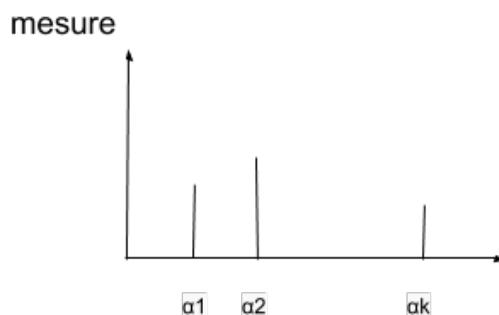


3. Statistiques sur les textes

Soit un document d :

- constitué de T symboles $d[1], \dots, d[i], \dots$
- appartenant à l'alphabet $A = \{\alpha_1, \dots, \alpha_K\}$ constitué de K symboles.

Une description statistique d'un texte correspond à un histogramme qui porte sur un ensemble de symboles :



Grâce à ces mesures, on souhaite pouvoir comparer 2 textes : d_1 et d_2 . On veut trouver les distances / similarités basée sur cette mesure

- l'ordre des symboles ou des termes est ignoré
- le sens du texte est ignoré

on utilise la théorie de l'information

- information
- divergence KL
- Entropie, entropie croisée



Modèles probabiliste : la suite de symbole observés (le message) est générée par un



processus aléatoire: $d = (d_1, d_2, \dots, d_T)$

- chaque d_i est la réalisation d'un tirage aléatoire
- obéissant à une distribution de probabilité p

Les symboles sont au choix :



- des caractères appartenant à un alphabet
- des termes appartenant à un vocabulaire

3.1 Modèles probabilistes

Les modèles probabilistes interprètent les données de type texte comme étant générées par une distribution de probabilité P inconnue.

La distribution P définit le langage utilisé dans le texte. On ne s'intéresse pas au sens du message, on regarde seulement comment les symboles se répartissent dans les documents, leurs fréquences d'apparition, les régularités, ...

Fréquence d'un symbole

Soit $\alpha \in A$ un symbole de l'alphabet. On note $P(X=\alpha)$ la fréquence d'apparition de ce symbole dans le langage \mathcal{L} considéré, soit $\sum_{\alpha \in \Omega} P(X=\alpha) = 1$ où Ω représente l'ensemble des productions de caractères.

On a par définition $\sum_{\alpha \in V} P(X=\alpha) = 1$

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



$$f_d(\alpha) = \frac{\sum_{i=1}^{|d|} I(d[i] = \alpha)}{|d|}$$

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



Fréquence des lettres en français

- Voir aussi : [Analyse Fréquentielle sur Wikipedia](#)

Représentation vectorielle

On suppose que les caractères d'un langage \mathcal{L} donné sont numérotés de 1 à K , soit $A_{\mathcal{L}} = \{\alpha_1, \dots, \alpha_k, \dots, \alpha_K\}$.

On notera \boldsymbol{p} le vecteur des fréquences des caractères dans un langage donné, où $p_L(k)$ donne la fréquence du $k^{\text{ème}}$ caractère.

Exemple: $\boldsymbol{p}_{\text{Français}} = (0.0942, 0.0102, 0.0264, 0.0339, 0.01587, 0.095, 0.0104, 0.0077, 0.0841, 0.0089, \dots)$ où



- $p_1 = 0.0942$ est la fréquence de la lettre 'A'
- $p_2 = 0.0102$ est la fréquence d'apparition de la lettre 'B'
- etc.

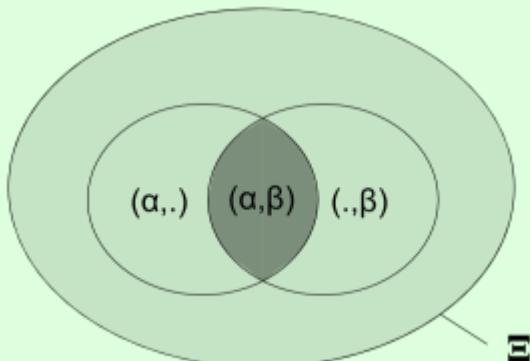
avec bien sûr : $\sum_{k \in \{1, \dots, K\}} p_L(k) = 1$

Probabilité jointe

On s'intéresse maintenant aux fréquence d'apparition de couples de lettres successives.

