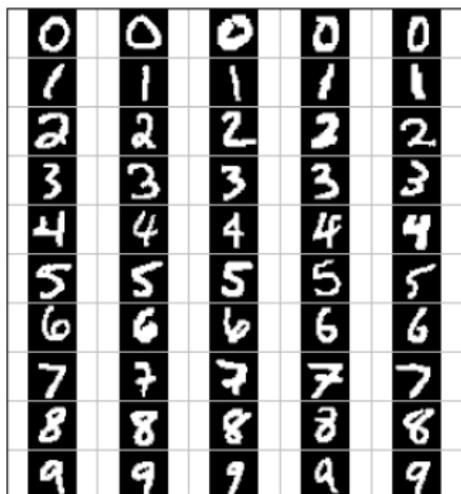


Regression avancée  
Chapitre 1 : introduction

Agathe Guilloux  
Professeure au LaMME - Université d'Évry - Paris Saclay

## Exemples

## Des chiffres



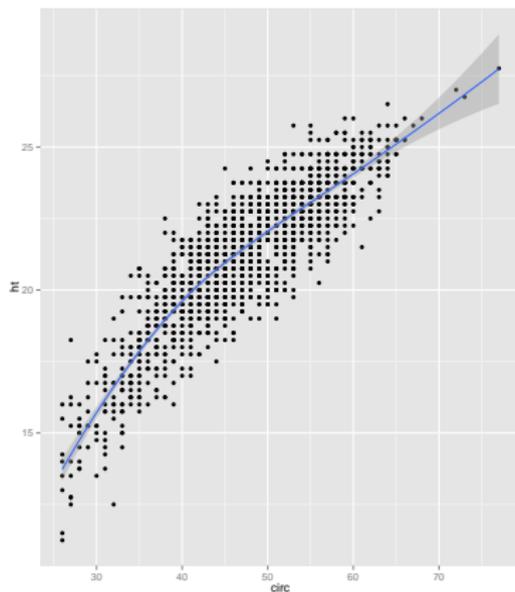
- ▶ Lire un code postal sur une enveloppe.
- ▶ But : assigner un chiffre à une image.
- ▶ Input : image.
- ▶ Output : chiffre correspondant.

## Spam detection



- ▶ Données : emails.
- ▶ Input : email.
- ▶ Output : Spam or No Spam.

# Eucalyptus



- ▶ But : prédire la hauteur en fonction de la circonférence.
- ▶ Input : circonférence.
- ▶ Output : hauteur.

## Données “Vulnerability”, Patt et al., PNAS (2009)

Les pays les moins développés sont-ils plus vulnérables aux changements climatiques ?

Les auteurs ont voulu expliquer  $\ln\_death\_risk$ , log du risque mortel dû aux évènements climatiques en fonction

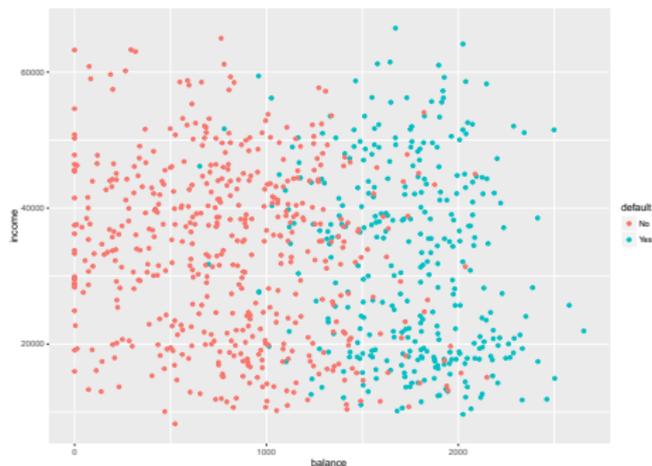
- ▶ du log du nombre d'évènements climatiques  $\ln\_death\_risk$
- ▶ du log de la fertilité  $\ln\_fertility$
- ▶ de l'indice de développement humain  $hdi$  (United Nations)
- ▶ du log de la population  $\ln\_pop$

Ils concluent que le développement socio-économique a un lien sur la fragilité aux événements climatiques, et ce lien pourrait se révéler dans le deuxième quart du 21<sup>ème</sup> siècle.

## Visualisation des données "Vulnerability"

country_name	ln_events	ln_fert	hdi	ln_pop	ln_death_risk
Albania	2.3025850	1.2383740	0.7530000	4.0061200	-0.7102835002
Algeria	3.4965080	1.5993880	0.7025000	6.2838850	0.8961844999
Angola	3.0445230	1.9459100	0.4460000	5.5560560	0.2246879996
Argentina	3.6375860	1.0116010	0.8525001	6.4835150	-1.1036180004
Armenia	1.3862940	0.7654679	0.7380000	3.9765620	-2.3671239981
Australia	4.3944490	0.7654679	0.9480000	5.8379250	-1.0504329996
Austria	3.0910430	0.5306283	0.9330000	4.9908860	-1.4073670018
Azerbaijan	1.7917590	1.0986120	0.7460000	4.9572340	-2.1846459984
Bahamas	2.3025850	1.0116010	0.8325000	1.6226830	1.3217560000
Bangladesh	4.8362820	1.5475620	0.5000000	7.8287280	4.1112999999
Belarus	1.6094380	0.5596158	0.7795000	5.1651670	-3.2192569975

