
ТЕОРИЯ ВЕРОЯТНОСТЕЙ И МАТЕМАТИЧЕСКАЯ СТАТИСТИКА

PROBABILITY THEORY AND MATHEMATICAL STATISTICS

УДК 519.237.4

АСИМПТОТИЧЕСКИЙ АНАЛИЗ СТАТИСТИЧЕСКИХ ОЦЕНОК ЭНТРОПИИ ШЕННОНА ДВОИЧНЫХ s -ГРАММ

В. Ю. ПАЛУХА^{1), 2)}, Ю. С. ХАРИН^{1), 2)}

¹⁾Научно-исследовательский институт прикладных проблем математики и информатики БГУ,
пр. Независимости, 4, 220030, г. Минск, Беларусь

²⁾Белорусский государственный университет, пр. Независимости, 4, 220030, г. Минск, Беларусь

Аннотация. Найдены асимптотическое распределение вероятностей статистической оценки энтропии Шеннона s -грамм $\hat{H}(s)$ и асимптотическое совместное распределение вероятностей статистических оценок энтропии Шеннона s - и $(s+1)$ -грамм $\hat{H}(s)$, $\hat{H}(s+1)$ для равномерно распределенной случайной двоичной последовательности при ее растущей длине. Доказано, что с ростом значения s коэффициент корреляции статистических оценок энтропии Шеннона s - и $(s+1)$ -грамм $\hat{H}(s)$, $\hat{H}(s+1)$ стремится к нулю. Теоретические результаты проиллюстрированы компьютерными экспериментами.

Образец цитирования:

Палуха ВЮ, Харин ЮС. Асимптотический анализ статистических оценок энтропии Шеннона двоичных s -грамм. *Журнал Белорусского государственного университета. Математика. Информатика.* 2025;2:62–74.

EDN: FEJGGY

For citation:

Palukha UYu, Kharin YuS. Asymptotic analysis of the statistical estimators of Shannon entropy of binary s -tuples. *Journal of the Belarusian State University. Mathematics and Informatics.* 2025;2:62–74. Russian.

EDN: FEJGGY

Авторы:

Владимир Юрьевич Палуха – кандидат физико-математических наук, доцент; заведующий научно-исследовательской лабораторией математических методов защиты информации, ученый секретарь¹⁾, доцент кафедры математического моделирования и анализа данных факультета прикладной математики и информатики²⁾.

Юрий Семенович Харин – доктор физико-математических наук, академик НАН Беларуси, профессор; директор¹⁾, профессор кафедры математического моделирования и анализа данных факультета прикладной математики и информатики²⁾.

Authors:

Uladzimir Yu. Palukha, PhD (physics and mathematics), docent; head of the research laboratory of mathematical methods of information security, scientific secretary^a and associate professor at the department of mathematical modelling and data analysis, faculty of applied mathematics and computer science^b.

palukha@bsu.by

<https://orcid.org/0009-0007-8474-1146>

Yuriy S. Kharin, doctor of science (physics and mathematics), academician of the National Academy of Sciences of Belarus, full professor; director^a and professor at the department of mathematical modelling and data analysis, faculty of applied mathematics and computer science^b.

kharin@bsu.by

<https://orcid.org/0000-0003-4226-2546>

Ключевые слова: энтропия Шеннона; двоичная последовательность; статистическая оценка; ковариация; коэффициент корреляции.

Благодарность. Авторы выражают признательность Н. С. Тегаке за помощь в проведении компьютерных экспериментов.

ASYMPTOTIC ANALYSIS OF THE STATISTICAL ESTIMATORS OF SHANNON ENTROPY OF BINARY s -TUPLES

U. Yu. PALUKHA^{a, b}, Yu. S. KHARIN^{a, b}

^aResearch Institute for Applied Problems of Mathematics and Informatics, Belarusian State University,

4 Nizeliezhnasci Avenue, Minsk 220030, Belarus

^bBelarusian State University, 4 Nizeliezhnasci Avenue, Minsk 220030, Belarus

Corresponding author: U. Yu. Palukha (palukha@bsu.by)

Abstract. The asymptotic probability distribution of the statistical estimate of Shannon entropy of s -tuples $\hat{H}(s)$ and the asymptotic joint probability distribution of the statistical estimates of Shannon entropy of s - and $(s+1)$ -tuples $\hat{H}(s)$, $\hat{H}(s+1)$ for a uniformly distributed random binary sequence with increasing length are found. It is proved that as the value of s increase, the correlation coefficient of the statistical estimates of Shannon entropy of s - and $(s+1)$ -tuples $\hat{H}(s)$, $\hat{H}(s+1)$ tends to zero. The theoretical results are illustrated by computer experiments.

Keywords: Shannon entropy; binary sequence; statistical estimator; covariance; correlation coefficient.

Acknowledgements. The authors are grateful to M. S. Tegaka for assistance in performing computer experiments.

Введение

Генераторы случайных и псевдослучайных последовательностей являются неотъемлемой частью систем защиты информации. Необходимым условием для данных генераторов выступает соответствие последовательностей, порождаемых ими, модели равномерно распределенной случайной последовательности¹. Одним из методов оценки качества генераторов является энтропийный анализ их выходных последовательностей [1]. Наблюдаемая двоичная последовательность разбивается на непересекающиеся фрагменты длины s (s -граммы), по ним вычисляется статистическая оценка энтропии Шеннона $\hat{H}(s)$. В работе находятся асимптотическое (при увеличении длины двоичной последовательности) распределение вероятностей $\hat{H}(s)$ и асимптотическое совместное распределение вероятностей $\hat{H}(s)$, $\hat{H}(s+1)$. Доказывается, что с ростом значения s коэффициент корреляции статистических оценок энтропии Шеннона стремится к нулю. Теоретические результаты иллюстрируются компьютерными экспериментами.

Материалы и методы исследования

Пусть имеется двоичная последовательность длины $T = Ms(s+1)$. Тогда ее можно разбить на $M(s+1)$ непересекающихся s -грамм и Ms непересекающихся $(s+1)$ -грамм. Частотные оценки вероятностей s -грамм $\langle X_j \rangle$ и $(s+1)$ -грамм $\langle X'_l \rangle$ определяются соотношениями

$$\begin{aligned} \hat{p}_i(s) &= \frac{1}{M(s+1)} \sum_{j=1}^{M(s+1)} I\{\langle X_j \rangle = i\} = \frac{v_i}{Ms}, \quad i = 0, \dots, 2^s - 1, \\ \hat{p}_k(s+1) &= \frac{1}{Ms} \sum_{l=1}^{Ms} I\{\langle X'_l \rangle = k\} = \frac{v_k}{Ms}, \quad k = 0, \dots, 2^{s+1} - 1. \end{aligned} \quad (1)$$

¹Криптология : учебник / Ю. С. Харин [и др.]. Минск : БГУ, 2013. 511 с. (Классическое университетское издание).

