

Практическое занятие №6. LL(1)-анализ

Д.Ю. Чалый

24 декабря 2010 г.

1 Построение множеств $FIRST$ и $FOLLOW$

Ключевой задачей при использовании метода LL(1)-анализа является корректное построение множеств $FIRST$ и $FOLLOW$.

Рассмотрим следующую грамматику:

$$\begin{array}{lcl} S & \rightarrow & ABa \mid DE \\ A & \rightarrow & EC \mid AC \\ B & \rightarrow & b \mid \epsilon \\ C & \rightarrow & c \\ D & \rightarrow & d \mid \epsilon \\ E & \rightarrow & BAB \mid c \end{array}$$

Построим множества $FIRST(X)$, где $X \in N$. Физический смысл множеств $FIRST(X)$ состоит в том, что это множество терминальных символов, с которых могут начинаться строки, выводимые из X . Построение происходит по алгоритму, который имеет итеративный характер, т.е. мы постепенно пополняем множества $FIRST$ для нетерминальных символов грамматики. При этом пользуются следующими правилами:

- Если в грамматике есть продукция вида $X \rightarrow aa$, где $a \in T$, $\alpha \in (N \cup T)^*$, то в множество $FIRST(X)$ помещаем a . Таким образом, после использования этого правила мы получим следующий набор множеств $FIRST$:

$$\begin{array}{ll} FIRST(S) & = \emptyset \\ FIRST(A) & = \emptyset \\ FIRST(B) & = \{b, \epsilon\} \\ FIRST(C) & = \{c\} \\ FIRST(D) & = \{d, \epsilon\} \\ FIRST(E) & = \{c\} \end{array}$$

- Если в грамматике есть продукция вида $X \rightarrow A\alpha$, где $A \in N$, $\alpha \in (N \cup T)^*$, то в множество $FIRST(X)$ включаем $FIRST(A) \setminus \{\epsilon\}$. Таким образом, после использования этого правила мы получим следующий набор множеств $FIRST$:

$$\begin{aligned}
 FIRST(S) &= \emptyset \cup (FIRST(D) \setminus \{\varepsilon\}) = \{d\} \\
 FIRST(A) &= \emptyset \cup (FIRST(E) \setminus \{\varepsilon\}) = \{c\} \\
 FIRST(B) &= \{b, \varepsilon\} \\
 FIRST(C) &= \{c\} \\
 FIRST(D) &= \{d, \varepsilon\} \\
 FIRST(E) &= \{c\} \cup (FIRST(B) \setminus \{\varepsilon\}) = \{c, b\}
 \end{aligned}$$

3. Для грамматик с ε -продукциями необходимо учитывать следующее. Если в грамматике есть продукция вида $X \rightarrow A_1 \dots A_n$, где $A_i \in N \cup T$, причем $\forall i < j: \varepsilon \in FIRST(A_i)$ и $\varepsilon \notin FIRST(A_j)$, то в множество $FIRST(X)$ включаем $\bigcup_{i=1}^j FIRST(A_i) \setminus \{\varepsilon\}$. Таким образом, после использования этого правила мы получим следующий набор множеств $FIRST$:

$$\begin{aligned}
 FIRST(S) &= \{d\} \cup (FIRST(E) \setminus \{\varepsilon\}) = \{b, c, d\} \\
 FIRST(A) &= \{c\} \\
 FIRST(B) &= \{b, \varepsilon\} \\
 FIRST(C) &= \{c\} \\
 FIRST(D) &= \{d, \varepsilon\} \\
 FIRST(E) &= \{c, b\} \cup ((FIRST(B) \cup FIRST(A)) \setminus \{\varepsilon\}) = \{b, c\}
 \end{aligned}$$

4. Еще одно правило для грамматик с ε -продукциями. Если в грамматике есть продукция вида $X \rightarrow A_1 \dots A_n$, где $A_i \in N \cup T$, то мы включаем в $FIRST(X)$ элемент ε тогда и только тогда, когда $\forall i: \varepsilon \in FIRST(A_i)$. В нашей грамматике таких продуктов нет.

Для построения итоговых множеств $FIRST$ необходимо применять вышеописанные правила до тех пор, пока возможно пополнение хотя бы одного множества $FIRST$. Проделайте это самостоятельно, а в итоге должно получиться:

$$\begin{aligned}
 FIRST(S) &= \{b, c, d\} \\
 FIRST(A) &= \{b, c\} \\
 FIRST(B) &= \{b, \varepsilon\} \\
 FIRST(C) &= \{c\} \\
 FIRST(D) &= \{d, \varepsilon\} \\
 FIRST(E) &= \{b, c\}
 \end{aligned}$$

