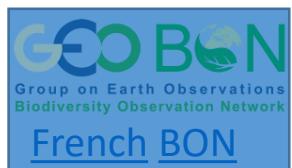
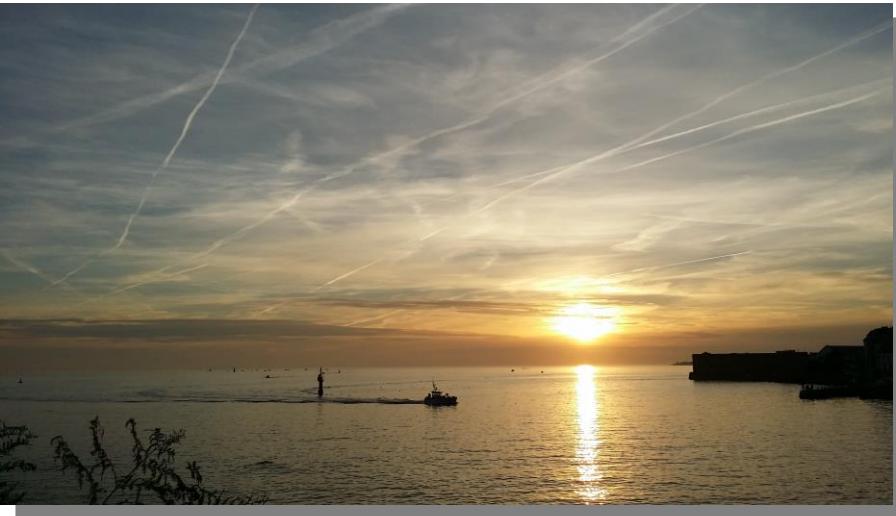


# Pôle national de données de Biodiversité

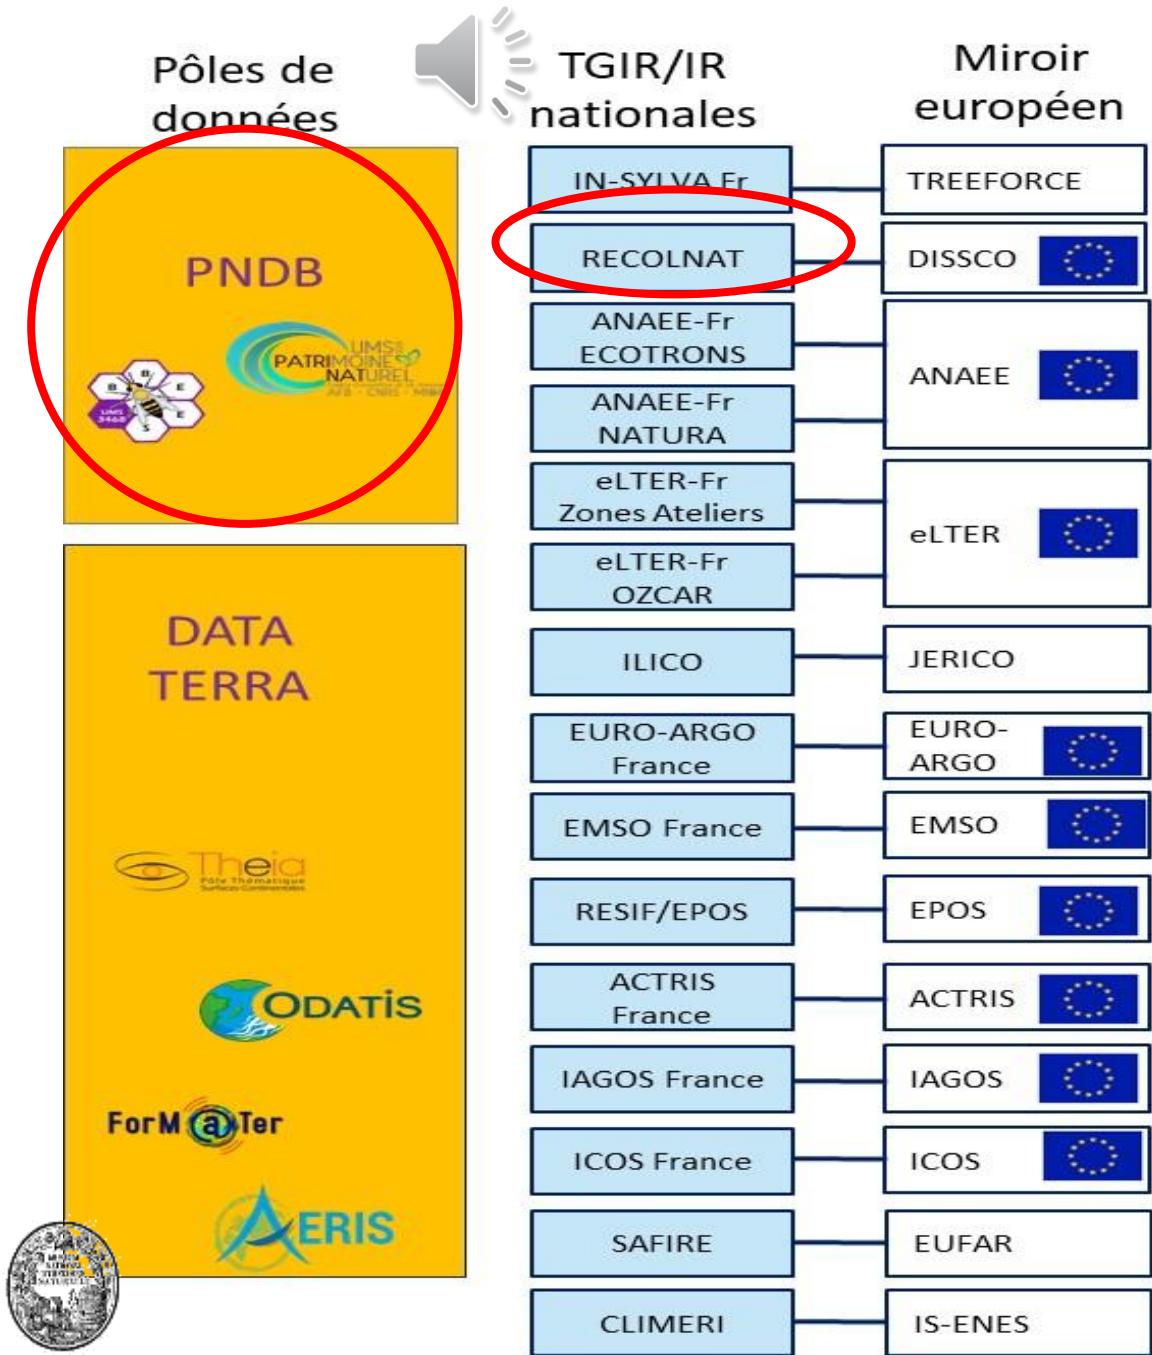
## de la gestion de données à son analyse, présentation des outils et services PNDB