Статистические оценки s - и $(s+1)$ -мерной энтропии Шеннона на основе частотных оценок вероятностей (1) имеют вид

$$\begin{aligned}\hat{H}(s) &= -\sum_{i=0}^{2^s-1} \hat{p}_i(s) \ln \hat{p}_i(s) \in [0, s \ln 2], \\ \hat{H}(s+1) &= -\sum_{k=0}^{2^{s+1}-1} \hat{p}_k(s+1) \ln \hat{p}_k(s+1) \in [0, (s+1) \ln 2].\end{aligned}\quad (2)$$

Чтобы вычислить ковариацию статистических оценок энтропии Шеннона (2) $\text{cov}_0\{\hat{H}(s), \hat{H}(s+1)\}$ при истинной гипотезе H_0 о том, что наблюдаемая последовательность является равномерно распределенной случайной последовательностью, необходимо сначала найти 2^{2s+1} ковариаций частотных оценок вероятностей $\text{cov}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\}$ для всех пар s - и $(s+1)$ -грамм (i, k) , $i = 0, \dots, 2^s-1$, $k = 0, \dots, 2^{s+1}-1$. Введем обозначения

$$a_{ik} = E_0\{\hat{p}_i(s), \hat{p}_k(s+1)\}, \quad b_{ik} = E_0\{\hat{p}_i(s)\} E_0\{\hat{p}_k(s+1)\}.$$

Тогда для искомых ковариаций частотных оценок вероятностей справедливо выражение

$$d_{ik} = \text{cov}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\} = a_{ik} - b_{ik}. \quad (3)$$

Поскольку $E_0\{\hat{p}_i(s)\} = 2^{-s}$, $i = 0, \dots, 2^s-1$, $E_0\{\hat{p}_k(s+1)\} = 2^{-s-1}$, $k = 0, \dots, 2^{s+1}-1$, имеем $b_{ik} = 2^{-2s-1}$, $i = 0, \dots, 2^s-1$, $k = 0, \dots, 2^{s+1}-1$. Для a_{ik} справедливо выражение

$$\begin{aligned}a_{ik} &= \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{j=1}^{M(s+1)} \sum_{l=1}^{Ms} E_0\{I\{\langle X_j \rangle = i, \langle X'_l \rangle = k\}\} = \\ &= \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{j=1}^{M(s+1)} \sum_{l=1}^{Ms} P_0\{\langle X_j \rangle = i, \langle X'_l \rangle = k\}.\end{aligned}$$

Значение величины

$$c_{ijkl} = P_0\{\langle X_j \rangle = i, \langle X'_l \rangle = k\},$$

входящей в выражение для a_{ik} , зависит от взаимного расположения s -граммы $\langle X_j \rangle$ и $(s+1)$ -граммы $\langle X'_l \rangle$. Если s -грамма $\langle X_j \rangle$ и $(s+1)$ -грамма $\langle X'_l \rangle$ не пересекаются, т. е. не содержат общих элементов ряда $\{x_1, \dots, x_T\}$, то в силу их независимости при истинной гипотезе H_0 имеем

$$c_{ijkl} = P_0\{\langle X_j \rangle = i\} P_0\{\langle X'_l \rangle = k\} = 2^{-s} \cdot 2^{-s-1} = 2^{-2s-1}, \quad i = 0, \dots, 2^s-1, \quad k = 0, \dots, 2^{s+1}-1. \quad (4)$$

Зафиксируем $(s+1)$ -грамму $\langle X'_l \rangle$. Она может пересекаться только с двумя s -граммами. Пусть j'_l и $j'_l + 1$ – их номера. Тогда a_{ik} представимо в виде

$$a_{ik} = \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{l=1}^{Ms} \sum_{j \neq j'_l, j'_l + 1} c_{ijkl} + \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{l=1}^{Ms} (c_{ij'_l kl} + c_{i(j'_l + 1) kl}). \quad (5)$$

Из выражения (4) для первого слагаемого в выражении (5) следует, что

$$\frac{1}{M(s+1)} \frac{1}{Ms} \sum_{l=1}^{Ms} \sum_{j \neq j'_l, j'_l + 1} c_{ijkl} = \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{l=1}^{Ms} \sum_{j \neq j'_l, j'_l + 1} \frac{1}{2^{2s+1}} = \frac{M(s+1)-2}{2^{2s+1} M(s+1)}. \quad (6)$$

Перед рассмотрением пересечений s - и $(s+1)$ -грамм введем обозначение

$$l' = \begin{cases} l \bmod s, & \text{если } l \bmod s > 0, \\ s, & \text{если } l \bmod s = 0, \end{cases} \quad l' \in \{1, 2, \dots, s\}. \quad (7)$$

Пусть длина пересечения $(s+1)$ -граммы $\langle X'_l \rangle$ и s -граммы $\langle X_{j'_l+1} \rangle$ равна m_l , а длина пересечения $(s+1)$ -граммы $\langle X'_l \rangle$ и s -граммы $\langle X_{j'_l} \rangle$ равна $s+1-m_l$.

Лемма 1. Справедливо соотношение $m_l = l'$.

Доказательство. Взаимное расположение s - и $(s+1)$ -грамм повторяется через каждые s $(s+1)$ -грамм. В связи с этим рассмотрим сначала первые s $(s+1)$ -грамм $\langle X'_l \rangle$ ($l=1, \dots, s$).

С первой $(s+1)$ -граммой $\langle X'_1 \rangle$ пересекаются s -граммы $\langle X_1 \rangle$ и $\langle X_2 \rangle$. Отметим, что s -грамма $\langle X_1 \rangle$ покрывается $(s+1)$ -граммой $\langle X'_1 \rangle$ полностью, т. е. $s+1-m_1=s$, а длина пересечения s -граммы $\langle X_2 \rangle$ и $(s+1)$ -граммы $\langle X'_1 \rangle$ равна $m_1=1$, т. е. при $l=1$ имеем $m_l=l$. Поскольку для $l=2, \dots, s$ s -граммы $\langle X_{j'_l} \rangle$ и $\langle X_{j'_{l-1}+1} \rangle$ совпадают, длины пересечений $(s+1)$ -граммы $\langle X'_{l-1} \rangle$ с s -граммой $\langle X_{j'_{l-1}+1} \rangle$ и $(s+1)$ -граммы $\langle X'_l \rangle$ с s -граммой $\langle X_{j'_l} \rangle = \langle X_{j'_{l-1}+1} \rangle$ в сумме дают s , т. е. $m_{l-1}+s+1-m_l=s$, откуда $m_l=m_{l-1}+1$. Таким образом, имеем рекуррентное соотношение с начальным значением $m_1=1$. Следовательно, для $l=1, \dots, s$ справедливо $m_l=l$, что при указанных значениях l равносильно $m_l=l'$.

В отношении $(s+1)$ -грамм $\langle X'_l \rangle$, $l=s+1, 2s+1, \dots, ts+1, \dots$, справедливы те же рассуждения, что и в отношении $(s+1)$ -грамм $\langle X'_1 \rangle$. Отличие состоит лишь в том, что $m_l=1=l'$. Дальнейшие рассуждения о сумме длин пересечений $(s+1)$ -граммы $\langle X'_{l-1} \rangle$ с s -граммой $\langle X_{j'_{l-1}+1} \rangle$ и $(s+1)$ -граммы $\langle X'_l \rangle$ с s -граммой $\langle X_{j'_l} \rangle = \langle X_{j'_{l-1}+1} \rangle$ также справедливы, т. е. для $l=ts+2, \dots, (t+1)s$, $t \in \mathbb{N}$, $m_l=m_{l-1}+1$. Следовательно, $m_l=l'$ для любого l . Лемма доказана.

На рис. 1 продемонстрированы возможные типы пересечений при $s=3$.

