Logiciels et codes sources, tour d'horizon

Violaine Louvet

18 février 2025

Contexte et objectifs

Contexte

- Les codes sont un des piliers de la recherche scientifique dans toutes les disciplines
- La dynamique de la science ouverte renforce la nécessité d'ouvrir les codes, ce qui est déjà le cas de la majorité des développements

Objectifs

- Comprendre le cadre de développement des codes de recherche
- Identifier les points clés essentiels pour se faciliter la vie mais aussi celle des autres utilisateurs et développeurs
- Savoir valoriser son développement

Tour de table

Merci de vous présenter en quelques phrases :

Laboratoire, sujet de thèse

Attendus pour ce cours

Plan

Plan

Plan

Code source, logiciel, algorithme, de quoi parle-t-on ?

- Algorithme : décrit le déroulé pour la résolution d'un problème posé.
- Code source : mise en oeuvre et formalisation de l'algorithme dans un langage informatique (par exemple python, C++, java ...). C'est un (ou plusieurs) fichier(s) texte.
- Exécutable : traduction du code source (en général via un compilateur ou un interpréteur) en code binaire compréhensible par l'ordinateur.
- Logiciel : en général, l'ensemble global comprenant les fichiers sources et/ou l'exécutable, et le plus souvent la documentation, des exemples d'utilisation, éventuellement les dépendances ... et évidemment la licence associée.

De l'importance des fichiers sources

- Un logiciel fonctionne grâce à du code exécutable, compréhensible uniquement par des machines (binaire).
- L'« âme »d'un logiciel est dans son code source, c'est-à-dire dans les instructions telles qu'elles sont rédigées pour être lisibles par l'humain dans un langage informatique.
- Seul le code source permet d'accéder aux informations techniques et scientifiques qui sont réellement exécutées lors de l'utilisation du logiciel.

```
DEBUT
    SI Il pleut
    ALORS Annulation représentation
    SINON SI L'interprète est absent
            ALORS Annulation représentation
            SINON SI Un musicien primordial est absent
                    ALORS Annulation représentation
                    SINON Représentation maintenue
                    FIN SI
            FIN SI
    FIN SI
FIN
```

```c
#include <stdlib.h>
#include <stdio.h>
#include <stdbool.h>

struct stats { int count; int sum; int sum_squares; };

void stats_update(struct stats * s, int x, bool reset) {
    if (s == NULL) return;
    if (reset) * s = (struct stats) { 0, 0, 0 };
    s->count += 1;
    s->sum += x;
    s->sum_squares += x * x;
}

double mean(int data[], size_t len) {
    struct stats s;
    for (int i = 0; i < len; ++i)
        stats_update(&s, data[i], i == 0);
    return ((double)s.sum) / ((double)s.count);
}

void main() {
    int data[] = { 1, 2, 3, 4, 5, 6 };
    printf("MEAN = %lf\n", mean(data, sizeof(data) / sizeof(data[0])));
}
```

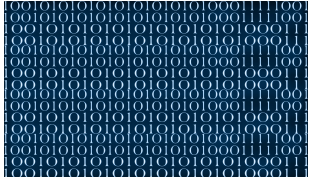

Code source, logiciel, algorithme : illustration par l'exemple

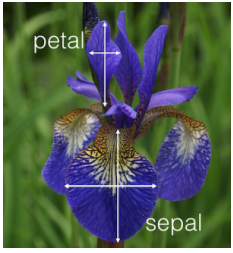

- Base de données de caractéristiques d'iris (tailles des sépales et des pétales)
- Entraînement d'un modèle d'apprentissage non supervisé par l'algorithme de clustering du kmeans

Code source, logiciel, algorithme : illustration par l'exemple

```
#!/usr/bin/env python
# coding: utf-8
# On charge les  bibliothèques dont on a besoin
import pandas as pd
import numpy as np
from sklearn import datasets
import matplotlib.pyplot as plt
from sklearn.cluster import KMeans

# On charge les données
# Réparti entre données d'entrainement
# et données de test
iris = datasets.load_iris()

# Stocker les données en tant que DataFrame Pandas
x = pd.DataFrame(iris.data)
# Définir les noms de colonnes
```

```
x.columns=['Sepal_Length','Sepal_width',
           'Petal_Length','Petal_width']
y = pd.DataFrame(iris.target)
print(y.columns == ['Targets'])

# Cluster K-means
model = KMeans(n_clusters=3)
# Adapter le modèle de données
model.fit(x)

# Afficher les différents clusters
colormap=np.array(['Red','green','blue'])
plt.scatter(x.Petal_Length, x.Petal_width,
            c=colormap[model.labels_],s=40)
plt.show()
```

Code source, logiciel, algorithme : illustration par l'exemple

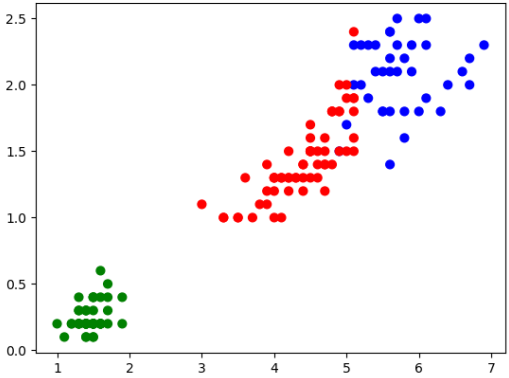

Demo

Plan

L'objet logiciel de la recherche

Définition du collège Codes sources et logiciels du Comité pour la science ouverte (COSO)

Les logiciels de recherche sont développés pour répondre à des besoins spécifiques de la science. Ils sont conçus, maintenus, et utilisés par des scientifiques (chercheurs et ingénieurs) et institutions de recherche, éventuellement dans une dimension internationale.
Ils peuvent découler de travaux de recherche comme ils peuvent les favoriser, notamment par des publications avant/sur/autour/avec le logiciel.
Ceux-ci peuvent se formaliser de différentes façons (une plateforme, un intergiciel, un workflow ou une bibliothèque, module ou greffon d'un autre logiciel) et être ainsi en interaction dans un écosystème ou au contraire plus autonomes.

Des types de logiciels très variés (1/2)

Les logiciels peuvent prendre de multiples formes dont il est difficile de faire une liste exhaustive :

- Logiciel autonome, logiciel applicatif, outil de simulation
  Exemple : SMilei, code de simulation pour la physique des plasmas chauds.
- Bibliothèque (Library)
  Exemple : KeOps, pour la manipulation de matrices de distances, de noyaux et autres opérateurs.
- Infrastructure (framework de développement, middleware, système exploitation)
  Exemple : OpenFLUID, plateforme logicielle dédiée à la modélisation spatialisée dans les paysages.

