

- 1 SVM pour la classification binaire
- 2 Exemples I - données artificielles
- 3 Éléments de théorie pour les SVM
- 4 Exemples II - données réelles
- 5 Noyaux positifs
- 6 Cas de l'analyse en composantes principales et de la régression

Introduction

Objectifs

- 1 Comprendre les grands principes des méthodes à noyaux

Objectifs

- 1 **Comprendre** les grands principes des méthodes à noyaux
- 2 **Entrevoir** les aspects algorithmiques des Support Vector Machines

Objectifs

- 1 **Comprendre** les grands principes des méthodes à noyaux
- 2 **Entrevoir** les aspects algorithmiques des Support Vector Machines
- 3 **Percevoir** l'impact de la théorie pour expliquer leurs performances statistiques

Objectifs

- 1 **Comprendre** les grands principes des méthodes à noyaux
- 2 **Entrevoir** les aspects algorithmiques des Support Vector Machines
- 3 **Percevoir** l'impact de la théorie pour expliquer leurs performances statistiques
- 4 **Observer** leur mise en oeuvre pour l'analyse des données

Objectifs

- 1 **Comprendre** les grands principes des méthodes à noyaux
- 2 **Entrevoir** les aspects algorithmiques des Support Vector Machines
- 3 **Percevoir** l'impact de la théorie pour expliquer leurs performances statistiques
- 4 **Observer** leur mise en oeuvre pour l'analyse des données

En somme...

montrer les bienfaits d'une interaction permanente entre **théorie** et **algorithmique**

Contexte

- explosion de la taille et de la diversité des données

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications
- digitalisation du monde

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications
- digitalisation du monde
 - ▶ lutte anti-terroriste

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications
- digitalisation du monde
 - ▶ lutte anti-terroriste
 - ▶ GoogleEarth

Contexte

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications
- digitalisation du monde
 - ▶ lutte anti-terroriste
 - ▶ GoogleEarth
 - ▶ projet "Barcode of Life"

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications
- digitalisation du monde
 - ▶ lutte anti-terroriste
 - ▶ GoogleEarth
 - ▶ projet "Barcode of Life"
- besoin de normes quantitatives - contrôle des risques

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications
- digitalisation du monde
 - ▶ lutte anti-terroriste
 - ▶ GoogleEarth
 - ▶ projet "Barcode of Life"
- besoin de normes quantitatives - contrôle des risques
 - ▶ Bâle II

- explosion de la taille et de la diversité des données
 - ▶ WWW
 - ▶ ADN
 - ▶ marchés financiers
- disponibilité des données
 - ▶ explosion des capacités de stockage et de calculs
 - ▶ explosion des communications
- digitalisation du monde
 - ▶ lutte anti-terroriste
 - ▶ GoogleEarth
 - ▶ projet "Barcode of Life"
- besoin de normes quantitatives - contrôle des risques
 - ▶ Bâle II
 - ▶ sécurité alimentaire

- Caractéristique des données : grand nombre de variables

Constats

- Caractéristique des données : grand nombre de variables
- Pour être appliquées, les méthodes statistiques classiques (analyse discriminante, régression linéaire) nécessitent une étape critique de **prétraitement**

Constats

- Caractéristique des données : grand nombre de variables
- Pour être appliquées, les méthodes statistiques classiques (analyse discriminante, régression linéaire) nécessitent une étape critique de **prétraitement**
- Les méthodes d'**apprentissage** fournissent des **boîtes noires** qui présentent

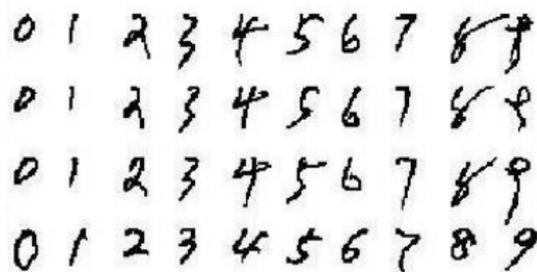
- Caractéristique des données : grand nombre de variables
- Pour être appliquées, les méthodes statistiques classiques (analyse discriminante, régression linéaire) nécessitent une étape critique de **prétraitement**
- Les méthodes d'**apprentissage** fournissent des **boîtes noires** qui présentent
 - ▶ de hautes performances

- Caractéristique des données : grand nombre de variables
- Pour être appliquées, les méthodes statistiques classiques (analyse discriminante, régression linéaire) nécessitent une étape critique de **prétraitement**
- Les méthodes d'**apprentissage** fournissent des **boîtes noires** qui présentent
 - ▶ de hautes performances
 - ▶ pour les données en grande dimension

- Caractéristique des données : grand nombre de variables
- Pour être appliquées, les méthodes statistiques classiques (analyse discriminante, régression linéaire) nécessitent une étape critique de **prétraitement**
- Les méthodes d'**apprentissage** fournissent des **boîtes noires** qui présentent
 - ▶ de hautes performances
 - ▶ pour les données en grande dimension
 - ▶ sans prétraitement

Champs d'application des méthodes à noyaux

- imagerie/**reconnaissance de formes**
- biologie/domaine médical
- finance/économie
- marketing, ...



Type de problèmes

- apprentissage supervisé: classification, régression

Type de problèmes

- apprentissage supervisé: classification, régression
- apprentissage non supervisé: clustering, détection d'anomalies

Type de problèmes

- apprentissage supervisé: classification, régression
- apprentissage non supervisé: clustering, détection d'anomalies
- réduction de la dimension

Type de problèmes

- apprentissage supervisé: classification, régression
- apprentissage non supervisé: clustering, détection d'anomalies
- réduction de la dimension
- comparaison de données hétérogènes

Type de problèmes

- apprentissage supervisé: classification, régression
- apprentissage non supervisé: clustering, détection d'anomalies
- réduction de la dimension
- comparaison de données hétérogènes
- séparation de signaux

Type de données

- en grande dimension :

Type de données

- en grande dimension :
 - ▶ expression de gènes en biologie

Type de données

- **en grande dimension :**
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing

Type de données

- **en grande dimension :**
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche

Type de données

- **en grande dimension :**
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**

Type de données

- **en grande dimension :**
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**
 - ▶ séquences d'ADN

Type de données

- **en grande dimension :**
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**
 - ▶ séquences d'ADN
 - ▶ graphes d'interaction

Type de données

- **en grande dimension :**
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**
 - ▶ séquences d'ADN
 - ▶ graphes d'interaction
- **hétérogènes**

Type de données

- **en grande dimension :**
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**
 - ▶ séquences d'ADN
 - ▶ graphes d'interaction
- **hétérogènes**
 - ▶ vecteurs

Type de données

- **en grande dimension** :
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**
 - ▶ séquences d'ADN
 - ▶ graphes d'interaction
- **hétérogènes**
 - ▶ vecteurs
 - ▶ séquences

Type de données

- **en grande dimension** :
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**
 - ▶ séquences d'ADN
 - ▶ graphes d'interaction
- **hétérogènes**
 - ▶ vecteurs
 - ▶ séquences
 - ▶ courbes

Type de données

- **en grande dimension** :
 - ▶ expression de gènes en biologie
 - ▶ fouille de données dans les fichiers logs en marketing
 - ▶ indexation de textes ou d'images dans les moteurs de recherche
- **structurées**
 - ▶ séquences d'ADN
 - ▶ graphes d'interaction
- **hétérogènes**
 - ▶ vecteurs
 - ▶ séquences
 - ▶ courbes
 - ▶ graphes

- Optimisation quadratique

Ingrédients mathématiques

- Optimisation quadratique
- Théorie des opérateurs à noyau

Ingrédients mathématiques

- Optimisation quadratique
- Théorie des opérateurs à noyau
- Théorie probabiliste de la classification

Ingrédients mathématiques

- Optimisation quadratique
- Théorie des opérateurs à noyau
- Théorie probabiliste de la classification
- Méthodes statistiques pour l'analyse des données

- **Introduction des noyaux** : Aronszajn (1950), Parzen (1962)

Repères historiques

- **Introduction des noyaux** : Aronszajn (1950), Parzen (1962)
- **Noyaux et reconnaissance des formes** : Aizerman, Braverman, Rozonoer (1964)

- **Introduction des noyaux** : Aronszajn (1950), Parzen (1962)
- **Noyaux et reconnaissance des formes** : Aizerman, Braverman, Rozonoer (1964)
- **Perceptron et classifieurs linéaires** : Rosenblatt (1958) Vapnik, Chervonenkis (1964)

- **Introduction des noyaux** : Aronszajn (1950), Parzen (1962)
- **Noyaux et reconnaissance des formes** : Aizerman, Braverman, Rozonoer (1964)
- **Perceptron et classifieurs linéaires** : Rosenblatt (1958) Vapnik, Chervonenkis (1964)
- **Support Vector Machines** : Boser, Guyon, Vapnik (1992), Cortes, Vapnik (1995), Vapnik (1995), Schölkopf (1997)

Repères historiques

- **Introduction des noyaux** : Aronszajn (1950), Parzen (1962)
- **Noyaux et reconnaissance des formes** : Aizerman, Braverman, Rozonoer (1964)
- **Perceptron et classifieurs linéaires** : Rosenblatt (1958) Vapnik, Chervonenkis (1964)
- **Support Vector Machines** : Boser, Guyon, Vapnik (1992), Cortes, Vapnik (1995), Vapnik (1995), Schölkopf (1997)
- **Performances statistiques** : Blanchard, Bousquet, Massart (2004), Steinwart (2005)

- Environ 40 librairies gratuites!!

- Environ 40 librairies gratuites!!
 - ▶ code en C : SVM-Light

- Environ 40 librairies gratuites!!
 - ▶ code en C : SVM-Light
 - ▶ en ligne: GIST

- Environ 40 librairies gratuites!!
 - ▶ code en C : SVM-Light
 - ▶ en ligne: GIST
 - ▶ sous S-Plus : package `libsvm`

- Environ 40 librairies gratuites!!
 - ▶ code en C : SVM-Light
 - ▶ en ligne: GIST
 - ▶ sous S-Plus : package libsvm
 - ▶ sous R : package kernlab

- Environ 40 librairies gratuites!!
 - ▶ code en C : SVM-Light
 - ▶ en ligne: GIST
 - ▶ sous S-Plus : package libsvm
 - ▶ sous R : package kernlab
 - ▶ sous Matlab : **SPIDER**



- Environ 40 librairies gratuites!!
 - ▶ code en C : SVM-Light
 - ▶ en ligne: GIST
 - ▶ sous S-Plus : package libsvm
 - ▶ sous R : package kernlab
 - ▶ sous Matlab : **SPIDER**



NB : Les logiciels libres sont pour la plupart sous licence **GPL**

SVM pour la classification binaire

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$
 - ▶ $x_i \in \mathbb{R}^d$ observations

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$
 - ▶ $x_i \in \mathbb{R}^d$ **observations**
 - ▶ $y_i \in \{-1, +1\}$ **classe** (ou label ou étiquette) binaire

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$
 - ▶ $x_i \in \mathbb{R}^d$ **observations**
 - ▶ $y_i \in \{-1, +1\}$ **classe** (ou label ou étiquette) binaire
- **Problème** : **prédiction** du label y connaissant x

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$
 - ▶ $x_i \in \mathbb{R}^d$ **observations**
 - ▶ $y_i \in \{-1, +1\}$ **classe** (ou label ou étiquette) binaire
- **Problème** : **prédiction** du label y connaissant x
- **On cherche** : un **classifieur** $g : \mathbb{R}^d \rightarrow \{-1, +1\}$

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$
 - ▶ $x_i \in \mathbb{R}^d$ **observations**
 - ▶ $y_i \in \{-1, +1\}$ **classe** (ou label ou étiquette) binaire
- **Problème** : **prédiction** du label y connaissant x
- **On cherche** : un **classifieur** $g : \mathbb{R}^d \rightarrow \{-1, +1\}$
- **Question** : trouver un classifieur g qui "**généralise**" bien.

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$
 - ▶ $x_i \in \mathbb{R}^d$ **observations**
 - ▶ $y_i \in \{-1, +1\}$ **classe** (ou label ou étiquette) binaire
- **Problème** : **prédiction** du label y connaissant x
- **On cherche** : un **classifieur** $g : \mathbb{R}^d \rightarrow \{-1, +1\}$
- **Question** : trouver un classifieur g qui "**généralise**" bien.
- **Idée** : on choisit g qui "**interprète**" bien, mais pas trop!

Le problème de classification binaire

- **Données disponibles** : $(x_1, y_1), \dots, (x_n, y_n)$
 - ▶ $x_i \in \mathbb{R}^d$ **observations**
 - ▶ $y_i \in \{-1, +1\}$ **classe** (ou label ou étiquette) binaire
- **Problème** : **prédiction** du label y connaissant x
- **On cherche** : un **classifieur** $g : \mathbb{R}^d \rightarrow \{-1, +1\}$
- **Question** : trouver un classifieur g qui "**généralise**" bien.
- **Idée** : on choisit g qui "**interprète**" bien, mais pas trop!
- **Concrètement** : on cherche une **fonction de décision** $f : \mathbb{R}^d \rightarrow \mathbb{R}$ et on y associe le classifieur $g = \text{sgn}(f)$

Performance d'un classifieur

- Etant donnée une **observation** x , un classifieur g réalise une **prédiction** $g(x)$ à comparer à la **classe** y .

Performance d'un classifieur

- Etant donnée une **observation** x , un classifieur g réalise une **prédiction** $g(x)$ à comparer à la **classe** y .

