Introdução e Análise Léxica

Sandro Rigo
sandro@ic.unicamp.br

Introdução

- O compilador traduz o programa de uma linguagem (fonte) para outra (máquina)
- Esse processo demanda sua quebra em várias partes, o entendimento de sua estrutura e significado
- O front-end do compilador é responsável por esse tipo de análise

Fases da Compilação

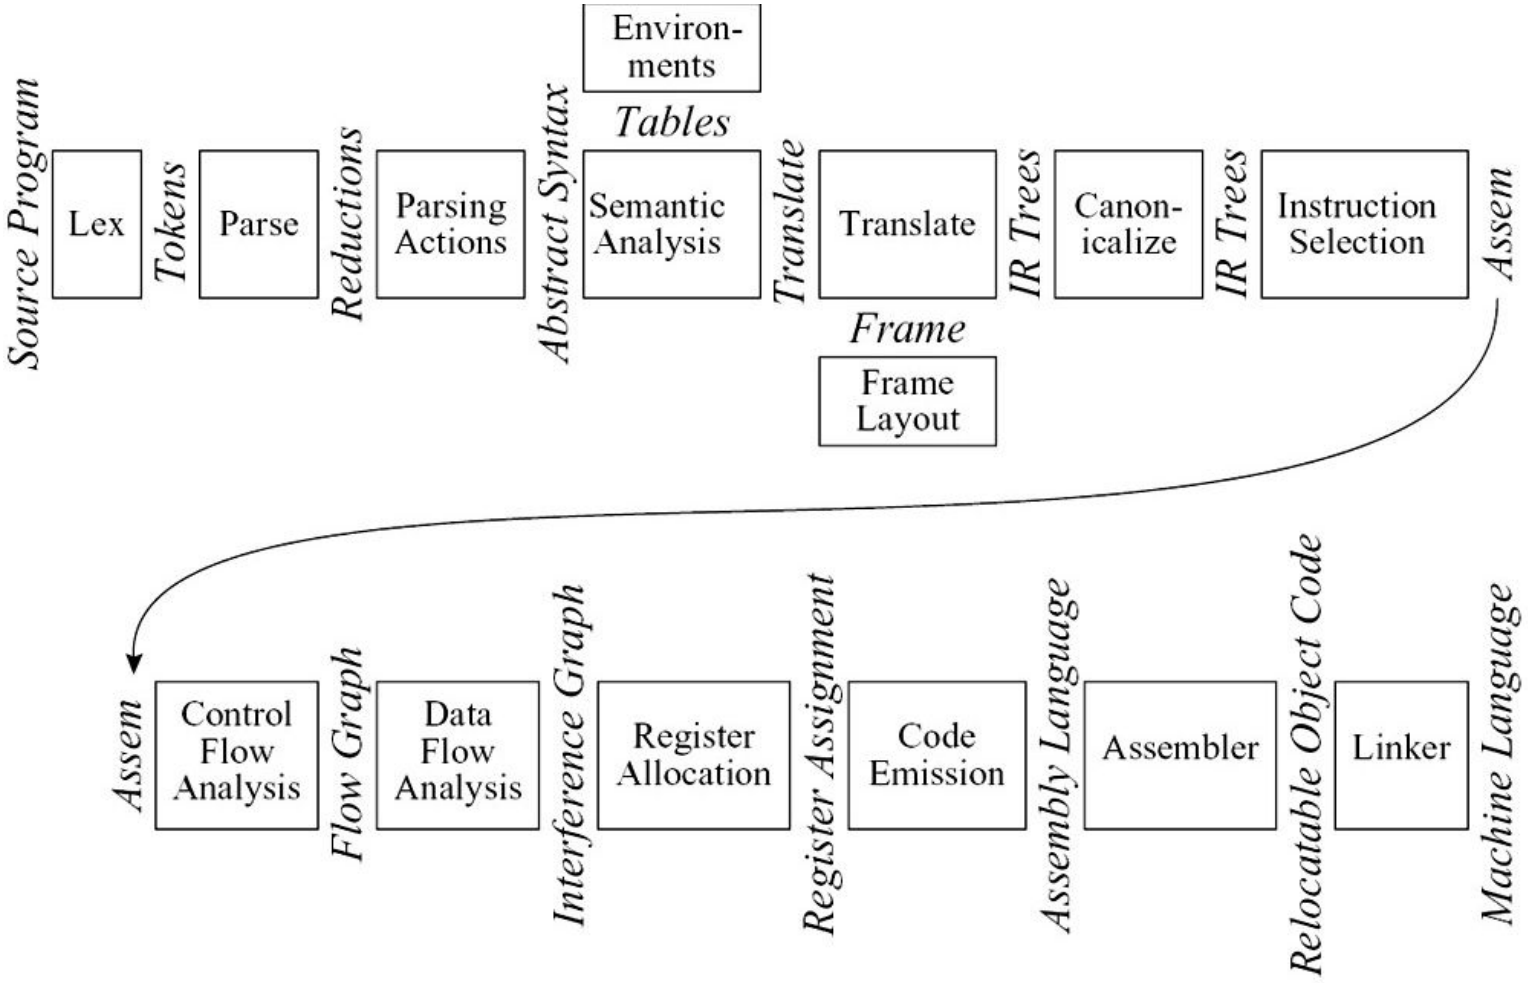

Introdução

- Análise Léxica:
  - Quebra a entrada em palavras conhecidas como *tokens*
- Análise Sintática:
  - Analisa a estrutura de frases do programa
- Análise Semântica:
  - Verificação de tipos, declarações, regras de visibilidade

Analisador Léxico

- Recebe uma seqüência de caracteres e produz uma seqüência de palavras chaves, pontuação e nomes
- Descarta comentários e espaços em branco

Cadeias e Linguagens

- Alfabeto
  - Conjunto finito não vazio de símbolos
  - Exemplos:
    - $\Sigma_1 = \{0,1\}$
    - $\Sigma_2 = \{a,b,c,...,z\}$
- Cadeia
  - Sequencia finita de símbolos de um alfabeto
    - 010010 é cadeia sobre Σ_1 de tamanho 6
  - O símbolo ε denota cadeia vazia de comprimento 0

Cadeias e Linguagens

- Dada uma cadeia w sobre Σ:
  - $w^0 = \varepsilon$
  - $W^k = w^{k-1}$ w para k > 0 (concatenação k vezes)
- Dada um alfabeto Σ:
  - Σ* é o conjunto de todas as cadeias finitas sobre Σ
  - Σ+ é o cojunto de todas as cadeias finitas sobre Σ menos a cadeia vazia
- Linguagem
  - Conjunto de cadeias

Cadeias e Linguagens

- Linguagem sobre Σ
  - Conjunto de cadeias em Σ
  - Subconjunto de Σ*
- Dadas L1 e L2 linguagens sobre Σ:
  - L1 U L2 = { x| x ϵ L1 ou x ϵ L2}
  - L1 . L2 = {xy| x ϵ L1 e y ϵ L2}
  - L1* = {x1 x2...xk| K>= 0 e cada xi ϵ L1}

Cadeias e Linguagens

- Linguagem livre de contexto:
  - Linguagens descritas por uma gramática livre de contexto
  - Úteis para especificar linguagens de programação
  - Vamos estudar com mais detalhes no próximo capítulo
- Linguagens regulares
  - Caso particular de linguagens livre de contexto
  - Linguagens que podem ser descritas através de expressões regulares ou reconhecida por autômatos finitos.

