



Cours Doctoral EDITE
Champs de Markov - Convergence des échantillonneurs

Marc Sigelle

Année 2008-2009

Dernière mise a jour : 11 mars 2009

Mesures de probabilité sur un ensemble Ω fini

- espace \mathcal{E} des fonctions réelles bornées sur Ω :

$$x \in \Omega \mapsto f(x) \in \mathbb{R}$$

- les fonctions indicatrices:

$$\forall y \in \Omega, \quad e_y(x) = \mathbb{1}_{x=y}$$

→ $\{e_y\}_{y \in \Omega}$ est la base canonique de \mathcal{E}

- la fonction constante 1:

$$x \mapsto 1 \quad \forall x \in \Omega$$

Mesures de probabilité sur Ω fini (suite)

- forme linéaire sur \mathcal{E} :

$$f \in \mathcal{E} \mapsto P(f) \in \mathbb{R}$$

* **positive** : $\forall x \in \Omega, f(x) \geq 0 \rightarrow \mu(f) \geq 0$

* **de masse totale 1** : $\mu(\mathbf{1}) = 1$

- on écrira dans la suite (abus)

$$\mu(x) = \mu(e_x)$$

- masses de Dirac

$$\delta_x(f) = f(x) \quad \forall x \in \Omega, \forall f \in \mathcal{E}$$

Distance entre mesures

- (une) norme sur \mathcal{E}

$$\|f\|_{\infty} = \sup_{x \in \Omega} |f(x)|$$


- distance en variation entre deux mesures

$$\begin{aligned} \|\mu_1 - \mu_2\|_1 &= \sum_{x \in \Omega} |\mu_1(x) - \mu_2(x)| \\ &= \sup_{\|f\|_{\infty}=1} |\mu_1(f) - \mu_2(f)| \end{aligned}$$

- on en tire

$$|\mu_1(f) - \mu_2(f)| \leq \|\mu_1 - \mu_2\|_1 \times \|f\|_{\infty}$$

Distance entre mesures (suite)



- o propriétés

$$\|\mu_1 - \mu_2\|_1 \in [0., 2.]$$

$$\|\mu_1 - \mu_2\|_1 = 0 \Leftrightarrow \mu_1 = \mu_2$$

$$\|\mu_1 - \mu_2\|_1 = 2 \Leftrightarrow \mu_1 \text{ et } \mu_2 \text{ sont à supports disjoints}$$

$$\|\mu_1 - \mu_2\|_1 = 2 - 2 \sum_{x \in \Omega} \min(\mu_1(x), \mu_2(x))$$

$$\forall a, b \geq 0 \Rightarrow |a - b| = a + b - 2 \min(a, b)$$


Noyau Q sur Ω (matrice stochastique)

- **linear application on \mathcal{E} :**

$$f \mapsto g = Qf \quad \text{with} \quad Q \mathbf{1} = \mathbf{1}$$

i.e. $Q(x, \cdot)$ est une mesure $\forall x \in \Omega$.

= famille de mesures sur Ω indicée par un élément de Ω lui-même !



- **interprétation en terme de probabilité de transition**

$$Q(x, y) = \pi(Y = y / X = x) = \pi(x \rightarrow y)$$

où $\pi(\cdot)$ est une mesure sur Ω

Noyau Q sur Ω (suite)

- produit d'une mesure μ par un noyau \rightarrow mesure définie par

$$(\mu Q)(f) = \mu(Qf) \quad \forall f \in \mathcal{E}$$

- en particulier

$$(\delta_x Q)(f) = \delta_x(Qf) = (Qf)(x) \Rightarrow (\delta_x Q) = Q(x, \cdot)$$

- on en tire

$$(\mu Q)(x) = \sum_{y \in \Omega} \mu(y) Q(y, x) \quad \forall x \in \Omega$$

- produit de deux noyaux \rightarrow noyau défini par

$$(Q R)(x, y) = \sum_{z \in \Omega} Q(x, z) R(z, y) \quad \forall x, y \in \Omega$$

- conséquences


$$(Q R)(x, \cdot) = \delta_x(Q R) = (\delta_x Q) R = Q(x, \cdot) R \quad \forall x \in \Omega$$

Coefficient de contraction de Dobrushin d'un noyau

- définition

$$c(Q) = \frac{1}{2} \max_{x,y \in \Omega} \|Q(x, \cdot) - Q(y, \cdot)\|$$

- comportement "physique"



