

2.13. Ambigüedad y forma normal de Chomsky

Definición (Derivación ambigua). Sea G una GLC. Un string $w \in \mathcal{L}(G)$ es *derivado ambiguamente por G* si posee dos o más derivaciones por la izquierda distintas; equivalentemente, si posee dos o más árboles de derivación distintos.

Definición (Gramática ambigua). Una GLC G es *ambigua* si deriva ambiguamente algún string de su lenguaje. Una gramática que no es ambigua se llama *no ambigua*.

2.14. Forma normal de Chomsky

Definición (Forma normal de Chomsky). Una GLC $G = (V, \Sigma, R, S)$ está en *forma normal de Chomsky* si la variable inicial aparece sólo al lado izquierdo de las reglas y todas las reglas tienen una de las formas siguientes:

- $A \rightarrow BC$,
- $A \rightarrow a$,
- $S \rightarrow \varepsilon$,

donde $A, B, C \in V$, $a \in \Sigma$, y la última regla aparece solamente cuando $\varepsilon \in \mathcal{L}(G)$.

Teorema. Toda GLC posee una GLC equivalente en forma normal de Chomsky.

Para transformar una gramática a forma normal de Chomsky se procede de la siguiente manera:

1. si es necesario, se introduce una nueva variable inicial que no aparece al lado derecho de ninguna regla;
2. se eliminan las reglas ε , conservando $S \rightarrow \varepsilon$ cuando corresponde;
3. se eliminan las reglas unitarias $A \rightarrow B$;
4. se aíslan los terminales que aparecen en lados derechos de largo al menos dos; y
5. se binarizan los lados derechos que contienen tres o más símbolos.

Ejercicios

1. Consideremos los tokens $\{ (,), [,], \mathfrak{t} \}$. Acá $\mathfrak{t}$ representa “texto” y los demás tokens representan paréntesis y corchetes.
 - a) Diseñe una GLC y un AP que generen exactamente los strings de tokens que representan expresiones con paréntesis y corchetes bien balanceados.

- b) ¿Es ambigua la GLC que diseñó? Justifique su respuesta.
- c) Si diseño una GLC ambigua, diseñe una GLC no ambigua que genere el mismo lenguaje.
- d) Diseñe una GLC y un AP para las expresiones con paréntesis y corchetes bien balanceados que además contengan exactamente un token $\mathbf{t}$ sin paréntesis ni corchetes.
- e) Transforme alguna de las GLC que diseñó a forma normal de Chomsky.

2. Sea $\Sigma = \{0, 1, \mathbf{f}\}$. Representaremos árboles binarios con hojas etiquetadas con 0 o 1 y nodos internos etiquetados con $\mathbf{f}$ en texto plano como sigue:

- 0 y 1 son representaciones válidas.
- Si x e y son representaciones válidas, entonces $\mathbf{f}xy$ también lo es.

Llamaremos por $\mathcal{T}$ al lenguaje de todas las representaciones válidas de árboles binarios.

- a) Diseñe una GLC (con tres reglas y una variable) y un AP que acepten $\mathcal{T}$.
- b) Use su gramática anterior para construir una GLC para $\mathcal{F} = (\mathcal{T})^*$, el lenguaje de todas las representaciones válidas de bosques binarios. ¿Es ambigua la GLC que diseñó?
- c) Para $u \in \Sigma^*$, sus *posiciones pendientes* $p: \Sigma^* \rightarrow \mathbb{Z}$ se definen como

$$p(u) = 1 + |u|_{\mathbf{f}} - |u|_0 - |u|_1.$$

Pruebe que $u \in \mathcal{T}$ si y sólo si $p(u) = 0$ y $p(v) \geq 1$ para todo prefijo v propio de u . ¿Qué significa intuitivamente esta condición?

- d) Muestre que si $x, y \in \mathcal{T}$ e y es un prefijo de x , entonces $x = y$. Concluya que toda palabra $w \in \mathcal{F}$ tiene una única factorización $w = t_1 t_2 \dots t_k$ con $t_i \in \mathcal{T}$ para todo $i = 1, \dots, k$.
- e) Use lo anterior para construir una GLC no ambigua para $\mathcal{F}$.
- f) Convierta la GLC no ambigua que diseñó a forma normal de Chomsky.

3. El objetivo de esta pregunta es diseñar un algoritmo eficiente que dada una GLC G y un string w , determine si $w \in \mathcal{L}(G)$. Dicho algoritmo se conoce como *algoritmo CYK* en honor a sus inventores Cocke, Younger y Kasami.

Sea $G = (V, \Sigma, R, S)$ una GLC **en forma normal de Chomsky** y sea $w \in \Sigma^*$ un string de largo n . Para $1 \leq i \leq j \leq n$, defina la tabla

$$T[i, j] = \{A \in V : A \xrightarrow{*} w_i w_{i+1} \dots w_j\}.$$

Es decir, $T[i, j]$ contiene las variables que pueden generar el substring $w_i \dots w_j$.

- a) Suponga que ya calculó toda la tabla T . Explique cómo decidir, en base a la tabla T , si $w \in \mathcal{L}(G)$.
- b) ¿Cómo calcularía $T[i, i]$ para todo $i = 1, \dots, n$? ¿Cuánto tiempo toma calcular toda la diagonal de la tabla?
- c) Fije $i < j$ y suponga que ya conocemos $T[i, k]$ y $T[k+1, j]$ para todo $k = i, i+1, \dots, j-1$. Explique cómo calcular $T[i, j]$ usando esta información y las reglas de G . ¿Cuánto tiempo toma calcular $T[i, j]$?

- d)* Use los incisos anteriores para describir un algoritmo de programación dinámica que decida si $w \in \mathcal{L}(G)$.
- e)* Muestre que su algoritmo corre en tiempo $\mathcal{O}(n^3|R|)$.