

# Алгоритм построения быстрых хеш-функций, основанных на замещении символов

М.И. Дябин<sup>1</sup>, А.В. Решетников<sup>2</sup>

<sup>1</sup>ООО «Каскад», г. Москва, dyabin@mail.ru

<sup>2</sup>ООО «Аккорд», г. Москва, a\_reshetnikov@hush.com

**Аннотация** — Рассматриваются хеш-функции, основанные на замещении символов алфавита целыми неотрицательными числами. Основным параметром таких функций является отображение  $T$ , осуществляющее замещение; основное назначение функций – выполнение статического хеширования; главные преимущества – высокая скорость работы и простота их реализации. Предлагается алгоритм, выполняющий оптимизацию параметра  $T$  с целью уменьшения количества коллизий для заданного словаря. Приводятся примеры эффективных хеш-функций, основанных на замещении символов.

**Ключевые слова** — быстрая хэш-функция, статическое хеширование, замещение символов алфавита.

## I. ВВЕДЕНИЕ

Понятие хеш-функции [1, раздел 6.4] хорошо известно в теории программирования. Область их применения разнообразна, в том числе хеш-функции используются для оптимизации программ, которым в процессе работы требуется произвести синтаксический анализ какого-либо длинного текста: в тех ситуациях, когда обрабатываемый текст может содержать часто повторяющиеся слова, для них целесообразно вычислить значения хешей и занести все эти значения в специальную таблицу. Действительно, поиск слова в словаре может быть существенно ускорен, если удачно подобранная хеш-функция позволяет просматривать не весь словарь целиком, а лишь ту его часть, которая содержит список всех слов с фиксированным значением хеша – общего для них и для того слова, которое требуется найти.

При разработке компиляторов, интерпретаторов, верификаторов и других программных систем – таких, которые предназначены для обработки текстовых данных, использующих некий формальный язык, содержащий ограниченный набор ключевых слов – возникает задача построения хеш-функции таким образом, чтобы с её помощью как можно эффективнее производилось распознавание ключевых слов заданного языка. Особенностью словаря в данном случае является то, что он содержит, как правило, небольшое количество слов, и набор этих слов фиксирован и известен уже на этапе разработки программы.

Задачи такого рода называются задачами *статического хеширования*. Хорошо известен один из методов их решения, представленный в статье [2].

В данной работе для задач статического хеширования мы рассматриваем новый метод решения: предлагается использовать для этой цели хеш-функции, основанные на *замещении символов* в словах некоторыми числами. Основным преимуществом нашего метода является простота его реализации; мы приведём фрагменты кода, реализующие некоторые из рассматриваемых хеш-функций.

При использовании замещения символов в простейшем случае предлагается каждому символу  $x$  из алфавита заданного языка поставить в соответствие то или иное число  $T(x)$ ; тогда хеширование произвольной строки  $s$  может быть произведено следующим образом: каждый элемент  $x \in s$  сначала замещается соответствующим ему числом  $T(x)$ , а затем над полученными числами производится какая-либо быстрая операция  $f$ . Например, если в качестве  $f$  мы возьмём сложение по модулю  $2^M$ , то тем самым полностью определим функцию, которая в данной работе будет обозначаться через  $h_0$  (более строгое её определение будет приведено далее).

Ясно, что скорость вычисления значения  $h_0(s)$  весьма высока: для получения этого значения требуется лишь извлечь из памяти  $|s|$  целых чисел ( $|s|$  – длина строки  $s$ ), выполнить их арифметическое сложение и, если это необходимо, взять остаток от деления полученной суммы на  $2^M$ . (Число  $M$  – это не что иное, как количество значащих битов в вычисленном хеше.) Однако, в случае неудачно подобранного соответствия  $T$  – оно является параметром функции  $h_0$  – общая скорость работы системы может проседать из-за возникновения *хеш-коллизий* – то есть совпадений значений  $h_0(s)$  и  $h_0(t)$  для двух различных строк  $s$  и  $t$ , взятых из словаря заданного языка. В связи с этим возникает важный вопрос:

*Каким образом можно подобрать параметр  $T$  так, чтобы для заданного словаря снизить число хеш-коллизий до приемлемого уровня?*

Настоящая работа предлагает один из возможных ответов на этот вопрос. Мы рассмотрим алгоритм, способный в случае фиксированного словаря проводить

оптимизацию параметра  $T$  не только для функции  $h_0$ , но и для более сложных хеш-функций. Эффективность данного алгоритма мы продемонстрируем на конкретном примере. Подчеркнём, что предлагаемый алгоритм не обязательно снижает число коллизий до теоретически возможного минимума.

