

# Un regret unifié pour l'optimisation convexe séquentielle

Pierre Gaillard

EDF – École Normale Supérieure

28 mai 2013

Publié dans NIPS 2012 avec N. Cesa-Bianchi, G. Lugosi et G. Stoltz.

# Introduction

Problème d'optimisation convexe séquentielle

$$\sum_{t=1}^T (\hat{\mathbf{p}}_t \cdot \mathbf{x}_t - y_t)^2 = \min_{\mathbf{q} \in \Delta_d} \left\{ \sum_{t=1}^T (\mathbf{q} \cdot \mathbf{x}_t - y_t)^2 \right\} + \text{Regret}_T$$

Linéarisation

$$\begin{aligned} \text{Regret}_T &= \sum_{t=1}^T (\hat{\mathbf{p}}_t \cdot \mathbf{x}_t - y_t)^2 - (\mathbf{q}^* \cdot \mathbf{x}_t - y_t)^2 \\ &\leq \sum_{t=1}^T \underbrace{2(\hat{\mathbf{p}}_t \cdot \mathbf{x}_t - y_t)\mathbf{x}_t}_{\mathbf{l}_t} \cdot (\hat{\mathbf{p}}_t - \mathbf{q}^*) \\ &= \sum_{t=1}^T \mathbf{l}_t \cdot (\hat{\mathbf{p}}_t - \mathbf{q}^*) \\ &\leq \sum_{t=1}^T \hat{\mathbf{p}}_t \cdot \mathbf{l}_t - \min_j \sum_{t=1}^T l_{j,t} \end{aligned}$$

Problème linéarisé

$$\sum_{t=1}^T \hat{\mathbf{p}}_t \cdot \mathbf{l}_t = \min_{i=1, \dots, d} \sum_{t=1}^T l_{i,t} + \text{Regret}'_T$$

# Cadre séquentiel linéarisé

À chaque instant  $t = 1, \dots, T$ ,

1. Nous proposons  $\hat{\mathbf{p}}_t = (\hat{p}_{1,t}, \dots, \hat{p}_{d,t}) \in \Delta_d$

2. La nature choisit un vecteur de pertes

$$\ell_t = (\ell_{1,t}, \dots, \ell_{d,t}) \in [0, 1]^d$$

3. Nous subissons alors la perte linéaire  $\hat{\ell}_t = \hat{\mathbf{p}}_t \cdot \ell_t$ .

Un exemple d'objectif consiste à minimiser notre **regret cumulée**

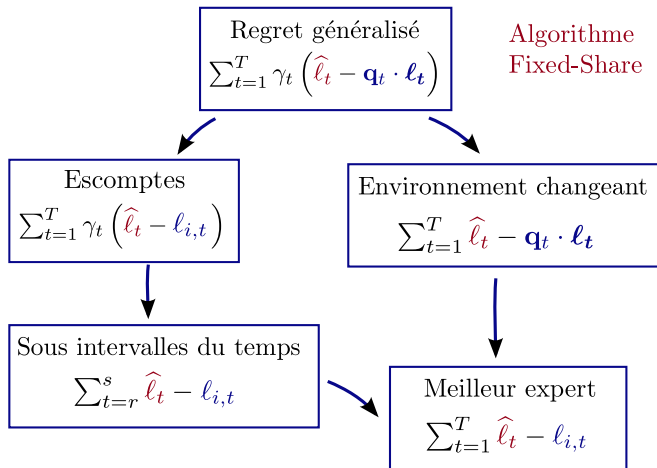
$$\mathcal{R}_T = \sum_{t=1}^T \hat{\mathbf{p}}_t \cdot \ell_t - \min_{i=1, \dots, d} \sum_{t=1}^T \ell_{i,t}$$

But de cet exposé

- **Unification** et amélioration de diverses notions de regrets
- Présenter un **algorithme** minimisant le regret général

# Les notions de regrets

À l'instant  $t$ , nous proposons les poids  $\hat{\mathbf{p}}_t \in \Delta_d$  et nous subissons la perte  $\hat{\ell}_t = \hat{\mathbf{p}}_t^\top \ell_t$ .



