Programmation Parallèle en Mémoire Partagée

Sophie Robert

UFR ST Département Informatique

Dernier cours

OpenMP

- Vue d'ensemble, modèle de programmation
- Régions parallèles
- Sections critiques, atomiques
- Construction collaboratives : boucle for, réduction
- Synchronisation : barrières, master, single
- Attribut sur le partage des données : shared, private, firstprivate, lastprivate
- Ordonnancement

OpenMP ce n'est pas fini

OpenMP 2 suite et fin

- Modèle mémoire
- Nouvelle construction : collaboration
- Les verrous

OpenMP 3

- Tâches

Quelques éléments OpenMP4

- Gestion de plus bas niveau

Retour sur la concurrence

```
#include <iostream>
#include <omp.h>
using namespace std;
int main(int argc, char** argv) {
    int compteur = 0;
    int N = atoi(argv[1]);

    int nbthreads=omp_get_max_threads();
    #pragma omp parallel
    {
        for (int i = 0; i < N; ++i)
            compteur++; //race condition
    }
    cout << "attendu : " <<  nbthreads*N << endl;
    cout << "obtenu : " << compteur << endl;
    return 0;
}
```

Modèle mémoire

Mémoire partagée mais ...

- OpenMP propose un modèle à mémoire partagée (SMP - Symmetric shared Memory MultiProcessor).
- Mais les processeurs (matériels) peuvent avoir leur propre mémoire locale rapide (les registres, les caches)
- Si un thread met à jour des données partagées, la nouvelle valeur sera sauvegardée dans un registre, puis stockée dans un cache local
- La mise à jour n'est pas obligatoirement visible immédiatement par les autres threads !

Directive flush

Cohérence avec la mémoire

La directive `flush` permet de rendre la vue temporaire d'un thread d'une valeur partagée cohérente avec la valeur en mémoire.

Directive

```
#pragma omp flush(list)
```

Interprétation

- Les variables visibles par les threads sont écrites en mémoire après ce point.
- S'il y a des pointeurs dans la liste, seul le pointeur est copié et pas la valeur pointée.

Directive flush producteur consommateur

```
int main() {
  int flag = 0;
  int data = 0;
  int result = 0;
  #pragma omp parallel
  {
    int id = omp_get_thread_num();
    if (id == 0) {
      usleep(100); // charge du producteur
      data = 10;
      flag = 1;
    } else {
       if (flag==1)
          result = data * 2; // partie consommateur
       std::cout << << data << result << std::endl;
    }
  }
```

Directive flush producteur consommateur

```
int main() {
  int flag = 0;
  int data = 0;
  int result = 0;
  #pragma omp parallel
  {
    int id = omp_get_thread_num();
    if (id == 0) {
      usleep(100000); // charge du producteur
      data = 10;
      flag = 1;
    } else {
       if (flag==1)
          result = data * 2; // partie consommateur
       std::cout << << data << result << std::endl;
    }
  }
```

Directive flush producteur consommateur

```
#pragma omp parallel
{
 int id = omp_get_thread_num();
 if (id == 0) {
   usleep(100000);
   data = 10;
   flag = 1;
   #pragma omp flush(flag,data)
 } else {
   while (flag == 0) {
     #pragma omp flush(flag)
   }
   #pragma omp flush(data)
   result = data * 2;
   std::cout << << data << result << std::endl;
 }
}
```

Sections

Construction collaboration

La directive `sections` donne un bloc structuré à chaque thread.

- Elle permet de découper un travail constitué de parties indépendantes
- Chaque partie sera réalisée par un thread qui peut éventuellement créer une région parallèle

Sections principe général

```
#pragma omp parallel
{
  #pragma omp sections
  {
    #pragma omp section
    {
      x_calculation();
    }
    #pragma omp section
    {
      y_calculation();
    }
    #pragma omp section
    {
      z_calculation();
    }
  }
}
```

La synchronisation 

barrière / nowait

- Par défaut il y a une barrière à la fin de la construction `omp sections`.
- La clause nowait permet de retirer la barrière implicite.

construction sections exemple

```
int main() {
 int nb = 1000000;
 std::vector<int> temperatures = mesures(nb);
 double moyenne = 0.0;
 int maximum = 0;
 int nb_critique = 0;
 #pragma omp parallel sections
  {
    #pragma omp section
     {
       long somme = 0;
       for (int t : temperatures) somme += t;
        moyenne = static_cast<double>(somme) / nb;
      }
```

construction sections exemple

```
#pragma omp section
  {
   int max_val = 0;
   for (int t : temperatures) if (t > max_val)
    max_val = t;
     maximum = max_val;
   }
#pragma omp section
   {
    int compteur = 0;
    for (int t : temperatures) if (t > 30) compteur
    ++;
      nb_critique = compteur;
   }
  } // fin sections
```

construction sections exemple

```
    double proportion_critique = (nb_critique) / nb;
    double score_risque = 0.5 * moyenne + 0.3 *
     maximum + 50 * proportion_critique;
    if (score_risque > 100) score_risque = 100;
    cout << score_risque << " / 100" << endl;
    return 0;

}
```

sections et parallélisme imbriquée

```
#pragma omp parallel sections
{
 #pragma omp section
 {
  #pragma omp parallel for reduction(+:somme)
    num_threads(4)
   for (size_t i=0; i<temperatures.size(); i++)
      somme += temperatures[i];
   moyenne = static_cast<double>(somme) / nb;
 }
//.....................
}
```

Attention

Il est nécessaire d'autoriser des régions parallèles imbriquées

```
    omp_set_nested(1);
```

Retour sur l'exemple producteur-consommateur

```
#define N 100000
int main(){
 double *A, sum;
 int flag = 0;
 A = new double[N];

 fill_rand(N, A); // Producteur

 sum = Sum_array(N, A);  // Consommateur

 return 0;
}
```

