

Arbres de classification

Chapitre 3

Marie Chavent

à partir des cours d'Adrien Todeschini et Robin Genuer

Master MIMSE - Université de Bordeaux

2015-2016

Références

- ▶ Classification and regression trees. L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, Chapman & Hall, 1984.
- ▶ Pattern classification. R. Duda, P. Hart and D. Stork. Wiley, New York, 2000.
- ▶ Bagging Predictors. L. Breiman. Machine Learning 26 :123-140.
- ▶ Random Forests. L. Breiman. Machine Learning 45 :5-32.

Introduction

- ▶ On parle d'arbres de décision pour désigner à la fois des arbres de **classification** et de **régression**
- ▶ Ici : arbres de **classification**
- ▶ **Principe général** : un arbre de classification est obtenu par un partitionnement récursif de l'espace d'entrée
- ▶ **CART** peut s'appliquer à des données comportant des variables d'entrée **quantitatives** et **qualitatives** et à une variable de sortie **multiclasse**.
- ▶ Fournit une représentation graphique simple du prédicteur obtenu, qui facilite l'interprétation des résultats.
- ▶ Deux étapes principales de CART :
 1. construction de l'arbre maximal
 2. élagage

Introduction

- ▶ On parle d'arbres de décision pour désigner à la fois des arbres de **classification** et de **régression**
- ▶ Ici : arbres de **classification**
- ▶ **Principe général** : un arbre de classification est obtenu par un partitionnement récursif de l'espace d'entrée
- ▶ **CART** peut s'appliquer à des données comportant des variables d'entrée **quantitatives** et **qualitatives** et à une variable de sortie **multiclasse**.
- ▶ Fournit une représentation graphique simple du prédicteur obtenu, qui facilite l'interprétation des résultats.
- ▶ Deux étapes principales de CART :
 1. construction de l'arbre maximal
 2. élagage

Introduction

- ▶ On parle d'arbres de décision pour désigner à la fois des arbres de **classification** et de **régression**
- ▶ Ici : arbres de **classification**
- ▶ **Principe général** : un arbre de classification est obtenu par un partitionnement récursif de l'espace d'entrée
- ▶ **CART** peut s'appliquer à des données comportant des variables d'entrée **quantitatives** et **qualitatives** et à une variable de sortie **multiclasse**.
- ▶ Fournit une représentation graphique simple du prédicteur obtenu, qui facilite l'interprétation des résultats.
- ▶ Deux étapes principales de CART :
 1. construction de l'arbre maximal
 2. élagage

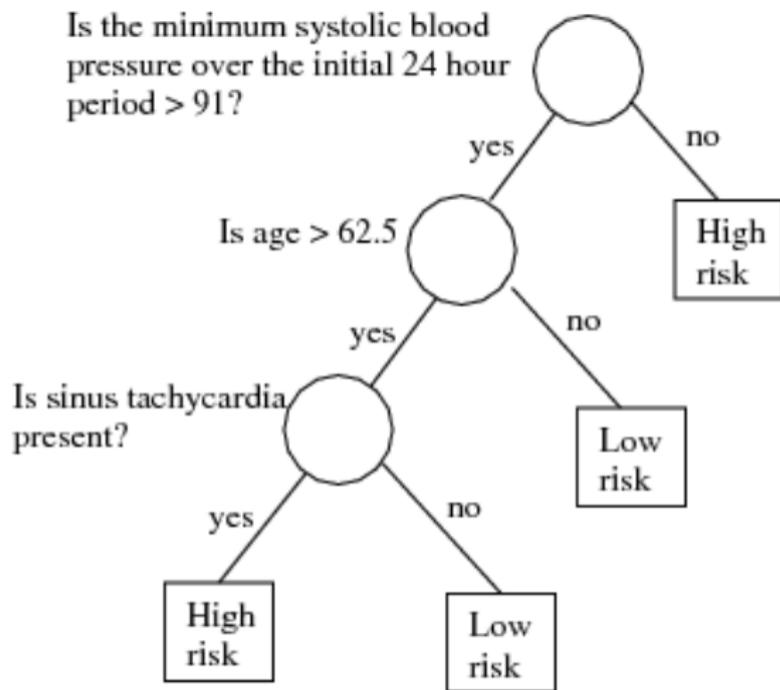
Introduction

- ▶ On parle d'arbres de décision pour désigner à la fois des arbres de **classification** et de **régression**
- ▶ Ici : arbres de **classification**
- ▶ **Principe général** : un arbre de classification est obtenu par un partitionnement récursif de l'espace d'entrée
- ▶ **CART** peut s'appliquer à des données comportant des variables d'entrée **quantitatives** et **qualitatives** et à une variable de sortie **multiclasse**.
- ▶ Fournit une représentation graphique simple du prédicteur obtenu, qui facilite l'interprétation des résultats.
- ▶ Deux étapes principales de CART :
 1. construction de l'arbre maximal
 2. élagage