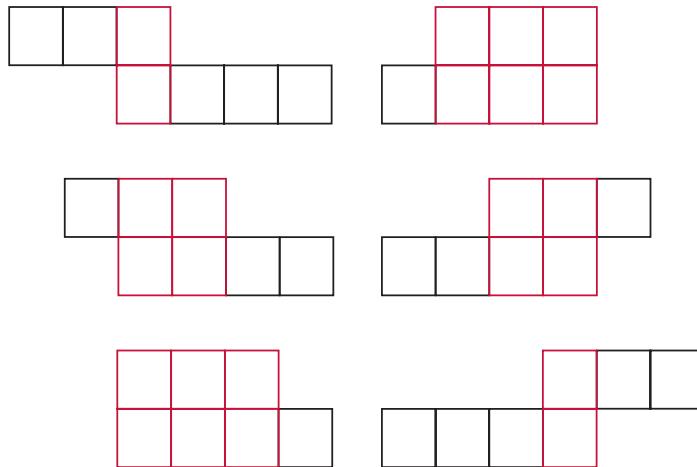


Рис. 1. Возможные типы пересечений 3- и 4-грамм

Fig. 1. Possible types of 3- and 4-tuples intersections

Полученный при пересечении $(s+1)$ -граммы $\langle X'_l \rangle$ и s -граммы $\langle X_{j'_l} \rangle$ вектор имеет длину $s+1+s-(s+1-m_l)=s+l'$. Соответствующий пересечению индекс i обозначим мультииндексом I_l^s , а индекс k – мультииндексом $K_1^{s+1-l'}$. Полученный при пересечении $(s+1)$ -граммы $\langle X'_l \rangle$ и s -граммы $\langle X_{j'_{l+1}} \rangle$ вектор имеет длину $s+1+s-m_l=2s+1-l'$. Соответствующий пересечению индекс i обозначим мультииндексом $I_l^{l'}$, а индекс k – мультииндексом $K_{s+2-l'}^{s+1}$.

Теорема 1. При истинной гипотезе H_0 для ковариаций (3) справедливо следующее выражение:

$$d_{ik} = \frac{1}{M(s+1)} \frac{1}{2^s} \left(\frac{1}{s} \sum_{l=1}^s \left(\frac{1}{2^l} I\{I_l^s = K_1^{s+1-l'}\} + \frac{1}{2^{s+1-l'}} I\{I_l^{l'} = K_{s+2-l'}^{s+1}\} \right) - \frac{1}{2^s} \right). \quad (8)$$

Доказательство. При расчете $c_{ij'_lkl}$ и $c_{i(j'_l+1)kl}$ необходимо учесть как длину двоичных векторов, полученных при пересечении, так и совпадение соответствующих пересечению элементов i и k . Тогда

$$\begin{aligned} c_{ij'_lkl} &= P_0 \left\{ \langle X_{j'} \rangle = i, \langle X'_l \rangle = k \right\} = \frac{1}{2^{s+l'}} I\{I_l^s = K_1^{s+1-l'}\}, \\ c_{i(j'_l+1)kl} &= P_0 \left\{ \langle X_{j'+1} \rangle = i, \langle X'_l \rangle = k \right\} = \frac{1}{2^{2s+1-l'}} I\{I_l^{l'} = K_{s+2-l'}^{s+1}\}. \end{aligned} \quad (9)$$

Заметим, что индикаторы в выражениях (9) представимы в виде

$$I\{I_{l'}^s = K_1^{s+1-l'}\} = \prod_{j=1}^{s+1-l'} (i_{l'+j-1} \oplus k_j \oplus 1), I\{I_1^{l'} = K_{s+2-l'}^{s+1}\} = \prod_{j=1}^{l'} (i_j \oplus k_{j+s+1-l'} \oplus 1).$$

Подставим выражения (6) и (9) в выражение (5) и получим

$$a_{ik} = \frac{M(s+1)-2}{2^{2s+1}M(s+1)} + \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{l=1}^{Ms} \left(\frac{1}{2^{s+l'}} I\{I_{l'}^s = K_1^{s+1-l'}\} + \frac{1}{2^{2s+1-l'}} I\{I_1^{l'} = K_{s+2-l'}^{s+1}\} \right),$$

где зависимость l' от l определяется формулой (7). Тогда

$$\begin{aligned} d_{ik} &= \frac{M(s+1)-2}{2^{2s+1}M(s+1)} + \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{l=1}^{Ms} \left(\frac{1}{2^{s+l'}} I\{I_{l'}^s = K_1^{s+1-l'}\} + \frac{1}{2^{2s+1-l'}} I\{I_1^{l'} = K_{s+2-l'}^{s+1}\} \right) - \\ &- \frac{1}{2^{2s+1}} = \frac{1}{M(s+1)} \frac{1}{Ms} \sum_{l=1}^{Ms} \left(\frac{1}{2^{s+l'}} I\{I_{l'}^s = K_1^{s+1-l'}\} + \frac{1}{2^{2s+1-l'}} I\{I_1^{l'} = K_{s+2-l'}^{s+1}\} \right) - \frac{1}{2^{2s}M(s+1)} = \\ &= \frac{1}{M(s+1)} \frac{1}{2^s} \left(\frac{1}{Ms} \sum_{l=1}^{Ms} \left(\frac{1}{2^{s+l'}} I\{I_{l'}^s = K_1^{s+1-l'}\} + \frac{1}{2^{s+1-l'}} I\{I_1^{l'} = K_{s+2-l'}^{s+1}\} \right) - \frac{1}{2^s} \right). \end{aligned} \quad (10)$$

Поскольку через каждые s $(s+1)$ -грамм слагаемые в сумме повторяются, из выражения (10) вытекает выражение (8). Теорема доказана.

Следствие 1. Справедлива следующая точная двусторонняя оценка ковариаций (3):

$$-\frac{1}{2^{2s}M(s+1)} \leq \text{cov}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\} \leq \frac{1}{2^{s-1}s(s+1)M} \left(1 - \frac{s+2}{2^{s+1}}\right). \quad (11)$$

Доказательство. В случае если индекс i состоит из одних нулей, а индекс k – из одних единиц, и наоборот, все индикаторы в выражениях (9) будут равны нулю. Тогда

$$a_{ik} = \frac{M(s+1)-2}{2^{2s+1}M(s+1)}, \quad d_{ik} = a_{ik} - b_{ik} = \frac{1}{2^{2s+1}} - \frac{1}{2^{2s}M(s+1)} - \frac{1}{2^{2s+1}} = -\frac{1}{2^{2s}M(s+1)}.$$

В случае если индексы i и k состоят из одних нулей или единиц, все индикаторы в выражениях (9) будут равны единице. Тогда

$$a_{ik} = \frac{M(s+1)-2}{2^{2s+1}M(s+1)} + \frac{1}{M(s+1)} \frac{1}{s} \sum_{l=1}^s \left(\frac{1}{2^{s+l}} + \frac{1}{2^{2s+1-l}} \right).$$

Поскольку $s+1-l$, как и l , пробегает все возможные значения от 1 до s , по формуле суммы геометрической прогрессии имеем

$$\sum_{l=1}^s \left(\frac{1}{2^{s+l}} + \frac{1}{2^{2s+1-l}} \right) = \frac{2}{2^s} \frac{\frac{1}{2} \left(1 - \frac{1}{2^s}\right)}{1 - \frac{1}{2}} = \frac{1}{2^{s-1}} \left(1 - \frac{1}{2^s}\right).$$

Окончательно получаем

$$\begin{aligned} a_{ik} &= \frac{M(s+1)-2}{2^{2s+1}M(s+1)} + \frac{1}{M(s+1)} \frac{1}{s} \frac{1}{2^{s-1}} \left(1 - \frac{1}{2^s}\right) = \frac{M(s+1)-2}{2^{2s+1}M(s+1)} + \frac{1}{2^{s-1}sM(s+1)} \left(1 - \frac{1}{2^s}\right), \\ d_{ik} &= a_{ik} - b_{ik} = \frac{1}{2^{2s+1}} - \frac{1}{2^{2s}M(s+1)} + \frac{1}{2^{s-1}sM(s+1)} \left(1 - \frac{1}{2^s}\right) - \frac{1}{2^{2s+1}} = \\ &= \frac{1}{2^{s-1}sM(s+1)} \left(1 - \frac{1}{2^s}\right) - \frac{1}{2^{2s}M(s+1)} = \frac{1}{2^{s-1}s(s+1)M} - \frac{1}{2^{2s}M(s+1)} \left(1 + \frac{2}{s}\right) = \\ &= \frac{1}{2^{s-1}s(s+1)M} \left(1 - \frac{s+2}{2^{s+1}}\right). \end{aligned}$$

Следствие доказано.

