

TP13/14 : Illustration du Théorème Central Limite

Pré-requis : je vous invite à consulter les chapitres de cours correspondants sur ma page ([support informatique](#)). Pour ce TP, on pourra en particulier se reporter à la section « Tracés d'histogrammes » du CH 8.

► Dans votre dossier Info_2a, créez le dossier TP_13.

I. Théorème Central Limite

Le but de ce TP est d'illustrer le **Théorème Central Limite**⁽¹⁾ (TCL). Ce théorème énonce la **convergence en loi** de suites de variables aléatoires. Commençons par rappeler la définition de convergence en loi.

Définition

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de v.a.r. définies sur $(\Omega, \mathcal{A}, \mathbb{P})$.

Soit X une v.a.r. définie sur $(\Omega, \mathcal{A}, \mathbb{P})$.

Soient F_{X_n} et F_X les fonctions de répartition de associées à ces v.a.r.

- On dit que la suite $(X_n)_{n \in \mathbb{N}^*}$ **converge en loi** vers X si :

$$\lim_{n \rightarrow +\infty} F_{X_n}(x) = F_X(x)$$

en tout point $x \in \mathbb{R}$ où F_X est continue.

- On note alors : $X_n \xrightarrow{\mathcal{L}} X$.

Théorème 1. Théorème Central Limite

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de v.a.r. indépendantes, de même loi, d'espérance m et d'écart-type σ .

Notons $S_n = \sum_{k=1}^n X_k$ et $\bar{X}_n = \frac{S_n}{n}$.

Notons enfin $S_n^* = \frac{S_n - nm}{\sigma\sqrt{n}} = \frac{\bar{X}_n - m}{\frac{\sigma}{\sqrt{n}}}$ la v.a.r. centrée réduite associée à S_n .

- Alors (S_n^*) converge en loi vers une v.a.r. de loi normale $\mathcal{N}(0, 1)$.
- En particulier, pour tout $a \in \mathbb{R}$ et tout $b \in \mathbb{R}$ tels que $a \leq b$, on a :

$$\lim_{n \rightarrow +\infty} \mathbb{P}(a \leq S_n^* \leq b) = \int_a^b \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$$

☞ Ainsi, pour n suffisamment grand, la loi de S_n^* approche la loi $\mathcal{N}(0, 1)$.

Nous allons illustrer cette propriété pour des suites de v.a.r. (X_n) dont tous les éléments suivent une loi uniforme / de Bernoulli / de Poisson.

⁽¹⁾On parle aussi du Théorème de la Limite Centrée (TLC).

Dans la suite, on considère les suites de v.a.r. (X_n) et (S_n) comme définies dans l'énoncé.

- ▶ Pour $n \in \mathbb{N}^*$, déterminer l'espérance et la variance de S_n .

- ▶ Déterminer l'espérance et la variance de S_n^* .

- ▶ Déterminer $\overline{X_n^*}$ la v.a.r. centrée réduite associée à X_n .

II. La loi normale en Scilab

- ▶ Coder dans un onglet **SciNotes** la densité d'une loi normale centrée réduite.
On nommera cette fonction `densiteNormaleCR`.

- ▶ Rappeler l'expression de la fonction de répartition Φ de la loi normale centrée réduite.

- ▶ Quelle méthode (non aléatoire) peut-on proposer pour calculer une version approchée de cette fonction de répartition ?

En **Scilab**, ce calcul approché est implémenté par la fonction `cdfnor` (cumulative distribution function normal distribution). L'appel général est le suivant :

$$[P,Q] = \text{cdfnor}(\text{"PQ"}, X, \text{Mean}, \text{Std})$$

Détaillons les différents éléments de cet appel.

- × **X** : borne supérieure d'intégration,
- × **Mean** : moyenne choisie (la loi n'est pas forcément centrée),
- × **Std** : écart-type choisi (la loi n'est pas forcément réduite),
- × **P** : résultat de l'appel. Autrement dit, c'est le calcul approché de $\int_{-\infty}^X \varphi(t) dt$,
- × **Q** : second résultat de l'appel. Cette variable contient le calcul approché de $\int_X^{+\infty} \varphi(t) dt$.

- Donner une relation entre P et Q.

- Coder dans un nouvel onglet **SciNotes** la fonction de répartition de loi normale centrée réduite. On nommera cette fonction `repartitionNormaleCR`.

Remarque

- L'option "PQ" sert à signifier que l'on cherche à déterminer les paramètres P et Q. Pour ce faire, tous les autres paramètres doivent être fournis lors de l'appel.
- En fait, `cdfnor` permet de réaliser le calcul de n'importe lequel des paramètres de la distribution normale si tous les autres paramètres sont fournis à la fonction. Plus précisément, on peut écrire :
 - × `X = cdfnor("X", Mean, Std, P, Q)`,
 - × `Mean = cdfnor("Mean", Std, P, Q, X)`,
 - × `Std = cdfnor("Std", P, Q, X, Mean)`.

III. Simulation de loi normale à l'aide de lois usuelles

Le cadre du TCL permet de simuler une v.a.r. suivant la loi normale centrée réduite à l'aide de lois usuelles. Dans la suite, on compare la densité de probabilité théorique avec celle obtenue par simulation. Pour ce faire, on procède comme suit :

- × on produit N observations de la simulation de S_n^* ,
- × on trace l'histogramme des fréquences associés.

Il reste à préciser quelle loi doit suivre les variables X_k .

On s'intéresse dans la suite aux cas suivants :

- 1) $X_k \hookrightarrow \mathcal{U}([0,1])$, 2) $X_k \hookrightarrow \mathcal{B}(p)$, 3) $X_k \hookrightarrow \mathcal{P}(\lambda)$.

