

А. Н. МАСЛОВ

ИЕРАРХИЯ ИНДЕКСНЫХ ЯЗЫКОВ ПРОИЗВОЛЬНОГО УРОВНЯ

(Представлено академиком А. Н. Колмогоровым 30 I 1974)

Строится последовательность классов языков, являющихся расширением класса контекстно-свободных (к.с.) языков ^(1, 2). Второй член последовательности — класс индексных языков ⁽³⁾. Класс конечноавтоматных языков является нулевым членом. Ряд фрагментов языков программирования, не являющихся контекстно-свободными, принадлежит второму и третьему классу из этой последовательности. Класс с номером $i+1$ может быть задан четырьмя способами: 1) порождающей грамматикой с индексами уровня не выше i ; 2) распознающим недетерминированным автоматом с памятью уровня $i+1$, состоящей из магазинного списка памяти уровня i ; 3) как наименьшее решение специальной системы уравнений с некоммутативными переменными; 4) макрограмматикой глубины i .

Некоторые свойства введенных классов легко получаются при рассмотрении одного способа задания и не столь очевидны с точки зрения других заданий.

1. Введем формальную операцию возведения в степень для букв A и B алфавита V . Множество всех изображений A^B обозначим через V^V . Доопределим операцию возведения в степень до операции над языками с помощью равенств:

$$(L_1 \cup L_2)^L = L_1^L \cup L_2^L, \quad (L_1 L_2)^L = L_1^L L_2^L, \quad A^{(L_1 \cup L_2)} = A^{L_1} \cup A^{L_2}, \quad A^{BL} = (A^B)^L,$$

где A и B — символы из алфавита V , а L , L_1 и L_2 — языки в алфавите V . Указанные равенства позволяют по интерпретации для обозначений A^B (т. е. по отображению $V^V \rightarrow V$) определить язык $L_1^{L_2}$ для языков L_1 и L_2 в том же алфавите V . Тем самым, в частности, определена операция возведения в степень для слов.

В изображении A^B букву B будем называть индексом буквы A . Теперь можно определить класс индексных грамматик, используя несколько более удобные обозначения, чем в ⁽³⁾.

Определение. Индексной грамматикой называется пятерка $G = (\Sigma, V, P, I, S_0)$, где $\Sigma = \{\sigma_1, \dots, \sigma_d\}$ — терминальный алфавит, $V = \{S_0, S_1, \dots, S_m\}$ — нетерминальный алфавит, S_0 — начальный символ, P — конечное множество продукций вида $S_i \rightarrow \omega$, $\omega \in (V^V \cup V \cup \Sigma)^*$ и $I: V^V \rightarrow V$ — интерпретация операции возведения в степень.

Слово y выводимо из слова x применением продукции $p \in P$ (обозначается $x \stackrel{p}{\vdash} y$), если $x = a S_i^z b$, $y = a \omega^z b$, $p: S_i \rightarrow \omega$, слова a , b и z в произвольном алфавите. Слово y выводимо из слова x , обозначается $x \vdash y$, если существует последовательность слов $x = y_0, y_1, \dots, y_n = y$ такая, что либо $y_i \stackrel{p}{\vdash} y_{i+1}$ для $p \in P$, либо y_{i+1} получается из y_i заменой некоторого вхождения A^B на $I(A^B)$. Каждая грамматика G определяет язык $L(G) = \{x \in \Sigma^* \mid S_0 \vdash x\}$ выводимых в ней слов.

Определение выводимости в индексной грамматике допускает естественное расширение. Пусть $V(1) = V^*$, $V(2) = (V^V)^*$, $V(k) = \{A^x \mid A \in V, x \in V(k-1)\}^*$ и $V(\infty) = \bigcup_k V(k)$. Например, $A^{BCDC} B^R \in V(3)$ и $A_1^{A_2 \dots A_R} \in V(k)$.

Слово y выводимо из слова x применением правила $p \in P$ на уровне $k > 1$ (обозначается $x \vdash^p y$), если существуют слова a_i, b_i, z_i и t_i такие, что $x = a_0 S_{i_0} z_0 b_0, y = a_0 S_{i_0}^p z_0 b_0, z_j = a_{j+1} S_{i_{j+1}}^{z_{j+1}} b_{j+1}, t_j = a_{j+1} S_{i_{j+1}}^{t_{j+1}} b_{j+1}$ при $1 < j < k-1, z_{k-1} = a_k S_{i_k}^{z_k} b_k, t_{k-1} = a_k \omega^{z_k} b_k, p : S_{i_k} \rightarrow \omega$.

Будем отождествлять выводимость \vdash^p и выводимость \vdash^{p^1} . Неформально, выводимость на уровне k обозначает применение продукции к нетерминалу, являющемуся индексом k -го уровня. Слово y выводится из слова x на уровне k (обозначается \vdash^k), если существует последовательность слов $x = y_0, y_1, \dots, y_n = y, y_i \in V(k)$, такая, что либо $y_i \vdash^{p, k'} y_{i+1}$ для $p \in P$ и $k' \leq k$, либо y_{i+1} получается из y_i заменой обозначения A^B на $I(A^B)$ на максимальном уровне, т. е. B не имеет индекса. Ясно, что \vdash^k и \vdash совпадают.

