

Techniques d'apprentissage supervisé pour discrimination

Séparateurs à Vaste Marge (SVM) – Présentation et applications

Plan

- ▶ SVM
 - ▶ Historique
 - ▶ Présentation
 - ▶ Noyaux
 - ▶ SVM multi-classe
- ▶ Données
 - ▶ Individus et Caractéristiques
 - ▶ Echantillons: Apprentissage/Test
- ▶ Applications
 - ▶ Diagnostic cytologique (exemple R)
 - ▶ RI sélective (basée sur des prédicteurs de difficulté des requêtes)



3

SVM

Séparateur à Vaste Marge

SVM - Introduction

- Classe d'algorithmes d'apprentissage supervisé
- But:
 - Initial: discrimination - prévision d'une variable qualitative binaire
 - Généralisé: prévision d'une variable quantitative
- Recherche le hyperplan de marge optimale de séparation (discrimination dichotomique)
- Trouver un classifieur (ou une fonction de discrimination) avec une capacité de généralisation (qualité de prévision) maximale

SVM - Historique

- Marge maximale + Fonction noyau → SVM
- **Idée des hyperplans à marge maximale:**
 - **1963:** V. Vapnik et A. Lerner^[1]
 - **1973:** Richard Duda et Peter Hart^[2]
- **Idée des fonctions noyaux:**
 - **1909:** théorème de Mercer^[3]
 - **1964:** Aizermann et al. ^[4] – fonctions noyaux dans l'apprentissage artificiel
- Article fondateur: **1992:** Boser et al. ^[5]
- **1995:** livre de Vapnik^[6]
- **1997:** brevet américain

[1] (en) Vladimir Vapnik et A. Lerner, Pattern Recognition using Generalized Portrait Method, Automation and Remote Control, 1963

[2] (en) Richard O. Duda, Peter E. Hart, David G. Stork, Pattern classification, Wiley-interscience, 1973

[3] (en) J. Mercer, Functions of positive and negative type and their connection with the theory of integral equations. Philos. Trans. Roy. Soc. London, A 209:415--446, 1909





[4] M. Aizerman, E. Braverman, and L. Rozonoer, Theoretical foundations of the potential function method in pattern recognition learning, Automation and Remote Control 25:821--837, 1964

[5] (en) Bernhard E. Boser, Isabelle M. Guyon, Vladimir N. Vapnik, A Training Algorithm for Optimal Margin Classifiers [archive] In Fifth Annual Workshop on Computational Learning Theory, pages 144--152, Pittsburgh, ACM. 1992

[6] V. Vapnik, The nature of statistical learning theory, N-Y, Springer-Verlag, 1995

SVM – Discrimination binaire (I)

- Exemples de quatre types de problèmes de discrimination binaire
 - Il s'agit de séparer les points bleus des croix rouges
 - La frontière de décision est représentée en noir



SVM – Discrimination binaire (II)

- But: construire une fonction de décision pour associer à chaque observation sa classe
- Cadre probabiliste; observations = vecteurs $\mathbf{x} \in \mathbb{R}^p$.
- On suppose l'existence d'une loi inconnue $\mathbb{P}(\mathbf{x}, y)$ sur $(\mathbb{R}^p, \{-1, 1\})$
- L'estimateur de la fonction de décision idéale $D : \mathbb{R}^p \rightarrow \{-1, 1\}$
 - qui minimise pour toutes les observations la probabilité d'erreur $\mathbb{P}(D(\mathbf{x}) \neq y \mid \mathbf{x})$
- On suppose l'existence d'un échantillon (ensemble d'apprentissage)
 - $\{(\mathbf{x}_i, y_i), i = 1, n\}$
 - i.i.d. de loi parente $\mathbb{P}(\mathbf{x}, y)$

SVM linéaires – Problème de discrimination linéaire

- Problème de discrimination linéairement séparable:
 - \exists une fonction de décision linéaire (séparateur linéaire) qui classe correctement toutes les observations de l'ensemble de l'apprentissage
 - f est une fonction caractéristique

$$D(\mathbf{x}) = \text{signe}(f(\mathbf{x})) \text{ avec } f(\mathbf{x}) = \mathbf{v}^\top \mathbf{x} + a, \mathbf{v} \in \mathbb{R}^p \text{ et } a \in \mathbb{R}$$

- On peut associer une frontière de décision à cette fonction de décision linéaire

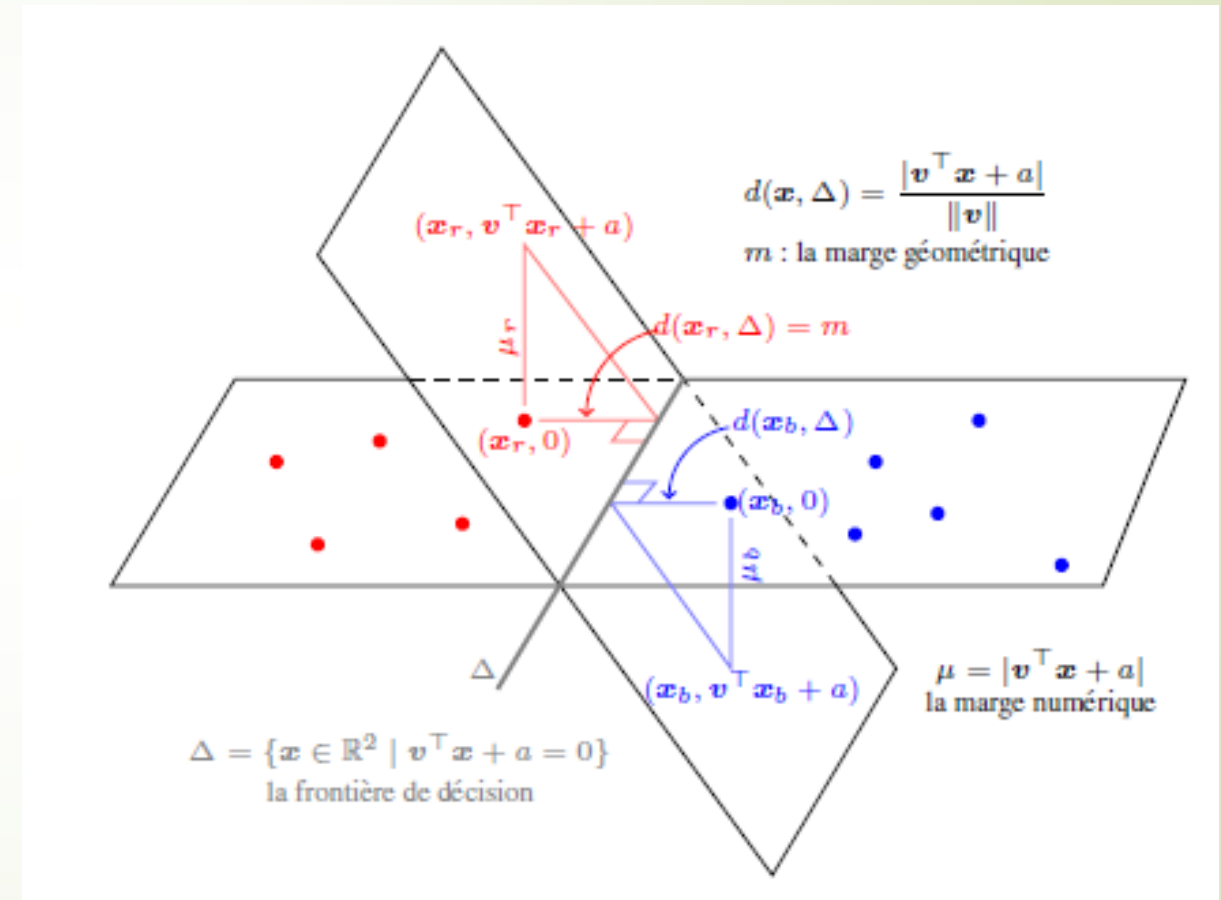
$$\Delta(\mathbf{v}, a) = \{\mathbf{x} \in \mathbb{R}^p \mid \mathbf{v}^\top \mathbf{x} + a = 0\}$$

SVM linéaire – La marge d'un classifieur

- Deux marges pour un même classifieur linéaire:
- Géométrique: la plus petite distance d'un point de l'échantillon à la frontière de décision
- Numérique: la plus petite valeur de la fonction de décision atteinte sur un point de l'échantillon

SVM linéaire – La marge d'un classifieur

- Illustration de deux notions de marge sur un exemple de discrimination linéaire séparable (2 dimensions)



SVM linéaire – Maximisation de la marge d'un classifieur

- Maximiser la marge → maximiser la confiance → minimiser la probabilité d'erreur associée au classifieur:

$$\max_{\mathbf{v}, a} \underbrace{\min_{i \in [1, n]} \text{dist}(\mathbf{x}_i, \Delta(\mathbf{v}, a))}_{\text{marge : } m}$$


- Définition: SVM sur des données linéairement séparables:

Soit $\{(\mathbf{x}_i, y_i); i = 1, n\}$ un ensemble de vecteurs formes étiquetées avec $\mathbf{x}_i \in \mathbb{R}^p$ et $y_i \in \{1, -1\}$. Un séparateur à vaste marge linéaire (SVM et support vector machine) est un discriminateur linéaire de la forme : $D(x) = \text{signe}(\mathbf{w}^\top \mathbf{x} + b)$ où $\mathbf{w} \in \mathbb{R}^p$ et $b \in \mathbb{R}$ sont donnés par la résolution du problème suivant :

$$\begin{cases} \min_{\mathbf{w}, b} & \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{avec} & y_i(\mathbf{w}^\top \mathbf{x}_i + b) \geq 1 \quad i = 1, n \end{cases}$$

SVM linéaire – Vecteurs support

- Les vecteurs support définissent la frontière de décision



SVM linéaire – Le cas des données non séparables (I)

- Notions d'écart:

$$\text{pas d'erreur : } y_i(\mathbf{w}^\top \mathbf{x}_i + b) \geq 1 \Rightarrow \xi_i = 0$$


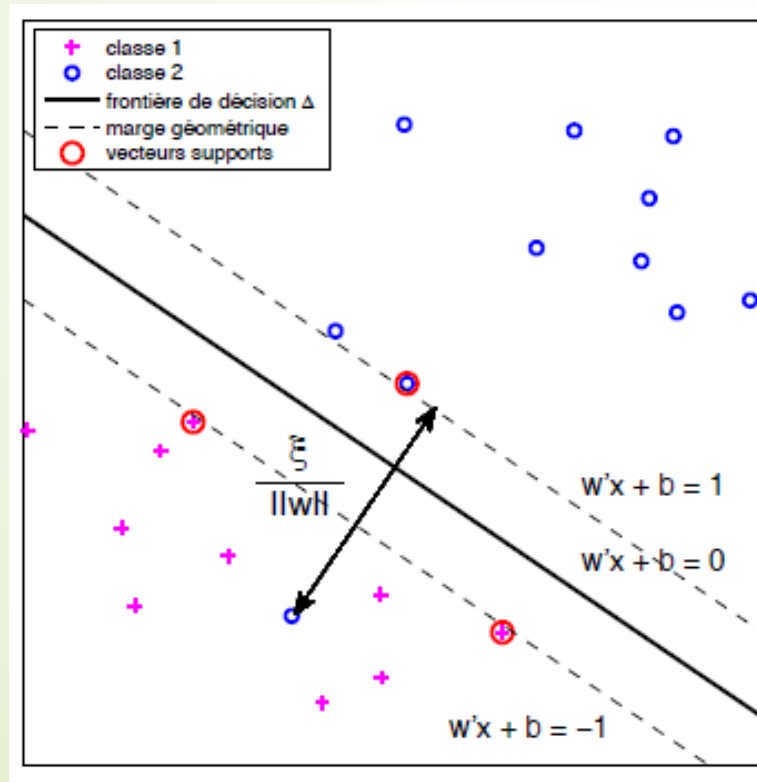
$$\text{erreur : } y_i(\mathbf{w}^\top \mathbf{x}_i + b) < 1 \Rightarrow \xi_i = 1 - y_i(\mathbf{w}^\top \mathbf{x}_i + b) > 0$$

- Notion de « cout charnière »:

$$\xi_i = \max(0, 1 - y_i(\mathbf{w}^\top \mathbf{x}_i + b))$$

SVM linéaire – Le cas des données non séparables (II)

- Notions d'écart et de cout charnière; point bleu mal classé



SVM – Le cas non linéaire: les noyaux

- Idée: reconsidérer le problème dans un espace de dimension supérieure, éventuellement de dimension infinie
- Dans le nouvel espace: séparation linéaire probable
- On applique aux vecteurs d'entrée x une transformation non-linéaire ϕ
- L'espace d'arrivée $\phi(X)$ est appelé **espace de redescription**
- L'intérêt de la fonction noyau est double :
 - Le calcul se fait dans l'espace d'origine, ceci est beaucoup moins coûteux qu'un produit scalaire en grande dimension.
 - La transformation ϕ n'a pas besoin d'être connue explicitement, seule la fonction noyau intervient dans les calculs → on peut envisager des transformations complexes, et même des espaces de redescription de dimension infinie

SVM – Le cas non linéaire: les noyaux

- Fonctions noyau:
 - Gaussien: $k(x, x') = e^{-\gamma \|x - x'\|^2}$
 - Sigmoidale: $k(x, x') = \tanh(\gamma x^T x')$
 - Polynomial: $k(x, x') = (\gamma x^T x')^d$
- d représente le degré polynomial
- γ représente un paramètre d'ajustement

SVM multi-class

- SVM peuvent être adaptés pour traiter les problèmes multi-classe
- Idée: transformer le problème à « k » classes en « n » classifieurs binaires
- Le classement est donné par le classifieur qui répond le mieux
- !!! Beaucoup d'exemples négatifs !!!
- Stratégies:
 - 1 contre 1: chaque classe est comparée à chaque classe; classement donné par le vote majoritaire ou un graphe acyclique de décision
 - 1 contre toutes: la classe en cause est étiquetée 1, toutes les autres sont étiquetées -1; le classifieur avec la plus élevée valeur de confiance est élu

SVM – Exemples d'applications

- Classification de données biologiques/physiques
- Classification de documents numériques
- Classification d'expressions faciales
- Classification de textures
- E-learning
- Détection d'intrusion
- Reconnaissance de la parole
- CBIR : Content Based Image Retrieval

Données

Jeux de données pour apprentissage

Données: Individus et Caractéristiques

- ▶ Exemple de jeu de données
- ▶ Lignes = individus (observations)
- ▶ Colonnes = caractéristiques
 - ▶ Caractéristiques qualitatives
 - ▶ Caractéristiques quantitatives
- ▶ Une colonne avec la classe correspondante

Données: Echantillons Apprentissage/Test

- Contexte de l'apprentissage supervisé
- Découpage du jeu de données: apprentissage/test
 - Validation croisée (10-fold cross-validation)
 - Méthode d'exclusion (« leave-one-out »)



22

Application 1

Diagnostic cytologique (exemple R)

Diagnostic cytologique (exemple R)

- Les données issues d'une base dévolue à la comparaison des techniques de modélisation et d'apprentissage:
 - <http://archive.ics.uci.edu/ml/>
- Données concernant le cancer du sein: nature maligne ou bénigne de la tumeur à partir des variables biologiques
- Préparation données
- Extraction des échantillons
- SVM: options par défaut
- Options par cross-validation
- Noyaux
 - Défaut: gaussien
 - Polynomial
 - Sigmoidal
- Echantillon de test

Application 2

[Chifu & Mothe, 2014]: Expansion sélective de requêtes par apprentissage