Construção de compiladores

Profs. Mário César San Felice (e Helena Caseli, Murilo Naldi, Daniel Lucrédio)
Departamento de Computação - UFSCar

1º semestre / 2018

Tópico 4 - Análise Sintática Descendente

Análise sintática descendente

Ou análise sintática top-down

Análise sintática … recordando

- Vimos duas formas de reconhecer uma linguagem através de uma gramática
  - Inferência recursiva
  - Derivação

- Ex: Gramática para expressões aritméticas
  - V = {E,I}
  - T = {+,*,(,),a,b,0,1}
  - P = conjunto de regras ao lado
  - S = E

```
E →  I
  |  E + E
  |  E * E
  |  (E)
I →  a
  |  b
  |  Ia
  |  Ib
  |  I0
  |  I1
```

Análise sintática … recordando

- Inferência recursiva
  - Dada uma cadeia (conjunto de símbolos terminais)
  - Vamos do corpo para a cabeça

- Ex: a*(a+b00)
  - a*(a+b00) ⇐ a*(a+I00) ⇐ a*(a+I0) ⇐ a*(a+I) ⇐ a*(a+E) ⇐ a*(I+E) ⇐ a*(E+E) ⇐ a*(E) ⇐ a*E ⇐ I*E ⇐ E*E ⇐ E

```
E → I
  | E + E
  | E * E
  | (E)
I → a
  | b
  | Ia
  | Ib
  | I0
  | I1
```

Análise sintática … recordando

- Derivação
  - Dada uma cadeia (conjunto de símbolos terminais)
  - Vamos da cabeça para o corpo

- Ex: a*(a+b00)
  - E ⇒ E*E ⇒ I*E ⇒ a*E ⇒ a*(E) ⇒ a*(E+E) ⇒ a*(I+E) ⇒ a*(a+E) ⇒ a*(a+I) ⇒ a*(a+I0) ⇒ a*(a+I00) ⇒ a*(a+b00)

```
E → I
  | E + E
  | E * E
  | (E)
I → a
  | b
  | Ia
  | Ib
  | I0
  | I1
```

Análise sintática descendente

- Produz uma derivação mais à esquerda da cadeia
- Os tokens são lidos da esquerda para a direita
- Em cada passo,
  - o problema é determinar qual produção aplicar

- Ex:
  - Entrada: a + b * c
  - Token atual = a
  - Símbolo inicial: E
  - Possíveis produções de E:
    - I
    - E + E
    - E * E

Qual escolher?

```
E → I
  | E + E
  | E * E
  | (E)
I → a | b | c
```

Análise sintática descendente

- Existem duas opções:
  - Com retrocesso (tentativa e erro)
  - Preditivo (tenta adivinhar)

- Imagine-se num labirinto de salas
  - Cada sala possui várias portas
  - Cada porta possui uma palavra mágica que a abre
  - Você possui uma lista de palavras
    - Que só pode ser utilizada na ordem correta

Análise sintática descendente

- Em cada sala, você olha a próxima palavra da lista e precisa abrir a porta correta

  - Se não houver uma porta com a próxima palavra
    - Esse era um caminho errado

  - Mas pode haver mais de uma porta com a próxima palavra → não-determinismo

Análise sintática descendente

- Uma opção é escolher uma das portas arbitrariamente e tentar esse caminho até o fim
  - Se der, deu
  - Se não der, você precisa voltar até o ponto da escolha (retrocesso)
    - Por isso é bom deixar uma marca para cada ponto de decisão

Exemplo força bruta

$$E \rightarrow T + E \mid T$$
$$T \rightarrow F * T \mid F$$
$$F \rightarrow a \mid b \mid (E)$$

- Entrada: a * b

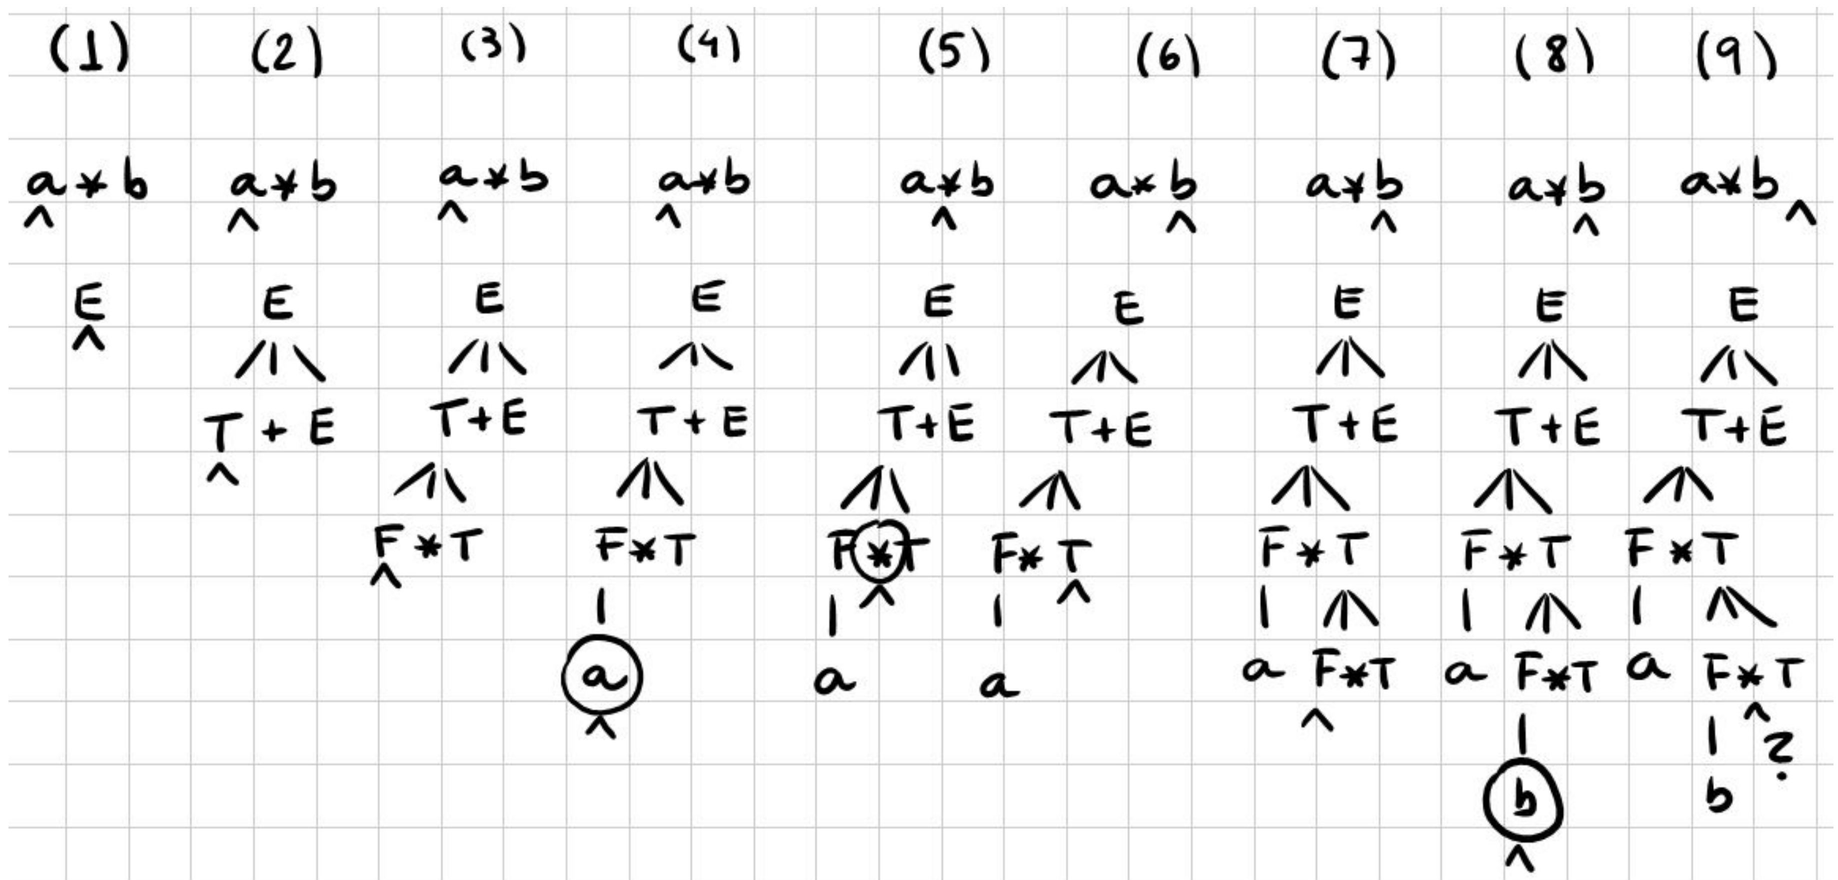

Retroceder: 6 ← 7 ← 8 ←

Exemplo força bruta

$$E \rightarrow T + E \mid T$$
$$T \rightarrow F * T \mid F$$
$$F \rightarrow a \mid b \mid (E)$$

