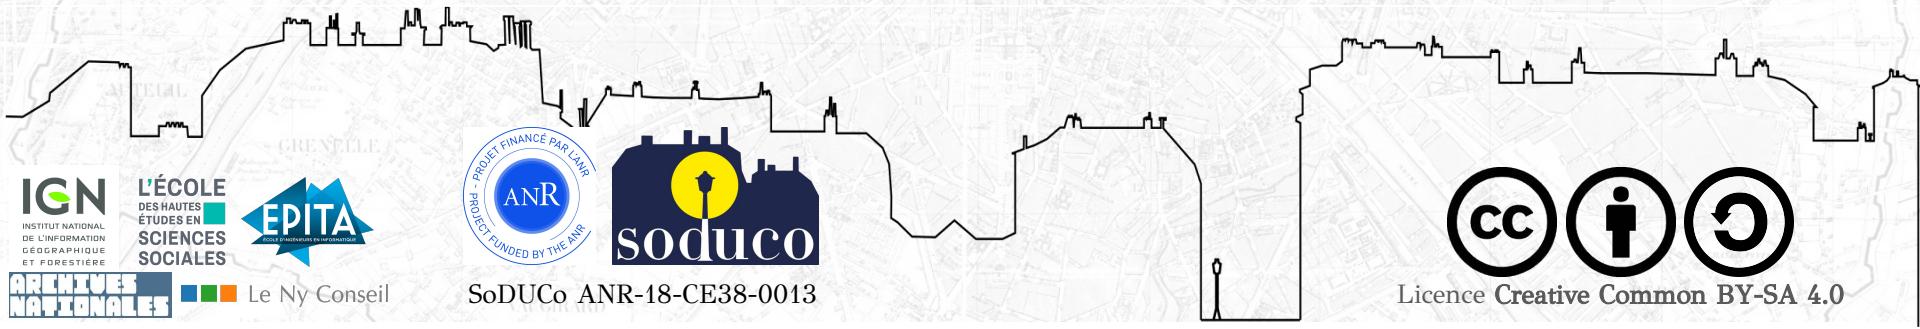


# RES(T)ITUER LES ANNUAIRES COMMERCIAUX ET LES ÉVOLUTIONS DE L'ESPACE PARISIEN DU XIX<sup>E</sup> SIÈCLE

## LE PROGRAMME DE RECHERCHE SoDUCo. PANORAMA

**SoDUCo Team :** N. Abadie, C. Bernard, M. Hersent, J. Perret, J. Rimbault, S. Tual (LASTIG, Univ Gustave Eiffel, ENSG/IGN), E. Carlinet, J. Chazalon (LRE, EPITA), S. Baciocchi, M. Barthelemy, P. Cristofoli, B. Duménieu, J. Gravier, M. Fernandez (CRH et CAMS, EHESS), V. Weiss (CTH, Archives Nationales) et P.A Le Ny (LeNy Conseil).

4<sup>e</sup> séance de l'Atelier SoDUCo-BnF - 6-7 novembre 2023 - Bibliothèque nationale de France, Site François Mitterrand, Paris



# Projet ANR SoDUCo

(Social Dynamics in Urban Context)

