

# Quelques propriétés asymptotiques en planification séquentielle d'expériences

Luc Pronzato

Laboratoire I3S, Sophia Antipolis, France

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

## Pourquoi planifier séquentiellement ?

Modèle de régression  $\eta(x, \theta)$ , non linéaire en  $\theta \Rightarrow$  l'expérience optimale pour estimer  $\theta$  dépend de  $\theta$  !

Matrice d'information  $\mathbf{M}(\xi, \theta) = \int_{\mathcal{X}} \mathbf{f}_{\theta}(x) \mathbf{f}_{\theta}^{\top}(x) \xi(dx)$  avec

- ▶  $\xi$  une mesure de probabilité sur  $\mathcal{X}$
- ▶  $\mathbf{f}_{\theta}(x) = \frac{1}{\sigma} \frac{\partial \eta(x, \theta)}{\partial \theta}$

$\xi_D^*(\theta)$  est *D*-optimal pour  $\theta$  :  $\xi_D^*(\theta)$  maximise  $\log \det[\mathbf{M}(\xi, \theta)]$


## Exemples

- [Box & Lucas, 1959] :

$$\eta(x, \theta) = \frac{\theta_1}{\theta_1 - \theta_2} [\exp(-\theta_2 x) - \exp(-\theta_1 x)]$$

→ pour  $\theta = (0.7, 0.2)^\top$ ,  $\xi_D^* = \frac{1}{2}\delta_{x^{(1)}} + \frac{1}{2}\delta_{x^{(2)}}$  avec  $x^{(1)} \simeq 1.25$  et  $x^{(2)} \simeq 6.60$

$x^{(1)}$  et  $x^{(2)}$  pour  $\theta_1 \in [0.5, 0.9]$  et  $\theta_2 = 0.2$



- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions

- ▶ Michaelis-Menten :  $\eta(x, \theta) = \frac{\theta_1 x}{\theta_2 + x}$ ,  $x \in (0, \bar{x}]$ ,  $\theta_1, \theta_2 > 0$   
→  $\xi_D^* = \frac{1}{2}\delta_{x(1)} + \frac{1}{2}\delta_{x(2)}$  avec  $x^{(1)} = \frac{\theta_2 \bar{x}}{2\theta_2 + \bar{x}}$  et  $x^{(2)} = \bar{x}$
- ▶ Décroissance exponentielle :  $\eta(x, \theta) = \theta_1 \exp(-\theta_2 x)$ ,  
 $x \geq \underline{x}$ ,  $\theta_1, \theta_2 > 0$   
→  $\xi_D^* = \frac{1}{2}\delta_{x(1)} + \frac{1}{2}\delta_{x(2)}$  avec  $x^{(1)} = \underline{x}$  et  $x^{(2)} = \underline{x} + \frac{1}{\theta_2}$
- ▶ ...

1) Introduction

2) Planification séquentielle  $D$ -optimale

3) Planification  $D$ -optimale avec contrainte

4) Planification séquentielle  $D$ -optimale pénalisée

5) Exemples

6) Conclusions

## Planification totalement séquentielle («full sequential

design») : choisir  $x_1, \dots, x_{n_0}$ , estimer  $\hat{\theta}^{n_0}$ , poser  $k = n_0$  puis

- ▶ planifier  $x_{k+1}$
- ▶ observer  $Y_{k+1}$
- ▶ ré-estimer  $\hat{\theta}^{k+1}$
- ▶  $k \leftarrow k + 1 \dots$

*D*-optimalité :

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \det \left[ \sum_{i=1}^k \mathbf{f}_{\hat{\theta}^k}(x_i) \mathbf{f}_{\hat{\theta}^k}^\top(x_i) + \mathbf{f}_{\hat{\theta}^k}(x) \mathbf{f}_{\hat{\theta}^k}^\top(x) \right]$$

ou encore

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \mathbf{f}_{\hat{\theta}^k}^\top(x) \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k}(x) \quad \text{avec}$$

$\xi_k = \sum_{i=1}^k \delta_{x_i}$  la mesure empirique définie par  $x_1, \dots, x_k$

$$\rightarrow \mathbf{M}(\xi_k, \theta) = \frac{1}{k} \sum_{i=1}^k \mathbf{f}_\theta(x_i) \mathbf{f}_\theta^\top(x_i)$$

On espère que  $\hat{\theta}^n \xrightarrow{\text{p.s.}} \bar{\theta}$  et  $\sqrt{n}(\hat{\theta}^n - \bar{\theta}) \xrightarrow{d} \mathcal{N}(\mathbf{0}, \mathbf{M}^{-1}[\xi_D^*(\bar{\theta}), \bar{\theta}])$

1)  
Introduction

2)  
Planification  
séquentielle  
*D*-optimale

3)  
Planification  
*D*-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
*D*-optimale  
pénalisée

5) Exemples

6) Conclusions

## Estimateur des MC en régression non-linéaire

$Y_i = \eta(x_i, \bar{\theta}) + \varepsilon_i$ ,  $x_i \in \mathcal{X} \subset \mathbb{R}^d$ ,  $\bar{\theta} \in \Theta \subset \mathbb{R}^p$ ,  $\{\varepsilon_i\}$  i.i.d.,  
variance  $\sigma^2$