Tokens

Tipo	Exemplos
ID	foo n14 last
NUM	73 0 00 515 082
REAL	66.1 .5 10. 1e67 5.5e-10
IF	if
COMMA	,
NOTEQ	!=
LPAREN	(

Não-Tokens

comment	/* try again */
preprocessor directive	#include<stdio.h>
preprocessor directive	#define NUMS 5, 6
macro	NUMS
blanks, tabs, and newlines	

Obs.: O pré-processador passa pelo programa antes do léxico

Exemplo

```
float match0(char *s) /* find a zero */
  {if (!strncmp(s, "0.0", 3))
    return 0.;
  }
```

Retorno do analisador léxico:

FLOAT ID(match0) LPAREN CHAR STAR ID(s) RPAREN
LBRACE IF LPAREN BANG ID(strncmp) LPAREN ID(s)
COMMA STRING(0.0) COMMA NUM(3) RPAREN RPAREN
RETURN REAL(0.0) SEMI RBRACE EOF

Analisador Léxico

- Alguns tokens têm um valor semântico associados a eles:
  - IDs e NUMs
- Como são descritas as regras léxicográficas?
  - An identifier is a sequence of letters and digits; the first character must be a letter. The underscore _ counts as a letter. Upper- and lowercase letters are different. If the input stream has been parsed into tokens up to a given character, the next token is taken to include the longest string of characters that could possibly constitute a token. Blanks, tabs, newlines, and comments are ignored except as they serve to separate tokens. Some white space is required to separate otherwise adjacent identifiers, keywords, and constants.
- Como os tokens são especificados?

Expressões Regulares

- Um linguagem é um conjunto de strings;
- Uma string é uma seqüência de símbolos
- Estes símbolos estão definidos em um alfabeto finito
- Ex: Linguagem C ou Pascal, linguagem dos primos, etc
- Queremos poder dizer se uma string está ou não em uma linguagem

Expressões Regulares

- **Símbolo:** Para cada símbolo **a** no alfabeto da linguagem, a expressão regular **a** representa a linguagem contendo somente a string *a*.
- **Alternação:** Dadas duas expressões regulares *M* e *N*, o operador de alternação (|) gera uma nova expressão *M* | *N*. Uma string está na linguagem de *M* | *N* se ela está na linguagem de *M* ou na linguagem de *N*. Ex., a linguagem de **a** | **b** contém as duas strings *a* e *b*.
- **Concatenação:** Dadas duas expressões regurales *M* e *N*, o operador de concatenação (·) gera uma nova expressão *M* · *N*. Uma string está na linguagem de *M* · *N* se ela é a concatenação de quaisquer duas strings α e β, tal que α está na linguagem de *M* e β está na linguagem de *N*. Ex.: (**a** | **b**) · **a** contém as strings *aa* e *ba*.

Expressões Regulares

- **Epsilon:** A expressão regular $\in$ representa a linguagem cuja única string é a vazia. Ex.: $(a \cdot b) \mid \in$ representa a linguagem {"", "ab"}.
- **Repetição:** Dada uma expressão regular *M*, seu Kleene closure é *M**. Uma string está em *M** se ela é a concatenação de zero ou mais strings, todas em *M*. Ex.: ((**a** | **b**) · **a**)* representa {"", "aa", "ba", "aaaa", "baaa", "aaba", "baba", "aaaaaa", …}.

Notação

- **a** An ordinary character stands for itself.
- ∈ The empty string.
- Another way to write the empty string.
- *M* | *N* Alternation, choosing from *M* or *N*.
- *M* · *N* Concatenation, an *M* followed by an *N*.
- *MN* Another way to write concatenation.
- *M** Repetition (zero or more times).
- *M*+ Repetition, one or more times.
- *M*? Optional, zero or one occurrence of *M*.
- **[a − zA − Z]** Character set alternation.
- . A period stands for any single character except newline.
- "a.+*" Quotation, a string in quotes stands for itself literally.

Exemplos

- Como seriam as expressões regulares para os seguintes tokens?
- IF
  - `if`
- ID
  - `[a-z][a-z0-9]*`
- NUM
  - `[0-9]+`

Exemplos

- Quais tokens representam as seguintes expressões regulares?
- ([0-9]+"."[0-9]*)|([0-9]*"."[0-9]+)

- ("--"[a-z]*"\n")|(" "|"\n"|"\t")+

- .

Exemplos

- Quais tokens representam as seguintes expressões regulares?
- ([0-9]+"."[0-9]*)|([0-9]*"."[0-9]+)
  - `REAL`
- ("--"[a-z]*"\n")|(" "|"\n"|"\t")+
  - *nenhum token, somente comentário, brancos, nova linha e tab*
- .
  - *error*

Exercício: Qual linguagem é aceita por cada expressão regular?

- $(\mathbf{0} \mid \mathbf{1})^* \cdot \mathbf{0}$
- $\mathbf{b}^*(\mathbf{abb}^*)^*(\mathbf{a}|\in)$
- $(\mathbf{a}|\mathbf{b})^*\mathbf{aa}(\mathbf{a}|\mathbf{b})^*$

Exercício: Qual linguagem é aceita por cada expressão regular?

- **(0 | 1)* · 0**
  - Números binários múltiplos de 2.
- **b*(abb*)*(a|∈)**
  - Strings de a's e b's sem a's consecutivos.
- **(a|b)*aa(a|b)***
  - Strings de a's e b's com a's consecutivos.

Analisador Léxico

- Ambiguidades:
  - `if8` é um ID ou dois tokens IF e NUM(8) ?
  - `if 89` começa com um ID ou uma palavra-reservada?
- Duas regras:
  - Maior casamento: o próximo token sempre é a substring mais longa possível de ser casada.
  - Prioridade: Para uma dada substring mais longa, a primeira regra a ser casada produzirá o token

Analisador Léxico

- A especificação deve ser completa, sempre reconhecendo uma substring da entrada
  - Mas quando estiver errada? Use uma regra com o “.”
  - Em que lugar da sua especificação deve estar esta regra?
    - Esta regra deve ser a última! (Por que?)

Autômatos Finitos

- Expressões Regulares são convenientes para especificar os tokens
- Precisamos de um formalismo que possa ser convertido em um programa de computador
- Este formalismo são os autômatos finitos

Autômatos Finitos

- Um autômato finito possui:
  - Um conjunto finito de estados
  - Arestas levando de um estado a outro, anotada com um símbolo
  - Um estado inicial
  - Um ou mais estados finais
  - Normalmente os estados são numerados ou nomeados para facilitar a manipulação e discussão

