Institut des ACTUAIRES

Formation Data Science Pour Actuariat (DSA)

Cours 1 : Représentations vectorielles

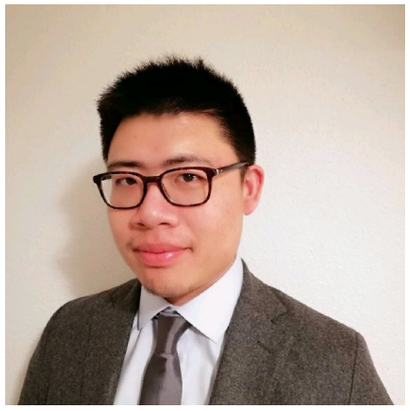

François HU - 05/07/2021 - francois.hu@socgen.com

Data Scientist au DataLab de la Société Générale Assurances

Doctorant à l'ENSAE-CREST

Enseignant à EPITA, ENSAE

Les cours se trouvent ici : https://curiousml.github.io/

Sommaire

1. **Quelques motivations**

2. **Words Embeddings**
   - Représentations vectorielles des mots : *one-hot-encoding* ?
   - word embedding
   - word2vec
   - doc2vec

3. **Topic modeling**
   - Représentation vectorielle des documents / topics
   - Latent Semantic Analysis (LSA)
   - Latent Dirichlet Allocation (LDA)

Programme

Introduction

Représentations vectorielles

Deep Learning pour NLP

Active Learning

Quelques motivations

Contextes **non-supervisé**

Représenter **numériquement des mots** de sorte que la relation suivante ait un sens :

```
vect(king) - vect(man) + vect(woman) = vect(queen)
```

Représenter **numériquement des thèmes (topics) cachés** et les **documents** :

- créer des **systèmes de recommandation**
  (utilisés par les e-commerçants, les moteurs de recherche, …)
- **catégorisation** de textes
- processus d'**exploration des données**
- en bio-informatique : **extraire des connaissances cachées** des données biologiques (molécules d'ADN)

2. Word Embeddings

Représentation vectorielle des mots : *one-hot-encoding* ?

objectif

texte à **apprendre :** mon client est content de son assurance → 

texte à **prédire :** l'assuré est satisfait de notre contrat → ?

Remarques

Représentation vectorielle des mots : *one-hot-encoding* ?

objectif

texte à **apprendre :** mon client est content de son assurance → 

texte à **prédire :** l'assuré est satisfait de notre contrat → ?

1. définir le vocabulaire

V = {'a' : 1, …
'assurance' : 59, …
'assuré' : 62, …
'client' : 698, …
'content' : 772, …
'contrat' : 899, …
'satisfait' : 8 201, …
'zoo' : 9 999, …
<UNK> : 10 000 }

Remarques

Représentation vectorielle des mots : *one-hot-encoding* ?

objectif

texte à **apprendre :** mon client est content de son assurance → 🙂

texte à **prédire :** l'assuré est satisfait de notre contrat → ?

1. définir le vocabulaire

V = {'a' : 1, …
'assurance' : 59, …
'assuré' : 62, …
'client' : 698, …
'content' : 772, …
'contrat' : 899, …
'satisfait' : 8 201, …
'zoo' : 9 999, …
<UNK> : 10 000 }

2. one-hot encoding

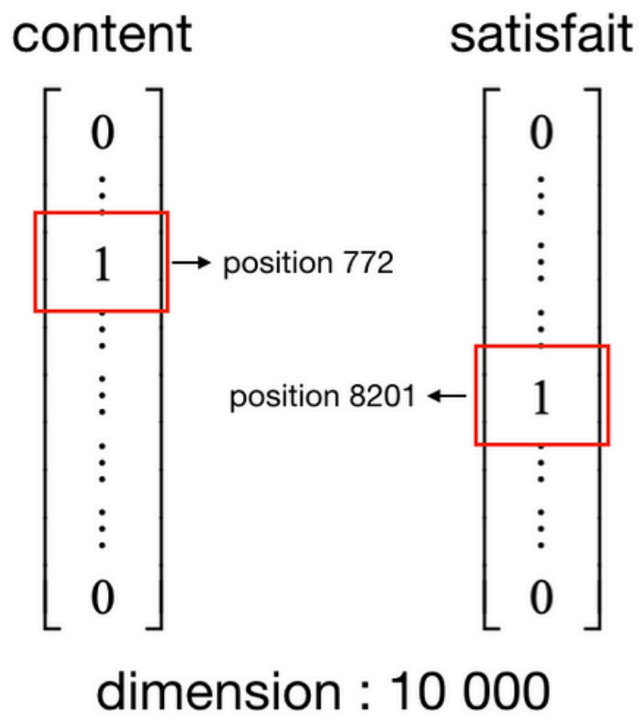

Remarques

Approche naïve de vectorisation :

approche one-hot

approche TF-IDF

Représentation vectorielle des mots : *one-hot-encoding* ?

objectif

texte à **apprendre :** mon client est content de son assurance → 🙂

texte à **prédire :** l'assuré est satisfait de notre contrat → ?

1. définir le vocabulaire

V = {'a' : 1, …
'assurance' : 59, …
'assuré' : 62, …
'client' : 698, …
'content' : 772, …
'contrat' : 899, …
'satisfait' : 8 201, …
'zoo' : 9 999, …
<UNK> : 10 000 }

2. one-hot encoding

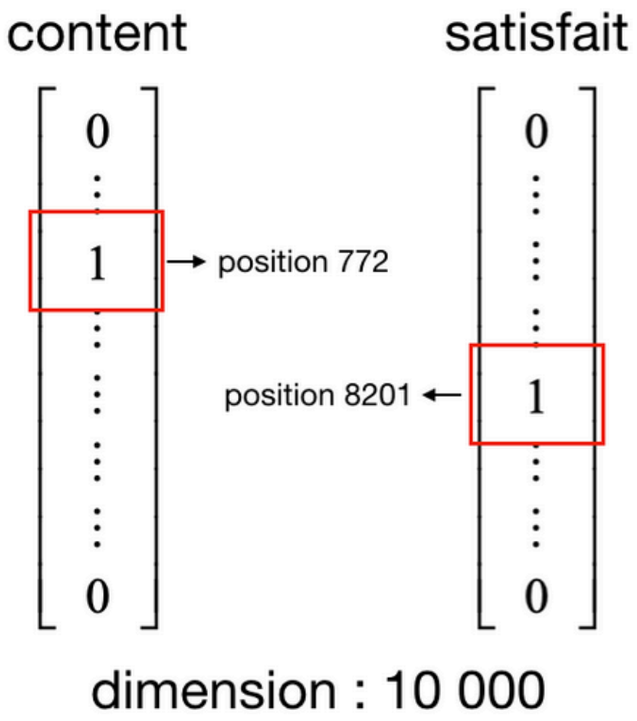

dimension : 10 000

Remarques

Approche naïve de vectorisation :

approche one-hot

approche TF-IDF

Problèmes :

vecteurs creux de grandes dimensions

sauvegardent des mots sans prendre en compte le contexte :

vect (« **content** »)

≠

vect (« **satisfait** »)

Représentation vectorielle des mots : *one-hot-encoding* ?

objectif

texte à **apprendre :** mon client est content de son assurance → 🙂

texte à **prédire :** l'assuré est satisfait de notre contrat → ?

1. définir le vocabulaire

V = {'a' : 1, …
'assurance' : 59, …
'assuré' : 62, …
'client' : 698, …
'content' : 772, …
'contrat' : 899, …
'satisfait' : 8 201, …
'zoo' : 9 999, …
<UNK> : 10 000 }

2. one-hot encoding

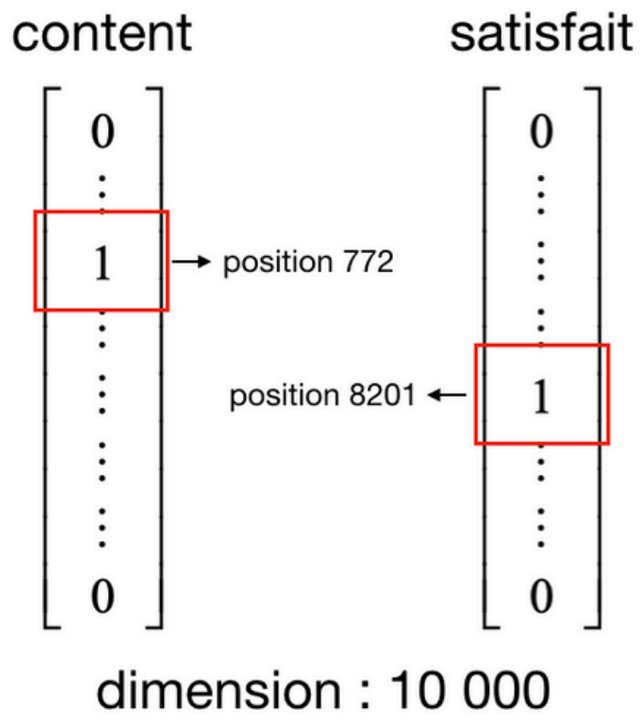

Remarques

Approche naïve de vectorisation :

approche one-hot

approche TF-IDF

Problèmes :

vecteurs creux de grandes dimensions

sauvegardent des mots sans prendre en compte le contexte :

vect (« **content** »)

≠

vect (« **satisfait** »)

Solution :

approche word embedding

Word Embedding

Word embedding (**plongement de mot** en français) : vectorisation des mots de sorte que les mots apparaissant dans des contextes similaires ont des significations apparentées

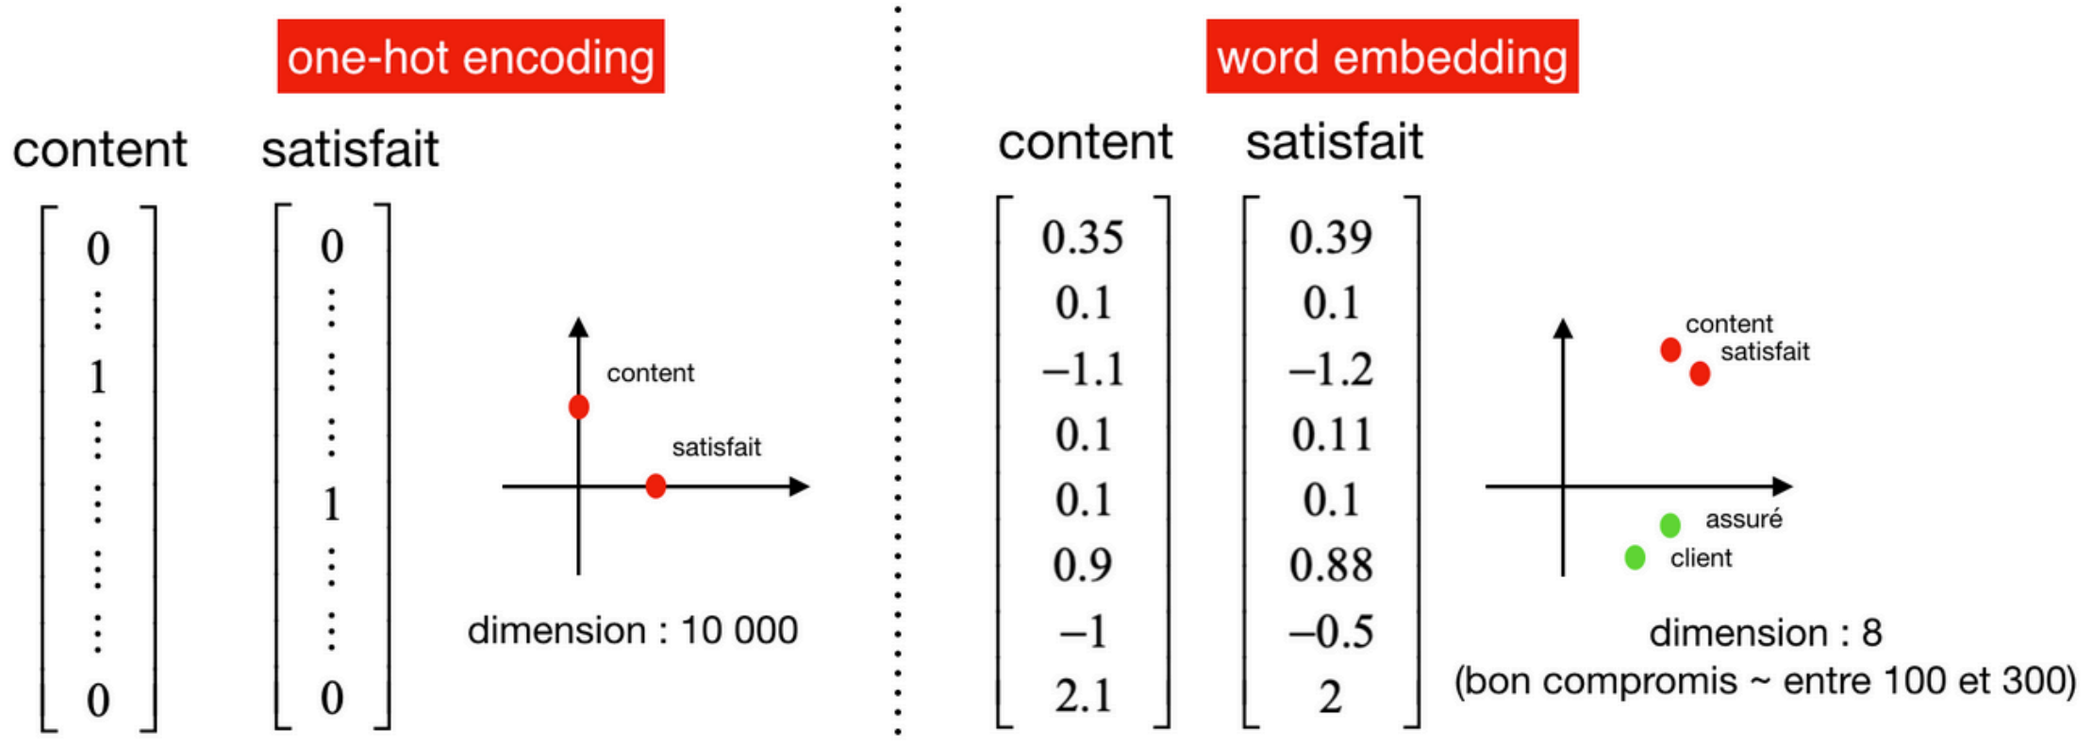

Vecteurs denses de plus petites dimensions

$$\text{mot1} \approx \text{mot2} \implies \text{word\_embedding(mot1)} \approx \text{word\_embedding(mot2)}$$

Word embedding populaire : **word2vec**

Word2vec

Principe : utiliser les réseaux de neurones pour construire ces vecteurs

Deux architectures de word2vec : **Continuous Bag-Of-Words** (CBOW) et **Skip-Gram**

