

Γλώσσες Χωρίς Συμφραζόμενα

Διδάσκοντες: **Φ. Αφράτη, Δ. Φωτάκης**

Επιμέλεια διαφανειών: **Δ. Φωτάκης**

Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών

Εθνικό Μετσόβιο Πολυτεχνείο



Γλώσσα χωρίς Συμφραζόμενα

- Γραμματική χωρίς Συμφραζόμενα:
 - Παραγωγές $P \subseteq (V - T) \times V^*$ ή $A \rightarrow w, w \in V^*$ (μόνο ένα τερματικό σύμβολο στα αριστερά).
 - Κανόνες εφαρμόζονται **ανεξάρτητα** από **συμφραζόμενα** του τερματικού συμβόλου (**context-free**).

- L είναι **γλώσσα χωρίς συμφραζόμενα (ΓΧΣ)** αν παράγεται από γραμματική χωρίς συμφραζόμενα.

$$\begin{array}{l} V = \{0, 1, S\}, \\ T = \{0, 1\}, \\ S \end{array} \quad \begin{array}{l} \text{Παραγωγές } P \\ S \rightarrow 0S1 \\ S \rightarrow \varepsilon \end{array}$$

$$\begin{array}{l} \text{Παραγωγές } P \\ S \rightarrow 0S0 \mid 1S1 \\ S \rightarrow 0 \mid 1 \mid \varepsilon \end{array}$$

Παράδειγμα

- Γραμματική χωρίς συμφραζόμενα $G(V, T, S, P)$:

$$\begin{array}{l} V = \{0, 1, S\}, \\ T = \{0, 1\}, \\ S \end{array} \quad \begin{array}{l} \text{Παραγωγές } P \\ S \rightarrow 0S1 \\ S \rightarrow \varepsilon \end{array}$$

- Γλώσσα $L(G) = \{0^n 1^n : n \geq 0\}$
- Υπάρχουν **γλώσσες χωρίς συμφραζόμενα που δεν είναι κανονικές**.

Παράδειγμα

- Γραμματική χωρίς συμφραζόμενα $G(V, T, S, P)$:

$$\begin{array}{l} V = \{(\, , \,)\, S\}, \\ T = \{(\, , \,)\}, \\ S \end{array} \quad \begin{array}{l} \text{Παραγωγές } P \\ S \rightarrow (S) \mid SS \\ S \rightarrow \varepsilon \end{array}$$

$$L(G) = \{w \in \{(\, , \,)\}^* : w \text{ έχει σωστά "ζυγισμένες" παρενθέσεις}\}$$

Παράδειγμα

- Γραμματική χωρίς συμφραζόμενα για γλώσσα

$$L = \{u \in \{0, 1\}^* : u = ww^R\} \text{ (παλίνδρομα άρτιου μήκους).}$$

$$\begin{array}{c} \text{Παραγωγές } P \\ \hline S \rightarrow 0S0 \mid 1S1 \mid \varepsilon \end{array}$$

- Γραμματική χωρίς συμφραζόμενα για γλώσσα όλων των συμβ/ρών που **δεν** είναι παλινδρομικές.

$$\begin{array}{c} \text{Παραγωγές } P \\ \hline S \rightarrow 0S0 \mid 1S1 \mid A \\ A \rightarrow 1B0 \mid 0B1 \\ B \rightarrow 0B \mid 1B \mid \varepsilon \end{array}$$

Εκφραστικότητα

- Γλώσσες χωρίς συμφραζόμενα περιγράφουν:

- Μικρά υποσύνολα φυσικών γλωσσών.
- Αριθμητικές εκφράσεις.
- **Γλώσσες προγραμματισμού** (C, C++, Pascal, ...).
- Συνήθως σε Backus-Naur form.

$$\begin{array}{c} \text{Παραγωγές } P \\ \hline E \rightarrow O \mid E + O \\ O \rightarrow H \mid O \times H \\ E \end{array} \quad \begin{array}{c} V = \{E, O, H, (,), \times, +, x, y, z, \dots\} \\ T = \{(,), \times, +, x, y, z, \dots\} \\ E \end{array}$$

$$\begin{array}{l} \langle \text{expression} \rangle ::= \langle \text{term} \rangle \mid \langle \text{expression} \rangle + \langle \text{term} \rangle \\ \langle \text{term} \rangle ::= \langle \text{factor} \rangle \mid \langle \text{term} \rangle \times \langle \text{factor} \rangle \\ \langle \text{factor} \rangle ::= (\langle \text{expression} \rangle) \mid x \mid y \mid z \mid \dots \end{array}$$

Κλειστότητα

- Οι γλώσσες χωρίς συμφραζόμενα είναι **κλειστές** ως προς **ένωση και παράθεση** (και Kleene star).

