

А. Л. СЕМЕНОВ

РЕГУЛЯРНОСТЬ ЯЗЫКОВ, k -ЛИНЕЙНЫХ ПРИ РАЗЛИЧНЫХ k

(Представлено академиком П. С. Новиковым 6 VII 1973)

Амаром и Пуцолу в работе ⁽¹⁾ была поставлена следующая проблема: будет ли язык, k -линейный при всяком k , регулярным. В настоящей заметке доказывается, что язык, k -линейный для двух различных k , будет регулярным. Определения и свойства КС-грамматик и конечных автоматов считаются известными ⁽²⁾.

Введем некоторые обозначения. Фиксируем алфавит $\Sigma = \{a_1, \dots, a_n\}$. Длину цепочки u будем обозначать $|u|$, множество всех цепочек длины p — Σ^p , пустую цепочку — λ , $\Sigma^* = \{\lambda\} \cup \Sigma \cup \Sigma^2 \cup \dots$, k — всегда рациональное число, равное p/q , k_i для $i=1, 2$ — рациональное число, равное p_i/q_i , $p, q > 0$.

Следующие определения имеются в работе ⁽¹⁾.

Определение 1. КС-грамматика $\langle \Sigma, V, I, P \rangle$ называется k -линейной, если ее правила имеют вид:

$$A \rightarrow uBv,$$

$$A \rightarrow w,$$

где $q|u| = p|v|$; $A, B \in V$; $u, v, w \in \Sigma^*$.

Определение 2. Язык, порождаемый k -линейной грамматикой, называется k -линейным языком, или просто k -языком.

Определение 3. k -автоматом называется упорядоченная пятка $\mathcal{A} = \langle \Sigma, S, F, f, \delta \rangle$, где Σ — алфавит, $S = \{s_1, \dots, s_m\}$ — множество состояний, F — множество заключительных состояний, $f: (\Sigma \cup \{\lambda\})^{p+q-1} \rightarrow S$ — функция выбора начального состояния, $\delta: \Sigma^p \times S \times \Sigma^q \rightarrow S$ — функция перехода. Функция δ распространяется на $\bigcup_{i=0}^{\infty} \Sigma^{p^i} \times S \times \Sigma^{q^i}$ следующим образом:

$$\delta(\lambda, s, \lambda) = s,$$

$$\delta(u'u, s, vv') = \delta(u', \delta(u, s, v), v').$$

Всякое натуральное число d можно единственным образом представить в виде

$$d = np + \theta + nq, \quad (1)$$

где n, θ натуральные, $\theta < p+q$. Следовательно, всякую цепочку x в алфавите Σ можно единственным образом представить в виде

$$x = u w v, \text{ где } q|u| = p|v|, \quad |w| < p+q. \quad (1')$$

Определение 4. Цепочка x , представленная в виде (1'), допускается автоматом $\mathcal{A} = \langle \Sigma, S, F, f, \delta \rangle$, если $\delta(u, f(w), v) \in F$.

Определение 5. Язык L представим в автомате \mathcal{A} , если он состоит из всех цепочек, допускаемых автоматом \mathcal{A} .

Таким образом, поведение автомата \mathcal{A} может быть неформально описано следующим образом: автомат сначала читает цепочку w и переходит в некоторое начальное состояние, затем он читает цепочки u и v кусками длины p и q соответственно с помощью двух головок, расходящихся от w в разные стороны. Цепочка допускается, если после ее прочтения автомат окажется в заключительном состоянии.

Из результатов работы (1) непосредственно следует, что язык k -линеен тогда и только тогда, когда он представим в k -автомате. В той же работе доказано, что класс k -языков при фиксированном k замкнут относительно объединения, пересечения и дополнения и что регулярные языки являются k -линейными для любого k .

Лемма 1. Пусть L — k -язык, x, y — фиксированные цепочки, \tilde{L} — множество цепочек t , для которых $xt y \in L$. Тогда \tilde{L} — k -язык.

Доказательство. Докажем лемму сначала для случая $x = \lambda$; $y = a \in \Sigma$. Представим язык L в виде конечного объединения языков L_w , отвечающих различным w , встречающимся в разложении (1') цепочек из L , $L = \bigcup_w L_w$. В силу замкнутости класса k -языков относительно объединения, лемму достаточно доказать для L_w . При фиксированном w автомат начинает работу над цепочками u и v , находясь всегда в одном и том же состоянии s_0 . Язык L_w представим в k -автомате $\mathcal{A} = \langle \Sigma, S, F, f, \delta \rangle$, среди состояний которого имеется «начальное» состояние s_0 и «тупиковое» состояние s_\varnothing такое, что для любых u, v $\delta(u, s_\varnothing, v) = s_\varnothing$, $s_\varnothing \in F$ и функция выбора начального состояния определена так:

$$f(w) = s_0, \quad f(z) = s_\varnothing \text{ для } z \in (\Sigma \cup \{\lambda\})^{p+q-1} - \{w\}.$$

Дальнейшее доказательство зависит от того, равно ли w пустой цепочке.