Le pattern producteur-consommateur

```
int main(){
double* A, sum; int numthreads, flag = 0;
A = new double[N];
#pragma omp parallel sections
{
  #pragma omp section // Partie producteur
  {
    fill_rand(N, A);
    #pragma omp flush
    flag = 1;
    #pragma omp flush (flag)
  }
```

Le pattern producteur-consommateur

```
    #pragma omp section // Partie consommateur
    {
      #pragma omp flush (flag)
      while (flag != 1)
        #pragma omp flush (flag)
      #pragma omp flush
      sum = Sum_array(N, A);
    }
}
```

Sections

Conseils

- la directive de collaboration `sections` est adapté à des algorithmes producteur/consommateur.
- Toujours préférer une directive de type omp parallel for si c'est possible
- Réserver les `sections` à du travail clairement découpé en parties indépendantes
- et ... (à suivre)

Les verrous en OpenMP

Verrous simples

- `omp_lock_t` : Type d'un verrou simple
- `omp_init_lock()` : Pour initialiser un verrou simple
- `omp_set_lock()` : Pour prendre le verrou
- `omp_unset_lock()` : Pour libérer le verrou
- `omp_test_lock()` : Pour tester si le verrou est utilisé ou pas et prendre le verrou s'il est libre
- `omp_destroy_lock()` : Pour détruire le verrou

fonctionnement

- Le verrou est disponible s'il est unset.
- La fonction de verrouillage est bloquante.

Les verrous en OpenMP

Barrière mémoire

- Un verrouillage implique une barrière mémoire (*memory fence*) de toutes les variables visibles par le thread (équivalent à un *flush* de toutes les variables).
- Un thread accède toujours à la copie la plus récente d'un verrou. Pas besoin d'utiliser un `flush` sur la variable verrou.

Premier exemple

```
#define taille 1000000
int main() {
  omp_lock_t lck;
  int cpt1=0;
  int cpt_total=0;
  omp_init_lock(&lck);
#pragma omp parallel shared(lck) firstprivate(cpt1)
  {
   #pragma omp for
    for (int i=0; i<taille; i++) {
      if (i%2==0)
        cpt1++; }
    omp_set_lock(&lck);
    cpt_total+=cpt1;
    omp_unset_lock(&lck);
  }
  omp_destroy_lock(&lck);
```

Exemple sans critical

```
omp_lock_t global_lock;  //!!!!
double somme_globale = 0.0;
int compteur_global = 0;

void ajout_valeur(double x) {
    omp_set_lock(&global_lock);
    somme_globale += x;
    compteur_global++;
    omp_unset_lock(&global_lock);
}
void traitement_partiel(int id, int n) {
    for (int i = 0; i < n; ++i) {
        double val = sin(id + i * 0.001);
        if (val > 0.5)
            ajout_valeur(val);
    }
}
```

Exemple sans critical (suite)

```
int main() {
    omp_init_lock(&global_lock);
#pragma omp parallel
    {
        int id = omp_get_thread_num();
        traitement_partiel(id, 10000);
    }
    omp_destroy_lock(&global_lock);
    double moyenne = somme_globale /
   compteur_global;
    return 0;
}
```

Exemple sans critical (suite)

```
void skip(int id);
void work(int id) ;
int main() {
  omp_lock_t lck;
  int id;
  omp_init_lock(&lck);
#pragma omp parallel shared(lck) private(id)
  {
    id = omp_get_thread_num();
    if (omp_test_lock(&lck)) {
      skip(id);
      omp_unset_lock(&lck);
    }
    work(id);
  }
  omp_destroy_lock(&lck);
  return 0;
```

Encore OpenMP 2 : La clause threadprivate

`threadprivate`

Rend une variable privée et la préserve pour chaque thread.

différence avec `private`

- Clause `private` : la variable globale est masquée
- Clause `threadprivate` : la portée globale de la variable est préservée pour chaque thread.

Exemple

```
#include <omp.h>
#include <stdio.h>

int x = 42;

int main(){

  #pragma omp parallel
  {
    x = omp_get_thread_num();
  }

  #pragma omp parallel
  {
    printf("%d\n", x);
  }
}
```

Résultat

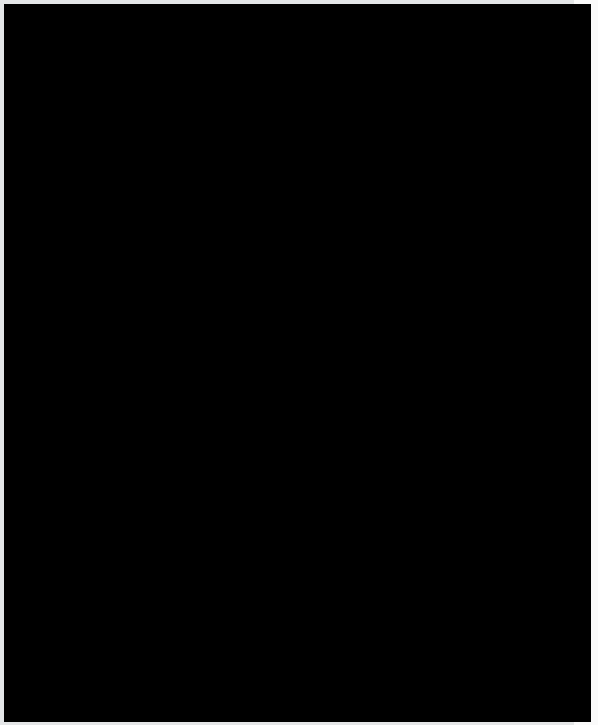

Exemple

```
#include <omp.h>
#include <stdio.h>

int x = 42;

int main(){

  #pragma omp parallel
  {
    x = omp_get_thread_num();
  }

  #pragma omp parallel
  {
    printf("%d\n", x);
  }
}
```