Des types de logiciels très variés (2/2)

- Plug-in ou module (sous-ensemble destiné à être intégré dans un framework, dans un environnement de développement)
  Exemple : MorphoLibJ, bibliothèque logicielle de morphologie mathématique pour le logiciel ImageJ.
- Outil de développement
  Exemple : OCaml, langage de programmation fonctionnelle, impérative et à objets
- Logiciel embarqué, enfoui
  Exemple : PlugDB, plateforme complète dédiée à la gestion sécurisée des données personnelles à travers un composant spécifique.

Pilier du processus de recherche

- Les logiciels de recherche peuvent être un outil, un résultat de recherche en lui-même, un objet de recherche.
- C'est un objet protéiforme, pouvant servir des objectifs très différents.
  - Son degré de sophistication technique, sa taille, son nombre de développeurs, ... n'augurent pas forcément de l'importance de son impact scientifique.
  - L'existence de publications scientifique ou de projet de recherche dans lesquels le logiciel joue un rôle est un critère d'identification fort.

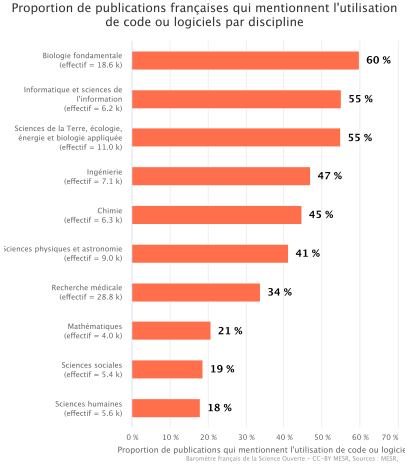

Plan

Cycle de vie d'un code de recherche

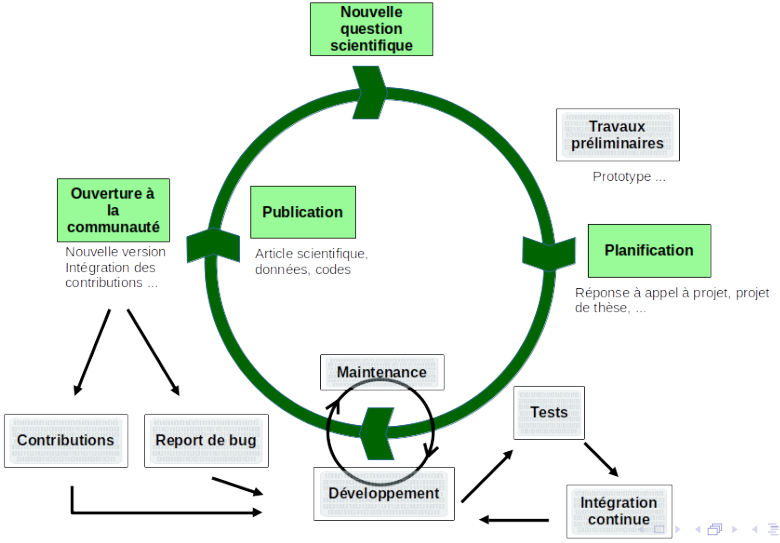

La vie d'un code de recherche

- Les questions scientifiques orientent le développement qui est complètement intégré au processus de recherche
- Les cycles et sous-cycles sont itératifs et imbriqués
- Selon le contexte, certaines étapes peuvent ne pas exister ou être juste esquissées (par exemple les tests et l'intégration continue)
- La temporalité est très variable : le cycle peut s'interrompre sur une durée plus ou moins longue (code dormant, voir mort) et reprendre si l'intérêt scientifique renaît

Différents contextes de développement

- Individuel : un chercheur / ingénieur (souvent un doctorant) développe seul un code adressant une question de recherche.
- Equipe de recherche : quelques chercheurs / ingénieurs, en général géographiquement (ou thématiquement) proche (même laboratoire) développent et partagent un code sur le sujet sur lequel ils travaillent.
- Communauté : organisation du développement d'un code à l'échelle de toute une communauté scientifique
- Partenariat avec une structure privée : développement dans le cadre d'une collaboration avec une entreprise.

→ Ces contextes illustrent une sorte de cycle de maturation du logiciel de recherche.

→ Beaucoup s'arrêtent dans la première phase

Maturité de développement

- Les différents contextes de développement impliquent souvent des niveaux de maturité très divers

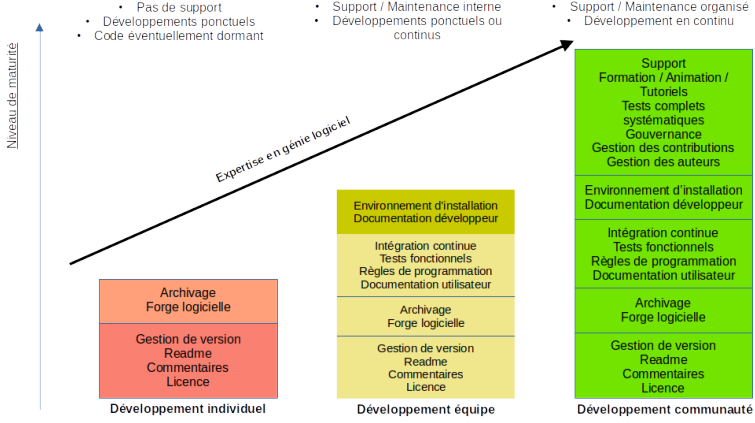

Différents contextes de développement : points clés

- Individuel
  - Sans doute la grande majorité de la production logicielle dans les laboratoires de recherche
  - Souvent réalisé dans le cadre d'une thèse
  - Une durée de vie pas toujours très longue

  → Assurer la réutilisabilité y compris pour l'auteur lui-même (bonnes pratiques)

  → Eviter de perdre le code, capitaliser sur ce type de développement

Différents contextes de développement : points clés

- Individuel
- Equipe de recherche
  - Souvent dans le cadre d'un projet de recherche partagé par toute une équipe, dans un laboratoire ou sur un thème scientifique bien défini, projet éventuellement financé et donc soumis à des contraintes d'ouverture
  - Développement en continu qui s'inscrit dans la durée avec plusieurs développeurs

  → Facilite l'appropriation et l'enrichissement par tous les membres y compris les nouveaux arrivés

  → Partage des outils sans plus value et souvent chronophage à développer (E/S, pré et post-traitement ...)

  → Nécessite de préciser un cadre (règles de programmation ...) et des outils de développement (forge ...)

