

Gramáticas

Definições

Exemplos de gramáticas

Gramáticas

- Conceito introduzido pela lingüística
 - Objetivo de ensinar o inglês pelo computador e conseguir um tradutor de línguas
- Fracasso da **tradução** por volta dos anos 50.
- Sucesso na **descrição de LP**. Algol 60 foi descrito como uma linguagem livre de contexto na **notação BNF**.
- Atualmente, a **tradução** voltou a ganhar força dado o sucesso da tradução por métodos estatísticos que aprender a tarefa a partir de grandes conjuntos de dados (temos a WEB a disposição!)

Antes de vermos a noção formal de uma gramática vamos para algumas definições:

Alfabeto ou Vocabulário: Conjunto finito não vazio de símbolos. Símbolo é um elemento qualquer de um alfabeto.

$\delta\epsilon$

Ex: {A, B, C, ..., Z} alfabeto latino

{ α , β , γ , δ , ϵ , ..., ω } alfabeto grego

{0, 1} alfabeto binário

{0, 1, 2, 3, 4, 5, 6, 7, 8, 9} alfabeto de dígitos

{a, b}

Cadeia ou palavra: Concatenação de símbolos de um alfabeto. Define-se como cadeia vazia ou nula uma cadeia que não contém nenhum símbolo.

Ex: aab

123094

λ – cadeia nula

Comprimento de cadeia: Número de símbolos de uma cadeia.

$$\text{Ex: } |aab| = 3$$

$$|123094|=6$$

$$|\lambda|=0$$

Concatenação de cadeias: Define-se a concatenação z de uma cadeia x com uma cadeia y , como sendo a concatenação dos símbolos de ambas as cadeias, formando a cadeia xy . $|z| = |x| + |y|$

$$\text{Ex: } x = abaa; y = ba \Rightarrow z = abaaba$$

$$x = ba; y = \lambda \Rightarrow z = ba$$

Produto de alfabetos: É o produto cartesiano de alfabetos.

Ex: $V_1 = \{a, b\}$ $V_2 = \{1, 2, 3\} \Rightarrow V_1.V_2 = V_1 \times V_2 = \{a_1, a_2, a_3, b_1, b_2, b_3\}$

Observe que $V_1.V_2 \neq V_2.V_1$

Exponenciação de alfabetos: São todas as cadeias de comprimento n sobre V (V^n). $V^0 = \{\lambda\}$, $V^1 = V$, $V^n = V^{n-1}.V$

Ex: $V = \{0, 1\}$

$V^3 = V^2.V = (V.V).V = \{00, 01, 10, 11\}.\{0, 1\} = \{000, 001, 010, 011, 100, 101, 110, 111\}$

$|V^n| = m^n$ onde $|V| = m$

Fechamento (Clausura) de um Alfabeto: Seja A um alfabeto, então o fechamento de A é definido como $A^* = A^0 \cup A^1 \cup A^2 \cup \dots \cup A^n \cup \dots$

Portanto A^* = conjunto das cadeias de qualquer comprimento sobre o alfabeto a .

Ex: $A = \{1\}$

$A^* = \{\lambda, 1, 11, 111, \dots\}$

Fechamento Positivo de A : $A^+ = A^* - \{\lambda\}$

Linguagem é uma coleção/conjunto de *cadeias* de símbolos sobre um alfabeto/vocabulário. Estas cadeias são denominadas **sentenças da linguagem**, e são formadas pela justaposição de elementos individuais, os símbolos da linguagem.

Ex: $V = \{0, 1\}$

$L1 = \{0^n 1^n \mid n \geq 1\}$ **infinita**

$L1 = \{01, 0011, 000111, \dots\}$

$L2 = \{ab, bc\}$ **finita**


(linguagem formada pelas cadeias ab e bc)

$L3 = \{ab^n \cup a^n b \mid n \geq 0\}$ **infinita**

(linguagem formada por todas as cadeias que começam com "a" seguido de um número qualquer de "b"'s **OU** começam com um número qualquer de "a"'s seguidos de um "b", por exemplo ab, abb, aab, aaab, ...)


Finalita ou Infinita?

