ОСНОВЫ ПРОГРАММНОГО КОНСТРУИРОВАНИЯ

Лекция № 13
27 ноября 2017 г.

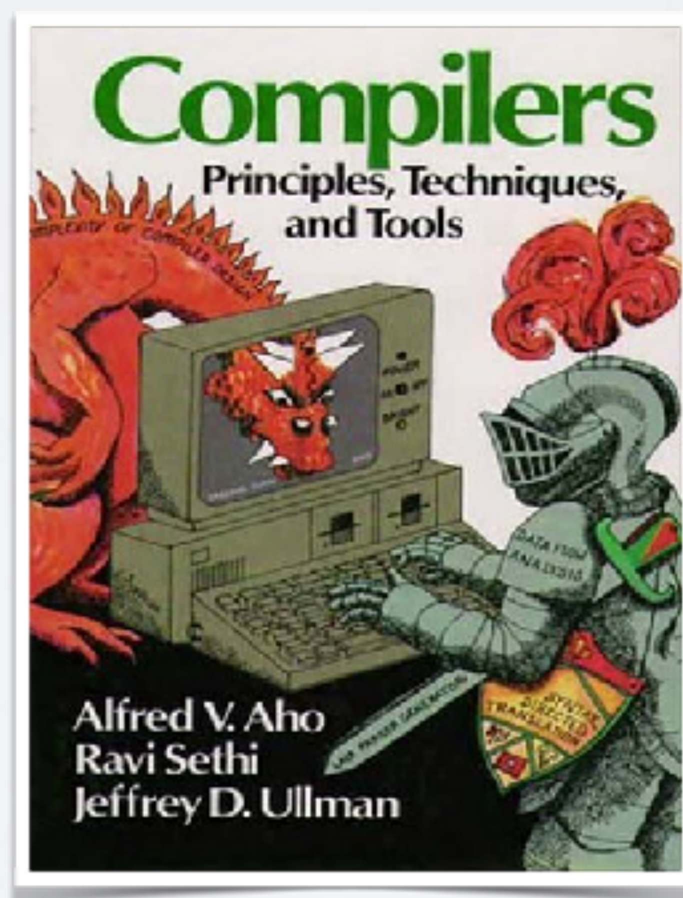

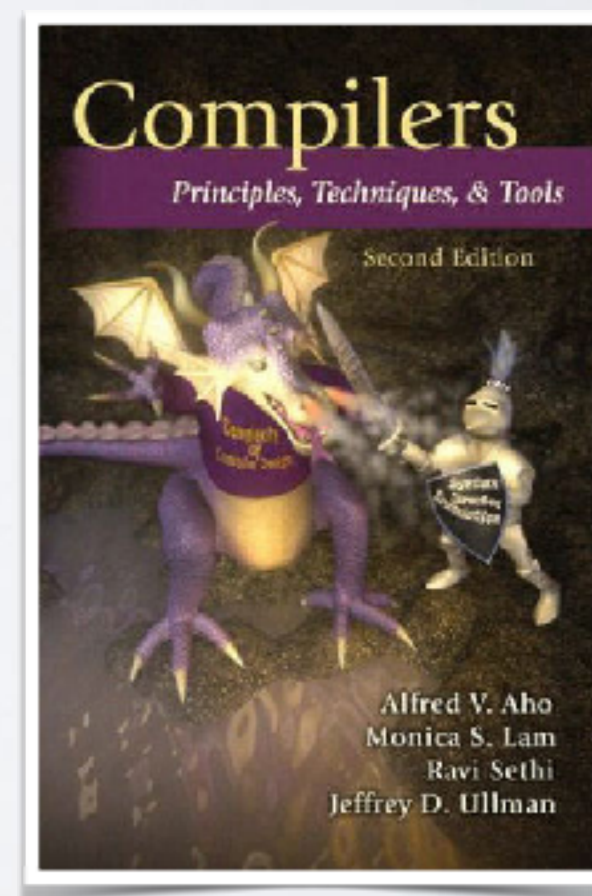

ТРАНСЛЯТОРЫ

Компиляторы, интерпретаторы, препроцессоры, конверторы, парсеры, анализаторы, форматтеры, проверяторы, …

