

Prédiction de suites individuelles et cadre statistique classique

Étude de quelques liens autour de la régression parcimonieuse et des techniques d'agrégation

Sébastien Gerchinovitz

Thèse soutenue le 12 décembre 2011 à l'École normale supérieure devant le jury :

M. Pierre	ALQUIER	Examineur
M. Olivier	CATONI	Examineur
M. Arnak	DALALYAN	Rapporteur
M. Pascal	MASSART	Examineur
M. Gilles	STOLTZ	Directeur
M. Alexandre	TSYBAKOV	Examineur

Introduction

Dans cette thèse, on s'est intéressé à deux types de problèmes d'apprentissage, tous deux du domaine de la prévision.

① Prévision de suites déterministes arbitraires

Problèmes d'apprentissage séquentiel où l'on ne peut pas faire d'hypothèse stochastique sur la suite $(y_t)_{t \geq 1}$ des données à prévoir.

Cela conduit à des algorithmes de prévision très robustes.


② Cadre statistique classique

Les données $(Y_t)_{t \geq 1}$ sont modélisées de façon stochastique.

Ces deux cadres entretiennent des **liens étroits**.

Chapitres traités

Nous avons abordé plusieurs problèmes voisins, dont trois dans le domaine de la **régression**.



Nous présenterons essentiellement les résultats des chapitres 3 et 4 :

- cadre principal : suites individuelles ;
- liens avec le cadre statistique classique.

- 1 Régression linéaire séquentielle
 - Brefs rappels statistiques
 - Cadre séquentiel déterministe
 - Exemple d'algorithme séquentiel

- 2 Régression linéaire séquentielle parcimonieuse
 - Grande dimension : même problème qu'en statistique
 - Algorithme séquentiel et bornes associées

- 3 Régression linéaire séquentielle sur des boules ℓ^1
 - Cadre et objectif de prévision
 - Vitesse minimax
 - Adaptativité en les paramètres du problème

- 4 Autres liens avec le cadre statistique
 - Agrégation de modèles non linéaires
 - Vitesse minimax des regrets interne et swap

Brefs rappels statistiques

Considérons le modèle de régression linéaire gaussienne avec *design* fixe : le statisticien observe $(X_1, Y_1), \dots, (X_T, Y_T) \in \mathbb{R}^d \times \mathbb{R}$ tels que

$$Y_t = \sum_{j=1}^d u_j^* X_{t,j} + \varepsilon_t, \quad 1 \leq t \leq T,$$

où les vecteurs $X_1, \dots, X_T \in \mathbb{R}^d$ sont déterministes et où $\varepsilon_t \stackrel{\text{i.i.d.}}{\sim} \mathcal{N}(0, \sigma^2)$.

- Le vecteur $\mathbf{u}^* \in \mathbb{R}^d$ est inconnu.
- Le statisticien a seulement accès à $(X_1, Y_1), \dots, (X_T, Y_T)$.

Exemples d'objectifs du statisticien :

- estimation : estimer $\mathbf{u}^* \in \mathbb{R}^d$;
- prévision/débruitage : estimer $(\sum_{j=1}^d u_j^* X_{t,j})_{1 \leq t \leq T}$.

Erreur quadratique moyenne

Objectif : estimer $(\sum_{j=1}^d u_j^* X_{t,j})_{1 \leq t \leq T} \in \mathbb{R}^T$, i.e., construire $\hat{\mathbf{u}} \in \mathbb{R}^d$ de petite **erreur quadratique moyenne** (EQM)

$$R(\hat{\mathbf{u}}) \triangleq \frac{1}{T} \sum_{t=1}^T \left(\sum_{j=1}^d u_j^* X_{t,j} - \sum_{j=1}^d \hat{u}_j X_{t,j} \right)^2 .$$

Un estimateur classique est l'estimateur des moindres carrés :

$$\hat{\mathbf{u}} \in \operatorname{argmin}_{\mathbf{u} \in \mathbb{R}^d} \frac{1}{T} \sum_{t=1}^T \left(Y_t - \sum_{j=1}^d u_j X_{t,j} \right)^2 .$$

L'EQM de cet estimateur vérifie $\mathbb{E}[R(\hat{\mathbf{u}})] \leq d\sigma^2/T$. Cette erreur est faible en petite dimension $d \ll T$.

Grande dimension et parcimonie

$\mathbb{E}[R(\hat{\mathbf{u}})] \leq d\sigma^2/T$: erreur faible en petite dimension $d \ll T$.

En grande dimension $d > T$:

- si la matrice de *design* $(X_{t,j})_{t,j} \in \mathbb{R}^{T \times d}$ est de rang maximal, $\mathbb{E}[R(\hat{\mathbf{u}})] = \sigma^2$ (sur-apprentissage) ;
- la tâche de prévision est néanmoins possible sous des hypothèses de parcimonie.

Hypothèse de parcimonie : on suppose \mathbf{u}^* parcimonieux, i.e.,

$$\|\mathbf{u}^*\|_0 \triangleq |\{j : u_j^* \neq 0\}| = s \ll T .$$

Si on connaissait le support $J^* \triangleq \{j : u_j^* \neq 0\}$ de \mathbf{u}^* , on pourrait appliquer l'estimateur des moindres carrés relativement à

$$\{\mathbf{u} \in \mathbb{R}^d, \forall j \notin J^*, u_j = 0\} .$$

Pour cet estimateur idéal, l'EQM serait au plus de l'ordre de $s/T \ll 1$.

Moindres carrés régularisés

En pratique, le support de \mathbf{u}^* est inconnu, mais on peut imiter l'estimateur précédent en **régularisant** les moindres carrés :

$$\hat{\mathbf{u}} \in \operatorname{argmin}_{\mathbf{u} \in \mathbb{R}^d} \left\{ \frac{1}{T} \sum_{t=1}^T \left(Y_t - \sum_{j=1}^d u_j X_{t,j} \right)^2 + \operatorname{reg}(\mathbf{u}) \right\} .$$

$\operatorname{reg}(\mathbf{u})$	$\mathbb{E}[R(\hat{\mathbf{u}})]$	Hypothèses sur $(X_{\bullet,j})_j$	Coût algorithmique
$\ \mathbf{u}\ _0$	$\frac{s \ln(d/s)}{T}$	aucune	combinatoire
$\ \mathbf{u}\ _1$	$\frac{s \ln d}{T}$	$X_{\bullet,j}$ presque orthogonaux	minimisation convexe

Algos : régularisation ℓ^0 [BM01, BTW07], régularisation ℓ^1 [CT07, vdG08, BRT09], pondération exponentielle [DT08, AL11, RT11].

Remarque : extensions possibles du cadre

Plusieurs extensions sont souvent considérées dans la littérature.

