

Sommes de Variables Aléatoires – Tale spé maths

A) Étude d'une variable aléatoire (Rappels)

1) étude d'un exemple

Exercice : On donne les 2 jeux suivants associés aux variables aléatoires X et Y :

Jeu N°1						
x_i	-5	-1	0	1	3	Quel est le jeu le plus intéressant ?
$P(X = x_i)$	0,2	0,3	0,1	0,1	0,3	

Jeu N°2						
y_i	-3	-1	0	1	2	Justifier la réponse avec des calculs appropriés
$P(Y = x_i)$	0,1	0,4	0,2	0,2	0,1	

2) Espérance mathématique

Définition : Soit X une variable aléatoire tel que $X(\Omega) = \{1; 2; 3; \dots; n\}$;

l'espérance mathématique de X est le réel $E(X) = \sum_{i=1}^n x_i \cdot P(X = x_i)$

Application : Dans le jeu n°1 on obtient

$$E(X) = (-5) \times 0,2 + (-1) \times 0,3 + 0 \times 0,1 + 1 \times 0,1 + 3 \times 0,3 = -0,3$$

Dans le jeu n°2 on obtient

$$E(Y) = (-3) \times 0,1 + (-1) \times 0,4 + 0 \times 0,2 + 1 \times 0,2 + 2 \times 0,1 = -0,3$$

3) Variance & écart-type

Définition : Soit X une variable aléatoire tel que $X(\Omega) = \{1; 2; 3; \dots; n\}$;

- la variance de X est le réel positif $V(X) = \sum_{i=1}^n (x_i - E(X))^2 \cdot P(X = x_i)$
- l'écart-type de X est le réel positif : $\sigma(X) = \sqrt{V(X)}$

Application : Dans le jeu n°1 on obtient

$$V(X) = (-5+0,3)^2 \times 0,2 + (-1+0,3)^2 \times 0,3 + (0+0,3)^2 \times 0,1 + \dots + (1+0,3)^2 \times 0,1 + (3+0,3)^2 \times 0,3 = 8,01$$

donc on déduit que : $\sigma(X) = \sqrt{8,01} \approx 2,83$

Dans le jeu n°2 on obtient

$$V(Y) = (-3+0,3)^2 \times 0,2 + (-1+0,3)^2 \times 0,4 + (0+0,3)^2 \times 0,2 + \dots + (1+0,3)^2 \times 0,2 + (2+0,3)^2 \times 0,1 = 1,81$$

donc on déduit que : $\sigma(X) = \sqrt{1,81} \approx 1,35$

Conclusion : le jeu n°1 paraît plus risqué que le jeu n°2

B) Étude de deux variables aléatoires

1) Analyse d'un exemple

Exercice : On pose X et Y les variables aléatoires définies par les lois suivantes

x_i	-4	1	20	y_i	-2	5
$P(X = x_i)$	0,1	0,35	0,55	$P(Y = y_i)$	0,27	0,73

- Soit Z la variable aléatoire définie par $Z = X + Y$. Quelles sont les valeurs prises par la variable aléatoire Z ?
- Peut-on déterminer la loi de probabilité de Z à partir des données de l'énoncé ? Si oui, donner cette loi

solution : on a $X(\Omega) = \{-4; 1; 20\}$ et $Y(\Omega) = \{-2; 5\}$

les valeurs possibles de Z sont

$$Z(\Omega) = \{-6; -1; 1; 6; 18; 25\} \text{ (cf tableau ci-contre)}$$

les probabilités liées à ces valeurs de Z sont :

$$p(Z = -6) = p((X = -4) \cap (Y = -2)) = 0,1 \times 0,27 = 0,027$$

$$p(Z = -1) = p((X = 1) \cap (Y = -2)) = 0,35 \times 0,27 = 0,0945$$

$$p(Z = 1) = p((X = -4) \cap (Y = 5)) = 0,1 \times 0,73 = 0,073$$

$$p(Z = 6) = p((X = 1) \cap (Y = 5)) = 0,35 \times 0,73 = 0,2555$$

$$p(Z = 18) = p((X = 20) \cap (Y = -2)) = 0,55 \times 0,27 = 0,1485$$

$$p(Z = 25) = p((X = 20) \cap (Y = 5)) = 0,55 \times 0,73 = 0,4015$$

on vérifie la validité de la loi de Z avec $\sum_{k \in Z(\Omega)} k \cdot P(Z = k) = 1$

Problème : que se passe-t-il si plusieurs valeurs de Z correspondent à des cas distincts de X et de Y ?

