

# Corrigé de l'examen du cours de M2 : Méthodes numériques probabilistes

16 janvier 2015, 13h30 - 16h30.

*Les notes de cours sont autorisées.*

## Exercice 1 : Stratification

1 Il suffit de considérer  $\hat{I}^{\text{MC}} = \frac{1}{n} \sum_{k=1}^n f(X_k)$  pour des  $X_k$  i.i.d. de même loi que  $X$ . On sait que  $\hat{I}^{\text{MC}}$  converge presque sûrement vers  $I$  (loi forte des grands nombres) et par le théorème central limite, on peut construire un intervalle de confiance de longueur  $\alpha \sqrt{\frac{\text{Var}(X)}{n}}$ , ce qui donne une expression de l'erreur.

2.1 On a

$$\begin{aligned}\text{Var}(f(X)) &= \mathbb{E}(f^2(X)) - (\mathbb{E}(f(X)))^2 \\ &= \sum_{i=1}^m \mathbb{P}(X \in A_i) \mathbb{E}(f^2(X) | X \in A_i) - \left( \sum_{i=1}^m \mathbb{P}(X \in A_i) \mathbb{E}(f(X) | X \in A_i) \right)^2 \\ &= \sum_{i=1}^m p_i (\sigma_i^2 + \mu_i^2) - \left( \sum_{i=1}^m p_i \mu_i \right)^2.\end{aligned}$$

En utilisant le fait que  $\sum_{i=1}^m p_i = 1$ , on a donc :

$$\text{Var}(f(X)) = \sum_{i=1}^m p_i \sigma_i^2 + \sum_{i=1}^m p_i \left( \mu_i - \sum_{j=1}^m p_j \mu_j \right)^2.$$

Le premier terme représente la somme des variances sur chacune des strates. Le second terme peut aussi être interprété comme une variance pour une variable aléatoire discrète qui prend la valeur  $\mu_i$  avec probabilité  $p_i$  ( $i \in \{1, \dots, m\}$ ).

2.2 Pour tout  $i$ , on a  $\mathbb{E}(\hat{I}_i) = \mathbb{E}(f(X_1^i)) = \mathbb{E}(f(X) | X \in A_i) = \mu_i$  et donc

$$\begin{aligned}\mathbb{E}(\hat{I}) &= \sum_{i=1}^m p_i \mathbb{E}(\hat{I}_i) \\ &= \sum_{i=1}^m \mathbb{P}(X \in A_i) \mathbb{E}(f(X) | X \in A_i) \\ &= \mathbb{E}(f(X)).\end{aligned}$$

De plus, pour tout  $i$ , dans la limite  $n_i \rightarrow \infty$ ,  $\hat{I}_i$  converge presque sûrement vers  $\mu_i$  par la loi forte des grands nombres. Par conséquent, dans la limite  $\min_{1 \leq i \leq m} n_i \rightarrow \infty$ ,  $\hat{I}$  converge presque sûrement vers  $\sum_{i=1}^m p_i \mu_i = I$ .

**2.3** Par indépendance des variables aléatoires  $(X_k^i)_{i \in \{1, \dots, m\}, k \geq 1}$ , on a

$$\begin{aligned} \text{Var}(\hat{I}) &= \sum_{i=1}^m p_i^2 \text{Var}(\hat{I}_i) \\ &= \sum_{i=1}^m p_i^2 \frac{\sigma_i^2}{n_i}. \end{aligned}$$

**3.1** Par Cauchy-Schwarz, on a

$$\begin{aligned} \left( \sum_{i=1}^m p_i \sigma_i \right)^2 &= \left( \sum_{i=1}^m \frac{p_i \sigma_i}{\sqrt{n_i}} \sqrt{n_i} \right)^2 \\ &\leq \left( \sum_{i=1}^m \frac{p_i^2 \sigma_i^2}{n_i} \right) \left( \sum_{i=1}^m n_i \right) \\ &= n \sum_{i=1}^m \frac{p_i^2 \sigma_i^2}{n_i}. \end{aligned}$$

Par conséquent,

$$\text{Var}(\hat{I}) \geq \frac{1}{n} \left( \sum_{i=1}^m p_i \sigma_i \right)^2$$

et on a égalité si et seulement si  $n_i = n_i^* = n \frac{p_i \sigma_i}{\sum_{j=1}^m p_j \sigma_j}$  (cas d'égalité de Cauchy Schwarz). En pratique, l'allocation optimale nécessite de connaître les variance  $\sigma_i^2$ , ce qui n'est pas très réaliste.

