

Analyse de performances et optimisation de codes

Anne Cadiou

Atelier optimisation de codes

Groupe Calcul - DevLOG

Maison de la Simulation, vendredi 17 mai 2019

Laboratoire de Mécanique des Fluides et d'Acoustique



Introduction

Pourquoi optimiser son code ?

- Exploiter au mieux l'architecture matérielle
- Diminuer le temps de calcul (CPU time)
- Minimiser l'occupation mémoire
- Diminuer les communications inter-noeuds
- Réduire le temps passé à faire des E/S
- Exploiter au mieux les fonctionnalités d'un langage
- Rendre son code plus lisible, portable, évolutif

... des critères pas toujours compatibles.

Mise en oeuvre

Sur un code existant :

- S'assurer de la validation du code
- Profiler (temps d'exécution, utilisation de la mémoire, etc.)
- Modifier les parties les plus critiques
 - Vectoriser
 - Revoir la structuration des données
 - Exploiter les caches
 - Utiliser des bibliothèques optimisées
 - Paralléliser
 - Revoir l'algorithme

Avant d'écrire le code

- Choisir une méthode numérique adaptée au problème à traiter
- Définir une structure de données adaptée à la méthode numérique choisie
- Évaluer le type de parallélisation possible pour ces choix
- Choisir un algorithme adapté au problème à traiter
- Évaluer la complexité de l'algorithme (nombre d'opérations)
- Étudier les bibliothèques existantes à appeler dans le code

Wikipedia

Analyser l'exécution d'une application, afin d'en connaître son comportement, d'évaluer les parties à optimiser

Sert à comprendre le comportement d'un code sur une architecture donnée, dans un environnement donné, afin d'exploiter au mieux toutes ses caractéristiques

Questions associées

- Mon code utilise-t'il efficacement les ressources CPU ?
- La structure de mes données est-elle optimale ?
- Quelles sont les caractéristiques parallèles de mon programme ?
- Combien de mémoire effective utilise mon programme ?
- La gestion des E/S est-elle efficace ?

Différents niveaux d'optimisation pour le calcul

- Automatique : à l'aide du compilateur
- Manuelle :
 - aider le compilateur,
 - exploiter le parallélisme,
 - s'appuyer sur les outils de profiling

Réduire le nombre total d'opérations dans le code, augmenter la localité spatiale et temporelle des données

Généralement, les E/S et communications sont des parties où le processeur attend

- Adapter la stratégie à l'architecture
- Masquer par du calcul
- Utiliser des bibliothèques standardisées et optimisées

Optimisation par le compilateur

Le compilateur cherche à optimiser automatiquement le code. En pratique, il n'a pas toujours assez d'informations (notamment la taille des données connue au run-time, ...).

Optimisations principales

- allocation optimale des registres, optimisation des accès mémoires ;
- élimination des redondances ;
- optimisation des boucles, en ne conservant à l'intérieur que ce qui est modifié ;
- optimisation du pipeline, utilisation du parallélisme d'instructions.

Options de compilation

`-Olevel`

plus `level` est grand,

- plus l'optimisation est sophistiquée ;
- plus le temps de compilation est important ;
- plus la taille du code peut devenir grande.

`-O0` : aucune optimisation

`-O1` : optimisation visant à accélérer le code, en particulier quand il ne contient pas beaucoup de boucles

`-O2` : 01 et déroulage de boucles ; augmente le temps de compilation

`-O3` : 02 et transformation des boucles, des accès mémoire, inlining

`-march=cpu_type` : génère les instructions adaptées au jeu d'instructions du processeur spécifié

Certaines optimisations peuvent modifier l'ordre des opérations et donc affecter les résultats (et leur reproductibilité).

Résolution d'un système linéaire par la méthode S.O.R. $64 \times 64 \times 64$ (2002)

Système	Cpu	Compilateur	Options	Time
Linux 2.4.7-10smp (Redhat 7.2)	Pentium IV Xeon 1.7Ghz Memory : 1024Mb RDRAM ECC PC860 Cache : 8K L1, 256K L2	Intel(R) Fortran Compiler for 32-bit applications Linux Version 5.0.1 Build	-O3 -tpp7 -axW -ipo	61s
Linux 2.4.7-10smp (Redhat 7.2)	Pentium IV Xeon 1.7Ghz Memory : 1024Mb RDRAM ECC PC860 Cache : 8K L1, 256K L2	Absoft f90	-O -B100	84s
Linux 2.4.7-10smp (Redhat 7.2)	Pentium IV Xeon 1.7Ghz Memory : 1024Mb RDRAM ECC PC860 Cache : 8K L1, 256K L2	GNU g77	-s -mcpu=pentiumpro -march=pentiumpro -mpentiumpro -O6 -frerun-cse-after-loop -fno-defer-pop -fschedule-insns -fomit-frame-pointer -fstrength-reduce -fforce-mem -fforce-addr -funroll-loops -freduce-all-givs -Wall	85s
Linux 2.4.7-10smp (Redhat 7.2)	Pentium IV Xeon 1.7Ghz Memory : 1024Mb RDRAM ECC PC860 Cache : 8K L1, 256K L2	Portland Group pgf90	-fast	88s
Alpha Server Compaq DS20 OSF 4.0F	Mémoire : 1.2 Gb Cache Prim. : ? Cache Second. : 4 Mb	DIGITAL f90	-O4 -tune ev6 -arch ev6 -fast	99s
Alpha Server Compaq 8200 OSF 4.0F	Mémoire : 2 Gb Cache Prim. : ? Cache Second. : 4 Mb	DIGITAL f90	-O4 -tune ev6 -arch ev6 -fast	150s
Linux 2.4.7-10smp (Redhat 7.2)	Pentium IV Xeon 1.7Ghz Memory : 1024Mb RDRAM ECC PC860 Cache : 8K L1, 256K L2	GNU g77	-	173s
Linux 2.4.2-2 (Redhat 7.2)	Pentium III Coppermine 993.33Mhz Memory : 512Mb Cache : 8K L1, 256K L2	Portland Group pgf90	-fast	366s
Linux 2.4.2-2 (Redhat 7.2)	Pentium III Coppermine 993.33Mhz Memory : 512Mb Cache : 8K L1, 256K L2	GNU g77	-	466s

Jeux d'instructions

```
program ProgALU
2
3     implicit none
4     integer :: n,ndim
5     real :: x,y,deb,fin
6
7     ndim = 100000000
8     x = 1.0
9     y = 2.0
10    deb=0.
11    fin=0.
12
13    call cpu_time(deb)
14    n = 0
15    do n = 1, ndim
16        x = x + y**4
17    end do
18    call cpu_time(fin)
19
20    print*, fin-deb
21
22 end program ProgALU
```

Résultat du calcul de

y^4	12.76 s
$y \times y \times y \times y$	0.51 s
$y/16$	0.57 s
$y \times 0.0625$	0.33 s

En utilisant les directives d'optimisation à la compilation **-O3** ce temps devient négligeable et équivalent.

Flops

Flops

La performance s'exprime en opérations à virgule flottante par seconde (Floating point Operations Per Second)

La puissance crête (point de vue théorique) mesure les performances des unités de calcul à virgule flottante (FPU) contenues dans le cœur

Exemple : Intel Core(TM) i7

4 coeurs, 2.6 GHz, registres vectoriels 16 (simple précision) ou 8 (double)

performance crête : $4 \times 2.6 \times 16 = 166.4 \text{ GFlops}$

En pratique, la puissance d'une machine dépend

- des accès mémoire
- de la vitesse des bus
(communication interne et réseau)
- du système d'exploitation
- de la charge de la machine
- la taille des mémoires caches

Impact de la complexité

Calcul de

$$\sum_{j=1}^n \sum_{i=1}^n (a_i + b_i) c_j$$

Traduction littérale en Fortran

```
do j=1,n
  do i=1,n
    d(i) = d(i) + (a(i) + b(i)) * c(j)
  end do
end do
```

Nombre d'opérations (flops) : $n \times n \times 3$

Complexité, flops et intensité

Complexité algorithmique :
nombre d'opérations

Estimation du temps d'exécution :

- dépend directement du nombre de cycles d'horloge effectuées par les opérations

En supposant que les opérations élémentaires durent 2.75 cycles d'horloge, sur un processeur intel7 cadencé à 2.6 GHz (milliards de cycles d'horloge par seconde)

$$n \times n \times 3 / (2.6 \times 1\text{e}9) \times 2.75 \sim 31 \text{ secondes}$$

(ordre de grandeur)

```
real 0m36,514s
user 0m36,489s
sys 0m0,016s
```

- mais aussi du mode d'adressage du processeur (à la manière dont il va accéder à la mémoire), du nombre de caches, de la bande passante, etc.

