

Calcul parallèle pour la recherche des QTL

O.Filangi

Séminaire Rules & Tools - La Rochelle
24/09/2010

Pourquoi?

- **Utilisation des SNP**
 - Changement d'échelle [100 MS => 50 000 SNP]
 - Plus de données à traiter(démocratisation du séquençage)
 - Densité de l'information
 - Génération des données croît plus vite que la vitesse des processeurs
- => **Conséquences sur l'analyse**
 - Echantillonage des analyses de liaisons élevé
 - Nouvelles analyses complexes (interaction, qtl additifs, ldla)

Objectif : Réduire le temps d'execution (~ revenir à des temps convenables)

Critères de parallélisation

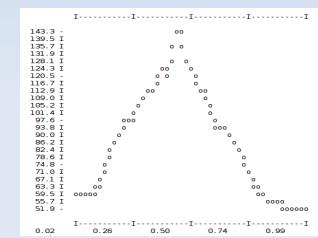
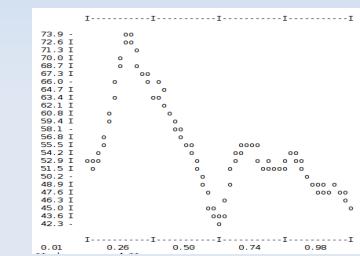
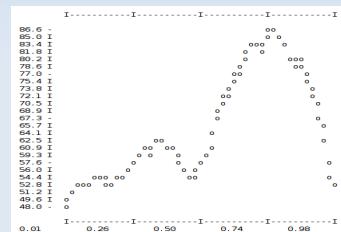
- **Gros grain**
 - Analyses uni-caractère
 - La position du calcul de vraisemblance
 - Analyses avec des données simulées pour l'estimation de seuil de rejet
 - Probabilités de transmissions de chaque F2
- **Grain fin**
 - Calcul matriciel
 - Resolution d'un systeme $N[\text{position}] \times M[\text{simulation}]$

Parallélisation (1)

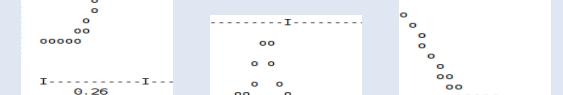


qtlmap

Parallélisation
des analyses (eQTL)



Parallélisation
du génome scan



Contexte multiprocesseurs – architecture à mémoire partagée
=> OpenMP

OpenMP-QTLMMap

- **Parallélisation à gros grain**
 - Language Fortran
 - Adapté au code sequentiel
 - 1997 => implémenté par beaucoup de compilateur
- **Avantages**
 - Peu intrusif : l'utilisation de **pragma** seul (sans utilisation de l'API [use omp_lib]) permet de compiler sans prise en charge de openMP
 - Très peu de modification du code existant
 - Support des variables globales (**threadprivate**) mais peu posés des problèmes
 - Transparents pour les utilisateurs (intervention faible)
 - Export OMP_NUM_THREADS = <nb proc>
 - Export OMP_NESTED = <true/false>

Retours d'exp./Problèmes

- Attention aux librairies ad-hoc truffé de variables globales => **non thread-safe**
- Résultats sensiblement différents avec les méthodes d'optimisation du calcul de vraisemblance
- Exemple problématique de l'imbrication de boucles parallèles et des variables globales **thread private** :

```
Subroutine analyse
  !$omp parallel default(shared)
  !$omp do
  Do ic=1,ncar
    Call optimization_H0
    Call optimization_H1
  End Do
  !$omp end do
  !$omp end parallel
End subroutine analyse
```

```
!valeurs des vraisemblances des familles de plein-freres
real ,dimension(:),allocatable, private :: fm0
 !$omp threadprivate (fm0)

Subroutine optimization_H0
  <Initialisation de fm0 >
End Subroutine optimization_H0

Subroutine optimization_H1
  !$omp parallel default(shared)
  !$omp do
  Do npos=1,nbpositions
    <Utilisation de fm0>
  End do
  !$omp end do
  !$omp end parallel

End Subroutine optimization_H1
```

Problèmes (suite)

Solution peu élégante mais qui marche....

```
!valeurs des vraisemblances des familles de plein-
freres
real ,dimension(:), private , pointer :: fm0
 !$omp threadprivate (fm0)

Subroutine optimization_H0
    <Initialisation de fm0 >
End Subroutine optimization_H0

Subroutine optimization_H1
    real,dimension(:), pointer :: fm0_buf
    fm0_buf => fm0
    !$omp parallel default(shared)
    fm0 => fm0_buf
    !$omp do
    Do npos=1,nbpositions
        <Utilisation de fm0>
    End do
    !$omp end do
    !$omp end parallel

End Subroutine optimization_H1
```

Performances OpenMP

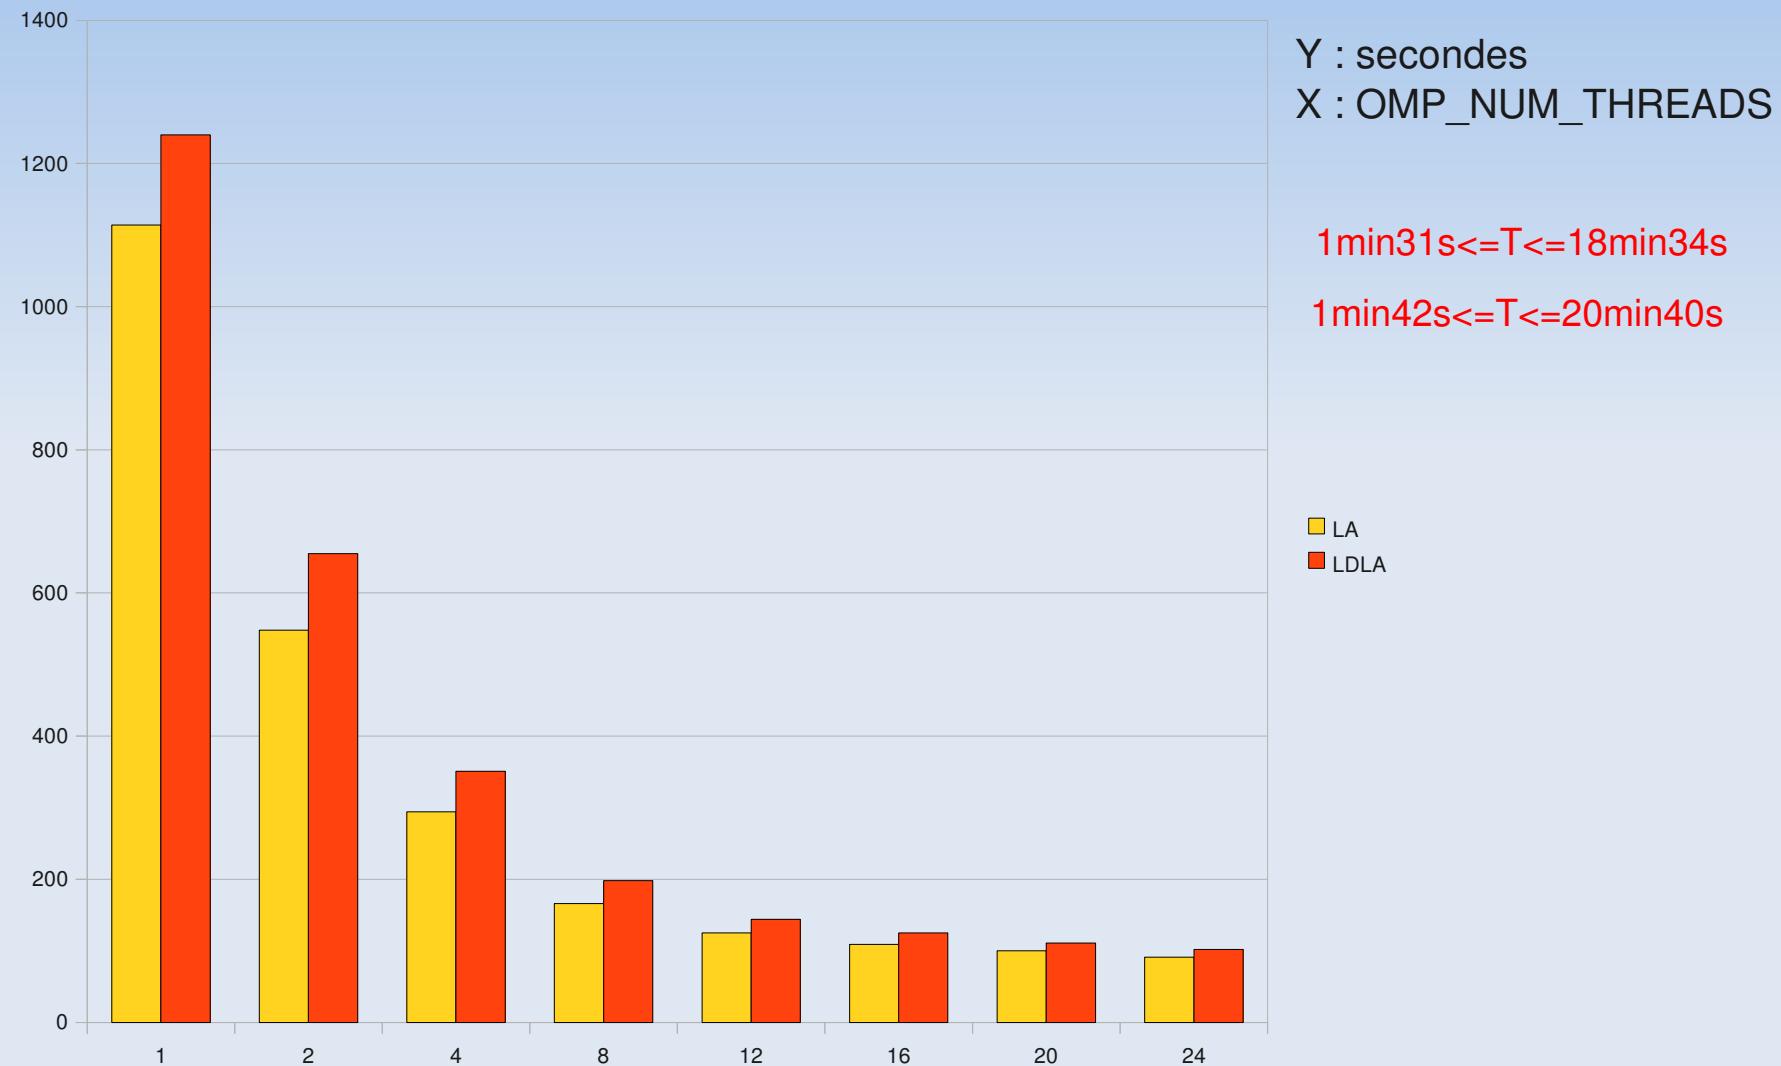
1 Dell Precision – Intel Xeon (E5410) quad core 2,33Ghz (**machine personnelle**)
2 DGA8 – Intel Xeon (E7450) 24 coeurs 2,40Ghz (**serveur de calcul du ctig**)

