



Р. М. Колпаков

**Некоторые результаты
о возможном числе
периодических
факторов в словах**

Рекомендуемая форма библиографической ссылки:
Колпаков Р. М. Некоторые результаты о возможном числе периодических факторов в словах // Математические вопросы кибернетики. Вып. 20. — М.: ФИЗМАТЛИТ, 2022. — С. 25–40. URL: <http://library.keldysh.ru/mvk.asp?id=2022-25>
DOI: 10.20948/mvk-2022-25

НЕКОТОРЫЕ РЕЗУЛЬТАТЫ О ВОЗМОЖНОМ ЧИСЛЕ ПЕРИОДИЧЕСКИХ ФАКТОРОВ В СЛОВАХ

Р. М. КОЛПАКОВ

(МОСКВА)

Пусть $w = w[1]w[2] \dots w[n]$ — произвольное формальное слово длины $|w| = n$. Фрагмент $w[i]w[i+1] \dots w[j]$ слова w , где $1 \leq i \leq j \leq n$, называется *фактором* слова w и обозначается через $w[i..j]$. Для любого $i = 1, \dots, n$ фактор $w[1..i]$ ($w[i..n]$) называется *префиксом* (*суффиксом*) слова w . Если два фактора v' , v'' слова w являются фактически одним и тем же фрагментом слова w , мы обозначаем это через $v' \equiv v''$. Отметим, что любые два фактора $w[i'..j']$, $w[i''..j'']$ такие, что $i' \neq i''$ или $j' \neq j''$, рассматриваются как различные факторы слова w даже если эти факторы являются одинаковыми словами. Таким образом, через $w[i'..j'] \equiv w[i''..j'']$ мы обозначаем то, что $w[i'..j']$ и $w[i''..j'']$ являются одним и тем же фактором, т. е. $i' = i''$ и $j' = j''$, в то время как через $w[i'..j'] = w[i''..j'']$ мы обозначаем то, что $w[i'..j']$ и $w[i''..j'']$ являются одинаковыми словами. Если некоторое слово u совпадает с некоторым фактором v слова w , то v называется *вхождением* слова u в w . Натуральное число $p \leq |w|$ называется *периодом* слова w , если $w[i] = w[i+p]$ для каждого $i = 1, \dots, n-p$. Мы обозначаем через $p(w)$ минимальный период слова w и через $e(w)$ отношение $|w|/p(w)$, которое называется *порядком* слова w . Значение $re(w) = e(w) - 1$ называется *сокращенным порядком* слова w . Например, для слова $w = abaaba$ мы имеем $p(w) = 3$, $e(w) = 5/3$ и $re(w) = 2/3$. Слово называется *периодическим*, если его порядок не меньше, чем 2. Слово называется *примитивным*, если это слово не является периодическим словом целого порядка. Вхождения периодических слов в некотором слове называются *периодичностями* в этом слове.

Пусть r — некоторая периодичность. Любой фактор длины $p(r)$ в r называется *циклическим корнем* периодичности r . Например, периодичность $abaabaab$ имеет различные циклические корни aba , baa и aab . Две периодичности называются *периодичностями с одинаковыми циклическими корнями*, если они имеют одинаковые множества различных циклических корней. Например, периодичности $abaabaab$ и $aabaabaaba$ являются периодичностями с одинаковыми циклическими корнями.

Периодичность в некотором слове называется *максимальной*, если эта периодичность не может быть расширена в этом слове ни на один символ ни вправо, ни влево с сохранением ее минимального периода. Более строго,

что $R(n) = R_{\geq 1}(n) \geq R_{\geq 2}(n) \geq \dots$. Для максимальных периодичностей могут быть естественным образом предположены следующие г и п о т е з ы:

1. $R_{\geq \lambda}(n) \leq cn$, где $c \rightarrow 0$, при $\lambda \rightarrow \infty$.
2. Число максимальных периодичностей, содержащих одну и ту же букву*, в слове w равно $o(|w|)$ при $|w| \rightarrow \infty$.

К сожалению, обе гипотезы являются неверными. В качестве контрпримера можно рассмотреть слово $w_k = (01)^k 0 (01)^k 0 = (01)^k 00 (10)^k$ длины $4k + 2$. Нетрудно увидеть, что w_k содержит $k + 3$ максимальных периодичностей, указанных на рис. 2. Легко заметить, что из этих максимальных периодично-

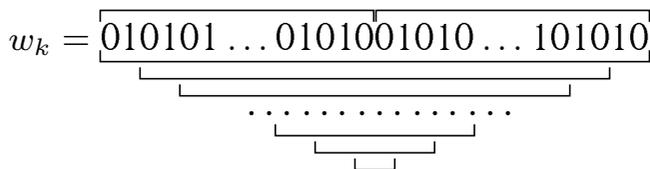


Рис. 2. Максимальные периодичности в слове w_k

стей $k + 1 - \lfloor \lambda/2 \rfloor$ периодичностей имеют минимальные периоды не меньше, чем λ , поэтому**) $R_{\geq \lambda}(w_k) = k + 1 - \lfloor \lambda/2 \rfloor \gtrsim k \gtrsim |w_k|/4$ при $k \rightarrow \infty$. Таким образом,

$$R_{\geq 1}(n) \geq R_{\geq 2}(n) \geq \dots \gtrsim n/4.$$

Кроме того, средние буквы слова w_k содержатся в $k + 2 > |w_k|/4$ максимальных периодичностях. С другой стороны, легко увидеть, что в действительности w_k имеет две смежные максимальные периодичности $(01)^k 0$, в то время как другие максимальные периодичности в w_k образуют серию вложенных друг в друга периодичностей, начинающихся в левой периодичности $(01)^k 0$ и заканчивающихся в правой периодичности $(01)^k 0$. Это может быть представлено в терминах порождения периодичностей, введенного в [13], в частности порождения серии максимальных периодичностей максимальными периодичностями $(01)^k 0$. Строго говоря, мы говорим, что в слове w две смежные и, возможно, пересекающиеся максимальные периодичности $r' \equiv w[i'..j']$, $r'' \equiv w[i''..j'']$ с одинаковыми циклическими корнями порождают максимальную периодичность $r \equiv w[i..j]$, если $p(r) \geq 3p$, $i' < i \leq j'$ и $i'' \leq j < j''$, где p — минимальный период периодичностей r' и r'' (см. рис. 3). Максимальная периодичность называется *вторичной*, если она порождается другими максимальными периодичностями в слове. Максимальная периодичность называется *первичной*, если она не является вторичной. Например, на рис. 4 указаны вторичные периодичности в слове w_k . Можно показать, что любая вторичная периодичность порождается единственной парой первичных периодичностей. Заметим, что первичные периодичности в слове однозначно определяют все вторичные периодичности и тем самым однозначно определяют все остальные максимальные периодичности в слове. Для

*) Здесь буквы, находящиеся в различных позициях слова, считаются различными, даже если эти буквы являются одинаковыми.