Erreur du classifieur = Taux d'observations mal classées

$$\frac{1}{n} \sum_{i=1}^n \mathbb{I}_{[g(x_i) \neq y_i]}$$

Performance d'un classifieur

- Etant donnée une **observation** x , un classifieur g réalise une **prédiction** $g(x)$ à comparer à la **classe** y .

Erreur du classifieur = Taux d'observations mal classées

$$\frac{1}{n} \sum_{i=1}^n \mathbb{I}_{[g(x_i) \neq y_i]} = \frac{\#\{i : g(x_i) \neq y_i\}}{n}$$

Cette erreur s'appelle aussi **erreur d'apprentissage**.

Performance d'un classifieur

- Etant donnée une **observation** x , un classifieur g réalise une **prédiction** $g(x)$ à comparer à la **classe** y .

Erreur du classifieur = Taux d'observations mal classées

$$\frac{1}{n} \sum_{i=1}^n \mathbb{I}_{[g(x_i) \neq y_i]} = \frac{\#\{i : g(x_i) \neq y_i\}}{n}$$

Cette erreur s'appelle aussi **erreur d'apprentissage**.

- Un classifieur g "**interprète**" convenablement les données si son erreur d'apprentissage est faible.

Performance d'un classifieur

- Etant donnée une **observation** x , un classifieur g réalise une **prédiction** $g(x)$ à comparer à la **classe** y .

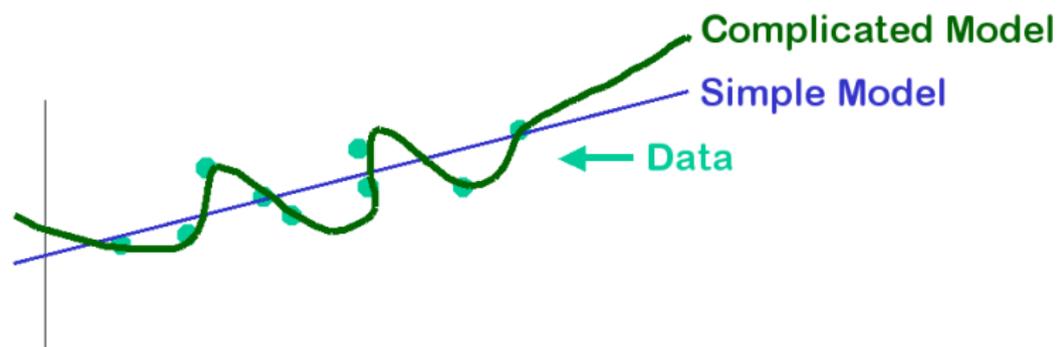
Erreur du classifieur = Taux d'observations mal classées

$$\frac{1}{n} \sum_{i=1}^n \mathbb{I}_{[g(x_i) \neq y_i]} = \frac{\#\{i : g(x_i) \neq y_i\}}{n}$$

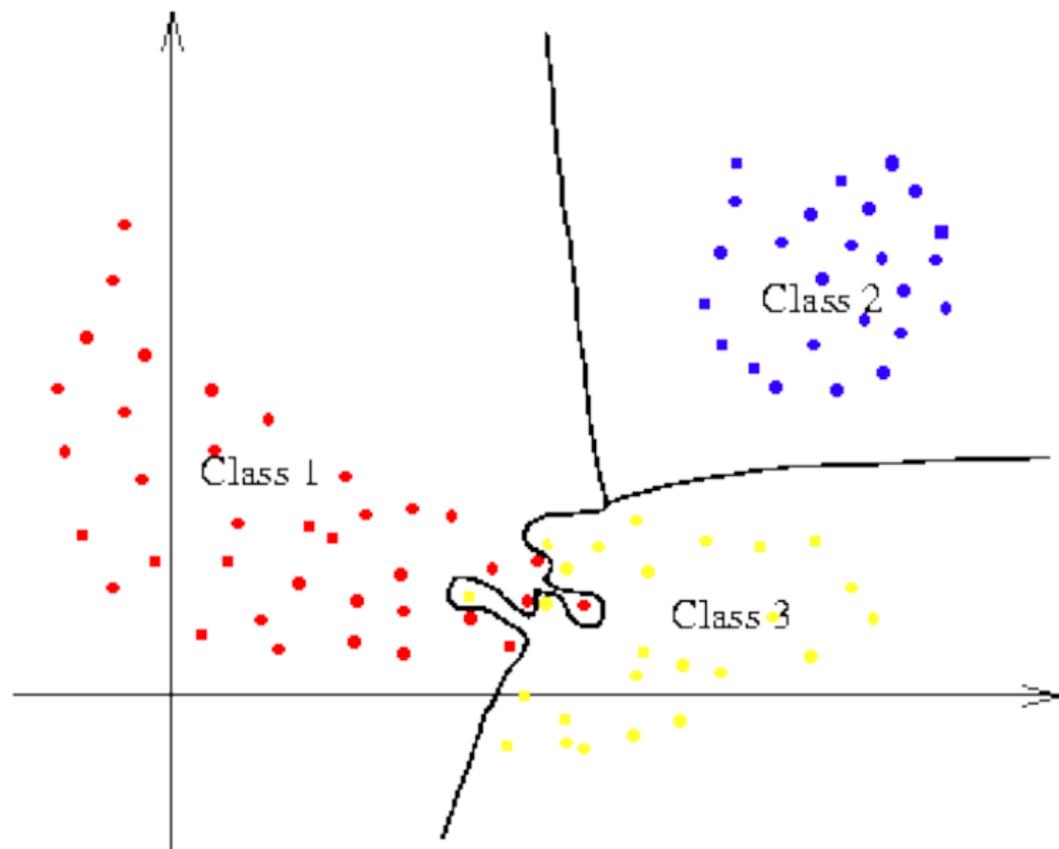
Cette erreur s'appelle aussi **erreur d'apprentissage**.

- Un classifieur g "**interprète**" convenablement les données si son erreur d'apprentissage est faible.
- **Attention!** si on s'intéresse seulement à ce type d'erreur, on risque d'avoir des problèmes...

Overfitting - régression



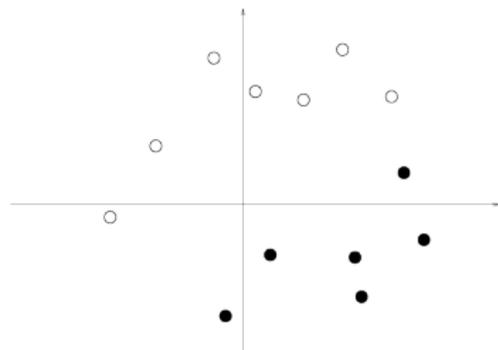
Overfitting - classification



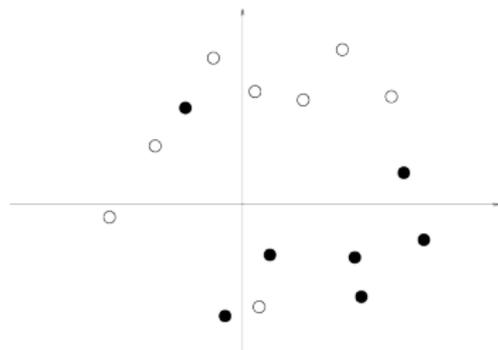
Cas de la classification - Les trois scénarios

- ① les populations sont linéairement séparables
- ② les populations sont *presque* linéairement séparables
- ③ les populations ne sont pas linéairement séparables

Séparabilité linéaire



Scénario 1



Scénario 2

- **Produit scalaire** entre deux vecteurs sur \mathbb{R}^d :

$$\forall u, v \in \mathbb{R}^d, \quad \langle u, v \rangle = u^T v = \sum_{j=1}^d u_j v_j$$

où $u = (u_1, \dots, u_d)^T$ et $v = (v_1, \dots, v_d)^T$

- **Produit scalaire** entre deux vecteurs sur \mathbb{R}^d :

$$\forall u, v \in \mathbb{R}^d, \quad \langle u, v \rangle = u^T v = \sum_{j=1}^d u_j v_j$$

où $u = (u_1, \dots, u_d)^T$ et $v = (v_1, \dots, v_d)^T$

- **Norme euclidienne** sur \mathbb{R}^d :

$$\forall u \in \mathbb{R}^d, \quad \|u\| = \sqrt{\langle u, u \rangle} = \sqrt{\sum_{j=1}^d u_j^2}$$

- **Forme des fonctions de décision :**

$$f(x) = b + \langle \beta, x \rangle$$

où $b \in \mathbb{R}$, $\beta \in \mathbb{R}^d$.

- **Forme des fonctions de décision :**

$$f(x) = b + \langle \beta, x \rangle$$

où $b \in \mathbb{R}$, $\beta \in \mathbb{R}^d$.

- L'équation $f(x) = 0$ définit un **hyperplan séparateur** H dans \mathbb{R}^d

- **Forme des fonctions de décision :**

$$f(x) = b + \langle \beta, x \rangle$$

où $b \in \mathbb{R}$, $\beta \in \mathbb{R}^d$.

- L'équation $f(x) = 0$ définit un **hyperplan séparateur** H dans \mathbb{R}^d
- **Classifieur associé :**

$$\forall x \in \mathbb{R}^d \quad g_f(x) = \begin{cases} +1 & \text{si } f(x) > 0 \\ -1 & \text{si } f(x) \leq 0 \end{cases}$$

Quelques propriétés

- 1 $\beta^* = \frac{\beta}{\|\beta\|}$ est le vecteur normal à H

Quelques propriétés

- 1 $\beta^* = \frac{\beta}{\|\beta\|}$ est le vecteur normal à H
- 2 $\forall x_0 \in H, \quad \langle \beta, x_0 \rangle = -b$

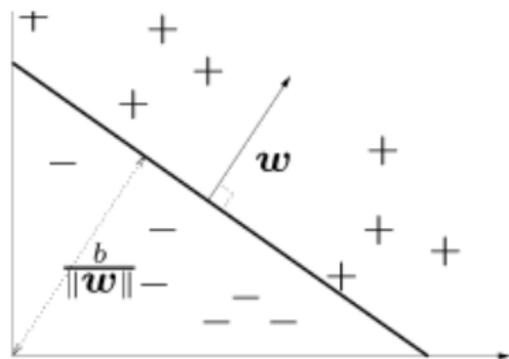
Quelques propriétés

- 1 $\beta^* = \frac{\beta}{\|\beta\|}$ est le vecteur normal à H
- 2 $\forall x_0 \in H, \quad \langle \beta, x_0 \rangle = -b$
- 3 la distance **signée** (éventuellement négative !) d'un point $x \in \mathbb{R}^d$ à H est donnée par

$$d(x, H) = \langle \beta^*, x - x_0 \rangle = \frac{1}{\|\beta\|} (b + \langle \beta, x \rangle)$$

où $x_0 \in H$

Scénario 1 - Une figure



A separating hyperplane $(w, b) \in \mathbb{R}^n \times \mathbb{R}$ for a 2D training set.

Attention! ici $w = \beta \dots$

Algorithme du perceptron (Rosenblatt, 1958)

Perceptron - version simplifiée $b = 0$

Génère une suite β_0, \dots, β_n de valeurs pour β

- 1 **Initialisation** - $\beta_0 = 0$

Algorithme du perceptron (Rosenblatt, 1958)

Perceptron - version simplifiée $b = 0$

Génère une suite β_0, \dots, β_n de valeurs pour β

- 1 **Initialisation** - $\beta_0 = 0$
- 2 **Etape i** - on considère le couple (x_i, y_i) et on regarde s'il est correctement classé ou non

$$\beta_i = \begin{cases} \beta_{i-1} & \text{si } y_i \cdot \langle \beta_{i-1}, x_i \rangle > 0 \\ \beta_{i-1} + y_i x_i & \text{si } y_i \cdot \langle \beta_{i-1}, x_i \rangle \leq 0 \end{cases}$$

Algorithme du perceptron général

Perceptron - version générale

- **Paramètres :**

Algorithme du perceptron général

Perceptron - version générale

- **Paramètres :**

- ▶ taux d'apprentissage η

Algorithme du perceptron général

Perceptron - version générale

- **Paramètres :**

- ▶ taux d'apprentissage η
- ▶ rayon des observations $R = \max_{1 \leq i \leq n} \|x_i\|$

Algorithme du perceptron général

Perceptron - version générale

- **Paramètres :**

- ▶ taux d'apprentissage η
- ▶ rayon des observations $R = \max_{1 \leq i \leq n} \|x_i\|$

- **Algorithme :**

Algorithme du perceptron général

Perceptron - version générale

- **Paramètres :**

- ▶ taux d'apprentissage η
- ▶ rayon des observations $R = \max_{1 \leq i \leq n} \|x_i\|$

- **Algorithme :**

- 1 **Initialisation** - $\beta_0 = 0, b_0 = 0$

Algorithme du perceptron général

Perceptron - version générale

- **Paramètres :**

- ▶ taux d'apprentissage η
- ▶ rayon des observations $R = \max_{1 \leq i \leq n} \|x_i\|$

- **Algorithme :**

① **Initialisation** - $\beta_0 = 0, b_0 = 0$

② **Etape i** - si (x_i, y_i) est mal classé par l'hyperplan (b_{i-1}, β_{i-1}) , alors:

$$\beta_i = \beta_{i-1} + \eta y_i x_i$$

$$b_i = b_{i-1} + \eta y_i^2 R^2$$

sinon $\beta_i = \beta_{i-1}, b_i = b_{i-1}$

Propriétés du perceptron

Théorème de Novikoff

Si les populations sont linéairement séparables alors l'algorithme du perceptron converge en un nombre fini $T \leq n$ d'étapes où:

$$T \leq \frac{2R^2}{M^2}$$

avec $M = \min_{1 \leq i \leq n} \{y_i d(x_i, H^*)\}$ pour un certain séparateur H^* .