Soient α et β deux symboles de l'alphabet.

La probabilité jointe est définie comme : $P(X=\alpha, Y=\beta) = \frac{|\{x_i \in X : (X,Y)=(\alpha,\beta)\}|}{|X|}$ où X est l'ensemble des productions de couples de caractères.



avec par définition: $\sum_{(\alpha, \beta) \in A \times A} P(X=\alpha, Y=\beta) = 1$

La **probabilité jointe empirique** est donnée par~:



$$f_d(\alpha, \beta) = \frac{|\{i : d[i] = \alpha, d[i+1] = \beta\}|}{d-1}$$

- Les séquences de deux caractères sont classiquement appelées des *bigrammes*.
- On définit de même les *trigrammes* comme les séquences de trois caractères
- etc.

Représentation matricielle

On notera $\boldsymbol{P}_{\mathcal{L}}$ la matrice des fréquences des bigrammes dans un langage \mathcal{L} donné, où P_{ij} donne la fréquence du bigramme (α_i, α_j) .

Exemple: $\boldsymbol{P}_{\text{Français}} = 10^{-5} \times \left(\begin{array}{cccc} 1.5 & 116.8 & 199.1 & \dots \\ 62.8 & 1.6 & 0.14 & \dots \\ 184.8 & 0 & 52.4 & \dots \end{array} \right)$

où



- $P_{11} = 1.5 \times 10^{-5}$ est la fréquence du bigramme 'AA',
- $P_{12} = 116.8 \times 10^{-5}$ est la fréquence d'apparition du bigramme 'AB'
- etc.

avec bien sûr : $\sum_{(i,j) \in \{1, \dots, K\}^2} P_{ij} = 1$



voir comptage des bigrammes en français

Corpus de documents

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

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

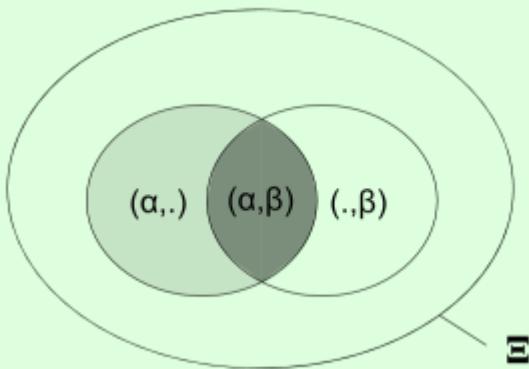


La fréquence jointe du couple (α, β) est donnée par $f_B(\alpha, \beta) = \frac{|\{(i,j) : d_i \in B, (d_i[j], d_i[j+1]) = (\alpha, \beta)\}|}{|B|-n}$

Probabilité conditionnelle

La **probabilité conditionnelle** du caractère β étant donné le caractère précédent α est définie comme :

$$P(Y = \beta | X = \alpha) = \frac{|\{x_i \in X : (X, Y) = (\alpha, \beta)\}|}{|\{x_i \in X : X = \alpha\}|}$$



qui se calcule empiriquement comme :

$$\$f_d(\beta | \alpha) = \frac{|\{i : d[i] = \alpha, d[i+1] = \beta\}|}{|\{j : d[j] = \alpha\}|} \$$$