Exemple de texte :

notre client est content de son assurance automobile

~~notre~~ client ~~est~~ content ~~de son~~ assurance automobile

client content assurance automobile

Word2vec

Principe : utiliser les réseaux de neurones pour construire ces vecteurs

Deux architectures de word2vec : **Continuous Bag-Of-Words** (CBOW) et **Skip-Gram**

Exemple de texte :

notre client est content de son assurance automobile

~~notre~~ client ~~est~~ content ~~de son~~ assurance automobile

client content assurance automobile

Générer des observations pour word2vec pour une **fenêtre de taille 2**

cible contexte

observation 1 : client content assurance automobile

observation 2 : client content assurance automobile

observation 3 : client content assurance automobile

observation 4 : client content assurance automobile

Word2vec

Principe : utiliser les réseaux de neurones pour construire ces vecteurs

Deux architectures de word2vec : **Continuous Bag-Of-Words** (CBOW) et **Skip-Gram**

Exemple de texte :

notre client est content de son assurance automobile

~~notre~~ client ~~est~~ content ~~de son~~ assurance automobile

client content assurance automobile

Générer des observations pour word2vec pour une **fenêtre de taille 2**

cible contexte

observation 1 : client content assurance automobile

observation 2 : client content assurance automobile

observation 3 : client content assurance automobile

