

ÉCOLE CENTRALE DE LYON

Formation doctorale : Bibliothèque Michel Serres



ÉCOLE
CENTRALE LYON

ÉCOLE CENTRALE DE LYON

Gestion des données de recherche : optimisation de l'impact de vos travaux(2/2).



ÉCOLE
CENTRALE LYON

Code & données de la recherche (2/2)

Formateurs : Code & données de la recherche

- Linda Angulo, Chargée de Mission Données de la Recherche
- Matteo Camier, Responsable HPC @pmcs2i.ec-lyon

Formateurs : Publications

- Nicolas Jardin, Directeur adjoint Biblio. Michel Serres
- Stéphanie Lamaison, Bibliothécaire Biblio. Michel Serres



ÉCOLE
CENTRALE LYON

36, avenue Guy de Collongue 69130 Écully - France
+33 (0)4 72 18 60 00

www.ec-lyon.fr

Commentaires et rappels



Guide de Bonnes Pratiques sur la gestion des données de la Recherche

Groupe de travail "Atelier Données"

Mission pour les Initiatives Transverses Interdisciplinaires

Voir: http://corist-shs.cnrs.fr/sites/default/files/ressources/guide_bonnes_pratiques_gestion_donnees_recherche_v2.pdf

Génération de fichiers NetCDF avec Python3

Voir: <https://desktop.arcgis.com/fr/arcmap/latest/manage-data/netcdf/fundamentals-of-netcdf-data-storage.htm>

<https://www.cs.ubbcluj.ro/weadl/wp-content/uploads/2022/06/Arild%20Burud%20-%20Introduction%20to%20netCDF%20and%20THREDDS.pdf>

```
netcdf filename {
dimensions:
  lat = 3 ;
  lon = 4 ;
  time = UNLIMITED ; // (2 currently)

variables:
  float lat(lat) ;
    lat:long_name = "Latitude" ;
    lat:units = "degrees_north" ;
  float lon(lon) ;
    lon:long_name = "Longitude" ;
    lon:units = "degrees_east" ;
  int time(time) ;
    time:long_name = "Time" ;
    time:units = "days since 1895-01-01" ;
    time:calendar = "gregorian" ;
  float rainfall(time, lat, lon) ;
    rainfall:long_name = "Precipitation" ;
    rainfall:units = "mm yr-1" ;
    rainfall:missing_value = -9999.f ;

// global attributes:
  :title = "Historical Climate Scenarios" ;
  :Conventions = "CF-1.0" ;

data:
  lat = 48.75, 48.25, 47.75;
  lon = -124.25, -123.75, -123.25, -122.75;
  time = 364, 730;
  rainfall =
    761, 1265, 2184, 1812, 1405, 688, 366, 269, 328, 455, 524, 877,
    1019, 714, 865, 697, 927, 926, 1452, 626, 275, 221, 196, 223;
}
```

Coordinate variable

Variable attribute

Global attribute

EXO-1 : clone > pull > checkout -b branch > switch > edit > commit > push > merge (owner, maintainer)

- fork, si pas invité !!

- Git Cheat Sheet

Git Cheat Sheet

01 Git configuration

<code>git config --global user.name "Your Name"</code>	Set the name that will be attached to your commits and tags.
<code>git config --global user.email "you@example.com"</code>	Set the e-mail address that will be attached to your commits and tags.
<code>git config --global color.ui auto</code>	Enable some colorization of Git output.

02 Starting a project

<code>git init [project name]</code>	Create a new local repository in the current directory. If [project name] is provided, Git will create a new directory named [project name] and will initialize a repository inside it.
--------------------------------------	---

<code>git rm [file]</code>	Remove file from working directory and staging area.
----------------------------	--

04 Storing your work

<code>git stash</code>	Put current changes in your working directory into stash for later use.
<code>git stash pop</code>	Apply stored stash content into working directory, and clear stash .
<code>git stash drop</code>	Delete a specific stash from all your previous stashes .

05 Git branching model

<code>git branch [-a]</code>	List all local branches in repository. With -a , show all branches (with remote).
<code>git branch [branch_name]</code>	Create new branch, referencing the current HEAD .
<code>git rebase [branch_name]</code>	Apply commits of the current working branch and apply them to the HEAD of [branch] to make the history of your branch more linear.
<code>git checkout [-b] [branch_name]</code>	Switch working directory to the specified branch. With -b , Git will create the specified branch if it does not exist.
<code>git merge [branch_name]</code>	Join specified [branch_name] branch into your current branch (the one you are on currently).
<code>git branch -d [branch_name]</code>	Remove selected branch, if it is already merged into any other. -D instead of -d forces deletion.

Commit	a state of the code base
Branch	a reference to a commit; can have a tracked upstream
Tag	a reference (standard) or an object (annotated)
HEAD	a place where your working directory is now

main ▼ wiki-openscience-ecl

Jun 11, 2024

 Update file open-science-glossary.txt
2 hours ago

 Update file open-science-glossary.txt

 Merge branch 'developer' into 'main' ⋮
Angulo Lopez Linda authored 4 hours ago

 presentation notes
Angulo Lopez Linda authored 4 hours ago

```
languol@IN1958 MINGW64 //ws1.localhost/Ubuntu-20.04/home/languol/gitlab/wiki-openscience-ecl (developer)
$ git status
On branch developer
Your branch is up to date with 'origin/developer'.

nothing to commit, working tree clean

languol@IN1958 MINGW64 //ws1.localhost/Ubuntu-20.04/home/languol/gitlab/wiki-openscience-ecl (developer)
$ git switch main
Switched to branch 'main'
Your branch is behind 'origin/main' by 7 commits, and can be fast-forwarded.
(use "git pull" to update your local branch)

languol@IN1958 MINGW64 //ws1.localhost/Ubuntu-20.04/home/languol/gitlab/wiki-openscience-ecl (main)
$ git pull
Updating 67b4c44..7143c1c
Fast-forward
 ..51es-et-codes-de-recherche-centrale-lyon_1.pdf" | Bin 0 -> 5419352 bytes
 ..1es-et-codes-de-recherche-centrale-lyon_1.pptx" | Bin 0 -> 11282177 bytes
 open-data-code-2024/exo-1/exo-1.txt                | 88 +++
 ../exo-1/open-science-glossary.txt                | 2 +
 open-data-code-2024/notes_ppt-1.txt               | 795 ++++++
 create mode 100644 "open-data-code-2024/donn\303\251es-et-codes-de-recherche-centrale-lyon_1.pdf"
 create mode 100644 "open-data-code-2024/donn\303\251es-et-codes-de-recherche-centrale-lyon_1.pptx"
 create mode 100644 open-data-code-2024/exo-1/exo-1.txt
 create mode 100644 open-data-code-2024/exo-1/open-science-glossary.txt
 create mode 100644 open-data-code-2024/notes_ppt-1.txt

languol@IN1958 MINGW64 //ws1.localhost/Ubuntu-20.04/home/languol/gitlab/wiki-openscience-ecl (main)
$ |
```