- Entrada: a * b

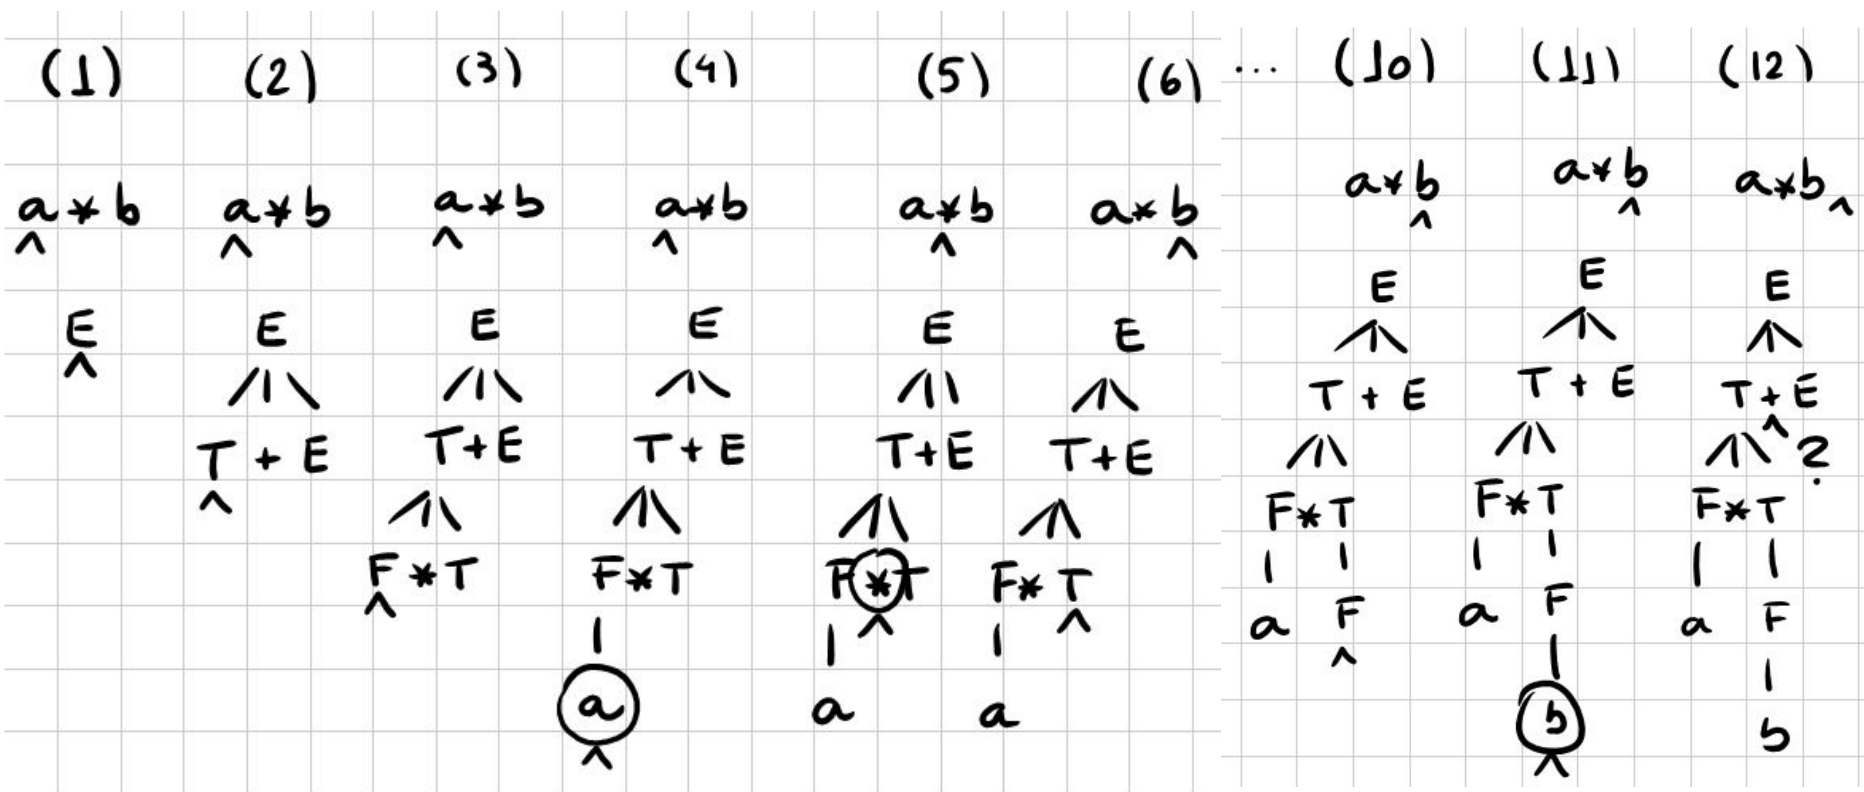

Retroceder: 2 ← 3 ← 4 ← 5 ← 6 ← 10 ← 11 ←

Exemplo força bruta

```
E → T + E | T
T → F * T | F
F → a | b | (E)
```

- Entrada: a * b

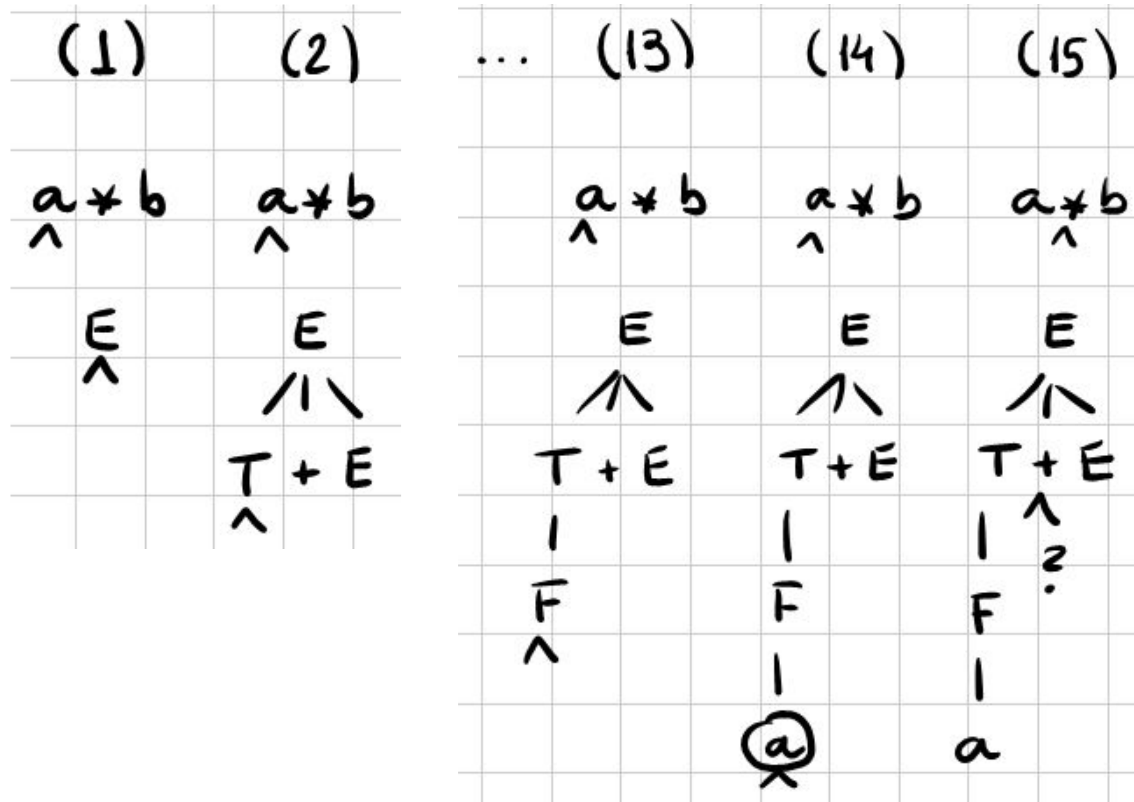

Retroceder: 1 ← 2 ← 13 ← 14 ←

Exemplo força bruta

E → T + E | T
T → F * T | F
F → a | b | (E)

- Entrada: a * b

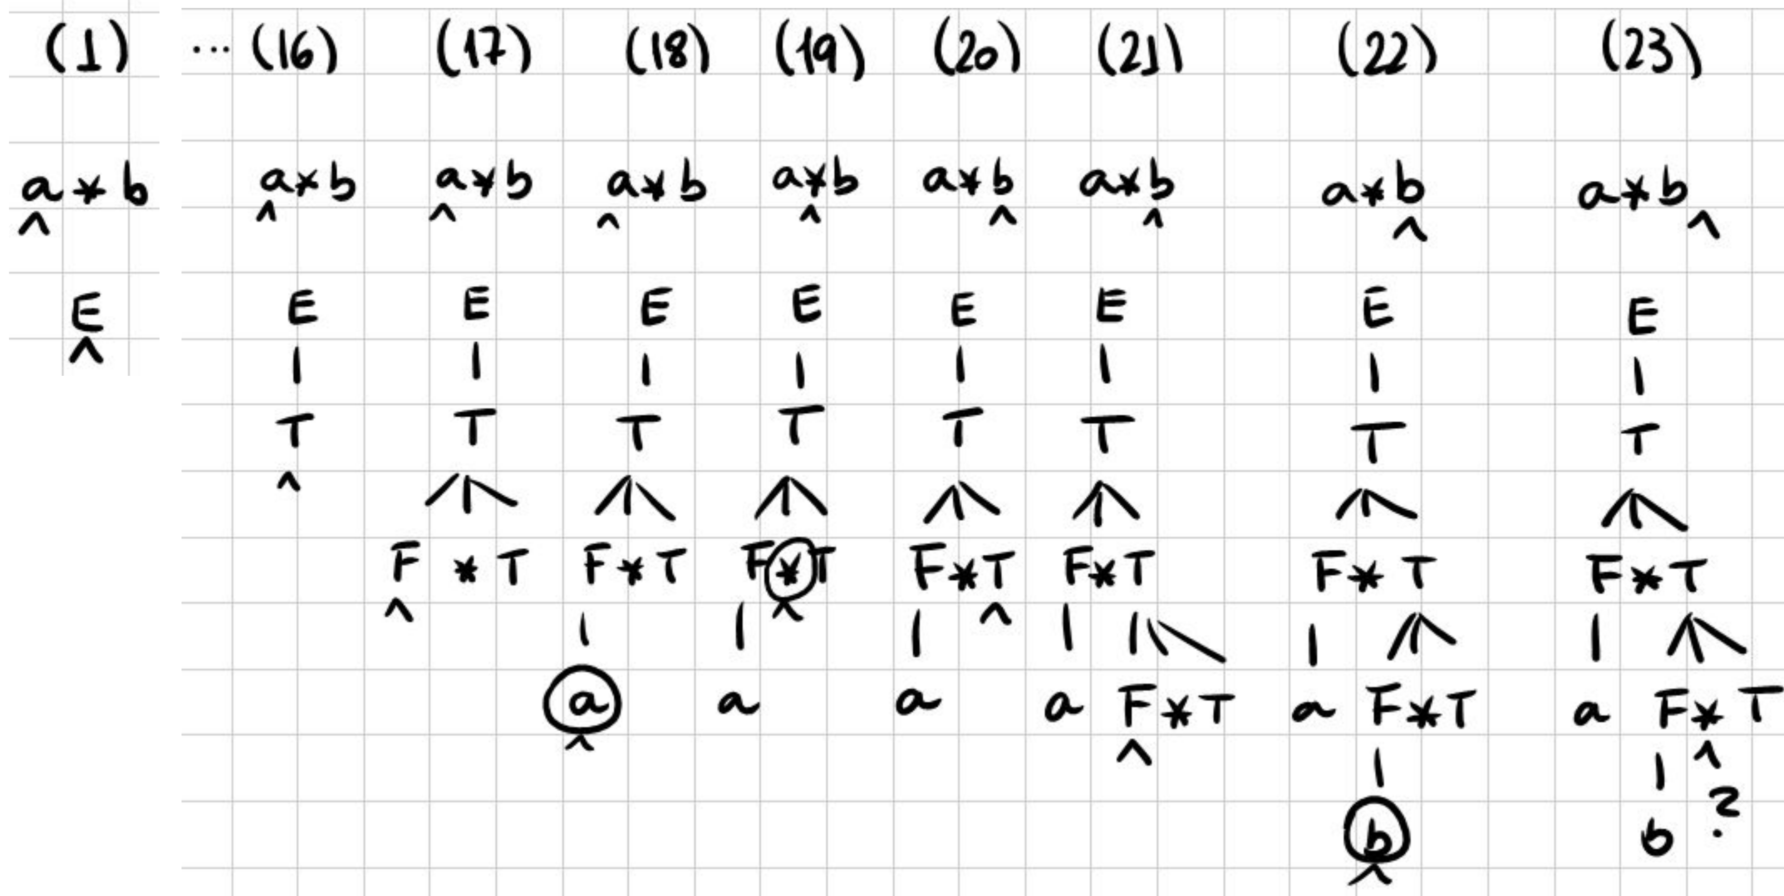

Retroceder: 20 ← 21 ← 22 ←

Exemplo força bruta

$E \rightarrow T + E \mid T$
$T \rightarrow F * T \mid F$
$F \rightarrow a \mid b \mid (E)$

- Entrada: a * b

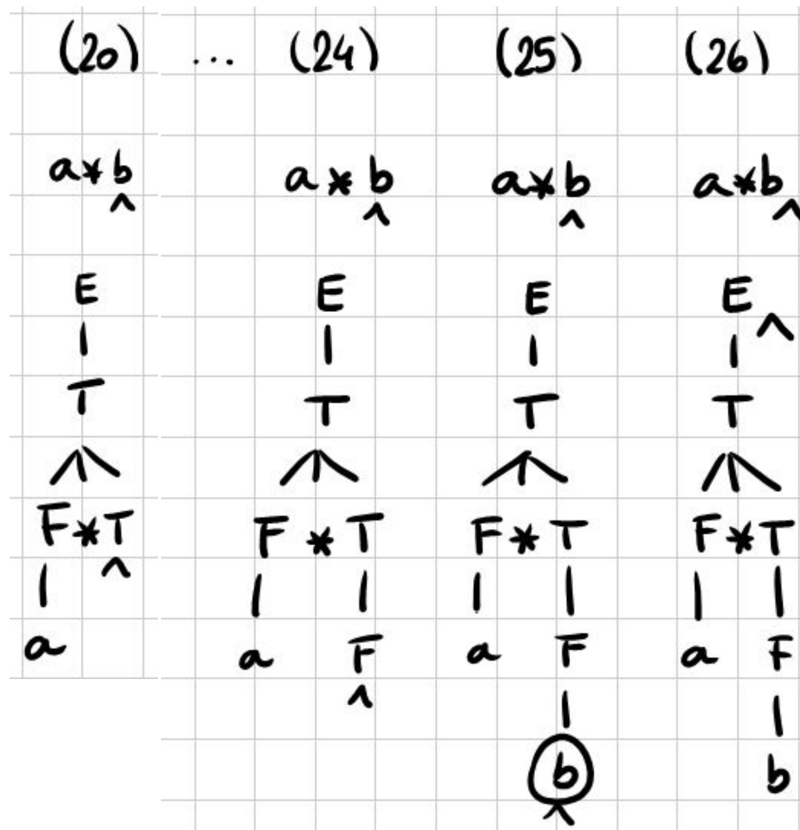

Cadeia reconhecida

Análise sintática descendente

- Essa abordagem resolve o não-determinismo na base da força bruta!
- Vantagem
  - Dá pra sair de qualquer labirinto
    - Desde que tenha saída, claro!
  - E desde que não haja ciclos
    - Pois corre-se o risco de tentar a mesma porta várias vezes, já que as “marcas” de retrocesso só são vistas quando estamos voltando
    - É como se só pudéssemos marcar o verso da porta - veremos mais sobre isso depois
- Desvantagem
  - Ineficiência … força bruta = tempo exponencial

Análise sintática descendente

- Outra opção é “adivinhar” a porta correta
  - Abordagem preditiva

- Como fazer isso?
  - Tentamos prever a porta correta com base na informação disponível “ao redor”

  - É uma “tentativa e erro” limitada
    - Tentamos uma das portas até um certo limite
    - Na prática
      - É comum olhar apenas uma sala à frente

