

**Produire, ouvrir et valoriser  
les logiciels de recherche**

## **Retour d'expérience en SHS : Hyphe**

Colloque Sciences Ouvertes 2024 – Université de Lorraine

28 novembre 2024

Benjamin Ooghe-Tabanou (@boogheta@piaille.fr / @boogheta)

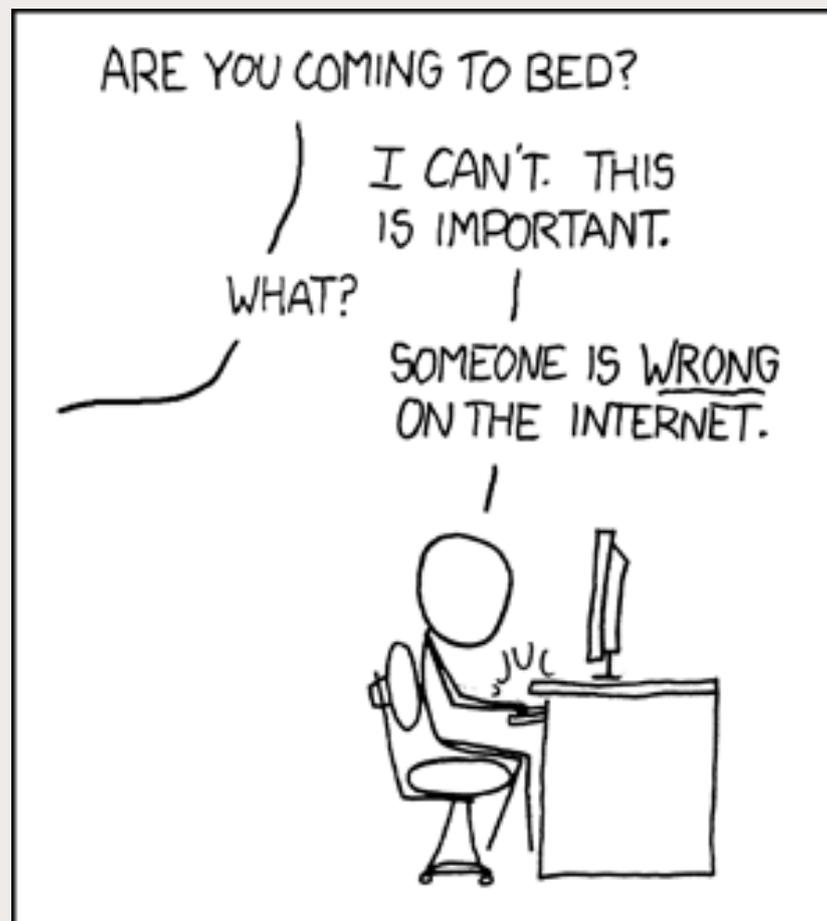
Sciences Po médialab (@medialab\_ScPo)

**SciencesPo**  
MÉDIALAB

# Exploiter le Web comme terrain d'enquêtes

Le Web : un espace de débats et de controverses

Collecter, enrichir, nettoyer, visualiser & analyser les traces numériques

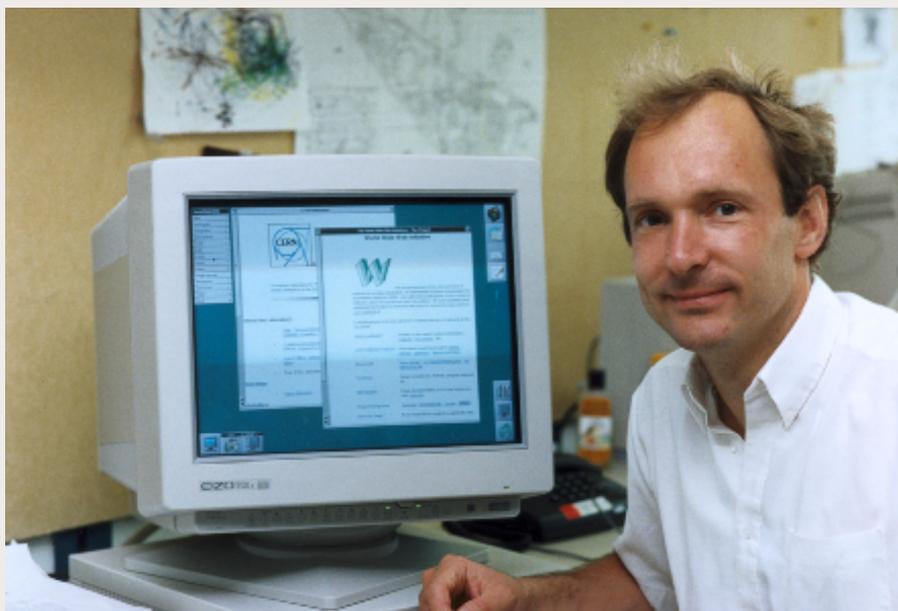


CC-BY-NC - Randall Munroe - XKCD



# Crawler le web en SHS : pour quoi faire ?

L' « **Hyperlien** » au cœur de la conception du Web  
→ porteur de sens et de structure



« The texts are **linked together** in a way that one can go from one concept to another to find the information one wants.

