

ОЦЕНКА КАЧЕСТВА ГЕНЕРАТОРОВ СЛУЧАЙНЫХ ЧИСЕЛ В СИСТЕМАХ ЗАЩИТЫ ИНФОРМАЦИИ

Ю. С. Харин¹⁾, М. В. Мальцев²⁾, В. Ю. Палуха³⁾

*Учреждение Белорусского государственного университета «НИИ прикладных проблем математики и информатики»,
пр. Независимости, 4, 220030, г. Минск, Беларусь, ¹⁾ kharin@bsu.by, ²⁾ maltsew@bsu.by, ³⁾ palukha@bsu.by,*

Рассматривается задача оценки качества генераторов случайных и псевдослучайных числовых последовательностей, используемых в системах защиты информации. С помощью вероятностно-статистических методов выявляются отклонения в выходных последовательностях генераторов от равномерно-распределенной случайной последовательности. Для решения данной задачи используются малопараметрические марковские модели и энтропийные характеристики.

Ключевые слова: статистическое тестирование; криптографический генератор; малопараметрическая марковская модель; энтропийный профиль; сложная гипотеза.

Введение

Критически важными элементами систем защиты информации являются генераторы случайных и псевдослучайных числовых последовательностей. Последовательность, вырабатываемая стойким генератором, не должна отличаться по своим свойствам от равномерно-распределенной случайной последовательности (РРСП). Основным методом оценки качества генераторов является статистическое тестирование. Известные наборы (батареи) тестов обладают рядом недостатков и ограничений: они проверяют простую нулевую гипотезу, не фиксируют семейство альтернатив, могут не обнаруживать сравнительно простые зависимости [1]. В связи с этим актуальной является разработка методов и алгоритмов, позволяющих более эффективно выявлять зависимости в выходных последовательностях генераторов. Направлениями, показавшими свою эффективность на практике, являются статистическое тестирование на основе сложных малопараметрических марковских моделей [2] и на основе энтропийных характеристик [3].

1. Статистическое тестирование на основе малопараметрических марковских моделей

Известной малопараметрической моделью является разработанная в Белорусском государственном университете цепь Маркова порядка s с r частичными связями [4]. В настоящей статье представлено обобщение данной модели для векторной цепи Маркова с $m \geq 2$ компонентами. Обозначим: $A = \{0, 1, \dots, N-1\}$ – множество мощности $|A| = N \geq 2$; $m \in \mathbb{N}$ – размерность состояния цепи Маркова, $J_i = (j_i, \dots, j_m) \in A^m$, $i \in \mathbb{N}$, – m -мерный целочисленный вектор; $J_a^b = (J_a, J_{a+1}, \dots, J_b)$ – упорядоченный набор m -мерных векторов; $\{x_t = (x_{t_1}, \dots, x_{t_m}) \in A^m : t \in \mathbb{N}\}$ – однородная векторная цепь Маркова порядка s с пространством состояний A^m с матрицей вероятностей одношаговых переходов $P = (p_{J_1^s, J_{s+1}})$:

$$p_{J_1^s, J_{s+1}} = P\{x_t = J_{s+1} \mid x_{t-1} = J_s, \dots, x_{t-s} = J_1\}, J_1, \dots, J_{s+1} \in A^m, t \in \{s+1, s+2, \dots\}. \quad (1)$$

Такую цепь Маркова будем обозначать ВЦМ(s) – векторная цепь Маркова порядка s .

Число независимых элементов матрицы P , равное $N^{ms}(N^m-1)$, возрастает экспоненциально при увеличении s , и применение этой модели на практике возможно лишь при небольших значениях параметров. В связи с этим, построена модификация ВЦМ(s), для которой условное распределение вероятностей определяется лишь некоторыми «значимыми» компонентами

предыдущих векторов-состояний. Обозначим: $M_r = \{(k_1, l_1), (k_2, l_2), \dots, (k_r, l_r)\}$ – множество $1 \leq r \leq sm$ пар индексов, упорядоченных в лексикографическом порядке, причем $k_1 = 1$. Множество M_r называется шаблоном связей или просто шаблоном. Определим также функцию-селектор $S_{M_r}(J_t, \dots, J_{t+s-1}) = (j_{t+k_1-1, l_1}, \dots, j_{t+k_r-1, l_r})$, $t \in \mathbb{N}$, которая в соответствии с шаблоном M_r «вырезает» r компонент из множества ms компонент $\{j_{u,l} : t \leq u \leq t+s-1, 1 \leq l \leq m\}$.