Estimation par MC:  $\hat{\theta}^n = \operatorname{arg\,min}_{\theta \in \Theta} S_n(\theta)$  avec

$$S_n(\theta) = \sum_{i=1}^n [Y_i - \eta(x_i, \theta)]^2$$

Les conditions pour la convergence forte de  $\hat{\theta}^n$  vers  $\bar{\theta}$  sont très différentes suivant que les  $x_k$  sont des constantes ou dépendent des  $\varepsilon_i$ ,  $i < k$

$\{x_i\}$  = suite déterministe

Définissons  $D_n(\theta, \bar{\theta}) = \sum_{k=1}^n [\eta(x_k, \theta) - \eta(x_k, \bar{\theta})]^2$

[Jennrich 1969]:  $\hat{\theta}^n \xrightarrow{\text{P.S.}} \bar{\theta}$  quand  $D_n(\theta, \theta')/n \rightarrow J(\theta, \theta')$

(uniformément) avec  $J(\theta, \theta')$  continue et  $> 0$  pour tout  $\theta \neq \theta'$

1)  
Introduction

2)  
Planification  
séquentielle  
*D*-optimale

3)  
Planification  
*D*-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
*D*-optimale  
pénalisée

5) Exemples

6) Conclusions

$\hookrightarrow$  pour un modèle linéaire,  $\eta(x, \theta) = \mathbf{f}^\top(x)\theta$  : condition équivalente à  $(1/n)[\mathbf{X}_n^\top \mathbf{X}_n] \rightarrow \mathbf{M}$  définie-positive avec  $\mathbf{X}_n = [\mathbf{f}(x_1), \dots, \mathbf{f}(x_n)]^\top$

$\Rightarrow$  beaucoup plus fort que la CNS pour la CV forte de  $\hat{\theta}^n$  :  $\lambda_{\min}[\mathbf{X}_n^\top \mathbf{X}_n] \rightarrow \infty$

L'analogie de cette CNS en régression non-linéaire serait :  $D_n(\theta, \theta') \rightarrow \infty \forall \theta \neq \theta'$  ([Wu 1981] : suffisant pour  $\hat{\theta}^n \xrightarrow{\text{a.s.}} \bar{\theta}$  quand  $\Theta$  est fini, nécessaire pour l'existence d'un estimateur faiblement convergent)

$x_i$  dépend de  $\varepsilon_{i-1}, \varepsilon_{i-2} \dots$

En particulier : planification séquentielle ( $x_i$  dépend de  $\hat{\theta}^{i-1}$ )

$\Rightarrow$  Régression linéaire

[Lai & Wei 1982] :

$\lambda_{\min}[\mathbf{X}_n^\top \mathbf{X}_n] \xrightarrow{\text{p.s.}} \infty$  et

$\{\log \lambda_{\max}[\mathbf{X}_n^\top \mathbf{X}_n]\}^\rho / \lambda_{\min}[\mathbf{X}_n^\top \mathbf{X}_n] \xrightarrow{\text{p.s.}} 0$  pour un  $\rho > 1$   
 $\Rightarrow \hat{\theta}^n \xrightarrow{\text{p.s.}} \bar{\theta}$  ( $\sim$  condition la plus faible possible)

1)  
Introduction

2)  
Planification  
séquentielle  
D-optimale

3)  
Planification  
D-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
D-optimale  
pénalisée

5) Exemples

6) Conclusions



1)  
Introduction

2)  
Planification  
séquentielle  
*D*-optimale

3)  
Planification  
*D*-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
*D*-optimale  
pénalisée

5) Exemples

6) Conclusions

## ⇒ Régression non-linéaire

[Lai 1994] → CS qui donne pour un modèle linéaire la condition de [Christopeit & Helmes 1980] :

$$\lambda_{\max}[\mathbf{X}_n^T \mathbf{X}_n] = \mathcal{O}\{\lambda_{\min}^{\rho}[\mathbf{X}_n^T \mathbf{X}_n]\} \text{ p.s. pour un } \rho \in (1,2)$$

⇒ Explique pourquoi en planification séquentielle, pour assurer la CV forte de  $\hat{\theta}^n$  on impose un choix déterministe de  $x_k$  quand  $k \in \{k_1, k_2, \dots\}$ , avec  $k_i = i^{\alpha}$ ,  $\alpha \in (1,2)$  [Lai 1994]

Revenons à notre problème...

Planification totalement séquentielle («full sequential

design»): choisir  $x_1, \dots, x_{n_0}$ , estimer  $\hat{\theta}^{n_0}$ , poser  $k = n_0$  puis

- ▶ planifier  $x_{k+1}$
- ▶ observer  $Y_{k+1}$
- ▶ ré-estimer  $\hat{\theta}^{k+1}$
- ▶  $k \leftarrow k + 1 \dots$

*D*-optimalité :

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \det \left[ \sum_{i=1}^k \mathbf{f}_{\hat{\theta}^k}(x_i) \mathbf{f}_{\hat{\theta}^k}^\top(x_i) + \mathbf{f}_{\hat{\theta}^k}(x) \mathbf{f}_{\hat{\theta}^k}^\top(x) \right]$$

ou encore

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \mathbf{f}_{\hat{\theta}^k}^\top(x) \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k}(x) \quad \text{avec}$$

$\xi_k = \sum_{i=1}^k \delta_{x_i}$  la mesure empirique définie par  $x_1, \dots, x_k$

$$\rightarrow \mathbf{M}(\xi_k, \theta) = \frac{1}{k} \sum_{i=1}^k \mathbf{f}_\theta(x_i) \mathbf{f}_\theta^\top(x_i)$$

