

Traitement de données et modélisation avec R

<https://elearn.univ-tlemcen.dz/>



Chapitre 1: Principales lois de probabilités

1. Loi normale.

1.1. Définitions.

Sur un échantillon de 150 athlètes universitaires, on a mesuré les variables quantitatives continues suivantes: la glycémie (g/l), le poids (kg) et la taille (cm). Les résultats obtenus sont donnés dans le tableau suivant et sont enregistrés dans le fichier :

C:\Users\Dell\Desktop\Data.csv

Ces données sont importées sous R via la commande :

Commande 1 :

```
> Tab = read.csv  
("C:/Users/Dell/Desktop/Data.csv",  
header=T, dec="," ,sep=";")
```

	A	B	C	D	E
1	Etudiant	Glycemie	Poids	Tailles	
2	1	1,32	87,55	187,97	
3	2	0,85	64,39	152,11	
4	3	1,11	72,82	184,00	
5	4	1,38	80,53	156,91	
6	5	1,13	83,10	174,48	
7	6	1,25	68,44	195,70	
8	7	0,90	96,60	144,61	
9	8	1,19	83,93	173,17	
10	9	0,84	89,20	186,30	
11	10	1,22	92,98	181,58	
12	11	1,08	73,09	149,82	
13	12	1,34	73,63	170,40	
14	13	1,00	75,28	180,68	
15	14	1,28	68,65	189,28	
16	15	1,28	86,33	165,89	
17	16	1,00	75,03	166,68	
18	17	1,18	63,83	169,02	
19	18	1,21	62,36	203,14	
20	19	1,26	78,06	151,77	
21	20	1,26	58,47	176,80	
22	21	0,93	77,95	183,42	
23	22	0,84	82,84	186,17	
24	23	1,16	52,29	144,52	
25	24	1,21	83,27	212,60	
26	25	0,89	71,60	178,58	

tewfik.mahdjoub@univ-tlemcen.dz




Section 2: Lois continues

La représentation de la variable "poids" par un histogramme, en tapant :

Commande 1 :

```
> hist ( Tab$Poids, xlab="Poids des  
athlètes", ylab="Fréquences observées",  
main="Poids de 150 athlètes  
universitaires")
```




Chapitre 1: Principales lois de probabilités

Section 1: Lois continues

L'axe (y'y) peut représenter des pourcentages (fréquences absolues/taille de l'échantillon) par ajout de l'instruction **prob=T**. On calcule ensuite, la moyenne **moy**, la variance **var** et l'écart-type **et** de la série. Puis on fait la représentation classique de la série par l'intervalle [**moy-et** , **moy+et**]

Commandes 2 :


```
> hist ( Tab$Poids, xlab="Poids des athlètes", ylab="Fréquences observées", main="Poids de 150 athlètes universitaires", prob=T)
> moy = mean(Tab$Poids)
> var = var(Tab$Poids)*149/150
> et = sqrt(var)
> abline (v=moy, col="red", lw=2)
> abline (v=moy+et, col="green", lw=2)
> abline (v=moy-et, col="green",lw=2)
```



Cet histogramme peut être approché par la fonction suivante :

Commande 3 :

```
> curve (dnorm (x, moy, et), 45 ,100 , add=T, lty=2, lw=2)
```



- ✓ **curve** permet de représenter une courbe.
- ✓ **dnorm()** est la fonction à représenter.
- ✓ **x** est la variable de **dnorm()**. Dans ce cas $x \in [45, 100]$.
- ✓ **add=T** permet d'ajouter la courbe à l'histogramme.

La fonction $dnorm(x, \mu, \sigma)$ est appelée la distribution normale ou la distribution de Gauss de moyenne μ et d'écart-type σ .

Les valeurs de la fonction sur (y'y) ne sont pas des probabilités. Ceux sont les valeurs de la fonction :


$$dnorm(x, \mu, \sigma) = f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

La distribution normale est définie pour $x \in \mathbb{R}$: c'est **une distribution continue**.

Il est possible de combiner plusieurs instructions graphiques :

Commandes 4 :

```
> x = seq(40, 120, by=0.1)
> plot (x, dnorm (x, moy-10, et), col="red", type="l")
> points (x, dnorm(x, moy+10, et), col="blue", type="l", cex=1)
> lines (x, dnorm(x, moy+20, et), col="green")
> curve (dnorm(x, moy, et), 40 ,120, add=T, col="gray")
```



- ✓ **seq** (a, b, by=step) permet de définir une suite allant de a à b avec un pas de déplacement step.
- ✓ **cex** (character expansion) permet de définir la taille du caractère.