2 caracteres simulés
5000 markers
5 peres, 15 meres, 750 F2
Pas 0,001 Morgan => 10000 positions à tester

Analyse 1 caractere (1)

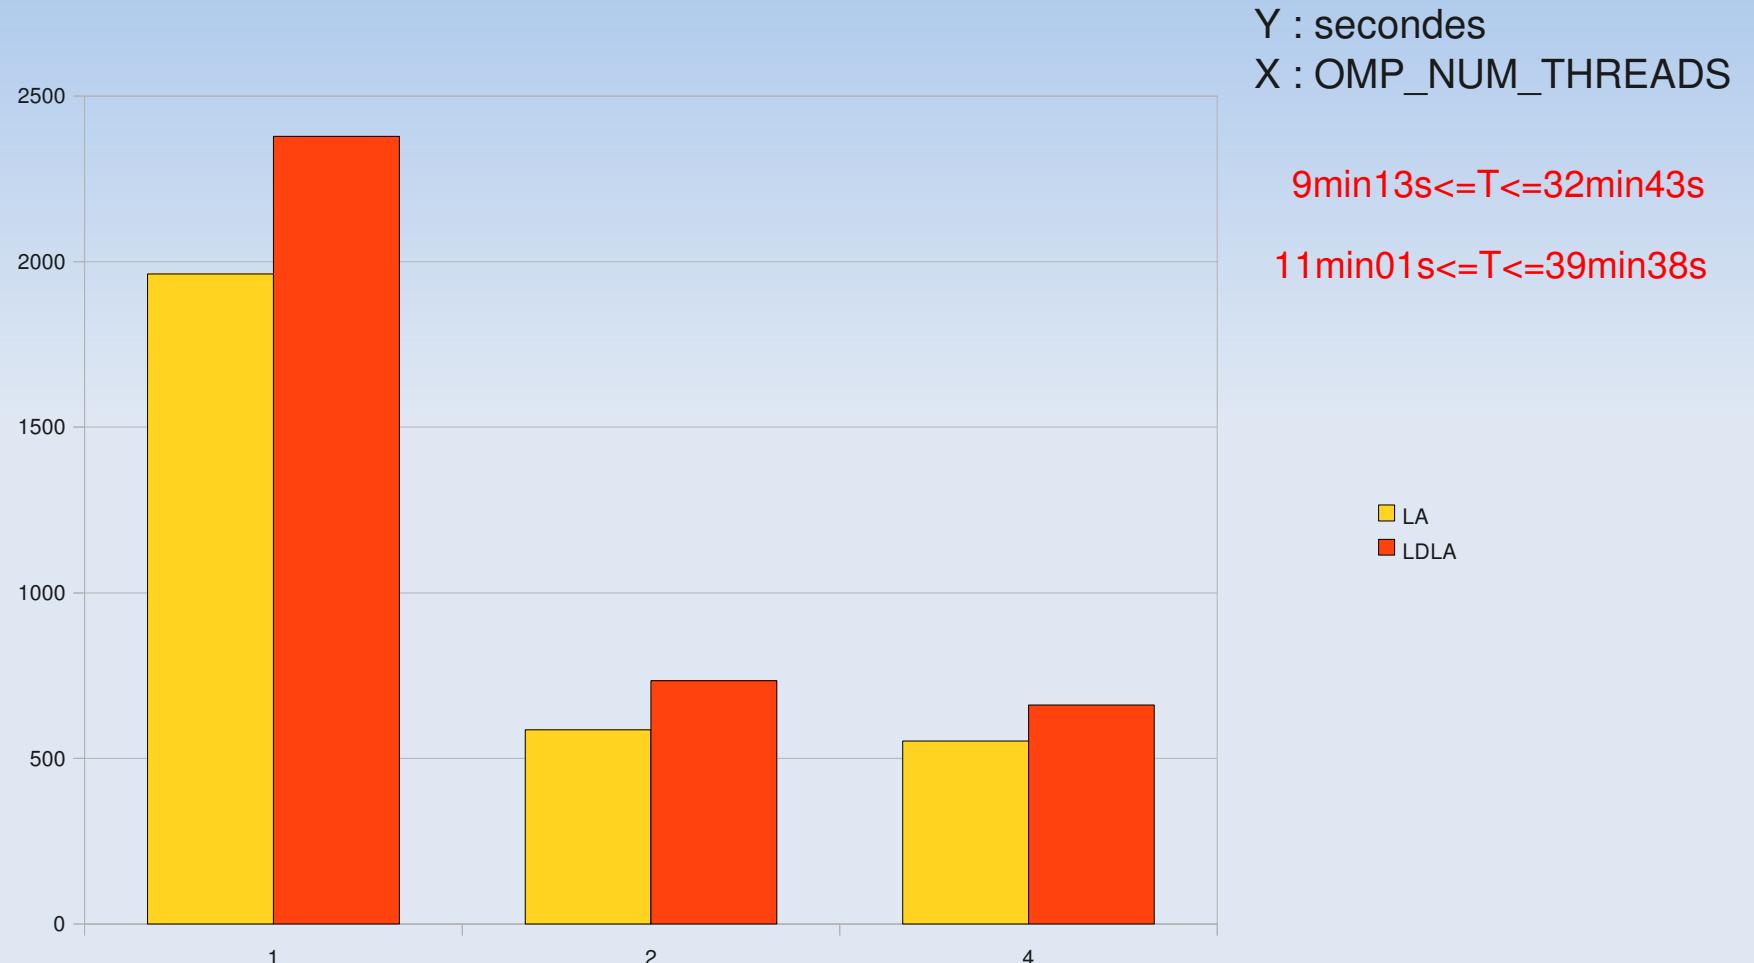


Analyse 1 caractere (2)



