

Textometric Exploitation of Coreference-annotated Corpora with TXM

Methodological Choices and First Outcomes

Matthieu Quignard (CNRS/ICAR, Lyon)
Serge Heiden (ENS/IHRIM, Lyon)
Frédéric Landragin (CNRS/LATTICE, Paris)
Matthieu Decorde (ENS/IHRIM, Lyon)



Co-reference ?

We had dinner yesterday evening with Serge and Pascal. They were very joyful.

- > [They] refers to two people, Serge and Pascal
- > [They] and [Serge and Pascal] corefer.
- > [They] → [Serge and Pascal] is an anaphora

The wine was delicious.

- > [The wine] does not strictly refer to the dinner but to the wine served at dinner (implicit)
- > [The wine] → [the dinner] is an associative anaphora

The DEMOCRAT Project



- 3 French partners
 - LATTICE (Paris), LILPA (Strasbourg), IHRIM-ICAR (Lyon)
- 48 months
- A manually annotated corpus of French written texts, from 9th century to the 21st ; 1 million words (actually less) ; balanced between narrative and non narrative texts (essays...).
- Tools for annotating texts and exploiting annotation (TXM)
- Support research on reference in discourse and discourse processing
 - Theory of reference (Landragin, Schnedecker)
 - Automated discourse analysis, NLP, deep learning

Annotation principles

- Units – Relations – Schemata (URS, cf. Glozz)
- Units
 - segments of text referring to a given character, idea, concept...
- Relations
 - Units in relation which each other, e.g. anaphora
- Schema
 - Sets of units corefferring to the same object = coreferring chains

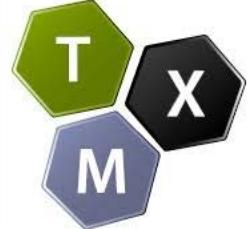
Annotation principles

- Units – Relations – Schemata (URS)
- Units
 - segments of text referring to a given character, idea, concept...
- Relations
 - Units in relation which each other, e.g. anaphora
- Schema
 - Sets of units corefferring to the same object = coreferring chains

The « Unitizing » Task

- The annotator must do the following operations
 - Decide whether an object has been mentionned or not
 - Some pronouns are not referential (one, nobody...)
 - **Delimitate** the segment of text that mentions that object
 - The segment has to be contiguous
 - Long enough (whole noun phrase)
 - The preposition should keep outside
 - Give a name to the referent and use the **same name** in all coreferring mentions
- NB : There are **overlapping** segments : [[my]_i computer]_j

TXM as an annotation framework



<http://textometrie.org>

- TXM is well known for exploiting, investigating corpora
 - frequencies
 - concordancer
 - charts with R
 - progressions...
- An extension has been developed for DEMOCRAT : ANALEC
 - **Online annotation**
 - Integration of the **URS** structure of annotation over the XML structure of the document itself
 - Online exploitation of the annotation as a means of **verification tool** (quality measurement)

Annotation

1 et sa felicité dans le paradis, dont la memoire s'est
2 conservée dans l'age d'or des poëtes ; le précepte
3 divin donné à nos premiers parens ; la malice de
4 l'esprit tentateur, et son apparition sous la forme
5 du serpent ; la chute d'**Adam** et d'Eve, funeste à
6 toute leur posterité ; le premier homme justement
7 puni dans tous ses enfans, et le genre humain maudit
8 de Dieu ; la premiere promesse de la rédemption, et
9 la victoire future des hommes sur le démon qui les
10 a perdus.

