

**Apprentissage Statistique**  
**M2 Probabilités et Statistiques, Université Paris-Sud**  
**Cours 1 : Théorie de l'apprentissage statistique: de Vapnik à la**  
**localisation (1/2)**

SYLVAIN ARLOT ET FRANCIS BACH  
NOTES DE COURS INITIALEMENT PRISES PAR THOMAS PUMIR ET ELODIE  
VERNET (2012)

TABLE DES MATIÈRES

1. Théorie de l'apprentissage : généralités	1
1.1. Cadre général de la prédiction	1
1.2. Régression	3
1.3. Classification (binaire supervisée)	3
1.4. Estimateur, notion de consistance	5
1.5. Quelques règles de classification classiques	6
1.6. No free lunch theorem : on n'a rien sans rien	8
2. Minimisation du risque structurel	9
2.1. Minimisation du risque empirique	9
2.2. Analyse du risque empirique sur un modèle	10
2.3. Choix de modèles	11
Références	13

1. THÉORIE DE L'APPRENTISSAGE : GÉNÉRALITÉS

**1.1. Cadre général de la prédiction.** On dispose de  $n$  observations  $D_n = (X_i, Y_i)_{1 \leq i \leq n} \in (\mathcal{X} \times \mathcal{Y})^n$ . Ces observations sont  $n$  réalisations indépendantes d'une variable aléatoire  $(X, Y)$  de loi commune  $P$ .

Si on se donne une nouvelle réalisation  $(X_{n+1}, Y_{n+1})$  de la variable aléatoire  $(X, Y)$ , l'objectif est de prédire  $Y_{n+1}$  sachant  $X_{n+1}$  en se trompant aussi rarement que possible.

Classiquement,  $\mathcal{X} = \mathbb{R}^p$ . Chacune des coordonnées de la variable explicative  $X \in \mathcal{X}$  est alors une variable décrivant l'objet d'étude.

La variable d'intérêt  $Y \in \mathcal{Y}$  décrit une caractéristique de l'objet d'étude ; on appelle  $Y$  l'étiquette associée à  $X$ . L'ensemble  $\mathcal{Y}$  peut être discret ou continu. Dans le cas discret, si  $\mathcal{Y} = \{0, 1\}$  on parle de classification binaire, si  $\mathcal{Y} = \{0, 1, \dots, m\}$  avec  $m \in \mathbb{N}$  on parle de classification multivariée.

**Exemple 1.** Dans le cas de l'aide au diagnostic médical

- $X$  représente l'ensemble des paramètres observables (âge, taille, résultats d'exams médicaux...)
- $Y$  représente l'étiquette associée au patient.

$$\text{Par exemple : } Y = \begin{cases} 0 & \text{si le patient est sain,} \\ 1 & \text{si le patient est malade.} \end{cases}$$

Il existe plusieurs types d'apprentissage :

- Apprentissage supervisé : on a observé tous les  $Y_i$ . C'est le cadre que l'on considérera dans la suite du cours.
- Apprentissage semi-supervisé : on observe quelques  $Y_i$ .
- Apprentissage non-supervisé : on ne connaît aucun  $Y_i$ .

**Définition 1.** On appelle *prédicteur/classifieur* toute application mesurable  $t : \mathcal{X} \rightarrow \mathcal{Y}$ . L'ensemble des prédicteurs/classifieurs est noté  $\mathbb{S}$ .

Le but d'un classifieur est de fournir une étiquette  $t(X_{n+1})$  à  $X_{n+1}$ . On espère bien évidemment faire coïncider  $t(X_{n+1})$  et  $Y_{n+1}$ , c'est-à-dire qu'on cherche le meilleur classifieur. Or, pour parler de meilleur classifieur, il est nécessaire de définir une mesure de la qualité du classifieur. On mesure cette qualité à l'aide d'une « fonction de contraste ». La fonction de perte correspondante, qui est l'espérance de la fonction de contraste, mesure alors la qualité du classifieur.

**Définition 2.** On appelle *fonction de contraste* toute fonction  $\gamma$  de la forme

$$\begin{aligned} \gamma : \quad \mathbb{S} \times (\mathcal{X} \times \mathcal{Y}) &\rightarrow \mathbb{R} \\ (t, (x, y)) &\mapsto \gamma(t, (x, y)) \quad . \end{aligned}$$

L'objectif est désormais de trouver  $t \in \mathbb{S}$  tel que  $\gamma(t; (X_{n+1}, Y_{n+1}))$  est minimal « en moyenne », ce qui signifie minimiser la fonction de perte définie comme suit.

**Définition 3.** La *fonction de perte*  $P\gamma$  associée à la fonction de contraste  $\gamma$  est définie par

$$P\gamma(t) = P\gamma(t; \cdot) = \mathbb{E}_{(X,Y) \sim P} [\gamma(t, (X, Y))]$$

pour tout  $t \in \mathbb{S}$ .

On remarquera que si  $t$  est aléatoire (ce qui est le cas quand  $t$  dépend de l'échantillon  $D_n$ ),  $P\gamma(t)$  l'est aussi.

**Définition 4.** On appelle *prédicteur de Bayes* tout prédicteur  $s^*$  qui minimise la fonction de perte :

$$s^* \in \operatorname{argmin}_{t \in \mathbb{S}} P\gamma(t) \quad .$$

La valeur minimale de la perte

$$\inf_{t \in \mathbb{S}} P\gamma(t) = P\gamma(s^*)$$

est appelée *risque de Bayes*.

