




Science ouverte et principes FAIR dans un projet de bioinformatique

Comment rendre un projet bioinformatique
plus reproductible ?

Roscoff, 2-6 juin 2025

Charlotte Berthelier, Pauline François,
Thomas Denecker & l'équipe formation de l'IFB



Une présentation sous le signe de l'Open



Attribution - Partage dans les Mêmes Conditions 2.0 France (CC BY-SA 2.0 FR)

This is a human-readable summary of (and not a substitute for) the [license](#), [Avertissement](#).



Vous êtes autorisé à :

Partager — copier, distribuer et communiquer le matériel par tous moyens et sous tous formats

Adapter — remixer, transformer et créer à partir du matériel pour toute utilisation, y compris commerciale.

L'Offrant ne peut retirer les autorisations concédées par la licence tant que vous appliquez les termes de cette licence.



Selon les conditions suivantes :

 **Attribution** — Vous devez [créditer](#) l'Oeuvre, intégrer un lien vers la licence et [indiquer](#) si des modifications ont été effectuées à l'Oeuvre. Vous devez indiquer ces informations par tous les moyens raisonnables, sans toutefois suggérer que l'Offrant vous soutient ou soutient la façon dont vous avez utilisé son Oeuvre.

 **Partage dans les Mêmes Conditions** — Dans le cas où vous effectuez un remix, que vous transformez, ou créez à partir du matériel composant l'Oeuvre originale, vous devez diffuser l'Oeuvre modifiée dans les mêmes conditions, c'est à dire avec la [même licence](#) avec laquelle l'Oeuvre originale a été diffusée.

Pas de restrictions complémentaires — Vous n'êtes pas autorisé à appliquer des conditions légales ou des [mesures techniques](#) qui restreindraient légalement autrui à utiliser l'Oeuvre dans les conditions décrites par la licence.



<https://creativecommons.org/licenses/by-sa/2.0/fr/>

Un contenu trouvable simplement,
accessible, décrit et réutilisable

Les slides

<https://doi.org/10.6084/m9.figshare.29125982>


Le code

https://github.com/IFB-ElixirFr/FAIR_EBAII_n2

DOI 10.5281/zenodo.4800637


Site web

https://ifb-elixirfr.github.io/FAIR_EBAII_n2/



Contexte


De plus en plus de données



Data is the new oil
Clive Humby


Data is the new oil? No: Data is the new soil.
David Mccandless

Quelques chiffres au quotidien



<https://content-technology.com/media-business/domo-releases-12th-annual-data-nevr-sleeps-report/> - 2024

En biologie, c'est pareil !




— Sequences (116.3 trillions) — Bases (19,938.8 trillions)



Number of Submissions

[More](#)



Data deluge en biologie

Type de données	Base de données	Volumes de données
Mesures de l'expression des gènes	ArrayExpress	72 938 experiments 2 429 810 assays 56,68 TB of archived data
Mesures de l'expression des gènes	GEO	5 570 704 échantillons
Structure 3D des protéines	PDB	177 009 Structures
Séquence nucléotidiques	GenBank	241 830 635 séquences et 1 731 302 248 418 bases
Données d'identification ou de quantification des protéines	Pride	580 917 268 spectres de masse
Séquence nucléotidiques (COVID-19)	GISAID (EpiCoV)	15 158 725 séquences virales



MAJ : Mars 2023

Comment ?

Cout



Prix par génome humain



Vitesse




Dans les années 90

4 ans pour le premier milliard de nucléotides du génome humain

Aujourd'hui

Le génome complet en moins de 24h

Pourquoi ? Créer de la connaissance !



Pourquoi générer toujours plus de données ?

Pourquoi ne pas simplement exploiter les données déjà disponibles ?

- La description des données est encore trop souvent incomplète ;
- Les données ne sont pas facilement récupérables ;
- Il n'y a souvent pas de contrôle systématique des erreurs par des experts ;
- Les données ne sont pas générées exactement de la façon souhaitée ;
- Une question de confiance.

Plus il y a de données, mieux c'est !



Conclusion : Plus simple ? Plus rapide ? Plus sûr ?

Une question de confiance

Lin, D., Crabtree, J., Dillo, I. et al. The TRUST Principles for digital repositories. Sci Data 7, 144 (2020).
<https://doi.org/10.1038/s41597-020-0486-7>



Les 3 “R” de la confiance

Souvent utilisées mais souvent confondues
et notamment par la langue (Plessier, 2018)


R

éplicabilité


épétabilité

eproductibilité

Répliquabilité




“L’étroitesse de l’accord entre les résultats individuels successifs obtenus sur le même échantillon soumis à l’essai dans le même laboratoire et dans les conditions suivantes : même analyste, même appareil, même jour ”




<https://doi.org/10.17226/25303>

“Obtaining consistent results across studies aimed at answering the same scientific question, each of which has obtained its own data”

Répétabilité




*“L’étroitesse de l’accord entre les résultats individuels obtenus sur le même échantillon soumis à l’essai **dans le même laboratoire et dont au moins l’un des éléments suivants est différent : l’analyste, l’appareil, le jour**”*



“The measurement can be obtained with stated precision by the same team using the same measurement procedure, the same measuring system, under the same operating conditions, in the same location on multiple trials. For computational experiments, this means that a researcher can reliably repeat her own computation ”

<https://doi.org/10.17226/25303>

Reproductibilité



*“L’étroitesse de l’accord entre les résultats individuels obtenus sur le même échantillon soumis à l’essai dans des laboratoires différents et dans les conditions suivantes : **analyste différent, appareil différent, jour différent ou même jour**”*

“Obtaining consistent computational results using the same input data, computational steps, methods, code, and conditions of analysis”



En résumé


		Data	
		Same	Different
Code	Same	Reproducible	Replicable
	Different	Robust	Generalisable

<https://doi.org/10.6084/m9.figshare.5443201.v1>,

Recommandations pour être reproductible

Description de la partie expérimentale

Méthodes, instruments, procédures, mesures, conditions expérimentales



<https://doi.org/10.17226/25303>

Description de la partie computationnelle

Etapes de l'analyse des données et choix techniques

Description de la partie statistique


Décisions analytiques : quand, comment, pourquoi

Discussion des choix et des résultats obtenus

Et dans les faits ?


Les données face aux ravages du temps

Data Entropy



MISSING DATA

As research articles age, the odds of their raw data being extant drop dramatically.



Vines, T. H. et al. *Curr. Biol.* <http://dx.doi.org/10.1016/j.cub.2013.11.014> (2013).

DataONE


3

Récupérer les données

https://youtu.be/66oNv_DJuPc



Reproduire les données



Kim et al, 2018


<https://dx.doi.org/10.1093%2Fgigascience%2Fqiy077>

En biologie


70 %

des analyses en biologie expérimentale
ne sont
pas reproductibles

Ten Years Reproducibility Challenge : êtes vous capables de refaire vos analyses d'il y a 10 ans ?



Monya Baker, 2016



(Collberg et al. 2015)

La bioinformatique n'y échappe pas...

Impossibilité d'installer des outils


- OS non compatible
- Dépendance plus disponible / plus valide

Mise à jour de l'outil rendant inutilisable les codes

- Python 2 et Python 3 !
- Changement des arguments des fonctions utilisées (R)

Impossibilité de reproduire les résultats de l'analyse computationnelle


- IDE : version stable du langage différente selon l'OS (Rstudio)
- Version des packages



(Perkel, Nature, 2020)



C'est quoi le cycle de vie des données ?



Le modèle de UK Data Archive définit les six étapes suivantes :

- **Création ou collecte des données** (*creating data*) ;
- **Traitement des données** (*processing data*) ;
- **Analyse des données** (*analysing data*) ;
- **Conservation des données** (*preserving data*) ;
- **Accès aux données** (*giving access to data / data discovery*) ;
- **Réutilisation des données** (*reusing data*).