On espère que  $\hat{\theta}^n \xrightarrow{\text{p.s.}} \bar{\theta}$  et  $\sqrt{n}(\hat{\theta}^n - \bar{\theta}) \xrightarrow{d} \mathcal{N}(\mathbf{0}, \mathbf{M}^{-1}[\xi_D^*(\bar{\theta}), \bar{\theta}])$

- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions

## 2) Planification séquentielle $D$ -optimale

Pour  $n_0 \leq k < n$ ,

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \mathbf{f}_{\hat{\theta}^k}^\top(x) \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k}(x)$$

Comment assurer que  $\hat{\theta}^n \xrightarrow{\text{p.s.}} \bar{\theta}$  et

$\sqrt{n}(\hat{\theta}^n - \bar{\theta}) \xrightarrow{d} \mathcal{N}(\mathbf{0}, \mathbf{M}^{-1}[\xi_D^*(\bar{\theta}), \bar{\theta}])$  quand  $n \rightarrow \infty$ ?

Pas facile au vu de ce qui précède...

- 1) choix déterministe de  $x_k$  quand  $k \in \{k_1, k_2, \dots\}$ , avec  $k_j = i^\alpha$ ,  $\alpha \in (1, 2)$  [Lai 1994]
- 2) faire croître  $n_0$  vers  $+\infty$  en même temps que  $n$
- 3) supposer que  $\mathcal{X}$  est un ensemble fini  
 $\Rightarrow$  répétitions de mesures

1)  
Introduction

2)  
Planification  
séquentielle  
 $D$ -optimale

3)  
Planification  
 $D$ -optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
 $D$ -optimale  
pénalisée

5) Exemples

6) Conclusions

$\mathcal{X}$  est un ensemble fini  $\mathcal{X} = \{x^{(1)}, \dots, x^{(K)}\}$

Convergence de  $\hat{\theta}^n$  vers  $\bar{\theta}$  : tout va bien si

$D_n(\theta, \bar{\theta}) = \sum_{k=1}^n [\eta(x_i, \theta) - \eta(x_i, \bar{\theta})]^2$  tend vers l'infini assez vite pour tout  $\theta \neq \bar{\theta}$

**Théorème 1 : convergence [LP, S&P Letters, 2009]**

Si  $D_n(\theta, \bar{\theta}) = \sum_{k=1}^n [\eta(x_i, \theta) - \eta(x_i, \bar{\theta})]^2$  vérifie

$$\text{pour tout } \delta > 0, \left[ \inf_{\|\theta - \bar{\theta}\| \geq \delta / \tau_n} D_n(\theta, \bar{\theta}) \right] / (\log \log n) \xrightarrow{\text{p.s.}} \infty$$

avec  $\mathcal{X}$  fini et  $\{\tau_n\}$  une suite non-décroissante de constantes positives, alors  $\hat{\theta}^n$  satisfait  $\tau_n \|\hat{\theta}^n - \bar{\theta}\| \xrightarrow{\text{p.s.}} 0$

(Remplacer  $\log \log n$  par  $(\log n)^\rho$ ,  $\rho > 1$ , si les  $\varepsilon_i$  forment une suite de différences de martingales)

1)  
Introduction

2)  
Planification  
séquentielle  
D-optimale

3)  
Planification  
D-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
D-optimale  
pénalisée

5) Exemples

6) Conclusions

## Théorème 2 : normalité asymptotique [LP, S&P Letters, 2009]

S'il existe une suite de matrices  $\mathbf{C}_n$  symétriques déf. pos. telles que  $\mathbf{C}_n^{-1} \mathbf{M}^{1/2}(\xi_n, \bar{\theta}) \xrightarrow{p} \mathbf{I}$  avec  $c_n = \lambda_{\min}(\mathbf{C}_n)$  et  $D_n(\theta, \bar{\theta})$  satisfaisant  $n^{1/4} c_n \rightarrow \infty$  et

$$\text{pour tout } \delta > 0, \left[ \inf_{\|\theta - \bar{\theta}\| \geq c_n^2 \delta} D_n(\theta, \bar{\theta}) \right] / (\log \log n) \xrightarrow{\text{p.s.}} \infty$$

alors  $\hat{\theta}^n$  satisfait  $\sqrt{n} \mathbf{M}^{1/2}(\xi_n, \hat{\theta}^n)(\hat{\theta}^n - \bar{\theta}) \xrightarrow{d} \mathcal{N}(\mathbf{0}, \mathbf{I})$

☞ On applique ceci à

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \mathbf{f}_{\hat{\theta}^k}^\top(x) \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k}(x)$$

$$\Rightarrow \hat{\theta}^n \xrightarrow{\text{p.s.}} \bar{\theta}$$

$$\Rightarrow \mathbf{M}(\xi_n, \hat{\theta}^n) \xrightarrow{\text{p.s.}} \mathbf{M}[\xi_D^*(\bar{\theta}), \bar{\theta}]$$

$$\Rightarrow [n \mathbf{M}(\xi_n, \hat{\theta}^n)]^{1/2} (\hat{\theta}^n - \bar{\theta}) \xrightarrow{d} \mathcal{N}(\mathbf{0}, \mathbf{I})$$

1)  
Introduction

2)  
Planification  
séquentielle  
D-optimale

3)  
Planification  
D-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
D-optimale  
pénalisée

