

# Rust et Python

Pourquoi et comment mettre du Rust dans votre code Python

Georges Racinet

Octobus, <https://octobus.net>

Wébinaire pour les dix ans d'Anybox – 4 Novembre 2020



- Cofondateur d'Anybox ! (octobre 2010)
- Développeur chez Octobus <https://octobus.net>
- Contributeur cœur Mercurial, DVCS évolué en Python
- Committeur cœur rust-cpython
- Mainteneur Heptapod (GitLab + Mercurial)  
<https://heptapod.net>





- développement Mercurial (cœur ou extensions)
- Heptapod
- développement et accompagnement Rust (plusieurs experts)



Une souplesse incroyable :

- Langage interprété
- Typage dynamique, tout est objet ou presque
- Gestion complète de la mémoire
- Librairie standard riche : « les piles sont fournies ».

... à un prix (relatif):

- lenteur générale
- consommation mémoire
- *Global interpreter lock* (GIL), empêche vrai parallélisme à haut niveau



- Traitements répétitifs: essayer PyPy et son JIT (compilateur à la volée)
- Réécrire tout en langage compilé (C, Rust...)
- Extensions CPython : réécrire les parties critiques seulement



- Traitements répétitifs: essayer PyPy et son JIT (compilateur à la volée)
- Réécrire tout en langage compilé (C, Rust...)
- Extensions CPython : réécrire les parties critiques seulement

Utiliser Python d'abord pour prototyper rapidement puis comme assemblage a toujours été un cas d'utilisation majeur du langage



# Question fondamentale pour un projet concret

Est-ce vraiment Python le problème ?

Python est lent, mais pas tant que ça.

- Quelle est vraiment la proportion de temps passé dans le code Python ?
- Avez-vous éliminé les traitements inutiles, externalisé ce qui devrait l'être ?
- Utilisez un profiler
- Si base de données riche (SQL), gros gains par amélioration requêtes.
- Un signe : si vous en êtes à tricher avec le langage



- CPython: implémentation de référence et la plus courante du *langage* Python, écrite en C.
- Autres implémentations:
  - PyPy (Python + JIT)
  - Jython (JVM, pas de GIL)
  - GraalPython (GraalVM)
  - RustPython (en Rust !).

Une *extension* Python est un module précompilé en langage machine, utilisant directement l'API interne de CPython.

L'intérêt tourne autour de la performance:

- Vitesse d'exécution
- Sobriété en termes de mémoire
- Vrai parallélisme: relâcher le GIL





Une bonne partie de la librairie standard:

- datetime, decimal
- sqlite3
- zlib, hashlib

Quelques classiques:

- numpy, scipy
- yaml
- psycopg

Tout ce qui est bien spécifié et a besoin d'être rapide.



# Rust, langage de choix pour écrire des extensions

Traditionnellement, les extensions sont écrites en C mais c'est pénible et dangereux (sécurité).

Arguments en faveur de Rust:

- langage compilé, fortement optimisé
- Sûreté mémoire (fuites, sécurité)
- \*Pas\* de *Garbage collector* ni de comptage de références par défaut
- Emphase sur le parallélisme
- ABI compatible avec C
- Librairie standard riche : les piles sont aussi livrées avec !



- Toute donnée a un propriétaire unique, identifié à la compilation
- Une donnée peut-être « prêtée » sous forme de références partagées (&truc) ou mutables (&mut truc)
- Impossible d'avoir une référence mutable en même temps qu'une autre référence

Intérêts :

- Sûreté / sécurité
- Absence de fuites mémoire
- Ce qu'il faut pour parallélisme sain avec sérénité
- Garantie à la compilation: optimisation agressive et meilleur passage à l'échelle des grands projets que C



# Exemple Mercurial: itération sur les ancêtres

```
import heapq

def iter_ancestors(parentfn, initrevs):
    seen = {nullrev}
    seen.update(initrevs)
    visit = [-r for r in initrevs]
    heapq.heapify(visit)
    while visit:
        current = -visit[0]
        yield current
        p1, p2 = parentfn(current)
        if p1 not in seen:
            heapq.heapreplace(visit, -p1)
            seen.add(p1)
        else:
            heapq.heappop(visit)
        heapq.heappush(visit, -p2)
        seen.add(p2)
```



On était déjà au max. En vrai, le code commençait ainsi:

```
def iter_ancestors(parentfn, initrevs):  
    seen = {nullrev}  
    see = seen.update  
    heappush = heapq.heappush  
    ...
```

Le simple fait de placer `seen.update` et `heapq.heappush` en variables locales apporte un vrai gain dans le cas de Mercurial. À ce stade **on se bat contre le langage** .