*Open tools, models, and data - Paris and its suburbs, 1789-1950*

<https://soduco.geohistoricaldata.org/>

<https://anr.fr/Projet-ANR-18-CE38-0013>

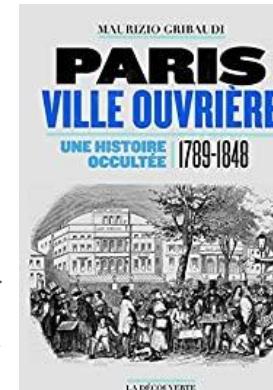
2019-2023



# SOCIAL DYNAMICS IN URBAN CONTEXT (SoDUCo)

- développement de **méthodes** et de **modèles** pour l'étude de l'évolution de la structure spatiale urbaine en relation avec les activités professionnelles de la population
- reconstitution de l'évolution de la ville de Paris à l'aide de deux jeux de sources spécifiques :
  - les **cartes et plans de la ville** et
  - les **annuaires commerciaux**
- produire des **outils libres** permettant d'exploiter ces sources et **diffuser de manière ouverte** les données extraites
- se fonde sur plusieurs années de travaux initiés par **M. Gribaudi** (EHESS) et des collaborations préalablement établies entre les différents partenaires (groupe *Geohistoricaldata*, projet *Belle époque*, ...), sur la vectorisation de la *Carte de Cassini* ou l'étude de l'espace Parisien au XIX<sup>e</sup>

M. Barthelemy & al., “Self-organization versus top-down planning in the evolution of a city”. Sci Rep 3, 2153 (2013). M. Gribaudi, *Paris, ville ouvrière. Une histoire occultée (1789-1848)*, Paris, La Découverte, 2014, 445 p. – J. Perret & al., 2015, « Roads and cities of 18th century France », Scientific Data, 15 septembre 2015, vol. 2, p. 150048. Baciocchi & al., *Engraved Footprints from the Past. Retrieving cartographic geohistorical data from the Cassini Carte de France, 1750-1789*, 2019, International Cartographic Conference 2019, Jul 2019, Tokyo, Japan. R. Cura, B. Dumenieu & al., “Historical collaborative geocoding. ISPRS International Journal of Geo-Information”, MDPI, 2018, 7 (7), pp.262.



# L'ATELIER BNF-SoDUCo 2022-2023

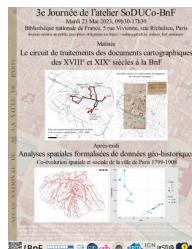
- diffuser et **mettre en question** le travail réalisé dans le cadre de SoDUCo
- faire **dialoguer** chercheurs et spécialistes de la conservation des documents sur des objets et projets communs allant de l'exploitation des fonds à la production et diffusion de données ouvertes

Membres de l'équipe ayant participé à l'organisation des séances de l'Atelier: A. Aniesa, M. Carlin, L.-A. Charles, P. Chevallier, J. Garel-Grislin, C. Ion, O. Loiseaux, J.-D. Mellot, J.-P. Moreux, E. Netchine (BnF), N. Abadie, C. Bernard, M. Hersent, J. Perret, J. Raimbault, S. Tual (IGN-LASTIG), E. Carlinet, J. Chazalon (EPITA), **S. Baciocchi**, M. Barthelemy, P. Cristofoli, B. Duménieu, J. Gravier, M. Fernandez (EHESS, CRH et CAMS), V. Rebolledo-Dhuin (UPEC) et P.A Le Ny (LeNy Conseil).



## THÉMATIQUES ABORDÉES LORS DES QUATRE SÉANCES DE L'ATELIERS :

1. *Paris, capitale géodésique. Atlas et plans à grande échelle: 1780 – 1950* (10/04/22) : **Le plan de Verniquet et l'exploitation automatisée des plans anciens.**
2. *Re(s)tituer les adresses des almanachs et annuaires commerciaux* (10/11/22) : **La chaîne de traitement et la description du contenu des annuaires.**
3. *Le circuit de traitements des documents cartographiques des XVIIIe et XIXe siècles à la BnF* (23/05/2023, matinée) et *Analyses spatiales formalisées et écologie urbaine* (23/05/2023, après-midi)
4. *Res(t)ituer les annuaires commerciaux et les évolutions de l'espace Parisien du XIXe siècle. Partager l'expérience et les ressources du programme ANR SoDUCo* (6 et 7 Novembre 2023) : Science ouverte - Métadonnées, catalogage & diffusion de données - Extraction & structuration de données - Données historiques numériques – Evaluation

