Qualité algorithmique

2 — Optimisation des performances

Anthony Labarre

Université Gustave Eiffel

Plan d'aujourd'hui

La compilation et les types

La lenteur de Python

Python est réputé “lent” pour plusieurs raisons :

- langage interprété : à chaque exécution, chaque instruction doit être analysée, interprétée, puis seulement exécutée ;
- machine virtuelle : le programme ne “parle” pas directement à la machine ;
- langage typé dynamiquement :
  - toutes les vérifications de type doivent se faire à l’exécution ;
  - le code ne peut donc pas être optimisé à l’avance ;

Solutions pénibles

Diverses solutions existent :

- compiler le code : Cython, Numba, . . .
- ajouter des annotations de type (via `cdef` en Cython) ;
- importer du code provenant d'autres langages (C, Fortran, . . .) : `ctypes`, `cffi`, . . . ;
- écrire directement le code en CPython ($\neq$ Cython) ;

. . . qu'on va courageusement éviter d'utiliser car elles nous compliqueraient grandement la vie.

(mais allez voir `https://compilers.pydata.org/` si vous êtes curieux)

Une solution pragmatique : PyPy

- Une des manières les plus rentables d'accélérer son code est d'utiliser l'interpréteur PyPy ;
- Si tout se passe bien, on n'a rien à modifier dans notre code : il suffit d'écrire `pypy3` au lieu de `python3` à l'exécution ;

Examinons un exemple.

```
cayley.py --operation prefix-reversal 9
```

PyPy est-il magique ?

- Deux approches de compilation permettent d'améliorer les performances :
  1. AOT (pour ahead of time) : comme en C ;
  2. JIT (pour just in time) : au fur et à mesure des besoins ;
- PyPy effectue de la compilation JIT ;
- Les gains en performance sont corrélés avec la proportion de code pouvant en bénéficier ;

Inconvénients de PyPy

- PyPy a toujours un train de retard sur la dernière version de Python ;
- Il peut donc y avoir des incompatibilités, pas toujours rattrapables ;
- Dans certains cas (rares), PyPy peut être moins performant que Python ;

- . . . mais vu l'investissement, ça vaut le coup d'essayer ;

(plus d'infos sur les performances :
`https://www.pypy.org/performance.html`)

Et dans d'autres langages ?

- Certains autres langages interprétés proposent peut-être des interpréteurs améliorés équivalents ;
- Cherchez “JIT”, “compilation”, . . .
- Si vous utilisez un langage compilé, examinez les options de votre compilateur ;
  - par exemple pour `gcc` : l'option `-O` permet de définir le niveau d'optimisation ;

Mémorisation des résultats

Mémorisation des résultats

- Rappels sur les compromis performances / mémoire : on peut accélérer les calculs en stockant des résultats intermédiaires ;
- On a vu que les dictionnaires pouvaient nous éviter facilement ces calculs ;
- En Python, c'est extrêmement simple à implémenter : il suffit d'utiliser le **décorateur** `lru_cache` du module standard `functools` ;

Utilisation de `lru_cache`

- `lru_cache` construit un dictionnaire `{paramètres: résultat}`, pour la fonction décorée, qui est automatiquement consulté à chaque appel ;
- De notre point de vue, on peut considérer ce dictionnaire comme global (même si c'est faux) ;
- On limite (ou non) sa taille avec le paramètre `maxsize` ;
- Utilisation :

```
# limite de taille par défaut
@lru_cache
def ma_fonction(...):
    ...
```

```
# taille illimitée
@lru_cache(maxsize=None)
def ma_fonction(...):
    ...
```

`lru_cache` en action

Mesurons le temps mis pour calculer F_{35} récursivement (visualisez les problèmes ici : https://recursion.vercel.app/) :

```
In [1]: def fib(n):
   ...:     return n if n < 2 else fib(n-1) + fib(n-2)
   ...:
In [2]: %time fib(35)
CPU times: user 1.47 s, sys: 202 µs, total: 1.47 s
Wall time: 1.47 s
Out[2]: 9227465
```

. . . et après décoration :

```
In [3]: from functools import lru_cache
In [4]: @lru_cache(maxsize=None)
   ...: def fib(n):
   ...:     return n if n < 2 else fib(n-1) + fib(n-2)
   ...:
In [5]: %time fib(35)
CPU times: user 59 µs, sys: 1 µs, total: 60 µs
Wall time: 64.6 µs
Out[5]: 9227465
```

`lru_cache` en action

On peut facilement vérifier la différence en termes de nombre d'appels avec `cProfile` :

```
$ python3 -m cProfile -s ncalls fibo.py  # sans lru_cache
         29860706 function calls (4 primitive calls) in 3.478 seconds

   Ordered by: call count

   ncalls  tottime  percall  cumtime  percall filename:lineno(function)
29860703/1    3.478    0.000    3.478    3.478 fibo.py:1(fib)

...

$ python3 -m cProfile -s ncalls fibo.py # avec lru_cache
         57 function calls (22 primitive calls) in 0.000 seconds

   Ordered by: call count

   ncalls  tottime  percall  cumtime  percall filename:lineno(function)
     36/1    0.000    0.000    0.000    0.000 fibo.py:3(fib)

...
```

Contourner les limitations de la récursivité

Python limite le nombre d'appels récursifs que l'on peut effectuer.

