



HAL
open science

Les Plans de Gestion des Données entités

Jean-François Dufayard, Paulette Lieby

► **To cite this version:**

Jean-François Dufayard, Paulette Lieby. Les Plans de Gestion des Données entités. Printemps de la Donnée 2024, INRAE; Université Haute-Alsace; Université de Strasbourg; INSA; PNDB; AgroParis-Tech; Université de Lille; Sorbonne Université; Data Terra, Jun 2024, Paris, France. 10.5281/zenodo.12205835 . hal-04683415

HAL Id: hal-04683415

<https://hal.inrae.fr/hal-04683415>

Submitted on 2 Sep 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution 4.0 International License

Les Plans de Gestion des Données *entités*

Contribution aux supports: Paulette Lieby (IR) - 

Jean-François Dufayard (chercheur) -  cirad



INSTITUT FRANÇAIS DE BIOINFORMATIQUE
Infrastructure nationale en biologie et santé
Centre de référence thématique
pour Recherche Data Gouv

De quoi parle-t-on ? Un peu de sémantique



Un PGD, en bref

PGD :

- Plan de Gestion des Données
- Pour Générer du Dialogue © Frédéric de Lamotte

Définir une **stratégie concertée** de gestion des données, le long de leur **cycle de vie**, dans le cadre d'un **projet** ou d'une **entité pérenne** gérant des données.

Ce que n'est pas un PGD

Macro gouvernance

→ Les lois nationales, internationales

Ce que n'est pas un PGD

Macro gouvernance

→ Les lois nationales, internationales

Micro gouvernance

→ Politiques de données (des tutelles, des communautés identifiées)

Ce que n'est pas un PGD

Macro gouvernance

→ Les lois nationales, internationales




Micro gouvernance

→ Politiques de données (des tutelles, des communautés identifiées)



Ce qu'est un PGD et sa situation



Méso gouvernance

→ Le plan de gestion: notre degré de liberté



Ce qu'est un PGD et sa situation



Attention: parfois on veut forger l'enclume

À la lumière des PGD entités, on veut éclairer la micro gouvernance

PGD projet ? PGD structure ? PGD entité ????

PGD projet : une stratégie de gestion, sur la durée d'un projet, mais traitant aussi des données froides, voir de l'archivage... un plan de gestion à **durée déterminée**

PGD entité (anciennement structure) : une stratégie de gestion, sur une entité pérenne (plateforme, laboratoire...), un plan de gestion à **durée indéterminée**

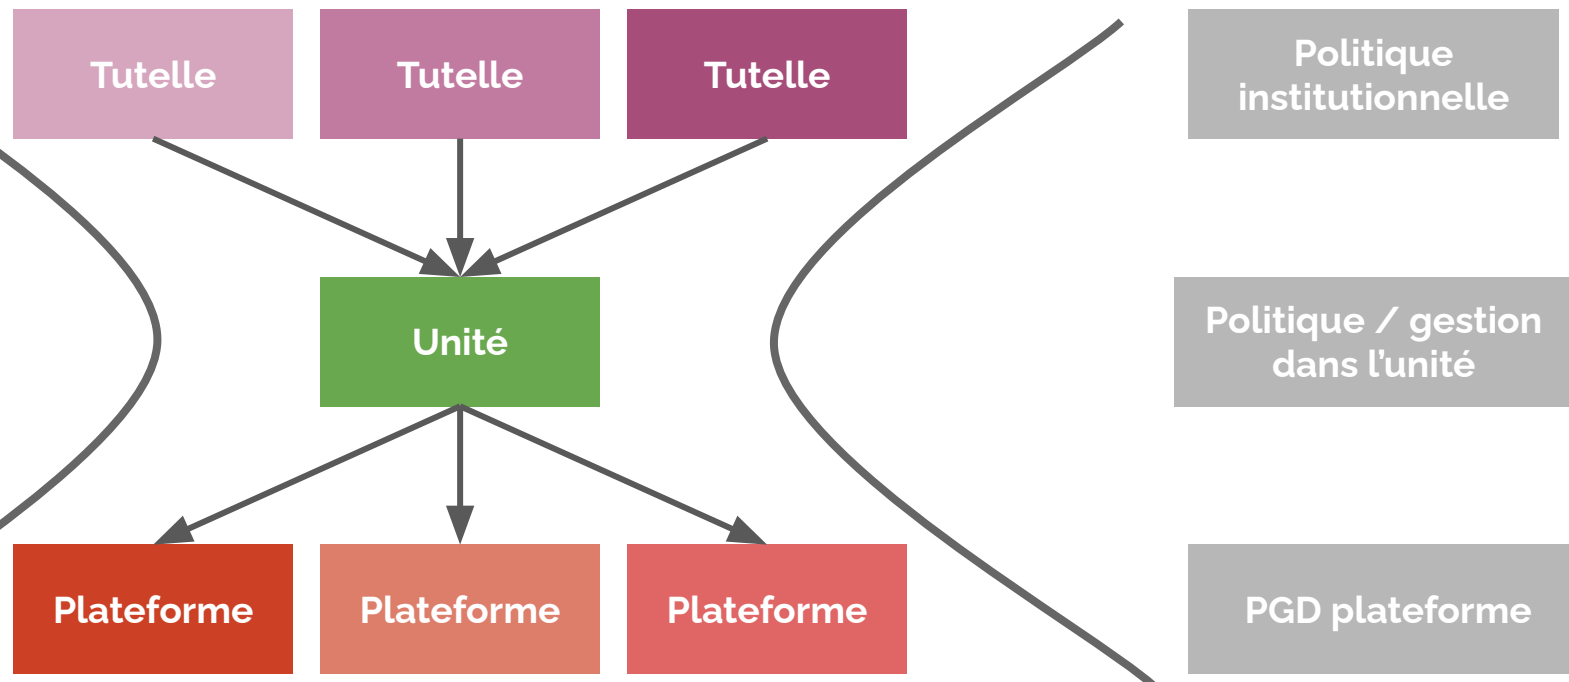
PGD entité ? Mais pour quelle entité ?