Introduction

- ▶ On parle d'arbres de décision pour désigner à la fois des arbres de **classification** et de **régression**
- ▶ Ici : arbres de **classification**
- ▶ **Principe général** : un arbre de classification est obtenu par un partitionnement récursif de l'espace d'entrée
- ▶ **CART** peut s'appliquer à des données comportant des variables d'entrée **quantitatives** et **qualitatives** et à une variable de sortie **multiclasse**.
- ▶ Fournit une représentation graphique simple du prédicteur obtenu, qui facilite l'interprétation des résultats.
- ▶ Deux étapes principales de CART :
 1. construction de l'arbre maximal
 2. élagage

Introduction

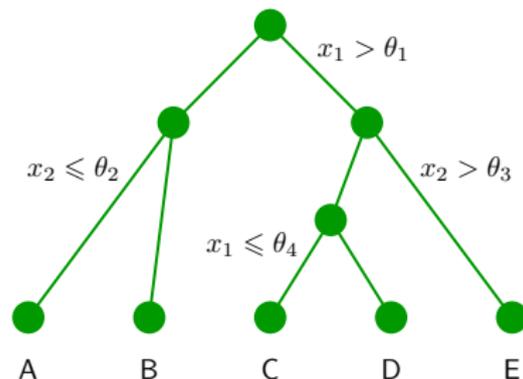
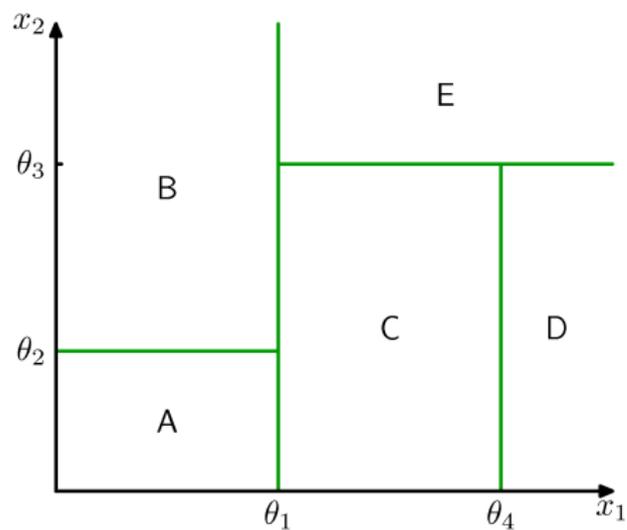


1. **Construction de l'arbre maximal**
2. Elagage

Notations

- ▶ Variables d'entrées : $\mathbf{X} = (X^1, \dots, X^p) \in \mathcal{X}$, quantitatives ou qualitatives
- ▶ Variable de sortie : $Y \in \mathcal{Y} = \{1, \dots, K\}$, qualitative à K classes.
- ▶ On cherche à construire un classifieur associé à un arbre : $g : \mathcal{X} \rightarrow \mathcal{Y}$ sur la base des observations d'apprentissage (\mathbf{X}_i, Y_i) , $i = 1, \dots, n$

Exemple d'arbre



Vocabulaire

- ▶ A chaque noeud t de l'arbre on associe une **coupure** (*split*)
- ▶ A chaque coupure est associée une **variable de coupure** X^{jt} selon laquelle on découpe le noeud
- ▶ Variable **quantitative** $X_i^{jt} \in \mathbb{R}$: on lui associe un **seuil de coupure** θ_t
 - ▶ si $X_i^{jt} \leq \theta_t$ alors l'observation i va dans le noeud fils **gauche**
 - ▶ si $X_i^{jt} > \theta_t$ alors l'observation i va dans le noeud fils **droit**
- ▶ Variable **qualitative** $X_i^{jt} \in \mathcal{A}$: on lui associe une partition des modalités en 2 groupes $\{A_t, {}^cA_t\}$:
 - ▶ si $X_i^{jt} \in A_t$ alors l'observation i va dans le noeud fils **gauche**
 - ▶ si $X_i^{jt} \notin A_t$ alors l'observation i va dans le noeud fils **droit**

Vocabulaire

- ▶ A chaque noeud t de l'arbre on associe une **coupure** (*split*)
- ▶ A chaque coupure est associée une **variable de coupure** X^{jt} selon laquelle on découpe le noeud
- ▶ Variable **quantitative** $X_i^{jt} \in \mathbb{R}$: on lui associe un **seuil de coupure** θ_t
 - ▶ si $X_i^{jt} \leq \theta_t$ alors l'observation i va dans le noeud fils **gauche**
 - ▶ si $X_i^{jt} > \theta_t$ alors l'observation i va dans le noeud fils **droit**
- ▶ Variable **qualitative** $X_i^{jt} \in \mathcal{A}$: on lui associe une partition des modalités en 2 groupes $\{A_t, {}^cA_t\}$:
 - ▶ si $X_i^{jt} \in A_t$ alors l'observation i va dans le noeud fils **gauche**
 - ▶ si $X_i^{jt} \notin A_t$ alors l'observation i va dans le noeud fils **droit**