11 La terre commence à se remplir, et les crimes
12 s'augmentent. Caïn le premier enfant d'Adam et
13 d'Eve, fait voir au monde naissant la premiere action
14 tragique ; et la vertu commence dès lors à estre
15 persecutée par le vice. Là paroissent les moeurs
16 contraires des deux frères : l'innocence d'Abel, sa
17 vie pastorale, et ses offrandes agréables ; celles de
18 Caïn rejetées, son avarice, son impiété, son
19 narcicide, et la jalouise mère des meurtres : le

default



◀ ▶ 4 / 45



DEMOCRATLYON3 - MENTION [443] ☰

Console



ACCESSIBILITÉ Faible

CATEGORIE GN.NAM

REF

Adam



Annotation

1 et sa felicité dans le paradis, dont la memoire s'est
2 conservée dans l'age d'or des poëtes ; le précepte
3 divin donné à nos premiers parens ; la malice de
4 l'esprit tentateur, et son apparition sous la forme
5 du serpent ; la chute d'**Adam** et d'Eve, funeste à
6 toute leur posterité ; le premier homme justement
7 puni dans tous ses enfans, et le genre humain maudit
8 de Dieu ; la premiere promesse de la rédemption, et
9 la victoire future des hommes sur le démon qui les
10 a perdus.

11 La terre commence à se remplir, et les crimes
12 s'augmentent. Caïn le premier enfant d'Adam et
13 d'Eve, fait voir au monde naissant la première action
14 tragique ; et la vertu commence dès lors à estre
15 persécutée par le vice. Là paroissent les moeurs
16 contraires des deux frères : l'innocence d'Abel, sa
17 vie pastorale, et ses offrandes agréables ; celles de
18 Caïn rejetées, son avarice, son impiété, son
19 narcicide et la jalouise mère des meurtres : le

Units

default



◀ ▶ 4 / 45



DEMOCRATLYON3 - MENTION [443] ☰

Console



ACCESSIBILITÉ Faible

CATEGORIE GN.NAM

REF

Adam



Annotation

1 et sa felicité dans le paradis, dont la memoire s'est
2 conservée dans l'age d'or des poëtes ; le précepte
3 divin donné à nos premiers parens ; la malice de
4 l'esprit tentateur, et son apparition sous la forme
5 du serpent ; la chute d'**Adam** et d'Eve, funeste à
6 toute leur posterité ; le premier homme justement
7 puni dans tous ses enfans, et le genre humain maudit
8 de Dieu ; la premiere promesse de la rédemption, et
9 la victoire future des hommes sur le démon qui les
10 a perdus.

11 La terre commence à se remplir, et les crimes
12 s'augmentent. Caïn le premier enfant d'Adam et
13 d'Eve, fait voir au monde naissant la premiere action
14 tragique ; et la vertu commence dès lors à estre
15 persecutée par le vice. Là paroissent les moeurs
16 contraires des deux frères : l'innocence d'Abel, sa
17 vie pastorale, et ses offrandes agréables ; celles de
18 Caïn rejetées, son avarice, son impiété, son
19 narcicide et la jalouise mère des meurtres : le

Unit properties

The screenshot shows a digital annotation tool interface. At the top, there is a toolbar with various icons. Below the toolbar, the main content area displays two blocks of French text. A large bracket on the right side of the page spans both text blocks, indicating they are part of the same unit. At the bottom of the screen, there is a navigation bar with icons for back, forward, and search, along with a progress indicator showing '4 / 45'. Below the navigation bar, there are several search and filter fields. From left to right, these fields are: 'ACCESSIBILITÉ' set to 'Faible', 'CATEGORIE' set to 'GN.NAM', 'REF' (Reference) set to 'Adam', and another dropdown menu. Arrows from the 'Unit properties' section point to the 'CATEGORIE' field ('GN.NAM') and the 'REF' field ('Adam').

