U.objectFieldOffset
6292                (k.getDeclaredField("sizeCtl"));
6293            TRANSFERINDEX = U.objectFieldOffset
6294                (k.getDeclaredField("transferIndex"));          http://goo.gl/5TxkdB
```

- Ensuite, suivant les besoins **getObjectVolatile(obj,offset)** et ses variantes sont utilisées
- Exemple : La classe **ConcurrentLinkedQueue** utilise **Unsafe** pour initialiser un **Node**, sans flusher les caches dans le constructeur

```
// ConcurrentLinkedQueue.java
188        Node(E item) {
189            UNSAFE.putObject(this, itemOffset, item);
190        }                                                    http://goo.gl/xHdi3p
```

Le constat

- Les algorithmes peuvent être inefficaces vis-à-vis des caches

5. Utiliser des algos copains avec les caches

- Il existe des algorithmes récursifs pour distribuer les traitements d'un ensemble de telle sorte que l'exploitation des caches soit optimale sans avoir à en connaître la taille

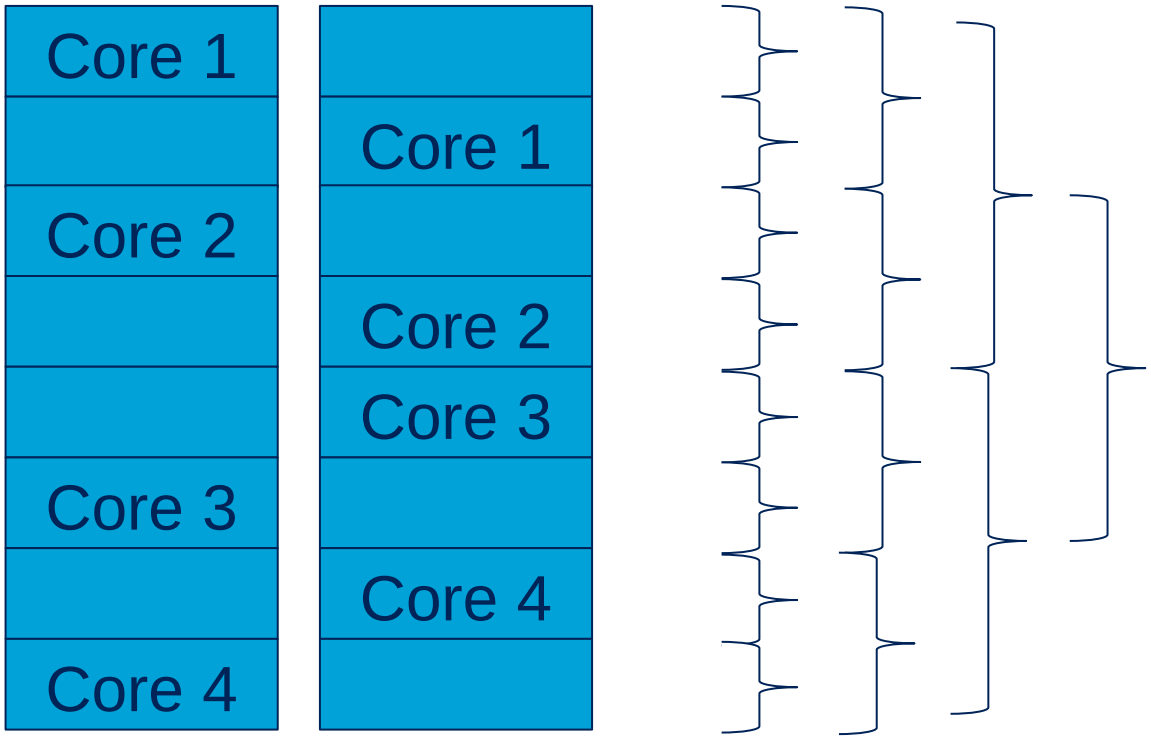

https://en.wikipedia.org/wiki/Cache-oblivious_algorithm

Le constat

- Le cache L1 est mutualisé avec d'autres variables

6. Garder une ligne de cache L1 pour une seule variable

- Faux-partage : lorsque deux variables atomiques **A** et **B** sont proches en mémoire
  - L'écriture sur **B** invalide toute la zone mémoire du cache de niveau 1, et donc invalide également **A**
- Les *cores* pensent à un partage des variables **A** ou **B** par plusieurs *cores*. Les caches sont alors synchronisés
- Puisque **A** et **B** sont éjectés du cache : impact important sur les performances (de 1 à 10)

Faux partage

Isolation L1

Une variable par cache L1 (2/3)

- Saturer l'espace pour remplir une zone L1

```
// synchronizer.cpp
452 struct SharedGlobals {
453     // These are highly shared mostly-read variables.
