C++

Optimisation

#pragma omp

parallel for

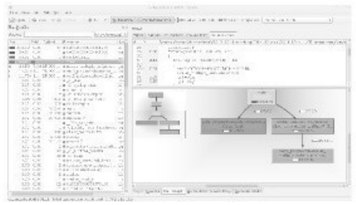

Optimisation

. 1ère règle de la bonne optimisation:

> Ne pas optimiser son code!

Optimisation est la **dernière chose à faire**, ne surtout pas chercher à optimiser dès le début.

Rend le code plus compliqué, plus de lignes, moins générique, moins lisible

Donald Knuth:

> *We should forget about small efficiencies,*
> *say about 97% of the time:*
> ***premature optimization is the root of all evil.***

Méthodologie d'optimisation

(facteur x10)

Avant de coder	Choix de l'algorithmique et des structures de données
Pendant le développement	Suivre bonnes méthodologies de développement
Après que le programme soit fonctionnel	Analyse du temps d'execution (profiling)
Potentiellement à la toute fin	Optimisation du code

(quelques %)

Choix structures données

- **Recherche de valeurs, insertions, suppressions**
  - Recherche très rapide, peu d'insertions — std::unordered_map
  - Beaucoup d'insertions, ordonnancement — std::map
- **Pas de recherche, insertions/suppression locale** — std::list
- **Accès direct, pas d'insertions/suppression**
  - Taille fixe, faible dimension — std::array
  - Taille variable, dimension importante — std::vector
- **Récupération meilleur valeur, insertion constante** — std::priority_queue
- **Organisation en graphe** — boost:graph

...

Choix structures données

- Utilisez la **STL**
- Utilisez la **boost**

  - D'avantages de structures de données
  - Future de la STL

Bonnes pratiques de code

- Ecrivez du code structuré et lisible.
  Séparez vos traitements en fonctions.

  90% des optimisations sont réalisées par le compilateur.
  Mais il faut le laisser libre d'optimiser, il faut pouvoir analyser votre code.

- Evitez les allocations dynamiques inutiles

  `T[N], std::array<T,N>` plutôt que `new T[N]`

- Passez vos arguments de fonctions en références constantes
  Idem pour les valeurs de retours de fonction.

  sauf built-in (int,float, ...)

  ex. ~~`fonction(std::string s)`~~ `fonction(std::string const& s)`

  `fonction(TYPE const& x);`

- Quand le développement est terminé:
  Compilez avec l'option **-O3** de gcc.

  Optimisation la plus élevée

Profiling

- Profileur libre: Valgrind + KCacheGrind

Ne pas chercher à optimiser sans avoir utilisé de profiler

1. Compilez en mode debug
2. Lancez valgrind en mode profiling

```
valgrind --tool=callgrind ./mon_executable
```

3. Visualisez le temps passé dans chaque fonction

```
kcachegrind callgrind.out.xxxx
```

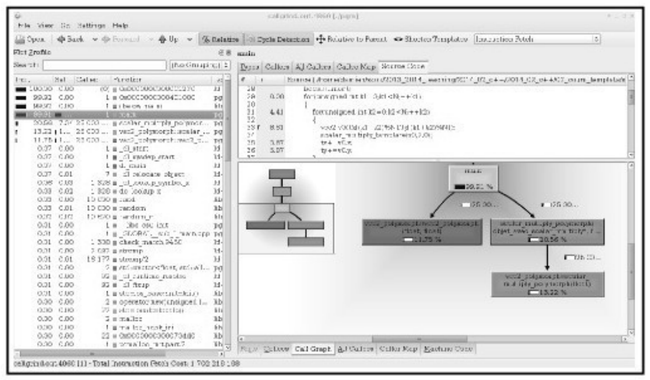

Optimisation du code

- Evitez la création d'objet temporaires

  Préférez `a+=b` à `c=a+b`
  Préférez allocation sur la pile plutôt que sur le tas

- Calculez en float plutôt que double
- Calculez en int plutôt que float
- Précalculez les valeurs de fonction mathématiques
  - Table LUT
  - Méta-programmation (constexpr, ...)
- Parallélisez