Concordancer

Calling all units coreferring to the same referent
= a view of a referring chain as a sequence of units

text_id	Contexte gauche	Pivot	Contexte droit
MontesquieuLois	, est, à certains égards,	le monarque	; à certains autres, il est le sujet.
MontesquieuLois	le sujet. Il ne peut être	monarque	que par ses suffrages qui sont ses volontés. L
MontesquieuLois	dans une monarchie de sçauoir quel est	le monarque	, et de quelle manière il doit gouverner. Liban
MontesquieuLois	le monarque, et de quelle manière	il	doit gouverner. Libanius dit que à Athènes un
MontesquieuLois	mieux dans la place publique, qu'	un monarque	dans son palais. Mais sçaura - t - il
MontesquieuLois	place publique, qu'un monarque dans	son	palais. Mais sçaura - t - il conduire une
MontesquieuLois	, les sujets sont à l'égard	du monarque	. On n'y doit point donner le suffrage par
MontesquieuLois	accommodeées ; le principe du gouvernement arrête	le monarque	; mais, dans une république où un citoyen se
MontesquieuLois	- à - dire de celui où	un seul	gouverne par des loix fondamentales. (j'ai dit
MontesquieuLois	en effet, dans la monarchie,	le prince	est la source de tout pouvoir politique et civil.
MontesquieuLois	dans la monarchie, le prince est	la source de tout pouvoir politique et civil	. Ces loix fondamentales supposent nécessair
MontesquieuLois	que la volonté momentanée et capricieuse d'	un seul	, rien ne peut être fixe, et par conséquent
MontesquieuLois	un bon sujet de défendre la justice	du prince,	ou les limites qu'elle s'est de tout temps
MontesquieuLois	où elles seroient ensevelies. Le conseil	du prince	n'est pas un dépôt convenable. Il est,
MontesquieuLois	, le dépôt de la volonté momentanée	du prince	qui exécute, et non pas le dépôt des loix
MontesquieuLois	dépôt de la volonté momentanée du prince	qui	exécute, et non pas le dépôt des loix fondame
MontesquieuLois	fondamentales. De plus, le conseil	du monarque	change sans cesse ; il n'est point permanent ;
MontesquieuLois	brigues pour être le premier esclave ;	le prince	seroit obligé de rentrer dans l'administration.
MontesquieuLois	aura d'abord la même puissance que	lui	. L'établissement d'un vizir est, dans cet
MontesquieuLois	, et plus, par conséquent,	le prince	est enivré de plaisirs. Ainsi, dans ces états
MontesquieuLois	Ainsi, dans ces états, plus	le prince	a de peuples à gouverner, moins il pense au
MontesquieuLois	s de peuples à gouverner, moins		gouvernement, plus les affaires

