

УДК 519.714

## АДДИТИВНАЯ СЛОЖНОСТЬ СЛОВ С ОГРАНИЧЕНИЯМИ НА СОСТАВ ПОДСЛОВ\*)

В. Н. Потапов

Аддитивной сложностью слова называется длина кратчайшей схемы конкатенации, порождающей это слово. Для слов длины  $n$ , удовлетворяющих различным ограничениям на состав подслов, получены асимптотические (при  $n \rightarrow \infty$ ) верхние оценки аддитивной сложности. Показано, что эти оценки неупрощаемы для наиболее сложных слов из рассматриваемых множеств.

### Введение

Пусть  $A$  — конечный алфавит и  $A^* = \bigcup_{m=0}^{\infty} A^m$  — множество конечных слов в алфавите  $A$ ,  $|A| \geq 2$ . Через  $uw$  будем обозначать конкатенацию слов  $u, w \in A^*$ . Символом  $\lambda$  обозначим "пустое" слово. *Схемой конкатенации* называется последовательность слов  $\alpha = v(0), v(1), \dots, v(m)$  такая, что каждое слово  $v(i)$  является либо буквой из  $A$ , либо конкатенацией предыдущих слов  $v(j_1)$  и  $v(j_2)$ , т. е.  $v(i) = v(j_1)v(j_2)$ , где  $j_1, j_2 < i$ . Говорят, что  $v(0), v(1), \dots, v(m)$  — схема конкатенации множества  $M \subset A^*$ , если все слова множества  $M$  содержатся в схеме конкатенации, т. е.  $M \subseteq \{v(0), v(1), \dots, v(m)\}$ . *Аддитивной сложностью* множества  $M$  называется величина  $l(M) = \min m$ , где минимум берется по всем схемам конкатенации множества  $M$ . В работах [5], [8], [9] указанная величина называлась мультипликативной сложностью. Однако по предложению А. А. Евдокимова термин "мультипликативная" заменен на более подходящий термин "аддитивная". Ниже речь пойдет в основном об аддитивной сложности множеств, состоящих из одного слова  $w \in A^*$ , которую будем обозначать через  $l(w)$ .

---

\*) Исследование выполнено при финансовой поддержке Российского фонда фундаментальных исследований (проект 02-01-00939), Министерства образования (проект Е 02-6.0-250), Совета по грантам Президента РФ и государственной программы поддержки ведущих научных школ (проект НШ-313.2003.1) и СО РАН (интеграционный проект 119).

Пусть  $B \subset A^*$ . Определим величину  $L(B)$  равенством

$$L(B) = \max_{w \in B} l(w).$$

В работе [5] установлена следующая асимптотика (при  $n \rightarrow \infty$ ):

$$L(M(n - k_n, k_n)) \sim \log n + \frac{\log |M(n - k_n, k_n)|}{\log \log |M(n - k_n, k_n)|},$$

где  $M(n - k_n, k_n)$  — множество двоичных слов длины  $n$ , в каждом из которых содержится  $k_n$  единиц. Здесь и далее  $\log x = \log_2 x$ . В настоящей работе установлены асимптотики (при  $n \rightarrow \infty$ ) вида  $L(B_n) \sim \frac{\log |B_n|}{\log \log |B_n|}$ , где  $B_n \subset A^n$  есть множество слов с одинаковым составом подслов фиксированной длины, или множество слов с запретами на подслова, или множество высоковероятных слов относительно некоторых вероятностных распределений. Некоторые из полученных асимптотик справедливы при определенных ограничениях снизу на скорость роста мощности множества  $B_n$  при  $n \rightarrow \infty$ .

Нижние оценки величины  $L(B_n)$  для разных  $B_n$  получены мощностным методом и основываются на результатах статьи [5]. Как замечено в работе [6], следующее утверждение непосредственно вытекает из [6, теорема Д.2].

**Утверждение 1.** Пусть  $B_1, B_2, \dots, B_n, \dots$  — последовательность множеств таких, что  $B_n \subset A^*$  и  $h_n = \log |B_n| \rightarrow \infty$  при  $n \rightarrow \infty$ . Тогда

$$L(B_n) \geq \frac{h_n}{\log h_n} \left( 1 + (1 + o(1)) \frac{\log h_n}{\log \log h_n} \right).$$

Верхние оценки для величины  $L(B_n)$  получены конструктивно. Как в работе [5], сначала определяются величины  $l(M_\alpha)$  для некоторых вспомогательных множеств  $M_\alpha \subset A^*$ , а затем из элементов этих множеств строятся схемы конкатенации для слов  $w \in B_n$ . В отличие от работы [5] для построения множеств  $M_\alpha$  используется вероятностный подход: на множестве слов  $A^*$  определяется вероятностное распределение и в множество  $M_\alpha$  включаются слова с вероятностями выше фиксированной. Это позволяет упростить структуру вспомогательных множеств  $M_\alpha$ , обобщить результаты статьи [5] и в некоторых случаях получить более точные верхние оценки. Результаты настоящей статьи анонсированы в [8], [9].

### 1. Марковские источники

Одним из наиболее важных инструментов, применяемых в настоящей статье, является понятие марковского источника и сопутствующий математический аппарат. *Марковским источником*  $S$  называется четверка  $(A, \Omega, \mu_S, p_S)$ , состоящая из конечного алфавита  $A = \{a_1, \dots, a_{|A|}\}$ , конечного множества состояний  $\Omega = \{\sigma_1, \dots, \sigma_{|\Omega|}\}$ , функции  $\mu_S : \Omega \times A \rightarrow \Omega$ , задающей переходы из одного состояния в другое, и набора вероятностей  $p_S(a|\sigma)$  букв  $a \in A$  в состояниях  $\sigma \in \Omega$ ,  $0 \leq p_S(a|\sigma) \leq 1$ . В другой терминологии марковский источник можно называть стохастическим конечным автоматом, а множество порождаемых им слов — стохастическим регулярным языком.

Функцию  $\mu_S$  удобно представлять в виде ориентированного графа  $G(\mu_S)$ , вершинами которого являются состояния источника. Два состояния  $\sigma'$  и  $\sigma''$  соединены дугой, помеченной буквой  $a$ , если  $\mu_S(\sigma', a) = \sigma''$  и  $p_S(a|\sigma') > 0$ . Источник  $S$  называется *неразложимым*, если ориентированный граф  $G(\mu_S)$  является сильно связанным. Неразложимый источник  $S$  называется *периодическим*, если в ориентированном графе  $G(\mu_S)$  длины всех контуров кратны некоторому целому числу  $d > 1$ . Если  $d = |\Omega|$ , т. е. ориентированный граф  $G(\mu_S)$  состоит из одного контура, то источник  $S$  будем называть *тривиальным*. В последнем случае вероятности всех букв равны 0 или 1.

Расширим область определения функции  $\mu_S$  и вероятности  $p_S$  с алфавита  $A$  на множество слов  $A^*$  с помощью рекуррентных формул:

$$\mu_S(\sigma, a_{i_1} a_{i_2} \dots a_{i_m}) = \mu_S(\mu_S(\sigma, a_{i_1}), a_{i_2} \dots a_{i_m}), \quad (1)$$

$$p_S(a_{i_1} a_{i_2} \dots a_{i_m} | \sigma) = p_S(a_{i_2} \dots a_{i_m} | \mu_S(\sigma, a_{i_1})) p_S(a_{i_1} | \sigma). \quad (2)$$

Пусть слово  $w \in A^*$  представлено в виде  $w = w_1 w_2 \dots w_m$ . Тогда из равенств (1) и (2) получаем

$$p_S(w|\sigma) = p_S(w_1|\tau_1) p_S(w_2|\tau_2) \dots p_S(w_m|\tau_m), \quad (3)$$

где  $\tau_1 = \sigma$  и  $\tau_j = \mu_S(\tau_{j-1}, w_{j-1})$ .

По определению вероятности букв в произвольном состоянии  $\sigma \in \Omega$  удовлетворяют равенству  $\sum_{a \in A} p_S(a|\sigma) = 1$ . Тогда из рекуррентной формулы (3) для любого слова  $w \in A^*$  и любого целого числа  $m > 0$  по индукции можно получить равенства

$$\sum_{a \in A} p_S(wa|\sigma) = p_S(w|\sigma) \text{ и } \sum_{w \in A^m} p_S(w|\sigma) = 1. \quad (4)$$

Последовательность состояний марковского источника образует однородную марковскую цепь, если вероятности переходов задать равенствами  $p(\mu_S(\sigma, a)|\sigma) = p_S(a|\sigma)$ . Данные выше определения неразложимого и периодического марковских источников соответствуют определениям неразложимой и периодической марковских цепей для состояний источника (см., например, [2, гл. 11, § 1]). В дальнейшем это позволит воспользоваться некоторыми фактами из теории марковских цепей.

Источник  $S$  называется *марковским источником  $k$ -го порядка*, если  $\Omega \subseteq A^k$  и для каждой  $a \in A$  справедливо равенство  $\mu_S(a_{i_1} a_{i_2} \dots a_{i_k}, a) = a_{i_2} \dots a_{i_k} a$ . В этом случае вклад вероятности буквы в вероятность слова зависит только от  $k$  предыдущих букв. Однако остается неопределенность в вычислении вероятности  $k$  первых букв каждого слова. Чтобы избежать этого, в дальнейшем для слова  $w \in A^*$  полагаем  $p_S(w) = p_S(w|w')$ , где  $w' \in A^k$  — суффикс длины  $k$  слова  $w$ . Таким образом, для марковского источника  $S$   $k$ -го порядка вероятность слова длины  $n, n > k$ , вычисляем по формуле

$$p_S(a_{i_1} a_{i_2} \dots a_{i_n}) = p_S(a_{i_1} | a_{i_{n-k+1}} \dots a_{i_n}) \times p_S(a_{i_2} | a_{i_{n-k+2}} \dots a_{i_n} a_{i_1}) \dots p_S(a_{i_n} | a_{i_{n-k}} \dots a_{i_{n-1}}), \quad (5)$$

согласующейся с формулой (3).

