

EXTRACTING AND PROVIDING ONLINE ACCESS TO ANNOTATED AND SEMANTICALLY ENRICHED HISTORICAL DATA

The AGODA project

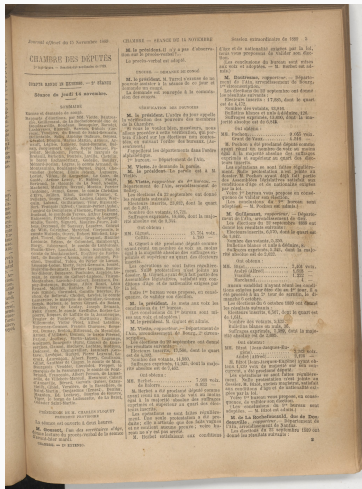
Marie Puren, Pierre Vernus, [Aurélien Pellet](#), Nicolas Bourgeois and Fanny Lebreton

1 June 2022

DH Benelux Conference 2022, University of Luxembourg

- AGODA : **A**nalyse sémantique et **G**raphes relationnels pour l'**O**uverture et l'étude des **D**ébats à l'**A**ssemblée nationale
- Funded by the Bibliothèque nationale de France for a period of one year
- One of the 5 pilot projects supported by the **DataLab**
- Collaboration between Epitech (MNSHS), Inria (ALMAAnaCH) and the University Lumière Lyon 2 (LARHRA)

PARLIAMENTARY DEBATES DURING THE THIRD REPUBLIC

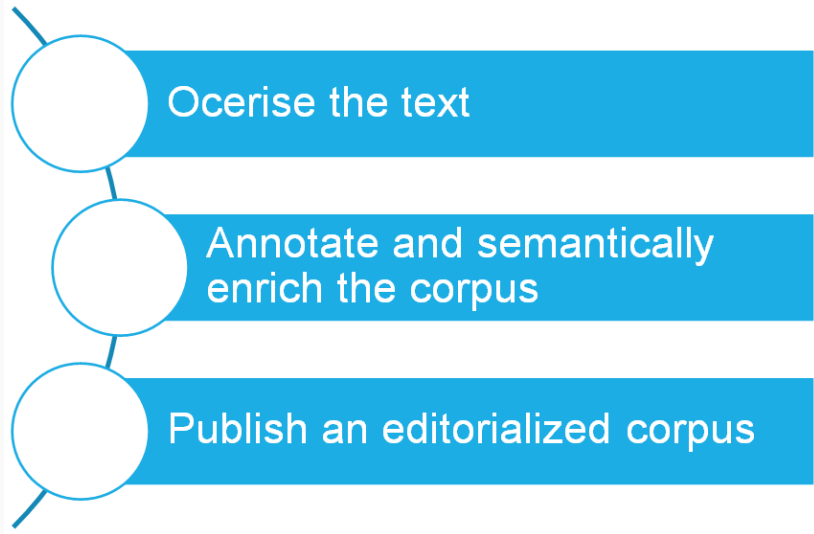


- Debates in the lower house of French Parliament (“Chambre des députés”) carefully recorded in the **Journal officiel de la République française**. **Débats parlementaires** (1881-1940)
- Available online on the digital library of the National Library of France (**Gallica**)
- Still difficult to work on this corpus : better if you already know what you’re looking for!

Figure – Parliamentary sitting
– 14 Nov. 1889

Working on a sub-part of the corpus : legislature 1889-1893, i.e. **10418 images to be processed**

- Give easier access to ancient transcriptions of parliamentary debates
- Facilitate research in this corpus
- Offer new ways of visualizing the documents



OCERISE THE DEBATES

THE CASE OF PARLIAMENTARY DEBATES

- Retrieval of ocerised texts via Gallica's **API Document** => uneven quality of the OCR
- Errors due to :
 - Document quality : stains and overprinting
 - **Curvature of the page** at the level of the binding




Figure – Quality assessment of the OCR provided by Gallica

EFFECT OF CURVATURE ON OCR RESULTS




Figure – 14
May 1890
(p.786)

Chagot dans son cabinet et voi il r près le discours qu'il lui tint : « Monsieur Chagot, lui dit-il, uS avrft tous les jours recours à labienveLu Gouvernement et de son représsu c t vos affaires particulières. Eh bien! rapof neut de vous avertir que, si vous tez pas les mesures, à mon sens i ^oS ow' bles, que vous avez prises contre l'ur alle vriers, vous n'aurez pas à courtoier S'lt cette bienveillance. » l per;ll M. Chagot se le tint pour dit et il etelit à ses ouvriers de conserver et de poolplir les fonctions qu'ils tenaient de n de leurs concitoyens. » cow! Eh bien, monsieur le m—i—i,»!

