# Compiladores - Gramáticas

Fabio Mascarenhas – 2015.2

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

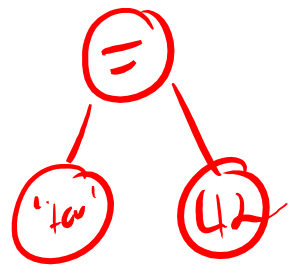


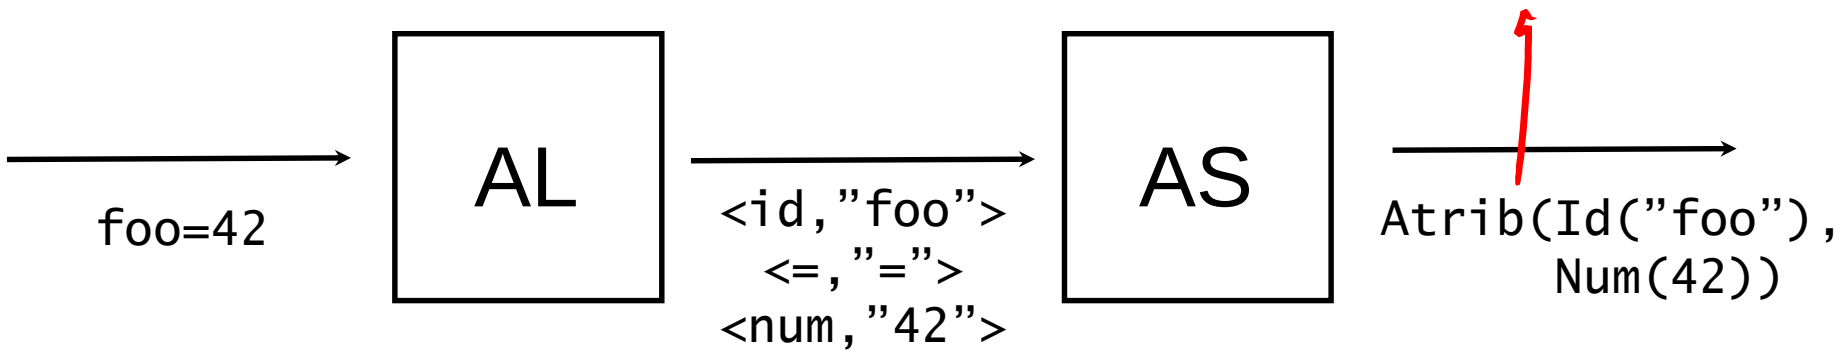

# Análise Sintática

- Programa:

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

- Tokens:

```
IF ID EQ ID THEN RETURN NUM ELSE RETURN NUM END
```

- Árvore:

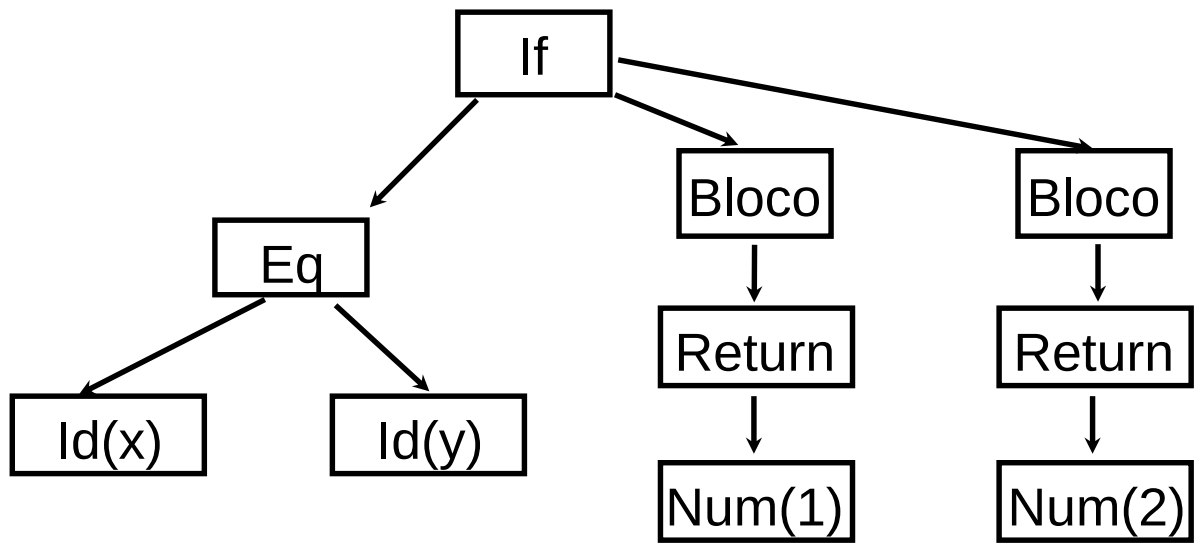

# Programas válidos e inválidos

- 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 → GRAMÁTICAS
  - Um *método* para distinguir sequências válidas de inválidas e extrair essa estrutura das sequências válidas → implementação → PARSERS

# 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 (tipos)
  - Um conjunto de *não-terminais (V)* → estrutura → expressão, comando
  - Um *não-terminal inicial (S)*
  - Um conjunto de *produções (P)* → regras sintáticas

# 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

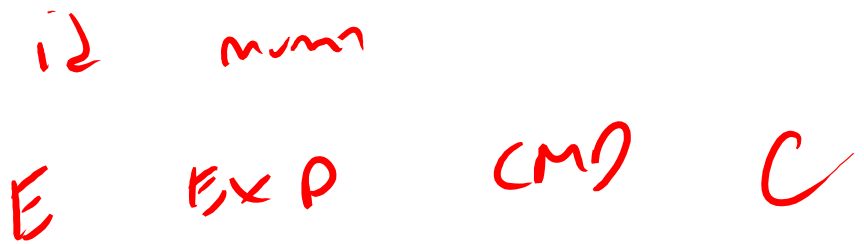

# CFGs são geradores

- 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*:
  - $v \rightarrow^* v$
  - 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

