Compiladores - Autômatos

Fabio Mascarenhas – 2015.1

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

Especificação x Implementação

- Usamos expressões regulares para dar a *especificação léxica* da linguagem

- Mas como podemos fazer a *implementação* do analisador léxico a partir dessa especificação?

Especificação x Implementação

- Usamos expressões regulares para dar a *especificação léxica* da linguagem

- Mas como podemos fazer a *implementação* do analisador léxico a partir dessa especificação?

  - Autômatos finitos!

  - Algoritmos para converter expressões regulares são conhecidos e podem ser reaproveitados, e autômatos levam a um analisador léxico bastante eficiente

Autômatos Finitos

- Um autômato finito é formado por:
  - Um *alfabeto* de entrada
  - Um conjunto de *estados*
  - Um *estado inicial*
  - Um conjunto de *estados finais* ***rotulados***
  - Um conjunto de transições entre estados

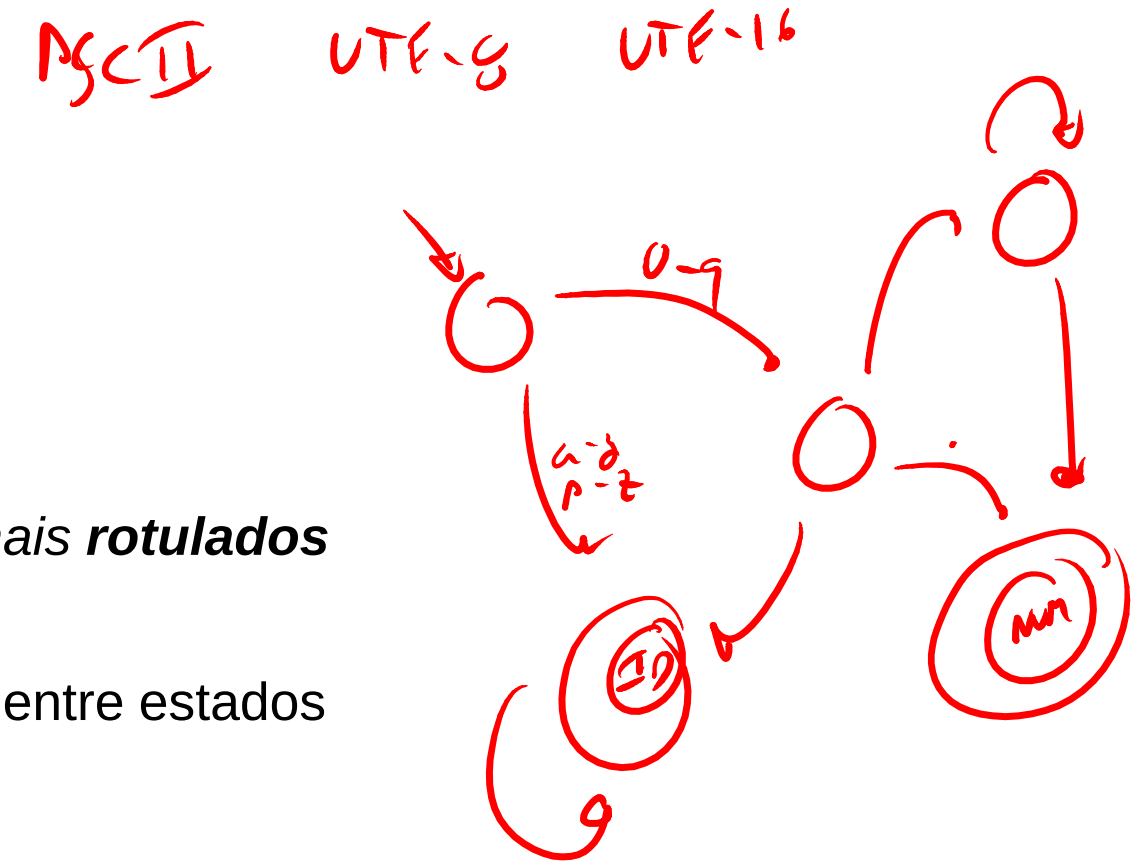

Transições

- Uma transição s_1 -^{a}-> s_2 quer dizer que se autômato está no estado s_1 e o próximo símbolo da entrada é *a* então ele vai para o estado s_2

- Se não há mais caracteres na entrada e estamos em um estado final então o autômato *aceitou* a entrada

- Se em algum ponto não foi possível tomar nenhuma transição, ou a entrada acabou e não estamos em um estado final, o autômato *rejeitou* a entrada