Первый случай: $w = \lambda$. Определим автомат $\mathfrak{B} = \langle \Sigma, S', F', f', \delta' \rangle$ следующим образом:

$$S' = \Sigma^p \times S \times \Sigma^{q-1} \cup \{s_\varnothing\};$$

$$f'(z) = (u_0, s_0, v_0'), \text{ если } z = u_0 v_0', \quad |u_0| = p, \quad |v_0'| = q-1;$$

$$f'(z) = s_\varnothing, \text{ если } |z| \neq p+q-1;$$

$$\delta'(u_2, (u_1, s, v_1'), a, v_2') = (u_2, \delta(u_1, s, v_1' a_1), v_2'), \quad |u_2| = p, \quad |v_2'| = q-1;$$

$$(u, s, v') \in F', \text{ если } \delta(u, s, v' a) \in F.$$

Второй случай: $w = \bar{w} a_{i_0}$. Определим $\mathfrak{B} = \langle \Sigma, S', F', f', \delta' \rangle$ следующим образом:

$$S' = \Sigma^p \times S \times \Sigma^{q-1} \cup \{s_0'\} \cup \{s_\varnothing\};$$

$$f'(\bar{w}) = s_0'; \quad f'(z) = s_\varnothing, \text{ если } z \neq \bar{w};$$

$$\delta'(u, s_0', a_i v') = s_\varnothing, \text{ если } a_i \neq a_{i_0};$$

$$\delta'(u, s_0', a_{i_0} v') = (u, s_0, v');$$

$$\delta'(u_1, (u, s, v'), a, v_1') = (u_1, \delta(u, s, v' a), v_1');$$

$$(u, s, v') \in F', \text{ если } \delta(u, s, v' a) \in F; \quad s_0' \in F, \text{ если } a_{i_0} = a.$$

Таким образом, автомат \mathfrak{B} с помощью внутренних состояний запоминает $q-1$ последнюю букву цепочки v , которая читается автоматом \mathcal{A} на некотором шаге, и цепочку u , которая читается автоматом \mathcal{A} на том же шаге, для того чтобы при появлении первой буквы следующей цепочки v смоделировать переход автомата \mathcal{A} . Из определения автомата \mathfrak{B} непосредственно вытекает представимость в нем \tilde{L} .

Доказательство для случая $x = a \in \Sigma$, $y = \lambda$ аналогично. Утверждение леммы легко получить теперь, используя индукцию по длине x и y .

Определение 6. k -язык L называется k^λ -языком, если длины всех его цепочек кратны $p+q$.

Следствие. Пусть L — k -язык. Тогда $L = \bigcup_{i=1}^N L_i e_i$, где L_i — k^λ -язык, $e_i \in \Sigma^*$.

Автомат $\mathcal{A} = \langle \Sigma, S, F, f, \delta \rangle$, в котором представим k^λ -язык, будем записывать в виде $\langle \Sigma, S, F, s_0, \delta \rangle$, где $s_0 = f(\lambda)$. Этому автомату можно поставить в соответствие обычный автомат $\mathcal{A} = \langle \Sigma^p \times \Sigma^q, S, F, s_0, \bar{\delta} \rangle$, где $\bar{\delta}(s, (u, v)) = \delta(u, s, v)$. Для автомата \mathcal{A} существует приведенный, т. е. автомат, допускающий тот же язык, и такой, что любое состояние этого автомата достижимо из начального и любые два состояния неэквивалентны. Приведен-

ному автомату соответствует k -автомат, в котором представим язык L . Последний автомат будем также называть приведенным.

Определение 7. Язык называется k_1, k_2 -линейным языком, или k_1, k_2 -языком, если он k_1 -линеен и k_2 -линеен; k_1^λ, k_2 -язык — это k_1^λ -язык, являющийся k_2 -языком.

Лемма 2. Предположим, что L является k_1^λ, k_2 -языком. Пусть L представим в некотором приведенном k_1 -автомате $\mathfrak{A} = \langle \Sigma, S, F, s_0, \delta \rangle$ и $s \in S$.

Тогда язык \bar{L} , представимый в k_1 -автомате $\langle \Sigma, S, \{s\}, s_0, \delta \rangle$, k_1^λ, k_2 -линеен.