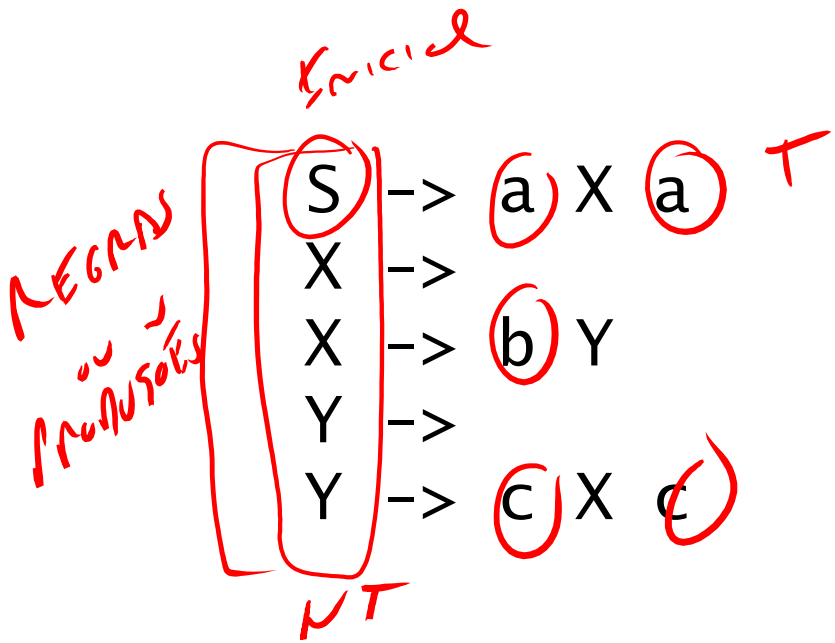


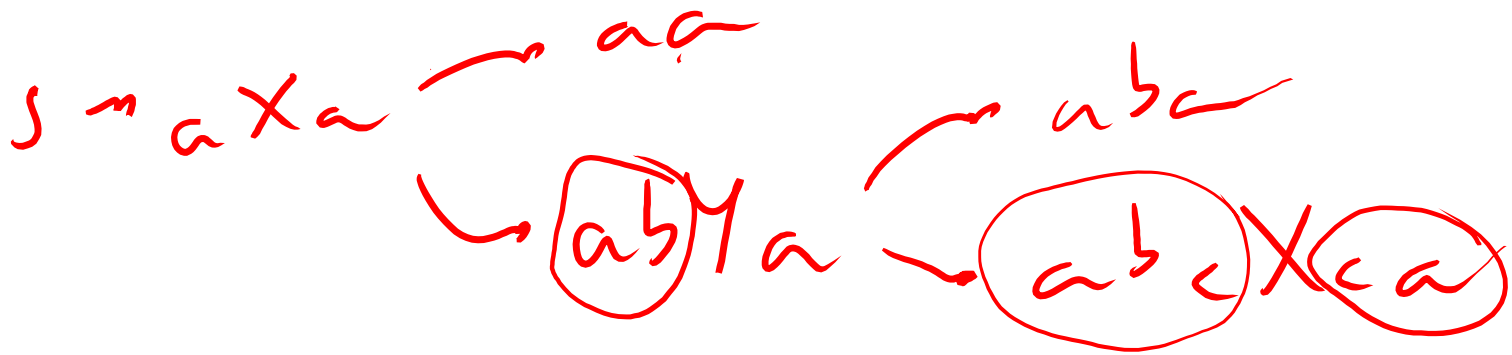

# Quiz

- 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

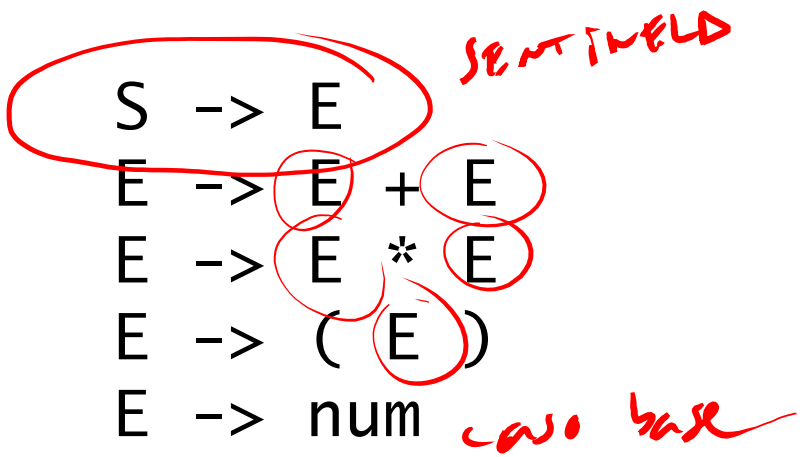

# Forma é importante

- 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

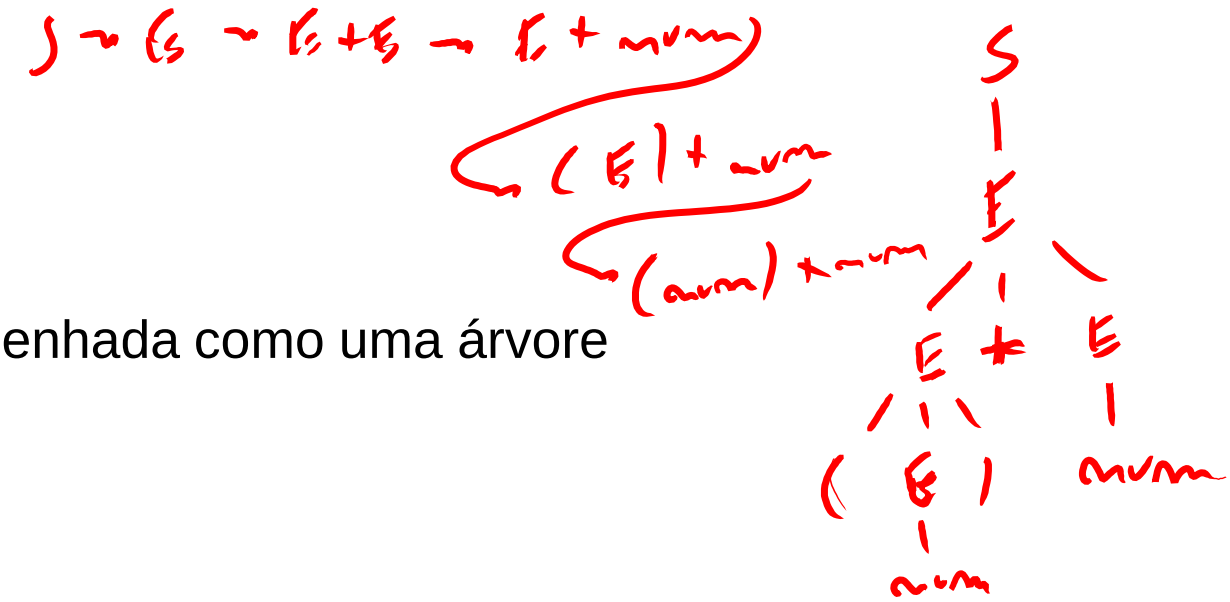

# Árvore sintática (árvore de parse)

- Uma árvore sintática [concreta] tem
  - terminais nas folhas
  - 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
```

# Removendo ambiguidade

- Do mesmo modo, não há um algoritmo para remover ambiguidade
- Se a ambiguidade está na gramática, e não na própria linguagem, o jeito é encontrar a *fonte* da ambiguidade e reescrever a gramática para eliminá-la
- No caso de ambiguidade em gramáticas de expressões e operadores, a ambiguidade vem da gramática não estar levando em conta as regras de associatividade e precedência dos operadores
- Em uma gramática de expressões, cada nível de precedência tem que ganhar seu próprio não-terminal
- Operadores que devem ser associativos à esquerda precisam usar recursão à esquerda, e associativos à direita precisam de recursão à direita

# Expressões simples, sem ambiguidade

- Assumindo que * tem precedência sobre +, e ambos são associativos à esquerda (ou seja, `num + num + num` deve ser interpretado como `(num + num) + num`)

```
S -> E
E -> E + T
E -> T
T -> T * F
T -> F
F -> ( E )
F -> num
```