Différents contextes de développement : points clés

- Individuel
- Equipe de recherche
- Communauté
  - Regroupement des forces d'une communauté pour développer un outil commun permettant à chacun de l'enrichir en fonction de ses besoins de recherche
  - Implique des personnes issues d'établissements différents et géographiquement éloignées y compris à l'international
  - Peut impliquer la mise en place d'un consortium définissant les accords de Propriété Intellectuelle et la question des licences
  - Suppose souvent un/des personnels permanents ou pas dédiés à la gestion du développement (besoin essentiel en génie logiciel)

  → Code très visible, et intéressant potentiellement beaucoup plus largement

  → Pérennisation des développements

  → S'assurer de la gouvernance du projet, gérer l'attribution des droits, les contributions ...

  → Intégrer la question du support (dont la formation), de la maintenance ...

Différents contextes de développement : points clés

- Individuel
- Equipe de recherche
- Communauté
- Partenariat avec une structure privée
  - Fait l'objet d'un contrat entre les établissements des chercheurs concernés et l'entreprise
  - Les conditions de Propriété Intellectuelle et de licence sont définies dans le contrat
  - Différents cas de figure peuvent se présenter : développement fermé, partiellement ou complètement ouvert

  → Une voie de transfert intéressante

  → Un moyen de financement pour consolider les développements d'une équipe de recherche

Plan

Plan

Au début était l'historique

Pourquoi a-t-on besoin de gérer l'historique ?

- *Ah, ce code marchait avant que je ne fasse des modifs !!*
- *Tu as modifié quelle version ? Ah mais non, c'était pas la dernière, je te l'ai envoyée par mail !*

- Besoin primaire de gérer l'historique des versions quand on développe (seul ou à plusieurs) !
- Les gestionnaires de version datent du début des années 70

Le cas de git

- Créé en 2005 pour le développement du noyau Linux par Linus Torvalds
  - $>$ 20 millions de lignes de code
  - $\sim$ 14 000 développeurs

Forges logicielles

- Au delà de la gestion de versions, une forge logicielle est un système complet en ligne de gestion, de partage et de maintenance collaborative de textes (et donc en particulier de codes sources)
- Intègre de nombreux outils :
  - système de gestion des versions (par exemple, via Git)
  - outil de suivi des bugs
  - gestionnaire de documentation
  - gestion des tâches
  - intégration continue ...

Une ressource essentielle

- Favorise les contributions et facilite leur intégration (pull request)
- Simplifie les interactions entre les développeurs (tickets) et les utilisateurs (forums)
- Facilite la gestion des tests automatiques (intégration continue)

Git et gitlab en deux slides

Git n'est pas gitlab

- Git est un logiciel de gestion de versions décentralisé (logiciel libre sous GPLv2)
- GitLab est un logiciel libre de forge basé sur git. A noter que gitlab est scindé en deux versions : l'une libre, l'autre propriétaire. Gitlab est une plateforme qui peut être déployée dans les établissements ou laboratoires.

- Le système de gestion de versions a comme objectif de pouvoir retracer des modifications physiques dans la mémoire de façon intelligente
- Ces changements sont stockés dans un dépôt (repository)
- Git fonctionne en créant deux dépôts des changements :
  - Le premier se trouve sur la même machine des fichiers de travail
  - Le deuxième se trouve dans une autre machine, souvent un serveur ou une plateforme cloud comme GitLab, qui s'occupe de centraliser les changements

Git et gitlab en deux slides

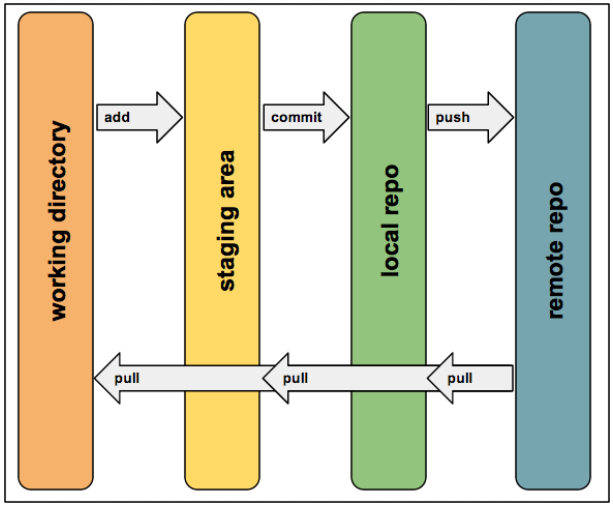

Forges $\neq$ archives

- Ne pas confondre les forges logicielles et les archives de codes
- Software Heritage n'est pas une forge logicielle, c'est une archive de codes sources
  - Pour la pérennisation des codes sources
  - mais pas pour leur développement collaboratif
  - Par contre SWH s'appuie sur les forges existantes
- A l'inverse, les forges logicielles n'assurent pas la pérennisation des codes sources

La forge est le coeur névralgique de tout développement

- Facilite la mise en oeuvre de bonnes pratiques de développement
- Absolument indispensable quand on développe à plus de un mais particulièrement utile aussi pour les développements individuels
- Simplifie aussi la diffusion du logiciel, son référencement, son archivage ...
  - En particulier, c'est le seul endroit où les informations sont constamment à jour

Forges disponibles

Rapport du collège logiciels et codes sources du COSO sur les forges

- Forges de l'ESR
  - De nombreux établissements, organismes voir laboratoires ont déployé leur propre forge (en général gitlab mais il en existe quelques autres)
  - Liste non exhaustive : CNRS, INRIA, Huma-Num, INRAE, UGA, U Bordeaux, ...
  - SourceSup est la forge nationale hébergée par Renater. Elle s'appuie sur FusionForge (et pas gitlab)
  - La plupart de ces forges ont un accès restreint à leur communauté / personnels avec un degré d'ouverture plus ou moins important
- Forges commerciales (github, gitlab.com ...)
  - Très utilisées dans le cadre de collaborations internationales ou pour assurer plus de visibilité
  - Pas de contraintes d'accès comparé à la plupart des forges ESR
  - Mais attention aux conditions d'utilisation ! Et à la pérennité de ces plateformes

La question du choix de la forge

- La plupart des logiciels libres de l'ESR à périmètre international et/ou sociétal utilisent une forge commerciale.
- Facilite tous les types de contributions par tout le monde.
- **MAIS**
  - Pas de garantie de pérennité.
  - Souvent soumises à des juridictions extra-européennes.
  - Utilisation des sources sans réel contrôle pour l'apprentissage des outils d'aide à l'écriture de code (OpenAI Codex/GitHub copilot, GitLab suggestions, etc.).
  - Flou juridique sur la question du respect des licences pour ces outils.
- Il y a un enjeu majeur de **souveraineté**.
- Le collège logiciels et codes sources du COSO travaille actuellement sur des préconisations pour répondre à ces enjeux.

Plan

Pourquoi s'intéresser à la qualité logicielle ?