Доказательство. Если у автомата \mathfrak{A} одно состояние, то лемма очевидна. Пусть число состояний равно $m > 1$. Так как автомат \mathfrak{A} приведенный, то для всякого состояния s' , отличного от s , существует пара цепочек u и v , для которых $|u| = lp$, $|v| = lq$, $l < m$, и одно из состояний $\delta(u, s, v)$ и $\delta(u, s', v)$ принадлежит, а другое не принадлежит F . Для найденных u и v пусть

$$L(s') = \{t \in \Sigma^* \mid utv \in L \Leftrightarrow \delta(u, s, v) \in F\}.$$

Язык $L(s')$ содержит все цепочки, приводящие из s_0 в s , не содержит ни одной цепочки, приводящей из s_0 в s' , и k_2 -линеен в силу леммы 1 и замкнутости k -линейных языков относительно дополнения. Очевидно, что $\bar{L} = \bigcap_{s' \neq s} L(s')$. Следовательно, \bar{L} — k_1, k_2 -линейный язык.

В дальнейшем предполагается, что $k_1 < k_2$ и l — натуральное число, делящееся на $M = (p_1 q_2 - p_2 q_1) p_2$. Определим числа

$$n = \frac{l q_1 (p_2 + q_2)}{p_1 q_2 - p_2 q_1}, \quad l' = \frac{l (p_1 + q_1)}{p_2}, \quad n' = \frac{n (p_1 + q_1)}{p_2 + q_2}.$$

Легко проверить, что $n > l$, $n' > l'$ и выполняются равенства $(n-l)p_1 = (n'-l')p_2$, $l(p_1 + q_1) = l'p_2$. Отсюда число $d = n(p_1 + q_1)$ можно представить в виде

$$d = (n-l)p_1 + lp_1 + lq_1 + (n-l)q_1, \quad (2)$$

$$d = (n'-l')p_2 + l'p_2 + l'q_2 + (n'-l')q_2. \quad (3)$$

Следовательно, имеют место следующие представления слова x длины d :

$$x = \tilde{u}uv\tilde{v}, \quad (2')$$

$$x = \tilde{u}yzt, \quad (3')$$

где сомножители имеют длины, равные слагаемым в представлениях (2) и (3), при этом $y = uv$, $\tilde{v} = zt$. Таким образом, в начале чтения слова x k_1 -автомат находится между u и v , а k_2 -автомат — между v и \tilde{v} .

Определим эквивалентность, которую будем называть отдаленной эквивалентностью, на состояниях приведенного k -автомата $\mathfrak{A} = \langle \Sigma, S, F, f, \delta \rangle$ с числом состояний m

$$s_1 \sim_{\text{def}} s_2 = \forall u, v \quad q|u| = p|v| \geq p q m(m-1) \Rightarrow \delta(u, s_1, v) = \delta(u, s_2, v).$$

Классы отдаленной эквивалентности обозначим S_i .

Лемма 3. Пусть s_1 и s_2 не отдаленно эквивалентны. Тогда существуют такие множества $A = (t_2)^* t_1$, $B = z_1 (z_2)^*$, где $t_i \in (\Sigma^p)^*$, $z_i \in (\Sigma^q)^*$, что для всех $u \in A$, $v \in B$, если $q|u| = p|v|$, то $\delta(u, s_1, v) \neq \delta(u, s_2, v)$.

Доказательство. Из определения отдаленной эквивалентности вытекает существование u и v вида $u = u_n u_{n-1} \dots u_1$, $v = v_1 v_2 \dots v_n$, где $|u_i| = p$, $|v_i| = q$, $n \geq m(m-1)$, для которых $\delta(u, s_1, v) \neq \delta(u, s_2, v)$. Рассмотрим последовательность пар состояний $(s_1^{(0)}, s_2^{(0)}) = (s_1, s_2)$; $(s_1^{(1)}, s_2^{(1)}) =$

$$(\delta(u_1, s_1^{(0)}, v_1), \delta(u_1, s_2^{(0)}, v_2)); \dots; (s_1^{(n)}, s_2^{(n)}) = (\delta(u_n, s_1^{(n-1)}, v_n), \delta(u_n, s_2^{(n-1)}, v_{n+1})).$$

$v_n)$). $s_1^{(i)} \neq s_2^{(i)}$ для всякого i . Так как $n \geq m(m-1)$, то в после довательности встретятся две одинаковые пары. Пусть, например, $s_1^{(i)} = s_1^{(j)}$, $s_2^{(i)} = s_2^{(j)}$, $j > i$. Тогда

$$A = (u_j \dots u_{i+1})^* u_i \dots u_1, \quad B = v_1 \dots v_i (v_{i+1} \dots v_j)^*,$$

очевидно, удовлетворяет условию.