Sachant qu'on ne peut pas trouver un meilleur prédicteur que le prédicteur de Bayes, le but est alors de s'approcher au plus du prédicteur de Bayes au sens de minimiser la « perte relative » :

**Définition 5.** On appelle *perte relative* d'un prédicteur  $t$  pour une fonction de contraste  $\gamma$  la quantité  $\ell(s^*, t) = P\gamma(t) - P\gamma(s^*)$ .

Par définition du prédicteur de Bayes, la perte relative est toujours positive et est nulle pour  $t = s^*$ .

**1.2. Régression.** Dans le cas de la régression on considère que :  $\mathcal{Y} = \mathbb{R}$ . Ici,  $Y$  est donc continue.

On peut toujours écrire que  $Y$  et  $X$  sont reliés par la relation

$$Y = \eta(X) + \varepsilon \quad \text{avec} \quad \eta(X) = \mathbb{E}[Y|X] .$$

Ceci implique que  $\mathbb{E}[\varepsilon|X] = 0$  p.s. ;  $\eta$  est appelée fonction de regression.

**Définition 6.** On définit le *contraste des moindres carrés* par

$$\gamma(t, (x, y)) = (t(x) - y)^2 .$$

**Proposition 1.** Si  $\mathcal{Y} = \mathbb{R}$  et  $\gamma$  est le *contraste des moindres carrés*, alors, pour tout  $t \in \mathbb{S}$ ,

$$P\gamma(t) = \mathbb{E}[(t(X) - \eta(X))^2] + P\gamma(\eta) \geq P\gamma(\eta)$$

si bien que  $\eta = s^*$  est un *prédicteur de Bayes* et que la *perte relative* s'écrit

$$\ell(s^*, t) = \mathbb{E}((t(x) - \eta(X))^2) .$$

*Démonstration.* Pour tout  $t \in \mathbb{S}$ ,

$$\begin{aligned} P\gamma(t) &= \mathbb{E}[(t(X) - Y)^2] \\ &= \mathbb{E}[(t(X) - \eta(X) - \varepsilon)^2] \\ &= \mathbb{E}[(t(X) - \eta(X))^2] + \mathbb{E}[\varepsilon^2] - 2\mathbb{E}[\mathbb{E}[\varepsilon(t(X) - \eta(X))|X]] . \end{aligned}$$

Or

$$\mathbb{E}[\mathbb{E}[\varepsilon(t(X) - \eta(X))|X]] = \mathbb{E}\left[(t(X) - \eta(X)) \underbrace{\mathbb{E}[\varepsilon|X]}_{=0}\right] = 0 ,$$

ce qui prouve le premier résultat. La suite de la proposition s'en déduit directement.  $\square$

On remarque que  $\ell(s^*, t) = \|t - \eta\|_{\mathbb{L}^2(P_X)}^2$ . Minimiser la perte relative revient donc à un problème d'estimation de  $\eta$  en norme  $\mathbb{L}^2(P_X)$ .

**1.3. Classification (binaire supervisée).** Dans le cas de la classification binaire (supervisée) on a :  $\mathcal{Y} = \{0, 1\}$ .

**Exemples :**

– Reconnaissance d'un objet

$\mathcal{X}$  = ensemble de caractéristique des pixels d'une image

$$\mathcal{Y} = \begin{cases} 1 & \text{si il y a présence d'un objet particulier sur l'image (voiture...)} \\ 0 & \text{si il y a absence d'un tel objet ;} \end{cases}$$

– catégorisation de textes

$$\mathcal{X} = \text{suite des caractères d'un texte}$$

$$\mathcal{Y} = \begin{cases} 1 & \text{si le texte appartient à une catégorie donnée} \\ 0 & \text{si le texte n'appartient pas à la catégorie;} \end{cases}$$

– détection de spams

$$\mathcal{X} = \text{suite des caractères d'un mail}$$

$$\mathcal{Y} = \begin{cases} 1 & \text{si le mail est un spam} \\ 0 & \text{si le mail n'est pas un spam.} \end{cases}$$

**Exemples** de fonctions de contrastes en classification binaire :

– contraste 0–1

$$\gamma_{0-1}(t, (x, y)) = \gamma(t, (x, y)) = \mathbb{1}_{t(x) \neq y}$$

– contraste asymétrique : étant donné  $w = (w_0, w_1) \in \mathbb{R}^2$

$$\gamma_w(t, (x, y)) = w_0 \mathbb{1}_{t(x) \neq 0, y=0} + w_1 \mathbb{1}_{t(x) \neq 1, y=1}$$

Le contraste asymétrique est une généralisation du contraste 0–1. Il peut éventuellement pénaliser une erreur plus que l'autre. Par exemple, il est utile dans le cas de la détection de spam : il est plus grave de classer un e-mail « normal » en tant que spam qu'un spam en tant qu'e-mail « normal ».

**Proposition 2.** On considère le contraste 0-1,  $\gamma(t, (x, y)) = \mathbb{1}_{t(x) \neq y}$ .

(On rappelle que  $\eta(X) = \mathbb{E}[Y|X] = \mathbb{P}(Y = 1|X)$ .)

Le classifieur de Bayes est alors  $s^*(X) = \mathbb{1}_{\eta(X) \geq \frac{1}{2}}$  p.s. sauf sur  $\{\eta(X) = \frac{1}{2}\}$ .

