Progedo, une infrastructure pour ouvrir les données

Sébastien Oliveau

PROGEDO

DATA INFRASTRUCTURE

Une infrastructure pour ouvrir les données

Sébastien Oliveau,
Directeur de l'infrastructure de recherche PROGEDO,
Maître de conférences à l'Université d'Aix-Marseille

8ème conférence document numérique et société

Communications scientifique et science ouverte

Opportunités, tension et paradoxe

Liège, 23 juin 2022

LIÈGE université

DicenIDF
Dispositifs d'Information et de Communication à l'Ère Numérique - Paris Ile de France

le cnam

PRO GE DO
DATA INFRASTRUCTURE

OUVRIR LA SCIENCE !

La science ouverte est la **diffusion sans entrave** des publications et des **données de la recherche.**

Elle s'appuie sur l'opportunité que représente la mutation numérique pour développer l'accès ouvert aux publications et -autant que possible- aux données de la recherche.

https://www.ouvrirlascier

Huma-Num est une très grande infrastructure de recherche (TGIR) visant à faciliter le **tournant numérique de la recherche en sciences humaines et sociales**. Huma-Num mets en œuvre un dispositif humain (concertation collective) et technologique en s'appuyant sur un réseau de partenaires et d'opérateurs.

Acteur central de la **politique nationale sur les données en sciences humaines et sociales**, PROGEDO soutient la réalisation de grandes enquêtes européennes, la mise à disposition des données françaises, le développement de la culture des données et la constitution de briques de compétences de niveau européen.

OpenEdition est une infrastructure complète d'**édition électronique au service de la communication scientifique en sciences humaines et sociales**. Elle rassemble quatre plateformes complémentaires dédiées aux livres, aux revues, aux carnets de recherche et aux événements scientifiques

Le Réseau national des MSH fédère 23 Maisons des Sciences de l'Homme réparties sur toute la France, et regroupées autour de cinq principes fondamentaux : **l'Interdisciplinarité**, **l'Internationalisation**, une Dynamique **Interinstitutionnelle**, **l'Implantation territoriale** et une **Identité scientifique**.

PRO GE DO
DATA INFRASTRUCTURE

OUVRIR LA SCIENCE !

Rendre les données

F Findable A Accessible I Interoperable R Reusable

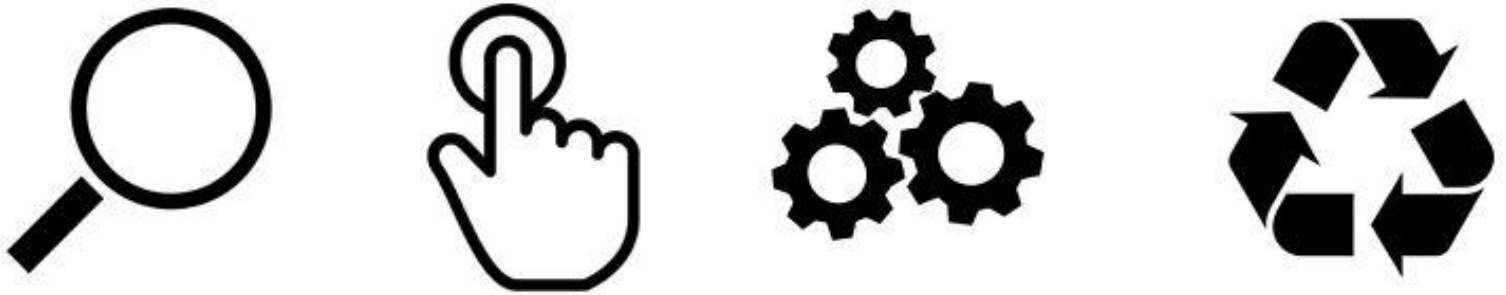

PRO GE DO
DATA INFRASTRUCTURE

OUVRIR LA SCIENCE !

Rendre les données aussi ouvertes que possible…

…les garder aussi fermées que nécessaires

Qu'est-ce qu'une donnée pour PROGEDO?

Matériaux: ce que l'on récolte sur le terrain

Un matériau peut être ouvert ou non

Un matériau peut-il être FAIR ?

