

Bibliothèque générique multi-cible d'algèbre linéaire

Wilfried Kirschenmann, EDF R&D - Supélec

Laurent Plagne, EDF R&D

Stéphane Vialle, Supélec - INRIA

Sommaire


1. Introduction
2. DSL de l'algèbre linéaire creux structuré : Legolas++
3. Programmation de processeurs parallèles
4. Parallélisation d'un code industriel d'algèbre linéaire
5. Conclusion

1. Introduction

1. Introduction

- Problématiques du HPC dans un contexte industriel
 - Différentes approches
 - Des accélérateurs de calcul
2. DSL de l'algèbre linéaire creux structuré : Legolas++
 3. Programmation de processeurs parallèles
 4. Parallélisation d'un code industriel d'algèbre linéaire
 5. Conclusion

1. Problématiques du HPC dans un contexte industriel



1. Différentes approches

Langage

- Expressivité maximale
- Performances rarement (jamais ?) optimales

Bibliothèques

- Performances maximales
- Aucune expressivité

« Domain Specific Language » (DSL)

- Expressivité étendue **dans le domaine**
- Très bonnes performances **dans le domaine**

1. Différentes approches

Fonction
mathématique

$A += B$

$A += B + C$

Langage
(C)

`add1(A, B)`

`add2(A, B, C)`

Bibliothèques
(BLAS)

`cblas_saxpy(
N, 1, B, 1, A, 1)`


~~`cblas_saxpy(
N, 1, B, 1, A, 1)`
`cblas_saxpy(
N, 1, C, 1, A, 1)`~~

DSL
(Legolas++)

$A += B$

$A += B + C$

1. Des accélérateurs de calcul



2. DSL de l'algèbre linéaire creux structuré : Legolas++

1. Introduction
2. **DSL de l'algèbre linéaire creux structuré : Legolas++**
 - Possibilités
 - Exemple de code
 - Réponse à la problématique du HPC industriel
 - Performances
3. Programmation de processeurs parallèles
4. Parallélisation d'un code industriel d'algèbre linéaire
5. Conclusion

$$\text{SPNMatrix} = \text{D}(\text{DSPNMatrix}) + \text{R}(\text{ScatteringMatrix})$$

$$\text{SPNMonogroupMatrix} = \text{D}(\text{DMonogroupMatrix}) + \text{R}(\text{RMonogroupMatrix})$$

$$\text{SPNMonogroupScatteringMatrix}$$

$$\begin{array}{cc} \text{DiffusionMatrix} & \text{HarmonicCouplingMatrix} \\ \begin{bmatrix} \hat{C}_x(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_x \hat{P}_{xx} \\ \hat{C}_y(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_y \hat{P}_{xy} \\ \hat{P}_{xx} \hat{B}_x^t & \hat{P}_{yx} \hat{B}_y^t & \hat{F}(\mathcal{D}_{\phi}^{gh}) \\ H.D(0,0) & .D(0,0) \end{bmatrix} & \begin{bmatrix} 0 & 0 & \alpha \hat{B}_x \hat{P}_{xx} \\ 0 & 0 & \alpha \hat{B}_y \hat{P}_{xy} \\ 0 & 0 & 0 \\ H.D(0,0) & .R(0,1) \end{bmatrix} \\ \text{HarmonicCouplingMatrix} & \text{DiffusionMatrix} \\ \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ \beta \hat{P}_{xx} \hat{B}_x^t & \beta \hat{P}_{yx} \hat{B}_y^t & 0 \\ H.D(0,0) & .R(1,0) \end{bmatrix} & \begin{bmatrix} \hat{C}_x(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_x \hat{P}_{xx} \\ \hat{C}_y(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_y \hat{P}_{xy} \\ \hat{P}_{xx} \hat{B}_x^t & \hat{P}_{yx} \hat{B}_y^t & \hat{F}(\mathcal{D}_{\phi}^{gh}) \\ H.D(0,0) & .D(1,1) \end{bmatrix} \end{array}$$

