


# Chapitre 18: Nombres aléatoires et pseudo-aléatoires

## 1.1. Introductions

Soit  $X$  une variable aléatoire et  $F_X$  sa fonction de répartition  
 $x_1, x_2, \dots, x_n$  les réalisations de  $X$ . En simulant un système on a très souvent besoin de ces réalisations.



graphes: schéma représentatif de la simulation.

### Propriété:

si  $X$  est une variable aléatoire de fonction de répartition  $F_X$  alors,  $Y = F_X(X)$  suit une loi uniforme.


### Preuve:

si  $X$  est continue alors  $F(x)$  est croissante et  $F_X^{-1}$  existe.

$$\begin{aligned} \text{soit } y \in [0, 1], F_Y(y) &= P(Y \leq y) = P[F_X(X) \leq y] \\ &= P(X \leq F_X^{-1}(y)) \\ &= F_X(F_X^{-1}(y)) = y \end{aligned}$$

$$\Rightarrow \forall y \in [0, 1], F_Y(y) = y \Rightarrow Y = F_X(X) \sim U[0, 1]$$

$$\Rightarrow Y \sim U_{[0,1]} \Rightarrow F_X(X) \sim U_{[0,1]}$$



### Remarque:

En utilisant le graphe on peut déterminer les valeurs de  $x$  à partir des valeurs de  $y$ .

\* Cette propriété permet de ramener la génération des réalisations de la variable aléatoire  $x$  de Fonction de répartition  $F_x(x)$  à la génération des réalisations de la V.a  $U_{[0,1]}$ .

Le problème est donc de générer des nombres aléatoires Uniformes sur  $[0, 1]$ .

### 1.2. La génération des nombres aléatoires (ou au hasard) et les tables.

À l'origine, on utilise des tirages des boules dans des urnes numéroté de 0 à 9, des cartes ou Dés pour obtenir des tables de nombre aléatoires.

Ceci étant insuffisant, on a construit des machines générant des nombres au hasard.

### Exemple 01:

Les machines servant au tirage des numéros gagnants de la Loterie nationale.

### Exemple 02:

Kendall et Babington-Smith, on obtenue 100.000 chiffres à partir d'un disque tournant divisé en secteurs multiples 10 et éclairé à intervalles réguliers. Vu la lourdeur de l'utilisation des tables sur l'ordinateur on préfère d'utiliser des générateurs de nombres dit « pseudo-aléatoires » qui générant des nombres à la demande.

### 1.3. Génération des nombres pseudo-aléatoires:

Le terme « Pseudo » vien du fait qu'on construit par un procédé déterministe une suite de nombres aléatoires

$$x_n = f(x_{n-1}, x_{n-2}, \dots, x_0)$$

Si le nombre  $x_0$  est donné (Initialisation) toute la suite  $x_n, n \in \mathbb{N}$  est déterminée, mais on demande à la suite d'avoir l'aspect d'une suite de nombres au hasard.

Supposons que  $N$  soit la plus grande valeur que peut atteindre  $x_n$ , le problème est arrivée à obtenir des suites telle que :

1. Les  $x_n$  sont réparties uniformément sur  $[0, N]$
2. Les  $x_n$  sont indépendants
3. L'algorithme de génération soit plus rapide possible.

### 1.3.1: Les générateurs congruentiels:

Rappel: Soient  $a, b, q, r \in \mathbb{N}$

$$a \equiv r \pmod{b} \Leftrightarrow \begin{cases} a = bq + r \\ r = 0, 1, \dots, b-1 \end{cases}$$

$r$ : est le reste de la division  $a/b$ .

#### Méthode congruentielle linéaire et mixte:

$$\begin{cases} X_{n+1} = a X_n + c \pmod{m} & n \geq 0 \\ X_0 \text{ donné} \end{cases}$$

où  $a, c, m$  et  $X_0$  sont des entiers telle que:

$m$ : module  $m > 0$

$a$ : multiplicateur  $0 \leq a < m$

$c$ : incrément  $0 \leq c < m$

$X_0$ : la valeur de départ  $0 \leq X_0 < m$

+ Dans le cas où  $c = 0$ : on obtient la méthode congruentielle multiplicative ou linéaire.

+ Dans le cas où  $c \neq 0$ : on obtient la méthode congruentielle mixte.