Utilisez des appels "poubelle" pour remplir le dictionnaire de `lru_cache` !

Exemple

Si calculer F_{1500} provoque une erreur, on peut effectuer un appel plus raisonnable juste pour réduire le nombre d'appels récursifs :

```
>>> fib(1500)  # décorée par lru_cache
...
RecursionError: maximum recursion depth exceeded
>>> fib(1400)  # appel "poubelle"
[le résultat s'affiche]
>>> fib(1500)  # assez de valeurs stockées
[le résultat s'affiche]
```

Les décorateurs

Les décorateurs

- Les **décorateurs** sont des fonctions modifiant d'autres fonctions ;
- Lorsqu'on "décore" une fonction `f` à l'aide d'une fonction `deco`, la fonction `deco` exécute `f` ET d'autres lignes de code rajoutées ;
- Intérêts :
  1. modifier le comportement du code à moindre coût ;
  2. tester rapidement des changements avant de les appliquer ;
  3. modifier le comportement de fonctions auxquelles on n'a pas accès en écriture ;

Utilisation de décorateurs

- Les **décorateurs** sont très simples à utiliser :
  - `@decorateur` devant la définition de la fonction à décorer ;
  - ou `@decorateur(arguments)` le cas échéant ;
- On peut les cumuler :

```
@deco_1
@deco_2
def fonction(...):
    ...
```

applique d'abord `deco_2`, puis `deco_1` ;

Écriture de décorateurs

Si l'utilisation des décorateurs est simple, leur écriture . . .

```
from functools import wraps

def decorateur(f):
    @wraps(f)
    def decoration(*args, **kwargs):
        return f(*args, **kwargs)
    return decoration
```

. . . mérite quelques mots d'explication.

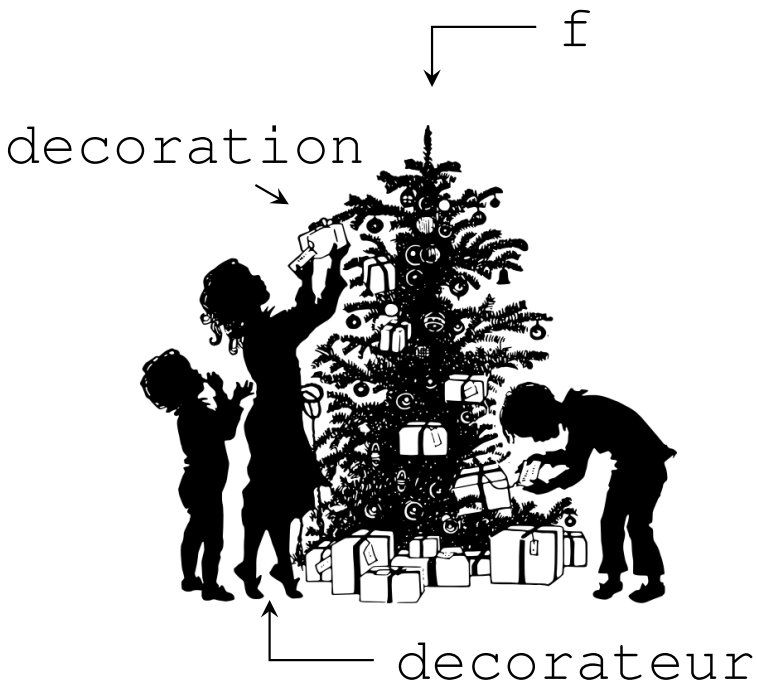

Intuitivement, le `decorateur` définit une nouvelle fonction de `decoration` qui va remplacer la fonction `f` lorsqu'on va la décorer (≡ `f = decorateur(f)`).

Examinons maintenant les détails techniques.

Fonctions imbriquées

```python
from functools import wraps

def decorateur(f):
    @wraps(f)
    def decoration(*args, **kwargs):
        return f(*args, **kwargs)
    return decoration
```

- On peut définir des fonctions **dans** d'autres fonctions ;
- En général, on l'évite car les fonctions imbriquées ne sont pas accessibles ;
- Dans ce contexte, c'est justifié : la `decoration` n'a pas à être visible hors du `decorateur` ;

Fonctions imbriquées et récursivité

Cela permet aussi d'écrire des fonctions récursives plus efficaces :

Version classique

```
def rech_rec(L, x, i):
    if i < 0:
        return
    if L[i] == x:
        return i
    return rech_rec(L, x, i-1)


def recherche(L, x):
    return rech_rec(L, x, len(L)-1)
```

Version améliorée

```
def recherche(L, x):
    def rech_rec(i):
        if i < 0:
            return
        if L[i] == x:
            return i
        return rech_rec(i-1)

    return rech_rec(len(L)-1)
```

Dans la seconde version, les contextes empilés lors des appels récursifs ne comporteront plus que le paramètre `i`.