*Remarque : En pratique,  $n_i^* = n \frac{p_i \sigma_i}{\sum_{j=1}^m p_j \sigma_j}$  n'est pas un entier. Il faut donc plutôt considérer des entiers  $\tilde{n}_i$  proches de  $n_i^*$ . Dans ce cas, on a*

$$\text{Var}(\hat{I}) = \frac{1}{n} \left( \sum_{i=1}^m p_i \sigma_i \right)^2 + \sum_{i=1}^m p_i^2 \sigma_i^2 \left( \frac{1}{\tilde{n}_i} - \frac{1}{n_i^*} \right)$$

et dans la limite  $n \rightarrow \infty$ , le second terme est négligeable par rapport au premier (typiquement d'ordre  $1/n^2$ ).

**3.2** Comme  $n_i = np_i$ , on a

$$\begin{aligned} \text{Var}(\hat{I}) &= \sum_{i=1}^m \frac{p_i^2 \sigma_i^2}{n_i} \\ &= \frac{1}{n} \sum_{i=1}^m p_i \sigma_i^2. \end{aligned}$$

En comparant avec le résultat de la question 2.3, on a donc  $n \text{Var}(\hat{I}) \leq \text{Var}(f(X))$ . Cela implique que l'allocation proportionnelle donne un estimateur de variance plus petite que l'estimateur de Monte Carlo standard  $\hat{I}^{\text{MC}}$  introduit à la question 1, puisque  $\text{Var} \hat{I}^{\text{MC}} = \text{Var}(f(X))/n$ .

Pour énoncer un théorème central limite, on considère (en utilisant le fait que  $I = \sum_{i=1}^m p_i \mathbb{E}(fX_1^i)$ ) :

$$\begin{aligned}\sqrt{n}(\hat{I} - I) &= \sum_{i=1}^m p_i \sqrt{n} \left( \frac{1}{np_i} \sum_{k=1}^{np_i} f(X_k^i) - \mathbb{E}(fX_1^i) \right) \\ &= \sum_{i=1}^m \sqrt{p_i} \sqrt{np_i} \left( \frac{1}{np_i} \sum_{k=1}^{np_i} f(X_k^i) - \mathbb{E}(fX_1^i) \right).\end{aligned}$$

Pour tout  $i \in \{1, \dots, m\}$ ,  $\sqrt{np_i} \left( \frac{1}{np_i} \sum_{k=1}^{np_i} f(X_k^i) - \mathbb{E}(fX_1^i) \right)$  converge en loi vers une variable aléatoire gaussienne  $G_i$  centrée et de variance  $\sigma_i^2$ . De plus, par l'indépendance des échantillons  $(X_k^i)_{i \in \{1, \dots, m\}, k \geq 1}$ , on en déduit que le vecteur

$$\left( \sqrt{np_1} \left( \frac{1}{np_1} \sum_{k=1}^{np_1} f(X_k^1) - \mathbb{E}(fX_1^1) \right), \dots, \sqrt{np_m} \left( \frac{1}{np_m} \sum_{k=1}^{np_m} f(X_k^m) - \mathbb{E}(fX_1^m) \right) \right)$$

converge en loi vers le vecteur gaussien  $(G_1, \dots, G_m)$  avec les  $(G_i)_{i \in \{1, \dots, m\}}$  indépendants. Par conséquent,

$$\lim_{n \rightarrow \infty} \sqrt{n}(\hat{I} - I) = \sum_{i=1}^m \sqrt{p_i} G_i \text{ en loi,}$$

et  $\sum_{i=1}^m \sqrt{p_i} G_i$  est une gaussienne centrée et de variance  $\sum_{i=1}^m p_i \sigma_i^2$ .

Pour diminuer l'erreur statistique, il faut diminuer la variance  $\sum_{i=1}^m p_i \sigma_i^2$  : il faut donc choisir les strates de manière à ce que les variances  $\sigma_i^2$  soient les plus petites possibles (la variance de  $f(X)$  conditionnellement à  $X \in A_i$  est petite).

## Exercice 2 : Variable de contrôle

1 Par la loi forte des grands nombres,  $\hat{I}$  converge presque sûrement et dans  $L^1$  vers  $\mathbb{E}(X - \alpha Y) = \mathbb{E}(X) = I$ . De plus, par le théorème central limite,  $\sqrt{n}(\hat{I} - I)$  converge en loi vers une gaussienne centrée et de variance  $\text{Var}(X - \alpha Y)$ .