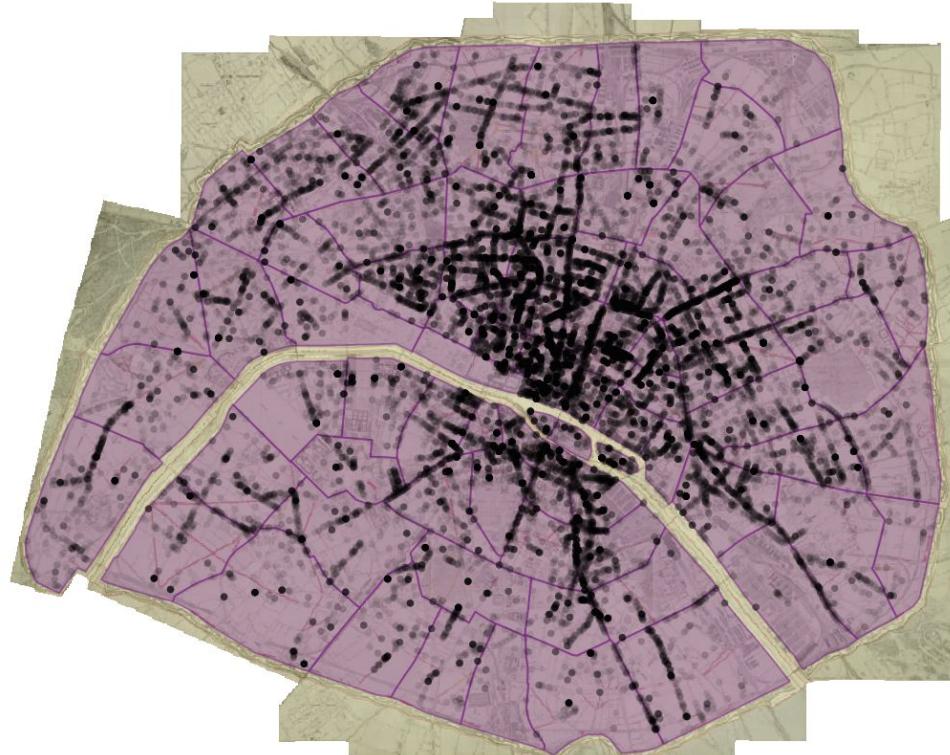


# Un cadre global

# Réutilisation d'un jeu de données

- sources primaires utilisés?
- traitements utilisés ?
- hypothèses effectuées ?
- Comment
  - reproduire les traitements ?
  - répliquer les traitements ?
  - modifier une étape ?

(hypothèse différente)



# Le cadre global du projet SoDUCo

- **Science ouverte**
  - Traçabilité et reproductibilité des traitements et données jusqu'aux sources primaires
  - Explication des hypothèses implicites
  - Réflexion sur les formats de diffusion des données et métadonnées
  - Tout est ouvert (ou le sera bientôt)
- **Interrogation critique** (réflexive) des sources, des traitements et des données
  - Évaluation de la qualité des données produites à chaque étape
  - Évaluation de la qualité des sources
  - Question du niveau / de la granularité d'analyse (“en détail et en quantité”)
  - Utilisation des données brutes au niveau de détail de la source où elles sont extraites
- **Cumulativité**
  - Pérennisation des données
  - Pérennisation des outils
  - Pérennisation du collectif de travail
  - Pérennisation pour les institutions patrimoniales

# 3 questions



- Quelles sources utiliser ?
- Comment extraire des informations dans les sources ?
- Comment utiliser, interpréter et analyser les données issues des sources ?

# Quelles sources utiliser ?

## Des possibilités

# Gallica-BnF

# Archives Nationales

# Retro-news

## Bibliothèques spécialisées (BHdV, BHVP, etc.)

# Bibliothèque de Stanford

# Quelques questions

- élaborer à partir de sources éparses des **corpus de documents** adaptés aux **questions de recherche** ?
- conserver la **trace des divers traitements** qui leur sont appliqués ainsi que les **états intermédiaires et finaux** des données numériques qui en sont extraites ?
- créer les conditions d'une **cumulativité** à la fois du point de vue de la **recherche** et du point de vue des **institutions patrimoniales** ?



