

Gains et pertes sont fondamentalement différents pour la minimisation du regret : le cas sparse

Joon Kwon

UPMC – Paris 6
Paris, France

Vianney Perchet

ENSAE
Paris, France

Journées SMAI–MODE 2016, Toulouse

vendredi 25 mars 2016

Cadre

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .
- ▶ À l'étape $t = 1, \dots, T$

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .
- ▶ À l'étape $t = 1, \dots, T$
 - ▶ Le joueur choisit $x_t \in \Delta_d$ et tire $i_t \sim x_t$.

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .
- ▶ À l'étape $t = 1, \dots, T$
 - ▶ Le joueur choisit $x_t \in \Delta_d$ et tire $i_t \sim x_t$.
 - ▶ La nature relève $g_t \in [0, 1]^d$.

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .
- ▶ À l'étape $t = 1, \dots, T$
 - ▶ Le joueur choisit $x_t \in \Delta_d$ et tire $i_t \sim x_t$.
 - ▶ La nature relève $g_t \in [0, 1]^d$.
 - ▶ Le joueur obtient un gain de $g_t^{(i_t)} \in [0, 1]$.

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .
- ▶ À l'étape $t = 1, \dots, T$
 - ▶ Le joueur choisit $x_t \in \Delta_d$ et tire $i_t \sim x_t$.
 - ▶ La nature relève $g_t \in [0, 1]^d$.
 - ▶ Le joueur obtient un gain de $g_t^{(i_t)} \in [0, 1]$.
- ▶ Une stratégie (ou algorithme) $\sigma = (\sigma_t)_{1 \leq t \leq T}$

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .
- ▶ À l'étape $t = 1, \dots, T$
 - ▶ Le joueur choisit $x_t \in \Delta_d$ et tire $i_t \sim x_t$.
 - ▶ La nature relève $g_t \in [0, 1]^d$.
 - ▶ Le joueur obtient un gain de $g_t^{(i_t)} \in [0, 1]$.
- ▶ Une stratégie (ou algorithme) $\sigma = (\sigma_t)_{1 \leq t \leq T}$

$$x_t = \sigma_t(x_1, i_1, g_1, \dots, x_{t-1}, i_{t-1}, g_{t-1}).$$

Cadre

- ▶ Ensemble d'action pour le joueur : $[d] := \{1, \dots, d\}$.
- ▶ Ensemble d'actions mixtes Δ_d .
- ▶ À l'étape $t = 1, \dots, T$
 - ▶ Le joueur choisit $x_t \in \Delta_d$ et tire $i_t \sim x_t$.
 - ▶ La nature relève $g_t \in [0, 1]^d$.
 - ▶ Le joueur obtient un gain de $g_t^{(i_t)} \in [0, 1]$.
- ▶ Une stratégie (ou algorithme) $\sigma = (\sigma_t)_{1 \leq t \leq T}$

$$x_t = \sigma_t(x_1, i_1, g_1, \dots, x_{t-1}, i_{t-1}, g_{t-1}).$$

$$\text{Maximiser : } \sum_{t=1}^T g_t^{(i_t)}$$

Le Regret

Le Regret

$$g_t^{(i)}$$

Le Regret

$$\sum_{t=1}^T g_t^{(i)}$$

Le Regret

$$\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)}$$

Le Regret

$$\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T g_t^{(i_t)}$$

Le Regret

$$R_T := \mathbb{E} \left[\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T g_t^{(i_t)} \right]$$

Le Regret

$$R_T \{\sigma, (g_t)_t\} = R_T := \mathbb{E} \left[\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T g_t^{(i_t)} \right]$$

Le Regret

$$R_T \{\sigma, (g_t)_t\} = R_T := \mathbb{E} \left[\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T g_t^{(i_t)} \right]$$

- ▶ **Introduit par** : Hannan (1957)
- ▶ **Surveys** : Cesa-Bianchi–Lugosi (2006), Rakhlin–Tewari (2008), Shalev-Shwartz (2011), Hazan (2012), Bubeck–Cesa-Bianchi (2012),...

