

How to publish research data? The example of Recherche Data Gouv

Améline Vallet – AgroParisTech

26/03/2024

Why publishing data?

- Enhances transparency and credibility in research
- Supports the replication and validation of results, strengthening scientific integrity
- Facilitates collaboration and information sharing across disciplines
- Accelerates the pace of research and findings

Findable



Accessible



Interoperable



Reusable



« Open data citation advantage »

- Studies that provide access to underlying data are cited 10-25% more often than those that don't

<https://doi.org/10.1371/journal.pone.0230416>

<https://peerj.com/articles/175/>

<https://doi.org/10.1371/journal.pone.0253129>



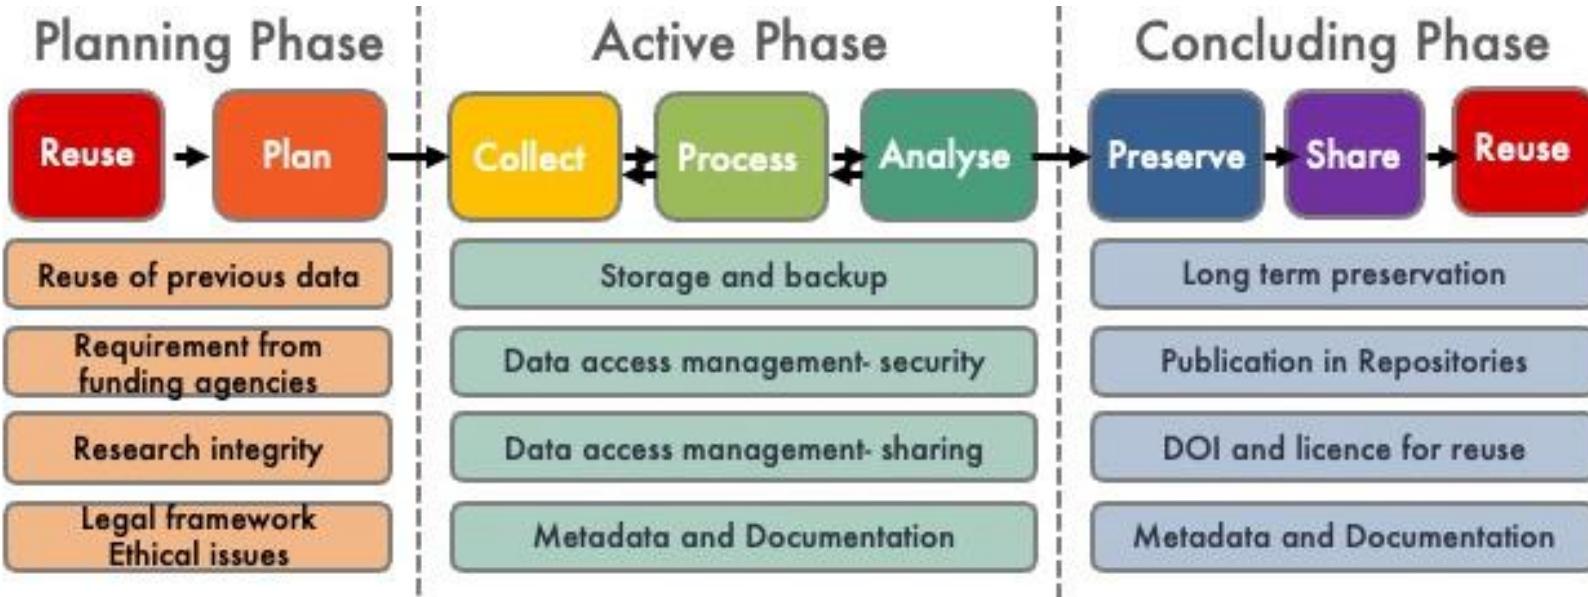
PUBLIC BENEFITS

RESEARCH COMMUNITY

BENEFITS

BENEFITS FOR YOU

How to publish data? Data cycle



How to choose a data repository: exclusion criteria

- Absence of moderation
- Absence of a persistent identifier
- Absence of guarantee for infrastructures
- Repositories imposing transfers in property rights / copyrights
- Excessive pricing policy
- Data localization (outside the EU)
- Restrictions for access (e.g., institutional affiliation)