Exemplo preditivo

$E \rightarrow T + E \mid T$

$T \rightarrow F * T \mid F$

$F \rightarrow a \mid b \mid (E)$

- Entrada: a * b

$K = 1$

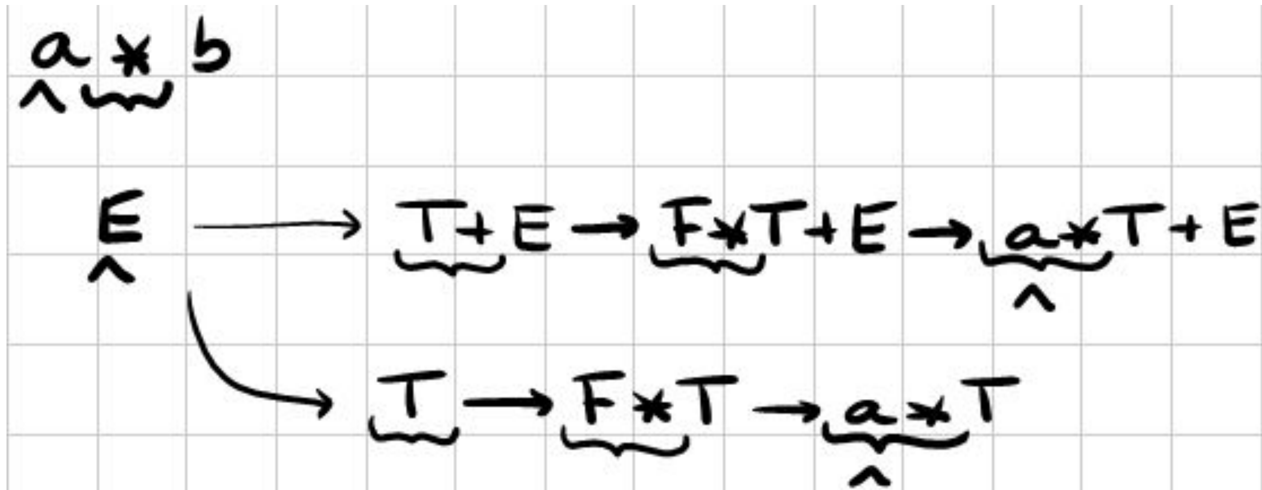

Olhando apenas um símbolo à frente não é possível resolver o não-determinismo em E

Exemplo preditivo

```
E → T + E | T
T → F * T | F
F → a | b | (E)

K = 2
```

- Entrada: a * b

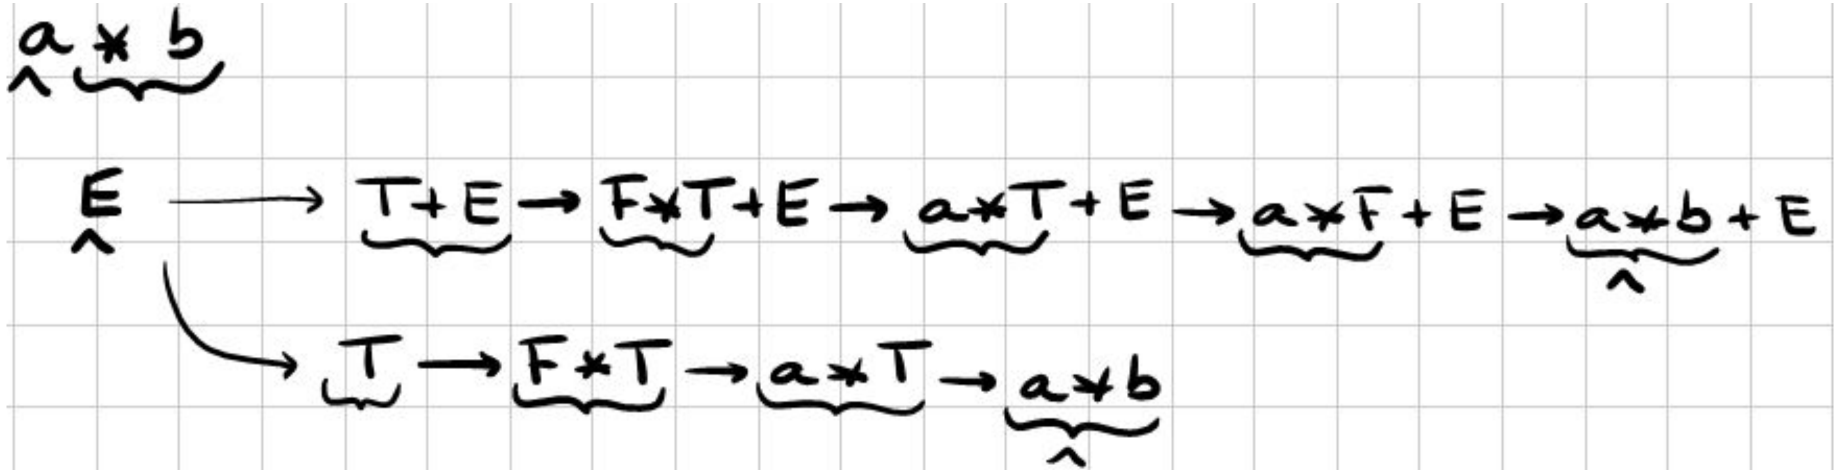

Olhando apenas dois símbolos à frente não é possível resolver o não-determinismo em E

Exemplo preditivo

$$
\begin{aligned}
E &\rightarrow T + E \mid T \\
T &\rightarrow F * T \mid F \\
F &\rightarrow a \mid b \mid (E)
\end{aligned}
$$

- Entrada: a * b

$K = 3$

a * b ε

E → T+E → F*T+E → a*T+E → a*F+E → a*b+E

E → T → F*Tε → a*Tε → a*bε

Olhando três símbolos à frente é possível resolver o não-determinismo em E (escolhendo E→T)

Exemplo preditivo

$E \rightarrow T + E \mid T$

$T \rightarrow F * T \mid F$

$F \rightarrow a \mid b \mid (E)$

$K = 3$

- Entrada: a * b

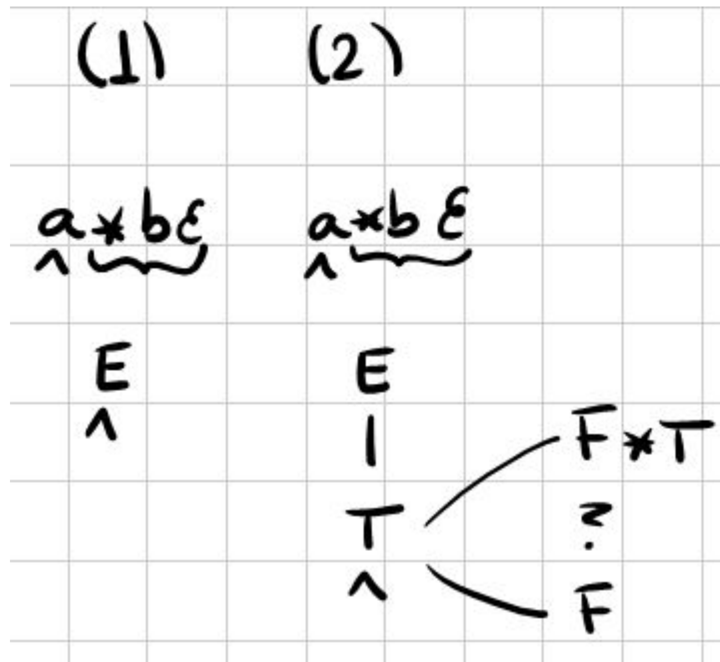

Olhando três símbolos à frente é possível resolver o não-determinismo em T (escolhendo T → F * T)

Exemplo preditivo

- Entrada: a * b

```
E → T + E | T
T → F * T | F
F → a | b | (E)

K = 3
```

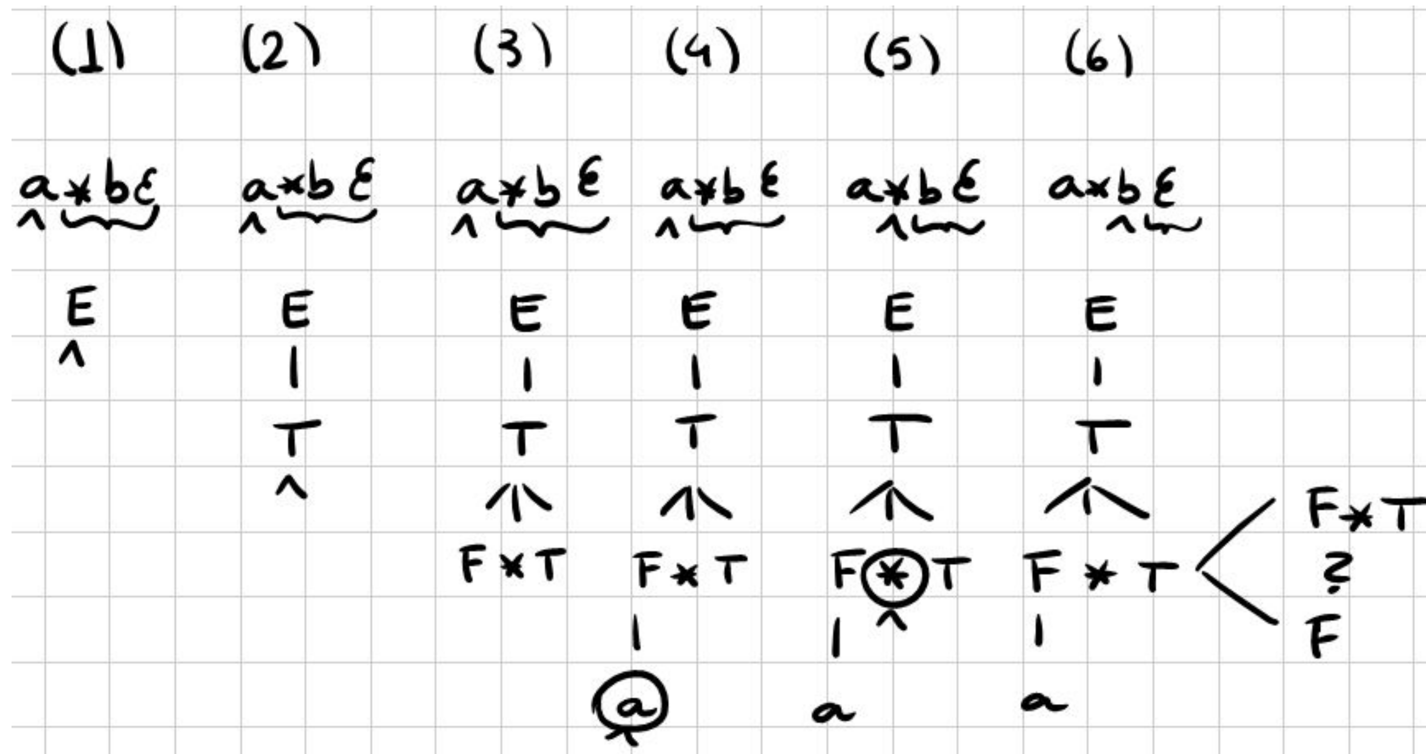

Olhando três símbolos à frente é possível resolver o novo não-determinismo em T (escolhendo T → F)