Propriétés du perceptron

Théorème de Novikoff

Si les populations sont linéairement séparables alors l'algorithme du perceptron converge en un nombre fini $T \leq n$ d'étapes où:

$$T \leq \frac{2R^2}{M^2}$$

avec $M = \min_{1 \leq i \leq n} \{y_i d(x_i, H^*)\}$ pour un certain séparateur H^* .

- **Défaut du perceptron** : mauvaise généralisation

Théorème de Novikoff

Si les populations sont linéairement séparables alors l'algorithme du perceptron converge en un nombre fini $T \leq n$ d'étapes où:

$$T \leq \frac{2R^2}{M^2}$$

avec $M = \min_{1 \leq i \leq n} \{y_i d(x_i, H^*)\}$ pour un certain séparateur H^* .

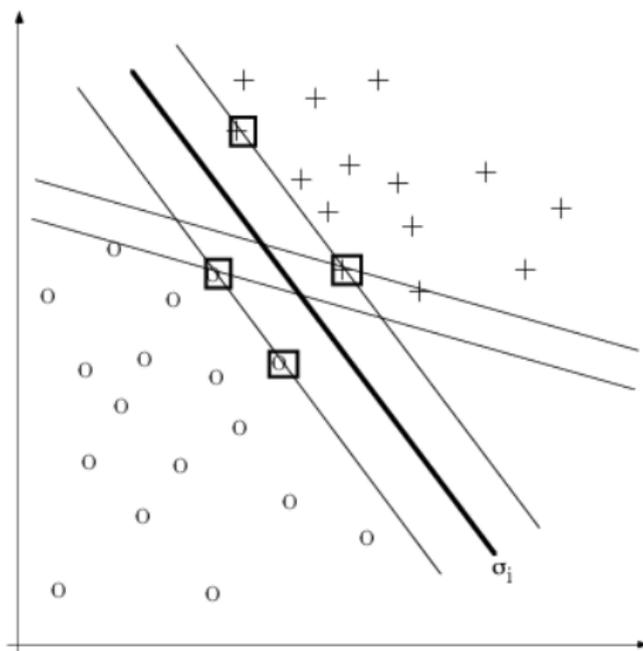
- **Défaut du perceptron** : mauvaise généralisation
- **Vertu du perceptron** : algorithme séquentiel (online)

Scénario 1 - hyperplan à bonne généralisation

Question: hyperplan se trouvant à distance maximale de chaque population ?

Scénario 1 - hyperplan à bonne généralisation

Question: hyperplan se trouvant à distance maximale de chaque population ?



Hyperplan à marges optimales (Vapnik-Chervonenkis, 1964)

Problème d'optimisation

$$\max_{\beta \in \mathbb{R}^d, b \in \mathbb{R}} M$$

sous les contraintes:

$$\forall i = 1, \dots, n, \quad y_i \cdot d(x_i, H) \geq M$$

On rappelle:

$$d(x_i, H) = \frac{1}{\|\beta\|} (b + \langle \beta, x_i \rangle)$$

Problème quadratique

Contraintes:

$$\forall i = 1, \dots, n, \quad y_i \cdot \frac{1}{\|\beta\|} (b + \langle \beta, x_i \rangle) \geq M$$

On peut très bien poser: $M = 1/\|\beta\|$

Formulation équivalente

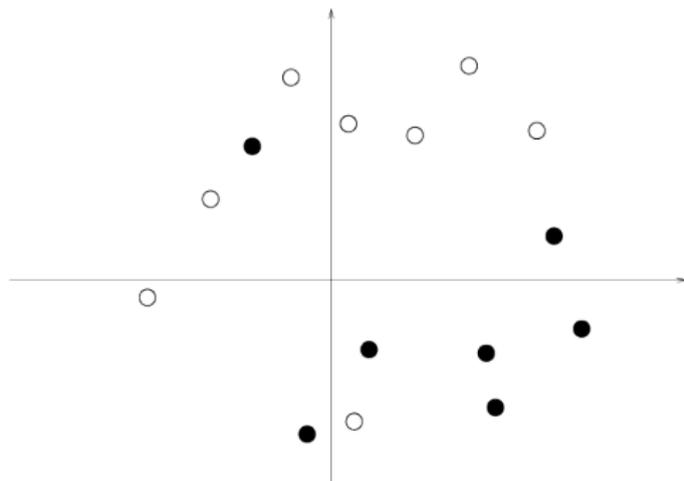
$$\min_{\beta, b} \frac{1}{2} \|\beta\|^2$$

sous les contraintes:

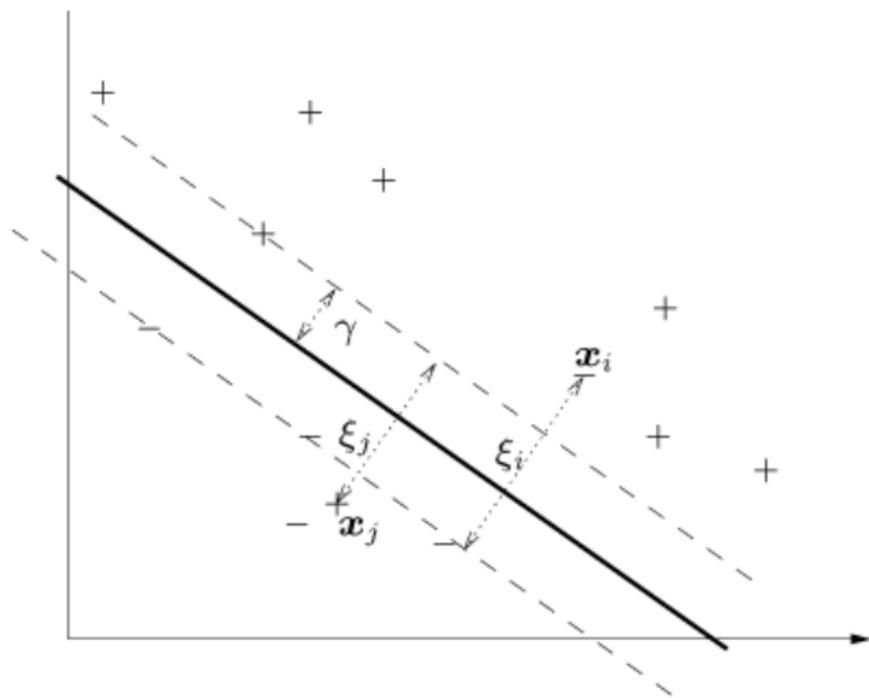
$$\forall i = 1, \dots, n, \quad y_i \cdot (b + \langle \beta, x_i \rangle) \geq 1$$

Scénario 2 - Populations presque linéairement séparables

Idée : la "bonne" séparation est linéaire mais certaines observations ont des labels bruités.



Scénario 2 - Variables "ressorts"



Scénario 2 - Variables "ressorts" (suite)

On introduit n variables supplémentaires ("slacks" ou "ressorts"):
 $\xi = (\xi_1, \dots, \xi_n)$ avec $\xi_i \geq 0, \forall i$

Nouveau problème d'optimisation

$$\min_{\beta, b} \frac{1}{2} \|\beta\|^2$$

sous les contraintes:

$$\forall i = 1, \dots, n, \quad y_i \cdot (b + \langle \beta, x_i \rangle) \geq 1 - \xi_i$$

$$\xi_i \geq 0$$

$$\sum_{i=1}^n \xi_i \leq \Xi$$

Formulation lagrangienne I

Formulation lagrangienne I

$$\min_{\beta, b} \frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^n \xi_i$$

sous les contraintes:

$$\begin{aligned} \forall i = 1, \dots, n, \quad \xi_i &\geq 0 \\ \xi_i &\geq 1 - [y_i \cdot (b + \langle \beta, x_i \rangle)] \end{aligned}$$

Formulation lagrangienne II

Multiplicateurs de Lagrange: $\alpha = (\alpha_1, \dots, \alpha_n)$, $\mu = (\mu_1, \dots, \mu_n)$

Formulation lagrangienne II

$$\min_{\beta, b, \xi} \frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i (y_i \cdot (b + \langle \beta, x_i \rangle) - (1 - \xi_i)) + \sum_{i=1}^n \mu_i \xi_i$$

Conditions du premier ordre (gradient nul)

$$\begin{aligned} \beta &= \sum_{i=1}^n \alpha_i y_i x_i \\ \sum_{i=1}^n \alpha_i y_i &= 0 \\ \forall i = 1, \dots, n, \quad \alpha_i &= C + \mu_i \end{aligned}$$

Formulation duale

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle$$

sous les contraintes:

$$\forall i = 1, \dots, n, \quad 0 \leq \alpha_i \leq C$$
$$\sum_{i=1}^n \alpha_i y_i = 0$$

On note $\hat{\alpha} = (\hat{\alpha}_1, \dots, \hat{\alpha}_n)$ la solution de ce problème.

Conditions de Karush-Kuhn-Tucker

Conditions de Karush-Kuhn-Tucker

$$\begin{aligned}\forall i = 1, \dots, n, \quad & \alpha_i (y_i \cdot f(x_i) - (1 - \xi_i)) = 0 \\ & y_i \cdot f(x_i) - (1 - \xi_i) \geq 0 \\ & \alpha_i + \mu_i = C \\ & \mu_i \xi_i = 0 \\ & \beta = \sum_{i=1}^n \alpha_i y_i x_i \\ & \sum_{i=1}^n \alpha_i y_i = 0\end{aligned}$$

Interprétation

Lien entre les coefficients et la position des observations

- si $\hat{\alpha}_i = 0$ alors $y_i \cdot f(x_i) \geq 1 \Rightarrow$ le point x_i est bien classé
car $\mu_i = C > 0$ et on a $\xi_i = 0$

Interprétation

Lien entre les coefficients et la position des observations

- si $\hat{\alpha}_i = 0$ alors $y_i \cdot f(x_i) \geq 1 \Rightarrow$ le point x_i est bien classé
car $\mu_i = C > 0$ et on a $\xi_i = 0$
- si $0 < \hat{\alpha}_i < C$ alors $y_i \cdot f(x_i) = 1 \Rightarrow$ le point x_i est sur la frontière de la marge
car $\mu_i > 0$ et $\xi_i = 0$

Lien entre les coefficients et la position des observations

- si $\hat{\alpha}_i = 0$ alors $y_i \cdot f(x_i) \geq 1 \Rightarrow$ le point x_i est bien classé
car $\mu_i = C > 0$ et on a $\xi_i = 0$
- si $0 < \hat{\alpha}_i < C$ alors $y_i \cdot f(x_i) = 1 \Rightarrow$ le point x_i est sur la frontière de la marge
car $\mu_i > 0$ et $\xi_i = 0$
- si $\hat{\alpha}_i = C$ alors $y_i \cdot f(x_i) \leq 1 \Rightarrow$ le point x_i dépasse la frontière de la marge
car $\mu_i = 0$ et donc $\xi_i \geq 0$

Lien entre les coefficients et la position des observations

- si $\hat{\alpha}_i = 0$ alors $y_i \cdot f(x_i) \geq 1 \Rightarrow$ le point x_i est bien classé
car $\mu_i = C > 0$ et on a $\xi_i = 0$
- si $0 < \hat{\alpha}_i < C$ alors $y_i \cdot f(x_i) = 1 \Rightarrow$ le point x_i est sur la frontière de la marge
car $\mu_i > 0$ et $\xi_i = 0$
- si $\hat{\alpha}_i = C$ alors $y_i \cdot f(x_i) \leq 1 \Rightarrow$ le point x_i dépasse la frontière de la marge
car $\mu_i = 0$ et donc $\xi_i \geq 0$

Interprétation

Lien entre les coefficients et la position des observations

- si $\hat{\alpha}_i = 0$ alors $y_i \cdot f(x_i) \geq 1 \Rightarrow$ le point x_i est bien classé
car $\mu_i = C > 0$ et on a $\xi_i = 0$
- si $0 < \hat{\alpha}_i < C$ alors $y_i \cdot f(x_i) = 1 \Rightarrow$ le point x_i est sur la frontière de la marge
car $\mu_i > 0$ et $\xi_i = 0$
- si $\hat{\alpha}_i = C$ alors $y_i \cdot f(x_i) \leq 1 \Rightarrow$ le point x_i dépasse la frontière de la marge
car $\mu_i = 0$ et donc $\xi_i \geq 0$

Phénomène remarquable!

En pratique, beaucoup de $\hat{\alpha}_i$ sont nuls!

Solution du problème

Définition

Les $\hat{\alpha}_i \neq 0$ correspondent aux **vecteurs de support**. On note I l'ensemble des indices parmi $\{1, \dots, n\}$ correspondants.

Solution du problème

Définition

Les $\hat{\alpha}_i \neq 0$ correspondent aux **vecteurs de support**. On note I l'ensemble des indices parmi $\{1, \dots, n\}$ correspondants.

