Компиляторные технологии

Введение:
Общие принципы работы компилятора

Мельник Дмитрий Михайлович

dm@ispras.ru

Материалы курса: compilers.ispras.ru

Вопросы: dm@ispras.ru

Планируется 6 контрольных, по их результатам можно получить «автомат» за экзамен

Первая лекция – введение и обзор области

(Материал этой лекции не войдет в контрольные)

Литература (1)

“Dragon Book”

Ахо, Лам, Сети, Ульман.

Компиляторы. Принципы, технологии, инструменты.

2-е издание (2008)

Литература (2)

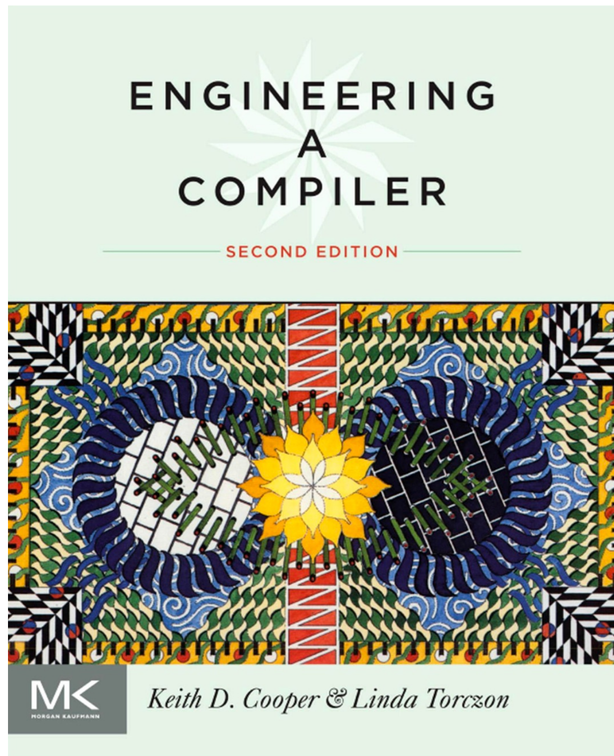

Keith D. Cooper, Linda Torczon. Engineering a Compiler (Second Edition)

Elsevier, Inc. 2012

Фазы компиляции

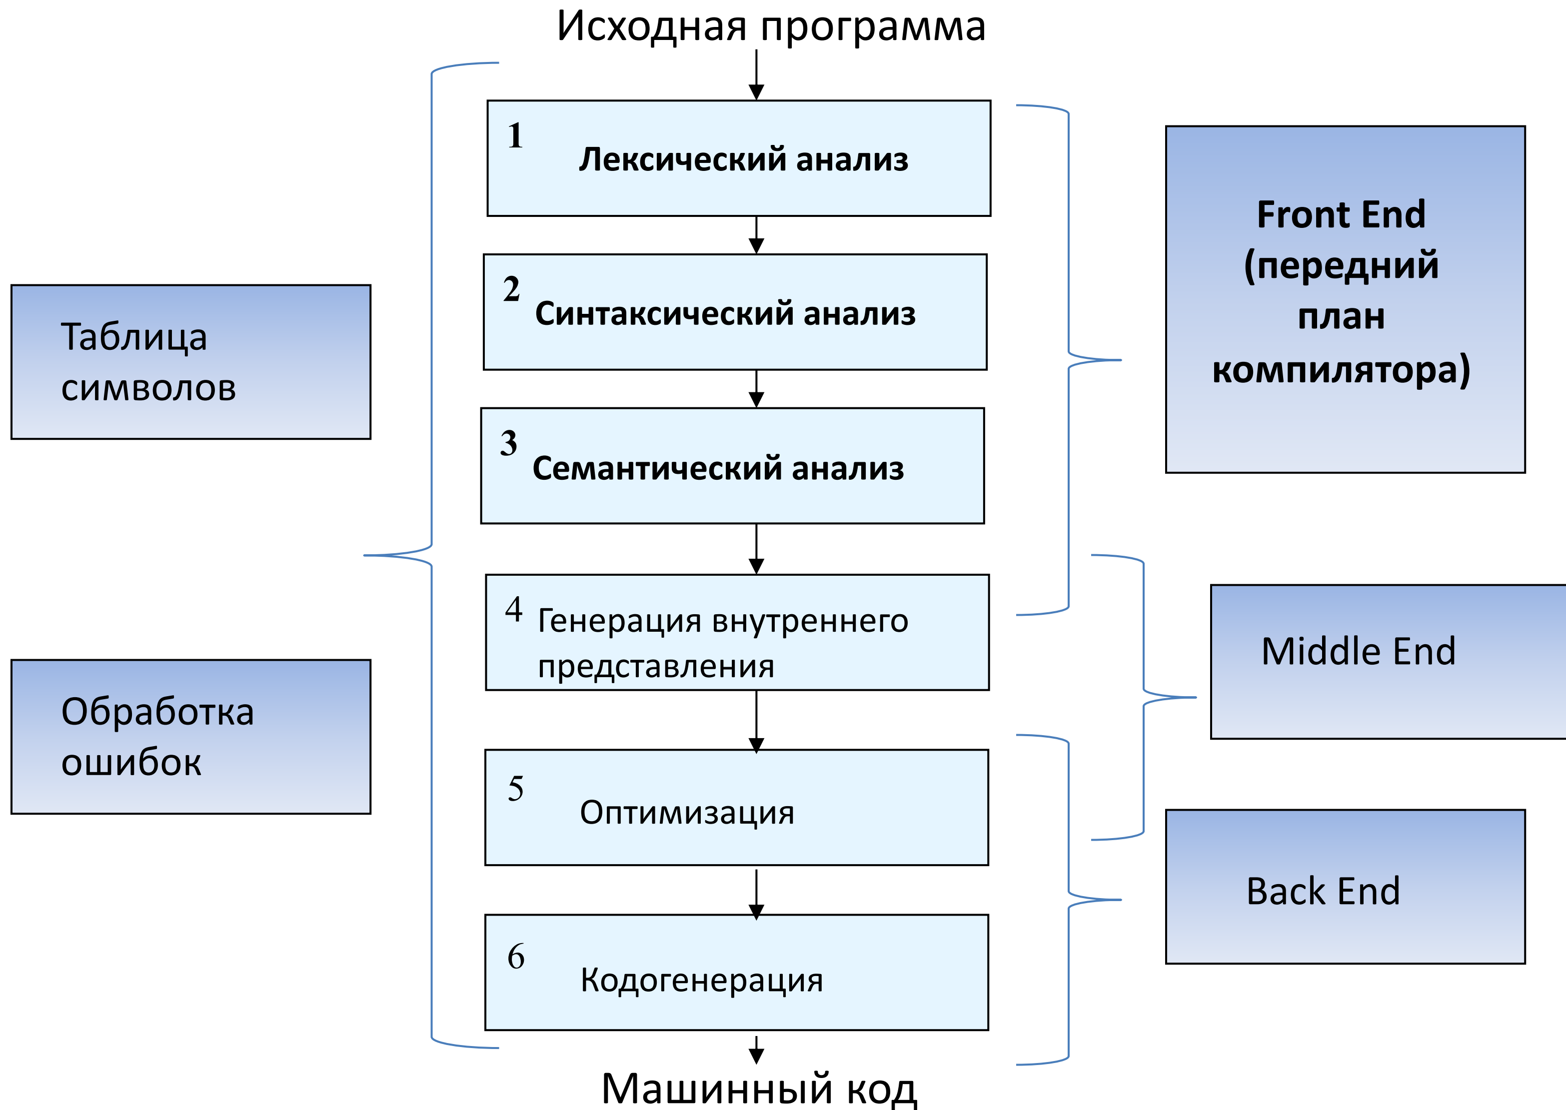

Препроцессирование

- Сформировать входную программу для компилятора
- Макросы – текстовые подстановки

```
#define i j    // Happy debugging!
```

- Включение файлов

```
#include “headers.h”
```

- Скрытие деталей реализации

```
#define tolower(c) __tobody (c, tolower, *__ctype_tolower_loc (), (c))
```

- Выполнить препроцессирование:

```
gcc test.c –E -o test.i
```

Лексический анализ

- В естественных языках:
  - *Лексический анализ слова – это разбор слова с точки зрения его значения, происхождения, употребления, наличия у него синонимов, антонимов, многозначности.*
- В компиляторе:
  - Цель: разбить текст (программу) на слова (лексемы)
  - Выполняется за один проход по тексту
  - Незначащие символы удаляются
    - Пробелы, комментарии
  - if x == y then z = 1e10; else z = 3.14;
    - Синтаксический анализ будет работать с последовательностью лексем:
    - *if*, *x*, ==, *y*, *then*, *z*, =, *1e10*, ;, *else*, *z*, =, 3.14, ;

Синтаксический анализ

- Выделить предложения и разобрать их структуру по правилам грамматики языка
- Часто требует рекурсивного обхода дерева, заглядывания вперед на несколько шагов
- **`if x == y then  z = 1;    else z = 2;`**