How to chose a data repository: listings

Nom	URL	Institution porteuse	Modération	Identifiant pérenne fourni	Pérennité de l'infrastructure/Engagement sur la durée de préservation des données	Discipline	Champs disciplinaires détaillés	Données acceptées=mots qui parlent à la communauté
data.InDoRES (inventaire des données de recherche en environnement et sociétés)	https://data.indores.fr/	CNRS-INEE et MNHN	La modération est opérée soit par l'équipe data.InDoRES soit par le référent local du réseau OpenDoRES de l'unité de recherche quand il existe. La complétude des métadonnées ainsi que la compréhension des contenus sont vérifiés par le modérateur. Le contenu scientifique est quant à lui laissé à la responsabilité du déposant.	DOI	Le portail InDoRES a été créé en 2016, l'entrepôt data.InDoRES a été lancé fin 2021. La pérennité de l'entrepôt est assurée par le soutien des deux tutelles (MNHN et CNRS-INEE). Le Centre de Calcul de l'IN2P3 assure le stockage et la sauvegarde des données de l'entrepôt.	Sciences de l'environnement	Ecologie, Environnement, Bio-archéologie	Données environnementales écologiques et géographiques
EaSy Data	https://www.easydata.earth/	Data Terra et BRGM	Modération sur les métadonnées et le périmètre. Organisée par thématiques (liste thématique ici : https://terra-vocabulary.org/ncl/DataTerraRepositoryFairIncubator/_Voc_thematique). Prise en charge de la modération par des experts de domaine dans chaque pôle de données de Data Terra. Interface de modération fournie.	DOI	La pérennité de l'entrepôt est assurée par l'IR Data Terra et le BRGM.	Sciences de l'environnement	Sciences de la terre et de l'environnement	Données de longue durée du système et de l'environnement (exemple : issues d'un projet), hors données d'observation prélevées et chargées par les personnes
GBIF Global Biodiversity Information Facility	https://www.gbif.org/	GBIF	Le GBIF fournit une moderation à 2 niveaux : 1) au niveau de l'entité publiant les données (publisher), par exemple le laboratoire de recherche. Le GBIF s'assure que l'entité fournit des données dans le périmètre du GBIF. Ce contrôle est opéré une seule fois, lors de la création de l'entité déposante.	DOI	En cas d'interruption d'accès aux données ou de rupture de service, le GBIF transférera les données auprès de ses partenaires afin d'assurer la préservation de long terme des données.	Sciences de l'environnement	Sciences du vivant, Biodiversité, Biologie animale, Biologie végétale, Ecologie, Environnement	taxons, données d'occurrences, d'échantillonnage toutes standardisées selon les standards Darwin Core ou les
PANGAEA	https://www.pangaea.de/	Alfred Wegener Institute, Helmholtz Center for Polar and	2 niveaux : Basic curation : porte sur les métadonnées. Enhanced curation : conversion des données	DOI	10 ans	Sciences de l'environnement	Sciences de la Terre, Sciences du vivant, Géosciences (biogéologie, chimie)	Données des océans et des fonds marins

