# 7. Восходящие анализаторы

- Восходящие анализаторы. LR (k)-анализаторы
- Построение LR (0)-анализатора
- LR (1)-анализатор. LALR-анализаторы
- Неоднозначные грамматики. Различные типы конфликтов
- Разрешение конфликтов

**Лекция 7. Восходящие анализаторы**

В этой лекции рассматриваются следующие вопросы:

- Восходящие анализаторы
- LR(k)-анализаторы
- Построение LR(0)-анализатора
- LR(1)-анализатор. LALR-анализаторы
- Неоднозначные грамматики. Различные типы конфликтов
- Разрешение конфликтов

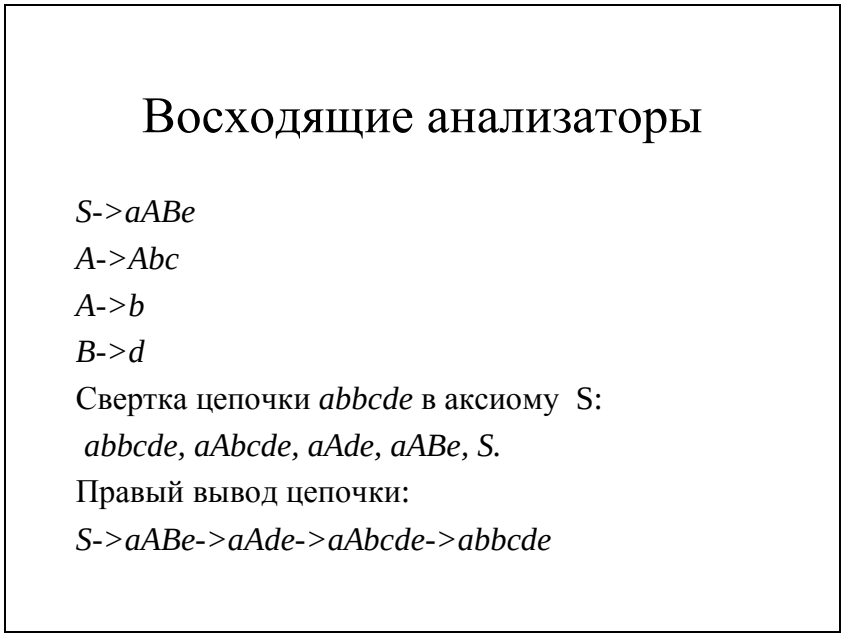


**Восходящие анализаторы**

*Восходящий анализатор (bottom-up parsing)* предназначен для построения дерева разбора, начиная с листьев и двигаясь вверх к корню дерева разбора. Мы можем представить себе этот процесс как "свертку" исходной строки *w* к аксиоме грамматики. Каждый шаг свертки заключается в сопоставлении некоторой подстроки *w* и правой части какого-то правила грамматики и замене этой подстроки на нетерминал, являющийся левой частью правила. Если на каждом шаге подстрока выбирается правильно, то в результате мы получим правый вывод строки *w*.

**Пример.** Рассмотрим грамматику
*S→aABe*
*A→Abc*
*A→b*
*B→d*

Цепочка *abbcde* может быть свернута в аксиому следующим образом:
*abbcde, aAbcde, aAde, aABe, S.*
Фактически, эта последовательность представляет собой правый вывод этой цепочки, рассматриваемый справа налево:
*S→aABe→aAde→aAbcde→abbcde.*

# LR(k)-анализатор

LR(k) означает, что

- входная цепочка обрабатывается слева направо
- выполняется правый вывод
- не более k символов цепочки используются для принятия решения

**LR(k)-анализатор**

LR(k) означает, что
- входная цепочка обрабатывается слева направо (left-to-right parse);
- выполняется правый вывод (rightmost derivation);
- не более k символов цепочки (k-token lookahead) используются для принятия решения.

При LR(k)-анализе применяется *метод "перенос-свертка" (shift-reduce)*. Этот метод использует магазинный автомат. Суть метода сводится к следующему. Символы входной цепочки переносятся в магазин до тех пор, пока на вершине магазина не накопится цепочка, совпадающая с правой частью какого-нибудь из правил (операция "перенос", "*shift*"). Далее все символы этой цепочки извлекаются из магазина и на их место помещается нетерминал, находящийся в левой части этого правила (операция "свертка", "*reduce*"). Входная цепочка допускается автоматом, если после переноса в автомат последнего символа входной цепочки и выполнения операции свертка, в магазине окажется только аксиома грамматики.

Анализатор состоит из входной цепочки, выхода, магазина, управляющей программы и таблицы, которая имеет две части (действие и переход). Схема такого анализатора выглядит следующим образом:

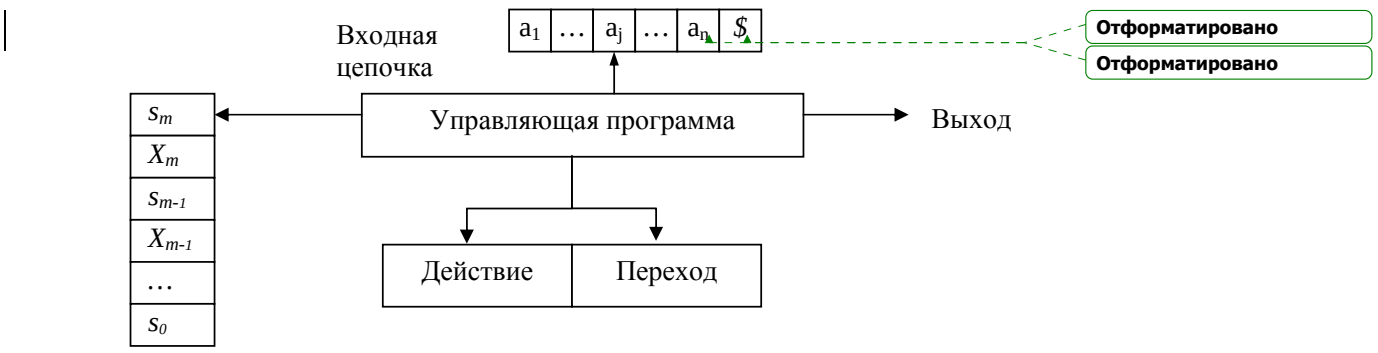

# Управляющая программа анализатора

- Управляющая программа одинакова для всех LR-анализаторов
- Рассматривается пара: $s_m$ – текущее состояние на вершине магазина, $a_i$ – текущий входной символ; после этого вычисляется action [$s_m$, $a_i$]:
  1. shift s, где s – состояние,
  2. свертка по правилу A–>β,
  3. допуск (accept)
  4. ошибка.

