Performance

Analyse : Mesure et Optimisation

Romaric David
david@unistra.fr
Direction Informatique
17/10/2013

UNIVERSITÉ DE STRASBOURG

Plan

- Performance ? What is it all about ?
- Mesure
- Optimisation : CPU
- Optimisation : mémoire
- Conclusion

Mesure, Optimisation

- En tant qu'utilisateur, nous sommes sensibles au **temps d'exécution** d'une application, à son **empreinte mémoire** et aux **ressources** qu'elle consomme. Cet atelier présente les outils à notre disposition pour mesurer ces différentes grandeurs ⇒ **Profiling**.
- L'atelier illustrera également quelques méthodes pour consommer moins de temps, mémoire et de ressources ⇒ **Optimisation**.
- Les programmes étudiés pour cet atelier sont des programmes séquentiels en C.

Mesure basique

- Mesure du temps d'exécution

  Outil externe : **time** ou **/usr/bin/time**
- time [executable]
  - Temps total (wall-clock time)
  - Temps en mode utilisateur (user)
  - Temps passé dans les appels système (sys). Exemple : printf, read, write, ...
  - Wall-clock = user + sys + temps d'attente i/o
- Appel système équivalent : **getrusage**
- Ceci ne donne qu'une vision globale du déroulé

TP 0 : Obtention des fichiers

- Connectez-vous sur vos PC
- `wget  http://hpc-web.u-strasbg.fr/optim.tgz`
- Décompressez l'archive
- Vous obtenez un répertoire `optim_base`

TP 1 : Temps d'exécution

- Nous utilisons le fichier `optim_base/jv/jv.c`
- Compilez ce programme
- Exécutez le programme par `time ./executable`
- Que peut-on dire du temps passé en I/O ?

Mesure : 1 première loupe

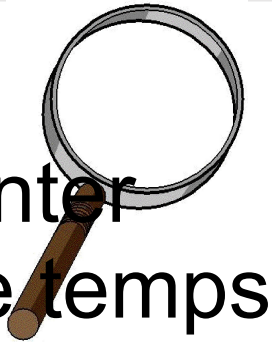

- À la compilation, il est possible d'instrumenter automatiquement le code, pour mesurer le temps passé routine par routine.
- Par échantillonnage à l'exécution, le programme examinera la fonction dans laquelle il se trouve et lui attribuera le quantum de temps écoulé
- Un profil est généré à la fin de l'exécution
- Ce profil est analysé avec gprof

