

# Arbres de décisions et forêts aléatoires.

Pierre Gaillard

7 janvier 2014

# Plan

- 1 Arbre de décision
- 2 Les méthodes d'ensembles et les forêts aléatoires

# Introduction



# Introduction

Jeu de données (ex :  $n$  emails)

- $n$  observations
- $p$  variables **explicatives** décrivant ces observations

Variable cible à prévoir,  $Y$ .

Elle peut être continue (**régression**) ou discrète (**classification**)

ex : spam / non spam

Variables explicatives,  $X_1, \dots, X_p$ .

ex : proportions de majuscules, présence de certains mots (remove, free, ...), de certains caractères (\$, !, ...)

# Idées

**Arbre de décisions.** Découper l'espace des variables explicatives en groupes homogènes de façon récursive et dyadique.

**Forêts aléatoires.** Construire aléatoirement de nombreux arbres et moyenne.

# I. Les arbres de décision



# Historique et références

Méthode introduite par **Leo Breiman** en 1984.

Il existe de nombreuses variantes : **CART** (Classification and regression trees), C4.5, CHAID, ID3

Package R : **tree**, rpart.

Références :

Breiman L. and al (1984) Classification and Regression Trees.



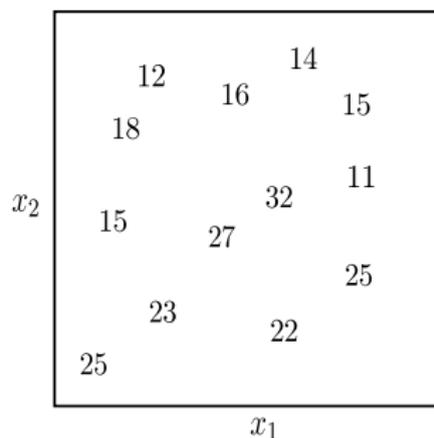
# Arbre de régression

Ensemble d'entraînement  $(X_t, Y_t)_{t \in S_0}$  indépendantes et identiquement distribuées.

## Objectif

Expliquer  $Y_t$  en fonction des variables contextuelles

$$X_t = (X_{1,t}, \dots, X_{p,t}).$$



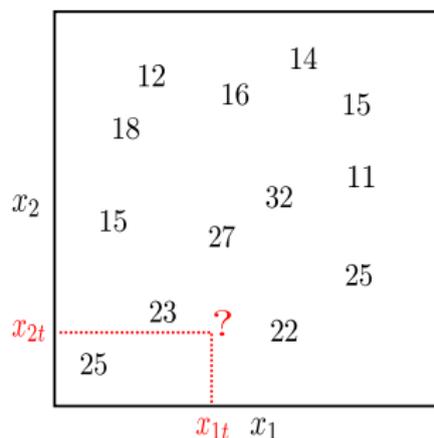
# Arbre de régression

Ensemble d'entraînement  $(X_t, Y_t)_{t \in S_0}$  indépendantes et identiquement distribuées.

## Objectif

Expliquer  $Y_t$  en fonction des variables contextuelles

$$X_t = (X_{1,t}, \dots, X_{p,t}).$$



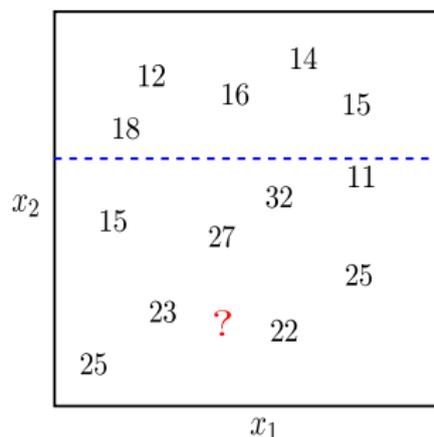
# Arbre de régression

Ensemble d'entraînement  $(X_t, Y_t)_{t \in S_0}$  indépendantes et identiquement distribuées.