# Traduction en Rust

## Type et constructeur

```
pub struct AncestorsIterator<G: Graph> {
    graph: G,
    visit: BinaryHeap<Revision>,
    seen: HashSet<Revision>,
}

impl AncestorsIterator<G: Graph> {
    pub fn new(
        graph: G,
        initrevs: impl IntoIterator<Item = Revision>
    ) -> Self {
        let visit: BinaryHeap<Revision> = initrevs.collect();
        let seen = visit.iter().cloned().collect();
        seen.insert(NULL_REVISION);
        AncestorsIterator {visit: visit, seen: seen};
    }
}
```



# Traduction en Rust

## Itération

```
impl<G: Graph> Iterator for AncestorsIterator<G> {
    type Item = Result<Revision, GraphError>;

    fn next(&mut self) -> Option<Self::Item> {
        let current = match self.visit.peek() {
            None => { return None; }
            Some(c) => *c,
        };
        let [p1, p2] = self.graph.parents(current)
            .map_err(|e| Some(e))?;
        if self.seen.insert(p1) {
            *(self.visit.peek_mut().unwrap()) = p1;
        } else {
            self.visit.pop();
        }
        if self.seen.insert(p2) {
            self.visit.push(p2);
        }
        Some(Ok(current))
    }
}
```



# Réimplémentation Rust pur: conclusion

Bas-niveau dans le résultat, haut-niveau dans l'expressivité

- abstractions à coût d'exécution nul :
  - généricité (paramètres de types comme `<G>`)
  - interfaces standard: les *traits* comme `Iterator`
- librairie standard riche :
  - `set` → `HashSet`
  - `heapq` → `BinaryHeap`
- code écrit chez Anybox (octobre 2018) ;-)

Maintenant, comment brancher tout ceci à Python ?





# Options FFI pour les extensions Rust

On a le choix !

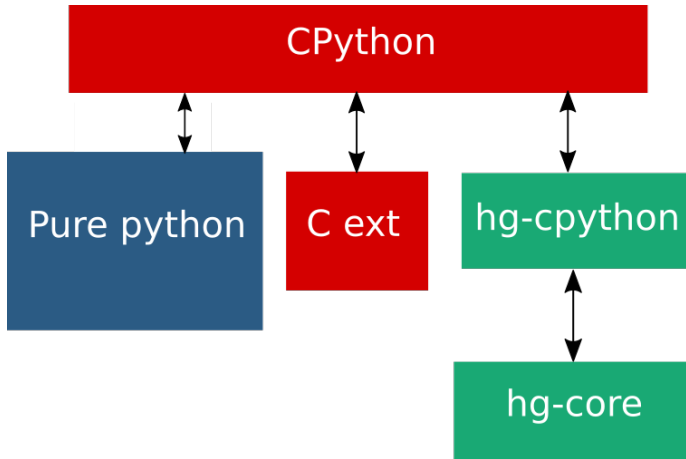
- écrire une extension C qui fait le pont
- rust-cpython
- PyO3 : *fork* de rust-cpython, a beaucoup évolué depuis
- cffi
- HPy (expérimental) : le futur !

Dans tout les cas, séparer en deux couches:

- librairie (*crate*) en Rust pure
- partie (autre *crate*) assurant l'interopérabilité.



# Options FFI : tableau complet pour Mercurial



Les échanges directs entre Rust et C sont également souhaitables et possibles, mais ne seront pas abordés ici (PyCapsule)



- expose les object CPython en structures Rust
- traduction automatique des types de base (int, set)
- des macros pour définir directement classes et modules Python
- acquisition du GIL garantie statiquement à la compilation avec un pseudo-object marqueur grâce aux règles du langage (!)