observation 4 : client content assurance automobile

Modèle CBOW :
cherche à prédire un mot à partir du contexte

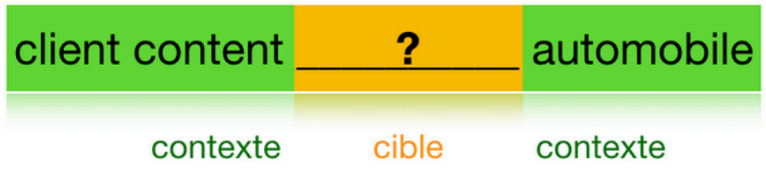

prédire **assurance**

Modèle skip-gram :
cherche à prédire les mots du contexte à partir d'un mot

prédire : **client** **content** **automobile**

Word2vec : modèle CBOW

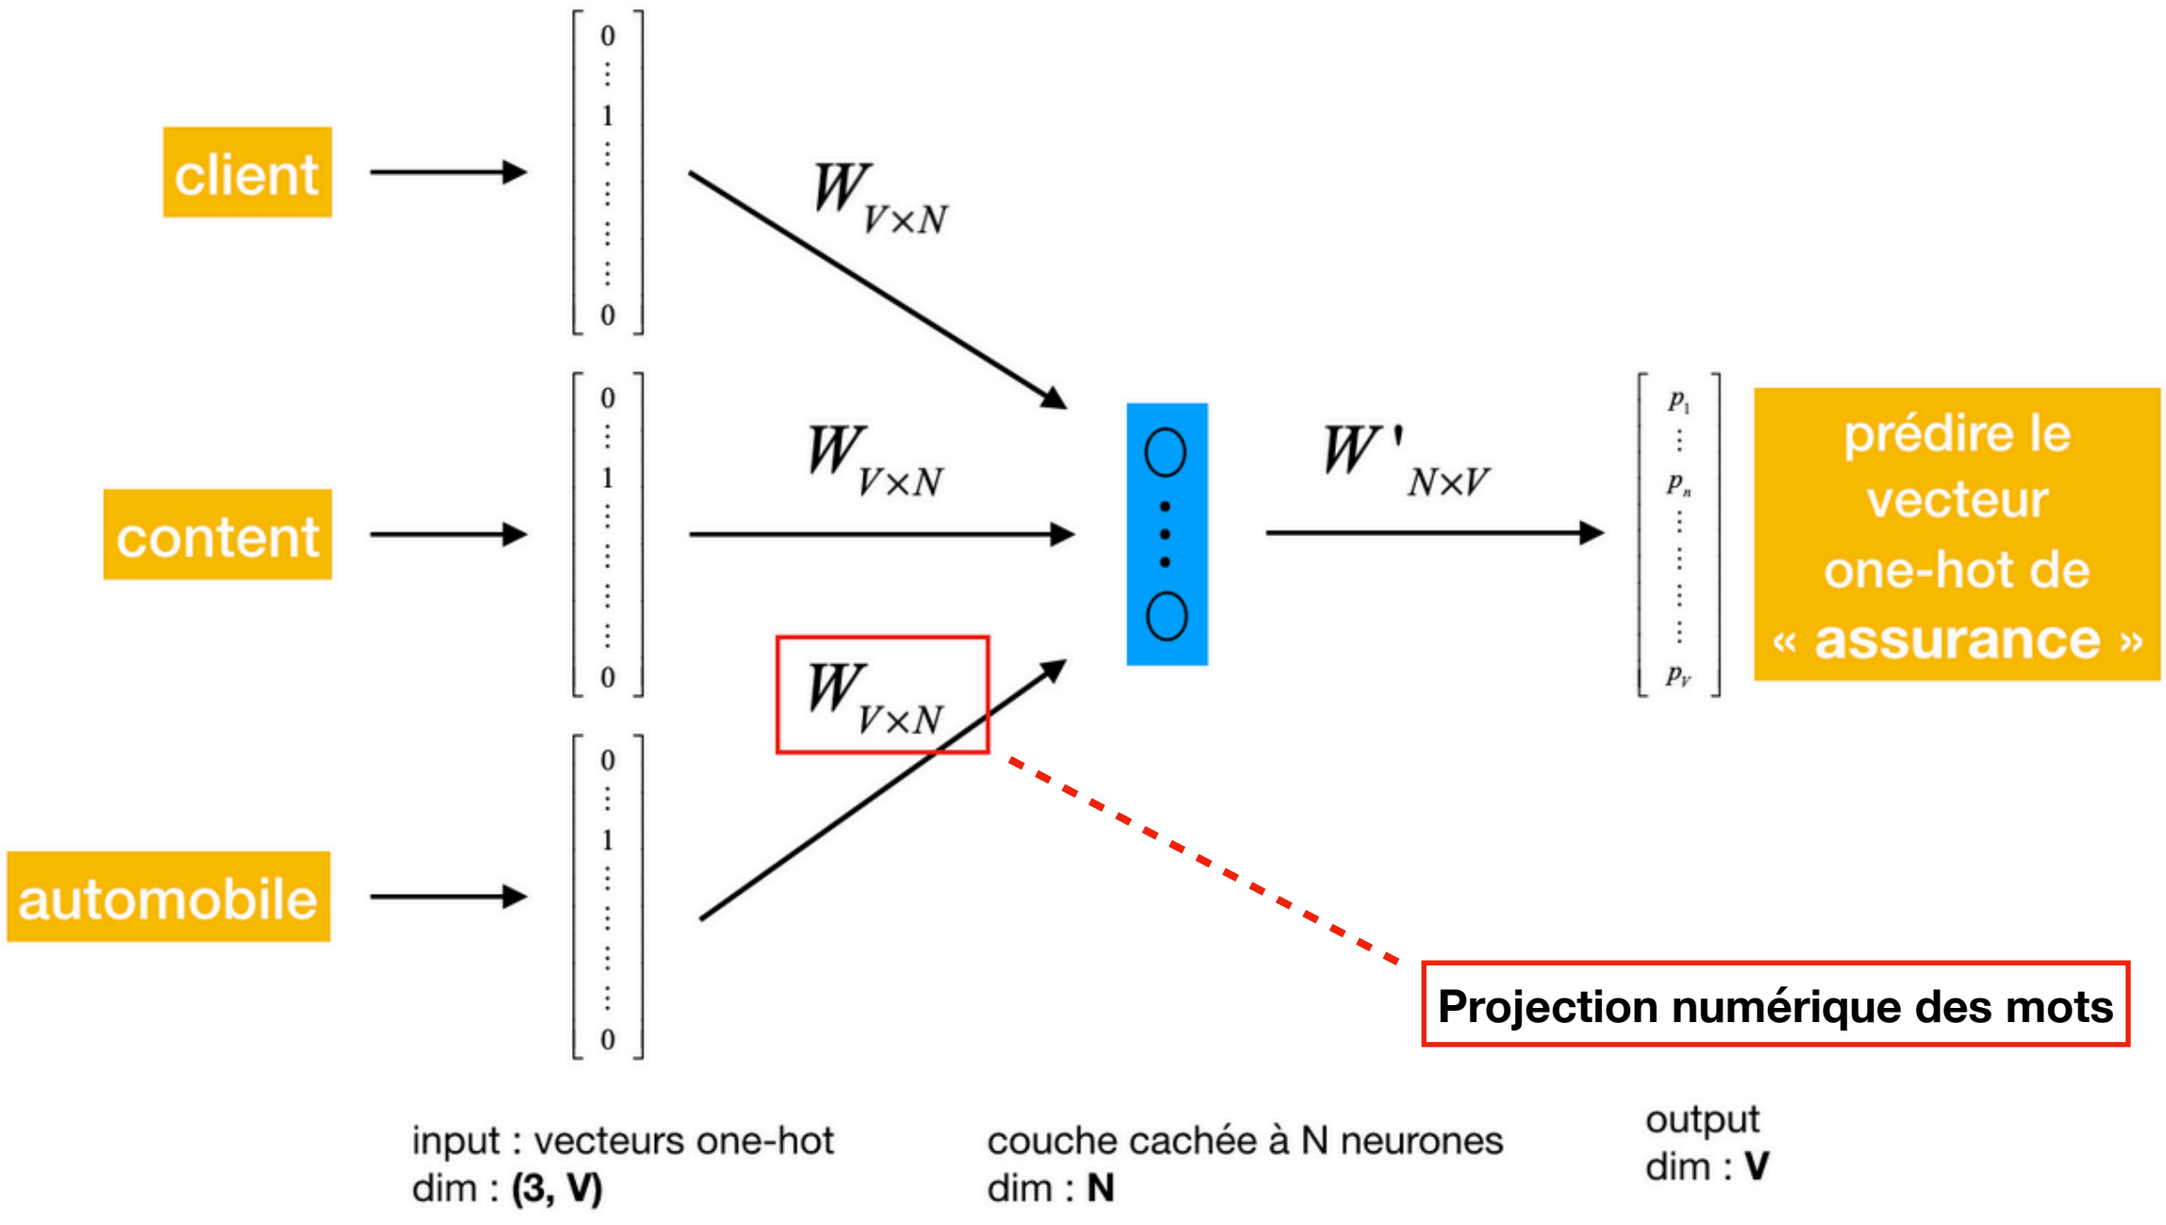

Word2vec : modèle Skip-Gram

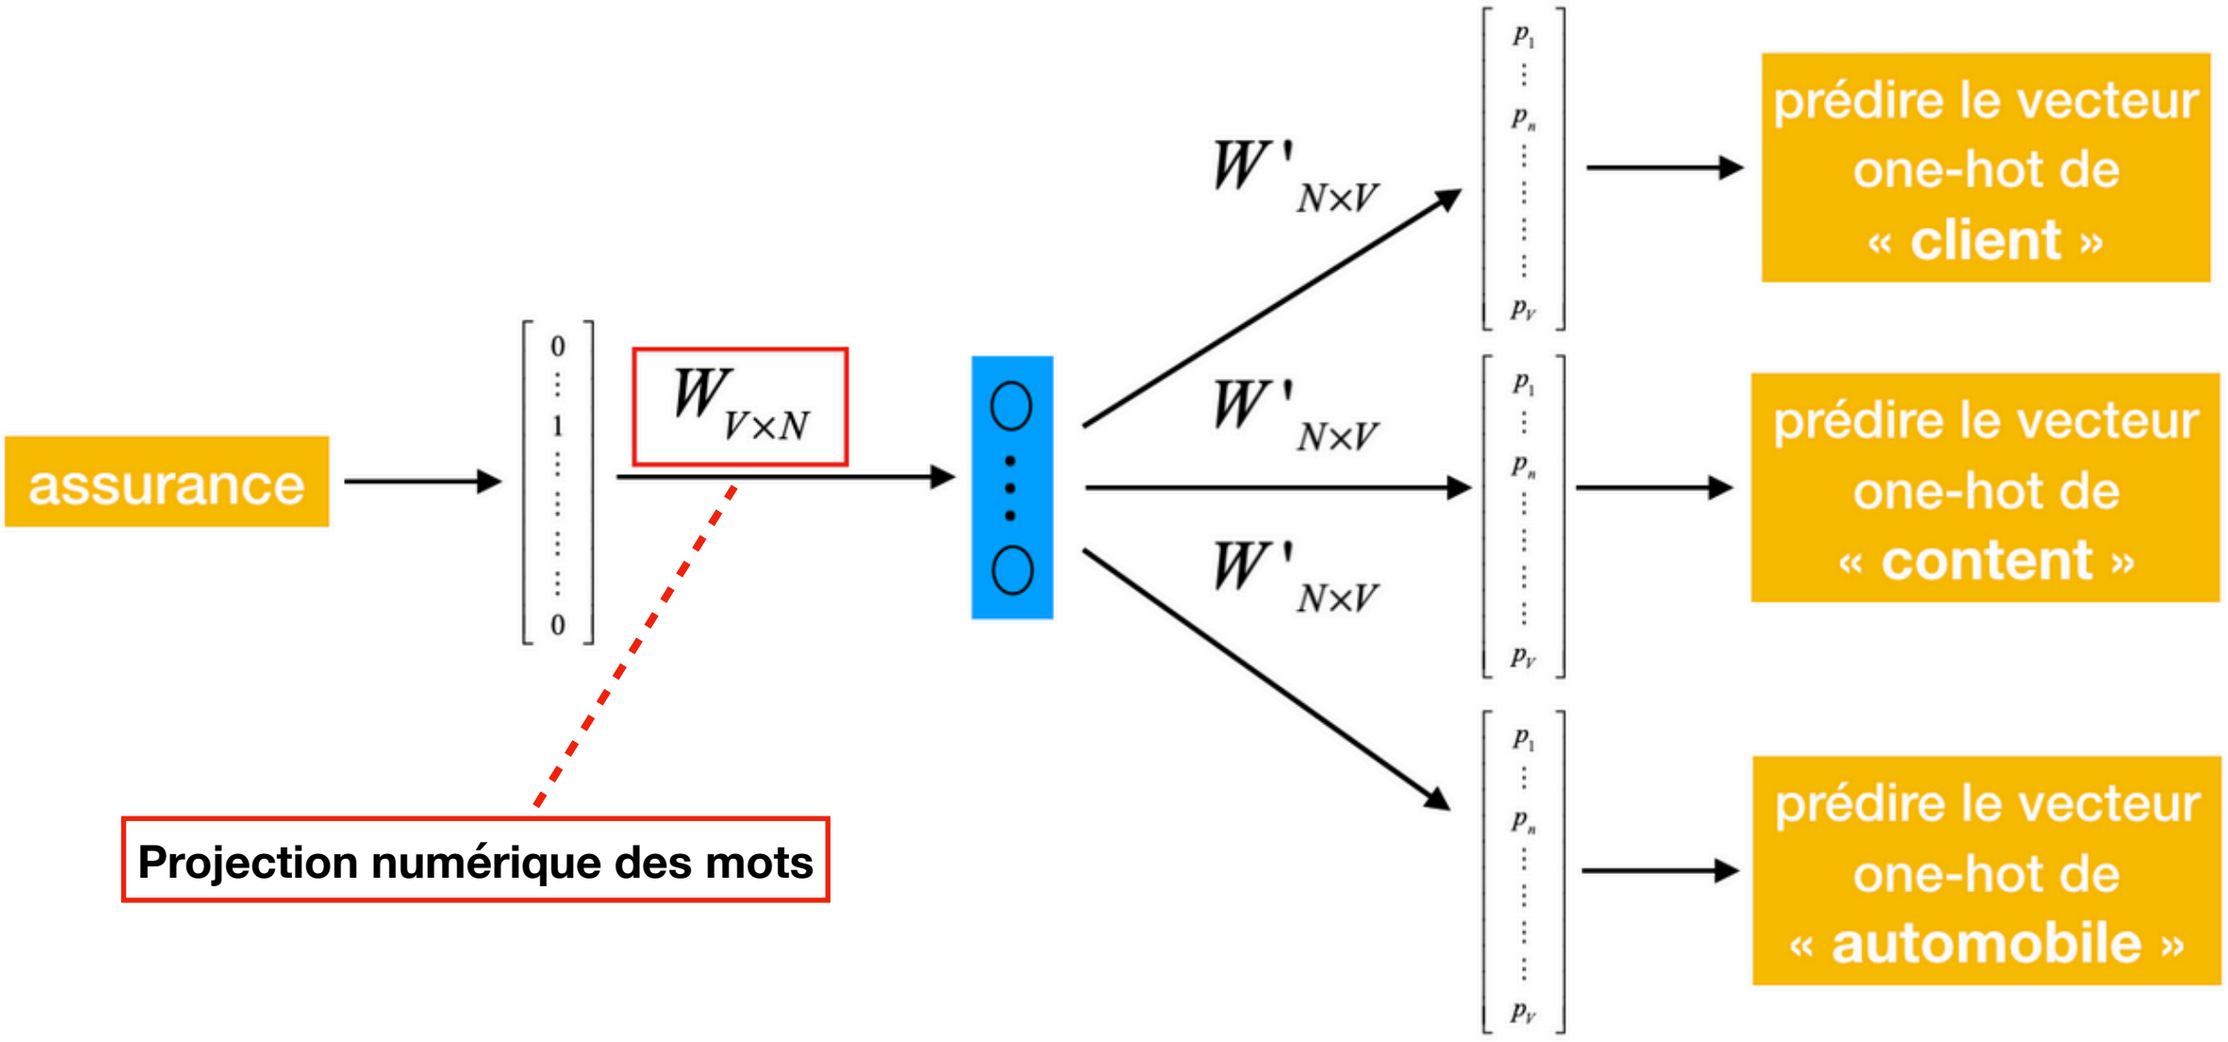

classification de textes avec word2vec

agrégation puis **classification classique** :

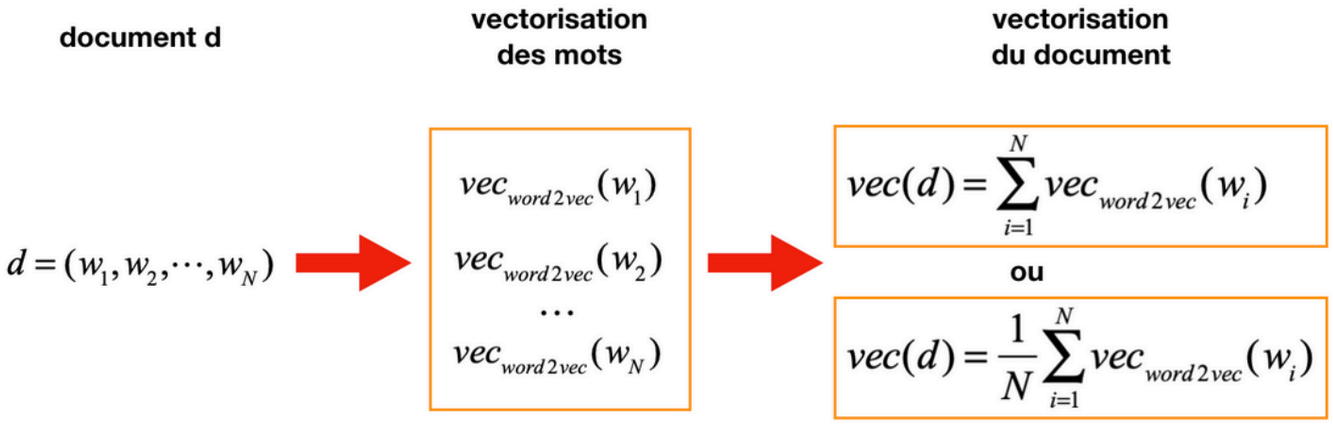

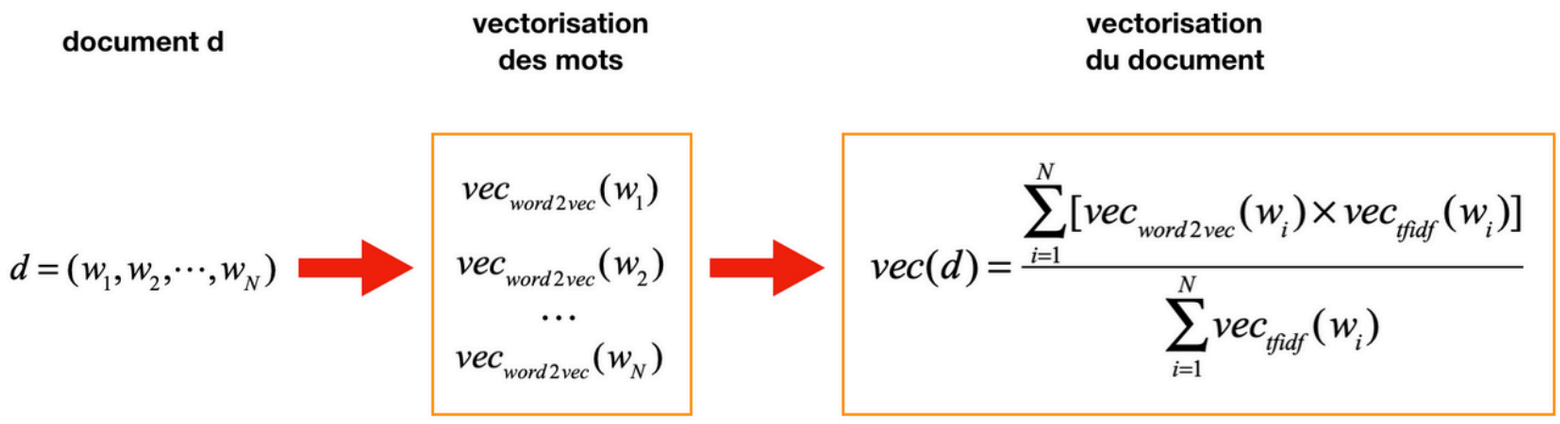

doc2vec puis **classification classique** : voir section suivante pour le modèle doc2vec

classification avec les **réseaux de neurones** : voir cours 2 pour les modèles séquentiels

classification de textes avec doc2vec

doc2vec

vectorisation des **documents** (resp. des mots) de sorte que les **documents** (resp. les mots) apparaissant dans des contextes similaires ont des significations apparentées

Distributed Memory (DM) :

$$p(w_i \mid w_{i-h}, \ldots, w_{i+h}, d)$$

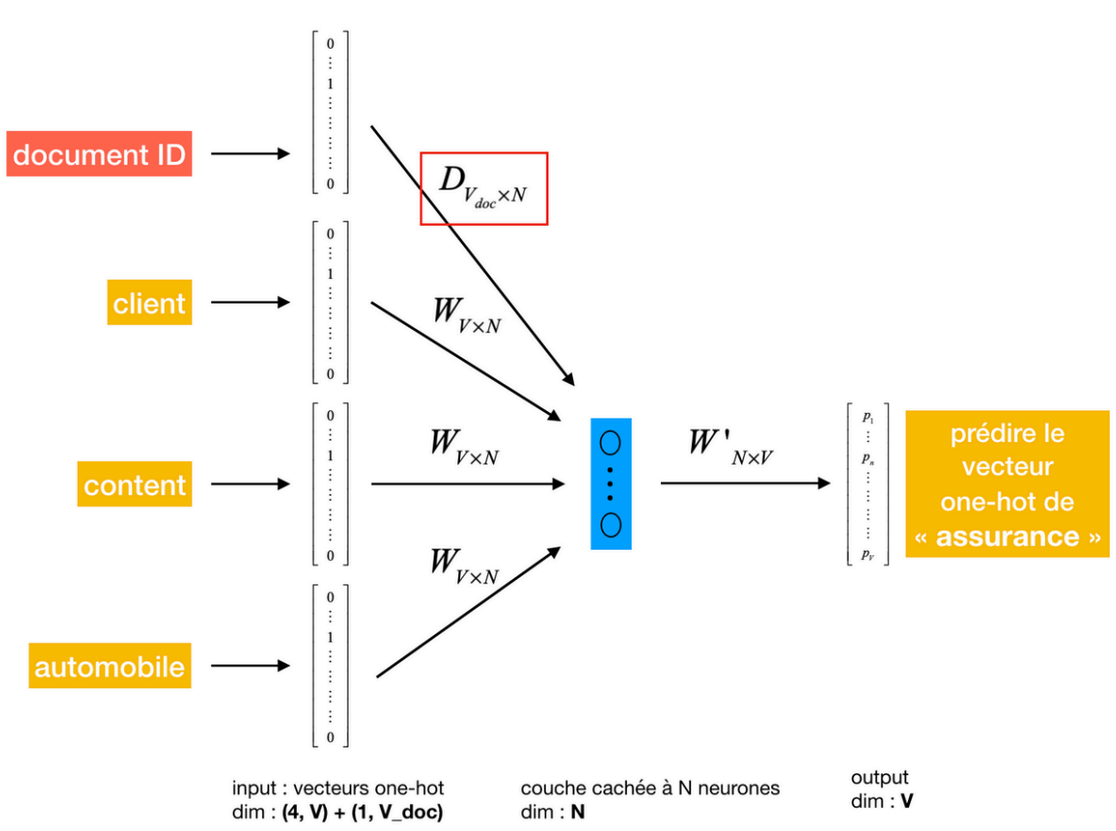

Distributed Bag-Of-Words (DBOW) :

$$p(w_{i-h}, \ldots, w_{i+h} \mid d)$$

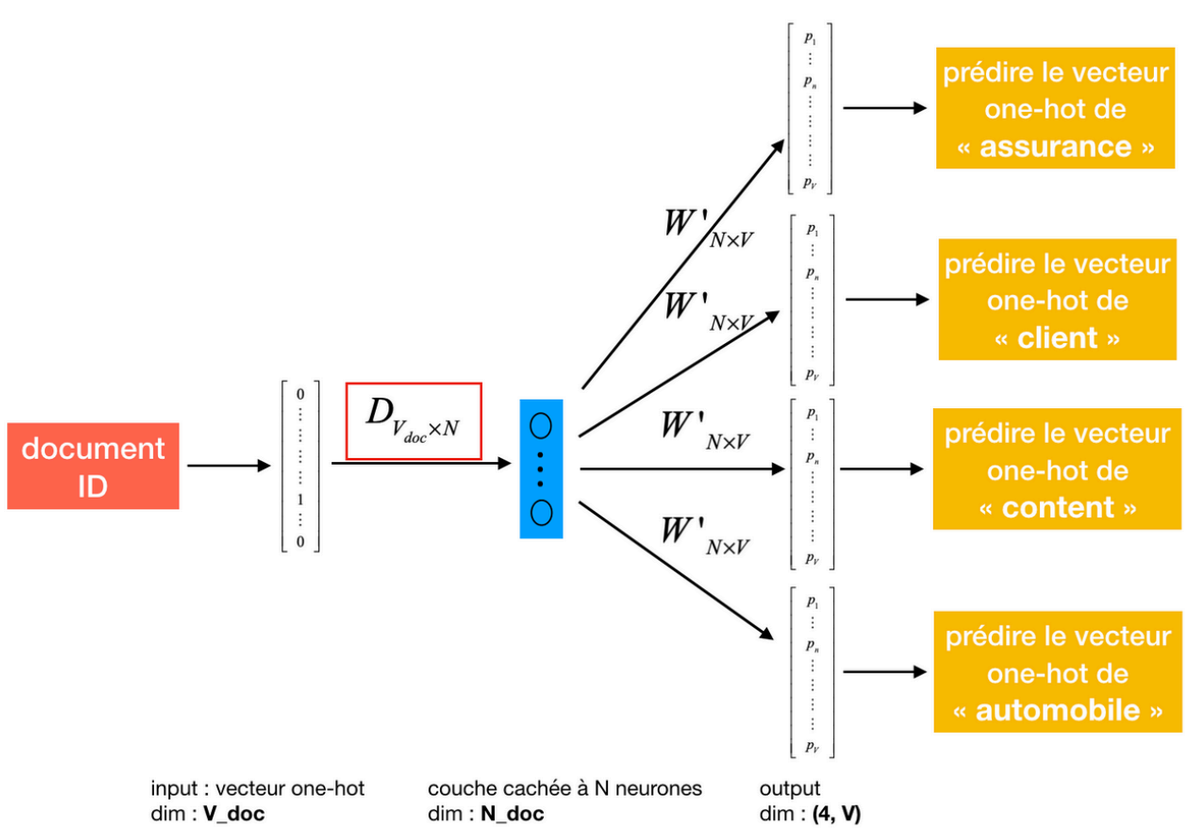

Résumé

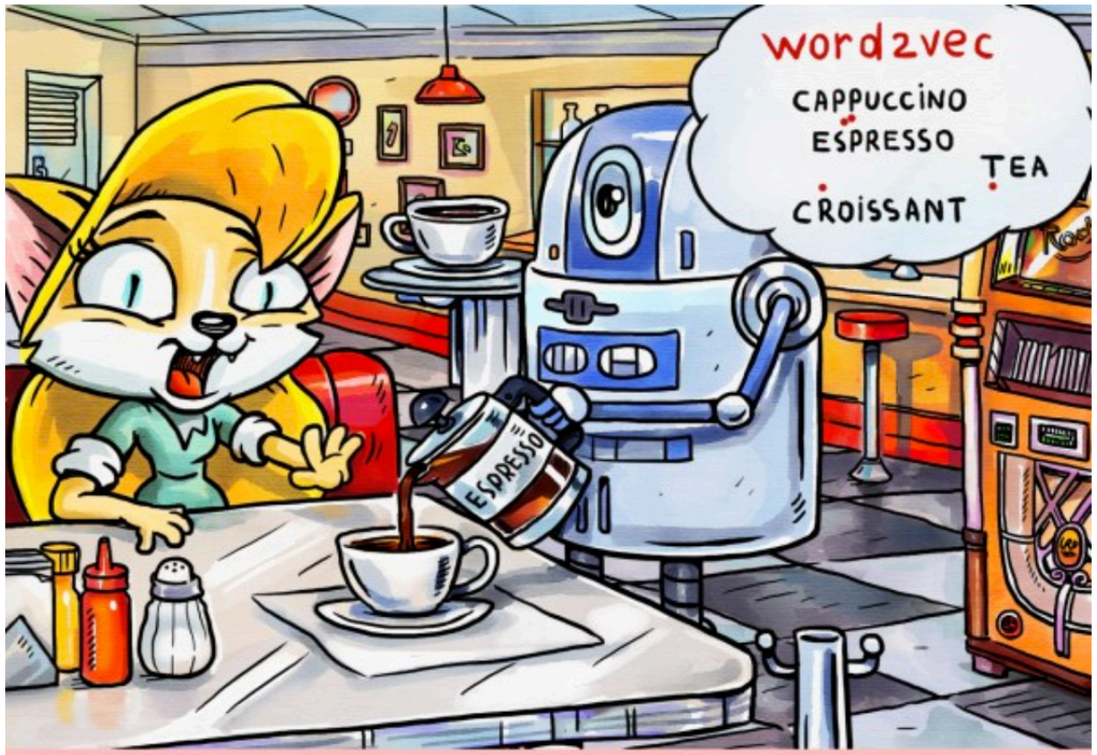

- Espresso? But I ordered a cappuccino!
- Don't worry, the cosine distance between them is so small that they are almost the same thing.

