

## CAPES Maths 2021, épreuve 1, parties D et E : Markov, Bienaymé-Tchebychev Le problème du collectionneur

De cette épreuve 1, je ne propose des corrigés que des parties D et E.

Les parties A, B et C ont toutes été évoquées dans des problèmes antérieurs. Il en est ainsi par exemple du « problème de Bâle » qui fait l'objet d'un sujet tiré d'un ancien problème de Baccalauréat série C.

Comme chaque année depuis 2018, au moins 50 % des thèmes abordés dans les sujets des écrits du CAPES font l'objet d'une étude figurant quelque part dans les pages d'Écrit. Encore faut-il trouver les « bonnes » études, j'en conviens. Le sujet 2021 ne déroge pas à la règle.

### Partie D : Inégalités de Markov et de Bienaymé-Tchebychev.

#### XIX. Inégalité de Markov

La question n'indique pas la nature de la variable aléatoire  $Y$ , elle peut être finie ou discrète ou bien à densité. La démonstration n'est pas la même suivant le cas. Nous nous en tenons à des variables finies ou discrètes, compte tenu de l'ambiance du problème et de l'application qui en sera donnée dans la partie E.

- Soit  $Y$  une variable aléatoire finie ou discrète positive définie sur un univers  $\Omega$ , et possédant une espérance. Elle en possède certainement une si elle est finie, et, si elle est discrète, la série  $E(Y) = \sum_{k=1}^{+\infty} y_k \times P(Y = y_k)$  est une série à termes positifs (car  $Y$  est par hypothèse à valeurs positives) convergente. Considérons que les variables aléatoires finies se mettent dans le sac des discrètes, elles ont un nombre fini de termes non nuls.
- Soit  $a$  un réel strictement positif.

Comme indiqué dans l'énoncé de cette question, décomposons l'ensemble  $Y(\Omega)$  des valeurs prises par  $Y$  en deux sous ensembles disjoints :  $Y_1 = [Y \geq a] = \{y \in Y(\Omega) ; y \geq a\}$  et  $Y_2 = [Y < a] = \{y \in Y(\Omega) ; y < a\}$ , ces deux sous ensembles formant une partition de  $Y(\Omega)$ .

- Puisque la série  $E(Y) = \sum_{k=1}^{+\infty} y_k \times P(Y = y_k)$  est une série à termes positifs convergente, sa somme ne dépend pas de l'ordre de sommation. Il est légitime de changer l'ordre de sommation, cela ne modifie pas la valeur de la somme :  $E(Y) = \sum_{y_k \in Y_1} y_k \times P(Y = y_k) + \sum_{y_k \in Y_2} y_k \times P(Y = y_k)$

- Puisque  $Y$  est une variable aléatoire positive,  $y_k \times P(Y = y_k)$  est positif ou nul pour tout  $k$  et la somme  $\sum_{y_k \in Y_2} y_k \times P(Y = y_k)$  est positive ou nulle. Si on néglige cette somme dans l'expression de

l'espérance, on obtient une inégalité :  $E(Y) \geq \sum_{y_k \in Y_1} y_k \times P(Y = y_k)$

- Mais lorsque  $y_k \in Y_1$ , l'inégalité  $y_k \geq a$  est vérifiée. Donc :

$$E(Y) \geq \sum_{y_k \in Y_1} a \times P(Y = y_k) = a \sum_{y_k \in Y_1} P(Y = y_k) = a \times P(Y_1)$$

En fin de compte :  $E(Y) \geq a \times P([Y \geq a])$

Puisque  $a$  est strictement positif, cette inégalité équivaut à l'inégalité :  $\frac{E(Y)}{a} \geq P([Y \geq a])$  qui est l'inégalité

de Markov : Pour tout réel  $a$  strictement positif,  $\frac{E(Y)}{a} \geq P([Y \geq a])$

### XX. Inégalité de Bienaymé-Tchebychev

Soit  $X$  une variable aléatoire définie sur un univers  $\Omega$  possédant une espérance notée  $E(X)$  et une variance notée  $V(X)$ . Par définition de la variance :  $V(X) = E[(X - E(X))^2]$

La variable aléatoire  $(X - E(X))^2$  est une variable aléatoire positive qui, par hypothèse, a une espérance.

- On peut lui appliquer l'inégalité de Markov, en employant non pas un réel  $a$  strictement positif, mais

son carré : Pour tout réel  $a$  strictement positif,  $\frac{V(X)}{a^2} = \frac{E[(X - E(X))^2]}{a^2} \geq P([(X - E(X))^2 \geq a^2])$

- Mais puisque  $a$  est strictement positif, l'inégalité  $(X - E(X))^2 \geq a^2$  est équivalente à l'inégalité :

$$\sqrt{(X - E(X))^2} \geq a \quad \text{autrement dit à l'inégalité} \quad |X - E(X)| \geq a \quad . \quad \text{De ce fait :}$$

$$P([(X - E(X))^2 \geq a^2]) = P(|X - E(X)| \geq a)$$

On obtient que pour tout réel  $a$  strictement positif :  $\frac{V(X)}{a^2} \geq P(|X - E(X)| \geq a)$ .

