

# BORNES INFÉRIEURES EN PRÉDICTION AVEC AVIS D'EXPERTS

Gilles STOLTZ, Université Paris-Sud

[www.math.u-psud.fr/~stoltz](http://www.math.u-psud.fr/~stoltz)

Directeur de thèse : Gábor LUGOSI, Universitat Pompeu Fabra, Barcelone

[www.econ.upf.es/~lugosi](http://www.econ.upf.es/~lugosi)

## Plan de l'exposé

1. Prédire une **suite individuelle** avec avis d'experts
2. Extension au cas où le nombre d'observations est **limité**
3. Mesure de la qualité d'une stratégie de prédiction par le **regret externe**
4. Indication de **bornes supérieures** sur le regret
5. Obtention de bornes inférieures, résolution du problème **minimax**

## Prédire une suite individuelle (1)

On se donne un ensemble (quelconque) d'observations,  $\mathcal{Y}$

On suppose que les observations  $y_1, y_2, \dots, y_n, \dots$  sont faites **séquentiellement**.

Ces observations ne sont pas la réalisation d'un quelconque processus stochastique sous-jacent (c'est-à-dire que l'on ne cherche pas à modéliser le problème). Elles sont **individualisées**.

**Notre mission** : juste avant le temps  $t$ , après avoir vu

$y_1^{t-1} = (y_1, y_2, \dots, y_{t-1})$ , prédire ce que sera  $y_t$

Notre prédiction  $I_t$  est un élément d'un ensemble  $\mathcal{X}$ , fixé.

**Exemple** : le temps qu'il fera demain,  $\mathcal{Y} = \{0, 1\}$  et  $\mathcal{X} = [0, 1]$

## Prédire une suite individuelle (2)

Pour réaliser notre tâche, nous avons accès à  $N$  **experts**, qui juste avant le temps  $t$ , nous donnent leur avis  $f_{j,t} = f_{j,t}(y_1^{t-1}) \in \mathcal{X}$ , où  $j = 1, \dots, N$

Pour prédire  $y_t$ , nous disposons donc de  $y_1^{t-1}$ , ainsi que des  $f_{j,s}$ ,  $s \leq t$

On introduit une **fonction de perte** (connue)  $\ell : \mathcal{X} \times \mathcal{Y} \rightarrow [0, 1]$

Notre perte instantanée au temps  $t$  est ainsi  $\ell(I_t, y_t)$

Les experts subissent quant à eux les pertes instantanées respectives

$$\ell(f_{j,t}, y_t)$$

## Plan de l'exposé

1. Prédire une **suite individuelle** avec avis d'experts
2. Extension au cas où le nombre d'observations est **limité**
3. Mesure de la qualité d'une stratégie de prédiction par le **regret externe**
4. Indication de **bornes supérieures** sur le regret
5. Obtention de bornes inférieures, résolution du problème **minimax**

## Nombre limité d'observations (1)

Dans le cadre précédent, au temps  $t$ , après avoir formé notre prédiction, nous avons accès à la vraie valeur  $y_t$  ; nous étions en situation dite d'**information complète**.

Imaginons cependant que voir  $y_t$  soit coûteux et que nous n'ayons qu'un **budget limité** de  $m(n)$  observations au temps  $n$

2 On détermine donc à chaque temps  $s$ , si on demande à voir l'observation ( $Z_s = 1$ ) ou non ( $Z_s = 0$ ).

On n'a ainsi accès, au temps  $t$ , qu'aux observations  $y_s$  telles que  $s \leq t - 1$  et  $Z_s = 1$ . C'est une situation d'**information incomplète**, introduite par Helmbold et Panizza, '97.

## Nombre limité d'observations (2)

**Jeu répété** entre le Statisticien et la Nature (omnisciente)

**Paramètres** : observations  $\mathcal{Y}$ , prédictions  $\mathcal{X}$ , perte  $\ell$ ,  $N$  experts, horizon  $n$ , budget de  $m$  observations

A chaque instant  $t = 1, \dots, n$ ,

- (1) la Nature choisit  $y_t \in \mathcal{Y}$  sans le révéler,
- (2) le Statisticien forme une prédiction  $I_t$  (grâce aux conseils  $f_j$  des experts et en fonctions de leurs performances passées),
- (3) les pertes  $\ell(f_{j,t}, y_t)$  et  $\ell(I_t, y_t)$  sont calculées (mais non révélées),
- (4) si moins de  $m$  observations ont été faites, le Statisticien peut demander à voir  $y_t$  (et ainsi connaître les pertes du (3)), sans quoi il reste dans l'ignorance de  $y_t$

## Plan de l'exposé

1. Prédire une **suite individuelle** avec avis d'experts
2. Extension au cas où le nombre d'observations est **limité**
3. **Mesure de la qualité d'une stratégie de prédiction par le regret externe**
4. Indication de **bornes supérieures** sur le regret
5. Obtention de bornes inférieures, résolution du problème **minimax**

## Définition du regret externe

Sauf dans le cas où  $\mathcal{X}$  et  $\ell$  sont convexes, notre prédiction  $I_t$  sera **randomisée**. A chaque temps  $t$ , il faudra donc donner la distribution de  $I_t$  en fonction des observations passées et des conseils présents, et la simulation de  $I_t$  se fera avec une randomisation auxiliaire.

