

3. COVARIANCE, CORRÉLATION ET ESTIMATION PONCTUELLE

3.1. **Variance de la somme.** Soient X et Y deux variables aléatoires pas nécessairement indépendantes. Calculer la variance de $X + Y$ en fonction des variances de X et Y et de leur covariance.

3.2. **Covariance pour les dés.** On désigne par $Y^{(1)}$ le nombre de 1 et par $Y^{(6)}$ le nombre de 6 apparaissant à l'issue de n lancers indépendants d'un dé équitale.

- (1) Quelle est la loi de probabilité de $Y^{(1)}$? de $Y^{(6)}$? de $Y^{(1)} + Y^{(6)}$?
- (2) Quel signe attendez-vous pour la covariance de $Y^{(1)}$ et $Y^{(6)}$?
- (3) Utiliser la formule pour la variance de la somme pour calculer la covariance et la corrélation de $Y^{(1)}$ et $Y^{(6)}$.

3.3. **Corrélation pour un geyser [R].** R a un jeu de données intégré nommé *faithful*. Il se compose d'une collection d'observations du geyser Old Faithful dans le parc national américain de Yellowstone. Pour avoir un aperçu du jeu, utiliser la fonction *head*. Le jeu de données contient 272 observations de durées d'éruption et intervalles de temps entre deux éruptions.

- (1) Tracer l'histogramme des durées de éruptions.
- (2) Tracer l'histogramme des intervalles d'attente.
- (3) Tracer le diagramme de dispersion des durées d'éruption et des intervalles d'attente. Est-ce qu'il révèle une relation entre les variables ?
- (4) Calculer la corrélation entre les 2 variables.

Suggestions: utiliser les fonctions R *hist*, *cor* et le symbole $\$$ pour extraire une colonne du jeu de données (par exemple *faithful\$eruptions*).

3.4. **Estimateur pour la v.a. exponentielle.** Soit $\{x_1, x_2, \dots, x_n\}$ un échantillon provenant d'une loi de densité exponentielle de paramètre λ . Déterminer l'estimateur du maximum de vraisemblance de λ . Est-il biaisé ? Est-il convergent ?

3.5. **Estimateur de la probabilité de pile.** Considérez des tirages indépendantes à pile ou face, et soit p la probabilité de pile à chaque tirage.

- (1) Fixez n et soit k le nombre de piles observées dans n tirages. Trouver l'estimateur du maximum de vraisemblance de p basé sur k .
- (2) Fixez k et soit n le nombre de tirages jusqu'à que la k -ème pile se produise. Trouver l'estimateur du maximum de vraisemblance de p basé sur N .

3.6. **Estimation du paramètre d'une variable aléatoire uniforme.** On nous donne un échantillon de n observations $\{x_1, x_2, \dots, x_n\}$, qui sont tirées d'une distribution uniforme sur $[0, \theta]$. Quel est l'estimateur du maximum de vraisemblance de θ ? Est-il convergent ? Est-il sans biais ou asymptotiquement sans biais ? Pouvez-vous construire des estimateurs alternatifs qui sont sans biais ?

3.7. **Au restaurant.** Soit une certaine population P dont on sait que le pourcentage mangeant x fois au restaurant sur 3 jours est :

- $x = 0$; 50%
- $x = 1$; 20%
- $x = 2$; 20%
- $x = 3$; 10%

On considère un sous-ensemble R de la population (par exemple les personnes répondant au téléphone l'après-midi), en gros $1/4$ de P . Pour R les pourcentages sont :

- $x = 0$; 76%
- $x = 1$; 12%
- $x = 2$; 8%
- $x = 3$; 4%

- (1) Déterminer le nombre moyen μ_P (resp. μ_R) de fois qu'une personne de P (resp. R) mange au restaurant.
- (2) Un premier statisticien fait un sondage par téléphone dans l'après-midi jusqu'à ce qu'il obtienne 50 réponses. Il prend comme estimateur $\hat{\mu}_{P,1} = \frac{x_1 + \dots + x_{50}}{50}$ où x_i est la valeur donnée par la personne i . Quel est le biais de $\hat{\mu}_{P,1}$ $B(\hat{\mu}_{P,1}) := E[\hat{\mu}_{P,1}] - \mu_P$? Quelle est l'erreur quadratique moyenne $E[(\hat{\mu}_{P,1} - \mu_P)^2]$?
- (3) Même question avec 200 réponses.
- (4) Un autre statisticien fait un sondage sur un échantillon aléatoire de 20 personnes à qui il téléphone matin et après-midi jusqu'à ce qu'il obtienne une réponse et prend comme estimateur $\hat{\mu}_{P,2} = \frac{y_1 + \dots + y_{20}}{20}$ où y_i est la valeur donnée par la personne i . Calculer le biais $B(\hat{\mu}_{P,2})$ et l'erreur quadratique moyenne $E[(\hat{\mu}_{P,2} - \mu_P)^2]$.
- (5) Conclusion ?

3.8. **Niveau d'eau.** Un limnimètre peut mesurer le niveau d'un fleuve entre h_1 et h_2 . On assume que le niveau suit une loi exponentielle avec espérance θ inconnue. Supposons que n mesures $\{x_1, x_2, \dots, x_n\}$ soient disponibles.

- (1) Quelle est la fonction de vraisemblance ?
- (2) Si $h_1 = 1$, $h_2 = 20$ and les mesures sont $\{1.5, 2, 3, 4, 5, 12\}$, trouvez approximativement l'estimation du maximum de vraisemblance de θ .