C'est l'inégalité de Bienaymé-Tchebychev.

Partie E : Le collectionneur.

Notons  $\{a_1, a_2, \dots, a_n\}$  l'ensemble des animaux formant la collection. Pour  $q$  entier au moins égal à 1, considérons l'expérience consistant à répertorier les animaux obtenus au cours des  $q$  premiers achats. Cette expérience peut être modélisée par l'ensemble  $\Omega_q = \{a_1, a_2, \dots, a_n\}^q$  des  $q$ -uplets d'éléments de  $\{a_1, a_2, \dots, a_n\}$  muni de l'équiprobabilité (équiprobabilité car les achats sont supposés indépendants les uns des autres).

L'ensemble  $\Omega_q$  ayant  $n^q$  éléments, chacune des éventualités de cet ensemble a pour probabilité  $\frac{1}{n^q}$ .

**XXI.** La variable aléatoire qui modélise le nombre d'achats nécessaires pour obtenir l'ensemble de la collection est la variable aléatoire  $T_n$

**XXII.** Lorsqu'on commence une collection, le premier animal obtenu est nécessairement un nouvel animal.  $T_1$  est la variable aléatoire constante qui prend la valeur 1 quel que soit l'élément de l'univers  $\Omega_1 = \{a_1, a_2, \dots, a_n\}$ . La variable aléatoire  $T_1$  prend la valeur 1 avec une probabilité égale à 1.

**XXIII. 1.** Soit  $q$  un entier au moins égal à 2. Le collectionneur obtient toujours un même animal au cours de ses  $q$  premiers achats si et seulement si le  $q$ -uplet associé à ses achats est l'un des  $q$ -uplets  $(a_i, a_i, \dots, a_i)$  où  $i = 1 ; 2 ; \dots ; n$ .

Il y a  $n$   $q$ -uplets qui réalisent cet évènement, la probabilité de ce dernier est :  $n \times \frac{1}{n^q} = \frac{1}{n^{q-1}}$

**XXIII. 2.** L'évènement «  $T_2 > q$  » est réalisé si et seulement si le collectionneur obtient toujours un même animal au cours de ses  $q$  premiers achats.

Cet évènement est, pour  $q \geq 2$ , exactement celui dont la probabilité vient d'être calculée, mais la même formule est applicable lorsque  $q = 1$  puisque  $\frac{1}{n^{q-1}} = 1$  lorsque  $q = 1$ . Ainsi, pour tout entier  $q$  strictement positif :

$$P(T_2 > q) = \frac{1}{n^{q-1}}$$

On note que les évènements  $A_q = "T_2 > q"$  sont des évènements emboîtés : pour tout entier  $q$  au moins égal à 2 :  $A_q \subset A_{q-1}$

**XXIII. 3.** L'évènement " $T_2 = q$ " est réalisé si et seulement si l'évènement  $A_{q-1} = "T_2 > q - 1"$  est réalisé mais l'évènement  $A_q = "T_2 > q"$  ne l'est pas. Il s'agit de l'évènement  $A_{q-1} - A_q$  ; en raison du fait que ces évènements sont emboîtés, la probabilité de cet évènement est :

$$P(T_2 = q) = P(T_2 > q - 1) - P(T_2 > q) = \frac{1}{n^{q-2}} - \frac{1}{n^{q-1}} = \frac{n-1}{n^{q-1}}$$

**XXIII. 4.** D'après **XXIII. 1**, s'il y a 100 animaux, avec 2 achats indépendants, la probabilité d'obtenir deux animaux identiques est exactement  $\frac{1}{100}$  et celle d'obtenir deux animaux différents est exactement  $\frac{99}{100}$ . Il suffit d'effectuer 2 achats pour que la probabilité « d'obtenir deux animaux différents soit supérieure ou égale à 0,99 ».