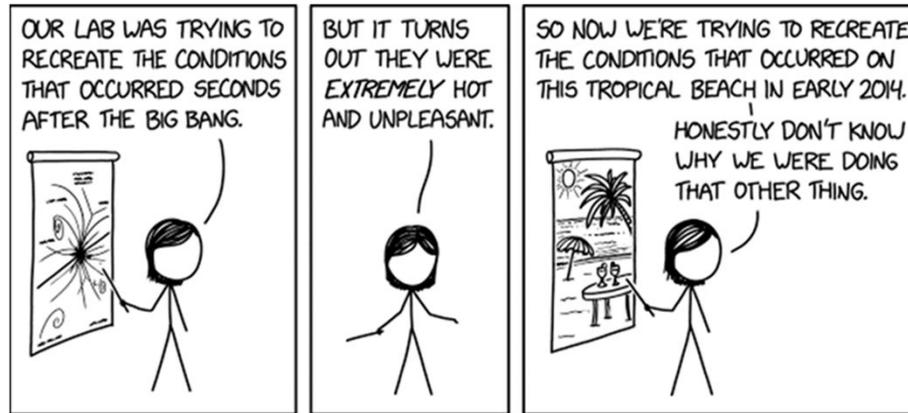
7143c1cd  

50368eb9  

92665753  

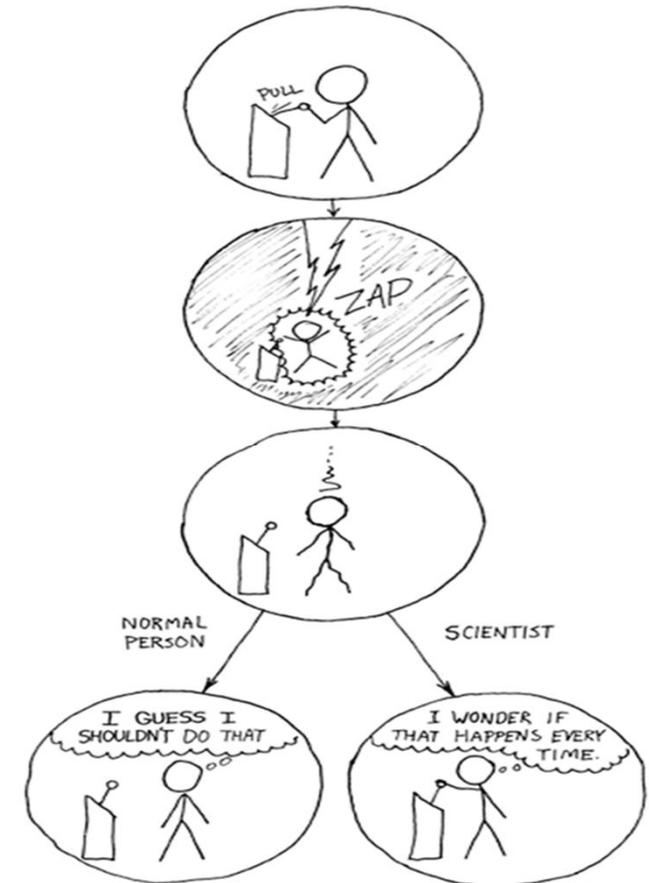
c3e97cf2  

Code & données de la recherche (2/2)