Следствие 2. Коэффициент корреляции частотных оценок вероятностей

$$\text{corr}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\} = \frac{\text{cov}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\}}{\sqrt{D_0\{\hat{p}_i(s)\} D_0\{\hat{p}_k(s+1)\}}} \quad (12)$$

удовлетворяет двустороннему неравенству

$$-2 \sqrt{\frac{s}{(s+1)(2^s-1)(2^{s+1}-1)}} \leq \text{corr}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\} \leq \frac{2^{s+2}-2s-4}{\sqrt{s(s+1)(2^s-1)(2^{s+1}-1)}}. \quad (13)$$

Доказательство. Для дисперсии частотных оценок вероятностей справедливо

$$\begin{aligned} D_0\{\hat{p}_i(s)\} &= D_0\left\{\frac{1}{M(s+1)} \sum_{j=1}^{M(s+1)} I\{\langle X_j \rangle = i\}\right\} = \frac{1}{M^2(s+1)^2} \sum_{j=1}^{M(s+1)} D_0\{I\{\langle X_j \rangle = i\}\} = \\ &= \frac{1}{M^2(s+1)^2} \sum_{j=1}^{M(s+1)} \frac{1}{2^s} \left(1 - \frac{1}{2^s}\right) = \frac{1}{2^s M(s+1)} \left(1 - \frac{1}{2^s}\right), \quad i = 0, \dots, 2^s - 1. \end{aligned} \quad (14)$$

Аналогично

$$D_0\{\hat{p}_k(s+1)\} = \frac{1}{2^{s+1} M s} \left(1 - \frac{1}{2^{s+1}}\right), \quad k = 0, \dots, 2^{s+1} - 1.$$

Тогда

$$\begin{aligned} D_0\{\hat{p}_i(s)\} D_0\{\hat{p}_k(s+1)\} &= \frac{1}{2^s M(s+1)} \left(1 - \frac{1}{2^s}\right) \frac{1}{2^{s+1} M s} \left(1 - \frac{1}{2^{s+1}}\right) = \frac{(2^s-1)(2^{s+1}-1)}{2^{2s} \cdot 2^{2s+2} M^2 s (s+1)}, \\ \sqrt{D_0\{\hat{p}_i(s)\} D_0\{\hat{p}_k(s+1)\}} &= \frac{\sqrt{(2^s-1)(2^{s+1}-1)}}{2^{2s+1} M \sqrt{s(s+1)}}. \end{aligned}$$

Подставим данное выражение в формулу (12) и получим

$$\text{corr}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\} = \frac{2^{2s+1} M \sqrt{s(s+1)} \text{cov}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\}}{\sqrt{(2^s-1)(2^{s+1}-1)}}.$$

Тогда на основе двусторонней оценки (11) получим двустороннюю оценку (13). Следствие доказано.

Введем обозначения

$$f_{ik} = \sum_{l=1}^s \left(\frac{1}{2^l} I\{I_l^s = K_1^{s+1-l}\} + \frac{1}{2^{s+1-l}} I\{I_1^l = K_{s+2-l}^{s+1}\} \right), \quad g_{ik} = \frac{f_{ik}}{s} - \frac{1}{2^s}. \quad (15)$$

Тогда из выражения (8) следует, что

$$d_{ik} = \frac{g_{ik}}{2^s M(s+1)}. \quad (16)$$

Лемма 2. Справедливо выражение

$$\sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik} = 2^{s+1} s.$$

Доказательство. Изменим порядок суммирования:

$$\begin{aligned} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik} &= \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \sum_{l=1}^s \left(\frac{1}{2^l} I\{I_l^s = K_1^{s+1-l}\} + \frac{1}{2^{s+1-l}} I\{I_1^l = K_{s+2-l}^{s+1}\} \right) = \\ &= \sum_{l=1}^s \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \left(\frac{1}{2^l} I\{I_l^s = K_1^{s+1-l}\} + \frac{1}{2^{s+1-l}} I\{I_1^l = K_{s+2-l}^{s+1}\} \right). \end{aligned} \quad (17)$$

Стоящие внутри сумм индикаторные функции, как следует из выражений (9), соответствуют пересечениям s - и $(s+1)$ -грамм, при этом пересечению длины l соответствует множитель 2^{l-s-1} (поскольку из суммы длин s - и $(s+1)$ -грамм была вычтена длина пересечения, а также был вынесен за скобки множитель 2^{-s} в определении d_{ik}). При суммировании по всем возможным s - и $(s+1)$ -граммам индикаторная функция будет равна единице ровно 2^{2s+1-l} раз, что соответствует числу возможных вариантов значений бит, оказавшихся вне пересечения длины l . Если рассуждать аналогично (либо переобозначить l), то 2^{-l} будет умножаться на индикаторную функцию, которая соответствует пересечению длины $s+1-l$. При суммировании по всем возможным s - и $(s+1)$ -граммам индикаторная функция будет равна единице ровно 2^{s+l} раз. Тогда в выражении (17) получим

$$\begin{aligned} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik} &= \sum_{l=1}^s \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \left(\frac{1}{2^l} I\{I_l^s = K_1^{s+1-l}\} + \frac{1}{2^{s+1-l}} I\{I_l^s = K_{s+2-l}^{s+1}\} \right) = \\ &= \sum_{l=1}^s \left(\frac{2^{s+l}}{2^l} + \frac{2^{2s+1-l}}{2^{s+1-l}} \right) = \sum_{l=1}^s (2^s + 2^s) = 2^{s+1}s. \end{aligned}$$

Лемма доказана.

Лемма 3. Справедливо выражение

$$\sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik}^2 = 2^{s+1} + 2s^2 - s - 2. \quad (18)$$

Доказательство. Перепишем f_{ik} в следующем виде:

$$f_{ik} = \sum_{l=1}^s \frac{1}{2^l} (x_{ik}^{(l)} + y_{ik}^{(l)}), \quad x_{ik}^{(l)} = I\{I_l^s = K_1^{s+1-l}\}, \quad y_{ik}^{(l)} = I\{I_l^s = K_{l+1}^{s+1}\}.$$

Тогда для f_{ik}^2 справедливо выражение

$$f_{ik}^2 = \left(\sum_{l=1}^s \frac{1}{2^l} (x_{ik}^{(l)} + y_{ik}^{(l)}) \right)^2 = \sum_{l=1}^s \frac{1}{2^{2l}} (x_{ik}^{(l)} + y_{ik}^{(l)})^2 + 2 \sum_{l=1}^{s-1} \sum_{t=l+1}^s \frac{1}{2^{l+t}} (x_{ik}^{(l)} + y_{ik}^{(l)}) (x_{ik}^{(t)} + y_{ik}^{(t)}).$$