	-4	1	20
-2	-6	-1	18
5	1	6	25

2) Étude de la variable aléatoire $Z=X+Y$

Définition : Soit X et Y deux variables aléatoires définies sur un univers fini Ω d'expérience aléatoire, qui prennent respectivement pour valeurs les réels x_i tels que $1 \leq i \leq n$ et y_j tels que $1 \leq j \leq m$, avec n et m entiers naturels.

Alors si on pose $Z=X+Y$, on a :

- $Z(\Omega) = \{x_i + y_j \mid 1 \leq i \leq n, 1 \leq j \leq m\} = \{k_i \mid 0 \leq i \leq N\}$ où $N = n + m$
- $\forall k \in Z(\Omega), P(Z=k) = P(X+Y=x_i+y_j) = P(\{k_i\})$

Théorème : Soit la variable aléatoire $Z=X+Y$ où X et Y suivent des lois distinctes alors l'espérance mathématique de Z est $E(X+Y) = E(X) + E(Y)$

Preuve :

Soient X, Y et Z trois variables aléatoires définies sur Ω tel que $Z = X + Y$.

On a alors $E(X+Y) = E(Z) = \sum_{i=0}^n Z(\omega_i)P(\{\omega_i\}) = \sum_{i=0}^n (X+Y)(\omega_i)P(\{\omega_i\})$.

On a par ailleurs $(X+Y)(\omega_i) = X(\omega_i) + Y(\omega_i)$.

Donc $E(X+Y) = \sum_{i=0}^n (X)(\omega_i)P(\{\omega_i\}) + \sum_{i=0}^n Y(\omega_i)P(\{\omega_i\})$.

D'où $E(X+Y) = E(X) + E(Y)$ en identifiant les deux sommes précédentes à $E(X)$ et $E(Y)$.

Remarque : on peut généraliser ce théorème avec le **théorème de transfert**

« hors-programme »: si f est continue alors : $E(f(X)) = \sum_{i=1}^n f(x_i) \cdot P(\{x_i\})$

Définition : Soit X et Y deux variables aléatoires définies sur un univers fini Ω on appelle la covariance du couple (X, Y) le réel issue de la **formule Huygens** :
 $cov(X, Y) = E(X \cdot Y) - E(X) \cdot E(Y)$

Propriété : Soit la variable aléatoire $Z=X+Y$ où X et Y suivent des lois distinctes alors la variance de Z est $V(Z) = V(X) + V(Y) + 2cov(X, Y)$

Preuve : (hors-programme) on applique la **formule de Koëning** :

Pour toute variable aléatoire X : $V(X) = E(X^2) - E^2(X)$

Exercice : Calculer $E(X+Y)$ dans l'étude en B)1)

[réponse : $E(X+Y)=14,06$; $E(X)=10,95$; $E(Y)=3,11$]

3) Étude de la transformation affine $Y=aX+b$

Propriété : Soit X une variable aléatoire définie sur un univers fini Ω ; soit Y la variable obtenue par transformation affine $Y=aX+b$; alors on a :

$$E(Y) = a \cdot E(X) + b ; \quad V(Y) = a^2 \cdot V(X) ; \quad \sigma(Y) = |a| \cdot \sigma(X)$$

