

# Expressões regulares

1. Histórico e motivação
2. Definição
  - a) Sintaxe
  - b) Semântica
  - c) Precedência dos operadores
3. Exemplos
4. Leis algébricas
5. Dialetos
6. Aplicações
7. Exercícios

Pré-requisito: básico de conjuntos (principais operações) e de teoria de linguagens (símbolos, alfabetos, cadeias e linguagens como conjuntos)

# Histórico e motivação

- São uma alternativa, juntamente com os autômatos finitos e as gramáticas lineares à direita ou à esquerda, para a representação formal de linguagens regulares (tipo 3);
- Pela sua natureza declarativa, normalmente são concisas e fáceis de serem manipuladas;
- Foram definidas por Kleene em 1956, no artigo “Representation of events in nerve nets and finite automata”;
- Demonstra-se a equipotência das expressões regulares com os autômatos finitos e as gramáticas lineares à esquerda ou à direita;
- São largamente utilizadas em linguagens de programação, ferramentas de busca de padrões e geradores automáticos de analisadores léxicos.

# Definição

Expressão regular  $X$  sobre um alfabeto  $\Sigma$ :

1.  $\emptyset$  é uma expressão regular sobre  $\Sigma$  e representa a linguagem vazia;
2.  $\varepsilon$  é uma expressão regular sobre  $\Sigma$  e representa a linguagem formada pela cadeia vazia  $\{\varepsilon\}$ ;
3.  $\forall \sigma \in \Sigma$ ,  $\sigma$  é uma expressão regular sobre  $\Sigma$  e representa a linguagem formada pela cadeia unitária  $\{\sigma\}$

Sejam  $X$  e  $Y$  são duas expressões regulares quaisquer sobre  $\Sigma$ . Então:

7. **Concatenação:**  $X.Y$ , ou simplesmente  $XY$ , é uma expressão regular sobre  $\Sigma$ , e representa a linguagem  $\{w=xy \mid x \in X \text{ e } y \in Y\}$ ;
8. **União:**  $X|Y$  é uma expressão regular sobre  $\Sigma$  e representa a linguagem  $\{w \mid w \in X \text{ ou } w \in Y\}$ ;
9. **Fecho recursivo e transitivo:**  $X^*$  é uma expressão regular sobre  $\Sigma$  e representa a linguagem  $X^0 \cup X^1 \cup \dots \cup X^n \cup \dots$

# Precedência dos operadores

1. Fecho recursivo e transitivo (maior)
2. Concatenação
3. União (menor)

Portanto...

$a|bcd^*$  representa a mesma linguagem que  $(a)|(bc(d)^*)$

⇒ Como nas expressões aritméticas, os parêntesis podem ser usados livremente para modificar, temporariamente, a precedência original dos operadores:

$a|bcd^*$ ,  $(a|b)cd^*$ ,  $(a|bc)d^*$ ,  $a|b(cd)^*$ ,  $a|(bcd)^*$  representam linguagens diferentes.

# Exemplos

Expressões regulares sobre o alfabeto  $\Sigma=\{a\}$ :

- $\emptyset$ , denotando a linguagem  $\{\}$
- $\epsilon$ , denotando a linguagem  $\{\epsilon\}$
- $a$ , denotando a linguagem  $\{a\}$
- $a|\epsilon$ , denotando a linguagem  $\{a, \epsilon\}$
- $aa$ , denotando a linguagem  $\{aa\}$
- $a^*$ , denotando a linguagem  $\{\epsilon, a, aa, aaa, \dots\}$
- $aa^*$ , denotando a linguagem  $\{a, aa, aaa, aaaa, \dots\}$ , ou seja, cadeias de comprimento mínimo 1
- $a(aa)^*$ , denotando a linguagem  $\{a, aaa, aaaaa, aaaaaaa, \dots\}$ , ou seja, cadeias de comprimento ímpar