Если вероятности (1) допускают следующее представление:

$$p_{J_1^s, J_{s+1}} = q_{S_{M_r}(J_1, \dots, J_s), J_{s+1}} = q_{(j_{k_1, l_1}, \dots, j_{k_r, l_r}), J_{s+1}}, J_1, \dots, J_{s+1} \in A^m,$$

где $Q = (q_{(i_1, \dots, i_r), I_{r+1}})$ – некоторая стохастическая $N^r \times N^m$ -матрица, $i_1, \dots, i_r \in A$, $I_{r+1} \in A^m$, то ВЦМ(s) называется векторной цепью Маркова с r частичными связями и шаблоном связей M_r (ВЦМ(s, r)). Условное распределение вероятностей состояния x_t для ВЦМ(s, r) в момент времени t зависит не от всех ms компонент s прошлых состояний, а только от r избранных компонент, которые определяются шаблоном M_r .

Разработан алгоритм идентификации ВЦМ(s, r) по реализации длины n : $X^{(n)} = (x_1, \dots, x_n)$, $x_1, \dots, x_n \in A^m$; построен статистический тест для обнаружения отклонений в $X^{(n)}$ от РРСП на основе ВЦМ(s, r) (гипотезе H_0 соответствует РРСП):

$$\text{принимается } \begin{cases} H_0, \text{ если } \rho_n \leq \Delta, \\ H_1 = \bar{H}_0, \text{ если } \rho_n > \Delta, \end{cases} \quad (2)$$

где $\rho_n = \sum_{i_1, \dots, i_r \in A} \sum_{I_{r+1} \in A^m} \bar{q}_{(i_1, \dots, i_r), I_{r+1}}^2 \nu_{s+1}^{M_r}(i_1, \dots, i_r, I_{r+1}) / q_{(i_1, \dots, i_r), I_{r+1}}^{(0)}$; $Q^{(0)} = (q_{(i_1, \dots, i_r), I_{r+1}}^{(0)})$ – стохастическая матрица размерности $N^r \times N^m$, все элементы которой равны $1/N^m$; $\bar{q}_{(i_1, \dots, i_r), I_{r+1}}^2 = (q_{(i_1, \dots, i_r), I_{r+1}}^{(0)} - \hat{q}_{(i_1, \dots, i_r), I_{r+1}}) / \sqrt{n-s}$, $\hat{q}_{(i_1, \dots, i_r), I_{r+1}}$ – оценки максимального правдоподобия вероятностей переходов; $\nu_{s+1}^{M_r}(i_1, \dots, i_r, I_{r+1})$ – частоты состояний ВЦМ(s, r); $\Delta = G_y^{-1}(1-\alpha)$, G_y – функция стандартного χ^2 -распределения с y степенями свободы, $\alpha \in (0, 1)$ – уровень значимости.

В компьютерных экспериментах с помощью алгоритма статистического тестирования, основанного на (2), выявлены отклонения от РРСП в генераторе rand стандартной библиотеки языка C – stdlib для реализации размера 10 МБ, тогда как тестирование на основе батареи NIST не выявило отклонения от «чистой случайности» в аналогичной последовательности размера 2 ГБ [5].

2. Статистическое тестирование генераторов на основе оценок энтропии

В качестве тестовых статистик могут выступать статистические оценки функционалов информационной энтропии, вычисленные по наблюдаемой двоичной последовательности. Пусть x – случайная величина из алфавита мощности $N = 2^s$ с дискретным распределением вероятностей $p = \{p_k\}$, $p_k = P\{x = \omega_k\}$, $p_k \geq 0$, $\sum_{k=1}^N p_k = 1$, $k = 1, \dots, N$, и пусть наблюдается случайная последовательность $\{x_t : t = 1, \dots, n\}$ объёма n из распределения вероятностей $\{p_k\}$. Частотные оценки вероятностей имеют вид

$$\hat{p}_k = \frac{v_k}{n}, \quad v_k = \sum_{t=1}^n I\{x_t = \omega_k\} \in \mathbb{N}_0 = \mathbb{N} \cup \{0\}, \quad I\{x_t = \omega_k\} = \begin{cases} 1, & x_t = \omega_k; \\ 0, & x_t \neq \omega_k. \end{cases}$$

Рассмотрим асимптотику соразмерного увеличения объёма выборки и мощности алфавита:

$$n, N \rightarrow \infty, n/N \rightarrow \lambda, 0 < \lambda < \infty. \quad (3)$$

В следующей таблице приведены формулы вычисления оценок энтропии Шеннона, Реньи и Тсаллиса, для которых в [3] при истинной гипотезе H_0 в асимптотике (3) доказана асимптотическая нормальность, а также параметры асимптотически нормального распределения. Для построения несмещённых оценок функционалов энтропии Реньи и Тсаллиса используется факториальная степень $\chi^2 = \chi(\chi - 1)$.