The network of links is called a **web**. [...]

The texts are known as **nodes**.

The process of proceeding from node to node is called **navigation**. »

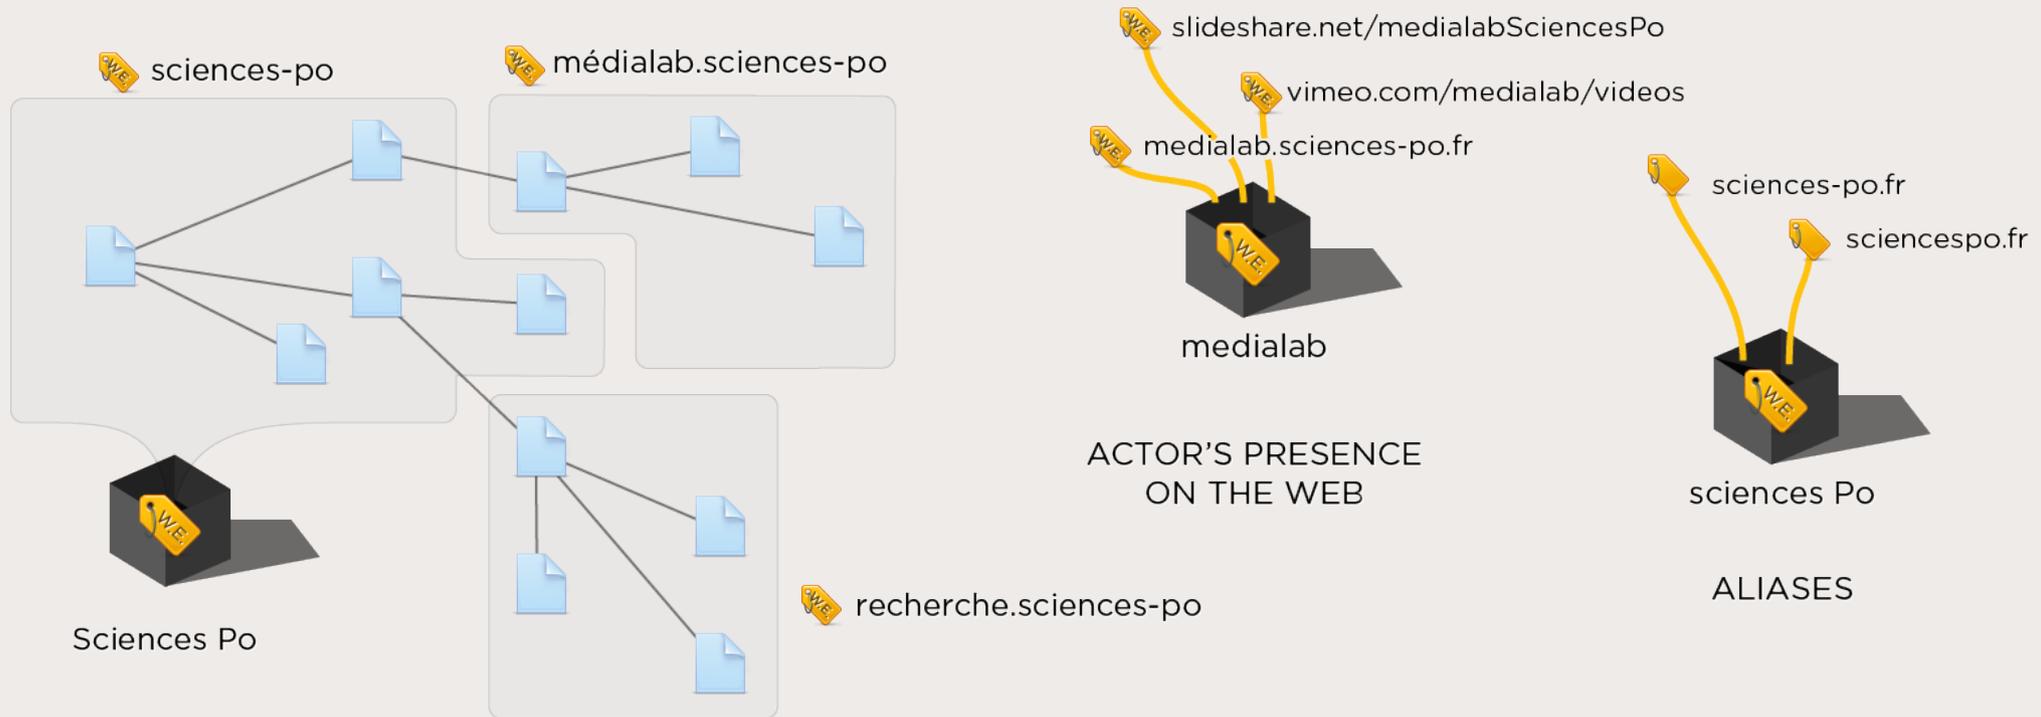
Tim Berners-Lee, 1990, WorldWideWeb: Proposal for a HyperText Project

« A hyperlink is a **manifestation of intention**. **By linking** one page to another, one piece of text to another, **people intend** to do particular things. »

Ryfe, Mensing, & Kelley, 2016, What is the meaning of a news link?

