

# Introduction à la régression

## cours n°1

ENSM.SE – 1A

Olivier Roustant - Laurent Carraro

# Problématique de la régression

➤ Expliquer une **réponse**  $y$   
grâce à des **prédicteurs**  $x_1, \dots, x_p$


... dans un contexte incertain


... à partir d'expériences

... dans un but **prédictif**

# Exemple 1 : entreprise d'énergie


➤ But : prévoir la consommation électrique






## Exemple 2 : société financière

➤ But : estimer le risque d'un portefeuille




- Exemple. Soit un portefeuille constitué de 40% d'actions Lafarge et 60% Carrefour
  - Quel(s) prédicteur(s) choisir ?
  - Quel modèle proposer ?

## Portefeuille : 40% Lafarge ; 60% Carrefour



## Exemple 3


- Réponse : concentration en ions  $\text{SO}_4^{--}$
- Prédicteur : concentration en ions  $\text{NO}_3^-$
- Objectif : prévoir la concentration en ions  $\text{SO}_4^{--}$  connaissant celle en ions  $\text{NO}_3^-$



Source : école des mines de Douai

Hétéroscédasticité  
= variance non  
constante

## Résolution du problème d'hétéroscédasticité



# Modélisation statistique : démarche

- Travail préliminaire
  - Etude des données
  - Choix des prédicteurs
- ⇒ proposition d'un modèle de régression
  - Plusieurs modèles possibles
- Etude statistique
  - Estimation, analyse des résultats
  - Validation du modèle : vérification des hypothèses
  - Si non validé, retour à la 1ère étape !

## Dans ce cours...

- On se limite à 1 ou 2 prédicteurs
- On n'étudiera pas de données temporelles sauf si elles sont indépendantes dans le temps
  - Nécessite des connaissances en séries temporelles

# Définition du modèle linéaire

- Y vecteur des réponses
- X matrice du plan d'expériences
- $\beta$  vecteurs des paramètres
- $\varepsilon$  vecteurs des écarts au modèle :


$$Y = X\beta + \varepsilon$$

$\varepsilon_1, \dots, \varepsilon_n$  indépendants et de même loi  $N(0, \sigma^2)$

# Interprétation


i.i.d. =  
indépendantes et  
identiquement  
distribuées

Générateur de jeux de  $n$  réponses i.i.d et de loi normale




# Exemples (1/2)

Que penser du modèle sur ces données ?



## Exemples (2/2)



# Exercice

On suppose que  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  sont des v.a. i.i.d de loi  $N(0, \sigma^2)$ . Dans quels cas peut-on se ramener à un modèle de régression linéaire ?

1.  $y_i = \beta_0 + \beta_1 x_i^2 + \varepsilon_i$
2.  $\log(y_i) = \beta_0 + \beta_1 \log(x_i) + \varepsilon_i$
3.  $y_i = \beta_0 \exp(\beta_1 x_i) \times |\varepsilon_i|$
4.  $y_i = \beta_0 / (1 + \beta_1 x_i) + \varepsilon_i$