


# impresso - Media Monitoring of the Past I+II

## *Beyond Borders: Connecting Historical Newspapers and Radio*



Marten Düring & impresso team



1700

1750

1800

1850

1900

1950

2000





**Erstes Blatt.**  
**Erbliche Wahn.**  
Der Gedanke ist ein so wertvolles Gut, dass man es nicht ohne Bedenken veräußern sollte. In der Regel wird es durch Erbschaft übertragen, und es ist ein Fehler, es an einen Fremden zu verkaufen. Ein Erbe, das die Wahn erblich vererbt, ist ein Fehler, das man vermeiden sollte. Ein Erbe, das die Wahn erblich vererbt, ist ein Fehler, das man vermeiden sollte.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

# Haute tension sur l'avenir électrique

Le développement de l'électricité est un fait qui ne peut être nié. Les progrès réalisés dans ce domaine sont impressionnants. Les usines électriques sont devenues de plus en plus nombreuses, et les réseaux de distribution se développent rapidement. L'avenir électrique est donc très prometteur.



Une éolienne de haute tension sur le réseau électrique français, haute tension de 150 millions de volts environ.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

**Erstherzog von Bayern.**  
Der Erstherzog von Bayern ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat. Er ist ein Mann, der die Wahn erblich vererbt hat.

# LE PLOIER Société anonyme „La Ploier“ Luxembourg

**Avis mortuaire.**  
Madame Alph. Dieleich  
Le décès s'est produit le 22 avril 1912 à 10 heures du matin à l'âge de 72 ans. Les obsèques auront lieu le 24 avril à 10 heures à l'église de la Madeleine.

**Wohlfahrt's**  
Wohlgeruchs  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Fell-, Häut- und Magerkohlen**  
Schmelzkohle  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**RESTAURANT**  
Kleider-Schwer  
Wäsche, Hemden, Hosen, etc.

**Waggon**  
Kinderwagen  
Spielzeug  
3750  
400  
Stappwagen "Dreieck"

**Automobil**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Benennung.**  
Sargmajer und Möbel-Lager  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Herren- & Confection**  
Kleider, Hosen, etc.

**Erste Luxemburger**  
Kleiderfabrik und Hutfabrik  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Chaussures Modernes**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Abteilung Möbel**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Reisende**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Mr. MICHEL - BRAUM**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**MARA STIEFEL**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Abt. Polstermöbel**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Wander**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.


**Automobil**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Wasch- und Bleichmittel**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**par- Einlagen**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.

**Wander**  
Lebensmittel  
Brot, Butter, Käse, Fleisch, Fisch, Obst, Gemüse, Getreide, Mehl, Zucker, Salz, Pfeffer, Gewürze, etc.


## L'ère des incertitudes



## Christophe Babaiantz: le prix du renoncement à Kaiseraugst

Le développement de l'électricité est un fait qui ne peut être nié. Les progrès réalisés dans ce domaine sont impressionnants. Les usines électriques sont devenues de plus en plus nombreuses, et les réseaux de distribution se développent rapidement. L'avenir électrique est donc très prometteur.

# The landscape of historical newspapers





# The challenging landscape of historical newspapers

1. Institutional silos
2. Big and messy data
3. Noisy historical text
4. Visualisation and exploration
5. Digital Scholarship



# Newspapers as Data



'Collections as Data' as a "conceptual orientation to collections that renders them as ordered information, stored digitally, so that they are inherently amenable to computation".

<https://collectionsasdata.github.io/>

Bibliothèque nationale de Luxembourg  
Open Data

HOME DATA TOOLS API

datasets contain XML (METS + ALTO), PDF, original TIFF and PNG files for every newspaper issue.

Pack	Size	Contents
STARTER PACK	250MB	5 days of news, 5 newspaper issues, 22 pages, D'Wäschfra (1868), Public Domain, CC0 (See copyright notice), Best for getting started & developing
DEV PACK	3GB	1 month of news, 26 newspaper issues, 112 pages, Luxemburger Wort (1877), Public Domain, CC0 (See copyright notice), Best for getting started with Big Data
SAMPLE PACK	1GB	11 different newspaper titles, 1 issue per newspaper, News between 1845 and 1877, Public Domain, CC0 (See copyright notice), Best for testing different newspapers and metadata

<https://data.bnl.lu>



## 2. Show the total number of articles per year

In [another notebook](#), I look at different ways of visualising Trove newspaper searches over time. I set the `q` parameter to a single space.

```
[6]: # Set the q parameter to a single space to get ALL THE ARTICLES  
params["q"] = " "
```

Now we can find the total number of newspaper articles in Trove.

```
[7]: # Get the JSON data from the Trove API using our parameters  
data = get_results(params)  
  
# Navigate down the JSON hierarchy to find the total results  
total = int(data["response"]["zone"][0]["records"]["total"])  
  
# Print the results  
print("There are currently {:,} articles in Trove!".format(total))
```

There are currently 233,666,567 articles in Trove!


Ok, that's not all that useful. What would be more interesting is to show the total number of details in [this notebook](#) but, in short, we have to loop through the decades from 1800 to 201

These two functions do just that.

<https://glam-workbench.net/trove-newspapers/>



<https://glamlabs.io/>



#### ANALYSING THE EDITIONS OF *LES FLEURS DU MAL* DE BAUDELAIRE FROM DATA.BNF.FR

This [notebook](#) shows how to exploit the editions of *Les fleurs du mal* de Baudelaire using network graphs from [data.bnf.fr](https://data.bnf.fr).

[Binder](#)

[Preview](#)



#### COMPUTER VISION APPLIED TO SMITHSONIAN OPEN ACCESS

This [notebook](#) introduces how to explore [Smithsonian Open Access](#) to apply computer vision methods in face detection.

[Binder](#)

[Preview](#)



#### ACCESSING EUROPEANA IIIIF API

This [notebook](#) extracts a dataset from the [Europeana IIIIF API](#). It performs an automatic search, retrieving the manifests from the IIIIF server to create a dataset with the metadata as a CSV file.

[Binder](#)

[Preview](#)

<https://data.cervantesvirtual.com/glam-jupyter-notebooks>



*In which areas of research is this method/approach currently being used and developed, and what are its merits?*

*What types of data and research interests fit well with this method/approach?*

# Interdisciplinary projects on newspapers



How can semantic indexing  
enhance the study and exploration  
of historical newspapers?