Другой способ уменьшения числа коллизий состоит в том, чтобы перейти от функции  $h_0$  к какой-либо более сложной хеш-функции. В самом деле: если в строке  $s$  поменять местами какие-либо два символа – обозначим новую строку через  $s'$ , то  $h_0(s) = h_0(s')$  – то есть, функция  $h_0$  не способна обнаруживать в строках различия такого рода. Мы предложим ещё несколько хеш-функций – а именно,  $h_{SHR}$ ,  $h_{ROL}^{xor}$  и несколько других – обладающих почти такой же скоростью вычисления, как и  $h_0$ , но способных обеспечить гораздо меньшее число хеш-коллизий.

## II. ХЕШ-ФУНКЦИЯ $h_0$

Начнём с того, что приведём математическое определение функции  $h_0$ , о которой говорилось во введении.

Пусть  $X$  – алфавит некоторого формального языка, то есть произвольное множество, элементы которого мы будем называть *символами* данного алфавита. *Строкой* длины  $n$  называется любая последовательность символов алфавита, содержащая ровно  $n$  элементов. *Пустая строка* – это строка длины 0. Множество всех строк конечной длины, составленных из символов алфавита  $X$ , будем обозначать через  $X^*$ ; пустая строка также принадлежит множеству  $X^*$ . На практике, конечно же,  $X$  всегда является конечным множеством.

Напомним, что задача статического хеширования словаря  $L \subseteq X^*$  состоит в том, чтобы построить какое-либо отображение  $h$  множества  $X^*$  в множество целых чисел, удовлетворяющее следующим условиям:

- 1) для любой строки  $s \in X^*$  вычисление значения  $h(s)$  должно производиться достаточно быстро;
- 2) желательно, чтобы разным словарным строкам  $s \in L$  соответствовали разные значения  $h(s)$ .

Отображение  $h$  при этом называется *хеш-функцией*, а число  $h(s)$  – *хешем* строки  $s$ .

Зафиксируем целое положительное число  $M$  и какое-либо отображение  $T$  множества  $X$  в множество целых неотрицательных чисел; таким образом, каждому элементу  $x \in X$  будет поставлено в соответствие определённое число  $T(x)$ . Пусть  $s = x_1x_2...x_n$  – строка, для которой требуется найти значение  $h_0(s)$ . По определению положим

$$h_0(s) = \left( \sum_{i=1}^n T(x_i) \right) \bmod 2^M \quad (1)$$

– остаток от деления суммы на число  $2^M$ .

Из соотношения (1) видно, что функция  $h_0$  не чувствительна к порядку следования символов в строке  $s$ . Коллизии неизбежны при использовании  $h_0$ , если в словаре есть строки, отличающиеся лишь порядком следования символов. Тем не менее, даже такая, казалось бы, примитивная хеш-функция, если её параметры  $M$  и  $T$  выбраны надлежащим образом, способна обеспечить весьма эффективное хеширование. Продемонстрируем это на примере.

Рассмотрим словарь, состоящий из списка команд процессора Intel 8086. Данный словарь включает в себя 116 строк, которые представлены в табл. 1 слева от стрелок. Справа от стрелок представлены их 8-битные хеши (т.е.  $M=8$ ), вычисленные с помощью функции  $h_0$ ; в процессе вычисления следующее отображение использовано в качестве параметра  $T$ :

|           |           |           |           |           |           |           |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| A<br>0x01 | B<br>0xBF | C<br>0x9D | D<br>0xE6 | E<br>0x5D | F<br>0x90 | G<br>0x13 |
| H<br>0xE7 | I<br>0x31 | J<br>0xF3 | K<br>0x4A | L<br>0x19 | M<br>0x34 | N<br>0x8E |
| O<br>0xFA | P<br>0x93 | Q<br>0xF0 | R<br>0xF1 | S<br>0xD6 | T<br>0xB1 | U<br>0xF4 |
|           | V<br>0x00 | W<br>0x15 | X<br>0x38 | Y<br>0x18 | Z<br>0x27 |           |

(В нижних строчках ячеек указаны числа, которые отображение  $T$  ставит в соответствие буквам, указанным в верхних строчках.)