**) Напомним, что $f(n) \gtrsim g(n)$ означает, что $f(n) \geq g(n) - o(g(n))$ при $n \rightarrow \infty$.

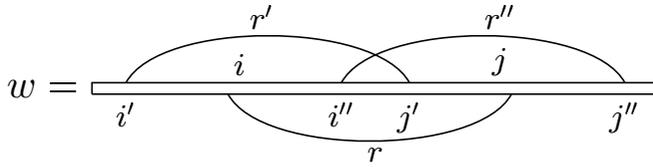


Рис. 3. Порождение максимальных периодичностей

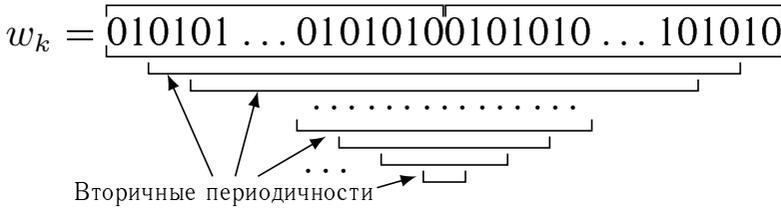


Рис. 4. Вторичные периодичности в w_k

любого натурального λ обозначим через $Rp_{\geq \lambda}(n)$ максимальное возможное число первичных периодичностей с минимальными периодами не меньшими, чем λ , в словах длины n , через $Ep_{\geq \lambda}(n)$ — максимальную возможную сумму порядков первичных периодичностей с минимальными периодами, не меньшими, чем λ , в словах длины n , и через $Eps_{\geq \lambda}(n)$ — максимально возможную сумму порядков первичных периодичностей с минимальными периодами, не меньшими, чем λ , и вторичных периодичностей, порождаемых этими первичными периодичностями, в словах длины n . Очевидно, что $Eps_{\geq \lambda}(n) \geq Ep_{\geq \lambda}(n) \geq 2Rp_{\geq \lambda}(n)$. В [18] доказано, что $Eps_{\geq \lambda}(n) = O(n/\lambda)$, так $Ep_{\geq \lambda}(n) = O(n/\lambda)$ и $Rp_{\geq \lambda}(n) = O(n/\lambda)$. Таким образом, число первичных периодичностей в слове удовлетворяет гипотезе 1. Более того, в [18] также доказано, что в слове длины n одна и та же буква содержится в не более чем $O\left(\log \frac{n}{\lambda}\right)$ первичных периодичностей с минимальными периодами, не меньшими, чем λ , тем самым первичные периодичности в слове удовлетворяют также гипотезе 2. Таким образом, первичные периодичности в слове являются более удобными для рассмотрения и анализа, чем все максимальные периодичности в слове. Также было показано, что порядок любой вторичной периодичности меньше, чем $7/3$, т.е. любая максимальная периодичность, порядок которой не меньше, чем $7/3$, является первичной. Таким образом, мы получаем, что в слове длины n содержится $O(n/\lambda)$ максимальных периодичностей, минимальные периоды которых не меньше, чем λ , и порядки которых не меньше, чем $7/3$, при этом не более чем $O\left(\log \frac{n}{\lambda}\right)$ таких периодичностей могут содержать один и тот же символ в данном слове.

Естественным обобщением периодичностей являются факторы слова, порядки которых строго меньше, чем 2, но не меньше некоторого порогового значения, большего единицы. Мы называем такие факторы *субпериодичностями*. Более строго, фактор r называется *субпериодичностью* (δ -subrepetition), если $1 < e(r) < 2$ ($1 + \delta \leq e(r) < 2$). Заметим, что аналогично понятию максимальной периодичности мы также можем ввести по-

нятие максимальной субпериодичности: субпериодичность в слове называется *максимальной*, если она не может быть расширена в этом слове ни на один символ ни вправо, ни влево с сохранением ее минимального периода (см. рис. 5).

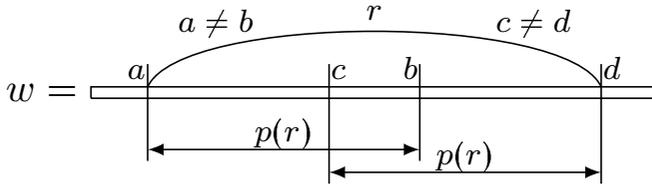


Рис. 5. Максимальная субпериодичность

Другим обобщением периодичностей являются *разрывные повторы*, являющиеся тесно связанными с субпериодичностями. Разрывными повторами являются факторы вида uvu , где u и v — непустые слова. Первый (второй) фактор u в разрывном повторе uvu называется *левой (правой) копией*, а фактор v называется *разрывом*. Под *периодом* разрывного повтора uvu понимается величина $|u| + |v|$ (заметим, что, вообще говоря, период разрывного повтора uvu может быть больше минимального периода слова uvu). Для разрывного повтора σ мы обозначаем длину копий повтора σ через $c(\sigma)$ и период повтора σ через $p(\sigma)$ (см. рис. 6). Под *порядком* $\widehat{e}(\sigma)$ разрывного

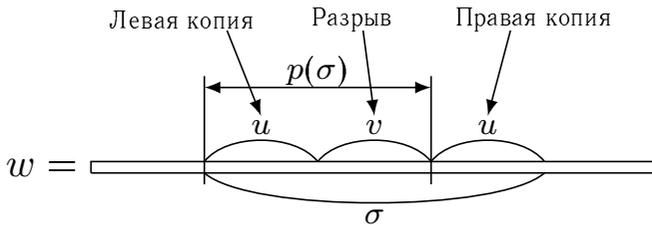


Рис. 6. Разрывный повтор σ в слове w

повтора $\sigma = uvu$ понимается величина $\frac{|\sigma|}{p(\sigma)} = 1 + \frac{c(\sigma)}{p(\sigma)}$, а под *сокращенным порядком* $r\widehat{e}(\sigma)$ повтора σ понимается величина $\widehat{e}(\sigma) - 1 = \frac{c(\sigma)}{p(\sigma)}$ (поскольку $p(\sigma)$ может быть больше минимального периода слова uvu , величина $\widehat{e}(\sigma)$ может быть меньше порядка слова uvu). Отметим, что различные разрывные повторы, имеющие разные периоды, могут образовывать один и тот же фактор в слове. Такие повторы рассматриваются как различные. Для любого вещественного $\alpha > 1$ разрывный повтор σ называется α -*разрывным*, если $p(\sigma) \leq \alpha c(\sigma)$.