auteur : Dmitry Malkov, data scientist et dessinateur de BD chez Data Monsters

word embedding :

- **word2vec :**
  CBOW, skip-gram

doc embedding :

- **doc2vec :**
  DM, DBOW

classification de textes avec ces embeddings

3. Topic modeling

Représentation vectorielle des documents / topics

Topic modeling (**modélisation thématique** en français) : un modèle statistique permettant de découvrir les "sujets" cachés qui apparaissent dans une collection de documents.

Idée :

- chaque **document** est vu comme un **mélange de topics**
- chaque **topic** est vu comme une **collection de mots**

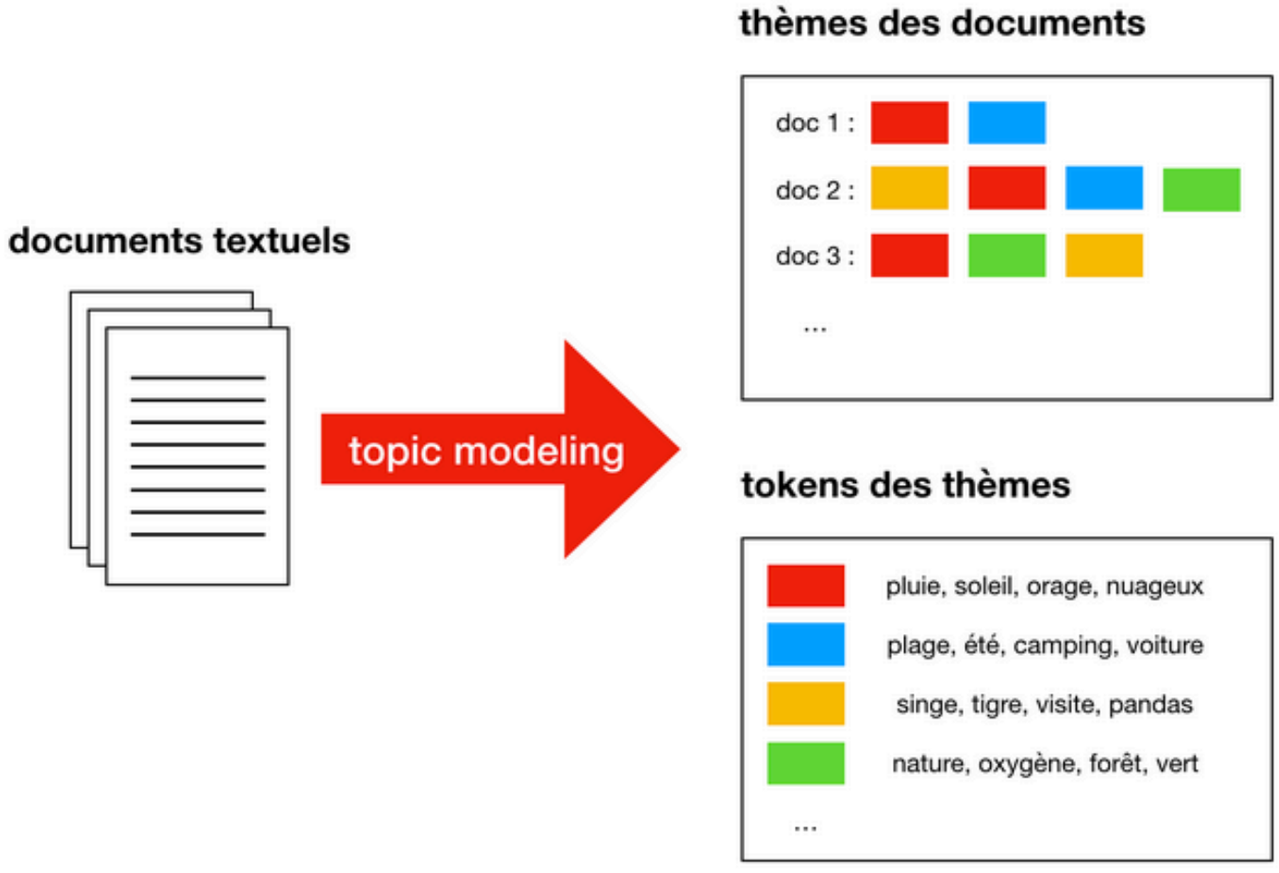

Topic model le plus populaire : LSA, **LDA**

Latent Semantic Analysis (1/2)

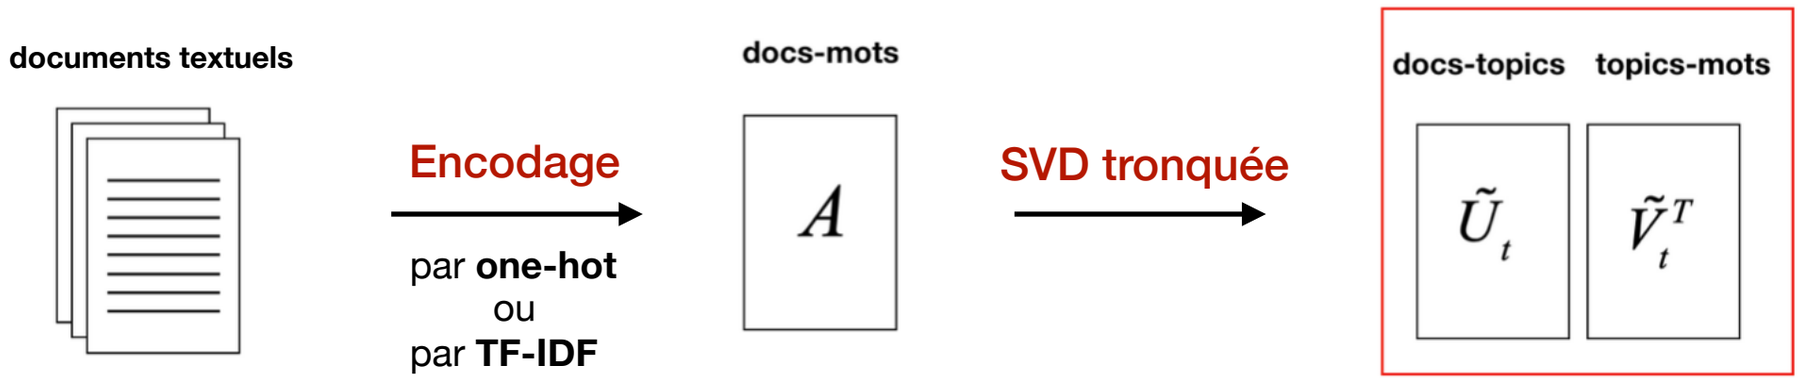

Latent Semantic Analysis (1/2)

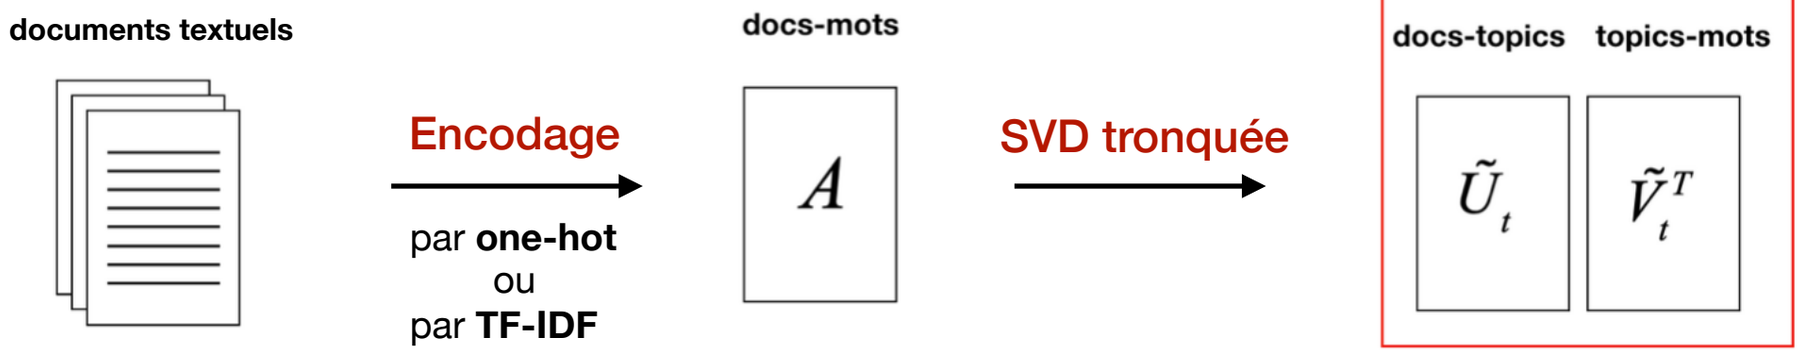

Décomposition en Valeurs Singulières (SVD) :

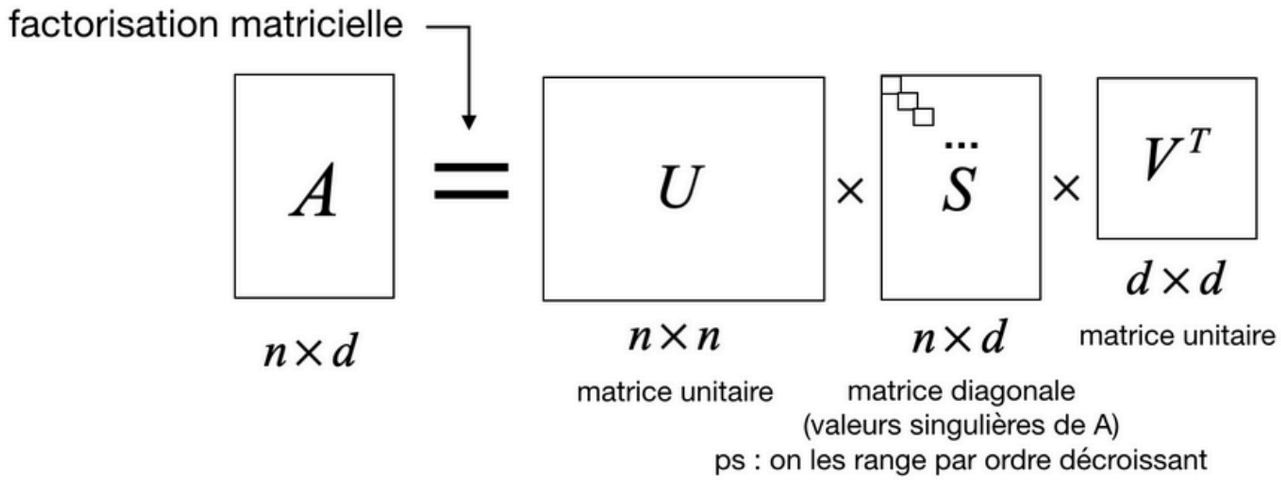

Latent Semantic Analysis (1/2)

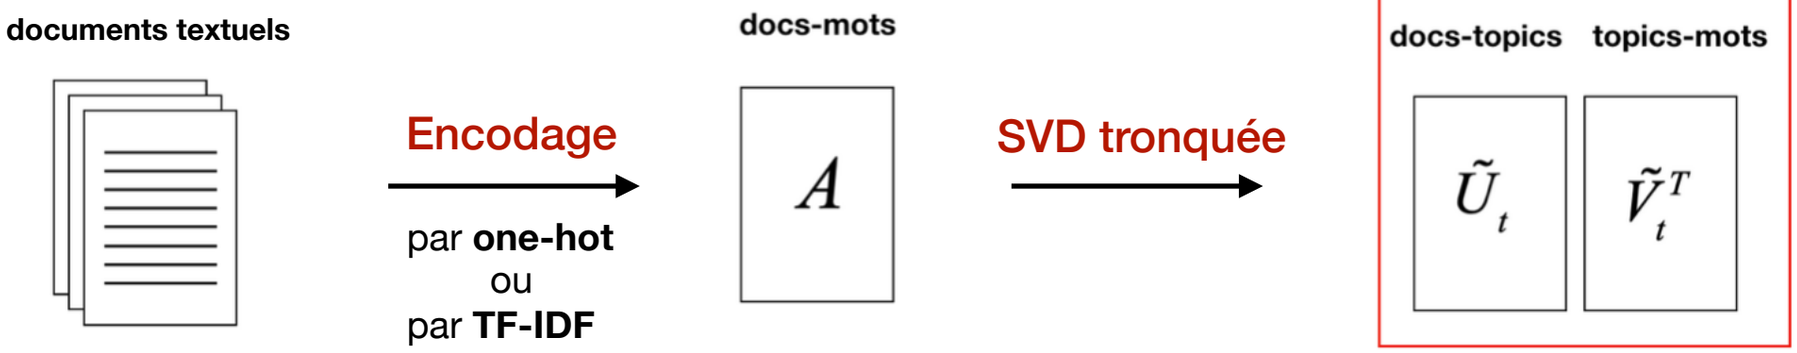

Décomposition en Valeurs Singulières (SVD) :