36, avenue Guy de Collongue 69130 Écully - France
+33 (0)4 72 18 60 00

www.ec-lyon.fr



ÉCOLE CENTRALE DE LYON

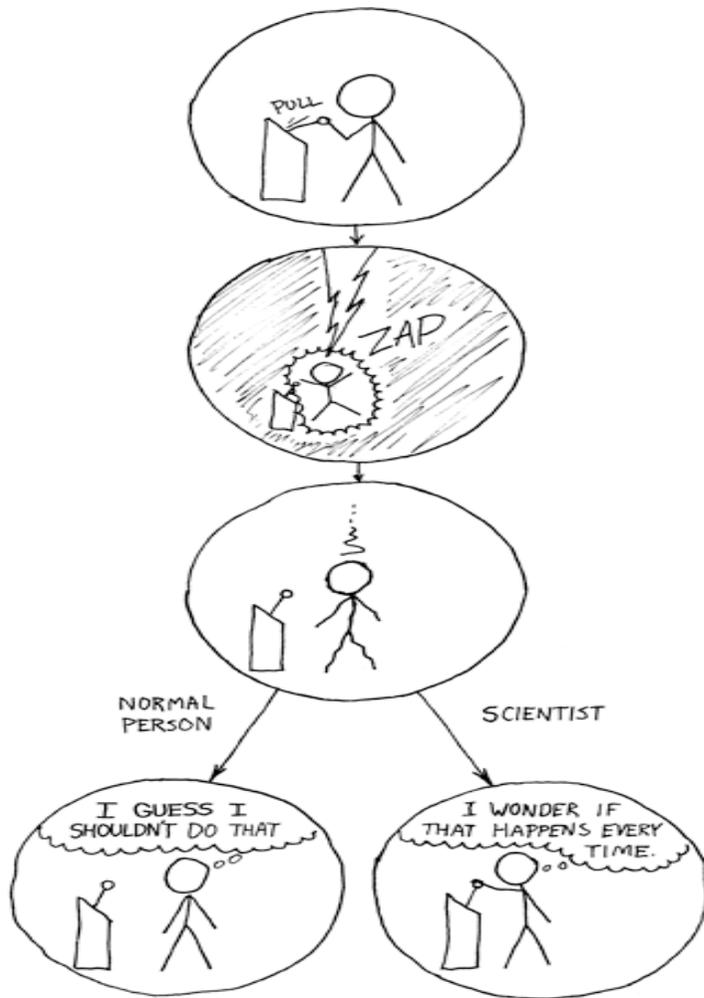
Produire des faits vérifiables

Reproducibility



ÉCOLE
CENTRALE LYON

L'environnement logiciel, source de variabilité



Reproductibilité

- recréer exactement le même environnement

Répliquabilité

- suffisamment bien documenté et partagé

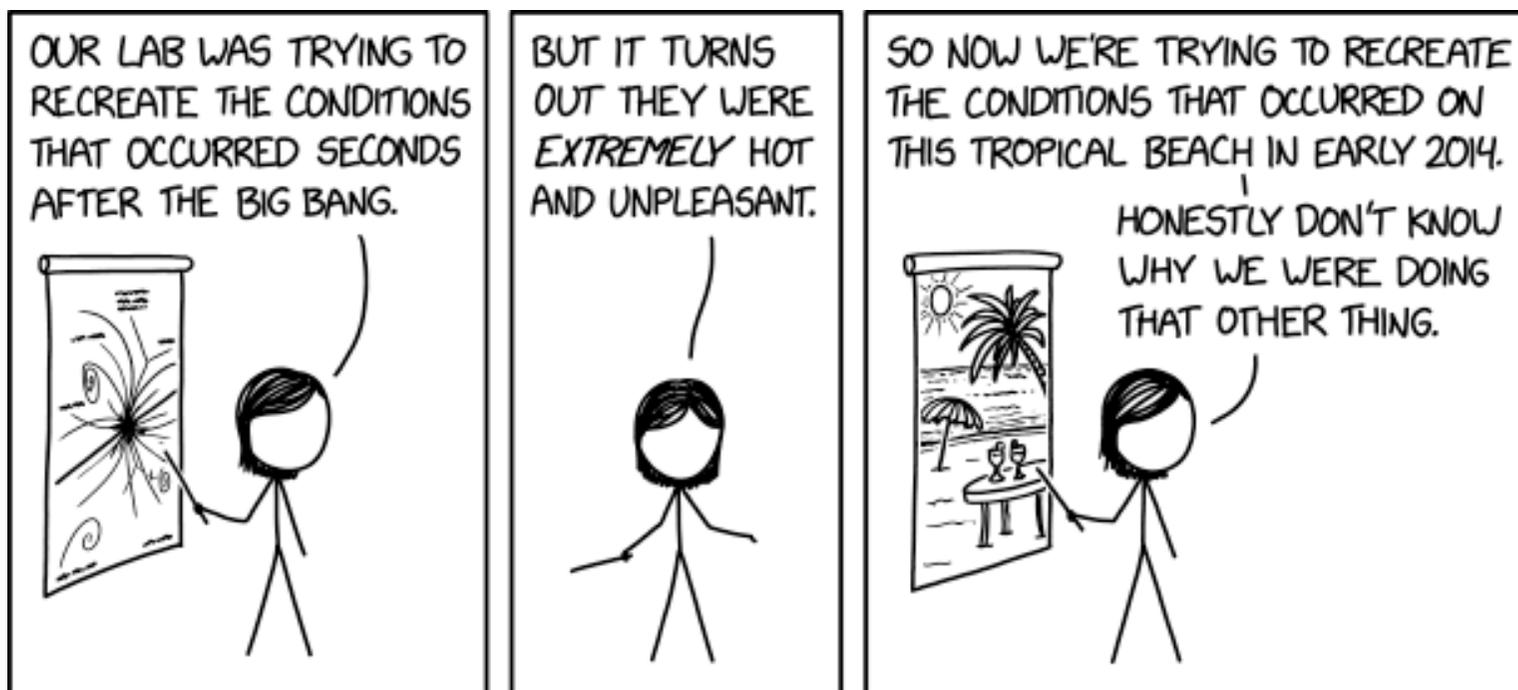
Validation des résultats

- cohérent et bien défini

Produire des faits vérifiables

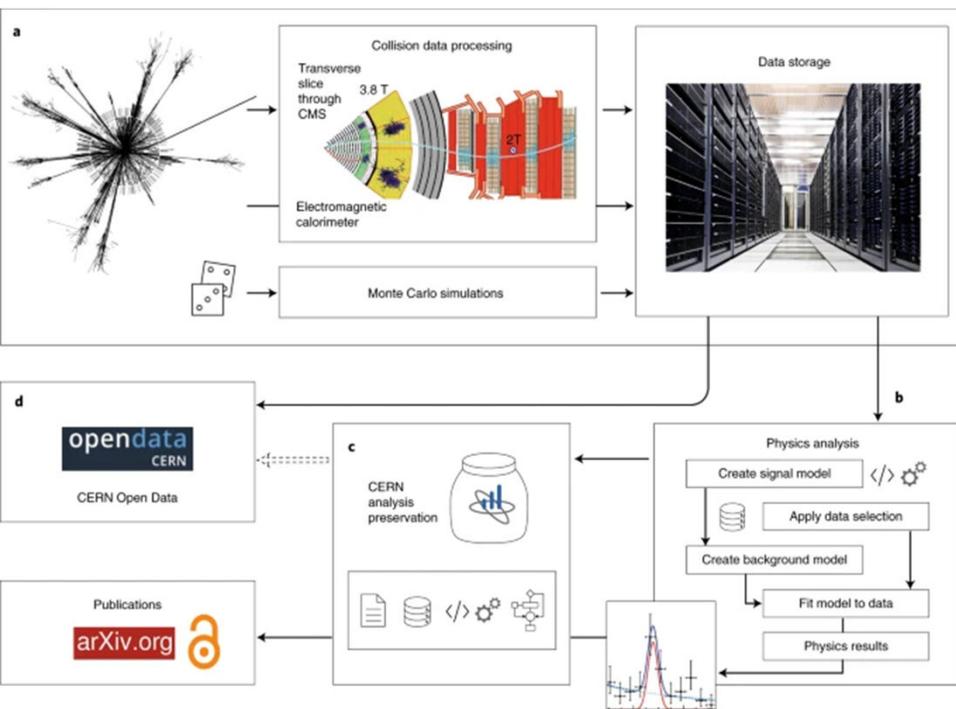
Trois axes de reproductibilité :

- méthode
- résultats
- inférence



Défis et enjeux de la reproductibilité

- L'amélioration continue des connaissances scientifiques.
- Événement bien décrit, observé à plusieurs reprises et provoqué par différentes personnes.
- La répétabilité et la répliquabilité



- Évaluée par des méthodes statistiques et probabilistes.
- Contraintes temporelles, financières et techniques.
- CERN, des stratégies pour la recherche reproductible



Rétractations : Scandales majeurs

▪ Équipe de Ranga Dias

- Article de 2023 dans Nature sur le supraconducteur à température ambiante rétracté
- Données fabriquées et falsifiées découvertes

▪ Équipe de Microsoft Quantum

- Article de 2018 dans Nature sur les particules de Majorana rétracté
- Données sélectionnées, résultats invalidés

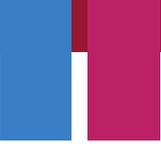
Les physiciens s'inquiètent pour leur réputation et leur avenir

"If you think of research as a product that is paid for by the taxpayer, then

Reproducibility
is the Quality
Assurance
Department,..."