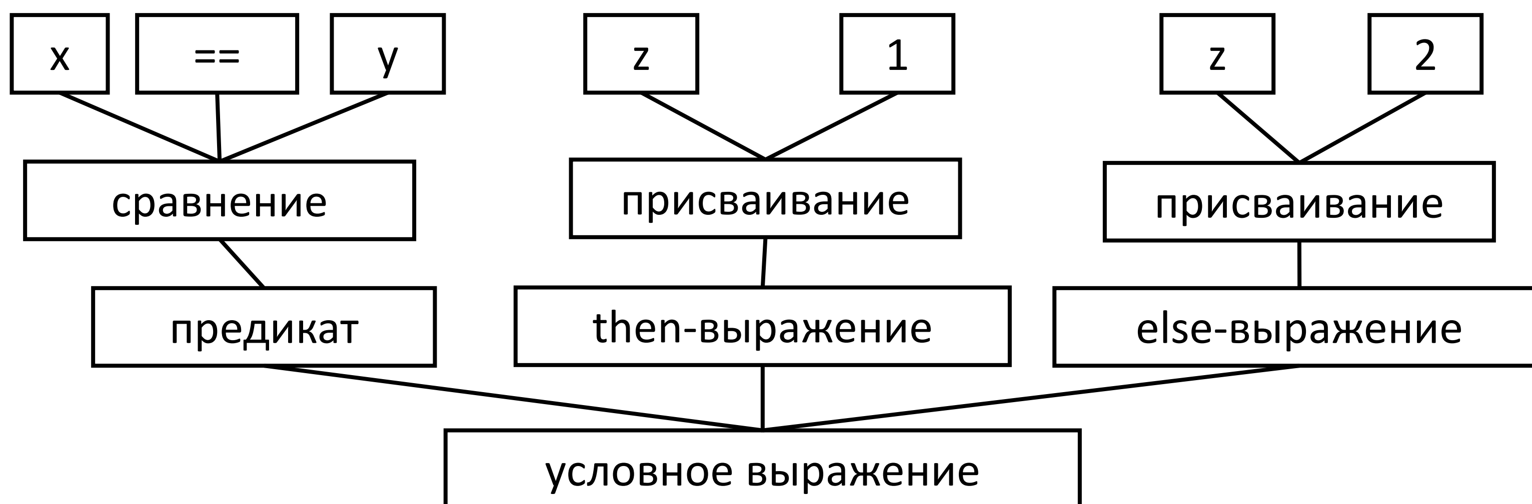

Семантический анализ

- Предложения языка могут быть многозначными
- Я встретил ее на поляне с цветами
    - Где находились цветы?
- Jack said Jack forgot his textbook at home
    - Сколько всего Джеков?
    - Кто из них забыл учебник?

Семантический анализ

- Грамматика языка дополняется правилами, позволяющими избегать двусмысленных трактовок

- Внутреннее определение переменной `j` перекрывает внешнее

- Необходимы дополнительные проверки этих правил
  - Не больше одной переменной `j` на уровень вложенности

```
{
   int j = 3;
   {
       int j = 4;
       printf("%d\n", j);
   }
}
```

- “Лена забыла дома своя учебник”
  - Несогласованность (несоответствие типов) между “своя” и “учебник”

Семантический анализ

- Результирующее дерево может содержать дополнительные операции, вставленные на этом этапе

```
int x, double y;
y =  x + y;
```

