CentraleSupélec

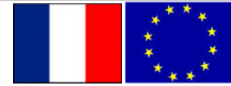

Mineure CalHau1

MPI : communications asynchrones et recouvrement calculs/communications

Stéphane Vialle

Stephane.Vialle@centralesupelec.fr
http://www.metz.supelec.fr/~vialle

CentraleSupélec

MPI-1 : communications asynchrones et recouvrement calculs/comms.

1. Intérêt du recouvrement calculs/communications
2. Communications point à point non bloquantes
3. Communications gérées par des threads explicites
4. Performances expérimentales

CentraleSupélec

MPI-1 : communications asynchrones et recouvrement …

1 – Intérêt du recouvrement calculs/communications

CentraleSupélec

Quand implanter un recouvrement ?

Mieux vaut (tenter de) recouvrir des temps similaires :

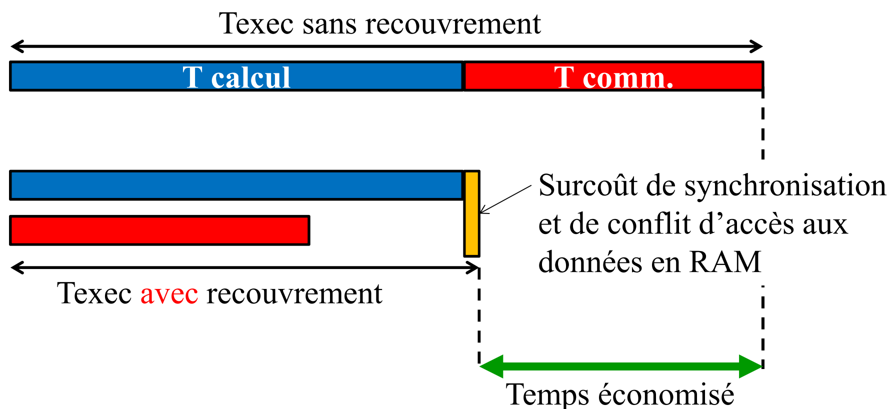

Meilleur cas : Tcalcul = Tcomm → ≈ 50% de temps économisé

Intérêt du recouvrement

Quand implanter un recouvrement ?

Mieux vaut (tenter de) recouvrir des temps similaires :

Ex 1 :

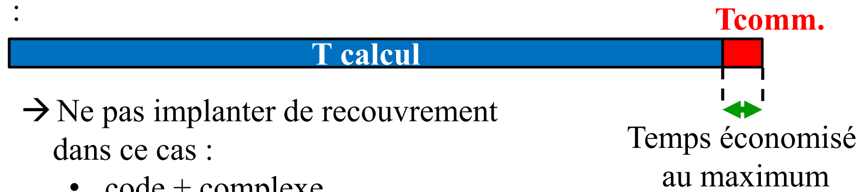

→ Ne pas implanter de recouvrement dans ce cas :
- code + complexe
- gain faible

Temps économisé au maximum

Ex 2 :

→ Arrêter de paralléliser ce cas là !
- Majorité du temps passé en communications !!

MPI-1 : communications asynchrones et recouvrement...

2 – Communications point à point non bloquantes de MPI

- Principes
- Ibsend-Irecv
- Issend-Irecv
- Irsend-Irecv
- Identificateurs persistents
- Limites expérimentales

Communications point à point non bloquantes

Principes des comm. Non bloquantes

Principes des communications non-bloquantes

```
MPI_Ixxxx(…, MPI_Request *request)
Ibsend/Irecv  -  Issend/Irecv  -  Irsend/Irecv
```

- **`Isend` ET `Irecv`** non bloquants
- Un paramètre de plus que leurs homologues bloquants :
  → Id sur la communication demandée (`MPI_Request`)
- Besoin de savoir si les communications sont terminées :
  → `MPI_Wait(request, …)` ou `MPI_Test(request, …)`

Comparaison aux communications bloquantes :

- Nécessite une synchronisation explicite – Plus complexe
- Permet de réaliser du recouvrement calcul-communication