5) Exemples

6) Conclusions

Tout ce qui précède reste vrai pour des expériences de type Bernoulli,

avec  $Y_i \in \{0,1\}$  (succès ou échec),

$\eta(x,\theta) = \text{Prob}(Y_i = 1|x_i = x,\theta)$

et  $\hat{\theta}^n$  l'estimateur du maximum de vraisemblance :

$$\hat{\theta}^n = \arg \max_{\theta \in \Theta} \sum_{i=1}^n \{ Y_i \log[\eta(x_i,\theta)] + (1 - Y_i) \log[1 - \eta(x_i,\theta)] \}$$

La matrice d'information de Fisher est donnée par

$$\mathbf{M}(\xi,\theta) = \int_{\mathcal{X}} \mathbf{f}_{\theta}(x) \mathbf{f}_{\theta}^{\top}(x) \xi(dx)$$

avec

$$\mathbf{f}_{\theta}(x) = \{ \eta(x,\theta)[1 - \eta(x,\theta)] \}^{-1/2} \frac{\partial \eta(x,\theta)}{\partial \theta}$$

1)  
Introduction

2)  
Planification  
séquentielle  
D-optimale

3)  
Planification  
D-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
D-optimale  
pénalisée

5) Exemples

6) Conclusions

### 3) Planification $D$ -optimale avec contrainte

Maximiser  $\log \det \mathbf{M}(\xi, \theta)$  sous la contrainte  $\Phi(\xi, \theta) \leq C$

avec  $\Phi(\xi, \theta) = \int_{\mathcal{X}} \phi(x, \theta) \xi(dx)$

( $\phi(x, \theta)$  = coût d'une observation en  $x$ )

CNS pour l'optimalité de  $\xi^*$  :

$\Phi(\xi^*, \theta) \leq C$  et il existe  $\lambda^* = \lambda^*(C, \theta) \geq 0$  tel que

$$\begin{cases} \lambda^*[C - \Phi(\xi^*, \theta)] = 0 \\ \forall x \in \mathcal{X}, \mathbf{f}_\theta^\top(x) \mathbf{M}^{-1}(\xi^*, \theta) \mathbf{f}_\theta(x) \leq \rho + \lambda^*[\phi(x, \theta) - \Phi(\xi^*, \theta)] \end{cases}$$

☞ En pratique :

maximiser  $H_\theta(\xi, \lambda) = \log \det \mathbf{M}(\xi, \theta) - \lambda \Phi(\xi, \theta)$  pour une suite  $\{\lambda_i\}$  croissante de facteurs multiplicatifs de Lagrange, en partant de  $\lambda_0 = 0$  et en s'arrêtant au 1<sup>er</sup>  $\lambda_i$  pour lequel  $\xi^*(\lambda_i)$  satisfait  $\Phi[\xi^*(\lambda_i), \theta] \leq C$  [Mikulecká 1983]

⇒ pas plus compliqué que la recherche d'un plan  $D$ -optimal !

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

Problème de dose-réponse en essai de médicament :

Définir  $\phi(x, \theta)$  à partir de la probabilité de succès (efficacité, pas de toxicité)

[Dragalin & Fedorov 2006; Dragalin, Fedorov & Wu 2008]

⇨  $\lambda$  dans  $H_\theta(\xi, \lambda) = \log \det \mathbf{M}(\xi, \theta) - \lambda \Phi(\xi, \theta)$  établit un compromis entre

- le gain d'information (pb. d'éthique collective) et
- le rejet de doses inefficaces ou toxiques (pb. d'éthique pour les patients enrôlés)

Si la fonction  $\phi(x, \theta)$  est suffisamment plate autour de son minimum, les points de support de  $\xi^*(\lambda)$ , optimal pour  $H_\theta(\xi, \lambda)$ , se concentrent autour de  $x^* = \arg \min_{x \in \mathcal{X}} \phi(x, \theta)$  quand  $\lambda \rightarrow \infty$

1)  
Introduction

2)  
Planification  
séquentielle  
*D*-optimale

3)  
Planification  
*D*-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
*D*-optimale  
pénalisée

5) Exemples

6) Conclusions



## Example 1 [Dragalin & Fedorov 2006]

Modèle de Cox pour des réponse bivariées :  $Y \rightarrow$  efficacité,  
 $Z \rightarrow$  toxicité

11 doses disponibles, équiréparties dans  $[-3,3]$ ,

$\mathcal{X} = \{x^{(1)}, \dots, x^{(11)}\}$ ,  $x^{(i)} < x^{(i+1)}$ ,  $i = 1, \dots, 10$

$\text{Prob}\{Y = y, Z = z | x, \theta\} = \pi_{yz}(x, \theta)$ ,  $Y, y, Z, z \in \{0, 1\}$

$\theta = (a_{11}, b_{11}, a_{10}, b_{10}, a_{01}, b_{01})^\top = (3, 3, 4, 2, 0, 2)^\top \in \mathbb{R}^6$

$$\pi_{11}(x, \theta) = \frac{e^{a_{11} + b_{11}x}}{1 + e^{a_{01} + b_{01}x} + e^{a_{10} + b_{10}x} + e^{a_{11} + b_{11}x}}$$


$$\pi_{10}(x, \theta) = \frac{e^{a_{10} + b_{10}x}}{1 + e^{a_{01} + b_{01}x} + e^{a_{10} + b_{10}x} + e^{a_{11} + b_{11}x}}$$

$$\pi_{01}(x, \theta) = \frac{e^{a_{01} + b_{01}x}}{1 + e^{a_{01} + b_{01}x} + e^{a_{10} + b_{10}x} + e^{a_{11} + b_{11}x}}$$

$$\pi_{00}(x, \theta) = \left(1 + e^{a_{01} + b_{01}x} + e^{a_{10} + b_{10}x} + e^{a_{11} + b_{11}x}\right)^{-1}$$