#### Exemple:

Supposons les constantes suivantes:  $a = 3, c = 0, m = 5, X_0 = 4$

Le générateur des nombres pseudo-aléatoires est suivant:

$$\begin{cases} X_{n+1} = 3 X_n \pmod{5} & n \geq 0 \\ X_0 = 4 \end{cases}$$

on calcule la suite des nombre pseudo-aléatoire

$$x_1 = 3x_0 = 12 \bmod 5 \Rightarrow x_1 = 2$$

$$x_2 = 3x_1 \bmod 5 \Rightarrow x_2 = 1$$

$$x_3 = 3x_2 \bmod 5 \Rightarrow x_3 = 3$$

$$\Rightarrow \begin{cases} x_0 = 4 \\ x_1 = 2 \\ x_2 = 1 \\ x_3 = 3 \end{cases} \quad \begin{array}{l} \text{Aucune valeur ne doit dépasser} \\ m = 5. \end{array}$$

La suite de nombre pseudo-aléatoire (n.p.a) est  
(4, 2, 1, 3, 4, 2, 1, 4)

### Remarque:

Pour obtenir une suite de nombres aléatoire entre 0 et 1  
il suffit de prendre  $u_n = \frac{x_n}{m}$ ,  $n \geq 0$

### Contre exemple:

Supposons les paramètres suivants:  $a = c = x_0 = 1$  et  $m = 3850$

Le générateur:

$$x_{n+1} = x_n + 1 \bmod 3850$$

La suite de n.p.a est (1, 2, 3, 4, 5, ...)

Ce générateur n'a aucun intérêt car la suite générée n'a pas l'aspect du hasard. ce n'est pas un bon générateur  
bien que le paramètre est très élevé.

### Remarque 02:

Donnons la formule générale de  $x_n$  en fonction de  $x_0$

$$\begin{aligned}x_n &= a x_{n-1} + c \pmod{m} \\&= a (a x_{n-2} + c) + c \pmod{m} \\&= a^2 x_{n-2} + ac + c \pmod{m} \\&= a^2 (a x_{n-3} + c) + ac + c \pmod{m} \\&= a^3 x_{n-3} + a^2 c + ac + c \pmod{m} \\&\vdots \\&= a^3 x_{n-3} + c(a^2 + a^1 + a^0) \\&\vdots \\x_n &= a^n x_0 + c \sum_{i=0}^{n-1} a^i \pmod{m}\end{aligned}$$

$$x_n = a^n x_0 + c \frac{1 - a^n}{1 - a} \pmod{m}$$

### 1.3.2. Problème de paramètre:

Le problème est le choix des 4 paramètres  $a, c, m$  et  $x_0$  pour que la suite des nombres générés ait de bonnes propriétés statistiques (satisfait 1, 2, 3 de paragraphe 3). Les paramètres «  $m$  » et «  $a$  » sont les plus importants, les paramètres «  $c$  » et «  $x_0$  » sont choisis pour que la période soit de longueur «  $m$  ». Certains auteurs affirment que la réalisation d'un bon générateur exige de paramètre «  $m$  » être grand mais ~~ceci~~ n'est pas une condition nécessaire (voir contre exemple)

En général, on dit qu'un générateur est bon si il engendre une bonne suite de nombre aléatoire c-a-d qu'il satisfait les propriétés statistique 1, 2, 3 de paragraphe 03.

#### 1.4. Tests de générateurs des nombres pseudo-aléatoires

Pour que les suites de nombres générés possèdent un comportement aléatoire sur  $[0, 1]$ , il faut tester ce comportement selon deux critères :

a. Uniformité : Peut-on considérer les résultats d'une génération comme des réalisations d'une variable aléatoire Uniforme  $U_{[0,1]}$  ?

b. Indépendance : Peut-on considérer les  $U_n$  comme des réalisations de variable aléatoire indépendantes ?

#### 1.4.1. Tests de l'uniformité de la distribution

Comparaison d'une loi empirique (obtenue à partir des nombres générés entre  $[0, 1]$ ) avec la loi théorique (loi uniforme  $[0, 1]$ ).

Donc il s'agit de tester l'hypothèse  $H_0$  selon laquelle les observations formées par le générateur sont bien réparties uniformément entre 0 et 1.

### 1-4-1-1: Test de Khi-deux:

Soient:

$n$ : Le nombre d'observation (Le nombre pseudo-aléatoire généré)

$k$ : Le nombre de classe de l'intervalle  $[0, 1]$ .

$n_i$ : Les effectifs observés dans la  $i$ ème classe.

