

**COURS D'APPRENTISSAGE STATISTIQUE**  
**(SYLVAIN ARLOT ET FRANCIS BACH)**  
**MASTÈRE M2 PROBABILITÉS-STATISTIQUE 2011**

**COURS 3 - CONVEXIFICATION DU RISQUE**

NOTES DE COURS PRISES PAR NELO MOLTER MAGALHÃES ET MAUD THOMAS

On cherche à optimiser le risque empirique. Cela n'est pas toujours possible, mais il existe des cas où on sait le faire, par exemple lorsque la perte est convexe.

1. RAPPELS D'OPTIMISATION

1.1. **Dualité Lagrangienne.** On cherche à minimiser sur  $\mathcal{X} \subset \mathbb{R}^n, x \rightarrow f(x)$  telle que :

$$(*) \quad \begin{cases} h_i(x) = 0, & i = 1, \dots, m \\ g_j(x) \leq 0, & j = 1, \dots, r \end{cases}$$

avec  $m + r = n$ . On note  $\mathcal{X}^*$  l'ensemble des  $x \in \mathcal{X}$  vérifiant (\*).

**Définition 1.** On appelle Lagrangien du problème d'optimisation la fonction  $\mathcal{L}$  définie par :

$$\mathcal{L}(x, \lambda, \mu) = f(x) + \lambda^T h(x) + \mu^T g(x)$$

où  $\lambda \in \mathbb{R}^m, \mu \in \mathbb{R}_+^r$

$\lambda$  et  $\mu$  sont appelés les multiplicateurs de Lagrange

**Proposition 1.1.**

$$\sup_{\lambda \in \mathbb{R}^m, \mu \in \mathbb{R}_+^r} \mathcal{L}(x, \lambda, \mu) = \begin{cases} f(x) & \text{si } x \text{ vérifie } (*) \\ \infty & \text{sinon.} \end{cases}$$

**Définition 2.** On appelle fonction duale la fonction  $q$  définie par :

$$q(\lambda, \mu) = \inf_{x \in \mathcal{X}} \mathcal{L}(x, \lambda, \mu)$$

**Proposition 1.2.**  $q$  est concave

*Remarque 1.* La proposition ci-dessus est vraie sans aucune hypothèse.

*Démonstration.*  $\mathcal{L}$  est affine en  $\lambda, \mu$ , et l'infimum de fonctions linéaires est toujours concave.  $\square$

**Proposition 1.3.**

$$\forall \lambda, \mu, x \quad q(\lambda, \mu) \leq f(x)$$

*Démonstration.* Si  $x$  vérifie (\*), alors

$$q(\lambda, \mu) = \inf_{x \in \mathcal{X}} \mathcal{L}(x, \lambda, \mu) \leq \sup_{\lambda \in \mathbb{R}^m, \mu \in \mathbb{R}_+^r} \mathcal{L}(x, \lambda, \mu) = f(x)$$

Sinon, l'inégalité est triviale.  $\square$

### 1.2. Problème dual : Maximiser $q(\lambda, \mu)$ en $(\lambda, \mu)$ .

Remarque 2. Par la proposition 1.3, on a :

$$\forall \lambda, \mu \quad q(\lambda, \mu) \leq \min_{x \in \mathcal{X}^*} f(x)$$

Donc :

$$\max_{(\lambda, \mu)} q(\lambda, \mu) \leq \min_{x \in \mathcal{X}^*} f(x)$$

**Définition 3.** On dit qu'il y a dualité faible si :

$$f^* := \min_{x \in \mathcal{X}^*} f(x) \geq q^* := \max_{(\lambda, \mu)} q(\lambda, \mu)$$

**Définition 4.** On dit qu'il y a dualité forte si

$$f^* = q^*$$

**Définition 5.** On appelle conditions de Slater les hypothèses suivantes :

- $h_i$  est une fonction affine pour tout  $i$
- $g_j$  est une fonction convexe pour tout  $j$
- il existe  $x \in \mathcal{X}$  tel que :

$$\begin{aligned} h_i(x) &= 0, & \forall i = 1, \dots, m \\ g_j(x) &< 0, & \forall j = 1, \dots, r \end{aligned}$$

**Proposition 1.4.** Si les hypothèses de Slater sont vérifiées alors il y a dualité forte.

Remarque 3. - Sous certaines hypothèses (le plus souvent satisfaites), le dual du dual est le primal

- Le dual n'est pas unique. En effet, par exemple, on a :

$$\min_{x:|x| \leq 1} f(x) = \min_{x:x^2 \leq 1} f(x)$$

On a deux fonctions  $g$  différentes donc deux problèmes duaux différents.