Autômatos Finitos

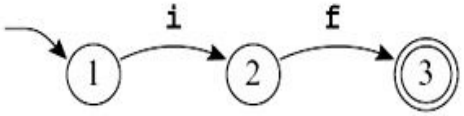

IF

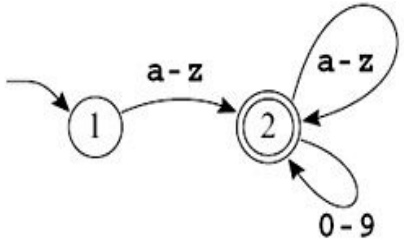

ID

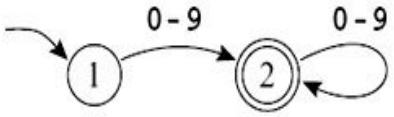

NUM

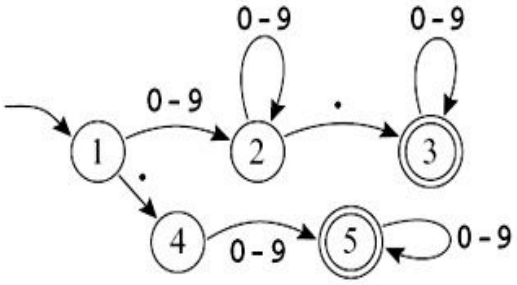

REAL

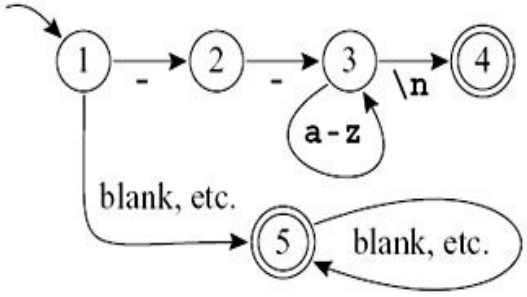

white space

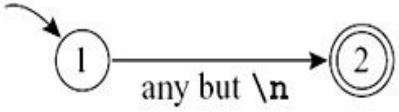

error

Deterministic Finite Automata

- DFAs não podem apresentar duas arestas que deixam o mesmo estado, anotadas com o mesmo símbolo
- Saindo do estado inicial, o autômato segue exatamente uma aresta para cada caractere da entrada
- O DFA aceita a string se, após percorrer todos os caracteres, ele estiver em um estado final

Deterministic Finite Automata

- Se em algum momento não houver uma aresta a ser percorrida para um determinado caractere ou ele terminar em um estado não-final, a string é rejeitada
- A linguagem reconhecida pelo autômato é o conjunto de todas as strings que ele aceita

Autômatos Finitos

- Consigo combinar os autômatos definidos para cada token de maneira a ter um único autômato que possa ser usado como analisador léxico?
  - Sim.
  - Veremos um exemplo *ad-hoc* e mais adiante mecanismos formais para esta tarefa

Autômato Combinado

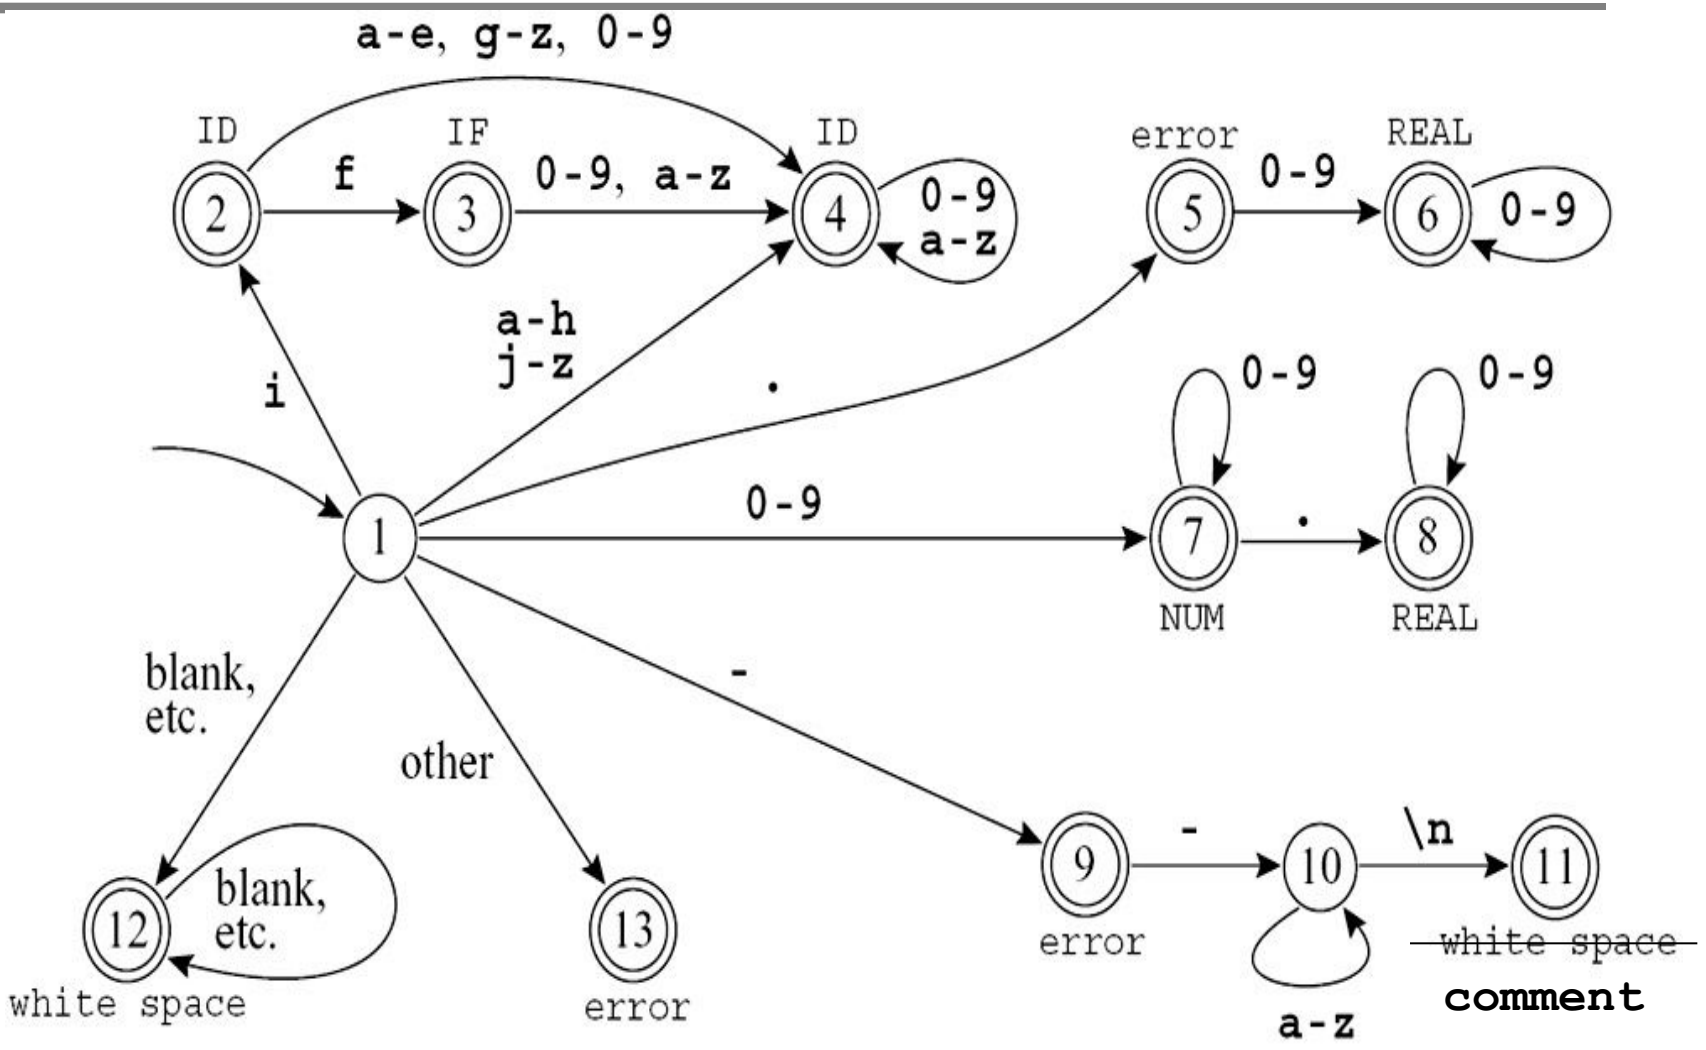

Autômato Combinado

- Estados finais nomeados com o respectivo token
- Alguns estados apresentam características de mais de um autômato anterior. Ex.: 2
- Como ocorre a quebra de ambigüidade entre ID e IF?

