

# Лекции по теории формальных языков

## Лекция 7.

Преобразования контекстно-свободных грамматик (окончание).

Лексический анализ.

Разделённые грамматики

Александр Сергеевич Герасимов

<http://gas-teach.narod.ru>

Кафедра математических и информационных технологий

Санкт-Петербургского академического университета

Российской академии наук.

Весенний семестр 2010/11 учебного года

25 марта 2011 г.

# План

- 1 Нелеворекурсивные контекстно-свободные грамматики: повторение
- 2 Нелеворекурсивные контекстно-свободные грамматики: новый материал
- 3 Левофакторизованные контекстно-свободные грамматики
- 4 Лексический анализ
- 5 Разделённые грамматики

# План

- 1 Нелеворекурсивные контекстно-свободные грамматики: повторение
- 2 Нелеворекурсивные контекстно-свободные грамматики: новый материал
- 3 Левофакторизованные контекстно-свободные грамматики
- 4 Лексический анализ
- 5 Разделённые грамматики

## Левая рекурсия: определения

- Нетерминал  $V$  называется *леворекурсивным*, если  $V \Rightarrow^+ V\gamma$ , и *непосредственно леворекурсивным*, если  $V \rightarrow V\gamma$  — правило вывода (такое правило вывода называется *леворекурсивным*).
- КС-грамматика называется *леворекурсивной*, если леворекурсивен хотя бы один её нетерминал. В противном случае КС-грамматика называется *нелеворекурсивной* (или грамматикой *без левой рекурсии*).
- *A-правилом* КС-грамматики называется правило вида  $A \rightarrow \alpha$ .

# Лемма об устранении непосредственной левой рекурсии

## Лемма

Пусть  $A$  — непосредственно леворекурсивный нетерминал грамматики  $G$ ,

$$A \rightarrow A\alpha_1 | \dots | A\alpha_k | \beta_1 | \dots | \beta_m, \quad (1)$$

— все  $A$ -правила грамматики  $G$ , причём ни одна из цепочек  $\beta_i$  не начинается с  $A$ . Тогда грамматика  $G'$ , которая получается из  $G$  добавлением нового нетерминала  $A'$  и заменой правил (1) на правила

$$A \rightarrow \beta_1 A' | \dots | \beta_m A', \quad A' \rightarrow \alpha_1 A' | \dots | \alpha_k A' | \varepsilon, \quad (2)$$

эквивалентна грамматике  $G$ .

Множество правил, полученное заменой правил (1) на правила (2) в множестве правил  $P$ , обозначим через  $eilr(P, A)$ .

# Лемма об устранении непосредственной левой рекурсии: доказательство

Доказательство.

- Применением правил (1) грамматики  $G$  из нетерминала  $A$  можно вывести в точности все цепочки вида  $\beta_i \alpha_{j_1} \dots \alpha_{j_l}$ , где  $i \in \{1, \dots, m\}$ ,  $l \geq 0$ ,  $j_1, \dots, j_l \in \{1, \dots, k\}$ .
- Применением правил (2) грамматики  $G'$  из нетерминала  $A$  можно вывести в точности такие же цепочки.
- Остальные правила грамматик  $G$  и  $G'$  и их аксиомы совпадают.



# Пример устранения леворекурсивных правил из КС-грамматики

- Грамматика  $GA_2$  (порождающая язык арифметических выражений  $LA$ ) с множеством правил  $P$ :

- ▶  $\underbrace{E}_A \rightarrow \underbrace{T}_{\beta_1} \mid \underbrace{E}_A + \underbrace{T}_{\alpha_1}$ ,

- ▶  $T \rightarrow F \mid T * F$ ,

- ▶  $F \rightarrow (E) \mid x$ .

- $P' = eilr(P, E)$ :

- ▶  $\underbrace{E}_A \rightarrow \underbrace{T}_{\beta_1} \underbrace{E'}_{A'}$ ,  $\underbrace{E'}_{A'} \rightarrow \underbrace{+T}_{\alpha_1} \underbrace{E'}_{A'} \mid \varepsilon$ ,

- ▶  $T \rightarrow F \mid T * F$ ,

- ▶  $F \rightarrow (E) \mid x$ .

- Грамматика  $GA_3 = eilr(P', T)$ :

- ▶  $E \rightarrow TE'$ ,  $E' \rightarrow +TE' \mid \varepsilon$ ,

- ▶  $T \rightarrow FT'$ ,  $T' \rightarrow *FT' \mid \varepsilon$ ,

- ▶  $F \rightarrow (E) \mid x$ .