# The team

Estelle Bunout  
Simon Clematide  
Marten Duering  
Maud Ehrmann  
Andreas Fickers  
Daniele Guido  
Frédéric Kaplan  
Peter Makarov  
Matteo Romanello  
Gerold Schneider  
Paul Schroeder  
Benoit Seguin  
Phillip Stroëbel  
Martin Volk  
Thijs van Beek  
Lars Wieneke



engineer



web dev



NLP

+ historical advisors  
+ associated historians



designer /  
web dev



NLP/DH



(digital)  
historian



NLP/DH



NLP



NLP



(digital)  
historian



designer /  
web dev



(digital)  
historian



web dev



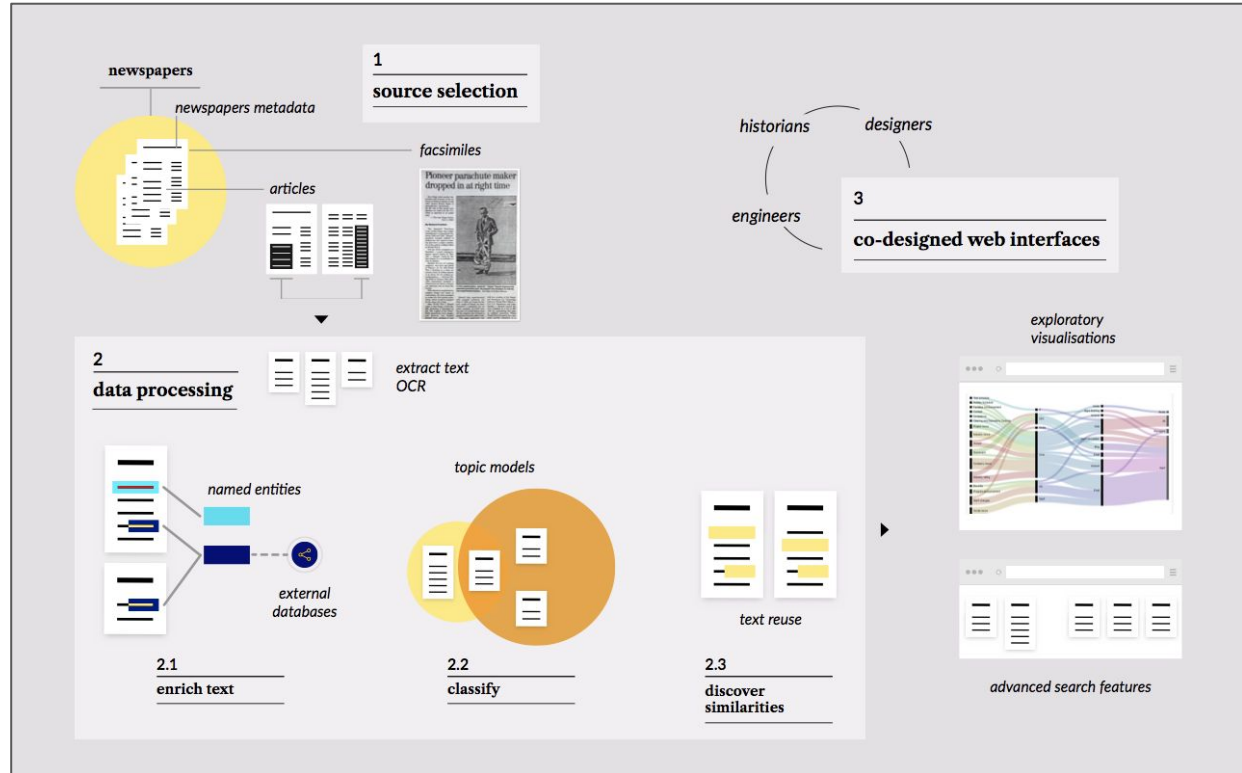
DH/robotics

# Objectives and research questions

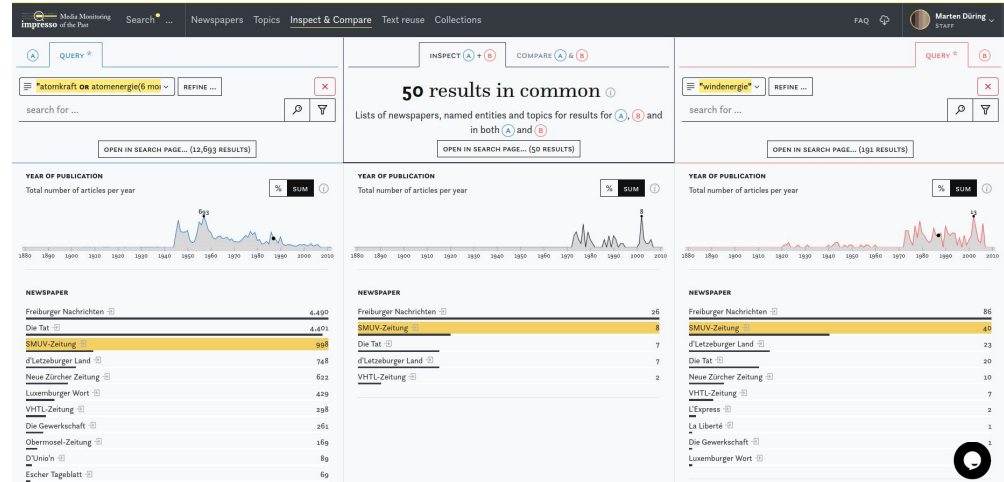

1. How to adapt NLP tools to historical texts?

2. How to explore complex and vast amounts of data?

3. What is the impact of new tooling on digital scholarship?



# Target audience



Historians without specific digital literacy but curiosity to go beyond keyword search and the motivation to learn how to use a research tool.



SEARCH ARTICLES SEARCH IMAGES NGRAMS


GROUP BY ARTICLE

ORDER BY RELEVANCE

DISPLAY AS LIST TILES

"arnhem OR amhem(2 more)" front · armée · guerre · ennemi · n · article French

Frontpage FIND SIMILAR WORDS



FILTER BY LANGUAGE OF ARTICLES (1 OPTION) results are filtered when: RESET

WRITTEN IN French(689 results)

- FILTER BY NEWSPAPER TITLES (14 OPTIONS) Journal de Genève (141 results) L'Impartial (123 results) La Liberté (112 results)

689 articles found containing arnhem or amhem or arnhem or arnehm - tagged as article; with topic FRONT · ARMÉE · GUERRE · ENNEMI · NORD; written in French

COMPARE ... SAVE / EXPORT



La progression des Aiiiés en Allemagne Journal de Genève WEDNESDAY, APRIL 18, 1945 - p.2

Personal use La progression des Aiiiés en Allemagne Q. o. allié, 17.--(AFP) Le communiqué de mardi annonce : Des forces alliées débouchant de la région d'Arnhem on LOCATIONS Claude Dallemagne, Zutphen, Gary Nord, Dessau, Leipzig, Halle, Saxony-Anhalt, Borna of Croatia, Altenburg, E. O. Plauen, Hof, Germany, Nuremberg, Heilbronn, Freudenstadt, Offenburg, Royan, Gironde, Berlin, Suisse, Moselle, Laufenburg, Germany, Lahr | : Des forces alliées débouchant de la région d'Arnhem ont avancé au delà d'Otterloo. Elles ont fait également

Kriegsbegriffe in CH X Arnhem 1944, filtered by topics X

VIEW ADD TO COLLECTION ...



Les forces alliées ont réalisé de nouveaux progrès à l'Ouest Journal de Genève SATURDAY, APRIL 7, 1945 - p.2

Personal use Les forces alliées ont réalisé de nouveaux progrès à l'Ouest C. Q allié, 6. — (A. F. P.) Au nord de Niraègue. les patrouilles alliées ont traversé le LOCATIONS Zutphen, Amelmo, Diepholz, Petershagen Nord railway station, Warburg, Hamm, Dortmund, Fulda, Karlsruhe, Deventer, Hamelin, Berlin, Lingen, Germany, Rheine, Recklinghausen, Siegen, Gotha (town) | de Niraègue. les patrouilles alliées ont traversé le Rhin Inférieur à l'ouest et à l'est d'Arnhem. Une vive

Kriegsbegriffe in CH X

VIEW ADD TO COLLECTION ...