Аналогично периодичностям разрывный повтор в слове называется *максимальным*, если его копии не могут быть расширены в этом слове ни на один символ ни вправо, ни влево с сохранением периода повтора (см. рис. 7). Например, в слове, изображенном на рис. 8, разрывные повторы $u'v'u'$ и $u''v''u''$ являются максимальными.

Заметим, что любой α -разрывный повтор $\sigma = uvu$ однозначным образом расширяется либо до максимального α -разрывного повтора $\sigma' = u'v'u'$ с тем

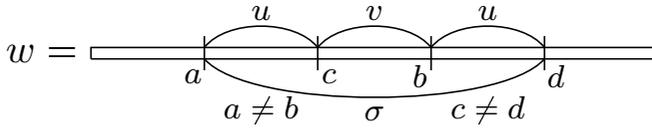


Рис. 7. Максимальный разрывный повтор σ в слове w

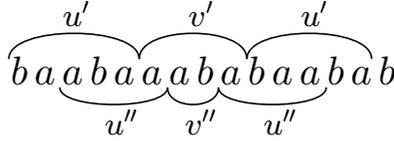


Рис. 8. Максимальные повторы в слове

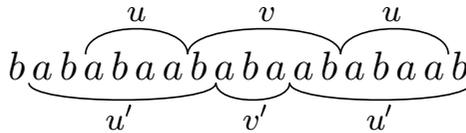


Рис. 9. Повтор, расширяемый до максимального разрывного повтора

же самым периодом (см. рис. 9), либо до максимальной периодичности r такой, что $p(r)$ является делителем периода $p(\sigma)$ (см. рис. 10).

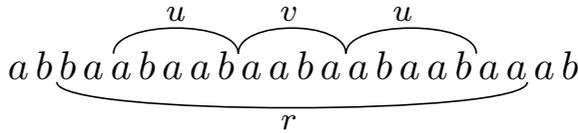


Рис. 10. Повтор, расширяемый до максимальной периодичности

Пусть r — некоторая максимальная δ -субпериодичность в слове w . Заметим, что мы можем также рассматривать r как разрывный повтор σ с периодом $p(r)$, левая (правая) копия которого является префиксом (суффиксом) длины $|r| - p(r)$ в слове w (см. рис. 11). Легко увидеть, что σ

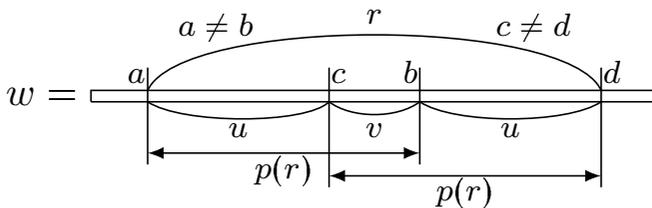


Рис. 11. Повтор, сопоставленный максимальной субпериодичности

является максимальным $\frac{1}{\delta}$ -разрывным повтором. Мы называем субпериодичность r и повтор σ сопоставленными друг другу. Заметим, что сопо-

ставленные друг другу субпериодичность r и повтор σ однозначно определяются друг из друга и $p(\sigma) = p(r)$, поэтому $\widehat{e}(\sigma) = e(r)$ ($r\widehat{e}(\sigma) = re(r)$). Таким образом, любая максимальная δ -субпериодичность соответствует сопоставленному ей максимальному $\frac{1}{\delta}$ -разрывному повтору. Вместе с тем для максимального разрывного повтора может не быть сопоставленной ему максимальной субпериодичности. Например, в слове, изображенном на рис. 12, разрывный повтор uvu сопоставляется максимальной субпериодичности r , в то время как разрывный повтор $u'v'u'$ не сопоставлен r , поэтому повтор $u'v'u'$ не имеет сопоставленной ему максимальной субпериодичности. Мак-

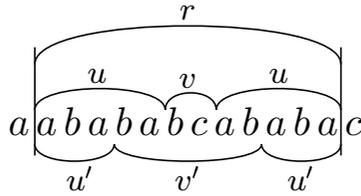


Рис. 12. Принципиальные и непринципиальные повторы

симальные разрывные повторы сопоставленные максимальной субпериодичностям называются *принципиальными*, в противном случае они называются *непринципиальными*. Таким образом, на рис. 12 повтор uvu является принципиальным, в то время как повтор $u'v'u'$ является непринципиальным. Поскольку имеется взаимно-однозначное соответствие между максимальными δ -субпериодичностями и принципиальными $\frac{1}{\delta}$ -разрывными повторами, мы получаем следующий факт.

Утверждение 1. В любом слове число максимальных субпериодичностей (δ -субпериодичностей) не превосходит числа максимальных разрывных повторов ($\frac{1}{\delta}$ -разрывных повторов).

Разрывный повтор uvu называется *примитивным*, если слово uv является примитивным. Например, на рис. 13 повтор $\sigma' \equiv u'v'u'$ является максимальным непримитивным разрывным повтorem, а повтор $\sigma'' \equiv u''v''u''$ — максимальным примитивным разрывным повтorem. Легко заметить, что для

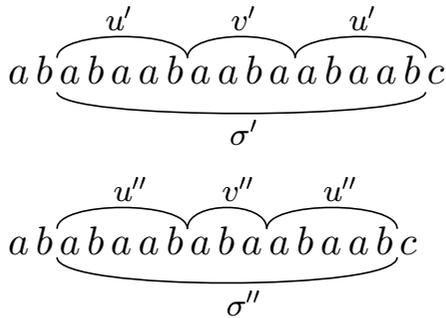


Рис. 13. Примитивные и непримитивные повторы в двух различных словах

любого непримитивного разрывного повтора $\sigma' \equiv u'v'u'$ фактор $u'v'u'$ является максимальной периодичностью с минимальным периодом, равным $p(u'v')$.