On calcule facilement  $\mathbb{E}(\hat{I}) = 0$  et

$$\begin{aligned}\text{Var}(\hat{I}) &= \frac{1}{n} \text{Var}(X - \alpha Y) \\ &= \frac{1}{n} (\text{Var}(X) - 2\alpha \text{Cov}(X, Y) + \alpha^2 \text{Var}(Y)).\end{aligned}$$

En particulier, la variance est un trinôme en  $\alpha$ , qui est minimum en  $\alpha = \alpha^* = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)}$  auquel cas la variance vaut  $\text{Var}(\hat{I}) = \frac{1}{n} \text{Var}(X) \left( 1 - \frac{\text{Cov}(X, Y)^2}{\text{Var}(X)\text{Var}(Y)} \right)$ .

On a donc  $\text{Var}(\hat{I}) = 0$  si et seulement si  $\text{Cov}(X, Y)^2 = \text{Var}(X)\text{Var}(Y)$  ce qui correspond au cas d'égalité dans l'inégalité de Cauchy Schwarz :

$$\text{Cov}(X, Y)^2 \leq \text{Var}(X)\text{Var}(Y).$$

L'égalité est réalisée si et seulement si  $X - \mathbb{E}(X)$  est égal, à une constante multiplicative près à  $Y - \mathbb{E}(Y) = Y$ , autrement dit si il existe une constante  $\lambda$  tel que

$$Y = \lambda(X - \mathbb{E}(X)).$$

Dans ce cas,  $\alpha^* = \frac{1}{\lambda}$  et  $X - \alpha^*Y = \mathbb{E}(X)$  est une quantité déterministe, qui est donc bien de variance nulle. Evidemment, pour utiliser en pratique la variable de contrôle idéale  $Y = \lambda(X - \mathbb{E}(X))$ , il faut connaître  $\mathbb{E}(X)$  que l'on cherche justement à évaluer...

**2** Dans la limite  $n \rightarrow \infty$ , par la loi forte des grands nombres,  $\alpha_n$  converge presque sûrement vers  $\alpha^*$ . Par conséquent, dans la limite  $n \rightarrow \infty$ ,  $\tilde{I}$  converge vers  $\mathbb{E}(X) = I$ . De plus, par le théorème de Slutsky, le vecteur

$$\left( \frac{1}{\sqrt{n}} \left( \sum_{k=1}^n X_k - \mathbb{E}(X) \right), \frac{1}{\sqrt{n}} \sum_{k=1}^n Y_k, \alpha_n \right)$$

converge en loi, quand  $n \rightarrow \infty$ , vers  $(G_1, G_2, \alpha^*)$  avec  $(G_1, G_2)$  un vecteur gaussien centré tel que  $\text{Var}(G_1) = \text{Var}(X)$ ,  $\text{Var}(G_2) = \text{Var}(Y)$  et  $\text{Cov}(G_1, G_2) = \text{Cov}(X, Y)$ . Ceci implique que  $\sqrt{n}(\tilde{I} - I) = \frac{1}{\sqrt{n}} (\sum_{k=1}^n X_k - \mathbb{E}(X)) - \alpha_n \frac{1}{\sqrt{n}} \sum_{k=1}^n Y_k$  converge en loi vers  $G_1 - \alpha^*G_2$ . La variable aléatoire  $G_1 - \alpha^*G_2$  est une gaussienne centrée telle que

$$\begin{aligned} \text{Var}(G_1 - \alpha^*G_2) &= \text{Var}(G_1) - 2\alpha^*\text{Cov}(G_1, G_2) + (\alpha^*)^2\text{Var}(G_2) \\ &= \text{Var}(X) - 2\alpha^*\text{Cov}(X, Y) + (\alpha^*)^2\text{Var}(Y) \\ &= \text{Var}(X) \left( 1 - \frac{\text{Cov}(X, Y)^2}{\text{Var}(X)\text{Var}(Y)} \right) \end{aligned}$$

qui est la variance optimale.

