



LECTAUREP: Paris Notary Record Books Automated Reading

Alix Chagué, Rostaing Aurélia

► To cite this version:

Alix Chagué, Rostaing Aurélia. LECTAUREP: Paris Notary Record Books Automated Reading. Fantastic Futures 2021 / Futures Fantastiques 2021, AI4LAM; BnF; Université Paris Saclay, Dec 2021, Paris, France. hal-03479258

HAL Id: hal-03479258

<https://hal.inria.fr/hal-03479258>

Submitted on 14 Dec 2021

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution | 4.0 International License



LECTAUREP

Paris Notary Record Books Automated Reading

FF21 - BnF - 10/12/2021

Alix Chagué (Inria, Université de Montréal)
Aurélia Rostaing (Archives nationales)



LECTAUREP's perimeter

B/W & colored digitizations of notary record books, 1803-1940s

Visionneuse

Cotes : 44 v°-51 r°

Liste chronologique des actes pour la période du 2 janvier au 14 mai 1902

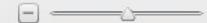
[Permalien](#) [Télécharger](#)

N° DU RÉPERTOIRE	DATES DES ACTES	NATURE ET ESPÈCE DES ACTES :		NOMS, PRÉNOMS ET DOMICILES DES PARTIES INDICATIONS, SITUATIONS ET PRIX DES BIENS	RELATION DE l'Enregistrement.	
		EN BREVETS	EN MINUTES		DATES	DROITS
1196	28	Procuration		An 1901 , mois de Décembre Portal (par Marie) à Paris, rue d'Amsterdam 84, et Marie, épouse de Abel Théophile Berger, Bd Haussmann, 104, s' renoncer à l' ^{et} 30 3.75		
1197	28	Défolt de procuration		Jeantecoul (nommée par Charles au nom à céder, à l'heure échoué Moreau	30	3.75
1198	28	Inventaire		Treuel (après décès de Henry Désiré), d. à Paris, rue Legendre 191, décédé à Pierres, le 23 Octobre 1901	6	12.45
1199	28	Motorité		Miziel (après le décès de Hortense Henriette Josephine, veuve de Alfred Jean Marie)	6	3.75

Zoom



Luminosité



Contraste



Verrouiller les paramètres



Stakes

Help end-users read, search, mine notarial registers

- > Turn massively digitized archives into data through AI (recurrent neural networks - LSTM)

Serve GLAM communities, academics, genealogists, HTR/AIS/LIS SPs

- > Mutualize & document data, models, platform, methods for interoperability purposes

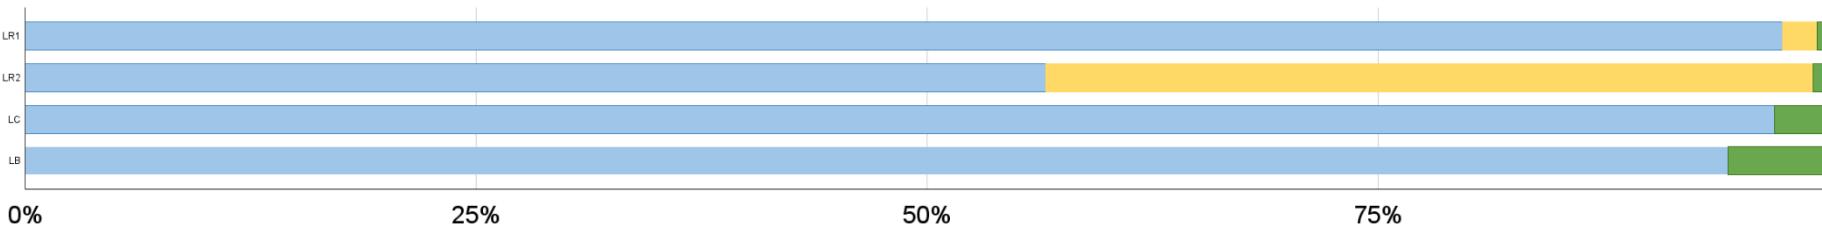
Consider digital heritage as a whole

- > Take into account B&W digitized microfilms & digitization from the original

Sample sets

	Images	Dates	Notaries	Notary Studies	Hands	Hands	Size (Go)	Target (p.)	Lots (p.)	Transcribed (p.)	Revised (p.)
Lot Rép. 1	b/w	1803-1907	12	4	~50	~16	11.6	~174 840 ?	20 800	533	138
Lot Rép. 2	col.	1889-1943	~100	~57	~200	~100	3.75	~1 M ?	1844	800	16
Lot CM-SD	col.	1829-1934	N/A	N/A	~30	~10	42.5	20 000	600	600	218
Lot Bronod	col.	1719-1760	1	1	1	1	1.2	3595	200	200	200