## Objectif

Expliquer  $Y_t$  en fonction des variables contextuelles

$$X_t = (X_{1,t}, \dots, X_{p,t}).$$



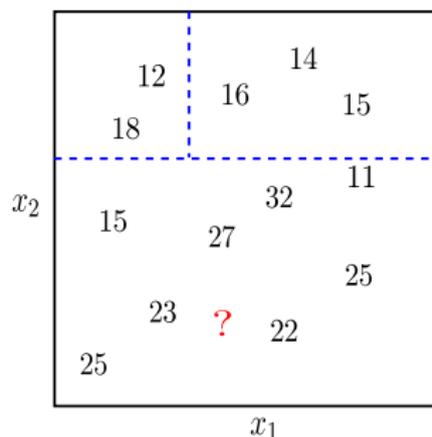
# Arbre de régression

Ensemble d'entraînement  $(X_t, Y_t)_{t \in S_0}$  indépendantes et identiquement distribuées.

## Objectif

Expliquer  $Y_t$  en fonction des variables contextuelles

$$X_t = (X_{1,t}, \dots, X_{p,t}).$$



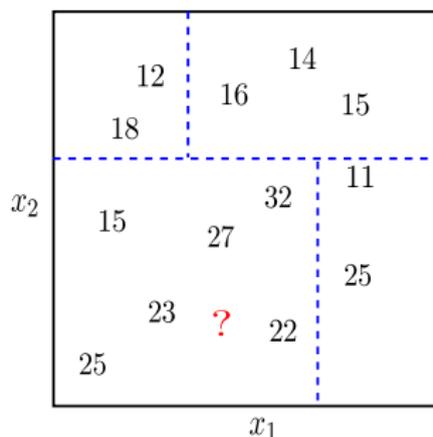
# Arbre de régression

Ensemble d'entraînement  $(X_t, Y_t)_{t \in S_0}$  indépendantes et identiquement distribuées.

## Objectif

Expliquer  $Y_t$  en fonction des variables contextuelles

$X_t = (X_{1,t}, \dots, X_{p,t})$ .



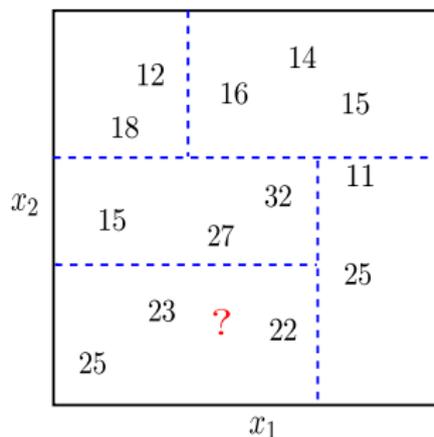
# Arbre de régression

Ensemble d'entraînement  $(X_t, Y_t)_{t \in S_0}$  indépendantes et identiquement distribuées.

## Objectif

Expliquer  $Y_t$  en fonction des variables contextuelles

$$X_t = (X_{1,t}, \dots, X_{p,t}).$$



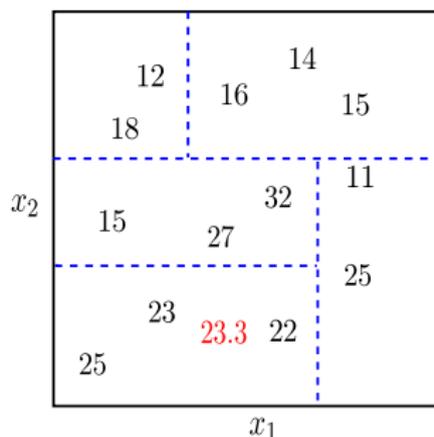
# Arbre de régression

Ensemble d'entraînement  $(X_t, Y_t)_{t \in S_0}$  indépendantes et identiquement distribuées.

