

# Catégorisation de produits

Du sémantique (k-NN) à l'image (CNN)



## **Chef d'activité data chez Cdiscount**

Je travaille avec deux équipes pour exploiter au maximum la donnée associée aux produits

Référentiel : structuration et complétion des données décrivant les produits chez Cdiscount

### **Parcours**

Data scientist chez  
**Cdiscount** depuis 2017  
Data scientist chez MFG  
Labs (Paris)  
Thèse Thales – LIP6 (Paris)  
Telecom Bretagne (Brest)

### **Data science**

L'exploitation de sources  
de données à disposition  
pour assister l'humain  
dans ses activités

### **Modèles**

Factorisation matricielle  
Séparateur à Vaste Marge

### **Technos**

SQL (PSQL/HiveQL)  
Python

# Sommaire



1

**Pourquoi le catégoriseur ?**

2

**Classification sémantique**

3

**Classification par l'image**

4

**La maintenance du catégoriseur**



**Cdiscount**

## **Cdiscount**

Plateforme française de vente de produits et de services pour répondre aux besoins de nos clients

### **1998**

Création à **Bordeaux** de  
Cdiscount  
Vente de CD à prix  
discount

### **2012**

Lancement de la  
Marketplace pour  
permettre à d'autres  
vendeurs de proposer  
leurs produits

### **2019**

30 millions de produits et  
services disponibles sur  
cdiscount.com



## Marketplace

Cdiscount héberge les propositions commerciales d'autres vendeurs et met en relation avec ses clients des vendeurs du monde entier

### Offre et produit

Les vendeurs placent des offres (prix, stock, mode de livraison) sur des produits

### Intégration en continu

La création manuelle est possible mais la majorité est automatisée

### Volumes importants

~ 1 M demandes de créations de produits par semaine



## Catégorie

Une catégorie est une typologie de produit et est unique pour chaque produit.

Elle caractérise les propriétés du produit et structure sa fiche sur le site

## Arborescence

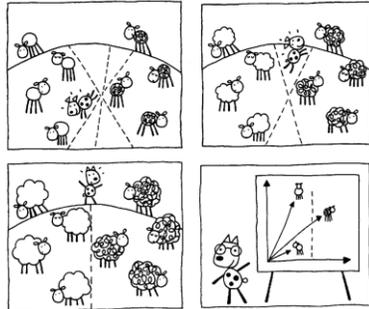
Les catégories sont regroupées dans une arborescence à quatre niveaux

## Evolutive

L'arbre des catégories est amélioré en continu : créations, déplacements et suppressions de catégories

## 8000 catégories

Au niveau le plus fin. Chaque produit doit avoir une catégorie



## Apprentissage supervisé

Etant donné un ensemble d'exemples pour lesquels la réponse est connue, créer un modèle capable de prédire la meilleure étiquette possible pour de nouveaux exemples

### Minimisation

Une fonction  $f(x)$  qui prédit  $y$  dont les paramètres sont estimés pour minimiser un coût

### X un vecteur

Les données sont représentées par un vecteur  $x$  dont chaque dimension est une caractéristique

### Feature engineering

Le choix des caractéristiques peut être manuel (ex. : TF-IDF) ou laissé au modèle (ex. : deep learning)



## Précision supérieure à 90 %

Seuil exigé après estimation de la précision humaine

### Validation manuelle

La qualité des prédictions est évaluée, sur un échantillon, chaque semaine

### Taux de classification

Les produits pour lesquels le classifieur n'est pas assez confiant demandent un traitement supplémentaire

### Qualité

Maintenir le catalogue de plus de 30 millions de produits bien catégorisé

# Sommaire



1

Pourquoi le catégoriseur ?

2

Classification sémantique

3

Classification par l'image

4

La maintenance du catégoriseur

# Les éléments d'une fiche produit

## Titre

Texte court caractérisant le produit visible également sur les listes de produit

## Image(s)

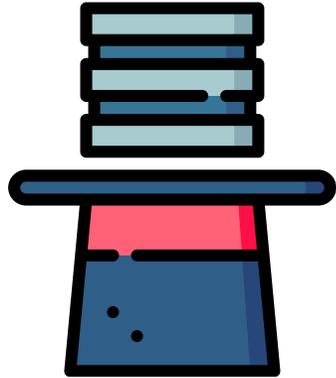
Visuel représentant le produit, éventuellement mis en situation, visible également sur les listes de produit

## Description

Texte naturel long permettant de décrire le produit et ses caractéristiques

## Caractéristiques

Texte structuré listant les propriétés techniques du produit (dimensions, poids, taille d'écran, nombre de places...)



## Vectorisation

Transformation du texte naturel sous forme de vecteur pour pouvoir l'utiliser dans un algorithme d'apprentissage

## Sac de mot

Représentation vectorielle où chaque dimension représente un mot observé

## TF-IDF

Calcule une valeur pour chaque mot de chaque produit

TF : occurrences dans le document

IDF : inverse des occurrences dans l'ensemble des produits

## *Embeddings / word2vec*

Apprentissage d'un espace vectoriel latent où chaque mot est un vecteur



## Vote des produits les plus ressemblants

1ere étape : sélection des k produits de la base d'apprentissage les plus ressemblants

2eme étape : vote entre ces k produits pour prédire la catégorie

### Base d'apprentissage

Ensemble de m produits dont la catégorie est connue

### Distance

Fonction attribuant une valeur réelle à une paire de vecteurs d'autant plus grande que les vecteurs sont distincts

### Décision locale

Seuls les k voisins interviennent dans une décision



## Garantir la précision

L'objectif premier du classificateur est sa précision

Utilisation de seuils de confiance pour rejeter les prédictions moins certaines

## Base d'apprentissage

Sélectionner un échantillon de produits correctement catégorisés représentatif de la diversité du catalogue au sein de chaque catégorie

## TF-IDF + k-NN

Transformation du texte brut en vecteur puis attribution d'une catégorie avec un score

## Seuils de confiance

Si le score prédit est inférieur à un seuil, dépendant de la catégorie, la prédiction est rejetée

# Sommaire



1

Pourquoi le catégoriseur ?