$np_i = n \times \frac{1}{k}$ : L'effectifs théorique de chaque classe (loi uniforme)

$P_i$ : La probabilité associée à la classe  $i$ .

on calcule le test statistique:

$$\chi^2 = \frac{k}{n} \sum_{i=1}^k \left( n_i - \frac{n}{k} \right)^2 = \frac{1}{np_i} \sum_{i=1}^k \left( n_i - \frac{n}{k} \right)^2$$

qui suit approximativement sous l'hypothèse  $H_0$ , une loi de khi-deux à  $(k-1)$  degrés de liberté. ( $\chi^2_{k-1}$ )

On fixe un seuil de signification et on rejette l'hypothèse  $H_0$  si  $\chi^2 >$  valeur critique (lue sur la table du  $\chi^2_{(k-1)}$ )

#### Remarque:

- Pour que ce test ait un sens il faut que  $np_i \geq 5$  c'est à dire  $n \geq 5k$ .

- si  $k > 30$ , on utilise l'approximation de Fisher de la loi de  $\chi^2$  par la loi normale.



- Pour le calcul de  $k$ , on peut utiliser les approximations suivantes:

\* Approximation de Mann et Wald:  $k = (4n)^{2/5}$

\* Approximation de Stunges:  $k = 1 + (3,3) \log n$ .

Exemple:

Soit la suite des nombres aléatoire suivante sur  $[0,1]$ :

0,99 - 0,01 - 0,03 - 0,05 - 0,89 - 0,91 - 0,19 - 0,33 - 0,36 - 0,45  
0,80 - 0,70 - 0,75 - 0,20 - 0,31 - 0,23 - 0,65 - 0,35 - 0,43 - 0,42 -  
0,62 - 0,79 - 0,11 - 0,15 - 0,21.

- La taille de l'échantillon  $n = 25$

- Le nombre de classe on le prend  $k = 4$

- L'hypothèse  $H_0$ : Les observations suivent une loi  $U_{[0,1]}$

- Le seuil de signification  $\alpha = 0,05$

La réponse:

Classe	$[0 - 0,25[$	$[0,25 - 0,5[$	$[0,5 - 0,75[$	$[0,75 - 1[$	Total
$n_i$	9	7	3	6	25
$\frac{n}{k} = np_i$	6,25	6,25	6,25	6,25	25
$(n_i - \frac{n}{k})^2$	7,5625	0,5625	10,5625	0,0625	18,75.

$$\chi^2 = \frac{k}{n} \sum_{i=1}^k (n_i - \frac{n}{k})^2 = \frac{4 \times 18,75}{25} = 3$$

Pour  $\alpha = 0,05$ , la valeur critique lue sur la table  $\chi^2_3$  est  $\chi^2_3(0,05) = 7,815$  on a  $\chi^2 = 3 < 7,815$

Décision: on accepte l'hypothèse  $H_0$ .

Donc les observations suivent la loi uniforme  $[0,1]$ .

### 1.4.2.2. Test de Kolmogorov - Smirnov:

Ce Test est plus puissant que le précédent car c'est celui pour lequel le risque d'accepter  $H_0$  est plus faible.

La procédure est la suivante:

1. On tire un échantillon de  $n$  observations à l'aide du générateur.
2. on classe les observations en ordre croissant.
3. on compare la fonction de répartition empirique  $F_n(x)$  calculé à partir de ces  $n$  nombre pseudo-aléatoire avec la fonction de répartition théorique  $F(x)$  de la loi  $U_{[0,1]}$ .

on calcule la statistique:

$$D = \text{Max} |F_n(x) - F(x)| = \max D(x_i)$$

où  $F_n(x) = \frac{\text{nombre d'observation } \leq x}{\text{taille de l'échantillon } n}$  et  $F(x) = x$

on fixe un seuil de signification  $\alpha$  et on compare cet écart  $D$  à des valeurs critiques particulières qu'on note  $D_n$  (où  $n$  est la taille de l'échantillon) obtenus à partir de la table de Kolmogorov-Smirnov.

La décision sera:

- + Accepter  $H_0$ , si  $D < D_n$  : c-à-d le générateur est bon.
- + Rejeter  $H_0$ , sinon : c-à-d le générateur n'a pas les qualités requises.

### Exemple:

Soit un échantillon de taille  $n=4$  d'une population

$$X_i = 0,34 - 0,49 - 0,56 - 0,70.$$

Tester l'hypothèse selon laquelle la distribution de la population suit une loi uniforme sur  $[0,1]$ , en prenant un seuil de signification  $\alpha=0,2$ ,  $\forall x \in [0,1]$ ,

$F(x) = x$  loi théorique.

