

RECITAL

Combining crowdsourcing and expertise in Digital Humanities

FOSDEM - February 2021

Olivier Aubert

www.olivieraubert.net - contact@olivieraubert.net

in collaboration with Françoise Rubellin (LAMO - Univ. Nantes)
and Guillaume Raschia (LS2N - Univ. Nantes)

Context: Comédie-Italienne history

RECITAL: Registres de la Comédie-Italienne

des Théâtres de la Foire et de la Comédie-Italienne

Literature and history lab aiming at studying fairground theaters and Italian Comedy in Paris around XVIIIth century

Multiple approaches

- edition and study of unedited plays (**Ciresfi**)
- musical studies and database (**Theaville**)
- VR reconstitution of no longer visible theatres (**VESPACE**)
- accounting registers study (**RECITAL**)

What are we expecting to learn from accounting registers?

- performed plays titles
- sold tickets (by category)
- expenses (taxes, accessories, musicians)
- theatre accounting

We want to learn generalities, but also find out exceptional things/events



Data to re-think theatre history

Economic history

author's royalties, subscriptions,
accounting rules...

Social history

audience composition, placement,
involved actors...

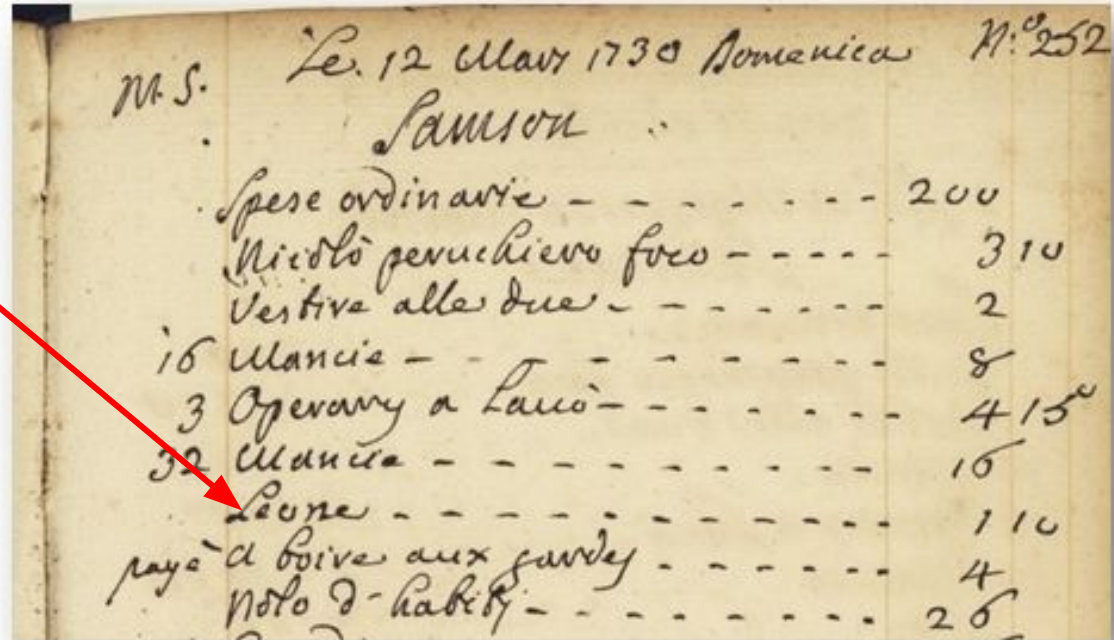
Hardware history

sets making, costumes...



Historical investigations...

Leone : Lion
(a turkey actually)



M.S.	Le. 12 May 1730	Romanica	N: 252
	Samson		
	Spese ordinarie	- - - - -	200
	Nicolò peruchiero fono	- - - - -	310
	Vestiva alle due	- - - - -	2
	16 Mancie	- - - - -	8
	3 Operarii a Lario	- - - - -	415 ^u
	32 Mancie	- - - - -	16
	Leone	- - - - -	110
	paye a boire aux gardes	- - - - -	4
	nolo d-habit	- - - - -	26

A similar project is underway on Comédie Française registers

See

<https://www.cfregisters.org/>



Registres

Accédez aux versions numérisées des registres journaliers de la Comédie.



Base de données

Accédez aux données qui concernent les recettes journalières de la Comédie.

