
Instrumenter CPython avec DTrace et SystemTap

Version 3.13.1

Guido van Rossum and the Python development team

décembre 27, 2024

Python Software Foundation
Email : docs@python.org

Table des matières

1	Activer les marqueurs statiques	2
2	Sondes DTrace statiques	3
3	Marqueurs statiques <i>SystemTap</i>	4
4	Marqueurs statiques disponibles	5
5	<i>Tapsets</i> de <i>SystemTap</i>	6
6	Exemples	7

auteur

David Malcolm

auteur

Łukasz Langa

DTrace et *SystemTap* sont des outils de surveillance, chacun fournissant un moyen de d'inspecter ce que font les processus d'un système informatique. Ils utilisent tous les deux des langages dédiés permettant à un utilisateur d'écrire des scripts qui permettent de :

- Filtrer les processus à observer.
- Recueillir des données sur le processus choisi.
- Générer des rapports sur les données.

À partir de Python 3.6, CPython peut être compilé avec des « marqueurs » intégrés, aussi appelés « sondes », qui peuvent être observés par un script *DTrace* ou *SystemTap*, ce qui facilite le suivi des processus CPython.

Particularité de l'implémentation CPython : Les marqueurs DTrace sont des détails d'implémentation de l'interpréteur CPython. Aucune garantie n'est donnée quant à la compatibilité des sondes entre les versions de CPython. Les scripts DTrace peuvent s'arrêter de fonctionner ou fonctionner incorrectement sans avertissement lors du changement de version de CPython.

1 Activer les marqueurs statiques

macOS est livré avec un support intégré pour *DTrace*. Sous Linux, pour construire CPython avec les marqueurs embarqués pour *SystemTap*, les outils de développement *SystemTap* doivent être installés.

Sur une machine Linux, cela se fait via :

```
$ yum install systemtap-sdt-devel
```

ou :

```
$ sudo apt-get install systemtap-sdt-dev
```

CPython doit être configuré avec l'option `--with-dtrace` :

```
checking for --with-dtrace... yes
```

Sous macOS, vous pouvez lister les sondes *DTrace* disponibles en exécutant un processus Python en arrière-plan et en listant toutes les sondes mises à disposition par le fournisseur Python :

```
$ python3.6 -q &
$ sudo dtrace -l -P python$! # or: dtrace -l -m python3.6

 ID  PROVIDER          MODULE           FUNCTION NAME
29564 python18035    python3.6        _PyEval_EvalFrameDefault function-entry
29565 python18035    python3.6        dtrace_function_entry function-entry
29566 python18035    python3.6        _PyEval_EvalFrameDefault function-
˓→return
29567 python18035    python3.6        dtrace_function_return function-
˓→return
29568 python18035    python3.6        collect gc-done
29569 python18035    python3.6        collect gc-start
29570 python18035    python3.6        _PyEval_EvalFrameDefault line
29571 python18035    python3.6        maybe_dtrace_line line
```

Sous Linux, pour vérifier que les marqueurs statiques *SystemTap* sont présents dans le binaire compilé, il suffit de regarder s'il contient une section `.note.stapsdt`.

```
$ readelf -S ./python | grep .note.stapsdt
[30] .note.stapsdt      NOTE          0000000000000000 00308d78
```

Si vous avez compilé Python en tant que bibliothèque partagée (avec l'option `--enable-shared` du script `configure`), vous devez plutôt regarder dans la bibliothèque partagée. Par exemple :

```
$ readelf -S libpython3.3dm.so.1.0 | grep .note.stapsdt
[29] .note.stapsdt      NOTE          0000000000000000 00365b68
```