Exemplo preditivo

- Entrada: a * b

```
E → T + E | T
T → F * T | F
F → a | b | (E)

K = 3
```

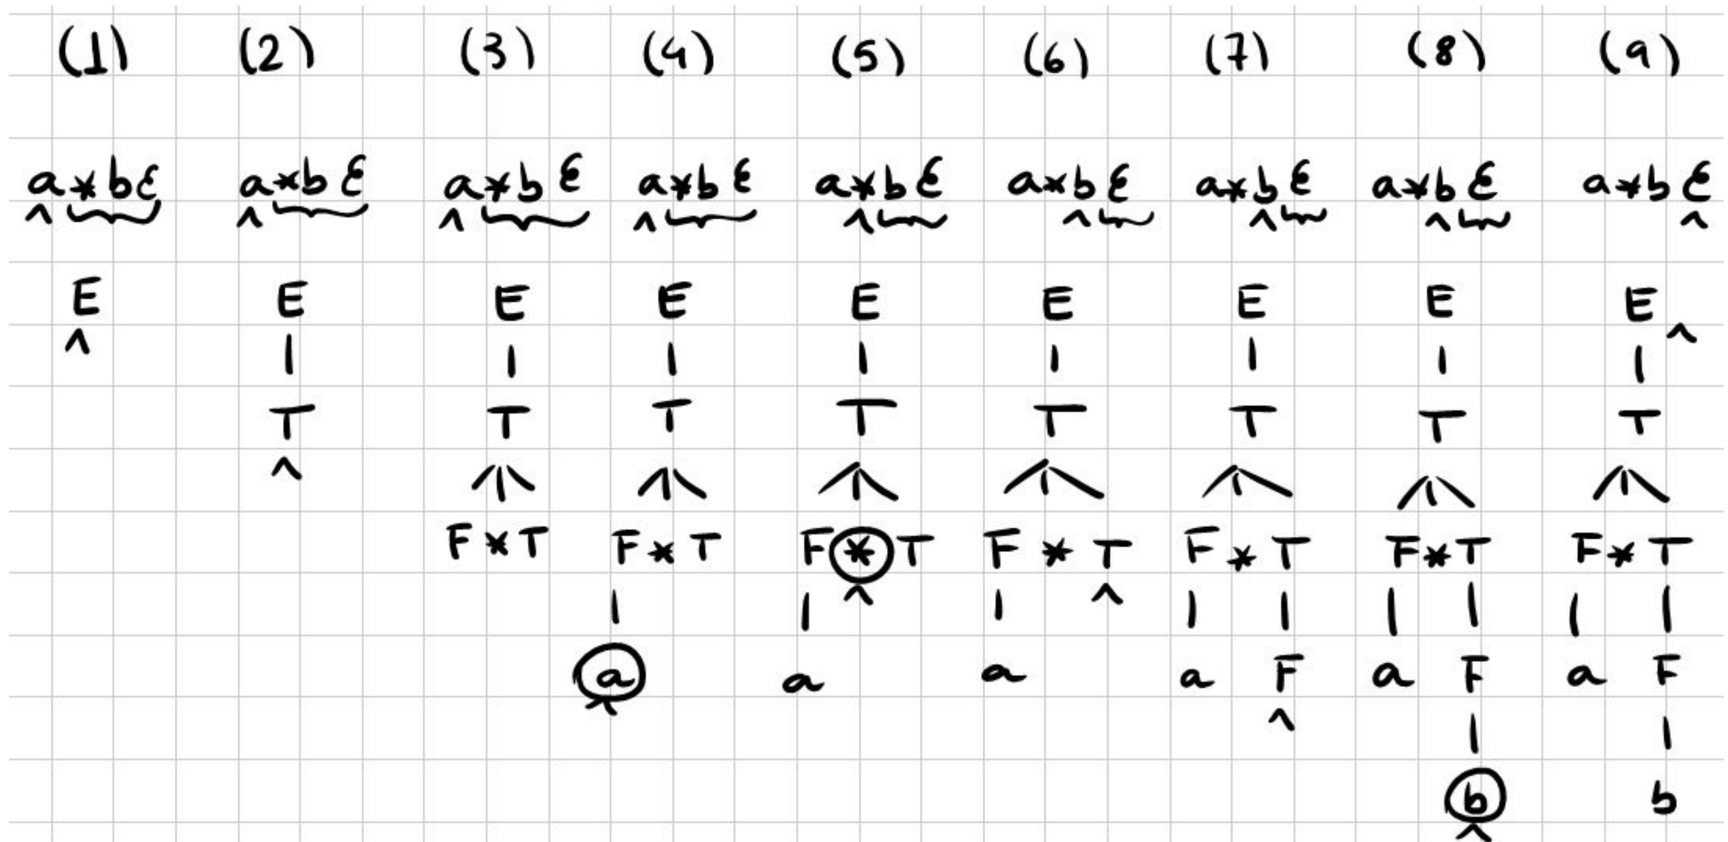

Cadeia reconhecida

Análise sintática descendente

- A abordagem preditiva é mais eficiente
  - Ela não precisa tentar todos os caminhos
  - Portanto, o tempo de execução não é exponencial
    - Como a força bruta da abordagem com retrocesso
- Porém, ela é mais cautelosa/preguiçosa ...

Análise sintática descendente

- Não é de todo labirinto que ela encontra a saída
  - Apenas alguns labirintos “especiais”
  - Com propriedades interessantes
    - Como pontos de não-determinismo limitados a 1, 2 ou k salas adjacentes

- Deve existir uma garantia de que naquele labirinto:
  - Para TODA sala com mais de uma porta com a mesma palavra ...
  - ... é SEMPRE possível determinar que a escolha da porta foi correta olhando no máximo k salas à frente

Análise sintática descendente

- Mas chega de labirintos, portas, palavras e listas
- Vamos fazer as associações:

Labirinto	**Não-terminal / regra**
Porta	**Programa / modelo**
Palavra na porta	**Gramática**
Lista de palavras	**Terminal / token**

Análise sintática descendente

- Mas chega de labirintos, portas, palavras e listas
- Vamos fazer as associações:

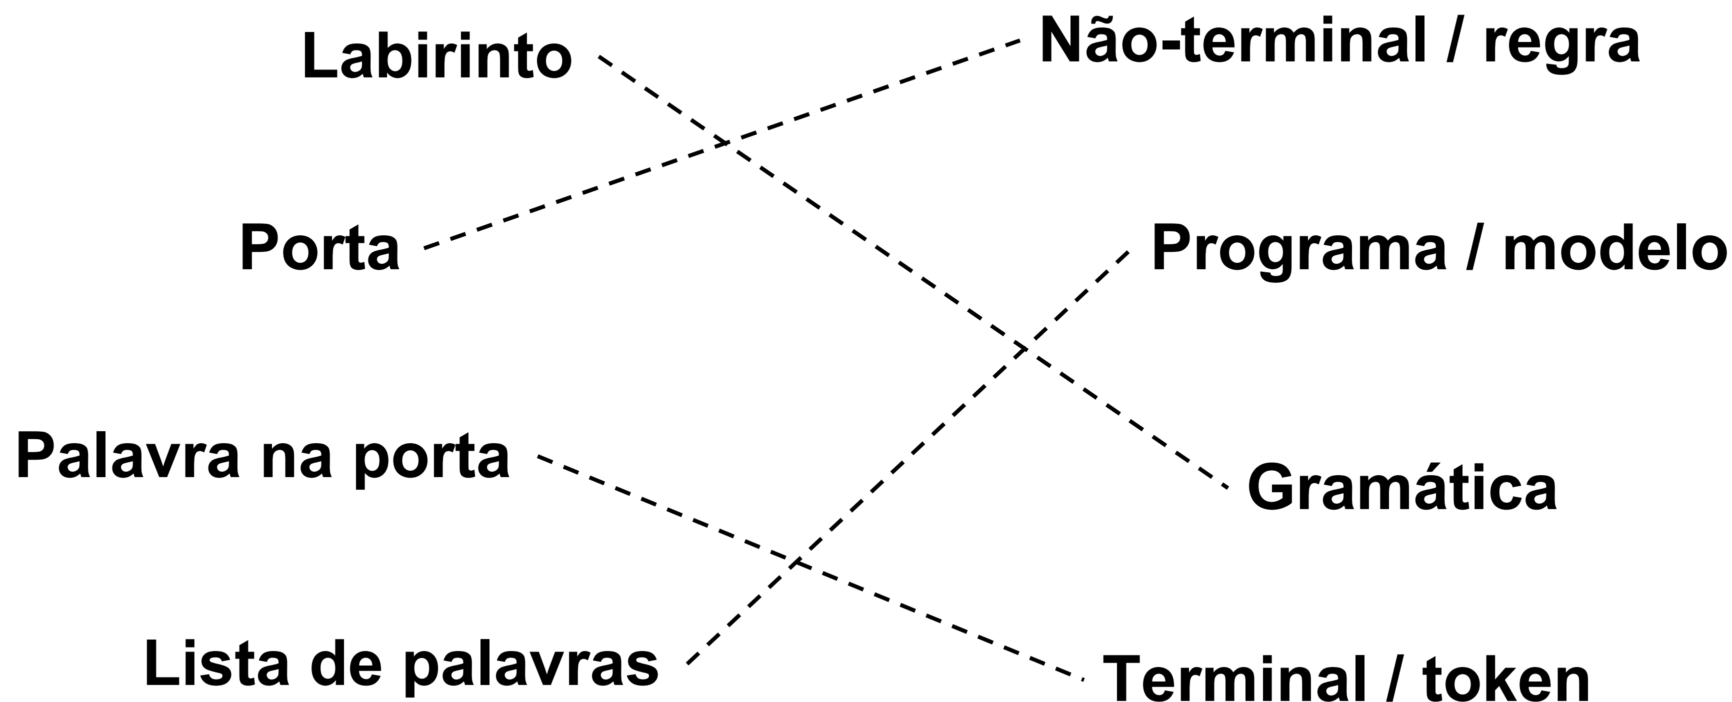

Análise sintática descendente

- Veremos algumas técnicas de implementação deste tipo de analisador sintático
  - Preditivo de descida recursiva – LL(1)
  - Preditivo de descida não-recursiva (usando pilha) – LL(1)
  - Técnica do macaco treinado – LL(*)

Analisador sintático preditivo de descendência recursiva

Analisador sintático preditivo de descendência recursiva

- É o tipo mais simples
- É o preferido quando se constrói à mão
- Usa funções recursivas
  - Uma função para cada não-terminal
- Cada função é um espelho das regras de produção
  - Faz o “casamento” dos terminais
  - E chamadas para outros não-terminais

Analisador sintático preditivo de descendência recursiva

- Exemplo:

```
S → c A d
A → a b A | c
```

```
void match(token) {
// Testa se o símbolo atual
// casa com o token
// Se sim, avança a leitura
// Se não, acusa erro
}

token prox() {
// Retorna o próximo token
// sem avançar a leitura
// Ou seja, dá apenas uma
// “olhadinha” à frente
}
```

```
void S() {
   match(“c”);
   A();
   match(“d”);
}

void A() {
   if(prox() == “a”) {
      match(“a”);
      match(“b”);
      A();
   }
   else if(prox() == “c”) {
      match(“c”);
   }
   else { // erro sintático
   }
}
```

Analisador sintático preditivo de descendência recursiva

- Vamos tentar implementar a linguagem ALGUMA

- Vamos agora estudar um pouco de teoria
  - Quem sabe não dá para automatizar esse processo?

Conjuntos primeiros e seguidores

- Conjuntos gerados com base em funções associadas a uma gramática
  - Ajudam na construção de analisadores descendentes e ascendentes
  - Ajudam a escolher qual produção aplicar
  - Podem servir de tokens de sincronização durante a recuperação em modo pânico
    - Mais sobre isso depois

Conjuntos primeiros

- α é uma cadeia de símbolos gramaticais
  - Não necessariamente de terminais

- `primeiros(α)`
  - É o conjunto de terminais que começam as cadeias derivadas de α

- Gramática
  - $S \rightarrow A\ B$
  - $A \rightarrow a\ A \mid a$
  - $B \rightarrow b\ B \mid c$

Conjuntos primeiros

- Gramática
  - $S \rightarrow A\ B$
  - $A \rightarrow a\ A \mid a$
  - $B \rightarrow b\ B \mid c$

- primeiros(S) = {a}
- primeiros(AB) = {a}
- primeiros(bB) = {b}

primeiros(A) = {a}
primeiros(aA) = {a}
primeiros(B) = {b,c}

- Obs: primeiros pode ser calculado para qualquer cadeia envolvendo terminais e/ou não-terminais

Conjunto primeiros

- Para calcular `primeiros(X)`
  - Onde X é um único símbolo (terminal ou não-terminal)

1. Se X é um terminal, `primeiros(X)` = {X}
2. Se X é um não-terminal e $X \rightarrow Y_1Y_2...Y_k$ é uma produção ($k \geq 1$)
   - Insira "a" em `primeiros(X)` se, para algum i:
     - "a" está em `primeiros(`Y_i`)` (obs: $a \neq \varepsilon$)
     - ε está em todos os `primeiros(`Y_1`)`,...,`primeiros(`Y_{i-1}`)`, ou seja,
       - $Y_1...Y_{i-1} \Rightarrow^* \varepsilon$
   - Insira ε em `primeiros(X)` se ε está em `primeiros(`Y_j`)` para todo j=1,2,...,k
3. Se $X \rightarrow \varepsilon$ é uma produção, então insira ε em `primeiros(X)`

Conjunto primeiros

- Para calcular `primeiros(X)`
  - Onde X é um único símbolo (terminal ou não-terminal)

1. Se X é um terminal, `primeiros(X)` = {X}
2. Se X é um não-terminal e $X \rightarrow Y_1 Y_2 ... Y_k$ é uma produção ($k \geq 1$)
   - Insira "a" em `primeiros(X)` se, para algum i:
     - "a" está em `primeiros(`Y_i`)` (obs: $a \neq \varepsilon$)
     - ε está em todos os `primeiros(`Y_1`)`,...,`primeiros` $_1$`)`, ou seja,
       - $Y_1 ... Y_{i-1} \Rightarrow^* \varepsilon$
   - Insira ε em `primeiros(X)` se ε está em p todo j=1,2,...,k
3. Se $X \rightarrow \varepsilon$ é uma produção, então insira ε em

Significa que preciso olhar todas as produções de X

Conjunto primeiros

- Para calc
  - Onde X (terminal ou nã

1. Se X é um t al, primeiros(X) = {X}
2. Se X é um não-terminal e X → $Y_1Y_2...Y_k$ é um
   - Insira "a" em primeiros(X) se, para algum i
     - "a" está em primeiros(Y_i) (obs: a ≠ ε)
     - ε está em todos os primeiros(Y_1),...,primeiros(Y_{i-1}), ou seja,
       - $Y_1...Y_{i-1} \Rightarrow^* \varepsilon$
   - Insira ε em primeiros(X) se ε está em primeiros(Y_j) para todo j=1,2,...,k
3. Se X → ε é uma produção, então insira ε em primeiros(X)

Todo mundo de primeiros(Y1) vai para primeiros(X) (Exceto ε)

Obs: veja que até agora o ε não é inserido, mesmo que ele apareça em alguns primeiros

Conjunto primeiros

- Para calcular `primeiros(X)`
  - Onde X é um único símbolo (terminal ou não-terminal)

1. Se X é um terminal, `primeiros(X)` = {X}
2. Se X é um não-terminal e $X \rightarrow Y_1 Y_2 \ldots Y_k$ é uma produção ($k \geq 1$)
   - Insira "a" em `primeiros(X)` se, para algum i:
     - "a" está em $\texttt{primeiros}(Y_i)$ (obs: $a \neq \varepsilon$)
     - ε está em todos os $\texttt{primeiros}(Y_1)$,...,$\texttt{primeiros}(Y_{i-1})$, ou seja,
       - $Y_1 \ldots Y_{i-1} \Rightarrow^* \varepsilon$
   - Insira ε em `prim` `iros(X)` s ε está em $\texttt{primeiros}(Y_j)$ para todo j=1,2,...,k
3. Se $X \rightarrow \varepsilon$ é uma p ção, então a ε em `primeiros(X)`

Se primeiros(Y1) contém ε, então também insiro os primeiros(Y2) (Exceto ε)

Se primeiros(Y1) e primeiros(Y2) contém ε, então também insiro os primeiros(Y3) (Exceto ε)

E assim por diante...