III.1. Simulation de la loi normale via les « 12 uniformes »

Dans le TCL, la convergence peut être très rapide. La loi de la variable S_n^* est alors une bonne approximation de la loi $\mathcal{N}(0, 1)$ pour des valeurs de n assez petites.

III.1.a) Rappels sur la loi uniforme

- Si $(a, b) \in \mathbb{R}^2$ avec $a < b$, que signifie $X \hookrightarrow \mathcal{U}([a, b])$?

- Rappeler la valeur de $\mathbb{E}(X)$ et $\mathbb{V}(X)$ si $X \hookrightarrow \mathcal{U}([a, b])$.

- En déduire la valeur de $m = \mathbb{E}(X)$ et $\sigma^2 = \mathbb{V}(X)$ dans le cas où $X \hookrightarrow \mathcal{U}([0, 1])$.

III.1.b) Simulation de la densité de probabilité

Dans ce paragraphe :

- × on considère des variables X_k indépendantes telles que $X_k \leftrightarrow \mathcal{U}([0, 1])$.
- × on choisit $n = 12$. Autrement dit, $S_n = S_{12}$.
- × on simule la v.a.r. S_{12}^* . Plus précisément, on représente l'histogramme des effectifs issu de N observations de S_{12}^* et on compare ce résultat à la densité de la loi $\mathcal{N}(0, 1)$.
- ▶ Que vaut alors S_{12}^* ? En donner une expression simple à l'aide de S_{12} .

- ▶ Par quel appel simule-t-on, à l'aide de la fonction `grand`, 1 échantillon de 12 v.a.r. indépendantes suivant la loi $\mathcal{U}([0, 1])$? En déduire la simulation de la v.a.r. S_{12} .

- ▶ Par quel appel simule-t-on, à l'aide de la fonction `grand`, $N = 10000$ échantillons de 12 v.a.r. indépendantes suivant la loi $\mathcal{U}([0, 1])$? En déduire la simulation de N échantillons de S_{12} .

- ▶ Recopier et compléter le programme suivant.
On l'enregistrera sous le nom `comparaison_dnormale_12_unif.sce`.

```

1 // Valeur des paramètres
2 N = 10000
3 nbC = 100
4
5 // Simulations de N observations de S12
6 G =
7 S =
8
9 // Simulations de N observations de S12*
10 Scr =
11
12 // Tracé de la densité théorique
13 plot
14 // Tracé de la densité observée
15 histplot
16
17 legend(["Simu - 12 uniformes", "Densité N(0,1)"], "in_upper_right")
18 xtitle(["Théorème Central Limite :";
19 " diagramme des fréquences des 12 uniformes";
20 " comparaison avec le tracé de la densité de N(0,1)"])

```

III.1.c) Simulation de la fonction de répartition

On se propose maintenant de comparer la fonction de répartition théorique avec sa version obtenue par simulation. Pour ce faire, on procède comme suit :

- × on récupère le tableau des effectifs des N observations précédentes,
- × on trace le diagramme en bâtons des effectifs **cumulés** associé.
- × compare ce diagramme avec la fonction de répartition de la loi $\mathcal{N}(0, 1)$.

On pourra faire appel à la fonction `dsearch` qui permet de déterminer la fréquence des valeurs contenues dans un vecteur. L'appel général est le suivant :

```
[indClasse, effectif] = dsearch(Obs, classe)
```

Détaillons les différents éléments de cet appel.

- × `Obs` : une série d'observations,
- × `classe` : une liste de réels rangés dans l'ordre strictement croissant définissant les classes, *Par exemple, classe = [0, 3, 7, 9] permet de définir trois classes :*
 - 1) la 1^{ère} classe est l'intervalle [0, 3],
 - 2) la 2^{ème} classe est l'intervalle]3,7],
 - 3) la 3^{ème} classe est l'intervalle]7,9].
- × `indClasse` : indique, pour chaque observation, la classe à laquelle elle appartient,
- × `effectif` : indique, pour chaque classe, le nombre d'observations qu'elle contient.

- ▶ Commenter le résultat de l'appel :

```
[indClasse, effectif] = dsearch([8.4, 7, 0, 1, 9, 8, %pi, 2, sqrt(2)], [0, 3, 7, 9])
```

- ▶ Par quel appel obtient-on le tableau `effCumule` des effectifs cumulés à l'aide du tableau `effectif` des effectifs ?

- ▶ Comment obtenir la fréquence des observations dans chaque classe ?

- La fonction `dsearch` est l'analogie, dans le cas continu, d'une fonction dont on s'est servi dans le cas discret. Rappeler le nom de cette fonction et décrire brièvement son utilisation.

- Recopier et compléter le programme suivant.
On l'enregistrera sous le nom `comparaison_rnormale_12_unif.sce`.

```
1 // Valeur des paramètres
2 N = 10000
3 nbC = 100
4
5 // Simulations de N observations de S12
6 G =
7 S =
8
9 // Simulations de N observations de S12*
10 Scr =
11
12 // Simulation de la fonction de répartition
13 classe =
14 [indice, effectif] = dsearch
15 effCumule =
16
17 // Tracé de la fonction de répartition observée
18 bar
19 // Tracé de la fonction répartition théorique
20 plot
21
22 legend(["Simu - 12 uniformes","Fonction répartition N(0,1)"],
23 "in_upper_left")
24 xtitle(["Théorème Central Limite :"];
25 " diagramme des fréquences cumulées des 12 uniformes";
26 " comparaison avec le tracé de la fct répartition de N(0,1)"])
```