Comparaison:Zenodo-Dryad-figshare

Zenodo		Dryad		Figshare	
FAIR Nonprofit organization (CERN & H2020)		FAIR Nonprofit organization		FAIR Commercial company-Digital Sciences (NPG)	
Muldi-disciplinary (physics)		Muldi-disciplinary (life science, medical)		Muldi-disciplinary (life science)	
<ul style="list-style-type: none"> ▪ <u>FBM community</u> ▪ Multiformat (All file types) ▪ Manuscript submission workflow ▪ Private link sharing (not friendly procedure) ▪ Quick & simple upload ▪ Satisfy funder (H2020, SNSF) & publisher (check the journal) open data mandates 		<ul style="list-style-type: none"> ▪ Multiformat "All data types ,specific formats " ▪ Manuscript submission workflow ▪ Private link sharing (friendly procedure) ▪ Quick & simple upload ▪ Satisfy funder (H2020, SNSF) & publisher (check the journal) open data mandates 		<ul style="list-style-type: none"> ▪ Multiformat All file types ▪ Manuscript submission workflow ▪ Private link sharing (friendly procedure) ▪ Quick & simple upload ▪ Don't satisfy SNSF funder ▪ Satisfy H2020 & publisher (check with journal) open data mandates 	
<ul style="list-style-type: none"> ▪ 50 GB limit per package. ▪ Flexible licensing (CC0 or CC BY) ▪ Easily access and reuse ▪ DOI to make data citeable. ▪ Exposing robust metadata in landing page markup with html meta tags ▪ Dataset directly link to publication. 		<ul style="list-style-type: none"> ▪ 20 GB limit per package: \$50 extra per additional 10 GB ▪ Licence CC0 only. ▪ Easily access and reuse ▪ DOI to make data citeable. ▪ Exposing robust metadata in landing page markup with html meta tags ▪ Dataset directly link to publication 		<ul style="list-style-type: none"> ▪ Unlimited public space but 5 GB limit per file. ▪ 20 GB of free restricted private space ▪ Licence CC0 or CC BY ▪ Easily access and reuse ▪ DOI to make data citeable. ▪ Exposing robust metadata in landing page markup with html meta tags ▪ Dataset directly link to publication 	
<ul style="list-style-type: none"> ▪ Datafile versioning ▪ Contents secure and curated ▪ Long-term preservation 		<ul style="list-style-type: none"> ▪ Possibility to update datafiles ▪ Contents secure and curated ▪ Long-term preservation 		<ul style="list-style-type: none"> ▪ Possibility to update datafiles ▪ Contents secure and curated ▪ Long-term preservation 	
<ul style="list-style-type: none"> ▪ Free for individuals 		<ul style="list-style-type: none"> ▪ Fee \$120 for individuals if not link to a sponsored journal paper ▪ Big data storage (>20 GB): \$50 extra per additional 10 GB 		<ul style="list-style-type: none"> ▪ Free for individuals 	
<ul style="list-style-type: none"> ▪ Only simple search tool ▪ Relevant ranking ▪ Altmetrics 		<ul style="list-style-type: none"> ▪ Simple and advanced search tool ▪ Relevant ranking 		<ul style="list-style-type: none"> ▪ Simple and advanced search tool ▪ Relevant ranking ▪ Views/share 	

How to choose a data repository: guidelines

Subject	General-purpose
UK Data Service	 zenodo  figshare
 EMBL-EBI	 The Dataverse Project  DRYAD
 Centre for Environmental Data Analysis SCIENCE AND TECHNOLOGY FACILITIES COUNCIL NATURAL ENVIRONMENT RESEARCH COUNCIL	
Institutional	
<u>University of Reading Research Data Archive</u>	
 RÉPUBLIQUE FRANÇAISE Liberté Égalité Fraternité	recherche.data.gouv.fr

- Disciplinary repository
- Institutional repository
- Research Data Gov

re3data.org
REGISTRY OF RESEARCH DATA REPOSITORIES

 Ouvrir la science ! **Liste des entrepôts de confiance**

Research Data Gouv

- **Une offre souveraine de dépôt, publication et de signalement des données**
- Plateforme nationale pluridisciplinaire et fédérée des données de la recherche
 - Complémentaire des entrepôts thématiques
 - Une solution opérationnelle à destination des équipes de recherche
 - Une alternative à la publication sur des plateformes commerciales ou ne répondant pas à des critères de confiance
 - Devenir un des services de *l'European open science cloud*
- **Un maillage d'offres d'accompagnement généraliste et thématique**
 - Sensibiliser, former ou accompagner les équipes de recherche en proximité thématique et/ou géographique



RÉPUBLIQUE
FRANÇAISE

Liberté
Égalité
Fraternité

recherche.data.gouv.fr

Example: JUICCE Project



JUICCE

- Research project started in 2019
- Focus on climate justice
- Distribution of the impacts of climate change related extreme events

Mapping of extreme events

- Development / selection of indicators
- Climate projections (RCPs)
- Compounds events