# Устранение правила из КС-грамматики

## Лемма

Пусть КС-грамматика  $G$  содержит правило  $A \rightarrow B\alpha$ ;  $B \rightarrow \beta_1 | \dots | \beta_k$  — все  $B$ -правила этой грамматики. Тогда грамматика  $G'$ , которая получается из  $G$  удалением правила  $A \rightarrow B\alpha$  и добавлением правил  $A \rightarrow \beta_1\alpha | \dots | \beta_k\alpha$ , эквивалентна  $G$ .

Множество правил, полученное описанным в этой лемме преобразованием из множества правил  $P$  грамматики  $G$ , обозначим через  $er(P, A \rightarrow B\alpha)$ .



## Алгоритм устранения левой рекурсии

*Вход.* Неукорачивающая КС-грамматика  $G = (\Sigma, \Gamma, P, A_1)$  без правил вида  $A \rightarrow A$ , где  $\Gamma = \{A_1, \dots, A_n\}$ .

*Выход.* Нелеворекурсивная КС-грамматика  $G'$ , эквивалентная  $G$ .

(Для каждого правила вида  $A_i \rightarrow A_j\alpha$  грамматики  $G'$  будет  $i < j$ .)

1.  $P' := P; \Gamma' := \Gamma; i := 1;$
2. **пока**  $i \leq n$  **повторять**
3.      $j := 1;$
4.     **пока**  $(j < i)$  **повторять**
5.         **для каждого**  $(A_i \rightarrow A_j\alpha) \in P'$  **выполнить**
6.              $P' := er(P', A_i \rightarrow A_j\alpha);$
7.          $j := j + 1;$
8.     **если**  $(\exists\beta ((A_i \rightarrow A_i\beta) \in P'))$
9.          $\Gamma' := \Gamma' \cup \{A_i'\};$
10.          $P' := eilr(P', A_i);$
11.      $i := i + 1;$
12.  $G' := (\Sigma, \Gamma', P', A_1)$

# Пример устранения левой рекурсии: начало

- Исходная грамматика:

- ▶  $A_1 \rightarrow A_2 A_3 | a,$
- ▶  $A_2 \rightarrow A_3 A_1 | A_1 b,$
- ▶  $A_3 \rightarrow A_1 A_2 | A_3 A_3 | a.$

- $i = 1$ : без изменений.

- $i = 2, j = 1$ :

- ▶  $A_1 \rightarrow A_2 A_3 | a,$
- ▶  $A_2 \rightarrow A_3 A_1 | \overline{A_1 b} | \overline{A_2 A_3 b} | ab,$
- ▶  $A_3 \rightarrow A_1 A_2 | A_3 A_3 | a.$

- $i = 2$ :

- ▶  $A_1 \rightarrow A_2 A_3 | a,$
- ▶  $A_2 \rightarrow \overline{A_3 A_1} | \overline{A_2 A_3 b} | ab \quad \overline{A_3 A_1 A'_2} | ab A'_2, \quad \overline{A'_2} \rightarrow \overline{A_3 b A'_2} | \varepsilon,$
- ▶  $A_3 \rightarrow A_1 A_2 | A_3 A_3 | a.$

## Пример устранения левой рекурсии: окончание

- $i = 3, j = 1$ :

- ▶  $A_1 \rightarrow A_2 A_3 | a,$
- ▶  $A_2 \rightarrow A_3 A_1 A'_2 | ab A'_2, \quad A'_2 \rightarrow A_3 b A'_2 | \varepsilon,$
- ▶  $A_3 \rightarrow A_1 A_2 | A_3 A_3 | a | \underline{A_2 A_3 A_2 | a A_2}.$

- $i = 3, j = 2$ :

- ▶  $A_1 \rightarrow A_2 A_3 | a,$
- ▶  $A_2 \rightarrow A_3 A_1 A'_2 | ab A'_2, \quad A'_2 \rightarrow A_3 b A'_2 | \varepsilon,$
- ▶  $A_3 \rightarrow A_3 A_3 | a | A_2 A_3 A_2 | a A_2 | \underline{A_3 A_1 A'_2 A_3 A_2 | ab A'_2 A_3 A_2}.$

- $i = 3$ :

