

ОБ ИСПОЛЬЗОВАНИИ ПРЕДИКТОРА СТМ ДЛЯ ТЕСТИРОВАНИЯ БИНАРНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ

А.Л. Костевич, А.В. Шилкин

НИИ прикладных проблем математики и информатики
пр Независимости, 4, Минск, Беларусь
телефон: + (017) 2095549; e-mail: shilkinanton@gmail.com

Рассматривается критерий тестирования бинарных последовательностей, разработанный в рамках непараметрического подхода проверки гипотезы о чистой случайности на базе универсального СТМ-предиктора.

Ключевые слова – Context Tree Weighting предиктор, статистическая проверка гипотез, универсальные предикторы.

1 ВВЕДЕНИЕ

Рассмотрим задачу проверки гипотезы H_0 о чистой случайности, т.е. о том, что последовательность описывается моделью независимых симметричных испытаний Бернулли.

Проверка данной гипотезы для широкого класса альтернатив в рамках классических (параметрических) статистических методов является затруднительной в силу большого числа возможных альтернатив. Поэтому в последнее время активно развивается непараметрический подход на основе универсальных методов сжатия. Однако сложность алгоритмической записи методов сжатия затрудняет поиск вероятностных характеристик, необходимых для построения статистических критериев, чем вызвано использование в тестах Маурера и Лемпеля-Зива [1] статистических оценок нужных параметров.

Приведенная в [2] схема построения критерия для проверки гипотезы H_0 позволяет в рамках непараметрического подхода строить тест на базе любого универсального предиктора. В [3] непараметрический подход из [2] адаптируется на случай использования предиктора Лемпеля – Зива. Адаптация подхода из [2] на случай использования Sampled Pattern Matching предиктора рассмотрена в [4].

В данной статье рассматривается применение Context Tree Weighting [5] предиктора, который является универсальным для древовидных источников с ограниченной длиной памяти.

2 КРИТЕРИЙ ПРОВЕРКИ ГИПОТЕЗЫ О ЧИСТОЙ СЛУЧАЙНОСТИ НА БАЗЕ УНИВЕРСАЛЬНЫХ ПРЕДИКТОРОВ

Приведем сначала предложенную в [2] схему построения статистического критерия проверки гипотезы

о чистой случайности на базе любого универсального предиктора. Пусть наблюдается временной ряд $X_1, X_2, \dots, X_t \in A\{0,1\}$, который описывается набором условных вероятностей $\{P\{X_t | X_{t-1}, \dots, X_1\}\}$ из некоторого класса моделей M . Пусть зарегистрированы наблюдения $x_1, x_2, \dots, x_t$ и требуется сделать прогноз значения следующего символа X_{t+1} .

Если вероятностная модель последовательности известна, то оптимальный прогноз определяется максимумом соответствующей условной вероятности:

$$\hat{X}_{t+1}^* = \arg \max_{a \in A} P\{a | X_{t-1}, \dots, X_1\} \quad (1)$$

При этом достигается минимальная средняя ошибка прогнозирования:

$$\pi_t^* = P\{\hat{X}_{t+1}^* \neq X_{t+1}\} \quad (2)$$

Если вероятностная модель последовательности неизвестна, то должен быть построен предиктор $\{\hat{P}\{X_t | X_{t-1}, \dots, X_1\}\}$, прогноз строится аналогично (1), но уже с большей вероятностью ошибки прогноза:

$$\begin{aligned} \hat{X}_{t+1} &= \arg \max_{a \in A} \hat{P}\{a | X_{t-1}, \dots, X_1\} \\ \epsilon_t &= P\{\hat{X}_{t+1} \neq X_{t+1}\} \end{aligned} \quad (3)$$

Предиктор (3) называется универсальным [6] для класса M , если при неизвестных $\{P\{X_t | X_{t-1}, \dots, X_1\}\}$ из этого класса ошибка предсказания сходится по вероятности к нулю при $t \rightarrow \infty$ для любого набора условных вероятностей из класса M . Под ошибкой предсказания в рамках непараметрического подхода рассматривается избыточность предиктора $\epsilon_t = \epsilon_t - \pi_t^*$ [4].

В [2] предлагается подход к тестированию гипотезы H_0 , основанный на построении последовательности прогнозов и оценке эффективности прогнозирования любого универсального предиктора.

Пусть наблюдается выборка $X = (x_1, \dots, x_n)$ объема n . Для каждого $t = 1, \dots, n-1$ по первым t наблюдениям будем строить прогноз для x_{t+1} с

использованием предиктора (3), затем вычислять индикатор успешного прогноза: $Y_t = I\{\hat{X}_t = x_t\}$.

