

MTH 8302 - Modèles de Régression et d'Analyse de Variance

Série d'Exercices 1 : Préparation pour le Devoir 1 et Test t pour la Régression Linéaire

Polytechnique Montréal - Hiver 2025

Chiheb Trabelsi

February 4, 2025



Table des Matières

- 1 Problème 1 : Gradients et Hessiennes
- 2 Problème 2 : Estimation par MEV pour la Loi Exp
- 3 Problème 3 : Estimation par MEV pour la Loi Bin
- 4 Problème 4 : Test t en Régression Linéaire
- 5 Problème 5 : Visualisation des LGN & TCL

Problème 1 : Gradients et Hessiennes

Problème 1 : Gradients et Hessiennes

• Rappel :

- Une matrice $\mathbf{A} \in \mathbb{R}^{n \times n}$ est symétrique si $\mathbf{A}^T = \mathbf{A}$.
- Le gradient $\nabla f(\mathbf{x})$ d'une fonction $f : \mathbb{R}^n \rightarrow \mathbb{R}$ est un vecteur contenant les dérivées partielles :

$$\nabla f(\mathbf{x}) = \begin{bmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_n} \end{bmatrix} = \left(\frac{\partial f}{\partial \mathbf{x}} \right).$$

- La Hessienne $\nabla^2 f(\mathbf{x})$ est une matrice symétrique $n \times n$ contenant les dérivées secondes :

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1^2} & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_2} & \cdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_2^2} & \cdots \\ \vdots & \vdots & \ddots \end{bmatrix}.$$

Règles de Dérivées Partielles :

- **Dérivée d'une forme quadratique** : Si \mathbf{x} est un vecteur et \mathbf{A} est une matrice symétrique, la dérivée de la forme quadratique $\mathbf{x}^T \mathbf{A} \mathbf{x}$ par rapport à \mathbf{x} est donnée par :

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{x}^T \mathbf{A} \mathbf{x}) = 2\mathbf{A} \mathbf{x}$$

- **Dérivée d'une forme linéaire** : Pour un vecteur \mathbf{x} et une matrice constante \mathbf{A} , la dérivée de $\mathbf{A} \mathbf{x}$ par rapport à \mathbf{x} est :

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{A} \mathbf{x}) = \mathbf{A}$$

où \mathbf{A} est considéré comme une constante par rapport à \mathbf{x} .

- **Dérivée d'un produit de type vecteur-matrice-vecteur** : Si \mathbf{b} et \mathbf{x} sont des vecteurs et \mathbf{A} est une matrice, alors la dérivée de $\mathbf{b}^T \mathbf{A} \mathbf{x}$ par rapport à \mathbf{x} est :

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{b}^T \mathbf{A} \mathbf{x}) = \mathbf{A}^T \mathbf{b}$$

Règles de Dérivation :

- **Dérivée d'une matrice dépendant d'un vecteur** : Si \mathbf{A} est une matrice qui ne dépend pas du vecteur \mathbf{x} et \mathbf{A} n'est pas nécessairement symétrique, alors la dérivée de $\mathbf{x}^T \mathbf{A} \mathbf{x}$ est :

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{x}^T \mathbf{A} \mathbf{x}) = \mathbf{x}^T (\mathbf{A} + \mathbf{A}^T)$$

si \mathbf{A} n'est pas nécessairement symétrique.

- **Dérivée du produit de deux matrices** : Si $\mathbf{A}(\mathbf{x})$ et $\mathbf{B}(\mathbf{x})$ sont des matrices dépendant du vecteur \mathbf{x} , alors la dérivée de leur produit $\mathbf{A}(\mathbf{x})\mathbf{B}(\mathbf{x})$ est donnée par :

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{A}(\mathbf{x})\mathbf{B}(\mathbf{x})) = \frac{\partial \mathbf{A}}{\partial \mathbf{x}} \mathbf{B} + \mathbf{A} \frac{\partial \mathbf{B}}{\partial \mathbf{x}}$$

Problème 1 : Question 1

- **Fonction** : $g(\mathbf{x}) = \log(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}) + \mathbf{d}^\top \mathbf{x}$, où \mathbf{C} symétrique.
- **Objectif** : Trouver $\nabla_{\mathbf{x}}g(\mathbf{x})$
- **Solution** :
- **Justification Détaillée** :

Problème 1 : Question 1 (Solution)

- **Fonction** : $g(\mathbf{x}) = \log(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}) + \mathbf{d}^\top \mathbf{x}$
- **Objectif** : Trouver $\nabla_{\mathbf{x}}g(\mathbf{x})$
- **Solution** : $\nabla_{\mathbf{x}}g(\mathbf{x}) = \frac{2\mathbf{C}\mathbf{x}}{1+\mathbf{x}^\top \mathbf{C}\mathbf{x}} + \mathbf{d}$
- **Justification Détaillée** :
 - ① **Décomposition de la Fonction** :
 - La fonction g se compose de deux termes : un terme logarithmique $\log(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x})$ et un terme linéaire $\mathbf{d}^\top \mathbf{x}$.
 - ② **Dérivation du Terme Logarithmique** :
 - Utilisons la règle de la chaîne pour la dérivation du terme logarithmique. Soit $h = 1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}$, la dérivée de h par rapport à \mathbf{x} est $2\mathbf{C}\mathbf{x}$ si \mathbf{C} est symétrique.
 - En combinant ces résultats, la contribution de la partie logarithmique au gradient est $\frac{2\mathbf{C}\mathbf{x}}{1+\mathbf{x}^\top \mathbf{C}\mathbf{x}}$.
 - ③ **Dérivation du Terme Linéaire** :
 - La dérivée du terme linéaire $\mathbf{d}^\top \mathbf{x}$ est simple et puisque la dérivée de \mathbf{x} par rapport à lui-même est l'identité.
 - ④ **Combinaison des Gradients** :
 - Le gradient total de $g(\mathbf{x})$ est la somme des gradients des deux termes. Donc, $\nabla_{\mathbf{x}}g(\mathbf{x}) = \frac{2\mathbf{C}\mathbf{x}}{1+\mathbf{x}^\top \mathbf{C}\mathbf{x}} + \mathbf{d}$.