## Objectif

Expliquer  $Y_t$  en fonction des variables contextuelles

$$X_t = (X_{1,t}, \dots, X_{p,t}).$$



# Construction de l'arbre

On découpe l'ensemble des variable explicative en deux de façon récursive :

- 1 Choix d'une variable explicative
- 2 Choix d'un seuil de coupe
- 3 Séparer les données en deux sous-ensemble et recommencer sur chaque sous-ensemble jusqu'à un critère d'arrêt.

# Exemple numérique : prévision de la qualité de l'air

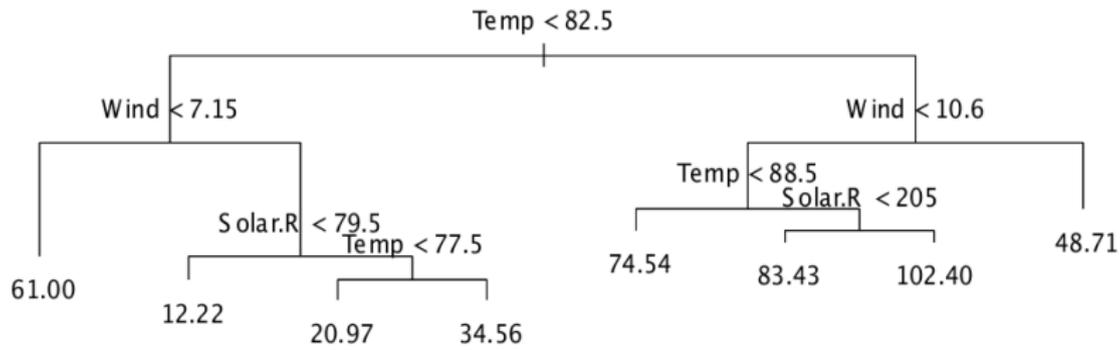
Relevé quotidien de la qualité de l'air (concentration d'ozone) à New York de mai à septembre 1973.

**Jeu de données.** 154 observations, 6 variables explicatives.

**Variables explicatives.** Vitesse moyenne du vent, température maximale, jour de la semaine, mois de l'année, ensoleillement.

**Références.** Sous R. Jeu de données `airquality`.

# Exemple : prévision de la qualité de l'air



# Construction de l'arbre

Nous devons répondre aux trois questions suivantes :

- Comment choisir la variable à segmenter parmi les variables explicatives disponibles ?
- Lorsque la variable est continue, comment déterminer le seuil de coupe ?
- Comment déterminer la bonne taille de l'arbre ?

# Choisir la variable et trouver la bonne coupe

Le choix de la variable explicative  $j$  où couper, et de la coupe correspondante  $\tau$  partitionne les données en deux ensembles :

$$E_{j,\tau}^- = \{i \in \{1, \dots, n\} \text{ tq. } X_{i,j} \leq \tau\}$$

$$E_{j,\tau}^+ = \{i \in \{1, \dots, n\} \text{ tq. } X_{i,j} > \tau\}$$

Exemple : prévision de la qualité de l'air

On peut décider de couper selon que la **température** est supérieure ou inférieure à **30°C**.

# Choisir la variable et trouver la bonne coupe

Le choix de la variable explicative  $j$  où couper, et de la coupe correspondante  $\tau$  partitionne les données en deux ensembles :

$$E_{j,\tau}^- = \{i \in \{1, \dots, n\} \text{ tq. } X_{i,j} \leq \tau\}$$

$$E_{j,\tau}^+ = \{i \in \{1, \dots, n\} \text{ tq. } X_{i,j} > \tau\}$$

**Idée.** Obtenir deux groupes les plus homogènes possible pour la variable à prévoir  $Y$ . On minimise leur variance :

$$(j^*, \tau^*) = \arg \min_{j, \tau} \left\{ \text{Var}(E_{j,\tau}^-) + \text{Var}(E_{j,\tau}^+) \right\}$$

