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 (4 по машинно-независимым, 2 по машинно-зависимым оптимизациям), по их результатам можно получить «автомат» за экзамен

Первая лекция – введение и обзор области

(материал этой лекции не войдет в контрольные)

Литература (1)

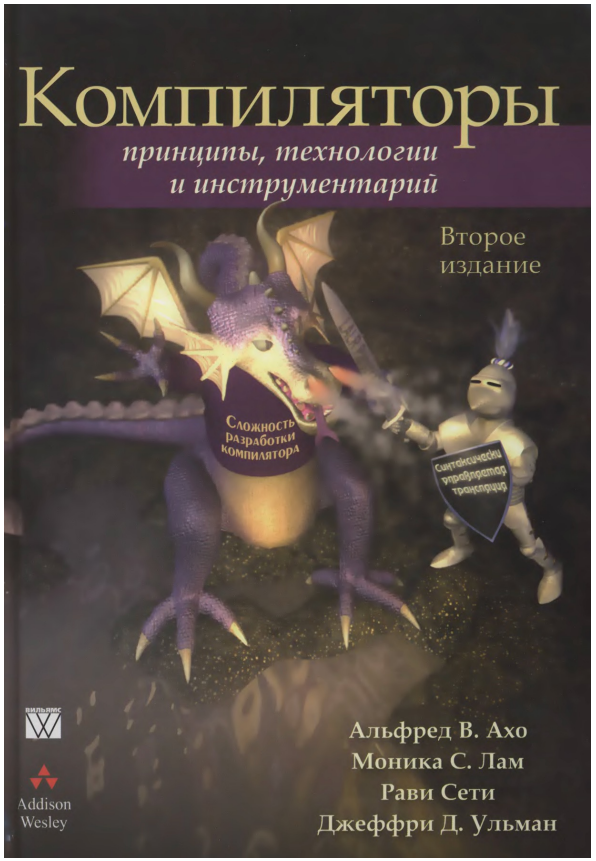

“Dragon Book”

Ахо, Лам, Сети, Ульман.

Компиляторы. Принципы, технологии, инструменты.

2-е издание (2008)

Литература (2)

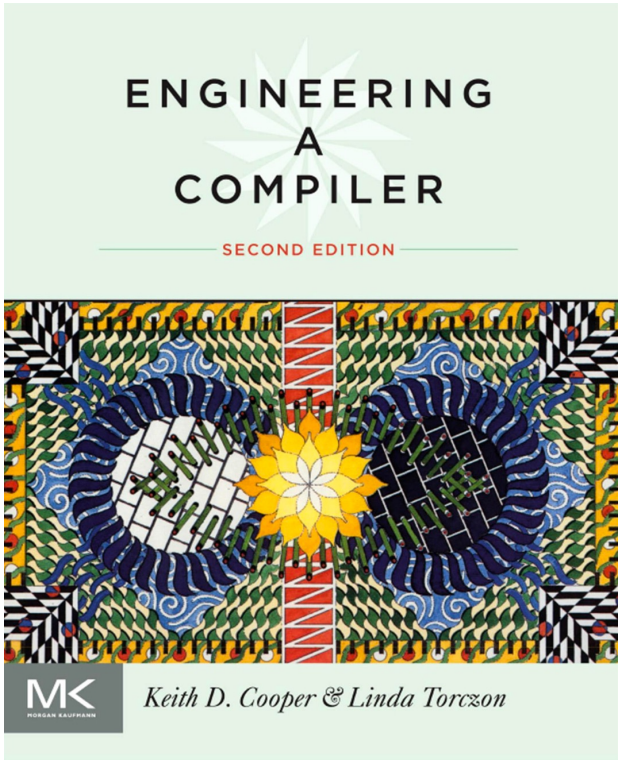

Keith D. Cooper, Linda Torczon. Engineering a Compiler (Second Edition)