**3.1** Par hypothèse,  $\mathbb{E} \int_0^T |\partial_z u(s, Z_s) \sigma(s, Z_s)|^2 ds < \infty$  et donc  $\mathbb{E}(Y) = 0$ . Par un calcul d'Itô, on a

$$\begin{aligned} d(u(t, Z_t)) &= \left( \partial_t u + b \partial_z u + \frac{\sigma^2}{2} \partial_{z,z} u \right) (t, Z_t) dt + (\partial_z u \sigma)(t, Z_t) dW_t \\ &= (\partial_z u \sigma)(t, Z_t) dW_t \end{aligned}$$

et donc, par intégration en temps :

$$\begin{aligned} Y &= \int_0^T (\partial_z u \sigma)(t, Z_t) dW_t \\ &= u(T, Z_T) - u(0, z_0) \\ &= \varphi(Z_T) - u(0, z_0) \\ &= X - u(0, z_0). \end{aligned}$$

Par conséquent,  $X - Y = u(0, z_0)$  est déterministe, et donc de variance nulle. Ceci implique, d'après la question 1, que  $Y$  est une variable de contrôle idéale pour  $X$ .

En pratique, si on sait calculer  $Y$ , c'est que l'on connaît  $u$  la solution de l'EDP, et en particulier  $\mathbb{E}(X)$  puisque  $u(0, z_0) = \mathbb{E}(X)$ . Ceci dit, on peut imaginer calculer une solution approchée de l'EDP pour construire une variable de contrôle.

**3.2** Supposons qu'il existe une fonction  $v$  solution de l'EDP

$$\begin{cases} \partial_t v + b \partial_z v + \frac{\sigma^2}{2} \partial_{z,z} v + \psi v = 0, \\ v(T, z) = \varphi(z). \end{cases}$$

telle que  $\partial_z v$  est bornée sur  $[0, T] \times \mathbb{R}$ . Par le même raisonnement que ci-dessus (calcul d'Itô sur  $d\left(\exp\left(\int_0^t \psi(Z_s) ds\right)v(t, Z_t)\right)$ ), on vérifie que

$$\exp\left(\int_0^T \psi(Z_s) ds\right) \varphi(Z_T) - v(0, z_0) = \int_0^T \exp\left(\int_0^t \psi(Z_s) ds\right) (\partial_z u \sigma)(t, Z_t) dW_t$$

et donc

$$Y = \int_0^T \exp\left(\int_0^t \psi(Z_s) ds\right) (\partial_z u \sigma)(t, Z_t) dW_t$$

est une variable de contrôle idéale pour  $X$ .

### Exercice 3 : Transformation de Girsanov

1 On a  $X_{t_1} = -h(t_1) + W_{t_1}$ ,  $X_{t_2} - X_{t_1} = -h(t_2) + h(t_1) + W_{t_2} - W_{t_1}$ , ...,  $X_{t_n} - X_{t_{n-1}} = -h(t_n) + h(t_{n-1}) + W_{t_n} - W_{t_{n-1}}$ . Par conséquent, puisque les variables aléatoires  $W_{t_1}, W_{t_2} - W_{t_1}, \dots, W_{t_n} - W_{t_{n-1}}$  sont des gaussiennes indépendantes centrées et de variances respectives  $t_1, t_2 - t_1, \dots, t_n - t_{n-1}$ , on obtient que  $X_{t_1}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}}$  sont des gaussiennes indépendantes de moyennes respectives  $h(t_1), h(t_2) - h(t_1), \dots, h(t_n) - h(t_{n-1})$  et de variances respectives  $t_1, t_2 - t_1, \dots, t_n - t_{n-1}$ . Par conséquent, pour tout fonction test  $\varphi : \mathbb{R}^n \rightarrow \mathbb{R}$ ,

$$\mathbb{E}(\varphi(X_{t_1}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}})) = \int \varphi(y_1, \dots, y_n) q(y_1, \dots, y_n) dy_1 \dots dy_n$$

avec

$$q(y_1, \dots, y_n) = \left( \prod_{i=0}^{n-1} \frac{1}{\sqrt{2\pi(t_{i+1} - t_i)}} \right) \exp\left(-\sum_{i=0}^{n-1} \frac{(y_i + h(t_{i+1}) - h(t_i))^2}{2(t_{i+1} - t_i)}\right).$$

