

I l'algorithme SHUS (Self Healing Umbrella Sampling):

1) le cadre:

$\pi(dx) = \gamma(x) \lambda(dx)$ avec $\gamma: E \rightarrow \mathbb{R}_+$ mesurable densité de proba par rapport à λ (i.e. $\int_E \gamma(x) \lambda(dx) = 1$).

On se donne

- une partition mesurable $(E_i)_{1 \leq i \leq g}$ de E

- un mode $\cdot I: E \ni x \mapsto \sum_{i=1}^g i \mathbb{1}_{E_i}(x)$.

des E_i de la partition on suppose que $\forall i, \theta_+(i) > 0$ (quelle à retirer)

$\cdot \mathcal{H} = \{ \theta = (\theta(1), \dots, \theta(g)) \in]0,1[^g \text{ tq } \sum_{i=1}^g \theta(i) = 1 \}$.

NB: $\theta_+ \in \mathcal{H}$.

Métabolisme: θ_0 et très loin de l'uniformité
 besoin de pondérer par les strates E_i de très faible
 probabilité $\theta_0(i)$ pour relier des strates de plus
 forte probas.

suggère de modifier la probabilité pour la rendre plus
 uniforme

Pour $\theta \in \mathcal{H}$, on pose
$$\pi_{\theta}(x) = \frac{1}{Z_{\theta}} \sum_{i=1}^y \frac{\eta(x) \mathbb{1}_{E_i}(x) \chi(x)}{\theta(i)}$$

$$= \frac{1}{Z_{\theta}} \frac{\eta(x) \chi(x)}{\theta(I(x))}$$

où la constante de normalisation Z_{θ} vaut

$$Z_{\theta} = \sum_{i=1}^y \frac{\pi(E_i)}{\theta(i)} = \sum_{i=1}^y \frac{\theta_0(i)}{\theta(i)} \quad \pi_{\theta}(E_i) = \frac{1}{Z_{\theta}} \frac{\pi(E_i)}{\theta(i)} = \frac{1}{Z_{\theta}} \frac{\theta_0(i)}{\theta(i)}$$

Pour $\theta = \theta_0$, $Z_{\theta} = y$
 cas: $\pi_{\theta}(\frac{1}{y}, \dots, \frac{1}{y}) = \pi$
 les strates E_i sont équipondérées
 suivant π_{θ} .

Construction d'un couple (X_n, θ_n) à l'instar de (X_{n-1}, θ_{n-1})
 approche θ_n et X_n suivant la méthode de Metropolis
 Hastings $\mathbb{P}_{\theta_{n-1}}(X_{n-1}, \cdot)$ qui admet $\pi_{\theta_{n-1}}$ comme probabilité
 On met à jour θ_n à partir de θ_{n-1} en prenant
 la strate $I(X_n)$ ($\theta_n(I(X_n)) < \theta_{n-1}(I(X_n))$
 et $\theta_n(i) > \theta_{n-1}(i)$ pour $i \neq I(X_n)$)

Calcul d'intégrale suivant π alors que l'on a simulé
suivant π_{θ_0} :

$$\pi_{\theta_0} = \frac{1}{\int \sum_{i=1}^g \theta_0(i) \frac{y(x) \mathbb{1}_{E_i}(x) \lambda(dx)}{\theta_0(i)}} = \int \frac{1}{\sum_{i=1}^g \theta_0(i)} \mathbb{1}_{E_i}(x) \pi(dx)$$

$$\frac{d\pi(x)}{d\pi_{\theta_0}} = \sum_{i=1}^g \theta_0(i) \mathbb{1}_{E_i}(x)$$

Pour $f: E \rightarrow \mathbb{R}$ mesurable bornée
 Pour $X \sim \pi_{\theta_0}$

$$\int_E f(x) \pi(dx) = \sum_{i=1}^g \int_{E_i} \theta_0(i) f(x) \pi_{\theta_0}(dx) = E \left(\sum_{i=1}^g \theta_0(i) f(X) \mathbb{1}_{E_i}(X) \right)$$