- 1 On a postulé une relation linéaire entre X_t et Y_t . De façon équivalente, on pourrait considérer le modèle

$$Y_t = \sum_{j=1}^d u_j^* \varphi_j(X_t) + \varepsilon_t, \quad 1 \leq t \leq T,$$

où le dictionnaire $(\varphi_1, \dots, \varphi_d)$ est constitué de fonctions **non linéaires** $\varphi_j : \mathbb{R}^d \rightarrow \mathbb{R}$ (éléments d'une base de fonctions par ex.).

- 2 Si ce modèle linéaire n'est pas vérifié, on peut considérer le modèle

$$Y_t = f(X_t) + \varepsilon_t, \quad 1 \leq t \leq T,$$

où la fonction de régression $f : \mathbb{R}^d \rightarrow \mathbb{R}$ est inconnue.

On peut chercher à estimer f par la meilleure comb. linéaire des φ_j . Dans ce cas, $\mathbb{E}[R(\hat{\mathbf{u}})] \lesssim$ **erreur d'approximation** + $\sigma^2 s \ln(d)/T$.

Cadre séquentiel déterministe

1 Cadre déterministe

- On supprime les hypothèses de modélisation stochastique : auparavant, la suite $(Y_t)_{t \geq 1}$ était stochastique.
- Maintenant, la suite $(y_t)_{t \geq 1}$ est **déterministe arbitraire** et on cherche des garanties déterministes. Cela conduit à des algorithmes de prévision très robustes.

- 2 **On ajoute une contrainte séquentielle** : les données y_t sont observées séquentiellement.

Agrégation de prévisions : à chaque date t , le statisticien dispose d'un vecteur de prévisions élémentaires $\mathbf{x}_t = (x_{t,j})_{1 \leq j \leq d} \in \mathbb{R}^d$ qu'il peut combiner pour prévoir l'observation $y_t \in \mathbb{R}$.

Quelques références historiques : [Fos91, CBLW96, KW97, AW01, Vov01].

Protocole et objectif de prévision

A chaque date $t \in \mathbb{N}^*$,

- 1 L'environnement révèle le vecteur de prévisions élémentaires $\mathbf{x}_t \in \mathbb{R}^d$.
- 2 Le statisticien formule sa prévision $\hat{y}_t \in \mathbb{R}$ à l'aide des prévisions élémentaires $x_{t,j}$ et des données passées (\mathbf{x}_s, y_s) , $1 \leq s \leq t-1$.
- 3 L'environnement révèle l'observation $y_t \in \mathbb{R}$ et le statisticien encourt la perte carrée $(y_t - \hat{y}_t)^2$.

Objectif : sur le **long terme**, prévoir presque aussi bien que le meilleur prédicteur linéaire $\mathbf{x} \mapsto \mathbf{u} \cdot \mathbf{x} \triangleq \sum_{j=1}^d u_j x_j$, $\mathbf{u} \in \mathbb{R}^d$, i.e., vérifier

$$\sum_{t=1}^T (y_t - \hat{y}_t)^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \underbrace{\sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2}_{\text{erreur d'approx.}} + \underbrace{\Delta_{T,d}(\mathbf{u})}_{\text{erreur d'estim. seq.}} \right\},$$

où le terme de **regret** $\Delta_{T,d}(\mathbf{u})$ est petit (sous-linéaire en T).

Protocole et objectif de prévision

A chaque date $t \in \mathbb{N}^*$,

- 1 L'environnement révèle le vecteur de prévisions élémentaires $\mathbf{x}_t \in \mathbb{R}^d$.
- 2 Le statisticien formule sa prévision $\hat{y}_t \in \mathbb{R}$ à l'aide des prévisions élémentaires $x_{t,j}$ et des données passées (\mathbf{x}_s, y_s) , $1 \leq s \leq t-1$.
- 3 L'environnement révèle l'observation $y_t \in \mathbb{R}$ et le statisticien encourt la perte carrée $(y_t - \hat{y}_t)^2$.

Objectif : sur le **long terme**, prévoir presque aussi bien que le meilleur prédicteur linéaire $\mathbf{x} \mapsto \mathbf{u} \cdot \mathbf{x} \triangleq \sum_{j=1}^d u_j x_j$, $\mathbf{u} \in \mathbb{R}^d$, i.e., vérifier

$$\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \underbrace{\frac{1}{T} \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2}_{\text{erreur d'approx.}} + \underbrace{\frac{\Delta_{T,d}(\mathbf{u})}{T}}_{\text{erreur d'estim. séq.}} \right\},$$

où le terme de **regret** $\Delta_{T,d}(\mathbf{u})$ est petit (sous-linéaire en T).

Exemple : l'algorithme *ridge* séquentiel

L'algorithme *ridge*, initialement étudié par [HK70] en statistique, a été étendu au cadre déterministe séquentiel par [AW01] et [Vov01].

Pour un paramètre $\lambda > 0$, l'algorithme *ridge séquentiel* produit à l'instant t la prévision $\hat{y}_t = \hat{\mathbf{u}}_t \cdot \mathbf{x}_t$, où

$$\hat{\mathbf{u}}_t \in \operatorname{argmin}_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{s=1}^{t-1} (y_s - \mathbf{u} \cdot \mathbf{x}_s)^2 + \lambda \|\mathbf{u}\|_2^2 + (\mathbf{u} \cdot \mathbf{x}_t)^2 \right\}.$$


Cet algorithme vérifie, pour toute suite $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_T, y_T) \in \mathbb{R}^d \times \mathbb{R}$,

$$\sum_{t=1}^T (y_t - \hat{y}_t)^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2 + \lambda \|\mathbf{u}\|_2^2 + d C_y \ln T \right\} + \dots$$

La vitesse $d \ln T$ correspond à la vitesse paramétrique d/T dans le cadre statistique.

Liens entre les cadres statistique et déterministe

Protocoles de prévision et hypothèses associées radicalement différents, mais **liens étroits** entre les cadres statistique et déterministe.



On illustre ces liens pour la régression parcimonieuse et la régression sur des boules ℓ^1 .

- 1 Régression linéaire séquentielle
 - Brefs rappels statistiques
 - Cadre séquentiel déterministe
 - Exemple d'algorithme séquentiel
- 2 Régression linéaire séquentielle parcimonieuse
 - Grande dimension : même problème qu'en statistique
 - Algorithme séquentiel et bornes associées
- 3 Régression linéaire séquentielle sur des boules ℓ^1
 - Cadre et objectif de prévision
 - Vitesse minimax
 - Adaptativité en les paramètres du problème
- 4 Autres liens avec le cadre statistique
 - Agrégation de modèles non linéaires
 - Vitesse minimax des regrets interne et swap

Grande dimension : même problème qu'en statistique

Rappel : l'algorithme *ridge* séquentiel encourt un regret au plus de l'ordre de $d \ln T$. Ce regret est sous-linéaire en T quand $d \ll T$.