# Définir finement les frontières de ses acteurs

Mais qu'est-ce donc qu'un « site web » ?



→ « **WebEntité** » : ensemble de pages web agrégées pour rassembler l'incarnation précise d'un acteur sur le web au sens d'une question de recherche spécifique

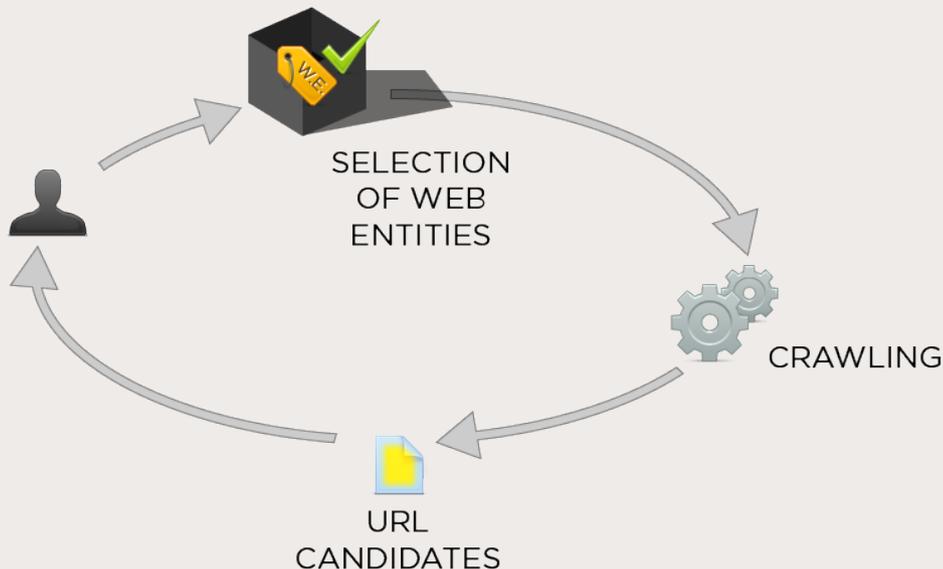
=> ensemble de préfixes d'URLs

# Une stratégie de crawling contrôlée

- Crawlers classiques : snowballing
  - Surreprésentation des couches hautes (Google, YouTube, Wikipedia...)
  - Dérive thématique rapide



- Hyphe : crawling semi-automatique
  - Fouille systématique uniquement des pages des WebEntités choisies
  - Choix humain des autres WebEntités à crawler grâce au degré de citation



PROSPECT 4,890 DISCOVERED

Search

APPLY CHANGES CANCEL

Distribution of citations (log scale)

NAME	CITED ↑
<input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Google.fr	23 >
<input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Instagram.com	19 >
<input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Free.fr	16 >
<input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Wordpress.org	16 >
<input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Wp.com	13 >

