

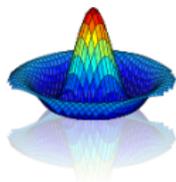
# Echantillonnage : Monte Carlo et hypercube latin et indices basés sur la régression

École Chercheur Mexico

Thierry Faure

Cemagref — LISC, Aubière, France

Gien, le 12 Mai 2009



**MEXICO**  
WEXICO

- 1 Introduction
- 2 Un exemple d'échantillonnage par méthode de Monte carlo
- 3 Des mesures
  - Maximin et Minimax
  - Discrépance
  - Dispersion
- 4 Echantillonnage par méthode de Monte carlo
- 5 Les hypercubes latins

# Plan

- 1 Introduction
- 2 Un exemple d'échantillonnage par méthode de Monte carlo
- 3 Des mesures
  - Maximin et Minimax
  - Discrépance
  - Dispersion
- 4 Echantillonnage par méthode de Monte carlo
- 5 Les hypercubes latins

# Objectifs et enjeux

Lorsque l'objectif est de modéliser le code en phase exploratoire (quand aucune simulation n'a encore été réalisée), on recherche souvent à satisfaire les deux contraintes suivantes :

- D'une part, répartir les points dans l'espace le plus possible de façon à capter les non-linéarités.
- D'autre part, faire en sorte que ce remplissage de l'espace subsiste par réduction de la dimension.

On cherche à réaliser des expérimentations en remplissant l'espace des paramètres "au mieux"

- Comment définir ce "au mieux" ?
- Minimum de points, représentativité

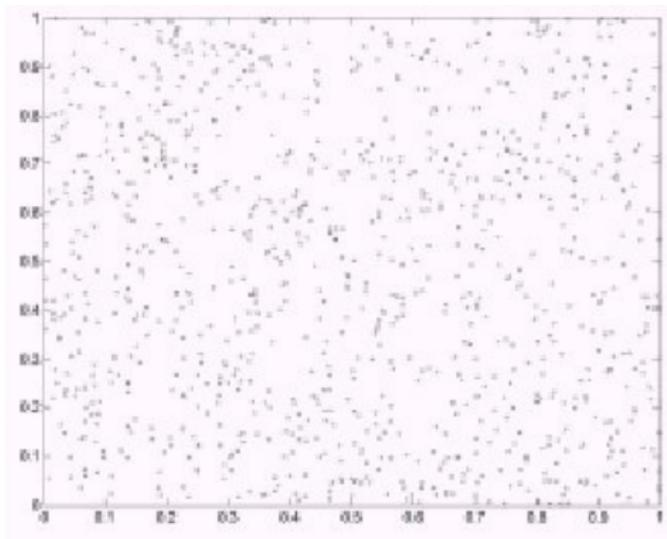
La qualité de la répartition spatiale est mesurée soit à l'aide de critères déterministes comme les distances minimax ou maximin (Johnson et al., 1990), soit à l'aide de critères probabilistes comme la discrédance

# Plan

- 1 Introduction
- 2 Un exemple d'échantillonnage par méthode de Monte carlo
- 3 Des mesures
  - Maximin et Minimax
  - Discrépance
  - Dispersion
- 4 Echantillonnage par méthode de Monte carlo
- 5 Les hypercubes latins

# Exemple d'échantillonnage

tirage selon une loi uniforme de  $n$  points indépendants de  $\Omega$   
`plot(runif(1000),runif(1000))`



# Plan

- 1 Introduction
- 2 Un exemple d'échantillonnage par méthode de Monte carlo
- 3 Des mesures**
  - Maximin et Minimax
  - Discrépance
  - Dispersion
- 4 Echantillonnage par méthode de Monte carlo
- 5 Les hypercubes latins

# Maximin et Minimax

Utilisation des critères minimax ou maximin (Johnson et al., 1990) pour disperser les points au mieux.