**1.3. Problèmes variationnels (ou minimax).** Il est rare que l'on ait pour une fonction  $K$  quelconque :

$$\min_x \max_\lambda K(x, \lambda) = \max_\lambda \min_x K(x, \lambda)$$

Mais cela est vrai si  $K$  est convexe par rapport à la variable  $x$  et concave par rapport à la variable  $\lambda$ .

### 1.4. Condition de KKT (Karush - Kühn - Tucker).

Rappel 1. Si  $f$  est de classe  $\mathcal{C}^1$  et convexe alors une condition d'optimalité est :  $\nabla f(x) = 0$

Supposons qu'il y ait dualité forte. On note :

- $x^* \in \operatorname{argmin}_{x \in \mathcal{X}^*} \{f(x)\}$
- $(\lambda^*, \mu^*) \in \operatorname{argmax} \{q(\lambda, \mu)\}$

On a alors :

$$\begin{aligned} f(x^*) &= q(\lambda^*, \mu^*) \\ &= \inf_x \{f(x) + \lambda^{*T} g(x) + \mu^{*T} h(x)\} \\ &\leq f(x^*) + \lambda^{*T} g(x^*) + \mu^{*T} h(x^*) \\ &\leq f(x^*) \end{aligned}$$

Donc toutes les inégalités sont en fait des égalités.

On obtient ainsi la première condition de KKT (complementary slackness)

$$\forall j, \lambda_j^* g_j(x^*) = 0$$

La deuxième condition de KKT est :

$$h(x^*) = 0 \text{ et } g(x^*) \leq 0$$

Quand  $x$  vérifie la deuxième condition de KKT, on dit qu'il est admissible.

Et enfin la troisième condition de KKT :

$$x^* \in \operatorname{argmin} \mathcal{L}(x, \lambda, \mu)$$

*Remarque 4.* On peut montrer que ces conditions sont nécessaires et suffisantes pour avoir dualité forte.

*Rappel 2.* Soit  $f : \mathbb{R}^d \rightarrow \mathbb{R}$  convexe.

Si on pose :  $f^*(y) = \sup_{x \in \mathcal{X}} \{x^T y - f(x)\}$ . Alors,  $\forall x, f(x) = \sup_{y \in \mathbb{R}^d} \{x^T y - f^*(y)\}$

*Remarque 5.*  $f^*$  s'appelle la duale de Fenchel-Legendre de  $f$ .

## 2. CLASSIFICATION BINAIRE (SUPERVISÉE)

**2.1. Convexification du risque.** *Données :*  $(X_i, Y_i)_{i=1, \dots, n} \in \mathcal{X} \times \{-1, 1\}$  indépendantes et identiquement distribuées.

*But :* trouver  $f : \mathcal{X} \rightarrow \{-1, 1\}$  telle que :

$$\mathcal{R}(f) = E(\mathbf{1}_{f(X) \neq Y}) = P(f(X) \neq Y)$$

soit le plus petit possible.

*Remarque 6.*  $\mathcal{R}(f)$  désigne le risque, ou encore la probabilité d'erreur de  $f$ .

Problème :  $\{-1, 1\}$  n'est pas un espace vectoriel, donc  $\{f : \mathcal{X} \rightarrow \{-1, 1\}\}$  non plus, ce qui peut poser une difficulté pour résoudre un problème de minimisation.

*Nouveau but :* trouver  $f : \mathcal{X} \rightarrow \mathbb{R}$  et considérer alors la fonction :  $x \rightarrow \operatorname{sign}(f(x))$  comme prédicteur, où :

$$\operatorname{sign}(a) = \begin{cases} 1 & \text{si } a > 0 \\ -1 & \text{si } a < 0 \\ 0 & \text{si } a = 0 \end{cases}$$

*Risque :* Le risque devient alors :

$$\mathcal{R}(f) = P(\operatorname{sign}(f(X)) \neq Y) = E(\mathbf{1}_{\operatorname{sign}(f(X)) \neq Y}) = E(\mathbf{1}_{Yf(X) \leq 0}) = E\Phi_{0-1}(Yf(X))$$

où :  $\Phi_{0-1}$  est la perte 0 - 1.

*Risque empirique :*

$$\hat{\mathcal{R}}(f) = \frac{1}{n} \sum_{i=1}^n \Phi_{0-1}(Y_i f(X_i))$$

On cherche à minimiser le risque empirique, mais on ne peut pas le faire directement car  $\Phi_{0-1}$  est ni continue, ni convexe.