Résultat

```
6
6
6
6
6
6
6
6
```

Exemple

```c
#include <omp.h>
#include <stdio.h>

int x = 42;

int main(){
   #pragma omp parallel private(x
    )
    {
      x = omp_get_thread_num();
    }

    #pragma omp parallel
    {
      printf("%d\n", x);
    }
 }
```

Résultat

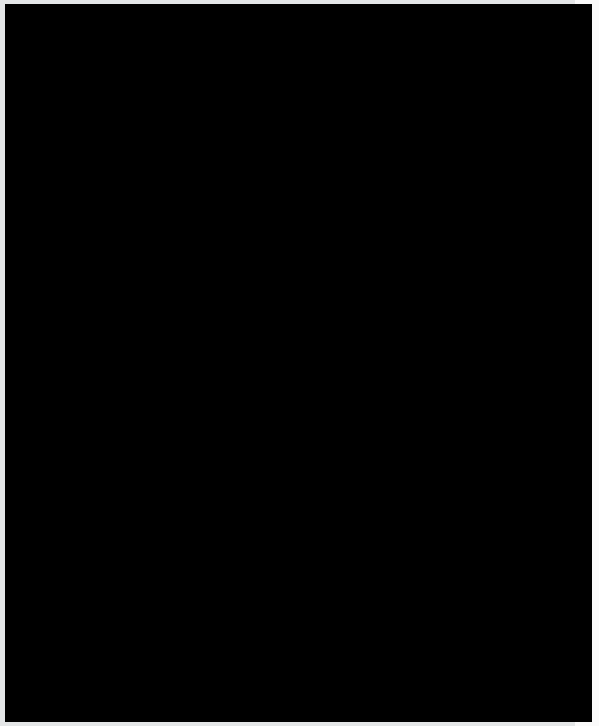

Exemple

```
#include <omp.h>
#include <stdio.h>

int x = 42;

int main(){
   #pragma omp parallel private(x
    )
    {
      x = omp_get_thread_num();
    }

    #pragma omp parallel
    {
      printf("%d\n", x);
    }
 }
```

Résultat

```
42
42
42
42
42
42
42
42
```

Exemple

```
#include <omp.h>
#include <stdio.h>

int x = 42;

int main(){

  #pragma omp parallel private(
   x)
  {
    x = omp_get_thread_num();
  }

  #pragma omp parallel private(
   x)
  {
    printf("%d\n", x);
```

Résultat

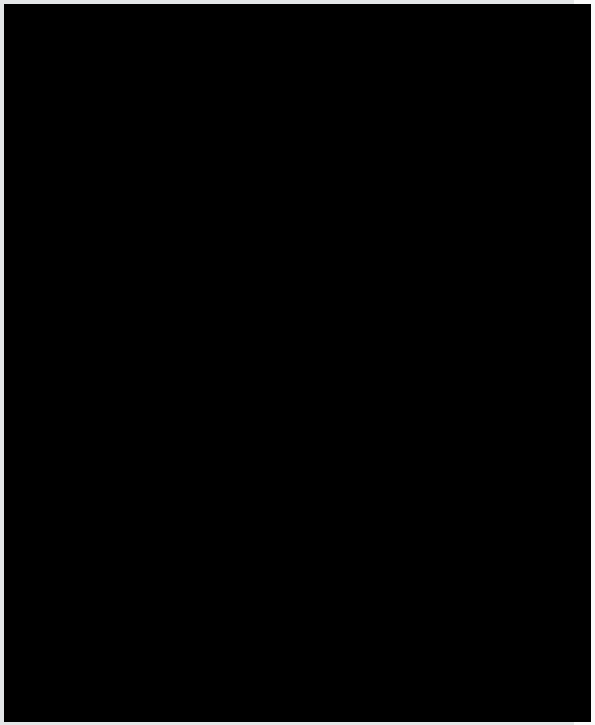

Exemple

```
#include <omp.h>
#include <stdio.h>

int x = 42;

int main(){

  #pragma omp parallel private(
   x)
  {
    x = omp_get_thread_num();
  }

  #pragma omp parallel private(
   x)
  {
    printf("%d\n", x);
```

Résultat

```
0
0
0
0
0
0
0
0
```

Exemple

```
#include <omp.h>
#include <stdio.h>

int x = 42;
#pragma omp threadprivate(x)

int main(){

#pragma omp parallel
    {
      x = omp_get_thread_num();
    }
#pragma omp parallel
    {
      printf("%d\n", x);
    }
}
```

Résultat

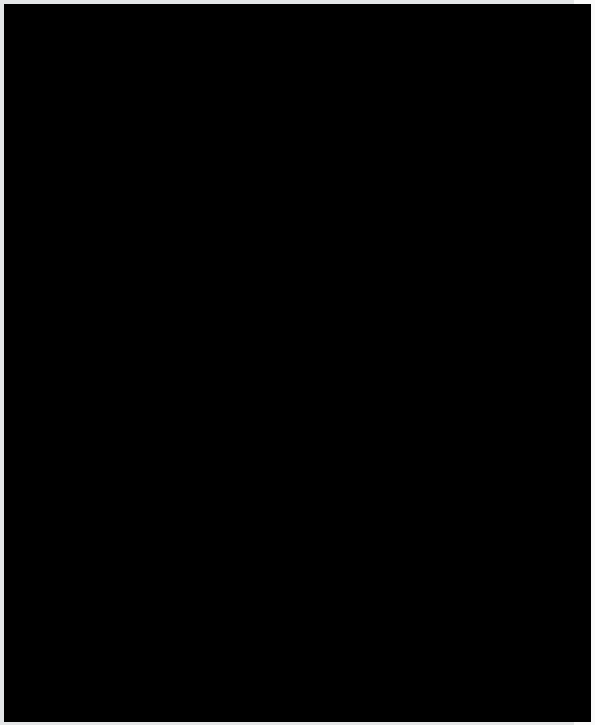

Exemple

```
#include <omp.h>
#include <stdio.h>

int x = 42;
#pragma omp threadprivate(x)

int main(){

#pragma omp parallel
    {
      x = omp_get_thread_num();
    }
#pragma omp parallel
    {
      printf("%d\n", x);
    }
}
```

