

Секция «Математика и механика»

Скорость сходимости оценки параметров многомерной логистической регрессии

Хапланов Арсений Юрьевич

Аспирант

Московский государственный университет имени М.В. Ломоносова,

Механико-математический факультет, Москва, Россия

E-mail: kharlanova@gmail.com

Логистическая регрессия часто используется в машинном обучении для решения проблем классификации. Предполагается, что бинарная случайная величина  $Y$  определенным образом зависит от факторов  $X_1, \dots, X_p$ , принимающих действительные значения. Нас будет интересовать обобщение модели, предложенной в [1]. А именно, пусть для каждого  $n \in \mathbb{N}$  величина  $Y = Y(n)$  отображает пространство элементарных исходов  $\Omega$  в множество  $\{0, 1, \dots, k\}$ , а  $X = X(n)$  — случайный вектор со значениями в  $\mathbb{R}^{p_n}$ . Пусть для  $j \in \{1, \dots, k\}$  и  $x \in \mathbb{R}^{p_n}$  справедливы соотношения:

$$\mathbb{P}(Y(n) = j | X(n) = x) := \pi_j(\alpha^{0,n}, x) = \frac{\exp\{-(\alpha_j^{0,n})^T x\}}{1 + \sum_{t=1}^k \exp\{-(\alpha_t^{0,n})^T x\}},$$

$$\mathbb{P}(Y(n) = 0 | X(n) = x) = 1 - \sum_{j=1}^k \pi_j(\alpha^{0,n}, x),$$

где  $T$  обозначает транспонирование, неслучайные векторы  $\alpha_j^{0,n} \in \mathbb{R}^{p_n}$ . По независимым наблюдениям векторов  $(X_q(n)^T, Y_q(n))^T$ ,  $q = 1, \dots, n$ , имеющих такое же распределение, как  $(X(n)^T, Y(n))^T$ , должным образом строится оценка  $\hat{\alpha}_n$  вектора  $\alpha^{0,n} = \{(\alpha_1^{0,n})^T, \dots, (\alpha_k^{0,n})^T\}^T$ . Положим  $R_n(\alpha) = \{(R_n(\alpha)^1)^T, \dots, (R_n(\alpha)^k)^T\}^T$ , где  $R_n(\alpha)^r = (\{\sum_{q=1}^n [\mathbb{I}\{Y_q(n) = r\} - \pi_r(\alpha, X_q(n))] X_q^l(n)\}_{l=1}^{p_n})^T$ ,  $\alpha \in \mathbb{R}^{kp_n}$ . Приведем наш основной результат, обобщающий работу [2], в которой рассматривался случай  $k = 1$ .

**Теорема.** Пусть  $p_n^3/n \rightarrow 0$  при  $n \rightarrow \infty$ . Предположим, что существуют константы  $L, c > 0$  такие, что для любого  $n \in \mathbb{N}$  норма  $X(n)$  ограничена константой  $L$  с вероятностью единица, и все собственные значения ковариационной матрицы вектора  $R_n(\alpha^{0,n})/\sqrt{n}$  лежат в полуинтервале  $[c, \infty)$ . Тогда для любой последовательности  $\delta_n > 0$ , удовлетворяющей условиям  $\delta_n p_n / \sqrt{n} \rightarrow 0$ ,  $\sqrt{p_n} / \delta_n \rightarrow 0$  при  $n \rightarrow \infty$ , выполняется предельное соотношение

$$\mathbb{P}(\|\alpha^{0,n} - \hat{\alpha}_n\| \geq \delta_n / \sqrt{n}) \rightarrow 0, n \rightarrow \infty.$$

Литература

1. A. Albert, J. Anderson. On the existence of maximum likelihood estimates in logistic regression models // *Biometrika*. 1984. vol. 71. No. 1. с.1-10.
2. Hua Liang, Pang Du. Maximum likelihood estimation in logistic regression models with a diverging number of covariates // *Electronic J. of Statist.* 2012. vol. 6. с. 1838-1846.