**Управляющая программа анализатора**

Управляющая программа одинакова для всех LR-анализаторов, а таблица изменяется от одного анализатора к другому. Программа анализатора читает последовательно символы входной цепочки. Программа использует магазин для запоминания строки следующего вида $s_0X_1s_1X_2\ldots X_ms_m$, где $s_m$ – вершина магазина. Каждый $X_i$ – символ грамматики, а $s_i$ – символ, называемый состоянием. Каждое состояние суммирует информацию, содержащуюся в стеке перед ним. Комбинация символа состояния на вершине магазина и текущего входного символа используется для индексирования управляющей таблицы и определения операции переноса-свертки. При реализации грамматические символы не обязательно располагаются в магазине; однако, мы будем использовать их при обсуждении для лучшего понимания поведения LR-анализатора.

Программа, управляющая LR-анализатором, ведет себя следующим образом. Рассматривается пара: $s_m$ – текущее состояние на вершине магазина, $a_i$ – текущий входной символ; после этого вычисляется action [$s_m$, $a_i$], которое может иметь одно из четырех значений:

1. shift *s*, где *s* – состояние,
2. свертка по правилу $A \rightarrow \beta$,
3. допуск (*accept*)
4. ошибка.

Функция **goto** получает состояние и символ грамматики и выдает состояние. Функция goto, строящаяся по грамматике G, есть функция переходов детерминированного магазинного автомата, который распознает язык, порождаемый грамматикой G.

Управляющая программа выглядит следующим образом:

```
Установить ip на первый символ входной цепочки w$;
while (цепочка не закончилась)
{
   Пусть s – состояние на вершине магазина,
   a – символ входной цепочки, на который указывает ip.
   if (action [s, a] == shift s')
   {
      push (a);
      push (s');
      ip++;
   }
   else if (action [s, a] == reduce A→β)
   {
      for (i=1; i<=|β|;  i++)
      {
         pop ();
         pop ();
      }
      Пусть s' – состояние на вершине магазина;
      push (A);
      push (goto [s', A]);
      Вывод правила (A→β);
   }
   else if (action [s, a] == accept)
   {
      return success;
   }
   else
   {
      error ();
   }
}
```

# Управляющая таблица LR(0)-анализатора

- LR(k)-анализатор использует содержимое магазина и очередные k символов входной цепочки для принятия решения о том, какие действия он должен выполнить.
- LR(0)-анализатор использует только содержимое магазина.

### Управляющая таблица LR(0)-анализатора

Обсудим подробно алгоритм построения управляющей таблицы на примере LR(0)-анализаторов.

Заметим, что LR(0)-анализатор принимает решение о своих действиях только на основании содержимого магазина, не учитывая символы входной цепочки. Для иллюстрации построения таблиц LR(0)-анализатора мы будем использовать грамматику $G_0$:

(1) $S \rightarrow (L)$
(2) $S \rightarrow x$
(3) $L \rightarrow S$
(4) $L \rightarrow L, S$

**Определение.** Пусть G = ($V_T$, $V_N$, P, S) – КС-грамматика. *Пополненной грамматикой* (augmented grammar) будем называть грамматику G' = ($V_T$, $V_N$+{S'}, P+{$S' \rightarrow S$}, S'), где $S'$ – нетерминал, непринадлежащий множеству N.

**Определение.** Пусть G = ($V_T$, $V_N$, P, S) – КС-грамматика. Будем называть *[$A \rightarrow w_1.w_2$,, u] LR(k)-ситуацией (LR(k)-item)*, если $A \rightarrow w_1w_2$ является правилом из P и *u* – цепочка терминалов, длина которой не превосходит *k*.

Понятно, что LR(0)-ситуации не должны содержать терминальной цепочки, то есть мы можем записывать их следующим образом: [$A \rightarrow w_1.w_2$].

Далее мы рассмотрим поведение анализатора грамматики при разборе входной цепочки.

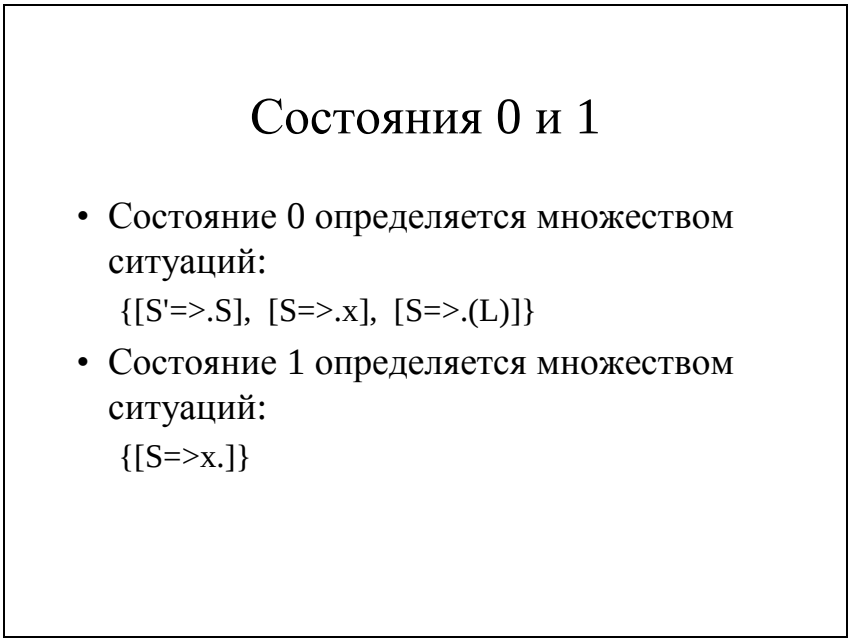


**Состояния 0 и 1**

В начале работы магазин пуст (на самом деле, на вершине магазина находится маркер конца *$*), и указатель входной цепочки находится перед ее первым символом. Этому состоянию соответствует ситуация [*S'→.S*].

