Cours Logiciels Libres

Écosystèmes de logiciels libres

Théo Zimmermann

Université Paris-Cité & Inria

Vendredi 25 mars 2022

Écosystèmes logiciels

Une collection de projets logiciels qui sont développés et évoluent conjointement dans le même environment.

(thèse de Mircea Lungu, 2009)

- Le terme provient de l'écologie, en passant par les sciences économiques et de gestion et le monde de l'entreprise.
- Les **écosystèmes de logiciels libres** existent depuis presque aussi longtemps que le logiciel libre :
  - Le système TeX ou des langages de programmation comme Perl ont accumulé de nombreuses **extensions/bibliothèques libres** dès les années 80.
  - À partir des années 90, l'arrivée des premières "archives complètes" puis des gestionnaires de paquets simplifie et accélère le partage.

Définitions

- **Paquet** : un composant logiciel qui est “empaqueté” de manière à rendre son installation facile.
- **Gestionnaire de paquets** : un logiciel qui sert à installer et supprimer des composants logiciels de façon cohérente.
  - Une innovation cruciale des gestionnaires de paquets “modernes” est la **gestion automatique des dépendances**.
  - *Exemples* : pip (Python), Maven (Java), opam (OCaml), mais aussi APT (Debian / Ubuntu), RPM (RedHat / Fedora).
- **Registre de paquets** (ou **archive** ou **dépôt** de paquets) : un serveur qui centralise les paquets pour faciliter leur distribution.
  - *Exemples* : PyPI (Python), MavenCentral (Java), opam-repository (OCaml), opam-coq-archive (Coq).
- **Index de paquets** : interface (web) par-dessus un registre de paquets permettant de rechercher les paquets disponibles.

Histoire des gestionnaires de paquets

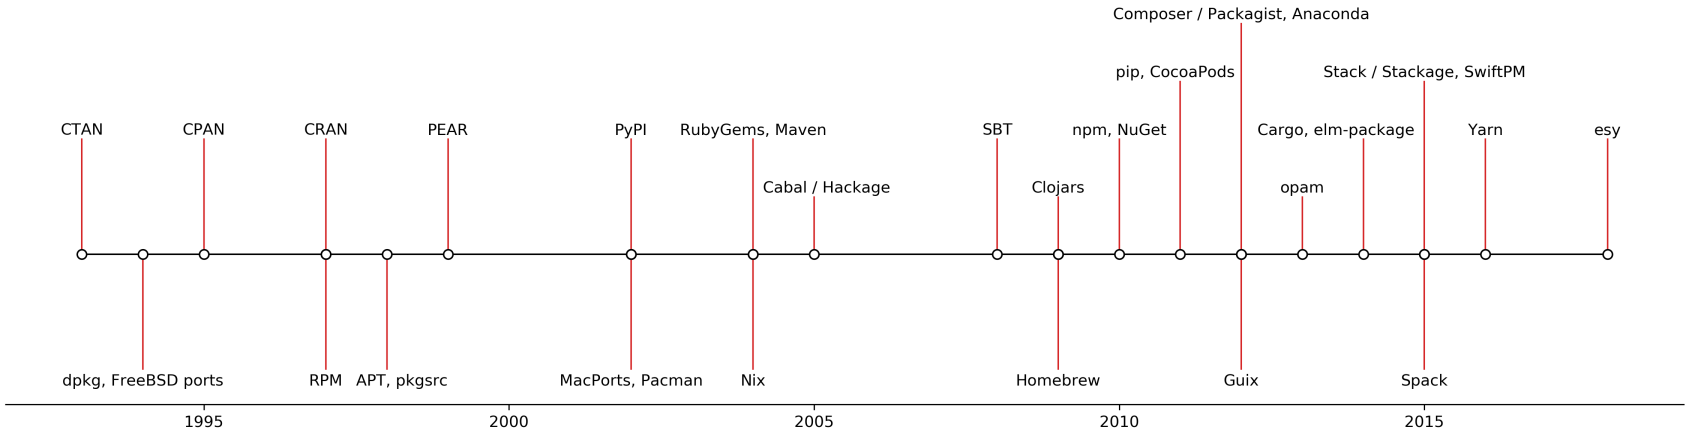

Figure 1: En haut, les gestionnaires de paquets spécifiques à une application, en bas ceux qui permettent de gérer un système d'exploitation

Distributions Linux

- Les distributions Linux mettent à la disposition de leurs utilisateurs une **collection de logiciels** à travers un gestionnaire de paquets.
- Les mainteneurs de distributions créent des paquets pour les logiciels populaires.
- Ces mainteneurs de paquets sont **indépendants** des mainteneurs des logiciels.

Écosystèmes de paquets

- En général, on parle d'écosystème de paquets pour désigner les paquets disponibles à travers un gestionnaire et un registre de paquets qui sont **spécifique à une application** (typiquement à un langage de programmation).
- Les paquets sont en général créés par les mainteneurs des logiciels.
- La plupart des paquets dépendent eux-mêmes d'autres paquets (disponibles dans le même écosystème). Par conséquent, il y a un **besoin de coordination** au niveau de l'écosystème.

