

Κανονικές Γλώσσες

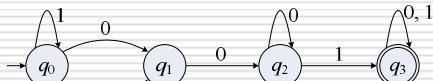
Διδάσκοντες: **Φ. Αφράτη, Δ. Φωτάκης**
Επιμέλεια διαφανειών: **Δ. Φωτάκης**

Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Εθνικό Μετσόβιο Πολυτεχνείο



Κανονικές Γλώσσες και Αυτόματα

- Αν γλώσσα αποφασίζεται από (D)FA, τότε παράγεται από κανονική γραμματική.
 - DFA $M(Q, \Sigma, \delta, s, F)$ και $L = L(M)$.
 - **Κανονική γραμματική G** για την L :
 - $V = Q \cup \Sigma$ (**μη-τερματικά αντιστοιχούν σε καταστάσεις**)
 - $S = s$
 - Παραγωγές $P = \{p \rightarrow \sigma q : \delta(p, \sigma) = q\} \cup \{f \rightarrow \varepsilon : f \in F\}$
 - Με επαγωγή αποδεικνύεται (εύκολα) ότι $L = L(G)$



Κανονικές Γλώσσες

- Κανονική γλώσσα αν παράγεται από κανονική γραμματική.
- Παραγωγές $P \subseteq (V - \Sigma) \times \Sigma^*(V - \Sigma) \cup \varepsilon$
 - Παραγωγές μορφής: $A \rightarrow w \mid wB, w \in \Sigma^*, A, B \in V - \Sigma$
 - 'Ένα μη-τερματικό αριστερά.
 - Στα δεξιά, το πολύ ένα μη-τερματικό στο τέλος.

$$V = \{0, 1, A, B, S\},$$

$$\Sigma = \{0, 1\},$$

$$S$$

$$V' = \{0, 1, S\},$$

$$\Sigma = \{0, 1\},$$

$$S$$

$$\text{Παραγωγές } P_1$$

$$S \rightarrow 1S \mid 0A$$

$$A \rightarrow 1S \mid 0B$$

$$B \rightarrow 1S \mid 0B \mid 0$$

$$\text{Παραγωγές } P_2$$

$$S \rightarrow 1S \mid 1 \mid 0A$$

$$A \rightarrow 1A \mid 0B$$

$$B \rightarrow 1B \mid 0B \mid 0$$

$$\text{Παραγωγές } P_3$$

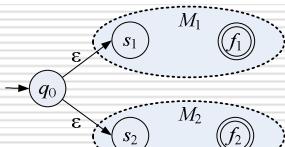
$$S \rightarrow 01S \mid 010S \mid \varepsilon$$

Κανονικές Γλώσσες και Αυτόματα

- Κάθε κανονική γλώσσα αποφασίζεται από (N)FA.
 - Κανονική γραμματική $G(V, \Sigma, S, P)$ που παράγει $L = L(G)$.
 - Χ.β.γ παραγώγες $A \rightarrow \varepsilon \mid \sigma \mid \sigma B, \sigma \in \Sigma, A, B \in V - \Sigma$
 - Μη-ντετερμινιστικό αυτόματο:
 - $Q = (V - \Sigma) \cup \{f\}, s = S, F = \{f\}$
 - Σχέση μετάβασης Δ : $(A, \sigma, B) \in \Delta, \text{ κανόνας } A \rightarrow \sigma B$
 $(A, \sigma, f) \in \Delta, \text{ κανόνας } A \rightarrow \sigma$
 $(A, \varepsilon, f) \in \Delta, \text{ κανόνας } A \rightarrow \varepsilon$
 - Με επαγωγή αποδεικνύεται (εύκολα) ότι $L = L(M)$
- Κλάση κανονικών γλωσσών ταυτίζεται με κλάση γλωσσών που αποφασίζονται από DFA (και NFA).

Κλειστότητα

- Η κλάση των κανονικών γλωσσών είναι **κλειστή** ως προς:
 - Ένωση $L_1 \cup L_2$

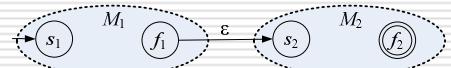


Διακριτά Μαθηματικά (Άνοιξη 2009)

Κανονικές Γλώσσες 5

Κλειστότητα

- Η κλάση των κανονικών γλωσσών είναι **κλειστή** ως προς:
 - Ένωση $L_1 \cup L_2$
 - Παράθεση $L_1 L_2$

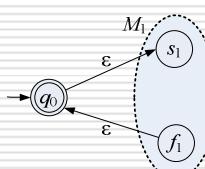


Διακριτά Μαθηματικά (Άνοιξη 2009)

Κανονικές Γλώσσες 6

Κλειστότητα

- Η κλάση των κανονικών γλωσσών είναι **κλειστή** ως προς:
 - Ένωση $L_1 \cup L_2$
 - Παράθεση $L_1 L_2$
 - Kleene star L^*



Διακριτά Μαθηματικά (Άνοιξη 2009)