Alors  $P\gamma(s^*) = \mathbb{E}[\eta(X) \wedge (1 - \eta(X))]$ . Et pour tout  $t \in \mathbb{S}$ ,  $\ell(s^*, t) = \mathbb{E}[|2\eta(X) - 1| \mathbb{1}_{t(X) \neq s(X)}]$

*Démonstration.*

$$P\gamma(t) = \mathbb{P}(t(X) \neq Y) = \mathbb{E}[\mathbb{P}(t(X) \neq Y|X)]$$

Si  $\eta(X) \geq \frac{1}{2}$  et si  $t(X) = 0$ ,  $\mathbb{P}(0 \neq Y|X) = \eta(X) \geq \frac{1}{2}$ .

De plus si  $\eta(X) \geq \frac{1}{2}$  et si  $t(X) = 1$ ,  $\mathbb{P}(1 \neq Y|X) = 1 - \eta(X) \leq \frac{1}{2}$ .

Ainsi si  $\eta(X) \geq \frac{1}{2}$ ,  $s^*(X) = 1$  et  $\mathbb{P}(s^*(X) \neq Y|X) = \eta(X) \wedge (1 - \eta(X))$ .

De même, si  $\eta(X) < \frac{1}{2}$ ,  $s^*(X) = 0$  et  $\mathbb{P}(s^* \neq Y|X) = \eta(X) \wedge (1 - \eta(X))$ .

On a ainsi défini l'estimateur de Bayes à un ensemble de mesure nulle près :  $s^*(X) = \mathbb{1}_{\eta(X) \geq \frac{1}{2}}$  et  $P\gamma(s^*) = \mathbb{E}[\eta(X) \wedge (1 - \eta(X))]$ .

De plus,  $\ell(s^*, t) = \mathbb{E}[\mathbb{E}[\mathbb{1}_{t(X) \neq Y} - \mathbb{1}_{s^*(X) \neq Y}|X]]$ .

Or, si  $\eta(X) \geq \frac{1}{2}$ , alors  $s^*(X) = 1$  et  $\mathbb{E}[\mathbb{1}_{t(X) \neq Y} - \mathbb{1}_{s^*(X) \neq Y}|X] = \mathbb{1}_{t(X) \neq s^*(X)}(\eta(X) - (1 - \eta(X)))$ .

Et si  $\eta(X) < \frac{1}{2}$ , alors  $s^*(X) = 0$  et  $\mathbb{E}[\mathbb{1}_{t(X) \neq Y} - \mathbb{1}_{s^*(X) \neq Y}|X] = \mathbb{1}_{t(X) \neq s^*(X)}(1 - \eta(X) - \eta(X))$ .

D'où  $\ell(s^*, t) = \mathbb{E}[|2\eta(X) - 1| \mathbb{1}_{t(X) \neq s(X)}]$ . □

**Exercice 1.** Déterminer le classifieur de Bayes,  $P\gamma(s^*)$ , et  $\ell(s^*, t)$  dans le cas du contraste asymétrique  $w_y \mathbb{1}_{t(x) \neq y}$ .

#### 1.4. Estimateur, notion de consistance. Définitions

- On appelle *estimateur*  $\hat{s}$  toute application mesurable qui à un  $n$ -échantillon associe un classifieur :

$$\hat{s} : (\mathcal{X} \times \mathcal{Y})^n \rightarrow \mathbb{S}.$$

- On appelle *algorithme d'apprentissage* (ou règle d'apprentissage)  $\hat{s}$  toute application mesurable qui pour tout  $n$ , à un  $n$ -échantillon associe un classifieur :

$$\hat{s} : \bigcup_{n \geq 1} (\mathcal{X} \times \mathcal{Y})^n \rightarrow \mathbb{S}.$$

On notera  $D_n$  un  $n$ -échantillon  $(X_i, Y_i)_{i=1..n}$ . Et pour simplifier les notations, on confondra souvent l'application  $\hat{s}$  et sa valeur en un  $n$ -échantillon en notant  $\hat{s} = \hat{s}(D_n) = \hat{s}((X_i, Y_i)_{i=1..n})$ . On remarquera que la perte  $P\gamma(\hat{s})$  est aléatoire :

$$P\gamma(\hat{s}) = \mathbb{E}[\gamma(\hat{s}, (X, Y)) | D_n] = \mathbb{E}[\gamma(\hat{s}, (X, Y)) | (X_i, Y_i)_{i=1..n}].$$

On appelle le risque l'espérance de la perte  $\mathbb{E}[P\gamma(\hat{s}(D_n))]$  et l'excès de risque l'espérance de la perte relative  $\mathbb{E}[\ell(s^*, \hat{s}(D_n))]$ .

On définit ensuite différents types de consistance.

