

# БАЙЕСОВСКОЕ ОЦЕНИВАНИЕ ПАРАМЕТРОВ НА ОСНОВЕ ЧИСЛЕННЫХ МЕТОДОВ МОНТЕ-КАРЛО

**Лобач В. И.**

*Белорусский государственный университет ФПМИ, Минск, Беларусь,  
e-mail: lobach@bsu.by*

Машинное обучение представляет собой раздел искусственного интеллекта, который базируется на идее того, что системы могут обучаться на основе поступающих данных и знаний, выявлять закономерности, строить прогнозы и принимать решения с минимальным вмешательством человека. В последние годы все большее влияние на машинное обучение оказывает байесовский подход [1,2]. Он позволяет строить адекватные модели в условиях малых выборок, а также учитывать экспертные знания ещё до получения данных. Байесовский подход базируется на принципе объединения априорных предположений о распределении параметров рассматриваемой модели и эмпирических данных для получения апостериорного распределения вероятностей параметров рассматриваемой модели и обладает рядом преимуществ перед классическими методами. Этот подход предоставляет возможность автоматической настройки структурных параметров алгоритмов машинного обучения, обеспечивает корректную работу с данными, достоверность которых установлена не точно.

Рассмотрим вероятностное распределение  $p(X)$  (плотность распределения вероятностей одномерной или многомерной случайной величины). Метод Монте-Карло предполагает генерацию выборки из этого распределения

$$X_1, X_2, \dots, X_N \sim p(X).$$

Данная выборка может быть использована для оценки вероятностных интегралов вида

$$E\{f(X)\} = \int_{-\infty}^{\infty} f(X) p(X) dX \approx \frac{1}{N} \sum_{i=1}^N f(X_i), \quad (1)$$

где  $f(X)$  – некоторая известная функция от  $X$ . К интегралам такого вида сводятся многие шаги при осуществлении байесовского подхода в исследовании вероятностных моделей. Например, такими интегралами являются функционал  $E(\ln(p(X, T/\theta)))$  на М – шаге ЕМ – алгоритма, байесовская оценка неизвестного параметра  $\theta$  вероятностного распределения

$$E(\theta / X) = \int_{-\infty}^{\infty} \theta p(\theta / X) d\theta$$

(условное математическое ожидание, которое является оптимальной в среднеквадратическом смысле оценкой параметра  $\theta$ ) и т.д.

Байесовский подход в статистическом анализе основывается на теореме Байеса. Пусть  $\theta$  – вектор параметров модели, а  $X$  – имеющийся набор данных. Через  $p(\theta)$  обозначим априорное распределение параметра  $\theta$  (априорная информация о параметрах, то есть информация, полученная до проведения эксперимента). В процессе наблюдений эта информация постепенно уточняется. Ставится задача

оценивания неизвестного значения величины  $\theta$ , наблюдая ее косвенные характеристики, после чего для решения проблемы прогнозирования применяются прогнозирующие статистики на основе подстановочного принципа (вместо неизвестного параметра  $\theta$  используются его оценки). Априорное распределение вероятностей пересматривается на основе существующей реализации временного ряда  $X$  для получения апостериорной плотности распределения вероятностей  $p(\theta/X)$ . По формуле Байеса устанавливается связь между  $p(\theta/X)$ ,  $p(X/\theta)$ ,  $p(\theta)$

$$p(\theta / X) = \frac{p(X / \theta) p(\theta)}{p(X)} = \frac{p(X / \theta) p(\theta)}{\int_{-\infty}^{\infty} p(X / \theta) p(\theta) d\theta}.$$

Учитывая, что знаменатель в этой формуле не зависит от  $\theta$ , указанную выше взаимосвязь представляют в виде

$$p(\theta / X) \sim p(X / \theta) p(\theta) = \tilde{p}(X / \theta),$$

где  $\sim$  означает пропорциональность.

До конца 80-х годов прошлого века для построения байесовских оценок параметров на основе апостериорных распределений в качестве вычислительных методов использовали аналитические методы, такие как сопряжённые апостериорные распределения и т.д. Но в результате стремительного развития информационных технологий с конца 90-х годов 20 века начали распространяться новые методы, которые базируются на непосредственном моделировании выборки из апостериорных распределений. Одним из подходов к моделированию является моделирование по принципу Монте-Карло. Среди методов Монте-Карло в свою очередь выделяют итерационные методы Монте-Карло, которые базируются на основе построения Марковских цепей. К таким методам относится генерирование выборки по Гиббсу [5,6], алгоритм Метрополиса, Метрополиса – Гастингса [3, 4]. Основой моделирования выборки с помощью МСМС – метода служит построение Марковского процесса, для которого стационарное распределение переходов определяется функцией  $p(\theta/X)$ . Приведем общую схему МСМС – метода. Рассматривается вопрос о генерации случайной выборки -из многомерного распределения с плотностью в общем виде  $p(T)$  в многомерном пространстве с помощью методов Монте – Карло по схеме Марковских цепей (МСМС). В этих методах вводится некоторая цепь Маркова с априорным распределением  $p_0(T)$  и вероятностями переходов  $q_n(T_{n+1}/T_n)$  генерация выборки осуществляется следующим образом:

$$T_1 \sim p_0(T), \quad T_2 \sim q_1(T_2 / T_1), \quad T_N \sim q_{N-1}(T_{N-1} / T_N). \quad (2)$$

