

Infrastructure de recherche PNDDB

(Pôle National de Données de Biodiversité)

Reflexion données/métadonnées

Atelier ODATIS 26 05 2021



Descriptif

**Connaissances relatives à la biodiversité (état, dynamiques, interactions, retro-actions...)
Communautés scientifiques très hétérogènes, peu structurées => données dispersées, hétérogènes**

Partenaires : 9 organismes, 10 Universités, FRB
Portage par le MNHN

Objectifs :

Développer, offrir et mettre en synergie :

- outils et services
- visant description, mise à disposition, validation, analyse et réutilisation des données de biodiversité,

Fonder un cadre scientifique intégratif : temps long, tous milieux, de la molécule aux anthroposystèmes ; pressions anthropiques)

Compléter le dispositif Syst. Terre-Environnement, en lien étroit avec le SIB national porté par OFB/MTE



Science ouverte

Stratégie :

S'appuyer sur l'existant et favoriser :

- pérennité, interopérabilité, ouverture, réutilisation
- croisement de données biodiv / autres (climat, env...)
(sans se substituer aux porteurs de B de données)

Développer la description des jeux de données (métadonnées, « quality data »)

Faire monter les communautés en compétence

S'inscrire dans le paysage complexe des infras au niveau national, européen, international



FAIR

Services :