2 DGA8 – Intel Xeon (E7450) 24 coeurs 2,40Ghz

Analyse 2 caracteres (1)

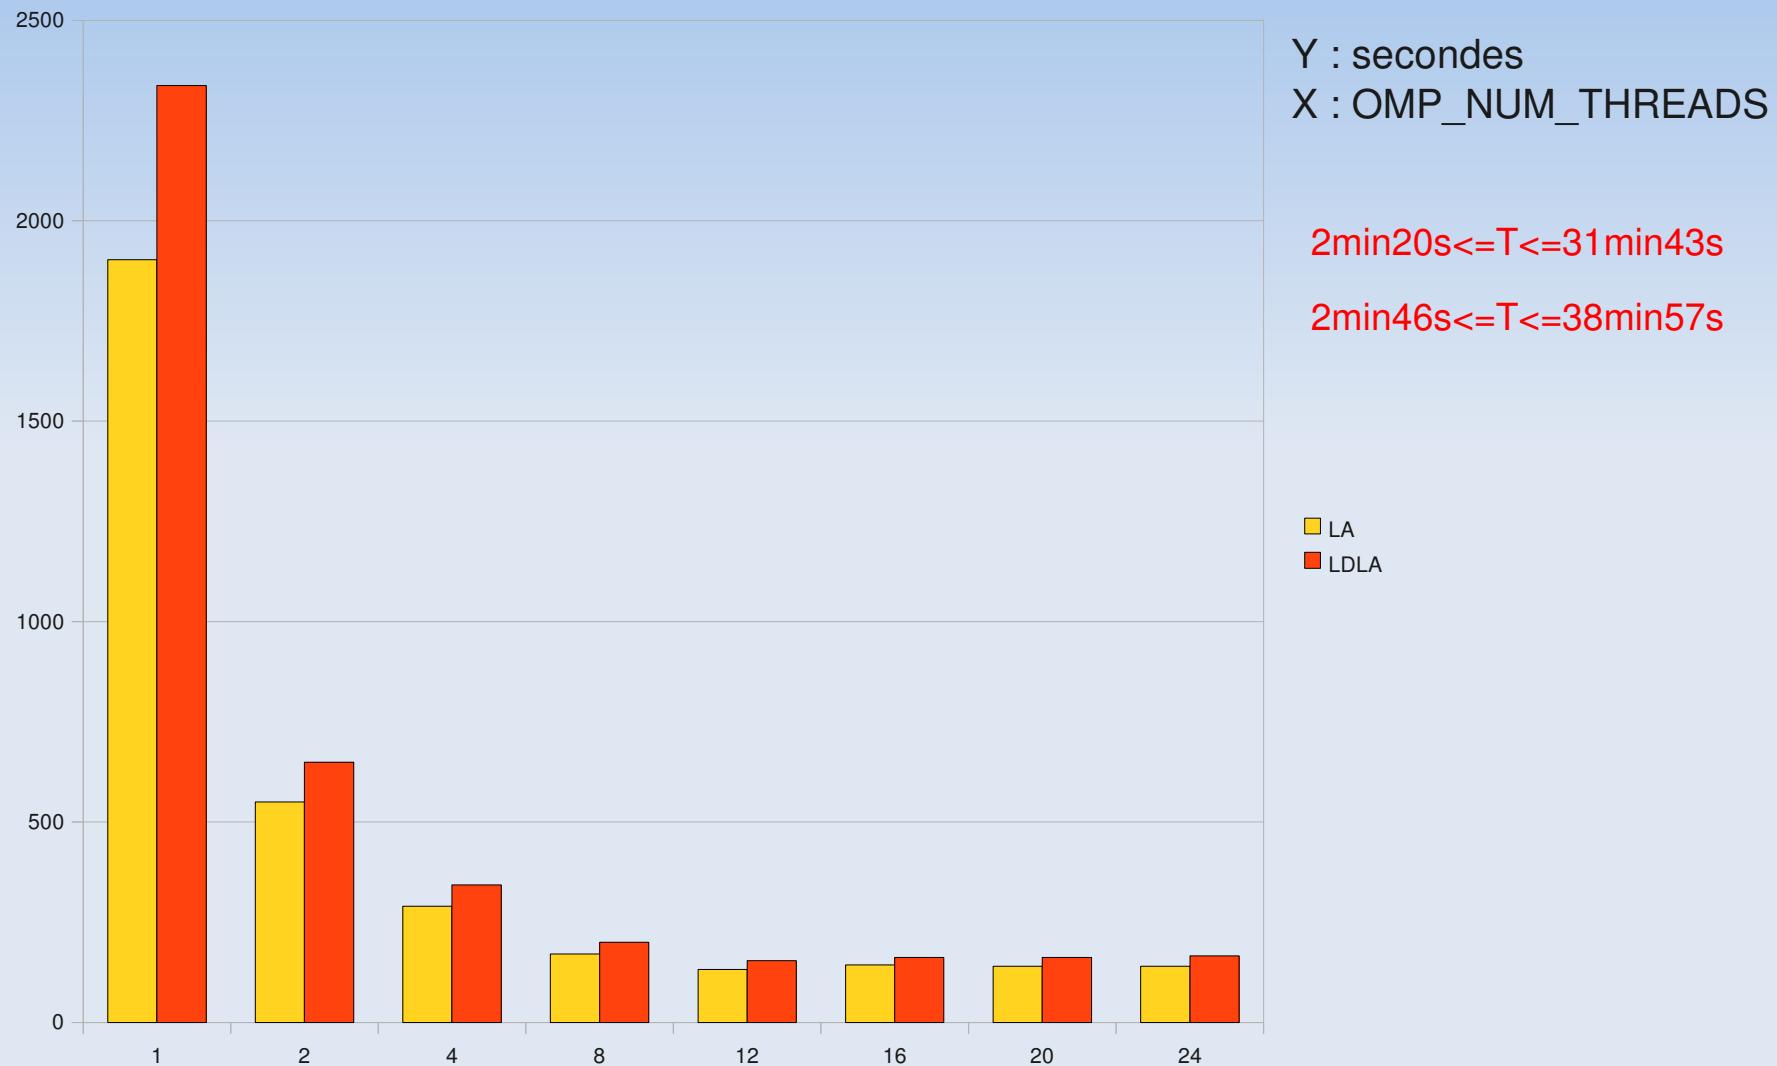


Dell Precision – Intel Xeon (E5410) quad core 2,33Ghz

Remarques :

- 1) export OMP_NUM_THREADS=2
=> 2 analyses simultanées de deux caractères
=> parallélisation du génome scan en ¼

Analyse 2 caractères (2)



2 DGA8 – Intel Xeon (E7450) 24 coeurs 2,40Ghz

Remarques :

- 1) export OMP_NUM_THREADS=2
=> 2 analyses simultanées de deux caractères
=> parallélisation du génome scan en 2