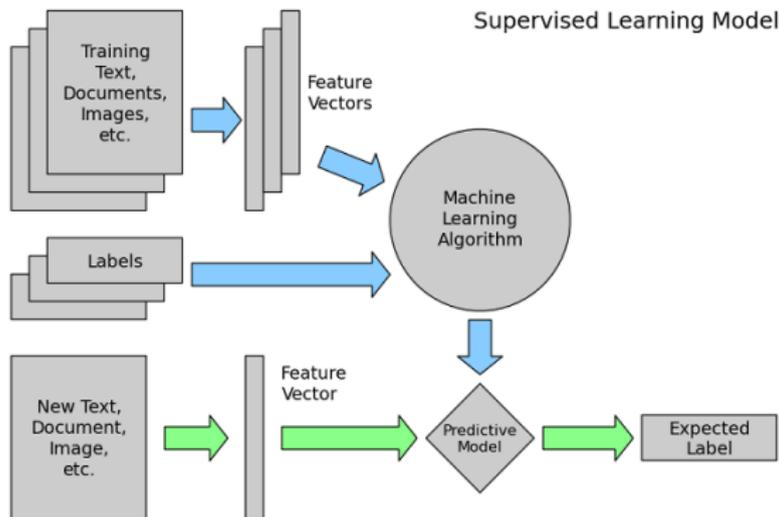
## Défaut de crédit



- ▶ But : prédire le défaut (ou non de paiement)
- ▶ Input : `balance` : le solde du compte client, `income` : les revenus du client
- ▶ Output : défaut Yes ou No

## Apprentissage statistique supervisé

# Apprentissage statistique supervisé



- ▶ Input : covariables, variables explicatives, features  $\mathbf{X} = (X^1, \dots, X^p)$
- ▶ Output : variable à expliquer, variable dépendante, réponse, label  $\mathbf{Y}$

## Données "Vulnerability"

country_name	ln_events	ln_fert	hdi	ln_pop	ln_death_risk
Albania	2.3025850	1.2383740	0.7530000	4.0061200	-0.7102835002
Algeria	3.4965080	1.5993880	0.7025000	6.2838850	0.8961844999
Angola	3.0445230	1.9459100	0.4460000	5.5560560	0.2246879996
Argentina	3.6375860	1.0116010	0.8525001	6.4835150	-1.1036180004
Armenia	1.3862940	0.7654679	0.7380000	3.9765620	-2.3671239981
Australia	4.3944490	0.7654679	0.9480000	5.8379250	-1.0504329996
Austria	3.0910430	0.5306283	0.9330000	4.9908860	-1.4073670018
Azerbaijan	1.7917590	1.0986120	0.7460000	4.9572340	-2.1846459984
Bahamas	2.3025850	1.0116010	0.8325000	1.6226830	1.3217560000
Bangladesh	4.8362820	1.5475620	0.5000000	7.8287280	4.1112999999
Belarus	1.6094380	0.5596158	0.7795000	5.1651670	-3.2192569975

Dans notre exemple :

- ▶  $X^1$  est ln\_events
- ▶  $X^2$  est ln\_fert
- ▶  $X^3$  est hdi
- ▶  $X^4$  est ln\_pop et
- ▶  $Y$  est ln\_death\_risk

# Données

## Données d'entraînement / learning set / training set

$\mathcal{D}_n = \{(\mathbf{X}_1, Y_1), \dots, (\mathbf{X}_n, Y_n)\}$  avec pour chaque individu  $i = 1, \dots, n$