Autômato Combinado

```
int edges[ ][ ] = { /* ...012...-...e f g h i j... */
/* state 0 */ {0,0,...0,0,0...0...0,0,0,0,0,0...},
/* state 1 */ {0,0,...7,7,7...9...4,4,4,4,2,4...},
/* state 2 */ {0,0,...4,4,4...0...4,3,4,4,4,4...},
/* state 3 */ {0,0,...4,4,4...0...4,4,4,4,4,4...},
/* state 4 */ {0,0,...4,4,4...0...4,4,4,4,4,4...},
/* state 5 */ {0,0,...6,6,6...0...0,0,0,0,0,0...},
/* state 6 */ {0,0,...6,6,6...0...0,0,0,0,0,0...},
/* state 7 */ {0,0,...7,7,7...0...0,0,0,0,0,0...},
/* state 8 */ {0,0,...8,8,8...0...0,0,0,0,0,0...},
   et cetera }
```

entrada

Ausência de aresta

Reconhecimento da Maior Substring

- A tabela anterior é usada para aceitar ou recusar uma string
- Porém, precisamos garantir que a maior string seja reconhecida
- Necessitamos de duas informações
  - Último estado final
  - Posição da entrada no último estado final

Reconhecimento da Maior Substring

Last Final	Current State	Current Input	Accept Action
0	1	⌈if --not-a-com	
2	2	|i⌈f --not-a-com	
3	3	|if⌈ --not-a-com	
3	0	|if⌉⌊--not-a-com	*return* IF
0	1	if⌈ --not-a-com	
12	12	if|⌈--not-a-com	
12	0	if|⌉-⌊-not-a-com	*found white space; resume*
0	1	if ⌈--not-a-com	
9	9	if |-⌈-not-a-com	
9	10	if |-⌉-⌊not-a-com	
9	10	if |-⌉-n⌊ot-a-com	
9	10	if |-⌉-no⌊t-a-com	
9	10	if |-⌉-not⌊-a-com	
9	0	if |-⌉-not-⌊a-com	*error, illegal token '-'; resume*
0	1	if -⌈-not-a-com	
9	9	if -|-⌈not-a-com	
9	0	if -|-⌉n⌊ot-a-com	*error, illegal token '-'; resume*

Nondeterministic Finite Automata (NFA)

- Pode ter mais de uma aresta saindo de um determinado estado com o mesmo símbolo
- Pode ter arestas anotadas com o símbolo Є
  - Essa aresta pode ser percorrida sem consumir nenhum caractere da entrada!

Nondeterministic Finite Automata (NFA)

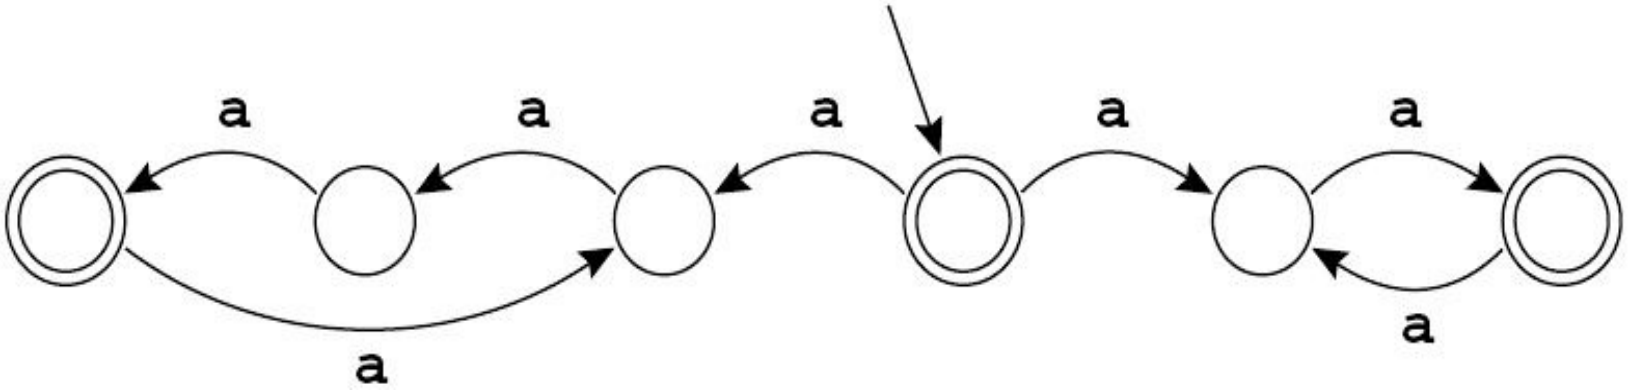

Que linguagem este autômato reconhece?

Obs: Ele é obrigado a aceitar a string se existe alguma escolha de caminho que leva à aceitação

Nondeterministic Finite Automata (NFA)

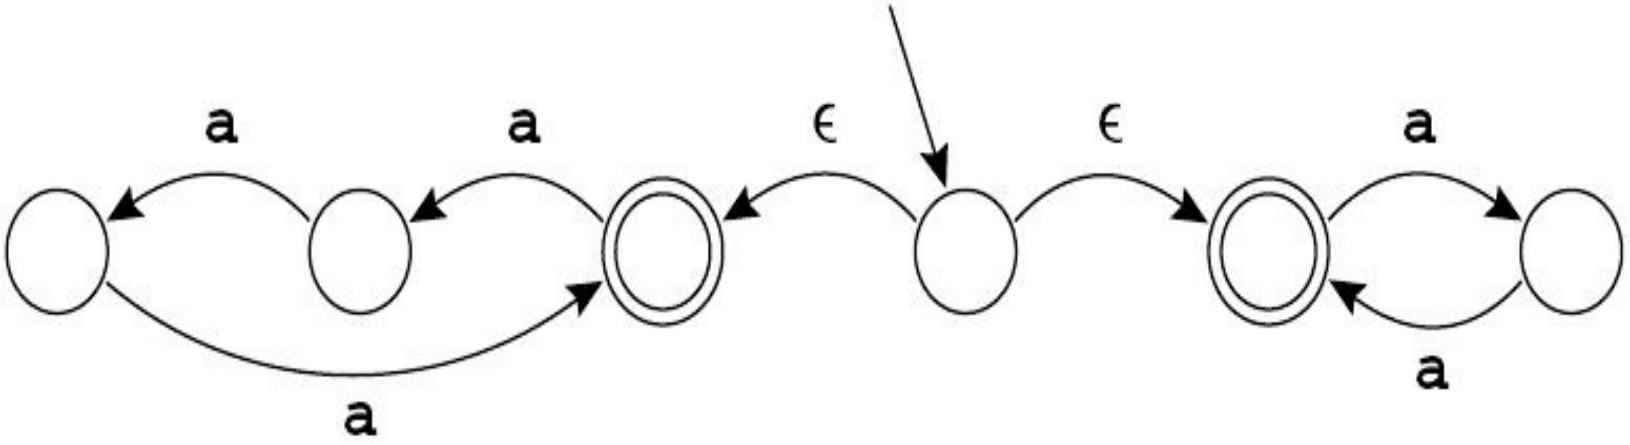

Que linguagem este autômato reconhece?

