
Modèle de langage en RI

1

Modèle de langage

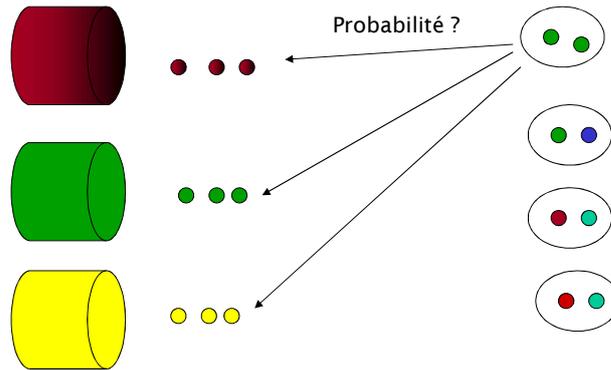
- Modèles de langues (ou de langages) tentent de modéliser « l'agencement de mots dans une langue »
- Exemple introductif
 - En Sibérie, il fait
 - In
- Probabilité de distribution de mots (une séquence de mots) dans un texte
 - Probabilité d'une séquence de mots dans une « langue » donnée.
 - $p_1=P$ (Dans ce cours nous allons étudier le modèle de langues)
- Notation
 - M la langue (le langage)
 - s une séquence
 - $P(s/M)$: probabilité d'observer s dans M

2

Métaphore

Source (génération de boules)

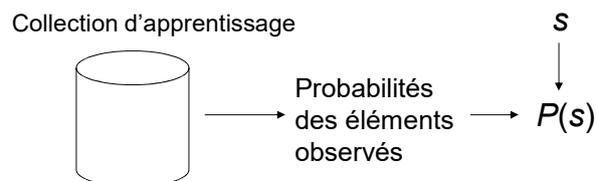
Quelle est la source qui a généré ces boules ?



3

Modèle de langage

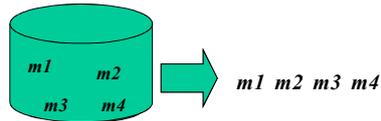
- Définition :
 - Un modèle de langage désigne une fonction de probabilité qui assigne une probabilité à une séquence de mots dans une langue.
 - Ce calcul se fait sur un corpus d'apprentissage



4

Probabilité d'une séquence

- D'une façon générale, la probabilité de générer une séquence donnée est mesurée comme suit

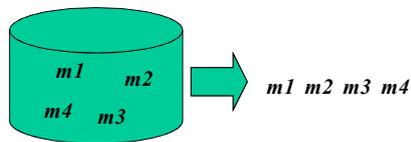


$$P(m1 m2 m3 m4) = P(m1) \times P(m2/m1) \times P(m3/m1 m2) \times P(m4/m3 m2 m1)$$

5

Probabilité d'une séquence (suite)

- Si les événements sont indépendants



$$P(m1 m2 m3 m4) = P(m1) \times P(m2) \times P(m3) \times P(m4)$$

6

Probabilité d'une séquence (suite)

Généralisation

- Modèle n-grammes (n séquence de mots ou caractères)

$$p(m_1, m_2, \dots, m_l) = \prod_{i=1}^l P(m_i | m_1 \dots m_{i-1})$$

- Uni-gramme $P(s) = \prod_{i=1}^l P(m_i)$

- Bi-grammes $P(s) = \prod_{i=1}^l P(m_i | m_{i-1}) = \prod_{i=1}^l \frac{P(m_{i-1}, m_i)}{P(m_{i-1})}$

- N-grammes $P(s) = \prod_{i=1}^l P(m_i | m_1 \dots m_{i-1})$

7

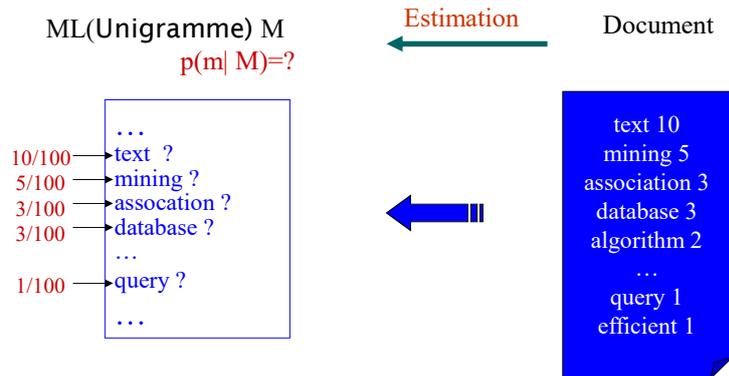
Estimation des probabilités

- Problème
 - Soit une séquence S, estimer son modèle de langage MS
- Modèle de langage de base
 - Maximum de vraisemblance

