

---

# CONSTRUIRE ENSEMBLE LE PATRIMOINE NUMÉRIQUE NATIONAL

---

LE PROJET CORPUS À LA BNF

Emmanuelle Bermès

COLLECTER  
LES RESSOURCES

SIGNALER  
LES RESSOURCES

CONSTITUER LES  
COLLECTIONS

ENRICHIR LES  
COLLECTIONS

CONTEXTUALISER  
LES RESSOURCES

MAÎTRISER  
LES RESSOURCES

« Encourager  
le partage et la dissémination  
des savoirs »

*Contrat de performance  
2017-2021*

TOUTE  
DISCIPLINE

TOUT  
PUBLIC

1 Mythes fondateurs

INTEROPERABILITÉ  
TOTALE

MAITRISE  
PARFAITE  
DES ACCÈS

EXHAUSTIVITÉ  
DES CORPUS

TEMPS  
CONTINU

AUTONOMIE TOTALE  
DU CHERCHEUR

CAPACITÉS  
TECHNIQUES  
INFINIES

GRANULARITÉ  
PARFAITE

PERFECTION  
DES ALGORITHMES

UNIVERSALITÉ DE LA  
(DATA)VISUALISATION

EXHAUSTIVITÉ  
DE LA  
DOCUMENTATION

TRACABILITÉ  
REVERSIBILITÉ

LIBERTÉ  
JURIDIQUE

2 Parcours dans  
les collections

Esprit

# Gargantua

soif intarissable de données,  
travail sur d'énormes corpus  
qui s'enrichissent continument

« Et lui furent ordonnées dix et sept mille neuf cents treize vaches pour l'allaiter ordinairement »

Gustave Doré, 1854

Source [gallica.bnf.fr](http://gallica.bnf.fr) / Bibliothèque nationale de France





# Projet OBVIL

## Common places

Fourniture de  
135 000  
fichiers ALTO  
à des fins de fouille  
de texte

Site internet :  
<http://obvil.lip6.fr/tgb/>

2 Parcours dans  
les collections

Esprit

# Arcimboldo

rassembler puis étudier des sources éparses  
et/ou hétérogènes

*Vertumne*

Giuseppe Arcimboldo, 1590

Château de Skokloster



## Contenu mis en avant

### HÔTEL BELLEVUE, BRUXELLES



## Collection mise en avant

Aucune collection n'est mise en avant.

## Mettre en avant cette exposition

Vous n'avez aucune exposition mise en avant.

## Contenus ajoutés récemment

### OTTO VON BISMARCK

Homme politique allemand

# Projet GRIPIC/ CELSA

# Giranium

Analyse de 300 lettres autographes d'Émile de Girardin conservées à l'Institut et mise en relation avec d'autres documents (manuscrits, presse, revues...)

Site internet :

<http://vintagedata.org/giranium/>

2 Parcours dans  
les collections

Esprit

# Duchamp

donner à (re)lire des contenus déjà existants,  
déjà connus

L.H.O.O.Q.

Marcel Duchamp, 1919

© Adagp, Paris

© Centre Pompidou, MNAM-CCI/ Georges Meguerditchian



L.H.O.O.Q.