*Question :* Quel lien y a-t-il entre la perte 0 - 1 et les pertes convexes ?

## 2.2. Exemples.

*Exemple 1.* (1) Perte quadratique : ici  $\Phi(u) = (u - 1)^2$

$$\Phi(Yf(X)) = (Y - f(X))^2 = (f(X) - Y)^2$$

On retrouve les moindres carrés.

$$\mathcal{R}_\Phi(f) := E\Phi(Yf(X)) = E(f(X) - Y)^2$$

$\mathcal{R}_\Phi(f)$  est appelé le  $\Phi$ -risque.

*Rappel 3.* On a vu précédemment :  $\mathcal{R}(f) - \inf_f \{\mathcal{R}(f)\} \leq \sqrt{\mathcal{R}_\Phi(f) - \inf_f \{\mathcal{R}_\Phi(f)\}}$

Le membre de droite s'appelle l'excès de  $\Phi$ -risque.

(2) Perte logistique : ici  $\Phi(u) = \log(1 + e^{-u})$

$$\Phi(Yf(X)) = \log(1 + e^{-Yf(X)}) = -\log\left(\frac{1}{1 + e^{-Yf(X)}}\right) = -\log(\sigma(Yf(X)))$$

où :  $\sigma(v) = \frac{1}{1+e^{-v}}$  fonction sigmoïde.

Lien avec les probabilités : on considère le modèle défini par :

$$q(Y = 1|X = x) = \sigma(f(x)) \text{ et } q(Y = -1|X = x) = \sigma(-f(x))$$

Alors le risque est égal à  $-$ la log-vraisemblance conditionnelle :  $E[-\log(q(Y|X))]$

(3) Perte hinge : ici  $\Phi(u) = \max(1 - u, 0)$

Soit  $f(x) = w^T x + b$ , on appelle marge la quantité (ceci correspond à une interprétation géométrique) :

$$\frac{1}{\|w\|}$$

On cherchera donc à minimiser  $\|w\|$ . Un classifieur adapté à ce problème est appelé classifieur "maximum margin".

*Remarque 7.* Pour ce dernier exemple, il y a deux formulations possibles :

-La formulation SVM (=support vector machine) séparable :

$$\min \frac{1}{2} \|w\|^2 \text{ tel que } y_i(w^T x_i + b) \geq 1$$

-La formulation SVM non séparable :

$$\min \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n \xi_i \text{ tel que}$$

$$\begin{aligned} y_i(w^T x_i + b) &\geq 1 - \xi_i \\ \xi_i &\geq 0 \end{aligned}$$

Cette dernière peut se reformuler comme suit :  $\min \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n \max(0, 1 - y_i(w^T x_i + b))$

Ou encore :  $\min \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n \Phi(y_i f(x_i))$

*Exemple 2.* Si on note :

$$\mathcal{L}(w, \xi, \alpha, \beta) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n \xi_i - \sum_{i=1}^n \beta_i \xi_i - \sum_{i=1}^n \alpha_i (y_i(w^T x_i + b) - 1 + \xi_i)$$

Les variables  $w, \xi$  sont liées au problème primal ; les variables  $\alpha, \beta$  sont liées au problème dual.

Pour minimiser cette expression en  $w$ , en dérivant, on trouve :  $0 = w - \sum_{i=1}^n \alpha_i y_i x_i$

En minimisant en  $\xi$  on trouve :  $0 = c - \alpha_i - \beta_i$

En minimisant en  $b$ , on trouve :  $0 = \sum_{i=1}^n \alpha_i y_i$

Et le problème dual s'écrit :  $\max_{\alpha} \frac{1}{2} \left\| \sum_{i=1}^n \alpha_i y_i x_i \right\|^2$  telle que :

$$\begin{aligned} 0 &= \sum_{i=1}^n \alpha_i y_i \\ 0 &\leq \alpha_i \leq c \end{aligned}$$

*Remarque 8.* Les conditions de KKT s'écrivent :

$$\begin{aligned} (c - \alpha_i) \xi_i &= 0, & i &= 1, \dots, n \\ \alpha_i (y_i (w^T x_i + b) - 1 + \xi_i) &= 0, & i &= 1, \dots, n \end{aligned}$$

On remarque alors que si  $y_i(w^T x_i + b) - 1 > 0$ , cela signifie qu'on est à droite du hinge et, comme  $\xi_i = 0$ , on a :  $\alpha_i = 0$

De même, si  $y_i(w^T x_i + b) - 1 = 0$ , cela signifie qu'on est sur le hinge, et on a :  $0 < \alpha_i < c$

Enfin, si  $y_i(w^T x_i + b) - 1 < 0$ , cela signifie qu'on est à gauche du hinge, et on a :  $\alpha_i = c$

Notons que ceci est un cas particulier du théorème du représentant (cours suivant).