- 1) Introduction
- 2) Planification séquentielle D-optimale
- 3) Planification D-optimale avec contrainte
- 4) Planification séquentielle D-optimale pénalisée
- 5) Exemples
- 6) Conclusions

$\phi_1(x, \theta) = \pi_{10}^{-1}(x, \theta)$  ( $\pi_{10}$  = efficacité et pas de toxicité)  
Dose optimale  $x^*$  : minimise  $\phi_1(x, \theta) \rightarrow x^* = x^{(5)} = -0.6$





- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions

Autre fonction de coût :

$$\phi_2(x, \theta) = \{\pi_{10}^{-1}(x, \theta) - [\max_x \pi_{10}(x, \theta)]^{-1}\}^2$$


(plus plate que  $\phi_1(x, \theta)$  autour de  $x^*$ )



## Autre fonction coût : (plus d'importance accordée à la toxicité)

$\phi_3(x, \theta) = \pi_{10}^{-1}(x, \theta)[1 - \pi_{\cdot 1}(x, \theta)]^{-1}$  avec

$\pi_{\cdot 1}(x, \theta) = \pi_{01}(x, \theta) + \pi_{11}(x, \theta) =$  probabilité marginale de toxicité ( $\phi_3(x, \theta)$  minimum en  $x^{(4)} = -1.2$ )



- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions

## 4) Planification séquentielle $D$ -optimale pénalisée

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\hat{\theta}^k}^\top \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k} - \lambda_k \phi(x, \hat{\theta}^k) \right\}$$

De nouveau : construction séquentielle  $\Rightarrow$  perte d'indépendance

$\Rightarrow$  On utilise l'hypothèse que  $\mathcal{X}$  est fini :  $\mathcal{X} = \{x^{(1)}, \dots, x^{(K)}\}$

- ▶ Si  $\lambda_k = \text{constante } \lambda$  (et  $|\phi(x, \theta)|$  borné) :

$$\Rightarrow \hat{\theta}^n \xrightarrow{\text{p.s.}} \bar{\theta} \text{ et } \sqrt{n} \mathbf{M}^{1/2}(\xi_n, \hat{\theta}^n) (\hat{\theta}^n - \bar{\theta}) \xrightarrow{d} \mathcal{N}(\mathbf{0}, \mathbf{I})$$

- ▶ Si de plus  $\dots \phi(x, \theta)$  continue en  $\theta$  pour tout  $x$  :

$$\Rightarrow \mathbf{M}(\xi_n, \bar{\theta}) \rightarrow \mathbf{M}^*(\bar{\theta}), \text{ optimale pour le critère } \log \det \mathbf{M}(\xi, \bar{\theta}) - \lambda \Phi(\xi, \bar{\theta})$$

- ▶ Egalement vrai si

$\lambda_k = \text{fonction mesurable bornée de } x_1, Y_1, \dots, x_k, Y_k$

(ex. :  $\lambda_k = \lambda^*(\hat{\theta}^k) = \text{coefficient de Lagrange optimal pour la minimisation de } \log \det \mathbf{M}(\xi, \hat{\theta}^k) \text{ sous la contrainte } \Phi(\xi, \hat{\theta}^k) \leq C$ )

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

- Si  $\lambda_k \nearrow \infty$ ,  $(\lambda_k \log \log k)/k \rightarrow 0$ , alors  $\hat{\theta}^n \xrightarrow{\text{P.S.}} \bar{\theta}$   
de plus, convergence vers un plan à coût minimum :

$$\Phi(\xi_n, \bar{\theta}) = \frac{1}{n} \sum_{i=1}^n \phi(x_i, \bar{\theta}) \xrightarrow{\text{P.S.}} \phi_{\bar{\theta}}^* = \min_{x \in \mathcal{X}} \phi(x, \bar{\theta})$$

... et  $\xi_N(x^{(i^*)}) \xrightarrow{\text{P.S.}} 1$  si  $\phi(x, \bar{\theta})$  a un seul minimum en  $x^{(i^*)} \in \mathcal{X} = \{x^{(1)}, \dots, x^{(K)}\}$

⇒ On peut donc optimiser  $\sum_{i=1}^n \phi(x_i, \bar{\theta})$  sans connaître  $\bar{\theta}$  :  
optimisation auto-ajustée

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\hat{\theta}^k}^\top \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k} - \lambda_k \phi(x, \hat{\theta}^k) \right\}$$

Déjà proposé en régression linéaire ( $\eta(x, \theta)$  linéaire en  $\theta$ )  
[Åström & Wittenmark, 1989], condition sur  $\lambda_k$  dans [LP, AS  
2000]

Ici MC en régression non-linéaire, ou max. de vraisemblance,  
mais avec  $\mathcal{X}$  fini

Attention :  $x_{k+1} = \arg \min_{x \in \mathcal{X}} \phi(x, \hat{\theta}^k)$  ne marche pas  
toujours !

