



Création d'un graphe de connaissances géohistorique à partir des annuaires du commerce parisien du 19ème siècle: application aux métiers de la photographie

Solenn Tual ⁽¹⁾, Nathalie Abadie ⁽¹⁾, Bertrand Duménieu ⁽²⁾, Joseph Chazalon ⁽³⁾, Edwin Carlinet ⁽³⁾

SemWebPro, Paris, 15 novembre 2023

Licence : CC BY 4.0



(1)




(2)



(3)

Annuaire du commerce de Paris


- Édités à partir de la fin du XVIIIème siècle jusqu'au milieu du XXème siècle par différents éditeurs.
- Organisés en différentes listes (alphabétique, par profession, par adresse).
- Chaque entrée contient :
 - Nom/Raison sociale
 - Activité/Profession/Statut
 - Adresse(s)
 - Distinctions militaires/professionnelles



Cherot, <i>joaillier</i> . S. Martin, 51.	Chevalier, <i>opt. du Roi</i> , Tour de l'Horl. du Palais, 1.
Chéroux, <i>orf.</i> Ste Avoye, 42.	Chevalier (L.), <i>opt. q.</i> Horl. Pal. 65.
Cherre, <i>layet</i> . Caire, 7.	Chevalier (Vinc.), <i>opt. q.</i> Horl. Pal. 69.
Cherré, <i>tap.</i> Moulins, 12.	Chevalier (Victor), <i>opt. q.</i> Horl. Pal. 77 b.
Cherrier, <i>tabl.</i> St Denis, 277.	

Liste ordonnée par nom - Annuaire Cambon Almgène de 1839.

Source : Gallica BNF



Annuaire du commerce de Paris

- Redondance importante des entrées d'une année ou d'une édition à une autre
- Snapshots temporels

même personne

succession

déménagement

Bibliothèque Ste-Geneviève, Clotilde, 1.
Bibliothèque de la Ville, quai d'Austerlitz, 33 (provisoirement).
Bibl'que protestante (Société), Moulins, 16.
 Bibron, aide-natural., au Muséum d'hist. nat.
 Bibus, tailleur, Roule, 21.
 Bibus, tailleur, Richelieu, 31.
 Bical et Dorre, fab. de socques, Vertbois, 14.
 Bican (Mme), fondeur en cuivre, cour de la Corderie-du-Temple, 26.
 Bichard (Mme), Nve-de-Luxembourg, 17.
 Bichard, tabacs et eau-de-vie, Faub.-St-Martin, 45.

Didot 1841a - page 95

Bibliothèque Ste-Geneviève, Clotilde, 1.
Bibliothèque de la Ville, quai d'Austerlitz, 33 (provisoirement).
Biblique protestante (Société), Moulins, 16.
 Bibron, aide-natural., au Muséum d'hist. nat.
 Bibus, tailleur, Roule, 21.
 Bibus, tailleur, Richelieu, 31.
 Bical, fab. de jouets, Montmorency, 33.
 Bical et Dorre, fab. de socques, Vertbois, 14.
 Bican (Vve) et fils, fondeur en cuivre, place de la Corderie-du-Temple, 26.
 Bichel, épicier, marché d'Aguesseau, 15.
 Bichard (Mme), Nve-de-Luxembourg, 17.
 Bichard, tabacs et eau-de-vie, Faub.-St-Martin, 45.

Didot 1842a - page 117

Bibliothèque Ste-Geneviève, rue des Sept-Voies et place du Panthéon.
Bibliothèque de la Ville, quai d'Austerlitz, 33 (provisoirement).
 Bibus, tailleur, Richelieu, 31.
 Bical, tab. de jouets, Montmorency, 33.
 Bical et Doire, fab. de socques, Vert-Bois, 14.
 Bican (Vve) et fils, fondeurs en cuivre, place de la Corderie-du-Temple, 26.
 Bichel, épicier, Marche-d'Aguesseau, 15.
 Bichard, tabac et eau-de-vie, Faub.-St-Martin, 45.

