

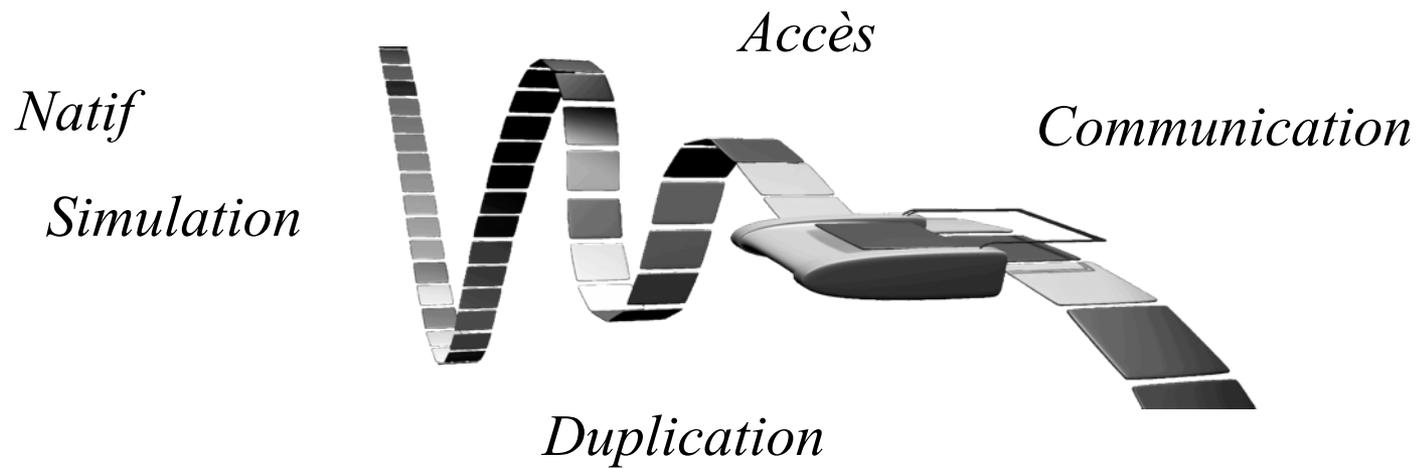
# La pérennisation des données numériques

Nicolas Larrousse, Michel Jacobson, Adrien  
Desseigne, Joel Marchand

Huma-Num

Les rencontres d'Huma-Num – Lyon - 11-14-juin-2018

# Des Humanités Classiques aux Humanités Numériques



# Des données coûteuses à produire



*Encodages de  
textes*



*Numérisations  
manuscrits*



*Modélisations  
3D*



*Transcriptions  
d'enregistrements*

...