Intensité arithmétique :
nombre d'opérations / quantité de mémoire échangée

Optimisation

```
! preprocessing
do i=1,n
    d(i) = 0.0D0
    s(i) = a(i) + b(i)
end do

! calcul
do j=1,n
    do i=1,n
        d(i) = d(i) + s(i) * c(j)
    end do
end do
```

Nombre d'opérations : $n + (2 \times n \times n)$
Réduction du temps de calcul global
de $\sim 1/3$

```
! preprocessing
sum_c = 0.0D0
do i=1,n
    d(i) = 0.0D0
    s(i) = a(i) + b(i)
    sum_c = sum_c + c(i)
end do

! calcul
do i=1,n
    d(i) = s(i) * sum_c
end do
```

Nombre d'opérations : $3 \times n$
Temps de calcul : négligeable

```
real 0m0,033s
user 0m0,020s
sys 0m0,012s
```

Mémoire

Il existe plusieurs sortes de mémoires

- la RAM (Random Access Memory)
 - barrette physiques fixées à la carte mère
 - volatile (perd le contenu si on coupe le courant)
 - mémoire vive virtuelle : swap
- le disque dur
 - stockage des données
 - sauvegarde sur du long terme
- la mémoire cache
 - petite mémoire interne au processeur
 - d'accès très rapide

La bande passante caractérise un débit d'informations en octets par seconde.

La latence désigne le temps minimum d'établissement de l'accès, mesuré en secondes.

Hiérarchie

Type	Taille	Vitesse	Coût unitaire
registre	< 1 KB	< 1 ns	\$\$\$\$
SRAM On-chip	8 KB - 6 MB	< 10 ns	\$\$\$
SRAM Off-chip	1 MB - 16 MB	< 20 ns	\$\$
DRAM	64 MB - 1 TB	< 100 ns	\$
flash	64 MB - 32 GB	< 100 μ s	c
disk	40 GB - 1 0B	< 20 ms	~

La bande passante et la vitesse augmentent avec la proximité avec le cœur

La latence augmente avec la taille

L'accès aux données est un des principaux facteurs limitant la performance

L'équilibre d'une machine se mesure par le ratio de la bande passante mémoire avec la performance crête

Fonctionnement des caches

- le cache est divisé en **lignes (ou blocs) de mots**
- 2 niveaux de granularité :
 - le CPU travaille sur des mots (par ex. de 32 ou 64 bits)
 - les transferts mémoire se font par ligne (ou blocs) (par ex. 256 octets)
- les lignes de caches sont organisées en ensembles à l'intérieur du cache, la taille de ces ensembles est constante et appelée le **degré d'associativité**
- exploitation de la **localité spatiale** : le cache contient des copies des mots par lignes de cache
- exploitation de la **localité temporelle** : choix judicieux des lignes de cache à retirer lorsqu'il faut ajouter une ligne à un cache déjà plein

Lorsque le processeur tente d'accéder à une information (instruction ou donnée), si l'information est dans le cache (**hit**), il n'y a pas d'attente, sinon (**miss**) le cache est chargé avec un bloc d'informations de la mémoire.

Principe de localité

Localité temporelle

Lorsqu'un programme accède à une donnée ou à une instruction, il est probable qu'il y accèdera à nouveau dans un futur proche

Localité spatiale

Lorsqu'un programme accède à une donnée ou à une instruction, il est probable qu'il accèdera ensuite aux données ou instructions voisines

```
subroutine sumVec(vec,n)
2
3     integer :: n,vec(n)
4     integer :: i,sum=0
5     do n = 1, n
6         sum = sum + vec(i)
7         end do
8     end subroutine
```

- bonne localité spatiale des données du tableau par son accès séquentiel
- bonne localité temporelle de la donnée sum par son accès fréquent

Localité temporelle

```
2      do n = 1, 100000  
3          x = vec(n)  
4          y = vec(n+k)  
5      end do
```

- conserver $\text{vec}(n+k)$ en mémoire rapide jusqu'à sa prochaine utilisation à l'itération $n+k$
- si on veut exploiter les registres, il faut au moins k registres
- dans le cas général, on aura besoin de stocker d'autres données

Localité spatiale

manipulation de tableaux 2D : les données sont stockées dans un bloc mémoire contigu sous la forme d'un vecteur

```
1      ndim = 40000
2      do j = 1, ndim
3          do i = 1, ndim
4              y = a(i,j)*x(j)
5          end do
6      end do
```

time : 3.68 secondes

```
1      ndim = 40000
2      do i = 1, ndim
3          do j = 1, ndim
4              y = a(i,j)*x(j)
5          end do
6      end do
```

time : 31.61 secondes

- en **Fortran** stockage par colonnes (l'indice le plus à gauche varie le plus vite). donc si la matrice a une grande taille dans une direction, la placer en 1er indice et faire les boucles les plus internes sur le premier indice
- en **C** stockage par ligne. l'optimal est l'inverse du Fortran

respecter l'alignement en mémoire des tableaux, réduit les défauts de cache

Mémoire cache

Principe

Le processeur a besoin d'un débit soutenu en lecture d'instructions et de données pour ne pas attendre sans rien faire

Problème

La mémoire centrale qui stocke ces instructions et données est beaucoup trop lente pour assurer ce débit

Solution

Utiliser une mémoire très rapide intermédiaire entre la mémoire centrale et le processeur (cache) et exploiter sa localité

Organisation des caches

Il y a différents niveaux de cache.

- Le cache L_1 est le plus rapide, mais le plus petit. Il est scindé en deux parties, données et instructions, la notion de localité s'appliquant différemment pour les données et les instructions.
- Le cache L_{i+1} joue de rôle de cache pour le niveau L_i .

Certains niveaux de caches (souvent L_3 mais parfois L_2) peuvent être partagé entre plusieurs coeurs : c'est moins cher, mais potentiellement les accès sont plus lents car il peut y avoir des problèmes d'accès concurrents.

Aider le compilateur

L'optimisation du compilateur est inhibée par :

- Boucles sans compteur
- Appel de sous-programmes dans une boucle
- Condition de sortie non standard
- Aliasing (pointeurs)
- Tests à l'intérieur des boucles

Il est donc important d'aider le compilateur, en s'inspirant de ce qu'il cherche à faire :

- Alignement de données
- Transformations de boucles
- Inlining
- Détection des invariants, etc.

Exemple avec le produit de deux matrices carrées

$n = 1024$

$$C_{ij} = \sum_{k=1}^{k=n} A_{ik} B_{kj}$$

$n \times n \times n \times 2$ opérations

Algorithme proche de l'expression mathématique

(respecte l'alignement pour le Fortran)

```
do k=1,n
  do j=1,n
    do i=1,n
      c(i,j) = c(i,j) + a(i,k)*b(k,j)
    end do
  end do
end do
```

1.45s

Déroulage de boucles (loop unrolling)

```
do j=1,n
  do k=1,n,2
    do i=1,n
      s0 = a(i,k)*b(k,j)
      s1 = a(i,k+1)*b(k+1,j)
      c(i,j) = c(i,j) + s0+s1
    end do
  end do
end do
```

Augmente le parallélisme d'instructions ; optimal dépendant de l'architecture
(généralement réalisé par le compilateur)

0.88s

Découpage par blocs

```
is = 8
js = 8
ks = 8
do k=1,n,ks
    do j=1,n,js
        do i=1,n,is
            do kk=k,min(n,k+ks-1)
                do jj=j,min(n,j+js-1)
                    do ii=i,min(n,i+is-1)
                        c(ii,jj) = c(ii,jj) + a(ii,kk)*b(kk,jj)
                    end do
                end do
            end do
        end do
    end do
end do
end do
```

Adapter la taille des blocs pour qu'ils tiennent dans le cache

1.84s

Transposée

```
do k=1,n
  do j=1,n
    bt(j,k) = b(k,j)
  end do
end do
do k=1,n
  do j=1,n
    do i=1,n
      c(i,j) = c(i,j) + a(i,k)*bt(j,k)
    end do
  end do
end do
```

0.88s

Utilisation de bibliothèques optimisées

```
148 subroutine prod blas(n,a,b,c)
! product of matrice
150
! declarations
152 implicit none
153 integer, intent(in) :: n
154 real*8, dimension(:, :), intent(in) :: a,b
155 real*8, dimension(:, :), intent(out) :: c
156
! C = 1 x A x B + 0 x C
157 call DGEMM('N','N',n,n,n,1.D0,a,n,b,n,0.D0,c,n)
158
160 end subroutine prod blas
```