{BnF  
Gallica

ARCHIVES  
NATIONALES

David Rumsey Map Collection  
CARTOGRAPHY ASSOCIATES POWERED BY LUNA IMAGING



# SESSION MÉTADONNÉES, CATALOGAGE & DIFFUSION DE DONNÉES

Lundi 6 novembre 2023 (9h30-12h15) en salle 70

10h00. **SoDUCo team**, Catalogage et diffusion des données dans le programme.

10h30. **Questions**

10h45. **J. Schoonman, B. Spaan et M. Claeys Bouuaert (Allmaps)**, Présentation du consortium Allmaps

11h05. **N. Vigneron (Wikimedia France)**, Science participative, science ouverte. L'expérience de Wikimedia France

11h25. **A. Joffres (Huma-num)**, Données, outils et communautés pour recherche en SHS

11h45. **Questions**

12h00. **Discussion – Table ronde**

**Comment extraire des informations dans les sources ?**

# Extraction des bâtiments et des îlots dans les cartes historiques

Thèse de Yizi Chen (2020-2023)

Modern vectorization and alignment of historical maps: An application to Paris Atlas (1789-1950):

<https://hal.science/tel-04106107v1>

## Vectorisation de cartes historiques

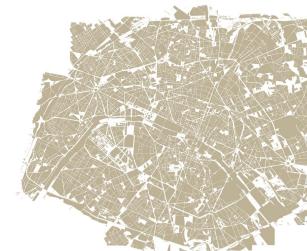
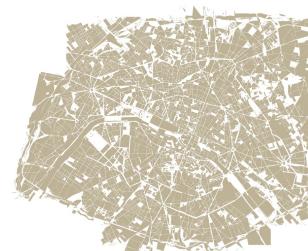
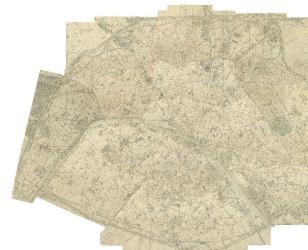
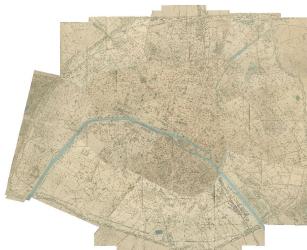
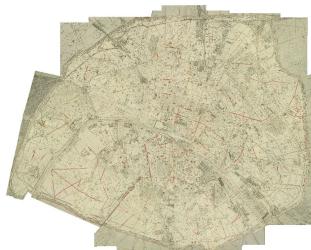
Atlas municipal des vingt arrondissements de Paris. 1925. Bibliothèque de l'Hôtel de Ville. Ville de Paris.

<http://bibliotheques-specialisees.paris.fr/ark:/73873/pf0000935524>



**Haut :** Extrait de l'*Atlas municipal des vingt arrondissements de Paris. 1925. Bibliothèque de l'Hôtel de Ville. Ville de Paris* ;  
**bas :** bâtiments et îlots morphologiques extraits.

# Une application pour la construction d'îlotiers (en cours)



1878

1886

1900

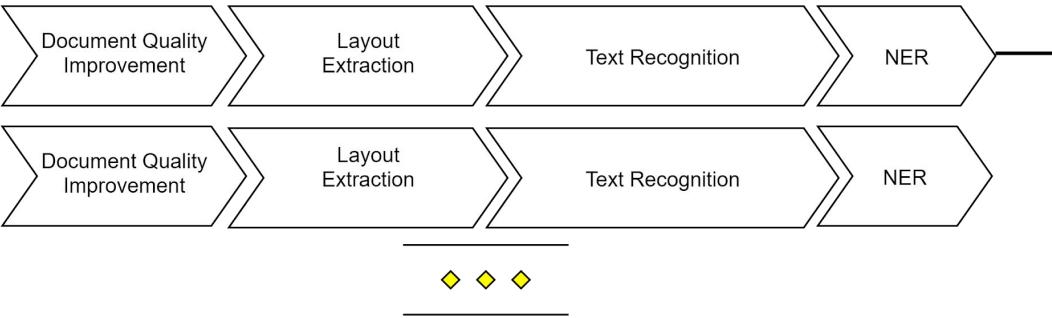
1925

1937

Atlas municipal des vingt arrondissements de Paris. Bibliothèque de l'Hôtel de Ville. Ville de Paris.