- remaining in the lot
- transcribed, not revised
- transcribed and revised



Technological environment

The screenshot shows the eScriptorium interface. At the top, there's a navigation bar with 'Home' and 'Contact'. Below it, a project titled 'Benjamin - Random set_1 (1)' is shown, along with file details: 'Element 1 - FRAN_2023_00773_0-jpg (2997x4298) - 2.33 MB'. There are buttons for 'Zip Import' and file management. The main area contains a grid-based transcription of a historical document and a detailed table of acts.

N°	DATES DU DE	NATURE ET ESPÈCE DES ACTES	NOMS, PRENOMS ET DOMICILES DES PARTIES	RELATION ENTRE LES ACTES	INDICATIONS, STATIONNEMENTS ET PRIX DES BIENS
576	24	Inventaire	An 1903 mois de Juillet	29	11.25
577	24	Décharge	Comme inventaire dans la Rue Rude 10, le 14 Juil 1903.	28	3.75
578	24	Procuration	Gérance de marchand, établi à Paris, au nom de son épouse, Mme Gérard, à l'ordre de M. Léonard, pour la vente de ses biens.	29	3.75
580	24	Procuration	Revenant au Dr Claude Auguste de Paris, le 24 Juil 1903.	24	..
581	25	Donation	Angèle Lemoine, son épouse Léonard tous propriétés
582	25	Procuration	Le Dr Léonard à Paris, le 24 Juil 1903.	3	3.75
583	25	Concession d'usufruit	Concession d'usufruit à la veuve de Mme Lemoine, Mme Lemoine et Alice Lemoine.	3	2.50
584	28	Concession à usufruit	Le Dr Léonard à Paris, le 24 Juil 1903.	4	7.50
585	29	Mainlevée	À la veuve Auguste Louise Gérard et à son fils, Mme Gérard, à Paris, le 24 Juil 1903.	..	Grat.
586	29	Cession de bail	Offerte par Mme Léonard à Mme Gérard et à son fils, Mme Gérard, à Paris, le 24 Juil 1903.	..	12.75
587	30	Recouvrement	Remise au Dr Léonard de la somme due à son épouse.	5	16.50
588	31	Stade 11 bin (REVENANT)	Restitution au Dr Léonard de la somme due à son épouse.	3	47.50
589	31	Dépot de gênes	Depot de gênes par Mme Léonard, ménage au 1007 ^e Rue de la Convention, Paris, le 24 Juil 1903 (MM).	3	38.75
590	Procuration	Mois d'Août 1903	Procuration de Mme Léonard à Paris, le 24 Août 1903.	3	239.50
591	1er	Bail	Ajout de deux étages au 1007 ^e Rue de la Convention, Paris, le 24 Août 1903.	3	3.75
592	3	Procuration	Abattement % sur l'ensemble à la date 28 Août 1903, par MM. Léonard et Gérard, à Paris, le 24 Août 1903.	3	14.25
			Les deux parties ont également accepté que dans les deux dernières années de leur mariage, Mme Léonard et Gérard, à Paris, le 24 Août 1903.	4	3.75

Hardware

- 2019 - lectaurep.paris.inria.fr (no GPU, virtual machine)
- 2020 - traces6.paris.inria.fr (2 GPU, more storage)
- 2021-2022 - escriptorium.cremma.fr (better architecture, + 2 GPUs, more storage, more RAM)

Software

- **Kraken** - open source HTR engine developed by Ben Kiessling since 2015
- **eScriptorium** - open source web application developed by SCRIPTA PSL since 2018

lectaurep VM

Traces6

CREMMA



Contractual deliverables

Models

- 1 perfectible model for line detection
- 1 perfectible model for region detection
- at least 4 usable models for text recognition
 - 2 generics (several hands): “Generic” (9 %) & “Random Set” (10 %)
 - 2 specialized (1 hand): “Bronod” (5 %) & “Contrats de Mariage” (3 %)