Yvan LE BRAS, Chef de projet (UMS PatriNat)  
Sandrine Pavoine, MNHN (UMR CESCO)  
Anne-Sophie ARCHAMBEAU, GBIF-France (UMS PatriNat)  
Cécile CALLOU, Dir UMS BBEES (CNRS-MNHN)  
Aurélie DELAVAUD (FRB)  
Dominique JOLY, DAS CNRS (INEE)  
Laurent PONCET, Dir. UMS PatriNat, en charge du Centre de données (MNHN)  
Jean-Denis VIGNE, DGD-Recherche, expertise, valorisation, enseignement MNHN

#PNDB @Yvan2935





## Infrastructures du/portées par le Muséum dans le cadre de l'Infrastructure de recherche Terre-Environnement du Ministère de l'Enseignement supérieur, de la Recherche et de l'Innovation

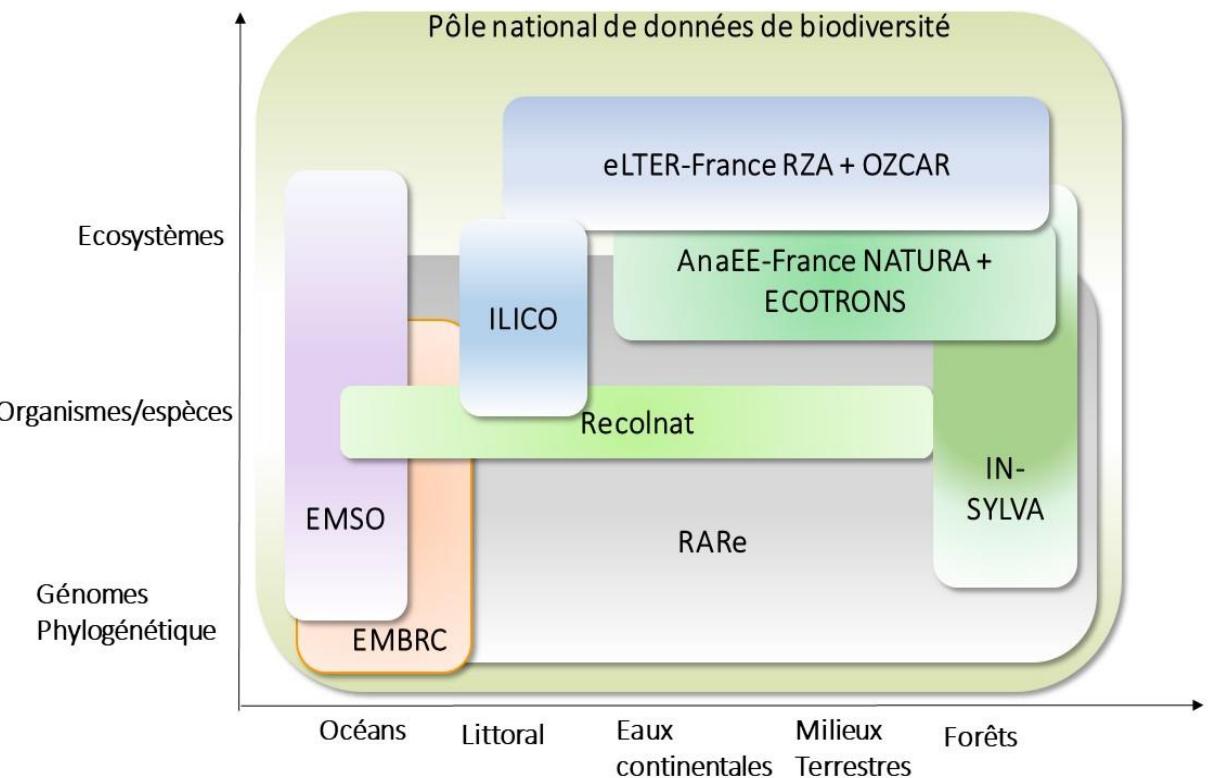


Figure 4: Paysage des infrastructures de recherche françaises dans le domaine de la biodiversité et des écosystèmes. L'encadré orange indique une infrastructure commune avec le domaine « biologie-santé ».

# Le PNDB, e-Infrastructure nationale de recherche

- **Infrastructure numérique** inscrite sur la feuille de route du MESRI depuis mars 2018
- **Consortium maître d'ouvrage :**  
(11 partenaires institutionnels, avec le soutien financier du MESRI)



- **Maître d'œuvre :**  
MNHN depuis mars 2018 (UMS PatriNat)
- **Gouvernance :**
  - Comité de pilotage
  - Conseil scientifique
  - Comité exécutif

# Objectifs du PNDB

1. Contribuer aux recherches concernant l'état et la dynamique de la biodiversité, en tenant compte :
  - De tous niveaux d'organisation du vivant, du génome aux communautés,
  - Des facteurs abiotiques (IR Syst. Terre-Env. : surf. continentale, océans, atmosphère, terre interne),
  - Des pratiques et comportements des sociétés humaines (socio-écosystèmes),
  - Des échelles de temps emboitées (collections d'histoire naturelle, bioarchéologie, paléontologie).
2. Répondre aux besoins des communautés scientifiques au jour le jour:
  - Accéder aux métadonnées et, autant que possible, aux données, adaptées à la question posée (y compris données « expertise »),
  - Faciliter la mise à disposition, la validation et l'analyse des métadonnées/données en dépassant leurs hétérogénéité, dispersion et provenance,
  - Accroître la caractérisation et la fiabilité des données en améliorant la documentation et les formats des métadonnées (équilibre entre « *big data* » et « *quality data* ») ,
  - Favoriser la réutilisation et le couplage des données dans une approche intégrée.
3. Faire progresser la consolidation de toutes les connaissances disponibles sur la biodiversité, au service de la compréhension et de la décision, notamment en promouvant :
  - La bancarisation des données de recherche (information, formation, accompagnement),
  - Les approches intégrées (réutilisation, couplage),
  - L'animation des communautés scientifiques concernées, en lien avec les dispositifs internationaux.