Mesure : 1 première loupe

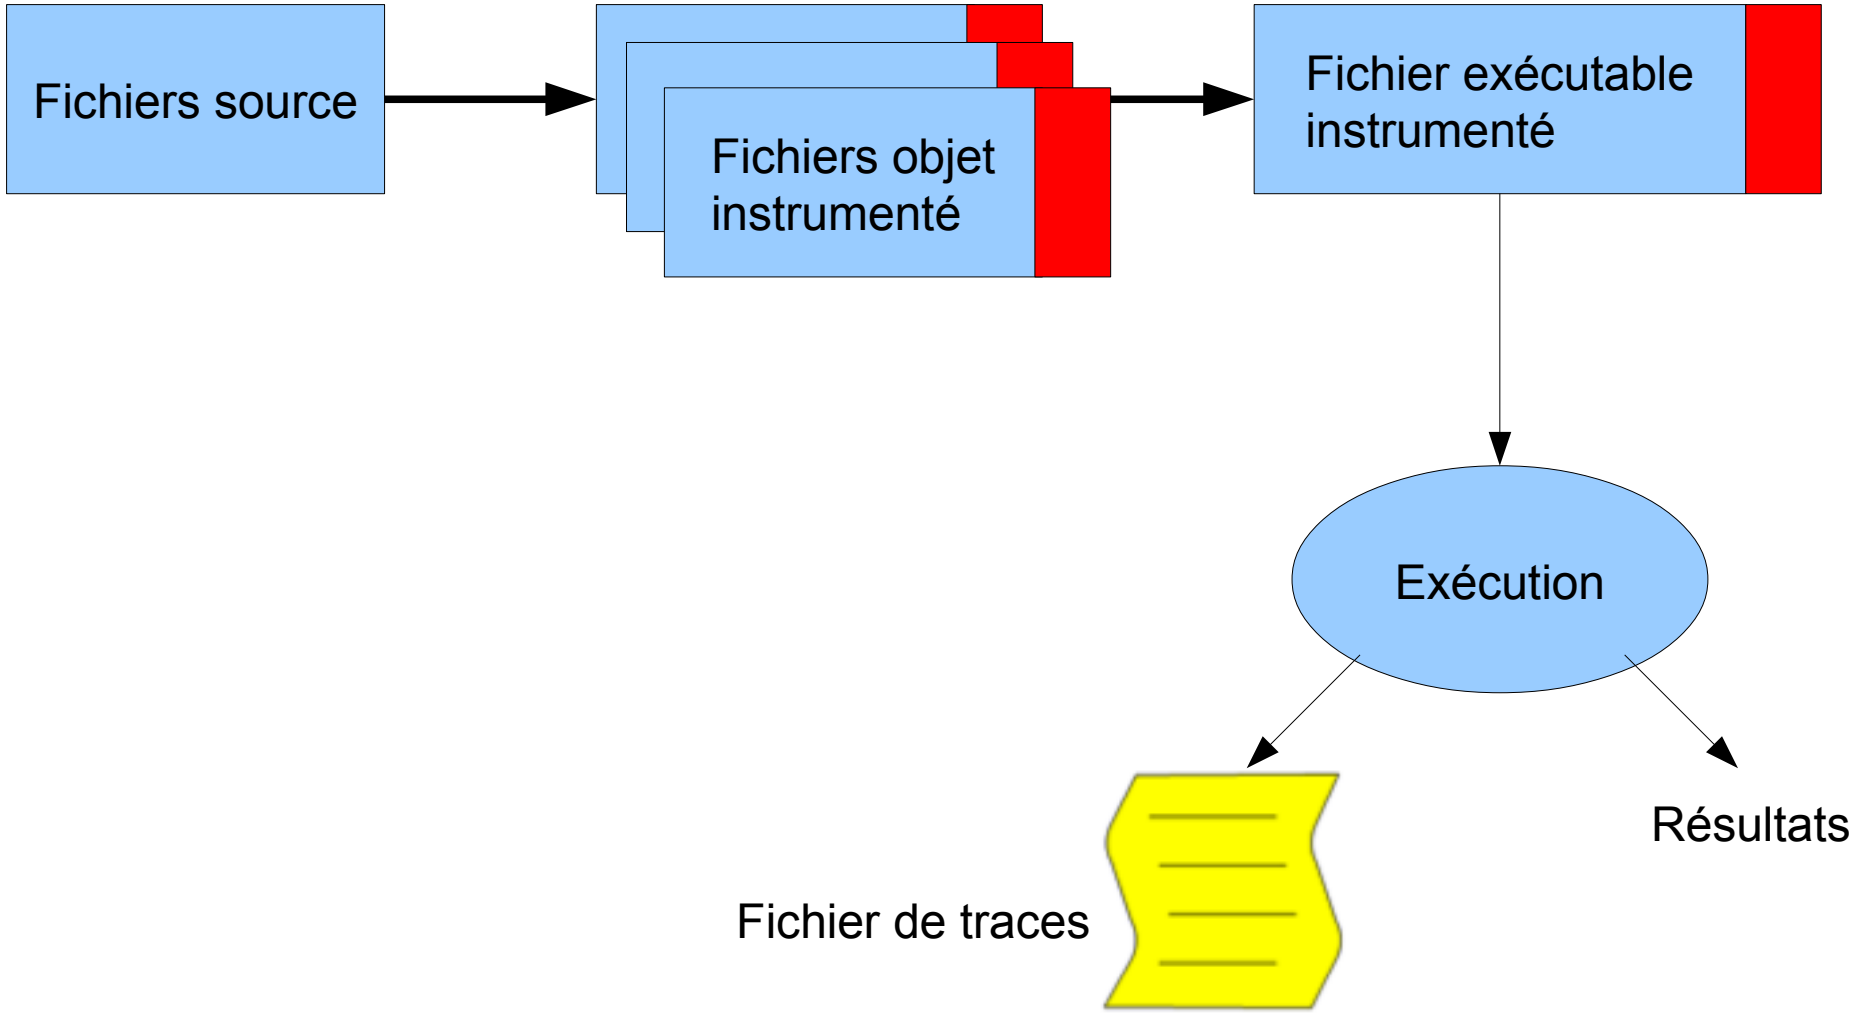

Mesure : 1 première loupe

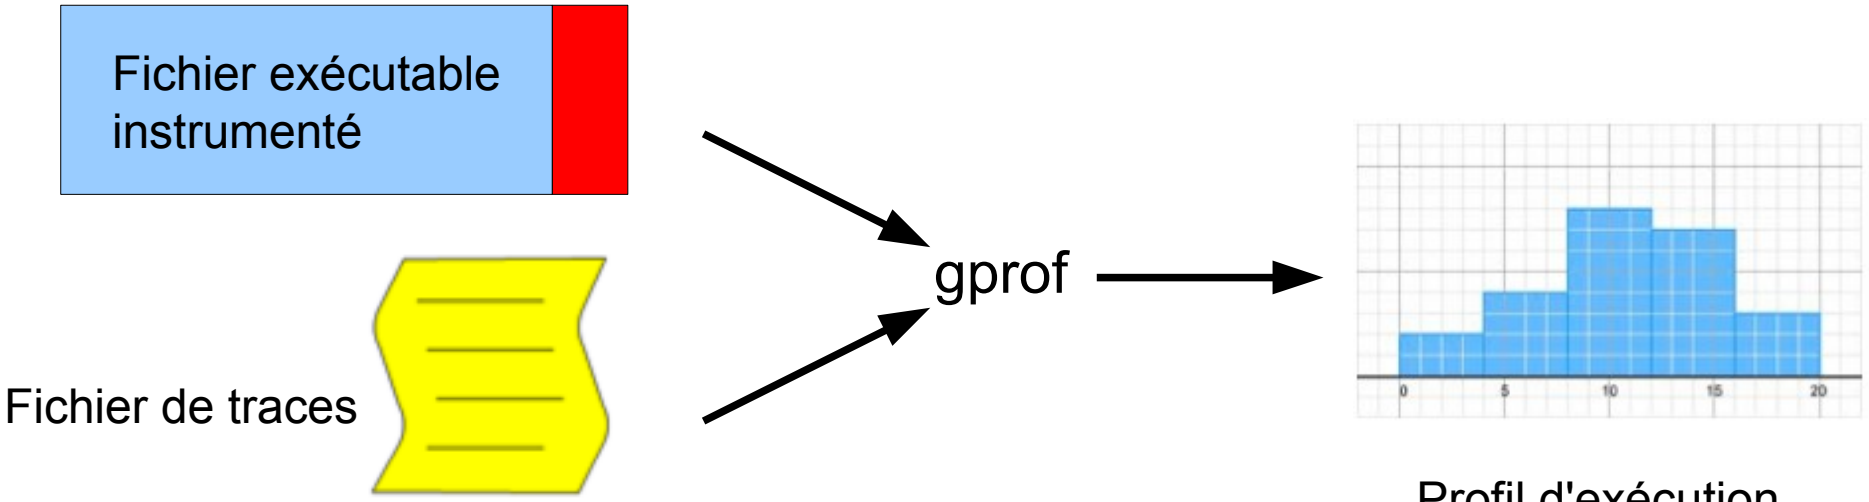

Profil d'exécution

- Dans le profil d'exécution, on retrouve :
  - Le temps passé dans chaque fonction, en intégrant les fonctions appelées : **temps inclusif** (100% pour main)
  - Le temps passé dans chaque fonction sans tenir compte des fonctions appelées : **temps exclusif**

TP 2 : Utilisation du profiler

- Nous utilisons le fichier `/optim_base/jv/jv.c`
- Compilez ce programme avec l'option d'instrumentation (-pg)
- Exécutez le programme, vous devriez obtenir un fichier `gmon.out`
- Analysez ce fichier avec gprof :
  `gprof ./a.out gmon.out`
- Examinons la sortie en détails (votre sortie peut varier)

TP 2 : Sortie de gprof

- Premiers chiffres : profil plat

```
rdavid@jdevt7b:/usr/local/atelier/jv$ gprof ./a.out gmon.out
Flat profile:

Each sample counts as 0.01 seconds.
  %   cumulative   self              self     total
 time   seconds   seconds    calls   s/call   s/call  name
 89.11     55.62    55.62        5    11.12    11.12  evolution
  9.52     61.56     5.94        4     1.49     1.49  faffiche
  1.38     62.42     0.86                             main
```

- Le profil est dit plat car chaque fonction est représentée au même niveau

TP 2 : Sortie de gprof

- Deuxièmes chiffres : graphe d'appel

```