On considère alors le changement de variables

$$\Psi : \begin{cases} \mathbb{R}^n \rightarrow \mathbb{R}^n \\ (y_1, \dots, y_n) \mapsto (y_1, y_1 + y_2, \dots, y_1 + y_2 + \dots + y_n) \end{cases}$$

qui est un  $\mathcal{C}^1$  difféomorphisme de jacobien 1. Remarquer que  $\Psi(x_1, x_2 - x_1, \dots, x_n - x_{n-1}) = (x_1, \dots, x_n)$  et donc  $\Psi^{-1}(x_1, \dots, x_n) = (x_1, x_2 - x_1, \dots, x_n - x_{n-1})$ . Par conséquent, en utilisant le changement de variable  $(x_1, \dots, x_n) = \Psi(y_1, \dots, y_n)$ , pour une fonction test  $\tilde{\varphi} : \mathbb{R}^n \rightarrow \mathbb{R}$ ,

$$\begin{aligned} \mathbb{E}(\tilde{\varphi}(X_{t_1}, X_{t_2}, \dots, X_{t_n})) &= \mathbb{E}(\tilde{\varphi} \circ \Psi(X_{t_1}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}})) \\ &= \int \tilde{\varphi} \circ \Psi(y_1, \dots, y_n) q(y_1, \dots, y_n) dy_1 \dots dy_n \\ &= \int \tilde{\varphi}(x_1, \dots, x_n) q \circ \Psi^{-1}(x_1, \dots, x_n) \text{Jac}(\Psi^{-1})(x_1, \dots, x_n) dx_1 \dots dx_n \\ &= \int \tilde{\varphi}(x_1, \dots, x_n) q(x_1, x_2 - x_1, \dots, x_n - x_{n-1}) dx_1 \dots dx_n \end{aligned}$$

ce qui montre que  $(X_{t_1}, X_{t_2}, \dots, X_{t_n})$  a pour loi  $q(x_1, x_2 - x_1, \dots, x_n - x_{n-1}) dx_1 \dots dx_n$ .

**2** On a, en développant le carré dans l'exponentielle :

$$\begin{aligned}
& \mathbb{E}(\varphi(X_{t_1}, X_{t_2}, \dots, X_{t_n})) \\
&= \int \varphi(x_1, \dots, x_n) \left( \prod_{i=0}^{n-1} \frac{1}{\sqrt{2\pi(t_{i+1} - t_i)}} \right) \exp \left( - \sum_{i=0}^{n-1} \frac{(x_{i+1} - x_i + h(t_{i+1}) - h(t_i))^2}{2(t_{i+1} - t_i)} \right) dx_1 \dots dx_n \\
&= \int \varphi(x_1, \dots, x_n) \exp \left( - \sum_{i=0}^{n-1} \frac{(x_{i+1} - x_i)(h(t_{i+1}) - h(t_i))}{(t_{i+1} - t_i)} + \frac{(h(t_{i+1}) - h(t_i))^2}{2(t_{i+1} - t_i)} \right) \\
&\quad \left( \prod_{i=0}^{n-1} \frac{1}{\sqrt{2\pi(t_{i+1} - t_i)}} \right) \exp \left( - \sum_{i=0}^{n-1} \frac{(x_{i+1} - x_i)^2}{2(t_{i+1} - t_i)} \right) dx_1 \dots dx_n.
\end{aligned}$$

On reconnaît sur la dernière ligne la densité du vecteur  $(W_{t_1}, W_{t_2} - W_{t_1}, \dots, W_{t_n} - W_{t_{n-1}})$  (cf. la première question avec  $h = 0$ ), et on a donc :

$$\begin{aligned}
& \mathbb{E}(\varphi(X_{t_1}, X_{t_2}, \dots, X_{t_n})) \\
&= \mathbb{E} \left( \varphi(W_{t_1}, \dots, W_{t_n}) \exp \left( - \sum_{i=0}^{n-1} \frac{(W_{t_{i+1}} - W_{t_i})(h(t_{i+1}) - h(t_i))}{(t_{i+1} - t_i)} + \frac{(h(t_{i+1}) - h(t_i))^2}{2(t_{i+1} - t_i)} \right) \right) \\
&= \mathbb{E} \left( \varphi(W_{t_1}, \dots, W_{t_n}) Z_t^{\text{disc}} \right).
\end{aligned}$$

**3** La fonction  $h$  est de classe  $\mathcal{C}^2$  et donc  $h'$  est borné sur tout intervalle de temps borné. Ceci implique que l'intégrale stochastique  $\int_0^t h'(s) dW_s$  est bien définie.