## Maximin

Distance minimum : C'est la plus petite distance entre deux points de l'échantillon :  $\min_{i \neq j} d(x_i, x_j)$ , avec  $d$  la distance euclidienne

$$d(x_i, x_j) = \sqrt{\sum_{l=1}^k (x_{il} - x_{jl})^2}$$

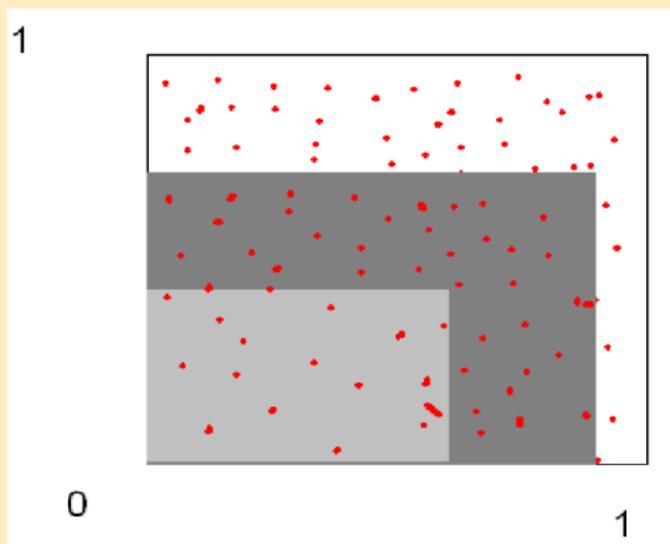
Plan maximin : Un plan maximin est un plan qui maximise la distance minimale entre deux points de l'échantillon.

## Minimax

Critère de distance maximum : C'est la plus grande distance entre un point du domaine d'étude et un point de l'échantillon. Plan minimax : Un plan minimax est un plan qui minimise la distance maximale entre un point du domaine et un point de l'échantillon.

# Discr pance

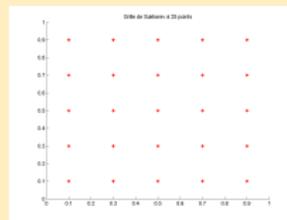
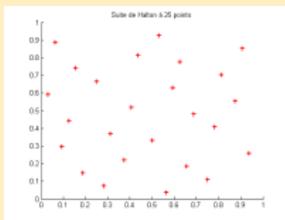
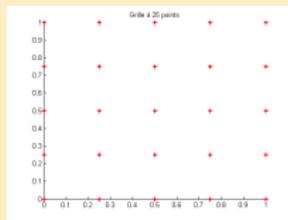
Discr pance :  $D^*(X) = \sup_{P \in \mathcal{P}^*} \left| \frac{\#(P, (x(n)))}{n} - \lambda(P) \right|$  Mesure l' cart maximal de la distribution des points de la suite   la r partition uniforme.



L'in galit  de Koksma-Hlawka montre que la discr pance intervient dans l'erreur de calcul d'une int grale pour des fonctions   variation born e.

# Dispersion

**Dispersion :**  $\delta(x_n) = \max_{y \in I^s} \min_{i=1, \dots, n} d(y, x_i)$



Regular Grid  
(25 points)

Halton sequence  
(25 points)

Sukharev grid  
(25 points)

Pour les discrédances :

Grille régulière (avec n points)	Sequence à faible discrepance
$O\left(\frac{1}{\sqrt{n}}\right)$	$O\left(\frac{\log^d(n)}{n}\right)$

# Plan

- 1 Introduction
- 2 Un exemple d'échantillonnage par méthode de Monte carlo
- 3 Des mesures
  - Maximin et Minimax
  - Discrépance
  - Dispersion
- 4 Echantillonnage par méthode de Monte carlo
- 5 Les hypercubes latins