Preuve : on a par définition $E(X) = \sum_{i=1}^n x_i \cdot P(X=x_i)$; soient $a, b \in \mathbb{R}$

donc $a \cdot E(X) = \sum_{i=1}^n (a \cdot x_i) \cdot P(X=x_i)$ or $P(X=x_i) = P(aX = a \cdot x_i)$

donc $a \cdot E(X) = \sum_{i=1}^n (a \cdot x_i) \cdot P(aX = a \cdot x_i)$ de même $P(X=x_i) = P(X+b = x_i+b)$

donc $a \cdot E(X) + b = \sum_{i=1}^n (a \cdot x_i) \cdot P(aX = a \cdot x_i) + b$ or $\sum_{i=1}^n P(X=x_i) = 1$

donc $a \cdot E(X) + b = \sum_{i=1}^n (a \cdot x_i) \cdot P(aX = a \cdot x_i) + b \cdot \sum_{i=1}^n P(X=x_i)$

donc $a \cdot E(X) + b = \sum_{i=1}^n (a \cdot x_i) \cdot P(aX+b = a \cdot x_i+b) + b \cdot \sum_{i=1}^n P(aX+b = a \cdot x_i+b)$

donc $a \cdot E(X) + b = \sum_{i=1}^n (a \cdot x_i + b) \cdot P(aX+b = a \cdot x_i+b)$

donc $a \cdot E(X) + b = \sum_{i=1}^n (y_i) \cdot P(Y = y_i) = E(Y)$

Exemple : On joue à un jeu, dans une foire, se déroulant en deux étapes.

- Dans la **phase 1**, on lance un dé équilibré à six faces. Si le résultat obtenu est 1 ou 6, on gagne 9 points. Sinon, on perd 6 points
- Dans la **phase 2**, on lance une pièce équilibrée. Si on obtient face, on gagne 6 points. Sinon, on perd 2 points.

Soit X la variable aléatoire du total de points obtenus. Calculons $E(X)$.

Soient X_1 la variable aléatoire du gain obtenu à la 1ère étape et X_2 la variable aléatoire du gain obtenu à la 2nde étape. Donc on obtient $X = X_1 + X_2$;

On étudie les lois de X_1 et X_2 ci-dessous

x_i	-6	9
$P(X_1 = x_i)$	$\frac{2}{3}$	$\frac{1}{3}$

x_i	-2	6
$P(X_2 = x_i)$	$\frac{1}{2}$	$\frac{1}{2}$

ainsi $E(X_1) = -1$ et $E(X_2) = 2$

donc $E(X) = E(X_1) + E(X_2) = -1 + 2 = 1$

C) Variables aléatoires indépendantes

1) Propriété de la variance

Propriété : Soient X et Y deux variables aléatoires indépendantes ; alors on a : $V(X+Y)=V(X)+V(Y)$ ou encore $cov(X, Y)=0$

Preuve : on sait que X et Y sont indépendantes donc $E(X \cdot Y)=E(X) \times E(Y)$ donc $cov(X, Y)=E(X \cdot Y)-E(X) \cdot E(Y)=0$ donc $V(X+Y)=V(X)+V(Y)$

Exercice : Calculer $V(X+Y)$ puis $\sigma(X+Y)$ dans le jeu de la « foire »
on a $V(X)=36 \times \frac{2}{3} + 81 \times \frac{1}{3} - (-1)^2 = 50$ et $V(Y)=4 \times \frac{1}{2} + 36 \times \frac{1}{2} - (2)^2 = 16$
donc $V(X+Y)=66$ donc $\sigma(X+Y)=\sqrt{66} \approx 8,12$

2) Somme d'un échantillon

Propriété : On considère un entier naturel $n \geq 1$ et X_1, \dots, X_n , n variables aléatoires définies sur Ω supposées indépendantes et identiquement distribuées.

On note la **somme** de l'échantillon : $S_n = X_1 + X_2 + \dots + X_n$ alors :

$$E(S_n) = n \cdot E(X) \quad , \quad V(S_n) = n \cdot V(X) \quad , \quad \sigma(S_n) = \sqrt{n} \cdot \sigma(X)$$

Preuve : $E(S_n) = E(X_1 + \dots + X_n) = E(X_1) + \dots + E(X_n) = n \cdot E(X)$

$$V(S_n) = V(X_1 + \dots + X_n) = V(X_1) + \dots + V(X_n) = n \cdot V(X)$$

donc $\sigma(S_n) = \sqrt{n \cdot V(X)} = \sqrt{n} \cdot \sqrt{V(X)} = \sqrt{n} \cdot \sigma(X)$