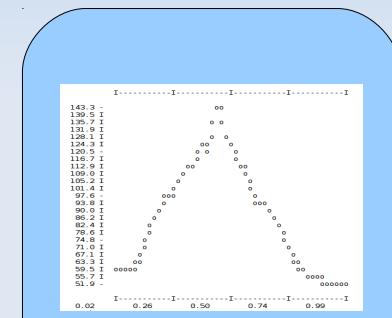
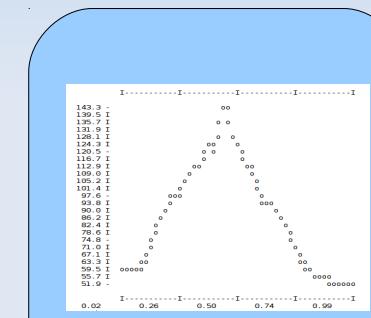
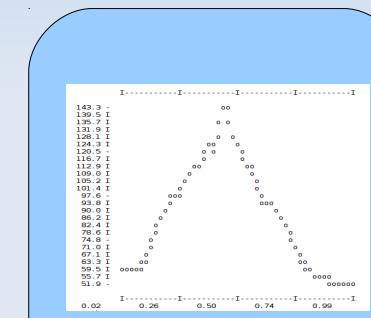
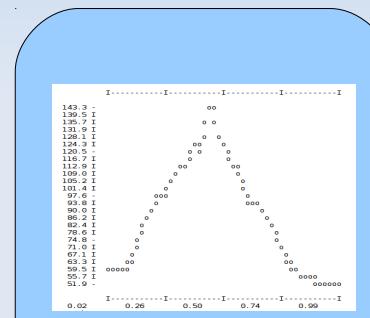
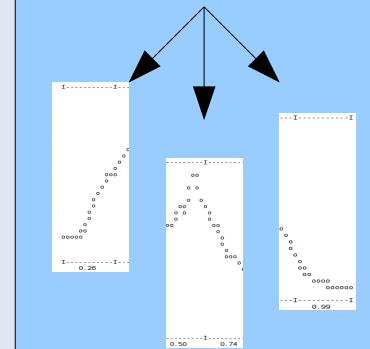
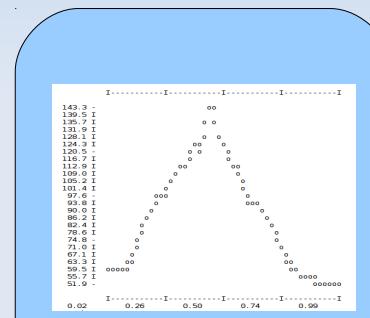
Parallélisation (2)



qtlmap

Parallélisation
des analyses
de données simulées

architecture à mémoire distribué
+
architecture à mémoire partagée



Parallélisation
du génome scan

MPI-QTLMMap

- Objectifs : exploiter la puissance de calcul des clusters des génopoles toulousaine et rennaise et du ctig
- Constraintes / Inconvénients :
 - Disponibilités des clusters
 - Au moment de l'execution : Combien de noeuds sont disponibles ?
 - Puis-je raisonnablement prendre toutes les ressources ?
 - Politique d'administration du cluster
 - Environnement MPI : mpich+gfortran rennes, openmpi+ifort à toulouse
 - Politique d'allocation des noeuds, allocation erronés du à une surcharge
 - Pour des utilisateurs avertis
 - Ecriture de batch parallel avec execution de l'environnement mpi

Implémentation

- Modification du code originale mais facilement adaptable si l'architecture logiciel a été bien pensé en couche
- Implémentation d'un gather :

```
call MPI_INIT (code)
call MPI_COMM_SIZE ( MPI_COMM_WORLD , nb_procs , code)
call MPI_COMM_RANK (MPI_COMM_WORLD, thread_rang , code)

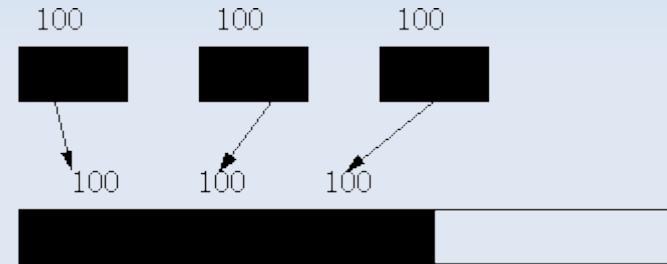
nbsimulByThread = nsim / nb_procs

allocate (lrtmaxTab(nbsimulByThread))
!le processus Maitre (0)
If ( thread_rang == 0 ) then
  allocate (lrtmaxTab_final(nsim))
End if

do isim=1,nbsimulByThread
  call analyse(..,lrtmaxTab(isim)...)
End do

!Declaration des types a passer par message
call MPI_TYPE_CONTIGUOUS (nbsimulByThread, MPI_DOUBLE_PRECISION, dim3double,code)
call MPI_TYPE_COMMIT(dim3double,code)

! Ici le processus Maitre (0) recupere l'ensemble des resultats de la simulation....
deb_indice=nbsimulByThread * (thread_rang)+1
call MPI_GATHER (lrtmaxTab(1),1, dim3double ,lrtmaxTab_final(deb_indice),1,dim3double, 0 ,MPI_COMM_WORLD ,code) 15
call MPI_TYPE_FREE(dim3double,code)
```



Problème

**Initialisation du germe pour la génération
de nombre aléatoire via la date : unicité du germe dans un
contexte parallèle ?**

```
! Initialize Random number Generator CoMmon (for Randlib)
call inrgcm()
! Init the random generator
call DATE_AND_TIME(date, time, zone, value)
phrase=date//time//zone
call phrtsd(phrase,iseed1,iseed2)
call setall(iseed1,iseed2)
```

« la génération de nombres aléatoires est trop importante pour être confiée au hasard »

Robert R. Coveyou du Oak Ridge National Laboratory

BayesCPI

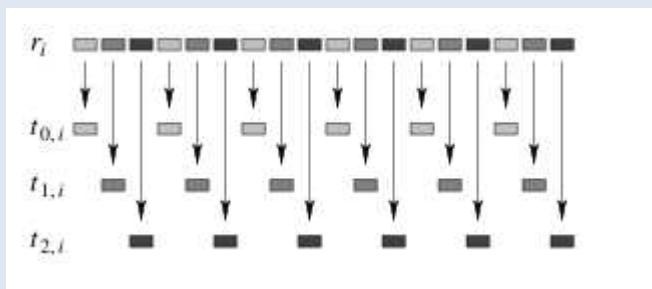
- Parallélisation du MCMC : exécuter N chaines parallèles puis recolter les données générées (**GATHER**).
- Utilisation des PRNG (**Pseudo Random Number Generator**) bien adapté à une implantation informatique des MCMC
- 4 techniques : **le random seeding, la paramétrisation, le block splitting et le leapfrog.**

La random seeding et la paramétrisation empêche le "fair play"

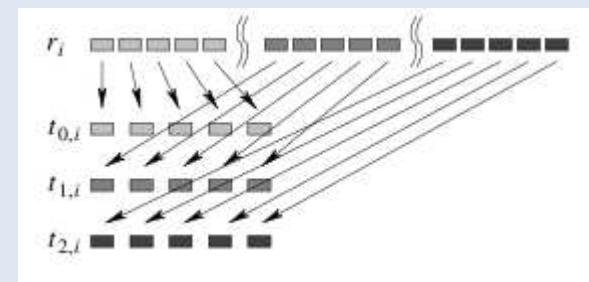
$$\begin{aligned} T(\theta, i) &= R(P*i) \\ T(1, i) &= R(P*i+1) \\ \cdots \\ T(p-1, i) &= R(P*i+(p-1)) \end{aligned}$$

$$\begin{aligned} T(\theta, i) &= R(i) \\ T(1, i) &= R(i+M) \\ \cdots \\ T(p-1, i) &= R(i+M*(p-1)) \end{aligned}$$

*M nombre maximum d'appel au PRNG
P le nombre de processus
R sequence*



leapfrog



Block splitting

BayesCPi (2)

Tina's Random Number Generator Library (TRNG) is a state of the art C++ pseudo-random number generator library for sequential and parallel Monte Carlo simulations. (**Tina's RNG**)

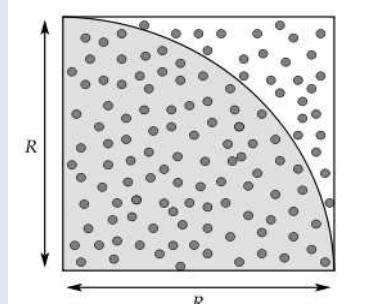
- Collection de générateurs

- Linear congruential generator
- Multiple recurrence generator based on a linear feedback shift register sequence over $F(2^{31}-1)$ of depth N
- Multiple recurrence generator based on a linear feedback shift register sequence over $F(M)$ of depth N, with M being a Sophie Germain Prime
- Yet Another Random Number sequence based on a linear feedback shift register sequence over $F(2^{31}-1)$ of depth N based on a multiple recursive generator
- Yet Another Random Number sequence based on a linear feedback shift register sequence over $F(M)$ of depth N, with M being a Sophie Germain Prime

- Collection de distributions : loi uniforme, gamma, normale....

Example:

The numerical value of π can be estimated by throwing random points into a square.