# Chaîne de traitement des annuaires

Vue PDF 701



Vue PDF 702

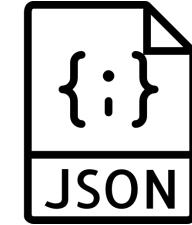


Vue PDF 1056

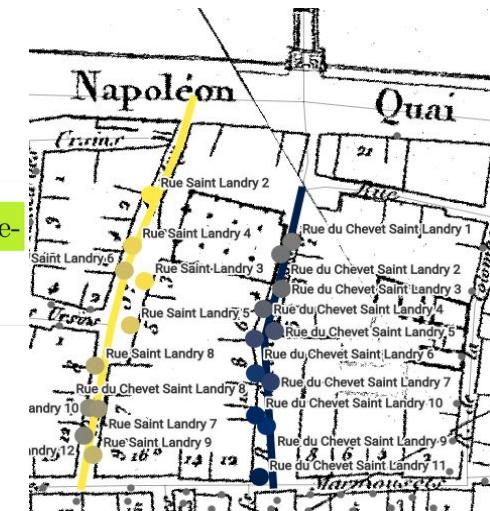


**PERSON**  
Dartigny (Mme), professeur de pianos, Seine-  
St-Germain, 79.  
**ACTIVITY**  
**LOCATION** CARDINAL

un JSON par vue



V2 data (2022-06): ~10 M d'entrées



# SESSION EXTRACTION & STRUCTURATION DE DONNÉES

Lundi 6 novembre 2023 (15h00-17h30) en salle 70

15h00. **SoDUCo team**, Extraction et structuration de données dans le programme SoDUCo

15h30. **C. Duvette et P. Kervegan** (DER - INHA) : Chapeliers, architectes, nouveautés : géo-analyse des activités visibles et invisibles d'un quartier

15h50. **Questions.**

16h20. **W. Charles** (IRIT, Université de Toulouse Jean Jaurès) et **S. Poublanc** (Framespa, Université de Toulouse Jean Jaurès) : Représenter les territoires de la France moderne dans des graphes de connaissances : le projet OBARDI

16h40. **C. Kermorvant** (TEKLIA) : Nouvelles approches pour l'extraction d'informations dans des documents numérisés