Didot 1843a - page 129

Bibliothèque Ste-Geneviève, rue des Sept-Voies et place du Panthéon.
Bibliothèque de la Ville, quai d'Austerlitz, 33 (provisoirement).
 Bibolet, relieur, passage Sainte-Marie-Saint-Germain, 10.
 Bibonne, architecte, Magasins, 12.
 Bibron, aide-naturaliste au Jardin-des-Plantes, Cuvier, 20.
 Bibus, tailleur, Richelieu, 31.
 Bichel, fab. de jouets, Montmorency, 33.
 Bican (Vve) et fils, fondeurs en cuivre, place de la Corderie-du-Temple, 26.
 Bichel, épicier, Marché-d'Aguesseau, 15.
 Bichard, tabac et eau-de-vie, Faub.-St-Martin, 45.

Didot 1844a - pages 125-126

Source images : Gallica BNF

Des sources géographiques anciennes à l'analyse géohistorique

Reconnaissance

Classification

Géo-référencement

Structuration

Scan → Texte

Ravrio et comp., fabr. de bronzes et cu-
riosités, r. Richelieu, 93; la fabrique
rue Montmartre, 161.


Segmentation des pages
+
Optical Character
Recognition (OCR)

Texte →
Entités nommées spatiales

Ravrio et comp. PER, fabr. de bronzes et cu- riosités ACT,
r. Richelieu LOC, 93 CARDINAL, la fabrique FT,
rue Montmartre LOC, 161 CARDINAL.


Reconnaissance des
Entités Nommées (NER)

Entités nommées spatiales →
Données géographiques



Géocodage


Données géographiques →
Données géohistoriques



Filtrage et liage des
entrées

Segmentation des entrées et reconnaissance optique des caractères (OCR)

Segmentation des pages en colonnes, paragraphes (XY cut), lignes (watershed) regroupées en entrées.




Source : Gallica BNF

Comparaison de 3 modèles d'OCR


	PERO OCR	Tesseract	Kraken
CER	3.78%	6.56%	15.72%

CER : Character Error Rate



Abadie et al. (2022)

Reconnaissance des entités nommées (NER)




Modèles

- CamemBERT
- CamemBERT pré-entraîné avec des entrées d'annuaires OCrisées

8341 entrées annotées :

- Train : 6004 entrées
- Dev : 668 entrées
- Test : 1669 entrées

Reconnaissance des entités nommées (NER)



Abadie et al. (2022)

Mettereau, prop., quai d'Anjou, 7.\n
 Mettemberg, élig., méd., St-Thomas-d'Enf., 5.\n
 Metz (de), rentier, St-Guillaume, 30.\n
 Metzinger, avocat, Rameau, 6.\n
 Metzmacher, peint. sur émaux, St-Martin, 124.\n
 Meurgey, épicier-herboriste, Dragon, 33.\n
 Meurice, Chaussée-d'Antin, 3.\n
 Meurice (Eug.), tapissier, Vivienne, 12.\n
 Meurillon, marbrier-sculpteur, butte Mont-\n
 Parnasse, 15.\n



Mettereau PER, prop. ACT, quai d'Anjou LOC, 7 CARDINAL.
 Mettemberg PER, élig. TITRE, méd. ACT, St-Thomas-d'Enf. LOC, 5 CARDINAL.
 Metz (de) PER, rentier ACT, St-Guillaume LOC, 30 CARDINAL.
 Metzinger PER, avocat ACT, Rameau LOC, 6 CARDINAL.
 Metzmacher PER, peint. sur émaux ACT, St-Martin LOC, 124 CARDINAL.
 Meurgey PER, épicier-herboriste ACT, Dragon LOC, 33 CARDINAL.
 Meurice PER, Chaussée-d'Antin LOC, 3 CARDINAL.
 Meurice (Eug.) PER, tapissier ACT, Vivienne LOC, 12 CARDINAL.
 Meurillon PER, marbrier-sculpteur ACT, butte Mont-Parnasse LOC, 15 CARDINAL.




