

Глава 4. Восходящий синтаксический анализ

4.2. Грамматики простого предшествования

Одним из наиболее легких подходов к решению проблемы поиска и своевременной свертки основы является реализация восходящего синтаксического анализа для небольшого класса КС-грамматик, называемых *грамматиками простого предшествования*. Технология синтаксического анализа для таких грамматик предполагает введение специальных бинарных отношений между каждой парой символов грамматики (как терминалов, так и нетерминалов). Эти отношения управляют выбором основ сентенциальных форм для последующей их свертки.

Основным недостатком этого метода является применимость его лишь в узком классе грамматик простого предшествования.

4.2.1. Отношения предшествования

Пусть $G = (V_T, V_N, P, S)$ – контекстно-свободная грамматика, а строка $\alpha X Y \beta$ – правосторонняя сентенциальная форма, где $\alpha, \beta \in (V_T \cup V_N)^*$, $X, Y \in V_T \cup V_N$. В некоторый момент (на одном из этапов процесса последовательных сверток сентенциальной формы) возникает одна из следующих возможных ситуаций:

1. Y – самый левый символ (*заголовок*) основы сентенциальной формы, а X не входит в основу. В этом случае говорят, что символ Y *предшествует* символу X (поскольку символ Y должен быть свернут раньше символа X), и записывают в виде $X < Y$.

2. X и Y входят в одну и ту же основу. В этом случае говорят, что X и Y имеют *равное предшествование* (поскольку сворачиваются одновременно), и записывают в виде $X \doteq Y$.

3. X – последний символ (*окончание*) основы, а Y не входит в основу. В этом случае говорят, что символ X *предшествует* символу Y (поскольку символ X должен быть свернут раньше символа Y), и записывают в виде $X > Y$.

Отношения $<$, \doteq , $>$ называются *отношениями предшествования*. Следует заметить, что, хотя эти отношения похожи на арифметические отношения $<$, $=$, $>$, они имеют совершенно иные свойства. В частности, они не обладают свойствами коммутативности и ассоциативности. Из отношения $X > Y$, не следует, что существует отношение $Y < X$. Эти отношения не являются симметричными, из отношения $X \doteq Y$ не следует $Y \doteq X$. Для одной и той же грамматики может быть так, что $X < Y$ и $X > Y$, или для некоторых пар символов не выполняется ни одно из отношений предшествования.

Формально эти отношения для символов $X, Y \in V_T \cup V_N$ грамматики определяются следующим образом:

1. $X \doteq Y$, если существует некоторая продукция $A \rightarrow \alpha XY\beta$, $A \in V_N$, $\alpha, \beta \in (V_T \cup V_N)^*$. Это значит, что в правосторонней сентенциальной форме X и Y входят в одну и ту же основу.

2. $X < Y$, если существует некоторая продукция $A \rightarrow \alpha XB\beta$, $A, B \in V_N$, $\alpha, \beta \in (V_T \cup V_N)^*$, такая, что $B \stackrel{\dagger}{\Rightarrow} Y\delta$, $\delta \in (V_T \cup V_N)^*$. Это значит, что в правосторонней сентенциальной форме основа начинается с символа Y (Y является заголовком основы).

3. $X > Y$, если существует некоторая продукция $A \rightarrow \alpha BZ\beta$, $A, B \in V_N$, $Z \in V_T \cup V_N$, $\alpha, \beta \in (V_T \cup V_N)^*$, такая, что $B \stackrel{\dagger}{\Rightarrow} \gamma X$ и $Z \stackrel{*}{\Rightarrow} Y\delta$, $\gamma, \delta \in (V_T \cup V_N)^*$. Это значит, что в правосторонней сентенциальной форме основа завершается символом X (X является окончанием основы). Следует заметить, что в правосторонней сентенциальной форме справа от основы может быть только терминальная строка. Поэтому в данном случае символ Y может быть только терминалом, т. е. $Y \in V_T$, и отношение $>$ определяется на множестве $(V_T \cup V_N) \times V_T$. Заметим также, что если $Y\delta$ выводится из Z за нуль шагов, то $Z = Y$.