Elsevier, Inc. 2012

Фазы компиляции

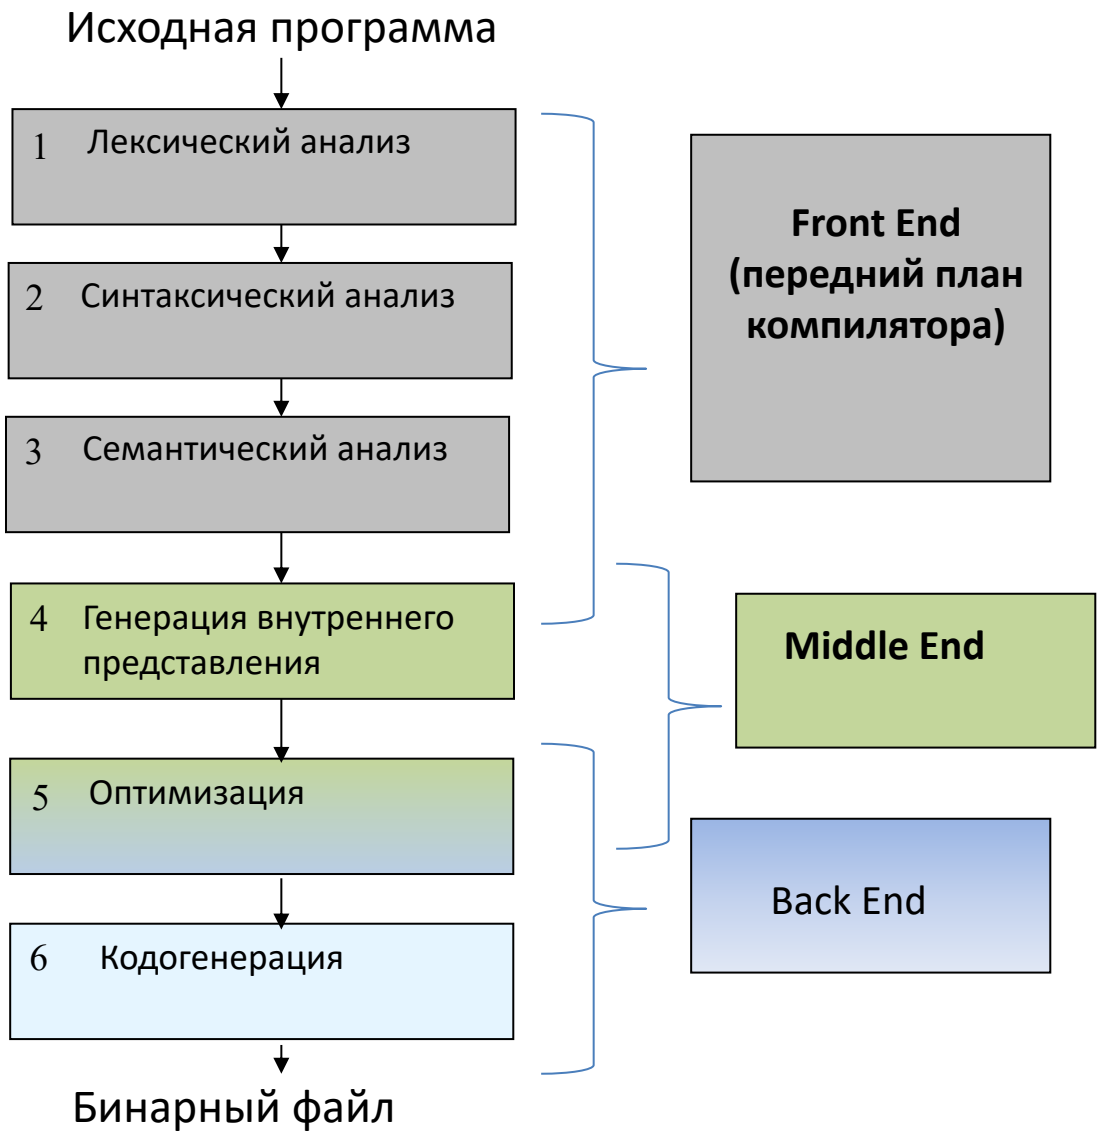

Препроцессирование

- 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;`**

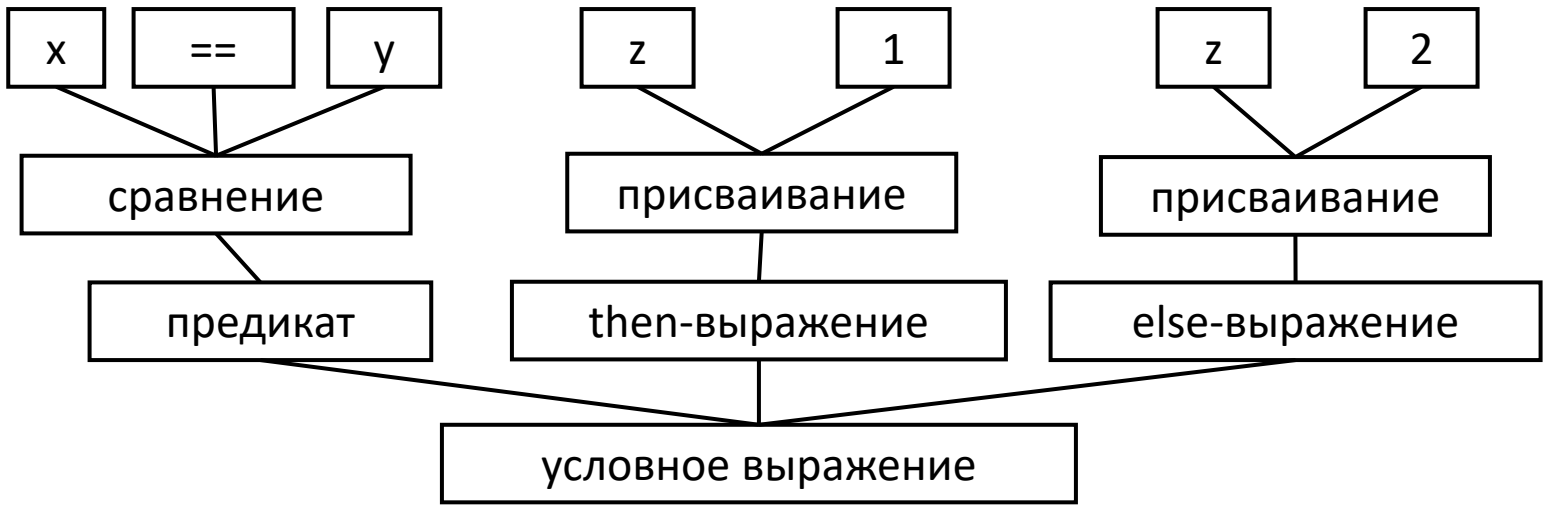

Семантический анализ

- Предложения языка могут быть многозначными
- Я встретил её 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;
```

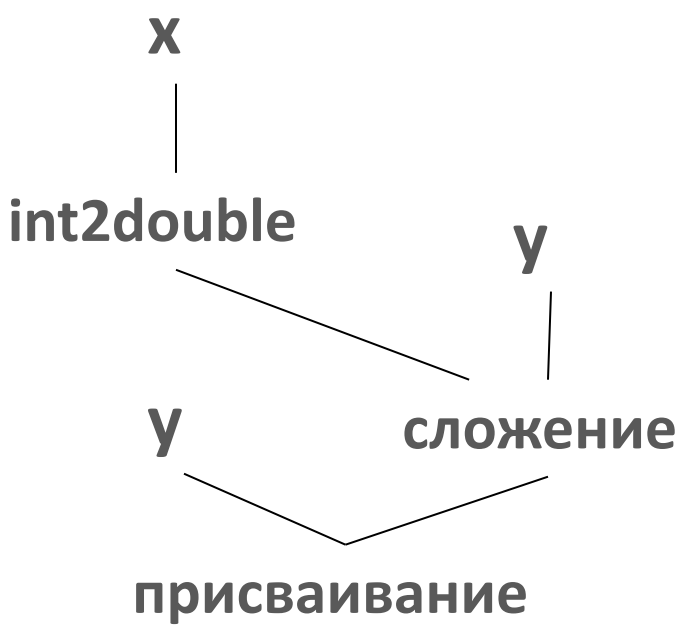

- Таблица имен заполняется в ходе всего анализа, начиная с лексического

Фазы компиляции

Структура front-end’a

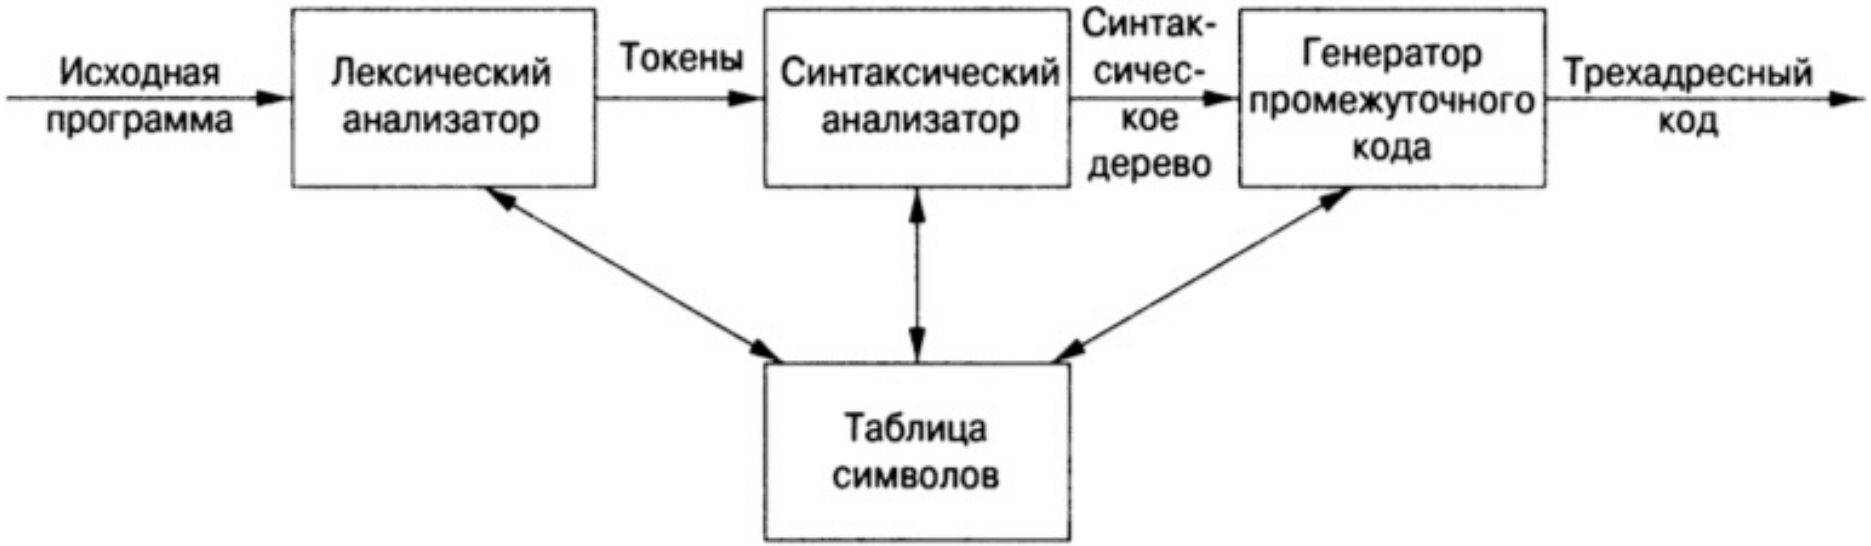

Трансляция во внутреннее представление

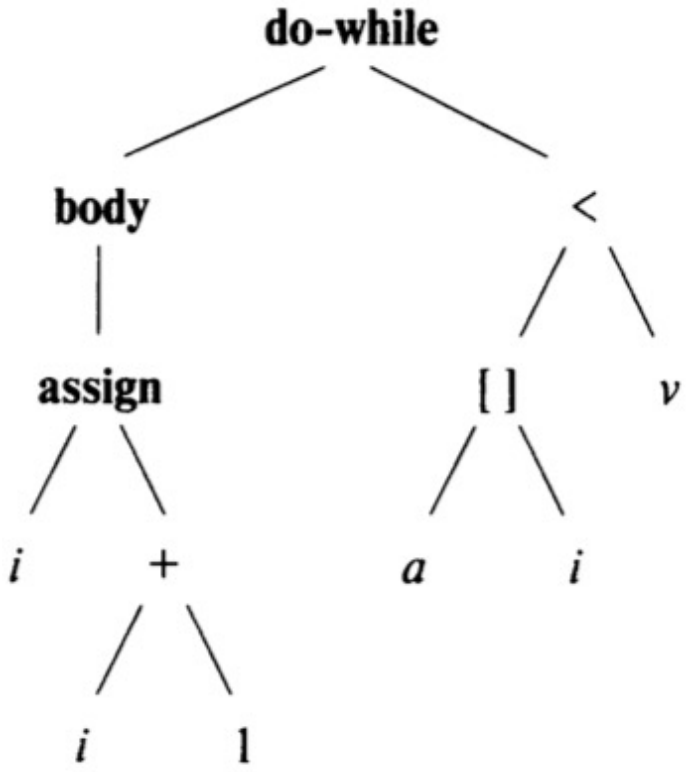

Абстрактное Синтаксическое Дерево (AST)

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

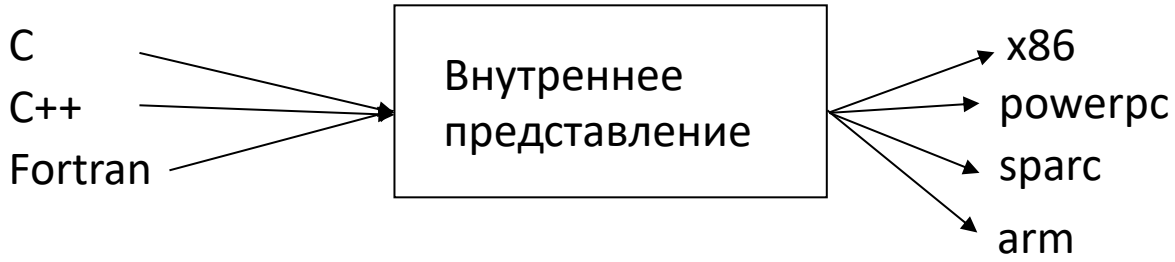

Внутреннее представление

- 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`
Аппаратные регистры (bx) и адресация памяти ([bx+4]) появляются на более поздних этапах компиляции, когда выполняются машинно-зависимые оптимизации.

