

# Consistance Dynamique et Commande Optimale Stochastique

Groupe de travail FiME

Pierre Girardeau<sup>1,2,3</sup>

Travail conjoint avec Pierre Carpentier<sup>2</sup>, Jean-Philippe Chancelier<sup>3</sup>,  
Guy Cohen<sup>3</sup> et Michel De Lara<sup>3</sup>

<sup>1</sup>OSIRIS, EDF R&D, France

<sup>2</sup>ENSTA-ParisTech, France

<sup>3</sup>École des Ponts-ParisTech, CERMICS, France

22 octobre 2010

# Plan

## 1 Motivation

- Formulation du problème
- Mesures de risque dynamiques
- Notion de consistance

## 2 Programmation Dynamique et Consistance

- Cas déterministe
- Cas stochastique sans contrainte de risque
- Cas stochastique avec contrainte de risque

## 3 Exemples

# Plan

## 1 Motivation

- Formulation du problème
- Mesures de risque dynamiques
- Notion de consistance

## 2 Programmation Dynamique et Consistance

- Cas déterministe
- Cas stochastique sans contrainte de risque
- Cas stochastique avec contrainte de risque

## 3 Exemples

# Introduction

## Commande optimale stochastique

- On considère un **système dynamique** influencé par des **bruits** exogènes.
- À chaque pas de temps :
  - des **observations** sont faites sur le système et conservées.
  - une **décision** est prise, et le système évolue.
- On cherche à **minimiser un certain objectif** fonction de l'évolution du système.

# Introduction

## Consistance dynamique

**La propriété de consistance dynamique concerne une suite de problèmes de décision.**

### Définition informelle de la consistance

- On peut souvent écrire un **nouveau problème** de commande optimale aux **instants ultérieurs** en “tronquant” le problème original.
- On se demande si la commande issue du problème original **reste optimale pour les problèmes de décision ultérieurs** [Ekeland and Lazrak, 2006].

# Introduction

## Consistance dynamique

**La propriété de consistance dynamique concerne une suite de problèmes de décision.**

### Définition informelle de la consistance

- On peut souvent écrire un **nouveau problème** de commande optimale aux **instants ultérieurs** en “tronquant” le problème original.
- On se demande si la commande issue du problème original **reste optimale pour les problèmes de décision ultérieurs** [Ekeland and Lazrak, 2006].

# Introduction

Pour fixer les idées

$\mathbf{X}_t$  : stock<sup>1</sup>,  $\mathbf{U}_t$  : commande,  $\mathbf{W}_t$  : bruit.

## Problème standard

$$\min_{\mathbf{X}, \mathbf{U}} \mathbb{E} \left( \sum_{t=t_0}^{T-1} L_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}) + K(\mathbf{X}_T) \right),$$

$$\text{s.c. } \mathbf{X}_{t_0} \text{ est donné,}$$

et, pour tout  $t = t_0, \dots, T - 1$  :

$$\mathbf{X}_{t+1} = f_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}),$$

$$\mathbf{U}_t \text{ est } \sigma\{\mathbf{X}_{t_0}, \mathbf{W}_{t_1}, \dots, \mathbf{W}_t\}\text{-mesurable.}$$

1. On l'appellera état sous certaines hypothèses.

# Introduction

## Motivation(s)

### État (inspiré de [Whittle, 1982, Section 1.1])

C'est une **variable**  $x$  valant  $x_t$  à l'instant  $t$  et **suffisante** pour que :

- la **décision optimale à l'instant  $t$**  ne dépende que de  $x_t$  et de  $t$  ;
- la variable  $x_{t+1}$  soit calculable à partir de  $x_t$ , de la décision à l'instant  $t$  et de la nouvelle observation à  $t + 1$ .

Pour beaucoup de systèmes, on a :

- un état "**habituel**" (stock d'énergie, mémoire d'un processus) qui découle du principe de **programmation dynamique** ;
- **consistance dynamique** du fait du même principe.



# Introduction

## Motivation(s)

### État (inspiré de [Whittle, 1982, Section 1.1])

C'est une **variable**  $x$  valant  $x_t$  à l'instant  $t$  et **suffisante** pour que :

- la **décision optimale à l'instant  $t$**  ne dépende que de  $x_t$  et de  $t$  ;
- la variable  $x_{t+1}$  soit calculable à partir de  $x_t$ , de la décision à l'instant  $t$  et de la nouvelle observation à  $t + 1$ .

Pour beaucoup de systèmes, on a :

- un **état "habituel"** (stock d'énergie, mémoire d'un processus) qui découle du principe de **programmation dynamique** ;
- **consistance dynamique** du fait du même principe.

# Introduction

## Motivation(s)

On peut alors chercher à :

- **changer le critère** en espérance à l'aide d'une autre mesure de risque,
- ajouter de **nouvelles contraintes**.

Parfois, la suite de problèmes de décision devient **inconsistante** [Haviv, 1996, Ruszczyński, 2009, Shapiro, 2009].

### Objectif de la présentation

Étudier la **consistance dynamique** d'une suite de problèmes à la lumière du concept de **variable d'état**.

↔ Plus de précisions dans [Carpentier et al., 2010].

# Motivation 1

## Mesures de risque dynamiques

### Littérature des mesures de risque

- De nombreux travaux sur la cohérence et la consistance des mesures de risque [Detlefsen and Scandolo, 2005, Cheridito et al., 2006, Artzner et al., 2007].

↪ Ce ne sera pas notre propos ici.

### Littérature *Stochastic Programming*

- Plusieurs travaux [Ruszczynski, 2009, Shapiro, 2009] s'attachent à **introduire de l'aversion au risque** adns les problèmes d'optimisation stochastique.
- Ils cherchent alors des **classes de mesures de risque préservant une certaine structure** pour le problème.

↪ On propose ici un point de vue différent.

# Motivation 1

## Mesures de risque dynamiques

### Littérature des mesures de risque

- De nombreux travaux sur la cohérence et la consistance des mesures de risque [Detlefsen and Scandolo, 2005, Cheridito et al., 2006, Artzner et al., 2007].

↪ Ce ne sera pas notre propos ici.


### Littérature *Stochastic Programming*

- Plusieurs travaux [Ruszczynski, 2009, Shapiro, 2009] s'attachent à **introduire de l'aversion au risque** adns les problèmes d'optimisation stochastique.
- Ils cherchent alors des **classes de mesures de risque préservant une certaine structure** pour le problème.

↪ On propose ici un point de vue différent.

# Motivation 2

Exemple [Haviv, 1996]

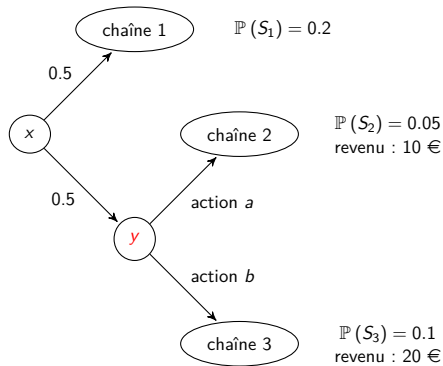


Maximiser le revenu espéré sous la  
contrainte :

$$\mathbb{P}(S_1 \cup S_2 \cup S_3) \leq 0.125.$$

# Motivation 2

Exemple [Haviv, 1996]




Vu de  $y$ , l'action  $b$  est admissible et optimale :

$$0.1 < 0.125.$$

# Motivation 2

Exemple [Haviv, 1996]




Vu de  $x$ , l'action  $b$  n'est même pas admissible :

$$0.5 \times 0.2 + 0.5 \times 0.1 = 0.15 > 0.125.$$

# Motivation 3

## Problème EDF de la cote touristique



Certaines réglementations liées aux activités estivales près des réservoirs imposent :

$$\mathbb{P}(\mathbf{X}_t \geq x_{\text{ref}}, \forall t \in \mathbb{T}_{\text{été}}) \geq p.$$



# Plan

## 1 Motivation

- Formulation du problème
- Mesures de risque dynamiques
- Notion de consistance

## 2 Programmation Dynamique et Consistance

- Cas déterministe
- Cas stochastique sans contrainte de risque
- Cas stochastique avec contrainte de risque

## 3 Exemples

# Un premier problème...

## Problème partant de $t_0$

$$\min_{x,u} \sum_{t=t_0}^{T-1} L_t(x_t, u_t) + K(x_T),$$

$$\text{s.c. } x_{t_0} \text{ donné,}$$

$$x_{t+1} = f_t(x_t, u_t), \quad \forall t = t_0, \dots, T-1.$$

## Boucle ouverte

Une solution est une suite de décisions  $u_{t_0, t_0}^\#, \dots, u_{t_0, T-1}^\#$ .