Текст

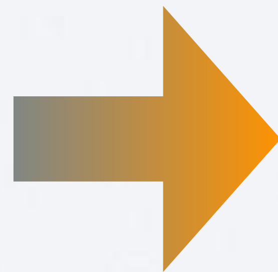

Нечто полезное

КОМПИЛЯТОР

Исходный текст

Анализ

Промежуточное представление

часто: синтаксическое дерево

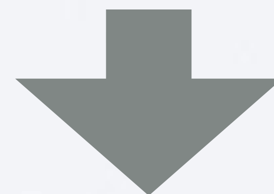

Синтез

Целевая программа

ОБ АНАЛИЗЕ

- Этапы:
  - Лексический анализ (*лексика = «слова»*).
  - Синтаксический анализ (*синтаксис = структура*).
  - Семантический анализ (*семантика = смысл*).
- Не во всех задачах трансляции присутствуют все этапы!

ЛЕКСИЧЕСКИЙ АНАЛИЗ (LEXER / SCANNER)

Пример: **`a = qq * (c--)`**

1. Идентификатор **a**.
2. Знак присвоения.
3. Идентификатор **qq**.
4. Знак умножения.
5. Левая скобка.
6. Идентификатор **c**.
7. Оператор декремента.
8. Правая скобка.

ЛЕКСИЧЕСКИЙ АНАЛИЗ (LEXER / SCANNER)

- На входе: текст.
- На выходе: поток *лексем*.
- «Съедаются» пробелы, переносы строки, часто – комментарии.
- Лексемы бывают:
  - Без атрибутов (означающие сами себя).
  - С атрибутом («идентификатор такой-то»). **Лексема = Токен + Атрибут**.
- Один и тот же поток лексем может порождаться различными текстами на входе.
- Ошибка: «не могу сделать лексему из того, что дали».

ИНТЕРФЕЙС СКАНЕРА

```
enum Token {
    LP = '(', RP = ')', ADD = '+', SUB = '-',
    MUL = '*', DIV = '/', NUM = 256, EOS, NONE
};

/* Remove current and get next. */
int lex_next();

/* Get current. */
int lex_lookahead();

/* Attribute of current. */
int lex_value();
```

РУЧНАЯ РЕАЛИЗАЦИЯ СКАНЕРА

```c
static int number, token = NONE;
int lex_next() {
    for (;;) {
        int c = getchar();

        if (c == EOF) {
            return token = EOS;
        } else if (isspace(c)) {
            continue;
        } else if (isdigit(c)) {
            number = c - '0';
            while ((c = getchar()), isdigit(c))
                number = number * 10 + c - '0';

            ungetc(c, stdin);
            return token = NUM;
        } else {
            return token = c;
        }
    }
}

int lex_value() { return number; }
int lex_lookahead() { return token == NONE ? lex_next() : token };
```

ПОСТРОЕНИЕ СКАНЕРОВ

- Недетерминированный конечный автомат (НКА):
  - Набор состояний.
  - Стартовое состояние.
  - Алфавит.
  - Переходы:
    Состояние → { Набор возможных состояний }.
  - Набор финальных состояний.

РЕГУЛЯРНЫЕ ВЫРАЖЕНИЯ

Символ	Значение	Символ	Значение
a	Символ **a**	**a?**	**(a|ε)**
a|b|c	Либо a, либо b, либо c	**a+**	**aa***
a*	Повторение a – 0 или более раз	**[a-z]**	**a|b|…|z**
(r)	Подвыражение	**.**	Любой символ

Пример выражения: **(a|b)*a(a|b)(a|b)**

НКА И ДКА

Детерминированный конечный автомат: из каждого состояния переход в следующее состояние однозначен.