Documentation

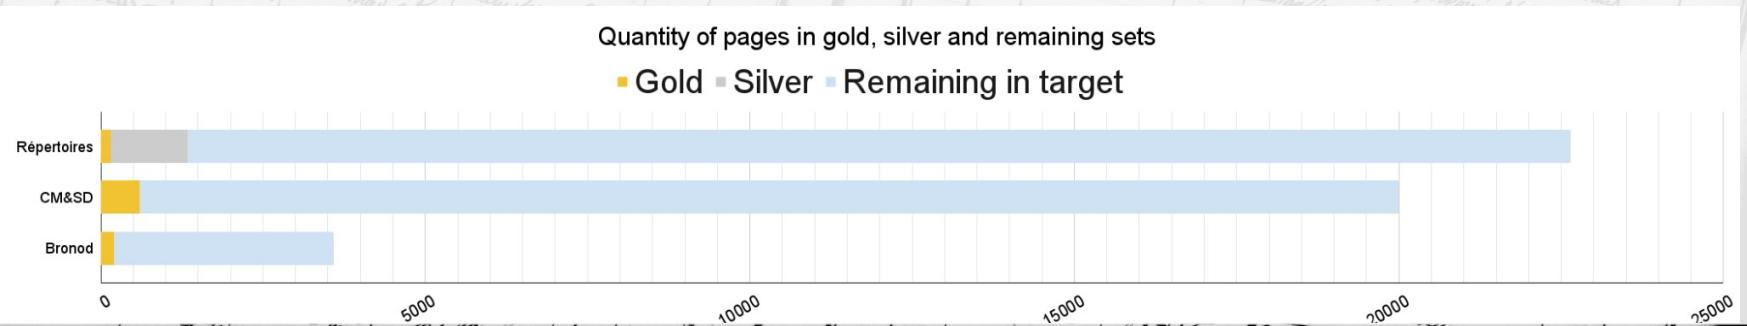
- Transcription conventions & good practices
- Open Science and Gitlab/Github environments (issues and codes)

Contractual deliverables

Data

- 239 images (31 401 lines) gold transcription published and documented as ground truth on HTR-United
 - from Répertoires, CM/SD and Bronod
 - additional publication on data.archives-nationales.culture.gouv.fr?
 - 333 more pages ready to join HTR-United
- 1561 images of silver transcription awaiting revision

data.culture.gouv.fr



Bonus deliverables

Scripta-PSL

- Providing use cases and feedback
- Developing features for eScriptorium (document tags, dashboard...)
- Creating general documentation for eScriptorium (tutorial)

GLAM & academics

- Sharing expertise with users, project carriers and working groups (smaller projects, CREMMALab, AI4LAM)
- Sharing expertise via scientific publication (Hypotheses blog)

KaMI: metrics from the lab to the field

A tool to better evaluate the performances of HTR models with:

- filters (digits, punctuation, diacritics, lower/upper case, etc.)
- more metrics (CER, WER, hit and substitutions or deletions, etc.).
- KaMI is agnostic (not limited to Kraken)

Reference

"Maison Chevillard" à la requête de Delarce avoué à Paris
11:25
2
Certificat délivré
Le Roy (concernant Louise Amable Anais à Paris B^ed Diderot
902
45 p^er^e renouveler inscription de rente 3% de 1100 f n^e
3

Prediction

Maison Chevillard à la requête de Delarce avoué à Pi
11:25
2
Certificat délivré
Le Roy (concernant Louise Amable Anais à Paris B^ed Diderot
902
45 p^er^e renouveler inscription de rente 3% de 1100 f n^e
3

Ignore all digits
 Ignore text case (all in lower case)
 Ignore the punctuation
 Ignore diacritical signs