Если для тестируемой выборки верна гипотеза H_0 о случайности, то последовательность индикаторов $\{Y_t\}$ также будет описываться гипотезой H_0 о независимости и симметричности испытаний Бернулли. Если же для тестируемой выборки верна гипотеза H_1 и $\pi_t^* < 0.5$, то в случае универсального для H_1 предиктора последовательность индикаторов успеха прогноза будет иметь некоторое (зависящее от H_1 и предиктора) совместное распределение, но со следующими маргинальными вероятностями:

$$H_1^{(Y)}: P\{Y_t = 1\} = \frac{1}{2} + \varepsilon_t, \quad \varepsilon_t > 0, \quad t \rightarrow \infty$$

В качестве статистического критерия для проверки H_0 против уже альтернативы $H_1^{(Y)}$ (и H_1 соответственно) в [2] предложен следующий статистический критерий:

$$\text{принять } \begin{cases} H_0, & \text{если } 2\sqrt{n} \left(S - \frac{1}{2}\right) < \Phi^{-1}(1-\alpha), \\ H_1, & \text{иначе} \end{cases} \quad (4)$$

где $S = \frac{1}{n} \sum_{t=1}^n Y_t$ — доля успеха в прогнозах, $\Phi(\cdot)$ — функция распределения стандартного нормального распределения, α — уровень значимости.

3 ОПИСАНИЕ СТВ-ПРЕДИКТОРА

Строка $s = q_{l-1} q_{l-2} \dots q_0$ является *суффиксом* строки $s' = q'_{l-1} q'_{l-2} \dots q'_0$, если $l < l'$, $q_{-i} = q'_{-i}$, $i = 0, l-1$.

Суффиксное множество S — это набор строк $s(k), k = 1, 2, \dots, |S|$, обладающее свойством *корректности* и *полноты*. Корректность означает, что ни одна строка из S не является суффиксом другой строки из S . Полнота означает, что любая полубесконечная строка $x''_{-\infty} = \dots x_{n-2} x_{n-1} x_n$ имеет суффикс во множестве S . Такой суффикс является единственным, поскольку множество S корректно.

Выберем и зафиксируем параметр D .

Источником ограниченной памяти древесной структуры назовем источник, которому соответствует суффиксное множество S такое, что $\forall s \in S$ длина $l(s) \leq D$. Каждому суффиксу $s \in S$ соответствует параметр $\theta_s \in (0, 1)$. Обозначим $\Theta_S = \{\theta_s, s \in S\}$.

Определим функцию $\beta_s(\cdot)$, которая выделяет суффикс из множества S для последовательности $x''_{-\infty}$. Поскольку длина каждого суффикса не превосходит D , то только последние D символов последовательности определяют суффикс в S . Если источник сгенерировал последовательность $x''_{-\infty}$, то

$$P\{X_t = 1 \mid x''_{t-D}, S, \Theta_S\} = \theta_{\beta_s(x''_{t-D})}, \quad \forall t$$

Тогда вероятность того, что источник сгенерирует последовательность X_1^t равна

$$P\{X_1^t = x_1^t \mid x_1^0, S, \Theta_S\} = \prod_{i=1}^t P\{X_i = x_i \mid x_{i-D}^0, S, \Theta_S\}$$

Говорят, что все источники с одинаковым суффиксным множеством имеют одинаковую модель. Множество всех моделей с ограниченной памятью образует класс моделей C_D .

Вероятность последовательности из a нулей и b единиц, сгенерированной источником без памяти с параметром θ , равняется $(1-\theta)^a \theta^b$. Если взвесить эту вероятность по всем θ с использованием распределения Дирихле с параметром $(0.5, 0.5)$, то получится так называемая *оценка Кричевского-Трофимова*.

Вероятность Кричевского-Трофимова последовательности из $a \geq 0$ нулей и $b \geq 0$ единиц определяется как:

$$P_e\{a, b\} = \int_0^1 \frac{1}{\pi \sqrt{(1-\theta)\theta}} (1-\theta)^a \theta^b d\theta$$

При этом для $a \geq 0, b \geq 0$ верны формулы последовательного вычисления:

$$P_e(0, 0) = 1, \quad P_e(a+1, b) = \frac{a+0.5}{a+b+1}, \quad P_e(a, b+1) = \frac{b+0.5}{a+b+1} \quad (5)$$

Контекстное дерево T_D — это множество узлов, соответствующих бинарным строкам $s, 0 \leq l(s) \leq D$. В каждом узле $s \in T_D$ хранится $a_s(x_1^0 \mid x_{1-D}^0)$ — число нулей в последовательности x_1^t после суффикса s , $b_s(x_1^0 \mid x_{1-D}^0)$ — число единиц.