Marcel Duchamp 1919

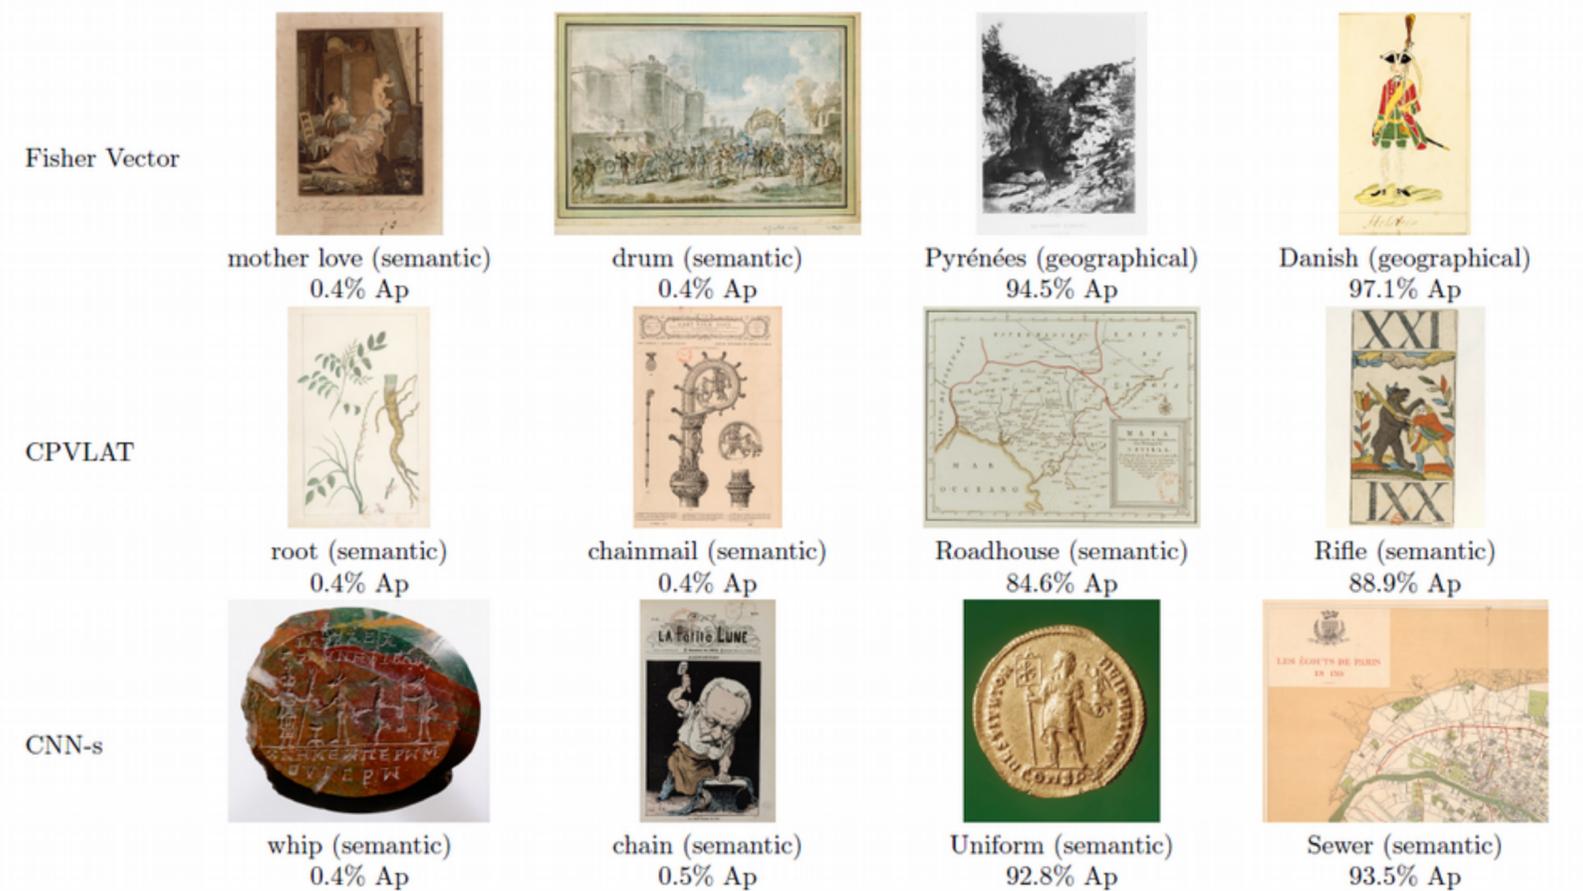


Fig. 4. Examples of bad (left) and good (right) performing classes for various features.

Utilisation d'images issues de la banque d'images de la BnF pour entraîner un algorithme d'indexation sémantique

# Laboratoire ETIS

# Projet ASAP

David Picard, Philippe-Henri Gosselin, Marie-Claude Gaspard  
 « Challenges in Content-Based Image Indexing of Cultural Heritage Collections. » *IEEE Signal Processing Magazine*, Institute of Electrical and Electronics Engineers, 2015, 32 (4), pp.95 – 102  
 Corpus : <http://images.bnf.fr>