Nondeterministic Finite Automata (NFA)

- Não são apropriados para transformar em programas de computador
  - "Adivinhar" qual caminho deve ser seguido não é uma tarefa facilmente executada pelo HW dos computadores

Convertendo ER's para NFA's

- NFAs se tornam úteis porque é fácil converter expressões regulares (ER) para NFA
- Exemplos:

a

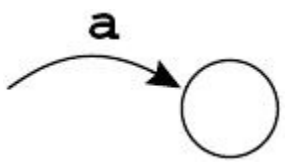

ab

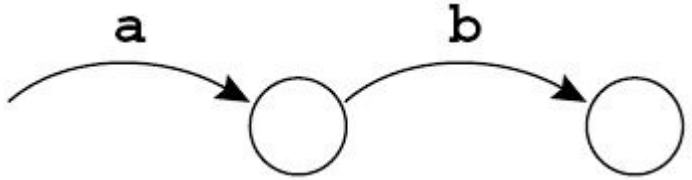

Convertendo ER's para NFA's

- De maneira geral, toda ER terá um NFA com uma cauda (aresta de entrada) e uma cabeça (estado final).

Convertendo ER's para NFA's

- Podemos definir essa conversão de maneira indutiva pois:
  - Uma ER é primitiva (único símbolo ou vazio) ou é uma combinação de outras ERs.
  - O mesmo vale para NFAs