Communications point à point non bloquantes

Ibsend – Irecv

Mode *bufferisé* et non-bloquant : `MPI_Ibsend` – `MPI_Irecv`

Rappel :
`Bsend-Recv`

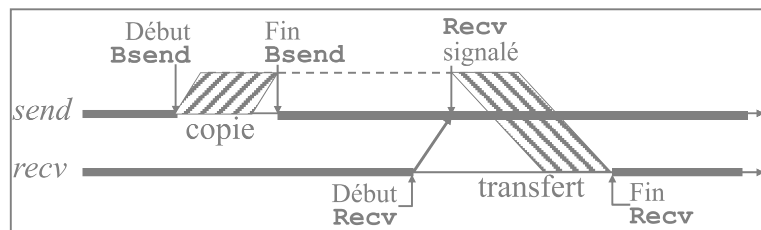

Non-bloquant :
`Ibsend-Irecv`

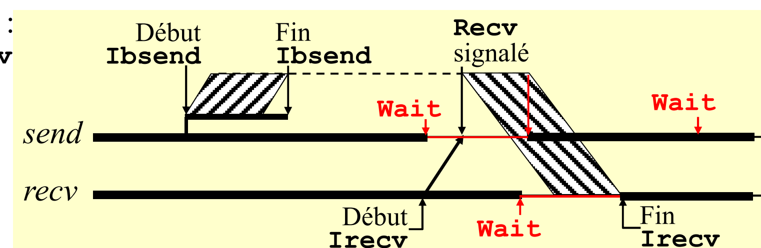

CentraleSupélec

Communications point à point non bloquantes

Issend – Irecv

Mode *synchrone* et non-bloquant : `MPI_Issend` – `MPI_Irecv`

Rappel :
`Ssend-Recv`

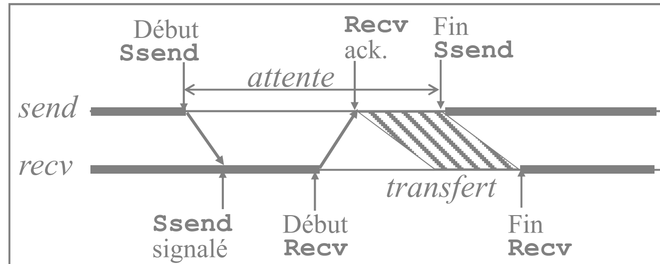

Non-bloquant :
`Issend-Irecv`

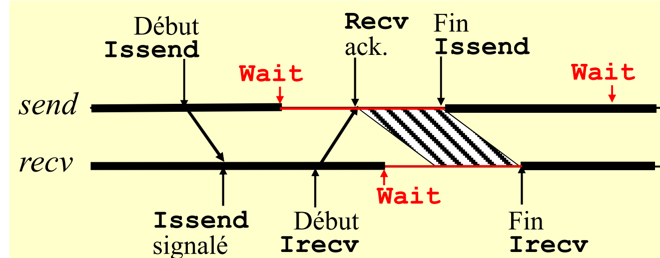

CentraleSupélec

Communications point à point non bloquantes

Irsend – Irecv

Mode *ready* et non-bloquant : `MPI_Irsend` – `MPI_Irecv`

Rappel :
`Rsend-Recv`

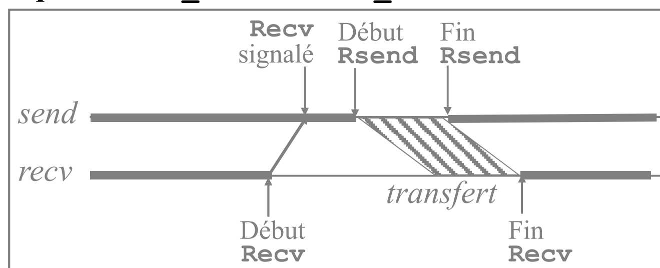

Non-bloquant :
`Irsend-Irecv`

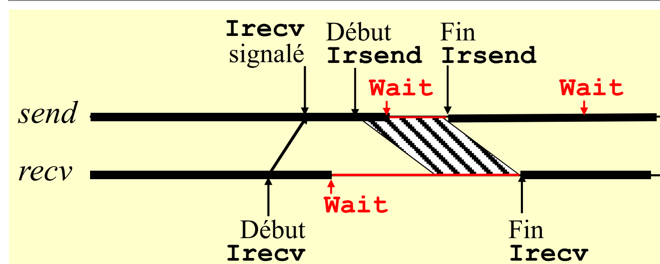

Communications point à point non bloquantes

Identificateurs persistents

Autre mode d'utilisation des comm. non bloquantes :

```
Loop:
   MPI_Issend(…,&s_request); MPI_Irecv(…,&r_request);
   …… // calculs
   MPI_Wait(&s_request,…);   MPI_Wait(&r_request,…);
```

```
MPI_Ssend_init(…,&s_request); MPI_Recv_init(…,&r_request);
Loop:
   MPI_Start(&s_request);     MPI_Start(&r_request);
   …… // calculs
   MPI_Wait(&s_request,…);    MPI_Wait(&r_request,…);
MPI_Request_free(&s_request);
MPI_Request_free(&r_request);
```

→ Evite de réinitialiser des communications non-bloquantes

Communications point à point non bloquantes

Limites expérimentales

Re-développement en Ibsend/Irecv, avec recouvrement calcul/comm :

- Temps de développement ↗
