

Unités vectorielles

Oguz Kaya

Polytech Paris-Sud

Orsay, France

Programmation parallèle : 4ème année apprentissage

January 15, 2019

1 Principes

1 Principes

2 SSE & Intrinsics

1 Principes

2 SSE & Intrinsics

Principe

Un processeur scalaire effectue les opérations séquentiellement, chaque opération portant sur des données scalaires (un scalaire)


Exemple : addition de vecteurs de 4 éléments

$$v3[0] = v1[0] + v2[0];$$

$$v3[1] = v1[1] + v2[1];$$

$$v3[2] = v1[2] + v2[2];$$

$$v3[3] = v1[3] + v2[3];$$




Principe

Un processeur vectoriel effectue les opérations en parallèle sur un ensemble de scalaires, chaque opération portant sur des vecteurs

Exemple : addition de vecteurs de 4 éléments

$v_3 = v_1 + v_2;$



1 Avantage :

- Calcul n fois plus rapide, n la largeur de l'unité vectorielle si l'algorithme se prête au paradigme SIMD : une même instruction simultanément sur plusieurs données
 - calcul vectoriel
 - traitement d'images

2 Inconvénient :

- Gain uniquement si l'algorithme se prête au paradigme SIMD,
- Parfois difficile (et sale) à utiliser,
- sinon on se retrouve dans le cas scalaire, perte d'efficacité

- Années 60 : premier projet Solomon
- Années 70 : ILLIAC IV, université de l'Illinois
- ensuite : CDC, Cray, NEC, Hitachi, Fujitsu
- depuis 1996 : processeurs “grand public” scalaires + unités vectorielles, Pentium (MMX, SSE, AVX), PowerPC (AltiVec)

Première unité vectorielle “grand public” introduite par Intel sur certains Pentium de première génération

- 8 registres 64bits
- 57 opérations sur les entiers
- Limitations :
 - uniquement sur les entiers
 - registres partagés avec l'unité FPU

- 1 Chargement des données de la mémoire vers les registres SIMD
- 2 opération sur les registres SIMD
- 3 placement du résultat en mémoire

- Vectorisation automatique : le compilateur tente de vectoriser le code automatiquement
- Assembleur : programmation bas-niveau, manipulation directe des registres et instructions
- **Intrinsics** : fichiers .h inclus dans GCC : pmmmintrin.h pour SSE3
- Bibliothèques de haut-niveau : masquage de la programmation vectorielle

Tips pour obtenir les meilleurs performances

- Organiser correctement les données pour éviter les accès non contigus et également optimiser le cache
- aligner les données
- rester le plus longtemps possible dans les registres

- Tableau de structures (Array of structures - AoS) : xyzwxyzwxyzw
...
- Structure de tableaux (Structure of Arrays - SoA)
xxxxxxxxx ... yyyyyyyyyy ... zzzzzzzzzz ... wwwwwwwwww ...
- Structure hybride : xxxxyyyyzzzzwwwwxxxxyyyyzzzzwwww ...

1 Principes

2 SSE & Intrinsics

Streaming SIMD Extensions

- SSE - Pentium III, Athlon XP
- SSE2 - Pentium 4
- SSE3 - Pentium 4 Prescott
- SSSE3 - (Supplemental SSE3)
- SSE4.1 - Core2
- SSE4.2 - Core i7
- AVX
- AVX2
- AVX512

Composition

Chaque nouvelle version de SSE ajoute des instructions à la précédente
 $SSE(N) = \text{nouvelles instructions} + SSE(N-1)$

Registres de 128 bits

8 registres 128bits sur x86 : XMM0 – > XMM7

16 registres 128bits sur x86 64 : XMM8 – > XMM15

Instructions

- transferts mémoire < – > registres SSE
- opérations arithmétiques
- opérations logiques
- tests
- permutations

Les intrinsics sont accessibles à travers des fichiers .h qui définissent :

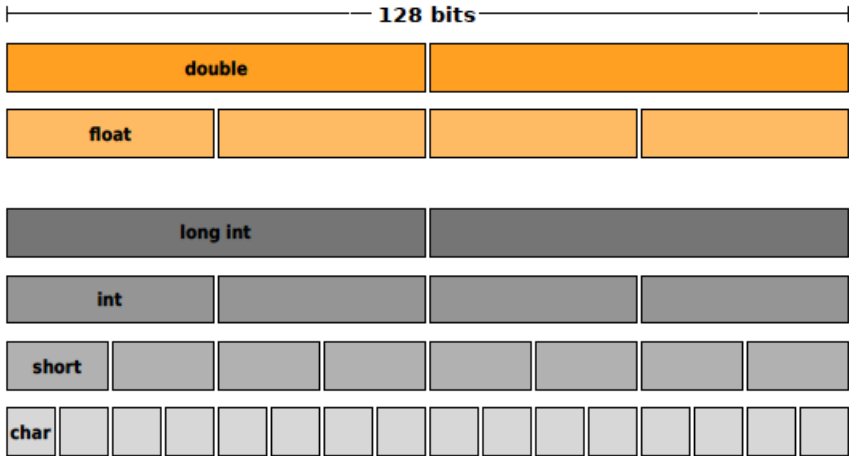
- des types de données
- des fonctions opérant sur ces types de données