Frolov, ICRCMP, 2024





Processus et attitudes actuel

- Publications soumise aux éditeurs, revue par des référents anonymes
- Mauvais résultats publiés, problèmes de responsabilité
- Besoin d'une meilleure assurance qualité et reproductibilité
- Aborder la pression systémique à publier

Quoi faire

- Encourager des vues positives sur le partage des données
- Créer une culture de résultats partageables et reproductibles

Renforcer la confiance dans la science

- **Les journaux et les agences de financement**
- **Créer une culture de résultats partageables et reproductibles**

Défis pratiques

- **Soutien nécessaire pour les étudiants en doctorat pour la préparation des données**

Travailler en Collaboration à l'échelle Européen

- Les projets européens, depuis 1984
- 31 projets Horizon 2020
- Environnements et Dépendances



Travailler en Collaboration avec vos collègues

Proposer des outils Informatiques

- CSV, netCDF, ... + Code
- Jupyter, RStudio, Emacs ou Git
- DMP-Opindor
- Research Data Gouv
- Newton et CC-IN2P3

Façons de procéder

- l'enthousiasme
- la gentillesse
- l'indifférence



L'environnement logiciel, source de variabilité

**Programme
(code; script)**

**Données (Bruts;
traitées)**

**Environnement
(Matériel; logiciel)**

Workflow

Recherche Reproductible

Cycle de vie des données



Collection

Stockage

Traitement

Analyse

Publication

Archivage

Réutilisation

Pérennisation

Suppression

Vie de la donnée



Newton HPC

- Espace utilisateur, \$HOME
- Volume scratch
- Espaces de stockage par laboratoire
- Volume dédié aux IO intensifs
- Espace des modules et logiciels communs

bash

 Copy code

```
Disk quotas for user USER (uid XXXX):
```

Filesystem	space	quota	limit	grace	files	quota	limit	grace
service2:/home/LABO/USER	1010G	1048G	1048G		837k	0	0	

Les gestionnaires d'environnement logiciels

- **Systemes d'exploitation (apt-get; yum)**
- **Packages de langage (pip_Python)**
- **Généralistes HPC (spack ; easybuild)**
- **Pour la reproductibilité HPC (nix; guix)**

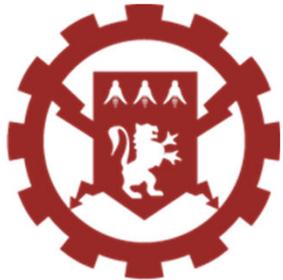
Environnements virtuels avec pip

Le gestionnaire de paquets, Python

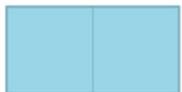
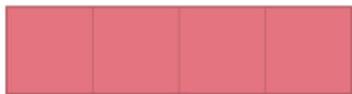
- Environnements virtuels
- Gestion des dépendances
- Documentation des environnements



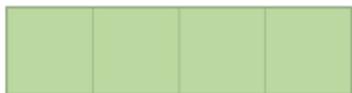
- Contrôle de version
- Partage et distribution



ÉCOLE
CENTRALE LYON



EASYBUILD.io



building software with ease

pmcs2i.ec-lyon

- Mise en place initiale
- Assurer la cohérence
- Faciliter le développement collaboratif
- Déploiements & reversions
- Corrections de Bugs
- Revenir à une version précédente

Cycle de vie des données



Le standard d'échange de données pour l'archivage (SEDA)

Issu d'une collaboration lancée dès 2006 entre les Archives de France et l'ancienne Direction générale de la modernisation de l'État (DgME), le standard d'échange de données pour l'archivage (SEDA) vise à faciliter l'interopérabilité entre le système d'information d'un service d'archives et les systèmes d'information de ses partenaires dans le cadre de leurs échanges de données.

Transaction et acteurs + Formalisme

Rechercher



Archives référencées ?

Ressources du site ?

Recherche avancée

Préservation du patrimoine culturel et scientifique

Type de document	DUA	Sort final	Observations
Comptes rendus des réunions du conseil de service et du comité des directeurs de laboratoires	8 ans	C	Les autres collections de comptes rendus qui peuvent exister à la délégation sont à détruire.

- Lieux de versement des archives historiques, CC-IN2P3
- Soutien technique et administratif aux unités de recherche et de service, PMCS21
- la typologie des documents, durée d'utilité administrative
- le sort final qui doit être appliqué aux documents (C, T, D)
- Observations nécessaires à la compréhension et à la mise en œuvre
 - Schémas de métadonnées (descriptives, structurelles et administratives)
 - Définir clairement les droits d'utilisation
 - Mettre régulièrement à jour les supports de stockage
 - Assurer un financement adéquat et un soutien politique
 - Prévoir l'obsolescence technologique
- https://www.legifrance.gouv.fr/codes/section_lc/LEGITEXT000006074236/LEGISCTA000006129161/

Pérennisation des Données et Code au CC-IN2P3

- Bandes magnétiques
- Redondance et sauvegarde
- Accès à long terme
- Gestion des versions
- Documentation
- Partage et collaboration