Язык $L_k(G) = \{x \in \Sigma^* \mid S_0 \vdash^k x\}$, образованный из слов, выводимых на уровне k , назовем индексным языком уровня $k+1$, а язык $L_\infty(G) = \{x \in \Sigma^* \mid \exists k (S_0 \vdash^k x)\}$ — индексным языком уровня ∞ .

З а м е ч а н и я. Допустив в качестве интерпретации отображения $I: V^V \rightarrow (V(1) \cup \Sigma)^*$ мы не изменим классы языков $L_k(G)$. Также не изменяет эти классы доопределение тупиковых изображений, включающих терминалы, с помощью равенств $\sigma^z = \sigma$.

Отметим следующие результаты. Класс языков L_∞ совпадает с классом рекурсивно-перечислимых языков. Для индексных грамматик уровня $k, k < \infty$, разрешима проблема пустоты порождаемого языка.

2. Класс контекстно-свободных языков совпадает с классом языков, допускаемых недетерминированным магазинным автоматом $(^1, ^2)$. Аналогичную роль для индексных языков уровня $k+2$ играют магазинные автоматы уровня $k+2$.

Магазинный автомат (с одним состоянием) можно понимать как левый вывод в к.с. грамматике, продукции которой приведены к виду $A \rightarrow BC$ или $A \rightarrow \sigma$. В этом случае нетерминальная часть промежуточного слова при левом выводе можно рассматривать как содержимое магазина (точнее, магазинного списка). Продукции индексной грамматики можно привести к виду $A \rightarrow B^c, A \rightarrow BC$ или $A \rightarrow \sigma$. Промежуточное слово при левом выводе имеет вид $\sigma_{j_1} \dots \sigma_{j_n} A_{i_1} z_1 \dots A_{i_m} z_m, z_i \in V(\infty)$. Нетерминальная часть должна естественным образом располагаться в памяти допускающего автомата.

Память уровня 1 — это магазин. Автомат может совершать с магазином следующие действия: 1) прочитать очередной символ на входной ленте и символ в вершине магазина, а затем стереть последний; 2) прочитать и заменить на два символа верхний символ в магазине.

Память уровня k — это магазинный список пар: активный символ — память уровня $k-1$. В частности, память уровня 2 — это магазинный список пар: активный символ — магазинный список символов. Автомат работает с вершинной парой, а при ее опустошении переходит к следующей паре. Автомат может совершать (недетерминированно) следующие действия, возможность выполнения которых зависит от читаемых символов (символ на входной ленте не читается, если не указано обратное): 1) если память уровня $k-1$ в вершинной паре пуста, то прочитать очередной символ на входной ленте и активный символ, а затем стереть вершинную пару; 2) прочитать активный символ и заменить вершинную пару на две, отличающихся от первоначальной лишь активным символом; 3) прочитать активный символ и изменить его, добавив при этом вершинный символ в память уровня $k-1$ (т. е. в вершину магазина уровня $k-1$ добавить пару «некоторый символ — пустая память уровня $k-2$ »); 4) прочитать активный символ (вершинной пары) и активный символ ее памяти уровня $k-1$, если

при этом память уровня $k-2$ (в вершине памяти уровня $k-1$) пуста, то стереть вершинную пару в памяти уровня $k-1$ и изменить прочитанный активный символ; 5) совершить одно из действий 2-5 с памятью уровня $k-1$, находящейся в вершинной паре.

В начальный момент в магазине хранится единственная пара «начальный символ — пустая память уровня $k-1$ ». Если, прочитав слово, автомат опустошил память, слово считается допустимым. Ясно, что левый вывод в грамматике уровня k и допустимость соответствующим автоматом (с одним состоянием), использующим память уровня $k+1$, тождественны. Мы не будем рассматривать подкласс детерминированных автоматов и заниматься обсуждением удобств описанной памяти при программной реализации.

Мы не расширим класс допустимых языков, если предположим наличие нескольких (но конечного числа) состояний у автомата.

Из этого следует, что семейство языков, допускаемое автоматами с памятью уровня k , является ⁽⁸⁾ полным абстрактным семейством языков (а.с.я.), которое порождено одним языком с помощью операций, участвующих в определении полного а.с.я. Отметим, что гнездный стек ⁽⁴⁾ получается из автомата с памятью уровня 2 отождествлением совпадающих начал у составляющих магазинов.

3. Язык L_∞ может быть определен как наименьшее решение системы уравнений $S = \{A = \sum_i \omega_i \mid (A \rightarrow \omega_i) \in P \text{ или } \omega_i = C^B, I(A^B) = C\}$, где $\bar{B} \cap \Sigma^* = \epsilon$ (ϵ — пустое слово), с некоммутативными переменными ⁽⁷⁾. Символ \bar{B} является левым обратным для B . Чтобы выделить системы уравнений, задающие подкласс L_k , достаточно заменить алфавит V на алфавит $\bigcup_{i=0}^k V_i$, где $V_i = \{A_i \mid A \in V\}$, а уравнения S — на уравнения $S' = \{A_i = \sum_{i=0}^k \omega_{i,i'} \mid 0 \leq i < k, (A = \sum \omega_i) \in S; \omega_{i,i'} \text{ получено из } \omega_i \text{ заменой всех нетерминалов } B \text{ на } j\text{-ом уровне на } B_{i+j} \text{ (см. также } (6))\}$.