Изменим порядок суммирования:

$$\begin{aligned} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik}^2 &= \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \left(\sum_{l=1}^s \frac{1}{2^{2l}} (x_{ik}^{(l)} + y_{ik}^{(l)})^2 + 2 \sum_{l=1}^{s-1} \sum_{t=l+1}^s \frac{1}{2^{l+t}} (x_{ik}^{(l)} + y_{ik}^{(l)}) (x_{ik}^{(t)} + y_{ik}^{(t)}) \right) = \\ &= \sum_{l=1}^s \frac{1}{2^{2l}} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} (x_{ik}^{(l)} + y_{ik}^{(l)})^2 + 2 \sum_{l=1}^{s-1} \sum_{t=l+1}^s \frac{1}{2^{l+t}} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} (x_{ik}^{(l)} + y_{ik}^{(l)}) (x_{ik}^{(t)} + y_{ik}^{(t)}). \end{aligned} \quad (19)$$

Справедливы следующие соотношения:

$$\begin{aligned} \frac{1}{2^{2l}} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} (x_{ik}^{(l)} + y_{ik}^{(l)})^2 &= 2^l + 1, \quad l = 1, \dots, s, \\ \frac{1}{2^{l+t}} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} (x_{ik}^{(l)} + y_{ik}^{(l)}) (x_{ik}^{(t)} + y_{ik}^{(t)}) &= 2, \quad l = 1, \dots, s-1, \quad t = l+1, \dots, s. \end{aligned} \quad (20)$$

Подставим выражения (20) в выражение (19) и получим

$$\begin{aligned} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik}^2 &= \sum_{l=1}^s (2^l + 1) + 2 \sum_{l=1}^{s-1} \sum_{t=l+1}^s 2 = \sum_{l=1}^s 2^l + s + 2(s^2 - s) = \frac{2(2^s - 1)}{2 - 1} + 2s^2 - s = \\ &= 2^{s+1} - 2 + 2s^2 - s. \end{aligned}$$

Лемма доказана.

Следствие 3. Справедливо выражение

$$\sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} g_{ik}^2 = \frac{2^{s+1} - s - 2}{s^2}. \quad (21)$$

Доказательство. Из выражений (15), (18) и (21) следует, что

$$\begin{aligned} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} g_{ik}^2 &= \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \left(\frac{f_{ik}}{s} - \frac{1}{2^s} \right)^2 = \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \left(\frac{f_{ik}^2}{s^2} - \frac{2f_{ik}}{2^s s} + \frac{1}{2^{2s}} \right) = \frac{1}{s^2} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik}^2 - \\ &- \frac{1}{2^{s-1} s} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} f_{ik} + \frac{2^{2s+1}}{2^{2s}} = \frac{2^{s+1} + 2s^2 - s - 2}{s^2} - \frac{2^{s+1} s}{2^{s-1} s} + 2 = \frac{2^{s+1} - s - 2}{s^2}. \end{aligned}$$

Следствие доказано.

Вернемся к статистическим оценкам (2).

Теорема 2. Пусть $0 < \hat{p}_i \leq 2^{1-s}$, $i = 0, \dots, 2^s - 1$, $0 < \hat{p}_k \leq 2^{-s}$, $k = 0, \dots, 2^{s+1} - 1$. Тогда при истинной гипотезе H_0 для ковариации и коэффициента корреляции статистических оценок энтропии Шеннона s - и $(s+1)$ -грамм $\hat{H}(s)$, $\hat{H}(s+1)$ справедливы следующие выражения:

$$\begin{aligned} \text{cov}_0 \{ \hat{H}(s), \hat{H}(s+1) \} &= \frac{2^{s+1} - s - 2}{M^2 s^2 (s+1)^2} + o\left(\frac{1}{M^2}\right), \\ \text{corr}_0 \{ \hat{H}(s), \hat{H}(s+1) \} &= \frac{2(2^{s+1} - s - 2)}{s(s+1)\sqrt{(2^s-1)(2^{s+1}-1)}} + o(1). \end{aligned} \quad (22)$$

Доказательство. Обозначим случайную величину $\xi_i = \hat{p}_i(s) - p_i$, $i = 0, \dots, 2^s - 1$. Тогда $\hat{H}(s) = -\sum_{i=0}^{2^s-1} (p_i + \xi_i) \ln(p_i + \xi_i)$. Воспользуемся представлением логарифма рядом Тейлора²:

$$\ln(p_i + \xi_i) = \ln\left(p_i \left(1 + \frac{\xi_i}{p_i}\right)\right) = \ln p_i + \frac{\xi_i}{p_i} - \frac{1}{2} \frac{\xi_i^2}{p_i^2} + O\left(|\xi_i|^3\right).$$

Для сходимости ряда Тейлора необходимо потребовать, чтобы $\frac{\xi_i}{p_i} \in (-1; 1]$, что при истинной гипотезе H_0 равносильно условию $\xi_i \in \left(-\frac{1}{2^s}; \frac{1}{2^s}\right]$. Проверим выполнение условия $\frac{\xi_i}{p_i} = \frac{\hat{p}_i - p_i}{p_i} = \frac{\hat{p}_i}{p_i} - 1 = 2^s \hat{p}_i - 1 \in (-1; 1]$:

$$2^s \hat{p}_i - 1 > -1 \Leftrightarrow 2^s \hat{p}_i > 0 \Leftrightarrow \hat{p}_i > 0, \quad 2^s \hat{p}_i - 1 \leq 1 \Leftrightarrow 2^s \hat{p}_i \leq 2 \Leftrightarrow \hat{p}_i \leq \frac{2}{2^s}. \quad (23)$$

Условие (23) выполнено согласно формулировке теоремы. Тогда для статистической оценки энтропии Шеннона получим

$$\begin{aligned} \hat{H}(s) &= -\sum_{i=0}^{2^s-1} (p_i + \xi_i) \left(\ln p_i + \frac{1}{p_i} \xi_i - \frac{1}{2p_i^2} \xi_i^2 + O\left(|\xi_i|^3\right) \right) = -\sum_{i=0}^{2^s-1} p_i \ln p_i - \\ &- \sum_{i=0}^{2^s-1} \left(p_i \frac{1}{p_i} \xi_i + \xi_i \ln p_i \right) - \sum_{i=0}^{2^s-1} \left(\frac{1}{p_i} \xi_i^2 - p_i \frac{1}{2p_i^2} \xi_i^2 \right) + O\left(\max_i |\xi_i|^3\right) = \\ &= H(s) - \sum_{i=0}^{2^s-1} (1 + \ln p_i) \xi_i - \frac{1}{2} \sum_{i=0}^{2^s-1} \frac{1}{p_i} \xi_i^2 + O\left(\max_i |\xi_i|^3\right). \end{aligned}$$

При истинной гипотезе H_0 $p_i = p = \frac{1}{2^s}$, $i = 0, \dots, 2^s - 1$. Кроме того, $\sum_{i=0}^{2^s-1} \xi_i = \sum_{i=0}^{2^s-1} \hat{p}_i - \sum_{i=0}^{2^s-1} p_i = 1 - 1 = 0$. Следовательно,

$$\begin{aligned} \hat{H}(s) &= H(s) - (1 + \ln p) \sum_{i=0}^{2^s-1} \xi_i - \frac{1}{2p} \sum_{i=0}^{2^s-1} \xi_i^2 + O\left(\max_i |\xi_i|^3\right) = \\ &= H(s) - 2^{s-1} \sum_{i=0}^{2^s-1} \xi_i^2 + O\left(\max_i |\xi_i|^3\right). \end{aligned}$$

²Воднев В. Т., Наумович А. Ф., Наумович Н. Ф. Основные математические формулы : справочник / под ред. Ю. С. Богданова. 2-е изд., перераб. и доп. Минск : Выш. шк., 1988. 272 с.