Bibliothèque optimisée BLAS (Basic Linear Algebra Subprogram)

0.17s

Distribution de boucles

Améliore la vectorisation et optimise l'usage du cache pour chaque boucle.

version initiale

```
do i = 2,n-1  
2   a(i+1) = b(i-1) + c(i)  
   b(i) = a(i)*k  
4   c(i) = b(i)-1  
end do
```

version optimisée

```
do i = 2,n-1  
2   a(i+1) = b(i-1) + c(i)  
   b(i) = a(i)*k  
4 end do  
do i = 2,n-1  
6   c(i) = b(i)-1  
end do
```

version initiale

```
do i = 1,n  
2   c(i) = 0.  
   do j = 1,n  
4     c(i) = c(i) + a(i,j)*b(j)  
   end do  
6 end do
```

version vectorisable

```
do i = 1,n  
2   c(i) = 0.  
end do  
4 do j = 1,n  
   do i = 1,n  
6     c(i) = c(i) + a(i,j)*b(j)  
   end do  
8 end do
```

Sortir les conditions des boucles

version initiale

```
do i = 1,n  
2   a(i) = b(i) + c(i)  
     if (expression) d(i) = 0.  
4 end do
```

version optimisée

```
if (expression) then  
2   do i = 1,n  
     a(i) = b(i) + c(i)  
     d(i) = 0.  
   end do  
4 else  
   do i = 1,n  
8     a(i) = b(i) + c(i)  
   end do  
10 end if
```

version initiale

```
do i = 1,n  
2   a(i) = b(i) + c(i)  
     if (i > 10) then  
       d(i) = a(i) + a(i-10)  
     end if  
6 end do
```

version optimisée

```
do i = 1,10  
2   a(i) = b(i) + c(i)  
end do  
4 do i = 11,n  
   a(i) = b(i) + c(i)  
6   d(i) = a(i) + a(i-10)  
end do
```

Sortir les invariants des boucles

version initiale

```
1 do i = 1,n  
2   a(i) = b(i) + c/d  
3 end do
```

version optimisée

```
cst = c/d  
2 do i = 1,n  
3   a(i) = b(i) + cst  
4 end do
```

version initiale

```
1 do k = 1,n  
2   c(k) = 2*(p-q)*(n-k+1)/(n*n+n)  
3 end do
```

version optimisée

```
fact = 2*(p-q)  
2 denom = n*n+n  
do k = 1,n  
  c(k) = fact*(n-k+1)/denom  
end do
```

Inlining

Évite l'overhead lié à l'appel des petites procédures dans les boucles
version initiale

```
1 do i = 1,n  
2   call func(a(i))  
3 end do
```

```
1 do i = 1,n  
2   ! corps de la routine func  
3   ! ...  
4 end do
```

Inlining en C

```
1 inline double Rand()  
2 // random number between -1 and 1  
3 {  
4     return 1-(random()*MAXRND);  
5 }
```

```
1 for (int i=0; i<=NX; i++)  
2 {  
3     U1k(i)=Complexe(Rand(),Rand());  
4     U2k(i)=Complexe(Rand(),Rand());  
5     U3k(i)=Complexe(Rand(),Rand());  
6 }
```

Éviter les conversions de type inutiles

version initiale

```
real*8 :: a(n)
2 do i = 1,n
    a(i) = 2 * a(i)
4 end do
```

version optimisée

```
real*8 :: a(n)
2 do i = 1,n
    a(i) = 2.D0 * a(i)
4 end do
```

Compter les opérations dans les expressions

Pas uniquement un problème d'algorithme mais d'arithmétique

Éviter les opérations inutiles (ou trop coûteuses)

version initiale

```
y = a + b * x + c * x**2 + d * x**3
```

7 multiplications et 3 additions
version initiale

```
1 up = val[(i-1)*n + j];
2 down = val[(i+1)*n + j];
3 left = val[i*n + j-1];
4 right= val[i*n + j+1];
5 sum = up + down + left + right;
```

3 multiplications

version optimisée

```
y = a + (b + (c + d*x)*x)*x
```

3 multiplications et 3 additions
version optimisée

```
1 int inj = i*n + j;
2 up = val[inj - n];
3 down = val[inj + n];
4 left = val[inj - 1];
5 right= val[inj + 1];
6 sum = up + down + left + right;
```

1 multiplication

Profiling

Historique

- 1970s Outils d'analyse de performance basés sur une mesure d'intervalles de temps, développés sur IBM/360 et IBM/370 ;
- 1973 Outils d'analyse de codes sous Unix ;
 prof : liste les instructions et le temps d'exécution ;
- 1974 Développements d'outils de simulation du jeu d'instructions
(accès aux traces et autres mesures de performances) ;
- 1982 gprof : extension à l'analyse du graphe d'appel ;
- 1994 Développement d'ATOM (DEC) : bibliothèque d'instrumentation ajoutant des instructions à la compilation ;
- 2006 Essor de profilers de compilateurs JIT (Just In Time) pour les langages de haut niveau

Principles

Observer le comportement d'un programme à l'exécution

- Identifier les fonctions les plus consommatoires en CPU
- Connaître le temps passé à appeler les fonctions et bibliothèques
- Identifier la séquence des instructions
- Suivre l'allocation de la mémoire
- Identifier la matrice des communications, suivre l'équilibrage des charges
- Obtenir le coût des synchronisations, de l'ordonnanceur de tâches
- Mesurer le volume et débit des I/O

Étapes de profiling de code

- Préparer le programme
 - recompiler avec une option spécifique
 - Exécuter le programme
 - éventuellement sous le contrôle d'un outil
 - enregistrer les statistiques (en mémoire ou dans un fichier)
 - Analyser les statistiques
-
- Instrumentation statique (à la compilation)
 - Instrumentation dynamique (à l'exécution)

Différentes approches d'analyse de performance

Échantillonnage

- l'exécution du programme est suspendue périodiquement pour effectuer des mesures
- inférence statistique du comportement du programme
- fonctionne sans modification particulière du programme

Instrumentation

- des capteurs sont insérés dans le code pour obtenir des informations détaillées
- biais important sur les petites fonctions
- nécessite la modification du code source

Virtualisation

- exécution sur une machine virtuelle construite pour accéder à toutes les métriques
- méthode très lente

Profiling

- obtention de temps d'exécution (statistiques, génération de résumés)
- souvent basé sur de l'échantillonnage

Tracing

- obtention de cartographies, de chronologies (connexions, génération d'un journal de bord)
- souvent basé sur de l'instrumentation

Différents types de sorties

- Profils plats
 - temps CPU passé dans chaque fonction
 - nombre de fois où une fonction est appelée
 - ⇒ utile pour connaître les fonctions les plus coûteuses
- Graphes d'appels
 - nombre de fois où une fonction est appelée par d'autres
 - nombre de fois où une fonction en appelle d'autres
 - ⇒ utile pour identifier la relation entre les fonctions
 - ⇒ suggère la suppression de certains appels
- Sources annotées
 - indique le nombre de fois où une ligne est exécutée

Mesures

Mesure non intrusive du temps

time donne de façon non intrusive le temps d'exécution d'une commande exécutée par le SHELL

```
acadiou@plume: ~$ sleep 5
```

```
acadiou@plume: ~$ time sleep 5 > cmd.out 2>&1
real 0m5.004s
user 0m0.004s
sys 0m0.000s
acadiou@plume: ~$ ls -l cmd.out
-rw-rw-r-- 1 acadiou acadiou 0 avril 17 17:44 cmd.out
```

real temps réel (walltime) écoulé pendant l'exécution

user temps CPU occupé par le programme

sys temps CPU utilisé par le programme pour faire des appels système

Le temps peut varier d'une exécution à l'autre (données statistiques)

Commande UNIX

/usr/bin/time commande unix qui retourne de façon non intrusive le temps d'exécution d'un programme

```
acadiou@plume: ~$ /usr/bin/time sleep 5 > prog.out 2>&1
acadiou@plume: ~$ cat prog.out

0.00user 0.00system 0:05.00elapsed 0%CPU (0avgtext+0avgdata 1832maxresident)k
0inputs+0outputs (0major+72minor)pagefaults 0swaps

acadiou@plume: ~$ /usr/bin/time -p sleep 5 > prog_format.out 2>&1
acadiou@plume: ~$ cat prog_format.out

real 5.00
user 0.00
sys 0.00
```

man time

perf

perf commande unix qui retourne de façon non intrusive le temps d'exécution d'un programme