- Complexité ↗
- Mais performances inchangées!!

Re-développement en Bsend/Recv dans un thread OpenMP :

- Temps de développement ↗
- Complexité ↗
- **Performances accrues** ☺

Le recouvrement calculs/communications fonctionne, mais

- pas toujours avec les communications non bloquantes de MPI
- avec des threads explicites encapsulant des communications MPI bloquantes

CentraleSupélec

MPI-1 : communications asynchrones et recouvrement …

3 – Communications non bloquantes gérées par des threads explicites

- MatrixProduct en MPI + OpenMP, par code répliqué
- MatrixProduct en MPI + OpenMP, par `#pragma omp sections`

CentraleSupélec

Produit de matrices avec recouvrement calculs/comms.

Même schéma initial de circulation des données (en P étapes)

Même opération : C = A × B

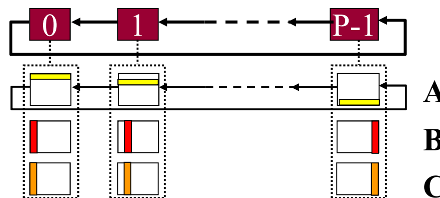

Faire circuler A en parallèle des calculs de l'étape :

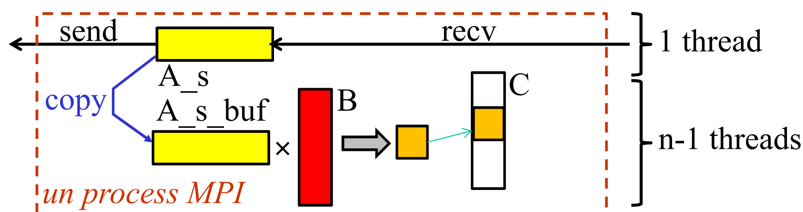

Produit de matrices avec recouvrement calculs/comms.

Même schéma initial de circulation des données (en P étapes)

Même opération : C = A × B

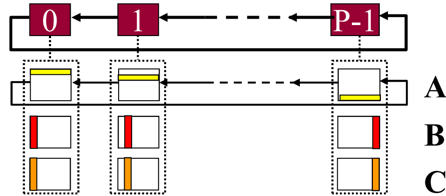

Faire circuler A en parallèle des calculs de l'étape :

- Utiliser des *threads* **OpenMP** dans chaque processus **MPI**
  - un thread réalisera un *MPI_Sendrecv_replace* (ou un *MPI-Sendrecv,* ou un couple *Bsend/recv*…)
  - les autres threads se répartiront les calcul de l'étape
- Les calculs doivent lire une matrice *A_s* stable :
  → donc lire une copie (dans un buffer *A_s_buf*)

Rmq : Faudra-t-il mettre des *#pragma omp barrier* ?