17h00. **Questions.**

## LES ATELIERS-FORMATION SODUCO – BNF DATALAB

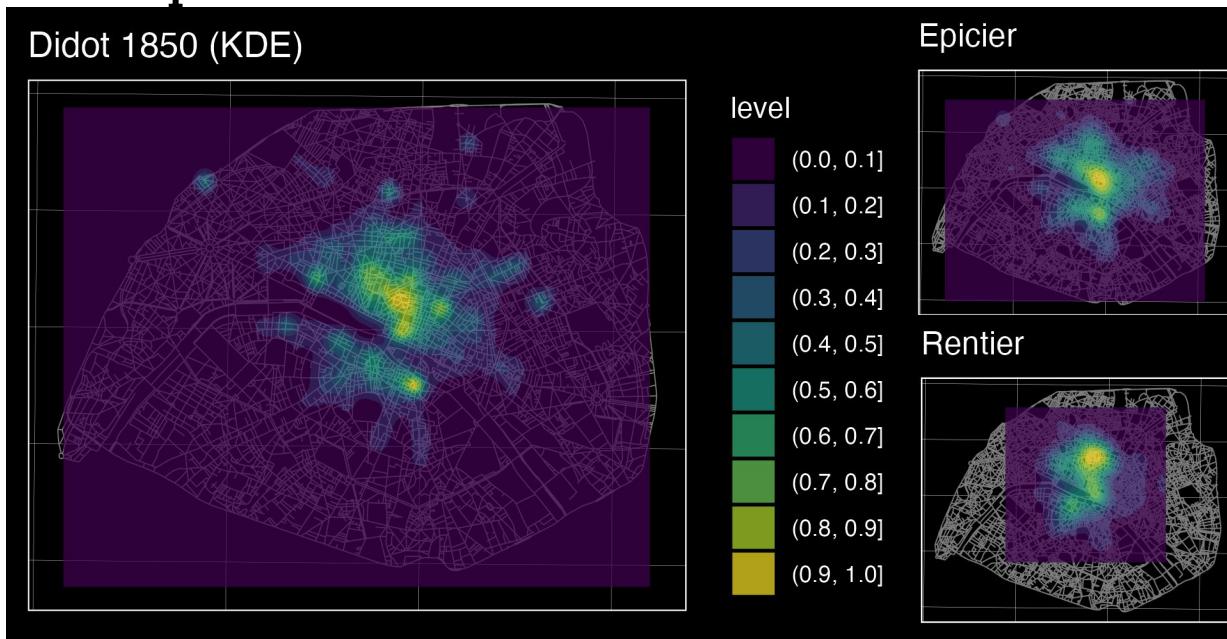
Mardi 7 novembre 2023 (13h30-17h30). Au datalab

13h30. **Atelier n°2** – Utiliser la chaîne SoDUCo d'extraction et d'enrichissement de documents textuels numériques.

13h30. **Atelier n°3** – Graphes de Connaissance Géohistoriques Professionnels.

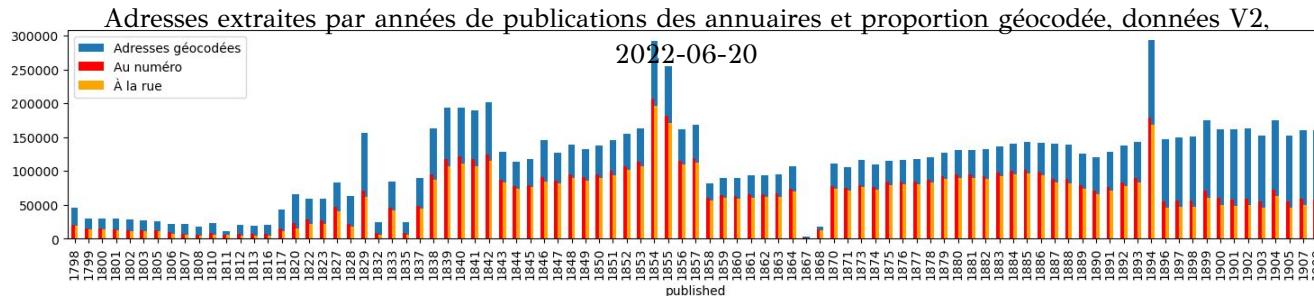
**Comment utiliser, interpréter et analyser les données issues des sources ?**

# Des données géohistoriques



données V2, 2022-06-20 et données V2 revues

<https://doi.org/10.5281/zenodo.8388102>



14h00. Keynote - **M. Barthelemy** (CEA) et **J. Gravier** (EHESS) : « Lois d'échelle » et dynamiques des activités urbaines dans une ville en croissance.

## **SESSION DONNÉES HISTORIQUES NUMÉRIQUES ÉVALUATIONS CRITIQUES ET PERSPECTIVES D'UTILISATIONS**

**Mardi 7 novembre 2023 (09h30-12h00) en salle 70**

09h30. **SoDUCo team**, Les données géohistoriques produites au cours du programme SoDUCo. Evaluation d'une « source numérique ».