НКА

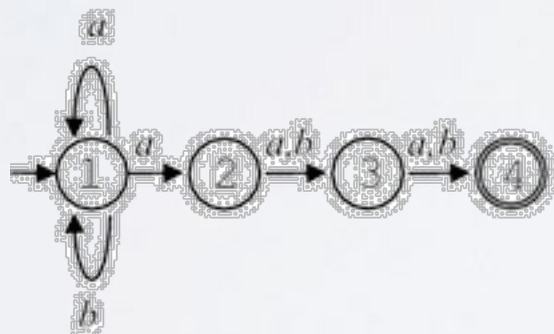

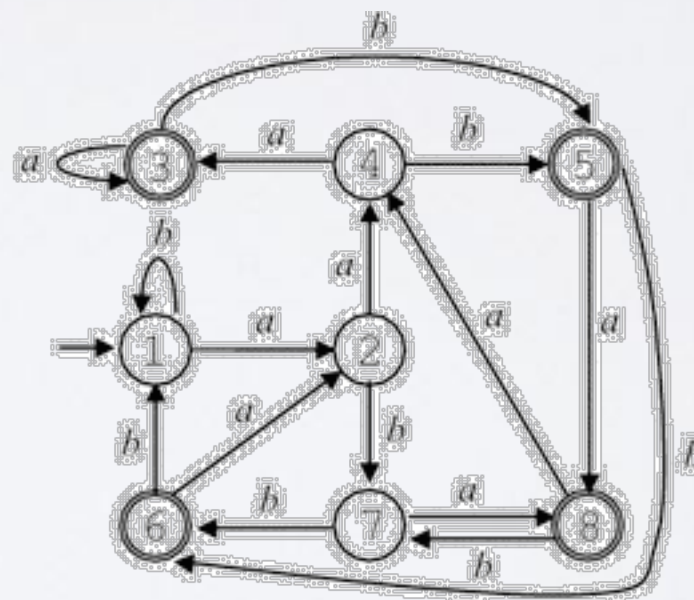

ДКА

Конечные автоматы для **(a|b)*a(a|b)(a|b)**

ПОСТРОЕНИЕ СКАНЕРА

- Набор соответствий «Рег. выражение – токен».
- Итог: один большой автомат с финальными состояниями там, где кончаются отдельные токены.

Рег. выражение	Токен
(	LP
)	RP
+	ADD
-	SUB
*	MUL
/	DIV
[0-9]+	NUMBER

ГЕНЕРАТОР RAGEL

```
action dgt      { printf("DGT: %c\n", fc); }
action dec      { printf("DEC: .\n"); }
action exp      { printf("EXP: %c\n", fc); }
action exp_sign { printf("SGN: %c\n", fc); }
action number   { /*NUMBER*/ }

number = (
    [0-9]+ $dgt ( '.' @dec [0-9]+ $dgt )?
    ( [eE] ( [+\-] $exp_sign )? [0-9]+ $exp )?
) %number;

main := ( number '\n' )*;
```

```
st0:
    if ( ++p == pe )
        goto out0;
    if ( 48 <= (*p) && (*p) <= 57 )
        goto tr0;
    goto st_err;
tr0:
    { printf("DGT: %c\n", (*p)); }
st1:
    if ( ++p == pe )
        goto out1;
    switch ( (*p) ) {
        case 10: goto tr5;
        case 46: goto tr7;
        case 69: goto st4;
        case 101: goto st4;
    }
    if ( 48 <= (*p) && (*p) <= 57 )
        goto tr0;
    goto st_err;
```