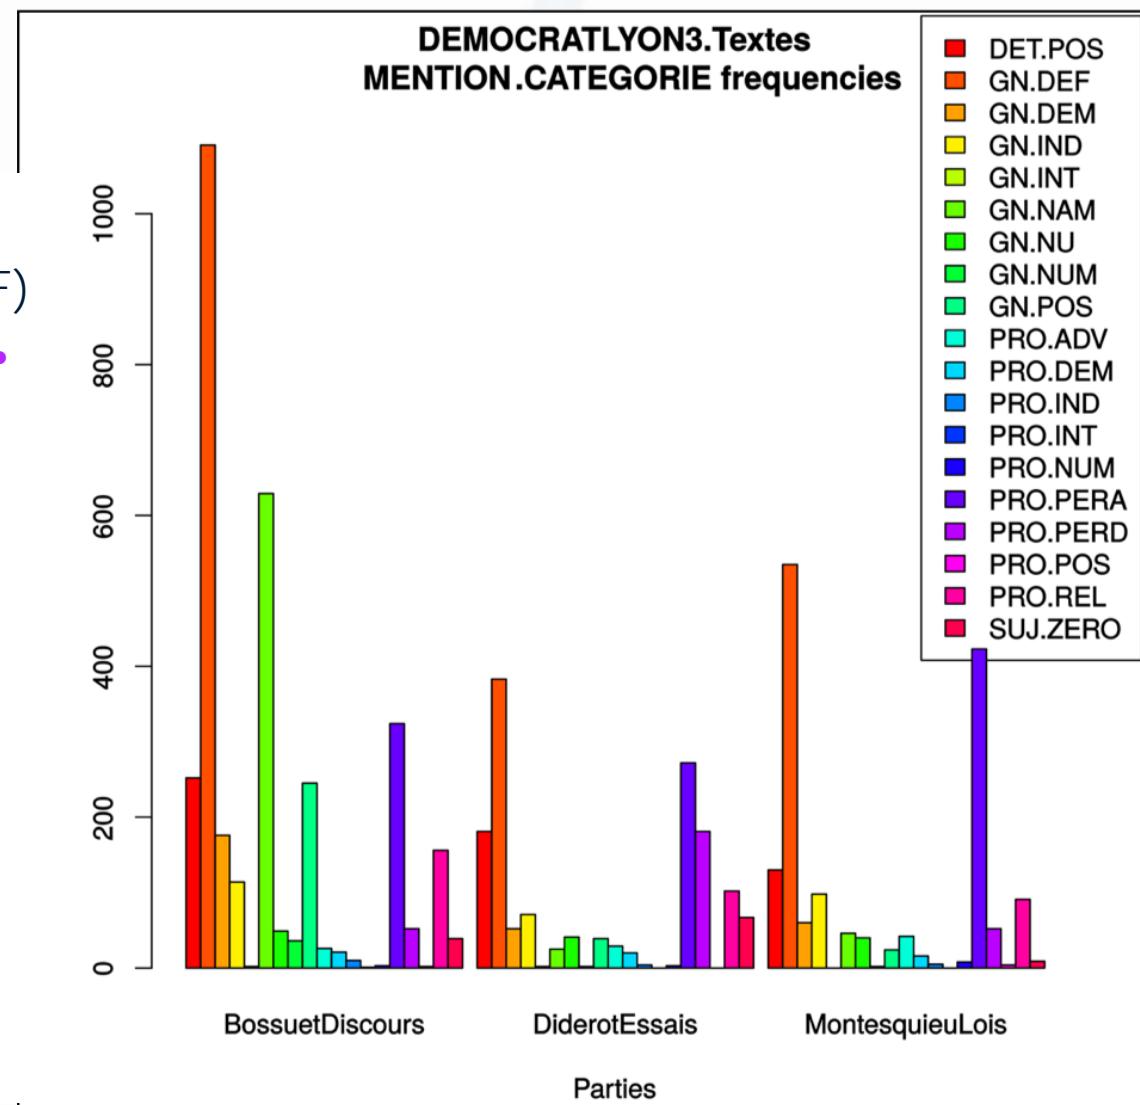
Concordancer

Calling all units coreferring to the same referent
= a view of a referring chain as a sequence of units

text_id	Contexte gauche	Pivot	Contexte droit
MontesquieuLois	, est, à certains égards,	le monarque	; à certains autres, il est le sujet.
MontesquieuLois	le sujet. Il ne peut être	monarque	que par ses suffrages qui sont ses volontés. L
MontesquieuLois	dans une monarchie de sçauoir quel est	le monarque	, et de quelle manière il doit gouverner. Liban
MontesquieuLois	le monarque, et de quelle manière	il	doit gouverner. Libanius dit que à Athènes un
MontesquieuLois	mieux dans la place publique, qu'	un monarque	dans son palais. Mais sçaura - t - il
MontesquieuLois	place publique, qu'un monarque dans	son	palais. Mais sçaura - t - il conduire une
MontesquieuLois	, les sujets sont à l'égard	du monarque	. On n'y doit point donner le suffrage par
MontesquieuLois	accommodeées ; le principe du gouvernement arrête	le monarque	; mais, dans une république où un citoyen se
MontesquieuLois	- à - dire de celui où	un seul	gouverne par des loix fondamentales. (j'ai dit
MontesquieuLois	en effet, dans la monarchie,	le prince	est la source de tout pouvoir politique et civil.
MontesquieuLois	dans la monarchie, le prince est	la source de tout pouvoir politique et civil	
MontesquieuLois	que la volonté momentanée et capricieuse d'	un seul	. Ces loix fondamentales supposent nécessair
MontesquieuLois	un bon sujet de défendre la justice	du prince,	, rien ne peut être fixe, et par conséquent
MontesquieuLois	où elles seroient ensevelies. Le conseil	du prince	ou les limites qu'elle s'est de tout temps
MontesquieuLois	, le dépôt de la volonté momentanée	du prince	n'est pas un dépôt convenable. Il est,
MontesquieuLois	dépôt de la volonté momentanée du prince	qui	qui exécute, et non pas le dépôt des loix
MontesquieuLois	fondamentales. De plus, le conseil	du monarque	exécute, et non pas le dépôt des loix fondame
MontesquieuLois	brigues pour être le premier esclave ;	le prince	change sans cesse ; il n'est point permanent ;
MontesquieuLois	aura d'abord la même puissance que	lui	seroit obligé de rentrer dans l'administration.
MontesquieuLois	, et plus, par conséquent,	le prince	. L'établissement d'un vizir est, dans cet
MontesquieuLois	Ainsi, dans ces états, plus	le prince	est enivré de plaisirs. Ainsi, dans ces états
MontesquieuLois	de peuples à gouverner, moins		a de peuples à gouverner, moins il pense au