**Définition 7.** On dit qu'il y a :

- *consistance faible* pour une loi  $P$  si le risque tend vers 0 quand la taille de l'échantillon tend vers l'infini :

$$\lim_{n \rightarrow +\infty} \mathbb{E}[\ell(s^*, \hat{s}(D_n))] = 0$$

- *consistance forte* pour une loi  $P$  si la perte relative tend vers 0  $P^{\otimes n}$  p.s. quand la taille de l'échantillon tend vers l'infini :

$$\ell(s^*, \hat{s}(D_n)) \rightarrow 0 \text{ } P^{\otimes n} \text{ p.s.}$$

- *consistance universelle faible* si il y a consistance faible pour toute loi :

$$\forall P \text{ loi sur } \mathcal{X} \times \mathcal{Y}, \lim_{n \rightarrow +\infty} \mathbb{E}_{D_n \sim P^{\otimes n}}[\ell(s^*, \hat{s}(D_n))] = 0$$

- *consistance universelle forte* si il y a consistance forte pour toute loi :

$$\forall P \text{ loi sur } \mathcal{X} \times \mathcal{Y}, \ell(s^*, \hat{s}(D_n)) \rightarrow 0 \text{ } P^{\otimes n} \text{ p.s.}$$

- *consistance universelle faible uniforme* si le risque converge uniformément en les lois de probabilité vers 0 :

$$\sup_{P \text{ loi sur } \mathcal{X} \times \mathcal{Y}} \mathbb{E}[\ell(s^*, \hat{s}(D_n))] \rightarrow 0.$$

On remarquera que la consistance universelle faible uniforme implique la consistance universelle faible. De plus, la consistance universelle faible implique la consistance faible. De même, la consistance universelle forte implique la consistance forte.

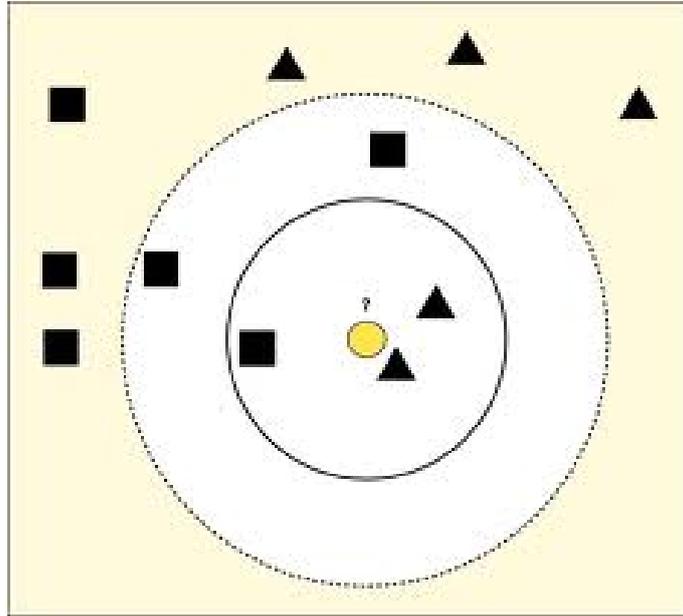


FIGURE 1. En jaune, point à classer grâce au  $k$  plus proches voisins. Pour  $k = 3$ , ce point serait classé dans la classe des triangles alors que pour  $k = 5$ , il serait classé dans la classe des carrés

### 1.5. Quelques règles de classification classiques.

- algorithme des  $k$  plus proches voisins

On travaille alors avec  $\mathcal{X} = \mathbb{R}^p$  (normée). Supposons que nous avons un  $n$ -échantillon  $(X_i, Y_i)_{i=1..n}$ . Cette règle consiste à considérer les  $k$ -plus proches voisins ( $k$ -ppv) d'un point  $x$ , puis de comparer le nombre d'étiquettes 1 et 0 pour les  $Y_i$  parmi les  $k$ -plus proches voisins. On note  $\hat{\eta}(x)$  le nombre moyen de  $Y_i$  ayant l'étiquette 1 parmi les  $k$  plus proches voisins de  $x$

$$\hat{\eta}(x) = \frac{1}{k} \sum_{X_i \in \text{k-ppv de } x} Y_i.$$

S'il y a plus d'étiquettes 1, on classera  $x$  en classe 1 et sinon on le classera dans la classe 0. Ainsi

$$\hat{s} = \mathbb{1}_{\hat{\eta} \geq \frac{1}{2}}.$$

On remarquera la ressemblance de cette règle de classification avec celle de Bayes pour le contraste 0-1 ( $s^* = \mathbb{1}_{\eta \geq \frac{1}{2}}$ ). On remplace  $\eta$  par un estimateur de celui-ci :  $\hat{\eta}$  : ceci s'appelle un « plug-in ».

**Théorème 3** (Stone). Avec  $\mathbb{X} = \mathbb{R}^p$ . On suppose que  $(k_n)_n$  est une suite d'entiers naturels divergeant vers  $+\infty$  et que  $k_n/n \rightarrow 0$ .

Il y a alors consistance universelle des  $k_n$  plus proches voisins.

La règle des plus proches voisins est un exemple de règle par moyennage local.

- Classification par moyennage local

On appelle règle par moyennage local, une règle de la forme

$$\hat{s} = \mathbb{1}_{\hat{\eta} \geq \frac{1}{2}},$$

où

$$\hat{\eta}(x) = \sum_i w_i(x) Y_i$$

avec  $w_i(x)$  petit si  $x$  est loin de  $X_i$  ( $w_i(x)$  est le poids de l'étiquette  $Y_i$  dans la moyenne),  $w_i \geq 0$  et  $\sum_i w_i = 1$ .

- Par exemple avec  $w_i(x) = \begin{cases} \frac{1}{k} & \text{si } X_i \in \text{k-ppv de } x \\ 0 & \text{sinon} \end{cases}$ , on retrouve

la règle des  $k$ -plus proches voisins.

