Opérations Vectorizées

Rémi Forax

Vocabulaire

Concurrence

- Exécuter plusieurs calculs en même temps

Parallèle

- Un calcul est décomposé et exécuté sur plusieurs threads

Vectorisé

- Une opération simple (+, min, etc) est exécutée par un même thread sur plusieurs données adajcences en mémoire (sur 128 bits, 256 bits, etc)

Distribué

- Un calcul est décomposé et exécuté sur plusieurs machines

SIMD

Single Instruction, Multiple Data

- Catégorie de CPUs capable d’exécuter une même opération sur des données multiples

Apparition pour les CPUs grand public en 1996 avec l’extension MMX sur Intel Pentium

- 3DNow (AMD 1998) et SSE (Intel 1999)
  - 16 registres de 128 bits
- AVX (AMD et Intel 2011)
  - 32 registres sur 256 bits
    - puis AVX2 (2013), puis AVX-512 (2016), 32 registres de 512 bits
- Neon (ARM / Apple / Qualcom / Samsung 2011)
  - 16 registres 128 bits
    - puis Helium/MVE (2019), support des flottants 16 bits par lignes

En pratique

Des registres spécializées (xmm0, ymm0, zmm0 sur Intel) effectue une même opération sur plusieurs colonnes (*lanes*)