## Attention

La solution dépend de la condition initiale  $x_{t_0}$ .

# Un premier problème...

## Problème partant de $t_0$

$$\min_{x,u} \sum_{t=t_0}^{T-1} L_t(x_t, u_t) + K(x_T),$$

$$\text{s.c. } x_{t_0} \text{ donné,}$$

$$x_{t+1} = f_t(x_t, u_t), \quad \forall t = t_0, \dots, T-1.$$

## Boucle ouverte

Une solution est une suite de décisions  $u_{t_0, t_0}^\#, \dots, u_{t_0, T-1}^\#$ .

## Attention

La solution dépend de la condition initiale  $x_{t_0}$ .

# Un premier problème...

## Problème partant de $t_0$

$$\min_{x,u} \sum_{t=t_0}^{T-1} L_t(x_t, u_t) + K(x_T),$$

$$\text{s.c. } x_{t_0} \text{ donné,}$$

$$x_{t+1} = f_t(x_t, u_t), \quad \forall t = t_0, \dots, T-1.$$

## Boucle ouverte

Une solution est une suite de décisions  $u_{t_0, t_0}^\#, \dots, u_{t_0, T-1}^\#$ .

## Attention

La solution dépend de la condition initiale  $x_{t_0}$ .

## ... et la suite de problèmes qui en découle

Problème partant de  $t_i$

$$\min_{x, u} \sum_{t=t_i}^{T-1} L_t(x_t, u_t) + K(x_T),$$

s.c.  $x_{t_i}$  donné,

$$x_{t+1} = f_t(x_t, u_t), \quad \forall t = t_i, \dots, T-1.$$

Soit  $u_{t_i, t_i}^\#, \dots, u_{t_i, T-1}^\#$  une solution.

Attention

La solution dépend de la condition initiale  $x_{t_i}$ .

## ... et la suite de problèmes qui en découle

Problème partant de  $t_i$

$$\min_{x, u} \sum_{t=t_i}^{T-1} L_t(x_t, u_t) + K(x_T),$$

s.c.  $x_{t_i}$  donné,

$$x_{t+1} = f_t(x_t, u_t), \quad \forall t = t_i, \dots, T-1.$$

Soit  $u_{t_i, t_i}^\#, \dots, u_{t_i, T-1}^\#$  une solution.

### Attention

La solution dépend de la condition initiale  $x_{t_i}$ .

# Première observation

## Indépendance vis-à-vis de la condition initiale

Si les solutions des problèmes aux différents instants ne dépendent pas de la condition initiale, alors on a consistance dynamique.

Preuve : Application du principe de Bellman au problème à l'instant  $t_0$ .

### Exemple

Soient  $l_t : \mathcal{U}_t \rightarrow \mathbb{R}$ ,  $K$  scalaire, et  $f_t : \mathcal{U}_t \rightarrow \mathbb{R}$  tels que  $x_t > 0, \forall t$ .

$$\min_{x, u} \sum_{t=t_0}^{T-1} l_t(u_t) x_t + Kx_T,$$

$$\text{s.c. } x_{t_0} \text{ donné,}$$

$$x_{t+1} = f_t(u_t) x_t, \quad \forall t = t_0, \dots, T-1.$$

$x_{t_0}$  **n'influe** que sur la valeur du problème, **pas sur l'argmin**.

# Première observation

## Indépendance vis-à-vis de la condition initiale

Si les solutions des problèmes aux différents instants ne dépendent pas de la condition initiale, alors on a consistance dynamique.

Preuve : Application du principe de Bellman au problème à l'instant  $t_0$ .

## Exemple

Soient  $l_t : \mathbb{U}_t \rightarrow \mathbb{R}$ ,  $K$  scalaire, et  $f_t : \mathbb{U}_t \rightarrow \mathbb{R}$  tels que  $x_t > 0, \forall t$ .

$$\min_{x,u} \sum_{t=t_0}^{T-1} l_t(u_t) x_t + Kx_T,$$

$$\text{s.c. } x_{t_0} \text{ donné,}$$

$$x_{t+1} = f_t(u_t) x_t, \quad \forall t = t_0, \dots, T-1.$$

$x_{t_0}$  **n'influe** que sur la valeur du problème, **pas sur l'argmin**.



# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.

# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
  - on résout le problème  $(\mathcal{P}_{t_1, t_1})$  ;
  - on obtient une décision  $u_{t_1, t_1}^\#$  pour  $t_1$ , et une suite de décisions  $u_{t_1, t_2}^\#, \dots, u_{t_1, T-1}^\#$  pour le futur ;
  - on obtient une décision  $u_{t_0, t_1}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_2}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur ;
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.

# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
  - on observe le stock perturbé  $f_{t_1}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on écrit un nouveau problème portant de  $t_1$  ;
  - on a  $x_{t_1} = f_{t_1}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on obtient une décision  $u_{t_1, t_1}^\#$  pour l'instant  $t_1$  ;
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.

# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
  - on observe le **stock perturbé**  $f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on écrit un **nouveau problème partant de  $t_1$**   
en  $x_{t_1} = f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on obtient une **décision  $u_{t_1, t_1}^\#$ , généralement différente de  $u_{t_0, t_1}^\#$ .**
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.

# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
  - on observe le **stock perturbé**  $f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on écrit un **nouveau problème partant de  $t_1$**   
 en  $x_{t_1} = f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on obtient une **décision  $u_{t_1, t_1}^\#$ , généralement différente de  $u_{t_0, t_1}^\#$ .**
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.

# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
  - on observe le **stock perturbé**  $f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on écrit un **nouveau problème partant de  $t_1$**   
 en  $x_{t_1} = f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on obtient une **décision**  $u_{t_1, t_1}^\#$ , **généralement différente de  $u_{t_0, t_1}^\#$** .
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.

# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
  - on observe le **stock perturbé**  $f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on écrit un **nouveau problème partant de  $t_1$**   
 en  $x_{t_1} = f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on obtient une **décision**  $u_{t_1, t_1}^\#$ , **généralement différente de  $u_{t_0, t_1}^\#$** .
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.