Entité ?

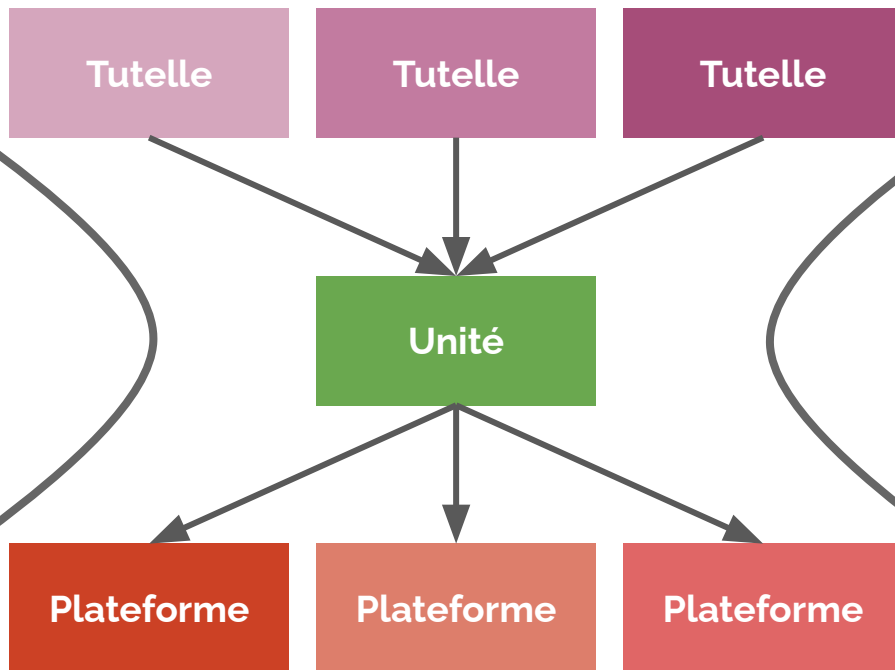
- Plateforme ?
- Plateau ?
- Laboratoire / unité ?
- Institut ???

Comment et pourquoi aborder l'exercice du PGD pour des entités aussi hétérogènes ?

La question ouverte du "sablier"



La question ouverte du “sablier”



Du document de **politique**, au **PGD**, en passant pas les **recommandations** pour les PGD

PGD classique, PGD structuré



Attention au gag de vocabulaire

Structure (entité) ≠ Structuré

PGD classique : ne contient que des réponses en texte libre


PGD structuré : une partie des réponses sont interprétables par une machine (chiffres, dates, choix multiples...)

Exemple: quel est la taille attendu d'un jeu de données ?