Vocabulaire

- ▶ A chaque noeud t de l'arbre on associe une **coupure** (*split*)
- ▶ A chaque coupure est associée une **variable de coupure** X^{jt} selon laquelle on découpe le noeud
- ▶ Variable **quantitative** $X_i^{jt} \in \mathbb{R}$: on lui associe un **seuil de coupure** θ_t
 - ▶ si $X_i^{jt} \leq \theta_t$ alors l'observation i va dans le noeud fils **gauche**
 - ▶ si $X_i^{jt} > \theta_t$ alors l'observation i va dans le noeud fils **droit**
- ▶ Variable **qualitative** $X_i^{jt} \in A$: on lui associe une partition des modalités en 2 groupes $\{A_t, {}^cA_t\}$:
 - ▶ si $X_i^{jt} \in A_t$ alors l'observation i va dans le noeud fils **gauche**
 - ▶ si $X_i^{jt} \notin A_t$ alors l'observation i va dans le noeud fils **droit**

Mesure de l'impureté (ou hétérogénéité)

- ▶ On va chercher, parmi toutes les coupures possibles celle qui sépare au mieux les classes :
 - ▶ i.e. donne deux noeuds fils les plus **homogènes** possibles
 - ▶ i.e. minimise une certaine **fonction d'impureté**
- ▶ On note R_t l'ensemble des données d'apprentissage appartenant au noeud t
 - ▶ La racine de l'arbre $R_1 = \{1, \dots, n\}$ contient l'ensemble des données
- ▶ On définit la fréquence de la classe k dans le noeud t

$$\hat{p}_{t,k} = \frac{1}{\text{Card}(R_t)} \sum_{i \in R_t} \mathbb{1}_{Y_i=k}$$

- ▶ On note $\hat{p}_t = (\hat{p}_{t,1}, \dots, \hat{p}_{t,K})$

Mesure de l'impureté (ou hétérogénéité)

- ▶ On va chercher, parmi toutes les coupures possibles celle qui sépare au mieux les classes :
 - ▶ i.e. donne deux noeuds fils les plus **homogènes** possibles
 - ▶ i.e. minimise une certaine **fonction d'impureté**
- ▶ On note R_t l'ensemble des données d'apprentissage appartenant au noeud t
 - ▶ La racine de l'arbre $R_1 = \{1, \dots, n\}$ contient l'ensemble des données
- ▶ On définit la fréquence de la classe k dans le noeud t

$$\hat{p}_{t,k} = \frac{1}{\text{Card}(R_t)} \sum_{i \in R_t} \mathbb{1}_{Y_i=k}$$

- ▶ On note $\hat{p}_t = (\hat{p}_{t,1}, \dots, \hat{p}_{t,K})$

Mesure de l'impureté (ou hétérogénéité)

- ▶ On va chercher, parmi toutes les coupures possibles celle qui sépare au mieux les classes :
 - ▶ i.e. donne deux noeuds fils les plus **homogènes** possibles
 - ▶ i.e. minimise une certaine **fonction d'impureté**
- ▶ On note R_t l'ensemble des données d'apprentissage appartenant au noeud t
 - ▶ La racine de l'arbre $R_1 = \{1, \dots, n\}$ contient l'ensemble des données
- ▶ On définit la fréquence de la classe k dans le noeud t

$$\hat{p}_{t,k} = \frac{1}{\text{Card}(R_t)} \sum_{i \in R_t} \mathbb{1}_{Y_i=k}$$

- ▶ On note $\hat{p}_t = (\hat{p}_{t,1}, \dots, \hat{p}_{t,K})$

Mesure de l'impureté (ou hétérogénéité)

Fonctions d'impureté standard :

- ▶ **Indice de Gini** :

$$\psi(\hat{p}_t) = \sum_{k=1}^K \hat{p}_{t,k} (1 - \hat{p}_{t,k})$$

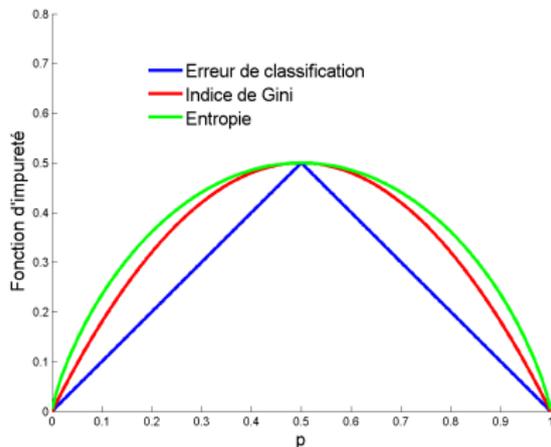
- ▶ **Entropie** :

$$\psi(\hat{p}_t) = - \sum_{k=1}^K \hat{p}_{t,k} \log(\hat{p}_{t,k})$$

Mesure de l'impureté (ou hétérogénéité)