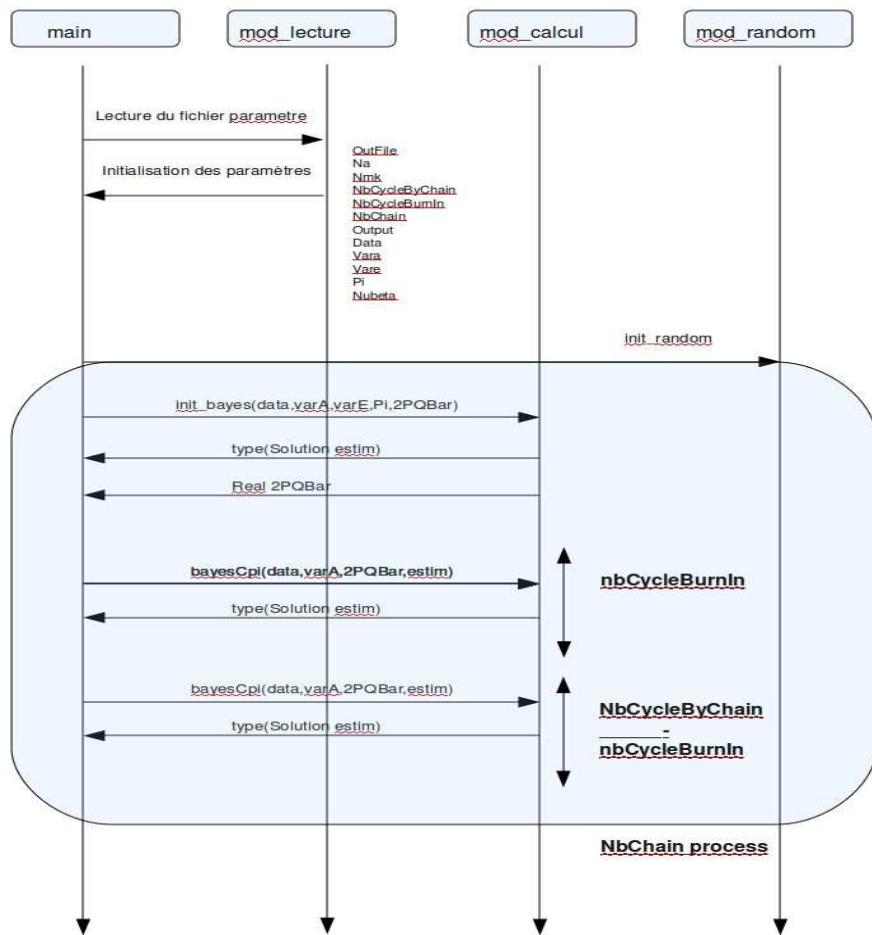
$$\frac{\text{number of points in circle}}{\text{number of points in square}} \approx \frac{\pi R^2 / 4}{R^2} = \frac{\pi}{4}$$

$$\pi \approx 4 \frac{\text{number of points in circle}}{\text{number of points in square}}.$$

Listing 6.7: Parallel Monte Carlo calculation of π using leapfrog and OpenMP.

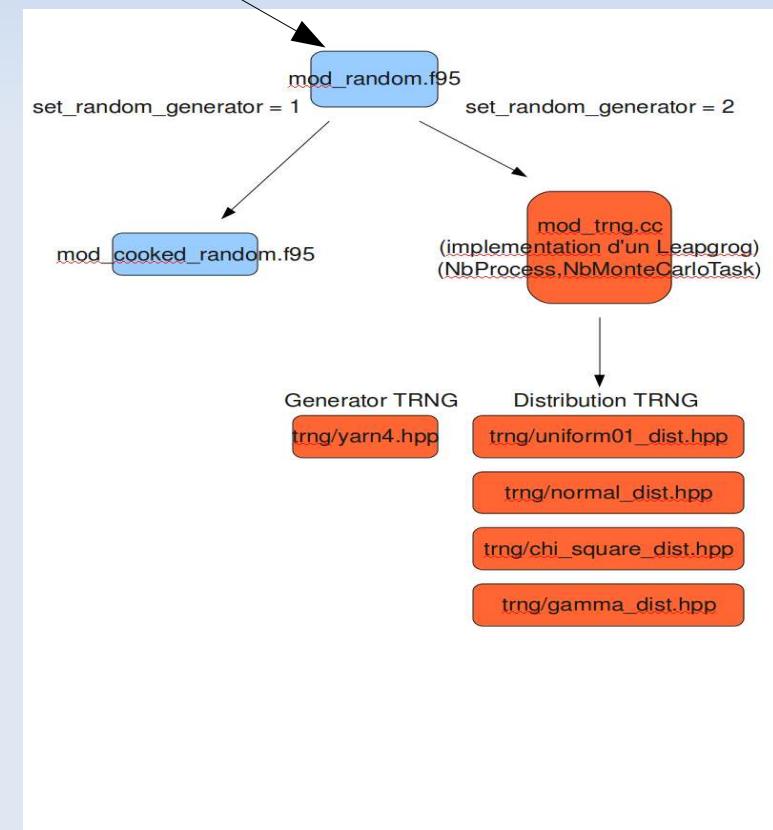
```
1 #include <cstdlib>
2 #include <iostream>
3 #include <omp.h>
4 #include <trng/yarn2.hpp>
5 #include <trng/uniform01_dist.hpp>
6
7 int main(int argc, char *argv[]) {
8     const long samples=10000000;           // total number of points in square
9     long in=0L;                          // no points in circle
10    // distribute workload over all processes
11 #pragma omp parallel
12 {
13     trng::yarn2 rx, ry;                // random number engines for x- and y-coordinates
14     int size=omp_get_num_threads();      // get total number of processes
15     int rank=omp_get_thread_rank();      // get rank of current process
16     // split PRN sequences by leapfrog method
17     rx.split(2, 0);                   // choose sub-stream no. 0 out of 2 streams
18     ry.split(2, 1);                   // choose sub-stream no. 1 out of 2 streams
19     rx.split(size, rank);             // choose sub-stream no. rank out of size streams
20     ry.split(size, rank);             // choose sub-stream no. rank out of size streams
21     trng::uniform01_dist<> u;        // random number distribution
22     long in_local=0L;
23     // throw random points into square
24     for (long i=rank; i<samples; i+=size) {
25         double x=u(rx), y=u(ry);       // choose random x- and y-coordinates
26         if (x*x+y*y<=1.0)            // is point in circle?
27             ++in_local;                 // increase thread-local counter
28     }
29 #pragma omp critical
30     in+=in_local;                    // increase global counter
31 }
32 // print result
33 std::cout << "pi = " << 4.0*in/samples << std::endl;
34 return EXIT_SUCCESS;
35 }
```

BayesCPI(3)



```

subroutine bayesCpi(...)
...
!STEP 1 : tirage de la variance residuelle
!-----
!on tire une V.A (u) dans une loi de CHI2 à N+3 ddl
u = random_chisq(numRandom=id_chisq,ndf=data%na+3)
...
  
```



BayesCPI (3)

```
#include <trng/yarn4.hpp>
#define GENRATOR_TYPE trng::yarn4

static GENRATOR_TYPE *streamsChisq = NULL;
static GENRATOR_TYPE *streamsNormal = NULL;
static GENRATOR_TYPE *streamsUnif = NULL;
static GENRATOR_TYPE *streamsBeta = NULL;

//Directive openMP : les tableaux streamsXXX sont locaux a chaque processus OpenMP
#pragma omp threadprivate (streamsChisq,streamsNormal,streamsUnif,streamsBeta)
```