- i) $L1 = \{ x \mid x \in \{a, b, c\}^* \text{ e } x \text{ contém } ab \}$
- ii) $L2 = \{ w \in \{0, 1\}^* \mid w \text{ tem pelo menos um } 1 \}$
- iii) $L3 = \{ x \mid x \text{ é uma cadeia de } 0\text{'s e } 1\text{'s e } |x| \geq 2 \}$
- iv) $L1 = \{ w \in \{a, b\}^* \mid \text{todo } a \text{ tem um } b \text{ imediatamente à sua direita} \}$
- v) $L2 = \{ w \in \{a, b\}^* \mid w \text{ tem } aa \text{ como subpalavra} \}$



Vamos analisar uma sentença do **Português** colocada no contexto da cadeia alimentar

O gato comeu o rato.



Regras para analisar a sentença dada

<sentença> -> <sn> <sv>

<sn> -> <artigo> <substantivo>

<sv> -> <verbo> <sn>

<artigo> -> o

<substantivo> -> gato | rato

<verbo> -> comeu

"->" definido por

< > para distinguir sentença, sv, sn das palavras do português

Com essa gramática poderíamos gerar:

1) O gato comeu o rato

2) O rato comeu o gato

que são gramaticalmente corretas mas 2) é inaceitável no contexto dado.

Para formar essa gramática parcial para o português usamos 4 conceitos:

- categorias sintáticas como <sentença>, <sn>, <sv>, <artigo>, <substantivo>, <verbo> são chamados de **não terminais** ou variáveis
- palavras são chamadas de **terminais**
- relação entre terminais e não terminais são chamadas de **produções**
- o não terminal que gera todas as cadeias de terminais (<sentença>) é chamado de **símbolo inicial**

Formalmente, as gramáticas são caracterizadas como quádruplas ordenadas

$$G = (V_n, V_t, P, S)$$

onde:

V_n representa o vocabulário não terminal da gramática. Este vocabulário corresponde ao conjunto de todos os símbolos dos quais a gramática se vale para definir as leis de formação das sentenças da linguagem.

V_t é o vocabulário terminal, contendo os símbolos que constituem as sentenças da linguagem. Dá-se o nome de terminais aos elementos de V_t .

P representa o conjunto de todas as leis de formação utilizadas pela gramática para definir a linguagem.

Para tanto, cada construção parcial, representada por um não-terminal, é definida como um conjunto de regras de formação relativas à definição do não-terminal a ela referente. A cada uma destas regras de formação que compõem o conjunto P dá-se o nome de produção da gramática.

Assumimos $V_n \cap V_t = \emptyset$. Convencionamos que $V_n \cup V_t = V$
Cada produção P tem a forma:

$$\alpha \rightarrow \beta \quad \alpha \in V^+; \quad \beta \in V^*$$

$S \in V_n$ denota a principal categoria gramática de G ; é dito o símbolo inicial ou o axioma da gramática. Indica onde se inicia o processo de geração de sentenças.

Ex.1: $G = (\{S, A, B\}, \{a, b\}, P, S)$

$P: \{S \rightarrow AB$

$A \rightarrow a$

$B \rightarrow b\}$

Notação/Convenções

- Letras do alfabeto latino maiúsculas $\{A, B, \dots, Z\}$: **variáveis**
- Letras do começo do alfabeto latino minúsculas $\{a, b, c, \dots\}$: **terminais**
- Letras do fim do alfabeto latino minúsculas $\{t, u, v, x, z\}$: **cadeias de terminais**
- Letras gregas minúsculas $\{\alpha, \beta, \gamma, \delta, \epsilon, \dots, \omega\}$: **cadeias de terminais e não terminais**

alfa, beta, gama, delta, épsilon, zeta, eta, teta, iota, kapa, lâmbda, mi, ni, xi, ômicron, pi, rô, sigma, tau, úpsilon, fi, qui, psi, ômega

Exercício

- Tentem definir uma gramática simples, por exemplo, de algum construtor (definição) ou comando de uma linguagem de programação.

