

Некоторые свойства статистического теста «Book Stack»

Бзикадзе Андрей Важевич, гр. 422

Санкт-Петербургский государственный университет
Математико-механический факультет
Кафедра статистического моделирования

Научный руководитель: к.ф.-м.н., доц. В.В Некруткин
Рецензент: к.ф.-м.н., доц. А.И. Коробейников



Санкт-Петербург
2015г.

- $\mathcal{A} = \{a_1, \dots, a_S\}$ — множество «книг»;
- Стопка «книг»;
- Начальный порядок;
- Из стопки случайная книга перекалывается наверх;
- $\{\eta_i\}_{i=1}^{\infty}$ — последовательность названий случайных книг;
- $\{\xi_i\}_{i=1}^{\infty}$ — последовательность положений случайных книг.


$$S = 5$$

$$\begin{aligned} i &= 1 \\ \eta_i &= 4 \\ \xi_i &= 2 \end{aligned}$$

$$\begin{aligned} i &= 2 \\ \eta_i &= 4 \\ \xi_i &= 1 \end{aligned}$$

$$\begin{aligned} i &= 3 \\ \eta_i &= 2 \\ \xi_i &= 5 \end{aligned}$$

$$i = 4$$



Применение «Book Stack»-преобразования:

- Рябко Б.Я. (1980): алгоритм сжатия данных под названием «метод стопки книг»;
- Bentley J.L., Sleator D.D., Tarjan R.E., Wei V.K. (1986): тот же алгоритм под названием «Move To Front»;
- Рябко Б.Я., Монарев В.А., Пестунов А.И., Шокин Ю.И., Стогниенко В.С. (2003–2004): тест для проверки свойств генераторов случайных чисел под названием «Book Stack».

Равносильны:

- $H_0 : \eta_i$ независимы и равномерно распределены на $\{1, 2, \dots, S\}$;
- $H_0^* : \xi_i$ независимы и равномерно распределены на $\{1, 2, \dots, S\}$.

Два теста:

- χ^2 -тест к исходной выборке;
- χ^2 -тест к преобразованной выборке.

Против каких альтернатив критерий «после» Book Stack будет более мощным, чем этот же критерий «до»?

Равносильны:

- $H_0 : \eta_i$ независимы и равномерно распределены на $\{1, 2, \dots, S\}$;
- $H_0^* : \xi_i$ независимы и равномерно распределены на $\{1, 2, \dots, S\}$.

Два теста:

- χ^2 -тест к исходной выборке;
- χ^2 -тест к преобразованной выборке.

Против каких альтернатив критерий «после» Book Stack будет более мощным, чем этот же критерий «до»?

Альтернатива: $H_1 : \{\eta_i\}$ — независимы и одинаково, но не равномерно, распределены.

Моделирование:

- Заданное дискретное распределение на $\{1, 2, \dots, S\}$;
- Вихрь Мерсенна;
- n — размер выборки, m — количество выборок;
- Критерий χ^2 с $S - 1$ степенью свободы: m штук P -значений.

Цель:

- Сравнение мощности критерия χ^2 «до» и «после» преобразования «Book Stack».

Обозначим: $p_k = \mathbb{P}(\eta_i = k) > 0$ для $k = 1, 2, \dots, S$.

Параметры: $S = 10$, $n = 10^4$, $m = 100$, $p_1 = 0.11$, $p_i = 0.099$.




Рис. : Мощность критерия χ^2 до «Book Stack».
 P -значение = $4.4 \cdot 10^{-16}$.





Рис. : Мощность критерия χ^2 после «Book Stack».
 P -значение = 0.903.

Предложение

Пусть $\{\eta_i\}_{i \geq 1}$ — независимы и одинаково распределены на множестве $\{1, 2, \dots, S\}$. Тогда последовательность состояний всей стопки — эргодическая однородная марковская цепь.




- Начальный порядок: $\Xi_0 = (3, 4, 1, 5, 2)^T$;
- $\Xi_1 = \Xi_2 = (4, 3, 1, 5, 2)^T$;
- $\Xi_3 = (2, 4, 3, 1, 5)^T$.

Начальный порядок книг — начальное распределение

Предложение

Пусть $\{\eta_i\}_{i \geq 1}$ — независимы и одинаково распределены на множестве $\{1, 2, \dots, S\}$. Тогда последовательность состояний всей стопки — эргодическая однородная марковская цепь.



