

УДК 681.142.2.

О МЕТАЯЗЫКЕ СИНТАКСИЧЕСКИ УПРАВЛЯЕМОГО ТРАНСЛЯТОРА

И.В. Вельбицкий

Эффективность работы синтаксически управляемого транслятора в значительной степени определяется метаязыком, используемым для описания грамматик [1]. В данной работе обсуждается метаязык, ориентированный на применение в синтаксически управляемых трансляторах.

1. Пусть S - словарь синтермов [2], элементы которого в дальнейшем, где это не оговорено, будут обозначаться малыми начальными буквами латинского алфавита; α - некоторый вспомогательный словарь, содержащий пустой символ, $\alpha = \{\emptyset, \nu_i\}_{i \in I}$, $I = \{1, \dots, \kappa\}$; R - множество имен некоторых конечных множеств (возможно, пустых) подмножеств правил вида:

$$\alpha \xrightarrow{W_m} z \quad (1)$$


или

$$\alpha \xrightarrow{W_m} z, \quad (2)$$

где $\alpha \in S$; $z \in R$; $R = \{\emptyset, z_i\}_{i \in I}$, $I = \{1, \dots, \ell\}$, $\emptyset$ - имя пустого множества правил; $\xrightarrow{W_m}$ или $\xrightarrow{W_m},$ - многоместное отношение, означающее, что синтерм слева от него некоторым образом конкатенирует с синтермом левой части любого правила из множества, имя

которого указано справа от W_m - отношения; $W_m = W_m(\alpha_1, \alpha_2, \dots, \alpha_n)$, α_i - слово в словаре $\alpha \cup R$, $i = 1, \dots, n$; конкатенация синтермов определяется типом m ($m = 0, 1, 2$) W_m -отношения. Число n аргументов W_m - отношения соответствует числу стеков, используемых при интерпретации правил грамматики. При этом предполагается, что на вершине пустых стеков помещены символы $\emptyset$; наличие символа $\emptyset$ в качестве аргумента W_m - отношения означает, что соответствующий этому аргументу стек не используется в интерпретации любого правила.

Для приложений удобно правила (1), (2) изображать соответственно в виде графов:




В этих графах дуга соответствует синтерму правила и несет информацию о W_m - отношении; граничные вершины дуги - именам множества правил; начало дуги - имени множества правил, которому принадлежит данное правило; конец дуги - имени множества правил-преемников [3].


Правило вида (1) интерпретируется следующим образом:

А. При $m = 0$ (отношение нулевого типа) синтерм α может конкатенировать с синтермами, встречающимися в левых частях правил из множества с именем z ; тем самым данное правило определяет свои возможные правила - преемники из множества R .

W_0 - отношение изображается графом:





Если в качестве z стоит символ $\emptyset$, то α соответствует последнему символу предложения языка. В этом случае конец дуги графа выделяется (например, штриховкой):




В. При $m = 1$ (отношение первого типа) указанная конкатенация и преобразование правил имеет место при одновременной записи непустых α_i в соответствующие z - а стеки. Очевидно, $W_1 = W_0$, если все α_i из W_1 - пустые символы. W_1 -отношение изображается графом:



С. При $m = 2$ (отношение второго типа) проверяется условие совпадения всех непустых символов $\nu_i \in \alpha$ с символами в вершинах соответствующих стеков. При выполнении условия происходит конкатенация, преобразование правил и выборка этих стеков. При отсутствии такого совпадения ни конкатенация, ни преобразование, ни выборка из соответствующих стеков не имеют места. W_2 - отношения изображаются графами:



если α соответствует конечному символу некоторого предложения языка. Если дуги, выходящие из одной вершины, отличаются лишь аргументами при W_2 - отношении, то они изображаются в виде метки:



Все сказанное о правилах вида (1) справедливо и для правил вида (2) с тем отличием, что синтерм α может быть конечным (может соответствовать конечному символу) некоторого предложения языка даже при z , отличном от $\emptyset$. При этом на графе конец соответствующей дуги выделяется (штриховкой).