ANNEE 1772 à 1773. DÉPENSE JOURNALIERE.

N^o. 1 De Samedi 17. avril 1772

A Représentations pour l'ouverture d'Opéra, Comédie de M. de Nolaine et Les Pommiers

	liv.	s.
A la Garde Militaire, trente-trois livres dix sols. . .	33	10
30 Jetons d'Assemblée de ce jour, à	180	
Jetons de lecture, à		
Jetons de comités, à		
24 Soldats assistants à chacun 1 ^{re}	24	
A. M.		
16 Feux d'Acteurs Et d'Actrices, à 20 s.	32	
Mus.		
Mlle.		
Douville		
Le Rame		
Battou		
proville		
Bryant		
Abol		
Daubouval		
Salanval		
Abouval		
Battouval		
Bouval		
Total . . .	269	10

Attesté par nous Semainiers, la dépense de ce jour d'un vingt-huit
avril mil sept. cent. soixante-trois montant à la somme
de Deux cent. sixante-neuf livres dix sols

Dubouval Salanval


The corpus

Accounting registers

kept under the roof of the
Bibliothèque-musée de l'Opéra




Available corpus



Registers for Comédie-Italienne - now available on [Gallica](#)

A century of accounting registers



(figure by Florent Coubard)

- 1 Register = 1 Theatre Season, from April to March
- digitized corpus: 1717-1794 (with 13 seasons missing)
- 64 registers of 300 to 600 pages
- about 26 000 pages

Anatomy of a register

Le Dimanche 4^e May 1760
Les Dépenses en monnaie
compte de la semaine avec le dimanche

Date	Description	Montant
10. Mai
11. Mai
12. Mai
13. Mai
14. Mai
15. Mai
16. Mai
17. Mai
18. Mai
19. Mai
20. Mai
21. Mai
22. Mai
23. Mai
24. Mai
25. Mai
26. Mai
27. Mai
28. Mai
29. Mai
30. Mai
31. Mai

Daily accounts
77%

Compte General de May 1760

Date	Description	Montant
1. Mai
2. Mai
3. Mai
4. Mai
5. Mai
6. Mai
7. Mai
8. Mai
9. Mai
10. Mai
11. Mai
12. Mai
13. Mai
14. Mai
15. Mai
16. Mai
17. Mai
18. Mai
19. Mai
20. Mai
21. Mai
22. Mai
23. Mai
24. Mai
25. Mai
26. Mai
27. Mai
28. Mai
29. Mai
30. Mai
31. Mai

Monthly accounts
10%

Le 31 May 1760

Date	Description	Montant
1. Mai
2. Mai
3. Mai
4. Mai
5. Mai
6. Mai
7. Mai
8. Mai
9. Mai
10. Mai
11. Mai
12. Mai
13. Mai
14. Mai
15. Mai
16. Mai
17. Mai
18. Mai
19. Mai
20. Mai
21. Mai
22. Mai
23. Mai
24. Mai
25. Mai
26. Mai
27. Mai
28. Mai
29. Mai
30. Mai
31. Mai

Final state + various
3%



Blank pages
10%

TH-OC-42 register (1760-1761) - 373 pages

Original corpus characteristics

- Handwritten pages
- 2+ languages: French and Italian (various dialects)
- 7+ « bookkeepers »: from Alborghetti to Linguet
- Currency of the Ancien Régime : Livre-Sou-Denier
- All along the century
 - formal changes of balance sheets
 - updating of accounting rules

Digitizing approaches

Two complementary approaches

Automated (AI-based)

vs

Manual (expert+crowdsourcing)

AI automation

Usage of AI for segmentation and transcription

- PhD work by Adeline Granet during the project (2015-2018)
- Difficult corpus characteristics + lack of ground truth (bootstrap)

Off-the-shelf open solutions now exist for HCR

- **Transkribus**: mostly open-source, but recent paying model for using models in SAAS mode.
- **eScriptorium** (web interface for **Kraken**): open-source

Crowdsourcing approach

- more tedious, workforce-demanding
- fit for irregular contents
- more apt at identifying exceptional/interesting items
- a requirement for building the ground-truth
- issues of data quality evaluation and data validation

Crowdsourcing platform - ScribeAPI

ScribeAPI software

issued from the Zooniverse project

MIT-licensed

Ruby-on-Rails platform

Crowdsourcing tasks in short



3 activities

- Mark (segment and categorize)
- Transcribe
- Verify

Crowdsourcing interface

8 different page
types

Déterminez le type de la page ci-
contre :

COUVERTURE

INTRODUCTION

ETAT

COMPTE QUOTIDIEN

COMPTE MENSUEL

COMPTE ANNUEL

PAGE VIERGE

OK

Inclassable ?