Cas binaire : $K = 2$

- ▶ Gini : $\psi(\hat{p}_t) = \hat{p}_{t,1}(1 - \hat{p}_{t,1}) + \hat{p}_{t,2}(1 - \hat{p}_{t,2}) = 2\hat{p}_{t,1}(1 - \hat{p}_{t,1})$
- ▶ Entropie : $\psi(\hat{p}_t) = -\hat{p}_{t,1} \log(\hat{p}_{t,1}) - (1 - \hat{p}_{t,1}) \log(1 - \hat{p}_{t,1})$

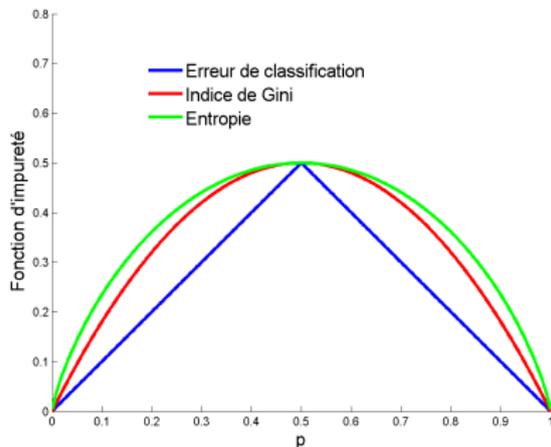


- ▶ positive
- ▶ nulle si le noeud est constitué d'observations de la même classe (noeud est pur)
- ▶ maximale si la moitié des obs. sont de classe 1 et l'autre moitié de classe 2.

Mesure de l'impureté (ou hétérogénéité)

Cas binaire : $K = 2$

- ▶ Gini : $\psi(\hat{p}_t) = \hat{p}_{t,1}(1 - \hat{p}_{t,1}) + \hat{p}_{t,2}(1 - \hat{p}_{t,2}) = 2\hat{p}_{t,1}(1 - \hat{p}_{t,1})$
- ▶ Entropie : $\psi(\hat{p}_t) = -\hat{p}_{t,1} \log(\hat{p}_{t,1}) - (1 - \hat{p}_{t,1}) \log(1 - \hat{p}_{t,1})$



- ▶ positive
- ▶ nulle si le noeud est constitué d'observations de la même classe (noeud est **pur**)
- ▶ maximale si la moitié des obs. sont de classe 1 et l'autre moitié de classe 2.

Mesure de l'impureté (ou hétérogénéité)

- ▶ On note t_L et t_R les noeuds fils gauche et droit du noeud t .
- ▶ On mesure la qualité d'une coupure c_t par

$$\Delta(c_t) = \psi(\hat{p}_t) - \pi_L \psi(\hat{p}_{t_L}) - \pi_R \psi(\hat{p}_{t_R})$$

où π_L et π_R sont les proportions de données de R_t appartenant à R_{t_L} et R_{t_R} .

- ▶ On choisit la coupure c_t associée au noeud t qui vérifie

$$c_t = \arg \max_{c_t = \{X^{j_t}, \theta_t\} \text{ ou } c_t = \{X^{j_t}, A_t\}} \Delta(c_t)$$

Mesure de l'impureté (ou hétérogénéité)

- ▶ On note t_L et t_R les noeuds fils gauche et droit du noeud t .
- ▶ On mesure la qualité d'une coupure c_t par

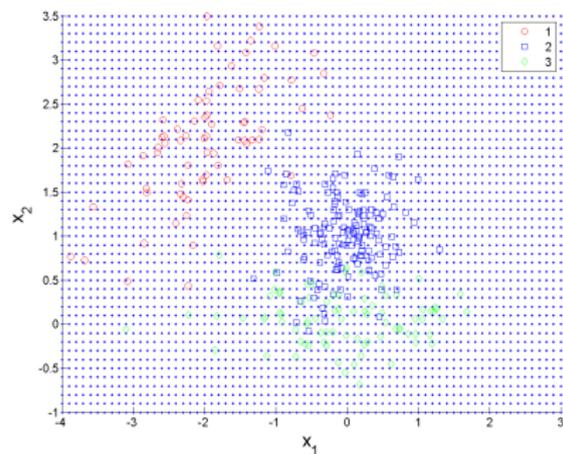
$$\Delta(c_t) = \psi(\hat{p}_t) - \pi_L \psi(\hat{p}_{t_L}) - \pi_R \psi(\hat{p}_{t_R})$$

où π_L et π_R sont les proportions de données de R_t appartenant à R_{t_L} et R_{t_R} .