Problème 1 : Question 2

- **Fonction** : $g(\mathbf{x}) = \log(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}) + \mathbf{d}^\top \mathbf{x}$, où \mathbf{C} symétrique.
- **Objectif** : Trouver $\nabla_{\mathbf{x}}^2 g(\mathbf{x})$
- **Solution** :
- **Justification Détaillée** :

Problème 1 : Question 2 (Solution)

- **Fonction** : $g(\mathbf{x}) = \log(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}) + \mathbf{d}^\top \mathbf{x}$, où \mathbf{C} symétrique.
- **Objectif** : Trouver $\nabla_{\mathbf{x}}^2 g(\mathbf{x})$
- **Solution** : $\nabla_{\mathbf{x}}^2 g(\mathbf{x}) = \frac{2\mathbf{C}}{1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}} - \frac{4\mathbf{C}\mathbf{x}\mathbf{x}^\top \mathbf{C}}{(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x})^2}$
- **Justification Détaillée** :

① **Rappel du Gradient** : Le gradient calculé précédemment est $\frac{2\mathbf{C}\mathbf{x}}{1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}}$.

② **Application de la Règle du Quotient** :

- Pour la Hessienne, nous appliquons la règle du quotient à chaque terme du gradient. Le dénominateur commun est $(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x})^2$.
- Le numérateur implique la différentiation du produit $2\mathbf{C}\mathbf{x}$ où \mathbf{C} est constant.

③ **Différentiation du Produit** :

- La dérivée de $2\mathbf{C}\mathbf{x}$ par rapport à \mathbf{x} donne $2\mathbf{C}$, qui est constante par rapport à \mathbf{x} .
- La dérivée du produit $\mathbf{x}^\top \mathbf{C}\mathbf{x}$ donne $2\mathbf{C}\mathbf{x}$ en utilisant la symétrie de \mathbf{C} .
- Le produit des dérivées implique $\mathbf{C}\mathbf{x}(\mathbf{C}\mathbf{x})^\top$ soit $\mathbf{C}\mathbf{x}\mathbf{x}^\top \mathbf{C}$.

④ **Combinaison des Résultats** :

- Combiner tous les termes en respectant les signes et les puissances du dénominateur pour former la Hessienne finale.

Problème 1 : Question 2 (Solution)

- **Fonction** : $g(\mathbf{x}) = \log(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}) + \mathbf{d}^\top \mathbf{x}$, où \mathbf{C} symétrique.
- **Objectif** : Trouver $\nabla_{\mathbf{x}}^2 g(\mathbf{x})$
- **Solution** : $\nabla_{\mathbf{x}}^2 g(\mathbf{x}) = \frac{2\mathbf{C}}{1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}} - \frac{4(\mathbf{x}^\top \mathbf{C}\mathbf{x})\mathbf{C}\mathbf{x}}{(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x})^2}$
- **Justification Détaillée** :
 - ① **Rappel du Gradient** : Le gradient calculé précédemment est $\frac{2\mathbf{C}\mathbf{x}}{1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}}$.
 - ② **Application de la Règle du Quotient** :
 - Pour la Hessienne, nous appliquons la règle du quotient à chaque terme du gradient.
 - La dérivée partielle de $\mathbf{x}^\top \mathbf{C}\mathbf{x}$ est $2\mathbf{C}\mathbf{x}$, résultant de la symétrie de \mathbf{C} .
 - ③ **Différentiation du Produit** :
 - La dérivée seconde de $2\mathbf{C}\mathbf{x}$ par rapport à \mathbf{x} est $2\mathbf{C}$.
 - Pour $\mathbf{x}^\top \mathbf{C}\mathbf{x}$ produit $2\mathbf{C}\mathbf{x}$, on obtient en différenciant encore $2\mathbf{C}$.
 - Finalement, la différenciation de $\mathbf{x}^\top \mathbf{C}\mathbf{x} \cdot \mathbf{x}^\top \mathbf{C}\mathbf{x}$ contribue avec $4(\mathbf{x}^\top \mathbf{C}\mathbf{x})\mathbf{C}\mathbf{x}$.
 - ④ **Expression Finale de la Hessienne** :

$$\nabla_{\mathbf{x}}^2 g(\mathbf{x}) = \frac{2\mathbf{C}}{1 + \mathbf{x}^\top \mathbf{C}\mathbf{x}} - \frac{4(\mathbf{x}^\top \mathbf{C}\mathbf{x})\mathbf{C}\mathbf{x}}{(1 + \mathbf{x}^\top \mathbf{C}\mathbf{x})^2}$$

Problème 1 : Question 3

- **Fonction :** $h(\mathbf{x}) = e^{-\mathbf{d}^\top \mathbf{x}} + \mathbf{x}^\top \mathbf{B} \mathbf{x}$
- **Objectif :** Trouver $\nabla_{\mathbf{x}} h(\mathbf{x})$
- **Solution :**
- **Justification :**
 - Application de la règle de la chaîne pour le terme exponentiel et la dérivation directe pour le terme quadratique.

Problème 1 : Question 3 (Solution)

- **Fonction** : $h(\mathbf{x}) = e^{-d\mathbf{x}^\top} + \mathbf{x}^\top \mathbf{B}\mathbf{x}$, où \mathbf{B} symétrique.
- **Objectif** : Trouver $\nabla_{\mathbf{x}}h(\mathbf{x})$
- **Solution** : $\nabla_{\mathbf{x}}h(\mathbf{x}) = -de^{-d\mathbf{x}^\top} + 2\mathbf{B}\mathbf{x}$
- **Justification** :
 - **Décomposition de la Fonction** :
 - La fonction h est composée de deux termes: un terme exponentiel $e^{-d\mathbf{x}^\top}$ et un terme quadratique $\mathbf{x}^\top \mathbf{B}\mathbf{x}$.
 - **Dérivation du Terme Exponentiel** :
 - Utilisons la règle de la chaîne pour la dérivation du terme $e^{-d\mathbf{x}^\top}$. Soit $z = -d\mathbf{x}^\top$, alors la dérivée par rapport à \mathbf{x} est $-d$ multiplié par la dérivée de e^z qui est e^z , résultant en $-de^{-d\mathbf{x}^\top}$.
 - **Dérivation du Terme Quadratique** :
 - La dérivée du terme quadratique $\mathbf{x}^\top \mathbf{B}\mathbf{x}$ est directe, étant donné que \mathbf{B} est symétrique. Elle est donnée par $2\mathbf{B}\mathbf{x}$, en suivant la règle standard pour la différentiation des formes quadratiques.
 - **Combinaison des Gradients** :
 - Le gradient total de $h(\mathbf{x})$ est la somme des gradients des deux termes, donc,

$$\nabla_{\mathbf{x}}h(\mathbf{x}) = -de^{-d\mathbf{x}^\top} + 2\mathbf{B}\mathbf{x}$$

Problème 1 : Question 4

- **Fonction** : Identique à la question 3.
- **Objectif** : Trouver $\nabla_{\mathbf{x}}^2 h(\mathbf{x})$
- **Solution** :
- **Justification** :
 - Le calcul des dérivées secondes pour chaque terme utilise la continuité de la dérivation du terme exponentiel et la constance de B .

