

Séminaire EDF
Méthodes numériques pour la commande optimale
◇
Calculs d'erreurs
en commande optimale stochastique.

Pierre Girardeau et SOWG¹

EDF — ENPC — ENSTA

9 avril 2009

¹**Systems and Optimization Working Group**

L. Andrieu, K. Barty, P. Carpentier, J.-P. Chancelier, G. Cohen, A. Dallagi, P. Girardeau & M. de Lara ◀ ☰ ▶ ↻ 🔍

Plan

- 1 Introduction
 - Le problème
 - Biais et variance des solutions
- 2 Arbres de scénarios
- 3 Méthodes particulières
 - Rappel sur la méthode
 - Évaluation de l'erreur sur un cas simple
 - Cas général

Introduction

Objectif

On veut préciser de quelle manière on doit **évaluer la sortie d'un algorithme de commande optimale stochastique.**

Notations

On considère trois types de variables aléatoires définies sur $(\Omega, \mathcal{A}, \mathbb{P})$:

- Un état \mathbf{X}_t associé au système à commander ;
- Une commande \mathbf{U}_t qui nous permet de piloter le système ;
- Un bruit \mathbf{W}_t qui influence le système.

On suppose en général que ces variables sont dans $L^2(\Omega, \mathcal{A}, \mathbb{P})$.

Le problème

$$\begin{aligned} \min_{\mathbf{X}, \mathbf{U}} \quad & \mathbb{E} \left(\sum_{t=0}^{T-1} L_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}) + K(\mathbf{X}_T) \right), \\ \text{s.c.} \quad & \mathbf{X}_{t+1} = f_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}), \\ & \mathbf{U}_t \preceq \mathbf{W}_0, \dots, \mathbf{W}_t. \end{aligned}$$

Exemples classiques

Un ensemble de commandes $\hat{\mathbf{U}}_t$:

$$(\mathbf{W}_0, \dots, \mathbf{W}_t) \longrightarrow \hat{\mathbf{U}}_t = \hat{\gamma}_t(\mathbf{W}_0, \dots, \mathbf{W}_t)$$

ou, dans un cadre favorable à la programmation dynamique :

$$\mathbf{X}_t \longrightarrow \hat{\mathbf{U}}_t = \hat{\gamma}_t(\mathbf{X}_t).$$

Le problème

$$\begin{aligned} \min_{\mathbf{X}, \mathbf{U}} \quad & \mathbb{E} \left(\sum_{t=0}^{T-1} L_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}) + K(\mathbf{X}_T) \right), \\ \text{s.c.} \quad & \mathbf{X}_{t+1} = f_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}), \\ & \mathbf{U}_t \preceq \mathbf{W}_0, \dots, \mathbf{W}_t. \end{aligned}$$

Ce qui est "attendu"

Un ensemble de commandes $\hat{\mathbf{U}}_t$:

$$(\mathbf{W}_0, \dots, \mathbf{W}_t) \longrightarrow \hat{\mathbf{U}}_t = \hat{\gamma}_t(\mathbf{W}_0, \dots, \mathbf{W}_t)$$

ou, dans un cadre favorable à la programmation dynamique :

$$\mathbf{X}_t \longrightarrow \hat{\mathbf{U}}_t = \hat{\gamma}_t(\mathbf{X}_t).$$

Un exemple en boucle ouverte

On cherche à estimer la moyenne μ d'une variable aléatoire \mathbf{W} de variance σ^2 :

$$\min_{u \in \mathbb{R}} \frac{1}{2} \mathbb{E} \left((u - \mathbf{W})^2 \right).$$

L'algorithme du gradient stochastique s'écrit ici :

$$\hat{\mathbf{U}}^k = \hat{\mathbf{U}}^{k-1} - \frac{1}{k} \left(\hat{\mathbf{U}}^{k-1} - \mathbf{W}^k \right) \quad \text{ou} \quad \hat{\mathbf{U}}^k = \frac{1}{k} \sum_{j=1}^k \mathbf{W}^j.$$

- $\hat{\mathbf{U}}^k$ est une variable aléatoire et dépend des tirages.
- $\mathbb{E} \left(\hat{\mathbf{U}}^k \right) = \mu \Rightarrow$ estimateur non biaisé.
- TCL : $\sqrt{k} \left(\hat{\mathbf{U}}^k - \mu \right) \rightarrow \mathcal{N} \left(0, \sigma^2 \right) \Rightarrow$ variance en $\frac{\sigma^2}{k}$.