# Processus de décision

Le **processus de décision réel** est en fait soumis à des **perturbations**  $\varepsilon_{t_1}, \dots, \varepsilon_{T-1}$  **non modélisées** :

- À l'instant  $t_0$  :
  - on écrit le problème à  $t_0$  ;
  - on obtient une décision  $u_{t_0, t_0}^\#$  pour  $t_0$ , et une suite de décisions  $u_{t_0, t_1}^\#, \dots, u_{t_0, T-1}^\#$  pour le futur.
- À l'instant  $t_1$  :
  - on observe le **stock perturbé**  $f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on écrit un **nouveau problème partant de  $t_1$**   
 en  $x_{t_1} = f_{t_0}(x_{t_0}, u_{t_0, t_0}^\#) + \varepsilon_{t_1}$  ;
  - on obtient une **décision**  $u_{t_1, t_1}^\#$ , **généralement différente de  $u_{t_0, t_1}^\#$** .
- Le même processus se poursuit jusqu'à la fin de l'horizon de temps.



## Deuxième observation

### Monde parfaitement déterministe

Dans le cas où le **modèle est exact** (si les perturbations  $\varepsilon_{t_i}$  sont nulles), les problèmes successifs avec comme conditions initiales :

$$x_{t_i} = x_{t_i}^\# := f_{t_i} \left( x_{t_{i-1}}^\#, u_{t_0, t_{i-1}}^\# \right),$$

sont **consistants dynamiquement**.

En général, cette observation est fautive !

## Deuxième observation

### Monde parfaitement déterministe

Dans le cas où le **modèle est exact** (si les perturbations  $\varepsilon_{t_i}$  sont nulles), les problèmes successifs avec comme conditions initiales :

$$x_{t_i} = x_{t_i}^\# := f_{t_i} \left( x_{t_{i-1}}^\#, u_{t_0, t_{i-1}}^\# \right),$$

sont **consistants dynamiquement**.

En général, cette observation est fautive !

# Troisième observation

## Quantité suffisante d'information

- Supposons que le **problème original soit résolu par programmation dynamique**,
- obtenant ainsi une suite de stratégies optimales  $\Phi_{t_0, t_0}^\#, \dots, \Phi_{t_0, T-1}^\#$  en **feedback** sur la variable  $x$ ,
- alors les problèmes successifs sont **consistants dynamiquement** pour  $t = t_0, \dots, T - 1$ .

# Un premier problème...

Problème partant de  $t_0$

$$\min_{\mathbf{X}, \mathbf{U}} \mathbb{E} \left( \sum_{t=t_0}^{T-1} L_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}) + K(\mathbf{X}_T) \right),$$

s.c.  $\mathbf{X}_{t_0}$  donné,

et, pour tout  $t = t_0, \dots, T - 1$  :

$$\mathbf{X}_{t+1} = f_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}),$$

$\mathbf{U}_t$  est  $\sigma\{\mathbf{X}_{t_0}, \mathbf{W}_{t_1}, \dots, \mathbf{W}_t\}$ -mesurable.

# Principe de Programmation Dynamique

## Hypothèse d'indépendance temporelle

Les variables aléatoires  $\mathbf{X}_{t_0}, \mathbf{W}_{t_1}, \dots, \mathbf{W}_T$  sont indépendantes entre elles.

## Principe de Programmation Dynamique

- Solution  $\Phi_t : \mathbb{X}_t \rightarrow \mathbb{U}_t$  en **feedback** sur  $\mathbf{X}_t$ .
- Soit  $V_t(x)$  le coût optimal partant de  $(t, x)$ , alors :

$$V_T(x) = K(x),$$

$$V_t(x) = \min_{u \in \mathbb{U}_t} \mathbb{E} \left( L_t(x, u, \mathbf{W}_{t+1}) + V_{t+1}(f_t(x, u, \mathbf{W}_{t+1})) \right).$$

**permet de calculer les stratégies optimales  $\Phi_{t_0, t_0}^\#, \dots, \Phi_{t_0, T-1}^\#$ .**

# Consistance dynamique

- On est dans le cas le plus standard en commande optimale.
- La suite de stratégies  $\Phi_{t_0, t_0}^\#, \dots, \Phi_{t_0, T-1}^\#$  reste optimale pour les problèmes ultérieurs :

## Problème partant de $t_i$

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

↔ Les problèmes successifs sont **dynamiquement consistants**.

# Consistance dynamique

- On est dans le cas le plus standard en commande optimale.
- La suite de stratégies  $\Phi_{t_0, t_0}^\#, \dots, \Phi_{t_0, T-1}^\#$  reste optimale pour les problèmes ultérieurs :

Problème partant de  $t_i$

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

↔ Les problèmes successifs sont **dynamiquement consistants**.

# Analogie avec le cas déterministe

## Question

Est-on dans le cas :

- 1 Indépendance vis-à-vis de la condition initiale ?
- 2 Monde parfaitement déterministe ?
- 3 Quantité suffisante d'information ?

▶ 1<sup>re</sup> obs.

▶ 2<sup>e</sup> obs.

▶ 3<sup>e</sup> obs.



# Réponse

Indépendance vis-à-vis de la condition initiale

Étant donné un feedback  $\Phi_t$  pour tout  $t$ , on définit :

- l'ensemble  $\Psi_t$  des fonctions de  $\mathbb{X}_t$  dans  $\mathbb{R}$  ;
- le produit scalaire :

$$\langle \psi_t, \mu_t \rangle := \mathbb{E}(\psi_t(\mathbf{X}_t)), \quad \text{avec } \mathbf{X}_t \sim \mu_t.$$

- l'opérateur linéaire  $A_t^{\Phi_t} : \Psi_{t+1} \rightarrow \Psi_t$  :

$$(A_t^{\Phi_t} \psi_{t+1})(\cdot) := \mathbb{E}(\psi_{t+1} \circ f_t(\cdot, \Phi_t(\cdot), \mathbf{W}_{t+1}))$$

*(transport rétrograde du coût à  $t + 1$  si on applique le feedback  $\Phi_t$ )*

# Réponse

Indépendance vis-à-vis de la condition initiale

Étant donné un feedback  $\Phi_t$  pour tout  $t$ , on définit :

- l'ensemble  $\Psi_t$  des fonctions de  $\mathbb{X}_t$  dans  $\mathbb{R}$  ;
- le produit scalaire :

$$\langle \psi_t, \mu_t \rangle := \mathbb{E}(\psi_t(\mathbf{X}_t)), \quad \text{avec } \mathbf{X}_t \sim \mu_t.$$

- l'opérateur linéaire  $A_t^{\Phi_t} : \Psi_{t+1} \rightarrow \Psi_t$  :

$$(A_t^{\Phi_t} \psi_{t+1})(\cdot) := \mathbb{E}(\psi_{t+1} \circ f_t(\cdot, \Phi_t(\cdot), \mathbf{W}_{t+1}))$$

*(transport rétrograde du coût à  $t + 1$  si on applique le feedback  $\Phi_t$ )*

# Réponse

Indépendance vis-à-vis de la condition initiale

Étant donné un feedback  $\Phi_t$  pour tout  $t$ , on définit :

- l'ensemble  $\Psi_t$  des fonctions de  $\mathbb{X}_t$  dans  $\mathbb{R}$  ;
- le produit scalaire :

$$\langle \psi_t, \mu_t \rangle := \mathbb{E}(\psi_t(\mathbf{X}_t)), \quad \text{avec } \mathbf{X}_t \sim \mu_t.$$

- l'opérateur linéaire  $A_t^{\Phi_t} : \Psi_{t+1} \rightarrow \Psi_t$  :

$$(A_t^{\Phi_t} \psi_{t+1})(\cdot) := \mathbb{E}(\psi_{t+1} \circ f_t(\cdot, \Phi_t(\cdot), \mathbf{W}_{t+1}))$$

*(transport rétrograde du coût à  $t + 1$  si on applique le feedback  $\Phi_t$ )*

# Réponse

Indépendance vis-à-vis de la condition initiale

Enfin :