- ▶ On choisit la coupure c_t associée au noeud t qui vérifie

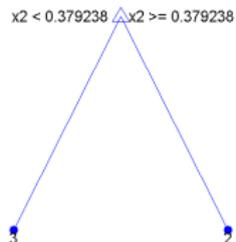
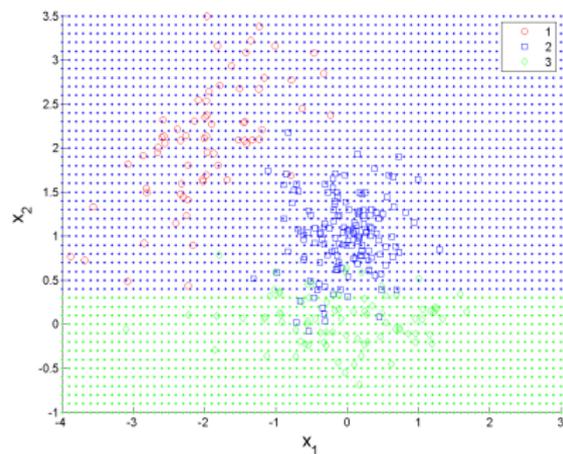
$$c_t = \arg \max_{c_t = \{X^{j_t}, \theta_t\} \text{ ou } c_t = \{X^{j_t}, A_t\}} \Delta(c_t)$$

Exemple : données synthétiques

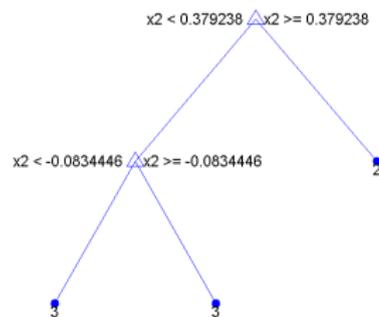
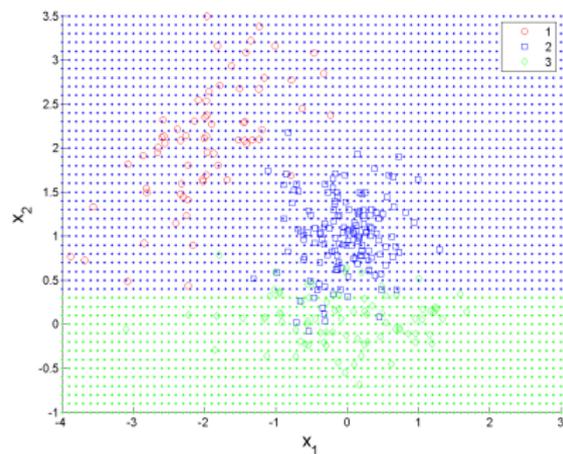


2

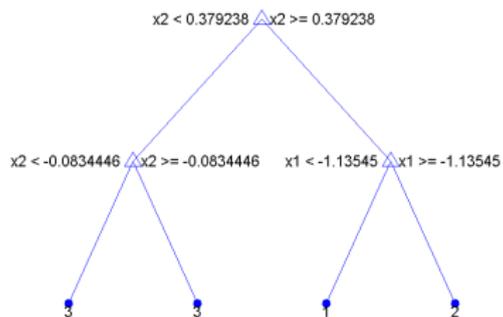
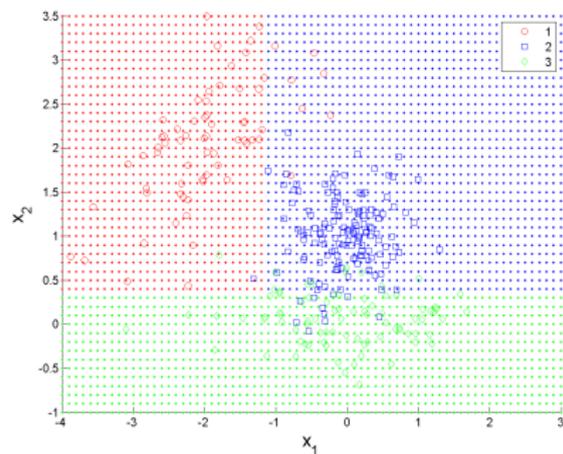
Exemple : données synthétiques



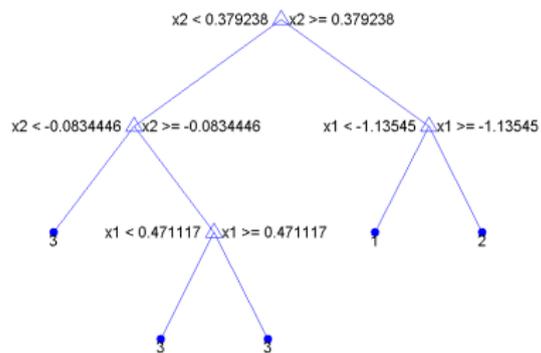
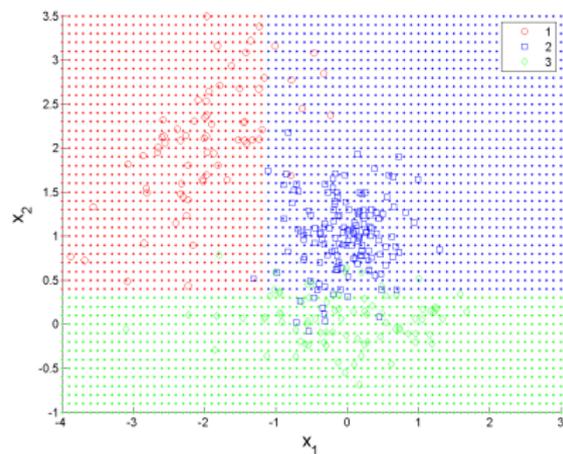
Exemple : données synthétiques