- ▶  $A_1 \rightarrow A_2 A_3 | a,$
- ▶  $A_2 \rightarrow A_3 A_1 A'_2 | ab A'_2, \quad A'_2 \rightarrow A_3 b A'_2 | \varepsilon,$
- ▶  $A_3 \rightarrow A_3 A_3 | a | a A_2 | A_3 A_1 A'_2 A_3 A_2 | ab A'_2 A_3 A_2 | \underline{a A'_3 | a A_2 A'_3 | ab A'_2 A_3 A_2 A'_3},$   
 $\underline{A'_3 \rightarrow A_3 A'_3 | A_1 A'_2 A_3 A_2 A'_3 | \varepsilon}.$

# План

- 1 Нелеворекурсивные контекстно-свободные грамматики: повторение
- 2 Нелеворекурсивные контекстно-свободные грамматики: новый материал**
- 3 Левофакторизованные контекстно-свободные грамматики
- 4 Лексический анализ
- 5 Разделённые грамматики

# Теорема о нелеворекурсивной КС-грамматике

## Теорема

Для любой неукорачивающей КС-грамматики  $G$  без правил вида  $A \rightarrow A$  алгоритм на слайде 9 строит эквивалентную ей нелеворекурсивную КС-грамматику  $G'$ .

## Доказательство.

- По леммам на слайдах 5 и 8 грамматики  $G$  и  $G'$  эквивалентны.
- Никакой нетерминал  $A'_i$  грамматики  $G'$  не является леворекурсивным, поскольку  $A'_i$  не может быть первым символом правой части никакого правила (см. преобразования  $eilr$  и  $er$  на слайдах 5 и 8).
- Индукцией по  $i$  докажем, что после  $i$ -го исполнения тела цикла по  $i$  (рассматриваемого алгоритма) справедливо утверждение: для каждого  $k \leq i$   $A_k \rightarrow A_j \alpha \in P'$  влечёт  $k < j$ .
- База индукции ( $i = 1$ ) верна, поскольку все правила вида  $A_1 \rightarrow A_1 \beta$  устранены в строках 8–10 алгоритма.

## Теорема о нелеворекурсивной КС-грамматике: окончание доказательства

- Индукционный переход. Рассмотрим  $i$ -е исполнение тела цикла по  $i$ , предположив, что устанавливаемое утверждение верно для всех предыдущих исполнений тела этого цикла.
  - ▶ При  $j$ -м ( $j < i$ ) исполнении тела цикла по  $j$  преобразование  $er$  (см. слайд 8) заменяет каждое правило вида  $A_i \rightarrow A_j\alpha$ , на правила вида  $A_i \rightarrow \beta\alpha$ , причём если  $\beta = A_m\beta'$ , то  $A_j \rightarrow A_m\beta' \in P'$  и по индукционному предположению  $j < m$ . Следовательно, после исполнения цикла по  $j$  устранены все правила вида  $A_i \rightarrow A_j\alpha$ , где  $j < i$ .
  - ▶ Затем при исполнении строк 8–10 устраняются все правила вида  $A_i \rightarrow A_l\alpha$ , при этом не появляются правила вида  $A_k \rightarrow A_l\alpha$ , где  $l \leq k$  (см. преобразование  $eilr$  на слайде 5).
  - ▶ Таким образом, после рассматриваемого исполнения тела цикла для каждого  $k \leq i$   $A_k \rightarrow A_j\alpha \in P'$  влечёт  $k < j$ .
- Теперь видно, что никакой из нетерминалов  $A_1, \dots, A_n$  грамматики  $G'$  не является леворекурсивным, так как если существует левосторонний вывод  $A_i \Rightarrow_{G'}^+ A_m\alpha$ , то  $i < m$ .

# План

- 1 Нелеворекурсивные контекстно-свободные грамматики: повторение
- 2 Нелеворекурсивные контекстно-свободные грамматики: новый материал
- 3 Левофакторизованные контекстно-свободные грамматики**
- 4 Лексический анализ
- 5 Разделённые грамматики

# Левифакторизованные КС-грамматики: мотивировка и определение

- Рассмотрим два правила из грамматики языка программирования Паскаль:

$\langle \text{оператор} \rangle \rightarrow \text{if } \langle \text{условие} \rangle \text{ then } \langle \text{оператор} \rangle$

$\langle \text{оператор} \rangle \rightarrow \text{if } \langle \text{условие} \rangle \text{ then } \langle \text{оператор} \rangle \text{ else } \langle \text{оператор} \rangle$

Когда синтаксический анализатор доходит до `if`, ему непонятно, какое из этих правил применить.

