

Chaîne de Markov:

Une chaîne de Markov est un processus $\{X_t : t \in \mathbb{N}\}$ tel que:

$$P(X_{t+1} \in A \mid X_t = x_t, X_{t-1} = x_{t-1}, \dots, X_0 = x_0) = P(X_{t+1} \in A \mid X_t = x_t)$$

On dira que la chaîne est homogène si:

$$P(X_{t+1} \in A \mid X_t = x) \quad (1)$$

ne dépend pas de t .

Exmp: La marche aléatoire $\{X_t : t \in \mathbb{N}\}$ définie par $X_0 \sim \nu$ et $X_{t+1} = X_t + \varepsilon_{t+1}$, $t \in \mathbb{N}$ avec $\varepsilon_1, \varepsilon_2, \dots \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$.

Def: Un noyau de transition sur (Ω, \mathcal{A}) est une application $K: \Omega \times \mathcal{A} \rightarrow \mathbb{R}$ telle que

- * Pour tout $A \in \mathcal{A}$, $x \mapsto K(x, A)$ est mesurable
- * Pour tout $x \in \Omega$, $A \mapsto K(x, A)$ est une mesure de probabilité sur (Ω, \mathcal{A}) .

Rmq: On dira alors que la chaîne homogène (1) a pour noyau de transition P où $P(x, A) = P(X_{t+1} \in A \mid X_t = x)$, $x \in \Omega, A \in \mathcal{A}$.

Exmp: Pour la marche aléatoire normale, on a

$$P(x, A) = \int_A \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(y-x)^2}{2\sigma^2}\right\} dy.$$

Rmq: On utilisera souvent l'abus de notation

$P(x, y)$ pour $x, y \in \Omega$, de sorte que

$$P(x, A) = \int_A P(x, y) dy.$$

Intuition: $P(x, A)$ est la probabilité d'adhérer en A sachant que je suis en x .

Notations: Soit $\{X_t : t \in \mathbb{N}\}$ une chaîne de Markov homogène de transition P et loi initiale ν . On notera:

* P_ν la loi de $\{X_t : t \in \mathbb{N}\}$

* νP^k la loi de X_k pour tout $k \in \mathbb{N}$, i.e.,

$$\forall A \in \mathcal{A}, \nu P^k(A) = P(X_k \in A) = \int \nu(dx_0) P(x_0, dx_1) \dots P(x_{k-1}, A)$$

$$* P^k(x, A) = P(X_k \in A \mid X_0 = x)$$

Objectif MCMC: Simuler selon une loi de probabilité donnée π .

Moyen: Construire une chaîne de Markov qui va "approcher" π au sens de la variation totale, i.e.,

$$\| \nu P^t - \pi \|_{VT} := \sup_{A \in \mathcal{A}} | \nu P^t(A) - \pi(A) | \longrightarrow 0, \quad t \rightarrow \infty.$$

Def: * Un noyau de transition P est π -invariant si

$$\int P(x, A) \pi(dx) = \pi(A), \quad \forall A \in \mathcal{A}$$

* π -irréductible si:

pour tout $x \in \Omega$ et $A \in \mathcal{A}$ tq $\pi(A) > 0$, $\exists k \in \mathbb{N}$ tel que $P^k(x, A) > 0$.

* et périodique de période

$p \geq 2$ s'il existe une partition $\Omega_1, \dots, \Omega_p$ de Ω tq. pour tout $x \in \Omega_i$, $P(x, \Omega_{i+1[p]}) = 1$, pour tout $i \in \mathbb{N}$.

Rmq: Si la période vaut $p = 1$, on dira que la chaîne est aperiodique.

Intuition:

- * L'irréductibilité assure que partant de n'importe quel point $x \in \Omega$ on peut arriver n'importe où dans Ω via la transition P . le temps peut être long cela dit...
- * L'apériodicité permet éviter la présence de cycles lorsque la chaîne parcourt un long trajet. Évite les versions aléatoires de $a_n = (-1)^n$, $n \in \mathbb{N}$.