Множества $FOLLOW$ строятся на основе рассчитанных множеств $FIRST$. Физический смысл множества $FOLLOW(X)$, где $X \in N$ состоит в том, что это множество терминальных символов, которые могут находиться непосредственно за нетерминалом X в выводимой сентенциальной форме. Необходимо заметить, что в множество $FOLLOW$ не может входить ε , однако может входить специальный знак $\#\$, обозначающий, что нетерминал может быть последним в выводимой сентенциальной форме. Очевидно, что знак $\#$ входит в множество $FOLLOW(S)$, где S – начальный символ грамматики, так как мы начинаем вывод именно с него. Сам алгоритм основывается на следующих правилах:

- Помещаем в множество $FOLLOW(S)$ знак $\$$.
- Пусть $X \rightarrow \alpha A a \beta$, где $\alpha, \beta \in (N \cup T)^*$, $A \in N$, $a \in T$, то помещаем в множество $FOLLOW(A)$ символ a .
- Пусть $X \rightarrow \alpha A B \beta$, где $\alpha, \beta \in (N \cup T)^*$, $A, B \in N$, то помещаем в множество $FOLLOW(A)$ элементы множества $FIRST(B)$.
- Пусть $X \rightarrow \alpha A$, где $\alpha \in (N \cup T)^*$, $A \in N$, то помещаем в множество $FOLLOW(A)$ элементы множества $FOLLOW(X)$.
- Если в грамматике есть ϵ -продукции, то необходимо это учитывать.
Пусть $X \rightarrow \alpha A X_1 X_2 \dots X_n \beta$, где $\alpha, \beta \in (N \cup T)^*$, $A, X_1, X_2 \dots X_n \in N$, причем $\forall i < n: \epsilon \in FIRST(X_i)$, тогда помещаем в $FOLLOW(A)$ элементы множества $FIRST(X_1), \dots, FIRST(X_n)$.
- Еще одно правило для того чтобы учитывать наличие ϵ -продукций.
Пусть $X \rightarrow \alpha A X_1 X_2 \dots X_n$, где $\alpha \in (N \cup T)^*$, $X_1, X_2 \dots X_n \in N$, причем $\forall 1 < i \leq n: \epsilon \in FIRST(X_i)$, тогда помещаем в $FOLLOW(X_1), \dots, FOLLOW(X_n)$ элементы множества $FOLLOW(X)$.
- Применяем вышеприведенные правила до тех пор, пока можем пополнять хоть одно множество $FOLLOW$.

Рассмотрим применение этих правил на примере нашей грамматики. Согласно правил 1 и 2, начальное содержимое множеств будем такими:

$$\begin{aligned} FOLLOW(S) &= \{\$\} \\ FOLLOW(A) &= \emptyset \\ FOLLOW(B) &= \{a\} \\ FOLLOW(C) &= \emptyset \\ FOLLOW(D) &= \emptyset \\ FOLLOW(E) &= \emptyset \end{aligned}$$

Применяем правила 3 и 5, получаем:

$$\begin{aligned} FOLLOW(S) &= \{\$\} \\ FOLLOW(A) &= \emptyset \cup ((FIRST(B) \cup \{a\} \cup FIRST(C)) \setminus \{\epsilon\}) = \{a, b, c\} \\ FOLLOW(B) &= \{a\} \cup (FIRST(A) \setminus \{\epsilon\}) = \{a, b, c\} \\ FOLLOW(C) &= \emptyset \\ FOLLOW(D) &= \emptyset \cup (FIRST(E) \setminus \{\epsilon\}) = \{b, c\} \\ FOLLOW(E) &= \emptyset \cup (FIRST(C) \setminus \{\epsilon\}) = \{c\} \end{aligned}$$

Теперь применим правила 4 и 6:

$$\begin{aligned} FOLLOW(S) &= \{\$\} \\ FOLLOW(A) &= \{a, b, c\} \cup FOLLOW(E) = \{a, b, c\} \\ FOLLOW(B) &= \{a, b, c\} \cup FOLLOW(E) = \{a, b, c\} \\ FOLLOW(C) &= \emptyset \cup FOLLOW(A) = \{a, b, c\} \\ FOLLOW(D) &= \{b, c\} \\ FOLLOW(E) &= \{c\} \cup FOLLOW(S) = \{c, \$\} \end{aligned}$$

... и еще несколько раз повторим применение правил и получим в итоге следующее

$$\begin{aligned} FOLLOW(S) &= \{\#\} \\ FOLLOW(A) &= \{a, b, c, \#\} \\ FOLLOW(B) &= \{a, b, c, \#\} \\ FOLLOW(C) &= \{a, b, c, \#\} \\ FOLLOW(D) &= \{b, c\} \\ FOLLOW(E) &= \{c, \#\} \end{aligned}$$

2 Критерий для LL(1)-грамматик

Для того чтобы убедиться, что грамматика действительно является LL(1)-грамматикой, существует критерий, состоящий из двух частей:

1. Для любых двух продукции $A \rightarrow \alpha$ и $A \rightarrow \beta$, $FIRST(\alpha) \cap FIRST(\beta) = \emptyset$.
2. Если существует продукция $A \rightarrow \epsilon$, то тогда для любой продукции $A \rightarrow \alpha$ должно выполняться $FOLLOW(A) \cap FIRST(\alpha) = \emptyset$.

