

Méthodes à noyaux

et

SVMs (Séparateurs à Vastes Marges)

Antoine Cornuéjols

Équipe TAO (INRIA/CNRS) - Université de Paris-Sud, Orsay

& ENSIIE (Evry)

antoine@lri.fr

<http://www.lri.fr/~antoine>



Plan

1- Induction

2- Méthodes à noyaux

2.1- Exemple de la régression

2.2- Fonctions noyau

3- Exemple d'algorithme à noyau : les SVMs

4- Mise en œuvre

5- Bilan



Apprentissage inductif *supervisé*

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

À partir de l'*échantillon d'apprentissage* $S = \{(x_i, u_i)\}_{1,m}$

on cherche à identifier une loi de dépendance sous-jacente

- Par exemple une fonction h aussi proche possible de f (fonction cible) tq : $u_i = f(x_i)$
- Ou bien de la distribution de probabilités $P(x_i, u_i)$

afin de prédire l'avenir



Apprentissage inductif *supervisé*

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

$$P(\mathbf{x}, u)$$
$$u_i = f(\mathbf{x}_i)$$

$$\mathcal{S}_m = \{(\mathbf{x}_i, u_i)\}_{1 \leq i \leq m}$$

↑
Échantillon
d'apprentissage

$$u = h(\mathbf{x})$$

- **Identification** : h « proche de » f
- **Prédiction** : h « bonne règle de décision »



L'induction supervisée

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

○ f : *fonction continue*

➔ **Régression**

➔ **Estimation de densité**

○ f : *fonction discrète*

➔ **Classification**

○ f : *fonction binaire* (booléenne)

➔ **Apprentissage de concept**



Cadre

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

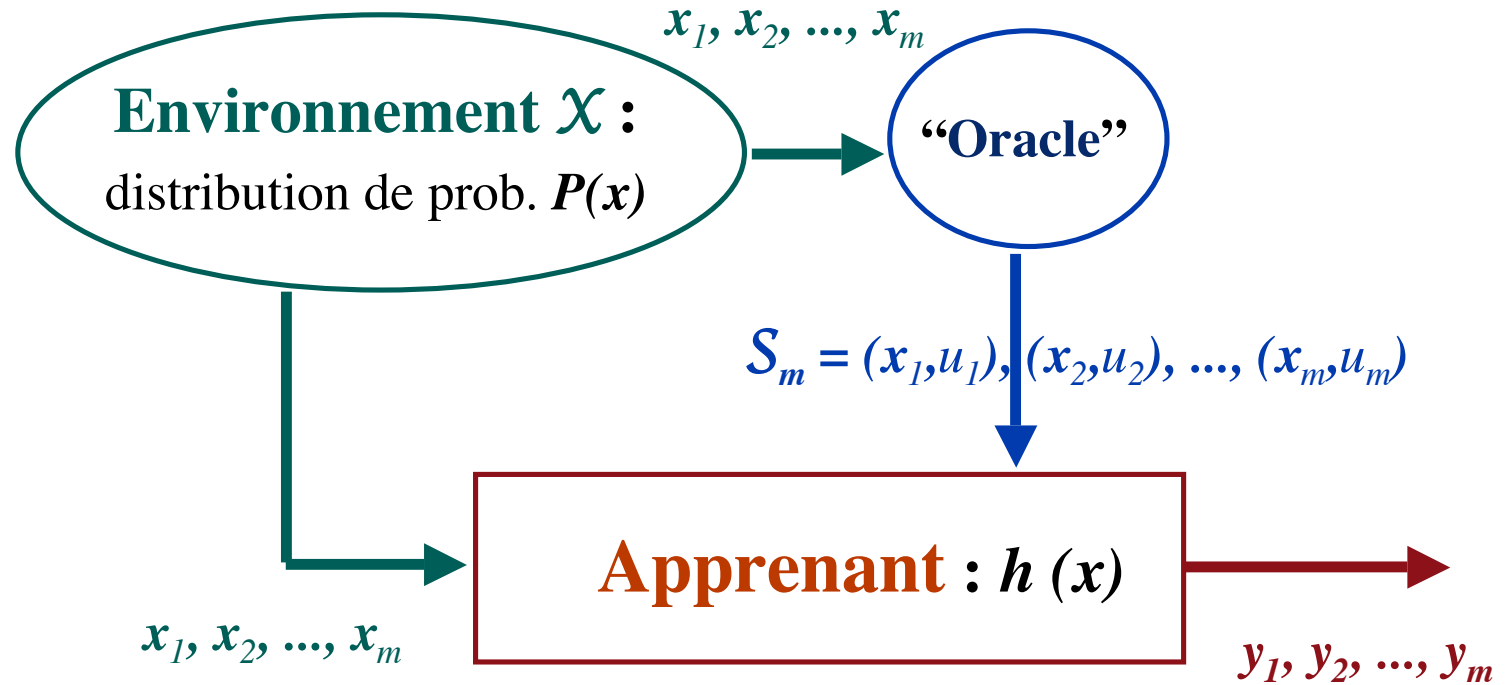
Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan



○ Hypothèses fondamentales

- Données i.i.d.
- Distribution $P_{\mathcal{X} \times \mathcal{U}}$ identique en apprentissage et après



Mesure de performance : le *risque réel*

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

Objectif : trouver une hypothèse $h \in \mathcal{H}$ minimisant *le risque réel*
(*espérance de risque, erreur en généralisation*)

$$R(h) = \int_{\mathcal{X} \times \mathcal{Y}} l(\underbrace{h(\mathbf{x})}_{\text{Étiquette prédite}}, \underbrace{u}_{\text{Étiquette vraie (ou désirée)}}) \underbrace{dP(\mathbf{x}, y)}_{\text{Loi de probabilité jointe sur } \mathcal{X} \times \mathcal{Y}}$$

Fonction de perte

*Étiquette
prédite*

*Étiquette vraie
(ou désirée)*

*Loi de probabilité
jointe sur $\mathcal{X} \times \mathcal{Y}$*



Le principe inductif ERM

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre


- Validation
- Construction de noyaux

Bilan

$$R(h) = \int_{X \times Y} l(h(x), u) dP(x, y)$$

- On ne connaît pas la loi de probabilité $P_{\mathcal{X} \times \mathcal{Y}}$.
- Le **principe ERM** (*minimisation du risque empirique*) prescrit de chercher l'hypothèse $h \in \mathcal{H}$ minimisant **le risque empirique**

$$R_{\text{Emp}}(h) = \frac{1}{m} \sum_{i=1}^m l(h(\mathbf{x}_i), u_i)$$



ERM régularisé

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- Pour éviter le surapprentissage (« overfitting »)

$$\hat{h} = \underset{h \in \mathcal{H}}{\text{ArgMin}} \left[R_{\text{Emp}}(h) + \lambda \Gamma(h) \right]$$

$$\hat{h} = \underset{h \in \mathcal{H}}{\text{ArgMin}} \left[R_{\text{Emp}}(h) + \lambda \Gamma(\mathcal{H}) \right]$$



Interpolation : par plus proches voisins

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax


Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan



+/- ?