454     // To avoid false-sharing they need to be the sole occupants of a $ line.
455     double padPrefix [8];
456     volatile int stwRandom;
457     volatile int stwCycle;
458
459     // Hot RW variables -- Sequester to avoid false-sharing
460     double padSuffix [16];
461     volatile int hcSequence;
462     double padFinal [8];
463 } ;
```

http://goo.gl/tdwLqg

- Cela permet d'avoir une variable par *core*. Chaque *core* possède une ligne de cache différent des autres. Il n'y a plus de collision.

Une variable par cache L1 (3/3)

- Java propose une annotation spéciale : **@sun.misc.Contended**
- Dans Java 8, seule cinq classes utilisent cette annotation
  - **Thread, Striped64**, **ConcurrentHashMap**, **Exchanger** et **ForkJoinPool**.

```
// LongAdder
120    @sun.misc.Contended static final class Cell {
121        volatile long value;
122          Cell(long x) { value = x; }
123        final boolean cas(long cmp, long val) {
124            return UNSAFE.compareAndSwapLong(this, valueOffset, cmp, val);
125        }
```

http://goo.gl/RWfzpt

- Chaque thread possède une variable unique dans une ligne de cache
- Elle est incrémentée sans devoir invalider les caches des autres *cores*
- Lors de la lecture, toutes les variables de tous les threads rencontrés sont ajoutées pour produire la somme totale

Le constat