En **grande dimension** $d > T$, on peut toujours espérer atteindre un regret sous-linéaire s'il existe $\mathbf{u}^* \in \mathbb{R}^d$ **parcimonieux** et de petite perte cumulée.

En effet, en utilisant l'algorithme *ridge* séquentiel non pas sur \mathbb{R}^d , mais sur l'e.v. engendré par le support J^* inconnu de \mathbf{u}^* , i.e.,

$$\{\mathbf{u} \in \mathbb{R}^d, \forall j \notin J^*, u_j = 0\},$$

on obtiendrait un regret au plus de l'ordre de $\|\mathbf{u}^*\|_0 \ln T$. Ce regret est sous-linéaire sous l'hypothèse de parcimonie $\|\mathbf{u}^*\|_0 \ll T/(\ln T)$.

Bornes de parcimonie

Dans la suite, on montre qu'il est possible d'atteindre des bornes proportionnelles à $\|\mathbf{u}^*\|_0$ (à des facteurs log près), i.e., on prouve des bornes de la forme

$$\sum_{t=1}^T (y_t - \hat{y}_t)^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2 + (\|\mathbf{u}\|_0 + 1) g_{T,d}(\|\mathbf{u}\|_1) \right\},$$

où g croît au plus logarithmiquement en T , d et $\|\mathbf{u}\|_1 \triangleq \sum_{j=1}^d |u_j|$.
On appelle de telles bornes des **bornes de parcimonie**.

Par intégration, ces bornes déterministes impliquent des **inégalités oracle de parcimonie** dans le cadre statistique classique, approximativement de la forme

$$\mathbb{E}[R(\hat{\mathbf{u}})] \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ R(\mathbf{u}) + C \frac{\|\mathbf{u}\|_0 \ln d}{T} \right\}.$$

Algorithme SeqSEW (*Sequential Sparse Exponential Weighting*)

Paramètres: seuil B , température inverse η et paramètre d'échelle τ .

A chaque date $t \geq 1$, **l'algorithme SeqSEW $_{\tau}^{B,\eta}$** produit la prévision

$$\hat{y}_t \triangleq \int_{\mathbb{R}^d} [\mathbf{u} \cdot \mathbf{x}_t]_B p_t(d\mathbf{u}),$$

où $[z]_B = \max\{-B, \min\{B, z\}\}$ désigne une opération de seuillage, et où la probabilité p_t sur \mathbb{R}^d est définie par

$$p_t(d\mathbf{u}) \triangleq \frac{1}{W_t} \exp\left(-\eta \sum_{s=1}^{t-1} \left(y_s - [\mathbf{u} \cdot \mathbf{x}_s]_B\right)^2\right) \pi_{\tau}(d\mathbf{u})$$

pour une constante de renormalisation W_t .

La probabilité a priori π_{τ} sur \mathbb{R}^d , introduite par [DT07] dans le cadre stochastique, favorise la **parcimonie** :

$$\pi_{\tau}(d\mathbf{u}) \triangleq \prod_{j=1}^d \frac{(3/\tau) du_j}{2(1 + |u_j|/\tau)^4}.$$

L'agrégation par **pondération exponentielle** a été développée parallèlement :

- en *machine learning* depuis [LW94, Vov90] ;
- en statistique depuis [Cat99, Cat04].

Le choix d'une probabilité a priori encourageant la **parcimonie** est plus récent (cf. [JS05, See08] par ex.). Notre probabilité a priori π_τ est celle de l'algorithme SEW de [DT08, DT11] dans le cadre stochastique.

Dans ces travaux, on montre que :

- l'algorithme de [DT11] fonctionne essentiellement pour des **raisons déterministes** ;
- en le calibrant (et en le seuillant) séquentiellement, on obtient des **résultats adaptatifs** dans le cadre stochastique.

Borne de parcimonie

On suppose pour simplifier que le statisticien a accès à l'avance à deux bornes B_y et B_x :

$$y_1, \dots, y_T \in [-B_y, B_y] \quad \text{et} \quad \|\mathbf{x}_1\|_\infty, \dots, \|\mathbf{x}_T\|_\infty \leq B_x.$$

Théorème (G.)

Sous les hypothèses précédentes, l'algorithme $\text{SeqSEW}_\tau^{B, \eta}$ calibré avec $B = B_y$, $\eta = 1/(8B_y^2)$ et $\tau = 4B_y/(\sqrt{dT}B_x)$ vérifie

$$\sum_{t=1}^T (y_t - \hat{y}_t)^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2 + 32 \|\mathbf{u}\|_0 B_y^2 \ln \left(1 + \frac{\sqrt{dT} B_x \|\mathbf{u}\|_1}{4B_y \|\mathbf{u}\|_0} \right) \right\} + 16B_y^2$$

Il s'agit d'une **borne de parcimonie** comme définie précédemment.

Preuve : recourt à une borne PAC-bayésienne séquentielle [Aud09] et exploitation de la forme à queue lourde de la loi a priori π_τ [DT07].

Borne de parcimonie

On suppose pour simplifier que le statisticien a accès à l'avance à deux bornes B_y et B_x :

$$y_1, \dots, y_T \in [-B_y, B_y] \quad \text{et} \quad \|\mathbf{x}_1\|_\infty, \dots, \|\mathbf{x}_T\|_\infty \leq B_x .$$

Théorème (G.)

Sous les hypothèses précédentes, l'algorithme $\text{SeqSEW}_\tau^{B, \eta}$ calibré avec $B = B_y$, $\eta = 1/(8B_y^2)$ et $\tau = 4B_y/(\sqrt{dT}B_x)$ vérifie

$$\sum_{t=1}^T (y_t - \hat{y}_t)^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2 + 32 \|\mathbf{u}\|_0 B_y^2 \ln \left(1 + \frac{\sqrt{dT} B_x \|\mathbf{u}\|_1}{4B_y \|\mathbf{u}\|_0} \right) \right\} + 16B_y^2$$

Calibration automatique : on peut prouver une borne similaire à l'aide de paramètres B_t , η_t et τ_t calibrés uniquement en fonction des données, i.e.,

$$\max_{1 \leq s \leq t-1} |y_s| \quad \text{et} \quad \max_{1 \leq s \leq t-1} \|\mathbf{x}_s\|_\infty .$$

Borne de parcimonie

On suppose pour simplifier que le statisticien a accès à l'avance à deux bornes B_y et B_x :

$$y_1, \dots, y_T \in [-B_y, B_y] \quad \text{et} \quad \|\mathbf{x}_1\|_\infty, \dots, \|\mathbf{x}_T\|_\infty \leq B_x.$$

Théorème (G.)