- Заменяем эти правила на

$\langle \text{оператор} \rangle \rightarrow \text{if } \langle \text{условие} \rangle \text{ then } \langle \text{оператор} \rangle \langle \text{иначе} \rangle$

$\langle \text{иначе} \rangle \rightarrow \text{else } \langle \text{оператор} \rangle \mid \varepsilon$

- Пусть  $A \rightarrow \alpha_1 \mid \dots \mid \alpha_n$  — все  $A$ -правила КС-грамматики. Тогда каждая цепочка  $\alpha_i$  называется *альтернативой нетерминала  $A$* .
- КС-грамматика называется *левофакторизованной*, если никакой её нетерминал не имеет альтернатив с непустым общим префиксом.
- Под *левой факторизацией* КС-грамматики понимается преобразование этой КС-грамматики к эквивалентной левифакторизованной.



# Левая факторизация некоторых A-правил

## Лемма

Пусть  $G = (\Sigma, \Gamma, P, S)$  — КС-грамматика,  $A \in \Gamma$ ,  $\alpha \in (\Sigma \cup \Gamma)^+$  — максимальная по длине цепочка, с которой начинаются хотя бы две альтернативы нетерминала  $A$ ,

$$A \rightarrow \alpha\beta_1 | \dots | \alpha\beta_n \quad (n \geq 2) \quad (1)$$

— все  $A$ -правила грамматики  $G$ , правые части которых начинаются с  $\alpha$ . Тогда грамматика  $G'$ , которая получается из  $G$  добавлением нового нетерминала  $A'$  и заменой правил (1) на правила

$$A \rightarrow \alpha A', \quad A' \rightarrow \beta_1 | \dots | \beta_n, \quad (2)$$

эквивалентна грамматике  $G$ , и нетерминал  $A'$  не имеет альтернатив с непустым общим префиксом.

Множество правил, полученное заменой правил (1) на правила (2) в множестве правил  $P$ , обозначим через  $If(P, A, \alpha, A')$ .

# Алгоритм левой факторизации КС-грамматики

*Вход.* КС-грамматика  $G = (\Sigma, \Gamma, P, S)$ .

*Выход.* Левофакторизованная КС-грамматика  $G'$ , эквивалентная  $G$ .

1.  $P' := P; \Gamma' := \Gamma;$
2. для каждого  $A \in \Gamma$
3.  $M := \{\alpha \in (\Gamma' \cup \Sigma)^+ \mid \exists \beta_1, \beta_2 \in (\Gamma' \cup \Sigma)^* : \beta_1 \neq \beta_2 \wedge (A \rightarrow \alpha\beta_1 \mid \alpha\beta_2) \in P'\};$
4. если  $(M \neq \emptyset)$
5. выбрать из  $M$  цепочку  $\alpha'$  максимальной длины;
6. выбрать новый нетерминал  $A' \notin \Gamma'; \Gamma' := \Gamma' \cup \{A'\};$
7.  $P' := \text{lf}(P', A, \alpha', A');$
8. перейти на 3;
9.  $G' := (\Sigma, \Gamma', P', S)$

# Пример левой факторизации КС-грамматики

- Исходная грамматика:
  - ▶  $A \rightarrow abC|abd|aB|aC|b$ .
- $M = \{ab, a\}$ ,  $\alpha' = ab$ :
  - ▶  $A \rightarrow \underline{ab}C|abd|aB|aC|b|\underline{ab}A'$ ,
  - ▶  $\underline{A'} \rightarrow C|d$ .
- $M = \{a\}$ ,  $\alpha' = a$ :
  - ▶  $A \rightarrow aB|aC|b|ab\underline{A'}|aA''$ ,
  - ▶  $A' \rightarrow C|d$ ,
  - ▶  $\underline{A''} \rightarrow B|C|bA'$ .

# Теорема о левифакторизованной КС-грамматике

## Теорема

Для любой КС-грамматики  $G = (\Sigma, \Gamma, P, S)$  алгоритм на слайде 18 строит эквивалентную ей левифакторизованную КС-грамматику  $G' = (\Sigma, \Gamma', P', S)$ .

Доказательство.