Base de données contenant environ 22 millions d'entrées structurées

=> Environ 10 millions avec la première extraction

Géocodage

Sources géohistoriques des données d'adresses et de rues utilisées pour localiser les annuaires :



Rues de l'Atlas de Verniquet et adresses "Paris artistique, 1800-1820"



Rues et adresses de l'atlas Jacoubet, 1827-1836



Rues et adresses de l'atlas municipal, 1888




Rues et adresses OpenStreetMap, 2020

Duménieu (2023)

Géocodage

Géocodeur sensible à la dimension temporelle




96% des entrées sont géocodées.

Outil open-source : https://github.com/GeoHistoricalData/historical_geocoding

- ★ CQ1. Quelle est l'adresse du commerce X en 1862 ?
- ★ CQ2. Combien y a-t-il de commerces de ce type localisé *rue de Rivoli* en 1856 ?
- ★ CQ3. Quels sont les commerces situés dans une zone définie par un polygone ou un rectangle englobant en 1875 ?
- ★ CQ4. Quels commerces ont potentiellement déménagé au cours de leur existence ?
- ★ CQ5. Quels commerces ont été repris par un autre commerçant exerçant la même activité ?

- Constitution d'une liste de mots-clés utilisés pour filtrer les entrées pertinentes pour notre cas d'étude

➔ Recherche des photographes et ateliers (~230) listés par des historiens de l'art dans la base de donnée des extractions



Marc Durand (dir.). « De l'image fixe à l'image animée : 1820-1910.

Tome 2 : actes des notaires de Paris pour servir à l'histoire des photographes et de la photographie ». Archives nationales (2015).
Pierrefitte-sur-Seine.

```
SELECT *  
FROM directories.elements AS e  
WHERE e.persons ILIKE '%plumi%'  
ORDER BY e.published
```

Exemple de requête SQL
Toutes les entrées dont l'entité
"Nom de personne/commerce"
contient "plumi"

Plumier (Victor), portraits sur
plaques et sur pap., Vivienne, 36.

Didot_1856a

Exemple de résultat

- Constitution d'une liste de mots-clés utilisés pour filtrer les entrées pertinentes pour notre cas d'étude

Réduction de la liste de mots-clés utilisés aux trois mots les plus couramment associés aux photographes listés dans la référence.

PHOTO	DAGUER	OPTI
Photographe	Daguerréotype	Optique
Photographie		Opticien



Juin 2022 : 34 062 entrées




UPDATE Octobre 2023 : 45 807 entrées (listes alphabétiques uniquement)

Création de ressources RDF à partir de la base de donnée relationnelle contenant ces entrées (avec *ontop*)

• Ontologie

Vocabulaires utilisés :

- **RDFS** : label des entrées
- **LOCN** : description des adresses
- **Geosparql** : description des objets géographiques
- **RDA Registry** : description des activités
- **PROV** : description des données



- Méthodes de liage

Méthode fondée sur les connaissances

Appariement des entrées par **comparaison stricte** de clés



Clé = combinaison de propriétés, découvertes avec *Sakey*

- Numéro de l'entrée (si plusieurs activités ou adresses dans l'entrée)
- Nom et Activité
- Nom et Adresse
- Adresse et Activité



Création des liens par inférence

- Méthodes de liage

Méthode fondée sur les données

➔ Appariement par **comparaison numérique** des propriétés

➔ Distances d'édition : Levenshtein, TokenWise

Distance de Levenshtein : compte le nombre d'insertions, de remplacements et de suppressions de caractères pour passer d'un mot à un autre


ex : **CHAT** <=> **PLAT** 2 remplacements

Distance TokenWise :

- Calcul de la distance de Levenshtein entre tous les mots du texte
- Score final normalisé (entre 0 et 1)

Liage réalisé avec Silk
Single-machine (tests des critères
avec Silk Workbench)

● Critères de liage (méthode numérique)



- Méthodes de liage

Méthode logique

Paramétrage simple = clés

Comparaison très stricte :

- peu adaptée pour traiter des textes bruités
- liens sûrs
- temps et ressources de calcul importantes