Thm: Si $\{X_t : t \in \mathbb{N}\}$ est une chaîne irréductible de transition P et de loi invariante π , alors

$$\frac{1}{T} \sum_{t=1}^T g(X_t) \rightarrow \int g(u) \pi(du), \quad T \rightarrow \infty$$

où g est une fonction π -intégrable et ceci est vrai pour tout X_0 π -p.p.

Thm: Si de plus la chaîne est apériodique alors

$$\|P^h(X_0, \cdot) - \pi(\cdot)\|_{TV} \rightarrow 0, \quad h \rightarrow \infty$$

pour tout X_0 π -p.p.

Harris récurrence:

Les conditions pour les 2 thm précédents sont assez faciles à vérifier sachant que π est P .

Pbm: Bien plus ^{difficile} de s'assurer que X_0 est dans une région où la densité π est > 0 .

Def: Une ~~noyau~~ chaîne de transition est Harris récurrencte si pour tout $x \in \Omega$

$$P(X_k \in A \text{ infinisent souvent} \mid X_0 = x) = 1.$$

Thm: Les 2 thm précédents sont vrais pour tout $X_0 \in \Omega$ si la chaîne est Harris récurrencte.

Soyons concret !!!

Les résultats précédents ne servent à rien si l'on ne sait pas construire une chaîne de Markov vérifiant ces conditions.

C'est l'objectif des méthodes MCMC, produire des méthodes génériques pour obtenir de telles chaînes de Markov.

Metropolis - Hastings :

L'idée est d'utiliser un noyau de transition Π -réversible, i.e.,

$$\pi(x) P(x, y) = \pi(y) P(y, x) \quad \forall x, y \in \Omega.$$

Req: La Π -réversibilité est facile à obtenir et implique la Π -invariance puisque

$$\pi P(B) = \int_{\Omega} P(x, B) \pi(dx) \stackrel{\text{inv}}{=} \int_B P(x, \Omega) \pi(dx) = \pi(B).$$

Algo: Metropolis - Hastings

Input: N longueur chaîne, ^{noyau de proposition} ~~noyau transition~~ $q(\cdot, \cdot)$ et état initial x_0 , loi cible π .

Output: Une chaîne de Markov $\{X_t : t \in \mathbb{N}\}$ de loi invariante π .

0) $t \leftarrow 0$

1) Générer candidat $X_* \sim P(x_t, \cdot)$

2) Accepter X_* , i.e., $X_{t+1} \leftarrow X_*$ avec proba

$$\alpha(x_t, x_*) = \min \left\{ 1, \frac{\pi(x_*) q(x_*, x_t)}{\pi(x_t) q(x_t, x_*)} \right\}$$

si on accepte x_* , i.e., $X_{t+1} \leftarrow x_*$

3) Revenir en 1 et incrémenter t , i.e., $t \leftarrow t+1$

⚠ Noyau de proposi^o \neq noyau de transi^o

En effet le noyau de transi^o de la chaîne est

$$P(x, y) = q(x, y) \alpha(x, y) + \int \left(1 - \int q(x, z) \alpha(x, z) dz \right) \mathbb{1}_{\{x=y\}}$$

Et c'est bien π -réversible comme conséquence de

$$\begin{aligned} \pi(x) q(x, y) \alpha(x, y) &= \pi(x) \int \pi(w) q(x, y), \pi(y) q(y, x) \} \\ &= \pi(y) q(y, x) \pi(x) \int \frac{\pi(w) q(x, y)}{\pi(y) q(y, x)}, 1 \} \\ &= \pi(y) q(y, x) \alpha(y, x) \end{aligned}$$

Quelques noyaux de transition :

- * π -H. indépendant $q(x, y) = q(y) \rightarrow$ pas très utile
- * marche aléatoire $q(x, y) = q(x+y)$, q selon une loi symétrique
- * marche aléatoire sur le log, $\frac{q(x, x)}{q(x, y)} = \frac{x}{y} \rightarrow$ utile si on se balade sur \mathbb{R}^+

(8)
Exmp: Faire un π -H. pour la loi cible $N(0,1)$
et où le noyau de proposition est celui d'une
marche aléatoire avec inova^o gaussiennes.