Sous les hypothèses précédentes, l'algorithme $\text{SeqSEW}_\tau^{B, \eta}$ calibré avec $B = B_y$, $\eta = 1/(8B_y^2)$ et $\tau = 4B_y/(\sqrt{dT}B_x)$ vérifie

$$\begin{aligned} & \sum_{t=1}^T (y_t - \hat{y}_t)^2 \\ & \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2 + 32 \|\mathbf{u}\|_0 B_y^2 \ln \left(1 + \frac{\sqrt{dT} B_x \|\mathbf{u}\|_1}{4B_y \|\mathbf{u}\|_0} \right) \right\} + 16B_y^2 \end{aligned}$$

Raffinement : on peut remplacer le terme $\sqrt{dT}B_x$ par $\sqrt{\sum_{j=1}^d \sum_{t=1}^T x_{t,j}^2}$ (quantité connue ou inconnue), qui fait apparaître la trace de la matrice de Gram empirique, plus standard en statistique.

Application au cadre statistique classique

Cadre : modèle de régression avec *design* aléatoire. On observe un échantillon **i.i.d.** $(X_1, Y_1), \dots, (X_T, Y_T) \in \mathbb{R}^d \times \mathbb{R}$ donné par

$$Y_t = f(X_t) + \varepsilon_t, \quad 1 \leq t \leq T,$$

où $(X_t, \varepsilon_t)_t$ est i.i.d. et $\mathbb{E}[\varepsilon_t | X_t] = 0$. L'objectif est d'estimer la fonction de régression $f : \mathbb{R}^d \rightarrow \mathbb{R}$ inconnue.

Méthode : l'échantillon $(X_1, Y_1), \dots, (X_T, Y_T)$ est traité **séquentiellement** via l'algo. $\text{SeqSEW}_\tau^{\mathcal{B}_t, \eta_t}$ avec $\tau = 1/\sqrt{dT}$, qui vérifie la borne **déterministe** :

$$\sum_{t=1}^T (Y_t - \underbrace{\tilde{f}_t(X_t)}_{=\hat{y}_t})^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (Y_t - \mathbf{u} \cdot X_t)^2 + 64 \max_{1 \leq t \leq T} Y_t^2 \|\mathbf{u}\|_0 \ln(\dots) \right\} + \dots$$

où $\tilde{f}_t : \mathbb{R}^d \rightarrow \mathbb{R}$ est construit à partir de $(X_s, Y_s)_{s \leq t-1}$ selon

$$\tilde{f}_t(\mathbf{x}) \triangleq \int_{\mathbb{R}^d} [\mathbf{u} \cdot \mathbf{x}]_{\mathcal{B}_t} \rho_t(d\mathbf{u}).$$

Conversion *online-to-batch*

On emploie la conversion *online-to-batch* [Lit89, CBCG04].

Rappel : on a la borne **déterministe**

$$\sum_{t=1}^T (Y_t - \tilde{f}_t(X_t))^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (Y_t - \mathbf{u} \cdot X_t)^2 + 64 \max_{1 \leq t \leq T} Y_t^2 \|\mathbf{u}\|_0 \ln(\cdot) \right\} + \dots$$

En prenant l'espérance de la borne précédente et en appliquant l'inégalité de Jensen deux fois, on obtient, en posant $\hat{f}_T \triangleq \frac{1}{T} \sum_{t=1}^T \tilde{f}_t$,

$$\mathbb{E} \left[(Y - \hat{f}_T(X))^2 \right] \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \mathbb{E} \left[(Y - \mathbf{u} \cdot X)^2 \right] + 64 \mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right] \frac{\|\mathbf{u}\|_0}{T} \ln(\cdot) \right\} + \dots$$

où (X, Y) est une copie de (X_1, Y_1) indépendante de $(X_t, Y_t)_{t=1}^T$.

Conversion *online-to-batch*

On emploie la conversion *online-to-batch* [Lit89, CBCG04].

Rappel : on a la borne **déterministe**

$$\sum_{t=1}^T (Y_t - \tilde{f}_t(X_t))^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (Y_t - \mathbf{u} \cdot X_t)^2 + 64 \max_{1 \leq t \leq T} Y_t^2 \|\mathbf{u}\|_0 \ln(\cdot) \right\} + \dots$$

En prenant l'espérance de la borne précédente et en appliquant l'inégalité de Jensen deux fois, on obtient, en posant $\hat{f}_T \triangleq \frac{1}{T} \sum_{t=1}^T \tilde{f}_t$,

$$\mathbb{E} \left[(Y - \hat{f}_T(X))^2 \right] \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \mathbb{E} \left[(Y - \mathbf{u} \cdot X)^2 \right] + 64 \mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right] \frac{\|\mathbf{u}\|_0}{T} \ln(\cdot) \right\} + \dots$$

où (X, Y) est une copie de (X_1, Y_1) indépendante de $(X_t, Y_t)_{t=1}^T$.

Conversion *online-to-batch*

On emploie la conversion *online-to-batch* [Lit89, CBCG04].

Rappel : on a la borne **déterministe**

$$\sum_{t=1}^T (Y_t - \tilde{f}_t(X_t))^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (Y_t - \mathbf{u} \cdot X_t)^2 + 64 \max_{1 \leq t \leq T} Y_t^2 \|\mathbf{u}\|_0 \ln(\cdot) \right\} + \dots$$

En prenant l'espérance de la borne précédente et en appliquant l'inégalité de Jensen deux fois, on obtient, en posant $\hat{f}_T \triangleq \frac{1}{T} \sum_{t=1}^T \tilde{f}_t$,

$$\mathbb{E} \left[\underbrace{(f(X) - \hat{f}_T(X))^2}_{+\sigma^2} \right] \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \mathbb{E} \left[\underbrace{(f(X) - \mathbf{u} \cdot X)^2}_{+\sigma^2} \right] + 64 \mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right] \frac{\|\mathbf{u}\|_0}{T} \ln(\cdot) \right\} + \dots$$

où (X, Y) est une copie de (X_1, Y_1) indépendante de $(X_t, Y_t)_{t=1}^T$.

Adaptation en la variance inconnue du bruit

Théorème (Une inégalité oracle de parcimonie, G.)