- По лемме на слайде 17 грамматики  $G$  и  $G'$  эквивалентны, и каждый нетерминал из  $\Gamma' \setminus \Gamma$  не имеет в  $G'$  альтернатив с непустым общим префиксом.
- Для каждого нетерминала  $A \in \Gamma$  грамматики  $G'$  в результате преобразования  $If$  множество  $M$  уменьшается, поэтому за конечное число шагов  $M$  станет пустым и у нетерминала  $A$  не останется альтернатив с непустым общим префиксом.



ВТОРАЯ ЧАСТЬ КУРСА.  
СИНТАКСИЧЕСКИЙ АНАЛИЗ

# Задача синтаксического анализа

По данной КС-грамматике  $G$  и цепочке терминалов  $w$  определить,  $w \in L(G)$  или нет; а также

- если  $w \in L(G)$ , то выдать информацию о выводе этой цепочки, например, дерево вывода;
- если  $w \notin L(G)$ , то желательно указать предполагаемую ошибку (или ошибки), приводящую к факту  $w \notin L(G)$ .

# Упрощённая схема компилятора



# План

- 1 Нелеворекурсивные контекстно-свободные грамматики: повторение
- 2 Нелеворекурсивные контекстно-свободные грамматики: новый материал
- 3 Левофакторизованные контекстно-свободные грамматики
- 4 **Лексический анализ**
- 5 Разделённые грамматики



# Задача лексического анализа. Лексемы и токены

## Лексический анализатор

- читает входную цепочку (программу),
- выделяет из неё подцепочки, имеющие самостоятельное значение и называемые *лексемами*, и
- каждую лексему относит к некоторому классу лексем — *токену*.

На вход синтаксического анализатора подаётся цепочка в алфавите токенов.

## Примеры лексем

```
if a13>2300 then bc2:=84
```

Лексемы	Токены
if	ключевое слово if
a13	идентификатор id
>	операция отношения rel
2300	число num
then	ключевое слово then
bc2	идентификатор id
:=	операция присваивания assign
84	число num

## Шаблоны токенов

Токены описываются *шаблонами*, в качестве которых обычно выступают (расширенные) регулярные выражения.

- Для записи альтернатив, являющихся символами общеизвестного алфавита, используют дефис, например, вместо  $a|b|\dots|z|0|1|\dots|9$  пишут  $a - z|0 - 9$ .
- Вместо  $rr^*$  пишут  $r^+$ .
- Вместо  $r|\varepsilon$  пишут  $r?$ .

Шаблон токена `id`:

$$\langle \text{имя} \rangle = a - z(a - z|0 - 9)^*$$

Шаблон токена `num`:

$$\langle \text{число} \rangle = (+|-)?(0 - 9)^+(\.(0 - 9)^+)?(E(+|-)?(0 - 9)^+)?$$

## Шаблоны токенов с примерами лексем

Токен	Примеры лексем	Шаблон
if	if	if
id	a, bc2, sum	$\langle \text{имя} \rangle$
rel	=, <, >=	$=   <   >   <=   >=$
aop	+, -	$+   -$
mop	*, /	$*   /$
num	84, +9.72, -43.6E50	$\langle \text{число} \rangle$
then	then	then
assign	:=	:=
comma	,	,

## Атрибуты токена. Регистрация токена


- Лексемы одного класса (например, идентификаторы) можно не различать на фазе синтаксического анализа, но их потребуется различать на следующих фазах компиляции.
- Если токен — это класс, состоящий из более чем одной лексемы, то информация о конкретной лексеме сохраняется в виде *атрибутов* токена.
- Обычно у токена нет атрибутов или один атрибут — указатель на запись в таблице символов.

```
if  id  rel  num  then  id  assign  num
   ↓   ↓   ↓           ↓           ↓
  ptr1 ptr2 ptr3      ptr4      ptr5
```

- Процесс занесения информации о лексеме в таблицу символов с последующим выводом пары (токен, атрибут) на выход лексического анализатора называют *регистрацией токена*.

## Организация ввода


- Естественно требовать однократности от лексического анализатора.
- Вместо посимвольного чтения программы эффективнее зачитывать блок программы в буфер, причём удобно использовать два буфера.
- Один указатель адресует первый символ текущей лексемы, а другой — обрабатываемый символ. Распознанная лексема будет находиться между этими указателями.