↳ à voir: impact valeur initiale, impact taille des inova^o

Exmp: Faire un π -H pour la loi cible $LN(0,1)$ avec
une transi^o de $N(0,1)$ et d'une marche aléatoire sur
le log.

↳ à voir: impact choix loi de proposition.

Représenter $\{X_t, X_{t+m} : t \in \mathbb{N}\}$ par parle de la
dépendance. Introduire l'ACF. Parler de l'amincissement
d'une chaîne ("thinning").

Echantillonneur de Gibbs:

(9)

Cas particulier de M-H.

Bonne option pour simuler selon une loi cible multivariée, ie, vivant dans \mathbb{R}^d , $d \geq 2$.

Exmp: Simuler selon une $N(\mu, \Sigma)$.

Algo:

$$X_0 = (X_{1,0}, \dots, X_{d,0})$$

In: Etat initial, N longueur de la chaîne, loi cible π .

Out: Chaîne de Markov & loi stationnaire π .

0 $t \leftarrow 0$

1) Pour $j=1, \dots, d$ faire

$$2) \quad \left| \begin{array}{l} X_{j,t} \sim \pi(\cdot | X_{-j,t}) \quad \text{ou} \quad X_{-j,t} = \{ X_{s,t} : s \neq j \} \end{array} \right.$$

3) Poser $X_{t+1} \leftarrow X_t$

4) Faire $t \leftarrow t+1$ et revenir à 1).

Rmq: Le taux d'acceptation de candidat est toujours $= 1$!!!

Le noyau de transition pour la j -ème composante est

$$P_j(x, y) = \pi(y_j | x_{-j}) \mathbb{1}_{\{x_{-j} = y_{-j}\}}, \quad j=1, \dots, d.$$

Exmp: Échantillonneur de Gibbs pour la loi cible $N(0, \Sigma)$ où $\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$, $-1 < \rho < 1$. (10)

$$\text{Rappel: } f(x, y) = \frac{1}{(2\pi)^{d/2}} |\Sigma|^{-1/2} \exp\left\{-\frac{1}{2} (x, y) \Sigma^{-1} \begin{pmatrix} x \\ y \end{pmatrix}\right\}$$
$$= \frac{1}{2\pi} (1-\rho^2)^{-1/2} \exp\left(-\frac{x^2 + y^2 - 2\rho xy}{2(1-\rho^2)}\right)$$

↳ à voir calcul de $f(x|y)$ et de $\exp f(y|x)$.

Modèles graphiques:

Pourquoi?? Supposer que les v.a. sont ttes ind. est clairement trop restrictif en pratique.

Essayer de considérer n'importe quelle forme de dépendance est trop ambitieux.

→ compromis

Principe: S'inspirer de l'hypothèse de dépendance Markovienne mais la "mettre" entre les variables.

Idée: Représenter les v.a. au sein d'un graphe pour lequel les noeuds représentent les v.a. et les arêtes la dépendance.

Soit $\mathcal{J} = \{1, \dots, n\}$ un ensemble fini de noeuds représentant les variables aléatoires X_1, \dots, X_n .

Notation: Pour $A \subset \mathcal{J}$, $X_A = \{X_i : i \in A\}$, $X_{-A} = \{X_i : i \notin A\}$
et $X_i = X_{\{i\}}$ et $X_{-i} = X_{\mathcal{J} \setminus \{i\}}$.

Def: On appelle système de voisinage la "collection" d'ensembles $\mathcal{N} = \{N_j : j \in \mathcal{J}\}$ où les ensembles N_j est le voisinage du noeud j .

Def: N_s est le voisinage de noeud s si $N_s \subset \gamma$ h.q. (19)

$s \notin N_s$ et $i \in N_s \Leftrightarrow s \in N_i$

\Rightarrow on appellera alors (γ, N) un modèle graphique.