Notre **perte cumulée** au temps  $n$  est

$$\hat{L}_n = \hat{L}_n(y_1^n) = \sum_{t=1}^n \ell(I_t, y_t)$$

tandis que celle du meilleur expert est  $\min_{j=1, \dots, N} L_{j,n}$ , où

$$L_{j,n} = L_{j,n}(y_1^n) = \sum_{t=1}^n \ell(f_{j,t}, y_t)$$

Nous nous intéresserons au **regret externe**,

$$\hat{R}_n = \hat{R}_n(y_1^n) = \hat{L}_n - \min_{j=1, \dots, N} L_{j,n}$$

## Plan de l'exposé

1. Prédire une **suite individuelle** avec avis d'experts
2. Extension au cas où le nombre d'observations est **limité**
3. Mesure de la qualité d'une stratégie de prédiction par le **regret externe**
4. Indication de **bornes supérieures** sur le regret
5. Obtention de bornes inférieures, résolution du problème **minimax**

## Bornes supérieures sur le regret externe (1)

Considérons l'**algorithme** suivant :

**Paramètres** : Deux nombres réels,  $\eta > 0$  et  $0 \leq \varepsilon \leq 1$

**Initialisation** :  $\mathbf{w}_1 = (1, \dots, 1)$

A chaque instant  $t = 1, 2, \dots,$

(1) choisir un expert  $J_t \in \{1, \dots, N\}$  selon la distribution

$$p_{i,t} = \frac{w_{i,t}}{\sum_{j=1}^N w_{j,t}} \quad i = 1, \dots, N,$$

et **prédire comme lui**,  $I_t = f_{J_t,t}$

(2) tirer une variable de Bernoulli  $Z_t$  de paramètre  $\varepsilon$ ,

(3) si  $Z_t = 1$ , demander l'observation  $y_t$  et calculer

$$w_{i,t+1} = w_{i,t} e^{-\eta \ell(f_{i,t}, y_t) / \varepsilon} \quad \text{pour tout } i = 1, \dots, N,$$

et sinon,  $\mathbf{w}_{t+1} = \mathbf{w}_t$

## Bornes supérieures sur le regret externe (2)

**Théorème.** Fixons  $\delta \in ]0, 1[$ . Pour un choix convenable de  $\varepsilon$  et  $\eta$  (dépendant de  $n$ ,  $m$  et  $\delta$ ), pour toute suite d'observations  $y_1, y_2, \dots, y_n$ , et avec probabilité  $1 - \delta$  par rapport à la randomisation auxiliaire, le Statisticien ne demande effectivement pas plus de  $m$  observations et

$$\hat{R}_n = \hat{L}_n - \min_{j=1, \dots, N} L_{j,n} \leq C_1 \frac{n}{\sqrt{m}} \sqrt{\ln \frac{N}{\delta}},$$

où  $C_1$  est une constante universelle.

**Remarque :** Si l'on ne s'intéresse qu'au regret moyen, on a une borne supérieure de la forme

$$\sup_{y_1^n \in \mathcal{Y}^n} \mathbb{E} \left[ \hat{L}_n - \min_{j=1, \dots, N} L_{j,n} \right] \leq C_2 \frac{n}{\sqrt{m}} \sqrt{\ln N}$$

## Plan de l'exposé

1. Prédire une **suite individuelle** avec avis d'experts
2. Extension au cas où le nombre d'observations est **limité**
3. Mesure de la qualité d'une stratégie de prédiction par le **regret externe**
4. Indication de **bornes supérieures** sur le regret
5. Obtention de bornes inférieures, résolution du problème **minimax**

## Problème minimax (1)

On va maintenant montrer que les bornes précédentes ne peuvent **pas être améliorées** en général.

Pour ce faire, nous prouverons pour tout  $N$  et tout  $\gamma \ln N \leq m \leq n$ , qu'il existe  $\mathcal{Y}$ ,  $\mathcal{X}$ ,  $\ell$  et des experts tels que

$$\inf_{\text{algo.}} \sup_{y_1^n \in \mathcal{Y}^n} \mathbb{E} \left[ \hat{L}_n - \min_{1 \leq j \leq N} L_{j,n} \right] \geq C_3 \frac{n}{\sqrt{m}} \sqrt{\ln N},$$

où  $\gamma$  et  $C_3$  sont des constantes universelles

## Problème minimax (2)

On prend par exemple  $\mathcal{X} = \{1/N, 2/N, \dots, 1\}$ ,  $\mathcal{Y} = [0, 1]$ ,  $f_{j,t} \equiv j/N$ .

On construit soigneusement  $\ell$  pour qu'il existe  $N$  probabilités  $\mathbb{P}_j$  sur

$(Y_1, Y_2, \dots, Y_n, \dots) \in \mathcal{Y}^{\mathbb{N}}$  telles que sous  $\mathbb{P}_j$ ,

- les variables  $\ell(k/N, Y_t)$  soient toutes indépendantes (quand  $k$  et  $t$  varient),
- les  $\ell(j/N, Y_t)$  suivent toutes, quelque soit  $t$ , une loi de Bernoulli de paramètre  $1/2 - \varepsilon$ ,
- les  $\ell(k/N, Y_t)$ ,  $k \neq j$ , suivent une loi de Bernoulli de paramètre  $1/2$

## Problème minimax (3)

Tout d'abord, on écrit que le cas le pire est pire que le cas moyen,

$$\sup_{y_1^n \in \mathcal{Y}^n} \mathbb{E} \left[ \hat{L}_n - \min_{j=1, \dots, N} L_{j,n} \right] \geq \max_{j=1, \dots, N} \mathbb{E}_j \left[ \mathbb{E} \left[ \hat{L}_n - L_{j,n} \right] \right]$$

Ensuite, en supposant que l'algorithme que l'on considère est déterministe, on remarque que

$$\mathbb{E}_j \hat{L}_n = \frac{n}{2} - \varepsilon \sum_{t=1}^n \mathbb{P}_j [I_t = j] \quad \text{et} \quad \mathbb{E}_j L_{j,n} = \frac{n}{2} - n\varepsilon$$

De sorte que la borne inférieure est plus grande que

$$n\varepsilon \max_{j=1, \dots, N} \left( 1 - \frac{1}{n} \sum_{t=1}^n \mathbb{P}_j [I_t = j] \right)$$

## Problème minimax (4)

Mais, par lemme de Fano généralisé,

$$\min_{j=1, \dots, N} \frac{1}{n} \sum_{t=1}^n \mathbb{P}_j [I_t = j] \leq \max \left( \frac{\bar{K}}{\ln(N-1)}, \frac{e}{e+1} \right)$$

où

$$\bar{K} = \frac{1}{n(N-1)} \sum_{i=2}^N \sum_{t=1}^n \mathcal{K} \left( \mathbb{P}_i^{I_t}, \mathbb{P}_1^{I_t} \right)$$

Nous allons montrer que  $\mathcal{K}(\mathbb{P}_i^{I_t}, \mathbb{P}_1^{I_t}) \leq 5 m \varepsilon^2$  et la preuve sera conclue, puisque la borne inférieure sera au moins

$$n \varepsilon \left( 1 - \max \left( \frac{e}{e+1}, \frac{5 m \varepsilon^2}{\ln N} \right) \right)$$

et que le choix  $\varepsilon \sim \sqrt{(\ln N)/m}$  convient

## Problème minimax (5)

Soient  $1 \leq T_1 < T_2 \dots < T_m \leq n$  les temps où l'on demande à voir les observations : ces temps  $T_j = T_j(Y_1^n)$  sont aléatoires. Soit  $K_t = \max\{k \mid T_k \leq t - 1\}$

Au temps  $t$ ,  $I_t$  est fonction de  $Y_{T_1}, Y_{T_2}, \dots, Y_{T_{K_t}}$ , c'est-à-dire de  $Z = (Y_{T_1}, Y_{T_2}, \dots, Y_{T_m})$ , puisque  $K_t$  lui-même est fonction de  $Z$

Ainsi,  $\mathcal{K}(\mathbb{P}_i^{I_t}, \mathbb{P}_1^{I_t}) \leq \mathcal{K}(\mathbb{P}_i^Z, \mathbb{P}_1^Z)$  pour tout  $t$

Mais on prouve que  $Z$  est formé de  $m$  composantes indépendantes, de loi commune sous  $\mathbb{P}_j$  un  $N$ -vecteur de variables de Bernoulli, de paramètres  $1/2$  pour toutes les composantes, sauf la  $j$ -ième, de paramètre  $1/2 - \varepsilon$

Un calcul explicite montre alors que  $\mathcal{K}(\mathbb{P}_i^Z, \mathbb{P}_1^Z) \leq 5 m \varepsilon^2$  pour  $\varepsilon \leq 1/10$