[Une introduction à la gestion et au partage des données de la recherche - Le cycle de vie des données](#)

Comment rendre un projet bioinformatique plus reproductible ?

PARTIE I

Du point de vue de l'analyse des données

Des principes hérités des principes FAIR data


Findable



Accessible



Interoperable



Reusable



Des principes hérités des principes FAIR data



Des principes hérités des principes FAIR data

Facile à trouver (pour l'Homme et la machine)

- Identifiant unique (un DOI par exemple)
- Métadonnées décrivant l'analyse et les outils ; elles sont FAIR, consultables et indexables
- Protocoles d'analyses simples à trouver (GitHub pages)



Des principes hérités des principes FAIR data

Facile à trouver (pour l'Homme et la machine)

- Identifiant unique (un DOI par exemple)
- Métadonnées décrivant l'analyse et les outils ; elles sont FAIR, consultables et indexables
- Protocoles d'analyses simples à trouver (GitHub pages)

Accessible

- Ressources disponibles (GitHub, Dockerhub) et outils tiers *open source* (conda)
- Les métadonnées sont accessibles, même lorsque le logiciel n'est plus disponible



Des principes hérités des principes FAIR data

Facile à trouver (pour l'Homme et la machine)

- Identifiant unique (un DOI par exemple)
- Métadonnées décrivant l'analyse et les outils ; elles sont FAIR, consultables et indexables
- Protocoles d'analyses simples à trouver (GitHub pages)

Accessible

- Ressources disponibles (GitHub, Dockerhub) et outils tiers *open source* (conda)
- Les métadonnées sont accessibles, même lorsque le logiciel n'est plus disponible

Interopérable

- Coopération des outils (snakemake, docker) aussi bien en local que sur serveurs (cloud ou cluster)

R

Des principes hérités des principes FAIR data

Facile à trouver (pour l'Homme et la machine)

- Identifiant unique (un DOI par exemple)
- Métadonnées décrivant l'analyse et les outils ; elles sont FAIR, consultables et indexables
- Protocoles d'analyses simples à trouver (GitHub pages)

Accessible

- Ressources disponibles (GitHub, Dockerhub) et outils tiers *open source* (conda)
- Les métadonnées sont accessibles, même lorsque le logiciel n'est plus disponible

Interopérable

- Coopération des outils (snakemake, docker) aussi bien en local que sur serveurs (cloud ou cluster)

Réutilisable

- Protocole rejouable (snakemake) à l'identique (Jupyter) dans un environnement virtuel (docker)

OPEN

ARTICLE

Introducing the FAIR Principles for research software

Michelle Barker^{1,2}, Neil P. Chue Hong³, Daniel S. Katz⁴, Anna-Lena Lamprecht⁵, Carlos Martinez-Ortiz⁶, Fotis Psomopoulos⁷, Jennifer Harrow⁸, Leyla Jael Castro⁹, Morane Gruenpeter⁹, Paula Andrea Martinez¹⁰ & Tom Honeyman¹¹

Research software is a fundamental and vital part of research, yet significant challenges to discoverability, productivity, quality, reproducibility, and sustainability exist. Improving the practice of scholarship is a common goal of the open science, open source, and FAIR (Findable, Accessible, Interoperable and Reusable) communities and research software is now being understood as a type of digital object to which FAIR should be applied. This emergence reflects a maturation of the research community to better understand the crucial role of FAIR research software in maximising research value. The FAIR for Research Software (FAIR4RS) Working Group has adapted the FAIR Guiding Principles to create the FAIR Principles for Research Software (FAIR4RS Principles). The contents and context of the FAIR4RS Principles are summarised here to provide the basis for discussion of their adoption. Examples of implementation by organisations are provided to share information on how to maximise the value of research outputs, and to encourage others to amplify the importance and impact of this work.

Introduction

In 2016 the publication of "The FAIR Guiding Principles for scientific data management and stewardship"¹ supported a vision where valuable scientific outputs are made FAIR by becoming more Findable, Accessible, Interoperable and Reusable. From the outset, the FAIR Guiding Principles were intended to be applicable to many kinds of digital assets. Increased understanding of the importance of research software in research has catalysed application of the FAIR Guiding Principles to this type of digital asset.

Community-endorsed FAIR principles for research software were released in 2022 by the FAIR for Research Software (FAIR4RS) Working Group (WG), which was jointly convened by the Research Software Alliance (ReSA), Future Of Research Communications and E-Scholarship (FORCE1), and the Research Data Alliance (RDA). This milestone reflects the maturation of the research community in understanding the benefits of having FAIR research software, and coming together as the FAIR4RS WG to achieve this. The FAIR4RS WG is a global and interdisciplinary community whose members share an interest in the application of FAIR principles to research software, such as researchers, software users, developers and maintainers, policy makers, infrastructure support staff, and funders.

The FAIR4RS Principles are relevant to any stakeholder in the research community seeking to increase transparency, reproducibility, and reusability of research. This paper highlights the importance of the FAIR4RS Principles and the positive signals of adoption that demonstrate high levels of community support. It must also be acknowledged that research software and data discoverability is a long-standing challenge and there have

¹Research Software Alliance, QLD 4780, Cairns, Australia. ²Software Sustainability Institute & EPCC, University of Edinburgh, 47 Potterrow, Edinburgh, EH8 9BT, UK. ³NCSA & CS & ECE & School, University of Illinois at Urbana-Champaign, 1205 W Clark St., Urbana, IL, 61801, USA. ⁴Institute of Computer Science, University of Potsdam, An der Bahn 2, 14476, Potsdam, Germany. ⁵Netherlands eScience Center, Science Park 140, 1098 XG, Amsterdam, Netherlands. ⁶Institute of Applied Biosciences, Centre for Research and Technology Hellas, Thessaloniki, 57001, Greece. ⁷ELIXIR Hub, South Building, Wellcome Genome Campus, Hinxton, Cambridgeshire, CB10 1SD, UK. ⁸Semantic Technologies team, ZB MED Information Centre for Life Sciences, Gleueler Strasse 60, 50931, Cologne, Germany. ⁹Software Heritage, Inria, 2 rue Simone Iff, Paris, 75012, France. ¹⁰Research Software Alliance/Australian Research Data Commons, Level 6, Duxing Tower, The University of Queensland, Brisbane, QLD 4072, Australia. ¹¹Australian Research Data Commons, University of Technology Sydney Library, Ultimo, NSW, 2007, Australia.


¹²✉e-mail: michelle@researchsoft.org

Exemple d'utilisation

Plan expérimental

Étude de la réponse à une privation en fer chez l'algue verte *Ostreococcus tauri*


16 échantillons de données RNAseq (triplicat, single-end de 100bp)



(Lelandais *et al.* 2016)

Données réduites pour la démonstration

Analyse de données



Notre question à présent ?

Comment réaliser cette analyse de façon reproductible ?

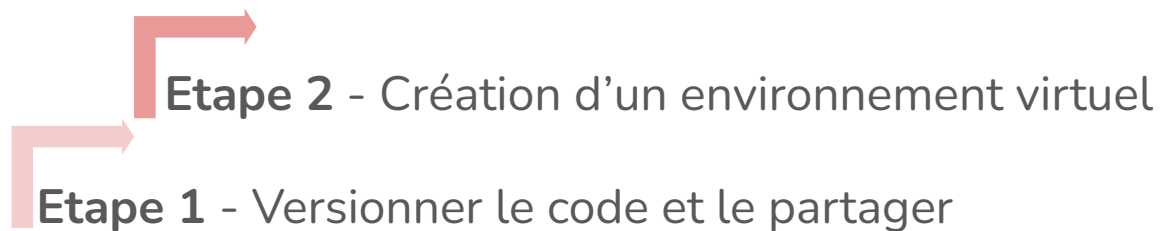
(et pourquoi pas la rejouer en un click!)