- La probabilité $P(.|\alpha_i)$ se représente sous forme vectorielle~: $\boldsymbol{\mu}_i = (P(\alpha_1|\alpha_i), P(\alpha_2|\alpha_i), \dots)$ où α_1 est le premier caractère de l'alphabet, α_2 le deuxième etc, avec $\sum_j \boldsymbol{\mu}_{ij} = 1$
- L'ensemble des probabilités conditionnelles $P(.|.)$ peut se représenter sous une forme matricielle~:



$$\$ \begin{array}{c} M \leftarrow \left(\begin{array}{cccc} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \\ \dots \end{array} \right) \\ P(\alpha_1|\alpha_1) & P(\alpha_2|\alpha_1) & P(\alpha_3|\alpha_1) & \dots \\ P(\alpha_1|\alpha_2) & P(\alpha_2|\alpha_2) & P(\alpha_3|\alpha_2) & \dots \end{array} \$$$

Sachant que $P(\alpha) = \sum_{\beta \in A} P(\alpha, \beta)$, on a : $\boldsymbol{\mu}_i = \frac{P_{i,:}}{\sum_j P_{i,j}}$

Soit en français :

$$\$ M_{\text{Français}} = \left(\begin{array}{cccc} 0.0016 & 0.0124 & 0.0211 & \dots \\ 0.0615 & 0.0016 & 0.0001 & \dots \\ 0.0700 & 0.0000 & 0.0198 & \dots \end{array} \right) \$$$

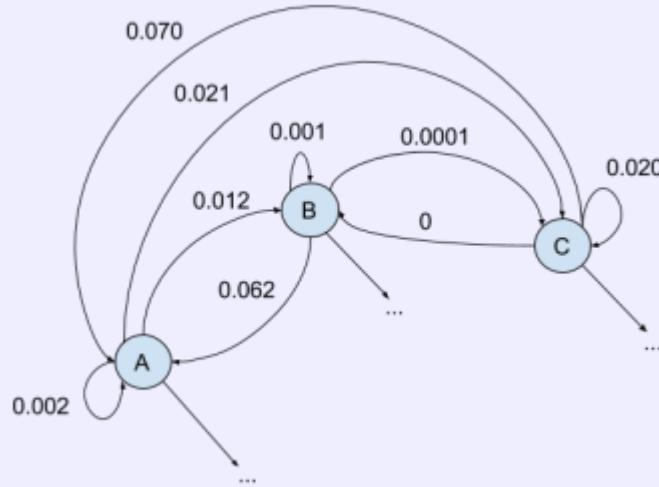


- M_{11} est la probabilité de voir un 'A' suivre un 'A'
- M_{12} est la probabilité de voir un 'B' suivre un 'A'
- etc.



La matrice des probabilités conditionnelles M permet de définir un **modèle génératif** de langage inspiré des **processus aléatoires de Markov**:

- La production d'un mot ou d'un texte est modélisée comme un parcours aléatoire sur une chaîne de Markov définie par la matrice de transitions M .
- La fréquence d'apparition des lettres est modélisée comme la mesure stationnaire de la chaîne de Markov, autrement dit le vecteur de probabilité vérifiant : $\boldsymbol{p} = \boldsymbol{p} M$



3.2 Comparer des documents

On considère deux langues \mathcal{L}_1 et \mathcal{L}_2 utilisant le même alphabet. La différence de fréquence des caractères dans ces deux langages permet de les distinguer. Il est ainsi possible de définir une distance entre deux langages basée sur les histogrammes de fréquence empirique des caractères dans les deux langages.

L'information apportée par la lecture du symbole α est définie comme : $I(\alpha) = -\log_2(P(X = \alpha))$ où $p_\alpha = P(X = \alpha)$ est la fréquence d'apparition de ce symbole dans la langue considérée.

L'information est une mesure de la "surprise" provoquée par l'apparition du symbole α . Si le symbole α est "rare" (p_α petit), l'information qu'il apporte est élevée. Si le symbole est fréquent, l'information qu'il apporte est faible.