Problème 1 : Question 4 (Solution)

- **Fonction** : Utilisez la même fonction que la question 3.

- **Objectif** : Trouver $\nabla_{\mathbf{x}}^2 h(\mathbf{x})$

- **Solution** : $\nabla_{\mathbf{x}}^2 h(\mathbf{x}) = dd^{\top} e^{-d\mathbf{x}^{\top}} + 2\mathbf{B}$

- **Justification** :

- **Décomposition du Gradient** :

- De la question 3, nous avons le gradient :

$$\nabla_{\mathbf{x}} h(\mathbf{x}) = -de^{-d\mathbf{x}^{\top}} + 2\mathbf{B}\mathbf{x}$$

- **Dérivation du Terme Exponentiel** :

- La dérivée seconde de $-de^{-d\mathbf{x}^{\top}}$ s'obtient en appliquant la règle du produit :

$$\nabla_{\mathbf{x}}^2 (-de^{-d\mathbf{x}^{\top}}) = dd^{\top} e^{-d\mathbf{x}^{\top}}$$

- **Dérivation du Terme Quadratique** :

- La dérivée seconde de $2\mathbf{B}\mathbf{x}$ est simplement $2\mathbf{B}$, car \mathbf{B} est une matrice constante.

- **Combinaison des Hessiennes** :

- En combinant les deux termes, nous obtenons la Hessienne :

$$\nabla_{\mathbf{x}}^2 h(\mathbf{x}) = dd^{\top} e^{-d\mathbf{x}^{\top}} + 2\mathbf{B}$$

Problème 1 : Question 5

- **Fonction** : $j(\mathbf{x}) = \|\mathbf{C}\mathbf{x} + \mathbf{d}\|_1$
- **Objectif** : Trouver $\nabla_{\mathbf{x}}j(\mathbf{x})$
- **Solution** :
- **Justification** :

Problème 1 : Question 5 (Solution)

- **Fonction** : $j(\mathbf{x}) = \|\mathbf{C}\mathbf{x} + \mathbf{d}\|_1$
- **Objectif** : Trouver $\nabla_{\mathbf{x}}j(\mathbf{x})$
- **Solution** : $\nabla_{\mathbf{x}}j(\mathbf{x}) = \mathbf{C}^\top \text{sgn}(\mathbf{C}\mathbf{x} + \mathbf{d})$
- **Justification - Définition de la Norme ℓ_1** :
 - La norme ℓ_1 est définie par :

$$\|\mathbf{y}\|_1 = \sum_i |y_i|, \quad \text{où } \mathbf{y} = \mathbf{C}\mathbf{x} + \mathbf{d}$$

- **Représentation Composante par Composante** :
 - En écrivant la norme comme une somme : $j(\mathbf{x}) = \sum_i |(\mathbf{C}\mathbf{x} + \mathbf{d})_i|$
- **Calcul du Gradient** :
 - La dérivée de $|y_i|$ est donnée par la fonction signe sgn :

$$\frac{\partial}{\partial x} |y_i| = \text{sgn}(y_i) \cdot \frac{\partial y_i}{\partial x}$$

- Or, $y_i = \mathbf{C}_i^\top \mathbf{x} + d_i$, donc sa dérivée est \mathbf{C}_i^\top .
- En sommant sur toutes les composantes : $\nabla_{\mathbf{x}}j(\mathbf{x}) = \sum_i \text{sgn}(y_i) \mathbf{C}_i^\top$

Problème 1 : Question 5 (Solution)

- **Expression Matricielle** : En notation matricielle compacte, cela donne : $\nabla_{\mathbf{x}} j(\mathbf{x}) = \mathbf{C}^\top \text{sgn}(\mathbf{C}\mathbf{x} + \mathbf{d})$

Problème 1 : Question 6

- **Fonction** : $f(\mathbf{x}) = \|\mathbf{C}\mathbf{x} + \mathbf{d}\|_2^2$
- **Objectif** : Trouver $\nabla_{\mathbf{x}}^2 f(\mathbf{x})$
- **Solution** :
- **Justification** :

Problème 1 : Question 6 (Solution)

- **Fonction** : $f(\mathbf{x}) = \|\mathbf{Cx} + \mathbf{d}\|_2^2$
- **Objectif** : Trouver $\nabla_{\mathbf{x}}^2 f(\mathbf{x})$
- **Solution** : $\nabla_{\mathbf{x}}^2 f(\mathbf{x}) = 2\mathbf{C}^T \mathbf{C}$
- **Justification - Définition de la Norme ℓ_2** :
 - La norme au carré est définie par :

$$\|\mathbf{y}\|_2^2 = \mathbf{y}^T \mathbf{y}, \quad \text{où } \mathbf{y} = \mathbf{Cx} + \mathbf{d}$$

- **Expansion de l'Expression** :
 - Exprimons la fonction sous une forme quadratique :

$$f(\mathbf{x}) = (\mathbf{Cx} + \mathbf{d})^T (\mathbf{Cx} + \mathbf{d})$$

- Développons le produit :

$$f(\mathbf{x}) = \mathbf{x}^T \mathbf{C}^T \mathbf{C} \mathbf{x} + 2\mathbf{d}^T \mathbf{C} \mathbf{x} + \mathbf{d}^T \mathbf{d}$$

Problème 1 : Question 6 (Solution)

• Calcul du Gradient :

- Le gradient du terme quadratique $\mathbf{x}^\top \mathbf{A} \mathbf{x}$ (où \mathbf{A} est symétrique) est $2\mathbf{A}\mathbf{x}$. Ici, $\mathbf{A} = \mathbf{C}^\top \mathbf{C}$.
- La dérivée du terme linéaire $2\mathbf{d}^\top \mathbf{C}\mathbf{x}$ est $2\mathbf{C}^\top \mathbf{d}$.
- En combinant ces résultats, nous obtenons :

$$\nabla_{\mathbf{x}} f(\mathbf{x}) = 2\mathbf{C}^\top \mathbf{C}\mathbf{x} + 2\mathbf{C}^\top \mathbf{d}$$

• Calcul de la Hessienne :

- Le gradient étant $\nabla_{\mathbf{x}} k(\mathbf{x}) = 2\mathbf{C}^\top \mathbf{C}\mathbf{x} + 2\mathbf{C}^\top \mathbf{d}$, la dérivée seconde est obtenue en différenciant à nouveau :

$$\nabla_{\mathbf{x}}^2 k(\mathbf{x}) = \nabla_{\mathbf{x}} (2\mathbf{C}^\top \mathbf{C}\mathbf{x} + 2\mathbf{C}^\top \mathbf{d})$$

- Comme $\mathbf{C}^\top \mathbf{C}$ est une matrice constante, la dérivée donne :

$$\nabla_{\mathbf{x}}^2 k(\mathbf{x}) = 2\mathbf{C}^\top \mathbf{C}$$

- **Note:** La Hessienne est une matrice constante, indiquant que la fonction $f(\mathbf{x})$ est une fonction quadratique à courbure uniforme.
- Cette Hessienne est utilisée en optimisation, notamment dans les problèmes de régression quadratique et d'apprentissage automatique.