Значит, входная цепочка может начинаться с любого терминального символа, с которого начинается правая часть любого правила с левой частью *S*. Мы укажем это следующим образом:

*[S'→.S]*
*[S→.x]*
*[S→.(L)]*

Состояние автомата определяется множеством ситуаций. Назовем это состояние 0.

Теперь мы должны выяснить, что произойдет, если анализатор выполнит перенос или свертку. Предположим, что мы выполним перенос *x* (то есть на вершине магазина окажется *x*). Этому случаю соответствует ситуация [*S→x.*]. Понятно, что правила *S'→S* и *S→(L)* не могут быть применены, поэтому мы их игнорируем. Таким образом, новое состояние, в которое автомат перейдет после переноса в магазин символа *x*, определяется ситуацией

*[S→x.]*

Это состояние назовем 1.

# Состояния 2 и 3

- Состояние 2 определяется множеством ситуаций:
  {[S=>(.L)], [L=>.L,S], [L=>.S], [S=>.(L)], [S=>.x]}
- В состояние 3 переход происходит из состояния 0 по нетерминалу S.

**Состояния 2 и 3**

Теперь предположим, что выполнен перенос открывающей круглой скобки. Этому случаю соответствует ситуация [*S→(.L)*]. То есть на вершине магазина окажется открывающая круглая скобка, а входная цепочка должна начинаться с некоторой цепочки, которая выводится из *L* и перед которой находится открывающая круглая скобка. Таким образом, к нашей ситуации мы должны добавить все ситуации, получающиеся из правил, левая часть которых суть нетерминал *L*, т.е. [*L→.L,S*] и [*L→.S*]. Помимо этого, поскольку правая часть правила *L→S* начинается нетерминалом *S*, мы должны добавить все ситуации, получающиеся из правил, левая часть которых суть нетерминал *S*, т.е. [*S→.L*] и [*S→.x*]. Таким образом, новое состояние, в которое автомат перейдет после переноса в магазин открывающей круглой скобки, определяется ситуациями:

*[S→(.L)]*
*[L→.L, S]*
*[L→.S]*
*[S→.(L)]*
*[S→.x]*

Это состояние 2. Мы можем изобразить часть первой строки таблицы переходов автомата:

| | ( | ) | *x* | , | *$* |
|---|---|---|---|---|---|
| ⋮ | | | | | |
| 0 | $s_3$ | | $s_2$ | | |

Понятно, что в состоянии 0 свертка выполняться не может.

Обсудим, что произойдет, если в состоянии 0 мы оказались после анализа некоторой цепочки, которая выводится из аксиомы грамматики. Это может случиться, если после переноса *x* или открывающей круглой скобки произошла свертка по правилу, левая часть которого – *S*. Все символы правой части такого правила будут извлечены из магазина, и анализатор будет выполнять переход для символа S в состоянии 0. Этому случаю соответствует ситуация [*S'→S.$*], определяющая состояние 3.

# Базовые операции

- Для построения множества состояний автомата необходимы две базовые операции closure (I) и goto (I, X).

### Базовые операции

В ситуации [*S*→*x.*], определяющей состояние 1, точка стоит в конце правой части правила. Это означает, что вершина магазина, на которой сформирована правая часть правила *S*→*x*, готова к свертке. В таком состоянии анализатор выполняет свертку.

Для построения множества состояний определим базовые операции *closure* (I) и *goto* (*I*, *X*), где *I* – множество ситуаций, *X* – символ грамматики (терминал или нетерминал). Операция closure добавляет ситуации к множеству ситуаций, у которых точка стоит слева от нетерминала. Добавляются те ситуации, которые получаются из правил, в левой части которого находится этот нетерминал.

```
closure (I)
{
   do {
      for (каждой ситуации [A->w.Xv] из I) {
         for (каждого правила грамматики X->u) {
            I+=[X->.u];     /* Операция += добавляет элемент к множеству */
         }
      }
   } while (I изменилось);
   return I;
}
```

Операция goto "переносит" точку после символа X. Это означает переход из одного состояния в другое под воздействием символа X.

```
goto (I, X)
{
   J={};       /* {} обозначает пустое множество */
   for (каждой ситуации [A->w.Xv] из I) {
      J+=[A->wX.v];
   }
   return closure (J);
}
```