Graficamente

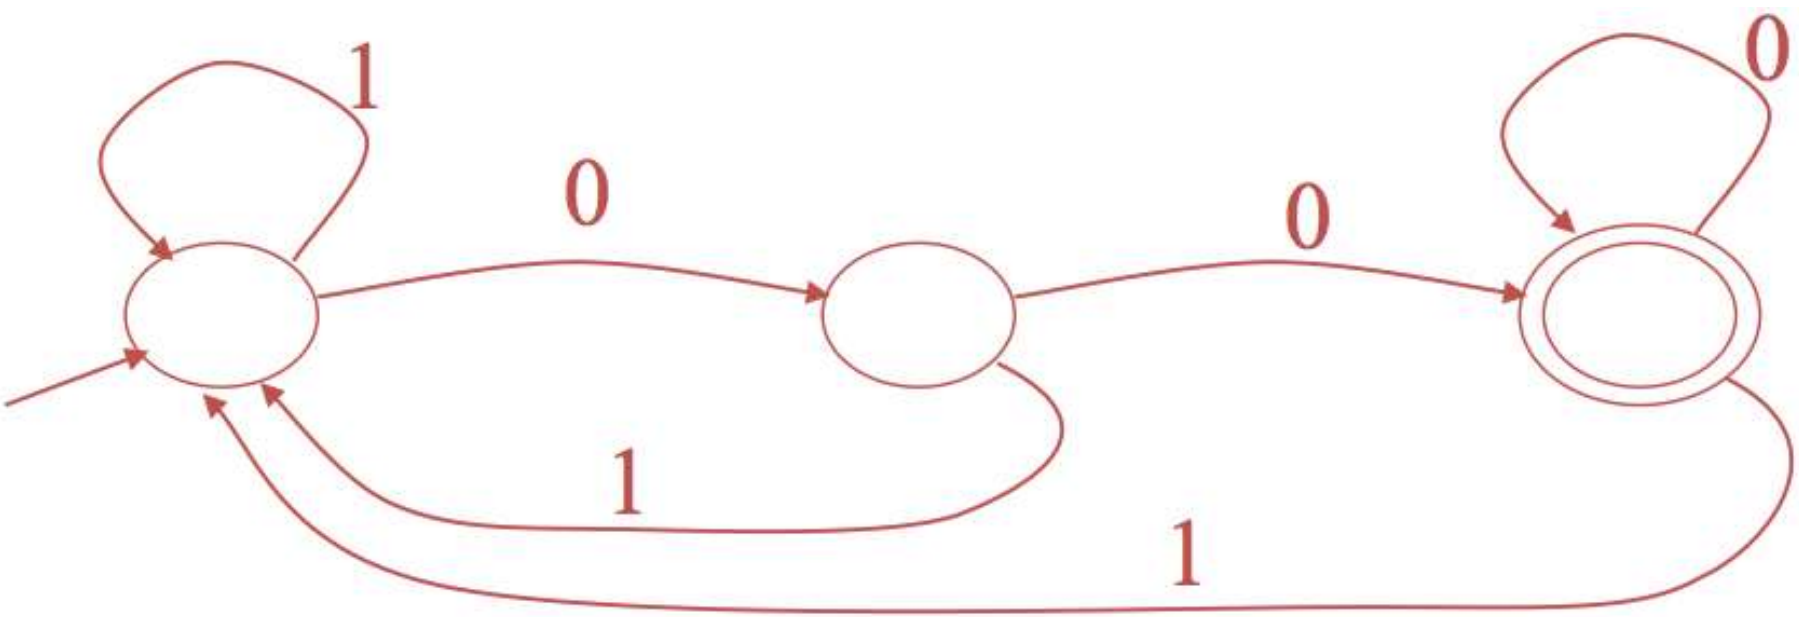

Graficamente

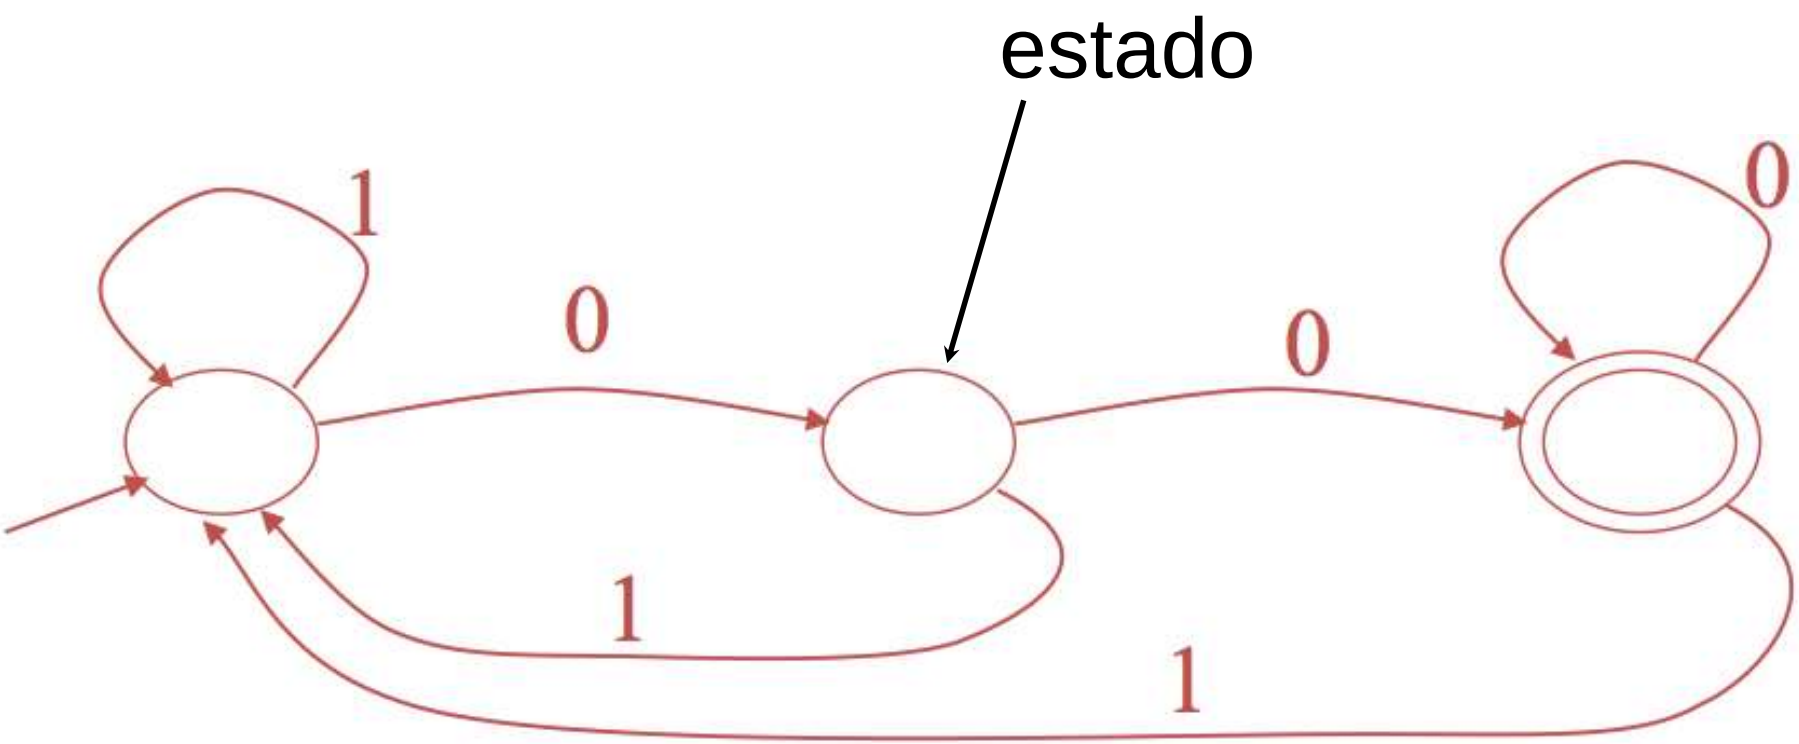

Graficamente

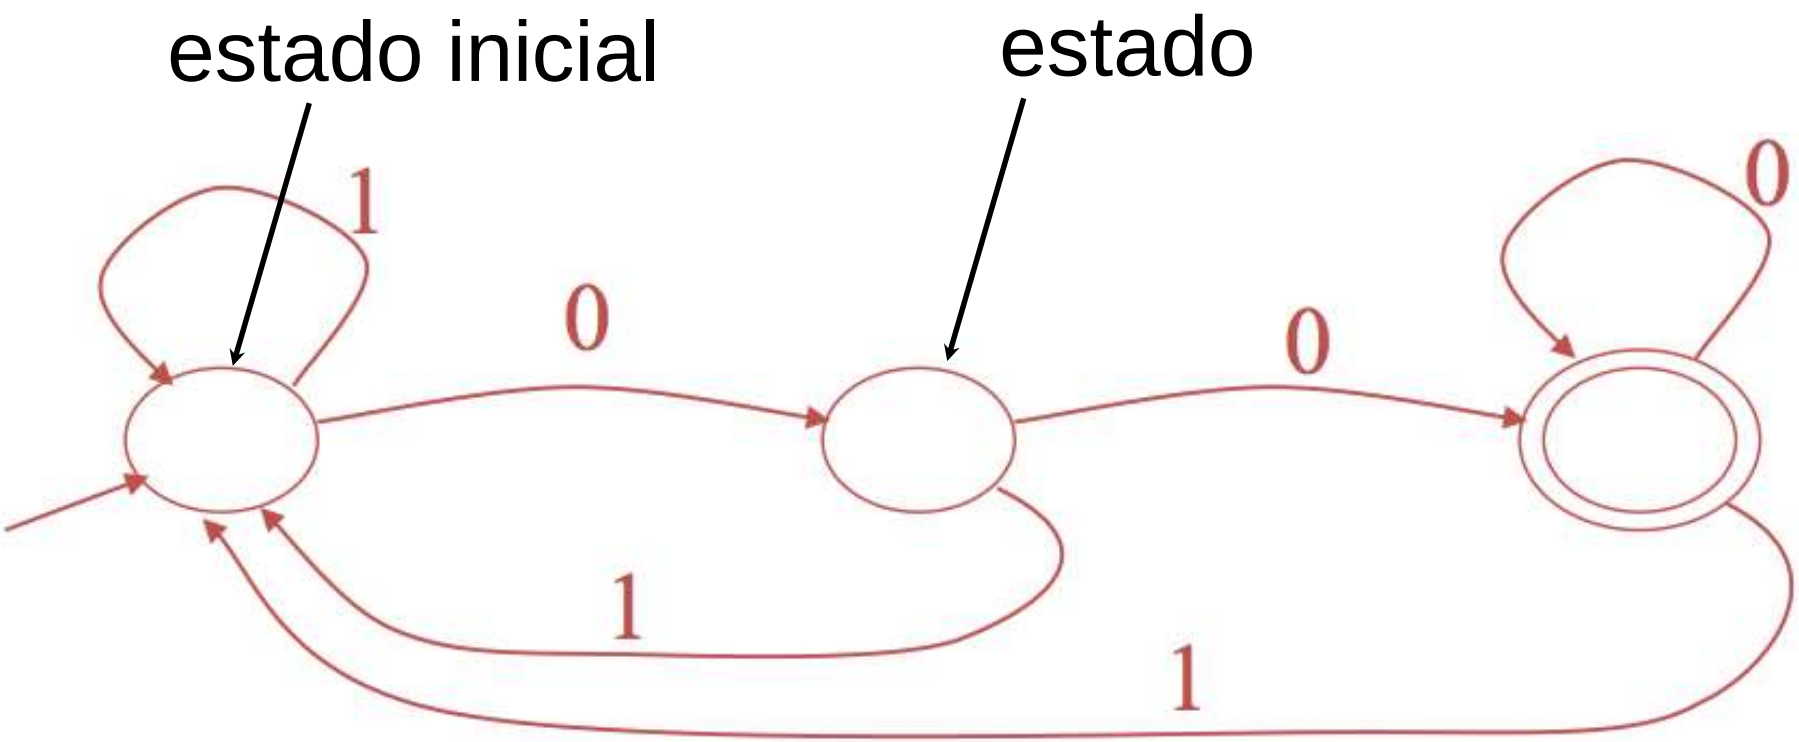

Graficamente

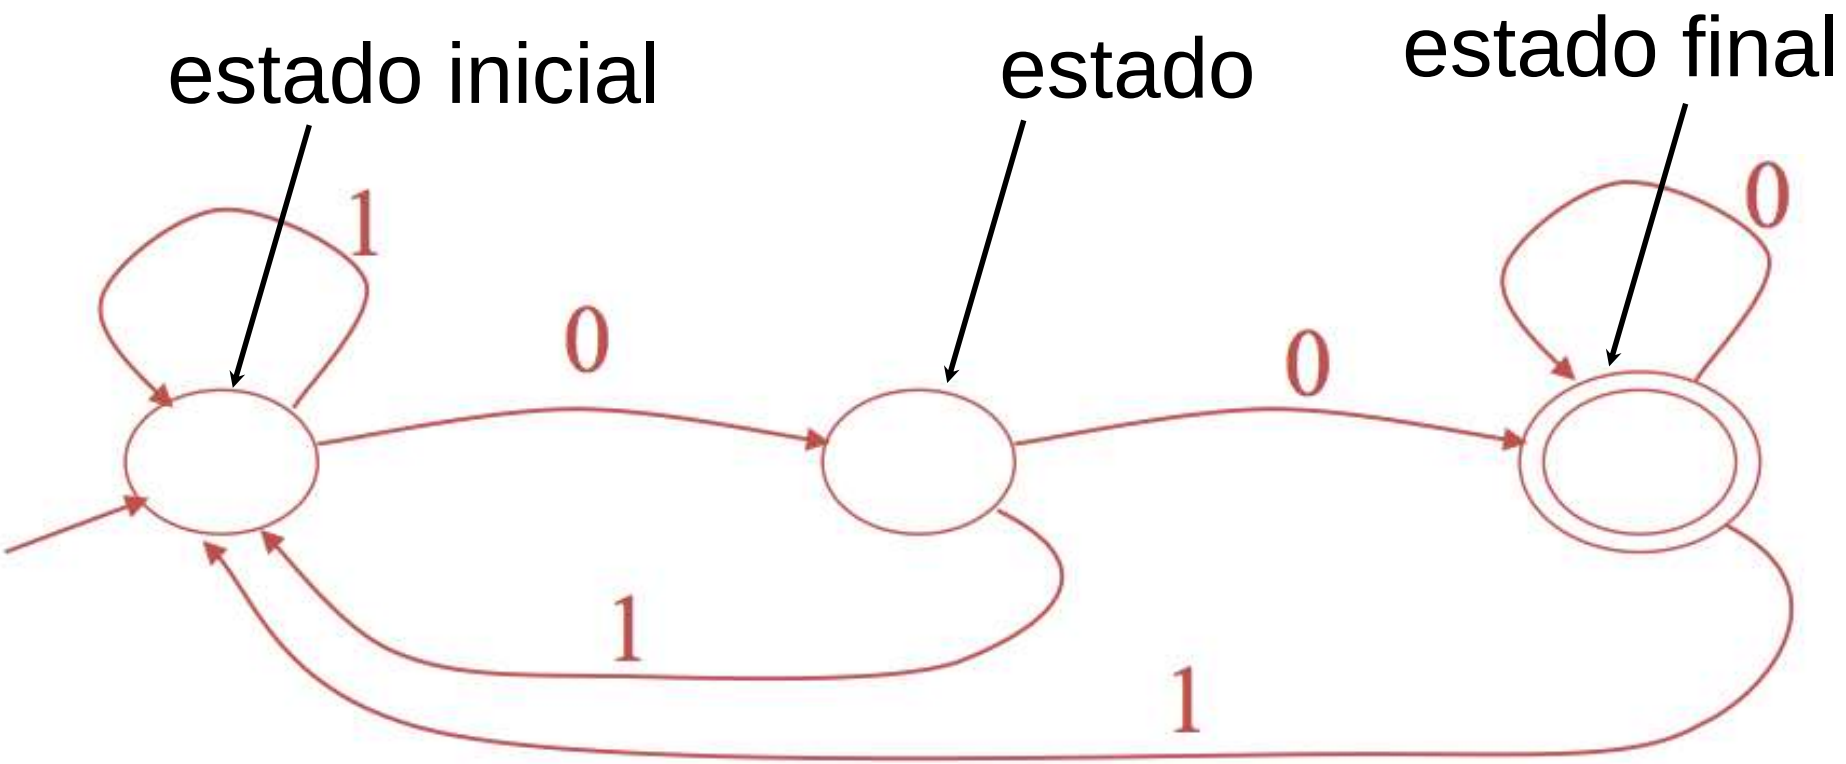

Graficamente

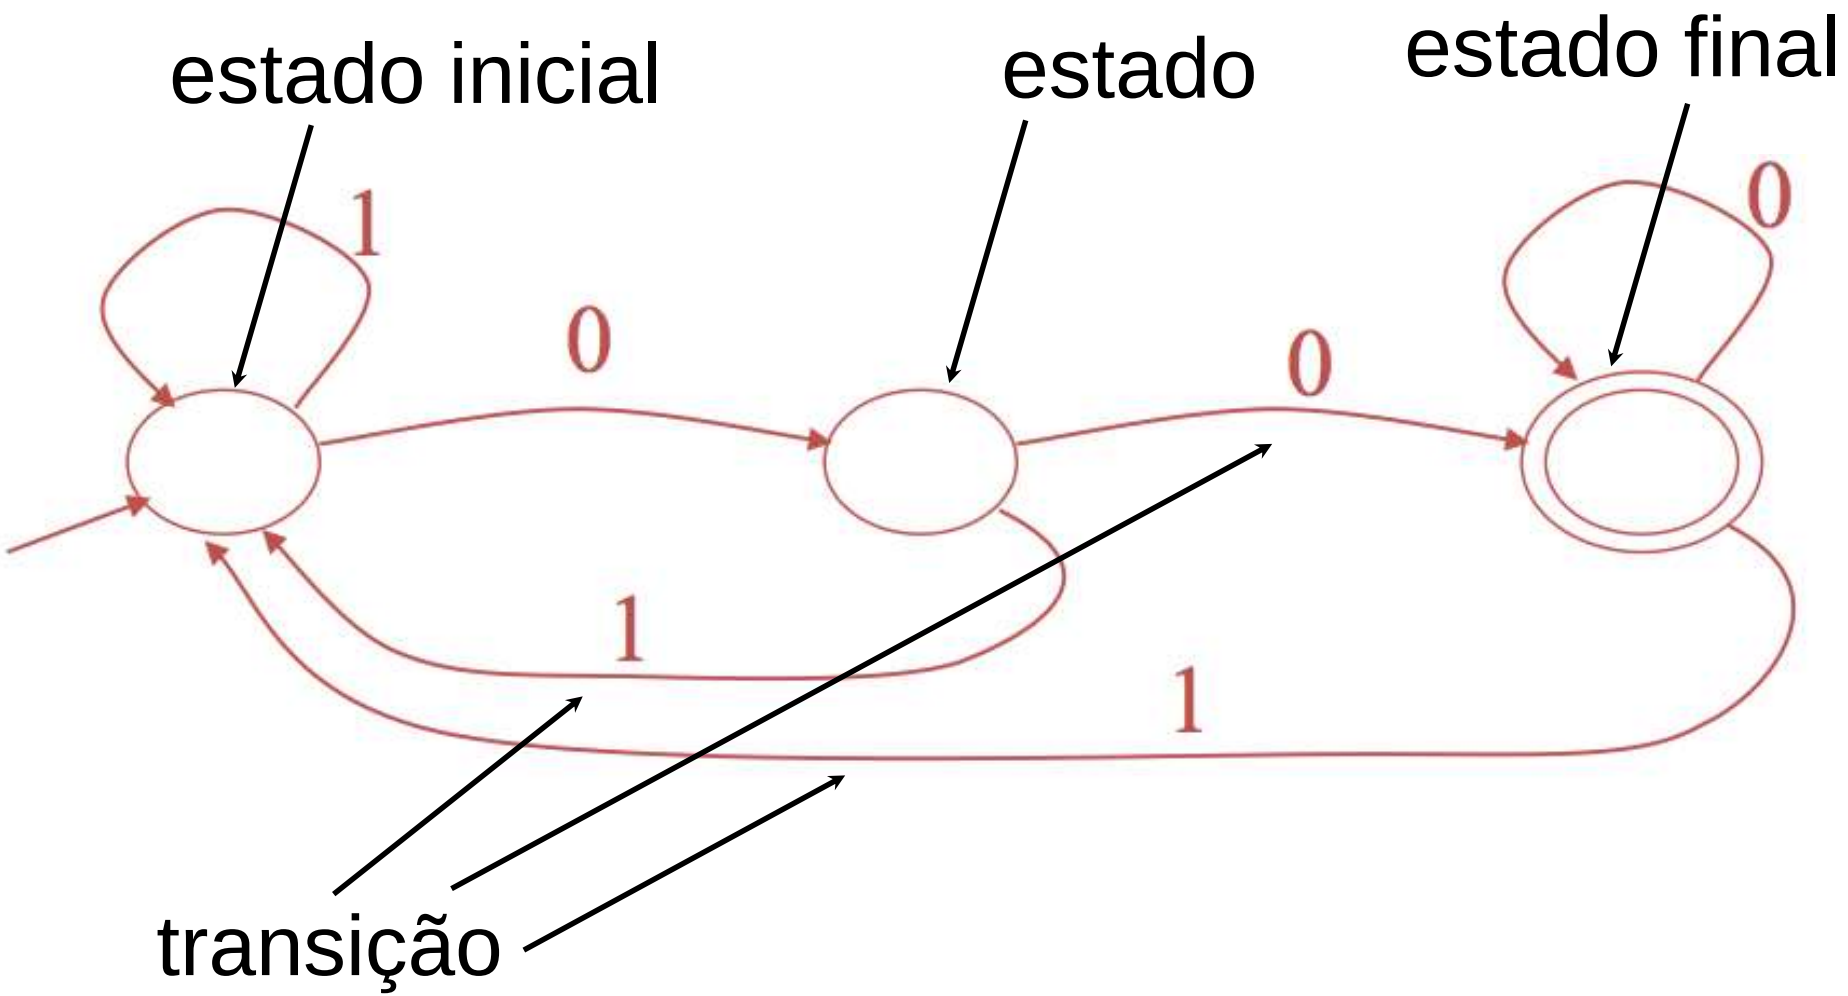

