中国科学技术大学
University of Science and Technology of China

语法分析 I

《编译原理和技术(H)》

张昱

0551-63603804，yuzhang@ustc.edu.cn

中国科学技术大学

计算机科学与技术学院

本章内容

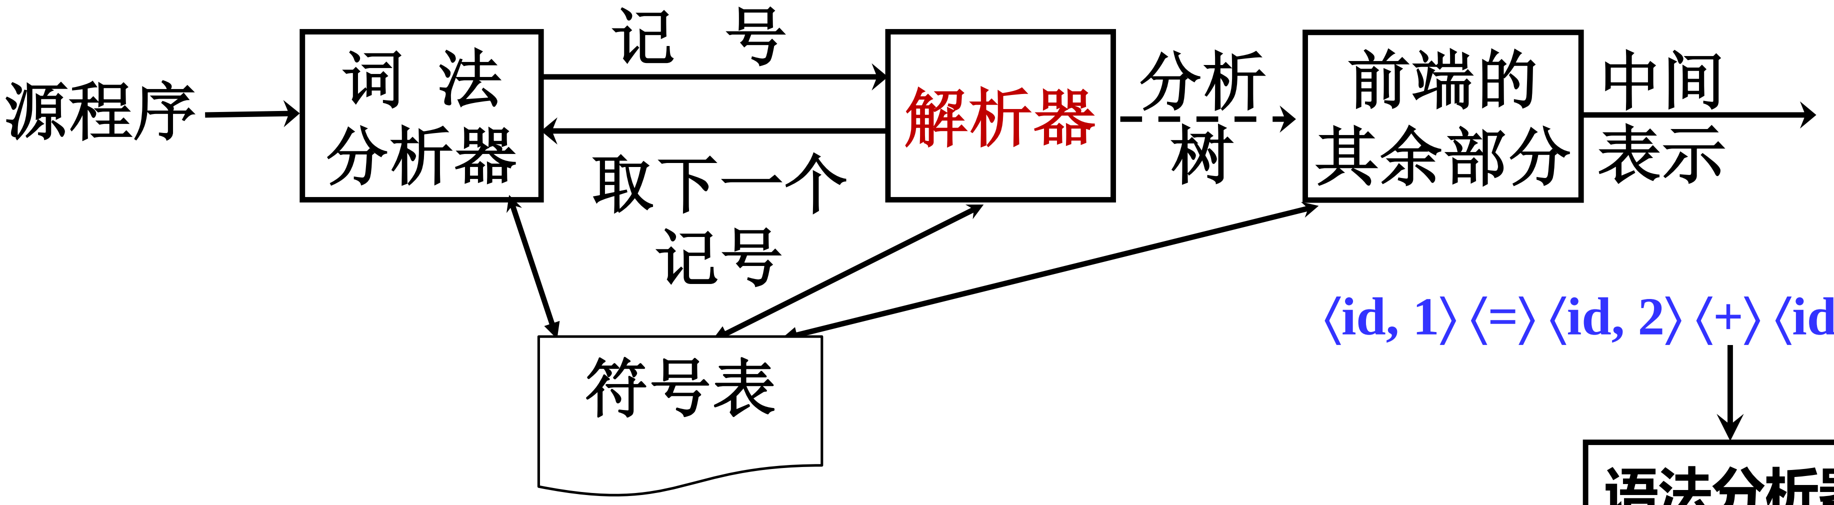

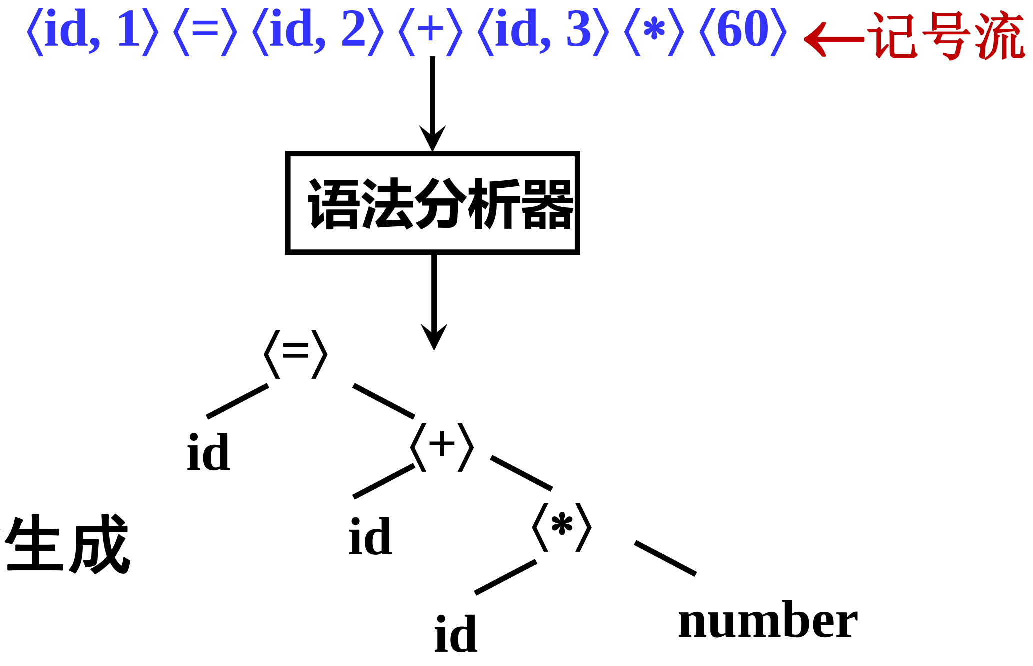

- 语法的形式描述：上下文无关文法
- 语法分析：自上而下、自下而上
- 语法分析器(parser、syntax analyzer)的自动生成
  - LL(k)、ALL(*)、SLR(k)、LR(k)、LALR(k)

3.1 上下文无关文法

- 正规式与上下文无关文法的比较
- 上下文无关文法的一些基本概念
  - 定义、推导、二义性
  - 名词：语言、文法等价、句型、句子

正规式的表达能力不足

正规式的表达能力

- 定义一些简单的语言，能表示给定结构的固定次数的重复或者没有指定次数的重复

  例：$a\,(ba)^5, a\,(ba)^*$

- 不能描述**配对或嵌套**的结构
  - 例1：配对括号串的集合，如不能表达 $(^n)^n, n \geq 1$

    原因：n不固定，无法表示右括号的个数必须正好与前面左括号的个数一样
  - 例2：$\{wcw \mid w$是由a和b组成的串$\}$

    原因：w的长度不固定，c后面的串要依据c前面不定长的串w来确定；

  有限自动机有有限个状态，无法记录访问同一状态的次数