# Une typologie foisonnante



*Textes*

*Transcriptions*

*Enrichissements*

*Sons*



*Vidéos*

*Images*

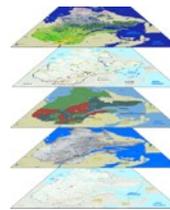


*Enregistrements  
physiologiques*

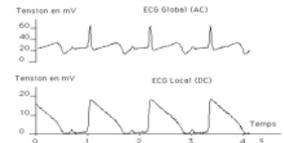
*Modèle 3D*



*Cartes*



*Géomatique*



*Données SIG*



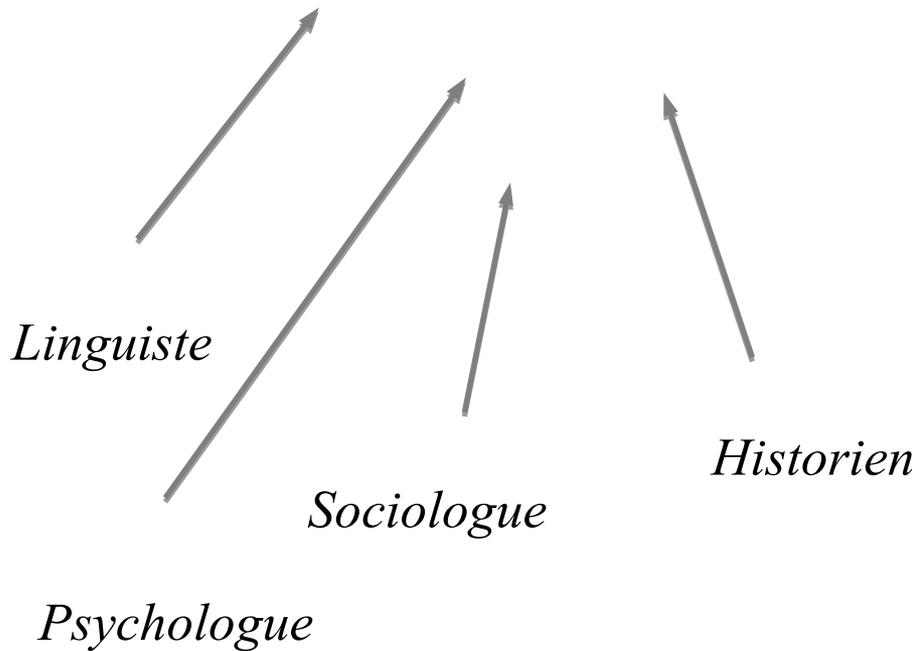
*SMS*

...

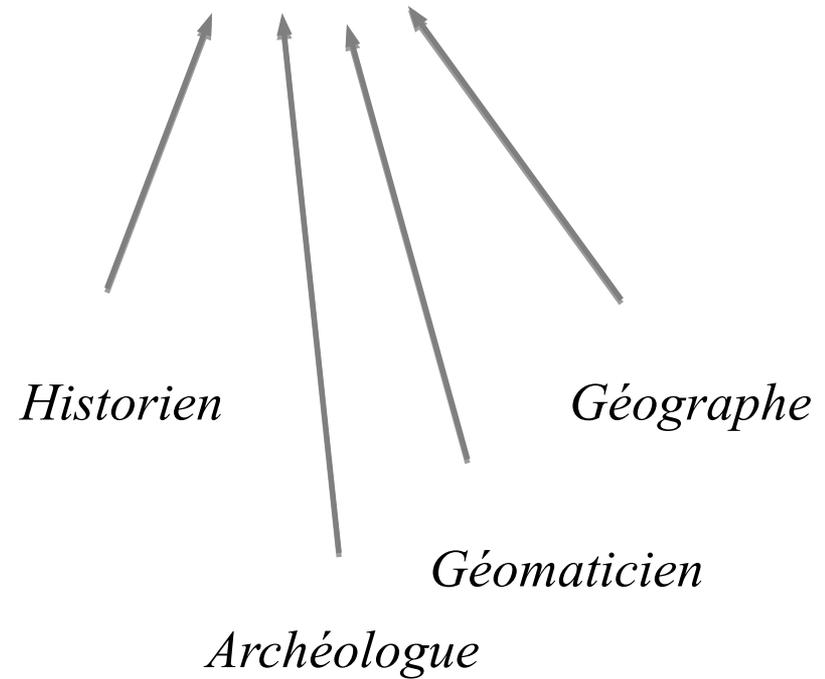
# Les données de la recherche en SHS

## Des usages multiples pour une même donnée

*Enregistrement  
Sonore*



*Carte*



# Un intérêt patrimonial

*Données de l'archéologie*



*Enregistrements de langues disparues*

*Musique*



*Numérisation de manuscrits plus consultables*



# Peu d'intérêt des tutelles

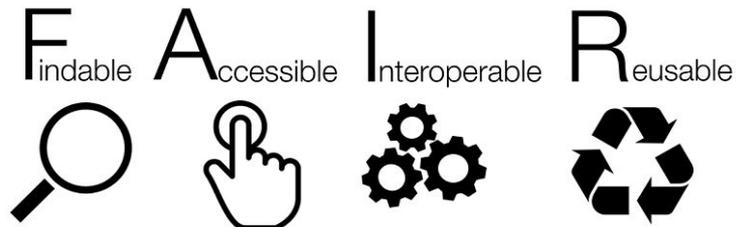
*Définition des données de la recherche ?*

*Travail non valorisé pour la carrière d'un chercheur*

*Coûts en général non intégrés dans les projets*



*Un timide avancée avec le  
« Data Management Plan »  
du programme H2020*



...



