

# REsearch and methodology in Data Science

## Cours 3 – Sélection de variables

Olivier Schwander

`<olivier.schwander@sorbonne-universite.fr>`

Master DAC  
Sorbonne Université



2023-2024

# Sélection de caractéristique

**Sélection de caractéristiques** sélectionner un sous-ensemble des caractéristiques existantes:


- ▶ Approches de type **Filtering**
- ▶ Approches de type **Wrappers**

**Extraction de caractéristiques** combiner des caractéristiques existantes pour obtenir un (petit nombre) de caractéristiques pertinentes:

- ▶ Approches de type **PCA**
- ▶ Approches de type **Auto-Encodage**
- ▶ Approches de type **Representation Learning (Deep Learning)**


## Sélection de caractéristiques

- ▶ Soit un ensemble d'entrée  $\mathcal{X} = \mathbb{R}^n$  tel que  $x = (x_1, x_2, \dots, x_n)$
- ▶ On cherche à trouver un sous-ensemble de dimensions caractérisé par un ensemble  $\mathcal{I}$  d'index dans  $[1; n]$
- ▶ Etant donné  $\mathcal{I} = (i_1, \dots, i_M)$ , le nouvel espace d'entrée sera caractérisé par  $x = (x_{i_1}, x_{i_2}, \dots, x_{i_M})$



## Sélection de caractéristiques

- ▶ Très grand espace de recherche
- ▶ Besoin de méthodes approchées



# Deux approches

## **Méthodes de filtrage:** sélection *a priori*

- ▶ Estimation du pouvoir prédictif de chaque caractéristique
- ▶ Étude mono-dimensionnelle de chaque caractéristique
- ▶ Sélection de celles avec le pouvoir prédictif le plus élevé

## **Méthodes de wrappers:** sélection *a posteriori*

- ▶ Choix basé sur la qualité du modèle obtenu

# Corrélation

Mesure de l'intensité de la liaison entre deux variables

**Corrélation linéaire** Soit la variable  $X_i$  (caractéristique) et la variable  $Y$  (étiquette):

$$\text{Corr}(X_i, Y) = \frac{\text{Cov}(X_i, Y)}{\sqrt{\text{Var}(X_i)\text{Var}(Y)}}$$

- ▶  $\text{Cov}(X_i, Y) = E[X_i Y] - E[X_i]E[Y] = E[(X_i - E[X_i])(Y - E[Y])]$
- ▶  $\text{Cov}(X_i, Y) = 0$  ssi  $X_i$  et  $Y$  sont indépendantes

## Corrélation empirique

**Comme d'habitude** lois inconnues pour  $X_i$  et  $Y$

**Estimateur**

$$R(i) = \frac{\sum_{k=1}^N (x_i^k - \bar{x}_i)(y^k - \bar{y})}{\sqrt{\sum_{k=1}^N (x_i^k - \bar{x}_i)^2 \sum_{k=1}^N (y^k - \bar{y})^2}}$$

- ▶ Dépendance linéaire
- ▶ Versions non-linéaires
- ▶ **Corrélation n'est pas causalité**

# Méthodes de filtrage

- ▶ Tri des variable par ordre de pertinence
- ▶ Conservation des caractéristiques les plus pertinentes

## Avantage

- ▶ Chaque caractéristique est analysée **indépendamment des autres.**
- ▶ Rapide

## Limite

- ▶ Chaque caractéristique est analysée **indépendamment des autres.**
- ▶ Une variable pourrait être utile en combinaison avec une autre

# Méthodes de wrappers

- ▶ Choisir un sous-ensemble de caractéristiques
- ▶ Entraîner un modèle et l'évaluer
- ▶ Choisir le sous-ensemble qui donne les meilleurs performances

## Coûteux:


- ▶ Nombre exponentiel de sous-ensembles
- ▶ Entraînement des modèles

**Recherche gloutonne:** ajout graduel de caractéristiques basé sur un score à chaque pas de l'algorithme

**Attention:** le score doit refléter la performance du système (en généralisation)

# Méthodes embarquées

De moins en moins de caractéristiques



Recursive Feature Elimination (RFE) SVM. *Guyon-Weston, 2000. US patent 7,117,188*

# Conclusion

## Grandes lignes d'un projet ML

- ▶ Définir la tâche et y réfléchir
- ▶ Analyser les données (statistiques descriptives, feature engineering)
- ▶ Établir un protocole expérimental
- ▶ Choisir un modèle et évaluer ses performances
- ▶ Présenter le travail