1 SET TO IN

Collectifmarianne... X

CRAWL

1 SET TO UNDECIDED

Legifrance.gouv.fr X

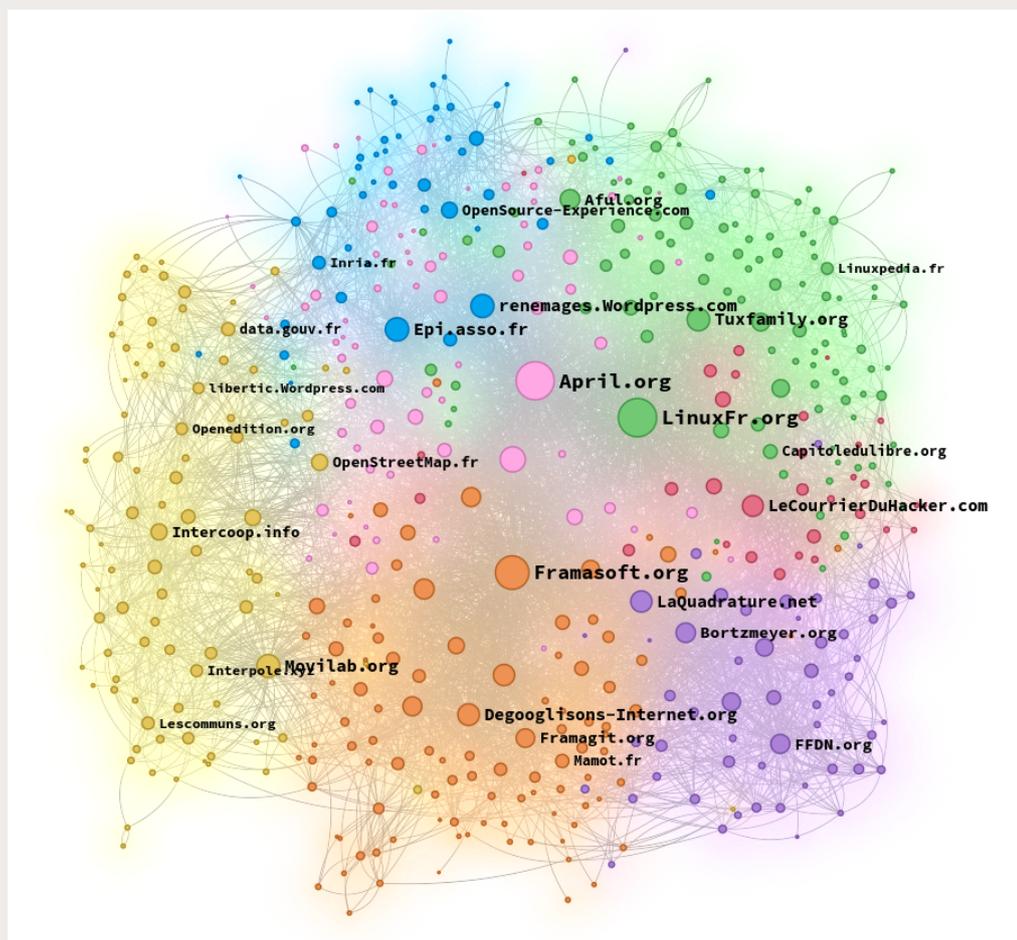
4 SET TO OUT

Gravatar.com X

Google.fr X

# De multiples usages pour Hyphe

- Une méthodologie complète :
  - sourcing, curation semi-automatisée, construction itérative, analyse exploratoire, catégorisation qualitative, visualisation de réseaux, analyse quantitative
- Divers publics-cibles :
  - Recherche : équiper les chercheurs en SHS pour réaliser un terrain web
  - Pédagogie : enseigner aux élèves le web au-delà de Google & Facebook
- Des analyses locales ou globales :
  - la structure interne d'un site web
  - Cartographie des communautés web sur une thématique
  - alliances et oppositions entre acteurs d'une controverse
  - etc.



Communautés du Libre en France sur le web

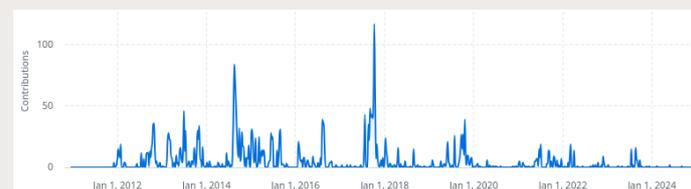
# Le développement d'outils au médialab

<https://medialab.sciencespo.fr/outils/>

- Viser une large **Adoption** :
  - **conception** d'outils dédiés aux besoins des chercheurs
  - **design** d'interfaces centrées sur l'utilisateur
  - **publication** d'outils web utilisables directement en ligne

- Assurer un maximum de **Réutilisabilité** :
  - diffusion **au plus tôt** en **Logiciel Libre**  
(téléchargeable, installable, vérifiable & modifiable)
  - développement « **opportuniste** » et « **agile** »  
« *Release early, release often* »
  - mise à disposition d'**APIs**

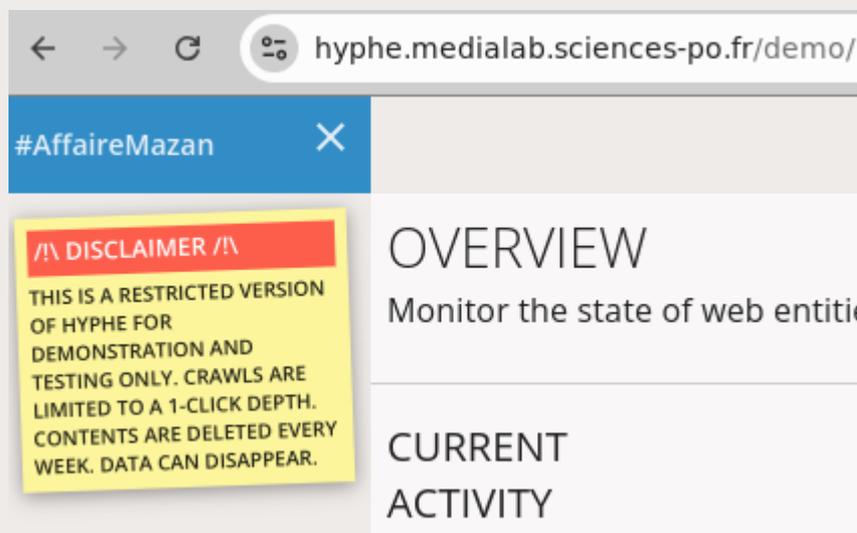
- **Documentation académique** et pratique  
(publications scientifiques, tutoriels, formations...)