- un autre exemple est la règle par partition. Soit  $((A_{k,n})_{k \in \mathbb{N}})_{n \in \mathbb{N}}$  une suite de partitions de  $\mathcal{X}$  (i.e.  $\cup_{k \in \mathbb{N}} A_{k,n} = \mathcal{X}$  et  $A_{k,n} \cap A_{j,n} = \emptyset$  pour  $k \neq j$ ). On note  $A_n(x)$  l'élément de la  $n$ -ième partition contenant  $x$  et  $N_n(x) = \text{Card}\{j \in \{1, \dots, n\} : X_j \in A_n(x)\}$ . Pour  $n$  donné, on considère les poids

$$w_i(x) = \frac{\mathbb{1}_{X_i \in A_n(x)}}{N_n(x)}$$

Lorsque  $\mathbb{X} = \mathbb{R}^p$ , cette règle est universellement consistante si  $\text{diam}(A_n(X)) \rightarrow 0$  et  $N_n(X) \rightarrow +\infty$  en probabilité lorsque  $n \rightarrow +\infty$ .

- pour la règle par noyaux (ou règle de Nadaraya-Watson), associée à un noyau  $K : \mathcal{X} \mapsto [0; +\infty[$  et une fenêtre  $h > 0$ , les poids sont

$$w_i(x) = \frac{K\left(\frac{x-X_i}{h}\right)}{\sum_{j=1}^n K\left(\frac{x-X_j}{h}\right)}$$

- Une autre règle de classification consiste à minimiser le risque empirique.

### Définitions

- On note  $P_n$  la mesure empirique associée à l'échantillon  $D_n$  :

$$P_n = \frac{1}{n} \sum_{i=1}^n \delta_{(X_i, Y_i)}$$

- Le risque empirique est l'application :

$$P_n \gamma(t) : \begin{cases} \mathbb{S} & \rightarrow \mathbb{R} \\ t & \mapsto P_n \gamma(t) = P_n(\gamma(t, \cdot)) = \frac{1}{n} \sum_{i=1}^n \gamma(t, (X_i, Y_i)) \end{cases}$$

Soit  $S \subset \mathbb{S}$  un sous ensemble de prédicteurs, on appelle  $S$  un modèle. On appelle le minimiseur du risque empirique  $s_S^*$  (ERM : Empirical Risk Minimizer) sur le modèle  $S$ , l'estimateur qui minimise le risque empirique sur  $S$  :

$$s_S^* \in \text{argmin}_{t \in S} P_n \gamma(t)$$

**1.6. No free lunch theorem : on n'a rien sans rien.** Le théorème suivant montre que dans le cas de la classification il n'est pas possible d'avoir une consistance universelle faible uniforme pour le contraste 0-1 sur l'ensemble des lois sur  $\mathcal{X} \times \mathcal{Y}$  lorsque  $\mathcal{X}$  est infini.

**Théorème 4.** *Si  $\mathcal{X}$  est infini,  $\mathcal{Y} = \{0, 1\}$ ,  $\gamma = \gamma_{0-1}$ , alors pour tout entier  $n \in \mathbb{N}$  et pour tout estimateur  $\widehat{s} : (\mathcal{X}, \mathcal{Y})^n \rightarrow \mathbb{S}$*

$$\sup_{P \text{ loi sur } \mathcal{X} \times \mathcal{Y}} \{ \mathbb{E}_{D_n \sim P^{\otimes n}} [\ell(s^*, \widehat{s}(D_n))] \} \geq \frac{1}{2} .$$

*Démonstration.* Soit un entier  $K \geq 1$  et  $A_1, \dots, A_K \in \mathcal{X}$ . Pour simplifier, on suppose  $A_i = i$  pour tout  $i$ .

Soit  $r \in \{0, 1\}^K$  fixé. On définit une loi  $P_r$  sur  $\mathcal{X} \times \mathcal{Y}$  comme suit :  $(X, Y) \sim P_r$  si et seulement si  $X$  suit une loi uniforme sur l'ensemble  $\{1, \dots, K\}$  et  $Y = r_X$  est une fonction de  $X$  uniquement. Ainsi, sous la loi  $P_r$ ,  $s^*(X) = s_r^*(X) = r_X$  et  $P_r \gamma(s_r^*) = 0$ .

On écrit alors que

$$\begin{aligned} & \sup_{P \text{ loi sur } \mathcal{X} \times \mathcal{Y}} \{ \mathbb{E}_{D_n \sim P^{\otimes n}} [\ell(s^*, \widehat{s}(D_n))] \} \\ & \geq \sup_{r \in \{0, 1\}^K} \left\{ \mathbb{E}_{D_n \sim P_r^{\otimes n}} [\ell_r(s_r^*, \widehat{s}(D_n))] \right\} \\ & = \sup_{r \in \{0, 1\}^K} \left\{ \mathbb{P}_{D_n \sim P_r^{\otimes n}, (X, Y) \sim P_r} (\widehat{s}(D_n; X) \neq Y) \right\} \\ & \geq \mathbb{P}_{r \sim R, D_n \sim P_r^{\otimes n}, (X, Y) \sim P_r} (\widehat{s}(D_n; X) \neq Y) \end{aligned}$$

où  $R$  est une loi quelconque sur  $\{0, 1\}^K$ . Réécrivons la dernière probabilité écrite afin de pouvoir échanger l'ordre d'intégration (c'est-à-dire, prendre d'abord une moyenne vis-à-vis de  $r$ , et ensuite moyenner par rapport aux  $X_i$  et à  $X$  :

$$\begin{aligned} & \mathbb{P}_{r \sim R, D_n \sim P_r^{\otimes n}, (X, Y) \sim P_r} (\widehat{s}(D_n; X) \neq Y) \\ & = \mathbb{P}_{r \sim R, X_1, \dots, X_n, X \sim \mathcal{U}(\{1, \dots, K\})} (\widehat{s}((X_i, r_{X_i})_{1 \leq i \leq n}; X) \neq r_X) \\ & = \mathbb{E}_{X_1, \dots, X_n, X \sim \mathcal{U}(\{1, \dots, K\})} [\mathbb{P}_{r \sim R} (\widehat{s}((X_i, r_{X_i})_{1 \leq i \leq n}; X) \neq r_X | X_1, \dots, X_n, X)] \end{aligned}$$