Comando de atribuição com variáveis simples em Pascal

$G = (\{\langle\text{atribuição}\rangle, \langle\text{variável}\rangle, \langle\text{expressão}\rangle, \langle\text{identificador}\rangle\}, \{:=, \text{letras}, \text{digitos}, _, \text{operadores}, (,)\}, P, \langle\text{atribuição}\rangle)$

$P = \{$
 $\langle\text{atribuição}\rangle ::= \langle\text{variável}\rangle := \langle\text{expressão}\rangle$
 $\langle\text{variável}\rangle ::= \langle\text{identificador}\rangle$
 $\}$

$\langle\text{expressão}\rangle$ deve ainda ser definida. Veremos isto mais para frente.

$\langle\text{identificador}\rangle ::=$ é formado por uma letra, seguido de qualquer número de letras, digitos ou underscore (tem fazer esta regra)

Definida uma gramática G , qual é a linguagem gerada por ela?

Precisaremos das relações \Rightarrow_G (deriva diretamente) e \Rightarrow_G^* (deriva) definidas entre as cadeias de V^*

Def1. Se $\alpha \rightarrow \beta$ é uma produção de P e γ (gama) e δ (delta) são cadeias quaisquer de V^* , então $\gamma \alpha \delta \Rightarrow_G \gamma \beta \delta$ (**deriva diretamente** na gramática G).

Dizemos que a produção $\alpha \rightarrow \beta$ é aplicada à cadeia $\gamma \alpha \delta$ para obter $\gamma \beta \delta$. A relação \Rightarrow_G relaciona cadeias exatamente quando a segunda é obtida a partir da primeira pela aplicação de uma **única produção**.

No Ex.1.: $S \Rightarrow_G AB$; $aB \Rightarrow_G ab$ **ou**
 $S \Rightarrow_G AB \Rightarrow_G aB \Rightarrow_G ab$

Def2. Suponha que $\alpha_1 \alpha_2 \alpha_3 \dots \alpha_m$ são cadeias de V^* e $\alpha_1 \Rightarrow_G \alpha_2, \alpha_2 \Rightarrow_G \alpha_3, \dots, \alpha_{m-1} \Rightarrow_G \alpha_m$. Então dizemos que $\alpha_1 \Rightarrow_G^* \alpha_m$ (**deriva**). Aplicamos algum número de produções de P . Por convenção $\alpha \Rightarrow_G^* \alpha$ para a cadeia α .

No Ex.1.: $S \Rightarrow_G^* ab$;
 $S \Rightarrow_G^* aB$;
 $AB \Rightarrow_G^* ab$;
 $ab \Rightarrow_G^* ab$

Def3. Forma sentencial: uma cadeia α composta de terminais e não terminais se $S \Rightarrow^* \alpha$

No Ex.1: aB, AB, S, ab são formas sentenciais.

Uma forma sentencial, α , é uma **sentença** de G se $S \Rightarrow^* \alpha$ e $\alpha \in Vt^*$ (são composta de terminais). Ou seja, as cadeias geradas pela gramática são as sentenças de G .

Def4. A Linguagem L gerada por uma gramática G é definida como o conjunto de cadeias geradas por G . Ou seja,

$$L(G) = \{x \mid x \in Vt^* \text{ e } S \Rightarrow_G^* x\} \text{ ou } \{x \mid x \text{ é sentença de } G\}$$

1. A cadeia consiste somente de terminais
2. A cadeia pode ser derivada a partir do símbolo inicial da gramática

Def5. Duas gramáticas $G1$ e $G2$ são equivalentes sse $L(G1) = L(G2)$

Exemplos de Gramáticas

$G1 = (\{S\}, \{0,1\}, P1, S)$

$P1: \{$
1. $S \rightarrow 0S1$
2. $S \rightarrow 01$
 $\}$

Qual é a linguagem gerada por $G1$? Aplicamos o **processo de derivação** para saber $L(G1)$, que é o processo de obtenção de cadeias a partir de uma gramática.