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

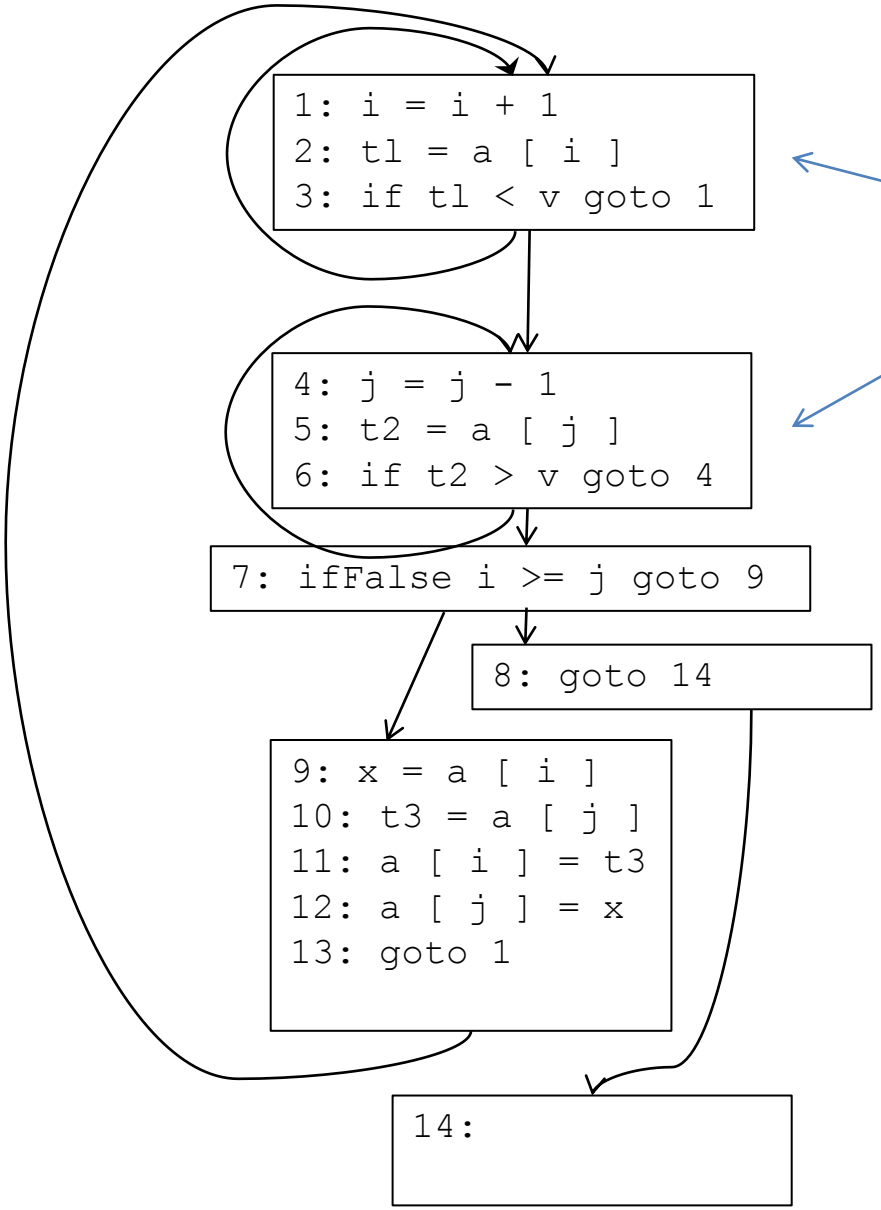

Базовые блоки

Граф потока управления /
Control Flow Graph (CFG)

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:

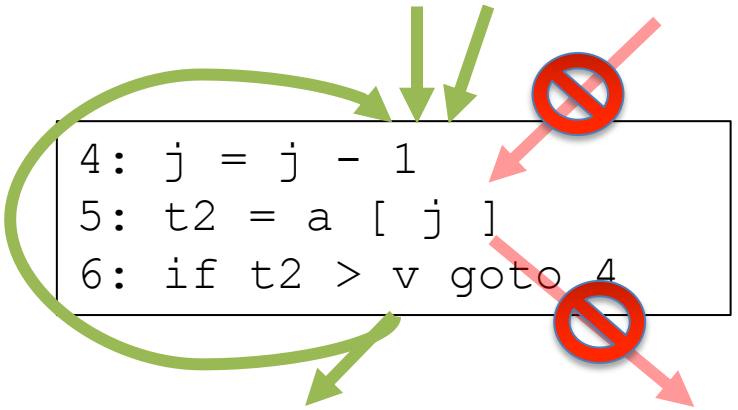

Дуги, передающие управление в/из середины базового блока, недопустимы (в таких случаях должны быть созданы отдельные базовые блоки)

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

$A \rightarrow X\ Y\ Z$

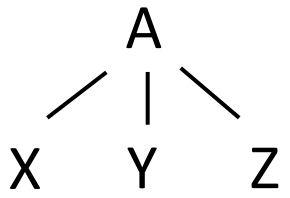

*list** → *list* + *digit*
list → *list* − *digit*
list → *digit*
digit → 0|1|2|3|4|5|6|7|8|9

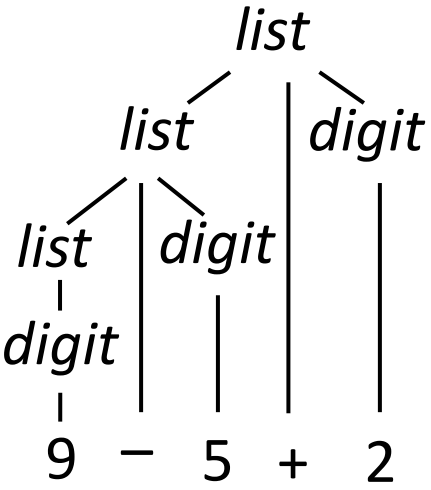

1. Корень дерева помечен стартовым символом.
2. Каждый лист помечен терминалом или ε.
3. Каждый внутренний узел помечен нетерминалом.
4. Если A является нетерминалом и помечает некоторый внутренний узел, а X_1, X_2, … ,X_n — метки его дочерних узлов слева направо, то должна существовать продукция $A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

Синтаксический анализ

