

Compiladores: Sesión 3. Análisis léxico, expresiones regulares

Prof. Gloria Inés Alvarez V.

Departamento de Ciencias e Ingeniería de la Computación
Pontificia Universidad Javeriana Cali

29 de enero de 2008

Definiciones básicas 1

Definición

Un alfabeto es un conjunto finito y no vacío de símbolos

Definición

Una cadena (ó palabra) es una secuencia finita de símbolos de un alfabeto. La cadena vacía es aquella que contiene cero símbolos y se denota ϵ . La longitud de una cadena es el número de símbolos que contiene y se denota $|abb| = 3$

Definiciones básicas 2

Definición

Potencias de un alfabeto: dado un alfabeto Σ , el conjunto Σ^k contiene todas las cadenas de longitud k que se pueden formar con símbolos del alfabeto

Notar la diferencia que hay entre Σ y Σ^1

Definición

Se denota Σ^ al conjunto de todas las cadenas que se pueden generar a partir del alfabeto Σ . Es decir, $\Sigma^* = \Sigma^0 \cup \Sigma^1 \cup \Sigma^2 \cup \dots$ por su parte, $\Sigma^+ = \Sigma^1 \cup \Sigma^2 \cup \dots$. En otras palabras, $\Sigma^* = \Sigma^+ \cup \{\epsilon\}$*

Definiciones básicas 3

Definición

Dado un alfabeto Σ , L es un lenguaje sobre Σ si y sólo si $L \subseteq \Sigma^$*

Notar que Σ^* , \emptyset y $\{\varepsilon\}$ son lenguajes que están definidos para cualquier alfabeto. Y notar que $\emptyset \neq \{\varepsilon\}$

Expresiones Regulares

- Son una notación para definir lenguajes
- Se ha demostrado que pueden expresar la clase de los lenguajes regulares
- Permiten hacer una definición algebraica de un lenguaje
- Se expresa el lenguaje de manera declarativa

Aplicaciones de las expresiones regulares

- Búsqueda de archivos en varios comandos de UNIX, por ejemplo grep
- Análisis léxico de un compilador

Operadores de las expresiones regulares

Dadas dos expresiones regulares E_1, E_2 , el resultado de aplicar cualquiera de estas tres operaciones, da como resultado otra expresión regular:

- Unión $(E_1 \cup E_2) = \{x \mid x \in E_1 \text{ ó } x \in E_2 \text{ ó } x \in E_1 \cap E_2\}$.
- Concatenación $E_1 \cdot E_2 = \{xy \mid x \in E_1, y \in E_2\}$
- Clausura o Estrella de Kleene $(E_1^*) = \cup_{i \geq 0} E_1^i$

Lenguaje asociado con una expresión regular

Definición

Casos base: $L(\varepsilon) = \{\varepsilon\}$, $L(\emptyset) = \emptyset$, si $a \in \Sigma$, $L(a) = \{a\}$ Una variable, normalmente representada con una letra mayúscula, por ejemplo L , representa un lenguaje.

Caso general:

- *Si E y F son expresiones regulares, $L(E + F) = L(E) \cup L(F)$*
- *Si E y F son expresiones regulares, $L(EF) = L(E)L(F)$*
- *Si E y F son expresiones regulares, $L(E^*) = (L(E))^*$*
- *Si E y F son expresiones regulares, $L((E)) = L(E)$*

Orden de precedencia de los operadores

Alta	Estrella
	Punto
Baja	Unión

El operador de más alta precedencia elige primero sus argumentos.

Ejemplo: $01^* + 1$ se interpreta como: $(0(1^*)) + 1$

Autómata de Estados Finito

Definición

Un autómata es una 5-tupla de la forma: $\mathcal{A} = \{Q, \Sigma, \delta, I, F\}$ donde:

- *Q es un conjunto de estados.*
- *Σ es un alfabeto de símbolos*
- *δ es una función $Q \times \Sigma \rightarrow 2^Q$*
- *I es un conjunto de estados iniciales que pertenecen a Q*
- *F es un conjunto de estados finales, de aceptación, que pertenecen a Q*

Definición

Si $|I| = 1$ y $\forall q \in Q, a \in \Sigma |\delta(q, a)| \leq 1$, se dice que el autómata es determinista, en caso contrario, se dice que es no determinista.

Lenguaje asociado a un Autómata de Estados Finito

Definición

Sea $\mathcal{A} = \{Q, \Sigma, \delta, I, F\}$, el lenguaje asociado a \mathcal{A} es:

$$L(\mathcal{A}) = \{x \mid \exists q_0 \in I, \delta(q_0, x) \cap F \neq \emptyset\}$$

Bibliografía

Introduction to Automata theory, languages and computation.
Hopcroft J., Motwani R., Ullman J. Segunda Edicion. Adisson
Wesley. 2001.