- 1) Introduction
- 2) Planification séquentielle D-optimale
- 3) Planification D-optimale avec contrainte
- 4) Planification séquentielle D-optimale pénalisée
- 5) Exemples
- 6) Conclusions

### Exemple 2 (régulateur auto-ajusté)

Recherche de  $x^*$  tel que  $\psi(x, \bar{\theta}) = T \rightarrow$  minimiser  
 $\phi(x, \bar{\theta}) = [\psi(x, \bar{\theta}) - T]^2$

- ▶ Modèle de Michaelis-Menten:

$$Y_i = \frac{\bar{\theta}_1 x}{\bar{\theta}_2 + x} + \varepsilon_i, \{\varepsilon_i\} \text{ i.i.d. } \mathcal{N}(0,1)$$

- ▶ Fonction à minimiser:

$$T = 1/2 \Rightarrow \phi(x, \theta) = \left[ \frac{\theta_1 x}{\theta_2 + x} - \frac{1}{2} \right]^2,$$

- ▶  $x \in [0,10]$ , (grille de 1001 points)

- ▶ Simulation avec  $\bar{\theta} = (1,1)^\top$

$$\Rightarrow \eta(x, \bar{\theta}) = x/(1+x), x^* = 1 \text{ (et } \phi(x^*, \bar{\theta}) = 0)$$

- ▶  $\lambda_k = (\log k)^8$

1)  
Introduction

2)  
Planification  
séquentielle  
D-optimale

3)  
Planification  
D-optimale  
avec  
contrainte

4)  
Planification  
séquentielle  
D-optimale  
pénalisée

5) Exemples

6) Conclusions

Ici,  $\psi(x, \theta) = \eta(x, \theta) \rightarrow$  on observe directement  $\psi(x_i, \bar{\theta}) + \varepsilon_i$

$\Psi(x, \bar{\theta})$  estimable si  $\{x_n\}$  a un point d'accumulation en  $x$

$\Rightarrow$  il n'est pas nécessaire d'estimer  $\bar{\theta}$

(il suffit d'estimer correctement le signe de la dérivée de

$\Psi(x, \bar{\theta})$  en  $x^*$  tel que  $\Psi(x^*, \bar{\theta}) = T$ )

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\hat{\theta}^k}^\top \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k} - \lambda_k \phi(x, \hat{\theta}^k) \right\}$$

fonctionne dès que  $\lambda_k \rightarrow \infty$

Dans ce cas particulier, on peut prendre aussi

$x_{k+1} = \arg \min_{x \in \mathcal{X}} \phi(x, \hat{\theta}^k)$  («best intention design»,  
«continual reassessment method», «forced certainty  
equivalence»)

- 1) Introduction
- 2) Planification séquentielle D-optimale
- 3) Planification D-optimale avec contrainte
- 4) Planification séquentielle D-optimale pénalisée
- 5) Exemples
- 6) Conclusions



Méthode alternative [Lai & Robbins 1978] :

$$x_{k+1} = x_k - \frac{Y_k - T}{k \hat{\beta}^k}$$

avec

$$\hat{\beta}^k = \frac{\sum_{i=1}^k (x_i - \bar{x}_k)(Y_i - \bar{Y}_k)}{\sum_{i=1}^k (x_i - \bar{x}_k)^2} \text{ tronqué à } [\underline{\beta}, \bar{\beta}]$$

$\hat{\beta}^k$  = estimateur des MC pour  $Y_i = T + \beta(x_i - x^*) + \varepsilon_i$

$\hat{\beta}^k$  = constante  $\rightarrow$  approximation stochastique

[Robbins-Monro, 1951]

- 1) Introduction
- 2) Planification séquentielle D-optimale
- 3) Planification D-optimale avec contrainte
- 4) Planification séquentielle D-optimale pénalisée
- 5) Exemples
- 6) Conclusions


$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\hat{\theta}^k}^\top \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k} - \lambda_k \phi(x, \hat{\theta}^k) \right\}$$

$\approx$  même chose pour  $x_{k+1} = \arg \min_{x \in \mathcal{X}} \phi(x, \hat{\theta}^k)$


( $\hat{\theta}^k$  tronqué à  $\theta_1 > 1/3, \theta_2 > 10^{-2}$ )

$$x_{k+1} = x_k - \frac{Y_k - T}{k \hat{\beta}_k} \quad (\hat{\beta}_k \text{ tronqué à } [10^{-2}, 5])$$

→ suite  $\{x_n\}$



→ suite  $\{\eta(x_n, \bar{\theta})\}$



- 1) Introduction
- 2) Planification séquentielle D-optimale
- 3) Planification

## Exemple 3 (régulateur auto-ajusté – suite)

- ▶  $\approx$  Exemple 2,  $Y_i = \frac{\bar{\theta}_1 x}{\theta_2 + x} + \varepsilon_i$ ,  $\{\varepsilon_i\}$  i.i.d.  $\mathcal{N}(0,0.1)$
- ▶ mais à présent

$$\Psi(x, \theta) = \theta_1 [1 - \exp(-\theta_2 x/3)] \neq \eta(x, \bar{\theta})$$

$$(\bar{\theta} = (1,1)^\top \Rightarrow \Psi(x^*, \bar{\theta}) = 1/2 \text{ pour } x^* = 3 \log(2) \simeq 2.08)$$

- ▶ Plus difficile que l'exemple 2 : on n'observe pas  $\Psi(x, \bar{\theta})$  !