8

Maximum de vraisemblance (Maximum-likelihood)

- Compter la fréquence relative des mots m :
 - $P_{ml}(m|M) = \#(m) / N$



Un article sur le "text mining"
(total #mots=100)

9

Problème des fréquences Zéro

- Si un événement (un mot) n'apparaît pas dans la séquence
 - Le modèle va assigner la probabilité 0 à l'événement

$$P(s) = \prod_{i=1}^l P(m_i) = 0, \quad \text{si } \exists m_i / p(m_i / M) = 0$$

- Solution : assigner des probabilités différentes de zéro à de tels mots

10

Problème des fréquences Zéro (suite)

- Contraintes :
 - On ne peut pas assigner des valeurs différentes de zéro de manière aléatoire
 - La somme des probabilités de l'ensemble des événements doit être égale à 1.
 - Plusieurs solutions

Techniques de lissage

11

Techniques de lissage

- Méthodes de « discounting »
 - Laplace correction, Lindstone correction, absolute discounting, leavet one-out discounting, Good-Turing method
- Techniques d'Interpolation
 - Estimations de Jelinek-Mercer, Dirichlet

12

Méthodes de « discounting »

- Ajouter une constante (1, 0,5 ou ϵ) à toutes les fréquences

- Laplace smoothing

- Ajouter un à tous les événements (n-gram : s)

$$P_{add_one}(s | M) = \frac{|s| + 1}{\sum_{s_i \in V} (|s_i| + 1)}$$

- Lindstone Smoothing:

- Ajouter ϵ puis normaliser

13

Méthodes de « discounting »

- **Dans MLE**, $P(s|M) = \#(s) / N$

Avec : s = un n-gramme

$\#(s)$ = la fréquence de s. (problème avec $\#(s) = 0$)

N = somme des fréquences des n-grammes

- **Good-Turing** : change la fréquence de s en

$$\#(s)^* = (\#(s) + 1) \frac{n_{s+1}}{n_s}$$

Avec: $\#(s)$ = la fréquence de s

n_s = nombre de n-grammes de fréquence $\#(s)$

n_{s+1} = nombre de n-grammes de fréquence $\#(s) + 1$

n_0 = nombre total des n-grammes

Problème : tf^* peut être zéro s'il n'y a pas de n-grammes de fréquence $(\#(s) + 1)$

14

-
- Soit $s = \langle \text{text mining information} \rangle$ et soit le document suivant

text 10
mining 5
association 3
database 3
algorithm 2
query 1
efficient 1

Calculer $p(s|D)$ avec :

1/ MLE

2/ Laplace smoothing (add_one)

3/ Good-Turing

15

Lissage par interpolation

- Les méthodes de « discounting » traitent les mots qui n'apparaissent pas dans le corpus de la même manière. Or, il y a des mots qui peuvent être plus fréquents que d'autres
- Solution
 - Construire un modèle mixte : combiner deux modèles

16

Lissage par interpolation (suite)

- Interpolation (Jelinek-Mercer)
 - Combiner le modèle M , avec un modèle plus général

$$\lambda \cdot \text{[cylinder]} + (1-\lambda) \cdot \text{[cylinder]} \quad \text{© james allan}$$

- Pb. “Règlage” de λ

$$P_{JM}(w_i | M) = \lambda \cdot \overset{\text{Dans le document}}{P_{ML}(w_i | M)} + (1-\lambda) \cdot \overset{\text{Dans le corpus}}{P_{JM}(w_i)}$$

17

Lissage par interpolation (suite)

- Lissage de Dirichlet
 - Problème avec Jelinek-Mercer
 - Les documents long seront privilégiés
 - Prendre en compte la taille de l'échantillon
 - Si N est la taille de l'échantillon et μ une constante

$$\underbrace{\frac{N}{N+\mu}}_{\lambda} \cdot \text{[cylinder]} + \underbrace{\frac{\mu}{N+\mu}}_{(1-\lambda)} \cdot \text{[cylinder]} \quad \text{© james allan}$$

$$P_{Dir}(w_i | M) = \left(\frac{N}{N+\mu}\right) \cdot P_{ML}(w_i | M) + \left(\frac{\mu}{N+\mu}\right) P_{Dir}(w_i)$$

