

M1 finance: Statistiques non paramétriques

Fiche 3: Tests d'adéquation

Emeline Schmisser, `emeline.schmisser@math.univ-lille1.fr`, bureau 314 (bâtiment M3).

Exercice 1.

On observe les variables suivantes : 3,9 ; 3,6 ; 3,3 ; 3,1 ; 2,7.

1. Est-ce que ces données suivent une loi uniforme sur $[2,4]$? (niveau $\alpha = 10\%$).

Exercice 2 : Estimation de la fonction de répartition

1. On veut estimer F_X de telle sorte que pour tout x , $|F_n(x) - F_X(x)| \leq 0.20$ avec probabilité 0.90. Combien d'observations doit-on au minimum avoir ?
2. Même question, mais cette fois-ci on veut un intervalle de confiance à 95%.
3. On observe 13 variables aléatoires d'une fonction de répartition inconnue. Les observations sont 3.5, 4.1, 4.8, 5.0, 6.3, 7.1, 7.2, 7.8, 8.1, 8.4, 8.6, 9. Dessiner F_n et la zone de confiance pour l'estimation de F_X .

Exercice 3 : Test de Lilliefors pour les exponentielles

À partir du test de Kolmogorov-Smirnov, on veut construire un test qui permette de vérifier si des variables aléatoires (X_1, \dots, X_n) suivent une loi exponentielle de paramètre $1/\lambda$. On calcule donc

$$D_n = \sup_x |F_n(x) - \hat{F}_X(x)|$$

avec $\hat{F}_X(x) = 1 - e^{-x/\hat{\lambda}}$ où $\hat{\lambda} = \frac{1}{n} \sum_{i=1}^n X_i$. Avant de construire une table, il faut vérifier que la loi de D_n ne dépend pas de λ . Posons $Y_i = X_i/\lambda$.

1. Montrer que $Y_i \sim \mathcal{E}(1)$.
2. Calculer D_n^+ en fonction des X_i .
3. Calculer D_n^+ en fonction des Y_i .

Si la dernière expression ne dépend pas de λ , alors la loi de D_n^+ ne dépend pas de λ . Par symétrie, on conclut que D_n ne dépend pas de λ . On peut donc construire une table pour ce test.

Exercice 4.

On souhaite étudier les log-return de SP500. Le fichier est sur Moodle. On souhaite savoir quelle est la densité de ces variables.

1. Ouvrir le fichier `r500` avec R. Attention, R considère `r500` comme une matrice, il faut indiquer à R de ne considérer que la première colonne de cette matrice.

On souhaite savoir si la densité peut être gaussienne

2. Utilisez les fonctions `qqnorm` et `qqline`. Commentez les résultats. Comment sont les queues de distribution par rapport à une loi normale ?
3. Faites un test statistique pour savoir si `r500` suit une loi normale. Vous pouvez utiliser R comme une super calculatrice, mais le test doit être rédigé sur feuille. Donnez une majoration de la p-valeur.

Puisque les log-return ne suivent pas une loi normale, ils suivent peut-être une loi de Student. On suppose maintenant que

$$R = \sigma \sqrt{\frac{k-2}{k}} T(k)$$

où σ^2 est la variance des log-return.

4. Calculer le coefficient de Kurtosis normalisé des log-return. Quelles valeurs de k pourraient convenir ?
5. À l'aide de `qqplot`, regardez quelle valeur de k pourrait convenir.
6. Faire maintenant le test. On comparera la valeur de la statistique de test avec celles obtenues précédemment.

Remarque 1 – Les statistiques de test calculées avec **R** sont dans cet exercice toutes de l'ordre de $c10^{-2}$.

Si ce n'est pas le cas, il y a une erreur dans vos calculs ou vos fonctions.

- La densité des log-return a des queues lourdes, et probablement pas de moments d'ordre 4.
- La plupart de ces tests sont disponibles sous **R**. La fonction `ks.test` fait le test de Kolmogorov-Smirnov, et les fonctions `lillie.test` et `ad.test`, disponibles si on installe le paquet `nortest`, font les tests de Lilliefors et d'Anderson-Darling pour la normalité.

Exercice 5 : Fonction de répartition de D_n

On veut construire un programme qui calcule $\mathbb{P}(D_n \leq a)$ pour tout n et tout $a \in [0, 1]$. La loi de D_n n'est pas définie explicitement, on va donc utiliser une méthode de Monte-Carlo.

1. Construire une fonction `Dn` qui étant donné n , simule n variables i.i.d de loi uniforme sur $[0, 1]$ et calcule la statistique D_n .
2. Construire une fonction `simul` qui étant donné n , N et a :
 - Calcule N fois la statistique de test D_n .
 - Calcule $P_{a,n}$ la probabilité empirique que D_n soit plus petite que a .
 - Renvoie $P_{a,n}$.
3. Quelle est la variance de $P_{a,n}$?
4. On veut calculer F_{D_n} à 0.5% près. Quelle doit être la valeur de N minimale pour que $\mathbb{P}(|P_{a,n} - F_{D_n}(a)| \leq 0.005) \geq 0.95$?
5. Cherchez (au centième près) la médiane de F_{D_n} pour $n = 10$.
6. Même question (au millièmème près) si $n = 100$.