L'opérateur $\star$

L'**opérateur unaire de déballage** $\star$ permet d'extraire le contenu d'un itérable en plusieurs morceaux.

```
from functools import wraps

def decorateur(f):
    @wraps(f)
    def decoration(*args, **kwargs):
        return f(*args, **kwargs)
    return decoration
```

Exemple (utilisation de $\star$)

Comment extraire les éléments d'une liste dans des variables séparées ?

✗ `>>> premier, reste, dernier = list(range(10))`

✓ `>>> premier, *reste, dernier = list(range(10))`

```
>>> print(premier, dernier)
0 9
>>> print(reste)
[1, 2, 3, 4, 5, 6, 7, 8]
```

`reste` est une liste, indépendamment du type de la valeur à droite du `=`.

`*` et appels de fonctions

- `*` permet aussi de convertir un itérable en une liste de paramètres (donc des variables séparées par des virgules, et non une liste Python) ;
- Ceci permet des appels très concis ;

Exemple (`*` et appels de fonctions)

`set.union` calcule l'union d'un nombre arbitraire d'ensembles.

```
>>> liste = [{i} for i in range(10)]
>>> set.union(liste[0], liste[1], liste[2], ...)
{0, 1, 2, 3, 4, 5, 6, 7, 8, 9}
```

```
>>> set.union(*liste)
{0, 1, 2, 3, 4, 5, 6, 7, 8, 9}
```

Fonctions à nombre variable d'arguments

```python
from functools import wraps

def decorateur(f):
    @wraps(f)
    def decoration(*args, **kwargs):
        return f(*args, **kwargs)
    return decoration
```

- La syntaxe `*args` dans une définition de fonction spécifie un nombre variable (éventuellement nul) d'arguments ;
- `args` est un `tuple` de valeurs ;

Exemple (nombre variable d'arguments)

```
>>> def fonction_1(*args):
...     print("J'ai reçu", len(args), "arguments")
...
>>> fonction_1()
J'ai reçu 0 arguments
>>> fonction_1(1, 2)
J'ai reçu 2 arguments
>>> fonction_1("bla", "blou", None)
J'ai reçu 3 arguments
```

Arguments nommés en nombre variable

```python
from functools import wraps

def decorateur(f):
    @wraps(f)
    def decoration(*args, **kwargs):
        return f(*args, **kwargs)
    return decoration
```

- On peut nommer les paramètres, ce qui permet de les communiquer dans n'importe quel ordre ;
- `**kwargs` dans la définition d'une fonction spécifie un dictionnaire arbitraire au format `{nom: valeur}`.

Exemple (arguments nommés en nombre variable)

```
>>> def fonction_2(**kwargs):
...     print("J'ai reçu", len(kwargs), "arguments")
...     for k, v in kwargs.items():
...         print("\tnom:", k, ", valeur:", v)
...
>>> fonction_2(taille=3, ens={1, 5}, temperature=37)
J'ai reçu 3 arguments
    nom: taille , valeur: 3
    nom: ens , valeur: {1, 5}
    nom: temperature , valeur: 37
```

Arguments anonymes et nommés

- On peut mélanger les deux types d'arguments, en respectant le format suivant :
  1. d'abord tous les arguments "positionnels" ;
  2. ensuite tous les arguments nommés ;
- Le format le plus général est donc :

```
def fonction(*args, **kwargs):
    ...
```

  qui accepte un nombre variable d'arguments anonymes suivi d'un nombre variable d'arguments nommés.
- C'est donc celui qu'on rencontrera le plus pour les décorateurs ;

Fonctionnement d'un décorateur

```python
from functools import wraps

def decorateur(f):
    @wraps(f)
    def decoration(*args, **kwargs):
        return f(*args, **kwargs)
    return decoration
```

- Lorsqu'on décore une fonction, on la remplace par une nouvelle version décorée ;
- Autrement dit, écrire ceci :

```python
@decorateur
def ma_fonction(...):
    ...
```

équivaut à écrire ceci :

```python
ma_fonction = decorateur(ma_fonction)
```

- C'est pourquoi `decorateur` renvoie une fonction, et non le résultat d'un appel (sinon on ne pourrait pas appeler le résultat) ;

Le décorateur `wraps`

```python
from functools import wraps

def decorateur(f):
    @wraps(f)
    def decoration(*args, **kwargs):
        return f(*args, **kwargs)
    return decoration
```

`@wraps` permet de rendre la décoration transparente : l'utilisateur ne se rend plus compte que la fonction est décorée.