v1.11.0 ... 🕒 on Dec 14, 2023	v1.10.6 ... 🕒 on Jul 21, 2023	v1.0.3 ... 🕒 on Aug 3, 2018	v0.2.2 ... 🕒 on Jun 20, 2017
v1.11.0-alpha ... 🕒 on Sep 8, 2023	v1.10.5 ... 🕒 on Nov 29, 2022	v1.0.2 ... 🕒 on Apr 26, 2018	v0.2.1 ... 🕒 on Feb 12, 2016
v1.10.9 ... 🕒 on Aug 25, 2023	v1.9.1 ... 🕒 on Aug 19, 2022	v1.0.1 ... 🕒 on Jan 26, 2018	v0.2 ... 🕒 on Apr 23, 2015
v1.10.8 ... 🕒 on Aug 21, 2023	v1.9.0 ... 🕒 on Mar 11, 2022	v1.0.0 ... 🕒 on Jan 15, 2018	v0.1 ... 🕒 on Feb 7, 2014
v1.10.7 ... 🕒 on Aug 3, 2023	v1.9.0-alpha3 ... 🕒 on Feb 14, 2022	v0.3 ... 🕒 on Oct 16, 2017	v0.0.0 ... 🕒 on Jul 19, 2013

# Faciliter l'adoption et l'installation

- Version de démonstration en ligne restreinte



~ 500 corpus  
de test créés  
chaque année

- Simplifier l'installation multi-plateformes  
→ Linux, Mac & Windows via Docker !



- Accompagner les installations individuelles et institutionnelles  
→ guider et automatiser des installations cloud
- Proposer un service payant d'installations SAS

# Accompagner les nouveaux utilisateurs

- Proposer des tutoriels texte ou vidéo
- Publiciser et expliquer les outils

**METSEM#06**  
SÉMINAIRE DE MÉTHODOLOGIE



*Explorer les  
internets  
avec Hyphe*

Judi 14 septembre 2017 - 10h à 12h  
Sciences Po, Salle Percheron  
98 rue de l'Université, 75007 Paris

Mathieu Jacomy  
médiabilab, Sciences Po

Le web c'est grand, surtout vers le fond. Et ce n'est pas très organisé, même si ce n'est pas non plus le chaos. Quelle est la structure du web et comment s'y orienter ? question plus difficile encore, comment trouver et identifier l'information pertinente sans amasser de caractères inutiles ? Le web nous oppose des défis à la fois méthodologiques et technologiques.

Le médiabilab de Sciences Po a développé HYPHE, un robot amasseur de données web aussi appelé «scraper», adapté aux besoins de la recherche en sciences sociales. Il s'adresse aux sociologues qui veulent investiguer le web comme terrain d'enquête qualitative et en tirer des indicateurs quantitatifs. S'appuyant sur le modèle du web «en couches», il guide son utilisateur pour construire, itérer et

après itération, un corpus de ressources et/ou d'acteurs, le travail manuel de sélection et de qualification de l'information est récompensé par un réseau de ressources que l'on peut exploiter de différentes manières: en analysant sa topologie avec GEPHI, en exportant ses textes vers un logiciel de traitement du langage, ou encore en construisant un moteur de recherche dédié.

Le médiabilab vous propose une présentation de HYPHE, un logiciel libre et open source, et une initiation à ses principaux concepts. Des exemples tirés des travaux des chercheurs ayant utilisé illustreront ses possibilités. Une démo de HYPHE est également disponible en ligne: hyphe.mediabilab.sciences-po.fr

Inscription obligatoire  
sur [metsem.hypotheses.org](http://metsem.hypotheses.org)

SciencesPo 

- séminaires
- conférences
- formations
- cours de master
- ateliers pratiques
- écoles d'été/hiver
- ...