Proposition en 7 étapes




Etape 1 - Versionner le code et le partager


Proposition en 7 étapes




Proposition en 7 étapes




Proposition en 7 étapes




Proposition en 7 étapes




Proposition en 7 étapes



Proposition en 7 étapes



Proposition en 7 étapes



Des choix techniques équivalents

GitHub



GitLab



Des choix techniques équivalents

GitHub



GitLab




docker



podman

Des choix techniques équivalents



GitLab




nextflow



podman

Des choix techniques équivalents




Etape 1 - Versionner le code et le partager

Pourquoi ?


- Figer la version du code
- Vision dans le temps
- Partage & ouverture à la communauté



Etape 1 - Versionner le code et le partager



Etape 1 - Versionner le code et le partager




Avantages

- Sauvegarde du code
- Simple pour partager
- Gestion automatique des versions, fusionne les différentes modifications

Inconvénients

- Pas simple pour les novices

Etape 1 - Versionner le code et le partager



Après

IFB-ElixirFr / IFB-FAIR-bioinfo-training

Code Issues Pull requests Actions Projects Wiki Security Insights Settings

master 2 branches 2 tags

Go to file Add file + Code

About

Formation continue sur la FAIRisation du code informatique

IFB-elixirfr.github.io/ifb-fair-bioinfo...

bioinformatics fair

Readme

AGPL-3.0 License

Releases 2

Tess release 8 days ago Latest

1 release

Packages

No packages published

Publish your first package

Contributors 12

Environments 1

github-pages Active

thomasedecker add new links ✓ 92e2188 on 2 Sep 61 commits

File	Description	Commit
docs	add new links	3 months ago
.gitignore	ignore .DS_Store files	3 months ago
images.zip	to unzip for git-github.md	3 months ago
LICENSE	Initial commit	3 months ago
README.md	Update README.md	3 months ago
_config.yml	Set theme jekyll-theme-cayman	3 months ago

README.md

Les principes FAIR appliqués à la bioinformatique

L'Institut Français de Bioinformatique (IFB) organise en partenariat avec l'Institut de Biologie Intégrative de la Cellule (I2BC) une formation à destination des bioinformaticiens et biostatisticiens souhaitant mettre en oeuvre les principes "FAIR" (Facile à trouver, Accessible, Interopérable, Réutilisable) dans leurs projets d'analyse et de développement. Les concepts FAIR, initialement définis dans le contexte d'ouverture des données de la recherche, seront ici adaptés pour cadrer avec un projet type de développement et/ou analyse bioinformatique/biostatistique. Ainsi, la formation n'abordera pas les aspects "FAIR" spécifiques aux données mais introduira plusieurs outils permettant d'améliorer la reproductibilité des analyses.

Pour plus d'informations (programme, slides, ...), un site web de la formation est disponible [ici](#).

Objectifs pédagogiques

A la fin de cette formation, les participants pourront mettre en oeuvre les principes de la science reproductible : encapsuler un environnement de travail, concevoir et exécuter des workflows, gérer des versions de code, passer à l'échelle sur un cluster de calcul, gérer des environnements logiciels et assurer la traçabilité de leur analyse à l'aide de Notebooks.

La formation organisée en deux temps

La formation s'organise en deux temps :

Etape 2 - Création d'un environnement virtuel

Pourquoi ?

- Figurer l'environnement
- Partager l'environnement



Etape 2 - Création d'un environnement virtuel

Avant



Etape 2 - Création d'un environnement virtuel

Avant



Avantages

- Rapide et léger
- Portable
- Simple à partager et déployer

Inconvénients

- Avec un système à jour
- Accepté dans votre structure ?



Etape 2 - Création d'un environnement virtuel

Avant



Après : figé un outil
(R & un package)

```
FROM rocker/tidyverse
```

```
MAINTAINER Thomas DENECKER (thomas.denecker@gmail.com)
```

```
RUN Rscript -e  
'devtools::install_github("PF2-pasteur-fr/SARTools",  
build_opts="--no-resave-data")'
```

Etape 3 - Installation des outils par un gestionnaire

Pourquoi ?

- Avoir la bonne version
- Installer simplement



Etape 3 - Installation des outils par un gestionnaire


Avant : exemple de FastQC

- 1) Télécharger la source
- 2) Décompresser le dossier
- 3) Installer et mettre à jour Java
(nombreux problèmes)
- 4) Changer les droits

Etape 3 - Installation des outils par un gestionnaire

Avant : exemple de FastQC

- 1) Télécharger la source
- 2) Décompresser le dossier
- 3) Installer et mettre à jour Java (nombreux problèmes)
- 4) Changer les droits



Avantages

- Gestionnaire simple à installer
- Installation simple des paquets
- Gestion des versions

Inconvénients


- Peut être lourd (solution miniconda)
- Paquets manquants (R)

Etape 3 - Installation des outils par un gestionnaire

Avant : exemple de FastQC

- 1) Télécharger la source
- 2) Décompresser le dossier
- 3) Installer et mettre à jour Java (nombreux problèmes)
- 4) Changer les droits

CONDA



Après

```
$ conda install -c bioconda -y fastqc=0.12.1
```

Tous les outils utilisés dans le protocole sont disponibles sur Conda (<https://anaconda.org/>) : bowtie2, samtools, htseqcount, aspera, snakemake, ...

Installation simple en une ligne !

Etape 4 - Création d'un script d'analyse

Pourquoi ?

- Avoir un script d'analyse reproductible
- Ne pas refaire ce qui est déjà fait
- Paralléliser



Etape 4 - Création d'un script d'analyse

Avant (script Shell)

```
for sample in `ls *.fastq.gz`  
do  
    fastqc ${sample}  
done
```

Etape 4 - Création d'un script d'analyse

Avant (script Shell)

```
for sample in `ls *.fastq.gz`  
do  
  fastqc ${sample}  
done
```



Avantages

- Workflow (gestion des jobs)
- Puissant et rapide
- Capable d'utiliser des environnements Conda
- Parallélisable sur un cluster

Inconvénients


- Une logique à apprendre
- Syntaxe moins simple que le script shell



Etape 4 - Création d'un script d'analyse

Avant (script Shell)

```
for sample in `ls *.fastq.gz`  
do  
    fastqc ${sample}  
done
```




Après (Snakefile)

```
$ cat > Snakefile  
SAMPLES, =  
glob_wildcards("./samples/{smp}.fastq.gz")  
  
rule final:  
input: expand("fastqc/{smp}/{smp}_fastqc.zip", smp  
=SAMPLES)  
  
rule fastqc:  
    input: "samples/{smp}.fastq.gz"  
    output: "fastqc/{smp}/{smp}_fastqc.zip"  
    message: "Quality check"  
    shell: "fastqc {input} --outdir  
fastqc/{wildcards.smp}"  
$ snakemake
```

Plus court à écrire mais pas à exécuter !

Où en sommes nous ?



Etape 5 - Déporter l'analyse sur un serveur

Pourquoi ?

- Environnement contrôlé
- Déport de l'analyse



Etape 5 - Déporter l'analyse sur un serveur

Avant

Adaptation en local et sur les
serveurs difficile voire non gérée ...

Etape 5 - Déporter l'analyse sur un serveur

Avant

Adaptation en local et sur les
serveurs difficile voire non gérée ... ➡



Avantages

- Simple à mettre en place
- Augmentation de la puissance (cloud ou cluster)
- Pour tout le monde

Inconvénients

- Pas simple pour les novices
- Attention aux données sensibles

Etape 5 - Déporter l'analyse sur un serveur

Avant

Adaptation en local et sur les
serveurs difficile voire non gérée ...  

Après

```
$ git clone  
https://github.com/thomasdenecker/FAIR_Bioinfo  
  
$ cd FAIR_Bioinfo  
  
$ sudo docker run --rm -d -p 80:8888 --name  
fair_bioinfo -v ${PWD}:/home/rstudio  
tdenecker/fair_bioinfo bash ./FAIR_script.sh
```

Le protocole est lancé !