Из табл. 1 видно, что все строки  $s$ , за исключением «AAD» и «DAA», имеют различные значения  $h_0(s)$ . Единственная коллизия между «AAD» и «DAA» неизбежна, поскольку эти строки совпадают друг с другом с точностью до перестановки символов.

## III. ХЕШ-ФУНКЦИИ $h_F$ И $h_F^{xor}$

Перейдём к рассмотрению функций, способных (потенциально) обеспечить более эффективное хеширование, чем функция  $h_0$ . Их будет проще задать, если предварительно переписать определение для  $h_0$  с использованием рекуррентных соотношений.

Выберем какие-либо параметры  $M$  и  $T$  функции  $h_0$  и рассмотрим произвольную строку  $s = x_1x_2...x_n$  над алфавитом  $X$ . Положим

$$y_0 = 0; \quad y_i = y_{i-1} + T(x_i) \quad (2)$$

для всех  $i \leq n$ . Очевидно, что

$$h_0(s) = y_n \bmod 2^M. \quad (3)$$

Таблица 1

Список команд процессора Intel 8086 (слева от стрелок) и их хеши (справа от стрелок), вычисленные с помощью функции  $h_0$ . Единственная коллизия наблюдается между строками «AAD» и «DAA», которые принципиально не различимы для данной хеш-функции

|              |             |               |               |
|--------------|-------------|---------------|---------------|
| AAA → 0x03   | JA → 0xF4   | JPO → 0x80    | RCL → 0xA7    |
| AAD → 0xE8   | JAE → 0x51  | JS → 0xC9     | RCR → 0x7F    |
| AAM → 0x36   | JB → 0xB2   | JZ → 0x1A     | REP → 0xE1    |
| AAS → 0xD8   | JBE → 0x0F  | LAHF → 0x91   | REPE → 0x3E   |
| ADC → 0x84   | JC → 0x90   | LDS → 0xD5    | REPNE → 0xCC  |
| ADD → 0xCD   | JCXZ → 0xEF | LEA → 0x77    | REP NZ → 0x96 |
| AND → 0x75   | JE → 0x50   | LES → 0x4C    | REPZ → 0x08   |
| CALL → 0xD0  | JG → 0x06   | LODSB → 0x8E  | RET → 0xFF    |
| CBW → 0x71   | JGE → 0x63  | LODSW → 0xE4  | RETF → 0x8F   |
| CLC → 0x53   | JL → 0x0C   | LOOP → 0xA0   | ROL → 0x04    |
| CLD → 0x9C   | JLE → 0x69  | LOOPE → 0xFD  | ROR → 0xDC    |
| CLI → 0xE7   | JMP → 0xBA  | LOOPNE → 0x8B | SAHF → 0x4E   |
| CMC → 0x6E   | JNA → 0x82  | LOOPNZ → 0x55 | SAL → 0xF0    |
| CMP → 0x64   | JNAE → 0xDF | LOOPZ → 0xC7  | SAR → 0xC8    |
| CMPSB → 0xF9 | JNB → 0x40  | MOV → 0x2E    | SBB → 0x54    |
| CMPSW → 0x4F | JNBE → 0x9D | MOVS B → 0xC3 | SCASB → 0x09  |
| CWD → 0x98   | JNC → 0x1E  | MOVSW → 0x19  | SCASW → 0x5F  |
| DAA → 0xE8   | JNE → 0xDE  | MUL → 0x41    | SHL → 0xD6    |
| DAS → 0xBD   | JNG → 0x94  | NEG → 0xFE    | SHR → 0xAE    |
| DEC → 0xE0   | JNGE → 0xF1 | NOP → 0x1B    | STC → 0x24    |
| DIV → 0x17   | JNL → 0x9A  | NOT → 0x39    | STD → 0x6D    |
| HLT → 0xB1   | JNLE → 0xF7 | OR → 0xEB     | STI → 0xB8    |
| IDIV → 0x48  | JNO → 0x7B  | OUT → 0x9F    | STOSB → 0x16  |
| IMUL → 0x72  | JNP → 0x14  | POP → 0x20    | STOSW → 0x6C  |
| IN → 0xBF    | JNS → 0x57  | POPA → 0x21   | SUB → 0x89    |
| INC → 0x5C   | JNZ → 0xA8  | POPF → 0xB0   | TEST → 0x95   |
| INT → 0x70   | JO → 0xED   | PUSH → 0x44   | XCHG → 0xCF   |
| INTO → 0x6A  | JP → 0x86   | PUSHA → 0x45  | XLATB → 0xC2  |
| IRET → 0x30  | JPE → 0xE3  | PUSHF → 0xD4  | XOR → 0x23    |

