



xsimd : SIMD explicite portable

Hadrien Grasland
CNRS – LAL

2018/06/21

Processus de vectorisation

- **Les instructions SIMD sont limitées et malpratiquées**
 - Mieux vaut les réserver à son « fond de boucle »
 - Mieux vaut **sous-traiter à une bibliothèque** ce qu'on peut
- **Mais si on doit créer sa bibliothèque ?**
 - Interface centrée sur le domaine cible (algèbre, FFT...)
 - Algorithmes SIMD internes soigneusement optimisés
 - **Couche inférieure qui abstrait les différences matérielles**

Types d'abstractions matérielles

- **SIMD implicite : On ne manipule pas de vecteurs**
 - On exprime le **parallélisme de données**... et on prie
 - Exemples : OpenCL, ~~Intel ArBB~~, ~~Intel Cilk Plus~~...
- **SIMD explicite : On manipule des vecteurs abstraits**
 - Généralement via un **type générique** du style
`VectorType<typename T, size_t N = MAX_HW_VEC<T>>`
 - Un peu moins d'élégance, beaucoup plus de contrôle
 - Exemples : VectorClass, UME::SIMD, **xsimd**...

Positionnement de xsimd

- **Un maillon de la pile QuantStack**
 - xsimd : Abstraction explicite du matériel SIMD
 - xtensor : Tableaux à N dimensions (« numpy en C++ »)
 - xtensor-blas : Binding vers les bibliothèques BLAS
- **Reprend les idées (et le code) de boost::simd**
 - Un projet open-source de NumScale (NT2, bSIMD...)
 - **Récemment sabordé** pour des raisons commerciales :-(

Opérations SIMD élémentaires

```
1 #include <xsimd/xsimd.hpp>
2
3 namespace xs = xsimd;
4 using vec = xs::simd_type<float>;
5 // using sse_vec = xs::batch<float, 4>;
6
7 vec hello_world(const vec& x, const vec& y) {
8     // xs::sin/cos respecte IEEE-754
9     auto sin = xs::sin(x + y);
10    auto cos = xs::cos(x - y);
11    return xs::select(x < y, sin, cos);
12 }
```

Calcul complet : Vue d'ensemble

```
1 #include <cstdint>
2 #include <vector>
3 #include "xsimd/xsimd.hpp"
4
5 namespace xs = xsimd;
6 using al_vec =
7     std::vector<double,
8         xsimd::aligned_allocator<double,
9             XSIMD_DEFAULT_ALIGNMENT>>;
10
11 void mean(const al_vec& i1, const al_vec& i2, al_vec& o) {
12     std::size_t size = i1.size();
13     constexpr std::size_t simd_size = xs::simd_type<double>::size;
14     std::size_t vec_size = size - size % simd_size;
15
16     for(std::size_t i = 0; i < vec_size; i += simd_size) {
17         auto bi1 = xs::load_aligned(&i1[i]);
18         auto bi2 = xs::load_aligned(&i2[i]);
19         auto bo = (bi1 + bi2) / 2;
20         bo.store_aligned(&o[i]);
21     }
22     for(std::size_t i = vec_size; i < size; ++i) {
23         o[i] = (i1[i] + i2[i]) / 2;
24     }
25 }
```

Calcul complet : Gestion de l'alignement

```
1 #include <cstdint>
2 #include <vector>
3 #include "xsimd/xsimd.hpp"
4
5 namespace xs = xsimd;
6 using al_vec =
7     std::vector<double,
8         xsimd::aligned_allocator<double,
9             XSIMD_DEFAULT_ALIGNMENT>>;
10
11 void mean(const al_vec& i1, const al_vec& i2, al_vec& o) {
12     std::size_t size = i1.size();
13     constexpr std::size_t simd_size = xs::simd_type<double>::size;
14     std::size_t vec_size = size - size % simd_size;
15
16     for(std::size_t i = 0; i < vec_size; i += simd_size) {
17         auto bi1 = xs::load_aligned(&i1[i]);
18         auto bi2 = xs::load_aligned(&i2[i]);
19         auto bo = (bi1 + bi2) / 2;
20     }
```

Calcul complet : Coeur du calcul

```
7     std::vector<double,  
8         xsimd::aligned_allocator<double,  
9             XSIMD_DEFAULT_ALIGNMENT>>;  
10  
11 void mean(const al_vec& i1, const al_vec& i2, al_vec& o) {  
12     std::size_t size = i1.size();  
13     constexpr std::size_t simd_size = xs::simd_type<double>::size;  
14     std::size_t vec_size = size - size % simd_size;  
15  
16     for(std::size_t i = 0; i < vec_size; i += simd_size) {  
17         auto bi1 = xs::load_aligned(&i1[i]);  
18         auto bi2 = xs::load_aligned(&i2[i]);  
19         auto bo = (bi1 + bi2) / 2;  
20         bo.store_aligned(&o[i]);  
21     }  
22     for(std::size_t i = vec_size; i < size; ++i) {  
23         o[i] = (i1[i] + i2[i]) / 2;  
24     }  
25 }
```


Rappel : Si vous pouvez sous-traiter...

```
1 #include <xtensor/xtensor.hpp>
2
3 using data = xt::xtensor<float, 1>;
4
5 void mean(const data& i1, const data& i2, data& o) {
6     o = (i1 + i2) / 2;
7 }
```

Conclusion

- **xsimd fournit une abstraction SIMD explicite**
 - Souvent nécessaire pour des performances optimales
 - Supporte SSE/AVX/AVX512 et leurs extensions, NEON...
- **Projet GSoC : De boost::simd à xtensor**
 - Départ : Algèbre basse dimensionnalité avec boost::simd
 - Portage vers xsimd effectué sans problème majeur
 - But : Optimiser xtensor jusqu'à pouvoir tout faire avec

Questions ?
Remarques ?