Donnée : matériau mis en forme (et forme spécifique)

Aujourd'hui, la donnée est implicitement numérique

Donnée secondaire ? Donnée issue du traitement d'une donnée existante (données agrégées par exemple)

Qu'est-ce qu'une donnée pour PROGEDO?

Les données dans le cadre de PROGEDO:

issues d'enquêtes (ou de registres administratifs)

quantitatives

représentatives

(il peut y avoir des exceptions, c'est le principe des règles)

!! Enjeux particuliers autour des « microdonnées » !!

Qu'est-ce qu'une donnée pour PROGEDO?

De nouveaux enjeux:

- les données liées aux publications
  - Besoin exprimé par les chercheurs
  - Enjeu au niveau de l'édition

- les données secondaires
  - Concept à préciser
  - Quel sauvegarde souhaitée/nécessaire

Les données en SHS

Cadre légal

- Loi pour une République Numérique
- Règlement Général pour la Protection des Données

Implications

- Diffusion obligatoire des données publiques
- Protection des données individuelles

Application

- Développement de l'Open Data
- Développement de procédures d'accès restreints

Accès aux données

- opendata.gouv.fr; zenodo; nakala; etc.
- PROGEDO; CASD; Health Data Hub; etc.

PROGEDO
DATA INFRASTRUCTURE

Protéger les données personnelles

Méthodes

- protéger l'accès
- pseudonymiser
- Rendre anonyme

Implications

- Environnements adaptés
- Potentiellement réidentifiant
- Perte d'information

Protéger l'accès

Ordinateurs non connectés dans les locaux du producteur	**Exécution à distance** (*remote execution*)	**Accès sécurisé à distance** (« bulles » informatiques)
Le chercheur se déplace physiquement dans les locaux du producteur et accède à une machine où il peut travailler et imprimer/exporter ses résultats	Le chercheur envoie une ligne de commande sur un serveur distant qui opère sans donner accès aux données et renvoie les résultats	Le chercheur se connecte sur un terminal qui lui donne accès aux données et à un environnement logiciel. Il peut exporter ses résultats.

Protéger l'accès

Ordinateurs non connectés
dans les locaux du producteur

Nécessité de se déplacer
Inégalités d'accès

Not FAIR

Exécution à distance
(*remote execution*)

Moindre convivialité
Moindre souplesse
(difficile de proposer des choix de logiciels en dehors de ce qui est proposé, idem pour les données)

FAIR ?

Accès sécurisé à distance
(« bulles » informatiques)

Environnements adaptés
Coûts

Aussi FAIR que possible

Pseudonymiser les données

Les fichiers « Production et recherche »

En termes de détails, les fichiers "FPR" offrent un niveau intermédiaire d'information entre les données standards anonymisées (plus agrégées) et les données confidentielles plus détaillées.

Les données pseudonymisées sont considérées comme potentiellement ré-identifiantes. A ce titre, elle nécessite une autorisation administrative auprès du **Comité du secret statistique**

La procédure d'habilitation auprès du Comité du Secret Statistique est gérée par l'intermédiaire des équipes de Quetelet-Progedo-Diffusion. L'accès aux données se fait ensuite depuis l'ordinateur du chercheur.

Pseudonymiser les données

PROGEDO assure le financement de Quetelet-Progedo-Diffusion et la coordination scientifique des équipes membres

Huma-Num assure l'accueil sur ses serveurs de l'infrastructure informatique de PROGEDO