Le Regret

$$R_T \{\sigma, (g_t)_t\} = R_T := \mathbb{E} \left[\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T g_t^{(i_t)} \right]$$

Une stratégie σ *garantit* $B(d, T)$ si :

- ▶ **Introduit par** : Hannan (1957)
- ▶ **Surveys** : Cesa-Bianchi–Lugosi (2006), Rakhlin–Tewari (2008), Shalev-Shwartz (2011), Hazan (2012), Bubeck–Cesa-Bianchi (2012),...

Le Regret

$$R_T \{\sigma, (g_t)_t\} = R_T := \mathbb{E} \left[\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T g_t^{(i_t)} \right]$$

Une stratégie σ *garantit* $B(d, T)$ si :

$$R_T \{\sigma, (g_t)_t\} \leq B(d, T).$$

- ▶ **Introduit par** : Hannan (1957)
- ▶ **Surveys** : Cesa-Bianchi–Lugosi (2006), Rakhlin–Tewari (2008), Shalev-Shwartz (2011), Hazan (2012), Bubeck–Cesa-Bianchi (2012),...

Le Regret

$$R_T \{\sigma, (g_t)_t\} = R_T := \mathbb{E} \left[\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T g_t^{(i_t)} \right]$$

Une stratégie σ *garantit* $B(d, T)$ si :

$$\forall (g_t)_t, \quad R_T \{\sigma, (g_t)_t\} \leq B(d, T).$$

- ▶ **Introduit par** : Hannan (1957)
- ▶ **Surveys** : Cesa-Bianchi–Lugosi (2006), Rakhlin–Tewari (2008), Shalev-Shwartz (2011), Hazan (2012), Bubeck–Cesa-Bianchi (2012),...

Le Regret minimax

- ▶ T : nombre d'étapes

Le Regret minimax

- ▶ T : nombre d'étapes
- ▶ d : nombre d'actions

Le Regret minimax

- ▶ T : nombre d'étapes
- ▶ d : nombre d'actions

$$R_T \{ \sigma, (g_t)_t \}$$

Le Regret minimax

- ▶ T : nombre d'étapes
- ▶ d : nombre d'actions

$$\max_{(\mathbf{g}_t)_t} R_T \{\sigma, (\mathbf{g}_t)_t\}$$

Le Regret minimax

- ▶ T : nombre d'étapes
- ▶ d : nombre d'actions

$$\min_{\sigma} \max_{(g_t)_t} R_T \{ \sigma, (g_t)_t \}$$

Le Regret minimax

- ▶ T : nombre d'étapes
- ▶ d : nombre d'actions

$\min_{\sigma} \max_{(g_t)_t} R_T \{\sigma, (g_t)_t\}$ est de l'ordre de $\sqrt{T \log d}$

Le Regret minimax

- ▶ T : nombre d'étapes
- ▶ d : nombre d'actions

$\min_{\sigma} \max_{(g_t)_t} R_T \{\sigma, (g_t)_t\}$ est de l'ordre de $\sqrt{T \log d}$

- ▶ **Borne supérieure** : Cesa-Bianchi (1997)

Le Regret minimax

- ▶ T : nombre d'étapes
- ▶ d : nombre d'actions

$\min_{\sigma} \max_{(g_t)_t} R_T \{\sigma, (g_t)_t\}$ est de l'ordre de $\sqrt{T \log d}$

- ▶ **Borne supérieure** : Cesa-Bianchi (1997)
- ▶ **Borne inférieure** : Cesa-Bianchi, Freund, Haussler, Helmbold, Schapire, Warmuth (1997)

Stratégies Mirror Descent

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t =$$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left($$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \right)$$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \sum_{s=1}^{t-1} g_s \right)$$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \sum_{s=1}^{t-1} g_s \right)$$

Theorem (Shalev-Shwartz (2007), Bubeck (2011), etc.)

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \sum_{s=1}^{t-1} g_s \right)$$

Theorem (Shalev-Shwartz (2007), Bubeck (2011), etc.)

- ▶ h est K -fortement convexe par rapport à $\|\cdot\|$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \sum_{s=1}^{t-1} g_s \right)$$

Theorem (Shalev-Shwartz (2007), Bubeck (2011), etc.)

- ▶ h est K -fortement convexe par rapport à $\|\cdot\|$
- ▶ $\|g\|_* \leq M$ pour tout vecteur de gain possible g

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \sum_{s=1}^{t-1} g_s \right)$$

Theorem (Shalev-Shwartz (2007), Bubeck (2011), etc.)