Soit X une v.a. de même loi que X_1 et indépendante de $(X_1, Y_1, \dots, X_T, Y_T)$. Alors,

$$\begin{aligned} & \mathbb{E} \left[(f(X) - \widehat{f}_T(X))^2 \right] \\ & \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \mathbb{E} \left[(f(X) - \mathbf{u} \cdot X)^2 \right] + 64 \mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right] \frac{\|\mathbf{u}\|_0}{T} \ln \left(1 + \frac{\sqrt{dT} \|\mathbf{u}\|_1}{\|\mathbf{u}\|_0} \right) \right\} + \dots \end{aligned}$$

On peut majorer $\mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right]$ sous diverses hypothèses : par ex., si $\|f\|_\infty < +\infty$ et $\mathbb{E} \left[\exp(\lambda \varepsilon_1) \mid X_1 \right] \leq e^{\lambda^2 \sigma^2 / 2}$ pour tout $\lambda \in \mathbb{R}$, alors

$$\mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right] \leq 2 \left(\|f\|_\infty^2 + 2 \sigma^2 \ln(2eT) \right).$$

On en déduit une borne de risque similaire à [DT11, Prop.1], mais de façon adaptative : l'estimateur \widehat{f}_T n'utilise pas la connaissance de σ^2 .

Adaptation en la variance inconnue du bruit

Théorème (Une inégalité oracle de parcimonie, G.)

Soit X une v.a. de même loi que X_1 et indépendante de $(X_1, Y_1, \dots, X_T, Y_T)$. Alors,

$$\begin{aligned} & \mathbb{E} \left[(f(X) - \widehat{f}_T(X))^2 \right] \\ & \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \mathbb{E} \left[(f(X) - \mathbf{u} \cdot X)^2 \right] + 64 \mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right] \frac{\|\mathbf{u}\|_0}{T} \ln \left(1 + \frac{\sqrt{dT} \|\mathbf{u}\|_1}{\|\mathbf{u}\|_0} \right) \right\} + \dots \end{aligned}$$

On peut majorer $\mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right]$ sous diverses hypothèses : par ex., si $\|f\|_\infty < +\infty$ et $\mathbb{E} \left[\exp(\lambda \varepsilon_1) \mid X_1 \right] \leq e^{\lambda^2 \sigma^2 / 2}$ pour tout $\lambda \in \mathbb{R}$, alors

$$\mathbb{E} \left[\max_{1 \leq t \leq T} Y_t^2 \right] \leq 2 \left(\|f\|_\infty^2 + 2\sigma^2 \ln(2eT) \right).$$

On en déduit une borne de risque similaire à [DT11, Prop.1], mais de façon **adaptative** : l'estimateur \widehat{f}_T n'utilise pas la **connaissance de σ^2** .

- 1 Régression linéaire séquentielle
 - Brefs rappels statistiques
 - Cadre séquentiel déterministe
 - Exemple d'algorithme séquentiel

- 2 Régression linéaire séquentielle parcimonieuse
 - Grande dimension : même problème qu'en statistique
 - Algorithme séquentiel et bornes associées

- 3 Régression linéaire séquentielle sur des boules ℓ^1
 - Cadre et objectif de prévision
 - Vitesse minimax
 - Adaptativité en les paramètres du problème

- 4 Autres liens avec le cadre statistique
 - Agrégation de modèles non linéaires
 - Vitesse minimax des regrets interne et swap

Rappel du cadre séquentiel déterministe

Tâche de prévision : à chaque date t , prévoir l'observation $y_t \in \mathbb{R}$ à partir du vecteur de prévisions élémentaires $\mathbf{x}_t \in \mathbb{R}^d$.

Étape initiale : l'environnement choisit deux suites **déterministes arbitraires** $(y_t)_{t \geq 1}$ dans \mathbb{R} et $(\mathbf{x}_t)_{t \geq 1}$ dans \mathbb{R}^d mais le statisticien n'y a pas accès.

A chaque date $t \in \mathbb{N}^*$,

- 1 L'environnement révèle le vecteur de prévisions élémentaires $\mathbf{x}_t \in \mathbb{R}^d$.
- 2 Le statisticien formule sa prévision $\hat{y}_t \in \mathbb{R}$ à l'aide des prévisions élémentaires $x_{t,j}$ et des données passées (\mathbf{x}_s, y_s) , $1 \leq s \leq t - 1$.
- 3 L'environnement révèle l'observation $y_t \in \mathbb{R}$ et le statisticien encourt la perte carrée $(y_t - \hat{y}_t)^2$.

Objectif : comparaison à des boules ℓ^1

Objectif : prévoir presque aussi bien que le meilleur prédicteur linéaire $\mathbf{x} \mapsto \mathbf{u} \cdot \mathbf{x}$ de norme $\|\mathbf{u}\|_1 \triangleq \sum_{j=1}^d |u_j|$ bornée, i.e., minimiser le regret

$$\sum_{t=1}^T (y_t - \hat{y}_t)^2 - \min_{\|\mathbf{u}\|_1 \leq U} \left\{ \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2 \right\}$$

pour un rayon $U > 0$ et un horizon de temps $T \geq 1$ (fixés ou pas).

Remarques :

- Étend la tâche d'**agrégation convexe** (cf. [Nem00, Tsy03] en statistique).
- Une borne sur le regret précédent par $f_{T,d}(U)$ pour tout $U > 0$ (avec $f_{T,d} \nearrow$) implique une borne **régularisée** de la forme

$$\sum_{t=1}^T (y_t - \hat{y}_t)^2 \leq \inf_{\mathbf{u} \in \mathbb{R}^d} \left\{ \sum_{t=1}^T (y_t - \mathbf{u} \cdot \mathbf{x}_t)^2 + f_{T,d}(\|\mathbf{u}\|_1) \right\}.$$

De telles bornes ont été obtenues en statistique pour le Lasso [MM11].

Regret minimax

On s'intéresse à la vitesse optimale du **regret minimax** défini par

$$\inf_{(\hat{y}_t)_{t \geq 1}} \sup_{\substack{\|x_1\|_\infty, \dots, \|x_T\|_\infty \leq X \\ |y_1|, \dots, |y_T| \leq Y}} \left\{ \sum_{t=1}^T (y_t - \hat{y}_t)^2 - \min_{\|u\|_1 \leq U} \sum_{t=1}^T (y_t - u \cdot x_t)^2 \right\},$$

où le sup est pris sur toutes les suites individuelles bornées par $X > 0$ et $Y > 0$ et où l'inf est pris sur tous les prédicteurs séquentiels $(\hat{y}_t)_{t \geq 1}$.

On observe un **phénomène de transition** identique à celui observé en statistique par [BM01] en *design* fixe et par [Tsy03] en *design* aléatoire :

- sur un premier régime, le regret minimax croît en \sqrt{T} ;
- sur un second régime, le regret minimax croît en $\ln T$.

Théorème (Majoration du regret minimax, G.)