Def: On appelle graphe acyclique orienté un modèle graphique représentant une structure de dépendance hiérarchique.


La dépendance de X_1 par rapport à X_2 est alors représentée par une flèche partant du noeud parent X_2 et pointant vers le noeud descendant X_1 .

On dira que X_1 est un descendant de X_3 s'il y a une "chaîne" de flèches liant X_3 à X_1 .

Req: * C'est un graphe orienté car nous avons des flèches et pas des arcs.

* C'est un graphe acyclique car on ne peut pas suivre les flèches partir de X_1 et revenir à X_1 .

Exmp: $f(\gamma) = f(X_1 | X_2, X_5) f(X_2 | X_3, X_6) f(X_3) f(X_4 | X_5) f(X_5 | X_6) f(X_6)$



Ppté (admix): Pour tout DAG on a

$$f(y) = \prod_{j \in \mathcal{Y}} f(y_j | \text{parents de } y_j)$$

En conséquence

$$f(y_i | y_{-i}) = \frac{f(y)}{\int f(y) dy_i} \propto \prod_{j \in \mathcal{Y}} f(y_j | \text{parents de } y_j)$$

$$\propto f(y_i | \text{parents de } y_i) \prod_{\substack{y_j: \text{ fils} \\ \text{de } y_i}} f(y_j | \text{parents de } y_j)$$

Exmp: Ligue 1 2014/2015

$N_{iS}^{(d)}$: nb buts équipe i devant à domicile contre équipe S .

$N_{iS}^{(e)}$: extérieur

Modèle: $N_{iS}^{(d)} \sim \text{Poisson}(d_{iS}^{(d)})$

$N_{iS}^{(e)} \sim \text{Poisson}(d_{iS}^{(e)})$

avec $d_{iS}^{(d)} = \beta_0^{(d)} + \beta_i - \beta_S \leftarrow \text{perf. eq. } S$

\uparrow effet domicile \uparrow perf. eq. i

$d_{iS}^{(e)} = \beta_0^{(e)} + \beta_S - \beta_i$

$\beta_1, \dots, \beta_{20} \stackrel{iid}{\sim} \mathcal{N}(\mu, \sigma^2)$ ← variables liées Ligue 1

\uparrow perf. moy. Ligue 1


Loi a priori

$$\beta_0^{(d)}, \beta_0^{(e)} \sim \mathcal{N}(0, 16) \leftarrow \text{très plat}$$

$$\mu \sim \mathcal{N}(0, 16) \leftarrow \text{très plat.}$$

$$\sigma^2 \sim \mathcal{U}(0, 5) \leftarrow$$

On a donc le DAG suivant



$$\begin{aligned} \pi(\beta_i | \dots) &\propto \prod_{j \neq i} \pi(N_{i,j}^{(d)} | \beta_0^{(d)}, \beta_i, \beta_j) \times \\ &\prod_{j \neq i} \pi(N_{i,j}^{(e)} | \beta_0^{(e)}, \beta_i, \beta_j) \times \\ &\pi(\beta_i | \mu, \sigma^2) \end{aligned}$$

$$\pi(\beta_i^{(d)} | \dots) \propto \prod_{j \neq i} \pi(N_{i,j}^{(d)} | \beta_i, \beta_j, \beta_0^{(d)}) \pi(\beta_i^{(d)})$$

$$\pi(\beta_i^{(e)} | \dots) \propto \prod_{j \neq i} \pi(N_{i,j}^{(e)} | \beta_i, \beta_j, \beta_0^{(e)}) \pi(\beta_i^{(e)})$$

$$\pi(\mu | \dots) \propto \prod_{i=1}^{20} \pi(\beta_i | \mu, \sigma^2) \pi(\mu)$$

$$\pi(\sigma^2 | \dots) \propto \prod_{i=1}^{20} \pi(\beta_i | \mu, \sigma^2) \pi(\sigma^2)$$

Inverse!