part de variance liée au choix de proba

$$\text{Var} \left(\sum_{i=1}^J \theta_{\bullet}(i) \mathbb{1}_{E_i}(X) \right) = \sum_{i=1}^J (\theta_{\bullet}(i))^2 \pi_{\theta}(E_i) - \left(\sum_{i=1}^J \theta_{\bullet}(i) \underbrace{\pi_{\theta}(E_i)}_{\frac{1}{J}} \right)^2$$

$$= J \sum_{i=1}^J \theta_{\bullet}(i)^2 - 1$$

peut être grande si θ_{\bullet} loin de l'uniformité (en cas de rééchantillonnage)

ex: 2 strates de poids proches de $\frac{1}{2}$ toutes les autres de poids proche de 0 \rightarrow $\text{Var} \approx \frac{J}{2} - 1 \gg 1$ si $J \gg 1$.

Introduire donc un paramètre $\alpha \in [0, 1]$ pour compenser le changement de proba!

$$y_{\theta}^{\alpha}(x) = \frac{1}{Z_{\theta}^{\alpha}} \sum_{i=1}^J \frac{y(x)}{\theta_{\bullet}^{\alpha}(i)} \mathbb{1}_{E_i}(x) \quad Z_{\theta}^{\alpha} = \sum_{i=1}^J \frac{\theta_{\bullet}(i)}{\theta_{\bullet}^{\alpha}(i)}$$

On pose $\pi_{\theta}^{\alpha}(dx) = y_{\theta}^{\alpha}(x) \lambda(dx)$ $\pi_{\theta}^0 = \pi$ $\pi_{\theta}^1 = \pi_{\theta}$

Posm $X \sim \Pi_{\theta^*}^a$ $Z_{\theta^*}^a = \sum_{i=1}^J \theta_*^{1-a}(i)$.

$$\frac{d\Pi}{d\Pi_{\theta^*}^a}(x) = \sum_{i=1}^J Z_{\theta^*}^a \theta_*^a(i) \mathbb{1}_{E_i}(x)$$

$$\text{Var} \left(\frac{d\Pi}{d\Pi_{\theta^*}^a}(x) \right) = \sum_{i=1}^J \left(Z_{\theta^*}^a \theta_*^a(i) \right)^2 \Pi_{\theta^*}^a(E_i) - \left(\sum_{i=1}^J Z_{\theta^*}^a \theta_*^a(i) \underbrace{\Pi_{\theta^*}^a(E_i)}_{\frac{\theta_*^{1-a}(i)}{Z_{\theta^*}^a}} \right)^2$$

$$= Z_{\theta^*}^{2a} \sum_{i=1}^J \theta_*^{1+a}(i) - 1$$

$$= \sum_{i=1}^J \theta_*^{1-a}(i) \sum_{i=1}^J \theta_*^{1+a}(i) - 1$$

lemme: $\alpha \rightarrow f(\alpha) = \sum_{i=1}^J \theta_*^{1-\alpha}(i) \sum_{i=1}^J \theta_*^{1+\alpha}(i) \nearrow \text{sur } [0, 1]$.

NB: pour $\alpha = 0$ on obtient $f(0) = \left(\sum_{i=1}^J \theta_*(i) \right)^2 = 1$

preuve du lemme:

$$\begin{aligned} \frac{d}{da} (\ln f(x)) &= \frac{d}{da} \ln \left(\sum_{i=1}^g \theta_*(i)^{1+a} \right) + \frac{d}{da} \ln \left(\sum_{i=1}^g \theta_*(i)^{1-a} \right) \\ &= \frac{\sum_{i=1}^g \theta_*(i)^{1+a} \ln \theta_*(i)}{\sum_{i=1}^g \theta_*(i)^{1+a}} - \frac{\sum_{i=1}^g \theta_*(i)^{1-a} \ln \theta_*(i)}{\sum_{i=1}^g \theta_*(i)^{1-a}}. \end{aligned}$$

où $g(b) = \frac{\sum_{i=1}^g \ln \theta_*(i) \theta_*(i)^b}{\sum_{i=1}^g \theta_*(i)^b} \geq 0$ pour $a \in [0, 1]$
 $\Rightarrow f \uparrow_{\text{sur } [0, 1]}$
pour $b \geq 0$

$$g'(b) = \frac{\sum_{i=1}^g (\ln \theta_*(i))^2 \theta_*(i)^b}{\sum_{i=1}^g \theta_*(i)^b} - \left(\frac{\sum_{i=1}^g (\ln \theta_*(i) \theta_*(i)^b)^2}{\sum_{i=1}^g \theta_*(i)^b} \right) \geq 0.$$

car variance

$$\left(\sum_{i=1}^g \ln \theta_*(i) \theta_*(i)^{\frac{b}{2}} \right)^2 \stackrel{\text{C.S.}}{\leq} \left(\sum_{i=1}^g (\ln \theta_*(i))^2 \theta_*(i)^b \right) \sum_{i=1}^g \theta_*(i)^b.$$