Etape 6 - Portabilité de l'exploration des résultats

Pourquoi ?

- Rendre simple l'exploration
- Simple à partager



Etape 6 - Portabilité de l'exploration des résultats

Avant : Terminal R

```
dds <- DESeqDataSetFromMatrix(countData =  
cts,colData = coldata, design= ~ batch +  
condition)  
  
dds <- DESeq(dds)  
resultsNames(dds) # lists the coefficients  
res <- results(dds, name =  
"condition_trt_vs_untrt")  
  
# or to shrink log fold changes  
# association with condition:  
res <- lfcShrink(dds,  
coef="condition_trt_vs_untrt", type="apeglm")
```

Etape 6 - Portabilité de l'exploration des résultats

Avant : Terminal R

```
dds <- DESeqDataSetFromMatrix(countData =  
cts,colData = coldata, design= ~ batch +  
condition)  
  
dds <- DESeq(dds)  
resultsNames(dds) # lists the coefficients  
res <- results(dds, name =  
"condition_trt_vs_untrt")  
  
# or to shrink log fold changes  
# association with condition:  
res <- lfcShrink(dds,  
coef="condition_trt_vs_untrt", type="apeglm")
```



Avantages

- Portable (HTML)
- Accessible partout
- Interactif (paramétrable, graphes dynamiques, ...)

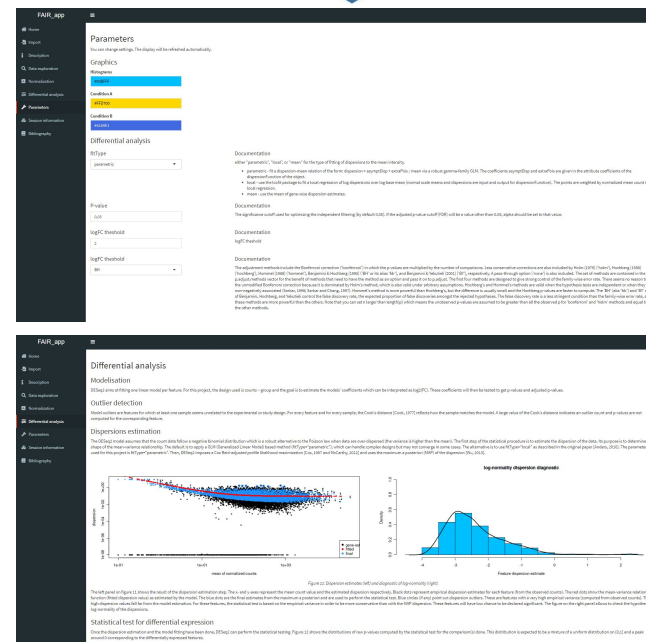
Inconvénients

- Mélange de R et de HTML

Etape 6 - Portabilité de l'exploration des résultats

Avant : Terminal R

```
dds <- DESeqDataSetFromMatrix(countData =  
cts,colData = coldata, design=~ batch +  
condition)  
  
dds <- DESeq(dds)  
resultsNames(dds) # lists the coefficients  
res <- results(dds, name =  
"condition_trt_vs_untrt")  
  
# or to shrink log fold changes  
# association with condition:  
res <- lfcShrink(dds,  
coef="condition_trt_vs_untrt", type="apeglm")
```



Etape 7 - Editer un rapport d'analyse


Pourquoi ?

- Avoir une trace de l'analyse
(date, heure, paramètres, ...)
- Stocker les versions des outils





Etape 7 - Editer un rapport d'analyse

Avant



Etape 7 - Editer un rapport d'analyse

Avant



Avantages



- Syntaxe simple (Markdown)
- Partage (PDF, HTML, ...)

Inconvénients

- Rares problèmes de visualisation en $\text{L}^{\text{A}}\text{T}_{\text{E}}\text{X}$

Etape 7 - Editer un rapport d'analyse

Avant



Après

Statistical report of project Demo: pairwise comparison(s) of conditions with DESeq2

Thomas Denecker

2020-11-12

The SARTools R package which generated this report has been developed at PF2 - Institut Pasteur by M.-A. Dillies and H. Varet (fugovaret@pasteur.fr). Thanks to cite H. Varet, L. Briet-Guilgouen, J.-Y. Coppee and M.-A. Dillies, SARTools: A DESeq2- and EdgeR-based R Pipeline for Comprehensive Differential Analysis of RNA-Seq Data, PLoS One, 2016, doi: <http://dx.doi.org/10.1371/journal.pone.0157022> when using this tool for any analysis published.

1 Introduction

The analyses reported in this document are part of the Demo project. The aim is to find features that are differentially expressed between STANDARD and DEPLETED. The statistical analysis process includes data normalization, graphical exploration of raw and normalized data, test for differential expression for each feature between the conditions, raw p-value adjustment and export of lists of features having a significant differential expression between the conditions.

The analysis is performed using the R software [1], Bioconductor [2] packages including DESeq2 [3,4] and the SARTools package developed at PF2 - Institut Pasteur. Normalization and differential analysis are carried out according to the DESeq2 model and package. This report comes with additional tab-delimited text files that contain lists of differentially expressed features.

For more details about the DESeq2 methodology, please refer to its related publications [3,4].

2 Description of raw data

The count data files and associated biological conditions are listed in the following table.

Table 1: Data files and associated biological conditions.

label	files	Iron
S1	SRR3099587_chr18_ftc.txt	STANDARD
S2	SRR3099586_chr18_ftc.txt	STANDARD
S3	SRR3099585_chr18_ftc.txt	STANDARD
D1	SRR3105699_chr18_ftc.txt	DEPLETED
D2	SRR3105698_chr18_ftc.txt	DEPLETED
D3	SRR3105697_chr18_ftc.txt	DEPLETED


After loading the data we first have a look at the raw data table itself. The data table contains one row per annotated feature and one column per sequenced sample. Row names of this table are feature IDs (unique identifiers). The table contains raw count values representing the number of reads that map onto the features. For this project, there are 7659 features in the count data table.

Table 2: Partial view of the count data table.

	S1	S2	S3	D1	D2	D3
octa01g00010	11	12	11	7	5	1

Conclusion


Quel est notre niveau de reproductibilité ?




Quel est notre niveau de reproductibilité ?




Quel est notre niveau de reproductibilité ?



Quel est notre niveau de reproductibilité ?



Quel est notre niveau de reproductibilité ?




Take home messages

Une vraie réflexion sur la reproductibilité des analyses en Bioinformatique

Proposition d'une solution qui aide à rendre reproductible n'importe quel protocole d'analyse

La reproductibilité est une plus value pour la Bioinformatique !

Un cercle vertueux



FAIR_bioinfo

- Gitlab formations IFB : <https://gitlab.com/ifb-elixirfr/training/fair-bioinfo>
- 2024 : <https://ifb-elixirfr.gitlab.io/training/fair-bioinfo/sessions/2024-10-fair-bioinfo-grand-ouest/programme>
- 2021 : <https://ifb-elixirfr.github.io/IFB-FAIR-bioinfo-training/session2021.html>
- 2020 : <https://ifb-elixirfr.github.io/IFB-FAIR-bioinfo-training/session2020.html>
- 2019 : https://github.com/thomasdenecker/FAIR_Bioinfo

FAIR & le cluster de l'IFB

- Slurm : https://ifb-elixirfr.github.io/IFB-FAIR-bioinfo-training/assets/pdf/Session2020/04_cluster.pdf
- Snakemake + Slurm :
https://ifb-elixirfr.github.io/IFB-FAIR-bioinfo-training/assets/pdf/Session2020/04_tp1_snakemake.pdf
- Docker/Singularity :
https://ifb-elixirfr.github.io/IFB-FAIR-bioinfo-training/assets/pdf/Session2020/04_tp2_singularity.pdf

Données

- Originale : <https://trace.ncbi.nlm.nih.gov/Traces/sra/?run=SRR4026187>
- Réduite : <https://doi.org/10.5281/zenodo.3997237>

Une belle équipe !

2019



T. Denecker C. Toffano-Nioche

2020-2023



C. Hernandez



H. Chiapello



G. Le Corguillé




P. Lieby



Y. Mahmah




J. Seiler



J. van Helden

PARTIE II

Du point de vue des données



Le modèle de UK Data Archive définit les six étapes suivantes :

- **Création ou collecte des données** (*creating data*) ;
- **Traitement des données** (*processing data*) ;
- **Analyse des données** (*analysing data*) ;
- **Conservation des données** (*preserving data*) ;
- **Accès aux données** (*giving access to data / data discovery*) ;
- **Réutilisation des données** (*reusing data*).

[Une introduction à la gestion et au partage des données de la recherche - Le cycle de vie des données](#)

Questions préliminaires

Qu'est ce qu'une donnée de recherche ?

In the context of the OECD Recommendation of the Council Concerning Access to Research Data from Public Funding (OECD, 2006), “research data” are defined as **factual records** (numerical scores, textual records, images and sounds) **used as primary sources for scientific research** and that are **commonly accepted in the scientific community** as necessary to validate research findings. A research data set constitutes a systematic, partial representation of the subject being investigated.

Scientific data are very diverse: they include observational data, which record natural phenomena (in fields such as astronomy, geoscience and demography); **experimental data**, which record the outcomes of man-made experiments, such as laboratory experiments in physics, chemistry and **biology**, or clinical trials; computational data, which are generated through large-scale simulations; and reference data, which are highly curated datasets, such as the human genome.

[OECD-ilibrary.org](https://oecd-ilibrary.org)

Qu'est ce qu'une métadonnée ?

Les métadonnées sont des « données qui décrivent des données » :

- **Information** structurée associée à un "objet", un document ou un jeu de données
- **Documentation** qui permet à l'utilisateur de comprendre, de comparer et d'échanger le contenu du jeu de données décrit

Il existe des **standards** de métadonnées :

- Standards minimaux (ex : Dublin Core)
- Standards métiers (ex : EML, DDI...)

Il est conseillé de produire les métadonnées **au moment de la collecte ou de la création** des données plutôt qu'à posteriori. Les métadonnées seront complétées **tout au long du cycle de vie des données**.

En résumé

Les données



Les métadonnées

Et dans la “vraie vie” ?

Le passé

- Le leg (du doctorant précédent ...)
- La biblio à T0
- Les méthodes pré existantes

Et dans la “vraie vie” ?

Le passé

- Le leg (du doctorant précédent ...)
- La biblio à T0
- Les méthodes pré existantes

Le présent

- Les manip
- La création de connaissance (méthodes, posters ...)

Et dans la “vraie vie” ?

Le passé

- Le leg (du doctorant précédent ...)
- La biblio à T0
- Les méthodes pré existantes

Le présent

- Les manips
- La création de connaissance (méthodes, posters ...)

Le futur

- Le manuscrit
- Les publications

Et dans la “vraie vie” ?

Le passé

- Le leg (du doctorant précédent ...)
- La biblio à T0
- Les méthodes pré existantes

Le présent

- Les manips
- La création de connaissance (méthodes, posters ...)

Le futur

- Le manuscrit
- Les publications

Des échantillons

- dans les frigos
- dans les tiroirs

Et dans la “vraie vie” ?

Le passé

- Le leg (du doctorant précédent ...)
- La biblio à T0
- Les méthodes pré existantes

Le présent

- Les manips
- La création de connaissance (méthodes, posters ...)

Le futur

- Le manuscrit
- Les publications

Des échantillons

- dans les frigos
- dans les tiroirs

Des fichiers

- des petits, des gros
- un peu partout (PC, cloud, cluster)
- des données brutes, du code, des résultats

Et dans la “vraie vie” ?

Le passé

- Le leg (du doctorant précédent ...)
- La biblio à T0
- Les méthodes pré existantes

Le présent

- Les manips
- La création de connaissance (méthodes, posters ...)

Le futur

- Le manuscrit
- Les publications

Des échantillons

- dans les frigos
- dans les tiroirs

Des fichiers

- des petits, des gros
- un peu partout (PC, cloud, cluster)
- des données brutes, du code, des résultats

De la connaissance

- des méthodes, du code
- des systèmes d'information
- des publications

Mais au fait c'est quoi FAIR appliqué aux datas ?


Findable




Accessible



Interoperable



Reusable



Sangya Pundir

Findable -- Faciliter la découverte des données

Findable 

- Les données ont un **PID** (Persistent IDentifier ou identifiant pérenne en français)
- Les données sont décrites par des **métadonnées**
- Ces métadonnées doivent être liées aux PIDs des données
- Les données sont déposées dans un **entrepôt de données**

<https://doranum.fr/enjeux-benefices/principes-fair/>

Accessible -- Permettre l'accès aux données et leur téléchargement

A accessible

- Les données sont accessibles à travers un **protocole de communication standard**
- Ce protocole est **libre et ouvert**
- Ce protocole permet un accès par **authentification** si besoin
- Les **métadonnées restent accessibles** même si les données ne le sont plus

<https://doranum.fr/enjeux-benefices/principes-fair/>

Interoperable -- Permettre l'exploitation des données quel que soit l'environnement informatique utilisé



- Les données sont **décrites avec un vocabulaire contrôlé**
- Le vocabulaire utilisé **respecte les principes FAIR**
- Les **métadonnées** sont reliées à d'autres données

<https://dorum.fr/enjeux-benefices/principes-fair/>


Reusable -- Permettre la réutilisation des données pour de futures recherches



- Les métadonnées ont une **pluralité d'attributs**
- Une **licence de réutilisation** est attribuée aux données
- La description des données indique leur **provenance**
- Le partage des données suit les **standards de la communauté scientifique**

<https://doranum.fr/enjeux-benefices/principes-fair/>

En résumé



<https://dorum.fr/enjeux-benefices/principes-fair/>

En savoir plus

scientific **data**

The FAIR Guiding Principles for scientific data management and stewardship


Wilkinson et al., 2016

<https://doi.org/10.1038/sdata.2016.18>



<https://www.go-fair.org/fair-principles/>

Exemple d'évaluation automatique par FAIR CHECKER



List of metrics with details and results

Principle	Name	Description	Comment	Recommendation	Score	Result	Test	Details
F1A	Unique IDs				2	Success	Check	
F1B	Persistent IDs			To ensure that the used identification scheme is persistent, you should build	0	Failure	Check	
F2A	Structured metadata				2	Success	Check	
F2B	Shared vocabularies for metadata			You should express all your metadata with properties coming from	1	Success	Check	
A1.1	Open resolution protocol				2	Success	Check	
I1	Machine readable format				2	Success	Check	
I2	Use shared ontologies			You should express all your metadata with properties coming from	1	Success	Check	
I3	External links				2	Success	Check	
R1.1	Metadata includes license			You should include information about licence in your metadata using one of the	0	Failure	Check	
R1.2	Metadata includes provenance				2	Success	Check	
R1.3	Community standards			You should express all your metadata with properties coming from	1	Success	Check	

<https://fair-checker.france-bioinformatique.fr>

Thomas Rosnet et al.

Comment gérer les données ?

Comment le gérer ?

Plan de gestion de données



Planifier et
anticiper



Gérer, faire fructifier
et ne pas les perdre



Data is the
new (s)oil !