Crowdsourcing interface - marking

133 data categories - displayed according to the page type

Ad. 6 febraro 1722 Venèdi

Lej filles Amoures du Diable, et Phaeton


Spese ord	160	—	—
ffoco a Mancie	—	20	10
L. Licomba	—	1	—
nofo d. Redie d. Comp. a	—	2	—
Putella	—	3	—
Peruchiero	—	2	10
Abigliare alle due	—	1	10
3 Ballaripi	—	15	—
Costa ala Cavetto	—	2	11

Marquez les postes de recette (2/5):

- ☒ Loge particulière ?
- ☐ Théâtre
- ☐ Première loge (1)
- ☐ Seconde loge (1)
- ☐ Troisième loge (1)
- ☐ Quatrième loge
- ☐ Parterre (1)
- ☐ Supplément
- ☐ Autre recette
- ☐ Total des recettes (1)

← SUIVANT

Crowdsourcing interface - marking



Marquez les éléments d'en-tête (1/5):

- ☐ Date du jour ?
- ☐ Titre(s)
- ☐ Événement exceptionnel
- ☐ Numéro de page

SUIVANT

Crowdsourcing interface - transcription



The interface displays a handwritten document snippet at the top. Below it, a form for transcription is shown. The form includes a label 'Titre des pièces :', an example text 'ex. 24e des boulevards, Ninette à la Cour ~', and a list of titles 'Les brouilleries nocturnes, La fille mal gardée, et Le ballet des hongrois ~'. A text input field is provided for transcription. At the bottom, there are four buttons: 'Besoin d'aide ?', 'Marque erronée ?', 'Illisible ?', and 'Marque suivante'.

26 Lundi 29 août 1790

Les femmes et le secret, le perdrix et Zémire

Titre des pièces :

ex. 24e des boulevards, Ninette à la Cour ~

Les brouilleries nocturnes, La fille mal gardée, et Le ballet des hongrois ~

Besoin d'aide ?

Marque erronée ?

Illisible ?

Marque suivante

Les femmes et le secret, la perdrix et Zémire

Crowdsourcing interface - verification



The image shows a screenshot of a crowdsourcing interface for verifying handwritten text. At the top, there is a sample of handwritten text in French: "Du Dimanche 21 Juillet 1776" and "Le Roi le fermier La Parodie". Below the text, there is a white box with an orange header that says "Votez pour la meilleure transcription". Inside this box, there is a label "Saisie d'origine : Titre des pièces :" followed by two input fields. The first field contains the text "Le roi et le fermier, La parodie" and the second field contains "Le roi, le fermier, la parodie". At the bottom of the box, there are two buttons: "Autre proposition ?" and "Marque erronée ?".

Votez pour la meilleure transcription

Saisie d'origine : *Titre des pièces :*

Le roi et le fermier, La parodie

Le roi, le fermier, la parodie

Autre proposition ?

Marque erronée ?

ScribeAPI

Pros

- Open source
- Collaborative annotation of images
- Able to express chained task sequences (mark-transcribe-verify)
- Well thought interface (accessible to non-technical users)

Cons

- Complex architecture/model
- End-of-life reached in 2016

Open-Source and Technical debt

Official ScribeAPI - End-of-Life in 2016

Dependencies on old versions of Ruby, js/coffeescript, Mongo, unbuildable as-is now

Current server/dependencies dockerized

But not all hope is lost

effort by Utrecht University to update critical dependencies (unmerged pull request)

After crowdsourcing - ongoing work

- Data quality evaluation
 - first phase crowdsourced (peer-reviewed verification)
 - second phase automated
 - third phase manual
- Data cleaning and validation
 - custom tools, using external information (list of play titles, actors...)
 - dedicated user-interface (dashboard) for experts
 - integration of AI-based tools
- Data publication
 - FAIR principles
 - collaboration/links with other projects/data

If you want to contribute, welcome at...

<https://recital.univ-nantes.fr/>