Il est nécessaire de modifier les fichiers de configuration par défaut pour permettre aux utilisateurs dans droits d'administration de les exploiter :

```
sudo sh -c 'echo -1 >/proc/sys/kernel/perf_event_paranoid'
```

Liste des actions

```
perf list
```

Statistiques

```
perf stat -e cycles,instructions,cache-misses
```

Trace enregistrée dans un fichier perf.data

```
perf record -p PID
```

Reporting (lecture de perf.data)

```
perf report  
perf report --stdio > perf.log
```

Exemple d'usage

```
$ perf stat -e cpu-clock sleep 5

Performance counter stats for 'sleep 5':

    2,042808 cpu-clock (msec) # 0,000 CPUs utilized

    5,003590297 seconds time elapsed
```

```
$ perf stat sleep 5

Performance counter stats for 'sleep 5':

    0,800250 task-clock (msec) # 0,000 CPUs utilized
        1 context-switches # 0,001 M/sec
        0 cpu-migrations # 0,000 K/sec
        63 page-faults # 0,079 M/sec
    1 187 237 cycles # 1,484 GHz
    909 456 instructions # 0,77 insn per cycle
    181 157 branches # 226,376 M/sec
        8 321 branch-misses # 4,59% of all branches

    5,001312184 seconds time elapsed
```

Mesure intrusive du temps

Appel de routines intrinsèques

Exemple en Fortran 90

- `dtime` Elapsed real time.
- `cpu_time` Elapsed CPU time. Fortran 90.

Temps CPU mesuré en secondes

```
real :: beg_cpu_time,end_cpu_time
call CPU_TIME(beg_cpu_time)
...
call CPU_TIME(end_cpu_time)
write(*,*) "Elapsed CPU time: ",end_cpu_time-beg_cpu_time
```

Exemple en C

- `#include <time.h>` Processor time used by the process. Diviser par `CLOCKS_PER_SEC` pour une mesure en secondes.

```
#include <stdio.h>
#include <time.h> /* clock_t, clock, CLOCKS_PER_SEC */
clock_t clock_t beg_cpu_time,end_cpu_time;
double time_elapsed_s;
beg_cpu_time = clock();
...
end_cpu_time = clock();
time_elapsed_s = (end_cpu_time-beg_cpu_time)/(double) CLOCKS_PER_SEC;
printf("Elapsed CPU time (s): %f \n", time_elapsed_s);
```

Exemple en Python

- `timeit.default_timer()` Python 3.3+
- `time.process_time()` Python 2.7+

```
import timeit

beg_cpu_time = timeit.default_timer()
...
end_cpu_time = timeit.default_timer()
print("Elapsed CPU time: ",end_cpu_time-beg_cpu_time)
```

Utiliser `%time` et `%timeit` avec Ipython ou Jupyter

Suivi de l'occupation mémoire

Suivi interactif pendant l'exécution

- `top`
- `htop`
- `free -m`

Outils de monitoring

- `gnome-system-monitor`
- `vmstat`
- `perf`

Qu'est ce qui tourne ?

top

- **h** affiche l'aide
- **m** affiche l'occupation mémoire (3 affichages)
- **M** trie par occupation mémoire
- **P** affiche les tâches sur les processus CPU
- **P** trie par processus CPU
- **k PID SIGNAL** tue le processus d'ID PID avec le signal SIGNAL (généralement 9)
- **q** quitter

alternative **htop** : suivre les instructions, en commençant par l'aide (F1)

Mémoire utilisée

free -m

```
total used free shared buffers cached
Mem: 258313 10840 149907 0 108 104596
-/+ buffers/cache: 3701 254611
Swap: 260511 127 260384
```

Afficher en gigabytes

free -g

et plus ...

free --tera

vmstat

```
procs -----memory----- ---swap-- -----io---- -system-- -----cpu-----
 r b swpd free buff cache si so bi bo in cs us sy id wa st
 0 0 0 18803116 1819280 8749912 0 0 36 67 186 167 6 1 93 0 0
```

Afficher la liste des processus

ps

```
PID TTY TIME CMD
6754 pts/28 00:00:00 bash
6767 pts/28 00:00:00 ps
```

Options utiles

ps -edf |grep commande

ps aux

ps -A --forest

ps -u user

Suivi pendant le calcul

Enregistrer l'occupation mémoire occupé par le processus 418 (thunderbird)
(6 enregistrements toutes les secondes)

```
pidstat -r -p 418 1 5 >> mem.log
```

```
Linux 4.4.0-119-generic (plume) 19/04/2018 _x86_64_ (4 CPU)

15:59:07 UID PID minflt/s majflt/s VSZ RSS %MEM Command
15:59:08 1000 418 0,00 0,00 2572484 486984 1,48 thunderbird
15:59:09 1000 418 201,00 0,00 2572484 487016 1,48 thunderbird
15:59:10 1000 418 0,00 0,00 2572484 487016 1,48 thunderbird
15:59:11 1000 418 0,00 0,00 2572484 487016 1,48 thunderbird
...
...
```

```
while sleep 1; do ps --pid 418 -o pcpu= -o pmem= -o rss=; done;
```

```
2.9 1.7 590352
2.9 1.7 590352
2.9 1.8 617256
2.9 1.8 617384
2.9 1.8 622252
2.9 1.8 621100
(...)
```

Outils

Protocoles de mesure

PAPI

<http://icl.cs.utk.edu/papi>

- interface multiplateforme de compteurs hardware (opérations et cycles, accès mémoire et caches)
- utilisée par TAU, SCALASCA, ompP, mpiP

Score-P

<http://www.score-p.org>

- bibliothèque de profiling et trace pour les applications HPC
- utilisée par TAU, SCALASCA, Vampir, Periscope

Extrae

<http://tools.bsc.es/extrae>

- bibliothèque d'instrumentation
- utilisée par Paraver

Outils de base

Pour débuter

- gprof
<https://sourceware.org/binutils/docs/gprof>
- Valgrind (Callgrind, Cachegrind, Massif)
<http://valgrind.org/>

et d'autres

- VTune (commercial)
- oprofile
<http://oprofile.sourceforge.net/news/>
- ompP
<http://www.ompp-tool.com>
- perfExpert
<https://github.com/TACC/perfexpert>
- etc.

l'écosystème est très riche...

Profiling parallèle

- Intel Advisor, Trace Analyzer and Collector (commercial)

- PerfSuite

<http://perfsuite.ncsa.illinois.edu/>

- mpiP (Lightweight, Scalable MPI Profiling)

<http://mpip.sourceforge.net>

- résultat sous format texte
- à ajouter lors de l'édition de liens

- IPM (Integrated Performance Monitoring)

<http://ipm-hpc.sourceforge.net>

- résultat sous format texte
- sans recompilation

- Paraver

<https://tools.bsc.es/paraver/>

- basé sur Extrae

- HPCToolkit

<http://www.hpctoolkit.org>

- basé sur de l'échantillonnage statistique

- MAQAO (Modular Assembly Quality Analyzer and Optimizer)

<http://www.maqao.org/>

- dédié à l'analyse intra-noeud
- sans recompilation

- TAU (Tuning and Analysis Utilities)

<http://www.cs.uoregon.edu/research/tau>

- basé sur PAPI
- séquentiel, parallèle (MPI et multithread)
- graphique et ligne de commande

- SCALASCA (SCalable performance Analysis of LARgre SCale Applications)

<http://www.scalasca.org/>

- basé sur PAPI, exploite Score-P
- séquentiel, parallèle (MPI et multithread)
- graphique et ligne de commande

Outils de visualisation

- Vampir (commercial) <https://vampir.eu/>
- CUBE <http://www.scalasca.org/>
 - utilisé par SCALASCA, Score-P, PerfSuite, Marmot, ompP, etc.
- Paraver <https://tools.bsc.es/paraver/>
 - utilisé par Extrae
- PerfExplore PerfView <http://perfsuite.ncsa.illinois.edu/>
 - inclus dans PerfSuite
- etc.