- ▶ des features

$$\mathbf{X}_i = (X_i^{(1)}, X_i^{(2)}, \dots, X_i^{(d)}) \in \mathcal{X}$$

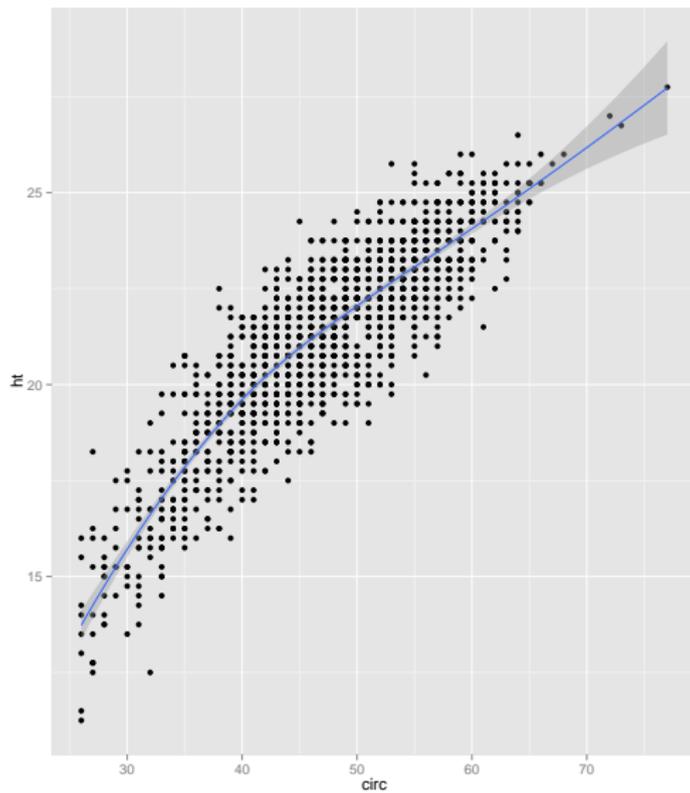
- ▶ un label  $Y_i \in \mathcal{Y}$

Hypothèse : les  $(\mathbf{X}_i, Y_i)$  sont i.i.d. de loi  $\mathbf{P}$  inconnue.

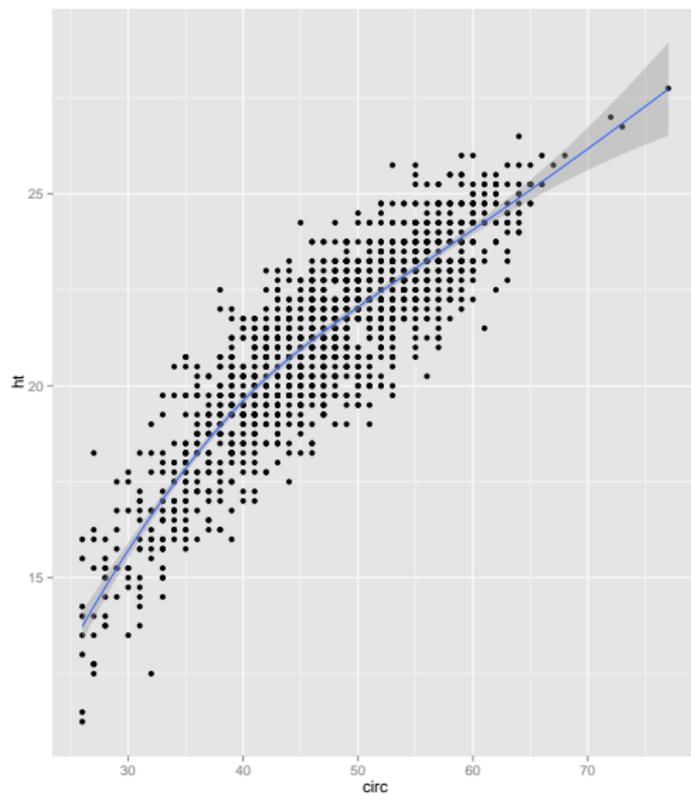
Deux exemples courants :

- ▶  $\mathbf{X} \in \mathbb{R}^d$  and  $Y \in \{-1, 1\}$  (classification)
- ▶ et  $\mathbf{X} \in \mathbb{R}^d$  and  $Y \in \mathbb{R}$  (régression).

# Eucalyptus



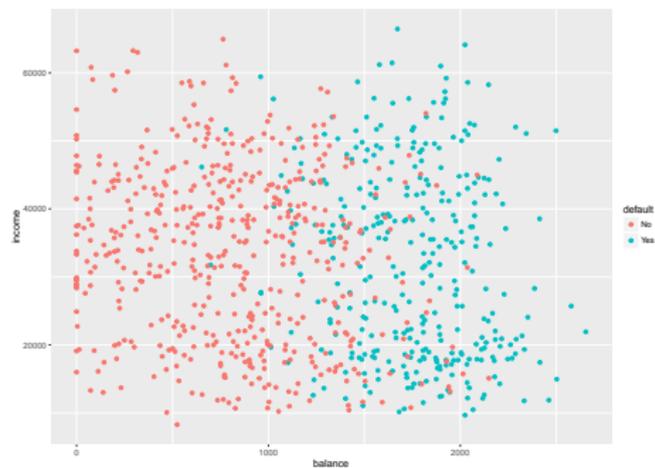
# Eucalyptus




▶  $\mathcal{X} = \mathbb{R}$

▶  $\mathcal{Y} = \mathbb{R}$

# Défaut de crédit



## Défaut de crédit



- ▶  $\mathcal{X} = \mathbb{R}^2$
- ▶  $\mathcal{Y} = \{\text{Yes}, \text{No}\}$  ou  $\{0, 1\}$

## Données "Vulnerability"

country_name	ln_events	ln_fert	hdi	ln_pop	ln_death_risk
Albania	2.3025850	1.2383740	0.7530000	4.0061200	-0.7102835002
Algeria	3.4965080	1.5993880	0.7025000	6.2838850	0.8961844999
Angola	3.0445230	1.9459100	0.4460000	5.5560560	0.2246879996
Argentina	3.6375860	1.0116010	0.8525001	6.4835150	-1.1036180004
Armenia	1.3862940	0.7654679	0.7380000	3.9765620	-2.3671239981
Australia	4.3944490	0.7654679	0.9480000	5.8379250	-1.0504329996
Austria	3.0910430	0.5306283	0.9330000	4.9908860	-1.4073670018
Azerbaijan	1.7917590	1.0986120	0.7460000	4.9572340	-2.1846459984
Bahamas	2.3025850	1.0116010	0.8325000	1.6226830	1.3217560000
Bangladesh	4.8362820	1.5475620	0.5000000	7.8287280	4.1112999999
Belarus	1.6094380	0.5596158	0.7795000	5.1651670	-3.2192569975

