



Micro-benchmarking de précision

Hadrien Grasland

2020-03-04



Optimisation guidée par benchmark

1. **Identifier** un problème de performances
2. **Profiler** pour localiser les composants critiques
3. **Construire** des *benchmarks* de ces composants
4. **Utiliser** ces *benchmarks* pour améliorer leur performance
5. **Vérifier** l'impact sur le système global

Exemple

1. La reconstruction ATLAS est trop lente pour le HL-LHC
2. Grand rôle de la trajectographie, en particulier :
 1. Propagation Runge-Kutta
 2. Navigation dans la géométrie
 3. Filtre de Kalman
3. Des benchmarks de ces composants ont été isolés
4. Ils facilitent le travail sur leur performance
5. L'effet sur une reconstruction complète sera ensuite vérifié

Pourquoi utiliser des benchmarks ?

- Compilent et s'exécutent **rapidement**
 - Cycle de développement efficace
- Accès à des **outils** inutilisables sur gros programme
 - MAQAO, cachegrind, examen de l'assembleur...
- Facilitent la détection & l'analyse de **régressions**
 - ...voire permettent leur automatisation
- Un problème simplifié stimule la **créativité**

Quel prix à payer ?

- On **porte des oeillères**, au risque de...
 - ...s'acharner quand l'impact est devenu négligeable
 - ...manquer une optimisation de plus haut niveau
- Le benchmark peut **ne pas être représentatif**
- Compilateur & matériel peuvent **sur-optimiser**
 - Niveau de performances inaccessible en conditions réelles
- Si on gère bien ces risques, l'impact reste positif

Au programme

- Aujourd'hui, on va parler de...
 - Biais d'origine logicielle (OS, compilateur...)
 - Imprécisions dans la mesure de temps
- On n'évoquera que brièvement les...
 - Biais d'origine matérielle (caches, ILP...)
 - Biais humain d'écriture du benchmark

Démarche

- Des exemples simples, voire simplistes ?
 - Moins d'explications de code, plus d'analyse
 - Suffisant pour exposer de nombreux problèmes
 - Souvent, le goulot d'étranglement *est* simple
 - Utile pour analyser toutes sortes de lieux communs
 - « La racine carrée, c'est lent »
 - « Les branches nuisent aux performances »

Limitier le biais logiciel

Mon Premier Benchmark™

```
1 #include <chrono>
2 #include <cstdlib>
3 #include <iostream>
4
5
6 int main() {
7     using Clock = std::chrono::steady_clock;
8     using NanoSecs = std::chrono::nanoseconds;
9
10    auto start = Clock::now();
11
12    std::rand(); // Code étudié
13
14    NanoSecs ns = Clock::now() - start;
15    std::cout << "T=" << ns.count() << "ns" << std::endl;
16
17    return 0;
18 }
```

Ex. d'utilisation :

- Je fais du Monte Carlo
- Je veux savoir combien le RNG système produit de nombres par seconde

Quelques exécutions

```
$ g++ -std=c++11 -O3 ex1a.cpp
```

```
$ ./a.out
```

```
T=1587ns
```

```
$ ./a.out
```

```
T=1734ns
```

```
$ ./a.out
```

```
T=1757ns
```

```
$ ./a.out
```

```
T=1707ns
```

```
$ ./a.out
```

```
T=1684ns
```

```
$ ./a.out
```

```
T=1807ns
```

Un résultat assez **reproductible**... Mais est-il **correct** ?

Autre protocole d'exécution

```
$ for i in {1..20}; do ./a.out; done
```

T=1751ns

T=1404ns

T=735ns

T=723ns

T=797ns

T=706ns

T=712ns

T=1500ns

T=906ns

T=1520ns

T=1440ns

T=1108ns

T=1086ns

T=982ns

T=1054ns

T=723ns

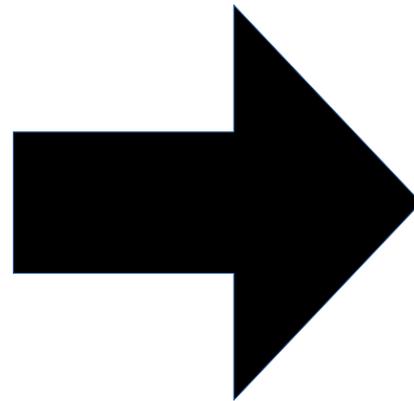
T=686ns

T=661ns

T=770ns

T=736ns

**Grandes
fluctuations !**



SUSPECT !

>2x plus petit qu'avant !

Un 3^e protocole d'exécution

```
1 #include <chrono>
2 #include <cstdlib>
3 #include <iostream>
4
5
6 #ifndef NUM_RUNS
7 #define NUM_RUNS 20
8 #endif
9
10 using NanoSecs = std::chrono::nanoseconds;
11
12 NanoSecs bench() {
13     using Clock = std::chrono::steady_clock;
14     auto start = Clock::now();
15
16     |std::rand(); // Code étudié
17
18     return Clock::now() - start;
19 }
20
21 int main() {
22     std::cout << "T_run(ns)" << std::endl;
23
24     for (size_t i = 0; i < NUM_RUNS; ++i) {
25         double nanosecs = bench().count();
26         std::cout << nanosecs << std::endl;
27     }
28
29     return 0;
30 }
```

Nb d'exécutions configurable

Equivalent au programme précédent

Pour s'abstraire des effets du shell,
on boucle *dans le processus*

Autre résultat

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=15 ex1b.cpp
```

```
$ ./a.out
```

```
T_run(ns)
```

```
2149
```

```
164
```

```
97
```

```
80
```

```
120
```

```
74
```

```
71
```

```
74
```

```
67
```

```
77
```

```
77
```

```
74
```

```
74
```

```
73
```

```
77
```

« Chauffe » des caches,
mécanismes paresseux de l'OS...

« Vrai » état d'équilibre ?
Un seul moyen de savoir...

Autres NUM_RUNS

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=100 ex1b.cpp && ./a.out  
[ ... blabla ... ]
```

81

80

83

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000 ex1b.cpp && ./a.out  
[ ... blabla ... ]
```

68

55

58

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=10000 ex1b.cpp && ./a.out  
[ ... blabla ... ]
```

47

48

44

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=100000 ex1b.cpp && ./a.out  
[ ... blabla ... ]
```

26

26

25

On en était encore loin !

**Certains mécanismes
de « chauffe » sont plus
lents que d'autres...**

Autres NUM_RUNS

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=10000000 ex1b.cpp && ./a.out  
[ ... blabla ... ]
```

38

32

32

36

32

37 **Stable à un facteur ~2x près après ~1s**

28

34 **Pas d'amélioration de stabilité ensuite**

30

33 **Mais mesure-t'on std::rand()... ou le reste de la boucle ?**

27

26

27

25

27

26

28

27

```
[ ... blabla ... ]
```

Test de linéarité

```
8 #ifndef NUM_RUNS
9 #define NUM_RUNS 20
10 #endif
11
12 #ifndef NUM_ITERS
13 #define NUM_ITERS 1
14 #endif
15
16 using NanoSecs = std::chrono::nanoseconds;
17
18 NanoSecs bench_run() {
19     using Clock = std::chrono::steady_clock;
20     auto start = Clock::now();
21
22     for (size_t iter = 0; iter < NUM_ITERS; ++iter) {
23         std::rand(); // Code étudié
24     }
25
26     return Clock::now() - start;
27 }
28
29 int main() {
30     size_t col1_width = 15;
31     std::cout << std::left;
32     std::cout << std::setw(col1_width) << "T_run(µs)"
33             << "T_iter,avg(ns)" << std::endl;
34
35     for (size_t i = 0; i < NUM_RUNS; ++i) {
36         double t_run = bench_run().count();
37         double t_iter = t_run / NUM_ITERS;
38         std::cout << std::setw(col1_width-1) << t_run / 1000
39                 << t_iter << std::endl;
40     }
41
42     return 0;
43 }
```

Boucle sur nouveau NUM_ITERS

Affichage à deux colonne :

- Durée totale du benchmark
- Temps moyen d'itération

Augmentons NUM_ITERS...

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=1 ex1c.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
0.036      36
```

```
0.027      27
```

```
0.032      32
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=10 ex1c.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
0.119     11.9
```

```
0.097      9.7
```

```
0.099      9.9
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=100 ex1c.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
0.733      7.33
```

```
0.727      7.27
```

```
0.729      7.29
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=1000 ex1c.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
6.811     6.811
```

```
6.802     6.802
```

```
6.797     6.797
```

x3

/3

x7

/1,4

x9

/1,1

...toujours plus haut, toujours plus fort !

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=100000 -DNUM_ITERS=10000 ex1c.cpp && ./a.out  
[ ... blabla ... ]  
67.250          6.7250  
67.681          6.7681  
67.452          6.7452
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=10000 -DNUM_ITERS=100000 ex1c.cpp && ./a.out  
[ ... blabla ... ]  
683.244         6.83244  
676.905         6.76905  
676.306         6.76306
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000 -DNUM_ITERS=1000000 ex1c.cpp && ./a.out  
[ ... blabla ... ]  
6750.66         6.75066  
6766.02         6.76602  
6820.27         6.82027
```

...bon, $T_{\text{iter,avg}}$ est **~stable**, T_{run} **linéaire** en NUM_ITERS, ça semble OK.