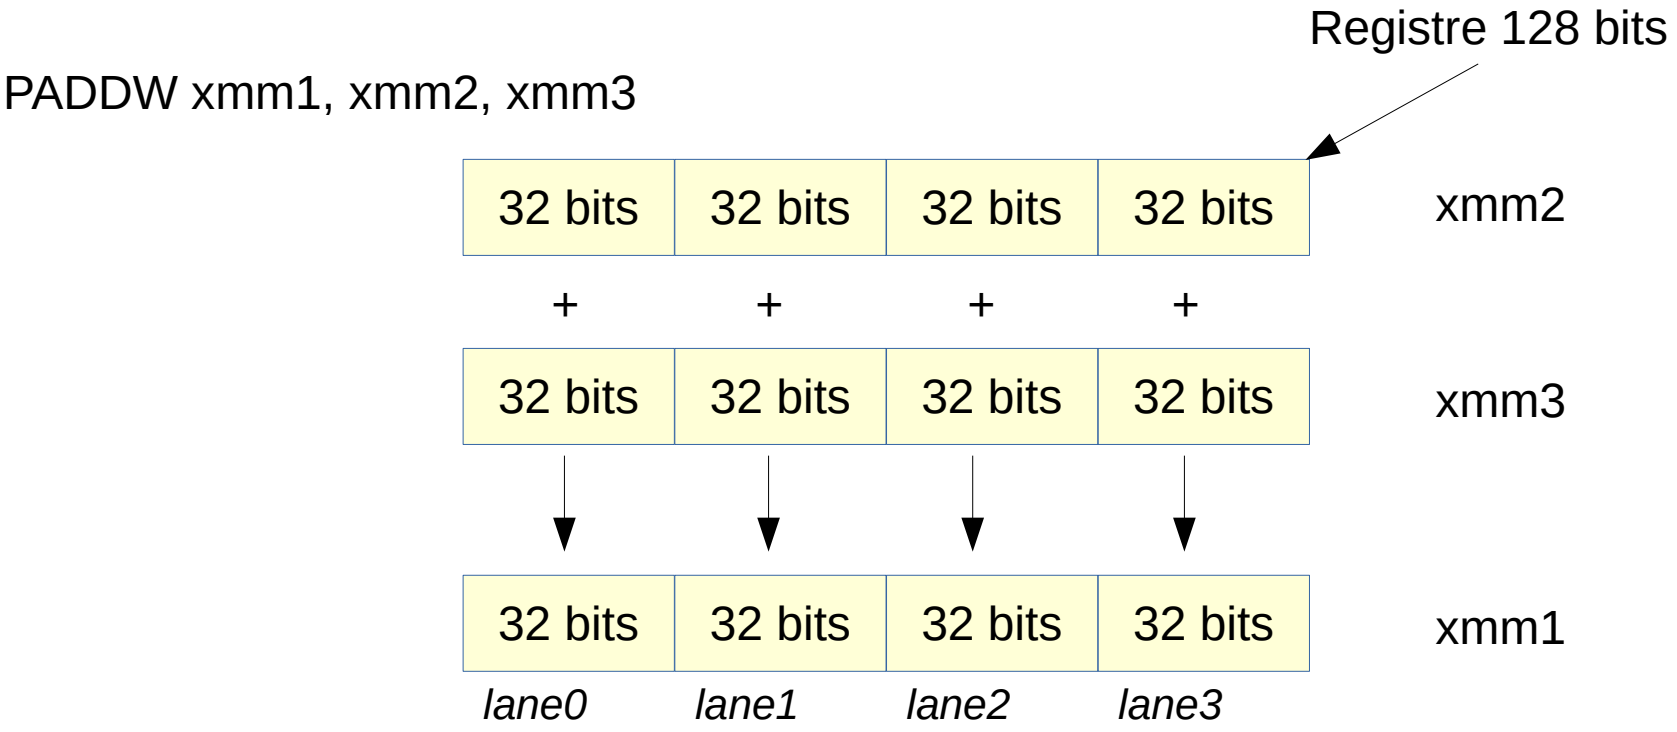

En pratique (2)

Une instruction indique

- La taille des registres (64 bits, 128 bits, 256 bits)
- L'opération (ADD, SUB, etc)
- La taille d'une ligne (8 bits, 32 bits, 64 bits, 128 bits)

PADD**W** xmm1, xmm2, xmm3

Préfixe

P	pour 128 bits
VEX VP	pour 256 bits
EVEX VP	pour 512 bits

ADD pour l'opération

Taille d'une ligne

B (byte) = 8 bits
W (word) = 32bits
D (double) = 64bits
Q (quad) = 128bits

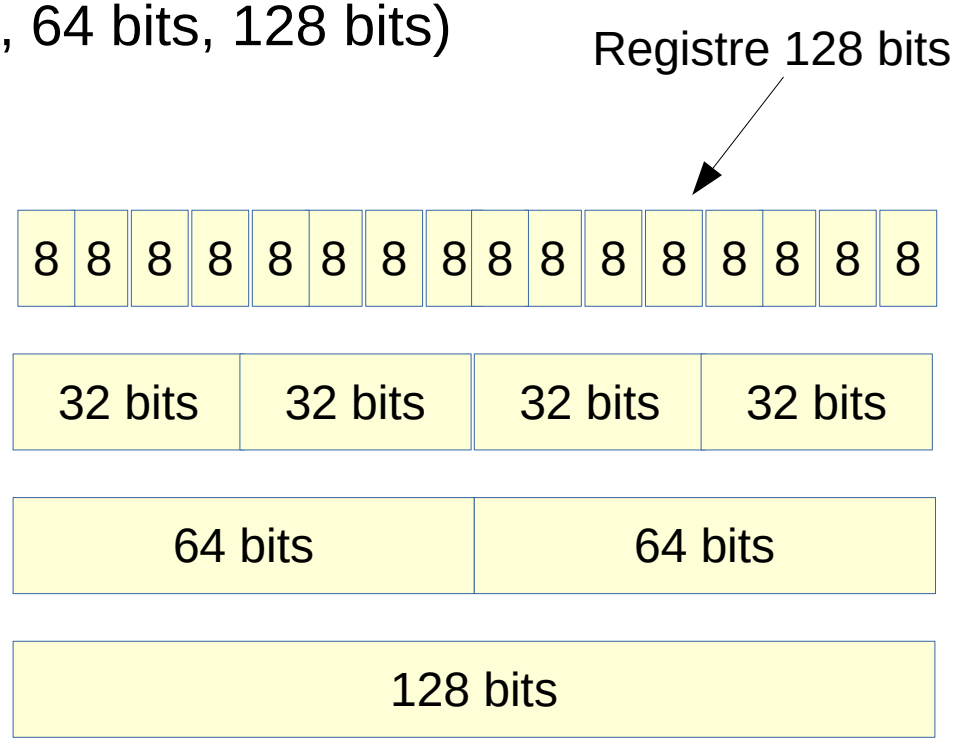

Opération vectorisée et mémoire

- Les registres vectorizées ont une taille supérieur aux registres normaux
  - Plus efficace pour les lectures/écritures
    - Par ex: 128 bits = 16 octets en 1 lecture/écriture