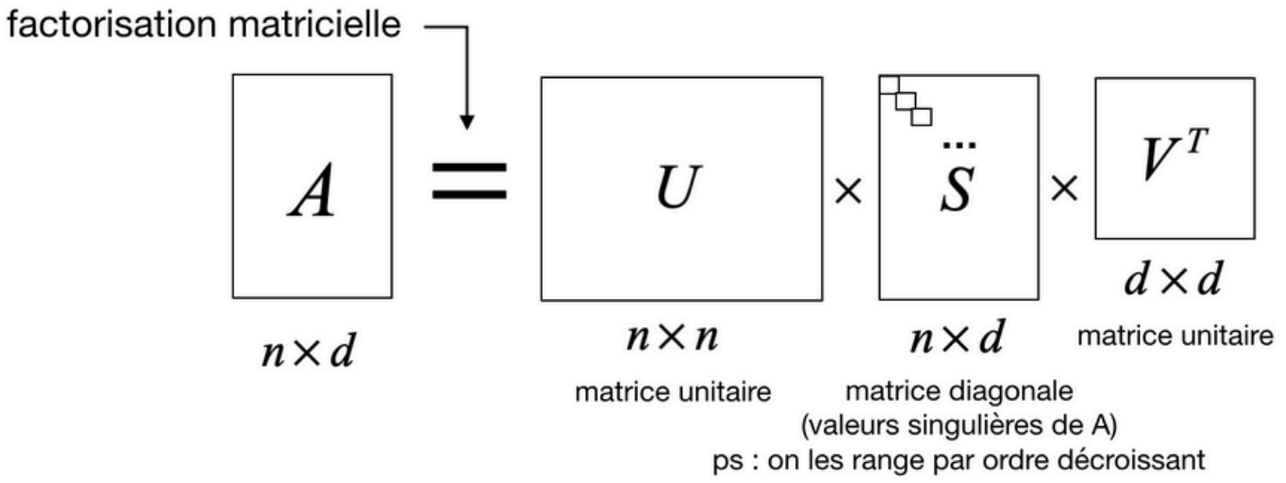

SVD tronquée :

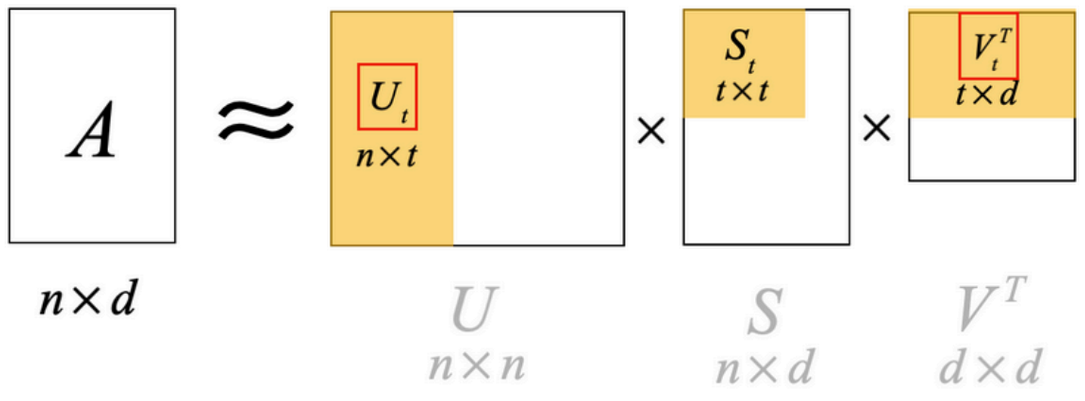

Latent Semantic Analysis (1/2)

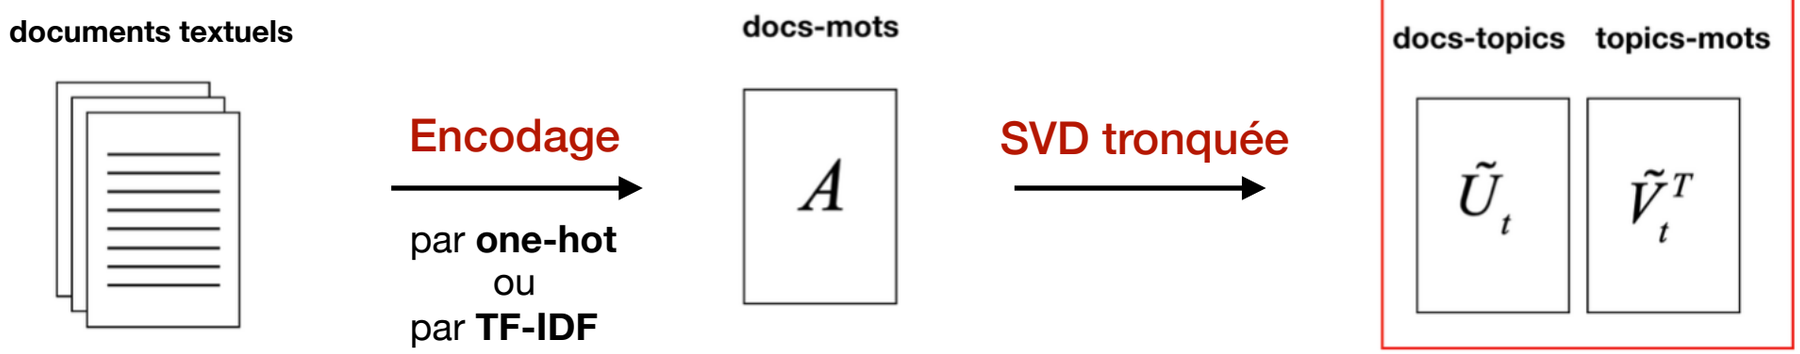

Décomposition en Valeurs Singulières (SVD) :

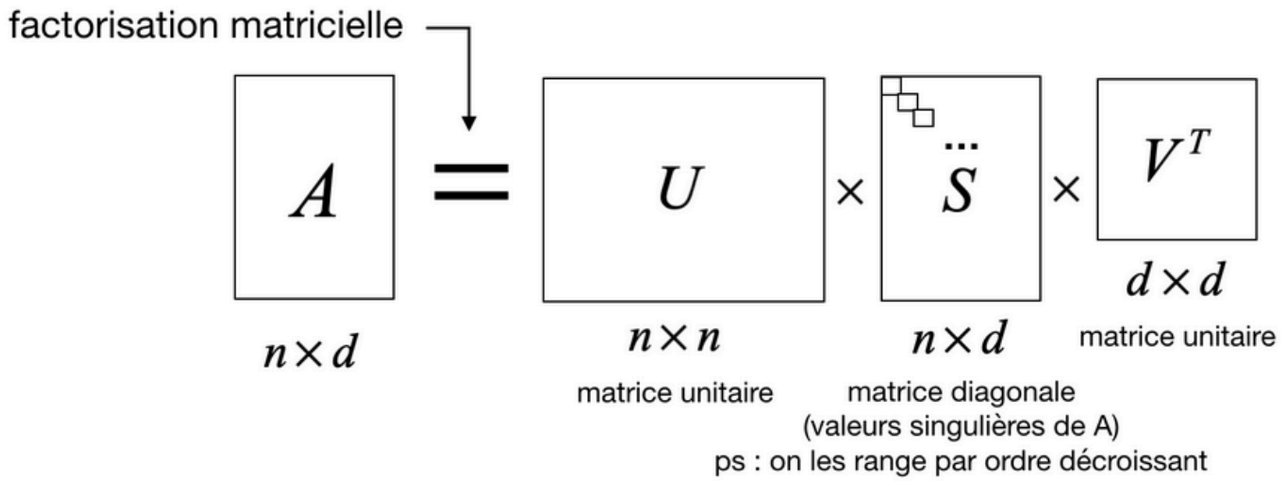

SVD tronquée :

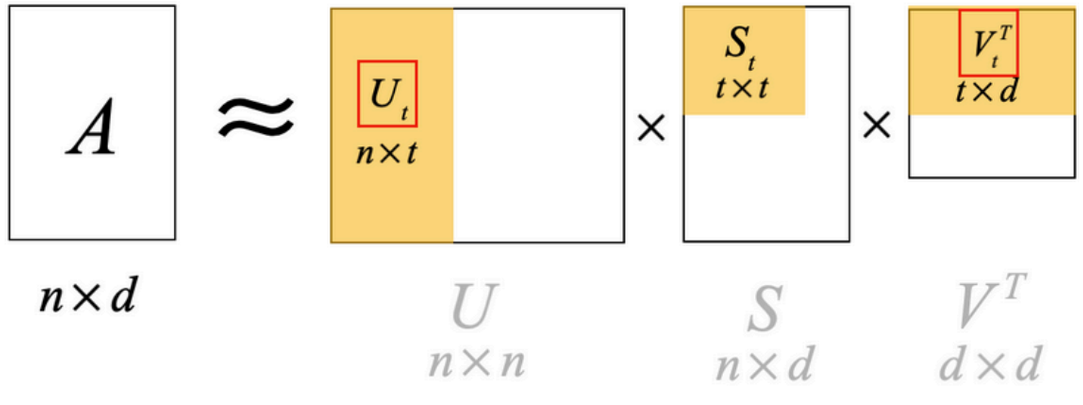

Comment choisir $\tilde{U}_t$ et $\tilde{V}_t^T$?

Latent Semantic Analysis (1/2)

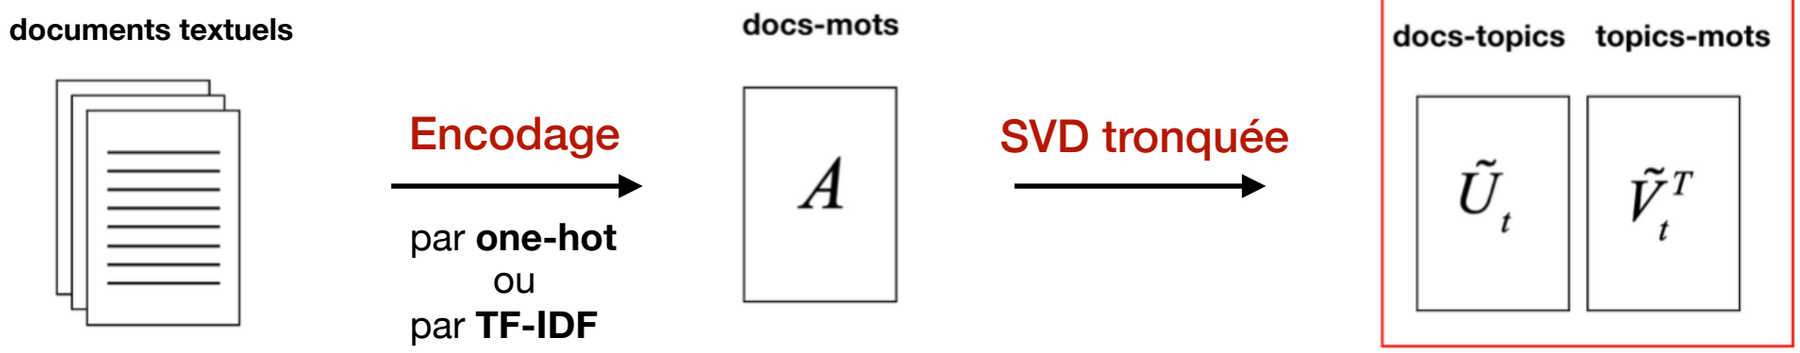

Décomposition en Valeurs Singulières (SVD) :

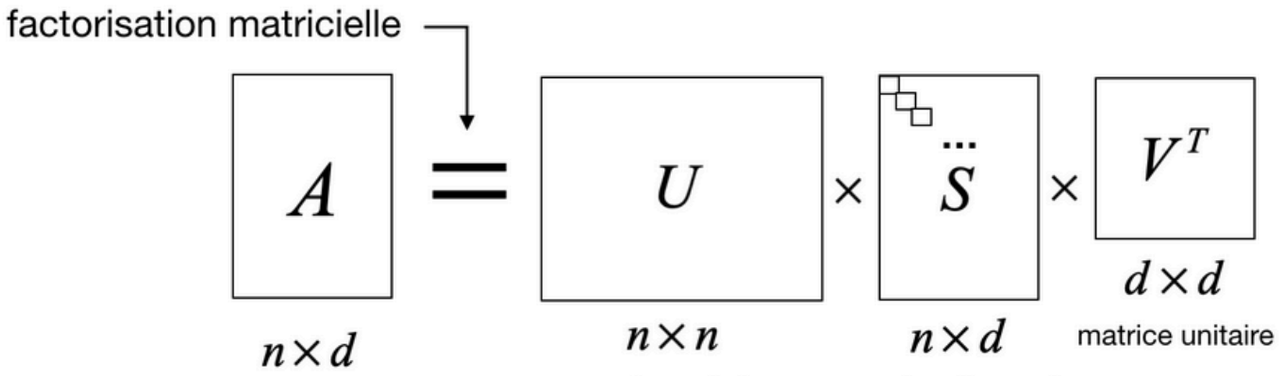

SVD tronquée :

Comment choisir $\tilde{U}_t$ et $\tilde{V}_t^T$?