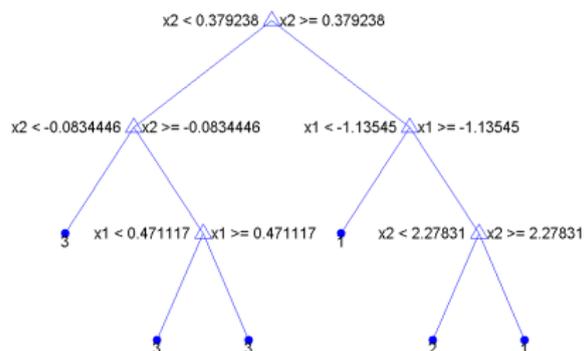
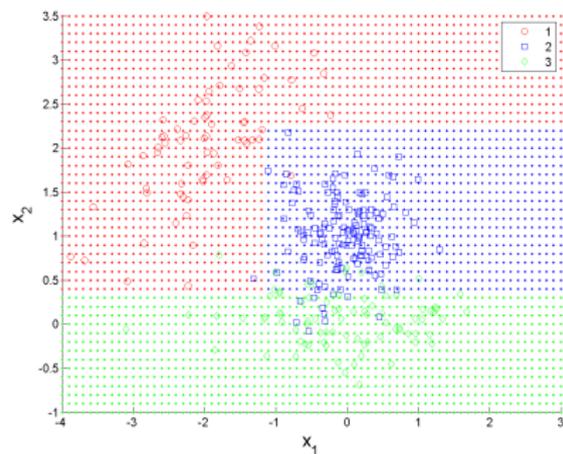
Exemple : données synthétiques



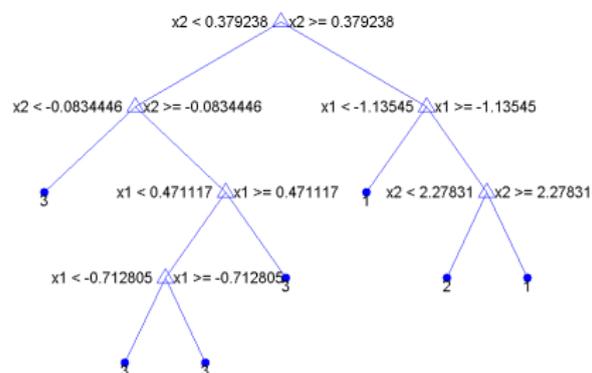
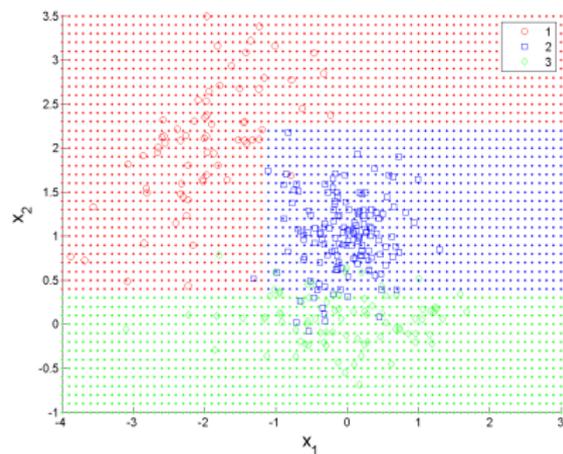
Exemple : données synthétiques



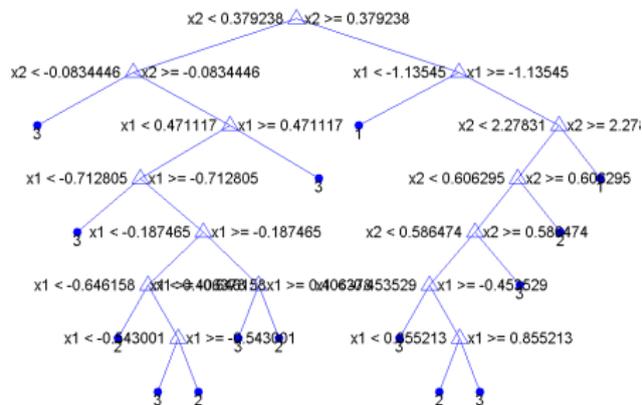
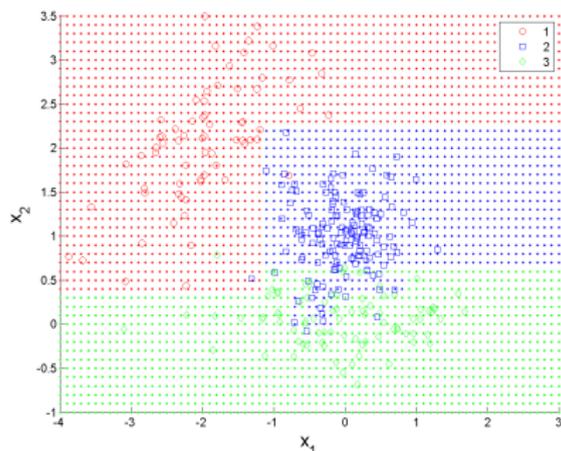
Exemple : données synthétiques