$G2 = (\{S,B,C\}, \{a,b,c\}, P2, S)$

$P2: \{$
1. $S \rightarrow aSBC$
2. $S \rightarrow aBC$
3. $CB \rightarrow BC$
4. $aB \rightarrow ab$
5. $bB \rightarrow bb$
6. $bC \rightarrow bc$
7. $cC \rightarrow cc$
 $\}$

$L(G2) = ?$

G1

- A menor cadeia gerada é 01: $S \Rightarrow^2 01$
- Se aplicarmos $n-1$ vezes a produção 1, seguida da produção 2 teremos:
 - $S \Rightarrow 0S1 \Rightarrow 00S11 \Rightarrow 0^3S1^3 \Rightarrow^*$
 - $0^{n-1}S1^{n-1} \Rightarrow 0^n1^n$
 - Portanto, $L(G1) = \{0^n1^n \mid n \geq 1\}$
ou $S \Rightarrow^* 0^n1^n$


Start Pause Stop

Noninverted Tree

Input 0011

String accepted! 4 nodes generated.

S	→	0S1
S	→	01





Input 0011
String accepted! 4 nodes generated.

S	→	0S1
S	→	01

Production	Derivation
	S
S->0S1	0S1
S->01	0011

Start Pause Step

Noninverted Tree

Input 00111

String rejected. 5 nodes generated.

S	→	0S1
S	→	01

G2

- A menor cadeia gerada é abc: $S \Rightarrow^2 aBC \Rightarrow^4 abC \Rightarrow^6 abc$
- Usamos a 1 $n-1$ vezes: $S \Rightarrow^* a^{n-1}S(BC)^{n-1}$
- Usamos a 2 uma vez: $S \Rightarrow^* a^n(BC)^n$
- A 3 permite trocar B com C para que B's precedam os C's
 - Para $n = 2$ aaBCBC \Rightarrow aaBBCC (usamos a regra 3 1 vez)
 - Para $n = 3$ aaaBCBCBC \Rightarrow aaaBCCBC \Rightarrow aaaBBCBC \Rightarrow aaaBBCCC (usamos a regra 3 3 vezes)
 - Para $n = 4$ aaaaBCBCBCBC \Rightarrow aaaaBCBCBBCC \Rightarrow aaaaBCBBCBC \Rightarrow aaaaBCBBCCC \Rightarrow aaaaBBCBBCCC \Rightarrow aaaaBBBCBCCC \Rightarrow aaaaBBBBCCCC (usamos a regra 3 6 vezes);
 - Para $n = 5$ usamos a 3 10 vezes.
- Assim $S \Rightarrow^* a^n B^n C^n$
- Usamos a 4 uma vez: $S \Rightarrow^* a^n b B^{n-1} C^n$
- Aplicamos a 5 $n-1$ vezes: $S \Rightarrow^* a^n b^n C^n$
- Aplicamos a 6 uma vez: $S \Rightarrow^* a^n b^n c C^{n-1}$
- Aplicamos a 7 $n-1$ vezes: $S \Rightarrow^* a^n b^n c^n$

$$L(G2) = \{a^n b^n c^n \mid n \geq 1\}$$

Fecho e a definição de Linguagem

A definição formal de linguagem é baseada em um subconjunto do fecho de um vocabulário terminal, como já vimos:

$$L(G) = \{x \mid x \in Vt^* \text{ e } S \Rightarrow_G^* x\} \text{ ou } \{x \mid x \text{ é sentença de } G\}$$

Então, a **maior** linguagem sobre um vocabulário Vt é Vt^* .

A **menor** linguagem sobre um vocabulário Vt é \emptyset (conjunto vazio) ou seja, a linguagem vazia, composta por zero cadeias/sentenças. Observe que é diferente do conjunto que tem a cadeia vazia $\{\lambda\}$

O conjunto de todos os subconjuntos possíveis de Vt^* é 2^{Vt^*} e representa o conjunto de todas as linguagens que podem ser definidas a partir de Vt^* .

$$\emptyset \text{ (conjunto vazio) e também } Vt^* \in 2^{Vt^*}$$

Exercício

Seja $V_t = \{a,b,c\}$ e a propriedade "todas as cadeias são iniciadas pelo símbolo a"

1. Qual a menor linguagem?
2. Qual a maior linguagem?
3. A linguagem $\{a, ab, ac, abc, acb\}$ satisfaz a propriedade acima?
4. A linguagem $\{a\} \{a\}^* \{b\}^* \{c\}^*$ satisfaz a propriedade acima?