M. Chagot, les compagnies de r fer ont tous les jours recours à vou90m vos agents ; tous les jours, elles onV'cuiUde de vos bons offices et des leurso.nvveliez seulement rappeler à MM. les libe c—contrôle qu'ils sont moins encorrôleurs e rades que les directeurs, les concolllP les surveillants des ingénieurs dee coHlIP les surveillants des ingénieurs c0 der, gnies, et je suis convaincu que ces def avertissement suffira à obtenir nières les satisfactions que no r mons. une Messieurs, hier, vous vouez à loi ou j0j no mense majorité le principe ou velle ayant pour but de garantir x oUVro la liberté d association, qui leur est recoe, me par les lois républicaines. inist8r, de Je ne demande pas à M. ie III iigtre, travaux publics de provoquer * j ^eiii loi nouvelle ; je lui demande Simple gleut P faire respecter les lois exis" leS ro9y y avoir hier des dissidences en bres de cette Chambre sur ais j'es l'OH loi qui vous est proposée; Illa questl qu'il ne saurait y en avoir sur 011 que je soulève aujourd'hui. un t Ce n'est pas simplement en 'élève, C'ef et un ouvrier que le débat s lit ull S de entre une compagnie q lui ren'Pgtsr.

vice public et des centaines de jugi gaVOir j, travailleurs. La question est de anlc Jlt.

doivent être livrés sans défense au* JieV ces des compagnies qui les ifres 0'10 et, Quant à moi, je ne le crois p *

Figure – OCR result

IMAGE CLEANING TOOL DEVELOPED BY ANR SODUCO



(a) Original image



(b) Cleaned image

Figure – Demonstration of the SODUCO tool on a parliamentary debate page

OCR TOOL DEVELOPED BY SODUCO

Tool based on the OCR engine **PERO OCR** : very efficient on historical texts

Developed within the framework of the ANR **SODUCO**

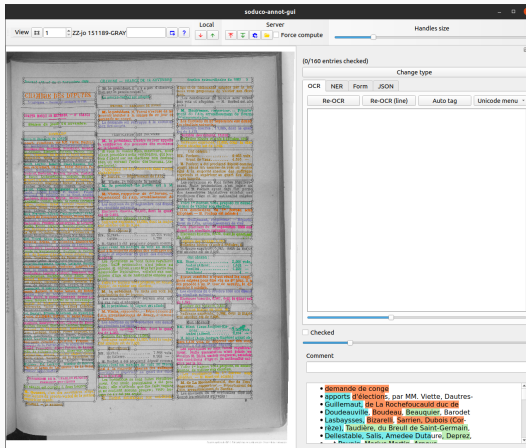
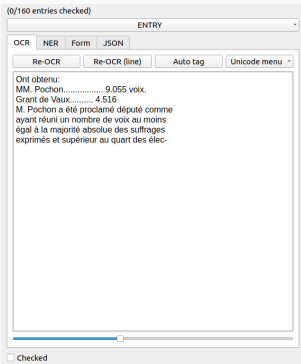


Figure – OCR tool developed by SODUCO

OCR AND NER



(a) OCR



(b) NER

Figure – OCR and NER zones

```
50
},
"id": 302,
"ner_xml": "<PER>Suirrages</PER> exprim\u00e9s, 9,90<CARDINAL>8</CARDINAL>, dont la majo-\u2029rit\u00e9 absolue est de <CARDINAL>4,455</CARDINAL>.",
"origin": "computer",
"parent": 263,
"persons": ["Suirrages"],
"text_ocr": "Suirrages exprim\u00e9s, 9,908, dont la majo-\nrnit\u00e9 absolue est de 4,455.",
"type": "ENTRY",
"activities": [],
"comment": "",
"checked": false
}
```

Figure – Output in JSON (extract)

THE PRINCIPLES OF THE ENCODING IN XML-TEI

Encoding is designed according to 4 principles :

- The different uses of texts
- The particularities of the source
- Similar projects : **ParlaClarin** and **ParlaMint**
- The automatic tagging process

For more information on this aspect :

<https://github.com/mpuren/agoda/tree/ODD>

EXPERIMENTING WITH DIFFERENT SOLUTIONS

```
<lb/><u who="#pers_ID" xml:id="CR_1889-11-26_u5" ana="#speaker">
  <seg xml:id="CR_1889-11-26_u5.1">
    <persName ref="#pers_ID">M. Paul Déroulède</persName>. Mes amis et moi
    <lb/>avons applaudi à ce que nous avons cru, à
    <lb/>ce que nous croyons encore être la forma-
    <lb/>tion spontanée d'une majorité de con-
    <lb/>science, de justice, de tolérance et d'union.
    <lb/><incident><desc>(Applaudissements sur quelques bancs à l'ex-
    <!-- Pas de lb possible dans incident --> trémité gauche de La salle. – Exclamations
    <!-- Pas de lb possible dans incident --> au centre et à gauche.)</desc></incident>
  </seg>
</u>

<lb/><u who="pers_ID" xml:id="CR_1889-11-26_u6" ana="#speaker">
  <seg xml:id="CR_1889-11-26_u6.1">
    <persName ref="#pers_ID">Gustave Rivet</persName>. La tolérance pour
    <lb/>toutes Les ignominies qui ont été commises
    <lb/>Pendant la période électorale.
  </seg>
</u>
```