正规式的表达能力不足

例：$L=\{a^nb^n \mid n \geq 1\}$，$L$不能用正规式描述

反证法

- 若存在接受L 的DFA D，状态数为k个（有限个）
- 设 D 读完ε, a, aa, …, a^k 分别到达状态s_0，s_1, …, s_k
- 至少有两个状态相同，例如是s_i和 s_j，则$a^j b^i$属于L，这与假设相矛盾

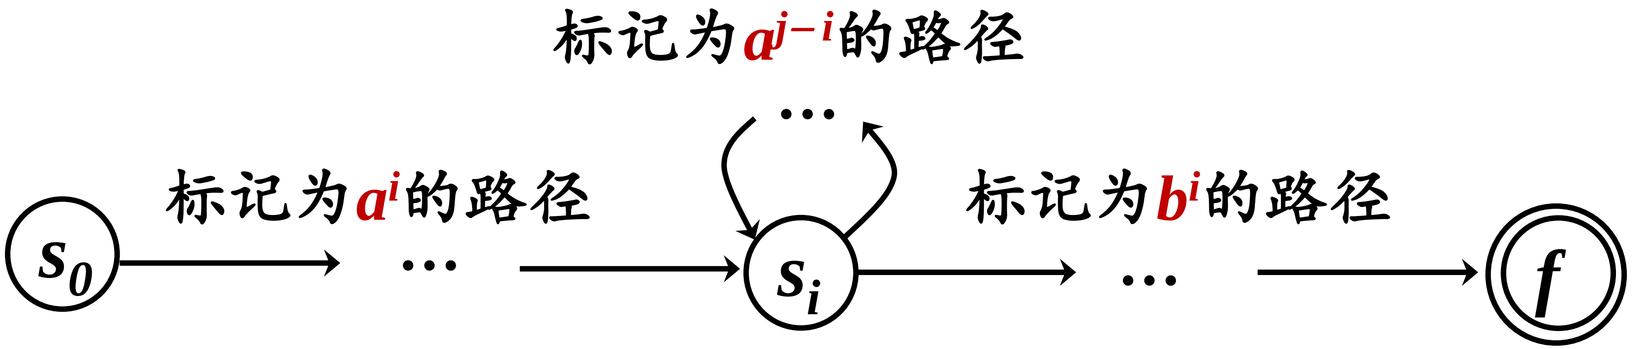

上下文无关文法的定义

Context-free Grammar（CFG） 注：**Syntax-语法**

- **CFG是四元组（V_T, V_N, S, P）**

  V_T : 终结符(terminal, 记号名，即token的第1元)集合

  V_N : 非终结符(nonterminal)集合

  S : 开始符号(start symbol)，是一个非终结符

  P : 产生式(production)集合

  产生式的形式 : $A \rightarrow \alpha$， $A \in V_N, \alpha \in (V_T \cup V_N)^*$

  有时用 $A ::= \alpha$

- **例 ({id, +, *, −, (,)}, {*expr*, *op*}, *expr*, *P*)** 第一个产生式左部的符号就是文法开始符号

  $expr \rightarrow expr\ op\ expr$ $expr \rightarrow (expr)$ $expr \rightarrow -\ expr$