L'objectif est d'assurer pour soi, pour ses collègues, pour sa communauté, pour tous de :

- comprendre ce que fait le logiciel et comment il le fait : les sources doivent être accessibles dans un environnement pérenne, le code doit être commenté ...
- installer le logiciel sans problème (avec une licence adaptée) dans différents contextes via l'utilisation d'outils adaptés (gestionnaire de paquets, outils de compilation, conteneur, ...)
- utiliser le logiciel, pouvoir identifier clairement les dépendances (de confiance et suffisamment pérennes), existence d'une documentation, d'exemples ...
- contribuer, faire évoluer les fonctionnalités grâce à la mise en place de règles de programmation claires, un code modulaire, un nommage explicite ... et une documentation développeur
- maintenir sur le long terme, intégrer des tests, pouvoir corriger les bugs sans dégrader le logiciel, pouvoir revenir dessus après plusieurs mois/années ...

Forte variabilité de l'exigence de qualité

La qualité logicielle est un sujet très vaste

- Une très large littérature sur les modèles, les indicateurs, les normes ...
- L'exigence est très dépendante du logiciel : sa cible, son utilisation, son périmètre ...
- Plus l'exigence est forte, plus les compétences en terme de génie logiciel doivent être présentes dans l'équipe de développement

Lien avec la reproductibilité

- Le respect de bonnes pratiques de développement est d'abord pour le propre bénéfice du développeur
- C'est aussi essentiel pour assurer la reproductibilité
- Et c'est un réel gain de temps, surtout quand, comme souvent en recherche, le développement n'est pas continu.

Les attendus de la qualité des logiciels

Liste non exhaustive et non priorisée !

- Performance / Utilisation de ressources
- Utilisabilité / facilité d'utilisation
- Maintenabilité
- Interopérabilité
- Compatibilité
- Installabilité
- Portabilité / adaptabilité
- Modifiabilité
- Supportabilité
- Testabilité

Tout n'est pas forcément pertinent pour les codes de recherche !!

D'autres éléments de qualité comme la sécurité, l'attractivité (esthétique de l'interface utilisateur), la tolérance aux fautes sont encore moins appropriées à la plupart des codes développés dans les labos.

Qualité minimale attendue

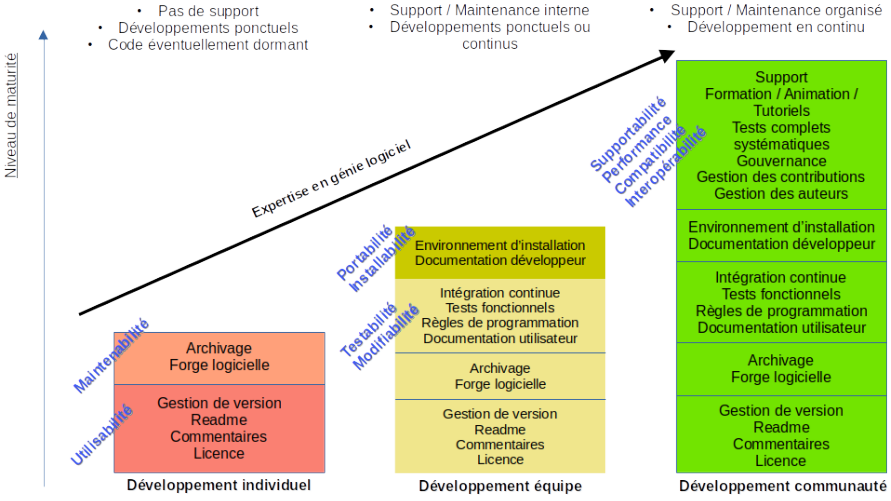

Plan

Importance des contributions aux logiciels libres

La science cumulative est un des enjeux majeurs de la science ouverte.
Comme pour les publications qui s'enrichissent mutuellement et continuellement de nouveaux résultats scientifiques, les logiciels libres se développent grâce aux contributions de leurs communautés.

- Il s'agit de faciliter les contributions :
  - Pour soi et pour les autres
  - Pour capitaliser sur le travail réalisé
  - Pour profiter de l'existant (ne pas réinventer la roue)

Rôle des communautés

Communauté d'un logiciel libre

L'ensemble des développeurs, des utilisateurs et des contributeurs forment la communauté du logiciel libre.
C'est l'essence même du logiciel libre.

- Différents types de contribution :
  - indiquer un bug,
  - suggérer une nouvelle fonctionnalité,
  - poser une question,
  - corriger un bug,
  - faire de la documentation,
  - ajouter une nouvelle fonctionnalité, ...

Anticiper, faciliter les contributions

- Mettre une licence (cf partie juridique)
- Rendre visible et attractif (cf partie diffusion)
  - En général, une recherche se fait par un moteur généraliste.
  - La première page sur laquelle on tombe est souvent le dépôt sur une forge.
  - Le fichier README doit donc être suffisamment informatif car c'est souvent la page par laquelle on accède au logiciel.
- Bien documenter l'installation, faire en sorte qu'elle soit simple, sinon on ne va pas plus loin.
- Bien soigner la documentation : du quick start aux tutoriels, examples, comment contribuer ...
- Il existe beaucoup d'outils et de bonnes pratiques qui vont aider pour cela.

Plan

De quoi s'agit-il ?

- Les systèmes d'IA générative sont des outils capables de créer des contenus (du texte, des images, des graphiques...) en réponse à une requête (prompt) émise par l'utilisateur
- Technologie qui évolue très très vite !
- C'est devenu un outil incontournable qui peut être une aide très efficace pour le développement si utilisé à bon escient

Principes fondamentaux

- Contrôle humain et responsabilité : on est responsable des contenus générés. Toute utilisation de ces outils exige le contrôle du résultat final
- Transparence : depuis 2023, le code de la recherche exige la transparence : cacher l'utilisation d'IA dans la création de contenu y est désormais considéré comme un manquement à l'intégrité scientifique.

Les cas d'usages

- Génération de code :
  - Génère automatiquement du code à partir de descriptions en langage naturel.
  - Exemple : "Écrire une fonction Python pour trier une liste de nombres."
- Complétion de code :
  - Suggère les lignes de code suivantes au fur et à mesure que vous tapez.
  - Exemple : Complétion automatique d'une boucle ou d'une instruction conditionnelle.
- Débogage :
  - Identifie et suggère des corrections pour les erreurs de codage courantes.
  - Exemple : Détection d'erreurs de syntaxe ou de failles logiques.
- Génération de tests :
  - Crée automatiquement des cas de test pour vérifier la validité du code.
  - Exemple : Génération de tests unitaires pour une fonction spécifique.
- Génération de documentation :
  - Produit des commentaires et de la documentation pour le code.
  - Exemple : Ajout de docstrings pour les fonctions et classes.