Déclaration des générateurs utilisés par le bayescpi

1

Initialisation

2

utilisation

```
! ** TRNG Implementation **
! Interface with C++ developpement of mod_trng.cc
interface
    subroutine init_random_leap(nbProc,whichProc,nb_chisq,nb_norm,nb_unif,nb_beta)
        integer ,intent(in) :: nbProc ! number of processor
        integer ,intent(in) :: whichProc ! numero du processus OpenMP
        integer ,intent(in) :: nb_chisq,nb_norm,nb_unif,nb_beta ! nombre de generateur
    end subroutine init_random_leap

    subroutine trng_normal_leap(numRand,mean,sig,res)
        integer ,intent(in) :: numRand ! index du random
        real ,intent(in) :: mean
        real ,intent(in) :: sig
        real ,intent(out) :: res
    end subroutine trng_normal_leap
...
End interface
```

```
// LEAPFROG Method .
// allocation of a random number engine for each random we needs
if ( *nbChisq > 0 ) streamsChisq = new GENRATOR_TYPE[*nbChisq];
if ( *nbNorm > 0 ) streamsNormal = new GENRATOR_TYPE[*nbNorm];
if ( *nbUnif > 0 ) streamsUnif = new GENRATOR_TYPE[*nbUnif];
if ( *nbBeta > 0 ) streamsBeta = new GENRATOR_TYPE[2*(*nbBeta)]; // we used 2 gamma...

//Number of generator
int total = *nbChisq + *nbNorm + *nbUnif + 2*(*nbBeta);

//Generator for chi2 random
for (int j=0;j<*nbChisq;j++) {
    streamsChisq[j].split(total,j);
    streamsChisq[j].split(*nbProc,*whichProc);
}

//Generator for normal random
for (int j=0;j<*nbNorm;j++) {
    streamsNormal[j].split(total,*nbChisq + j);
    streamsNormal[j].split(*nbProc,*whichProc);
}

//Generator for uniform random
for (int j=0;j<*nbUnif;j++) {
    streamsUnif[j].split(total,*nbChisq + *nbNorm + j);
    streamsUnif[j].split(*nbProc,*whichProc);
}

//Generator for beta random (using 2 gamma random)
for (int j=0;j<2*(*nbBeta);j++) {
    streamsBeta[j].split(total,*nbChisq + *nbNorm + *nbUnif + j);
    streamsBeta[j].split(*nbProc,*whichProc);
}
```

```
extern "C" void trng_normal_leap_(int *numRand,float*mean,float*sig,float*res) {
    trng::normal_dist<float> d(*mean, *sig);
    assert (numRand!=NULL);
    assert ((*numRand)>=0);
    *res = d(streamsNormal[*numRand]);
}
```

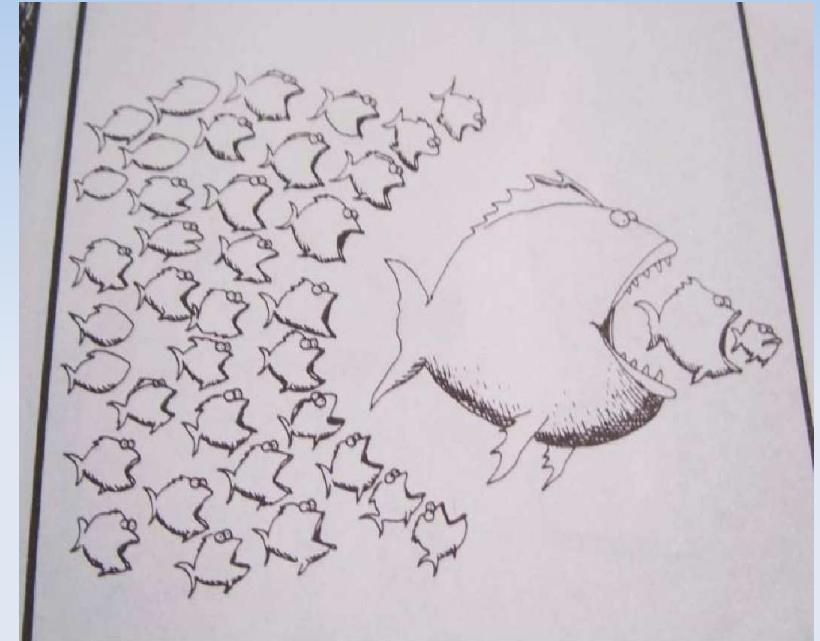
GPU Computing

GPU : Graphical Processing Unit

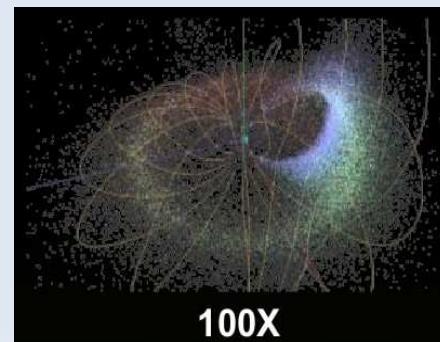
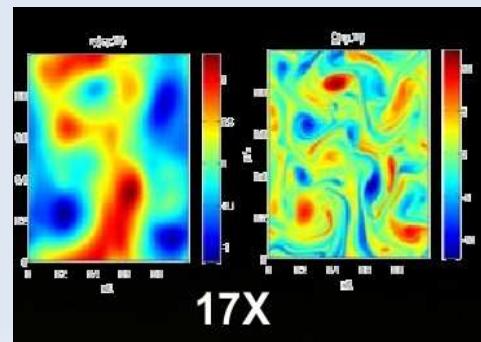
- Cartes vidéos, PlayStation3,XBox
- NVIDIA,ATI,AMD

CUDA (an acronym for Compute Unified Device Architecture) is a parallel computing architecture developed by NVIDIA

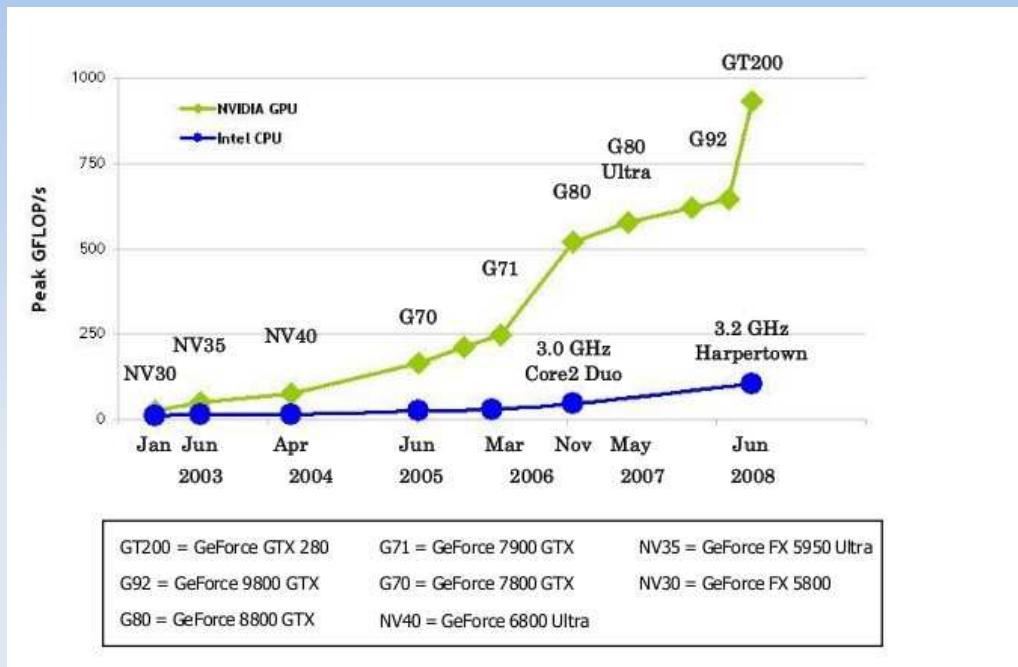
GPGPU : General-purpose computing on graphics processing units



Pourquoi ?