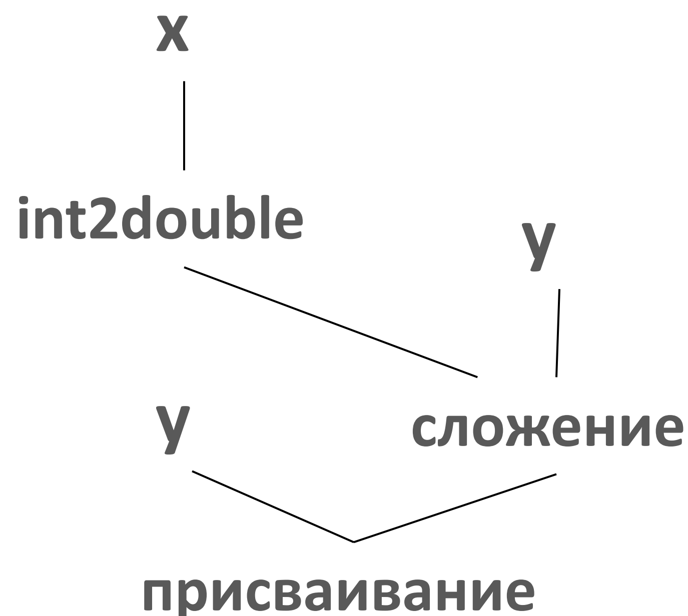

- Таблица имен заполняется в ходе всего анализа, начиная с лексического

Фазы компиляции

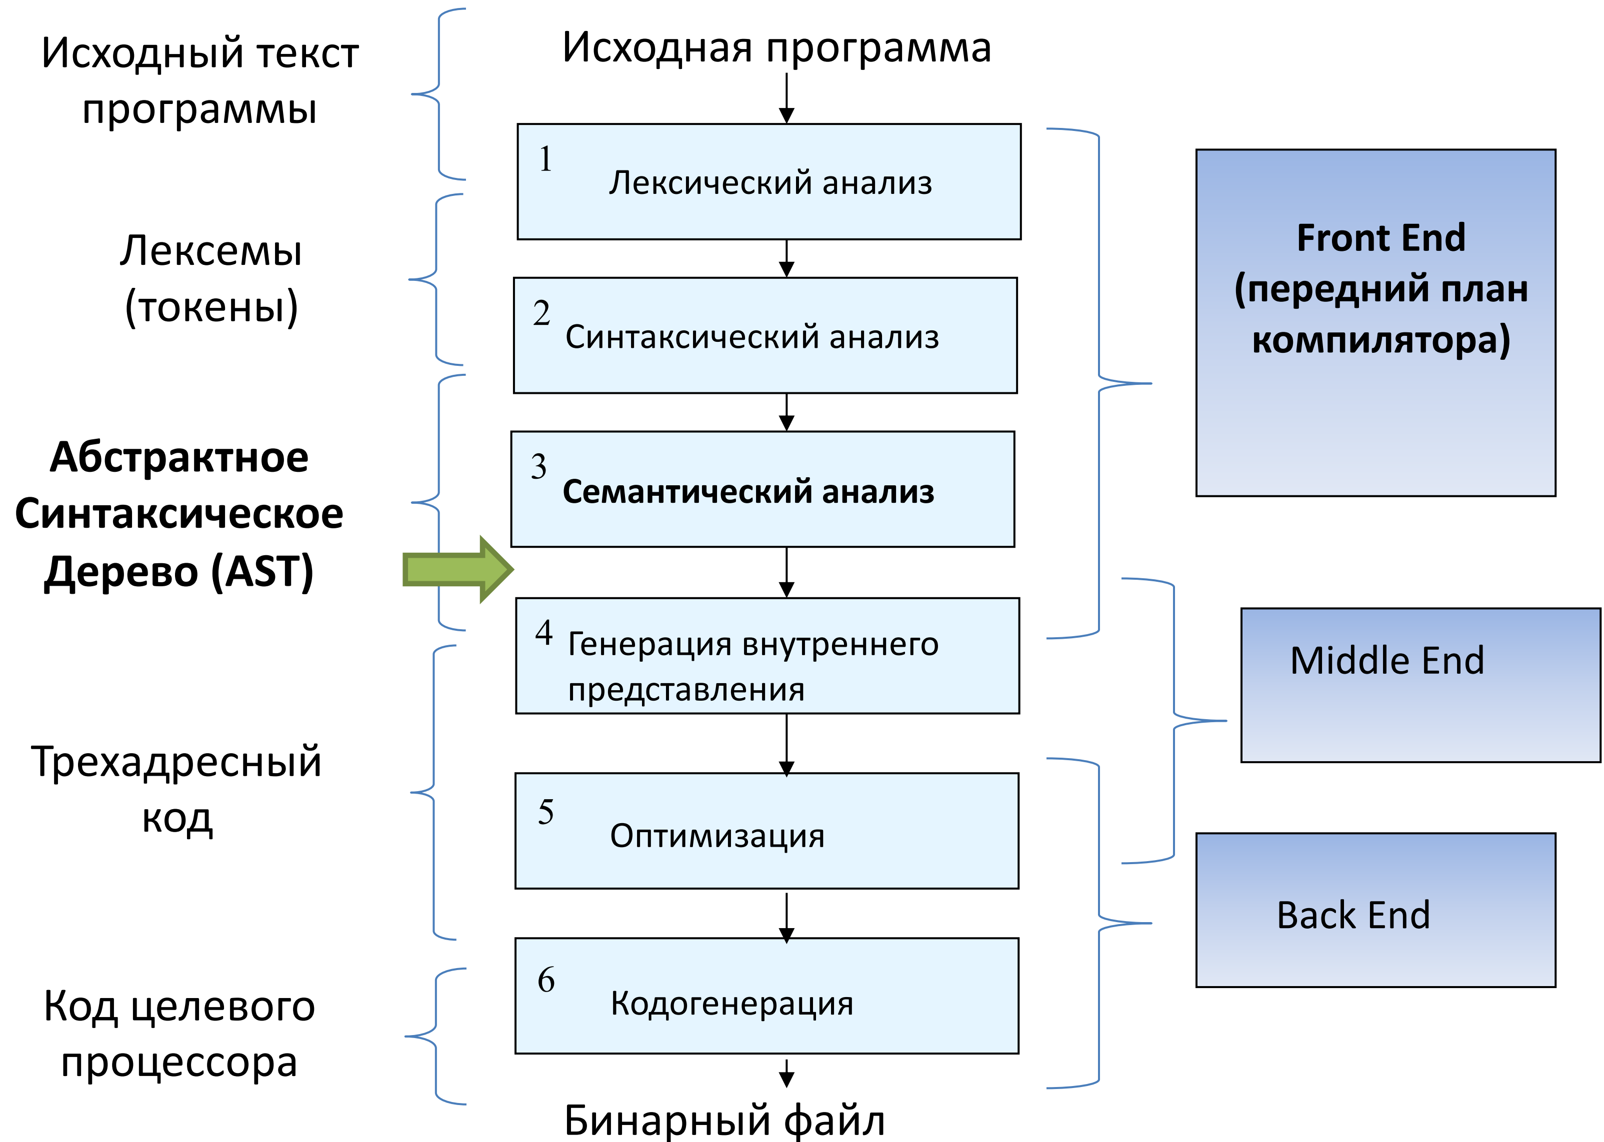

Структура front-end'а

Трансляция во внутреннее представление

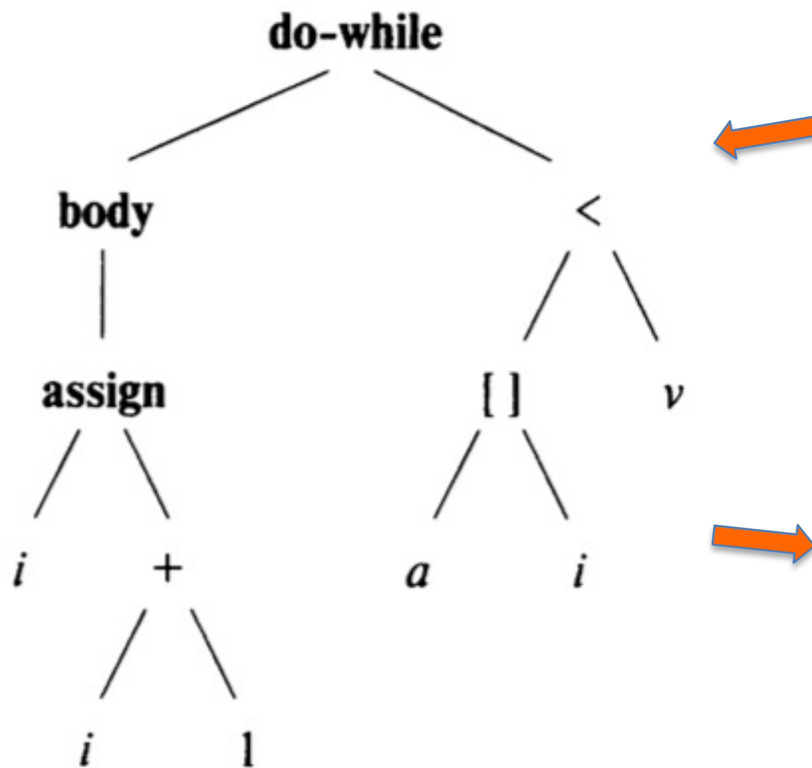

Абстрактное Синтаксическое Дерево (AST)

Исходная программа

```
do {
  i = i + 1 ;
} while (a[i] < v);
```

```
1: i = i + 1
2: t1 = a [ i ]
3: if t1 < v goto 1
```

Результат трансляции: промежуточное представление (трехадресный код)

Зачем нужно внутреннее представление

- Удобство выполнения анализа и синтеза

- Возможность построить компилятор с нескольких языков на несколько архитектур (GCC, Clang)

- Для разных этапов – разные представления

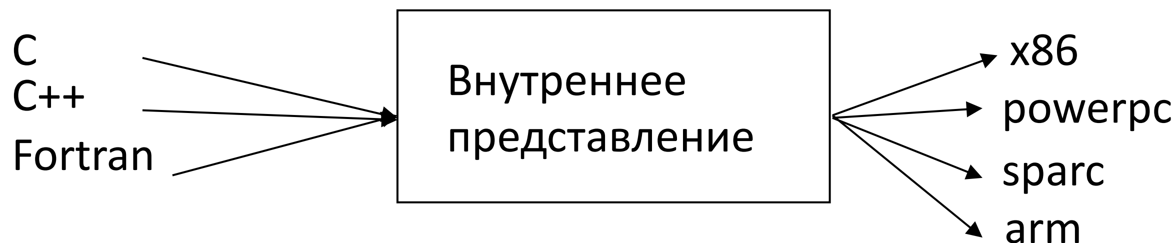

Внутреннее представление

- Трехадресное представление:

```
dest = OP arg1, arg2
```

- Неограниченное число псевдорегистров

- LLVM:

```
%3 = load i64, i64* %1
%4 = load i64, i64* %2
%5 = add nsw i32 %3, %4
```

- GCC:

```
(set (mem:SI (plus:SI (reg:SI 3 bx) (const_int 4)
      (reg:SI 85))
```

(Представление для операции записи в память `[bx + 4] = @reg85`)

Трансляция во внутреннее представление

```
{
  int i; int j; float[100] a;
  float v; float x;
  while ( true ) {
    do i = i+1; while ( a[i] < v );
    do j = j-1; while ( a[j] > v );
    if ( i >= j ) break;
    x = a[i];
    a[i] = a[j];
    a[j] = x;
  }
}
```

Исходная программа

```
1: i = i + 1
2: tl = a [ i ]
3: if tl < v goto 1
4: j = j - 1
5: t2 = a [ j ]
6: if t2 > v goto 4
7: ifFalse i >= j goto 9
8: goto 14
9: x = a [ i ]
10: t3 = a [ j ]
11: a [ i ] = t3
12: a [ j ] = x
13: goto 1
14:
```

Результат трансляции: промежуточное представление (трехадресный код)