Résultat

```
4
7
0
1
3
5
6
2
```

Quelques limites d'OpenMP 2

Structure de données liste

```
class noeud {
private:
    int val;
    noeud* suivant;
public:
    noeud(int _val);
    noeud* next();
    void traiter();
};
class liste {
private:
    noeud* tete;
};
```

Quelques limites d'OpenMP 2

Parcours de liste 

```
int main(int argc, char* argv[]) {
  liste *l = new liste();
  noeud *n;
  for (n = l->get_tete(); n != NULL; n = n->next())
     n->traiter();
  return 0;
}
```

Quelques limites d'OpenMP 2

Première solution 

```
#pragma omp parallel
    {
     noeud *n;
     for (n=l->get_tete(); n!=NULL; n=n->next()) {
     #pragma omp single nowait
          n->traiter();
     }
    }
```

Quelques limites d'OpenMP 2

Limites

- Peu naturel
- Mauvaises performances
- Pas composable

Quelques limites d'OpenMP 2

Structure de données de type arbre

```
class noeud {
private:
    int val;
    noeud* gauche;
    noeud* droit;
public:
    noeud(int _val);
    noeud* a_gauche();
    noeud* a_droite();
    void traitement();
};
class arbre {
private:
    arbre* racine;
};
```

Quelques limites d'OpenMP 2

Parcours séquentiel

```
void noeud::traitement() {
    if (this->gauche != NULL) gauche->traitement();
    if (this->droit != NULL) droit->traitement();
    if (val % 2 == 0)
        val++;
    else
        val += 2;
}
```

Quelques limites d'OpenMP 2

Parcours parallèle 

```
void noeud::traitement() {
#pragma omp parallel sections
{
#pragma omp section
    if (this->gauche != NULL) gauche->traitement();
#pragma omp section
    if (this->droit != NULL) droit->traitement();
}
    if (val % 2 == 0)
        val++;
    else
        val += 2;
}
```

Quelques limites d'OpenMP 2

Limites

- Trop de régions parallèles : surcoûts, synchronisations supplémentaires
- Pas toujours bien supporté par l'implémentation

OpenMP 3.0 - OpenMP Tasks

Une nouvelle directive task

```
#pragma omp parallel
{
    #pragma omp single nowait
    {
        #pragma omp task [clauses]
        {
            // code Task 1
        }

        #pragma omp task [clauses]
        {
            // code Task 2
        }
    }
}
```

OpenMP 3.0 - OpenMP Tasks

Comment fonctionne un tâche/task

- Chaque thread qui rencontre la directive task crée une tâche
- l'exécution par un des threads de l'équipe créé pour la région parallèle est immédiate ou différée.
- directive hautement composable : imbrication possible dans
  - des régions parallèles
  - d'autres tâches
  - des directives `omp for`, `omp sections`, `omp single`

Caractéristiques générales des tâches

Une tâche a

- du code à exécuter
- un environnement de données propre
  - Variable locales de la tâche
- un thread de l'équipe qui exécute le code à un moment ultérieur

Deux activités : *packaging* et exécution

- Chaque thread rencontrant la construction `task` *package* une nouvelle instance de tâche (code + données)
- Un thread libre de l'équipe exécute la tâche à un moment ultérieur (planification dynamique)

OpenMP Tasks

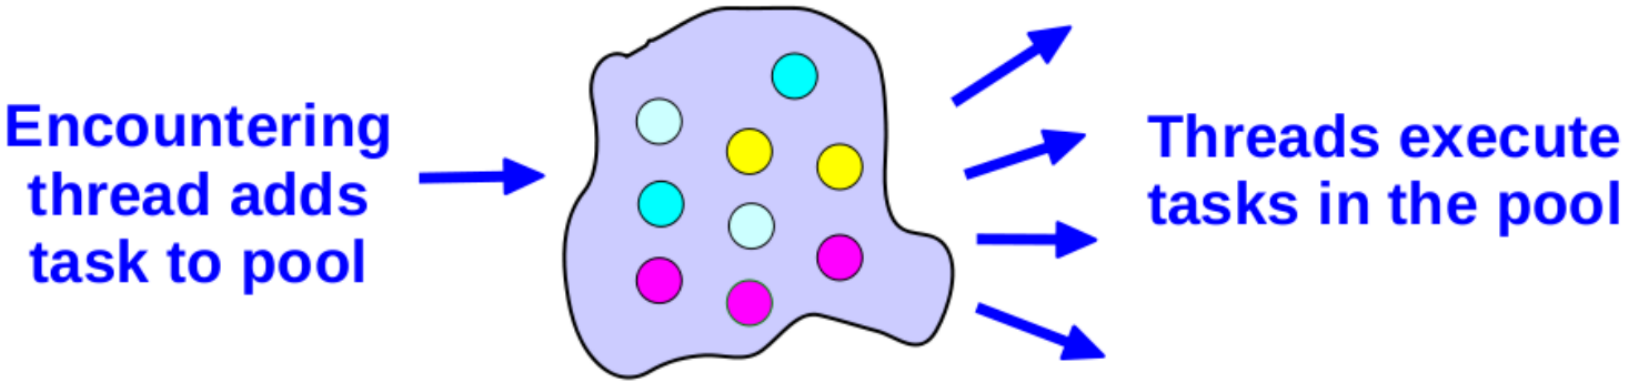

Developer specifies tasks in application
Run-time system executes tasks

(An Overview of OpenMP 3.0, R. van der Pas, IWOMP2009)

Tâches dans OpenMP 3.