Intégration des LLM dans les flux de développement

- Plugins IDE :
  - De nombreux environnements de développement intégrés (IDE) prennent désormais en charge les plugins LLM.
  - Exemples : Visual Studio Code (avec l'extension GitHub Copilot), PyCharm (avec l'extension Tabnine).
- Contrôle de version :
  - Les LLM peuvent suggérer des révisions de code et des améliorations avant de valider les modifications.
  - Exemple : Intégration avec GitHub pour les révisions de pull requests
- Intégration continue :
  - Automatise les processus de test et de déploiement.
  - Exemple : Utilisation des LLM pour écrire et mettre à jour des cas de test dans des outils comme Jenkins ou GitHub Actions.

Utilisation de l'IA pour les revues de code

- Revue de code automatisée :
  - Les LLM peuvent analyser le code et fournir des commentaires sur la qualité et identifier les vulnérabilités de sécurité.
  - Exemple : DeepCode analyse le code pour identifier les bugs et suggérer des améliorations. Snyk utilise l'IA pour détecter les vulnérabilités dans les dépendances et le code
- Amélioration de la lisibilité :
  - Les LLM peuvent suggérer des refactorisations pour améliorer la lisibilité et la maintenabilité du code.
  - Exemple : CodeClimate utilise l'IA pour évaluer la qualité du code et suggérer des améliorations.
- Feedback en temps réel :
  - Les outils d'IA peuvent fournir des commentaires en temps réel pendant le processus de revue de code.
  - Exemple : GitHub Copilot peut suggérer des améliorations de code directement dans l'IDE.

Exemples d'outils utilisant des LLM

- GitHub Copilot :
  - Un outil développé par GitHub et Microsoft qui utilise des LLM pour suggérer des lignes de code et des fonctions entières.
  - Intégré dans Visual Studio Code et d'autres IDE.
- Tabnine :
  - Un plugin d'autocomplétion de code qui utilise des LLM pour fournir des suggestions de code contextuelles.
  - Disponible pour plusieurs IDE, y compris PyCharm et IntelliJ IDEA.
- Kite :
  - Un autre outil d'autocomplétion de code qui utilise des LLM pour fournir des suggestions de code en temps réel.
  - Supporte plusieurs langages de programmation et IDE.
- DeepCode :
  - Un outil d'analyse de code qui utilise des LLM pour identifier les bugs et suggérer des améliorations de code.
  - Intégré avec GitHub et d'autres plateformes de contrôle de version.

Points de vigilance

- Fiabilité : Les systèmes d'IA génératives font parfois des erreurs, et peuvent présenter des « hallucinations » (informations erronées / inventées de façon très péremptoire)
- L'utilisation de ces outils ne peut se substituer à l'expérience des personnes qui développent
- Propriété : Il est possible que le contenu généré soit issu de données d'entrainement protégées par un copyright
- Confidentialité : ces systèmes n'offrent pas une protection suffisante en matière de données personnelles. Ne pas partager ce type de données dans vos requêtes.
- Les établissements de recherche se dotent progressivement de lignes de conduite concernant l'utilisation de l'IAg pour la recherche.

En conclusion

Ne vous passez pas de cet outil mais utilisez le avec parcimonie en ayant en tête ces points de vigilance.

Plan

Consignes

- Par groupe de 4 ou 5, pendant 15 mn
- Discuter entre vous de vos pratiques de développement logiciel :
  - outils utilisés,
  - organisation du développement,
  - partage des développements,
  - ...
- Identifier 2 bonnes pratiques et 2 éléments à améliorer
- Un rapporteur par groupe pour faire la restitution.

Plan

Droits d'auteur appliqués au logiciel

Le logiciel est protégé par le droit d'auteur avec des règles spécifiques :

- Droits moraux attachés à l'auteur
- Droits patrimoniaux, qui régissent les modalités d'exploitation, sont propriétés de ou des institutions qui emploient le ou les auteurs
- Contrairement aux autres droits d'auteurs, il y a une « dévolution automatique des droits patrimoniaux à l'employeur »
- Depuis le 15 décembre 2021, c'est vrai aussi pour les stagiaires
- L'algorithme, considéré comme une suite d'idées, ou le modèle mathématique ne peuvent pas être soumis au droit d'auteur
- La documentation est protégée par le droit commun du droit d'auteur

Attribution des droits

- Il est essentiel de pouvoir tracer les différentes contributions pour identifier à qui appartiennent les droits
- En général, différents rôles à considérer :
  - Participation essentielle au développement
  - Apport scientifique important
  - Participation anecdotique (codage d'exemple, corrections, ...)
  - Participation à la diffusion (script d'installation, création d'un paquet ...)
- L'identification des auteurs doit se faire en amont et de façon concertée

Dater la création

- Le droit d'auteur s'applique dès la création du logiciel, il est donc essentiel de pouvoir dater cette création
  - La preuve peut être faite par tout moyen, y compris des choses simples : enregistrement des versions, cahier de laboratoire, envoi de mail à soi-même avec la dernière version ... tout ce qui a un horodatage
  - Preuve aussi par le dépôt APP (Agence pour la Protection des Programmes) : se rapprocher de son service valorisation

- S'il n'y a pas de droit explicitement donné à travers une licence, utiliser un logiciel relève de la contrefaçon.

Pas de licence $\equiv$ tous droits réservés

Les types de licences

Deux grands types de licence :

- Licences libres ou Open Source, termes plus ou moins similaires
  - Les licences dites « libres »(traduction bancale de l'anglais « royalty-free ») viennent de la Free Software Foundation
  - Open Source vient de l'Open Source Society
  - Ils n'ont pas exactement la même philosophie
  - Une licence libre ne veut pas dire libre de droit, bien au contraire !

- Licences privatives / propriétaires, l'auteur se réserve certains droits et peut restreindre l'utilisation. Ces licences ne respectent pas au moins une des 4 libertés fondamentales du logiciel libre.

- Liste des licences existantes : https://spdx.org/licenses/ (Software Package Data Exchange)

Le logiciel libre

- L'ouverture des logiciels développés dans le cadre de la recherche publique est un point essentiel de la science ouverte

- Le logiciel libre définit 4 types de libertés pour l'utilisateur :
  - **Utilisation sans restriction**, liberté d'exécuter le programme, pour tous les usages.
  - **Modification**, liberté d'étudier le fonctionnement du programme, et de l'adapter à vos besoins. Accès au code source condition requise.
  - **Copie**, liberté de redistribuer des copies.
  - **Redistribution**, liberté d'améliorer le programme et de publier vos améliorations, pour en faire profiter toute la communauté. Accès au code source condition requise.

Les principales licences libres

Il existe différents types de licences libres :

- sans copyleft / évanescentes : le logiciel peut être redistribué uniquement sous forme de code binaire, au sein d'un ensemble soumis à la licence de son choix.
- copyleft faible / persistantes : Le logiciel peut être redistribué au sein d'un logiciel placé sous la licence de son choix, mais le code source du logiciel initial doit toujours être fourni avec la licence initiale.
- copyleft fort / diffusives : les termes de la licence du logiciel s'imposent à tout logiciel qui sera redistribué en l'intégrant. Les autres logiciels intégrés doivent donc être sous une licence libre compatible avec celle du logiciel initial.

