

В. С. ПРОСКУРОВ

ТЕОРЕМА О КОДИРОВАНИИ ВЫСКАЗЫВАНИЙ
В ПРОИЗВОЛЬНЫХ ЯЗЫКАХ

(Представлено академиком И. М. Виноградовым 26 III 1970)

Проблема кодирования ⁽¹⁾ содержательных или формальных текстов является одной из проблем обработки информации. Основной трудностью является нахождение эффективного взаимно однозначного кодирования. В работе ⁽²⁾ рассмотрены различные правила кодирования слов некоторого словаря, состоящего из N слов, основное из которых — операция свертывания ∇_k кодов слов, содержащих l_i букв, до кодов, содержащих k букв ($k \leq l_i$, $1 \leq i \leq N$). В теореме 2 работы ⁽²⁾ доказывается, что свертывание ∇_k — неоднозначное кодирование с вероятностью нарушения однозначности, стремящейся к нулю при $k \rightarrow l = \max_{1 \leq i \leq N} \{l_i\}$. Причем кодирование становится однозначным лишь при $k = l = \max_{1 \leq i \leq N} \{l_i\}$. Свертывание ∇_k не позволяет по коду длины k определить исходное слово. При распространении теоремы 2 на высказывания величина k соответственно увеличится.

Ниже доказывается теорема о том, что существует взаимно однозначное кодирование, позволяющее любое высказывание представить кодом любой наперед заданной длины (например, $k = 1$), по которому можно восстановить исходное высказывание.

Введем необходимые определения и обозначения.

Алфавит \mathfrak{A} есть строго упорядоченная последовательность n попарно различных символов с порядковыми номерами $0, 1, 2, \dots, n-1$:

$$\mathfrak{A} = a_0 a_1 a_2 \dots a_{n-1} = (a_i, i = 0, 1, 2, \dots, n-1). \quad (1)$$

Символ a_0 будем называть пробелом.

Всякая совокупность букв из алфавита \mathfrak{A} , не содержащая ни одного пробела, называется словом в алфавите \mathfrak{A} :

$$\sigma_l(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l) = a_{i_1} a_{i_2} \dots a_{i_k} \dots a_{i_l}. \quad (2)$$

В дальнейшем всегда будем иметь в виду, что $1 \leq i_k \leq n-1$ для всех $k = 1, 2, \dots, l$ при $l \geq 1$.

Число букв, входящих в данное слово, будем называть длиной слова в алфавите \mathfrak{A} и обозначать через l .

По определению при $l = 0$ будем считать $k = 0$, $i_k = 0$, $\sigma_0(\mathfrak{A}, 0) = a_0$ — пустое слово в алфавите \mathfrak{A} .

Словарем $\Sigma_N(\mathfrak{A})$ в алфавите \mathfrak{A} назовем подмножество $\{\sigma_r(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_r)\}$ множества $\Sigma(\mathfrak{A})$ всех слов в алфавите \mathfrak{A} , состоящее из N слов, где $1 \leq r \leq N$:

$$\Sigma_N(\mathfrak{A}) = \{\sigma_r(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_r)\} \subset \Sigma(\mathfrak{A}), \quad (3)$$

где $r = 1, 2, \dots, N$.

Аналогично введем:

$$\mathfrak{B} = b_0 b_1 b_2 \dots b_{m-1} = (b_i, i = 0, 1, 2, \dots, m-1), \quad (4)$$

b_0 — пробел в алфавите \mathfrak{B} ,

$$\sigma_l(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l) = b_{i'_1} b_{i'_2} \dots b_{i'_k} \dots b_{i'_l} \quad (5)$$

слово в алфавите \mathfrak{B} , $1 \leq i \leq m-1$ для всех $k=1, 2, \dots, l$ при $l \geq 1$, где l — длина слова в алфавите \mathfrak{B} .

По определению при $l=0$ будем считать $k=0$, $i_k'=0$, $\tau_0(\mathfrak{B}, 0) = b_0$ — пустое слово в алфавите \mathfrak{B} .

$$\Sigma_N(\mathfrak{B}) = \{\sigma_{i_r}(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l)\} \subset \Sigma(\mathfrak{B}), \quad (6)$$

где $r=1, 2, \dots, N$; $\Sigma_N(\mathfrak{B})$ — словарь в алфавите \mathfrak{B} , содержащий N слов; $\Sigma(\mathfrak{B})$ — множество всевозможных слов в алфавите \mathfrak{B} .