- ▶ h est K -fortement convexe par rapport à $\|\cdot\|$
- ▶ $\|g\|_* \leq M$ pour tout vecteur de gain possible g

$$R_T \leq \frac{\delta_h}{\eta} + \eta \frac{TM^2}{K}$$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \sum_{s=1}^{t-1} g_s \right)$$

Theorem (Shalev-Shwartz (2007), Bubeck (2011), etc.)

- ▶ h est K -fortement convexe par rapport à $\|\cdot\|$
- ▶ $\|g\|_* \leq M$ pour tout vecteur de gain possible g

$$R_T \leq \frac{\delta_h}{\eta} + \eta \frac{TM^2}{K} \quad \eta = \sqrt{\frac{\delta_h}{TM^2}}$$

Stratégies Mirror Descent

- ▶ $h : \mathbb{R}^d \rightarrow \mathbb{R} \cup \{+\infty\}$ strictement convexe, sci, $\text{dom } h = \Delta_d$
- ▶ $\delta_h := \max_{\Delta_d} h - \min_{\Delta_d} h$.
- ▶ $\eta > 0$ un paramètre.

$$x_t = \nabla h^* \left(\eta \sum_{s=1}^{t-1} g_s \right)$$

Theorem (Shalev-Shwartz (2007), Bubeck (2011), etc.)

- ▶ h est K -fortement convexe par rapport à $\|\cdot\|$
- ▶ $\|g\|_* \leq M$ pour tout vecteur de gain possible g

$$R_T \leq \frac{\delta_h}{\eta} + \eta \frac{TM^2}{K} \quad \underset{\eta = \sqrt{\delta_h / (TM^2)}}{\rightsquigarrow} \quad \sqrt{T\delta_h/K} \cdot M$$

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

$$h(x) = \begin{cases} \sum_{i=1}^d x^{(i)} \log x^{(i)} & \text{si } x \in \Delta_d \\ +\infty & \text{sinon} \end{cases}$$

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

$$h(x) = \begin{cases} \sum_{i=1}^d x^{(i)} \log x^{(i)} & \text{si } x \in \Delta_d \\ +\infty & \text{sinon} \end{cases}$$

L'Algorithme à poids exponentiels

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

$$h(x) = \begin{cases} \sum_{i=1}^d x^{(i)} \log x^{(i)} & \text{si } x \in \Delta_d \\ +\infty & \text{sinon} \end{cases}$$

L'Algorithme à poids exponentiels

$$x_t^{(i)} = \frac{\exp\left(\eta \sum_{s=1}^{t-1} g_s^{(i)}\right)}{\sum_{j=1}^d \exp\left(\eta \sum_{s=1}^{t-1} g_s^{(j)}\right)}$$

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

$$h(x) = \begin{cases} \sum_{i=1}^d x^{(i)} \log x^{(i)} & \text{si } x \in \Delta_d \\ +\infty & \text{sinon} \end{cases}$$

L'Algorithme à poids exponentiels

$$x_t^{(i)} = \frac{\exp\left(\eta \sum_{s=1}^{t-1} g_s^{(i)}\right)}{\sum_{j=1}^d \exp\left(\eta \sum_{s=1}^{t-1} g_s^{(j)}\right)}$$

- ▶ $\delta_h = \log d$.

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

$$h(x) = \begin{cases} \sum_{i=1}^d x^{(i)} \log x^{(i)} & \text{si } x \in \Delta_d \\ +\infty & \text{sinon} \end{cases}$$

L'Algorithme à poids exponentiels

$$x_t^{(i)} = \frac{\exp\left(\eta \sum_{s=1}^{t-1} g_s^{(i)}\right)}{\sum_{j=1}^d \exp\left(\eta \sum_{s=1}^{t-1} g_s^{(j)}\right)}$$

- ▶ $\delta_h = \log d$.
- ▶ h est 1-fortement convexe par rapport à $\|\cdot\|_1$.