Cycle de vie des données



Produits gratuits

- **Licence publique générale GNU (GPL)**

Produits commerciaux

- **Licence Apache**
- **Licence MIT**

Licence permissive

- **Licence BSD**
- **Creative Commons**

Cycle de vie des données



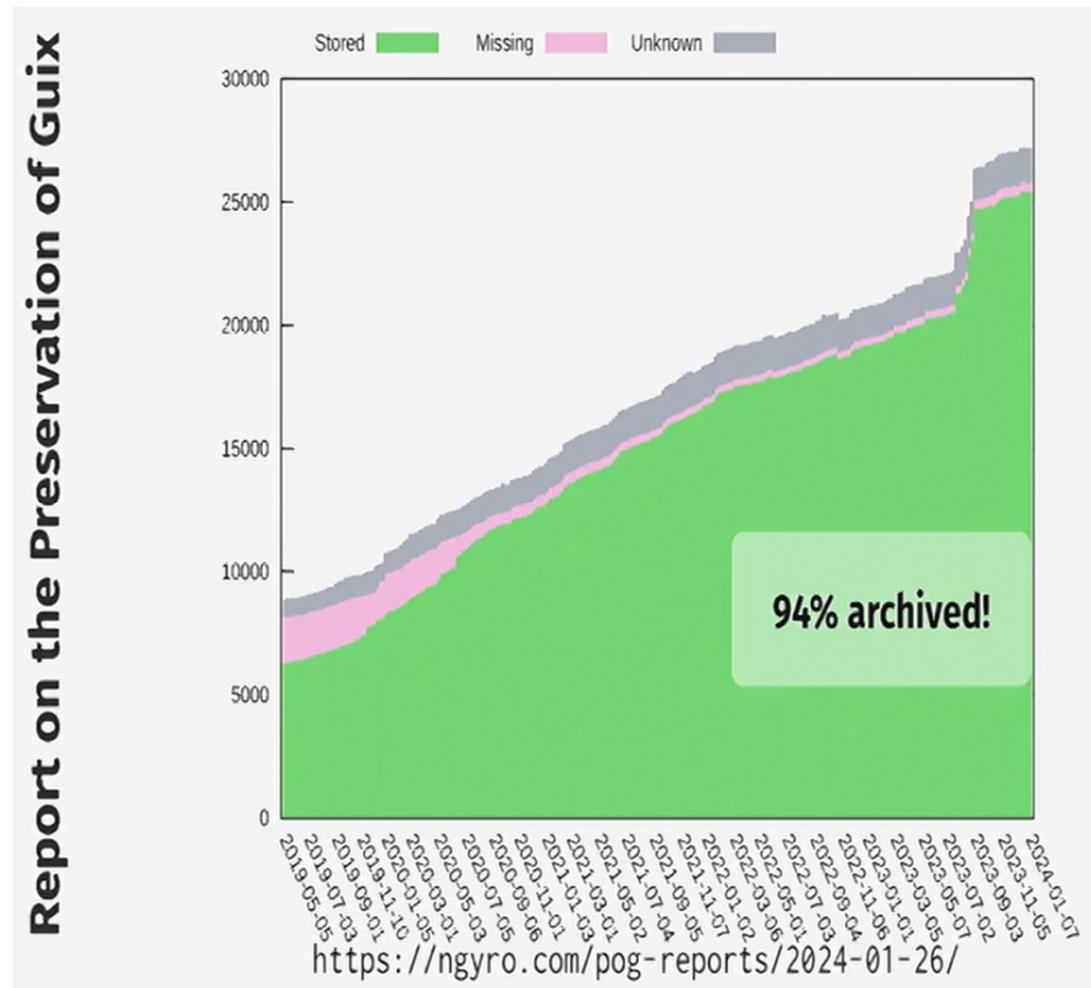
- **Normes et Formats Durables**
- **Gestion des Métadonnées**
- **Politiques et Cadres Juridiques**
- **Maintenance et Actualisation**
- **Gestion de la Confidentialité et de la Sécurité**
- **Engagement Communautaire**