# Expressões simples, sem ambiguidade

- Assumindo que ^ tem precedência sobre * que tem precedência sobre +, ^ é associativo à direita, * e + são associativos à esquerda (ou seja, `num + num + num` deve ser interpretado como `(num + num) + num`)

```
S -> E
E -> E + T
E -> E - T
E -> T
T -> T * F
T -> F
F -> A ^ F
F -> A
A -> ( E )
A -> num
```

# Duas derivações, uma árvore

- Duas derivações de uma frase podem dar a mesma árvore de uma for mais à esquerda e outra mais à direita

```
S -0-> E
 -1-> E + E
 -2-> E * E + E
 -4-> num * E + E
 -4-> num * num + E
 -4-> num * num + num

S -0-> E
 -1-> E + E
 -4-> E + num
 -2-> E * E + num
 -4-> E * num + num
 -4-> num * num + num
```

# Duas derivações, duas árvores

- Duas derivações mais à esquerda dão duas árvores diferentes: gramática ambígua

```
S -0-> E
 -1-> E + E
 -2-> E * E + E
 -4-> num * E + E
 -4-> num * num + E
 -4-> num * num + num

S -0-> E
 -2-> E * E
 -4-> num * E
 -1-> num * E + E
 -4-> num * num + E
 -4-> num * num + num
```

# If-else sem ambiguidade

- Uma solução adotada por diversas linguagens é acrescentar uma delimitador que fecha o if:

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

- Uma desvantagem é que agora é necessário ter uma construção “else-if” para ter ifs em cascata sem uma multiplicação de `end`s

- E claro, estamos mudando a linguagem!

# If-else sem ambiguidade, com a “cara de C”

- Uma solução adotada por diversas linguagens é acrescentar uma delimitador que fecha o if:

```
S -> C
C -> if exp { C }
C -> if exp { C } else { C }
C -> outros
```

- Uma desvantagem é que agora é necessário ter uma construção “else-if” para ter ifs em cascata sem uma multiplicação de `ends`

- E claro, estamos mudando a linguagem!

# If-else sem mudar a linguagem

- Outra solução é separar os ifs em dois tipos, com não-terminais diferentes:

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

- Notem a semelhança com a gramática não ambígua de expressões

# Quiz

- Qual a versão não ambígua da gramática:

```
S -> S S
S -> a
S -> b
```

```
S -> S a
S -> S b
S ->
```

```
S  -> S S'
S' -> a
S' -> b
```

```
S  -> S
S  -> S'
S' -> a
S' -> b
```

```
S -> S a
S -> S b
S -> a
S -> b
```

# Quiz

- Qual a versão não ambígua da gramática:

```
S -> S S
S -> a
S -> b
```

```
S -> S a
S -> S b
S ->
```

```
S  -> S S'
S' -> a
S' -> b
```

```
S  -> S
S  -> S'
S' -> a
S' -> b
```

```
* S -> S a
  S -> S b
  S -> a
  S -> b
```

# Quiz

- Qual a versão não ambígua da gramática:

```
S -> S S
S -> a
S -> b
```

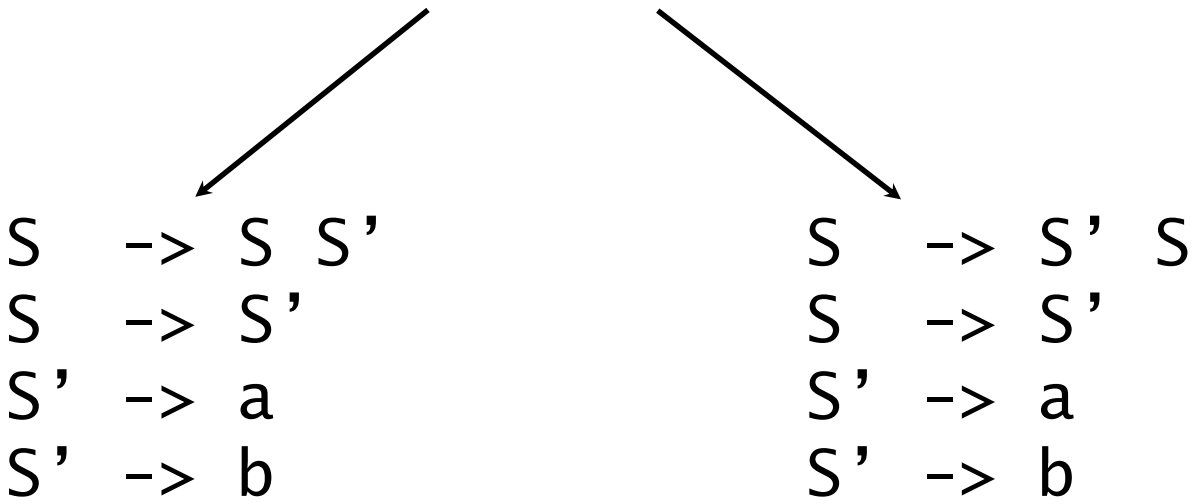

```
S  -> S S'
S  -> S'
S' -> a
S' -> b
```

```
S  -> S' S
S  -> S'
S' -> a
S' -> b
```

# Contornando ambiguidade

- Na prática, um uso judicioso de ambiguidade pode simplificar a gramática, e deixar ela mais natural
- Tanto a versão ambígua da gramática de expressões simples quanto a gramática do if-else são mais simples que suas versões não ambíguas!
- Podemos eliminar a ambiguidade não na gramática, mas na *implementação do analisador sintático*
- As ferramentas de geração de analisadores possuem regras de eliminação de ambiguidade, e diretivas de precedência e associatividade que permitem controlar como essa eliminação é feita