Un exemple en boucle ouverte

On cherche à estimer la moyenne μ d'une variable aléatoire \mathbf{W} de variance σ^2 :

$$\min_{u \in \mathbb{R}} \frac{1}{2} \mathbb{E} \left((u - \mathbf{W})^2 \right).$$

L'algorithme du gradient stochastique s'écrit ici :

$$\hat{\mathbf{U}}^k = \hat{\mathbf{U}}^{k-1} - \frac{1}{k} \left(\hat{\mathbf{U}}^{k-1} - \mathbf{W}^k \right) \quad \text{ou} \quad \hat{\mathbf{U}}^k = \frac{1}{k} \sum_{j=1}^k \mathbf{W}^j.$$

- $\hat{\mathbf{U}}^k$ est une variable aléatoire et dépend des tirages.
- $\mathbb{E} \left(\hat{\mathbf{U}}^k \right) = \mu \Rightarrow$ estimateur non biaisé.
- TCL : $\sqrt{k} \left(\hat{\mathbf{U}}^k - \mu \right) \rightarrow \mathcal{N} \left(0, \sigma^2 \right) \Rightarrow$ variance en $\frac{\sigma^2}{k}$.

Un exemple en boucle ouverte

On cherche à estimer la moyenne μ d'une variable aléatoire \mathbf{W} de variance σ^2 :

$$\min_{u \in \mathbb{R}} \frac{1}{2} \mathbb{E} \left((u - \mathbf{W})^2 \right).$$

L'algorithme du gradient stochastique s'écrit ici :

$$\hat{\mathbf{U}}^k = \hat{\mathbf{U}}^{k-1} - \frac{1}{k} \left(\hat{\mathbf{U}}^{k-1} - \mathbf{W}^k \right) \quad \text{ou} \quad \hat{\mathbf{U}}^k = \frac{1}{k} \sum_{j=1}^k \mathbf{W}^j.$$

- $\hat{\mathbf{U}}^k$ est une variable aléatoire et dépend des tirages.
- $\mathbb{E} \left(\hat{\mathbf{U}}^k \right) = \mu \Rightarrow$ estimateur non biaisé.
- TCL : $\sqrt{k} \left(\hat{\mathbf{U}}^k - \mu \right) \rightarrow \mathcal{N} \left(0, \sigma^2 \right) \Rightarrow$ variance en $\frac{\sigma^2}{k}$.

Le cas de la boucle fermée

- On se place dans le cadre de la programmation dynamique.
- ξ représente les paramètres aléatoires de la méthode de résolution (tirages d'aléas, construction d'arbres).

Ici $\|\cdot\|^2 = \|\cdot\|_{L^2(\mathcal{X})}^2$. Alors :

Erreur Quadratique Moyenne

$$\begin{aligned} \text{EQM} &= \mathbb{E}_{\xi} \left(\left\| \hat{U}(\mathcal{X}, \xi) - U^*(\mathcal{X}) \right\|_{L^2(\mathcal{X})}^2 \right) \\ &= \left\| \mathbb{E}_{\xi} \left(\hat{U}(\mathcal{X}, \xi) \right) - U^*(\mathcal{X}) \right\|_{L^2(\mathcal{X})}^2 \longrightarrow \text{Carré du biais} \\ &\quad + \mathbb{E}_{\xi} \left(\left\| \mathbb{E}_{\xi} \left(\hat{U}(\mathcal{X}, \xi) \right) - \hat{U}(\mathcal{X}, \xi) \right\|_{L^2(\mathcal{X})}^2 \right) \longrightarrow \text{Variance.} \end{aligned}$$

Le cas de la boucle fermée

- On se place dans le cadre de la programmation dynamique.
- ξ représente les paramètres aléatoires de la méthode de résolution (tirages d'aléas, construction d'arbres).