Essayons maintenant de mesurer *autre chose* que `std::rand()`...

Nouvelle opération benchmark

```
18 NanoSecs bench_run() {
19     using Clock = std::chrono::steady_clock;
20     auto start = Clock::now();
21
22     for (size_t iter = 0; iter < NUM_ITERS; ++iter) {
23         std::sqrt(4.2); // Code étudié
24     }
25
26     return Clock::now() - start;
27 }
```

Lieu commun du calcul : « La racine carrée est lente, donc à éviter »

Ce genre de savoir millénaire doit toujours être...

- **Vérifié** : Est-ce toujours vrai sur les systèmes actuels ?
- **Quantifié** : Combien de fois plus lent qu'une somme ?

Sauf que...

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=1 ex2a.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
0.032      32
```

```
0.033      33
```

```
0.035      35
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=10 ex2a.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
0.018      1.8
```

```
0.018      1.8
```

```
0.017      1.7
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=100 ex2a.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
0.016      0.16
```

```
0.017      0.17
```

```
0.017      0.17
```

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=1000000 -DNUM_ITERS=1000 ex2a.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
0.017      0.017
```

```
0.017      0.017
```

```
0.017      0.017
```

<< 1 cycle processeur !

Décroissant ?

Explication

```
$ objdump -d a.out
```

```
[ ... blabla ... ]
```

```
0000000000401350 <_Z9bench_runv>:
```

```
401350:      53                push   %rbx
401351:      e8 4a fd ff ff   callq 4010a0
<_ZNSt6chrono3_V212steady_clock3nowEv@plt> ← Mesure d'horloge
401356:      48 89 c3         mov    %rax,%rbx
401359:      e8 42 fd ff ff   callq 4010a0
<_ZNSt6chrono3_V212steady_clock3nowEv@plt> ← Mesure d'horloge
40135e:      48 29 d8         sub   %rbx,%rax
401361:      5b              pop    %rbx
401362:      c3              retq
401363:      66 2e 0f 1f 84 00 00  nopw  %cs:0x0(%rax,%rax,1)
40136a:      00 00 00
40136d:      0f 1f 00        nopl  (%rax)
```

```
[ ... blabla ... ]
```

- **La valeur de $\text{sqrt}(4,2)$ n'est pas utilisée**
 - **Son calcul n'a pas d'effet de bord**
- **L'optimiseur a éliminé le calcul !**

Cas plus complexe

```
19 NanoSecs bench_run() {
20     using Clock = std::chrono::steady_clock;
21     auto start = Clock::now();
22
23     for (size_t iter = 0; iter < NUM_ITERS; ++iter) {
24         std::sqrt(std::rand()); // Code étudié
25     }
26
27     return Clock::now() - start;
28 }
```

On a déjà vu que le compilateur n'élimine pas l'appel à `std::rand()`

- Manipulation d'un état global ou thread-local → effet de bord

Que va-t'il faire si on calcule une racine carrée à partir de cette valeur ?

- Non trivial : Effet de bord possible via *errno* !

Résultat avec GCC 9.2.1

- `std::rand()` seul :

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=10000 -DNUM_ITERS=10000 ex1c.cpp && ./a.out  
[ ... blabla ... ]  
67.665          6.7665  
67.667          6.7667  
67.256          6.7256
```

- `std::sqrt(std::rand())` :

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=10000 -DNUM_ITERS=10000 ex2b.cpp && ./a.out  
[ ... blabla ... ]  
70.078          7.0078  
69.986          6.9986  
69.934          6.9934
```

~1 cycle CPU de plus



Alors, sqrt aussi rapide qu'une addition ?

Dans le doute, cf assembleur

Avant :

```
0000000000401370 <_Z9bench_runv>:
 401370: push  %rbp
 401371: push  %rbx
 401372: mov   $0x2710,%ebx
 401377: sub   $0x8,%rsp
 40137b: callq 4010b0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
 401380: mov   %rax,%rbp
 401383: nopl  0x0(%rax,%rax,1)
 401388: callq 401040 <rand@plt>
 40138d: sub   $0x1,%rbx
 401391: jne   401388 <_Z9bench_runv+0x18>
 401393: callq 4010b0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
 401398: add   $0x8,%rsp
 40139c: sub   %rbp,%rax
 40139f: pop   %rbx
 4013a0: pop   %rbp
 4013a1: retq
 [ ... pas du code ... ]
```

Traduction du nouveau code :

- Convertir la sortie de rand() en double
- Voir si le nombre est négatif
- Si oui, appeler sqrt, sinon ne rien faire

Après :

```
00000000004013a0 <_Z9bench_runv>:
 4013a0: push  %rbp
 4013a1: push  %rbx
 4013a2: mov   $0x2710,%ebx
 4013a7: sub   $0x8,%rsp
 4013ab: callq 4010c0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
 4013b0: mov   %rax,%rbp
 4013b3: nopl  0x0(%rax,%rax,1)
 4013b8: callq 401040 <rand@plt>
 4013bd: pxor  %xmm0,%xmm0
 4013c1: pxor  %xmm1,%xmm1
 4013c5: cvtsi2sd %eax,%xmm0
 4013c9: ucomisd %xmm0,%xmm1
 4013cd: ja    4013e4 <_Z9bench_runv+0x44>
 4013cf: sub   $0x1,%rbx
 4013d3: jne   4013b8 <_Z9bench_runv+0x18>
 4013d5: callq 4010c0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
 4013da: add   $0x8,%rsp
 4013de: sub   %rbp,%rax
 4013e1: pop   %rbx
 4013e2: pop   %rbp
 4013e3: retq
 4013e4: callq 401070 <sqrt@plt>
 4013e9: jmp   4013cf <_Z9bench_runv+0x28>
 4013eb: nopl  0x0(%rax,%rax,1)
```

Nouveau code

Nouveau code

Implications

- Ce type de « sur-optimisation » est très pernicieux
 - En apparence, l'opération n'a pas été éliminée
 - En réalité, elle a été *partiellement* éliminée
 - Facile d'en tirer de mauvaises conclusions
 - Souvent difficile de vérifier l'assembleur
- Solution : Du point de vue du compilateur...
 - L'entrée de la fonction doit changer à chaque itération
 - La sortie de la fonction doit faire l'objet d'un effet de bord

Une approche classique

```
20 std::pair<double, NanoSecs> bench_run() {
21     using Clock = std::chrono::steady_clock;
22     auto start = Clock::now();
23
24     double sum = 0.;
25     for (size_t iter = 0; iter < NUM_ITERS; ++iter) {
26         double res = std::sqrt(std::rand()); // Code étudié
27         sum += (2 * int(iter%2) - 1) * res;
28     }
29
30     return std::make_pair(sum, Clock::now() - start);
31 }
32
33 int main() {
34     size_t col1_width = 15;
35     std::cout << std::left;
36     std::cout << std::setw(col1_width) << "Result"
37             << std::setw(col1_width) << "T_run(µs)"
38             << "T_iter,avg(ns)" << std::endl;
39
40     for (size_t i = 0; i < NUM_RUNS; ++i) {
41         auto res_and_time = bench_run();
42         double t_run = res_and_time.second.count();
43         double t_iter = t_run / NUM_ITERS;
44         std::cout << std::setw(col1_width) << res_and_time.first
45                 << std::setw(col1_width-1) << t_run / 1000
46                 << t_iter << std::endl;
47     }
48
49     return 0;
50 }
```

- Entrées aléatoires
- Réduction des sorties

Nouvelle colonne « Sortie ».

Sans intérêt pour nous,
mais nécessaire dans cette
approche de *benchmark*.

L'élimination de code mort
marche *entre fonctions* !

Résultat

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=10000 -DNUM_ITERS=100000 ex2c.cpp && ./a.out
```

```
[ ... blabla ... ]
```

```
3.67738e+06      801.718      8.01718
-448656         797.564      7.97564
-1.57817e+06    797.571      7.97571
```

```
$ objdump -d a.out
```

```
[ ... blabla ... ]
```

```
000000000401450 <_Z9bench_runv>:
```

```
401450: push  %rbp
401451: push  %rbx
401452: xor   %ebx,%ebx
401454: sub   $0x18,%rsp
401458: callq 4010c0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
40145d: movq  $0x0,(%rsp)
401464:
401465: mov   %rax,%rbp
401468: nopl  0x0(%rax,%rax,1)
40146f:
401470: callq 401040 <rand@plt>
401475: pxor  %xmm0,%xmm0
401479: pxor  %xmm2,%xmm2
40147d: cvtsi2sd %eax,%xmm0
401481: ucomisd %xmm0,%xmm2
401485: movapd %xmm0,%xmm1
401489: sqrtsd %xmm1,%xmm1
40148d: ja    4014d3 <_Z9bench_runv+0x83>
40148f: mov  %ebx,%eax
401491: mov  $0xffffffff,%edx
```

Racine carrée !