$$H(0,0) = H.D(0,0)$$

$$\begin{array}{cc} \text{SpaceScatteringMatrix} & \\ \begin{bmatrix} \hat{C}_x(\mathcal{S}_{\psi}^{gg'h}) \\ \hat{C}_y(\mathcal{S}_{\psi}^{gg'h}) \\ \hat{F}(\mathcal{S}_{\phi}^{gg'h}) \\ H.R(0,1) (0,0) \end{bmatrix} & \\ \text{SpaceScatteringMatrix} & \\ \begin{bmatrix} 0 \\ 0 \\ 0 \\ H.R(0,1) (1,1) \end{bmatrix} & \end{array}$$

$$H(0,1) = H.R(0,1)$$

$$\text{SPNMonogroupScatteringMatrix}$$

$$\begin{array}{cc} \text{SpaceScatteringMatrix} & \\ \begin{bmatrix} \hat{C}_x(\mathcal{S}_{\psi}^{gg'h}) \\ \hat{C}_y(\mathcal{S}_{\psi}^{gg'h}) \\ \hat{F}(\mathcal{S}_{\phi}^{gg'h}) \\ H.R(1,0) (0,0) \end{bmatrix} & \\ \text{SpaceScatteringMatrix} & \\ \begin{bmatrix} 0 \\ 0 \\ 0 \\ H.R(1,0) (1,1) \end{bmatrix} & \end{array}$$

$$H(1,0) = H.R(1,0)$$

$$\text{SPNMonogroupMatrix} = \text{D}(\text{DMonogroupMatrix}) + \text{R}(\text{RMonogroupMatrix})$$

$$\begin{array}{cc} \text{DiffusionMatrix} & \text{HarmonicCouplingMatrix} \\ \begin{bmatrix} \hat{C}_x(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_x \hat{P}_{xx} \\ \hat{C}_y(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_y \hat{P}_{xy} \\ \hat{P}_{xx} \hat{B}_x^t & \hat{P}_{yx} \hat{B}_y^t & \hat{F}(\mathcal{D}_{\phi}^{gh}) \\ H.D(1,1) & .D(0,0) \end{bmatrix} & \begin{bmatrix} 0 & 0 & \alpha \hat{B}_x \hat{P}_{xx} \\ 0 & 0 & \alpha \hat{B}_y \hat{P}_{xy} \\ 0 & 0 & 0 \\ H.D(1,1) & .R(0,1) \end{bmatrix} \\ \text{HarmonicCouplingMatrix} & \text{DiffusionMatrix} \\ \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ \beta \hat{P}_{xx} \hat{B}_x^t & \beta \hat{P}_{yx} \hat{B}_y^t & 0 \\ H.D(1,1) & .R(1,0) \end{bmatrix} & \begin{bmatrix} \hat{C}_x(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_x \hat{P}_{xx} \\ \hat{C}_y(\mathcal{D}_{\psi}^{gh}) & -\hat{B}_y \hat{P}_{xy} \\ \hat{P}_{xx} \hat{B}_x^t & \hat{P}_{yx} \hat{B}_y^t & \hat{F}(\mathcal{D}_{\phi}^{gh}) \\ H.D(1,1) & .D(1,1) \end{bmatrix} \end{array}$$

$$H(1,1) = H.D(1,1)$$

$$\underline{\text{SPNMonogroupMatrix}} = \text{D}(\text{DMonoGroupMatrix}) + \text{R}(\text{RMonoGroupMatrix})$$

DiffusionMatrix

$$\begin{bmatrix} \hat{C}_x(\mathcal{D}_\psi^{gh}) & & -\hat{B}_x \hat{P}_{xx} \\ & \hat{C}_y(\mathcal{D}_\psi^{gh}) & -\hat{B}_y \hat{P}_{xy} \\ \hat{P}_{xx} \hat{B}_x^t & \hat{P}_{yx} \hat{B}_y^t & \hat{F}(\mathcal{D}_\phi^{gh}) \\ & & \text{H.D}(0,0) . \text{D}(0,0) \end{bmatrix}$$