Exemple (avec et sans `@wraps`)

```
>>> @decorateur
... def ma_fonction():
...     """Je ne fais rien."""
...     pass
...
>>> ma_fonction.__name__, ma_fonction.__doc__   # sans @wraps
('decoration', None)
>>> ma_fonction.__name__, ma_fonction.__doc__   # avec @wraps
('ma_fonction', 'Je ne fais rien.')
```

Appliquer un décorateur à une fonction tierce

- Décorer une fonction que l'on définit soi-même est simple ;
- Mais comment décorer une fonction provenant d'un module tiers ?
  - `@deco\n def fonction(...)` n'est possible que si on peut écrire dans le fichier ;
  - `fonction = deco(fonction)` fonctionne . . . sauf si `fonction` est récursive !
- Il vaut mieux utiliser la fonction intégrée

```
setattr(objet, attribut, valeur)
```

qui permet de modifier un attribut d'un objet de manière dynamique.

Appliquer un décorateur à une fonction tierce

L'option la plus simple est d'importer le module, puis d'utiliser `setattr` pour appliquer le décorateur.

Exemple (décorer une fonction à la volée)

```
import fibo
from functools import lru_cache
setattr(fibo, "fib", lru_cache(fibo.fib))
...
```

Et on peut même décorer toutes les fonctions importées :

Exemple (décorer toutes les fonctions importées)

```
import mon_module
from functools import lru_cache

for nom in dir(mon_module):
    objet = getattr(mon_module, nom)  # renvoie l'objet correspondant au nom donné
    if callable(objet):                  # objet appelable -> fonction (ou classe)
        setattr(mon_module, nom, lru_cache(objet))
...
```

Appliquer un décorateur à une fonction tierce

- Si l'on ne veut pas importer tout le module, les choses se compliquent un peu ;
- `setattr(fibo, ...)` ne fonctionne pas puisqu'on n'a pas importé le module `fibo` ;
- On doit identifier **l'objet** correspondant au module qui contient `fib` ;
- Cela donne :

```
from fibo import fib
from functools import lru_cache
import sys
setattr(sys.modules[fib.__module__], "fib", lru_cache(fib))
...
```

Ajout de propriétés à une fonction

On peut rajouter des propriétés à une fonction.

- Une manière d'implémenter `lru_cache` est de rajouter un dictionnaire à la fonction décorée ;

Exemple

```
def lru_cache(f):
    f.resultats = dict()
    def decoration(*args, **kwargs):
        # si args / kwargs appartient à f.resultats: renvoyer le résultat
        # sinon, appeler f et mettre à jour f.resultats
```

- Et on peut faire cela avec n'importe quel ajout dont on aurait besoin lors d'appels différents ;

La sérialisation

Contexte

- Certains calculs coûteux doivent parfois être effectués juste pour une initialisation ;
- Même si on ne peut pas y échapper la première fois, on veut éviter de refaire le travail à chaque lancement du programme ;
- La **sérialisation** consiste à enregistrer un objet au format binaire sur le disque pour pouvoir le recharger en mémoire plus tard ;

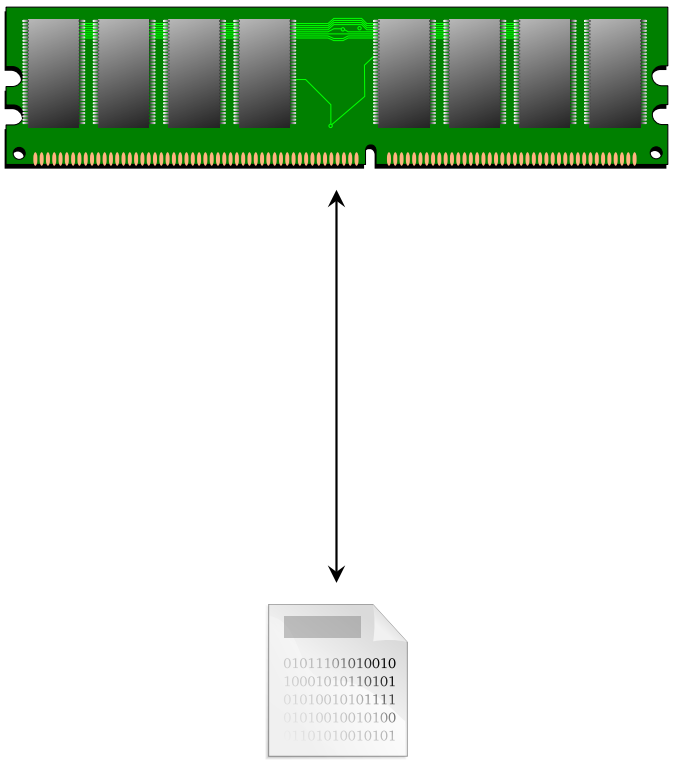

Le module standard `pickle`

- Python propose la sérialisation à l'aide du module standard `pickle` ;
- Il est extrêmement simple à utiliser :
  1. pour sauver un objet :

```
>>> import pickle
>>> objet = ...
>>> with open("mon_objet", "wb") as sortie:
...     pickle.dump(objet, sortie)
```