# La notion de regret – Environnement stationnaire

À l'instant  $t$ , nous proposons les poids  $\hat{\mathbf{p}}_t \in \Delta_d$  et nous subissons la perte  $\hat{\ell}_t = \hat{\mathbf{p}}_t^\top \ell_t$ .

Notre **perte cumulée** se décompose

$$\underbrace{\sum_{t=1}^T \hat{\ell}_t}_{\text{Notre perte}} = \underbrace{\min_{i=1, \dots, d} \sum_{t=1}^T \ell_{i,t}}_{\text{Erreur d'approximation}} + \underbrace{\mathcal{R}_T}_{\text{Erreur d'estimation}}$$

## Objectif

Avoir un regret moyen qui converge **uniformément** vers 0

$$\sup_{\ell_1, \dots, \ell_T \in [0,1]^d} \frac{\mathcal{R}_T}{T} \xrightarrow{T \rightarrow \infty} 0.$$

# Regret dans un environnement changeant

À l'instant  $t$ , nous proposons les poids  $\hat{\mathbf{p}}_t \in \Delta_d$  et nous subissons la perte  $\hat{\ell}_t = \hat{\mathbf{p}}_t^\top \ell_t$ .

Notre **perte cumulée** se décompose

$$\underbrace{\sum_{t=1}^T \hat{\ell}_t}_{\text{Notre perte}} = \underbrace{\min_{\mathbf{q}_1, \dots, \mathbf{q}_T} \sum_{t=1}^T \mathbf{q}_t \cdot \ell_t}_{\text{Erreur d'approximation}} + \underbrace{\mathcal{R}_T}_{\text{Erreur d'estimation}}$$

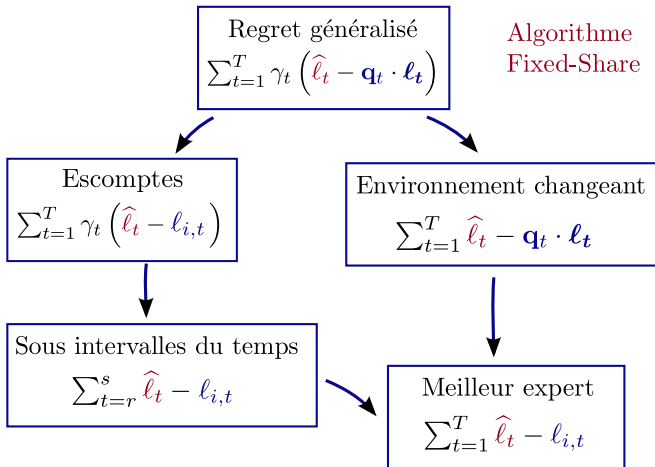
## Objectif

Avoir un regret moyen qui converge **uniformément** vers 0

$$\max_{\ell_1, \dots, \ell_T \in [0,1]^d} \frac{\mathcal{R}_T}{T} \xrightarrow{T \rightarrow \infty} 0.$$

# Les notions de regrets

À l'instant  $t$ , nous proposons les poids  $\hat{\mathbf{p}}_t \in \Delta_d$  et nous subissons la perte  $\hat{\ell}_t = \hat{\mathbf{p}}_t^\top \ell_t$ .



# Regret escompté

À l'instant  $t$ , nous proposons les poids  $\hat{\mathbf{p}}_t \in \Delta_d$  et nous subissons la perte  $\hat{\ell}_t = \hat{\mathbf{p}}_t^\top \ell_t$ .

Des **facteurs d'escomptes**  $\gamma_t \in [0, 1]$  mesurent l'importance relative des pertes plus ou moins récentes.