Каждому узлу s ставится в соответствие взвешенная вероятность P_w^s :

$$P_w^s = \begin{cases} 0.5 P_e(a_s, b_s) + 0.5 P_w^{0s} P_w^{1s}, & 0 \leq l(s) < D \\ P_e(a_s, b_s), & l(s) = D \end{cases} \quad (6)$$

Таким образом, для определения вероятности $P_{CTW}(x_1^t \mid x_{1-D}^0)$ последовательности x_1^t требуется произвести подсчет частот $a_s, b_s, \forall s \in T_D$, тогда

$$P_{CTW}(x_1^t \mid x_{1-D}^0) = P_w^\lambda(x_1^t \mid x_{1-D}^0) \quad (7)$$

где λ — пустая строка.

Отметим, что (7) является взвешенной вероятностью по всем возможным моделям источника из C_D .

4 ИССЛЕДОВАНИЕ БИНАРНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ С ИСПОЛЬЗОВАНИЕМ СТВ-ПРЕДИКТОРА

Прогноз значения следующего символа в момент времени t с использованием предиктора СТВ строится согласно правилу (3) с использованием (7):

$$\hat{x}_{t+1} = \arg \max_{i=0,1} \{P_{CTW}(x_i' || i | x_{1-D}^0)\} \quad (8)$$

где символ $||$ означает конкатенацию строк.

Таким образом, для построения последовательности индикаторов успеха прогнозов $\{Y_t\}$ по выборке $x_{1-D}^0 || x_1^n$ объема $n + D + 1$ с использованием СТВ-предиктора с параметром D в каждый момент времени $t = \overline{1, n}$ требуется выполнить следующие шаги:

1) обновить частоты a_s, b_s , суффиксов $s_1 = x_{t-1}, \dots,$

$$s_{D+1} = x_{t-D-1} \dots x_{t-1};$$

2) пересчитать (5), (7) согласно новым значениям частот;

3) построить прогноз (8) и вычислить индикатор Y_t .

Заметим, что (5) представляет собой последовательное произведение малых чисел, что вызывает вопрос точности вычислений для больших n . Тем не менее, модификация (6) и использование логарифмирования ([5]) позволяет эффективно реализовать вычисление вероятности последовательности (7) и построение прогнозов (8). Таким образом, СТВ-предиктор, так же как и предикторы Лемпеля – Зива и SPM ([3], [4]) допускает эффективную реализацию и может быть использован в режиме прогнозирования on-line.

Приведем результаты вычислительного эксперимента по оценке мощности и уровня значимости критерия (4) на базе СТВ-предиктора с параметром $D=1$ в случае марковской альтернативы 1-го порядка с дважды стохастической (д. с.) матрицей вероятностей одношаговых переходов (в.о.п.) $P = \begin{pmatrix} p & 1-p \\ 1-p & p \end{pmatrix}$.

Нетрудно видеть, что выбранный класс цепей Маркова с д. с. матрицей в.о.п. принадлежит однопараметрическому экспоненциальному семейству с параметром p , причем стационарное распределение числа нулей и единиц в последовательности равномерно. В этом случае равномерно наиболее мощным критерием для проверки гипотезы $H_0: p = 0.5$ против двусторонней альтернативы $H_1: p \neq 0.5$ будет критерий знакоперемен [7]. На рис. 1 приведена оценка мощности критерия на базе СТВ-предиктора (о) и оценка мощности критерия знакоперемен (сплошная) для $n = 10,500$, $p = 0.4$, число экспериментов 10^3 . Можно видеть, что СТВ-предиктор проигрывает в мощности оптимальному критерию знакоперемен. Это объясняется тем, что при построении прогнозов СТВ-предиктор во взвешенной сумме (7), кроме модели цепи Маркова 1-го порядка учитывает так же возможность наличия модели источника без памяти.

Приведем результаты эксперимента с обучением предиктора по некоторой части выборки объема m , и последующим прогнозированием следующей части выборки объема n без обновления частот в контекстном дереве. Мощность критерия на базе предиктора СТВ примет вид (6) при $m = n = 500$.

Оценка уровня значимости $\alpha = 0.05$ представлена (x).




Рис. 1. Сравнение оценок мощности критериев.

Из рис. 1 видно, что критерий на базе СТВ-предиктора выдерживает заданный уровень значимости и является состоятельным.