Accès aux jeux de métadonnées-données

Services et outils associés

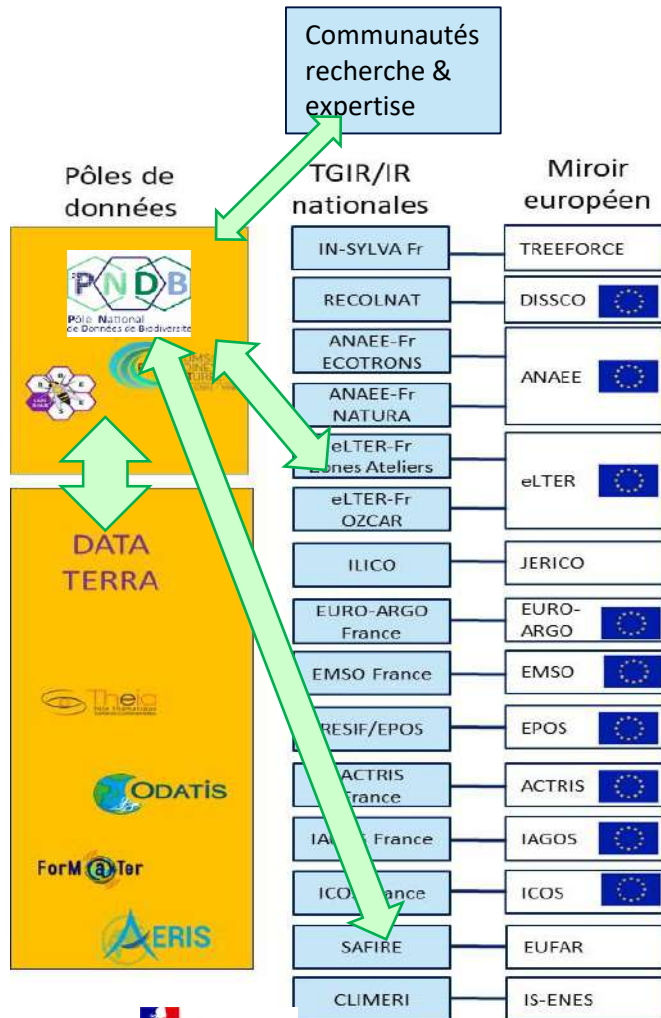
Aide à la bancarisation

Animation des communautés autour de Sci. ouverte

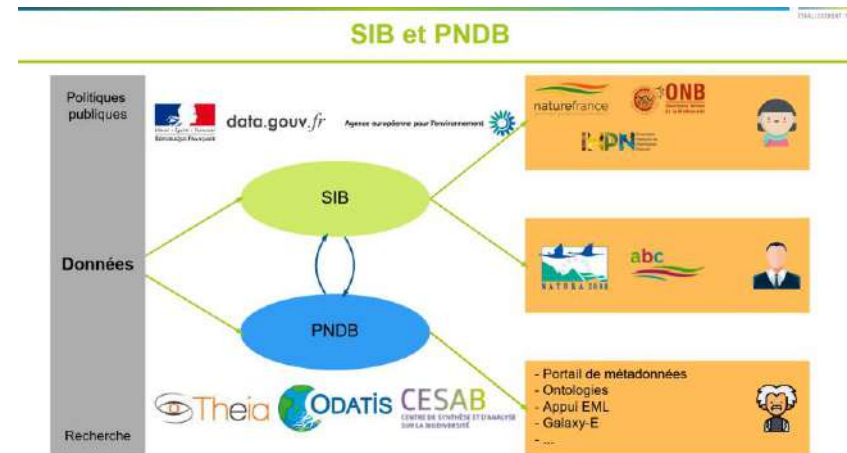
Stimulation des interactions producteurs/utilisateurs

Positionnement à l'échelle nationale

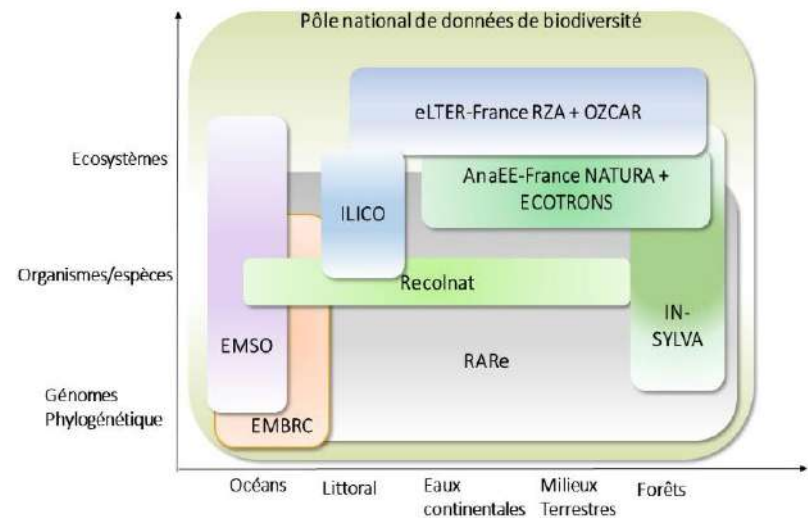
Par rapport aux producteurs de données



Par rapport aux utilisateurs de données



Par rapport aux milieu et aux niveaux biologiques



Services et données

- **Type(s)**
 - Structuration/standardisation de la donnée
 - Avec inférence de métadonnées
 - Métadonnées très fines/détaillées
 - Accès direct à des données ouvertes brutes
 - Analyse/couplage de données hétérogènes sur infrastructure cloud / HPC / distribuée via plateforme ET outils open sources et à fort degré « FAIR »

- **Gestion des données**
 - Conseils sur entrepôts de données les plus pertinents
 - Approche « tout est métadonnée »
 - maDMP (projet Equipex+)
 - Data paper (projet FNSO 2019)

- **Éléments d'ouverture**
 - TOUTES métadonnées et données ouvertes (uniquement licence ouverte Etalab v2 compatible CC-BY 4.0)
 - TOUS les scripts/outils/platformes sous licence ouverte (GNU GPL/MIT/CECILL, ...)
 - 160 codes ouverts pour les outils « [Galaxy Ecology](#) » (PNDB)
 - Plus de 8000 accessibles via l' « [app store](#) » Galaxy



Données et métadonnées du PNDB

Positionnement PNDB

332

WILLIAM K. MICHENER ET AL.