Таким образом, интерпретация правил (1), (2) включает определения как допустимого множества конкатенаций с данным синтермом правила, так и множества правил преобразователей, а также указание на то, что данный синтерм может быть конечным.

1.1. Несколько слов о соответствии термов синтермам. Синтерм является элементом метаязыка, терм - языка. Соответствие между ними зададим функцией $F = F(t, \tau)$, где $t \in T$ - терм, T - терминальный словарь языка, τ - некоторый параметр соответствующего множества из $\mathcal{R}$. Каждому имени этого множества поставлен в соответствие некоторый индекс τ из множества индексов $\mathcal{M}$, который в дальнейшем будем записывать в виде верхнего индекса соответствующего имени из $\mathcal{R}$. На графе индекс τ записывается в вершине, инцидентной началу дуги.



Содержательно: каждому терму в зависимости от его места в предложении языка могут соответствовать различные синтермы. И, наоборот, в каждой локальной конструкции языка одному синтерму могут соответствовать несколько термов. Например, в АЛГОЛе - 60 символу "+" можно поставить в соответствие три различных синтерма, которые условно обозначим: "+₁", "+₂", "+₃".

Синтерму "+₁" соответствует конструкция языка, которую неформально можно назвать как: "перед арифметическим выражением". Этому синтерму соответствует два терма: "+", "-".

Синтерм "+₂" соответствует конструкции языка, которую можно определить как: "внутри арифметического выражения". Этому синтерму соответствует шесть термов: "+", "-", "x", "/", ":", "=".

Синтерм "+₃" соответствует конструкции: "внутри комментария". Этому синтерму соответствует 115 термов: 52 буквы латинского алфавита (заглавные и прописные), 10 цифр, 29 ограничителей, 24 буквенных выражения.

Очевидно, что конструкции языка могут быть локализованы

лишь с помощью правил его грамматики. Естественно каждому множеству правил, соответствующему определенной конструкции языка, поставить в соответствие некоторый параметр τ , благодаря которому термы, имеющие одинаковое продолжение, можно обозначать одним синтермом и представлять одним правилом в соответствующем множестве правил $z^\tau \in R$.

Таким образом, использование словаря синтермов, определяемого с помощью некоторой функции $F = F(t, \tau)$, $t \in T$, $\tau \in M$, позволяет существенно уменьшить число правил в каждом множестве z^τ , следовательно, во всем множестве R . Это на практике позволяет компактно записывать грамматики исходных языков.

1.2. Выше было определено, что z^τ — множество подмножеств правил вида (1), (2). Будем в дальнейшем подмножество правил, совпадающее с некоторым множеством правил, имеющим имя z_i^τ , обозначать именем z_i . Следовательно, записи множеств:



$$z_i^\tau: \{A_1, \dots, A_p, A_{p+1}, \dots, A_{p+q}\},$$

$$z_j^\tau: \{A_1, \dots, A_p\},$$

$$z_i^\tau: \{z_j, A_{p+1}, \dots, A_{p+q}\},$$

$$z_j^\tau: \{A_1, \dots, A_p\}$$


эквивалентны между собой, где $A_1, \dots, A_{p+q}$ — правила вида (1), (2). На графе указанная ситуация изображается дугой без обозначений, направленной к вершине z_j^τ . Например, изображенные ниже графы эквивалентны:



1.3. Множество правил

$$z_i^{\tau*}: \{A_1, \dots, A_q\},$$

элементами которого являются правила множества $\{A_1, \dots, A_q, z\}$, где z — расположенное на вершине стековой памяти имя некоторого множества правил, назовем **разомкнутым**. На графе разомкнутым множествам соответствуют дуги, в обозначении которых отсутствуют синтермы, например:



Подводя итог, можно сказать, что грамматикой языка, неориентированной для синтаксического анализа (не содержащей определений семантики), понимается семерка:

$$G = (T, S, M, \alpha, F, R, z_0), \quad (3)$$

где

T — терминальный словарь языка;

S — словарь синтермов;

M, α — вспомогательные словари, $M \cap \alpha = \emptyset$;

$F = F(t, \tau)$ — функция соответствия термов ($t \in T$) синтермам в зависимости от параметра $\tau \in M$ грамматики языка;

$R = \{z_i^\tau\}_{i \in I, \tau \in M}$ — множество имен некоторых конечных множеств (возможно, пустых) подмножеств правил вида (1), (2);

z_0 — аксиома грамматики, некоторое выделенное начальное множество правил.