Table des Matières

- 1 Problème 1 : Gradients et Hessiennes
- 2 Problème 2 : Estimation par MEV pour la Loi Exp**
- 3 Problème 3 : Estimation par MEV pour la Loi Bin
- 4 Problème 4 : Test t en Régression Linéaire
- 5 Problème 5 : Visualisation des LGN & TCL

Estimation par la Méthode du Maximum de Vraisemblance et Propriétés des Estimateurs (Loi Exponentielle)

Problème 2 : Estimation par MEV pour la Loi Exp

- Soit X_1, X_2, \dots, X_n un échantillon aléatoire issu d'une **loi exponentielle** de paramètre θ , c'est-à-dire :

$$f(x; \theta) = \frac{1}{\theta} e^{-x/\theta}, \quad x > 0.$$

- Déterminer l'estimateur du maximum de vraisemblance (EMV) du paramètre θ .
- Vérifier si cet estimateur est biaisé.
- Vérifier si cet estimateur est consistant (ou convergent) en calculant sa variance.

Rappel : On appelle **erreur quadratique moyenne** la quantité :

$$EQM(\hat{\theta}_n) = \mathbb{E} \left[(\hat{\theta}_n - \theta)^2 \right] = \text{Var}(\hat{\theta}_n) + [\text{Biais}(\hat{\theta}_n)]^2.$$

Un estimateur est dit **consistant** si :

$$\lim_{n \rightarrow \infty} EQM(\hat{\theta}_n) = 0.$$

Problème 2 : Estimation par MEV pour la Loi Exp

- On observe les fréquences suivantes pour une variable X suivant une

	x	$f_X(x)$
loi exponentielle :	$(0, 1]$	10
	$(1, 2]$	15
	$(2, 3]$	8
	$(3, 4]$	5
	$(4, 5]$	2

- Trouver l'estimateur du maximum de vraisemblance (EMV) de θ en utilisant les données observées.
- Estimer la probabilité $P(X \leq 2)$.

Problème 2 : Estimation par MEV pour la Loi Exp

- Soit X_1, X_2, \dots, X_n un échantillon aléatoire issu d'une loi exponentielle de paramètre θ , c'est-à-dire :

$$f(x; \theta) = \frac{1}{\theta} e^{-x/\theta}, \quad x > 0.$$

- Nous allons déterminer l'estimateur du maximum de vraisemblance (EMV) du paramètre θ , puis analyser ses propriétés.

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- La fonction de vraisemblance est donnée par :

$$L(\theta) = \prod_{i=1}^n f(X_i; \theta) = \prod_{i=1}^n \frac{1}{\theta} e^{-X_i/\theta}.$$

- En prenant le logarithme :

$$\ell(\theta) = \sum_{i=1}^n \left(-\ln \theta - \frac{X_i}{\theta} \right) = -n \ln \theta - \frac{1}{\theta} \sum_{i=1}^n X_i.$$

- On dérive par rapport à θ et on résout :

$$\frac{d\ell}{d\theta} = -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n X_i = 0.$$

- En résolvant, on obtient :

$$\hat{\theta}_{EMV} = \frac{1}{n} \sum_{i=1}^n X_i.$$

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- Calculons l'espérance de $\hat{\theta}_{EMV}$:

$$\mathbb{E}[\hat{\theta}_{EMV}] = \mathbb{E}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i].$$

- Comme $\mathbb{E}[X_i] = \theta$, on obtient :

$$\mathbb{E}[\hat{\theta}_{EMV}] = \theta.$$

- L'estimateur est donc non biaisé.

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- La variance de $\hat{\theta}_{EMV}$ est donnée par :

$$\text{Var}(\hat{\theta}_{EMV}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i).$$

- Comme $\text{Var}(X_i) = \theta^2$, on a :

$$\text{Var}(\hat{\theta}_{EMV}) = \frac{\theta^2}{n}.$$

- L'erreur quadratique moyenne est :

$$EQM(\hat{\theta}_{EMV}) = \text{Var}(\hat{\theta}_{EMV}) + [b(\hat{\theta}_{EMV})]^2 = \frac{\theta^2}{n}.$$

- Comme $\lim_{n \rightarrow \infty} EQM(\hat{\theta}_{EMV}) = 0$, $\hat{\theta}_{EMV}$ est consistant.

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- On observe les fréquences suivantes :

x	$f_X(x)$
$(0, 1]$	10
$(1, 2]$	15
$(2, 3]$	8
$(3, 4]$	5
$(4, 5]$	2

- L'EMV de θ est donné par :

$$\hat{\theta} = \frac{\sum x_i f_X(x_i)}{n}.$$

- En utilisant les données, nous obtenons une estimation numérique.

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- La fonction de répartition d'une loi exponentielle est :

$$F(x) = 1 - e^{-x/\theta}.$$

- Ainsi,

$$P(X \leq 2) = 1 - e^{-2/\hat{\theta}}.$$

- En utilisant l'estimation de $\hat{\theta}$, nous obtenons une valeur numérique.