# Stratégie du PNDB

## 1. S'appuyer sur bases de métadonnées/données et systèmes d'information existant :

- en les mettant en relation et en générant des synergies (notamment référentiels et ontologies)
  - en contribuant à renforcer leur visibilité et leur cohérence
    - les uns par rapport aux autres
- GBIF, SINP-INPN, INDOR, SIB-SIMM, SISMER, INFOTERRE...  
 ReCoINat, RARe, AnaEE, RZA...  
 iBOL2...
- 



## 2. Contribuer à étendre l'existant avec d'autres BdD de recherche ou d'expérimentation :

BARcoding, « omiques », communautés, socio-écosystèmes, pressions, temps long...

## 3. Potentialiser les données à travers la mise à disposition d'outils (y compris existant) :

- de traitement/croisement des jeux de données et d'accès aux plateformes de calcul intensif,
- de modélisation (stimulant, en retour, les interactions et la conceptualisation)
- d'aide à la bancarisation (e.g. ajout de métadonnées ; format et correspondance des métadonnées)

## 4. Générer une dynamique d'animation et d'échanges entre chercheurs/communautés :

- en s'appuyant sur l'existant et le valorisant (e-learning GBIF, CES, CESAB...)
- par une stratégie de communication, d'information, de rencontres/colloques
- en sensibilisant toutes les communautés aux enjeux de l'*open data* (FAIR)