  2. pour charger un objet :

```
>>> import pickle
>>> with open("mon_objet", "rb") as entree:
...     objet = pickle.load(entree)
```

Limitations de `pickle`

- La plupart des objets “standards” de Python sont sérialisables ;
- Ce n’est pas garanti pour les objets des modules tiers ou ceux que vous définissez ;
- Attention à la compatibilité, notamment avec PyPy (voir les formats dans la documentation de `pickle`) ;

Consultez la documentation de `pickle` pour savoir ce qui n’est pas sérialisable et comment y remédier.

Le parallélisme

Threads et processus

- Un **processus** est une instance d'un programme en cours d'exécution ;
- Un **fil** (ou thread) peut être vu comme un sous-processus d'un processus donné ;
- Un processus peut comporter plusieurs threads, qui :
  - partagent le même espace mémoire et les mêmes ressources ;
  - **donnent l'illusion** de travailler en parallèle ;
- En réalité, un processus s'exécute sur un seul cœur du processeur, que se partagent tour à tour ses threads ;

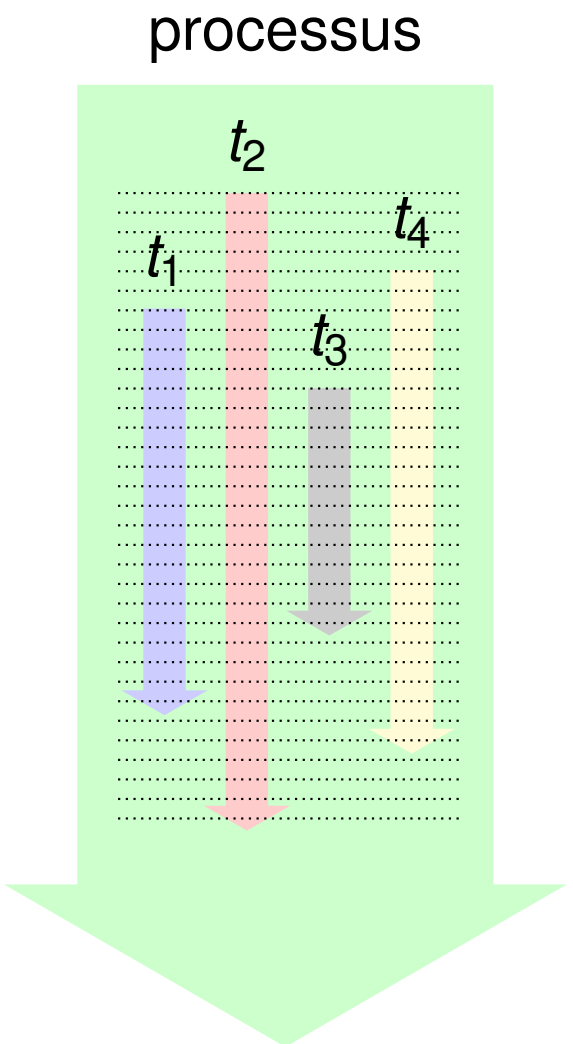

Threads

- Les threads ont leur utilité et sont disponibles via le module standard `threading` ;
- Leur intérêt du point de vue des performances est limité :
  1. ils ne permettent pas d'exploiter plusieurs cœurs à la fois ;
  2. en Python, le GIL (Global Interpreter Lock) ne permet pas aux threads d'agir en parallèle même si le processeur le permet ;
- On va donc privilégier une approche multipliant les processus plutôt que les threads, puisque chaque processus pourra tourner en parallèle sur un cœur différent ;

Le module standard `multiprocessing`

- Le module standard `multiprocessing` nous donne accès aux processus multiples (et aux threads) ;
- Il démultiplie le processus actuel en plusieurs processus (rappelez-vous de `fork`) ;
- On obtient donc plusieurs interpréteurs Python pouvant chacun s'exécuter sur des cœurs différents ;

Gains et mises en garde

- Le parallélisme n'est pas la réponse à tout ;
- Avec n cœurs, on va au mieux n fois plus vite ;
- Attention : le parallélisme a des coûts, proportionnels notamment à la communication entre les processus :
  1. en temps de calcul ;
  2. en mémoire ;
  3. . . . et en difficulté d'implémentation ;

Exemple 1 (sans dépendances entre processus)