Convertendo ER's para NFA's

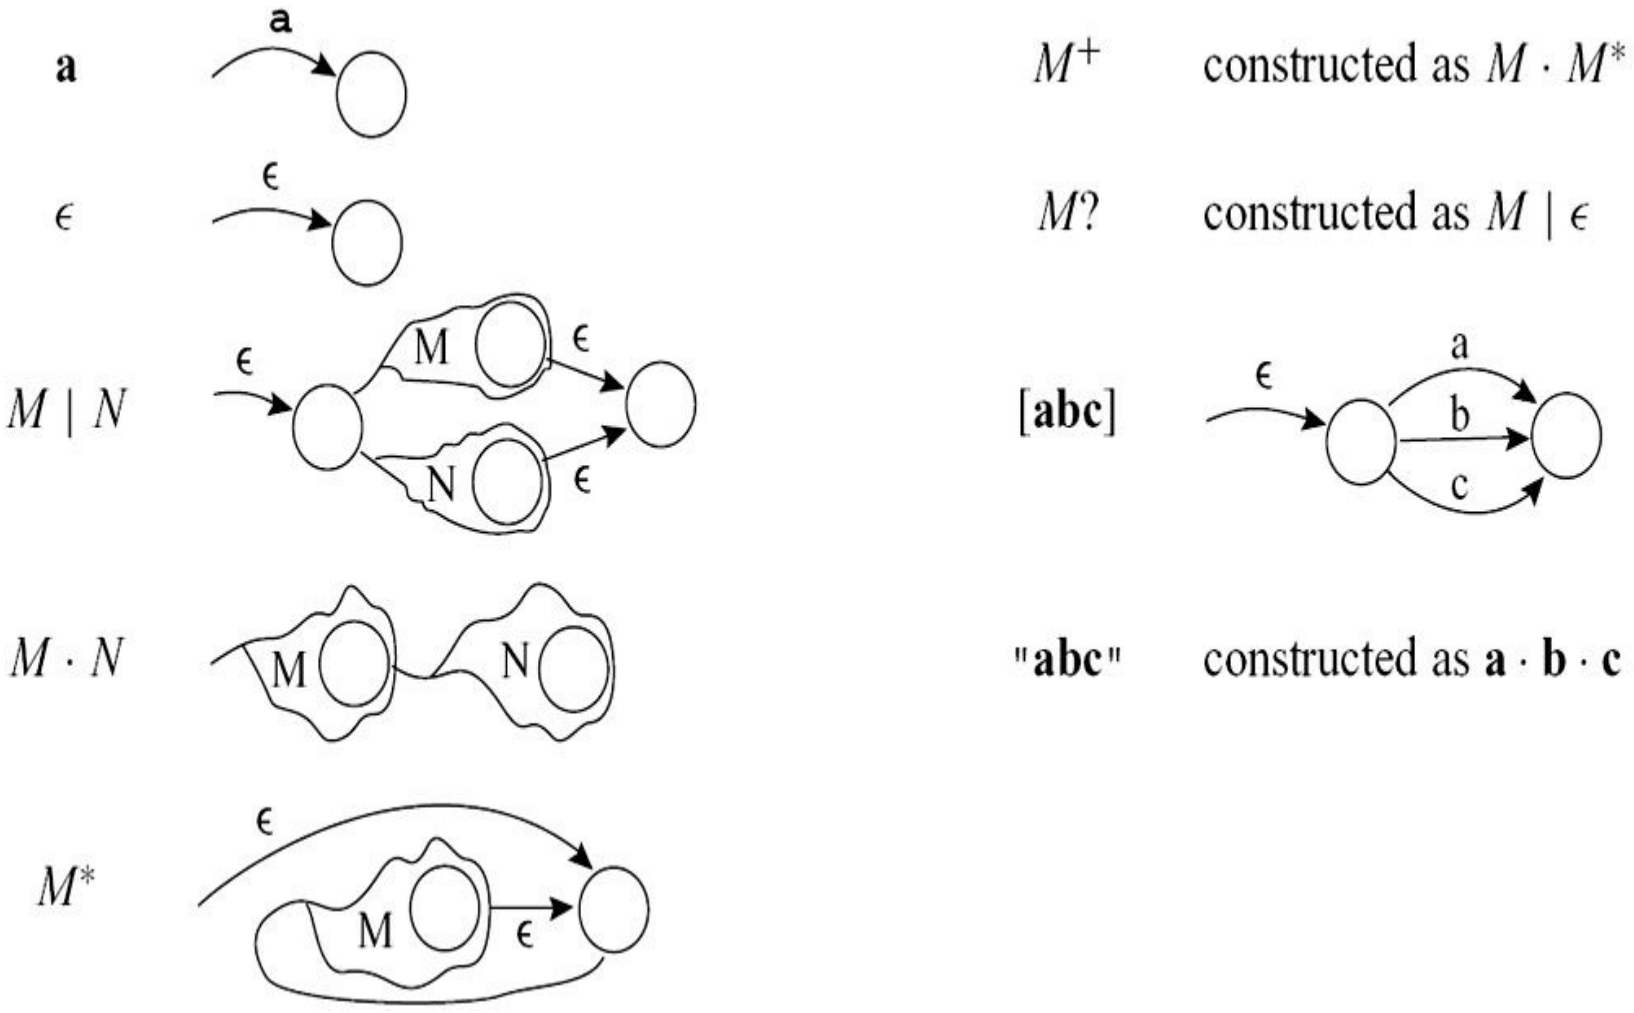

Exemplo

ERs para IF, ID, NUM e **error**

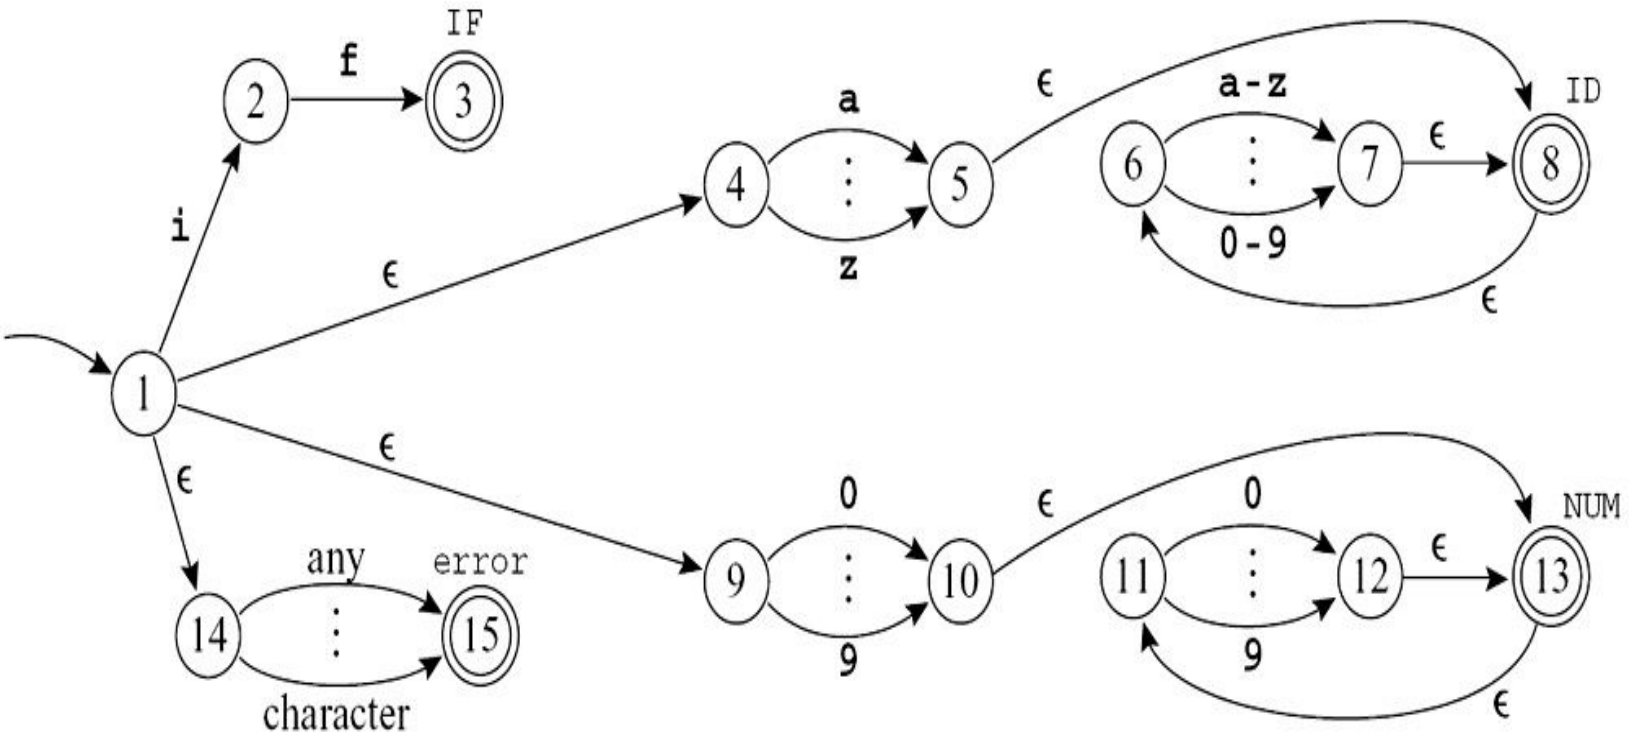

NFA vs. DFA

- DFAs são facilmente simuláveis por programas de computador
- NFAs são mais complexos, pois o programa teria que “adivinhar” o melhor caminho em alguns momentos
- Outra alternativa seria tentar todas as possibilidades

Simulando NFA para "`in`"

Início (1) -> NFA pode estar em {1,4,9,14}

Consome `i` -> NFA pode estar em {2,5,6,8,15}

Consome `n` -> NFA pode estar em {6,7,8}

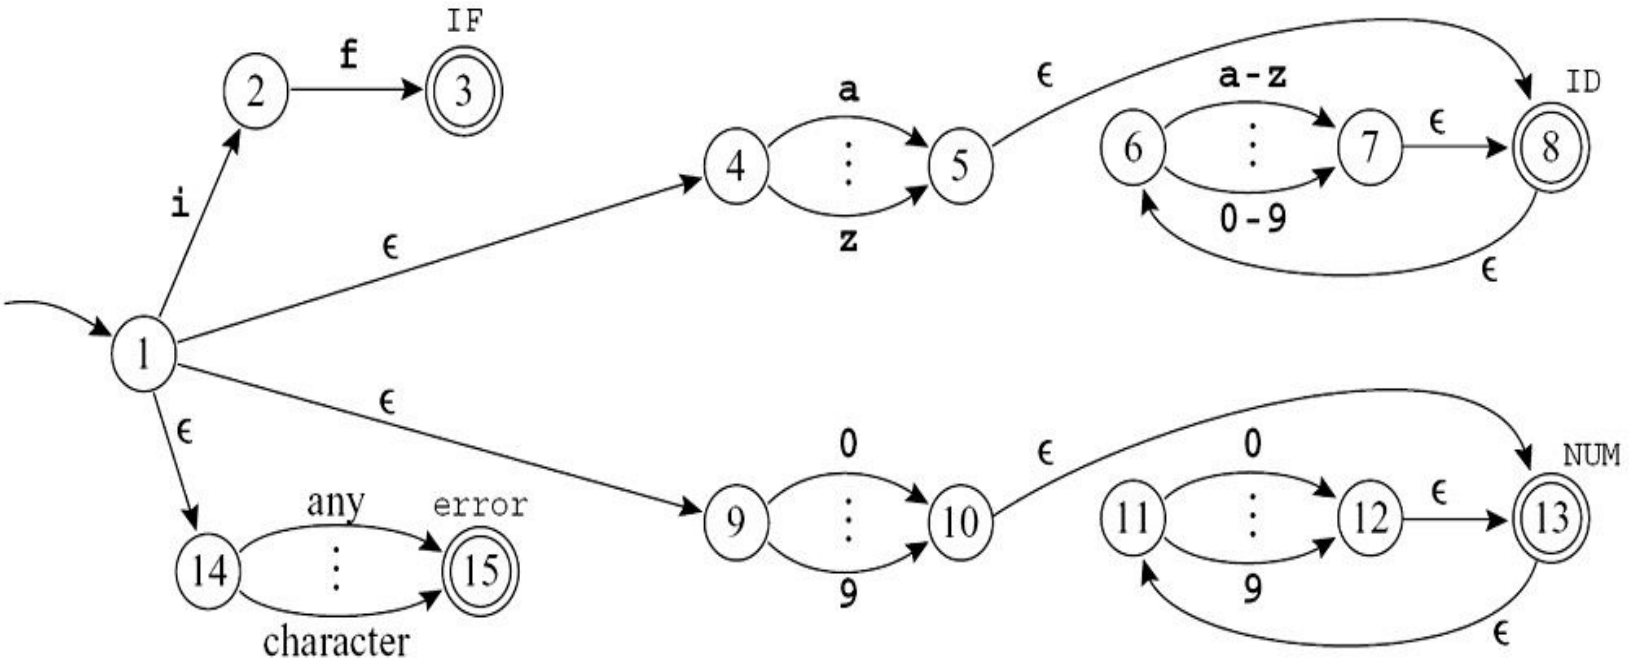

Є-Closure

- Edge(s,c): todos os estados alcançáveis a partir de s, consumindo c
- Closure(S): todos os estados alcançáveis a partir do conjunto S, sem consumir caractere da entrada
- Closure(S) é o conjunto T tal que:

$$T = S \cup \left(\bigcup_{s \in T} \mathbf{edge}(s, \epsilon) \right).$$

Algoritmo

Computado por iteração:

$$T \leftarrow S$$
$$\textbf{repeat } T' \leftarrow T$$
$$T \leftarrow T' \cup \left(\bigcup_{s \in T'} \textbf{edge}(s, \epsilon)\right)$$
$$\textbf{until } T = T'$$