- → "dispersion" des lois de probabilités d'un noyau

échantillonnage des distributions de Gibbs

→ lié à la dispersion des différentes lois de transitions associées

Coefficient de Dobrushin d'un noyau (suite)

- propriétés fondamentales

a) $c(Q) \in [0., 1.]$

b) $c(Q) = 1 - \min_{x,y \in \Omega} \left(\sum_{z \in \Omega} \min(Q(x,z), Q(y,z)) \right) \leq 1 - |\Omega| \min_{a,b \in \Omega} Q(a,b)$

c) $\| \mu_1 Q - \mu_2 Q \|_1 \leq c(Q) \| \mu_1 - \mu_2 \|_1$

d) $c(Q R) \leq c(Q) c(R)$

- tout résulte de cela pour les MRFs, en particulier c) et d)

Coefficient de Dobrushin d'un noyau (suite)

- exemple pour c) : deux masses de Dirac

$$\mu_1 = \delta_a \quad \text{et} \quad \mu_2 = \delta_b$$

$$\mu_1 Q(x) = Q(a, x)$$

$$\| \mu_1 Q - \mu_2 Q \|_1 = \sum_{x \in \Omega} |Q(a, x) - Q(b, x)| = \| Q(a, \cdot) - Q(b, \cdot) \|_1$$

$$\leq \max_{x, y \in \Omega} \| Q(x, \cdot) - Q(y, \cdot) \|_1 = 2 c(Q)$$

$$= \| \mu_1 - \mu_2 \|_1 c(Q)$$

→ égalité lorsque $(a, b) = \arg \min_{(x, y)} \| Q(x, \cdot) - Q(y, \cdot) \|_1$ (Ω fini $\rightarrow \exists(a, b)$)

Coefficient de Dobrushin d'un noyau (suite)

◦ propriété c) \Rightarrow d)

$$\forall x, y \in \Omega \quad (QR)(x, \cdot) - (QR)(y, \cdot) = Q(x, \cdot) R - Q(y, \cdot) R$$

$$\rightarrow \forall x, y \in \Omega \quad \|(QR)(x, \cdot) - (QR)(y, \cdot)\|_1 \leq c(R) \|Q(x, \cdot) - Q(y, \cdot)\|_1$$

$$\Rightarrow \frac{1}{2} \max_{x, y \in \Omega} \|(QR)(x, \cdot) - (QR)(y, \cdot)\|_1 \leq \frac{1}{2} \max_{x, y \in \Omega} \|Q(x, \cdot) - Q(y, \cdot)\|_1 c(R) \quad \square$$

◦ **demonstration de c)**

$$(\mu_1 Q)(f) - (\mu_2 Q)(f) = \mu_1 (Qf) - \mu_2 (Qf)$$

$$Qf = \frac{\max Qf - \min Qf}{2} \phi + \frac{\max Qf + \min Qf}{2} \quad (-1 \leq \phi \leq +1)$$

$$\Rightarrow | \mu_1 (Qf) - \mu_2 (Qf) | = \frac{Qf(M) - Qf(m)}{2} | \mu_1(\phi) - \mu_2(\phi) |$$

$$= \left[\frac{Q_M(f) - Q_m(f)}{2} \right] | \mu_1(\phi) - \mu_2(\phi) | \quad (\|\phi\|_\infty = 1)$$

$$\leq \frac{\|Q(M, \cdot) - Q(m, \cdot)\|_1}{2} \|f\|_\infty \|\mu_1 - \mu_2\|_1$$

$$\leq c(Q) \|f\|_\infty \|\mu_1 - \mu_2\|_1 \quad \forall f$$

Mesure(s) invariante(s) associée(s) un noyau

- **définition**

$$(\mu Q)(x) = \mu(x) \quad \forall x \in \Omega$$

→ “vecteurs propres” de la matrice stochastique Q pour la valeur propre 1.