Ici $\|\cdot\|^2 = \|\cdot\|_{L^2(\mathbf{X})}^2$. Alors :

Erreur Quadratique Moyenne


$$\begin{aligned} \text{EQM} &= \mathbb{E}_{\xi} \left(\left\| \widehat{\mathbf{U}}(\mathbf{X}, \xi) - \mathbf{U}^*(\mathbf{X}) \right\|_{L^2(\mathbf{X})}^2 \right) \\ &= \left\| \mathbb{E}_{\xi} \left(\widehat{\mathbf{U}}(\mathbf{X}, \xi) \right) - \mathbf{U}^*(\mathbf{X}) \right\|_{L^2(\mathbf{X})}^2 \longrightarrow \text{Carré du biais} \\ &+ \mathbb{E}_{\xi} \left(\left\| \mathbb{E}_{\xi} \left(\widehat{\mathbf{U}}(\mathbf{X}, \xi) \right) - \widehat{\mathbf{U}}(\mathbf{X}, \xi) \right\|_{L^2(\mathbf{X})}^2 \right) \longrightarrow \text{Variance.} \end{aligned}$$

Plan

- 1 Introduction
 - Le problème
 - Biais et variance des solutions
- 2 Arbres de scénarios
- 3 Méthodes particulières
 - Rappel sur la méthode
 - Évaluation de l'erreur sur un cas simple
 - Cas général


Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes

Monte Carlo standard




Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes

Monte Carlo standard




Échantillons croisés




Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes


Monte Carlo standard



Échantillons croisés




Échantillons indépendants




Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes


Monte Carlo standard



Échantillons croisés




Échantillons indépendants



$$\frac{1}{N} \sum_{i=1}^N f(\mathbf{w}_1^i, \mathbf{w}_2^i)$$


Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes

Monte Carlo standard




$$\frac{1}{N} \sum_{i=1}^N f(\mathbf{w}_1^i, \mathbf{w}_2^i)$$

Échantillons croisés




$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^j)$$

Échantillons indépendants




Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes

Monte Carlo standard




$$\frac{1}{N} \sum_{i=1}^N f(\mathbf{w}_1^i, \mathbf{w}_2^i)$$

Échantillons croisés



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^j)$$


Échantillons indépendants



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^{i,j})$$

Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes


Monte Carlo standard



$$\frac{1}{N} \sum_{i=1}^N f(\mathbf{w}_1^i, \mathbf{w}_2^i)$$


$$\mathbb{V} \sim \frac{1}{N}$$

Échantillons croisés



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^j)$$


Échantillons indépendants



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^{i,j})$$

Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes


Monte Carlo standard



$$\frac{1}{N} \sum_{i=1}^N f(\mathbf{w}_1^i, \mathbf{w}_2^i)$$

$$\mathbb{V} \sim \frac{1}{N}$$


Échantillons croisés



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^j)$$

$$\mathbb{V} \sim \frac{1}{\sqrt{N}}$$


Échantillons indépendants



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^{i,j})$$

Estimer $\mathbb{E}(f(\mathbf{W}_1, \mathbf{W}_2))$, avec \mathbf{W}_1 et \mathbf{W}_2 indépendantes


Monte Carlo standard



$$\frac{1}{N} \sum_{i=1}^N f(\mathbf{w}_1^i, \mathbf{w}_2^i)$$

$$\mathbb{V} \sim \frac{1}{N}$$


Échantillons croisés



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^j)$$

$$\mathbb{V} \sim \frac{1}{\sqrt{N}}$$

Échantillons indépendants



$$\frac{1}{N} \sum_{i=1}^{\sqrt{N}} \sum_{j=1}^{\sqrt{N}} f(\mathbf{w}_1^i, \mathbf{w}_2^{i,j})$$

$$\mathbb{V} \sim \frac{1}{\sqrt{N}}$$

Le cas des arbres de scénarios (suite)

Les modes de calcul 2 et 3 correspondent aux **arbres de scénarios** (sur deux pas de temps). Transposé au problème d'optimisation stochastique sur T pas de temps, ce calcul montre que l'erreur entre solution exacte et solution discrétisée décroît comme le **taux de bifurcation moyen** τ et non comme le **nombre de feuilles** N de l'arbre. Comme

$$N = \tau^T,$$

on en conclut que le nombre de scénarios nécessaire pour résoudre le problème à précision donnée **croît exponentiellement** avec T .

Deux résultats allant dans ce sens.