Notre **perte cumulée escomptée** s'écrit

$$\underbrace{\sum_{t=1}^T \gamma_t \hat{\mathbf{p}}_t^\top \ell_t}_{\text{Notre perte}} = \underbrace{\min_{i=1, \dots, d} \sum_{t=1}^T \gamma_t \ell_{i,t}}_{\text{Erreur d'approximation}} + \underbrace{\mathcal{R}_T^{\text{esc}}}_{\text{Erreur d'estimation}}$$

## Objectif

Avoir un regret moyen qui converge **uniformément** vers 0

$$\sup_{\ell_1, \dots, \ell_T \in [0, 1]^d} \frac{\mathcal{R}_T^{\text{esc}}}{\sum_{t=1}^T \gamma_t} \xrightarrow{T \rightarrow \infty} 0.$$



# Regret sur des sous-intervalles du temps.

Pour  $1 \leq \tau_T \leq T$ , notre regret sur les sous intervalles de longueur  $\tau_T$  est donné par

$$\mathcal{R}_T^{\tau_T\text{-adapt}} = \max_{\substack{[r, s] \subset [1, T] \\ s+1-r \leq \tau_T}} \left\{ \sum_{t=r}^s \hat{\mathbf{p}}_t^\top \ell_t - \min_{i=1, \dots, d} \sum_{t=r}^s \ell_{i,t} \right\}.$$

## Objectif

Avoir un regret moyen qui converge **uniformément** vers 0

$$\sup_{\ell_1, \dots, \ell_T \in [0, 1]^d} \frac{\mathcal{R}_T^{\tau_T\text{-adapt}}}{\tau_T} \xrightarrow{T \rightarrow \infty} 0.$$

# Algorithme Fixed-Share, Herbster & Warmuth 1998

**Paramètres:**  $\eta > 0$ , vitesse d'apprentissage et  $0 < \alpha < 1$ , proportion de mélange

**Initialisation:**  $\hat{\mathbf{p}}_1 = \mathbf{v}_1 = (1/d, \dots, 1/d)$

**Pour** chaque instant  $t = 1, \dots, T$ ,

1. Prévoir  $\hat{\mathbf{p}}_t$  ;
2. Observer les pertes  $\ell_t \in [0, 1]^d$  ;
3. [Mise à jour des poids selon les pertes]  $\mathbf{v}_{t+1}$  tel que

$$v_{j,t+1} = \frac{\hat{p}_{j,t} e^{-\eta \ell_{j,t}}}{\sum_{i=1}^d \hat{p}_{i,t} e^{-\eta \ell_{i,t}}}$$

4. [Mise à jour de partage]  $\hat{\mathbf{p}}_{t+1} = (1 - \alpha)\mathbf{v}_{t+1} + \alpha\hat{\mathbf{p}}_1$  .

# Borne de regret – Herbster & Warmuth 1998

Critère de régularité pour la suite  $\mathbf{q}_1^T = \mathbf{q}_1, \dots, \mathbf{q}_T \in \Delta_d$  de comparaison

$$\left\| \mathbf{q}_1^T \right\|_1 = \|\mathbf{q}_1\|_1 + \sum_{t=1}^{T-1} \|\mathbf{q}_{t+1} - \mathbf{q}_t\|_1$$

Théorème (Herbster & Warmuth 1998)

Soit  $T \geq 1$ . Pour toutes suites de pertes  $\ell_1^T \in [0, 1]^{d \times T}$  et de comparaison  $\mathbf{q}_1^T \in \Delta_d^T$ ,

$$\sum_{t=1}^T \hat{\mathbf{p}}_t^T \ell_t - \sum_{t=1}^T \mathbf{q}_t^T \ell_t \leq \frac{\ln d}{\eta} + \frac{\eta}{8} T + \frac{\left\| \mathbf{q}_1^T \right\|_1}{\eta} \ln \frac{d}{\alpha} + \frac{T - \left\| \mathbf{q}_1^T \right\|_1}{\eta} \ln \frac{1}{1 - \alpha}.$$

# Borne de regret – Herbster & Warmuth 1998

**Critère de régularité** pour la suite  $\mathbf{q}_1^T = \mathbf{q}_1, \dots, \mathbf{q}_T \in \Delta_d$  de comparaison

$$\left\| \mathbf{q}_1^T \right\|_1 = \|\mathbf{q}_1\|_1 + \sum_{t=1}^{T-1} \|\mathbf{q}_{t+1} - \mathbf{q}_t\|_1$$

Nous pouvons **optimiser** le théorème en les paramètres  $\eta$  et  $\alpha$ .