On s'intéresse désormais à la probabilité sachant  $X_1, \dots, X_n, X$  écrite ci-dessus. Il s'agit de la probabilité que l'on ait une certaine fonction de  $(X, X_1, \dots, X_n, r_{X_1}, \dots, r_{X_n})$  égale à  $r_X$ . On souhaite choisir  $R$  telle que cette probabilité est plutôt grande.

Une idée naturelle est de prendre  $r_1, \dots, r_K$  indépendantes et de même loi  $\mathcal{B}(\frac{1}{2})$ ; on suppose désormais que  $R$  est définie de la sorte. Ainsi, lorsque  $X \notin \{X_1, \dots, X_n\}$  (ce qui se produit souvent lorsque  $K \gg n$ ),  $\widehat{s}((X_i, r_{X_i})_{1 \leq i \leq n}; X)$  est indépendante de  $r_X$ . On en déduit que

$$\mathbb{P}_{r \sim R} (\widehat{s}((X_i, r_{X_i})_{1 \leq i \leq n}; X) \neq r_X | X_1, \dots, X_n, X) \geq \frac{1}{2} \mathbb{1}_{X \notin \{X_1, \dots, X_n\}}$$

et donc

$$\begin{aligned}
& \mathbb{P}_{r \sim R, D_n \sim P_r^{\otimes n}, (X, Y) \sim P_r}(\widehat{s}(D_n; X) \neq Y) \\
& \geq \frac{1}{2} \mathbb{P}(X \notin \{X_1, \dots, X_n\}) \\
& = \frac{1}{2} \mathbb{E}[\mathbb{P}(X_1 \neq X, \dots, X_n \neq X) | X] \\
& = \frac{1}{2} \mathbb{E}[\mathbb{P}(X_1 \neq X | X) \times \dots \times \mathbb{P}(X_n \neq X | X)] \\
& = \frac{1}{2} \left(1 - \frac{1}{K}\right)^n.
\end{aligned}$$

Récapitulons : on a démontré que pour tout  $K \geq 1$ ,

$$\sup_{P \text{ loi sur } \mathcal{X} \times \mathcal{Y}} \{\mathbb{E}_{D_n \sim P^{\otimes n}}[\ell(s^*, \widehat{s}(D_n))]\} \geq \frac{1}{2} \left(1 - \frac{1}{K}\right)^n.$$

En faisant tendre  $K$  vers  $+\infty$ , on obtient la minoration cherchée.  $\square$

Le théorème se prouve grâce à la construction d'une loi de probabilité pathologique qui rend la classification difficile. Et pour cette loi, on ne peut pas faire mieux que prédire l'étiquette  $Y$  au hasard.

Ceci suggère qu'à la place de chercher à obtenir la consistance universelle uniforme, c'est-à-dire un résultat en pire cas sur l'ensemble des lois  $P$  possibles, il faut plutôt étudier des ensembles de lois  $P$  plus petits (mais « réalistes »), pour lesquels il est possible d'obtenir des *vitesse d'apprentissage* uniformes.

**Exercice 2.** On considère le contraste 0-1  $\gamma(t; (x, y)) = \mathbb{1}_{t(x) \neq y}$  en classification binaire supervisée, et l'on suppose que  $\mathcal{X}$  est fini. On définit la règle de majorité suivante : pour tout  $n \in \mathbb{N}$ ,  $n \geq 1$ , pour tout  $x \in \mathcal{X}$ ,

$$\widehat{s}^{\text{maj}}(x; D_n) := \begin{cases} 1 & \text{si } \text{Card}\{i \text{ t.q. } X_i = x \text{ et } Y_i = 1\} > \text{Card}\{i \text{ t.q. } X_i = x \text{ et } Y_i = 0\} \\ 0 & \text{sinon.} \end{cases}$$

Alors, montrer que  $\widehat{s}^{\text{maj}}$  est uniformément universellement consistante.

Indication : utiliser l'inégalité de Hoeffding :

**Théorème 5.** Soient  $\xi_1, \dots, \xi_n$  des variables aléatoires indépendantes telles que pour tout  $i$ ,  $a_i \leq \xi_i \leq b_i$  p.s. pour des réels  $a_1, \dots, a_n$  et  $b_1, \dots, b_n$ . Alors,

$$\mathbb{P}\left(\sum_{i=1}^n \xi_i - \sum_{i=1}^n \mathbb{E}[\xi_i] \geq \varepsilon\right) \leq \exp\left(-\frac{2\varepsilon^2}{\sum_{i=1}^n (b_i - a_i)^2}\right). \quad (1)$$

## 2. MINIMISATION DU RISQUE STRUCTUREL

Références pour cette section : [3], [1, Chapitre 4], et éventuellement le premier cours de [2].