ПРИМЕР. Простое арифметическое выражение языка АЛГОЛ-60, в определении [4] которого: <первичное выражение> ::= <целое> <простая переменная> <(простое арифметическое выражение)> — задаётся следующей R — грамматикой

$$G = (T, S, M, \alpha, F, R, z_0),$$

2°. Рассмотрим некоторые свойства $\mathcal{R}$ - грамматики. Пусть для простоты $S = T$. Цепочка символов $\varphi = a_1 a_2 \dots a_n$ является W - выводом φ (обозначение $a_i \Rightarrow \varphi$), если существует последовательность правил преемников, порождающих эту цепочку, начиная от a_i . Если при этом a_k порождается правилом вида (1) с символом ϕ в правой части или правилом вида (2), то W - вывод φ называется законченным и обозначается $a_i \Rightarrow \varphi$.

Язык, порождаемый $\mathcal{R}$ - грамматикой (3):

$$\mathcal{L}(G) = \{ \varphi | \varphi = a_1 \dots a_n; a_i \in T, 1 \leq i \leq n, a_i \in \tau_0, a_i \Rightarrow \varphi \}.$$

Терминальные символы a_j и $a_{j,k}$ ($k > 0$) в цепочке $\varphi = a_1 \dots a_{j,k}$, $a_i \in \tau_0$, порождаемые правилами с $W_1 = (\varphi_1, \dots, \varphi_n)$ и $W_2 = (\varphi_1, \dots, \varphi_n)$, соответственно, называются базовым начальным и базовым конечным для i - го стека, если $\varphi_i = \varphi_i'$, $1 \leq i \leq n$.

Правило $\mathcal{R}$ - грамматики называется фиктивным, если не существует законченного W - вывода φ , в котором данное правило применялось по крайней мере один раз. Грамматика, не содержащая фиктивных правил, называется приведенной. $\mathcal{R}$ - грамматика является детерминированной, если терминальные символы каждого множества правил совпадают лишь в правилах, содержащих W_2 с различными наборами аргументов.

Выделим интересные для практических приложений классы детерминированных $\mathcal{R}$ - грамматики:

1. монарные, мощность всех множеств правил которых равна 1;

2. односторонние линейные, для всех правил которых $m = 0$;

3. левоконтекстные, для всех правил которых $m \neq 2$;

4. с ранним определением синтерма, у которых все подмножества любого из множеств τ_i правил имеют одинаковый признак τ ;

5. с поздним определением синтерма, у которых хотя бы два подмножества любого из множеств τ_i правил имеют различные признаки τ ;

6. последовательные, у которых элементы множества $\mathcal{R}$ могут быть упорядочены так, что при любом поро-

ждении преемников может быть либо правило из этого же множества, либо из любого следующего в упорядоченной последовательности множеств правил.

Монарные грамматики допускают построение универсального алгоритма исправления одиночных ошибок, однако они порождают весьма узкий класс языков.

Односторонние линейные $\mathcal{R}$ - грамматики позволяют проводить синтаксический анализ без стековой памяти.

Левоконтекстные $\mathcal{R}$ - грамматики допускают построение эффективного алгоритма локализации синтаксических ошибок и позволяют компактно описать довольно широкий класс языков.

$\mathcal{R}$ - грамматики с ранним определением синтерма позволяют строить более быстрые схемы синтаксического анализа по сравнению с $\mathcal{R}$ - грамматиками с поздним определением синтерма.

Последовательные $\mathcal{R}$ - грамматики допускают весьма простые технические средства для реализации синтаксического анализа.