Algoritmo da Simulação

- Da maneira que fizemos a simulação, vamos definir:

$$\mathbf{DFAedge}(d, c) = \mathbf{closure}(\bigcup_{s \in d} \mathbf{edge}(s, c))$$

como o conjunto de estados do NFA que podemos atingir a partir do conjunto *d*, consumindo *c*

Algoritmo da Simulação

- Estado inicial s_1 e string c_1, ..., c_k

$d \leftarrow \textbf{closure}(\{s_1\})$
for $i \leftarrow 1$ **to** k
  $d \leftarrow \textbf{DFAedge}(d, c_i)$

Convertendo NFA em DFA

- Manipular esses conjuntos de estados é muito caro durante a simulação
- Solução:
  - Calcular todos eles antecipadamente
- Isto converte o NFA em um DFA !!
  - Cada conjunto de estados no NFA se torna um estado no DFA

Convertendo NFA em DFA

```
states[0] ← {};      states[1] ← closure({s1})
p ← 1;      j ← 0
while j ≤ p
  foreach c ∈ Σ
    e ← DFAedge(states[j], c)
    if e = states[i] for some i ≤ p
      then trans[j, c] ← i
      else p ← p + 1
           states[p] ← e
           trans[j, c] ← p
  j ← j + 1
```

Convertendo NFA em DFA

- O estado d é final se qualquer um dos estados de states[d] for final
- Pode haver vários estados finais em states[d]
  - d será anotado com o token que ocorrer primeiro na especificação léxica (ERs) -> Regra de prioridade
- Ao final
  - Descarta *states[ ]* e usa *trans[ ]* para análise léxica

Convertendo NFA em DFA

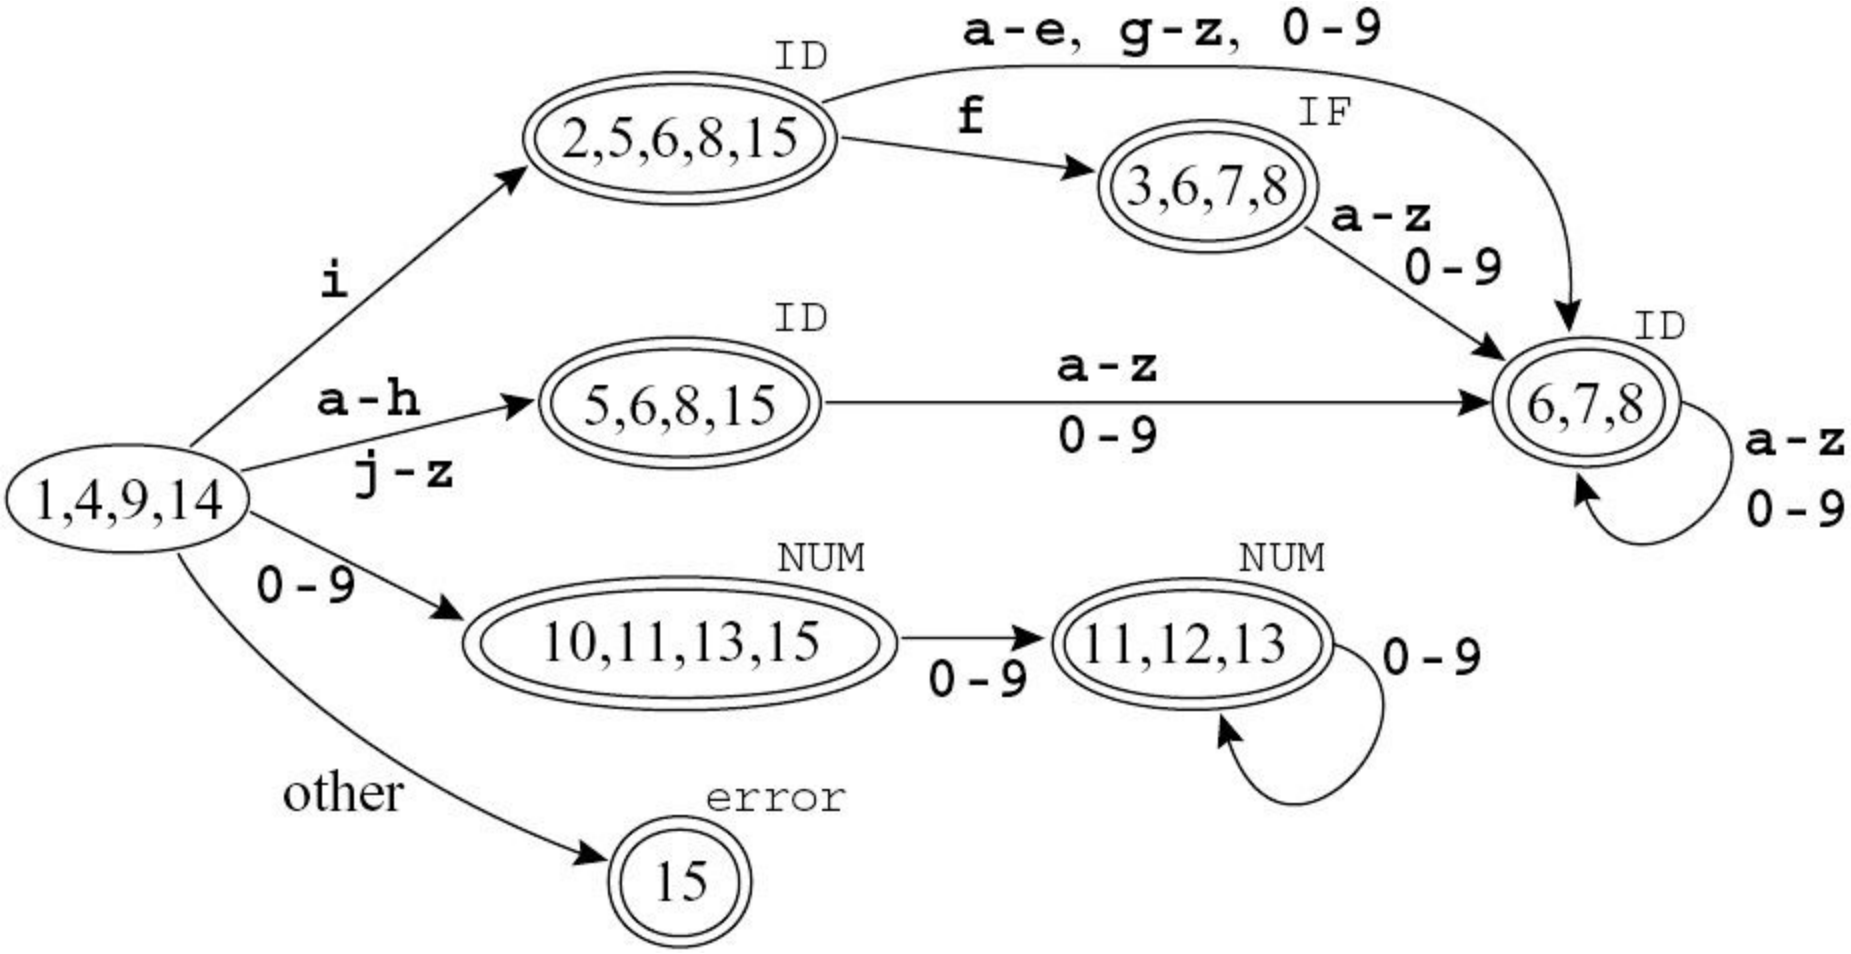

Convertendo NFA em DFA

- Esse é o menor autômato possível para essa linguagem?
  - Não!
  - Existem estados que são *equivalentes*!
- s_1 e s_2 são equivalentes quando o autômato aceita σ começando em s_1 ⇔ ele também aceita σ começando em s_2

Convertendo NFA em DFA

- Quais estados são equivalentes no autômato anterior?