- Le cache L1 est mutualisé avec d'autres **et c'est une bonne chose !**

7. Colocaliser des variables dans une ligne de cache L1

- Rapprocher des variables dans la même ligne de cache (autant que possible)

- En dehors des types primitifs, ce n'est pas facile avec Java, car les objets sont réparties dans la mémoire

```
// ConcurrentHashMap.java
619    static class Node<K,V> implements Map.Entry<K,V> {
620        final int hash;
621        final K key;
622        volatile V val;
623        volatile Node<K,V> next;
```

http://goo.gl/hqcmKf

- La valeur de hash est dupliquée localement dans le `Node` du `HashMap`
- Évite de naviguer dans la mémoire

Colocaliser une variable par cache L1 (2/2)

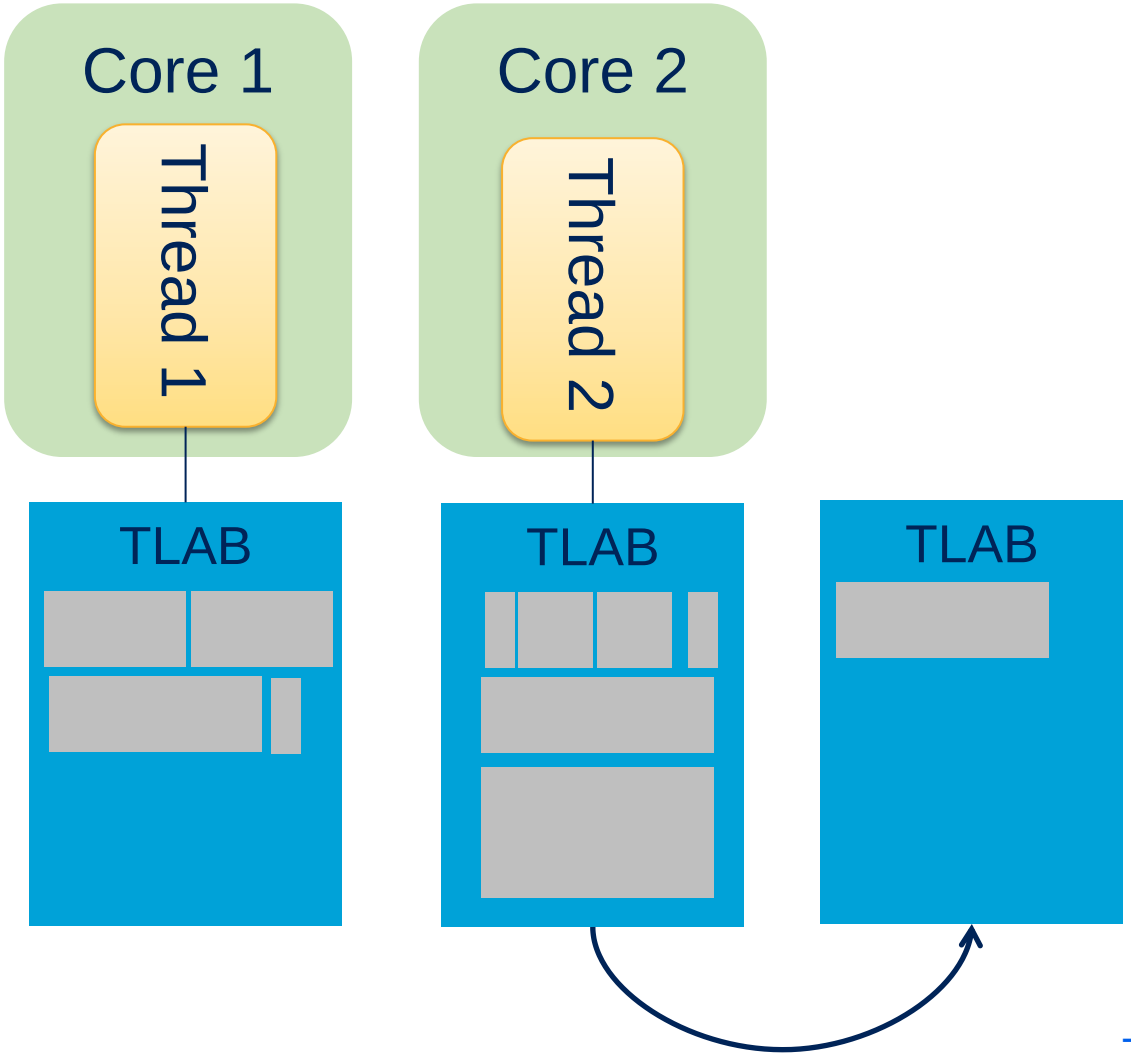

Allocateur mémoire Eden

- Un bloc par thread
- Allocation par incrément d'un offset
- Ajout d'un bloc si nécessaire

TLAB: Thread Local Allocation Bloc

Compare and set

Le constat

- La mémoire peut être modifiée par un autre *core* **à tout moment**

8. Boucler sans fin pour apporter des modifications

- Boucler jusqu'à l'obtention de l'écriture attendue (SpinLock)

```
static AtomicBoolean semaphore=new AtomicBoolean(false) ;
void lock()
{ while ( !mutex.compareAndSet(
    false, // Valeur attendue
    true   // Valeur valorisée  ));
}
```

(**AtomicBoolean** utilise **Unsafe** en interne, donc les instructions assembleur)

