

Introduction à la statistique textuelle

Olivier Godechot

Pourquoi compter les mots ?

- Limite des enquêtes par questions fermées
 - La standardisation des réponses est une déformation
 - Alternative : questions ouvertes, entretiens, etc.
- Existence aujourd'hui de sources écrites numérisées de grande taille
 - Internet
 - Base de données de presse (lexis-nexis, europress)
 - Base de données de revue (etc.)
 - Œuvres complètes, etc.
- Limite de nos capacités de lecture analytique
 - Comment analyser des milliers de pages

Qu'est-ce que compter les mots ?

- On travaille sur des chaînes de caractères
 - Les chaînes de caractères semblables = mots semblables
 - Les chaînes de caractères dissemblables = mots différents
 - Ex: Événement différent de événement
- Pour repérer les mots, il faut repérer les séparateurs de mots :
 - Espace, signes de ponctuation, caractères spéciaux (sauts de paragraphe, de ligne, etc.)
- Choisir ou non de confondre majuscule et minuscule, voyelle avec accents et voyelle sans accents
- Regroupement de mots ou de chaînes de plusieurs mots
 - Segments de deux mots, de trois mots, etc.

Les unités de compte

- Statistiques → corrélation. Deux variables corrélées : Des individus répondent la même chose à plusieurs variables.
- Deux mots corrélés ? Définir un individu ou « unité de contexte élémentaire »
 - Un individu = une personne.
 - Adapté pour réponse courte à question ouverte
 - Pb si réponse longue. Corrélation entre deux mots si énoncés à 15 minutes d'intervalle.
 - Un individu = une phrase
 - Unité de contexte, relativement cohérente
 - Mais phrases de taille différente
 - Un individu = un paragraphe
 - Idem
 - Unité de taille fixe : 10 mots / 12 mots, etc.
 - Taille fixe
 - Pas forcément le même contexte

Comment compter ?

- L'effectif par unité de compte ...
- Ou la présence absence par unité ?

Quels mots compter ?

- Les mots les plus fréquents : Les mots outils...(de, le, et, ...)
- Les mots les plus singuliers : Les hapax ... en général, quelle que soit la taille du texte, 50% des formes graphiques
- Quels mots apportent le plus d'information ? les mots singuliers ou les mots les plus fréquents ?
- Tous les mots : ne rien rater vs beaucoup de mots n'apportent pas d'information. Quantité d'information trop importante
- Une sélection de mots qui ont du sens : information plus précise vs arbitraire de la sélection.

La lemmatisation

- Regroupement de forme lexicale sous un même lemme.
- Regroupement des pluriels et des singuliers, des conjugaisons et des déclinaisons d'un même mot.
- À la main vs automatique (dictionnaire)
- Risque d'erreur important : ex. bus → boire

Les limites de la statistique textuelle

- Le problème de l'homonymie
 - Ex : La petite brise la glace / Le boucher sale la coupe.
- Le problème de la polysémie
- Le problème de la synonymie
- Le problème de la modalisation
 - Formules négatives : travailler et ne pas travailler
 - Nuances
- Arbitraire des modalités de réponse fermées vs arbitraire des catégories du langage
- Le résultat : différence de contenu ou différente manière (sociale) de s'exprimer

Les traitements statistiques sur les mots

- Pas de spécificité statistique – seulement des affinités. On a juste des variables qui sont des mots.
- L'analyse des données
 - Analyse factorielle / Analyse de correspondance multiple
 - Classification ascendante hiérarchique
- La régression
- Les analyses en termes de distance lexicale

Les usages

- Bons résultats : Questions ouvertes dont les réponses sont standardisées et stéréotypées
- Résultats discutables : Entretiens, si texte très différent.
- Les alternatives
 - La lecture simple (utilisation de toute l'information, difficulté à accéder aux phénomènes de nombre, pas d'aspect systématique)
 - Le codage exhaustif (très bon résultats, coûts)
- Les hybridations.
 - Outil possible en complément d'autres techniques
 - Outil élémentaire pour un codage
 - Outil confirmatoire de la lecture simple

Les logiciels disponibles

- Mes macros pour SAS
- Spad-t et spad
- Alceste
- Hyperbase
- Prospero