Compiladores - Gramáticas

Fabio Mascarenhas – 2017.1

http://www.dcc.ufrj.br/~fabiom/comp

Análise Sintática

- A análise sintática agrupa os tokens em uma *árvore sintática* de acordo com a estrutura do programa (e a gramática da linguagem)
- Entrada: sequência de tokens fornecida pelo analisador léxico
- Saída: árvore sintática do programa

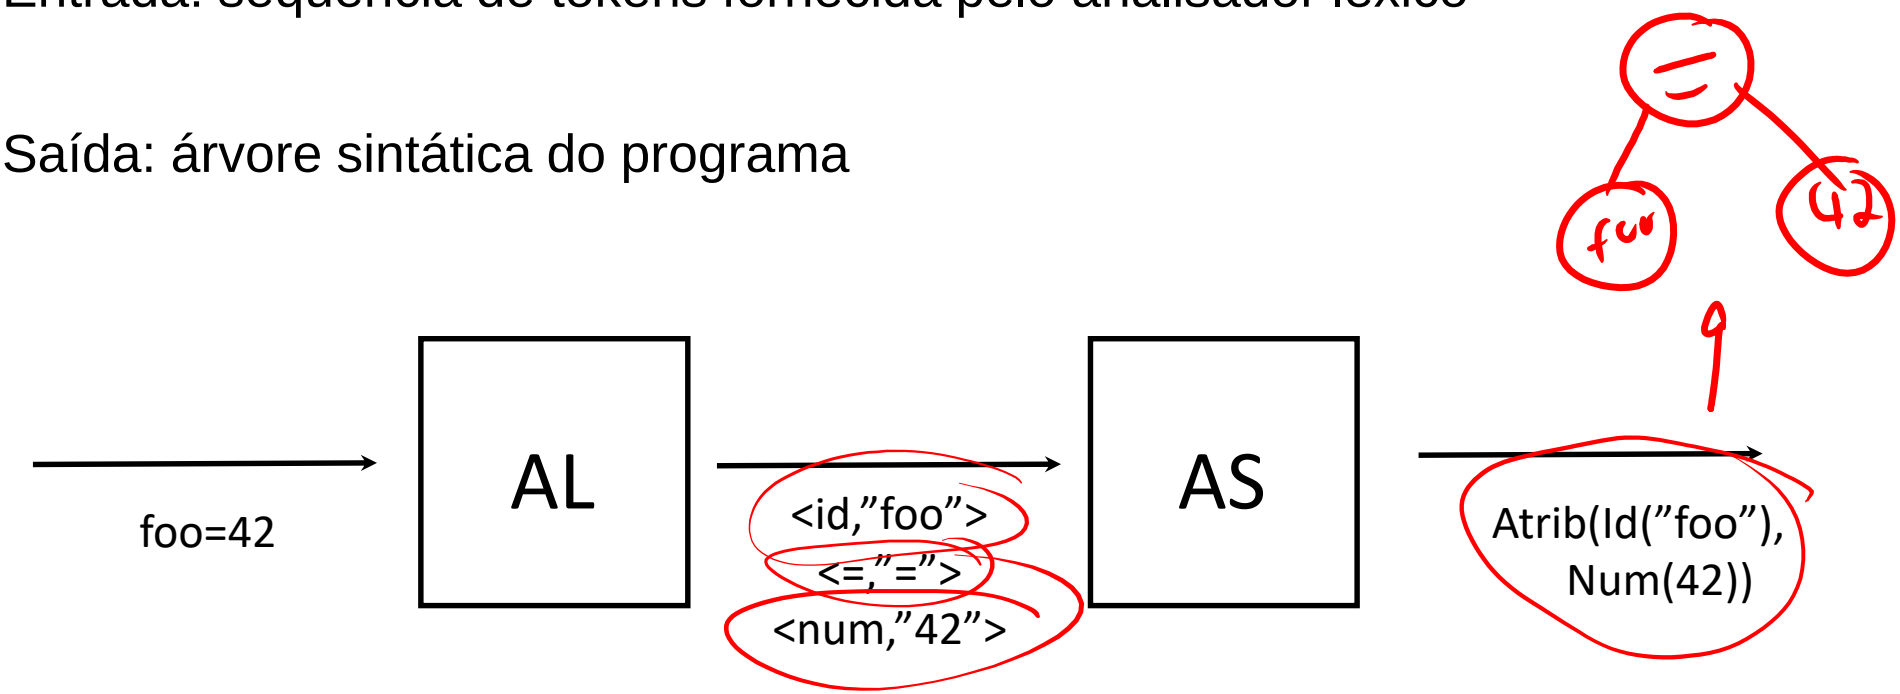

Análise Sintática

- Programa:

  if x == y then return 1 else return 2 end

- Tokens:

  IF ID EQ ID THEN RETURN NUM ELSE RETURN NUM END

- Árvore:

