

Секция «Математика и механика»

Скорость сходимости оценки регрессионной функции, построенной по модифицированному методу ближайшего соседа

Хапланов Арсений Юрьевич

Аспирант

Московский государственный университет имени М.В. Ломоносова,

Механико-математический факультет, Москва, Россия

E-mail: kharlanova@gmail.com

Для построения оценки регрессионной функции в [1] использован метод ближайшего соседа в сочетании с равномерным усреднением. Полученная оценка оказалась состоятельной. Нас интересует среднеквадратичное отклонение упомянутой оценки от регрессионной функции.

Предположим, что имеется последовательность независимых одинаково распределенных векторов $(X, Y), (X_1, Y_1), \dots$ со значениями в $\mathbb{R}^d \times \mathbb{R}$. Пусть дана реализация $(x_i, y_i), i = 1, \dots, n$. Из набора (x_1, \dots, x_n) выбираем без возвращения k_n элементов и проделываем это независимым образом l_n раз. Для каждой выборки ищется ближайшая к x в евклидовой метрике точка x_{i_j} ($j = 1, \dots, l_n$). Оценка регрессионной функции $r(x) = \mathbb{E}(Y|X = x)$, где $x \in \mathbb{R}^d$, задается формулой

$$r_n(x) = \frac{1}{l_n} \sum_{j=1}^{l_n} Y_{i_j}.$$

Будем обозначать условную дисперсию $\sigma^2(x) = \text{var}(Y | X = x)$.

Теорема. Пусть существуют положительные константы σ, C, M, α , для которых $P(\|X\| > t) \leq e^{-\alpha t}$ при всех $t \geq M$, а также для любых $x, x' \in \mathbb{R}^d$

$$\sigma^2(x) \leq \sigma^2, |r(x) - r(x')| \leq C \|x - x'\|,$$

где $\|\cdot\|$ – евклидова норма. Тогда найдется константа $R > 0$, зависящая только от α и M , такая, что верно неравенство

$$\mathbb{E}([r_n(X) - r(X)]^2) \leq \sigma^2 \left[\frac{1}{l_n} + \left(1 - \frac{1}{l_n}\right) \frac{k_n}{n} \frac{1}{(1 - k_n/n + 1/n)^2} \right] + 4RC^2(\ln k_n)^3 f_d(n).$$

Здесь $f_1(n) = 2k_n^{-1/2}$, $f_2(n) = \sqrt{2(1 + \ln k_n)k_n^{-1/2}}$, $f_d(n) = \sqrt{\frac{2}{1-2/d}} k_n^{-1/d}$, если $d \geq 3$.

Заметим, что в отличие от [2] не предполагается ограниченность нормы вектора X .

Литература

1. Biau G. On the layered nearest neighbour estimate, the bagged nearest neighbour estimate and the random forest method in regression and classification // J. Multivariate Analysis. 2010. No. 101. С. 2499–2518.
2. Biau G. On the rate of convergence of the bagged nearest neighbor estimate // J. Machine Learning Research. 2010. No. 11. P. 687-712.