Контекстно-свободная грамматика $G = (V_T, V_N, P, S)$ называется *грамматикой простого предшествования*, если:

- 1) не содержит ε -продукций;
- 2) никакие две продукции грамматики не имеют совпадающих правых частей (грамматики, в которых нет двух продукций с одинаковыми правыми частями, называются *обратимыми*);
- 3) любые два символа, составляющие элемент множества $(V_T \cup V_N) \times (V_T \cup V_N)$, связаны одним и тем же отношением предшествования.

Отношения предшествования обычно записывают в виде *матрицы предшествования*, строки и столбцы которой соответствуют символам грамматики. На пересечении i -й строки и j -го столбца записывается отношение предшествования между соответствующими символами грамматики. Элементами матрицы являются знаки $<$, \doteq , $>$ или «пусто». Последний случай означает, что соответствующие символы не могут стоять рядом ни в одной сентенциальной форме.

4.2.2. Вычисление отношений предшествования

Формальный процесс вычисления отношений предшествования для символов $X, Y \in V_T \cup V_N$ заданной КС-грамматики можно представить такой последовательностью действий (в описании действий строки $\alpha, \beta \in (V_T \cup V_N)^*$, $A \in V_N$):

1. Определить для каждого нетерминала X грамматики множество $L(X) = \{Y \mid X \xrightarrow{\pm} Y\alpha\}$, т. е. множество символов грамматики (как терминалов, так и нетерминалов), с которых могут начинаться строки, выводимые из нетерминала X . Для этого необходимо построить отношение $\langle \text{LEFT} \rangle$, определяемое следующим образом: $X \langle \text{LEFT} \rangle Y$, если в грамматике существует продукция вида $X \rightarrow Y\beta$. Затем вычислить отношение $\langle \text{LEFT} \rangle^+$ как транзитивное замыкание отношения $\langle \text{LEFT} \rangle$. Тогда $L(X)$ есть множество символов Y , для которых выполняется отношение $X \langle \text{LEFT} \rangle^+ Y$.

2. Вычислить отношение $\langle \text{LEFT} \rangle^*$ как рефлексивно-транзитивное замыкание отношения $\langle \text{LEFT} \rangle$. Очевидно, что отношение $\langle \text{LEFT} \rangle^*$ легко вычисляется по отношению $\langle \text{LEFT} \rangle^+$, поскольку имеет место соотношение $\langle \text{LEFT} \rangle^* = \langle \text{LEFT} \rangle^+ \cup I$, где I – отношение тождественности. Отношение $\langle \text{LEFT} \rangle^*$ понадобится для вычисления отношения \rangle .

3. Определить для каждого нетерминала X грамматики множество $R(X) = \{Y \mid X \xrightarrow{+} \alpha Y\}$, т. е. множество символов грамматики, являющихся крайними справа в строках, выводимых из нетерминала X . Для этого необходимо построить отношение $\langle \text{RIGHT} \rangle$, определяемое следующим образом: $Y \langle \text{RIGHT} \rangle X$, если в грамматике существует продукция вида $X \rightarrow \beta Y$. Затем вычислить отношение $\langle \text{RIGHT} \rangle^+$ как транзитивное замыкание отношения $\langle \text{RIGHT} \rangle$. Тогда $R(X)$ есть множество символов Y , для которых выполняется отношение $Y \langle \text{RIGHT} \rangle^+ X$.

4. Построить для всех символов грамматики отношение \doteq по его определению, т. е. $X \doteq Y$, если в грамматике существует продукция вида $A \rightarrow \alpha XY\beta$.

5. Вычислить отношение \prec . Из его формального определения следует, что $X \prec Y$, если в грамматике имеется продукция вида $A \rightarrow \alpha XB\beta$, где $B \in V_N$, и $Y \in L(B)$. Таким образом, отношение \prec можно вычислить как произведение отношений \doteq и $\langle \text{LEFT} \rangle^+$, т. е. $(\prec) = (\doteq) (\langle \text{LEFT} \rangle^+)$.