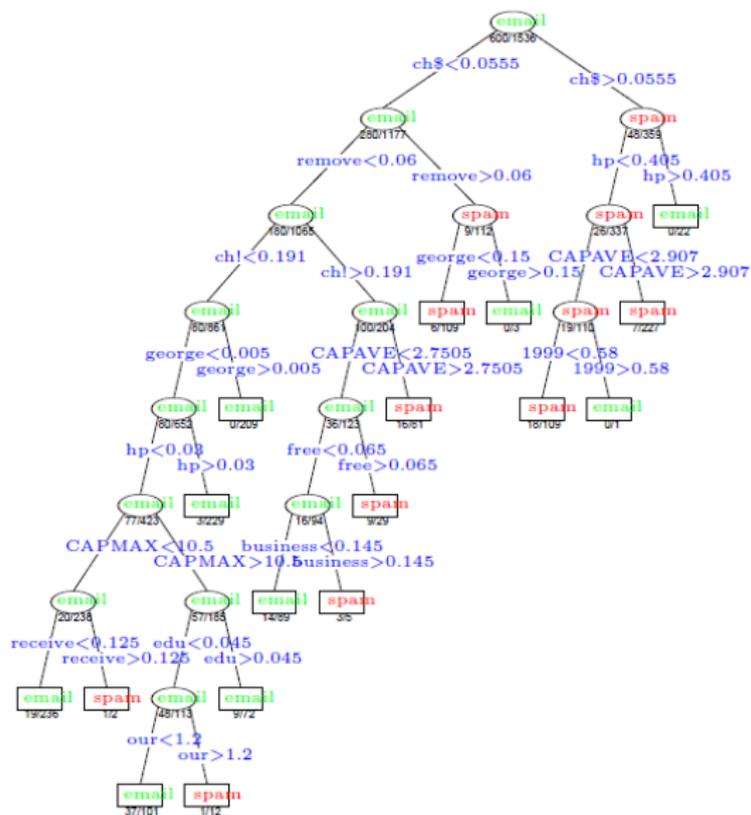
Exemple : données synthétiques



Exemple : données synthétiques



Exemple : spam



Critère d'arrêt

De façon générale, on ne découpe pas un noeud pur.

Ensuite, plusieurs choix possibles

- ▶ On ne découpe pas un noeud qui contient moins de n_{min} données.
 - ▶ Si $n_{min} = 1$, on découpe les données au maximum (arbre maximal).
 - ▶ Si $n_{min} > 1$, on obtient un arbre moins profond.
 - ▶ choix de n_{min} difficile
- ▶ On ne découpe pas un noeud si $\max_{c_t} \Delta(c_t) < \epsilon$, donc si le gain en pureté n'est pas suffisant
 - ▶ choix de ϵ difficile

Critère d'arrêt

De façon générale, on ne découpe pas un noeud pur.

Ensuite, plusieurs choix possibles

- ▶ On ne découpe pas un noeud qui contient moins de n_{min} données.
 - ▶ Si $n_{min} = 1$, on découpe les données au maximum (arbre maximal).
 - ▶ Si $n_{min} > 1$, on obtient un arbre moins profond.
 - ▶ choix de n_{min} difficile
- ▶ On ne découpe pas un noeud si $\max_{c_t} \Delta(c_t) < \epsilon$, donc si le gain en pureté n'est pas suffisant
 - ▶ choix de ϵ difficile

Règle de classification

- ▶ A chaque noeud terminal (ou feuille) on associe la classe majoritaire des observations appartenant à ce noeud :

$$k_t = \arg \max_k \hat{p}_{t,k}$$

- ▶ La règle de classification est :

$$g(\mathbf{x}) = k_{F(\mathbf{x})}$$

où $F(\mathbf{x})$ est la feuille dans laquelle tombe l'observation \mathbf{x} .