Mapping of population vulnerability

- High resolution modeling
- Socio-economic characteristics
- Impact predictions

Analysis of inequalities

- Literature review
- Spatial statistics
- Change overtime and scenarios

Reducing inequalities

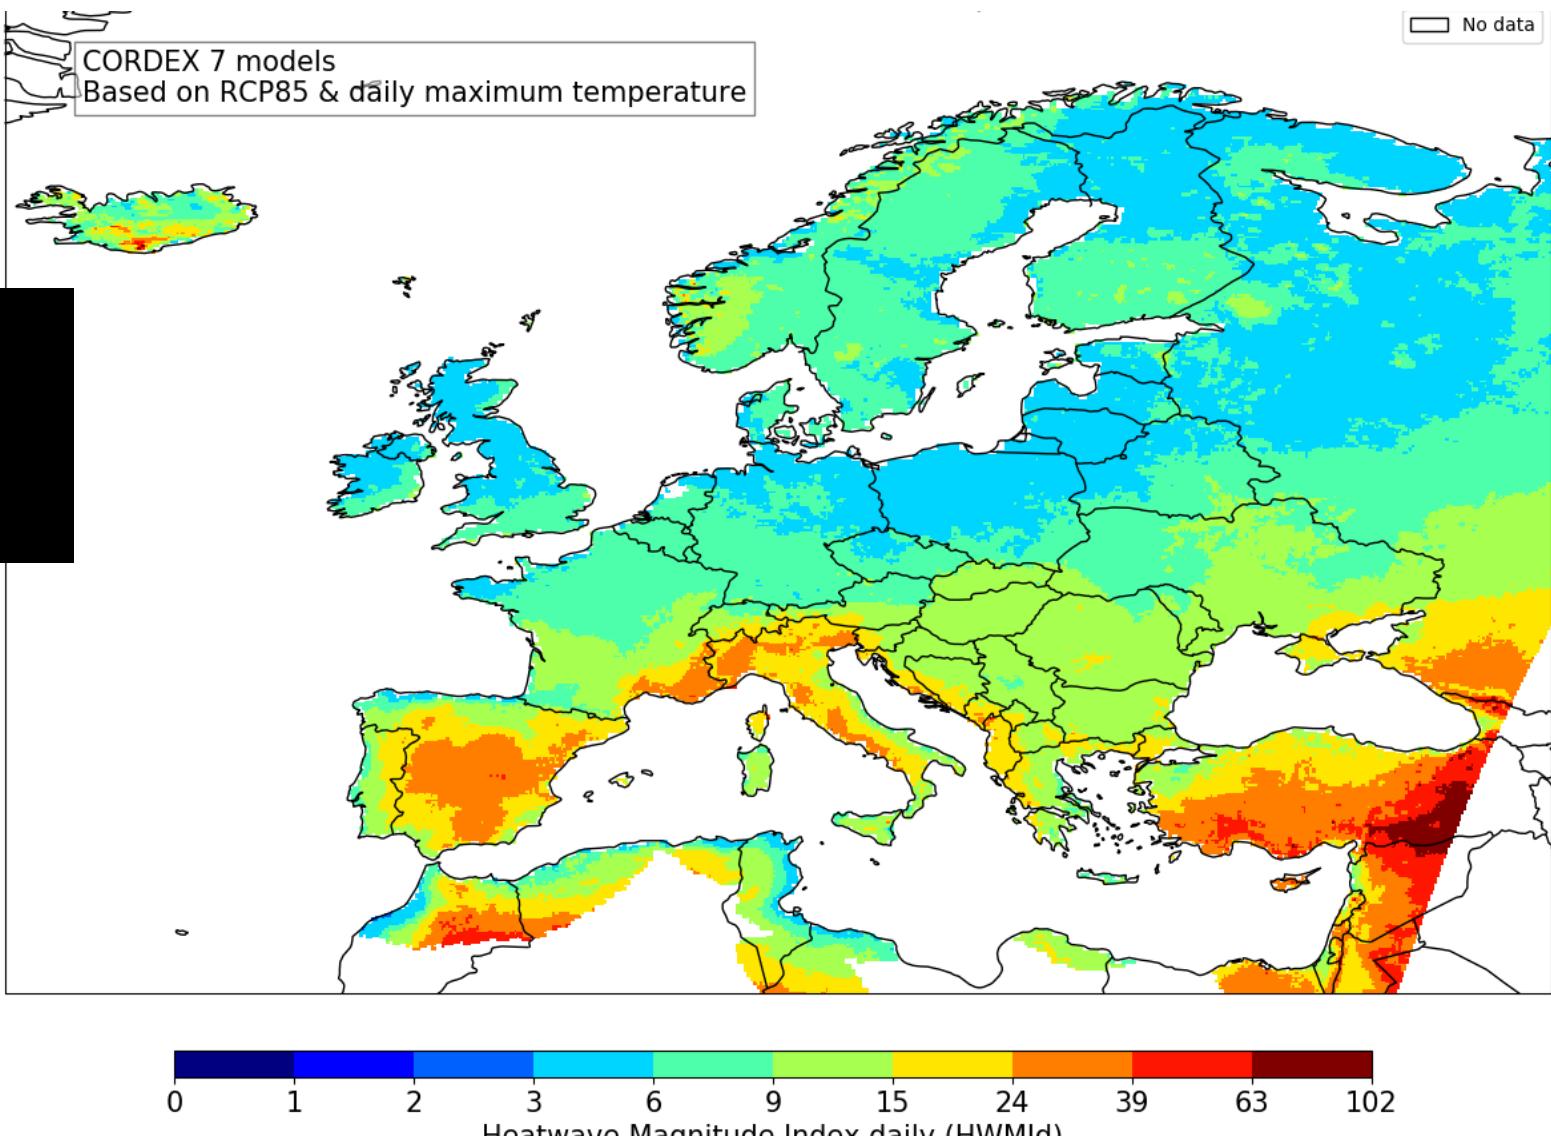
- Nature-based solutions
- Urban planning tools