Теорема 2. $RE^m(w) < n \ln n$ для любого слова w длины n .

Доказательство. Для каждого максимального разрывного повтора σ из $RE^m(w)$ мы разлагаем величину $r\hat{e}(\sigma) = \frac{c(\sigma)}{p(\sigma)}$ на $c(\sigma)$ слагаемых, соответствующих парам $(w[i], w[i + p(\sigma)])$ одинаковых символов в повторе σ . Каждое такое слагаемое дает в сумму $RE^m(w) = \sum_{\sigma \in K^m(w)} r\hat{e}(\sigma)$ вклад, равный $\frac{1}{p(\sigma)}$. Рассмотрим в w две позиции i и j , где $1 \leq i < j \leq n$. Если $w[i] = w[j]$, то эта пара одинаковых символов соответствует слагаемому, включенному в величину $r\hat{e}(\sigma)$ для некоторого однозначным образом определенного максимального разрывного повтора σ такого, что $w[i]$ и $w[j]$ являются соответствующими символами левой и правой копий повтора σ соответственно. Заметим, что в этом случае $p(\sigma) = j - i$, поэтому пара $(w[i], w[j])$ дает вклад в $RE^m(w)$, равный величине $\frac{1}{p(\sigma)} = \frac{1}{j - i}$. Учитывая всевозможные пары различных символов в w , мы получаем верхнюю оценку

$$RE^m(w) \leq \sum_{1 \leq i < j \leq n} \frac{1}{j - i} = \sum_{p=1}^{n-1} \frac{n-p}{p} = n \sum_{p=1}^{n-1} \frac{1}{p} - (n-1).$$

Поскольку функция $f(x) = \frac{1}{x}$ является выпуклой вниз для $x > 0$, мы имеем

$$\sum_{p=2}^{n-1} \frac{1}{p} \leq \int_{3/2}^{n-1/2} \frac{dx}{x}.$$

Кроме того, поскольку $f'(1) = -1$, мы также имеем $\int_1^{3/2} \frac{dx}{x} \geq 3/8$. Таким образом,

$$\sum_{p=1}^{n-1} \frac{1}{p} \leq \frac{5}{8} + \int_1^{n-1/2} \frac{dx}{x} = \frac{5}{8} + \ln(n-1/2) < \frac{5}{8} + \ln n.$$

Следовательно,

$$n \sum_{p=1}^{n-1} \frac{1}{p} - (n-1) < n \ln n + \left(\frac{5}{8}n - (n-1)\right) = n \ln n + \left(1 - \frac{3}{8}n\right) < n \ln n$$

для $n > 2$. Таким образом, $RE^m(w) < n \ln n$.

Отметим, что разрывный повтор σ является α -разрывным повтором, если $\frac{p(\sigma)}{c(\sigma)} \leq \alpha$, т. е. $r\hat{e}(\sigma) = \frac{c(\sigma)}{p(\sigma)} \geq 1/\alpha$. Поэтому из теоремы 2 вытекает следующий факт.

Следствие 2. Число всех максимальных α -разрывных повторов в слове длины n меньше, чем $\alpha n \ln n$.

Из утверждения 1 и следствия 2 мы получаем следующую верхнюю оценку для числа максимальных δ -субпериодичностей в слове.

Следствие 3. Число всех максимальных δ -субпериодичностей в слове длины n меньше, чем $(n \ln n)/\delta$.

Теорема 2 может быть обобщена на случай максимальных разрывных повторов с ограниченными периодами. Пусть $\lambda = 2, 3, \dots$. Обозначим через $RE_{\geq \lambda}^m(w)$ ($RE_{\leq \lambda}^m(w)$) сумму сокращенных порядков всех максимальных

разрывных повторов с периодами, не меньшими, чем λ (не большими, чем λ) в слове w . Обозначим также через $RE_{\geq \lambda}^p(w)$ ($RE_{\leq \lambda}^p(w)$) сумму сокращенных порядков всех максимальных примитивных разрывных повторов с периодами, не меньшими, чем λ (не большими, чем λ) в слове w . В ([17], следствия 2 и 3) были получены верхние оценки для $RE_{\geq \lambda}^p(w)$ и $RE_{\leq \lambda}^p(w)$ для любого слова w . Используя аналогичное доказательство, мы можем получить те же самые верхние оценки для $RE_{\geq \lambda}^m(w)$ и $RE_{\leq \lambda}^m(w)$.

Теорема 3. $RE_{\geq \lambda}^m(w) < n \ln(n/\lambda)$ для любого слова w длины $n > \lambda$.

Доказательство. Заметим, что для любого максимального разрывного повтора σ с периодом, не меньшим, чем λ , каждая пара одинаковых символов $(w[i], w[j])$, соответствующая слагаемому, включенному в величину $r\hat{e}(\sigma)$, удовлетворяет ограничению $j - i = p(\sigma) \geq \lambda$. Таким образом, аналогично доказательству теоремы 2, верхняя оценка для $RE_{\geq \lambda}^m(w)$ может быть модифицирована следующим образом:

$$RE_{\geq \lambda}^m(w) \leq \sum_{1 \leq i < i + \lambda \leq j \leq n} \frac{1}{j - i} = \sum_{p=\lambda}^{n-1} \frac{n-p}{p} = n \sum_{p=\lambda}^{n-1} \frac{1}{p} - (n - \lambda).$$

Поскольку функция $f(x) = \frac{1}{x}$ является выпуклой вниз для $x > 0$, мы имеем

$$\sum_{p=\lambda+1}^{n-1} \frac{1}{p} \leq \int_{\lambda+1/2}^{n-1/2} \frac{dx}{x}.$$