8. Boucler sans fin pour apporter des modifications

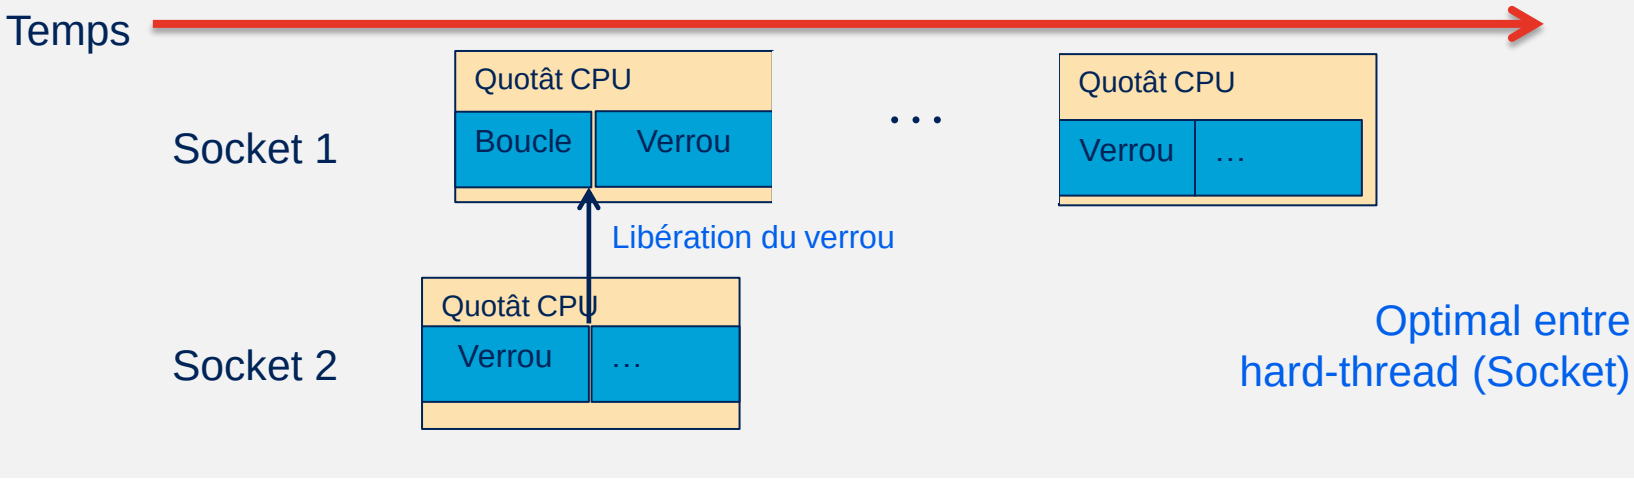

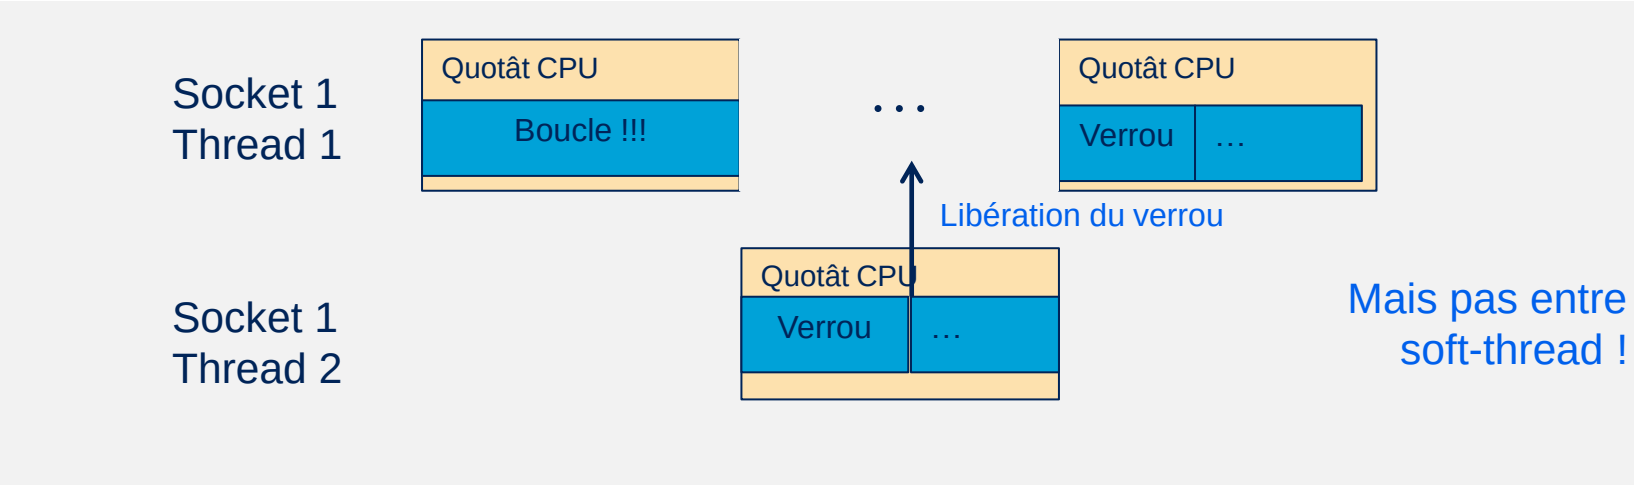

Colocaliser une variable par cache L1 (3/3)

- Nécessite que l'OS répartisse les traitements sur plusieurs *cores*

```
void lock()
{
  int numberOfLoopBeforeTryWithASoftThread=40 ;
  int cnt=0 ;
  while ( !semaphore.compareAndSet(
    false, // Valeur attendue
    true // Valeur valorisée
    ))
    if (++cnt== numberOfLoopBeforeTryWithASoftThread)
    { cnt=0;
      Thread.yield(); // Force a context switch
    }
}
```

Colocaliser une variable par cache L1 (3/3)

- Hotspot utilise cela pour la gestion des synchronisations

```
// synchronizer.cpp
495 while (obj->mark() == markOopDesc::INFLATING()) {
496   // Beware: NakedYield() is advisory and has almost no effect on some
platforms
497   // so we periodically call Self->_ParkEvent->park(1).
498   // We use a mixed spin/yield/block mechanism.
499   if ((YieldThenBlock++) >= 16) {
500     Thread::current()->_ParkEvent->park(1);
501   } else {
502     os::NakedYield();
503   }
504 }
```

http://goo.gl/kVDYVN

- Ces boucles peuvent entraîner un trafic important sur le bus de communication entre les *sockets*
- Une succession de **Thread.Yield()** n'est pas efficace vis-à-vis du *context switch*
- Il existe justement un paramètre à la JVM pour éviter cet excès (**-XX:+DontYieldALot**).