Représentation de la solution

Fonction de décision:

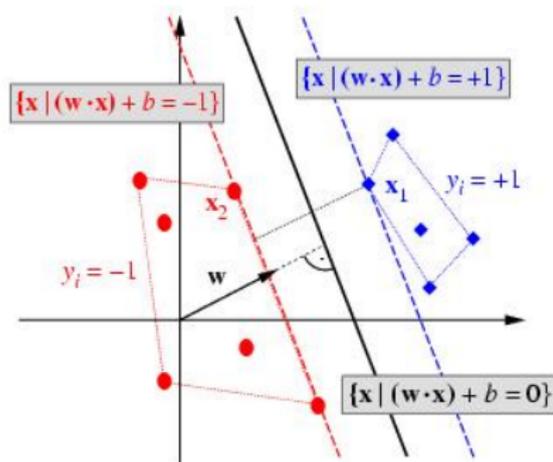
$$\hat{f}(x) = \hat{b} + \sum_{i \in I} \hat{\alpha}_i y_i \langle x_i, x \rangle$$

où :

$$\hat{\beta} = \sum_{i \in I} \hat{\alpha}_i y_i x_i, \quad I = \{i : \hat{\alpha}_i \neq 0\}$$

$$\hat{b} = y_j - \sum_{i \in I} \hat{\alpha}_i y_i \langle x_i, x_j \rangle, \quad \text{pour un certain } j \in I$$

Canonical Optimal Hyperplane



Note:

$$(w \cdot x_1) + b = +1$$

$$(w \cdot x_2) + b = -1$$

$$\Rightarrow (w \cdot (x_1 - x_2)) = 2$$

$$\Rightarrow \left(\frac{w}{\|w\|} \cdot (x_1 - x_2) \right) = \frac{2}{\|w\|}$$

\Rightarrow Représentation **parcimonieuse** ("sparse") des SVM

Scénario 3 - remarques préliminaires

- La plupart des problèmes de classification relèvent de **séparations non-linéaires**

Scénario 3 - remarques préliminaires

- La plupart des problèmes de classification relèvent de **séparations non-linéaires**
- L'algorithme de construction de l'hyperplan à marges optimales ne fait intervenir les observations que sous la forme des **produits scalaires** $\langle x_i, x_j \rangle$ pour tout i, j

Scénario 3 - remarques préliminaires

- La plupart des problèmes de classification relèvent de **séparations non-linéaires**
- L'algorithme de construction de l'hyperplan à marges optimales ne fait intervenir les observations que sous la forme des **produits scalaires** $\langle x_i, x_j \rangle$ pour tout i, j
- La fonction de décision dépend du produit scalaire entre le nouveau point x et les vecteurs de support x_i

- **Astuce du noyau ("kernel trick")** : l'algorithme de construction de l'hyperplan à marges optimales ne dépend des observations qu'au travers des coefficients de la matrice de Gram

$$K = (\langle x_i, x_j \rangle)_{1 \leq i, j \leq n}$$

- **Astuce du noyau ("kernel trick")** : l'algorithme de construction de l'hyperplan à marges optimales ne dépend des observations qu'au travers des coefficients de la matrice de Gram

$$K = (\langle x_i, x_j \rangle)_{1 \leq i, j \leq n}$$

- **Méthodes à noyaux** : on remplace le produit scalaire canonique par un noyau positif

$$k : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$$

et alors K devient la matrice des $k(x_i, x_j)$.

Support Vector Machines

Formulation duale

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j k(x_i, x_j)$$

sous les contraintes:

$$\forall i = 1, \dots, n, \quad 0 \leq \alpha_i \leq C$$
$$\sum_{i=1}^n \alpha_i y_i = 0$$

Support Vector Machines

Formulation duale

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j k(x_i, x_j)$$

sous les contraintes:

$$\forall i = 1, \dots, n, \quad 0 \leq \alpha_i \leq C$$
$$\sum_{i=1}^n \alpha_i y_i = 0$$

Fonction de décision :

$$\hat{f}(x) = \hat{b} + \sum_{i \in I} \hat{\alpha}_i k(x_i, x)$$

avec I indices des vecteurs de support.

Exemples de noyaux

- noyaux polynomiaux

$$k_r(x, x') = (\langle x, x' \rangle)^r$$

$$k_{r,c}(x, x') = (\langle x, x' \rangle + c)^r$$

Exemples de noyaux

- noyaux polynomiaux

$$\begin{aligned}k_r(x, x') &= (\langle x, x' \rangle)^r \\k_{r,c}(x, x') &= (\langle x, x' \rangle + c)^r\end{aligned}$$

- noyau à fonctions de base radiales gaussiennes (RBF)

$$k_\sigma(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right)$$

Exemples de noyaux

- noyaux polynomiaux

$$\begin{aligned}k_r(x, x') &= (\langle x, x' \rangle)^r \\k_{r,c}(x, x') &= (\langle x, x' \rangle + c)^r\end{aligned}$$

- noyau à fonctions de base radiales gaussiennes (RBF)

$$k_\sigma(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right)$$

- noyau sigmoïde (réseau de neurones)

$$k_{\kappa,\theta}(x, x') = \tanh(\kappa \langle x, x' \rangle + \theta)$$

- Sélection d'un noyau

Problèmes pratiques

- Sélection d'un noyau
- Réglage des paramètres : utilisation d'une **base de validation**

Problèmes pratiques

- Sélection d'un noyau
- Réglage des paramètres : utilisation d'une **base de validation**
- Mesures de performances : erreur sur la **base de test**

Problèmes pratiques

- Sélection d'un noyau
- Réglage des paramètres : utilisation d'une **base de validation**
- Mesures de performances : erreur sur la **base de test**
- Comparaison à d'autres méthodes

Problèmes pratiques

- Sélection d'un noyau
- Réglage des paramètres : utilisation d'une **base de validation**
- Mesures de performances : erreur sur la **base de test**
- Comparaison à d'autres méthodes
- Extensions:

- Sélection d'un noyau
- Réglage des paramètres : utilisation d'une **base de validation**
- Mesures de performances : erreur sur la **base de test**
- Comparaison à d'autres méthodes
- Extensions:
 - ▶ problème de classification à plus de deux classes

- Sélection d'un noyau
- Réglage des paramètres : utilisation d'une **base de validation**
- Mesures de performances : erreur sur la **base de test**
- Comparaison à d'autres méthodes
- Extensions:
 - ▶ problème de classification à plus de deux classes
 - ▶ cas de populations très disproportionnées

Problèmes multi-classes

Soit ℓ le nombre de classes

- **Un-contre-tous**
($\ell - 1$) classifieurs binaires + vote

Problèmes multi-classes

Soit ℓ le nombre de classes

- **Un-contre-tous**
 $(\ell - 1)$ classifieurs binaires + vote
- **Un-contre-un**
 C_ℓ^2 classifieurs binaires + vote

Problèmes multi-classes

Soit ℓ le nombre de classes

- **Un-contre-tous**
($\ell - 1$) classifieurs binaires + vote
- **Un-contre-un**
 C_ℓ^2 classifieurs binaires + vote
- **Fusion de classes** (**error-correcting output codes**)
Plusieurs classifieurs binaires + règle de superposition

Problèmes multi-classes

Soit ℓ le nombre de classes

- **Un-contre-tous**
($\ell - 1$) classifieurs binaires + vote
- **Un-contre-un**
 C_ℓ^2 classifieurs binaires + vote
- **Fusion de classes** (**error-correcting output codes**)
Plusieurs classifieurs binaires + règle de superposition
- **Critères d'optimisation multi-classes**
Algorithme SVM modifié + règle de classification :

$$g(x) = \arg \min_{1 \leq j \leq \ell} \left(b_j + \sum_{i: y_i=j} \alpha_i k(x_i, x) \right) \in \{1, \dots, \ell\}$$

Exemples I - données artificielles

Utilisation du logiciel Spider

- Développé au Max Planck Institute (Tübingen)

Utilisation du logiciel Spider

- Développé au Max Planck Institute (Tübingen)
- Disponible en ligne :

Utilisation du logiciel Spider

- Développé au Max Planck Institute (Tübingen)
- Disponible en ligne :

Utilisation du logiciel Spider

- Développé au Max Planck Institute (Tübingen)
- Disponible en ligne :

<http://www.kyb.tuebingen.mpg.de/bs/people/spider/main.html>

Utilisation du logiciel Spider

- Développé au Max Planck Institute (Tübingen)
- Disponible en ligne :

<http://www.kyb.tuebingen.mpg.de/bs/people/spider/main.html>

Premiers pas :

```
X = randn(5, 10);  
Y = [1,1,1,-1,-1]';  
d = data(X,Y);  
a=svm;  
[tr, a] = train(a,d)
```

Effet des paramètres C et σ

Données = réalisations de deux gaussiennes bivariées

Script :

```
m = 20; d = 1; s = 1;

x1 = [randn(m,1)*s-d randn(m,1)*s-d];
x2 = [randn(m,1)*s+d randn(m,1)*s+d];
d = data([x1;x2], [ones(m,1) ; -ones(m,1)]);

a = svm; sigma = 1; a.C = 1;
a.child = kernel('rbf', sigma);
[r a] = train(a,d);
plot(a)
```

Éléments de théorie pour les SVM

Formalisme probabiliste pour la classification binaire

- **Observation:** $X \in \mathbb{R}^d$ (ou \mathcal{X}), loi μ

Formalisme probabiliste pour la classification binaire

- **Observation:** $X \in \mathbb{R}^d$ (ou \mathcal{X}), loi μ
- **Label/Classe:** $Y \in \{-1, +1\}$

Formalisme probabiliste pour la classification binaire

- **Observation:** $X \in \mathbb{R}^d$ (ou \mathcal{X}), loi μ
- **Label/Classe:** $Y \in \{-1, +1\}$
- **Fonction de régression :**

$$\eta(x) = \mathbb{P}\{Y = 1|X = x\}$$

Formalisme probabiliste pour la classification binaire

- **Observation:** $X \in \mathbb{R}^d$ (ou \mathcal{X}), loi μ
- **Label/Classe:** $Y \in \{-1, +1\}$
- **Fonction de régression :**

$$\eta(x) = \mathbb{P}\{Y = 1|X = x\}$$

- **Echantillon :** données indépendantes et de même loi

$$D_n = \{(X_1, Y_1), \dots, (X_n, Y_n)\}$$

Formalisme probabiliste pour la classification binaire

- **Observation:** $X \in \mathbb{R}^d$ (ou \mathcal{X}), loi μ
- **Label/Classe:** $Y \in \{-1, +1\}$
- **Fonction de régression :**

$$\eta(x) = \mathbb{P}\{Y = 1|X = x\}$$

- **Echantillon :** données indépendantes et de même loi

$$D_n = \{(X_1, Y_1), \dots, (X_n, Y_n)\}$$

- **Classifieur :**

fait une prédiction $g(X) \in \{-1, +1\}$

- **Une mesure d'erreur :**

$$L(g) = \mathbb{P} \{ Y \cdot g(X) < 0 \} = \mathbb{E}(\mathbb{I}_{[Y \cdot g(X) < 0]})$$

- **Une mesure d'erreur :**

$$L(g) = \mathbb{P} \{ Y \cdot g(X) < 0 \} = \mathbb{E}(\mathbb{I}_{[Y \cdot g(X) < 0]})$$

- **Classifieur et erreur de Bayes :**

$$\begin{aligned} g^* &= \arg \min_g L(g) = \operatorname{sgn} \left(\eta - \frac{1}{2} \right) \\ L^* &= L(g^*) \end{aligned}$$

- Une mesure d'erreur :

$$L(g) = \mathbb{P} \{ Y \cdot g(X) < 0 \} = \mathbb{E}(\mathbb{I}_{[Y \cdot g(X) < 0]})$$

- Classifieur et erreur de Bayes :

$$\begin{aligned} g^* &= \arg \min_g L(g) = \operatorname{sgn} \left(\eta - \frac{1}{2} \right) \\ L^* &= L(g^*) \end{aligned}$$

- Critère empirique :

$$\hat{L}_n(g) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}_{[Y_i \cdot g(X_i) < 0]}$$

Minimisation du risque empirique (ERM)

La théorie de Vapnik ('95 →) a permis de développer des stratégies consistantes pour la classification de données en grande dimension.

Inconvénients de l'ERM

- algorithmique : problème NP-difficile .

Minimisation du risque empirique (ERM)

La théorie de Vapnik ('95 →) a permis de développer des stratégies consistantes pour la classification de données en grande dimension.

Inconvénients de l'ERM

- algorithmique : problème NP-difficile .
- contrôle de la complexité : propriété de Glivenko-Cantelli pour éviter le surapprentissage (overfitting).

Minimisation du risque empirique (ERM)

La théorie de Vapnik ('95 →) a permis de développer des stratégies consistantes pour la classification de données en grande dimension.

Inconvénients de l'ERM

- algorithmique : problème NP-difficile .
- contrôle de la complexité : propriété de Glivenko-Cantelli pour éviter le surapprentissage (overfitting).

Minimisation du risque empirique (ERM)

La théorie de Vapnik ('95 →) a permis de développer des stratégies consistantes pour la classification de données en grande dimension.

Inconvénients de l'ERM

- algorithmique : problème NP-difficile .
- contrôle de la complexité : propriété de Glivenko-Cantelli pour éviter le surapprentissage (overfitting).

Mais :

Les méthodes efficaces construisent les estimateurs dans des classes massives!