- [Shapiro, 2006] $\mathbb{P}(|\inf J_N - \inf J| \geq \epsilon) \leq c_1 e^{-c_2 N^{\frac{1}{T}} \epsilon^2}.$
- [Cohen, 2009] $\mathbb{E}\left(\|\gamma_N(\cdot) - \gamma(\cdot)\|^2\right) \sim O\left(N^{-\frac{1}{T+d/2}}\right).$

Plan

- 1 Introduction
 - Le problème
 - Biais et variance des solutions
- 2 Arbres de scénarios
- 3 Méthodes particulières
 - Rappel sur la méthode
 - Évaluation de l'erreur sur un cas simple
 - Cas général

Rappels

- Algorithme itératif pour résoudre les conditions d'optimalité du problème [Dallagi, 2007].
- Basé sur une technique de Monte-Carlo :
 - On travaille sur N scénarios de bruit $\mathbf{W}^1, \dots, \mathbf{W}^N$, tirés a priori.
 - L'algorithme calcule une stratégie sous la forme :

$$\hat{\mathbf{U}}_t(\cdot) = \mathcal{R} \left(\left\{ \mathbf{x}_t^i, \mathbf{u}_t^i \right\}_{i=1, \dots, N} \right) (\cdot),$$

avec \mathcal{R} une fonction d'interpolation-régression.

Algorithme (étape ℓ)

- 1 Propager l'état en avant :

$$\begin{aligned}\mathbf{x}_0^i &= \mathbf{w}_0^i, \\ \mathbf{x}_{t+1}^i &= f_t(\mathbf{x}_t^i, \mathbf{u}_t^i, \mathbf{w}_{t+1}^i).\end{aligned}$$

- 2 Propager l'état adjoint en arrière :
- 3 Calculer les particules de gradient :
- 4 Mettre à jour les particules de commande :

Algorithme (étape ℓ)

- 1 Propager l'état en avant :
- 2 Propager l'état adjoint en arrière :

$$\begin{aligned}\Lambda_T^i &= K'(\mathbf{x}_T^i), \\ \Lambda_t^i &= \frac{1}{n} \sum_{j=1}^n \left[\frac{\partial L_t}{\partial \mathbf{x}}(\mathbf{x}_t^i, \mathbf{u}_t^i, \mathbf{w}_{t+1}^j) \right. \\ &\quad \left. + \tilde{\Lambda}_{t+1}^i \left(f_t(\mathbf{x}_t^i, \mathbf{u}_t^i, \mathbf{w}_{t+1}^j) \right)^\top \frac{\partial f_t}{\partial \mathbf{x}}(\mathbf{x}_t^i, \mathbf{u}_t^i, \mathbf{w}_{t+1}^j) \right].\end{aligned}$$

- 3 Calculer les particules de gradient :
- 4 Mettre à jour les particules de commande :

Algorithme (étape ℓ)

- 1 Propager l'état en avant :
- 2 Propager l'état adjoint en arrière :
- 3 Calculer les particules de gradient :

$$G_t^i = \sum_{j=1}^n \left[\frac{\partial L_t}{\partial u} \left(\mathbf{x}_t^i, \mathbf{u}_t^i, \mathbf{w}_{t+1}^j \right) + \tilde{\Lambda}_{t+1} \left(f_t \left(\mathbf{x}_t^i, \mathbf{u}_t^i, \mathbf{w}_{t+1}^j \right) \right)^\top \frac{\partial f_t}{\partial u} \left(\mathbf{x}_t^i, \mathbf{u}_t^i, \mathbf{w}_{t+1}^j \right) \right]$$

- 4 Mettre à jour les particules de commande :

Algorithme (étape ℓ)

- 1 Propager l'état en avant :
- 2 Propager l'état adjoint en arrière :
- 3 Calculer les particules de gradient :
- 4 Mettre à jour les particules de commande :

$$\left(\mathbf{U}_t^i\right)^+ = \mathbf{U}_t^i - \rho G_t^i.$$

Un problème à deux pas de temps

Soient \mathbf{W}_0 et \mathbf{W}_1 deux variables aléatoires i.i.d. $\mathcal{U}[-1, 1]$

- L'aléa \mathbf{W}_0 se produit et est observé.
- Une décision \mathbf{U} est prise.
- Un second aléa \mathbf{W}_1 se produit.