4. Другим способом задания индексных знаков уровня k являются макрограмматики. Поставим в соответствие каждому терминальному символу σ функциональный (от одной переменной) терминальный символ $\sigma(\)$, а каждой цепочке $\sigma_i \sigma_{i_2} \dots \sigma_{i_m}$ — формулу $\sigma_{i_1}(\sigma_{i_2}(\dots(\sigma_{i_m}(\epsilon))\dots))$. Множества формул, соответствующих цепочкам описанных выше языков, порождаются макрограмматиками. Вариант макрограмматик, порождающих класс с номером 2 (индексные языки), изучен в ⁽⁵⁾.

Будем использовать X в качестве сокращения для X_1, \dots, X_n . Пусть имеется набор нетерминальных функциональных символов F_i , которым могут быть приданы параметры $F_i[\mathbf{p}]$, переменные $F_i(\mathbf{x})$ или и параметры и переменные одновременно $F_i[\mathbf{p}](\mathbf{x})$; размерность векторов \mathbf{p} и \mathbf{x} однозначно определяется символом F_i . Символы p_i и x_i являются элементарными формулами. Остальные формулы получаются из элементарных, формулы ϵ (пустое слово) и терминальных и нетерминальных функциональных символов — подстановкой формул вместо параметров и переменных. Макрограмматика задается начальным символом F_0 и набором правил вида $F[\mathbf{p}](\mathbf{x}) \rightarrow \Phi\{\mathbf{p}\}(\Psi_1\{\mathbf{p}\}(\mathbf{x}), \dots, \Psi_m\{\mathbf{p}\}(\mathbf{x}))$ (Φ и Ψ_i — формулы, а фигурные скобки обозначают, что элементарными подформулами в Φ и Ψ_i являются только p_j , причем p_j находятся на глубине ≤ 1 относительно вложенности квадратных скобок), а также правил аналогичного вида, в которых параметры и (или) переменные отсутствуют, в частности, правил вида $F(\mathbf{x}) \rightarrow x_i$.

Если некоторая формула имеет подформулу $F[\chi](\theta)$, то, при наличии правила $F[\mathbf{p}](\mathbf{x}) \rightarrow \Phi\{\mathbf{p}\}(\Psi\{\mathbf{p}\}(\mathbf{x}))$, эта подформула может быть заменена на $\Phi\{\chi\}(\Psi\{\chi\}(\theta))$, причем: 1) фигурные скобки обозначают, что в Φ и Ψ_i вместо p_j всюду подставлены формулы χ_j ; 2) замену можно осуществлять только в том случае, когда в результате замены получается формула, т. е. размерности векторов переменных и параметров соответствуют функцио-

нальным символам, которым они приданы; 3) правило, для которого $\Phi\{p\} = p_i$, можно применять только в том случае, когда $\chi_i = H$ или $\chi_i = H(\Gamma)$, в последнем случае осуществляется приведение $H(\Gamma)$ к $H[\Gamma]$.

Множество цепочек, соответствующих терминальным формулам, выводимым из F_0 с помощью описанных замен и аналогичных замен при отсутствии параметров и (или) переменных, называется порождаемым языком.

Макрограмматики общего вида порождают класс языков L_∞ . Макрограмматики, не использующие параметры, порождают класс контекстно-свободных языков. Фиксируем число k . Если в каждом выводе макрограмматики глубина вложенности квадратных скобок или, эквивалентно, глубина приведений, не превышает k , то макрограмматика имеет глубину k . Можно показать, что макрограмматика глубины k порождает класс языков с номером k .

Подробное изложение результатов будет опубликовано в журнале «Проблемы передачи информации».

Автор признателен А. А. Мучнику за поддержку в работе и Э. Д. Стоцкому, В. М. Ломковской и А. Н. Колодию за полезное обсуждение.

Поступило
9 I 1974

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

- ¹ С. Гинзбург, Математическая теория контекстно-свободных языков, М., 1970.
² А. В. Гладкий, Формальные грамматики и языки, «Наука», 1973. ³ А. V. Aho, J. Assoc. Comp. Machinery, v. 15, № 4, 647 (1968). ⁴ А. V. Aho, J. Assoc. Comp. Machinery, v. 16, № 3, 383 (1969). ⁵ M. J. Fischer, Report No. NSF-22, The Computational Laboratory of Harvard University, 1968. ⁶ O. Mayer, Lect. Notes Comp. Sci., v. 2, 166 (1973). ⁷ A. Blikle, Information and Control, v. 24, № 2, 134 (1972). ⁸ S. Ginsburg, S. A. Greibach, Mem. Am. Math. Soc., № 87, 1 (1969).