

Série d'Exercices n°3

Processus Empiriques

Master 2 Probabilités et Statistiques
Département de Mathématiques
Université Mohamed Khider - Biskra

Année Universitaire 2025/2026

Exercice 1 : Théorèmes Fondamentaux

a) Théorème de Glivenko-Cantelli

- i) Énoncer précisément le théorème de Glivenko-Cantelli.
- ii) Soit X_1, \dots, X_n des variables aléatoires i.i.d. de fonction de répartition continue F . On note F_n la fonction de répartition empirique. Montrer que :

$$\sup_{t \in \mathbb{R}} |F_n(t) - F(t)| \xrightarrow{p.s.} 0 \quad \text{quand } n \rightarrow \infty$$

- iii) Donner une borne sur la vitesse de convergence en utilisant l'inégalité de Dvoretzky-Kiefer-Wolfowitz.

b) Théorème de Donsker (Théorème Fonctionnel Central Limite)

- i) Énoncer le théorème de Donsker pour le processus empirique.
- ii) Soit $\mathbb{G}_n(t) = \sqrt{n}(F_n(t) - F(t))$. Montrer que pour F continue, \mathbb{G}_n converge en loi vers un pont brownien $B \circ F$ dans l'espace $\ell^\infty(\mathbb{R})$.
- iii) Expliquer pourquoi ce résultat est fondamental pour la construction des tests d'adéquation non paramétriques.

Exercice 2 : Pont Brownien et Distribution de Kolmogorov-Smirnov

Soit $B = \{B(t), 0 \leq t \leq 1\}$ un pont brownien standard.

a) Définition et propriétés du pont brownien

- i) Donner la définition d'un pont brownien à partir d'un mouvement brownien.
- ii) Calculer $\mathbb{E}[B(t)]$ et $\text{Cov}(B(s), B(t))$ pour $0 \leq s \leq t \leq 1$.
- iii) Montrer que $B(t)$ et $B(1-t)$ ont même loi.

b) Maximum d'un pont brownien et distribution de KS

- i) Soit $M = \sup_{0 \leq t \leq 1} |B(t)|$. La fonction de répartition de M est donnée par :

$$P(M \leq x) = 1 - 2 \sum_{k=1}^{\infty} (-1)^{k-1} e^{-2k^2 x^2}$$

En déduire que sous H_0 , pour n grand :

$$P(\sqrt{n}D_n \leq x) \approx 1 - 2 \sum_{k=1}^{\infty} (-1)^{k-1} e^{-2k^2 x^2}$$

où $D_n = \sup_t |F_n(t) - F(t)|$.

- ii) Calculer les valeurs critiques pour $\alpha = 0.05$ et $\alpha = 0.01$ à partir de cette formule. Comparer avec les valeurs tabulées pour $n = 20$.

Exercice 3 : Inégalités de Concentration et Applications

Soit $\mathcal{F} = \{\mathbb{1}_{(-\infty, t]}, t \in \mathbb{R}\}$ la classe des fonctions indicatrices des demi-droites.

a) **Inégalité de Dvoretzky-Kiefer-Wolfowitz (DKW)**

- i) Énoncer l'inégalité DKW : pour tout $\epsilon > 0$,

$$P\left(\sup_{t \in \mathbb{R}} |F_n(t) - F(t)| > \epsilon\right) \leq 2e^{-2n\epsilon^2}$$

- ii) Utiliser cette inégalité pour construire des bandes de confiance non-asymptotiques pour F . Expliciter les bornes inférieure et supérieure pour un niveau de confiance $1 - \alpha$.
 iii) Pour $n = 100$ et $\alpha = 0.05$, calculer la largeur des bandes de confiance. Application numérique.

b) **Comparaison avec l'approche de Kolmogorov-Smirnov**

- i) Montrer que pour n fixé, l'approche DKW donne des bandes de confiance plus larges que celle basée sur la distribution exacte de Kolmogorov-Smirnov.
 ii) Expliquer pourquoi on préfère souvent utiliser le test de Kolmogorov-Smirnov en pratique, malgré l'avantage de non-asymptoticité de DKW.

Exercice 4 : Processus Empirique Indexé par des Classes de Fonctions

Soit \mathcal{F} une classe de fonctions mesurables bornées.

a) **Processus empirique généralisé**

- i) Définir le processus empirique indexé par \mathcal{F} :

$$\mathbb{G}_n(f) = \sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n f(X_i) - \mathbb{E}[f(X)] \right), \quad f \in \mathcal{F}$$

- ii) Donner deux exemples de classes \mathcal{F} et expliquer leur intérêt statistique.

b) **Classes Donsker**

- i) Définir ce qu'est une classe Donsker.
 ii) Donner une condition suffisante sur \mathcal{F} pour qu'elle soit Donsker (condition sur la dimension VC).
 iii) Montrer que la classe $\mathcal{F} = \{\mathbb{1}_{(-\infty, t]}, t \in \mathbb{R}\}$ est Donsker.

Exercice 5 : Bootstrap du Processus Empirique

Soit X_1, \dots, X_n i.i.d. de loi F , et soit X_1^*, \dots, X_n^* un échantillon bootstrap tiré de F_n .

a) **Processus empirique bootstrap**

- i) Définir $F_n^*(t) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{X_i^* \leq t\}}$.
 ii) Montrer que conditionnellement à X_1, \dots, X_n , on a :

$$\sqrt{n}(F_n^* - F_n) \xrightarrow{\mathcal{L}} \mathbb{G} \quad \text{presque sûrement}$$

où \mathbb{G} est le processus empirique limite.

b) **Application au test de Kolmogorov-Smirnov**

- i) Proposer une procédure bootstrap pour approximer la distribution de la statistique $D_n = \sup_t |F_n(t) - F(t)|$.
- ii) Expliquer l'intérêt de cette approche bootstrap, notamment dans le cas où les paramètres de la loi théorique sont estimés à partir des données.

Ressources bibliographiques

- Van der Vaart, A. W. (2000). *Asymptotic Statistics*.
- Shorack, G. R., & Wellner, J. A. (1986). *Empirical Processes with Applications to Statistics*.
- Lehmann, E. L., & Romano, J. P. (2005). *Testing Statistical Hypotheses*.
- Articles originaux :
 - Kolmogorov, A. N. (1933). Sulla determinazione empirica di una legge di distribuzione.
 - Cramér, H. (1928). On the composition of elementary errors.
 - Anderson, T. W., & Darling, D. A. (1954). A test of goodness of fit.

Bon travail !