**2.3. Liens entre risque et  $\Phi$ -risque.** Plaçons nous dans le cadre initial de ce paragraphe, avec une fonction  $g : \mathcal{X} \rightarrow \{-1, 1\}$ . Si on note  $\eta(x) = P(Y = 1|X = x)$ , alors le risque de  $g$  vérifie :

$$\mathcal{R}(g) = E\Phi_{0-1}(Yg(X)) = E[E(\mathbf{1}_{(g(X)) \neq Y}|X = x)] \geq E \min(\eta(X), 1 - \eta(X))$$

Et le meilleur classifieur est  $g^*(x) = \text{sign}(2\eta(x) - 1)$ .

**Lemma 2.1.**

$$\mathcal{R}(g) - \mathcal{R}(g^*) = E[\mathbf{1}_{g(X) \neq g^*(X)} |2\eta(X) - 1|]$$

*Démonstration.*

$$\begin{aligned} \mathcal{R}(g) - \mathcal{R}(g^*) &= E[E[\mathbf{1}_{g(X) \neq Y} - \mathbf{1}_{g^*(X) \neq Y}|X = x]] \\ &= E[\eta(X)(\mathbf{1}_{g(X)=-1} - \mathbf{1}_{g^*(X)=-1})] + E[(1 - \eta(X))(\mathbf{1}_{g(X)=1} - \mathbf{1}_{g^*(X)=1})] \\ &= E[(2\eta(X) - 1)(\mathbf{1}_{g(X)=-1} - \mathbf{1}_{g^*(X)=-1})] \\ &= E[(2\eta(X) - 1)(\mathbf{1}_{g(X) \neq g^*(X)} \text{sign}(2\eta(X) - 1))] \end{aligned}$$

D'où le résultat. □

**Définition 6.** Soit  $f : \mathcal{X} \rightarrow \mathbb{R}$ , on définit le  $\Phi$ -risque conditionnel par

$$E[\Phi(Yf(X))|X = x]$$

*Remarque 9.* On a  $E[\Phi(Yf(X))|X = x] = \eta(x)\Phi(f(x)) + (1 - \eta(x))\Phi(-f(x)) := C_{\eta(x)}(f(x))$   
Avec  $C_{\eta}(\alpha) = \eta\Phi(\alpha) + (1 - \eta)\Phi(-\alpha)$

**Proposition 2.2.** Si on pose :  $H(\eta) = \inf_{\alpha} C_{\eta}(\alpha)$ , on a :

$$\mathcal{R}_{\Phi}^* := \inf_g \mathcal{R}_{\Phi}(g) = E[H(\eta(X))]$$

**Définition 7.**  $\Phi$  est calibrée si

$$\begin{aligned} \text{pour } \eta > \frac{1}{2}, \quad & \inf_{\alpha < 0} C_{\eta}(\alpha) > H(\eta) \\ \text{pour } \eta < \frac{1}{2}, \quad & \inf_{\alpha > 0} C_{\eta}(\alpha) > H(\eta) \end{aligned}$$

**Proposition 2.3.** Soit  $\Phi : \mathcal{R} \rightarrow \mathbb{R}$  convexe, on a :  $\Phi$  calibrée  $\Leftrightarrow \Phi$  dérivable en 0 et  $\Phi'(0) < 0$

*Démonstration.* Notons  $h : \alpha \mapsto C_{\eta}(\alpha)$  ;

Comme  $\Phi$  est convexe, h aussi :

$$\begin{aligned} h \text{ atteint son minimum sur } \mathbb{R}_+ &\Leftrightarrow h'_d(0) < 0 \\ h \text{ atteint son minimum sur } \mathbb{R}_- &\Leftrightarrow h'_g(0) > 0 \end{aligned}$$

Par ailleurs, on a :

$$\begin{aligned} h'_d(0) &= \eta\Phi'_d(0) - (1 - \eta)\Phi'_g(0) < 0 \text{ si } \eta > \frac{1}{2} \\ h'_g(0) &= \eta\Phi'_g(0) - (1 - \eta)\Phi'_d(0) > 0 \text{ si } \eta < \frac{1}{2} \end{aligned}$$

–  $\Leftarrow$  :

Comme  $\Phi$  est dérivable en 0 :  $\Phi'_d(0) = \Phi'_g(0)$ ,  
donc, comme  $\Phi'(0) < 0$  :

$$\begin{aligned} h'(0) &= \Phi'(0)(2\eta - 1) < 0 \text{ si } \eta > \frac{1}{2} \\ h'(0) &= \Phi'(0)(2\eta - 1) > 0 \text{ si } \eta < \frac{1}{2} \end{aligned}$$

Donc  $\Phi$  est calibrée.

