

Apprentissage, réseaux de neurones et
modèles graphiques (RCP209)
Algorithmes à noyaux. Applications.

Marin FERECATU & Michel Crucianu
(prenom.nom@cnam.fr)

<http://cedric.cnam.fr/vertigo/Cours/ml2/>

Département Informatique
Conservatoire National des Arts & Métiers, Paris, France

Plan du cours

2 Objectifs et contenu de l'enseignement

3 Estimation du support d'une densité

4 SVM pour la régression

5 Applications

Objectif

“La raison d'être des statistiques, c'est de vous donner raison.” — Abe Burrows

Algorithmes à noyaux :

- One class SVM (estimation du support d'une densité)
- SVM pour la regression
- Kernel PCA (KPCA)

Applications :

- Classes d'images
- Boucle de pertinence
- Détection des objets

Plan du cours

2 Objectifs et contenu de l'enseignement

3 Estimation du support d'une densité

4 SVM pour la régression

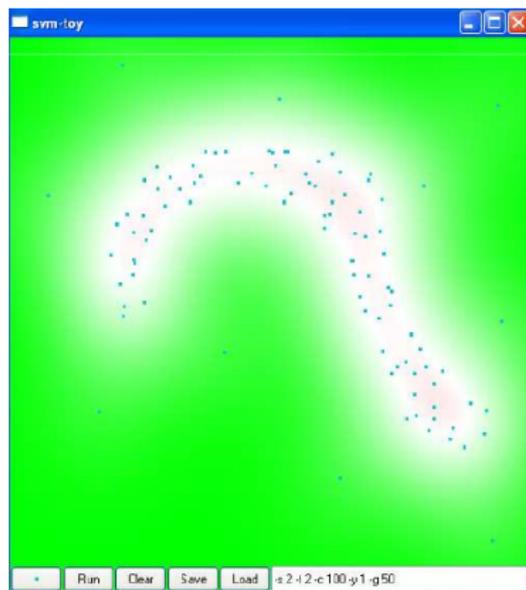
5 Applications

Estimation du support d'une densité

Estimation du support d'une densité :

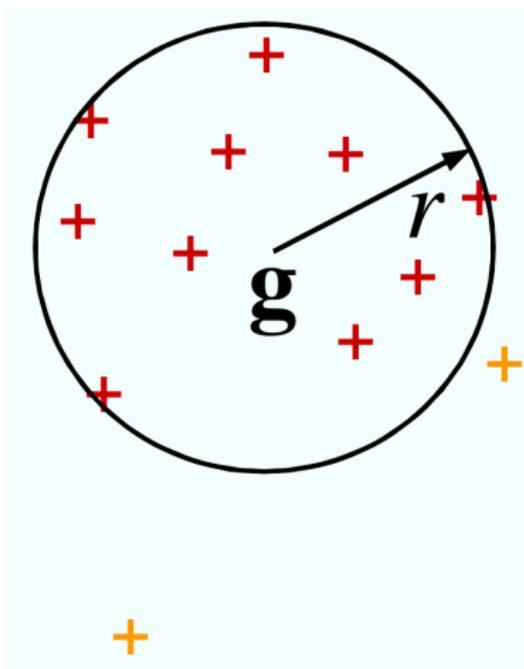
- Les données d'apprentissage $D = \{x_1, x_2, \dots, x_n \in \mathcal{X}\}$, issues de variables i.i.d. suivant la densité de probabilité $p(x)$ inconnue.
- Pas d'étiquettes de classe y_i
- Le problème consiste à décider si une nouvelle observation x est proche ou non de cet ensemble T , c.t.d. s'il est tiré de la même distribution.
- On cherche donc à estimer le support de cette densité ← moins de difficultés que pour l'estimation de la densité

Estimation du support d'une densité



Exemple avec noyau RBF : intensité de la couleur proportionnelle à l'éloignement de la frontière

Estimation du support d'une densité



Approche SVDD (Support Vector Data Description, Tax & Duin 2004) : trouver dans l'espace d'arrivée \mathcal{H} la plus petite hypersphère englobant les données

Support Vector Data Description (SVDD)

Support Vector Data Description (SVDD) :

$$\left\{ \begin{array}{l} \min_{R, g} R^2 + C \sum_{i=1}^n \xi_i \\ \text{avec :} \\ \|x_i - g\|^2 \leq R^2 + \xi_i, i = 1, \dots, n \\ \xi_i \geq 0, i = 1, \dots, n \end{array} \right.$$

- g le centre
- R le rayon
- $C = \frac{1}{\nu n}$ permet de régler la proportion ν de points que l'on désire maintenir en dehors de la boule (outliers).

Support Vector Data Description (SVDD)

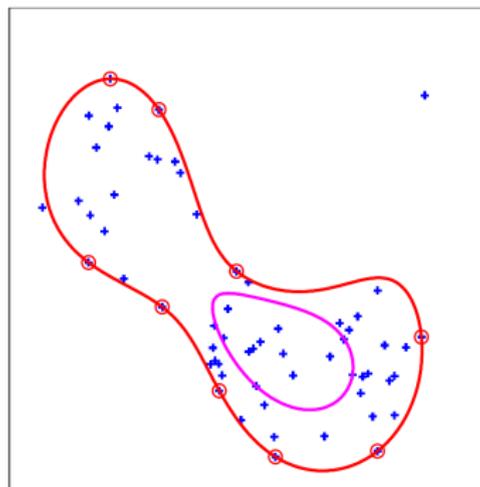
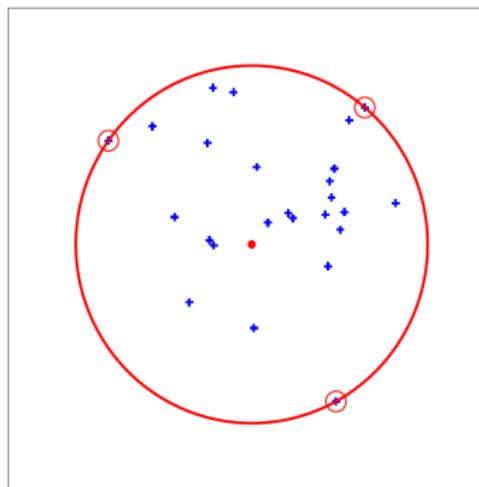
SVDD : Le problème dual

$$\left\{ \begin{array}{l} \min_{\alpha} \frac{1}{2} \alpha^T K \alpha - \frac{1}{2} \alpha^T \text{diag}(K) \\ \text{avec :} \\ \mathbf{e}^t \alpha = 1 \\ 0 \leq \alpha_i \leq C, i = 1, \dots, n \end{array} \right.$$