Comms. gérées par threads explicites

MatrixProduct en MPI + OpenMP

Programmation synchrone : exemple 1 avec le kernel 0

Calcul et circulation de As[…]

```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {
  // rmk: omp_get_thread_num() → thread Id.
  //      omp_get_num_threads()→ current number of threads

  ligDebTh = ……; nbLigTh = ……        // Compute a sub-slice
  for (i = ligDebTh; i < ligDebTh + nbLigTh; i++) // of C
     for (j… )
        for (k… )
          C[i][j] += As[i][k]*TBs[k][j]; // optim Bs[j][k]

  #pragma omp barrier                // Sync. all threads
  #pragma omp single {
    MPI_sendrecv_replace(As,…);      // MPI exchange of As
  }
 }
}
```

Comms. gérées par threads explicites

CentraleSupélec

MatrixProduct en MPI + OpenMP

Programmation synchrone : exemple 1 avec le kernel 1

Calcul et circulation de As[…]

```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {
  // rmk: omp_get_thread_num() → thread Id.
  //      omp_get_num_threads()→ current number of threads
  ligDebTh = ……; nbLigTh = ……        // Compute a
  cblas_dgemm(…,nbLigTh,…,           // sub-slice of C
              &As[ligDebTh][0],…,
              &Bs[0][0],…,
              &Cs[ligDebTh][0],…);
  #pragma omp barrier                // Sync. all threads
  #pragma omp single {
    MPI_sendrecv_replace(As,…);      // MPI exchange of As
  }
 }
}
```

Comms. gérées par threads explicites

CentraleSupélec

MatrixProduct en MPI + OpenMP

Prog. asynchrone et overlapped : exemple 2 – avec le kernel 1

Circulation de As[…] et calcul à partir de As[…]

```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {


  if (omp_get_thread_num() == 0)     // 1 thread:
    MPI_sendrecv_replace(As,…);      //  MPI exchange of As
  } else {                           // n-1 threads:
    // rmk: omp_get_thread_num() → thread Id.
    //      omp_get_num_threads()→ current number of threads
    ligDebTh = ……; nbLigTh = ……      //  Compute a sub-slice
    cblas_dgemm(…,nbLigTh,…,&As[ligDebTh][0],…);  // of Cs
  }

 }
}
```

Comms. gérées par threads explicites

MatrixProduct en MPI + OpenMP

Prog. asynchrone et overlapped : exemple 2 – avec le kernel 1

Circulation de As[…] et calcul à partir de As[…]

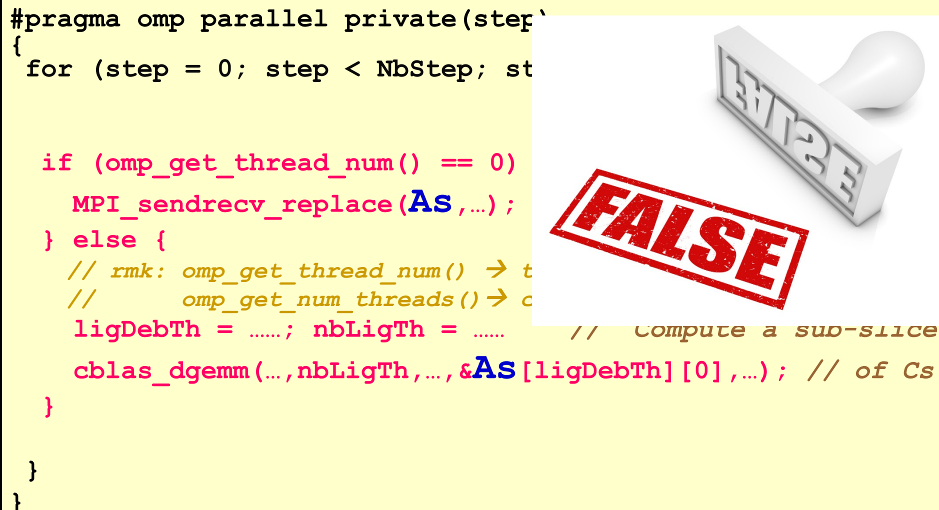


```
#pragma omp parallel private(step
{
 for (step = 0; step < NbStep; st

  if (omp_get_thread_num() == 0)
    MPI_sendrecv_replace(As,…);
  } else {
    // rmk: omp_get_thread_num() → t
    //      omp_get_num_threads()→ c
    ligDebTh = ……; nbLigTh = ……      // Compute a sub-slice
    cblas_dgemm(…,nbLigTh,…,&As[ligDebTh][0],…); // of Cs
  }

 }
}
```