Кроме того, поскольку $f'(\lambda) = -\frac{1}{\lambda^2}$, мы также имеем

$$\int_{\lambda}^{\lambda+1/2} \frac{dx}{x} \geq \frac{1}{2} \cdot \frac{1}{2} \left(\frac{1}{\lambda} + \left(\frac{1}{\lambda} - \frac{1}{2\lambda^2} \right) \right) = \frac{4\lambda - 1}{8\lambda^2}.$$

Таким образом,

$$\sum_{p=\lambda}^{n-1} \frac{1}{p} \leq \frac{4\lambda + 1}{8\lambda^2} + \int_{\lambda}^{n-1/2} \frac{dx}{x} = \frac{4\lambda + 1}{8\lambda^2} + \ln \left(\frac{n-1/2}{\lambda} \right) < \frac{4\lambda + 1}{8\lambda^2} + \ln \left(\frac{n}{\lambda} \right).$$

Следовательно,

$$n \sum_{p=\lambda}^{n-1} \frac{1}{p} - (n - \lambda) < n \ln \left(\frac{n}{\lambda} \right) + n \frac{4\lambda + 1}{8\lambda^2} - (n - \lambda) = n \ln \left(\frac{n}{\lambda} \right) + \left(\lambda - n \frac{8\lambda^2 - 4\lambda - 1}{8\lambda^2} \right).$$

Легко проверить, что $\lambda - n \frac{8\lambda^2 - 4\lambda - 1}{8\lambda^2} \leq 0$ для $n > \lambda > 1$. Таким образом, $RE_{\geq \lambda}^m(w) < n \ln \left(\frac{n}{\lambda} \right)$.

Теорема 4. $RE_{\leq \lambda}^m(w) < n(1 + \ln \lambda)$ для любого слова w длины n .

Доказательство. Заметим, что в этом случае каждая пара одинаковых символов $(w[i], w[j])$, соответствующая слагаемому, которое вносит вклад в $RE_{\leq \lambda}^m(w)$, удовлетворяет ограничению $j - i \leq \lambda$. Таким образом,

аналогично доказательству теоремы 2, верхняя оценка для $RE_{\leq \lambda}^m(w)$ может быть модифицирована следующим образом:

$$RE_{\leq \lambda}^m(w) \leq \sum_{1 \leq i < j \leq \min(i+\lambda, n)} \frac{1}{j-i} = \sum_{p=1}^{\lambda} \frac{n-p}{p} = n \sum_{p=1}^{\lambda} \frac{1}{p} - \lambda < n \sum_{p=1}^{\lambda} \frac{1}{p}.$$

Поскольку функция $f(x) = \frac{1}{x}$ является убывающей для $x > 0$, мы имеем

$$\sum_{p=2}^{\lambda} \frac{1}{p} \leq \int_1^{\lambda} \frac{dx}{x} = \ln \lambda.$$

Таким образом,

$$n \sum_{p=1}^{\lambda} \frac{1}{p} \leq n(1 + \ln \lambda),$$

поэтому $RE_{\leq \lambda}^m(w) < n(1 + \ln \lambda)$.

Аналогично следствиям 2 и 3 из теоремы 2 мы имеем следующие следствия из теорем 3 и 4.

Следствие 4. Число всех максимальных α -разрывных повторов с периодами, не меньшими, чем λ , в слове длины n меньше, чем $\alpha n \ln(n/\lambda)$.

Следствие 5. Число всех максимальных δ -субпериодичностей с минимальными периодами, не меньшими, чем λ , в слове длины n меньше, чем $n \ln(n/\lambda)/\delta$.

Следствие 6. Число всех максимальных α -разрывных повторов с периодами, не большими, чем λ , в слове длины n меньше, чем $\alpha n(1 + \ln \lambda)$.

Следствие 7. Число всех максимальных δ -субпериодичностей с минимальными периодами, не большими, чем λ , в слове длины n меньше, чем $n(1 + \ln \lambda)/\delta$.

Чтобы получить нижние оценки для сумм сокращенных порядков всех максимальных разрывных порядков для общего случая неограниченного алфавита, положим $RE^m(n) = \max_{|w|=n} RE^m(w)$, $RE^p(n) = \max_{|w|=n} RE^p(w)$ и $RE^s(n) = \max_{|w|=n} RE^s(w)$. Тогда мы очевидным образом получаем $RE^s(n) \leq RE^p(n) \leq RE^m(n)$. Рассмотрим слово $w'_k = ab_1ab_2ab_3 \dots ab_ka$ такое, что $|w'_k| = 2k + 1$. Легко проверить, что

$$RE^m(w'_k) = RE^p(w'_k) = RE^s(w'_k) > \frac{1}{2}[(k+1)\ln(k+1) - k] \gtrsim \frac{1}{4}|w'_k| \ln |w'_k|,$$

поэтому

$$\frac{1}{4}n \ln n \lesssim RE^s(n) \leq RE^p(n) \leq RE^m(n) \leq n \ln n.$$

Таким образом, $RE^s(n) = \Theta(n \log n)$, $RE^p(n) = \Theta(n \log n)$, $RE^m(n) = \Theta(n \log n)$.

Заметим, что w'_k содержит не меньше $\lfloor \alpha/2 \rfloor ((k+1) - \lfloor \alpha/2 \rfloor)$ максимальных примитивных α -разрывных повторов и не меньше $\lfloor \frac{1}{2\delta} \rfloor [(k+1) - \lfloor \frac{1}{2\delta} \rfloor]$

максимальных δ -субпериодичностей. Таким образом, для достаточно большого α и достаточно малого δ слово w'_k содержит $\Omega(\alpha|w'_k|)$ максимальных примитивных α -разрывных повторов и $\Omega(|w'_k|/\delta)$ максимальных δ -субпериодичностей. Заметим также, что w'_k содержит в общей сложности $\Theta(|w'_k|^2)$ максимальных субпериодичностей.