- Начальный порядок: $\Xi_0 = (3, 4, 1, 5, 2)^T$;
- $\Xi_1 = \Xi_2 = (4, 3, 1, 5, 2)^T$;
- $\Xi_3 = (2, 4, 3, 1, 5)^T$.

Начальный порядок книг — начальное распределение.

Предложение

Фиксируем $S \in \mathbb{N}$. **Стационарное распределение ОМЦ** преобразования «Book Stack» задается следующим вектором-строкой:

$$\pi_S = (\pi_{1,2,\dots,S}, \pi_{1,2,\dots,S,S-1}, \dots, \pi_{S,S-1,\dots,1}) \in \mathbb{R}^{S!},$$

$$\text{где } \pi_{i_1, i_2, \dots, i_S} = \frac{\prod_{k=1}^{S-1} p_{i_k}}{\prod_{k=1}^{S-2} \left(1 - \sum_{j=1}^k p_{i_j} \right)}.$$

Предложение

Пусть начальное распределение полки $\{\Xi_i\}_{i \geq 0}$ — стационарное распределение $(\pi_{1,2,\dots,S}, \dots, \pi_{S,S-1,\dots,1})$.

Тогда

- 1 последовательность $\{\xi_i\}_{i \geq 1}$ является **стационарной** «в узком смысле»;
- 2 для любого $j \in 1 : S$

$$s_j \stackrel{\text{def}}{=} \mathbb{P}(\xi_i = j) = \sum_{k=1}^S p_k \sum_{\substack{\alpha \in \mathfrak{S}_S \\ \alpha_j = k}} \pi_\alpha,$$

где \mathfrak{S}_S — множество перестановок порядка S .

Теорема

Пусть $\xi_1, \dots, \xi_n, \dots$ — последовательность положений случайных книг. Обозначим

$$\tau_k = \tau_k(n) = \mathbb{I}_k(\xi_1) + \dots + \mathbb{I}_k(\xi_n),$$

где \mathbb{I}_A — индикатор множества A и $1 \leq k \leq S$. Тогда

$$\mathbb{E} \left(\frac{\tau_k}{n} - s_k \right)^2 = O(1/n).$$

Сходимость по вероятности сохраняется и при группировке, то есть при разбиении $\{1, 2, \dots, S\}$ на дизъюнктные подмножества.

Теорема

Пусть $\{\eta_i\}$ независимы и одинаково распределены с распределением, задаваемым набором вероятностей $\{p_i\}_{i=1}^S$, где $\max_i p_i > \min_i p_i > 0$. Тогда

$$\sum_{i=1}^S (p_i - 1/S)^2 \geq \sum_{i=1}^S (s_i - 1/S)^2.$$

При $n \rightarrow \infty$ статистика χ^2 после «Book Stack» не больше, чем до преобразования.

Аналогичное «выравнивание» имеет место для энтропии и расстояния по вариации.

Параметр $S = 8$, $n = m = 10^3$, $p_1 = 0.165$, $p_i = 0.119$.

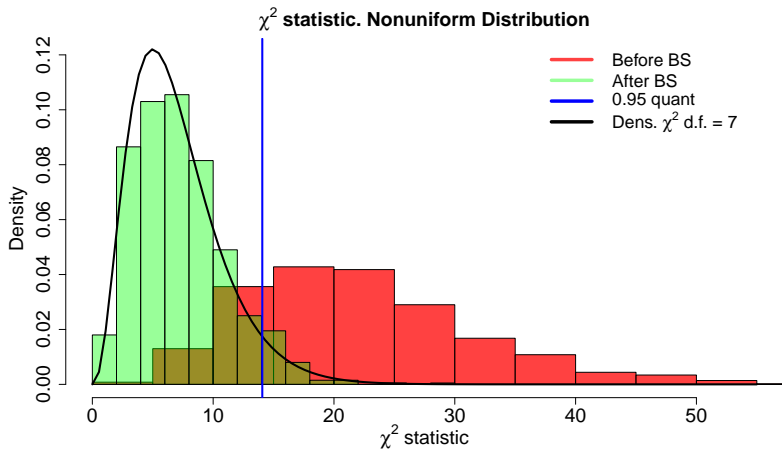


Рис. : Гистограмма распределения статистики критерия χ^2 до и после «Book Stack». Теоретическое значение 0.95 квантили — 14.07.