Граф  $G(\mu_S)$ , соответствующий марковскому источнику  $k$ -го порядка, является подграфом графа де Брейна  $G_k$ , т. е. вершинами графа  $G(\mu_S)$  являются слова  $w \in A^k$  и слова вида  $bw'$  и  $w'a$ , где  $w' \in A^{k-1}$  и  $a, b \in A$ , соединены дугой, ориентированной из  $w'$  в  $w'a$ . Пусть  $w = a_{i_1} a_{i_2} \dots a_{i_n} \in A^n$  и  $\tau, \sigma \in \Omega$ . Введем обозначения:

$$I_S(w|\sigma) = -\log p_S(w|\sigma) = -\sum_{j=1}^n \log p_S(a_{i_j} | \tau_j), \quad (6)$$

где  $\tau_1 = \sigma$ ,  $\tau_j = \mu_S(\tau_{j-1}, a_{i_{j-1}})$ ,

$$I_{S,\tau}(w|\sigma) = -\sum \log p_S(a_{i_j} | \tau), \quad (7)$$

а сумма берется по всем  $j$  таким, что  $\tau_j = \tau$ . Очевидно справедливо равенство

$$I_S(w|\sigma) = \sum_{\tau \in \Omega} I_{S,\tau}(w|\sigma). \quad (8)$$

Если  $S$  — марковский источник  $k$ -го порядка, то для слова  $w \in A^*$  длины  $|w| > k$  аналогично определяются величины  $I_S(w)$  и  $I_{S,\tau}(w)$ , где  $\tau \in A^k$ .

Пусть  $x = x_1 x_2 \dots x_n \dots$  — символьная последовательность в алфавите  $A$  и слово  $x^n = x_1 x_2 \dots x_n$  — префикс (начало) длины  $n$  последовательности  $x$ . Для неразложимого непериодического марковского источника

$S$  величина  $I_S(x^n|\sigma)/n$  сходится (при  $n \rightarrow \infty$ ) по вероятности к энтропии источника  $H(S) > 0$  независимо от  $\sigma \in \Omega$  (см., например, [3, теорема 3.5.3]). Тем более имеет место сходимость в среднем:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{w \in A^n} p_S(w|\sigma) I_S(w|\sigma) = H(S).$$

Здесь и далее подразумевается, что  $0 \log 0 = 0$ .

В дальнейшем, когда это не приводит к неоднозначности, индекс  $S$  в обозначениях  $p_S, \mu_S$  и  $I_S$  будем опускать.

## 2. Оценки аддитивной сложности через вероятности слов

Множество  $T \subset A^*$ , удовлетворяющее свойству

$$\text{если } w \in T \text{ и } w = uv, \text{ то } u \in T, \quad (9)$$

обладает структурой дерева — здесь предками вершины-слова являются префиксы слова. Множество слов, обладающее свойством (9), будем называть *деревом*.

Дерево  $T \subset A^*$  будем называть *полным*, если

$$\text{для любых } a, b \in A \text{ из } wa \in T \text{ следует } wb \in T. \quad (10)$$

Обозначим через  $g(T)$  множество слов, соответствующих листьям (висячим вершинам) дерева  $T$ . Нам понадобится следующее

**Утверждение 2.** Пусть  $S$  — марковский источник в алфавите  $A$  с множеством состояний  $\Omega$  и  $T$  — дерево в алфавите  $A$ . Тогда

- (a) для любого  $\sigma \in \Omega$  справедливо неравенство  $\sum_{u \in g(T)} p(u|\sigma) \leq 1$ ;
- (b)  $l(T) = |T| - 1$ ;
- (c) если  $T$  — полное дерево, то  $|T| = |A|(|T| - |g(T)|) + 1$ ;
- (d) если каждое слово  $w \in T \setminus g(T)$  является префиксом не менее двух слов из  $T$ , то  $|T| \leq 2|g(T)| - 1$ .

Доказательство. Индукцией по числу вершин дерева нетрудно показать, что для полного дерева справедливы равенства

$$(|T| - 1) = (|g(T)| - 1) \frac{|A|}{|A| - 1} \text{ и } \sum_{u \in g(T)} p(u|\sigma) = 1.$$

Отсюда следуют (a) и (c).

Неравенства  $l(T) \leq |T| - 1$  и  $|T| \leq 2|g(T)| - 1$  также получаются индукцией по числу вершин в дереве, а неравенство  $l(T) \geq |T| - 1$  следует из определения аддитивной сложности. Утверждение 2 доказано.

Пусть  $S$  — марковский источник в алфавите  $A$  с множеством состояний  $\Omega$ ,  $\sigma \in \Omega$  и  $q > 0$ . Множество

$$M_\sigma(q) = \{u \in A^* \mid p(u|\sigma) \geq q\}$$

удовлетворяет условию (9), т. е. является деревом. Рассмотрим полное дерево

$$T_\sigma(q) = \{u \in A^* \mid u = wa, w \in M_\sigma(q), a \in A \cup \{\lambda\}\}.$$

Заметим, что  $g(T_\sigma(q)) = T_\sigma(q) \setminus M_\sigma(q)$  и для каждого  $u \in g(T_\sigma(q))$  справедливо неравенство

$$p(u|\sigma) < q. \quad (11)$$

Введем обозначение

$$\varrho_S = 1 - \max_{\sigma \in \Omega, u \in A^*} \{p(u|\sigma), \mu(\sigma, u) = \sigma\}.$$

Заметим, что  $\varrho_S > 0$  для любого неразложимого нетривиального марковского источника  $S$ .

В следующей лемме приводится верхняя оценка мощности множества  $T_\sigma(q)$ .

**Лемма 1.** Пусть  $S$  — марковский источник в алфавите  $A$  с множеством состояний  $\Omega$  и  $\varrho = \varrho_S > 0$ . Тогда при любых  $\sigma \in \Omega$  и  $q, 0 < q < 1$ , справедливо неравенство

$$|T_\sigma(q)| \leq \frac{4|A|^2|\Omega|^2}{q\varrho}.$$

Доказательство. Рассмотрим дерево

$$T' = M_\sigma(q) \cup \left( \{u \in A^* \mid p(u|\sigma) \geq \frac{q\varrho}{|\Omega||A|}\} \cap g(T_\sigma(q)) \right).$$

По определению  $T' \subset T_\sigma(q)$  и  $p(u|\sigma) \geq q\varrho/|\Omega||A|$  для любого слова  $u \in T'$ . Тогда из утверждения 2 (a) имеем

$$1 \geq \sum_{u \in g(T')} p(u|\sigma) \geq |g(T')| \frac{q\varrho}{|\Omega||A|}. \quad (12)$$

Покажем, что в дереве  $T'$  нет путей без разветвлений длиннее  $|\Omega| + 1$ . Действительно, пусть  $w, wx_1, wx_1x_2, \dots, wx_1 \dots x_k$ , где  $k > |\Omega|$ , — набор слов из  $T'$ , соответствующий такому пути. Рассмотрим набор состояний

$\tau_1 = \mu(\sigma, w), \tau_2 = \mu(\sigma, wx_1), \dots, \tau_k = \mu(\sigma, wx_1 \dots x_{k-1})$ . Найдутся  $i, j$  такие, что  $1 \leq i < j \leq k$ ,  $1 \leq j-i \leq |\Omega|$  и  $\tau_i = \tau_j$ , причем  $wx_1 \dots x_i \in M_\sigma(q)$ , так как  $i < j$ . Тогда  $p(wx_1 \dots x_{i-1}|\sigma) \geq q$  и из определения  $\varrho$  следует неравенство  $p(x_i \dots x_{j-1}|\tau_i) \leq 1 - \varrho$ . Из (4) получаем

$$p(x_i \dots x_{j-1}|\tau_i) + \sum_{k=i}^{j-1} \sum_{a \neq x_k} p(x_i \dots x_{k-1}a|\tau_i) = 1.$$

Отсюда следует, что при некоторых  $a \in A$  и  $t, i \leq t \leq j-1$ , верно неравенство

$$p(x_i \dots x_{t-1}a|\tau_i) \geq \frac{\varrho}{|A|(j-i)} \geq \frac{\varrho}{|A||\Omega|}.$$

Тогда из равенства (3) имеем

$$p(wx_1 \dots x_{t-1}a|\sigma) \geq \frac{q\varrho}{|A||\Omega|}$$

и  $wx_1 \dots x_{t-1} \in M_\sigma(q)$ . Следовательно,  $wx_1 \dots x_{t-1}a \in T'$ . Противоречие, т. е. в дереве  $T'$  нет путей без разветвлений длиннее  $|\Omega| + 1$ . Тогда из утверждения 2 (d) следует, что

$$|T'|/(|\Omega| + 1) \leq 2|g(T')| - 1. \quad (13)$$

Из утверждения 2 (c) и неравенств (12), (13) получаем

$$|T_\sigma(q)| = |A||M_\sigma(q)| + 1 \leq |A||T'| + 1 \leq 4|A||\Omega||g(T')| \leq \frac{4|A|^2|\Omega|^2}{q\varrho}.$$

Лемма 1 доказана.

По вероятности слова получим оценку его аддитивной сложности.