Conjunto primeiros

- Para calcular `primeiros(X)`
  - Onde X é um único símbolo (terminal ou não-terminal)

1. Se X é um terminal, `primeiros(X)` = {X}
2. Se X é um não-terminal e $X \rightarrow Y_1Y_2...Y_k$ é uma produção ($k \geq 1$)
   - Insira "a" em `primeiros(X)` se, para algum i:
     - "a" está em $\texttt{primeiros}(Y_i)$ (obs: $a \neq \varepsilon$)
     - ε está em todos os $\texttt{primeiros}(Y_1)$,...,$\texttt{primeiros}(Y_{i-1})$, ou seja,
       - $Y_1...Y_{i-1} \Rightarrow^* \varepsilon$
   - Insira ε em `primeiros(X)` se ε está em $\texttt{primeiros}(Y_j)$ para todo j=1,2,...,k
3. Se $X \rightarrow \varepsilon$ é uma produção, então insira ε em `primeiros(X)`

Agora sim: se ε aparece sozinho no lado direito, ou se está em TODOS os primeiros de TODOS os símbolos à direita, então ele entra!

Conjunto primeiros

- E → TE’
- E’ → +TE’ | ε
- T → FT’
- T’ → *FT’ | ε
- F → (E) | id
- X → E’T
- Y → T’E’

primeiros(E)={(,id}
primeiros(T)={(,id}
primeiros(F)={(,id}
primeiros(“(“)={(}
primeiros(id)={id}
primeiros(E’)={+,ε}
primeiros(+)={+}
primeiros(T’)={*,ε}
primeiros(*)={*}
primeiros(X)={+,(,id}
primeiros(Y)={*,+,ε}

Conjunto primeiros

- Nosso interesse é calcular o conjunto primeiros de uma cadeia de símbolos gramaticais
  - Para ajudar na análise sintática
- Para calcular `primeiros`($X_1X_2...X_n$)
  - Adicione todos os símbolos (exceto ε) de `primeiros`(X_1)
  - Se ε está em `primeiros`(X_1), adicione também todos os símbolos (exceto ε) de `primeiros`(X_2)
  - Se ε está em `primeiros`(X_1) e `primeiros`(X_2), adicione também todos os símbolos (exceto ε) de `primeiros`(X_3)
  - ...
  - Se ε está em `primeiros` de TODOS os X_i, então adicione ε

Conjunto primeiros

- E → TE’
- E’ → +TE’ | ε
- T → FT’
- T’ → *FT’ | ε
- F → (E) | id
- X → E’T
- Y → T’E’

```
primeiros(E)={(,id}
primeiros(T)={(,id}
primeiros(F)={(,id}
primeiros("(")={(}
primeiros(id)={id}
primeiros(E')={+,ε}
primeiros(+)={+}
primeiros(T')={*,ε}
primeiros(*)={*}
primeiros(X)={+,(,id}
primeiros(Y)={*,+,ε}
```

primeiros(TE’)={(,id}
primeiros(+TE’)={+}
primeiros(FT’)={(,id}
primeiros(*FT’)={*}
primeiros(“(“E”)”)={(}
primeiros(E’T)={+,(,id}
primeiros(T’E’)={*,+,ε}

Conjuntos seguidores

- A é um não-terminal

- `seguidores(A)`
  - É o conjunto de terminais que podem aparecer imediatamente após A em alguma forma sentencial
    - Em outras palavras, é o conjunto de terminais a tal que existe uma derivação na forma $S \overset{*}{\Rightarrow} \alpha A a \beta$
    - $\{a \mid S \overset{*}{\Rightarrow} \alpha A a \beta\}$

Conjuntos seguidores

- Símbolo especial $ (fim de cadeia)
  - Se A pode ser o símbolo mais à direita em alguma forma sentencial, $ está em seguidores(A)

- Gramática
  - $S \rightarrow A\ B$
  - $A \rightarrow a\ A \mid a$
  - $B \rightarrow b\ B \mid c$

- seguidores(S) = {$}
- seguidores(A) = {b,c}
- seguidores(B) = {$}

Conjunto seguidores

- Para calcular o conjunto `seguidores`

1. Adicione $ a `seguidores(S)`
   - S é o símbolo inicial

2. Se existir uma produção A → αBβ, adicione os `primeiros(β)` a `seguidores(B)` (exceto ε)

3. Se existir uma produção A → αB, ou uma produção A → αBβ onde `primeiros(β)` contém ε, adicione os `seguidores(A)` a `seguidores(B)`

Conjunto seguidores

- E → TE’
- E’ → +TE’ | ε
- T → FT’
- T’ → *FT’ | ε
- F → (E) | id

```
primeiros(E)={(,id}
primeiros(T)={(,id}
primeiros(F)={(,id}
primeiros("(")={(}
primeiros(id)={id}
primeiros(E')={+,ε}
primeiros(+)={+}
primeiros(T')={*,ε}
primeiros(*)={*}
primeiros(TE')={(,id}
primeiros(+TE')={+}
primeiros(FT')={(,id}
primeiros(*FT')={*}
primeiros("("E")")={(}
primeiros(E'T)={+,(,id}
primeiros(T'E')={*,+,ε}
```

seguidores(E)={$,)}
seguidores(E’)={$,)}
seguidores(T)={+,$,)}
seguidores(T’)={+,$,)}
seguidores(F)={*,+,$,)}

Exercício

- Construa os conjuntos primeiros e seguidores para a seguinte gramática

```
expr → expr soma termo | termo
soma → + | -
termo → termo mult fator | fator
mult → *
fator → ( expr ) | número
```

Resposta

```
expr → expr soma termo | termo
soma → + | -
termo → termo mult fator | fator
mult → *
fator → ( expr ) | número
```

primeiros(expr)={(,número}

primeiros(soma)={+,-}

primeiros(termo)={(,número}

primeiros(mult)={*}

primeiros(fator)={(,número}

primeiros(expr soma termo)={(,número}

primeiros(termo mult fator)={(,número}

primeiros("(" expr ")")={(}

Resposta

```
primeiros(expr)={(,número}
primeiros(soma)={+,-}
primeiros(termo)={(,número}
primeiros(mult)={*}
primeiros(fator)={(,número}
primeiros(expr soma termo)={(,número}
primeiros(termo mult fator)={(,número}
primeiros("(" expr ")")={(}
```

seguidores(expr)={$,),+,-}
seguidores(soma)={(,número}
seguidores(termo)={$,),+,-,*}
seguidores(mult)={(,número}
seguidores(fator)={$,),+,-,*}

Exercício

- Construa os conjuntos primeiros e seguidores para a seguinte gramática

```
declaracao → if-decl | 'outra'
if-decl → 'if' '(' exp ')' declaracao
 else-parte
else-parte → 'else' declaracao | ε
exp → '0' | '1'
```

Resposta

```
declaracao → if-decl | 'outra'
if-decl → 'if' '(' exp ')' declaracao else-parte
else-parte → 'else' declaracao | ε
exp → '0' | '1'
```

primeiros(declaracao)={'outra','if'}

primeiros(if-decl)={'if'}

primeiros(else-parte)={'else',ε}

primeiros(exp)={'0','1'}

Resposta

```
declaracao → if-decl | 'outra'
if-decl → 'if' '(' exp ')' declaracao else-parte
else-parte → 'else' declaracao | ε
exp → '0' | '1'

primeiros(declaracao)={'outra','if'}
primeiros(if-decl)={'if'}
primeiros(else-parte)={'else',ε}
primeiros(exp)={'0','1'}
```

seguidores(declaracao)={$,'else'}
seguidores(if-decl)={$,'else'}
seguidores(else-parte)={$,'else'}
seguidores(exp)={')'}

Gramáticas LL

Gramáticas LL(k)

- LL(k) = classe de gramáticas / analisador sintático
  - Left-to-right = da esquerda para a direita
  - Leftmost derivation = derivação mais à esquerda
  - k = # símbolos à frente para previsão correta

- k > 1 geralmente acarreta em baixa eficiência
  - Por isso, estudaremos inicialmente o caso LL(1)

- LL(1) é bastante rica para a maioria das construções de linguagens de programação
  - Mas exige cuidado e trabalho
  - Por exemplo, é preciso remover ambiguidade e recursão à esquerda

Gramáticas LL(1)

- Uma gramática G é LL(1) sse para duas produções distintas $A \rightarrow \alpha \mid \beta$:
  - α e β não derivam cadeias começando com o mesmo terminal
  - No máximo um dentre α e β deriva a cadeia vazia
  - Se $\beta \overset{*}{\Rightarrow} \varepsilon$, então α não deriva nenhuma cadeia começando com um terminal em seguidores(A)
    - O correspondente vale para α

Gramáticas LL(1)

- Uma gramática G é LL(1) sse para d
distintas $A \rightarrow \alpha \mid \beta$:

primeiros(α) e primeiros(β) são disjuntos

  - α e β não derivam cadeias começando com o mesmo terminal
  - No máximo um dentre α e β deriva a cadeia vazia
  - Se $\beta \stackrel{*}{\Rightarrow} \varepsilon$, então α não deriva nenhuma cadeia começando com um terminal em seguidores(A)
    - O correspondente vale para α

Gramáticas LL(1)

- Ex: a gramática a seguir não é LL(1)

```
declaracao → if-decl | 'outra'
if-decl → 'if' '(' exp ')' declaracao
  else-parte
else-parte → 'else' declaracao | ε
exp → '0' | '1'
comando → declaracao | if-decl
```

```
primeiros(declaracao)={'outra','if'}
primeiros(if-decl)={'if'}
```

Gramáticas LL(1)

- Ex: a gramática a seguir não é LL(1)

ExprRel → TermoRel ExprRel2

ExprRel2 → 'OU' FatorRel ExprRel2 | ε

FatorRel → '(' ExprRel ')' | Expr '<' Expr

Expr → Termo Expr2

Expr2 → '+' Termo Expr2 | ε

Termo → Fator Termo2

Termo2 → '*' Fator Termo2 | ε

Fator → '(' Expr ')' | id

primeiros('(' ExprRel ')')={'('}

primeiros(Expr '<' Expr)={id, '('}

Gramáticas LL(1)

- Uma gramática G é LL(1
distintas A → α | β:
  - α e β não derivam cad
mesmo terminal
  - No máximo um dentre α ... deriva a cadeia vazia
  - Se β *⇒ ε, então α não deriva nenhuma cadeia começando com um terminal em seguidores(A)
    - O correspondente vale para α

Quer dizer que se ε está em `primeiros(β)`, então `primeiros(α)` e `seguidores(A)` são disjuntos

Gramáticas LL(1)

- Ex: a gramática a seguir não é LL(1)

```
listaComandos → comando ';' listaComandos |
  '{' listaComandos '}'
comando → if-decl | 'outra' | ε
if-decl → 'if' '(' exp ')' then-parte
then-parte → comandoThen | listaComandos
comandoThen → 'soma' | ε
exp → '0' | '1'
```

then-parte → comandoThen | listaComandos

```
primeiros(comandoThen)={'soma',ε}
primeiros(listaComandos)={'if','outra',';','{'}
seguidores(then-parte)={';'}
```

Gramáticas LL(1)

- Estas condições garantem ser possível escolher a produção apropriada olhando apenas o símbolo atual

- Ex:

```
cmd → 'if' '(' expr ')' cmd else cmd
          | 'while' '(' expr ')' cmd
          | '{' listaCmd '}'
```

- Se o símbolo atual for ‘if’, ‘while’ ou ‘{‘ é possível decidir exatamente qual alternativa usar

- Implementação é simples: basta um if (ou switch)

Gramáticas LL(1)

- Em um analisador sintático preditivo de descendência recursiva
  - Essas condições facilitam a implementação da escolha da alternativa

- No exemplo anterior de implementação manual, fizemos a “predição” usando apenas raciocínio
  - Mas é possível utilizar um algoritmo
  - Baseado nas condições das gramáticas LL(1)

Tabela LL(1)

- Tabela de predição
  - Array bidimensional M[A,a]
  - Linha corresponde à produção atual
  - Coluna corresponde ao próximo terminal

	Terminais e $
Não-terminais	

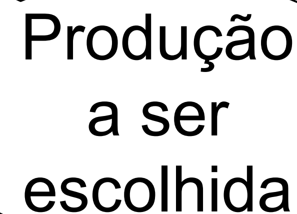

Tabela LL(1)

- Ideia geral
  - A produção $A \rightarrow \alpha$ é escolhida se o próximo símbolo de entrada “a” estiver em `primeiros(α)`
  - Se $\alpha = \varepsilon$ ou $\alpha \overset{*}{\Rightarrow} \varepsilon$, escolhemos $A \rightarrow \alpha$ se
    - o próximo símbolo de entrada “a” estiver em `seguidores(A)`
    - se $ foi alcançado e $ está em `seguidores(A)`

Tabela LL(1)

- Objetivo
  - Colocar na tabela as possibilidades de escolha de produção, dados:
    - Um símbolo da entrada (terminal)
      - que representa o próximo símbolo a ser lido
    - A produção (não-terminal) sendo expandida
      - que representa qual símbolo precisa ser substituído no processo de derivação