$A \rightarrow X\ Y\ Z$

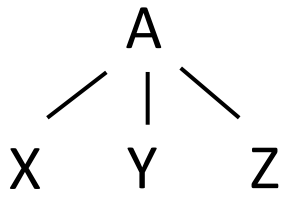

*list** → *list* + *digit*
list → *list* − *digit*
list → *digit*
digit → 0|1|2|3|4|5|6|7|8|9

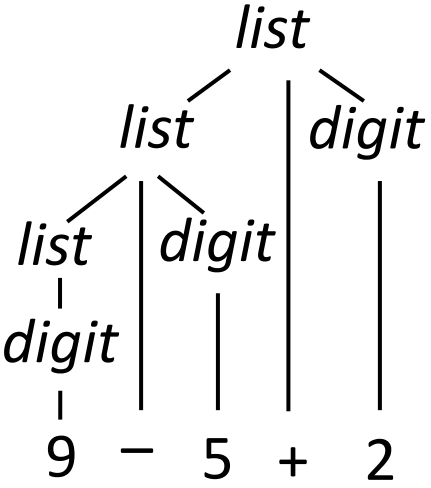

Процесс поиска дерева разбора для данной строки терминалов называется *разбором* (parsing) или *синтаксическим анализом* этой строки.

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

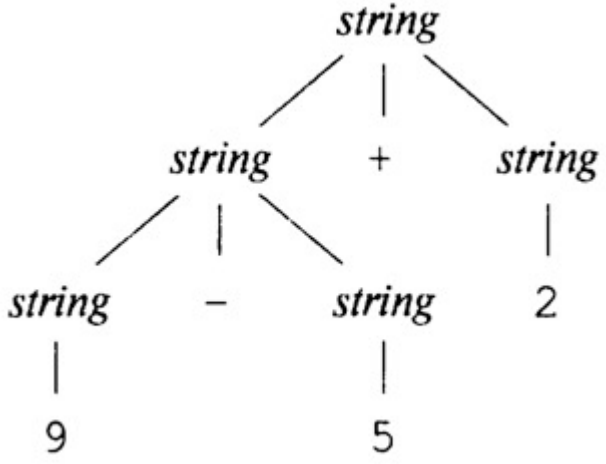

(9-5)+2

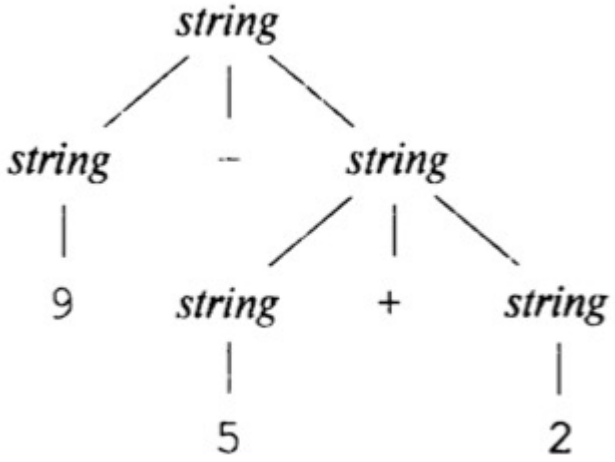

9–(5+2)

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

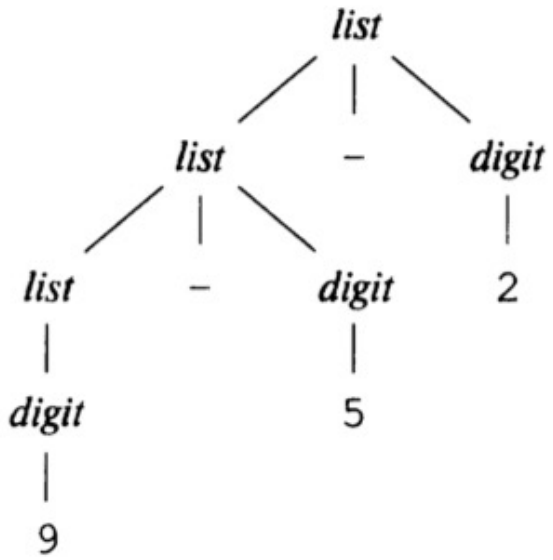

Правоассоциативные

Примеры: =

$a = b = c \Leftrightarrow a = (b = c)$

right → letter = right | letter

letter → a | b | … | z

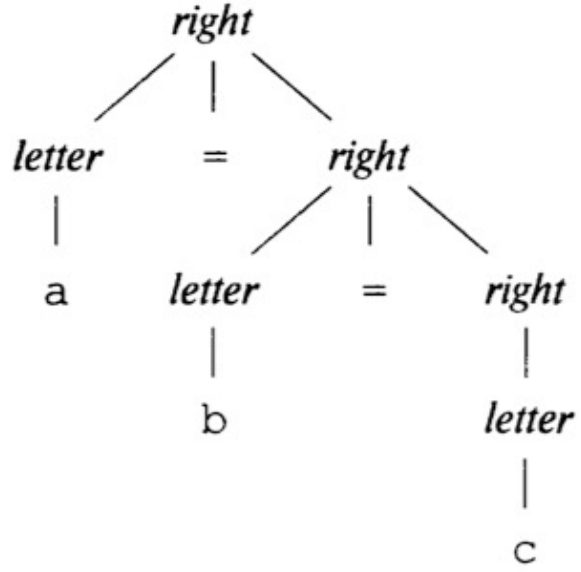

Приоритет операторов

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

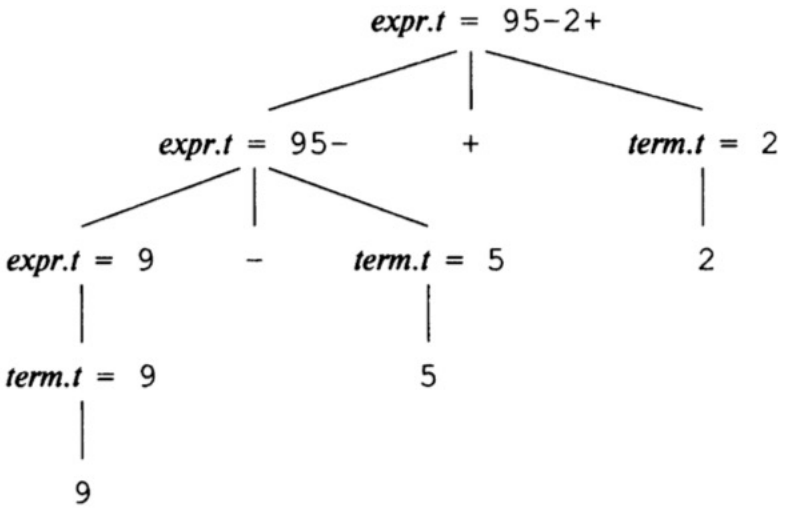

Синтезированный атрибут для символа X (вершины дерева разбора) вычисляется на основе атрибутов потомков и самого узла X