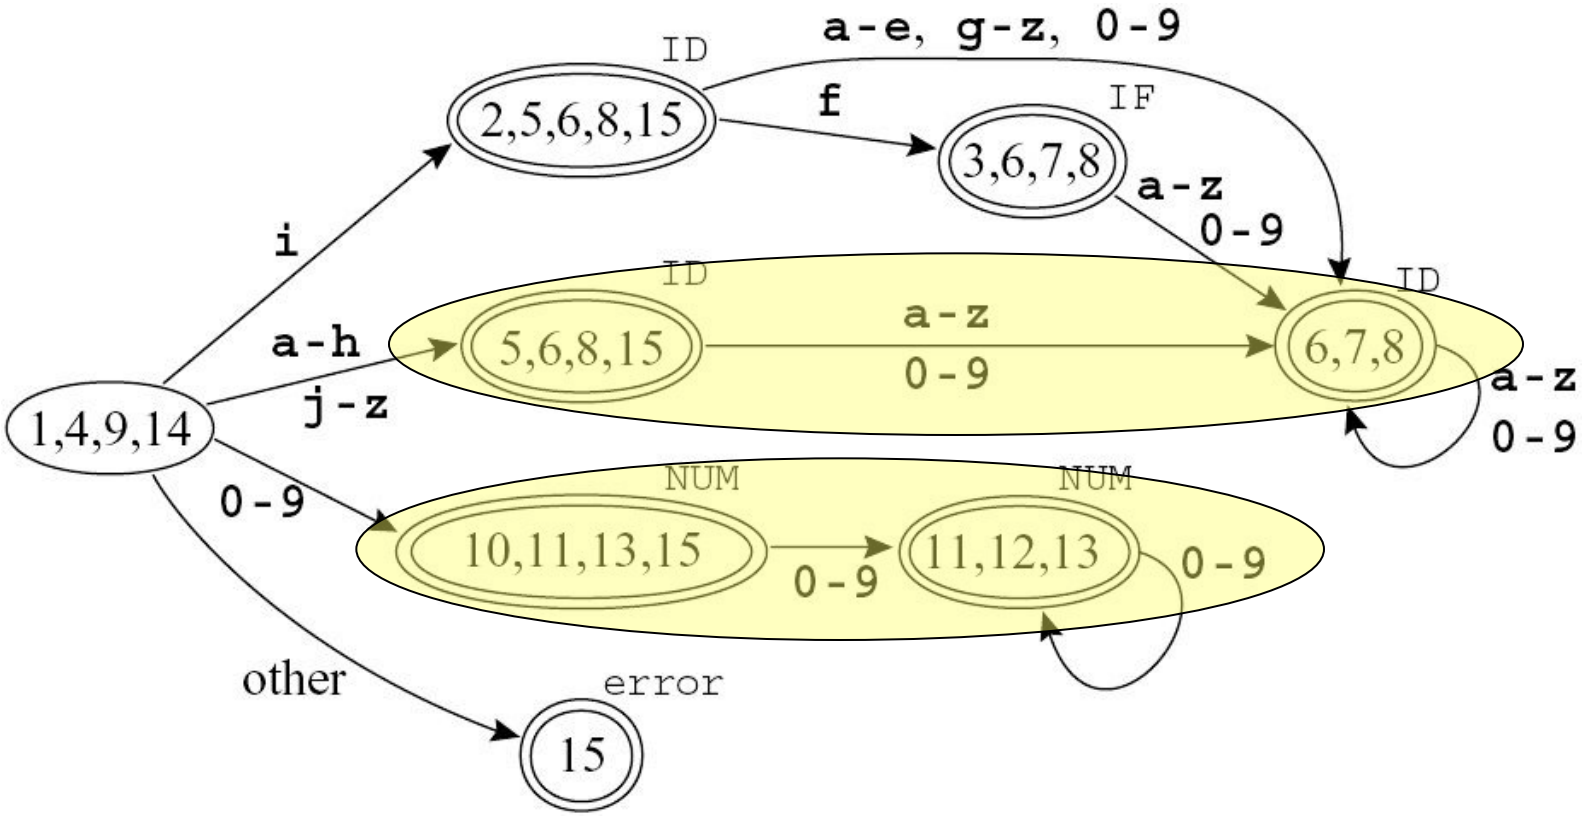

Convertendo NFA em DFA

- Como encontrar estados equivalentes?
  - trans[s1,c] = trans[s2,c] para ∀ c
  - Não é suficiente!!!

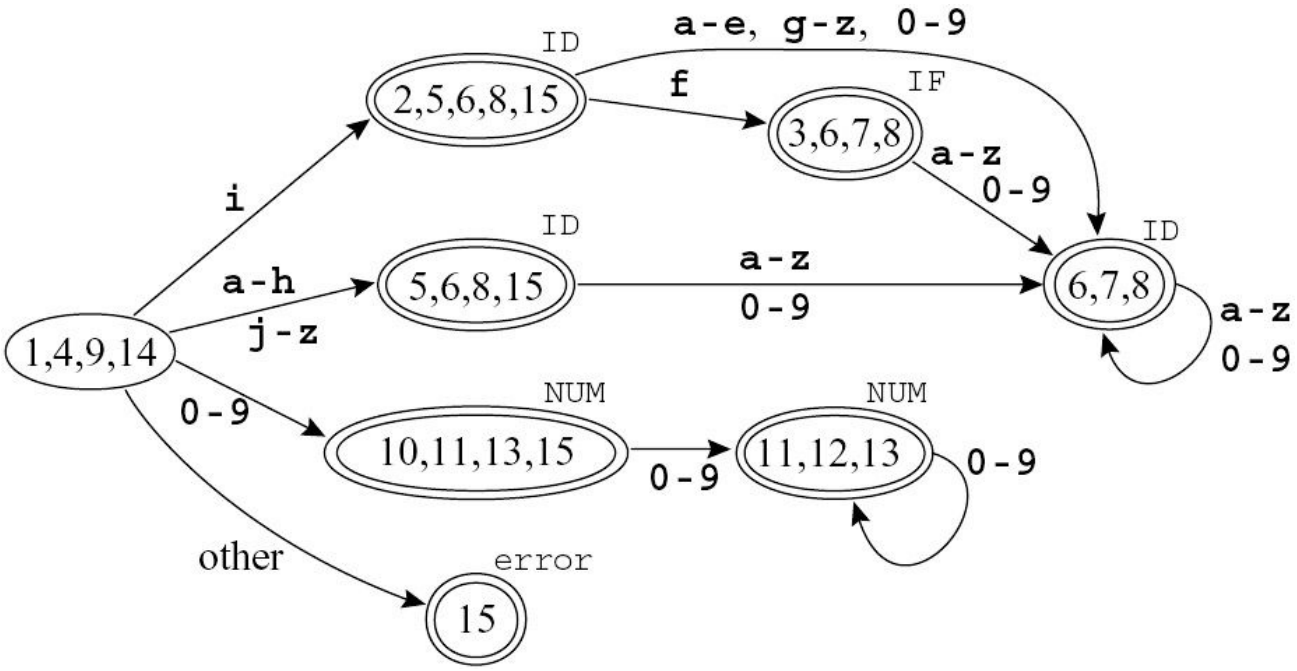

Convertendo NFA em DFA

- Contra-exemplo: