

NLP with Python

Nom : **PICAULT**

Prénom : **Matthieu**

Année : **M2**

Semestre : **9**

Nature : **CM**

Volume horaire : **12 H**

ECTS / Coef : **2**

Prérequis

Introduction à Python (M1 ESA)
Installation de la suite Anaconda

Résumé

Ce cours se concentre sur le traitement des informations textuelles (articles de presse, réseaux sociaux, documents officiels, ...) et son utilisation dans les domaines de l'Economie et de la Finance.
Afin d'apprendre à extraire les informations importantes d'un texte, les étudiants s'appuient sur les principaux packages de Python en analyse textuelle comme *Nltk* et *Spacy* et travaillent à partir de cas pratiques.
L'évaluation s'appuie sur un projet de groupe.

Objectifs

L'objectif de ce cours est de permettre aux étudiants de :

- Manipuler des données textuelles (*string*).
- Isoler les éléments importants d'un texte en étudiant sa structure grammaticale (*Part-of-Speech tagging*)
- Calculer la complexité de documents au sein d'un corpus et mesurer la similarité entre les documents.
- Identifier les occurrences (*TF-IDF*) et les thèmes principaux d'un corpus de documents (*Latent Dirichlet Allocation*).
- Estimer le sentiment associé aux documents du corpus.
- Introduction à l'utilisation des Machine Learning supervisés aux données textuelles.

Bibliographie

- Bird, S., Klein, E., & Loper, E. (2009). *Natural language processing with Python: analyzing text with the natural language toolkit.* " O'Reilly Media, Inc.".
- Hardeniya, N., Perkins, J., Chopra, D., Joshi, N., & Mathur, I. (2016). *Natural language processing: python and NLTK*. Packt Publishing Ltd.
- Perkins, J. (2014). *Python 3 text processing with NLTK 3 cookbook*. Packt Publishing Ltd.
- Beysolow II, T. (2018). *Applied Natural Language Processing with Python: Implementing Machine Learning and Deep Learning Algorithms for Natural Language Processing*. Apress.
- Loughran, T., & McDonald, B. (2016). Textual analysis in accounting and finance: A survey. *Journal of Accounting Research*, 54(4), 1187-1230.

PLAN

Introduction: What is NLP and text analysis?

Section 1: Preparing a corpus and the NLP pipeline

Section 2: Similarity, complexity, and sentiment.

Section 3: Machine Learning using text as data

Section 4: Identifying the topics across a corpus using the LDA method.