```
401496: pxor  %xmm0,%xmm0
40149a: add   $0x1,%rbx
40149e: and   $0x1,%eax
4014a1: lea   (%rdx,%rax,2),%eax
4014a4: cvtsi2sd %eax,%xmm0
4014a8: mulsd %xmm1,%xmm0
4014ac: addsd (%rsp),%xmm0
4014b1: movsd %xmm0,(%rsp)
4014b6: cmp   $0x186a0,%rbx
4014bd: jne   401470 <_Z9bench_runv+0x20>
4014bf: callq 4010c0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
4014c4: movsd (%rsp),%xmm0
4014c9: add   $0x18,%rsp
4014cd: sub  %rbp,%rax
4014d0: pop  %rbx
4014d1: pop  %rbp
4014d2: retq
4014d3: movsd %xmm1,0x8(%rsp)
4014d9: callq 401070 <sqrt@plt>
4014de: movsd 0x8(%rsp),%xmm1
4014e4: jmp   40148f <_Z9bench_runv+0x3f>
4014e6: nopw %cs:0x0(%rax,%rax,1)
```

```
[ ... blabla ... ]
```

Limites de cette technique

- L'approche doit être adaptée à chaque problème
 - On ne génère pas des flottants comme des entiers
 - Tout résultat n'a pas une « somme » évidente
 - Il faut trouver un « bon » effets de bord
- Un compilateur sophistiqué pourrait sur-optimiser pour la réduction et le générateur aléatoire utilisé
- Contribution génération aléatoire & réduction difficile à isoler
- Sorties « inutiles » trop facilement éliminées par un collègue

L'approche *inline(never)*...

- Une autre technique ancienne : désactiver l'inlining
 - Théorie : Le compilateur ne peut spécialiser sans inlining
 - Problèmes :
 - Le compilateur sait spécialiser si il y a peu d'appels
 - Le compilateur raisonne sur les interfaces (pure, etc.)
 - Pas de méthode standard pour désactiver l'*inlining*
 - Fichier source séparé ? Obsolète avec la LTO/WPO
- ...en un mot, cette approche n'est plus à conseiller

3^e approche : détourner l'*inline assembly*

- Basée sur les assembleurs *inline* de type « GCC » :

```
int a=10, b;  
asm ("movl %1, %%eax;  
     movl %%eax, %0;"  
     : "=r"(b)           /* output */  
     : "r"(a)           /* input */  
     : "%eax"           /* clobbered register */);
```

- Comment en faire une barrière d'optimisation ?
 - On passe un pointeur sur une donnée à l'assembleur inline
 - On déclare qu'on peut lire ou écrire partout dans la cible
 - Le compilateur est, en pratique, forcé de nous croire
- Non portable en théorie, largement portable en pratique

Mise en pratique

```
18 template <typename T>
19 void assume_accessed(T&& value) {
20     __asm__ volatile("" : : "g"(&value) : "memory");
21 }
22
23 NanoSecs bench_run() {
24     using Clock = std::chrono::steady_clock;
25     auto start = Clock::now();
26
27     double x = 4.2;
28     for (size_t iter = 0; iter < NUM_ITERS; ++iter) {
29         assume_accessed(x);
30         double res = std::sqrt(x); // Code étudié
31         assume_accessed(res);
32     }
33
34     return Clock::now() - start;
35 }
```

Hack encapsulé

« modifie » x

« lit » res

Mesures obtenues

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=20 -DNUM_ITERS=100000000 ex3a.cpp && ./a.out
```

| T_run(μ s) | T_iter, avg(ns) |
|-----------------|-----------------|
|-----------------|-----------------|

| | |
|--------|---------|
| 404327 | 4.04327 |
|--------|---------|

| | |
|--------|--------|
| 390330 | 3.9033 |
|--------|--------|

| | |
|--------|---------|
| 390454 | 3.90454 |
|--------|---------|

| | |
|--------|---------|
| 390403 | 3.90403 |
|--------|---------|

| | |
|--------|---------|
| 390268 | 3.90268 |
|--------|---------|

| | |
|--------|---------|
| 390501 | 3.90501 |
|--------|---------|

| | |
|--------|---------|
| 390379 | 3.90379 |
|--------|---------|

| | |
|--------|---------|
| 390275 | 3.90275 |
|--------|---------|

| | |
|--------|---------|
| 390356 | 3.90356 |
|--------|---------|

| | |
|--------|---------|
| 390299 | 3.90299 |
|--------|---------|

| | |
|--------|---------|
| 390355 | 3.90355 |
|--------|---------|

| | |
|--------|---------|
| 390304 | 3.90304 |
|--------|---------|

| | |
|--------|---------|
| 390288 | 3.90288 |
|--------|---------|

| | |
|--------|---------|
| 390271 | 3.90271 |
|--------|---------|

| | |
|--------|---------|
| 390281 | 3.90281 |
|--------|---------|

| | |
|--------|---------|
| 390527 | 3.90527 |
|--------|---------|

| | |
|--------|---------|
| 390448 | 3.90448 |
|--------|---------|

| | |
|--------|---------|
| 390667 | 3.90667 |
|--------|---------|

| | |
|--------|---------|
| 390302 | 3.90302 |
|--------|---------|

| | |
|--------|---------|
| 390281 | 3.90281 |
|--------|---------|

Notez que l'approche « aléatoire + somme » ne donnait qu'un résultat 1,25ns supérieur à la mesure `std::rand()`

Le parallélisme d'instruction complique l'interprétation du temps d'exécution d'un code complexe.

(D'ailleurs, ici nous mesurons le nombre de racines carrées par seconde « crête » de la machine, quand elle n'a rien d'autre à faire...)

Vérifions l'assembleur

```
0000000004013d0 <_Z9bench_runv>:
  [ ... prologue ... ]
4013df: callq 4010b0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
4013e4: lea 0x10(%rsp),%r12
4013e9: pxor %xmm2,%xmm2
4013ed: lea 0x18(%rsp),%rbp
4013f2: mov %rax,%r13
4013f5: mov 0xc24(%rip),%rax # 402020 <_IO_stdin_used+0x20>
4013fc: mov %rax,0x10(%rsp)
401401: nopl 0x0(%rax)
401408: movsd 0x10(%rsp),%xmm0
40140e: ucomisd %xmm0,%xmm2
401412: movapd %xmm0,%xmm1
401416: sqrtsd %xmm1,%xmm1 ← OK, ça marche
40141a: ja 40143b <_Z9bench_runv+0x6b>
40141c: movsd %xmm1,0x18(%rsp)
401422: sub $0x1,%rbx
401426: jne 401408 <_Z9bench_runv+0x38>
401428: callq 4010b0 <_ZNSt6chrono3_V212steady_clock3nowEv@plt>
  [ ... épilogue ... ]
40143b: movsd %xmm1,0x8(%rsp)
401441: callq 401060 <sqrt@plt>
401446: movsd 0x8(%rsp),%xmm1
40144c: movsd %xmm1,0x18(%rsp)
401452: sub $0x1,%rbx
401456: pxor %xmm2,%xmm2
40145a: jne 401408 <_Z9bench_runv+0x38>
40145c: jmp 401428 <_Z9bench_runv+0x58>
40145e: xchg %ax,%ax
```

« Coeur de boucle »
bien plus lisible !