9. Boucler avec un Compare simple, puis un Compare-And-Set

- Une première boucle sans flush du cache dans le core
- Une deuxième avec flush du cache

```
void lock()
{
  for (;;)
  { while (semaphore.get()) {} ; // Attend une invalidation du cache L1
    if (!semaphore.compareAndSet(false,true)) return ; // Toujours ok ?
  }
}
```

- La première boucle consulte le cache local, sans envoyer d'invalidation du cache sur le bus
- Le cache local est rafraîchi ssi un autre *socket* ou un autre *core* le demande
- Ensuite, un CAS est appliqué
- Entre temps, le sémaphore peut avoir été pris. Si c'est le cas, on recommence

10. Préparer spéculativement une modification et essayer de l'écrire en mémoire

- Exemple : valoriser le pointeur **head** d'une liste chaînée

```
AtomicReference <Node> head;
void insert(int x)
{
  Node newNode=new Node(x);
  Node currentHead;
  do  {
    newNode.next= (currentHead=head) // Ici
  } while (!currenthead.compareAndSet(currenthead,newNode)) // Là
}
```

- Si un hard-thread ou un soft-thread intervient entre ici et là le **compareAndSet()** échoue
- Un autre thread a modifié **head**
- On recommence
- Notez la valorisation spéculative de **next** à chaque itération

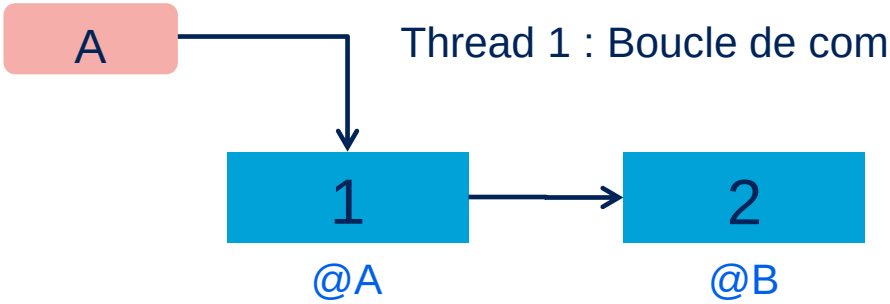

Thread 1 : Boucle de comparaison du pointeur sur valeur A

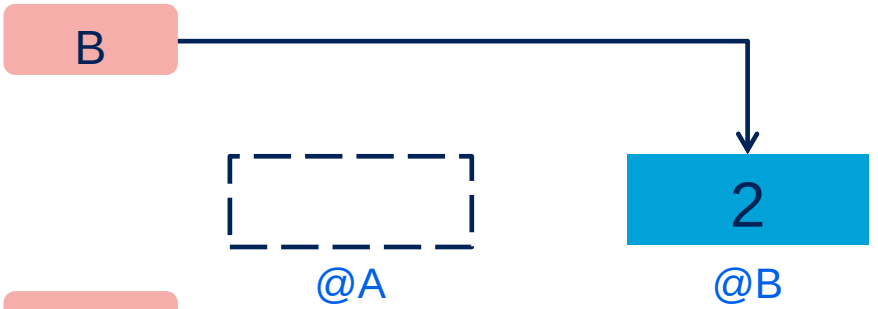

Thread 2: Modifie le pointeur en B

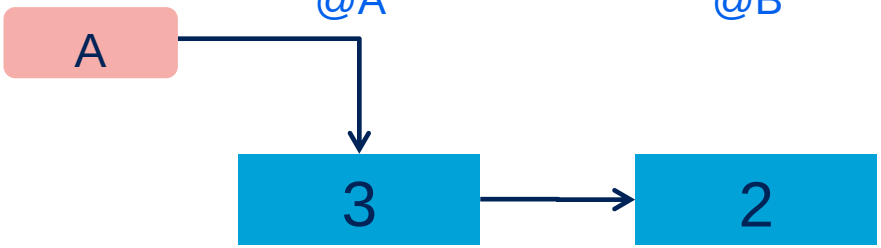

Thread 2: Modifie le pointeur à nouveau mais sur la même adresse ! En A

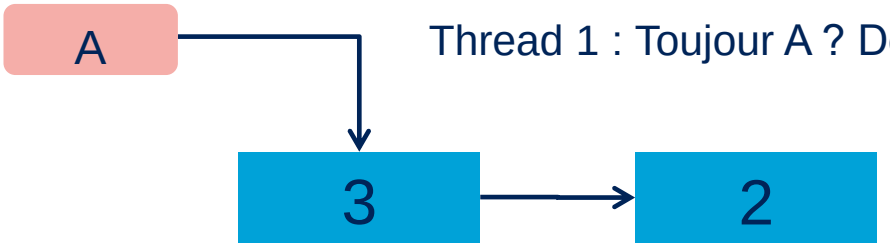

Thread 1 : Toujour A ? Donc il n'a pas bougé. Je peux valoriser ! **Glups**

- Il arrive lorsque la donnée **A** est modifiée en **B**, puis immédiatement en **A (A-B-A)**

- Pour résoudre cela, plusieurs approches sont proposées :
  - Utilisation d'un pool de **Node**
  - Ajout d'un octet de plus s'il est possible de rester atomique
  - Utilisation de quelques bits de l'adresse mémoire pour indiquer un numéro de version à chaque adresse
  - …

- Plus radical :
  - Instructions spécifiques de certains processeurs
    - Présent dans : Alpha, PowerPC, MIPS, et ARM mais pas x86 !
