

# Exploration de corpus

## Infos pratiques

---

- > ECTS : 3.0
- > Nombre d'heures : 24.0
- > Période de l'année : Enseignement quatrième semestre
- > Méthodes d'enseignement : En présence
- > Forme d'enseignement : Travaux dirigés
- > Ouvert aux étudiants en échange : Oui
- > Composante : Philo, Info-Comm, Langues, Littératures & Arts du spectacle
- > Code ELP : 4L4SC01P

## Présentation

---

Le cours s'attachera à présenter deux méthodes d'exploration de corpus. La première s'appuiera sur la notion d'automate telle qu'elle est mobilisée dans le domaine de la linguistique informatique. Nous utiliserons le logiciel Unitex, dont l'interface graphique permet de constituer et de maintenir des automates complexes. Trois objectifs seront alors visés : 1) apprendre à construire des ressources linguistiques sous la forme d'automates qui permettent à leur tour l'annotation de textes (en particulier, une annotation sémantique) ; 2) se confronter à la complexité de la modélisation linguistique que cette démarche implique ; 3) tester et étudier sur des corpus diversifiés ces ressources et en tirer des conclusions quant à leurs performances.

La seconde méthode d'exploration de corpus s'appuiera sur l'utilisation du logiciel, TXM, fondé sur des méthodes statistiques. Quatre objectifs seront alors visés : 1) produire des concordances à partir de recherches de motifs lexicaux complexes construits à partir des propriétés des mots ; 2) construire différents tableaux de contingence croisant les mots, les textes et leurs structures ; 3) calculer la liste des mots apparaissant de façon préférentielle dans les mêmes contextes qu'un motif lexical complexe (cooccurents statistiques).

## Objectifs

---

Il s'agit de donner à manipuler deux outils d'exploration de corpus (l'un symbolique, l'autre statistique) en offrant des repères méthodologiques.

## Évaluation

---

*M3C en 2 sessions*

\* *Régime standard session 1*

TD : La note est constituée d'au moins deux épreuves, dont une en temps limité.

\* *Régime dérogatoire session 1*

Une épreuve en temps limité donnant lieu à une seule note

\* *Session 2 dite de rattrapage*

Une épreuve en temps limité.

## Pré-requis nécessaires

---

Aucun

## Compétences visées

---

Savoir manipuler les outils d'exploration de corpus

## Bibliographie

---

Habert, Benoît. Portrait de linguiste(s) à l'instrument. *Texto!* [en ligne], décembre 2005, vol. X, n°4

Marandin, Jean-Marie, Cori, Marcel. La linguistique au contact de l'informatique : de la construction des grammaires aux grammaires de construction. *Histoire Épistémologie Langage*, 23-1, 2001, pp. 49-79

Poudat, Céline, Landragin Frédéric. Explorer un corpus textuel. De Boeck 2017

# Contact(s)

> **Delphine Battistelli**

Responsable pédagogique

[dbattist@parisnaterre.fr](mailto:dbattist@parisnaterre.fr)