Comms. gérées par threads explicites

MatrixProduct en MPI + OpenMP

Prog. asynchrone et overlapped : exemple 2 – avec le kernel 1

Circulation de As[…] et calcul à partir de AsBuf[...]

```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {
  #pragma omp single                 // Saving As into AsBuf
  {memcpy(AsBuf,As,…);}
  if (omp_get_thread_num() == 0)     // 1 thread:
    MPI_sendrecv_replace(As,…);      //  MPI exchange of A
  } else {                           // n-1 threads:
    // rmk: omp_get_thread_num() → thread Id.
    //      omp_get_num_threads()→ current number of threads
    ligDebTh = ……; nbLigTh = ……      // Compute a sub-slice
    cblas_dgemm(…,nbLigTh,…,&AsBuf[ligDebTh][0],…);//of Cs
  }

 }
}
```

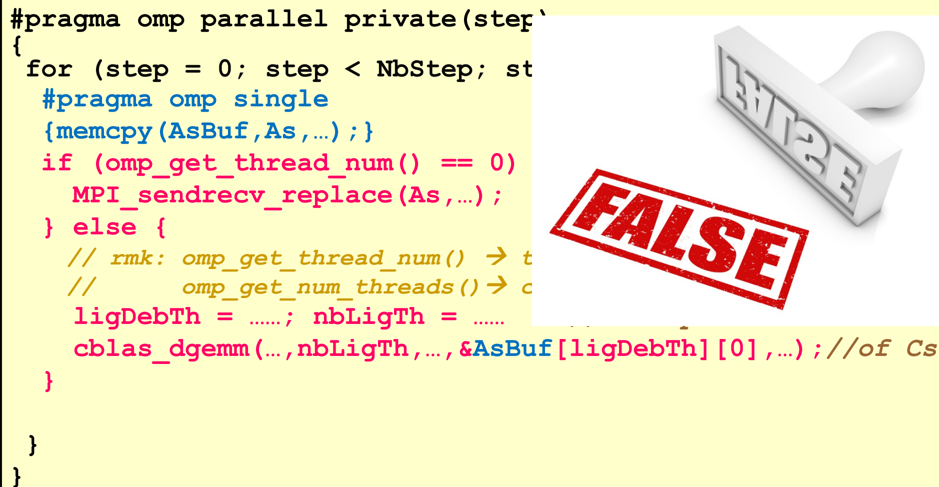
Comms. gérées par threads explicites
MatrixProduct en MPI + OpenMP
Prog. asynchrone et overlapped : exemple 2 – avec le kernel 1
Circulation de As[…] et calcul à partir de AsBuf[...]
#pragma omp parallel private(step
{
for (step = 0; step < NbStep; st
#pragma omp single
{memcpy(AsBuf,As,…);}
if (omp_get_thread_num() == 0)
MPI_sendrecv_replace(As,…);
} else {
// rmk: omp_get_thread_num() → t
// omp_get_num_threads()→ c
ligDebTh = ……; nbLigTh = ……
cblas_dgemm(…,nbLigTh,…,&AsBuf[ligDebTh][0],…);//of Cs
}
}
}
FALSE