Параметры: $S = 8$, $n = m = 10^3$, $p_1 = 0.25$, $p_i = 0.107$.

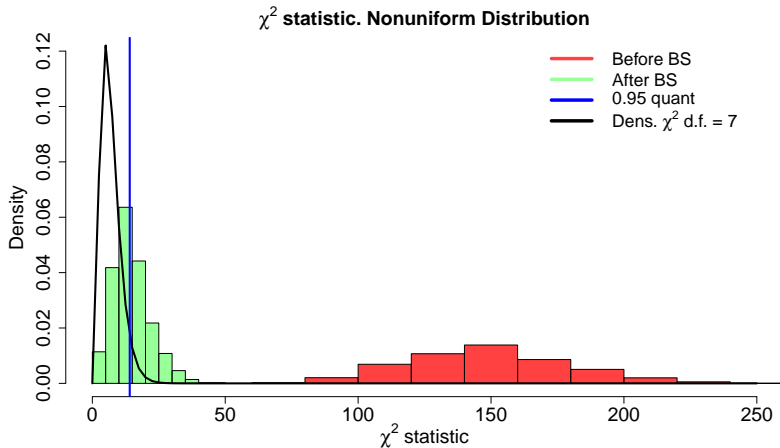


Рис. : Гистограммы распределения статистики критерия χ^2 до и после «Book Stack». Теоретическое значение 0.95-квантили — 14.07.

Итог:

Если рассматривать в качестве альтернативы независимые и одинаково, но не равномерно, распределенные случайные величины η_i , то при больших объемах выборки

- Критерий χ^2 к ξ_i не мощнее, чем к η_i .

Другая альтернатива:

- $H_1 : \{\eta_i\}$ — конечная однородная марковская цепь со стационарным равномерным распределением на множестве $\{1, 2, \dots, S\}$.

Только вычислительные эксперименты.

Модель марковской цепи:

- Задано: $p < 1$;
- Матрица переходных вероятностей: $\mathbf{P} = (p_{ij})$, где $p_{ii} = p$ и $p_{ij} = (1 - p)/(S - 1)$ при $i \neq j$.

Статистические тесты:

- Критерий χ^2 для исходной марковской цепи $\{\eta_i\}$;
- Критерий χ^2 для $\{\xi_i\}$;
- Двумерный критерий χ^2 для $\{(\eta_i, \eta_{i+1})^T\}$ (i — нечетное);
- Двумерный критерий χ^2 для $\{(\xi_i, \xi_{i+1})^T\}$ (i — нечетное).

Параметры: $S = 8$, $n = 10^4$, $p = 1/S + 0.01$, $m = 10^3$.

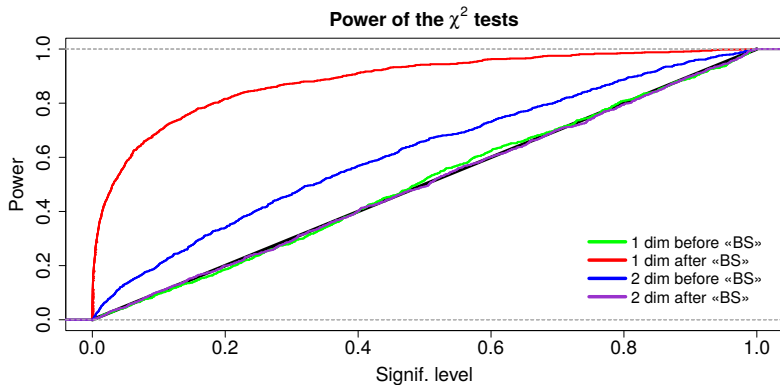


Рис. : Мощности одномерного/двумерного критериев χ^2 до/после «Book Stack».

- Если рассматривать в качестве альтернативы независимые и одинаково, но **не равномерно**, распределенные случайные величины η_i , то применение «Book Stack»-теста **не является оправданным**.
- **Перспективным** представляется изучение «Book Stack»-теста для альтернатив, связанных с **зависимостью** η_i .