3. Пусть $\mathcal{U}$ - множество информатив, некоторое множество стандартных подпрограмм и таблиц, однозначно описывающих некоторый язык L_i , $\mathcal{A}$ - множество правил $\mathcal{R}$ - грамматики, задающей язык L_{i-1} ; $\mathcal{D}$ - множество директив, задающих отображение множества $\mathcal{A}$ в $\mathcal{U}$. Тогда под семантическим описанием правил $\mathcal{R}$ - грамматики будем понимать некоторое множество $\mathcal{C} \subseteq (\mathcal{D} \times \mathcal{U})$, элементы которого поставлены во взаимно однозначное соответствие элементам множества $\mathcal{A}$. Под полным описанием $\mathcal{R}$ - грамматики языка понимается восьмерка

$$G = (\mathcal{C}, S, M, \mathcal{A}, F, \mathcal{R}, \tau_0, \mathcal{C}),$$

каждое правило которой имеет вид:

$$a \xrightarrow{W_m} \tau_i(d, u) \quad (4)$$

или

$$a \xrightarrow{W_m} \tau_i(d, u), \quad (5)$$

где $d \in \mathcal{D}$, $u \in \mathcal{U}$ из $\mathcal{C}$.

Приведенная $\mathcal{R}$ - грамматика весьма эффективна при распознавании в синтаксически управляемых устройствах. Действительно, последовательность символов является предложением языка, если синтерм, соответствующий ее первому символу, является символом, встречающимся в левой части одного из правил - преемников приведенного правила, а последний символ встречается в одном из

правил вида (5) или в правиле вида (4) с символом ϕ в правой части. На каждом этапе распознавания текущему символу исходной последовательности, или текущему символу, и некоторой последовательности предшествующих символов по правилам, предписанным в d , ставится в соответствие последовательность символов из u , где d и u — директивное и информативное описания семантики правила R — грамматики, применяемого к текущему символу исходной последовательности.

Транслятор строится таким образом, что каждому его блоку ставится в соответствие как некоторый параметр R — грамматика входного для этого блока языка. Блоки работают последовательно. Каждый символ исходного предложения последовательно "проходит" через блоки транслятора до блока, в котором либо заканчивается его обработка, либо происходит накопление для последующих этапов трансляции. Затем выбирается следующий символ исходного предложения (управление передается первому блоку) и т. д. Все блоки на всех этапах трансляции работают по одной и той же программе синтаксического анализа, которая является основной программой всего транслятора. По окончании работы i -го блока, и включении $(i + 1)$ -го или первого в i -м блоке формируется управляющее слово о состоянии программы синтаксического анализа в момент включения. Включение $(i + 1)$ -го блока — это настройка общей программы синтаксического анализа с помощью соответствующего этому блоку управляющего слова. Каждый блок, кроме синтаксического анализа, может доопределить текущий символ семантически. Благодаря этому сокращаются R — грамматики последующих блоков, упрощаются соответствующие им информативные и директивные стандартные подпрограммы.

При многопроходной схеме трансляция ведется последовательно, несколькими итеративно работающими блоками. Важно отметить, что и в этом случае все блоки при всех проходах работают по одной и той же программе синтаксического анализа.

Описанный метаязык позволяет весьма компактно представлять грамматики существующих алгоритмических языков. Так, например, грамматика языка ALGOL — 60 задается приблизительно 250 правилами (машинными словами). Программа синтаксического анализа, реализующая распознавание правил R — грамматики в процессе работы синтаксически управляемого транслятора, содержит около 100

команд и работает со скоростью нескольких десятков команд на каждый символ исходного предложения.

ЛИТЕРАТУРА

1. И. В. ВЕЛЬБИЦКИЙ, Ю. Л. ЮЩЕНКО. Метаязык, ориентированный для синтаксического анализа и контроля. Кибернетика, № 2, 1970.
2. И. В. ВЕЛЬБИЦКИЙ. Первичные средства подготовки синтаксически правильных программ — Труды II Всесоюзной конференции по ВС., М., 1969.
3. К. БЕРЖ. Теория графов и её применение. Изд-во Иностранной литературы, М., 1962.
4. Алгоритмический язык ALGOL-60 (пересмотренное сообщение). М., Изд-во "Мир", 1965.

Поступила в редакцию
20 июня 1970 г.