Заметим, что сгенерированная таким образом выборка не является совокупностью независимых случайных величин. Однако, она подходит для оценки вероятностных интегралов вида (1). Часто берут однородную цепь Маркова, когда вероятность перехода  $q_n(T_n/T_{n-1})$  не зависит от момента времени  $n$ , т.е.  $q_n(T_n/T_{n-1}) = q(T_n/T_{n-1})$ . Основн<sub>ый</sub> вопрос, как выбрать вероятности перехода  $q(T_n/T_{n-1})$ , чтобы выборка, сгенерированная по схеме (2), была выборкой из распределения  $p(T)$ . Один из вариантов выбора  $q(T_n/T_{n-1})$  дается алгоритмом Метрополиса-Гастингса.

Он состоит в следующем. Пусть на шаге  $n$  сгенерировано значение  $T_n$ , тогда на шаге  $n+1$  генерируется точка  $T^*$  из некоторого предложенного распределения  $g(T/T_n)$  (например, нормального). Затем вычисляется величина

$$\alpha(T^*, T_n) = \min \left( 1, \frac{\tilde{p}(T^*)r(T_n / T^*)}{\tilde{p}(T_n)r(T^* / T_n)} \right).$$

Точка  $T^*$  принимается в качестве следующей точки  $T_{n+1}$  с вероятностью  $\alpha(T^*, T_n)$ . С вероятностью  $1 - \alpha(T^*, T_n)$  принимается  $T_{n+1} = T_n$ . Таким образом, определена цепь Маркова с вероятностью перехода

$$q(T_{n+1} / T_n) = \begin{cases} r(T_{n+1} / T_n) \alpha(T_{n+1}, T_n), & \text{если } T_{n+1} \neq T_n, \\ 1 - r(T_{n+1} / T_n) \alpha(T_{n+1}, T_n), & \text{если } T_{n+1} = T_n. \end{cases}$$

Алгоритм стартует из некоторого случайного значения  $T_0$  и несколько первых итераций игнорируются для того, чтобы забыть о начальном значении. Алгоритм работает лучше всего, когда вспомогательная функция  $r(T_{n+1}/T_n)$  близка к форме целевой функции  $p(T)$ .

В данной работе на основе байесовского подхода в машинном обучении рассмотрена задача оценивания параметров временных рядов, которая сводится к нахождению условных математических ожиданий. Условные математические ожидания являются оптимальными в среднеквадратическом смысле оценки. Численная реализация условных математических ожиданий сводится к вычислению многомерных интегралов, для вычисления которых используется *MCMC* – метод. На основе алгоритма Метрополиса-Гастингса построены цепи Маркова, которые использованы для приближенного вычисления условного математического ожидания *MCMC* – методом. Проведены компьютерные эксперименты, показывающие эффективность предлагаемого алгоритма оценивания.

#### Литература

1. Harrison, B. Deep Learning and Bayesian Methods /B Hamson // The European Physical Journal Conferences. - 2017. P 52 – 61.
2. Jun, Zhu. Learning with Bayesian Methods /Jun Zhu, Jianfei Chen, Wenbo Hu Big, Bo Zhang. 2017. Learning with Bayesian Methods. // National Science Review 2010. - P. 133 - 157.
3. Geweke, J. 2012. Bayesian estimation of state-space models using M-H algorithm and Gibbs sampling. //J. Geweke //Comput. Statistics and Data Analysis. 2012. - №2. P. 117– 130.
4. Gholami, G.H. Fundamental Concepts of MCMC Methods Proved on Metropolis-Hastings Algorithm. / G.H. Gholami, A. Etemadi, E. Fayyazi. // International Journal of advanced research in Computer Science. 2012. - №2. P. 114– 172.
5. Geman, S. 1984. Stochastic Relaxation, Gibbs Distribution, and Bayesian Restoration of Images. / S. Geman // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1984. - №6. – P. 721 – 741.
6. Barber, D. Bayesian reasoning and machine learning. Cambridge University Press. /D. Barber. 2019. - 666 p.