

Statistiques sur les termes

Soit un document d :

- constitué de K mots $d[1], \dots, d[i], \dots$
- appartenant au vocabulaire $V = \{t_1, \dots, t_m\}$ constitué de m termes.

Fréquence d'un terme t :

Soit $t \in V$ un terme de vocabulaire. On note $P(X=t)$ la fréquence d'apparition de ce terme *dans le langage* \mathcal{L} considéré, soit~: $P(X=t) = \frac{|\{\omega \in \Omega : X=\omega=t\}|}{|\Omega|}$ où Ω représente l'ensemble des productions de termes.

On a par définition~: $\sum_{t \in A} P(X=t) = 1$

La fréquence empirique du symbole t dans le document d est donnée par~:



$$f_d(t) = \frac{|\{i: d[i] = t\}|}{|d|}$$

où $|d|$ est le nombre de mots dans le document.

Corpus de documents

Soit B un corpus de documents, constitué de n documents.



La fréquence empirique du terme t dans le corpus B est donnée par~: $f_B(t) = \frac{|\{(i,j): d_i \in B, d_i[j] = t\}|}{|B|}$ où $|B|$ est le nombre total de mots dans le corpus.

Fréquence locale :

Le fréquence empirique *locale* $f_{B,d}(t)$ est donnée par : $f_{B,d}(t) = p(X=t|Y=d) = \frac{|\{j: d \in B, d[j] = t\}|}{|d|}$ où $|d|$ est le nombre de mots dans le document d .

Fréquence documentaire

On appelle **fréquence documentaire** $g(t)$ d'un terme t la fréquence d'apparition du terme dans les différents documents de la base :

$$g(t) = p(t \in d)$$

Fréquence documentaire empirique :

$g(t) = \frac{|\{d:t \in d\}|}{|B|}$ avec:

- $n = |B|$: nombre de documents
- $|\{d:t \in d\}|$: nombre de documents contenant t

Information documentaire

$I(t) = -\log_2 g(t)$

- $I(t) = 0 \Rightarrow$ aucune information documentaire.

Ainsi, les termes apportant I bits d'information permettent de réaliser I partitions de la base (pour extraire des sous-ensembles de taille $|B| / 2^I$)

On remarque que :

- si le terme est présent dans tous les documents, son information documentaire est nulle.
- si le terme est présent dans un seul document, son information documentaire est maximale

On peut de même calculer l'**entropie (documentaire) croisée** de la base comme $E(I(t))$: $H(B) = -E(\log_2 p(t \in d)) = -\sum_{t \in V} p(t) \log_2 p(t \in d)$ où $p(t)$ représente la probabilité d'apparition du terme t sur tous les documents de la base.

On note $h(t)$ la **contribution documentaire** du terme t : $h(t) = -p(t) \log_2 p(t \in d)$

On calcule de même l'**entropie conditionnelle** d'un document d comme $E(I(t) | d)$: $H(d) = -E(\log_2 p(t \in d) | d) = -\sum_{t \in V} p(t|d) \log_2 p(t \in d) = -\sum_{t \in d} p(t|d) \log_2 p(t \in d)$

On note $h(t|d)$ la **contribution documentaire conditionnelle** du terme t dans le document d : $h(t|d) = -p(t|d) \log_2 p(t \in d)$

Cette contribution est également appelée : **TF-IDF** ("Term frequency - Inverse document frequency")

From:
<https://wiki.centrale-med.fr/informatique/> - WiKi informatique

Permanent link:
https://wiki.centrale-med.fr/informatique/public:algo-txt:statistiques_sur_les_termes

Last update: **2020/04/20 17:27**