Exercice : Dans le jeu de « yam's » on lance 5 dés et on effectue la somme des points obtenus ; on a $E(X)=3,5$; $V(X) \approx 2,92$ et $\sigma(X) \approx 1,71$

donc $E(S_5) = 5 \times 3,5 = 17,5$; $V(S_5) = 5 \times 2,92 = 14,6$ et

$\sigma(S_5) = \sqrt{5} \times 1,71 = 3,82$; obtient donc $17,5 \text{ pts} \pm 3,82 \text{ pts}$

3) Moyenne d'un échantillon

Propriété : On considère un entier naturel $n \geq 1$ et X_1, \dots, X_n , n variables aléatoires définies sur Ω supposées indépendantes et identiquement distribuées.

On note la **moyenne** de l'échantillon : $M_n = \frac{X_1 + X_2 + \dots + X_n}{n}$ alors :

$$E(M_n) = E(X) \quad , \quad V(M_n) = \frac{V(X)}{n} \quad , \quad \sigma(M_n) = \frac{\sigma(X)}{\sqrt{n}}$$

Preuve : $E(M_n) = E\left(\frac{1}{n} S_n\right) = \frac{1}{n} E(S_n) = \frac{1}{n} \times n E(X) = E(X)$

$$V(M_n) = V\left(\frac{1}{n} S_n\right) = \frac{1}{n^2} V(S_n) = \frac{1}{n^2} \times n V(X) = \frac{V(X)}{n}$$

et donc : $\sigma(M_n) = \sqrt{\frac{V(X)}{n}} = \frac{\sigma(X)}{\sqrt{n}}$ pour tout $n \in \mathbb{N}$

Exercice : On propose un jeu de gain d'argent de « tickets à gratter » suivant :

a	0	5	10	20	50	100
$P(X=a)$	0,6	0,2	0,1	0,06	0,03	0,01

On souhaite déterminer la moyenne des gains obtenus pour 10 tickets
on a $E(X)=5,7$, $V(X) \approx 181,44$ et $\sigma(X) \approx 13,47$

donc $E(M_{10}) = 5,7$; $V(M_{10}) = \frac{181,44}{10} = 18,144$, $\sigma(M_{10}) = \frac{13,47}{\sqrt{10}} \approx 4,26$

4) Application à la loi Binomiale

Propriété : Soient X_1, \dots, X_n des variables aléatoires suivantes toutes la même loi de Bernoulli $B(p)$ avec $p \in [0; 1]$ on pose : $S_n = X_1 + X_2 + \dots + X_n$

alors on obtient :

- la variable S_n suit la loi Binomiale $B(n, p)$
- $E(S_n) = np$; $V(S_n) = np(1-p)$; $\sigma(S_n) = \sqrt{np(1-p)}$


Exercice : On étudie la somme de 20 variables aléatoires de Bernoulli avec $p=0,4$; ainsi la variable aléatoire « somme » suit la loi Binomiale $B(20; 0,4)$; $E(S)=8$; $V(S)=4,8$ et $\sigma(S)=2,19$

on obtient le diagramme de la distribution de S :

On souhaite déterminer des intervalles de fluctuation de cette variable :

- $P(5,8 \leq S \leq 10,2)$
- $P(3,6 \leq S \leq 12,4)$
- $P(1,4 \leq S \leq 14,6)$

Comment calculer précisément ces 3 valeurs ?




D) Concentration & loi des grands nombres

1) Les intervalles de Normalité

Théorème de Laplace-Gauss : On considère une variable aléatoire X suivant la loi Binomiale $B(n, p)$ avec $n \geq 30$ et $p \in [0; 1]$ avec $np \geq 5$ et $n(1-p) \geq 5$; alors si on pose $E(X) = \mu = np$ et $\sigma(X) = \sigma = \sqrt{np(1-p)}$:

- $P(\mu - \sigma \leq X \leq \mu + \sigma) = 0,6826 \approx \mathbf{0,68}$
- $P(\mu - 2\sigma \leq X \leq \mu + 2\sigma) = 0,9544 \approx \mathbf{0,95}$
- $P(\mu - 3\sigma \leq X \leq \mu + 3\sigma) = 0,9974 \approx \mathbf{0,99}$