① Support Vector Machines - Vapnik (1995)

① Support Vector Machines - Vapnik (1995)

- ▶ **Kernel trick** : envoyer les données dans un espace de Hilbert où les données soient (presque) linéairement séparables

① Support Vector Machines - Vapnik (1995)

- ▶ **Kernel trick** : envoyer les données dans un espace de Hilbert où les données soient (presque) linéairement séparables
- ▶ **Hyperplan à marge maximale** : optimization convexe sous contraintes quadratiques

① Support Vector Machines - Vapnik (1995)

- ▶ **Kernel trick** : envoyer les données dans un espace de Hilbert où les données soient (presque) linéairement séparables
- ▶ **Hyperplan à marge maximale** : optimization convexe sous contraintes quadratiques

② Boosting - Freund (1990) - Freund, Schapire (1996)

① Support Vector Machines - Vapnik (1995)

- ▶ **Kernel trick** : envoyer les données dans un espace de Hilbert où les données soient (presque) linéairement séparables
- ▶ **Hyperplan à marge maximale** : optimization convexe sous contraintes quadratiques

② Boosting - Freund (1990) - Freund, Schapire (1996)

- ▶ on commence avec une classe \mathcal{H} de **classifieurs simples**

① Support Vector Machines - Vapnik (1995)

- ▶ **Kernel trick** : envoyer les données dans un espace de Hilbert où les données soient (presque) linéairement séparables
- ▶ **Hyperplan à marge maximale** : optimization convexe sous contraintes quadratiques

② Boosting - Freund (1990) - Freund, Schapire (1996)

- ▶ on commence avec une classe \mathcal{H} de **classifieurs simples**
- ▶ puis on construit itérativement une **combinaison linéaire** de classifieurs simples qui fait décroître l'erreur empirique

① Support Vector Machines - Vapnik (1995)

- ▶ **Kernel trick** : envoyer les données dans un espace de Hilbert où les données soient (presque) linéairement séparables
- ▶ **Hyperplan à marge maximale** : optimization convexe sous contraintes quadratiques

② Boosting - Freund (1990) - Freund, Schapire (1996)

- ▶ on commence avec une classe \mathcal{H} de **classifieurs simples**
- ▶ puis on construit itérativement une **combinaison linéaire** de classifieurs simples qui fait décroître l'erreur empirique

① Support Vector Machines - Vapnik (1995)

- ▶ **Kernel trick** : envoyer les données dans un espace de Hilbert où les données soient (presque) linéairement séparables
- ▶ **Hyperplan à marge maximale** : optimization convexe sous contraintes quadratiques

② Boosting - Freund (1990) - Freund, Schapire (1996)

- ▶ on commence avec une classe \mathcal{H} de **classifieurs simples**
- ▶ puis on construit itérativement une **combinaison linéaire** de classifieurs simples qui fait décroître l'erreur empirique

"Boosting is the best off-the-shelf classifier in the world" - Breiman, 1996.

Caractéristique commune

Si on fait abstraction:

- 1 des intuitions géométriques

Caractéristique commune

Si on fait abstraction:

- ① des intuitions géométriques
- ② de la dynamique particulière de chaque algorithme, alors:

Caractéristique commune

Si on fait abstraction:

- ① des intuitions géométriques
- ② de la dynamique particulière de chaque algorithme, alors:

Caractéristique commune

Si on fait abstraction:

- ① des intuitions géométriques
- ② de la dynamique particulière de chaque algorithme, alors:

Boosting et SVM peuvent s'envisager comme des:

procédures de minimisation d'un risque convexe pénalisé dans des espaces fonctionnels massifs.

Caractéristique commune

Si on fait abstraction:

- ① des intuitions géométriques
- ② de la dynamique particulière de chaque algorithme, alors:

Boosting et SVM peuvent s'envisager comme des:

procédures de minimisation d'un risque convexe pénalisé dans des espaces fonctionnels massifs.

Elles sont caractérisées par

- des classes d'estimateurs différentes,

Caractéristique commune

Si on fait abstraction:

- ① des intuitions géométriques
- ② de la dynamique particulière de chaque algorithme, alors:

Boosting et SVM peuvent s'envisager comme des:

procédures de minimisation d'un risque convexe pénalisé dans des espaces fonctionnels massifs.

Elles sont caractérisées par

- des classes d'estimateurs différentes,
- des risques différents,

Caractéristique commune

Si on fait abstraction:

- ① des intuitions géométriques
- ② de la dynamique particulière de chaque algorithme, alors:

Boosting et SVM peuvent s'envisager comme des:

procédures de minimisation d'un risque convexe pénalisé dans des espaces fonctionnels massifs.

Elles sont caractérisées par

- des classes d'estimateurs différentes,
- des risques différents,
- des pénalités différentes.

- **Support Vector Machines** - soit k un noyau positif

$$\mathcal{F} = \left\{ f = \sum_{i=1}^{+\infty} \alpha_i k(x_i, \cdot) : \alpha_i \in \mathbb{R}, x_i \in \mathcal{X} \right\}$$

- **Support Vector Machines** - soit k un noyau positif

$$\mathcal{F} = \left\{ f = \sum_{i=1}^{+\infty} \alpha_i k(x_i, \cdot) : \alpha_i \in \mathbb{R}, x_i \in \mathcal{X} \right\}$$

- **Boosting** - soit \mathcal{G} famille de classifieurs simples de VC dimension V finie

$$\mathcal{F} = \left\{ f = \sum_{i=1}^{+\infty} w_i g_i : w_i \in \mathbb{R}, g_i \in \mathcal{G} \right\}$$

- **Support Vector Machines** - soit k un noyau positif

$$\mathcal{F} = \left\{ f = \sum_{i=1}^{+\infty} \alpha_i k(x_i, \cdot) : \alpha_i \in \mathbb{R}, x_i \in \mathcal{X} \right\}$$

- **Boosting** - soit \mathcal{G} famille de classifieurs simples de VC dimension V finie

$$\mathcal{F} = \left\{ f = \sum_{i=1}^{+\infty} w_i g_i : w_i \in \mathbb{R}, g_i \in \mathcal{G} \right\}$$

- **Support Vector Machines** - soit k un noyau positif

$$\mathcal{F} = \left\{ f = \sum_{i=1}^{+\infty} \alpha_i k(x_i, \cdot) : \alpha_i \in \mathbb{R}, x_i \in \mathcal{X} \right\}$$

- **Boosting** - soit \mathcal{G} famille de classifieurs simples de VC dimension V finie

$$\mathcal{F} = \left\{ f = \sum_{i=1}^{+\infty} w_i g_i : w_i \in \mathbb{R}, g_i \in \mathcal{G} \right\}$$

Les deux algorithmes construisent des combinaisons linéaires de fonctions.

Cas des SVM - Retour sur la formulation lagrangienne I

On pose

$$f(x) = \sum_{i=1}^n \alpha_i k(x_i, x)$$

$$\|f\|_{\mathcal{F}} = \sqrt{\sum_{i,j} \alpha_i \alpha_j k(x_i, x_j)}$$

Cas des SVM - Retour sur la formulation lagrangienne I

On pose

$$f(x) = \sum_{i=1}^n \alpha_i k(x_i, x)$$

$$\|f\|_{\mathcal{F}} = \sqrt{\sum_{i,j} \alpha_i \alpha_j k(x_i, x_j)}$$

Formulation lagrangienne I

$$\min_{f \in \mathcal{F}} \frac{1}{2} \|f\|_{\mathcal{F}}^2 + C \sum_{i=1}^n \xi_i$$

sous les contraintes:

$$\forall i = 1, \dots, n, \quad \xi_i \geq (1 - y_i \cdot f(x_i))_+$$

Interprétation - "hinge loss"

On pose : $\varphi(x) = (1 + x)_+$ "hinge loss"

Interprétation - "hinge loss"

On pose : $\varphi(x) = (1 + x)_+$ "hinge loss"

Minimisation d'un risque pénalisé

$$\min_{f \in \mathcal{F}} \frac{1}{2} \|f\|_{\mathcal{F}}^2 + C \sum_{i=1}^n \varphi(-y_i f(x_i))$$

Interprétation - "hinge loss"

On pose : $\varphi(x) = (1 + x)_+$ "hinge loss"

Minimisation d'un risque pénalisé

$$\min_{f \in \mathcal{F}} \frac{1}{2} \|f\|_{\mathcal{F}}^2 + C \sum_{i=1}^n \varphi(-y_i f(x_i))$$

Commentaires:

- formulation importante pour la théorie statistique

Interprétation - "hinge loss"

On pose : $\varphi(x) = (1 + x)_+$ "hinge loss"

Minimisation d'un risque pénalisé

$$\min_{f \in \mathcal{F}} \frac{1}{2} \|f\|_{\mathcal{F}}^2 + C \sum_{i=1}^n \varphi(-y_i f(x_i))$$

Commentaires:

- formulation importante pour la théorie statistique
- moins commode pour l'optimisation que la formulation duale

Interprétation - "hinge loss"

On pose : $\varphi(x) = (1 + x)_+$ "hinge loss"

Minimisation d'un risque pénalisé

$$\min_{f \in \mathcal{F}} \frac{1}{2} \|f\|_{\mathcal{F}}^2 + C \sum_{i=1}^n \varphi(-y_i f(x_i))$$

Commentaires:

- formulation importante pour la théorie statistique
- moins commode pour l'optimisation que la formulation duale
- $\|f\|_{\mathcal{F}}$ fournit une mesure de régularité de f

- **Fonction de décision :**

$$f : \mathcal{X} \rightarrow \mathbb{R}$$

- **Fonction de décision :**

$$f : \mathcal{X} \rightarrow \mathbb{R}$$

- **Classifieur :**

$$g(x) = g_f(x) = \text{sgn}(f(x)) \in \{-1, +1\}$$

- **Fonction de décision :**

$$f : \mathcal{X} \rightarrow \mathbb{R}$$

- **Classifieur :**

$$g(x) = g_f(x) = \text{sgn}(f(x)) \in \{-1, +1\}$$

- **Critère naturel :**

$$L(f) = \mathbb{P}\{Y \cdot f(X) < 0\} = \mathbb{E}\{\mathbb{I}_{[Y \cdot f(X) < 0]}\}$$

- **Fonction de perte** : φ convexe, positive, telle que $\varphi(x) \geq \mathbb{I}_{\mathbb{R}_+}(x)$

- **Fonction de perte** : φ convexe, positive, telle que $\varphi(x) \geq \mathbb{I}_{\mathbb{R}_+}(x)$
- **Critère pratique (φ -risque)** :

$$\begin{aligned}A(f) &= \mathbb{E}\varphi(-Yf(X)) \\ &= \mathbb{E}[\eta(X)\varphi(-f(X)) + (1 - \eta(X))\varphi(f(X))]\end{aligned}$$

où $\eta(X) = \mathbb{P}\{Y = 1|X = x\}$

- **Fonction de perte** : φ convexe, positive, telle que $\varphi(x) \geq \mathbb{I}_{\mathbb{R}_+}(x)$
- **Critère pratique (φ -risque)** :

$$\begin{aligned}A(f) &= \mathbb{E}\varphi(-Yf(X)) \\ &= \mathbb{E}[\eta(X)\varphi(-f(X)) + (1 - \eta(X))\varphi(f(X))]\end{aligned}$$

où $\eta(X) = \mathbb{P}\{Y = 1|X = x\}$

- **Fonction de perte** : φ convexe, positive, telle que $\varphi(x) \geq \mathbb{I}_{\mathbb{R}_+}(x)$
- **Critère pratique (φ -risque)** :

$$\begin{aligned}A(f) &= \mathbb{E}\varphi(-Yf(X)) \\ &= \mathbb{E}[\eta(X)\varphi(-f(X)) + (1 - \eta(X))\varphi(f(X))]\end{aligned}$$

où $\eta(X) = \mathbb{P}\{Y = 1|X = x\}$

Question : minimiser A revient-il à minimiser L ?

- **Fonction de perte** : φ convexe, positive, telle que $\varphi(x) \geq \mathbb{I}_{\mathbb{R}_+}(x)$
- **Critère pratique (φ -risque)** :

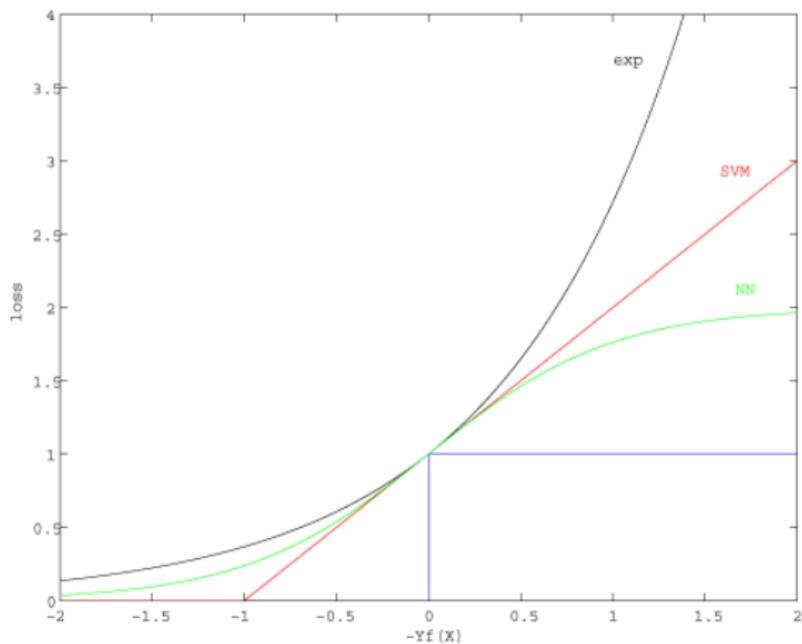
$$\begin{aligned}A(f) &= \mathbb{E}\varphi(-Yf(X)) \\ &= \mathbb{E}[\eta(X)\varphi(-f(X)) + (1 - \eta(X))\varphi(f(X))]\end{aligned}$$

où $\eta(X) = \mathbb{P}\{Y = 1|X = x\}$

Question : minimiser A revient-il à minimiser L ?

On a seulement que: $L(f) \leq A(f)$...