Parallélisation

Principe

```
for(k=0;k<N;++k)
   fonction_de_calcul_lente();
```

Non parallélisé

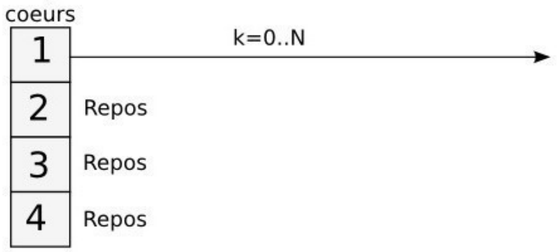

Parallélisation

Principe

```
for(k=0;k<N;++k)
   fonction_de_calcul_lente();
```

Version parallélisé

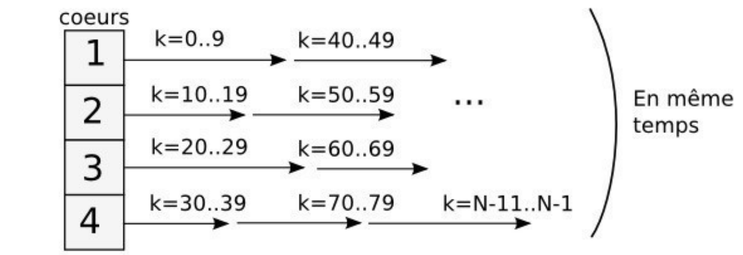

Parallélisation

Implémentation

- Threads

```
pthread_t threads[N];
pthread_create(...);
```

Créez une liste de tâche, ordonner les threads, etc
=> Fastidieux

- OpenMP

```
#pragma omp parallel for
for(k=0;k<N;++k)
   fonction_de_calcul_lente();
```

Boucle parallélisée

Exemple OpenMP

```
float calcul_longueur_courbe(float r,
                             const std::vector<float>& tab_rand)
{

    const unsigned int N_sample=tab_rand.size()/2;
    float L=0.0f;
    for(unsigned int k_sample=0;k_sample<N_sample-1;++k_sample)
    {
        float x0=tab_rand[2*k_sample+0];
        float y0=tab_rand[2*k_sample+1];
        float x1=tab_rand[2*(k_sample+1)+0];
        float y1=tab_rand[2*(k_sample+1)+1];

        L+=std::pow(std::pow(std::fabs(x1-x0),r)+
                    std::pow(std::fabs(y1-y0),r),1.0f/r);

    }
    return L;
}
```

```
#pragma omp parallel for
    for(unsigned int k=0;k<N;++k)
    {
        float norme_alpha=8.0f*static_cast<float>(k)/N;
        aire[k]=calcul_longueur_courbe(norme_alpha,tab_rand);
    }
```

Sans omp

9.8s

Avec omp

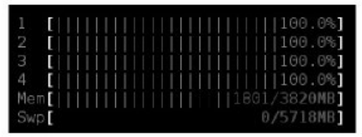

3.2s

Compiler avec

```
gcc -fopenmp ...
```

Utilisation d'OpenMP

- Boucle avec calculs longs

  ex. Multiplication matricielle
  Traitement d'images, vidéos, etc...

  - Les traitements doivent être indépendants !

    `v[k]=f(v[k-1])` Ne fonctionne pas

    Algo reccursifs non parallélisables

  - Les traitements doivent être longs

    Inutile : somme d'un vecteur de 1000 éléments

OpenMP

```
int main()
{
#pragma omp parallel
   {
      std::cout<<"Hello World!"<<std::endl;
   }

   return 0;
}
```

gcc pgm.c **-fopenmp**

Processeurs 4 coeurs: *Hello World!Hello World!*

Hello World!
Hello World!