1ère
extraction

34 062 entrées



250 622 liens

Méthode numérique

Paramétrage complexe = identifier les seuils de tolérance pertinents

Comparaison numérique :

- plus tolérante au bruit OCR
- risque plus élevé de produire des liens erronés (importance de choisir des seuils plutôt strictes)

& Propagation des liens sameAs

34 062 entrées



357 130 liens

- Méthodes de liage

Méthode numérique

Paramétrage complexe = identifier les seuils de tolérance pertinents

Comparaison numérique :

- plus tolérante au bruit OCR
- risque plus élevé de produire des liens erronés (importance de choisir des seuils plutôt strictes)



Grappe géohistorique :

<https://dir.geohistoricaldata.org/sparql>

2ème
extraction

45 807 entrées



841 609 liens



Visualisation spatiale...

 bit.ly/graphes_geohistoriques_soduco



Visualisation des graphes géohistoriques construits à partir des entrées d'annuaires du commerce de Paris (XIX^{ème} siècle)

[SPARQL Endpoint](#) | [Dépôt Git-Hub](#) | [Aide](#)

Dataset

Photographes et professions associées

[Statistiques du dataset](#)

Filtres

Propriétés

Raison sociale

Description

Adresse

 Les champs du formulaire acceptent les expressions régulières. Deux regex utiles :

- La propriété contient *mot1* ET *mot2*: `(?=.*mot1)(?=.*mot2)`
- La propriété contient *mot1* OU *mot2*: `mot1|mot2`


[Tester une regex complexe.](#)

Période



 Le filtre temporel permet de faire varier l'affichage des points préalablement chargés sur la carte sans lancer une nouvelle recherche.

Données chargées pour la période 1790-1915.



Plan de Paris contenant l'enceinte des fortifications - Andriveau-Goujon - 1849 © [GeoHistoricalData](#)

ANNÉE – 1860

NADAR

homme de lettres, artiste photographe

113 St-Lazare

Source : DidotBottin_1860

Identifiant de l'entrée : 24b37a26-65d1-57c3-abdc-91409f6066e6

Nombre de ressources liées : 5



DONNÉES LIÉES



113 ST-LAZARE

Nadar



35 BOUL. DES CAPUCINES

Nadar

Nadar

Nadar

Nadar



Questions de compétences

Quelle est l'adresse du commerce de Gallino en 1862 ?



11 rue suger



```
PREFIX locn: <http://www.w3.org/ns/locn#>
PREFIX ont: <http://rdf.geohistoricaldata.org/def/directory#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX prov: <http://www.w3.org/ns/prov#>
PREFIX pav: <http://purl.org/pav/>
select * where { graph <http://rdf.geohistoricaldata.org/id/directories/photographies> {
  ?e a ont:Entry.
  ?e rdfs:label ?label.
  ?e prov:wasDerivedFrom ?directory.
  ?directory pav:createdOn 1862.
  ?e locn:address ?add.
  ?add locn:fullAddress ?fullAdd.
  ?add prov:wasGeneratedBy <http://rdf.geohistoricaldata.org/id/directories/activity/0001>.
  Filter regex(rlcase(?label), "gallino").
}
```

Photographies et professions associées ▾

Statistiques du dataset

Filtres

Propriétés

Raison sociale

gallino

Description

Ex : photo

Adresse


Ex : rvoli

⚠ Les champs du formulaire acceptent les expressions régulières. Deux regex utiles :

- La propriété contient mot1 ET mot2 (?= 'mot1')(?= 'mot2')
- La propriété contient mot1 OU mot2. mot1|mot2

Tester une regex complexe

Période



⚠ Le filtre temporel permet de faire varier l'affichage des points préalablement chargés sur la carte sans lancer une nouvelle recherche.

Données chargées pour la période 1861-1862.

Questions de compétences

Combien y a-t-il de commerces de ce type localisés rue de Rivoli en 1856 ?