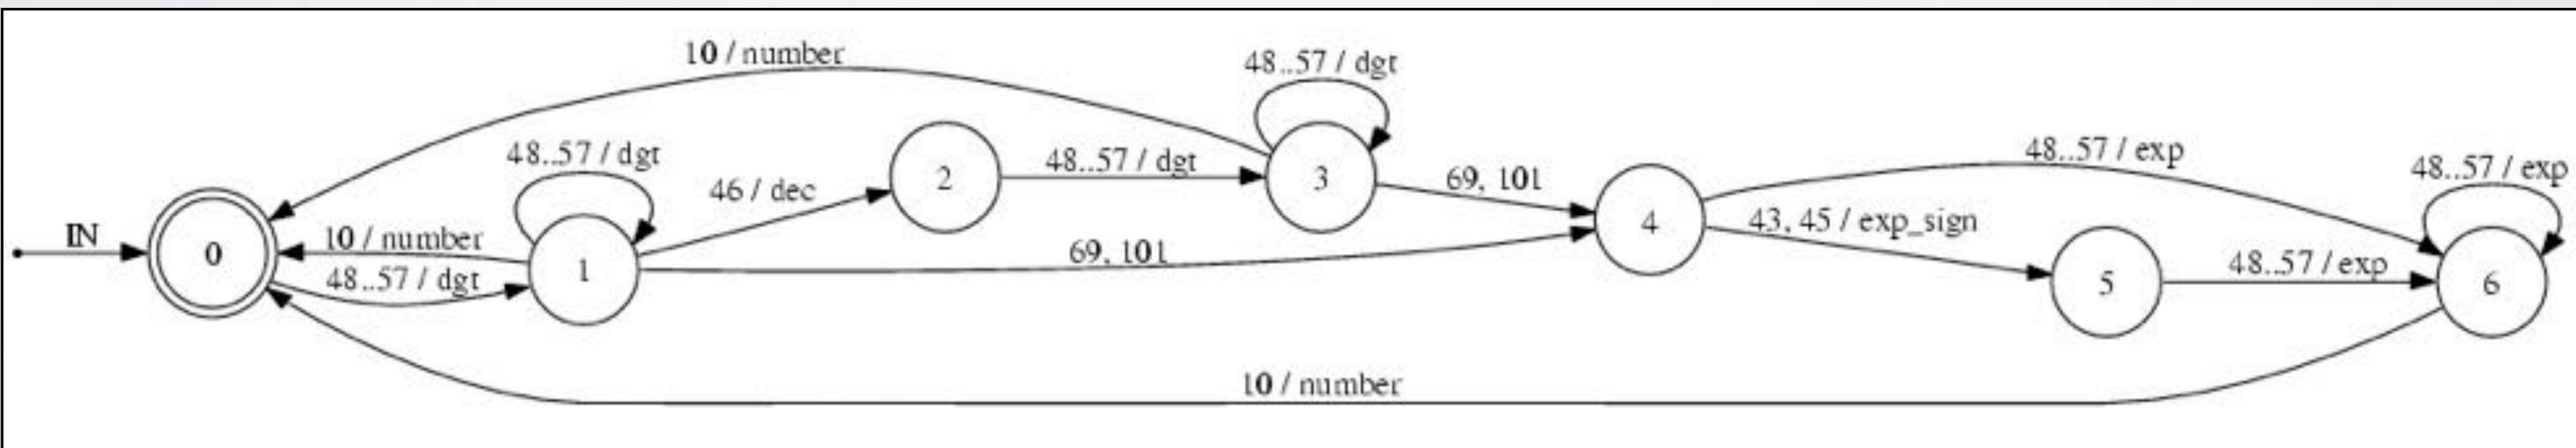

СИНТАКСИЧЕСКИЙ АНАЛИЗ

- Понятие порождающей грамматики: **G = (Σ, N, S, P)**.
  - **Σ** – алфавит терминальных символов, или *терминалов* (тех символов, которые можно использовать для записи предложений языка).
  - **N** – алфавит нетерминальных символов (*нетерминалов*, вспомогательных символов, металингвистических или синтаксических переменных).
  - **S** – символ из **N** (начальный/стартовый символ).
  - **P** – набор правил вывода. Формат правила: $\alpha \rightarrow \beta$, где α и β – цепочки, состоящие из символов (**Σ ∪ N**).