Унаследованные атрибуты вычисляются на основе атрибутов предков узла.

Синтаксически управляемые определения

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

|| – конкатенация строк

Схема Трансляции

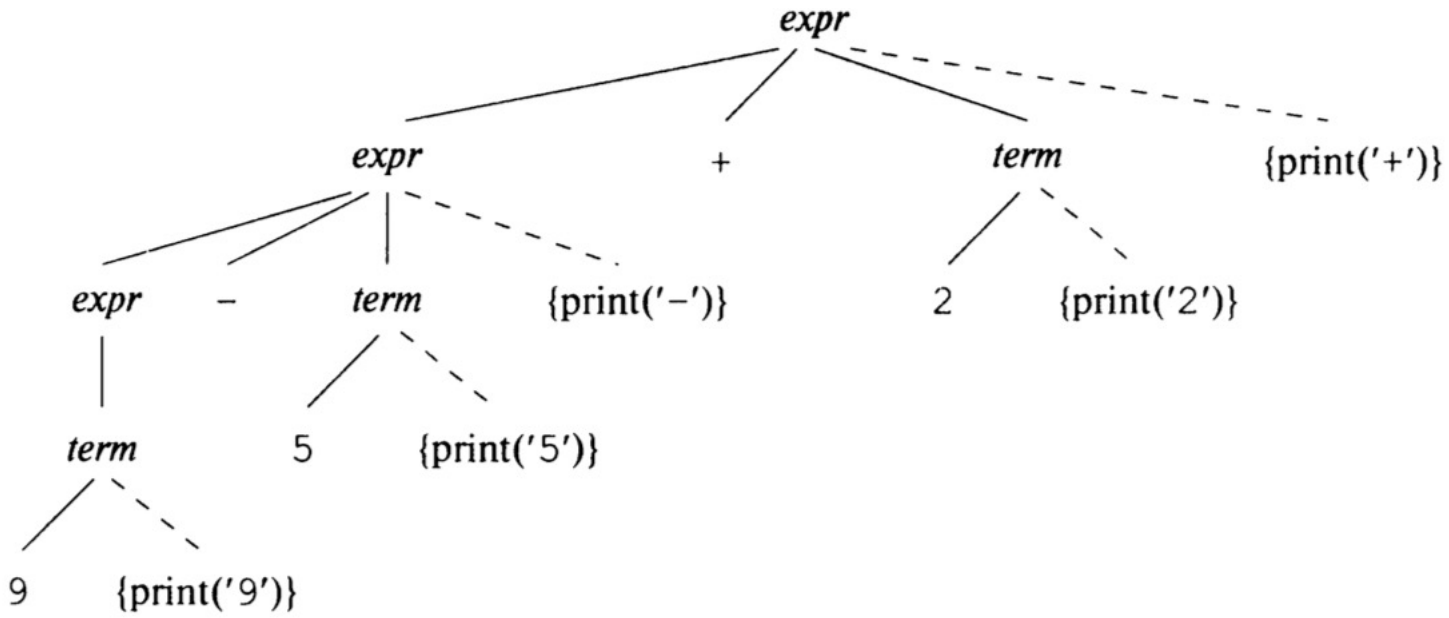

Правила, дополненные семантическими действиями

expr	→	$expr_1$ + *term*	{print('+')}
expr	→	$expr_1$ – *term*	{print('–')}
expr	→	*term*	
term	→	0	{print('0')}

Метод Рекурсивного Спуска

Пример грамматики

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

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

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

optexpr → ϵ
| **expr**

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)

FIRST(**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 → A α | β

Это правило порождает последова-тельности вида:

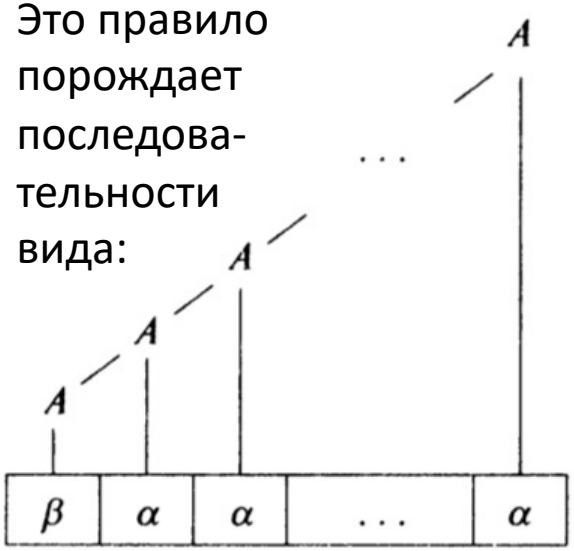

⇒

Ту же последова-тельность можно получить и другим способом:

A → A α | β

⇒

A → β R
R → α R | ε

Устранение Левой Рекурсии в Схеме Трансляции