**Лемма 2.** Пусть  $S$  — марковский источник в алфавите  $A$  с множеством состояний  $\Omega$ ,  $w \in A^*$  и  $\sigma \in \Omega$ . Пусть числа  $I$  и  $\theta$  удовлетворяют неравенствам  $I \geq I_S(w|\sigma)$  и  $I > \theta = 4 \log^2 I |A|^2 |\Omega|^3 / \varrho_S$ . Тогда

$$l(w) \leq \frac{I}{\log I} \left( 1 + \frac{1 + \log \theta}{\log I} + \frac{\log^2 \theta}{\log I (\log I - \log \theta)} \right).$$

Доказательство. Пусть  $q = \theta/I$ , где по условию  $q < 1$ . Тогда для любого состояния  $\sigma \in \Omega$  из леммы 1 следует неравенство

$$|T_\sigma(q)| \leq \frac{I}{|\Omega| \log^2 I}.$$

Из утверждения 2 (b) имеем

$$l\left(\bigcup_{\sigma \in \Omega} T_{\sigma}(q)\right) \leq \frac{I}{\log^2 I}. \quad (14)$$

Так как для любого  $\sigma \in \Omega$  множество  $T_{\sigma}(q)$  является полным деревом, то слово  $w \in A^*$  можно представить в виде такой конкатенации  $w = w_1 w_2 \dots w_m$ , что  $w_i \in g(T_{\tau_i}(q))$  при  $i < m$  и  $w_m \in T_{\tau_m}(q)$ , где  $\tau_1 = \sigma$ ,  $\tau_i = \mu(\tau_{i-1}, w_{i-1})$ . Тогда из (11) следует, что  $p(w_i | \tau_i) < q$  при  $i < m$ . Из равенств (3) и (6) следует, что

$$p(w | \sigma) = p(w_1 | \tau_1) p(w_2 | \tau_2) \dots p(w_m | \tau_m) < q^{m-1},$$

$$I \geq I_S(w | \sigma) \geq (m-1) \log \frac{1}{q}. \quad (15)$$

Отсюда и из неравенств (14), (15) получаем неравенство

$$l(w) \leq l\left(\bigcup_{\sigma \in \Omega} T_{\sigma}(q)\right) + m - 1 \leq \frac{I}{\log \frac{1}{q}} + \frac{I}{\log^2 I}. \quad (16)$$

Используя равенство

$$\frac{1}{\log \frac{1}{q}} = \frac{1}{\log I - \log \theta} = \frac{1}{\log I} \left( 1 + \frac{\log \theta}{\log I} + \left( \frac{\log \theta}{\log I} \right)^2 \left( \frac{1}{1 - \log \theta / \log I} \right) \right),$$

из неравенства (16) получаем утверждение леммы 2.

Лемму 2 нетрудно обобщить на набор слов  $w_1, \dots, w_m \in A^*$ . А именно, если  $\sum_{i=1}^m I(w_i | \tau_i) \leq I$  для некоторого набора состояний  $\tau_1, \tau_2, \dots, \tau_m$  и выполнены условия леммы 2, то

$$l(\{w_1, \dots, w_m\}) \leq \frac{I}{\log I} \left( 1 + \frac{1 + \log \theta}{\log I} + \frac{\log^2 \theta}{\log I (\log I - \log \theta)} \right). \quad (17)$$

Пусть  $x$  — бесконечная последовательность букв и  $x^n = x_1 \dots x_n$  — ее префикс. Тогда из леммы 2 вытекает

**Следствие 1.** Пусть  $S$  — неразложимый нетривиальный марковский источник в алфавите  $A$  с множеством состояний  $\Omega$ ,  $\sigma \in \Omega$  и  $x \in A^{\infty}$ . Тогда при  $n \rightarrow \infty$

$$l(x^n) \leq \frac{I(x^n | \sigma)}{\log I(x^n | \sigma)} (1 + o(1)).$$

Доказательство. Если марковский источник  $S$  является неразложимым и нетривиальным, то  $\varrho_S > 0$ . Среди любого набора из  $|\Omega| + 1$  состояний найдутся два одинаковых. Следовательно, для произвольных  $\sigma \in \Omega$  и  $u \in A^{|\Omega|+1}$  имеем  $p(u|\sigma) \leq 1 - \varrho_S$ . Тогда из (3) получаем неравенство

$$I(x^n|\sigma) \geq \lfloor n/(|\Omega| + 1) \rfloor \log \frac{1}{1 - \varrho_S},$$

т. е.  $I(x^n|\sigma) \rightarrow \infty$  при  $n \rightarrow \infty$ . Отсюда и из леммы 2 следует справедливость следствия 1.

Для слова  $u \in A^*$  введем обозначение  $u^s = \underbrace{u \dots u}_s$  — степень слова  $u$ . Рассмотрим марковский источник  $S$  первого порядка в алфавите  $A$ , удовлетворяющий условию:

$$\text{если } \mu_S(b, w) = b \text{ и } p_S(w|b) > 1/2, \text{ то } w = b^s. \quad (18)$$

Справедлива следующая

**Лемма 3.** Пусть  $S$  — марковский источник первого порядка в алфавите  $A$ , удовлетворяющий условию (18),  $\xi = \max_{a \in A} \{1, \lceil -\log \log(1/p(a|a)) \rceil\}$  и  $w_1, \dots, w_m$  — набор таких слов в алфавите  $A$  длины не менее 2, что две последние буквы каждого слова различны. Если величина  $I$  удовлетворяет неравенствам  $I \geq \sum_{i=1}^m I_S(w_i)$  и  $I > \theta = 8(\log^2 I)(\xi|A|^5)$ , то

$$l(\{w_1, \dots, w_m\}) \leq \frac{I}{\log I} \left( 1 + \frac{1 + \log \theta}{\log I} + \frac{\log^2 \theta}{\log I(\log I - \log \theta)} \right) + \xi|A|.$$

Доказательство. Пусть  $E = \{a \in A \mid p(a|a) > 1/2\}$ . Для каждой буквы  $a \in E$  определим число  $i_a = \lceil -\log \log(1/p(a|a)) \rceil$  и введем новые буквы  $a(0), a(1), \dots, a(i_a)$ . Буква  $a(i)$  в указанном ниже смысле соответствует слову  $a^{2^i}$  в алфавите  $A$ . Рассмотрим алфавит  $A' = A \cup (\cup_{a \in E} \{a(0), a(1), \dots, a(i_a)\})$ . Определим марковский источник  $S'$  первого порядка в алфавите  $A'$ . Сначала определим вспомогательные величины  $\widehat{p}(x|y)$  для всех пар букв  $x, y \in A'$ .

Если  $a \in A \setminus E$ , то

$$\widehat{p}(x|a) = \begin{cases} p(x|a) & \text{при } x \in A; \\ 0 & \text{при } x \in A' \setminus A. \end{cases}$$

Если  $a \in E$ , то

$$\widehat{p}(x|a) = \begin{cases} (p(a|a))^{2^{i_a}} & \text{при } x = a(i_a); \\ (p(a|a))^{2^j} (1 - (p(a|a))^{2^j}) & \text{при } x = a(j), j < i_a; \\ p(x|a) & \text{при } x \in A \setminus \{a\}; \\ 0 & \text{при } x = a \text{ или } x = b(i), \text{ где } b \neq a. \end{cases}$$

Определим  $\widehat{p}(x|a(i))$  при  $i < i_a$  равенствами

$$\widehat{p}(x|a(i)) = \begin{cases} 0, & \text{если } x = a(j), \text{ где } j \geq i; \\ \widehat{p}(x|a) & \text{в остальных случаях.} \end{cases}$$

При  $i = i_a$  положим  $\widehat{p}(x|a(i_a)) = \widehat{p}(x|a)$ . Нетрудно видеть, что для каждой буквы  $a \in A$

$$\sum_{x \in A'} \widehat{p}(x|a) = \sum_{x \in A'} \widehat{p}(x|a(i_a)) = 1$$

и при  $i < i_a$

$$\sum_{x \in A'} \widehat{p}(x|a(i)) = 1 - (p(a|a))^{2^i}.$$

Теперь определим вероятности букв в источнике  $S'$  равенствами

$$p'(x|y) = p_{S'}(x|y) = \begin{cases} \widehat{p}(x|y)/(1 - (p(a|a))^{2^i}), & \text{если } y = a(i), i < i_a, \\ \widehat{p}(x|y) & \text{в противном случае.} \end{cases}$$

Пусть  $\bar{A}^* \subset A^*$  — множество таких слов в алфавите  $A$ , в каждом из которых две последние буквы различны. Зададим инъективное отображение  $F : \bar{A}^* \rightarrow (A')^*$  следующим образом. Пусть  $a \in E$  и  $a \neq b$ . Определим  $F(a^k b) = (a(i_a))^q (a(i_a) - 1)^{q_{i_a-1}} \dots (a(0))^{q_0} b$ , если  $0 \leq k = q_0 2^0 + q_1 2^1 + \dots + q_{i_a-1} 2^{i_a-1} + q 2^{i_a}$ , где  $q_i \in \{0, 1\}$ , а  $q$  — некоторое целое число. В случае  $a \notin E$  положим  $F(a^k b) = a^k b$ .

Произвольное слово  $u \in \bar{A}^*$  можно представить в виде

$$u = a_{j_1}^{k_1} a_{j_2}^{k_2} \dots a_{j_t}^{k_t} a_{j_{t+1}} = a_{j_1} a_{j_1}^{k_1-1} a_{j_2} a_{j_2}^{k_2-1} \dots a_{j_t} a_{j_t}^{k_t-1} a_{j_{t+1}}.$$

Здесь  $k_i$  могут равняться 1. Пусть

$$F(u) = a_{j_1} F(a_{j_1}^{k_1-1} a_{j_2}) F(a_{j_2}^{k_2-1} a_{j_3}) \dots F(a_{j_t}^{k_t-1} a_{j_{t+1}}).$$

Для источника  $S'$  вероятности букв были выбраны как условные вероятности подслов в описанном выше разбиении. Покажем, что для любого

слова  $u \in \bar{A}^*$  справедливо равенство  $p(u) = p'(F(u))$ . Действительно, если  $a \notin E$ , то  $p(a^k b|a) = p'(a^k b|a)$ . Если  $a \in E$ , то справедливы равенства

$$\begin{aligned} p'(F(a^k b|a)) &= p'((a(i_a))^q (a(i_a - 1))^{q_{i_a - 1}} \dots (a(0))^{q_0} b|a) \\ &= p'((a(i_a))^q a(j_1) a(j_2) \dots a(j_r) b|a) = p(a|a)^{q_{2^{i_a}}} p(a|a)^{2^{j_1}} (1 - p(a|a)^{2^{j_1}}) \\ &\times \left( \prod_{j=2}^r \frac{p(a|a)^{2^{j_s}} (1 - p(a|a)^{2^{j_s}})}{(1 - p(a|a)^{2^{j_s - 1}})} \right) \frac{p(b|a)}{(1 - p(a|a)^{2^{j_r}})} = (p(a|a))^k p(b|a) = p(a^k b|a). \end{aligned}$$

Используя (3), имеем

$$\begin{aligned} p'(F(u)) &= p'(a_{j_1} | a_{j_{t+1}}) p'(F(a_{j_1}^{k_1 - 1} a_{j_2}) | a_{j_1}) p'(F(a_{j_2}^{k_2 - 1} a_{j_3}) | a_{j_2}) \dots p'(F(a_{j_t}^{k_t - 1} a_{j_{t+1}}) | a_{j_t}) \\ &= p(a_{j_1} | a_{j_{t+1}}) p(a_{j_1}^{k_1 - 1} a_{j_2} | a_{j_1}) p(a_{j_2}^{k_2 - 1} a_{j_3} | a_{j_2}) \dots p(a_{j_t}^{k_t - 1} a_{j_{t+1}} | a_{j_t}) = p(u). \end{aligned}$$

По определению (6) для любого слова  $u \in \bar{A}^*$  получаем равенство

$$I_{S'}(F(u)) = I_S(u). \quad (19)$$

Покажем, что

$$\varrho_{S'} = 1 - \max_{x \in A', v \in (A')^*} \{p'(v|x) \mid \mu_{S'}(x, v) = x\} \geq 1/2. \quad (20)$$

Другими словами, покажем, что если  $x$  — последняя буква слова  $v \in (A')^*$ , то  $p'(v|x) \leq 1/2$ .

