

## Parte III: Lenguajes y Autómatas

---

23 de noviembre de 2018

**Alfabeto** Conjunto finito no vacío, habitualmente usamos  $\Sigma$  para referirnos a alfabetos.

**Cadena** (fijado el alfabeto) Secuencia finita de símbolos de  $\Sigma$ .

**Lenguaje** un subconjunto de  $\Sigma^*$ .

**Lenguaje Regular** puede ser reconocido por un AFD, o un AFN o un AFN- $\epsilon$ .

# Hablemos de lenguajes no-regulares

Gracias al pumping lemma demostramos que

$$L_{bal} = \{\alpha \mid \alpha \text{ tiene paréntesis balanceados}\}$$

no es un lenguaje regular.

Fenómenos similares en computación:

- lenguajes de programación: {}, if...then...else...
- lenguajes de intercambio de datos: json ({} y []), XML (etiquetas)

Las *gramáticas libres de contexto* son el formalismo para describir lenguajes con esas características.

## Gramáticas libres de contexto

Una gramática para  $0^n 1^n$ :

$$A \rightarrow 0A1 \mid \epsilon$$

Una gramática para paréntesis balanceados:

$$S \rightarrow S(S)S \mid \epsilon$$

Una gramática para expresiones aritméticas con variables:

$$E \rightarrow N \mid I \mid E+E \mid E^*E \mid (E)$$

$$I \rightarrow a \mid I0 \mid \dots \mid I9$$

$$N \rightarrow 1 \mid \dots \mid 9 \mid ND$$

$$D \rightarrow 0 \mid \dots \mid 9$$

## Formalizando las Gramáticas Libres de Contexto

Una GLC está dado por los siguientes componentes  $G = (V, T, P, S)$ :

**Alfabeto terminal** Conjunto de símbolos sobre los que definimos el lenguaje.  $T_0 = \{0, 1\}$ ,  $T_1 = \{(, )\}$ ,  $T_2 = \{0, \dots, 9, +, *, (, )\}$ .

**Variables (o símbolos no-terminales)** Son las categorías sintácticas; cada una representará un lenguaje. En los ejemplos:  $V_0 = \{A\}$ ,  $V_1 = \{S\}$ ,  $V_2 = \{E, N, D, I\}$

**Símbolo inicial** Es una variable que determina el lenguaje que estamos generando.  $S_0 = A$ ,  $S_1 = S$ ,  $S_2 = E$

**Reglas (o producciones)** representan la definición recursiva del lenguaje: son de la forma  $U \rightarrow \alpha$  donde  $\alpha \in (V \cup T)^*$ .  
Decimos que  $U$  es la *cabeza* y  $\alpha$  el *cuerpo*.

## Generación (derivación) de cadenas

Comenzamos con la variable inicial y elegimos una de las reglas para esa variable y así sucesivamente:

$$S \Rightarrow (S) \Rightarrow ((S)) \Rightarrow ((\epsilon))$$

$$E \Rightarrow E * E \Rightarrow I * E \Rightarrow I * (E) \Rightarrow a * (E)$$

$$\Rightarrow a * (N) \Rightarrow a * (ND) \Rightarrow a * (4D) \Rightarrow a * (42)$$

Formalmente, si  $\alpha, \beta \in (V \cup T)^*$  decimos que  $\alpha$  *deriva*  $\beta$  si obtenemos  $\beta$  reemplazando en  $\alpha$  una variable de  $V$  por el cuerpo de una producción  $V \rightarrow \gamma$ :

$$\alpha'V\alpha'' \Rightarrow \alpha'\gamma\alpha''$$

## El lenguaje de una gramática

La clausura reflexiva-transitiva de  $\Rightarrow$  nos permite definir el lenguaje de una gramática:

**reflexiva**  $\alpha \Rightarrow^* \alpha$

**transitiva** Si  $\alpha \Rightarrow^* \beta$  y  $\beta \Rightarrow \gamma$ , entonces  $\alpha \Rightarrow^* \gamma$ .

Volviendo al ejemplo podemos escribir  $S \Rightarrow^* a^*$  (42).

Sea  $G = (V, T, P, S)$ , su lenguaje está definido como

$$L(G) = \{\alpha \in T^* \mid S \Rightarrow^* \alpha\}$$

- Podemos elegir más de una variable para realizar una derivación:

$$a * E \Leftarrow I * E \Rightarrow I * (E)$$

Se puede adoptar una estrategia para elegir siempre la primer variable de izquierda a derecha.

- Existe otra forma de representar las derivaciones, los *árboles de derivación*, que muestran que las gramáticas pueden ser ambiguas.



# Árboles de derivación

**nodos interiores** variables de la gramática.

**raiz** el símbolo inicial.

**hojas** no-terminales o terminales o  $\epsilon$ .

Un árbol donde todas las hojas sean terminales es una palabra de la gramática.

Si una palabra tiene dos árboles distintos, entonces la gramática es ambigua.

**Si definen una gramática, asegúrense que sea no ambigua.**