- La lecture de la mémoire (`LL`) signale que la zone de cache correspondante doit être traitée avec attention
- Si le cache est écrit, l'instruction `SC` utilisée dans un CAS échoue
- Ce n'est plus la valeur qui compte, mais la présence de la valeur dans le cache
- Une chance, le langage Java n'est pas confronté à ce problème car il utilise un ramasse miettes

Framework

Le constat

- Ne plus modifier les données évite l'éviction des caches

11. Conteneur immuable

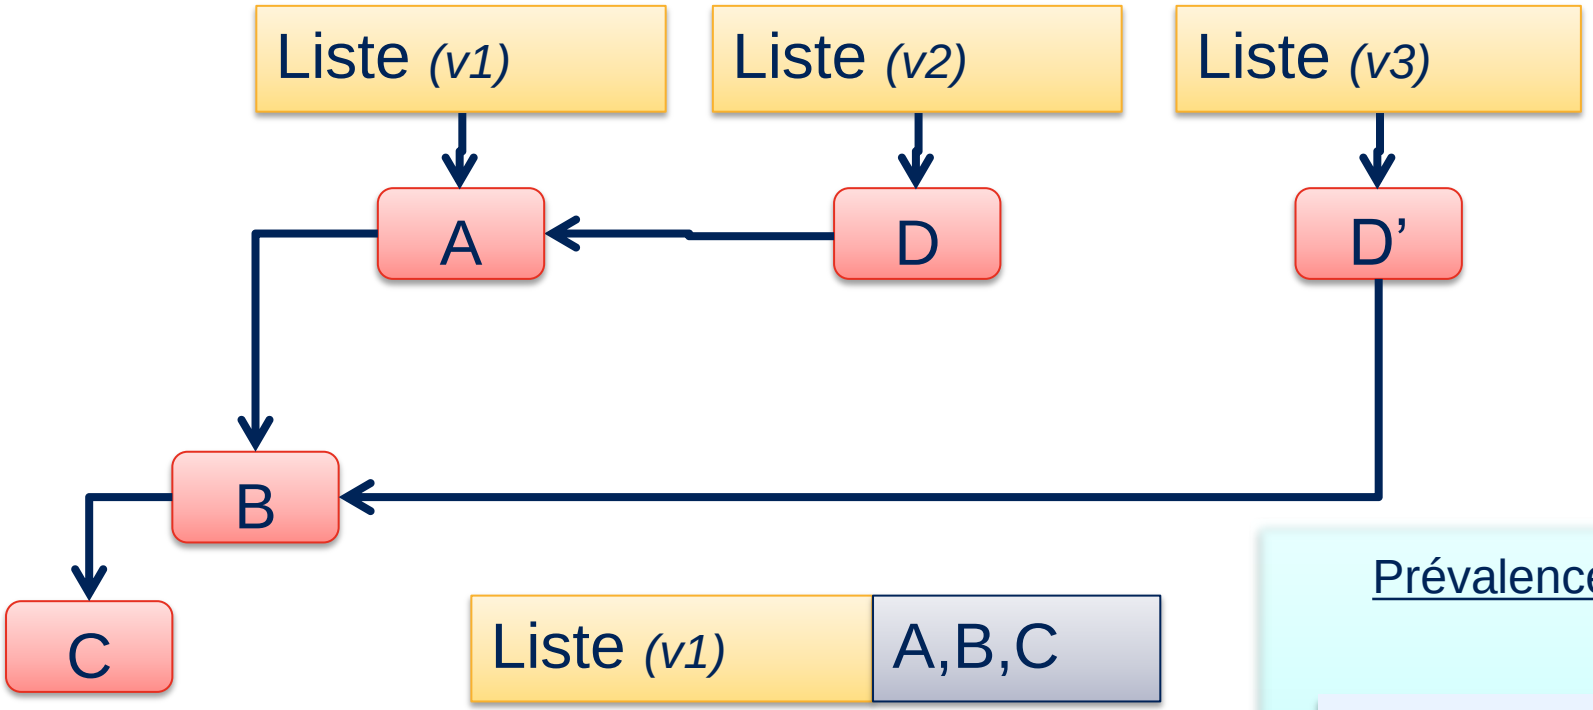

Liste *(v1)*	A,B,C
Liste *(v2)*	D,A,B,C
Liste *(v3)*	D',B,C

Prévalence

Ajouter D

Supprimer A

11. Conteneur immuable

12. Transaction en mémoire

- Les modifications s'effectuent dans des « transactions »
- En cas de collisions, les modifications sont rejouées
- Les frameworks utilisent les approches « haute-fréquence »

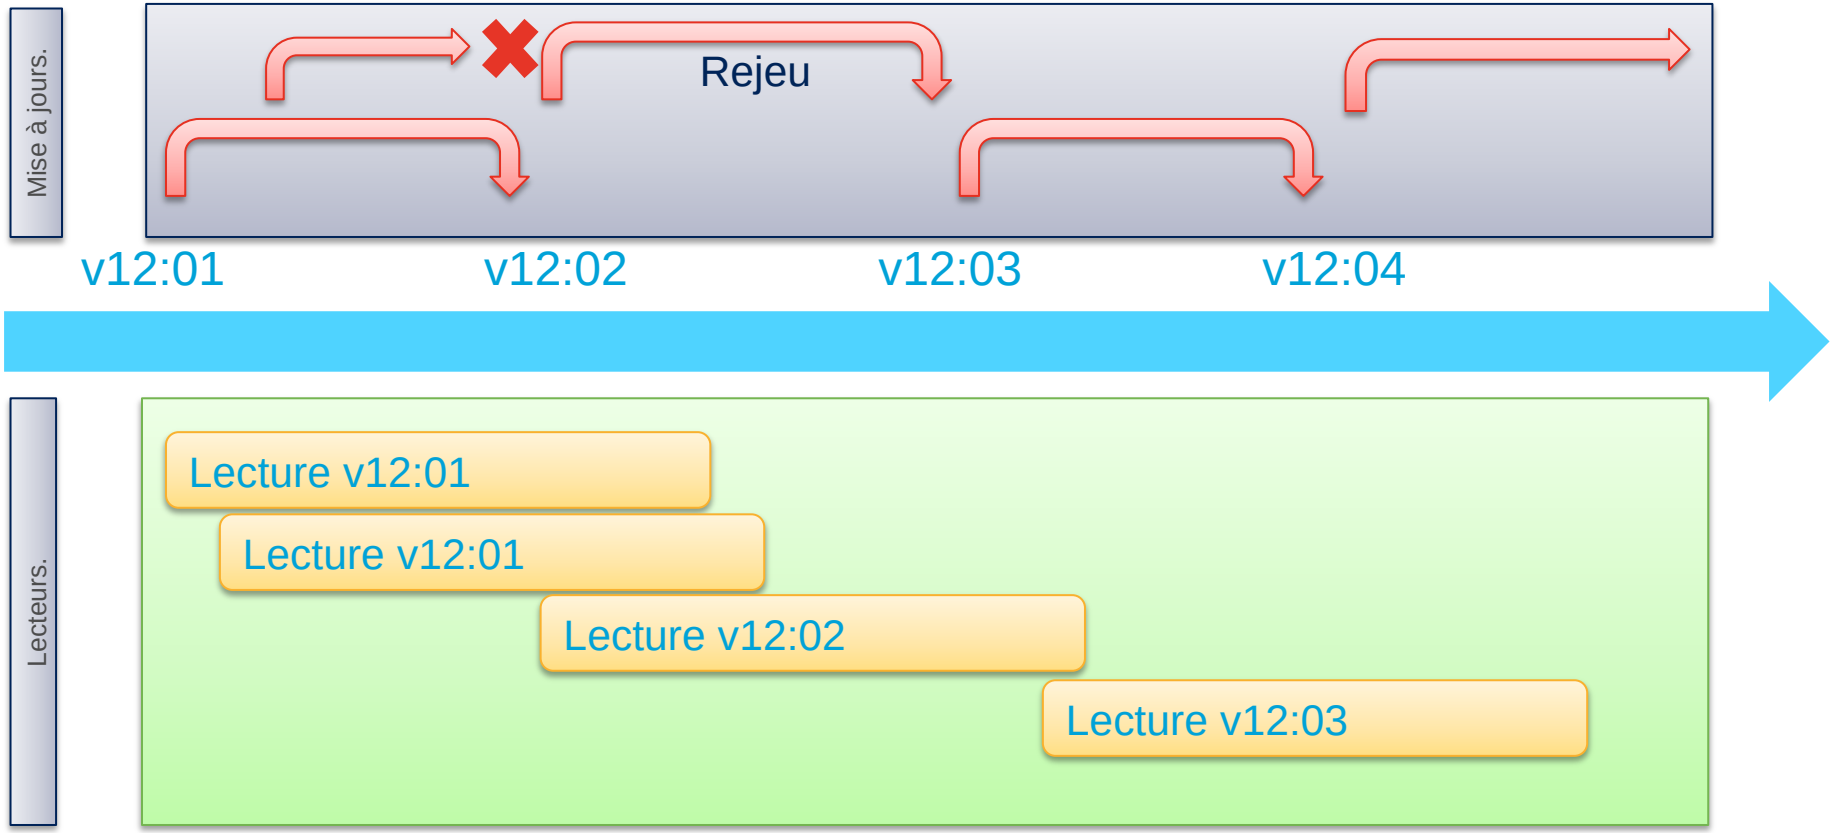

- Généralisation du modèle *Read-Modify-Write*
- En cas d'échec de l'écriture, il faut rollbacker
  - Via des call-backs
  - Ou des indirections de pointeur, permettant de reconstruire l'état précédent
- Librairie en Scala ou Closure
- En cas de forte contention, un délai aléatoire est ajouté avant de tenter à nouveau

Autres

13. Affinité des threads avec les sockets

- Java **ne permet pas** de jouer avec les affinités des threads
- Il existe des librairies pour cela (OpenHFT), compatibles Linux et Windows