**XXIII. 5.** La réponse est dans l'énoncé...

**XXIII. 6.** Si :  $\begin{cases} Z_1 = T_1 \\ Z_k = T_k - T_{k-1} \text{ pour } k \geq 2 \end{cases}$ , inversement :  $\begin{cases} T_1 = Z_1 \\ T_k = Z_1 + Z_2 + \dots + Z_k \text{ pour } k \geq 2 \end{cases}$

**XXIII. 7.** Sachant que le collectionneur a déjà obtenu  $(k-1)$  animaux, la probabilité que ce collectionneur obtienne un nouvel animal en effectuant un achat est égale à  $\frac{n-(k-1)}{n}$ . La variable aléatoire  $Z_k$  modélise le nombre d'épreuves de Bernoulli identiques et indépendantes devant se succéder pour obtenir un nouvel animal. De ce fait, elle suit la loi géométrique de paramètre :  $p = \frac{n-(k-1)}{n}$

On sait qu'une loi géométrique de paramètre  $p$  a pour espérance  $\frac{1}{p}$  et pour variance  $\frac{1-p}{p^2}$ .

En l'occurrence,  $Z_k$  a pour espérance  $\frac{n}{n-k+1}$  et pour variance  $\frac{n \times (k-1)}{(n-k+1)^2}$ .

**XXIII. 8.** Du fait que :  $T_n = Z_1 + Z_2 + \dots + Z_n = \sum_{k=1}^n Z_k$ , et par linéarité de l'espérance :

$$E(T_n) = \sum_{k=1}^n E(Z_k) = \sum_{k=1}^n \frac{n}{n-k+1} = n \times \sum_{k=1}^n \frac{1}{n-k+1}$$

Si on effectue le changement d'indice :  $j = n - k + 1$ , l'indice  $j$  parcourt, en décroissant, l'ensemble des entiers de 1 à  $n$ .

$$\text{Ainsi : } E(T_n) = n \times \sum_{j=1}^n \frac{1}{j} = n \times H_n$$

**XXIII. 9.** D'après la question **A. V**,  $E(T_n) \approx n \times \ln n$ .

**XXIV. 1.** Dans le cas de variables aléatoires mutuellement indépendantes, la variance d'une somme est égale à la somme des variances. Donc, si on admet l'indépendance mutuelle des diverses variables  $Z_k$ , la variance

$$\text{de } T_n \text{ est égale à la somme des variances : } v(T_n) = \sum_{k=1}^n v(Z_k) = \sum_{k=1}^n \frac{n \times (k-1)}{(n-k+1)^2}$$

Si on effectue le changement d'indice :  $j = n - k + 1$ , lorsque  $k$  parcourt l'ensemble des entiers de 1 à  $n$ , l'indice  $j$  parcourt, en décroissant, l'ensemble des entiers de 1 à  $n$  et par ailleurs :  $k - 1 = n - j$ .

$$\text{On obtient : } v(T_n) = n \times \sum_{j=1}^n \frac{n-j}{j^2} = n^2 \times \sum_{j=1}^n \frac{1}{j^2} - n \times \sum_{j=1}^n \frac{1}{j}.$$

$$\text{Autrement dit : } v(T_n) = n^2 \times B_n - n \times H_n$$

**XXIV. 2.** Quel que soit l'entier  $n$  strictement positif :  $v(T_n) = n^2 \times B_n - n \times H_n \leq n^2 \times B_n$  et compte tenu de la majoration obtenue à propos de la suite  $(B_n)$  (majoration par sa limite) dans le courant de la **partie B** :

$$v(T_n) = n^2 \times B_n - n \times H_n \leq n^2 \times B_n \leq n^2 \times \frac{\pi^2}{6}$$

**XXV.** Soit  $n$  un entier strictement positif donné. Pour tout réel  $\lambda$  strictement positif, appliquons l'inégalité de Bienaymé-Tchebychev à la variable aléatoire  $T_n$  en employant le nombre strictement positif  $a = \lambda n \ln n$  :

$$\frac{V(T_n)}{(\lambda n \ln n)^2} = \frac{V(T_n)}{\lambda^2 \times n^2 \times (\ln n)^2} \geq P(|T_n - E(T_n)| \geq \lambda n \ln n).$$

Compte tenu de la majoration de la variance obtenue en **XXIV. 2** :  $\frac{\pi^2}{6 \lambda^2 \times (\ln n)^2} \geq P(|T_n - E(T_n)| \geq \lambda n \ln n)$

**XXVI.** Nous avons vu en question **XXIII. 8** que :  $E(T_n) = n \times H_n$ . Appliquons l'inégalité de Bienaymé-

Tchebychev précédente en utilisant le réel  $\lambda = 1$ . Elle devient :  $\frac{\pi^2}{6 (\ln n)^2} \geq P(|T_n - n \times H_n| \geq n \ln n)$

Mais l'inégalité  $|T_n - n \times H_n| \geq n \ln n$  est réalisée si et seulement si  $T_n - n \times H_n \geq n \ln n$ , c'est-à-dire  $T_n \geq n \times H_n + n \ln n$  ou bien  $-T_n + n \times H_n \geq n \ln n$ , c'est-à-dire  $n \times H_n - n \ln n \geq T_n$ .