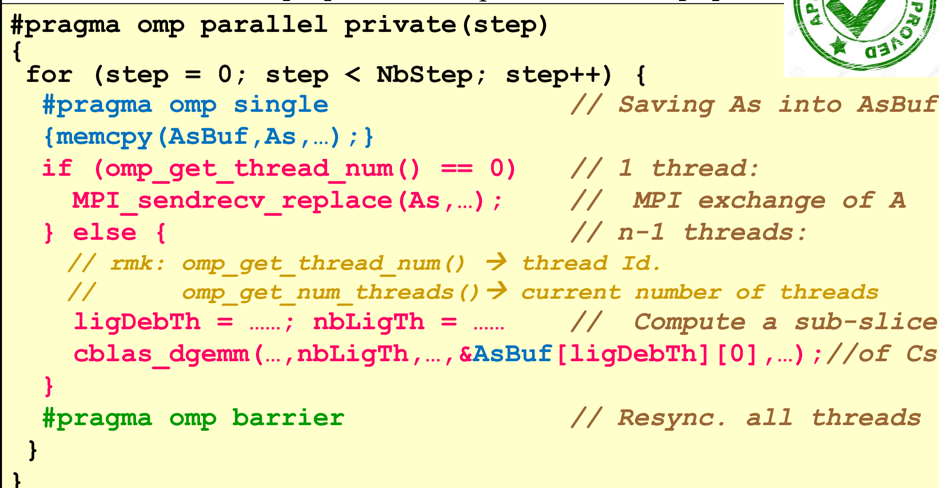
Comms. gérées par threads explicites
MatrixProduct en MPI + OpenMP
Prog. asynchrone et overlapped : exemple 2 – avec le ker
Circulation de As[…] et calcul à partir de AsBuf[...]
APPROVED
#pragma omp parallel private(step)
{
for (step = 0; step < NbStep; step++) {
#pragma omp single // Saving As into AsBuf
{memcpy(AsBuf,As,…);}
if (omp_get_thread_num() == 0) // 1 thread:
MPI_sendrecv_replace(As,…); // MPI exchange of A
} else { // n-1 threads:
// rmk: omp_get_thread_num() → thread Id.
// omp_get_num_threads()→ current number of threads
ligDebTh = ……; nbLigTh = …… // Compute a sub-slice
cblas_dgemm(…,nbLigTh,…,&AsBuf[ligDebTh][0],…);//of Cs
}
#pragma omp barrier // Resync. all threads
}
}

Comms. gérées par threads explicites

MatrixProduct en MPI + OpenMP

Prog. asynchrone et overlapped : exemple 2 – avec le kernel 0

Circulation de As[…] et calcul à partir de AsBuf[...]

```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {
  #pragma omp single                        // Saving As into AsBuf
  {memcpy(AsBuf,As,…);}
  if (omp_get_thread_num() == 0)     // 1 thread:
    MPI_sendrecv_replace(As,…);      //  MPI exchange of A
  } else {                           // n-1 threads:
    // rmk: omp_get_thread_num() → thread Id.
    //      omp_get_num_threads()→ current number of threads
    ligDebTh = ……; nbLigTh = ……      //  Compute a sub-slice
    for (i = ligDebTh; i < ligDebTh + nbLigTh; i++)//of Cs
      for (j… )
        for (k… )
          Cs[i][j] += AsBuf[i][k]*TBs[k][j];    // Bs[j][k]
  }
  #pragma omp barrier                // Resync. all threads
 }
}
```

Comms. gérées par threads explicites

MatrixProduct en MPI + OpenMP

Prog. asynchrone et overlapped : VARIANTE ex 2 avec le kernel 1

Circulation de As[…] et calcul à partir de AsBuf[...]

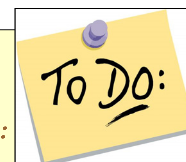


```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {
  if (omp_get_thread_num() == 0)     // 1 thread:
    … // MPI comm. : send As, recv AsBuf
  } else {                           // n-1 threads:
    // rmk: omp_get_thread_num() → thread Id.
    //      omp_get_num_threads()→ current number of threads
    ligDebTh = ……; nbLigTh = ……      //   Compute on As
    cblas_dgemm(…,nbLigTh,…,&As[ligDebTh][0],…);
  }
  … // Resynchronize all threads if needed
  … // Management of As and AsBuf arrays (As ←→ AsBuf)
 }
}
```