Оценки функционалов энтропии и параметры их распределения

Тип	Оценка	Мат. ожидание	Дисперсия
Шеннон	$\hat{H} = \ln n - \frac{1}{n} \sum_{k=1}^N v_k \ln v_k$	$\mu_H = \ln n - e^{-\lambda} \sum_{k=1}^{+\infty} \frac{\ln(k+1)\lambda^k}{k!}$	$\sigma_H^2 = \frac{e^{-\lambda}}{n} \sum_{k=1}^{+\infty} \frac{(k+1)\lambda^k}{k!} \ln^2(k+1) - \frac{e^{-2\lambda}}{N} \left(\sum_{k=1}^{+\infty} \frac{\ln(k+1)\lambda^k}{k!} \right)^2 - \frac{e^{-2\lambda}}{n} \left(\sum_{k=1}^{+\infty} \ln(k+1) \frac{\lambda^k}{k!} (k+1-\lambda) \right)^2$
Реньи	$\hat{H}_2 = 2 \ln n - \ln \sum_{k=1}^N v_k^2$	$\mu_{H,2} = \ln N$	$\sigma_{H,2}^2 = \frac{2}{n\lambda}$
Тсаллис	$\hat{S}_2 = 1 - \frac{1}{n^2} \sum_{k=1}^N v_k^2$	$\mu_{S,2} = 1 - \frac{1}{N}$	$\sigma_{S,2}^2 = \frac{2}{Nn^2}$

Пусть $\alpha \in (0, 1)$ – уровень значимости, h – статистическая оценка энтропии Шеннона, Реньи или Тсаллиса, μ_h и σ_h^2 – асимптотические математическое ожидание и дисперсия этих оценок при истинной гипотезе H_0 . Вычислим h для наблюдаемой последовательности. Решающее правило, основанное на статистике h , имеет вид [3]:

$$\text{принимается} \begin{cases} H_0, & \text{если } t_- < h < t_+; \\ \overline{H_0}, & \text{в противном случае,} \end{cases} \quad t_{\pm} = \mu_h \pm \sigma_h \Phi^{-1} \left(1 - \frac{\alpha}{2} \right). \quad (4)$$

где $\Phi(\cdot)$ – функция распределения стандартного нормального закона.

Вычислим нормированную статистику $\tilde{h} = (h - \mu_h) / \sigma_h$ которая в асимптотике (3) и при истинной гипотезе H_0 имеет стандартное нормальное распределение. Следовательно, двустороннее p -значение для неё равно

$$p\text{-value} = 2 \left(1 - \Phi \left(\left| \tilde{h} \right| \right) \right). \quad (5)$$


Пусть наблюдается двоичная последовательность $\{y_\tau\}$, $\tau = 1, \dots, T$. Из непересекающихся фрагментов длины s (s -грамм) $X^{(t)} = (X_j^{(t)}) = (y_{(t-1)s+1}, \dots, y_{ts}) \in \{0, 1\}^s$, $t = 1, \dots, n = [T/s]$, сформируем новую последовательность $\{x_t\}$ из алфавита мощности $N = 2^s$ по правилу

$x_i = \sum_{j=1}^s 2^{j-1} X_j^{(i)} + 1$. На основе критерия (4) вычислим последовательность нормированных отклонений оценки энтропии от математического ожидания в зависимости от s , которую назовём энтропийным профилем:

$$\chi(s) = \frac{\hat{h}(s) - \mu_h(s)}{\sigma_h(s)\Phi^{-1}(1-\alpha/2)} = \frac{\tilde{h}(s)}{\Phi^{-1}(1-\alpha/2)}, s = s_-, \dots, s_+. \quad (6)$$

Аналогично строятся последовательности p -значений (3).

