

Statistiques TP 2 Probabilités et statistiques avec Maple7

A l'agrégation, seul maple7 étant pour l'instant disponible, on repart.... presque à 0. On commence par charger le package "stats", en tapant *with(stats)*:. On aura aussi besoin du package "statplots", et du package "plots".

On va travailler au début sur une variable aléatoire supposée modéliser la taille d'une population, qui suit une loi normale $N(\mu, \sigma^2)$ avec $\mu = 175$ et $\sigma = 10$.

1 Manipulation de lois, utilisation de commandes de base

Différence avec la feuille précédente : les commandes RandomVariable, et les manipulations formelles comme par exemple ExpectedValue, PDF(X,x), CDF(X,x) n'existent plus.

Pour une loi normale d'espérance 175 et d'écart-type 10, on peut :

- obtenir la valeur de la densité en un point au moyen de *statevalf[pdf,normald[175,10]](180)*;
- obtenir la valeur de la fonction de répartition en un point au moyen de *statevalf[cdf,normald[175,10]](180)*;
(Pour une variable aléatoire discrète, on peut obtenir la probabilité qu'elle vaille k à l'aide de *pf* : par exemple,) *statevalf[pf,binomiald[100,0.3]](35)*;
- obtenir le graphe de la densité au moyen de *plot(statevalf[pdf,normald[175,10]],140..200)*;
- obtenir une valeur approchée de l'espérance de X à l'aide de *f1:=x->statevalf[pdf,normald[175,10]](x); evalf(int(x*f1(x),x=100..300))*;
obtenir un échantillon de taille 1000 de X (pour maple, l'objet obtenue est une liste) à l'aide de
Ech:=random[normald[175,10]](1000);
(On peut ne pas mettre les `[]` extérieurs, mais dans ce cas à chaque fois qu'on manipule Ech dans la suite, il faut écrire `[Ech]`)
- obtenir la moyenne empirique, l'écart-type de l'échantillon précédent à l'aide de
describe[mean](Ech);
describe[standarddeviation](Ech);
- obtenir un quantile à l'aide de
describe[quantile[975/1000]](Ech)
Attention 0.975 ne marche pas, il faut vraiment une fraction.
- dessiner un histogramme de l'échantillon à l'aide de *histogram(Ech)*:. Si on veut des rectangles de largeur constante, utiliser *histogram(Ech,area=1)*.
- obtenir la courbe des quantiles à l'aide de *scatterplot(Ech, format=quantile)*;
- obtenir la fonction de répartition empirique à l'aide de *xyexchange(scatterplot(Ech, format=quantile))*;
- obtenir une "boîte à moustache" à l'aide de *boxplot(Ech)*.

2 Statistiques sur un échantillon de taille n

Ne refaites pas cette partie ! J'ai juste donné pour information comment répondre aux questions avec les commandes de maple7.

1. Générer un 100-échantillon Ech de loi normale $N(175, 100)$ à l'aide de la commande *random Ech:=random[normald[175,10]](100)*;

- Calculer la moyenne empirique $\bar{x} = \frac{\sum_{i=1}^n X_i}{n}$ de l'échantillon de trois manières : en faisant une boucle pour calculer la somme, à l'aide de la commande *add* (utilisée pour sommer un nombre fixé de termes), et à l'aide de la commande *mean*.
`add(Ech[i],i=1..100)/100;`
`moy:=describe[mean]([Ech]);`
- Calculer l'écart-type empirique $\bar{\sigma} = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{x})^2}{n-1}}$ (attention au $n - 1$, on verra sa justification plus tard en TD...) de deux manières : directement à l'aide de *add*, et à l'aide de *standarddeviation*.
`eca:=describe[standarddeviation]([Ech]);`
- Calculer le quantile correspondant à 0.975 à l'aide de *quantile*.
`describe[quantile[975/1000]]([Ech]);`
- Tracer un histogramme correspondant à l'échantillon *Ech* à l'aide de la commande *histogram*. Le représenter sur le même graphique que la vraie densité de X et que la densité estimée $N(\bar{x}, \bar{\sigma})$.
`P1:=histogram([Ech]);`
`P2:=plot(statevalf[pdf,normald[175,10]],140..200);`
`P3:=plot(statevalf[pdf,normald[moy,eca]],140..200);`
`plots[display](P1,P2,P3);`
- Construire un tableau qui contienne les quantiles de 0 à 1 par pas de 0.05. Tracer une fonction de répartition empirique à l'aide de ce tableau.
`qu:=array[1..20];`
`for i from 1 to 20 do qu[i]:=describe[quantile[i/20]]([Ech]); end do;`
`plot([seq([qu[i],i/20],i=1..20)]);`

3 Illustration de la loi des grands nombres

La loi des grands nombres est le théorème qui sera bientôt vu en Probabilités, qui dit que si $(X_n)_{n \in \mathbb{N}}$ est une suite de variables aléatoires indépendantes de même loi, d'espérance finie m , alors pour presque tout ω , $\frac{\sum_{i=1}^n X_i(\omega)}{n}$ converge vers m : la moyenne arithmétique converge vers l'espérance. Cela entraîne que si de plus $E(X_i^2)$ est finie, l'écart-type empirique converge presque sûrement vers le vrai écart-type. D'autre part, ici, on a également convergence des fonctions de répartition empiriques vers la fonction de répartition théorique.