Fonctions de perte



Fonctions cibles

- Minimiseur de la fonctionnelle A noté f^*

Fonctions cibles

- Minimiseur de la fonctionnelle A noté f^*
- Minimum du φ -risque : $A^* = \min_f A(f) = A(f^*)$

Fonctions cibles

- Minimiseur de la fonctionnelle A noté f^*
- Minimum du φ -risque : $A^* = \min_f A(f) = A(f^*)$
- On peut montrer que $\text{sgn}(f^*) = g^*$ le classifieur optimal

Fonctions cibles

- Minimiseur de la fonctionnelle A noté f^*
- Minimum du φ -risque : $A^* = \min_f A(f) = A(f^*)$
- On peut montrer que $\text{sgn}(f^*) = g^*$ le classifieur optimal
- On peut également montrer que l'excès de risque en erreur de classification $L(f) - L^*$ est contrôlé par $A(f) - A^*$

Fonctions cibles

- Minimiseur de la fonctionnelle A noté f^*
- Minimum du φ -risque : $A^* = \min_f A(f) = A(f^*)$
- On peut montrer que $\text{sgn}(f^*) = g^*$ le classifieur optimal
- On peut également montrer que l'excès de risque en erreur de classification $L(f) - L^*$ est contrôlé par $A(f) - A^*$
- Exemples:

Fonctions cibles

- Minimiseur de la fonctionnelle A noté f^*
- Minimum du φ -risque : $A^* = \min_f A(f) = A(f^*)$
- On peut montrer que $\text{sgn}(f^*) = g^*$ le classifieur optimal
- On peut également montrer que l'excès de risque en erreur de classification $L(f) - L^*$ est contrôlé par $A(f) - A^*$
- Exemples:
 - ▶ perte exponentielle (boosting)

$$f^*(x) = \frac{1}{2} \log \left(\frac{\eta(x)}{1 - \eta(x)} \right)$$

Fonctions cibles

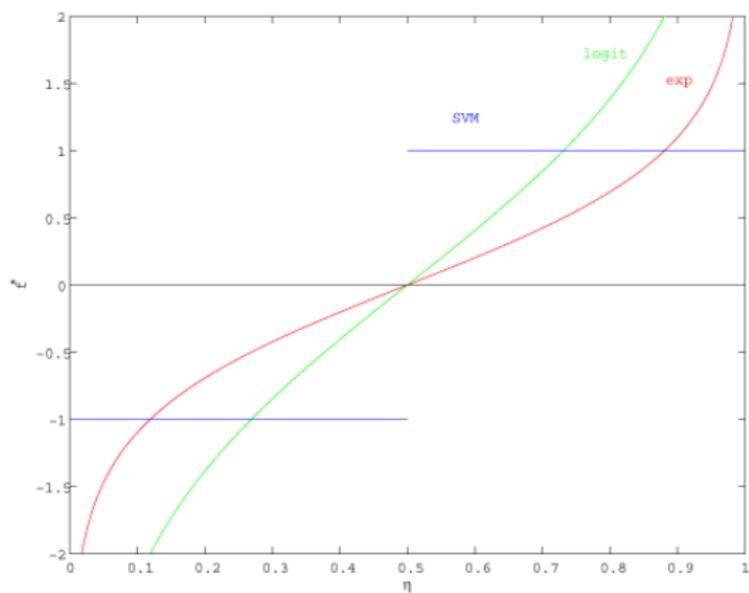
- Minimiseur de la fonctionnelle A noté f^*
- Minimum du φ -risque : $A^* = \min_f A(f) = A(f^*)$
- On peut montrer que $\text{sgn}(f^*) = g^*$ le classifieur optimal
- On peut également montrer que l'excès de risque en erreur de classification $L(f) - L^*$ est contrôlé par $A(f) - A^*$
- Exemples:
 - ▶ perte exponentielle (boosting)

$$f^*(x) = \frac{1}{2} \log \left(\frac{\eta(x)}{1 - \eta(x)} \right)$$

- ▶ "hinge loss" (SVM)

$$f^*(x) = \text{sgn}(\eta(x) - 1/2) = g^*(x)$$

Fonctions cibles



Et après?

Jusqu' à présent, on a mis en évidence :

- 1 les fonctions de décision candidates sont des **combinaisons linéaires** de fonctions

Et après?

Jusqu' à présent, on a mis en évidence :

- ① les fonctions de décision candidates sont des **combinaisons linéaires** de fonctions
- ② les critères de risque sont **convexifiés**

Et après?

Jusqu' à présent, on a mis en évidence :

- ① les fonctions de décision candidates sont des **combinaisons linéaires** de fonctions
- ② les critères de risque sont **convexifiés**

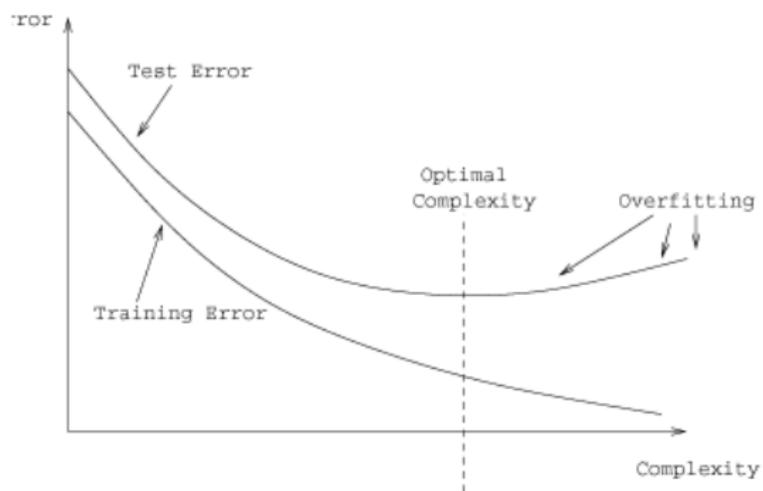
Et après?

Jusqu' à présent, on a mis en évidence :

- ① les fonctions de décision candidates sont des **combinaisons linéaires** de fonctions
- ② les critères de risque sont **convexifiés**

Quelle théorie pour le contrôle de la complexité ?

Overfitting



Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension

Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension
 - ▶ Mesure de complexité de nature combinatoire

Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension
 - ▶ Mesure de complexité de nature combinatoire
 - ▶ Capacité d'une famille d'ensembles à séparer un jeu de points

Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension
 - ▶ Mesure de complexité de nature combinatoire
 - ▶ Capacité d'une famille d'ensembles à séparer un jeu de points
- Exemple : \mathcal{H} famille de demi-espaces sur \mathbb{R}^m , $\text{VCdim}(\mathcal{H}) = m + 1$

Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension
 - ▶ Mesure de complexité de nature combinatoire
 - ▶ Capacité d'une famille d'ensembles à séparer un jeu de points
- Exemple : \mathcal{H} famille de demi-espaces sur \mathbb{R}^m , $\text{VCdim}(\mathcal{H}) = m + 1$
- Problème pour interpréter les performances des SVM ($m = \infty$)

Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension
 - ▶ Mesure de complexité de nature combinatoire
 - ▶ Capacité d'une famille d'ensembles à séparer un jeu de points
- Exemple : \mathcal{H} famille de demi-espaces sur \mathbb{R}^m , $\text{VCdim}(\mathcal{H}) = m + 1$
- Problème pour interpréter les performances des SVM ($m = \infty$)
- Idem avec le boosting...

Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension
 - ▶ Mesure de complexité de nature combinatoire
 - ▶ Capacité d'une famille d'ensembles à séparer un jeu de points
- Exemple : \mathcal{H} famille de demi-espaces sur \mathbb{R}^m , $\text{VCdim}(\mathcal{H}) = m + 1$
- Problème pour interpréter les performances des SVM ($m = \infty$)
- Idem avec le boosting...

Théorie de la complexité de Vapnik-Chervonenkis

- Notion de VC dimension
 - ▶ Mesure de complexité de nature combinatoire
 - ▶ Capacité d'une famille d'ensembles à séparer un jeu de points
- Exemple : \mathcal{H} famille de demi-espaces sur \mathbb{R}^m , $\text{VCdim}(\mathcal{H}) = m + 1$
- Problème pour interpréter les performances des SVM ($m = \infty$)
- Idem avec le boosting...

Les algorithmes performants ne sont pas rigoureusement expliqués par la théorie "standard" de Vapnik-Chervonenkis.

Autre mesure de complexité

- \mathcal{F} une famille de fonctions de décision et D_n un jeu de points X_1, \dots, X_n

Autre mesure de complexité

- \mathcal{F} une famille de fonctions de décision et D_n un jeu de points X_1, \dots, X_n

Complexité de Rademacher

Soient $\epsilon_1, \dots, \epsilon_n$ variables de signes $+1/-1$ i.i.d.

$$R_n(\mathcal{F}) = \mathbb{E}_\epsilon \sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \epsilon_i f(X_i) \right|$$

Autre mesure de complexité

- \mathcal{F} une famille de fonctions de décision et D_n un jeu de points X_1, \dots, X_n

Complexité de Rademacher

Soient $\epsilon_1, \dots, \epsilon_n$ variables de signes $+1/-1$ i.i.d.

$$R_n(\mathcal{F}) = \mathbb{E}_\epsilon \sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \epsilon_i f(X_i) \right|$$

Cas des familles $\mathcal{F} = \{f(x) = \sum \alpha_i k(x_i, x) : \sum_{i,j} \alpha_i \alpha_j k(x_i, x_j) \leq B^2\}$

Résultat:

$$R_n(\mathcal{F}) \leq \frac{B}{n} \sqrt{\sum_{i=1}^n k(X_i, X_i)}$$

Exemples II - données réelles

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$

Validation croisée

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$
- **Une solution** : on réserve une partie des données initiales pour constituer une base de test obtenue par sous-échantillonnage **aléatoirement**

Validation croisée

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$
- **Une solution** : on réserve une partie des données initiales pour constituer une base de test obtenue par sous-échantillonnage **aléatoirement**
- **Une autre approche** : la validation croisée

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$
- **Une solution** : on réserve une partie des données initiales pour constituer une base de test obtenue par sous-échantillonnage **aléatoirement**
- **Une autre approche** : la validation croisée
 - ▶ on coupe l'échantillon D (taille n) en p sous-échantillons D_1, \dots, D_p de taille n/p

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$
- **Une solution** : on réserve une partie des données initiales pour constituer une base de test obtenue par sous-échantillonnage **aléatoirement**
- **Une autre approche** : la validation croisée
 - ▶ on coupe l'échantillon D (taille n) en p sous-échantillons D_1, \dots, D_p de taille n/p
 - ▶ on apprend sur $D \setminus D_i$ de taille $n - n/p$

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$
- **Une solution** : on réserve une partie des données initiales pour constituer une base de test obtenue par sous-échantillonnage **aléatoirement**
- **Une autre approche** : la validation croisée
 - ▶ on coupe l'échantillon D (taille n) en p sous-échantillons D_1, \dots, D_p de taille n/p
 - ▶ on apprend sur $D \setminus D_i$ de taille $n - n/p$
 - ▶ on teste sur D_i

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$
- **Une solution** : on réserve une partie des données initiales pour constituer une base de test obtenue par sous-échantillonnage **aléatoirement**
- **Une autre approche** : la validation croisée
 - ▶ on coupe l'échantillon D (taille n) en p sous-échantillons D_1, \dots, D_p de taille n/p
 - ▶ on apprend sur $D \setminus D_i$ de taille $n - n/p$
 - ▶ on teste sur D_i
 - ▶ on fait la moyenne des erreurs

- **Problème** : estimation de l'**erreur en généralisation** $\mathbb{P}\{Y \cdot f(X) < 0\}$
- **Une solution** : on réserve une partie des données initiales pour constituer une base de test obtenue par sous-échantillonnage **aléatoirement**
- **Une autre approche** : la validation croisée
 - ▶ on coupe l'échantillon D (taille n) en p sous-échantillons D_1, \dots, D_p de taille n/p
 - ▶ on apprend sur $D \setminus D_i$ de taille $n - n/p$
 - ▶ on teste sur D_i
 - ▶ on fait la moyenne des erreurs
 - ▶ en général $p = 10$

Erreur d'apprentissage vs. erreur de test

Script :

```
load spam.data
N = size(spam,1); ncol = size(spam, 2); d = ncol-1;
m = floor(N*.1); n = N-m;
ind = randperm(N);
X = spam(ind, 1:d);
Y = 2*spam(ind,ncol)-1;
d1 = data(X(1:n, :), Y(1:n));
d2 = data(X((n+1):N, :), Y((n+1):N));
a=svm;
[tr a] = train(a,d1);
r = test(a, d2);
loss(tr)
loss(r)
```

Utiliser la validation croisée

Il faut remplacer:

```
a=svm;
```

par

```
s=svm;
```

```
a=cv(s, 'folds=10');
```

On récupère l'erreur correspondante avec :

```
tmp = tmp.Y
```

Noyaux positifs

Définition

Soit \mathcal{X} l'espace où vivent les observations.

Noyau positif

Une fonction $k : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$ est un noyau positif si et seulement si

- 1 k est symétrique: $k(x, x') = k(x', x)$, $\forall x, x' \in \mathcal{X}$
- 2 k est positive:

$$\sum_{i=1}^n \sum_{j=1}^n c_i c_j k(x_i, x_j) \geq 0, \quad \forall c_i \in \mathbb{R}, \quad \forall x_i \in \mathcal{X}, \quad \forall n \geq 1$$

Un théorème d'analyse

Théorème de Mercer

Pour tout noyau positif k sur \mathcal{X} il existe un espace de Hilbert \mathcal{H} et une application Φ tels que:

$$k(x, x') = \langle \Phi(x), \Phi(x') \rangle, \quad \forall x, x' \in \mathcal{X}$$

où $\langle \cdot, \cdot \rangle$ représente le produit scalaire sur \mathcal{H} .