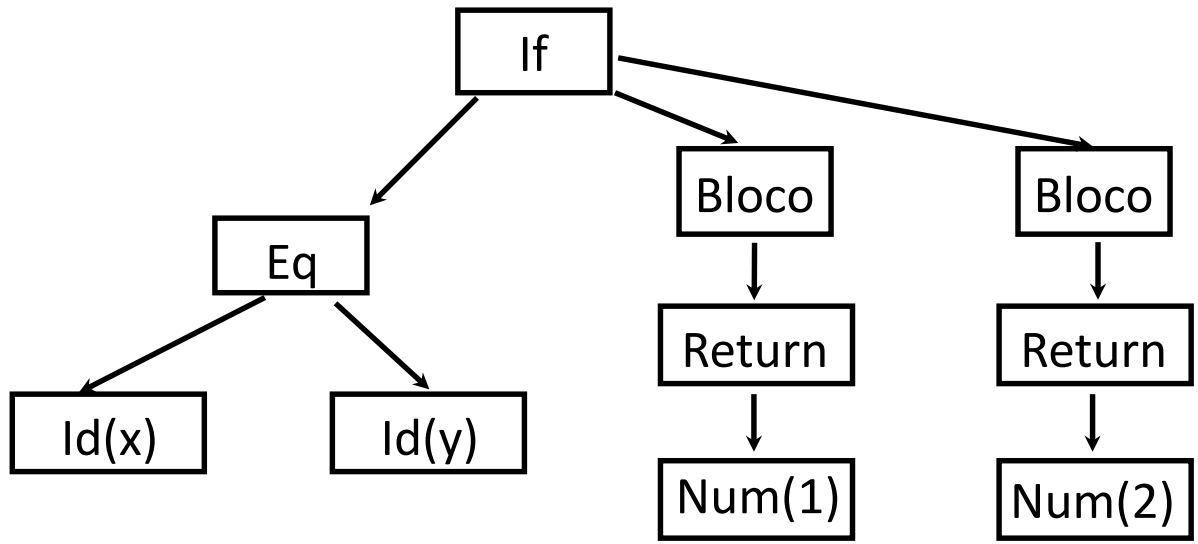

Programas válidos e inválidos

- Nem todas as sequências de tokens são programas válidos
- O analisador sintático tem que distinguir entre sequências válidas e inválidas
- Precisamos de:
  - Uma linguagem para *descrever sequências válidas de tokens* e a estrutura do programa

especificação GRAMÁTICA

  - Um *método* para distinguir sequências válidas de inválidas e extrair essa estrutura das sequências válidas

implementação PARSER

Estrutura recursiva

- A estrutura de uma linguagem de programação é *recursiva*
- Uma *expressão* é:
  - <expressão> + <expressão>
  - <expressão> == <expressão>
  - (<expressão>)
  - ...
- *Gramáticas livres de contexto* são uma notação natural para esse tipo de estrutura recursiva

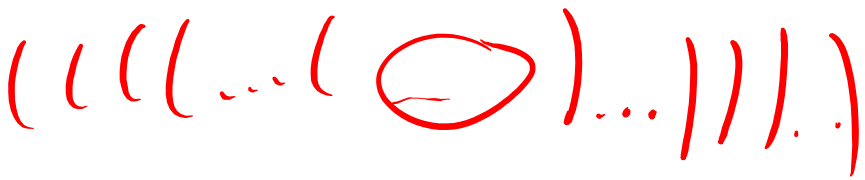

CFGs

- Uma gramática livre de contexto (CFG) é formada por:
  - Um conjunto de *terminais (T)* tokens / palavras
  - Um conjunto de *não-terminais (V)* termos sintáticos
  - Um *não-terminal inicial (S)* raiz / programa
  - Um conjunto de *produções (P)* estrutura

Produções

- Uma produção é um par de um *não-terminal* e uma cadeia (possivelmente vazia) de terminais e não-terminais

- Podemos considerar produções como *regras*; o não-terminal é o lado esquerdo da regra, e a cadeia é o lado direito

- É comum escrever gramáticas usando apenas as produções; os conjuntos de terminais e não-terminais e o não-terminal inicial podem ser deduzidos com a ajuda de algumas convenções tipográficas

CFGs são geradores

- Uma CFG é um *gerador* para cadeias de alguma linguagem
- Para gerar uma cadeia, começamos com o não-terminal inicial
- Substituimos então um não-terminal presente na cadeia pelo lado direito de uma de suas regras
- Fazemos essas substituições até ter uma string apenas de terminais

Deriva em um passo/n passos

- Se obtemos a cadeia *w* a partir da cadeia *v* com uma substituição de não-terminal dizemos que *v deriva w em um passo*: $v \rightarrow w$

- O fecho reflexivo-transitivo da relação *deriva em um passo* é a relação *deriva em n passos*:

  - $v \rightarrow^* v$ 0 passos

  - Se $v \rightarrow w$ então $v \rightarrow^* w$

  - Se $u \rightarrow^* v$ e $v \rightarrow^* w$ então $u \rightarrow^* w$

- A *linguagem* da gramática G são as cadeias de **terminais** *w* tal que $S \rightarrow^* w$

Quiz

- Quais das cadeias abaixo estão na gramática dada?