index % time    self  children    called     name
                                                 <spontaneous>
[1]    100.0    0.86   61.56                 main [1]
               55.62    0.00       5/5           evolution [2]
                5.94    0.00       4/4           faffiche [3]
-----------------------------------------------
               55.62    0.00       5/5           main [1]
[2]     89.1   55.62    0.00       5         evolution [2]
-----------------------------------------------
                5.94    0.00       4/4           main [1]
[3]      9.5    5.94    0.00       4         faffiche [3]
-----------------------------------------------
```

- Ceci nous permet de retracer l'exécution du programme. Ici, seul `main` appelle d'autres fonctions

TP 2 : Sortie de gprof

- Pour aller plus loin...
- Des outils peuvent analyser la sortie de gprof pour produire une représentation du graphe d'appel
- Essayez python `optim_base/utils/gprof2dot.py`
- [illegible] ée peut être visualisée par `xdot` :

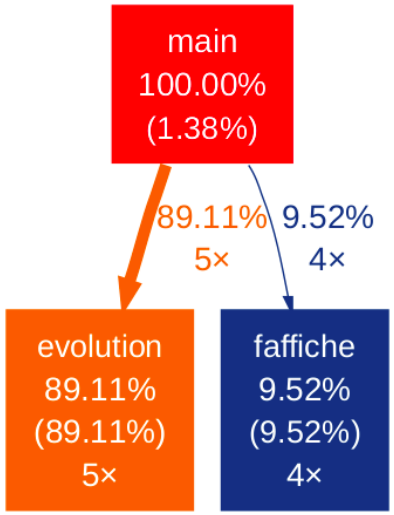

TP 2 : Sortie de gprof

- Gprof permet également d'extraire le temps passé ligne par ligne
- Compilez `jv.c` avec les options `-pg` et `-g`
- Exécutez le programme
- Analysez la trace produite avec `gprof -l`
- Dans la sortie, les noms de fonctions sont remplacés par des numéros de ligne dans des fichiers sources