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

$$h(x) = \begin{cases} \sum_{i=1}^d x^{(i)} \log x^{(i)} & \text{si } x \in \Delta_d \\ +\infty & \text{sinon} \end{cases}$$

L'Algorithme à poids exponentiels

$$x_t^{(i)} = \frac{\exp\left(\eta \sum_{s=1}^{t-1} g_s^{(i)}\right)}{\sum_{j=1}^d \exp\left(\eta \sum_{s=1}^{t-1} g_s^{(j)}\right)}$$

- ▶ $\delta_h = \log d$.
- ▶ h est 1-fortement convexe par rapport à $\|\cdot\|_1$.
- ▶ $g \in [0, 1]^d \implies \|g\|_\infty \leq 1$.

L'Algorithme à poids exponentiels garantit $\sqrt{T \log d}$

$$R_T \leq \sqrt{T \delta_h / K} \cdot M$$

$$h(x) = \begin{cases} \sum_{i=1}^d x^{(i)} \log x^{(i)} & \text{si } x \in \Delta_d \\ +\infty & \text{sinon} \end{cases}$$

L'Algorithme à poids exponentiels

$$x_t^{(i)} = \frac{\exp\left(\eta \sum_{s=1}^{t-1} g_s^{(i)}\right)}{\sum_{j=1}^d \exp\left(\eta \sum_{s=1}^{t-1} g_s^{(j)}\right)}$$

- ▶ $\delta_h = \log d$.
- ▶ h est 1-fortement convexe par rapport à $\|\cdot\|_1$.
- ▶ $g \in [0, 1]^d \implies \|g\|_\infty \leq 1$.

$$R_T \leq \sqrt{T \log d}.$$

Gains et pertes sont équivalents

Gains et pertes sont équivalents

- ▶ La nature choisit des vecteurs de *pertes* $\ell_t \in [0, 1]^d$

Gains et pertes sont équivalents

- ▶ La nature choisit des vecteurs de *pertes* $\ell_t \in [0, 1]^d$

$$\sum_{t=1}^T \langle \ell_t | x_t \rangle - \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

Gains et pertes sont équivalents

- ▶ La nature choisit des vecteurs de *pertes* $\ell_t \in [0, 1]^d$

$$\sum_{t=1}^T \langle \ell_t | x_t \rangle - \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

- ▶ $g_t^{(i)} := 1 - \ell_t^{(i)}$

Gains et pertes sont équivalents

- ▶ La nature choisit des vecteurs de *pertes* $\ell_t \in [0, 1]^d$

$$\sum_{t=1}^T \langle \ell_t | x_t \rangle - \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

- ▶ $g_t^{(i)} := 1 - \ell_t^{(i)}$
- ▶ $\ell_t \in [0, 1]^d \implies g_t \in [0, 1]^d$.

Gains et pertes sont équivalents

- ▶ La nature choisit des vecteurs de *pertes* $\ell_t \in [0, 1]^d$

$$\sum_{t=1}^T \langle \ell_t | x_t \rangle - \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

- ▶ $g_t^{(i)} := 1 - \ell_t^{(i)}$
- ▶ $\ell_t \in [0, 1]^d \implies g_t \in [0, 1]^d$.

$$\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T \langle g_t | x_t \rangle$$

Gains et pertes sont équivalents

- ▶ La nature choisit des vecteurs de *pertes* $\ell_t \in [0, 1]^d$

$$\sum_{t=1}^T \langle \ell_t | x_t \rangle - \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

- ▶ $g_t^{(i)} := 1 - \ell_t^{(i)}$
- ▶ $\ell_t \in [0, 1]^d \implies g_t \in [0, 1]^d$.

$$\max_{i \in [d]} \sum_{t=1}^T g_t^{(i)} - \sum_{t=1}^T \langle g_t | x_t \rangle = \sum_{t=1}^T \langle \ell_t | x_t \rangle - \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Hypothèse

Les vecteurs de gains (resp. de pertes) sont s -sparse, i.e. ont au plus s composantes non nulles.

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Hypothèse

Les vecteurs de gains (resp. de pertes) sont s -sparse, i.e. ont au plus s composantes non nulles.

Exemple

$d = 3$ et $s = 1$.

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Hypothèse

Les vecteurs de gains (resp. de pertes) sont s -sparse, i.e. ont au plus s composantes non nulles.