- l'opérateur adjoint  $(A_t^{\Phi_t})^*$  qui transporte les mesures  $\mu_t$ .
- un opérateur  $\Lambda_t^{\Phi_t} : \mathcal{X}_t \rightarrow \mathbb{R}$  de la forme suivante.

$$\Lambda_t^{\Phi_t}(\cdot) := \mathbb{E}(L_t(\cdot, \Phi_t(\cdot), \mathbf{W}_{t+1})),$$

*(coût instantané en  $(t, \cdot)$  lorsque le feedback  $\Phi_t$  est appliqué)*

# Réponse

Indépendance vis-à-vis de la condition initiale

On aboutit à la **formulation distribuée** [Witsenhausen, 1973] du **problème original** :

$$\min_{\Phi, \mu} \sum_{t=t_0}^{T-1} \langle \Lambda_t^{\Phi_t}, \mu_t \rangle + \langle K, \mu_T \rangle,$$

s.c.  $\mu_{t_0}$  donné,

$$\mu_{t+1} = (A_t^{\Phi_t})^* \mu_t, \quad \forall t \geq t_0, \quad (\text{Fokker-Planck})$$

⇨ Contrôle optimal **déterministe en dimension infinie**.

⇨ **Linéaire en les  $\mu_t$ ,  $t = t_0, \dots, T$** , non-linéaire en les  $\Phi_t$ ,  $t = t_0, \dots, T - 1$ .

# Réponse

Indépendance vis-à-vis de la condition initiale

On aboutit à la **formulation distribuée** [Witsenhausen, 1973] du **problème original** :

$$\min_{\Phi, \mu} \sum_{t=t_0}^{T-1} \langle \Lambda_t^{\Phi_t}, \mu_t \rangle + \langle K, \mu_T \rangle,$$

s.c.  $\mu_{t_0}$  donné,

$$\mu_{t+1} = (A_t^{\Phi_t})^* \mu_t, \quad \forall t \geq t_0, \quad (\text{Fokker-Planck})$$

↪ Contrôle optimal **déterministe en dimension infinie**.

↪ **Linéaire** en les  $\mu_t, t = t_0, \dots, T$ , non-linéaire en les  $\Phi_t, t = t_0, \dots, T - 1$ .

# Réponse

Indépendance vis-à-vis de la condition initiale

On aboutit à la **formulation distribuée** [Witsenhausen, 1973] du **problème original** :

$$\min_{\Phi, \mu} \sum_{t=t_0}^{T-1} \langle \Lambda_t^{\Phi_t}, \mu_t \rangle + \langle K, \mu_T \rangle,$$

s.c.  $\mu_{t_0}$  donné,

$$\mu_{t+1} = (A_t^{\Phi_t})^* \mu_t, \quad \forall t \geq t_0, \quad (\text{Fokker-Planck})$$

↪ Contrôle optimal **déterministe en dimension infinie**.

↪ **Linéaire en les**  $\mu_t$ ,  $t = t_0, \dots, T$ , non-linéaire en les  $\Phi_t$ ,  $t = t_0, \dots, T - 1$ .

# Réponse

Indépendance vis-à-vis de la condition initiale

## Résolution du problème distribué par programmation dynamique

$$\begin{aligned} \mathcal{V}_T(\mu) &= \langle K, \mu \rangle, \\ \mathcal{V}_{T-1}(\mu) &= \min_{\Phi} \langle \Lambda_{T-1}^{\Phi}, \mu \rangle + \mathcal{V}_T \left( (A_{T-1}^{\Phi})^* \mu \right). \end{aligned}$$

Le feedback optimal  $\Gamma_{T-1}^{\sharp} : \mu \rightarrow \Phi_{\mu}^{\sharp}(\cdot)$  **dépend a priori de  $x$  et de  $\mu$ .**

$$\begin{aligned} \mathcal{V}_{T-1}(\mu) &= \min_{\Phi} \langle \Lambda_{T-1}^{\Phi} + A_{T-1}^{\Phi} K, \mu \rangle. \\ &= \min_{\Phi(\cdot)} \int_{\mathbb{X}} (\Lambda_{T-1}^{\Phi} + A_{T-1}^{\Phi} K)(x) \mu(dx). \end{aligned}$$

La minimisation peut se faire “x par x”.



# Réponse

Indépendance vis-à-vis de la condition initiale

## Résolution du problème distribué par programmation dynamique

$$\begin{aligned} \mathcal{V}_T(\mu) &= \langle K, \mu \rangle, \\ \mathcal{V}_{T-1}(\mu) &= \min_{\Phi} \langle \Lambda_{T-1}^{\Phi}, \mu \rangle + \mathcal{V}_T \left( (A_{T-1}^{\Phi})^* \mu \right). \end{aligned}$$

Le feedback optimal  $\Gamma_{T-1}^{\sharp} : \mu \rightarrow \Phi_{\mu}^{\sharp}(\cdot)$  **dépend a priori de  $x$  et de  $\mu$ .**

$$\begin{aligned} \mathcal{V}_{T-1}(\mu) &= \min_{\Phi} \langle \Lambda_{T-1}^{\Phi} + A_{T-1}^{\Phi} K, \mu \rangle. \\ &= \min_{\Phi(\cdot)} \int_{\mathbb{X}} (\Lambda_{T-1}^{\Phi} + A_{T-1}^{\Phi} K)(x) \mu(dx). \end{aligned}$$

La minimisation peut se faire “ $x$  par  $x$ ”.

## Conclusion partielle

L'interversion de l'intégrale et de la minimisation conduit à :

- des **feedbacks optimaux ne dépendant plus de**  $\mu : \Gamma_{T-1}^\# \equiv \Phi_\mu^\#$
  - $\mathcal{V}_{T-1}$  ne dépend de  $\mu$  que de façon multiplicative.
- On est à nouveau dans le **cas très particulier de l'observation 1**.

La classe de problèmes considérée n'est pas si générale !

# Plusieurs types de contraintes en optimisation stochastique

On peut faire face à des contraintes :

- presque-sûres :  $g(\mathbf{X}_T) \leq a$ ;
- en probabilité :  $\mathbb{P}(g(\mathbf{X}_T) \leq a) \geq p$ ;
- en espérance :  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$ ;
- ...

Les contraintes en probabilité peuvent être mises sous la forme de contraintes en espérance :

$$\mathbb{P}(g(\mathbf{X}_T) \leq a) = \mathbb{E}(\mathbf{1}_{\mathbb{X}^{\text{ad}}}(\mathbf{X}_T)),$$

avec  $\mathbb{X}^{\text{ad}} = \{x \in \mathbb{X}, g(x) \leq a\}$ .

# Plusieurs types de contraintes en optimisation stochastique

On peut faire face à des contraintes :

- presque-sûres :  $g(\mathbf{X}_T) \leq a$ ;
- en probabilité :  $\mathbb{P}(g(\mathbf{X}_T) \leq a) \geq p$ ;
- en espérance :  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$ ;
- ...

Les contraintes en probabilité peuvent être mises sous la forme de contraintes en espérance :

$$\mathbb{P}(g(\mathbf{X}_T) \leq a) = \mathbb{E}(\mathbf{1}_{\mathbb{X}^{\text{ad}}}(\mathbf{X}_T)),$$

avec  $\mathbb{X}^{\text{ad}} = \{x \in \mathbb{X}, g(x) \leq a\}$ .

↳ Contraintes en proba

# Plusieurs types de contraintes en optimisation stochastique

On peut faire face à des contraintes :

- presque-sûres :  $g(\mathbf{X}_T) \leq a$ ;
- en probabilité :  $\mathbb{P}(g(\mathbf{X}_T) \leq a) \geq p$ ;
- en espérance :  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$ ;
- ...