Une version suffisamment moderne de `readelf` peut afficher les métadonnées :

```
$ readelf -n ./python

Displaying notes found at file offset 0x00000254 with length 0x00000020:
  Owner          Data size          Description
  GNU            0x00000010        NT_GNU_ABI_TAG (ABI version tag)
  OS: Linux, ABI: 2.6.32

Displaying notes found at file offset 0x00000274 with length 0x00000024:
  Owner          Data size          Description
  GNU            0x00000014        NT_GNU_BUILD_ID (unique build ID)
  (suite sur la page suivante)
```

```

→bitstring)
Build ID: df924a2b08a7e89f6e11251d4602022977af2670

Displaying notes found at file offset 0x002d6c30 with length 0x00000144:
  Owner          Data size      Description
  stapsdt        0x00000031    NT_STAPSDT (SystemTap probe_
→descriptors)
  Provider: python
  Name: gc_start
  Location: 0x00000000004371c3, Base: 0x0000000000630ce2, Semaphore:_
→0x000000000008d6bf6
  Arguments: -4@%ebx
  stapsdt        0x00000030    NT_STAPSDT (SystemTap probe_
→descriptors)
  Provider: python
  Name: gc_done
  Location: 0x00000000004374e1, Base: 0x0000000000630ce2, Semaphore:_
→0x000000000008d6bf8
  Arguments: -8@%rax
  stapsdt        0x00000045    NT_STAPSDT (SystemTap probe_
→descriptors)
  Provider: python
  Name: function_entry
  Location: 0x00000000053db6c, Base: 0x0000000000630ce2, Semaphore:_
→0x000000000008d6be8
  Arguments: 8@%rbp 8@%r12 -4@%eax
  stapsdt        0x00000046    NT_STAPSDT (SystemTap probe_
→descriptors)
  Provider: python
  Name: function_return
  Location: 0x00000000053dba8, Base: 0x0000000000630ce2, Semaphore:_
→0x000000000008d6bea
  Arguments: 8@%rbp 8@%r12 -4@%eax

```

The above metadata contains information for SystemTap describing how it can patch strategically placed machine code instructions to enable the tracing hooks used by a SystemTap script.

2 Sondes DTrace statiques

L'exemple suivant de script *DTrace* montre la hiérarchie d'appel/retour d'un script Python, en ne traçant que l'invocation d'une fonction *start*. En d'autres termes, les appels de fonctions lors de la phase d'import ne seront pas répertoriées :

```

self int indent;

python$target:::function-entry
/copyinstr(arg1) == "start"/
{
    self->trace = 1;
}

python$target:::function-entry
/self->trace/
{
    printf("%d\t%s:", timestamp, 15, probename);
    printf("%*s", self->indent, "");
}

```

(suite sur la page suivante)

(suite de la page précédente)

```
        printf("%s:%s:%d\n", basename(copyinstr(arg0)), copyinstr(arg1), arg2);
        self->indent++;
}

python$target:::function-return
/self->trace/
{
    self->indent--;
    printf("%d\t%*s:", timestamp, 15, probename);
    printf("%*s", self->indent, "");
    printf("%s:%s:%d\n", basename(copyinstr(arg0)), copyinstr(arg1), arg2);
}

python$target:::function-return
/copyinstr(arg1) == "start"/
{
    self->trace = 0;
}
```

Il peut être utilisé de cette manière :

```
$ sudo dtrace -q -s call_stack.d -c "python3.6 script.py"
```

La sortie ressemble à ceci :

```
156641360502280  function-entry:call_stack.py:start:23
156641360518804  function-entry: call_stack.py:function_1:1
156641360532797  function-entry:  call_stack.py:function_3:9
156641360546807  function-return:  call_stack.py:function_3:10
156641360563367  function-return: call_stack.py:function_1:2
156641360578365  function-entry: call_stack.py:function_2:5
156641360591757  function-entry:  call_stack.py:function_1:1
156641360605556  function-entry:   call_stack.py:function_3:9
156641360617482  function-return:  call_stack.py:function_3:10
156641360629814  function-return:  call_stack.py:function_1:2
156641360642285  function-return:  call_stack.py:function_2:6
156641360656770  function-entry:  call_stack.py:function_3:9
156641360669707  function-return:  call_stack.py:function_3:10
156641360687853  function-entry:  call_stack.py:function_4:13
156641360700719  function-return:  call_stack.py:function_4:14
156641360719640  function-entry:  call_stack.py:function_5:18
156641360732567  function-return:  call_stack.py:function_5:21
156641360747370  function-return:call_stack.py:start:28
```

3 Marqueurs statiques SystemTap

La façon la plus simple d'utiliser l'intégration *SystemTap* est d'utiliser directement les marqueurs statiques. Pour cela vous devez pointer explicitement le fichier binaire qui les contient.

Par exemple, ce script *SystemTap* peut être utilisé pour afficher la hiérarchie d'appel/retour d'un script Python :

```
probe process("python").mark("function_entry") {
    filename = user_string($arg1);
    funcname = user_string($arg2);
    lineno = $arg3;
```

(suite sur la page suivante)

```

printf("%s => %s in %s:%d\\n",
       thread_indent(1), funcname, filename, lineno);
}

probe process("python").mark("function_return") {
    filename = user_string($arg1);
    funcname = user_string($arg2);
    lineno = $arg3;

    printf("%s <= %s in %s:%d\\n",
           thread_indent(-1), funcname, filename, lineno);
}

```

Il peut être utilisé de cette manière :

```
$ stap \
show-call-hierarchy.stp \
-c "./python test.py"
```

La sortie ressemble à ceci :

```

11408 python(8274):      => __contains__ in Lib/_abcoll.py:362
11414 python(8274):      => __getitem__ in Lib/os.py:425
11418 python(8274):      => encode in Lib/os.py:490
11424 python(8274):      <= encode in Lib/os.py:493
11428 python(8274):      <= __getitem__ in Lib/os.py:426
11433 python(8274):      <= __contains__ in Lib/_abcoll.py:366

```

où les colonnes sont :

- temps en microsecondes depuis le début du script
- nom de l'exécutable
- PID du processus

et le reste indique la hiérarchie d'appel/retour lorsque le script s'exécute.

Pour une compilation --enable-shared de CPython, les marqueurs sont contenus dans la bibliothèque partagée *libpython*, et le chemin du module de la sonde doit le refléter. Par exemple, la ligne de l'exemple ci-dessus :

```
probe process("python").mark("function_entry") {
```

doit plutôt se lire comme :

```
probe process("python").library("libpython3.6dm.so.1.0").mark("function_entry") {
```

(en supposant une version de CPython 3.6 compilée avec le débogage activé)

4 Marqueurs statiques disponibles

```
function_entry(str filename, str funcname, int lineno)
```

Ce marqueur indique que l'exécution d'une fonction Python a commencé. Il n'est déclenché que pour les fonctions en Python pur (code intermédiaire).

Le nom de fichier, le nom de la fonction et le numéro de ligne sont renvoyés au script de traçage sous forme d'arguments positionnels, auxquels il faut accéder en utilisant \$arg1, \$arg2, \$arg3 :

- \$arg1 : (const char *) nom de fichier, accessible via `user_string($arg1)`
- \$arg2 : (const char *) nom de la fonction, accessible via `user_string($arg2)`
- \$arg3 : numéro de ligne int

```
function_return(str filename, str funcname, int lineno)
```

This marker is the converse of `function_entry()`, and indicates that execution of a Python function has ended (either via `return`, or via an exception). It is only triggered for pure-Python (bytecode) functions.

The arguments are the same as for `function_entry()`

```
line(str filename, str funcname, int lineno)
```

Ce marqueur indique qu'une ligne Python est sur le point d'être exécutée. C'est l'équivalent du traçage ligne par ligne avec un profiteur Python. Il n'est pas déclenché dans les fonctions C.