a b c b a

a c c a

a b a

a b c b c b a

S -> a X a
X -> ε
X -> b Y
Y -> ε
Y -> c X c

Quiz

- Quais das cadeias abaixo estão na gramática dada?

a b c b a

a c c a

* a b a

a b c b c b a

S -> a X a
X ->
X -> b Y
Y ->
Y -> c X c

Exemplo - expressões aritméticas simples

- Uma gramática bastante simples mas que exemplifica várias questões de projeto de gramáticas

S -> E

E -> E + E

E -> E * E

E -> (E)

E -> num

sentinela

recursão direta

Forma é importante

- Na construção de compiladores estamos tão interessados nas gramáticas quanto as linguagens que elas geram
- Muitas gramáticas podem gerar a mesma linguagem, mas a gramática vai ditar a *estrutura* do programa resultante
- A estrutura é a saída mais importante da fase de análise sintática

Derivações

- Uma *derivação* de uma cadeia *w* é uma sequência de substituições que leva de *S* a *w*:
  - S -> x_1 -> x_2 -> ... -> w
- Uma derivação pode ser desenhada como uma árvore
  - A raiz é S
  - Para se uma substituição X -> Y_1 ... Y_n é usada acrescente os filhos Y_1 ... Y_n ao nó X

Árvore sintática (árvore de parse)

- Uma árvore sintática [concreta] tem
  - terminais nas folhas (excepto nos nós ε)
  - não-terminais nos nós interiores
- Percorrer as folhas da árvore *em ordem* dá a cadeia sendo derivada
- A árvore sintática dá a *estrutura e associatividade* das operações que a cadeia original não mostra

Mais à esquerda e mais à direita

- Qualquer sequência de substituições que nos leve de *S* a *w* é uma derivação de *w*, mas em geral estamos interessados em *derivações sistemáticas*

- Uma *derivação mais à esquerda* de *w* é uma sequência de substituições em que sempre substituimos o não-terminal *mais à esquerda*

- Uma *derivação mais à direita* de *w* é uma sequência de substituições em que sempre substituimos o não-terminal *mais à direita*

- Veremos que estratégias de análise sintática diferentes levam a derivações mais à esquerda ou mais à direita

Unicidade da árvore sintática

- Podemos ter várias *derivações* para uma mesma cadeia *w*, mas só pode haver **uma** *árvore sintática*

- A árvore sintática dá a estrutura do programa, e a estrutura se traduz no significado do programa

- Logo, um programa com mais de uma árvore sintática tem mais de uma possível interpretação!

- Já a diferença entre uma derivação mais à esquerda e mais à direita se traduz em uma diferença na implementação do analisador sintático, e não na estrutura do programa

Uma cadeia, duas árvores

- Vamos voltar para a gramática de expressões:

S -> E
E -> E + E
E -> E * E
E -> (E)
E -> num

- Podemos obter duas árvores diferentes para a cadeia num * num + num

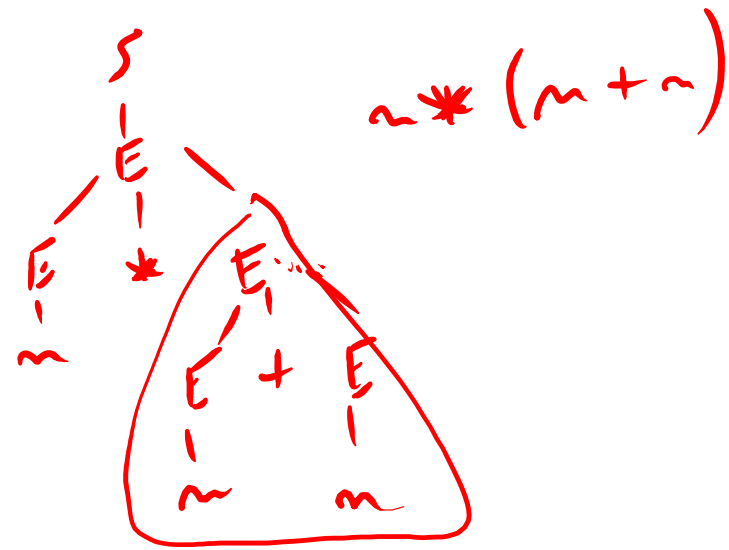

Ambiguidade

- Uma gramática é *ambígua* se existe alguma cadeia para qual ela tem mais de uma *árvore sintática*
  - De maneira equivalente, se existe mais de uma derivação *mais à esquerda* para uma cadeia
  - Ou se existe mais de uma derivação *mais à direita* para uma cadeia
  - As três definições são equivalentes
- Ambiguidade é ruim para uma linguagem de programação, pois leva a interpretações inconsistentes entre diferentes compiladores

Detectando ambiguidade

- Infelizmente, não existe um algoritmo para detectar se uma gramática qualquer é ambígua ou não

- Mas existem *heurísticas*, a principal delas é verificar se existe uma regra misturando *recursão à esquerda* e *recursão à direita*

  - É o caso da gramática de expressões

  - Às vezes isso é bem sutil: ambiguidade do if-else

S -> C
C -> if exp then C
C -> if exp then C else C
C -> outros