

# Notes du cours (2)

Slide 7:

$\forall i$  tq  $y_i = 1$  <sup>bleu</sup>, on a  $\langle w, x_i \rangle + b \geq 1$


$\forall i$  tq  $y_i = -1$  <sup>rouge</sup>, on a  $\langle w, x_i \rangle + b \leq -1$

donc pour les bleus  $y_i (\langle w, x_i \rangle + b) \geq 1$

rouges  $y_i (\langle w, x_i \rangle + b) \leq -1$

$\Rightarrow$  pointier correctement classifié  $\Leftrightarrow y_i (\langle w, x_i \rangle + b) \geq 1$ .

Slide 8 : distance d'un point  $x$  à  $H$ .



la distance de  $X$  à  $H$  est donnée par  $\|XX^\#\|$

$\vec{OX} = \vec{OA} + AX^\# + X^\#X$  et  $A$  et  $X^\#$  sont dans  $H$

$\Leftrightarrow \vec{x} = \vec{a} + AX^\# + X^\#X$  donc  $AX^\# \perp \vec{w}$

$$\Rightarrow \langle \vec{x}, \vec{w} \rangle = \langle \vec{a}, \vec{w} \rangle + \langle AX^\#, \vec{w} \rangle + \langle X^\#X, \vec{w} \rangle \quad \left| \begin{array}{l} \vec{a} \cdot \vec{w} \\ A \in H \Rightarrow \\ \langle \vec{x}, \vec{w} \rangle + b \\ X^\#X \perp \vec{w} \end{array} \right.$$

$$\Rightarrow \langle \vec{x}, \vec{w} \rangle = -b + \sqrt{\|w\|^2} \quad \left| \begin{array}{l} 0 \\ 0 + \sqrt{\langle \vec{w}, \vec{w} \rangle} \\ \end{array} \right.$$

$$\Rightarrow \sqrt{\|w\|} = \frac{\langle \vec{x}, \vec{w} \rangle + b}{\|w\|}$$



Slide 13 ou veut résoudre

$$\min_{w \in \mathbb{R}^d, b \in \mathbb{R}, s \in \mathbb{R}^n} \frac{1}{2} \|w\|_2^2 + C \sum_{i=1}^n s_i$$

s.c.  $y_i (\langle x_i, w \rangle + b) \geq 1 - s_i$  et  $s_i \geq 0 \quad \forall i = 1, \dots, n.$

Rappel.  $\min_{x \in \mathbb{R}^p} f(x)$  s.c.  $g_i(x) \leq 0 \quad i = 1, \dots, n.$

$$L(x, \alpha) = f(x) + \sum_{i=1}^n \alpha_i g_i(x) \quad \alpha = (\alpha_1, \dots, \alpha_n) \text{ sont les variables duales.}$$

$$D(\alpha) = \inf_x L(x, \alpha)$$

$$D^* = D(\alpha^*) = \max_{\alpha \geq 0} D(\alpha) \quad \text{Sous dualité forte } D^* = P^* = f(x^*)$$

On a la dualité forte si  $f, g_i$  sont convexes et  $\exists x$  tel  $g_i(x) < 0 \quad i = 1, \dots, n.$

$$f(x^*) = \min_x f(x) \quad \text{s.c. } g_i(x) \leq 0 \quad i = 1, \dots, n.$$

OK dans le cas des SVM.

$$L(w, b, s, \alpha, \beta) = \frac{1}{2} \|w\|_2^2 + C \sum_{i=1}^n s_i + \sum_{i=1}^n \alpha_i (1 - s_i - y_i (\langle x_i, w \rangle + b)) - \sum_{i=1}^n \beta_i s_i$$