Κανονικές Γλώσσες 7

Κλειστότητα

- Η κλάση των κανονικών γλωσσών είναι **κλειστή** ως προς:
 - Ένωση $L_1 \cup L_2$
 - Παράθεση $L_1 L_2$
 - Kleene star L^*
 - Συμπλήρωμα
 - DFA και εναλλαγή τελικών – μη τελικών.
 - Τομή $L_1 \cap L_2 = \overline{L_1} \cup \overline{L_2}$

Διακριτά Μαθηματικά (Άνοιξη 2009)

Κανονικές Γλώσσες 8

Κλειστότητα

- Η κλάση των κανονικών γλωσσών είναι **κλειστή** ως προς:
 - Τομή $L_1 \cap L_2$
 - Έστω DFA $M_1(Q_1, \Sigma, \delta_1, s_1, F_1)$ με $L_1 = L(M_1)$ και DFA $M_2(Q_2, \Sigma, \delta_2, s_2, F_2)$ με $L_2 = L(M_2)$.
 - Ορίζουμε DFA $M'(Q', \Sigma, \delta', s', F')$ με $L(M') = L_1 \cap L_2$
 - Καταστάσεις $Q' = Q_1 \times Q_2$
 - Αρχική κατάσταση $s' = (s_1, s_2)$
 - Τελικές καταστάσεις $F' = \{(p, q) : p \in F_1 \text{ και } q \in F_2\}$
 - Συνάρτηση μετάβασης $\delta'((p, q), \sigma) = (\delta_1(p, \sigma), \delta_2(q, \sigma))$
 - Διαφορά $L(M_1) - L(M_2)$
 - Μόνη αλλαγή: Τελικές = $\{(p, q) : p \in F_1 \text{ και } q \notin F_2\}$

Κανονικές Εκφράσεις

- Κανονική έκφραση αλφάβητου Σ :
 1. Το \emptyset και κάθε $\sigma \in \Sigma$ είναι KE.
 2. Αν α και β είναι KE, τότε $(\alpha \cup \beta)$ είναι KE.
 3. Αν α και β είναι KE, τότε $(\alpha \beta)$ είναι KE.
 4. Αν α είναι KE, τότε α^* είναι KE.
 5. Τίποτα άλλο δεν είναι KE.
- Παραδείγματα KE του $\Sigma = \{0, 1\}$: (παραλείπουμε παρενθέσεις)
 - ε γιατί εκφράζεται σαν \emptyset^*
 - $(0 \cup 1)$, $(0 \cup 1)1^*$, $((0 \cup 1)1(0 \cup 1)0)^*$
 - $(10 \cup 01)^* \cup (0001 \cup 1000)^*$, $(1 \cup 1^*)^*$
 - $0^*10^*010^*(10^* \cup \emptyset^*)$

... και Αντίστοιχες Γλώσσες

- Αν α μια KE, $\mathcal{L}(\alpha)$ είναι η αντίστοιχη γλώσσα.
 1. $\mathcal{L}(\emptyset) = \emptyset$, $\mathcal{L}(\sigma) = \{\sigma\}$
 2. $\mathcal{L}((\alpha \cup \beta)) = \mathcal{L}(\alpha) \cup \mathcal{L}(\beta)$
 3. $\mathcal{L}((\alpha\beta)) = \mathcal{L}(\alpha)\mathcal{L}(\beta)$
 4. $\mathcal{L}(\alpha^*) = \mathcal{L}(\alpha)^*$
- Μια γλώσσα μπορεί να αναπαρίσταται από άπειρες κανονικές εκφράσεις.

Παραδείγματα

- Ποια γλώσσα αντιστοιχεί στην KE: $(a \cup b)^*$
$$\begin{aligned}\mathcal{L}((a \cup b)^*) &= \mathcal{L}((a \cup b))^* && (\text{κανόνας 4}) \\ &= (\mathcal{L}(a) \cup \mathcal{L}(b))^* && (\text{κανόνας 2}) \\ &= \{\{a\} \cup \{b\}\}^* && (\text{κανόνας 1}) \\ &= \{a, b\}^*\end{aligned}$$
- Ποια γλώσσα αντιστοιχεί στην KE: $((a \cup b)^*(ba))$
$$\begin{aligned}\mathcal{L}(((a \cup b)^*(ba))) &= \mathcal{L}((a \cup b)^*) \mathcal{L}((ba)) && (\text{κανόνας 3}) \\ &= \mathcal{L}((a \cup b))^* (b \mathcal{L}(b) \mathcal{L}(a)) && (\text{κανόνες 4 και 3}) \\ &= (\mathcal{L}(a) \cup \mathcal{L}(b))^* \{b\} \{a\} && (\text{κανόνες 2 και 1}) \\ &= \{a, b\}^* \{ba\} && (\text{κανόνας 1})\end{aligned}$$