Graficamente

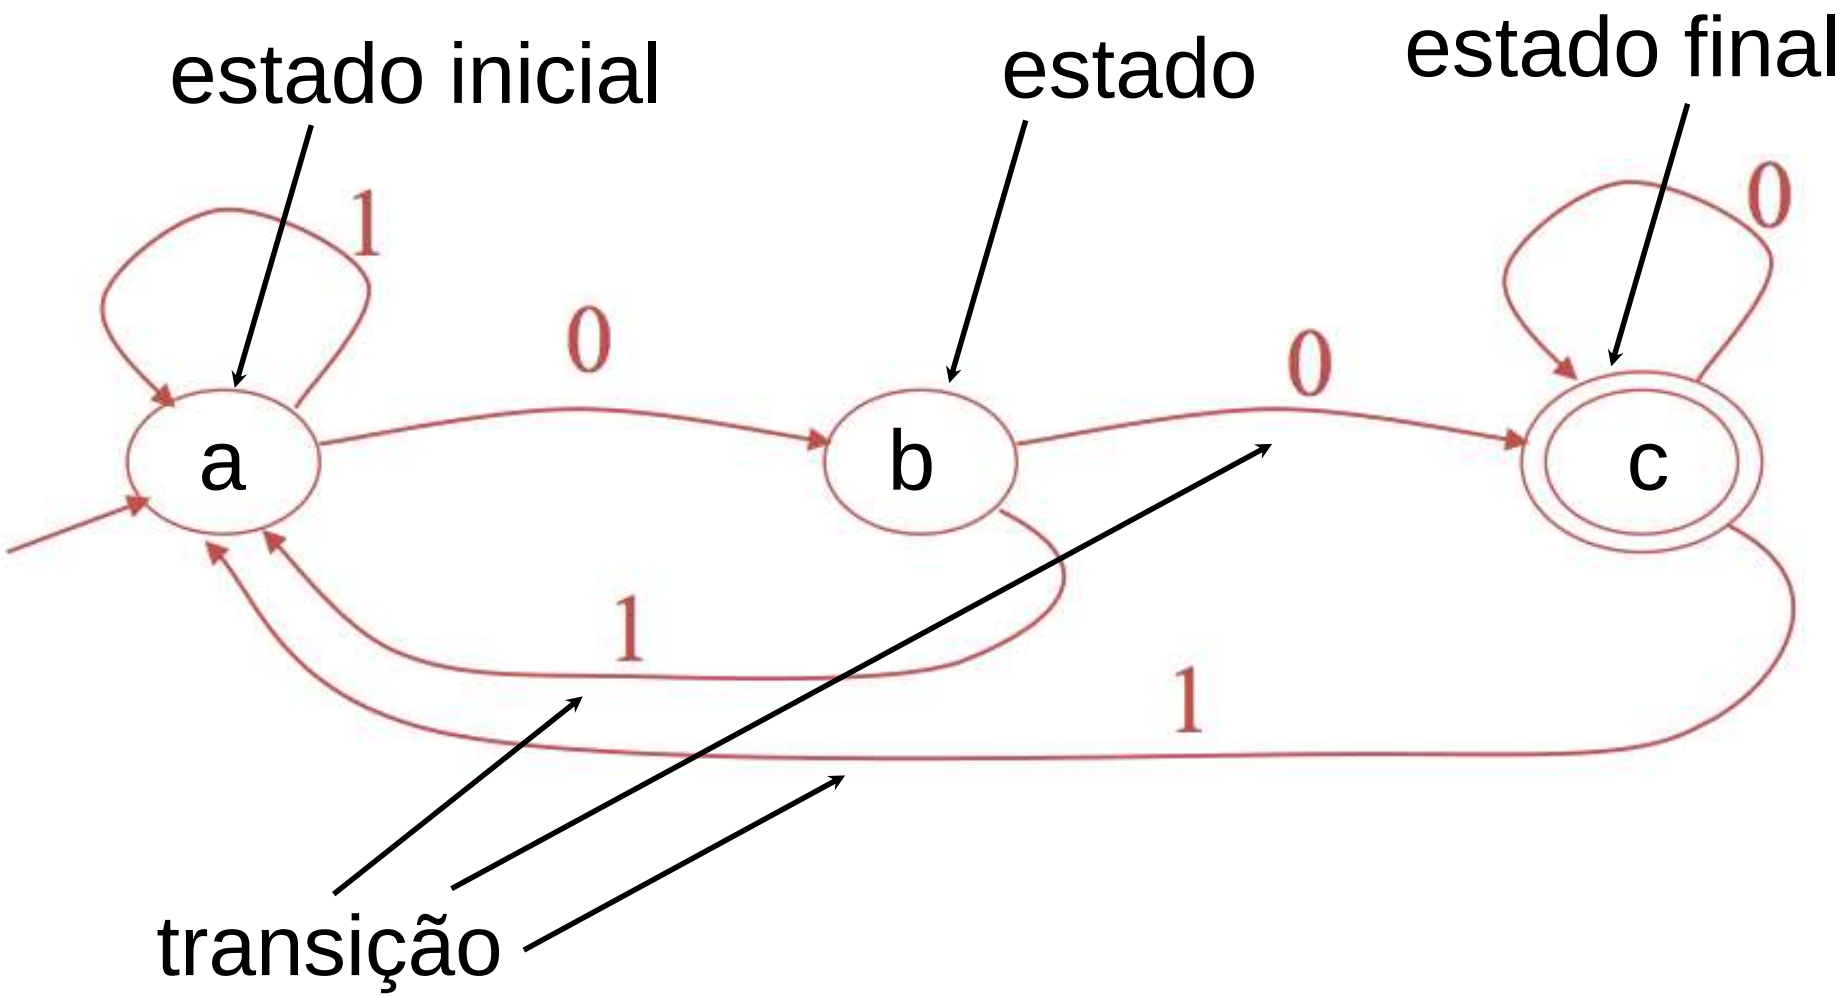

Graficamente

(0|1)*00

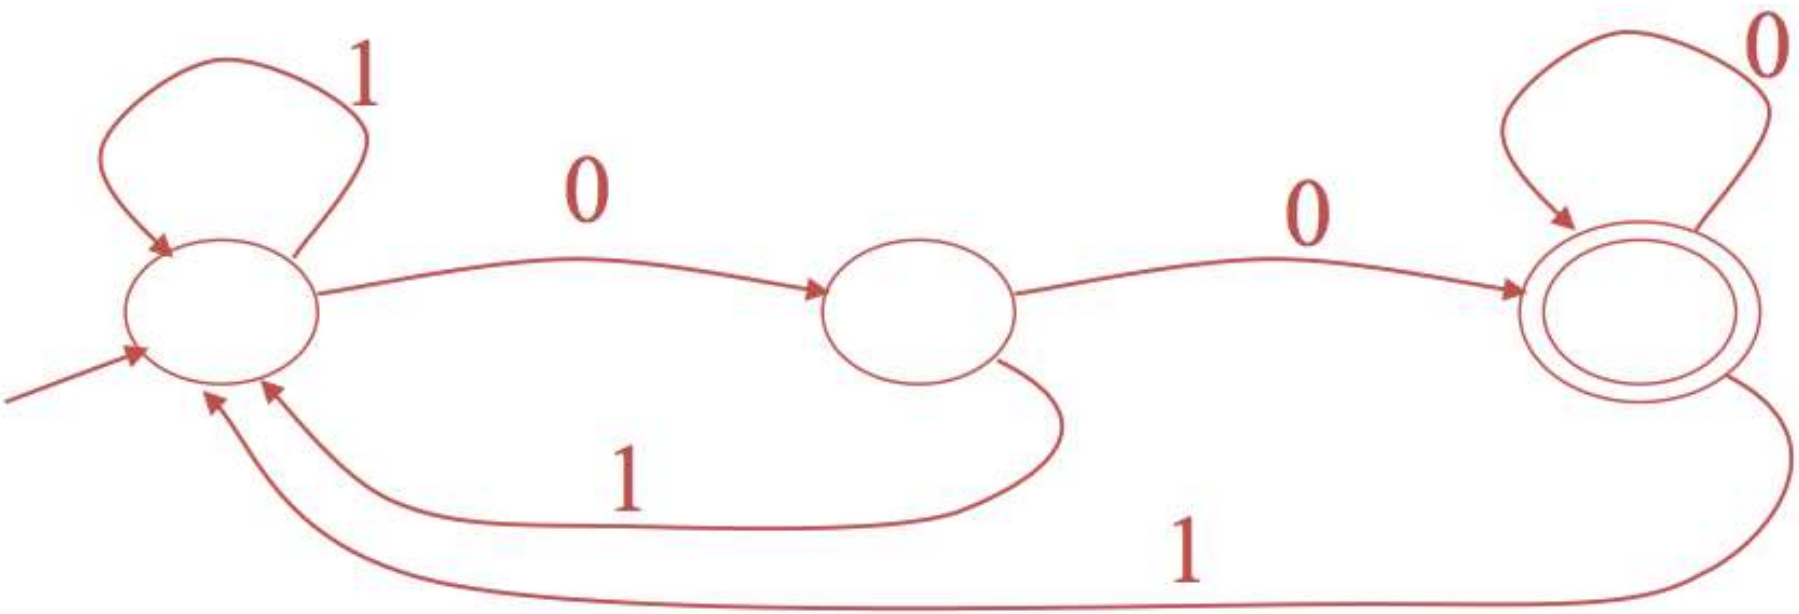

Transições ∈

- Uma transição ∈ é uma transição que pode ser tomada espontaneamente pelo autômato, sem ler nenhum símbolo da entrada

- Podemos também construir um autômato que pode tomar mais de uma transição dado um estado e um símbolo

- Autômatos com transições ∈ e múltiplas transições saindo de um mesmo estado para um mesmo caractere são *não-determinísticos*

DFA vs NFA

- Um DFA é um autômato determinístico, um NFA é não-determinístico
- Um DFA, dada uma entrada, toma apenas um caminho através dos seus estados
- Um NFA toma **todos** os caminhos possíveis para aquela entrada, e aceita entrada se **pelo menos um** caminho termina em um estado final