HarmonicCouplingMatrix

$$\begin{bmatrix} 0 & 0 & \alpha \hat{B}_x \hat{P}_{xx} \\ 0 & 0 & \alpha \hat{B}_y \hat{P}_{xy} \\ 0 & 0 & 0 \\ & & \text{H.D}(0,0) . \text{R}(0,1) \end{bmatrix}$$

HarmonicCouplingMatrix

$$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ \beta \hat{P}_{xx} \hat{B}_x^t & \beta \hat{P}_{yx} \hat{B}_y^t & 0 \\ & & \text{H.D}(0,0) . \text{R}(1,0) \end{bmatrix}$$

DiffusionMatrix


$$\begin{bmatrix} \hat{C}_x(\mathcal{D}_\psi^{gh}) & & -\hat{B}_x \hat{P}_{xx} \\ & \hat{C}_y(\mathcal{D}_\psi^{gh}) & -\hat{B}_y \hat{P}_{xy} \\ \hat{P}_{xx} \hat{B}_x^t & \hat{P}_{yx} \hat{B}_y^t & \hat{F}(\mathcal{D}_\phi^{gh}) \\ & & \text{H.D}(0,0) . \text{D}(1,1) \end{bmatrix}$$

2. Legolas++ : exemple de code

```
Typedef Legolas++ : :Vector<double> Vector;  
Vector a, b, c;
```

...


c = 3*b;



```
for (int i = 0 ; i < c.size() ; i++)  
    c[i] += 3*b[i];
```

...

a = 4*b-7*c;



```
for (int i = 0 ; i < a.size() ; i++)  
    a[i] = 4*b[i]-7*c[i];
```

...

2. Legolas++ : réponses aux problématiques du HPC industriel

Performances


- Allocation paresseuse
- Évaluation paresseuse
- Pas de vecteurs temporaires
- Instructions optimisées en assembleur

Maintenance et évolutivité

- Écriture mathématique
- Code petit
- Optimisations localisées
- Performances garanties

2. Legolas++ : performances

$X = aY + bZ$ (Bi Quad 2.33GHz L2=6MB)



3. Programmation de processeurs parallèles

1. Introduction
2. DSL de l'algèbre linéaire creux structuré : Legolas++
3. **Programmation de processeurs parallèles**
 - **Principes généraux**
 - CPU multi-cœur et Intel Threading Building Blocks
 - Les processeurs graphiques et CUDA
4. Parallélisation d'un code industriel d'algèbre linéaire
5. Conclusion

3. Programmation de processeurs parallèles : principes

Boucles que nous souhaitons paralléliser :

```
for (int i = 0 ; i < a.size() ; i++)  
    f(i);
```

Avec :

f qui ne provoque pas d'effets de bord

Exemple :

```
void f ( const int & i ) {  
    a[i]+=b[i]+c[i];  
}
```

a, b et c étant trois tableaux de flottants

3. Programmation de processeurs parallèles : principes

```
struct Add3 {
```

```
    Add3 (Vector & a, const Vector & b, const Vector & c) :  
        a_(a), b_(b), c_(c) {}
```

```
    void operator() ( const int & i ) const {  
        a[i]+=b[i]+c[i];  
    }
```

```
private :
```

```
    Vector & a;
```


```
    const Vector & b;
```

```
    const Vector & c;
```

```
};
```

3. Programmation de processeurs parallèles : principes

```
...  
for (int i = 0 ; i < a.size() ; i++)  
    a[i] += b[i]+c[i];  
...
```




```
...  
const Add3 functor(a,b,c);  
for (int i = 0 ; i < a.size() ; i++)  
    functor(i);  
...
```

3. Programmation de processeurs parallèles

1. Introduction
2. DSL de l'algèbre linéaire creux structuré : Legolas++
3. **Programmation de processeurs parallèles**
 - Principes généraux
 - **CPU multi-cœur et Intel Threading Building Blocks**
 - Les processeurs graphiques et CUDA
4. Parallélisation d'un code industriel d'algèbre linéaire
5. Conclusion