10h00. **L. Kesztenbaum** (INED) et **G. Postel-Vinay** (PSE), Construction de bases de données historiques: retours d'expérience.

**10h30. Questions**

11h00. **C. Lemercier** (CNRS, Sciences Po-Paris CSO), Histoire quantitative, données ouvertes en SHS.

**11h30. Questions et discussion finale**

## **LES ATELIERS-FORMATION SODUCO – BNF DATALAB**

**Mardi 7 novembre 2023 (13h30-17h30). Au datalab**

13h30. **Atelier n°1** – Exploration des données et cartographie grand public

13h30. **Atelier n°2** – Utiliser la chaîne SoDUCo d'extraction et d'enrichissement de documents textuels numériques.

13h30. **Atelier n°3** – Graphes de Connaissance Géohistoriques Professionnels.

**16h45. Bilan collectif et discussion des ateliers (Mezzanine du DataLab)**

Et après ?

# Des suites

- **Mezanno** – plan quadriennal BnF
  - EPITA-LRE, EHESS-CRH, IGN-ENSG-LASTIG
- **Decidon** : projet soumis à l'ANR par EPITA-LRE (Marie Puren)
  - EPITA-LRE, INRIA-Almanach, EHESS-CRH, ENC-Jean-Mabillon, LARAH, BnF-DEP
- Thèses
  - **Solenn Tual** (2022-) - *Reconstitution automatique de la généalogie des parcelles et des bâtiments à partir de sources historiques.* (IGN-ENSG-LASTIG / EPITA-LRE / EHESS-CRH)
  - **Charly Bernard** (2022-) - *De sources multiples fortement hétérogènes à un référentiel d'adresses ouvert.* (IGN-ENSG-LASTIG / EHESS-CRH)

# Ce séminaire est aussi

- L'occasion de faire un **retour critique** sur le projet
  - C'est vous qui allez nous aider à faire le bilan critique du projet
- De confronter nos **expériences** respectives
- De réfléchir à comment **faire mieux** par la suite
- Proposer un **cadre de discussion** formel et **informel**

# Jeux de données, les outils, les articles et les plateformes

Jeux de données :

[Collection SoDUCo sur NAKALA](#)

[Annuaires historiques parisiens, 1798-1914, V2-juin 2022](#)

[A Dataset of French Trade Directories from the 19th Century \(FTD\)](#)

[A Dataset of French Trade Directories from the 19th Century for Nested NER task](#)

[NER models from "A Benchmark of Named Entity Recognition Approaches in Historical\[...\]"](#)

[Quartiers de Paris \(1860-1919\)](#)

[Populations des quartiers de Paris \(1801-1911\)](#)

[Dépôts des plans géoréférencés](#)

[ICDAR 2021 Competition on Historical Map Segmentation — Dataset](#)

Codes :

[Détection de segments](#)

[All the material \(paper, code, dataset, results\) of our DAS 2022 paper \(OCR+NER benchmark\)](#)

[All the material \(code, dataset, results\) of our Benchmark of Nested NER approaches](#)

[Démonstrateurs sur le cas des photographes parisiens](#)

[Démonstrateur v2 comprenant plusieurs datasets mis en place lors de l'atelier de liage](#)

[Segmentation et vectorisation de cartes](#)

[Des annuaires en annotations IIIF - Des cartes géoréférencées en annotations IIIF](#)

Plateformes ou sites :

[Social Dynamics in Urban Context](#)

[Catalogue - Sparql Endpoint du catalogue](#)

[Application de visualisation \(en cours\)](#)

[Viewer IIIF des annuaires traités](#)

[API REST annuaires](#)

[Datahub annuaires & atlas Ontop SPARQL endpoint for directories and professions](#)

Articles, poster & thèse:

[A Benchmark of Nested Named Entity Recognition Approaches in Historical Structured Documents](#)

[A Benchmark of Named Entity Recognition Approaches in Historical Documents Application to 19th Century French Directories](#)