Entropie

L'entropie d'une langue est définie comme l'espérance de l'information apportée par un caractère. $H(\mathcal{L}) = E_X(I(X)) = -E_X(\log_2(P(X)))$ i.e. $H(\mathcal{L}) = - \sum_{k \in \{1, \dots, K\}} P(X = \alpha_k) \log_2(P(X = \alpha_k))$



L'entropie représente la surprise moyenne provoquée par une production de symboles. Une entropie faible indique que la séquence est très prévisible, une



entropie élevée indique une séquence très imprévisible.



L'entropie d'un message m de taille T , selon le modèle de langage \mathcal{L} donné, est définie comme : $H(m) = E(I(m[t])) = -E(\log_2(p_{\mathcal{L}}(m[t])))$ i.e. $H(m) = - \frac{1}{T} \sum_t \log_2(p_{\mathcal{L}}(m[t]))$

Exos :



- pour quels types de distribution l'entropie est-elle minimale? maximale?
- quelle est l'entropie d'un message dont les probas d'apparition des termes obéissent à une loi de puissance :

$$C = \frac{1}{\sum_k} \sum_k \frac{1}{k} p(\alpha_k) = \frac{C}{k}$$

Divergence de Kullback-Leibler

Pour comparer deux langues \mathcal{L}_1 et \mathcal{L}_2 , on peut utiliser la *divergence de Kullback-Leibler* définie comme l'espérance de la différence des informations apportées par un même symbole:

$$D(\mathcal{L}_1 || \mathcal{L}_2) = \sum_k P_1(X = \alpha_k) \log_2 \left(\frac{P_1(X = \alpha_k)}{P_2(X = \alpha_k)} \right)$$

où P_1 désigne la distribution des symboles du langage \mathcal{L}_1 et P_2 la distribution des symboles du langage \mathcal{L}_2 .



- La divergence de K-L est positive.
- Elle vaut 0 si les deux distributions sont identiques.

Comparer 2 messages

Soient d_1 et d_2 deux textes pour lesquels on a calculé les histogramme des fréquences empiriques: f_1 et f_2 .

La divergence empirique de Kullback Leibler est une mesure de dissimilarité (l'inverse d'une similarité) qui estime combien d_1 diffère de d_2 $D(d_1 || d_2) = \sum_{\alpha} f_1(\alpha) \log_2 \left(\frac{f_1(\alpha)}{f_2(\alpha)} \right)$

Classer des messages

Il arrive que l'on ne sache pas à l'avance si une suite de symboles $m[1], \dots, m[T]$ est générée par le

langage \mathcal{L}_1 (dont les symboles obéissent à la distribution p_1) ou le langage \mathcal{L}_2 (dont les symboles obéissent à la distribution p_2).

Soit f la fréquence empirique des symboles de m .

Si m est produit par \mathcal{L}_1 , on devrait avoir : $D(f||p_1) < D(f||p_2)$ soit $\sum_{\alpha \in d} f(\alpha) \log_2 \left(\frac{f(\alpha)}{p_1(\alpha)} \right) < \sum_{\alpha \in d} f(\alpha) \log_2 \left(\frac{f(\alpha)}{p_2(\alpha)} \right)$ soit : $\sum_{\alpha \in d} f(\alpha) \log_2 \left(\frac{p_1(\alpha)}{p_2(\alpha)} \right) > 0$



Soit m un message de taille T . Pour savoir si le message appartient au langage \mathcal{L}_1 ou au langage \mathcal{L}_2 , on calcule: $\text{Test} = \frac{1}{T} \sum_t \log_2 \left(\frac{p_1(m[t])}{p_2(m[t])} \right)$

- Si $\text{Test} > 0$, il est plus probable que m obéisse au langage \mathcal{L}_1
- Si $\text{Test} < 0$, il est plus probable que m obéisse au langage \mathcal{L}_2

On peut ainsi produire un classifieur basé sur les modèles probabilistes p_1 et p_2 .

Utilisation :

- Deviner la langue d'un document
- Distinguer les messages frauduleux des messages courants
- etc.

From:

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



Permanent link:

<https://wiki.centrale-med.fr/informatique/restricted:cm2>

Last update: **2020/04/27 10:44**