Exemple

$d = 3$ et $s = 1$.

$$g_1 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Hypothèse

Les vecteurs de gains (resp. de pertes) sont s -sparse, i.e. ont au plus s composantes non nulles.

Exemple

$d = 3$ et $s = 1$.

$$g_1 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \quad g_2 = \begin{pmatrix} \frac{1}{2} \\ 0 \\ 0 \end{pmatrix}$$

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Hypothèse

Les vecteurs de gains (resp. de pertes) sont s -sparse, i.e. ont au plus s composantes non nulles.

Exemple

$d = 3$ et $s = 1$.

$$g_1 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \quad g_2 = \begin{pmatrix} \frac{1}{2} \\ 0 \\ 0 \end{pmatrix} \quad g_3 = \begin{pmatrix} 0 \\ \frac{1}{3} \\ 0 \end{pmatrix}$$

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Hypothèse

Les vecteurs de gains (resp. de pertes) sont s -sparse, i.e. ont au plus s composantes non nulles.

Exemple

$d = 3$ et $s = 1$.

$$g_1 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \quad g_2 = \begin{pmatrix} \frac{1}{2} \\ 0 \\ 0 \end{pmatrix} \quad g_3 = \begin{pmatrix} 0 \\ \frac{1}{3} \\ 0 \end{pmatrix}$$

$$\ell_1 := \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} - g_1 = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}$$

Une hypothèse de parcimonie

Soit $s \geq 1$ un entier.

Hypothèse

Les vecteurs de gains (resp. de pertes) sont s -sparse, i.e. ont au plus s composantes non nulles.

Exemple

$d = 3$ et $s = 1$.

$$g_1 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \quad g_2 = \begin{pmatrix} \frac{1}{2} \\ 0 \\ 0 \end{pmatrix} \quad g_3 = \begin{pmatrix} 0 \\ \frac{1}{3} \\ 0 \end{pmatrix}$$

$$\ell_1 := \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} - g_1 = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix} \rightsquigarrow \text{n'est pas 1-sparse}$$

Regret minimax pour les gains s -sparse

Regret minimax pour les gains s -sparse

$(d \text{ actions})$
 $(s\text{-sparse})$

Regret minimax pour les gains s -sparse

$\left(\begin{array}{l} d \text{ actions} \\ s\text{-sparse} \end{array} \right)$

regret minimax

Regret minimax pour les gains s -sparse

$$\left(\begin{array}{l} d \text{ actions} \\ s\text{-sparse} \end{array} \right) \text{ plus facile } \leq \left(\begin{array}{l} d \text{ actions} \\ \text{sans hyp.} \end{array} \right)$$

regret minimax

Regret minimax pour les gains s -sparse

$$\left(\begin{array}{l} d \text{ actions} \\ s\text{-sparse} \end{array} \right) \underset{\text{plus facile}}{\leq} \left(\begin{array}{l} d \text{ actions} \\ \text{sans hyp.} \end{array} \right)$$

$$\text{regret minimax} \quad \sqrt{T \log d}$$

Regret minimax pour les gains s -sparse

$$\left(\begin{array}{l} s \text{ actions} \\ \text{sans hyp.} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ s\text{-sparse} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ \text{sans hyp.} \end{array} \right)$$

regret minimax

$$\sqrt{T \log d}$$

Regret minimax pour les gains s -sparse

$$\left(\begin{array}{l} s \text{ actions} \\ \text{sans hyp.} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ s\text{-sparse} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ \text{sans hyp.} \end{array} \right)$$

$$\sqrt{T \log s}$$

regret minimax

$$\sqrt{T \log d}$$

Regret minimax pour les gains s -sparse

$$\left(\begin{array}{l} s \text{ actions} \\ \text{sans hyp.} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ s\text{-sparse} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ \text{sans hyp.} \end{array} \right)$$

$$\sqrt{T \log s} \leq \text{regret minimax} \leq \sqrt{T \log d}$$

Regret minimax pour les gains s -sparse

$$\left(\begin{array}{l} s \text{ actions} \\ \text{sans hyp.} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ s\text{-sparse} \end{array} \right) \text{ plus facile} \leq \left(\begin{array}{l} d \text{ actions} \\ \text{sans hyp.} \end{array} \right)$$

$$\sqrt{T \log s} \leq \text{regret minimax} \leq \sqrt{T \log d}$$

$$\sqrt{T \log s}$$

Borne supérieure pour les gains s -sparse

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

► $h_p(x) = \frac{1}{2} \|x\|_p^2 \quad (\text{if } x \in \Delta_d)$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