- Έστω ΓΧΣ $G_1(V_1, T_1, S_1, P_1)$ και $L_1 = L(G_1)$.

- Έστω ΓΧΣ $G_2(V_2, T_2, S_2, P_2)$ και $L_2 = L(G_2)$.

Θεωρούμε ότι $(V_1 - T_1) \cap (V_2 - T_2) = \emptyset$

- Ένωση $L_1 \cup L_2$:

- Νέο αρχικό σύμβολο S , δύο νέες παραγωγές $S \rightarrow S_1 \mid S_2$

- $G(V_1 \cup V_2 \cup \{S\}, T_1 \cup T_2, S, P_1 \cup P_2 \cup \{S \rightarrow S_1 \mid S_2\})$

- Παράθεση $L_1 L_2$:

- Νέο αρχικό σύμβολο S , νέα παραγωγή $S \rightarrow S_1 S_2$

- $G(V_1 \cup V_2 \cup \{S\}, T_1 \cup T_2, S, P_1 \cup P_2 \cup \{S \rightarrow S_1 S_2\})$

Κλειστότητα

- Οι γλώσσες χωρίς συμφραζόμενα είναι **κλειστές** ως προς **Kleene star** (και ένωση και παράθεση).

- Έστω ΓΧΣ $G(V, T, S, P)$ και $L = L(G)$.

- Kleene star L^* :

- Νέο αρχικό σύμβολο S' , νέα παραγωγή $S' \rightarrow S' S \mid \varepsilon$

- $G(V \cup \{S'\}, T, S, P \cup \{S' \rightarrow S' S \mid \varepsilon\})$

- Άσκηση: Ν.δ.ο. $L = \{a^i b^j c^k : j = i + k\}$ είναι ΓΧΣ.

- Έστω $L_1 = \{a^i : i \geq 0\}$ και $L_2 = \{b^k c^k : k \geq 0\}$

- $L = L_1 L_2$ (παράθεση των δύο γλωσσών).

Αριστερότερες Παραγωγές

- Έστω $u, v, w \in V^*$ για γραμματική $G(V, T, S, P)$.
- Αν $A \rightarrow w$ παραγωγή, τότε uAv παράγει άμεσα uwv :
 $uAv \Rightarrow uwv$
- u παράγει v , $u \Rightarrow^* v$: αν υπάρχουν $k \geq 0$ και u_1, \dots, u_{k-1} ώστε $u \Rightarrow u_1 \Rightarrow \dots \Rightarrow u_{k-1} \Rightarrow v$ (παραγωγή k βημάτων)
- **Αριστερότερη παραγωγή**: σε κάθε βήμα το αριστερότερο μη-τερματικό σύμβολο αντικαθίσταται.
- Αν $u \Rightarrow^* v$ υπάρχει τουλάχιστον μία αριστερότερη παραγωγή με την οποία το v παράγεται από το u .

Διφορούμενες Γραμματικές

- Αν $u \Rightarrow^* v$ υπάρχει τουλάχιστον μία αριστερότερη παραγωγή με την οποία το v παράγεται από το u .
- Αν για κάποια u, v υπάρχουν δύο ή περισσότερες αριστερότερες παραγωγές, η γραμματική λέγεται **διφορούμενη ή ασαφής**.
- Διφορούμενη γραμματική: $V = \{(\cdot), S\}$, $T = \{(\cdot)\}$, $\frac{\text{Παραγωγές } P}{S \rightarrow (S) \mid SS \mid \epsilon}$
 - Δύο αριστερότερες παραγωγές για (\cdot) .
 $S \Rightarrow (S) \Rightarrow (\cdot)$
 $S \Rightarrow SS \Rightarrow S \Rightarrow (S) \Rightarrow (\cdot)$

Διφορούμενες Γραμματικές

- Διφορούμενες γραμματικές: **συντακτική ανάλυση**;
 - Μετατρέπουμε τη διφορούμενη γραμματική σε **ισοδύναμη μη-διφορούμενη**.
 - Π.χ. $V = \{(\cdot), S\}$, $\frac{\text{Παραγωγές } P}{S \rightarrow (S)S \mid \epsilon}$
 $T = \{(\cdot)\}$
 - **Εγγενώς διφορούμενες** γραμματικές **δεν** μπορούν να μετατραπούν σε μη-διφορούμενες.
 - Γραμματικές **γλωσσών προγραμματισμού** **δεν** είναι διφορούμενες.