```
private static final ExecutorService ES =
  Executors.newFixedThreadPool(
   Runtime.getRuntime().availableProcessors(),
    new AffinityThreadFactory("bg",
       DIFFERENT_SOCKET,DIFFERENT_CORE, ANY));
```

- **LongAdder** de Java8 utilise un identifiant caché par thread dans une ligne de cache L1

```
// Striped64.java
185    static final int getProbe() {
186        return UNSAFE.getInt(Thread.currentThread(), PROBE);
187    }
```

http://goo.gl/YGEQAD

  - Donc : Une ligne L1 par thread !

  - Il pourrait bénéficier d'une variable dans un cache L1 par *core* (et non par thread)

  - *Attention à la migration de threads entre cores*
    - *Le scheduleur Unix ne migre pas si un core travaille (pas d'I/O)*

14. Utiliser synchronize

- C'est maintenant rapide pour un traitement sans IO !
- Mais le verrouillage doit être très court et n'utiliser que de la CPU

- Avec Hotspot 8, la JVM utilise des stratégies efficaces pour gérer les verrous
  - L'en-tête de chaque objet utilise des bits pour associer le threads au verrous
  - Les threads sont alloués en bas de la mémoire de la JVM
  - Cela laisse des bits disponibles pour une utilisation d'un CAS (*Compare-and-set*) pour l'état et l'association avec le thread

- Plusieurs stratégies sont utilisées. De la plus rapide à la plus lente, au fur et à mesure des échecs successifs

Conteneurs lock-free