Равенство (3) можно рассматривать как ещё одно определение функции  $h_0$ . Согласно данному определению, для того чтобы вычислить  $h_0(x_1x_2...x_n)$ , можно сначала последовательно вычислить  $y_1, y_2, ..., y_n$  по формулам (2), а затем в качестве  $h_0(s)$  взять остаток от деления числа  $y_n$  на число  $2^M$ .

Далее перейдём от (2) к формулам более общего вида. Наряду с отображением  $T$  выберем на множестве целых неотрицательных чисел какое-либо преобразование  $F$  данного множества. Введём следующее рекуррентное соотношение:

$$y_0 = 0; \quad y_i = F(y_{i-1}) + T(x_i), \quad (4)$$

где, как и раньше, через  $x_i$  обозначен  $i$ -ый символ строки  $s = x_1x_2...x_n$ , для которой требуется найти значение её хеша. Считаем по определению

$$h_F(x_1x_2...x_n) = y_n \bmod 2^M. \quad (5)$$

Равенство (5) определяет функцию  $h_F$ , параметрами которой служат два отображения –  $F$  и  $T$ , а также целое положительное число  $M$ . Мы говорим, что  $h_F$  основана на замещении символов, поскольку её основным параметром является отображение  $T$ , осуществляющее замещение символов алфавита  $X$ .

В рамках данной работы предполагается, что  $F$  – фиксированное преобразование (этим объясняется выбор обозначения « $h_F$ »), а поиск параметра  $T$  осуществляется с помощью алгоритма, который будет рассмотрен далее. Конкретные примеры преобразований  $F$ , при которых функция  $h_F$  является достаточно эффективной, будут приведены в следующем разделе.

Если в формуле (4) операцию арифметического сложения заменить операцией побитового исключающего *или* – то есть ввести новое рекуррентное соотношение

$$y_0^{xor} = 0; \quad y_i^{xor} = F(y_{i-1}^{xor}) \oplus T(x_i), \quad (6)$$

то аналогичным образом можно определить функцию

$$h_F^{xor}(x_1 x_2 \dots x_n) = y_n^{xor}, \quad (7)$$

которая также основана на замещении символов. В формуле (6) символ « $\oplus$ » обозначает операцию поразрядного сложения двух целых чисел по модулю 2. Деление с остатком в данном случае не требуется.

**Предостережение 1.** Может показаться, что определение (7) игнорирует длину хеша  $M$ ; но на самом деле это, конечно, не так: параметр  $M$  учитывается при выборе отображения  $F$  как в функции  $h_F$ , так и в функции  $h_F^{xor}$ . Действительно: если, например,  $F$  – логический сдвиг влево, то  $M$  определяет номер разряда, начиная с которого двоичные знаки числа должны игнорироваться после выполнения его сдвига. Важно помнить об этом, подготавливая реализацию какой-либо из функций  $h_F$  или  $h_F^{xor}$ : на практике должны иметь место равенства

$$y_i = (F(y_{i-1}) \bmod 2^M) + T(x_i);$$

$$y_i^{xor} = (F(y_{i-1}^{xor}) \bmod 2^M) \oplus T(x_i).$$

#### IV. ХЕШ-ФУНКЦИИ $h_{SHR}$ , $h_{ROL}^{xor}$ и $h_{ROR}^{xor}$

Приведём примеры преобразований  $F$ , для которых функции  $h_F$  и  $h_F^{xor}$  способны эффективно хешировать словари с заранее известными списками строк.