Calculons les *n* premières puissances de 2 en répartissant le travail sur tous les processeurs.

```python
import multiprocessing


def calculer(num):
    return 2 ** num


def main():
    n = int(1e5)
    print(
        "Calcul parallèle des", n, "premières puissances de 2 sur",
        multiprocessing.cpu_count(), "coeurs"
    )
    nombres = range(n)
    with multiprocessing.Pool() as p:
        valeurs = p.map(func=calculer, iterable=nombres)


if __name__ == '__main__':
    main()
```

crée un ensemble de *k* processus (par défaut, *k* est le nombre de cœurs)

applique `f` à chaque élément de `it` (version parallèle de `map`)

Limitations de `Pool.map`

- `Pool.map(func=f, iterable=it)` suppose que chaque élément de `it` est un paramètre à passer à `f` ;
- Comment faire pour utiliser des fonctions à plusieurs paramètres ?
- On utilise `Pool.starmap` ;

Exemple 2 (sans dépendances entre processus)

Calculons $0^0, 1^1, 2^2, \ldots, n^n$ en répartissant le travail sur tous les processeurs.

```
import multiprocessing


def calculer(mantisse, exposant):
    return mantisse ** exposant

def main():
    n = int(1e4) * 2
    print(
        "Calcul parallèle de 0 ** 0, 1 ** 1, 2 ** 2, ...,", n, "**", n, "sur",
        multiprocessing.cpu_count(), "coeurs"
    )
    nombres = zip(range(n+1), range(n+1))
    with multiprocessing.Pool() as p:
        valeurs = p.starmap(func=calculer, iterable=nombres)


if __name__ == '__main__':
    main()
```

crée les couples `(0, 0), (1, 1), (2, 2), ...`

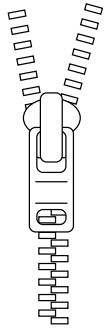

crée un ensemble de *k* processus (par défaut, *k* est le nombre de cœurs)

applique `f` à chaque itérable de `it` : si `it = [[a, b, c], ...]`, on aura `f(a, b, c)`

Communication entre processus

- Dans les exemples précédents, les processus accèdent au même itérable, mais uniquement en lecture pour l'initialisation ;
- On ne sait pas dans quel ordre les tâches sont effectuées, mais le `Pool` attend que tous les processus se terminent avant de passer à la suite (à la fin du **`with`**) :

- Les choses se compliquent quand il faut partager des données entre les processus ;
- `multiprocessing` le permet, mais avec des types particuliers ;
- Examinons un exemple simple : tester la primalité d'un naturel ;

Test parallèle de primalité : intuition

- L'algorithme naïf pour vérifier si un nombre n est premier teste tous les diviseurs impairs jusqu'à $\sqrt{n}$;
- Pour le paralléliser, on demande à chaque processus de vérifier en parallèle un sous-intervalle ;
- Si on trouve un diviseur, plus la peine d'en chercher un autre . . .
- . . . et il faut donc le communiquer aux autres processus !

Test parallèle de primalité : implémentation

(explications sur les sources de “High Performance Python”)

Il nous faut définir :

1. un flag permettant de noter si un diviseur a été trouvé ;
2. un manager pour partager cette variable entre les différents processus ;
3. un intervalle de vérification (vérifier si l'un des processus a trouvé un diviseur toutes les x secondes) ;

Test parallèle de primalité : implémentation

La fonction de vérification devient :

```
16  def check_prime_in_range(n_from_i_to_i):
17      (n, (from_i, to_i), value) = n_from_i_to_i
18      if n % 2 == 0:
19          return False
20      assert from_i % 2 != 0
21      check_every = CHECK_EVERY
22      # tester tous les diviseurs impairs dans l'intervalle donné
23      for i in range(from_i, int(to_i), 2):
24          # tous les CHECK_EVERY diviseurs, vérifier si l'un des
25          # processus a trouvé un diviseur
26          check_every -= 1
27          if not check_every:
28              if value.value == FLAG_SET:  # oui -> on arrête tout
29                  return False
30              check_every = CHECK_EVERY
31
32          # si NOUS avons trouvé un diviseur, le signaler
33          if n % i == 0:
34              value.value = FLAG_SET
35              return False
36      return True
```

Test parallèle de primalité : implémentation

Une autre fonction (`check_prime`) s'occupe du découpage de l'intervalle de recherche et de la répartition :

```
48      from_i = to_i
49      to_i = int(math.sqrt(n)) + 1
50
51      ranges_to_check = create_range.create(from_i, to_i, nbr_processes)
52      ranges_to_check = list(zip(len(ranges_to_check) * [n], ranges_to_check,
        ↪  len(ranges_to_check) * [value]))
53      assert len(ranges_to_check) == nbr_processes
54      results = pool.map(check_prime_in_range, ranges_to_check)
55      if False in results:
56          return False
57      return True
```