FAIR et qualité des données

Standard de métadonnées

Dublin Core

DDI

Protocoles standards déchange

OAI-PMH

Documentation des Process

Certification Core

Trust Seal

PRO GE DO
DATA INFRASTRUCTURE

Quelques limites à évoquer

Rapidité des changements => formation

Instabilité législative

Durabilité des infrastructures informatiques

Pérennité des financements

PROGEDO
DATA INFRASTRUCTURE

Produire, Partager, Promouvoir

Produire des données

Donner acc

Gérer la diffusion des [illegible]ées

Promouvoir la culture des données

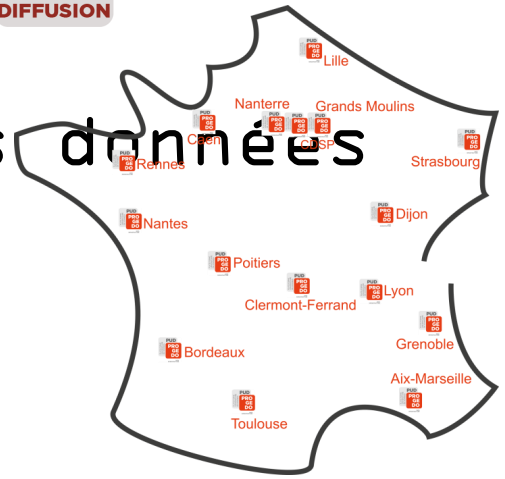

PROGEDO
DATA INFRASTRUCTURE

Départements

Méthodes & Statistiques Publiques

cessda

Opinion et enquêtes sociopolitiques

European Social Survey

ISSP

European Values Study

Santé

SHARE
Survey of Health, Ageing and Retirement in Europe
50+ in Europe

CSE HS2PE

Données historiques économiques

DFIH
Données Financières Historiques

DB·NOMICS
the world's economic database

eurofidai
CNRS UPS 3390

Population et parcours

GGP

Politique Française des données en SHS

- Méthodes & Statistiques Publiques
- Opinion et enquêtes sociopolitiques
- Santé
- Données historiques économiques et financières
- Population et parcours de vie

QUETELET PROGEDO DIFFUSION

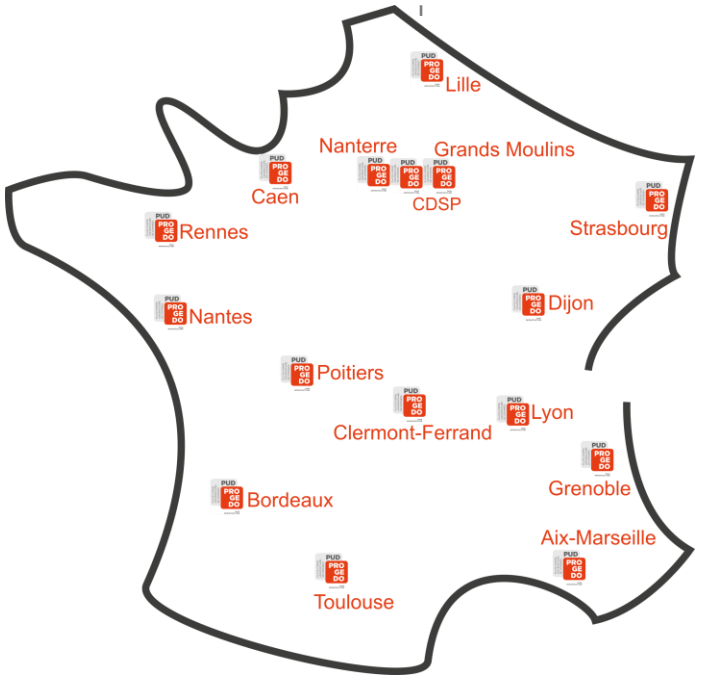

PUD PLATE-FORME UNIVERSITAIRE DE DONNÉES PROGEDO DATA INFRASTRUCTURE

Plateformes Universitaires de Données

Réseau national RMSH et Universités partenaires

Pour les enquêtes quantitatives en SHS: https://data.progedo.fr
Pour les données SHS de manière plus générique: https://nakala.f