Soit  $Y_t = - \int_0^t h'(s) dW_s - \frac{1}{2} \int_0^t (h'(s))^2 ds$ . Par un calcul d'Itô, on a

$$\begin{aligned}
dZ_t &= d(\exp(Y_t)) \\
&= \exp(Y_t) dY_t + \frac{1}{2} \exp(Y_t) d\langle Y \rangle_t \\
&= Z_t \left( -h'(t) dW_t - \frac{1}{2} (h'(t))^2 dt \right) + \frac{1}{2} Z_t (h'(t))^2 dt \\
&= -h'(t) Z_t dW_t.
\end{aligned}$$

*Remarque :* On peut alors vérifier que  $\mathbb{E}(Z_t) = 0$ , ce qui est une conséquence de (2) en prenant  $\varphi = 1$ . En effet,  $Z_t = Z_0 - \int_0^t h'(s) Z_s dW_s$  avec  $Z_0 = 1$ . Par ailleurs

$$\mathbb{E} \int_0^t (h'(s) Z_s)^2 ds = \int_0^t (h'(s))^2 \mathbb{E}(Z_s)^2 ds$$

et on vérifie que  $\sup_{s \in [0, t]} \mathbb{E}(Z_s)^2 < \infty$  car  $\int_0^t h'(s) dW_s$  est une gaussienne centrée et de variance  $\int_0^t (h'(s))^2 ds$ .

**4** Par un calcul d'Itô, on a

$$d(h'(t)W_t) = h''(t)W_t dt + h'(t)dW_t$$

et donc

$$h'(t)W_t = \int_0^t h''(s)W_s ds + \int_0^t h'(s)dW_s.$$

5 En prenant  $\varphi = 1_{\|\cdot\|_{L^\infty(0,t)} \leq \varepsilon}$ , on a (puisque  $X_s = -h(s) + W_s$ ) :

$$\mathbb{E} \left( 1_{\|W_s - h(s)\|_{L^\infty(0,t)} \leq \varepsilon} \right) = \mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} Z_t \right)$$

ce qui se réécrit :

$$\begin{aligned} \mathbb{P} \left( \|W_s - h(s)\|_{L^\infty(0,t)} \leq \varepsilon \right) &= \mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds - \frac{1}{2} \int_0^t (h'(s))^2 ds \right) \right) \\ &= \exp \left( -\frac{1}{2} \int_0^t (h'(s))^2 ds \right) \mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds \right) \right). \end{aligned}$$

Par conséquent

$$\frac{\mathbb{P} \left( \|W_s - h(s)\|_{L^\infty(0,t)} \leq \varepsilon \right)}{P \left( \|W_s\|_{L^\infty(0,t)} \leq \varepsilon \right)} = \exp \left( -\frac{1}{2} \int_0^t (h'(s))^2 ds \right) \frac{\mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds \right) \right)}{P \left( \|W_s\|_{L^\infty(0,t)} \leq \varepsilon \right)}$$

et on veut montrer que

$$\lim_{\varepsilon \rightarrow 0} \frac{\mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds \right) \right)}{P \left( \|W_s\|_{L^\infty(0,t)} \leq \varepsilon \right)} = 1.$$

Ceci est équivalent à

$$\lim_{\varepsilon \rightarrow 0} \frac{\mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \left[ \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds \right) - 1 \right] \right)}{P \left( \|W_s\|_{L^\infty(0,t)} \leq \varepsilon \right)} = 0.$$

Or, on a, en utilisant le fait que  $|\exp(y) - 1| \leq \exp(|y|)|y|$ , et en posant  $C = (\|h'\|_{L^\infty(0,t)} + t\|h''\|_{L^\infty(0,t)})$

$$1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \left| \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds \right) - 1 \right| \leq 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} C\varepsilon \exp(C\varepsilon)$$

puisque  $1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \left| -h'(t)W_t + \int_0^t h''(s)W_s ds \right| \leq \varepsilon (\|h'\|_{L^\infty(0,t)} + t\|h''\|_{L^\infty(0,t)})$  et donc

$$\begin{aligned} &\left| \frac{\mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \left[ \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds \right) - 1 \right] \right)}{P \left( \|W_s\|_{L^\infty(0,t)} \leq \varepsilon \right)} \right| \\ &\leq \frac{\mathbb{E} \left( 1_{\|W_s\|_{L^\infty(0,t)} \leq \varepsilon} \left| \exp \left( -h'(t)W_t + \int_0^t h''(s)W_s ds \right) - 1 \right| \right)}{P \left( \|W_s\|_{L^\infty(0,t)} \leq \varepsilon \right)} \\ &\leq C\varepsilon \exp(C\varepsilon) \end{aligned}$$

qui tend effectivement vers 0 quand  $\varepsilon \rightarrow 0$ .