où  $\text{Var}(E) = \min_{y \in \mathbb{R}} \sum_{i \in E} (Y_i - y)^2$

# Choisir la variable et trouver la bonne coupe

Le choix de la variable explicative  $j$  où couper, et de la coupe correspondante  $\tau$  partitionne les données en deux ensembles :

$$E_{j,\tau}^- = \{i \in \{1, \dots, n\} \text{ tq. } X_{i,j} \leq \tau\}$$

$$E_{j,\tau}^+ = \{i \in \{1, \dots, n\} \text{ tq. } X_{i,j} > \tau\}$$

## Exemple : prévision de la qualité de l'air

On décide de couper selon que la **température** est supérieure ou inférieure à **30°C**, si les données qui ont une température inférieure à 30°C ont une qualité de l'air similaire (de même pour celle supérieures).

# Trouver la bonne coupe pour une variable catégorique

Pour des variables catégoriques non ordonnée, on ne peut pas trouver de seuil  $\tau$ , pour diviser les données facilement en deux ensembles.

Exemple : prévision de la qualité de l'air

On peut avoir une variable renseignant si le temps est **ensoleillé**, **nuageux**, **pluvieux**, ou **neigeux**.

Si la variable prend ses valeurs dans un ensemble de  $k$  catégories, il y a  $2^{k-1} - 1$  partitions correspondantes. C'est trop !

**Solution.** Ordonner les catégories suivant la moyenne des  $Y_i$  leur appartenant.

# À quel point doit on laisser l'arbre grandir ?

Un arbre trop grand risque de **surprendre** les données.

Un trop petit risque de **ne pas capter leur structure**.

La taille optimal est un paramètre à **calibrer** sur les données.

Solutions :

- Descendre tant que la variance au sein des feuilles décroît plus qu'un certain seuil.  
**Vision à trop court terme** : une mauvaise coupe peut parfois mener à de très bonnes coupes.
- **Élagage**. On fait grandir l'arbre au maximum puis on supprime les noeuds inintéressants.

# Élagage (pruning)

On réexamine l'arbre et on retire les noeuds causés par le bruit présent dans l'ensemble d'entraînement.

On suppose qu'un **ensemble de validation** (test) est accessible. On minimise alors sur l'ensemble de test, l'erreur quadratique  $R(T)$  pénalisée par la taille de l'arbre  $|T|$  :

$$R_\alpha(T) = R(T) + \alpha|T|$$

Le **paramètre de complexité**  $\alpha$  pénalise les grands arbres.

Le cas  $\alpha = 0$  revient à retirer les noeuds de l'arbre qui augmentent l'erreur de validation.

# Avantages

- Facilement **interprétable** : règles de décisions simples
- **Prévision rapide**
- **Méthode générique**
  - facile à implémenter sur de nouvelles données
  - non paramétrique
  - peu d'hypothèse sur les variables
- Faible perturbation des valeurs extrêmes (outsiders) qui se retrouvent isolées dans de petites feuilles.
- Peu sensible au bruit des variables non discriminantes : non choisies lors des coupes et donc non introduites dans le modèle  
→ possibilité d'un grand nombre de covariables.
- Utilisation de **tous types de variables** (catégoriques, discrètes, continues)

# Inconvénients

- **Instabilité** (effet papillon) !! La modification d'une variable dans l'arbre transforme l'arbre complètement.
- **Arbres non optimaux** : règles heuristiques/empiriques.
- **Long à entraîner** : choix des coupes, élagage, ...

# Exemple numérique : prévision de la qualité de l'air

Relevé quotidien de la qualité de l'air (concentration d'ozone) à New York de mai à septembre 1973.

**Jeu de données.** 154 observations, 6 variables explicatives.

**Variables explicatives.** Vitesse moyenne du vent, température maximale, jour de la semaine, mois de l'année, ensoleillement.