## Données "Vulnerability"

country_name	ln_events	ln_fert	hdi	ln_pop	ln_death_risk
Albania	2.3025850	1.2383740	0.7530000	4.0061200	-0.7102835002
Algeria	3.4965080	1.5993880	0.7025000	6.2838850	0.8961844999
Angola	3.0445230	1.9459100	0.4460000	5.5560560	0.2246879996
Argentina	3.6375860	1.0116010	0.8525001	6.4835150	-1.1036180004
Armenia	1.3862940	0.7654679	0.7380000	3.9765620	-2.3671239981
Australia	4.3944490	0.7654679	0.9480000	5.8379250	-1.0504329996
Austria	3.0910430	0.5306283	0.9330000	4.9908860	-1.4073670018
Azerbaijan	1.7917590	1.0986120	0.7460000	4.9572340	-2.1846459984
Bahamas	2.3025850	1.0116010	0.8325000	1.6226830	1.3217560000
Bangladesh	4.8362820	1.5475620	0.5000000	7.8287280	4.1112999999
Belarus	1.6094380	0.5596158	0.7795000	5.1651670	-3.2192569975

►  $\mathcal{X} = \mathbb{R}^4$

►  $\mathcal{Y} = \mathbb{R}$

## Spam detection



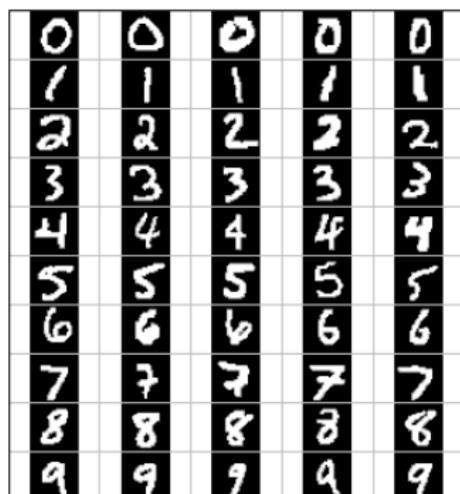
- ▶ Input : email.
- ▶ Output : Spam or No Spam.

## Spam detection



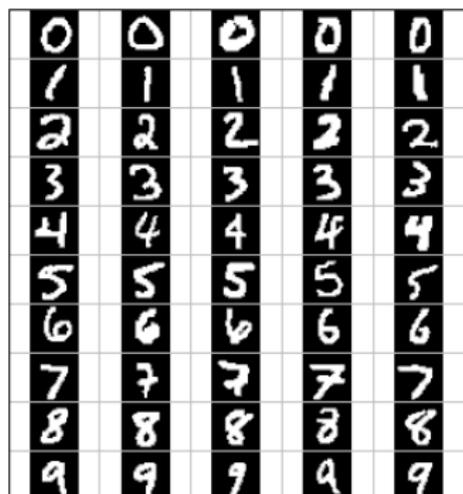
- ▶ Input : email.
- ▶ Output : Spam or No Spam.
  
- ▶  $\mathcal{X} = ??? \rightarrow$  features design
- ▶  $\mathcal{Y} = \{0, 1\}$

## Des chiffres



- ▶ Input : image.
- ▶ Output : chiffre correspondant.

## Des chiffres



- ▶ Input : image.
- ▶ Output : chiffre correspondant.
  
- ▶  $\mathcal{X} = ??? \rightarrow$  features design
- ▶  $\mathcal{Y} = \{0, 1, 2, \dots, 9\}$

# Prédicteur / predictor

## Prédicteur

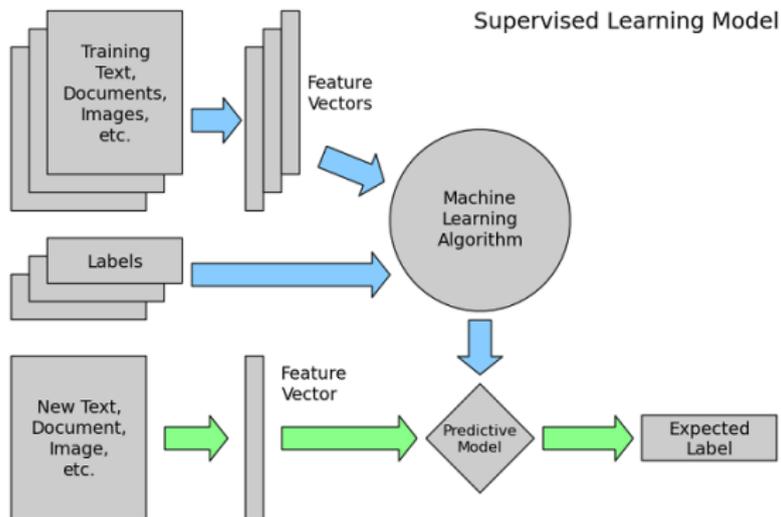
Un prédicteur est une fonction dans  $\mathcal{F} = \{f: \mathcal{X} \rightarrow \mathcal{Y} \text{ mesurable}\}$

But de l'apprentissage supervisé : construire un **bon prédicteur**  $\hat{f}$  à partir des données d'entraînement.