  $expr \rightarrow \mathrm{id}$ $op \rightarrow +$ $op \rightarrow *$

CFG的简化表示

表达式的CFG的简化表示

- 引入选择符 |

$expr \rightarrow expr\ op\ expr\ |\ (expr)\ |\ -\ expr\ |\ \mathbf{id}$

$op \rightarrow +\ |\ *$

注：+, *是*op*的选择(alternatives)

Backus–Naur Form
巴科斯-诺尔，范式

- 简化名称

$E \rightarrow E\ A\ E\ |\ (E\ )\ |\ -E\ |\ \mathbf{id}$

$A \rightarrow +\ |\ *$

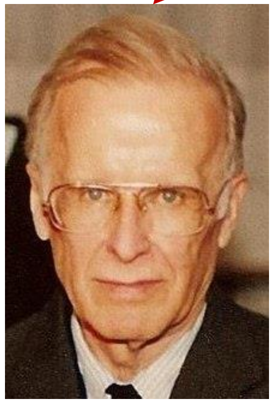

John Backus
1977图灵奖
首次在ALGOL 58中实现BNF

Peter Naur
2005图灵奖
在ALGOL 60中发展和简化

图灵奖获得者

- John Backus (1924-2007)
  - **1977图灵奖获奖成就**
    - Fortran发明组组长
    - 提出了BNF
  - **履历**
    - 弗吉尼亚大学化学(因出勤率低而开除，随后入伍)
    - 哥伦比亚大学数学BS 1949, AM 1950
    - IBM
  - **获奖演说：** Can Programming Be Liberated From the von Neumann Style?

- Peter Naur (1928-2016)
  - **2005图灵奖获奖成就**
    - ALGOL 60
    - 发展BNF并简化
  - **履历**
    - 哥本哈根大学天文学BS 1949、博士1957
    - 1950-51剑桥：天气恶劣破坏天文观测计划，但花很多时间编程以解决天文学中的扰动问题
    - 毕业后转向计算机科学
    - 获奖演说： Computing vs. Human Thinking

正规式和CFG的比较

- **都能表示语言**
- **凡是能用正规式表示的语言，都能用CFG表示**
  - 正规式
    $(a|b)^*ab$

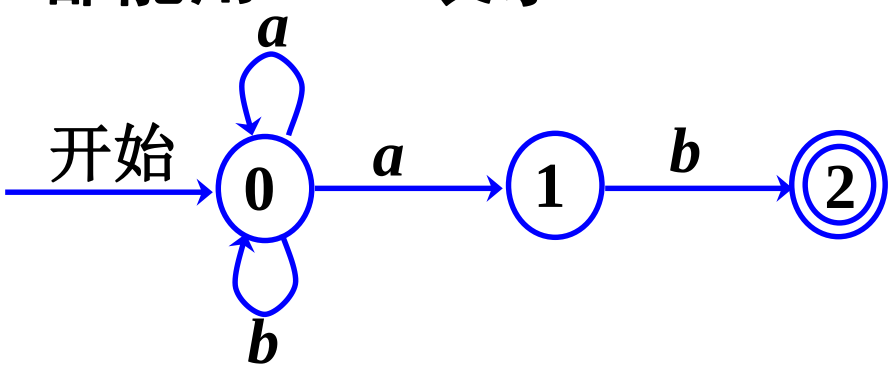

  - 上下文无关文法CFG

    可机械地由NFA变换而得，**NFA的字母表视为终结符集合**

    为每个NFA状态 ***i*** 引入一个非终结符A_i，NFA中每条弧对应于产生式的一个**分支（选择）**，

    对于接受状态 *i*，则引入$A_i \to \varepsilon$

    $A_0 \to a\ A_0 \mid b\ A_0 \mid a\ A_1$

    $A_1 \to b\ A_2$

    $A_2 \to \varepsilon$ (该产生式并不必要)

> 如果状态*i*有一个*a*转换到状态*j*，则引入产生式$A_i \to aA_j$;
>
> 如果是ε转换，则引入$A_i \to A_j$。

分离词法分析器的理由

- 正规文法是上下文无关文法的特例
- 为什么要用正规式定义词法
  - 词法规则非常简单，不必用上下文无关文法
  - 对于词法记号，正规式描述简洁且易于理解
  - 从正规式构造出的词法分析器（DFA）效率高
- 分离词法分析和语法分析的好处 (从软件工程看)
  - 简化设计，便于编译器前端的模块划分
  - 改进编译器的效率
  - 增强编译器的可移植性，如输入字符集的特殊性等可以限制在词法分析器中处理

词法分析并入语法分析?