TP 2 : Sortie de gprof

% time	cumulative seconds	self seconds	calls	self Ts/call	total Ts/call	name
64.71	40.34	40.34				evolution (jv.c:68 @ 80487c1)
13.01	48.45	8.11				evolution (jv.c:63 @ 80487f9)
6.50	52.51	4.05				faffiche (jv.c:128 @ 8048942)
3.37	54.60	2.10				evolution (jv.c:74 @ 804882d)
1.82	55.74	1.14				evolution (jv.c:76 @ 804883c)
1.73	56.82	1.08				faffiche (jv.c:127 @ 8048971)
1.48	57.74	0.92				evolution (jv.c:79 @ 804885d)
1.40	58.61	0.87				evolution (jv.c:62 @ 8048808)
1.27	59.40	0.79				evolution (jv.c:82 @ 804886f)
0.76	59.88	0.47				main (jv.c:151 @ 8048a14)
0.74	60.34	0.46				evolution (jv.c:63 @ 80487b6)
0.63	60.73	0.39				evolution (jv.c:62 @ 80487ab)
0.59	61.09	0.37				evolution (jv.c:71 @ 8048817)
0.55	61.44	0.34				evolution (jv.c:54 @ 804887f)
0.47	61.73	0.29				main (jv.c:149 @ 8048a3e)
0.32	61.93	0.20				evolution (jv.c:57 @ 80487a4)
0.25	62.09	0.15				faffiche (jv.c:127 @ 8048939)
0.24	62.23	0.15				evolution (jv.c:80 @ 804886d)

TP 2 : Sortie de gprof

- Examinons la ligne en question :

```
 nbvoisins+=g1[((xv+maxi)%maxi)*maxj+(yv+maxj)
%maxj];
```

- Elle contient des opérations arithmétiques et une recopie mémoire

Limitations de gprof

- Mesure du temps passé en contexte utilisateur uniquement
- Surcoût en temps lié au interruptions régulières
- Le profiling nécessite une recompilation ⇒ pas de profiling des bibliothèques externes non prévues pour le profiling.

Limitations de gprof

- Exemple de compilation séparée : fonction évolution est recompilée sans -pg, le graphe d'appels est incomplet :

```
granularity: each sample hit covers 4 byte(s) for 0.02% of 62.35 seconds

index % time    self  children    called     name
                                                 <spontaneous>
[1]     89.2   55.59    0.00                 evolution [1]
-----------------------------------------------
                                                 <spontaneous>
[2]     10.8    0.81    5.95                 main [2]
                5.95    0.00       4/4           faffiche [3]
-----------------------------------------------
                5.95    0.00       4/4           main [2]
[3]      9.5    5.95    0.00       4         faffiche [3]
-----------------------------------------------
```

Gprof : conclusion

- Gprof est un bon **outil de mesure** pour synthétiser des informations quantitatives sur un programme
- Présent dans de nombreuses distributions Linux
- Gprof fait partie des premiers outils à utiliser
- Par contre, si les performances ne sont pas satisfaisantes, il nous faut trouver par nous même les pistes d'amélioration
- Certains outils mesurent plus précisément le comportement du programme et éclairent sur des pistes à utiliser

Mesure 2 : mémoire

- L'architecture des processeurs actuels est représentée ici :