Simple: *"oh ben ça dépend, sur les plantes ça peut monter à 40Go, mais sur des petits organismes on va pas dépasser les 10Go... Après on restera loin du To bien entendu".*

Structuré: **25Go**

Le premier pas est le plus difficile:
les produits de la recherche



Le nœud gordien : le produit de la recherche

Produit de la recherche: ensemble de données gérées de la même façon, dans le cadre d'un projet ou d'une entité

On **découpe** notre PGD en produits de la recherche

On répond aux **questions du PGD** pour chaque produit de la recherche

Il n'existe **jamais une seule solution** de découpage

Le produit de la recherche - exemple projet

Classiquement, dans un projet, avec de multiples types de données

Par exemple, dans un même projet:

- Des données de bioimagerie
- Des données de séquençage

Produit de la recherche 1

Bioimagerie

Images brutes - images analysées - images annotées...

Produit de la recherche 2

Séquençage

Lectures brutes - assemblages - *mappings* - annotations...

...

...


Fil narratif de la stratégie, dans le PGD projet

Le produit de la recherche - exemple entité

Dans le cas d'une plateforme de production et d'analyse de données

Par exemple, pour une plateforme de séquençage:

- Des données brutes
- Des données analysées (*mappings*, assemblages)
- Des données valorisées (génomomes annotés, génotypage, phylogénies...)