□

2) l'algorithme SHUS \propto_α avec $\alpha \in [0, 1]$ et $\alpha \in [\frac{1}{2}, 1]$.

On part de $(\tilde{\theta}_0, X_0)$ à valeurs dans $]0, +\infty[^J \times E$ et on passe par récurrence de $(\tilde{\theta}_n, X_n)$ à $(\tilde{\theta}_{n+1}, X_{n+1})$ en effectuant 3 étapes :

1) normalisation : on pose $S_n = \sum_{i=1}^J \tilde{\theta}_n(i)$.
 et $\theta_n = \frac{\tilde{\theta}_n}{S_n} \in \mathbb{H}$.

2) tirage de $X_{n+1} \sim P_{\theta_n}^\alpha(X_n, \cdot)$ moyen de Metropolis-Hastings qui cible $\pi_{\theta_n}^\alpha$ (plus généralement P_θ^α cible π_θ^α)

3) mise à jour des poids
 pour $1 \leq i \leq J$,
 $\tilde{\theta}_{n+1}(i) = \tilde{\theta}_n(i) + \frac{\gamma}{g_\alpha(S_n)} S_n \theta_n^\alpha(i) \mathbb{1}_{E_i}(X_{n+1})$
 avec $\gamma > 0$,
 et pour $s > 0$, $g_\alpha(s) = \begin{cases} s & \text{si } \alpha = 1 \\ \ln(1+s) & \text{si } \alpha < 1 \end{cases}$

$$\text{On a } \tilde{\theta}_{m+1}(I(X_{m+1})) > \tilde{\theta}_m(I(X_{m+1}))$$

$$\text{et } \tilde{\theta}_{m+1}(i) = \tilde{\theta}_m(i) \text{ pour } i \neq I(X_{m+1}).$$

$$\sum_{i=1}^J \frac{\theta_*(i)}{\tilde{\theta}_{m+1}^\alpha(i)} < \sum_{i=1}^J \frac{\theta_*(i)}{\tilde{\theta}_m^\alpha(i)} \quad (\text{on suppose } \alpha > 0).$$

Pour $i \neq I(X_{m+1})$

$$\prod_{\theta_{m+1}}^\alpha(E_i) = \frac{1}{\sum_{j=1}^J \frac{\theta_*(j)}{\tilde{\theta}_{m+1}^\alpha(j)}}$$

$$\frac{\theta_*(i)}{\tilde{\theta}_{m+1}^\alpha(i)} \quad \text{"} \quad \tilde{\theta}_m^\alpha(i)$$

$$\frac{1}{\sum_{j=1}^J \frac{\theta_*(j)}{\tilde{\theta}_m^\alpha(j)}} \frac{\theta_*(i)}{\tilde{\theta}_m^\alpha(i)} = \prod_{\theta_m}^\alpha(E_i)$$

augmentation de la proba cible des états non visités à l'inst. $m+1$.

Par passage au complémentaire

$$\prod_{\theta_{m+1}}^\alpha(E_{\bar{I}(X_{m+1})}) < \prod_{\theta_m}^\alpha(E_{\bar{I}(X_{m+1})})$$

$$1 - \sum_{i \neq I(X_{m+1})} \prod_{\theta_{m+1}}^\alpha(E_i) < 1 - \sum_{i \neq I(X_{m+1})} \prod_{\theta_m}^\alpha(E_i)$$

Le pas de l'algorithme est $\gamma_{m+1} = \frac{\gamma}{S_m}$ dans la mise à jour de $\tilde{\theta}_{m+1}$.