Attention : il nous faudra préciser le terme **bon** !! En un certain sens (à définir), on veut que

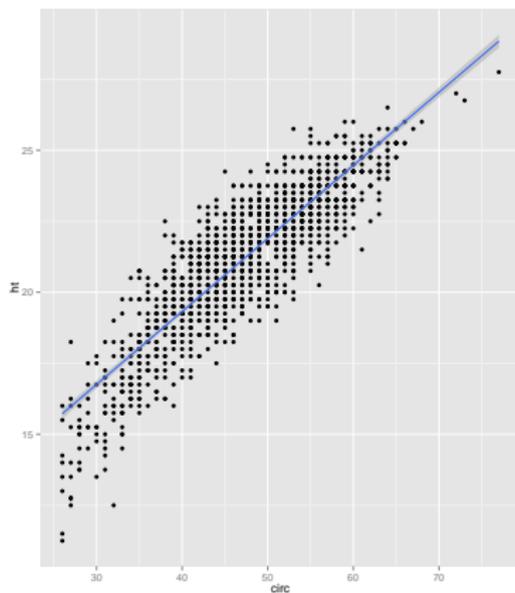
$$Y_i \simeq \hat{f}(\mathbf{X}_i).$$

# Apprentissage statistique supervisé



## Régression linéaire univariée

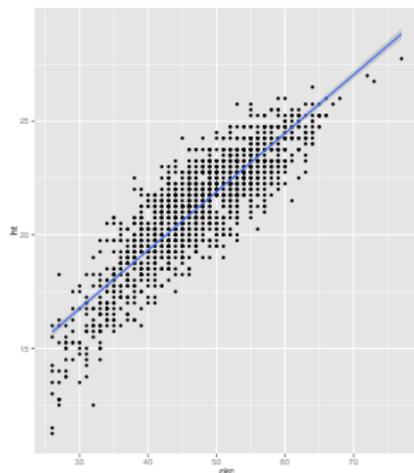
# Eucalyptus



- ▶ But : prédire la hauteur en fonction de la circonférence.
- ▶ Input : circonférence **circ**.
- ▶ Output : hauteur ht.

On peut commencer par chercher  $\hat{f}$  parmi des fonctions très simples : les fonctions linéaires.

# Eucalyptus



- ▶ Modèle linéaire :

$$\mathcal{F} = \{f_{\beta}(\mathbf{circ}) = \beta_1 + \beta_2 \mathbf{circ}, \beta_1, \beta_2 \in \mathbb{R}\}$$

- ▶ Comment choisir  $\beta = (\beta_1, \beta_2)$  ?

## Moindres carrés

On veut que

$$Y_i \simeq \hat{f}(X_i).$$

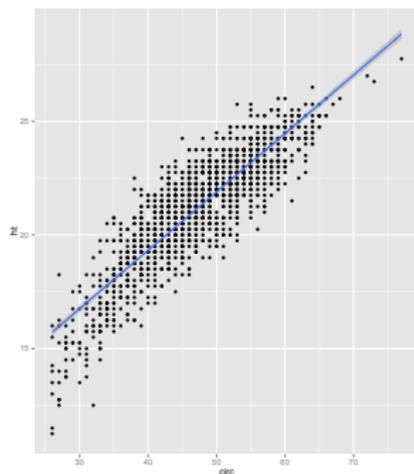
► Critère naturel

$$\begin{aligned} \sum_{i=1}^n |Y_i - f_{\beta}(\mathbf{X}_i)|^2 &= \sum_{i=1}^n |ht_i - f_{\beta}(\mathbf{circ}_i)|^2 \\ &= \sum_{i=1}^n |ht_i - (\beta_1 + \beta_2 \mathbf{circ}_i)|^2 \end{aligned}$$

► On choisit  $\beta$  qui minimise ce critère :

$$\hat{\beta} = \underset{\beta \in \mathbb{R}^2}{\operatorname{argmin}} \sum_{i=1}^n |h_i - (\beta_1 + \beta_2 \mathbf{circ}_i)|^2$$

## Prédiction

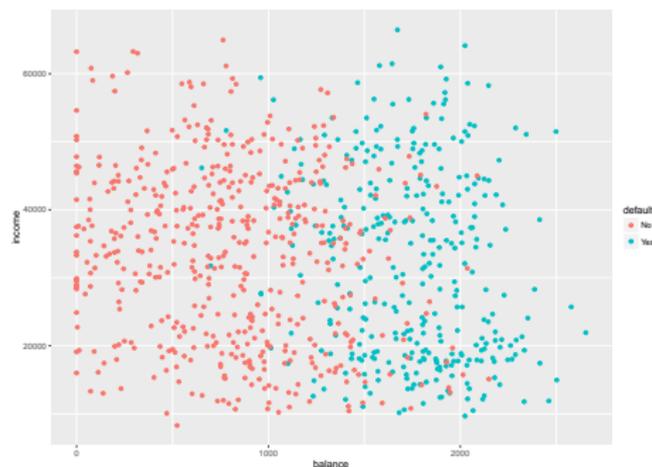


- Prédicteur linéaire pour la hauteur :

$$\widehat{ht} = f_{\widehat{\beta}}(\mathbf{circ}) = \widehat{\beta}_1 + \widehat{\beta}_2 \mathbf{circ}$$

Pas si simple...