Tabela LL(1)

- Algoritmo
  1. Para cada terminal “a” em `primeiros(α)`
     - Adicione A → α em M[A,a]
  2. Se ε está em `primeiros(α)` então, para cada terminal “b” em `seguidores(A)`
     - Adicione A → α em M[A,b]
  3. Se ε está em `primeiros(α)` e $ está em `seguidores(A)`
     - Adicione A → α em M[A,$]

- Células vazias correspondem a erro sintático

Exemplo Tabela LL(1)

- E → TE'
- E' → +TE' | ε
- T → FT'
- T' → *FT' | ε
- F → (E) | id

```
primeiros(E)={(,id}
primeiros(T)={(,id}
primeiros(F)={(,id}
primeiros("(")={(}
primeiros(id)={id}
primeiros(E')={+,ε}
primeiros(+)={+}
primeiros(T')={*,ε}
primeiros(*)={*}
primeiros(TE')={(,id}
primeiros(+TE')={+}
primeiros(FT')={(,id}
primeiros(*FT')={*}
primeiros("("E")")={(}
primeiros(E'T)={+,(,id}
primeiros(T'E')={*,+,ε}
```

```
seguidores(E)={$,)}
seguidores(E')={$,)}
seguidores(T)={+,$,)}
seguidores(T')={+,$,)}
seguidores(F)={*,+,$,)}
```

Exemplo Tabela LL(1)

	+	*****	**(**	**)**	**id**	**$**
E			E→TE’		E→TE’	
E’	E’→+TE’			E’→ε		E’→ε
T			T→FT’		T→FT’	
T’	T’→ε	T’→*FT’		T’→ε		T’→ε
F			F→(E)		F→id	

Exercício Tabela LL(1)

- Construa a tabela LL(1) da gramática

$S \rightarrow iEtSS' \mid a$

$S' \rightarrow eS \mid \varepsilon$

$E \rightarrow b$

primeiros(iEtSS')={i}

primeiros(a)={a}

primeiros(eS)={e}

primeiros(b)={b}

seguidores(S)={$,e}

seguidores(S')={$,e}

seguidores(E)={t}

Tabela LL(1)

- Resposta

	i	**t**	**e**	**a**	**b**	**$**
S	S→iEtSS'			S→a		
S'			S'→eS S'→ε			S'→ε
E					E→b	

Não-determinismo causado pela ambiguidade da gramática

Tabela LL(1)

- O algoritmo anterior serve, portanto, para detectar se uma gramática é LL(1)
  - Células com múltiplos valores são indícios de:
    - Ambiguidade
    - Necessidade de fatoração
    - Recursão à esquerda

- Pode ajudar a transformar uma gramática em LL(1)
  - Mas existem gramáticas que nunca podem ser transformadas em LL(1)
  - Gramática do exercício anterior é um exemplo

Algoritmo LL(1)

- Sugestão para implementar o algoritmo LL(1) em um analisador sintático de descendência recursiva
  1. Monte a tabela LL(1) para a gramática
  2. O seguinte pseudocódigo ilustra a estratégia, para cada não-terminal T

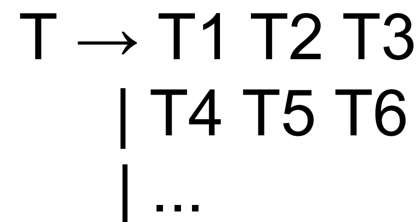


```
void T() {
  Token atual = obterTokenAtual();
  int alt = M[T,atual];
  if(alt == 1) { T1(); T2(); T3(); }
  else if(alt == 2) {T4(); T5(); T6(); }
  … }
```

Analisador sintático preditivo sem recursividade

Lembrando um pouco de LFA

- Estamos lidando com gramáticas livres de contexto
  - Gramáticas LL(1), para ser mais específico
- A máquina capaz de processar este tipo de linguagem é um PDA
  - Autômato com pilha
- Mas acabamos de implementar um analisador que não usa pilha!!!

Lembrando um pouco de LFA

- Mas acabamos de implementar um analisador que não usa pilha!!!
  - Aí é que você se engana!
  - Recursividade e pilha são intimamente relacionados
    - Cada chamada recursiva equivale a um empilhamento
    - Cada retorno de chamada recursiva equivale a um desempilhamento

Análise preditiva sem recursão

- Veremos agora um modelo baseado no uso de uma pilha

- É o mesmo algoritmo da versão recursiva
  - Mas aqui a sequência de derivação fica explícita

- É um bom exercício de compreensão do processo de análise LL(1)