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- On observe les fréquences suivantes :

x	$f_X(x)$
$(0, 1]$	10
$(1, 2]$	15
$(2, 3]$	8
$(3, 4]$	5
$(4, 5]$	2

- Nous avons une distribution exponentielle de paramètre θ , et notre objectif est d'estimer ce paramètre à partir des données.
- Rappelons que l'estimateur du maximum de vraisemblance (EMV) pour θ est donné par la moyenne empirique :

$$\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i.$$

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- Comme nous avons des données groupées par intervalles, nous utilisons les points centraux des intervalles pour approximer les valeurs de X_i . Ainsi, nous prenons :

$$X_1 = 0.5, \quad X_2 = 1.5, \quad X_3 = 2.5, \quad X_4 = 3.5, \quad X_5 = 4.5.$$

- En pondérant par les fréquences observées $f_X(x)$, l'EMV s'écrit :

$$\hat{\theta} = \frac{\sum x_i f_X(x_i)}{\sum f_X(x_i)}.$$

- En remplaçant par les valeurs observées :

$$\hat{\theta} = \frac{(0.5 \times 10) + (1.5 \times 15) + (2.5 \times 8) + (3.5 \times 5) + (4.5 \times 2)}{10 + 15 + 8 + 5 + 2}.$$

- En effectuant le calcul, nous obtenons une estimation numérique de $\hat{\theta} = \frac{74}{40} = 1.85$.

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- Nous souhaitons estimer $P(X \leq 2)$ en utilisant la fonction de répartition d'une loi exponentielle.
- La fonction de répartition cumulative d'une loi exponentielle de paramètre θ est définie par :

$$F(x) = P(X \leq x) = 1 - e^{-x/\theta}.$$

- Cette formule est obtenue en intégrant la densité de la loi exponentielle :

$$P(X \leq x) = \int_0^x \frac{1}{\theta} e^{-t/\theta} dt.$$

- Une primitive de la fonction $e^{-t/\theta}$ est $-\theta e^{-t/\theta}$, ce qui nous donne :

$$P(X \leq x) = \left[-e^{-t/\theta} \right]_0^x = 1 - e^{-x/\theta}.$$

Prob 2 : Estimation par MEV pour la Loi Exp (Solution)

- En appliquant cette formule pour $x = 2$, nous obtenons :

$$P(X \leq 2) = 1 - e^{-2/\hat{\theta}}.$$

- En remplaçant $\hat{\theta}$ par son estimation obtenue précédemment, nous pouvons calculer une estimation numérique de cette probabilité.



$$P(X \leq 2) = 1 - e^{-1.081} \approx 1 - 0.3395 = 0.6605.$$

- Ainsi, l'estimation de $P(X \leq 2)$ est 0.6605.

Table des Matières

- 1 Problème 1 : Gradients et Hessiennes
- 2 Problème 2 : Estimation par MEV pour la Loi Exp
- 3 Problème 3 : Estimation par MEV pour la Loi Bin**
- 4 Problème 4 : Test t en Régression Linéaire
- 5 Problème 5 : Visualisation des LGN & TCL

Estimation par la Méthode du Maximum de Vraisemblance et Propriétés des Estimateurs (Loi Binomiale)

Problème 3 : Estimation par MEV pour la Loi Binomiale

- Soit X_1, X_2, \dots, X_n un échantillon aléatoire issu d'une **loi binomiale** de paramètres m et p , c'est-à-dire :

$$P(X = x) = \binom{m}{k} p^x (1 - p)^{m-x}, \quad x = 0, 1, 2, \dots, m.$$

où :

- m est le nombre d'essais indépendants.
 - p est la probabilité de succès pour un essai donné.
 - X_i représente le nombre de succès observés pour un individu dans m essais.
- Nous allons déterminer l'estimateur du maximum de vraisemblance (EMV) de p , puis analyser ses propriétés.

Problème 3 : Estimation par MEV pour la Loi Bin

- On observe les fréquences suivantes pour une variable X suivant une

	x	$f_X(x)$
	0	8
loi Binomiale :	1	18
	2	12
	3	7
	4	5

- Trouver l'estimateur du maximum de vraisemblance (EMV) de \hat{p} en utilisant les données observées.
- Estimer la probabilité $P(X \leq 2)$.

Prob 3 : Estimation par MEV pour la Loi Bin (Solution)

- La fonction de vraisemblance est donnée par :

$$L(p) = \prod_{i=1}^n P(X_i; p) = \prod_{i=1}^n \binom{m}{X_i} p^{X_i} (1-p)^{m-X_i}.$$

- En prenant le logarithme :

$$\ell(p) = \sum_{i=1}^n \left[\ln \binom{m}{X_i} + X_i \ln p + (m - X_i) \ln(1-p) \right].$$

- En dérivant par rapport à p : $\frac{d\ell}{dp} = \sum_{i=1}^n \left[\frac{X_i}{p} - \frac{m-X_i}{1-p} \right]$.
- En posant cette dérivée égale à zéro : $\sum_{i=1}^n \left[\frac{X_i}{p} - \frac{m-X_i}{1-p} \right] = 0$.
- En résolvant pour p , on obtient :

$$\hat{p}_{EMV} = \frac{1}{nm} \sum_{i=1}^n X_i.$$

Prob 3 : Estimation par MEV pour la Loi Bin (Solution)

- Calculons l'espérance de \hat{p}_{EMV} :

$$\mathbb{E}[\hat{p}_{EMV}] = \mathbb{E}\left[\frac{1}{nm} \sum_{i=1}^n X_i\right] = \frac{1}{nm} \sum_{i=1}^n \mathbb{E}[X_i].$$

- Comme $X_i \sim \text{Bin}(m, p)$, on a $\mathbb{E}[X_i] = mp$, donc :

$$\mathbb{E}[\hat{p}_{EMV}] = \frac{1}{nm} \cdot nmp = p.$$

- L'estimateur \hat{p} est donc non biaisé.

Prob 3 : Estimation par MEV pour la Loi Bin (Solution)

- La variance de \hat{p}_{EMV} est donnée par :

$$\text{Var}(\hat{p}_{EMV}) = \text{Var}\left(\frac{1}{nm} \sum_{i=1}^n X_i\right).$$

- Comme $X_i \sim \text{Bin}(m, p)$, sa variance est :

$$\text{Var}(X_i) = mp(1 - p).$$

- Donc :

$$\text{Var}(\hat{p}_{EMV}) = \frac{1}{n^2 m^2} \sum_{i=1}^n mp(1 - p) = \frac{p(1 - p)}{nm}.$$

- L'erreur quadratique moyenne est :

$$EQM(\hat{p}_{EMV}) = \text{Var}(\hat{p}_{EMV}) + [b(\hat{p}_{EMV})]^2 = \frac{p(1 - p)}{nm}.$$

- Comme $\lim_{n \rightarrow \infty} EQM(\hat{p}_{EMV}) = 0$, \hat{p}_{EMV} est consistant.