- 直接从字符流进行语法分析
  - 文法复杂化：文法中需有反映语言的注释和空白的规则
  - 分析器复杂化：处理包含注释和空白的分析器，比注释和空白符已被词法分析器过滤的分析器要复杂得多

- 分离但在同一遍（Pass）中进行
  - 是通常编译器的做法

3.1 上下文无关文法

- □ 正规式与上下文无关文法的比较
- □ 上下文无关文法的一些基本概念
  - ■ 定义、推导、二义性
  - ■ 名词：语言、文法等价、句型、句子

CFG：推导

推导(derivation)

- 是从文法推出文法所描述的语言中**合法串**集合的动作
- 把产生式看成重写规则，把符号串中的非终结符用其产生式右部的串来代替

例 $E \rightarrow E + E \mid E * E \mid (E) \mid - E \mid \mathbf{id}$

$E \Rightarrow -E$ 读作 E 推导出 $-E$

$E \Rightarrow -E \Rightarrow -(E) \Rightarrow -(E + E) \Rightarrow -(\mathrm{id} + E) \Rightarrow -(\mathrm{id} + \mathrm{id})$

上述代换序列称为从 E 到 -(id+id) 的推导　　-(id+id) 是E 的实例

记法

- 如果 $A \rightarrow \gamma$ 是产生式，α 和β 是文法的任意符号串，那么可以说$\alpha A\beta \Rightarrow \alpha\gamma\beta$
- 0步或多步推导 $S \Rightarrow^* \alpha$：1) $\forall\alpha.\ \alpha \Rightarrow^* \alpha$；2) 如果$\alpha \Rightarrow^* \beta$，$\beta \Rightarrow \gamma$，那么 $\alpha \Rightarrow^* \gamma$
- 一步或多步推导 $S \Rightarrow^+ w$

思考

- 上下文无关是什么意思？

思考

- 上下文无关是什么意思？
  - 指对于文法推导的每一步$\alpha A\beta \Rightarrow \alpha\gamma\beta$

文法符号串γ仅依据A的产生式推导，不依赖A的上下文α和β

语言、文法、句型、句子

上下文无关语言

- 由上下文无关文法G产生的语言称为上下文无关语言，它包含：从开始符号S出发，经$\Rightarrow^{+}$推导所能到达的所有仅由终结符组成的串
- 句型(sentential form)： $S\Rightarrow^{*}\alpha$，S是开始符号， α是由终结符和/或非终结符组成的串，则α是文法G的句型
- 句子(sentence)： $S\Rightarrow^{+}w$, w是仅由终结符组成的句型

等价的文法

- 它们产生同样的语言

最左推导与最右推导

例 $E \to E + E \mid E * E \mid (E) \mid -E \mid \mathbf{id}$

- 最左推导(leftmost derivation)

  每步代换句型中**最左边**的非终结符

  $$E \Rightarrow_{lm} -E \Rightarrow_{lm} -(E) \Rightarrow_{lm} -(E + E)$$
  $$\Rightarrow_{lm} -(\mathbf{id} + E) \Rightarrow_{lm} -(\mathbf{id} + \mathbf{id})$$

- 最右推导（rightmost or canonical，规范推导）

  每步代换句型中**最右边**的非终结符

  $$E \Rightarrow_{rm} -E \Rightarrow_{rm} -(E) \Rightarrow_{rm} -(E + E)$$
  $$\Rightarrow_{rm} -(E + \mathbf{id}) \Rightarrow_{rm} -(\mathbf{id} + \mathbf{id})$$

分析树(parse tree)

例 $E \rightarrow E + E \mid E * E \mid (E) \mid -E \mid \mathbf{id}$

-(id+id)最左推导的**分析树**（parse tree）

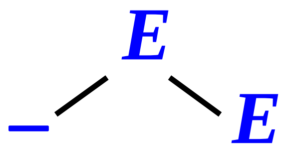

$E \Rightarrow -E$

分析树(parse tree)

例 $E \rightarrow E + E \mid E * E \mid (E) \mid -E \mid \mathbf{id}$

-(id+id)最左推导的**分析树**（parse tree）

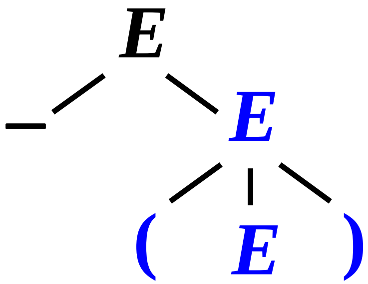

$E \Rightarrow -E \Rightarrow -(E)$

分析树(parse tree)

例 $E \rightarrow E + E \mid E * E \mid (E) \mid -E \mid \mathbf{id}$

-(id+id)最左推导的**分析树**（parse tree）

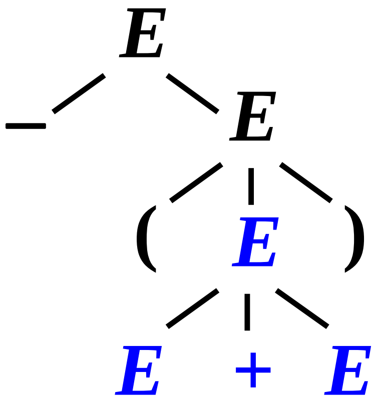

$E \Rightarrow -E \Rightarrow -(E) \Rightarrow -(E + E)$

分析树(parse tree)