14



```
PREFIX locn: <http://www.w3.org/ns/locn#>
PREFIX ont: <http://rdf.geohistoricaldata.org/def/directory#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX prov: <http://www.w3.org/ns/prov#>
PREFIX pav: <http://purl.org/pav/>
select (count(distinct ?e) as ?nombre) where {graph <http://rdf.geohistoricaldata.org/id/directories/photographes> {
  ?e a ont:Entry.
  ?e prov:wasDerivedFrom ?directory.
  ?directory pav:createdOn 1856.
  ?e locn:address ?add.
  ?add locn:thoroughfare ?voie.
  ?add prov:wasGeneratedBy <http://rdf.geohistoricaldata.org/id/directories/activity/0001>.
}
}
Filter regex(lcase(?voie), "rivoli").
```

Questions de compétences

Quels sont les commerces situés dans une zone définie par un polygone ou un rectangle englobant en 1875 ?


```
PREFIX locn: <http://www.w3.org/ns/locn#>
PREFIX ont: <http://rdf.geohistoricaldata.org/def/directory#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX prov: <http://www.w3.org/ns/prov#>
PREFIX pav: <http://purl.org/pav/>
PREFIX gsp: <http://www.opengis.net/ont/geosparql#>
PREFIX geof: <http://www.opengis.net/def/function/geosparql/>
select ?label where {
  graph <http://rdf.geohistoricaldata.org/id/directories/photographes> {
    ?e a ont:Entry.
    ?e rdfs:label ?label.
    ?e prov:wasDerivedFrom ?directory.
    ?directory pav:createdOn 1875.
    ?e locn:address ?add.
    ?add gsp:hasGeometry ?geom.
    ?geom gsp:asWKT ?wkt.
  }
  FILTER (geof:sfIntersects(?wkt, "<http://www.opengis.net/def/crs/OGC/1.3/CRS84> Polygon((2.3360 48.8625,2.3360 48.8663,2.3385 48.8663,2.3385 48.8625,2.3360 48.8625))"^^gsp:wktLiteral))
}
```

Questions de compétences

Quels sont les commerces situés dans une zone définie par un polygone ou un rectangle englobant en 1875 ?



Exemple de la zone située autour du Palais royal :



Allévy

Barrès

Baur Vve

Bureau S

Crillon A

Derepas

Legros

Mustière

Prudent

Vantier

Questions de compétences

Quels commerces ont potentiellement déménagé au cours de la période 1860-1870 ?

```
PREFIX locn: <http://www.w3.org/ns/locn#>
PREFIX ont: <http://rdf.geohistoricaldata.org/def/directory#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX prov: <http://www.w3.org/ns/prov#>
PREFIX pav: <http://purl.org/pav/>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
select distinct ?label ?voie ?labelo ?voieo where { graph <http://rdf.geohistoricaldata.org/id/directories/photographes> {
  ?e a ont:Entry.
  ?e rdfs:label ?label.
  ?e prov:wasDerivedFrom ?directory.
  ?directory pav:createdOn ?date.
  ?e locn:address ?add.
  ?add locn:thoroughfare ?voie.
  ?e owl:sameAs ?o.
  ?o rdfs:label ?labelo.
  ?o locn:address ?addo.
  ?addo locn:thoroughfare ?voieo.
  Filter ((?date > 1860) && (?date < 1870)).
  Filter (!sameTerm(?voie, ?voieo))
}}
```




Exemple : Déménagement de Nadar de la Rue St-Lazare au Boulevard des Capucines vers 1860-1861

Questions de compétences

Quels commerces ont potentiellement déménagé au cours de la période 1860-1870 ?