L'évènement  $[T_n \geq n \times H_n + n \ln n]$  est inclus dans l'évènement  $[|T_n - n \times H_n| \geq n \ln n]$  et donc a une probabilité plus faible.

On obtient :  $\frac{\pi^2}{6 (\ln n)^2} \geq P(T_n \geq n \times H_n + n \ln n)$ . Pour assurer que l'inégalité  $0,01 \geq P(T_n \geq n \times H_n + n \ln n)$

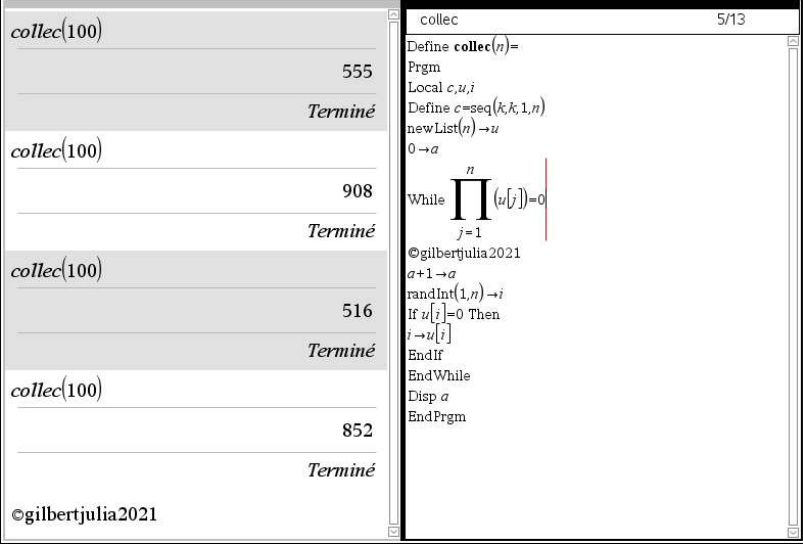
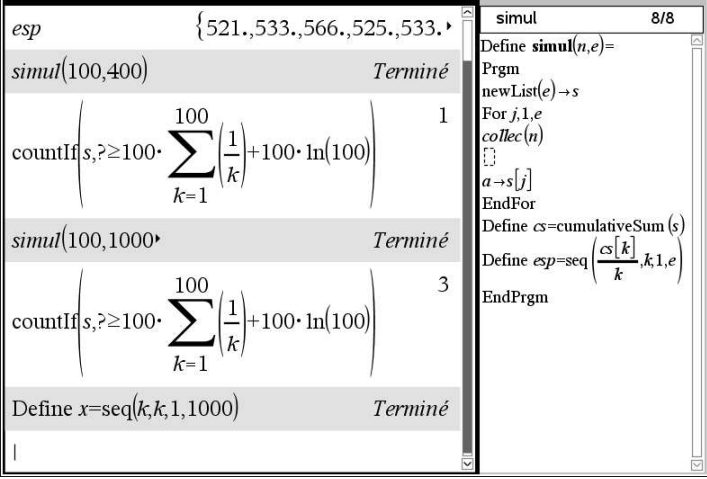
est réalisée, il suffit de choisir  $n$  de telle sorte que :  $0,01 \geq \frac{\pi^2}{6 (\ln n)^2}$ , c'est-à-dire de telle sorte que :

$$(\ln n)^2 \geq \frac{100 \pi^2}{6}, \text{ soit : } n \geq \exp\left(\frac{10 \pi}{\sqrt{6}}\right).$$

Une calculatrice indique que l'entier  $n_0 = 371573$  est convenable.

*Ce résultat exorbitant illustre le caractère théorique, et en pratique « anecdotique » de l'inégalité de Bienaymé-Tchebychev*

Complément : Une simulation.

<p>Le programme <b>collec</b> simule la confection d'une collection. Il renvoie le nombre d'achats à effectuer pour obtenir une collection complète. Il a été exécuté plusieurs fois avec 100 animaux.</p> <p>Avec 100 animaux, l'espérance du nombre d'achats devrait être voisine de 519. Il semble ici que le nombre d'achats soit plus grand. Qu'en est-il vraiment ?</p>	
<p>Le programme <b>simul</b> répète un certain nombre <b>e</b> de fois le programme précédent et répertorie dans une liste <b>s</b> les nombres d'achats nécessaires pour compléter la collection. La liste <b>esp</b> répertorie les moyennes des nombres d'achats nécessaires.</p> <p>On l'a exécuté pour 400 essais puis pour 1000. On note respectivement seulement 1 cas puis 3 cas où <math>T_n \geq n \times H_n + n \ln n</math></p>	
<p>Il semble bien que sur le long terme, le résultat « moyenne voisine de 519 » soit plausible.</p>	