Случай ограниченного алфавита является более сложным для исследования. Для простоты мы рассматриваем случай бинарного алфавита $\{0, 1\}$. Положим $RE_{bin}^m(n) = \max_{w \in \{0,1\}^n} RE^m(w)$, $RE_{bin}^p(n) = \max_{w \in \{0,1\}^n} RE^p(w)$ и $RE_{bin}^s(n) = \max_{w \in \{0,1\}^n} RE^s(w)$. Возьмем слово $w''_k = (0011)^k = \underbrace{00110011 \dots 0011}_k$

длины $4k$. Легко заметить, что все максимальные примитивные разрывные повторы в w''_k являются повторами с однобуквенными копиями 0 или 1. Разрывные повторы в w''_k с однобуквенными копиями 0 разбиваются на две подгруппы. Первая подгруппа состоит из всех разрывных повторов, позиции левых однобуквенных копий которых тождественны 1 по модулю 4, а позиции правых однобуквенных копий которых тождественны 2 по модулю 4. Общая сумма сокращенных порядков этих повторов равна

$$\sum_{i=1}^{k-1} \sum_{j=1}^i \frac{1}{4j+1}.$$

Вторая подгруппа состоит из всех разрывных повторов, позиции левых однобуквенных копий которых тождественны 2 по модулю 4, а позиции правых однобуквенных копий которых тождественны 1 по модулю 4. Общая сумма сокращенных порядков этих повторов равна

$$\sum_{i=1}^{k-1} \sum_{j=1}^i \frac{1}{4j-1}.$$

Поэтому общая сумма сокращенных порядков всех разрывных повторов с однобуквенными копиями 0 в w''_k равна

$$\sum_{i=1}^{k-1} \sum_{j=1}^i \frac{1}{4j+1} + \sum_{i=1}^{k-1} \sum_{j=1}^i \frac{1}{4j-1} = \sum_{i=1}^{k-1} \sum_{j=1}^{2i} \frac{1}{2j+1}.$$

Симметричным образом мы имеем ту же самую сумму сокращенных порядков всех разрывных повторов с однобуквенными копиями 1 в w''_k . Таким образом, общая сумма сокращенных порядков всех максимальных примитивных разрывных повторов в w''_k равна

$$2 \sum_{i=1}^{k-1} \sum_{j=1}^{2i} \frac{1}{2j+1}.$$

Сумма $\sum_{j=1}^{2i} \frac{1}{2j+1}$ может быть ограничена снизу следующим образом:

$$\sum_{j=1}^{2i} \frac{1}{2j+1} \geq \int_1^{2i+1} \frac{1}{2x+1} dx = \frac{1}{2} \ln(2x+1) \Big|_1^{2i+1} = \frac{1}{2} (\ln(4i+3) - \ln 3).$$

Следовательно,

$$2 \sum_{i=1}^{k-1} \sum_{j=1}^{2i} \frac{1}{2j+1} \geq \sum_{i=1}^{k-1} (\ln(4i+3) - \ln 3) = \sum_{i=1}^{k-1} \ln(4i+3) - (k-1) \ln 3.$$

Более того,

$$\begin{aligned} \sum_{i=1}^{k-1} \ln(4i+3) &= \sum_{i=2}^k \ln(4i-1) > \int_1^k \ln(4x-1) dx = \\ &= [(x - \frac{1}{4}) \ln(4x-1) - x] \Big|_1^k = (k - \frac{1}{4}) \ln(4k-1) - k - \frac{3}{4} \ln 3 + 1. \end{aligned}$$

Таким образом,

$$RE^p(w''_k) > (k - \frac{1}{4})[\ln(4k-1) - \ln 3] - (k-1) \gtrsim \frac{1}{4} |w''_k| \ln |w''_k|,$$

поэтому, учитывая теорему 2, мы имеем

$$\frac{1}{4} n \ln n \lesssim RE_{bin}^p(n) \leq RE_{bin}^m(n) \leq n \ln n.$$

Таким образом, $RE_{bin}^p(n) = \Theta(n \log n)$ и $RE_{bin}^m(n) = \Theta(n \log n)$. Кроме того, нетрудно показать, что w''_k содержит не меньше, чем $\lfloor \frac{\alpha-1}{4} \rfloor (4k - \lceil \alpha \rceil)$ максимальных примитивных α -разрывных повторов, поэтому для достаточно большого α число максимальных примитивных α -разрывных повторов в w''_k равняется $\Omega(\alpha |w''_k|)$. Также легко показать, что w''_k содержит в общей сложности $\Theta(|w''_k|^2)$ максимальных примитивных разрывных повторов. С другой стороны, отметим, что w''_k содержит $2k+1$ максимальных периодичностей и только $2k-2$ максимальных субпериодичностей. Все эти субпериодичности имеют вид $abba$, где $a, b \in \{0, 1\}$, $a \neq b$, т. е. все эти субпериодичности имеют сокращенный порядок $1/3$, поэтому $RE^s(w''_k) = (2k-2)/3 \sim |w''_k|/6$.

Пусть w — слово длины n . Заметим, что $RE^m(w) - RE^p(w)$ является суммой сокращенных порядков всех максимальных непримитивных разрывных повторов в слове w , которая, очевидно, меньше числа всех максимальных непримитивных разрывных повторов в слове w . Следовательно, поскольку w содержит не более $O(n)$ максимальных непримитивных разрывных повторов, мы получаем, что $RE^m(w) - RE^p(w) = O(n)$, поэтому $RE^m(n) - RE^p(n) = O(n)$. Таким образом, из $RE^p(n) = \Theta(n \log n)$, $RE^m(n) = \Theta(n \log n)$ мы заключаем, что $RE^m(n) \sim RE^p(n)$. Таким же образом мы имеем $RE_{bin}^m(n) \sim RE_{bin}^p(n)$.

Задача оценки максимального возможного числа максимальных α -разрывных повторов в словах была сформулирована в [19] и активно изучалась в последние годы. В [9, 11] было независимо установлено, что число максимальных α -разрывных повторов в слове длины n не превосходит $O(\alpha n)$ (в [11, 12] доказано, что на самом деле это число не превосходит $18\alpha n$). Используя в качестве примера слово w''_k , можно видеть, что полученная верхняя оценка для числа максимальных α -разрывных повторов является точной по порядку для достаточно больших α в случае слов над произвольным алфавитом. Позднее в [15] полученная верхняя оценка для числа максимальных α -разрывных повторов была усилена до $3(\pi^2/6 + 5/2)\alpha n$.

Используя утверждение 1 и исходя из данной оценки, можно получить, что число максимальных δ -субпериодичностей в слове длины n не превосходит $3(\pi^2/6 + 5/2)n/\delta$. Используя пример слова w'_k , можно увидеть, что полученная оценка для числа максимальных δ -субпериодичностей является точной по порядку для достаточно малых δ в случае слов над произвольным алфавитом.