Рассмотрим три возможных случая: 1)  $x \in E$ ; 2)  $x \in A' \setminus A$ ; 3)  $x \in A \setminus E$ . Из определения источника  $S'$  следует, что если  $a \in E$ , то  $p'(b|a) \leq 1/2$  для любого  $b \in A'$ . Поэтому если буква  $a \in E$  содержится в слове  $xv$ , то  $p'(v|x) \leq 1/2$ . Предположим, что  $x = a(i) \in A' \setminus A$ . Тогда по определению источника  $S'$  либо буква  $a \in E$  содержится в слове  $v$ , либо  $p'(v|x) = 0$ . Предположим, что  $x \in A \setminus E$ . Тогда если в слове  $v$  содержится буква  $a(i) \in A' \setminus A$ , то либо между буквами  $x$  и  $a(i)$  содержится буква  $a \in E$ , либо  $p'(v|x) = 0$ . Предположим, что  $xv \in (A \setminus E)^*$ . Тогда  $p'(v|x) = p(v|x)$  и из условия (18) имеем либо  $p(v|x) \leq 1/2$ , либо  $v = x^s$ . Однако неравенство  $p(x^s|x) > 1/2$  противоречит тому, что  $x \notin E$ . Таким образом, неравенство (20) доказано.

Из определения источника  $S'$  следует, что  $|A'| \leq |A|\xi$ . Пользуясь неравенством (17) и условиями леммы для набора слов  $w_1, w_2, \dots, w_m$ , получаем

$$l(\{F(w_1), \dots, F(w_m)\}) \leq \frac{I}{\log I} \left( 1 + \frac{1 + \log \theta}{\log I} + \frac{\log^2 \theta}{\log I (\log I - \log \theta)} \right). \quad (21)$$

Здесь  $\max\{\theta, \sum_{i=1}^m I_{S'}(F(w_i))\} \leq I$  и  $\theta = 8(\log^2 I)(\xi|A|)^5 < I$ .

Нетрудно видеть, что  $l(\{w_1, \dots, w_m\}) \leq l(\{F(w_1), \dots, F(w_m)\}) + L$ , где  $L$  — аддитивная сложность множества слов вида  $a^{2^j}$ , соответствующих буквам алфавита  $A'$ . Из определений величин  $i_a$  и  $\xi$  следует, что  $L \leq |A|\xi$ . Тогда из формул (19) и (21) получаем утверждение леммы 3.

### 3. Аддитивная сложность слов с запретами на подслова

Пусть  $Z \subset A^*$ . Через  $B(Z)$  обозначим множество, состоящее из всех слов, в которых не содежатся подслова из  $Z$ . Рассмотрим случай, когда множество запретов  $Z$  является конечным, а  $B(Z)$  — бесконечным. Тогда множество  $B(Z)$  является регулярным языком (см., [7, гл. I, § 6]). Введем обозначение  $B_n(Z) = B(Z) \cap A^n$ .

Из предложения, доказанного в [10, предложение 4.7.6], нетрудно убедиться в справедливости следующего утверждения.

**Утверждение 3.** *Если  $Z$  — конечное множество, то существует*

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log |B_n(Z)|.$$

Оценим аддитивную сложность слов с запретами на подслова в случае, когда мощность множества  $B(Z)$  растет экспоненциально.

**Теорема 1.** *Пусть  $Z$  — множество запретов и  $\lim_{n \rightarrow \infty} \frac{1}{n} \log |B_n(Z)| > 0$ . Тогда при  $n \rightarrow \infty$*

$$L(B_n(Z)) = \frac{\log |B_n(Z)|}{\log n} (1 + o(1)).$$

*Доказательство.* Пусть  $f_n = \log |B_n(Z)|$ . Из условия теоремы следует, что при  $n \rightarrow \infty$

$$f_n = \alpha n (1 + o(1)), \tag{22}$$

где  $\alpha > 0$ . Тогда нижняя оценка величины  $L(B_n(Z))$  вытекает из утверждения 1.

Выберем  $k = k(n)$  такое, что справедливы неравенства

$$|A| \frac{f_n}{\log^3 f_n} \geq 2^{f_k} \geq \frac{f_n}{\log^3 f_n}. \tag{23}$$

Введем обозначение:  $\widehat{B}_n(Z) = \bigcup_{i=0}^n B_i(Z)$ . Так как множество  $\widehat{B}_n(Z)$  является деревом, то из утверждения 2 следует, что при  $k \rightarrow \infty$

$$L(\widehat{B}_k(Z)) = |\widehat{B}_k(Z)| - 1 \leq k |B_k(Z)| (1 + o(1)). \tag{24}$$

Поскольку любое слово  $w \in B_n(Z)$  можно представить в виде конкатенации  $w = w_1 w_2 \dots w_t$ , где  $|w_i| = k$  при  $i < t$  и  $|w_t| \leq k$ , имеем

$$l(w) \leq L(\widehat{B}_k(Z)) + t - 1. \quad (25)$$

Покажем, что при  $n \rightarrow \infty$

$$L(\widehat{B}_k(Z)) = o\left(\frac{f_n}{\log f_n}\right). \quad (26)$$

Из неравенств (23) следует, что  $|B_k(Z)| \leq |A| f_n / \log^3 f_n$ . Тогда, используя асимптотическое равенство (22), получаем

$$\alpha k(1 + o(1)) = f_k \leq \log f_n - 3 \log \log f_n + \log |A|,$$

т. е.  $k = O(\log f_n)$  при  $n \rightarrow \infty$ .

Отсюда и из (23) и (24) следует, что

$$L(\widehat{B}_k(Z)) = O\left(\log f_n \frac{|A| f_n}{\log^3 f_n}\right),$$

т. е. равенство (26) доказано.

Покажем, что при  $n \rightarrow \infty$  справедливо асимптотическое равенство

$$t = \lceil n/k \rceil = \frac{f_n}{\log f_n} (1 + o(1)). \quad (27)$$

Из (22) следует, что  $f_n/f_k = (1 + o(1))n/k$ . Тогда из неравенства (23) получаем  $f_k \geq \log f_n - 3 \log \log f_n$  и при  $n \rightarrow \infty$

$$n/k = (1 + o(1))f_n/f_k \leq \frac{f_n}{\log f_n} (1 + o(1)). \quad (28)$$

Так как из (22) следует, что  $\log f_n \sim \log n$ , то формулы (25)–(28) дают требуемую верхнюю оценку величины  $L(B_n(Z))$ . Теорема 1 доказана.

#### 4. Аддитивная сложность высоковероятных слов

Рассмотрим некоторый неразложимый непериодический марковский источник  $S$  в алфавите  $A$  с множеством состояний  $\Omega$ . Пусть  $\sigma \in \Omega$ . Все слова  $w \in A^n$  упорядочим в порядке убывания их вероятностей  $p(w|\sigma)$  и будем отбирать наиболее вероятные до тех пор, пока впервые суммарная вероятность отобранных слов не превзойдет некоторый заранее заданный уровень  $\alpha$ ,  $0 < \alpha < 1$ . Множество отобранных слов обозначим через  $M_n(\alpha, S, \sigma)$ .

Теорема о марковских цепях, аналогичная приведенному ниже утверждению, доказана в [2, гл.12, § 2, теорема 2]. Доказательство полностью переносится на случай марковских источников, если использовать определение энтропии источника, данное во введении.

**Утверждение 4.** Для любого  $\alpha$ ,  $0 < \alpha < 1$ ,

$$\lim_{n \rightarrow \infty} \frac{\log |M_n(\alpha, S, \sigma)|}{n} = H(S),$$

$$\lim_{n \rightarrow \infty} \frac{1}{n} \left( \max_{w \in M_n(\alpha, S, \sigma)} I_S(w|\sigma) \right) = H(S).$$

В следующей теореме содержится асимптотика для  $L(M_n(\alpha, S, \sigma))$ .

**Теорема 2.** Пусть  $S$  — неразложимый непериодический марковский источник и  $\sigma \in \Omega$ . Тогда при любом  $\alpha$ ,  $0 < \alpha < 1$ , и  $n \rightarrow \infty$  справедливо асимптотическое равенство

$$L(M_n(\alpha, S, \sigma)) = \frac{nH(S)}{\log n} (1 + o(1)).$$

Доказательство. Как указано ранее, энтропия неразложимого непериодического источника  $S$  положительна, т. е.  $H(S) > 0$ . Введем обозначение:  $I_n = \max_{w \in M_n(\alpha, S, \sigma)} I_S(w|\sigma)$ . Из утверждения 4 следует, что  $I_n/n \rightarrow H(S) > 0$ . Поэтому  $\log I_n / \log n \rightarrow 1$  при  $n \rightarrow \infty$ . Отсюда и из леммы 2 при  $n \rightarrow \infty$  получаем

$$L(M_n(\alpha, S, \sigma)) \leq \frac{I_n}{\log I_n} (1 + o(1)) = \frac{nH(S)}{\log n} (1 + o(1)).$$

Введем обозначение:  $h_n = \log |M_n(\alpha, S, \sigma)|$ . Тогда из утверждения 4 следуют пределы  $\lim_{n \rightarrow \infty} h_n/n = H(S)$  и  $\lim_{n \rightarrow \infty} \log h_n / \log n = 1$ . Отсюда и из утверждения 1 при  $n \rightarrow \infty$  получаем нижнюю оценку

$$L(M_n(\alpha, S, \sigma)) \geq \frac{h_n}{\log h_n} (1 + o(1)) = \frac{nH(S)}{\log n} (1 + o(1)).$$

Теорема 2 доказана.