# méthode de Monte carlo

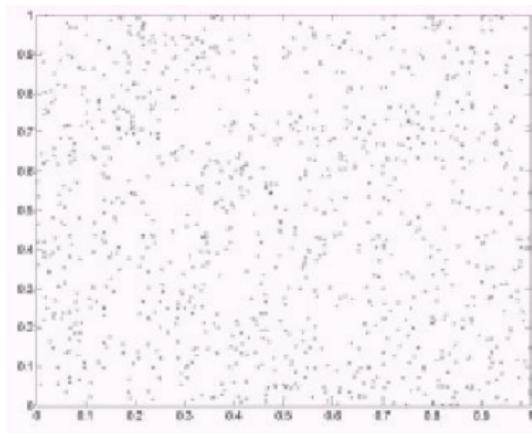
Le plan classique dans les méthodes de monte-carlo consiste à générer des suites de points pseudo-aléatoires dans l'espace des facteurs. L'erreur d'estimation découle du théorème central limite. Elle est en  $1/\sqrt{n}$ ,  $n$  étant la taille de l'échantillon.

On distingue :

- nombres pseudo-aléatoires
- nombres quasi-aléatoires

# nombres pseudo-aléatoires

- tirage selon une loi uniforme de  $n$  points indépendants de  $\Omega$
- erreur probable d'estimation en  $O(\sqrt{n})$
- la vitesse de convergence ne dépend pas de la dimension  $d$  de  $\Omega$



# Nombres quasi-aléatoires

- Utilisation de suite à faible discrédance
- exemples : Niederreiter, Halton, Sobol