2

Classification sémantique

3

Classification par l'image

4

La maintenance du catégoriseur

# Les éléments d'une fiche produit

## Titre

Texte court caractérisant le produit visible également sur les listes de produit

## Image(s)

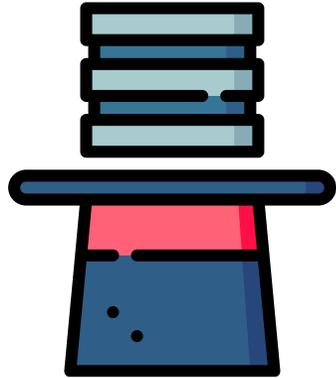
Visuel représentant le produit, éventuellement mis en situation, visible également sur les listes de produit

## Description

Texte naturel long permettant de décrire le produit et ses caractéristiques

## Caractéristiques

Texte structuré listant les propriétés techniques du produit (dimensions, poids, taille d'écran, nombre de places...)



## Vectorisation

Transformation de l'image sous forme de vecteur pour pouvoir l'utiliser dans un algorithme d'apprentissage

## Aplatissement

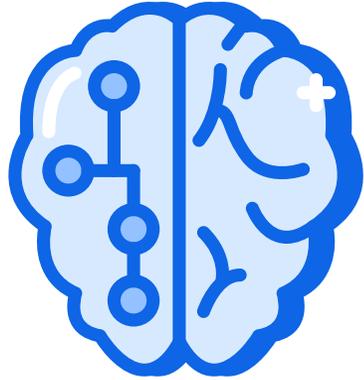
Une image peut être vue comme trois matrices de pixel, une par dimension dans l'espace de couleur (RVB)

## Points d'intérêt

Résume l'information autour de points d'intérêts (*SIFT*)

## Deep learning

Laisser en charge au modèle l'apprentissage du « bon vecteur »



## Réseau de neurones

Formalisation mathématique d'un ensemble de modèles connectés pour produire une décision finale

### 1958

Rosenblatt propose le perceptron

Somme pondérée des entrées

### 1988

Rumelhart, Le Cun : rétropropagation

Plusieurs sommes pondérées, ensuite repondérées

### 2012

Krizhevsky utilise un CNN dans la compétition ImageNet

L'architecture du réseau permet de trouver le « bon vecteur »



## Garantir la précision

L'objectif premier du classificateur est sa précision

Utilisation de seuils de confiance pour rejeter les prédictions moins certaines

## Base d'apprentissage

Sélectionner un échantillon de produits correctement catégorisés représentatif de la diversité du catalogue au sein de chaque catégorie

## Architecture DL

Transformation du texte brut en vecteur puis attribution d'une catégorie avec un score

## Seuils de confiance

Si le score prédit est inférieur à un seuil, dépendant de la catégorie, la prédiction est rejetée

# Sommaire



1

Pourquoi le catégoriseur ?

2

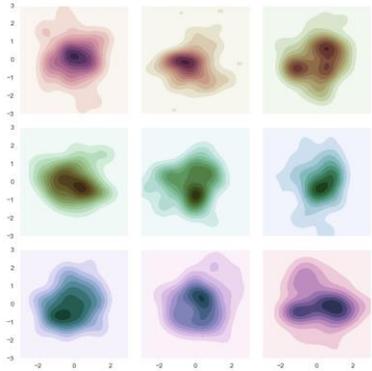
Classification sémantique

3

Classification par l'image

4

La maintenance du catégoriseur



## Distribution sous-jacente aux données

Classiquement, les modèles d'apprentissage supposent une distribution fixe dans le temps qui génère les données d'apprentissage et d'entraînement

## Apprentissage vs monde réel

Biais dans la sélection des produits formant la base d'apprentissage

## Evolution des produits

Les produits vendus sur Cdiscount évoluent et leur description visuelle et textuelle avec eux

## Nouveaux produits

Régulièrement, de nouveaux types de produits apparaissent



## Equilibre des catégories

Un modèle d'apprentissage ne peut prédire que des catégories qu'il a déjà observées avant et suppose souvent une répartition équitable des exemples connus parmi les catégories possibles

### Déséquilibre naturel

Toutes les catégories n'ont pas le même nombre de produits : fendeur de bûches vs décorations de Noël

### Modèle textuel

Possible d'entraîner le modèle sur un ordinateur classique en quelques heures

### Modèle visuel

Infrastructure spécifique nécessaire et apprentissage (et validation) long



## L'humain est nécessaire

La gestion du bon fonctionnement au jour le jour d'un tel système de classification nécessite une supervision humaine

### Base d'apprentissage

La bonne sélection des produits à utiliser comme référence est la clé des performances

### Evaluation du modèle

Une personne experte sur l'arbre des catégories peut évaluer la précision des prédictions et intervenir si besoin

### Communication

Un score entre 0 et 1 n'est pas une explication en soit lors des échanges en interne ou avec nos vendeurs



Merci !

**Aux organisateurs**

Pour cette journée d'échange autour de la data science

**A vous**

Pour votre écoute lors de cette présentation