18

Lissage par interpolation (suite)

- Lissage de Dirichlet (ex transp. 9)

$$P_{Dir}(w_i | d) = \frac{|d|}{|d| + \mu} \times \frac{tf(w_i, d)}{|d|} + \frac{|\mu|}{|d| + \mu} P_{ML}(w_i | C)$$

$$P_{Dir}(w_i | d) = \frac{tf(w_i, d) + \mu P_{ML}(w_i | C)}{|d| + \mu}$$

d: un document

C: le corpus (collection)

μ est une constante par exemple $\frac{1}{2}$

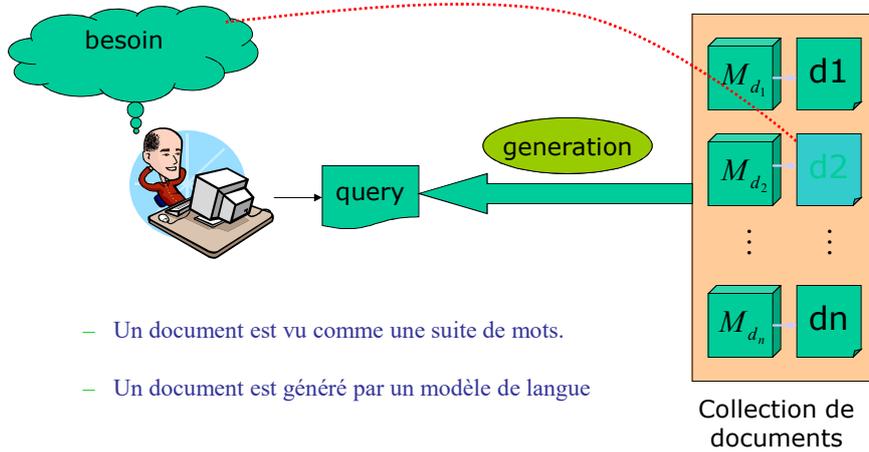
19

Modèle de Langage en RI

Plusieurs modèles, plusieurs adaptations

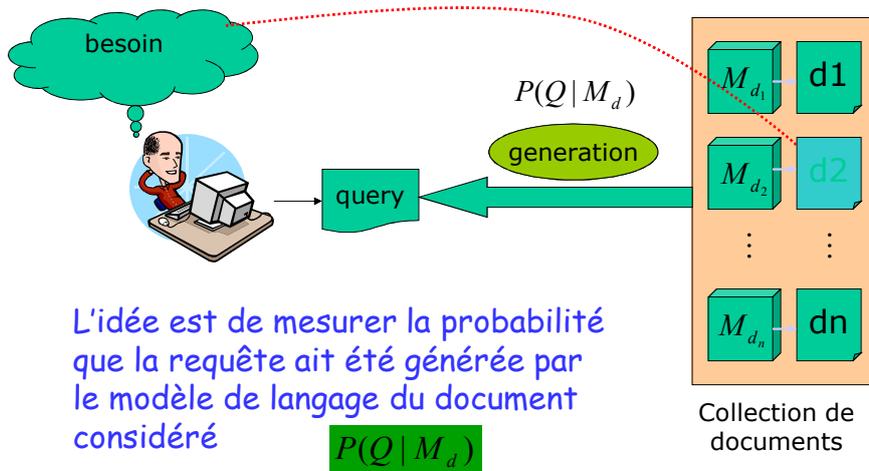
20

RI basée sur les ML



21

..... et la RI là dedans



22

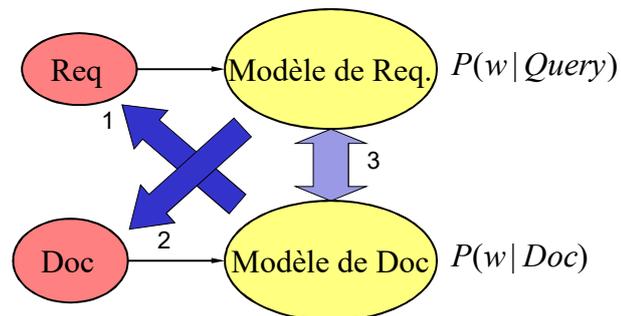
Comment estimer $P(Q/M_D)$

- Le modèle de langage est inconnu
 - Mais, nous avons un échantillon : le document,
 - Estimer le modèle de langage à partir de cet échantillon

23

ML en RI

- Il existe plusieurs manières d'adapter les ML à la RI.