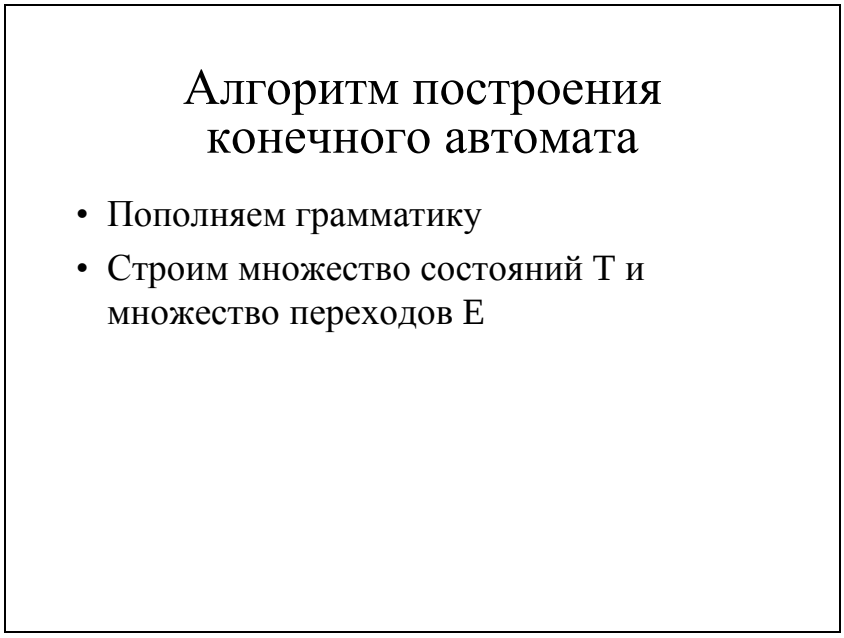


**Алгоритм построения конечного автомата**

Теперь обсудим алгоритм построения анализатора. Во-первых, пополним грамматику. Обозначим T множество состояний, E – множество переходов.

```
T = {closure ([S'->.S])};
E = {};
do
{
   for (каждого состояния I из T)
   {
      for (каждой ситуации [A->w.Xv] из  I)
      {
         J = goto (I, X);
         T+={J};      /* ко множеству состояний добавляется новое состояние */
         E+=(I->J);   /* ко множеству ребер добавляется ребро, идущее из
                         состояния I в состояние J. Этот переход
                         осуществляется по символу X */
      }
   }
} while (E или T изменились);
```

Поскольку для символа *$* операция goto (*I*, *$*) не определена, мы выполняем действие accept.

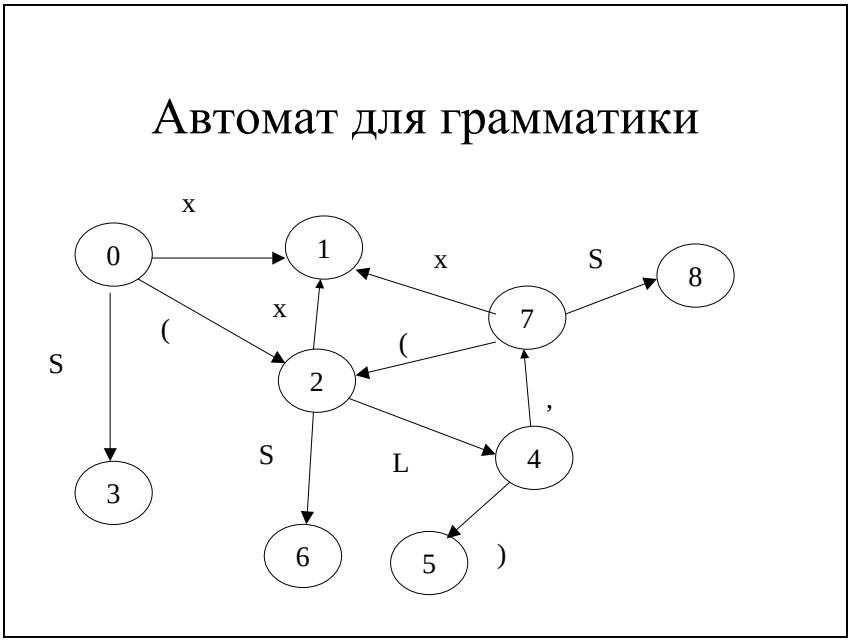


**Автомат для грамматики**

Для определенной нами грамматики автомат получится следующим:

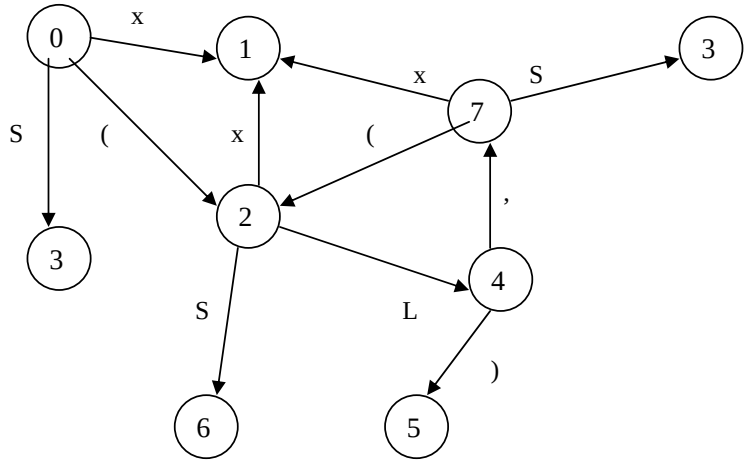


где состояния определяются следующим образом:
0: {[S'.S], [S→.x], [S→.(L)]}
1: {[S→x.]}
2: {[S→ (.L)], [L→.L,S], [L→.S], [S→.(L)], [S→.x]}
3: {[S'→S.]
4: {[S→ (L.)], [L→L., S]}
5: {[S→ (L).]}
6: {[L→S.]}
7: {[L→L,.S], [S→.(L)], [S→.x]}
8: {[L→L,S.]}

# Управляющая таблица

| | ( | ) | x | , | $ | S | L |
|---|---|---|---|---|---|---|---|
| 0 | s2 | | s1 | | | 3 | |
| 1 | r2 | r2 | r2 | r2 | r2 | | |
| 2 | s2 | | s1 | | | 6 | 4 |
| 3 | | | | | acc | | |
| 4 | | s5 | | s7 | | | |
| 5 | r1 | r1 | r1 | r1 | r1 | | |
| 6 | r3 | r3 | r3 | r3 | r3 | | |
| 7 | s2 | | s1 | | | 8 | |
| 8 | r4 | r4 | r4 | r4 | r4 | | |

**Управляющая таблица**

Теперь мы можем вычислить множество сверток R:

```
R = empty set;
for (each state I in T)
{
   for (each item [A->w.] in I)
   {
      R+={(I, A->w)};
   }
}
```

Таким образом, алгоритм построения управляющей таблицы автомата состоит из следующих шагов:

- Пополнение грамматики
- Построение множества состояний
- Построение множества переходов
- Построение множества сверток

Для того, чтобы построить таблицу анализатора для грамматики, поступим следующим образом:

1. для каждого ребра $I \rightarrow^{X} J$ мы поместим в позицию [*I*, *X*] таблицы
   - shift *J*, если *X* – терминал,
   - goto *J*, если *X* – нетерминал.
2. для каждого состояния *I*, содержащего ситуацию [*S'*→*S.*] мы поместим accept в позицию [*I*,*$*]
3. для состояния, содержащего ситуацию [*A*→*w.*] (правило номер *n* с точкой в конце правила), поместим reduce n в позицию [*I*, *Y*] для каждого терминала *Y*.
4. пустая ячейка означает ошибочную ситуацию

Приведем управляющую таблицу для грамматики $G_0$:

| | ( | ) | x | , | $ | S | L |
|---|---|---|---|---|---|---|---|
| 0 | s2 | | s2 | | | 3 | |
| 1 | r2 | r2 | r2 | r2 | r2 | | |
| 2 | s2 | | s1 | | | 6 | 4 |
| 3 | | | | | acc | | |
| 4 | | s5 | | s7 | | | |
| 5 | r1 | r1 | r1 | r1 | r1 | | |
| 6 | r3 | r3 | r3 | r3 | r3 | | |
| 7 | s3 | | s2 | | | 8 | |
| 8 | r4 | r4 | r4 | r4 | r4 | | |

# LR(1)-анализатор

- LR(1)-анализатор мощнее, чем LR(0)-анализатор
- Для построения управляющей таблицы такого анализатора мы должны модифицировать базовые процедуры closure и goto

### LR(1)-анализатор

LR(1)-анализатор использует для принятия решения один символ входной цепочки. Алгоритм построения управляющей таблицы LR(1)-анализатора подобен уже рассмотренному алгоритму для LR (0)-анализатора, но понятие ситуации в LR(1)-анализаторе более сложное: LR(1)-ситуация состоит из правила грамматики, позиции правой части (представляемой точкой) и одного символа входной строки *(lookahead symbol)*. LR(1)-ситуация выглядит следующим образом: [$A \rightarrow w_1 \ . \ w_2 \ , \ a$], где $a$ – терминальный символ. Ситуация [$A \rightarrow w_1 \ . w_2, \ a$] означает, что цепочка $w_1$ находится на вершине магазина, и префикс входной цепочки выводим из цепочки $w_2 \ x$. Как и прежде, состояние автомата определяется множеством ситуаций. Для построения управляющей таблицы необходимо переопределить базовые операции closure и goto.

```
closure (I) {
   do {
      I_old=I;
      for (каждой ситуации [A->w1.Xw2, z] из I)
         for (любого правила X->u)
            for (любой цепочки w, принадлежащей FIRST (w2 z))
               I+=[X->.u, w];
   } while (I != I_old );
   return I;
}
goto (I, X) {
   J = {};
   for (каждой ситуации [A->w1 .Xw2 , z] из I)
      J+=[A->w1 X.w2 , z];
   return closure (J);
}
```

Естественно, операция reduce также зависит от символа входной цепочки:

```
R=[]
foreach (I из T)
   foreach ([A->w., z] из I)
      R+={(I, z, A->w)}
```

Тройка ($I$, $z$, $A \rightarrow w$) означает, что в состоянии $I$ для символа $z$ входной цепочки анализатор будет осуществлять свертку по правилу $A \rightarrow w$.

# Управляющая таблица LR(1)-анализатора

Построим управляющую таблицу анализатора для следующей грамматики:

E –> E+T

E –> T

T –> T*F

T –> F

F –> (E)

F –> id

**Управляющая таблица LR(1)-анализатора**

***Пример.*** Рассмотрим грамматику:

*(1) E→T*
*(2) E→T*
*(3) T→T*F*
*(4) T→F*
*(5) F→ (E)*
*(6) F→id*

Управляющая таблица для такой грамматики выглядит следующим образом:

| **Состо-** | **action** | | | | | | | **goto** | | |
|---|---|---|---|---|---|---|---|---|---|---|
| **яние** | *id* | + | * | *(* | *)* | *$* | E | | T | F |
| 0 | *s5* | | | *s4* | | | | 1 | 2 | 3 |
| 1 | | s6 | | | | accept | | | | |
| 2 | | r2 | s7 | | r2 | r2 | | | | |
| 3 | | r4 | r4 | | r4 | r4 | | | | |
| 4 | S5 | | | s4 | | | | 8 | 2 | 3 |
| 5 | | r6 | r6 | | r6 | r6 | | | | |
| 6 | *s5* | | | *s4* | | | | | 9 | 3 |
| 7 | *s5* | | | *s4* | | | | | | 10 |
| 8 | | s6 | | | s11 | | | | | |
| 9 | | r1 | s7 | | r1 | r1 | | | | |
| 10 | | r3 | r3 | | r3 | r3 | | | | |
| 11 | | r5 | r5 | | r5 | r5 | | | | |

Как обычно,
si – перенос и переход в состояние i
ri – свертка по правилу i
i – переход в состояние i

# LALR(1)-анализатор

- Таблицы LR(1)-анализатора могут быть очень большими
- Таблицы LALR(1)-анализатора получаются из таблиц LR(1)-анализатора слиянием "эквивалентных" состояний в одно

### LALR(1)-анализатор

Таблицы LR(1)-анализатора могут оказаться очень большими, ведь даже маленькая грамматика нашего примера привела к автомату с двенадцатью состояниями. Таблицы меньшего размера можно получить путем слияния любых двух состояний, которые совпадают с точностью до символов входной строки (lookahead symbols).