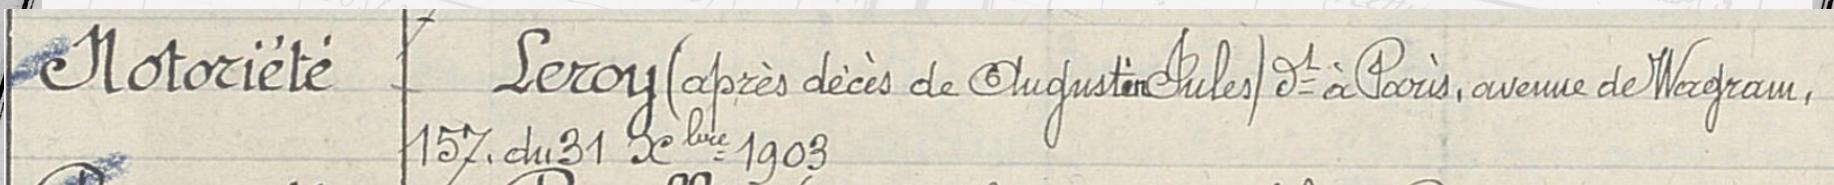
Compare

	Default	Ignoring digits	Ignoring case	Ignoring punctuation	Ignoring diacritics	Combining all options
Levenshtein Distance (Char.)	440	433	433	421	210	178
Levenshtein Distance (Words)	228	216	224	219	130	99
Hamming Distance	Ø	Ø	Ø	Ø	Ø	Ø
Word Error Rate (WER)	30.645	33.333	30.107	29.514	17.473	16.202
Char. Error Rate (CER)	9.596	10.253	9.443	9.57	4.554	4.38
Word Accuracy (Wacc)	69.354	66.666	69.892	70.485	82.526	83.797
Match Error Rate (MER)	9.333	9.949	9.183	9.297	4.538	4.363
Char. Information Lost (CIL)	13.52	14.385	13.196	13.425	6.203	5.75
Char. Information Preserved (CIP)	86.479	85.614	86.803	86.574	93.796	94.249
Hits	4274	3919	4282	4107	4417	3901
Substitutions	204	200	195	193	78	57
Deletions	107	104	108	99	116	105
Insertions	129	129	130	129	16	16

A corpus raising challenges for NLP-ists

A corpus of text with strong potential to raise new challenges for NLP due to its specificities

- many abbreviations
- many named entities
- non verbal sentences

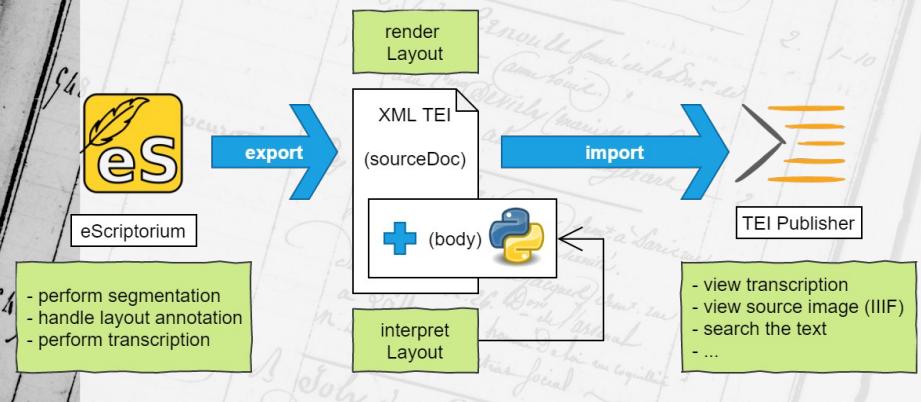


Notoriété | Leroy (après décès de Augustin Jules) demeurant à Paris, avenue de Wagram, 157, du 31 décembre 1903."

Affidavit | Leroy (after death of Augustin Jules) dwelling in Paris, avenue de Wagram, 157, on December 31st 1903.

Towards TEI XML and TEI Publisher

- More systematic usage of TEI XML in the pipeline
- Displays documents with complex layout in simple interface
- Benefits from viewing IIIF facsimile and search feature in tools like TEI Publisher



The screenshot shows the TEI Publisher interface. At the top, there's a navigation bar with "Start", "Documentation", "News", "Download", a GitHub icon, "Enter Query", and language selection ("Language English"). Below the navigation is a search bar with a magnifying glass icon. The main area displays a document titled "FRAN_0025_1290_L-1-tei". The document contains two entries:

292 15 P. V. ouv.
Cof.

Bajal au décès de
Désiré Alexandre
Martin à
Romainville 22
7 et 9 rue des
Oserats arrivé le
10 8^ebre 1938

293 15 Inventaire

Jadin au décès de
Dieudonne
Joseph Adolphe
à Paris 6 rue
des Battiglioni y
arrivé le 22-12-
1938 ép's de
Henriette
Eugénie
Montigny

Pierrat et
Anderson à Jules

On the right side of the document, there is a facsimile of a French 4-francs banknote and some handwritten notes in French.

Conclusion

Generic HTR models enable fuzzy search in loose lines (B/W 19th c. & part of col. 20th c.).

Segmentation models need to be upgraded in case of tight lines (large part of col. 20th c.).

A segmentation rating tool could be handy.