DANS LE CORRIDOR ALLIÉ EN HOLLANDE Les Britanniques ont colmaté une ré[...]

Journal de Genève TUESDAY, SEPTEMBER 26, 1944 - p.2 Personal use DANS LE CORRIDOR ALLIÉ EN HOLLANDE Les Britanniques ont colmaté une récente brèche faite par les S. S. Auprès de la 2<sup>ème</sup> armée britannique, 26. — (Ier LOCATIONS Eindhoven, Brussels, Turnhout, Berlin, Nancy Wake, Veghel, Deurne, Netherlands, Metz, Moselle PEOPLE United Kingdom, Eisenhower Doctrine

| : Le corridor menant aux troupes portées d'Arnhem, qui avait été coupé hier par les Allemands, a de nouveau



# Example codesign: Word embeddings

find similar words



Enlarge your search! Type **one word** and obtain a list of surrounding words

atom German 50

Click on one of the following words to update your search

atom atomkraft nuklear atomare nukleare  
atomaren atomenergie atomarer atombombe  
thermonuklearen nuklearen atombomben  
wasserstoffbombe plutonium nuklearer atomischen  
wasserstoffbomben atomund atomares

Word embeddings?  
Keyword suggestions?  
OCR mistakes!

find similar words



Enlarge your search! Type **one word** and obtain a list of surrounding words

nucleaire French 50

Click on one of the following words to update your search

nucleaire nucieaire nucleaires nucléaire nueleaire  
nucieaires nuoleaire thermonucleaire hydrogene  
nuclôaires nuclei atomiques cleaire reacteur  
thermonucleaires reacteurs nuclaire lhydrogene  
cleaires megatonnes televidues lenergie

# Add similar

Media Monitoring of the Past **impresso** Search ... Newspapers To

SEARCH ARTICLES SEARCH IMAGES NGRAMS

"arnhem" ×

article text

Contains  NOT contains

arnhem

ADD NEW ... ADD SIMILAR ...

Enlarge your search! Type **one word** and obtain a list of surrounding words

arnhem French 25

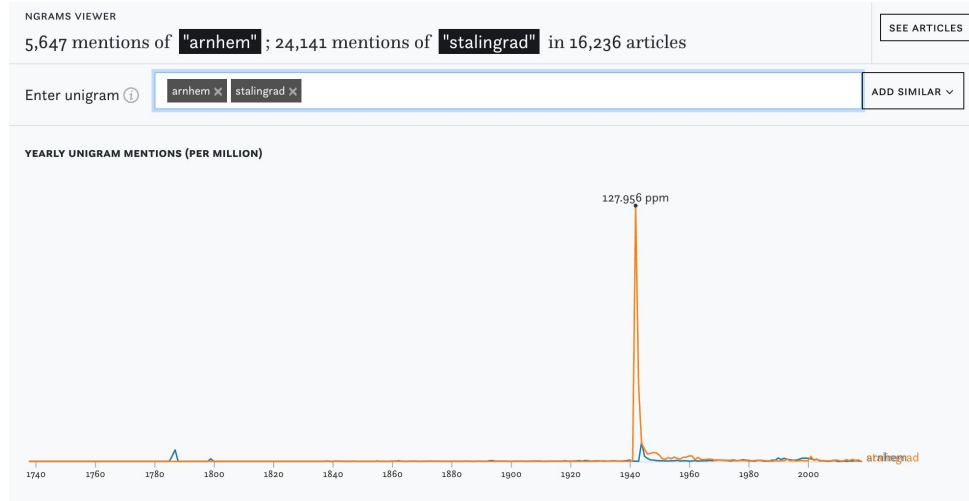
Click on one of the following words to update your search

arnhem amhem nimègue  
 zwolle venlo sittard  
 rotterdam tilburg roosendaal  
 eindhoven deventer arnhem  
 tilburg roosendaal

REMOVE

French (2,969 results) ↗

# Ngrams



# Filter by topic

The screenshot shows the 'impresso' Media Monitoring interface. At the top, there is a search bar with the query '"arnhem"'. Below the search bar, there are tabs for 'SEARCH ARTICLES', 'SEARCH IMAGES', and 'NGRAMS'. A list of filters is visible, including 'beigium (107 results)', 'Paris (592 results)', 'Berlin (585 results)', 'Basel (472 results)', and 'Enschede (448 results)'. A 'FILTER BY TOPIC (222 OPTIONS)' section is expanded, showing a list of topics with checkboxes. The selected topics are 'fr match · équipe · ligue · club · saison (1,182 results)', 'fr front · armée · guerre · ennemi · nord (603 results)', and 'fr match · jeu · but · équipe · minute (441 results)'. Other topics include 'fr bat · finale · tour · tournoi · match (414 results)', 'de schweiz · frankreich · deutschland · italien · schwede (346 results)', 'fr armée · colonel · service · major · chef (304 results)', 'fr suisse · pays · asile · étranger · canton (297 results)', 'fr août · juillet · septembre · juin · mois (292 results)', 'fr avril · mai · mars · lieu · juin (285 results)', and 'de berlin · münchen · wien · mark · frankfurt (272 results)'. At the bottom, there is an 'APPLY' button.

# Inspect & Compare

The screenshot shows the 'impresso' interface in 'INSPECT' and 'COMPARE' modes. The main heading is '8 results in common'. Below this, there are three panels, each showing a 'YEAR OF PUBLICATION' line chart. The first panel is for the query '"arnhem OR arnhem(2 more)"' with 206 results. The second panel is for 'front · armée · guerre · ennemi · n' with 8 results. The third panel is for 'stalingrad' with 11,167 results. Each chart shows a peak in 1942. Below the charts, there are controls for 'SCALE: LINEAR' and 'SORT BY ABSOLUTE INTERSECTION'. A 'NEWSPAPER (5 OPTIONS)' section is visible, showing a horizontal bar chart for 'L'Espresso', 'L'Espresso', 'Journal de Genève', 'L'Espresso', 'L'Espresso', and 'Newspaper'.




[Gianni Sarconi, \*The Master of Numbers\* \(2006\)](#)



[Jennifer Kuhns, \*Glass mosaic of Alice Paul, suffragist. 1885-1977\* \(2019\)](#)

*How could this method/approach contribute to the study of historical processes of knowledge evolution?*





Outlook: What is next?

# Text Reuse at Scale

Opportunity: integration of TR data with other semantic enrichments.

1. Expert workshop in Nov 2022 produced research objectives, tasks & mockups.
2. New prototype component.
3. User evaluation.
4. Research paper [[preprint](#)].
5. Revised prototype to be integrated in main app.

The screenshot displays the 'Text Reuse (experimental)' application interface. It is divided into several main sections:

- SEARCH TEXT REUSE PASSAGES:** Includes a search bar with 'hospitals' and a 'Filter' button. Below it is a 'NUMBER OF PASSAGES PER YEAR' line chart showing data from 1980 to 2020. There are also 'CLUSTER SIZE' and 'LEXICAL OVERLAP' sliders.
- Overview of Text Reuse Distribution:** A table showing 'NUMBER OF PASSAGES PER YEAR' for various countries like 'United States', 'France', 'Germany', etc., with columns for 'NUMBER' and 'TIME'.
- Statistics:** A line chart showing 'NUMBER OF CLUSTERS PER YEAR' for different clusters, with a legend for 'Cluster 1', 'Cluster 2', etc.
- List of Text Reuse Passages:** A list of search results with columns for 'DATE', 'TITLE', and 'LOCATION'. One result is highlighted with a red box.
- COMPARE TEXT REUSE PASSAGES:** A comparative view showing two passages side-by-side for comparison.