**Пример.** Рассмотрим грамматику $G_1$ с правилами:

S → AA
A → aA
A → b

Пополним эту грамматику правилом S' → S.
Для этой грамматики мы получим следующие состояния:

0: {*[S'→.S, $], [S→.AA, $], [A→.aA, a], [A→.aA, b], [A→.b, a], [A→.b, b]*}
1: {*[S'→S., $]*}
2: {*[S'→A.A, $], A→.aA, $], [A→.b, $]*}
3: {*[A→a.A, a], [A→a.A, b], [A→.a.A, a], [A→.a.A, b], [A→.b, a], [A→.b, b]*}
4: {*[A→b., a], [A→b., b]*}
5: {*[S→AA. $]*}
6: {*[A→a.A, $], [A→.aA, $], [A→.b, $]*}
7: {*[A→b., $]*}
8: {*[A→aA.,a], [A→aA.,b]*}
9: {*[A→aA.,$]*}

Граф переходов выглядит так:

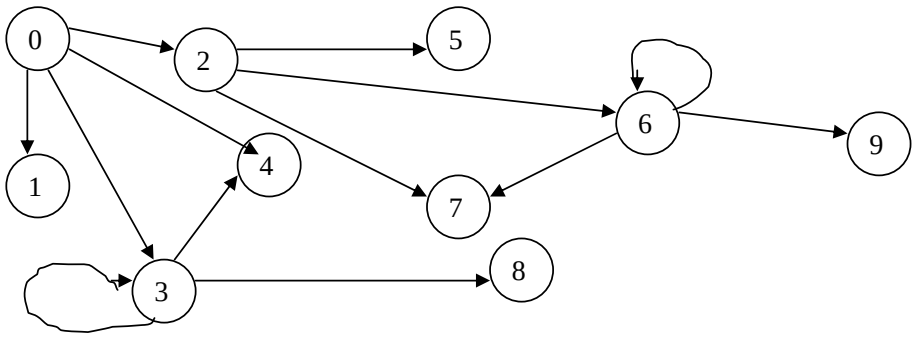

# Таблица LALR-анализатора для грамматики $G_1$

| | a | b | $ | S | A |
|---|---|---|---|---|---|
| 0 | s36 | s47 | | 1 | 2 |
| 1 | | | acc | | |
| 2 | s36 | s47 | | | 5 |
| 36 | s36 | s47 | | | 89 |
| 47 | r3 | r3 | r3 | | |
| 5 | | | r1 | | |
| 89 | r2 | r2 | r2 | | |

**Таблица LALR-анализатора для грамматики $G_1$**

Теперь можно построить таблицу LR-анализатора:

| **State** | **action** | | | **goto** | |
|---|---|---|---|---|---|
| | *a* | *b* | *$* | S | A |
| 0 | *s3* | *s4* | | 1 | 2 |
| 1 | | | accept | | |
| 2 | s6 | s7 | | 5 | |
| 3 | s3 | s4 | | 8 | |
| 4 | r3 | r3 | | | |
| 5 | | | r1 | | |
| 6 | s6 | s7 | | 9 | |
| 8 | r2 | r2 | | | |
| 9 | | | r2 | | |

Нетрудно заметить, что пары состояний 3 и 6, 4 и 7, 8 и 9 различаются только вторыми компонентами, определяющих их ситуаций. Поэтому мы можем «склеить» эти пары. В результате получится таблица LALR-анализатора:

| **State** | **action** | | | **goto** | |
|---|---|---|---|---|---|
| | *a* | *b* | *$* | S | A |
| 0 | *s36* | *s47* | | 1 | 2 |
| 1 | | | accept | | |
| 2 | s36 | s47 | | 5 | |
| 36 | s36 | s47 | | 89 | |
| 47 | r3 | r3 | r3 | | |
| 5 | | | r1 | | |
| 89 | r2 | r2 | r2 | | |


**Пример LR(1)-грамматики**

Таким образом, LALR анализатор имеет значительное преимущество в размере таблиц по сравнению с LR. Однако, существуют грамматики, которые можно обработать LR анализатором, но нельзя LALR анализатором. LALR анализатор будет считать их неоднозначными, а LR анализатор не будет.

**Пример.** Грамматика

S → aAd
S → bBd
S → aBe
S → bAe
A → c
B → c

не является LALR грамматикой, поскольку для входной цепочки *ac* мы можем выполнить свертку либо по правилу A → c (если текущий входной символ d) либо по правилу B → c (если текущий входной символ e).

Однако на практике большинство таких неоднозначностей можно устранить. Перейдем к рассмотрению различных возможных неоднозначностей и методов их устранения.

# Неоднозначные грамматики. Конфликты «перенос-свертка»

- S –> if E then S | if E then S else S | other

  Подобные конфликты могут быть решены путем трансформации грамматики с следующему виду:
- S –> M | U
- M –> if E then M else M | other
- U –> if E then S | if E then M else U

**Неоднозначные грамматики. Конфликты «перенос-свертка»**

Вопрос неоднозначности становится особенно важеным в процессе построения управляющей таблицы анализатора LR(k)-языка, так как неоднозначность грамматики приводит к конфликтам при построении таблицы.

Рассмотрим сначала конфликты типа перенос-свертка (*shift/reduce)*. Конфликты данного типа возникают, когда в процессе работы анализатора возникает выбор между переносом текущего символа на вершину стека и сверткой последовательности, расположенной на вершине стека.

**Пример.** Пусть дана грамматика $G_1$, имеющая следующий набор правил:

(1) *stmt* → ***if*** *expr* ***then*** *stmt*
(2) *stmt* → ***if*** *expr* ***then*** *stmt* ***else*** *stmt*
(3) *stmt* → *other*

, где *other* мы используем для обозначения других операторов.

На следующем слайде рассмотрим, что происходит при анализе следующей входной цепочки:
*if* $E_1$ *then if* $E_2$ *then* $S_1$ *else* $S_2$.