  - Rappel: La lecture/écriture en mémoire a une granularité en multiple de 8 bits (1 octet)

Vecteur et mémoire

Au lieu d'accéder à un tableau octet par octet

```
for(var i = 0; i < 16; i++) {  // avec 16 lanes
  a[i] = b[i] + c;
}
```

On passe par des vecteurs intermédiaires

```
var vb = *Vector.fromArray(b, 0);  // lit 16 valeurs
var vc = *Vector.broadcast(c);       // on met c dans chaque lane
var va = vb.add(vc);
va.intoArray(a, 0);                  // écrit 16 valeurs
```

Vector API en Java

(jdk.incubator.vector)

Accès aux Instructions

Un appel a une méthode Java est transformé en une instruction spécifique au CPU par le JIT

```
IntVector v1 = …
IntVector v2 = …
v1.add(v2);
```

Les types (IntVector par ex) n'indique pas le nombre de *lanes*

IntVector.add(IntVector) peut être VPADD[B,W,D,Q]

API jdk.incubator.vector

Un vecteur correspond à un registre (immutable) ayant un type et un nombre de lanes

- Vector
  - Interface de base
- [Byte|Short|Int|Long|Float|Double]Vector
  - Version specifique
- VectorSpecies
  - Un type + shape (taille en bits)
    permet de dériver un type de vecteur + nombre de *lanes*
- VectorMask
  - Vecteur de boolean, bit sets
- VectorShuffle
  - Vecteur d’index d’indirection

VectorSpecies<*>

Représente un type (byte|short|int|long|float|double) et une shape (64|128|256|512 bits)

Création par méthodes statiques

- of(Class<?> elementType, VectorShape shape)
  VectorShape.S_64_BIT, S_128_BIT, S_256_BIT, S_512_BIT)
- ofPreferredShape(Class<?> elementType)

Constantes dans [Byte|Short|Int|Long|Float|Double]Vector

- pour IntVector, on a les constantes
  IntVector.SPECIES_[64|128|256|512] de type VectorSpecies<Integer>

Il a une notion de taille préférée (SPECIES_PREFERRED)

par ex, certains CPUs supportent les opérations 256 bits en découpant en deux 128 bits

la taille préférée est alors 128 bits

Exemple

Créer deux vecteurs d’entiers, les additionner et afficher les valeurs de chaque *lane*

```
VectorSpecies<Integer> species =
        IntVector.SPECIES_PREFERRED;

IntVector v1 = IntVector.zero(species);
IntVector v2 = IntVector.broadcast(species, 42);
IntVector v3 = v1.add(v2);

for(var i = 0; i < v3.length(); i++) {  // length == lane count
  System.out.println(v3.lane(i));
}
// affiche plusieurs 42  (128 bits = 4, 256 bits = 8, etc)
```

Vector vs Objet

Un vecteur n'**est pas** un objet avec une adresse en mémoire (c'est un *value based object*)

- On le manipule comme un objet, mais il marche comme un int
  - Il correspond à **un registre** du processeur
  - Un vecteur est une valeur non-mutable
    - v1.add(v2) ne change pas v1 !
- Les opérations nécessitant l'addresse en mémoire ne marche pas ou renvoie des résultats fantaisistes
  - Pas de synchonized / wait() / notify()
  - Pas de System.identityHashCode()
  - Pas de v1 == v2

VectorMask<*>

Masque booléen indiquant si une lane doit être prise en compte (true) ou non (false)

Exemple

```
var species = IntVector.SPECIES_256;
var v1 = IntVector.zero(species);
var v2 = IntVector.broadcast(species, 42);

VectorMask<Integer> mask =
   VectorMarsk.fromLong(species, 0b11010); // affichage en ordre inverse
                                           // F, T, F, T, T, F, F, F

var v3 = v1.blend(v2, mask);   // v1 ou v2 suivant le masque

System.out.println(v3); // affiche [0, 42, 0, 42, 42, 0, 0,  0]
```

VectorMask<*> et if

Faire un if dans une boucle qui ne fait que des calculs est super lent

Au lieu de

```
for(var i = 0; i < 8; i++) {
  if (a[i] < 3) {
    b[i] = a[i] + c;
  }
}
```