- 3 Principes :
- Probabilité de générer la requête à partir de Md (1),
 - Probabilité de générer le document à partir de Mq (2),
 - Combinaison (comparaison) des deux modèles(3)

24

ML en RI (suite)

- Principe 1: (principe standard) : génération de la requête par le document
 - $RSV(D,Q) = P(Q|M_D)$
 - Document D: représenté par son ML $P(w|M_D)$
 - Requête Q = séquence de mots q_1, q_2, \dots, q_n
- Principe 2 : génération du document par la requête
 - $RSV(D,Q) = P(D|M_Q)$
 - Requête Q: représentée par son ML $P(w|M_Q)$
 - Document D = séquence de mots
- Principe 3: ratio de vraisemblance (comparaison de modèles)
 - Document D: LM $P(w|M_D)$
 - Requête Q: LM $P(w|M_Q)$
 - $RSV(Q,D)$: comparaison entre $P(w|M_D)$ and $P(w|M_Q)$

25

Principe 1 : Génération de la requête par le document

- Chaque document est traité comme un modèle de langage
- Estimer le modèle de langage M_d de chaque document
- Classer les documents par leur probabilité de générer la requête

$$P(Q / M_D) = \prod_{t \in Q} P(t / M_D)$$

26

Principe 1 : génération de la requête par le document (suite)

- La probabilité de générer la requête sachant un modèle de langage du document d avec MLE est:

$$p(Q | M_d) = \prod_{t \in Q} p_{ml}(t | M_d)$$
$$= \prod_{t \in Q} \frac{tf_{(t,d)}}{dl_d}$$

Les termes de la requête sont générés de manière indépendantes

M_d : modèle de langage du document d

$tf_{(t,d)}$: fréquence d'un terme dans d

dl_d : nombre total de termes dans d

27

Approche1 : Problème avec l'Est. Max. Vrai. (MLE)

- Problème des $tf = 0$: quand un document ne contient pas un ou plusieurs termes de la requête.
- Utiliser les techniques de lissage : le modèle mixte
 - Combiner le modèle de langage de document et le modèle de langage de la collection
 - Le modèle de collection est utilisé comme un modèle de référence pour les mots non observés dans le document (lissage JM)

$$p(Q, d) = \lambda p_{mle}(Q | M_d) + (1 - \lambda) p(Q | M_c)$$

28

Approche 1 : Modèle mixte de base

- Formulation générale

$$RSV(Q, d) = \prod_{t \in Q} ((1 - \lambda)p(t | M_c) + \lambda p(t | M_d))$$

Modèle général (collection)

Modèle de document

$$p(t | M_c) = p(t) = \frac{\text{total_tf}_t}{\text{total_tf_col}}$$

total_tf_t : fréquence du terme dans la collection
total_tf : collection : nombre total de termes dans la collection

29

Exemple

- (2 documents)
 - d₁: Xerox reports a profit but revenue is down
 - d₂: Lucent narrows quarter loss but revenue decreases further
- Requête: *revenue down*
- MLE unigram;
 - Lissage JM $\lambda = \frac{1}{2}$
 - Lissage Dir, $\mu = \frac{1}{2}$

30

Principe 2 : Génération du document à partir de la requête

- Chaque requête est traitée comme un modèle de langage
- Estimer le modèle de langage M_q de chaque requête
- Classer les documents

$$P(D / M_q) = \prod_{t \in Q} P(t / M_q)$$

- Comme la requête est très réduite, ce type d'estimation n'est pas intéressant

31

références

- J.M. Ponte and W.B. Croft. 1998. A language modelling approach to information retrieval. In *SIGIR 21*.
- D. Hiemstra. 1998. A linguistically motivated probabilistic model of information retrieval. *ECDL 2*, pp. 569-584.
- A. Berger and J. Lafferty. 1999. Information retrieval as statistical translation. *SIGIR 22*, pp. 222-229.
- D.R.H. Miller, T. Leek, and R.M. Schwartz. 1999. A hidden Markov model information retrieval system. *SIGIR 22*, pp. 214-221.
- M. Boughanem, W. Kraaij and J-Y. Nie. Modèles de langage pour la recherche d'information. 2004 (lavoisier)

32