**Références.** Sous R. Jeu de données `airquality`.

# Exemple numérique. Code R

## Prévision de la qualité de l'air

```
# Chargement de la library
library("tree")

# Chargement des données
data(airquality)

# Construction de l'arbre
ozone.tr <- tree(Ozone ~ ., data=airquality)

# Élagage
ozone.tr2 <- prune.tree(ozone.tr)
```

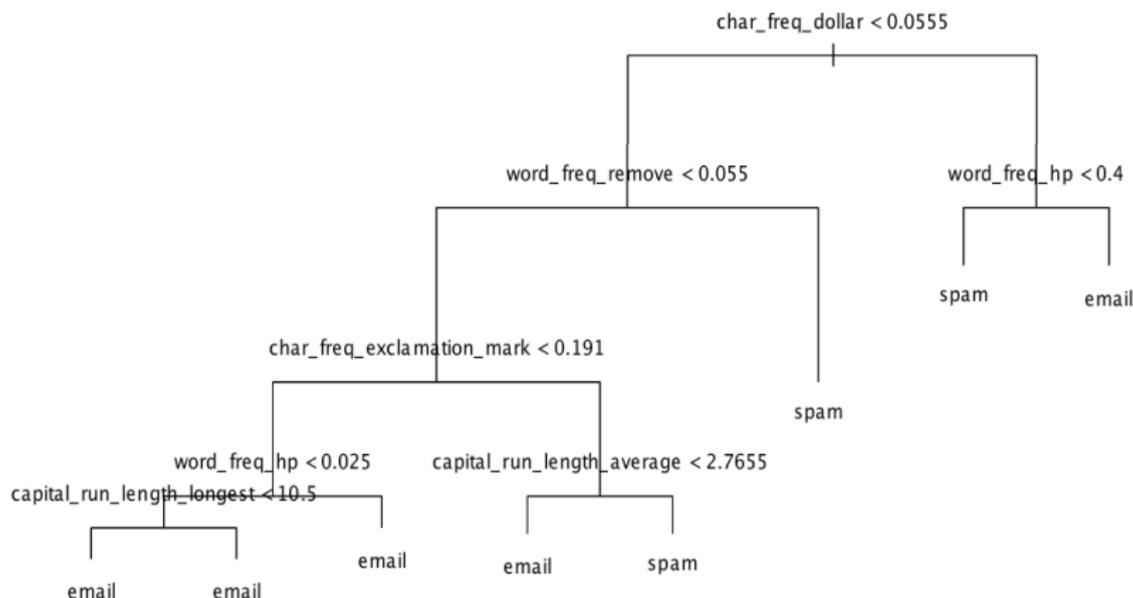
# La classification

La variable à expliquer prend ses valeurs dans un ensemble de **catégories**.

## Exemples.

Détection de spam. Reconnaissance d'objet, de races d'animaux, de variétés de plantes à partir de mesures,...

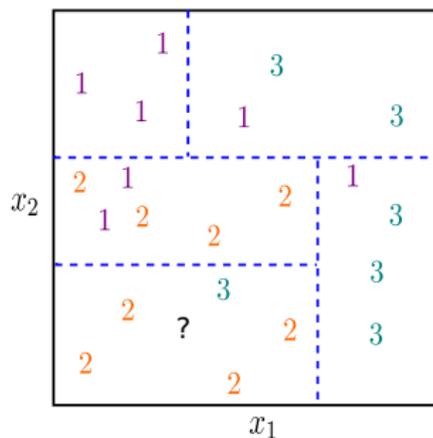
# Arbre de classification. Détection de spams



# Arbre de classification

Différences avec l'arbre de régression :

- au lieu de prévoir comme la moyenne des éléments de la feuille, on prévoit comme la majorité.
- le critère de variance pour sélectionner la variable et la coupe est légèrement différents.



# Trouver la bonne coupe pour un arbre de classification

Encore une fois, on choisit ensuite la coupe de façon à maximiser l'homogénéité au seins des groupes.

