

Usage scientifique des données BnF

Café Science Ouverte PAMIR

-

3 octobre

Jean-Philippe Moreux
Chef de mission IA, BnF



Quelles données ?

DONNÉES, adj. pris subst. *terme de Mathématique*, qui signifie certaines choses ou quantités, qu'on suppose être données ou connues, & dont on se sert pour en trouver d'autres qui sont inconnues, & que l'on cherche. Un problème, ou une question, renferme en général deux sortes de grandeurs, les données & les cherchées, *data & quæsitæ*. V. PROBLÈME, &c.

Quelles données ?

documents nés numériques



documents numérisés




données dérivées

imagination dream idea wonder amazing awe warmth you imagination dream idea wonder amazing awe warmth you
inspired thought insight craft passion revolution idea learn inspired thought insight craft passion revolution idea learn
create unique life possible different illustrate illustrate vision create unique life possible different illustrate illustrate vision
decorate enlighten notion concept idea invention elevated describe enlighten notion concept idea invention elevated
form design light creation you sculpt passion insight story form design light creation you sculpt passion insight story
artist dreamer illuminate print art favourite mood mystical artist dreamer illuminate print art favourite mood mystical
construct desire describe awesome revise involve explore construct desire describe awesome revise involve explore
see believe yourself graphic force motion line form wonder see believe yourself graphic force motion line form wonder
light free timeless www.thedailyblog.com alone design arts light free timeless www.thedailyblog.com alone design arts
imagination dream idea wonder amazing awe warmth you imagination dream idea wonder amazing awe warmth you
inspired thought insight craft passion revolution idea learn inspired thought insight craft passion revolution idea learn
create unique life possible different illustrate illustrate vision create unique life possible different illustrate illustrate vision
decorate enlighten notion concept idea invention elevated describe enlighten notion concept idea invention elevated
form design light creation you sculpt passion insight story form design light creation you sculpt passion insight story
artist dreamer illuminate print art favourite mood mystical artist dreamer illuminate print art favourite mood mystical
construct desire describe awesome revise involve explore construct desire describe awesome revise involve explore
see believe yourself graphic force motion line form wonder see believe yourself graphic force motion line form wonder
light free timeless www.thedailyblog.com alone design arts light free timeless www.thedailyblog.com alone design arts

jeux de données



métadonnées



Pour quels usages ?

Obtenir des données : API, dumps, datasets

Chercher des données : SRU Catalogue, SRU Gallica, SPARQL data.bnf

Référencer/liar des données : identifiants ARK, ISNI, etc.



**Industries culturelles,
recherche, grand public**



**Interroger, aligner, réutiliser,
transformer, agréger...**

Par quels moyens ? quelle modalité ?

Z39.50



OAI-PMH



- Synchrone ([exemple](#))
- Asynchrone ([exemple](#))

Régime d'usage

Métadonnées (CG, data.bnf...) : licence [Etalab](#) (équivalent CC-By)

- tout usage autorisé (y compris commercial), attribution obligatoire
- Note : les métadonnées ne sont pas protégeables par le CPI. Une base de métadonnées peut l'être (droit des producteurs de bases de données)

Documents numérisés de Gallica : [licence Gallica](#)

- pour la recherche, tout usage autorisé (y compris publication commerciale), attribution obligatoire
- usage commercial sous redevance (CRPA, Code des relations entre le public et l'administration) : la licence porte sur les fichiers, non sur les contenus (domaine public)

Régime d'usage

Documents sous droit (notamment Gallicaintramuros, archives du Web) :

- pour la recherche, autorisation d'accès dans les enceintes de la BnF (exception *text mining*) : service BnF datalab ouvert en 2021 (collaboration Huma-Num)
- usage commercial si accord des ayants droit. Note : La BnF n'est pas titulaire de droits de propriété intellectuelle

Données d'usage : au cas par cas. Note : attention aux données personnelles et au droit de la personnalité

A paraître : *Guide juridique sur la réutilisation des données patrimoniales détenues par des institutions culturelles dans des systèmes d'intelligence artificielle générative* (INA, BnF)

En pratique : cas de Gallica

Interroger le moteur d'indexation Gallica : API [SRU](#), API Facettes, API Occurrences

Accéder aux métadonnées Gallica : protocole [OAI-PMH](#) et API [OAIRecord](#)

Accéder aux données documentaires : API [Pagination](#), [Calendrier](#), [Table des matières](#)

Obtenir le texte : [HTML](#)*, [PDF](#)*, [OCR](#)*

Obtenir les images : API IIIF [Presentation](#) et [Image](#)* v2, [Vignettes précalculées](#)
2026 : API IIIF v3 + gestionnaire d'API (qualité de service paramétrable)

** API limitées à 6 ou 12 appels par minute*

Enjeux

Politique d'ouverture des données et essor des usages computationnels des collections :

- Succès du Datalab
- ... mais problème de qualité de service (usage massif des API)
- difficulté à répondre à la demande (datasets, dumps)

Restrictions API / mise en place d'un gestionnaire d'API (politiques de qualité) / séparation des architectures Gallica web et Gallica API


Essor de l'IA Gen :

- Moissonnage massif des collections patrimoniales (robots de scraping)
- Ouverture d'un service [Data IA](#) (datasets à façon pour le secteur privé)

Usage des ressources




Appels sites BnF (en millions)




Septembre 2025 (2 semaines, 792 M)

API images-total des requêtes



API de présentation-total des requêtes



2025 (6 mois, environ 75 M)

Ressources

- api.bnf.fr : documentation, tutoriels, jeux de données
- [Les API ouvertes de la BNF](#) : webinaire DINUM, juin 2021
- <https://www.bnf.fr/fr/bnf-datalab> : [présentation](#)
- [Gallica et corpus numériques](#) : tutoriel