Fichiers

- SSE : xmmintrin.h
- SSE2 : emmintrin.h
- SSE3 : pmmmintrin.h
- SSSE3 : tmmmintrin.h
- SSE4.1 : smmintrin.h
- SSE4.2 : nmmintrin.h

Types

- `__m128` : 4 floats
- `__m128d` : 2 doubles
- `__m128i` : entiers



Nomenclature générale

`_mm{operation}{alignement}_{dataorganization}{datatype}...`

Exemple : addition de 2 vecteurs de 4 floats

```
__m128 C = _mm_add_ps( __m128 A, __m128 B)
```

- s (single) : flottant simple précision (32bits)
- d (double) : flottant double précision (64bits)
- i... (integer) : entier
- p (packed) : contigus
- u (unaligned) : données non alignées en mémoire
- l (low) : bits de poids faible
- h (high) : bits de poids fort
- r (reversed) : dans l'ordre inverse

- 1 déclaration des variables SSE (registres) :
`__m128 r1`
- 2 chargement des données de la mémoire vers les registres SIMD :
`r1 = _mm_load... (type* p)`
- 3 opérations sur les registres SIMD
- 4 placement du contenu des registres en mémoire :
`_mm_store... (type* p, r1)`

- alignés ou non alignés :
_mm_load... ou _mm_loadu...
_mm_store... ou _mm_storeu...
- par vecteurs : $4 \times SP$, $2 \times DP$, ...
_mm_load_ps, _mm_loadu_pd, ...
_mm_store_ps, _mm_storeu_pd, ...
- par élément scalaire :
_mm_load_ss, _mm_load_sd, ...
_mm_store_ss, _mm_store_sd, ...

Le processeur peut effectuer des transferts efficaces de 16 octets (128 bits) entre la mémoire et un registre SSE sous la condition que le bloc soit aligné sur 16 octets. Cette contrainte est matérielle

Attention

L'alignement dépend de l'architecture et du type de variable. Par défaut l'alignement d'un entier 32 bits est effectué sur 4 octets
Pour obtenir l'alignement : `__alignof__(type)`

Cacheline splits

Une ligne de cache a généralement une taille de 32 à 64 octets.

Si la donnée chargée dans un registre SSE provient d'une zone mémoire à "cheval" sur 2 lignes de cache, alors il faut lire les 2 lignes de cache pour pouvoir remplir le registre SSE, ce qui implique une baisse de performance

- Alignement de données statiques sur 16 octets :
`int x __attribute__((aligned (16)))`
- Alignement de données dynamiques sur 16 octets :
`type* x = (type*) _mm_malloc(size*sizeof(type), 16);`

SSE fournit des opérations d'accès sur des données alignées et non alignées. Cependant les accès non alignés sont beaucoup plus lents!

Copie de 4 foats

```
#include <immintrin.h>
#include <iostream>

int main()
{
    float array0[ 4 ] __attribute__((aligned(16))) = { 0.0f, 1.0f, 2.0f, 3.0f };
    float array1[ 4 ] __attribute__((aligned(16)));

    // Load 4 values from the first array into a SSE register.
    __m128 r0 = _mm_load_ps( array0 );
    // Store the content of the register into the second array.
    _mm_store_ps( array1, r0 );

    for( auto x: array0 )
    {
        std::cout << x << std::endl;
    }

    return 0;
}
```

- `_mm_add_pd` - (Add-Packed-Double)
 - Entrée : [A0, A1], [B0, B1]
 - Sortie : [A0 + B0, A1 + B1]
- `_mm_add_ps` - (Add-Packed-Single)
 - Entrée : [A0, A1, A2, A3], [B0, B1, B2, B3]
 - Sortie : [A0 + B0, A1 + B1, A2 + B2, A3 + B3]
- `_mm_add_epi64` - (Add-Packed-LongInt)
 - Entrée : [A0, A1], [B0, B1]
 - Sortie : [A0 + B0, A1 + B1]
- `_mm_add_epi32` - (Add-Packed-Int)
 - Entrée : [A0, A1, A2, A3], [B0, B1, B2, B3]
 - Sortie : [A0 + B0, A1 + B1, A2 + B2, A3 + B3]