- 1  HYPHE - Introduction to with Mathieu Jacomy - part 1/6  
VILA-BigSoftVideo at Aalborg University • 793 vues • il y a 4 ans • 22:45
- 2  HYPHE - Mathieu Jacomy Q and A - part 2/6  
VILA-BigSoftVideo at Aalborg University • 168 vues • il y a 4 ans • 11:22
- 3  HYPHE - Web crawling process session with Mathieu Jacomy - part 3/6  
VILA-BigSoftVideo at Aalborg University • 488 vues • il y a 4 ans • 13:42
- 4  HYPHE - Web crawling proces Q and A with Mathieu Jacomy - part 4/6  
VILA-BigSoftVideo at Aalborg University • 144 vues • il y a 4 ans • 6:05
- 5  HYPHE - What is a Web Entity with Mathieu Jacomy - part 5/6  
VILA-BigSoftVideo at Aalborg University • 241 vues • il y a 4 ans • 10:38
- 6  HYPHE - The Web as Layers with Mathieu Jacomy - part 6/6  
VILA-BigSoftVideo at Aalborg University • 168 vues • il y a 4 ans • 10:00

Error loading web entities

WEB ENTITIES

IN 4  UNDECIDED 0  OUT 0  DISCOVERED 153

Q Search

You chose to display nothing.  
Enjoy some user mockery! :)

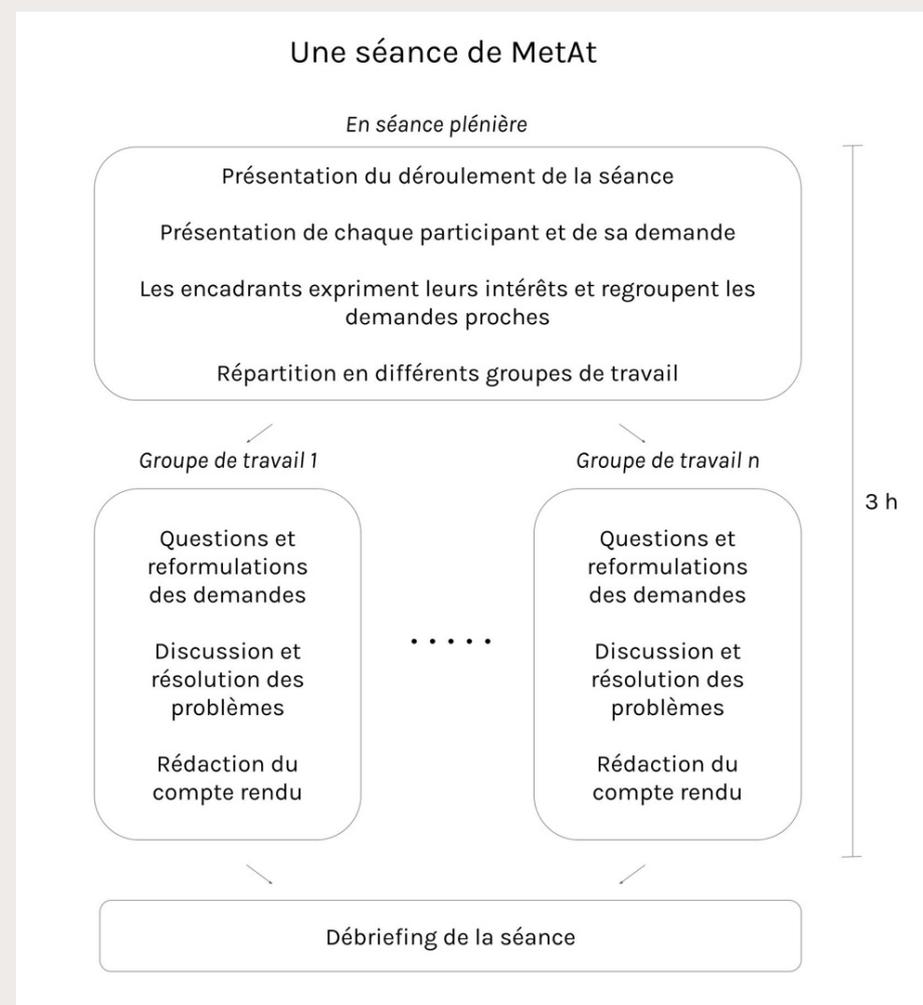


- Investir sur l'Expérience Utilisateur (UX)  
concevoir des interfaces tous publics  
→ **designer d'interfaces est un métier !**

# Le MetAt, atelier de méthodes numériques

<https://medialab.sciencespo.fr/activites/metat-atelier-de-methodes/>

- Demandes d'accompagnement :
  - discussion et conseil méthodologique
  - formation aux outils
  - collecte & nettoyage de données
  - visualisation exploratoire
  - ...
- Un mardi après-midi par mois
- Ouvert à tous, sur inscription préalable
- Initialement « atelier du médialab » :  
→ canaliser les sollicitations
- Élargi à la communauté des ingénieurs de recherche de Sciences Po en 2017 et à ceux de l'UPC en cours
- Contribue à l'autoformation continue

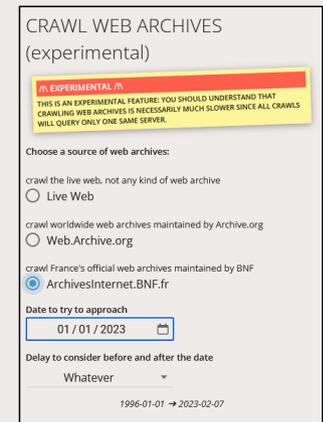


Diego Antolinos-Basso, Audrey Baneyx, Héloïse Théro, Benjamin Ooghe-Tabanou and Paul Girard, "L'atelier de méthodes de Sciences Po : apprendre, aider, rassembler", Humanités numériques, 5 | 2022, Online since 01 June 2022, connection on 09 November 2022.