Réduisons le travail manuel...

```
18 template <typename T>
19 void assume_accessed(T&& value) {
20     __asm__ volatile("" : : "g"(&value) : "memory");
21 }
22
23 template <typename Func>
24 void bench_iter(Func&& iteration) {
25     assume_accessed(iteration);
26     auto res = iteration();
27     assume_accessed(res);
28 }
29
30 NanoSecs bench_run() {
31     using Clock = std::chrono::steady_clock;
32     auto start = Clock::now();
33
34     double x = 4.2;
35     for (size_t iter = 0; iter < NUM_ITERS; ++iter) {
36         bench_iter([&x] { return std::sqrt(x); }); // Code étudié
37     }
38
39     return Clock::now() - start;
40 }
```

...et hop, on peut extraire la logique

main.cpp

```
1 #include <cmath>
2 #include <iomanip>
3 #include <ios>
4 #include <iostream>
5
6 #include "benchLib.hpp"
7
8
9 #ifndef NUM_RUNS
10 #define NUM_RUNS 20
11 #endif
12
13 #ifndef NUM_ITERS
14 #define NUM_ITERS 1
15 #endif
16
17 int main() {
18     // Code étudié
19     double x = 4.2;
20     auto iteration = [&x] { return std::sqrt(x); };
21
22     size_t col1_width = 15;
23     std::cout << std::left;
24     std::cout << std::setw(col1_width) << "T_run(µs)"
25             << "T_iter,avg(ns)" << std::endl;
26
27     for (size_t i = 0; i < NUM_RUNS; ++i) {
28         double t_run = bench_run(iteration, NUM_ITERS).count();
29         double t_iter = t_run / NUM_ITERS;
30         std::cout << std::setw(col1_width-1) << t_run / 1000
31                 << t_iter << std::endl;
32     }
33
34     return 0;
35 }
```

benchLib.hpp

```
1 #pragma once
2
3 #include <chrono>
4
5
6 using NanoSecs = std::chrono::nanoseconds;
7
8 template <typename T>
9 void assume_accessed(T&& value) {
10     __asm__ volatile("" : : "g"(&value) : "memory");
11 }
12
13 template <typename Func>
14 void bench_iter(Func&& iteration) {
15     assume_accessed(iteration);
16     auto res = iteration();
17     assume_accessed(res);
18 }
19
20 template <typename Func>
21 NanoSecs bench_run(Func&& iteration, size_t num_iters) {
22     using Clock = std::chrono::steady_clock;
23     auto start = Clock::now();
24
25     for (size_t iter = 0; iter < num_iters; ++iter) {
26         bench_iter(iteration);
27     }
28
29     return Clock::now() - start;
30 }
```

Métrieologie du temps d'exécution

Où en sommes-nous ?

- Jusqu'ici, on a regardé la stabilité des temps « à l'oeil »
- Il est plus que temps d'introduire de vraies barres d'erreur
 - Sur le temps de « run », un écart-type est vite calculé
 - Mais attention en inférant l'écart type du temps d'itération
 - $\text{Var}(T_{\text{run}}) = \text{Var}(\text{Somme}(i, T_{\text{iter},i}))$
 - Indépendance : $\text{Var}(T_{\text{run}}) = \text{Somme}(i, \text{Var}(T_{\text{iter},i}))$
 - Même distribution : $\text{Var}(T_{\text{run}}) = N_{\text{iter}} \times \text{Var}(T_{\text{iter}})$
 - Donc sous ces hypothèses, $\sigma_{\text{iter}} = \sigma_{\text{run}} / \sqrt{N_{\text{iter}}}$

Résultats

```
$ g++ -std=c++11 -O3 -DNUM_RUNS=10000 -DNUM_ITERS=100000 ex4a.cpp && ./a.out  
[ ... blabla ... ]
```

```
389.808      3.89808  
390.277      3.90277  
389.808      3.89808  
390.212      3.90212  
389.814      3.89814  
389.814      3.89814  
389.809      3.89809  
389.81       3.8981  
389.81       3.8981  
394.425      3.94425  
389.813      3.89813
```

```
=====
```

```
T_tot = 3919.15ms
```

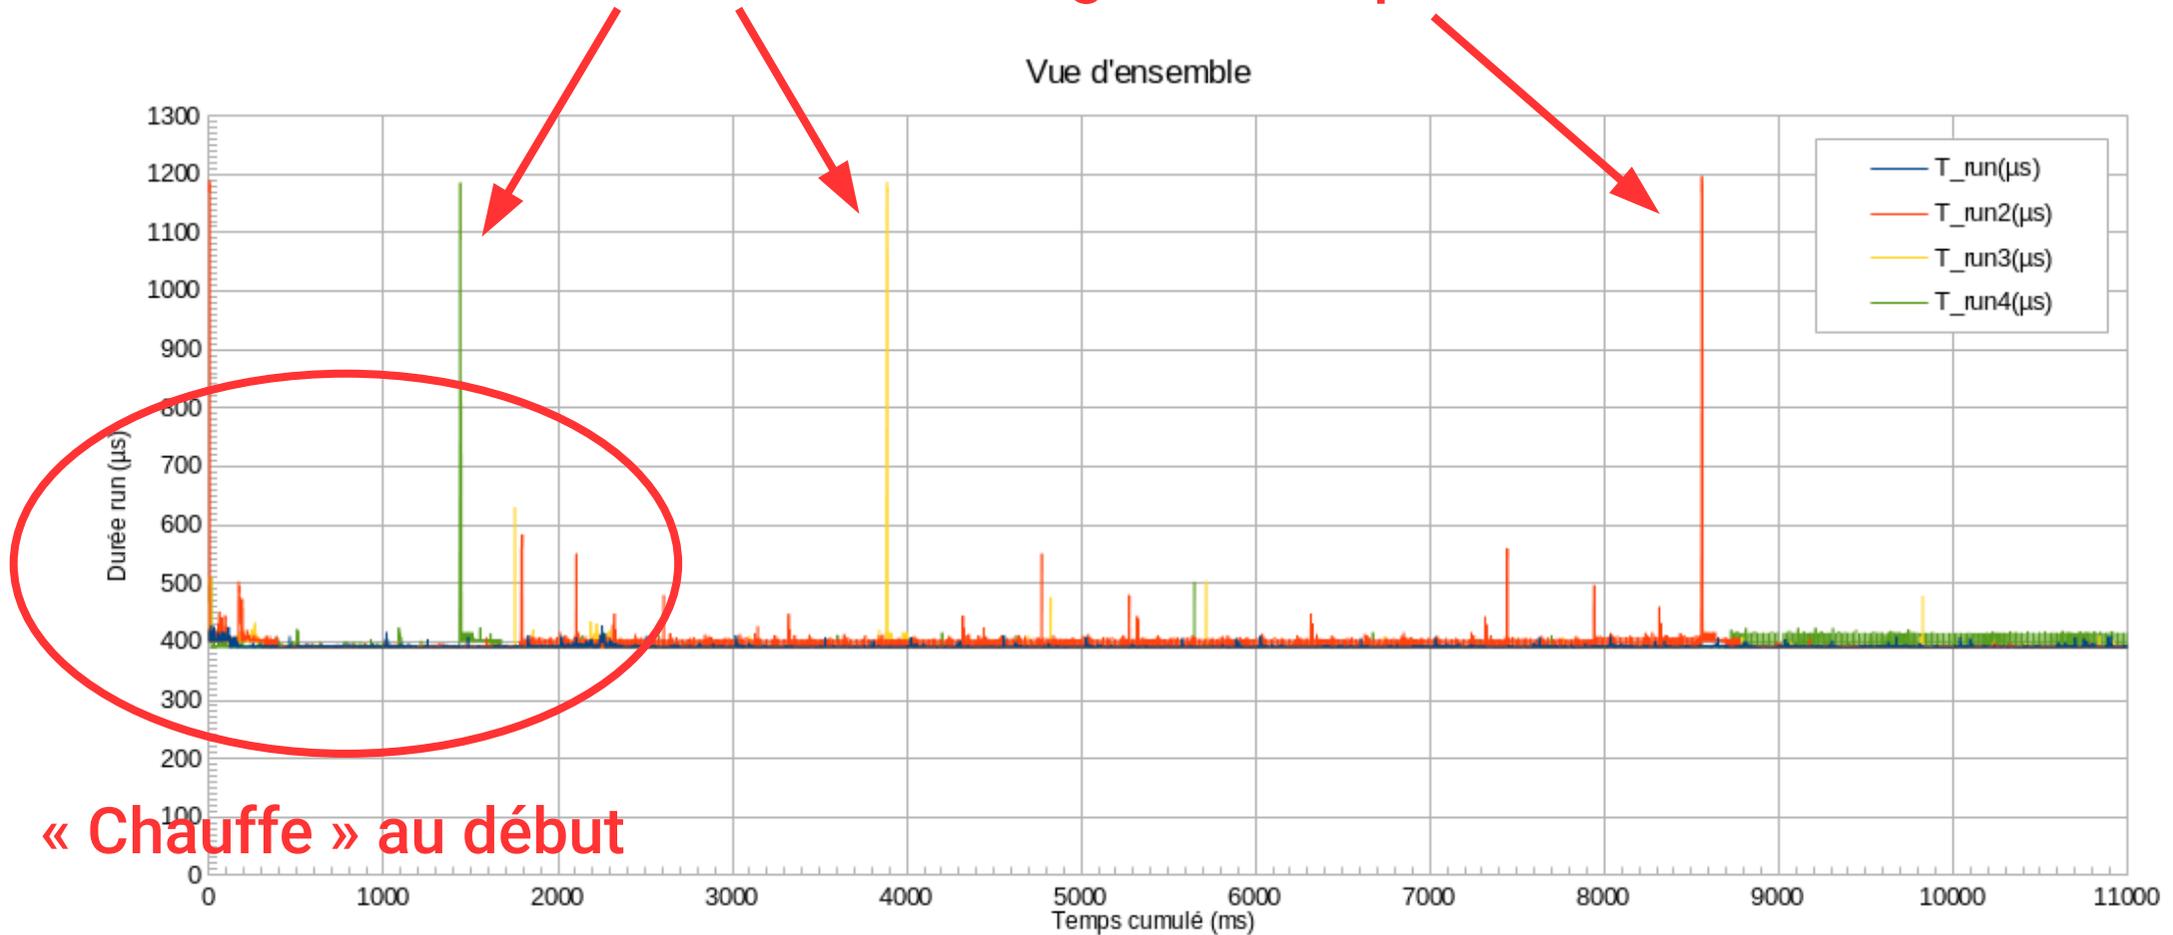
```
T_run ~ 391.915+/-1493.37μs
```

```
T_iter ~ 3.91915+/-4722.46ns
```