- Générer un échantillon de X de taille 5000 et obtenir deux tableaux dont le i ème terme soit respectivement la moyenne empirique, l'écart-type empirique des i premiers termes.
 On pourra par exemple vérifier et utiliser $\sum_{i=1}^n (X_i - (\frac{1}{n} \sum_{j=1}^n X_j))^2 = \sum_{i=1}^n X_i^2 - \frac{1}{n} (\sum_{i=1}^n X_i)^2$
 On peut aussi construire des sous-échantillons : par exemple `[seq(Ech[i],i=1..10)]` construit un sous échantillon formé des 10 premiers termes de Ech.
- Représenter pour des tailles n allant de 30 à 5000 par pas de 10 la moyenne empirique \bar{x} en fonction de n ainsi qu'une droite horizontale correspondant à l'espérance; faire la même chose pour l'écart-type.
- Représenter les fonctions de répartition empiriques pour les tailles 100, 500,1000 et 5000 ainsi que la fonction de répartition théorique.
- On considère maintenant une variable aléatoire suivant une loi de Cauchy de paramètres $(0, 1)$ de densité $\frac{1}{\pi(1+x^2)}$. Est-elle d'espérance finie ? Effectuer les mêmes opérations que sur X .

4 Théorème central limite

1. On l'a vu, la moyenne empirique converge vers l'espérance. Représenter pour des tailles n allant de 30 à 5000 par pas de 10 $\frac{\sqrt{n}}{\sigma}(\bar{x} - \mu)$.

Cette quantité ne semble pas converger, mais elle reste d'ordre 1. Néanmoins, le théorème central limite affirme que si (X_n) est une suite de variables aléatoires indépendantes de même loi et d'espérance μ et de variance σ^2 finies, $\frac{\sqrt{n}}{\sigma}(\bar{x} - \mu)$, où \bar{x} est la moyenne arithmétique des n premiers X_i , converge en loi vers une loi normale centrée réduite. Cette quantité reste donc aléatoire, mais on sait comment elle est distribuée asymptotiquement.

2. Ici les X_i suivent une loi gaussienne, donc on connaît exactement la loi de $\frac{\sqrt{n}}{\sigma}(\bar{x} - \mu)$. Quelle est-elle ?
3. Construire une procédure qui prend en entrée deux entiers n et N_{obs} , génère N_{obs} n -échantillons de X , calcule pour chacun de ces échantillons $\frac{\sqrt{n}}{\sigma}(\bar{x} - \mu)$ et trace sur un même graphique un histogramme de ces grandeurs ainsi que la densité de la loi normale centrée réduite.

Rappel : une procédure se présente sous la forme :

```
Bidule := proc(parametres)
local i :: integer : (ligne pas indispensable)
instructions;
end proc;
```

4. Tester la procédure avec $N_{obs} = 1000$ et $n = 30, 50, 100, 300, 1000$.
5. L'intérêt de ce théorème est qu'il marche avec toute loi de variance finie. Soit Z une variable aléatoire qui suit une loi binomiale $B(n, p)$.
 - (a) Rappeler l'espérance de Z et sa variance. Pour $n = 100$ et $p = 0.3$, obtenir le graphe des $(k, P(Z = k))$ à l'aide de `pf`. Comparer avec la densité d'une variable aléatoire normale de même espérance et variance.
 - (b) Z suit la même loi qu'une somme de n variables de Bernoulli indépendantes de paramètre p . On peut donc appliquer le théorème central limite. Donner une procédure qui prend n, p et N_{obs} en entrée, génère un N_{obs} échantillon $(Z_1, \dots, Z_{N_{obs}})$ de loi binomiale $B(n, p)$ et trace un histogramme des $\frac{Z_i - np}{\sqrt{np(1-p)}}$ ainsi que la densité de la loi normale centrée réduite. Lancer la procédure avec $N_{obs} = 1000$, $n = 100$ et $p = 0.1$ puis $0.3, 0.5, 0.99$. Recommencer avec $n = 300$.
 - (c) On peut voir aussi la convergence en loi sur le graphe de la loi de probabilité. Tracer pour différentes valeurs de n et p le graphe formé des $(\frac{k - np}{\sqrt{np(1-p)}}, \sqrt{np(1-p)}P(Z = k))$, ainsi que la densité de la loi normale centrée réduite.

5 Challenge

J'ai mis sur ma page web (<http://www.math.u-bordeaux1.fr/~chabanol>), dans le répertoire Enseignement puis Statistiques 6 échantillons obtenus en simulant des lois classiques. Récupérez-les et faites-les lire par maple à l'aide de la commande `importdata('toto')`. Serez-vous capable de deviner quelle loi a généré chaque échantillon ?