$$\begin{aligned}\tilde{\theta}_{m+1}(i) &= S_m \theta_m(i) \left(1 + \gamma_{m+1} \theta_m^{\alpha-1}(i) \mathbb{1}_{E_i}(X_{m+1}) \right) \\ &= \tilde{\theta}_m(i) \left(1 + \gamma_{m+1} \theta_m^{\alpha-1}(i) \mathbb{1}_{E_i}(X_{m+1}) \right).\end{aligned}$$

Algorithme de Wang Landau de paramètre α noté WL_α :

Pour une suite de pas $(\gamma_m)_{m \geq 1}$ et $(\theta_0, X_0) \in]0, +\infty[\times E$ on réalise le passage de $(\tilde{\theta}_m, X_m)$ à $(\tilde{\theta}_{m+1}, X_{m+1})$ de $]0, +\infty[\times E$ en effectuant 3 étapes

1) normalisation $S_m = \sum_{i=1}^N \tilde{\theta}_m(i)$ $\theta_m = \frac{\tilde{\theta}_m}{S_m} \in \mathbb{H}$.

2) génération de $X_{m+1} \sim P_{\theta_m}^\alpha(X_m, \cdot)$ moyen MH utilisant $\tilde{\theta}_m^\alpha$

3) $\tilde{\theta}_{m+1}(i) = \tilde{\theta}_m(i) \left(1 + \gamma_{m+1} \theta_m^{\alpha-1}(i) \mathbb{1}_{E_i}(X_{m+1}) \right).$

Algorithme stochastique pour $(Q_n)_n$.

Typiquement on va avoir besoin du comportement suivant des pas : $\sum \gamma_n = +\infty$ et $\sum \gamma_n^2 < +\infty$.

$$Q_{n+1}(i) = \frac{\tilde{Q}_{n+1}(i)}{S_{n+1}} = \frac{1 + \gamma_{n+1} \theta_n^{\alpha-1}(i) \mathbb{1}_{E_i}(X_{n+1})}{1 + \gamma_{n+1} \theta_n^\alpha(I(X_{n+1}))} \times \underbrace{\frac{\tilde{Q}_n(i)}{S_n}}_{\theta_n(i)}.$$

Le choix $\gamma_{n+1} = \frac{\gamma}{j_\alpha(S_n)}$ fait dans SHUS $^\alpha$ ou

assurer que $\gamma_{n+1} \sim n^{-\alpha}$ $\alpha \in]\frac{1}{2}, 1[$.

ce qui implique que $\sum_{n \geq 0} \gamma_{n+1} = +\infty$ et $\sum_{n \geq 0} \gamma_{n+1}^2 < +\infty$.

3) intuition sur le choix de β :

$$S_{m+1} = S_m + \frac{\gamma}{\beta \alpha(S_m)} S_m \theta_m^\alpha (I(X_{m+1}))$$

On espère que pour $m \rightarrow +\infty$, $\theta_m \rightarrow \theta_*$ et la loi de X_{m+1} converge vers $\pi_{\theta_*}^\alpha$ si bien que $E(\theta_m^\alpha (I(X_{m+1}))) \rightarrow \sum_{i=1}^J \theta_*^\alpha(i) \underbrace{\pi_{\theta_*}^\alpha(E_i)}_{\frac{\theta_*^{1-\alpha}(i)}{Z_{\theta_*}^\alpha}}$

$$= \frac{1}{Z_{\theta_*}^\alpha} \sum_{i=1}^J \theta_*(i) \underbrace{1}_{1}$$

On peut espérer que Comportement asymptotique pour $\alpha < 1$

$$\frac{ds(t)}{dt} = \frac{\gamma s(t)}{Z_{\theta_*}^\alpha \beta \alpha(s(t))}$$

On se $m \rightarrow +\infty$ comme $s(m)$ Cas $\alpha = 1$:

$$g_1(s) = s \quad s(t) \sim \frac{\gamma t}{Z_{\theta_*}^\alpha}$$

$$\frac{ds(t)}{dt} = \frac{\gamma}{Z_{\theta_*}^\alpha \beta}$$

$$S_m \sim \frac{\gamma m}{Z_{\theta_*}^\alpha} \quad \gamma_m \sim \frac{Z_{\theta_*}^\alpha}{m}$$