Rque : Ces valeurs sont obtenues par la courbe de GAUSS : $f(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-0,5x^2}$



on a : $\int_{-1}^1 f(x) \cdot dx \approx 0,6826$; $\int_{-2}^2 f(x) \cdot dx \approx 0,9544$; $\int_{-3}^3 f(x) \cdot dx \approx 0,9974$

Rque² : On dit alors que X suit une « Loi Normale » $N(\mu; \sigma)$

2) Inégalité de Markov

Propriété : Si X est une variable aléatoire discrète à valeurs positives et soit a un réel strictement positif, alors : $P(X \geq a) \leq \frac{E(X)}{a}$

Preuve : Soit $A = \{x \in X(\Omega) / x \geq a\}$ et $B = \{x \in X(\Omega) / x < a\}$ alors $A \cap B = \emptyset$ et $A \cup B = X(\Omega)$ donc l'ensemble $\{A, B\}$ forme une partition de l'Univers donc on obtient les inégalités suivantes ;

$$\begin{aligned} E(X) &= \sum_{k \in X(\Omega)} k \cdot P(X=k) = \sum_{k \in A} k \cdot P(X=k) + \sum_{k \in B} k \cdot P(X=k) \\ &\geq \sum_{k \in A} k \cdot P(X=k) = \sum_{k \geq a} k \cdot P(X=k) \geq \sum_{k \geq a} a \cdot P(X=k) \\ &= a \cdot \sum_{k \geq a} P(X=k) = a \cdot P(X \geq a) \quad \text{donc} \quad a P(X \geq a) \leq E(X) \quad [QED] \end{aligned}$$

Propriété : Si X est une variable aléatoire discrète à valeurs positives et soit a un réel strictement positif, alors : $P(|X| \geq a) \leq \frac{E(X^2)}{a^2}$

Preuve : on applique l'inégalité de Markov : $P(X^2 \geq a^2) \leq \frac{E(X^2)}{a^2}$
or $X^2 \geq a^2$ équivaut à $|X| \geq a$ donc on déduit : $P(|X| \geq a) \leq \frac{E(X^2)}{a^2}$

Exercice : Le nombre de pièces sortant d'une usine en une journée est une variable aléatoire d'espérance 50. On veut estimer la probabilité que la production d'un jour donné dépasse 75 pièces.

On a : $P(X \geq 75) \leq \frac{E(X)}{75}$ donc $P(X \geq 75) \leq \frac{50}{75} = \frac{2}{3}$ soit environ 67 %

En fait cette probabilité est trop grande et ne donne pas assez d'informations

3) Inégalité de Bienaymé-Tchebychev

Propriété : Si X est une variable aléatoire discrète à valeurs positives et soit δ un réel strictement positif, alors : $P(|X - E(X)| \geq \delta) \leq \frac{V(X)}{\delta^2}$

Preuve : on applique la 2nde inégalité de Markov :

$$P(|X - E(X)| \geq a) \leq \frac{E((X - E(X))^2)}{a^2} \quad \text{et} \quad (X - E(X))^2 = X^2 - 2X \cdot E(X) + E^2(X)$$

donc $E((X - E(X))^2) = E(X^2) - E^2(X) = V(X)$ donc $P(|X - E(X)| \geq \delta) \leq \frac{V(X)}{\delta^2}$

Exercice : On reprend l'exercice précédent ; Que peut-on dire de plus sur cette probabilité si on sait que la variance de la production quotidienne est 25 ?

$$P(X \geq 75) \leq P(|X - 50| \geq 25) \leq \frac{V(X)}{25^2} \quad \text{donc} \quad P(X \geq 75) \leq \frac{25}{625} = \frac{1}{25} = 0,04$$