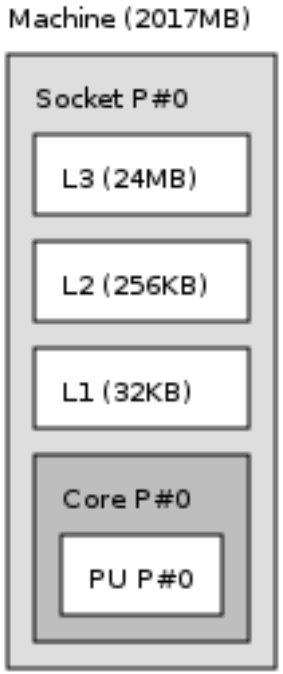

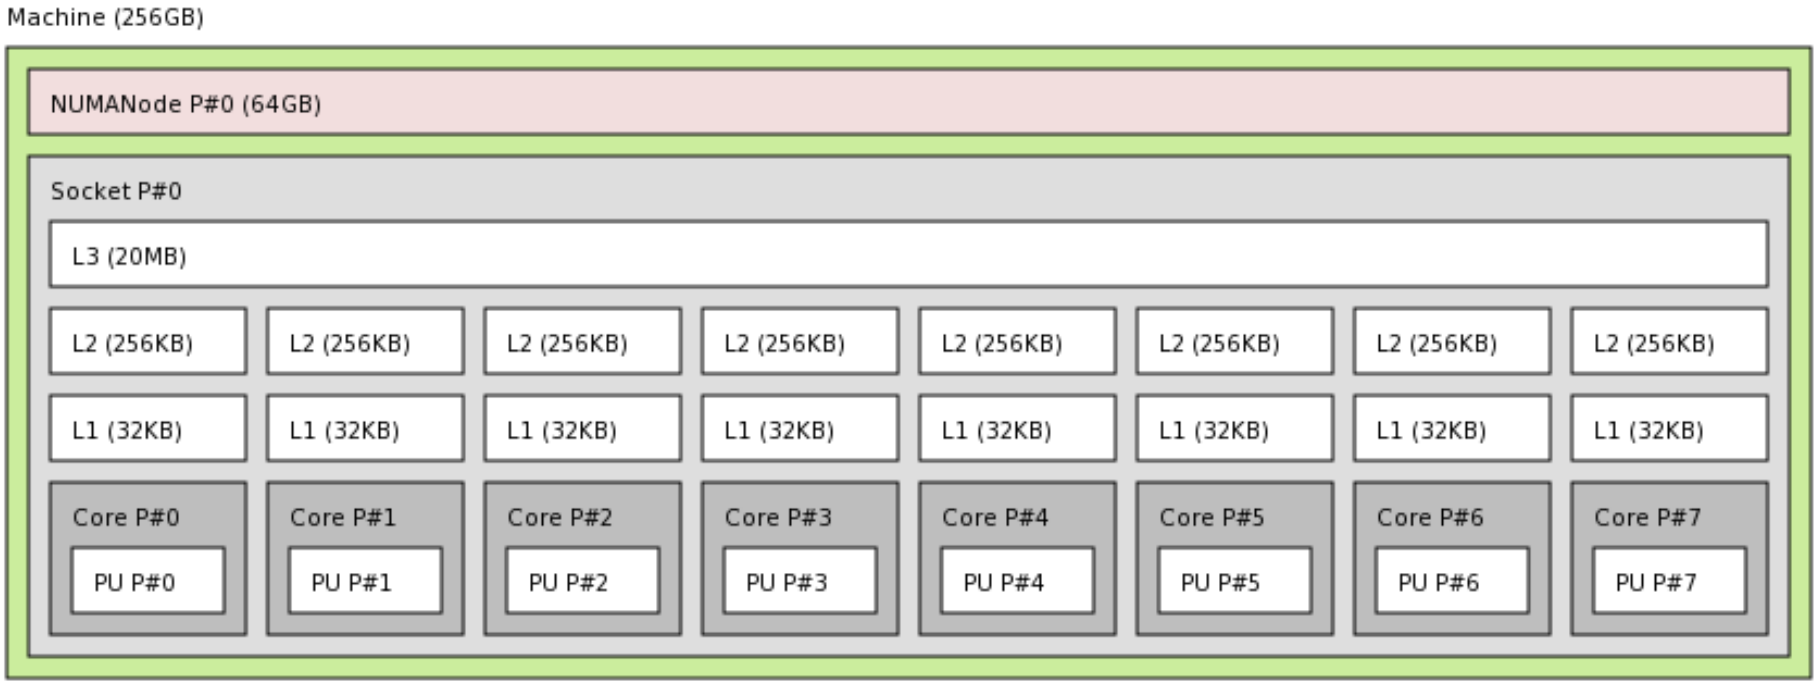

Machine mono-coeur Machine multi-coeur

Mesure 2 : mémoire

- Utilité du cache
  - Le cache est une mémoire rapide de petite taille
  - Au fur et à mesure de leur utilisation en mémoire, les données sont placées dans les différents niveaux de cache par le matériel
  - Le cache étant de taille limitée, il est nécessaire fréquemment de remplacer les données qui s'y trouvent par d'autres données
  - Il existe différents algorithmes qui associent une donnée (@ mémoire) et son emplacement dans le cache

- Le nombre de cycles nécessaires à l'obtention d'une donnée dépend de son emplacement :

Level	Hit
1	5
2	10
3	40-65
Mémoire	60ns (150 / 200 cycles)

Source http://software.intel.com/en-us/forums/topic/287236

- Notez que pour les machines multi-processeurs, les délais dépendent en plus du processeur rattaché à la mémoire correspondante

Mesure 2 : mémoire

- On gagnera donc à utiliser des données qui se trouvent dans le cache
- Un défaut de cache, le fait d'utiliser une donnée qui ne se trouve pas dans le cache, est coûteux en termes de performances.
- Les défauts de cache sont nombreux et inévitables, on va néanmoins chercher à les minimiser
- Il existe 2 méthodes de mesure

Mesure 2 : mémoire

- Mesure basées sur les événements matériels :
  - Les processeurs sont munis d'un grand nombre de compteurs
  - La bibliothèque PAPI (Performance Application Programming Interface) donne accès à ces compteurs de manière portable
  - PAPI est utilisée par d'autres outils comme TAU
- Mesure basée sur des simulateurs
  - Le simulateur valgrind peut accueillir un simulateur de cache à 3 niveaux

Mesure 2 : mémoire

- Sur la machine virtuelle de l'atelier, nous utilisons valgrind + cachegrind :

```
rdavid@jdevt7b:~/Jeuvie$ valgrind --tool=cachegrind optim_base/jv/jv.short
==5207== Cachegrind, a cache and branch-prediction profiler
==5207== Copyright (C) 2002-2011, and GNU GPL'd, by Nicholas Nethercote et al.
==5207== Using Valgrind-3.7.0 and LibVEX; rerun with -h for copyright info
==5207== Command: /usr/local/atelier/jv/jv.short
==5207==
--5207-- warning: L3 cache found, using its data for the LL simulation.
```