Navigation tabs at the top include 'SEARCH', 'NEWSPAPERS', 'TOPICS', 'INSPECT & COMPARE', 'TEXT REUSE', and 'TEXT REUSE (EXPERIMENTAL)'. A user profile icon is visible in the top right corner.

b) Overview tab: Distribution of metadata and enrichments in a set of clusters.

c) Statistics tab: Distribution of Text Reuse measures over time and newspapers.

a) Search and filters.

d) Passages tab: Passages within cluster c62714.

e) Passages tab: Comparative view.

SEARCH TEXT REUSE PASSAGES

"hiroshima"

hiroshima

NUMBER OF PASSAGES PER YEAR <sup>1</sup>  
Number of text reuse passages per year

ADD NEW DATE FILTER ...

CLUSTER SIZE <sup>1</sup>  
2 - 453 (2,881 results)

2

LEXICAL OVERLAP <sup>1</sup>  
100 (208 results)

0

TIME SPAN IN DAYS <sup>1</sup>  
0 - 470 (2,636 results)

0

FILTER BY NEWSPAPER TITLES (25 OPTIONS) <sup>1</sup>  
check one or more newspaper to filter results

FILTER BY TOPIC (181 OPTIONS) <sup>1</sup>  
check one or more topics to filter results

FILTER BY COLLECTION (13 OPTIONS) <sup>1</sup>  
check one or more collection to filter results

FILTER BY COUNTRY OF PUBLICATION (2 OPTIONS) <sup>1</sup>  
check one or more countries to filter results

FILTER BY ARTICLE TYPE (4 OPTIONS) <sup>1</sup>

a) Search and filters.

TEXT REUSE

Overview of Text Reuse Distribution

2,897 passages in 1,464 clusters containing **1 Hiroshima**

OVERVIEW STATISTICS 1,464 CLUSTERS 2,897 PASSAGES

NEWSPAPER	COUNTRY	TYPE	
L'Impartial <input type="checkbox"/>	CH <input type="checkbox"/>	sr <input type="checkbox"/>	2,897
Journal de Genève <input type="checkbox"/>	LI <input type="checkbox"/>	nl <input type="checkbox"/>	43
L'Express <input type="checkbox"/>		section <input type="checkbox"/>	19
Gazette de Lausanne <input type="checkbox"/>		page <input type="checkbox"/>	17
La Liberté <input type="checkbox"/>			146
Le Peuple, La Sentinelle <input type="checkbox"/>			184
Confédérée <input type="checkbox"/>			38
Freiburger Nachrichten <input type="checkbox"/>			37
Die Zeit <input type="checkbox"/>			33
La lutte syndicale <input type="checkbox"/>			18

LANGUAGE	PERSON	LOCATION	
fr <input type="checkbox"/>	United States <input type="checkbox"/>	Japan <input type="checkbox"/>	813
en <input type="checkbox"/>	Alan Morath <input type="checkbox"/>	France <input type="checkbox"/>	590
	Enola Gay <input type="checkbox"/>	SS <input type="checkbox"/>	55
	Marguerite Duras <input type="checkbox"/>	45 <input type="checkbox"/>	345
	Holbert Beane-Méry <input type="checkbox"/>	40 <input type="checkbox"/>	340
	George Washington <input type="checkbox"/>	39 <input type="checkbox"/>	323
	Pearl Harbor <input type="checkbox"/>	38 <input type="checkbox"/>	246
	Franco II of France <input type="checkbox"/>	34 <input type="checkbox"/>	201

b) Overview tab: Distribution of metadata and enrichments in a set of clusters.

TEXT REUSE <sup>1</sup>

List of Text Reuse Passages

View 7 passages in 1 cluster in clusters c62714

OVERVIEW STATISTICS VIEW 7 PASSAGES

TIME DIFFERENCE (LARGEST FIRST) <sup>1</sup>

La destruction totale d'Hiroshima  
Gazette de Lausanne  THURSDAY, FEBRUARY 15, 1958 - P.2

New York, 8. - (Reuter) Un message de Radio-Tokio capté à New York mercredi, dit que la bombe atomique « a littéralement fait passer de vie à trépas » tous les êtres vivants, humains et animaux, à Hiroshima. La radio a ajouté que les morts et les blessés étaient brûlés à un point tel qu'il est impossible de les recon- naïtre et que les autorités sont inca- cables d' (MORE...)

Cluster size: 7 passages with 28.07% lexical overlap over 19388 days. Content length: 1,258 tokens.

COMPARE WITH OTHER PASSAGES IN CLUSTER

Revue de la destruction de Hiroshima  
L'Impartial  WEDNESDAY, AUGUST 8, 1945 - P.5

NEW-YORK, 8. - (Reuter). — UN MESSAGE DE RADIO-TOKIO CAP- TE A NEW-YORK MERCREDI DIT QUE LA BOMBE ATOMIQUE « A LITTERALEMENT FAIT PASSER DE VIE A TREPAS » TOUS LES ETRES VIVANTS, HUMAINS ET ANIMAUX, A HIROSHIMA. La radio a ajouté que les morts et les blessés étaient brûlés à un point tel qu'il est impos- sible d' (MORE...)

Cluster size: 7 passages with 28.07% lexical overlap over 19388 days. Content length: 1,258 tokens.

COMPARE WITH OTHER PASSAGES IN CLUSTER

d) Passages tab: Passages within cluster c62714.

TEXT REUSE

Statistics

2,897 passages in 1,464 clusters containing **1 Hiroshima**

OVERVIEW STATISTICS 1,464 CLUSTERS 2,897 PASSAGES

TYPE OF VISUALISATION: NUMBER OF TEXT REUSE CLUSTERS OVER TIME, BY NEWSPAPER <sup>1</sup>

This graph shows the number of clusters of text reuse passages per year. Each line represents text reuse clusters in a single newspaper title.

c) Statistics tab: Distribution of Text Reuse measures over time and newspapers.