Outils pour les I/O

Darshan <https://www.mcs.anl.gov/research/projects/darshan/>

- Sans recompilation, avec la variable LD_PRELOAD
- Analyse les appels à Posix, MPI-IO, HDF5 et NetCDF
- Le code doit avoir un appel à la bibliothèque MPI (e.g. MPI_Init et MPI_Finalize)
- Compatible C, C++, Fortran

Méthodologie d'analyse

Préparation

- Préparer l'environnement
- Obtenir un cas de référence
- Instrumenter le code le cas échéant

Mesure

- Collecter les données
- Aggréger les informations
- Se focaliser sur une partie (appel, mémoire, E/S)

Cycle d'analyse

Analyse

- Calculer les métriques
- Identifier les problèmes affectant les performances

Optimisation

- Modifier le code pour résoudre ou diminuer les problèmes

et reprendre la préparation et les mesures.

Exemples

Exemple basé sur gprof

<https://sourceware.org/binutils/docs-2.28/gprof/>

Somme de matrices

Comparaison de différentes implémentations contenues dans mFunc.f90

Compilation avec profiling

```
f95 -fdefault-real-8 -fdefault-double-8 -pg -c mFunc.f90
f95 -fdefault-real-8 -fdefault-double-8 -pg -c main.f90
f95 -fdefault-real-8 -fdefault-double-8 -pg mFunc.o main.o -o a.out
```

Exécution et génération du fichier de monitoring (gmon.out)

```
/usr/bin/time ./a.out > job.log
```

```
2.66user 0.09system 0:02.76elapsed 99%CPU (0avgtext+0avgdata 395084maxresident)k
0inputs+16outputs (0major+98409minor)pagefaults 0swaps
```

Analyse avec gprof

```
gprof ./a.out gmon.out > prof.log
```

prof.log contient le profil plat et le graphe d'appel sous forme de fichier texte

Profil plat

```
Flat profile:  
2  
Each sample counts as 0.01 seconds.  
4    % cumulative self self total  
     time seconds seconds calls s/call s/call name  
6  67.46 1.26 1.26 1 1.26 __func_MOD_summatijk  
27.84 1.78 0.52 1 0.52 0.52 __func_MOD_summatjik  
8  4.82 1.87 0.09 1 0.09 0.09 __func_MOD_summatkji  
  0.00 1.87 0.00 1 0.00 1.87 MAIN__
```

Le temps passé dans chaque subroutine est donné

en pourcentage du temps CPU total et en secondes

Résultat équivalent en instrumentant le code avec l'appel à CPU_TIME

```
ijk :: elapsed CPU time : 1.2160000000000002  
jik :: elapsed CPU time : 0.5959999999999964  
kji :: elapsed CPU time : 9.200000000000526E-002
```

légende

```
% the percentage of the total running time of the  
12 time program used by this function.  
  
14 cumulative a running sum of the number of seconds accounted  
seconds for by this function and those listed above it.  
16  
self the number of seconds accounted for by this  
18 seconds function alone. This is the major sort for this  
listing.  
20  
calls the number of times this function was invoked, if  
22 this function is profiled, else blank.  
  
24 self the average number of milliseconds spent in this  
ms/call function per call, if this function is profiled,  
26 else blank.  
  
28 total the average number of milliseconds spent in this  
ms/call function and its descendants per call, if this  
30 function is profiled, else blank.  
  
32 name the name of the function. This is the minor sort  
for this listing. The index shows the location of  
34 the function in the gprof listing. If the index is  
in parenthesis it shows where it would appear in  
36 the gprof listing if it were to be printed.
```

Graphe d'appel

```
44      Call graph (explanation follows)

46
47      granularity: each sample hit covers 2 byte(s) for 0.53% of 1.87 seconds
48
49      index % time self children called name
50          0.00 1.87 1/1 main [2]
51  [1] 100.0 0.00 1.87 1 MAIN__ [1]
52      1.26 0.00 1/1 __mfunc_MOD_summatjik [3]
53      0.52 0.00 1/1 __mfunc_MOD_summatjik [4]
54      0.09 0.00 1/1 __mfunc_MOD_summatkji [5]
55 -----
56
57          <spontaneous>
58  [2] 100.0 0.00 1.87 main [2]
59      0.00 1.87 1/1 MAIN__ [1]
60 -----
61      1.26 0.00 1/1 MAIN__ [1]
62  [3] 67.4 1.26 0.00 1 __mfunc_MOD_summatjik [3]
63 -----
64      0.52 0.00 1/1 MAIN__ [1]
65  [4] 27.8 0.52 0.00 1 __mfunc_MOD_summatjik [4]
66 -----
67      0.09 0.00 1/1 MAIN__ [1]
68  [5] 4.8 0.09 0.00 1 __mfunc_MOD_summatkji [5]
```

(explanation follows)

70 This table describes the call tree of the program, and was sorted by
the total amount of time spent in each function and its children.

72 Each entry in this table consists of several lines. The line with the
74 index number at the left hand margin lists the current function.
The lines above it list the functions that called this function,
76 and the lines below it list the functions this one called.
This line lists:

78 index A unique number given to each element of the table.

Index numbers are sorted numerically.

80 The index number is printed next to every function name so
it is easier to look up where the function is in the table.

82 % time This is the percentage of the 'total' time that was spent
84 in this function and its children. Note that due to
different viewpoints, functions excluded by options, etc,
86 these numbers will NOT add up to 100%.

88 self This is the total amount of time spent in this function.

90 children This is the total amount of time propagated into this
function by its children.

92 called This is the number of times the function was called.
94 If the function called itself recursively, the number
only includes non-recursive calls, and is followed by
96 a '+' and the number of recursive calls.

98 name The name of the current function. The index number is
printed after it. If the function is a member of a
100 cycle, the cycle number is printed between the
function's name and the index number.

...

102

104 For the function's parents, the fields have the following meanings:

106 self This is the amount of time that was propagated directly
from the function into this parent.

108 children This is the amount of time that was propagated from
the function's children into this parent.

112 called This is the number of times this parent called the
function '/' the total number of times the function
was called. Recursive calls to the function are not
included in the number after the '/'.

116 name This is the name of the parent. The parent's index
number is printed after it. If the parent is a
member of a cycle, the cycle number is printed between
the name and the index number.

122 If the parents of the function cannot be determined, the word
'<spontaneous>' is printed in the 'name' field, and all the other
124 fields are blank.

Options utiles

```
126 For the function's children, the fields have the following meanings:  
128     self This is the amount of time that was propagated directly  
from the child into the function.  
130     children This is the amount of time that was propagated from the  
132     child's children to the function.  
134     called This is the number of times the function called  
this child '/', the total number of times the child  
136     was called. Recursive calls by the child are not  
listed in the number after the '/'.  
138     name This is the name of the child. The child's index  
140     number is printed after it. If the child is a  
member of a cycle, the cycle number is printed  
142     between the name and the index number.  
144 If there are any cycles (circles) in the call graph, there is an  
entry for the cycle-as-a-whole. This entry shows who called the  
146     cycle (as parents) and the members of the cycle (as children.)  
The '+' recursive calls entry shows the number of function calls that  
148     were internal to the cycle, and the calls entry for each member shows,  
for that member, how many times it was called from other members of  
the cycle.
```

- **-b** : pour ne pas sortir le texte explicatif
- **--static-call-graph**
- **--graph[=symspec]** : permet de définir la racine de l'arbre (**-q[symspec]**)
- **-A** : annote le code source

Version graphique

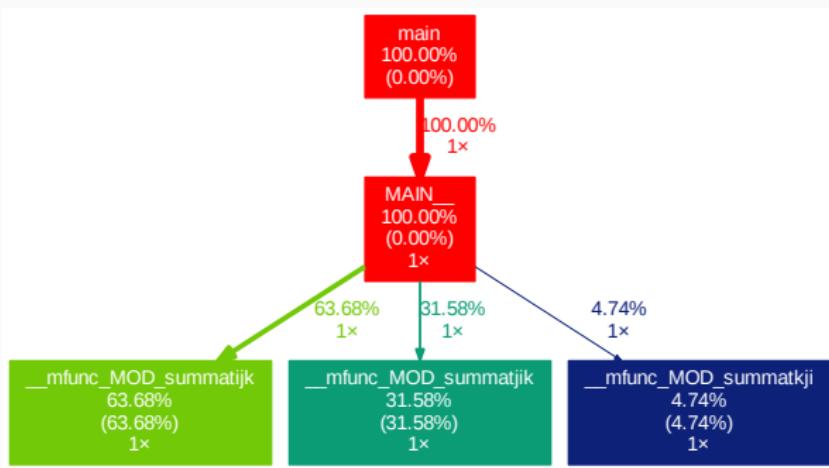
Basée sur graphviz et dot avec un petit utilitaire python gprof2dot.py

Générer le .dot

```
gprof ./a.out | ./gprof2dot.py > job.dot
```

Sortir l'image

```
dot -Tpdf job.dot -o output.pdf
```



Remarques

gprof est un outil de base limité par certains aspects :

- Contenu des traces relativement sommaire
- Peu adapté au profiling d'applications parallèles, car trop sommaire : il peut juste générer un fichier gmon.out par processus

Pour le profiling parallèle et pour demander à chaque processus d'écrire un fichier de log, il suffit de définir une valeur à la variable d'environnement GMON_OUT_PREFIX.