OpenMP a toujours eu des tâches

Elles avaient juste un autre nom. Le thread rencontrant une construction `parallel` *package* un ensemble de tâches implicites, une par thread

1. Une équipe de thread est créée
2. Chaque thread de l'équipe est assigné à une tâche et est lié (`tied`) à elle
3. Une barrière retient le thread maître original jusqu'à ce que toutes les tâches implicites soient terminées.

Tâches dans OpenMP 3.

OpenMP a toujours eu des tâches

4. OpenMP 3.0 ajoute simplement une manière de créer explicitement une tâche à faire exécuter par une équipe de threads
5. Toute partie d'un programme OpenMP fait partie d'une tâche ! ! !

Construction `task`

```
#pragma omp task [clause[[,]clause] ...]
```

Les clauses

- `if (expression)`
- `untied`
- `shared (list)`
- `private (list)`
- `firstprivate (list)`
- `default( shared | none)`

Comment utiliser la directive task ?

```
void noeud::traitement() {
#pragma omp parallel
 {
  int id = omp_get_thread_num();
  int nthreads = omp_get_num_threads();
#pragma omp single nowait
  {
#pragma omp task
   if (this->gauche != NULL) gauche->traitement();
#pragma omp task
   if (this->droit != NULL) droit->traitement();
  }
 }
 if (val % 2 == 0)
   val++;
 else
   val += 2;
}
```

La clause `if`

Lorsque l'argument de la clause `if` est faux

- La tâche est exécutée directement par le thread rencontrant la construction `task`
- L'environnement de données reste local à la tâche (variables privées copiées si nécessaires)
- La tâche est toujours considérée distincte pour la synchronisation

Utilité / Optimisation

- Éviter de créer des tâches trop petites (coût de création vs coût d'exécution)
- Contrôler le cache et l'affinité mémoire (les données sont déjà locales)

La clause `untied`

Optimisation

- Par défaut les tâches sont liées
  - Une tâche liée est toujours exécutée par le même thread
- Performance/ordonnancement parfois non optimale
  - Séquentialité
  - Parcours récursifs -> déséquilibrage de charge possible
- Avec la clause `untied` la tâche peut être exécutée par n'importe quel thread libre mais il faut éviter
  - les variables `threadprivate`
  - l'utilisation de l'indice du thread

  et faire très attention aux verrous et sections critiques car des interblocages sont possibles.

Task switching

Définition

- Certaines constructions contiennent des points d'ordonnancement de tâches à des positions définies
- Lorsqu'un thread rencontre l'un de ces points, il est autorisé à suspendre la tâche courante et en exécuter une autre. C'est du **task switching**.
- Il peut ensuite revenir à la tâche d'origine et la reprendre

Revoir l'exemple sur les arbres

Exemple de *task switching*

les tâches sont tied

```
#pragma omp single
{
  for (i=0; i<ONEZILLION; i++)
  #pragma omp task
   process(item[i]);
}
```

Interprétation

- Trop de tâches sont générées en un clin d'œil

Exemple de *task switching*

Les tâches sont **untied**

```
#pragma omp single
{
  for (i=0; i<ONEZILLION; i++)
  #pragma omp task untied
  process(item[i]);
}
```

Interprétation

- La génération de tâches peut être suspendue temporairement
- Grâce au *task switching*, le thread courant peut :
  - exécuter une tâche déjà générée dans le pool
- Cela améliore l'équilibrage et le parallélisme

Synchronisation pour les tâches

Quand/où les tâches se terminent ?

- Aux barrières de threads explicites ou implicites
  - S'applique à toutes les tâches générées dans la région `parallel` courante jusqu'à la barrière.
- Aux barrières de tâches
  - Attend que toutes les tâches définies dans la tâche courante se terminent

```
#pragma omp taskwait
```

  - **Attention :** s'applique uniquement aux tâches créées dans la tâche courante, pas à celles créées par ses descendants !

Quelques exemples - 1. Fibonacci

```
// La parallel region avant l'appel de la fonction
long fibonacci(long n) {
  long x, y;
  if (n<2)
    return n;
  else {
#pragma omp task untied shared(x) firstprivate(n)
      x=fibonacci(n-1);

#pragma omp task untied shared(y) firstprivate(n)
      y=fibonacci(n-2);

#pragma omp taskwait
      return x+y;
  }
}
```

Quelques exemples

Produit de matrices 

- Tasks ou parallel for ?

Parcours de liste 

```
int main(int argc, char* argv[]) {
    liste *l = new liste(); ......
    noeud *n;
    for (n = l->get_tete(); n != NULL; n = n->next
   ())
       n->traiter();
    return 0;
}
```

Parcours de liste avec des tasks

```
int main(int argc, char* argv[]) {
    liste *l = new liste(); ......
    noeud *n;
#pragma omp parallel
{
#pragma omp single private(n) nowait
    for (n = l->get_tete(); n != NULL; n = n->next
   ()) {
    #pragma omp task untied
       n->traiter();
    }
}
    return 0;
}
```

Parcours et traitement pour un arbre

```
#pragma omp parallel
  {
#pragma omp single nowait
      {
#pragma omp task
        if (this->gauche != NULL) gauche->
    traitement();
#pragma omp task
        if (this->droit != NULL) droit->traitement
    ();
      }
  }
  if (val % 2 == 0)
      val++;
  else
      val += 2;
```

Retour sur les conseils

directives for - sections - tasks

- algorithme itératif : directive for
- découper en blocs simplement : sections
- producteur / consommateur : sections
- calculs parallèles imbriqués (non itératif simple) : tasks

Remarques

- Pour la directive **sections** le parallélisme imbriqué a un surcoût dû à la création d'une nouvelle équipe à chaque `omp parallel`.
- Pour la directive **task** on réutilise l'équipe existante.

Encore quelques limitations avec OpenMP 3.