3. Programmation de processeurs parallèles : CPU multi-cœur et TBB

```
class tbb : :blocked_range<T>;
```



Sert à définir sur quel intervalle la boucle pourra être parallélisée

```
void tbb : :parallel_for<RANGE, BODY>(const RANGE&  
range, const BODY& body);
```



Fonction qui permet de paralléliser une boucle for effectuant des appels à body()

3. Programmation de processeurs parallèles : CPU multi-cœur et TBB

```
struct Add3 {  
    Add3 (Vector & a, const Vector & b, const Vector & c) :  
        a_(a), b_(b), c_(c) {}  
    void operator() ( const int & i ) const {  
        a[i]+=b[i]+c[i];  
    }  
    void operator() ( const tbb::blocked_range<int> & range ) const {  
        for (int i = range.begin() ; i < range.end() ; i++)  
            (*this)(i);  
    }  
private :  
    Vector & a;  
    const Vector & b;  
    const Vector & c;  
};
```

3. Programmation de processeurs parallèles : CPU multi-cœur et TBB

```
...  
const Add3 functor(a,b,c);  
for (int i = 0 ; i < a.size() ; i++)  
    functor(i);  
...
```



```
...  
typedef tbb :: blocked_range<int> Range;  
...  
const Add3 functor(a,b,c);  
const Range range(0, a.size());  
tbb :: parallel_for< Range, Add3 >(range, functor);  
...
```

3. Programmation de processeurs parallèles


1. Introduction
2. DSL de l'algèbre linéaire creux structuré : Legolas++
3. **Programmation de processeurs parallèles**
 - Principes généraux
 - CPU multi-cœur et Intel Threading Building Blocks
 - **Les processeurs graphiques et CUDA**
4. Parallélisation d'un code industriel d'algèbre linéaire
5. Conclusion

3. Programmation de processeurs parallèles : GPUs et CUDA

Le GPU G80 (**G200**) en chiffres :

- Puissance de calcul théorique de 512 Gflops (**1 Tflops**)
- Bande passante mémoire de 74 Go/s (**140 Go/s**)
- 16 (**30**) cœurs SIMD 8 voies: 128 (**240**) unités de calcul
- Jusqu'à 12 288 threads simultanés (**30 720**)
- Jusqu'à 1.5 Go de RAM (**4 Go**)

3. Programmation de processeurs parallèles : GPUs et CUDA




3. Programmation de processeurs parallèles : GPUs et CUDA

```
void cuda_parallel_for_Add3(const Add3 adder, const int N) {  
    const int bSize = 512;  
    const int nbEltsPerThreads = 4;  
    int gSize = N/(bSize*nbEltsPerThreads)+1;  
    while (gSize > 65535)  
        gSize /=2;  
    const dim3 blockDim(bSize, 1, 1);  
    const dim3 gridDim(gSize, 1, 1);  
    add3Kernel<<< gridDim, blockDim >>>( adder, N);  
}
```

3. Programmation de processeurs parallèles : GPUs et CUDA


```
__global__ void add3Kernel(const Add3 adder, const int N) {  
    const int bx = blockIdx.x;  
    const int tx = threadIdx.x;  
    const int bSize = blockDim.x;  
    const int gSize = gridDim.x;  
    const int nbThreads = bSize*gSize;  
    const int threadId = tx+bx*bSize;  
    for (int i = threadId ; i < N ; i += nbThreads )  
        adder(i);  
}
```

3. Programmation de processeurs parallèles : GPUs et CUDA




3. Programmation de processeurs parallèles : GPUs et CUDA

- Fonction testée : saxpy
foreach i : $Y[i] = a.X[i] + Y[i]$



3. Programmation de processeurs parallèles : GPUs et CUDA



3. Programmation de processeurs parallèles : GPUs et CUDA

Outils de développement

- Compilateur NVCC
- CUDA profiler
- Émulateur de GPU supportant gdb


Librairies

- cuBLAS
- cuFFT

4. Parallélisation d'un code industriel d'algèbre linéaire

1. Introduction
2. DSL de l'algèbre linéaire creux structuré : Legolas++
3. Programmation de processeurs parallèles
4. **Parallélisation d'un code industriel d'algèbre linéaire**
 - Principes
 - Code actuel avec Legolas++
 - Code parallélisé avec TBB
 - Code parallélisé avec CUDA
 - Résultats
5. Conclusion