- ▶ $h_p(x) = \frac{1}{2} \|x\|_p^2$ (if $x \in \Delta_d$)
- ▶ $\delta_h \leq 1$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

- ▶ $h_p(x) = \frac{1}{2} \|x\|_p^2$ (if $x \in \Delta_d$)
- ▶ $\delta_h \leq 1$
- ▶ h_p est $(p-1)$ -fortement cvx pour $\|\cdot\|_p$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

- ▶ $h_p(x) = \frac{1}{2} \|x\|_p^2$ (if $x \in \Delta_d$)
- ▶ $\delta_h \leq 1$
- ▶ h_p est $(p-1)$ -fortement cvx pour $\|\cdot\|_p$
- ▶ $\|g\|_q = \left(\sum_{i=1}^d |g^{(i)}|^q \right)^{1/q}$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

- ▶ $h_p(x) = \frac{1}{2} \|x\|_p^2$ (if $x \in \Delta_d$)
- ▶ $\delta_h \leq 1$
- ▶ h_p est $(p-1)$ -fortement cvx pour $\|\cdot\|_p$
- ▶ $\|g\|_q = \left(\sum_{i=1}^d |g^{(i)}|^q \right)^{1/q} \leq s^{1/q}$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

- ▶ $h_p(x) = \frac{1}{2} \|x\|_p^2$ (if $x \in \Delta_d$)
- ▶ $\delta_h \leq 1$
- ▶ h_p est $(p-1)$ -fortement cvx pour $\|\cdot\|_p$

$$R_T \leq \sqrt{\frac{T}{p-1}} s^{1/q}.$$

- ▶ $\|g\|_q = \left(\sum_{i=1}^d |g^{(i)}|^q \right)^{1/q} \leq s^{1/q}$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

- ▶ $h_p(x) = \frac{1}{2} \|x\|_p^2$ (if $x \in \Delta_d$)
- ▶ $\delta_h \leq 1$
- ▶ h_p est $(p-1)$ -fortement cvx pour $\|\cdot\|_p$
- ▶ $\|g\|_q = \left(\sum_{i=1}^d |g^{(i)}|^q \right)^{1/q} \leq s^{1/q}$

$$R_T \leq \sqrt{\frac{T}{p-1}} s^{1/q}.$$

$$p = 1 + \frac{1}{2 \log s - 1}$$

Borne supérieure pour les gains s -sparse

$$\begin{cases} h \text{ est } K\text{-fortement convexe pour } \|\cdot\| \\ \forall g, \quad \|g\|_* \leq M \end{cases} \implies R_T \leq \sqrt{T\delta_h/K} \cdot M$$

- ▶ $h_p(x) = \frac{1}{2} \|x\|_p^2$ (if $x \in \Delta_d$)
- ▶ $\delta_h \leq 1$
- ▶ h_p est $(p-1)$ -fortement cvx pour $\|\cdot\|_p$
- ▶ $\|g\|_q = \left(\sum_{i=1}^d |g^{(i)}|^q \right)^{1/q} \leq s^{1/q}$

$$R_T \leq \sqrt{\frac{T}{p-1}} s^{1/q}.$$

$$p = 1 + \frac{1}{2 \log s - 1}$$

$$R_T \leq \sqrt{T \log s}$$

Regret minimax pour les pertes s -sparse

Regret minimax pour les pertes s -sparse

L'algorithme à poids exponentiels

Regret minimax pour les pertes s -sparse

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$

Regret minimax pour les pertes s -sparse

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

Regret minimax pour les pertes s -sparse

Theorem (Littlestone–Warmuth (1994))

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

Regret minimax pour les pertes s -sparse

Theorem (Littlestone–Warmuth (1994))

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

$$\sum_{t=1}^T \sum_{i=1}^d \ell_t^{(i)}$$

Regret minimax pour les pertes s -sparse

Theorem (Littlestone–Warmuth (1994))