On cherche à résoudre :

Le problème

$$\min_{\mathbf{U} \preceq \mathbf{W}_0} \mathbb{E} \left(\varepsilon \mathbf{U}^2 + (\mathbf{W}_0 + \mathbf{U} + \mathbf{W}_1)^2 \right) := J(\mathbf{U}).$$

Un problème à deux pas de temps

Stratégie optimale

La solution optimale se calcule facilement :

$$\mathbf{U}^*(\mathbf{W}_0) = -\frac{\mathbf{W}_0}{1+\varepsilon} \text{ et } J(\mathbf{U}^*) = \frac{1}{3} \frac{1+2\varepsilon}{1+\varepsilon}.$$

Stratégie particulière

$$\hat{U}(\mathbf{W}_0) = \mathcal{P}(\{\mathbf{W}_0^i, \mathbf{U}^i\}_{i=1, \dots, n})(\mathbf{W}_0),$$

$$\text{avec : } \mathbf{U}_0^i = -\frac{\mathbf{W}_0^i + \frac{1}{n} \sum_{j=1}^n \mathbf{W}_1^j}{1+\varepsilon}.$$

↔ La stratégie particulière dépend de tirages !

Un problème à deux pas de temps

Stratégie optimale

La solution optimale se calcule facilement :

$$\mathbf{U}^*(\mathbf{W}_0) = -\frac{\mathbf{W}_0}{1+\varepsilon} \text{ et } J(\mathbf{U}^*) = \frac{1}{3} \frac{1+2\varepsilon}{1+\varepsilon}.$$


Stratégie particulière

$$\hat{\mathbf{U}}(\mathbf{W}_0) = \mathcal{R}\left(\{\mathbf{W}_0^i, \mathbf{U}^i\}_{i=1,\dots,n}\right)(\mathbf{W}_0),$$

avec :
$$\mathbf{U}_0^i = -\frac{\mathbf{W}_0^i + \frac{1}{n} \sum_{j=1}^n \mathbf{W}_1^j}{1+\varepsilon}.$$


↔ La stratégie particulière dépend de tirages !

Stratégies



- Stratégie optimale (en noir) et stratégies particulières.

Stratégies



- Stratégie optimale (en noir) et stratégies particulières.

Erreur

On choisit comme régresseur le plus proche voisin et on cherche à évaluer biais et variance.

Proposition

$$\text{Biais}^2 = \left\| \mathbf{U}^* - \mathbb{E}_{\xi} \left(\widehat{\mathbf{U}} \right) \right\|_{L^2(\mathbf{X})}^2 = \frac{13}{4(1+\varepsilon)^2 n^3} + o\left(\frac{1}{n^3}\right),$$

$$\text{Variance} = \mathbb{E}_{\xi} \left(\left\| \widehat{\mathbf{U}} - \mathbb{E}_{\xi} \left(\widehat{\mathbf{U}} \right) \right\|_{L^2(\mathbf{X})}^2 \right) = \frac{1}{3(1+\varepsilon)^2 n} + o\left(\frac{1}{n}\right).$$

- Le biais est négligeable devant la variance.
- La variance est d'ordre minimal (Monte-Carlo).
- Que se passe-t-il lorsque l'horizon augmente ?

Plusieurs pas de temps

Sans introduction d'une variable d'état, on a :

$$\begin{aligned}\mathbf{U}_0 &= g_0(\mathbf{W}_0), \\ \mathbf{U}_1 &= g_1(\mathbf{W}_0, \mathbf{W}_1), \\ &\vdots \\ \mathbf{U}_t &= g_t(\mathbf{W}_0, \dots, \mathbf{W}_t).\end{aligned}$$

↔ On s'attend à ce que biais comme variance souffrent de la dimension.

Expérience numérique

Protocole expérimental

On répète $M = 10^4$ fois l'expérience suivante :

- 1 Tirer N trajectoires (particules) des bruits $\mathbf{W}_0, \dots, \mathbf{W}_T$.
- 2 Appliquer l'algorithme particulière et obtenir une stratégie particulière (qui dépend des tirages).

On calcule $\hat{U}^M(\mathbf{x}) = \frac{1}{M} \sum_{j=1}^M \hat{U}(\mathbf{x}, \xi^j)$ et :

$$\text{Biais}^2 \approx \left\| U^*(\mathbf{x}) - \hat{U}^M(\mathbf{x}) \right\|_{L^2(\mathbf{x})}^2$$

$$\text{Variance} \approx \frac{1}{M} \sum_{j=1}^M \left\| \hat{U}(\mathbf{x}, \xi^j) - \hat{U}^M(\mathbf{x}) \right\|_{L^2(\mathbf{x})}^2$$

Expérience numérique

Protocole expérimental

On répète $M = 10^4$ fois l'expérience suivante :


- 1 Tirer N trajectoires (particules) des bruits $\mathbf{W}_0, \dots, \mathbf{W}_T$.
- 2 Appliquer l'algorithme particulière et obtenir une stratégie particulière (qui dépend des tirages).