**2.1. Minimisation du risque empirique.** On rappelle (voir la section 1.5) que le risque empirique est défini par :

$$P_n \gamma(t) = \frac{1}{n} \sum_{i=1}^n \gamma(t, (x_i, y_i))$$

On a alors  $\mathbb{E}(P_n \gamma(t)) = P\gamma(t)$ , c'est-à-dire que le risque empirique estime la perte sans biais pour tout  $t \in \mathbb{S}$  fixé.

On peut alors estimer l'estimateur de Bayes en minimisant le risque empirique sur un modèle  $S \subset \mathbb{S}$ , cet estimateur est appelé l'ERM (Empirical Risk Minimizer) :

$$\hat{s}_S(D_n) \in \operatorname{argmin}_{t \in S} \{P_n \gamma(t)\}$$

**2.2. Analyse du risque empirique sur un modèle.** On remarque la minoration de la perte relative suivante :

$$\ell(s^*, \hat{s}_S) \geq \inf_{t \in S} \ell(s^*, t).$$

On appelle cette borne inférieure l'erreur d'approximation de  $S$  et on la note :

$$\ell(s^*, S) = \inf_{t \in S} \ell(s^*, t).$$

On suppose dans la suite que l'infimum est atteint, on note  $s_S^*$  un prédicteur réalisant cet infimum  $s_S^* \in \operatorname{argmin}_{t \in S} \{\ell(s^*, t)\}$ .

On peut alors décomposer la perte relative sous la forme suivante :

$$\ell(s^*, s_S^*) = \ell(s^*, S) + (P\gamma(\hat{s}_S) - P\gamma(s_S^*)).$$

On appelle  $P\gamma(\hat{s}_S) - P\gamma(s_S^*)$  (ou son espérance) l'erreur d'estimation. On retrouve alors un problème ressemblant au *compromis biais-variance*. Si le modèle  $S$  est petit, alors l'erreur d'estimation est faible mais l'erreur d'approximation est grande. C'est le problème de *sous-apprentissage*. Inversement, si le modèle  $S$  est grand, l'erreur d'approximation est petite mais l'erreur d'estimation est plus grande. Ce dernier problème est le problème de *sur-apprentissage* (overfitting) : l'estimateur suit les données plus le bruit, il apprend par cœur sans généraliser.

La propriété suivante donne une majoration de l'erreur d'estimation.

**Propriété** Si  $\hat{s}_S$  est un  $\rho$  minimiseur du risque empirique, c'est-à-dire si  $(P_n \gamma(\hat{s}_S) - P_n \gamma(s_S^*)) \leq \rho$ , alors

$$P\gamma(\hat{s}_S) - P\gamma(s_S^*) \leq \rho + 2 \sup_{t \in S} |(P - P_n)\gamma(t)|$$

*Démonstration.*

$$\begin{aligned} & P\gamma(\hat{s}_S) - P\gamma(s_S^*) \\ = & \underbrace{(P - P_n)\gamma(\hat{s}_S)}_{\leq \sup_{t \in S} |(P - P_n)\gamma(t)|} + \underbrace{P_n \gamma(\hat{s}_S) - P_n \gamma(s_S^*)}_{\leq \rho} + \underbrace{(P - P_n)\gamma(s_S^*)}_{\leq \sup_{t \in S} |(P - P_n)\gamma(t)|} \\ \leq & \rho + 2 \sup_{t \in S} |(P - P_n)\gamma(t)| \end{aligned}$$

□

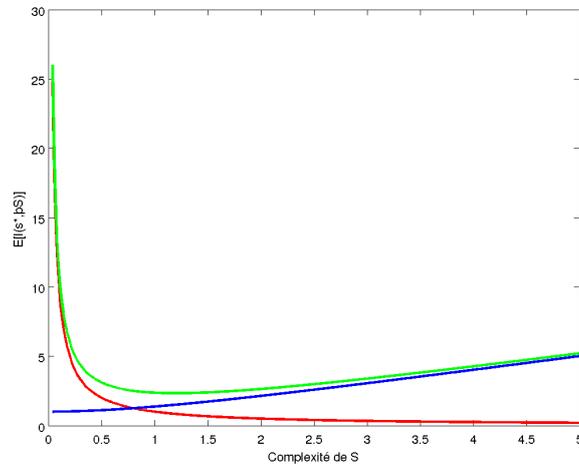


FIGURE 2. En fonction de la complexité, en rouge erreur d'approximation, en bleu erreur d'estimation, en vert somme des deux.

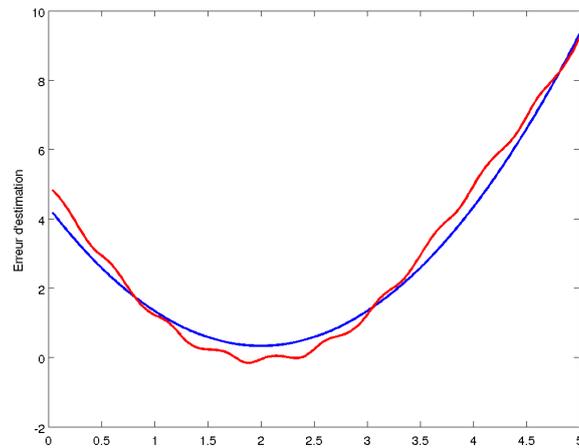


FIGURE 3. Risque en fonction de la complexité. En rouge : risque empirique, en bleu risque

D'après l'inégalité précédente et en remarquant que  $\sup_{t \in S} |(P - P_n)\gamma(t)|$  est croissant en  $S$ , il est légitime de considérer ce dernier suprémum comme une mesure de complexité de  $S$ .