4. Parallélisation d'un code industriel d'algèbre linéaire : principes




À chaque étape, on effectue des opérations vectorielles ou matricielles :

- $f1(\text{dir}, \text{vect})$
- $f2(\text{dir}, \text{vect})$
- $f3(\text{dir}, \text{vect})$
- $f4(\text{dir}, \text{vect})$

4. Parallélisation d'un code industriel d'algèbre linéaire : code Legolas++

```
for ( int iter = 0 ; iter < iterationMax ; iter++)  
    for ( int dir = 0 ; dir < 3 ; d--) {  
        f1(dir, vectComplet);  
        f2(dir, vectComplet);  
        f3(dir, vectComplet);  
        f4(dir, vectComplet);  
        reordonnement(dir);  
    }
```

4. Parallélisation d'un code industriel d'algèbre linéaire : principes




4. Parallélisation d'un code industriel d'algèbre linéaire : code Legolas++

```
for ( int iter = 0 ; iter < iterationMax ; iter++)  
  for ( int dir = 0 ; dir < 3 ; d--) {  
    for (int ligneldx = 0 ; ligneldx < nbLignes ; ligneldx++){  
      f1(dir, lignes[ligneldx ]);  
      f2(dir, lignes[ligneldx ]);  
      f3(dir, lignes[ligneldx ]);  
      f4(dir, lignes[ligneldx ]);  
    }  
    reordonnancement(dir);  
  }
```

4. Parallélisation d'un code industriel d'algèbre linéaire

Speed-up obtenu par rapport à la version séquentielle traitant le vecteur entier

—◆ ligne par ligne séquentiel




4. Parallélisation d'un code industriel d'algèbre linéaire : code Legolas++

```
for ( int iter = 0 ; iter < iterationMax ; iter++)  
    for ( int dir = 0 ; dir < 3 ; d--) {  
        LigneParLigneFunctor functor(dir, lignes);  
        const Range range(0, nbLignes );  
        tbb : :parallel_for<Range,  
            LigneParLigneFunctor>(range, functor);  
  
        reordonnancement(dir);  
    }
```

4. Parallélisation d'un code industriel d'algèbre linéaire

Speed-up obtenu par rapport à la version séquentielle traitant le vecteur entier

—◆— ligne par ligne séquentiel —■— ligne par ligne TBB



4. Parallélisation d'un code industriel d'algèbre linéaire

Pas de cache sur GPU !

→ Il faut optimiser le code à la main...

4. Parallélisation d'un code industriel d'algèbre linéaire

```
for (int i = 0 ; i < size ; i++)  
    a[i] += b[i];  
for (int i = 0 ; i < size ; i++)  
    d[i] *= a[i];
```

6*size accès mémoire

```
for (int i = 0 ; i < size ; i++) {  
    float a_i = a[i] + b[i];  
    a[i] = a_i;  
    d[i] *= a_i;  
}
```

5*size accès mémoire

4. Parallélisation d'un code industriel d'algèbre linéaire

```
for (int i = 0 ; i < size ; i++)  
    a[i] = b[i]-b[i+1];
```


3*size accès mémoire

```
float b_i = b[0];  
for (int i = 0 ; i < size ; i++){  
    float b_ip1 = b[i+1];  
    a[i] = b_i - b_ip1 ;  
    b_i = b_ip1;  
}
```