## 5. Favoriser la cohérence avec les efforts nationaux, européens et internationaux



Économies pour une Terre dure

LA RECHERCHE AGRONOMIQUE  
POUR LE DÉVELOPPEMENT

dépoussiérez les théories

maîtriser le risque  
pour un développement durable

la science pour la vie, l'humain, la terre

Institut de Recherche  
pour le Développement  
FRANCE

# Cahier des charges du PNDB

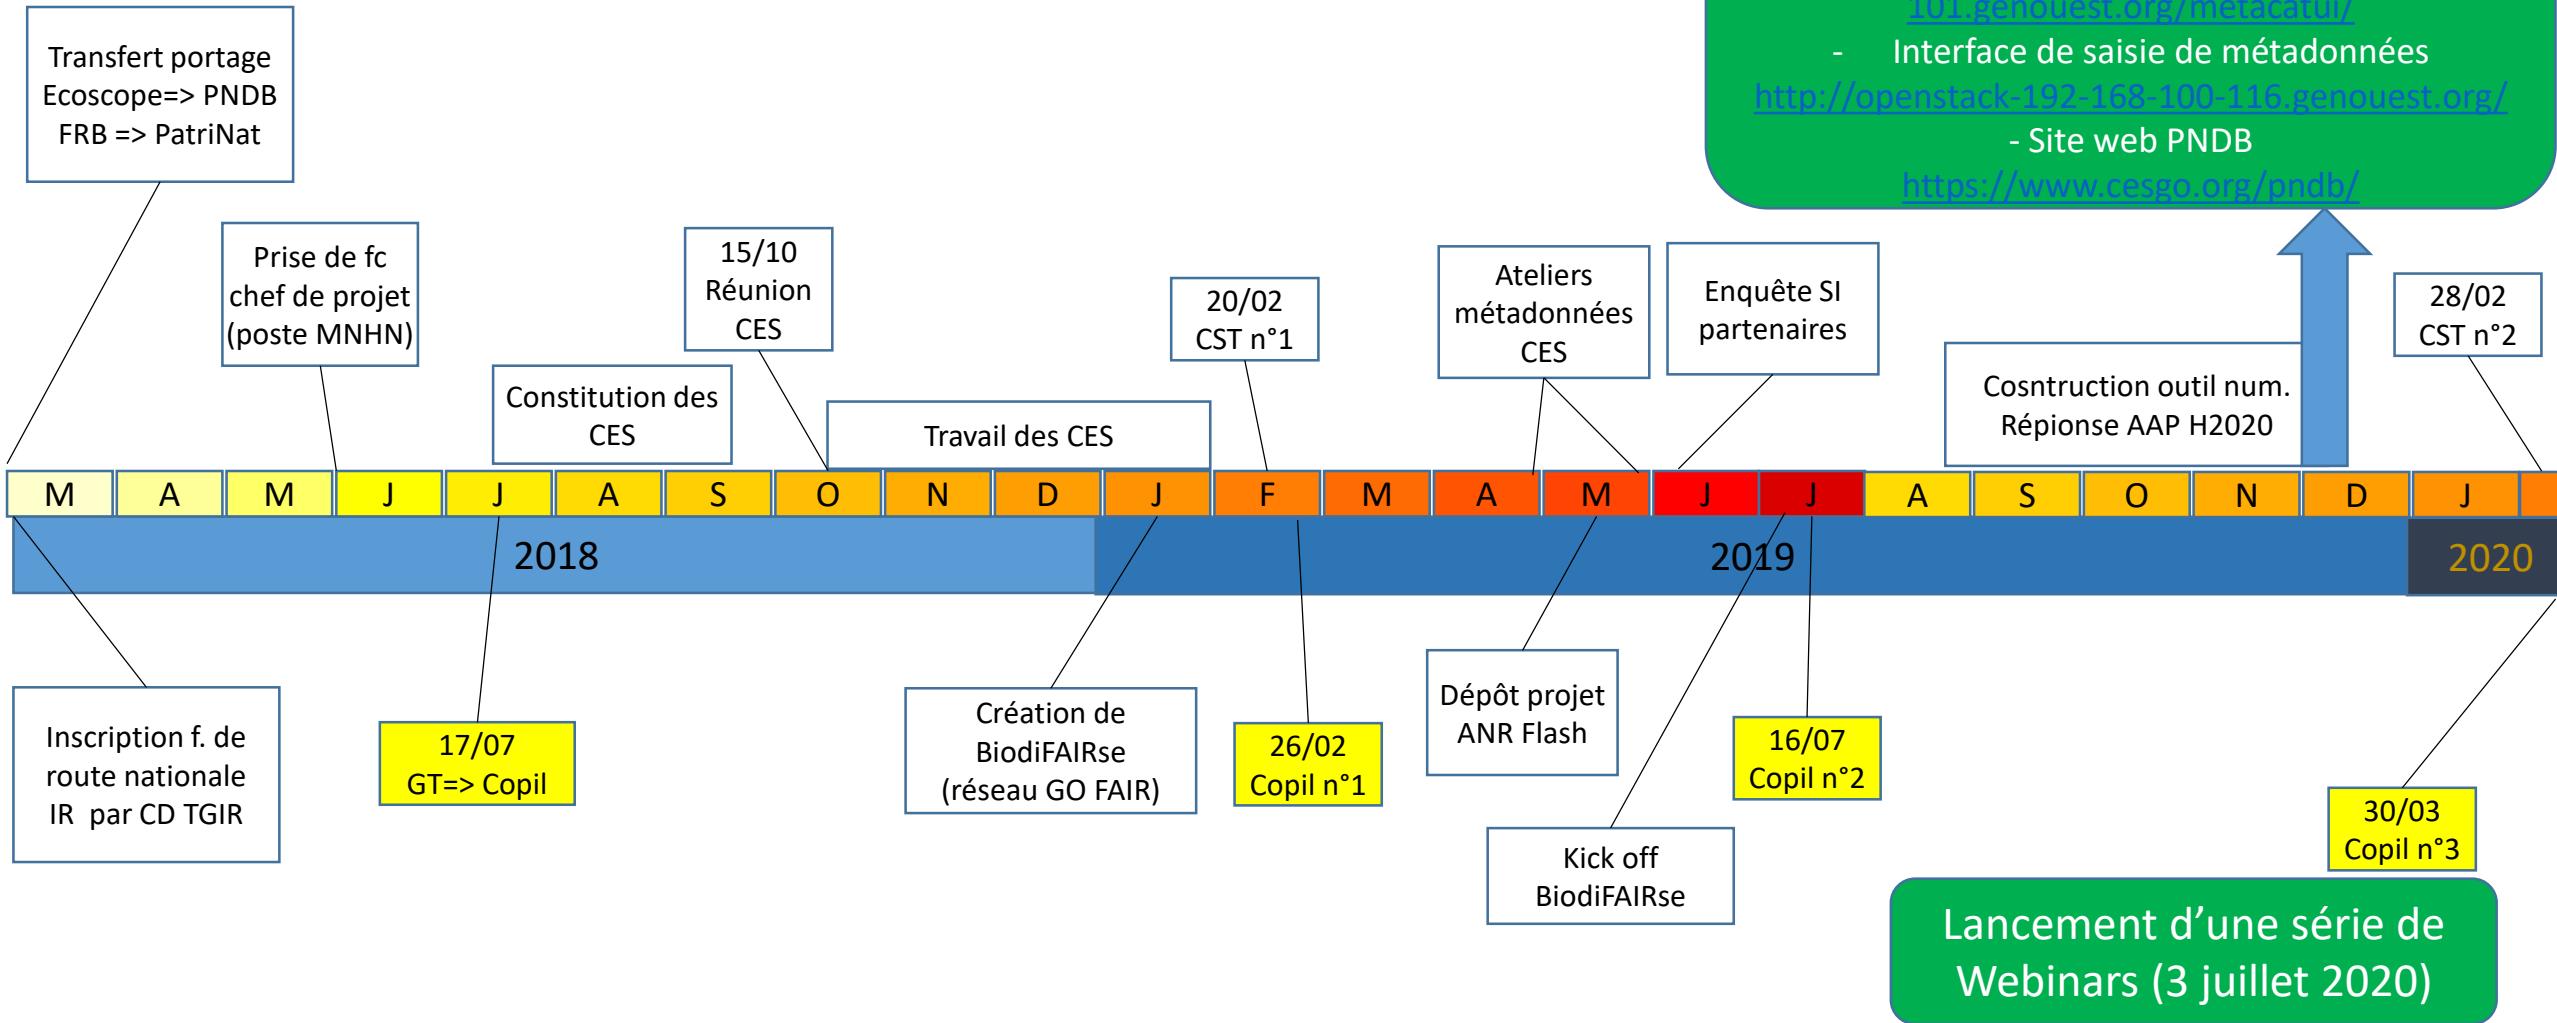
## 10 lignes de force

1. Orientation FAIR (aussi FAIR et *Open* que possible)
2. Relier/mutualiser avec les composantes existantes du Syst. Terre-Env.
3. Articuler/mutualiser avec le SIB-SIMM
4. Offrir des services à valeur ajoutée
5. Privilégier la qualité (*quality data*), au-delà de la quantité (*big data*),
6. Promouvoir la flexibilité des services (« à la carte »)
7. Développer, faciliter et favoriser la description fine des données
8. Viser une portée internationale (couverture & utilisation)
9. Articuler le PNDB avec les initiatives européennes et internationales
10. Pour commencer, s'appuyer sur un petit nombre de cas d'étude  
  
(preuve de concept)

## 3 volets

1. Accès aux métadonnées et données
2. Animation et accompagnement
3. Accès aux outils de traitement, de couplage, d'analyse (calcul)

# Déroulement et réalisations du PNDB



Visitez la version préliminaire du site web du PNDB pour suivre le projet

<https://www.cesgo.org/pnbd/>

PNDB



Outils

Animation

Projets

## Pôle national de données de Biodiversité (PNDB)

*Un pôle de données, e-infrastructure, au service des scientifiques produisant, gérant et analysant des données de biodiversité*

AGENCE FRANÇAISE  
POUR LA BIODIVERSITÉ  
ÉTABLISSEMENT PUBLIC DE L'ÉTAT

brgm  
Géosciences pour une Terre durable



cnrs  
dépasser les frontières

INRA  
SCIENCE & IMPACT



INERIS  
maîtriser le risque  
pour un développement durable

cirad  
LA RECHERCHE AGRONOMIQUE  
POUR LE DÉVELOPPEMENT

FRB  
FONDATION  
POUR LA RECHERCHE  
SUR LA BIODIVERSITÉ

Ifremer

IRD  
Institut de Recherche  
pour le Développement  
FRANCE

irstea

En 2018, le Ministère de l'Enseignement supérieur, de la recherche et de l'innovation a inscrit sur sa feuille de route la création d'une nouvelle infrastructure intitulée Pôle National de données de biodiversité (PNDB). Les missions du PNDB s'inscrivent dans une approche FAIR (Facile à trouver, Accessible, Interopérable, Réutilisable), et consistent à :

Visitez la pré-maquette du portail de données du PNDB et jouez avec les premiers jeux de données-métadonnées  
<https://openstack-192-168-100-101.genouest.org/metacatui/>

The screenshot shows the homepage of the PNDB pre-mockup website. At the top, there is a navigation bar with links for "PNDB", "DONNÉES", "RÉSUMÉ", "A PROPOS", "aller à: DOIx or II Go", and "CONNEXION". Below the header, a large title reads "PÔLE NATIONAL DE DONNÉES DE BIODIVERSITÉ". A subtitle below it states "Un pôle de données au service des scientifiques produisant, gérant et analysant des données de biodiversité". A search bar contains the placeholder text "Exemple: espèces invasives" and a magnifying glass icon. Below the search bar, several logos of partner institutions are displayed, including brgm, cirad, cnrs, FRB, Ifremer, INERIS, INRAe, IRD, Muséum National d'Histoire Naturelle, OFB, and Université Montpellier. At the bottom, a text block discusses the creation of the PNDB infrastructure and its missions.

