

Введение в Markov chain Monte Carlo

Рассмотрим выборку $\mathbf{X} = (X_1, X_2, \dots, X_n)$ из параметрического семейства распределений $\{F_\theta, \theta \in \Theta\}$. Будем предполагать, что задано некоторое априорное распределение $\pi(\theta)$ параметра θ . Один из способов построения байесовских оценок параметра θ состоит в вычислении среднего значения $\mathbf{E}(\theta|\mathbf{X})$ для апостериорного распределения параметра θ :

$$\pi(\theta|\mathbf{X}) = \frac{L(\mathbf{X}; \theta)\pi(\theta)}{\int_{\Theta} L(\mathbf{X}; \theta)\pi(\theta)d\theta},$$

которое считается известным с точностью до константы в знаменателе.

Мы выделили две основные задачи МСМС методов:

- (i) Сгенерировать выборку из распределения $\pi(\theta|\mathbf{X})$, известного с точностью до константы.
- (ii) Используя методы Монте Карло, численно оценить апостериорное среднее значение $\mathbf{E}(\theta|\mathbf{X})$.

Семинар был посвящен разбору двух классических МСМС методов: метода Метрополиса — Гастингса и метода сэмплирования по Гиббсу.

АЛГОРИТМ МЕТРОПОЛИСА — ГАСТИНГСА. Предположим, что $\pi(\theta|\mathbf{X}) \propto f(\theta)$, причем $f(\theta)$ — полностью известная функция. Рассмотрим также некоторую вспомогательную цепь Маркова с переходным ядром $g(\theta_2|\theta_1)$. Мы будем считать, что при любом $\theta_1 \in \Theta$ существуют реализуемые алгоритмы сэмплирования из условного распределения $g(\cdot|\theta_1)$.

Алгоритм 1 (Метрополиса — Гастингса).

1. Выбираем произвольное $\theta_0 \in \Theta$.
2. Для $t \geq 1$, генерируем Y_t согласно переходной плотности $g(\cdot|\theta_{t-1})$. Вычисляем «коэффициент принятия»

$$R(Y_t|\theta_{t-1}) = \frac{f(Y_t)}{f(\theta_{t-1})} \times \frac{g(\theta_{t-1}|Y_t)}{g(Y_t|\theta_{t-1})}.$$

Генерируем случайную величину U_t из равномерного на отрезке $[0, 1]$ распределения. Определяем θ_t по правилу:

$$\theta_t = \begin{cases} Y_t, & \text{если } R(Y_t|\theta_{t-1}) > U_t, \\ \theta_{t-1}, & \text{иначе.} \end{cases}$$

Мы показали, что результатом работы алгоритма Метрополиса — Гастингса является цепь Маркова θ_t с переходным ядром

$$g^*(\theta_2|\theta_1) = g(\theta_2|\theta_1) \cdot \min\{1, R(\theta_2|\theta_1)\} + \delta_{\theta_1}(\theta_2) \cdot \tilde{R}(\theta_1),$$

где $\tilde{R}(\theta_1) = \int_{\Theta} g(\theta|\theta_1)(1 - \min\{1, R(\theta|\theta_1)\})d\theta$, и $\delta_{\theta_1}(\theta)$ — дельта-функция Дирака.

Используя это представление, мы показали, что цепь $\{\theta_t\}$ удовлетворяет уравнению детального баланса:

$$\pi(\theta_1|\mathbf{X})g^*(\theta_2|\theta_1) = \pi(\theta_2|\mathbf{X})g^*(\theta_1|\theta_2) \text{ при всех } \theta_1, \theta_2 \in \Theta, \quad (1)$$

что влечет за собой тот факт, что $\pi(\theta|\mathbf{X})$ является стационарным распределением цепи $\{\theta_t\}$. Сходимость цепи к стационарному распределению гарантирует следующая теорема (которую мы привели без доказательства):

Теорема 1. Пусть

$$\mathbf{P}(R(Y_{t+1}|Z_t) \geq 1) < 1 \quad \text{и} \quad g(\theta_2|\theta_1) > 0 \text{ при всех } (\theta_1, \theta_2) \in \Theta^2.$$

Тогда

(i) Для любой функции h такой, что $\mathbf{E}(h(\theta)|\mathbf{X}) < \infty$,

$$\frac{1}{T} \sum_{t=1}^T h(\theta_t) \rightarrow \mathbf{E}(h(\theta)|\mathbf{X}) \text{ п.н. при } T \rightarrow \infty.$$

(ii) Для любых начальных данных $\theta_0 \in \Theta$,

$$d_{TV}(g^{*T}(\cdot|\theta_0) - \pi(\cdot|\mathbf{X})) \rightarrow 0 \text{ при } T \rightarrow \infty.$$

Отметим, что первое утверждение теоремы обеспечивает сходимость выборочного среднего, построенного по $\{\theta_t\}$, к апостериорному среднему $\mathbf{E}(\theta|\mathbf{X})$.

АЛГОРИТМ СЭМПЛИРОВАНИЯ ПО ГИББСУ. Предположим, что апостериорная плотность $\pi(\theta, \varphi|\mathbf{X}) \propto f(\theta, \varphi)$, где $(\theta, \varphi) \in \Theta \times \Phi$, причем функция $f(\theta, \varphi)$ такова, что полностью известны условные плотности

$$g_1(\theta|\varphi) = \frac{f(\theta, \varphi)}{f_2(\varphi)} \quad \text{и} \quad g_2(\varphi|\theta) = \frac{f(\theta, \varphi)}{f_1(\theta)}.$$

Здесь,

$$f_1(\theta) = \int_{\Phi} f(\theta, \varphi)d\varphi \quad \text{и} \quad f_2(\varphi) = \int_{\Theta} f(\theta, \varphi)d\theta.$$

По аналогии с алгоритмом Метрополиса — Гастингса, мы будем предполагать, что для $g_1(\theta|\varphi)$ и $g_2(\varphi|\theta)$ реализуемы какие-либо алгоритмы сэмплирования.

Алгоритм 2 (Сэмплирования по Гиббсу).

1. Выбираем произвольное $\theta_0 \in \Theta$. Генерируем φ_0 согласно условной плотности $g_2(\cdot | \theta_0)$.
2. Для $t \geq 1$, генерируем θ_t согласно условной плотности $g_1(\cdot | \varphi_{t-1})$ и φ_t согласно условной плотности $g_2(\cdot | \theta_t)$. Добавляем пару (θ_t, φ_t) в выборку.

На семинаре мы рассмотрели пример использования алгоритма сэмплирования по Гиббсу для моделирования двумерного нормального вектора (θ, φ) с нулевым вектором средних и ковариационной матрицей

$$\Sigma = \begin{pmatrix} 1 & r \\ r & 1 \end{pmatrix},$$

где $r \in (-1, 1)$.

Наконец, мы обсудили некоторые классические способы уменьшения погрешности оценок, построенных с использованием МСМС методов: использование интервала «разогрева», «просеивание» получающейся цепи Маркова и т.д.