Soit $d, T \geq 1$ et $U, X, Y > 0$. Le regret minimax vérifie, en fonction de U ,

$$\inf_{(\hat{y}_t)_{t \geq 1}} \sup_{\|x_t\|_\infty \leq X, |y_t| \leq Y} \left\{ \sum_{t=1}^T (y_t - \hat{y}_t)^2 - \min_{\|u\|_1 \leq U} \sum_{t=1}^T (y_t - u \cdot x_t)^2 \right\}$$

$$\lesssim \begin{cases} UXY \sqrt{T \ln(2d)} & \text{si } U < U_1, \\ UXY \sqrt{T \ln\left(1 + \frac{2dY}{\sqrt{T}UX}\right)} & \text{si } U \in [U_1, U_2], \\ dY^2 \ln\left(1 + \frac{\sqrt{T}UX}{dY}\right) & \text{si } U > U_2, \end{cases}$$

où U_1 et U_2 dépendent de d, T, X et Y .

Commentaires :


- 1ère borne : prouvée par [KW97] pour l'algorithme EG^\pm ;
- 2ème borne : technique inspirée de la littérature statistique, i.e., **argument à la Mauray** [Nem00, Tsy03, BN08] ; cette borne améliore légèrement celle de l'algorithme EG^\pm ;
- 3ème borne : conséquence directe des bornes de parcimonie. Cette borne améliore légèrement celle induite par l'algorithme *ridge* séquentiel.

Deux régimes distincts


On peut réécrire la borne précédente en fonction de d , Y et d'une quantité intrinsèque $\kappa \triangleq \sqrt{TUX}/(2dY)$ qui relie d à $\sqrt{TUX}/(2Y)$:

$$\begin{cases} dY^2 \kappa \sqrt{\ln(2d)} & \text{si } \kappa < \kappa_{\min}(d), \\ dY^2 \kappa \sqrt{\ln(1 + 1/\kappa)} & \text{si } \kappa \in [\kappa_{\min}(d), 1], \\ dY^2 \ln(1 + 2\kappa) & \text{si } \kappa > 1. \end{cases}$$

En petite dimension $d \lesssim T$, on observe une **transition** en $\kappa = 1$:



(a) Transition si $d \lesssim T$.



(b) Pas de transition si $d \gtrsim T$.

Borne inférieure

La borne supérieure précédente

$$\begin{cases} dY^2 \kappa \sqrt{\ln(2d)} & \text{si } \kappa < \kappa_{\min}(d) , \\ dY^2 \kappa \sqrt{\ln(1 + 1/\kappa)} & \text{si } \kappa \in [\kappa_{\min}(d), 1] , \\ dY^2 \ln(1 + 2\kappa) & \text{si } \kappa > 1 . \end{cases}$$

est optimale à un facteur logarithmique près pour tous $d \geq 1$, $Y > 0$ et $\kappa \geq \kappa_{\min}(d) \approx \sqrt{\ln d}/d$.

Pour le montrer, on a exhibé une borne inférieure de la façon suivante :

- réduction au cadre stochastique (via la conversion *online-to-batch*) ;
- emploi de la borne inférieure de [Tsy03] pour l'agrégation convexe.

Borne inférieure

La borne supérieure précédente

$$\begin{cases} dY^2 \kappa \sqrt{\ln(2d)} & \text{si } \kappa < \kappa_{\min}(d) , \\ dY^2 \kappa \sqrt{\ln(1 + 1/\kappa)} & \text{si } \kappa \in [\kappa_{\min}(d), 1] , \\ dY^2 \ln(1 + 2\kappa) & \text{si } \kappa > 1 . \end{cases}$$

est optimale à un facteur logarithmique près pour tous $d \geq 1$, $Y > 0$ et $\kappa \geq \kappa_{\min}(d) \approx \sqrt{\ln d}/d$.

Pour le montrer, on a exhibé une borne inférieure de la façon suivante :

- réduction au cadre stochastique (via la conversion *online-to-batch*) ;
- emploi de la borne inférieure de [Tsy03] pour l'agrégation convexe.

Conclusion : l'agrégation sur des boules ℓ^1 est approximativement de **même complexité** dans les cadres stochastique et déterministe.

Adaptativité en les paramètres du problème

Problème : certains algorithmes étudiés précédemment sont **inefficaces** en grande dimension d et requièrent la **connaissance a priori** de X, Y, T et U .

Un exemple de cheminement

- 1 Afin de résoudre ce problème, nous avons introduit une **variante automatique** de l'**exponentielle des gradients** (algorithme EG^\pm) de [KW97], combinée à une pré-transformation lipschitzienne des pertes.

Adaptativité en les paramètres du problème

Problème : certains algorithmes étudiés précédemment sont **inefficaces** en grande dimension d et requièrent la **connaissance a priori** de X, Y, T et U .

Un exemple de cheminement

- 1 Afin de résoudre ce problème, nous avons introduit une **variante automatique** de l'**exponentielle des gradients** (algorithme EG^\pm) de [KW97], combinée à une pré-transformation lipschitzienne des pertes.

Cet algorithme est quasi-optimal dans le régime $\kappa \leq 1$ et s'adapte en X, Y et T grâce à une calibration séquentielle.

On peut s'adapter à U en agrégeant des sous-algorithmes associés à une grille $\mathcal{U}_t = \{U_r = a_t 2^r : r = 0, \dots, R_t\}$ évoluant avec t .

Adaptativité en les paramètres du problème

Problème : certains algorithmes étudiés précédemment sont **inefficaces** en grande dimension d et requièrent la **connaissance a priori** de X, Y, T et U .

Un exemple de cheminement

- 1 Afin de résoudre ce problème, nous avons introduit une **variante automatique** de l'**exponentielle des gradients** (algorithme EG^\pm) de [KW97], combinée à une pré-transformation lipschitzienne des pertes.
- 2 Comme régulièrement en recherche, nous nous sommes aperçus que le problème avait déjà été résolu ! (par [ACBG02] via un autre algo.)

Adaptativité en les paramètres du problème

Problème : certains algorithmes étudiés précédemment sont **inefficaces** en grande dimension d et requièrent la **connaissance a priori** de X, Y, T et U .

Un exemple de cheminement

- 1 Afin de résoudre ce problème, nous avons introduit une **variante automatique** de l'**exponentielle des gradients** (algorithme EG^\pm) de [KW97], combinée à une pré-transformation lipschitzienne des pertes.
- 2 Comme régulièrement en recherche, nous nous sommes aperçus que le problème avait déjà été résolu ! (par [ACBG02] via un autre algo.)
- 3 Ainsi, notre algorithme fournit une deuxième solution pour s'adapter efficacement aux paramètres du problème.

Adaptativité en les paramètres du problème

Problème : certains algorithmes étudiés précédemment sont **inefficaces** en grande dimension d et requièrent la **connaissance a priori** de X, Y, T et U .