Sur la machine support d'exécution

Last-Level (pour le modèle de cache)

Mesure 2 : mémoire


```
==5207==
==5207== I   refs:      76,674,125,568
==5207== I1  misses:             1,026
==5207== LLi misses:             1,022
==5207== I1  miss rate:           0.00%
==5207== LLi miss rate:           0.00%
==5207==
==5207== D   refs:      41,502,666,201  (37,263,848,578 rd   + 4,238,817,623 wr)
==5207== D1  misses:        20,354,629  (    10,979,553 rd   +     9,375,076 wr)
==5207== LLd misses:        14,064,843  (     4,689,848 rd   +     9,374,995 wr)
==5207== D1  miss rate:            0.0% (          0.0%     +           0.2%   )
==5207== LLd miss rate:            0.0% (          0.0%     +           0.2%   )
==5207==
==5207== LL refs:           20,355,655  (    10,980,579 rd   +     9,375,076 wr)
==5207== LL misses:         14,065,865  (     4,690,870 rd   +     9,374,995 wr)
==5207== LL miss rate:             0.0% (          0.0%     +           0.2%   )
```

Cache d'instruction : L1

Caches de données : L1 et LL.
Où est L2 ?

Mesure 2 : mémoire

En plus de la sortie texte, un fichier de profiling est analysable par cg_annotate :

```
rdavid@jdevt7b:~/Jeuvie$ cg_annotate cachegrind.out.5314
--------------------------------------------------------------------------------
I1 cache:         32768 B, 64 B, 4-way associative
D1 cache:         32768 B, 64 B, 8-way associative
LL cache:         25165824 B, 64 B, 24-way associative
Command:          ./jv.short
Data file:        cachegrind.out.5314
Events recorded:  Ir I1mr ILmr Dr D1mr DLmr Dw D1mw DLmw
Events shown:     Ir I1mr ILmr Dr D1mr DLmr Dw D1mw DLmw
Event sort order: Ir I1mr ILmr Dr D1mr DLmr Dw D1mw DLmw
Thresholds:       0.1 100 100 100 100 100 100 100 100
Include dirs:
User annotated:
Auto-annotation:  off

--------------------------------------------------------------------------------
            Ir I1mr ILmr             Dr      D1mr      DLmr            Dw      D1mw      DLmw
--------------------------------------------------------------------------------
38,983,423,216  910  906 18,559,529,660 1,564,482 1,564,221 2,333,273,351 6,250,230 6,250,217  PROGRAM TOTALS

--------------------------------------------------------------------------------
            Ir I1mr ILmr             Dr      D1mr      DLmr            Dw      D1mw      DLmw  file:function
--------------------------------------------------------------------------------
30,441,809,784    5    5 15,259,682,959 1,562,503 1,562,503   601,000,003 1,562,501 1,562,501  /home/rdavid/Jeuvie/jv.c:evolution
 4,100,012,710    3    3  1,596,779,144         0         0 1,000,003,100         0         0  /build/buildd/eglibc-2.15/stdlib/random_r.c:random_
r
 2,300,000,000    2    2    700,000,000         0         0   500,000,000         0         0  /build/buildd/eglibc-2.15/stdlib/random.c:random
 1,607,000,074    6    6    503,000,018         1         1   201,000,029 1,562,501 1,562,501  /home/rdavid/Jeuvie/jv.c:main
   400,000,778    1    1    400,000,778         0         0             0         0         0  /build/buildd/eglibc-2.15/string/../sysdeps/i386/i6
86/multiarch/strcat.S:???
   100,000,269   23   20    100,000,128        12        11            63         1         1  ???:???
```

Mesure 2 : mémoire

Les événements remontés sont :

Ir : I cache reads (ie. instructions executed)
I1mr: I1 cache read misses
I2mr: L2 cache instruction read misses
Dr : D cache reads (ie. memory reads)
D1mr: D1 cache read misses
D2mr: L2 cache data read misses
Dw : D cache writes (ie. memory writes)
D1mw: D1 cache write misses
D2mw: L2 cache data write misses

Mesure 2 : mémoire

Il peut être bien plus intéressant d'avoir une remontée d'informations au niveau ligne de code et non par fonction :
cg_annotate --auto=yes cachegrind.out.5314

nous apprend par exemple que l'instruction :
nbvoisins+=g1[((xv+maxi)%maxi)*maxj+(yv+maxj)%maxj];
est celle qui génère les défauts de cache du programme.
Est-ce logique ?