Les objectifs du PGD

1. **Assurer la reproductibilité des expériences** (comment les données sont obtenues)
2. **Respecter le droit et les personnes** (clarifier le cadre juridique et éthique)
3. **Permettre la réutilisation des données** (Garantir la compréhension des données)
4. **Éviter les pertes de données** (Assurer un stockage adapté)
5. **Établir le rôle de chacun** (Définir les responsabilités)
6. **Clarifier les droits de réutilisation** (Spécifier les modalités de partage)

Un exemple qui finira de vous convaincre : Le Spidergate

NEWS | 07 February 2020 | Clarification [13 February 2020](#)

‘Avalanche’ of spider-paper retractions shakes behavioural-ecology community

Allegations of fabricated data have prompted a university investigation and some soul-searching.

By [Giuliana Viglione](#)



Jonathan Pruitt (McMaster University, CA)

- 1ère alerte en 2020 par Kate Laskowski
- Mise en évidence de nombreuses falsifications dans la donnée brute (patterns de duplications de cellules)
- 19 papiers rétractés dont sa thèse.

→ Manque de publication des données, manque de suivi, manque d'un PGD.


Les outils

Il existe plusieurs outils dont :

DMP OPIDoR Solution nationale



DSW - Data Stewardship Wizard Solution européenne (ELIXIR)




Comment bien décrire les données ?

Bilan de la qualité des métadonnées

Les métadonnées demandées sont différentes entre les bases de données et souvent complexes

La soumission est hétérogène

Les métadonnées sont souvent incomplètes, inconsistantes, redondantes et tout simplement pas assez informatives



Quality of dictionary attributes in NCBI BioSample according to their type, in [Gonçalves et al., 2019](#)

Utilisation de standards

Définition


A standard provides the **requirements, specifications, guidelines or characteristics** that can be used for the **description, interoperability, citation, sharing, publication, or preservation** of all kinds of **digital objects** such as data, code, algorithms, workflows, software, or papers.

source: <https://fairsharing.org/educational/>

Comment trouver le bon ?

Sansone, et al. FAIRsharing as a community approach to standards, repositories and policies.

Nat Biotech. 2019 <https://doi.org/10.1038/s41587-019-0080-8>



Exemple de standard : Genomic standards consortium

Producteur de Minimum Information
Standards utilisés
par l'ENA (EBI) et SRA (NCBI)

Notion de checklists sur l'ENA

<https://www.ebi.ac.uk/ena/browser/checklists>


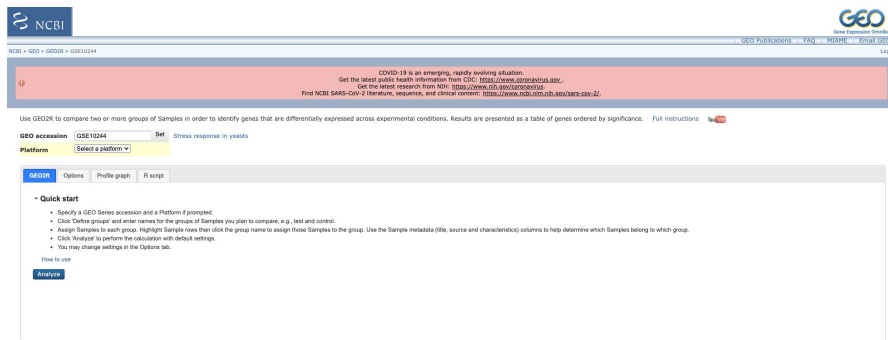
Specification projects	MIGS					MIMS	MIMARKS		New checklists
Checklists	EU	BA	PL	VI	ORG	metagenomes	survey	specimen	e.g., pan-genomes
Shared descriptors	collection date, environmental package, environment (biome), environment (feature), environment (material), geographic location (country and/or sea, region), geographic location (latitude and longitude), investigation type, project name, sequencing method, submitted to INSDC								
Checklist-specific descriptors	assembly, estimated size, finishing strategy, isolation and growth condition, number of replicons, ploidy, propagation, reference for biomaterial					target gene			
Applicable environmental packages (measurements and observations)	Air Host-associated Human-associated Human-oral Human-gut Human-skin Human-vaginal							Microbial mat/biofilm Miscellaneous natural or artificial environment Plant-associated Sediment Soil Wastewater/sludge Water	

Yilmaz et al, 2011


Soumettre les données

Pourquoi soumettre les données et les métadonnées ?

- Pour l'Open Science et la reproductibilité des expériences
- Pour être FAIR et donner accès aux données
- Pour l'archivage
- Pour les publications
- Pour l'analyse avec par exemple MGInfy, GEOtoR, ...



Getting started




Soumission très hétérogène

Par simple fichier Excel



Un peu plus complexe



MAIS

avec une qualité des métadonnées
bien supérieure

Data brokering

Proposer une solution pour fluidifier la soumission des données

Des outils sont proposés dans des branches particulières

L'IFB souhaite offrir une solution nationale divisée en 3 activités

- Développement d'outils
- Formation
- Support aux utilisateurs



Questions juridiques

Quelles obligations de partage des données ?

Les données de la recherche sont des informations publiques :

- Elles sont soumises à un principe d'**ouverture par défaut** et de **libre utilisation** (Loi Lemaire - Loi République numérique 2016 LPRN)
- Elles sont soumises à un **principe de gratuité** (Loi Valter 2015)
 - Cas particulier de Météo France et IGN
 - Spécificité des brevets et autres formes de valorisation
- Elles sont **protégées contre les risques d'accaparement**

Et les principes FAIR ?

Aussi ouvert que possible, aussi fermé que nécessaire

Des exceptions ?

- Le droit d'auteur comme dans les publications scientifiques, logiciels, ...
- Les projets en partenariat avec le privé
- Les données personnelles soumises à la RGPD (sauf avec un consentement, anonymisation ou dérogations)
- Les données sensibles comme la biodiversité (orchidée)
- Secret médical, secret d'affaires, secret militaire, secret des procédés,...

Licence

Moyen d'encadrer le partage et la réutilisation des données

Pas forcément nécessaire mais fortement recommandé dans tous les cas

Liste des licences et explication : <https://www.data.gouv.fr/fr/licences>

Modalité de partage

- Considérer les restrictions, embargo et limites de réutilisation
- Se renseigner sur les obligations de partages spécifiques au bailleurs
- Identifier les jeux de données partageables ou non
- Identifier les futurs utilisateurs
- Déterminer quand partager
- Déterminer où partager en fonction des données, des bailleurs, ...

Exemple d'entrepôts de données

Thématique



Trouver le bon ? <https://www.re3data.org/> ou <https://repositoryfinder.datacite.org/>

Toujours chercher à valoriser les données

Publier un **datapaper**

Publier un **article de recherche** (dans un PCI ?)

Rédiger une brève pour un **magazine** spécialisé

Contribuer à un **blog**,



BMC Research Notes

Open Data Journal for Agricultural Research

Bonnes pratiques


Un environnement de travail sûr

Sauvegardé

Stratégie 3 2 1



3 copies



2 systèmes



dont 1 distante

Protégé

Le stockage

Nombreuses méthodes et technologies de stockage des données

- Disque dur
- Clé USB
- Cloud

Vérifier l'intégrité des données lors de transfert

Il est possible de contrôler l'intégrité des données avec par exemple le **md5sum**

Les fichiers : nommage et format

Nommage

- Bref et explicite
- Sans espace ni caractères spéciaux
- Avec une date au bon format
- Avec l'élément le plus important en premier
- Avec la version du document

Format

Si possible non propriétaire

Les formats qui perdent le moins de données à la conversion

Le format utilisé par la communauté

PUBLIC SERVICE ANNOUNCEMENT:

OUR DIFFERENT WAYS OF WRITING DATES AS NUMBERS CAN LEAD TO ONLINE CONFUSION. THAT'S WHY IN 1988 ISO SET A GLOBAL STANDARD NUMERIC DATE FORMAT.