Type	Exemple de licences
Sans copyleft	BSD license, Apache License 2 MIT
Copyleft faible	GNU library or « Lesser »General Public License (LGPL)
Copyleft fort	GNU General Public, License EUPL

Exemple de licences libres : GNU GPL

- Exemple de la licence GNU GPL = GNU General Public License :
  - C'est la licence la plus connue et la plus répandue dans le monde du libre. Elle autorise, sans l'accord de l'auteur et sans crainte d'une action en contrefaçon :
    - l'utilisation du logiciel,
    - l'étude du fonctionnement du logiciel,
    - l'adaptation du logiciel aux besoins de l'utilisateur,
    - la copie et la diffusion auprès d'amis ou de collègues,
    - l'amélioration du logiciel par l'utilisateur et la distribution du logiciel modifié au public.
  - ATTENTION : il s'agit d'une licence dite contaminante / diffusive !! Elle impose à l'utilisateur de rediffuser ces modifications sous licence GPL $\rightarrow$ l'ensemble du logiciel réutilisant un bout de code GPL est contaminé par la GPL.

Exemple de licences libres : BSD

- Exemple de la licence BSD = Berkeley System Distribution licence :
  - Licence évanescente
  - C'est une licence très peu restrictive : les logiciels diffusés sous licence BSD peuvent être librement copiés ou modifiés. Une seule contrainte : faire figurer sur tous les travaux dérivés, les documentations et les publicités relatives à ces travaux une mention apparente faisant référence à la licence elle-même, et mentionnant les auteurs du logiciel original.

  - A noter : dans le cas de logiciels très populaires, le nombre des auteurs est souvent très important. La mention de l'intégralité des contributeurs est donc complexe et peu lisible. Pour supprimer ce désagrément, la version 2 de la licence BSD supprime les obligations de mentions des auteurs.

Licence multiple

- Principe : distribuer un même logiciel sous plusieurs licences différentes, en général du dual-licensing

- Intérêt : concilier un aspect financier et la possibilité de contribuer au logiciel
  - Soit l'utilisateur utilise une licence libre et peut contribuer en mettant à disposition son travail
  - soit l'utilisateur achète une licence d'utilisation qui va lui permettre d'intégrer le logiciel dans un autre projet propriétaire.

- En pratique : la gestion des licences multiple est délicate. En particulier, s'assurer de la complète paternité sur le logiciel.
  $\rightarrow$ Contacter votre service de valorisation

Licence multiple : exemple

Exemple : MySQL

- Système de gestion de bases de données relationnelles.
- Logiciel libre et open source.
- Distribué sous une double licence GPL et privative.
- Ce qui permet de le distribuer dans un produit propriétaire.

En pratique, mettre une licence sur un logiciel

- Anticiper le choix de la licence !
  - Dépend des conventions et contrats éventuels
  - En accord avec les établissements concernés, et l'ensemble des co-auteurs
  - Avant l'ouverture et la diffusion
  - Tenir compte des licences des dépendances incluses
- En pratique :
  - Intégrer le fichier texte de la licence dans le dépôt du code (fichier LICENSE ou COPYING)
  - Intégrer les entêtes de la licence dans tous les fichiers source (cf exemple ci-dessous)
  - Intégrer un fichier AUTHORS avec le nom des auteurs

```
/*
 * Copyright (c) 2017 Alice Commit <alice@example.com>
 *
 * SPDX-License-Identifier: BSD-2-Clause
 * License-Filename: LICENSES/BSD-2-Clause_Alice.txt
 */
```

Plan

Plan

Plan de Gestion de Données / Data Management Plan

- Document exigé désormais pour la majorité des projets financés
- Aide concrète à la gestion des données durant tout le projet et au-delà
- Permet de se poser les bonnes questions, et d'anticiper les besoins :
  - Type des données, volumétrie, stockage, sauvegarde, partage ...
  - Problématiques juridiques
  - Diffusion, valorisation et conservation
  - Financement prévu ...

Plan de Gestion Logiciel / Software Management Plan

- La nécessité de prévoir et d'anticiper le déroulement d'un projet de recherche en ce qui concerne les logiciels développés dans ce cadre est aussi importante que pour les données
- Mais les questions ne se posent pas de la même façon
- Quelques éléments clés :
  - Objectif (scientifique) du logiciel
  - Cible en terme d'utilisateurs
  - Aspects techniques : plateforme de développement, langage de programmation, règles de programmation, dépendances, intégration des contributions, intégration continue / tests, documentation, packaging, OS cibles ...
  - Aspects juridiques : impact des dépendances, attribution des droits, gestion des auteurs et contributeurs, copyright assignement, licences, ...
  - Ouverture et diffusion

Modèles de Plan de Gestion Logiciel

Il existe peu de modèles de Plan de Gestion Logiciel.
Deux sont disponibles sur DMP Opidor (en anglais) :

- PRESOFT project - également sur Hal
- Software Sustainability Institut

MAIS une implémentation de Software Management Plan est en cours sur DMP Opidor !!

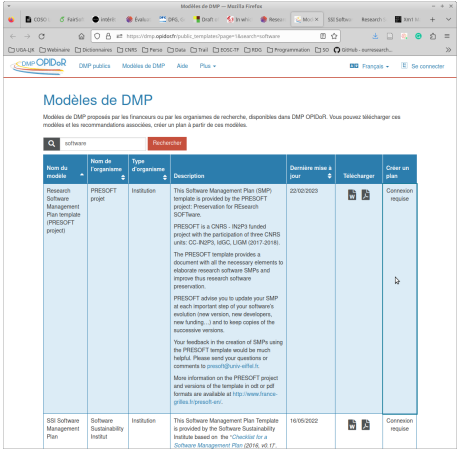

Plan

Principes FAIR

Findable/Trouvable : Données faciles à trouver.

- possédant un identifiant unique et pérenne
- décrites par des métadonnées riches
- enregistrées ou indexées dans une source interrogeable

Accessible : Données ou au moins méta-données facilement accessibles.