Граф Потока Управления

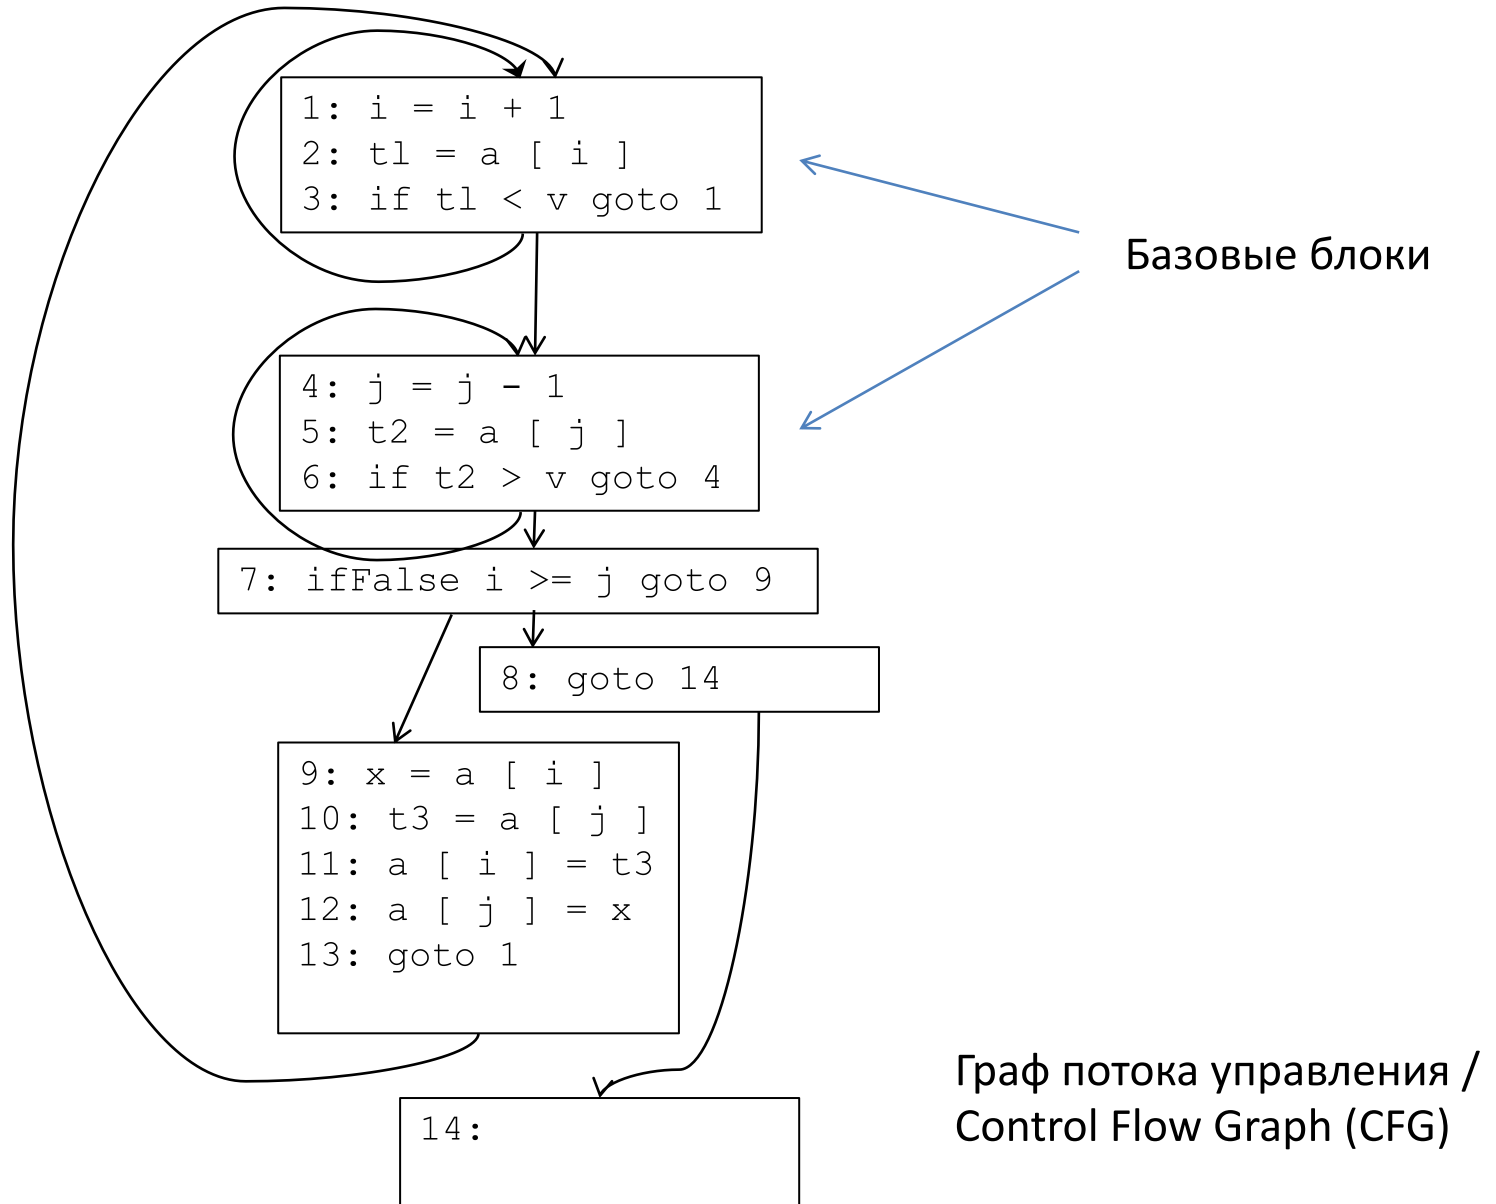

Базовые блоки

Базовый блок (или *линейный участок*) – последовательность следующих одна за другой трехадресных инструкций, обладающая следующими свойствами:

- поток управления может входить в базовый блок только через его первую инструкцию, т.е. в программе нет переходов в середину базового блока;
- поток управления покидает базовый блок без останова или ветвления, за исключением, возможно, в последней инструкции базового блока.

Пример:

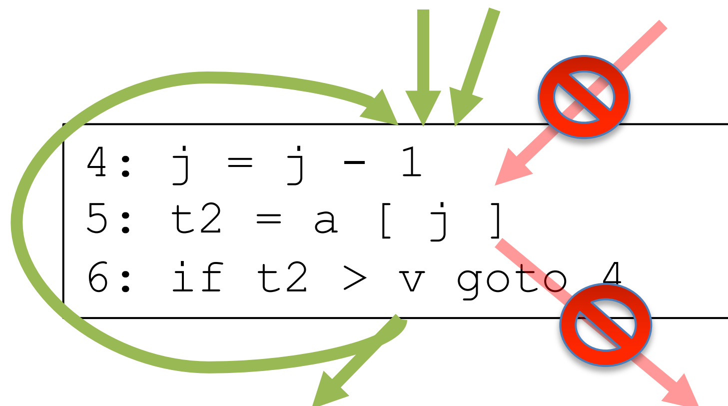

Дуги, передающие управление в/из середины базового блока, недопустимы (в таких случаях должны быть созданы отдельные базовые блоки)

Синтаксический Анализ

Грамматики

Пример правила грамматики (*продукция*):

stmt → **if** (*expr*) *stmt* **else** *stmt*

Продукция определяет возможный вид языковой конструкции.
if , (,), **else** – терминалы (*токены*)
stmt, expr – нетерминалы
ε – специальный терминал (пустая строка)

Грамматика состоит из множества продукций, терминальных и нетерминальных символов и стартового символа.

Грамматики

Пример грамматики:

*list** → *list* + *digit*
list → *list* − *digit*
list → *digit*
digit → 0|1|2|3|4|5|6|7|8|9

Грамматика выводит (порождает) строки, начиная с стартового символа, подставляя вместо нетерминалов правую часть продукций. Строки терминалов, порождаемые грамматикой из стартового символа, образуют *язык*, определяемый грамматикой.

Грамматики

*1: list** → *list* + *digit* | *list* – *digit* | *digit*
2: digit → 0|1|2|3|4|5|6|7|8|9

Разбор строки (parsing):

9 – 5 + 2
9 => digit (2); 5 => digit (2); digit => list (1c)
list – digit + 2
list – digit => list (1b)
list + 2
2 => digit (2); list + digit => list* (1a)

Дерево разбора

A → X Y Z

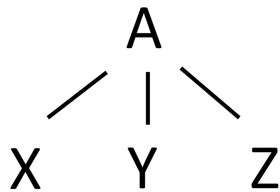

*list** → *list* + *digit*
list → *list* − *digit*
list → *digit*
digit → 0|1|2|3|4|5|6|7|8|9

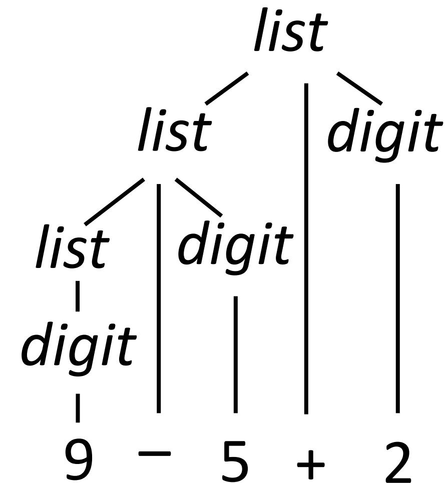

1. Корень дерева помечен стартовым символом.
2. Каждый лист помечен терминалом или ε.
3. Каждый внутренний узел помечен нетерминалом.
4. Если A является нетерминалом и помечает некоторый внутренний узел, а $X_1, X_2, \ldots, X_n$ — метки его дочерних узлов слева направо, то должна существовать продукция $A \to X_1 X_2 \ldots X_n$. Здесь X_i – может быть как терминалом, так и нетерминалом.

Синтаксический анализ

$A \rightarrow X\ Y\ Z$

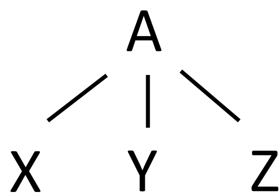

*list** → *list* + *digit*
list → *list* − *digit*
list → *digit*
digit → 0|1|2|3|4|5|6|7|8|9

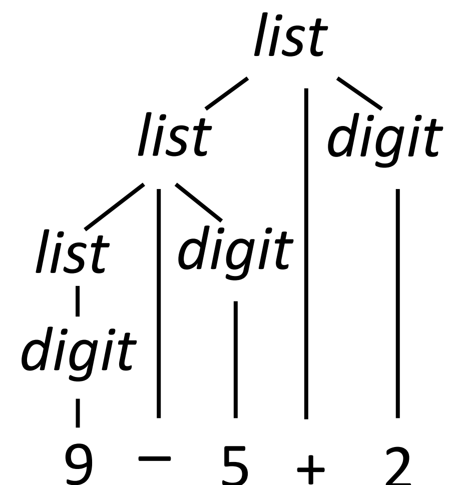

Процесс поиска дерева разбора для данной строки терминалов называется *разбором* (parsing) или *синтаксическим анализом* этой строки.

