Statistiques sur les termes

Soit un document d :

- constitué de K mots $d[1]$, ..., $d[i]$, ...
- appartenant au vocabulaire $V = \{t_1,...,t_m\}$ 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~: $$P(X=t) = \frac{|\omega \in \Omega : X=t|}{|\Omega|}$$ 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* $f_B(t,d)$ est donnée par : $$f_B(t,d) = p(X=t|Y=d) = p(t|d)$$ $$f_B(t,d) = \frac{|\{j:d \in B,d[j] = t\}|}{|d|} $$ 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 :

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

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

Information documentaire

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

- $I(t) = 0$ ⇒ 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")