COMPARE TEXT REUSE PASSAGES

MONDAY, NOVEMBER 28, 1910 "M. Winston Churchill, ministre du commerce, pronon..." TEXTREUSEPASSAGE

Compare the passage below

lia crise britaiaillique. Gazette de Lausanne  MONDAY, NOVEMBER 28, 1910 - P.2

with #  of 3 passages BY DATE (DESC)

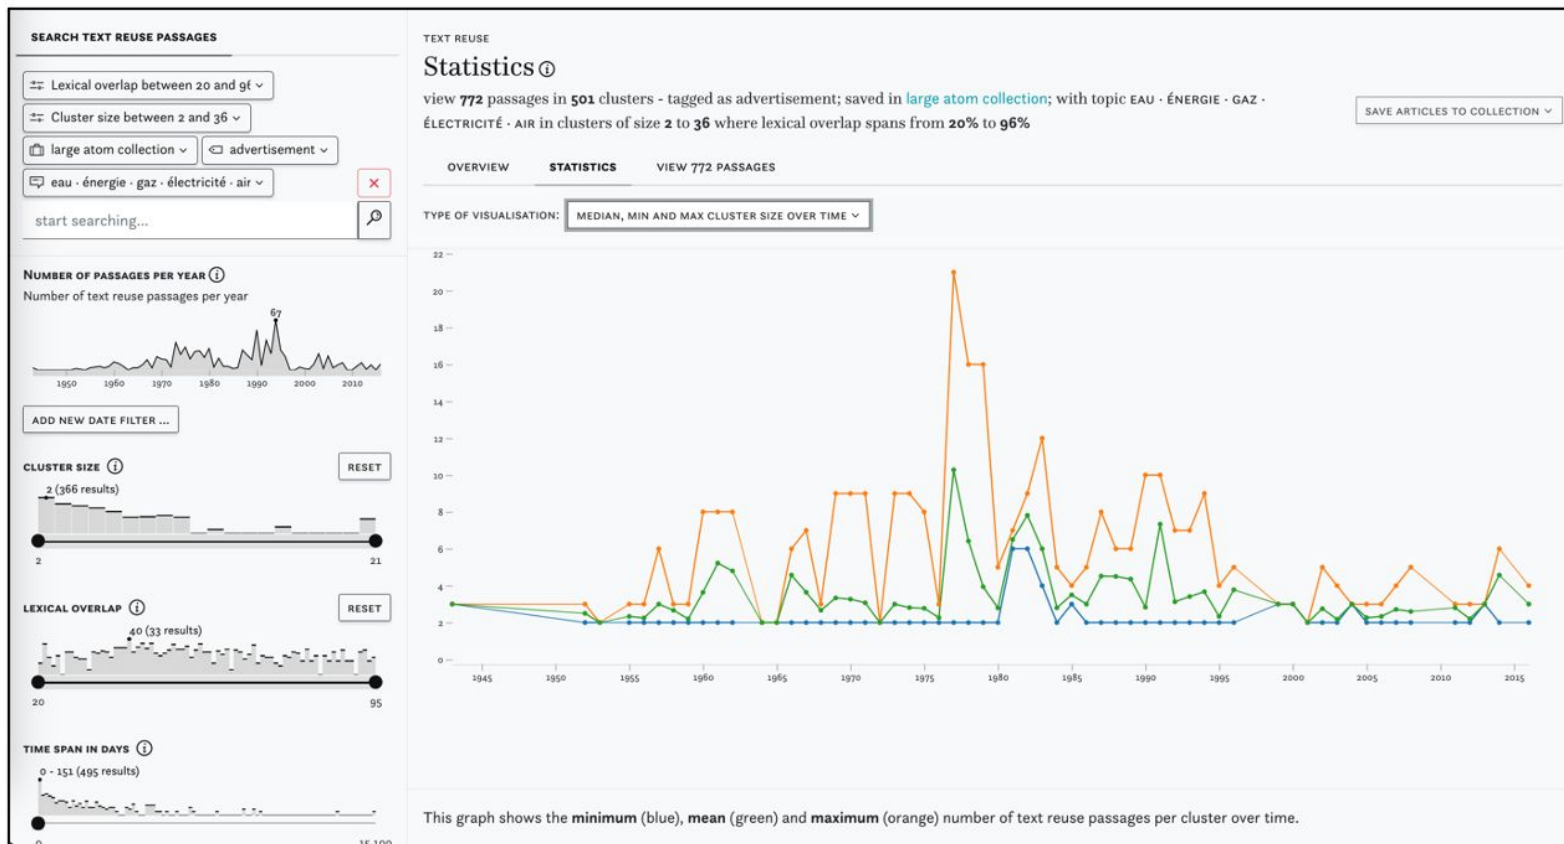
Les suffragistes font de l'action directe L'Indépendance luxembourgeoise  TUESDAY, NOVEMBER 29, 1910 - P.2

M. Winston Churchill, ministre du commerce, prononçait ven- dredi soir à Bradford a été coupé de plu- sieurs interruptions de suffragistes et de suffragettes qui ont été expulsés à tour de rôle. Comme l'orateur rentrait de Bradford à Londres, il fut attaqué dans le train par un individu, qui a essayé de le frapper avec une cravache en disant «Voilà pour toi, chien!» Deux agents de police parèrent le coup et s'emparè- rent de l'homme après une lutte violente. A la gare de Londres, trois femmes ont également essayé de frapper M. Churchill ; elles en ont été empêchées par les agents.

M. Winston Churchill, revenant à Londres, après avoir prononcé un dis- cours à Bradford, où les suffragettes et leurs partisans avaient déjà Wololment, main fesié contre lui, a été attaqué dans le train par un individu, qui a essayé de le frapper avec une cravache en disant «Voilà pour toi, chien!» Deux agents de police parèrent le coup et s'em- parèrent de l'homme, après une lutte violente. On croit que l'assaillant est un des suffragistes expulsés de la réunion où M. Winston Churchill venait de parler. A la gare de Londres, trois femmes ont également essayé de frapper M. Chur- chill ; elles en ont été empêchées par les agents.

e) Passages tab: Comparative view.

# Example: When did nuclear power ads circulate?



# Editing press agency content

COMPARE TEXT REUSE PASSAGES ×

MONDAY, NOVEMBER 28, 1910 "M. Winston Churchill, ministre du commerce, pronon..." TEXTREUSEPASSAGE

Compare the passage below

with #  of 3 passages

lia crise britaiiiiiluc.  
**Gazette de Lausanne** MONDAY, NOVEMBER 28, 1910 – P.2

M. Winston Churchill, ministre du commerce, prononçait vendredi soir à Bradford a été coupé de plusieurs interruptions de suffragistes et de suffragettes qui ont été expulsés à tour de rôle. Comme l'orateur rentrait de Bradford à Londres, il fut attaqué dans le train par un individu, qui a essayé de le frapper avec une cravache en disant : « Voilà pour toi, chien ! » Deux agents de police parèrent le coup et s'emparèrent de l'homme après une lutte violente. A la gare de Londres, trois femmes ont également essayé de frapper M. Churchill ; elles en ont été empêchées par les agents.

Les suffragistes font de l'action directe  
**L'indépendance luxembourgeoise** TUESDAY, NOVEMBER 29, 1910 – P.2

M. Winston Churchill, revenant à Londres, après avoir prononcé un discours à Bradford, où les suffragettes et leurs partisans avaient déjà violemment manifesté contre lui, a été attaqué dans le train par un individu, qui a essayé de le frapper avec une cravache en disant: «Voilà pour toi, chien!» Deux agents de police, qui accompagnaient M. Churchill, parèrent le coup, et s'emparèrent de l'homme, après une lutte violente. On croit que l'assaillant est un des suffragistes expulsés de la réunion où M. Winston Churchill venait de parler. A la gare de Londres, trois femmes ont également essayé de frapper M. Churchill ; elles en ont été empêchées par les agents.