Неоднозначности

Исходная грамматика:
1: list → list + digit | list → list – digit | list → digit*
2: digit → 0|1|2|3|4|5|6|7|8|9

Преобразованная (но не эквивалентная с точки зрения разбора):
string → string + string | string - string |0|1|2|3|4|5|6|7|8|9

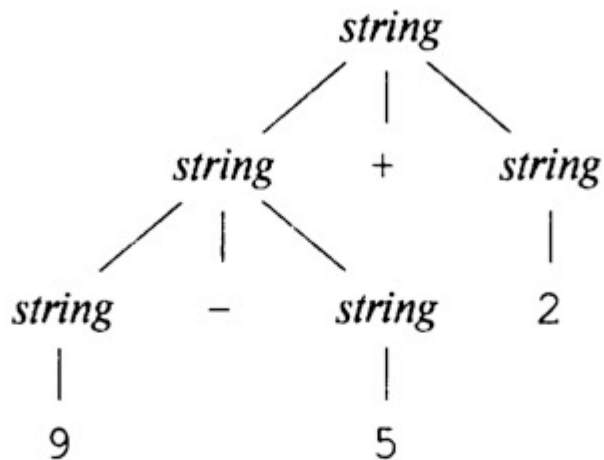

(9-5)+2

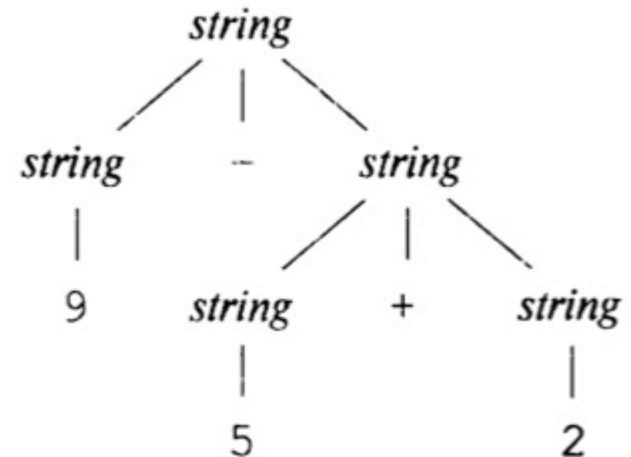

9−(5+2)

Ассоциативность операторов

Левоассоциативные
*Примеры: +, −, *, /*
$a + b + c \Leftrightarrow (a + b) + c$

list → *list* + *digit*
digit → 0|1|2|3|4|5|6|7|8|9

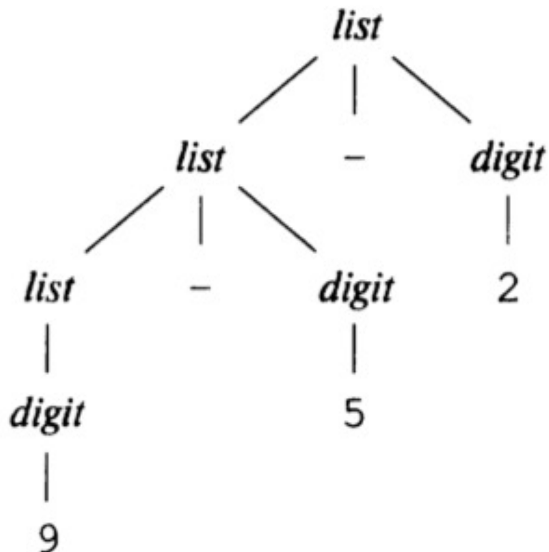

Правоассоциативные
Примеры: =
$a = b = c \Leftrightarrow a = (b = c)$

right → letter = right | letter
letter → a | b | … | z

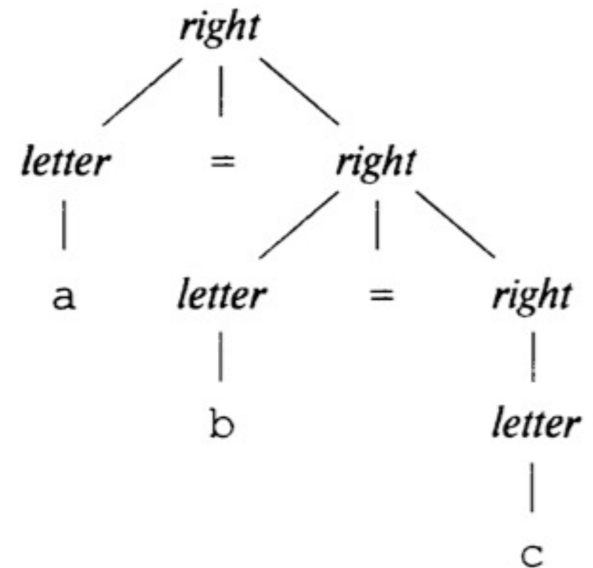

Приоритет операторов

expr → expr + term | expr − term | term
term → term * factor | term / factor | factor
factor → digit | (expr)

Грамматика для подмножества Java

```
stmt → id = expression ;
      | if ( expression ) stmt
      | if ( expression ) stmt else stmt
      | while ( expression ) stmt
      | do stmt while ( expression ) ;
      | { stmts }
stmts → stmts stmt
      | ε
```

Синтаксически Управляемая Трансляция

При выполнении синтаксического анализа («парсинга») строки, можно связать с продукциями семантические правила (или программный код), и выполнять их при «свертке» соответствующих нетерминалов. Это и есть синтаксически управляемая трансляция.

Постфиксная запись

Пример:

(9 – 5) + 2 ⇒ 9 5 – 2 +

9 – (5 + 2) ⇒ 9 5 2 + -

Вычисление постфиксных выражений:

9 5 2 + – 3 *	9 5 2
9 5 2 + – 3 *	9 **7**
9 5 2 + – 3 *	**2**
9 5 2 + – 3 *	2 **3**
9 5 2 + – 3 *	**6**

Строка сканируется слева направо, числа помещаются в стек. Когда встречаем оператор, аргументы берутся с вершины стека, операция выполняется, и значение помещается обратно на стек.

Постфиксная запись

Постфиксной записью для выражения E является:

1. Если E является переменной или константой, то постфиксная запись E представляет собой само E.

2. Если E — выражение вида E_1 **op** E_2, где **op** — произвольный бинарный оператор, то постфиксная запись E представляет собой E'_1 E'_2 **op**, где E'_1 и E'_2 — постфиксные записи для E_1 и E_2 соответственно.

3. Если E — выражение в скобках вида (E_1), то постфиксная запись для E такова же, как и постфиксная запись для E_1.

Синтезированные и унаследованные атрибуты

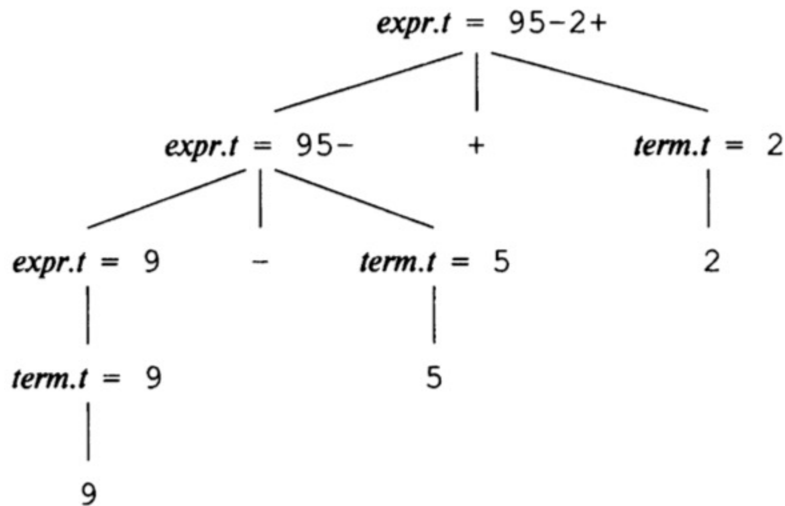

Синтезированный атрибут для символа X (вершины дерева разбора) вычисляется на основе атрибутов потомков и самого узла X

Унаследованные атрибуты вычисляются на основе атрибутов предков узла.

Синтаксически управляемые определения

Продукция	Семантическое правило
$expr \rightarrow expr_1 + term$	$expr.t = expr_1.t \,\|\|\, term.t \,\|\|\, '+'$
$expr \rightarrow expr_1 - term$	$expr.t = expr_1.t \,\|\|\, term.t \,\|\|\, '-'$
$expr \rightarrow term$	$expr.t = term.t$
$term \rightarrow 0$	$term.t = '0'$