2*size accès mémoire

4. Parallélisation d'un code industriel d'algèbre linéaire

Speed-up obtenu par rapport à la version séquentielle traitant le vecteur entier



5. Conclusion

- Introduction
- DSL de l'algèbre linéaire creux structuré : Legolas++
- Programmation de processeurs parallèles
- Parallélisation d'un code industriel d'algèbre linéaire
- **Conclusion**

Génération automatique de code multi-cible

- **NVCC : le compilateur CUDA**
- Modèle d'intégration de CUDA dans un code C++
- Solution envisagées

Génération de code multi-cible : NVCC le compilateur CUDA

Il n'y a pas de pile d'appels sur GPU. La programmation sur GPU est donc moins libre que sur CPU :

- Pas de fonctions récursives
- Pas de pointeurs de fonctions
- N'est pas compatible C++ pour le code des noyaux
- Supporte les templates avec certaines contraintes :
 - Pas de mot clé **typename**
- Le mot clé **typedef** n'est pas toujours géré correctement

Génération de code multi-cible : NVCC le compilateur CUDA

Il n'y a pas de pile d'appels sur GPU. La programmation sur GPU est donc moins libre que sur CPU :

- Pas de fonctions récursives

```
cuda_parallel_for< FunctorType< float > >
```

```
typedef FunctorType< float > Functor  
cuda_parallel_for< Functor >
```

```
Typedef typename FUNCTOR::RealType;
```

Génération de code multi-cible : NVCC le compilateur CUDA

Il n'y a pas de pile d'appels sur GPU. La programmation sur GPU est donc moins libre que sur CPU :


- Pas de fonctions récursives
- Pas de pointeurs de fonctions
- N'est pas compatible C++ pour le code des noyaux
- Supporte les templates avec certaines contraintes :
 - Pas de mot clé **typename**
- Le mot clé **typedef** n'est pas toujours géré correctement

➔ **Il n'est pas raisonnable de vouloir compiler une application C++ avec NVCC**

Génération automatique de code multi-cible

- NVCC : le compilateur CUDA
- **Modèle d'intégration de CUDA dans un code C++**
- Solution envisagées


Génération de code multi-cible : modèle d'intégration CUDA/C++



Les accélérateurs de calcul

- NVCC : le compilateur CUDA
- Modèle d'intégration de CUDA dans un code C++
- **Solution envisagées**

Génération de code multi-cible : Solution envisagées



Génération de code multi-cible : Solution envisagées

Headers CUDA++

```
Template < typename FUNCTOR >  
void cuda_parallel_for(const FUNCTOR & functor, const Range & range);  
  
struct AxyFunctor{  
    float * x_;  
    float * y_;  
    void operator(const Range & range) const {  
        for (int i = range.begin() ; i<range.end() ; i++)  
            y[i]+=x[i];  
    }  
};
```

Génération de code multi-cible : Solution envisagées

Code C++

```
Int main ()  
{  
    ....  
    AxyFunctor functor;  
    functor.x_ = ###;  
    functor.y_ = ###;  
    Range range(0, ###);  
    cuda_parallel_for< AxyFunctor >(functor, range);  
    ...  
};
```

Génération de code multi-cible : Solution envisagées

Code CUDA++

```
Template < typename FUNCTOR>
void cuda_parallel_for(const FUNCTOR & functor, const Range & range)
{
    ...
    cuda_parallel_forKernel< Functor ><<< Dg, Db >>>(functor, range);
    ...
};
```

Génération de code multi-cible : Solution envisagées

Headers CUDA++

```
Template < typename FUNCTOR>  
void cuda_parallel_forKernel(const FUNCTOR functor, const Range range)  
{  
    ...  
    functor( localRange );  
    ...  
};
```

Génération de code multi-cible : Solution envisagées

Code CUDA++

```
Template < typename FUNCTOR>
cuda_parallel_for(const FUNCTOR & functor, const Range & range)
{
    ...
    cuda_parallel_forKernel< Functor ><<< Dg, Db >>>(functor, range);
    ...
};

void instantiateTemplates()
{
    AxyFunctor functor;
    Range range(0,0);
    cuda_parallel_for< AxyFunctor >(functor, range);
};
```