<http://journals.openedition.org/revuehn/2799> DOI: <https://doi.org/10.4000/revuehn.2799>

# Favoriser l'émergence d'un écosystème d'outils

- Mettre en place des partenariats (BnF, INA, etc.)
- Proposer une API exploitable par d'autres outils
  - interne : Hyphe-Browser, minet ...
  - externe : IssueCrawler, PandorÆ ...



```

Default API commands (no namespace)

CORPUS HANDLING

• test_corpus :
  ◦ corpus (optional, default: "--hyphe--")

Returns the current status of a corpus : "ready"/"starting"/"missing"/"stopped"/"error".

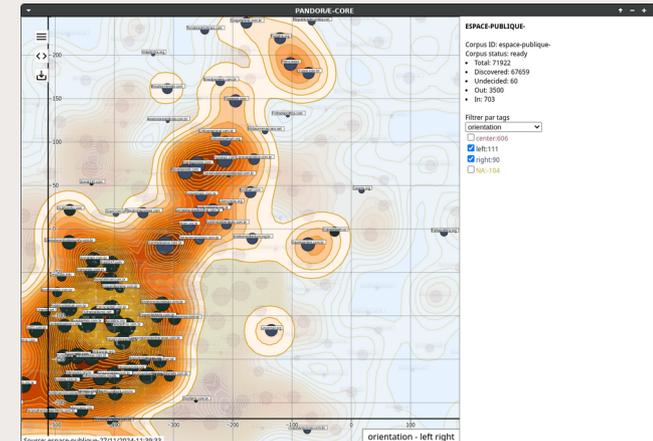
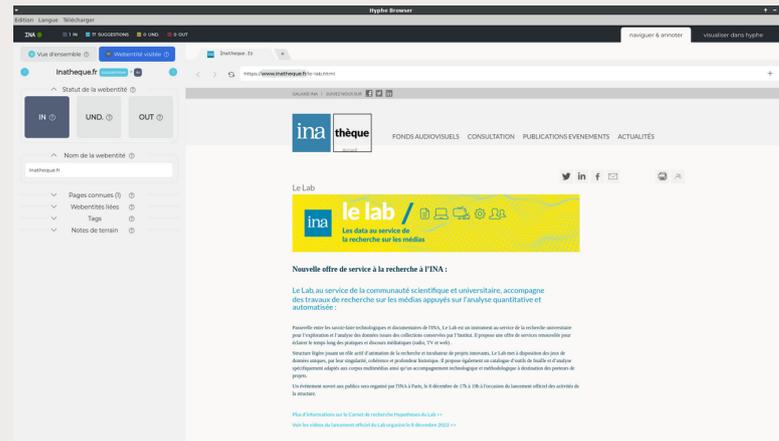
• list_corpus :
  ◦ light (optional, default: true)

Returns the list of all existing corpora with metas.

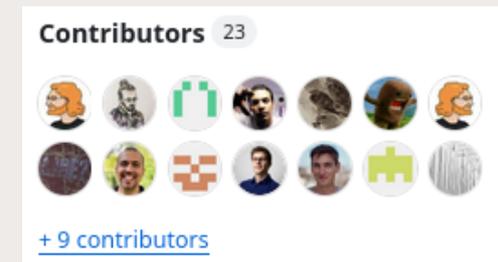
• get_corpus_options :
  ◦ corpus (optional, default: "--hyphe--")

Returns detailed settings of a corpus.

• set_corpus_options :
  ◦ corpus (optional, default: "--hyphe--")
  ◦ options (optional, default: null)
    
```



- Proposer une documentation destinée aux développeurs (architecture, code, installation, configuration...)
- Encourager (et accepter !) les Pull Requests



# Documenter et valoriser scientifiquement

- Permettre la **citation académique** de l'outil :
  - DOI pour le logiciel (via Zenodo)
  - Archivage via Software Heritage
  - Publications méthodologiques peer-reviewed
    - Jacomy M., Girard P., Ooghe-Tabanou B., Venturini T. (2016), **Hyphe, a Curation-Oriented Approach to Web Crawling for the Social Sciences**, ICWSM 2016, Cologne  
<https://sciencespo.hal.science/hal-01293078v2>
    - Ooghe-Tabanou B., Girard P., Jacomy M., Plique G. (2018), **Hyperlink is not dead!**, ACM Proceedings of the 2nd International Conference on Web Studies (WS.2 2018) Paris.  
<https://dl.acm.org/doi/10.1145/3240431.3240434>
- Publier également auprès des communautés logicielles :
  - Présenter les challenges techniques (devroom Open Research @ FOSDEM)
    - Plique G., Jacomy M., Ooghe-Tabanou B., Girard P. (2018), **It's a Tree... It's a Graph... It's a Traph! Designing an on-file multi-level graph index for the Hyphe web crawler**, FOSDEM 2018, Bruxelles  
<https://medialab.github.io/hyphe-traph/fosdem2018/#/>