(a) Encoding model 1 : semantics and layout

```
<u who="#pers_ID" xml:id="CR_1889-11-26_u5" ana="#speaker">
  <seg xml:id="CR_1889-11-26_u5.1"><persName ref="#pers_ID">M. Paul Déroulède</persName>. Mes amis et moi
avons applaudi à ce que nous avons cru, à ce que nous croyons encore être la formation spontanée d'une majorité de
conscience, de justice, de tolérance et d'union. <incident><desc>(Applaudissements sur quelques bancs à l'extrémité
gauche de la salle. –Exclamations au centre et à gauche.)</desc></incident></seg>
</u>

<u who="#pers_ID" xml:id="CR_1889-11-26_u6" ana="#speaker">
  <seg xml:id="CR_1889-11-26_u6.1"><persName ref="#pers_ID">Gustave Rivet</persName>. La tolérance pour
toutes les ignominies qui ont été commises pendant la période électorale.</seg>
</u>
```

(b) Encoding model 2 : semantics only

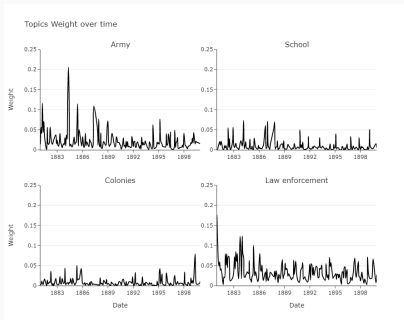
Figure – Parliamentary session of 26 November 1889 (extract)

TOPIC MODELING AND WORD EMBEDDING

EXPLORING DEBATES WITH TOPIC MODELING

Topic 8	Topic 11	Topic 15
salaire	général	pari
question	commission	télégraphe
gouvernement	régiment	faire
jour	troupe	ingénieur
patron	monsieur	train
chambre	année	ligne
droit	jeune	chambre
syndicat	temps	personnel
délégué	faire	etat
monsieur	corps	administration
travail	soldat	employé
travaux	ministre	poste
ministre	homme	public
grève	loi	travaux
faire	an	service
mineur	guerre	agent
mine	service	ministre
loi	militaire	fer
compagnie	officier	chemin
ouvrier	armée	compagnie

(a) 3 topics among 40 :
working class (8), army (11)
and infrastructures (15)



(b) Topic's evolution over time

Figure – Topic modeling with LDA

WORD EMBEDDING : WORD2VEC AND TOP2VEC



(a) Word vectors projected with t-SNE
(word2vec : CBOW,W=5)

Cluster 55	Cluster 68	Cluster 70
victimes	divorce	enveloppes
inondations	epoux	timbres
secourir	mariage	poste
eprouvées	conjugal	postale
orages	divorces	timbre
sinistres	adultère	recepissés
grele	conjugale	postes
secours	remarier	postaux
venir	séparation	telegraphes
infortunes	indissolubilité	colis
ravages	conjoints	fixe
miseres	mutuel	recouvrements
catastrophe	separations	graphes
evenements	mari	postales
repartition	mariages	taxe
incendies	femme	decide
soulager	conjoint	soit

(b) 3 clusters among the 113 topics found by top2vec : storm (55), divorce (68) and poste (70)

Figure – Results of word2vec and top2vec

- Nicolas Bourgeois, Aurélien Pellet, Marie Puren. "Using Topic Generation Model to explore the French Parliamentary Debates during the early Third Republic (1881-1899)". (hal-03526254v2)
- Marie Puren, Nicolas Bourgeois, Aurélien Pellet, Pierre Vernus, Fanny Lebreton. "Between History and Natural Language Processing : Study, Enrichment and Online Publication of French Parliamentary Debates of the Early Third Republic (1881-1899)". ParlaCLARIN III at LREC2022 - Workshop on Creating, Enriching and Using Parliamentary Corpora, Jun 2022, Marseille, France. (hal-03623351)

THANK YOU FOR YOUR ATTENTION!



Marie Puren : `marie.puren@epitech.eu`

Pierre Vernus : `pierre.vernus@msh-lse.fr`

Aurélien Pellet : `aurelien.pellet@epitech.eu`

Nicolas Bourgeois : `nicolas.bourgeois@epitech.eu`

Fanny Lebreton : `fanny.lebreton@chartes.psl.eu`