Análise preditiva sem recursão

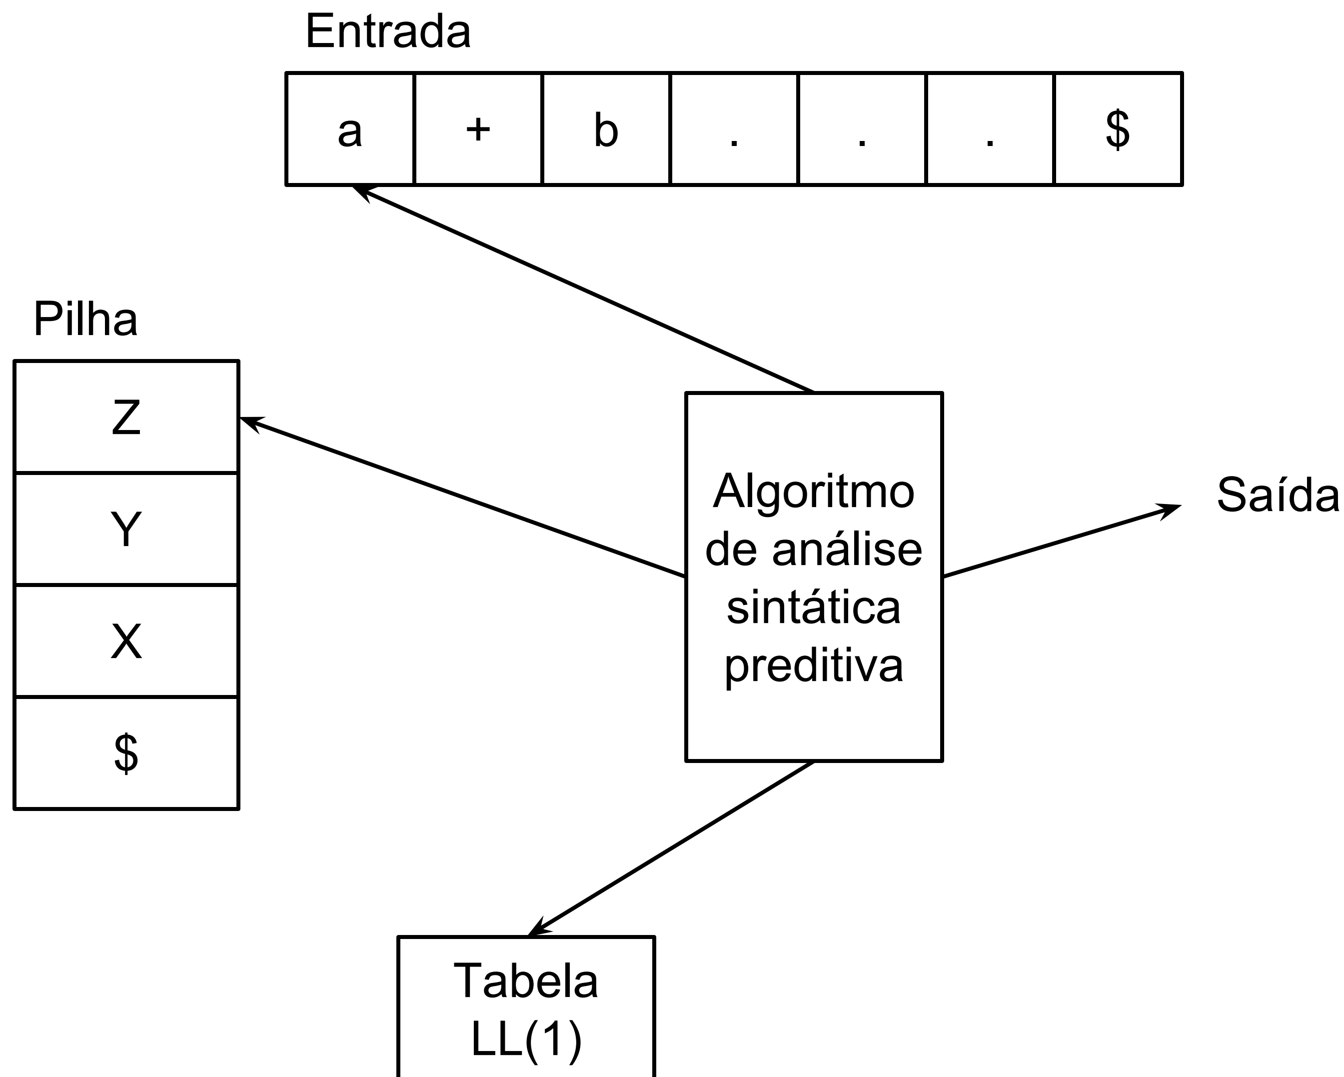

Análise preditiva sem recursão

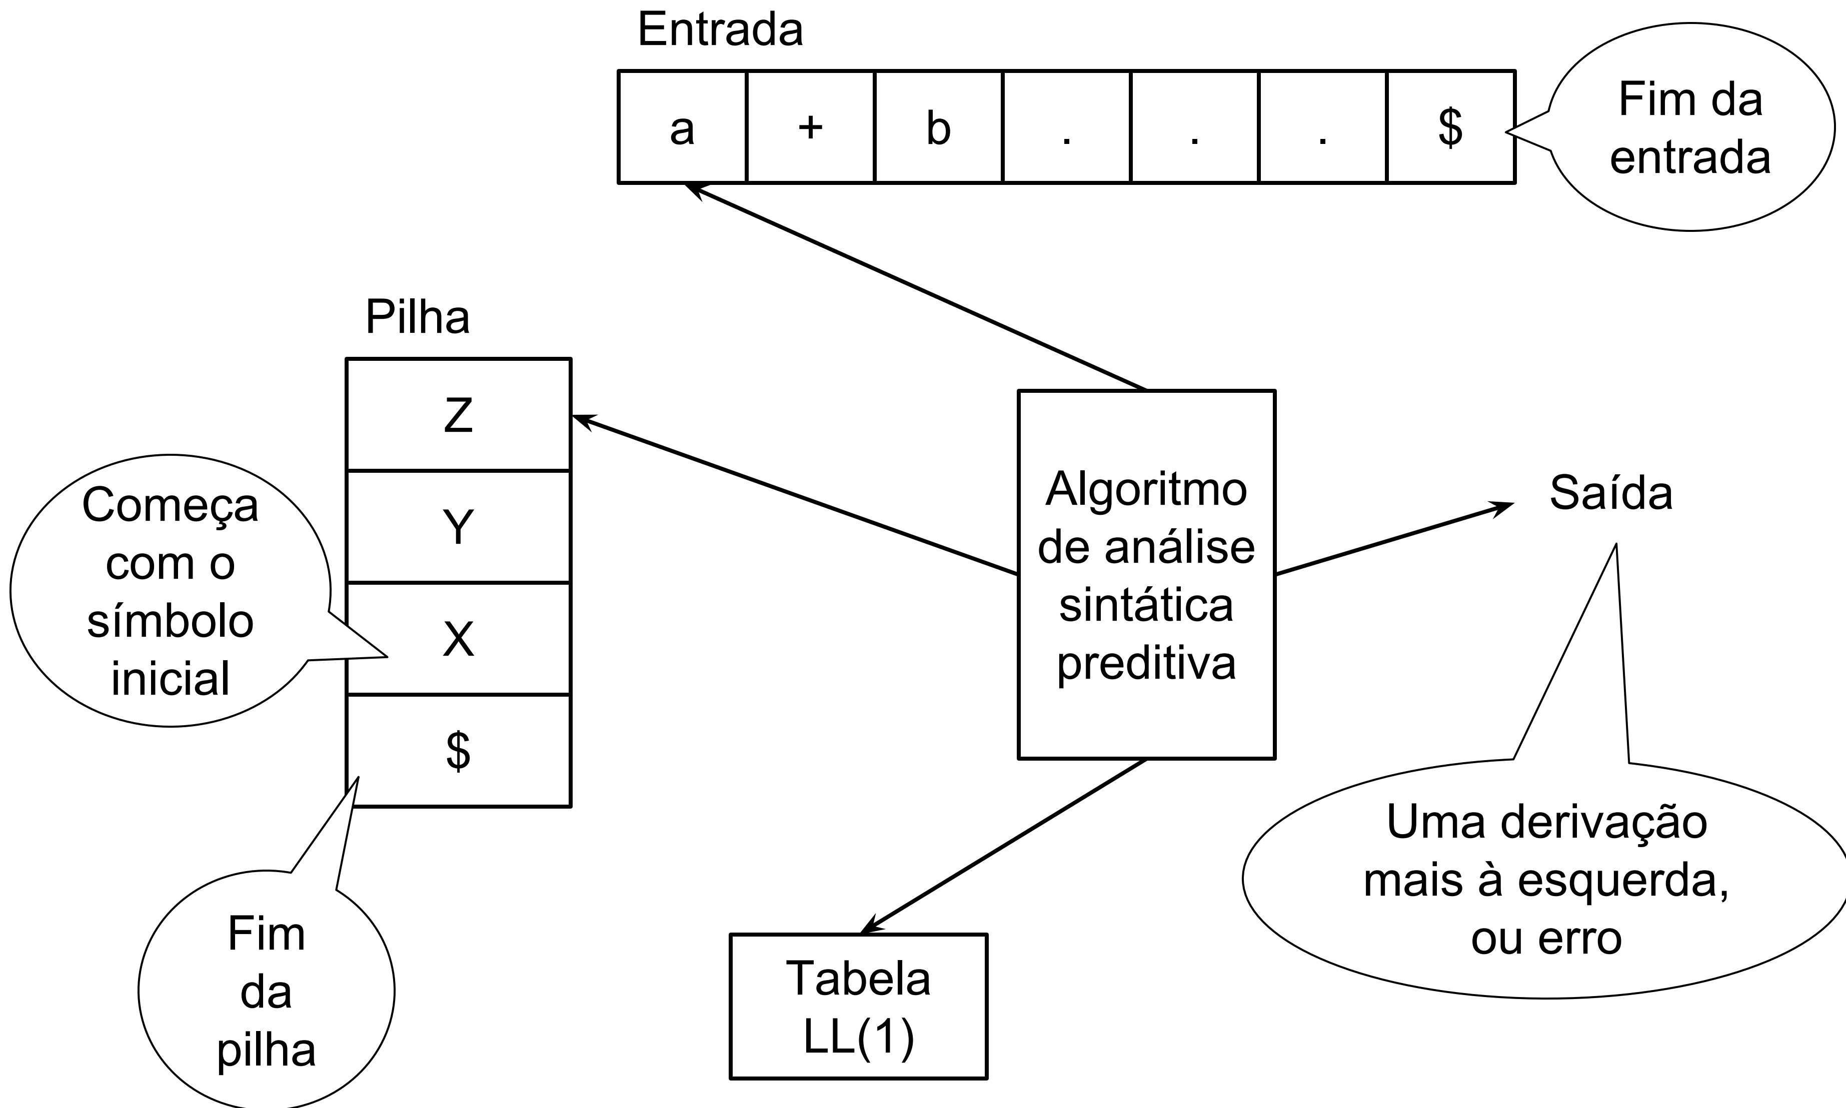

Algoritmo de análise sintática preditiva

```
Condições iniciais:
   entrada = w$
   símbolo S no topo da pilha, sobre $
Algoritmo:
1.     ip = primeiro símbolo de w
2.     X = topo da pilha // inicialmente, X = S
3.     enquanto(X != $) { // pilha não vazia
4.        a = w[ip]
5.        se(X == a) desempilhar e avançar ip
6.        senão se(X é terminal) erro
7.        senão se(M[X,a] é vazio) erro
8.        senão se(M[X,a] = X→Y1Y2...Yk {
9.           imprimir "X→Y1Y2...Yk"
10.          desempilhar
11.          empilhar Yk,Yk-1,...,Y1 // nessa ordem
12.       }
13.       X = topo da pilha
14.    }
```

Análise sintática preditiva sem recursão

- Exercício
  - Entrada = id + id * id $

$E \rightarrow TE'$

$E' \rightarrow +TE' \mid \varepsilon$

$T \rightarrow FT'$

$T' \rightarrow *FT' \mid \varepsilon$

$F \rightarrow (E) \mid id$

	+	*****	**(**	**)**	**id**	**$**
E			E→TE’		E→TE’	
E’	E’→+TE’			E’→ε		E’→ε
T			T→FT’		T→FT’	
T’	T’→ε	T’→*FT’		T’→ε		T’→ε
F			F→(E)		F→id	

Exercício

Casamento	Pilha	Entrada	Ação
	E$	**id**+id*id$	E→TE′
	TE′$	**id**+id*id$	T→FT′
	FT′E′$	**id**+id*id$	F→id
	idT′E′$	**id**+id*id$	match
id	**T′**E′$	**+**id*id$	T′→ε
	E′$	**+**id*id$	E′→+TE′
	+TE′$	**+**id*id$	match
id**+**	**T**E′$	**id***id$	T→FT′
	FT′E′$	**id***id$	F→id
	idT′E′$	**id***id$	match
id+**id**	**T′**E′$	*****id$	T′→*FT′
	*****FT′E′$	*****id$	match
id+id*****	**F**T′E′$	**id**$	F→id
	idT′E′$	**id**$	match
id+id***id**	**T′**E′$	**$**	T′→ε
	E′$	**$**	E′→ε
	$	**$**	OK

Recuperação de erros

Recuperação de erros

- Ao se deparar com erros sintáticos, o que fazer?
  - Relatar os erros o quanto antes, de modo claro e preciso
  - (opcional) corrigir erros mais simples (ex: ponto-e-vírgula faltando)
  - Continuar a análise
  - Evitar o problema da cascata de erros
  - Evitar laços infinitos na tentativa de recuperação de erros
  - Não atrasar muito o processamento de programas corretos
- Tarefa difícil
- Na maioria das vezes, feita de forma ad hoc

Recuperação de erros

- Há duas situações de erro na técnica LL apresentada:
  1. A pilha tem um terminal no topo, que é diferente do próximo símbolo de entrada
  2. A entrada na tabela LL(1) para o próximo símbolo de entrada e não-terminal no topo da pilha é vazia

Recuperação de erros

- Não vamos entrar em muitos detalhes, pois são técnicas muito avançadas
  - Quem precisar implementar um compilador profissional pode posteriormente se aprofundar nesse tópico
- Mas veremos duas estratégias básicas
  - Modo pânico
  - Recuperação em nível de frase

Recuperação de erros – modo pânico

- Estratégia:
  - Uma vez encontrado um erro, ignorar símbolos até um ponto de sincronismo
  - A partir do qual se sabe continuar
- Ex:

Pilha	Entrada	Ação
if-decl$	**if**(*2>3) then outra$	
if expr then cmd else cmd$	**if**(*2>3) then outra$	
expr then cmd else cmd$	**(**(*2>3) then outra$	
(expr) then cmd else cmd$	**(***2>3) then outra$	
expr) then cmd else cmd$	*****2>3) then outra$	Pular até achar um ")" e desempilha o símbolo atual
) then cmd else cmd$	**)** then outra$	Sincronismo
...	...	...

Recuperação de erros – modo pânico

- A eficácia depende da escolha dos tokens de sincronização
- Evita loop infinito
- Porém, pode descartar muitos tokens
  - Nos piores casos, pode descartar quase o programa inteiro

Recuperação de erros – modo pânico

- Heurísticas para escolha dos tokens de sincronização

1. Todos os símbolos seguidores de um não-terminal são tokens de sincronização para esse terminal
   - Não é suficiente. Por exemplo, “;” é seguidor de muitos não-terminais, o que pode levar ao descarte de muitos tokens desnecessariamente
2. Utilizar a hierarquia
   - Programa > blocos > comandos > expressões
   - Usar palavras-chave dos não-terminais mais altos na hierarquia como tokens de sincronização para os não-terminais mais baixos na hierarquia
   - Ex: “if”, “while”, “for” são tokens de sincronização para o não-terminal “Expr”

Recuperação de erros – modo pânico

3. Se um terminal no topo da pilha não puder casar com o terminal da entrada
   - Solução simples: fazer de conta que o terminal estava lá e continuar a análise
   - Emitir uma mensagem (ou não)
   - Ex: HTML

```
1 <html>
2 <head>
3 </head>
4 <body>
5 <table>
6     <tr><td>celula 1</tr>
7     <tr><td>celula2</td></tr>
8 </table>
9 </body>
```

Arquivo HTML original

```
▼<html>
   <head></head>
 ▼<body>
   ▼<table>
     ▼<tbody>
       ▼<tr>
           <td>celula 1</td>
         </tr>
       ▼<tr>
           <td>celula2</td>
         </tr>
       </tbody>
     </table>
   </body>
</html>
```

Elemento sendo inspecionado no Google Chrome

Recuperação de erros em nível de frase

- Consiste em preencher as entradas vazias da tabela com ponteiros para rotinas de tratamento de erro
- Essas rotinas podem modificar, inserir ou remover símbolos da entrada e emitir as mensagens apropriadas
- As rotinas implementam maneiras de recuperação de erro específicas para a linguagem
  - Em contraste com o modo pânico, que sempre ignora tokens até achar um de sincronização
- Por exemplo: ao encontrar
  - while(2 > 3)) { comandos... }
- O analisador pode desconsiderar o segundo parêntese e tentar continuar
  - IMPORTANTE: “desconsiderar” significa relatar e continuar tentando, e não tratar o programa como se estivesse correto!
  - Em outras palavras, o programa não deve “compilar” com sucesso!

LL(k) e LL(*)

LL(k)

- A grande vantagem do algoritmo LL(1) é a sua possibilidade de automação!
  - É possível construir analisadores à mão, claro
  - Mas estamos interessados em poupar trabalho (tempo=dinheiro)
- A princípio, é simples estender o algoritmo LL(1) para LL(k), onde k > 1
  - Ao invés de `primeiros` e `seguidores`, teríamos $\texttt{primeiros}_k$ e $\texttt{seguidores}_k$
  - Teríamos uma LL(k), construída exatamente da mesma maneira
- A diferença é que, ao tentar prever qual regra usar, é preciso olhar (e comparar) k símbolos adiante

LL(k)

- Exemplo:

```
stat : ID '=' expr
     | ID ':' stat
     ;
```

Essa gramática não é LL(1), mas é LL(2)

É possível gerar o seguinte analisador preditivo de descendência recursiva

```
void stat() {
  if ( LA(1)==ID&&LA(2)==EQUALS ) { // PREDICT
    match(ID);                      // MATCH
    match(EQUALS);
    expr();
  }
  else if ( LA(1)==ID&&LA(2)==COLON ) { // PREDICT
    match(ID);                          // MATCH
    match(COLON);
    stat();
  }
  else «error»;
}
```

LL(k)

- Mas na prática, k>1 não é muito interessante
  - Essa tabela seria (exponencialmente) grande, com muitas colunas, para cobrir todas as combinações de k símbolos à frente
  - Segundo, a tabela LL(k) como vimos não expressa realmente todo o poder da análise LL(k). Isto porque, para k>1, a tabela precisaria considerar diferentes contextos para os conjuntos seguidores
  - Terceiro, se uma gramática não é LL(1), ela provavelmente não é LL(k) também
    - Exemplo: recursividade à esquerda independe de k

LL(k)

- Outro exemplo de uma gramática que não é LL(k)
  - Nenhum k fixo pode resolver o problema de decidir qual regra usar

```
method
    : type ID '(' args ')' ';'              // E.g., "int f(int x,int y);"
    | type ID '(' args ')' '{' body '}' // E.g., "int f(int z) {...}"
    ;
type: 'void' | 'int' ;
args: arg (',' arg)* ; // E.g., "int x, int y, int z, ..."
arg : 'int' ID ;
body: ... ;
```

  - Solução (menos legível, ruim para adicionar semântica)

```
method
    :   type ID '(' args ')' (';' | '{' body '}')
    ;
```

LL(k)

- Em resumo, LL(1) era o melhor que podíamos fazer de forma automática
- A alternativa é construir o analisador "na mão" ou partir para a análise LR
  - Que veremos a seguir
- Mas analisadores LR são mais complexos de implementar/utilizar em outros aspectos
  - Apesar de as gramáticas ficarem mais legíveis
- E construir à mão é trabalhoso
- Felizmente, existe uma técnica chamada LL(*), que une o melhor dos mundos LL e LR
  - Foi desenvolvida há alguns anos, e não consta nos livros clássicos de compiladores (Dragão, Louden)

LL(*)

- Outro exemplo

```
def : modifier* classDef      // E.g., public class T {...}
    | modifier* interfaceDef // E.g., interface U {...}
    ;
```

- Podemos fatorar à esquerda (ruim)

```
def : modifiers* (classDef|interfaceDef) ;
```

- Outra opção: método ad hoc

```
def : {findAhead(CLASS_TOKEN)}?     modifier* classDef
    | {findAhead(INTERFACE_TOKEN)}? modifier* interfaceDef
```

LL(*)

- O grande problema dos analisadores LL não é o reconhecimento em si
  - Que é fácil:
    - Não-terminal = naoTerminal()
    - Terminal = match(Terminal)
- O problema é determinar (predizer) corretamente a regra a ser utilizada
- O método findAhead auxilia na predição
  - Ele inspeciona símbolos à frente, em busca de um determinado símbolo
  - O número de símbolos a ser inspecionado é variável
    - k=*, por isso LL(*)

LL(*)

- Voltemos à analogia do labirinto
  - É como se pudéssemos mandar um macaco treinado em busca de uma pista
  - Não precisamos efetivamente ir adiante (e voltar)
    - O que é custoso (retrocesso/backtracking)
- A técnica LL(*) consiste em gerar automaticamente o método lookAhead
  - Com base na definição da gramática
- Vamos então estudar como isso é feito

LL(*)

- Voltando ao exemplo

```
stat : ID '=' expr
     | ID ':' stat
     ;
```

- Nesse caso, a decisão consiste em encontrar um ponto de divergência entre as duas regras
  - Normalmente é um único token que fica alguns símbolos à frente
  - Podemos ver como um DFA!

