

Évaluation d'un modèle générique endogène de calcul de termes

Introduction

On a réalisé un ensemble de scripts en python3 qui tente de distinguer les mots vides des mots pleins, afin de pouvoir détecter les termes répétés dans un document.

Vue d'ensemble des scripts

find_empty_words.py et find_repeated_terms.py sont des points d'entrée, ils gèrent les arguments de la ligne de commande grâce à argparse.py (inclut dans l'archive car non intégré à python3.1) et la lecture des fichiers via fileutils.py.

empty_words.py et terms.py sont les bibliothèques.

Étiquetage des mots vides

On a utilisé les hypothèses suivantes :

- un mot vide dans un contexte est vide dans tout contexte
- un mot vide a moins de 3 syllabes
- une frontière vP ou Pv est caractérisée par le fait que le mot vide est plus court et plus fréquent que son voisin mot plein

Observations

```
$ ./find_stop_words.py corpus/a/*/fr.html
fait leur en ses dont états été dans autres entre pas ce son comme
donc être au il unis et ont est par le quand leurs la avec vie
tout portail the bien sur deux nord aux même ils sous nom non
siècle centre de juifs très les que peut qui mars du voir ou fort
sont on qu sans ne cas of mais des cette liens air pour si un
plus une où ces sa se vers
```

L'étiquetage n'est pas très efficace sur le corpus choisi.

Recherche des termes

Il n'y a pas grand chose à dire, la seule astuce utilisée est la suppression des sous-termes. Par exemple « bob et alice » est un sous-terme de « bob et alice et george », on soustrait donc le nombre d'occurrences du second au premier et on supprime le sous-terme si son compteur arrive à zéro.

Observations

../corpus/a/History of evolutionary thought/fr.html
4 êtres vivants
3 sélection naturelle
3 théorie synthétique
3 évolution des espèces
2 caractères acquis
2 dimorphisme sexuel
2 découverte des mécanismes de l'hérédité
2 fixisme catastrophisme et gradualisme
2 idée d'évolution
2 mécanismes de l'hérédité
2 naissance de la théorie synthétique
2 origine des espèces
2 première fois
2 père de la taxinomie
2 révolution darwinienne
2 scala naturæ
2 théorie de la recapitulation
2 théorie depuis les années
2 théorie synthétique de l'évolution
2 théories au xviii
2 xix e siècle et la révolution darwinienne
2 xxe siècle la théorie synthétique
2 êtres vivants sous l'effet

Malgré le problème d'étiquetage, la recherche de termes est plus flexible et pertinente que la recherche par fenêtre glissante étudiée au TP1.

Pour une raison qui m'échappe, aucun terme n'est trouvé dans [corpus/a/Amelia Earhart/fr.html](#).