Conditions KKT : à l'optimum, on a :

$$\nabla_w L(w^*, b^*, s^*, \alpha^*, \beta^*) = 0 = w - \sum_{i=1}^n \alpha_i y_i x_i$$

$$\nabla_b L(w^*, b^*, s^*, \alpha^*, \beta^*) = 0 = - \sum_{i=1}^n \alpha_i y_i$$

$$\nabla_s L(w^*, b^*, s^*, \alpha^*, \beta^*) = 0 = \begin{pmatrix} C \\ \vdots \\ C \end{pmatrix} - \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} - \begin{pmatrix} \beta_1 \\ \vdots \\ \beta_n \end{pmatrix}$$

ou encore les + sur les valeurs à l'optimum

Conditions supplémentaires.

$$\alpha_i (1 - s_i - y_i (\langle w^*, x_i \rangle + b^*)) = 0 \Leftrightarrow \alpha_i = 0 \text{ ou } 1 - s_i - y_i (\langle w^*, x_i \rangle + b^*) = 0$$

$$\beta_i s_i^* = 0 \Leftrightarrow \beta_i = 0 \text{ ou } s_i = 0.$$

On a donc à l'optimum.

$$w = \sum_{i=1}^n \alpha_i y_i x_i$$

Seuls les  $i$  tq  $\alpha_i \neq 0$  apparaissent dans  $w$ . on les appelle les vecteurs support

pour ces vecteurs support, on a :

$$y_i (\langle x_i, w \rangle + b) = 1 - s_i \quad \begin{cases} s_i = 0 & \text{donc } x_i \in \text{support} \\ s_i > 0 & x_i \text{ est un outlier } \leftarrow \alpha_i = C. \end{cases}$$

→ SVM : support vector machine

Pour un vecteur support, i.e. tq  $d_i \neq 0$ , et tel que  $\xi_i = 0$  (c'est un point qui est sur l'un des hyperplans) on a  $1 - \xi_i - y_i (\langle x_i, w \rangle + b) = 0$

et  $\xi_i = 0$

$$\Leftrightarrow 1 - y_i \langle x_i, w \rangle - y_i b = 0$$

$$\Leftrightarrow y_i b = 1 - y_i \langle x_i, w \rangle.$$

$$\Leftrightarrow \overset{-1 \text{ ou } 1 \Rightarrow y_i^2 = 1}{y_i^2} b = y_i - y_i^2 \langle x_i, w \rangle.$$

$$\Leftrightarrow b = y_i - \langle x_i, w \rangle \quad \text{à l'optimum } w = \sum_{i=1}^n d_i y_i x_i$$


$$\| b = y_i - \langle x_i, \sum_{j=1}^n d_j y_j x_j \rangle = y_i - \sum_{j=1}^n d_j y_j \langle x_i, x_j \rangle$$

Notre classifieur SVM.

$x \rightarrow \text{signe} (\langle x, w \rangle + b) \leftarrow$

Slide 20.

Hinge loss  $\leftrightarrow$  SVM.



$$\min \frac{1}{2} \|w\|_2^2 + C \sum \xi_i \quad \text{sc } y_i (\langle x_i, w \rangle + b) \geq 1 - \xi_i \quad \xi_i \geq 0$$

Si  $i$  est correctement classé,  $y_i (\langle w, x_i \rangle + b) \geq 1$  ( $\xi_i = 0$ )

$$\Leftrightarrow 1 - y_i (\langle w, x_i \rangle + b) \leq 0 \text{ et } \xi_i = 0$$

dans le cas  $\max(0, 1 - y_i (\langle x_i, w \rangle + b)) = 0 = \xi_i$

Si  $i$  est un outlier  $y_i (\langle w, x_i \rangle + b) < 1$

$$\Leftrightarrow 1 - y_i (\langle w, x_i \rangle + b) > 0$$

$$\text{donc } \max(0, 1 - y_i (\langle w, x_i \rangle + b)) = 1 - y_i (\langle w, x_i \rangle + b) = \xi_i$$

on a aussi  $1 - \xi_i - y_i (\langle w, x_i \rangle + b) = 0$ .

$$\Leftrightarrow \xi_i = 1 - y_i (\langle w, x_i \rangle + b)$$

Notre problème est équivalent :

$$\min_{w, b} \frac{1}{2} \|w\|_2^2 + C \sum_{i=1}^n \max(0, 1 - y_i (\langle x_i, w \rangle + b))$$

ou n'a plus besoin de contraintes.

$$\frac{1}{n} \sum_{i=1}^n \ell(x_i, y_i) + \mu$$

$$= \min_{w, b} \frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i (\langle x_i, w \rangle + b)) \text{ hinge} + \frac{\lambda}{2Ch} \frac{1}{2} \|w\|_2^2$$

Slide 22 Problème dual. on remplace  $w^*$  et  $b^*$

par leurs valeurs en fonction des variables duales

$$L(w, b, s, \alpha, \beta) = \frac{1}{2} \|w\|_2^2 + C \sum s_i + \sum \alpha_i (1 - s_i - y_i (\langle x_i, w \rangle + b)) - \sum \beta_i s_i.$$

à l'optimum on a  $w^* = \sum d_i^* y_i x_i$

$$\Rightarrow d_i^* (1 - s_i^* - y_i (\langle x_i, w^* \rangle + b^*)) = 0 \quad (*)$$

(pour simplifier, on enlève les  $*$ ).  $\beta_i^* s_i^* = 0$ .  $\sum d_i^* y_i = 0 \Rightarrow d_i^* + \beta_i^* = C$ .

$$(**) \frac{1}{2} \left\| \sum_{i=1}^n d_i y_i x_i \right\|_2^2 + \sum_{i=1}^n (d_i + \beta_i) s_i + \sum_{i=1}^n 0 - \sum_{i=1}^n 0$$

$$= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n d_i d_j y_i y_j \langle x_i, x_j \rangle + \sum_{i=1}^n d_i s_i + \sum_{i=1}^n \beta_i s_i$$

Il reste à exprimer  $s_i$  en fonction des variables duales.

$$(*) \Leftrightarrow d_i = d_i s_i + d_i y_i (\langle x_i, w \rangle + b)$$

$$\Leftrightarrow d_i s_i = d_i (1 - y_i (\langle x_i, w \rangle + b))$$

On calcule:


$$\begin{aligned} \sum d_i s_i &= \sum d_i - \sum d_i y_i \langle x_i, w \rangle - \sum d_i y_i b \\ &= \sum d_i - \sum_{i=1}^n d_i y_i \langle x_i, \sum_{j=1}^n d_j y_j x_j \rangle - b \underbrace{\sum d_i y_i}_{=0} \\ &= \sum d_i - \sum_{i=1}^n \sum_{j=1}^n d_i d_j y_i y_j \langle x_i, x_j \rangle \end{aligned}$$

$$(***) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n d_i d_j y_i y_j \langle x_i, x_j \rangle + \sum d_i - \sum \sum d_i d_j y_i y_j \langle x_i, x_j \rangle$$

$$= \sum_{i=1}^n d_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n d_i d_j y_i y_j \langle x_i, x_j \rangle = D(\alpha)$$

Slide 29

problème de classification XOR  
exclusive or.



↔ un point est bleu si exactement une de ses coordonnées = +1

dans  $\mathbb{R}^2$  on ne peut trouver d'hyperplan (droite) qui sépare les points rouges des bleus.

On essaie de trouver une transformation  $\mathcal{U}$  telle que dans le nouvel espace les points soient séparables par un hyperplan.

$$\mathcal{U}(x) = (x_1^2, x_2^2, \sqrt{2}x_1x_2, \sqrt{2}x_1, \sqrt{2}x_2, 1)$$


$\mathbb{R}^2 \xrightarrow{\mathcal{U}} \mathbb{R}^6$  en augmente la dimension.

$$\mathcal{U}(1, 1) = (1, 1, \sqrt{2}, \sqrt{2}, \sqrt{2}, 1)$$

$$\mathcal{U}(-1, -1) = (1, 1, \sqrt{2}, -\sqrt{2}, -\sqrt{2}, 1)$$

$$\mathcal{U}(1, -1) = (1, 1, -\sqrt{2}, \sqrt{2}, -\sqrt{2}, 1)$$

$$\mathcal{U}(-1, 1) = (1, 1, -\sqrt{2}, -\sqrt{2}, \sqrt{2}, 1)$$



c'est linéairement séparable

→ on peut faire passer un hyperplan qui sépare les points rouges des pts bleus.

Slide 30  $x, x' \in \mathbb{R}^2$

$$\langle \mathcal{U}(x), \mathcal{U}(x') \rangle = \left\langle \begin{pmatrix} x_1^2 \\ x_2^2 \\ \sqrt{2}x_1x_2 \\ \sqrt{2}x_1 \\ \sqrt{2}x_2 \\ 1 \end{pmatrix}, \begin{pmatrix} x_1'^2 \\ x_2'^2 \\ \sqrt{2}x_1'x_2' \\ \sqrt{2}x_1' \\ \sqrt{2}x_2' \\ 1 \end{pmatrix} \right\rangle$$

$\langle \cdot, \cdot \rangle_{\mathbb{F} = \mathbb{R}^6}$

$$= (x_1x_1')^2 + (x_2x_2')^2 + 2x_1x_2x_1'x_2' + 2x_1x_1' + 2x_2x_2' + 1$$

$$= (x_1x_1' + x_2x_2' + 1)^2 = (\langle x, x' \rangle + 1)^2 \quad \text{à nouveau cela dépend de } \langle x, x' \rangle$$

## Slide 35

$K$  et  $K'$  2 noyaux PDS.  $K+K'$  est PDS?

$$K+K'(x, x') = K(x, x') + K'(x, x') = K(x', x) + K'(x', x) = (K+K')(x', x).$$

$$u^T (K+K') u = u^T K u + u^T K' u \geq 0.$$

$\Rightarrow K+K'$  est PDS

$K \cdot K'$  est PDS?

$$u^T (K \odot K') u = \sum_{1 \leq i, j \leq n} u_i u_j K_{ij} K'_{ij} \quad (*)$$

$$K \odot K'$$

$$= (K_{ij} \cdot K'_{ij})_{ij}$$

on sait  $K$  est une matrice définie positive.

il existe  $M$  tq  $K = M M^T$

$$K_{ij} = \sum_{k=1}^n M_{ik} M_{kj}$$

$$(*) = \sum_{1 \leq i, j \leq n} u_i u_j \sum_{k=1}^n M_{ik} M_{kj} K'_{ij} = \sum_{k=1}^n \sum_{i, j} u_i M_{ik} K'_{ij} u_j M_{kj}$$

$$z_k = u \odot M_{\cdot k} = \begin{pmatrix} u_i M_{ik} \\ \vdots \end{pmatrix}$$

$$= \sum_{k=1}^n z_k^T K' z_k \geq 0.$$

$K \cdot K'$  est bien PDS.  $\star$

## Slides 36 et suivantes

Noyau linéaire.  $K(x, x') = \langle x, x' \rangle + c \quad c \geq 0.$

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

$K$  est symétrique.

$$u^T K u = \sum_{1 \leq i, j \leq n} u_i u_j K(x_i, x_j) = \sum_{1 \leq i, j \leq n} u_i u_j \langle x_i, x_j \rangle + c \sum_{1 \leq i, j \leq n} u_i u_j = \left\| \sum_{i=1}^n u_i x_i \right\|_2^2 + c \left( \sum_{i=1}^n u_i \right)^2 \geq 0. \quad \text{PDS.}$$

$\Rightarrow$  Noyau polynomial  $K(x, x') = (\langle x, x' \rangle + c)^q \quad q \in \mathbb{N}^*$

PDS comme puissance du noyau linéaire.