Comms. gérées par threads explicites

MatrixProduct en MPI + OpenMP

Prog. asynchrone et overlapped : ex 3 – avec *section* et *task*, kernel 0

Circulation de As[…] et calcul à partir de AsBuf[…]

```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {
  #pragma omp single                    // Saving As into
  {memcpy(AsBuf,As,…);}                 // AsBuf

  #pragma omp sections
  {
    #pragma omp section                 // MPI exchange of A
    {MPI_sendrecv_replace(A,…);}        // (one thread)

    #pragma omp section                 // Computation on Abuf
    {… AsBuf …}                         // (on one thread)
  }


}
```

Comms. gérées par threads explicites

MatrixProduct en MPI + OpenMP

Prog. asynchrone et overlapped : ex 3 – avec *section* et *task*, kernel 0

Circulation de As[…] et calcul à partir de AsBuf[…]

```
#pragma omp parallel private(step)
{
 for (step = 0; step < NbStep; step++) {
  #pragma omp single                    // Saving As
  {memcpy(AsBuf,As,…);}                 // AsBuf

  #pragma omp sections
  {
    #pragma omp section                 // MPI exchange of As
    {MPI_sendrecv_replace(As,…);}       // (one thread)

    #pragma omp section                 // Computation on
    {…                                  // AsBuf
     for (i = 0; i < nbLigSlice; i++)
     #pragma omp task {… AsBuf …}       // (on all available
    }                                   //  threads)
  }
 }
}
```

CentraleSupélec

MPI-1 : communications asynchrones et recouvrement …

4 – Performances expérimentales du recouvrement calculs/communications

CentraleSupélec

Performances expérimentales

Perf. produit de matrices sur anneau

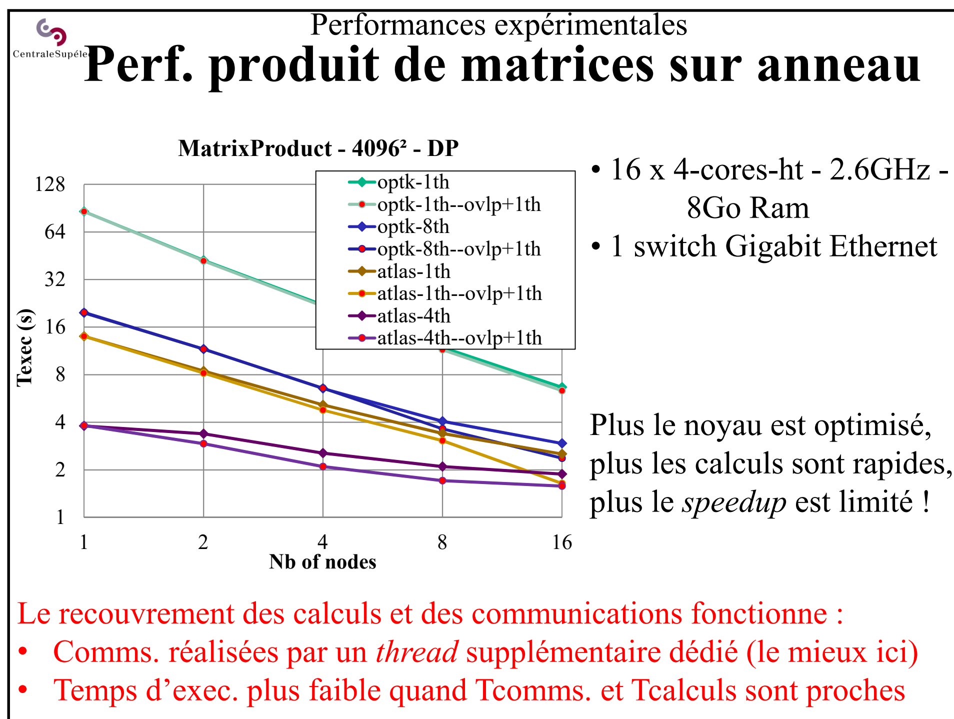

- 16 x 4-cores-ht - 2.6GHz - 8Go Ram
- 1 switch Gigabit Ethernet

Plus le noyau est optimisé, plus les calculs sont rapides, plus le *speedup* est limité !