Guix, conteneur avec guix time-machine

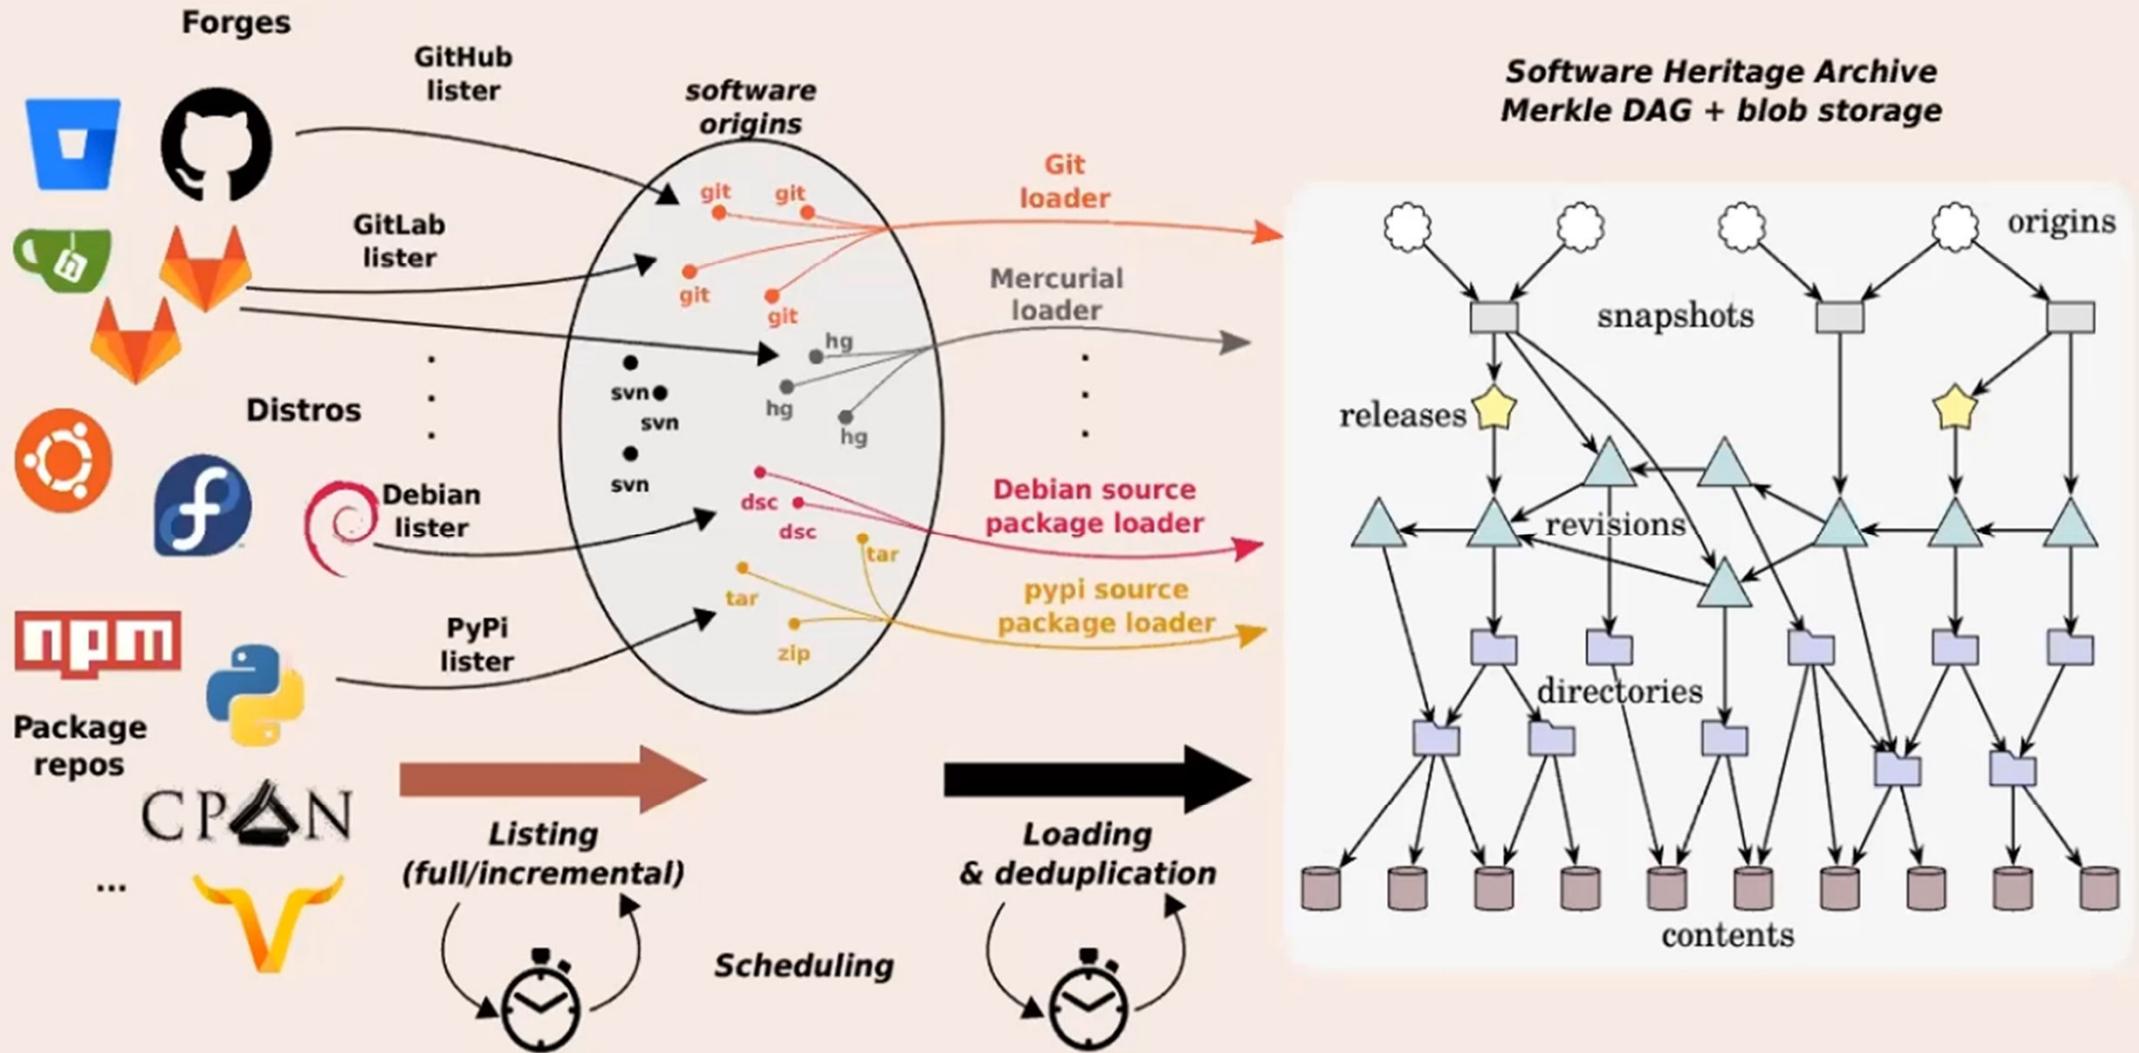
- Software Heritage
- env. virtuel universel
- voyage dans le temps & l'espace



31



Code, Forges logicielles et Software Heritage



L'Impératif de la Recherche Ouverte et Reproductible

nature
physics

PERSPECTIVE

<https://doi.org/10.1038/s41567-018-0342-2>

Corrected: Publisher Correction

OPEN

Open is not enough

Xiaoli Chen^{1,2}, Sünje Dallmeier-Tiessen^{1*}, Robin Dasler^{1,11}, Sebastian Feger^{1,3}, Pamfilos Fokianos¹, Jose Benito Gonzalez¹, Harri Hirvonsalo^{1,4,12}, Dinos Kousidis¹, Artemis Lavasa¹, Salvatore Mele¹, Diego Rodriguez Rodriguez¹, Tibor Šimko^{1*}, Tim Smith¹, Ana Trisovic^{1,5*}, Anna Trzcinska¹, Ioannis Tsanaktsidis¹, Markus Zimmermann¹, Kyle Cranmer⁶, Lukas Heinrich⁶, Gordon Watts⁷, Michael Hildreth⁸, Lara Lloret Iglesias⁹, Kati Lassila-Perini⁴ and Sebastian Neubert¹⁰

The solutions adopted by the high-energy physics community to foster reproducible research are examples of best practices that could be embraced more widely. This first experience suggests that reproducibility requires going beyond openness.