Chapitre 1: Principales lois de probabilités

Section 1: Lois continues


✓ Pour ne pas initialiser le repère lors de l'utilisation de `curve`, il est nécessaire d'ajouter `add=T`.

D'après ces représentations graphiques, $y=\text{moy}$ est un axe de symétrie de `dnorm(a, moy, et)`.

De la même manière, on peut tester l'impact de l'écart-type `et` :

Commandes 5 :

```
> graphics.off()
> x = seq (40,120, by=0.1)
> plot (x, dnorm(x, moy, et-5), col="red",
,type="l")
> points (x, dnorm(x, moy, et),
,col="blue", type="l",cex=1)
> lines (x, dnorm(x, moy, et+5),
,col="green")
```



✓ `graphics.off()` efface tous les graphes se trouvant dans la fenêtre graphique de




L'écart-type et représente la distance de la moyenne $y=\text{moy}$ au point d'inflexion de la courbe (point où la courbe change de concavité). Plus l'écart-type est important plus la courbe est aplatie.

La courbe de Gauss de **moyenne moy=0** et **d'écart-type et=1** est la représentation graphique de **la distribution normale centrée réduite**.

Commande 6 :


```
> graphics.off()
> curve (dnorm (x, 0, 1), -10, 10)
```



✓ $x \in \mathbb{R}$: x peut être négatif.

1.2. Calcul des probabilités.

Dans la distribution du poids des athlètes, **la probabilité d'avoir le poids entre a et b est l'aire qui se trouve entre les droites $x=a$ et $x=b$, la courbe de la loi normale et l'axe (x').**




$$P(a \leq \text{Poids} \leq b) = \int_a^b dnorm(x, \mu, \sigma) dx$$

Comment calculer la probabilité :

$$P(60 \leq \text{Poids} \leq 80) = \int_{60}^{80} dnorm(x, \mu, \sigma) dx$$

Représentée par l'aire suivante :



Remarque :

Ce graphe est obtenu en utilisant le package **ggplot2**


```
> install.packages("ggplot2")
```

Chapitre 1: Principales lois de probabilités

Section 1: Lois continues

```
> library(ggplot2)
> x = seq (40, 120, by=0.1)
> y = dnorm (x, moy, et)
> tab1 = data.frame (x, y)
> sous_tab = subset (tab1, x>=60 &
x<=80)
> ggplot (tab1, aes(x = x, y = y)) +
geom_line (color = "blue", size = 1) +
+ geom_ribbon ( data = sous_tab,
aes(ymin = 0, ymax = y), fill = "orange",
alpha = 0.5)
```

On calcule d'abord:



par la commande:


```
Commandes 7 :
> pnorm ( 80, moy, et)
[1] 0.6886458
> pnorm ( moy, moy, et)
[1] 0.5
✓ C'est la probabilité d'avoir un poids
inférieur à 80kg.
```

Il est important de noter que :

```
Commandes 8 :
> pnorm ( moy, moy, et)
[1] 0.5
> pnorm (120, moy, et)
[1] 0.9999853
```

Aire sous la courbe de Gauss=1

Puis on calcule :



Finalement, la probabilité d'avoir un poids entre 60kg et 80kg se calcule sous  par :

```
Commande 9 :
> pnorm (80, moy, et) – pnorm (60, moy,
et)
[1] 0.6003262
```

La fonction inverse de **pnorm()** est **qnorm()** : elle donne l'abscisse correspondant à une aire donnée. C'est la fonction qui donne les quantiles.

```
Commandes 10 :
> qnorm (0.25, moy, et)
[1] 67.34255
> qnorm(1, moy, et)
[1] Inf
> qnorm(0.999999, moy, et)
[1] 126.2395
> qnorm(0.05, moy, et)
[1] 56.81338
✓ Pour obtenir 5% de l'aire il suffit de
prendre x=56.81338 kg
```

Enfin, pour faire un tirage aléatoire d'une liste de nombre distribuée suivant une loi normale on utilise la commande **rnorm()**:

```
Commandes 10 :
> liste =rnorm (20, 0, 1)
> hist(liste)
> liste
[1] -0.46812616 -1.03925129 -0.77144222 -
0.59931557 0.09872294 0.29767433 -
0.35403427
[8] 2.20808857 -0.03872791 1.74339612 -
0.03669780 -0.40638779 -0.49629263
0.92281499
[15] 0.48140168 -2.16153183 -2.32351438 -
0.77081139 0.35782530 0.15763633
✓ C'est le tirage aléatoire de 20 nombres
distribués suivant la loi normale
dnorm( ,0 ,1 ).
```