- K est la matrice de Gramm $K_{ij} = k(x_i, x_j)$
- $\mathbf{g} = \sum_{i=1}^n \alpha_i \phi(x_i)$
- Un nouveau point x appartient au support si $\|\phi(x) - \mathbf{g}\| \leq R^2$, ou :

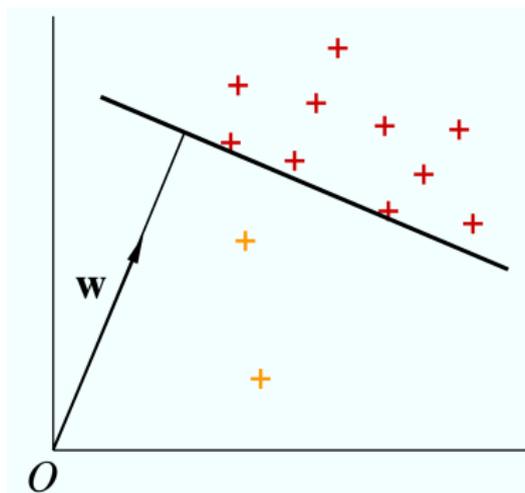
$$K(x, x) - 2 \sum_{i=1}^n \alpha_i K(x_i, x) + \sum_{i,j=1}^n \alpha_i \alpha_j K(x_i, x_j) \leq R^2$$

Support Vector Data Description (SVDD)



Exemple SVDD : linéaire (à gauche) et noyau gaussien (à droite). A droite, le calcul a été fait pour deux valeurs de C . Le point en haut à droite est un outlier (il est placé en dehors de l'enveloppe calculée).

Estimation du support d'une densité



Approche OCSVM (One Class SVM, Schölkopf et al. 2001) trouver dans l'espace d'arrivée \mathcal{H} l'hyperplan le plus éloigné de l'origine, qui sépare les données de l'origine

One Class SVM (OCSVM)

One Class SVM (OCSVM) :

$$\left\{ \begin{array}{l} \min_{w, \xi_i, \rho} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i - \rho \\ \text{avec :} \\ w \cdot x_i \geq \rho - \xi_i, i = 1, \dots, n \\ \xi_i \geq 0, i = 1, \dots, n \end{array} \right.$$

- Fonction de décision : $f(x) = \text{sign}(\langle w, \phi(x) \rangle - \rho)$
- ρ : distance à l'origine
- $C = \frac{1}{\nu n}$ paramètre de régularisation qui permet de contrôler le nombre de outliers.

One Class SVM (OCSVM)

Le dual est le même que celui des SVDD avec le terme linéaire de la fonction cout en moins :

$$\left\{ \begin{array}{l} \min_{\alpha} \frac{1}{2} \alpha^T K \alpha \\ \text{avec :} \\ e^t \alpha = 1 \\ 0 \leq \alpha_i \leq C, i = 1, \dots, n \end{array} \right.$$

- K est la matrice de Gramm $K_{ij} = k(x_i, x_j)$
- Fonction de décision :

$$f(x) = \text{sign}(\langle w, \phi(x) \rangle - \rho) = \text{sign}\left(\sum_{i=1}^n \alpha_i K(x_i, x) - \rho\right)$$

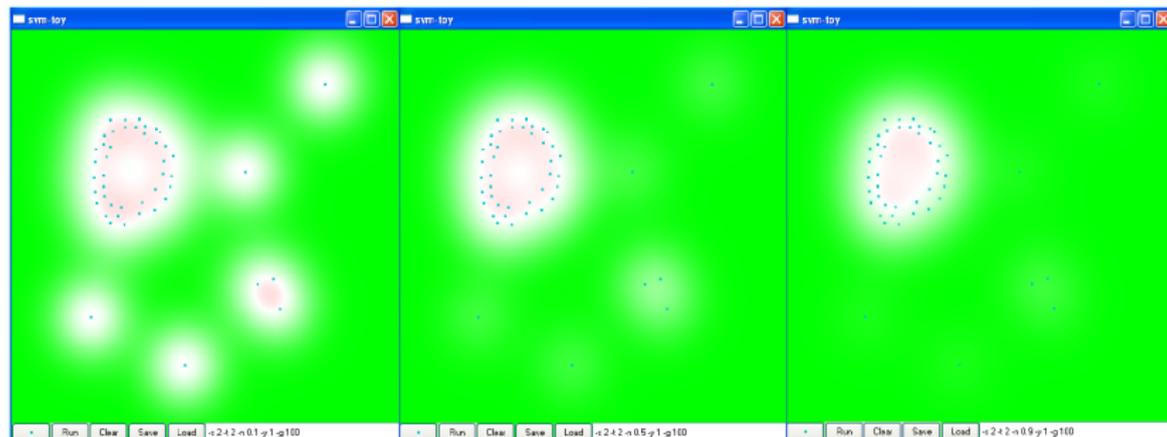
$$\text{avec } \rho = \langle w, \phi(x_s) \rangle = \sum_{i=1}^n \alpha_i K(x_i, x_s)$$

- $C = \frac{1}{\nu n}$ paramètre de régularisation qui permet de contrôler le nombre de outliers.

One Class SVM (OCSVM)

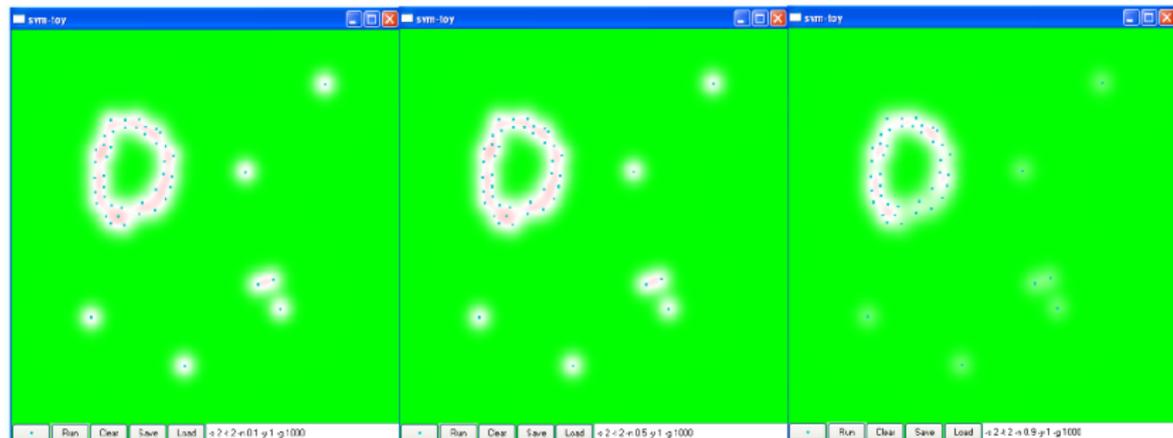
- Dans les deux formulations $\nu \in (0, 1]$ et $\nu n = 1/C$ est :
 - Une borne supérieure pour la fraction de outliers
 - Une borne inférieure pour la fraction de vecteurs de support
- Bornes de généralisation : la probabilité pour que de nouveaux exemples (tirages i.i.d. suivant la densité $p(x)$) soient en dehors d'une région un peu plus grande que le support déterminé ne sera pas supérieure de beaucoup à la fraction de outliers dans les données d'apprentissage

One Class SVM (OCSVM)



Noyau RBF avec $\gamma=100$: $\nu=0,1$, $\nu=0,5$, $\nu=0,9$

One Class SVM (OCSVM)



Noyau RBF avec $\gamma=1000$: $\nu=0,1$, $\nu=0,5$, $\nu=0,9$

Plan du cours

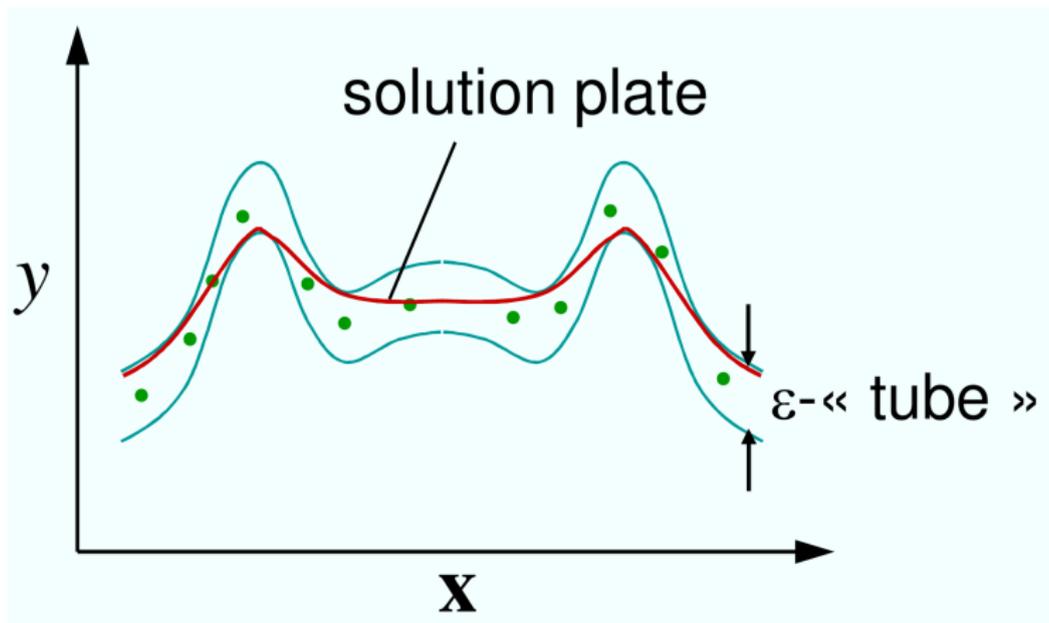
- 2 Objectifs et contenu de l'enseignement
- 3 Estimation du support d'une densité
- 4 SVM pour la régression**
- 5 Applications

SVM pour la régression (SVR)

SVM pour la régression (SVR) :

- Données d'apprentissage $\mathcal{D} = \{(x_i, y_i) ; i = 1, \dots, n\}$
- $x_i \in \mathcal{X}, y_i \in \mathcal{R}$
- En **régression ϵ -SV** on cherche une fonction $f : \mathcal{X} \rightarrow \mathcal{R}$ aussi "plate" que possible et $|f(x_i) - y_i| < \epsilon$
- On cherchera des solutions de la forme $f(x) = \langle w, \phi(x) \rangle + b$ dans l'espace \mathcal{H} d'arrivée.
- La condition d'aplatissement se traduit par la minimisation de $\|w\|^2 = \langle w, w \rangle$

SVM pour la régression

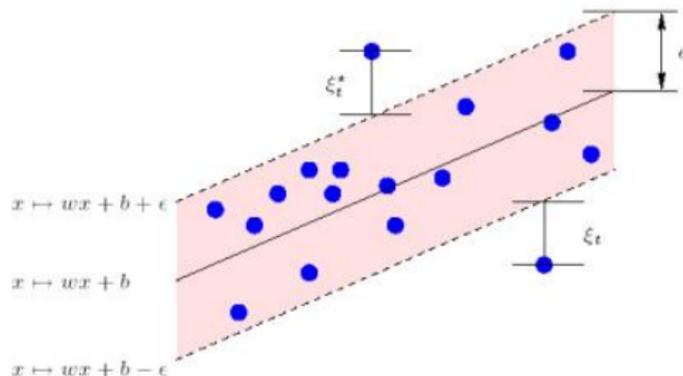


SVM pour la régression : on cherche une solution aussi plate que possible sans s'éloigner trop des points d'apprentissage (en vert).

SVM pour la régression

La régression ϵ -SV correspond à l'utilisation de la fonction de coût ϵ -insensible :

$$|\xi|_{\epsilon} = \begin{cases} 0 & \text{si } |\xi| < \epsilon \\ |\xi| - \epsilon & \text{sinon} \end{cases}$$



SVM pour la régression

Comme en discrimination, on accepte quelques erreurs au-delà de ϵ et on introduit les « variables d'assouplissement ξ_i, ξ_i^*

Le problème d'optimisation sera :

$$\left\{ \begin{array}{l} \min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{avec :} \\ y_i - \langle w, \phi(x_i) \rangle - b \leq \epsilon + \xi_i, i = 1, \dots, n \\ \langle w, \phi(x_i) \rangle + b - y_i \leq \epsilon + \xi_i^*, i = 1, \dots, n \\ \xi_i, \xi_i^* \geq 0, i = 1, \dots, n \end{array} \right.$$

- La constante $C > 0$ permet de choisir le point d'équilibre entre l'aplatissement de la solution et l'acceptation d'erreurs au-delà de ϵ

SVM pour la régression

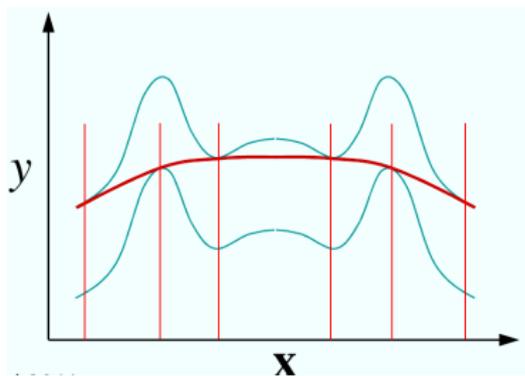
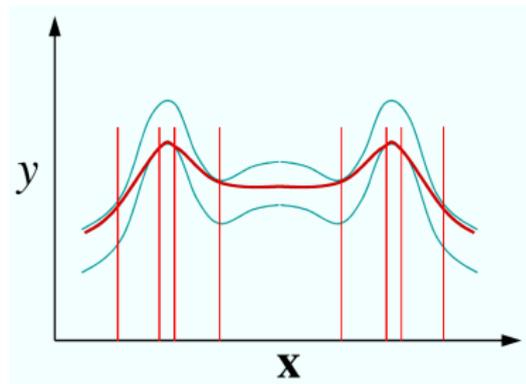
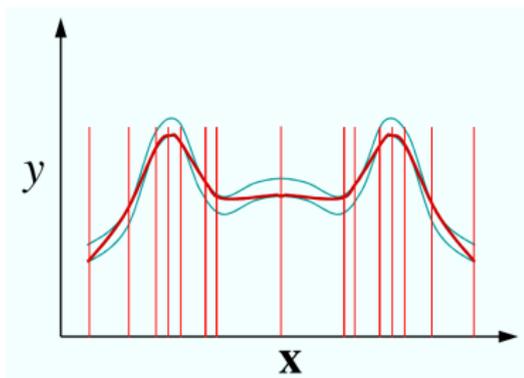
Avec les multiplicateurs de Lagrange on obtient le problème dual :

$$\left\{ \begin{array}{l} \min_{\alpha, \alpha^*} \frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) + \epsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) - \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \\ \text{avec :} \\ 0 \leq \alpha_i, \alpha_j \leq C, \quad i, j = 1, \dots, n \\ \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \end{array} \right.$$

- Tous les points d'apprentissage à l'intérieur du ϵ -tube ont $\alpha_i = \alpha_i^* = 0$. Les points qui ont $\alpha_i, \alpha_i^* \neq 0$ sont appelés vecteurs de support.
- Comme $w = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \phi(x_i)$, la fonction recherchée sera :

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b$$

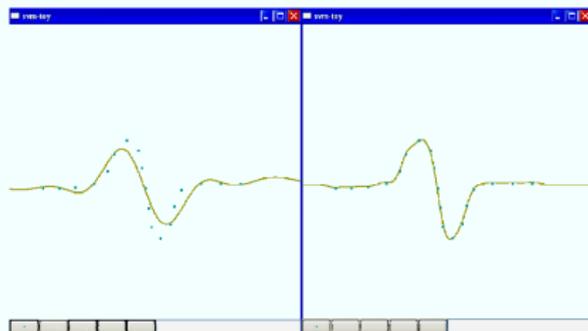
SVM pour la régression



SVM pour la régression



Noyau RBF avec $\gamma=100$: $\nu=0,1$ et $\varepsilon=0,1$, $\nu=0,9$ et $\varepsilon=0,1$, $\nu=0,1$ et $\varepsilon=0,01$, $\nu=0,9$ et $\varepsilon=0,01$



Noyau RBF avec $\gamma=40$ (gauche) et avec $\gamma=1000$ ($\nu=0,9$ et $\varepsilon=0,01$ dans les deux cas)

Algorithmes à noyaux

Algorithmes à noyaux :

- Kernel PCA (Principal Component Analysis) Scholkopf et al. 2001
- Kernel CCA (Cannonical Correlation Analysis) Hardoon et al. 2003
- Kernel FDA (Factorial Discriminant Analysis) Roth et al. 2000
- Tout algorithme qui utilise des produits scalaires entre les échantillons peut être non-linéarisé par le "truc à noyaux"

Plan du cours

2 Objectifs et contenu de l'enseignement

3 Estimation du support d'une densité

4 SVM pour la régression

5 Applications

Applications

Applications :

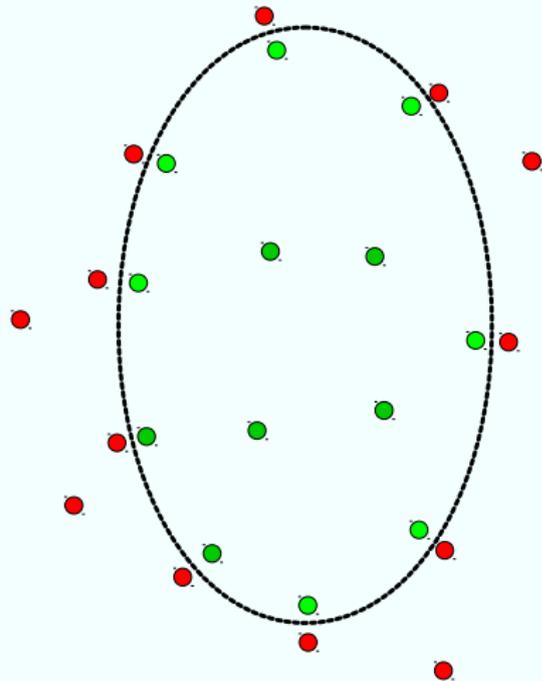
- Recherche d'images en boucle de pertinence
- Autres applications

Rappel: principe SVM

Machines à vecteurs de support (SVM)