Funcionamento de um NFA

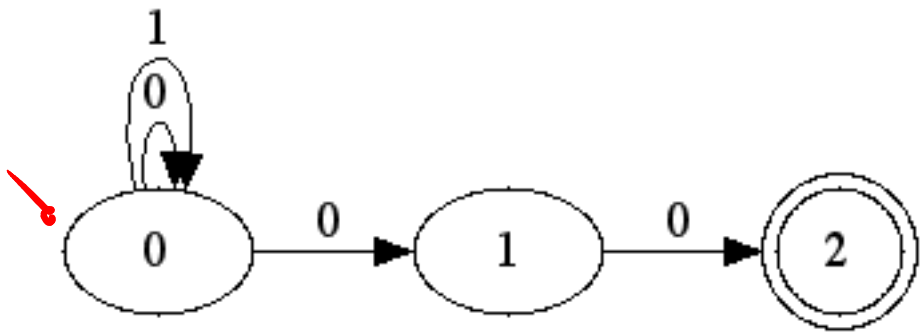

Inicial: {0}

- Entrada:
- Estados:

Funcionamento de um NFA

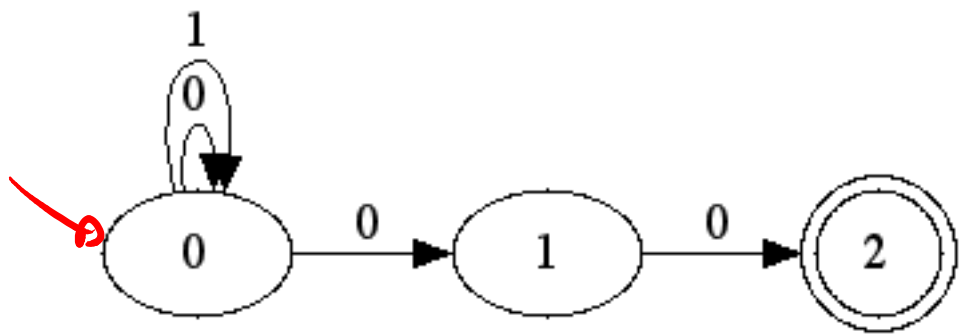

- Entrada: 1
- Estados: { 0 }

Funcionamento de um NFA

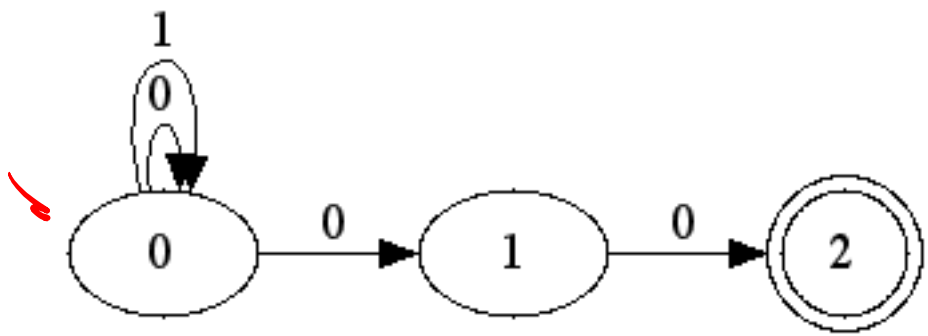

- Entrada: 1 0
- Estados: { 0 } { 0, 1 }

Funcionamento de um NFA

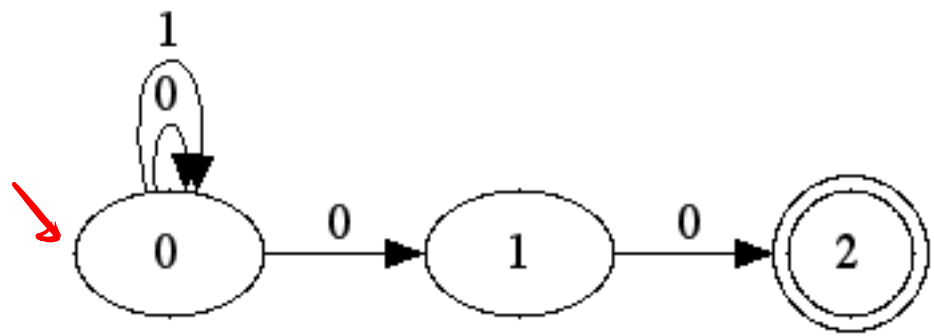

- Entrada: 1 0 0
- Estados: { 0 } { 0, 1 } { 0, 1, 2 }

Funcionamento de um NFA

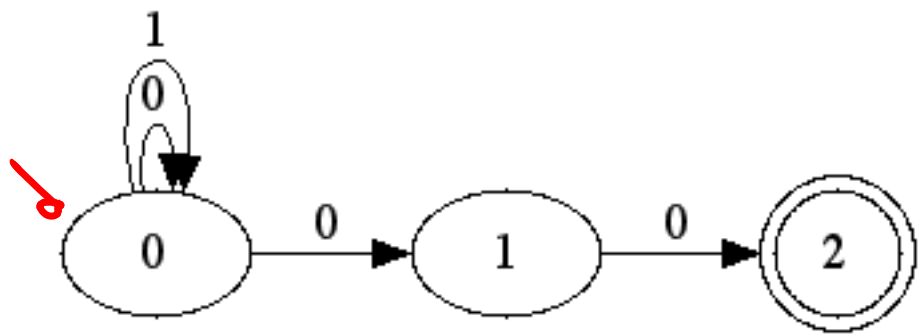

- Entrada: 1 0 0
- Estados: { 0 } { 0, 1 } { 0, 1, 2 }
- Aceita!

Funcionamento de um NFA

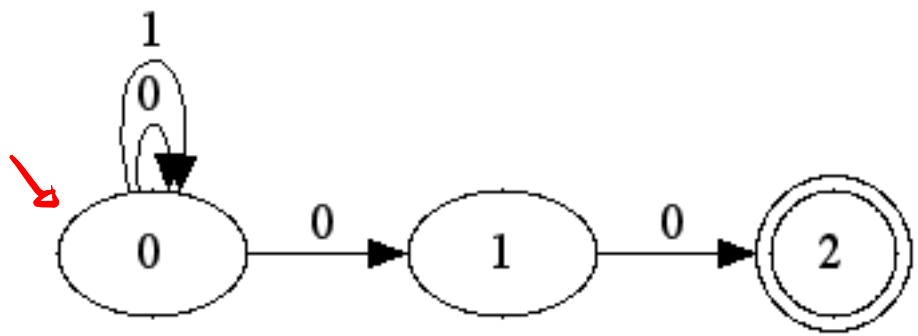

- Entrada: 0
- Estados: { 0, 1 }

Funcionamento de um NFA

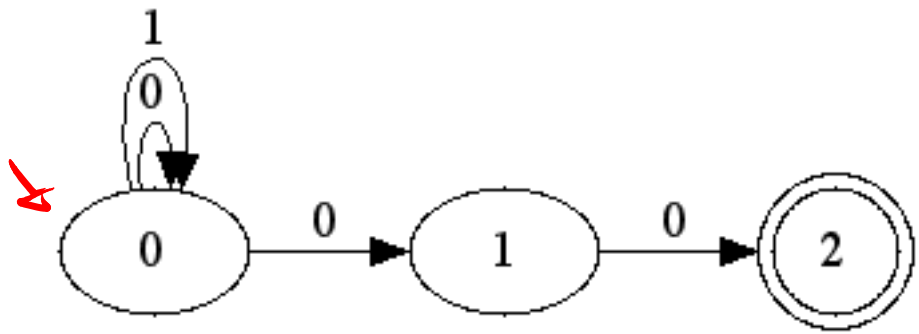

- Entrada: 0 1 1 1 0 0 0
- Estados: { 0, 1 } { 0 } {0} {0} {0,1} {0,1,2} {0,1,2}
- Não aceita!