2 Parcours dans  
les collections

Esprit

J. Cook

explorer, décrire et analyser un terrain  
inconnu

A general chart of the Island of Newfoundland with the rocks & soundings

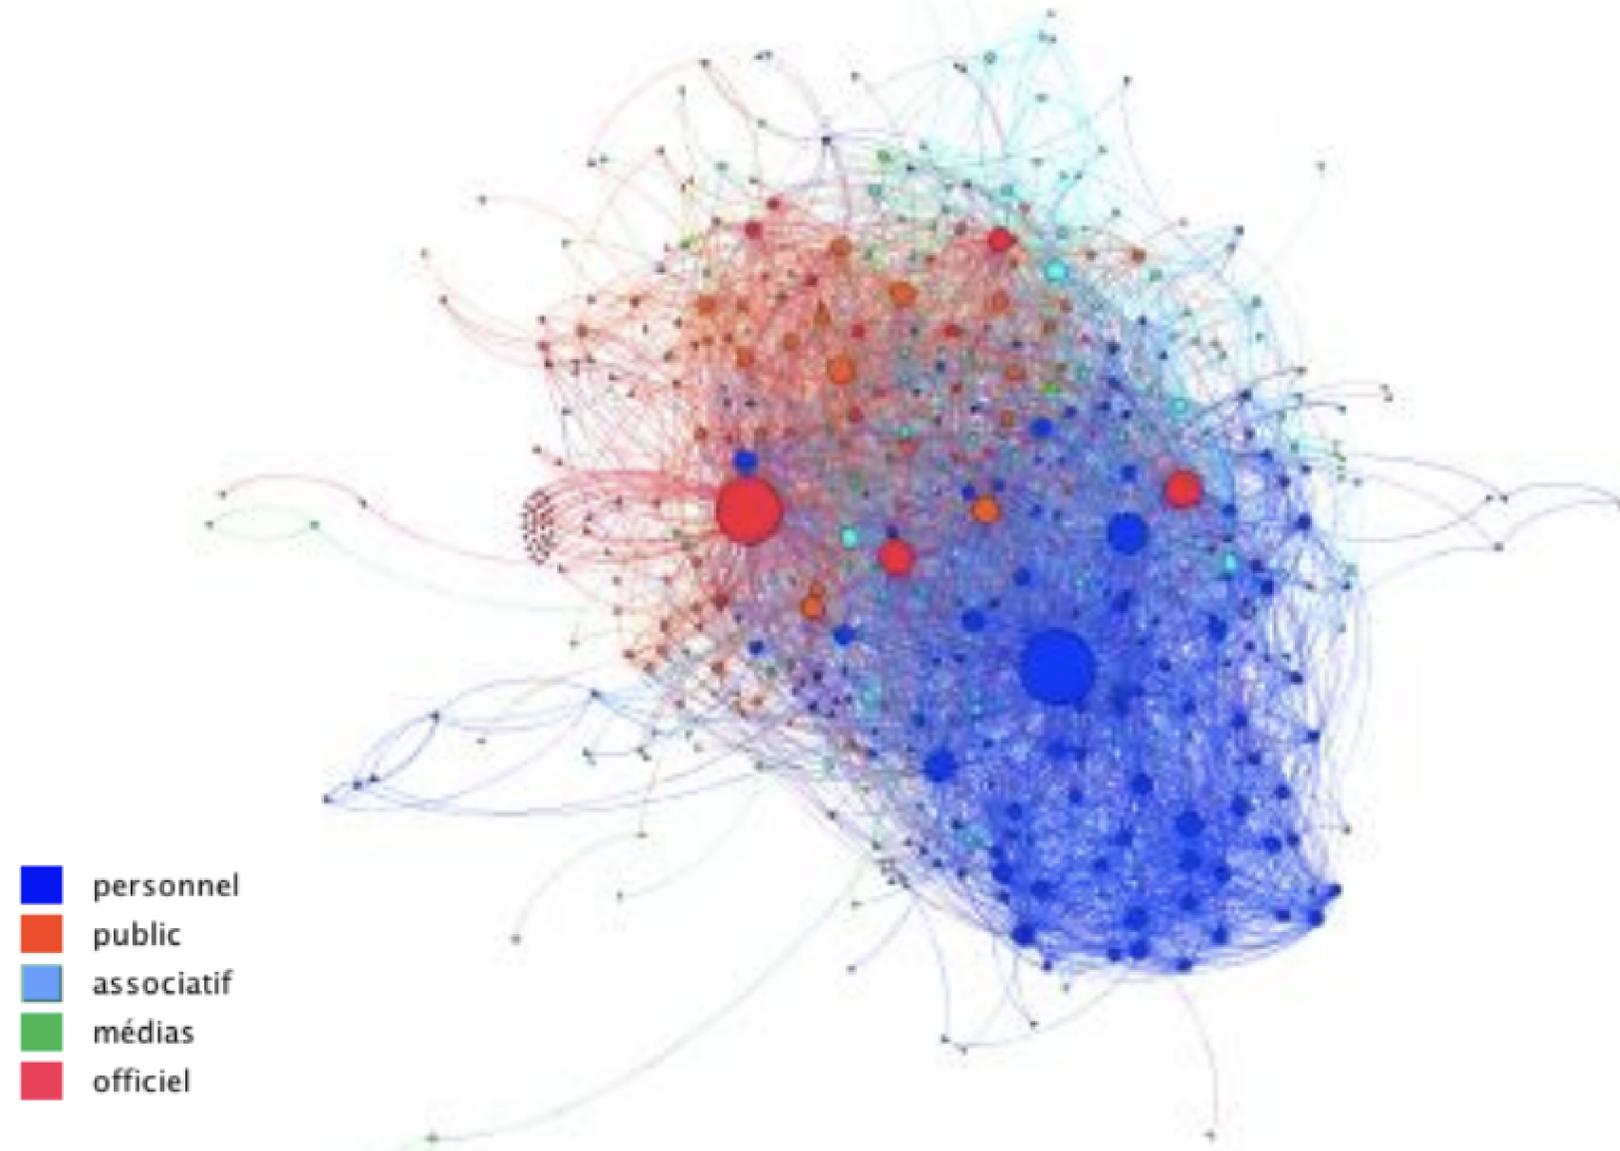
Thomas Jefferys, 1771

McMaster University Digital Archive :

<https://digitalarchive.mcmaster.ca/islandora/object/macrepo%3A21591>

{BnF} Bibliothèque  
nationale de France





Projet Labex Les passés dans le présent

**Le devenir en ligne du patrimoine**

**numérisé : l'exemple de la Grande Guerre**

<https://hal.archives-ouvertes.fr/hal-01425600>

2 Parcours dans  
les collections

Esprit

# Picasso

façonner une nouvelle forme de patrimoine

Portrait de Dora Maar

Pablo Picasso, 1937

© Succession Picasso/ Musée Picasso





# Projet Gallica Studio GallicaPix

Développé par Jean-Philippe Moreux (BnF) et Guillaume Chiron (L3i) un module de recherche d'images par le contenu qui fouille dans les collections d'images et d'imprimés de Gallica relatives à la Première Guerre Mondiale (période 1910-1920). Il repose sur différentes techniques d'intelligence artificielle (réseaux de neurones) et sur l'API IIF pour l'affichage des images.

Site internet :

<http://demo14-18.bnf.fr:8984>

« Offrir aux chercheurs,  
dans les emprises  
de la Bibliothèque, des outils  
de fouille et d'exploration  
de textes et de données sur des corpus  
numériques de la BnF. »

Contrat d'objectifs et de performance 2017-2021

Offrir aux chercheurs, dans les emprises de la Bibliothèque, des outils de fouille et d'exploration de textes et de données sur des corpus numériques de la BnF

► Proposer des environnements scientifiques et techniques (plate-forme sécurisée, logiciels, assistance d'experts...) pour explorer, dans le respect des dispositions réglementaires, les corpus numériques de la BnF

CONTRAT D'OBJECTIFS  
ET DE PERFORMANCE 2017-2021



{ BnF | Bibliothèque  
nationale de France

## Le programme de recherche CORPUS de la BnF

Un projet inscrit au plan quadriennal de la recherche de la BnF 2016-2019

### Objectifs :

- préfigurer un service de fourniture de corpus numériques à destination de la recherche
- fournir à des chercheurs des données et des outils pour les analyser, dans le respect du droit d'auteur et de la vie privée

3 années d'expérimentation (archives web, numérisation, métadonnées) + 1 année de bilan

**4**  
ans

**3**  
« collections »  
numérisées ou  
nativement  
numériques

**2020**  
horizon

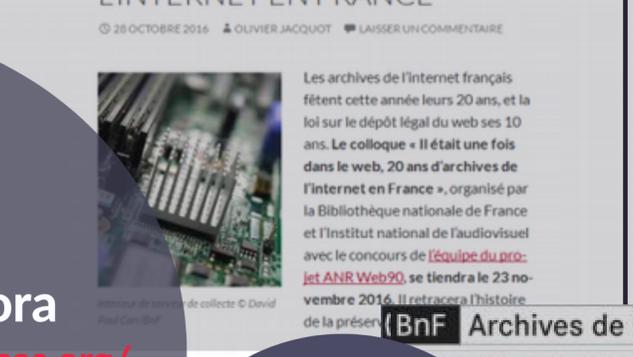
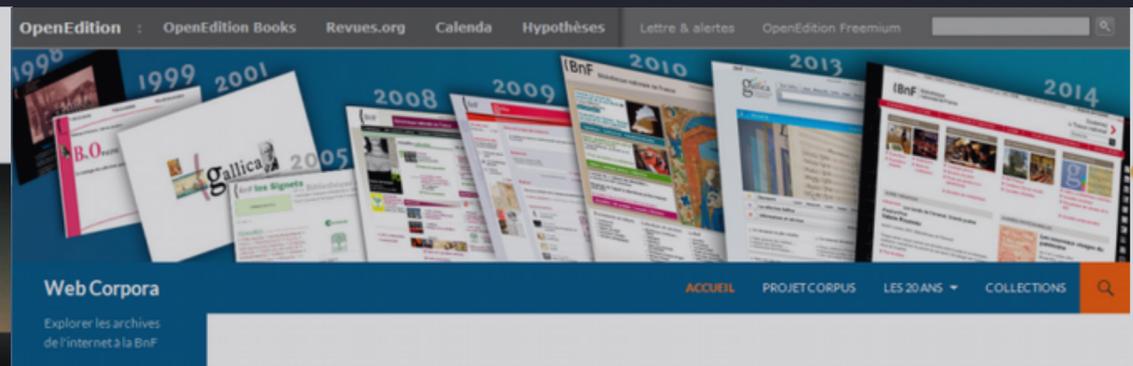
→ Fiche dans la base ANIR :  
→ <http://c.bnf.fr/fom>

# ANNÉE

# 1

« Il était une fois dans le web : 20 ans d'archives de l'Internet en France »  
Journée d'étude co-organisée par la BnF, Vidéos :

<http://c.bnf.fr/fse>



Étude de besoins  
<https://hal-bnf.archives-ouvertes.fr/hal-01739730v1>

Émile de Girardin

Prince de la Presse



Le portail BnF API et jeux de données décrit et documente l'ensemble des API qui permettent d'interroger et de récupérer les métadonnées des catalogues (notamment BnF Catalogue général, data.bnf.fr, Gallica) et les collections numérisées de la BnF. Pour faciliter l'accès aux données et leur utilisation, des jeux de données (images et textes, métadonnées, statistiques) sont directement téléchargeables via le portail.

Plusieurs formats, plusieurs technologies permettent de répondre à la diversité des usages des données de la bibliothèque : alimentation de catalogues, création de nouveaux services innovants, fouille de données, datavisualisation, etc.

Développeurs et développeuses, chercheurs et chercheuses, amateurs et amatrices de culture, les données et métadonnées diffusées par la BnF n'attendent plus que vous !

Site internet API et jeux de données

<http://api.bnf.fr>

Projet de recherche  
GIRANIUM

{BnF

Le projet  
Corpus et  
ses publics  
potentiels.

UNE ÉTUDE PROSPECTIVE SUR  
LES BESOINS ET LES ATTENTES  
DES FUTURS USAGERS.

Eleonora Molraghi, assistante de recherche  
sur le programme de recherche Corpus porté  
par la Bibliothèque nationale de France

Janvier 2018

# 3 Le projet Corpus Les besoins

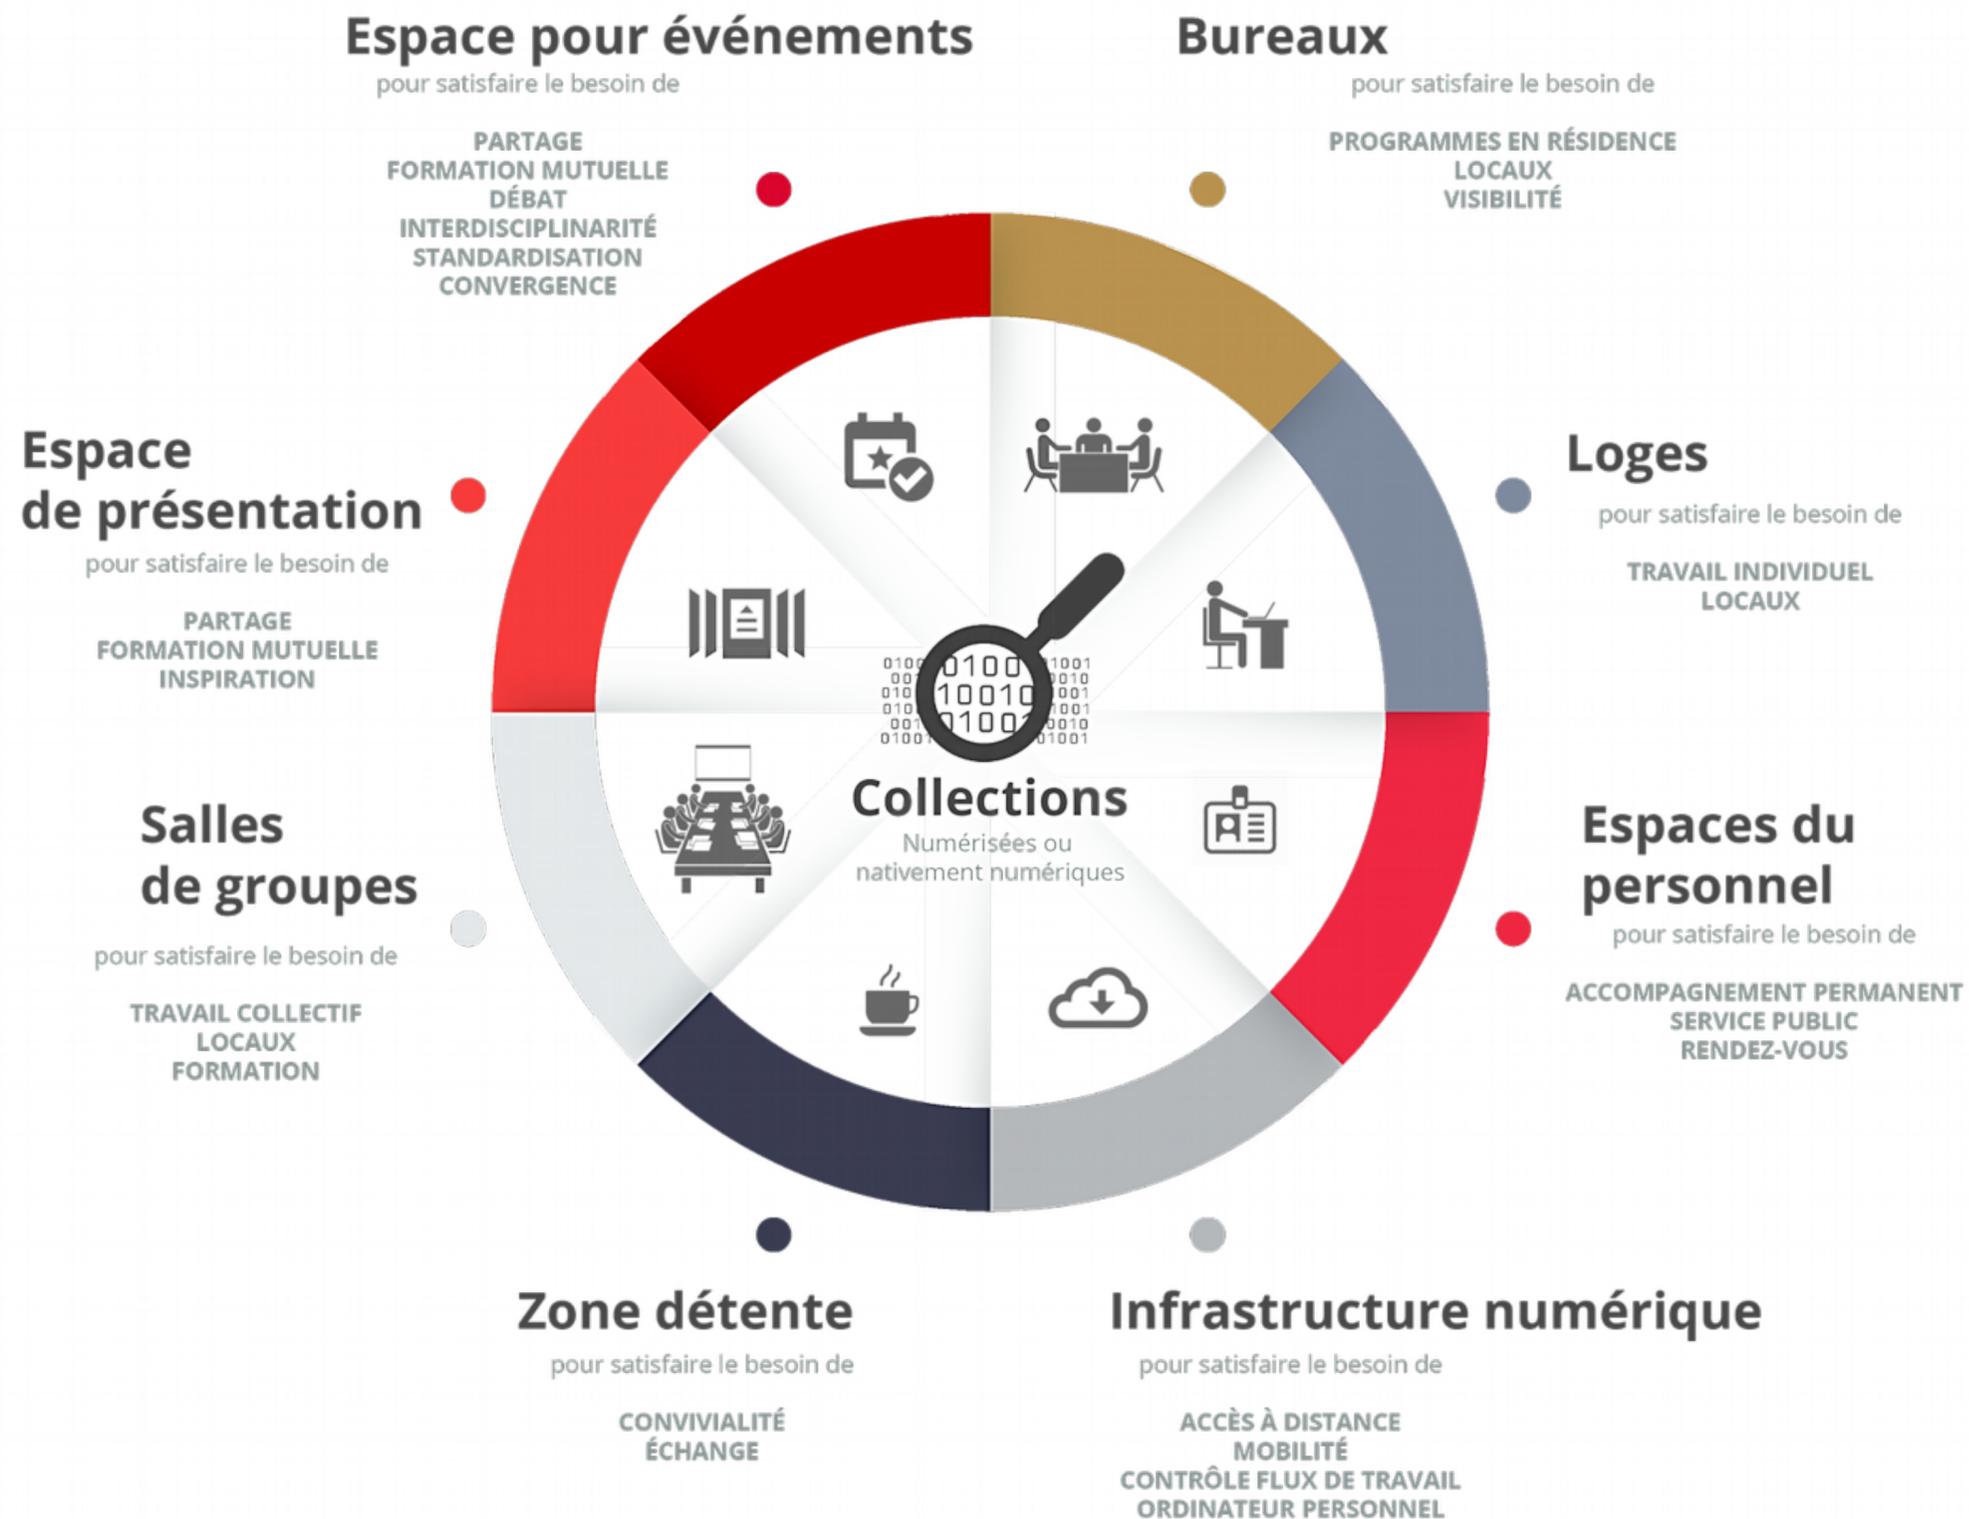
ACCÈS OU  
FOURNITURE  
DE DONNÉES

ACCOMPAGNEMENT  
ET FORMATION  
AUTOUR DES  
DONNÉES ET DES  
POLITIQUES  
DOCUMENTAIRES

ANIMATION D'UNE  
COMMUNAUTÉ  
INTERDISCIPLINAIRE

ORIENTATION ET  
REDIRECTION

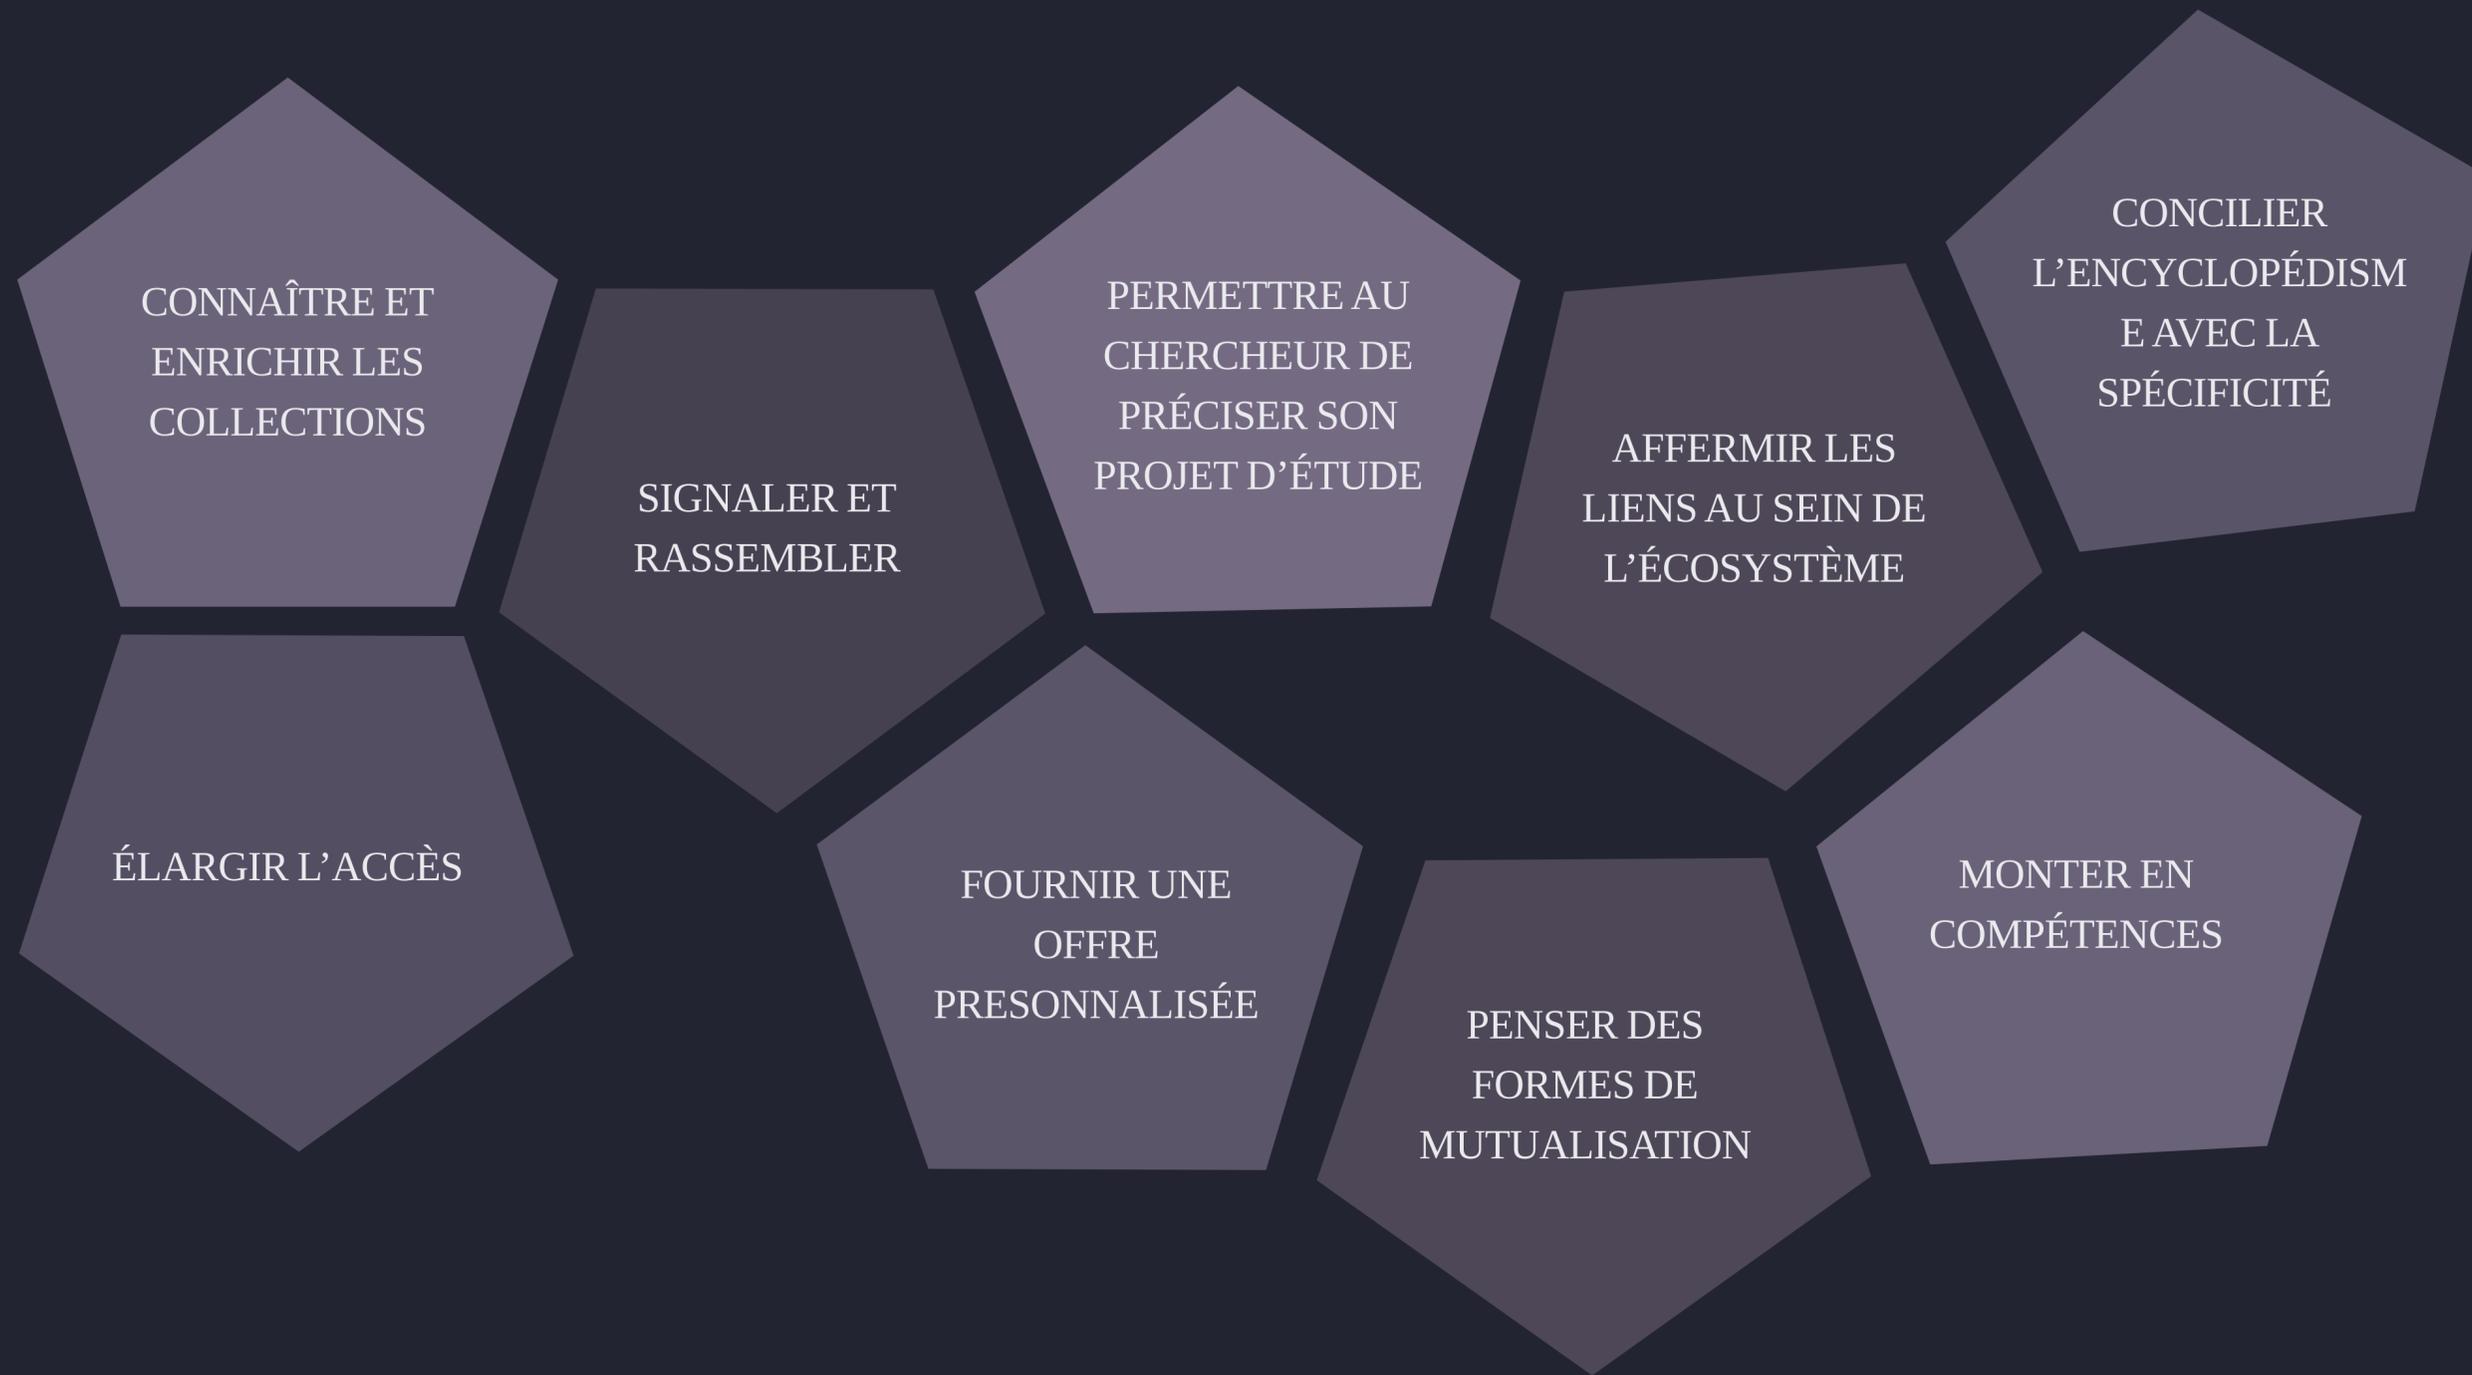
VALORISATION ET  
RÉINTÉGRATION  
D'OUTILS OU  
RÉSULTATS



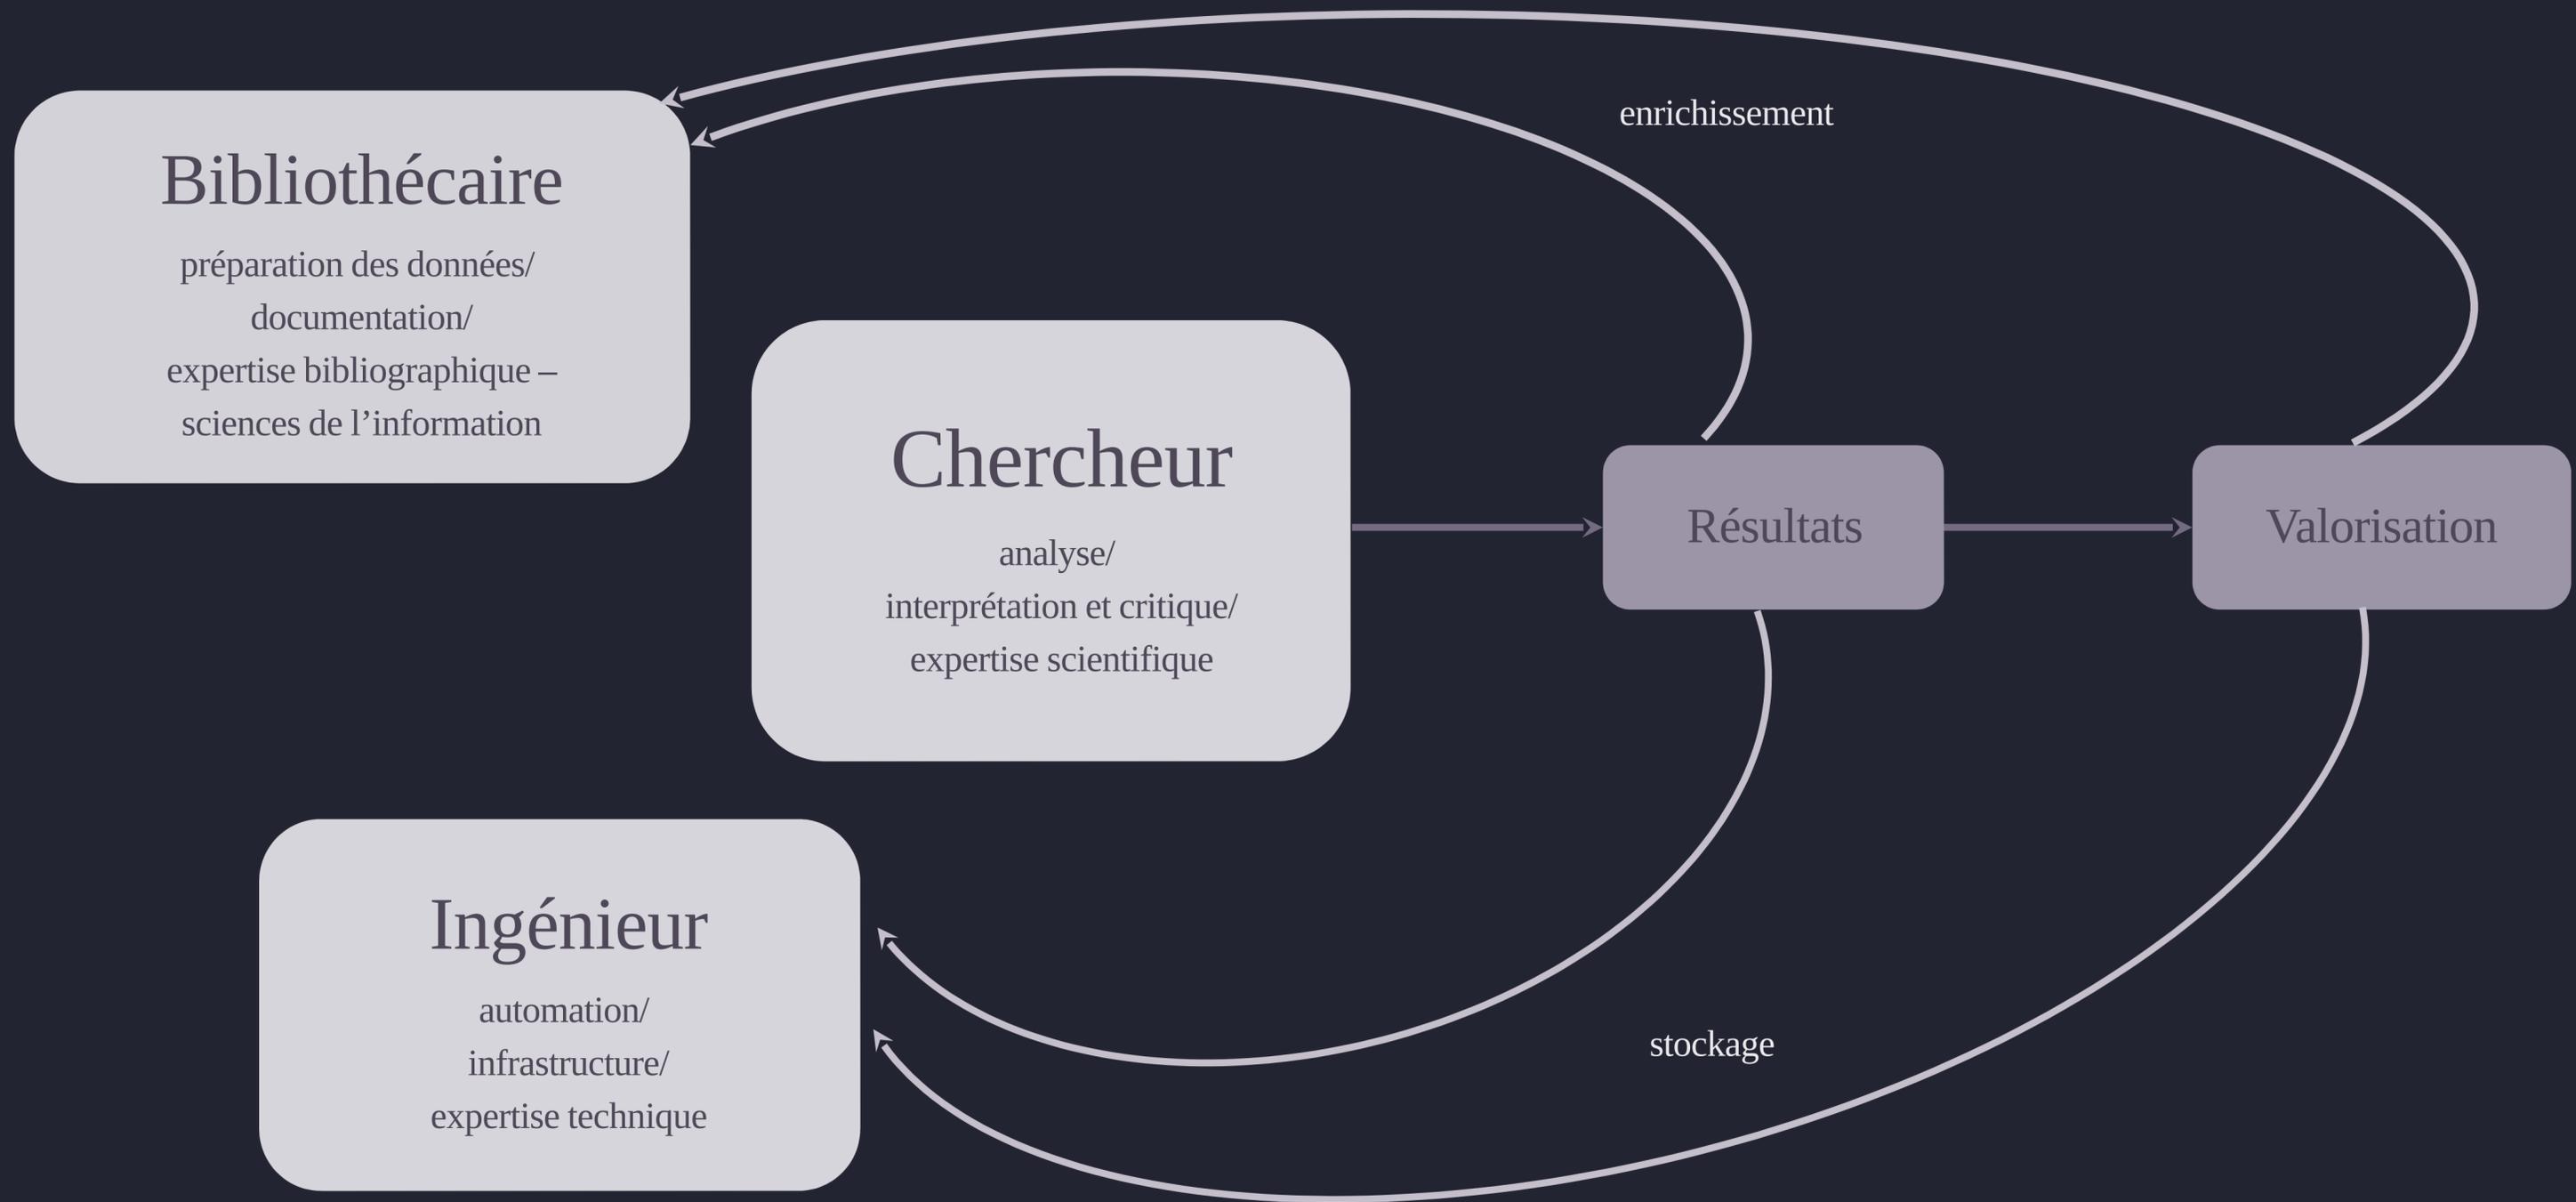
# 3 Le projet Corpus

## Les enjeux

---



# 4 Comprendre et exploiter les données ensemble



**AVEZ-VOUS  
DES QUESTIONS ?**

**AVEZ-VOUS  
DES QUESTIONS ?**

**MERCI  
DE VOTRE  
ATTENTION !**