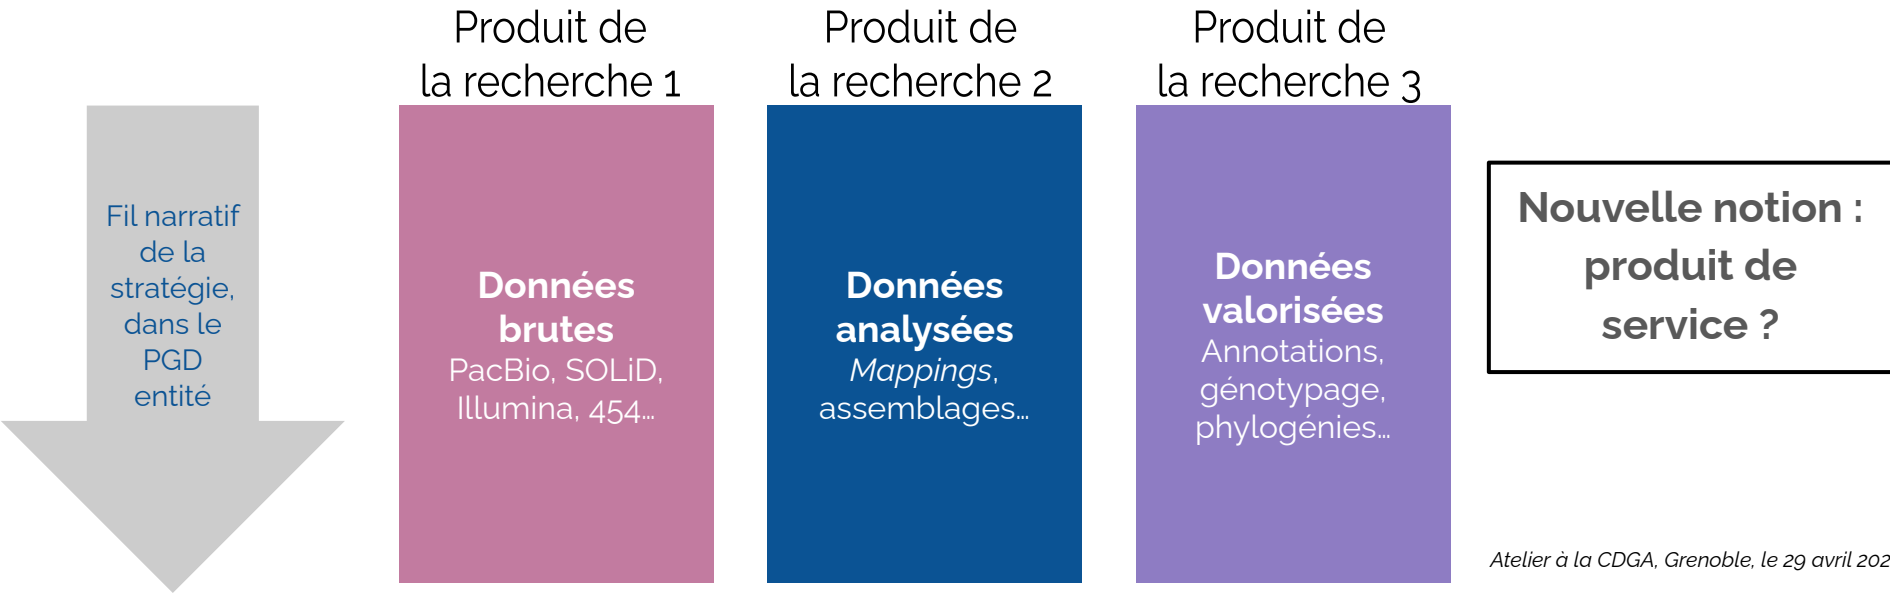


Le produit de la recherche - exemple entité


Dans le cas d'une plateforme de production et d'analyse de données

Par exemple, pour une plateforme de séquençage:

- Des données brutes
- Des données analysées (*mappings*, assemblages)
- Des données valorisées (génomomes annotés, génotypage, phylogénies...)



Et c'est grave ?
Un peu, si on raisonne sur le long terme
Parlons d'avenir



Les PGD entités et les PGD projets en synergie

Ce qu'on aimerait dans l'avenir, des PGD opérationnels,
dits ***“machine actionable”***

PGD entité

PGD projet

Les PGD entités et les PGD projets en synergie

Ce qu'on aimerait dans l'avenir, des PGD opérationnels, dits ***“machine actionable”***

Quels sont les prochains projets à émarger ?

Quelle évolution des besoins pour mon collectif ?

Combien de nouveaux utilisateurs, quels groupes de travail à administrer ?

Quel est le futur plan de charge du collectif ?

PGD entité

PGD projet

Quel matériel pour produire les données ?

Quel matériel pour stocker et analyser les données ?

Quels tarifs ?

Comment renseigner mon PGD projet avec l'ensemble de ces informations ?

Les PGD entités et les PGD projets en synergie

Ce qu'on aimerait dans l'avenir, des PGD opérationnels, dits ***“machine actionable”***

Quels sont les prochains projets à émarger ?

Quelle évolution des besoins pour la plateforme ?

Combien de nouveaux utilisateurs, quels groupes de travail à administrer ?

Quel est le futur plan de charge de la plateforme ?

PGD entité

**Spécifications techniques
(matériel de production,
stockage,
sécurité...)
Modèle économique**

...

**Besoins en stockage
Besoin en calcul
Durée du projet
Comptes utilisateurs**

...

PGD projet

Quel matériel pour produire les données ?

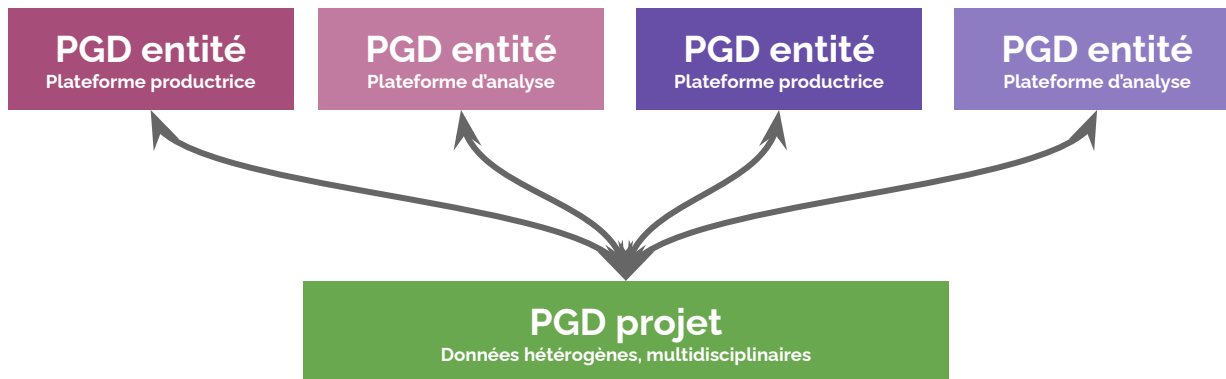
Quel matériel pour stocker et analyser les données ?

Quels tarifs ?

Comment renseigner mon PGD projet avec l'ensemble de ces informations ?