### 5. Множество слов с заданным составом подслов

В этом разделе будем рассматривать круговые слова  $w \in A^*$ , т. е. слова вида  $a_{i_{n-t}} a_{i_{n-t+1}} \dots a_{i_n} a_{i_1} \dots a_{i_s}$  будем считать подсловами слова  $a_{i_1} \dots a_{i_n}$ . Пусть  $\sigma \in A^k$ . Обозначим через  $r_w(\sigma)$  число вхождений подслова  $\sigma$  в слово  $w$ . Заметим, что  $\sum_{\sigma \in A^k} r_w(\sigma) = |w|$ . Упорядочим (например, лексикографически) множество  $A^k$ . Введем обозначение:  $\mathbf{r}_w = (r_w(\sigma_1), r_w(\sigma_2), \dots, r_w(\sigma_T))$ , где  $\sigma_i \in A^k$  и  $T = |A|^k$ .

Пусть  $\mathbf{r} = (r(\sigma_1), r(\sigma_2), \dots, r(\sigma_T))$  — произвольный вектор с неотрицательными вещественными компонентами. Введем обозначение:  $|\mathbf{r}| = \sum_{i=1}^T r(\sigma_i)$ . Определим величины  $I(\mathbf{r})$ ,  $I_\tau(\mathbf{r})$ ,  $r(\tau)$  при  $\tau \in A^{k-1}$  равенствами

$$r(\tau) = \sum_{a \in A} r(\tau a), \quad (29)$$

$$I_\tau(\mathbf{r}) = \sum_{a \in A} r(\tau a) \log \frac{r(\tau)}{r(\tau a)}, \quad (30)$$

$$I(\mathbf{r}) = \sum_{\tau \in A^{k-1}} I_\tau(\mathbf{r}). \quad (31)$$

Заметим, что непрерывная дифференцируемость функции  $I(\mathbf{r})$  в точке  $\mathbf{r} > \mathbf{0}$  следует из ее определения. Если  $\mathbf{r}$  — целочисленный вектор, определим множество

$$M(\mathbf{r}) = \{w \in A^* \mid r_w(\sigma) = r(\sigma) \text{ для всех } \sigma \in A^k\},$$

состоящее из слов с одинаковым составом подслов длины  $k$ .

Для оценки мощности множества  $M(\mathbf{r})$  воспользуемся утверждением из [11], доказательство которого имеется также в [1, гл. 17, теорема 4].

**Утверждение 5.** Пусть  $G$  — связный ориентированный мультиграф, в котором степени захода и исхода каждой вершины одинаковы и для  $k$ -й вершины равны  $r_k$ ,  $1 \leq k \leq n$ . Тогда число различных эйлеровых контуров в мультиграфе  $G$  равно

$$\Delta \prod_{k=1}^n (r_k - 1)!,$$

где  $\Delta$  — число прадеревьев (остовных деревьев, ориентированных от корня) с фиксированным корнем в мультиграфе  $G$ .

Справедливо следующее

**Утверждение 6.** Пусть  $M(\mathbf{r}) \neq \emptyset$  и  $|\mathbf{r}| = n$ . Тогда

$$|A|^{k-1} \frac{\prod_{\tau \in A^{k-1}} r(\tau)!}{\prod_{\sigma \in A^k} r(\sigma)!} \geq |M(\mathbf{r})| \geq \frac{1}{(1 + n/|A|^{k-1})^{|A|^{k-1}}} \frac{\prod_{\tau \in A^{k-1}} r(\tau)!}{\prod_{\sigma \in A^k} r(\sigma)!}.$$

Доказательство. Рассмотрим граф де Брейна  $G_{k-1}$ . В этом графе каждую дугу, соответствующую слову  $\sigma \in A^k$ , заменим на  $r(\sigma)$  дуг,

соединяющих те же вершины. Удалим изолированные вершины. В полученном мультиграфе  $G(M)$  дуги пометим теми же буквами, какими они были помечены в ориентированном графе  $G_{k-1}$ . Степени захода и исхода вершины мультиграфа  $G(M)$ , соответствующей слову  $\tau \in A^{k-1}$ , одинаковы и равны  $r(\tau)$ , причем число исходящих из нее дуг, помеченных буквой  $a \in A$ , равно  $r(\tau a)$ .

Каждому слову  $w \in M(\mathbf{r})$  соответствует эйлеров контур в мультиграфе  $G(M)$ . Зафиксируем произвольную вершину в мультиграфе  $G(M)$ . Тогда эйлеров контур будет порождать нумерации (в порядке обхода) дуг, выходящих из каждой вершины. Нумерации и соответствующие эйлеровы контуры будем называть эквивалентными, если они совпадают с точностью до перестановки одинаково помеченных дуг. Ясно, что эквивалентным нумерациям соответствуют одинаковые слова. Нетрудно видеть, что число неэквивалентных нумераций равно

$$\prod_{\tau \in A^{k-1}} \frac{r(\tau)!}{\prod_{a \in A} r(\tau a)!} = \frac{\prod_{\tau \in A^{k-1}} r(\tau)!}{\prod_{\sigma \in A^k} r(\sigma)!}.$$

Учитывая, что для определения слова нужно зафиксировать начало контура, из последнего равенства вытекает требуемая верхняя оценка.

В мультиграфе  $G(M)$  имеется эйлеров контур, так как  $M(\mathbf{r}) \neq \emptyset$ . Пусть  $V \subseteq A^{k-1}$  — множество вершин в мультиграфе  $G(M)$ . Из утверждения 5 следует, что число эйлеровых контуров в мультиграфе  $G(M)$  не меньше величины  $\prod_{\tau \in V} (r(\tau) - 1)!$ . Зафиксируем некоторую вершину в качестве начала контура. Каждый эйлеров контур с фиксированным началом входит в класс эквивалентности, состоящий из  $\prod_{\sigma \in A^k} r(\sigma)!$  контуров. Поскольку неэквивалентные эйлеровы контуры порождают различные слова (когда начало фиксировано), справедливо неравенство

$$|M(\mathbf{r})| \geq \frac{\prod_{\tau \in V} (r(\tau) - 1)!}{\prod_{\sigma \in A^k} r(\sigma)!} = \frac{\prod_{\tau \in A^{k-1}} r(\tau)!}{\prod_{\tau \in V} r(\tau) \prod_{\sigma \in A^k} r(\sigma)!}.$$

Теперь для получения нижней оценки достаточно применить очевидное неравенство

$$\prod_{\tau \in V} r(\tau) \leq \left( \frac{n + |A|^{k-1}}{|A|^{k-1}} \right)^{|A|^{k-1}}.$$

Утверждение 6 доказано.

**Утверждение 7.** Пусть  $M(\mathbf{r}) \neq \emptyset$  и  $|\mathbf{r}| = n$ . Тогда

$$I(\mathbf{r}) + (k-1) \log |A| \geq \log |M(\mathbf{r})| \geq I(\mathbf{r}) - C \log n,$$

где константа  $C > 0$  не зависит от  $n$ .

Доказательство. Из (29)–(31) следует равенство

$$I(\mathbf{r}) = \sum_{\tau \in A^{k-1}} I_\tau(\mathbf{r}) = \sum_{\tau \in A^{k-1}} \log \left( \frac{r(\tau)^{r(\tau)}}{\prod_{a \in A} r(\tau a)^{r(\tau a)}} \right). \quad (32)$$

Используя формулу Стирлинга  $n! = (n/e)^n \sqrt{2\pi n} e^{\theta_n/12n}$ , где  $0 \leq \theta_n \leq 1$ , получаем неравенство

$$\log \left( \frac{r(\tau)!}{\prod_{a \in A} r(\tau a)!} \right) \geq I_\tau(\mathbf{r}) - \left( \frac{(|A|-1)}{2} \right) \left( \log \frac{r(\tau)}{|A|} + \log 2\pi + \frac{1}{6} \right).$$

Из него и утверждения 6 следует нижняя оценка.

Нетрудно видеть, что  $\frac{n!}{n_1! \dots n_m!} \leq \frac{n^n}{n_1^{n_1} \dots n_m^{n_m}}$ , где  $n = \sum_{i=1}^m n_i$  и  $n_i \geq 0$  — целые числа ( $0^0 = 0! = 1$ ). Тогда из утверждения 6 и (32) следует, что  $\log |M(\mathbf{r})| \leq I(\mathbf{r}) + (k-1) \log |A|$ . Утверждение 7 доказано.

### 6. Аддитивная сложность слов с заданным составом подслов

Для получения асимптотики аддитивной сложности слов с фиксированным составом подслов нам понадобится несколько простых утверждений.

С помощью неравенства Йенсена для функции  $\log t$  нетрудно доказать

**Утверждение 8.** Пусть  $p_i, q_i \geq 0$  и  $\sum_{i=1}^m p_i = \sum_{i=1}^m q_i = 1$ . Тогда

$$(a) \quad \sum_{i=1}^m p_i \log \frac{1}{p_i} \leq \sum_{i=1}^m p_i \log \frac{1}{q_i};$$

$$(b) \quad \sum_{i=1}^m p_i \log \frac{1}{p_i} \geq p_1 \log \frac{1}{p_1} + \left( \sum_{i=2}^m p_i \right) \log \left( 1 / \sum_{i=2}^m p_i \right).$$

**Утверждение 9.** Пусть  $S$  — марковский источник  $(k-1)$ -го порядка и  $w \in A^*$ . Тогда

$$(a) \quad I_{S,\tau}(w) \geq I_\tau(\mathbf{r}_w) \text{ для любого } \tau \in A^{k-1};$$

(b)  $I_S(w) \geq I(\mathbf{r}_w)$ .