1. Construction de l'arbre maximal
2. **Elagage**

Elagage

Les critères d'arrêt étant difficiles à régler en pratique, Breiman et al. ont proposé une meilleure stratégie :

- ▶ Partant de l'arbre maximal T_{max} , on construit une suite de sous-arbres élagués de T_{max}
- ▶ On choisit l'arbre final parmi cette collection d'arbres

Construction de la suite d'arbres

Critère de coût-complexité à minimiser :

$$C_\alpha(\mathbf{T}) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{g_T(X_i) \neq Y_i} + \alpha \frac{|\mathbf{T}|}{n}$$

où $|\mathbf{T}|$ est le nombre de feuilles de l'arbre \mathbf{T}

- ▶ Si $\alpha = 0$, $\mathbf{T}_{max} = \arg \min_T C_\alpha(\mathbf{T})$ avec $C_0(\mathbf{T}_{max}) = 0$ (taux d'erreur nul)
- ▶ On augmente légèrement α , l'arbre qui minimise $C_\alpha(\mathbf{T})$ est un arbre élagué de \mathbf{T}_{max} , noté $\mathbf{T}_{|\mathbf{T}|-1}$, pour lequel on a regroupé deux feuilles dans leur noeud père, qui devient alors un noeud terminal.
- ▶ On repart de $\mathbf{T}_{|\mathbf{T}|-1}$ et on augmente encore α
- ▶ et ainsi de suite ...

Construction de la suite d'arbres

Critère de coût-complexité à minimiser :

$$C_\alpha(\mathbf{T}) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{g_T(X_i) \neq Y_i} + \alpha \frac{|\mathbf{T}|}{n}$$

où $|\mathbf{T}|$ est le nombre de feuilles de l'arbre \mathbf{T}

- ▶ Si $\alpha = 0$, $\mathbf{T}_{max} = \arg \min_T C_\alpha(\mathbf{T})$ avec $C_0(\mathbf{T}_{max}) = 0$ (taux d'erreur nul)
- ▶ On augmente légèrement α , l'arbre qui minimise $C_\alpha(\mathbf{T})$ est un arbre élagué de \mathbf{T}_{max} , noté $\mathbf{T}_{|\mathbf{T}|-1}$, pour lequel on a regroupé deux feuilles dans leur noeud père, qui devient alors un noeud terminal.
- ▶ On repart de $\mathbf{T}_{|\mathbf{T}|-1}$ et on augmente encore α
- ▶ et ainsi de suite ...

Construction de la suite d'arbres

- ▶ On obtient une suite de sous-arbres élagués :

$$T_{max} = T_{|T|} \supset T_{|T|-1} \supset \dots \supset T_1 = \text{racine}$$

- ▶ Par construction, l'arbre T_l est élagué de l'arbre T_{l-1}
- ▶ On peut montrer que

$$T_l = \arg \min_T C_{\alpha_l}(T)$$

où α_l est la valeur de α pour laquelle on a déterminé T_l

- ▶ On choisit $l_{opt} \in \{1, \dots, |T|\}$ et l'arbre T_{opt} associé par validation croisée

Limites des arbres de classification

▶ Instabilité

- ▶ Un faible changement dans les données d'apprentissage peut donner un arbre très différent
- ▶ Du à la construction hiérarchique de l'arbre
- ▶ Solution : méthodes d'ensemble **bagging** et **random forests** (Breiman 1996, 2001)

▶ Partitions binaires ?

- ▶ On pourrait considérer un partitionnement en plus de deux noeuds.
- ▶ Cette stratégie est en général moins bonne, les données d'apprentissage étant trop vite fragmentées

▶ Combinaisons linéaires

- ▶ On peut considérer des règles de partition de la forme $\sum a_j X^j \leq \theta_t$
- ▶ Poids a_j peuvent être obtenus par optimisation
- ▶ Mais perte de l'interprétation et augmentation significative du temps de calcul

Limites des arbres de classification

▶ Instabilité

- ▶ Un faible changement dans les données d'apprentissage peut donner un arbre très différent
- ▶ Du à la construction hiérarchique de l'arbre
- ▶ Solution : méthodes d'ensemble **bagging** et **random forests** (Breiman 1996, 2001)

▶ Partitions binaires ?

- ▶ On pourrait considérer un partitionnement en plus de deux noeuds.
- ▶ Cette stratégie est en général moins bonne, les données d'apprentissage étant trop vite fragmentées

▶ Combinaisons linéaires

- ▶ On peut considérer des règles de partition de la forme $\sum a_j X^j \leq \theta_t$
- ▶ Poids a_j peuvent être obtenus par optimisation
- ▶ Mais perte de l'interprétation et augmentation significative du temps de calcul

Limites des arbres de classification

▶ Instabilité

- ▶ Un faible changement dans les données d'apprentissage peut donner un arbre très différent
- ▶ Du à la construction hiérarchique de l'arbre
- ▶ Solution : méthodes d'ensemble **bagging** et **random forests** (Breiman 1996, 2001)

▶ Partitions binaires ?

- ▶ On pourrait considérer un partitionnement en plus de deux noeuds.
- ▶ Cette stratégie est en général moins bonne, les données d'apprentissage étant trop vite fragmentées

▶ Combinaisons linéaires

- ▶ On peut considérer des règles de partition de la forme $\sum a_j X^j \leq \theta_t$
- ▶ Poids a_j peuvent être obtenus par optimisation
- ▶ Mais perte de l'interprétation et augmentation significative du temps de calcul