

КЛАССЫ TR-ГРАММАТИК

В.И.Константинов

Выделяются интересные для практических приложений классы TR-грамматик, допускающих беступиковые схемы синтаксического анализа. Рассматриваются вопросы машинной реализации TR-грамматик на основе TR-таблиц. Приводятся алгоритмы работы синтаксических анализаторов для выделенных классов TR-грамматик.

1. Рассмотрим TR-грамматику без леворекурсивных элементов. По определению [1], с каждой TR-грамматикой связано множество R имен некоторых конечных подмножеств правил вида $(\epsilon, z, p), \epsilon \in AU \cup V_N, z \in R, p \in P$. Сопоставим каждому подмножеству правил z_k множество терминальных символов, которое назовем опорным для подмножества z_k и обозначим $O(z_k)$. Множество $O(z_k)$ строится следующим образом:

- а) если $z_k = \{a_1 \rightarrow z_{i1}, \dots, a_n \rightarrow z_{in}\}, a_i \in A, 1 \leq i \leq n$, то $O(z_k) = \{a_1, \dots, a_n\}$, причем некоторые из a_i могут совпадать;
- б) если $z_k = \{a_1 \rightarrow z_{i1}, \dots, a_n \rightarrow z_{in}, S_1 \rightarrow z_{j1}, \dots, S_m \rightarrow z_{jm}\}, a_i \in A, 1 \leq i \leq n, S_j \in V_N, 1 \leq j \leq m$, то $O(z_k) = \{a_1, \dots, a_n\} \cup O(S_1) \cup \dots \cup O(S_m)$, $O(S_j) = \{a \in A / S_j \Rightarrow a\psi, \psi \in (AU \cup V_N)^*\}$.

Таким образом, $O(z_k)$ - это множество первых терминальных элементов цепочек, выводимых из правил z_k .

ЛЕММА I. В грамматиках без леворекурсивных элементов множество $O(z_k)$ для каждого z_k может быть построено за конечное число шагов.

Действительно, каждая грамматика содержит конечное число нетерминальных символов $S_1, \dots, S_n$. Любое из $O(z_k)$ будет построено за конечное число шагов, если за конечное число шагов будут построены $O(S_j)$, S_j - нетерминальные левые части правил из z_k . Покажем, как за конечное число шагов строится $O(S_j)$ для каждого $S_j \in V_N$. Определяя $O(S_j)$ как множество терминальных первых элементов цепочек, выводимых из S_j , под выводом из S_j будем понимать вывод из аксиомы $z_0^{G(S_j)}$, соответствующей S_j .

Если $z_0^{G(S_j)}$ состоит из правил с терминальными левыми частями, заносим их в $O(S_j)$ и на этом процесс построения $O(S_j)$ заканчиваем. Пусть среди правил, принадлежащих $z_0^{G(S_j)}$, есть правила с нетерминальной левой частью и пусть левые части этих правил - $S_1, \dots, S_k$. Очевидно, что ни одно из $S_1, \dots, S_k$ не может совпадать с S_j , иначе элемент S_j был бы леворекурсивным. Рассмотрим аксиомы $z_0^{G(S_1)}, \dots, z_0^{G(S_k)}$. Терминальные левые части входящих в них правил заносим в $O(S_j)$, для нетерминальных этот процесс продолжаем. Поскольку на каждом шаге число нетерминальных элементов, которые могут быть первыми элементами порождаемых S_j цепочек, уменьшается хотя бы на единицу и нетерминальных элементов - конечное число, приходим в конце концов к цепочкам, начинающимся только с терминальных символов, т.е. за конечное число шагов $O(S_j)$ действительно построено.

Лемма доказана.

Пусть дана TR-грамматика G , образованная атомными грамматиками $G(S_i), G = \bigcup_{i=0}^n G(S_i)$. Назовем грамматикой $G(S_i)$ грамматикой первого типа, если все её заключительные правила - первого типа [1], иначе $G(S_i)$ назовем грамматикой второго типа.

Свяжем с каждой атомной грамматикой $G(S_i)$ второго типа некоторое множество терминальных элементов, обозначаемое $P(S_i)$ и строящееся следующим образом.

Если $a \rightarrow z$ - заключительное правило грамматики $G(S_i)$, то

- 1) при $a \in A$ в $P(S_i)$ попадают элементы из $O(z) = O(\epsilon_1) \cup \dots \cup O(\epsilon_k), \epsilon_1, \dots, \epsilon_k \in AU \cup V_N$ - левые части правил из $z, O(\epsilon) = \epsilon, \epsilon \in A$;
- 2) при $a \in V_N$

$$P(S_i) = \begin{cases} P(a) \cup O(z), & a \neq S_i, \\ O(z), & a = S_i. \end{cases}$$

Если $G(a)$ – грамматика первого типа, то $P(a) = \emptyset$ и процесс построения $P(S_i)$ на этом заканчиваем. В противном случае анализируем заключительные правила второго типа грамматики $G(a)$ и т.д. В получаемую в результате такого процесса цепочку из $P(S_i)$ и $O(z_k)$ заносим те из $P(S_i)$, которые ранее в ней не рассматривались. Если в грамматике $G(S_i)$ заключительных правил второго типа несколько, то $P(S_i)$ строим для каждого такого правила отдельно, а затем берем их объединение. Очевидно, что множества $P(S_i)$ могут быть построены за конечное число шагов.