Les contraintes en probabilité peuvent être mises sous la forme de contraintes en espérance :

$$\mathbb{P}(g(\mathbf{X}_T) \leq a) = \mathbb{E}(\mathbf{1}_{\mathbb{X}^{\text{ad}}}(\mathbf{X}_T)),$$

avec  $\mathbb{X}^{\text{ad}} = \{x \in \mathbb{X}, g(x) \leq a\}$ .

▶ Contraintes en proba

- Les contraintes en  $\mathbb{P}$  apportent des difficultés supplémentaires [Prekopa, 1995].

# Plusieurs types de contraintes en optimisation stochastique

On peut faire face à des contraintes :

- presque-sûres :  $g(\mathbf{X}_T) \leq a$ ;
- en probabilité :  $\mathbb{P}(g(\mathbf{X}_T) \leq a) \geq p$ ;
- en espérance :  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$ ;
- ...

Les contraintes en probabilité peuvent être mises sous la forme de contraintes en espérance :

$$\mathbb{P}(g(\mathbf{X}_T) \leq a) = \mathbb{E}(\mathbf{1}_{\mathbb{X}^{\text{ad}}}(\mathbf{X}_T)),$$

avec  $\mathbb{X}^{\text{ad}} = \{x \in \mathbb{X}, g(x) \leq a\}$ .

► Contraintes en proba

- Les contraintes en  $\mathbb{P}$  apportent des difficultés supplémentaires [Prékopa, 1995].
- La difficulté qui nous intéresse est commune à  $\mathbb{P}$  et  $\mathbb{E}$ .
- On se concentre par la suite sur les contraintes en espérance.

# Plusieurs types de contraintes en optimisation stochastique

On peut faire face à des contraintes :

- presque-sûres :  $g(\mathbf{X}_T) \leq a$  ;
- en probabilité :  $\mathbb{P}(g(\mathbf{X}_T) \leq a) \geq p$  ;
- en espérance :  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$  ;
- ...

Les contraintes en probabilité peuvent être mises sous la forme de contraintes en espérance :

$$\mathbb{P}(g(\mathbf{X}_T) \leq a) = \mathbb{E}(\mathbf{1}_{\mathbb{X}^{\text{ad}}}(\mathbf{X}_T)),$$

avec  $\mathbb{X}^{\text{ad}} = \{x \in \mathbb{X}, g(x) \leq a\}$ .

► Contraintes en proba

- Les contraintes en  $\mathbb{P}$  apportent des difficultés supplémentaires [Prékopa, 1995].
- La difficulté qui nous intéresse est commune à  $\mathbb{P}$  et  $\mathbb{E}$ .

↪ On se concentre par la suite sur les contraintes en espérance.

# Plusieurs types de contraintes en optimisation stochastique

On peut faire face à des contraintes :

- presque-sûres :  $g(\mathbf{X}_T) \leq a$  ;
- en probabilité :  $\mathbb{P}(g(\mathbf{X}_T) \leq a) \geq p$  ;
- en espérance :  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$  ;
- ...

Les contraintes en probabilité peuvent être mises sous la forme de contraintes en espérance :

$$\mathbb{P}(g(\mathbf{X}_T) \leq a) = \mathbb{E}(\mathbf{1}_{\mathbb{X}^{\text{ad}}}(\mathbf{X}_T)),$$

avec  $\mathbb{X}^{\text{ad}} = \{x \in \mathbb{X}, g(x) \leq a\}$ .

► Contraintes en proba

- Les contraintes en  $\mathbb{P}$  apportent des difficultés supplémentaires [Prékopa, 1995].
- La difficulté qui nous intéresse est commune à  $\mathbb{P}$  et  $\mathbb{E}$ .

↪ On se concentre par la suite sur les contraintes en espérance.



# Plusieurs types de contraintes en optimisation stochastique

On peut faire face à des contraintes :

- presque-sûres :  $g(\mathbf{X}_T) \leq a$  ;
- en probabilité :  $\mathbb{P}(g(\mathbf{X}_T) \leq a) \geq p$  ;
- en espérance :  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$  ;
- ...

Les contraintes en probabilité peuvent être mises sous la forme de contraintes en espérance :

$$\mathbb{P}(g(\mathbf{X}_T) \leq a) = \mathbb{E}(\mathbf{1}_{\mathbb{X}^{\text{ad}}}(\mathbf{X}_T)),$$

avec  $\mathbb{X}^{\text{ad}} = \{x \in \mathbb{X}, g(x) \leq a\}$ .

► Contraintes en proba

- Les contraintes en  $\mathbb{P}$  apportent des difficultés supplémentaires [Prékopa, 1995].
  - La difficulté qui nous intéresse est commune à  $\mathbb{P}$  et  $\mathbb{E}$ .
- ↪ On se concentre par la suite sur les contraintes en espérance.

# Ajout d'une contrainte en espérance

Problème partant de  $t_0$

$$\min_{\mathbf{X}, \mathbf{U}} \mathbb{E} \left( \sum_{t=t_0}^{T-1} L_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}) + K(\mathbf{X}_T) \right), \quad (1a)$$

$$\text{s.c. } \mathbb{E}(g(\mathbf{X}_T) \leq a), \quad (1b)$$

et, pour tout  $t = t_0, \dots, T - 1$  :

$$\mathbf{X}_{t_0} \text{ donné,} \quad (1c)$$

$$\mathbf{X}_{t+1} = f_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}), \quad (1d)$$

$$\mathbf{U}_t \text{ est } \sigma\{\mathbf{X}_{t_0}, \mathbf{W}_{t_1}, \dots, \mathbf{W}_t\}\text{-mesurable.} \quad (1e)$$

# Formulation distribuée

## Problème équivalent

$$\begin{aligned} \min_{\Phi, \mu} \quad & \sum_{t=t_0}^{T-1} \langle \Lambda_t^{\Phi_t}, \mu_t \rangle + \langle K, \mu_T \rangle, \\ \text{s.c.} \quad & \langle g, \mu_T \rangle \leq a, \\ & \mu_{t_0} \text{ donné,} \\ & \mu_{t+1} = (A_t^{\Phi_t})^* \mu_t, \quad \forall t = t_0, \dots, T-1. \end{aligned}$$

On peut inclure la contrainte dans la fonction coût avec :

$$\chi_{\{\langle g, \mu_T \rangle \leq a\}}.$$

- La mesure  $\mu_{t_0}$  n'intervient plus de manière linéaire.
- On perd la propriété d'indépendance à la condition initiale.

Les feedbacks optimaux dépendent maintenant, en général, de  $\mu_{t_0}$ .

# Formulation distribuée

## Problème équivalent

$$\begin{aligned} \min_{\Phi, \mu} \quad & \sum_{t=t_0}^{T-1} \langle \Lambda_t^{\Phi_t}, \mu_t \rangle + \langle K, \mu_T \rangle, \\ \text{s.c.} \quad & \langle g, \mu_T \rangle \leq a, \\ & \mu_{t_0} \text{ donné,} \\ & \mu_{t+1} = (A_t^{\Phi_t})^* \mu_t, \quad \forall t = t_0, \dots, T-1. \end{aligned}$$

On peut inclure la contrainte dans la fonction coût avec :

$$\chi_{\{\langle g, \mu_T \rangle \leq a\}}.$$

- La mesure  $\mu_{t_0}$  n'intervient plus de manière linéaire.
- On perd la propriété d'indépendance à la condition initiale.