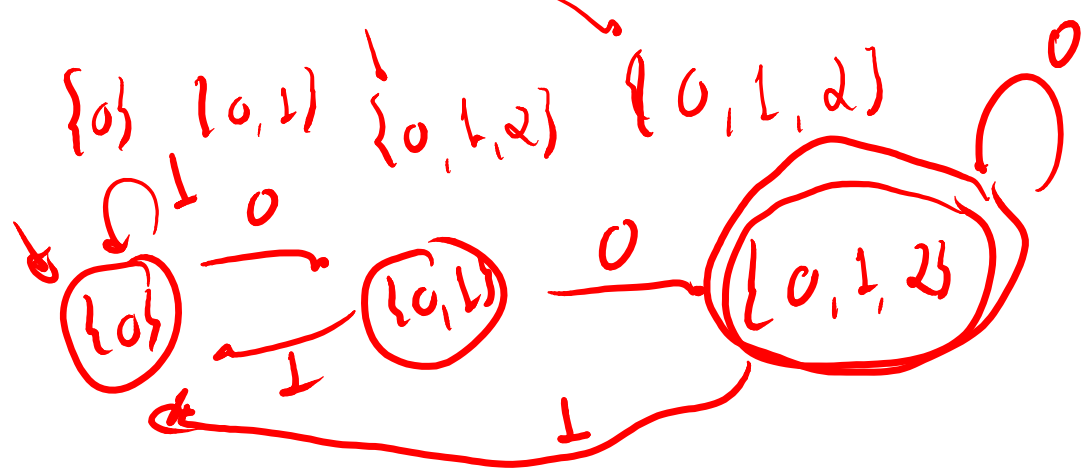

Autômatos e linguagens

- DFAs, NFAs e expressões regulares todos expressam a mesma classe de conjunto de símbolos
    - Linguagens regulares
- Isso quer dizer que podemos converter de um para outro
- DFAs são mais rápidos para executar
- NFAs têm representação mais compacta
- Expressões regulares são mais fáceis de entender qual conjunto está sendo expresso

Autômatos e linguagens

- DFAs, NFAs e expressões regulares todos expressam a mesma classe de conjunto de símbolos
  - Linguagens regulares
- Isso quer dizer que podemos converter de um para outro
- DFAs são mais rápidos para executar
- NFAs têm representação mais compacta

Por isso usamos expressões regulares para a especificação, e DFAs (ou NFAs) para implementação!

- Expressões regulares são mais fáceis de entender qual conjunto está sendo expresso

DFA de análise léxica

- Um DFA de análise léxica tem os estados finais rotulados com tipos de token
- A ideia é executar o autômato até chegar no final da entrada, ou dar erro por não conseguir fazer uma transição, mantendo uma pilha de estados visitados e o token que está sendo lido
- Então voltamos atrás, botando símbolos de volta na entrada, até chegar em um estado final, que vai dar o tipo do token

Analisador léxico de tabela

```
// reconhecer palavras
estado = s0
lexema = ""
pilha.limpa()

while (!eof && estado ≠ erro) do
   char = leChar()
   lexema = lexema + char
   push (estado)
   estado = trans(estado,char)

end;
```

```
// limpar estado final
while (estado ∉ SF and !pilha.vazia()) do
   estado ← pilha.pop()
   lexema = lexema.truncaUltimo()
   voltaChar()
end;

if (estado ∈ SF )
   // rótulo do estado é tipo do token
   then return <estado.rotulo, lexema>
   else  return erro
```

Uma otimização

- Se visitamos um estado final então podemos limpar a pilha, já que vamos parar nele na volta

```
// reconhecer palavras
estado = s0
lexema = ""
pilha.limpa()
while (!eof && estado ≠ erro) do
   char = leChar()
   lexema = lexema + char
   if estado ∈ SF
     then pilha.limpa()
   push (estado)
   estado = trans(estado,char)
end;
```

```
// limpar estado final
while (estado ∉ SF and !pilha.vazia()) do
   estado ← pilha.pop()
   lexema = lexema.truncaUltimo()
   voltaChar()
end;

if (estado ∈ SF )
   // rótulo do estado é tipo do token
   then return <estado.rotulo, lexema>
   else  return erro
```

Construindo o DFA de análise léxica

- Passo 1: construir um NFA para cada regra, o estado final desse NFA é rotulado com o tipo do token
  - Construção de Thompson → conversão de ER p/ NFA
- Passo 2: combinar os NFAs em um NFA com um estado inicial que leva aos estados iniciais do NFA de cada regra via uma transição $\in$
- Passo 3: transformar esse NFA em um DFA, estados finais ficam com o rótulo da regra que aparece primeiro
  - Algoritmo de construção de subconjuntos