Следствие. Пусть r — фиксированное натуральное число и для всех i и j из $u_{ij} \in U_{ij}$, $v_{ij} \in V_{ij}$, $|u_{ij}| = rp$, $|v_{ij}| = rq$ следует $\delta(u_{ij}, s_1, v_{ij}) = \delta(u_{ij}, s_2, v_{ij})$. Тогда $s_1 \sim s_2$.

Пусть L — k_1^A, k_2 -язык, представимый в k_1 -автомате $\mathcal{A} = \langle \Sigma, S, F, s_0, \delta \rangle$. По лемме 2, для всякого состояния s_h автомата \mathcal{A} существует k_2 -автомат $\mathcal{B}_h = \langle \Sigma, T_h, F_h, f_h, \delta_h \rangle$, в котором представим тот же язык, что и в k_1 -автомате $\langle \Sigma, S, s_h, s_0, \delta \rangle$.

Лемма 4. Пусть u, v, u', v' — цепочки в алфавите Σ такие, что $|u| = |u'| = lp$; $|v| = |v'| = lq$; $l = Mr$; $M = (p_1 q_2 - p_2 q_1) p_2$; r натуральное. Пусть далее для всех i, j, h из равенств

$$\bar{u}uv\bar{v} = x y z t, \quad \bar{u}u'v'\bar{v} = x y' z t,$$

левые части которых есть разложения (2'), а правые части есть разложения (3') и $\bar{u} \in U_{ij}$, $\bar{v} \in V_{ij}$, следует, что $\delta_h(y, f_h(\lambda), z) = \delta_h(y', f_h(\lambda), z)$.

Тогда $\delta(u, s_0, v) \sim \delta(u', s_0, v')$.

Доказательство. Так как $\delta_h(y, f_h(\lambda), z) = \delta_h(y', f_h(\lambda), z)$, то $\delta_h(xu, f_h(\lambda), zt) = \delta_h(xu', f_h(\lambda), zt)$ для всех h . Следовательно, $\delta(\bar{u}u, s_0, v\bar{v}) = \delta(\bar{u}u', s_0, v'\bar{v})$. Отсюда и из следствия леммы 3 сразу вытекает требуемое утверждение.

Лемма 5. Для всякого S_i множество R_i цепочек uv таких, что $|u| = lp_1$, $|v| = lq_1$, $\delta(u, s_0, v) \in S_i$, регулярно.

Доказательство. Тройке i, j, h поставим в соответствие разбиение $(\Sigma^{M(p_1+q_1)})^*$ на конечное число классов C_α . Цепочка x принадлежит классу C_α , если $\delta_h(x, f_h(\lambda), v_{ij}) = t_\alpha \in T_h$. Докажем, что C_α регулярно. Множество P всех цепочек uv таких, что $|u| = lp_2$, $|v| = lq_2$, $u \in \Sigma^*$, $v \in V_{ij}$, k_2 -линейно. Множество Q_α цепочек uv таких, что $\delta_h(u, f_h(\lambda), v) = t_\alpha$, k_2 -линейно. Следовательно, $L_\alpha = P \cap Q_\alpha$ — k_2 -линейно. Тогда C_α — это множество всех u в разложении (1') цепочек из L_α . Нетрудно построить конечный автомат, допускающий это множество.

Для каждой тройки i, j, h выберем какой-нибудь один класс и рассмотрим пересечение таких классов во всех i, j, h . Таких пересечений конечное число, все они регулярны, их объединение есть $(\Sigma^{M(p_1+q_1)})^*$ и каждое из них целиком лежит в некотором R_i . Регулярность R_i доказана.

Теорема. Пусть L — k_1, k_2 -язык. Тогда L регулярен.

Доказательство. В силу следствия из леммы 1, теореме достаточно доказать для k_1^A, k_2 -языка. Для всякого множества R_i цепочек длины, кратной $M(p_1+q_1)$, переводящих \mathcal{A} в одно из состояний S_i , определим множество D_i пар цепочек (u, v) таких, что $m(m-1)p_1 < |u| \leq (M+m(m-1))p_1$, $m(m-1)q_1 < |v| \leq (M+m(m-1))q_1$ и $\delta(u, s, v) \in F$ для некоторого состояния s из S_i , а значит, и для всех состояний из S_i . Множество E_i цепочек вида uxv , где $x \in R_i$, $(u, v) \in D_i$ регулярно. Множество G всех цепочек y таких, что $y \in L$, $|y| \leq m(m-1)(p_1+q_1)$, конечно. Очевидно, $L = (\cup E_i) \cup G$ регулярен. Теорема доказана.

Автор благодарит А. А. Мучника и А. Маслова за помощь в работе.

Московский государственный университет
им. М. В. Ломоносова

Поступило
5 VII 1973

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

¹ V. Amar, G. Putzolu, Information and Control, v. 8, № 1 (1965). ² А. В. Гладкий, Формальные грамматики и языки, М., 1973.