PNDB DONNÉES RÉSUMÉ A PROPOS aller à: DOIx or II Go CONNEXION

# PÔLE NATIONAL DE DONNÉES DE BIODIVERSITÉ

Un pôle de données au service des scientifiques produisant, gérant et analysant des données de biodiversité

Exemple: espèces invasives

brgm

cirad LA RECHERCHE AGROÉCONOMIQUE POUR LE DÉVELOPPEMENT

cnrs

FRB FONDATION POUR LA RECHERCHE SUR LA BIODIVERSITÉ

Ifremer

INERIS maîtriser le risque pour un développement durable

INRAe

IRD Institut de Recherche pour le Développement FRANCE

MUSÉUM NATIONAL D'HISTOIRE NATURELLE

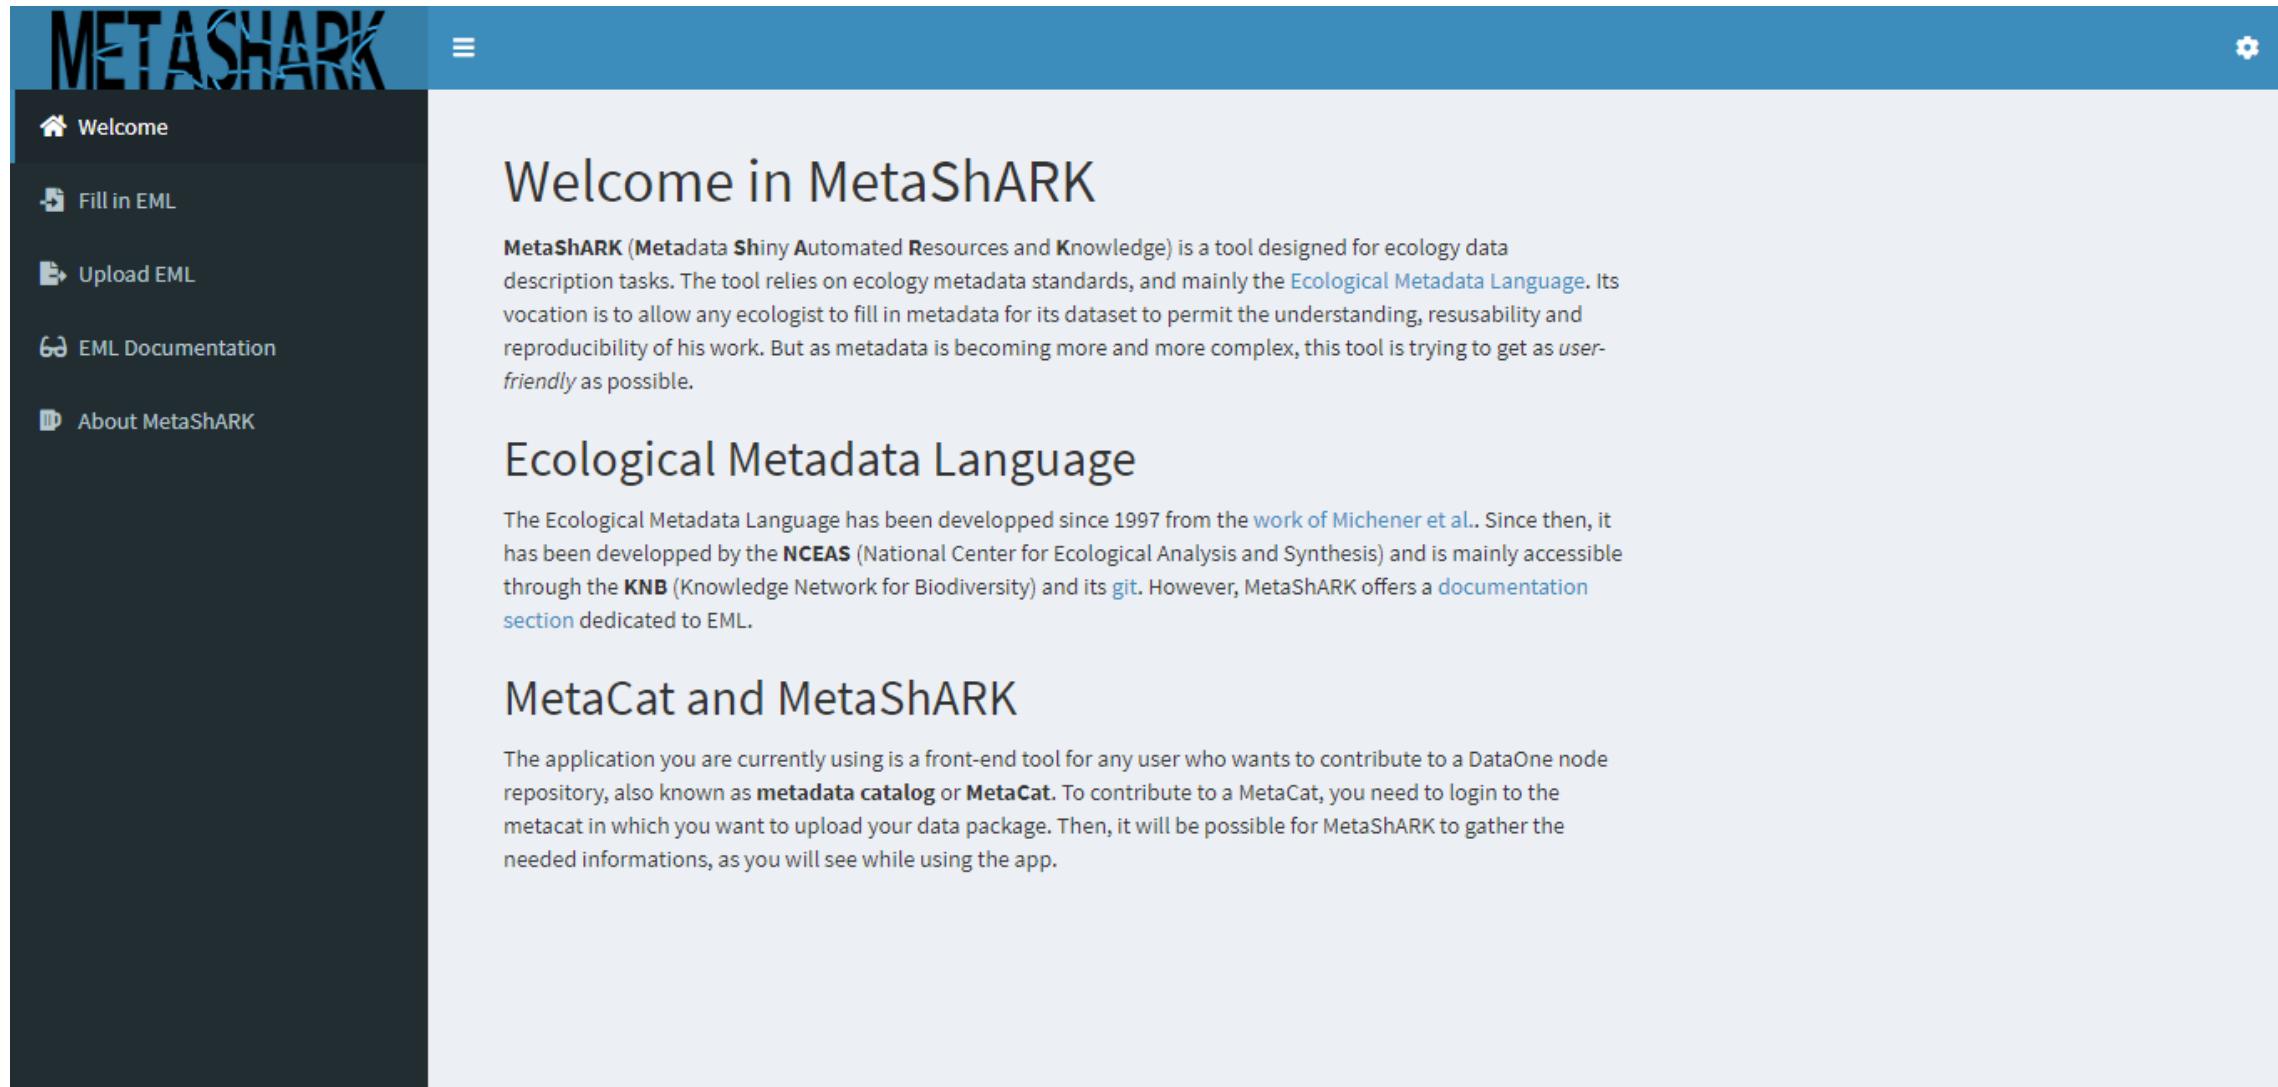
OFB OFFICE FRANÇAIS DE LA BIODIVERSITÉ

UNIVERSITÉ MONTPELLIER

En 2018, le Ministère de l'Enseignement supérieur, de la recherche et de l'innovation a inscrit sur sa feuille de route la création d'une nouvelle infrastructure intitulée Pôle National de données de biodiversité (PNDB). Les missions du PNDB s'inscrivent dans une approche FAIR (Facile à trouver, Accessible, Intéropérable, Réutilisable), et consistent à :

1. fournir un accès aux jeux de données et de métadonnées, à des services associés et à des produits dérivés des analyses
2. promouvoir l'animation scientifique pour identifier les lacunes et favoriser l'émergence de dispositifs portés par des communautés d'utilisateurs et producteurs

Testez l'interface de saisie de données et métadonnées du PNDB  
<http://openstack-192-168-100-116.genouest.org/>



The screenshot shows the MetaShARK application interface. The top navigation bar is blue with the MetaShARK logo on the left and a gear icon on the right. A sidebar on the left contains links: Welcome, Fill in EML, Upload EML, EML Documentation, and About MetaShARK. The main content area has a title "Welcome in MetaShARK". Below it is a paragraph about the tool's purpose: "MetaShARK (Metadata Shiny Automated Resources and Knowledge) is a tool designed for ecology data description tasks. The tool relies on ecology metadata standards, and mainly the Ecological Metadata Language. Its vocation is to allow any ecologist to fill in metadata for its dataset to permit the understanding, resusability and reproducibility of his work. But as metadata is becoming more and more complex, this tool is trying to get as user-friendly as possible." There are three sections below: "Ecological Metadata Language", "MetaCat and MetaShARK", and a summary of the application's purpose.

## Welcome in MetaShARK

MetaShARK (Metadata Shiny Automated Resources and Knowledge) is a tool designed for ecology data description tasks. The tool relies on ecology metadata standards, and mainly the Ecological Metadata Language. Its vocation is to allow any ecologist to fill in metadata for its dataset to permit the understanding, resusability and reproducibility of his work. But as metadata is becoming more and more complex, this tool is trying to get as user-friendly as possible.