例 $E \rightarrow E + E \mid E * E \mid (E) \mid -E \mid \mathbf{id}$

-(id+id)最左推导的**分析树**（parse tree）

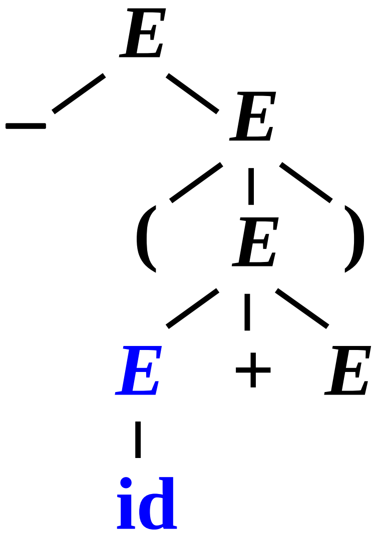

$E \Rightarrow -E \Rightarrow -(E) \Rightarrow -(E + E) \Rightarrow -(\mathrm{id} + E)$

分析树(parse tree)

例 $E \rightarrow E + E \mid E * E \mid (E) \mid -E \mid \mathbf{id}$

-(id+id)最左推导的**分析树**（parse tree）

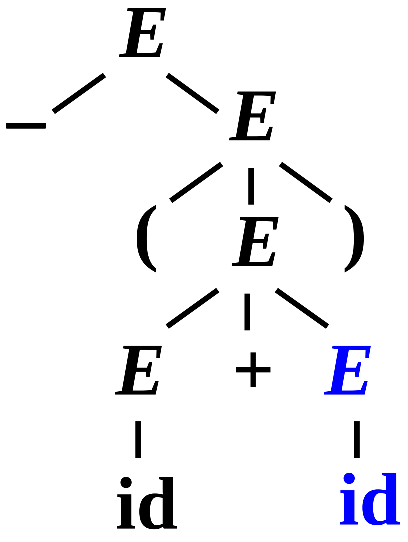

$$E \Rightarrow -E \Rightarrow -(E) \Rightarrow -(E+E) \Rightarrow -(\mathrm{id}+E) \Rightarrow -(\mathrm{id}+\mathrm{id})$$

文法的二义性

中国科学技术大学 University of Science and Technology of China

文法的某些句子存在不止一种最左(最右)推导，或者不止一棵分析树，则该文法是**二义**的。

例 $E \to E + E \mid E * E \mid (E) \mid -E \mid \mathrm{id}$

id*id+id 有两个不同的最左推导

$$
\begin{aligned}
E &\Rightarrow E * E \\
&\Rightarrow \mathrm{id} * E \\
&\Rightarrow \mathrm{id} * E + E \\
&\Rightarrow \mathrm{id} * \mathrm{id} + E \\
&\Rightarrow \mathrm{id} * \mathrm{id} + \mathrm{id}
\end{aligned}
\qquad
\begin{aligned}
E &\Rightarrow E + E \\
&\Rightarrow E * E + E \\
&\Rightarrow \mathrm{id} * E + E \\
&\Rightarrow \mathrm{id} * \mathrm{id} + E \\
&\Rightarrow \mathrm{id} * \mathrm{id} + \mathrm{id}
\end{aligned}
$$

文法的二义性

id*id+id 有两棵不同的分析树

$$E \Rightarrow E * E \Rightarrow \mathrm{id} * E \Rightarrow \mathrm{id} * E + E \Rightarrow \mathrm{id} * \mathrm{id} + E \Rightarrow \mathrm{id} * \mathrm{id} + \mathrm{id}$$

$$E \Rightarrow E + E \Rightarrow E * E + E \Rightarrow \mathrm{id} * E + E \Rightarrow \mathrm{id} * \mathrm{id} + E \Rightarrow \mathrm{id} * \mathrm{id} + \mathrm{id}$$