В [20] полученная верхняя оценка для числа максимальных разрывных повторов была обобщена на случай максимальных разрывных повторов с разрывами произвольного размера. Чтобы сформулировать данную оценку, введем следующие понятия и обозначения.

Для любого вещественного x положим

$$|x|^+ = \begin{cases} x, & \text{если } x > 0; \\ 0 & \text{в противном случае;} \end{cases} \quad |x|^- = \begin{cases} -x, & \text{если } x < 0; \\ 0 & \text{в противном случае.} \end{cases}$$

Пусть $f(x)$ — некоторая функция из \mathbb{N} в \mathbb{R} . Для каждого $x \in \mathbb{N}$ положим $\partial_f^+(x) = |f(x+1) - f(x)|^+$ и $\partial_f^-(x) = |f(x+1) - f(x)|^-$. Обозначим также $\sup_x \{\partial_f^+(x)\}$ ($\sup_x \{\partial_f^-(x)\}$) через ∂_f^+ (∂_f^-), если этот супремум существует. Пусть $f(x), g(x)$ — две функции из \mathbb{N} в \mathbb{R} такие, что $f(x) \geq g(x) > 0$ для любого $x \in \mathbb{N}$. Если обе величины ∂_f^+ и ∂_g^+ существуют, обозначим $\max\{\partial_f^+, \partial_g^+\}$ через $\partial_{f,g}^a$. Если обе величины ∂_f^- и ∂_g^- существуют, обозначим $\max\{\partial_f^-, \partial_g^-\}$ через $\partial_{f,g}^b$. Если хотя бы одна из величин $\partial_{f,g}^a$ или $\partial_{f,g}^b$ существует, то мы определяем $\partial_{f,g}$ как $\min\{\partial_{f,g}^a, \partial_{f,g}^b\}$, если обе величины $\partial_{f,g}^a, \partial_{f,g}^b$ существуют; в противном случае мы определяем значение $\partial_{f,g}$ равным существующей величине из величин $\partial_{f,g}^a, \partial_{f,g}^b$. Положим также $\Delta_{f,g}(x) = \frac{1}{x}(f(x) - g(x)) \geq 0$ для каждого $x \in \mathbb{N}$, и $\Delta_{f,g} = \sup_x \{\Delta_{f,g}(x)\}$, если этот супремум существует.

Пусть f, g — некоторые функции из \mathbb{N} в \mathbb{R} такие, что $f(x) \geq g(x) > 0$ для всех $x \in \mathbb{N}$. Мы называем разрывный повтор uvw f, g -разрывным повтором, если $g(|u|) \leq |v| \leq f(|u|)$. Например, α -разрывные повторы можно рассматривать как частный случай f, g -разрывных повторов для $f(x) = (\alpha - 1)x$ и $g(x) = \min\{1, \alpha - 1\}$. В [20] получена следующая верхняя оценка для числа максимальных f, g -разрывных повторов.

Теорема 5 [20]. Пусть $f(x), g(x)$ — некоторые функции такие, что обе величины $\partial_{f,g}, \Delta_{f,g}$ существуют. Тогда слово длины n содержит не более $O(n(1 + \max\{\partial_{f,g}, \Delta_{f,g}\}))$ максимальных f, g -разрывных повторов.

Например, пусть $f(x) = \alpha_f + \beta_f x$ и $g(x) = \alpha_g + \beta_g x$, где $0 < \alpha_g \leq \alpha_f$ и $0 \leq \beta_g \leq \beta_f$. Тогда для каждого $x \in \mathbb{N}$ мы имеем $\partial_f^+(x) = \beta_f$, $\partial_f^-(x) = 0$, $\partial_g^+(x) = \beta_g$, $\partial_g^-(x) = 0$, поэтому $\partial_f^+ = \beta_f$, $\partial_f^- = 0$, $\partial_g^+ = \beta_g$, $\partial_g^- = 0$. Таким образом, $\partial_{f,g}^a = \beta_f$, $\partial_{f,g}^b = \beta_g$, и $\partial_{f,g} = \min\{\beta_f, \beta_g\} = \beta_g$. Мы также имеем $\Delta_{f,g}(x) = \frac{1}{x}(\alpha_f - \alpha_g) + (\beta_f - \beta_g)$, поэтому $\Delta_{f,g} = \Delta_{f,g}(1) = (\alpha_f - \alpha_g) + (\beta_f - \beta_g)$. Следовательно, из теоремы 5 в этом случае мы имеем, что число максимальных f, g -разрывных повторов в слове длины n ограничено сверху значением

$$\begin{aligned} O(n(1 + \max\{\beta_g, (\alpha_f - \alpha_g) + (\beta_f - \beta_g)\})) &= \\ &= O(n(1 + \max\{\beta_g, (\alpha_f - \alpha_g), (\beta_f - \beta_g)\})). \end{aligned}$$

В заключение мы формулируем некоторые открытые проблемы в данной области.

1. Мы предполагаем, что $R_{\geq \lambda}(n) - R_{\geq \lambda+1}(n) = \Omega(n)$ для любого λ . Можно ли доказать эту гипотезу?

2. Выше на примере слов w_k показано, что $R_{\geq \lambda}(n) \gtrsim n/4$ для любого λ . Вместо слов w_k мы также можем рассмотреть слова $\hat{w}_k = ((01)^k 0)^k$ такие, что $R_{\geq \lambda}(\hat{w}_k) > (k - \lfloor \lambda/2 \rfloor)(k - 1)$ для $k > \lambda$, поэтому $R_{\geq \lambda}(\hat{w}_k) \gtrsim k^2 \gtrsim |\hat{w}_k|/2$ при $k \rightarrow \infty$. Таким образом, мы на самом деле имеем

$$R_{\geq 1}(n) \geq R_{\geq 2}(n) \geq R_{\geq 3}(n) \geq \dots \gtrsim n/2.$$

Является ли нижняя оценка $n/2$ строгой?

3. Обозначим через $Rp(n)$ максимальное возможное число первичных периодичностей и через $Ep(n)$ максимальную возможную сумму порядков первичных периодичностей в словах длины n . Верно ли, что $Rp(n) = R(n)$? Если $Rp(n) = R(n)$, то верно ли, что $Ep(n) = E(n)$?