. . . que le code principal appelle après avoir initialisé le reste :

```
62      NBR_PROCESSES = 4 # int(sys.argv[1])
63      CHECK_EVERY = int(sys.argv[1])
64      manager = multiprocessing.Manager()
65      value = manager.Value(b'c', FLAG_CLEAR)  # 1 byte character
66      pool = Pool(processes=NBR_PROCESSES)
```

Performances selon le nombre de processus

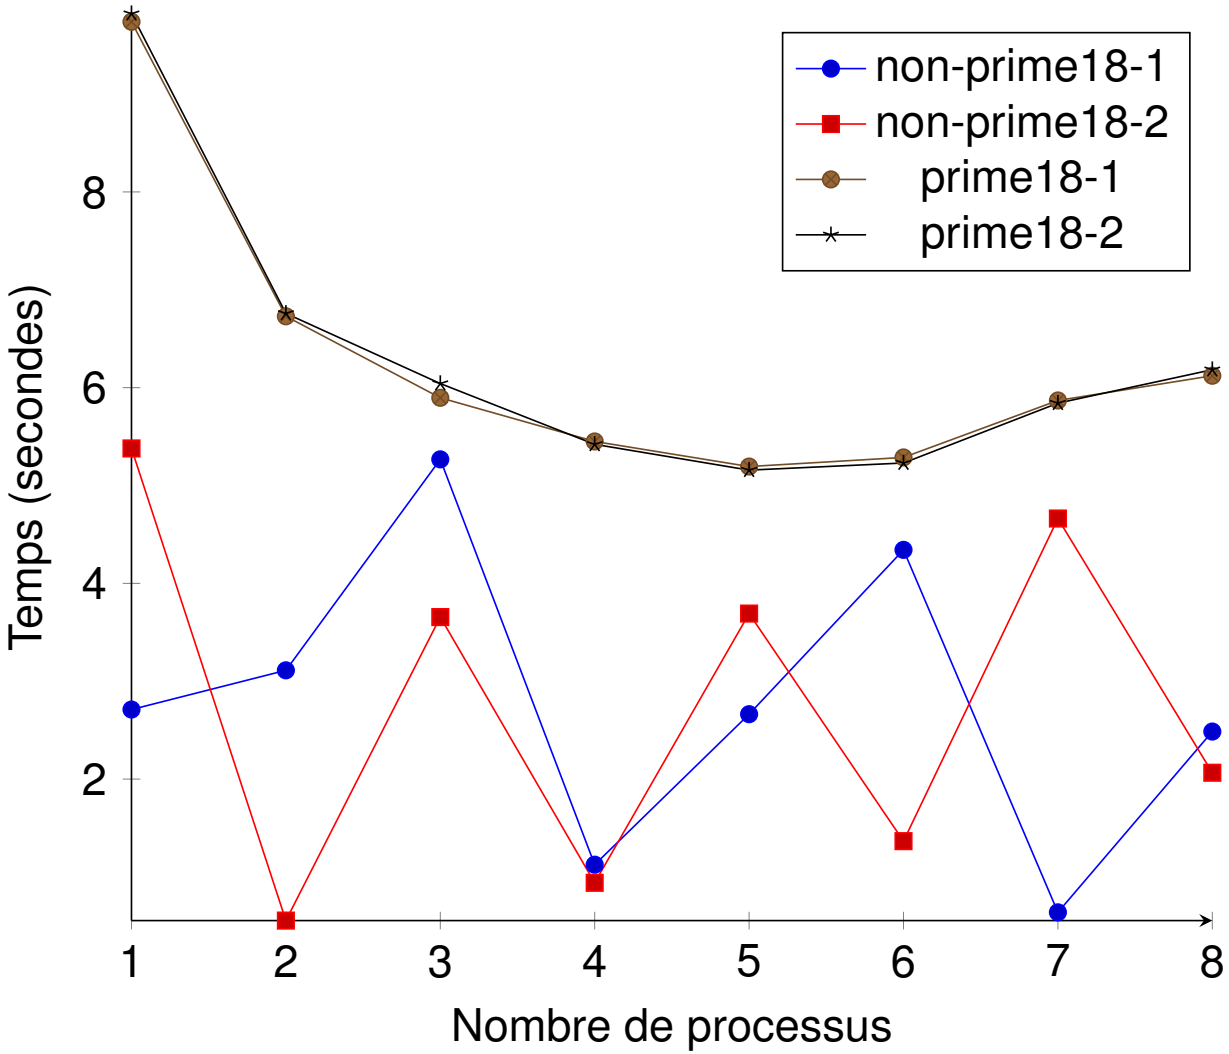

Performances selon le rafraîchissement (4 CPUs)