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

$$sT \geq \sum_{t=1}^T \sum_{i=1}^d \ell_t^{(i)}$$

Regret minimax pour les pertes s -sparse

Theorem (Littlestone–Warmuth (1994))

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

$$sT \geq \sum_{t=1}^T \sum_{i=1}^d \ell_t^{(i)} = \sum_{i=1}^d \sum_{t=1}^T \ell_t^{(i)}$$

Regret minimax pour les pertes s -sparse

Theorem (Littlestone–Warmuth (1994))

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

$$sT \geq \sum_{t=1}^T \sum_{i=1}^d \ell_t^{(i)} = \sum_{i=1}^d \sum_{t=1}^T \ell_t^{(i)} \geq d \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

Regret minimax pour les pertes s -sparse

Theorem (Littlestone–Warmuth (1994))

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

$$sT \geq \sum_{t=1}^T \sum_{i=1}^d \ell_t^{(i)} = \sum_{i=1}^d \sum_{t=1}^T \ell_t^{(i)} \geq d \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

$$R_T \lesssim \frac{\log d}{\eta} + \eta \frac{sT}{d}$$

Regret minimax pour les pertes s -sparse

Theorem (Littlestone–Warmuth (1994))

L'algorithme à poids exponentiels joué contre des pertes $\ell_t \in [0, 1]^d$ garantit :

$$R_T \lesssim \frac{\log d}{\eta} + \eta \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}.$$

$$sT \geq \sum_{t=1}^T \sum_{i=1}^d \ell_t^{(i)} = \sum_{i=1}^d \sum_{t=1}^T \ell_t^{(i)} \geq d \cdot \min_{i \in [d]} \sum_{t=1}^T \ell_t^{(i)}$$

$$R_T \lesssim \frac{\log d}{\eta} + \eta \frac{sT}{d} = \sqrt{Ts \frac{\log d}{d}}$$

Le cadre bandit

Le cadre bandit

À l'étape $t = 1, \dots, T$

- ▶ Le joueur choisit $i_t \in [d]$.
- ▶ La nature révèle seulement $g_t^{(i_t)}$.
- ▶ Le joueur obtient $g_t^{(i_t)}$.

Le cadre bandit

À l'étape $t = 1, \dots, T$

- ▶ Le joueur choisit $i_t \in [d]$.
- ▶ La nature révèle seulement $g_t^{(i_t)}$.
- ▶ Le joueur obtient $g_t^{(i_t)}$.

Theorem

Le regret minimax est de l'ordre de \sqrt{Td}

- ▶ **Borne supérieure** : Audibert et Bubeck (2009)
- ▶ **Borne inférieure** : Auer, Cesa-Bianchi, Freund et Schapire (2002)

Bornes supérieures et inférieures

	Gains	Pertes
Borne sup.		
Borne inf.		

Bornes supérieures et inférieures

	Gains	Pertes
Borne sup.		
Borne inf.		\sqrt{Ts}

Bornes supérieures et inférieures

	Gains	Pertes
Borne sup.		$\sqrt{Ts \log \frac{d}{s}}$
Borne inf.		\sqrt{Ts}

Bornes supérieures et inférieures

	Gains	Pertes
Borne sup.		$\sqrt{Ts \log \frac{d}{s}}$
Borne inf.	\sqrt{Ts}	\sqrt{Ts}

Bornes supérieures et inférieures

sans hypothèse de parcimonie : \sqrt{Td}

	Gains	Pertes
Borne sup.		$\sqrt{Ts \log \frac{d}{s}}$
Borne inf.	\sqrt{Ts}	\sqrt{Ts}

Bornes supérieures et inférieures

sans hypothèse de parcimonie : \sqrt{Td}

	Gains	Pertes
Borne sup.	\sqrt{Td}	$\sqrt{Ts \log \frac{d}{s}}$
Borne inf.	\sqrt{Ts}	\sqrt{Ts}

- ▶ Si le joueur sait que les vecteurs sont s -sparse

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse.

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse. Mais s'ils se révèlent être 10-sparse, ... ?

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse. Mais s'ils se révèlent être 10-sparse, ... ?

OUI

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse. Mais s'ils se révèlent être 10-sparse, ... ?