Будем называть $K = (K'(\mathfrak{A}, \mathfrak{B}), K''(\mathfrak{B}, \mathfrak{A}))$ взаимно однозначным кодированием слов (или просто кодированием) в алфавите \mathfrak{A} словами в алфавите \mathfrak{B} и обратно, если

$$K'(\mathfrak{A}, \mathfrak{B}) (\sigma_{i_1}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l)) = \sigma_{i'_2}(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l), \quad (7)$$

$$K''(\mathfrak{B}, \mathfrak{A}) (\sigma_{i'_2}(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l)) = \sigma_{i_1}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l), \quad (8)$$

где $K'(\mathfrak{A}, \mathfrak{B})$ — однозначное преобразование (кодирование) слова в алфавите \mathfrak{A} в слово в алфавите \mathfrak{B} (допускается случай $\mathfrak{A} = \mathfrak{B}$) для любого слова из $\Sigma(\mathfrak{A})$; $K''(\mathfrak{B}, \mathfrak{A})$ — однозначное преобразование (кодирование) слова в алфавите \mathfrak{B} в слово в алфавите \mathfrak{A} (допускается случай $\mathfrak{B} = \mathfrak{A}$) для любого слова из $\Sigma(\mathfrak{B})$.

Согласно определению кодирования K устанавливает взаимно однозначное соответствие между словами (2) из $\Sigma(\mathfrak{A})$ и (6) из $\Sigma(\mathfrak{B})$

$$\sigma_i(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l) \xleftrightarrow{K} \sigma_{i'_r}(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l). \quad (9)$$

Следовательно, зная $\Sigma_N(\mathfrak{A})$, с помощью кодирования $K'(\mathfrak{A}, \mathfrak{B})$ можно получить $\Sigma_N(\mathfrak{B})$ и обратно — зная $\Sigma_N(\mathfrak{B})$, с помощью кодирования $K''(\mathfrak{B}, \mathfrak{A})$ можно получить $\Sigma_N(\mathfrak{A})$.

Теорема 1. Для любого словаря $\Sigma_N(\mathfrak{A}) \subset \Sigma(\mathfrak{A})$ существует взаимно однозначное кодирование K и алфавит \mathfrak{B} такие, что для каждого $\sigma_{i_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l) \in \Sigma_N(\mathfrak{A})$, $1 \leq r \leq N$, будут справедливы соотношения:

$$K'(\mathfrak{A}, \mathfrak{B}) (\sigma_{i_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l)) = \sigma_{i'_2}(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l),$$

$$K''(\mathfrak{B}, \mathfrak{A}) (\sigma_{i'_2}(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l)) = \sigma_{i_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l),$$

причем l может быть любым наперед заданным целым положительным числом с условием $l > l_r$ или $l \leq l_r, l_{r-1}, l_{r-2}, \dots, 1$.

Доказательство. Пусть задан алфавит (1). Возьмем позиционную систему счисления с основанием n и цифрами

$$0, 1, 2, \dots, n-1 = (k, k=0, 1, 2, \dots, n-1). \quad (10)$$

Установим взаимно однозначное соответствие между символами алфавита \mathfrak{A} и цифрами системы счисления (10) так, чтобы символу $a_k \in \mathfrak{A}$, стоящему в последовательности (1) на k -м месте, соответствовала цифра k из последовательности (10), стоящая на k -м месте, и обратно. Обозначим правило, устанавливающее это соответствие, через F^n :

$$a_k \xleftrightarrow{F^n} k, \quad 0 \leq k \leq n-1. \quad (11)$$

Возьмем слово $\sigma_{i_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l) \in \Sigma_N(\mathfrak{A})$. В силу правила F^n (11) слову $\sigma_{i_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l)$ соответствует одно и только одно целое положительное число

$$i_1 i_2 \dots i_k \dots i_l (n) = i_1 n^{l-1} + i_2 n^{l-2} + \dots + i_l = \sum_{k=1}^{i_r} i_k n^{l-k}$$

в позиционной системе счисления с основанием n и обратно:

$$F^n(\sigma_{l_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_{l_r})) = i_1 i_2 \dots i_k \dots i_{l_r}(n), \quad (12)$$

$$F^n(i_1 i_2 \dots i_k \dots i_{l_r}(n)) = \sigma_{l_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_{l_r}). \quad (13)$$

Количество цифр в записи числа будем называть длиной числа.

Имеет место следующее утверждение:

Л е м м а. Пусть заданы $l' = \max_{1 \leq r \leq N} \{l_r\}$ и l — целые положительные чис-

ла. Для любого целого положительного числа не больше $i_1, i_2, \dots, i_k, \dots, i_{l_r}(n)$ в позиционной системе счисления с основанием n найдется равное ему число длиной не больше l в позиционной системе счисления с основанием $m = [n^{l'/l}]'$, где

$$[n^{l'/l}]' = \begin{cases} n^{l'/l}, & \text{если } n^{l'/l} \text{ целое число} \\ [n^{l'/l}] + 1, & \text{в противном случае,} \end{cases}$$

$[n^{l'/l}]'$ — целая часть числа $n^{l'/l}$.

Из справедливости леммы следует, что любое число длины не большей l' в позиционной системе счисления с основанием n может быть представлено равным ему числом длиной не больше l в позиционной системе счисления с основанием m .