Exemple:

```
use cpython::{Python, PyResult, PyDict, py_class};

py_class!(class MyType |py| {
    data number: i32;
    def __new__(_cls, arg: i32) -> PyResult<MyType> {
        MyType::create_instance(py, arg)
    }
    def half(&self) -> PyResult<i32> {
        Ok(self.number(py) / 2)
    }
});
```



Comment gérer les grands transferts de données entre les parties Rust et Python de l'application ?

Le risque est de reperdre à l'interface tout ce que l'on a gagné en écrivant du Rust: que tout le temps soit passé à créer des objets Python.





- Exemple : `set`  $\leftrightarrow$  `HashSet`
- C'est en fait une copie
- Facile à implémenter et à manipuler
- Peut s'avérer très inefficace.  
Imaginer un traitement dont le résultat est d'ajouter un élément à un ensemble de taille un million. . .
- Règle grossière: acceptable comme étape intermédiaire et pour les petites données.



Exemple:

« Quel est l'âge du capitaine ?

– (lourd traitement) 42 ! »

- la solution ultime
- peut être contradictoire avec le problème à résoudre.
- suppose d'avoir traduit suffisamment de processus complexes, on a souvent besoin d'étapes intermédiaires raisonnables.



# Flux de données: encapsulation



- Nul besoin de convertir/copier d'énormes objets
- Réacquérir le GIL à chaque utilisation (lent) ou le garder (tue le parallélisme)
- Nécessite de définir des abstractions compliquées pour ne pas polluer tout le code avec du spécifique Python (GIL encore)





Les objets complexes traversant l'interface sont entièrement implémentés en Rust. Exemple : on fournit à Python une classe `RustSet` suffisamment compatible avec `set`

- La partie Python n'utiliserait (quasi) plus que des `RustSet`.
- Le GIL ne sert plus que pour l'objet entier, à l'interface.
- Effort supplémentaire, rebutant si peu de valeur ajoutée
- Problème: les règles de Rust interdisent d'utiliser le même objet deux fois...





# Références partagées entre Rust et Python

- problème: si on a une référence permettant la mutation d'un objet Rust, toute autre référence est interdite.
- exemple : si l'on implémente un `RustSet` visible depuis Python, impossible de donner à Python des itérateurs dessus.
- solution: `rust-cpython` fournit la notion de `shared_data`.
- historique:
  - premier prototype G. Racinet (juin 2019)
  - améliorations R. Gomès (été 2019)
  - cas général avec compteur générationnel et empoisonnement de références M. Thomas, Y. Nishihara (octobre 2019).

Un avantage substantiel de `rust-cpython` sur les autres solutions



# HPy, une API plus abstraite pour les extensions

Un projet ambitieux auquel contribuer

- Permettre aux extensions de ne plus manipuler directement des pointeurs `*PyObject` mais des « *handles* » abstraits.
- Poussé par développeurs cœur CPython et par communauté PyPy
- Exemple : PyPy et son JIT plus extensions natives (déjà possible mais très compliqué)
- Le rêve : PyPy + extensions en Rust (essais préliminaires par G. Racinet au sprint PyPy 2020)



- Extensions CPython:  
<https://docs.python.org/3/extending/index.html>
- rust-cpython: <https://crates.io/crates/cpython>
- Mercurial: <https://www.mercurial-scm.org>
- PyPy: <https://pypy.org>
- HPy: <https://github.com/hpyproject/hpy>
- Sprint PyPy (HPy) 2020 <https://morepypy.blogspot.com/2020/03/leysin-2020-sprint-report.html>
- Références partagées entre Rust et CPython:  
<https://octopus.net/blog/2019-07-25-rust-cpython-shared-ref.html>
- Présentations Rust et Python par R. Gomès (Octopus) à FOSDEM 2020: [https://archive.fosdem.org/2020/schedule/speaker/raphael\\_gomes/](https://archive.fosdem.org/2020/schedule/speaker/raphael_gomes/)



À vous pour les questions