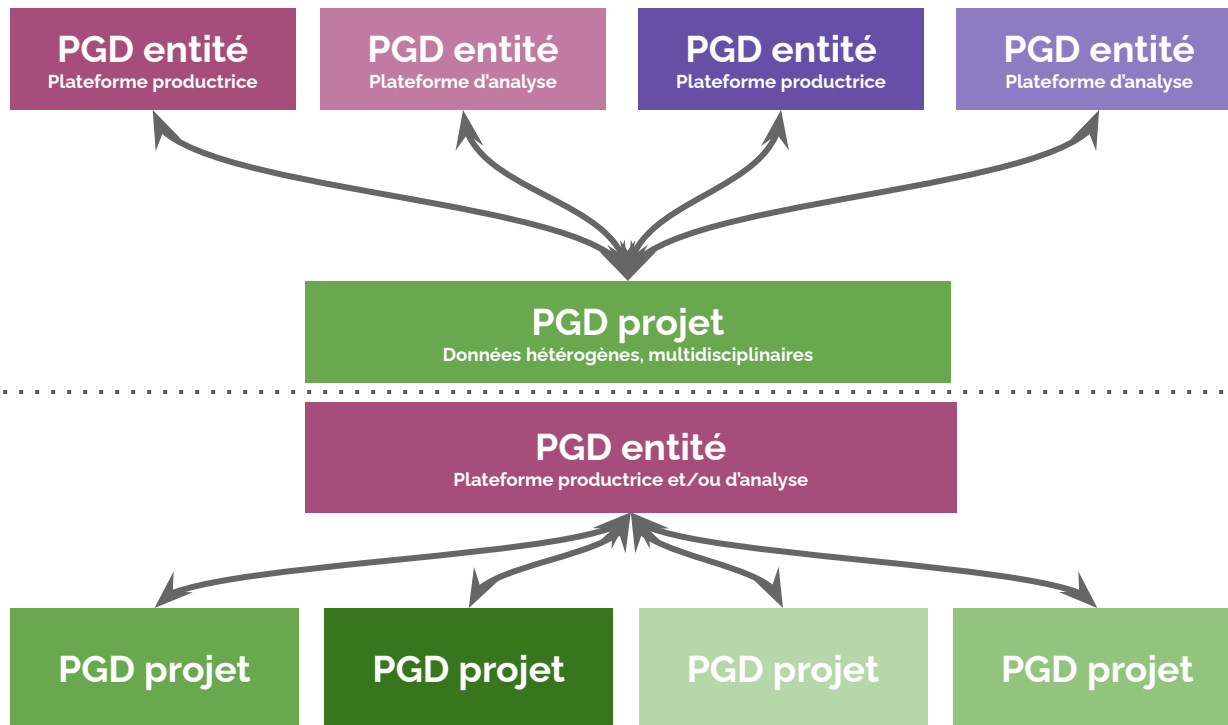
Les PGD entités et les PGD projets en synergie

Mais dans la vraie vie... Rien n'est aussi simple



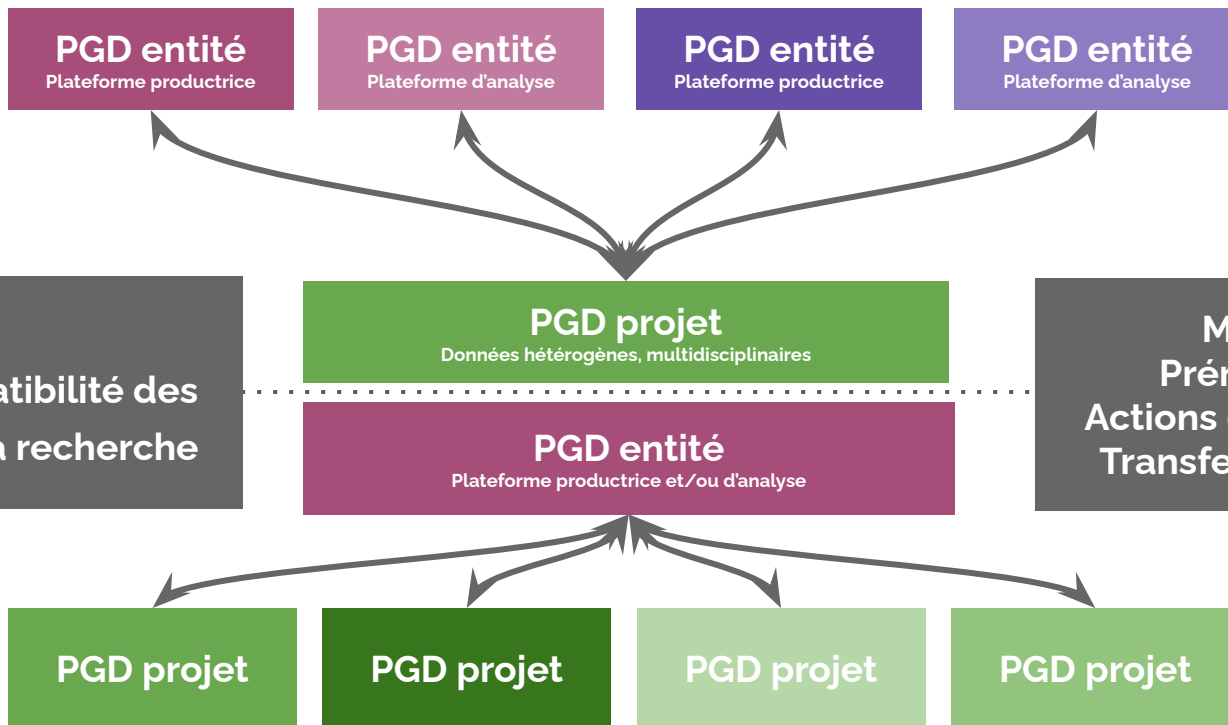
Les PGD entités et les PGD projets en synergie