On calcule $\hat{\mathbf{U}}^M(\mathbf{x}) = \frac{1}{M} \sum_{j=1}^M \hat{\mathbf{U}}(\mathbf{x}, \xi^j)$ et :

$$\text{Biais}^2 \approx \left\| \mathbf{U}^*(\mathbf{x}) - \hat{\mathbf{U}}^M(\mathbf{x}) \right\|_{L^2(\mathbf{x})}^2,$$


$$\text{Variance} \approx \frac{1}{M} \sum_{j=1}^M \left\| \hat{\mathbf{U}}(\mathbf{x}, \xi^j) - \hat{\mathbf{U}}^M(\mathbf{x}) \right\|_{L^2(\mathbf{x})}^2.$$

Plusieurs pas de temps - Biais



- Biais pour un problème à trois pas de temps en fonction du nombre de particules.

Plusieurs pas de temps - Variance



- Variance pour un problème à trois pas de temps en fonction du nombre de particules.

Difficultés théoriques dans le cas général

- Dans le cas avec variable d'état, les équations sont non-linéaires en les \mathbf{U}_t^i :

$$\Lambda_t^i = \frac{1}{n} \sum_{j=1}^n \left[\frac{\partial C_t}{\partial \mathbf{x}} \left(\mathbf{x}_t^i, \mathbf{U}_t^i, \mathbf{w}_{t+1}^j \right) + \tilde{\Lambda}_{t+1} \left(f_t \left(\mathbf{x}_t^i, \mathbf{U}_t^i, \mathbf{w}_{t+1}^j \right) \right)^\top \frac{\partial f_t}{\partial \mathbf{x}} \left(\mathbf{x}_t^i, \mathbf{U}_t^i, \mathbf{w}_{t+1}^j \right) \right].$$

- $\tilde{\Lambda}_{t+1}$ est un opérateur de régression (généralement non-linéaire) portant sur les particules \mathbf{X}_{t+1}^i , qui dépendent de \mathbf{X}_t^i et de \mathbf{U}_t^i .

On se contentera d'expériences numériques.

Expérience numérique


On considère une extension du précédent problème à plusieurs pas de temps :

Le problème

$$\begin{aligned} \min_{\mathbf{X}, \mathbf{U}} \quad & \mathbb{E} \left(\varepsilon \sum_{t=0}^{T-1} \mathbf{U}_t^2 + \mathbf{X}_T^2 \right), \\ \text{s.c.} \quad & \mathbf{X}_{t+1} = \mathbf{X}_t + \mathbf{U}_t + \mathbf{W}_{t+1}, \\ & \mathbf{U}_t \preceq \mathbf{X}_t. \end{aligned}$$


- On espère observer une stabilité du biais et de la variance en fonction du pas de temps.

Résultats - Biais



- Biais pour les 4 stratégies ($T = 4$) en fonction du nombre de particules.

Résultats - Variance



- Variance pour les 4 stratégies ($T = 4$) en fonction du nombre de particules.

Conclusion

- Arbres de scénarios :
 - **L'erreur est inversement proportionnelle au taux de branchement $N^{\frac{1}{T}}$!**
 - Complexité exponentielle en l'horizon de temps.
- Méthodes particulières :
 - L'erreur semble peu varier en fonction de T .
 - Mais on a toujours que l'erreur se dégrade avec la dimension.

Conclusion

- Arbres de scénarios :
 - **L'erreur est inversement proportionnelle au taux de branchement $N^{\frac{1}{T}}$!**
 - Complexité exponentielle en l'horizon de temps.
- Méthodes particulières :
 - **L'erreur semble peu varier en fonction de T .**
 - Mais on a toujours que l'erreur se dégrade avec la dimension.



Références I



Cohen, G. (2009).

Optimal scenario tree topology and corresponding rate of convergence.
En préparation.



Dallagi, A. (2007).

Méthodes particulières en commande optimale stochastique.
Thèse de doctorat, Université Paris 1, Panthéon-Sorbonne.



Shapiro, A. (2006).

On complexity of multistage stochastic programs.
Operations Research Letters, 34 :1–8.