# Пример конфликта «перенос-свертка»

- Рассмотрим следующую входную последовательность:
  *if* $E_1$ *then if* $E_2$ *then* $S_1$ *else* $S_2$
- Во время анализа возникнет неоднозначность; обычно ее разрешают путем введения дополнительных соглашений о принадлежности ветки else
- Грамматику можно преобразовать к эквивалентной форме без конфликта "перенос/свертка"

**Пример конфликта перенос-свертка**

Итак, имеется следующая входная цепочка: ***if*** $E_1$ ***then if*** $E_2$ ***then*** $S_1$ ***else*** $S_2$. Рассмотрим работу анализатора пошагово:

| Содержимое стека | Необработанная часть входной цепочки | Действие |
|---|---|---|
| *$* | ***if*** $E_1$ ***then if*** $E_2$ ***then*** $S_1$ ***else*** $S_2$ | *shift* |
| *$**if*** | $E_1$ ***then if*** $E_2$ ***then*** $S_1$ ***else*** $S_2$ | *shift* |
| *$* ***if*** $E_1$ | ***then if*** $E_2$ ***then*** $S_1$ ***else*** $S_2$ | *shift* |
| *$* ***if*** $E_1$ ***then*** | ***if*** $E_2$ ***then*** $S_1$ ***else*** $S_2$ | *shift* |
| *$* ***if*** $E_1$ ***then if*** | $E_2$ ***then*** $S_1$ ***else*** $S_2$ | *shift* |
| *$* ***if*** $E_1$ ***then if*** $E_2$ | ***then*** $S_1$ ***else*** $S_2$ | *shift* |
| *$* ***if*** $E_1$ ***then if*** $E_2$ ***then*** | $S_1$ ***else*** $S_2$ | *shift* |
| *$* ***if*** $E_1$ ***then if*** $E_2$ ***then*** $S_1$ | ***else*** $S_2$ | *shift* |

После последнего шага возникают две альтернативы: либо (а) применить свертку по правилу 1 к последовательности ***if*** $E_2$ ***then*** $S_1$ на вершине стека, либо (б) перенести символ ***else*** на вершину стека. Обе альтернативы легко угадываются из вида правил 1 и2. Грамматики с правилами такого типа называются грамматиками с «висящим» (*dangling) else*.

Для подавляющего большинства языков программирования, имеющих условные операторы описанного вида, действие (б) предпочтительно. Общепринятым правилом для данной ситуации является соотнесение каждого ***else*** с «ближайшим» ***then***. Это правило может быть формализовано с использованием однозначной грамматики. Идея в том, чтобы установить соответсвие между ***then*** и ***else***, что эквивалентно требованию, чтобы между ***then*** и ***else*** могли появиться только оператор, не являющийся условным оператором, или условный оператор с обязательным ***else*** *(**if** expr **then** stmt **else** stmt).*

## Разрешение конфликта перенос-свертка

- Конфликт перенос-свертка может быть решен следующими методами:
  - Вводя новые нетерминалы *matched_statement* и *unmatched_statement*
  - Явным образом разрешая конфликт при его возникновении (предпочитая перенос в случае возникновения конфликта перенос-свертка)

### Разрешение конфликта перенос-свертка

Следуя формализации правила явного предпочтения, может быть построена следующая грамматика:

(1) *stmt* → *matched_stmt*
(2) *stmt* → *unmatched_stmt*
(3) *matched_stmt* → ***if*** *expr* ***then*** *matched_stmt* ***else*** *matched_stmt*
(4) *matched_stmt* → *Other*
(5) *unmatched_stmt* → ***if*** *expr* ***then*** *stmt*
(6) *unmatched_stmt* → ***if*** *expr* ***then*** *matched_stmt* ***else*** *unmatched_stmt*

Новая грамматика порождает тот же язык, что и старая, но вывод цепочки `if` $E_1$ `then if` $E_2$ `then` $S_1$ `else` $S_2$ теперь не содержит конфликтов.

Альтернативой построению новой грамматики может служить «соглашение», что в случае конфликта перенос-свертка, перенос является предпочтительным действием.

После принятия одной из этих альтернатив вывод может быть продолжен следующим образом:

| Stack contents | Unprocessed input string | Action |
|---|---|---|
| *$* ***if*** $E_1$ ***then if*** $E_2$ ***then*** $S_1$ ***else*** | $S_2$ | *shift* |
| *$* ***if*** $E_1$ ***then if*** $E_2$ ***then*** $S_1$ ***else*** $S_2$ | | *reduce [2]* |
| *$* ***if*** $E_1$ ***then*** $S$ | | *reduce [1]* |
| *$* | | |

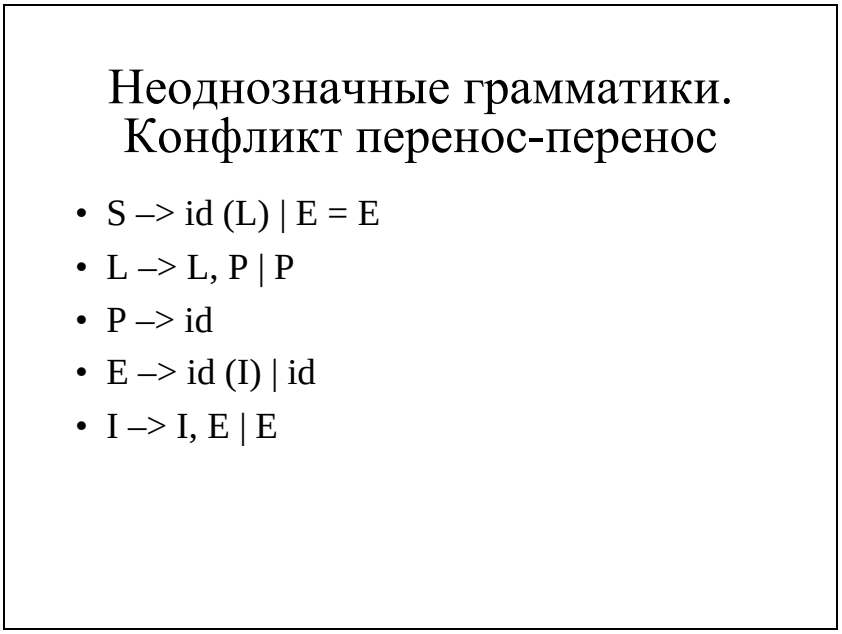


**Неоднозначные грамматики. Конфликт перенос-перенос**

Второй тип конфликта, который может возникнуть, это так называемый конфликт перенос-перенос (reduce/reduce), который возникает, когда на вершине стека анализатора возникает строка терминалов, к которой может быть применена свертка по двум различным правилам.