Dans ce cas chaque processus PID produit un gmon.out.PID

Exemple :

```
export GMON_OUT_PREFIX='gmon.out'
mpif90 -pg prof.f95 -o a.out
mpirun -np 4 ./a.out
```

génère dans l'exemple les fichiers de trace

```
-rw-rw-r-- 1 acadiou acadiou 938 mai 4 10:01 gmon.out.9817
-rw-rw-r-- 1 acadiou acadiou 938 mai 4 10:01 gmon.out.9818
-rw-rw-r-- 1 acadiou acadiou 938 mai 4 10:01 gmon.out.9819
-rw-rw-r-- 1 acadiou acadiou 938 mai 4 10:01 gmon.out.9820
```

à lire avec

```
gprof ./a.out gmon.out.*
```

Exemple basé sur valgrind

<http://valgrind.org/docs>

```
valgrind --tool=callgrind --dump-instr=yes --simulate-cache=yes --collect-jumps=yes ./a.out > valgrind_prof.log 2>&1
```

Pour différer la création du rapport, ajouter l'option `--instr-atstart=no` et lancer dans un autre terminal afin d'activer le démarrage du profiling

```
callgrind_control -i on
```

```
-rw-rw-r-- 1 acadiou acadiou 1616 avril 19 12:14 valgrind_prof.log  
-rw----- 1 acadiou acadiou 295162 avril 19 12:14 callgrind.out.14258
```

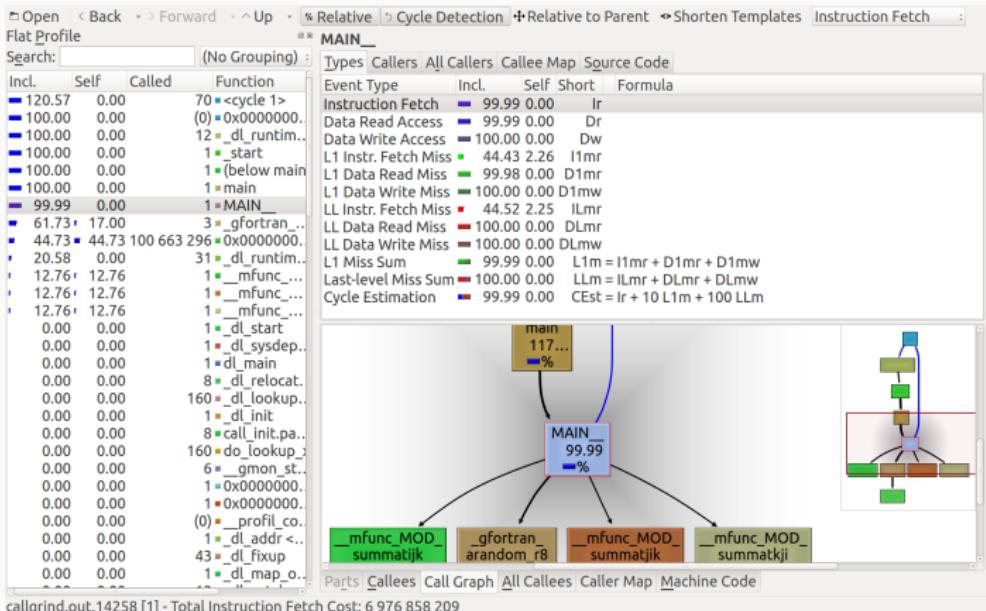
Sortie du code

```
ijk :: elapsed CPU time : 1.2160000000000002  
2 jik :: elapsed CPU time : 0.5959999999999964  
kji :: elapsed CPU time : 9.200000000000526E-002
```

Fichier de profiling

```
==14258== Callgrind, a call-graph generating cache profiler
2 ==14258== Copyright (C) 2002-2015, and GNU GPL'd, by Josef Weidendorfer et al.
==14258== Using Valgrind-3.11.0 and LibVEX; rerun with -h for copyright info
4 ==14258== Command: ./test.out
==14258==
6 --14258-- warning: L3 cache found, using its data for the LL simulation.
==14258== For interactive control, run 'callgrind_control -h'.
8 ==14258==
==14258== Events : Ir Dr Dw I1mr Dimr Dimw I1mr DLmr DLmw
10 ==14258== Collected : 6976858209 1662625553 705269796 2386 71319689 41944841 2352 71306775 41944459
==14258==
12 ==14258== I refs: 6,976,858,209
==14258== I1 misses: 2,386
14 ==14258== L1i misses: 2,352
==14258== I1 miss rate: 0.00%
16 ==14258== L1i miss rate: 0.00%
==14258==
18 ==14258== D refs: 2,367,895,349 (1,662,625,553 rd + 705,269,796 wr)
==14258== D1 misses: 113,264,530 ( 71,319,689 rd + 41,944,841 wr)
20 ==14258== LDd misses: 113,251,234 ( 71,306,775 rd + 41,944,459 wr)
==14258== D1 miss rate: 4.8% ( 4.3% + 5.9% )
22 ==14258== LDd miss rate: 4.8% ( 4.3% + 5.9% )
==14258==
24 ==14258== LL refs: 113,266,916 ( 71,322,075 rd + 41,944,841 wr)
==14258== LL misses: 113,253,586 ( 71,309,127 rd + 41,944,459 wr)
26 ==14258== LL miss rate: 1.2% ( 0.8% + 5.9% )
```

Sortie graphique avec Kcachegrind



Remarques

valgrind dégrade énormément les performances

- Peu adapté à un programme long à exécuter
- Verbeux
- Vraiment très lent

Exemple de profiling parallèle

NAS Parallel Benchmark (MPI/OpenMP)

<https://www.nas.nasa.gov/publications/npb.html>

Cas BT-MZ

- Résolution des équations de Navier-Stokes compressibles 3D
 - Grille régulière
 - Avance de 200 pas de temps (solveur tri-diagonal par blocs)
-
- NPB : The NAS Parallel Benchmarks
 - MZ : multi-zone
 - BT : Block Tri-diagonal solver

Préparation du cas test

Obtention du benchmark

```
$ wget https://www.nas.nasa.gov/assets/npb/NPB3.4-MZ.tar.gz  
$ tar xvfz NPB3.4-MZ.tar.gz  
$ cd NPB3.4-MZ  
NPB3.4-MZ$ cd NPB3.4-MZ-MPI  
NPB3.4-MZ/NPB3.4-MZ-MPI$ ls  
bin BT-MZ common config LU-MZ Makefile README README.install SP-MZ sys test_scripts
```

Sélection des options pour le Makefile en fonction du calculateur

```
cp config/NAS.samples/make.def.gcc_mpich config/make.def  
make bt-mz CLASS=B NPROCS=4
```

Options de compilation

config/make.def

```
(...)
#-----
# This is the fortran compiler used for fortran programs
#
FC = mpif90
# This links fortran programs; usually the same as ${FC}
FLINK = $(FC)

#-----
# These macros are passed to the linker
#
F_LIB =

#-----
# These macros are passed to the compiler
#
F_INC =

#-----
# Global *compile time* flags for Fortran programs
#
FFLAGS = -O3 -fopenmp
(...)
```

Compilation du benchmark - sans profiling

```
NPB3.4-MZ/NPB3.4-MZ-MPI$ make bt-mz CLASS=B NPROCS=4
=====
= NAS PARALLEL BENCHMARKS 3.4 =
= MPI+OpenMP Multi-Zone Versions =
= MPI/Fortran =
=====

cd BT-MZ; make CLASS=B VERSION=
make[1]: Entering directory 'BT-MZ'
(...
../sys/setparams bt-mz B
mpif90 -c -O3 -fopenmp bt_data.f
mpif90 -c -O3 -fopenmp mpinpb.f
mpif90 -c -O3 -fopenmp bt.f
(...
mpif90 -O3 -fopenmp -o ../bin/bt-mz.B.x bt.o bt_data.o initialize.o exact_solution.o exact_rhs.o
    set_constants.o adi.o rhs.o zone_setup.o x_solve.o y_solve.o exch_qbc.o solve_subs.o
    z_solve.o add.o error.o verify.o setup_mpi.o mpinpb.o error_cond.o ../common/print_results
    .o ../common/timers.o
make[1]: Leaving directory 'BT-MZ'
```

Exécutable dans bin/bt-mz.B.x

```
ls -lh bin
total 164K
-rwxr-xr-x 1 acadiou acadiou 162K avril 22 20:46 bt-mz.B.x
```

Exécution du benchmark

Environnement et exécution

```
export OMP_NUM_THREADS=2  
mpirun -np 2 ..../bin/bt-mz.B.x
```

Sortie

```
NAS Parallel Benchmarks (NPB3.4-MZ MPI+OpenMP) - BT-MZ Benchmark

Number of zones: 8 x 8
Total mesh size: 304 x 208 x 17
Iterations: 200 dt: 0.000300
Number of active processes: 2

Use the default load factors
Total number of threads: 4 ( 2.0 threads/process)

Calculated speedup = 4.00

Time step 1
Time step 20
(...)
Time step 200
Verification being performed for class B
accuracy setting for epsilon = 0.100000000000E-07
(...)
Verification Successful
```

```
BT-MZ Benchmark Completed.  
Class = B  
Size = 304x 208x 17  
Iterations = 200  
Time in seconds = 89.60  
Total processes = 2  
Total threads = 4  
Mop/s total = 6709.97  
Mop/s/thread = 1677.49  
Operation type = floating point
```

Compile options:

```
FC = mpif90  
FLINK = ${FC}  
F_LIB = (none)  
F_INC = (none)  
FFLAGS = -O3 -fopenmp  
FLINKFLAGS = ${FFLAGS}  
RAND = (none)  
(...)  
npb@nas.nasa.gov
```

Instrumentation

Recompilation

```
make clean
```

Changement de l'environnement

```
export PATH="/softs/scorep/bin:$PATH"
export LD_LIBRARY_PATH="/softs/scorep/lib:$LD_LIBRARY_PATH"
export PATH="/softs/scalasca-2.5/bin:$PATH"
export LD_LIBRARY_PATH="/softs/scalasca-2.5/lib:$LD_LIBRARY_PATH"
```

Modification du Makefile

```
(...)
#-----
# This is the fortran compiler used for fortran programs
#-----
FC = $(PREP) mpif90
# This links fortran programs; usually the same as ${FC}
FLINK = $(FC)
```

```
make bt-mz PREP=scorep CLASS=B NPROCS=4
```

```
ls -lh bin
total 7,9M
-rwxr-xr-x 1 acadiou acadiou 7,9M avril 22 20:47 bt-mz.B.x
```

Ré-exécution du benchmark

```
export OMP_NUM_THREADS=2  
mpirun -np 2 ../bin/bt-mz.B.x
```

Sortie

```
NAS Parallel Benchmarks (NPB3.4-MZ MPI+OpenMP) - BT-MZ Benchmark  
  
Number of zones: 8 x 8  
Total mesh size: 304 x 208 x 17  
Iterations: 200 dt: 0.000300  
Number of active processes: 2  
  
Use the default load factors  
Total number of threads: 4 ( 2.0 threads/process)  
  
Calculated speedup = 4.00  
  
Time step 1  
Time step 20  
(...)  
Time step 200  
Verification being performed for class B  
accuracy setting for epsilon = 0.100000000000E-07  
(...)  
Verification Successful
```

Coût supplémentaire en temps (overhead) lié à l'instrumentation :

```
BT-MZ Benchmark Completed.  
(...)  
Time in seconds = 100.58  
(...)  
npb@nas.nasa.gov
```

Génération des fichiers de mesure

```
$ ls -1 scorep-bt-mz/  
MANIFEST.md  
profile.cubex  
scorep.cfg
```

Rapport sous forme de texte

```
$ scorep-score scorep-bt-mz/profile.cubex

Estimated aggregate size of event trace: 50MB
Estimated requirements for largest trace buffer (max_buf): 25MB
Estimated memory requirements (SCOREP_TOTAL_MEMORY): 29MB
(hint: When tracing set SCOREP_TOTAL_MEMORY=29MB to avoid intermediate flushes or reduce requirements using USR
regions filters.)

flt type max_buf[B] visits time[s] time[%] time/visit[us] region
    ALL 26,089,663 1,218,400 404.18 100.0 331.73 ALL
    OMP 26,047,552 1,217,152 401.63 99.4 329.98 OMP
    MPI 42,070 1,246 1.91 0.5 1529.89 MPI
```

Détail par fonction

```
$ scorep-score -r scorep-bt-mz/profile.cubex

(...)

OMP 2,238,336 51,456 0.02 0.0 0.35 !$omp parallel @exch_qbc.f:217
OMP 2,238,336 51,456 0.02 0.0 0.33 !$omp parallel @exch_qbc.f:206
OMP 2,238,336 51,456 0.02 0.0 0.38 !$omp parallel @exch_qbc.f:256
OMP 2,238,336 51,456 0.02 0.0 0.35 !$omp parallel @exch_qbc.f:245
OMP 1,124,736 25,856 0.07 0.0 2.82 !$omp parallel @rhs.f:29
OMP 1,119,168 25,728 0.01 0.0 0.46 !$omp parallel @add.f:23
OMP 1,119,168 25,728 0.03 0.0 1.12 !$omp parallel @y_solve.f:44
OMP 1,119,168 25,728 0.03 0.0 1.13 !$omp parallel @x_solve.f:47
OMP 1,119,168 25,728 0.03 0.0 1.21 !$omp parallel @z_solve.f:44
OMP 668,928 51,456 0.04 0.0 0.87 !$omp implicit barrier @exch_qbc.f:215
(...)
```

```
(...)
MPI 17,889 402 0.01 0.0 18.03 MPI_Isend
MPI 17,889 402 0.00 0.0 7.97 MPI_Irecv
OMP 11,136 256 0.00 0.0 2.95 !$omp parallel @initialize.f:23
OMP 8,320 640 0.00 0.0 0.20 !$omp atomic @error.f:104
OMP 8,320 640 0.00 0.0 0.18 !$omp atomic @error.f:51
OMP 5,568 128 0.00 0.0 1.35 !$omp parallel @error.f:87
OMP 5,568 128 0.00 0.0 2.10 !$omp parallel @exact_rhs.f:22
OMP 5,568 128 0.00 0.0 1.34 !$omp parallel @error.f:28
MPI 5,226 402 1.61 0.4 4013.78 MPI_Waitall
(...)

MPI 476 14 0.00 0.0 106.39 MPI_Bcast
MPI 204 6 0.00 0.0 582.44 MPI_Reduce
MPI 136 4 0.01 0.0 1256.30 MPI_Barrier
MPI 68 2 0.00 0.0 86.88 MPI_Allgather
MPI 52 4 0.00 0.0 0.75 MPI_Comm_rank
MPI 52 4 0.00 0.0 3.03 MPI_Comm_size
MPI 26 2 0.00 0.0 105.51 MPI_Comm_split
```

