

О ПРИМЕНИМОСТИ РОБАСТНОГО ПОСЛЕДОВАТЕЛЬНОГО РАЗЛИЧЕНИЯ ДИСКРЕТНЫХ РАСПРЕДЕЛЕНИЙ ВЕРОЯТНОСТЕЙ ПРИ НАЛИЧИИ ИСКАЖЕНИЙ

А. Ю. Харин

*Белорусский государственный университет
г. Минск, Беларусь
E-mail: KharinAY@bsu.by*

Рассматривается задача построения робастного (устойчивого) последовательного теста для различения двух дискретных распределений вероятностей по наблюдаемой выборке. В недавних работах автора такой тест построен для вероятностных распределений из специального класса. Результаты, представленные в данной работе, позволяют аппроксимировать произвольное дискретное распределение вероятностей с конечным множеством значений распределением из указанного класса.

Ключевые слова: последовательный анализ, искажения, робастность.

ВВЕДЕНИЕ. МАТЕМАТИЧЕСКАЯ МОДЕЛЬ

Последовательный подход [1] используется в решении прикладных задач, где требуется различение дискретных распределений вероятностей, которыми характеризуется наблюдаемая последовательность. Такие задачи имеют место в генетике [2], в экономике, при контроле за качеством выпускаемой продукции, и в других областях. Теоретически последовательный тест Вальда [1] при решении таких задач обладает оптимальным свойством: он минимизирует среднее число необходимых наблюдений для обеспечения заданных значений вероятностей ошибок первого и второго рода. Однако на практике модельные предположения часто искажены [3], и поэтому указанное свойство теряется. В связи с этим возникает необходимость в исследовании робастности (устойчивости) к заданным типам искажений тестов, оптимальных в рамках гипотетических предположений, а также в построении робастных тестов [4]. Для специальной модели дискретных данных эти две задачи решены в [5], когда искажения описываются моделью «выбросов» Тьюки – Хьюбера [3].

В данной работе получено обобщение результатов [5] на случай произвольных дискретных вероятностных распределений с конечным множеством значений.

Пусть наблюдается последовательность независимых одинаково распределенных случайных величин $x_1, x_2, \dots, x_t \in U = \{1, \dots, M\}$, $t \in N$, из одного из двух гипотетических распределений вероятностей:

$$P^{(k)}\{x_t = u\} = p_u, u \in U, p_1^{(k)} + \dots + p_M^{(k)} = 1, k = 0, 1. \quad (1)$$

Без ограничения общности предположим, что $0 \leq p_1^{(k)} \leq \dots \leq p_M^{(k)} < 1$.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ

Л е м м а 1. Пусть $\delta \in [0,1)$, $a = 1 - \delta$. Тогда

$$\exists l_1, \dots, l_M \in N \cup \{+\infty\}, 1 \leq l_M \leq \dots \leq l_1 \leq +\infty, \quad (2)$$

такие что выполняются соотношения

$$\left| p_u - a^{l_u} \right| \leq \delta, u \in U; \quad (3)$$

$$\left| \sum_{u \in U} a^{l_u} - 1 \right| \leq M\delta. \quad (4)$$

Доказательство. Докажем вначале (3).

$$\begin{aligned} \left| p_u - a^{l_u} \right| &\leq \max \left\{ a^{l_u - 1} - a^{l_u}, a^{l_u} - a^{l_u + 1} \right\} = \max \left\{ a^{l_u - 1} (1 - a), a^{l_u} (1 - a) \right\} = \\ &= \delta \cdot a^{l_u - 1} \leq \delta. \end{aligned}$$

Теперь докажем (4).

$$\left| \sum_{u \in U} a^{l_u} - 1 \right| \leq \sum_{u \in U} \left| a^{l_u} - p_u \right| \leq \delta \sum_{u \in U} a^{l_u - 1} \leq M\delta.$$

Таким образом, лемма 1 доказана.

Л е м м а 2. Пусть в условиях леммы 1 $\delta \in [0, \frac{1}{2})$. Тогда для набора (2), удовлетворяющего (3), справедливы следующие неравенства:

$$1 - \delta \leq \sum_{u \in U} a^{l_u} \leq \frac{1 - \delta}{1 - 2\delta}. \quad (5)$$

Доказательство. При доказательстве второго утверждения леммы 1 получено неравенство:

$$a \cdot |s - 1| \leq \delta \cdot s, s = \sum_{u \in U} a^{l_u}.$$

Рассмотрим теперь два случая.

1) $s \geq 1$. Тогда

$$a \cdot s - a \leq \delta \cdot s, s \cdot (a - \delta) \leq a, s \leq \frac{1 - \delta}{1 - 2\delta}.$$

2) $s < 1$. В этом случае

$$a - a \cdot s \leq \delta \cdot s, a \leq (\delta + a) \cdot s, s \geq a = 1 - \delta.$$

Объединяя полученные результаты, получаем (5). Таким образом, лемма 2 доказана.

Замечание. Второе утверждение леммы 1 может быть усилено:

$$\left| \sum_{u \in U} a^{l_u} - 1 \right| \leq \frac{\delta}{1 - \delta} (1 + M\delta).$$

В самом деле, из доказательства леммы 1:

$$\left| \sum_{u \in U} a^{l_u} - 1 \right| \leq \delta \cdot \sum_{u \in U} a^{l_u - 1} = \frac{\delta}{a} \cdot \sum_{u \in U} a^{l_u} \leq \\ \leq \frac{\delta}{a} \cdot \sum_{u \in U} (p_u + \delta) = \frac{\delta}{1 - \delta} \cdot (1 + M\delta),$$

так как в силу (3)

$$p_u - \delta \leq a^{l_u} \leq p_u + \delta, \quad \sum_{u \in U} p_u = 1.$$

Таким образом, с использованием лемм 1, 2 и замечания, для двух произвольных дискретных распределений вероятностей с конечным числом состояний с любой наперед заданной точностью можно построить минимаксный робастный последовательный тест [5] для их различения.

ЛИТЕРАТУРА

1. Вальд А. Последовательный анализ. М., 1960.
2. Waterman M. S. Mathematical methods for DNA sequences. Boca Raton: CRC Press, 1989.
3. Хьюбер П. Робастность в статистике. М., 1984.
4. Kharin A. Robustness of sequential testing of hypotheses on parameters of Markov chains // International Conference on Robust Statistics. Antwerp: University of Antwerp. 2003. P. 64–65.
5. Kharin A. On robustifying of the sequential probability ratio test for a discrete model under contaminations // Austrian Journal of Statistics. 2002. Vol. 31. № 4. P. 267–277.