Comparaison/Performances



Evolution des GPU / CPU

G80 (Nov 2006 – GeForce 8800 GTX)

128 flux processeurs

Jusqu'à 12 288 threads simultanés

Mémoire partagés (PBSM) accélère le calcul

Fermi (2010 – Tesla C2050)

448 coeurs

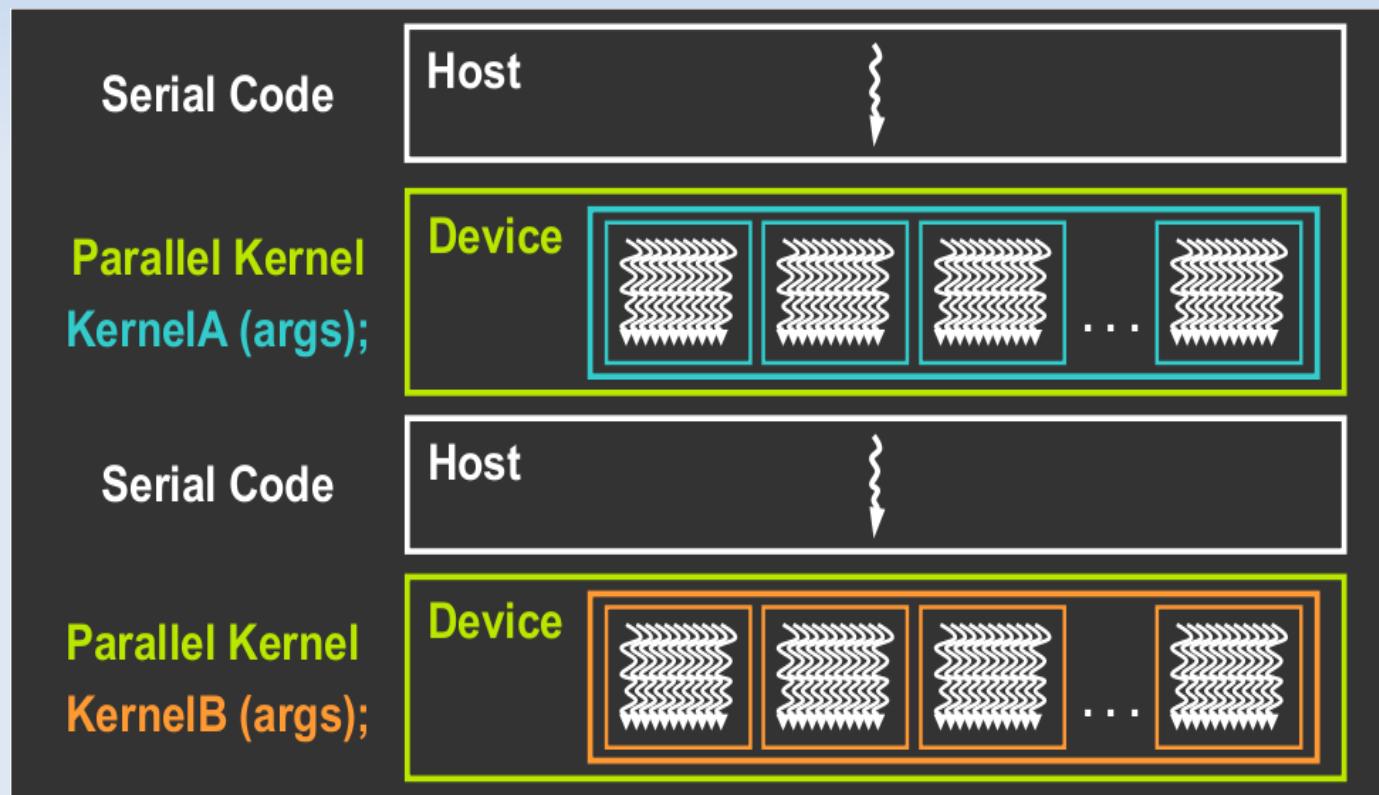
1,03 TFlops SP, 515 Gflops DP

"En comparaison avec les derniers CPU quad-core, les solutions Tesla C2050 et C2070 délivrent des performances de supercalcul équivalentes pour une consommation 20 fois moins importante et un prix 10 fois plus faible."



Programmation hétérogène

- alternance de code séquentiel (fonctions **host**) / code parallèle (fonctions **kernel**)
- les fonctions **hosts** s'exécutent sur un seul thread (**CPU thread**)
- les fonctions **kernels** s'exécutent sur plusieurs threads (**GPU threads**)



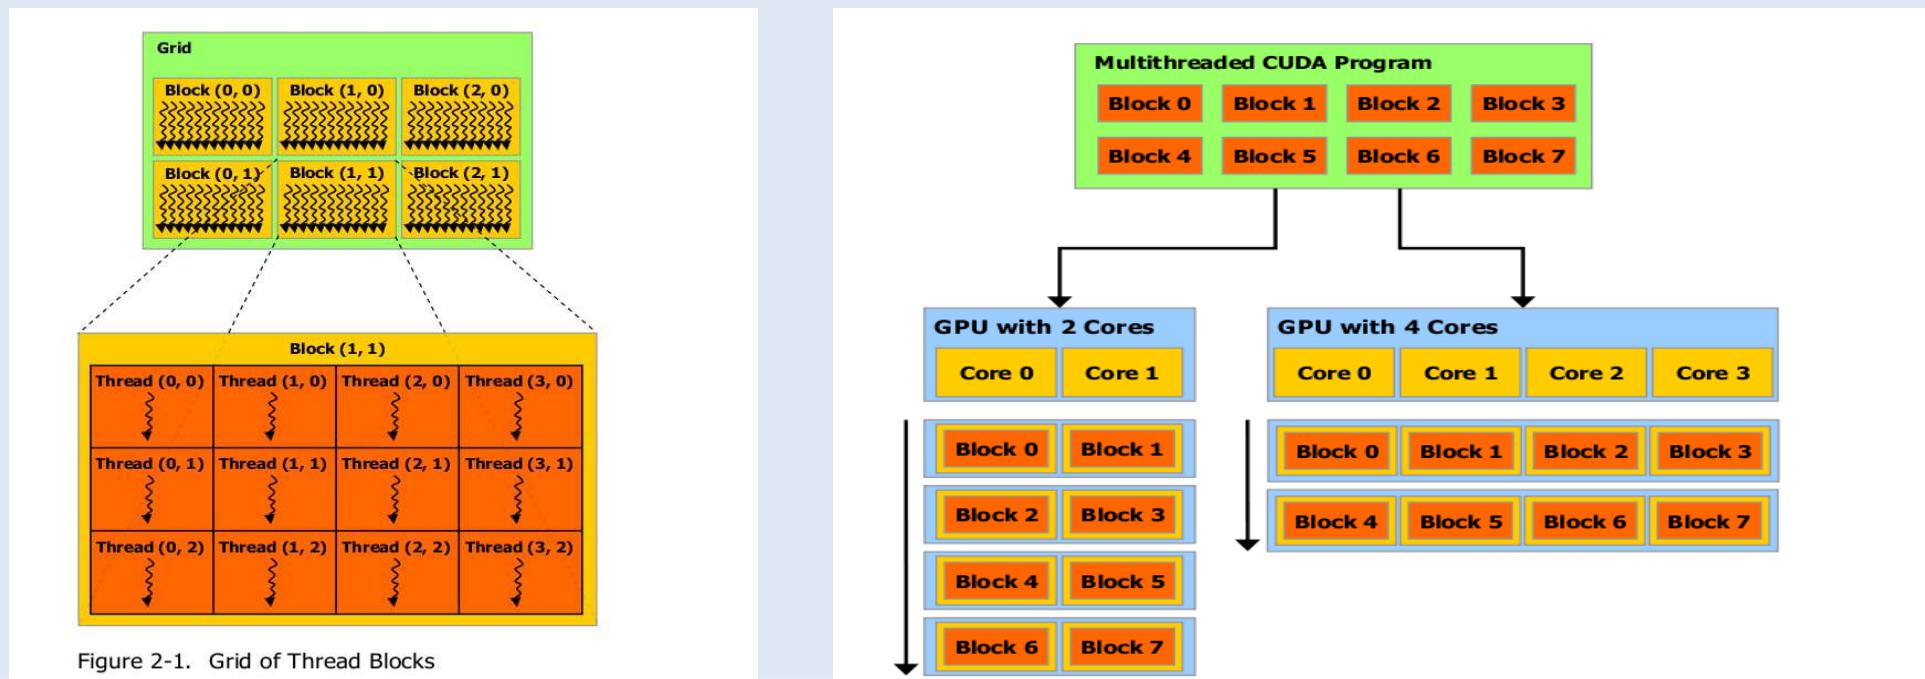
Fonction **kernel** = **nombre threads simultanés**