Mais dans la vraie vie... Rien n'est aussi simple



Les PGD entités et les PGD projets en synergie

Mais dans la vraie vie... Rien n'est aussi simple



Qui réfléchit à tout ça ?



RESEARCH DATA ALLIANCE
Structuration / réflexion
internationale


**MINISTÈRE
DE L'ENSEIGNEMENT
SUPÉRIEUR
ET DE LA RECHERCHE**

*Liberté
Égalité
Fraternité*

 **anr**[®]
agence nationale
de la recherche

CoSO

Comité pour la science ouverte



CoSIN

**Comité aux services et
infrastructures numériques**

Réseau des ADAC

**Administrateur des données et
codes sources de la recherche**

 **CENTRES DE RESSOURCES**
Un accompagnement technique sur le dépôt de
données sur Recherche Data Gov



 **RÉPUBLIQUE
FRANÇAISE** recherche.data.gouv.fr

*Liberté
Égalité
Fraternité*



**Un écosystème au service du partage
et de l'ouverture des données de recherche**



**CENTRES DE RÉFÉRENCES
THÉMATIQUES**

Un spectre de compétences fondamentales relatives à
la donnée et propre à chaque discipline

 **Huma-Num**
la TGR des humanités numériques

**Infrastructures
nationales**

 **IFB**
INSTITUT FRANÇAIS DE BIOINFORMATIQUE

 **RARE**
Ressources agronomiques
pour la recherche

 **eosc** 
Infrastructures
européennes



 **EMPHASIS**
EUROPEAN INFRASTRUCTURE FOR PLANT PHENOTYPING

Niveau International

Niveau national

*Niveau régional
Exemple à Montpellier*



ATELIERS DE LA DONNÉE

Des experts de la donnée à disposition
et à proximité des chercheurs



MUSE ISDM
MONTPELLIER UNIVERSITÉ D'EXCELLENCE
INSTITUT DE SCIENCE DES DONNÉES
MONTPELLIER

ECODOR

DipS INRAE

 **DDOR** ...

Tutelles

Atelier à la CDGA, Grenoble, le 29 avril 2024



RESEARCH DATA ALLIANCE
Structuration / réflexion internationale

Groupe de travail
"PGD thématiques"



Réseau des
"research data managers"
<https://www.youtube.com/watch?v=S7HfUe1hWcg>

Niveau International
Niveau national
Niveau régional
Exemple à Montpellier



CENTRES DE RESSOURCES
Un accompagnement technique sur le dépôt de données sur Recherche Data Gov



Groupe de travail
"PGD entités"

RÉPUBLIQUE FRANÇAISE
recherche.data.gouv.fr
Un écosystème au service du partage et de l'ouverture des données de recherche

ATELIERS DE LA DONNÉE
Des experts de la donnée à disposition et à proximité des chercheurs



CENTRES DE RÉFÉRENCES THÉMATIQUES
Un spectre de compétences fondamentales relatives à la donnée et propre à chaque discipline

ECODOR

- CoSO
Comité pour la science ouverte
- CoSIN
Comité aux services et infrastructures numériques
- Réseau des ADAC
Administrateur des données, des algorithmes et des codes sources



Infrastructures nationales



Groupe de travail
"Modèles thématiques de PGD entités"



Tutelles

Et si on veut faire un PGD entité...
Maintenant ?