Target corpus: 3100 notary record books (~14% color)

~1,2 M pages, ~1000s handwritings, 1803-1940s (sample transcribed: 1,11 %o)



eScriptorium Home Contact

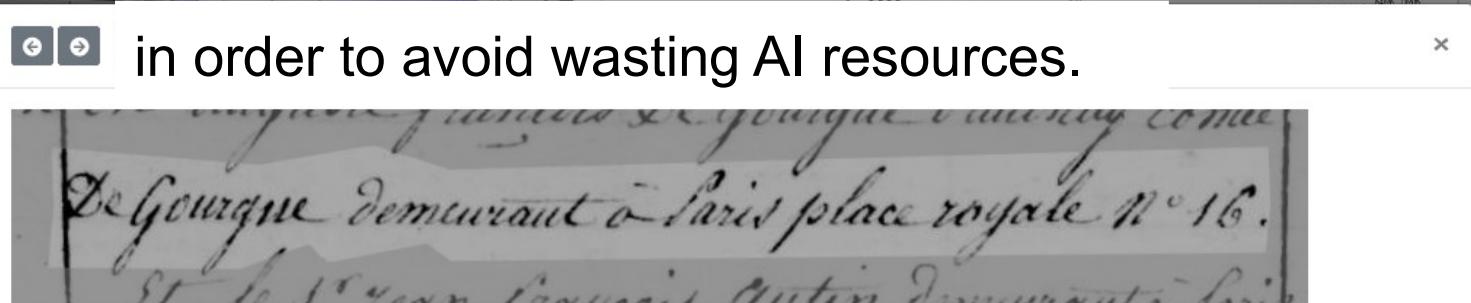
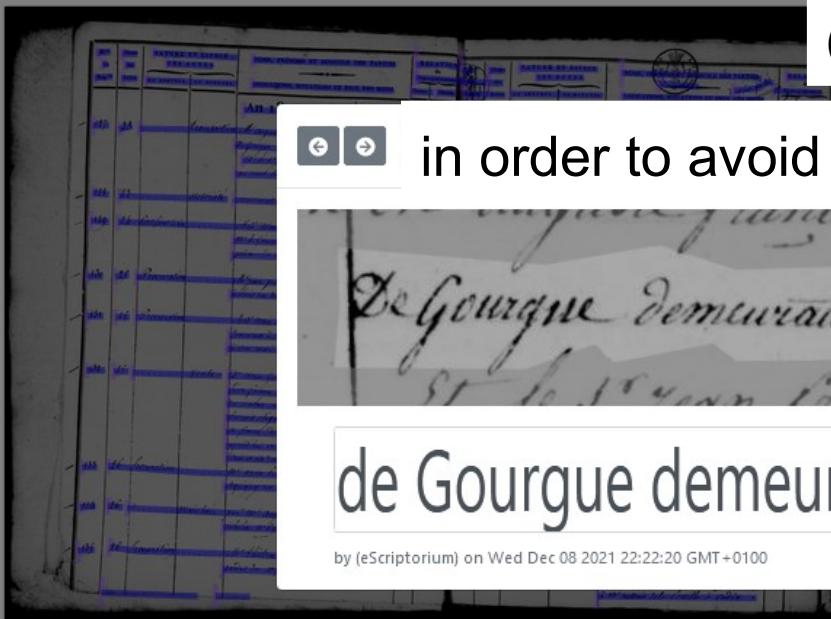
Scaling for production deployment means

My Projects My Models Hello lectaurep

> collaborative logistics, infrastructures, project engineering.

> better sources diplomatic (how many handwritings in a book?)
> better mastering of digital images metadata (B/W-col. distribution) .

in order to avoid wasting AI resources.



de Gourgue demeurant à Paris place royale n°16.

by (eScriptorium) on Wed Dec 08 2021 22:22:20 GMT+0100

à la demande de la volonté à la fois

Thank you!

Links to doc!

- Blog: <https://lectaurep.hypotheses.org/>
- Gitlab: <https://gitlab.inria.fr/almanach/lectaurep>
- Github: <https://github.com/lectaurep>

Data on HTR-United

- <https://github.com/HTR-United/lectaurep-mariages-et-divorces>
- <https://github.com/HTR-United/lectaurep-bronod>
- <https://github.com/HTR-United/lectaurep-repertoires>

Contact

- ✉ alix.chague@inria.fr
- ✉ aurelia.rostaing@culture.gouv.fr