- `_mm_mul_pd` - (Multiply-Packed-Double)
 - Entrée : [A0, A1], [B0, B1]
 - Sortie : [A0 * B0, A1 * B1]
- `_mm_mul_ps` - (Multiply-Packed-Single)
 - Entrée : [A0, A1, A2, A3], [B0, B1, B2, B3]
 - Sortie : [A0 * B0, A1 * B1, A2 * B2, A3 * B3]
- `_mm_addsub_pd` - (Add-Subtract-Packed-Double) (SSE3)
 - Entrée : [A0, A1], [B0, B1]
 - Sortie : [A0 - B0, A1 + B1]
- `_mm_addsub_ps` - (Add-Subtract-Packed-Single)
 - Entrée : [A0, A1, A2, A3], [B0, B1, B2, B3]
 - Sortie : [A0 - B0, A1 + B1, A2 - B2, A3 + B3]

- `_mm_hadd_pd` - (Horizontal-Add-Packed-Double)
 - Entrée : [A0, A1], [B0, B1]
 - Sortie : [B0 + B1, A0 + A1]
- `_mm_hadd_ps` (Horizontal-Add-Packed-Single)
 - Entrée : [A0, A1, A2, A3], [B0, B1, B2, B3]
 - Sortie : [B0 + B1, B2 + B3, A0 + A1, A2 + A3]
- `_mm_hsub_pd` - (Horizontal-Subtract-Packed-Double)
 - Entrée : [A0, A1], [B0, B1]
 - Sortie : [A0 - A1, B0 - B1]
- `_mm_hsub_ps` - (Horizontal-Subtract-Packed-Single)
 - Entrée : [A0, A1, A2, A3], [B0, B1, B2, B3]
 - Sortie : [A0 - A1, A2 - A3, B0 - B1, B2 - B3]

`_mm_{and , or , xor ... }_{ps, pd, si128}`

Comparaisons

La comparaison de 2 registres SSE à l'aide des instructions `_mm_cmp...` produit un masque contenant un champs de 1 lorsque la condition est vérifiée, et un champs de 0 dans le cas contraire

Mélange des données : Shuffle

L'instruction shuffle permet de combiner des données de 2 registres donnés en argument suivant un masque indiquant les positions à récupérer

Il est possible de passer le même registre en argument

Limitation

L'instruction shuffle impose de récupérer autant de données dans les 2 registres. Par exemple, il est possible de récupérer 2 flottants dans chacun des 2 registres mais pas 1 flottant de l'un et 3 flottants de l'autre

Exemple

```
float a0[4] __attribute__((aligned(16))) = {1, 2, 3, 4};
float a1[4] __attribute__((aligned(16))) = {5, 6, 7, 8};
float a2[4] __attribute__((aligned(16)));

__m128 r0 = _mm_load_ps(a0);
__m128 r1 = _mm_load_ps(a1);

// _MM_SHUFFLE is a macro used to create the mask.
// In this example, it takes values 0 and 1 from r1
// and values 2 and 3 from r0
r0 = _mm_shuffle_ps(r0, r1, _MM_SHUFFLE(3, 2, 1, 0));

_mm_store_ps(a2, r0); // contains {1, 2, 7, 8}
```

- `_mm_set_ps(float, float, float, float)`
- `_mm_set_pd(double, double)`
- `_mm_set_epi32(int, int, int, int)`
- `_mm_set_epi16(short, short, short, short, short, short, short, short)`

Soit une machine fournissant les instructions vectorielles suivantes :

- vector float **vec_ld**(float*) : chargement aligné de 4 floats
- void **vec_st**(vector float, float*) : rangement aligné de 4 floats
- vector float **vec_splat**(float) : remplissage d'un vecteur par une constante
- vector float **vec_add**(vector float, vector float) : somme élément par élément de deux vecteurs de floats
- vector float **vec_mul**(vector float, vector float) : produit élément par élément de deux vecteurs de floats
- float **vec_hadd**(vector float) : somme des éléments d'un vecteur de floats

- Toutes ces instructions ont une latence de 1 cycle.
- On considère que vector float est le type représentant un registre vectoriel 128 bits contenant 4 floats contigus. Leur initialisation peut s'écrire : `vector float f = 1,2,3,4;`
- Implémenter un code vectoriel utilisant ces instructions permettant de calculer le produit scalaire de deux tableaux de float de $4N$ éléments.