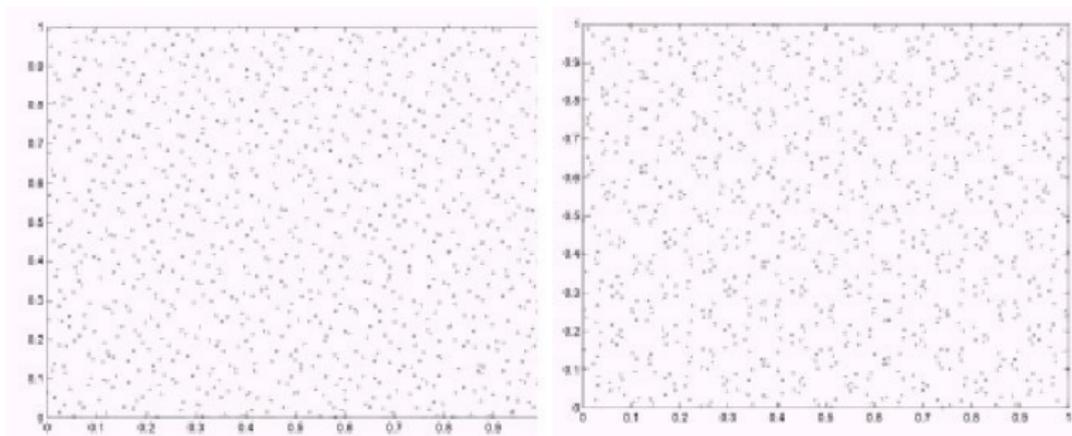


FIG.: Niederreiter et Sobol

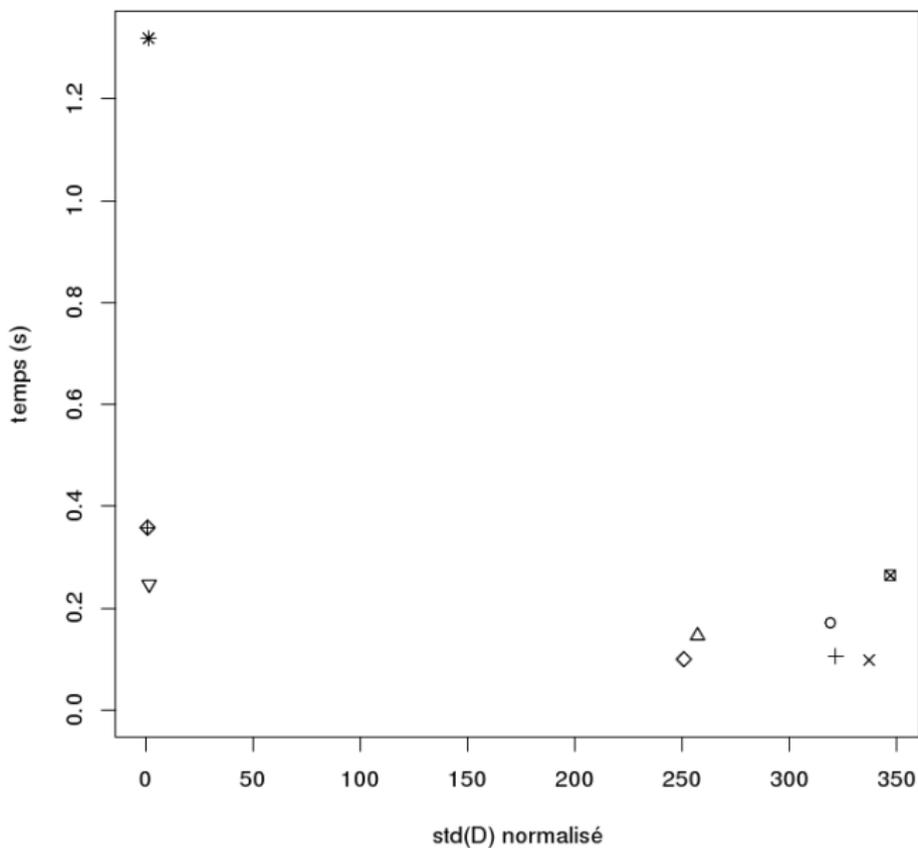


FIG.: Comparaison des méthodes d'échantillonnages

# Plan

- 1 Introduction
- 2 Un exemple d'échantillonnage par méthode de Monte carlo
- 3 Des mesures
  - Maximin et Minimax
  - Discrépance
  - Dispersion
- 4 Echantillonnage par méthode de Monte carlo
- 5 Les hypercubes latins

# Hypercube latin

Méthode la plus populaire des “space-filling designs”

Définition : Un plan hypercube latin (LHD) avec  $n$  runs et  $K$  facteurs d'entrées (noté  $LHD(n,K)$ ) est une matrice  $n \times K$ , dans laquelle chaque colonne est une permutation aléatoire de  $\{ 1, 2, \dots, K \}$ .

Propriétés :

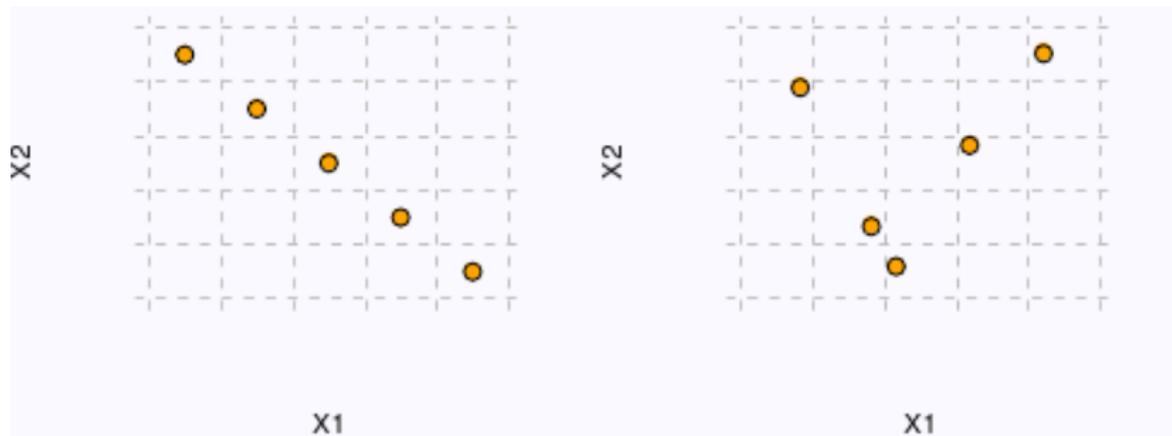


# Quelques méthodes de construction

- Méthode standard : distribution
- Méthode de construction : Algorithm LHSA
- Itérative
- maximin L

# Méthode standard

- Chaque dimension de  $\Omega$  est découpée en L classes de même amplitude, découpage de  $\Omega$  en  $L^d$  strates,
- Tirages de L strates telles que toutes les classes du découpage des facteurs soient présentes une fois et une seule,
- Tirage d'un point dans chacune des L strates.
- Répétition du processus.