THIS IS **THE** CORRECT WAY TO WRITE NUMERIC DATES:

2013-02-27

THE FOLLOWING FORMATS ARE THEREFORE DISCOURAGED:

02/27/2013 02/27/13 27/02/2013 27/02/13
20130227 2013.02.27 27.02.13 27-02-13
27.2.13 2013. II. 27. 27/2-13 2013.158904109
MMXIII-II-XXVII MMXIII ^{LVII}CCCLXV 1330300800
((3+3)×(111+1)-1)×3/3-1/3³ 2013 missss
10/11011/1101 02/27/20/13 0 1 2 3 7 2-27-13
5 67 8

<https://xkcd.com/1179/>

Organisation des données

Organisation des dossiers

- Limitez le nombre de dossiers par niveau (5 ou 6 max)
- Allez du général au spécifique
- Choisissez des noms de dossiers explicites

Avec un **README** pour décrire le contenu (txt ou md)

Accompagné d'un bon README (ici une proposition de recherche.data.gouv)

```
<Les textes d'aide sont écrits entre chevrons et sont destinés à être supprimés avant toute sauvegarde>

<Un README : Pourquoi ?

***La documentation d'un jeu de données doit être suffisante pour permettre à n'importe quel réutilisateur
de comprendre et d'évaluer sa qualité. Le README fournit des informations complémentaires et accessibles
lorsqu'elles ne sont pas déjà mises à disposition dans les métadonnées du jeu de données, dans les
métadonnées des fichiers, et/ou dans des fichiers associés, ou des fichiers accessibles à long terme sur
des services d'hébergement (entrepôt de fichiers ou publication). Dans ce dernier cas, nous vous prions
d'inclure les URLs des documents en question ou leurs références***

<Privilégier les formats text document (.txt), ou markdown (.md)>

Modèle de Fichier RDC README --- Général --- Version: 0.1 (2022-11-22)

Ce fichier README a été généré le [YYYY-MM-DD] par [NAME].

Dernière mise-à-jour le : [YYY-MM-DD].

# INFORMATIONS GENERALES

## Titre du jeu de données :

## DOI:

## Adresse de contact :

<Ci-après suit une liste d'éléments suggérés pour vous aider à enrichir, si nécessaire, votre
documentation. La pertinence de certains dépend de la discipline du jeu de données ou du contexte de
production>

<***Supprimer toute section non-applicable***>

# INFORMATIONS METHODOLOGIQUES

## Conditions environnementales / expérimentales :

## Description des sources et méthodes utilisées pour collecter et générer les données :
<Si applicable, décrire les standards, les informations de calibration, les instruments utilisés, etc.>

## Méthodes de traitement des données :
<Si applicable, décrire le traitement des données et inclure tout détail pouvant être important pour
réutiliser ou reproduire les données. Commenter chaque étape.
Par exemple, inclure les méthodes de nettoyage et d'analyse ; les codes et/ou algorithmes ; les procédés
d'anonymisation ou de pseudonymisation pour les données sensibles concernant les humains ou des espèces
menacées>

## Procédures d'assurance-qualité appliquées sur les données :

## Autres informations contextuelles :
<Toute information que vous considérez importante pour évaluer la qualité du jeu de données ou pour sa
réutilisation : par exemple, des informations concernant les logiciels nécessaires pour interpréter les
données.
Si applicable et non-inclus préalablement, ajouter les noms complets et les versions de tous les
logiciels, de tous les paquets et de toutes les bibliothèques nécessaires pour lire et interpréter les
données *e.g.* pour compiler les scripts.>
```

```
# APERÇU DES DONNEES ET FICHIERS

## Convention de nommage des fichiers :

## Arborescence/plan de classement des fichiers :

# INFORMATIONS SPECIFIQUES AUX DONNEES POUR : [NOM DU FICHIER]

<Le cas échéant, reproduire cette section pour chaque dossier ou fichier.
Les éléments se répétant peuvent être expliqués dans une section initiale commune.>

<Pour les données tabulaires, fournir un dictionnaire des données/manuel de codage contenant les
informations suivantes :>

## Liste des variables/entêtes de colonne :

Pour chaque nom de variable ou entête de colonne, indiquer :

-- le nom complet de la variable sous forme "lisible par les humains" ;
-- la description de la variable ;
-- unité de mesure, si applicable ;
-- séparateur décimal "i.e." virgule ou point, si applicable ;
-- valeurs autorisées : liste ou plage de valeurs, ou domaine ;
-- format, si applicable, e.g. date>

## Code des valeurs manquantes :
<Définir les codes ou symboles utilisés pour les valeurs manquantes.>

## Informations additionnelles :
<Toute information que vous jugez utile pour mieux comprendre le fichier>
```

<https://recherche.data.gouv.fr/fr/categorie/33/guide/modele-de-readme>

Et maintenant ?

Vous souhaitez vous former

- Catalogue des formations IFB (PFs et nationales) :
<https://www.france-bioinformatique.fr/formations/>
- Catalogue des formations au niveau ELIXIR/Europe :
<https://tess.elixir-europe.org/events>
- Ressources pédagogiques utiles :
 - <https://doranum.fr/>
 - <https://moodle.france-bioinformatique.fr/course/index.php?categoryid=2>
- Liste des ateliers de la donnée (il y en a peut-être près de chez vous!) :
<https://recherche.data.gouv.fr/fr/ateliers-de-la-donnee>

→ Pour un conseil plus personnalisé, demander gentiment à Lucie (en la payant en chocolat ou en kouignette 😊)

Une belle équipe !



H. Chiapello



T. Denecker



J-F Dufayard




F. de Lamotte



P. Lieby



Y. Mahmah



G Sarah



J. Seiler

Si la reproductibilité vous intéresse ...

Permet d'avoir une vue d'ensemble de la gestion de la reproductibilité dans les autres domaines scientifiques

Revoir les JRFRR 2025 : [Conférence | Canal U](#)

Comment FAIRe ? Et si on essayait !

Création d'un PGD



Titre du projet

EBAIL N2

☒ projet de test, d'entraînement ou à des fins de formation

<https://dmp.opidor.fr/plans/9346>

Choisissez un modèle

Vous pouvez choisir soit un modèle fourni par votre organisme soit par un autre organisme, ou un modèle financeur. Le modèle par défaut est **Science Europe - DMP template (english)**.

Retrouvez la liste des modèles disponibles

CNRS (Votre organisme)

Autre organisme

Financier

Souhaitez-vous utiliser le modèle d'un financeur ?

Agence nationale de la recherche (ANR)

Plusieurs modèles sont disponibles, lequel souhaitez-vous utiliser ?

ANR - Modèle de PGD (français)

Veuillez sélectionner un modèle dans la liste.

Créer un plan

Utiliser le modèle par défaut

Comment reproduire l'analyse ?

The screenshot shows the EBAIL N2 interface. At the top, there's a navigation bar with links like 'Tableau de bord', 'Créer des plans', 'DMPs publics', 'Modèles de DMP', 'Aide', and 'Plus'. Below this is a header with the CNRS logo and the user 'Thomas Denecker'. The main content area is titled 'EBAIL N2' and has a sub-header 'Renseignements sur le projet'. Below this, there's a section '1. Data description and collection or re-use of existing data (2 questions)'. The first question is '3a. What metadata and documentation (for example the methodology of data collection and way of organising data) will accompany the data?'. The answer field contains text about data availability and a link to a GitHub repository. To the right of the answer field, there's a 'Recommendations' section with a list of guidelines for metadata and documentation. Below the first question, there's a second question '3b. What data quality control measures will be used?'. The answer field for this question is empty. To the right of the second question, there's another 'Recommendations' section with a list of guidelines for data quality control measures.

https://github.com/IFB-ElixirFr/FAIR_EBAIL_n2/blob/master/demoFAIR_EBAIL_n2.ipynb

Reproduire l'analyse sur JupyterLab

OPeR
Tableau de bord Créer des plans DMPs publics Modèles de DMP Aide Plus
Français Thomas Denecker

EBAIL N2

Renseignements sur le projet Produits de recherche Modèle choisi Rédiger Partager Demande d'assistance conseil Télécharger

tout développer | tout réduire

1. Data description and collection or re-use of existing data (2 questions)

2. Documentation and data quality (2 questions)

3a. What metadata and documentation (for example the methodology of data collection and way of organising data) will accompany the data?