6. Вычислить отношение \succ . Из его формального определения следует, что $X \succ Y$ (напомним, что отношение определено только для $Y \in V_T$), если существует продукция

а) вида $A \rightarrow \alpha BY\beta$, где $B \in V_N$, $Y \in V_T$, и $X \in R(B)$;

б) вида $A \rightarrow \alpha BZ\beta$, где $B, Z \in V_N$, и $X \in R(B)$, $Y \in L_T(Z)$, где $L_T(Z) \subseteq L(Z)$ – подмножество терминалов множества $L(Z)$.

Таким образом, $(\succ) = (\langle \text{RIGHT} \rangle^+) (\doteq) (\langle \text{LEFT} \rangle^*)$. Поскольку Y может быть только терминалом, при вычислении произведения отношений следует рассматривать только те отношения $X \langle \text{LEFT} \rangle^* Y$, где $Y \in V_T$.

7. Построить матрицу предшествования, объединив матрицы отношений \doteq , \prec и \succ в одну и заменив единицы на соответствующие обозначения (\doteq, \prec, \succ) отношений.

Пример процесса вычисления отношений предшествования для грамматики с продукциями

$$S \rightarrow AB$$

$$A \rightarrow aA \mid a$$

$$B \rightarrow bB \mid b$$

представлен на рис. 4.3.

$S \rightarrow AB$
 $A \rightarrow aA \mid a$
 $B \rightarrow bB \mid b$

< LEFT >

	S	A	B	a	b
S		1			
A				1	
B					1

< LEFT >⁺

	S	A	B	a	b
S		1		1	
A				1	
B					1

< LEFT >^{*}

	S	A	B	a	b
S	1	1		1	
A		1		1	
B			1		1
a				1	
b					1

< RIGHT >

	S	A	B
S			
A		1	
B	1		1
a		1	
b			1

< RIGHT >⁺

	S	A	B
S			
A		1	
B	1		1
a		1	
b	1		1

$\dot{=}$

	S	A	B	a	b
S					
A			1		
B					
a		1			
b			1		

<

	S	A	B	a	b
S					
A				1	
B					
a				1	
b					1

>

	S	A	B	a	b
S					
A				1	
B					
a				1	
b					1

Матрица предшествования

	S	A	B	a	b
S					
A		$\dot{=}$		<	>
B			$\dot{=}$		
a		$\dot{=}$		<	>
b			$\dot{=}$		<

Рис. 4.3. Процесс вычисления отношений предшествования

Из отношений $\langle \text{LEFT} \rangle^+$ и $\langle \text{RIGHT} \rangle^+$ следует, что

$$L(S) = \{A, a\}, L(A) = \{a\}, L(B) = \{b\},$$

$$R(S) = \{B, b\}, R(A) = \{A, a\}, R(B) = \{B, b\}.$$

Грамматика не является грамматикой простого предшествования, поскольку она не удовлетворяет третьему условию, требующему, чтобы любые два символа грамматики были связаны одним и тем же отношением предшествования. В нашем случае одновременно выполняются $A < b$ и $A > b$. Действительно $A < b$, так как имеется продукция $S \rightarrow AB$ и $b \in L(B)$, т. е. $B \xrightarrow{+} b$, а $A > b$, так как существует продукция $S \rightarrow AB$, такая, что $A \in R(A)$ и $b \in L(B)$, т. е. $A \xrightarrow{+} aA$ и $B \xrightarrow{*} b$.

Более кратко для вычисления вручную (пусть имеется продукция вида $A \rightarrow \alpha XY\beta$):

1) $X \doteq Y$ для любых символов (терминалов и нетерминалов),

2) если $Y \in V_N$, то X связано отношением $<$ со всеми элементами из $L(Y)$,

3) если $X \in V_N$, то

а) если $Y \in V_T$, то все элементы из $R(X)$ связаны отношением $>$ с элементом Y ,

б) если $Y \in V_N$, то все элементы из $R(X)$ связаны отношением $>$ со всеми терминалами из $L(Y)$.