OUI

Theorem (K. & Perchet (2015))

Il existe une stratégie qui garantit $\sqrt{T \log s^}$ où $s^* = \max_{1 \leq t \leq T} \|g_t\|_0$.*

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse. Mais s'ils se révèlent être 10-sparse, ... ?

OUI

Theorem (K. & Perchet (2015))

Il existe une stratégie qui garantit $\sqrt{T \log s^}$ où $s^* = \max_{1 \leq t \leq T} \|g_t\|_0$.*

- ▶ On ne sait rien quant à la parcimonie des vecteurs.

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse. Mais s'ils se révèlent être 10-sparse, ... ?

OUI

Theorem (K. & Perchet (2015))

Il existe une stratégie qui garantit $\sqrt{T \log s^}$ où $s^* = \max_{1 \leq t \leq T} \|g_t\|_0$.*

- ▶ On ne sait rien quant à la parcimonie des vecteurs.
- ▶ On joue cette stratégie.

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse. Mais s'ils se révèlent être 10-sparse, ... ?

OUI

Theorem (K. & Perchet (2015))

Il existe une stratégie qui garantit $\sqrt{T \log s^}$ où $s^* = \max_{1 \leq t \leq T} \|g_t\|_0$.*

- ▶ On ne sait rien quant à la parcimonie des vecteurs.
- ▶ On joue cette stratégie.
- ▶ Si les vecteurs se révèlent être s -sparse, alors on aura :

$$R_T \lesssim \sqrt{T \log s}.$$

- ▶ Si le joueur sait que les vecteurs sont s -sparse, il peut choisir la stratégie adéquate pour se garantir $\sqrt{T \log s}$.
- ▶ Si s est inconnu peut-il malgré tout tirer profit d'une éventuelle parcimonie ?
- ▶ Le joueur sait que les vecteurs sont 1000-sparse. Mais s'ils se révèlent être 10-sparse, ... ?

OUI

Theorem (K. & Perchet (2015))

Il existe une stratégie qui garantit $\sqrt{T \log s^}$ où $s^* = \max_{1 \leq t \leq T} \|g_t\|_0$.*

- ▶ On ne sait rien quant à la parcimonie des vecteurs.
- ▶ On joue cette stratégie.
- ▶ Si les vecteurs se révèlent être s -sparse, alors on aura :

$$R_T \lesssim \sqrt{T \log s}.$$

résultat analogue pour les pertes

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.				
Borne inf.				

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$		
Borne inf.				

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$		
Borne inf.				

peuvent être garanties
sans connaître s

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$	\sqrt{Td}	
Borne inf.			\sqrt{Ts}	

peuvent être garanties
sans connaître s

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$	\sqrt{Td}	
Borne inf.			\sqrt{Ts}	

peuvent être garanties
sans connaître s

grande disparité

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$	\sqrt{Td}	
Borne inf.			\sqrt{Ts}	

peuvent être garanties
sans connaître s

grande disparité
problème ouvert

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$	$\sqrt{T d}$	$\sqrt{T s \log \frac{d}{s}}$
Borne inf.			$\sqrt{T s}$	$\sqrt{T s}$

peuvent être garanties
sans connaître s

grande disparité
problème ouvert

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$	$\sqrt{T d}$	$\sqrt{T s \log \frac{d}{s}}$
Borne inf.			$\sqrt{T s}$	$\sqrt{T s}$

peuvent être garanties
sans connaître s

grande disparité
problème ouvert

petite disparité

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$	$\sqrt{T d}$	$\sqrt{T s \log \frac{d}{s}}$
Borne inf.			$\sqrt{T s}$	$\sqrt{T s}$

peuvent être garanties
sans connaître s

grande disparité
problème ouvert

petite disparité
↗ en d ?

Recapitulatif

	Information complète		Bandit	
	Gains	Pertes	Gains	Pertes
Borne sup.	$\sqrt{T \log s}$	$\sqrt{T s \frac{\log d}{d}}$	$\sqrt{T d}$	$\sqrt{T s \log \frac{d}{s}}$
Borne inf.			$\sqrt{T s}$	$\sqrt{T s}$

peuvent être garanties
sans connaître s

grande disparité
problème ouvert

petite disparité
↗ en d ?

et si on ne
connaît pas s ... ?