Обозначим случайную величину $\eta_k = \hat{p}_k(s+1) - p_k$, $k = 0, \dots, 2^{s+1}-1$. Для сходимости ряда Тейлора необходимо потребовать, чтобы $\frac{\eta_k}{p_k} \in (-1; 1]$. Данное условие, проверяемое аналогично условию (23), выполняется согласно формулировке теоремы. Тогда при истинной гипотезе H_0 имеем $\hat{H}(s+1) = H(s+1) - 2^s \sum_{k=0}^{2^{s+1}-1} \eta_k^2 + O\left(\max_k |\eta_k|^3\right)$.

Введем обозначения $u_1 = \sum_{i=0}^{2^s-1} \xi_i^2$, $u_2 = \sum_{k=0}^{2^{s+1}-1} \eta_k^2$. Тогда при истинной гипотезе H_0 $\hat{H}(s) = a_1 u_1 + b_1 + v_1$, $\hat{H}(s+1) = a_2 u_2 + b_2 + v_2$, где $a_1 = -2^{s-1}$; $b_1 = H(s) = s \ln 2$; $v_1 = O\left(\max_i |\xi_i|^3\right)$; $a_2 = -2^s$; $b_2 = H(s+1) = (s+1) \ln 2$; $v_2 = O\left(\max_k |\eta_k|^3\right)$.

Сформируем составной случайный вектор ζ длины $3 \cdot 2^s$ конкатенацией случайных векторов ξ и η : $\zeta = (\xi \|\eta) \in \mathbb{R}^{2^s} \times \mathbb{R}^{2^{s+1}}$. Тогда при $M \rightarrow \infty$ вектор ζ будет иметь асимптотически нормальное распределение. Приведем формулу для смешанного центрального момента 4-го порядка гауссовского вектора³

$$\sigma_{ijkl} = \sigma_{ij} \sigma_{kl} + \sigma_{ik} \sigma_{jl} + \sigma_{il} \sigma_{kj}. \quad (24)$$

Из формулы (14) для всех $i = 0, \dots, 2^s-1$ следует, что

$$\sigma_{ii} = E_0 \left\{ \xi_i^2 \right\} = E_0 \left\{ (\hat{p}_i(s) - p_i(s))^2 \right\} = D_0 \left\{ \hat{p}_i(s) \right\} = \frac{1}{2^s M(s+1)} \left(1 - \frac{1}{2^s} \right). \quad (25)$$

Аналогично для всех $i, j = 0, \dots, 2^s-1$, $i \neq j$, имеем

$$\begin{aligned} \sigma_{ij} &= E_0 \left\{ \xi_i \xi_j \right\} = E_0 \left\{ (\hat{p}_i(s) - p_i(s)) (\hat{p}_j(s) - p_j(s)) \right\} = \text{cov}_0 \left\{ \hat{p}_i(s), \hat{p}_j(s) \right\} = \\ &= \text{cov}_0 \left\{ \frac{v_i}{M(s+1)}, \frac{v_j}{M(s+1)} \right\} = \frac{\text{cov}_0 \{v_i, v_j\}}{M^2(s+1)^2} = -\frac{M(s+1)p_i p_j}{M^2(s+1)^2} = -\frac{1}{2^s \cdot 2^s M(s+1)}. \end{aligned} \quad (26)$$

С учетом свойств дисперсии, формулы (24) и равенства всех σ_{ii} , $i = 0, \dots, 2^s-1$, при истинной гипотезе H_0 получаем

$$\begin{aligned} D_0 \{u_1\} &= D_0 \left\{ \sum_{i=0}^{2^s-1} \xi_i^2 \right\} = E_0 \left\{ \left(\sum_{i=0}^{2^s-1} \xi_i^2 \right)^2 \right\} - E_0^2 \left\{ \sum_{i=0}^{2^s-1} \xi_i^2 \right\} = \\ &= E_0 \left\{ \sum_{i=0}^{2^s-1} \xi_i^2 \sum_{j=0}^{2^s-1} \xi_j^2 \right\} - \left(E_0 \left\{ \sum_{i=0}^{2^s-1} \xi_i^2 \right\} \right)^2 = \sum_{i=0}^{2^s-1} \sum_{j=0}^{2^s-1} E_0 \left\{ \xi_i^2 \xi_j^2 \right\} - \left(\sum_{i=0}^{2^s-1} E_0 \left\{ \xi_i^2 \right\} \right)^2 = \\ &= \sum_{i,j=0}^{2^s-1} \sigma_{ijij} - \left(\sum_{i=0}^{2^s-1} \sigma_{ii} \right)^2 = \sum_{i,j=0}^{2^s-1} (\sigma_{ii} \sigma_{jj} + 2\sigma_{ij}^2) - \left(\sum_{i=0}^{2^s-1} \sigma_{ii} \right)^2 = \\ &= \sum_{i,j=0}^{2^s-1} (\sigma_{ii}^2 + 2\sigma_{ij}^2) - \left(\sum_{i=0}^{2^s-1} \sigma_{ii} \right)^2 = 2 \sum_{i,j=0}^{2^s-1} \sigma_{ij}^2 + 2^{2s} \sigma_{ii}^2 - (2^s \sigma_{ii})^2 = \\ &= 2 \sum_{i,j=0}^{2^s-1} \sigma_{ij}^2 = 2 \left(\sum_{i=0}^{2^s-1} \sigma_{ii}^2 + \sum_{i=0}^{2^s-1} \sum_{j \neq i} \sigma_{ij}^2 \right). \end{aligned} \quad (27)$$

³Харин Ю. С., Зуев Н. М., Жук Е. Е. Теория вероятностей, математическая и прикладная статистика : учебник. Минск : БГУ, 2011. 464 с. (Классическое университетское издание).

Подставим формулы (25) и (26) в выражение (27) и получим

$$D_0\{u_1\} = 2 \left(2^s \frac{2^{-2s} (1 - 2^{-s})^2}{M^2 (s+1)^2} + 2^s (2^s - 1) \frac{2^{-2s} \cdot 2^{-2s}}{M^2 (s+1)^2} \right) = \frac{1}{2^{s-1} M^2 (s+1)^2} \times \\ \times \left((1 - 2^{-s})^2 + (2^s - 1) 2^{-2s} \right) = \frac{1}{2^{s-1} M^2 (s+1)^2} (1 - 2^{-s+1} + 2^{-s}) = \frac{2^s - 1}{2^{2s-1} M^2 (s+1)^2}. \quad (28)$$

Аналогично $D_0\{u_2\} = \frac{2^{s+1} - 1}{2^{2s+1} M^2 s^2}$.

Воспользовавшись формулой (24) для вычисления $E_0\{u_1 u_2\}$, получим

$$E_0\{u_1 u_2\} = E_0 \left\{ \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \xi_i^2 \eta_k^2 \right\} = \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} E_0\{\xi_i^2 \eta_k^2\} = \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \sigma_{iikk}. \quad (29)$$

При $j=i, l=k$ формула (24) принимает вид $\sigma_{iikk} = \sigma_{ii} \sigma_{kk} + 2\sigma_{ik}^2$, где $\sigma_{ii} = D_0\{\xi_i\}$, $\sigma_{kk} = D_0\{\eta_k\}$ и $\sigma_{ik} = \text{cov}_0\{\xi_i, \eta_k\}$, $i = 0, \dots, 2^s - 1$, $k = 0, \dots, 2^{s+1} - 1$. Поскольку

$$E\{\xi_i\} = E\{\eta_k\} = 0, \quad i = 0, \dots, 2^s - 1, \quad k = 0, \dots, 2^{s+1} - 1, \quad (30)$$

