

## TP4

### 1 Monte Carlo : un exemple continu 1D

On considère la densité de probabilité sur  $\mathbb{R}$  donnée par

$$f(x) \propto (1 + \sin(3x)) e^{-x^2/2}$$

à une constante de normalisation près.

1. Quelle est la valeur de la constante de normalisation ? Faire un graphe de  $f$ .
2. Simuler plusieurs réalisations de densité  $f$  à l'aide de la méthode des rejets et les présenter sous forme d'histogramme, sur lequel on rajoutera le graphe de  $f$ .
3. Simuler plusieurs réalisations de densité  $f$  à l'aide de l'algorithme de Metropolis-Hastings et faire de même que dans la question précédente.
4. Calculer la valeur théorique de  $\int x^2 f(x) dx$ , puis donner une valeur approchée à l'aide des méthodes de Monte Carlo (rejet et MH) et les comparer.

### 2 Régression logistique (approche bayésienne)

On considère le modèle de régression logistique  $\mathbb{P}(Y = 1|X) = \sigma(X, \beta)$  avec  $X \in \mathbb{R}^d$  et où on a choisi la sigmoïde "logit"

$$\sigma(X, \beta) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X^{(1)} + \dots + \beta_d X^{(d)})}}.$$

On rappelle que si les paramètres  $\beta = (\beta_0, \dots, \beta_d)$  ont pour loi *a priori*  $\mathcal{N}(0, I_{d+1})$ , la densité *a posteriori* de  $\beta$  sachant  $X = [X_1, \dots, X_N] \in (\mathbb{R}^d)^N$  et  $Y \in \{0, 1\}^N$  est donnée à une constante multiplicative près par

$$p(\beta|X, Y) \propto \prod_{i=1}^N \sigma(X_i, \beta)^{y_i} (1 - \sigma(X_i, \beta))^{1-y_i} e^{-\|\beta\|^2/2}.$$

1. Construire un jeu de données factice : simuler  $N$  vecteurs  $X_1, \dots, X_N$  de  $\mathbb{R}^d$  et  $Y = (y_1, \dots, y_d) \in \{0, 1\}^d$  de la façon de votre choix.
2. Simuler à l'aide de Metropolis-Hastings une variable de densité  $p(\beta|X, Y)$  ; on fera attention au nombre de pas acceptés dans l'algorithme, qu'on essaiera de maintenir aux environs de 25% en ajustant la variance de la loi des variables proposées.
3. Donner une approximation de l'estimateur

$$\hat{\theta} = \int \theta p(\beta|X, Y) d\theta.$$

En déduire une prédiction du taux de succès de  $Y^*$  pour les données d'un nouvel individu  $X^* \in \mathbb{R}^d$ .