$X_i$	0,34	0,49	0,56	0,70
$F_n(X_i)$	$\frac{1}{4}$	$\frac{2}{4}$	$\frac{3}{4}$	1
$F(x_i)$	0,34	0,49	0,56	0,70
$D(x_i)$	0,09	0,01	0,19	0,30

on déduit le test statistique de RS:  $D = \max D(x_i) = 0,30$

Pour  $\alpha=0,2$ , la valeur critique lue sur la table de K-S

est  $D_4 = 0,494$

Comme  $D = 0,30 < D_4 = 0,494$  on accepte l'hypothèse  $H_0$ .

### 1.4.1.3. Test de l'histogramme:

Soit  $n$  nombre pseudo-aléatoire généré sur  $[0,1]$   
soit  $k$  le nombre de classe sur  $[0,1]$

$n_i$ : l'effectif observé dans la classe  $i$

On divise l'intervalle  $[0,1]$  en  $k$  classes et on trace l'histogramme de la série  $(x_i, k \frac{n_i}{n})$  et si l'uniformité est parfaite, on aura alors  $n_i \approx \frac{n}{k} \Rightarrow k \frac{n_i}{n} \approx 1$

Ce test n'est utilisé si l'uniformité était parfaite.


#### Exemple:

Soit un échantillon de la taille  $n = 10$  (exemple du test  $\chi^2$ ) on utilise l'approximation de Mann et Wald, on trouve:

$$k = 4,37 \approx 5$$

$$k = (4 \cdot 10)^{\frac{2}{5}} = 4,37.$$

Classe	$[0 - 0,2[$	$[0,2 - 0,4[$	$[0,4 - 0,6[$	$[0,6 - 0,8[$	$[0,8 - 1[$
$n_i$	4	2	1	0	3
$k \frac{n_i}{n}$	2	1	0,5	0	1,5



Remarque:

D'après l'histogramme, on ne peut pas décider avec ce test il faut faire d'autres tests.

1-4-2. Test de l'indépendance (test de séquences ou « runs » test.)

Ce test est utilisé pour tester si les observations sont mutuellement indépendantes.

- On considère les données telles qu'ils sont collectées l'échantillon doit être divisé en deux classes.

soient  $n_1$  et  $n_2$  le nombre d'observations dans la classe 1 et 2 respectivement.

On registre (+) si l'observation est de la classe 1 et (-) si l'observation est de la classe 2.

- On compte le nombre de séquences homogènes de (+) et (-)

Exemple: ds :  $\underbrace{++}_{n_1} \underbrace{+++}_{n_2} \underbrace{--}_{n_3}$   $r = 4$

on définit un seuil de signification  $\alpha$  et on accepte l'hypothèse  $H_0$ : "Les observations sont indépendantes" si:

\*  $r$  est compris entre les valeurs critiques lues sur les tables  $n_1$  et  $n_2 \leq 20$

\* si  $n_1$  et  $n_2 > 20$ , on utilise le résultat suivant:

$$r \sim N(\mu, \sigma^2)$$

$$\text{où } \mu = \frac{2n_1n_2}{n} + 1 \text{ et } \sigma^2 = \frac{2n_1n_2(2n_1n_2 - n_1 - n_2)}{n^2(n-1)}$$

Exemple:

- on définit la classe 1 (+) par les nbres  $\leq 0,5$
- on définit la classe 2 (-) par les nbres  $> 0,5$

Réponse:

$$n = 25$$

$$n_1 = 16$$

$$n_2 = 9$$

$$n_1 + n_2 = n$$

0,99 - 0,04 - 0,03 - 0,05 - 0,89 - 0,94 - 0,19 - 0,33 - 0,36 -

0,45 - 0,80 - 0,70 - 0,75 - 0,20 - 0,31 - 0,23 - 0,65 - 0,35

0,43 - 0,42 - 0,62 - 0,79 - 0,11 - 0,15 - 0,21

$r = \text{nombre de séquence} = 10$

test bilatéral pour un seuil de signification  $\alpha = 0,05$   
la valeur critique  $r_1$  lue sur la table 4 est  $r_1 = 7$

La valeur critique  $r_2$  lue sur la table 5 est  $r_2 = 18$

$$r = 10 \in [7, 18]$$

on accepte l'hypothèse nulle  $H_0$ , les observations sont indépendantes.