- ▶  $x_1 = 1$ ,  $x_2 = 10$ , puis

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\hat{\theta}^k}^\top \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k} - \lambda_k \phi(x, \hat{\theta}^k) \right\}$$

pour 3 suites  $\{\lambda_k\}$

- ▶ (a)  $\lambda_k = \log^2 k$
- ▶ (b)  $\lambda_k = k/(1 + \log^2 k)$
- ▶ (c)  $\lambda_k = k^{1.1}$

1)  
Introduction

2)  
Planification  
séquentielle  
D-optimale

3)  
Planification  
D-optimale  
avec  
contrainte


4)  
Planification  
séquentielle  
D-optimale  
pénalisée

5) Exemples

6) Conclusions

→  $\Psi(x_k, \bar{\theta})$ ,  $k = 1, \dots, 500$


(a)  $\lambda_k = \log^2 k$    (b)  $\lambda_k = k/(1 + \log^2 k)$    (c)  $\lambda_k = k^{1.1}$



- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions

→  $\hat{\theta}^k, k = 1, \dots, 500$

(a)  $\lambda_k = \log^2 k$    (b)  $\lambda_k = k/(1 + \log^2 k)$    (c)  $\lambda_k = k^{1.1}$



- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

## Example 4 (optimiseur auto-ajusté)

- Modèle [Box & Lucas, 1959]:


$$Y_i = \eta(x_i, \bar{\theta}) + \varepsilon_i, \{\varepsilon_i\} \text{ i.i.d. } \mathcal{N}(0, \sigma^2)$$

$$\eta(x, \theta) = \frac{\theta_1}{\theta_1 - \theta_2} [\exp(-\theta_2 x) - \exp(-\theta_1 x)]$$

- On veut maximiser  $\eta(x, \bar{\theta})$ ,  $x \in [0, 10]$ , grille de 1001 points

- $\bar{\theta} = (0.7, 0.2)^\top$

$$\Rightarrow \xi_D^* = \frac{1}{2} \delta_{x^{(1)}} + \frac{1}{2} \delta_{x^{(2)}} \text{ avec } x^{(1)} \simeq 1.25 \text{ et } x^{(2)} \simeq 6.60$$
$$x^* = 2.51, \eta(x^*, \bar{\theta}) = \max_{x \in \mathcal{X}} \eta(x, \bar{\theta}) \simeq 0.606$$



- 1) Introduction
- 2) Planification séquentielle D-optimale
- 3) Planification D-optimale avec contrainte
- 4) Planification séquentielle D-optimale pénalisée
- 5) Exemples
- 6) Conclusions

►  $x_1 = 1.25$ ,  $x_2 = 6.6$ , puis

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\hat{\theta}^k}^\top \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k} - \lambda_k \phi(x, \hat{\theta}^k) \right\}$$

pour 3 suites  $\{\lambda_k\}$

- (a)  $\lambda_k = \log^2 k$
- (b)  $\lambda_k = k/(1 + \log^2 k)$
- (c)  $\lambda_k = k^{1.1}$

1)  
Introduction

2)  
Planification  
séquentielle  
*D*-optimale

3)  
Planification  
*D*-optimale  
avec  
contrainte


4)  
Planification  
séquentielle  
*D*-optimale  
pénalisée

5) Exemples

6) Conclusions

$\rightarrow \eta(x_k, \bar{\theta}), k = 1, \dots, 500, \sigma = 1$

(a)  $\lambda_k = \log^2 k$  (b)  $\lambda_k = k/(1 + \log^2 k)$  (c)  $\lambda_k = k^{1.1}$




- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions



$\rightarrow \eta(x_k, \bar{\theta}), k = 1, \dots, 500, \sigma = 0.1$

(a)  $\lambda_k = 10 \log^2 k$    (b)  $\lambda_k = 10 k / (1 + \log^2 k)$    (c)  $\lambda_k = 10 k^{1.1}$



- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions

## Exemple 1 [Dragalin & Fedorov 2006] (suite)

Essais cliniques: 11 doses,  $Y$  pour efficacité,  $Z$  pour toxicité,  
36 patients

Méthode «up and down» [Ivanova 2003]


$$x_{N+1} = \begin{cases} \max\{x^{(i_N-1)}, x^{(1)}\} & \searrow & \text{si } Z_N = 1, \\ x^{(i_N)} & \longrightarrow & \text{si } Y_N = 1 \text{ et } Z_N = 0, \\ \min\{x^{(i_N+1)}, x^{(11)}\} & \nearrow & \text{si } Y_N = 0 \text{ et } Z_N = 0, \end{cases}$$

pour les 10 premiers patients, puis **planification séquentielle  $D$ -optimale pénalisée** à la première toxicité observée (avec accroissement d'au plus une dose à chaque pas [Dragalin & Fedorov 2006])

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions


$\triangle$  pour  $(Y = 0, Z = 0)$ ,  $\triangleright$  pour  $(Y = 1, Z = 0)$ ,  $\diamond$  pour  $(Y = 1, Z = 1)$  et  $\nabla$  pour  $(Y = 0, Z = 1)$

Fonction de pénalisation  $\phi_1(x, \theta) = \pi_{10}^{-1}(x, \theta)$



- 1) Introduction
- 2) Planification séquentielle *D*-optimale
- 3) Planification *D*-optimale avec contrainte
- 4) Planification séquentielle *D*-optimale pénalisée
- 5) Exemples
- 6) Conclusions