Case $\frac{1}{2} < \alpha < 1$: $f_\alpha(s) = (\ln(\cancel{\gamma} + s))^{\frac{\alpha}{1-\alpha}}$

$$\frac{ds(t)}{dt} = \frac{\gamma s(t)}{Z_0^\alpha (\ln(s(t)))^{\frac{\alpha}{1-\alpha}}} \quad \frac{d \ln s(t)}{dt} = \frac{\gamma}{Z_0^\alpha} \frac{1}{(\ln s(t))^{\frac{\alpha}{1-\alpha}}}$$

$$\frac{d}{dt} \left((\ln(s(t)))^{\frac{1}{1-\alpha}} \right) = \frac{\gamma}{(1-\alpha) Z_0^\alpha}$$

$$\ln(s(t)) \underset{t \rightarrow +\infty}{\sim} \left(\frac{\gamma t}{(1-\alpha) Z_0^\alpha} \right)^{1-\alpha} \quad (\ln S) \underset{n}{\sim} \left(\frac{\gamma n}{(1-\alpha) Z_0^\alpha} \right)^{1-\alpha}$$

$$\gamma_n \sim \frac{\gamma}{\left(\frac{\gamma n}{(1-\alpha) Z_0^\alpha} \right)^\alpha} = \frac{\gamma^{1-\alpha} \left((1-\alpha) Z_0^\alpha \right)^\alpha}{n^\alpha} \quad \text{pour } n \rightarrow +\infty$$

4) Intuition sur la convergence pour $\alpha=1$:

Supposons que $(\theta_m)_m$ converge vers $\theta_\infty \in \Theta$ lorsque $m \rightarrow \infty$
 et montrons qu'alors $\theta_\infty = \theta_*$

$$\frac{1}{m} \sum_{k=1}^m \frac{1}{E_i}(X_k) \rightarrow \pi_{\theta_\infty}^a(E_i) = \frac{\theta_*(i)}{\sum_{\theta_\infty} \theta_\infty^a(i)}$$

$$\tilde{\theta}_m(i) = \tilde{\theta}_0(i) + \gamma \sum_{k=1}^m \theta_{k-1}^a(i) \frac{1}{E_i}(X_k) \underset{m \rightarrow \infty}{\sim} \gamma \frac{\theta_\infty^a(i)}{\sum_{\theta_\infty} \theta_\infty^a(i)} \underset{m \rightarrow \infty}{\sim} \frac{\theta_*(i)}{\sum_{\theta_\infty} \theta_\infty^a(i)}$$

$$S_m = \sum_{i=1}^J \tilde{\theta}_m(i) \underset{m \rightarrow \infty}{\sim} \frac{\gamma}{\sum_{\theta_\infty} \theta_\infty^a(i)} \sum_{i=1}^J \theta_*(i) = \frac{\gamma}{\sum_{\theta_\infty} \theta_\infty^a(i)} \cdot 1$$

$$\theta_m(i) \underset{m \rightarrow \infty}{\sim} \frac{\tilde{\theta}_m(i)}{S_m} \rightarrow \frac{\gamma \theta_*(i) / \sum_{\theta_\infty} \theta_\infty^a(i)}{\gamma / \sum_{\theta_\infty} \theta_\infty^a(i)} = \theta_*(i) \quad \text{ie } \theta_\infty = \theta_*$$

II Convergence de l'algorithme SHUS_a:

Hypothèses:

A1 la densité cible γ est tq $\sup_{x \in E} \gamma(x) < +\infty$
et $\min_{1 \leq i \leq J} \theta_*(i) > 0$

A2 Pour tout $\theta \in \mathbb{H}$, le noyau P_θ^a est un noyau
de Metropolis Hastings qui cible Π_θ^a avec proposition
 $q(x, y) \chi(|x-y|)$ où q est une densité symétrique
(c'est-à-dire $q(x, y) = q(y, x) \forall (x, y) \in E^2$) et vérifie $\inf_{(x, y) \in E \times E} q(x, y) > 0$

Thm. Soit $\gamma > 0$, $\alpha \in [0, 1[$, $\alpha \in]\frac{1}{2}, 1]$. Supposons A1 et A2.

Alors l'algorithme $SHUS_\alpha$ en un de n étapes quelle
 CI $(\theta_0, X_0) \in]0, +\infty[\times E$ converge au sens suivant

1) $\mathbb{P}(\theta_n \xrightarrow[n \rightarrow +\infty]{} \theta_*) = 1$.