On note  $p(j|E)$  la proportion d'observations ayant le label  $j$  dans l'ensemble  $E$ . On remplace le critère de variance par

- **l'entropie** :  $C(E) = - \sum_j p(j|E) \log p(j|E)$
- **le critère de Gini** :  $C(E) = 1 - \sum_j p(j|E)^2$

On minimise ensuite le critère :

$$(j^*, \tau^*) = \arg \min_{j, \tau} \left\{ C(E_{j, \tau}^-) + C(E_{j, \tau}^+) \right\}$$

# Exemple numérique. Détection de spams

Jeu de données contenant 2788 emails et 1813 spams en anglais.

Variables contextuelles disponibles :

- `word_freq_...` : 48 réels donnant le pourcentage de certains mots dans l'email (ex : `word_freq_free`)
- `char_freq_...` : 6 réels donnant le pourcentage de certains caractères (ex : `$,!,...`)
- `capital_run_length_average` : durée moyenne de suite de majuscules consécutives.
- `capital_run_length_longest` : durée de la plus grande suites de majuscules consécutives.
- `capital_run_length_total` : nombre total de majuscules.

## II. Les méthodes d'ensembles et les forêts aléatoires



## Pourquoi combiner ? Une intuition...

Classification binaire  $Y \in \{-1, +1\}$ , variables exogènes  $X \in \mathbb{R}^p$ .  
On dispose d'un ensemble de  $K$  méthodes de classification initiales  
( $h_k$ ) indépendantes telles que

$$P \{h_k(X) \neq Y\} = \varepsilon$$

Alors en moyennant ces méthodes et en prévoyant

$$H(X) = \text{sign} \left( \sum_{k=1}^K h_k(X) \right)$$

par l'inégalité de Hoeffding, la probabilité d'erreur de  $H$  est

$$P \{H(X) \neq Y\} \leq \exp \left( -\frac{1}{2} K (2\varepsilon - 1)^2 \right)$$

qui décroît vers 0 exponentiellement en  $K$ .

# Le bagging (Bootstrap AGGregatING)

Introduit par Breiman (1996).

Deux ingrédients clefs : bootstrap et aggregation..

On sait que l'agrégation de méthode de prévision initiales indépendantes (base learners) mène à une réduction importante de l'erreur de prévision.

⇒ obtenir des méthodes initiales aussi indépendantes que possible.

**Idee naive** : entrainer nos "base learners" (ex : CART) sur des sous-ensembles d'observations disjoints de l'ensemble d'entrainement.

**Problème** : le nombre d'observations de l'ensemble d'entrainement n'est pas infini → les "base learners" auront trop peu de données et de mauvaises performances.

# Idée du bagging

Le bagging crée des sous-ensembles d'entraînement à l'aide d'échantillonnage **bootstrap** [Elfron et Tibshirani, 1993].

Pour créer un nouveau "base learner"

- 1 on tire **aléatoirement avec remise**  $n$  observations de l'ensemble d'entraînement.
- 2 on entraîne notre méthode (ex : CART) sur cet ensemble d'observations

Chaque "base learner" contient ainsi environ 36.8% des observations de l'ensemble d'entraînement.

La performance d'un "base learner" est obtenu par l'erreur "**out-of-bag**".

# Les forêts aléatoires

Méthode introduite par **Leo Breiman** en 2001.

Idées plus anciennes : **Bagging** (1996), arbres de décisions **CART** (1984)

Preuves de convergences récentes (2006,2008)

Un site web utile :

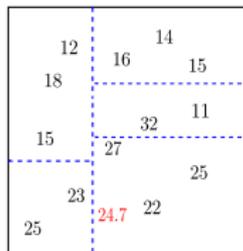
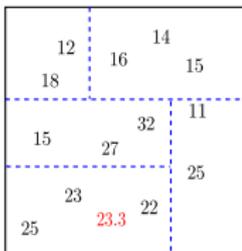
<http://www.stat.berkeley.edu/~breiman/RandomForests>



# Forêts aléatoires

Les forêts aléatoires consistent à faire tourner en parallèle un **grand nombre** ( $\approx 400$ ) d'arbres de décisions **construits aléatoirement**, avant de les **moyenner**.