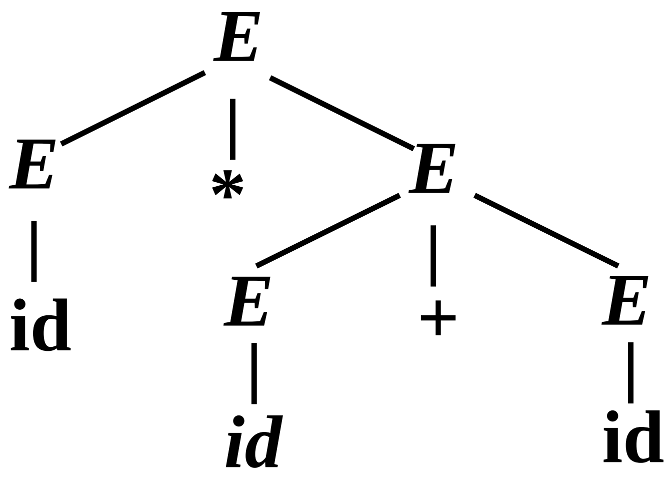

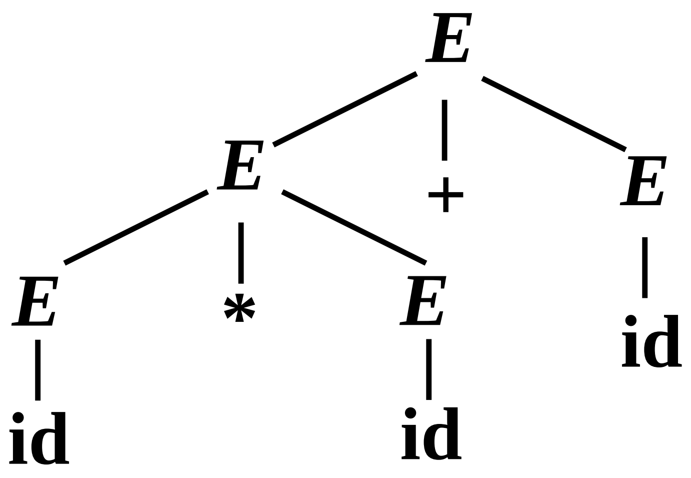

3.2 语言和文法

- □ 语言和文法：验证、消除二义性
- □ 非上下文无关文法

验证文法产生的语言

文法$G: S \to$ '(' S ')' $S \mid \varepsilon$　　　　语言$L(G)$ = 配对的括号串的集合

① 从S推出的是配对的括号串

② 任意配对的括号串可由S推出

- 证明①：按推导步数进行归纳

按任意步推导，推出的是配对括号串

- 归纳基础(Basis)：　$S \Rightarrow \varepsilon$
- 归纳 (Induction)假设

  少于n步的推导都产生配对的括号串，如 $S \Rightarrow^* x$, $S \Rightarrow^* y$

- 归纳步骤：　n步的最左推导如下：

$$S \Rightarrow \text{'('}\, S \,\text{')'}\, S \Rightarrow^* \text{'('}\, x \,\text{')'}\, S \Rightarrow^* \text{'('}\, x \,\text{')'}\, y$$

验证文法产生的语言

文法 $G: S \rightarrow$ '(' S ')' $S \mid \varepsilon$　　语言$L(G)$ = 配对的括号串的集合

□ 证明② ：任意长度的配对括号串均可由 S 推导出来

按串长进行归纳

- 归纳基础(Basis)：　$S \Rightarrow \varepsilon$
- 归纳 (Induction)假设：长度小于 $2n$ 的配对的括号串都可以从 S 推导出来
- 归纳步骤：考虑长度为$2n(n \geq 1)$的$w =$ '(' x ')' y

$$S \Rightarrow \text{'('} S \text{')'} S \Rightarrow^* \text{'('} x \text{')'} S \Rightarrow^* \text{'('} x \text{')'} y$$

表达式的另一种文法

□ 用一种层次的观点看待表达式

$$\underline{\underline{\mathrm{id}} * \underline{\mathrm{id}} * \underline{(\mathrm{id}+\mathrm{id})}} + \underline{\mathrm{id} * \mathrm{id}} + \underline{\mathrm{id}}$$