Prob 3 : Estimation par MEV pour la Loi Bin (Solution)

- On observe les fréquences suivantes :

x	$f_X(x)$
0	8
1	18
2	12
3	7
4	5

- L'EMV de p est donné par :

$$\hat{p} = \frac{\sum x_i f_X(x_i)}{nm}$$

- En remplaçant par les valeurs observées :

$$\hat{p} = \frac{(0 \times 8) + (1 \times 18) + (2 \times 12) + (3 \times 7) + (4 \times 5)}{(8 + 18 + 12 + 7 + 5) \times 4}$$

- En effectuant le calcul, nous obtenons une estimation numérique de $\hat{p} = \frac{92}{200} = 0.46$.

Prob 3 : Estimation par MEV pour la Loi Bin (Solution)

- La fonction de répartition d'une loi binomiale est :

$$F(x) = P(X \leq x) = \sum_{k=0}^x \binom{m}{k} p^k (1-p)^{m-k}.$$

- Ainsi,

$$P(X \leq 2) = \sum_{k=0}^2 \binom{m}{k} \hat{p}^k (1-\hat{p})^{m-k}.$$

- En utilisant l'estimation de \hat{p} , nous obtenons une valeur numérique.

Prob 3 : Estimation par MEV pour la Loi Bin (Solution)

- Nous souhaitons estimer $P(X \leq 2)$, qui s'écrit :

$$P(X \leq 2) = P(X = 0) + P(X = 1) + P(X = 2).$$

- La fonction de masse de probabilité de la loi binomiale donne :

$$P(X = x) = \binom{m}{x} \hat{p}^x (1 - \hat{p})^{m-x}.$$

- Calculons chaque terme avec $\hat{p} = 0.46$ et $m = 4$:

$$P(X = 0) = \binom{4}{0} (0.46)^0 (1 - 0.46)^4 = (0.54)^4 = 0.0859.$$

$$P(X = 1) = \binom{4}{1} (0.46)^1 (1 - 0.46)^3 = 4 \times (0.46) \times (0.54)^3 = 0.2919.$$

$$P(X = 2) = \binom{4}{2} (0.46)^2 (1 - 0.46)^2 = 6 \times (0.46)^2 \times (0.54)^2 = 0.3504.$$

- En sommant ces probabilités :

$$P(X \leq 2) = 0.0859 + 0.2919 + 0.3504 = 0.7282.$$

Table des Matières

- 1 Problème 1 : Gradients et Hessiennes
- 2 Problème 2 : Estimation par MEV pour la Loi Exp
- 3 Problème 3 : Estimation par MEV pour la Loi Bin
- 4 Problème 4 : Test t en Régression Linéaire
- 5 Problème 5 : Visualisation des LGN & TCL

Problème 1 : Gradients et Hessiennes

Problème 2 : Estimation par MEV pour la Loi Exp

Problème 3 : Estimation par MEV pour la Loi Bin

Problème 4 : Test t en Régression Linéaire

Problème 5 : Visualisation des LGN & TCL

Test t en Régression Linéaire

Problème 4 : Test t en Régression Linéaire

- Une université souhaite étudier l'impact du nombre d'heures de révision (X) sur les notes obtenues à un examen (Y).
- On modélise cette relation par une régression linéaire simple :

$$Y = \beta_0 + \beta_1 X + \varepsilon, \quad \varepsilon \sim \mathcal{N}(0, \sigma^2).$$

- L'objectif est de tester si X a un effet sur Y ou non. On considère alors l'hypothèse suivante :

$$H_0 : \beta_1 = 0 \quad \text{contre} \quad H_1 : \beta_1 \neq 0.$$

- Cela permet de vérifier si le nombre d'heures de révision a un effet significatif sur la note finale.

Problème 4 : Test t en Régression Linéaire (Solution)

- L'estimateur des moindres carrés pour β_1 est donné par :

$$\hat{\beta}_1 = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sum(X_i - \bar{X})^2}.$$

- Son écart-type est estimé par :

$$s_{\hat{\beta}_1} = \frac{s}{\sqrt{\sum(X_i - \bar{X})^2}}, \quad \text{où} \quad s^2 = \frac{1}{n-2} \sum(Y_i - \hat{Y}_i)^2.$$

- La statistique de test suit une loi de Student à $n - 2$ degrés de liberté :

$$t = \frac{\hat{\beta}_1}{s_{\hat{\beta}_1}}.$$

- Si $|t| > t_{\alpha/2, n-2}$, on rejette H_0 .

Problème 4 : Test t en Régression Linéaire (Solution)

- On collecte les données suivantes :

X (Heures de révision)	Y (Note à l'examen)
2	50
3	55
5	65
7	70
8	75
10	85

- On utilise Python pour estimer β_1 et effectuer le test t .

Problème 4 : Test t en Régression Linéaire (Solution)


```
import numpy as np
import scipy.stats as stats
import statsmodels.api as sm
X = np.array([2, 3, 5, 7, 8, 10]) # Données
Y = np.array([50, 55, 65, 70, 75, 85]) # Données
X = sm.add_constant(X) # Ajout d'une colonne de 1 pour l'ordonnée à l'origine
model = sm.OLS(Y, X).fit() # Régression linéaire
print(model.summary()) # Affichage des résultats
beta1_hat = model.params[1] # Extraction de beta1_hat
se_beta1 = model.bse[1] # Extraction de se_beta1 pour le test t
t_stat = model.tvalues[1] # Extraction de t_stat pour le test t
p_value = model.pvalues[1] # Extraction de la p_value pour le test t
alpha = 0.05 # Fizer le niveau de signification à 0.05
t_crit = stats.t.ppf(1 - alpha/2, df=len(Y) - 2) # calcul de la statistique critique
print(f"Estimateur de beta1 : {beta1_hat:.4f}")
print(f"Écart-type : {se_beta1:.4f}")
print(f"Statistique t : {t_stat:.4f}")
print(f"p-value : {p_value:.4f}")
print(f"Valeur critique pour alpha={alpha}: {t_crit:.4f}")
if abs(t_stat) > t_crit:
    print("Rejet de H0 : beta1 est significatif")
else:
    print("On ne rejette pas H0 : beta1 n'est pas significatif")
```

Estimateur de beta1 : 4.1993; Écart-type : 0.1997

Statistique t : 21.0246; p-value : 0.0000

Valeur critique pour alpha=0.05: 2.7764; Rejet de H0 : beta1 est significatif

Problème 4 : Test t en Régression Linéaire (Solution)



Problème 4 : Test t en Régression Linéaire (Solution)

- Si la p -value est inférieure à $\alpha = 0.05$, on rejette H_0 , ce qui signifie que X a un effet significatif sur Y .
- Si la p -value est plus grande, alors on ne peut pas conclure que X influence Y .
- La valeur de $\hat{\beta}_1$ nous donne une estimation de l'effet d'une heure de révision supplémentaire sur la note obtenue.