En termes statistiques, si les arbres sont décorrélés, cela permet de réduire la variance des prévisions.

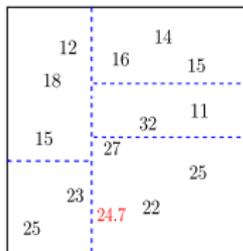
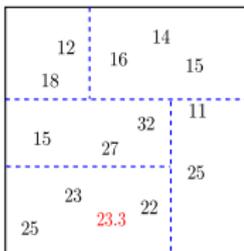


$$\text{prévoit } \frac{24.7+23.3}{2} = 24$$

# Forêts aléatoires

Intuition : si  $K$  arbres sont identiquement distribués, de variance  $\sigma^2$ , avec un coefficient de corrélation deux à deux  $\rho$ , la variance de leur moyenne est alors

$$\bar{\sigma}^2 = \frac{1}{K}(K\sigma^2 + K(K-1)\rho\sigma^2) = \rho\sigma^2 + \frac{1-\rho}{K}\sigma^2$$



prévoit  $\frac{24.7+23.3}{2} = 24$

# Créer des arbres peu corrélés

**Bootstrapping.** Plutôt qu'utiliser toutes les données pour construire les arbres. On choisit pour chaque arbre aléatoirement un sous-ensemble (avec répétition possibles) des données.

**Choix aléatoire de la variable explicative à couper.**

À la différence des arbres Cart, on ne fait pas d'élagage.

# Sélection aléatoire des variables de coupe

$q$  : paramètre contrôlant l'aléatoire

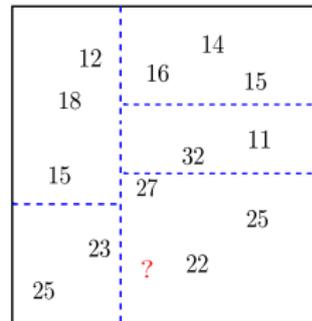
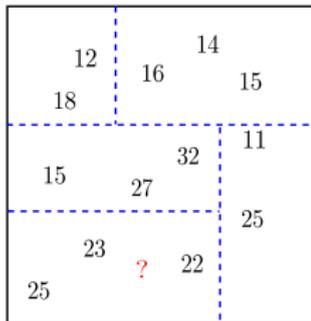
Pour couper un noeud :

- 1 on choisit aléatoirement un **sous-ensemble de  $q$  variables explicatives potentielles** parmi les  $p$  disponibles
  - 2 on choisit la variable à couper et le seuil de coupe en **minimisant le critère de variabilité** (Variance, Entropie, Gini) parmi ce sous-ensemble.
- si  $q = p$  : pas d'aléatoire. On retrouve le choix déterministe de CART
  - si  $q = 1$  : aléatoire total dans le choix de la variable (mais pas dans le seuil de la coupe  $\rightarrow$  VR-trees).