## Ecological Metadata Language

The Ecological Metadata Language has been developed since 1997 from the [work of Michener et al.](#). Since then, it has been developed by the **NCEAS** (National Center for Ecological Analysis and Synthesis) and is mainly accessible through the **KNB** (Knowledge Network for Biodiversity) and its [git](#). However, MetaShARK offers a documentation section dedicated to EML.

## MetaCat and MetaShARK

The application you are currently using is a front-end tool for any user who wants to contribute to a DataOne node repository, also known as [metadata catalog](#) or **MetaCat**. To contribute to a MetaCat, you need to login to the metacat in which you want to upload your data package. Then, it will be possible for MetaShARK to gather the needed informations, as you will see while using the app.

Testez la plateforme d'analyse / couplage de données du PNDB <https://ecology.usegalaxy.eu/>

The screenshot displays the Galaxy Ecology interface, showing three main panels:

- Top Left Panel:** A world map with numerous red and blue data points. The map includes a legend for 'None', 'Red', and 'Blue'. Below the map are buttons for 'Export' and 'None'.
- Top Right Panel:** A 'History' panel titled 'treat biodiversity data & tuto GBIF data handling'. It shows 23 items, 16 deleted, and a size of 395.98 MB. Sub-items include '20: Species occurrences' and '13: data 2.GeoJSON'.
- Bottom Left Panel:** A 'Workflow' editor titled 'Complete EBV workflow example from GBIF data'. It shows a complex workflow graph with nodes like 'Count', 'OGR2ogr', 'Wallace', 'RStudio', and 'Ogrinfo'. A tooltip for 'Ogrinfo' is visible at the bottom.
- Bottom Right Panel:** A 'Your workflows' section listing several workflows:
 

Name	Tags	Owner	# of Steps	Published	Show in tools panel
GBIF data Quality check and filtering workflow Oct-2019	#EBVuseable #EBVready	You	11	No	<input type="checkbox"/>
GBIF data Quality check and filtering workflow Jul-2019		You	11	No	<input type="checkbox"/>
wf tuto sdm pretreatment		You	10	No	<input type="checkbox"/>
Workflow constructed from history 'Machine learning test: classification and regression'		You	12	No	<input type="checkbox"/>
Regional GAM workflow		You	10	Yes	<input type="checkbox"/>
Workflow constructed from history 'imported: test vigie-chiro Yves Bas' (imported from uploaded file)		You	4	No	<input type="checkbox"/>