Les feedbacks optimaux dépendent maintenant, en général, de  $\mu_{t_0}$ .

# Formulation distribuée

## Problème équivalent

$$\min_{\Phi, \mu} \sum_{t=t_0}^{T-1} \langle \Lambda_t^{\Phi_t}, \mu_t \rangle + \langle K, \mu_T \rangle,$$

$$\text{s.c. } \langle g, \mu_T \rangle \leq a,$$

$$\mu_{t_0} \text{ donné,}$$

$$\mu_{t+1} = (A_t^{\Phi_t})^* \mu_t, \quad \forall t = t_0, \dots, T-1.$$

On peut inclure la contrainte dans la fonction coût avec :

$$\chi_{\{\langle g, \mu_T \rangle \leq a\}}.$$

- La mesure  $\mu_{t_0}$  n'intervient plus de manière linéaire.
- On perd la propriété d'indépendance à la condition initiale.

**Les feedbacks optimaux dépendent maintenant, en général, de  $\mu_{t_0}$ .**

## Retour à la consistance

Si on résout le problème **déterministe** précédent, on obtient une suite de feedbacks  $(\Phi_{t_0}^\#, \dots, \Phi_{T-1}^\#)$ .

- On a consistance dynamique si les  $\mu$  suivent Fokker-Planck.
- Or, à l'instant  $t$ , la meilleure observation de la loi de  $X_t$  est le Dirac !

Réolvons le problème par programmation dynamique :

$$\begin{aligned} \mathcal{V}_T(\mu) &= \langle K, \mu \rangle + \chi_{\{(g, \mu) \leq a\}}(\mu), \\ \mathcal{V}_{T-1}(\mu) &= \min_{\phi} \langle \Lambda_{T-1}^\phi, \mu \rangle + \mathcal{V}_T((A_{T-1}^\phi)^* \mu), \end{aligned}$$

- On obtient des feedbacks  $\Gamma_t^\#$  dépendant de  $x$  et de  $\mu$ .
- On retrouve la consistance dynamique.
- Mais la variable d'état est de dimension infinie.

## Retour à la consistance

Si on résout le problème **déterministe** précédent, on obtient une suite de feedbacks  $(\Phi_{t_0}^\#, \dots, \Phi_{T-1}^\#)$ .

- On a consistance dynamique si les  $\mu$  suivent Fokker-Planck.
- Or, à l'instant  $t$ , la meilleure observation de la loi de  $\mathbf{X}_t$  est le Dirac !

Résolvons le problème par programmation dynamique :

$$\mathcal{V}_T(\mu) = \langle K, \mu \rangle + \chi_{\{\langle g, \mu \rangle \leq a\}}(\mu),$$

$$\mathcal{V}_{T-1}(\mu) = \min_{\phi} \langle \Lambda_{T-1}^\phi, \mu \rangle + \mathcal{V}_T((A_{T-1}^\phi)^* \mu),$$

- On obtient des feedbacks  $\Gamma_t^\#$  dépendant de  $x$  et de  $\mu$ .
- On retrouve la consistance dynamique.
- Mais la variable d'état est de dimension infinie.

## Retour à la consistance

Si on résout le problème **déterministe** précédent, on obtient une suite de feedbacks  $(\Phi_{t_0}^\#, \dots, \Phi_{T-1}^\#)$ .

- On a consistance dynamique si les  $\mu$  suivent Fokker-Planck.
- Or, à l'instant  $t$ , la meilleure observation de la loi de  $\mathbf{X}_t$  est le Dirac !

Résolvons le problème par programmation dynamique :

$$\mathcal{V}_T(\mu) = \langle K, \mu \rangle + \chi_{\{\langle g, \mu \rangle \leq a\}}(\mu),$$

$$\mathcal{V}_{T-1}(\mu) = \min_{\phi} \langle \Lambda_{T-1}^\phi, \mu \rangle + \mathcal{V}_T((A_{T-1}^\phi)^* \mu),$$

- On obtient des feedbacks  $\Gamma_t^\#$  dépendant de  $x$  et de  $\mu$ .
- On retrouve la consistance dynamique.
- Mais la variable d'état est de dimension infinie.



## Retour à la consistance

Si on résout le problème **déterministe** précédent, on obtient une suite de feedbacks  $(\Phi_{t_0}^\#, \dots, \Phi_{T-1}^\#)$ .

- On a consistance dynamique si les  $\mu$  suivent Fokker-Planck.
- Or, à l'instant  $t$ , la meilleure observation de la loi de  $\mathbf{X}_t$  est le Dirac !

Résolvons le problème par programmation dynamique :

$$\mathcal{V}_T(\mu) = \langle K, \mu \rangle + \chi_{\{\langle g, \mu \rangle \leq a\}}(\mu),$$

$$\mathcal{V}_{T-1}(\mu) = \min_{\phi} \langle \Lambda_{T-1}^{\phi}, \mu \rangle + \mathcal{V}_T\left((A_{T-1}^{\phi})^* \mu\right),$$

- On obtient des feedbacks  $\Gamma_t^\#$  dépendant de  $x$  et de  $\mu$ .
- On retrouve la consistance dynamique.
- Mais la variable d'état est de dimension infinie.

## Retour à la consistance

Si on résout le problème **déterministe** précédent, on obtient une suite de feedbacks  $(\Phi_{t_0}^\#, \dots, \Phi_{T-1}^\#)$ .

- On a consistance dynamique si les  $\mu$  suivent Fokker-Planck.
- Or, à l'instant  $t$ , la meilleure observation de la loi de  $\mathbf{X}_t$  est le Dirac !

Résolvons le problème par programmation dynamique :

$$\mathcal{V}_T(\mu) = \langle K, \mu \rangle + \chi_{\{\langle g, \mu \rangle \leq a\}}(\mu),$$

$$\mathcal{V}_{T-1}(\mu) = \min_{\phi} \langle \Lambda_{T-1}^{\phi}, \mu \rangle + \mathcal{V}_T((A_{T-1}^{\phi})^* \mu),$$

- On obtient des feedbacks  $\Gamma_t^\#$  dépendant de  $x$  et de  $\mu$ .
- On retrouve la consistance dynamique.
- Mais la variable d'état est de dimension infinie.

# Conclusion

- Pour une large classe de problèmes de commande optimale, **la notion de consistance est très liée à la définition d'un état.**
- En général, le **feedback doit dépendre de la loi** de la variable d'état "usuelle".

- Remarquons que nous avons choisi de ne pas modifier le niveau de contrainte :

$$\mathbb{E}(g(\mathbf{X}_T)) \leq a, \quad \forall t_i \geq t_0.$$

- La dernière programmation dynamique introduite n'est **pas soluble en pratique** : les lois sont des objets de dimension infinie.

# Conclusion

- Pour une large classe de problèmes de commande optimale, **la notion de consistance est très liée à la définition d'un état.**
- En général, le **feedback doit dépendre de la loi** de la variable d'état "usuelle".
- Remarquons que nous avons choisi de ne pas modifier le niveau de contrainte :

$$\mathbb{E}(g(\mathbf{X}_T)) \leq a, \quad \forall t_i \geq t_0.$$

- La dernière programmation dynamique introduite n'est **pas soluble en pratique** : les lois sont des objets de dimension infinie.

• Retour à la dimension finie

# Conclusion

- Pour une large classe de problèmes de commande optimale, **la notion de consistance est très liée à la définition d'un état.**
- En général, le **feedback doit dépendre de la loi** de la variable d'état "usuelle".
- Remarquons que nous avons choisi de ne pas modifier le niveau de contrainte :

$$\mathbb{E} (g(\mathbf{X}_T)) \leq a, \quad \forall t_i \geq t_0.$$

- La dernière programmation dynamique introduite n'est **pas soluble en pratique** : les lois sont des objets de dimension infinie.