Un exemple de cheminement

- 1 Afin de résoudre ce problème, nous avons introduit une **variante automatique** de l'**exponentielle des gradients** (algorithme EG^\pm) de [KW97], combinée à une pré-transformation lipschitzienne des pertes.
- 2 Comme régulièrement en recherche, nous nous sommes aperçus que le problème avait déjà été résolu ! (par [ACBG02] via un autre algo.)
- 3 Ainsi, notre algorithme fournit une deuxième solution pour s'adapter efficacement aux paramètres du problème.
- 4 Nous serions heureux que notre technique de pré-transformation lipschitzienne des pertes s'avère utile dans d'autres contextes !

- 1 Régression linéaire séquentielle
 - Brefs rappels statistiques
 - Cadre séquentiel déterministe
 - Exemple d'algorithme séquentiel

- 2 Régression linéaire séquentielle parcimonieuse
 - Grande dimension : même problème qu'en statistique
 - Algorithme séquentiel et bornes associées

- 3 Régression linéaire séquentielle sur des boules ℓ^1
 - Cadre et objectif de prévision
 - Vitesse minimax
 - Adaptativité en les paramètres du problème

- 4 Autres liens avec le cadre statistique
 - Agrégation de modèles non linéaires
 - Vitesse minimax des regrets interne et swap

Agrégation de modèles non linéaires

Cadre : modèle de régression gaussienne avec *design* fixe. Le statisticien observe le vecteur $(Y_1, \dots, Y_n) \in \mathbb{R}^n$ donné par

$$Y_i = s_i + \sigma \xi_i \in \mathbb{R}, \quad 1 \leq i \leq n, \quad \xi_i \stackrel{\text{i.i.d.}}{\sim} \mathcal{N}(0, 1).$$

Objectif : étant donnée une collection au plus dénombrable $(\hat{s}_m)_{m \in \mathcal{M}}$ d'estimateurs des moindres carrés associés à des **modèles non-linéaires** $S_m \subset \mathbb{R}^n$, estimer (s_1, \dots, s_n) presque aussi bien que le meilleur des \hat{s}_m .

Résultats :

- Notre estimateur mélange les \hat{s}_m par **pondération exponentielle**, de même que [LB06] dans le cas de modèles linéaires.
- Cet estimateur vérifie une inégalité de type oracle avec grande probabilité pour des modèles S_m non-linéaires.
- On utilise des arguments de concentration de [BM01, Mas07].

Regrets interne et *swap*

Nous avons étudié d'**autres formes de regret** qui jouent un rôle important en théorie des jeux. Le cadre séquentiel est celui introduit par [FS97].

A chaque date $t \in \mathbb{N}^*$,

- 1 Le statisticien choisit un vecteur de poids $\mathbf{p}_t = (p_{i,t})_{1 \leq i \leq K}$ entre K actions.
- 2 Chaque action $i = 1, \dots, K$ encourt une perte $\ell_{i,t} \in [0, 1]$ et l'environnement révèle le vecteur de pertes $\ell_t \triangleq (\ell_{i,t})_{1 \leq i \leq K}$.
- 3 Le statisticien encourt la **perte linéaire** $\mathbf{p}_t \cdot \ell_t \triangleq \sum_{i=1}^K p_{i,t} \ell_{i,t}$.

Les **regrets interne** et **swap** sont de la forme

$$\sum_{t=1}^T \mathbf{p}_t \cdot \ell_t - \min_{\varphi} \sum_{t=1}^T \varphi(\mathbf{p}_t) \cdot \ell_t ,$$

où l'infimum est pris sur un ensemble d'applications linéaires $\varphi : \mathcal{X}_K \rightarrow \mathcal{X}_K$ qui préservent le simplexe $\mathcal{X}_K \triangleq \{\mathbf{x} \in \mathbb{R}_+^K, \sum_{i=1}^K x_i = 1\}$.

Vitesse minimax des regrets interne et *swap*

Nous avons étudié les **vitesse** **minimax** des regrets interne et *swap* en environnement stochastique ou déterministe.

	environnement	regret interne	regret <i>swap</i>
bornes sup	$(\ell_t)_{1 \leq t \leq T}$ déterministe	$\sqrt{T \ln K}$	$\sqrt{TK \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.		
bornes inf	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ déterministe	\sqrt{T}	\sqrt{TK}

Bornes inf et sup prouvées par [Sto05] et [BM07].

Vitesse minimax des regrets interne et *swap*

Nous avons étudié les **vitesse** **minimax** des regrets interne et *swap* en environnement stochastique ou déterministe.

	environnement	regret interne	regret <i>swap</i>
bornes sup	$(\ell_t)_{1 \leq t \leq T}$ déterministe	$\sqrt{T \ln K}$	$\sqrt{TK \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	$\sqrt{T \ln K}$	$\sqrt{TK \ln K}$
bornes inf	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ déterministe	\sqrt{T}	\sqrt{TK}

Regret interne : **agrégation exponentielle** utile pour supprimer $\sqrt{\ln K}$.

Vitesse minimax des regrets interne et *swap*

Nous avons étudié les **vitesse** **minimax** des regrets interne et *swap* en environnement stochastique ou déterministe.

	environnement	regret interne	regret <i>swap</i>
bornes sup	$(\ell_t)_{1 \leq t \leq T}$ déterministe	$\sqrt{T \ln K}$	$\sqrt{TK \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
bornes inf	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ déterministe	\sqrt{T}	\sqrt{TK}

Regrets interne et *swap* : vitesses exactes en stochastique.

Vitesse minimax des regrets interne et *swap*

Nous avons étudié les **vitesse** **minimax** des regrets interne et *swap* en environnement stochastique ou déterministe.

	environnement	regret interne	regret <i>swap</i>
bornes sup	$(\ell_t)_{1 \leq t \leq T}$ déterministe	$\sqrt{T \ln K}$	$\sqrt{TK \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
bornes inf	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ déterministe	\sqrt{T}	\sqrt{TK}

Borne inférieure *swap* déterministe : preuve via l'**inégalité de Pinsker**.


Vitesse minimax des regrets interne et *swap*

Nous avons étudié les **vitesse** **minimax** des regrets interne et *swap* en environnement stochastique ou déterministe.

	environnement	regret interne	regret <i>swap</i>
bornes sup	$(\ell_t)_{1 \leq t \leq T}$ déterministe	$\sqrt{T \ln K}$	$\sqrt{TK \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
bornes inf	$(\ell_t)_{1 \leq t \leq T}$ i.i.d.	\sqrt{T}	$\sqrt{T \ln K}$
	$(\ell_t)_{1 \leq t \leq T}$ déterministe	\sqrt{T}	\sqrt{TK}


Problème ouvert : quid des facteurs $\sqrt{\ln K}$ en déterministe ?

Conclusion : structure de la thèse



Les liens entre ces chapitres peuvent être synthétisés comme suit.