2) $\forall f: E \rightarrow \mathbb{R}$ mesurable bornée

$\mathbb{E}[f(X_n)] \xrightarrow[n \rightarrow +\infty]{} \int_E f(x) \pi_{\theta_*}^\alpha(dx)$.

et $\mathbb{P}(\lim_{n \rightarrow +\infty} \frac{1}{n} \sum_{k=1}^n f(X_k) = \int_E f(x) \pi_{\theta_*}^\alpha(dx)) = 1$.

3) $\lim_{n \rightarrow +\infty} \mathbb{E} \left[\left(\sum_{i=1}^{\gamma} \theta_{n-1}^{1-\alpha}(i) \right) \left(\sum_{i=1}^{\gamma} \theta_{n-1}^\alpha (I(X_n)) f(X_n) \right) \right] = \int_E f(x) \pi_{\theta_*}^\alpha(dx)$

$\mathbb{P}(\lim_{n \rightarrow +\infty} \frac{1}{n} \sum_{k=1}^n \left(\sum_{i=1}^{\gamma} \theta_{k-1}^{1-\alpha}(i) \right) \left(\sum_{i=1}^{\gamma} \theta_{k-1}^\alpha (I(X_k)) f(X_k) \right) = \int_E f(x) \pi_{\theta_*}^\alpha(dx)) = 1$

NB: $\frac{d\pi}{d\pi_{\theta_*}^\alpha}(x) = \sum_{i=1}^{\alpha} \theta_*^{\alpha} (I(x)) = \left(\sum_{i=1}^{\gamma} \theta_*^{1-\alpha}(i) \right) \theta_*^\alpha (I(x))$ approche par $\frac{d\pi}{d\pi_{\theta_{k-1}}^\alpha}(x)$

• Pour le même résultat avec $\alpha = 1$, il faut supposer
 en outre que $\inf_{x \in E} \gamma(x) > 0$.
 permet de montrer la récurrence de l'algorithme
 ie son retour vers une infimité de fois dans un compact
 de \mathbb{R}^d . $\limsup_{n \rightarrow +\infty} \min_{1 \leq i \leq d} \theta_n(i) > 0$ ici

$$\theta_{n+1}(i) = \theta_n(i) \frac{1 + \gamma_{n+1} \theta_n^{\alpha-1}(i) \mathbb{1}_{E_i}(x_{n+1})}{1 + \gamma_{n+1} \theta_n^\alpha(\mathbb{I}(x_{n+1}))}$$

$\frac{1+b}{1+c} = 1 + b - c + \frac{c(c-b)}{1+c}$ appliqué avec $b = \gamma_{n+1} \theta_n^{\alpha-1}(i) \mathbb{1}_{E_i}(x_{n+1})$
 $c = \gamma_{n+1} \theta_n^\alpha(\mathbb{I}(x_{n+1}))$

$$\theta_{n+1}(i) = \theta_n(i) \left\{ 1 + \gamma_{n+1} \left(\theta_n^{\alpha-1}(i) \mathbb{1}_{E_i}(x_{n+1}) - \theta_n^\alpha(\mathbb{I}(x_{n+1})) \right) + \gamma_{n+1}^2 \frac{\theta_n^\alpha(\mathbb{I}(x_{n+1})) \left(\theta_n^\alpha(\mathbb{I}(x_{n+1})) - \theta_n^{\alpha-1}(i) \mathbb{1}_{E_i}(x_{n+1}) \right)}{1 + \gamma_{n+1} \theta_n^\alpha(\mathbb{I}(x_{n+1}))} \right\}$$