Доказательство. Из (7) и (30) следует, что

$$I_{S,\tau}(w) = -r_w(\tau) \left( \sum_{a \in A} \frac{r_w(\tau a)}{r_w(\tau)} \log p_S(a|\tau) \right),$$

$$I_\tau(\mathbf{r}_w) = -r_w(\tau) \left( \sum_{a \in A} \frac{r_w(\tau a)}{r_w(\tau)} \log \frac{r_w(\tau a)}{r_w(\tau)} \right).$$

Так как  $\sum_{a \in A} p_S(a|\tau) = \sum_{a \in A} r_w(\tau a)/r_w(\tau) = 1$  для любого  $\tau \in A^{k-1}$ , то из утверждения 8 получаем пункт (a) утверждения 9. Отсюда и из равенств (8), (31) следует пункт (b) утверждения 9. Утверждение 9 доказано.

**Утверждение 10.** Пусть  $I_i > 0$  и  $\sum_{i=1}^m I_i = I$ . Тогда при  $I \rightarrow \infty$

$$\sum_{i=1}^m I_i / \log I_i = \frac{I}{\log I} (1 + o(1)).$$

Доказательство. Без ограничения общности можно считать, что при любом  $i$ ,  $1 \leq i \leq m'$ , справедливо неравенство  $I_i \geq I/\log^2 I$ , а при  $2 \leq m'+1 \leq i \leq m$  — неравенство  $I_i < I/\log^2 I$ . Положим  $I'_1 = I_1 + \sum_{i=m'}^m I_i$ .

Тогда  $I = I'_1 + \sum_{i=2}^{m'-1} I_i$  и  $I'_1 / \log I'_1 \geq I_1 / \log I_1$ , поскольку функция  $t/\log t$  возрастает при  $t \geq e$ . В этом случае имеем

$$\begin{aligned} \sum_{i=1}^m \frac{I_i}{\log I_i} &\leq \frac{I'_1}{\log I'_1} + \sum_{i=2}^{m'-1} \frac{I_i}{\log I_i} + (m - m' + 1) \frac{I}{\log^2 I} \\ &\leq \frac{I}{\log I - 2 \log \log I} + (m - m' + 1) \frac{I}{\log^2 I}. \end{aligned}$$

Отсюда вытекает справедливость утверждения 10.

Как замечено в работе [5], задача об оценке аддитивной сложности набора слов в алфавите, состоящем из одной буквы, сводится к задаче об оценке сложности вычисления набора степеней одной переменной. Таким образом, из [4] следует

**Утверждение 11.** Пусть  $F = \{a^{s_1}, a^{s_2}, \dots, a^{s_m}\}$  — набор степеней буквы  $a \in A$  и  $N = \prod_{i=1}^m s_i$ . Тогда при  $N \rightarrow \infty$

$$l(F) \leq \left( \frac{\log N}{\log \log N} + \log \max_i s_i + m \right) (1 + o(1)).$$

В случае, когда  $k = 1$  и  $A = \{0, 1\}$ , теорема 3 уточняет остаточный член в формуле для величины  $L(M(n - k_n, k_n))$ , полученной в [5]. Однако новая оценка, по сравнению с оценкой из [5], справедлива в более узкой области значений параметров, а именно, когда  $0 < \lim_{n \rightarrow \infty} k_n/n < 1$ .

**Теорема 3.** Пусть  $A$  — конечный алфавит,  $\mathbf{r}_n$  — последовательность целочисленных векторов размерности  $|A|^k$  такая, что  $|\mathbf{r}_n| = n$ ,  $M(\mathbf{r}_n) \neq \emptyset$  и

$$|\mathbf{r}_n/n - \mathbf{r}_0| = o\left(\frac{\log \log n}{\log n}\right)$$

для некоторого положительного вектора  $\mathbf{r}_0$ . Тогда при  $n \rightarrow \infty$

$$L(M(\mathbf{r}_n)) = \frac{nI(\mathbf{r}_0)}{\log n} \left(1 + \frac{\beta_n \log \log n}{\log n}\right),$$

где  $1 \leq \liminf_{n \rightarrow \infty} \beta_n \leq \limsup_{n \rightarrow \infty} \beta_n \leq 2$ .

Доказательство. Поскольку функция  $I(\mathbf{r})$  дифференцируема в точке  $\mathbf{r}_0 > \mathbf{0}$ , при  $n \rightarrow \infty$  имеем

$$|I(\mathbf{r}_n/n) - I(\mathbf{r}_0)| = O(|\mathbf{r}_n/n - \mathbf{r}_0|) = o\left(\frac{\log \log n}{\log n}\right).$$

Заметим, что  $nI(\mathbf{r}_n/n) = I(\mathbf{r}_n)$ . Тогда из утверждения 7 получаем

$$\begin{aligned} \log |M(\mathbf{r}_n)| &= I(\mathbf{r}_n) + O(\log n) = nI(\mathbf{r}_n/n) + O(\log n) \\ &= n \left( I(\mathbf{r}_0) + o\left(\frac{\log \log n}{\log n}\right) \right). \end{aligned}$$

Так как  $\mathbf{r}_0 > \mathbf{0}$ , то  $I(\mathbf{r}_0) > 0$ . Поэтому из утверждения 1 при  $n \rightarrow \infty$  получаем  $L(M(\mathbf{r}_n)) \geq \frac{nI(\mathbf{r}_0)}{\log n} \left(1 + (1 + o(1)) \frac{\log \log n}{\log n}\right)$ .

Рассмотрим марковский источник  $S$   $(k - 1)$ -го порядка в алфавите  $A$  и вероятностями букв  $p_S(a|\tau) = r_0(\tau a)/r_0(\tau)$  в состояниях  $\tau \in A^{k-1}$ . Так как по условию теоремы  $p_S(a|\tau) > 0$  для всех  $a \in A$  и  $\tau \in A^{k-1}$ , то  $\varrho_S > 0$ .

Для произвольного слова  $w \in M(\mathbf{r}_n)$  имеем

$$\begin{aligned} I_S(w) &= \sum_{\tau \in A^{k-1}} \sum_{a \in A} r_n(\tau a) \log \frac{r_0(\tau)}{r_0(\tau a)} \\ &= n \left( \sum_{\tau \in A^{k-1}} \frac{r_n(\tau)}{n} \left( \sum_{a \in A} \frac{r_n(\tau a)}{r_n(\tau)} \log \frac{r_0(\tau)}{r_0(\tau a)} \right) \right) = n \left( I(\mathbf{r}_0) + o\left(\frac{\log \log n}{\log n}\right) \right). \end{aligned}$$

Поэтому из леммы 2 при  $I = I_S(w)$  и  $n \rightarrow \infty$  следует, что

$$l(w) \leq \frac{nI(\mathbf{r}_0)}{\log n} \left( 1 + (1 + o(1)) \frac{2 \log \log n}{\log n} \right).$$

Отсюда и из определения величины  $L(M(\mathbf{r}_n))$  получаем верхнюю оценку. Теорема 3 доказана.

Заметим (см., например, [3, раздел 3.6]), что величина  $I(\mathbf{r}_0)$  равняется энтропии источника  $S$ , использованного при доказательстве теоремы 3.

В следующей теореме подобная асимптотика приводится при более слабых условиях на последовательность  $\mathbf{r}_n$ .

**Теорема 4.** Пусть  $A$  — конечный алфавит,  $\mathbf{r}_n$  — последовательность целочисленных векторов размерности  $|A|^k$  такая, что  $|\mathbf{r}_n| = n$ ,  $M(\mathbf{r}_n) \neq \emptyset$  и  $\lim_{n \rightarrow \infty} (\log I(\mathbf{r}_n) \log n) / I(\mathbf{r}_n) = 0$ . Тогда при  $n \rightarrow \infty$

$$L(M(\mathbf{r}_n)) \sim \frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)} \sim \frac{\log |M(\mathbf{r}_n)|}{\log \log |M(\mathbf{r}_n)|}.$$

Доказательство. 1. Для множества  $M(\mathbf{r}_n)$  определим марковский источник  $S_1$   $(k-1)$ -го порядка в алфавите  $A$  с вероятностями букв  $p_{S_1}(a|\tau) = p_1(a|\tau) = r_n(\tau a) / r_n(\tau)$  в состояниях  $\tau \in A^{k-1}$ .

Пусть  $w \in M(\mathbf{r}_n)$ . Тогда из определения источника  $S_1$  и равенств (6), (30), (31) вытекают равенства

$$I_{S_1}(w|\tau_0) = I_{S_1}(w) = I(\mathbf{r}_n), \quad (33)$$

где  $\tau_0$  — суффикс длины  $k-1$  слова  $w$ .

2. Объединив буквы алфавита  $A$  в блоки фиксированной длины, получим новый алфавит  $B$ . Вычислив вероятности блоков, построим такой марковский источник  $S_2$  первого порядка в алфавите  $B$ , что вероятности слов в алфавите  $B$  и соответствующих им слов в алфавите  $A$  будут совпадать.

Вначале определим длину блоков. Для каждого состояния  $\tau \in A^{k-1}$  рассмотрим множество  $A_\tau \subset A^*$ , состоящее из слов  $w$  таких, что

$\mu_1(\tau, w) = \tau$  (т. е.  $\tau$  — суффикс слова  $\tau w$ ) и справедливо неравенство  $p_1(w|\tau) > 1/2$ . Обозначим через  $w_\tau$  кратчайшее слово из множества  $A_\tau$ , если  $A_\tau \neq \emptyset$ . Покажем, что  $A_\tau \subset \{w_\tau^s \mid s \text{ — целое}\}$ . Заметим, что элементы множества  $A_\tau$  являются префиксами друг друга. Пусть  $w_1, w_2 \in A_\tau$ ,  $|w_1| \leq |w_2|$  и слово  $w'_2$  — префикс слова  $w_2$  такой, что  $|w'_2| = |w_1|$ . Пусть  $w'_2 \neq w_1$ . Тогда из равенства (3) получаем  $p_1(w'_2|\tau) \geq p_1(w_2|\tau) > 1/2$  и  $p_1(w_1|\tau) > 1/2$ , что противоречит равенству (4). Пусть  $w \in A_\tau$ , тогда  $w = w_\tau w'$ . Так как слово  $\tau$  является суффиксом слов  $\tau w_\tau$  и  $\tau w_\tau w'$ , то слово  $\tau$  является также суффиксом слова  $\tau w'$ , причем из (3) следует, что

$$p_1(w|\tau) = p_1(w_\tau|\tau)p_1(w'|\tau) > 1/2.$$

Поэтому  $w' \in A_\tau$  и  $w_\tau$  — префикс слова  $w'$ . Рассуждая по индукции, заключаем, что  $w = w_\tau^s$  при некотором целом числе  $s$ .