## Défaut de crédit

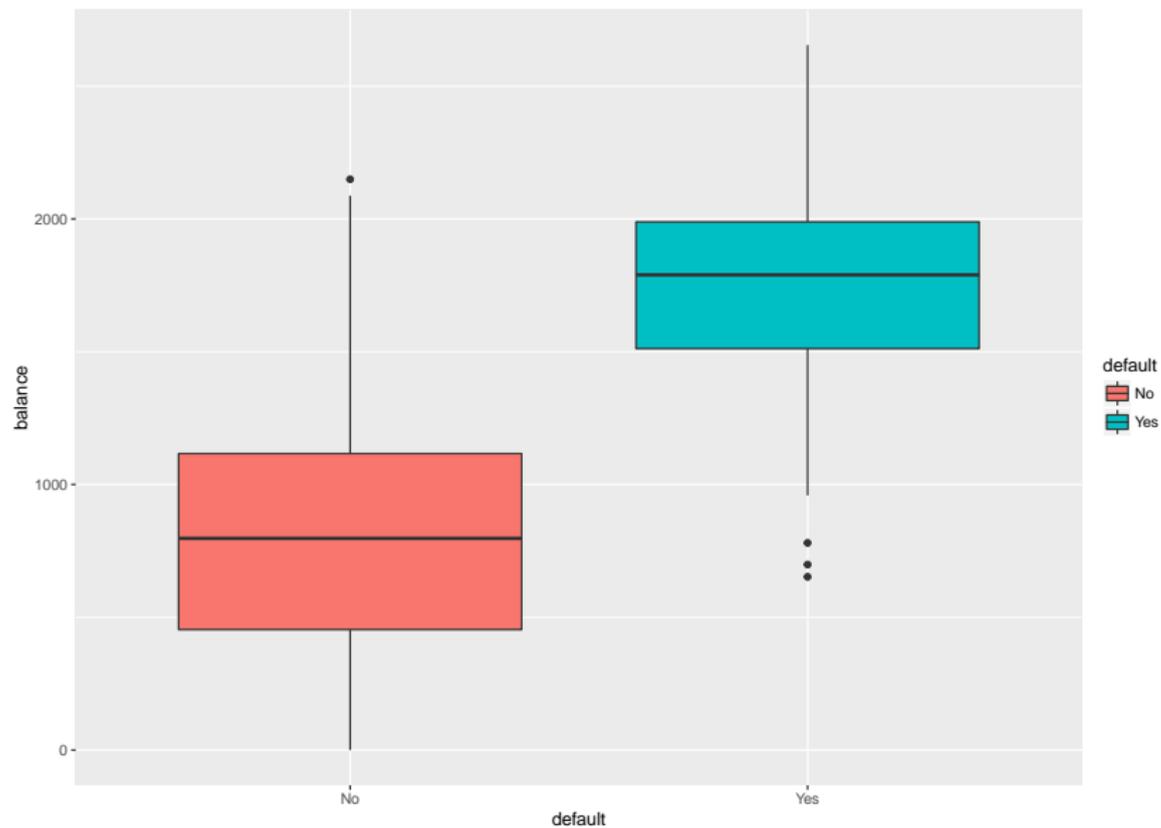


►  $\mathcal{X} = \mathbb{R}^2$

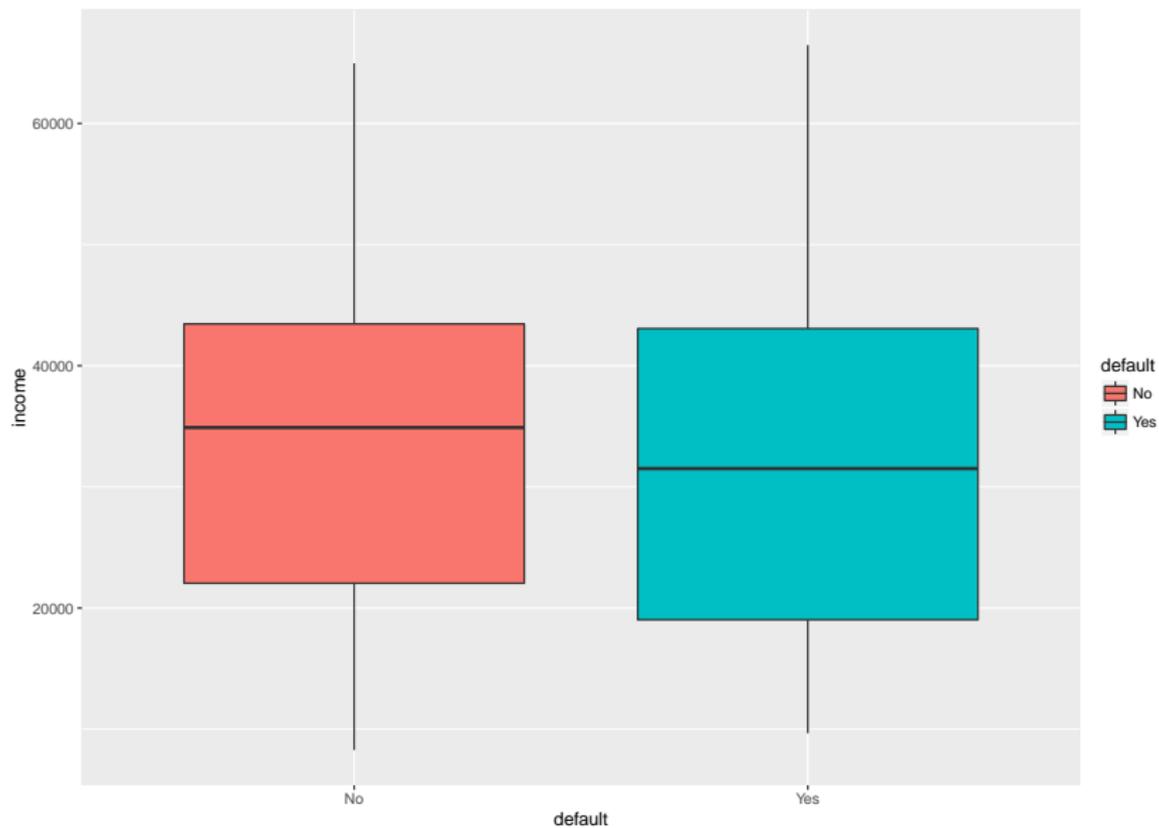
►  $\mathcal{Y} = \{0, 1\}$

On veut prédire le défaut (ou  $\{0, 1\}$ ) à partir du solde du compte et du revenu.