$f = 0$: hyper surface de séparation

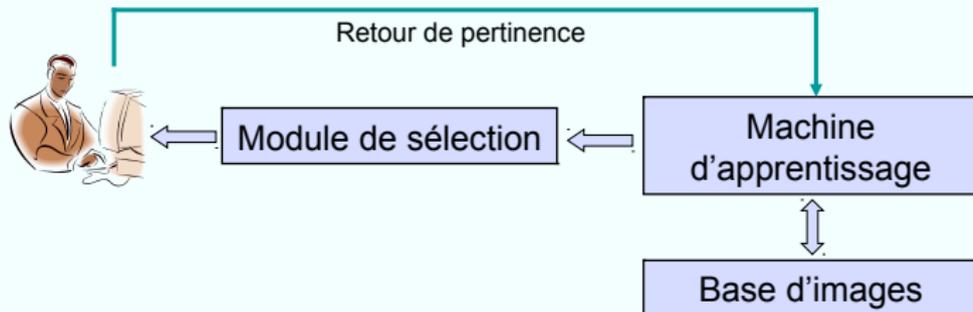
$$f(\mathbf{x}) = \sum_{i=1}^N \alpha_i K(\mathbf{x}_i, \mathbf{x}) - b$$



SVM pour le contrôle de pertinence

Recherche par retour de pertinence:

- Personnalisation de la recherche
- Recherche interactive supervisé
- L'utilisateur participe activement à la recherche
- Session de recherche itérative



SVM pour le contrôle de pertinence

- Contrôle de pertinence (*relevance feedback*) : tenir compte du feedback de l'utilisateur dans la recherche itérative par le contenu

1. Recherche d'images par l'exemple

2.113606
IDS
mer_a_000061.44.jpg

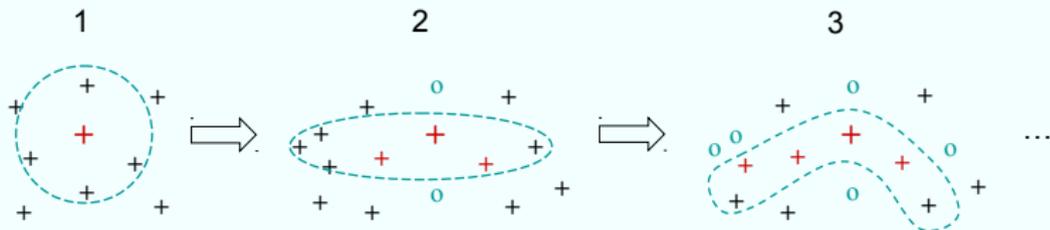
2.209391
IDS
montagne_a_000163.50.jpg

2.383989
IDS
transpor.ids_115a.83.jpg

2.453606
IDS
mer_a_000587.49.jpg

<http://www-rocq.inria.fr/imedia/>

2. Recherche itérative avec contrôle de pertinence



Composantes du mécanisme

1. **Learner** : à partir de l'information disponible (notamment des exemples positifs et/ou négatifs), estimer l'ensemble d'images visé
2. **Sélecteur** : à partir de l'estimation produite par le *learner*, choisir les images que l'utilisateur doit marquer lors de l'itération suivante
3. **Utilisateur** : fournir à chaque itération le retour pour les images choisies par le sélecteur
 - Les évaluations sont souvent faites à l'aide d'une vérité terrain, en émulant l'utilisateur

Difficultés pour l'apprentissage

- **Très peu d'exemples** étiquetés : leur nombre est souvent inférieur au nombre de dimensions de l'espace de description !
- **Déséquilibre** important entre le nombre d'exemples positifs et le nombre d'exemples négatifs
- **Forme** potentiellement **complexe** de l'ensemble d'images visé, qui peut même présenter **plusieurs modes distants** dans l'espace de description
- L'interactivité exige un **temps de réponse très court**, à la fois pour le *learner* et pour le sélecteur

Sélecteur : objectifs et critères

■ Objectifs

1. Retourner un maximum d'images pertinentes à l'utilisateur
2. Maximiser le transfert d'information **utilisateur** → **système**

■ Critères de sélection

- ◆ « **Les plus positives** » (MP) : retourner les images les plus pertinentes suivant l'estimation actuelle faite par le *learner* – critère classique le plus utilisé
- ◆ « **Les plus informatives** » (MI) : retourner les images qui permettent à l'utilisateur de fournir un maximum d'information sur sa cible → **minimiser le nombre d'exemples**

Critère « les plus informatives »

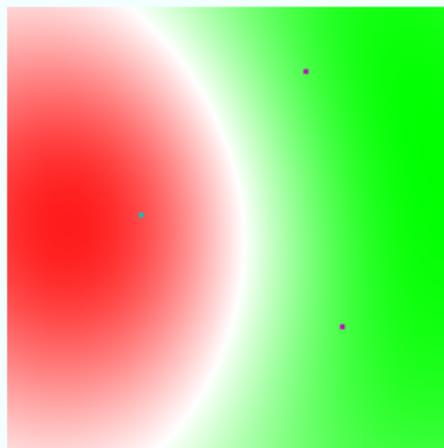
- Composantes **complémentaires** du critère MI
 1. Ambiguïté élevée (de chaque image sélectionnée) par rapport à l'estimation courante faite par le *learner*
 - ◆ Comme critère individuel : « les plus ambiguës »
 2. Faible redondance de l'ensemble des s images retournées
- Un critère « les plus informatives » pour SVM [FCB04]
 1. Présélectionner les $t > s$ images pour lesquelles les valeurs de la fonction de décision SVM sont les plus proches de 0 (images les plus ambiguës)
 2. Choisir itérativement les s images pour lesquelles

$$\arg \max_x \min_i d(x, x_i)$$

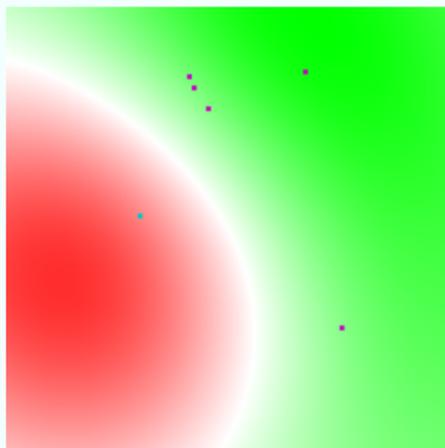
$$\arg \min_x \max_i K(x, x_i)$$

Plus ambiguës : illustration

- Les s images les plus proches de la frontière peuvent être redondantes



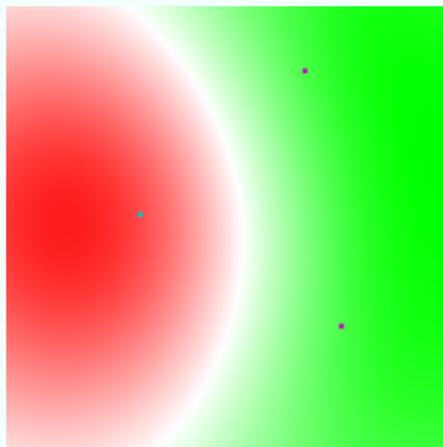
Avant sélection



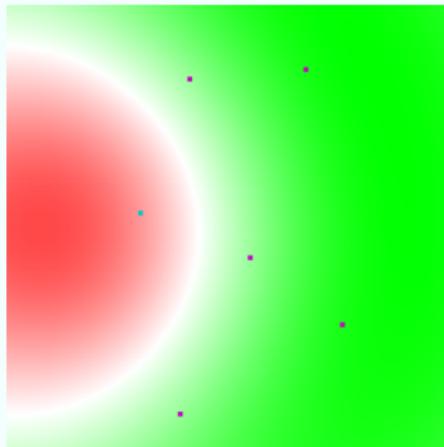
Après sélection, *feedback*, estimation

Plus informatives : illustration

- Le critère conjoint minimise également la redondance
⇒ focalisation plus rapide sur les images recherchées



Avant sélection



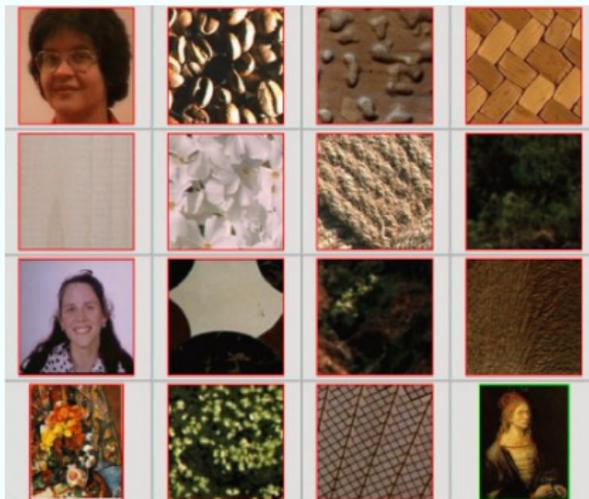
Après sélection, *feedback*, estimation

Contrôle de pertinence : exemple (3)

Objectif : retrouver des portraits

Base de 7500 images, dont 110 portraits

Disponible : description globale (couleur, texture, forme)

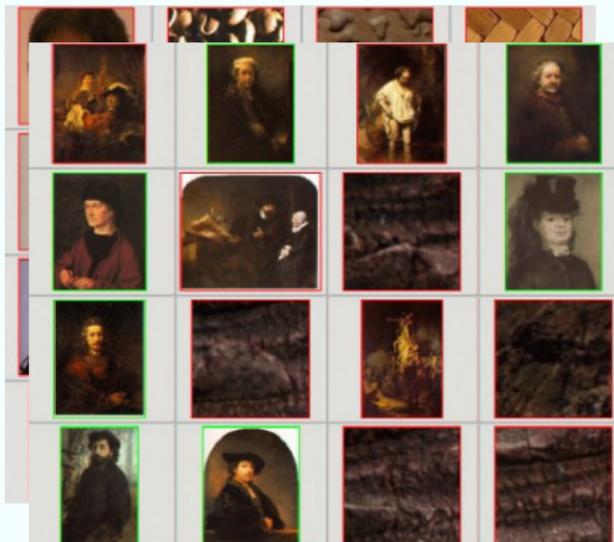


Contrôle de pertinence : exemple (3)

Objectif : retrouver des portraits

Base de 7500 images, dont 110 portraits

Disponible : description globale (couleur, texture, forme)

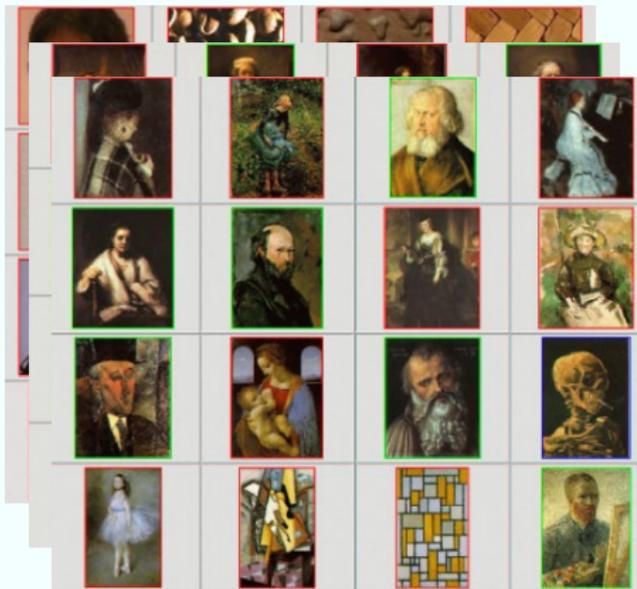


Contrôle de pertinence : exemple (3)

Objectif : retrouver des portraits

Base de 7500 images, dont 110 portraits

Disponible : description globale (couleur, texture, forme)

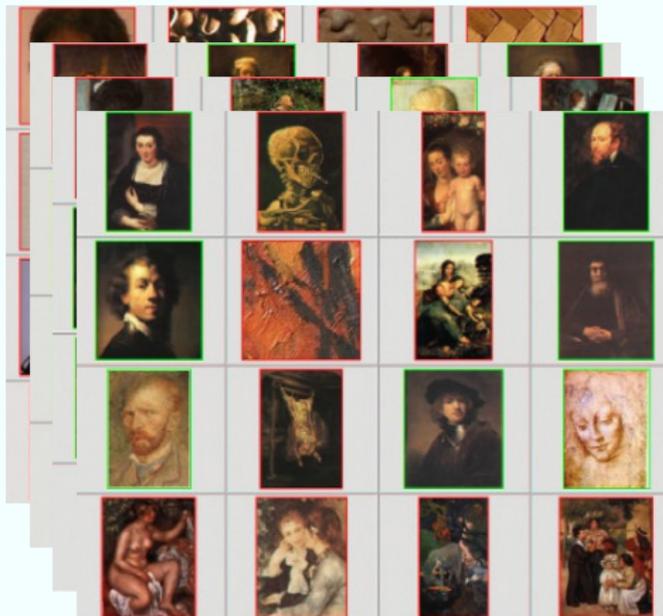


Contrôle de pertinence : exemple (3)

Objectif : retrouver des portraits

Base de 7500 images, dont 110 portraits

Disponible : description globale (couleur, texture, forme)



Contrôle de pertinence : exemple (3)

Objectif : retrouver des portraits

Base de 7500 images, dont 110 portraits

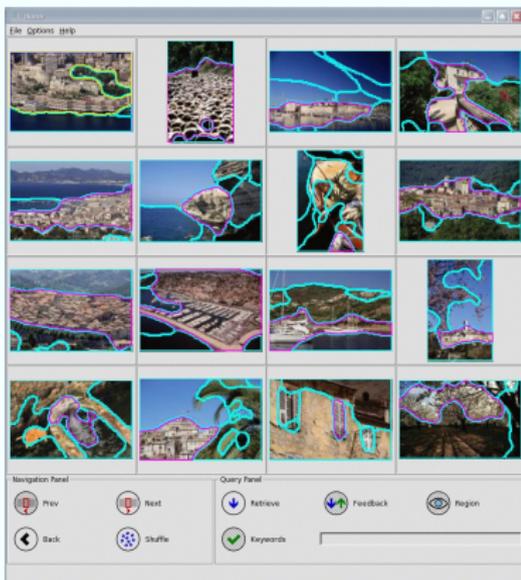
Disponible : description globale (couleur, texture, forme)

Première page de résultats après 4 itérations

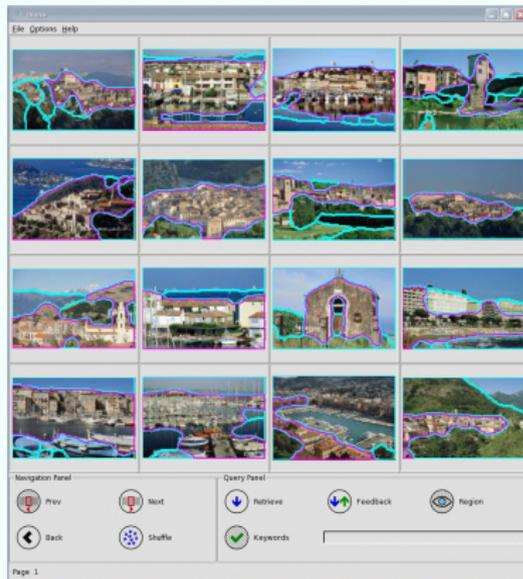


Contrôle de pertinence : exemple (4)

Recherche de régions urbaines dans une base d'images généraliste
(60.000 régions d'image)



Recherche directe

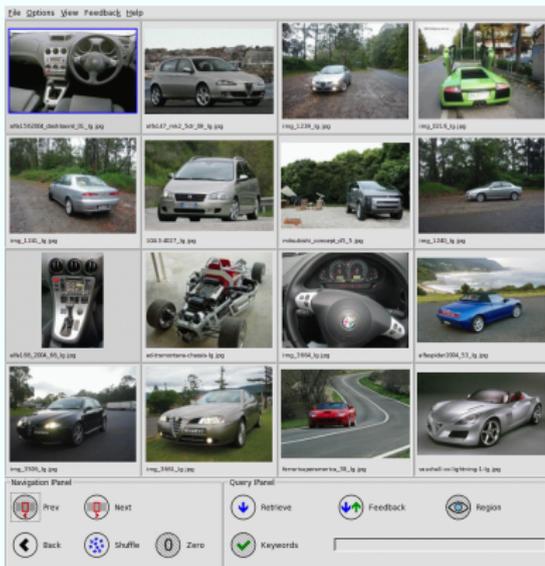


Recherche par contrôle de pertinence

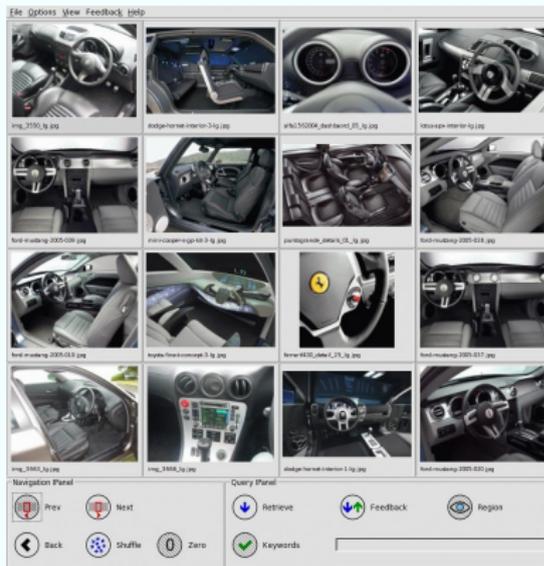
Contrôle de pertinence : exemple (5)

Sujet de recherche: Intérieur voiture

Base de données projet Européen TRENDS (~600.000 images)