Прежде всего, рассмотрим функцию  $h_{SHR}$ , где в качестве  $F$  выбрана операция *SHR* – сдвиг числа вправо на 1 бит, или, что то же самое, целочисленное деление числа на 2. Реализация такой функции на языке программирования C может выглядеть следующим образом:

```
unsigned h=0;
for (size_t i=0; s[i] != 0; i++)
{
    unsigned c = (unsigned)s[i];
    h = (h >> 1) + table[c];
}
h &= (1u << M) - 1;
```

Здесь переменная  $s$  представляет собой строку, для которой требуется вычислить хеш  $h_{SHR}$ ; переменная  $table$  – это массив, в котором каждый элемент с индексом  $x$  содержит беззнаковое число  $T(x)$ . Длина массива  $table$  по меньшей мере на 1 больше, чем самое большое беззнаковое представление символа, встречающегося в строке  $s$ . Переменная  $M$  содержит параметр  $M$  функции  $h_{SHR}$  – количество битов в вычисляемом хеше; для упрощения реализации сделано предположение, что значение  $M$  строго меньше<sup>1</sup>, чем количество битов, содержащихся в типе *unsigned int*. После выполнения данного кода значение  $h_{SHR}(s)$  будет записано в переменную  $h$ .

Функция  $h_{SHR}$  выполняет хеширования словаря из табл. 1 без коллизий при  $M=8$  в случае, когда  $T$  – отображение, заданное следующей таблицей:

|           |           |           |           |           |           |           |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| A<br>0x4A | B<br>0x74 | C<br>0xBE | D<br>0x56 | E<br>0x18 | F<br>0x00 | G<br>0x79 |
| H<br>0x00 | I<br>0x71 | J<br>0x00 | K<br>0x00 | L<br>0x20 | M<br>0xB8 | N<br>0xA6 |
| O<br>0x00 | P<br>0x38 | Q<br>0x00 | R<br>0x04 | S<br>0x9F | T<br>0x00 | U<br>0x4E |
|           | V<br>0x00 | W<br>0x00 | X<br>0x19 | Y<br>0x00 | Z<br>0x78 |           |

Представляет интерес функция  $h_{ROL}^{xor}$ : в качестве  $F$  она использует операцию *циклического* сдвига числа на 1 бит влево, рассматривая при этом сдвигаемое число как  $M$ -битное. Данная функция также хеширует словарь из табл. 1 без коллизий при  $M=8$ , если в качестве  $T$  выбрано отображение

|           |           |           |           |           |           |           |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| A<br>0x54 | B<br>0xFF | C<br>0x3B | D<br>0x80 | E<br>0x61 | F<br>0x06 | G<br>0x92 |
| H<br>0xDE | I<br>0x7F | J<br>0x39 | K<br>0xC5 | L<br>0x15 | M<br>0x0A | N<br>0xB3 |
| O<br>0xD7 | P<br>0xDB | Q<br>0xDC | R<br>0x23 | S<br>0x71 | T<br>0x6F | U<br>0x0C |
|           | V<br>0xE4 | W<br>0x63 | X<br>0x65 | Y<br>0x16 | Z<br>0xFD |           |

Реализация функции  $h_{ROL}^{xor}$  на языке C может (при тех же допущениях) иметь следующий вид:

<sup>1</sup> В противном случае вместо «1u» требовалось бы писать «1ul».

```

unsigned h=0;
for (size_t i=0; s[i]!=0; i++)
{
    unsigned c = (unsigned)s[i];
    h = ((h<<1) | (h>>(M-1))) & ((1u<<(M-1)-1);
    h ^= table[c];
}

```

Двойственным образом определяется и реализуется функция  $h_{ROR}^{xor}$ , использующая в качестве  $F$  циклический сдвиг вправо  $ROR$  на 1 бит.

С математической точки зрения функции  $h_{ROL}^{xor}$  и  $h_{ROR}^{xor}$  интересны тем, что их значения могут быть вычислены без использования рекуррентных соотношений следующим образом:

$$\begin{aligned}
 h_{ROL}^{xor} &= \bigoplus_{i=1}^n [T(x_i) \text{ ROL } (n-i)]; \\
 h_{ROR}^{xor} &= \bigoplus_{i=1}^n [T(x_i) \text{ ROR } (n-i)],
 \end{aligned} \tag{8}$$

где через  $x \text{ ROL } a$  и  $x \text{ ROR } a$  обозначены результаты циклических сдвигов  $M$ -битного числа  $x$  влево и вправо, соответственно, на  $a$  битов.

Эксперименты показывают, что  $h_{ROL}$  и  $h_{ROR}$  – тоже весьма эффективные хеш-функции, однако, для них, вообще говоря, не выполняются соотношения, аналогичные (8).