Projets de site, incluant les PUD le cas échéant

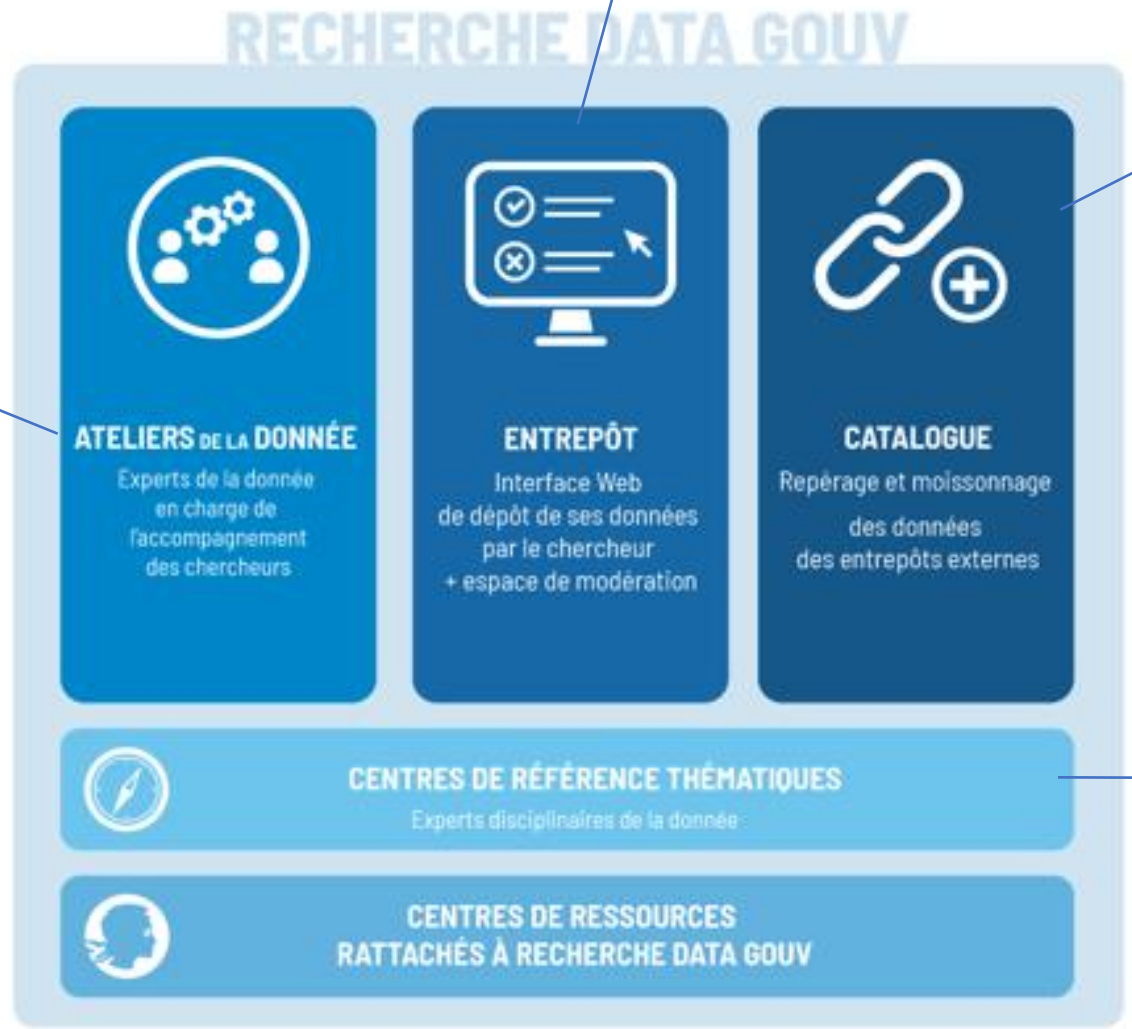

Pour les enquêtes quantitatives en SHS: https://data.progedo.fr

De manière plus générique en SHS: https://isidore.science/

Huma-Num + PROGEDO DATA INFRASTRUCTURE

PROGEDO

DATA INFRASTRUCTURE

Développer la culture des données

Merci de votre attention

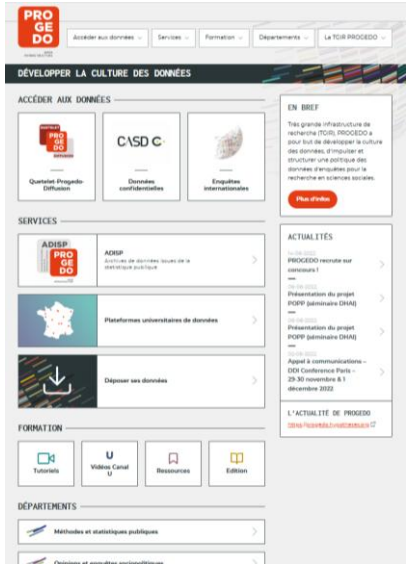

https://www.proge