Pour les architectures parallèles à mémoire partagée (CPU multi-cœurs)

- On peut définir des régions parallèles, paralléliser l'exécution de boucles, définir et exécuter des tâches parallèles. A partir du programme séquentiel
  1. on identifie une partie coûteuse (en temps) du programme
  2. on ajoute une/plusieurs directive(s)/construction(s) OpenMP
  3. on optimise (si besoin) avec l'ajout de clauses spécifiques
  4. retour en 2

Mais...

On ne profite pas de tout le parallélisme des processeurs modernes (vectorisation)

OpenMP 4.0

Conclusion avec 2 "fonctionnalités" supplémentaires

- Dépendances de tâches
- Programmation vectorielle

Dépendances de tâches

Nouvelle clause à la construction `task`

```
depend(dependence-type: list)
```

où `dependence-type` est : `in`, `out` ou `inout`.

Motivations

- Permettre d'exprimer le parallélisme de tâches d'une manière plus déstructurée.
- Pour potentiellement réduire le nombre de synchronisations coûteuses

Dépendances de tâches

Comment exprimer les dépendances

Les dépendances sont construites dynamiquement lors de la création des tâches, en fonction de l'ordre où les tâches sont rencontrées et des variables partagées concernées.

- une tâche avec une dépendance `in:x` attend la fin de toutes les tâches avec une dépendance sur `x`.
- une tâche avec une dépendance `out/inout:x` attend la fin de toutes les tâches avec une dépendance `in/out/inout:x` qui lui précédent aient terminées
- pas de contraintes sur le contenu des tâches
- les dépendances ne sont pas des synchronisations globales, elles ne concernent que les tâches sœurs.

Exemple

```
int a = 10; // variable shared
#pragma omp task depend(in:a)
  T1
#pragma omp task depend(out:a)
  T2
#pragma omp task depend(in:a)
  T3
#pragma omp task depend(in:a)
  T4
#pragma omp task depend(inout:a)
  T5
#pragma omp task depend(in:a)
  T6
```

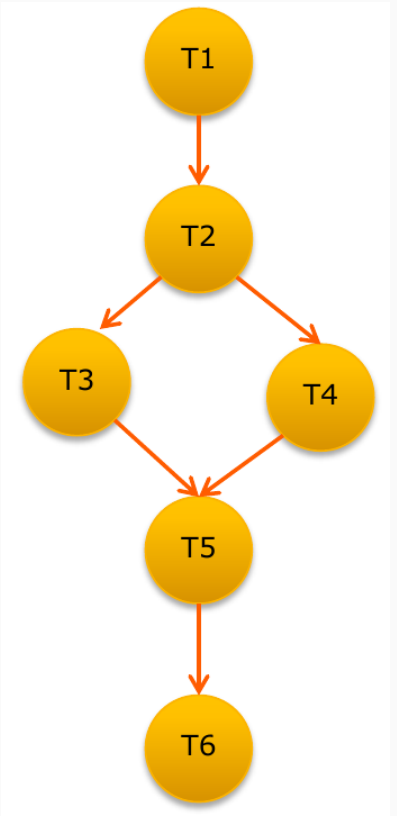

Exemple plus complexe

```
 void blocked_cholesky(int NB, float A[NB][NB]){
   int i, j, k;
   for (k = 0; k < NB; k++){
#pragma omp task depend(inout:A[k][k])
       spotrf(A[k][k]);
     for (i = k+1; i<NB; i++)
#pragma omp task depend(in:A[k][k]) depend(inout:A[k][i])
         strsm(A[k][k], A[k][i]);
       //update trailing submatrix
       for (i = k+1; i<NB; i++){
         for (j=k+1; j<i; j++)
#pragma omp task depend(in:A[k][i],A[k][j]) depend(inout:A[j
    ][i])
             sgemm(A[k][i], A[k][j], A[j][i]);
#pragma omp task depend(in:A[k][i]) depend(inout:A[i][i])
           ssyrk(A[k][i], A[i][i]);
       }
   }
 }
```