Coordination au niveau des écosystèmes

Les mécanismes de base (dans tous les écosystèmes) :

- Communication **descendante** (des mainteneurs de paquets vers ceux qui en dépendent) :
  - Notes de version.
  - Numéro de version (*semver*).
- Communication **ascendante** :
  - Rapports de bug.

Exemples d'écosystèmes de paquets

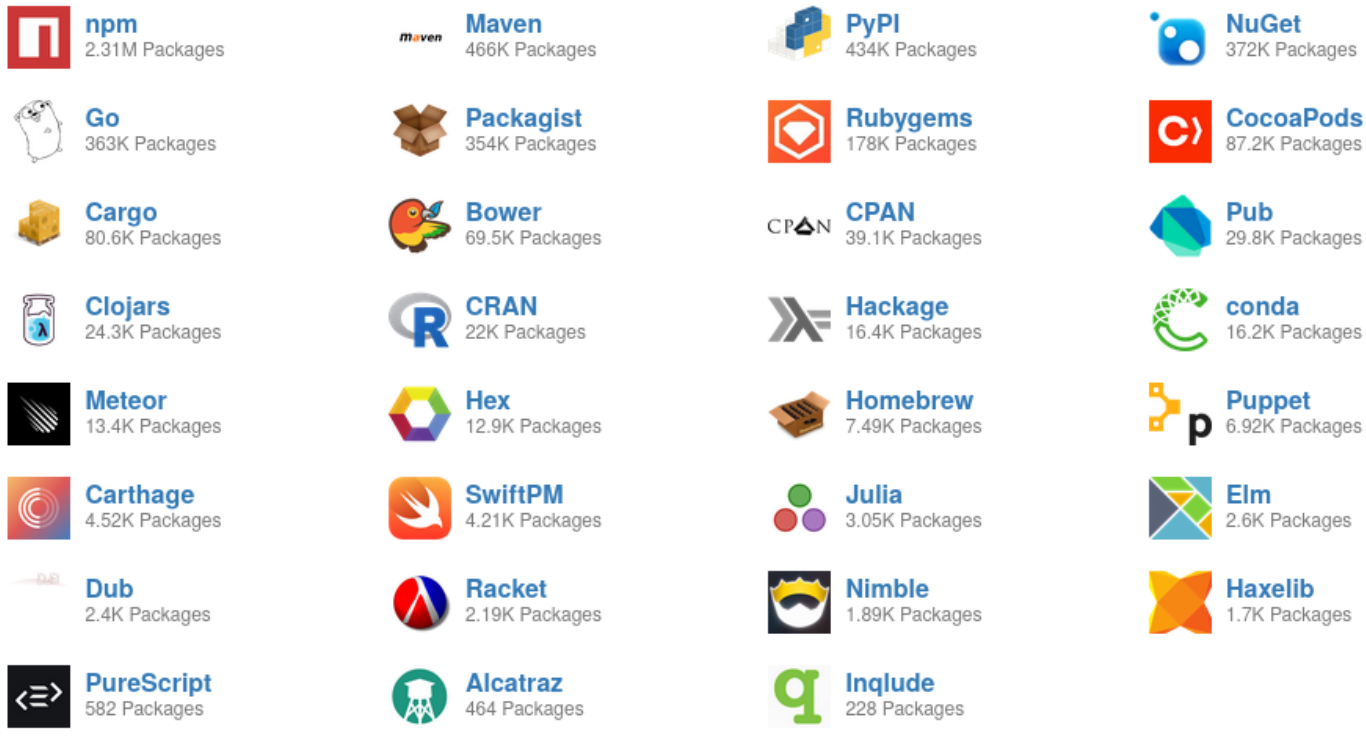

Figure 2: Les registres de paquets indexés par https://libraries.io

Les écosystèmes populaires peuvent atteindre plusieurs **centaines de milliers de paquets**. En comparaison, les distributions Linux en comportent quelques milliers à quelques dizaines de milliers.

Spécifier les dépendances

Exemple `package.json` (npm) :

```
{
  "name": "mon_paquet",
  "version": "1.0.2",
  "description": "Voilà ce que fait mon paquet.",
  "main": "index.js",
  "license": "MIT",
  "dependencies": {
    "super-bibliotheque": "^1.0.2",
    "autre-bibliotheque": "~2.1.0",
    "encore-une-autre": "0.8"
  }
}
```

Spécifier les dépendances

Exemple `projet.opam` (opam) :

```
opam-version: "2.0"
synopsis: "Description courte"
description: "Description longue"
maintainer: "moi@mondomaine.me"
authors: ["Moi"]
homepage: "https://github.com/Moi/MonProjet"
depends: [
  "ocaml"
  "dune"   { >= "2.5"  }
  "ppxlib" { >= "0.22.0" }
  "base"   { >= "v0.14.1" & < "v0.15.0" }
]
...
```

Dépendances : risques et bénéfices

- Réutiliser des bibliothèques existantes permet d'être **plus productif**. C'est pourquoi la plupart des projets logiciels en utilisent (ne dépendent pas seulement de la bibliothèque standard).
- Mais ajouter des dépendances comporte aussi des risques :
  - Licences des bibliothèques : doivent être comprises et respectées.
  - Le paquet sera-t-il **mis à jour** pour régler les bugs / les vulnérabilités / s'adapter à l'évolution de l'environnement ?
  - Des vulnérabilités pourraient-elles être introduites par accident / volontairement dans de **futures versions** ?
- Il est essentiel de savoir **de quoi** et **de qui** on dépend.

Dépendances transitives : un risque caché

- Les dépendances ont elles-mêmes des dépendances : ce sont les **dépendances transitives**.
- Il faut aussi en respecter la licence.
- Elles peuvent aussi créer des problèmes si elles sont mal maintenues (vulnérabilités, incompatibilités avec l'évolution d'autres bibliothèques, etc.).

Exemples de situations réelles

How one developer just broke Node, Babel and thousands of projects in 11 lines of JavaScript

Code pulled from NPM – which everyone was using

Chris Williams, Editor in Chief — Wed 23 Mar 2016 // 01:24 UTC

A post-mortem of the malicious event-stream backdoor

Danny Grander, Liran Tal
December 6, 2018

Ruby off the Rails: Code library yanked over license blunder, sparks chaos for half a million projects

Devs scramble for replacement mimetype data package

Thomas Claburn in San Francisco — Thu 25 Mar 2021 // 08:24 UTC

“Dependency hell”

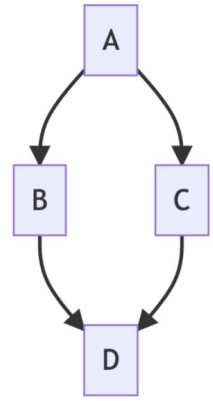

- Le projet A dépend des bibliothèques B v1 et C v1.
- B v1 et C v1 dépendent toutes les deux de la bibliothèque D v1.
- D est mise à jour (v2).
- B est mise à jour (v2) pour dépendre de D v2.
- C n’est pas mise à jour.
- Le projet A **ne peut pas mettre à jour** B tant que C n’est pas mise à jour pour être compatible avec D v2.

Tester la compatibilité avec les dépendances inverses

Le projet A dépend de la bibliothèque B :

- B est une dépendance de A
- A est une **dépendance inverse** de B.

Les mainteneurs de bibliothèques très utilisées peuvent choisir :

- d'**éviter** tout changement cassant la compatibilité ;
- d'**évaluer** les changements cassant la compatibilité **par le test** avec des dépendances inverses ;
- de **réparer** (certains) paquets cassés par les changements.

Mécanismes sociaux de coordination

Certains écosystèmes cherchent à éviter le “dependency hell” en favorisant la coordination et la mise à jour des paquets pour être compatibles avec les **dernières versions** de leurs dépendances.

Exemples :

- Stackage (Haskell),
- CRAN (R),
- Plateforme Coq.

Plateforme Coq

- Une “distribution” de Coq et de **paquets standards**.
- La version de chaque paquet est fixée. Des tests vérifient que tous les paquets inclus sont **compatibles** entre eux.
- À chaque nouveau cycle de préparation de la Plateforme, les mainteneurs des paquets sont **informés** pour qu'ils / elles indiquent quelle version doit être incluse.
- Éventuellement, les mainteneurs produisent une **nouvelle version** (par exemple si la dernière n'était pas compatible avec des mises à jour dans des dépendances).
- Les utilisateurs savent que les versions distribuées dans la Plateforme sont une bonne base sur laquelle s'appuyer.

Solutions aux problèmes de maintenance

Lorsqu'un logiciel open source utilisé par de nombreuses entreprises ou pour des applications critiques est "mal maintenu" (manque de ressources), les utilisateurs (entreprises) peuvent contribuer à **fournir des ressources** :

- **financières** (dons à une fondation responsable du logiciel),
- **humaines** (développeurs pour participer à la maintenance).

La deuxième solution est plus efficace que la première car tant que les ressources financières n'atteignent pas de quoi **payer un salaire**, cela ne permettra pas d'ajouter plus de monde pour la maintenance du projet.

Solutions aux problèmes d'abandon

- Un **projet open source abandonné** peut toujours être forké par ses utilisateurs pour **poursuivre sa maintenance**.
- Si le projet est suffisamment important et attire assez de volontaires, ça peut lui donner une **nouvelle jeunesse** (exemple : le serveur Apache).
- Mais si le projet abandonné par son auteur initial est forké par une seule personne, comment s'assurer qu'il ne sera pas **abandonné à nouveau** ?

Organisations communautaires de maintenance de paquets

- En rassemblant les forks de projets abandonnés dans une organisation communautaire, il est possible de plus facilement assurer leur avenir, car **le mainteneur peut plus facilement être remplacé**.
- Ce type d'organisations a d'autres avantages :
  - Les auteurs de projets qui ne sont plus disponibles pour les maintenir peuvent les **léguer** à l'organisation.
  - Des membres de la communauté peuvent plus facilement aider un grand nombre de projets sur des **tâches de routine** et l'application de **bonnes pratiques**.