# Where did the news come from?

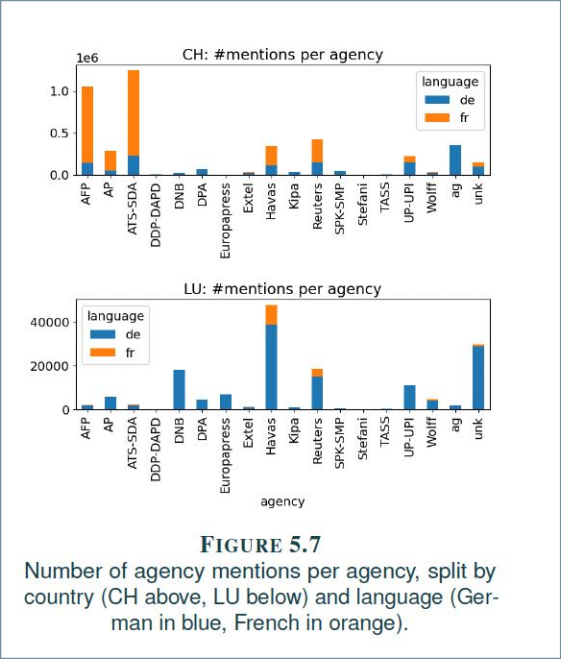
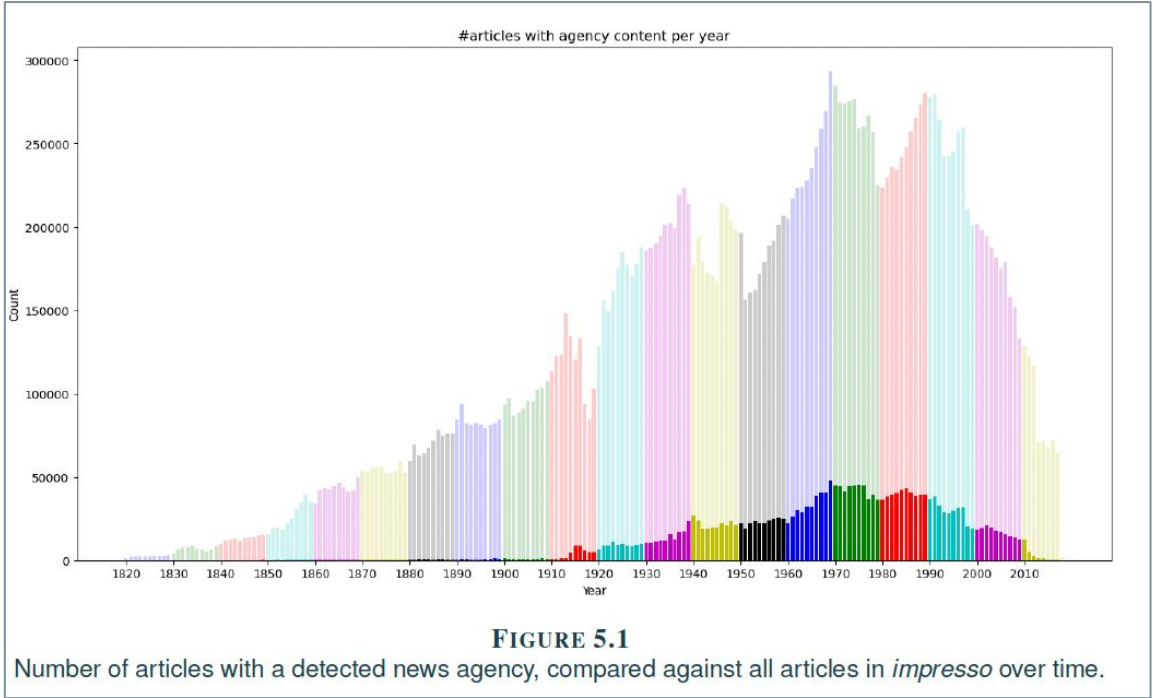
## News Agency Recognition

- Construction of an annotated dataset (27 agencies, ca 2000 articles, fr and de);
- Training and evaluation of models to recognise news agencies;
- Application on the whole *impresso* corpus;
- First analyses.

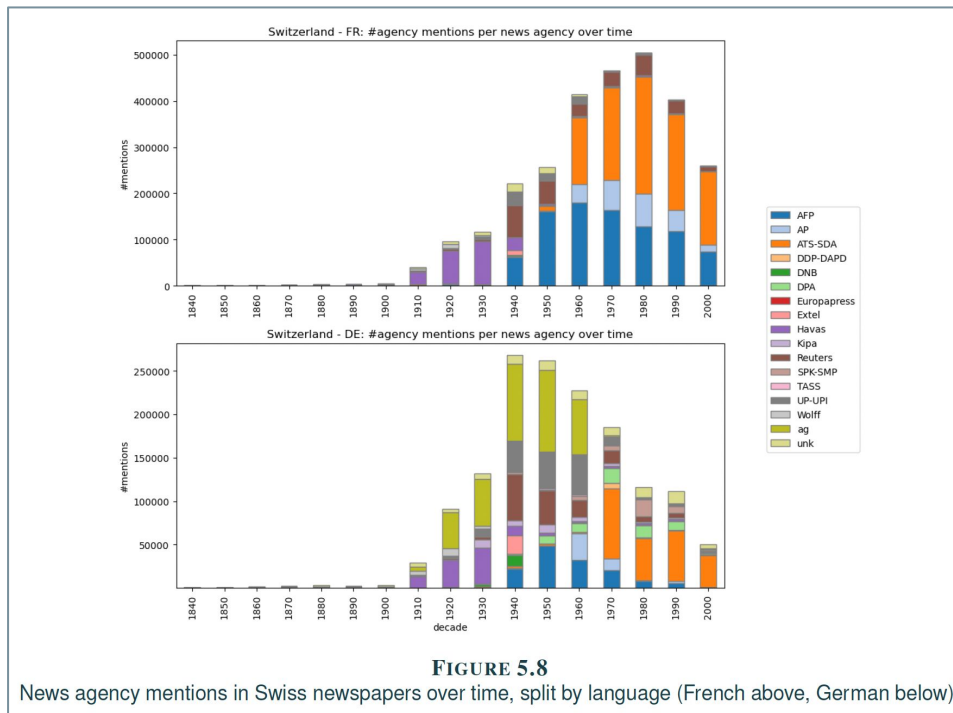
The screenshot displays the 'impresso' Media Monitoring search interface. The search query is '"conference"' and the selected news agencies are 'Reuters AND AFP'. The search results show 16,641 articles found. The interface includes various filters on the left side, such as 'FILTER BY LANGUAGE OF ARTICLES', 'FILTER BY NEWSPAPER TITLES', 'FILTER BY ARTICLE TYPE', 'FILTER BY COUNTRY OF PUBLICATION', 'FILTER BY ACCESS RIGHT', 'FILTER BY ARCHIVE', 'FILTER BY PERSON', 'FILTER BY LOCATION', 'FILTER BY TOPIC', and 'FILTER BY NEWS AGENCY'. The 'FILTER BY NEWS AGENCY' filter is expanded, showing a list of news agencies with checkboxes and result counts: 'WRITTEN BY' (dropdown), 'Reuters(16,641 results)', 'AFP(16,641 results)', 'ATS SDA (3,361 results)', 'UP UPI (1,430 results)', and 'AP (785 results)'. The search results on the right show a list of articles, including 'Die Tat' (Wednesday, May 1, 1968) and 'Erdbeben registriert Pasadena (Kaliforni...)' (Wednesday, June 16, 1954). The 'conference' keyword is highlighted in yellow in the search results.