Conclusion : structure de la thèse



Perspectives de recherche

Je souhaiterais aborder **plusieurs problèmes** au croisement des suites individuelles et du cadre statistique classique. En voici deux exemples.

- 1 Régression parcimonieuse : peut-on prouver des garanties déterministes pour une variante **séquentielle** de l'algorithme **Lasso** ?
- 2 Peut-on tisser des liens plus étroits entre les **suites individuelles** et la **sélection de modèles** en termes de ...
 - ... techniques de calibration ?
 - ... bornes ? (bornes de type oracle en suites individuelles ?)

Perspectives de recherche

Je souhaiterais aborder **plusieurs problèmes** au croisement des suites individuelles et du cadre statistique classique. En voici deux exemples.

- 1 Régression parcimonieuse : peut-on prouver des garanties déterministes pour une variante **séquentielle** de l'algorithme **Lasso** ?
- 2 Peut-on tisser des liens plus étroits entre les **suites individuelles** et la **sélection de modèles** en termes de ...
 - ... techniques de calibration ?
 - ... bornes ? (bornes de type oracle en suites individuelles ?)

Merci !



P. Auer, N. Cesa-Bianchi, and C. Gentile.
Adaptive and self-confident on-line learning algorithms.
64:48–75, 2002.



P. Alquier and K. Lounici.
PAC-Bayesian bounds for sparse regression estimation with exponential weights.
Electron. J. Stat., 5:127–145, 2011.



J.-Y. Audibert.
Fast learning rates in statistical inference through aggregation.
Ann. Statist., 37(4):1591–1646, 2009.



K. S. Azoury and M. K. Warmuth.
Relative loss bounds for on-line density estimation with the exponential family of distributions.
43(3):211–246, 2001.



L. Birgé and P. Massart.
Gaussian model selection.
J. Eur. Math. Soc., 3:203–268, 2001.



A. Blum and Y. Mansour.
From external to internal regret.
J. Mach. Learn. Res., 8:1307–1324, 2007.



F. Bunea and A. Nobel.

Sequential procedures for aggregating arbitrary estimators of a conditional mean.
IEEE Trans. Inform. Theory, 54(4):1725–1735, 2008.



P. J. Bickel, Y. Ritov, and A. B. Tsybakov.

Simultaneous analysis of Lasso and Dantzig selector.
Ann. Statist., 37(4):1705–1732, 2009.



F. Bunea, A. B. Tsybakov, and M. H. Wegkamp.

Aggregation for Gaussian regression.
Ann. Statist., 35(4):1674–1697, 2007.



O. Catoni.

Universal aggregation rules with exact bias bounds.

Technical Report PMA-510, Laboratoire de Probabilités et Modèles Aléatoires, CNRS, Paris, 1999.



O. Catoni.

Statistical learning theory and stochastic optimization.
Springer, New York, 2004.



N. Cesa-Bianchi, A. Conconi, and C. Gentile.

On the generalization ability of on-line learning algorithms.
IEEE Trans. Inform. Theory, 50(9):2050–2057, 2004.



N. Cesa-Bianchi, P.M. Long, and M.K. Warmuth.
Worst-case quadratic loss bounds for prediction using linear functions and gradient descent.
IEEE Trans. Neural Networks, 7(3):604–619, 1996.



E. Candes and T. Tao.
The Dantzig selector: statistical estimation when p is much larger than n .
Ann. Statist., 35(6):2313–2351, 2007.



A. Dalalyan and A. B. Tsybakov.
Aggregation by exponential weighting and sharp oracle inequalities.
In *Proceedings of the 20th Annual Conference on Learning Theory (COLT'07)*, pages 97–111, 2007.



A. Dalalyan and A. B. Tsybakov.
Aggregation by exponential weighting, sharp PAC-Bayesian bounds and sparsity.
72(1-2):39–61, 2008.



A. Dalalyan and A. B. Tsybakov.
Mirror averaging with sparsity priors.
Bernoulli, 2011.
To appear. Available at <http://hal.archives-ouvertes.fr/hal-00461580/>.



D. Foster.

Prediction in the worst-case.

Ann. Statist., 19:1084–1090, 1991.



S. Freund and R.E. Schapire.

A decision-theoretic generalization of on-line learning and an application to boosting.

J. Comput. System Sci., 55(1):119–139, 1997.



A. E. Hoerl and R. W. Kennard.

Ridge regression: biased estimation for nonorthogonal problems.

Technometrics, 12(1):55–67, 1970.



I. M. Johnstone and B. W. Silverman.

Empirical bayes selection of wavelet thresholds.

Ann. Statist., 33(4):1700–1752, 2005.



Jyrki Kivinen and Manfred K. Warmuth.

Exponentiated gradient versus gradient descent for linear predictors.

Inform. and Comput., 132(1):1–63, 1997.



G. Leung and A. R. Barron.

Information theory and mixing least-squares regressions.

IEEE Trans. Inform. Theory, 52(8):3396–3410, 2006.



N. Littlestone.

From on-line to batch learning.

In *Proceedings of the 2nd Annual Conference on Learning Theory (COLT'89)*, pages 269–284, 1989.



N. Littlestone and M. K. Warmuth.

The weighted majority algorithm.

Inform. and Comput., 108:212–261, 1994.



P. Massart.

Concentration Inequalities and Model Selection, volume 1896 of *Lecture Notes in Mathematics*.

Springer, Berlin, 2007.



P. Massart and C. Meynet.

The Lasso as an ℓ^1 -ball model selection procedure.

Electron. J. Stat., 5:669–687, 2011.



A. Nemirovski.

Topics in Non-Parametric Statistics.

Springer, Berlin/Heidelberg/New York, 2000.



P. Rigollet and A. B. Tsybakov.

Exponential Screening and optimal rates of sparse estimation.

Ann. Statist., 39(2):731–771, 2011.



M. W. Seeger.

Bayesian inference and optimal design for the sparse linear model.

J. Mach. Learn. Res., 9:759–813, 2008.



G. Stoltz.

Incomplete information and internal regret in prediction of individual sequences.

PhD thesis, Paris-Sud XI University, 2005.



A. B. Tsybakov.

Optimal rates of aggregation.

In *Proceedings of the 16th Annual Conference on Learning Theory (COLT'03)*, pages 303–313, 2003.



S. A. van de Geer.

High-dimensional generalized linear models and the Lasso.

Ann. Statist., 36(2):614–645, 2008.



V. Vovk.

Aggregating strategies.

In *Proceedings of the 3rd Annual Workshop on Computational Learning Theory (COLT'90)*, pages 371–383, 1990.



V. Vovk.

Competitive on-line statistics.

Internat. Statist. Rev., 69:213–248, 2001.