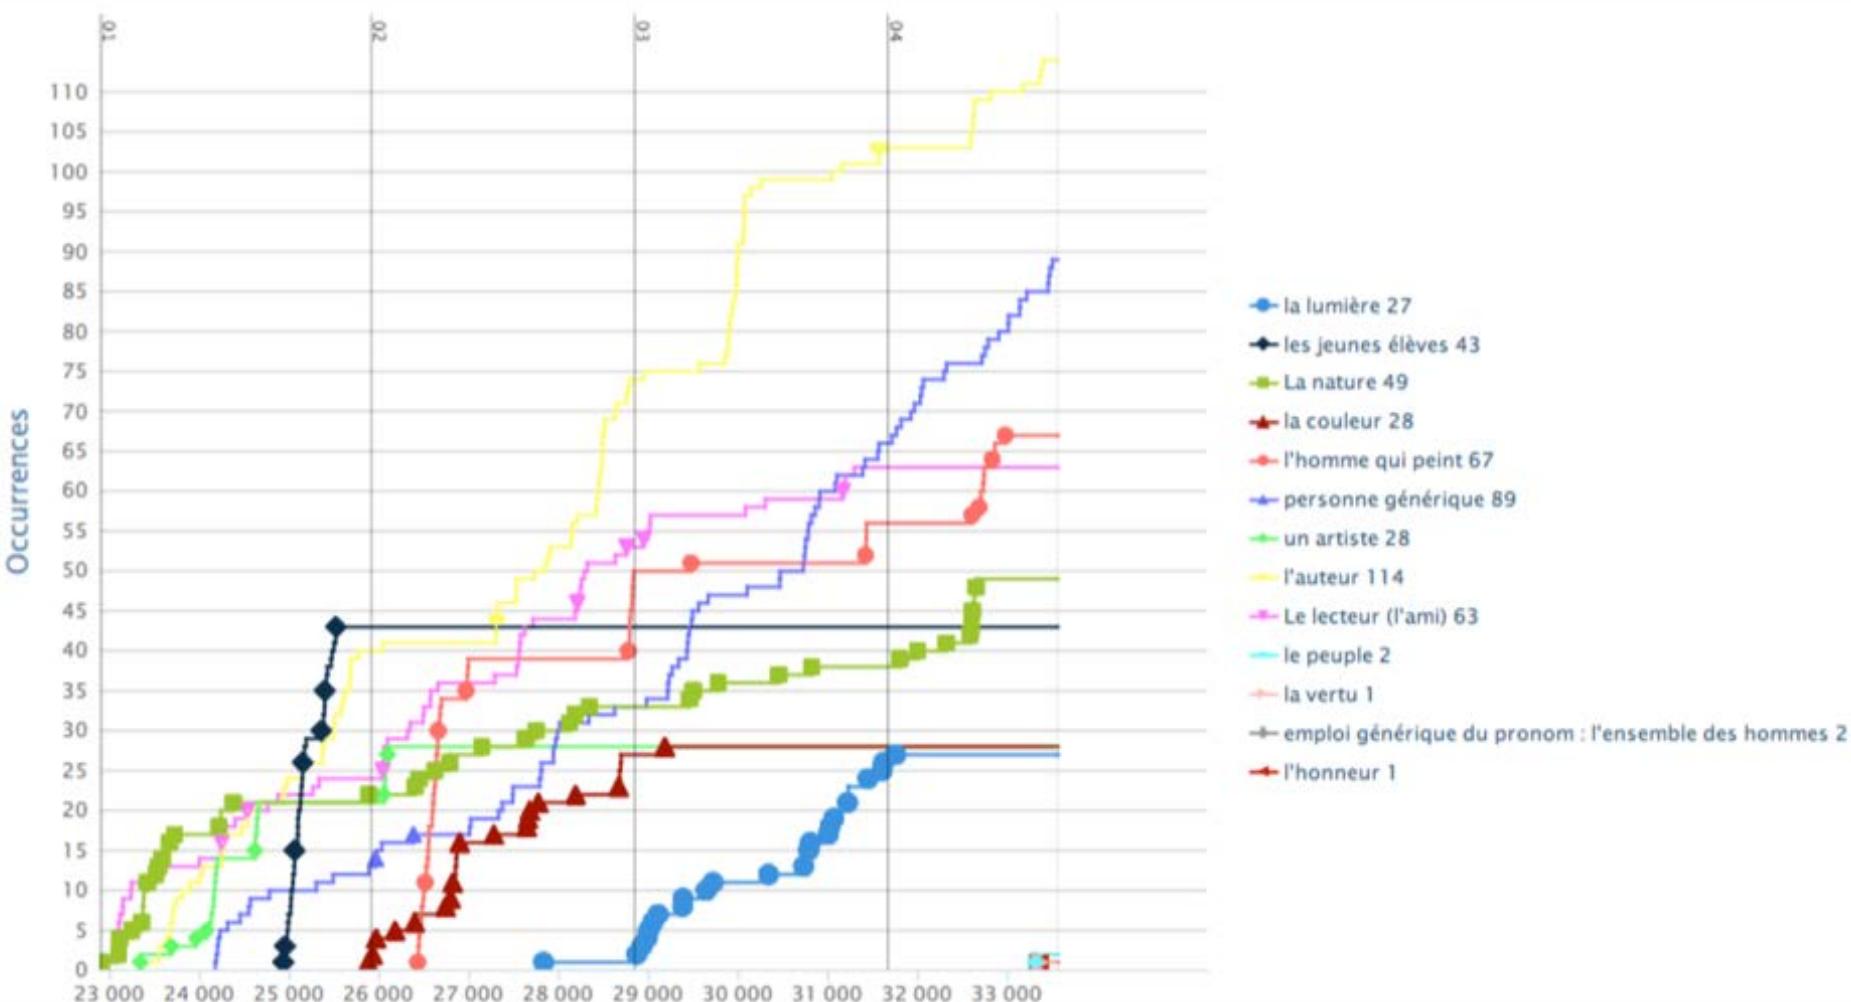
Histogram

- Common pattern
 - Definite NP • (GN.DEF)
 - Personal Pronouns • • (PRO.PERx)
 - Relative Pronouns (PRO.REL) •
- Pattern specific of Bossuet's Discourse
 - Lots of Proper Nouns (GN.NAM) •
 - NP with possessives (GN.POS) •



Progressions

= view of chains (schemata) throughout the corpus across chapters (textual units)



Summary

- URS annotation is now possible in TXM => complex annotation tasks such as semantic, reference tagging
- URS annotation can also be queried and checked via usual TXM tools
 - direct feedback on what we are currently doing
 - quality checking, consistency
- Undergoing work
 - develop groovy scripts for checking errors and inconsistencies
 - embed algorithms for intercoder reliability
 - at unit level (segmentation)
 - at schema level (referent identification)