Грамматика, рассмотренная ранее, не является LL(1)-грамматикой, из-за того, что не выполняется первый пункт критерия. Например, если рассмотреть продукции для нетерминала S , получим $FIRST(ABa) \cap FIRST(DE) = (FIRST(A)) \cap (FIRST(D) \cup FIRST(E)) = \{b, c\} \cap (\{\epsilon, d, \#\} \cup \{b, c\}) = \{b, c\} \cap \{\epsilon, b, c, d\} = \{b, c\} \neq \emptyset$.

Вторая часть критерия не выполняется если рассмотреть продукции для нетерминала B . Действительно, $FOLLOW(B) \cap FIRST(b) \neq \emptyset$.

3 Метод LL(1)-анализа

Метод LL(1)-анализа является эффективным методом синтаксического анализа, который позволяет строить вывод входной строки за линейное время. Его можно промоделировать при помощи построения управляющей таблицы LL(1)-анализатора. Рассмотрим следующую LL(1)-грамматику:

$$\begin{aligned} S &\rightarrow AB \mid DE \\ A &\rightarrow aA \mid \epsilon \\ B &\rightarrow b \mid dB \\ D &\rightarrow cA \\ E &\rightarrow e \mid \epsilon \end{aligned}$$

Множества $FIRST$ и $FOLLOW$ для символов грамматики получаются такими (убедитесь в этом!):

$$\begin{aligned}
 FIRST(S) &= \{a, b, c, d\} \\
 FIRST(A) &= \{\epsilon, a\} \\
 FIRST(B) &= \{b, d\} \\
 FIRST(D) &= \{c\} \\
 FIRST(E) &= \{\epsilon, e\}
 \end{aligned}$$

$$\begin{aligned}
 FOLLOW(S) &= \{\#\} \\
 FOLLOW(A) &= \{b, d, e, \#\} \\
 FOLLOW(B) &= \{\#\} \\
 FOLLOW(D) &= \{e, \#\} \\
 FOLLOW(E) &= \{\#\}
 \end{aligned}$$

Управляющая таблица представляет собой структуру, в которой столбцы поименованы терминалами (плюс знак конца строки $\#$), строки нетерминалами, а в ячейках таблицы располагаются продукции. Сначала удобно расположить все продукции, не являющиеся ϵ -продукциями. Они располагаются в таблице по принципу если $A \rightarrow \alpha$ — продукция в исходной грамматике, то поместим ее в строку, отмеченную A и в столбцы, отмеченные символами из $FIRST(\alpha)$. Если действовать по такому принципу, то для нашей грамматики таблица заполнится так:

	a	b	c	d	e	$\#$
S	$S \rightarrow AB$	$S \rightarrow AB$	$S \rightarrow DE$	$S \rightarrow AB$		
A	$A \rightarrow aA$					
B		$B \rightarrow b$		$B \rightarrow dB$		
D				$D \rightarrow cA$		
E					$E \rightarrow e$	

Продукции вида $X \rightarrow \epsilon$ помещаются в столбцы таблицы, помеченные символами из множества $FOLLOW(X)$. Для нашей грамматики мы получим такую таблицу:

	a	b	c	d	e	$\#$
S	$S \rightarrow AB$	$S \rightarrow AB$	$S \rightarrow DE$	$S \rightarrow AB$		
A	$A \rightarrow aA$	$A \rightarrow \epsilon$		$A \rightarrow \epsilon$	$A \rightarrow \epsilon$	$A \rightarrow \epsilon$
B		$B \rightarrow b$		$B \rightarrow dB$		
D			$D \rightarrow cA$			
E					$E \rightarrow e$	$E \rightarrow \epsilon$

Посмотрим теперь, как это работает. Пусть на вход подана строка ce . Мы начинаем вывод с S . Смотрим, какая продукция находится в строке S и столбце c . Это продукция $S \rightarrow DE$, значит вывод надо начинать с нее:

$$S \rightarrow DE$$

Теперь нам надо раскрыть нетерминал D , заглядываем в строку, отмеченную им, и в столбец c , там находится продукция $D \rightarrow cA$, получаем

$$S \rightarrow DE \rightarrow cAE$$

Первым в сентенциальной форме cAE стоит терминал, который мы успешно сравниваем с первым символом входной строки, перейдем ко второму символу, e . Смотрим в строку A таблицы и столбец e . Там находится продукция $A \rightarrow \epsilon$, получаем:

$$S \rightarrow DE \rightarrow cAE \rightarrow cE$$

Далее видим в строке E и столбце e находится продукция $E \rightarrow e$, применяем ее:

$$S \rightarrow DE \rightarrow cAE \rightarrow cE \rightarrow ce$$

Вот так мы вывели входную строку, пользуясь управляющей таблицей.