имеем $D_0\{\xi_i\} = E_0\{\xi_i^2\}$, $D_0\{\eta_k\} = E_0\{\eta_k^2\}$, $i = 0, \dots, 2^s - 1$, $k = 0, \dots, 2^{s+1} - 1$. Используя формулы (24) и (29) для вычисления $\text{cov}\{u_1, u_2\}$, получим

$$\begin{aligned} \text{cov}\{u_1, u_2\} &= E_0\{u_1 u_2\} - E_0\{u_1\} E_0\{u_2\} = \\ &= \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} (\sigma_{ii} \sigma_{kk} + 2\sigma_{ik}^2) - \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \sigma_{ii} \sigma_{kk} = 2 \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} \sigma_{ik}^2. \end{aligned}$$

Из выражения (30) для $i = 0, \dots, 2^s - 1$, $k = 0, \dots, 2^{s+1} - 1$ следует, что

$$\begin{aligned} \text{cov}_0\{\xi_i, \eta_k\} &= E_0\{\xi_i \eta_k\} = E_0\{(\hat{p}_i(s) - p_i(s))(\hat{p}_k(s+1) - p_k(s+1))\} = \\ &= \text{cov}_0\{\hat{p}_i(s), \hat{p}_k(s+1)\} = d_{ik}. \end{aligned}$$

Таким образом,

$$2^{2s-1} \text{cov}_0\{u_1, u_2\} = 2^{2s} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} d_{ik}^2 \geq 0. \quad (31)$$

Подставим выражения (16) и (21) в выражение (31) и получим

$$2^{2s-1} \text{cov}_0\{u_1, u_2\} = \frac{2^{2s}}{2^{2s} M^2 (s+1)^2} \sum_{i=0}^{2^s-1} \sum_{k=0}^{2^{s+1}-1} g_{ik}^2 = \frac{2^{s+1} - s - 2}{M^2 s^2 (s+1)^2}. \quad (32)$$

Найдем порядок v_1 относительно M . Справедливо ограничение сверху

$$\max_i |\xi_i|^3 \leq \sum_{i=0}^{2^s-1} |\xi_i|^3.$$

Исследуем свойства величины $\Xi = \sum_{i=0}^{2^s-1} |\xi_i|^3$. Поскольку, как было сказано выше, величины ξ_i имеют одинаковое асимптотически нормальное распределение, моменты всех порядков и нулевое математиче-

ское ожидание, то сама величина Ξ будет иметь тот же порядок, что и ее математическое ожидание. Обозначим стандартное отклонение величин ξ_i через $\sigma = \sqrt{D\{\xi_i\}} = \sqrt{\sigma_{ii}}$. Из выражения (27) следует, что $\sigma \sim O\left(\frac{1}{\sqrt{M}}\right)$. Применим формулу для абсолютного центрального момента 4-го порядка нормальной случайной величины⁴ с учетом того, что величины ξ_i распределены асимптотически нормально и $E\{\xi_i\} = 0$, $i = 0, \dots, 2^s - 1$. Получим $E\{\xi_i^4\} = 3\sigma_{ii}^2 = 3\sigma^4$. Тогда из неравенства Ляпунова⁵ следует, что

$$\left(E\{|\xi_i|^3\}\right)^{\frac{1}{3}} \leq \left(E\{\xi_i^4\}\right)^{\frac{1}{4}} = (3\sigma^4)^{\frac{1}{4}} = 3^{\frac{1}{4}}\sigma,$$

откуда

$$E\{|\xi_i|^3\} \leq \left(E\{\xi_i^4\}\right)^{\frac{3}{4}} = 3^{\frac{3}{4}}\sigma^3 \sim O\left(\frac{1}{M^{\frac{3}{2}}}\right),$$

и при фиксированном значении s справедливо $\Xi \sim O\left(\frac{1}{M^{\frac{3}{2}}}\right)$, откуда $v_1 \sim O\left(\frac{1}{M^{\frac{3}{2}}}\right)$.

Из выражения (28) следует, что $u_1 \sim O\left(\frac{1}{M}\right)$. Аналогично $u_2 \sim O\left(\frac{1}{M}\right)$, $v_2 \sim O\left(\frac{1}{M^{\frac{3}{2}}}\right)$. Значит, при вычислении ковариации остаточными членами v_1 , v_2 можно пренебречь. Учитывая свойство ковариации и применяя выражение (32), получаем

$$\begin{aligned} \text{cov}_0\{\hat{H}(s), \hat{H}(s+1)\} &= a_1 a_2 \text{cov}_0\{u_1, u_2\} + a_1 \text{cov}_0\{u_1, v_2\} + a_2 \text{cov}_0\{v_1, u_2\} + \\ &+ \text{cov}_0\{v_1, v_2\} = 2^{2s-1} \text{cov}_0\{u_1, u_2\} + O\left(\frac{1}{M^{\frac{5}{2}}}\right) = \frac{2^{s+1} - s - 2}{M^2 s^2 (s+1)^2} + o\left(\frac{1}{M^2}\right). \end{aligned}$$

Для того чтобы найти коэффициент корреляции статистических оценок энтропии Шеннона $\text{corr}_0\{\hat{H}(s), \hat{H}(s+1)\} = \frac{\text{cov}_0\{\hat{H}(s), \hat{H}(s+1)\}}{\sqrt{D_0\{\hat{H}(s)\} D_0\{\hat{H}(s+1)\}}}$, необходимо вычислить $D_0\{\hat{H}(s)\}$ и $D_0\{\hat{H}(s+1)\}$.

Аналогично после пренебрежения остаточными членами получаем

$$\begin{aligned} D_0\{\hat{H}(s)\} &= a_1^2 D_0\{u_1\} + D_0\{v_1\} + a_1 \text{cov}_0\{u_1, v_1\} = 2^{2(s-1)} D_0\{u_1\} + O\left(\frac{1}{M^{\frac{5}{2}}}\right) = \\ &= \frac{2^{2(s-1)}(2^s - 1)}{2^{2s-1} M^2 (s+1)^2} + o\left(\frac{1}{M^2}\right) = \frac{2^s - 1}{2 M^2 (s+1)^2} + o\left(\frac{1}{M^2}\right) = \frac{b_1}{M^2} (1 + o_1(1)), \\ D_0\{\hat{H}(s+1)\} &= a_2^2 D_0\{u_2\} + D_0\{v_2\} + a_2 \text{cov}_0\{u_2, v_2\} = 2^{2s} D_0\{u_2\} + O\left(\frac{1}{M^{\frac{5}{2}}}\right) = \\ &= \frac{2^{2s}(2^{s+1} - 1)}{2^{2s+1} M^2 s^2} + o\left(\frac{1}{M^2}\right) = \frac{2^{s+1} - 1}{2 M^2 s^2} + o\left(\frac{1}{M^2}\right) = \frac{b_2}{M^2} (1 + o_2(1)), \end{aligned}$$

⁴Харин Ю. С., Зуев Н. М., Жук Е. Е. Теория вероятностей... 464 с.

⁵Там же.