4. Верно ли, что $RE_{bin}^s(n) = \Theta(n \log n)$?

5. Является ли верхняя оценка $O(n/\delta)$ для числа максимальных δ -субпериодичностей точной по порядку в случае слов над бинарным алфавитом?

6. Верно ли, что слово длины n содержит не более αn максимальных α -разрывных повторов?

7. Пусть $f(x) = \alpha x$, $g(x) = \beta x$, где $\beta < \alpha$. Верно ли, что в этом случае слово длины n содержит $O(n(1 + \alpha - \beta))$ максимальных f, g -разрывных повторов?

8. Пусть на символах словарного алфавита определен некоторый линейный порядок. Этот порядок определяет лексикографический порядок на словах над рассматриваемым алфавитом. Тогда под *корнем Линдона* максимальной периодичности r в заданном слове понимается циклический корень периодичности r , который является словом Линдона для рассматриваемого лексикографического порядка, т. е. циклический корень, который является наименьшим в рассматриваемом лексикографическом порядке циклическим корнем среди всех циклических корней периодичности r . Самый левый корень Линдона периодичности r называется *левым корнем Линдона* периодичности r . В [8] доказано, что для любого фактора длины l в слове число содержащихся в этом факторе левых корней Линдона максимальных периодичностей в данном слове не превосходит $3l/2$. Верно ли, что данное число не превосходит l ?

СПИСОК ЛИТЕРАТУРЫ

1. Bannai H., I T., Inenaga S., Nakashima Y., Takeda M., Tsuruta K. The “Runs” Theorem // SIAM J. Comput. — 2017. — V. 46, No 5. — P. 1501–1514.
2. Crochemore M., Ilie L. Analysis of maximal repetitions in strings // Lecture Notes in Comput. Sci. — 2007. — V. 4708. — P. 465–476.
3. Crochemore M., Ilie L. Maximal repetitions in strings // J. Comput. Syst. Sci. — 2008. — V. 74, No 5. — P. 796–807.
4. Crochemore M., Ilie L., Tinta L. Towards a solution to the “Runs” conjecture // Lecture Notes in Comput. Sci. — 2008. — V. 5029. — P. 290–302.
5. Crochemore M., Iliopoulos C., Kubica M., Radoszewski J., Rytter W., Walen T. The maximal number of cubic runs in a word // J. Comput. Syst. Sci. — 2012. — V. 78, No 6. — P. 1828–1836.

6. Crochemore M., Iliopoulos C., Kubica M., Radoszewski J., Rytter W., Walen T. Extracting powers and periods in a word from its runs structure // *Theoret. Comput. Sci.* — 2014. — V. 521. — P. 29–41.
7. Crochemore M., Kubica M., Radoszewski J., Rytter W., Walen T. On the maximal sum of exponents of runs in a string // *J. Discrete Algorithms* — 2012. — V. 14. — P. 29–36.
8. Crochemore M., Mercas R. On the density of Lyndon roots in factors // *Theoret. Comput. Sci.* — 2016. — V. 656. — P. 234–240.
9. Crochemore M., Kolpakov R., Kucherov G. Optimal Bounds for Computing α -gapped Repeats // *Lecture Notes in Comput. Sci.* — 2016. — V. 9618. — P. 245–255.
10. Fischer J., Holub S., I T., Lewenstein M. Beyond the Runs Theorem // *Lecture Notes in Comput. Sci.* — 2015. — V. 9309. — P. 277–286.
11. Gawrychowski P., I T., Inenaga S., Köppl D., Manea F. Efficiently Finding All Maximal α -gapped Repeats // *Proceedings of 33rd Symposium on Theoretical Aspects of Computer Science (STACS 2016)*. — 2016. — 39:1–39:14.
12. Gawrychowski P., I T., Inenaga S., Köppl D., Manea F. Tighter Bounds and Optimal Algorithms for All Maximal α -gapped Repeats and Palindromes // *Theory Comput. Syst.* — 2018. — V. 62, No 1. — P. 162–191.
13. Gasieniec L., Kolpakov R., Potapov I. Space efficient search for maximal repetitions // *Theoret. Comput. Sci.* — 2005. — V. 339. — P. 35–48.
14. Giraud M. Not so many runs in strings // *Lecture Notes in Comput. Sci.* — 2008. — V. 5196. — P. 232–239.
15. I T., Köppl D. Improved upper bounds on all maximal α -gapped repeats and palindromes // *Theoret. Comput. Sci.* — 2019. — V. 753. — P. 1–15.
16. Kolpakov R., Kucherov G. On Maximal Repetitions in Words // *J. Discrete Algorithms* — 2000. — V. 1, No 1. — P. 159–186.
17. Kolpakov R., Kucherov G., Ochern P. On maximal repetitions of arbitrary exponent // *Inform. Process. Lett.* — 2010. — V. 110, No 7. — P. 252–256.
18. Kolpakov R. On primary and secondary repetitions in words // *Theoret. Comput. Sci.* — 2012. — V. 418. — P. 71–81.
19. Kolpakov R., Podolskiy M., Posypkin M., Khrapov N. Searching of gapped repeats and subrepetitions in a word // *J. Discrete Algorithms* — 2017. — V. 46–47. — P. 1–15.
20. Kolpakov R. On the number of gapped repeats with arbitrary gap // *Theoret. Comput. Sci.* — 2018. — V. 723. — P. 11–22.
21. Puglisi S., Simpson J., Smyth W. How many runs can a string contain? // *Theoret. Comput. Sci.* — 2008. — V. 401. — P. 165–171.
22. Puglisi S., Simpson J. The expected number of runs in a word // *Australasian J. Combinatorics* — 2008. — V. 42. — P. 45–54.
23. Rytter W. The number of runs in a string: improved analysis of the linear upper bound // *Lecture Notes in Comput. Sci.* — 2006. — V. 3884. — P. 184–195.
24. Rytter W. The Number of Runs in a String // *Inform. and Comput.* — 2007. — V. 205, No 9. — P. 1459–1469.
25. Simpson J. Modified Padovan words and the maximum number of runs in a word // *Australasian J. of Combinatorics* — 2010. — V. 46. — P. 129–145.

Поступило в редакцию 6 II 2022