**Hyphe: web corpus curation tool & links crawler**

DOI [10.5281/zenodo.10598422](https://doi.org/10.5281/zenodo.10598422)  archived  repository  archived [swh:1:dir:fd7d09aedcef215682ea25b3f86e21e8dc6dfc09](https://swh:1:dir:fd7d09aedcef215682ea25b3f86e21e8dc6dfc09)

# Documenter et valoriser scientifiquement

Title	Creator	Publication Title	Date
 Online networking behaviour of tourism stakeholders in a multi-desti...	Herasimovich et al.	Journal of Destination Marketing & M...	2024-03-01
 Varying Roles of Destination Management Organizations in the Digit...	Herasimovich et al.	Information and Communication Tech...	2024
 Green politics beyond the state: radicalizing the democratic potential...	Ejsing et al.	Climatic Change	2023-05-30
 Gruson-Daniel, Célya. "Mapping Contemporary "research on Resea...	Community	Open Research Community	2023-03-15
 Mapping European Digital Heritage Politics: An Empirical Study of E...	Capurro and Severo	Heritage & Society	2023
 InSciC—Knowledge-Aware Crawler for Indian Sciences	Hegade et al.	Proceedings of International Confere...	2023
 The 'more-than-food' geographies of omega-3s	Browne		2022-10
 Atlas multi-plateforme d'un mouvement social : le cas des Gilets jau...	Morales et al.	Statistique et Société	2022-09-28
 When teachers Google physical literacy: A cartography of controver...	Young et al.	European Physical Education Review	2022-08-01
 A network view on reliability: using machine learning to understand ...	Blanke and Venturini	Journal of Computational Social Scie...	2022-05-01
 Research Methodologies and Ethical Challenges in Digital Migration...	Sandberg et al.		2022
 Controversy Mapping and the Care for Climate Commons	Papazu and Veng		2022
 Réinterroger les notions d'accès à l'information géographique numér...	Desbonnet		2021-09-01
 Making the circular economy online: a hyperlink analysis of the artic...	Humalisto et al.	Environmental Politics	2021-07-29
 Savoirs incertains	Boullier et al.	RESET. Recherches en sciences soci...	2021-05-20
 Uncertain Knowledge. Studying "Truth" and "Conspiracies" in the Di...	Boullier et al.	RESET. Recherches en sciences soci...	2021-05-20
 "I'm not an antivaxxer, but...": Spurious and authentic diversity amo...	Cafiero et al.	Social Networks	2021-05-01
 Communication network analysis to advance mapping 'sport for dev...	Herasimovich and Alzu...	International Review for the Sociology...	2021-03-01
 Mapping the spread of Russian and Chinese contents on the French...	Douzet et al.	Journal of Cyber Policy	2021-01-02
 Beyond collected data: Politics of APIs on social media platformsa			2021
 Étude exploratoire sur la « recherche sur la recherche » : acteurs et ...	Gruson-Daniel and And...		2021
 Machine Learning based Classification of Online News Data for Dis...	Gopal et al.	2020 IEEE Global Humanitarian Tech...	2020-10
 La vulgarisation des recherches sur le phénomène de harcèlement ...	Stassin	Revue française des sciences de l'inf...	2020-09-01
 Ville intelligente et e-gouvernance en Inde, cartographier un nouvea...	Leclerc	Mappemonde. Revue trimestrielle sur...	2020-07-01
 Exploratory analysis of the hypertext structure linked to diabetes	Shi		2020-06-23
 Cartographier la propagation des contenus russes et chinois sur le ...	Douzet et al.	Herodote	2020-06-17
 Communication network analysis to advance mapping 'sport for dev...	Herasimovich and Alzu...	International Review for the Sociology...	2020-03-15
 Beyond issue publics? Curating a corpus of generic Danish debate i...	Munk and Olesen	STS Encounters	2020-02-08
 A New Web-Based Big Data Analytics for Dynamic Public Opinion M...	Tournay et al.	OMICS: A Journal of Integrative Biology	2020-01

# Merci de votre attention !

---

Code source de Hyphe :

<https://github.com/medialab/hyphe>

Version de démo limitée en ligne :

<https://hyphe.medialab.sciences-po.fr/demo/>

[benjamin.ooghe@sciencespo.fr](mailto:benjamin.ooghe@sciencespo.fr)

[@boogheta@paille.fr](mailto:@boogheta@paille.fr) [@boogheta](https://twitter.com/boogheta) [@medialab\\_ScPo](https://twitter.com/medialab_ScPo)