# Распознавание лексем

- Неоднозначности при распознавании лексем обычно разрешаются с помощью *принципа наидлиннейшей лексемы*: среди всех лексем, начинающихся с данной позиции, выбирается самая длинная.
- Можно использовать конечный автомат, распознающий шаблоны всех токенов. Каждому заключительному состоянию такого автомата однозначно соответствует токен, и с этим состоянием связана функция регистрации токена.
- Можно построить конечные автоматы для каждого шаблона в отдельности, затем соединить их в один  $\varepsilon$ -НКА и найти для этого  $\varepsilon$ -НКА эквивалентный ДКА с минимальным числом состояний (см. лекции 1 и 2).

# Автомат для шаблона rel




Функция регистрации токена REG- применяется, если последний прочитанный символ не принадлежит распознанной лексеме.

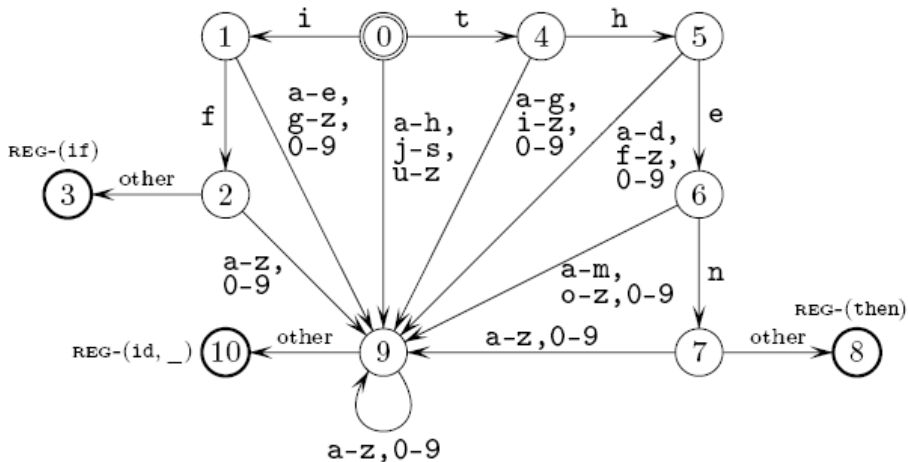
Функция регистрации токена REG применяется, если последний прочитанный символ принадлежит распознанной лексеме.



# Автомат для шаблона num



# Автомат для шаблонов if, then, id



Не изображены дуги из вершин 1, 4, 5, 6 в вершину 10 с меткой other.

# План

- 1 Нелеворекурсивные контекстно-свободные грамматики: повторение
- 2 Нелеворекурсивные контекстно-свободные грамматики: новый материал
- 3 Левофакторизованные контекстно-свободные грамматики
- 4 Лексический анализ
- 5 Разделённые грамматики

# Нисходящий анализ. Пример 1

- Синтаксический анализ называется *нисходящим анализом* (*анализом сверху вниз*), если дерево вывода анализируемой цепочки строится сверху (от корня) вниз.
- Далее все рассматриваемые выводы являются левосторонними, если иное не будет оговорено.
- Рассмотрим грамматику  $G_1$ :
  - ▶  $S \rightarrow aDS \mid bDc$ ,
  - ▶  $D \rightarrow aD \mid cc$ .
- Проверим,  $aaccbccc \in L(G_1)$  или нет. Предположим, что  $S \Rightarrow^* aaccbccc$ . Тогда

$$S \Rightarrow a \underbrace{DS}_{accbccc} \Rightarrow aa \underbrace{DS}_{ccbccc} \Rightarrow aacc \underbrace{S}_{bccc} \Rightarrow aaccb \underbrace{Dc}_{ccc} \Rightarrow aaccbccc.$$

Итак,  $aaccbccc \in L(G_1)$ .

## Нисходящий анализ. Пример 2.

### Определение разделённой грамматики

- Рассматриваем грамматику  $G_1$ :
  - ▶  $S \rightarrow aDS \mid bDc$ ,
  - ▶  $D \rightarrow aD \mid cc$ .
- Проверим,  $baabcc \in L(G_1)$  или нет. Предположим, что  $S \Rightarrow^* baabcc$ . Тогда

$$S \Rightarrow b \underbrace{Dc}_{aabcc} \Rightarrow ba \underbrace{Dc}_{abcc} \Rightarrow baa \underbrace{Dc}_{bcc} \Rightarrow ?!$$

Таким образом,  $baabcc \notin L(G_1)$ .

- КС-грамматика называется *разделённой*, если
  - ▶ правая часть каждого правила вывода начинается с терминала, и
  - ▶ для каждого нетерминала все его альтернативы начинаются с разных терминалов.