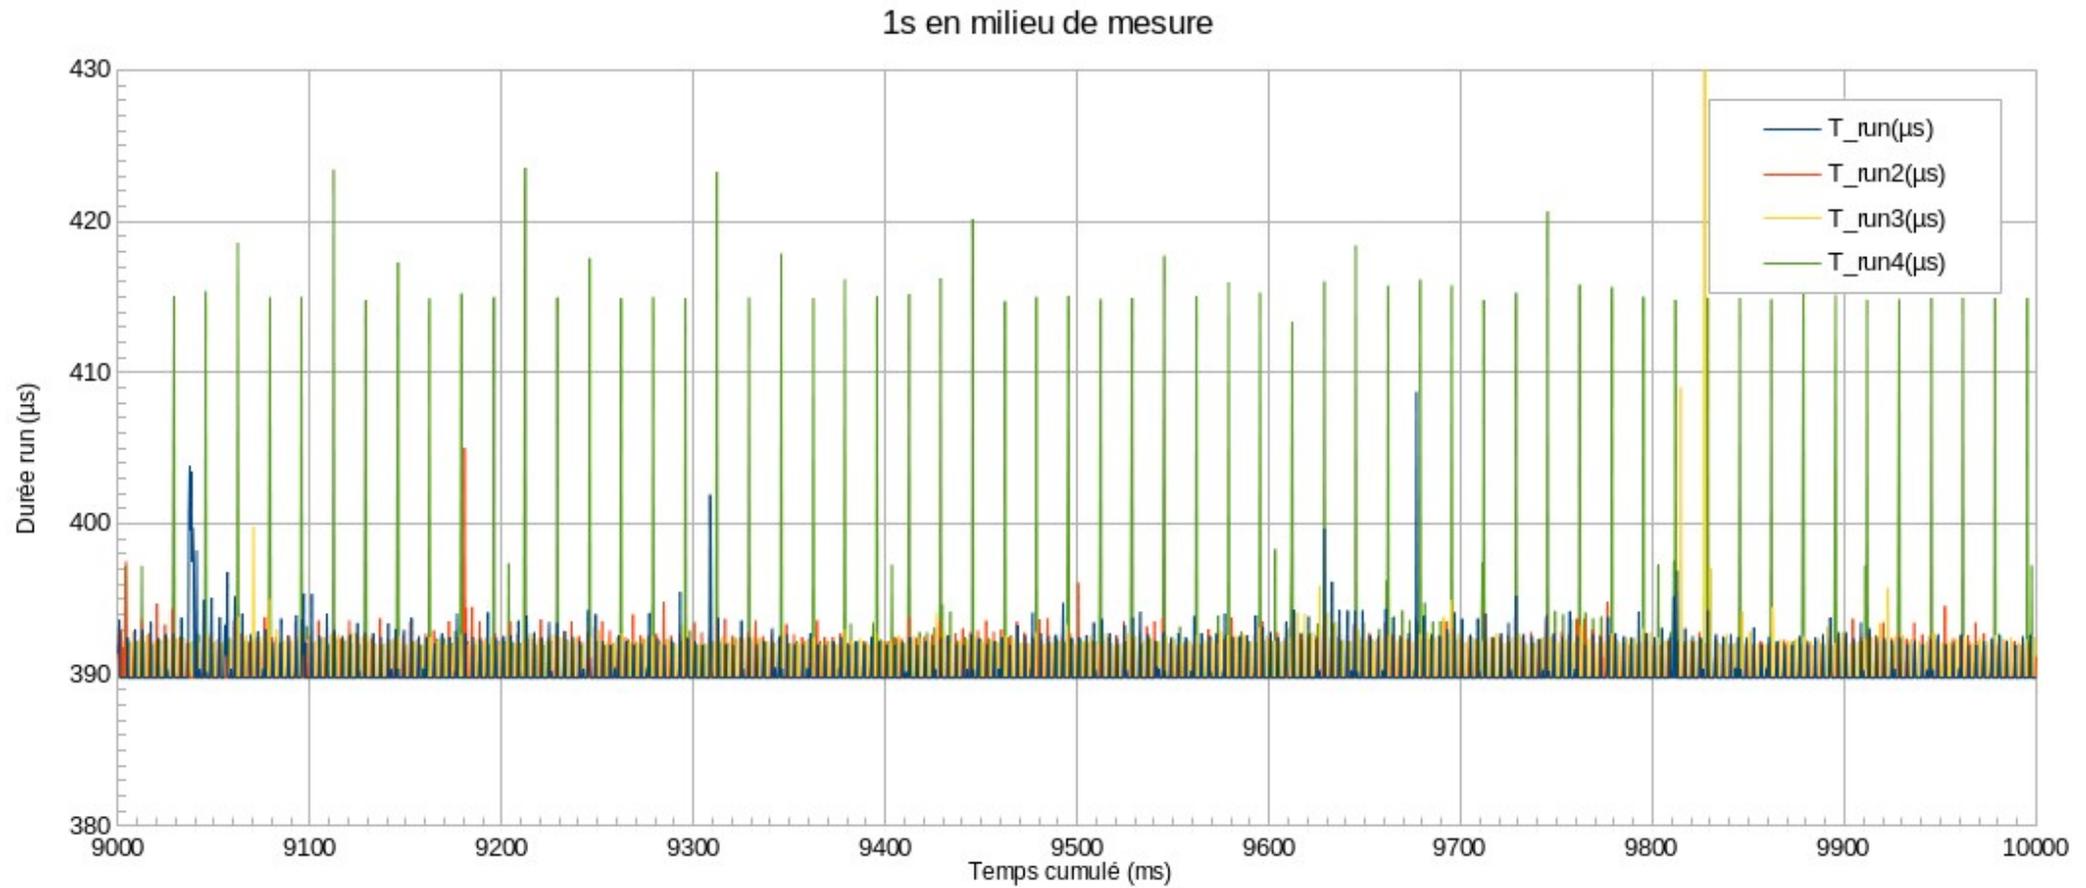
Ouch !

Examinons les temps...

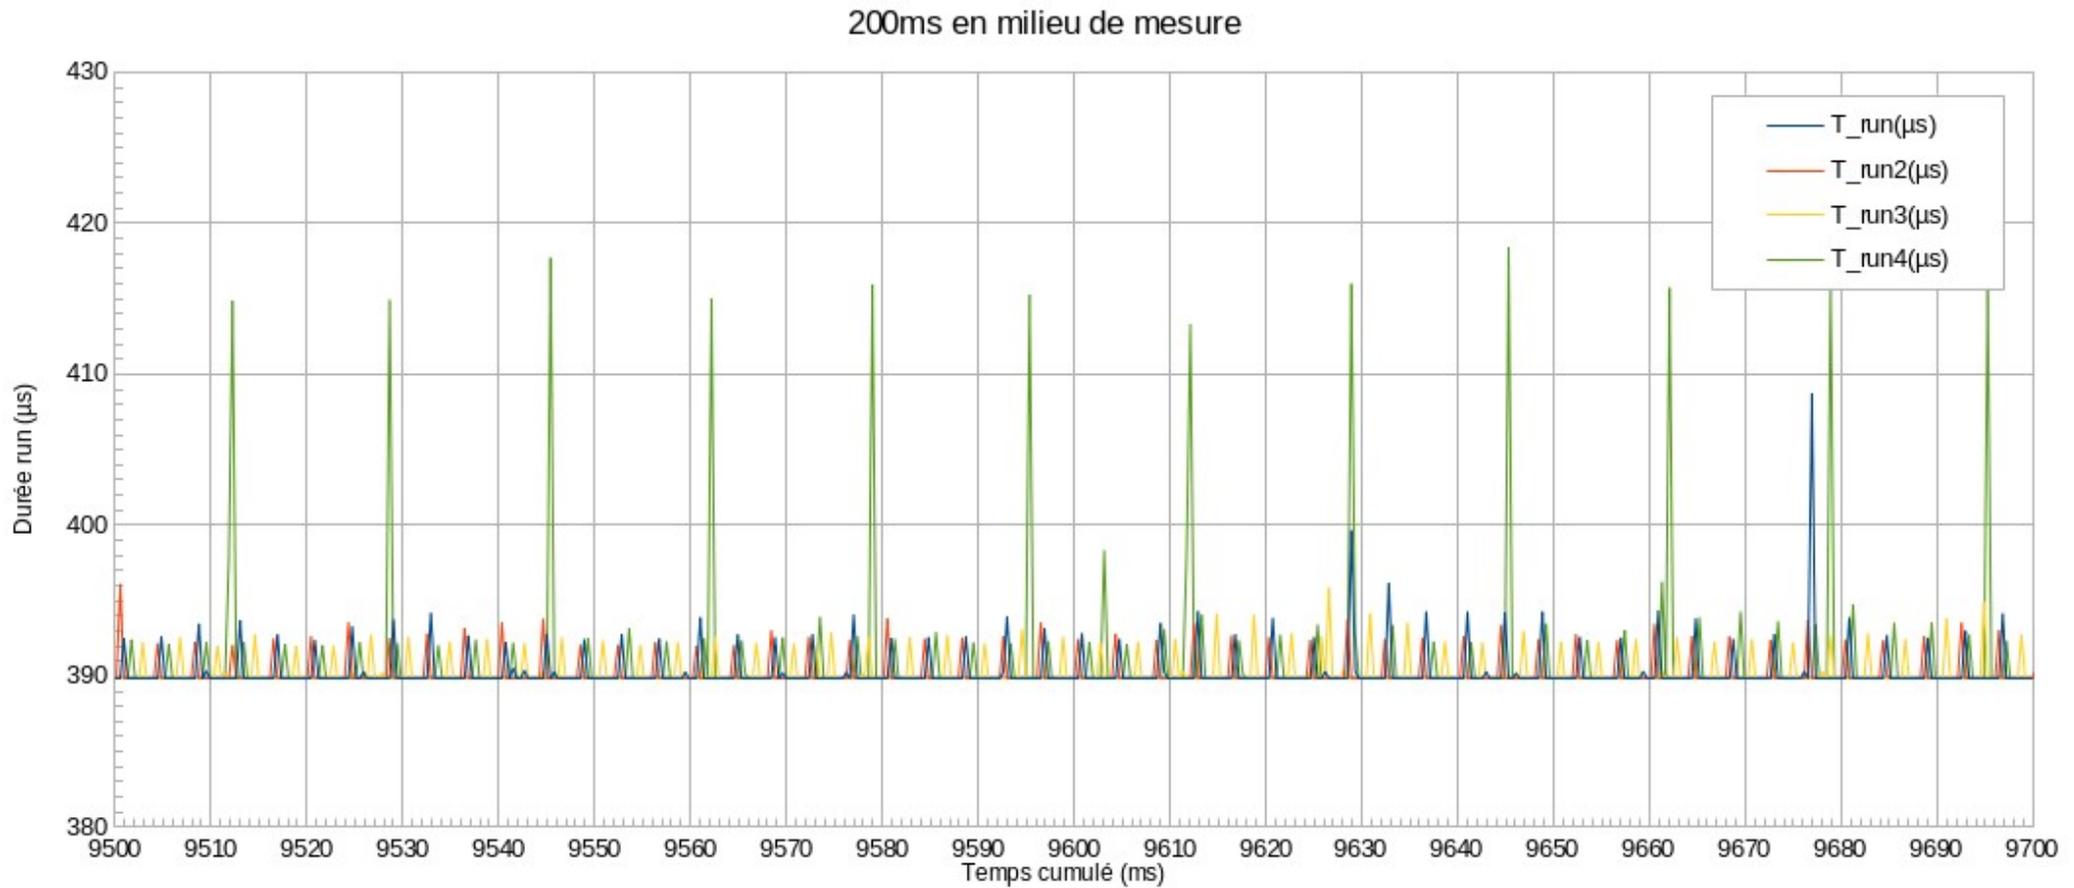
Événements rares de grande ampleur...



Zoomons un peu...



...encore un peu



Premières conclusions

- Il faut éjecter la période de chauffe (~ 1 s du début) de l'analyse
 - A la fois bruitée et non reproductible
- Perturbations périodiques de très grande ampleur
 - Ordonnanceur du système d'exploitation + IRQs
 - Pour diminuer leur poids statistique, il faut privilégier un grand nombre de mesures courtes ($\ll 1$ ms)

Effets de ces changements

Avant :

```
[ ... blabla ... ]
389.808      3.89808
390.277      3.90277
389.808      3.89808
390.212      3.90212
389.814      3.89814
389.814      3.89814
389.809      3.89809
389.81       3.8981
389.81       3.8981
394.425      3.94425
389.813      3.89813
```

=====

```
T_tot = 3919.15ms
T_run ~ 391.915+/-1493.37µs
T_iter ~ 3.91915+/-4722.46ns
```

Après :

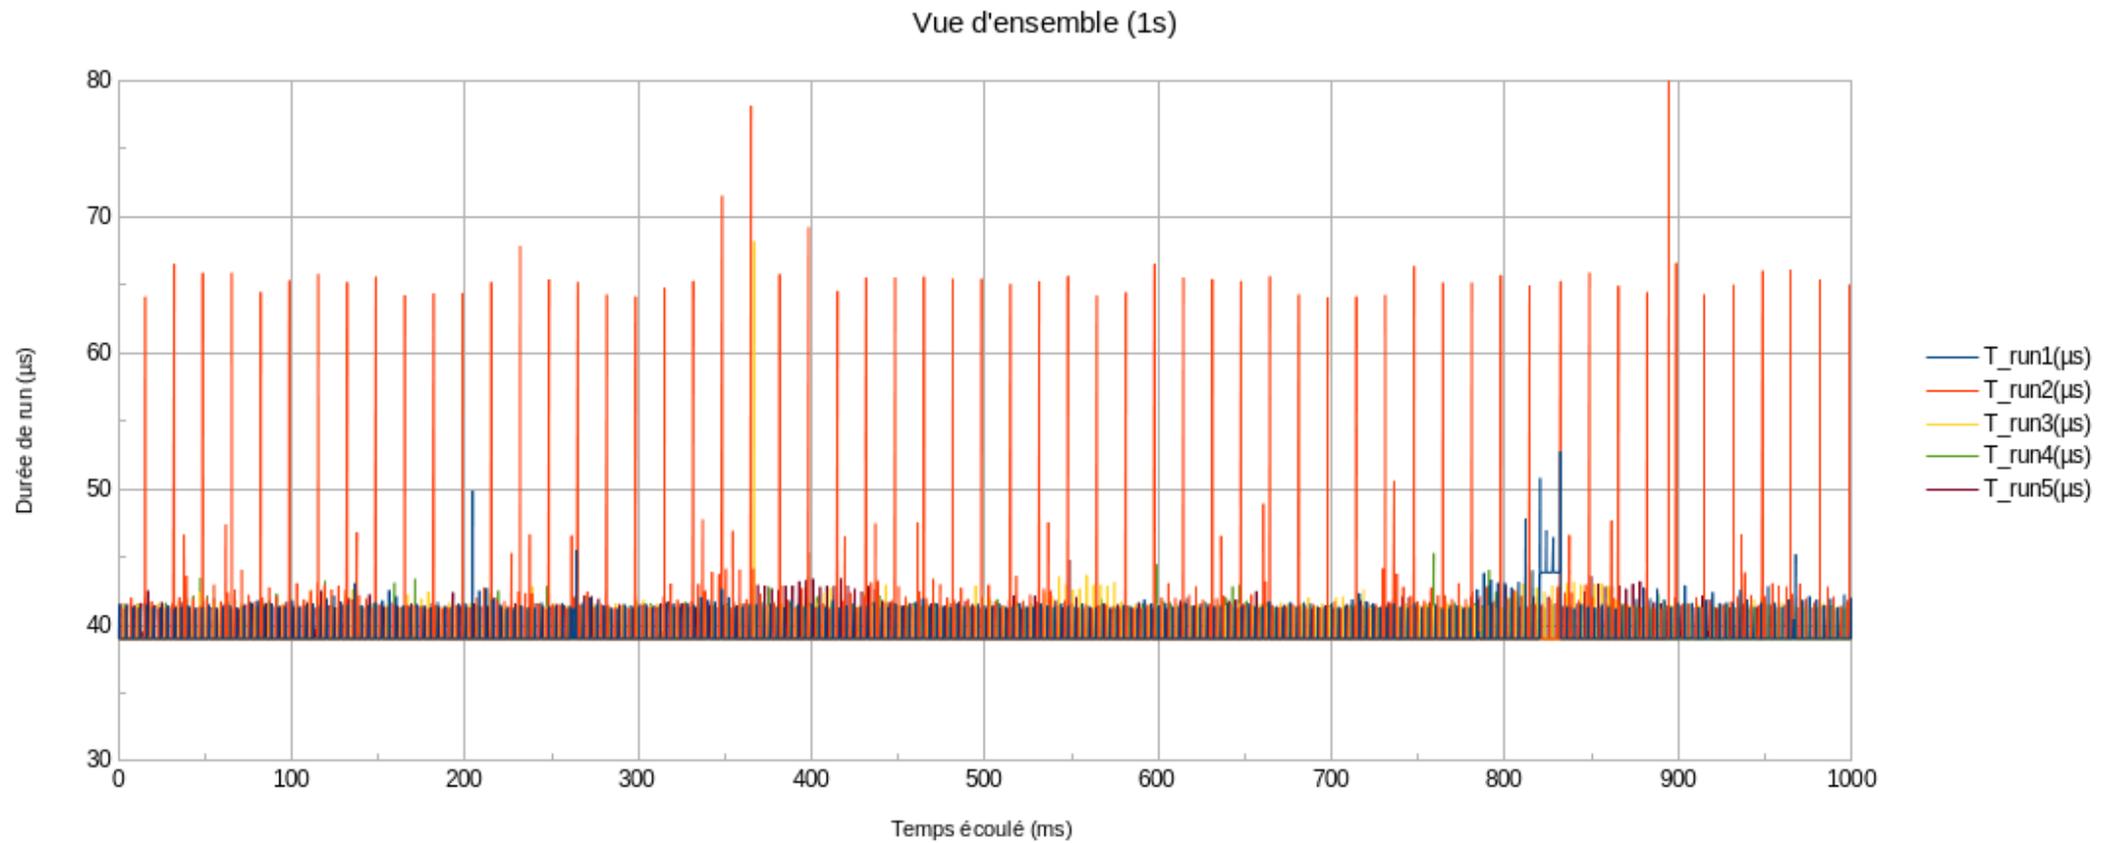
```
[ ... blabla ... ]
38.999       3.8999
38.996       3.8996
38.996       3.8996
38.997       3.8997
38.995       3.8995
38.998       3.8998
38.996       3.8996
38.997       3.8997
38.997       3.8997
38.995       3.8995
38.998       3.8998
```

=====

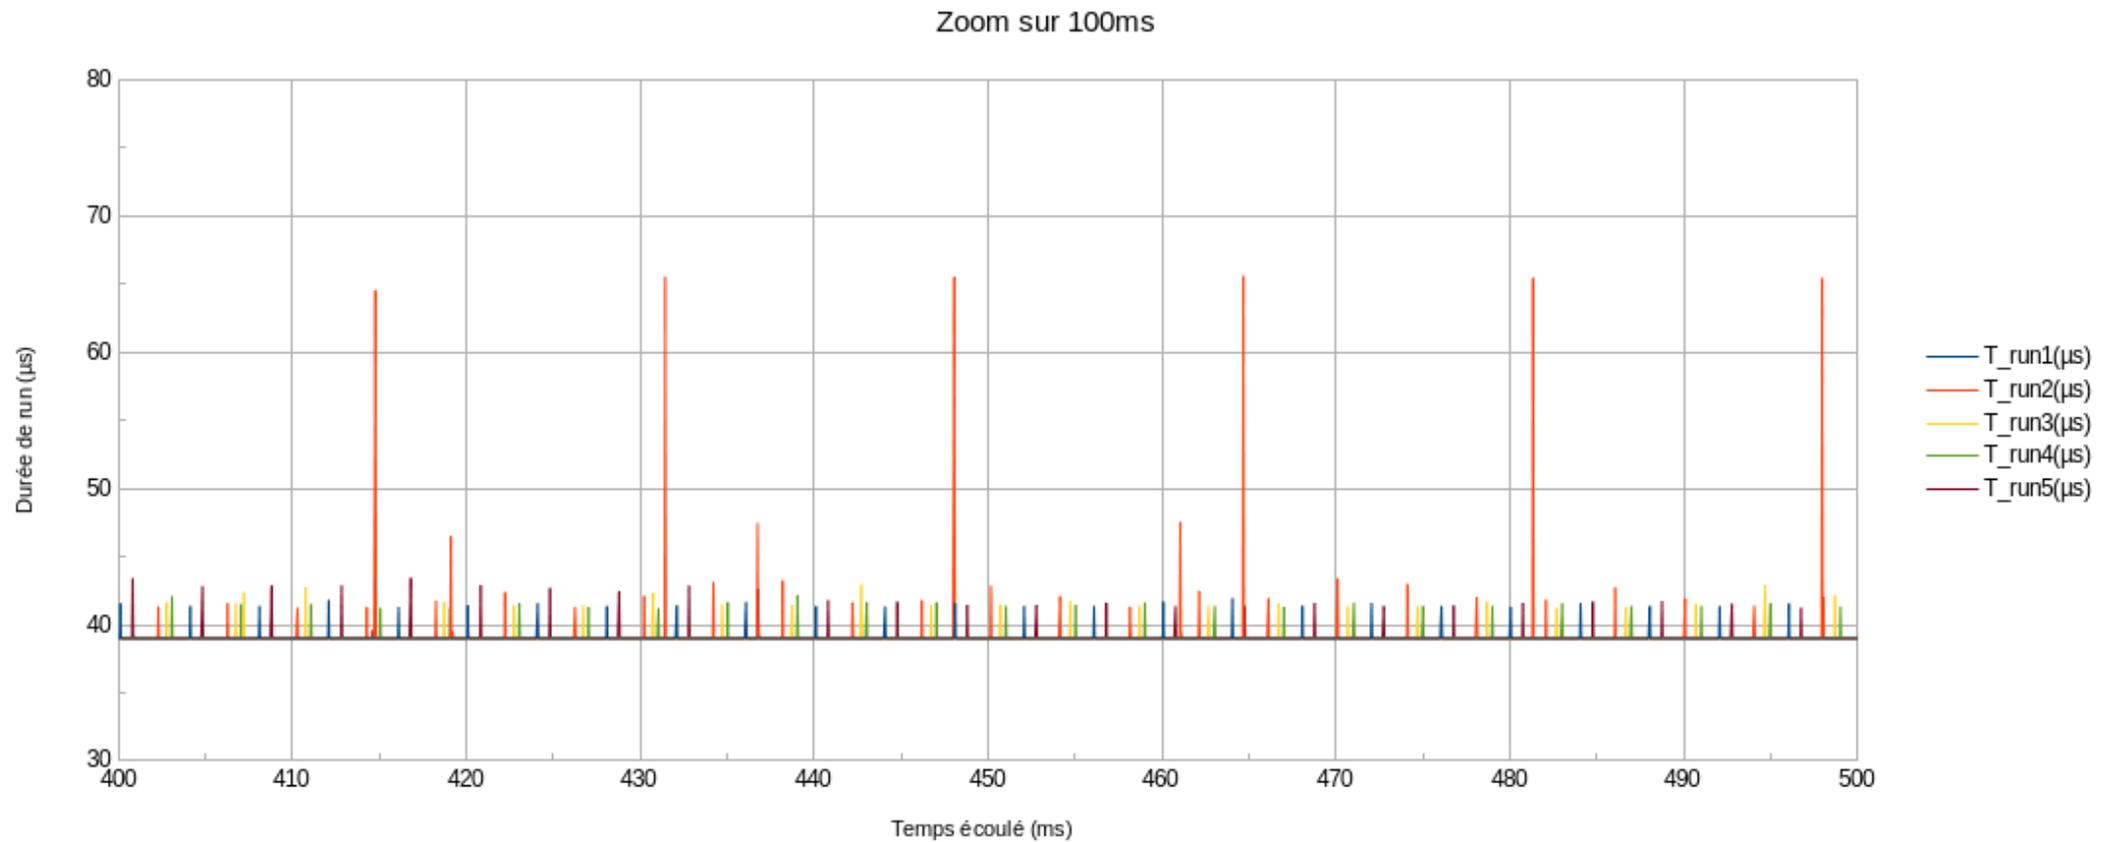
```
T_tot = 3902.67ms
T_run ~ 39.0267+/-97.2103µs
T_iter ~ 3.90267+/-972.103ns
```

C'est mieux, mais ce n'est pas encore ça...

Nouvelles mesures, vue d'ensemble

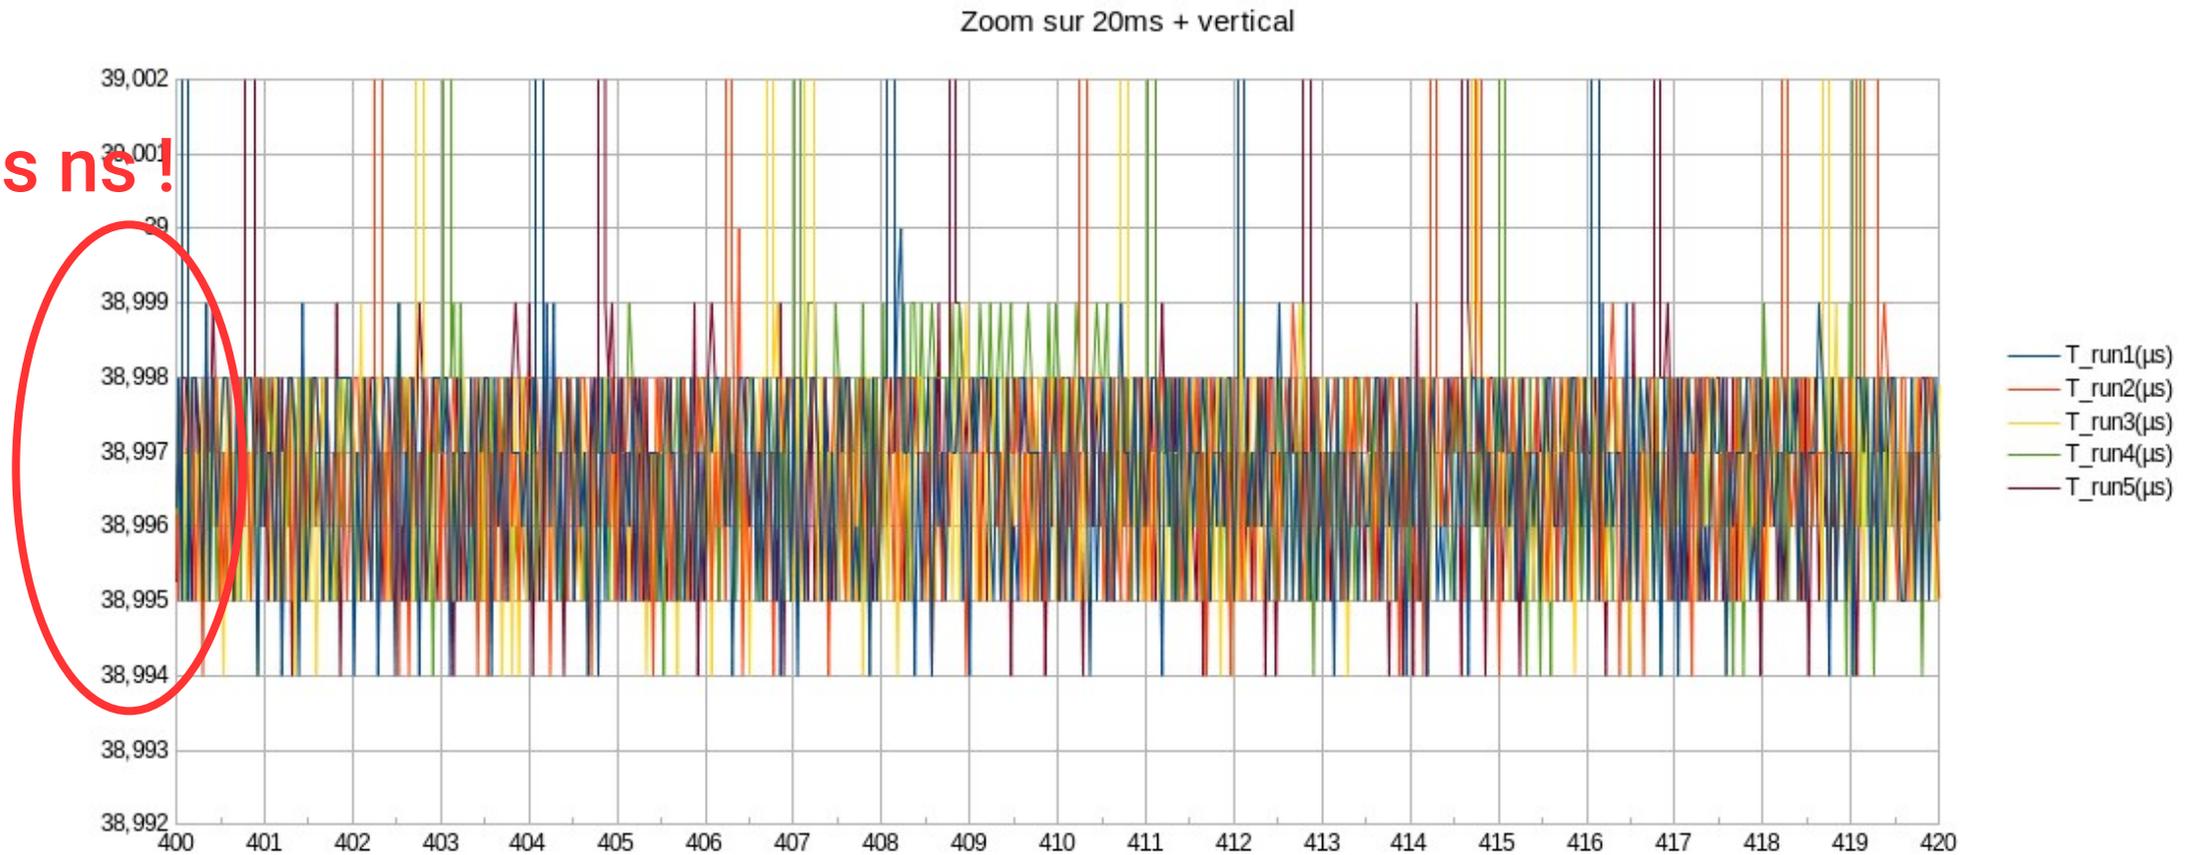


Zoomons un peu...



...encore un peu

quelques ns !



Nouvelles conclusions

- Nous mesurons dans un état stable
- La majorité de nos mesures sont précises à quelques ns
 - ...mais la contribution des « pics ordonnanceur » à nos statistiques reste forte, et dissimule cette vraie résolution
- Solution : Utiliser des statistiques robustes aux *outliers*
 - Médiane = Estimateur robuste de la moyenne
 - On peut également dériver un estimateur robuste de l'écart-type à partir de l'intervalle inter-quartile

Effets des statistiques robustes

Avant :

```
[ ... blabla ... ]
38.999      3.8999
38.996      3.8996
38.996      3.8996
38.997      3.8997
38.995      3.8995
38.998      3.8998
38.996      3.8996
38.997      3.8997
38.997      3.8997
38.995      3.8995
38.998      3.8998
=====
T_tot = 3902.67ms
T_run ~ 39.0267+/-97.2103µs
T_iter ~ 3.90267+/-972.103ns
```

Après :

```
T_tot = 1175.2ms
T_run ~ 38.997+/-0.0022239µs
T_iter ~ 3.8997+/-0.022239ns
```

**Le niveau de bruit de mesure
est le même (~1-2ns)...**

**...mais les statistiques
robustes permettent d'extraire
le « signal utile » !**

Conclusion

- Les benchmarks sont un outil utile
- L'écriture d'un benchmark n'a rien d'évident
- Un bon protocole de mesure et d'analyse permet...
 - ...d'éliminer un certain nombre de biais
 - ...de se rapprocher de la précision de l'horloge machine
- Cette présentation ne fait qu'introduire le problème
 - Gare à vos biais dans l'écriture du code
 - Gare aux biais du matériel (cache, ILP, etc)

Merci de votre attention !

Benchmarking addition

T_tot = 279.126ms

T_run ~ 27.865+/-0.000741301μs

T_iter ~ 0.5573+/-0.0104836ns

Benchmarking multiplication

T_tot = 278.824ms

T_run ~ 27.865+/-0.000741301μs

T_iter ~ 0.5573+/-0.0104836ns

Benchmarking division

T_tot = 195.276ms

T_run ~ 19.507+/-0.000741301μs

T_iter ~ 3.9014+/-0.0104836ns

Benchmarking square root

T_tot = 195.223ms

T_run ~ 19.508+/-0.0014826μs

T_iter ~ 3.9016+/-0.0209672ns

Benchmarking exponential

T_tot = 320.799ms

T_run ~ 32.053+/-0.000741301μs

T_iter ~ 6.4106+/-0.0104836ns

Benchmarking logarithm

T_tot = 284.638ms

T_run ~ 28.424+/-0.0252042μs

T_iter ~ 5.6848+/-0.356442ns

Benchmarking sinus

T_tot = 524.091ms

T_run ~ 52.365+/-0.0311346μs

T_iter ~ 10.473+/-0.44031ns

Benchmarking arc-tangent

T_tot = 549.212ms

T_run ~ 54.879+/-0.014826μs

T_iter ~ 21.9516+/-0.209672ns

Mesures effectuées avec un CPU Intel Xeon E5-1620 v3 @ 3.50GHz + Linux 5.5.6 + GCC 9.2.1