**2.3. Choix de modèles.** On considère une famille de modèles  $(S_m)_{m \in \mathcal{M}}$ . On associe à chaque modèle un minimiseur du risque empirique (ERM) :  $\hat{s}_m$  pour  $m \in \mathcal{M}$ . On appelle oracle, le modèle  $m^*$  qui minimise la perte relative de l'ERM associé

$$m^* \in \arg \min_{m \in \mathcal{M}} \{ \ell(s^*, \hat{s}_m) \}.$$

Or ce modèle est inaccessible car on ne connaît pas l'estimateur de Bayes  $s^*$ . À la place, on cherche un modèle  $\widehat{m}(D_n) \in \mathcal{M}$  qui vérifie l'inégalité suivante, dite inégalité oracle, avec une grande probabilité ou en espérance :

$$\ell(s^*, \widehat{s}_{\widehat{m}}) \leq C \inf_{m \in \mathcal{M}} \{\ell(s^*, \widehat{s}_m)\} + R_n.$$

Quelques exemples de familles de modèles en régression :

– On note  $m$  une partition finie de  $\mathcal{X}$ ,

$$\begin{aligned} S_m &= \{f : \mathcal{X} \rightarrow \mathbb{R} \text{ mesurable telle que } \forall \lambda \in m, f \text{ est constante sur } \lambda \\ &= \text{ev}\{\mathbb{1}_\lambda, \lambda \in m\} \end{aligned}$$

–  $S_m = \text{ev}\{\Phi_1, \dots, \Phi_m\}$ , où  $(\Phi_k)_{k \geq 1}$  est une famille libre de  $L^2(P_X)$

–  $S_m = \{f : (x_1, \dots, x_d) \rightarrow \sum_{j \in m} \alpha_j x_j, \alpha_j \in \mathbb{R}\}$ , où  $\mathcal{X} \subset \mathbb{R}^d$ ,  $m \subset \{1, \dots, d\}$ .

En classification, un exemple de famille de modèles est  $S = \{f : \mathcal{X} \rightarrow \{0, 1\}\}$  telle que  $E_f = \{x : f(x) = 1\}$  est un demi espace de  $\mathbb{R}^d$

Le principe de la sélection de modèle à l'aide des données est de trouver  $\widehat{m}$  minimisant un critère  $\text{crit}(m)$  approximant la perte relative de l'ERM du modèle  $m$  pour tout  $m \in \mathcal{M}_n$  : c'est-à-dire, si  $\text{crit}(m) \approx \ell(s^*, \widehat{s}_m(D_n))$  pour tout  $m \in \mathcal{M}_n$ , on choisit

$$\widehat{m} \in \text{argmin}_{m \in \mathcal{M}_n} \{\text{crit}(m)\}.$$

On appelle le critère idéal, le critère suivant :  $\text{crit}_{\text{id}}(m) = P\gamma(\widehat{s}_m)$  ou  $\ell(s^*, \widehat{s}_m)$ .

Le lemme suivant donne une recette pour obtenir une égalité oracle.

**Lemme 6.** Si  $\widehat{m} \in \text{argmin}_{m \in \mathcal{M}} \{\text{crit}(m)\}$  avec

$$\forall m \in \mathcal{M}, \quad -B(m) \leq \text{crit}(m) - \text{crit}_{\text{id}}(m) \leq A(m)$$

alors

$$\ell(s^*, \widehat{s}_{\widehat{m}}) - B(\widehat{m}) \leq \inf_{m \in \mathcal{M}_n} \{\ell(s^*, \widehat{s}_m) + A(m)\}$$

*Démonstration.* Par définition de  $\widehat{m}$ ,

$$\text{crit}(\widehat{m}) \leq \text{crit}(m).$$

Ainsi,

$$\text{crit}_{\text{id}}(\widehat{s}) + (\text{crit} - \text{crit}_{\text{id}})(\widehat{s}) - P\gamma(s^*) \leq \text{crit}_{\text{id}}(m) + (\text{crit} - \text{crit}_{\text{id}})(m) - P\gamma(s^*)$$

D'où,

$$\ell(s^*, \widehat{s}_{\widehat{m}}) - B(\widehat{m}) \leq \inf_{m \in \mathcal{M}_n} \{\ell(s^*, \widehat{s}_m) + A(m)\}$$

□

Exemple : si  $\text{crit}(m) \geq \text{crit}_{\text{id}}(m)$  pour tout  $m$ , le lemme s'applique avec  $B(m) = 0$  et  $A(m) = \text{crit}(m) - \text{crit}_{\text{id}}(m)$ .

## RÉFÉRENCES

- [1] Sylvain Arlot. Classification supervisée : des algorithmes et leur calibration automatique, 2009. Notes d'un cours de troisième année à l'École Centrale Paris. <http://www.di.ens.fr/~arlot/enseign/2009Centrale/cours-classif.pdf.gz>.
- [2] Sylvain Arlot. Sélection de modèles et sélection d'estimateurs pour l'apprentissage statistique, January 2011. Cours Peccot. Collège de France. <http://www.di.ens.fr/~arlot/peccot.htm>.
- [3] Luc Devroye, László Györfi, and Gábor Lugosi. *A probabilistic theory of pattern recognition*, volume 31 of *Applications of Mathematics (New York)*. Springer-Verlag, New York, 1996.