**Пример.** Рассмотрим грамматику $G_2$ ('***id***', '**(**', '**)**', '**=**' и '**,**' – терминалы).

| | | | |
|---|---|---|---|
| (1) | *stmt* | → | ***id (****parameters_list****)*** |
| (2) | *stmt* | → | *expr* = *expr* |
| (3) | *parameter_list* | → | *parameter_list****,*** *parameter* |
| (4) | *parameter_list* | → | *Parameter* |
| (5) | *parameter* | → | ***Id*** |
| (6) | *expr* | → | ***id (****expr_list****)*** |
| (7) | *expr* | → | ***Id*** |
| (8) | *expr_list* | → | *expr_list****,*** *expr* |
| (9) | *expr_list* | → | *Expr* |

В процессе разбора входной цепочки ***id*** (***id***, ***id***) происходит следующее:

| Содержимое стека | Необработанная часть | Действие |
|---|---|---|
| *$* | ***id*** (***id***, ***id***) | *shift* |
| $ ***id*** | (***id***, ***id***) | *shift* |
| $ ***id*** ( | ***id***, ***id***) | *shift* |
| $ ***id*** (***id*** | , ***id***) | *shift* |

Очевидно, что после выполнения последнего шага необходимо произвести свертку находящегося на вершине стека терминала ***id***. Но какое правило использовать? Если использвать правило (5), то будет получен вызов процедуры, если использовать правило (7), то получится вырезка из массива. Чтобы избежать неоднозначности, в первом правиле можно заменить терминал ***id*** на другой терминал, например, ***procid***. Но в этом случае, чтобы вернуть правильный лексический класс, лексический анализатор должен выполнить сложную работу по определению, является ли данный идентификатор обозначением процедуры или массива.

# Неоднозначные грамматики. Приоритет операций

- Иногда конфликт перенос-свертка не может быть решён предпочтением переноса, например, рассмотрим грамматику:
  E –> id | num | E* E | E + E
- В этой грамматика нет приоритетов операций, поэтому сложение и умножение выполняются в порядке появления во входной последовательности. Следующее преобразование решает эту проблему:
  E –> E + T | T
  T –> T * F | F
  F –> id | num | (E)

**Неоднозначные грамматики. Приоритет операций**

**Пример.** Рассмотрим грамматику $G_3$
(1) *E* → ***id***
(2) *E* → ***num***
(3) *E* → *E*E*
(4) *E* → *E+E*

Рассмотрим процесс анализа входной цепочки `2*3+4`.

| Содержимое стека | Необработанная часть входной цепочки | Действие |
|---|---|---|
| *$* | ***2*3+4*** | *shift* |
| *$**2*** | ****3+4*** | reduce [2] |
| *$E* | ****3+4*** | *shift* |
| *$E** | ***3+4*** | *shift* |
| *$E*3* | ***+4*** | reduce [2] |
| *$E*E* | ***+4*** | *shift* |

После выполнения последнего описанного шага возникают две альтернативы: либо (а) произвести свертку последовательности, находящейся на вершине стека, используя правило 3, либо (б) произвести перенос символа + на вершину стека. Так как приоритет умножения больше приоритета сложения, следует сделать свертку. Однако, это противоречит общему правилу, согласно которому, в случае конфликта перенос-свертка, перенос является предпочтительной операцией (которое было таким удобным способом разрешить конфликт в первом случае).

В данной ситуации существует эквивалентная грамматика $G_4$, в которой цепочка `2*3+4` имеет единственный вывод:
(1) *E* → *E+T*
(2) *E* → T
(3) *T* → *T*F*
(4) *T* → *F*
(5) *F* → ***id***
(6) *F* → ***num***

# Неоднозначные грамматики. Ассоциативность

- Рассмотрим предыдущую грамматику и входную цепочку 1+2+3
- Неясно, как посредством грамматики определить, является ли сложение левоассоциативным или нет; для задания ассоциативности аппарата грамматик не достаточно
- Большинство генераторов синтаксических анализаторов позволяют явно задать ассоциативность операторов (%left, %nonassoc…)

**Неоднозначные грамматики. Ассоциативность**

Рассмотрим конфигурации, возникающие при анализе строки `1+2+3`.

| Содержимое стека | Необработанная часть входной цепочки | Действие |
|---|---|---|
| *$* | ***1+2+3*** | *Shift* |
| ***$1*** | ***+2+3*** | Reduce [2] |
| *$E* | ***+2+3*** | *Shift* |
| *$E+* | ***2+3*** | *Shift* |
| *$E+**2*** | ***+3*** | |

После последнего шага возникает конфликт перенос-свертка. Выбор переноса делает сложение правоассоциативным, выпор свертки - левоассоциативным. Так как левоассоциативное сложение более естественно, свертка предпочтительна. В данном случае не существует эквивалентной однозначной грамматики. Формализма грамматик не хватает для описания данной ситуации и необходимы дополнительные средства.

Таким образом, существуют ряд стандартных ситуаций, в которых возникают неоднозначные грамматики. Большая часть подобных ситуаций может быть решена преобразованием грамматик («висящие» *else*, приоритет операций и т.д.), но не всегда это необходимо («висящие» *else*) и не всегда является лучшим решением. Существуют ситуации, когда подходящее преобразование грамматики не существует, в таких случаях необходимо привлекать дополнительные механизмы, как это сделано, например, для определения ассоциативности операций.

# Литература к лекции

- А. Ахо, Р. Сети, Дж. Ульман "Компиляторы: принципы, технологии и инструменты", М.: "Вильямс", 2001, 768 стр.
- D. Grune, C. H. J. Jacobs "Parsing Techniques – A Practical Guide", Ellis Horwood, 1990. 320 pp.

**Литература к лекции**

- А. Ахо, Р. Сети, Дж. Ульман "Компиляторы: принципы, технологии и инструменты", М.: "Вильямс", 2001, 768 стр.
- D. Grune, C. H. J. Jacobs "Parsing Techniques – A Practical Guide", Ellis Horwood, 1990, 320 pp.