|| – конкатенация строк

Схема Трансляции

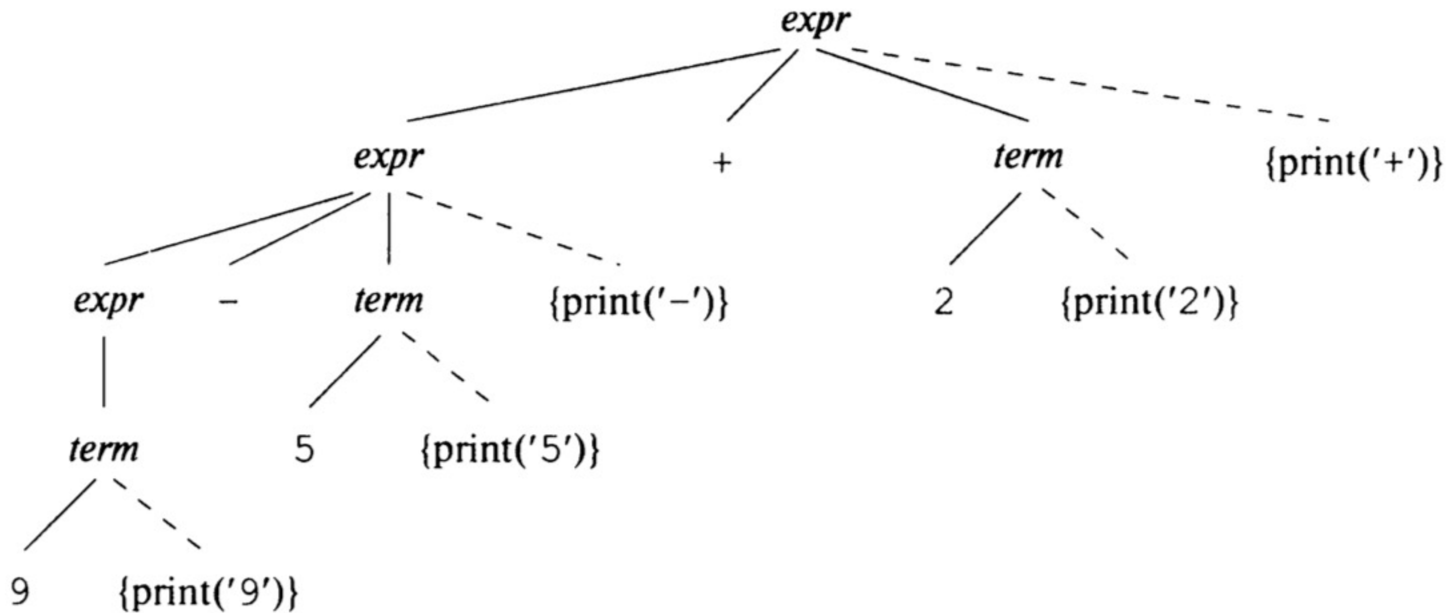

Правила, дополненные семантическими действиями

$$expr \rightarrow expr_1 + term \quad \{\text{print}('+')\}$$

$$expr \rightarrow expr_1 - term \quad \{\text{print}('-')\}$$

$$expr \rightarrow term$$

$$term \rightarrow 0 \quad \{\text{print}('0')\}$$

Метод Рекурсивного Спуска

Пример грамматики

$$
\begin{array}{lcl}
\mathit{stmt} & \rightarrow & \textbf{expr}\ ; \\
& | & \textbf{if}\ (\ \textbf{expr}\ )\ \mathit{stmt} \\
& | & \textbf{for}\ (\ \mathit{optexpr}\ ;\ \mathit{optexpr}\ ;\ \mathit{optexpr}\ )\ \mathit{stmt} \\
& | & \textbf{other} \\
\mathit{optexpr} & \rightarrow & \epsilon \\
& | & \textbf{expr}
\end{array}
$$

Метод Рекурсивного Спуска

```
stmt → for ( optexpr ; optexpr ; optexpr ) stmt
```

Предиктивный анализатор (predictive parsing): сканируемый символ однозначно определяет поток управления в теле процедуры для каждого нетерминала. Последовательность вызовов процедур при обработке входной строки неявно определяет его дерево разбора.

```
match(for); match('(');
optexpr(); match(';’); optexpr(); match(';'); optexpr();
match(')'); stmt();
```

Функция `match(t)`:

- сравнивает свой аргумент `t` со сканируемым символом и переходит к следующему символу в случае соответствия
- изменяет значение глобальной переменной `lookahead`, которая хранит сканируемый входной терминал

Метод Рекурсивного Спуска

$$
\begin{aligned}
stmt \;\rightarrow\;& \mathbf{expr}\ ;\\
|\;& \mathbf{if}\ (\ \mathbf{expr}\ )\ stmt\\
|\;& \mathbf{for}\ (\ optexpr\ ;\ optexpr\ ;\ optexpr\ )\ stmt\\
|\;& \mathbf{other}
\end{aligned}
$$

$$
\begin{aligned}
optexpr \;\rightarrow\;& \epsilon\\
|\;& \mathbf{expr}
\end{aligned}
$$

FIRST(α) – множество терминалов, которые могут появиться в качестве первого символа одной или нескольких строк, сгенерированных из α. Если α может порождать ε, то ε также входит в FIRST (α)

FlRST(**stmt**) = {**expr**, **if**, **for**, **other**}

Метод Рекурсивного Спуска

stmt → **expr** *;*
| **if** (**expr**) *stmt*
| **for** (*optexpr* ; *optexpr* ; *optexpr*) *stmt*
| **other**

optexpr → ϵ
| **expr**

```
void stmt() {
  switch (lookahead ) {
  case expr:
    match(expr); match(';'); break;
  case if:
    match(if); match('('); match(expr);
match(')');
    stmt(); break;
  case for:
    match(for); match('(');
    optexpr(); match(';’); optexpr();
match(';');
    optexpr(); match(')'); stmt();
  case other;
    match(other); break;
  default:
    report("syntax error");
  }
}
```

```
void optexpr() {
  if (lookahead == expr)
    match(expr);
}

void match(terminal t) {
  if (lookahead == t)
    lookahead = nextTerminal;
  else report("syntax error");
}
```

Устранение Левой Рекурсии

```
expr → expr + term | term
```

Это леворекурсивное правило вида $A \to A\ \alpha \mid \beta$

Это правило порождает последовательности вида:

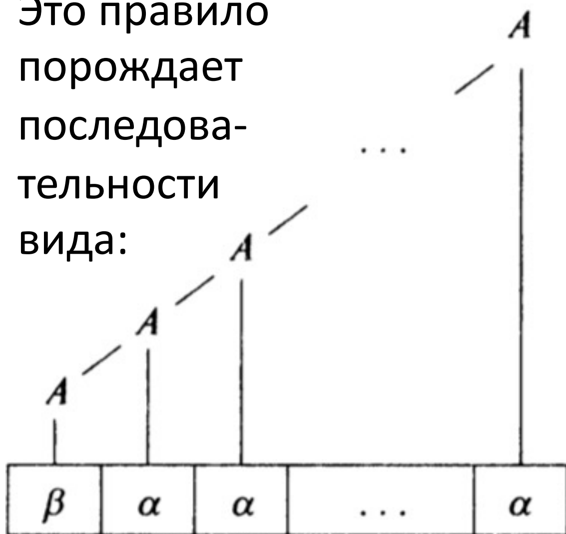

⇒

Ту же последовательность можно получить и другим способом:

$A \to A\ \alpha \mid \beta$

⇒

$A \to \beta\ R$

$R \to \alpha\ R \mid \varepsilon$

Устранение Левой Рекурсии в Схеме Трансляции

Удаление рекурсии: $A \to A\,\alpha \mid A\,\beta \mid \Upsilon \quad \Rightarrow \quad \begin{aligned} &A \to \Upsilon\, R \\ &R \to \alpha\, R \mid \beta\, R \mid \varepsilon \end{aligned}$

Преобразуем схему трансляции:

$$\begin{aligned} expr &\to expr_1 + term \quad \{\text{print}('+')\} \\ expr &\to expr_1 - term \quad \{\text{print}('-')\} \\ expr &\to term \\ term &\to 0 \quad \{\text{print}('0')\} \end{aligned}$$

Учитывая, что

A = expr
α = + term { print('+') }
β = - term { print('-') }
ϒ = term

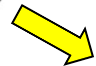

$$\begin{aligned} expr &\to term\ rest \\ rest &\to +\ term\ \{\ \text{print}('+')\ \}\ rest \\ &\mid\ -\ term\ \{\ \text{print}('-')\ \}\ rest \\ &\mid\ \epsilon \\ term &\to 0\ \{\ \text{print}('0')\ \} \end{aligned}$$