Ecological Applications
Vol. 7, No. 1

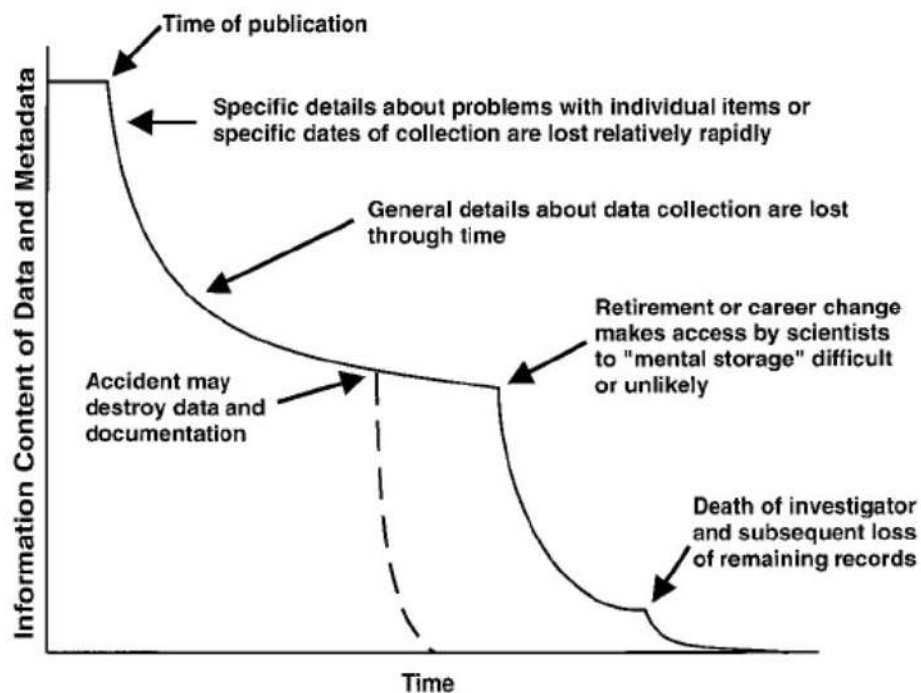
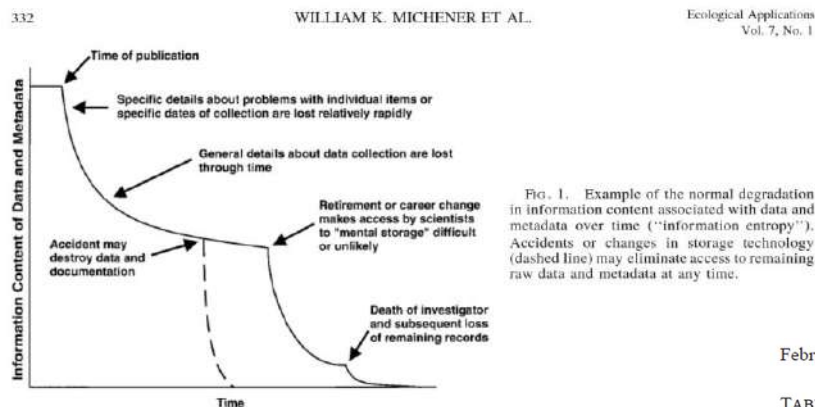


FIG. 1. Example of the normal degradation in information content associated with data and metadata over time (“information entropy”). Accidents or changes in storage technology (dashed line) may eliminate access to remaining raw data and metadata at any time.

Données et métadonnées du PNDB

Positionnement PNDB



NONGEOSPATIAL METADATA FOR THE ECOLOGICAL SCIENCES, Michener *et al.* 1997

February 1997

ECOLOGICAL METADATA

339

TABLE 2. Content of metadata (refer to classes in Table 1) associated with three levels of secondary data utilization.

Metadata descriptor classes	Levels of secondary data utilization and associated metadata content		
	Level I: exchange with expert colleague	Level II: searchable and third party data reuse	Level III: publishable and auditable
I. Data set descriptors	X	X	X
II. Research origin descriptors		X	X
III. Data set status and accessibility		X	X
IV. Data structural descriptors	X	X	X
V. Supplemental descriptors			X

Description des variables

Provenance



Données et métadonnées du PNDB

Positionnement PNDB

Data Table, Image, and Other Data Details

4 sources

2 derivations

Data Table

Entity Name: Total_Aromatic_Alkanes_PWS.csv

Download

Description: Combined dataset from PAH, Alkane and Sample tables documenting samples collected after the Exxon Valdez oil spill in Prince William Sound, AK

Object Name: Total_Aromatic_Alkanes_PWS.csv

Online Distribution Info: <https://cn.dataone.org/cn/v2/resolve/urn:uuid:44108e76-406d-4d58-b1b3-fb4b85e31ff9>

Size: 2601033 byte

Text Format:

- Number of Header Lines: 1
- Record Delimiter: #x0A
- Attribute Orientation: column
- Simple Text
- Field Delimiter: .