# Алгоритм построения распознающего МПА для разделённой грамматики

По умолчанию под МПА будем понимать ДМПА, который имеет единственное состояние и команду допуска. Такой МПА задаётся четвёркой  $(\hat{\Sigma}, \hat{\Gamma}, \delta, \gamma_0)$ , состоящей из входного алфавита  $\hat{\Sigma}$ , стекового алфавита  $\hat{\Gamma}$ , множества команд  $\delta$  и начального содержимого стека  $\gamma_0$ .

*Вход.* Разделённая грамматика  $G = (\Sigma, \Gamma, P, S)$ .

*Выход.* МПА  $\mathcal{M} = (\hat{\Sigma}, \hat{\Gamma}, \delta, \gamma_0)$  такой, что  $L(G) = L(\mathcal{M})$ .

1.  $\hat{\Sigma} := \Sigma \cup \{\vdash\}$ ;  $\hat{\Gamma} := \Sigma \cup \Gamma \cup \{\nabla\}$ ;  $\gamma_0 := S$ ;
2.  $\delta := \{(\vdash, \nabla) \rightarrow \checkmark\}$ ;
3. для каждого  $(B \rightarrow a\gamma) \in P$
4.  $\delta := \delta \cup \{(a, B) \rightarrow (a\gamma, \_)\}$ ;
5. для каждого  $a \in \Sigma$
6.  $\delta := \delta \cup \{(a, a) \rightarrow (\varepsilon, \rhd)\}$

# Пример построения распознающего МПА для разделённой грамматики

Грамматика  $G_1$ :

- $S \rightarrow aDS \mid bDc$ ,
- $D \rightarrow aD \mid cc$ .

Управляющая таблица распознающего МПА для  $G_1$  и её оптимизированный вариант:

	a	b	c	⊥
S	aDS	bDc		
D	aD		cc	
a	$\varepsilon, \rightarrow$			
b		$\varepsilon, \rightarrow$		
c			$\varepsilon, \rightarrow$	
∇				✓

	a	b	c	⊥
S	$DS, \rightarrow$	$Dc, \rightarrow$		
D	$D, \rightarrow$		$c, \rightarrow$	
c			$\varepsilon, \rightarrow$	
∇				✓

## Протокол обработки цепочки оптимизированным МПА для разделённой грамматики

Такт	Позиция указателя	Содержимое стека
1	$\diamond$ аaccbccc $\vdash$	$S\bar{\nabla}$
2	а $\diamond$ accbccc $\vdash$	$DS\bar{\nabla}$
3	аа $\diamond$ ccbccc $\vdash$	$DS\bar{\nabla}$
4	аас $\diamond$ cbccc $\vdash$	$cS\bar{\nabla}$
5	аacc $\diamond$ bccc $\vdash$	$S\bar{\nabla}$
6	аaccb $\diamond$ ccc $\vdash$	$Dc\bar{\nabla}$
7	аaccbc $\diamond$ cc $\vdash$	$cc\bar{\nabla}$
8	аaccbcc $\diamond$ c $\vdash$	$c\bar{\nabla}$
9	аaccbccc $\diamond$ $\vdash$	$\bar{\nabla}$

Последовательность (с удалёнными подряд идущими дубликатами) конкатенаций прочитанного префикса входной цепочки и содержимого стека (без  $\bar{\nabla}$ ) есть левый вывод входной цепочки в грамматике  $G_1$ :

$S, aDS, aaDS, aaccS, aaccS, aaccbDc, aaccbccc, aaccbccc, aaccbccc.$



# Литература

## Основная литература

- Замятин А. П., Шур А. М. Языки, грамматики, распознаватели: Учебное пособие. Екатеринбург : Изд-во Урал. ун-та, 2007 (электронный вариант книги — на <http://elar.usu.ru>, поиск).

## Дополнительная литература

- Ахо А., Лам М., Сети Р., Ульман Дж. Компиляторы: принципы, технологии и инструментарий. М.: ООО "И.Д. Вильямс", 2008.
- Ахо А., Ульман Дж. Теория синтаксического анализа, перевода и компиляции. М.: Мир, 1978.
- Мартыненко Б. К. Языки и трансляции: Учеб. пособие. СПб.: Издательство С.-Петербургского университета, 2004 (электронный вариант книги — на <http://www.math.spbu.ru/user/mbk>).