Science Europe

• Indicate which metadata will be provided to help others identify and discover the data.
• Indicate which metadata standards (for example DOI, TEI, ENL, MARC, CDOI) will be used.
• Use community metadata standards where these are in place.
• Indicate how the data will be organised during the project, mentioning for example conventions, version control, and folder structures. Consistent, well-ordered research data will be easier to find, understand, and re-use.
• Consider what other documentation is needed to enable re-use. This may include information on the methodology used to collect the data, analytical and procedural information, definitions of variables, units of measurement, and so on.
• Consider how this information will be captured and where it will be recorded for example in a database with links to each item, a 'readme' text file, file headers, code books, or lab notebooks.

Les données sont déjà publiées (les métadonnées y sont disponible) :
https://www.ncbi.nlm.nih.gov/assembly/GCF_00214015.3/

Un fichier notebook Jupyter est aussi disponible pour reproduire l'analyse :
https://github.com/IFB-Elisir/journeeAxeBioinfo_2020/blob/main/demoJourneeAxeBioinfo.ipynb

Enregistrer

Répondre 7 minutes ago par thomas.denecker@france-bioinformatique.fr

3b. What data quality control measures will be used?

Science Europe

• Explain how the consistency and quality of data collection will be controlled and documented. This may include processes such as calibration, repeated samples or measurements, standardised data capture, data entry validation, peer review of data, or representation with controlled vocabularies.

Toutes ces informations sont disponible dans l'article.

Enregistrer

Répondre 7 minutes ago par thomas.denecker@france-bioinformatique.fr



OPEN
OnDemand

<https://ondemand.cluster.france-bioinformatique.fr>

Attention, prendre 12 CPUs et 10G de mémoire

Reproduire l'analyse en un click !

Au programme

- Notebook Jupyter (kernel bash)
- Téléchargement des données
- Import des scripts et des fichiers de paramétrage
- Réalisation des l'analyse
 - En parallèle
 - Sur le cluster
 - De façon reproductible
- Exploration préliminaire des résultats

Les principes FAIR appliqués à la bioinformatique

Outils et environnements FAIR pour la bioanalyse

Thomas Denecker - Data brokering - IFB core



Rejouer son article en un click

Cas d'étude

Contexte

L'objectif de l'étude est d'étudier la réponse à une privation en fer chez l'algue verte *Ostreococcus tauri* Lelandais et al, 2016. Il s'agit d'un organisme de 13.0328 Mb séparé en 20 chromosomes.

L'expérience est composée de 16 échantillons de données RNAseq (triplicat, single-end de 100bp). Le plan d'expérience est illustré ci-dessous. Pour accompagner cette démonstration, nous avons choisi les échantillons S11 et S12 (reponse adaptative à long terme,)




Figure 1 | Plan expérimental

Partager ses résultats avec un notebook interactif

Au programme

- Notebook Jupyter (kernel R)
- Import des résultats
- Réalisation d'un tableau explorable avec datatable
- Réalisation d'un volcano plot avec plotly. Lors du survol d'un point, des informations sont retournées

Les principes FAIR appliqués à la bioinformatique

Notebook R interactif pour le partage des résultats

Thomas Denecker - Data brokering - IFB core

Un notebook R interactif

Chargement des packages

```
options(warn=1)
library(plotly)
library(DT)
library(dplyr)
library(plotly)
```

Lectures du tableau de résultats de SARTools

```
dataSartools <- read.csv2("backlog/tables/DEPLETBvsTMM0M0.complete.txt", sep = "\t", header = T, stringsAsFactors = F)
dataSartools <- dataSartools %>%
  filter(log2FoldChange != 0) %>%
  arrange(desc(log2FoldChange)) %>%
  mutate(log2PvalChange = as.numeric(log2FoldChange),
         pvalue = as.numeric(pvalue))
```

Datatable

Documentation : <https://studio.github.io/D/>

```
datatable(dataSartools[, c("ID", "log2FoldChange", "pvalue")], extensions = "Buttons", filter = "top",
           options = list(
             dom = "Bfrip",
             buttons = c('copy', 'csv', 'excel', 'pdf', 'print'),
             pageLength = 5, autoWidth = TRUE
           ))
```

Volcano plot avec Plotly

Documentation : <https://plotly.com/r/>

```
inter = cbind(x = dataSartools$log2FoldChange,
              y = -log10(dataSartools$pvalue),
              pvalue = dataSartools$pvalue,
              feature = dataSartools$ID)

inter = na.omit(inter)
inter = as.data.frame(inter)
inter[,1] = as.numeric(as.character(inter[,1]))
inter[,2] = as.numeric(as.character(inter[,2]))

color = rep("black", nrow(inter))
pos = which(abs(inter[,1]) >= 2 & inter[,2] >= -log10(0.01))
color[pos] = "red"

plot_ly(inter, x = ~x, y = ~y, type = 'scatter', mode = 'markers',
        text = paste("Feature:", feature, "<br>logFC:", x, "<br>pvalue:", pvalue ),
        marker = list(color = color)) %>%
  layout(title = "Volcano plot",
         shapes=list(list(type='line', x0=max(inter[,1]), y0=log10(0.01), y1=log10(0.01), lineDash='dot', width=1)),
         list(type='line', x0=-2, x1=2, y0=0, y1=max(inter[,2], lineDash='dot', width=1)),
         list(type='line', x0=2, x1=2, y0=0, y1=max(inter[,2], lineDash='dot', width=1)),
         list(lineColor = 'blue', title = 'log2(fold change)' ),
         xAxis = list(titleLine = FALSE, title = 'log2(fold change)'))
```

sessionInfo()

Snakemake ou Nextflow ?

Sources :

- <https://academic.oup.com/bib/article/18/3/530/2562749>
- <https://labs.epi2me.io/snakemake-vs-nextflow/>

Même si les deux langages sont assez éloignés, leur fonctionnement et leur intérêt sont très proches.

	Snakemake	Nextflow
Langage	Python	Groovy
Parallélisation automatique des tâches	Oui	Oui
Gestion des noms input/output	Définition explicite	Dénomination automatique
Test du pipeline	Dryrun	Sur un petit jeu de données
Installation	Simple, possible avec conda	Simple, possible avec conda
Communauté	Importante	Importante + Nf-core
Portabilité	Docker et Singularity (Podman en cours d'ajout)	Docker, Singularity et Podman

Il existe de nombreux autres créateur de pipeline, notamment Galaxy qui reste parmi les alternatives les plus utilisées.

Sa plus grande limite est que seul les admins system sont autorisés à y ajouter des outils.

Sources :

- <https://www.ionos.fr/digitalguide/serveur/know-how/podman-vs-docker/>
- <https://phoenixnap.com/kb/podman-vs-docker>

Apparition de Podman

Le support officiel de Docker a été abandonné il y a quelques temps, petit à petit il deviendra inutilisable sur divers système (+ manque de maintenance)

Podman a donc été créé pour contrer cette perte avant tout.

Avantages et inconvénients

	Docker	Podman
Présence d'un daemon	Oui	Non
Démarrage	Classique	Plus rapide
Privilèges	Root	Aucun
Sécurité	Aucune	Plus forte
Compatibilité	Aucune	Avec Docker et autres systèmes de contenerisation
Kubernetes	Non compatible	Compatible

Podman, c'est quoi ?

Comme Docker, c'est une solution de contenerisation légère, pratique et fiable. Elle ne nécessite pas les privilèges root, augmentant sa sécurité. Les commandes de base de Docker sont les mêmes dans Podman (run, build, pull, push, ps, images etc)