□ 无二义的文法

$expr \rightarrow expr + term \mid term$

$term \rightarrow term * factor \mid factor$

$factor \rightarrow \mathrm{id} \mid (expr)$

+ 是自左向右结合

* 是自左向右结合

如果改成

$expr \rightarrow term + expr \mid term$

呢？

+ 是自右向左结合

表达式的另一种文法

$expr \rightarrow expr + term \mid term$

$term \rightarrow term * factor \mid factor$

$factor \rightarrow \mathbf{id} \mid (expr)$

id * id * id
分析树

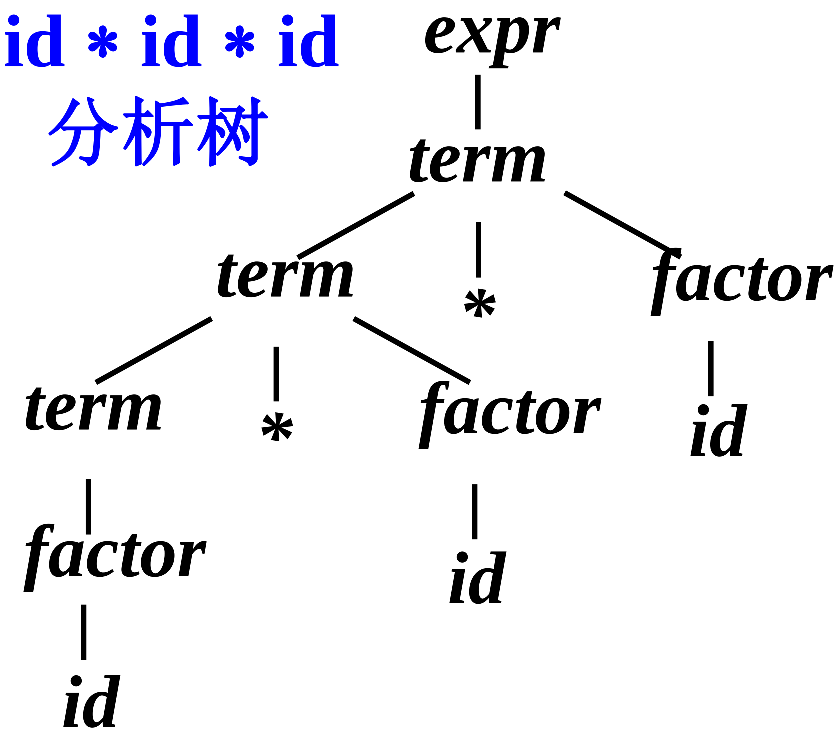

id + id * id
分析树

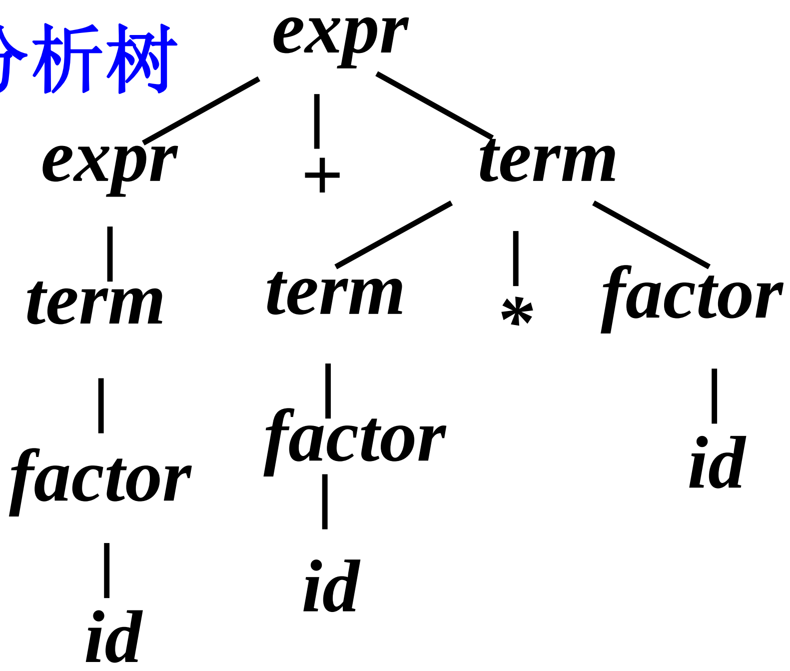

消除二义性(Eliminating ambiguity)

$$stmt \rightarrow \textbf{if } expr \textbf{ then } stmt$$
$$\mid \textbf{if } expr \textbf{ then } stmt \textbf{ else } stmt$$
$$\mid \textbf{other}$$

- 句型：**if** *expr* **then if** *expr* **then** *stmt* **else** *stmt*

  有两个最左推导：

  $stmt \Rightarrow \textbf{if } expr \textbf{ then } stmt$

  $\Rightarrow \textbf{if } expr \textbf{ then if } expr \textbf{ then } stmt \textbf{ else } stmt$

  $stmt \Rightarrow \textbf{if } expr \textbf{ then } stmt \textbf{ else } stmt$

  $\Rightarrow \textbf{if } expr \textbf{ then if } expr \textbf{ then } stmt \textbf{ else } stmt$

消除二义性

University of Science and Technology of China

无二义的文法

$$stmt \rightarrow matched\_stmt$$
$$\quad | \; unmatched\_stmt$$

else 的就近匹配规则

$$matched\_stmt \rightarrow \textbf{if } expr \textbf{ then } matched\_stmt \textbf{ else } matched\_stmt$$
$$\quad | \; \textbf{other}$$

$$unmatched\_stmt \rightarrow \textbf{if } expr \textbf{ then } stmt$$
$$\quad | \; \textbf{if } expr \textbf{ then } matched\_stmt \textbf{ else } unmatched\_stmt$$

3.2 语言和文法

- 语言和文法：验证、消除二义性
- 非上下文无关文法

形式语言鸟瞰

文法 $G = (V_T, V_N, S, P)$

- 0型文法：$\alpha \rightarrow \beta$， $\alpha, \beta \in (V_N \cup V_T)^*$， $|\alpha| \geq 1$

  短语文法

- 1型文法：$|\alpha| \leq |\beta|$，但$S \rightarrow \varepsilon$可以例外

  上下文有关文法

- 2型文法：$A \rightarrow \beta$， $A \in V_N, \beta \in (V_N \cup V_T)^*$

  上下文无关文法

- 3型文法：$A \rightarrow aB$或$A \rightarrow a$或$A \rightarrow \varepsilon$， $A, B \in V_N, a \in V_T$