- Méthodes par *plus proches voisins*
- Nécessité d'une *notion de distance*

Espace des exemples : \mathcal{X}

⇒ Hypothèse de continuité dans \mathcal{X}



Interpolation : par fonction de décision

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

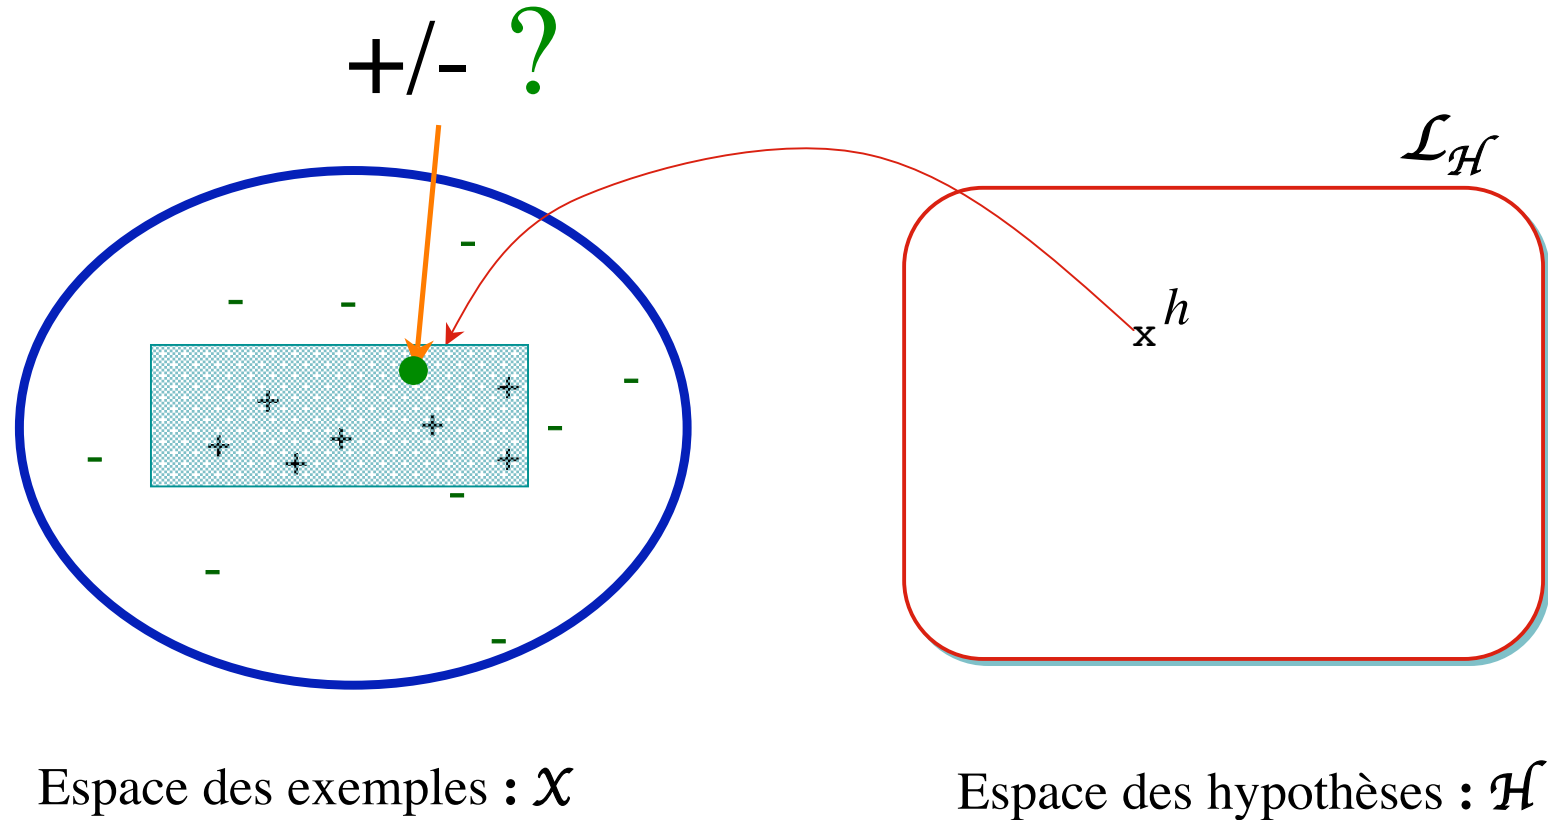
Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan





Le compromis biais-variance

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

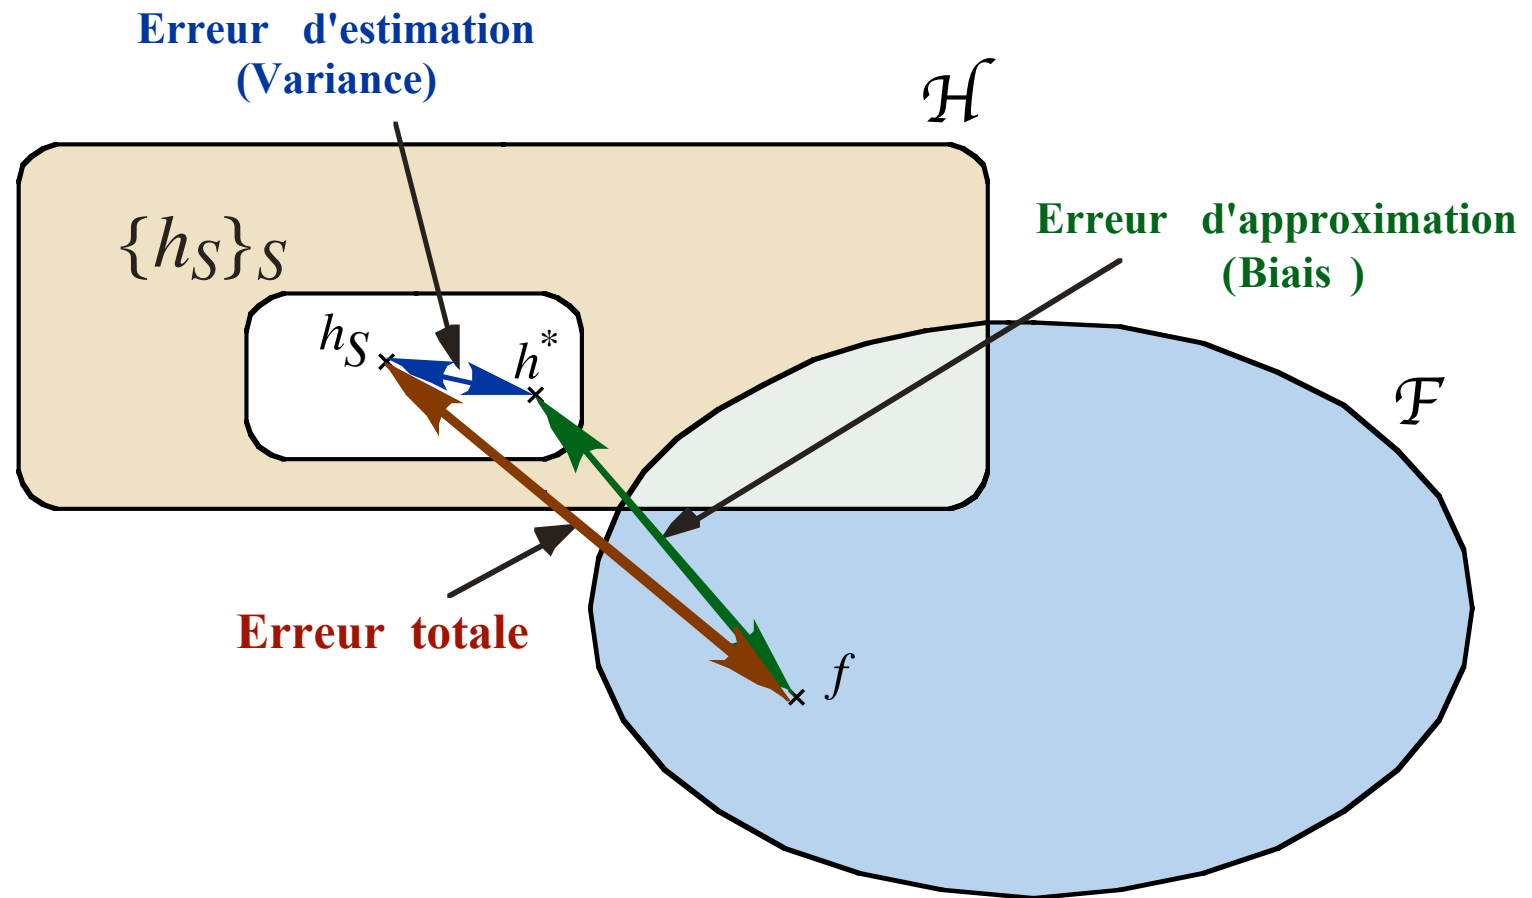
Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan





Conditions pour l'induction

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Conditions de généralisation**
 - Si espace d'hypothèses : Choix de \mathcal{H}
 - Contrôler la capacité de \mathcal{H}
 - Si directement dans \mathcal{X} (**plus proches voisins**)
 - Choix de la distance
 - Choix des poids sur les voisins
- **Efficacité en gain d'information** (e.g. taille d'échantillon)
- Efficacité computationnelle

Exemple : régression linéaire

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax


Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan



$$R_{\text{Emp}}(h) = R_{\text{Emp}}(\mathbf{w}) = \frac{1}{m} \sum_{i=1}^m l(h(\mathbf{x}_i), u_i) = \frac{1}{m} \sum_{i=1}^m (y_i - h(\mathbf{x}_i))^2 = \frac{1}{m} \sum_{i=1}^m \xi_i^2$$

Approximation par moindres carrés

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construc
noyaux

Bilan

$$R_{\text{Emp}}(\mathbf{w}) = \|\xi\|_2^2 = (\mathbf{y} - \mathbf{X}\mathbf{w})^\top (\mathbf{y} - \mathbf{X}\mathbf{w})$$

$$\frac{\partial R_{\text{Emp}}(\mathbf{w})}{\partial \mathbf{w}} = -2\mathbf{X}^\top \mathbf{y} + 2\mathbf{X}^\top \mathbf{X}\mathbf{w}$$

$$\mathbf{X}^\top \mathbf{X}\mathbf{w} = \mathbf{X}^\top \mathbf{y}$$

$$\mathbf{w} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}$$

$$\mathbf{w} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y} = (\mathbf{X}^\top \mathbf{X})(\mathbf{X}^\top \mathbf{X})^{-2} \mathbf{X}^\top \mathbf{y} = \sum_{i=1}^m \alpha_i \mathbf{x}_i$$

$$h(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle = \sum_{i=1}^m \alpha_i \langle \mathbf{x}_i, \mathbf{x} \rangle$$

Représentation
duale

Ridge regression

Induction

Méthodes à noyaux

- Régression

- Fonctions noyax

Les SVMs

- Principe

- Problème associé

- Illustration

Mise en œuvre

- Validation

- Construction de noyaux

Bilan

- Si $\mathbf{X}^\top \mathbf{X}$ n'est pas inversible
 - Pas assez de données
 - Bruit

- **Problème mal-posé**



Régularisation

$$\hat{\mathbf{w}} = \underset{\mathbf{w} \in \mathcal{W}}{\text{ArgMin}} \left[\frac{1}{m} \sum_{i=1}^m (y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle)^2 + \lambda \|\mathbf{w}\|^2 \right]$$

$\lambda \geq 0$ (Coefficient de régularisation)

Solution pour la « ridge regression »

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de

noyaux

Bilan

(Duale)

$$\hat{\mathbf{w}} = \underset{\mathbf{w} \in \mathcal{W}}{\text{ArgMin}} \left[\frac{1}{m} \sum_{i=1}^m (y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle)^2 + \lambda \|\mathbf{w}\|^2 \right]$$

$$\frac{\partial R_{\text{Emp}}(\mathbf{w})}{\partial \mathbf{w}} = \frac{1}{m} [-2\mathbf{X}^\top \mathbf{y} + 2\mathbf{X}^\top \mathbf{X} \mathbf{w}] + 2\lambda \mathbf{w} \quad \lambda \leftarrow m \cdot \lambda$$

$$\mathbf{X}^\top \mathbf{X} \mathbf{w} + \lambda \mathbf{w} = (\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{I}_d) \mathbf{w} = \mathbf{X}^\top \mathbf{y}$$

$$\mathbf{w} = (\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{I}_d)^{-1} \mathbf{X}^\top \mathbf{y} \quad \text{(Primale)}$$

Système de d équations linéaires à d inconnues : $O(d^3)$

$$\mathbf{w} = \lambda^{-1} \mathbf{X}^\top (\mathbf{y} - \mathbf{X} \mathbf{w}) = \mathbf{X}^\top \boldsymbol{\alpha}$$

$$\boldsymbol{\alpha} = \lambda^{-1} (\mathbf{y} - \mathbf{X} \mathbf{w}) = \lambda^{-1} (\mathbf{y} - \mathbf{X} \mathbf{X}^\top \boldsymbol{\alpha}) = (\mathbf{X} \mathbf{X}^\top + \lambda \mathbf{I}_m)^{-1} \mathbf{y}$$

$$h(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle = \left\langle \sum_{i=1}^m \alpha_i \mathbf{x}_i, \mathbf{x} \right\rangle = \sum_{i=1}^m \alpha_i \langle \mathbf{x}_i, \mathbf{x} \rangle = \mathbf{y}^\top (\mathbf{G} + \lambda \mathbf{I}_m)^{-1} \langle \mathbf{x}_i, \mathbf{x} \rangle$$



Formule duale

Induction

Méthodes à noyaux

• Régression

• Fonctions noyax

Les SVMs

• Principe

• Problème associé

• Illustration

Mise en œuvre

• Validation

• Construction de
noyaux

Bilan

$$h(\mathbf{x}) = \sum_{i=1}^m \alpha_i \langle \mathbf{x}_i, \mathbf{x} \rangle = \mathbf{y}^\top (\mathbf{G} + \lambda \mathbf{I}_m)^{-1} \langle \mathbf{x}_i, \mathbf{x} \rangle$$

*Provient directement
des données*

- L'information sur les exemples est **entièrement contenue dans les produits scalaires** (matrice de Gram \mathbf{G} et les $\langle \mathbf{x}_i, \mathbf{x} \rangle$)
- L'équation en α requiert $O(m)$ opérations
- Le calcul de $h(\mathbf{x})$ requiert $O(m l)$ opérations



Régression *non linéaire*

- Idée : re-décrire les données dans un espace dans lequel la relation cherchée puisse avoir la forme d'une droite

Induction

Méthodes à noyaux

- Régression

- Fonctions noyaux

Les SVMs


- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

$$\phi : \mathbf{x} \in \mathbb{R}^d \mapsto \phi(\mathbf{x}) \in F \subseteq \mathbb{R}^N$$





Régression non linéaire

Induction

Méthodes à noyaux

- Régression

- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- Idée : re-décrire les données dans un espace dans lequel la relation cherchée puisse avoir la forme d'une droite

$$\phi : \mathbf{x} \in \mathbb{R}^d \mapsto \phi(\mathbf{x}) \in F \subseteq \mathbb{R}^N$$

- Expression **primale** :

$$\mathbf{w} = (\phi(\mathbf{X})^\top \phi(\mathbf{X}) + \lambda \mathbf{I}_N)^{-1} \phi(\mathbf{X})^\top \mathbf{y} \quad O(N^3)$$

$$y = h(\mathbf{x}) = \langle \mathbf{w}, \phi(\mathbf{x}) \rangle \quad O(N)$$

- Expression **duale** :

$$O(m^3 + m^2 N)$$

$$h(\mathbf{x}) = \sum_{i=1}^m \alpha_i \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle = \mathbf{y}^\top (\mathbf{G} + \lambda \mathbf{I}_m)^{-1} \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle$$

$$O(mN)$$

$$G_{ij} = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle$$



Les fonctions noyau (kernel functions)

Induction

Méthodes à noyaux

- Régression

- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan


- Fonction k telle que :

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

$$\forall \mathbf{x}, \mathbf{z} \in \mathcal{X} : k(\mathbf{x}, \mathbf{z}) = \langle \phi(\mathbf{x}), \phi(\mathbf{z}) \rangle$$

où : $\phi : \mathbf{x} \mapsto \phi(\mathbf{x}) \in F$

Espace de redescription
muni d'un produit interne





Les fonctions noyau : exemple

Soit : $\mathcal{X} \subseteq \mathbb{R}^2$

Induction

Méthodes à noyaux

• Régression

• Fonctions noyaux

Les SVMs

• Principe

• Problème associé

• Illustration

Mise en œuvre

• Validation

• Construction de
noyaux

Bilan

$$\phi : \mathbf{x} = (x_1, x_2) \mapsto \phi(\mathbf{x}) = (x_1^2, x_2^2, \sqrt{2} x_1 x_2) \in F = \mathbb{R}^3$$

$$h(\mathbf{x}) = w_{11} x_1^2 + w_{22} x_2^2 + w_{12} \sqrt{2} x_1 x_2$$

$$\begin{aligned} \langle \phi(\mathbf{x}), \phi(\mathbf{z}) \rangle &= \langle (x_1^2, x_2^2, \sqrt{2} x_1 x_2), (z_1^2, z_2^2, \sqrt{2} z_1 z_2) \rangle \\ &= x_1^2 z_1^2 + x_2^2 z_2^2 + 2x_1 x_2 z_1 z_2 \\ &= (x_1 z_1 + x_2 z_2)^2 = \langle \mathbf{x}, \mathbf{z} \rangle^2 \end{aligned}$$

$$k(\mathbf{x}, \mathbf{z}) = \langle \mathbf{x}, \mathbf{z} \rangle^2$$

- Rq (non unicité de l'espace F défini par Φ) :

$$\phi : \mathbf{x} = (x_1, x_2) \mapsto \phi(\mathbf{x}) = (x_1^2, x_2^2, x_1 x_2, x_2 x_1) \in F = \mathbb{R}^4$$



Les fonctions noyau

Induction

Méthodes à noyaux

- Régression

- Fonctions noyax

Les SVMs

- Principe

- Problème associé

- Illustration

Mise en œuvre

- Validation

- Construction de noyaux

Bilan

○ Efficacité computationnelle :

$$O(m^3 + m^2 d)$$

$$h(\mathbf{x}) = \sum_{i=1}^m \alpha_i \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle = \mathbf{y}^\top (\mathbf{G} + \lambda \mathbf{I}_m)^{-1} \mathbf{k}(\mathbf{x}_i, \mathbf{x})$$

$$O(m d)$$

$$G_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$$



Les méthodes à noyau

- **Modularité**
 - Découplage entre
 - Les **algorithmes** (linéaires)
 - La **description des données**

Induction

Méthodes à noyaux

• Régression

• Fonctions noyax

Les SVMs

• Principe

• Problème associé

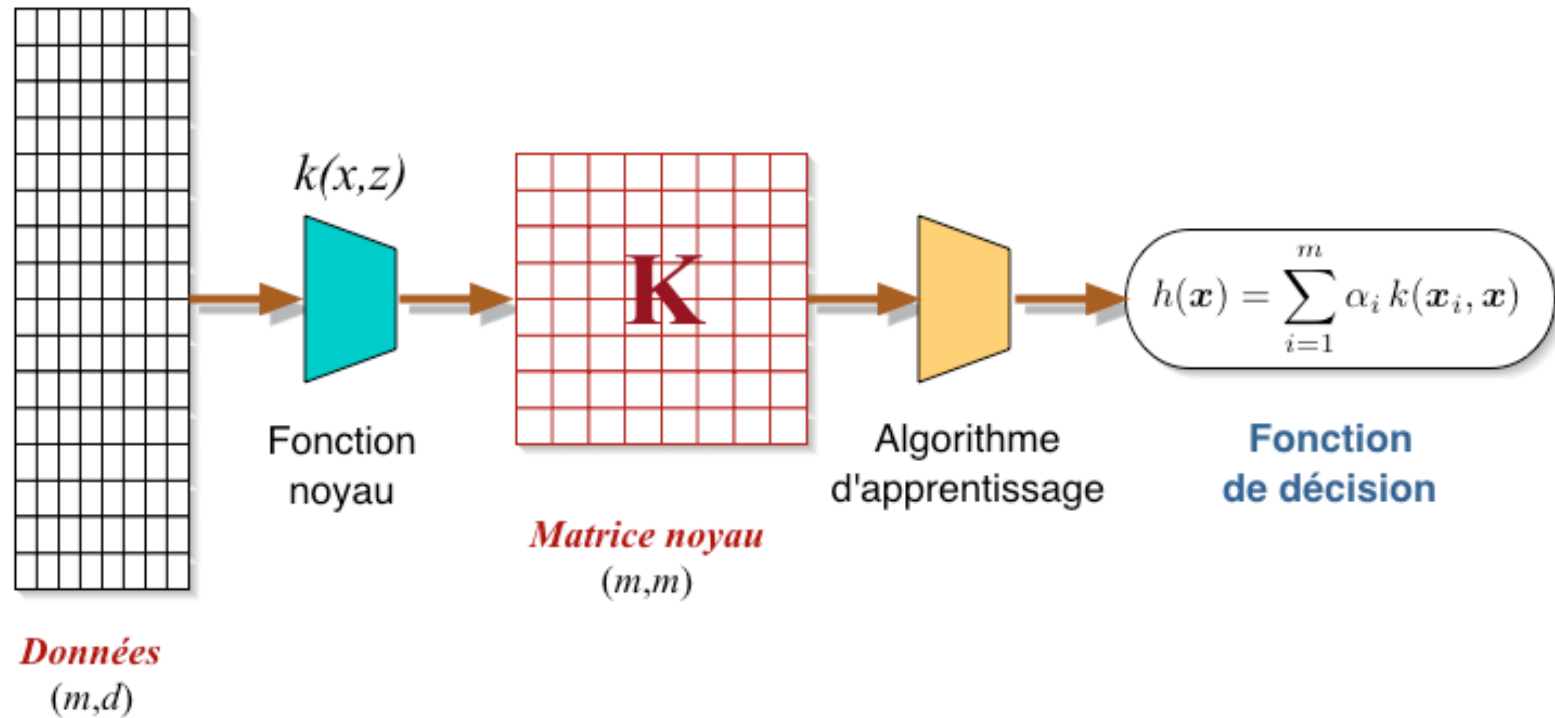
• Illustration

Mise en œuvre

• Validation

• Construction de noyaux

Bilan





Leçons (provisoires)

Induction

Méthodes à noyaux

- Régression

- Fonctions noyax

Les SVMs

- Principe

- Problème associé

- Illustration

Mise en œuvre

- Validation

- Construction de noyaux

Bilan

L'emploi de fonctions noyau permet :

- D'utiliser les algorithmes de recherche de régularités linéaires pour la *recherche de régularités non linéaires*
- D'employer ces algorithmes même sur des *données non vectorielles* (du moment que l'on sait trouver une fonction noyau adéquate)
- De redécrire implicitement les données dans des *espaces de grande dimension* sans en avoir le coût computationnel



Les méthodes à noyaux

Tout passe par les produits internes dans F !!!

Induction

Méthodes à noyaux

• Régression

• Fonctions noyax

Les SVMs

• Principe

• Problème associé

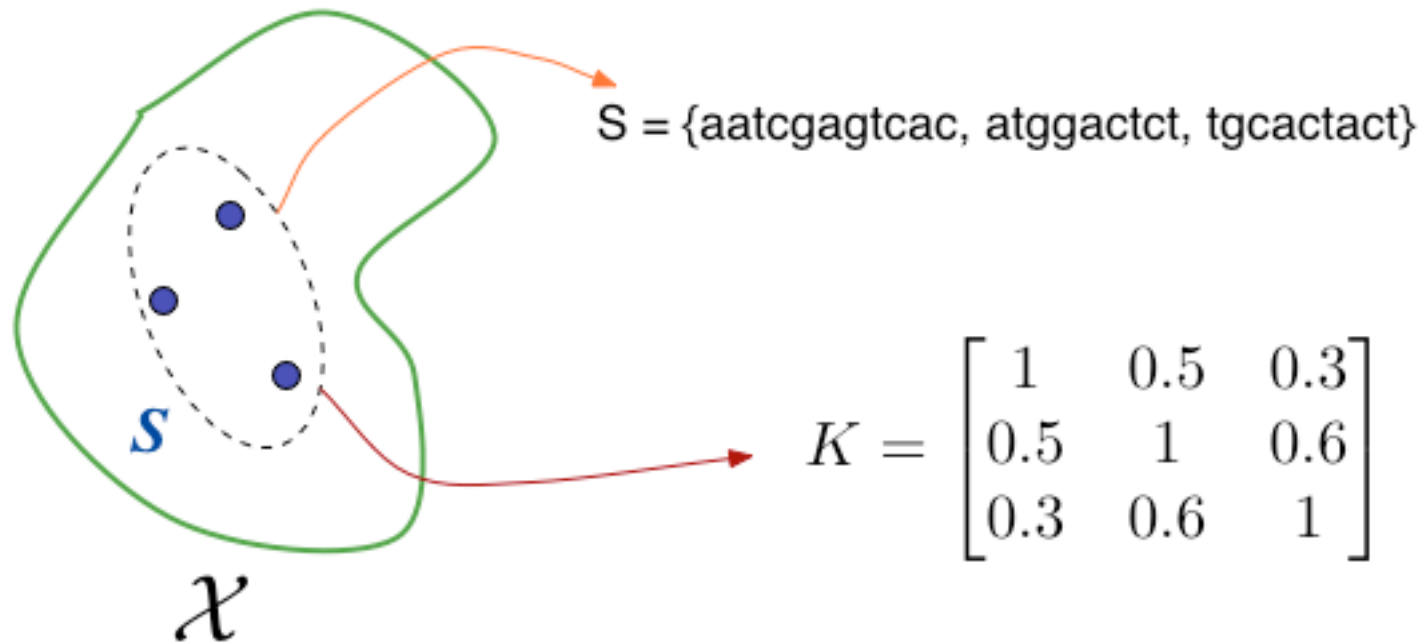
• Illustration

Mise en œuvre

• Validation

• Construction de
noyaux

Bilan



*Philosophie de représentation des données
radicalement différente*



Conséquences d'une représentation par noyau

Induction

Méthodes à noyaux

- Régression

- Fonctions noyax

Les SVMs


- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Des informations sont perdues**
 - ***Orientation*** (invariance de la matrice K par rotation)
 - ***Alignement*** des données avec les axes (idem)



Les fonctions noyau : définition

Induction

Méthodes à noyaux

- Régression

- Fonctions noyax

Les SVMs

- Principe

- Problème associé

- Illustration

Mise en œuvre

- Validation

- Construction de noyaux

Bilan

- **Fonction noyau** \longleftrightarrow **positive définie**

- Symétrique : $k(\mathbf{x}, \mathbf{z}) = k(\mathbf{z}, \mathbf{x})$

- Positive définie :

$$\forall n > 0, \forall \mathbf{x}_1, \dots, \mathbf{x}_n \in \mathcal{X}, \forall c_1, \dots, c_n \in \mathbb{R} : \sum_{i=1}^n \sum_{j=1}^n c_i c_j k(\mathbf{x}_i, \mathbf{x}_j) \geq 0$$

- **Théorème de Mercer**

- *Toute fonction positive définie peut être exprimée comme un produit interne dans un espace de description*



Fonctions noyau et similarité

○ $k(\mathbf{x}, \mathbf{z})$ grand $\Leftrightarrow \mathbf{x}$ *similaire* à \mathbf{z}

Induction

Méthodes à noyaux

• Régression

• Fonctions noyaux

Les SVMs

• Principe

• Problème associé

• Illustration

Mise en œuvre

• Validation

• Construction de noyaux

Bilan

- Évident pour le noyau gaussien : $k(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{d(\mathbf{x}, \mathbf{z})^2}{2\sigma^2}\right)$
- Plus généralement :

$$k(\mathbf{x}, \mathbf{z}) = \frac{\|\phi(\mathbf{x})\|^2 + \|\phi(\mathbf{z})\|^2 - d(\phi(\mathbf{x}), \phi(\mathbf{z}))^2}{2}$$

Si tous les points sont de même « longueur » dans F ,

($\|\phi(\mathbf{x})\|^2 = k(\mathbf{x}, \mathbf{x}) = \text{Const.}, \forall \mathbf{x} \in \mathcal{X}$),

alors le noyau est une fonction décroissante de d .

$$\text{Inversement : } d(\mathbf{x}, \mathbf{z}) = \sqrt{k(\mathbf{x}, \mathbf{x}) - 2k(\mathbf{x}, \mathbf{z}) + k(\mathbf{z}, \mathbf{z})}$$



Fonctions noyau pour des vecteurs

Induction

Méthodes à noyaux

• Régression

• Fonctions noyax

Les SVMs

• Principe

• Problème associé

• Illustration

Mise en œuvre

• Validation

• Construction de
noyaux

Bilan

○ Noyaux polynomiaux

$$k_{\text{poly}1}(\mathbf{x}, \mathbf{z}) = (\mathbf{x}^\top \mathbf{z})^d$$

*Tous les produits d'**exactement**
d variables*

$$k_{\text{poly}2}(\mathbf{x}, \mathbf{z}) = (\mathbf{x}^\top \mathbf{z} + c)^d$$

*Tous les produits d'**au plus**
d variables*

○ Noyaux gaussiens

$$k_G(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{d(\mathbf{x}, \mathbf{z})^2}{2\sigma^2}\right)$$

*Sorte de décomposition
en série de Fourier*

○ Noyaux sigmoïdes

$$k(\mathbf{x}, \mathbf{z}) = \tanh(\kappa \mathbf{x}^\top \mathbf{z} + \theta)$$

*Pas définie positive.
Mais fonction de décision
proche des réseaux connexionnistes*



Les SVMs (Séparateurs à Vastes Marges)

Induction

Méthodes à noyaux

• Régression

• Fonctions noyax

Les SVMs

• Principe

• Problème associé

• Illustration

Mise en œuvre

• Validation

• Construction de noyaux

Bilan

○ Tâche de discrimination (entre deux classes)

□ Cas de la séparation linéaire

- On cherche h sous forme d'une fonction linéaire : $h(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b$

- La *surface de séparation* est donc l'hyperplan :

$$\mathbf{w} \cdot \mathbf{x} + b = 0$$

- Elle est valide si $\forall i \quad u_i h(\mathbf{x}_i) \geq 0$

- L'hyperplan est dit sous forme canonique lorsque $\min_i |\mathbf{w} \cdot \mathbf{x}_i + b| = 1$

ou encore

$$\forall i \quad u_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1$$



Hyperplan de plus vaste marge

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax


Les SVMs


- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan





Optimisation de la marge

Induction

Méthodes à noyaux

- Régression

- Fonctions noyax

Les SVMs

- Principe

- Problème associé


- Illustration

Mise en œuvre

- Validation

- Construction de noyaux

Bilan





Optimisation de la marge

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- La distance d'un point à l'hyperplan est :

$$d(\mathbf{x}) = \frac{|\mathbf{w} \cdot \mathbf{x} + w_0|}{\|\mathbf{w}\|}$$

- L'hyperplan optimal est celui pour lequel la distance aux points les plus proches (*marge*) est maximale. Cette distance vaut

$$\frac{2}{\|\mathbf{w}\|}$$

- Maximiser la marge revient donc à minimiser $\|\mathbf{w}\|$ sous contraintes:

$$\begin{cases} \min \frac{1}{2} \|\mathbf{w}\|^2 \\ \forall i \quad u_i (\mathbf{w} \cdot \mathbf{x}_i + w_0) \geq 1 \end{cases}$$

**EXPRESSION
PRIMALE**



Remarques sur la justification de ce critère inductif

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé

- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

○ Intuitivement satisfaisant

- Si il y a du bruit dans les données, le séparateur à marge maximale sera plus robuste

○ Risque empirique régularisé

- Satisfaire les données : $u_i \left[(\mathbf{w} \cdot \mathbf{x}_i) + w_0 \right] \geq 1, \quad i = 1, \dots, n$

- Régulariser : $\text{Min} \left(\eta(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \right)$



Transformation du problème d'optimisation

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

○ Méthode des multiplicateurs de Lagrange

$$\begin{cases} L(\mathbf{w}, w_0, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^m \alpha_i [(\mathbf{x}_i \cdot \mathbf{w} + w_0) u_i - 1] \\ \alpha_i \geq 0 \quad (\forall i) \end{cases}$$

**EXPRESSION
DUALE**

$$\begin{cases} \max_{\alpha} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j u_i u_j k(\mathbf{x}_i, \mathbf{x}_j) \\ \sum_{i,j=1}^m \alpha_i u_i = 0 \\ \alpha_i \geq 0 \quad (\forall i) \end{cases}$$



Justification impliquant la fonction noyau

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé

• Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- Norme du vecteur de poids

$$\begin{aligned} \|\mathbf{w}\|^2 &= \langle \mathbf{w}, \mathbf{w} \rangle = \left\langle \sum_{i=1}^m \alpha_i \phi(\mathbf{x}_i), \sum_{j=1}^m \alpha_j \phi(\mathbf{x}_j) \right\rangle \\ &= \sum_{i,j=1}^m \alpha_i \alpha_j \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle = \sum_{i,j=1}^m \alpha_i \alpha_j k(\mathbf{x}_i, \mathbf{x}_j) \\ &= \boldsymbol{\alpha}^\top \mathbf{K} \boldsymbol{\alpha} \end{aligned}$$


- Espace d'hypothèses de norme bornée

$$\|\mathbf{w}\|^2 = \boldsymbol{\alpha}^\top \mathbf{K} \boldsymbol{\alpha} \leq B^2$$

\mathcal{F}_B

- Fonction de perte (hinge loss)

$$(1 - y h(\mathbf{x}))_+$$



- Alors :

$$\hat{R}_m(\mathcal{F}_B) \leq \frac{2B}{m} \sqrt{\text{tr}(\mathbf{K})}$$

Complexité de Rademacher de \mathcal{F}_B

Avec $\text{prob} \geq 1 - \delta$

$$R_{\text{Réel}}(h) \leq R_{\text{Emp}}(h) + \hat{R}_m(\mathcal{F}_B) + \sqrt{\frac{\ln(2/\delta)}{2m}}$$



Morale

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Les données s'expriment à travers la matrice noyau**
- **La matrice noyau contrôle la régularisation du risque**



Solution du problème d'optimisation dual

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé

• Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- Dans la forme duale :

$$h(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^{m_S} \alpha_i u_i k(\mathbf{x}_i, \mathbf{x}) + w_0 \right)$$

m_S : nb de points
de support



Schéma de fonctionnement des SVMs

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

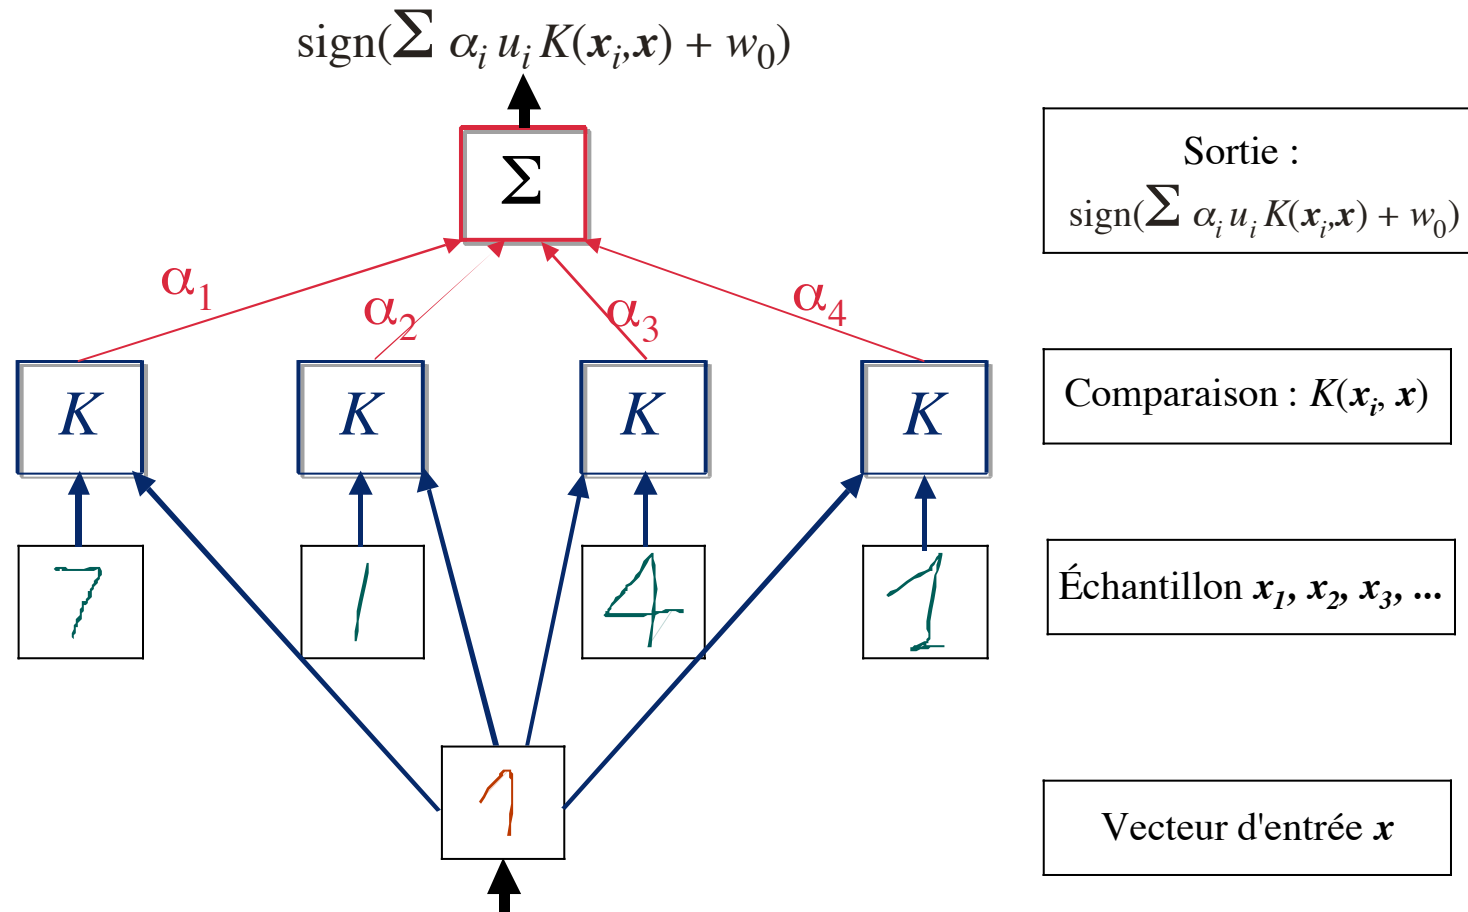
Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan





Cas du problème non séparable : *marges douces*

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé

- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- On introduit des variables “ressort” qui pénalisent l’erreur commise :

$$\begin{cases} \min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i \\ \forall i \quad u_i (\mathbf{w} \cdot \mathbf{x}_i + w_0) \geq 1 - \xi_i \end{cases}$$

- Le problème dual a la même forme à l’exception d’une constante C

$$\begin{cases} \max_{\alpha} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j u_i u_j k(\mathbf{x}_i, \mathbf{x}_j) \\ \sum_{i,j=1}^m \alpha_i u_i = 0 \\ 0 \leq \alpha_i \leq C \quad (\forall i) \end{cases}$$



Illustration

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- Soient 5 points sur la droite :
 $\{(x_1=1, u_1=1), (x_2=2, u_2=2), (x_3=4, u_3=-1), (x_4=5, u_4=-1), (x_5=6, u_5=1)\}$



- Utilisation d'un noyau polynomial de degré 2
 - $k(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^2$
 - $C = 100$

- Recherche de α_i par :

$$\begin{cases} \max_{\alpha} \sum_{i=1}^5 \alpha_i - \frac{1}{2} \sum_{i,j=1}^5 \alpha_i \alpha_j u_i u_j (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^2 \\ \sum_{i,j=1}^5 \alpha_i u_i = 0 \\ 0 \leq \alpha_i \leq 100 \quad (\forall i) \end{cases}$$



Illustration

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Utilisation d'un programme de résolution de problème quadratique**
 - $\alpha_1=0, \alpha_2=2.5, \alpha_3=0, \alpha_4=7.333, \alpha_5=4.833$
 - Les **points de supports** sont : $\{x_2=2, x_4=5, x_5=6\}$
- La **fonction de décision** est :
 - $$h(x) = (2.5)(1)(2x+1)^2 + 7.333(1)(5x+1)^2 + 4.833(1)(6x+1)^2 + b$$
$$= 0.6667 x^2 - 5.333 x + b$$
 - Avec b obtenue par $h(2)=1$ ou par $h(5)=-1$ ou par $h(6)=1$, puisque x_2, x_4 et x_5 sont sur la droite $u_i(w^T\Phi(x)+b)=1$ ce qui donne $b=9$

- **D'où :**

$$h(x) = 0.6667 x^2 - 5.333 x + 9$$



Illustration

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs


- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

Valeur de la fonction discriminante





La mise en pratique

- **Il faut choisir :**

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Le type de fonction noyau k**

- **Sa forme**

- **Ses paramètres**

- **La valeur de la constante C**

- La sélection de ces paramètres requiert l'utilisation de **méthodes empiriques pour faire le meilleur choix (validation croisée)**



Exemple

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

● : exemple +

● : exemple -

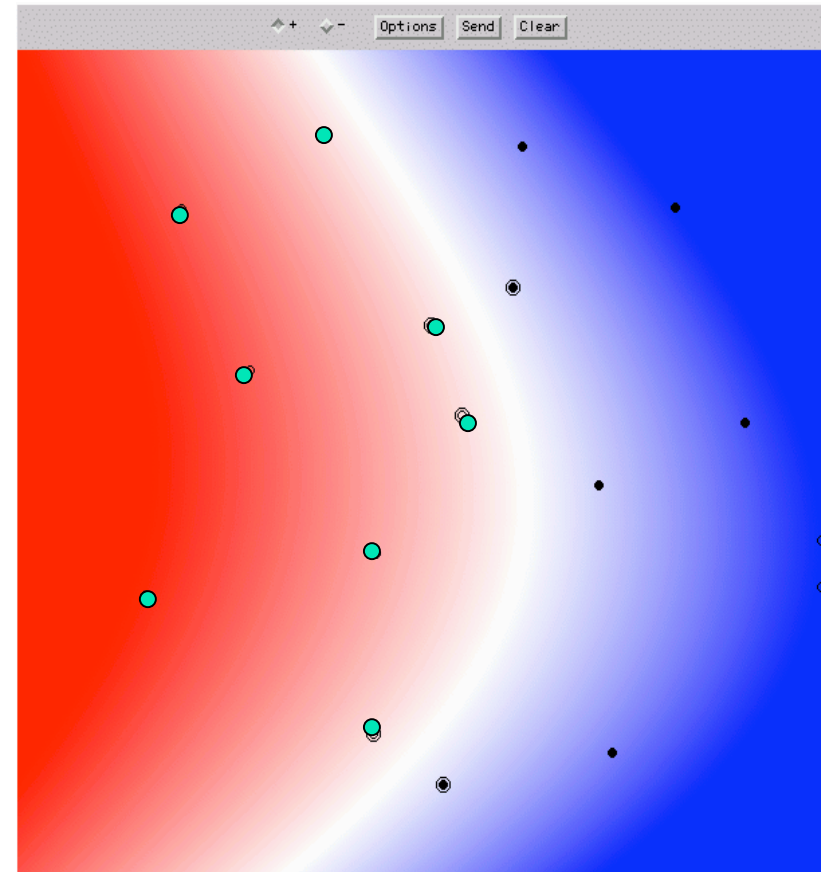
Dans cercle : points de support

Fct noyau polynomiale de degré 3

Démo :

<http://svm.research.bell-labs.com/>

<http://svm.dcs.rhbnc.ac.uk/pagesnew/GPat.shtml>



Les données d'apprentissage

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax


Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan



Effet des paramètres de contrôle

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre



- Validation
- Construction de noyaux

Bilan

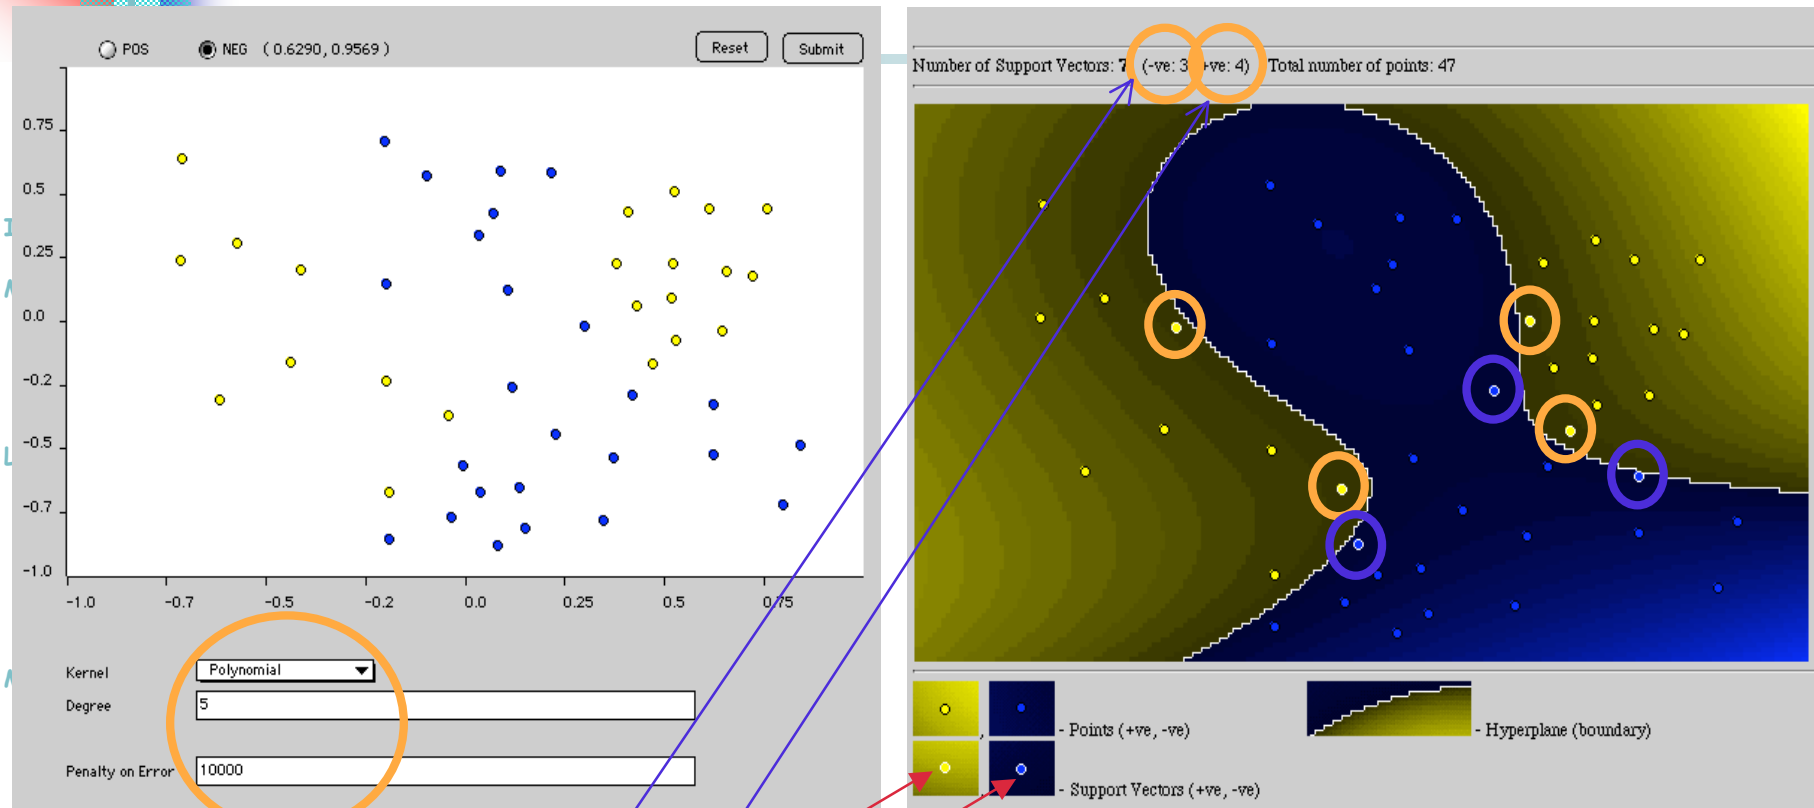
- Apprentissage de **deux classes**
 - exemples tirés uniformément sur l'échiquier
- SVM à **fonctions noyau gaussienne**

$$K(\mathbf{x}, \mathbf{x}') = e^{-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}}$$

- Ici deux valeurs de σ
 - **En haut** : petite valeur
 - **En bas** : grande valeur
- Les gros points sont des **exemples critiques**
 - **Plus en haut qu'en bas**
- Dans les deux cas : $R_{\text{emp}} = 0$



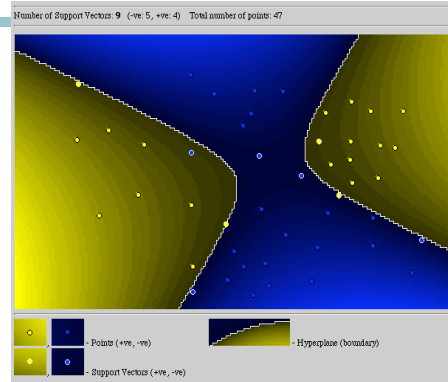

Paramètres de contrôle : les fonctions noyau



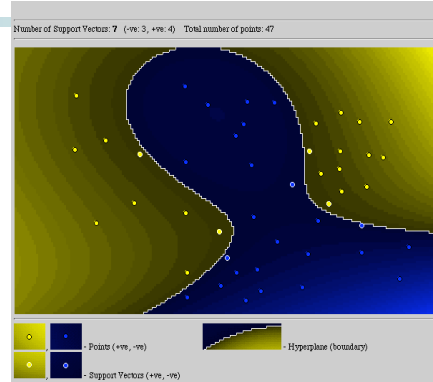
noyaux

- <http://svm.dcs.rhbnc.ac.uk/pagesnew/GPat.shtml>
- 47 exemples (22 +, 25 -)
- Exemples critiques : 4 + et 3 -
- Ici *fonction polynomiale* de degré 5 et $C = 10000$

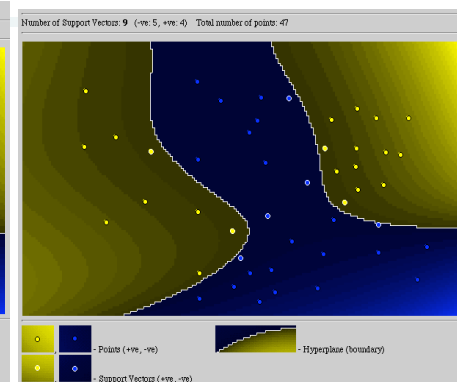
Paramètres de contrôle : les fonctions noyau



(5-, 4+)



(3-, 4+)




(5-, 4+)


- 47 exemples (22 +, 25 -)

Ici *fonction polynomiale* de degré 2, 5, 8 et $C = 10000$

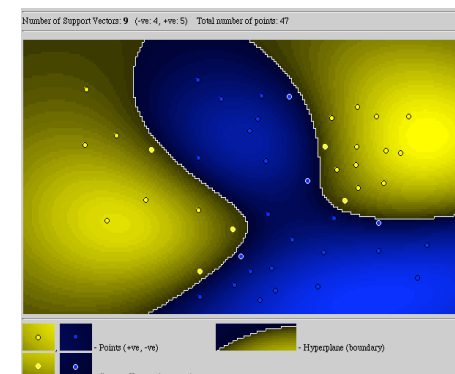
- *Exemples critiques* : 4 + et 3 -



(10-, 11+)



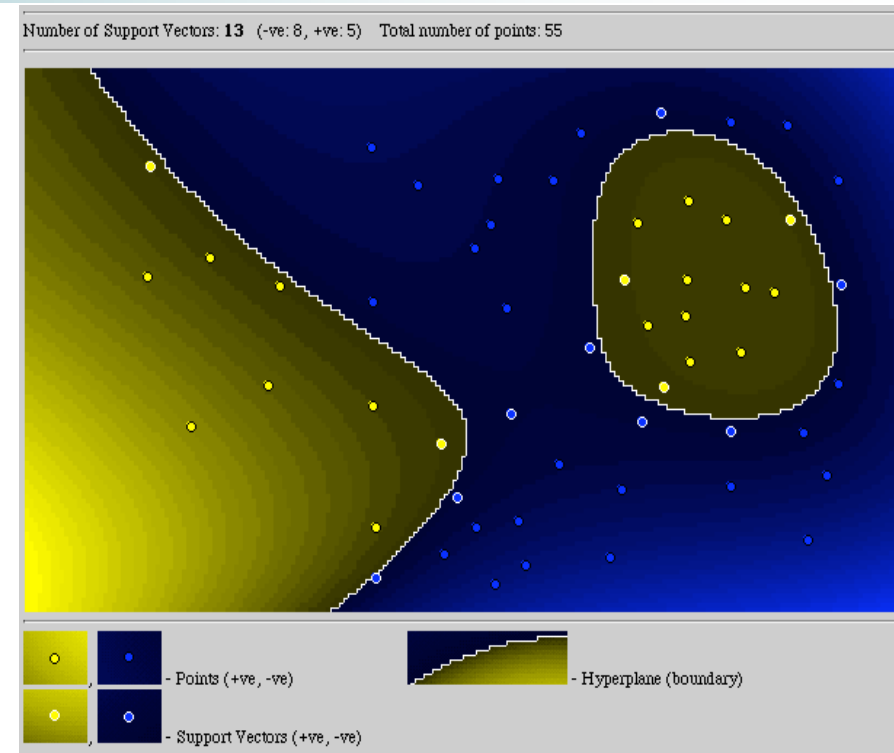

(8-, 6+)



(4-, 5+)

Ici *fonction Gaussienne* de $\sigma = 2, 5, 10$ et $C = 10000$

Ajout de quelques points ...



- <http://svm.dcs.rhnc.ac.uk/pagesnew/GPat.shtml>
- 47 + 8 exemples (30 +, 25 -)
- Exemples critiques : 5 + et 8 -
- Ici *fonction polynomiale* de *degré 5* et $C = 10000$



Estimation de la performance

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Empiriquement** : par **validation croisée**
- **Heuristiquement** (mais théoriquement fondé)
 - **Nombre de points de supports**
 - Moins il y en a, mieux c'est
 - **Caractéristiques de la matrice noyau**
 - Si pas de structure dans K , aucune régularité ne peut-être trouvée
 - E.g.
 - Si les termes hors diagonale sont très petits : sur-adaptation
 - Si matrice uniforme : sous-apprentissage : tous les points sont attribués à la même classe



Construction de fonctions noyau

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- Construction à partir de fonctions noyau de base
(Propriétés de clôture)
 - $K(\mathbf{x}, \mathbf{z}) = K_1(\mathbf{x}, \mathbf{z}) + K_2(\mathbf{x}, \mathbf{z})$
 - $K(\mathbf{x}, \mathbf{z}) = a K_1(\mathbf{x}, \mathbf{z})$
 - $K(\mathbf{x}, \mathbf{z}) = K_1(\mathbf{x}, \mathbf{z}) \cdot K_2(\mathbf{x}, \mathbf{z})$
 - ...
- Construction de fonctions noyau dédiées
 - **Splines B_m**
 - **Expansion de Fourier**
 - **Ondelettes**
 - ...



Construction de noyaux

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

○ Noyau invariant par translation


$$k(\mathbf{x}, \mathbf{z}) = k(\mathbf{x} - \mathbf{z})$$

○ Noyau défini sur des ensembles

$$k(A_1, A_2) = 2^{|A_1 \cap A_2|} \iff \phi(A)_U = \begin{cases} 1 & \text{si } U \subseteq A, \\ 0 & \text{sinon.} \end{cases}$$



Stratégies de construction



In	on
Mé	des à noyaux
	gression
	ctions noyax
Le	Ms
	ncipe
	blème associé
	ustration
Mi	n œuvre
	idation
	nstruction de
	aux
Bi	

- **Noyau vu comme un moyen de coder de l'information a priori**
 - Invariance: synonymie, longueur de document, ...
 - Traitements linguistiques: normalisation des mots, sémantique, stopwords, weighting scheme, ...
- **Noyaux de convolution :**

le texte est une structure de données récursivement définie.

Pb : *construire un noyau global à partir de noyaux locaux ?*
- **Noyaux à partir de modèles génératifs :**

la “topologie” du problème est traduite en une fonction noyau

Noyaux pour arbres : exemple

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs


- Principe
- Problème associé
- Illustration

Mise en œuvre


- Validation
- Construction de noyaux

Bilan


○ Exemple :




A Parse Tree



... quelques sous-arbres parmi ceux de l'arbre !





Illustration

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

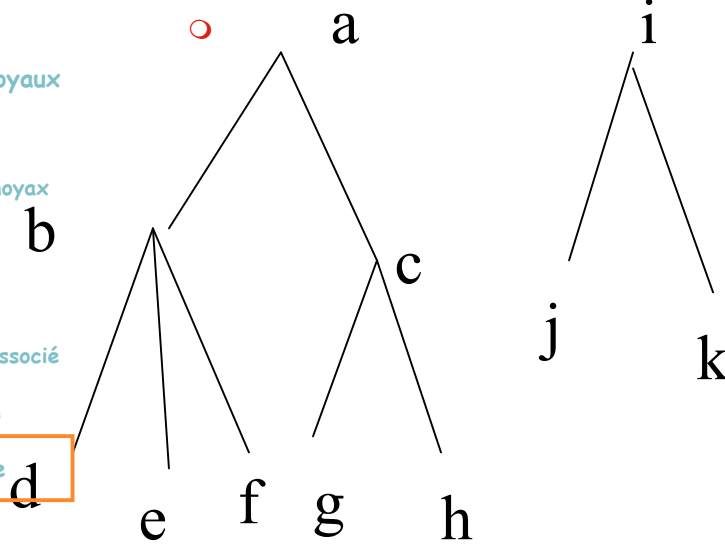
Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan



Kco-root	i	j	k
a	1	0	0
b	0	0	0
c	1	0	0
d	0	0	0
e	0	0	0
f	0	0	0
g	0	0	0
h	0	0	0

→ K=2



Applications

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs



- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- Catégorisation de textes
- Reconnaissance de caractères manuscrits
- Détection de visages
- Diagnostic de cancer du sein
- Classification de protéines
- Prévission de consommation électrique
- Recherche de vidéos par du texte



Trained SVM classifiers for pedestrian and face object detection (Papageorgiou, Oren, Osuna and Poggio, 1998)



Implémentation des SVMs

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Minimisation de fonctions différentiables convexes à plusieurs variables**
 - **Pas d'optima locaux**
 - **Mais :**
 - **Problèmes de stockage de la matrice noyau (si milliers d'exemples)**
 - **Long dans ce cas**
 - D'où mise au point de méthodes spécifiques
 - Gradient sophistiqué
 - Méthodes itératives, optimisation par morceaux
 - **Plusieurs packages publics disponibles**
 - SVMTorch
 - SVM^{Light}
 - SMO
 - ...



Bilan : état des recherches

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Deux tâches évidentes**
 - **Conception de noyaux**
 - Commence à être bien étudié
 - Encore des recherches pour certains types de données
 - **Noyautiser les algorithmes classiques** (« kernelization »)
 - SVM
 - Kernel Régression
 - Kernel PCA
 - Clustering (K-means, ...)
 - Estimation de densité, détection de nouveauté
 - Tri (**ranking**)
 - ...
- **Recherche sur la sélection automatique des modèles (choix des paramètres)**



Bilan

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Les méthodes à noyau sont :**
 - Une bonne idée
 - Destinées à durer
- Offrent une **boîte à outils**
 - Très versatile
 - Avec de bons fondements théoriques
 - E.g. garanties de performance



Bilan

Nouvelle philosophie de représentation

Induction

Méthodes à noyaux

- Régression
- Fonctions noyaux

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

- **Toute l'information** sur les données passe par le filtre de **la matrice noyau**
 - De l'information est perdue
 - Permet des manipulations particulières
 - E.g. ajout d'une constante sur la diagonale → marge souple ou terme de régularisation
 - Incorporation de connaissances a priori
 - Matrice noyau : interface entre les modules de traitement
- **La qualité de l'apprentissage** peut être estimée à partir des **caractéristiques de la matrice noyau**



Sources documentaires

Induction

Méthodes à noyaux

- Régression
- Fonctions noyax

Les SVMs

- Principe
- Problème associé
- Illustration

Mise en œuvre

- Validation
- Construction de noyaux

Bilan

○ Ouvrages / articles

- Cornuéjols & Miclet (02) : *Apprentissage artificiel. Concepts et algorithmes*. Eyrolles, 2002.
- Herbrich (02) : *Learning kernel classifiers*. MIT Press, 2002.
- Schölkopf, Burges & Smola (eds) (98) : *Advances in Kernel Methods : Support Vector Learning*. MIT Press, 1998.
- Schölkopf & Smola (02) : *Learning with kernels*. MIT Press, 2002.
- Shawe-Taylor & Cristianini(04) : *Kernel methods for pattern analysis*. Cambridge University Press, 2004.
- Smola, Bartlett, Schölkopf & Schuurmans (00) : *Advances in large margin classifiers*. MIT Press, 2000.
- Vapnik (95) : *The nature of statistical learning*. Springer-Verlag, 1995.

○ Sites web

- <http://www.kernel-machines.org/> (point d'entrée)
- <http://www.support-vector.net> (point d'entrée)