Plan

- Performance ? What is it all about ?
- Mesure
- Optimisation : CPU
- Optimisation : mémoire
- Conclusion

Optimisation CPU

- Pour traiter de 2 techniques d'optimisation CPU, nous travaillons sur une version à peine modifiée des Stream Benchmarks http://www.cs.virginia.edu/stream/ref.html
- Ce benchmark réalise des opérations très simples :
  - addition de tableaux
  - recopie
  - triad : a=b+ coefficient * c
- Le bench affiche un résultat en MB/s, que nous allons améliorer

Optimisation CPU

- Quelles sont (quelques unes) des optimisations CPU réalisées par les compilateurs ?
  Source http://gcc.gnu.org/onlinedocs/4.8.1/
  - Sortie des invariants de boucle
  - Réduction de variables en examinant les variables induites (ex : indice et adresse mémoire)
  - Déroulage de boucles ⇒ Réduction coût de gestion
  - Vectorisation ⇒ Réduction temps passé
  - Inlining ⇒ Réduction temps passé dans la gestion des appels

Optimisation CPU – Loop Unrolling

- Nous allons augmenter le ratio d'instructions utiles :
  - En augmentant relativement la longueur du corps de boucle
  - En diminuant le nombre de tours de boucle
- Faites une copie du fichier

  `optim_base/atelier/Stream/stream.c`

  sur votre compte, et ajoutez une directive de compilation `TUNED_ADD` pour proposer une version « fonction » du code contenu dans la ligne 334-335

Optimisation CPU – Loop Unrolling

- Voici un exemple de boucle déroulée de taille 4 :

```
for (j=0; j<STREAM_ARRAY_SIZE; j=j+4)
{       a[j] =   b[j]+scalar*c[j];
        a[j+1] = b[j+1]+scalar*c[j+1];
        a[j+2] = b[j+2]+scalar*c[j+2];
        a[j+3] = b[j+3]+scalar*c[j+3];
 }
```

- Quelle amélioration de performance observez-vous ?

Optimisation CPU – Loop Unrolling

- Avec le compilateur Gcc, pour dérouler automatiquement les boucles dans tout le code, utiliser l'option à la ligne de commande :

```
-funroll-loops
```

- Pour dérouler spécifiquement **une** boucle, on ajoute des instructions (pragma) à destination du compilateur dans le code :

```
#pragma GCC push_options
#pragma GCC optimize ("unroll-loops")
définition de fonction
#pragma GCC pop_options
```

Optimisation CPU – Vectorisation

- Depuis une dizaine d'années, les processeurs disposent de petites unités vectorielles (stockage + calcul) effectuant diverses opérations mathématiques, motivés par les besoins du traitement d'images. 5ème version à ce jour http://sseplus.sourceforge.net/fntable.html
- Ces instructions nécessitent l'emploi de types spécifiques, décrits dans des fichiers spécifiques
- Les fonctions correspondant aux opérateurs arithmétiques sont des fonctions intrinsèques connues par le compilateur... si on le lui demande

Optimisation CPU – Vectorisation

- SSE : 1ers jeux d'instructions vectorielles, accessible sur Intel et AMD
- AVX : Jeux d'instructions introduit avec le Sandy Bridge, disponible également sur AMD Bulldozer, visant à étendre le SSE
  - Vecteurs de 256 ou 512 bits
  - Apparition d'opérateurs non destructifs comme c=a+b
- Dans les exemples, nous étudierons des cas très simples issus de SSE 1

Optimisation CPU – Vectorisation

- Exemple de type de données :

  __m128 : un vecteur de 128 bits
  4 flottants ou 2 doubles

- Exemple d'opération :
  _mm_add_p**s** : addition terme à terme sur des éléments flottants de 4 octets

- L'opération arithmétique effectue en une fois les 4 additions ⇒ gain de temps CPU

Optimisation CPU – Vectorisation

- Dans le code, ajouter l'inclusion de l'en-tête spécifique :

  #include <xmmintrin.h>
- Pour que les types et les fonctions soient activés dans le compilateur, ajouter les options -msse, jusqu'à -msse4.2 si le processeur le supporte
- -msse suffit pour notre atelier
- Pour vérifier le niveau de sse pris en charge par le processeur, regardez la sortie de **cat /proc/cpuinfo**
- Instruction assembleur correspondant : cpuid

- Exemple de code : addition de 2 vecteurs

```
#include <xmmintrin.h>

__m128 * mm_c= (__m128 *) c;  // c,b,a les tableaux
d'origine
__m128 * mm_b= (__m128 *) b;
__m128 * mm_a= (__m128 *) a;
        for (j=0; j<STREAM_ARRAY_SIZE/4; j++)
        {
        *mm_c = _mm_add_ps(*mm_a,*mm_b);

        // Do some pointer arithmetic on the mm types
        mm_c ++; // Fera avancer le pointeur de 4 octets
        mm_b ++;
        mm_a ++;
        }
```

- Intégrez ces modifications dans **stream.c** et mesurez le résultat obtenu

Optimisation CPU – Vectorisation

- Résultats obtenus
- L'exécutable `optim_base/Stream/stream` est la version de base, compilée avec gcc, travaillant sur des float
- L'exécutable `optim_base/Stream/stream_sse` est la version où les 4 kernels ont été optimisés avec des instructions sse

Version	Copy	Scale	Add	Triad
Base	1988	2039	2659	2343
Sse	3147	3065	4028	3501

Mb/s

Optimisation CPU – Vectorisation

- Avec le compilateur gcc :
  - `-ftree-vectorize`
  - inclus dans le niveau d'optimisation `-O3`

Plan

- Performance ? What is it all about ?
- Mesure
- Optimisation : CPU
- Optimisation : mémoire
- Conclusion