–  $\Rightarrow$  :

Si on a  $\Phi$  calibrée, en faisant :

$$\begin{aligned} \eta \longrightarrow \frac{1}{2}^+, \text{ on a } : \frac{1}{2}\Phi'_d(0) - \frac{1}{2}\Phi'_g(0) &\leq 0 \\ \eta \longrightarrow \frac{1}{2}^-, \text{ on a } : \frac{1}{2}\Phi'_g(0) - \frac{1}{2}\Phi'_d(0) &\geq 0 \end{aligned}$$

Ainsi  $\Phi'_d(0) \leq \Phi'_g(0)$  ; et comme  $\Phi$  est convexe par hypothèse, on a  $\Phi'_d \geq \Phi'_g$  ;

D'où le résultat. □

On suppose pour la suite  $\Phi$  convexe,  $\Phi'(0) < 0$  et  $\Phi$  dérivable en 0.

**Définition 8.** On définit  $\Psi(\theta) = \Phi(0) - H(\frac{1+\theta}{2})$

Ainsi  $\Psi(\theta) = \Phi(0) - \inf_{\alpha} \{ \frac{1+\theta}{2} \Phi(\alpha) + \frac{1-\theta}{2} \Phi(-\alpha) \}$

**Proposition 2.4.**  $\Psi$  est paire,  $\Psi$  est convexe

$\Psi \geq 0$

$\Psi(0) = 0 = \Phi(0) - \inf_{\alpha} \frac{\Phi(\alpha) + \Phi(-\alpha)}{2}$

**Theorem 2.5.**

$$\Psi(\mathcal{R}(f) - \mathcal{R}(f^*)) \leq \mathcal{R}_{\Phi}(f) - \mathcal{R}_{\Phi}^*$$

*Démonstration.* Par définition :  $\Psi(\mathcal{R}(f) - \mathcal{R}(f^*)) = \Psi(E[\mathbf{1}_{\text{sign}(f(X)) \neq g^*(X)} | 2\eta(X) - 1 |])$

$\leq E[\Psi(\mathbf{1}_{\text{sign}(f(X)) \neq g^*(X)} | 2\eta(X) - 1 |)]$  (par Jensen)

$= E[\mathbf{1}_{\text{sign}(f(X)) \neq g^*(X)} \Psi(2\eta(X) - 1)]$  (par parité de  $\Psi$ )

$= E[\mathbf{1}_{\text{sign}(f(X)) \neq g^*(X)} (\Phi(0) - H(\eta(X)))]$  (par définition de  $\Psi$ )

On borne l'indicatrice par 1,  $\Phi(0)$  par  $\mathcal{R}_{\Phi}(f)$ , et on conclut avec la Proposition 2.2. □

*Exemple 3.* (1) Perte quadratique

On trouve  $H(\eta) = \inf_{\alpha} \eta \Phi(\alpha) + (1 - \eta) \Phi(-\alpha) = \inf_{\alpha} \eta(\alpha - 1)^2 + (1 - \eta)(\alpha + 1)^2$

Pour calculer l'expression de  $H$ , on optimise en  $\alpha$  : en dérivant par rapport à  $\alpha$ , on trouve,  $2\eta(\alpha - 1) + 2(1 - \eta)(\alpha + 1) = 2\alpha - 2\eta + 1$

En annulant cette expression, on trouve  $\alpha = \eta - \frac{1}{2}$

Ainsi,  $H(\eta) = 1 - (2\eta - 1)^2$ ; et  $\Psi(\theta) = \theta^2$

(2) SVM

On trouve  $H(\eta) = \inf_{\alpha} \eta \max(1 - \alpha, 0) + (1 - \eta) \max(1 + \alpha, 0)$

En optimisant, on trouve :  $H(\eta) = 2 \min(\eta, 1 - \eta)$ , et  $\Psi(\theta) = |\theta|$

(3) Perte logistique

On trouve par le même procédé :  $\Psi(\theta) \geq \frac{\theta^2}{2}$

## RÉFÉRENCES

- [1] Convex Optimization, Boyd and Vandenberghe, Cambridge University Press, 2004
- [2] Convex Analysis and Non Linear Optimization, Borwein and Lewis, Springer, 2006.