OpenMP

parallel for: ordre non prévisible

```
int main()
{
#pragma omp parallel for
   for(int k=0;k<10;++k)
   {
      std::cout<<k<<std::endl;
   }

   return 0;
}
```

```
08
1
2
3
64
5

7

9
```


OpenMP

Affichage des ID des threads

```
#pragma omp parallel for
    for(int k=0;k<10;++k)
    {
#pragma omp critical
        {
        std::cout<<omp_get_thread_num()<<"/"
                 <<omp_get_num_threads()<<std::endl;
        }
    }
```

zone critique: 1 seul thread à la fois

ID thread courant

nbr total thread

```
0/4
0/4
1/4
1/4
0/4
1/4
3/4
3/4
2/4
2/4
```

Par défaut: nbr thread=nbr coeurs

→ `set_num_threads(N)`

Réductions en OpenMP

```
   int sum=0;
#pragma omp parallel for
   for(int k=1;k<10;++k)
   {
       sum += k;
   }
   std::cout<<sum<<std::endl;
```

Résultats aléatoires et **faux** !

sum est partagée pour tous les threads
sum+=k n'est pas atomique

Réductions en OpenMP

```
   int sum=0;
#pragma omp parallel for reduction(+:sum)
   for(int k=1;k<10;++k)
   {
       sum += k;
   }
   std::cout<<sum<<std::endl;
```

Définit sum en mémoire locale aux thread
(sum_1,sum_2,sum_3,sum_4)

Réalise les sommes en parallèles sur les variables locales

Réunit à la fin.
(sum=sum_1+sum_2+sum_3+sum_4)

Réductions en OpenMP

```
   int sum=0;
#pragma omp parallel for
   for(int k=1;k<10;++k)
   {
#pragma omp critical
       sum += k;
   }
   std::cout<<sum<<std::endl;
```

Résultat juste ...

Mais plus aucune parallélisation:
plus lent que le code original

Mesure temps avec OpenMP

```
   double start=omp_get_wtime();

   int sum=0;
#pragma omp parallel for reduction(+:sum)
   for(int k=1;k<10;++k)
   {
       sum += k;
   }
   std::cout<<sum<<std::endl;

   double end=omp_get_wtime();
   std::cout<<"temps = "<<end-start<<"s"<<std::endl;
```

Se méfier des autres mesures avec les threads
(ex. boost::timer cumule le temps des threads)

Accélération avec OpenMP

- Il est inutile de paralléliser quelques opérations simples et rapides

Version non parallèle

```
double start=omp_get_wtime();

int sum=0;

for(int k=1;k<10;++k)
{
    sum += k;
}

double end=omp_get_wtime();

std::cout<<sum<<std::endl;
std::cout<<"temps = "<<end-start<<"s"<<std::endl;
```

$2.4\ 10^{-7}$ s

Version parallèle

```
   double start=omp_get_wtime();

   int sum=0;
#pragma omp parallel for reduction(+:sum)
   for(int k=1;k<10;++k)
   {
       sum += k;
   }

   double end=omp_get_wtime();

   std::cout<<sum<<std::endl;
   std::cout<<"temps = "<<end-start<<"s"<<std::endl;
```

$2.4\ 10^{-3}$ s

10000x plus lent!

=> Création, synchonisation des threads possède un cout!
Cout de la fonction doit être supérieur au cout de gestion des threads

Accélération avec OpenMP

- Commence à devenir interessant pour 100 millions d'opérations

```
   double start=omp_get_wtime();

   unsigned long int sum=0;
#pragma omp parallel for reduction(+:sum)
   for(unsigned long int k=0;k<100000000;++k)
   {
       sum += k;
   }

   double end=omp_get_wtime();

   std::cout<<sum<<std::endl;
   std::cout<<"temps = "<<end-start<<"s"<<std::endl;
```

non parallélisé	parallélisé
0.005s **VS**	0.003s

- Dépend de nombreux facteurs
  (architecture, compilateur, niveau d'optimisation, etc)

Accélération avec OpenMP

- Calculs plus complexes sont plus intéressants

```
   double start=omp_get_wtime();

   double sum=0.0f;
#pragma omp parallel for reduction(+:sum)
   for(unsigned long int k=1;k<100000000;++k)
   {
       sum += tan(1.4*k)*tanh(0.25*k+1.35/k)+cos(7.4*(k-5));
   }

   double end=omp_get_wtime();

   std::cout<<"temps = "<<end-start<<"s"<<std::endl;
```

Non parallélisé	Parallélisé
16.7s	7.7s

Autre type de parallélisation

- Parallélisation sur clusters de PC: **MPI** (**M**essage **P**assing **I**nterface)

  Parallélisation de type fork(), échange par msg

- Parallélisation sur carte graphique: (GP)**GPU**

  2000 threads de calculs en parallèles