Περιοδικότητα ΓΧΣ

- (Άπειρη) κανονική γλώσσα: **μεγάλη** συμβ/ρά οδηγεί DFA σε ίδια κατάσταση («κύκλος»).
 - Επανάληψη τμήματος συμβ/ράς που αντιστοιχεί σε κύκλο οδηγεί σε **τελική** κατάσταση (συμβ/ρά της γλώσσας).
- (Άπειρη) ΓΧΣ L παράγεται από γραμματική $G(V, T, S, P)$.
 - Έστω συμβ/ρά $w = uxyz$: κατά την παραγωγή της εφαρμόζονται δύο διαφορετικές παραγωγές για μη-τερμ. A :
 $S \Rightarrow^* uAx \Rightarrow^* uvAyz \Rightarrow^* uvxyz$ με $A \Rightarrow^* vAy$ και $A \Rightarrow^* x$
 - Γλώσσα **χωρίς συμφραζόμενα**: για κάθε $n \geq 0$, εφαρμογή $1^{\text{ης}}$ n φορές και μετά $2^{\text{ης}}$ δίνει $u^n x y^n z \in L$
 $S \Rightarrow^* uAx \Rightarrow^* uvAyz \Rightarrow^* uv^2Ay^2z \Rightarrow^* \dots \Rightarrow^* u^n x y^n z$

Συντακτικά Δέντρα (parse trees)

- ... απεικονίζει την παραγωγή συμβ/ράς από γραμματική $G(V, T, S, P)$:
 - Ρίζα επιγράφεται με αρχικό σύμβολο S .
 - Κόμβοι επιγράφονται με σύμβολα του V .
 - Ενδιάμεσοι κόμβοι επιγράφονται με **μη-τερματικά**.
 - Φύλλα επιγράφονται με **τερματικά** ή ϵ .
 - (Ενδιάμεσος) κόμβος με επιγραφή A και παράθεση επιγραφών παιδιών του $u \in V^*$: εφαρμογή κανόνα $A \rightarrow u$.
 - Παράθεση επιγραφών φύλλων από αριστερά προς δεξιά δίνει τη συμβ/ρά που παράγεται από συντακτικό δέντρο.

Παράδειγμα




Μεγάλες Συμβολοσειρές

- Γραμματική χωρίς συμφραζόμενα $G(V, \Sigma, S, P)$:
 - **Εύρος $\varphi(G)$** : μέγιστος #συμβόλων σε δεξιά μέλος κανόνα.
 - Κάθε κόμβος συντακτικού δέντρου έχει $\leq \varphi(G)$ παιδιά.
 - Παραγόμενη συμβ/ρά από συντακτικό δέντρο ύψους h έχει μήκος $\leq \varphi(G)^h$.
 - Κάθε συμβ/ρά με μήκος $> \varphi(G)^{|N|}$ παράγεται από συντακτικό δέντρο ύψους $\geq |N| + 1$.
 - $N = V - \Sigma$ σύνολο μη τερματικών, $|N| = \#$ μη τερματικών.
 - Υπάρχει κλάδος με $\geq |N| + 2$ σύμβολα, 1 τερματικό.
 - Υπάρχει κλάδος όπου κάποιο μη-τερματικό σύμβολο εμφανίζεται τουλάχιστον δύο φορές.

Μεγάλες Συμβολοσειρές

- Γραμματική χωρίς συμφραζόμενα $G(V, \Sigma, S, P)$. Κάθε συμβ/ρά w , $|w| > \varphi(G)^{|N|}$ παράγεται από συντακτικό δέντρο με κλάδο όπου κάποιο μη-τερματικό εμφανίζεται τουλάχιστον δύο φορές.
 - Έστω $w = uvxyz$
 - Παραγωγή αναλύεται:
 - $A \Rightarrow^* vAy (T')$
 - $S \Rightarrow^* uAz \Rightarrow^* uvAyx \Rightarrow^* uvxyz$
 - $S \Rightarrow^* uAz \quad A \Rightarrow^* x (T'')$
 - Για κάθε #εφαρμογών 1ης παραγωγής παίρνουμε συμβ/ρά στη γλώσσα $L(G)$.