Атомную TR -грамматику $G(S_i)$, $S_i \in V_N$, назовем грамматикой с неопределенным самопересечением, если она содержит хотя бы одно правило $S_k \rightarrow z_j$ (либо $S_k \rightarrow z_j$) такое, что $G(S_k)$ – атомная грамматика второго типа и $P(S_k) \cap O(z_j) \neq \emptyset$. Содержательно это определение поясним следующим примером. Пусть в грамматике $G(S)$ можно вывести цепочку $\alpha = \varphi S_1 S_2 \psi$; $S_1, S_2 \in V_N$, $\varphi, \psi \in (AUV_N)^*$ и пусть порождаемые S_1 цепочки имеют вид $\theta\{\mu\}$, а S_2 – соответственно $\mu\nu$, $\theta, \mu, \nu \in (AUV_N)^* \setminus \epsilon$, ϵ – пустая цепочка. Тогда в момент анализа первого элемента цепочки μ неизвестно, следует ли распознавать его в $G(S_2)$ или остаться в $G(S_1)$.

TR – грамматику назовем **детерминированной**, если опорное множество любого из подмножеств правил, её образующих, не содержит совпадающих элементов и ни одна из образующих её атомных грамматик не является грамматикой с неопределенным самопересечением.

Выделение класса детерминированных TR -грамматик объясняется тем, что они допускают или отвергают входные цепочки быстрее, чем недетерминированные. Из леммы I и определения атомной TR -грамматики с неопределенным самопересечением следует:

ЛЕММА 2. Свойство TR -грамматики быть детерминированной проверяется за конечное число шагов.

В классе детерминированных TR -грамматик выделим подкласс, образованный **мононетерминальными** грамматиками. По определению, грамматика является мононетерминальной, если любое из подмножеств правил, её образующих, содержит не более од-

ного правила с нетерминальной левой частью. Особенностью этого подкласса является более высокая скорость работы анализатора, что показано ниже.

П. При представлении TR -грамматик в памяти электронной вычислительной машины (ЭВМ) каждому правилу TR -грамматик отведем строку TR -таблицы. Подмножеству правил будет при этом соответствовать уровень – последовательность рядом стоящих строк TR -таблицы. Роль имени подмножества правил выполняет адрес первого правила уровня. Для подмножеств правил, являющихся аксиомами, эти адреса соответствуют нетерминальным символам. Атомные TR -грамматики можно располагать в памяти ЭВМ в любом порядке.

Строка TR -таблицы имеет следующую структуру:

T_1	T_2	T_3	T_4	T_5	T_6	T_7
-------	-------	-------	-------	-------	-------	-------

T_1 – указатель конца уровня,

$$T_1 = \begin{cases} 1 & \text{– данное правило, последнее в уровне;} \\ 0 & \text{– в противном случае;} \end{cases}$$

T_2 – указатель вида правила,

$$T_2 = \begin{cases} 1 & \text{– правило с нетерминальной левой частью,} \\ 0 & \text{– правило с терминальной левой частью;} \end{cases}$$

T_3 – код символа из A либо адрес строки TR -таблицы для правил с нетерминальной левой частью;

T_4 – адрес множества глобальных правил-преемников;

T_5 – выделитель разомкнутых правил,

$$T_5 = \begin{cases} 1 & \text{– правило входит в подмножество, имя которого принадлежит } R^*, \\ 0 & \text{– в противном случае;} \end{cases}$$

T_6 – указатель типа правил,

$$T_6 = \begin{cases} 1 & \text{– правило второго типа,} \\ 0 & \text{– в противном случае;} \end{cases}$$

T_7 – выходной символ (для преобразующих TR -грамматик).

Рассмотрим алгоритм работы синтаксического анализатора для детерминированных и мононетерминальных грамматик. Этот практически важный класс (он включает языки АЛГОЛ-60, ФОРТРАН, BASIC и др.) допускает беступиковые схемы синтаксического анализа. Последнее означает, что никакая подстрока входной строки не анализируется более одного раза. Это позволяет вести синтаксический анализ за время, пропорциональное n -длине входной строки, тогда

как для КС-грамматик [2] это время в общем случае пропорционально n^3 . Описание алгоритмов будет вестись применительно к таблицам. Это не уменьшает общности, т.к. небольшая модификация делает их пригодными и для грамматик, представленных в виде подмножеств правил. Для этого необходимо вместо адресов памяти рассматривать имена подмножеств правил и номера правил в подмножестве, их содержащем.