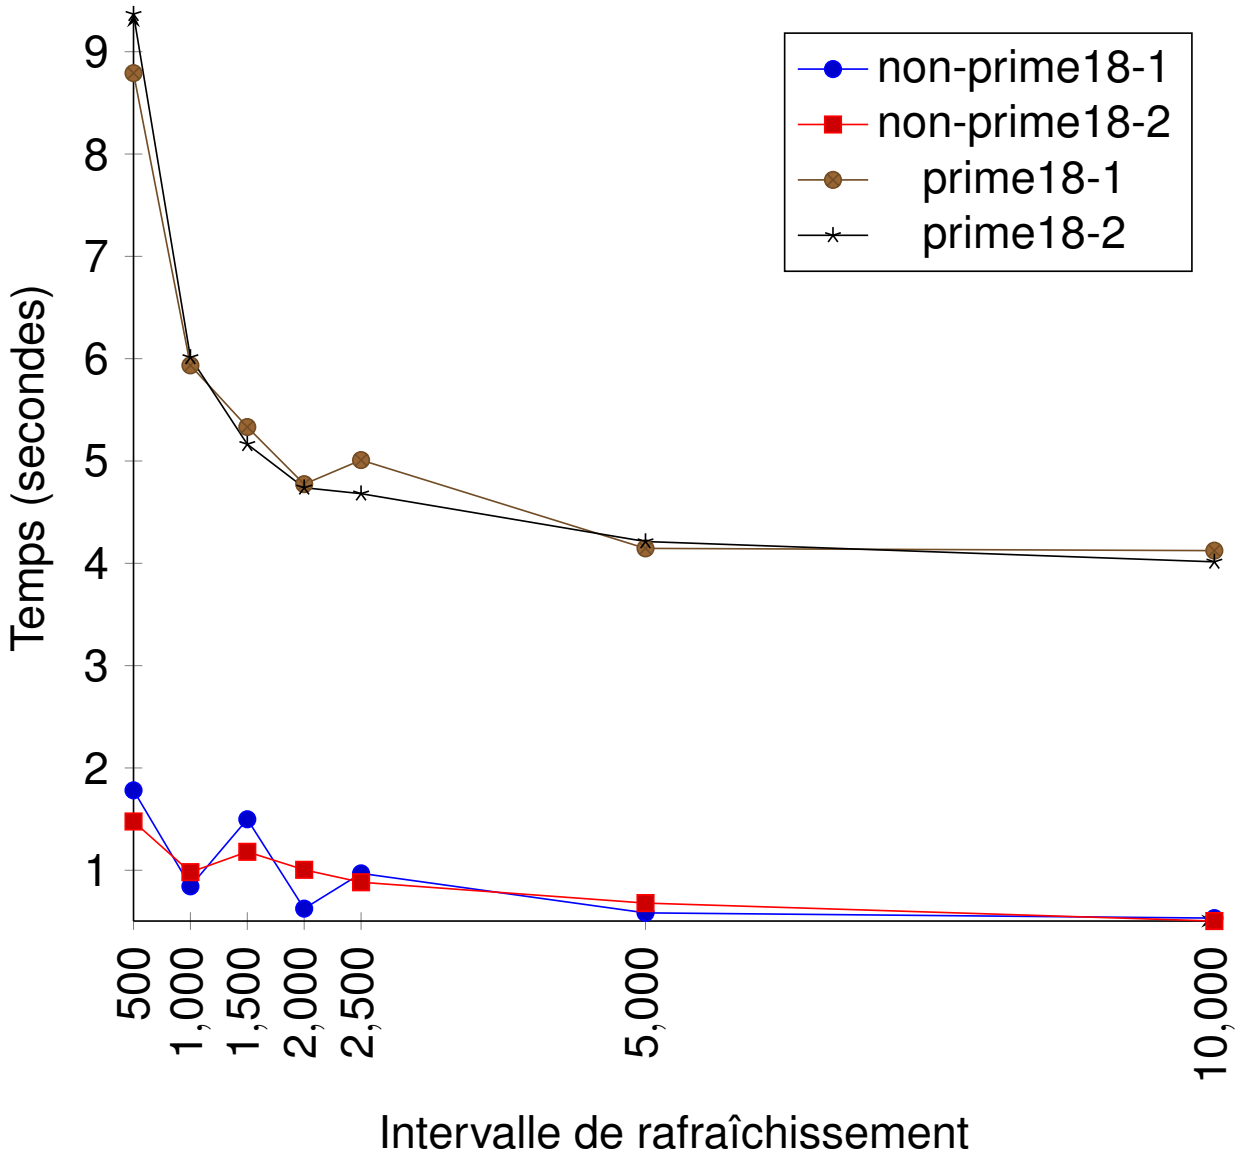

viztracer

`cProfile` ne donne que les statistiques liées au processus “père” !

Si l’on veut prendre en compte tous les processus lancés, il faut utiliser `viztracer` comme suit :

```
$ python3 -m viztracer --log_multiprocess programme.py
```