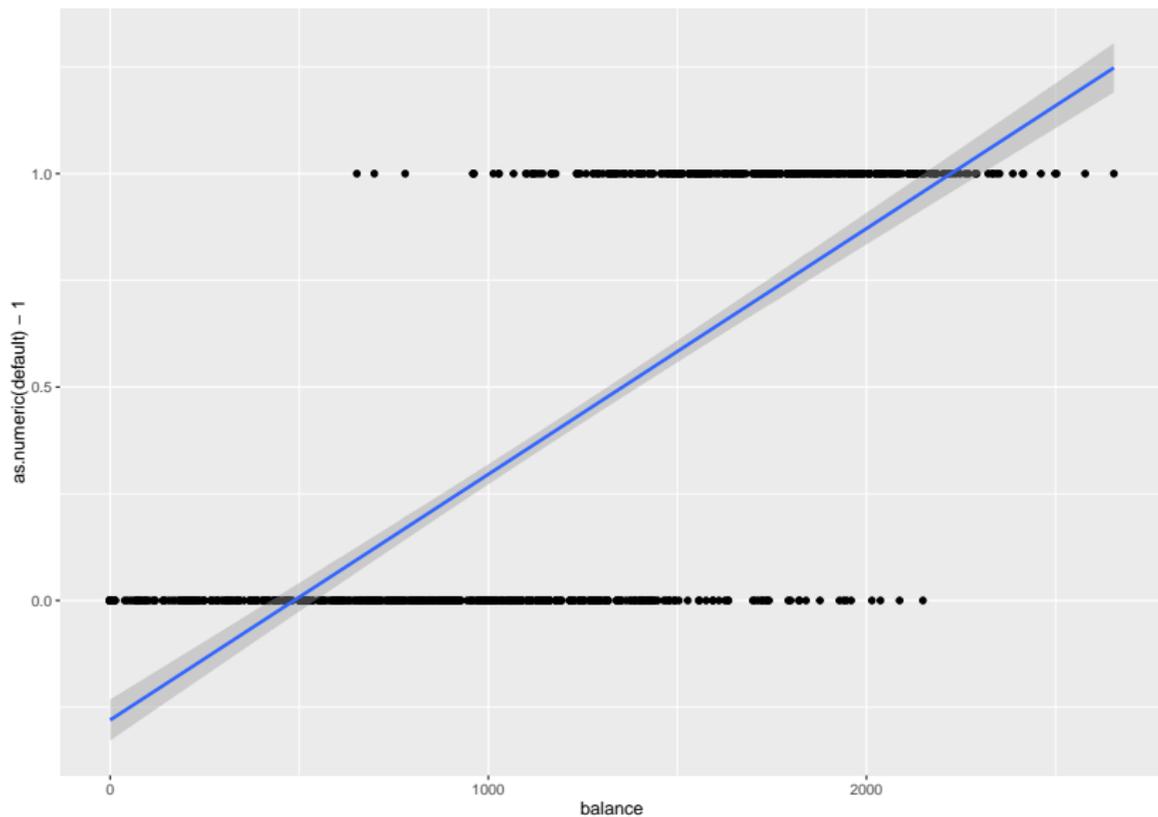
## Pour le solde



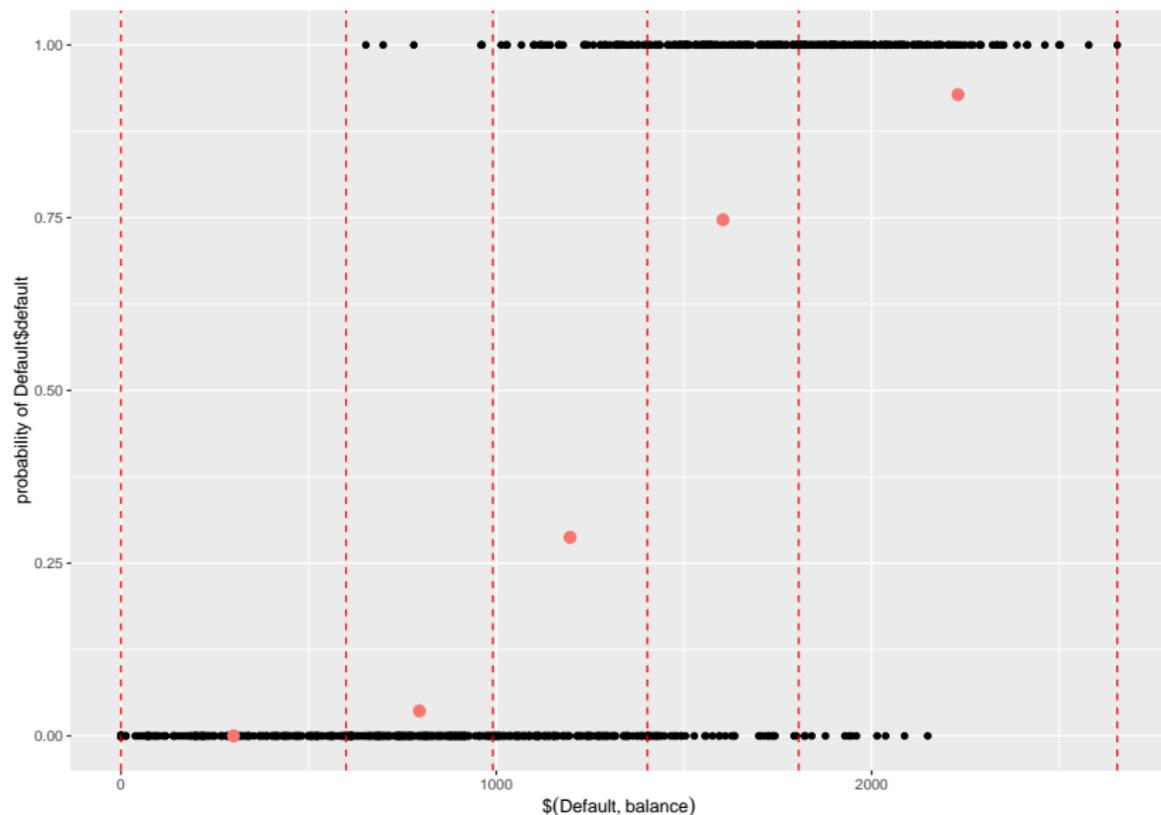
## Pour le revenu



## Par régression linéaire ?



# L'espérance des $Y_i$ sachant $X_i$



Une approche possible : la modélisation statistique

## La loi de $Y_i$ sachant $\mathbf{X}_i$

Dans ces exemples, c'est l'espérance des  $Y_i$  qui dépend des  $X_i$  et

- ▶ pour les données "Défaut de crédit" :  $Y_i \in \{0, 1\}$  suit une loi de Bernoulli
- ▶ pour les données "Eucalyptus" :  $Y_i \in \mathbb{R}$ , on pense à une loi normale.

On va modéliser la loi de  $Y_i$  sachant  $\mathbf{X}_i$  :

- ▶ on va supposer que  $\mathbb{E}(Y_i|\mathbf{X}_i) = f^*(\mathbf{X}_i)$
- ▶ bien on va chercher à construire un prédicteur  $\hat{f}$  "proche" de  $f^*$  à partir des données.

## Résumé

## Dans ce cours

Nous allons

- ▶ adopter le point de vue de la régression, c'est-à-dire modéliser la loi de  $Y_i$  sachant  $\mathbf{X}_i$ ,
- ▶ les familles de lois que nous allons considérer appartiennent à la “**famille exponentielle**” (cf. Chapitre 2)
- ▶ notre façon de définir le “bon” sera le **maximum de vraisemblance** (cf. Chapitre 2)

Nous parlerons dans ce cours de “**modèle linéaire généralisé**” (generalized linear model / GLM).

Quelques remarques :

- ▶ il y a d'autres approches possibles → cf. **Cours de Machine learning du Semestre 2**
- ▶ le cas gaussien se traite plus simplement avec une approche géométrique → cf. **Cours de Modélisation statistique.**

# Outline

Exemples

Apprentissage statistique supervisé

Régression linéaire univariée

Pas si simple...

Une approche possible : la modélisation statistique

Résumé