► Retour à la dimension finie

# Conclusion

- Pour une large classe de problèmes de commande optimale, **la notion de consistance est très liée à la définition d'un état.**
- En général, le **feedback doit dépendre de la loi** de la variable d'état "usuelle".
- Remarquons que nous avons choisi de ne pas modifier le niveau de contrainte :

$$\mathbb{E} (g(\mathbf{X}_T)) \leq a, \quad \forall t_i \geq t_0.$$


- La dernière programmation dynamique introduite n'est **pas soluble en pratique** : les lois sont des objets de dimension infinie.

► Retour à la dimension finie

# Plan

- 1 Motivation
  - Formulation du problème
  - Mesures de risque dynamiques
  - Notion de consistance
- 2 Programmation Dynamique et Consistance
  - Cas déterministe
  - Cas stochastique sans contrainte de risque
  - Cas stochastique avec contrainte de risque
- 3 Exemples

# Retour sur le problème de Haviv




Il faut préciser comment réécrire la contrainte :

$$\mathbb{P}(S_1 \cup S_2 \cup S_3) \leq 0.125,$$

au second pas de temps.



# Retour sur le problème de Haviv




Une réécriture (naturelle ?) de la  
 contrainte en y est :

$$0.5 \times \mathbb{P}(S_2 \cup S_3) \leq \underbrace{0.125 - 0.5 \times \mathbb{P}(S_1)}_{0.025},$$

soit :


$$\mathbb{P}(S_2 \cup S_3) \leq 0.05.$$


# Retour sur le problème de Haviv





Vu de  $x$  comme de  $y$ , l'action  $b$  est alors non-admissible.


# Références I


- 

Artzner, P., Delbaen, F., Eber, J.-M., Heath, D., and Ku, H. (2007).  
 Coherent multiperiod risk-adjusted values and Bellman's principle.  
*Annals of Operations Research*, 152(1) :5–22.
- 

Bouchard, B., Elie, R., and Touzi, N. (2009).  
 Stochastic target problems with controlled loss.  
*SIAM Journal on Control and Optimization*, 48(5) :3123–3150.
- 

Carpentier, P., Chancelier, J.-P., Cohen, G., De Lara, M., and Girardeau, P. (2010).  
 Dynamic consistency for stochastic optimal control problems.  
 arXiv :1005.3605.
- 

Cheridito, P., Delbaen, F., and Kupper, M. (2006).  
 Dynamic monetary risk measures for bounded discrete-time processes.  
*Electronic Journal of Probability*, 11(3) :57–106.
- 

Detlefsen, K. and Scandolo, G. (2005).  
 Conditional and dynamic convex risk measures.  
*Finance and Stochastics*, 9(4) :539–561.
- 

Ekeland, I. and Lazrak, A. (2006).  
 Being serious about non-commitment : subgame perfect equilibrium in continuous time.  
 arXiv, math.OC 0604264.

## Références II



Haviv, M. (1996).  
On constrained Markov decision processes.  
*Operations Research Letters*, 19 :25–28.



Prékopa, A. (1995).  
*Stochastic Programming*.  
Kluwer, Dordrecht.



Ruszczynski, A. (2009).  
Risk-averse dynamic programming for markov decision processes.  
*Optimization Online*, to appear in *Mathematical Programming*.



Shapiro, A. (2009).  
On a time consistency concept in risk averse multistage stochastic programming.  
*Operations Research Letters*, 37(3) :143 – 147.



Whittle, P. (1982).  
*Optimization over time*.  
John Wiley & Sons.



Witsenhausen, H. S. (1973).  
A standard form for sequential stochastic control.  
*Mathematical Systems Theory*, 7(1) :5–11.

# Contraintes en probabilité

## Contraintes en probabilité jointes

Plutôt que  $\mathbb{P}(h(\mathbf{X}_T) \geq b) \leq a$ , on peut s'intéresser à :

$$\mathbb{P}(h_t(\mathbf{X}_t) \geq b_t, \forall t = t_1, \dots, T) \leq a.$$

Via l'introduction d'une variable aléatoire supplémentaire à valeurs binaires :

$$\begin{aligned} \mathbf{Y}_{t_0} &= 1, \\ \mathbf{Y}_{t+1} &= \mathbf{Y}_t \times \mathbf{1}_{\{h_{t+1}(\mathbf{x}_{t+1}) \geq b_{t+1}\}}, \quad \forall t = t_0, \dots, T-1, \end{aligned}$$

elle s'écrit alors :  $\mathbb{E}(\mathbf{Y}_T) \leq a$ .

► Retour

# Retour à la dimension finie I

## Problème équivalent

- Idée de [Bouchard et al., 2009] adaptée au temps discret.
- Consiste à ajouter une commande  $\mathbf{V}_t$  et un état  $\mathbf{Z}_t$ .

$$\min_{\mathbf{x}, \mathbf{z}, \mathbf{u}, \mathbf{v}} \mathbb{E} \left( \sum_{t=t_0}^{T-1} L_t(\mathbf{x}_t, \mathbf{u}_t, \mathbf{w}_{t+1}) + K(\mathbf{x}_T) \right), \quad (2a)$$

sous les contraintes dynamiques sur  $\mathbf{X}$  :

$$\mathbf{X}_{t_0} = x_{t_0}, \quad (2b)$$

$$\mathbf{X}_{t+1} = f_t(\mathbf{X}_t, \mathbf{U}_t, \mathbf{W}_{t+1}), \quad \forall t = t_0, \dots, T-1, \quad (2c)$$

les contraintes de non-anticipativité :

$$\mathbf{U}_t \preceq \mathcal{A}_t, \quad \forall t = t_0, \dots, T-1, \quad (2d)$$

# Retour à la dimension finie II

## Problème équivalent

les contraintes dynamiques sur  $\mathbf{Z}$  :

$$\mathbf{Z}_{t_0} = 0, \quad (2e)$$

$$\mathbf{Z}_{t+1} = \mathbf{Z}_t + \mathbf{V}_t, \quad \forall t = t_0, \dots, T-1, \quad (2f)$$

les contraintes de non-anticipativité :

$$\mathbf{V}_t \preceq \mathcal{A}_{t+1}, \quad \forall t = t_0, \dots, T-1, \quad (2g)$$

la contrainte presque-sûre portant sur l'instant final :

$$g(\mathbf{X}_T) - \mathbf{Z}_T \leq a, \quad \mathbb{P}\text{-p.s.}, \quad (2h)$$

et les contraintes intermédiaires sur les nouvelles commandes :

$$\mathbb{E}(\mathbf{V}_t \mid \mathcal{A}_t) = 0, \quad \forall t = t_0, \dots, T-1. \quad (2i)$$

# Retour à la dimension finie III

Équivalence avec le problème original : (1)  $\subset$  (2)

Soient  $(\mathbf{U}_{t_0}, \dots, \mathbf{U}_{T-1})$  et  $(\mathbf{X}_{t_0}, \dots, \mathbf{X}_T)$  satisfaisant (1). On définit  $\mathbf{Z}$  et  $\mathbf{V}$  par :

$$\begin{aligned} \mathbf{Z}_{t_0} &= 0, \\ \mathbf{Z}_{t+1} &= \mathbf{Z}_t + \mathbf{V}_t, \quad \forall t \geq t_0, \\ \mathbf{V}_t &= \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_{t+1}) - \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_t), \quad \forall t \geq t_0. \end{aligned}$$

Par sommation, on obtient la relation :

$$\mathbf{Z}_T = g(\mathbf{X}_T) - \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_{t_0}) = g(\mathbf{X}_T) - \mathbb{E}(g(\mathbf{X}_T)) \geq g(\mathbf{X}_T) - a.$$

Les processus  $\mathbf{X}$ ,  $\mathbf{Z}$ ,  $\mathbf{U}$  et  $\mathbf{V}$  vérifient donc bien les contraintes de (2).