Le recouvrement des calculs et des communications fonctionne :

- Comms. réalisées par un *thread* supplémentaire dédié (le mieux ici)
- Temps d'exec. plus faible quand Tcomms. et Tcalculs sont proches

Performances expérimentales

Perf. produit de matrices sur anneau

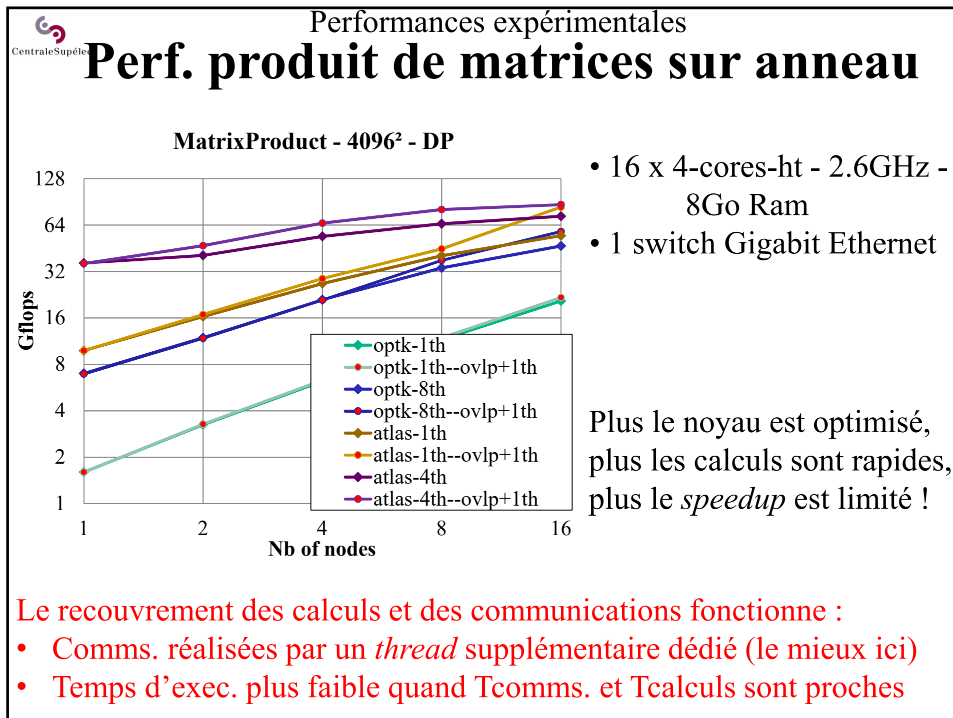

- 16 x 4-cores-ht - 2.6GHz - 8Go Ram
- 1 switch Gigabit Ethernet

Plus le noyau est optimisé, plus les calculs sont rapides, plus le *speedup* est limité !

Le recouvrement des calculs et des communications fonctionne :

- Comms. réalisées par un *thread* supplémentaire dédié (le mieux ici)
- Temps d'exec. plus faible quand Tcomms. et Tcalculs sont proches

→ TP

CentraleSupélec

TP : produit de matrices avec recouvrement calculs/comms.

Même schéma initial de circulation des données (en P étapes)

Même opération : C = A × B

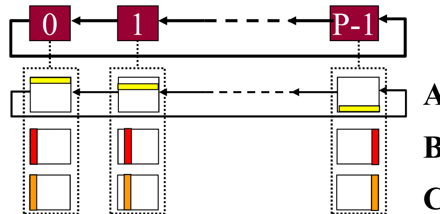

Faire circuler A en parallèle des calculs de l'étape :

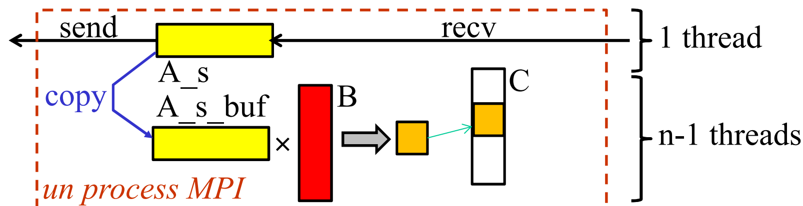

CentraleSupélec

MPI-1: communications asynchrones et recouvrement calculs/communications

Questions ?