

Exploring web archives using Hyphe, a research oriented web crawler

Sara Aubry, BnF & Benjamin Ooghe-Tabanou, médialab Sciences Po
IIPC Web Archiving Conference, April 25-26th 2024, Paris

(BnF) Archives de l'internet

Remonter le temps
Trouver l'archive d'un site, une page, un fichier en indiquant son adresse URL

Recherche par mot dans des collections sélectionnées

Rechercher l'URL | Archives de l'internet Labs

Recherche avancée

Découvrir les collections à travers des sélections thématiques

Presse et actualité | Des vidéos à la chaîne | La bande dessinée | Le web électoral de 2... | Intelligence artificielle... | Traits et portraits

Tous les parcours guidés

Sur son blog ouvert en 2008, Margaux Motin expose avec humour des anecdotes de sa vie de trentenaire.

La Loutr masquée est un blog collectif créé par deux passionnés. « Parce que les BD, c'est bien ! ».

« Bandes détournées » écrit des scénarios à partir d'images et BD anciennes.

Casemate, un des derniers magazines de prépublications de bandes dessinées en France.

L'auteur de bande dessinée et caricaturiste de presse Phil Decressac saisit la société contemporaine.

Recherche par URL
URL: http://www.elysee.fr
Date: du 1 jan. 1996 au 2 avr. 2024
5 425 résultats

2024	45 résultats
2023	1 012 résultats
2022	650 résultats
2021	385 résultats
2020	337 résultats
2019	348 résultats
2018	66 résultats

National Library of France web archives

- From 1996 to now
- 52 billion URLs, 2 PB of data
- Growing with annual crawls of million websites (5.6 mio in 2023) and regular crawls of thematic, event and media focused websites (currently 70,000)

hyphe

An open source tool for social scientists to create corpuses of web actors and map the hyperlinks between them

Methodological principles:

- **Web entities:** fine definition of actors beyond “websites”
- **Prospection loop:** iterative curation of discovered actors

slideshow.net/medialabSciencesPo
vimeo.com/medialab/videos
medialab.sciences-po.fr
sciences-po.fr
sciencespo.fr

medialab
sciences Po
ALIASES

ACTOR'S PRESENCE ON THE WEB

SELECTION OF WEB ENTITIES
CRAWLING
URL CANDIDATES

RES PADON

Connecting Hyphe to web archives, an outcome of the project



Allowing Hyphe to:

- Target a specific date and a time frame around this date
- Browse the archive via a wayback-like system
- Target precise capture dates to avoid drifting over time
- Support permalinks and archival URLs

Addressing new research methods & use cases:

- Map online communities from the past
- Compare time snapshots & study the structural transformations
- Complete live web with archived material of disappeared websites

CRAWL WEB ARCHIVES (experimental)

[EXPERIMENTAL] THIS IS AN EXPERIMENTAL FEATURE. YOU SHOULD UNDERSTAND THAT CRAWLING WEB ARCHIVES IS NECESSARILY MUCH SLOWER SINCE ALL CRAWLS WILL QUERY ONLY ONE SAME SERVER.

Choose a source of web archives:

crawl the live web, not any kind of web archive

Live Web

crawl worldwide web archives maintained by Archive.org

Web.Archive.org

crawl France's official web archives maintained by BnF

ArchivesInternet.BnF.fr

Date to try to approach
01 / 01 / 2023

Delay to consider before and after the date
Whatever

1996-01-01 → 2023-02-07

Hyphe is now compatible with web archives from BnF, INA, Arquivo.pt & Internet Archive



Experiment crawling through the archives in a DataSprint

- Hands on workshop during 5 days within BnF DataLab
- Dive into data to explore hypothesis on research questions
- Gather complementary skills & expertises: research, web archiving, engineering, design, digital methods
- Experiment with different methodological and exploratory approaches
- Find preliminary insights

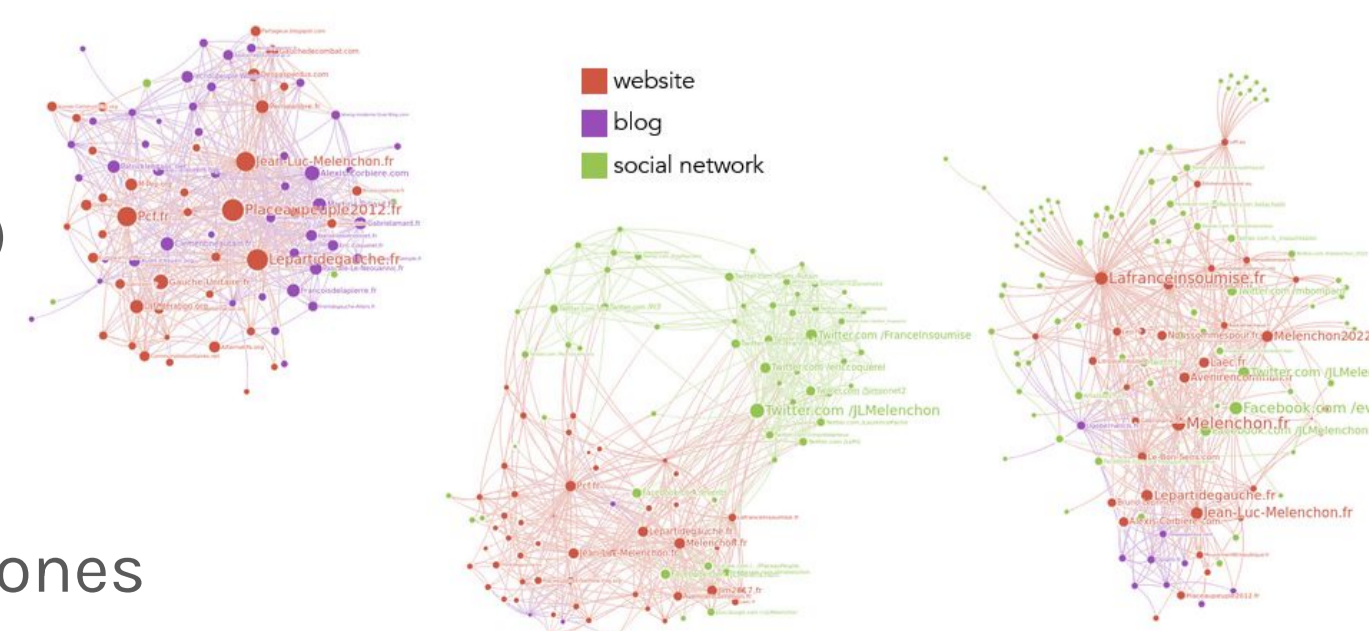


Focus on a presidential candidate's campaigns: Jean-Luc Mélenchon

Hypothesis: online communities changed across 2012, 2017 & 2022 campaigns

Methodological approach:

- Define time windows depending on available archives
- Start coherent crawls from stable sources (Wikipedia)
- Define common rules to select and include actors
- Use ontologies to tag actors (editorial form, nature)
- Produce graphs to visualize differences
- Identify disappeared actors, newcomers and resilient ones



- Hyphe's source code, demo & references: <https://github.com/medialab/hyphe>
- BnF's Web Archives introduction: <https://www.bnf.fr/fr/depot-legal-du-web>
- ResPaDon DataSprint results: <https://respaddon.medialab.sciencespo.fr>
- Contacts: sara.aubry@bnf.fr benjamin.ooghe@sciencespo.fr
- Photo credits: Caroline Maufroy / Sciences Po