[\[Poster\] A Benchmark of Nested Named Entity Recognition Approaches in Historical Structured Documents - Archive ouverte HAL](#)

[Entry Separation using a Mixed Visual and Textual Language Model: Application to 19th century French Trade Directories](#)

[Création d'un graphe de connaissances géohistorique à partir d'annuaires du commerce parisien du 19ème siècle: application aux métiers de la photographie](#)

[Vectorization of historical maps using deep edge filtering and closed shape extraction - Archive ouverte HAL](#)

[Combining Deep Learning and Mathematical Morphology for Historical Map Segmentation - Archive ouverte HAL](#)

[ICDAR 2021 Competition on Historical Map Segmentation - Archive ouverte HAL](#)

[Modern vectorization and alignment of historical maps: An application to Paris Atlas \(1789-1950\)](#)

[A hidden Markov model for matching spatial networks](#)

[Modèles et outils pour la publication de métadonnées d'archives géographiques et de leurs données dérivées](#)

[Regard de... La géographie théorique et quantitative pour étudier les usages du concept de quartier en archéologie](#)

[Evolution of the urban structure of Paris during the 19th century. Building a temporal typology of urban activity categories](#)

[Exploitation des données Soduco : premiers éléments de l'évolution des activités parisiennes au fil du siècle](#)

# **RES(T)ITUER LES ANNUAIRES COMMERCIAUX ET LES ÉVOLUTIONS DE L'ESPACE PARISIEN DU XIX<sup>E</sup> SIÈCLE**

**Lundi 6 novembre 2023 (9h30-17h30) en salle 70 – Buffet repas au Belvédère (12h15-13h30)**

09h30. M. Carlin (BnF DataLab) : *Ouverture de la journée & SoDUCo team, Le programme de recherche SoDUCo. Bilan*

10h00. SESSION « MÉTADONNÉES, CATALOGAGE & DIFFUSION DE DONNÉES » avec J. Schoonman, B. Spaan et M. Claeys Bouuaert (Allmaps), N. Vigneron (Wikimedia France) et A. Joffres (Huma-num)

14h00. KEYNOTE - M. Barthelemy (CEA) et J. Gravier (EHESS) : « Lois d'échelle » et dynamiques des activités urbaines dans une ville en croissance.

15h00. SESSION « EXTRACTION & STRUCTURATION DE DONNÉES » avec C. Duvette, P. Kervegan (INHA), W. Charles, S. Poublanc (Univ. Toulouse J. Jaurès) et C. Kermorvant (TEKLIA)

**Mardi 7 novembre 2023 (9h30-12h00) en salle 70 – Buffet repas au Belvédère (12h15-13h15)**

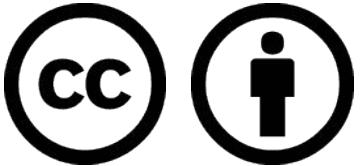
9h30. SESSION « DONNÉES HISTORIQUES NUMÉRIQUES. ÉVALUATIONS CRITIQUES ET PERSPECTIVES D'UTILISATIONS » avec L. Kesztenbaum (INED), G. Postel-Vinay (PSE), C. Lemercier (CNRS).

**Mardi 7 novembre 2023 (13h30-17h30) au BnF DataLab**

13h30. ATELIERS-FORMATIONS SoDUCo – BNF DATA LAB (sur inscription, places limitées)

# (Ré)utiliser cette présentation

Licence Creative Common BY 4.0



N'hésitez pas à **réutiliser** ces contenus et nous **citer**.

*Sauf citation ou mention contraire,  
nous sommes les auteurs des contenus.*

Consultez le diaporama pendant et après la présentation

<https://link.infini.fr/soduco>

Les autres présentations de l'atelier :

<https://link.infini.fr/soduco-catalog>

<https://link.infini.fr/soduco-lois-dechelle>

<https://link.infini.fr/soduco-extraction>

<https://link.infini.fr/soduco-geohistorique>