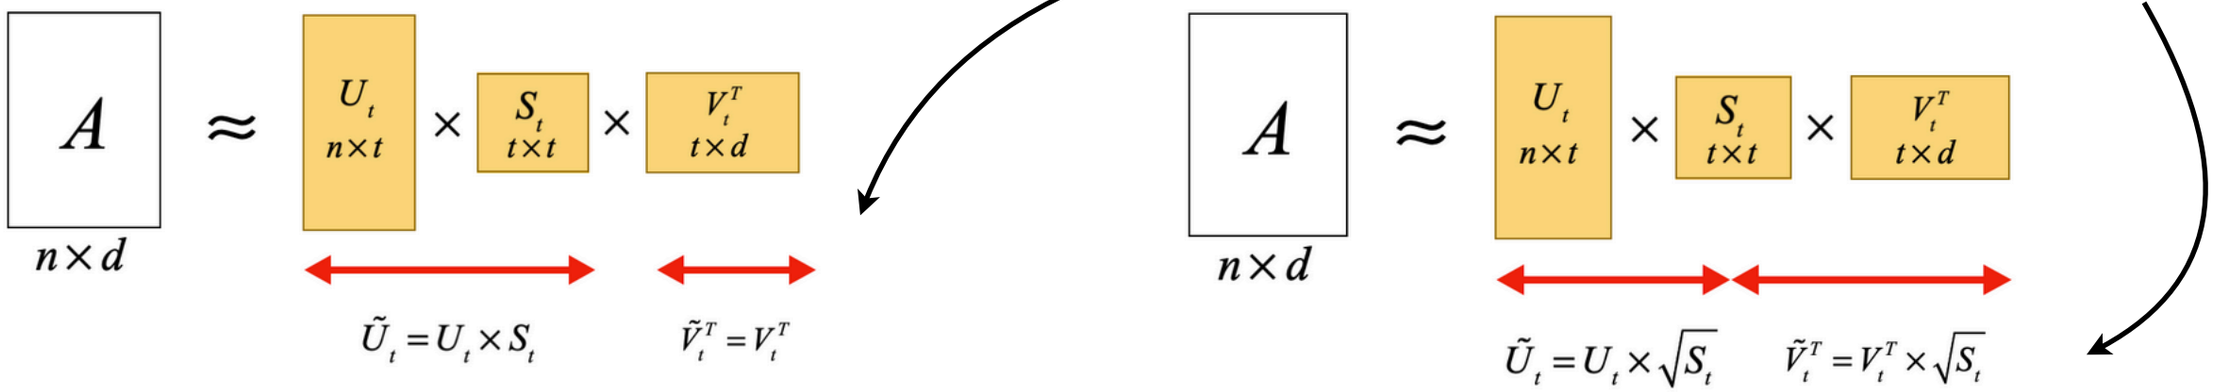

Latent Semantic Analysis (2/2)

Remarques :

- approche **algèbre linéaire**
- évaluer la similarité entre les **documents** (similarité cosinus)
- évaluer la similarité entre les **mots** (similarité cosinus)

Désavantages :

- vecteurs difficilement **interprétable**
- besoin d'un **grand ensemble de docs et de vocabulaires** pour obtenir une bonne précision

Latent Semantic Analysis (2/2)

Remarques :

- approche **algèbre linéaire**
- évaluer la similarité entre les **documents** (similarité cosinus)
- évaluer la similarité entre les **mots** (similarité cosinus)

Désavantages :

- vecteurs difficilement **interprétable**
- besoin d'un **grand ensemble de docs et de vocabulaires** pour obtenir une bonne précision

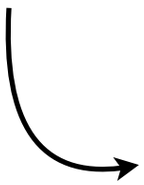

Solution : une version probabiliste avec LDA

Latent Dirichlet Allocation : définition

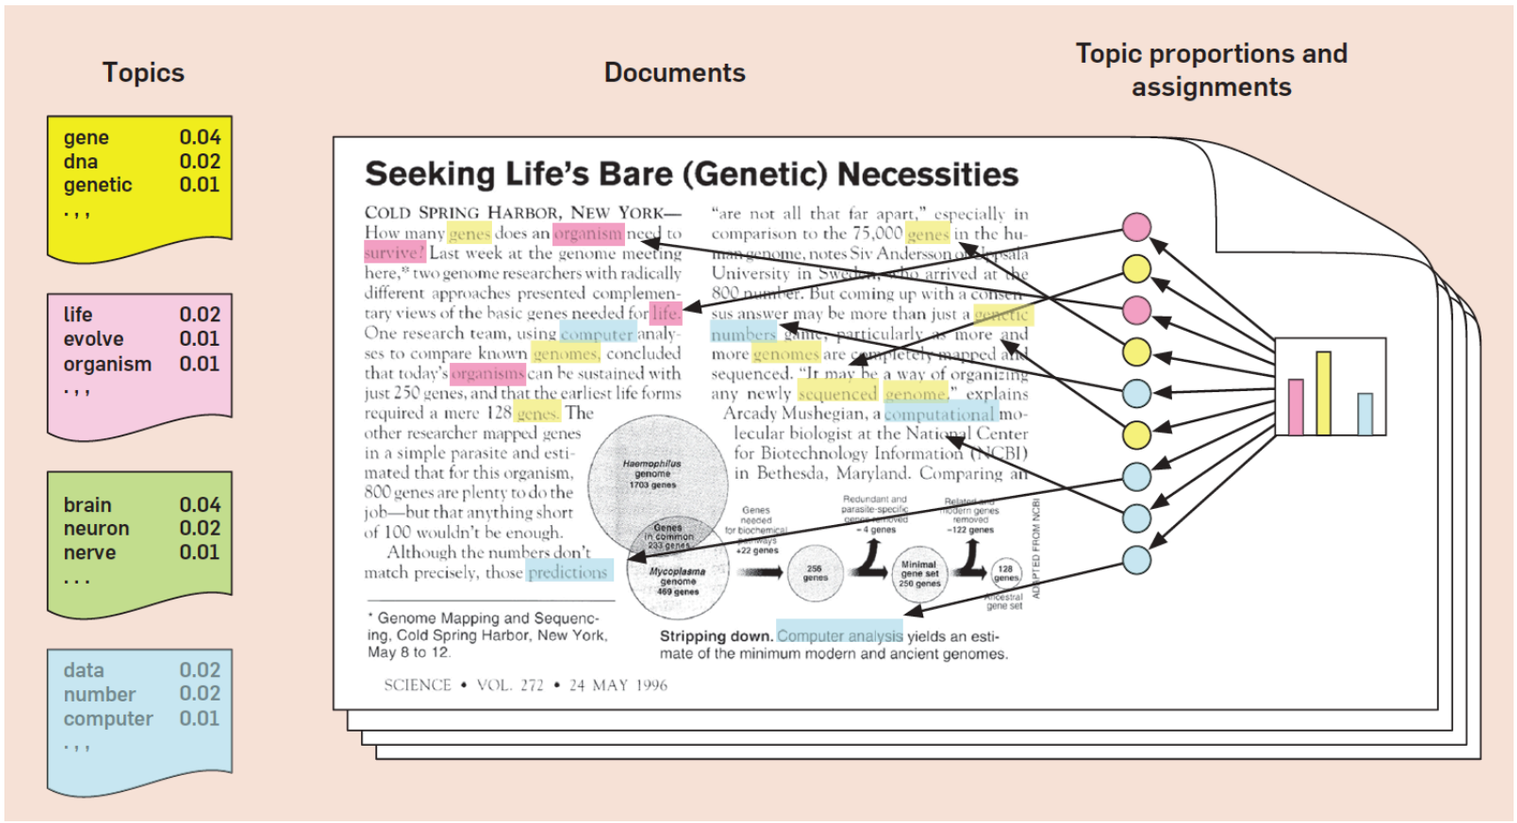

comment est généré un document d d'après le modèle LDA ?

un document $d = (w_1, \ldots, w_W)$ est généré de la manière suivante : pour tout $w \in d$

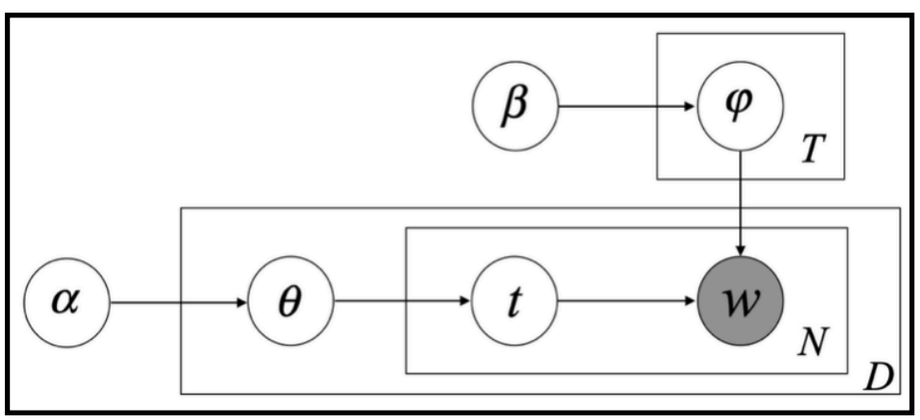

- $\theta_d \sim Dir(\alpha)$, $\phi_t \sim Dir(\beta)$
- $t \sim Multinomial(\theta_{.d})$, $w \sim Multinomial(\phi_{.t})$

source : Blei, D.M. (2012). Probabilistic topic models. Communications of the ACM, 55(4), 77-84.

Latent Dirichlet Allocation : zoom sur Dirichlet

Dirichlet distribution (dimension 3) :

TOPICS

- Vacances
- Nature
- Sports

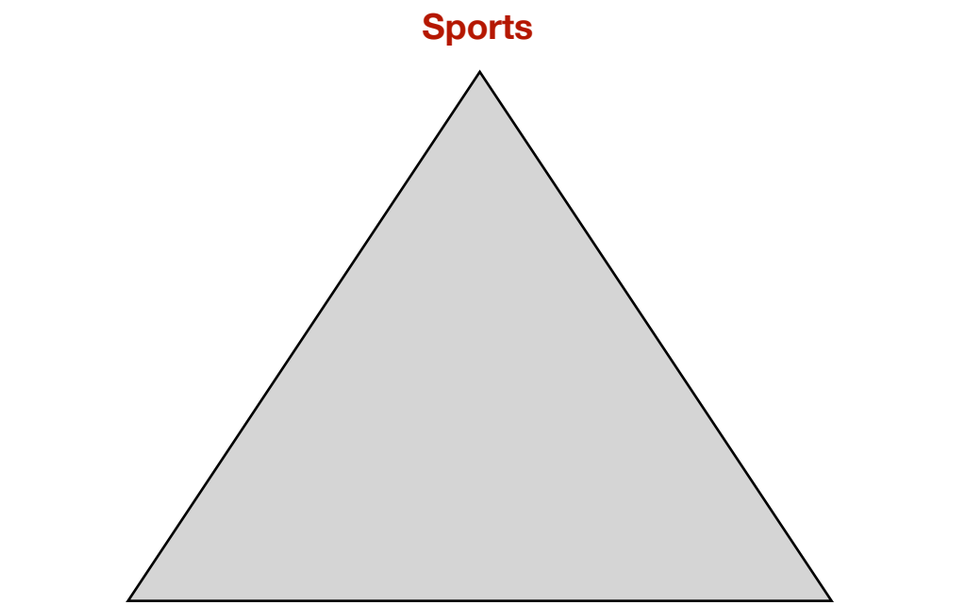

Latent Dirichlet Allocation : zoom sur Dirichlet

Dirichlet distribution (dimension 3) :

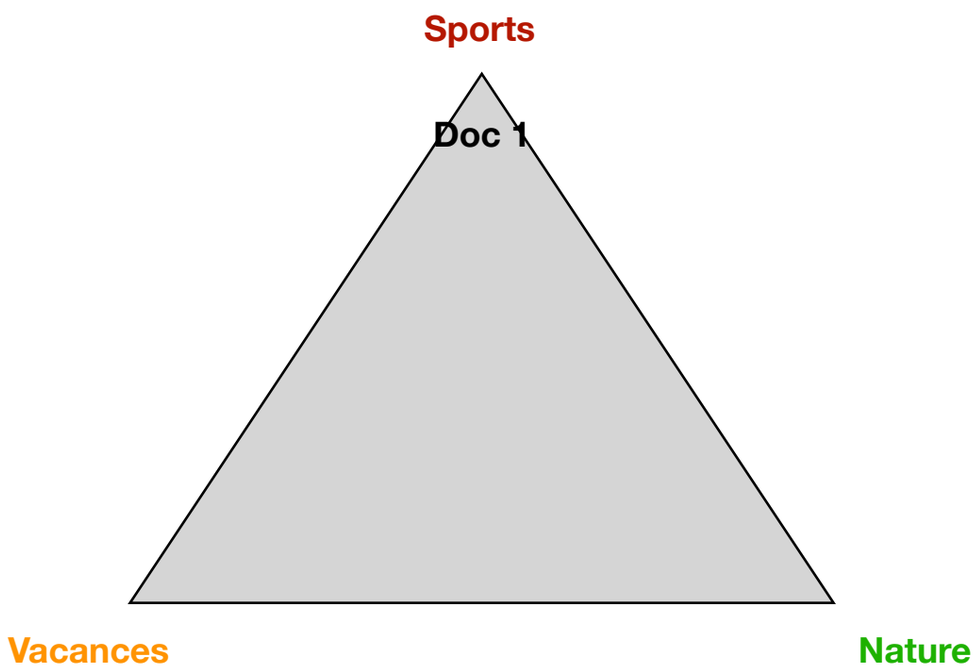

Latent Dirichlet Allocation : zoom sur Dirichlet

Dirichlet distribution (dimension 3) :