Exemple plus complexe

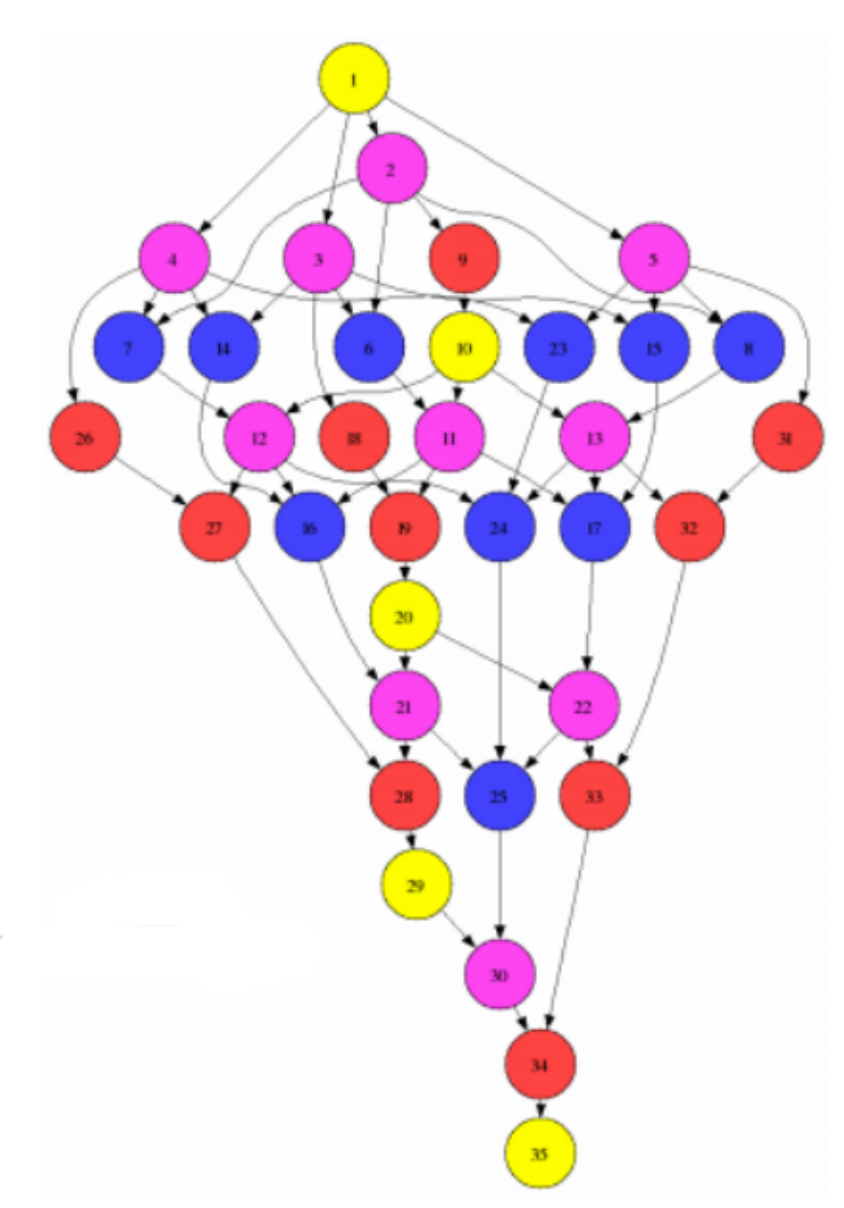

Vectorisation

Calcul scalaire

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

Addition de vecteurs

```
v3[0] = v1[0] + v2[0];
v3[1] = v1[1] + v2[1];
v3[2] = v1[2] + v2[2];
v3[3] = v1[3] + v2[3];
```

Vectorisation

Calcul vectoriel

Un processeur vectoriel applique une même instruction simultanément sur plusieurs données (un vecteur de scalaires).

Addition de vecteurs

v3 = v1 + v2 ;

Modèle SIMD

Single Instruction Multiple Data

Quelques jeux d'instructions SIMD

x86 : MMX, SSE, AVX

PowerPC : AltiVec

ARM : NEON

Vectorisation sans OpenMP 4.0

Auto vectorisation ou extensions

1. L'auto-vectorisation des compilateurs
2. Utilisation d'extensions spécifiques à chaque architecture

Copie de 4 floats avec SSE

```
#include<stdio.h>
#include<xmmintrin.h> // header pour SSE
int main() {
  float a1[4] __attribute__ ((aligned(16))) ={1.4,
   2.5, 3.6, 4.8};
  float a2[4] __attribute__ ((aligned(16)));
  __m128 v1;
  v1 = _mm_load_ps(a1);
  _mm_store_ps(a2, v1);
  return 0;
  }
```

Construction OpenMP de boucles SIMD

Une nouvelle directive `simd`

```
#pragma omp simd [clause[[,] clause],...]
suivi de la boucle for
```

Vectorise un nid de boucle

- La directive ne crée pas de threads mais
- elle exploite les registres vectoriels pour
- qu'une seule instruction traite plusieurs éléments à la fois.

Exemple

Code

```
void sprod(float *a, float *b, float *c){
  #pragma omp simd
   for (int k = 0; k<n; k++)
     c[k] = a[k] * b[k]
}
```

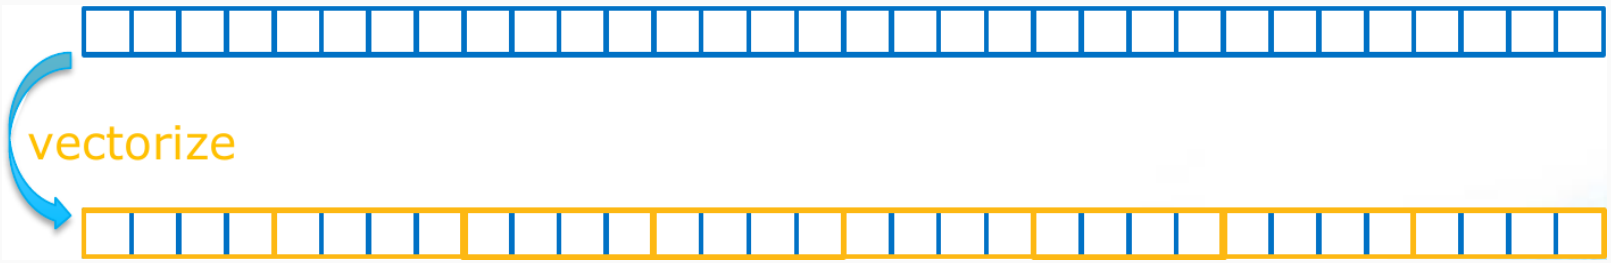

Les clauses de `simd`

`private(var-list)`

Vecteur de variables non initialisées

`reduction(op:var-list)`

Créé des variables privées pour `var-list` et applique l'opérateur de réduction op à la fin de la construction

Exemple

```
float sprod(float *a, float *b){
  float sum 0.0f;
  #pragma omp simd reduction(+:sum)
  for (int k = 0; k<n; k++)
    sum+=a[k] * b[k]
}
```