- **réversibilité**

$$\mu(x) Q(x, y) = \mu(y) Q(y, x) \quad \forall x, y \in \Omega$$

→ μ mesure invariante pour Q (sommation sur x par exemple)

- **interprétation en terme de probabilités de transition** (Bayes)

$$\forall \pi, \pi(X = x) \pi(Y = y / X = x) = \pi(Y = y) \pi(X = x / Y = y) \quad \forall x, y \in \Omega$$

$$i.e. \pi(X = x) \pi(x \rightarrow y) = \pi(Y = y) \pi(y \rightarrow x).$$

⇒ $\pi(\cdot)$ est réversible, donc invariante, *p.r.* à sa propre probabilité de transition $\pi(\cdot \rightarrow \cdot)$.

Mesure(s) invariante(s) associée(s) un noyau (suite)

- **stricte positivité**

$$Q(x, y) > 0 \quad \forall x, y \in \Omega, \Leftrightarrow c(Q) < 1$$

- **irréductibilité**

$$\exists r \in \mathbb{N}^+ \text{ t.q. } Q^r > 0$$

- **théorème de Perron-Frobenius:** si Q est stochastique > 0 , \exists une **unique mesure invariante** μ de Q , avec une **convergence géométrique** de la chaîne de Markov associée \forall la mesure initiale P_0

$$\forall M \geq 0, \quad \|(P_0 Q^M) - \mu\|_1 = \|(P_0 Q^M) - (\mu Q^M)\|_1 \leq c(Q)^M \|P_0 - \mu\|_1 ,$$

$$c(Q) < 1$$

Mesure(s) invariante(s) associée(s) un noyau (suite)

- la convergence tient aussi Q si irréductible: $Q^r > 0$

$$\mu Q = \mu \Rightarrow \mu Q^r = \mu$$

$$\| P_0 Q^{nr+p} - \mu \|_1 = \| P_0 (Q^r)^n Q^p - \mu (Q^r)^n \|_1 \leq c(Q^r)^n \| P_0 Q^p - \mu \|_1 ,$$


$$c(Q^r) < 1$$

- loi des grands nombres (échantillons $X^{(n)}$ non indépendants!)

$$\frac{\sum_{n=M}^{M+N} P_n(f)}{N} \xrightarrow{N \rightarrow +\infty} \mu(f) \Rightarrow \frac{\sum_{n=M}^{M+N} f(X^{(n)})}{N} \xrightarrow{N \rightarrow +\infty} \mathbf{E}_\mu[f(X)]$$

Echantillonnage d'une distribution de Gibbs

- chaîne de Markov de variables d'images !



- échantillonnage homogène : trouver $Q_T(x, y)$ tel que

$$\lim_{n \rightarrow +\infty} \mathbb{P}(X^{(n)} = x) = P_T(X = x) \quad \text{distribution de Gibbs à température } T$$

- échantillonnage inhomogène : trouver $Q_n(x, y)$ tel que

$$\lim_{n \rightarrow +\infty} \mathbb{P}(X^{(n)} = x) = \frac{1}{|\Omega^*|} \mathbb{1}_{x \in \Omega^*} \quad \text{distribution de Gibbs à température "0"}$$

→ minimum globaux de $U(x)$

- reformulation : trouver $Q_T(x, y)$ irréductible, réversible *p.r.* $\mathbf{P}_T(\cdot)$

→ admettant donc $\mathbf{P}_T(\cdot)$ comme mesure invariante $\forall T$

Échantillonneur de Gibbs

- **descripteur au site s** $\xi \rightarrow \eta : \Delta U_{\text{global}} = \Delta U(\cdot / V_s)_{\text{local}}$

$$\rightarrow U(x_s = \xi, x^s) + U(x_s = \eta / V_s) = U(x_s = \eta, x^s) + U(x_s = \xi / V_s)$$

$$\frac{\exp -U(x_s = \xi, x^s) / T}{Z_T} \cdot \frac{\exp -U(x_s = \eta / V_s) / T}{Z_T^s}$$

$$= \frac{\exp -U(x_s = \eta, x^s) / T}{Z_T} \cdot \frac{\exp -U(x_s = \xi / V_s) / T}{Z_T^s} \quad \forall T > 0$$

- **noyau de transition local**


$$Q_T^s(x, y) = \mathbb{1}_{x_r=y_r, r \neq s} \cdot P_T(y_s / V_s) = \mathbb{1}_{x_r=y_r, r \neq s} \cdot \frac{\exp -U(y_s / V_s) / T}{Z_T^s}$$

réversible (mais non strictement positif) *p.r.* la distribution de Gibbs

$$P_T(x) = \frac{\exp -U(x) / T}{Z_T} ,$$

Échantillonneur de Gibbs (suite)

- **visite de l'ensemble des sites** : \mathcal{T} = arrangement (= permutation) de S



- **noyau de transition global**

$$Q_T(x, y) = P(Y = y / X = x) = \prod_{s \in \mathcal{T}} P_T(y_s / V_s) = \prod_{s \in \mathcal{T}} Q_T^s(x, y)$$

strictement > 0 et **réversible** (produit de noyaux réversibles).