Optimisation : mémoire

- Pour optimiser la mémoire, il faut profiter des données tant qu'elles sont dans le cache.
- Pour cela, on essaye de profiter de 2 principes de localité :
  - Localité spatiale : travailler sur des données proches en mémoire.
    En effet, proches en mémoire, elles seront vraisemblablement présentes dans le cache en même temps

Optimisation : mémoire

- Localité temporelle : utiliser les données à plusieurs reprises de manière rapprochée dans le temps
  Cela permet de *rentabiliser* le coût de chargement des données

- Pour bénéficier de ces caractéristiques, il est parfois nécessaire de restructurer en profondeur les structures mémoire de ses codes.
- Le travail est comparable à celui qu'on pourrait effectuer lors du portage du code sur un GPU, où les performances sont largement dépendantes des caractéristiques des accès mémoire

Optimisation : mémoire

- Ordre des éléments en mémoire pour un tableau 2D en C

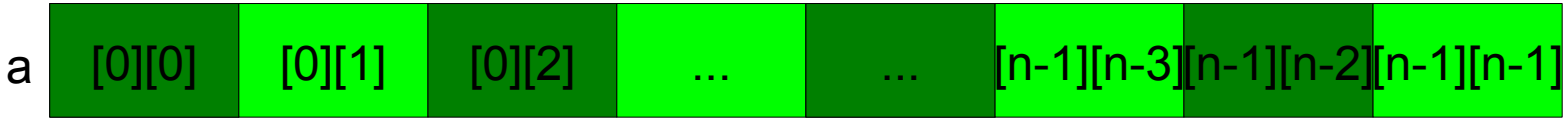

- en C, quand on écrit a[i][j], on accède à l'élément d'adresse : ← Fonction d'accès

  $a+i \times dim\_y + j$

- C'est une convention du langage, d'autres langages procèdent autrement (Fortran)
- Dans tous les cas, nous cherchons à nous aligner dans nos codes à l'ordre mémoire

Optimisation : mémoire

- Dans le fichier `optim_base/cache/t.c`, nous reproduisons pour des tableaux de taille variable la fonction d'accès vue précédemment :
- Nous allouons une zone contigüe en mémoire :

```
t=malloc(nb_elem*sizeof(TYPE));
```

- Nous accédons à cette zone par un adressage 2D :

```
#define ADDR(i,j,dim) (i*dim+j)
```

- Correspond exactement à ce qu'aurait fait le compilateur sur un tableau dont il connaît la taille

Optimisation : mémoire

- Nous réalisons un parcours du tableau dans 2 fonctions différentes qui produisent le même résultat
-
```
for (i=0 ; i < dim ; i++)
        for (j=0 ; j < dim ; j++)
                {
                t[ADDR(i,j,dim)]=i+j;
                }
```
Fonction `parcours_ok`
- Quelle est l'adresse de deux accès consécutifs ?

Optimisation : mémoire

- Instrumentez le code et lisez les traces avec gprof
- Nous lançons le code avec valgrind

  valgrind –tool=cachegrind ./t 20 (long)
- Le résultat faît apparaître un nombre de défauts de cache relativement élevés : 50% des accès se traduisent par un cache miss

Optimisation : mémoire


```
Allocation 419430400 elements
==2020==
==2020== I   refs:      12,583,478,066
==2020== I1  misses:               835
==2020== LLi misses:               834
==2020== I1  miss rate:           0.00%
==2020== LLi miss rate:           0.00%
==2020==
==2020== D   refs:       8,388,916,188  (7,549,999,949 rd   + 838,916,239 wr)
==2020== D1  misses:       445,647,270  (       1,958 rd   + 445,645,312 wr)
==2020== LLd misses:       445,647,270  (       1,958 rd   + 445,645,312 wr)
==2020== D1  miss rate:            5.3% (         0.0%     +         53.1%  )
==2020== LLd miss rate:            5.3% (         0.0%     +         53.1%  )
==2020==
==2020== LL refs:          445,648,105  (       2,793 rd   + 445,645,312 wr)
==2020== LL misses:        445,648,104  (       2,792 rd   + 445,645,312 wr)
==2020== LL miss rate:             2.1% (         0.0%     +         53.1%  )
```

Optimisation : mémoire

- Avec `cg_annotate --auto=yes` cachegrind.out.[pid], on se rend bien compte de l'endroit où se produisent les défauts de cache.
- Est-ce logique ?
- Quelle est la différence principale entre les fonctions parcours_ok et parcours_ko ?

Plan

- Performance ? What is it all about ?
- Mesure
- Optimisation : CPU
- Optimisation : mémoire
- Conclusion

Conclusion

- La boîte à outils pour l'analyse des performances est vaste… mais peut s'utiliser pas à pas
- L'optimisation de code dé-structure le code initial
  - Pensez à conserver l'interface et à documenter
  - Certaines optimisations rendent le code dépendant de l'architecture, prévoyez une roue de secours
  - Le compilateur ne fait pas tout
- Autre piste : les optimisations algorithmiques liées à la connaissance du domaine (symétries…)