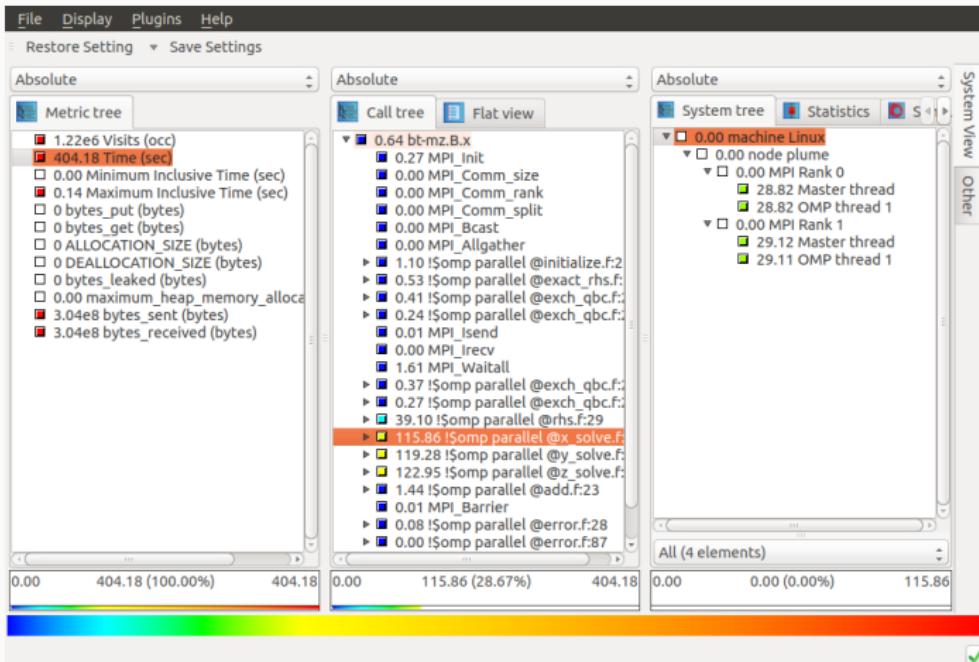
Profil plat extrait avec CUBE

```
$ cube_stat -t 20 -p scorep-bt-mz/profile.cubex

cube::Region NumberOfCalls ExclusiveTime InclusiveTime
!$omp do @z_solve.f:51 25728 121.182131 121.182131
!$omp do @y_solve.f:51 25728 117.609398 117.609398
!$omp do @x_solve.f:53 25728 114.142487 114.142487
!$omp do @rhs.f:292 25856 10.884323 10.884323
!$omp do @rhs.f:182 25856 10.555631 10.555631
!$omp do @rhs.f:77 25856 10.358581 10.358581
!$omp do @rhs.f:34 25856 3.031725 3.031725
!$omp do @rhs.f:59 25856 2.408346 2.561018
!$omp implicit barrier @z_solve.f:427 25728 1.740977 1.740977
!$omp implicit barrier @x_solve.f:406 25728 1.689967 1.689967
!$omp implicit barrier @y_solve.f:405 25728 1.644672 1.644672
MPI_Waitall 402 1.613540 1.613540
!$omp do @add.f:23 25728 1.343585 1.425174
!$omp do @rhs.f:399 25856 1.040513 1.040513
!$omp do @initialize.f:51 256 0.995974 0.995974
bt-mz.B.x 2 0.639516 404.180371
!$omp implicit barrier @rhs.f:410 25856 0.573769 0.573769
!$omp do @exch_qbc.f:256 51456 0.352579 0.392707
!$omp do @exch_qbc.f:245 51456 0.306733 0.356091
MPI_Init 2 0.271824 0.271824
```

Graphe d'appel avec CUBE

```
$ cube scorep-bt-mz/profile.cubex
```



Analyse avec SCALASCA

```
scalasca -analyze mpirun -np 2 ..../bin/bt-mz.B.x

S=C=A=N: Scalasca 2.5 runtime summarization
S=C=A=N: ./scorep_bt-mz_2x2_sum experiment archive
S=C=A=N: Mon Apr 22 22:11:51 2019: Collect start
(...)
Iterations = 200
Time in seconds = 100.02
(...)
S=C=A=N: Mon Apr 22 22:13:33 2019: Collect done (status=0) 102s
S=C=A=N: ./scorep_bt-mz_2x2_sum complete.
```

Génération des fichiers de sortie

```
$ ls -1 scorep_bt-mz_2x2_sum/
MANIFEST.md
profile.cubex
scorep.cfg
scorep.log
```

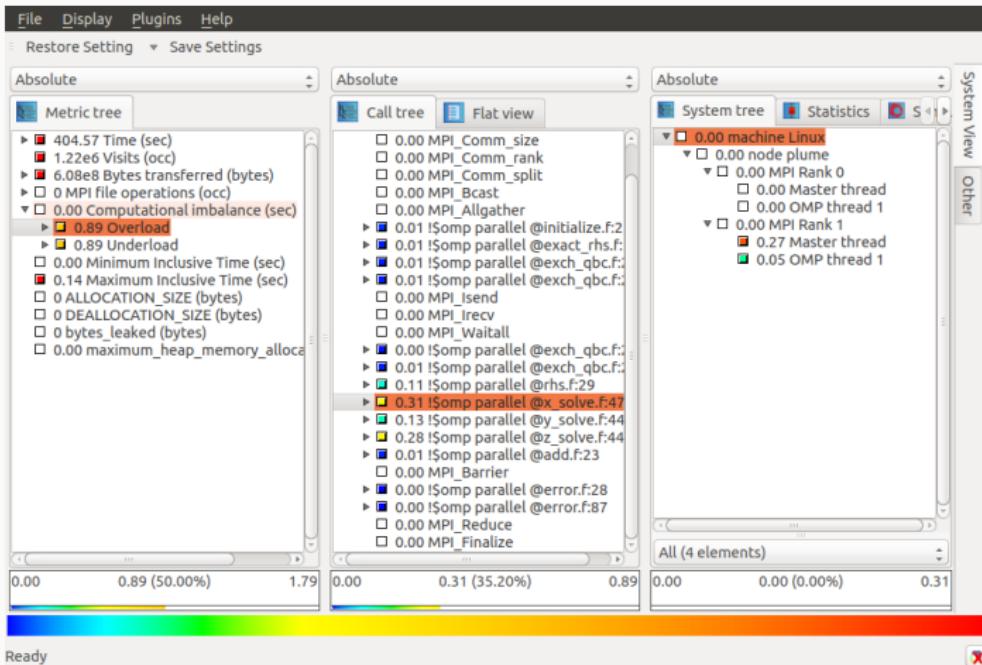
Examen des fichiers de sortie

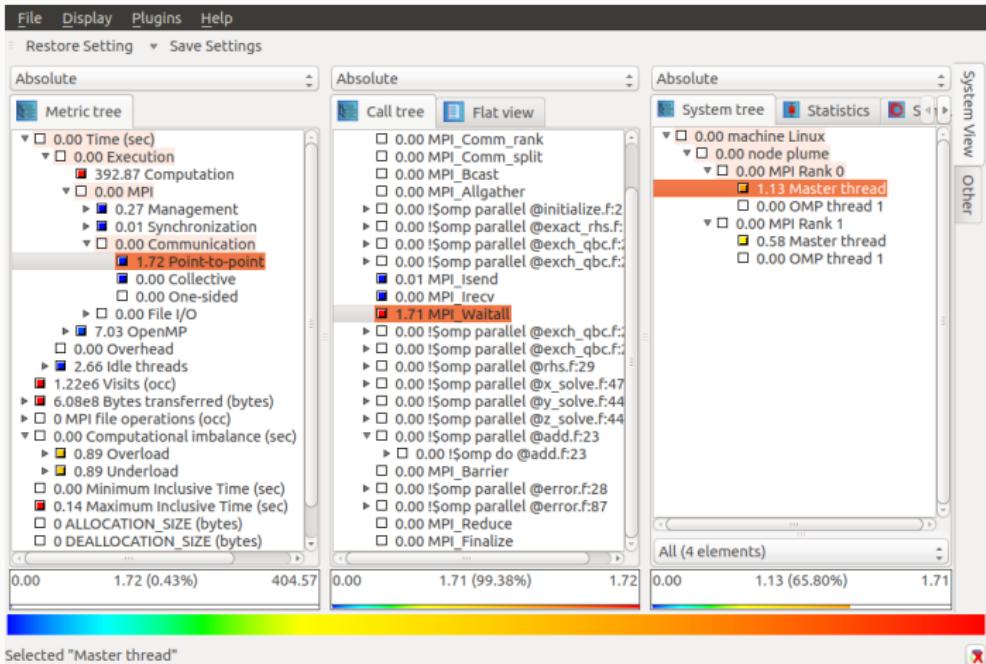
```
scalasca -examine -s scorep_bt-mz_2x2_sum

INFO: Post-processing runtime summarization report (profile.cubex)...
/softs/scorep/bin/scorep-score -r ./scorep_bt-mz_2x2_sum/profile.cubex > ./scorep_bt-mz_2x2_sum/
    scorep.score
INFO: Score report written to ./scorep_bt-mz_2x2_sum/scorep.score
```

Visualisation avec CUBE

```
$ cube scorep-bt-mz/summary.cubex
```





Références

Références

- Introduction à l'Optimisation de codes sur les Systèmes de Calcul Haute Performance, N. Renon, 2007
- Optimization techniques, S. Cozzini, 2008
- Code Optimization I: Machine Independent Optimizations, D.S. Fussell, 2011
- Performances et Optimisations, V. Louvet, 2011-2012
- Optimization techniques, A. Cassagne, 2014
- Optimisation séquentielle, IDRIS, 2016
- VI-HPS Tool guide
- NAS Benchmarks
- Tutoriels <https://computing.llnl.gov/>
- G. Markomanolis *Studying the behavior of parallel applications and identifying bottlenecks by using performance analysis tools*, École Méthodologie et outils d'optimisation en développement logiciel, IN2P3, 2012