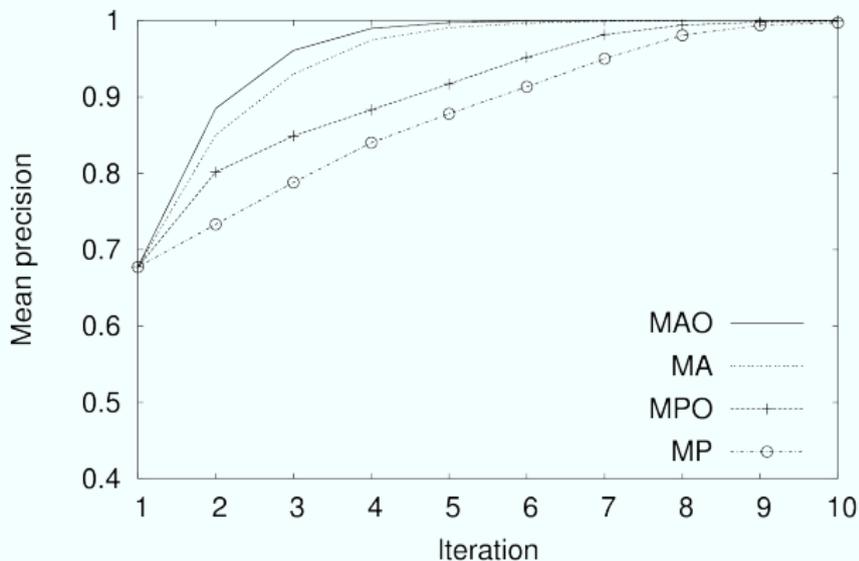


Recherche directe



Recherche par contrôle de pertinence

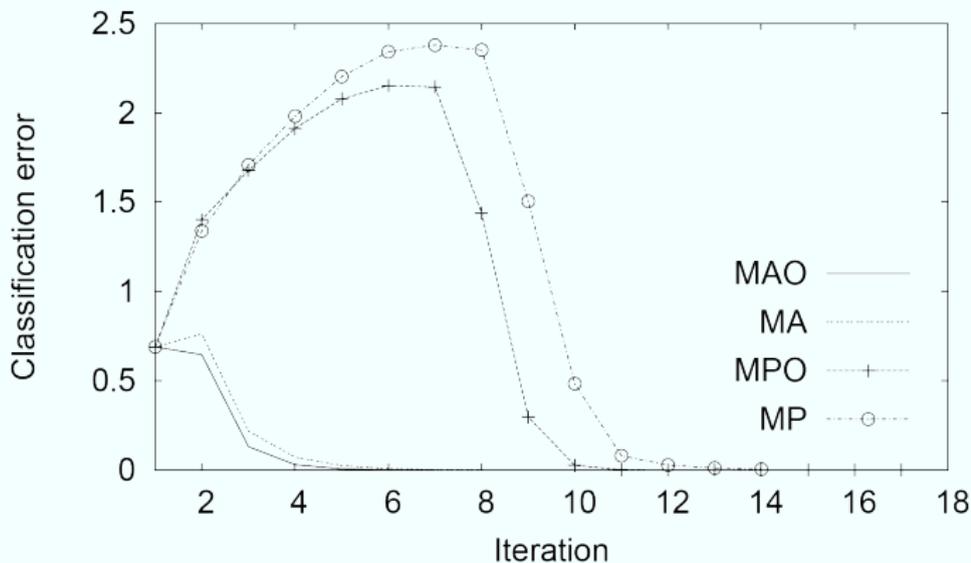
Rapidité de convergence : *ranking*



Évolution de la précision moyenne lors d'itérations successives

[Fer05], [FCB04]

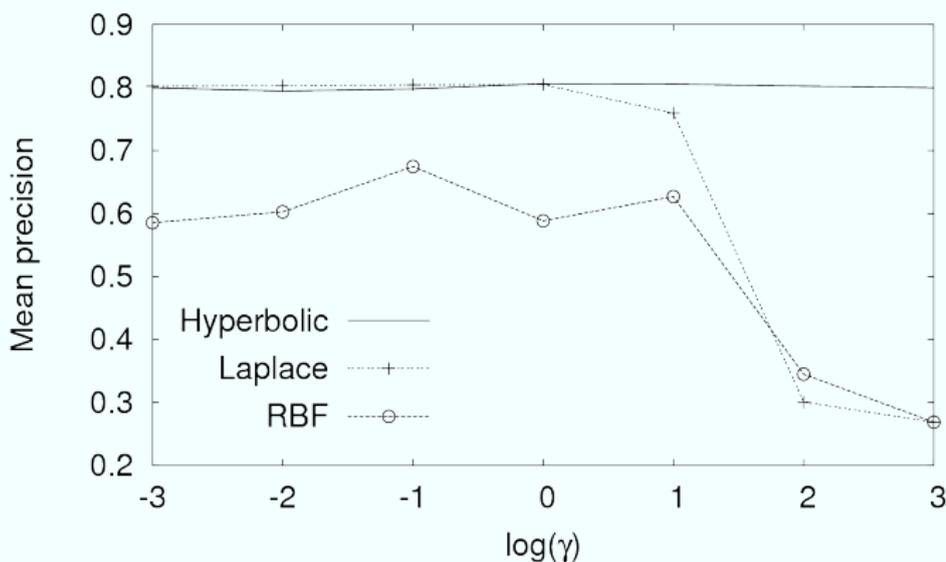
Rapidité de convergence : séparation



Évolution de l'erreur de discrimination lors d'itérations successives

[Fer05], [FCB04]

Dépendance du paramètre d'échelle



Dépendance des résultats (précision moyenne durant les 15 premières itérations) du paramètre d'échelle du noyau

[Fer05], [FCB04]

SVM : conclusion

- Avantages des SVM pour le contrôle de pertinence
 - ◆ La fonction de décision associée permet à la fois la définition d'une frontière et le classement des images
 - ◆ Avec un large choix des noyaux, les SVM permettent une grande liberté dans la forme des classes (avec un contrôle par la régularisation)
 - ◆ D'autres sources d'information (en dehors des exemples) permettent de définir des noyaux appropriés
 - ◆ Apprentissage très rapide avec le nombre relativement limité d'exemples fournis par le contrôle de pertinence
 - ◆ Moindre sensibilité au déséquilibre entre exemples positifs et négatifs
- Inconvénients
 - ◆ Par rapport aux noyaux de Parzen, absence de caractère incrémental (dans la formulation de base) et donc étape de sélection plus coûteuse

Autres applications (très nombreuses)

- Finance (évolution des prix, valeurs en bourse, etc.)
- Structure des protéines (Protein Folding)
- Génomique (microarray gene expression data)
- Reconnaissance de visage
- Détections des catastrophes, forecasting
- Images satellite et surveillance
- Diagnostic médical (cancer du sein)
- En physique; exemple: Particle and Quark-Flavour Identification in High Energy Physics (Classifying LEP Data with Support Vector Algorithms by Schölkopf et al. AIHENP'99)

Références

Livres, articles, web :

- Steinwart, Christmann, *Support Vector Machines*, Springer 2008
- Scholkopf, Smola, *Learning with Kernels*, The MIT Press, 2001
- Hastie, Tibshirani, Friedman, *The elements of statistical learning : Data mining, inference, and prediction*, New York, Springer Verlag, 2006
- —, *Machines à vecteurs supports (WikiStat)*, <http://wikistat.fr>
- Tax and Duin, *Support Vector Data Description*, Machine Learning, 54(1), 2004
- Hardoon, Szedmak, Shawe-Taylor, *Canonical correlation analysis; an overview with application to learning methods*, Tech. Rep., University of London, 2003.
- Roth, Steinhage, *Nonlinear discriminant analysis using kernel functions*, Advances in Neural Information Processing Systems, 2000.