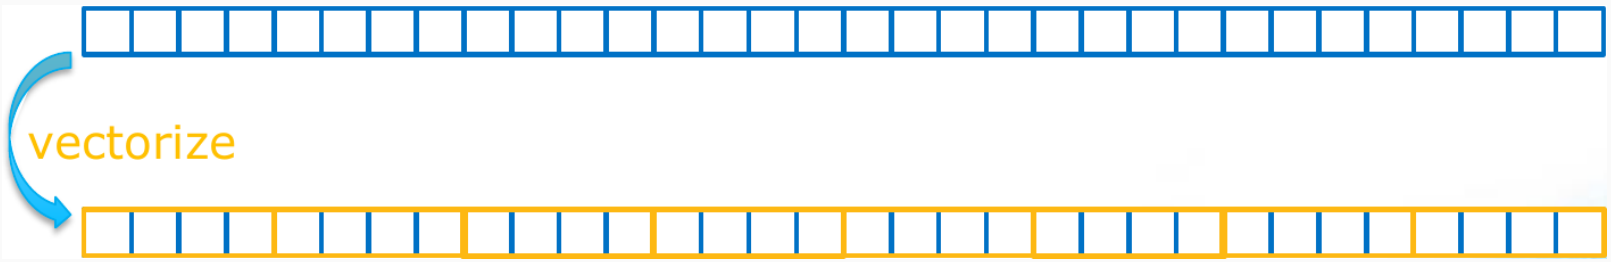

Les clauses de `simd`

`safelen(length)`

- Nombre maximum d'itérations qui peuvent s'exécuter en concurrence sans problème de dépendances
- En pratique, taille maximum d'un vecteur

Exemple

```
for (int i=m; i<n; i++)
      b[i]=b[i-m]-1.0f;
```

```
#pragma omp simd safelen(m)
for (int i=m; i<n; i++)
      b[i]=b[i-m]-1.0f;
```

Les clauses de `simd`

`linear(list[:linear-step])`

Pour utiliser également la vectorisation pour gérer l'indice de boucle.

Exemple

- `linear(i:1)`

- `linear(i:2)`

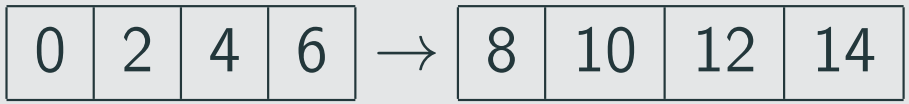

Construction *worksharing* SIMD

Parallélise ET vectorise un nid de boucle

- Distribue l'espace d'itération d'une boucle à travers une équipe de threads
- Subdivise des morceaux de boucle (d'itérations) pour tenir dans un registre vectoriel SIMD

Syntaxe

```
    #pragma omp for simd [clause[[,] clause
] ,...]
    boucle for
```

Exemple

```
void sprod(float *a, float *b, float *c){
  float sum 0.0f;
  #pragma omp parallel for simd reduction(+:
sum)
  for (int k = 0; k<n; k++)
    sum += a[k] * b[k]
  return sum;
}
```

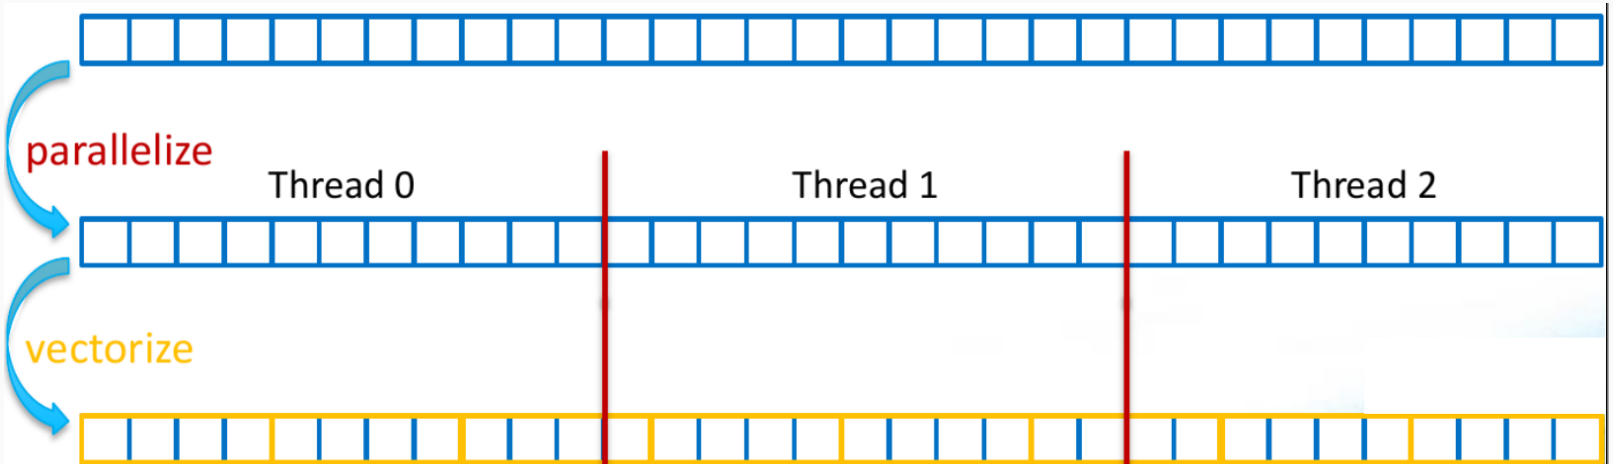

SIMD : vectorisation de fonctions

```
float min(float a, float b){
  return a<b ? a : b;
}
```

```
float distsq(float x, float y){
  return (x-y)*(x-y);
}
```

```
void example(){
  #pragma omp parallel for simd
  for   (i = 0; i < n; i++){
    d[i] = min (distsq(a[i], b[i]), c[i]);
  }
```

SIMD : vectorisation de fonctions

Syntaxe

Déclare une ou plusieurs fonctions pour être compilées afin d'être appelées depuis une boucle parallèle SIMD

```
#pragma omp declare simd
declaration ou definition de fonction
```

SIMD : vectorisation de fonctions

```
#pragma omp declare simd
float min(float a, float b){
  return a<b ? a : b;
}
```

```
#pragma omp declare simd
float distsq(float x, float y){
  return (x-y)*(x-y);
}
```

```
void example(){
  #pragma omp parallel for simd
  for  (i = 0; i < n; i++){
    d[i] = min (distsq(a[i], b[i]), c[i]);
  }
```