Soit une estimation plus précise de 4 %

Cela est bien sûr logique puisque l'on connaît maintenant 2 paramètres sur X

Exercice : Soit une variable aléatoire X qui suit la loi binomiale de paramètres $n=20$ et $p=0,4$; on souhaite comparer les valeurs de normalités de Gauss on sait que : $E(X)=8$; $V(X)=4,8$; $\sigma(X)\approx 2,2$

si $\delta=\sigma(X)=2,2$ alors $P(|X-8|\geq 2,2)\leq \frac{4,8}{2,2^2}=0,99$

si $\delta=2\sigma(X)=4,4$ alors $P(|X-8|\geq 4,4)\leq \frac{4,8}{4,4^2}=0,25$

si $\delta=3\sigma(X)=6,6$ alors $P(|X-8|\geq 6,6)\leq \frac{4,8}{6,6^2}=0,11$

si $\delta=4\sigma(X)=8,8$ alors $P(|X-8|\geq 8,8)\leq \frac{4,8}{8,8^2}=0,06$

Conclusion ; l'inégalité de *Bienaymé-Tchebychev* est très intéressante pour observer les valeurs "extrêmes" c'est-à-dire très éloignées de la moyenne

Rque : On peut modéliser le problème à l'aide d'un script en langage PYTHON

Soit une variable aléatoire X qui suit la loi binomiale de paramètres $n = 20$ et $p = 0,1$.

```

1 import random as rd
2 import math
3 def simulX():
4     a=0
5     for expe in range (20):
6         if rd.randint(1,100)<=10:
7             a=a+1
8     return a
9 def proba(N):
10    echant=[simulX() for i in range (N)]
11    c=0
12    d=2*math.sqrt(1.8)
13    for e in echant:
14        if abs(e-2)>=d:
15            c=c+1
16    return c/N

```

on a : $E(X)=2$; $V(X)=1,8$ et $\sigma(X)=\sqrt{1,8}\approx 1,34$

On constate qu'un écart à $E(X)$ supérieur à $2\sigma(X)$ est de probabilité souvent inférieur à 0,05 alors que l'inégalité de *Bienaymé-Tchebychev* nous donne pour cette même probabilité une majoration par 0,25.

$$P(|X-2|\geq 2\sqrt{1,8})\leq \frac{1,8}{4\times 1,8}=0,25$$

l'inégalité est donc loin d'être optimale.

```

1 >>>proba(1000)
2 0.038
3 >>>proba(10000)
4 0.0454
5 >>>proba(100000)
6 0.041278
7 >>>proba(1000000)
8 0.04516

```

4) Inégalité de concentration

Propriété : Soit une variable aléatoire moyenne M_n d'un échantillon de taille n de la variable aléatoire X . Pour tout réel strictement positif δ , on a

$$P(|M_n - E(X)|\geq \delta)\leq \frac{V(X)}{n \cdot \delta^2}$$

Exercice : Soit une variable aléatoire X qui suit la loi de Bernoulli de paramètre $p=0,2$. On considère un échantillon de n variables aléatoires suivant la loi de X . On appelle M_n la variable aléatoire moyenne associée à cet échantillon. Déterminer la taille n de l'échantillon pour que la condition $P(0,03 < M_n < 0,37)\geq 0,95$ soit satisfaite ; on rappelle que $E(M_n)=E(X)=0,2$

la condition donne : $P(|M_n - 0,2| > 0,17)\leq 0,05$ donc $\frac{V(X)}{n \cdot \delta^2}\leq 0,05$ avec $V(X)=p(1-p)=0,16$ et $\delta=0,17$ donc $n\geq 110,73$ soit $n\geq 111$

5) Loi des grands nombres

Propriété : Soit une variable aléatoire moyenne M_n d'un échantillon de taille n de la variable aléatoire X . Pour tout réel strictement positif δ , on a

$$\lim_{n \rightarrow +\infty} P(|M_n - E(X)|\geq \delta) = 0$$

Rque : La loi des grands nombres traduit le fait que plus la taille de l'échantillon d'une variable aléatoire X est grande, plus l'écart entre la moyenne de cet échantillon et l'espérance de la variable aléatoire X est faible

Exercice : On considère la variable aléatoire X qui prend ses valeurs de manière équiprobable parmi les entiers 1 à 5. On nomme M_n la variable aléatoire moyenne d'un échantillon de taille n de la variable aléatoire X

Éditer un script PYTHON afin de simuler et vérifier la "loi des grands nombres"