- Le théorème de Mercer est non constructif: il ne fournit ni \mathcal{H} , ni Φ

- Le théorème de Mercer est non constructif: il ne fournit ni \mathcal{H} , ni Φ
- En pratique:

- Le théorème de Mercer est non constructif: il ne fournit ni \mathcal{H} , ni Φ
- En pratique:
 - ▶ \mathcal{H} est un espace de grande dimension

- Le théorème de Mercer est non constructif: il ne fournit ni \mathcal{H} , ni Φ
- En pratique:
 - ▶ \mathcal{H} est un espace de grande dimension
 - ▶ Φ est une application non-linéaire

- Le théorème de Mercer est non constructif: il ne fournit ni \mathcal{H} , ni Φ
- En pratique:
 - ▶ \mathcal{H} est un espace de grande dimension
 - ▶ Φ est une application non-linéaire
- \mathcal{H} est un espace de représentation des données, connu sous le nom de "feature space" ou espace de caractéristiques

- Le théorème de Mercer est non constructif: il ne fournit ni \mathcal{H} , ni Φ
- En pratique:
 - ▶ \mathcal{H} est un espace de grande dimension
 - ▶ Φ est une application non-linéaire
- \mathcal{H} est un espace de représentation des données, connu sous le nom de "feature space" ou espace de caractéristiques
- L'astuce du noyau consiste à faire l'impasse sur \mathcal{H} et Φ si on sait qu'ils existent!

Distances images

- Norme euclidienne sur \mathbb{R}^m : $\forall u \in \mathbb{R}^m$, $\|u\| = \sqrt{\langle u, u \rangle}$ où \langle , \rangle produit scalaire sur \mathbb{R}^m

Distances images

- Norme euclidienne sur \mathbb{R}^m : $\forall u \in \mathbb{R}^m$, $\|u\| = \sqrt{\langle u, u \rangle}$ où \langle , \rangle produit scalaire sur \mathbb{R}^m
- Distance euclidienne:
$$d(u, v) = \|u - v\| = \sqrt{\langle u, u \rangle + \langle v, v \rangle - 2 \langle u, v \rangle}$$

Distances images

- Norme euclidienne sur \mathbb{R}^m : $\forall u \in \mathbb{R}^m$, $\|u\| = \sqrt{\langle u, u \rangle}$ où \langle , \rangle produit scalaire sur \mathbb{R}^m
- Distance euclidienne:
$$d(u, v) = \|u - v\| = \sqrt{\langle u, u \rangle + \langle v, v \rangle - 2 \langle u, v \rangle}$$
- Transformation non-linéaire : $\Phi : \mathbb{R}^d \rightarrow \mathbb{R}^m$ avec $m > d$

Distances images

- Norme euclidienne sur \mathbb{R}^m : $\forall u \in \mathbb{R}^m$, $\|u\| = \sqrt{\langle u, u \rangle}$ où \langle , \rangle produit scalaire sur \mathbb{R}^m
- Distance euclidienne:
$$d(u, v) = \|u - v\| = \sqrt{\langle u, u \rangle + \langle v, v \rangle - 2 \langle u, v \rangle}$$
- Transformation non-linéaire : $\Phi : \mathbb{R}^d \rightarrow \mathbb{R}^m$ avec $m > d$
- Noyau: $k(x, x') = \langle \Phi(x), \Phi(x') \rangle$

Distances images

- Norme euclidienne sur \mathbb{R}^m : $\forall u \in \mathbb{R}^m$, $\|u\| = \sqrt{\langle u, u \rangle}$ où \langle , \rangle produit scalaire sur \mathbb{R}^m
- Distance euclidienne:
$$d(u, v) = \|u - v\| = \sqrt{\langle u, u \rangle + \langle v, v \rangle - 2 \langle u, v \rangle}$$
- Transformation non-linéaire : $\Phi : \mathbb{R}^d \rightarrow \mathbb{R}^m$ avec $m > d$
- Noyau: $k(x, x') = \langle \Phi(x), \Phi(x') \rangle$
- Distance image:

$$d_\Phi(x, x') = \|\Phi(x) - \Phi(x')\| = \sqrt{k(x, x) + k(x', x') - 2k(x, x')}$$

\Rightarrow la distance induite par Φ ne fait intervenir que le noyau

Intérêt pour la classification

- **Aucune complication algorithmique** en remplaçant le produit scalaire par une autre mesure de similarité

Intérêt pour la classification

- **Aucune complication algorithmique** en remplaçant le produit scalaire par une autre mesure de similarité
- **Transformer un problème initialement non-linéaire en un problème linéaire** en envoyant les données dans un espace plus grand

Intérêt pour la classification

- **Aucune complication algorithmique** en remplaçant le produit scalaire par une autre mesure de similarité
- **Transformer un problème initialement non-linéaire en un problème linéaire** en envoyant les données dans un espace plus grand

Intérêt pour la classification

- **Aucune complication algorithmique** en remplaçant le produit scalaire par une autre mesure de similarité
- **Transformer un problème initialement non-linéaire en un problème linéaire** en envoyant les données dans un espace plus grand

Exemple

Soit $f(x, y) = ax^2 + bx + c - y = 0$ une surface de décision polynomiale (parabole dans \mathbb{R}^2).

Intérêt pour la classification

- **Aucune complication algorithmique** en remplaçant le produit scalaire par une autre mesure de similarité
- **Transformer un problème initialement non-linéaire en un problème linéaire** en envoyant les données dans un espace plus grand

Exemple

Soit $f(x, y) = ax^2 + bx + c - y = 0$ une surface de décision polynomiale (parabole dans \mathbb{R}^2).

Rôle clé de la transformation:

$$\begin{aligned}\Phi : \mathbb{R}^2 &\rightarrow \mathbb{R}^4 \\ x &\mapsto (x^2, x, 1, y)^T\end{aligned}$$

Du non-linéaire au linéaire

Exemple (suite)

On peut écrire:

$$g(x^2, x, 1, y) = ax^2 + bx + c - y = 0$$

où $g(u, v, w, y) = au + bv + cw - y$.

L'équation $g(u, v, w, y) = 0$ définit une surface de décision linéaire dans \mathbb{R}^4 .

Du non-linéaire au linéaire

Exemple (suite)

On peut écrire:

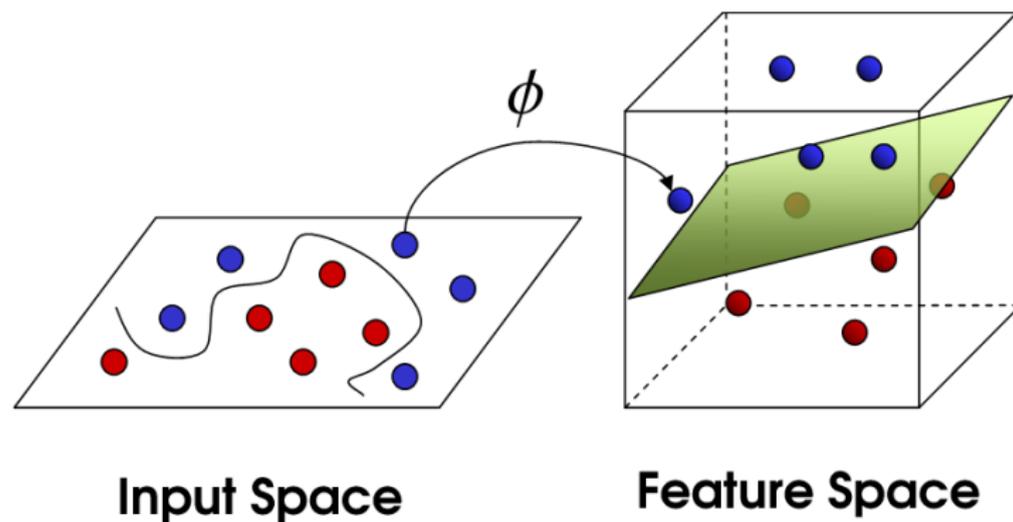
$$g(x^2, x, 1, y) = ax^2 + bx + c - y = 0$$

où $g(u, v, w, y) = au + bv + cw - y$.

L'équation $g(u, v, w, y) = 0$ définit une surface de décision linéaire dans \mathbb{R}^4 .

Un problème non-linéaire dans un certain espace peut parfois se formuler comme un problème linéaire dans un espace plus grand.

Du non-linéaire au linéaire



ACP à noyau

ACP classique

On considère un nuage de points x_1, \dots, x_n centrés en l'origine.

ACP classique

On considère un nuage de points x_1, \dots, x_n centrés en l'origine.

Buts de l'ACP

- méthode de visualisation des données
- réduction de la dimension effective des données

ACP classique

On considère un nuage de points x_1, \dots, x_n centrés en l'origine.

Buts de l'ACP

- méthode de visualisation des données
- réduction de la dimension effective des données

L'ACP consiste à identifier les composantes principales de l'échantillon constituées par

- 1 la meilleure direction de projection du nuage de points
i.e. celle de variance maximale

On considère un nuage de points x_1, \dots, x_n centrés en l'origine.

Buts de l'ACP

- méthode de visualisation des données
- réduction de la dimension effective des données

L'ACP consiste à identifier les composantes principales de l'échantillon constituées par

- 1 la meilleure direction de projection du nuage de points
i.e. celle de variance maximale
- 2 puis, la meilleure direction de projection orthogonale à la première

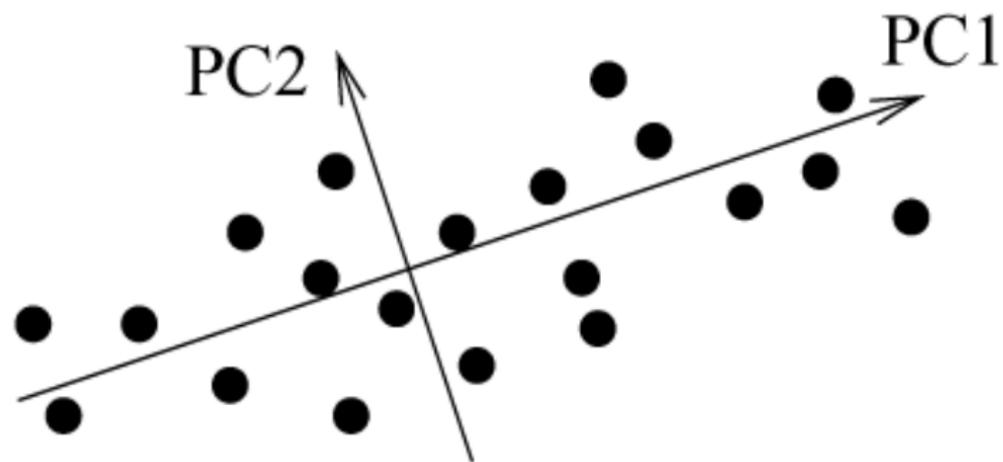
On considère un nuage de points x_1, \dots, x_n centrés en l'origine.

Buts de l'ACP

- méthode de visualisation des données
- réduction de la dimension effective des données

L'ACP consiste à identifier les composantes principales de l'échantillon constituées par

- 1 la meilleure direction de projection du nuage de points
i.e. celle de variance maximale
- 2 puis, la meilleure direction de projection orthogonale à la première
- 3 et, ainsi de suite, jusqu'à la n -ième



- Projection orthogonale d'un vecteur x sur la direction $w \in \mathbb{R}^d$:

$$p_w(x) = \frac{\langle x, w \rangle}{\|w\|}$$

- Projection orthogonale d'un vecteur x sur la direction $w \in \mathbb{R}^d$:

$$p_w(x) = \frac{\langle x, w \rangle}{\|w\|}$$

- Variance empirique du nuage de points selon la direction w :

$$\mathbb{V}(p_w) = \frac{1}{n} \sum_{i=1}^n \frac{\langle x_i, w \rangle^2}{\|w\|^2}$$

- Projection orthogonale d'un vecteur x sur la direction $w \in \mathbb{R}^d$:

$$p_w(x) = \frac{\langle x, w \rangle}{\|w\|}$$

- Variance empirique du nuage de points selon la direction w :

$$\mathbb{V}(p_w) = \frac{1}{n} \sum_{i=1}^n \frac{\langle x_i, w \rangle^2}{\|w\|^2}$$

- Matrice de covariance empirique $\Sigma = \frac{1}{n} \sum_{i=1}^n x_i x_i^T$

- Projection orthogonale d'un vecteur x sur la direction $w \in \mathbb{R}^d$:

$$p_w(x) = \frac{\langle x, w \rangle}{\|w\|}$$

- Variance empirique du nuage de points selon la direction w :

$$\mathbb{V}(p_w) = \frac{1}{n} \sum_{i=1}^n \frac{\langle x_i, w \rangle^2}{\|w\|^2}$$

- Matrice de covariance empirique $\Sigma = \frac{1}{n} \sum_{i=1}^n x_i x_i^T$
- On a donc :

$$\mathbb{V}(p_w) = \frac{w^T \Sigma w}{\|w\|^2}$$

Problème d'optimisation

Première composante principale

$$\arg \max_w \mathbb{V}(p_w) = \frac{w^T \Sigma w}{\|w\|^2}$$

Problème d'optimisation

Première composante principale

$$\arg \max_w \mathbb{V}(p_w) = \frac{w^T \Sigma w}{\|w\|^2}$$

Solution

Les composantes principales sont les vecteurs propres de la Σ rangés selon la décroissance des valeurs propres correspondantes.

Problème d'optimisation

Première composante principale

$$\arg \max_w \mathbb{V}(p_w) = \frac{w^T \Sigma w}{\|w\|^2}$$

Solution

Les composantes principales sont les vecteurs propres de la Σ rangés selon la décroissance des valeurs propres correspondantes.

Remarque : la matrice Σ est symétrique réelle donc diagonalisable dans une base orthonormée.