Покажем, что

$$|w_\tau| \leq |A|^{k-1} + k - 2. \quad (34)$$

Пусть в слове  $w_\tau$  найдутся два вхождения некоторого подслова  $\delta \in A^{k-1}$  (возможно перекрывающиеся), например,  $w_\tau = w_1 \delta w_2 \delta w_3$ . Рассмотрим слово  $w_1 \delta w_3$ . Поскольку  $|\delta w_3| \geq k - 1$ , слово  $\tau$  является суффиксом слова  $w_1 \delta w_3$  и из равенства (3) получаем

$$\begin{aligned} p_1(w_1 \delta w_3|\tau) &= p_1(w_1 \delta|\tau)p_1(w_3|\delta) \geq p_1(w_1 \delta|\tau)p_1(w_2 \delta|\delta)p_1(w_3|\delta) \\ &= p_1(w_\tau|\tau) > 1/2. \end{aligned}$$

Это противоречит определению слова  $w_\tau$ , т. е. все подслова длины  $k - 1$  в слове  $w_\tau$  разные и справедливо неравенство (34). Определим число  $\Gamma$  равенством

$$\Gamma = (k - 1) \prod_{\tau \in A^{k-1}} |w_\tau| \leq (k - 1)(|A|^{k-1} + k - 2)^{|A|^{k-1}} = C, \quad (35)$$

где  $C$  — константа, не зависящая от  $n$ .

Пусть  $B = A^\Gamma$  и  $u \in B^*$ . Тогда через  $u[\Gamma]$  обозначим слово в алфавите  $A$ , соответствующее слову  $u$  ( $|u[\Gamma]| = \Gamma|u|$ ).

Рассмотрим марковский источник  $S_2$  первого порядка в алфавите  $B$  с вероятностями

$$p_{S_2}(a|b) = p_2(a|b) = p_1(a[\Gamma]|b'), \quad (36)$$

где  $b'$  — суффикс длины  $k - 1$  слова  $b[\Gamma]$ .

3. Покажем, что источник  $S_2$  удовлетворяет условию (18). Пусть  $\mu_{S_2}(b, u) = b$ , т. е.  $b$  — последняя буква в слове  $u$  и  $p_2(u|b) > 1/2$ . Докажем, что слово  $u$  есть степень буквы  $b$ . Из равенства (36) получаем,

что  $p_1(u[\Gamma]|b') = p_2(u|b) > 1/2$ , где  $b'$  — суффикс длины  $k-1$  слова  $b[\Gamma]$  и, следовательно, слова  $u[\Gamma]$ . Тогда  $u[\Gamma] \in A_{b'}$  и по доказанному в пункте 2  $u[\Gamma] = w_{b'}^t$  для некоторого целого числа  $t$ . Так как число  $|w_{b'}|$  делит  $\Gamma$ , то  $b[\Gamma] = w_{b'}^{t'}$  и  $u[\Gamma] = (b[\Gamma])^{t/t'}$ , т. е.  $u = b^s$ , где  $s = t/t'$ .

4. Слово  $w$  из  $M(\mathbf{r}_n)$  представим в виде  $w = v[\Gamma]w'$ , где  $|w'| < \Gamma$  и  $v \in B^*$ . Из пункта (b) утверждения 2 вытекает, что  $l(\bigcup_{i=0}^{\Gamma} A^i) = |\bigcup_{i=0}^{\Gamma} A^i| - 1$ . Поэтому

$$l(w) \leq l(v) + l\left(\bigcup_{i=0}^{\Gamma} A^i\right) + 1 \leq l(v) + (|A|^{\Gamma+1} - 1)/(|A| - 1). \quad (37)$$

Из равенства (36) следует, что

$$I_2(v|b_0) = I_1(v[\Gamma]|\tau_0) \leq I_1(w|\tau_0), \quad (38)$$

где буква  $b_0 \in B$  такова, что  $\tau_0$  — суффикс длины  $k-1$  слова  $b_0[\Gamma]$ . Здесь и далее  $I_1 = I_{S_1}$  и  $I_2 = I_{S_2}$ .

5. Рассмотрим множество

$$E = \left\{d \in B \mid -\log \log \frac{1}{p_2(d|d)} \geq \log^2 I(\mathbf{r}_n)\right\},$$

состоящее из букв, образующих длинные серии. Слово  $v \in B^*$  разобьем на подслова, выделяя подслова, состоящие из повторений какой-либо буквы из множества  $E$ . Число  $I_2(v|b_0)$  представим в виде

$$I_2(v|b_0) = I'(v|b_0) + \sum_{d \in E} I_{2,d}(v|b_0), \quad (39)$$

где  $I'(v|b_0) = \sum_{c \in B \setminus E} I_{2,c}(v|b_0)$ .

Если  $d \neq B$ , то рассмотрим марковский источник  $S_3$  первого порядка в алфавите  $C = (B \setminus E) \cup \{\lambda\}$ , где  $\lambda \notin B$  играет роль "фиктивной" буквы. Вероятности букв определим равенствами:  $p_{S_3}(c|b) = p_3(c|b) = p_2(c|b)$ , если  $c, b \in C \setminus \{\lambda\}$ ;  $p_{S_3}(c|\lambda) = p_3(c|\lambda) = 1/|C|$  для всех  $c \in C$ ;  $p_{S_3}(\lambda|b) = p_3(\lambda|b) = \sum_{d \in E} p_2(d|b)$ . Ясно, что для любых слов  $v \in (C \setminus \{\lambda\})^*$

и  $c \in C \setminus \{\lambda\}$  имеет место равенство  $p_3(v|c) = p_2(v|c)$ . По определению источника  $S_3$  для единственной добавленной буквы  $\lambda$  и всех  $c \in C$  имеем  $p_3(c|\lambda) \leq 1/2$ . Поэтому источник  $S_3$  так же, как и источник  $S_2$ , удовлетворяет условию (18). Если  $E = B$ , то положим  $S_3 = S_2$ .

Слово  $v \in B^*$  представим в виде конкатенации  $v = v_1 v_2 \dots v_m$ , где либо  $v_i \in C^*$ , либо  $v_i = d^{s_i}$  для некоторой буквы  $d \in E$ . Набор слов  $v_i$  разобьем на несколько подмножеств. Пусть  $F_0 = \{v_i \mid v_i \in C^*\}$  и  $F_d = \{v_i \mid v_i = d^{s_i}\}$  для каждого  $d \in E$ . Через  $f_0$  и  $f_d$  обозначим число включений слов из множеств  $F_0$  и  $F_d$  соответственно в конкатенацию  $v_1 v_2 \dots v_m$ .

Из введенных обозначений непосредственно вытекают соотношения:

$$f_0 \leq \sum_{d \in E} f_d + 1, \quad |F_d| \leq f_d \quad (40)$$

и

$$l(v) \leq l(F_0) + \sum_{d \in E} l(F_d) + 2 \sum_{d \in E} f_d. \quad (41)$$

6. Оценим сверху величину  $l(F_d)$  для произвольного  $d \in E$ . Для упрощения вычислений будем полагать, что  $d$  не является последней буквой слова  $v$  и каждое слово  $v_i \in F_d$  входит в конкатенацию  $v_1 v_2 \dots v_m$  однократно, т. е.  $f_d = |F_d|$ . Пусть  $N_d = \prod_{v_i \in F_d} |v_i|$ . Из утверждения 11 следует, что при  $N_d \rightarrow \infty$

$$l(F_d) \leq (1 + o(1)) \left( \frac{\log N_d}{\log \log N_d} + \log \frac{n}{\Gamma} + |F_d| \right). \quad (42)$$

Покажем, что

$$\log N_d \leq I_{2,d}(v|b_0). \quad (43)$$

Учитывая неравенство  $\sum_{v_i \in F_d} |v_i| \leq r_v(d)$ , как и в [5] получаем

$$\log \prod_{v_i \in F_d} |v_i| \leq \log \left( \frac{r_v(d)}{f_d} \right)^{f_d} = f_d \log \frac{r_v(d)}{f_d}.$$

Так как  $f_d = \sum_{b \neq d} r_v(db)$ , то из утверждений 8 (b) и 9 (a) следует, что

$$f_d \log \frac{r_v(d)}{f_d} \leq I_d(\mathbf{r}_v) \leq I_{2,d}(v) \leq I_{2,d}(v|b_0).$$

Теперь покажем от противного, что при  $n \rightarrow \infty$  справедливо неравенство

$$l(F_d) \leq (1 + o(1)) \left( \frac{I_{2,d}(v|b_0)}{\log I_{2,d}(v|b_0)} + \log n + f_d \right) + \log I(\mathbf{r}_n). \quad (44)$$

Пусть при  $n \rightarrow \infty$  неравенство (44) не выполняется. Тогда найдется подпоследовательность  $n_m$  такая, что  $l(F_d) \geq \log I(\mathbf{r}_{n_m})$ , причем по условию теоремы  $\log I(\mathbf{r}_{n_m}) \rightarrow \infty$  при  $m \rightarrow \infty$ . Следовательно,  $l(F_d) \rightarrow \infty$  и

$N_d \rightarrow \infty$  при  $m \rightarrow \infty$ , так как  $\max_{v_i \in F_d} \log |v_i| \geq l(F_d)$ . Тогда неравенство (44) получается из неравенств (42), (43) и возрастания функции  $\frac{t}{\log t}$  при  $t \geq e$ . Противоречие. Таким образом справедливость неравенства (44) установлена.