  正规文法

上下文无关文法的优缺点

优点

- 文法给出了精确的、易于理解的语法说明
- 可以给语言定义出层次结构
- 可以基于文法自动产生高效的分析器
- 以文法为基础实现语言便于对语言修改

缺点

- 表达能力不足够，只能描述编程语言中的大部分语法

非上下文无关的语言构造

$L_1 = \{wcw \mid w$属于$(a \mid b)^*\}$

用来抽象：标识符的声明应先于其引用

C、Java都不是上下文无关语言

$L_2 = \{a^n b^m c^n d^m \mid n \geq 0, m \geq 0\}$

用来抽象：形参个数和实参个数应该相同

$L_3 = \{a^n b^n c^n \mid n \geq 0\}$

用来抽象：早先排版描述的一个现象

b e g i n：5个字母键，5个回退键，5个下划线键

形似的上下文无关语言

wcw

$$L_1' = \{wcw^R \mid w \in (a|b)^*\}$$

$$S \rightarrow aSa \mid bSb \mid c$$

$a^nb^mc^nd^m$

$$L_2' = \{a^nb^mc^md^n \mid n \geq 1, m \geq 1\}$$

$$S \rightarrow aSd \mid aAd$$

$$A \rightarrow bAc \mid bc$$

$a^nb^nc^n$

$$L_2'' = \{a^nb^nc^md^m \mid n \geq 1,\ m \geq 1\}$$

$$S \rightarrow AB$$

$$A \rightarrow aAb \mid ab$$

$$B \rightarrow cBd \mid cd$$

上下文有关文法

例 $L_3 = \{a^n b^n c^n \mid n \geq 1\}$的上下文有关文法

$S \rightarrow aSBC$ $S \rightarrow aBC$ $CB \rightarrow BC$ $aB \rightarrow ab$

$bB \rightarrow bb$ $bC \rightarrow bc$ $cC \rightarrow cc$

$a^n b^n c^n$的推导过程如下：

$S \Rightarrow^* a^{n-1}S(BC)^{n-1}$ 用$S \rightarrow aSBC$ n-1次

$S \Rightarrow^+ a^n(BC)^n$ 用$S \rightarrow aBC$ 1次

$S \Rightarrow^+ a^n B^n C^n$ 用$CB \rightarrow BC$交换相邻的CB

$S \Rightarrow^+ a^n b B^{n-1} C^n$ 用$aB \rightarrow ab$ 1次

$S \Rightarrow^+ a^n b^n C^n$ 用$bB \rightarrow bb$ n-1次

$S \Rightarrow^+ a^n b^n c C^{n-1}$ 用$bC \rightarrow bc$ 1次

$S \Rightarrow^+ a^n b^n c^n$ 用$cC \rightarrow cc$ n-1次

例题1 写等价的非二义文法

下面的二义文法描述命题演算公式的语法，为它写一个等价的非二义文法

$$S \rightarrow S \text{ and } S \mid S \text{ or } S \mid \text{not } S \mid \text{p} \mid \text{q} \mid \text{'('}\ S\ \text{')'}$$

解答

非二义文法的产生式如下：

$$E \rightarrow E \text{ or } T \mid T$$

$$T \rightarrow T \text{ and } F \mid F$$

$$F \rightarrow \text{not } F \mid \text{'('}\ E\ \text{')'} \mid \text{p} \mid \text{q}$$

例题1 写等价的非二义文法

下面的二义文法描述命题演算公式的语法，为它写一个等价的非二义文法

$$S \rightarrow S \text{ and } S \mid S \text{ or } S \mid \text{not } S \mid \text{p} \mid \text{q} \mid \text{'('}\ S\ \text{')'}$$

解答

非二义文法的产生式如下：

$$E \rightarrow E \text{ or } T \mid T$$

$$T \rightarrow T \text{ and } F \mid F$$

$$F \rightarrow \text{not } E \mid \text{'('}\ E\ \text{')'} \mid \text{p} \mid \text{q} \qquad ?$$

not p and q有两种不同的最左推导

not p and q

not p and q

例题2 写等价的不同文法

设计一个文法：字母表{a, b}上 a 和 b 的个数相等的所有串的集合

- 二义文法：　$S \to a\ S\ b\ S \mid b\ S\ a\ S \mid \varepsilon$

　　aabbabab　　*aabbabab*

- 二义文法：　$S \to a\ B \mid b\ A \mid \varepsilon$

　　$A \to a\ S \mid b\ A\ A$

　　$B \to b\ S \mid a\ B\ B$

　　aabbabab　*aabbabab*　*aabbabab*

- 非二义文法：$S \to a\ B\ S \mid b\ A\ S \mid \varepsilon$

　　$A \to a \mid b\ A\ A$

　　$B \to b \mid a\ B\ B$

　　a abb abab

　　$a\ B \quad S$

中国科学技术大学
University of Science and Technology of China

下期预告：自上而下的分析