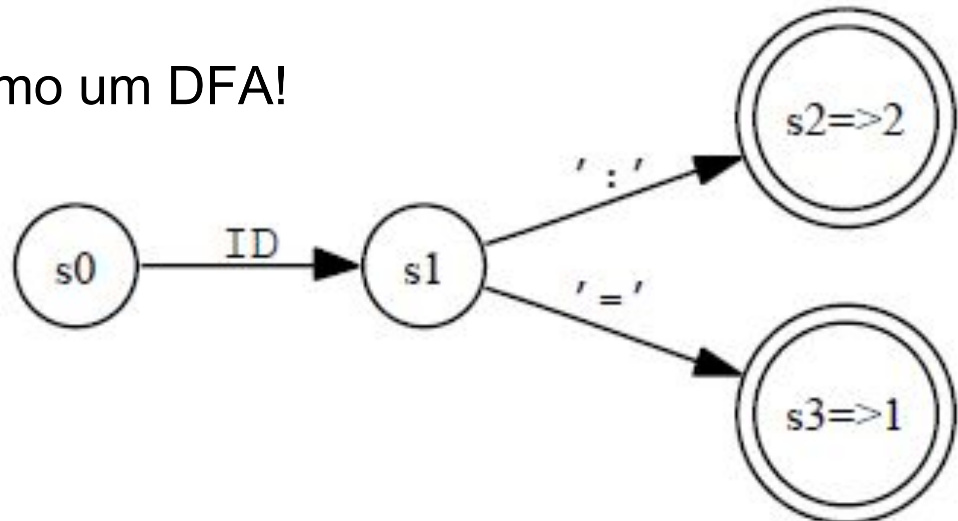

LL(*)

- Faz sentido então pensarmos em um DFA de decisão
  - Um modelo mais simples, não chega a ser uma gramática livre de contexto
    - De fato, é uma gramática regular
  - Serve apenas para tomar a decisão
- Importante:
  - Em análise LL(k), com k fixo, o DFA é sempre ACÍCLICO!!!
    - Ou seja, o macaco não passa por uma mesma sala mais do que uma única vez
  - LL(*) utiliza um DFA que pode conter ciclos

LL(*)

- Observe o seguinte exemplo:

```
def : modifier* classDef
    | modifier* interfaceDef
    ;
```

- O DFA de decisão seria:

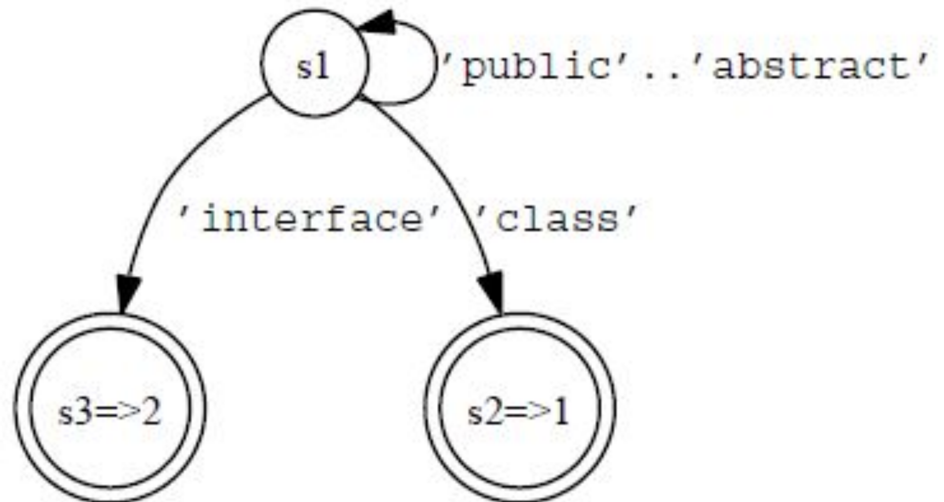

LL(*)

- Possível código para predição

```
void def() {
  int alt=0;
  while (LA(1) in modifier) consume(); // scan past modifiers
  if ( LA(1)==CLASS ) alt=1;              // 'class'?
  else if ( LA(1)==INTERFACE ) alt=2;  // 'interface'?
  switch (alt) {
    case 1 : ...
    case 2 : ...
    default : error;
  }
}
```

LL(*)

- Outro exemplo:

```
method
    : type ID '(' args ')' ';'           // E.g., "int f(int x,int y);"
    | type ID '(' args ')' '{' body '}' // E.g., "int f(int z) {...}"
    ;
type: 'void' | 'int' ;
args: arg (',' arg)* ; // E.g., "int x, int y, int z, ..."
arg : 'int' ID ;
body: ... ;
```

- O DFA ficaria:

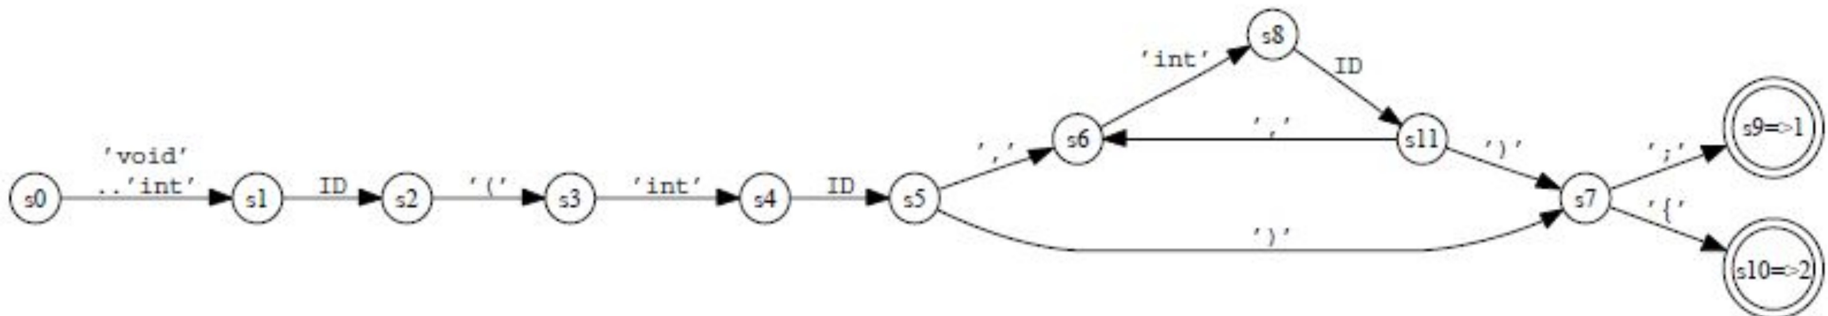

LL(*)

- Mais um exemplo

```
interfaceDef
    :   'interface' ID ('extends' classname)?
        '{'
        (   variableDefinition
        |   methodDefinition
        )*
        '}'
    ;
```

LL(*)

- DFA de decisão para a gramática do slide anterior

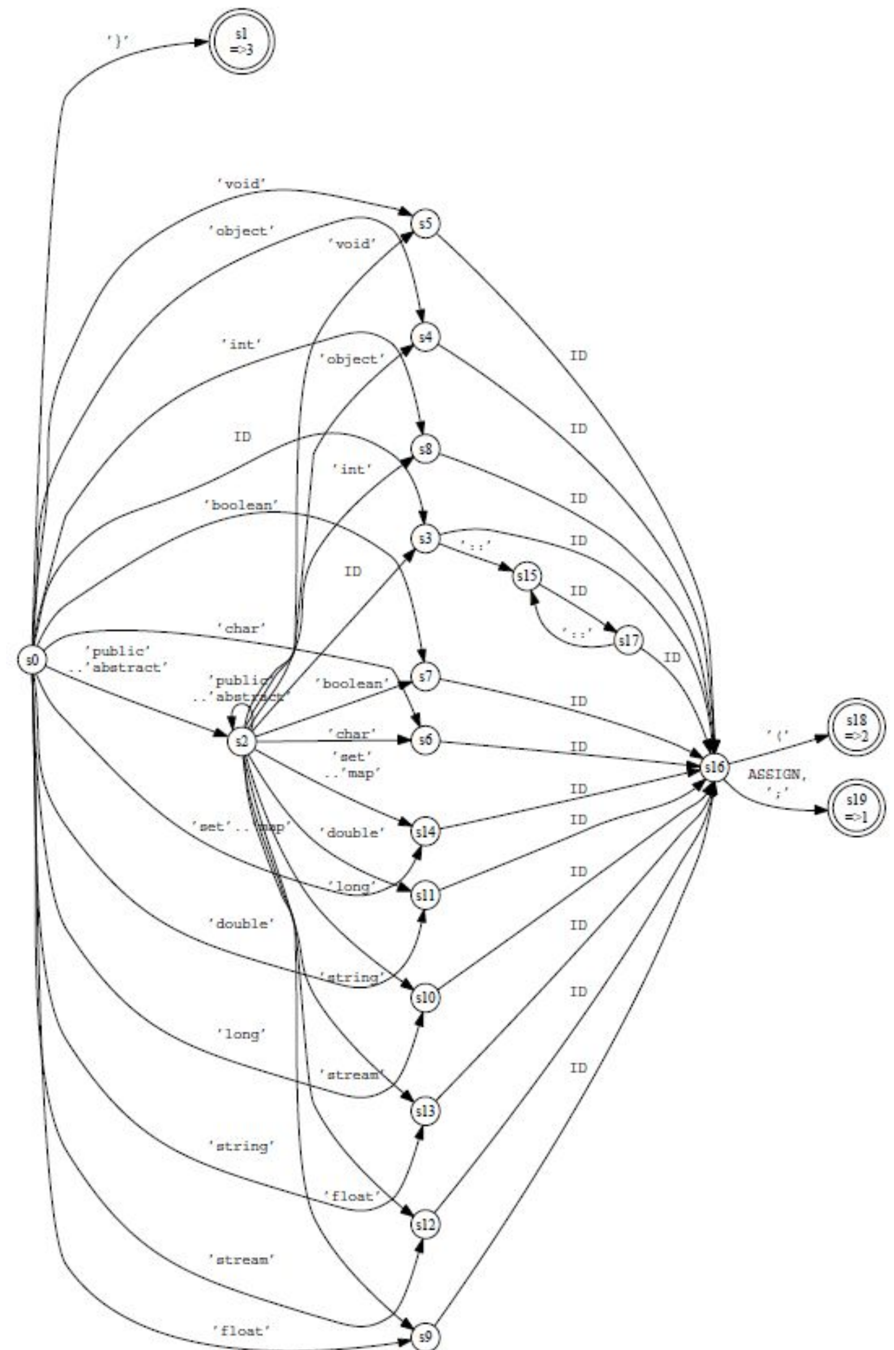

LL(*)

- O DFA de decisão pode ser arbitrariamente complexo
  - Não tem importância, a execução de um DFA é rápida
  - Além disso, o DFA está apenas tentanto predizer a regra
    - Não está executando ações, fazendo chamadas recursivas, o que torna o analisador sintático mais "pesado"
    - É a diferença entre mandar um macaco e ir você mesmo
- Mas eventualmente, ele chegará a um ponto de decisão
  - Um único token que diferencia entre as regras

LL(*)

- Formalmente, a técnica LL(*) usa um DFA que:
  - Reconhece a linguagem de decisão
    - Que deve ser uma linguagem regular!!
  - Não possui estados “mortos”
  - Possui pelo menos um estado de aceitação para cada regra alternativa
- Em outras palavras:
  - Dada uma gramática livre de contexto
  - Sempre que houver mais de uma alternativa
  - Gera-se uma expressão regular que representa a linguagem de decisão para cada alternativa
    - E constrói-se um DFA de decisão

LL(*)

- Ou seja, LL(*) é uma técnica poderosa, com grande poder de reconhecimento
  - Não precisa fatorar à esquerda, o que leva a gramáticas mais intuitivas
  - Permite a geração de analisadores de descendência recursiva
    - Mais legíveis e fáceis de compreender (quando comparado com analisadores LR – que veremos a seguir)
    - Facilita a inserção de ações semânticas (veremos mais adiante)

ALL(*) - Adaptive LL(*)

- Geração do DFA de decisão em tempo de execução
  - Múltiplos subparsers em cada ponto de dúvida
  - Fase de especulação
  - Em caso de ambiguidade: predicado semântico ou "a regra que aparecer primeiro"
- Uso da pilha de execução do parser
  - Para realizar a previsão de acordo com o contexto anterior
- Resultado: qualquer gramática não-recursiva à esquerda pode ser analisada

ALL(*) - ANTLR 4

- Além disso:
  - Reescrita de regras - remoção da recursividade direta à esquerda
  - Muitas otimizações - permite recursividade no léxico!
- Resultado:
  - Quase qualquer gramática "roda" no ANTLR!

ANTLR

ANTLR

- ANTLR é um gerador baseado na técnica ALL(*)
- Gera analisadores sintáticos preditivos de descendência recursiva
  - Facilidade de manutenção/legibilidade
- Suporte a várias linguagens
- Suporte a retrocesso, predicados sintáticos/semânticos
- Suporte para geração de árvores de sintaxe abstrata

Fim