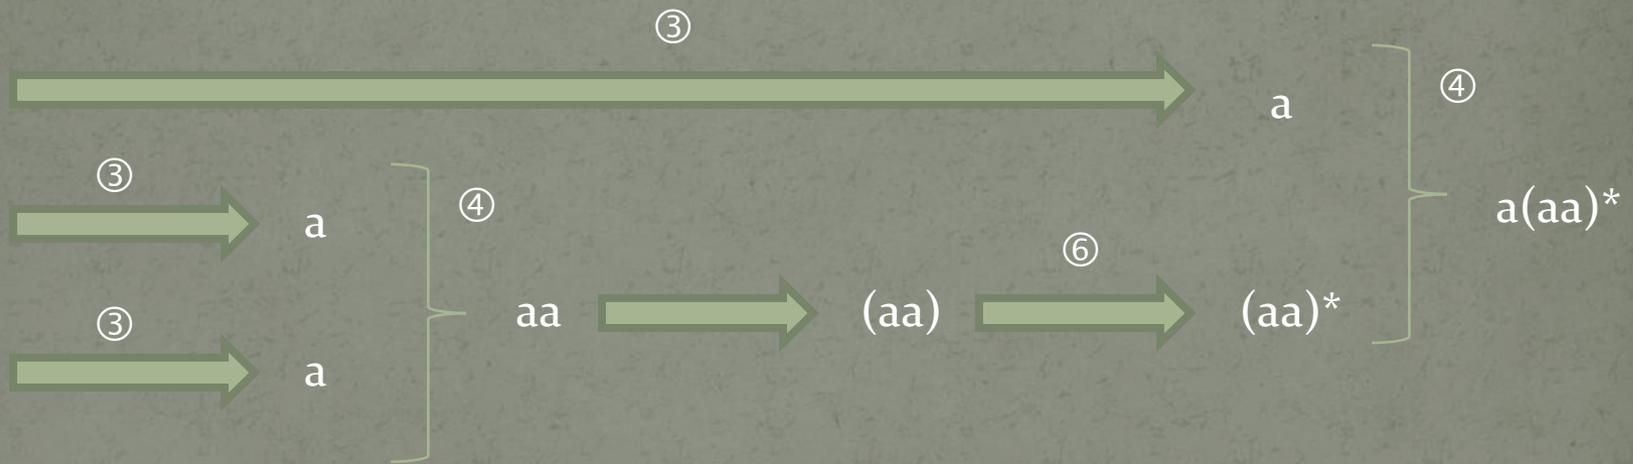
# Análise estrutural

Expressão regular sobre o alfabeto {a}:  $a(aa)^*$

- “a” é uma expressão regular (regra número 3);
- Se “a” é uma expressão regular, então “aa” também é (regra número 4);
- Se “aa” é uma expressão regular, então (aa) também é;
- Se (aa) é uma expressão regular, então  $(aa)^*$  também é (regra número 6);
- Se “a” e  $(aa)^*$  são expressões regulares, então  $a(aa)^*$  também é (regra número 4 novamente).

