

Algorithme de décomposition d'un texte en lexèmes.

Inspiration: Partie 2 de Compilation: analyse lexicale et syntaxique

Idee: Reconnaître une suite de lexèmes caractérisés par des expressions rationnelles dans un texte donné.

Exemple: $x + 13 \times y \rightarrow \boxed{\text{id}} \mid \boxed{\text{plus}} \mid \boxed{\text{nombre}} \mid \boxed{\text{mult}} \mid \boxed{\text{id}}$

Soient Σ un alphabet de caractères, et T l'ensemble des types des lexèmes.

Definition 1: Une règle d'analyse lexicale est un couple (e, t) où e est une expression rationnelle sur Σ telle que $e \in L(e)$, et $t \in T$. On notera $e \rightarrow t$.

Problème 1: On cherche à résoudre le problème suivant:

Entrées: $(e_i \rightarrow t_i)_{i \in [1, n]}$ une liste ordonnée de règles.
texte, une chaîne de caractères

Sortie: Liste de lexème décomposant le texte.

Remarque 3: D'après le théorème de Kleene, pour chaque e_i il existe (et on peut construire) un automate fini reconnaissant e_i . De plus, comme les règles sont fixes et que cet algorithme est usuellement utilisé plus d'une fois, on peut supposer posséder des automates A_i reconnaissant e_i obtenus par pré-calcul.

Fonction analyse-lexicale (texte):

Si texte == "" alors

 | Renvoyer []

Sinon

 | (lexeme, nouveau-texte) := premier-lexeme (texte)

 | Renvoyer lexeme :: (analyse-lexicale(nouveau-texte))

Fin si

Fin fonction

Fonction premier-lexeme (texte):

pos-fin-meilleur := -∞

meilleur-type := ⊥

Initialiser l'automate A_i pour i de 1 à n

Pour i de 1 à longueur(texte) faire

 | Pour j allant de 1 à n faire

 | Faire lire à A_j le caractère $\text{texte}[i]$

 | Si A_j est dans un état final faire

 | pos-fin-meilleur := i

 | meilleur-type := type de A_j

 Fin si

 Fin pour

Fin pour

Si indice_meilleur == 1 faire

| Erreur: le texte ne contient aucun préfixe qui
soit un lexème

Fin Si

prefixe := texte[1 : pos_fin_meilleur]

lexeme := (prefixe, type de A indice_meilleur)

Retourner (lexeme, texte[pos_fin_meilleur + 1 :])

Fin fonction

Théorème 4: Dans le pire cas, l'algorithme est
quadratique en la taille du texte.

Preuve: Pour un texte de longueur n , analyse_lexicale
sera appelé au plus n fois, faisant appel à
premier_lexeme qui parcourt dans le pire cas
tout le texte restant. La complexité
est donc de $O(n^2)$.

Exemple 5: $a \rightarrow \text{lexeme-1}$
 $a * b \rightarrow \text{lexeme-2}$ sur le texte a^n .