A Scalable Programming Model

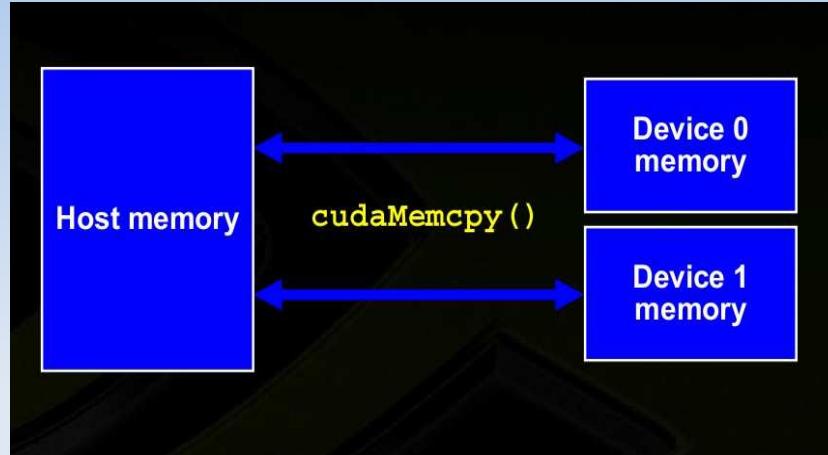
CUDA est un modèle de programmation parallèle

Kernel = grille de block de thread

- Les blocks de threads ne sont pas synchronisés => **exécutions séquentielles ou simultanées** ce qui permet une évolution du modèle de programmation
- Block Id 1D ou 2D
- Thread Id 1D,3D

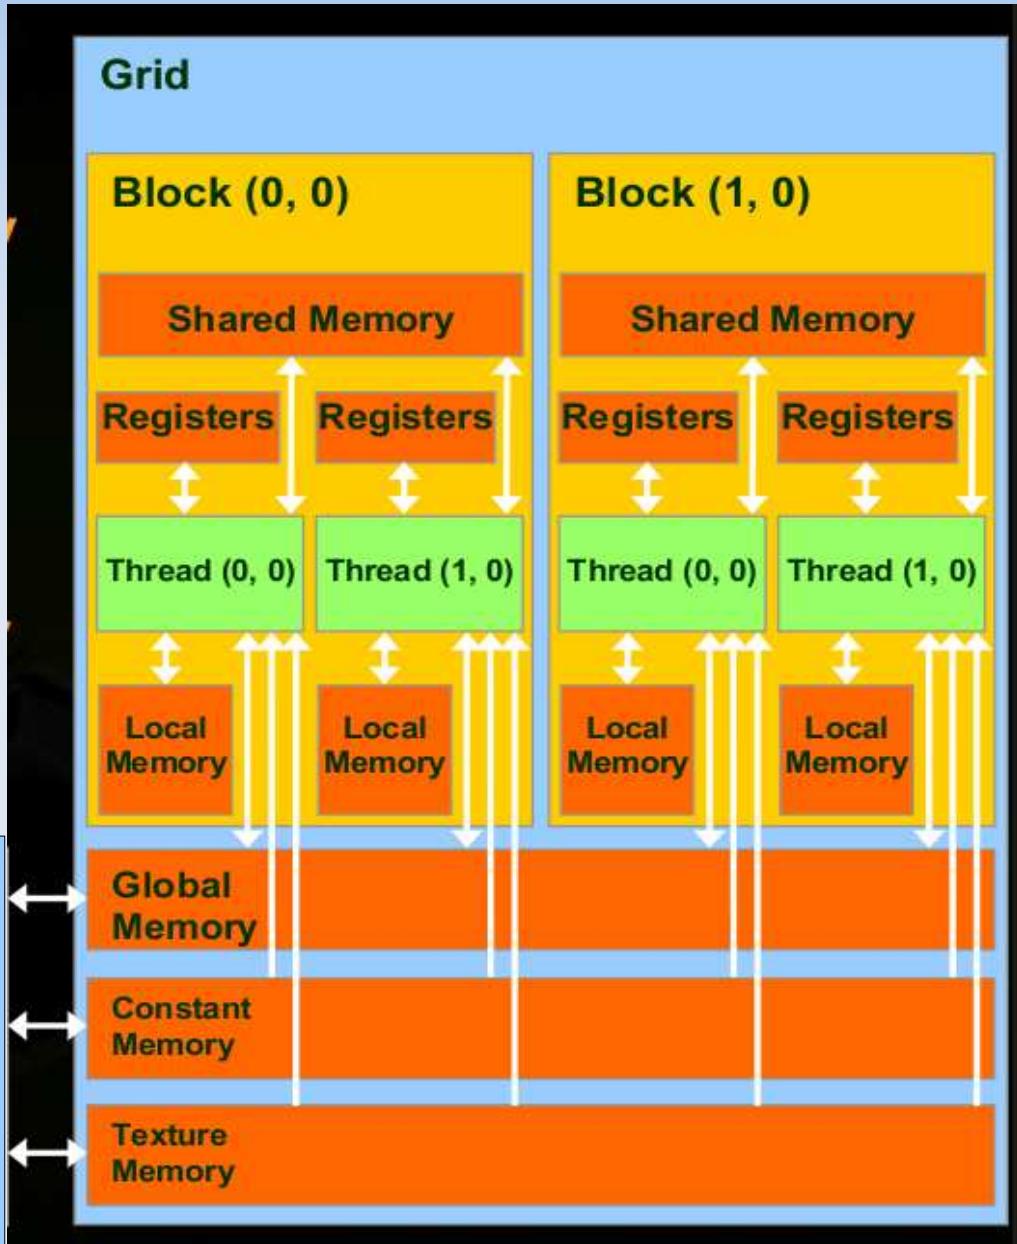
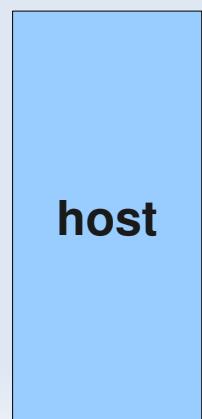


Utilisation des données



Les données doivent être transférées sur le matériel

Hiérarchie mémoire



Exemple

CPU program

```
void increment_cpu(float *a,
                   float b,
                   int N)
{
    for (int idx = 0; idx < N; idx++)
        a[idx] = a[idx] + b;
}

void main()
{
    .....
    increment_cpu(a, b, N);
}
```

CUDA program

```
__global__ void increment_gpu(float *a,
                             float b,
                             int N)
{
    int idx = blockIdx.x * blockDim.x + threadIdx.x;
    if (idx < N)
        a[idx] = a[idx] + b;
}

void main()
{
    .....
    dim3 dimBlock (blocksize);
    dim3 dimGrid( ceil( N / (float)blocksize ) );
    increment_gpu<<<dimGrid, dimBlock>>>(a, b, N);
}
```

Analyse QTLMap - Cuda

Première implémentation naïve => on écrit l'algorithme du modèle linéaire homoscédastique

- 1) Transfert de la matrice de contingence sur le device
- 2) $X \cdot X^{-1}$ (CUBLAS::cublasSsyrk)
- 3) Estimabilité des effets du modèle (décomposition cholesky)
- 4) Construction de la solution $RHS = Xr' \cdot Y$ (CUBLAS::cublasSgemv)
- 5) Résolution LU (Etape de descente)
- 6) Résolution LU (Etape de remonté)
- 7) $XB = XINC * Solution$ (CUBLAS::cublasSgemv)
- 8) $RHS = Y - XB$ (CUBLAS::cublasSscal,cublasSaxpy)
- 9) Variances résiduelles (CUBLAS::cublasSdot)
- 10) Récupération des données stoquées sur le device

Remarques:

- Les données statiques (Y, CD, \dots) sont préalablement transférées sur le device.
- Utilisation de la librairie CUBLAS
- Implémentation ad-hoc

=> Perte de performance.....

- › Matrice trop petite (peu de niveau à estimer=>pas intensif).
- › Le calcul à la position implique beaucoup trop de transfert sur le matériel

Conclusion/retour d'exp. :

=> calculer les solutions pour toutes les positions en même temps

- 1 seul transfert
- beaucoup plus de threads vont être utilisés

=> Pour une utilisation de calcul matriciel "simple" => implémentation en fortran simple avec CUBLAS sans besoin de connaître les rouages de CUDA

Synthèses

	Prise en main	Difficultés	Deploiement	Retour d'ex.
OpenMP	++		- Serveur de calcul MP - Machine personnel	+
MPI	+	- Environnement d'exécution - Passage des informations/résultats entre processus	- Serveur de calcul MP, MD - Machine personnelle	-
CUDA	-	- Réécritures des algos - Connaissance du C	- Machine personnelle avec carte GPU - Cluster GPU	-/+

MP : mémoire partagée

MD : mémoire distribuée (cluster)

Questions ?