# Análise estrutural

Expressão regular sobre o alfabeto {a}:  $a(aa)^*$



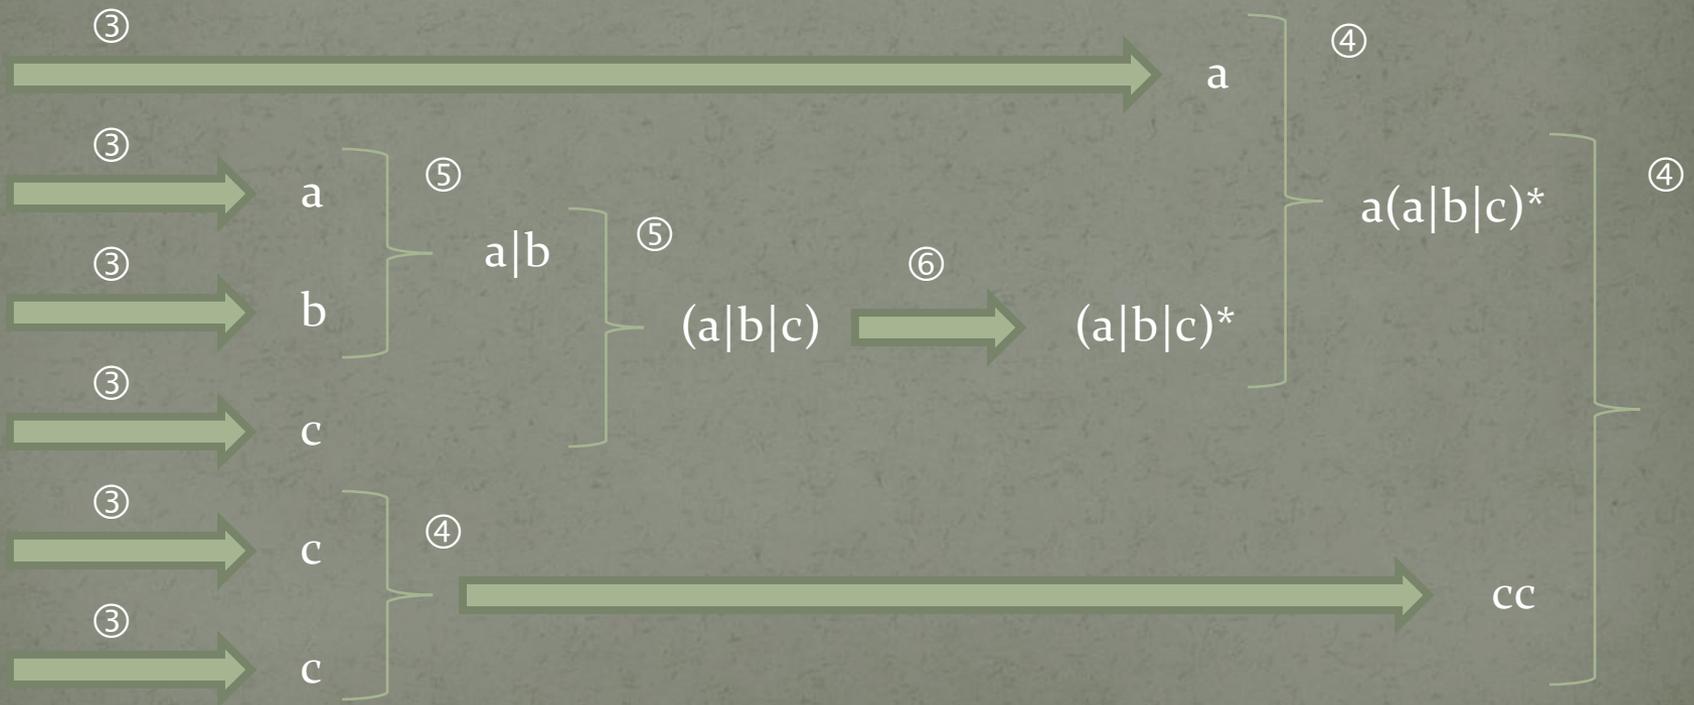
# Exemplos

Expressões regulares sobre o alfabeto  $\Sigma=\{a,b,c\}$ :

- $\emptyset$
- $\epsilon$
- $a$
- $b$
- $c$
- $a|b$
- $cb$
- $a(a|b|c)^*cc$ , denotando a linguagem formada pelas cadeias que iniciam com o símbolo “a” e terminam com dois símbolos “c” consecutivos;
- $(a|b|c)^*a(a|b|c)^*a(a|b|c)^*$ , denotando a linguagem formada pelas cadeias com pelo menos dois símbolos “a”;
- $((b|c)^*a(b|c)^*a)^*(b|c)^*a(b|c)^*a(b|c)^*$ , denotando a linguagem formada pelas cadeias com uma quantidade par, maior que zero, de símbolos “a”.

# Análise estrutural

Expressão regular sobre o alfabeto {a,b,c}:  $a(a|b|c)^*cc$



# Leis algébricas

## Associatividade

- União:

$$(X \mid Y) \mid Z = X \mid (Y \mid Z)$$

$$(\{a\} \mid \{b\}) \mid \{c\} = \{a\} \mid (\{b\} \mid \{c\}) = \{a,b,c\}$$

- Concatenação:

$$(XY)Z = X(YZ)$$

$$(\{a\} \{b\}) \{c\} = \{a\} (\{b\} \{c\}) = \{abc\}$$

# Leis algébricas

## Comutatividade

- União:

$$X \cup Y = Y \cup X$$

$$\{a,b\} \cup \{c,d\} = \{c,d\} \cup \{a,b\} = \{a,b,c,d\}$$

- Concatenação:

Não se aplica

$$\{a,b\} \{c,d\} \neq \{c,d\} \{a,b\}$$

# Leis algébricas

Elemento neutro

- União:

$$X \mid \emptyset = \emptyset \mid X = X$$

$$\{a,b\} \mid \emptyset = \emptyset \mid \{a,b\} = \{a,b\}$$

- Concatenação:

$$X\varepsilon = \varepsilon X = X$$

$$\{a,b\} \varepsilon = \varepsilon \{a,b\} = \{a,b\}$$

# Leis algébricas

Distributividade da concatenação sobre a união

- Esquerda:

$$X ( Y \mid Z ) = X Y \mid X Z$$

$$\{a\} (\{b\} \mid \{c\}) = \{a\}\{b\} \mid \{a\}\{c\} = \{ab, ac\}$$

- Direita:

$$( Y \mid Z ) X = Y X \mid Z X$$

$$(\{b\} \mid \{c\}) \{a\} = \{b\}\{a\} \mid \{c\}\{a\} = \{ba, ca\}$$

# Leis algébricas

Outras identidades

- $\emptyset X = X \emptyset = \emptyset$
- $X | X = X$
- $(X^*)^* = X^*$
- $\emptyset^* = \varepsilon$
- $\varepsilon^* = \varepsilon$
- $\emptyset | \varepsilon = \varepsilon$
- $X | X^* = X^*$

grep	Notação algébrica original
[Aa]	(A a)
[0-3]	(0 1 2 3)
[Aao-3]	(A a 0 1 2 3)
a*	a*
a+	aa*
a?	(a ε)
a{2}	aa
a{2,}	aaa*
a{2,4}	aa aaa aaaa
\(ab\)*	(ab)*
.	Qualquer caracter
.*	Qualquer cadeia
abc\ cba	abc cba

# Aplicações

- Ferramentas e linguagens de script:
  - `grep '\(abc\)*' arquivo`
  - `awk '/\((abc\)* / {print $1}' arquivo`
- Geradores de analisadores léxicos:
  - `[A-Za-z][A-Za-z0-9]*` (lex, C)
  - JavaLex (Java), Coco-R (Java, C++, C#) etc
- Sistemas de busca de padrões:
  - a) Bancos de dados, Editores de texto etc
  - b) Biologia, genética
- Linguagens de programação:
  - a) Java (java.util.regex)
  - b) C++, C# etc

Esta é a teoria.

Agora vamos aos exercícios.

Dúvidas?

# Exercícios

Para cada uma das expressões regulares sobre o alfabeto  $\{a,b,c\}$  apresentadas a seguir, (i) faça uma análise estrutural da mesmas, e (ii) apresente 5 cadeias pertencentes às respectivas linguagens.

•  $abb(ccc)^*$

•  $(a|bb|ccc)^*$

•  $a^*|a^*bb^*|(ab^*|(ab)^*)^*$

# Exercícios

Descreva, informalmente, da forma mais clara e concisa possível, e com o auxílio de exemplos, as linguagens representadas pelas seguintes expressões regulares sobre o alfabeto  $\{a,b\}$ :

•  $(a|b)(a|b)(a|b)^*$

•  $(b^*ab^*a)^*b^*|a^*b(a^*ba^*ba^*)^*$

•  $b^*|b^*ab^*|b^*ab^*ab^*|b^*ab^*ab^*ab^*a(a|b)^*$

# Exercícios

Obtenha expressões regulares que representem as seguintes linguagens definidas de maneira informal:

- Conjunto de todas as cadeias sobre o alfabeto  $\{a,b,c\}$  tais que elas contém apenas 3 símbolos “b”, todos eles consecutivos (exemplos: *acbbb*, *abbbccaa*);
- Conjunto de todas as cadeias sobre o alfabeto  $\{a,b,c\}$  tais que elas contém apenas 3 símbolos “b”, não consecutivos (exemplos: *babccb*, *cabcbaabca*);
- Conjunto de todas as cadeias sobre o alfabeto  $\{a,b,c\}$  tais que elas contém apenas 3 símbolos “b”, sendo que o primeiro “b” deve ser separado do segundo por pelo menos um símbolo e o segundo do terceiro por pelo menos dois símbolos (exemplos: *babccbcc*, *acabacabccbaa*).