On utilise un masque

```
IntVector va = IntVector.fromArray(species, a, 0);
IntVector vc = IntVector.broadcast(3);
VectorMask<Integer> mask = va.lt(vt);   // '<' renvoie un mask
IntVector vb = va.add(vc, mask);        // on fait le '+' suivant le mask
vb.intoArray(b, 0);
```

Vector<*>

Interface commune de [Byte|Short|Int|Long|Float|Double]Vector

- Opérations de base
  - length(), lane(int index), withLane(int index, value), addIndex(int scale)
- Opérations spécifiques
  - blend, rearrange, etc
- Opérations par *lane* (*lanewise*)
  - Tests unaire et binaire
  - Applications unaire, binaire et ternaire
  - Conversions

VectorOperators définie chaque opération

Vector<*> - Opérations spécifiques

Voir un vecteur comme un autre, par ex 32 bits → 8 bits

reinterpretShape(Species, int part)

Intervertir les lanes d'un vecteur

rearrange(VectorShuffle, VectorMask?)
rearrange(VectorShuffle, Vector, VectorMask?)

Mixer deux vecteurs selon un masque

blend(Vector, VectorMask)

Découper les lanes + compléter avec les valeurs d'un vecteur

slice(int origin, Vector, VectorMask?)
unslice(int origin, Vector, int part, VectorMark?)

Exemple

Exemple de rearrange

```
var species = IntVector.SPECIES_128;
var v1 = IntVector.zero(species);
for(var i = 0; i < v1.length; i++) {
  v1 = v1.withLane(i, i * 10);
}
System.out.println(v1);  // [0, 10, 20, 30]

VectorShuffle<Integer> shuffle =
      VectorShuffle.fromValues(species, 0, 2, 1, 3);
var v2 = v1.rearrange(shuffle);
System.out.println(v2);  // [0, 20, 10, 30]
```

Exemple (2)

Exemple de addIndex(scale) + rearrange

```
var species = IntVector.SPECIES_128;
var v1 = IntVector.zero(species).addIndex(10);

System.out.println(v1);  // [0, 10, 20, 30]

VectorShuffle<Integer> shuffle =
    VectorShuffle.fromValues(species, 0, 2, 1, 3);
var v2 = v1.rearrange(shuffle);
System.out.println(v2);  // [0, 20, 10, 30]
```

VectorOperators

Enum qui définie les opérations que l’on peut faire sur un Vector

- Test unaire et binaire (renvoie un VectorMask)
  - IS_NAN, IS_NEGATIVE, etc
  - EQ(==), NE(!=), LE(<=), LT(<), GE(>=), GT(>)
- Application unaire, binaire et ternaire
  - ABS, COS, SIN, etc
  - ADD, SUB, MUL, DIV, AND, OR, etc
  - FMA, BITWISE_BLEND
- Conversion
  - I2L, I2D, ZERO_EXTENDED_B2I, etc

Vector<*> - Opérations *Lanewise*

Opérations par *lane* utilisant les VectorOperators

- Tests unaire et binaire
  - test(Test op, VectorMask?) → VectorMask
    compare(Comparison op, Vector, VectorMask?) → VectorMask
- Applications unaire, binaire et ternaire
  - lanewise(Unary op, VectorMask?)
    lanewise(Binary op, Vector, VectorMask?)
    lanewise(Ternary op, Vector, Vector, VectorMask?)
- Conversions
  - convert(Conversion op, int part)
    convertShape(Conversion op, Species, int part)

Exemple

Exemple d’application avec lanewise()

```
var species = IntVector.SPECIES_128;

var v1 = IntVector.fromArray(species,
                 new int[] { 7, 3, 16, 5 },
                 0);
var v2 = IntVector.broadcast(species, 42);

var v3 = v1.lanewise(VectorOperators.ADD, v2);

System.out.println(v3);  // [49, 45, 58, 47]
```

Vector - Reduce en ligne

On peut demander d’effectuer une reduction sur toutes les *lanes* avec une opération associative

- Cette opération est pas définie sur Vector mais sur chaque [Byte|Short|Int|Long|Float|Double]Vector
  - car le type de retour est différent