Quel modèle ?

Modèle de PGD : la série de questions à laquelle on répond lors de la rédaction.

Il existe de nombreux modèles de PGD :

- Spécifiques à des guichets de financement (ANR, H2020...)
- Spécifiques à des instituts (INRAE, CIRAD, CNRS...)
- Spécifiques à des centres (GENCI...)

- ❖ Certains modèles sont en partie structurés (Science Europe structuré)
- ❖ Certains modèles sont adaptés aux entités (Science Europe structuré, INRAE structure)
- ❖ Certains sont les deux
- ❖ Certains sont compatibles avec le *RDA DMP common standard*

Le modèle entité n'est pas toujours très différent du modèle projet !

Quel modèle ?

Les modèle entité n'est pas toujours très différent du modèle projet !

Le projet / la structure	Obtention des données	Documentation des données	Stockage et sécurité des données
<ul style="list-style-type: none"> Présentation du projet / de la structure Partenaires Politique en matière de gestion des données 	<ul style="list-style-type: none"> Quelles données seront produites (type, format, volume...) Comment seront-elles produites ? Des données existantes seront-elles réutilisées ? 	<ul style="list-style-type: none"> Quelle documentation et quelles métadonnées accompagneront les données ? Quelles procédures contrôlent la qualité des données ? Comment les données seront-elles organisées ? 	<ul style="list-style-type: none"> Comment, où, par qui, seront stockées, sauvegardées et sécurisées les données ?
Exigences légales et éthiques	Accès et partage des données	Archivage des données	Responsabilités et ressources
<ul style="list-style-type: none"> Droit applicable aux données produites Données à caractère personnel, respect du RGPD Données sensibles Prise en compte des questions éthiques 	<ul style="list-style-type: none"> Quelles données seront partagées ou publiées ? Comment ? Avec qui ? Dans quel délai ? Quelle licence sera associée aux données ? Comment les données produites pourraient-elles être réutilisées ? 	<ul style="list-style-type: none"> Comment les données seront-elles sélectionnées pour une préservation à long terme ? Y a t'il un plan d'archivage ? 	<ul style="list-style-type: none"> Qui est responsable de la gestion des données ? Quelles sont les ressources dédiées à la gestion et à l'ouverture des données ?

Besoin de modèles thématiques

Préparer les PGD *machine actionable* avec des questions précises et adaptées

- ❖ Demande de nombreuses infrastructures nationales :

France Génomique, France BioImaging, MetaboHUB, ProFi, ACF, EMBR-FR

→ Groupe de travail

(Animation Paulette Lieby, Frédéric Brau)



- ❖ Groupe de travail, PGD thématiques (entité et projet)

(Animation Françoise Genova)



- ❖ DMP-OPIDoR, par le biais de formulaires spécialisés

Quels outils ?

Nombreux outils sur la place internationale:



Deux focus stratégiques:

- ❖ DMP-OPIDoR:
 - outil favorisé au national
 - évolution constante (fonctionnalités *machine actionable*, ergonomie...)
 - nombreux modèles académiques, génériques
- ❖ DSW (Data Stewardship Wizard)
 - outil favorisé au niveau Européen (ELIXIR)
 - édition libre et collaborative des modèles

Quels outils ?

Nombreux outils sur la place internationale:



Deux focus stratégiques:

- ❖ DMP-OPIDoR:
 - outil favorisé au national
 - nombreux modèles académiques, génériques



Besoin stratégique : interopérabilité



- ❖ DSW (Data Stewardship Wizard)
 - outil favorisé au niveau Européen (ELIXIR)
 - édition libre et collaborative des modèles



Conclusion, sur les aspects théoriques

- ❖ Le PGD n'est pas un exercice à maturité
- ❖ Le PGD est un exercice clivant
- ❖ Le PGD incite à une étape de dialogue cruciale
- ❖ Le PGD recèle des informations “exclusives”
- ❖ Les différents PGD
 - Projets,
 - Plateformes,
 - Unités,
 - Établissements,

contiennent les mêmes questions, mais des réponses très différentes