# Retour à la dimension finie III

Équivalence avec le problème original : (1)  $\subset$  (2)

Soient  $(\mathbf{U}_{t_0}, \dots, \mathbf{U}_{T-1})$  et  $(\mathbf{X}_{t_0}, \dots, \mathbf{X}_T)$  satisfaisant (1). On définit  $\mathbf{Z}$  et  $\mathbf{V}$  par :

$$\begin{aligned} \mathbf{Z}_{t_0} &= 0, \\ \mathbf{Z}_{t+1} &= \mathbf{Z}_t + \mathbf{V}_t, \quad \forall t \geq t_0, \\ \mathbf{V}_t &= \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_{t+1}) - \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_t), \quad \forall t \geq t_0. \end{aligned}$$

Par sommation, on obtient la relation :

$$\mathbf{Z}_T = g(\mathbf{X}_T) - \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_{t_0}) = g(\mathbf{X}_T) - \mathbb{E}(g(\mathbf{X}_T)) \geq g(\mathbf{X}_T) - a.$$

Les processus  $\mathbf{X}$ ,  $\mathbf{Z}$ ,  $\mathbf{U}$  et  $\mathbf{V}$  vérifient donc bien les contraintes de (2).

## Retour à la dimension finie III

Équivalence avec le problème original : (1)  $\subset$  (2)

Soient  $(\mathbf{U}_{t_0}, \dots, \mathbf{U}_{T-1})$  et  $(\mathbf{X}_{t_0}, \dots, \mathbf{X}_T)$  satisfaisant (1). On définit  $\mathbf{Z}$  et  $\mathbf{V}$  par :

$$\begin{aligned} \mathbf{Z}_{t_0} &= 0, \\ \mathbf{Z}_{t+1} &= \mathbf{Z}_t + \mathbf{V}_t, \quad \forall t \geq t_0, \\ \mathbf{V}_t &= \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_{t+1}) - \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_t), \quad \forall t \geq t_0. \end{aligned}$$

Par sommation, on obtient la relation :

$$\mathbf{Z}_T = g(\mathbf{X}_T) - \mathbb{E}(g(\mathbf{X}_T) \mid \mathcal{A}_{t_0}) = g(\mathbf{X}_T) - \mathbb{E}(g(\mathbf{X}_T)) \geq g(\mathbf{X}_T) - a.$$

Les processus  $\mathbf{X}$ ,  $\mathbf{Z}$ ,  $\mathbf{U}$  et  $\mathbf{V}$  vérifient donc bien les contraintes de (2).

# Retour à la dimension finie IV

Équivalence avec le problème original : (2)  $\subset$  (1)

Soient des processus  $\mathbf{X}$ ,  $\mathbf{Z}$ ,  $\mathbf{U}$  et  $\mathbf{V}$  vérifiant les contraintes de (2). On remarque que  $\mathbf{Z}_T = \sum_{t=t_0}^{T-1} \mathbf{V}_t$ , d'où :

$$\mathbb{E}(\mathbf{Z}_T) = \sum_{t=t_0}^{T-1} \mathbb{E}(\mathbb{E}(\mathbf{V}_t \mid \mathcal{A}_t)) = 0.$$

Comme, par hypothèse, on a que  $g(\mathbf{X}_T) - \mathbf{Z}_T \leq a$ , on en déduit que  $\mathbb{E}(g(\mathbf{X}_T)) \leq a$ , ce qui montre que les processus  $\mathbf{X}$  et  $\mathbf{U}$  vérifient les contraintes du problème (1).

Les deux problèmes ont même ensemble admissible et même critère, d'où l'équivalence.

# Retour à la dimension finie $V$

La contrainte  $\mathbb{E}(\mathbf{V}_t \mid \mathcal{A}_t) = 0$  ne pose pas de problème à la programmation dynamique

## Cadre simplifié

On se donne :

- une variable  $\mathbf{X}$  mesurable par rapport à  $\mathcal{G} := \sigma(\mathbf{Y})$ ,
- une variable  $\mathbf{W}$  indépendante de  $\mathbf{Y}$ ,
- la tribu  $\mathcal{F}$  engendrée par  $(\mathbf{Y}, \mathbf{W})$ .

On cherche à résoudre :

$$\min_{\mathbf{U} \preceq_{\mathcal{F}}} \mathbb{E}(j(\mathbf{X}, \mathbf{U}, \mathbf{W}) \mid \mathcal{G}) \quad \text{sous} \quad \mathbb{E}(\mathbf{U} \mid \mathcal{G}) = 0.$$

## Théorème

Il existe une solution  $\mathbf{U}^\#$  du problème telle que  $\mathbf{U}^\#$  soit mesurable par rapport au couple  $(\mathbf{X}, \mathbf{W})$ .

# Retour à la dimension finie VI

Preuve dans le cas où  $\mathbf{Y}$  est finie

- On note  $y_1, \dots, y_N$  les valeurs que prend  $\mathbf{Y}$ .
- Le problème est formé de  $N$  sous-problèmes d'optimisation indépendants :

$$\min_{\mathbf{U} \preceq (\mathbf{Y}, \mathbf{W})} \mathbb{E} \left( j(\mathbf{X}, \mathbf{U}, \mathbf{W}) \mid \mathbf{Y} = y_i \right) \quad \text{sous} \quad \mathbb{E}(\mathbf{U} \mid \mathbf{Y} = y_i) = 0.$$

$\mathbf{X}$  mesurable par rapport à  $\mathbf{Y} \Rightarrow \exists \vartheta$  mesurable telle que  $\mathbf{X} = \vartheta(\mathbf{Y})$  ;  
 on note  $x_i = \vartheta(y_i)$ .

- $\mathbf{U}$  mesurable par rapport à  $(\mathbf{Y}, \mathbf{W}) \Rightarrow$

$$\mathbf{U} = \sum_{i=1}^N \mathbf{U}_i \mathbf{1}_{\{\mathbf{Y}=y_i\}},$$

où chaque  $\mathbf{U}_i$  est mesurable par rapport à  $\mathbf{W}$ .

# Retour à la dimension finie VII

Preuve dans le cas où  $Y$  est finie

- Le problème “ $i$ ” se met sous la forme :

$$\min_{\mathbf{U}_i \preceq \mathbf{W}} \mathbb{E}(j(x_i, \mathbf{U}_i, \mathbf{W})) \quad \text{sous} \quad \mathbb{E}(\mathbf{U}_i) = 0.$$

La solution  $\mathbf{U}_i^\sharp$  de ce dernier problème :

- est mesurable par rapport à  $\mathbf{W}$ ,
- dépend paramétriquement de la valeur  $x_i$  (plutôt que de  $y_i$ ).

On en déduit que toute solution  $\mathbf{U}^\sharp$  du problème de départ se met sous la forme :

$$\mathbf{U}^\sharp = \sum_{i=1}^N \mathbf{U}_i^\sharp \mathbf{1}_{\{\mathbf{x}=x_i\}},$$

et donc que  $\mathbf{U}^\sharp$  est mesurable par rapport à  $(\mathbf{X}, \mathbf{W})$ .

▶ Retour