The arguments are the same as for `function_entry()`.

```
gc_start(int generation)
```

Fires when the Python interpreter starts a garbage collection cycle. `arg0` is the generation to scan, like `gc.collect()`.

```
gc_done(long collected)
```

Fonction appelée lorsque l'interpréteur Python termine un cycle de collecte du ramasse-miettes. `Arg0` est le nombre d'objets collectés.

```
import_find_load_start(str modulename)
```

Fonction appelée avant que `importlib` essaye de trouver et de charger le module. `arg0` est le nom du module.

Ajouté dans la version 3.7.

```
import_find_load_done(str modulename, int found)
```

Fonction appelée après que la fonction `find_and_load` du module `importlib` soit appelée. `arg0` est le nom du module, `arg1` indique si le module a été chargé avec succès.

Ajouté dans la version 3.7.

```
audit(str event, void *tuple)
```

Fonction appelée quand les fonctions `sys.audit()` ou `PySys_Audit()` sont appelées. `arg0` est le nom de l'évènement de type chaîne de caractère C. `arg1` est un pointeur sur un *n*-uplet d'objet de type `PyObject`.

Ajouté dans la version 3.8.

5 Tapsets de SystemTap

La façon la plus simple d'utiliser l'intégration *SystemTap* est d'utiliser un « *tapset* ». L'équivalent pour *SystemTap* d'une bibliothèque, qui permet de masquer les détails de niveau inférieur des marqueurs statiques.

Voici un fichier *tapset*, basé sur une version non partagée compilée de CPython :

```
/*
Provide a higher-level wrapping around the function_entry and
function_return markers:
*/
probe python.function.entry = process("python").mark("function_entry")
{
    filename = user_string($arg1);
    funcname = user_string($arg2);
    lineno = $arg3;
    frameptr = $arg4
}
probe python.function.return = process("python").mark("function_return")
{
    filename = user_string($arg1);
    funcname = user_string($arg2);
    lineno = $arg3;
    frameptr = $arg4
}
```

Si ce fichier est installé dans le répertoire *tapset* de *SystemTap* (par exemple `/usr/share/systemtap/tapset`), alors ces sondes supplémentaires deviennent disponibles :

```
python.function.entry(str filename, str funcname, int lineno, frameptr)
```

Cette sonde indique que l'exécution d'une fonction Python a commencé. Elle n'est déclenchée que pour les fonctions en Python pur (code intermédiaire).

```
python.function.return(str filename, str funcname, int lineno, frameptr)
```

Cette sonde est l'inverse de `python.function.return`, et indique que l'exécution d'une fonction Python est terminée (soit via `return`, soit via une exception). Elle est uniquement déclenchée pour les fonctions en Python pur (code intermédiaire ou *bytecode*).

6 Exemples

Ce script *SystemTap* utilise le *tapset* ci-dessus pour implémenter plus proprement l'exemple précédent de traçage de la hiérarchie des appels de fonctions Python, sans avoir besoin de nommer directement les marqueurs statiques :

```
probe python.function.entry
{
    printf("%s => %s in %s:%d\n",
           thread_indent(1), funcname, filename, lineno);
}

probe python.function.return
{
    printf("%s <= %s in %s:%d\n",
           thread_indent(-1), funcname, filename, lineno);
}
```

The following script uses the tapset above to provide a top-like view of all running CPython code, showing the top 20 most frequently entered bytecode frames, each second, across the whole system :

```
global fn_calls;

probe python.function.entry
{
    fn_calls[pid(), filename, funcname, lineno] += 1;
}

probe timer.ms(1000) {
    printf("\033[2J\033[1;1H") /* clear screen */
    printf("%6s %80s %6s %30s %6s\n",
           "PID", "FILENAME", "LINE", "FUNCTION", "CALLS")
    foreach ([pid, filename, funcname, lineno] in fn_calls - limit 20) {
        printf("%6d %80s %6d %30s %6d\n",
               pid, filename, lineno, funcname,
               fn_calls[pid, filename, funcname, lineno]);
    }
    delete fn_calls;
}
```