7. Оценим сверху величину  $f_d$  для произвольной буквы  $d \in E$ . Из неравенства  $t' - 1 \geq \ln t'$  при  $t' > 0$  нетрудно получить справедливое при  $t \in (0, 1)$  неравенство  $\ln \frac{1}{1-t} \geq -\ln \ln \frac{1}{t}$  и неравенство  $\log \frac{1}{1-t} \geq -\log \log \frac{1}{t} + \log \log e$ . Из пункта (b) утверждения 8 получаем

$$\begin{aligned} I_{2,d}(v|b_0) &= \sum_{b \in B} r_v(db) \log \frac{1}{p_2(b|d)} \geq f_d \log \frac{1}{1-p_2(d|d)} \\ &\geq f_d \left( -\log \log \frac{1}{p_2(d|d)} + \log \log e \right). \end{aligned}$$

Тогда из определения множества  $E$  и формул (33), (38), (39) следуют неравенства

$$I_{2,d}(v|b_0) \leq I(\mathbf{r}_n) \quad (45)$$

и

$$f_d \leq \frac{I_{2,d}(v|b_0)}{-\log \log (p_2(d|d))^{-1} + \log \log e} \leq \frac{I(\mathbf{r}_n)}{\log^2 I(\mathbf{r}_n)}. \quad (46)$$

8. Используя лемму 3, оценим сверху величину  $l(F_0)$ . Обозначим через  $v'_i$  слово  $v_i$  без первой буквы, т. е.  $v_i = c_i v'_i$ . Из равенства (39) следует, что

$$I'(v|b_0) = - \sum_{v_i \in F_0} \log p_2(v'_i d_i | c_i),$$

где  $d_i$  — буква, следующая за подсловом  $v_i$  в слове  $v$ . Из определения множества  $F_0$  следует, что  $d_i \notin C$ , а из определения источника  $S_3$  следует, что  $-\log p_3(\lambda|c) \leq -\log p_2(d_i|c)$  для произвольной буквы  $c \in C$ . Поэтому

$$I'(v|b_0) \geq - \sum_{v_i \in F_0} \log p_3(v'_i \lambda | c_i) = - \sum_{v_i \in F_0} \log p_3(v_i \lambda | \lambda) + \log p_3(c_i | \lambda).$$

Отсюда и из определения источника  $S_3$  следует, что

$$\sum_{v_i \in F_0} I_3(v_i \lambda) = \sum_{v_i \in F_0} I_3(v_i \lambda | \lambda) \leq I'(v|b_0) + f_0 \log \frac{1}{|C|}.$$

Так как буква  $\lambda$  отсутствует в словах  $v_i$ , то всюду сократив ее в схеме конкатенации слов  $v_i \lambda$ , получим схему конкатенации слов  $v_i$ . Следовательно,

$l(F_0) \leq l(\{v_i \lambda | v_i \in F_0\})$ . Пусть  $\widehat{I} = I'(v|b_0) + f_0 \log \frac{1}{|C|}$ ,  $h_n = \log I(\mathbf{r}_n)$  и  $I = \max\{\widehat{I}, h_n^{1+\log \log h_n}\}$ . При  $n \rightarrow \infty$  имеем

$$8(\log^2 I(\mathbf{r}_n)|B|)^5 < \frac{h_n^{1+\log \log h_n}}{((1 + \log \log h_n) \log h_n)^2} \leq \frac{I}{\log^2 I},$$

так как по условию теоремы  $h_n \rightarrow \infty$ . Таким образом, выполнены условия леммы 3, из которой следует неравенство

$$l(F_0) \leq \frac{I}{\log I} \left( 1 + \frac{1 + \log \theta}{\log I} + \frac{\log^2 \theta}{\log I (\log I - \log \theta)} \right) + |B| \log^2 I(\mathbf{r}_n),$$

где  $\theta = 8 \log^2 I(\log^2 I(\mathbf{r}_n)|B|)^5$ . Так как

$$\log \log I(\mathbf{r}_n) = o(\log h_n(1 + \log \log h_n)) = o(1) \log I,$$

то  $\log \theta = o(1) \log I$  и предыдущее неравенство можно представить в виде

$$l(F_0) \leq \frac{I}{\log I} (1 + o(1)) + |B| \log^2 I(\mathbf{r}_n). \quad (47)$$

Из определения величины  $h_n$  следует, что при  $n \rightarrow \infty$

$$h_n^{1+\log \log h_n} = o\left(\frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}\right).$$

Тогда, учитывая определения величин  $I$  и  $\widehat{I}$ , из неравенств (40), (46) и (47) при  $n \rightarrow \infty$  получаем

$$l(F_0) \leq \left( \frac{\widehat{I}}{\log \widehat{I}} + \frac{h_n^{1+\log \log h_n}}{\log h_n(1 + \log \log h_n)} \right) (1 + o(1)) = \frac{I'(v|b_0)}{\log I'(v|b_0)} + o\left(\frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}\right). \quad (48)$$

9. Получим верхнюю оценку величины  $l(w)$  для слов  $w \in M(\mathbf{r}_n)$ . Пусть слово  $v \in B^*$  соответствует слову  $w \in A^*$  как указано в п. 4. Из неравенств (41), (44), (45), (46) и (48) следует, что при  $n \rightarrow \infty$

$$l(v) \leq \frac{I'(v|b_0)}{\log I'(v|b_0)} + \sum_{d \in E} \frac{I_{2,d}(v|b_0)}{\log I_{2,d}(v|b_0)} + o\left(\frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}\right) + C \log n,$$

где  $C > 0$  не зависит от  $n$ . Из условия теоремы следует, что при  $n \rightarrow \infty$

$$\log n = o\left(\frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}\right). \quad (49)$$

Используя утверждение 10 и формулу (39), при  $n \rightarrow \infty$  получаем

$$l(v) \leq \frac{I_2(v|b_0)}{\log I_2(v|b_0)}(1 + o(1)) + o\left(\frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}\right).$$

Отсюда и из (33), (37), (38) следует, что при  $n \rightarrow \infty$

$$l(w) \leq \frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}(1 + o(1)). \quad (50)$$

10. Из (49) и утверждения 7 следует соотношение  $\log |M(\mathbf{r}_n)| \sim I(\mathbf{r}_n)$ . Отсюда и из утверждения 1 при  $n \rightarrow \infty$  получаем

$$L(M(\mathbf{r}_n)) \geq \frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}(1 + o(1)).$$

Пользуясь этим неравенством и (50), при  $n \rightarrow \infty$  имеем

$$L(M(\mathbf{r}_n)) \sim \frac{I(\mathbf{r}_n)}{\log I(\mathbf{r}_n)}.$$

Теорема 4 доказана.

Пусть  $x$  — последовательность букв в алфавите  $A$  и слово  $x^n = x_1 \dots x_n$  — ее префикс длины  $n$ . Рассмотрим вектор  $\mathbf{r}_n(k, x) = (r_{x^n}(\sigma_1), \dots, r_{x^n}(\sigma_T))$ , где  $\sigma_i \in A^k$  и  $T = |A|^k$ . Тогда  $x^n \in M(\mathbf{r}_n(k, x))$  и  $l(x^n) \leq L(M(\mathbf{r}_n(k, x)))$ . Из теоремы 4 непосредственно вытекает

**Следствие 2.** Пусть  $\lim_{n \rightarrow \infty} (\log I(\mathbf{r}_n(k, x)) \log n) / I(\mathbf{r}_n(k, x)) = 0$  при  $x \in A^\infty$ . Тогда при  $n \rightarrow \infty$

$$l(x^n) \leq \frac{I(\mathbf{r}_n(k, x))}{\log I(\mathbf{r}_n(k, x))}(1 + o(1)).$$

## ЛИТЕРАТУРА

1. Берж К. Теория графов и ее применения. М.: Изд-во иностранной литературы, 1962.
2. Боровков А. А. Теория вероятностей. М.: Наука, 1976.

3. Галлагер Р. Теория информации и надежная связь. М.: Советское радио, 1974.
4. Гашков С. Б., Кочергин В. В. Об аддитивных цепочках векторов, вентиляных схемах и сложности вычисления степеней // Методы дискретного анализа в теории графов и сложности: Сб. науч. тр. Вып. 52. Новосибирск: Ин-т математики СО РАН, 1992. С. 24–40.
5. Кочергин В. В. О мультипликативной сложности двоичных слов с заданным числом единиц // Математические вопросы кибернетики. Вып. 8. М.: Наука, 1999. С. 63–76.
6. Лупанов О. Б. Об одном подходе к синтезу управляющих систем — принципе локального кодирования // Проблемы кибернетики. Вып. 14. М.: Наука, 1965. С. 31–110.
7. Марков А. А. Введение в теорию кодирования. М.: Наука, 1982.
8. Потапов В. Н. Энтропия и мультипликативная сложность слов // Материалы XI Межгосударственной школы-семинара "Синтез и сложность управляющих систем" (Нижний Новгород, 20–25 ноября 2000 г.). Часть II. М.: Изд-во центра прикл. исслед. при мех.-мат. фак. МГУ, 2001. С. 160–162.
9. Потапов В. Н. Энтропийная оценка мультипликативной сложности // Проблемы теоретической кибернетики: Тезисы докладов XIII Международной конференции (Казань, 27–31 мая 2002 г.). Часть II. М.: Изд-во центра прикл. исслед. при мех.-мат. фак. МГУ, 2002. С. 154.
10. Стенли Р. Перечислительная комбинаторика. М.: Мир, 1990.
11. van Aardenne-Ehrenfest T., de Bruijn N. G. Circuits and trees in oriented linear graphs // Simon Stevin. 1951. V. 28. P. 203–217.

Адрес автора:

Институт математики  
им. С. Л. Соболева СО РАН,  
пр. Академика Коптюга, 4,  
630090 Новосибирск,  
Россия  
E-mail: vpotapov@math.nsc.ru

Статья поступила  
15 августа 2003 г.