Пусть на вход анализатора поступила цепочка $S = \alpha_1 \alpha_2 \dots \alpha_n$, $S \in A^* \setminus \varepsilon$. Введем еще один символ, $\#$, $\# \in (A \cup V_n)$, который назовем маркером конца входной строки. Считаем, что любая строка ограничена справа маркером $\#$. Алгоритм работы анализатора для детерминированных TR -грамматик представим в виде записанной на языке BASIC программы. Поскольку изобразительные средства BASICa не позволяют передать все тонкости алгоритма (нельзя работать с частью ячейки), для соответствующих разрядов строки TR -таблицы введем обозначение $T_i[J]$, $1 \leq i \leq 7$.

```

10 LET L = 0
20 LET I, J, K = 1
30 IF T2[J] = 0 THEN 80
40 LET L = L + 1
50 LET S[L] = J
60 LET J = T3[J]
70 GOTO 30
80 IF Σ[I] = T3[J] THEN 220
90 IF T1[J] = 1 THEN 120
100 LET J = J + 1
110 GOTO 30
120 IF L = 0 THEN 290
130 IF T5[J] = 0 THEN 190
140 LET J = S[L]
150 LET L = L - 1
160 LET V[K] = T7[J]
170 LET K = K + 1
180 GOTO 260
190 LET J = S[L]
200 LET L = L - 1
210 GOTO 90

```

```

220 LET V[K] = T7[J]
230 LET K = K + 1
240 LET I = I + 1
250 IF Σ[I] = # THEN 310
260 LET J = T4[J]
270 IF J ≠ 0 THEN 30
280 IF L ≠ 0 THEN 130
290 PRINT "MISTAKE"
300 STOP
310 IF L = 0 THEN 370
320 LET J = S[L]
330 LET L = L - 1
340 LET V[K] = T7[J]
350 LET K = K + 1
360 GOTO 310
370 IF T4[J] ≠ 0 OR T6[J] ≠ 1 THEN 290
380 PRINT "NO MISTAKES"
390 END

```

В этой программе $\Sigma[I]$ - I -й входной символ, $S[L]$ - L -ая ячейка стека связи, $V[K]$ - K -ый выходной символ. Описание массивов $\Sigma[I]$, $V[K]$, $S[L]$, $T[J]$ в программу не включено.

Данный алгоритм непосредственно применим и для мономонетерминальных грамматик. Однако, если ввести каноническую форму записи TR -грамматик, согласно которой в любом уровне сначала идут правила с терминальной левой частью, а затем - с нетерминальной, работу анализатора можно ускорить. Для этого оператор 210 заменяем на 210 GOTO 120. Это позволяет избежать проверки, является ли считанное из стека правило последним в уровне (в случае мономонетерминальных грамматик оно обязательно последнее).

Предложенный алгоритм был реализован в синтаксическом анализаторе системного транслятора для однородной вычислительной системы (ОВС) "Минск-222" [3,4]. Объем задающей его программы - порядка 50 слов ЭВМ "Минск-22", скорость работы - несколько десятков команд на анализируемый символ входной цепочки. Этот же алгоритм положен в основу синтаксического анализатора, являющегося одним из модулей программного обеспечения ОВС МИНИМАКС [5].

Л и т е р а т у р а

1. КОНСТАНТИНОВ В.И., КУРИЕВ Р.М. Метаязык трансляции кон-
текстно-свободных языков. Настоящий сборник, с. 77-83.
2. ЯНГЕР Д.Х. Распознавание и анализ контекстно-свободных
языков за время n^3 . - Проблемы математической логики, М., "Мир",
1970, с. 344-362.
3. ЕВРЕИНОВ Э.В., ЛОПАТО Г.Л. Универсальная вычислительная
система "Минск-222". - "Вычислительные системы", Новосибирск, 1966,
вып. 23, с. 13-20.
4. КОНСТАНТИНОВ В.И. Транслятор для однородной вычислитель-
ной системы, - "Вычислительные системы", Новосибирск, 1972, вып. 51,
с. 59-69.
5. ВИНСКУРОВ В.Г., ДМИТРИЕВ Д.К., ЕВРЕИНОВ Э.В., КОСТЕВЕН-
СКИЙ В.М., ЛЕЖНОВА Г.М., МИРЕНОВ Н.Н., РЕЗАНОВ В.В., ХОРОШЕВ -
СКИЙ В.Г. Однородная вычислительная система из мини-машин. - "Вы-
числительные системы" Новосибирск, 1972, вып. 51, с. 127-145.

Поступила в ред.-изд. отд.
6 февраля 1973 года