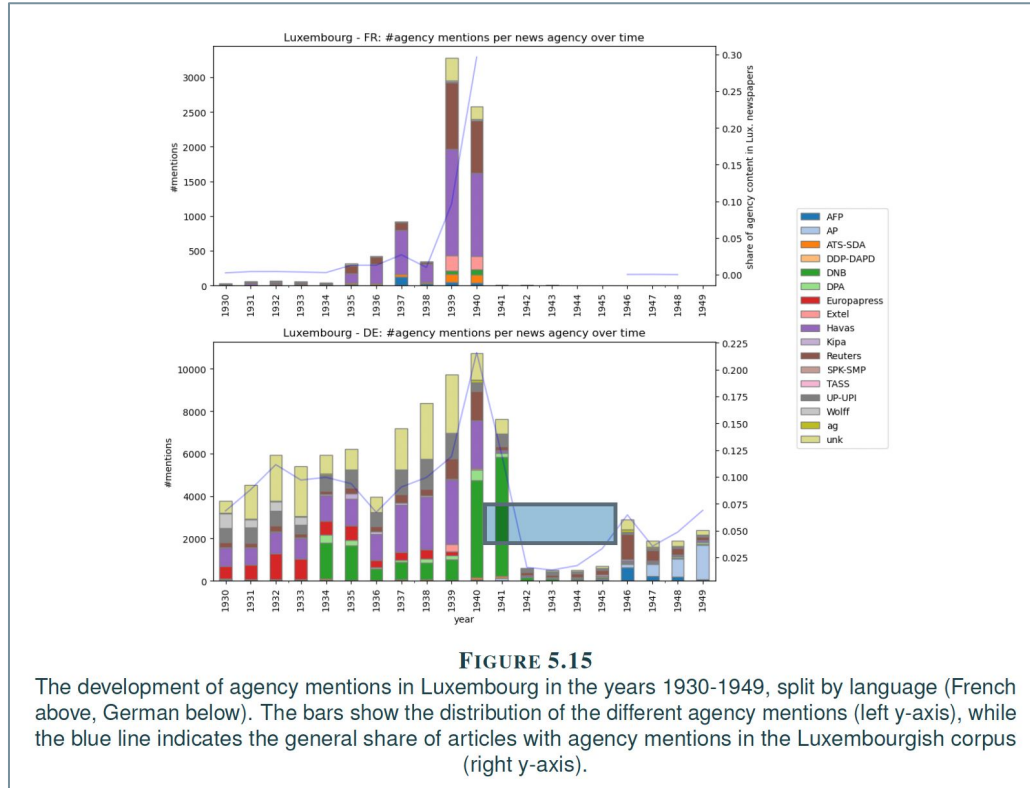
# News agency mentions



# In Swiss newspapers



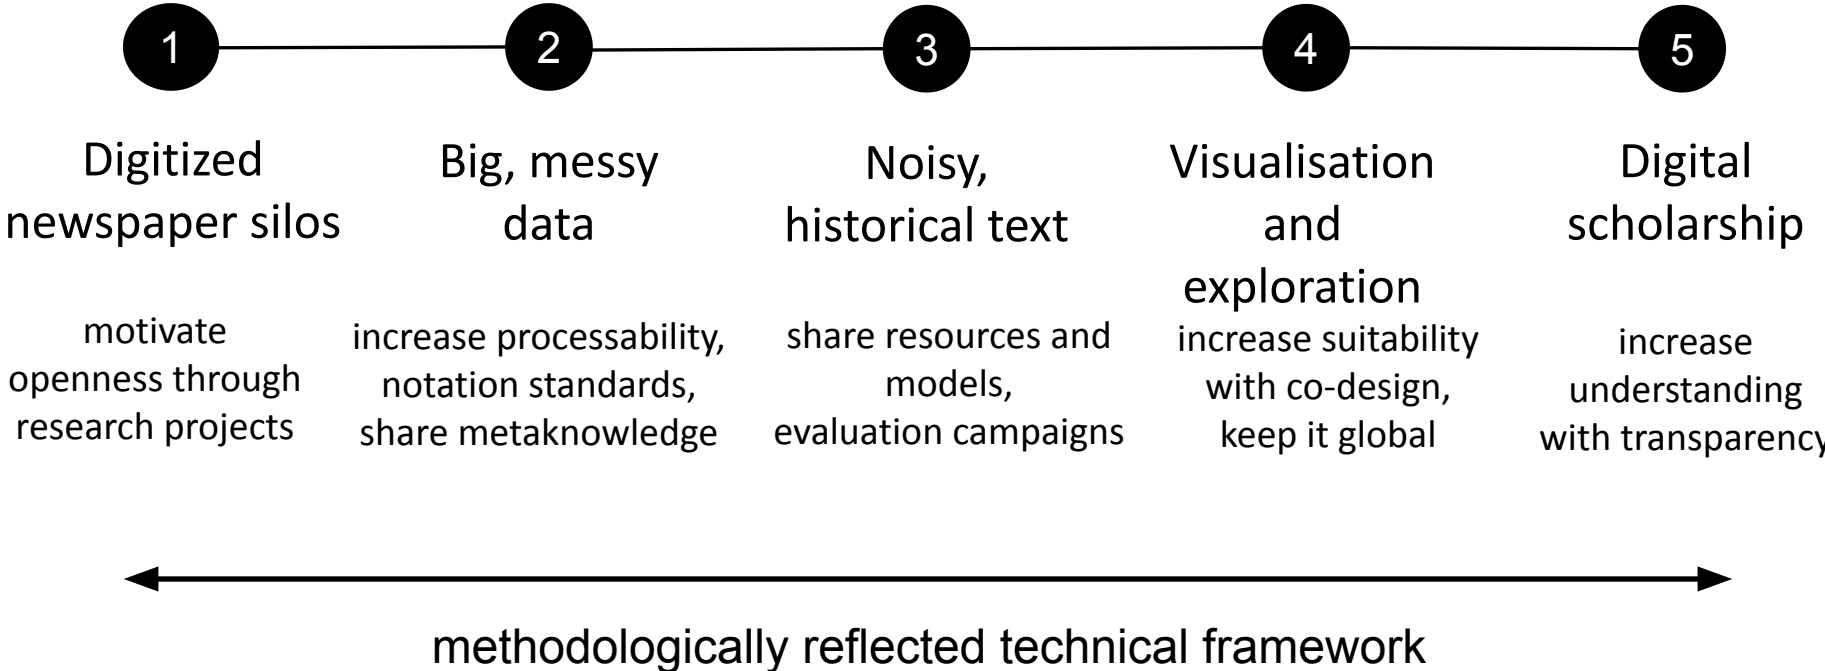
# In Luxembourgish newspapers (1940-1944)



**FIGURE 5.15**

The development of agency mentions in Luxembourg in the years 1930-1949, split by language (French above, German below). The bars show the distribution of the different agency mentions (left y-axis), while the blue line indicates the general share of articles with agency mentions in the Luxembourgish corpus (right y-axis).

# Reliable Semantic Indexing of Historical Newspapers at Scale: Are We There Yet?



# What's next ? (from the community)

What are the main challenges we need to address in relation with historical newspapers?