Number Of Records: 12142

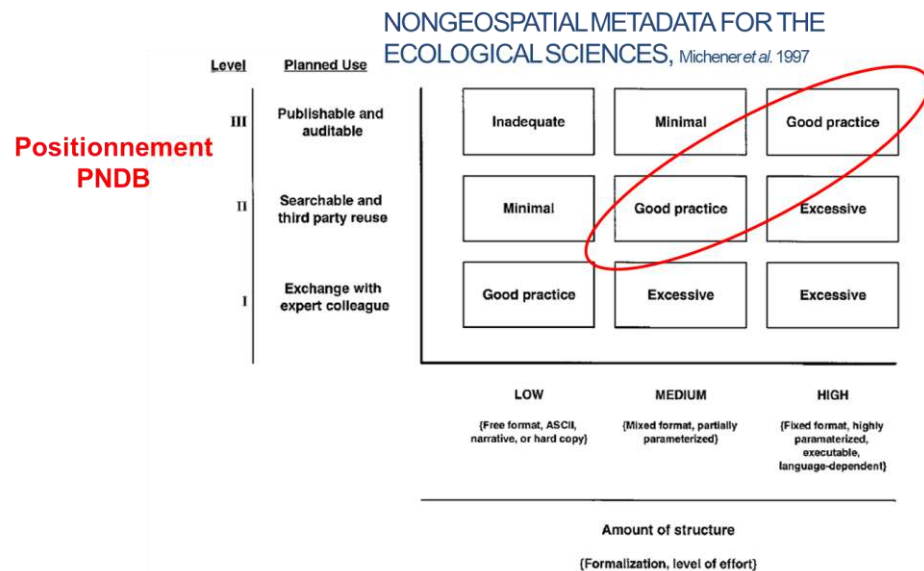


FIG. 3. Degree of metadata format/structure sufficient for three levels of projected secondary data utilization.

Données et métadonnées du PNDB

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

**Mode
single**

Données




Métadonnées



Datapackage




Metacat



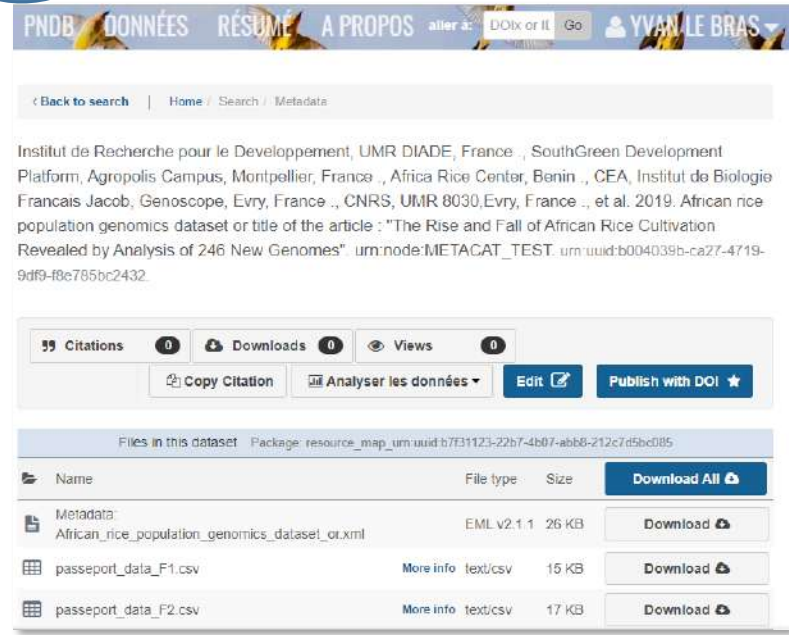
- dataset1
- dataset2
- script1
- article1
- protocol1