Problème 4 : Test t en Régression Linéaire (Solution)

- Le test t en régression linéaire permet de tester si une variable explicative a un effet significatif sur la variable dépendante.
- Il repose sur l'estimation du coefficient β_1 et son écart-type.
- Si $|t|$ est supérieur à la valeur critique de Student, on rejette H_0 et on conclut que la variable X a un impact significatif.

Table des Matières

- 1 Problème 1 : Gradients et Hessiennes
- 2 Problème 2 : Estimation par MEV pour la Loi Exp
- 3 Problème 3 : Estimation par MEV pour la Loi Bin
- 4 Problème 4 : Test t en Régression Linéaire
- 5 Problème 5 : Visualisation des LGN & TCL

Problème 5 : Visualisation des Lois des Grands Nombres et du Théorème Central Limite

Problème 5 - Visualisation des LGN & TCL : Objectifs

- Explorer les trois théorèmes fondamentaux des probabilités :
 - 1 La **loi faible des grands nombres** : comment la moyenne empirique fluctue autour de l'espérance.
 - 2 La **loi forte des grands nombres** : convergence des trajectoires individuelles.
 - 3 Le **théorème central limite** : distribution asymptotique des moyennes.
- Manipuler un jeu de données simulé et ajuster les paramètres pour comprendre leur impact.
- Expliquer ce que vous observez à partir des graphiques générés.

Problème 5 - Visualisation des LGN & TCL

● Rappel: Différence entre la Loi Faible et la Loi Forte des Grands Nombres

- La Loi Faible des Grands Nombres concerne une forte probabilité : \bar{X}_n sera proche de μ pour une grande taille d'échantillon, mais pas nécessairement pour toutes les séquences d'observations.

- **Formulation mathématique :**

$$P(|\bar{X}_n - \mu| \geq \epsilon) \rightarrow 0 \quad \text{quand } n \rightarrow \infty, \quad \forall \epsilon > 0.$$

- **Exemple :** Si nous lançons une pièce et calculons la proportion de 'face', la probabilité que cette proportion s'écarte significativement de 0.5 devient très faible lorsque le nombre de lancers augmente.
- La Loi Forte des Grands Nombres concerne une convergence presque sûre : elle garantit que \bar{X}_n converge vers μ pour (presque) toutes les séquences possibles des variables aléatoires.

- **Formulation mathématique :**

$$P\left(\lim_{n \rightarrow \infty} \bar{X}_n = \mu\right) = 1.$$

- **Exemple :** Si nous lançons une pièce et calculons la proportion de 'face', cette proportion atteindra finalement 0.5 et y restera avec probabilité 1.

Problème 5 - Visualisation des LGN & TCL

- **Idée Principale du Théorème Central Limite (TCL) :** Peu importe la distribution initiale des X_i , la moyenne ou la somme des X_i suit une distribution normale lorsque n est suffisamment grand.
- **Formule pour la Moyenne :**

$$\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \xrightarrow{d} \mathcal{N}(0, 1) \quad \text{quand } n \rightarrow \infty.$$

- **Exemple Simple :** Si nous lançons un dé n fois et calculons la moyenne des résultats obtenus, la distribution de cette moyenne deviendra progressivement normale à mesure que n augmente, même si les résultats individuels du dé suivent une distribution uniforme.

Problème 5 : Visualisation des LGN & TCL

- Nous allons considérer une distribution uniforme $U(0, 1)$.
- Cela permet de voir comment la convergence des moyennes s'applique à un cas plus général.
- Vous devrez exécuter du code et analyser les figures obtenues.

Problème 5 : Loi Faible des Grands Nombres

- On génère n réalisations d'une variable aléatoire uniforme $U(0, 1)$.
- L'estimateur qui est considéré est la moyenne empirique \bar{X} . Elle est calculée pour chaque taille d'échantillon n .
- **Expérience** : Modifiez n dans le code ci-dessous et observez son effet sur la dispersion de la moyenne.

Problème 5 : Loi Faible des Grands Nombres

```
import numpy as np
import matplotlib.pyplot as plt

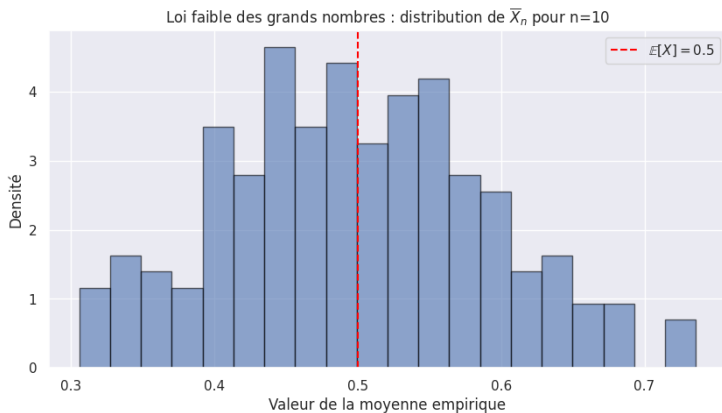
np.random.seed(42)

n_values = [10, 100, 1000, 5000] # Différentes tailles d'échantillon
num_trials = 200 # Nombre de répétitions

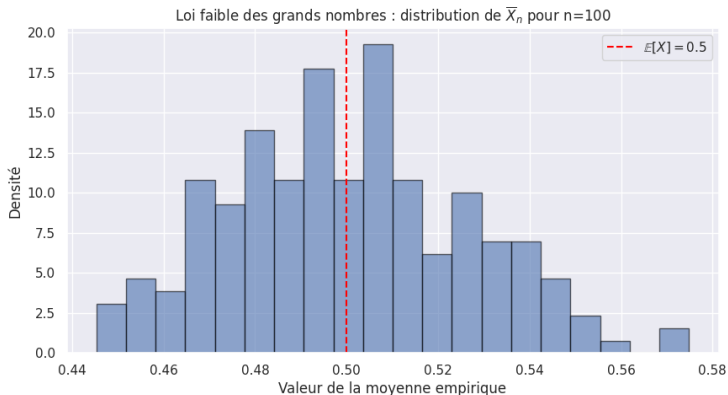
for n in n_values:
    X = np.random.uniform(0, 1, (num_trials, n)) # Variables uniformes
    means = np.mean(X, axis=1) # Moyennes empiriques

    plt.figure(figsize=(10, 5))
    plt.hist(means, bins=20, density=True, alpha=0.6, color='b', edgecolor='black')
    plt.axvline(0.5, color='red', linestyle='dashed', label=r'$\mathbb{E}[X] = 0.5$')
    plt.title(f"Loi faible des grands nombres : distribution de $\overline{\{X\}}_n$
              f"pour n={n}")
    plt.xlabel("Valeur de la moyenne empirique")
    plt.ylabel("Densité")
    plt.legend()
    plt.show()
```