- Document processing
- Text and image processing
- **Evaluation** (digitisation and content mining)
- Exploration of enriched, **global** collections
- **Working with data**
- **Workflows**
- **Criticism, inclusivity**
- Legal matters



Report from Dagstuhl Seminar 22292

## Computational Approaches to Digitised Historical Newspapers

Edited by

Maud Ehrmann<sup>1</sup>, Marten Düring<sup>2</sup>, Clemens Neudecker<sup>3</sup>, and Antoine Doucet<sup>4</sup>

<sup>1</sup> EPFL - Lausanne, CH, [maud.ehrmann@epfl.ch](mailto:maud.ehrmann@epfl.ch)

<sup>2</sup> University of Luxembourg, LU, [marten.during@uni.lu](mailto:marten.during@uni.lu)

<sup>3</sup> Staatsbibliothek zu Berlin, DE, [clemens.neudecker@bb.spk-berlin.de](mailto:clemens.neudecker@bb.spk-berlin.de)

<sup>4</sup> University of La Rochelle, FR, [antoine.doucet@univ-lr.fr](mailto:antoine.doucet@univ-lr.fr)

### Abstract

Historical newspapers are mirrors of past societies, keeping track of the small and great history and reflecting the political, moral, and economic environments in which they were produced. Highly valued as primary sources by historians and humanities scholars, newspaper archives have been massively digitised in libraries, resulting in large collections of machine-readable documents and, over the past half-decade, in numerous academic research initiatives on their automatic processing. The Dagstuhl Seminar 22292 "Computational Approaches to Digitised Historical Newspaper" gathered researchers and practitioners with backgrounds in natural language processing, computer vision, digital history and digital library involved in computational approaches to historical newspapers with the objectives to share experiences, analyse successes and shortcomings, deepen our understanding of the interplay between computational aspects and digital scholarship, and discuss future challenges. This report documents the program and the outcomes of the seminar.

# What's next ? (from impresso)



Media  
Monitoring  
of the Past

Beyond Borders: Connecting Historical Newspapers and Radio

## Main objectives

- Enrichment and integration of **newspaper and radio sources in a single semantic space;**
- Expand the corpus to Western Europe;
- Develop interfaces for exploratory and computational research;
- Conduct case studies in (media) history, theme "influences."



09/2023 - 02/2027



## 1 Source collection

### European media archives

AUSTRIA  
BELGIUM  
FRANCE  
GERMANY  
LUXEMBOURG  
THE NETHERLANDS  
SWITZERLAND  
UK





## 2 Media processing

### Enriching & connecting

SEMANTIC ENRICHMENT  
ACROSS LANGUAGES  
ACROSS MEDIA

dense vector  
representations




interview  
advertisement  
radio schedule

EXTERNAL  
KNOWLEDGE

## 3 Media exploration


### Connected and comparable enriched media sources

PROJECT DATA



API

IMPRESSO WEB APP



CO-DESIGNED INTERFACES


historians  
designers  
engineers

process data  
using impresso API

USER-ORIENTED API

COMPATIBLE DATA

IMPRESSO DATA LAB



CO-DEVELOPED METHODS

EXTERNAL  
DOCUMENTS



compatible  
enrichments

community  
of historians



# For more information

The screenshot shows the impresso website with a navigation menu on the left containing links for HOME, PROJECT, APP, BLOG, PUBLICATIONS, OVERVIEW, and CONSORTIUM. The main content area features the title "Media Monitoring of the Past" and a subtitle "Mining 200 years of historical newspapers". Below this, there is a section titled "How can newspapers help understand the past? How to explore them?" followed by a paragraph describing the project's objective: "The objective of the project 'Media monitoring of the past. Mining 200 years of historical newspapers' is to enable critical text mining of newspaper archives with the implementation of a technological framework to extract, process, link, and explore data from print media archives. Supported by an international consortium composed of computational linguists, digital humanists, designers, historians, librarians and archivists, impresso (i.e. 'what has been printed') will tackle the challenges of content enrichment and data representation, visualization and analysis, completed by methodological and epistemological reflections. Expected outcomes include, among others, a set of natural language processing (NLP) tools dedicated to historical print media, visualization interfaces for active exploration and critical analysis of newspaper corpora in a transparent manner, as well as a digital history research project on resistance to European unification in the late 19th and early 20th centuries." The page also includes a "Time frame: September 2017 - August 2020" and "Funding: Swiss National Science Foundation" section, and a "JOIN OUR MAILING LIST" button.

impresso website (update soon)

The screenshot shows the Zenodo website interface. The header includes the Zenodo logo, a search bar, and navigation links for Upload, Comments, and a user profile. The main content area is titled "Impresso - Media Monitoring of the Past" and lists "Recent uploads". The first upload is "Extended Overview of CLEF HPE 2020: Named Entity Processing on Historical Newspapers" by @Elmerran, @Bormann, @Fackler, and @Dierckx, published on October 23, 2020. The second upload is "CLEF HPE 2020 Named Entity Recognition and Linking on Historical Newspapers (slides)" by the same authors, also published on October 23, 2020. The third upload is "Deep diving in NLP enhanced digitised newspapers. A hands-on session with the impresso interface" by @elmer, published on June 4, 2020. The fourth upload is "Introducing the CLEF 2020 HPE Shared Task: Named Entity Recognition and Linking on Historical Newspapers" by the same authors, published on October 23, 2020. A "New upload" button is visible in the top right corner.

data on Zenodo

The screenshot shows the GitHub repository page for "impresso-project". The repository is titled "Media Monitoring of the Past" and contains 300 files. The main content area displays a list of files, including "fakenews-quiz", "impresso-language-identification", "epfl-sha-class", "federal-gazette", "impresso-data-sanitycheck", "impresso-test-acquisition", "CLEF-HPE-2020-internal", "impresso-technical-cookbook", and "impresso-gycommons". Each file entry includes a commit hash, a date, and a "Updated" timestamp. The right sidebar shows "Top languages" (Python, JavaScript, HTML), "Most used topics" (historical-newspapers, digital-humanities, named-entity-linking, named-entity-recognition), and a "People" section with avatars of contributors.

code on GitHub

The screenshot shows the YouTube channel page for "Impresso Project". The channel has 5 subscribers and a "SUBSCRIBE" button. The main content area features a video titled "Media Monitoring of the Past" with a description: "This video introduces the Impresso - Media Monitoring of the Past project. How can newspapers help understand the past? How to explore them? The objective of the impresso project is to enable critical text mining." Below the video, there are sections for "Created playlists" (CLEF HPE 2020, DH2020-conference, Future2 impresso) and "Uploads" (CLEF HPE 2020 - Sinker Team, CLEF HPE 2020 - NLP-UoAM Team, CLEF HPE 2020 - ERTM Team).

impresso youtube channel

The screenshot shows the impresso-project.ch/app website. The header includes navigation links for Search, Newspapers, Topics, Inspect & Compare, and Text reuse. The main content area features a large title "Media Monitoring of the Past" and a summary of the project's data: "78 newspapers collected, 600,919 issues, 5,429,856 pages scanned, 479,448 content items identified, 3,459,709 tokens, 19,493,358,793 words, 2 countries of publication, 230,086 named entities disambiguated". Below this, there is a "More? Check on our blog" section and a "Mining 200 years of historical newspapers" section. The bottom of the page includes a "Dark Mode On" toggle and a "Download Non-Disclosure Agreement Form" button.

impresso-project.ch/app