где $b_1 = \frac{2^s - 1}{2(s+1)^2}$; $b_2 = \frac{2^{s+1} - 1}{2s^2}$. Применив разложение в ряд Тейлора⁶ $\frac{1}{\sqrt{1+x}} = 1 - \frac{1}{2}x + o(x)$, получим

$$\begin{aligned} \frac{1}{\sqrt{D_0\{\hat{H}(s)\}D_0\{\hat{H}(s+1)\}}} &= \frac{1}{\sqrt{\left(\frac{b_1}{M^2}(1+o_1(1))\right)\left(\frac{b_2}{M^2}(1+o_2(1))\right)}} = \\ &= \frac{M^2}{\sqrt{b_1 b_2}} \frac{1}{\sqrt{(1+o_1(1))(1+o_2(1))}} = \frac{M^2}{\sqrt{b_1 b_2}} \left(1 - \frac{1}{2} \max\{o_1(1), o_2(1)\}\right) = \frac{M^2}{\sqrt{b_1 b_2}} (1 + o(1)) = \\ &= \frac{2M^2 s(s+1)}{\sqrt{(2^s - 1)(2^{s+1} - 1)}} + o(M^2). \end{aligned}$$

Следовательно,

$$\begin{aligned} \text{corr}_0\{\hat{H}(s), \hat{H}(s+1)\} &= \left(\frac{2^{s+1} - s - 2}{M^2(s+1)^2 s^2} + o\left(\frac{1}{M^2}\right) \right) \left(\frac{2M^2 s(s+1)}{\sqrt{(2^s - 1)(2^{s+1} - 1)}} + o(M^2) \right) = \\ &= \frac{2(2^{s+1} - s - 2)}{s(s+1)\sqrt{(2^s - 1)(2^{s+1} - 1)}} + o(1). \end{aligned}$$

Заметим, что для главного члена коэффициента корреляции статистических оценок энтропии Шеннона справедливо

$$\frac{2(2^{s+1} - s - 2)}{s(s+1)\sqrt{(2^s - 1)(2^{s+1} - 1)}} = \frac{2^{\frac{3}{2}}}{s(s+1)} \frac{1 - \frac{s+2}{2^{s+1}}}{\sqrt{(1 - 2^{-s})(1 - 2^{-s-1})}} = O\left(\frac{1}{s^2}\right).$$

Теорема доказана.

Следствие 4. Из формул (22) следует, что с ростом значения s коэффициент корреляции статистических оценок энтропии Шеннона s - и $(s+1)$ -грамм стремится к нулю.

Результаты и их обсуждение

Для демонстрации справедливости формул (22) и следствия 4 была проведена серия компьютерных экспериментов. Рассматривалась псевдослучайная последовательность, полученная алгоритмом BeLT⁷ в режиме счетчика. Для $s = 2, \dots, 10$ из наблюдаемой последовательности брались $K = 1000$ фрагментов длины $T = Ms(s+1)$ с фиксированным значением $M = 10\,000$. По полученным K фрагментам для каждого значения s вычислялись статистические оценки энтропии Шеннона, по которым затем рассчитывались выборочные значения ковариации и коэффициента корреляции. Также для указанных значений параметров были определены теоретические значения ковариации и коэффициента корреляции статистических оценок энтропии Шеннона по главным членам в формулах (22). Проведено сравнение выборочных и теоретических значений ковариации (рис. 2) и коэффициента корреляции (рис. 3) статистических оценок энтропии Шеннона, вычисленных по s - и $(s+1)$ -граммам, в зависимости от значения s . Как видно из рис. 2 и 3, экспериментально полученные значения ковариации и коэффициента корреляции близки к теоретическим значениям, коэффициент корреляции стремится к нулю с ростом значения s .

Следствие 4 обосновывает применение энтропийного профиля [1] для статистического тестирования криптографических генераторов: для принятия решения о справедливости гипотезы о равномерной распределенности наблюдаемой последовательности необходимо вычисление оценки энтропии при различных значениях длины фрагмента s .

⁶Воднев В. Т., Наумович А. Ф., Наумович Н. Ф. Основные математические формулы... 272 с.

⁷Информационные технологии и безопасность. Криптографические алгоритмы генерации псевдослучайных чисел : СТБ 34.101.47-2017. Введ. 09.01.2017. Минск : Госстандарт, 2017. III, 21 с.

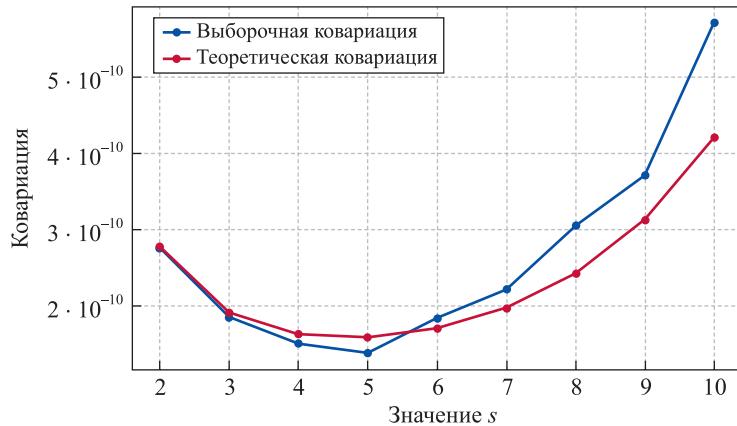


Рис. 2. Сравнение выборочных и теоретических значений ковариации статистических оценок энтропии Шеннона, вычисленных по s - и $(s+1)$ -граммам, в зависимости от значения s

Fig. 2. Comparison of sample and theoretical values of covariance of the statistical estimates of Shannon entropy, calculated from s - and $(s+1)$ -tuples, depending on the value of s

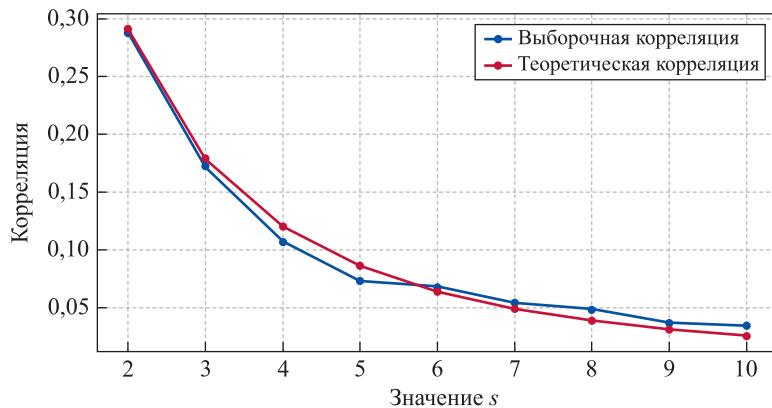


Рис. 3. Сравнение выборочных и теоретических значений коэффициента корреляции статистических оценок энтропии Шеннона, вычисленных по s - и $(s+1)$ -граммам, в зависимости от значения s

Fig. 3. Comparison of sample and theoretical values of correlation coefficient of the statistical estimates of Shannon entropy, calculated from s - and $(s+1)$ -tuples, depending on the value of s

Заключение

Найдены асимптотическое (при увеличении длины двоичной последовательности) совместное распределение вероятностей частотных оценок вероятностей s - и $(s+1)$ -грамм, асимптотическое распределение вероятностей статистической оценки энтропии Шеннона s -грамм $\hat{H}(s)$ и асимптотическое совместное распределение вероятностей статистических оценок энтропии Шеннона s - и $(s+1)$ -грамм $\hat{H}(s)$, $\hat{H}(s+1)$. Доказано, что с ростом значений s коэффициент корреляции статистических оценок энтропии Шеннона s - и $(s+1)$ -грамм $\hat{H}(s)$, $\hat{H}(s+1)$ стремится к нулю. Теоретические результаты подтверждены компьютерными экспериментами. Обосновано применение энтропийного профиля [1] для статистического тестирования криптографических генераторов.

Библиографические ссылки

1. Palukha UYu, Kharin YuS, Siarheeu AI, Arlou AA. On statistical testing of random and pseudorandom sequences based on entropy functionals. In: Kharin YuS, editor. *Computer data analysis and modeling: stochastics and data science. Proceedings of the 13th International conference; 2022 September 6–10; Minsk, Belarus*. Minsk: Belarusian State University; 2022. p. 148–162. EDN: QBMBVS.