- **convergence et loi des grands nombres** :

$$P(X^{(n)} = x) = P_0 (Q_T)^n(x) \rightarrow P_T(X = x) \quad \forall P_0$$

$$\frac{\sum_{n=M}^{M+N} f(X^{(n)})}{N} \xrightarrow{N \rightarrow +\infty} \mathbf{E}_T[f(X)] \quad \text{ex:} \quad \frac{\sum_{n=M}^{M+N} \mathbb{1}_{X_s^{(n)}=i}}{N} \xrightarrow{N \rightarrow +\infty} \mathbf{E}_T[\mathbb{1}_{X_s=i}] = P_T(X_s = i) !$$

Échantillonneur de Gibbs : vitesse de convergence

- **majoration du coefficient de Dobrushin**

$$P_T(y_s / V_s) = \frac{1}{\sum_{\xi \in E} \exp [U(y_s / V_s) - U(\xi / V_s)] / T} \quad \forall s \in S$$
$$\geq \frac{1}{|E|} \exp - \delta_s / T$$

$$\delta_s = \max_{V_s} (\max_{\eta \in E} U(\eta / V_s) - \min_{\xi \in E} U(\xi / V_s)) = \text{oscillation de } U(. / .)$$

$$\Rightarrow Q_T(x, y) \geq \left(\frac{1}{|E|} \exp - \delta_s / T \right) \quad \forall x, y \in \Omega$$

- **d'où il résulte :**

$$c(Q_\theta) \leq 1 - |\Omega| \frac{1}{|E|^{|S|}} \exp \left(- \sum_{s \in S} \delta_s / T \right)$$
$$= 1 - \exp \left(- \sum_{s \in S} \delta_s / T \right)$$

Échantillonneur de Metropolis

- niveau global

$$(\alpha) \quad Q_T(x, y) = \begin{matrix} 1 \\ 1 \end{matrix} \quad \begin{matrix} \text{si } U(y) < U(x) & (P_T(y) > P_T(x)) \\ \text{si } U(y) > U(x) & + \end{matrix}$$

$$Q_T(y, x) = \begin{matrix} 1 \\ 1 \end{matrix} \quad \begin{matrix} \text{si } U(y) > U(x) & + \\ \text{(réversibilité)} & \Rightarrow \end{matrix}$$

$$P_T(x) Q_T(x, y) = P_T(y) Q_T(y, x) \quad \text{(réversibilité)} \Rightarrow$$

$$(\beta) \quad Q_T(x, y) = \frac{P_T(y)}{P_T(x)} \\ = \exp - (U(y) - U(x) / T) \quad \text{si } U(y) > U(x)$$


Échantillonneur de Metropolis

- **niveau local : loi d'acceptance**

$$R^s(x, y) = R(x_s, y_s) \text{ symétrique e.g. } R(x_s, y_s) = \frac{1}{|E|} \text{ (loi uniforme sur } E \text{)}$$

$$S_T^s(x, y) = \mathbb{1}_{x_r=y_r, r \neq s} \cdot R^s(x, y) Q_T(x, y)$$

$\mathbf{R^s(x, y)} \quad \mathbf{Q_\theta(x, y)}$



réversible car R symétrique

- **tour \mathcal{T} comme précédemment**

$$S_T(x, y) = \prod_{s \in \mathcal{T}} S_T^s(x, y) = \prod_{s \in \mathcal{T}} [R^s(x, y) Q_T(x, y)]$$

réversible *p.r.* $P_\theta(x)$ et **strictement** $> 0 \Rightarrow$ **convergence** :

$$P(X^{(n)} = x) = P_0 (Q_T)^n(x) \rightarrow P_T(X = x) \quad \forall P_0$$

- **+ loi des grands nombres**

Échantillonneurs : vitesse de convergence

- **Metropolis : majoration du coefficient de Dobrushin**

loi d'acceptation équilibrée sur E ,

$$S_T(x, y) \geq \frac{1}{|\Omega|} \exp(-\Delta / T) \quad \text{avec } \Delta = \max_{y \in \Omega} U(y) - \min_{x \in \Omega} U(x)$$
$$\Rightarrow c(S_T) \leq 1 - \exp(-\Delta / T)$$

- **pour les deux échantillonneurs, on obtient une majoration du type**

$$c(Q_T) \leq 1 - \exp(-\Delta / T)$$

où Δ dépend de l'échantillonneur étudié.