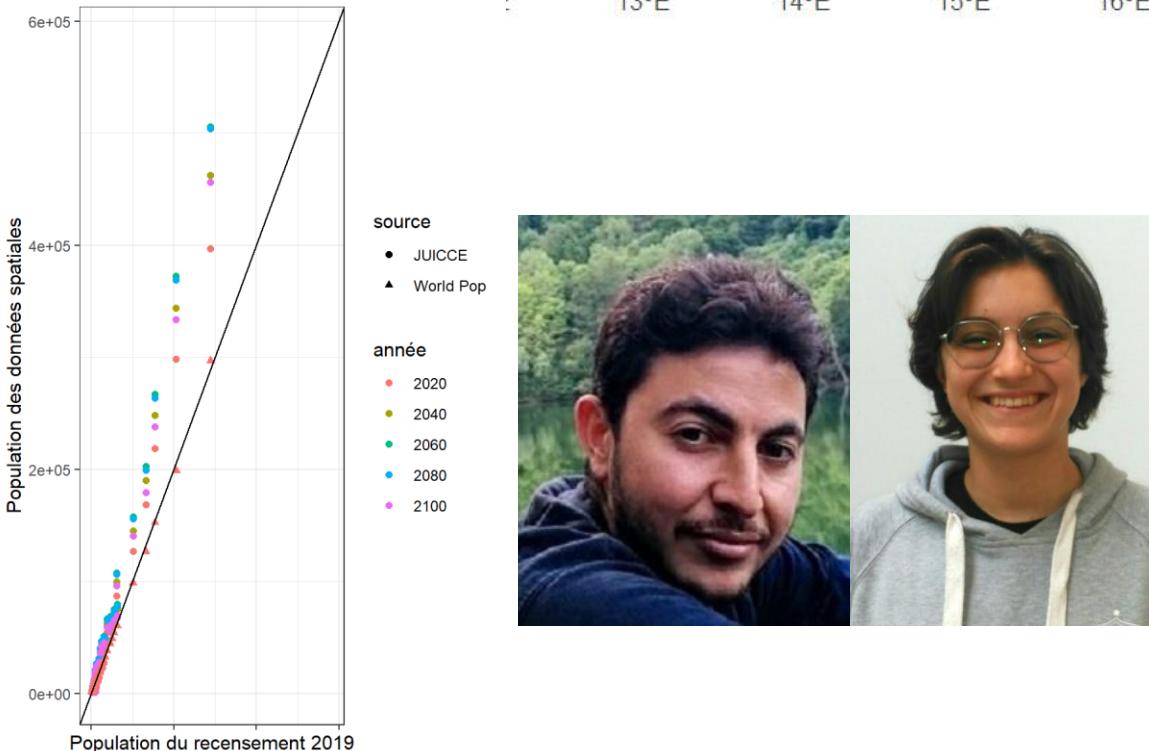
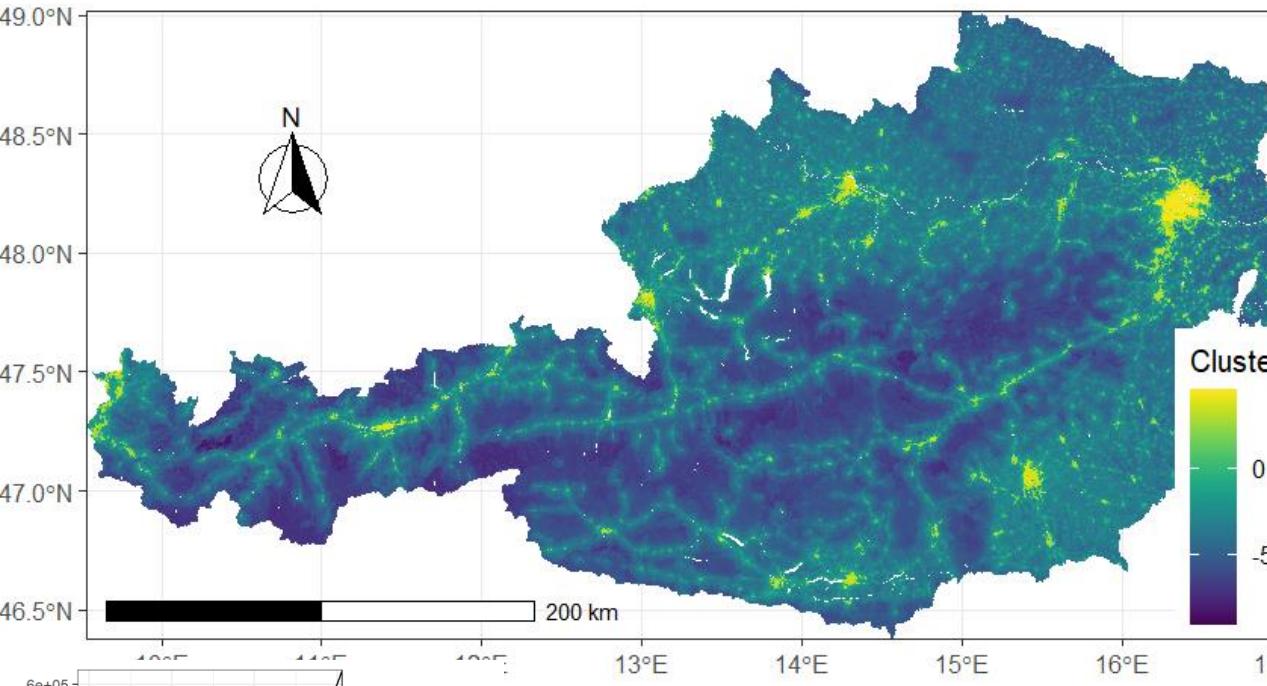
Knowledge transfer