Fonction de pénalisation  $\phi_3(x, \theta) = \pi_{10}^{-1}(x, \theta)[1 - \pi_{.1}(x, \theta)]^{-1}$



- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

(36 patients, 1000 répétitions)

design	$\Phi_1(\xi, \theta)$	$\psi(\xi, \theta)$	$\widehat{x^*}_{\{t < 4\}}$	$\widehat{x^*}_{\{t = 4\}}$	$\widehat{x^*}_{\{t = 5\}}$	$\widehat{x^*}_{\{t = 6\}}$	$\widehat{x^*}_{\{t > 6\}}$	$\#x^{(11)}$
S1	1.87	28.02	2%	38.6%	36.9%	8.6%	13.9%	0
$\xi_{u \& d}(\bar{\theta})$	1.47	29.4						
S2	3.16	17.23	0	19.8%	70.5%	7.8%	1.9%	5%
$\xi_D^*(\bar{\theta})$	4.45	14.99						
S3	2.38	18.78	0	22.3%	68.2%	7%	2.5%	2.3%
$\xi_{\lambda=2}^*(\bar{\theta})$	1.97	17.00						

$$\phi_1(\xi, \theta) = \pi_{10}^{-1}(x, \theta), \quad \psi(\xi, \theta) = \det^{-1/6}[\mathbf{M}(\xi, \theta)], \quad \text{OSD} = x^{(5)}$$

S1 = «up & down»

S2 = «up & down», puis  $D$ -optimal séquentiel

S3 = «up & down», puis  $D$ -optimal séquentiel pénalisé

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

(240 patients, 150 répétitions)

	$\Phi_1(\xi, \theta)$	$\psi(\xi, \theta)$	$x^*_{\{t < 4\}}$	$x^*_{\{t = 4\}}$	$x^*_{\{t = 5\}}$	$x^*_{\{t = 6\}}$	$x^*_{\{t > 6\}}$	$\#x^{(11)}$
S1	1.54	29.04	0	14%	77.3%	7.3%	1.3%	0
$\xi_{u \& d}(\bar{\theta})$	1.47	29.4						
S4	1.52	27.87	0	8.7%	90%	0.7%	0.7%	0.1%

S4 = «up & down», puis  $D$ -optimal séquentiel pénalisé  
avec  $\lambda_N \nearrow$  de façon logarithmique

- changement quand  $\sigma(\text{dose optimale estimée}) < \Delta_x$   
 $\Delta_x =$  intervalle entre 2 doses consécutives
- accroissement prudent des doses quand  $\sigma(\text{dose optimale estimée}) > \Delta_x/2$

S4 plus performante que S1 (= «up & down»)

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

## 6) Conclusions

- Convergence et normalité asymptotique des estimateurs en planification séquentielle  $D$ -optimale

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \mathbf{f}_{\hat{\theta}^k}^\top(x) \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k}(x)$$

et planification séquentielle  $D$ -optimale pénalisée

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\hat{\theta}^k}^\top \mathbf{M}^{-1}(\xi_k, \hat{\theta}^k) \mathbf{f}_{\hat{\theta}^k} - \lambda_k \phi(x, \hat{\theta}^k) \right\}$$

quand  $\lambda_k$  borné

... sous l'hypothèse  $\mathcal{X}$  fini (seulement une condition technique?)

- $\lambda_n \rightarrow \infty$  pas trop vite  $\rightarrow$  optimisation/régulation auto-ajustée

- 1) Introduction
- 2) Planification séquentielle  $D$ -optimale
- 3) Planification  $D$ -optimale avec contrainte
- 4) Planification séquentielle  $D$ -optimale pénalisée
- 5) Exemples
- 6) Conclusions

- Normalité asymptotique quand  $\lambda_n \rightarrow \infty$  suffisamment lentement?

$$\lambda_{\min}[\mathbf{M}(\xi_n, \hat{\theta}^n)] \sim A/\lambda_n?$$

Trouver une suite de matrices  $\mathbf{C}_n$  symétriques déf. pos. telles que  $\mathbf{C}_n^{-1} \mathbf{M}^{1/2}(\xi_n, \bar{\theta}) \xrightarrow{P} \mathbf{I}$ : construire  $\mathbf{C}_n$  à partir de

$$x_{k+1} = \arg \max_{x \in \mathcal{X}} \left\{ \mathbf{f}_{\bar{\theta}}^{\top} \mathbf{M}^{-1}(\xi_k, \bar{\theta}) \mathbf{f}_{\bar{\theta}} - \lambda_k \phi(x, \bar{\theta}) \right\}?$$

- Et pour la minimisation de  $\mathbb{E}\{\sum_{i=1}^N \phi(x_i, \theta)\}$  ( $\theta \sim \nu(d\theta)$ ) en horizon fini?

↪ Programmation dynamique stochastique... il faut trouver de bonnes approximations pour les lois *a posteriori* de  $\theta$ , c'est-à-dire  $\nu(d\theta | Y_1^k)$ ,  $k = 1, 2, \dots$

- Système dynamique :

$$x_k = (u(t_k) \ u(t_{k-1}) \ \dots \ u(t_{k-d+1}))^{\top} \rightarrow \dots \text{difficultés supplémentaires}$$

- 1) Introduction
- 2) Planification séquentielle D-optimale
- 3) Planification D-optimale avec contrainte
- 4) Planification séquentielle D-optimale pénalisée
- 5) Exemples
- 6) Conclusions