Echantillonnage inhomogène (recuit) : convergence

○ hypothèses et notations

- une suite $T_n \rightarrow T = 0$
- une loi de probabilité initiale sur Ω , notée μ_0
- une suite de mesures invariantes notées $P_n = P_{T_n}(\cdot)$
- la génération d'échantillons avec des noyaux de transition notés $Q_n = Q_{T_n}(\cdot, \cdot)$

A chaque étape n

$$P(X^{(n)} = x) = \pi_n(x) = \mu_0 Q_1 Q_2 \dots Q_n(x)$$

Recuit simulé : convergence

- utilisation du lemme d'Abel [Winkler(1995)]

$P_n = P_n Q_n$ pour $n \geq 1 \Rightarrow :$

$$\begin{aligned} P_n - \pi_n &= P_n - \mu_0 Q_1 Q_2 \dots Q_n = P_n Q_n - \mu_0 Q_1 Q_2 \dots Q_{n-1} Q_n \\ &= (P_n - P_{n-1}) Q_n + (P_{n-1} - \pi_{n-1}) Q_n \\ &\quad \text{et par récurrence} \\ &= (P_n - P_{n-1}) Q_{n-1} + (P_{n-1} - P_{n-2}) Q_{n-1} Q_n \\ &\quad + (P_{n-2} - P_{n-3}) Q_{n-2} Q_{n-1} \dots Q_n \quad \dots \\ &\quad + (P_{n-p+1} - P_{n-p}) Q_{n-p+1} \dots Q_n + (P_{n-p} - \pi_{n-p}) Q_{n-p+1} \dots Q_n \end{aligned}$$

- condition suffisante de convergence : on distingue

1. les p premiers termes : $\sum_k \|P_k - P_{k-1}\| < +\infty$

(Cauchy pour la suite $\{P_k\}$: $\|P_m - P_q\| \leq \sum_{k=q}^m \|P_k - P_{k-1}\|$)

2. le dernier terme : $\forall p \geq 1, c(Q_{n-p} Q_{n-p+1} \dots Q_n) \rightarrow 0$

Recuit simulé (suite)

- 1ère condition : $\sum_k \|P_k - P_{k-1}\| < +\infty$ d'où $P_k \rightarrow P_0 = \frac{1}{|\Omega^*|} \mathbb{1}_{x \in \Omega^*}$

$$\forall x \in \Omega, P_k(x) \nearrow \text{ ou } \searrow \text{ quand } T \rightarrow 0^+$$

- 2ème condition : suite de conditions suffisantes !

$$\forall p \geq 1, c(Q_{n-p} Q_{n-p+1} \dots Q_n) \rightarrow 0 \quad (c(Q_n) \rightarrow 1!)$$

$$c(Q_{n-p} Q_{n-p+1} \dots Q_n) \leq \prod_{k=n-p}^n (1 - \exp(-\frac{\Delta}{T_k}))$$

$$\lim_{n \rightarrow +\infty} \prod_{k=1}^n (1 - \exp(-\frac{\Delta}{T_k})) = 0 \text{ produit infini "diverge" vers } 0 !!$$

$$\sum_{n=1}^{+\infty} \exp -\frac{\Delta}{T_n} = +\infty \Leftrightarrow \boxed{T_n \geq \frac{\Delta}{\log n + 1}}$$

[Geman and Geman(1984)]

References

- [Geman and Geman(1984)] S. Geman and D. Geman. Stochastic relaxation, gibbs distribution, and the bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(6):721–741, 1984.
- [Winkler(1995)] Winkler, G. (1995). *Image Analysis, Random Fields and Dynamic Monte Carlo Methods. A Mathematical Introduction*. Applications of mathematics. Springer-Verlag.