EML Assembly Line
<https://ediorg.github.io/EMLassembleline/index.html>



cedarr
 CEDAR R package for API linking in an R interface.
<https://github.com/earnaud/cedarr>



Portail de données métadonnées :
<https://openstack-192-168-100-101.genouest.org/metacatui>
<http://data.test.pndb.fr/data> <https://data.pndb.fr/data>



Données et métadonnées du PNDB

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

Mode batch

Données + Métadonnées enrichies unifiées



MetaSNAKE

API MetaSHARK ?

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

- dataset1
- dataset2
- script1
- article1
- protocol1

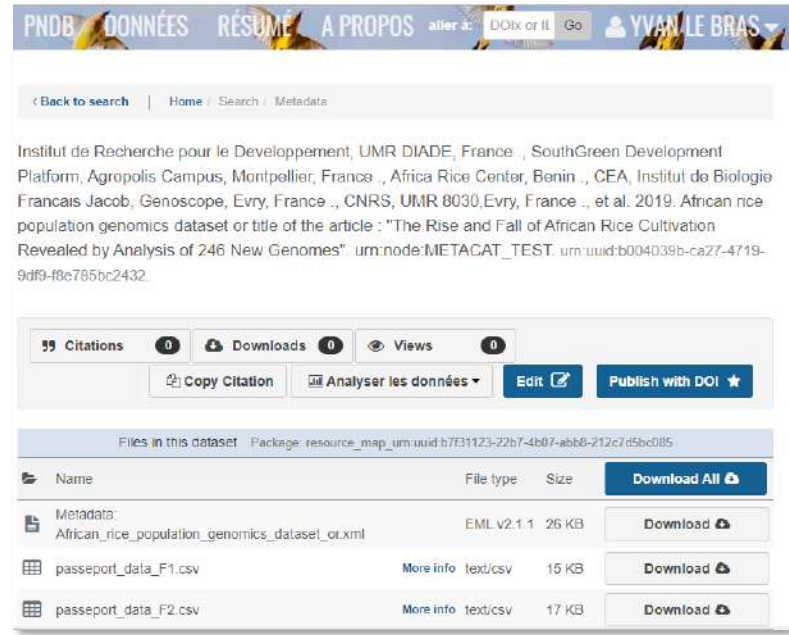
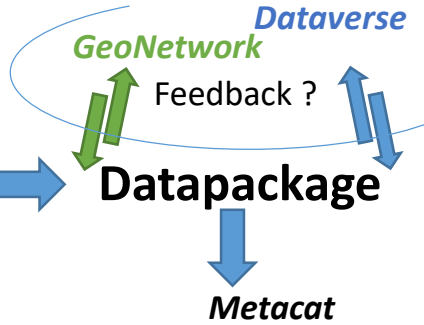
SI externes
- Infrastructures
- organismes

Dataverse
GeoNetwork
Solution à façon

Dublin core, ISO19115,

Métadonnées initiales hétérogènes

Primary variables description
Semantic enrichment
Via EML



Portail de données métadonnées :
<https://openstack-192-168-100-101.genouest.org/metacatui>
<https://data.test.pndb.fr/data> <https://data.pndb.fr/data>



Standardisation par la métadonnée vs par un standard de données

- **Pour faciliter l'accès aux données brutes par tous types d'acteurs**
 - Les participants aux atlas de la biodiversité communale n'ont pas accès à la donnée, ou que une partie filtrée après passage par SI d'association puis SI politique publique
- **Pour faciliter le calcul d'indicateurs de Biodiversité**
 - On ne peut pas se contenter de données d'occurrence ou de présence seule pour les calculs d'indicateurs à l'échelle des communautés ou écosystèmes
- **Problème du fait que un standard de données peut obliger à contraindre / modifier le sens d'une variable primaire**
 - Pour certaines données de recherche notamment, il faut rentrer dans le cadre même si la correspondance est pas parfaite