L'environnement logiciel, source de variabilité

Programme
(code; script)

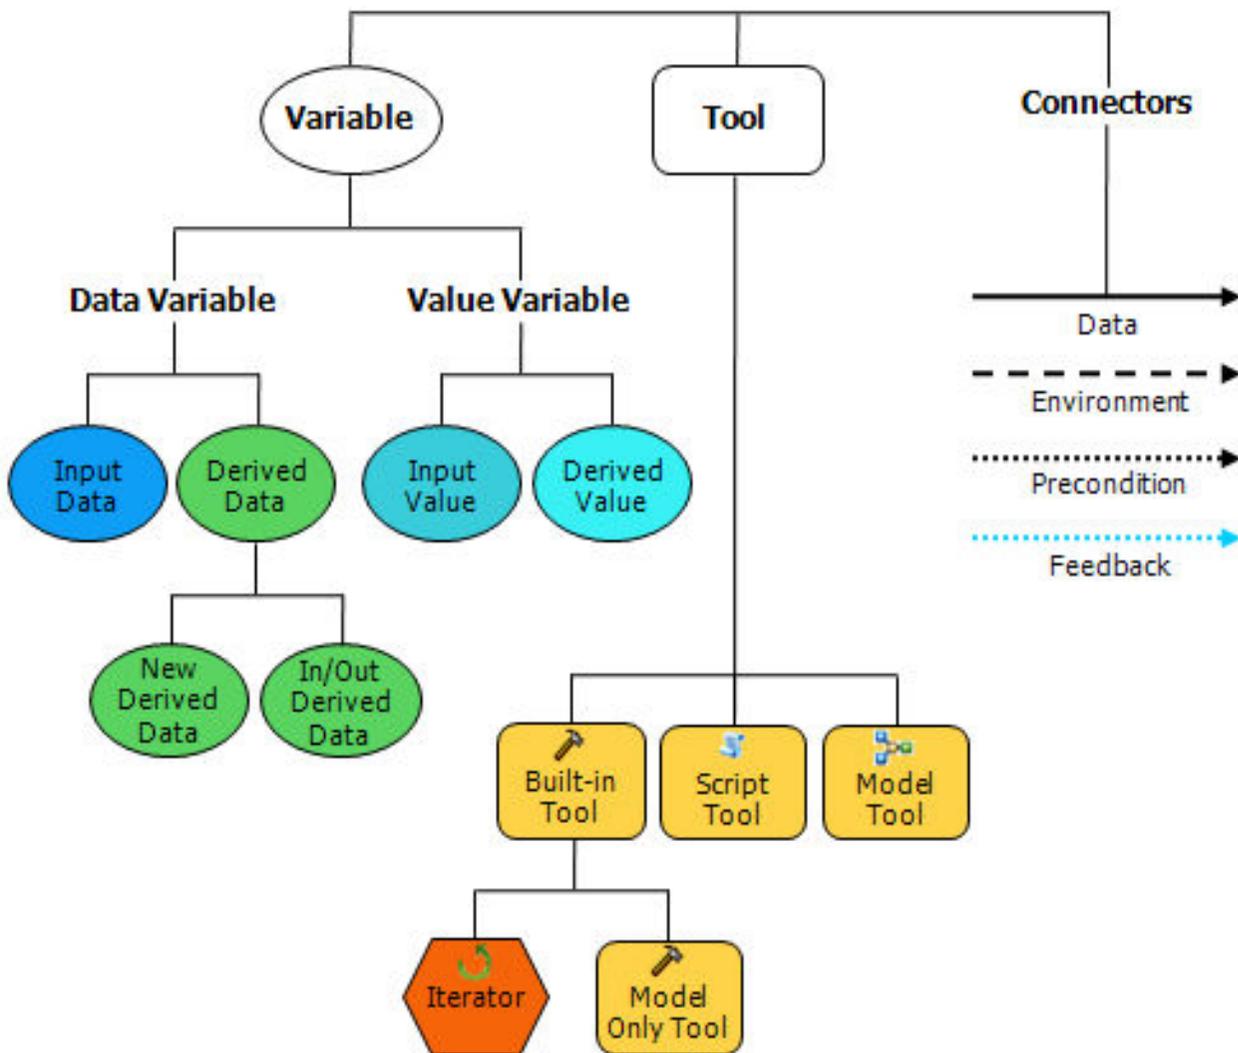
Données (Bruts;
traitées)

Environnement
(Matériel; logiciel)

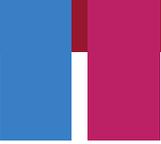
Workflow

Recherche Reproductible

Work flow, Tâches Ordonnées et Automatisées



- Gestion des versions de code
- Documentation
- Automatisation
- Environnements
- FAIR



Exemple de workflow reproductible

Développement du code : Utilisation de Git pour le contrôle de version

Automatisation : Création de scripts pour le traitement des données

Documentation : Rédaction d'un guide utilisateur

Environnements : Déploiement avec Docker

Cycle de vie des données



Data papers et data journals

- Communiquer sur l'existence des données et permettre de les trouver
- Créditer les auteurs (reconnaissance, référence citable) et valoriser les données
- Faciliter la réutilisation des données, en les rendant intelligibles



ScienceDirect

Journals & Books Help Search My account Central College Lyon

Data in Brief
Open access

3.1 CiteScore | 1.2 Impact Factor

Articles & Issues About Publish Search in this journal Submit your article Guide for authors

- Dans un data journal, revue dédiée à ce type de publication
- Dans une revue classique qui publie des data papers en plus des articles traditionnels.
- Éléments communs aux articles classiques et spécifiques liés aux données.

Exemple de structure de data paper

UN ACCÈS AUX DONNÉES

Le data paper fournit l'accès aux données qu'il décrit. Les données peuvent être :

 INTÉGRÉES AU DATA PAPER



Volume 2, March 2015, Pages 42–47



Open Access

Titre : le titre doit se concentrer sur les données spécifiques partagées, ce n'est pas un titre d'article de recherche

Auteur(s) : nom, affiliations, email,...

DOI : <https://doi.org/10.1016/j.dib.2014.12.001>

Type de licence : CC-BY...

Date de l'article : date de soumission de l'article, date de publication, date de validation, date de révision.

Résumé : présentation du contexte d'obtention des données (front de recherche, question de recherche)

Métadonnées :

Domaine de recherche	Physique, chimie, psychologie, etc.
Domaine plus spécifique	Ex : physique nucléaire
Type de données	Tableau, image (radiographie, microscopie...), texte, graphique, figure, etc.
Moyens d'acquisition des données	Microscopie, enquête (vue générale), MEB, RMN, spectroscopie de masse, etc.
Format des données	Brut, filtré, analysé, etc.
Facteurs expérimentaux	Description brève de la préparation des échantillons
Caractéristiques expérimentales	Description expérimentale très brève
Emplacement de source de données	Ville, Pays, coordonnées GPS pour échantillons ou données
Accès aux données	Nom de l'entrepôt, son DOI, ou l'Url directe aux données
Article de recherche lié	Si les données accompagnent un article de recherche, citez-le

Intérêt du jeu de données : décrire la valeur scientifique de ces données

Description des données : décrire brièvement les données partagées

Matériels et méthodes : description complète de la méthode d'obtention des données. Inclure n'importe quelles figures/tables pertinentes à la compréhension des données.

