

# Exemple d'analyse de données

Fabrice Rossi

Université Paris 1

# Présentation des données

## Contexte

- ▶ spectres proche infrarouge d'échantillons de vin
- ▶ but pratique : calculer le taux d'alcool dans le vin à partir du spectre


## Caractéristiques

- ▶ 124 spectres, dont 30 réservés à l'évaluation finale
- ▶ 256 variables : nombre d'onde compris entre 400 et 4000  $\text{cm}^{-1}$

## Analyse


- ▶ trop de variables : 256 variables contre 94 objets (pour l'apprentissage)
- ▶ modèle linéaire simplifié

# Spectres




⇒ Quelques spectres atypiques

# Spectres




⇒ Trois spectres atypiques

# Spectres « propres »




On conserve les spectres atypiques les moins extrêmes

# Variable à prédire




Quelques valeurs extrêmes : peuvent être utiles pour l'apprentissage

# Lien variable à prédire / variables explicatives







# Lien variable à prédire / variables explicatives



# Lien variable à prédire / variables explicatives




# Modèle linéaire simple




Modèle linéaire simple :  $Alcool = \alpha X_1 + \beta$


# Modèle linéaire simple : prévisions




# Représentation universelle




# Représentation des erreurs



# Modèle linéaire plus riche



# Modèle linéaire plus riche



# Choix du modèle


## Candidats

- ▶ modèle linéaire réduit : choix des variables
- ▶ modèle linéaire régularisé *ridge*
- ▶ modèle linéaire régularisé *lasso*


## Méthode

- ▶ validation croisée (3 blocs, par exemple)
- ▶ choix du meilleur modèle
- ▶ et choix du paramètre du modèle (nombre de variables, paramètre de compromis)
- ▶ construction du modèle complet
- ▶ évaluation sur l'ensemble de test

# Choix de variables



# Choix de variables



# Remarques

## Validation croisée


- ▶ chaque bloc correspond à un ordre spécifique pour les variables
- ▶ on agrège des **prévisions** pas des modèles
- ▶ on sélectionne une **classe** de modèles (des paramètres) pas un modèle
- ▶ on doit construire un modèle dans la classe après sélection
- ▶ le modèle final dépend de **toutes** les données d'apprentissage : on ne peut pas estimer ses performances sur l'ensemble d'apprentissage

## Ensemble de test

- ▶ données indépendantes pour l'évaluation finale
- ▶ ne doit jamais être utilisé pour autre chose
- ▶ en particulier le choix du modèle final est fait sans utiliser l'ensemble de test


# Meilleur modèle

30 variables




# Meilleur modèle (tricherie)

12 variables




# Modèle trop faible

3 variables



# Modèle trop puissant

90 variables



# Meilleur modèle

30 variables