- Workshops with policy and decision makers
 - Open science
 - Scientific outreach

HEATWAVES MAPPING

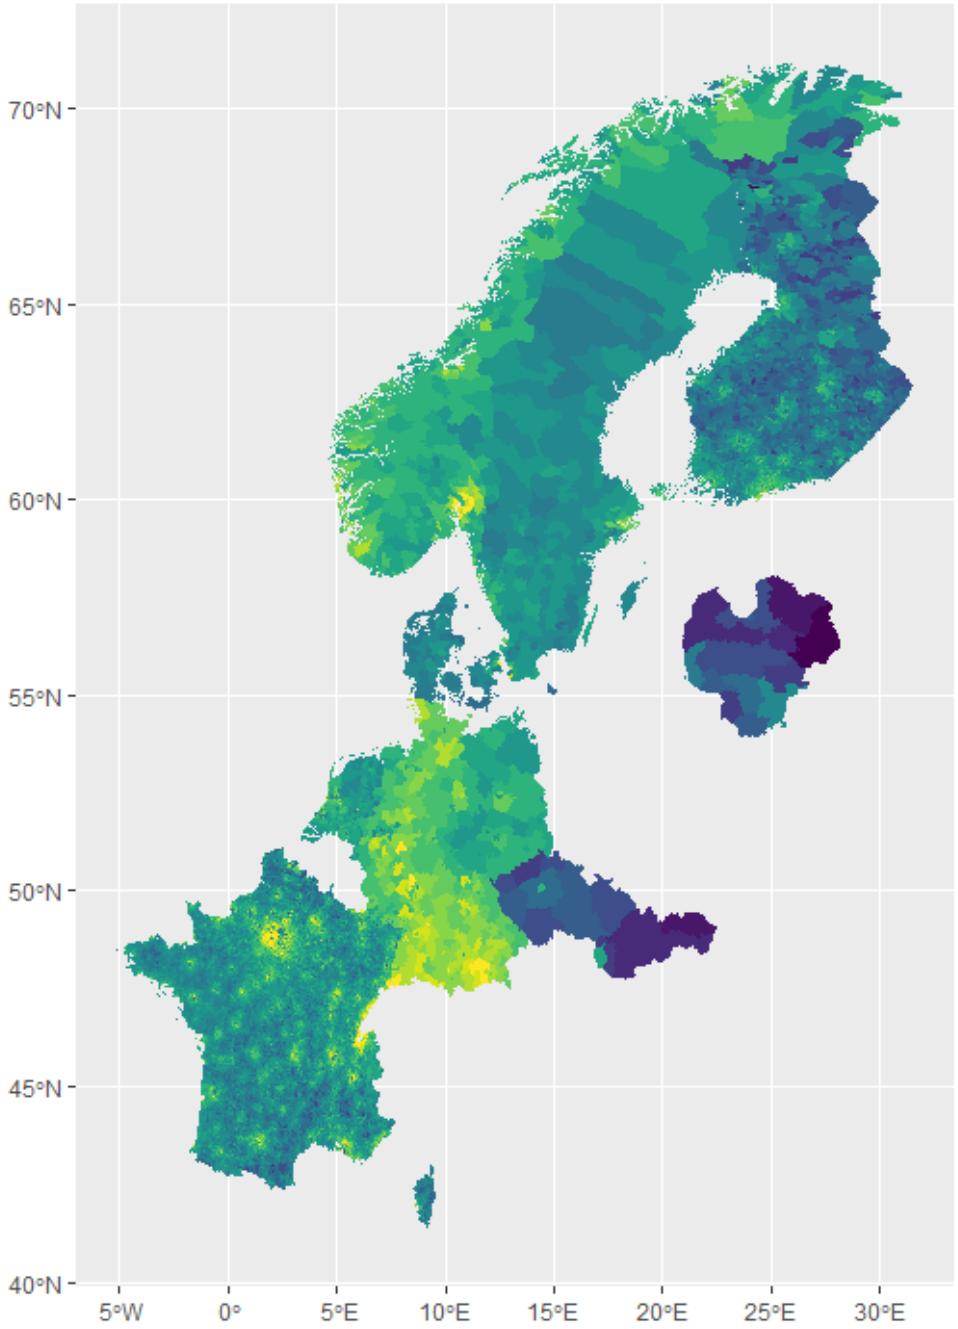
Philémon Poux
Clément Devenet





SPATIALLY EXPLICIT PROJECTIONS OF POPULATION (AGE, GENDER)

Mehdi Mikou
Juliette Piketty-Moine

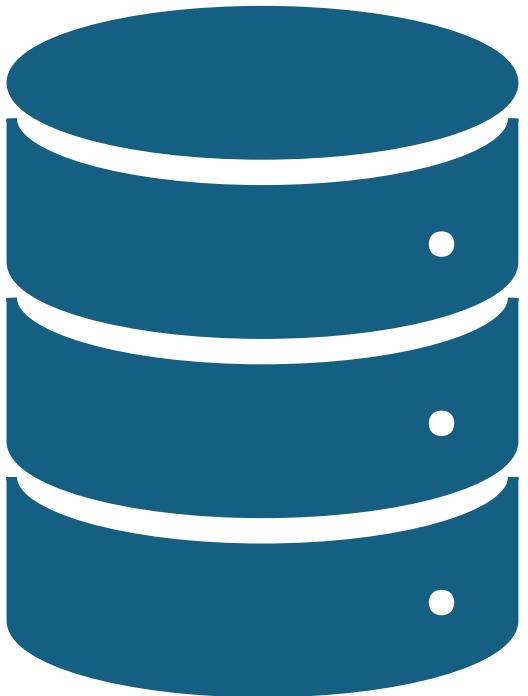


INCOME MAPPING AND PROJECTIONS

Thérèse Blanchet
Mehdi Mikou



- Demographic, economic and climatic spatial datasets
- High resolution (large volume of data)



Thank you!

Améline Vallet
ameline.vallet@agroparistech.fr