«Φούσκωμα» Συμβολοσειράς

- Κάθε συμβολοσειρά w , $|w| > \varphi(G)^{|N|}$, γράφεται $w = uvxyz$ ώστε $uv^nxy^nz \in L(G)$ για κάθε $n \geq 0$.

$$S \Rightarrow^* uAz \Rightarrow^* uvAyz \Rightarrow^* uv^2xy^2z = w$$

- $n = 0$: $S \Rightarrow^* uAz \Rightarrow^* uz$
- $n = 1$: εξ' ορισμού.
- $n = 2$: $S \Rightarrow^* uAz \Rightarrow^* uvAyz \Rightarrow^* uv^2xy^2z$
- ... ΚΟΚ.



Θεώρημα Άντλησης (Pumping Lemma)

- Για κάθε γλώσσα L χωρίς συμφραζόμενα, υπάρχει $k \geq 1$ ώστε κάθε $w \in L$, $|w| > k$, γράφεται $w = uvxyz$:
 - για κάθε $n \geq 0$, $uv^nxy^nz \in L$.
 - $|vy| > 0$ (τουλάχιστον ένα από τα v, y μη-κενό).
 - $|uxy| \leq k$
- Απόδειξη:
 - Αποδείξαμε το (1).
 - Για (2), συντακτικό δέντρο με ελάχιστο αριθμό κόμβων.
 - Κάθε κανόνας συνεισφέρει στην τελική συμβολοσειρά.
 - Για (3), θεωρούμε δύο κατώτερες εμφανίσεις A στον αντίστοιχο κλάδο.

Εφαρμογές

- Γλώσσα $L = \{a^n b^k c^n : n \geq 0\}$ δεν είναι χωρίς συμφραζόμενα.
 - Έστω k ο φυσικός αριθμός του λήμματος άντλησης.
 - Θεωρούμε $w = a^k b^k c^k = uvxyz$.
 - Αν vy περιέχει τρία διαφορετικά σύμβολα, στη uv^nxy^nz εμφανίζονται σύμβολα εκτός σειράς.
 - Αν vy περιέχει λιγότερα από τρία διαφορετικά σύμβολα, στη uv^nxy^nz υπάρχει διαφορετικός αριθμός a, b, c .
 - Διαισθητικά, χρειάζονται δύο στοιχεία για την αναγνώριση αυτής της γλώσσας.

Εφαρμογές

- Γλώσσα $L = \{a^n : n \text{ είναι πρώτος}\}$ δεν είναι γλώσσα χωρίς συμφραζόμενα.
 - Θεωρούμε $w = uvxyz$ ώστε $|w|$ πρώτος.
 - Έστω $|vy| = t$ και $|uxz| = r$.
 - Ο αριθμός $r + nt$ δεν είναι πρώτος για κάθε $n \geq 0$. (π.χ. $n = r + t + 1 \Rightarrow (r+t)(t+1)$).
 - Για αλφάβητα ενός συμβόλου, γλώσσες χωρίς συμφραζόμενα είναι κανονικές.

Εφαρμογές

- Ισχύει ότι η τομή μιας γλώσσας χωρίς συμφραζόμενα με μία κανονική γλώσσα είναι γλώσσα χωρίς συμφραζόμενα.
- Γλώσσα $L = \{w \in \{a, b, c\}^* : w \text{ έχει ίσο αριθμό } a, b \text{ και } c\}$ δεν είναι χωρίς συμφραζόμενα.
 - Η γλώσσα $L_1 = \{a^n b^n c^n : n \geq 0\}$ είναι τομή της L με κανονική γλώσσα $a^* b^* c^*$.
 - Αν L ήταν ΓΧΣ, θα ήταν και η L_1 . Άτοπο.

Μη-Κλειστότητα

- Η κλάση των γλωσσών χωρίς συμφραζόμενα **δεν** είναι κλειστή ως προς συμπλήρωμα και τομή.
 - $L_1 = \{a^n b^n c^m : n \geq 0, m \geq 0\}$ χωρίς συμφραζόμενα.
 - $L_2 = \{a^m b^n c^n : m \geq 0, n \geq 0\}$ χωρίς συμφραζόμενα.
 - Τομή $L_1 \cap L_2 = \{a^n b^n c^n : n \geq 0\}$ **δεν** είναι χωρίς συμφραζόμενα.
 - Μη-κλειστότητα ως προς συμπλήρωμα: $L_1 \cap L_2 = \overline{L_1 \cup L_2}$