Пусть R_m^n — правило перевода чисел из позиционной системы счисления с основанием n в числа позиционной системы счисления с основанием m , а R_n^m — обратное правило (3).

Тогда

$$R_m^n(i_1 i_2 \dots i_k \dots i_{l_r}(n)) = i'_1 i'_2 \dots i'_k \dots i'_l(m), \quad (14)$$

$$R_n^m(i'_1 i'_2 \dots i'_k \dots i'_l(m)) = i_1 i_2 \dots i_k \dots i_{l_r}(n), \quad (15)$$

где $i'_1, i'_2, \dots, i'_k, \dots, i'_l$ — цифры позиционной системы счисления с основанием m и цифрами

$$0, 1, 2, \dots, m-1 = (k, k = 0, 1, 2, \dots, m-1). \quad (16)$$

Пусть F^m — правило, устанавливающее взаимно однозначное соответствие между символами в алфавите (4) и цифрами позиционной системы счисления с основанием m (16), аналогично правилу (11):

$$b_k \xrightarrow{F^m} k, \quad 0 \leq k \leq m-1. \quad (17)$$

Следовательно,

$$F^m(i'_1 i'_2 \dots i'_k \dots i'_l(m)) = \sigma_l(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l), \quad (18)$$

$$F^m(\sigma_l(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l)) = i'_1 i'_2 \dots i'_k \dots i'_l(m). \quad (19)$$

Таким образом, вследствие (12), (14), (18) имеем

$$\begin{aligned} \sigma_{l_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_{l_r}) &\xrightarrow{F^n} i_1 i_2 \dots i_k \dots i_{l_r}(n) \xrightarrow{R_m^n} \\ &= i'_1 i'_2 \dots i'_k \dots i'_l(m) \xrightarrow{F^m} \sigma_l(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l), \end{aligned}$$

где

$$m = [n^{l'/l}]', \quad l = \max_{1 \leq r \leq N} \{l_r\}.$$

Если в качестве $K'(\mathfrak{A}, \mathfrak{B})$ использовать последовательно F^n (11), R_m^n , F^m (17), то

$$K'(\mathfrak{A}, \mathfrak{B})(\sigma_{l_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_{l_r})) = \sigma_l(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l).$$

Аналогично, вследствие (13), (15), (19), имеем

$$\sigma_l(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l) \stackrel{F^m}{\Leftrightarrow} i'_1 i'_2 \dots i'_k \dots i'_l (m) \stackrel{R_n^m}{=} i_1 i_2 \dots i_k \dots i_l (n) \stackrel{F^n}{\Leftrightarrow} \stackrel{F^n}{\Leftrightarrow} \sigma_{l_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l),$$

где

$$m = |n^{l_r}|', \quad l = \max_{1 \leq r \leq N} \{l_r\}.$$

Если в качестве $K''(\mathfrak{B}, \mathfrak{A})$ использовать последовательно F^m (17), R_n^m , F^n (11), то

$$K''(\mathfrak{B}, \mathfrak{A})(\sigma_l(\mathfrak{B}, i'_1, i'_2, \dots, i'_k, \dots, i'_l)) = \sigma_{l_r}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_l).$$

Тем самым теорема доказана полностью.

Назовем высказыванием в алфавите \mathfrak{A} конечную совокупность слов (2) в алфавите \mathfrak{A} (1), объединенную в одно слово с помощью пробелов a_0 :

$$\sigma_{i_1}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_{l_1}) a_0 \sigma_{i_2}(\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_{l_2}) a_0 \dots a_0 \sigma_{i_s} \times \\ \times (\mathfrak{A}, i_1, i_2, \dots, i_k, \dots, i_{l_s}).$$

Длиной высказывания назовем количество символов в нем, включая пробелы между словами,

$$l = \sum_{k=1}^s (l_k + 1) - 1.$$

Совокупность всевозможных высказываний из слов словаря $\Sigma_N(\mathfrak{A})$ (3) будем обозначать через $D(\Sigma_N(\mathfrak{A}))$.

Аналогично введем высказывание в алфавите \mathfrak{B} (4) и $D(\Sigma_N(\mathfrak{B}))$ — множество всевозможных высказываний из слов словаря $\Sigma_N(\mathfrak{B})$ (6).

Очевидно, правила K^n (11), R_m^n , F^m (17), R_n^m можно распространить и на высказывания. Тогда доказанная теорема будет справедлива и для произвольных высказываний из $D(\Sigma_N(\mathfrak{A}))$.

Отдел по внедрению экономико-математических методов
в планирование народного хозяйства
Госплана СССР
Москва

Поступило
5 III 1970

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

- ¹ А. И. Мальцев, Алгоритмы и рекурсивные функции, «Наука», 1965. ² Л. Н. Королёв, ДАН, 113, № 4 (1957). ³ А. И. Китов, Н. А. Крилицкий, Электронные цифровые машины и программирование, М., 1961.