**Предостережение 2.** Возьмём в качестве  $F$  операцию  $SHL$ , выполняющую для  $M$ -битового числа его логический сдвиг влево на 1 бит. Функция  $h_{SHL}$  обладает тем недостатком перед функцией  $h_{SHR}$ , что всякий раз после выполнения сдвига влево какого-либо числа  $y$  полученное значение  $y \ll 1$  необходимо подвергать взятию от него остатка от деления на  $2^M$ : в противном случае появление лишних битов в числе  $y \ll 1$  может привести к результату, отличному от  $h_{SHL}(s)$ , а также нарушить кроссплатформенность реализации функции.

**Предостережение 3.** Согласно экспериментам, хеш-функции  $h_{SHR}^{xor}$  и  $h_{SHL}^{xor}$  не столь эффективны, как хеш-функции  $h_{SHR}$  и  $h_{SHL}$ .

#### V. АЛГОРИТМ ОПТИМИЗАЦИИ ПАРАМЕТРА $T$

Пусть  $T: X \rightarrow Y$  – любое отображение. Введём следующее обозначение: если  $\alpha \in X$  и  $\beta \in Y$  – произвольные элементы, то обозначим через  $T_{\alpha \mapsto \beta}$  отображение такое, что  $T_{\alpha \mapsto \beta}(x) = T(x)$  для всех  $x \in X \setminus \{\alpha\}$  и  $T_{\alpha \mapsto \beta}(\alpha) = \beta$ . Другими словами, если  $T$  задано некоторой таблицей  $table$ , то после выполнения команды

$table[\alpha] := \beta$  та же таблица будет задавать отображение  $T_{\alpha \mapsto \beta}$ .

Опыт показывает, что для функций  $h_F$  и  $h_F^{xor}$  параметр  $T$  следует подбирать итерационно следующим образом.

**Шаг 1.** Изначально в качестве  $T$  можно взять любое отображение (например, проще всего положить  $T(x) = 0$  для всех  $x$ ).

**Шаг 2.** Если текущее значение  $T$  позволяет избежать коллизий (либо если при заданных начальных условиях известно минимальное теоретически возможное число коллизий и это число достигается при текущем значении параметра  $T$ ), то поиск оптимального значения  $T$  завершён.

**Шаг 3.** Если среди всех отображений вида  $T_{\alpha \mapsto \beta}$  есть такое отображение  $T_{\alpha_0 \mapsto \beta_0}$ , при котором число коллизий уменьшается, следует положить  $T := T_{\alpha_0 \mapsto \beta_0}$  и перейти к шагу 2.

**Шаг 4.** Иначе следует провести рандомизацию параметра  $T$  и перейти к шагу 2.

Все таблицы для  $T$ , представленные в данной работе, были получены с использованием данного алгоритма. При поиске параметра  $T$  для функции  $h_{SHR}$  понадобилось всего лишь 16 итераций, при этом ни разу не был выполнен шаг 4 (изначально было выбрано  $T(x) = 0$  при всех  $x$ ).

Шаг 4 требует отдельного внимания. Рандомизация таблицы означает генерацию псевдослучайного вектора достаточно большой размерности. Желательно при этом, чтобы алгоритм рандомизации был детерминирован: при одних и тех же начальных условиях желательно, чтобы в конце концов алгоритм всегда находил одно и то же отображение  $T$ . Такой детерминированный алгоритм генерации псевдослучайных векторов представлен в работе [3]. В той же статье подробно обсуждаются общие способы решения данной проблемы.

#### VI. ВЫВОДЫ

Были рассмотрены функции  $h_F$  и  $h_F^{xor}$  при различных значениях параметра  $F$ . На примере словаря, состоящего из команд микропроцессора Intel 8086, было показано, что  $h_{SHR}$  и  $h_{ROL}^{xor}$  при надлежащем выборе значения  $T$  способны провести статическое хеширование данного словаря без коллизий, а функция  $h_0$  способна снизить число коллизий до единственной коллизии, которую в данном случае невозможно исключить принципиально. Также был предложен алгоритм, позволяющий находить  $T$  в случае произвольного словаря.

Отображение  $T$  осуществляет замену символов алфавита целыми неотрицательными числами. Исполь-

зование отображений такого вида с целью построения хеш-функций ранее было предложено П.К.Пирсоном в работе [4]. Введённая им функция при попытке хешировать с её помощью словарь из табл. 1 всякий раз приводила к возникновению нескольких десятков коллизий, даже после оптимизации параметра  $T$  по описанному выше алгоритму.