GM fore $H_i(\theta, x) = \theta^\alpha (i) \frac{1}{E_i(x)} - \theta(i) \theta^\alpha (I(x))$

et $h_i(\theta) = \int H_i(\theta, x) \pi_\theta^\alpha(dx)$

$$= \frac{\theta^\alpha (i) \theta_\star(i)}{\sum_\theta \theta^\alpha (i)} - \theta(i) \sum_{j=1}^J \frac{\theta^\alpha (j) \theta_\star(j)}{\sum_\theta \theta^\alpha (j)}$$

$$= \frac{\theta_\star(i) - \theta(i)}{\sum_\theta \theta^\alpha}$$

$$\Lambda_{m+1}^{(i)} = \gamma_{m+1} \theta_m(i) \left(\theta_m^{2\alpha}(I(x_{m+1})) - \underbrace{\theta_m^\alpha(I(x_{m+1})) \theta_m^{\alpha-1}(i) \frac{1}{E_i(x_{m+1})}}_{\theta_m^{2\alpha-1}(I(x_{m+1})) \frac{1}{E_i(x_{m+1})}} \right)$$

$$= \gamma_{m+1} \theta_m^{2\alpha}(I(x_{m+1})) \frac{1 + \gamma_{m+1} \theta_m^\alpha(I(x_{m+1}))}{\theta_m(i) - \frac{1}{E_i(x_{m+1})}}$$

$$\theta_{m+1} = \theta_m + \gamma_{m+1} H(\theta_m, x_{m+1}) + \frac{1}{\gamma_{m+1}} \underbrace{\Lambda_{m+1}}_{(i \text{ par } i)} \theta_m^\alpha(I(x_{m+1}))$$

$$|\Lambda_{m+1}|^2 \leq \gamma_{m+1}^2 \theta_m^{\text{Ga}}(\mathbb{I}(X_{m+1})) \sum_{i=1}^I \underbrace{(\theta_i - \frac{1}{E_i}(X_{m+1}))^2}_{\in [-1, 1]}$$

$$\leq \gamma \gamma_{m+1}^2$$

$$|\Lambda_{m+1}| \leq \gamma_{m+1} \sqrt{\gamma}$$

$$\theta_{m+1} = \theta_m + \gamma_{m+1} h(\theta_m) + \gamma_{m+1} (H(\theta_m, X_{m+1}) - h(\theta_m)) + \gamma_{m+1} \Lambda_{m+1}$$

Pour faire apparaître un accroissement de m dans l'équation de Poisson, on

$$\hat{H}_{\theta}^{\alpha} - P_{\theta}^{\alpha} \hat{H}_{\theta}^{\alpha} = H(\theta, x) - h(\theta)$$

$$H(\theta_m, X_{m+1}) - h(\theta_m) = \hat{H}_{\theta_m}^{\alpha}(X_{m+1}) - P_{\theta_m}^{\alpha} \hat{H}_{\theta_m}^{\alpha}(X_{m+1})$$

γ équations
1 pour chaque valeur de i .

$$\begin{aligned}
 H(\theta_m, X_{m+1}) - h(\theta_m) &= \hat{H}_{\theta_m}(X_{m+1}) - P_{\theta_m}^a \hat{H}_{\theta_m}(X_{m+1}) \\
 &= \underbrace{\hat{H}_{\theta_m}(X_{m+1}) - P_{\theta_m}^a \hat{H}_{\theta_m}(X_m)}_{\text{erreur mark}} + \underbrace{P_{\theta_m}^a \hat{H}_{\theta_m}(X_m) - P_{\theta_{m+1}}^a \hat{H}_{\theta_{m+1}}(X_{m+1})}_{\text{valeur espérée}} \\
 &\quad + \underbrace{P_{\theta_{m+1}}^a \hat{H}_{\theta_{m+1}}(X_{m+1}) - P_{\theta_m}^a \hat{H}_{\theta_m}(X_{m+1})}_{\text{petit si } \theta \rightarrow P_{\theta}^a \hat{H}_{\theta} \text{ est régulière}}
 \end{aligned}$$

petit si $\theta \rightarrow P_{\theta}^a \hat{H}_{\theta}$ est régulière

car $\theta_{m+1} - \theta_m = O(\gamma_{m+1})$.