Удаление рекурсии: $A \rightarrow A\,\alpha \mid A\,\beta \mid \Upsilon \quad \Rightarrow \quad \begin{array}{l} A \rightarrow \Upsilon\, R \\ R \rightarrow \alpha\, R \mid \beta\, R \mid \varepsilon \end{array}$

Преобразуем схему трансляции:

$$
\begin{array}{lcll}
expr & \rightarrow & expr_1 + term & \{\text{print}('+')\} \\
expr & \rightarrow & expr_1 - term & \{\text{print}('-')\} \\
expr & \rightarrow & term & \\
term & \rightarrow & 0 & \{\text{print}('0')\}
\end{array}
$$

Учитывая, что

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

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

Устранение Левой Рекурсии в Схеме Трансляции

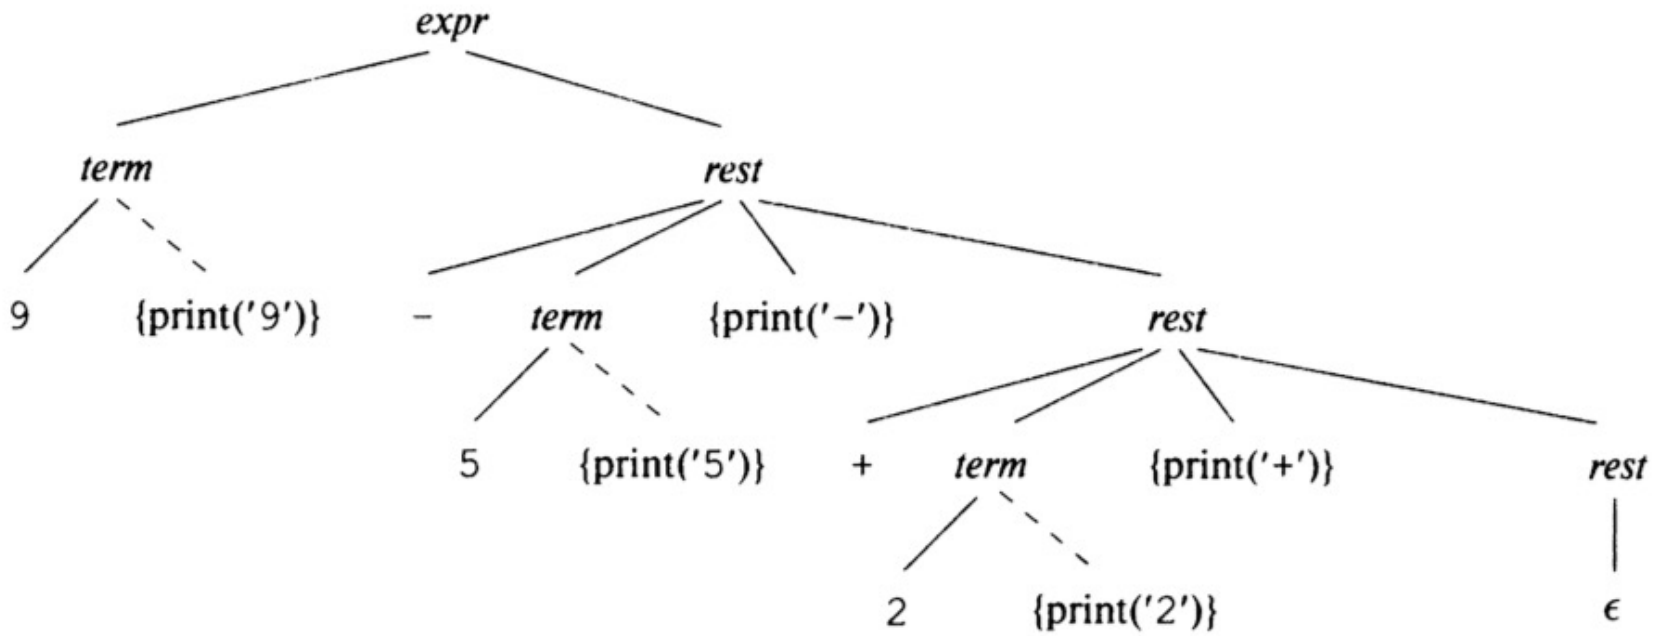

$(9 – 5) + 2 \Rightarrow 9\ 5 – 2 +$

Реализация Схемы Синтаксически Управляемой Трансляции

expr	→	*term rest*
rest	→	+ *term* { print('+') } *rest*
	|	− *term* { print('−') } *rest*
	|	ϵ
term	→	0 { print('0') }

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

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

```
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

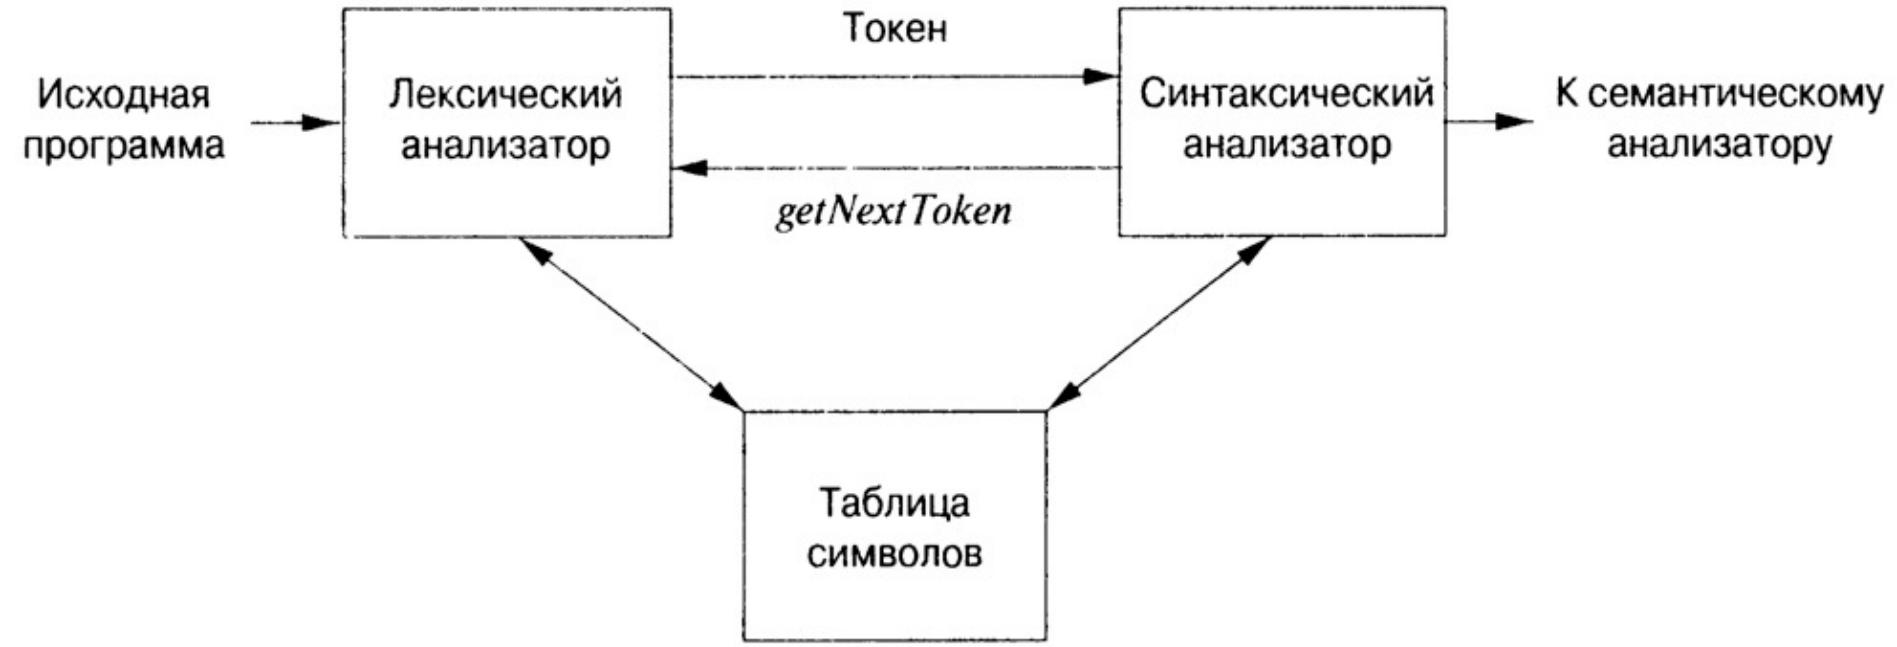

Абстрактное Синтаксическое Дерево

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:

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

Построение Абстрактного Синтаксического Дерева (AST)

$$
\begin{array}{rcll}
\mathit{program} & \rightarrow & \mathit{block} & \{ \text{return } \mathit{block.n}; \} \\
\mathit{block} & \rightarrow & \text{'}\{\text{'}\ \mathit{stmts}\ \text{'}\}\text{'} & \{ \mathit{block.n} = \mathit{stmts.n}; \} \\
\mathit{stmts} & \rightarrow & \mathit{stmts}_1\ \mathit{stmt} & \{ \mathit{stmts.n} = \textbf{new}\ \mathit{Seq}\,(\mathit{stmts}_1.n, \mathit{stmt.n}); \} \\
 & | & \epsilon & \{ \mathit{stmts.n} = \textbf{null}; \} \\
\mathit{stmt} & \rightarrow & \mathit{expr}\ ; & \{ \mathit{stmt.n} = \textbf{new}\ \mathit{Eval}\,(\mathit{expr.n}); \} \\
 & | & \textbf{if}\ (\ \mathit{expr}\ )\ \mathit{stmt}_1 & \{ \mathit{stmt.n} = \textbf{new}\ \mathit{If}\,(\mathit{expr.n}, \mathit{stmt}_1.n); \} \\
 & | & \textbf{while}\ (\ \mathit{expr}\ )\ \mathit{stmt}_1 & \{ \mathit{stmt.n} = \textbf{new}\ \mathit{While}\,(\mathit{expr.n}, \mathit{stmt}_1.n); \} \\
 & | & \textbf{do}\ \mathit{stmt}_1\ \textbf{while}\ (\ \mathit{expr}\ )\ ; & \{ \mathit{stmt.n} = \textbf{new}\ \mathit{Do}\,(\mathit{stmt}_1.n, \mathit{expr.n}); \} \\
 & | & \mathit{block} & \{ \mathit{stmt.n} = \mathit{block.n}; \}
\end{array}
$$

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 + ":");
    }
}
```

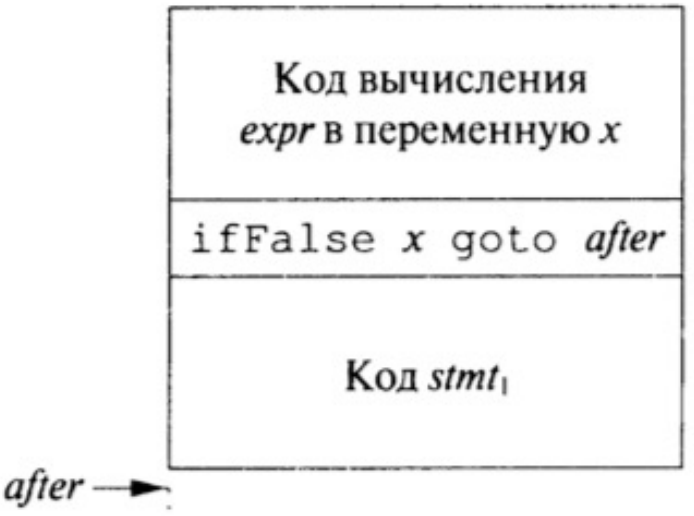

Трансляция Выражений

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

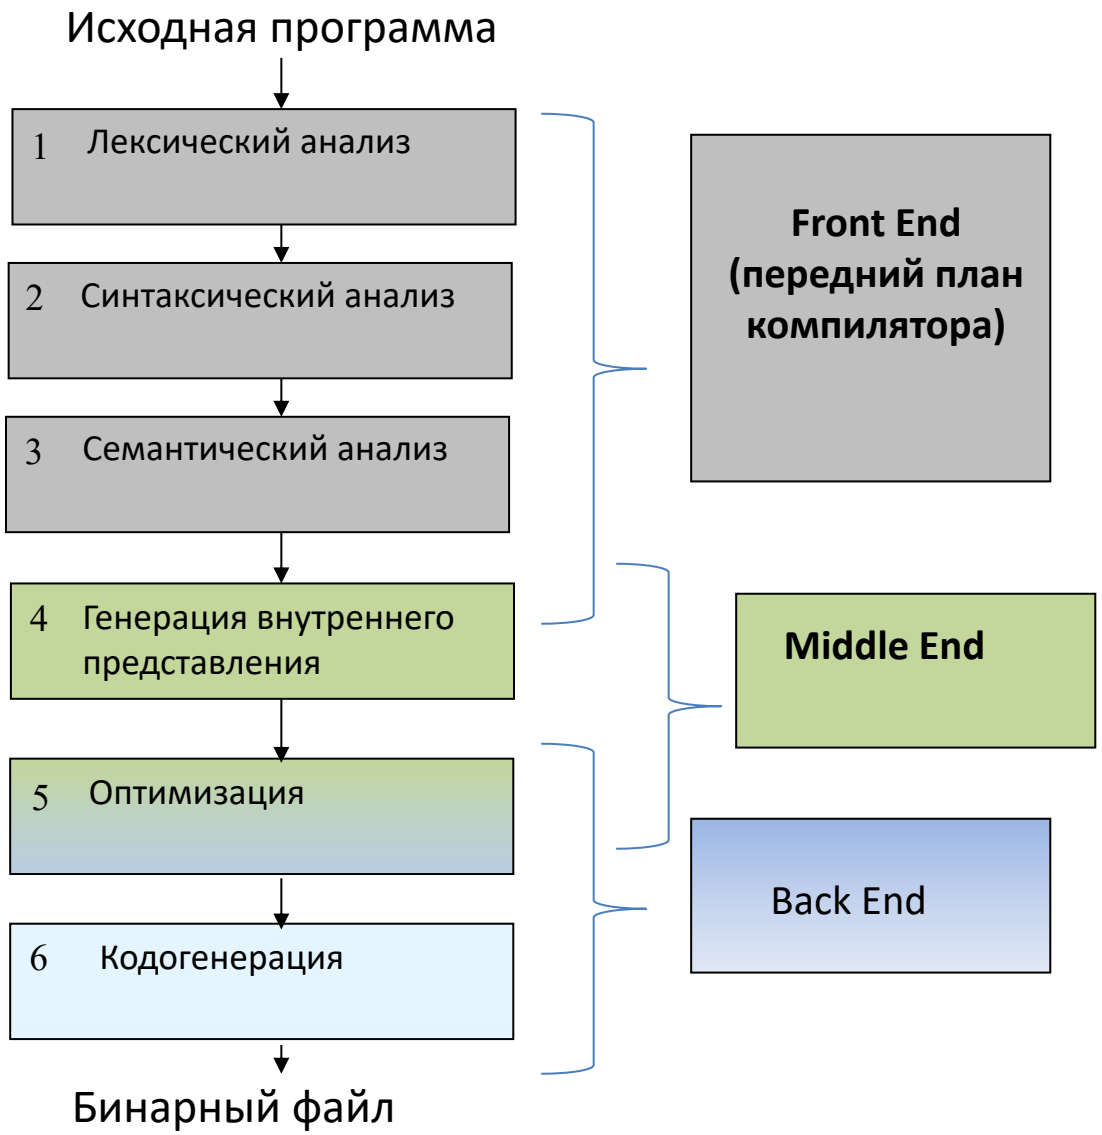

Bison

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();
    }
```