# SERVICES POUR LES DONNÉES NUMÉRIQUES

Huma-Num propose des services pour les données numériques produites en SHS.  
A chaque étape du cycle de vie des données correspond un service dédié.



## STOCKER

Entreposer . Organiser

## ARCHIVER

Préservation à long terme



## TRAITER

Outils . Logiciels

## SIGNALER

Enrichissement sémantique  
Accès unifié



isidore



**DONNÉES  
DE LA RECHERCHE**

Partenariat avec le CC-IN2P3  
et le CINES



## EXPOSER

Documenter . Partager



nakala

nakal(©)na



## DIFFUSER

Machines virtuelles  
Diffusion web



# La pérennisation des données numériques

Comment bien perdre ses données ?

- Vous ne savez pas comment relire une cartouche Iomega JAZ
- Votre disquette 3½ pouces est endommagée
- Vous avez effacé par mégarde le dossier où était votre fichier
- Le codec utilisé pour votre image n'est plus reconnu par aucun de vos outils
- Vous ne savez plus comment se nomme le fichier ni sur quel disque vous l'avez mis
- Vous avez 40 exemplaires d'un même fichier mais vous ne savez pas lequel est le bon
- La lecture de votre fichier par la nouvelle version du logiciel vous donne un autre résultat qu'avant
- Vous ne pouvez plus installer votre unique outil de visualisation sur la nouvelle version de votre système d'exploitation
- Vous revenez 10 ans plus tard sur un de vos fichiers, mais vous ne comprenez plus sa structure ni son contenu que vous n'avez jamais documenté
- ...



# La pérennisation des données numériques

## Les causes de la perte

- Obsolescence
- Vieillessement
- Mauvaises manipulation
- Manque d'organisation
- Manque de documentation
- ...

# La pérennisation des données numériques

## 1. Organiser ses données

- Définir un plan de nommage
  - Simple, court, documenté, durable
  - Éviter quelques chausse-trapes (accents, espaces, casse,...)
- Exemple : le plan de nommage de l'IRHT pour la cotation d'un manuscrit numérisé:
  - 2 chiffres du département
  - 3 chiffres de la commune
  - 2 chiffres indiquant le type de bibliothèque
  - 2 chiffres, séquentiel, allant de 01 à 99
- Exemple pour Chartre = 280856201\_MS1038\_t1

# La pérennisation des données numériques

## 1. Organiser ses données

- Définir un plan de classement
  - Pas trop profond
  - Classificatoire : tout fichier à une place et une seule possible
- Exemple du plan de classement de l'IRHT
  - Pays/Ville/Etablissement/TIFF/Cote\_manuscript/

# La pérennisation des données numériques

## 1. Organiser ses données

- Choisir ses formats
  - Ouvert, libre, normalisé, largement utilisé, existence d'outils de contrôle de conformité
- Cf. Guide méthodologique du CINES et la liste des formats acceptés ([facile.cines.fr](http://facile.cines.fr))

# La pérennisation des données numériques

## 2. Stocker ses données

- Avoir plusieurs copies des données
  - Sur des lieux distants (lutte contre des sinistres type incendie, inondation...)
  - Sur des types de support et ou d'accès distincts (lutte contre les risques de marché [éditeur défaillant ou arrêtant son support] ou d'attaques)
- Définir une politique de sauvegarde
  - Combien de copies sont gardées ? Combien de temps ? À quelle périodicité ? (lutte contre les fausses manipulations)
- La chasse aux doublons
  - Les différentes copies ne doivent pas être isolées mais répondre à une organisation, une synchronisation et idéalement offrir une vue unifiée sur les données

# La pérennisation des données numériques

## 3. Décrire ses données

- Les données doivent être associées à des descripteurs
  - Métadonnées de provenance, de contexte, d'identification, d'intégrité, de droits, de codage, etc.
- Il existe des standards pour exprimer ses métadonnées
  - Dublin-Core
  - EAD
  - CIDOC-CRM
  - EDM
  - ...
- Il vaut mieux expliciter dans un simple format texte non standardisé que de garder ces informations dans sa tête.