ACP (suite)

On cherche un vecteur v et un réel λ tels que:

$$\Sigma v = \lambda v$$

Or, on a :

$$\Sigma v = \frac{1}{n} \sum_{i=1}^n \langle x_i, v \rangle x_i$$

D'où:

$$v = \sum_{i=1}^n \left(\frac{\langle x_i, v \rangle}{n\lambda} \right) x_i = \sum_{i=1}^n \alpha_i x_i$$

ACP (suite)

On cherche un vecteur v et un réel λ tels que:

$$\Sigma v = \lambda v$$

Or, on a :

$$\Sigma v = \frac{1}{n} \sum_{i=1}^n \langle x_i, v \rangle x_i$$

D'où:

$$v = \sum_{i=1}^n \left(\frac{\langle x_i, v \rangle}{n\lambda} \right) x_i = \sum_{i=1}^n \alpha_i x_i$$

On utilise

$$x_j^T \Sigma v = \lambda \langle x_j, v \rangle, \quad \forall j$$

et on y substitue les expressions de Σ et v :

$$\frac{1}{n} \sum_{i=1}^n \alpha_i \left\langle x_j, \sum_{k=1}^n \langle x_k, x_i \rangle x_k \right\rangle = \lambda \sum_{i=1}^n \alpha_i \langle x_j, x_i \rangle$$

- On note $K = (\langle x_i, x_j \rangle)_{i,j}$ la matrice de Gram

ACP (suite)

- On note $K = (\langle x_i, x_j \rangle)_{i,j}$ la matrice de Gram
- On peut écrire alors le système:

$$K^2 \alpha = n \lambda K \alpha$$

- On note $K = (\langle x_i, x_j \rangle)_{i,j}$ la matrice de Gram
- On peut écrire alors le système:

$$K^2\alpha = n\lambda K\alpha$$

- Pour résoudre en α , on résout donc le problème aux éléments propres

$$K\alpha = n\lambda\alpha$$

Défauts de l'ACP classique

- elle est adaptée surtout au cas de réalisations de gaussiennes multivariées

Défauts de l'ACP classique

- elle est adaptée surtout au cas de réalisations de gaussiennes multivariées
 - ▶ en général, la non-corrélation n'implique pas l'indépendance des directions principales

Défauts de l'ACP classique

- elle est adaptée surtout au cas de réalisations de gaussiennes multivariées
 - ▶ en général, la non-corrélation n'implique pas l'indépendance des directions principales
 - ▶ alternative : Analyse en Composantes **Indépendantes** (plutôt que Principales)

Défauts de l'ACP classique

- elle est adaptée surtout au cas de réalisations de gaussiennes multivariées
 - ▶ en général, la non-corrélation n'implique pas l'indépendance des directions principales
 - ▶ alternative : Analyse en Composantes **Indépendantes** (plutôt que Principales)
- elle est adaptée aux structures linéaires

Défauts de l'ACP classique

- elle est adaptée surtout au cas de réalisations de gaussiennes multivariées
 - ▶ en général, la non-corrélation n'implique pas l'indépendance des directions principales
 - ▶ alternative : Analyse en Composantes **Indépendantes** (plutôt que Principales)
- elle est adaptée aux structures linéaires
 - ▶ les nuages de points ne sont pas tous ellipsoïdaux!!

Défauts de l'ACP classique

- elle est adaptée surtout au cas de réalisations de gaussiennes multivariées
 - ▶ en général, la non-corrélation n'implique pas l'indépendance des directions principales
 - ▶ alternative : Analyse en Composantes **Indépendantes** (plutôt que Principales)
- elle est adaptée aux structures linéaires
 - ▶ les nuages de points ne sont pas tous ellipsoïdaux!!
 - ▶ alternative : **Kernel PCA**

- On applique une transformation Φ qui envoie le nuage de points X dans un espace où la structure est linéaire

- On applique une transformation Φ qui envoie le nuage de points X dans un espace où la structure est linéaire
- La matrice de covariance de $\Phi(X) = (\Phi(x_1), \dots, \Phi(x_n))^T$ est alors

$$\Sigma = \frac{1}{n} \sum_{i=1}^n \Phi(x_i) \Phi(x_i)^T$$

- On applique une transformation Φ qui envoie le nuage de points X dans un espace où la structure est linéaire
- La matrice de covariance de $\Phi(X) = (\Phi(x_1), \dots, \Phi(x_n))^T$ est alors

$$\Sigma = \frac{1}{n} \sum_{i=1}^n \Phi(x_i) \Phi(x_i)^T$$

- **Astuce du noyau** : $K = (k(x_i, x_j))_{i,j} = (\Phi(x_i)^T \Phi(x_j))_{i,j}$

ACP à noyau (suite)

- "Directions" principales de la forme:

$$p_i(x) = \sum_{j=1}^n \alpha_{i,j} k(x_j, x)$$

ACP à noyau (suite)

- "Directions" principales de la forme:

$$p_i(x) = \sum_{j=1}^n \alpha_{i,j} k(x_j, x)$$

- le vecteur $\alpha_i = (\alpha_{i,1}, \dots, \alpha_{i,n})$ est solution du problème d'optimisation:

$$\max_{\alpha} \frac{\alpha^T K^2 \alpha}{\alpha^T K \alpha}$$

sous les contraintes: $\alpha_j^T K \alpha_j$ pour $j = 1, \dots, i - 1$

ACP à noyau (suite)

- "Directions" principales de la forme:

$$p_i(x) = \sum_{j=1}^n \alpha_{i,j} k(x_j, x)$$

- le vecteur $\alpha_i = (\alpha_{i,1}, \dots, \alpha_{i,n})$ est solution du problème d'optimisation:

$$\max_{\alpha} \frac{\alpha^T K^2 \alpha}{\alpha^T K \alpha}$$

sous les contraintes: $\alpha_j^T K \alpha_j$ pour $j = 1, \dots, i - 1$

- on résout le problème aux éléments propres:

$$K \alpha = n \lambda \alpha$$

SVM pour la régression

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives
- **Données** : $\{(x_i, y_i)\}_{i=1, \dots, n}$

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives
- **Données** : $\{(x_i, y_i)\}_{i=1, \dots, n}$
- **Prédicteur** : $f(x) = \beta^T x + b$, $\beta \in \mathbb{R}^d$, $b \in \mathbb{R}$

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives
- **Données** : $\{(x_i, y_i)\}_{i=1, \dots, n}$
- **Prédicteur** : $f(x) = \beta^T x + b$, $\beta \in \mathbb{R}^d$, $b \in \mathbb{R}$
- **Norme** : $\|f\| = \|\beta\| = \sqrt{\beta^T \beta}$

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives
- **Données** : $\{(x_i, y_i)\}_{i=1, \dots, n}$
- **Prédicteur** : $f(x) = \beta^T x + b$, $\beta \in \mathbb{R}^d$, $b \in \mathbb{R}$
- **Norme** : $\|f\| = \|\beta\| = \sqrt{\beta^T \beta}$
- **Critère** : moindres carrés $(y - f(x))^2$

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives
- **Données** : $\{(x_i, y_i)\}_{i=1, \dots, n}$
- **Prédicteur** : $f(x) = \beta^T x + b$, $\beta \in \mathbb{R}^d$, $b \in \mathbb{R}$
- **Norme** : $\|f\| = \|\beta\| = \sqrt{\beta^T \beta}$
- **Critère** : moindres carrés $(y - f(x))^2$
- **Problèmes** :

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives
- **Données** : $\{(x_i, y_i)\}_{i=1, \dots, n}$
- **Prédicteur** : $f(x) = \beta^T x + b$, $\beta \in \mathbb{R}^d$, $b \in \mathbb{R}$
- **Norme** : $\|f\| = \|\beta\| = \sqrt{\beta^T \beta}$
- **Critère** : moindres carrés $(y - f(x))^2$
- **Problèmes** :
 - ▶ overfitting quand d est grand,

Problème de la régression

- Problème de prédiction d'une variable d'intérêt réelle à partir d'un vecteur $X \in \mathbb{R}^d$ de variables explicatives
- **Données** : $\{(x_i, y_i)\}_{i=1, \dots, n}$
- **Prédicteur** : $f(x) = \beta^T x + b$, $\beta \in \mathbb{R}^d$, $b \in \mathbb{R}$
- **Norme** : $\|f\| = \|\beta\| = \sqrt{\beta^T \beta}$
- **Critère** : moindres carrés $(y - f(x))^2$
- **Problèmes** :
 - ▶ overfitting quand d est grand,
 - ▶ sensibilité aux valeurs aberrantes.

Régression "ridge"

Idée : imposer une contrainte sur la norme L_2 des poids

Problème d'optimisation

$$\min_f \sum_{i=1}^n (y_i - f(x_i))^2$$

sous la contrainte:

$$\|f\|^2 \leq \lambda$$

Régression "ridge"

Formulation équivalente

$$\min_f \sum_{i=1}^n (y_i - f(x_i))^2 + C \|f\|^2$$

On note $X = (x_1, \dots, x_n)^T$, $Y = (y_1, \dots, y_n)^T$

Régression "ridge"

Formulation équivalente

$$\min_f \sum_{i=1}^n (y_i - f(x_i))^2 + C \|f\|^2$$

On note $X = (x_1, \dots, x_n)^T$, $Y = (y_1, \dots, y_n)^T$

Solution :

$$\hat{\theta} = (X^T X + C \text{Id})^{-1} X^T Y$$

SVM pour la régression

On cherche le prédicteur sous la forme

$$f(x) = \sum_{i=1}^n \alpha_i k(x_i, x)$$

On pose $K = (k(x_i, x_j))_{i,j}$ la matrice de Gram et on définit:

$$\|f\|_K^2 = \alpha^T K \alpha$$

SVM pour la régression

On cherche le prédicteur sous la forme

$$f(x) = \sum_{i=1}^n \alpha_i k(x_i, x)$$

On pose $K = (k(x_i, x_j))_{i,j}$ la matrice de Gram et on définit:

$$\|f\|_K^2 = \alpha^T K \alpha$$

Problème d'optimisation

$$\min_{\alpha} \sum_{i=1}^n (y_i - K\alpha)^2 + C\alpha^T K \alpha$$

SVM pour la régression

On cherche le prédicteur sous la forme

$$f(x) = \sum_{i=1}^n \alpha_i k(x_i, x)$$

On pose $K = (k(x_i, x_j))_{i,j}$ la matrice de Gram et on définit:

$$\|f\|_K^2 = \alpha^T K \alpha$$

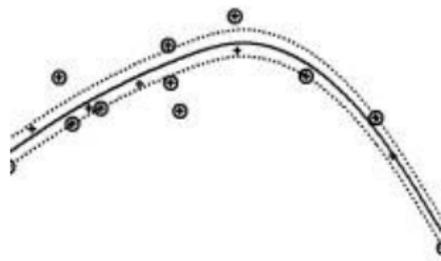
Problème d'optimisation

$$\min_{\alpha} \sum_{i=1}^n (y_i - K\alpha)^2 + C\alpha^T K \alpha$$

Solution :

$$\hat{\alpha} = (K + Cn \text{Id})^{-1} Y$$

SVM pour la régression



⇒ concept analogue de vecteurs de support

Conclusion

- Idées géométriques sous-jacentes à la conception des SVM

On a vu ...

- Idées géométriques sous-jacentes à la conception des SVM
- Aspects algorithmiques des SVM - optimisation

- Idées géométriques sous-jacentes à la conception des SVM
- Aspects algorithmiques des SVM - optimisation
- Aspects statistiques - contrôle de la complexité

- Idées géométriques sous-jacentes à la conception des SVM
- Aspects algorithmiques des SVM - optimisation
- Aspects statistiques - contrôle de la complexité
- Adaptation (sans douleur!) de méthodes statistiques classiques pour l'analyse de données

- Idées géométriques sous-jacentes à la conception des SVM
- Aspects algorithmiques des SVM - optimisation
- Aspects statistiques - contrôle de la complexité
- Adaptation (sans douleur!) de méthodes statistiques classiques pour l'analyse de données
- SVM en action avec l'utilisation du logiciel SPIDER

- Aspects fonctionnels dans l'étude des SVM (théorie des RKHS)

On a tu ...

- Aspects fonctionnels dans l'étude des SVM (théorie des RKHS)
- Technologie de construction de noyaux dédiés

- Aspects fonctionnels dans l'étude des SVM (théorie des RKHS)
- Technologie de construction de noyaux dédiés
- Variantes des SVM

- Aspects fonctionnels dans l'étude des SVM (théorie des RKHS)
- Technologie de construction de noyaux dédiés
- Variantes des SVM
- Autres applications des méthodes à noyaux : Kernel CCA, Kernel ICA, One-Class SVM, ... etc...

On a tu ...

- Aspects fonctionnels dans l'étude des SVM (théorie des RKHS)
- Technologie de construction de noyaux dédiés
- Variantes des SVM
- Autres applications des méthodes à noyaux : Kernel CCA, Kernel ICA, One-Class SVM, ... etc...
- Concurrents des SVM comme le boosting

- <http://www.kernel-machines.org>
- Vapnik (1998) - Statistical Learning Theory
- Hastie, Tibshirani, Friedman (2001) - The Elements of Statistical Learning
- Schölkopf, Tsuda, Vert (2004) - Kernel Methods in Computational Biology
- Autres ouvrages de référence:
 - ▶ Schölkopf, Burges, Smola (1998) - Advances in Kernel Methods: Support Vector Learning
 - ▶ Cristianini, Shawe-Taylor (2000) - An Introduction to Support Vector Machines and Other Kernel-based Learning Methods
 - ▶ Schölkopf, Smola (2002) - Learning with Kernels
 - ▶ Shawe-Taylor, Cristianini (2004) - Kernel Methods for Pattern Analysis