Устранение Левой Рекурсии в Схеме Трансляции

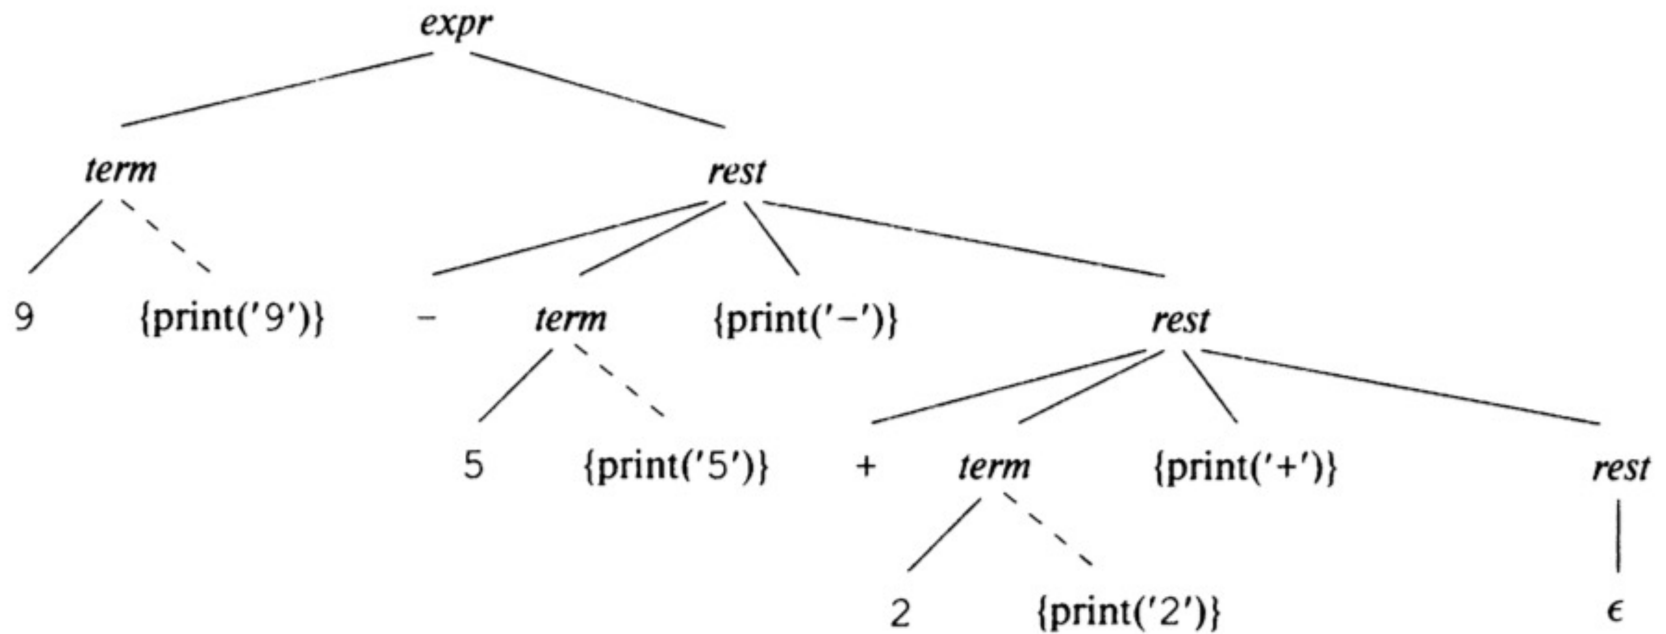

(9 – 5) + 2 ⇒ 9 5 – 2 +

Реализация Схемы Синтаксически Управляемой Трансляции

$$
\begin{array}{lcl}
expr & \rightarrow & term\ rest \\
rest & \rightarrow & +\ term\ \ \{\ \text{print}('+')\ \}\ \ rest \\
 & | & -\ term\ \ \{\ \text{print}('-')\ \}\ \ rest \\
 & | & \epsilon \\
term & \rightarrow & 0\ \ \{\ \text{print}('0')\ \}
\end{array}
$$

```
void rest() {
        if ( lookahead == '+' ) {
                match('+'); term(); print('+'); rest();
        }
        else if ( lookahead == '-' ) {
                match('-'); term(); print('-'); rest();
        }
        else { } /* Не делать ничего */ ;
}
```

```
void expr() {
        term(); rest();
}
```

```
void term() {
        if ( lookahead — цифра ) {
                t = lookahead; match(lookahead); print(t);
        }
        else report("syntax error");
}
```

Лексический Анализ

Лексический Анализ

Основная задача лексического анализа – разбиение входного потока символов на лексемы (токены).

Что делается в лексическом анализаторе:

- Удаление пробельных символов и комментариев
- Считывание констант
- Распознавание ключевых слов и идентификаторов
- Распознавание операторов
    - Опережающее чтение: >, >=, >>

Лексический Анализ

Почему лексический анализ выделяется в отдельную фазу?

- упрощение разработки
- увеличение эффективности компилятора

Примеры токенов:

Токен	Неформальное описание	Примеры лексем
if	Символы `i`, `f`	`if`
else	Символы `e`, `l`, `s`, `e`	`else`
comparison	< или > или <= или >= или == или !=	<=, !=
id	Буква, за которой следуют буквы и цифры	`pi`, `score`, `D2`
number	Любая числовая константа	`3.14159`, `0`, `6.02e23`
literal	Все, кроме ", заключенное в двойные кавычки	`"core dumped"`

Регулярные выражения

Цифра: **[0-9]**
Идентификатор: **[a-z][a-z0-9]***
Целое: **{DIGIT}+**
Вещественное: **{DIGIT}+"."{DIGIT}***
Ключевые слова: **if|then|begin|end|function**
Операторы: **+|-|*|/**
Комментарий (Паскаль): **{[^}\n]*}**
Пробельные символы: **[\t\n]+**

Взаимодействие Лексического Анализатора с Синтаксическим

Абстрактное Синтаксическое Дерево

Абстрактное Синтаксическое Дерево, Abstract Syntax Tree (**AST**).
В AST похожие операторы объединены в группы, т.к. во время генерации кода (или анализа) обрабатываются схожим образом.

Конкретный синтаксис	Абстрактный синтаксис
=	**assign**
||	**cond**
&&	**cond**
== !=	**rel**
< <= >= >	**rel**
+ −	**op**
* / %	**op**
!	**not**
$-_{unary}$	**minus**
[ ]	**access**

Построение Абстрактного Синтаксического Дерева (AST)

Пусть у каждого символа грамматики задан атрибут **n**, в котором мы будем хранить ссылку на соответствующий ему узел в AST. Пусть **X.n** – указатель на базовый тип *ASTNode **, а каждому оператору соответствует унаследованный от него класс с собственным конструктором. Мы будем конструировать AST во время синтаксически управляемой трансляции с использованием подобной схемы:

$$
\begin{array}{lcll}
add & \rightarrow & add_1 + term & \{ add.n = \textbf{new}\ Op('+', add_1.n, term.n); \} \\
 & | & term & \{ add.n = term.n; \} \\
 & & & \\
term & \rightarrow & term_1 * factor & \{ term.n = \textbf{new}\ Op('*', term_1.n, factor.n); \} \\
 & | & factor & \{ term.n = factor.n; \} \\
 & & & \\
factor & \rightarrow & (\ expr\ ) & \{ factor.n = expr.n; \} \\
 & | & \textbf{num} & \{ factor.n = \textbf{new}\ Num(\textbf{num}.value); \}
\end{array}
$$

Построение Абстрактного Синтаксического Дерева (AST)

$$
\begin{array}{rcll}
program & \rightarrow & block & \{\ \text{return } block.n;\ \} \\
\\
block & \rightarrow & '\{'\ stmts\ '\}' & \{\ block.n = stmts.n;\ \} \\
\\
stmts & \rightarrow & stmts_1\ stmt & \{\ stmts.n = \textbf{new}\ Seq\,(stmts_1.n, stmt.n);\ \} \\
 & | & \epsilon & \{\ stmts.n = \textbf{null};\ \} \\
\\
stmt & \rightarrow & expr\ ; & \{\ stmt.n = \textbf{new}\ Eval\,(expr.n);\ \} \\
 & | & \textbf{if}\ (\ expr\ )\ stmt_1 & \\
 & & & \{\ stmt.n = \textbf{new}\ If\,(expr.n, stmt_1.n);\ \} \\
 & | & \textbf{while}\ (\ expr\ )\ stmt_1 & \\
 & & & \{\ stmt.n = \textbf{new}\ While\,(expr.n, stmt_1.n);\ \} \\
 & | & \textbf{do}\ stmt_1\ \textbf{while}\ (\ expr\ )\ ; & \\
 & & & \{\ stmt.n = \textbf{new}\ Do\,(stmt_1.n, expr.n);\ \} \\
 & | & block & \{\ stmt.n = block.n;\ \}
\end{array}
$$

Статические проверки

Выполняются на этапе построения дерева (либо во время генерации трехадресного представления):

- **Проверки синтаксиса.** Правила, которые нельзя отразить в грамматике – например, что идентификатор должен быть объявлен в области видимости не более одного раза, или что инструкция break располагается в охватывающем цикле или инструкции switch.

- **Проверки типов**. Оператор применен к корректному количеству операторов допустимого типа. Также программа проверки типов может вставить оператор преобразования типов в синтаксическое дерево (например, при сложении целого числа с числом с плавающей точкой).

Статические проверки

Примеры статических проверок:

- Слева от присваивания должно находится lvalue (должно быть ячейкой памяти), например:

```
i = 5;
i = i + 1;
a[i] = *p;
```

- Проверка типов:

  Правило грамматики:

  if (*expr*) *stmt*

  Проверка:

  if (E_1.*type* == E_2.*type*) E.*type* = boolean;

  else error;

Трансляция Инструкций

Код для трансляции условного оператора: **if** (*expr*) **then** $stmt_1$

```
class If extends Stmt {
        Expr E; Stmt S;
        public If(Expr x, Stmt y) { E = x; S = y; after = newlabel(); }
        public void gen() {
                Expr n = E.rvalue();
                emit( "ifFalse " + n.toString() + " goto " + after);
                S.gen();
                emit(after + ":");
        }
}
```

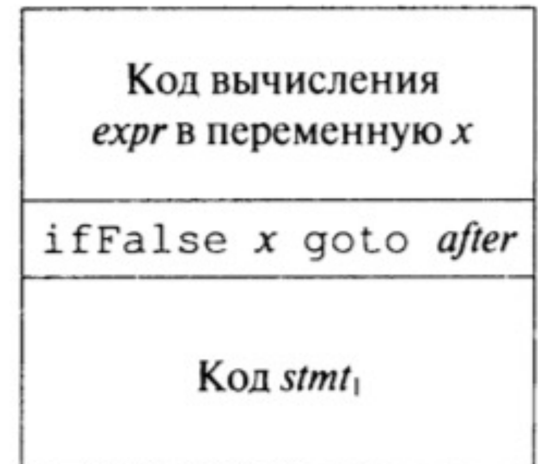

Трансляция Выражений

Пример:

```
a[i] = 2*a[j-k]   ⇒   t3 = j - k
                      t2 = a [ t3 ]
                      t1 = 2 * t2
                      a [ i ] = t1
```

Трансляция Выражений

Трансляция левой части выражений:

```
Expr lvalue(x : Expr) {
        if ( x является узлом Id ) return x;
        else if ( x является узлом Access (y, z), а y – узел Id ) {
                return new Access (y, rvalue(z));
        }
        else error;
}
```

Трансляция Выражений

Трансляция правой части выражений:

$Expr\ rvalue(x : Expr)$ {

  if (x – узел Id или $Constant$) **return** x;

  else if (x – узел Op (**op**, y, z) или Rel (**op**, y, z)) {

    t = новая временная переменная;

    Генерация строки для t = $rvalue(y)$ **op** $rvalue(z)$;

    return Новый узел t;

  }

  else if (x узел $Access$ (y, z)) {

    t = новая временная переменная;

    Вызов $lvalue(x)$ возвращающий $Access$ (y, z');

    Генерация строки для t = $Access$ (y, z');

    return Новый узел t;

  }

  else if (x – узел $Assign$ (y, z)) {

    $z' = rvalue(z)$;

    Генерация строки для $lvalue(y) = z'$;

    return z';

  }

}

Фазы компиляции

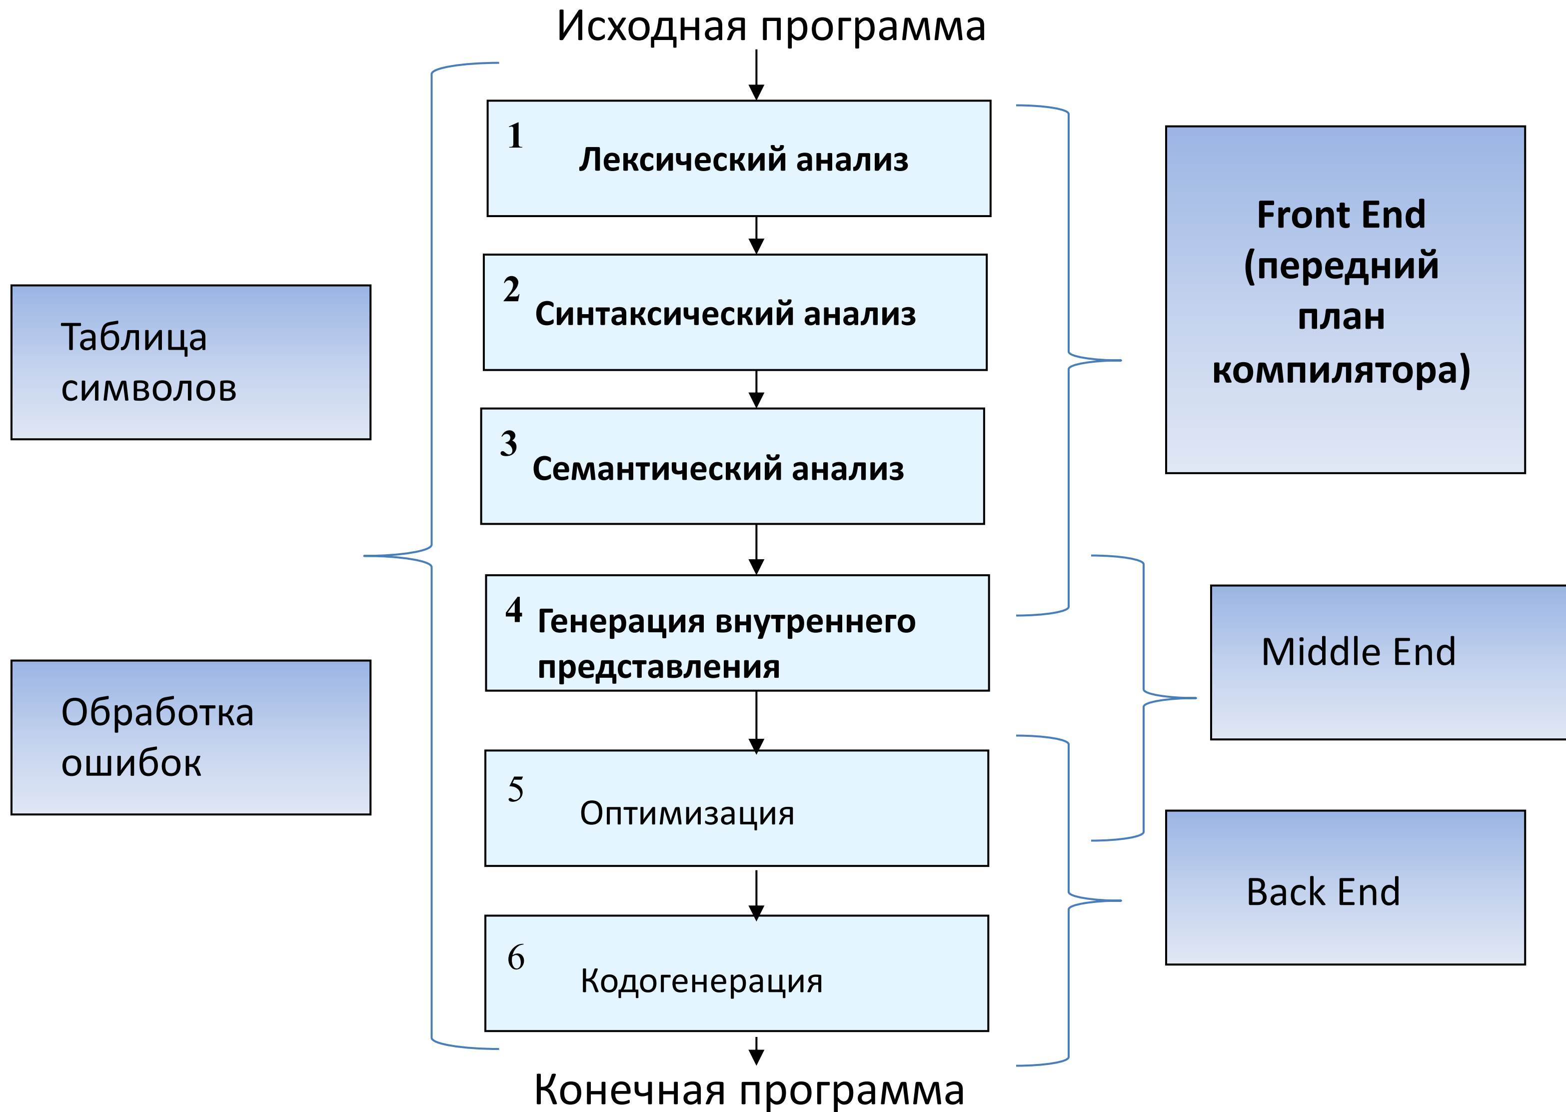

Bison

Грамматика для вычисления выражений в постфиксной записи (`rpcalc.y`) :

```
input:    /* empty */
        | input line
;

line:     '\n'
        | exp '\n'  { printf ("\t%.10g\n", $1); }
;

exp:      NUM             { $$ = $1;          }
        | exp exp '+'     { $$ = $1 + $2;     }
        | exp exp '-'     { $$ = $1 - $2;     }
        | exp exp '*'     { $$ = $1 * $2;     }
        | exp exp '/'     { $$ = $1 / $2;     }
      /* Exponentiation */
        | exp exp '^'     { $$ = pow ($1, $2); }
      /* Unary minus    */
        | exp 'n'         { $$ = -$1;         }
;
%%
```

Bison

Определения типов и токены :

```
%{
#define YYSTYPE double
#include <math.h>
%}

%token NUM

%% /* Grammar rules and actions follow */
```

Bison

Лексический анализатор:

```
#include <ctype.h>

yylex ()
{
  int c;

  /* skip white space  */
  while ((c = getchar ()) == ' ' || c == '\t')
    ;
  /* process numbers   */
  if (c == '.' || isdigit (c))
    {
      ungetc (c, stdin);
      scanf ("%lf", &yylval);
      return NUM;
    }
  /* return end-of-file  */
  if (c == EOF)
    return 0;
  /* return single chars */
  return c;
}
```

Bison

Управляющий файл:

```
main ()
{
  yyparse ();
}
```

Flex

```
%{
/* need this for the call to atof() below */
#include <math.h>
%}

DIGIT    [0-9]
ID       [a-z][a-z0-9]*

%%

{DIGIT}+    {
            printf( "An integer: %s (%d)\n", yytext,
                    atoi( yytext ) );
            }

{DIGIT}+"."{DIGIT}*        {
            printf( "A float: %s (%g)\n", yytext,
                    atof( yytext ) );
            }

if|then|begin|end|procedure|function        {
            printf( "A keyword: %s\n", yytext );
            }

{ID}        printf( "An identifier: %s\n", yytext );
```

Flex

```
"+"|"-"|"*"|"/"   printf( "An operator: %s\n", yytext );

"{"[^}\n]*"}"     /* eat up one-line comments */

[ \t\n]+          /* eat up whitespace */

.           printf( "Unrecognized character: %s\n", yytext );

%%

main( argc, argv )
int argc;
char **argv;
    {
    ++argv, --argc;  /* skip over program name */
    if ( argc > 0 )
            yyin = fopen( argv[0], "r" );
    else
            yyin = stdin;

    yylex();
    }
```