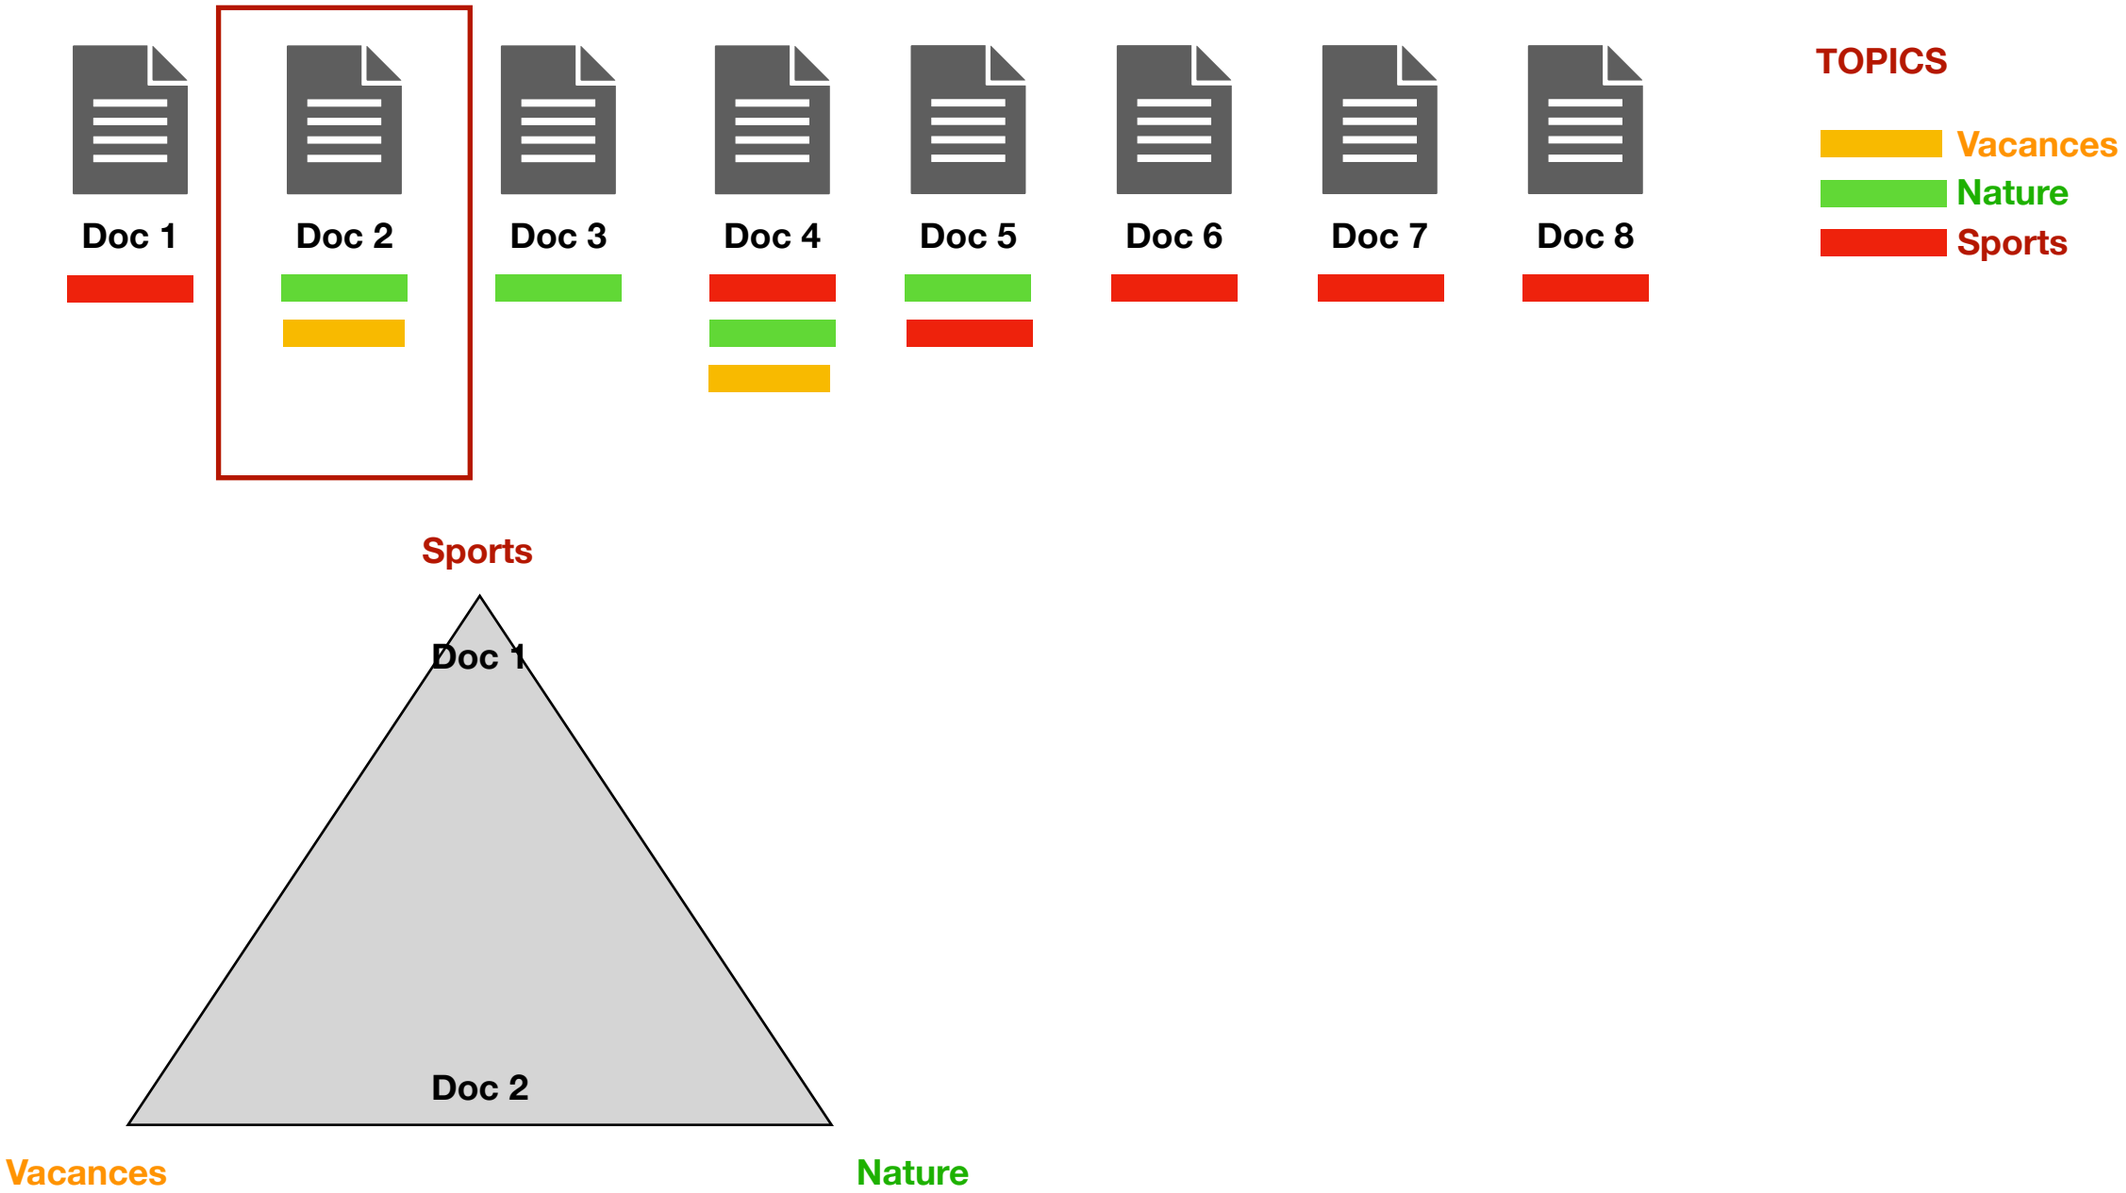

Latent Dirichlet Allocation : zoom sur Dirichlet

Dirichlet distribution (dimension 3) :

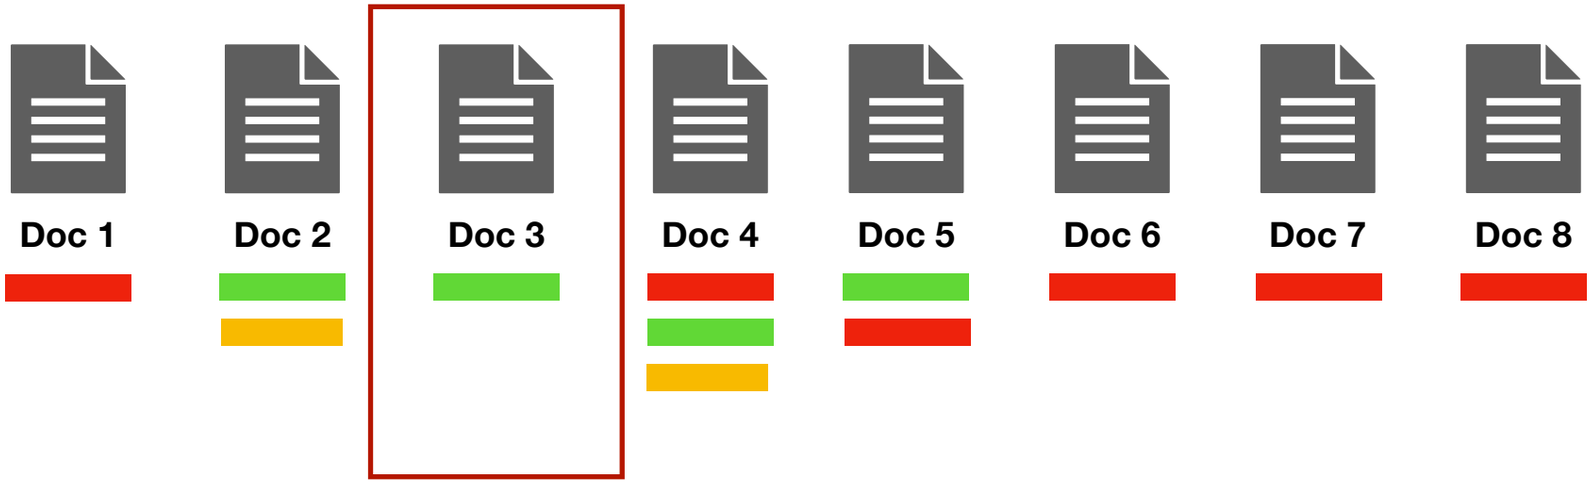

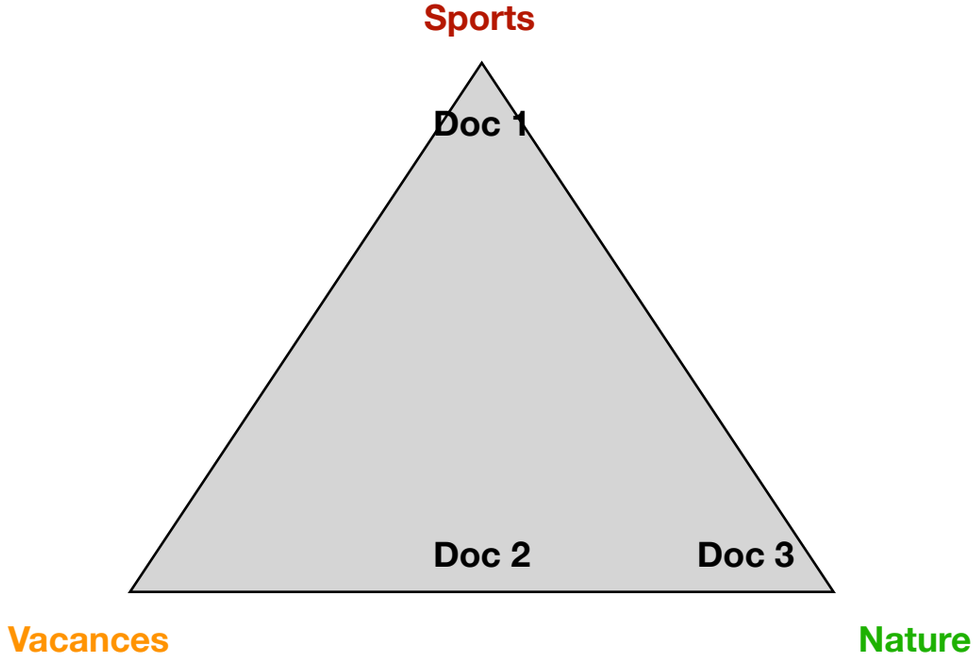

Latent Dirichlet Allocation : zoom sur Dirichlet

Dirichlet distribution (dimension 3) :

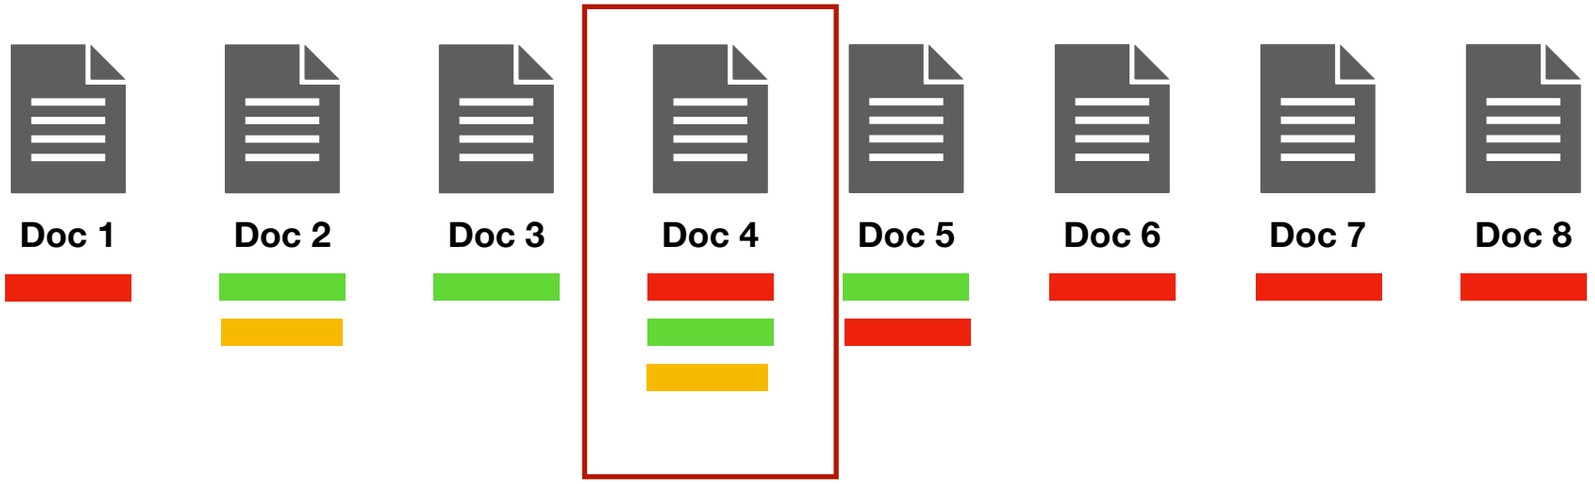

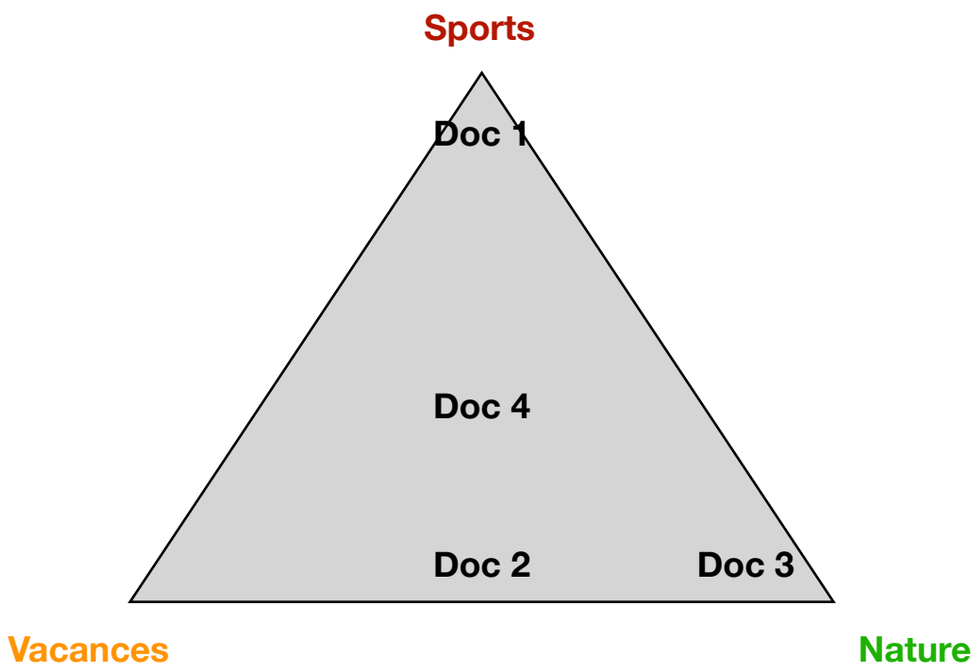

Latent Dirichlet Allocation : zoom sur Dirichlet

Dirichlet distribution (dimension 3) :