DFA da linguagem de comandos simples

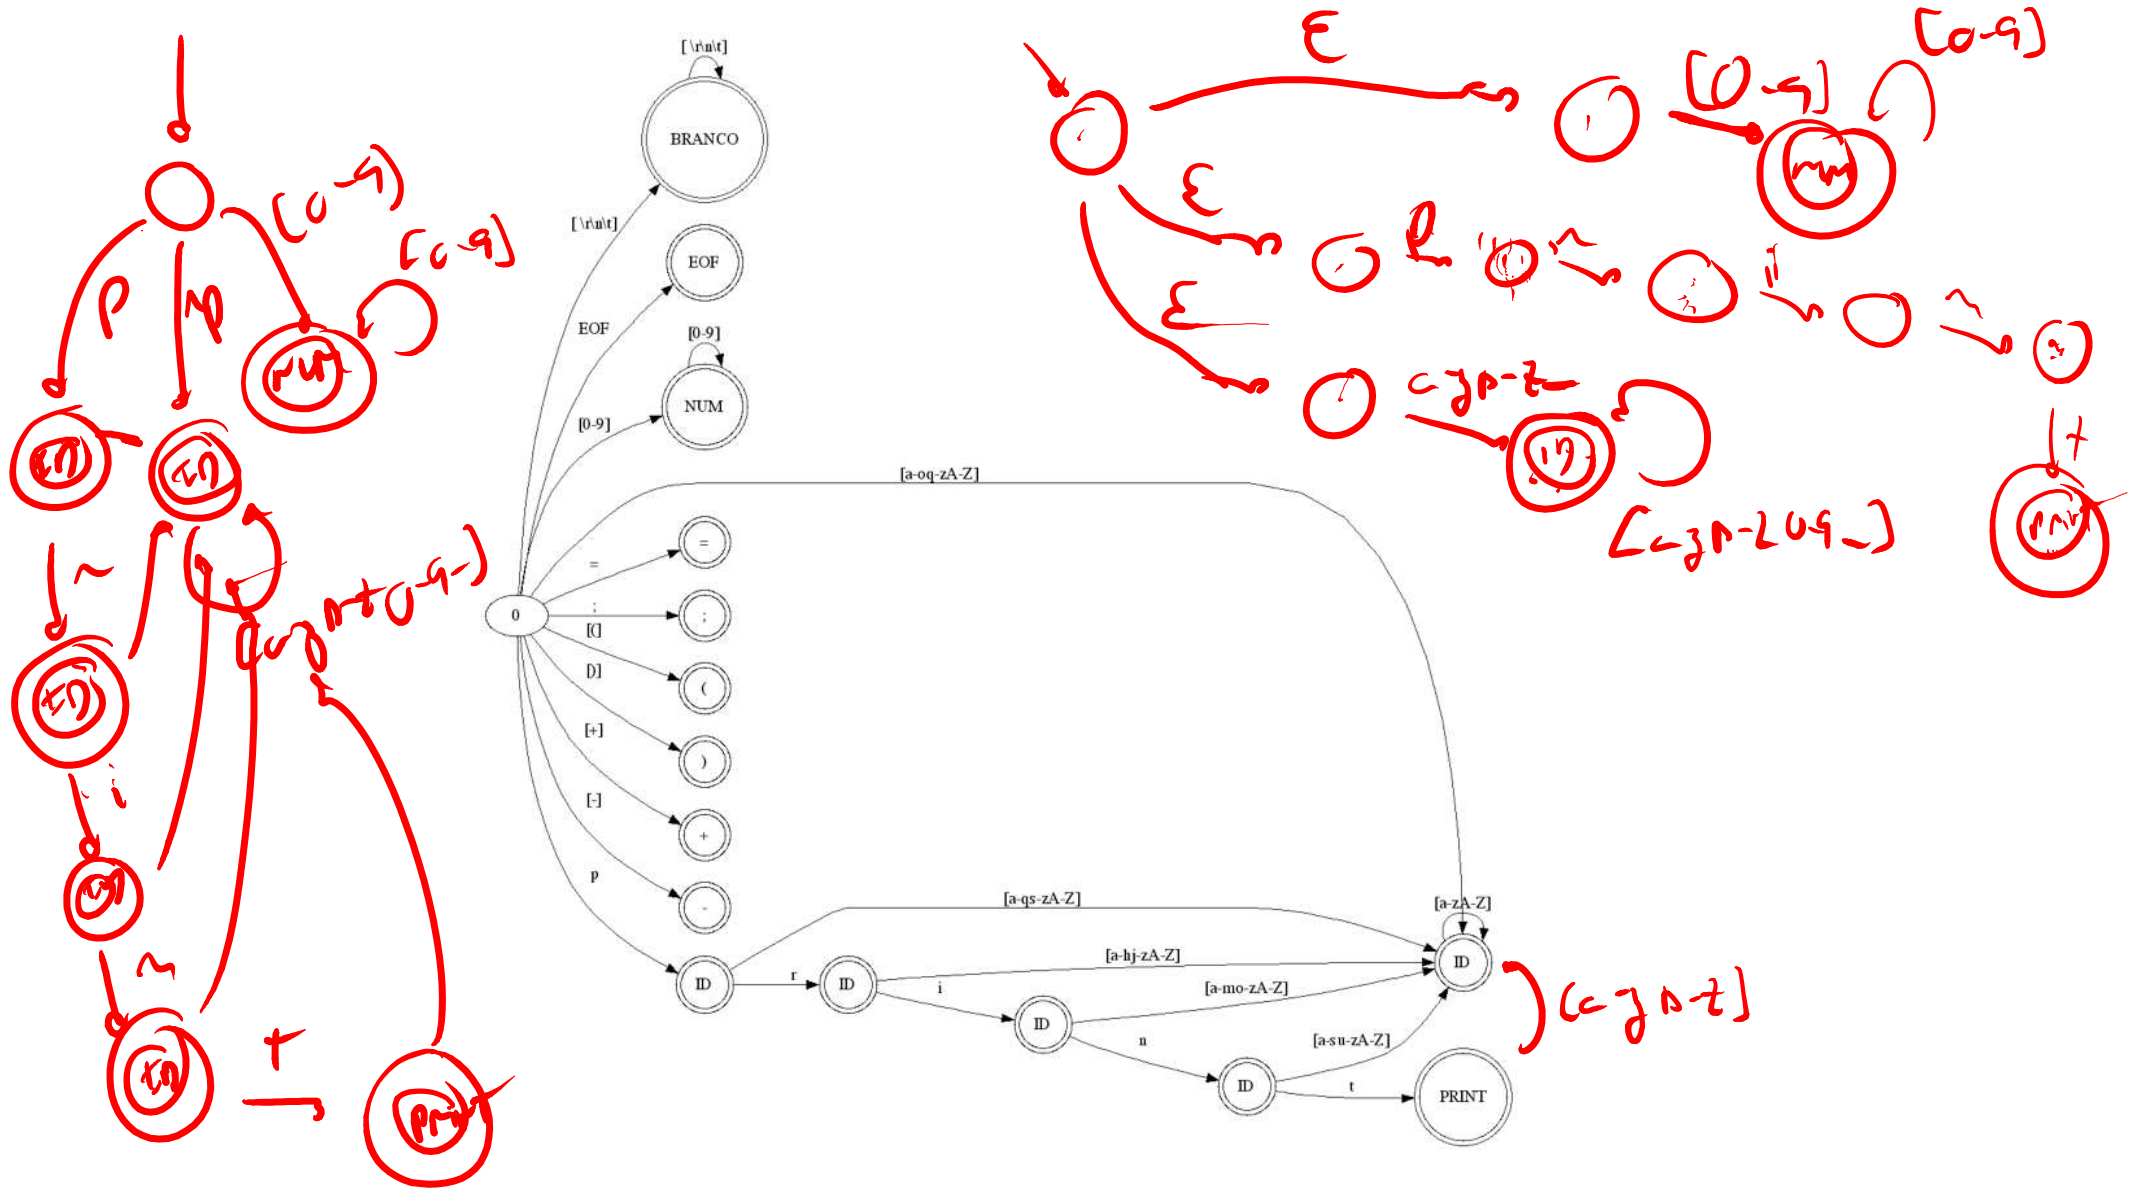

[+] vs [++]

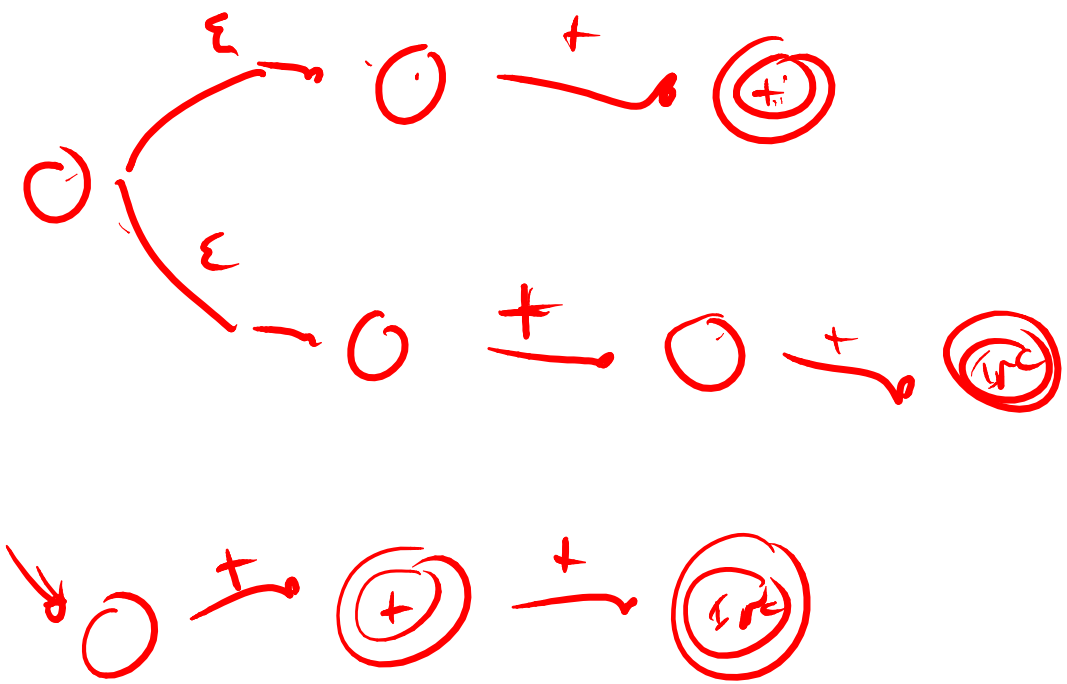

Juntando ID e palavras reservadas