- Les opérations associatives sont définies dans VectorOperators
  - ADD, MUL, AND, OR, etc

  Par exemple sur IntVector,
  IntVector.reduceLane(Associative op, VectorMask?) → int

Exemple

Exemple de reduceLanes()

```
var species = IntVector.SPECIES_128;
var array = new int[] { 1, 2, 3, 4, 11, 12, 13, 14 };

var v1 = IntVector.fromArray(species, array, 0)
var v2 = IntVector.fromArray(species, array, 4);
var v3 = v1.add(v2);

int sum = v3.reduceLanes(VectorOperators.ADD);

System.out.println(sum);  // 60
```

Lire/Ecrire dans un tableau

[Byte|Short|Int|Long|Float|Double]Vector

Méthodes statique de lecture

- fromArray(Species, array, offset, VectorMask?)
- fromByteArray(Species, byte[], offset, ByteOrder)

Méthodes d’instance d’écriture

- intoArray(array, offset, VectorMask?)
- intoByteArray(byte[], offset, ByteOrder)

Le masque optionnel permet de lire/écrire moins de données (et éviter les IAOOB)

Exemple

Dupliquer un tableau d’entier

```
private static final VectorSpecies<Integer> =
    IntVector.SPECIES_PREFERRED;

static int[] copy(int[] array) {
  var length = array.length;
  var newArray = new int[length];
  for(var i = 0; i < length; i += SPECIES.length()) {
    var v = IntVector.fromArray(SPECIES, array, I);
    v.intoArray(newArray, i);
  }
  return newArray;
}
```

Ce code est FAUX !

- marche que si array.length est un multiple de SPECIES.length()

Exemple avec une postLoop

On fini avec une boucle classique

```
static int[] copy(int[] array) {
  var length = array.length;
  var newArray = new int[length];
  var loopBound = length – length % SPECIES.length();
  var i = 0;
  for(; i < loopBound; i += SPECIES.length()) {
    var v = IntVector.fromArray(SPECIES, array, I);
    v.intoArray(newArray, i);
  }
  for(; i < length; i++) {   // post loop
    newArray[i] = array[i];
  }
  return newArray;
}
```

Exemple avec un masque

On utilise un masque

```
static int[] copy(int[] array) {
  var length = array.length;
  var newArray = new int[length];
  var loopBound = length – length % SPECIES.length();
  var i = 0;
  for(; i < loopBound; i += SPECIES.length()) {
    var v = IntVector.fromArray(SPECIES, array, I);
    v.intoArray(newArray, i);
  }
  var mask = indexInRange(length % SPECIES.length());
  var v = IntVector.fromArray(SPECIES, array, i, mask);
  v.intoArray(newArray, i, mask);
  return newArray;
}
```

Calculer le masque

Le masque: iota < broadcast(index)

```
static VectorMask indexInRange(int index) {
  var iota = IntVector.zero(SPECIES).addIndex(1);
  var value = IntVector.broadcast(SPECIES, index);
  return iota.compare(VectorOperators.LT, value);
}
```

Par exemple,
si l'index vaut 3

iota	0	1	2	3
	<	<	<	<
broadcast(3)	3	3	3	3
	=	=	=	=
mask	true	true	true	false

Exemple avec un masque

En fait, il existe déjà **loopBound**() et **indexInRange**() sur VectorSpecies

```
static int[] copy(int[] array) {
  var length = array.length;
  var newArray = new int[length];
  var loopBound = SPECIES.loopBound(length);
  var i = 0;
  for(; i < loopBound; i += SPECIES.length()) {
    var v = IntVector.fromArray(SPECIES, array, I);
    v.intoArray(newArray, i);
  }
  var mask = SPECIES.indexInRange(i, length);
  var v = IntVector.fromArray(SPECIES, array, i, mask);
  v.intoArray(newArray, i, mask);
  return newArray;
}
```

Performance

L’API permet uniquement de typer le vecteur pas d’indiquer sa longueur/shape

- IntVector pas IntVector128
- donc l’information de longueur/shape doit toujours être accessible au JIT
  - => mettre SPECIES en **constante** (static final)

L’implantation actuelle est pas finie

- Stocker un vecteur dans un champ ou une case de tableau est pas efficace