СКОБОЧНАЯ ГРАММАТИКА

- Терминалы (**Σ**): ‘**(**’ и ‘**)**’.
- Нетерминалы (**N**): **EXPR** и **Q**.
- Стартовый нетерминал (**S**): **EXPR**.

- Правила вывода (**P**):
  - **EXPR → Q**
  - **Q → ()**
  - **Q → (Q)**
  - **Q → QQ**

Корректные выражения: **(), ()()(), (((((())))))()()**, …

Некорректные выражения: **)(, (((, (aa)**

ДЕРЕВО РАЗБОРА

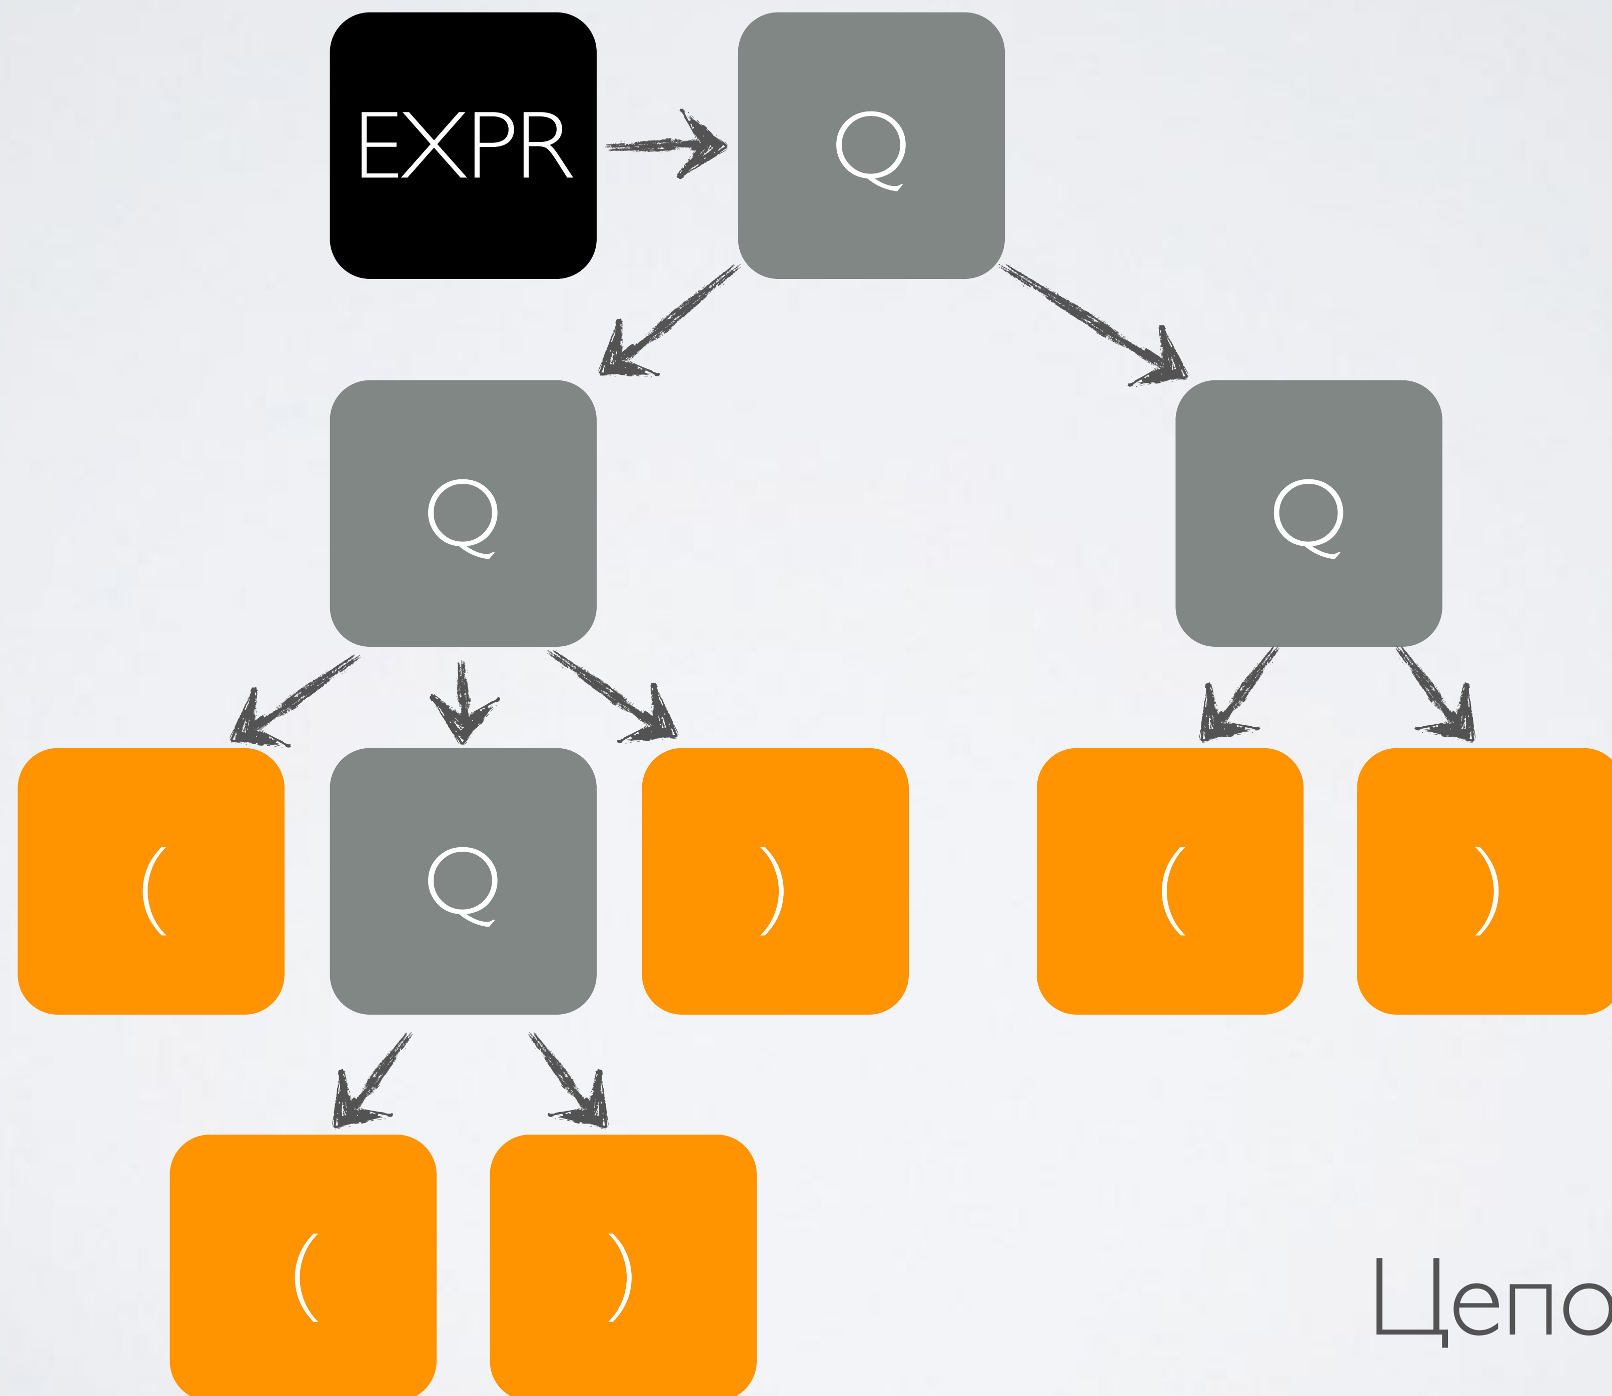

Цепочка (())()

КОНТЕКСТНО-СВОБОДНЫЕ ГРАММАТИКИ

- Ограничение на правила вывода: только **N**$\rightarrow\beta$ (**N** – нетерминал).
- Свойство *локальности* и *независимости* подстановок: подстановка, выполняемая в каком-то месте, не влияет на прочие подстановки за пределами этого места.
- Достаточно полно описывают существующие языки программирования.
- Есть алгоритмы синтаксического анализа.