- entrepôt de confiance, pérenne, certifié
- définir les conditions d'accès et la licence de diffusion
- si embargo ou accès restreint : méta-données accessibles

Interoperable : Facile à combiner avec d'autres jeux de données, par les humains et les systèmes informatiques

- formats libres et ouverts
- mise à disposition du code source si le logiciel de traitement existe
- standards de métadonnées et vocabulaire standardisés

Reusable/Réutilisable : Prêtes à être réutilisables pour une future recherche y compris via des méthodes informatiques

Code de recherche $\neq$ données de recherche

- Les données de recherche sont plutôt passives, les codes sont intrinsèquement vivants
  - On ne change en général pas les données, collectées dans un contexte bien défini
  - On change éventuellement la façon dont on les traite et on les analyse (grâce à des codes)
  - Les codes sont associés à une (ou des) action(s) : création de connaissances, transformation d'informations, visualisation, ...
  - Le code peut être réutilisé tel que, en reproduisant son environnement et toutes ses dépendances mais on a surtout envie de le modifier pour l'adapter à nos besoins propres ou l'enrichir de nouvelles fonctionnalités
- Les codes s'appuient sur des dépendances et tout un environnement logiciel et matériel qui évolue sans cesse
  - Cela complexifie les questions de reproductibilité
- Les codes représentent un travail de création, et correspondent à un cadre juridique différent de celui des données

Codes de recherche et FAIR

Les principes FAIR sont-ils adaptables au logiciel ?

- Les objectifs des principes FAIR sont de rendre les objets de recherche réutilisables
- Problématique proche de la reproductibilité
- Or la reproductibilité en matière de logiciel est un idéal difficile à atteindre
- Questions ouvertes :
  - Comment définir les contributions et donc les citations ? En particulier quand il y a un grand nombre d'auteurs. Et des types de contributions très différents.
  - Comment intégrer l'environnement, les dépendances ?
  - Comment considérer la problématique de l'installation qui peut être très complexe ?
  - Comment prendre en compte la dynamique du code dans un identifiant pérenne et unique ?
  - ...

Plan

Publication de logiciels

- Tout comme pour les données pour lesquelles il existe une forme de publication : les data papers, il est possible de publier spécifiquement sur du code
- Liste de journeaux dans lesquels les soumissions sur les logiciels sont acceptées : https://www.software.ac.uk/which-journals-should-i-publish-my-software
- Exemple de process de review du JOSS (Journal of Open Source Software) :
  - Général : dépôt, licence, auteurs et contributeurs
  - Fonctionnalité : installation, confirmation des fonctionnalités annoncées, performances éventuelles
  - Documentation : objectifs, installation, exemples, documentation fonctionnelle, tests, recommandations pour la communauté
  - Article : description claire des fonctionnalités et du problème résolu, positionnement par rapport à d'autres logiciels proches, qualité de la rédaction, références

Le cas de ReScience

- Revue créée en 2015 par Konrad Hinsen et Nicolas Rougier
- Objectif : publier les tentatives des chercheurs de répliquer les calculs effectués par d'autres auteurs, en utilisant des logiciels écrits indépendamment, libres et open-source, avec un processus ouvert d'examen par les pairs

Plan

Archivage des codes sources

Pourquoi archiver ?

- Le code source est fragile :
  - Obsolescence des formats, problème matériel, dépendances à des outils (forge par exemple) qui disparaissent ...
  - La perte des codes ayant été utilisés pour de la production scientifique arrive malheureusement régulièrement
- Les logiciels sont un des piliers des processus de recherche, au côté des publications et des données et il est essentiel de les préserver

- Archivage $\neq$ stockage $\neq$ outil de développement
  - Archivage $\equiv$ préservation sur du long terme

Software Heritage

- Initiative dont l'objectif est de construire une archive universelle des codes sources
- En les collectant, les préservant et les partageant sur le long terme
- Lancée en 2016 par INRIA et soutenue par l'UNESCO
- Collecte de l'intégralité des logiciels disponibles publiquement sous forme de code source.
- Depuis des plateformes d'hébergement de codes, comme GitHub, GitLab.com ou Bitbucket, et des archives de paquets, comme Npm ou Pypi ...

Collect
Preserve
Share

https://archive.softwareheritage.org/

Signalement des logiciels de la recherche

Pourquoi signaler ?

- Assurer la description
- Faciliter la recherche (par domaine scientifique par exemple)
- Permettre la citation
- Valoriser les logiciels

- Importance des métadonnées pour :
  - Décrire de façon précise et contrôlée un logiciel
  - Identifier son usage
  - Spécifier le contexte
  - Créditer plus facilement les créateurs
- Importance des identifiants pérennes pour :
  - Garantir un lien stable à la ressource en ligne

HAL, Hyper Articles en Ligne

- Archive ouverte pluridisciplinaire
- Initiée en 2000 par le CNRS et exploitée par le CCSD - Centre pour la Communication Scientifique Directe
- Fournit des outils pour l'archivage et la diffusion ouverte des résultats scientifiques.
- Où les chercheurs peuvent déposer leurs résultats académiques dans le respect de leurs droits d'auteur
- Supporte différents types de dépôt :
  - Publications,
  - Documents (par exemple préprints et rapport),
  - Thèses ...
- Pour rendre la recherche aussi accessible et ouverte que possible

https://hal.science/

HAL + Software Heritage

- Un nouveau type de dépôt sur HAL : le logiciel
  - Collaboration initiée en 2018 entre HAL et SWH
  - Après une phase de test avec INRIA, déployé largement aujourd'hui
  - En particulier, le dépôt SWHID (identifiant pérenne de SWH) est désormais en production
- Complémentarité des deux plateformes
  - Grande visibilité des logiciels dans une démarche de science ouverte via HAL
  - Archivage pérenne via Software Heritage
  - Modération des métadonnées pour assurer leur qualité
  - Différents formats d'export pour faciliter la citation

HAL + Software Heritage : en pratique

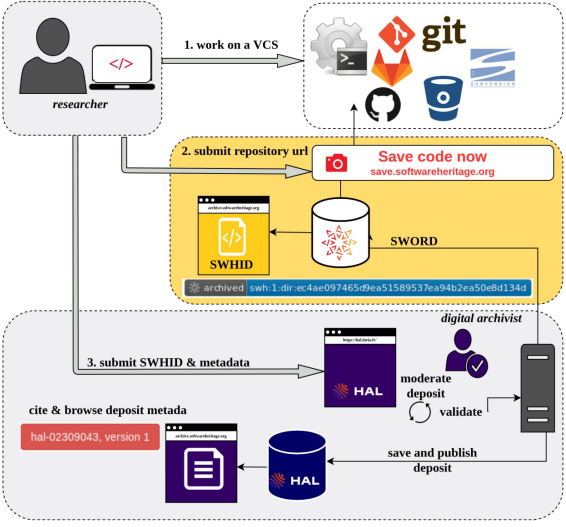

Métadonnées

Métadonnées intrinsèques

Font référence aux informations contenues dans le code source lui-même, telles que les fichiers README, les licences et les fichiers de gestion des paquets.

Métadonnées extrinsèques

Métadonnées sur des entités externes telles que des plateformes d'hébergement de code, des registres ou des référentiels scientifiques contenant des informations supplémentaires sur le logiciel.
Elles renseignent aussi sur la relation entre le logiciel et dautres produits de recherche : des publications, des jeux de données. Ces métadonnées ne sont pas incluses dans le code source.