TOPICS

- Vacances
- Nature
- Sports

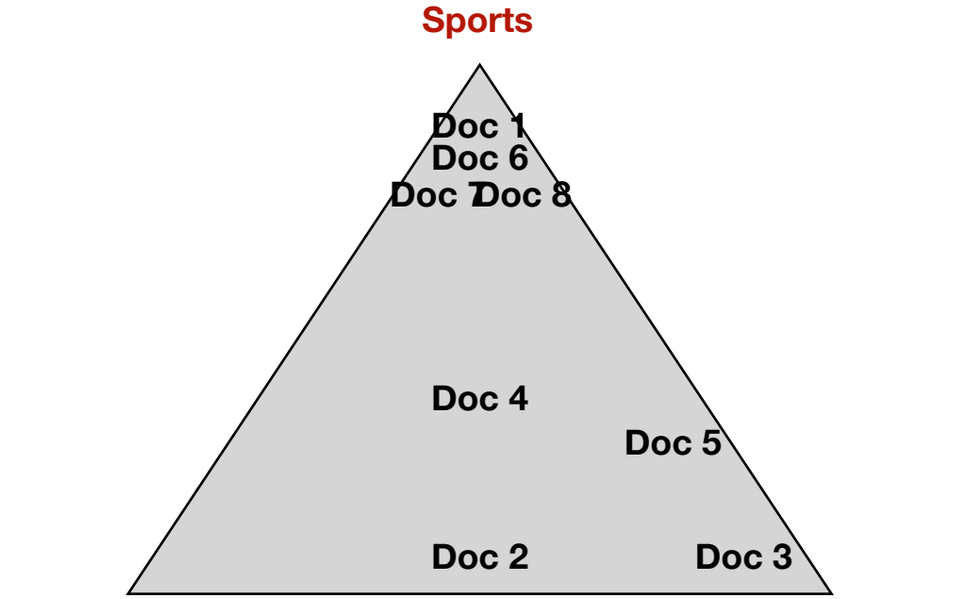

Latent Dirichlet Allocation : zoom sur Dirichlet

Dirichlet distribution (dimension 3) :

TOPICS

- Vacances
- Nature
- Sports

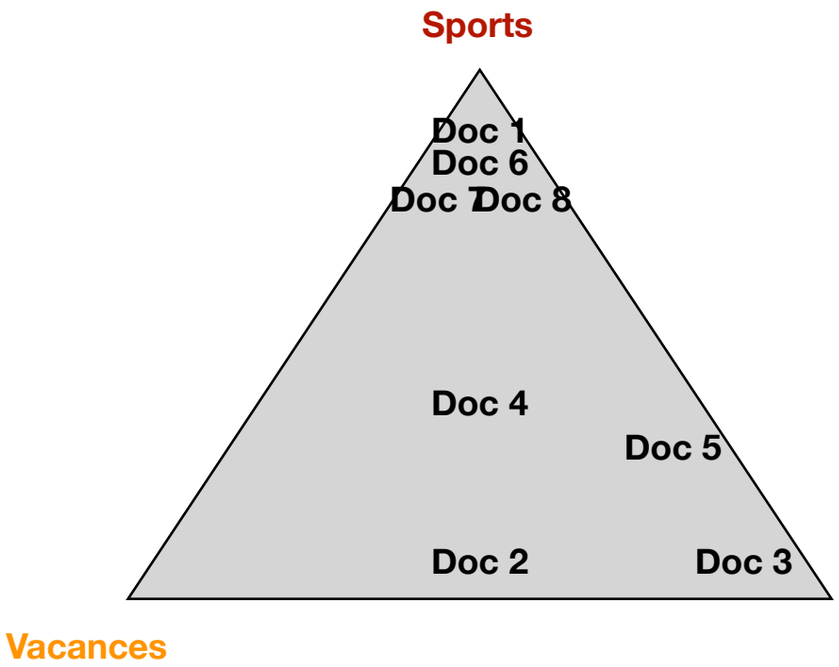

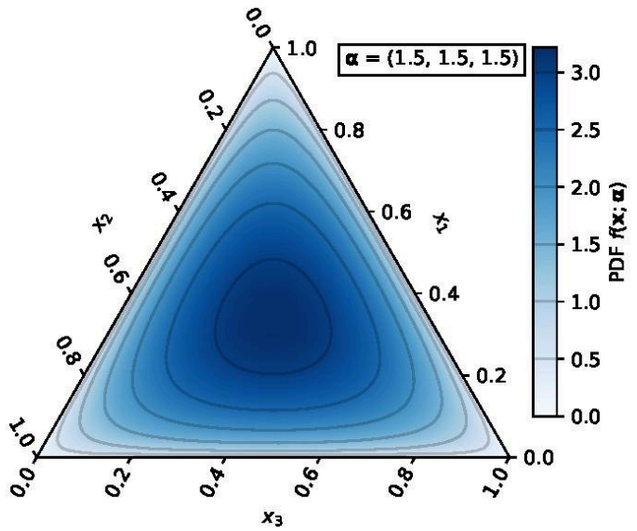

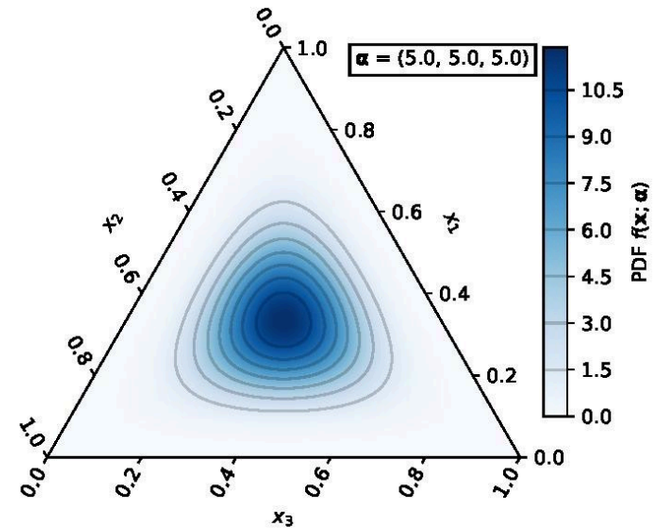

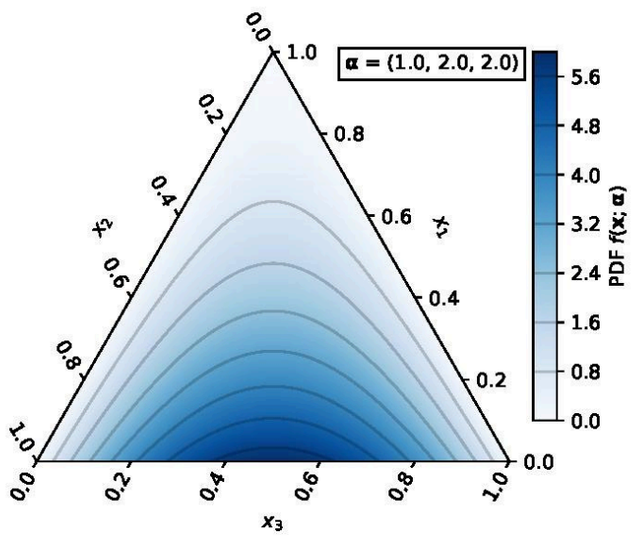

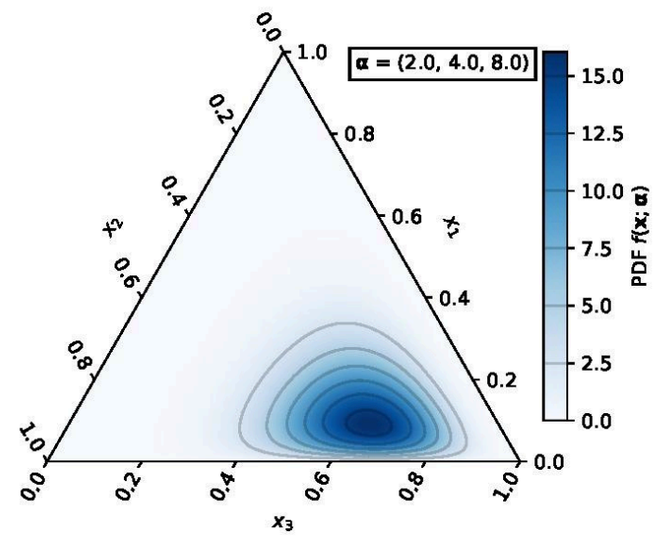

Latent Dirichlet Allocation : zoom sur Dirichlet

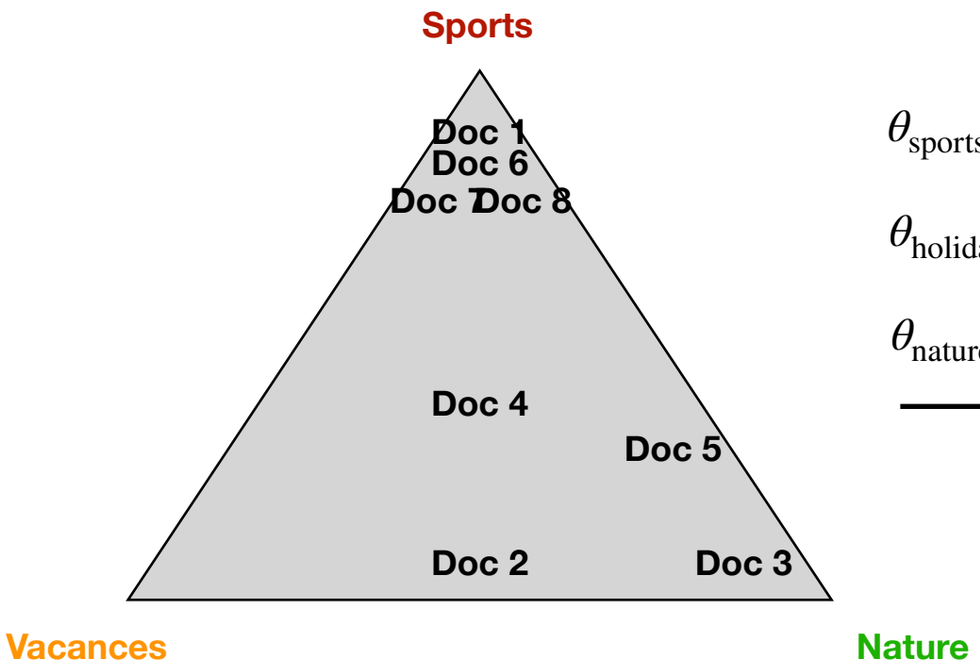

$\theta_{\text{sports}} = P(\text{sports} \mid \alpha) = 0.7$

$\theta_{\text{holiday}} = P(\text{vacances} \mid \alpha) = 0.1$

$\theta_{\text{nature}} = P(\text{nature} \mid \alpha) = 0.2$

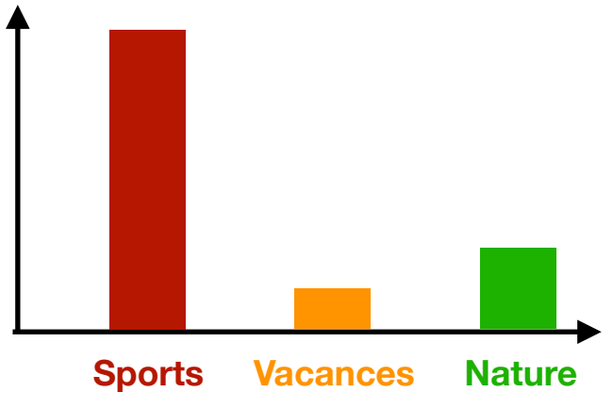

Dirichlet distribution
« distribution de distribution »

Multinomial distribution

Résumé

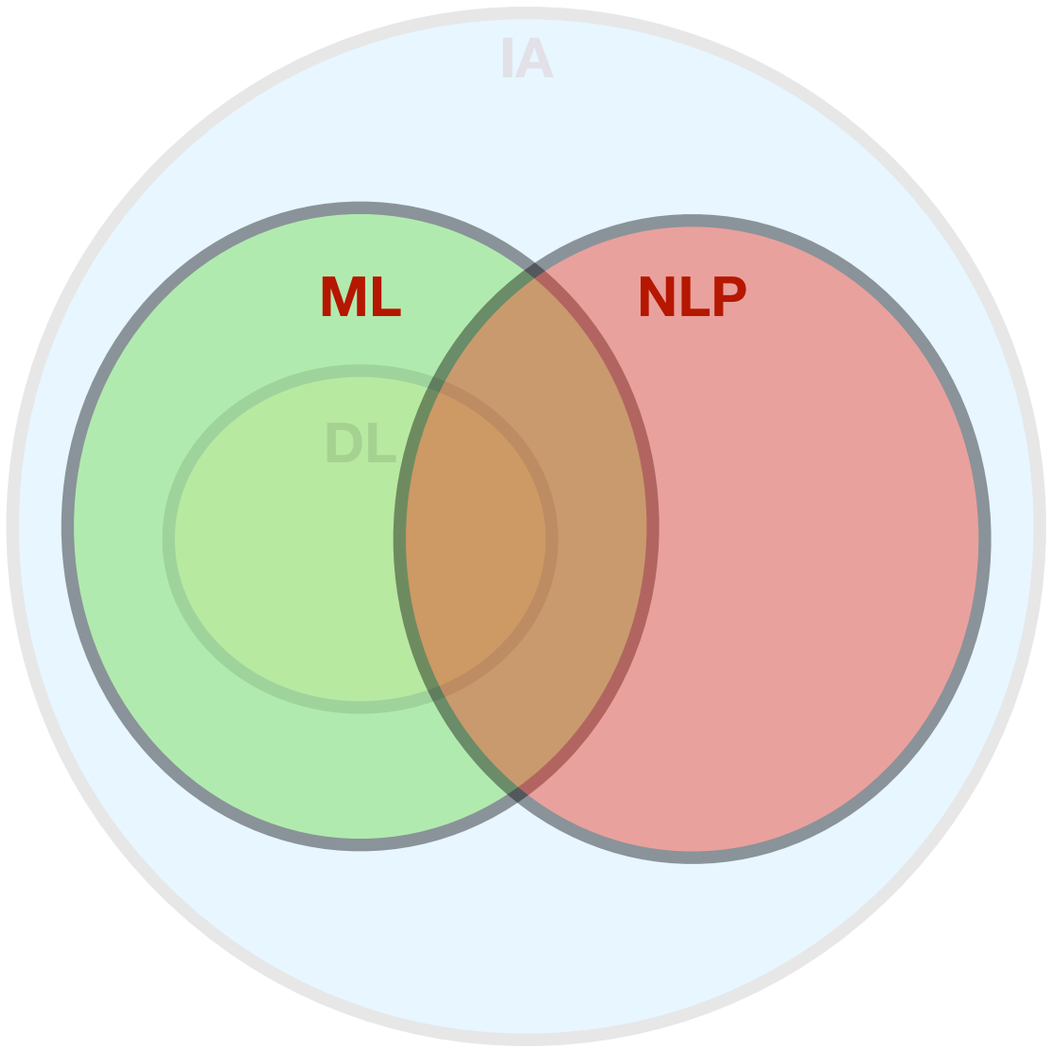

Topic modeling

Topic models :

- **LSA**
- **LDA**

TP sur le topic modeling :
https://curiousml.github.io/