



# NATIONAL LIBRARIES AS SERVICE PROVIDERS FOR RESEARCH: BNF CASE STUDY

By Emmanuelle Bermès and Jean-Philippe Moreux



**Delivering BnF digital collections to researchers in order to allow them, on-site, to perform computational analysis of digital corpora »**

---

**Performance and strategic report 2017-2021**

# CORPUS, a BnF research project

---

Part of the BnF's 4-year internal research programme 2016-2019

## OBJECTIVES :

- Designing a future service for providing access to digital corpora for researchers
- Providing researchers with data and tools to analyse them, in agreement with IPR and privacy legislation

3 years of experimentation (web archives, digitization, metadata) + 1 year for conclusions

4            3            2020            →<http://c.bnf.fr/fom>  
years        digitized        by  
                and born-digital  
                collections

# Founding myths



# The Gargantua way

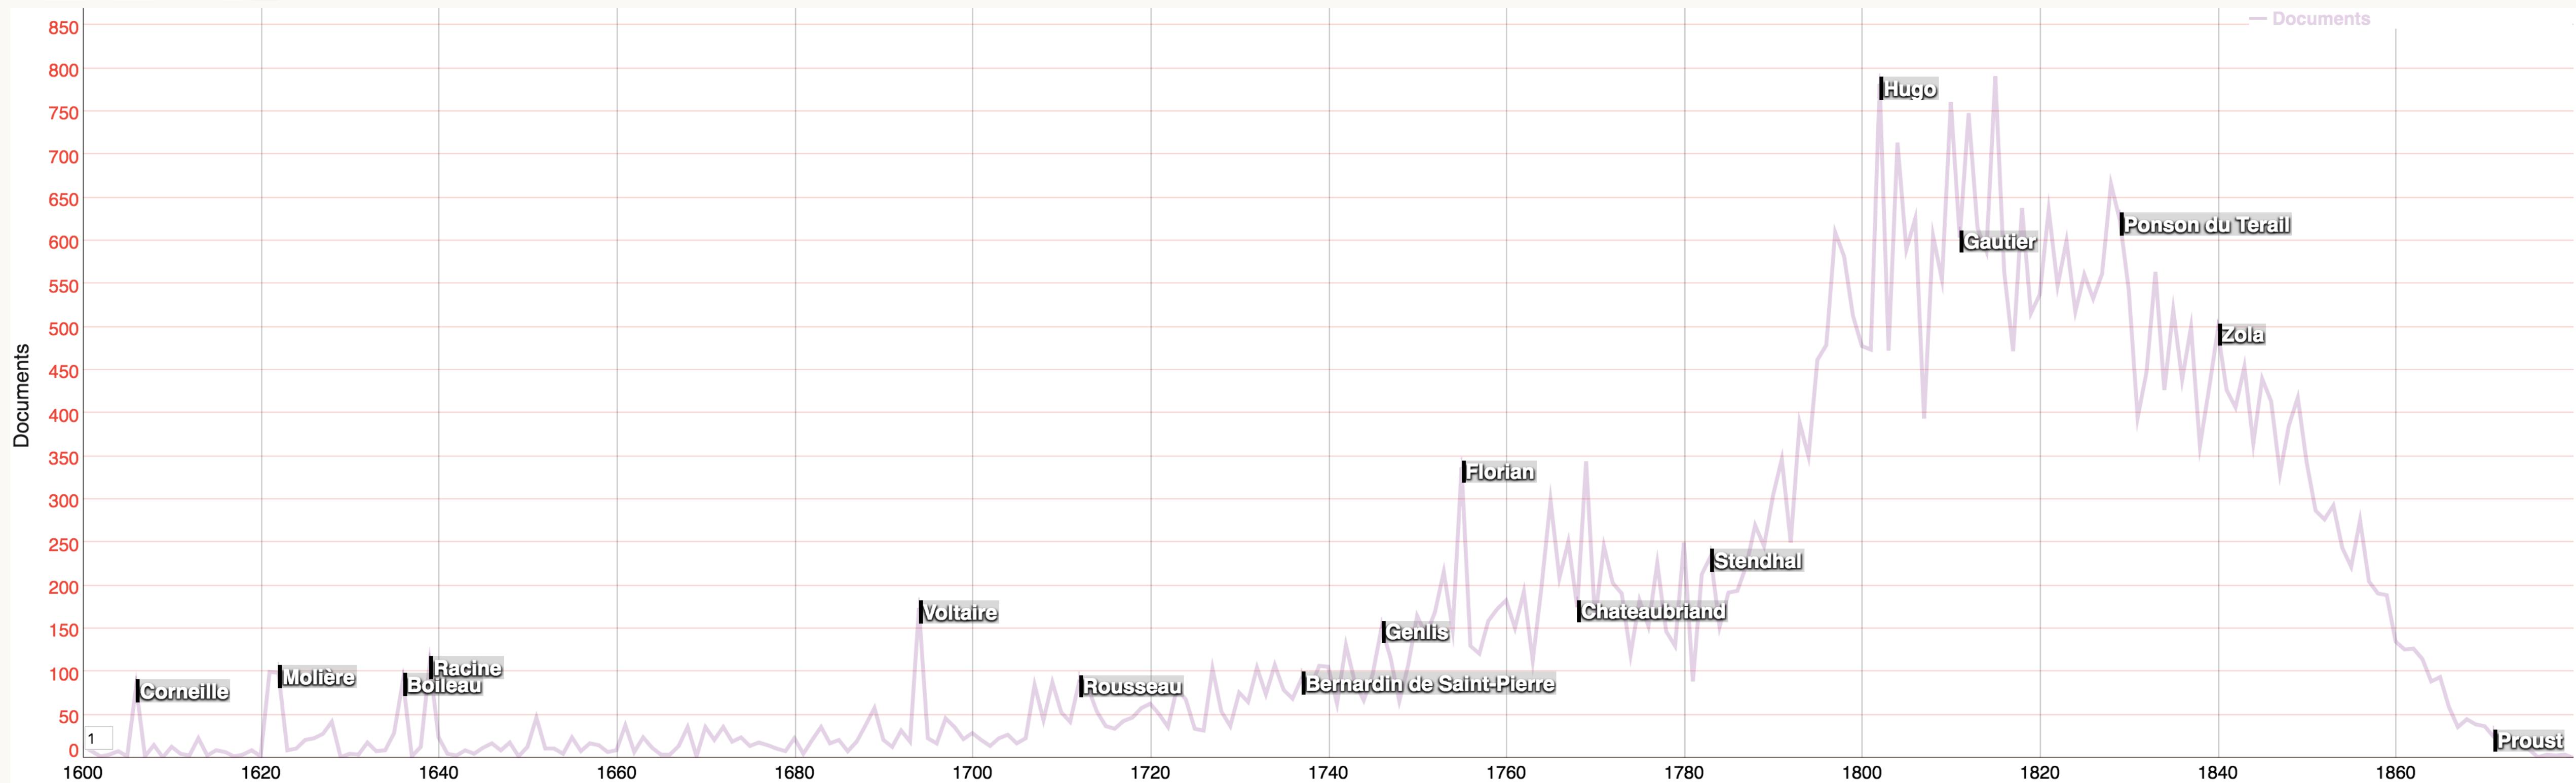
inexhaustible thirst for data,  
work on huge corpora  
continually enriched

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

Gustave Doré, 1854

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





# OBVIL “Très Grande Bibliothèque” project

{ BnF | Bibliothèque  
nationale de France

135,000  
monographs  
delivered  
for text mining

Website:  
<http://obvil.lip6.fr/tgb/>  
<http://api.bnf.fr/documents-de-gallica-produits-au-format-tei-par-obvil>

L'Encyclopédie

Author "Diderot" x

**author = Diderot**

None

TGB

1

L'Encyclopédie

Daubenton & Diderot • BECASSE, scolopax • Histoire naturelle | Ornithologie

On peut aussi les prendre aux lacets dans les bois, ou le long des ruisseaux ; ces lacets n'ont rien de particulier. Les bécasses se mangent roties, sans être vuidées: quand on en veut faire un ragout, on ne les laisse cuire à la broche qu'à moitié: on les dépece ; on les [met dans une casserole avec du vin, des capres, des champignons, du sel & du poivre, & on les laisse bouillir jusqu'à ce que la cuisson soit](#) achevée. Le salmi se fait presque de la même maniere ; on ajoute seulement des trufes & des anchois, & on lie la fausse avec le foie & les entrailles de la bécasse. La bécasse considérée comme aliment, passe pour être nourrissante, restaurante

[View passage in context](#)

2

L'Encyclopédie

Daubenton & Diderot • BEC-FIGUE, ficedula • Histoire naturelle | Ornithologie

est excellent à manger : il se nourrit de figues, de raisin, &c. Voyez Oiseau. (I) \* Pour l'appréter, on le plume ; on lui coupe la tête & les pieds ; on le rotit à la broche : à mesure qu'il cuit on le [saupoudre de croûte de pain rapée & mêlée de sel, & on le mange au verjus de grain & au poivre blanc](#).

L'Encyclopédie

TGB

Liger, Louis (1658-1717) • OEconomie générale de la campagne, ou Nouvelle maison rustique — Tome 2 • 1700

: après qu'elles font rôties, on y fait une fauce avec orange, sel, poivre blanc, & une ciboulette. Beccafes en ragout. Pour faire un bon ragout de beccasses, on s'en fert lorsqu'elles sont à demy cuites, puis on les coupe en pieces, pour les [mettre dans une casserole avec du vin, des capres & des champignons, le tout assaisonné de sel & de poivre, après quoy on les laisse bouillir jusqu'à ce que la cuisson soit](#) parfaite, pour être servies après y avoir pressé un jus d'orange. Des Beccafines. On apprête les becassines de la même maniere que les beccasses lorsqu'on les veut faire rôtir ; mais quand on souhaite les man- ger en ragout, on les fend en deux

[View passage in context](#)

Show differences

Browse by Metadata Counts

Show options

**article topics**

Frequency by L'Encyclopédie Generated class

Showing top 100 results

Histoire naturelle	2 166
Histoire de la philosophie	1 381
Grammaire	1 183
Art mécanique	708
Méta physique	601
Histoire ancienne	550
Histoire ecclésiastique	390
Morale	369
Géographie	350
Commerce	349

## Reuse of L'Encyclopédie within the TGB

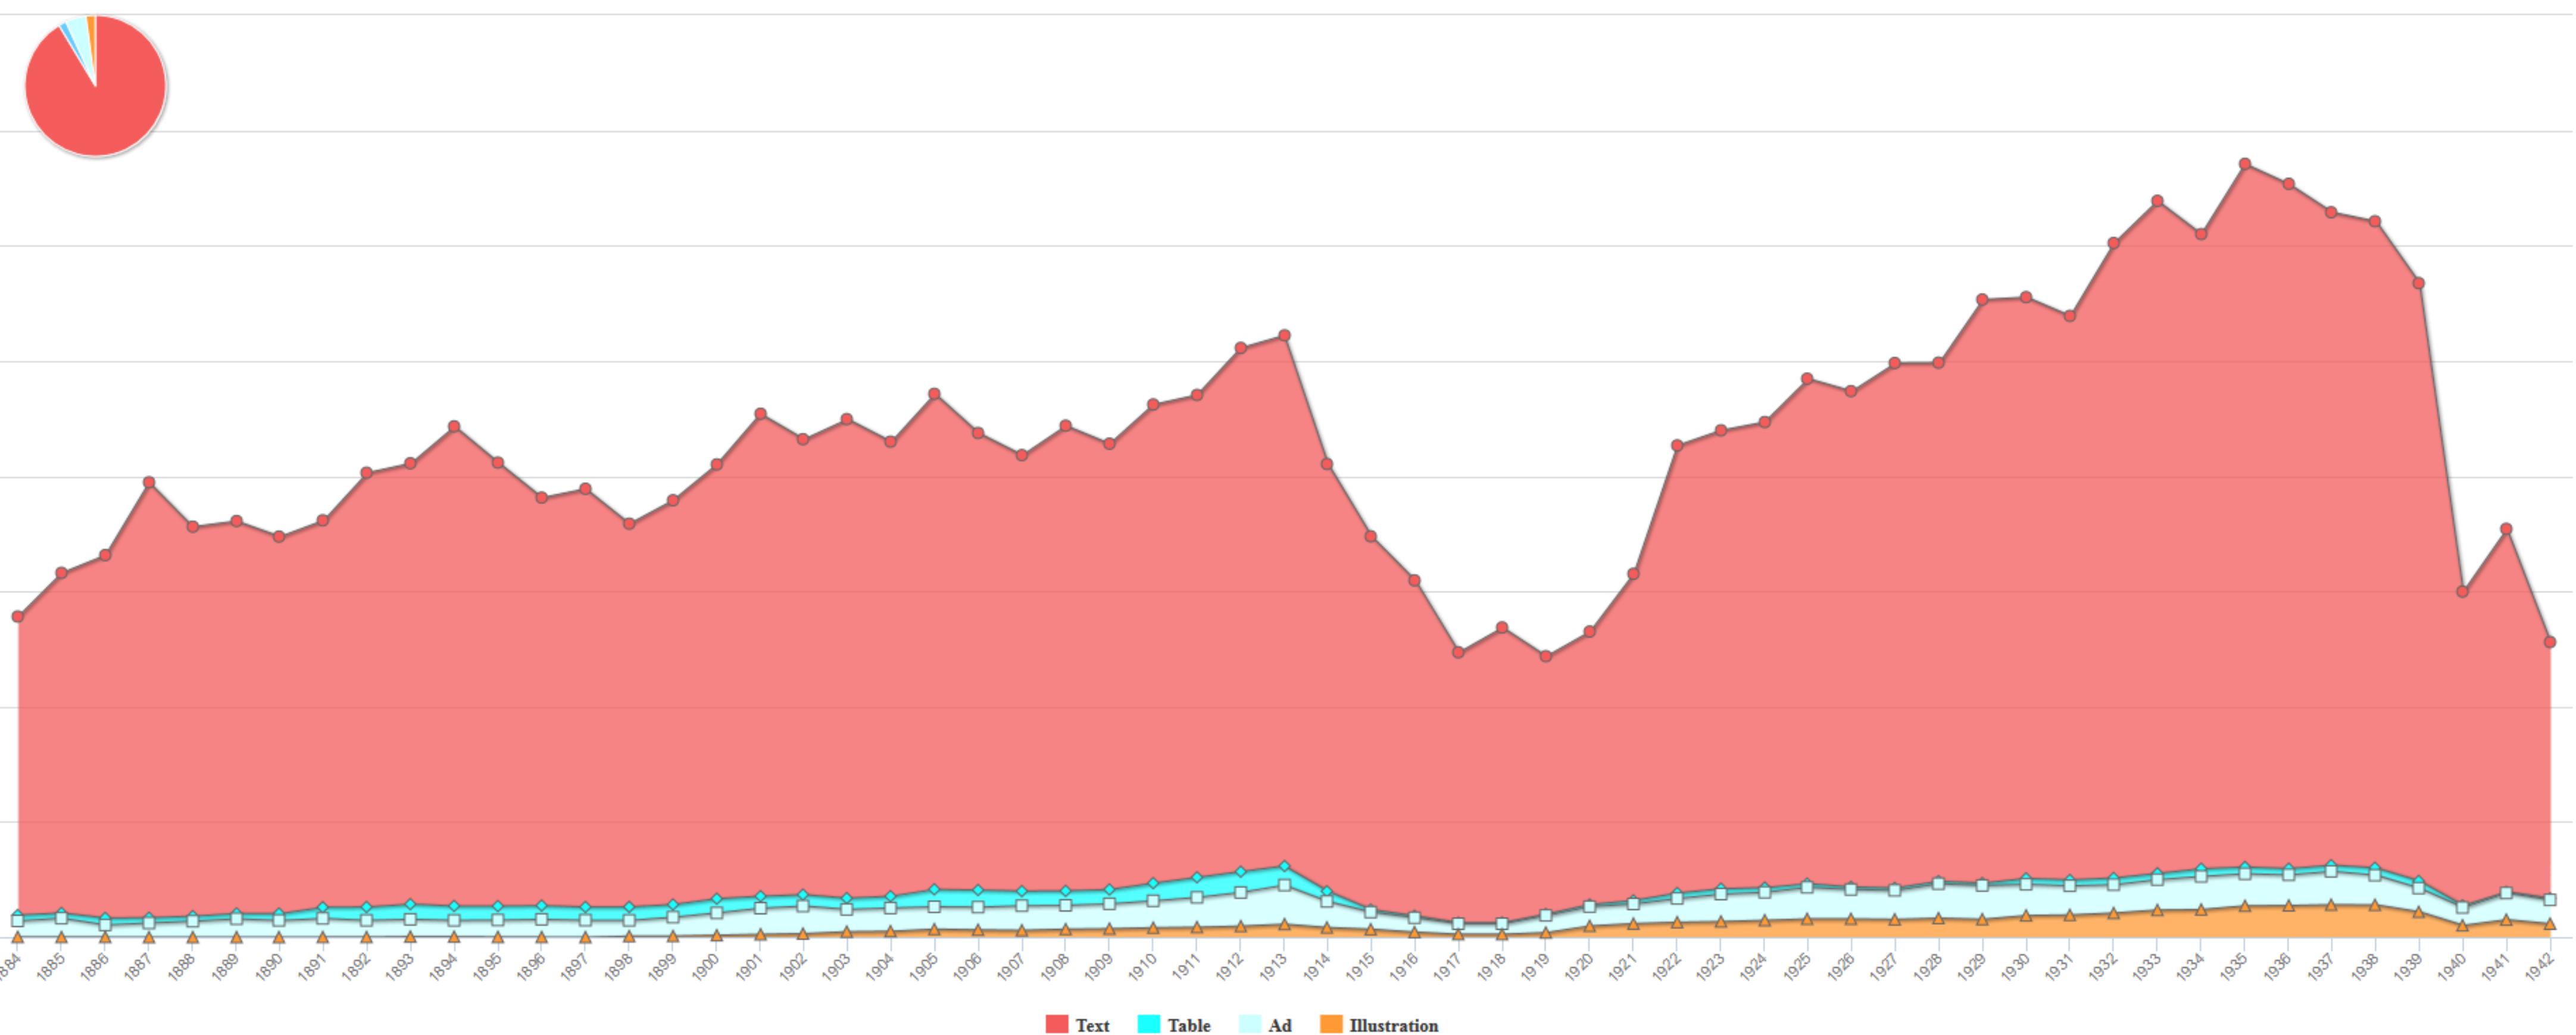
Alignments made  
with PhiloLine:

[http://anomander.uchicago.edu/text-align/encyc\\_vs\\_tgb](http://anomander.uchicago.edu/text-align/encyc_vs_tgb)

- 310k fragments aligned
- Cross-faceted search on both corpora
- Time series chart

# OBVIL, ARTFL (Univ. of Chicago) “Use & Reuse” project

- Investigate reuse models during the XVIII<sup>th</sup> c.
- Understand the XVIII<sup>th</sup> c. heritage through the reuse during XIX<sup>th</sup> and XX<sup>th</sup> c.
- Thanks to sequence alignment algorithms (bioinformatics)
- Output : closed and distant readings analysis, reuse fragments dataset



Le Matin,  
1884-1942

The impact of  
wars on the  
newspaper  
industry

# Europeana Newspapers project

10 M OCRed pages from 12 European Libraries

# Data Mining the Metadata

- 900,000 ALTO files used for data mining French dailies
- 6 M metadata dataset for DH

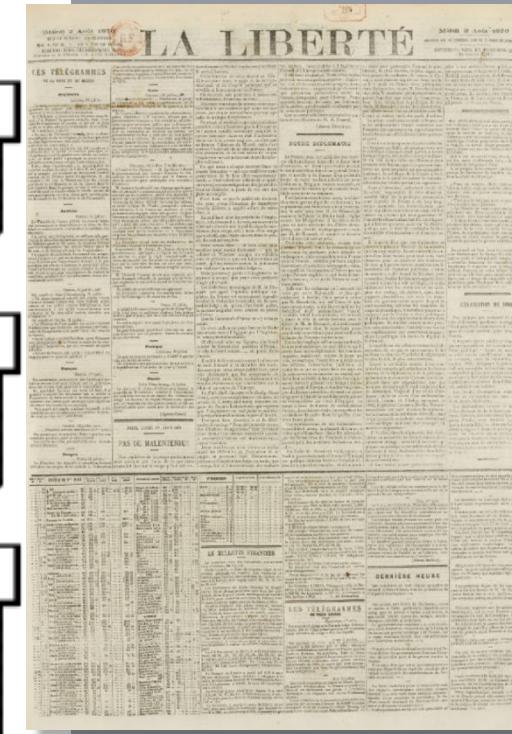
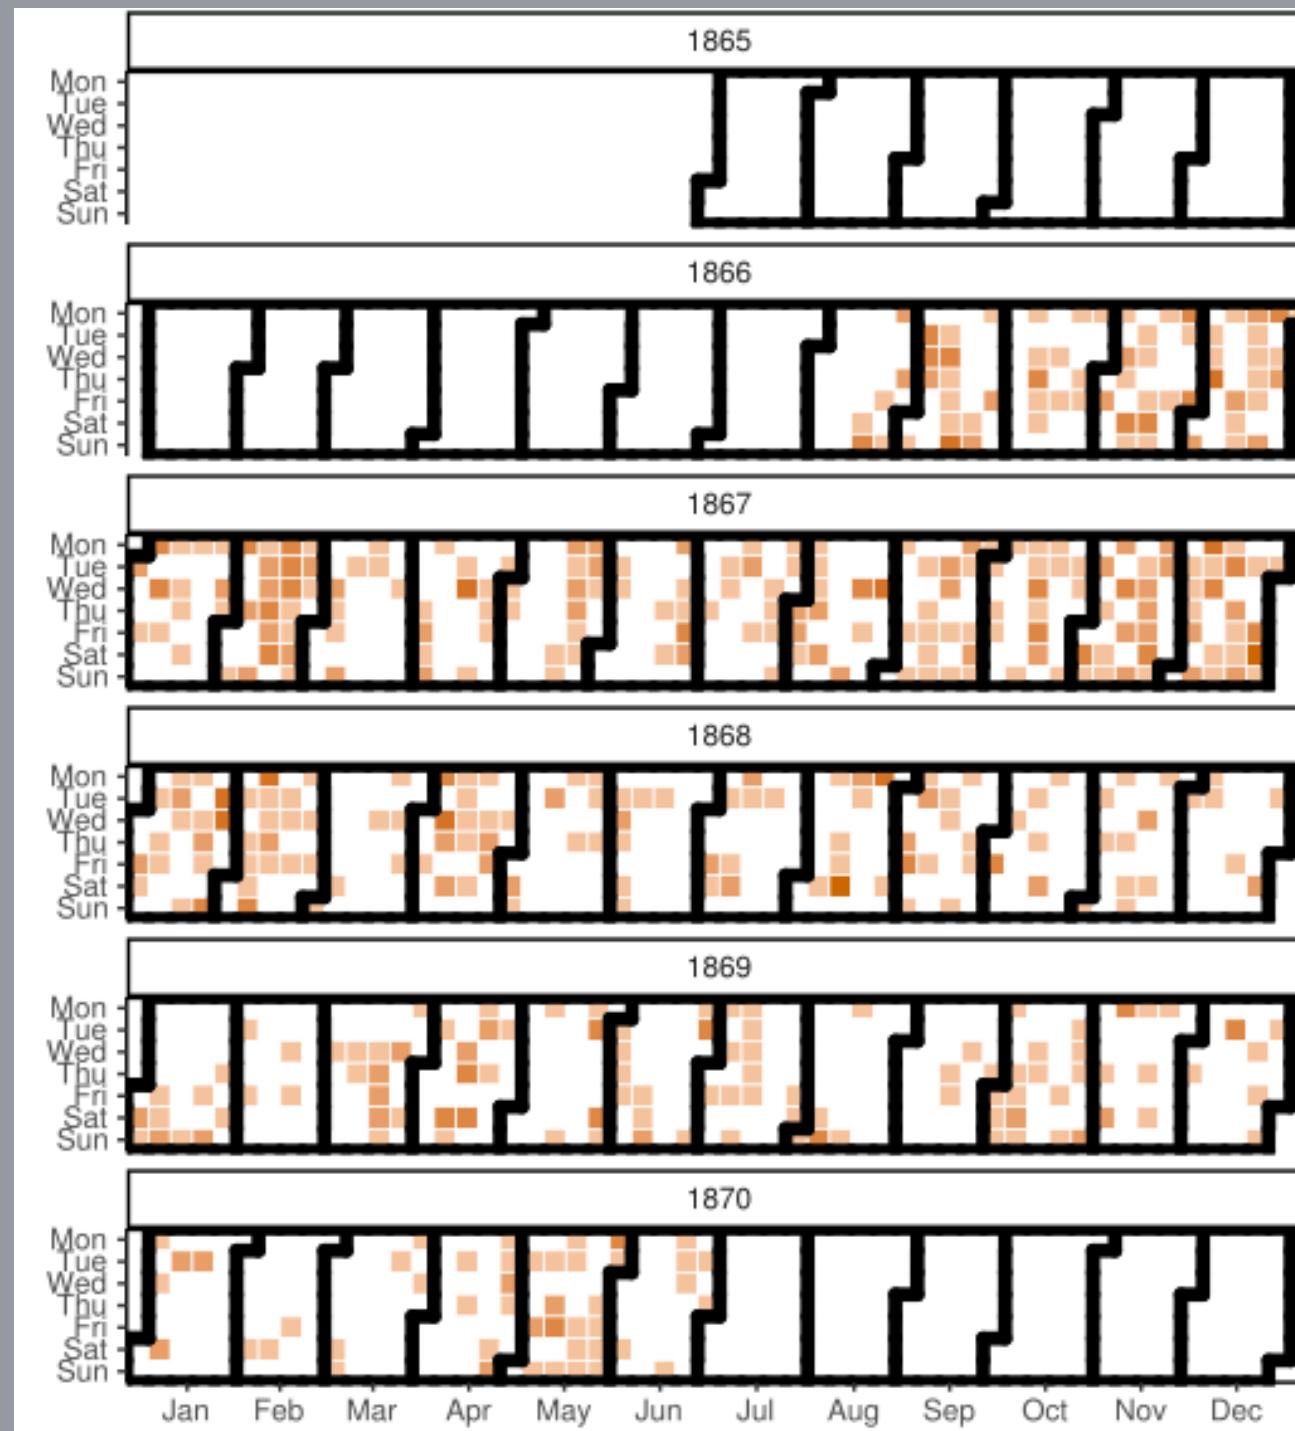
Website:  
[http://altomator.github.io/EN-data\\_mining/](http://altomator.github.io/EN-data_mining/)  
<http://www.europeana-newspapers.eu/>

# The Arcimboldo way

gathering and studying scattered  
and/or heterogeneous sources

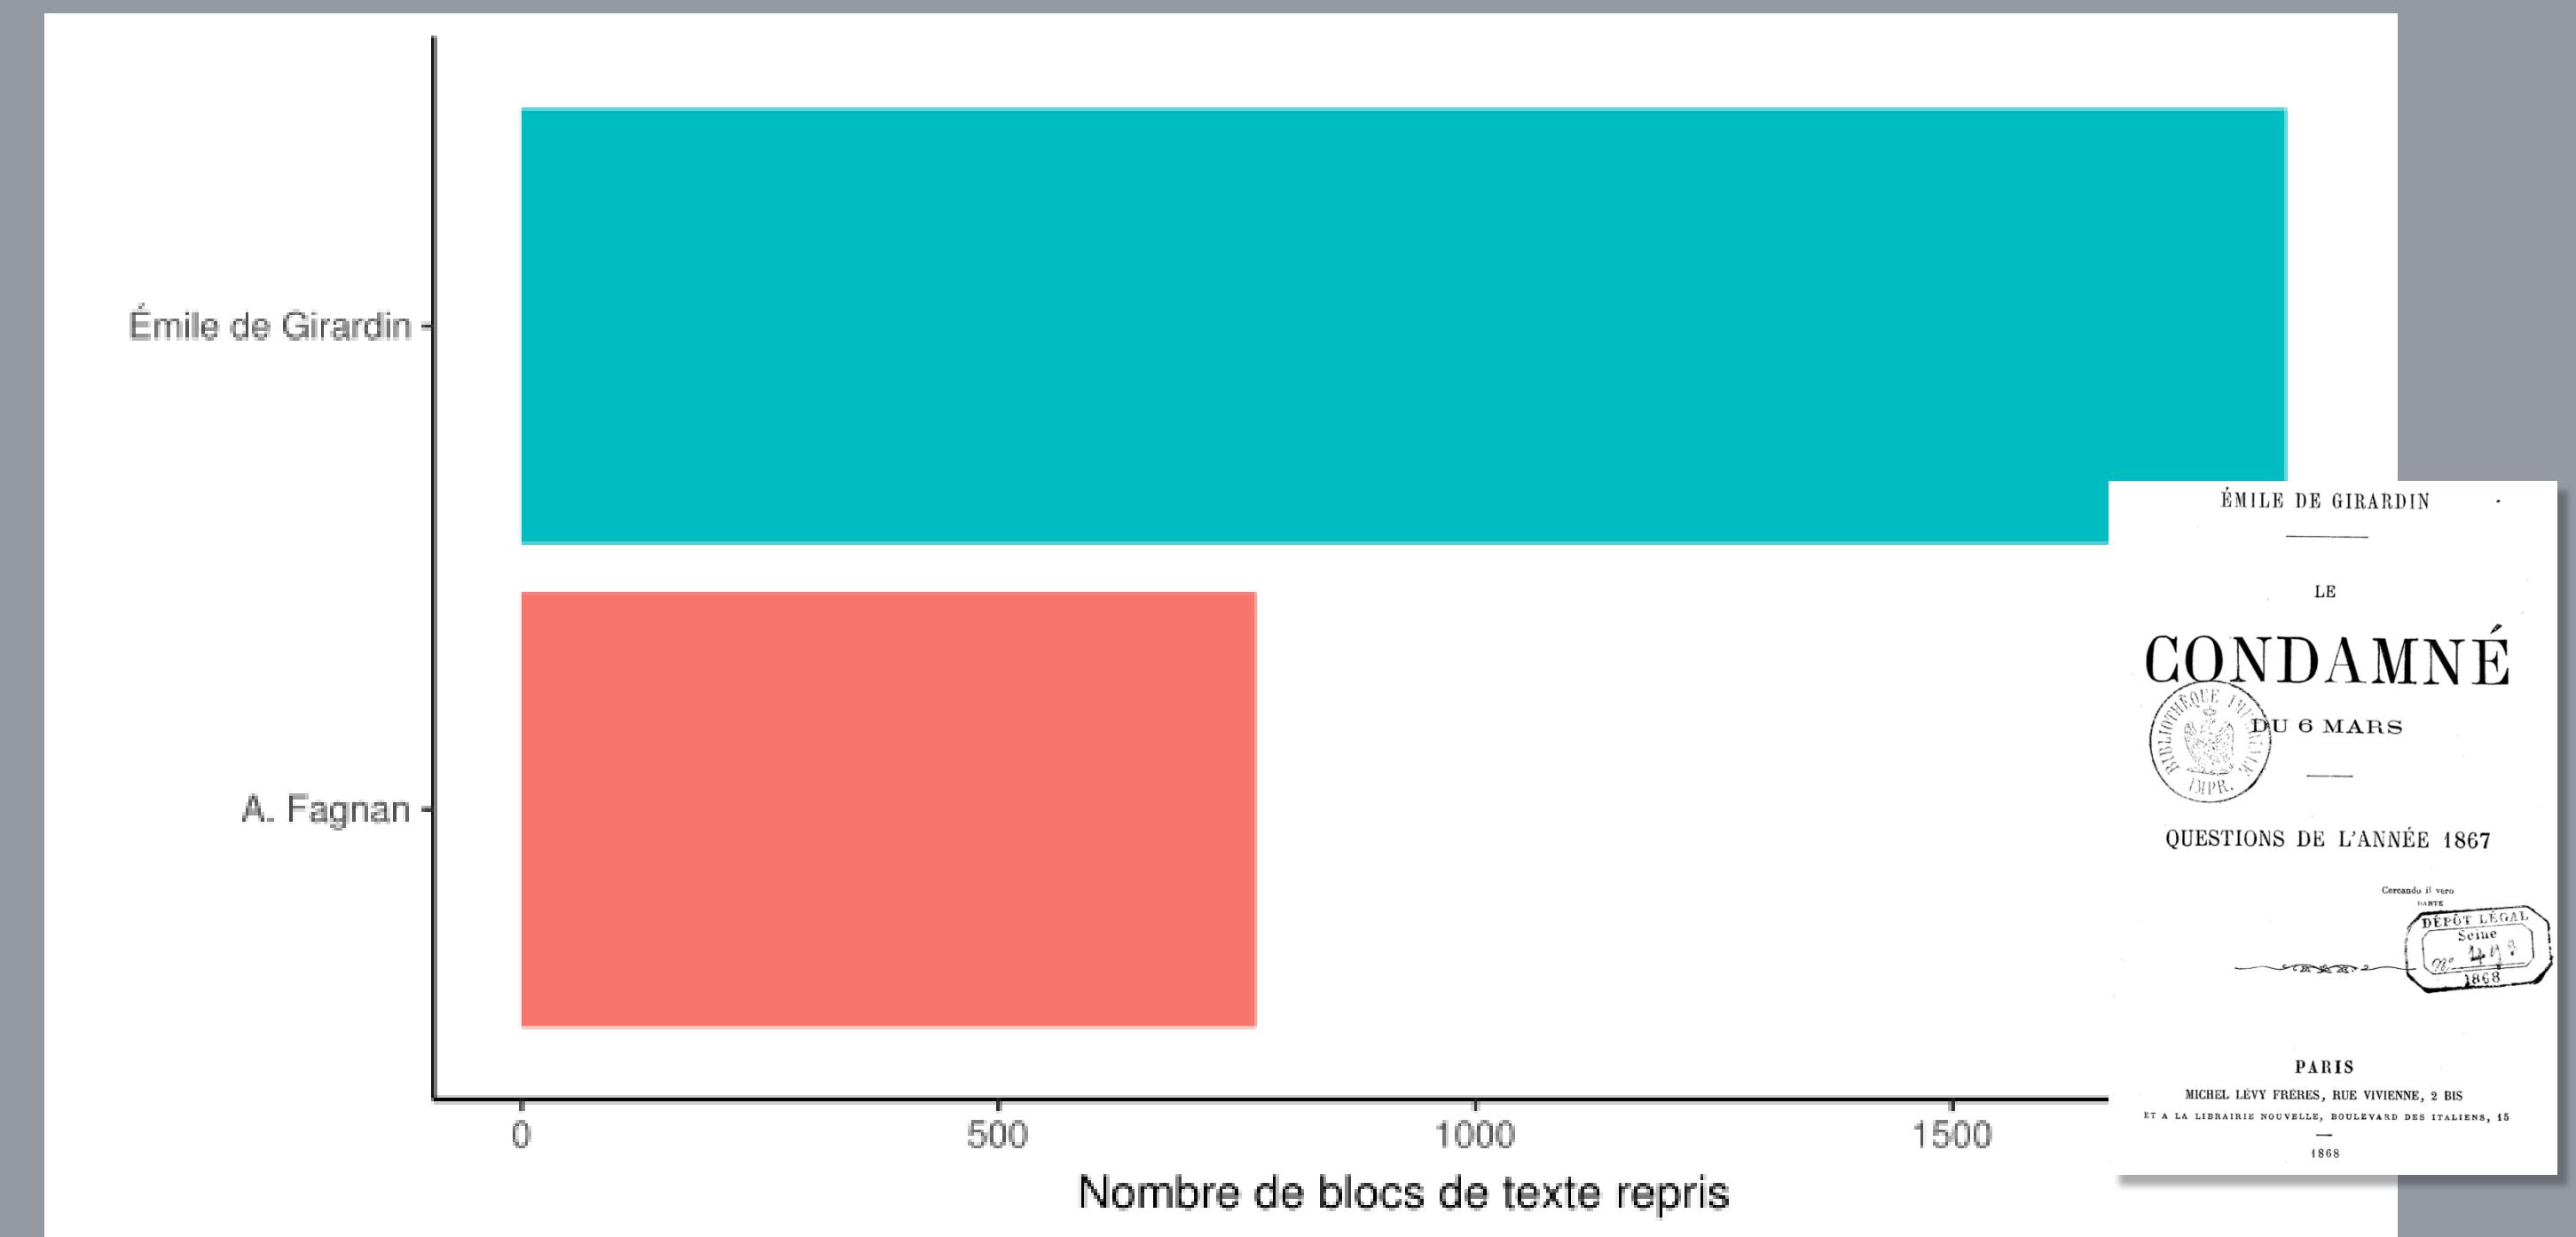
*Vertumne*  
Giuseppe Arcimboldo, 1590  
Château de Skokloster





Who is « A. Fagnan », a regular journalist  
of *Liberté* newspaper, unknown in authorities files?

# GRIPIC/ CELSA The Giranium project



The third of Girardin's memoirs (1867) are reprints of *Liberté*.  
Fagnan=Girardin!

Analysis of  
300 autograph letters  
from Émile de Girardin,  
and other documents  
(notes, newspapers,  
works, diaries, maps...)

Website:  
[http://vintagedata.org/  
giranum/](http://vintagedata.org/giranum/)

# The J. Cook way

exploring, describing and analysing  
an uncharted territory

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

Thomas Jefferys, 1771

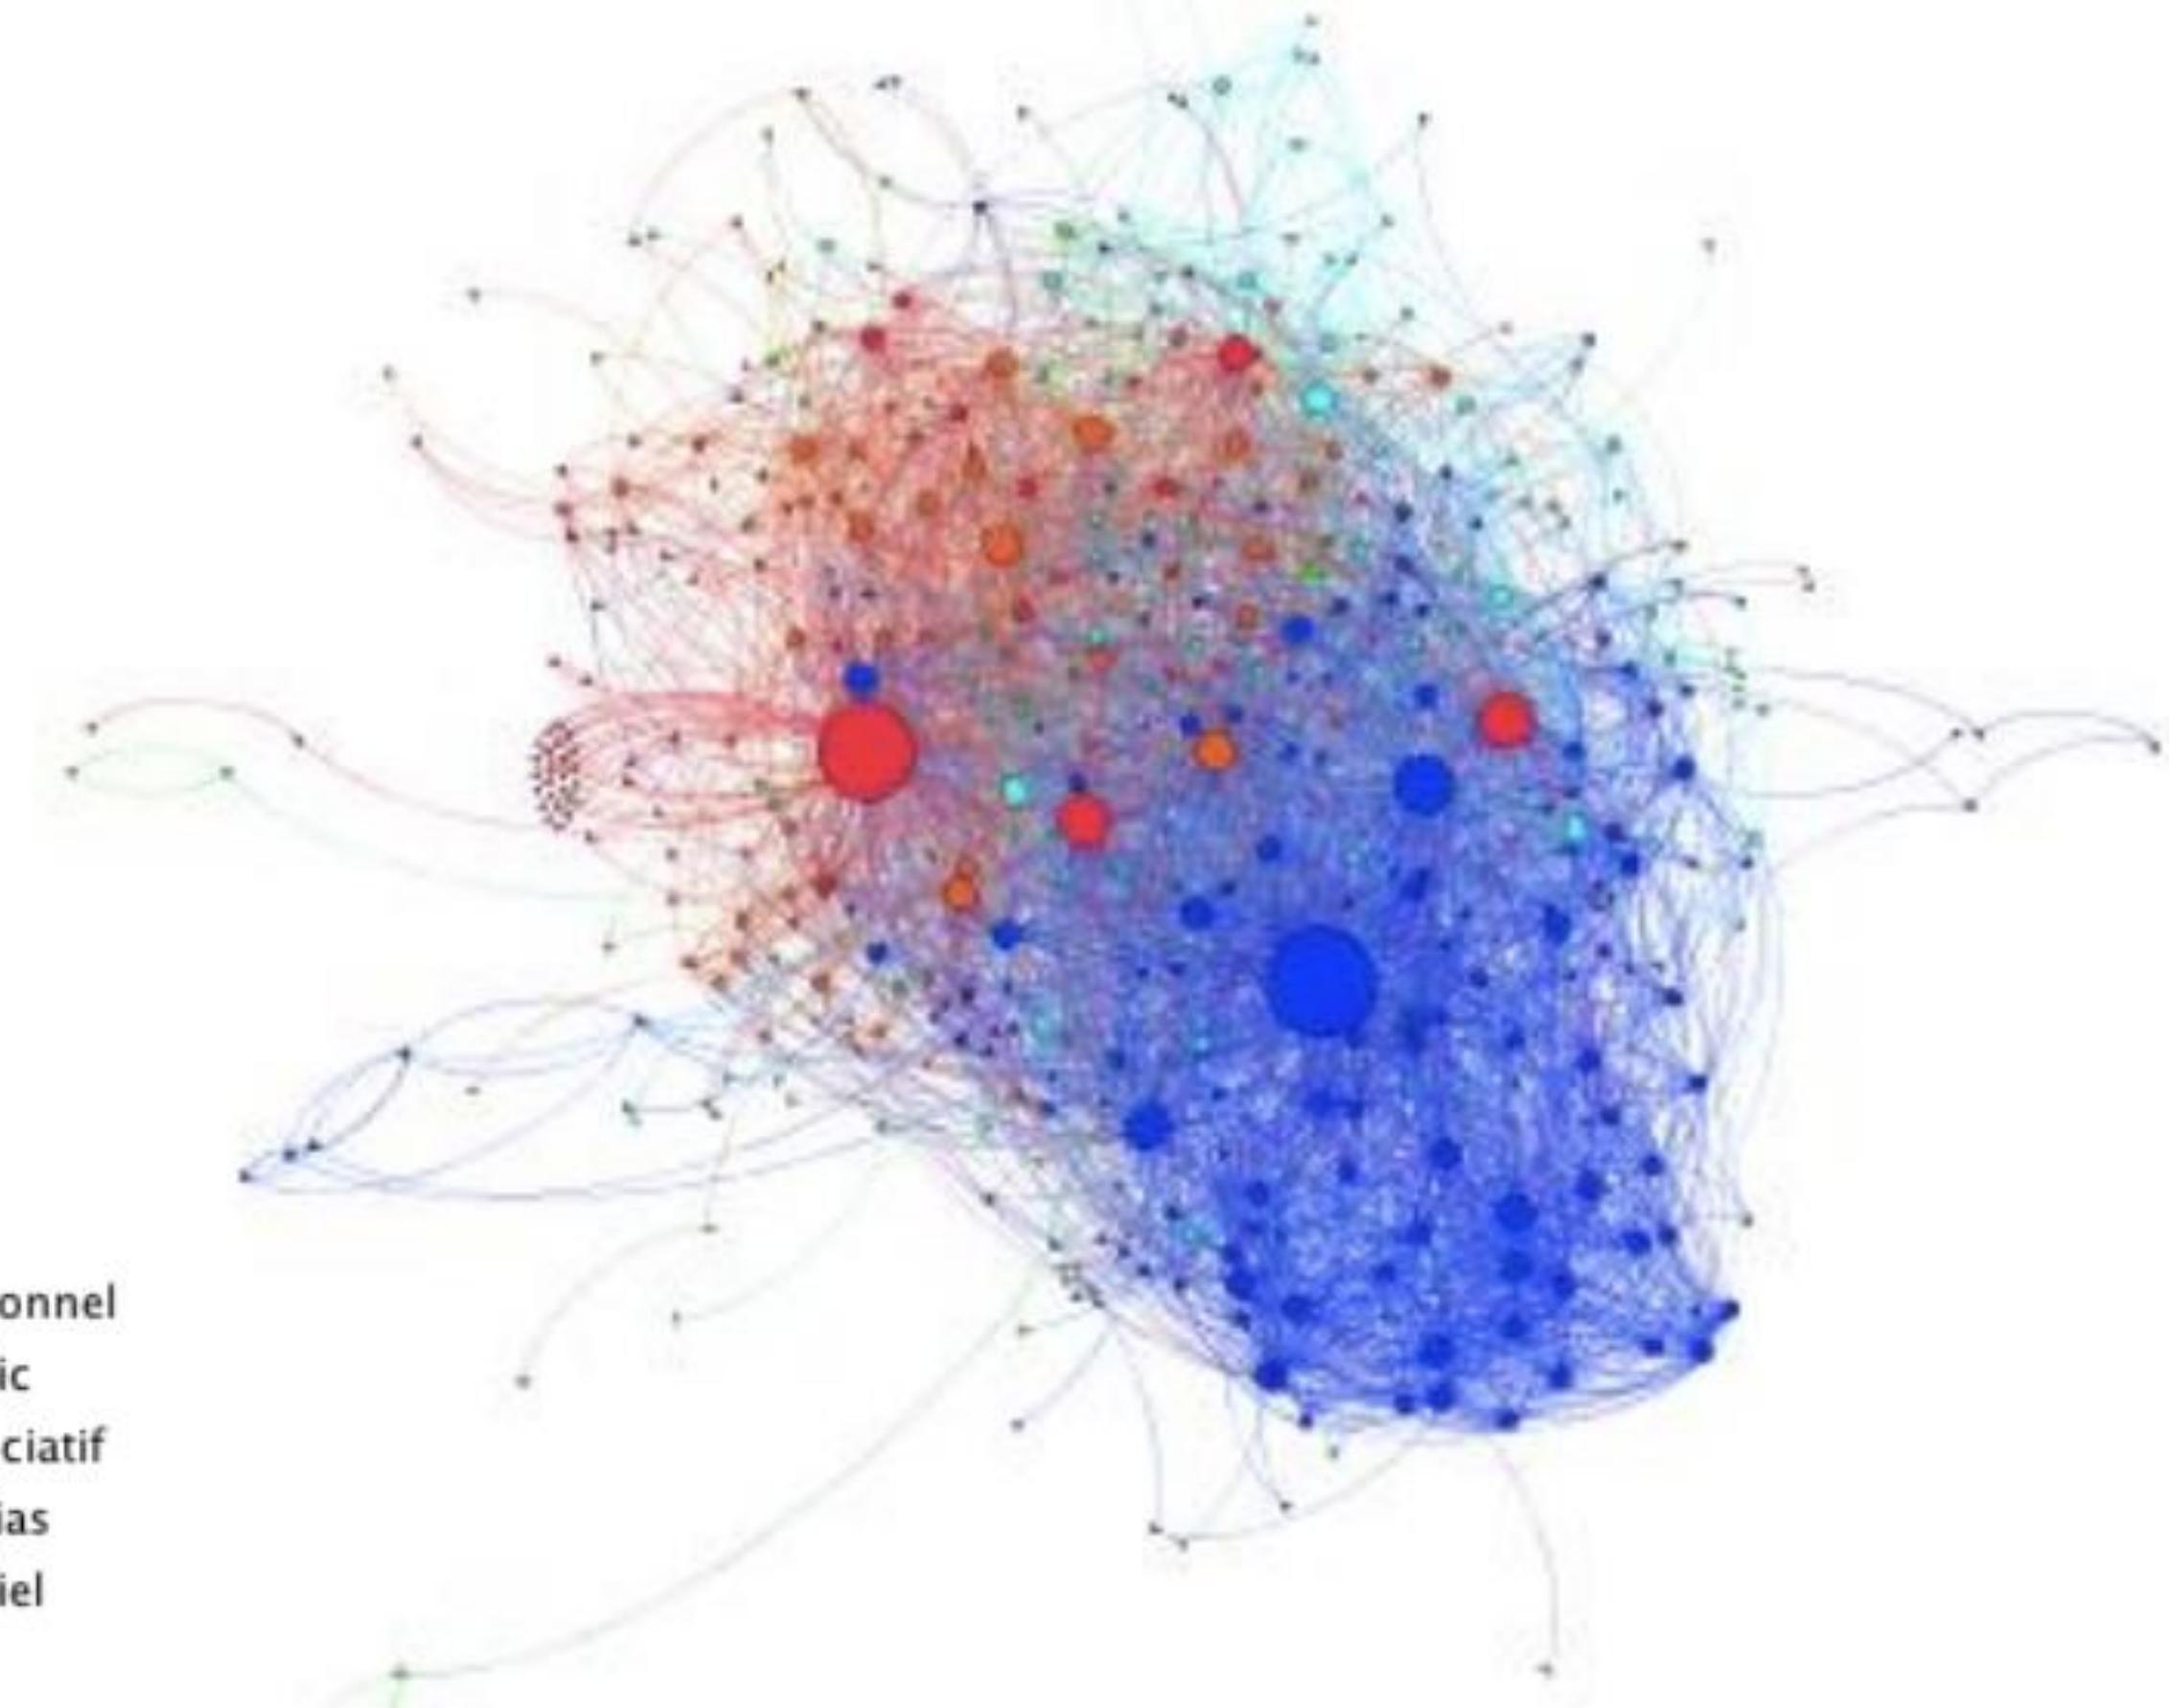
McMaster University Digital Archive :

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



Bibliothèque  
nationale de France





- personnel
- public
- associatif
- médias
- officiel

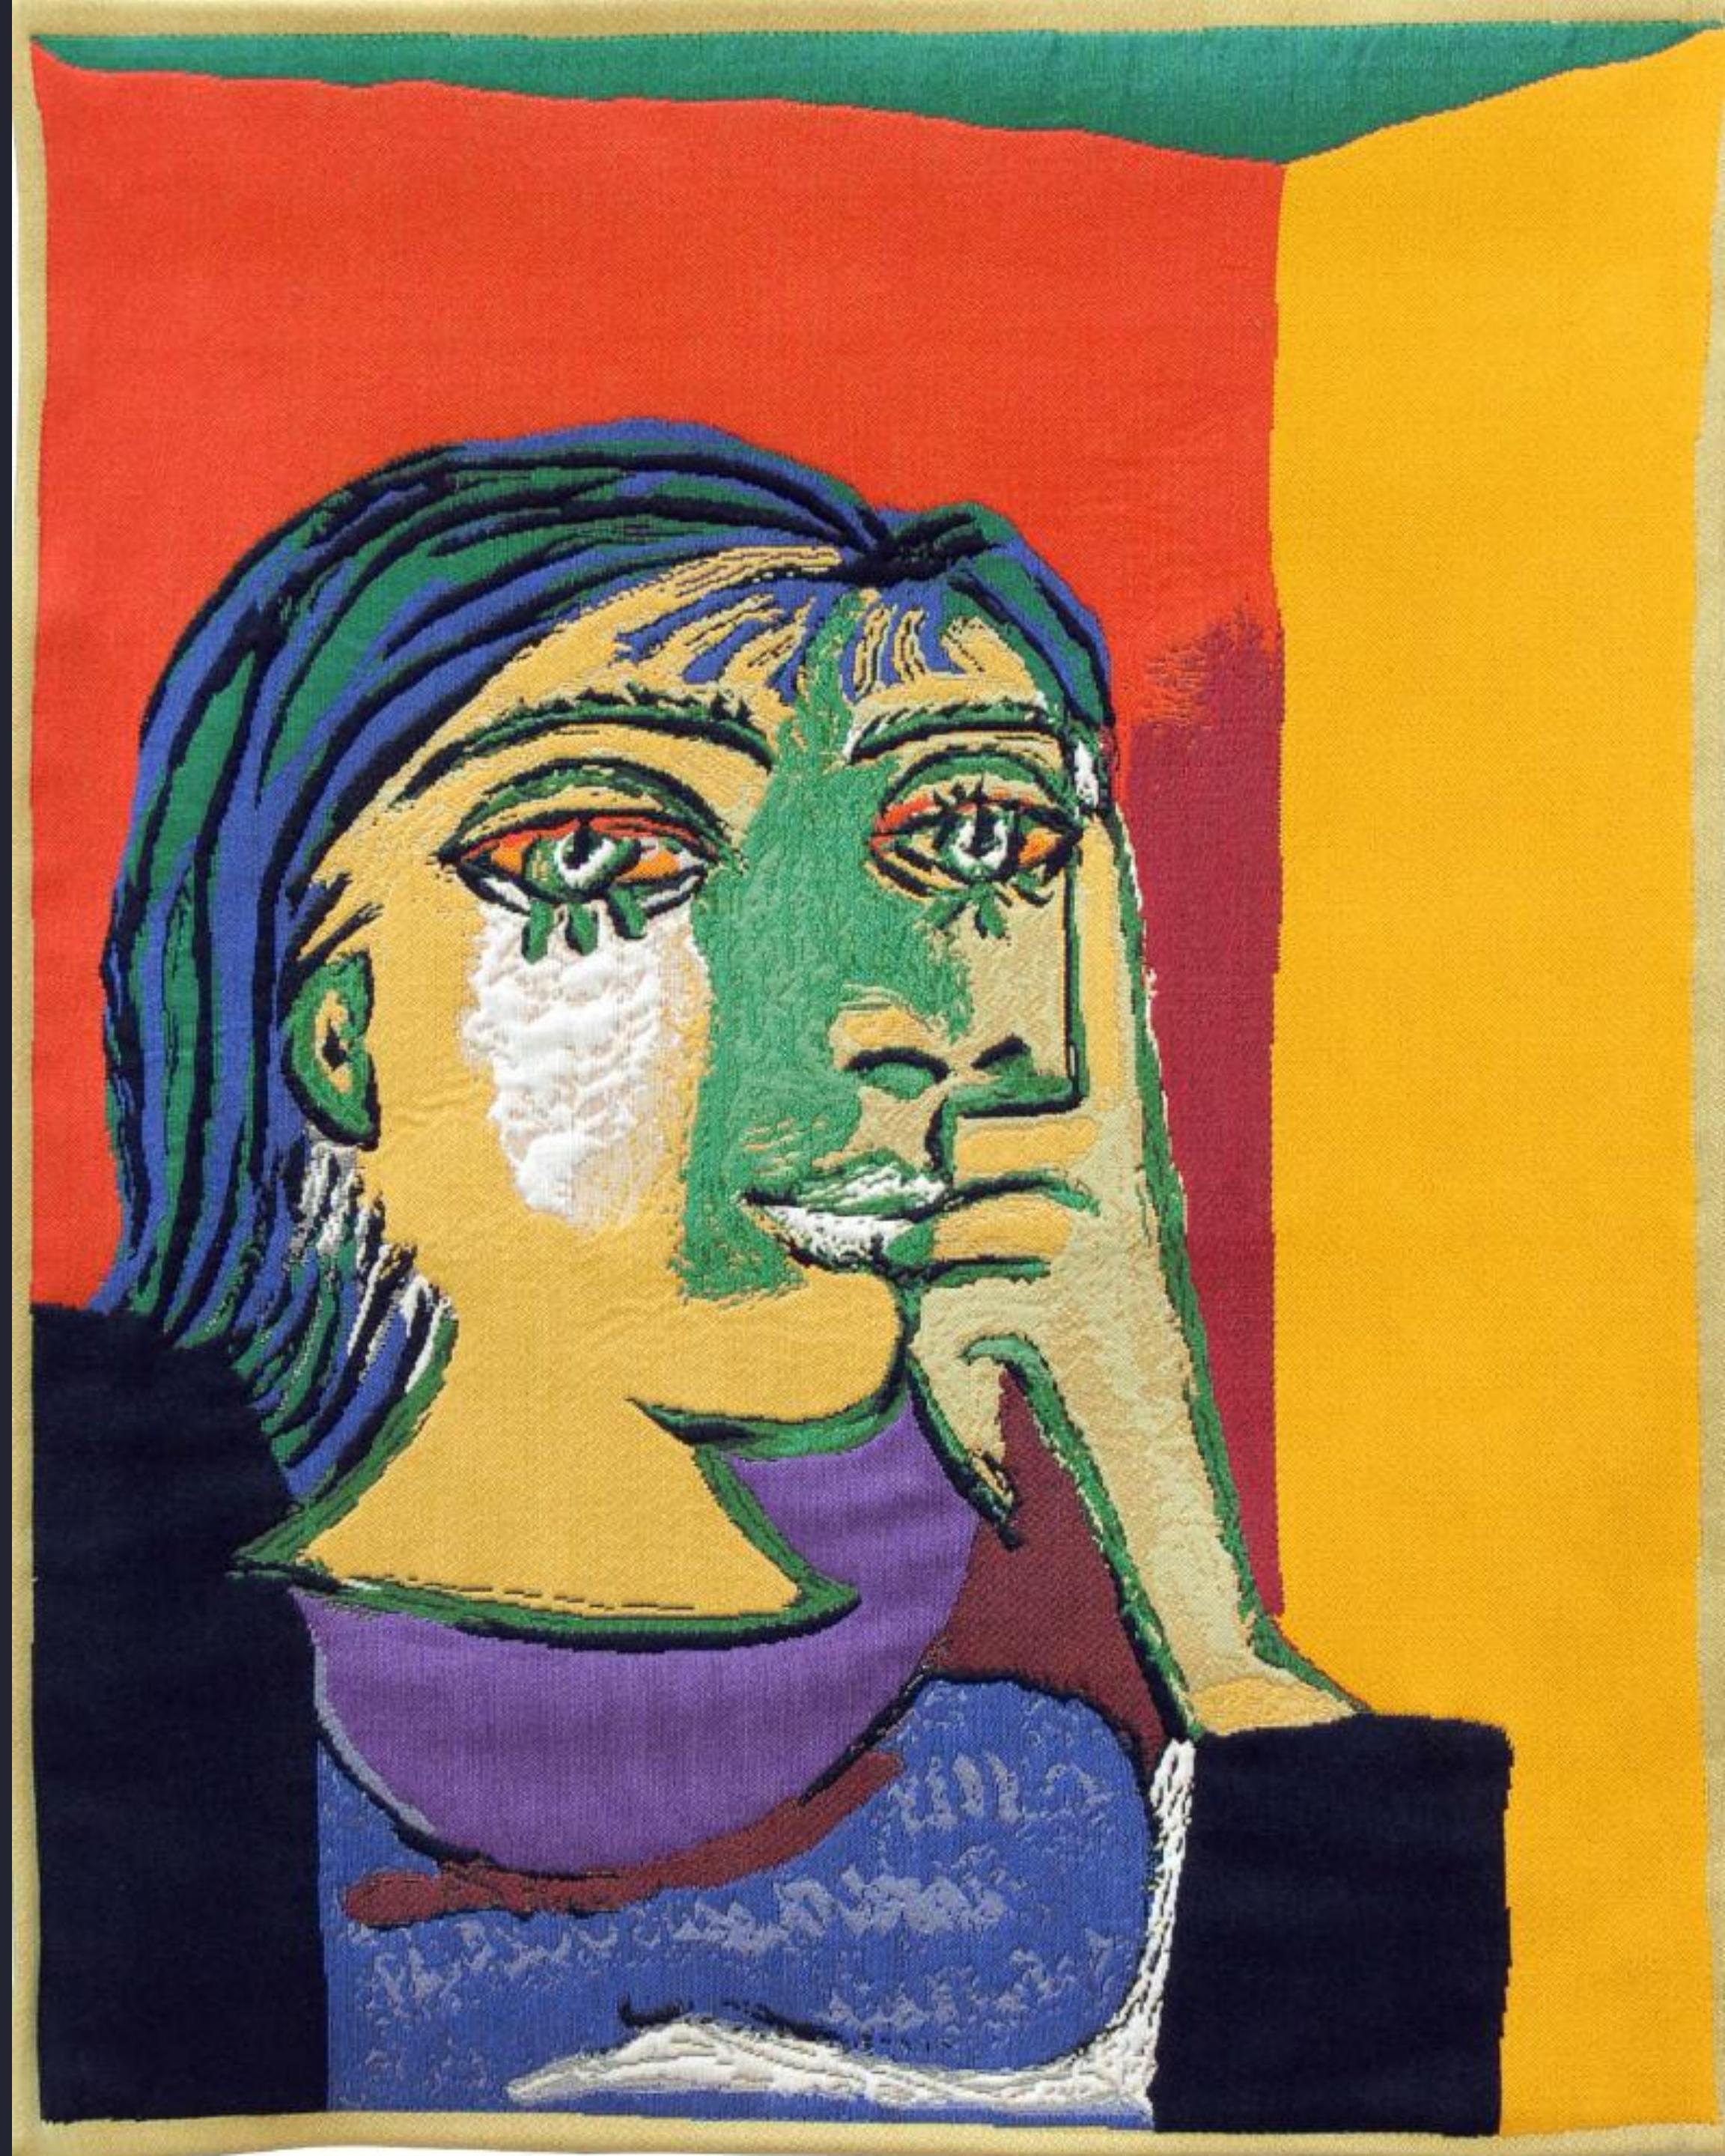
Project by *Les passés dans le présent*  
The future of online digitized heritage:  
the example of the World War I

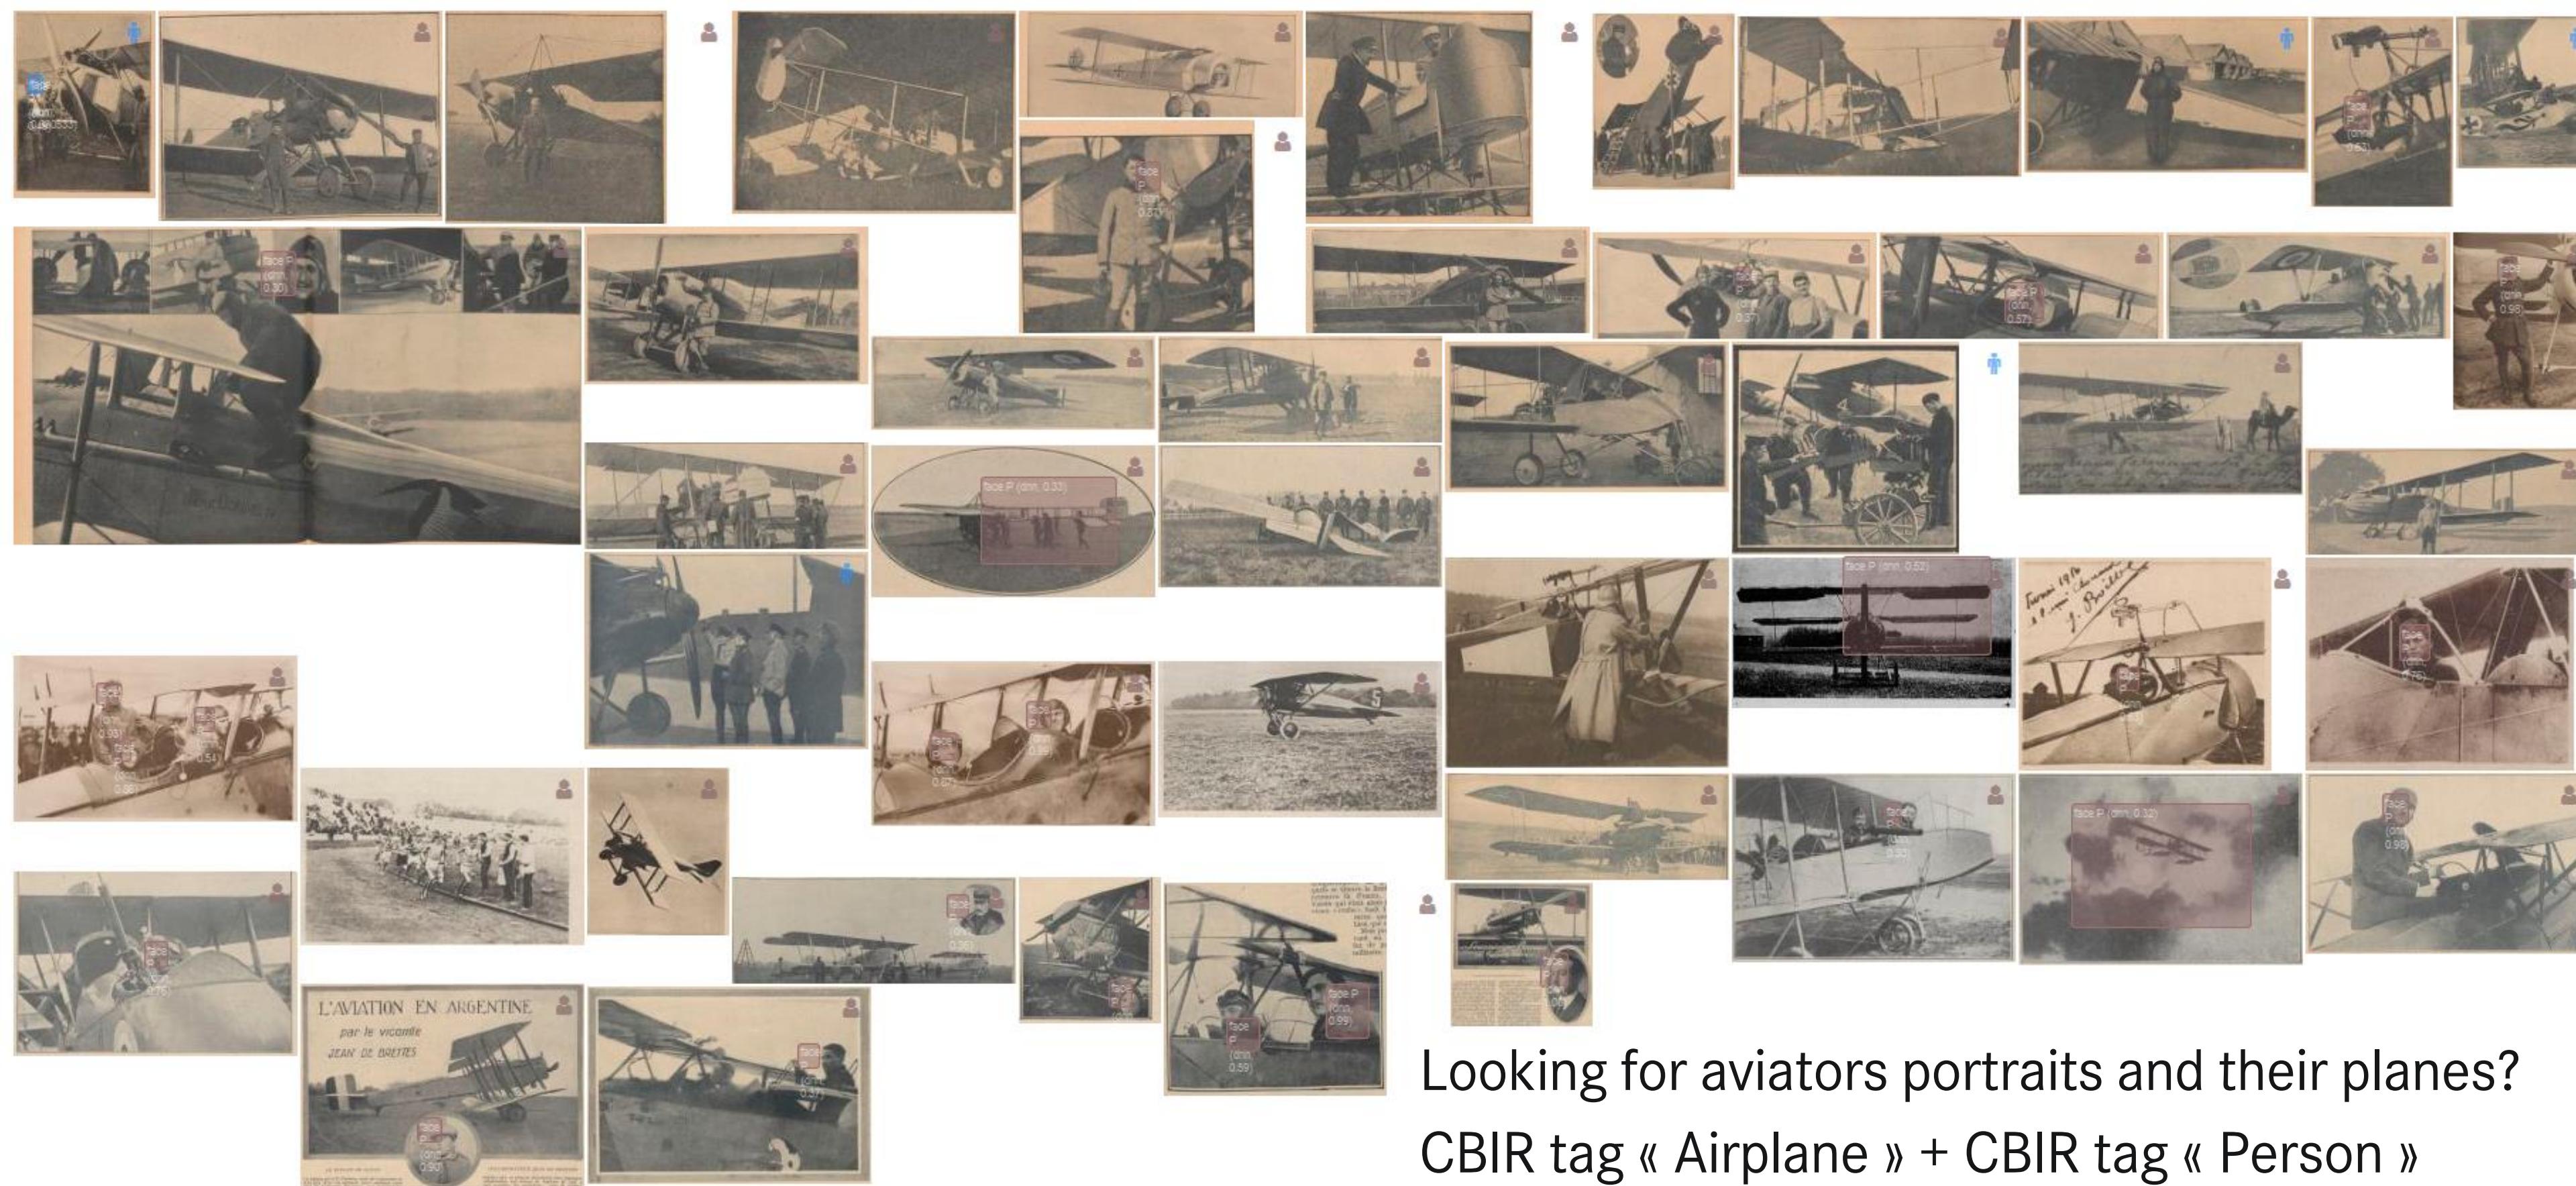
Report:  
<https://hal.archives-ouvertes.fr/hal-01425600>

# The Picasso way

shaping new forms of heritage

Dora Maar portrait  
Pablo Picasso, 1937  
© Picasso estate/ Musée Picasso





Looking for aviators portraits and their planes?  
CBIR tag « Airplane » + CBIR tag « Person »

- Data mining of 500k pages for illustrations
- Mixed collections (print, still image, maps...)
- Image genres classification with a custom CNN model
- Content-based image search (IBM Watson, Google Cloud Vision)
- Cross-modal query (text, metadata, CBIR)
- End-to-end access to data with BnF APIs (inc. IIIF)
- Outputs datasets for DH

# GallicaPix Deep Learning applied to WW1 iconography



# Report | January 2018

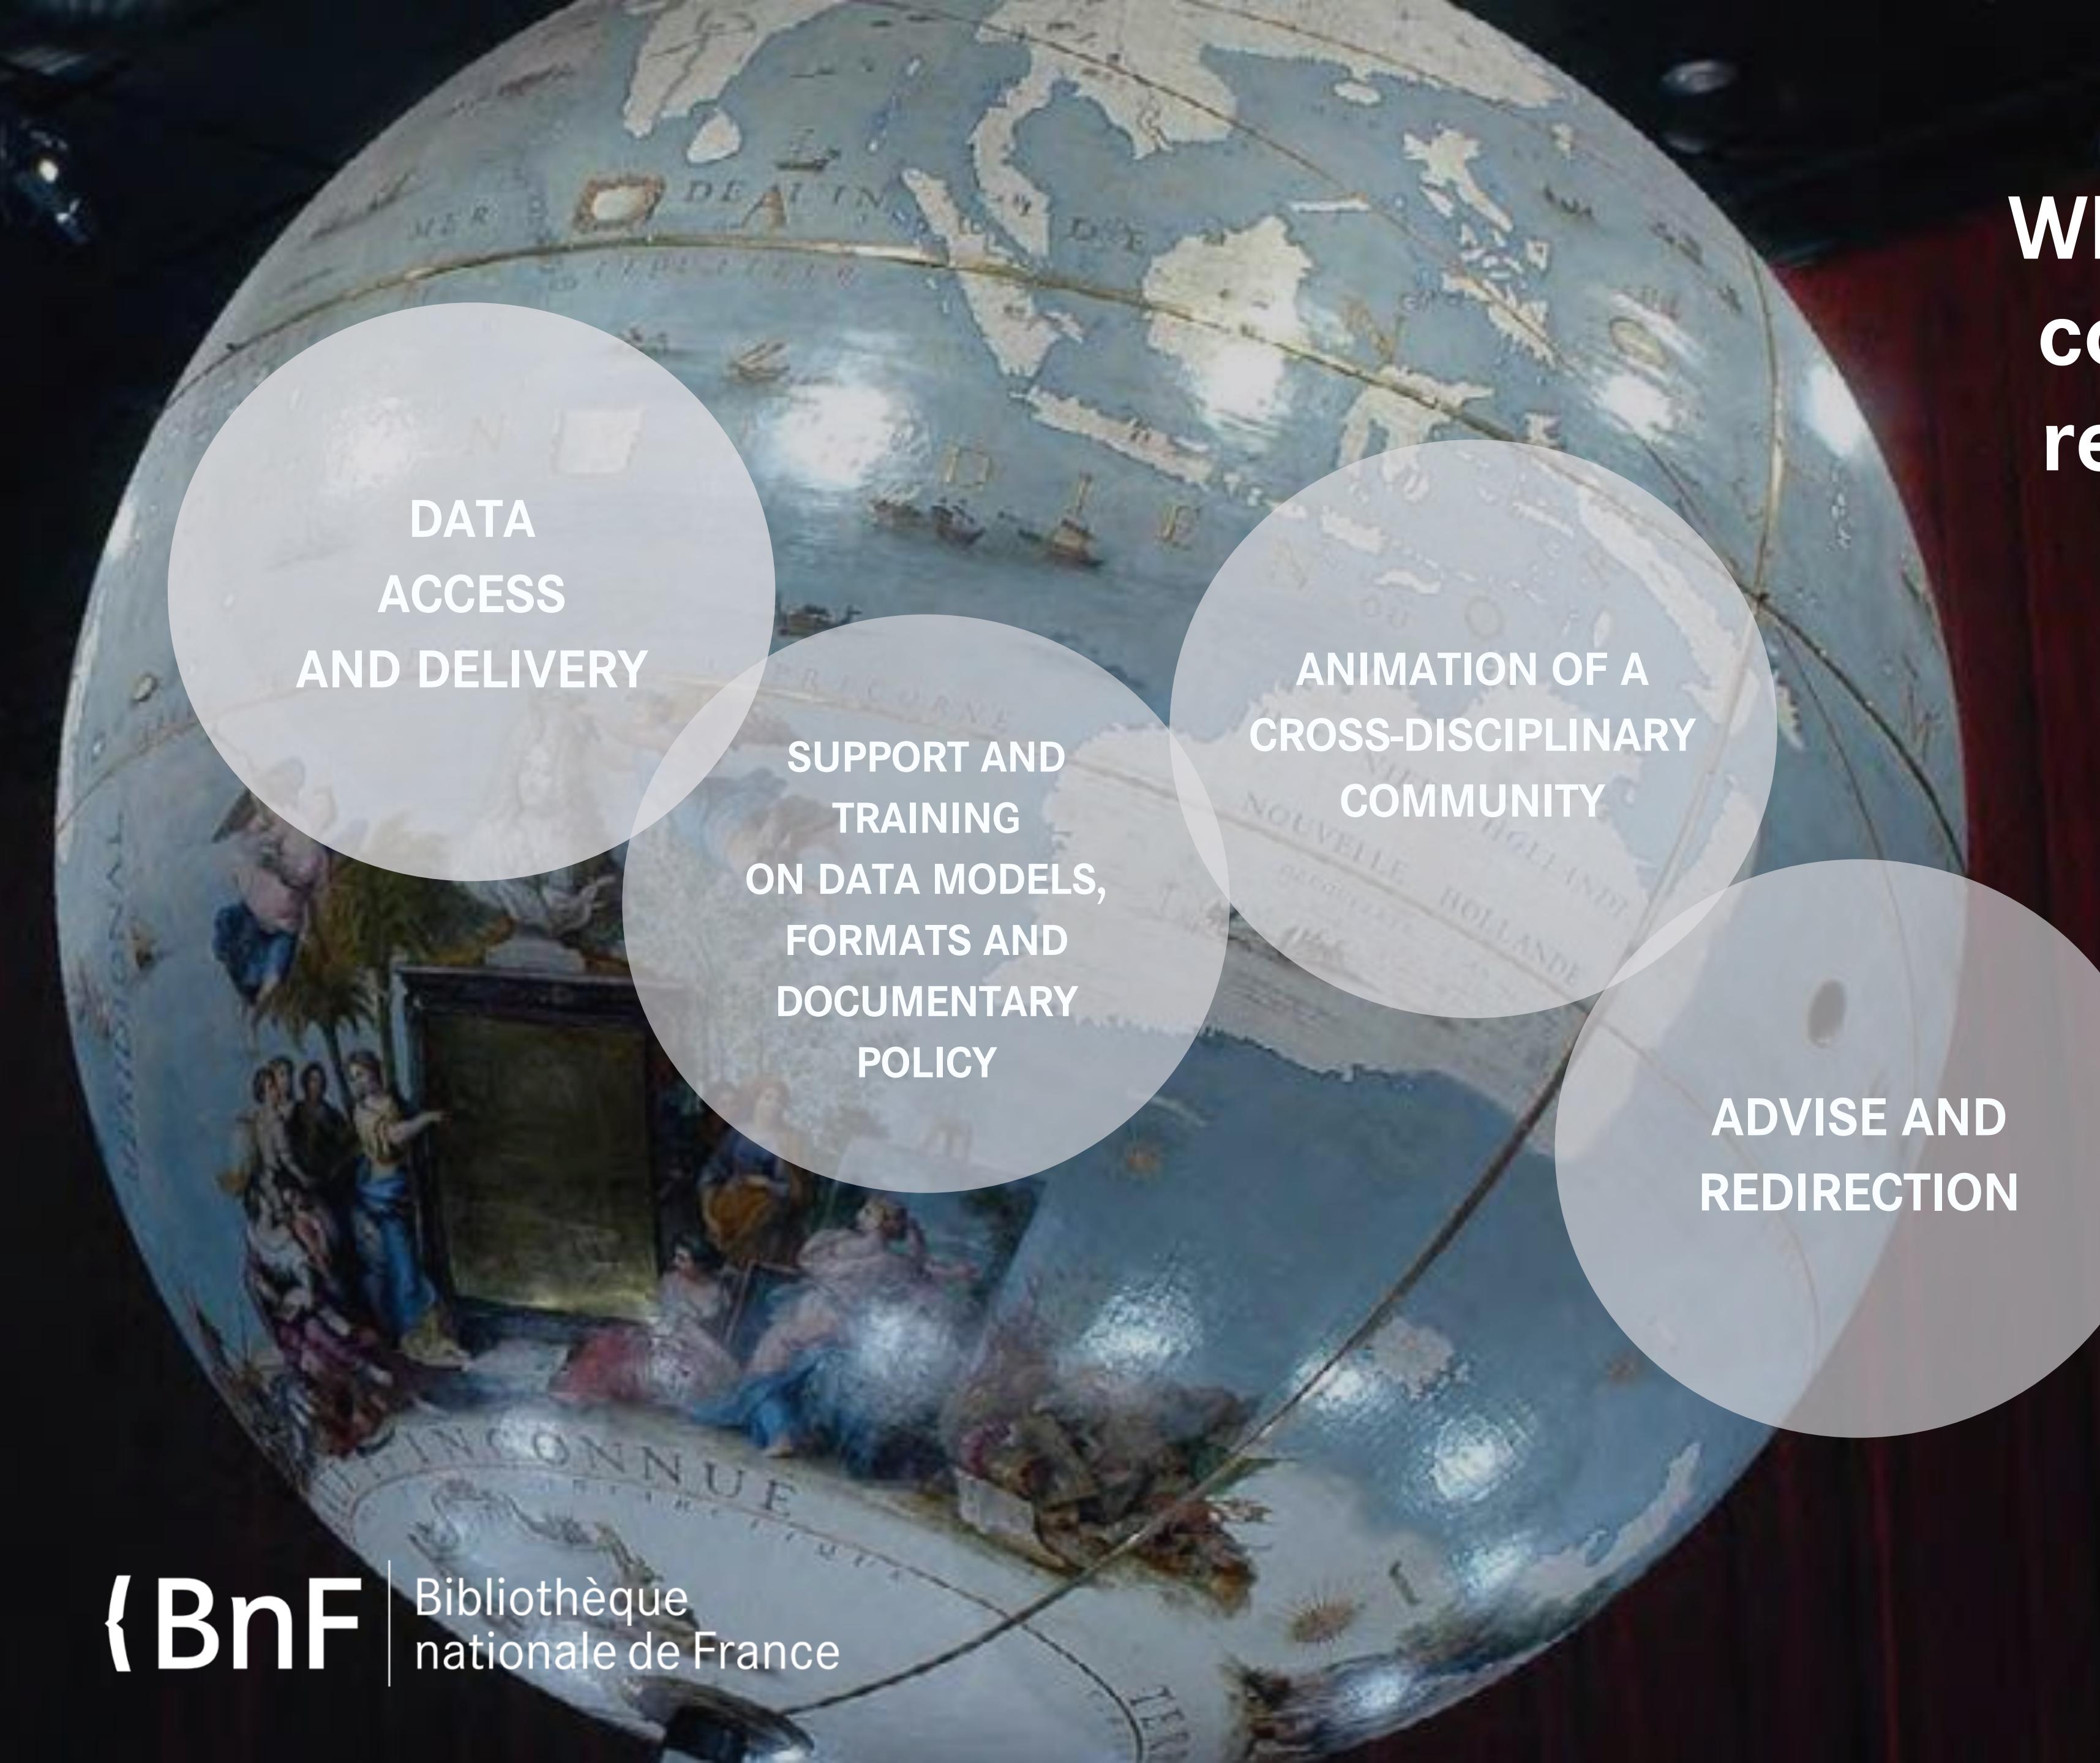
**“The Corpus project  
and its potential users.**

**A prospective study of users’  
needs and expectations.”**

**Eleonora Moiraghi**  
Research assistant

---

<https://hal-bnf.archives-ouvertes.fr/hal-01739730>



# What the BnF could do for researchers

...

DATA  
ACCESS  
AND DELIVERY

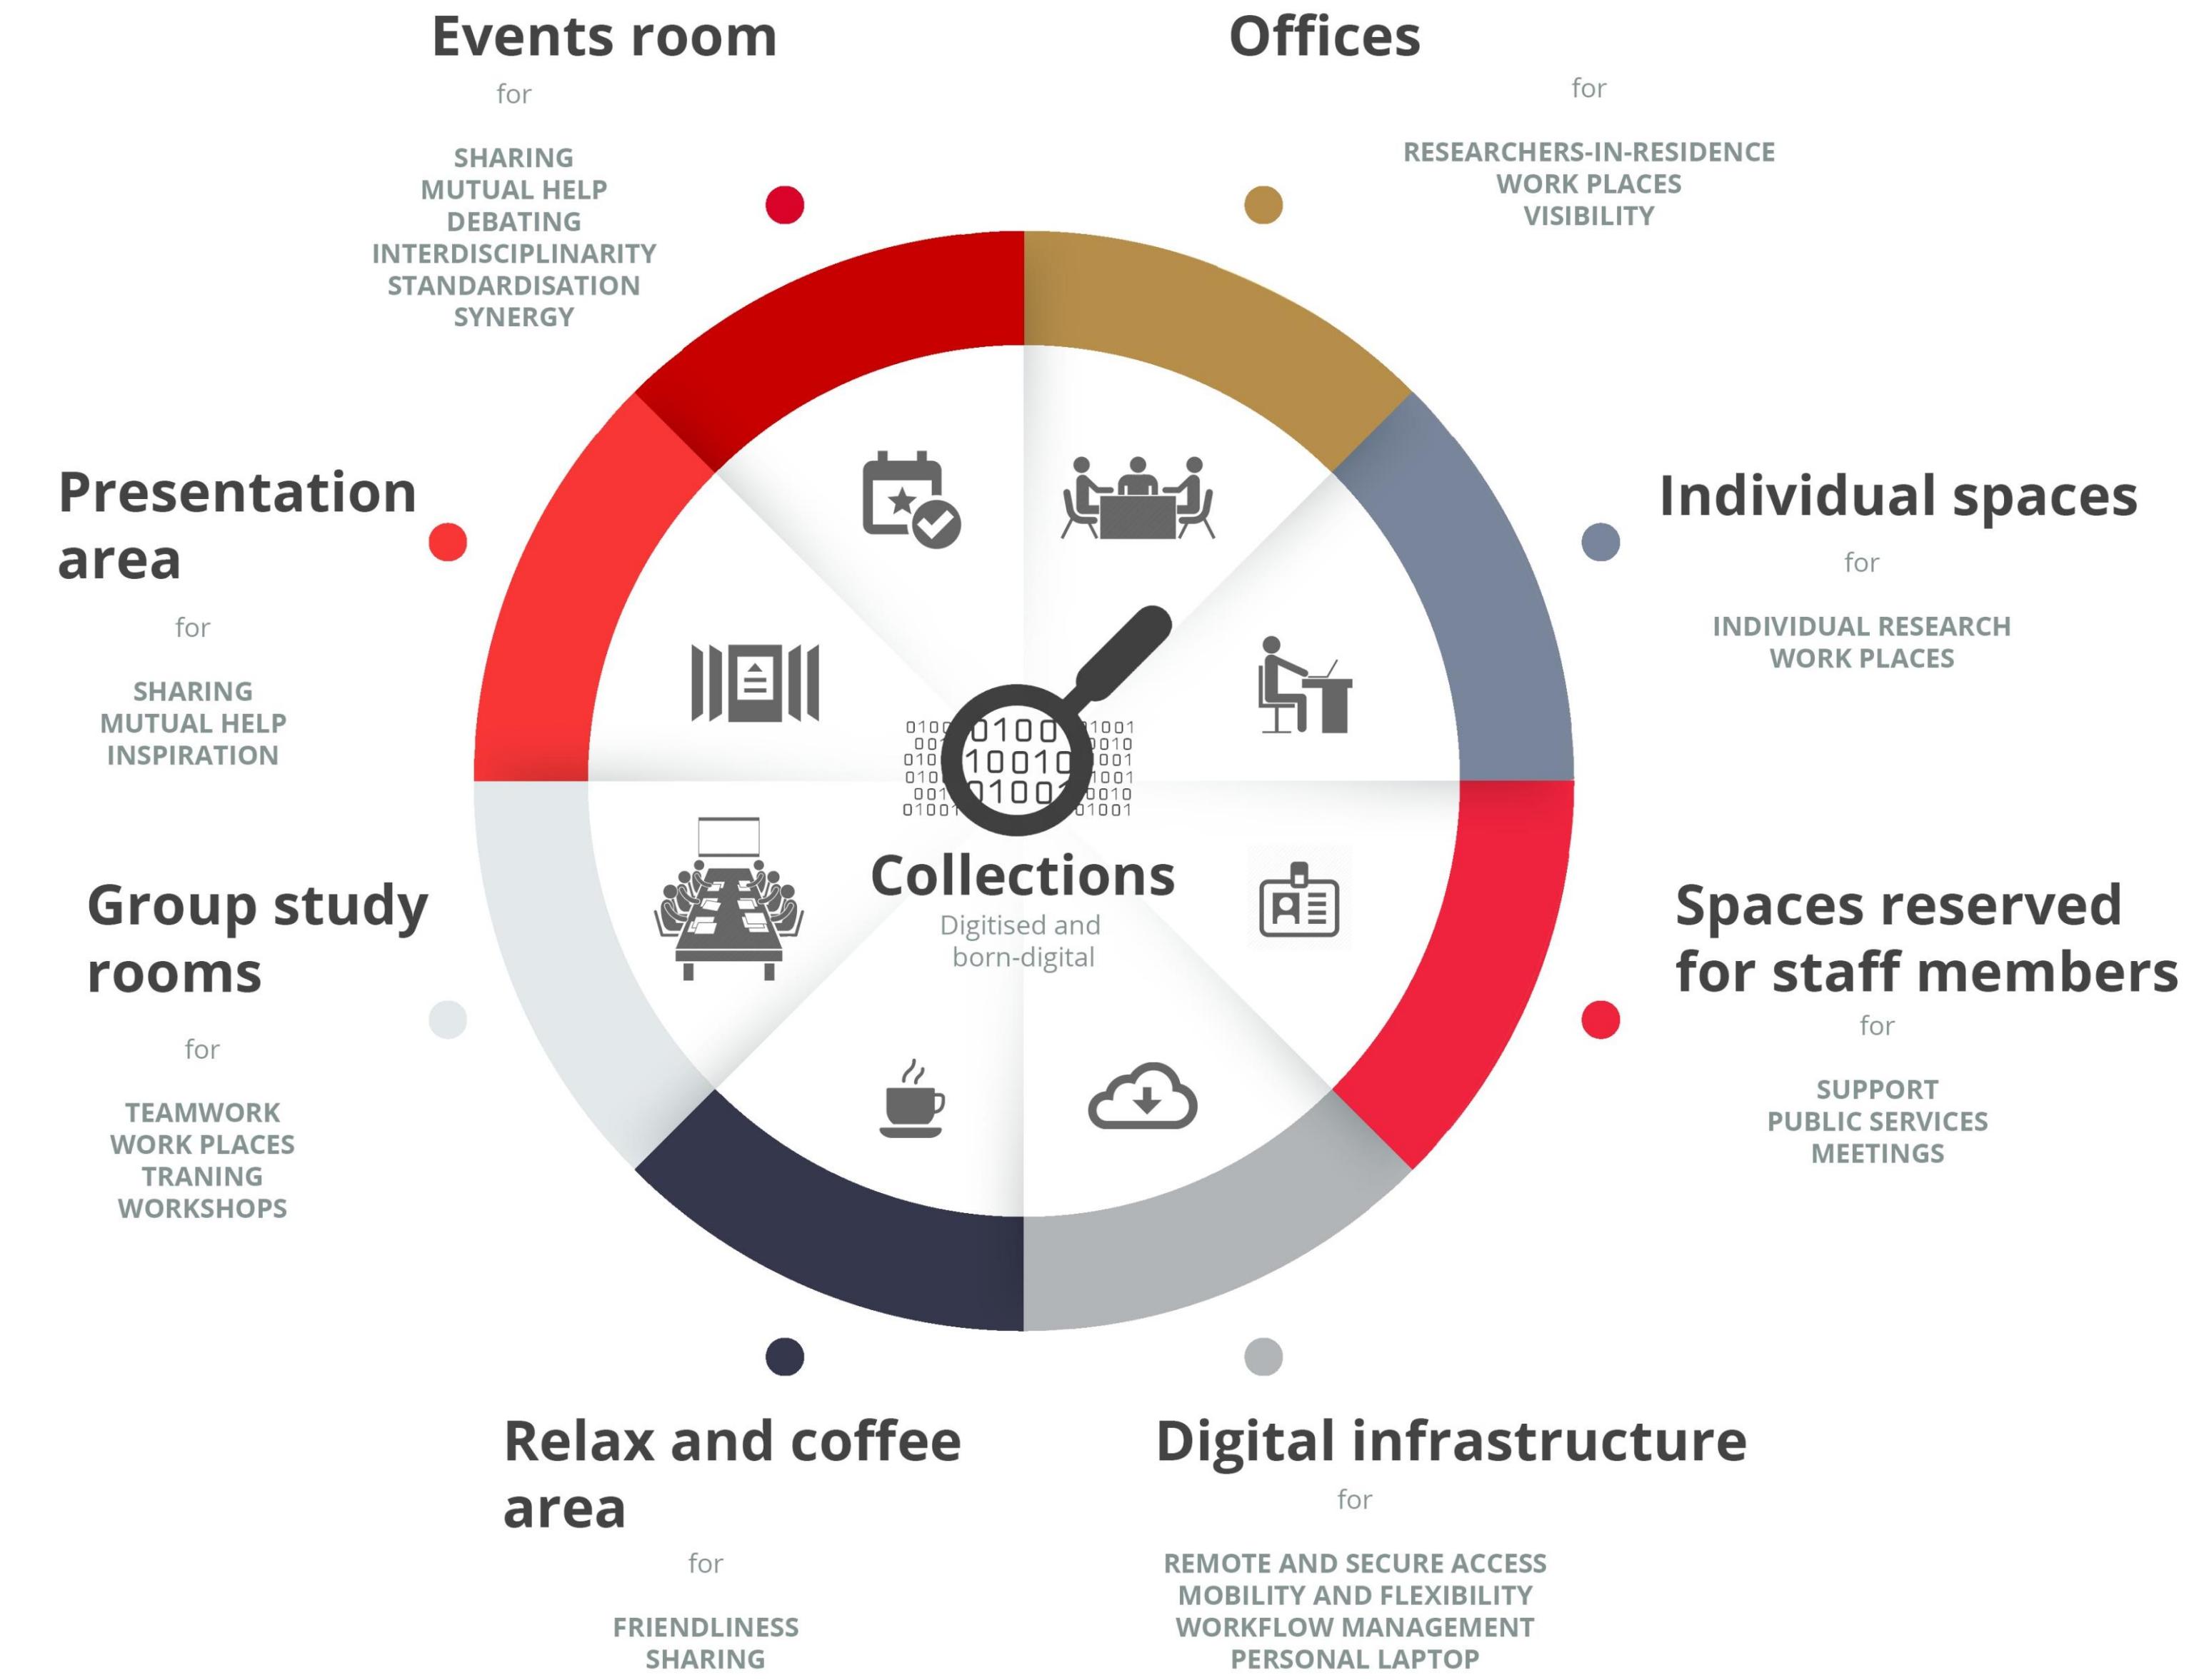
SUPPORT AND  
TRAINING  
ON DATA MODELS,  
FORMATS AND  
DOCUMENTARY  
POLICY

ANIMATION OF A  
CROSS-DISCIPLINARY  
COMMUNITY

ADVISE AND  
REDIRECTION

DISSEMINATION  
AND INTEGRATION  
OF TOOLS AND  
RESEARCH  
FINDINGS

# Towards a Digital Humanities Lab



# Online/ virtual services



The screenshot shows the homepage of the BnF API and datasets website. At the top, there's a banner with the text "Découvrez et utilisez les données de la BnF". Below the banner is a large green graphic of a DNA double helix. The main content area has a dark background with white text. It describes the portal as documenting APIs for querying and retrieving metadata from BnF catalogues and digitized collections. It mentions various formats and technologies used for data distribution. A call to action encourages users to participate in the hackathon. There are also links to "Actualités" and "Journée d'études".

Web archives Labs,  
an interface designed  
to meet researchers' needs



The screenshot shows the homepage of the BnF Archives de l'internet Labs website. The header features the BnF logo and the text "Archives de l'internet Labs". The main content area is divided into three sections: "Actualités 2010-2017" showing news from various French media sites; "Attentats 2015" featuring a collage of images related to the Paris attacks; and "Incunables 1996-2000" showing a collection of early web pages. The footer includes the BnF logo and the URL "archivesinternet.bnf.fr".

Website  
« API and datasets »  
created for the  
hackathon 2017  
<http://api.bnf.fr/>

**THANK YOU !**