L'exemple de CodeMeta

- Format de métadonnées qui joue un rôle de pivot / table de concordance entre différents vocabulaires disponibles
- Format privilégié pour HAL + SWH
- La présence d'un fichier codemeta.json dans le dépôt du projet sur SWH est détecté par HAL qui charge automatiquement les métadonnées
- Existence d'un outil en ligne facilitant la création du fichier json : `https://codemeta.github.io/codemeta-generator/` (mais aussi d'outils spécifiques pour les paquets R et Python).

Petit TP : votre fichier codemeta.json

- Par groupe de 4 ou 5
- Pendant 15 mn
- Choisissez un des codes sur lequel vous travaillez
- A l'aide du *codemeta-generator*, créer votre fichier *codemeta.json*
- Courte restitution

Citation

- L'utilisation de HAL et SWH facilite la citation du logiciel :
  - Plusieurs formats d'exports possibles (BibTeX, TEI, DCTERMS, codemeta.json, etc.)
  - Permet de créer les liens nécessaires entre les publications, les données et les codes
  - Indispensable pour la reproductibilité. En particulier, le SWHID désigne précisément un logiciel dans son contexte (version, commit, ...)
  - Important pour créditer correctement les auteurs et contributeurs

Plan

Enjeux de la reproductibilité

Intégrité scientifique

Décret no 2021-1572 du 3 décembre 2021 : « l'ensemble des règles et valeurs qui doivent régir les activités de recherche pour en garantir le caractère honnête et scientifiquement rigoureux »

- L'ouverture des publications, des données et des codes sources est une condition nécessaire à la reproductibilité des résultats scientifiques
- Suffisante ?

La recherche reproductible (computationnelle) est encore aujourd'hui l'exception
il vaut mieux parler de transparence

Exemple : Repeatability in Computer Science

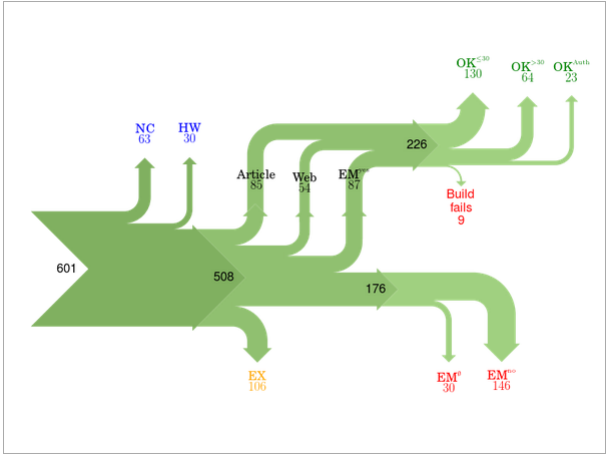

Legend

Classification		Code Location		Build Results	
BC	Paper where the results are backed by code.	Article	Code is found from link in the article itself.	OK^<30	We succeed in building the system in ≤30 minutes.
NC	Paper excluded due to results not being backed by code.	Web	Code is found from a web search.	OK^>30	We succeed in building the system in >30 minutes.
HW	Paper excluded due to replication requiring special hardware.	EM^yes	Code is provided by author after email request.	OK^Author	We fail to build, but the author says the code builds with reasonable effort.
EX	Paper excluded due to overlapping author lists.	EM^no	Author responds that the code cannot be provided.	Fails	We fail to build, and the author doesn't respond to survey or says code may have problems building.
		EM^0	Author does not respond to email request within 2 months.		

Définitions [1]

Pas mal de concepts différents dont les définitions ne font pas consensus : répétabilité, reproductibilité, réplicabilité

Rerunnable Can you re-run your program ? One day, one week, one month, one year (just kidding) apart ?

Repeatable Can you re-run your program and get same results ? Did you save everything, including random seed ?

Reproducible Can someone re-run your program and get same results ? Did you save the software stack ?

Replicable Can someone reimplement your model and get same results ? Did you describe everything ?

Reusable Can someone reuse your program using different data ? Is your software data-dependent ?

1. Konrad Hinsen, Nicolas P. Rougier. ReScience 2017. hal-01573262

Vraie et fausse reproductibilité [2]

- Le code ouvert permet et facilite l'inspection critique du source
- Mais il ne suffit pas de rendre le code public
- Il faut aussi ouvrir son environnement
- Et évaluer la fiabilité des dépendances
- Sans parler des dépendances possibles au hardware

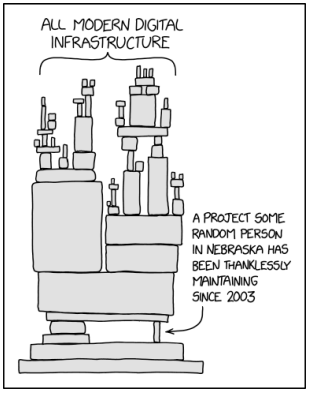

a

a. https://xkcd.com/2347/

2. Open Science Days UGA 2022, K. Hinsen

Complexité liée au logiciel

Chaque résultat numérique d'un code dépend de :

- les données d'entrée
- le code source
- les bibliothèques (dépendances) utilisées par le code
- les compilateurs / interpréteurs
- les options de compilation
- le système d'exploitation de l'ordinateur
- le hardware de la machine

Tout un environnement non stable, pas toujours documenté, qui évolue en permanence et qu'on ne contrôle pas.

Reproductibilité et bonnes pratiques

Le respect de bonnes pratiques de développement facilite le cheminement vers la reproductibilité :

- Versionning : être capable d'accéder à la version du code qui a permis la publication
- Tests : permet d'assurer la reproductibilité du comportement au cours de la vie du code
- Revue de code : s'assurer que le code est lisible et compréhensible par d'autres que soi
- Documentation : décrire ce que fait le logiciel (approche scientifique), comment l'utiliser, ...
- Utiliser des formats ouverts
- Définir des conventions de programmation et de nommage
- Utiliser des environnements logiciels reproductibles : guix, nix

Plan

Conclusions

- Le logiciel est un pilier de la recherche dans la plupart des disciplines scientifiques
- Le logiciel libre est ancré historiquement depuis toujours dans le monde universitaire et est un précurseur du mouvement de la science ouverte.
- La question de la reproductibilité computationnelle est complexe et nécessite de mettre en oeuvre de bonnes pratiques
  - qui vont aussi grandement faciliter la vie du développeur
- L'utilisation d'une forge logicielle est la base pour simplifier toutes les étapes du cycle de vie d'un logiciel, y compris son archivage
- Ne pas négliger cette production scientifique ! Valorisez la grâce à HAL et Software Heritage.