Таким образом, если размер словаря не слишком велик, то, скорее всего, предложенный в данной работе алгоритм сможет за приемлемое время подобрать для него параметр  $T$ , при котором хеширование данного словаря с помощью функций  $h_0$ ,  $h_{SHR}$ ,  $h_{ROL}^{xor}$  или  $h_{ROR}^{xor}$  оказывается весьма эффективным. Авторы не исключают того, что одновременный поиск параметров  $F$  и  $T$  для функций  $h_F$  и  $h_F^{xor}$  в принципе мог бы обеспечить ещё более высокое качество статического хеширования. Но для выполнения такого поиска авторам алгоритм неизвестен.

## An Algorithm of Building Fast Hash Functions Based on Replacement of Symbols

M.I. Dyabin<sup>1</sup>, A.V. Reshetnikov<sup>2</sup>

<sup>1</sup>“Kaskad” Ltd., Moscow, dyabin@mail.ru

<sup>2</sup>“Accord” Ltd., Moscow, a\_reshetnikov@hush.com

**Abstract** — Let there be given a formal language  $X$ . Let  $T$  be a mapping which replaces the symbols of  $X$  by non-negative integer numbers. For any sequence  $s = x_1x_2...x_n$  of elements of  $X$ , suppose that  $y_0 = 0$ ,  $y_i = (y_{i-1} \text{ div } 2) + T(x_i)$  for all  $i$ . Let us define  $h_{SHR}(s) = (y_n \text{ mod } 2^M)$ , where  $M$  is a positive integer number, say  $M = 8$ . So  $h_{SHR}$  is an example of a function based on replacement of alphabetical symbols.  $M$  and  $T$  are the parameters of the function. If both parameters are chosen correctly,  $h_{SHR}$  becomes very effective for hashing a given dictionary statically; an example is given in this paper. There are some other functions, based on replacement of symbols, which are also quite suitable for static hashing. The main problem is how to find an appropriate value for  $T$ . A possible solution is offered. The core idea is that if it is possible to fix  $T$  in exactly one element in order to reduce the number of hash collisions, this should be done; otherwise  $T$  should be randomized.

**Keywords** — fast hash function, static hashing, replacement of alphabetic symbols.

### REFERENCES

- [1] Knuth D.E. The Art of Computer Programming. V. 3. Searching and Sorting. Second Edition. Reading, Massachusetts: Addison – Wesley, 1973. xiv + 782 pp.
- [2] Fredman M.L., Komlós J., Szemerédi E. Storing a Sparse Table with  $O(1)$  Worst Case Access Time // Journal of the ACM. 1984. V. 31. № 3. P. 538–544.
- [3] Дябин М.И., Решетников А.В., Саксонов Е.А. Быстрый метод генерации псевдослучайных векторов большой размерности для тестирования систем на кристалле // Проблемы разработки перспективных микро- и нанoeлектронных систем (МЭС). 2021. Выпуск 4. С. 86–91. doi:10.31114/2078-7707-2021-4-86-91 (in Russian).
- [4] Pearson P.K. Fast Hashing of Variable-Length Text Strings // Communications of the ACM. 1990. V. 33. № 6. P. 677–680.

### ЛИТЕРАТУРА

- [1] Knuth D.E. The Art of Computer Programming. V. 3. Searching and Sorting. Second Edition. Reading, Massachusetts: Addison – Wesley, 1973. xiv + 782 pp. (Кнут Д.Э. Искусство программирования. Том 3. Сортировка и поиск. 2-е изд. Пер. с англ. М.: И. Д. «Вильямс», 2007. 824 с.)
- [2] Fredman M.L., Komlós J., Szemerédi E. Storing a Sparse Table with  $O(1)$  Worst Case Access Time // Journal of the ACM. 1984. V. 31. № 3. P. 538–544.
- [3] Дябин М.И., Решетников А.В., Саксонов Е.А. Быстрый метод генерации псевдослучайных векторов большой размерности для тестирования систем на кристалле // Проблемы разработки перспективных микро- и нанoeлектронных систем (МЭС). 2021. № 4.С. 86–91.
- [4] Pearson P.K. Fast Hashing of Variable-Length Text Strings // Communications of the ACM. 1990. V. 33. № 6. P. 677–680.