Разработанный в НИИ ПМИ программный комплекс «ЭАДП» реализует критерий (4). В начале работы необходимо выбрать файл с последовательностью, порядок Big Endian или Little Endian, диапазон s и функционалы энтропии. Вычисляемые значения добавляются на экран в режиме реального времени. Имеется возможность изменять уровень значимости α без пересчёта оценок энтропии и переключаться на различные режимы отображения: непосредственно оценки энтропии $\hat{h}$, нормированные значения (6), p -значения (5). Помимо вывода самих значений в консоль, программа отображает графики зависимостей этих величин от длины фрагмента s . Главное окно программного комплекса с результатами работы представлено на следующем рисунке.



Программный комплекс «ЭАДП»

Введём в рассмотрение сложную нулевую гипотезу $H_0^{(\varepsilon)}$, согласно которой для распределения вероятностей $\{p_k\}$ справедливо

$$p_k = \frac{1}{N} + \varepsilon_k, -\frac{1}{N} \leq \varepsilon_k \leq \frac{N-1}{N}, \varepsilon_k = O\left(\frac{1}{N}\right), k = 1, \dots, N, \sum_{k=1}^N \varepsilon_k = 0, \sum_{k=1}^N \varepsilon_k^2 = \varepsilon^2, 0 \leq \varepsilon \leq \varepsilon_+. \quad (7)$$

Сложная нулевая гипотеза (7) означает, что допустимы незначительные отклонения от дискретной равномерности.

В [6] показано, что оценка энтропии Тсаллиса при справедливости гипотезы (7), где $\varepsilon_+ \leq \frac{1}{\sqrt{2}}$, в асимптотике (3) имеет асимптотически нормальное распределение, при этом для параметров распределения справедливы оценки

$$\begin{aligned}\mu_{S,2}^{(\varepsilon)} &= \mu_{S,2} - \varepsilon^2 \geq \mu_{S,2}^{(\varepsilon_+)} = \mu_{S,2} - \varepsilon_+^2, \\ \sigma_{S,2}^{2(\varepsilon)} &< \sigma_{S,2}^{2(\varepsilon_+)} = \sigma_{S,2}^2 + \frac{2}{n^2}(2\lambda + 1)\varepsilon_+^2 + \frac{4\varepsilon_+^3}{n}(1 - \varepsilon_+).\end{aligned}\quad (8)$$

Решающее правило для проверки сложной нулевой гипотезы (7) имеет вид [6]

$$\begin{aligned}\text{принимается} &\begin{cases} H_*^{(\varepsilon)}, & \text{если } \Delta_- < \hat{S}_2 < \Delta_+, \\ H_*^{(\varepsilon)}, & \text{иначе,} \end{cases} \\ \Delta_- &= \mu_{S,2}^{(\varepsilon_+)} - \sigma_{S,2}^{(\varepsilon_+)} \Phi^{-1}\left(1 - \frac{\alpha}{2}\right), \quad \Delta_+ = \mu_{S,2} + \sigma_{S,2}^{(\varepsilon_+)} \Phi^{-1}\left(1 - \frac{\alpha}{2}\right), \quad \varepsilon_+ \leq \frac{1}{\sqrt{2}}.\end{aligned}\quad (9)$$

Библиографические ссылки

1. Зубков А. М. Серов А. А. Проверка пакета статистических критериев NIST на специальных псевдослучайных последовательностях // Математические вопросы криптографии, 2019, том 10, выпуск 2. С. 89-96.
2. Kharin Yu.S. Parsimonious models of high-order Markov chains for evaluation of cryptographic generators // Математические вопросы криптографии, том 7, выпуск 2. С. 131-142.
3. Палуха В.Ю. Статистические тесты на основе оценок энтропии для проверки гипотез о равномерном распределении случайной последовательности // Весці НАН Беларусі. Серыя фізіка-матэматычных навук. 2017. № 1. С. 79-88.
4. Харин Ю. С. Цепи Маркова с г-частичными связями и их статистическое оценивание // Доклады НАН Беларуси. 2004. Т. 48, № 1. С. 40-44.
5. Харин Ю. С., Мальцев М. В. Применение специальных марковских моделей для оценки качества криптографических генераторов // Комплексная защита информации: материалы XXV научно-практической конференции, Россия, 15-17 сентября 2020 года. С. 224-228.
6. Палуха В. Ю., Харин Ю. С. Статистическое тестирование криптографических генераторов на основе сложной нулевой гипотезы // Теоретическая и прикладная криптография: материалы II Международной научной конференции, Минск, 19-20 октября 2023 г. / Белорусский государственный университет; редколлегия: Ю. С. Харин (гл. ред.) [и др.]. Минск: БГУ, 2023. С. 185-193.