$$\begin{aligned}
 \theta_{m+1} &= \theta_m + \gamma_{m+1} (\hat{H}_{\theta_m}(X_{m+1}) - P_{\theta_m}^a \hat{H}_{\theta_m}(X_m)) + \gamma_{m+1} h(\theta_m) + R_{m+1} \\
 \text{où } R_{m+1} &= \underbrace{\gamma_{m+1} \underbrace{\hat{H}_{\theta_m}(X_{m+1}) - P_{\theta_m}^a \hat{H}_{\theta_m}(X_{m+1})}_{R_{m+1}^1}}_{R_{m+1}^2} + \underbrace{\gamma_{m+1} (P_{\theta_m}^a \hat{H}_{\theta_m}(X_m) - P_{\theta_{m+1}}^a \hat{H}_{\theta_{m+1}}(X_{m+1}))}_{R_{m+1}^3} \\
 &\quad + \underbrace{\gamma_{m+1} (P_{\theta_{m+1}}^a \hat{H}_{\theta_{m+1}}(X_{m+1}) - P_{\theta_m}^a \hat{H}_{\theta_m}(X_{m+1}))}_{R_{m+1}^3}
 \end{aligned}$$

h s'appelle le champ moyen et l'algorithme.

$$\sum_{k=0}^{m-1} R_{k+1}^2 = \sum_{k=0}^{m-1} \gamma_{k+1} \left(P_{\theta_k}^\alpha \hat{H}_{\theta_k}(X_k) - P_{\theta_{k+1}}^\alpha \hat{H}_{\theta_{k+1}}(X_{k+1}) \right)$$

$$= \gamma_1 P_{\theta_0}^\alpha \hat{H}_{\theta_0}(X_0) - \gamma_m P_{\theta_m}^\alpha \hat{H}_{\theta_m}(X_m)$$

$$+ \sum_{k=1}^{m-1} (\gamma_{k+1} - \gamma_k) P_{\theta_k}^\alpha \hat{H}_{\theta_k}(X_k)$$

pour $\gamma_k = \frac{c}{k^\alpha}$ $\frac{\gamma_{k+1} - \gamma_k}{c} = \frac{1}{(k+1)^\alpha} - \frac{1}{k^\alpha}$

$$= \frac{1}{k^\alpha} \left(\left(1 + \frac{1}{k}\right)^{-\alpha} - 1 \right) \underset{k \rightarrow +\infty}{\sim} -\frac{\alpha}{k^{1+\alpha}}$$

Fonction de Lyapounov: $\omega(\theta) = \sum_{i=1}^d \theta_i \ln \left(\frac{\theta_i}{\theta^*} \right) =$ entropie relative de θ^*/θ .

lemme: $\omega \geq 0$ sur Θ ne s'annule qu'en θ_*

$\nabla \omega \cdot h(\theta) < 0$ pour $\theta \in \Theta \setminus \{\theta_*\}$

\Rightarrow " en moyenne l'algo tend à se rapprocher de θ_* "

preuve: Par convexité de $x \rightarrow x \ln x$ (dérivée $\ln x + 1$ d'après seconde) sur \mathbb{R}_+

$$\omega(\theta) = \sum_{i=1}^g \frac{\theta_*(i)}{\theta(i)} \ln \left(\frac{\theta_*(i)}{\theta(i)} \right) \times \theta(i) \geq \sum_{i=1}^g \frac{\theta_*(i)}{\theta(i)} \times \theta(i) \ln \left(\underbrace{\sum_{i=1}^g \frac{\theta_*(i)}{\theta(i)}}_{\frac{1}{\theta}} \right)$$

la fonction étant strictement convexe on a même inégalité stricte si $\frac{\theta_*(i)}{\theta(i)}$ n'est pas constante ie si $\theta \neq \theta_*$

$$\nabla \omega(\theta) = \left(\frac{\theta_*(1)}{\theta(1)}, \dots, \frac{\theta_*(g)}{\theta(g)} \right) \quad h(\theta) = \frac{\theta_* - \theta}{Z_\theta}$$

$$h \cdot \nabla \omega(\theta) = \frac{1}{Z_\theta} \sum_{i=1}^g (\theta_*(i) - \theta(i)) \frac{\theta_*(i)}{\theta(i)} = \frac{1}{Z_\theta} \left(\underbrace{\sum_{i=1}^g \theta_*(i)}_1 - \sum_{i=1}^g \frac{\theta_*(i)}{\theta(i)} \right)$$

$\sum_{i=1}^g \left(\frac{\theta_*(i)}{\theta(i)} \right)^2 \theta(i) \geq \left(\sum_{i=1}^g \frac{\theta_*(i)}{\theta(i)} \theta(i) \right)^2 = 1$ avec inégalité stricte si θ n'est pas proportionnelle à θ_* ie si $\theta \neq \theta_*$