Corollaire (Herbster & Warmuth 1998)

*Pour  $\eta$  et  $\alpha$  bien choisis en fonction de  $m_T$  et  $T$ , pour toute suite de pertes  $\ell_1^T \in [0, 1]^{d \times T}$  l'algorithme fixed-share vérifie*

$$\sum_{t=1}^T \hat{\ell}_t - \inf_{\|\mathbf{q}_1^T\|_1 \leq m_T} \sum_{t=1}^T \mathbf{q}_t \cdot \ell_t \leq \square \sqrt{m_T T \ln \left( \frac{dT}{m_T} \right)}.$$

En particulier,  $R_T \ll T$  dès que  $m_T \ll T$ .

# Borne de regret – généralisation aux escomptes

**Critère de régularité.** Pour des suites de comparaison  $\mathbf{q}_1^T \in \Delta_d^T$ , et d'escomptes  $\gamma_1^T \in \mathbb{R}^T$  on note

$$m(\gamma_1^T, \mathbf{q}_1^T) = \gamma_1 + \sum_{t=1}^T \sum_{i=1}^d (\gamma_t \mathbf{q}_{i,t} - \gamma_{t-1} \mathbf{q}_{i,t-1})_+$$

## Théorème

Soit  $T, m_T$  et  $U_T \geq 1$ . Pour tous  $\ell_1^T, \mathbf{q}_1^T$  et  $\gamma_1^T$  tels que

$$m(\gamma_1^T, \mathbf{q}_1^T) \leq m_T \quad \text{et} \quad \sum_{t=1}^T \gamma_t \leq U_T$$

l'algorithme fixed-share vérifie

$$\mathcal{R}_T := \sum_{t=1}^T \gamma_t \left( \hat{\mathbf{p}}_t^T \ell_t - \mathbf{q}_t^T \ell_t \right) \leq \sqrt{\frac{U_T m_T}{2} \ln \left( \frac{d e U_T}{m_T} \right)}$$

En particulier, le regret  $\mathcal{R}_T \ll T$  dès que  $U_T m_T \ll T$ .

# Regret escompté

Pour les **escomptes**  $\gamma_t \in [0, 1]$ , notre **regret escompté** est donné par

$$\mathcal{R}_T^{\text{esc}} = \max_{i \in \{1, \dots, d\}} \sum_{t=1}^T \gamma_t (\hat{\mathbf{p}}_t^\top \ell_t - \ell_{i,t}) . \quad (1)$$

Les facteurs d'escomptes  $\gamma_t$  mesurent l'importance relative des pertes plus ou moins récentes.

## Corollaire

Soit  $T \geq 1$ . Pour tous  $\ell_1^T, \gamma_1^T$  tels que  $\sum_{t=1}^T \gamma_t \leq U_T$ , l'algorithme fixed-share vérifie

$$\mathcal{R}_T^{\text{esc}} \leq \sqrt{U_T \ln(d e U_T) / 2}.$$

# Regret pour des sous-intervalles du temps.

Pour  $1 \leq \tau_T \leq T$ , notre regret sur les sous intervalles de longueur  $\tau_T$  est donné par

$$\mathcal{R}_T^{\tau_T\text{-adapt}} = \max_{\substack{[r, s] \subset [1, T] \\ s+1-r \leq \tau_T}} \left\{ \sum_{t=r}^s \hat{\mathbf{p}}_t^\top \ell_t - \min_{i=1, \dots, d} \sum_{t=r}^s \ell_{i,t} \right\}.$$

## Corollaire

Soit  $\tau_T, T \geq 1$ . Pour toutes pertes  $\ell_1^T$  l'algorithme fixed-share vérifie

$$\mathcal{R}_T^{\tau_T\text{-adapt}} \leq \square \sqrt{\tau_T \ln(d\tau_T)}.$$