# Méthode de construction : Algorithm LHSA (Mc Kay, 1979)

Pour générer un LHS pour  $n = 8$ ,  $s = 2$ , dans la première étape nous générons 2 permutations  $\{1, 2, \dots, 8\}$  comme  $(2,5,1,7,4,8,3,6)$  et  $(5,8,3,6,1,4,7,2)$  pour former un LHS(8, 2) qui est la matrice sur la gauche. Nous générons alors nombres aléatoires pour former un matrice  $8 \times 2$ . exemple ici

# Indices basés sur la régression

Méthodes statistiques reliées à la régression (Venables and Ripley, 1999)  
Coefficients de Corrélation utilisés pour mesurer les relations entre les entrées et les sorties du modèle.

- Coefficient PEAR (Pearson Product Moment Correlation Coefficient)

$r_{Z_i, \hat{Y}} = \frac{c\hat{d}v(\hat{Y}, Z_i)}{s_{\hat{Y}}s_{Z_i}}$  Il varie entre  $-1$  et  $+1$  et il mesure le degré d'association linéaire entre les variations de  $Z_i$  et celles de  $\hat{Y}$ .

- Coefficient PCC : partial correlation coefficient : Mesure l'association entre les  $Z_i$  et les  $\hat{Y}$  après élimination des effets possible des facteurs d'entrées  $Z_j$   $ineqj$ .

- Standardized regression coefficients (SRC) :  $\hat{b}_i(\frac{s_{Z_i}}{s_{\hat{Y}}})$  avec

$$f(z_k) = b_0 + b_i z_{k,i} + \epsilon_{ik}$$

# Conclusion

- Le modèle de régression peut être étendu pour prendre en compte les interactions . En particulier lorsque le coefficient de détermination est faible.
- Les méthodes de régression sont efficaces pour prendre en compte les effets linéaires. D'autres méthodes sont à considérer pour capturer les non linéarité.

# Utilisation

```
library(sensitivity) pcc(X, y, rank = FALSE, nboot = 0, conf = 0.95)  
src(X, y, rank = FALSE, nboot = 0, conf = 0.95)  
plot(x, ylim = c(-1,1), ...)
```

# Bibliographie

- G. E.P. Box, et al., 2005, Statistics for experimenters, 2nd edition, Wiley.
- B. Husslage et al., 2008, Space-filling Latin hypercube designs for computer experiments, SSRN-id895464 Report No. 2008-104
- M. E. Johnson et al., 1990, Moore L.M., Ylvisaker D. Minimax and maximin distance designs. J. of Statis. Planning and Inference, 26, 131-148.
- A. Saltelli, K. Chan and E. M. Scott eds, 2000, Sensitivity Analysis, Wiley.
- A. Saltelli et al. 2008, Global sensitivity analysis - The primer, Wiley.
- Thomas J.Santner, et al., 2003, The design and analysis of computer experiments, Springer.
- Venables, W.N., Ripley, B.D., 1999. Modern Applied Statistics with S-PLUS. Springer, Berlin.

Copyrights MEXICO 2009 ©

Permission is granted to copy, distribute and/or modify this document under the terms of the GNU Free Documentation License, Version 1.3 or any later version published by the Free Software Foundation ; with no Invariant Sections, no Front-Cover Texts, and no Back-Cover Texts. A copy of the license is included in the section entitled "GNU Free Documentation License".

see <http://www.gnu.org/licenses/fdl.html>