Problème 5 : Lois Faible des Grands nombre (Solution)




Problème 5 : Lois Faible des Grands nombre (Solution)



Problème 5 : Lois Faible des Grands nombre (Solution)



Problème 5 : Lois Faible des Grands nombre (Solution)



- On observe que la dispersion diminue avec l'augmentation de la taille de l'échantillon où la distribution des moyennes empiriques se concentre de plus en plus autour de $\mathbb{E}[X]$

Problème 5 : Lois Forte des Grands nombre Nombres

- Nous allons tracer les trajectoires individuelles de la moyenne empirique.
- **Expérience** : Faites varier le nombre de trajectoires num_{trials} pour voir si toutes convergent.
- Que remarquez-vous ?

Loi Forte des Grands Nombres

```

n = 10000 # Taille de l'échantillon
num_trials = [1, 5, 50] # Nombre de trajectoires à afficher # Nombre de trajectoires


X = np.random.uniform(0, 1, (num_trials, n)) # Variables uniformes
means = np.cumsum(X, axis=1) / np.arange(1, n + 1) # Moyennes cumulatives

plt.figure(figsize=(10, 5))
for i in range(num_trials):
    plt.plot(means[i, :], alpha=0.7, label=f'Trajectoire {i+1}')

plt.axhline(0.5, color='red', linestyle='dashed', label=r'$\mathbb{E}[X] = 0.5$')
plt.title("Loi forte des grands nombres : trajectoires de $\overline{\{X\}}_n$")
plt.xlabel("Nombre d'échantillons $n$")
plt.ylabel("Moyenne empirique $\overline{X}_n$")
plt.legend()
plt.show()

```

Problème 5 : Lois Forte des Grands nombre (Solution)



- Que ce soit pour une expérience à 1 seul essai, ou pour des expériences à plusieurs essais (5 et 50 essais dans le graphe), \bar{X} converge vers 1 pour une taille d'échantillon n élevée.

Problème 5 : Théorème Central Limite

- On observe la distribution des moyennes empiriques pour différentes tailles d'échantillon.
- **Expérience** : Changez n (5, 10, 25, 50, 500) et analysez la forme de l'histogramme.
- De quelle distribution \bar{X} s'approche lorsqu'on augmente n ?

Problème 5 : Théorème Central Limite

```
import scipy.stats as stats
```

```
num_trials = 100
```

```
n_values = [5, 10, 25, 50, 500]
```

```
for n in n_values:
```

```
    X_tcl = np.random.uniform(0, 1, (num_trials, n))
```

```
    sample_means = np.mean(X_tcl, axis=1)
```

```
    plt.figure(figsize=(10, 5))
```

```
    plt.hist(sample_means, bins=20, density=True, alpha=0.6, color='g', edgecolor='black',
```

```
            # Superposition d'une loi normale
```

```
            mu, sigma = 0.5, np.sqrt(1/12 / n)
```

```
            x_vals = np.linspace(0.3, 0.7, 100)
```

```
            plt.plot(x_vals, stats.norm.pdf(x_vals, mu, sigma), color="red", lw=2, label="Densité")
```

```
            plt.axvline(0.5, color='black', linestyle='dashed', label=r'$\mathbb{E}[X] = 0.5$')
```

```
            plt.title(f"Théorème Central Limite : Distribution pour $n={n}$")
```


```
            plt.xlabel("Valeur de la moyenne empirique")
```

```
            plt.ylabel("Densité")
```


```
            plt.legend()
```

```
            plt.show()
```

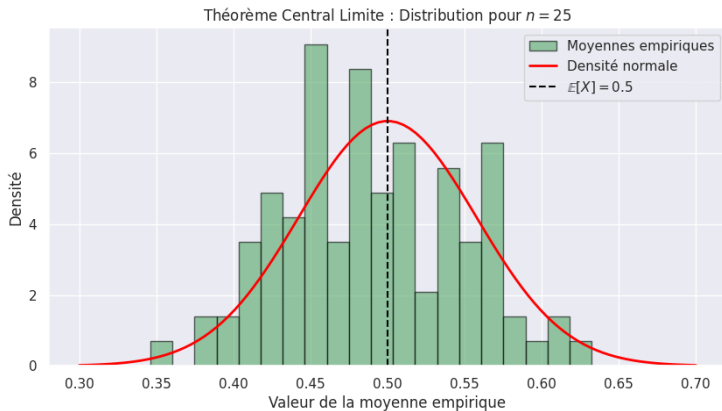
Problème 5 : Théorème Central Limite (Solution)



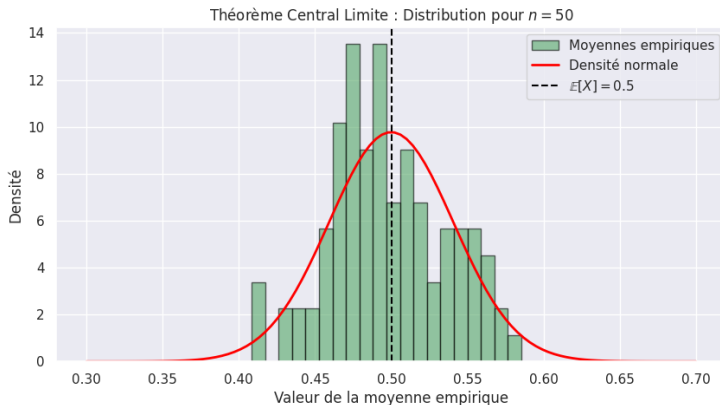
Problème 5 : Théorème Central Limite (Solution)




Problème 5 : Théorème Central Limite (Solution)



Problème 5 : Théorème Central Limite (Solution)



Problème 5 : Théorème Central Limite (Solution)



- La distribution de \bar{X} se rapproche de plus en plus d'une distribution normale.

Problème 5 : LGN & TCL

- **Loi faible des grands nombres** : Plus n est grand, plus la moyenne empirique se concentre autour de $\mathbb{E}[X]$.
- **Loi forte des grands nombres** : Chaque trajectoire individuelle converge vers $\mathbb{E}[X]$.
- **Théorème central limite** : Lorsque n augmente, la distribution des moyennes suit une loi normale.