Tutoriels : <https://training.galaxyproject.org/>

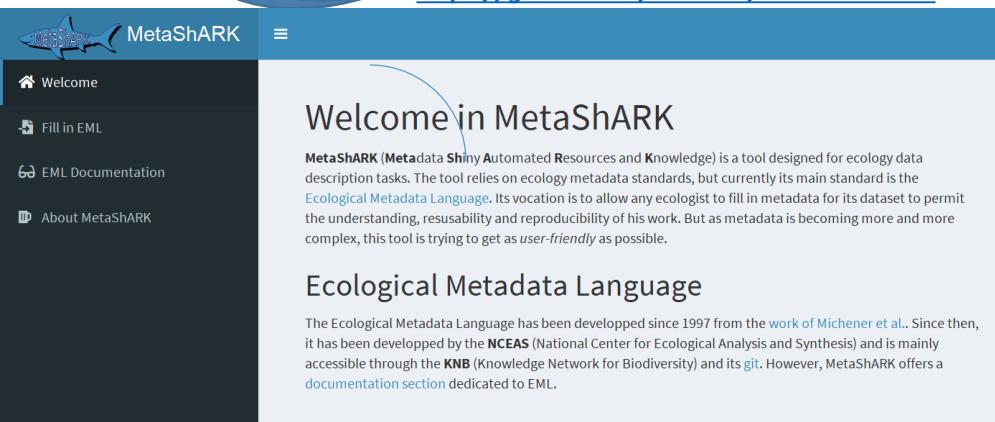
Codes sources : <https://github.com/65MO/Galaxy-E>

<https://github.com/galaxyecology/tools-ecology>

# Le paysage (méta)données via l' *Ecological Metadata Language*

Données + Métadonnées → Datapackage

MetaSHARK  
<https://github.com/earnaud/MetaShARK-v2>



The screenshot shows the MetaShARK interface. On the left, there's a sidebar with links: 'Welcome', 'Fill in EML', 'EML Documentation', and 'About MetaShARK'. The main content area has a title 'Welcome in MetaShARK' and a paragraph explaining the tool's purpose: 'MetaShARK (Metadata Shiny Automated Resources and Knowledge) is a tool designed for ecology data description tasks. The tool relies on ecology metadata standards, but currently its main standard is the Ecological Metadata Language. Its vocation is to allow any ecologist to fill in metadata for its dataset to permit the understanding, resusability and reproducibility of his work. But as metadata is becoming more and more complex, this tool is trying to get as user-friendly as possible.' Below this is a section titled 'Ecological Metadata Language' with a brief description of its history and availability.



The screenshot shows the 'EML Assembly Line' website. It features a large R logo and the text 'EML Assembly Line'. Below it is the URL <https://ediorg.github.io/EMLassemblyline/index.html>. A call-to-action button 'Start the Wizard to Create EML' is prominently displayed.

EML



dataset1

dataset2

script1

article1

protocol1

*GeoNetwork*

SI externes  
- Infrastructures  
- organismes

*Dataverse*

Datapackage



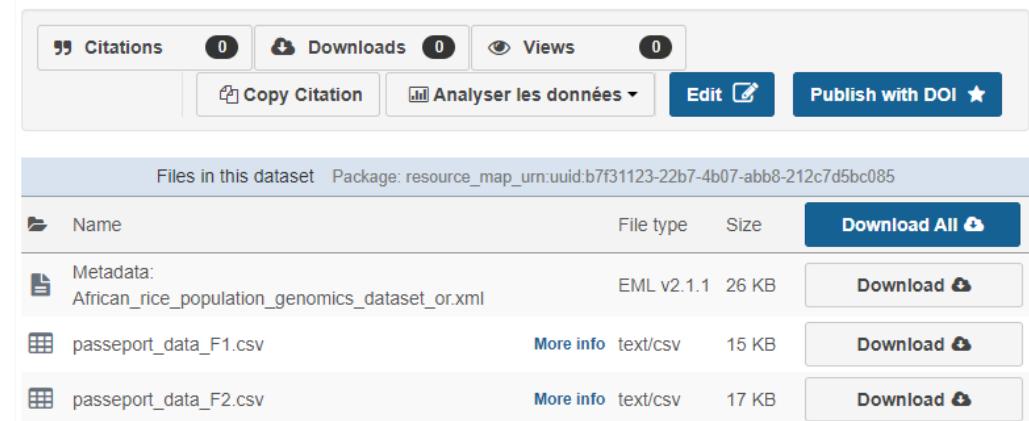
Metacat



The screenshot shows a dataset page from Metacat. At the top, there are tabs: 'PNDB', 'DONNÉES', 'RÉSUMÉ', 'A PROPOS', and 'aller à: DOIx or II Go'. Below the tabs, there's a search bar with 'YVAN LE BRAS' and a profile icon. The main content area displays a summary of a dataset from Institut de Recherche pour le Développement, UMR DIADE, France, involving African rice population genomics. It includes sections for 'Citations', 'Downloads', 'Views', and buttons for 'Copy Citation', 'Analyser les données', 'Edit', and 'Publish with DOI'.

< Back to search | Home / Search / Metadata

Institut de Recherche pour le Développement, UMR DIADE, France, SouthGreen Development Platform, Agropolis Campus, Montpellier, France, Africa Rice Center, Benin, CEA, Institut de Biologie Francais Jacob, Genoscope, Evry, France, CNRS, UMR 8030, Evry, France, et al. 2019. African rice population genomics dataset or title of the article : "The Rise and Fall of African Rice Cultivation Revealed by Analysis of 246 New Genomes". urn:nodenode:METACAT\_TEST. urn:uuid:b004039b-ca27-4719-9df9-f8e785bc2432.



The screenshot shows the 'Files in this dataset' section of Metacat. It lists three files: 'Metadata: African\_rice\_population\_genomics\_dataset\_or.xml' (EML v2.1.1, 26 KB), 'passeport\_data\_F1.csv' (text/csv, 15 KB), and 'passeport\_data\_F2.csv' (text/csv, 17 KB). Each file has a 'Download' button next to it. Above the file list, there are buttons for 'Citations', 'Downloads', 'Views', 'Copy Citation', 'Analyser les données', 'Edit', and 'Publish with DOI'.

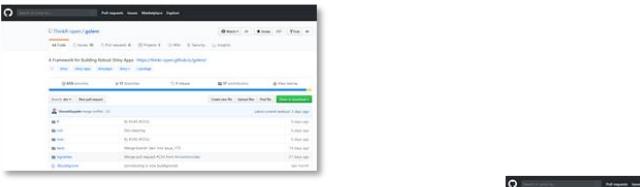
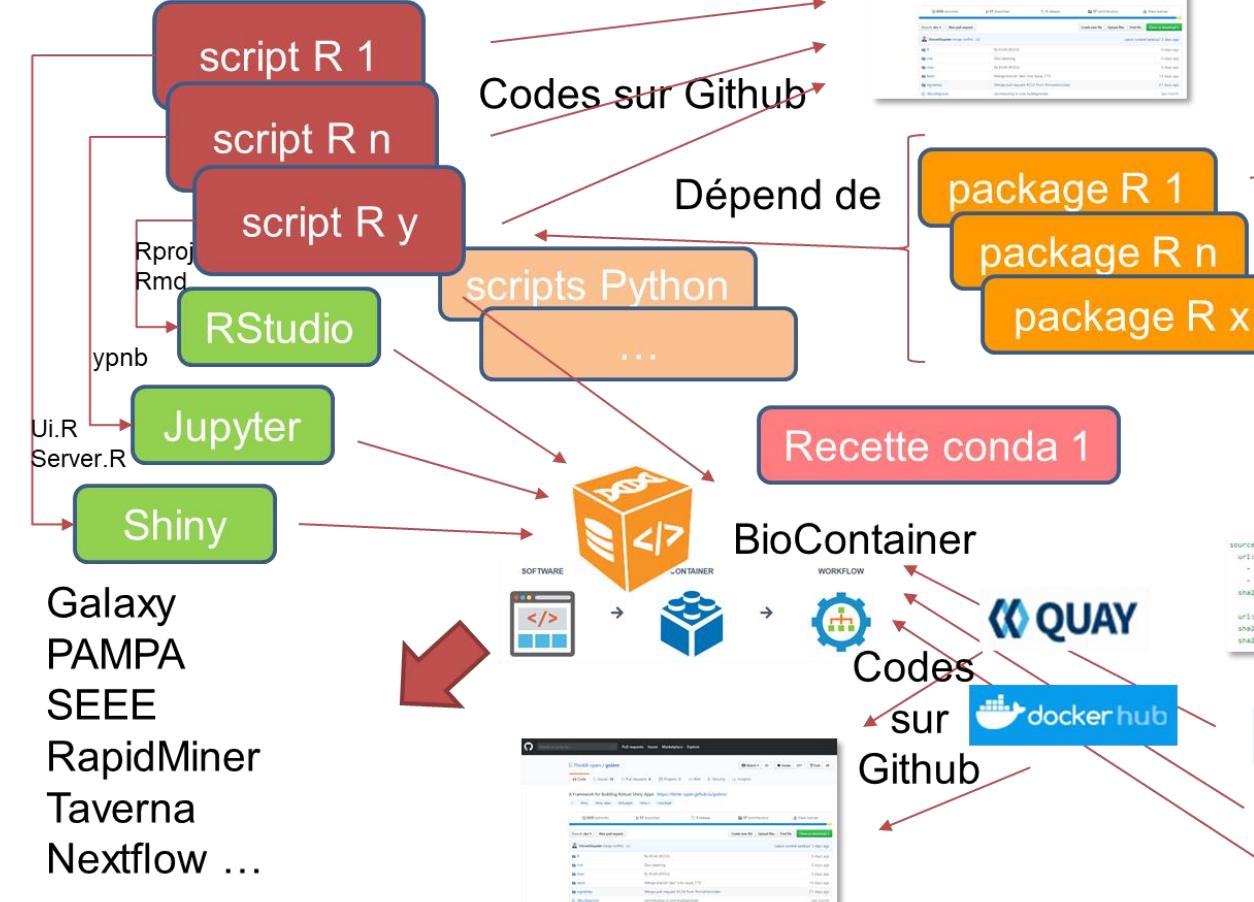
Portail de données métadonnées :

<https://openstack-192-168-100-101.genouest.org/metacatui>

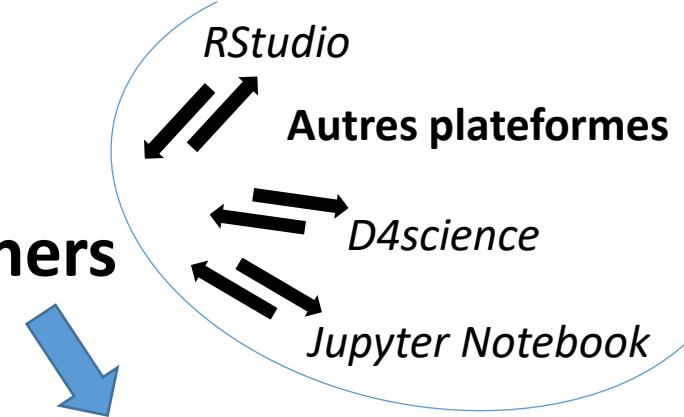
# Le paysage analyse via *Github*, *Conda*, *Containers*, *Cloud* et *Galaxy*

**Codes + dépendances** → **Containers**

## EcoinfoFAIR



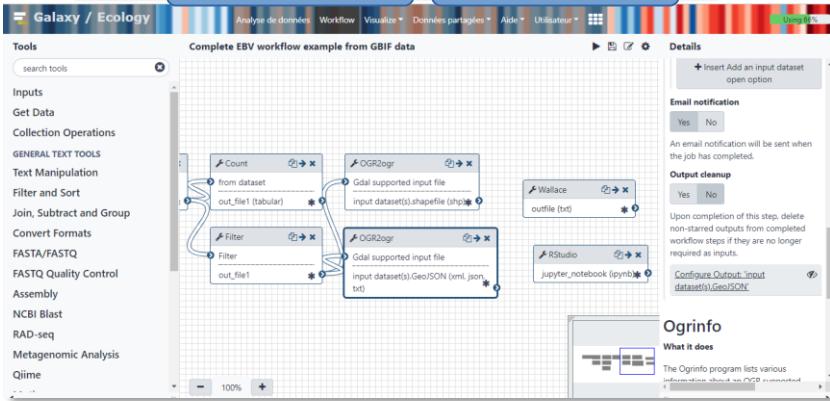
**Containers**



**Machines virtuelles (local ou cloud)**  
**Galaxy**



**Workflows**      **Histories**



# Merci de votre attention



## PNDB team

Coline Royaux - M2 EBE (Galaxy)



Elie Arnaud – Ingénieur R Shiny / métadonnées



Julien Sananikone – Ingénieur DevOps / administration système & réseau / développeur web



Yvan Le Bras

Démo portail de données et métadonnées

<https://www.youtube.com/watch?v=STwsYDHEt2A&feature=youtu.be>

Démo Galaxy Europe

<https://www.youtube.com/watch?v=HeIAHggX6D4&t=268s>