Remerciements

Références : références des données citées.



JOINTES AU DATA PAPER

sous forme de matériel supplémentaire

Transparency document. Supplementary material

 [Download Word document \(1.0KB\)](#) [Help with docx files](#)

Supplementary material

Appendix A. Supplementary material

 [Download text file \(24KB\)](#) [Help with txt files](#)

Supplementary material

Dassou, A. G., Carval, D., Dépigny, S., Fansi, G., & Tixier, P. (2016). Dataset on the abundance of ants and *Cosmopolites sordidus* damage in plantain fields with intercropped plants. *Data in Brief*, 9, 17-23. <http://dx.doi.org/10.1016/j.dib.2016.08.027>



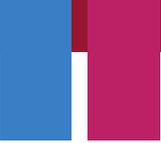
DÉPOSÉES DANS UN ENTREPÔT

auquel cas le data paper fournit l'identifiant pérenne (type DOI) permettant de faire le lien vers l'entrepôt en question.

Specifications table

Subject area	Biology, Microbiology, Mycology, Aspergillus, Fungi
More specific subject area	Experiments of Aspergillus, Fungi
Type of data	List of identified proteins (tab) and figures
How data was acquired	Tandem mass spectrometry (LC-MS/MS) using Thermo Easy nLC 1000 (Thermo, USA) coupled to Orbitrap Velos Pro mass spectrometer (Thermo, USA)
Data format	Raw, analysed and filtered
Experimental factors	High
Experimental features	Experiments prepared from the saprophyte (ATCC26), a spore isolate and five control isolates of <i>A. flavus</i> were pooled and pro-fractionated on 1D SDS-PAGE. Proteins in the gel pieces were processed, subjected to tryptic digestion and the extracted peptides after the cleanup was analyzed in a high resolution mass spectrometer.
Data source location	Aravind Medical Research Foundation, Madurai, India
Data accessibility	The mass spectrometry proteomics data have been deposited to the ProteomeXchange Consortium via the PRIDE partner repository with the dataset identifier PXD001020

Selvam, R. M. et al. (2015). Data set for the mass spectrometry based exoproteome analysis of *Aspergillus flavus* isolates. *Data in brief*, 2, 42-47. <http://dx.doi.org/10.1016/j.dib.2014.12.001>



Rédiger les data papers

Outils pour rédiger les data papers

- Boîte à outils de publication intégrée du GBIF (IPT)
- NephilaPapier
- Outil d'écriture arpha

Critères d'acceptation

- Prend en charge les principes de données FAIR
- les données doivent être collectées à l'aide d'une méthode scientifique et avoir une valeur pour la communauté des chercheurs
- N'acceptera généralement pas les soumissions de descriptions de données qui ont déjà été publiées comme matériel supplémentaire dans un article de recherche original.



Crédits image et sources principales

Formations

- Ecole Centrale de Lyon, A.S.P.I.C.S.
- FUN MOOCS
 - Sorbonne Université, La science ouverte
 - INRIA, Recherche reproductible : principes méthodologiques pour une science transparente
 - INRIA, Recherche reproductible II: Practices and tools for managing computations and data

Ressources en ligne

- <https://mi-gt-donnees.pages.math.unistra.fr/site/guide.html>
- <https://www.recherche-reproductible.fr/>
- <https://www.ouvrirelascience.fr/science-ouverte-donnees-de-la-recherche>
- <https://recherche.data.gouv.fr/fr/page/classes-virtuelles>
- <https://dmp.opidor.fr>
- <https://cat.opidor.fr>
- <https://printempsdeladonnee.fr/calendrier/>
- <https://doranum.fr/>
- <https://www.canal-u.tv/chaines/ad/journee-gitlab/software-heritage-l-archive-universelle-a-la-croisee-des-forges>
- <https://xkcd.com>
- http://corist-shs.cnrs.fr/sites/default/files/ressources/guide_bonnes_pratiques_gestion_donnees_recherche_v2.pdf
- <https://desktop.arcgis.com/fr/arcmap/latest/manage-data/netcdf/fundamentals-of-netcdf-data-storage.htm>
- <https://desktop.arcgis.com/fr/arcmap/latest/manage-data/netcdf/fundamentals-of-netcdf-data-storage.htm>
- <https://www.dgdr.cnrs.fr/bo/2007/12-07/433-bo1207-insdAf-dpAci-res-2007-002.htm>
- https://www.legifrance.gouv.fr/codes/section_lc/LEGITEXT000006074236/LEGISCTA000006129161/
- <https://www.qbif.org/fr/event/7j0sFhaug80CIMqs6aWegK/webinar-introduction-to-data-papers>

GLOSSAIRE DONNEES DE LA RECHERCHE (2/2)

Données de la recherche	Enregistrements factuels (chiffres, textes, images et sons), qui sont utilisés comme sources principales pour la recherche scientifique et sont reconnus par la communauté scientifique comme nécessaires pour la validation des résultats.
Données à caractère personnel	Données concernant une personne physique qui est identifiée ou identifiable, par exemple par corrélation avec d'autres jeux de données.
Éditeurs prédateurs ou revues prédatrices	Éditeurs ou revues ayant des pratiques d'évaluation par les pairs ou des pratiques commerciales et/ou contestables (prix excessifs, contrôle des réutilisations, etc.).
Embargo	Période pendant laquelle une production scientifique ne peut pas être diffusée en accès ouvert.
Publication en accès ouvert	Publication accessible à son lectorat immédiatement et sans restriction d'accès. Son financement peut provenir de subventions publiques ou de sociétés savantes, de paiements par les institutions des auteurs (voir APC), de financement par les bibliothèques universitaires, etc.
Trustworthy Repositories	Criteria for the Selection of Trustworthy Repositories, ils reçoivent le label de certification qui vise à promouvoir des entrepôts de données fiables et durables.
Logiciel	Texte, écrit dans un ou plusieurs langages informatiques, décrivant des calculs destinés à être exécutés par un ordinateur. Il peut prendre diverses formes : fichiers de code, assemblage graphique, formules de tableur, cahier computationnel, etc.
Forge	Environnement de développement logiciel facilitant le travail collaboratif autour d'un projet logiciel. Une forge contient des outils tels que le dépôt versionné de code source, des forums de discussion, un environnement de tests automatisés, etc.

ÉCOLE CENTRALE DE LYON

Je vous remercie pour votre attention.



ÉCOLE
CENTRALE LYON