- Les containeurs de Java de type **Blocking*** ou **Concurrent*** sont implémentés avec les techniques que nous avons évoqué
- L'implémentation de **ConcurrentHashMap** de Java8 est une ré-implémentation complète de la version de Java7
  - N'a pas besoin de verrous tant qu'il n'y a pas de collision sur la valeur de hash
  - Sinon bloque l'accès

- D'autres librairies sont plus efficaces
  - High-Scale-Java
  - LMAXCollection
  - SnapTree pour un arbre balancé sans verrous
  - Concurrency Freaks avec différentes améliorations de **ReadWriteLock**

Pour conclure

- À tous les niveaux, nous retrouvons ces algorithmes (futex de Linux, …)
- Les nouveautés annoncées pour Java9 vont également dans le même sens
  - co-localiser les structures et les conteneurs de types primitifs avec les « Value classes »
  - Mais Java9 envisage de supprimer Unsafe !!!
    - JEP 193: Variable Handles
    - *Oracle's plan is for Unsafe not to be removed, but rather hidden through the new modules system, to be available in Java 9*

- Ces approches sont très subtiles
  mais **oh combien amusantes !!!**
- C’est un terrain de recherche encore à défricher !
- Proposez vos implémentation ASAP !

recrutement@octo.com

Vous croyez que *les technologies* changent le monde ?

Nous aussi ! Rejoignez-nous !

There is a better way

OCTO Technology

Pourquoi choisir OCTO !

Questions ?