5 ПРИМЕНЕНИЕ ПРЕДИКТОРА СТВ ДЛЯ ПОИСКА РАЗЛАДКИ

В отличие от предикторов Лемпеля – Зива и SPM, СТВ-предиктор допускает эффективную реализацию в оконном режиме. Это достигается за счет заранее известного параметра D (и, соответственно, вида контекстного дерева T_D), а также за счет того, что для пересчета модифицированной вероятности последовательности (6) требуется выполнить линейное от D число операций.

Рассмотрим следующую модель разладки. Пусть наблюдается выборка объемом $n = 20000$ бит. Первые 5000 бит являются последовательностью н. о. р. с. в. Бернулли с вероятностью успеха $p = 0.5 + \varepsilon$, следующие 5000 бит являются последовательностью н. о. р. с. в. Бернулли с вероятностью успеха $p = 0.5 - \varepsilon$, затем 5000 бит является цепью Маркова 1-го порядка с д.с. матрицей в.о.п. с параметром $p = 0.5 + \varepsilon$, наконец, последние 5000 бит является цепью Маркова 1-го порядка с д.с. матрицей в.о.п. с параметром $p = 0.5 - \varepsilon$.

Можно видеть, что для каждой части такой последовательности существуют оптимальные критерии — критерий знаков [7] для первых двух фрагментов, критерий знакоперемен для последних. Однако принятие решение по всей выборке с использованием данных критериев приведет к мощности на уровне значимости. Поэтому для поиска такого рода разладки проведем эксперимент с использованием скользящего окна.




Рис.2. Сравнение оценок мощности для поиска разладки.
Длина окна 2000.

Пусть используется скользящее окно длины m по пересекающимся интервалам. Внутри окна ведется подсчет статистик критериев знаков, знакоперемен, принимается решение о принятии H_0 после чего окно сдвигается на единицу. Легко видеть, что каждый критерий применяется $n-m$ раз ($n=20000$), и, согласно теории множественной проверки гипотез, i -й тест должен быть использован с индивидуальным уровнем значимости $\alpha_i = \alpha / (n-m)$. Если гипотеза H_0 отвергается в одном из тестов, то принимается общее решение о том, что верна гипотеза H_1 .

По наблюдаемой последовательности строится последовательность индикаторов успеха прогнозов с использованием предиктора СТW, который так же действует в оконном режиме (т.е. прогноз x_t строится по x_t^f , если $t \leq m$, по x_{t-m+1}^f , иначе). Решение принимается по всей последовательности индикаторов длиной 20000.

На рис.2 приведены результаты оценки мощности в случае $m=2000, \epsilon=0.005, 0.01, \dots, 0.05$. Результаты оценки мощности для $m=200, \epsilon=0.005, 0.01, \dots, 0.05$ приведены на рисунке 3. Из рис. 2, 3 видно, что мощности критерия знаков (○) и критерия знакоперемен (×) эквивалентны, при этом использование предиктора (сплошная) в режиме скользящего окна дает значительный выигрыш в мощности.

ЛИТЕРАТУРА

[1] NIST Special Publication 800-22: A statistical test suite




Рис.3. Сравнение оценок мощности для поиска разладки.
Длина окна 200.

for random and pseudorandom number generators for cryptographic applications. – 2001.

- [2] Kostevich A.L., Shilkin A.V. On Approach to Randomness Testing on the base of the Universal Predictors // Computer Data Analysis and Modeling: Complex Stochastic Data and Systems. Proceedings of the Eighth International Conference «Computer Data Analysis and Modeling: Complex Stochastic Data and Systems» – Minsk: Belarusian State University, 2007. – Vol. 1. – P. 256–259.
- [3] Костевич А.Л., Шилкин А.В. Анализ эффективности применения универсальных предикторов для проверки гипотезы о чистой случайности // Материалы III Международной научной конференции «Сетевые компьютерные технологии» – Минск: издательский центр БГУ. – 2007. – С. 211–216
- [4] Шилкин А.В., Семенов В.И. О методике применения SPM-предиктора для тестирования бинарных последовательностей. // Материалы IV Международной конференции «Информационные системы и технологии» – Мн: Акад. упр. при Президенте Респ. Беларусь, 2008., – С. 90–95;
- [5] F.M.J. Willems, Y.M. Shtarkov, T.J. Tjalkens, The Context Tree Weighting Method : Basic properties // IEEE Trans. on Inform. Theory – 1995, – P. 653–664.
- [6] J. Suzuki. Universal prediction and universal coding // Systems and Computers, 2003. – Vol. 34(6). – P. 1–11.
- [7] Боровков А.А. Математическая статистика. – М.: Наука, Главная редакция физико-математической литературы. – 1984. – 472 с.