En pratique, Breiman (2001) propose  $q \approx \log(p)$

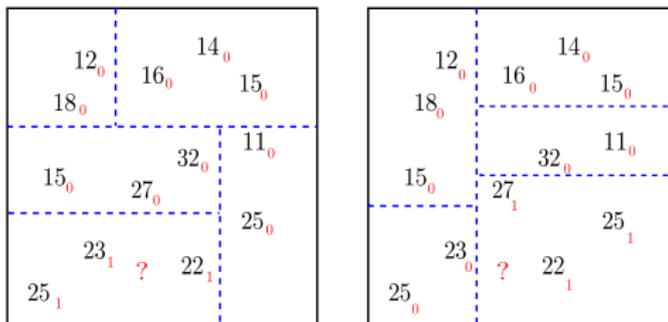
# Une notion importante : la proximité

**Intuition** : Tomber souvent dans les mêmes feuilles des arbres → expliquer la sortie  $Y$  de façon similaire.



# Une notion importante : la proximité

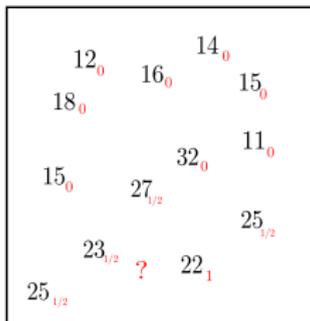
**Intuition** : Tomber souvent dans les même feuilles des arbres  $\rightarrow$  expliquer la sortie  $Y$  de façon similaire.



$$\text{prox}(X_t, X_s) = \frac{1}{K} \sum_{k=1}^K \mathbb{1} \left\{ \begin{array}{l} X_t \text{ et } X_s \text{ tombent dans la} \\ \text{m\^eme feuille dans l'arbre } k \end{array} \right\} .$$

# La notion de proximité

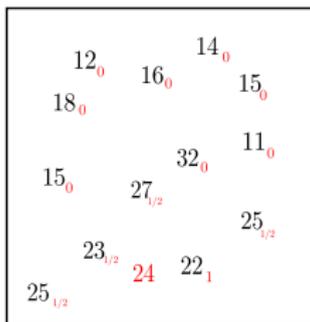
**Intuition** : Tomber souvent dans les même feuilles des arbres → expliquer la sortie  $Y$  de façon similaire.



$$\text{prox}(X_t, X_s) = \frac{1}{K} \sum_{k=1}^K \mathbb{1} \left\{ \begin{array}{l} X_t \text{ et } X_s \text{ tombent dans la} \\ \text{même feuille dans l'arbre } k \end{array} \right\} .$$

# La notion de proximité

**Intuition** : Tomber souvent dans les même feuilles des arbres → expliquer la sortie  $Y$  de façon similaire.



On prédit ensuite par exemple par

$$\arg \min_{a \in \mathbb{R}} \sum_{X_s \in E_t} \text{prox}(X_t, X_s) (Y_s - a)^2.$$

# Détection d'anomalies

Les forêts aléatoires se prêtent bien à la détection de **valeurs extrêmes** [Liu et al. 2008].

Celles-ci se retrouvent en effet **isolées rapidement dans une feuille à part**.

Le score d'anomalie  $s(x)$  d'une observation  $x$  est déterminé approximativement par la longueur moyenne du chemin de  $x$  aux feuilles des arbres de la forêts.

Plus le chemin est court plus l'observation est susceptible d'être atypique.

# Importance des variables explicatives

Les forêts aléatoires permettent de classer les variables explicatives par ordre d'importance dans la prévision.

Tout d'abord,

- on construit la forêt aléatoire
- on calcule l'erreur  $E$  "out-of-bag" de la forêt

Le score d'une variable explicative  $X_i$  est calculé comme suit

- on permute aléatoirement les valeurs de la variable explicative parmi les observations de l'ensemble d'entraînement
- on calcule à nouveau l'erreur out-of-bag et on fait la différence avec  $E$ .

On renormalise les scores.

# Avantages-Inconvénients

## Avantages

- pas de sur-apprentissage
- en général : meilleure performance que les arbres de décision
- calcul de l'erreur "Out-of-Bag" direct. Validation croisée non nécessaire
- paramètres faciles à calibrer

## Inconvénients

- boîte noire : difficilement interprétable
- entraînement plus lent

# Exemple numérique. Code R

## Prévision de la qualité de l'air

# Chargement de la library

```
library("randomForest")
```

# Chargement des données

```
data(airquality)
```

# Construction de l'arbre

```
ozone.rf <- randomForest(Ozone ~ ., data=airquality, mtry=3,  
                          importance=TRUE, na.action=na.omit)
```