ГРАММАТИКА ВЫРАЖЕНИЙ

- Наивный подход:
  - $E \to E + E$
  - $E \to E - E$
  - $E \to NUM$

- 2−3−4: (2−3)−4 или 2−(3−4) ?
- Левоассоциативные и правоассоциативные операторы.

УЧИТЫВАЕМ АССОЦИАТИВНОСТЬ

- Шаг в нужную сторону:
  - E → E + NUM
  - E → E − NUM
  - E → NUM
- Более короткая запись:
  - E → E + NUM | E − NUM | NUM

ДОБАВЛЯЕМ УМНОЖЕНИЕ

Так пойдет?

E → E + NUM | E – NUM | E * NUM | E / NUM | NUM

Не учтены приоритеты!

В дереве разбора операции * и /
должны стоять пониже, ближе к листьям.

ПРАВИЛЬНОЕ УМНОЖЕНИЕ

- Добавляем еще один нетерминал, **F**:
  - **E → E + T | E − T | T**
  - **T → T * F | T / F | F**
  - **F → NUM**
- А как добавить скобки?
  - **F → (E)**

НАПРАВЛЕНИЯ РАЗБОРА

- Нисходящий разбор (от корня к листьям).
- Восходящий разбор (от листьев к корню).

МЕТОД РЕКУРСИВНОГО СПУСКА

- Нисходящий разбор.
- Годится только для грамматик класса **LL(1)**:
  - Отсутствие левой рекурсии (**A→Aβ**).
  - Однозначность.
  - Глубина просмотра 1 (текущий токен однозначно определяет правило вывода).

ГРАММАТИКА ВЫРАЖЕНИЙ И РЕКУРСИВНЫЙ СПУСК

- Годная грамматика:
  - E → T { [+−] T }*
  - T → F { [*/] F }*
  - F → NUM | (E)
- На каждый нетерминал заводим отдельную функцию.

ИСХОДНЫЙ КОД ПРОВЕРЯТОРА

```
void E() {
    T();
    for (;;) {
        if (lex_lookahead() == ADD || lex_lookahead() == SUB) {
            lex_next();
            T();
        } else {
            break;
        }
    }
}

void F() {
    if (lex_lookahead() == LP) {
        lex_next();
        E();
        match(RP);
    } else {
        NUM();
    }
}

void match(int token) {
    if (lex_lookahead() == token) {
        lex_next();
    } else {
        error();
    }
}
```

E → T { [+−] T }*

T → F { [*/] F }*

F → NUM | (E)

ПОЛЕЗНАЯ ПРОДУКЦИЯ

- При вычислении выражения:
  - Каждая функция возвращает значение подвыражения.
- При построении синтаксического дерева:
  - Каждая функция возвращает указатель на построенный ей узел дерева.
  - Потомками этого узла являются значения, возвращенные другими функциями-нетерминалами.

ОБРАБОТКА ОШИБОК

- Функция match().
- В приведенном примере все нераспознанное попадает в функцию NUM().
- Функция, соответствующая стартовому нетерминалу, должна «проглотить» все выражение.

ПОЛНЫЙ ПРИМЕР

Исходный код лексера и парсера для вычисления простых арифметических выражений:

https://github.com/cypok/simple_parser

```
Tokenization of <2 + 2 * 2 + (37 - 35)>:
2 ADD 2 MUL 2 ADD LP 37 SUB 35 RP EOS

Evaluated 2 + 2 * 2 + (37 - 35) to 8
```

КОНЕЦ ТРИНАДЦАТОЙ ЛЕКЦИИ