# La pérennisation des données numériques

## 4. La pérennisation à long-terme

- Objectif : maintenir l'authenticité, l'intégrité la traçabilité et la lisibilité de l'information
  - Migrations des supports et des formats (lutte contre le vieillissement et l'obsolescence)
  - Apporter la preuve que l'information n'a pas été altérée. Le cas échéant, restauration de données dégradées à partir de copies intègres
  - Journalisation de toutes les opérations sur les archives
  - Apporter la preuve de la provenance (qui, quand, quoi) des informations

# La pérennisation des données numériques

## Le dispositif en collaboration avec le CINES

- Couvre la partie 4
- Demande à ce que les parties 1 à 3 soient déjà franchies
- S'ajoute une partie administrative (ouverture de compte), une explicitation des règles de gestion (statut des archives, durée de conservation, communicabilité), une partie protocolaire (organisation des échanges), éventuellement des travaux préalables pour la prise en charge de nouveaux formats
- Représente pour le producteur l'avant chambre des Archives nationales
- Il s'agit d'un transfert de la responsabilité de la conservation

# La pérennisation des données numériques

## Pérenniser des données numériques

- Ne peut pas se faire sans le producteur. C'est lui qui en connaît le contenu, le contexte de production/collecte, l'usage envisagé.
- Ne peut se faire tout seul. Il faut d'autres compétences que scientifique ou du domaine. Compétences techniques numériques, compétences archivistiques
- Le coût humain est important
- Les délais sont généralement assez longs : on compte plutôt en années

# La pérennisation des données numériques

## Métaphores possibles

- L'archivage comme l'alpinisme. On ne part pas seul, on s'entraîne avant, ça va être dur, ça va être long, ça va être coûteux. On y va par étapes progressivement : promenade en pleine, en montagne à vaches, petite course. Bien maîtriser chaque étape avant de passer à la prochaine.
- Photo de classe ou de famille dont plus personne ne sait qui est dessus. Ce qu'on transmet aux futurs chercheurs doit être décrit maintenant avant que les souvenirs ne s'effacent.
- Pyramide des besoins : la base correspond à la production de données, le sommet à ce qui est préservé pour les futures générations.
- INA : 10 % du budget pour l'infrastructure, 90 % pour la description.



*Un projet pilote basé sur les  
données orales*

*Un besoin « urgent »*

*S'appuyer sur des ressources  
existantes et les adapter*

*Regrouper les objets en collections*

*Prise en compte de nouveaux formats*

*Metadonnées spécifiques*

*Notion de version*

*Fonctionner sur le long terme dans un environnement instable ...*

# Le rôle de l'infrastructure Huma-Num



## Identification des besoins

*Repérage en collaboration avec les communautés*

*Identification des formats de données et de métadonnées*

## Accompagnement des projets d'archivage

*Sélection et organisation des données à préserver*

*Appui technique*

## Faire le lien avec les autres organismes



*Lien avec les institutions d'archives et les autres partenaires*

*Sensibilisation des tutelles et des agences de financement*



## Quelques effets secondaires attendus du service de préservation

*Une prise en compte de l'importance des données dès le début du projet*

*Une incitation à produire de « meilleures » données*

*Préparer l'interopérabilité des données*

## **Quelques perspectives pour la préservation**

### **Un évidente fragilité des données**

*Les migrations permanentes des données ne les préservent pas*

*Des pertes par simple ignorance*

### **Une prise de conscience nécessaire**

*Informier les producteurs dès le début du projet*

*Promouvoir de bonnes pratiques*