St-Lazare

Boulevard des Capucines



ANNÉE – 1860

NADAR

homme de lettres, artiste photographe

113 St-Lazare

Source : DidotBottin 1860

Identifiant de l'entrée : 24b37a26-65d1-57c3-abdc-91409f6066e6

Nombre de ressources liées : 5

DOMAINES LIÉS



113 ST-LAZARE

Nadar

35 BOUL. DES CAPUCINES

Nadar

Nadar

Nadar

Nadar

TimelineJS 1859 1860 1861 1862 1863 1864 1865

Questions de compétences


Quels commerces ont été repris par un autre commerçant exerçant la même activité ?

```
PREFIX locn: <http://www.w3.org/ns/locn#>
PREFIX ont: <http://rdf.geohistoricaldata.org/def/directory#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX prov: <http://www.w3.org/ns/prov#>
PREFIX pav: <http://purl.org/pav/>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
select distinct ?label ?fadd ?labelo ?faddo where { graph <http://rdf.geohistoricaldata.org/id/directories/photographes> {
  ?e a ont:Entry.
  ?e rdfs:label ?label.
    ?e locn:address ?add.
    ?add locn:fullAddress ?fadd.
  ?e owl:sameAs ?o.
  ?o rdfs:label ?labelo.
  ?o locn:address ?addo.
    ?addo locn:fullAddress ?faddo.
  Filter (!sameTerm(?label, ?labelo) && sameTerm(?fadd, ?faddo) )
}}
```

 Exemple : Succession des photographes Bourgeois puis Bureau puis Mouret puis Bacard puis Courrier (A.) au 59 rue de Rivoli entre 1856 et 1908

Questions de compétences

Quels commerces ont été repris par un autre commerçant exerçant la même activité ?



Bourgeois

Bureau

Mouret

Bacard

Courrier A



Exemple : Succession des photographes Bourgeois puis Bureau puis Mouret puis Bacard puis Courrier (A.) au 59 rue de Rivoli entre 1856 et 1908

Démarche fonctionnelle d'exploitation des entrées issues des annuaires

- extraction fine et en masse
- entrées structurées, souvent bruitées.

Travaux à venir :

- évaluation quantitative des appariements,
- mise en œuvre de l'approche pour d'autres types de commerces,
- aide pour l'explicitation des relations spatio-temporelles entre les entrées (succession, déménagement),
- liage avec des ressources externes

Méthode, code, application et données accessibles sur le web.

Merci pour votre attention

Tutoriel, ontologie, ressources, code et questions de compétences

https://github.com/soduco/atelier_graphes_geohistoriques_annuaires

Application

bit.ly/graphe_geohistorique_soduco

Endpoint

<https://dir.geohistoricaldata.org/sparql>

Solenn Tual, Nathalie Abadie, Bertrand Duménieu, Joseph Chazalon et Edwin Carlinet. Création d'un graphe de connaissances géohistorique à partir d'annuaires du commerce parisien du 19ème siècle: application aux métiers de la photographie. *IC 2023, 34èmes journées francophones d'Ingénierie des connaissances*, Strasbourg, France, 3-7 Juillet 2023. [hal-04121643](https://hal.archives-ouvertes.fr/hal-04121643)

Références

Nathalie Abadie, Edwin Carlinet, Joseph Chazalon, et Bertrand Duméniou. **A Benchmark of Named Entity Recognition Approaches in Historical Documents Application to 19th Century French Directories**. Number 13237 in Document Analysis Systems. DAS 2022., La Rochelle, France, May 2022. Springer, Cham.

Bertrand Duméniou. **Localiser les adresses anciennes ? Plans historiques & annuaires parisiens au XIXe siècle**. Journée d'étude scientifique "Pour un traitement scientifique automatisé des cartes anciennes", Festival Printemps des Cartes 2023

Marc Durand (dir.). **De l'image fixe à l'image animée : 1820-1910. Tome 2 : actes des notaires de Paris pour servir à l'histoire des photographes et de la photographie**. Archives nationales (2015). Pierrefitte-sur-Seine.

Danai Symeonidou, Vincent Armant, Nathalie Pernelle, and Fatiha Saïs. **SAKey : Scalable Almost Key Discovery in RDF Data**. In proceedings of the 13th International Semantic Web Conference, ISWC 2014, volume Lecture Notes in Computer Science of The Semantic Web – ISWC 2014, pages 33-49, Riva del Garda, Italy, October 2014. Springer.

Silk Linked Data Integration Framework : outil de liage de données, <https://github.com/silk-framework/silk>

Pero OCR, <https://pero-ocr.fit.vutbr.cz/>