Παραδείγματα

- Ποια γλώσσα αντιστοιχεί στην KE: $(a \cup (ba))^*$

$$\begin{aligned}
 L((a \cup (ba))^*) &= L((a \cup (ba)))^* && (\text{κανόνας 4}) \\
 &= (L(a) \cup L((ba)))^* && (\text{κανόνας 2}) \\
 &= (L(a) \cup (L(b)L(a)))^* && (\text{κανόνας 3}) \\
 &= (\{a\} \cup (\{b\}\{a\}))^* && (\text{κανόνας 1}) \\
 &= \{a, ba\}^*
 \end{aligned}$$

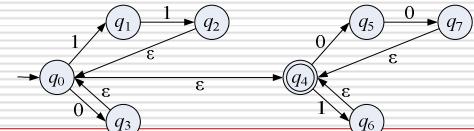
- Κάθε b ακολουθείται από a
(ή δεν περιέχει δύο συνεχόμενα b).
- Γλώσσα $\{ε \cup 1 \cup 11\}(0 \cup 01 \cup 011)^*$
 - Δεν περιέχει 111.

Παραδείγματα

- KE για $L = \{w \in \{a, b\}^* : w$ περιέχει ba και τελειώνει σε $b\}$
 $(a \cup b)^*ba(a \cup b)^*b$
- KE για $L = \{w \in \{0, 1\}^* : w$ περιέχει ξηρό αριθμό 0}
- $(1^*01^*0)^* \cap (1 \cup 01^*0)^*$
- $L = \{w \in \{0, 1\}^* : w$ τελειώνει με 1 και δεν περιέχει 00}
- $(1 \cup 01)(1 \cup 01)^*$
- KE για $L = \{w \in \{0, 1\}^* : w$ περιέχει μία εμφάνιση του 00}
- $(1 \cup 01)^*00(1 \cup 10)^*$
- KE για $L = \{w \in \{0, 1\}^* : w$ δεν περιέχει 110}
- $(0 \cup 10)^*1^*$

Κανονικές Εκφράσεις και Αυτόματα

- Κάθε γλώσσα που αναπαρίσταται από κανονική έκφραση αποφασίζεται από (N)FA (και είναι κανονική).
 - Απόδειξη με επαγωγή στην πολυπλοκότητα της KE.
 - Βάση: ορίζουμε (στοιχειώδη) NFA για \emptyset , $\{\sigma\}$, και $\{\varepsilon\}$.
- $s \xrightarrow{} L = \emptyset$ $s \xrightarrow{} L = \{\varepsilon\}$ $s \xrightarrow{\sigma} f \xrightarrow{} L = \{\sigma\}$
- Βήμα: για ένωση, παράθεση, $*$ βλ. προηγούμενες κατασκευές.
- Παράδειγμα: Γλώσσα $(11 \cup 0)^*(00 \cup 1)^*$



Κανονικές Εκφράσεις και Αυτόματα

- Κάθε κανονική γλώσσα (που αποφασίζεται από (D)FA) αναπαρίσταται από κανονική έκφραση.
 - Αλγόριθμος δυναμικού προγραμματισμού (παρόμοιος με αλγόριθμο Warshall) παράγει κανονική έκφραση από περιγραφή DFA.
- Τα παρακάτω είναι ισοδύναμα:
 - Μια γλώσσα παράγεται από κανονική γραμματική.
 - Μια γλώσσα αναπαρίσταται από κανονική έκφραση.
 - Μια γλώσσα αποφασίζεται από DFA
 - Μια γλώσσα αποφασίζεται από NFA.

KE και DFA

- Κάθε γλώσσα που γίνεται δεκτή από DFA αναπαρίσταται από κανονική έκφραση.
 - Έστω $M(Q, \Sigma, \delta, s, F)$ με $Q = \{q_1, \dots, q_n\}$ και $s = q_1$.
 - Θα ορίσουμε κανονική έκφραση R : $L(R) = L(M)$.
 - Για κάθε $i, j = 1, \dots, n$ και $k = 0, \dots, n$, ορίζουμε

$R^{[k]}(i, j) = \text{σύνολο συμβ/ρών } \Sigma^* \text{ που οδηγούν } M \text{ από } q_i \text{ σε } q_j$
χωρίς να περνάνει πιο ενδιάμεση κατάσταση με δεύτερη > k
Αρχική q_i και τελική q_j μαρούν να έχουν δεύτερη > k

$$R^{[0]}(i, j) = \{w \in \Sigma^* : (q_i, w) \vdash_M^* (q_j, \epsilon)\}$$

$$L(M) = \bigcup \{R^{[k]}(1, j) : q_j \in F\}$$

- Av $R^{[k]}(i, j)$ αναπαρίστανται από κανονικές εκφράσεις, $L(M)$ αναπαρίσταται από κανονική έκφραση (ένωση).

Παρατηρήσεις

- Κάθε πεπερασμένη γλώσσα είναι κανονική.
 - Απόδειξη (έύκολη) με επαγωγή στον #συμβ/ρών.
- Κανονική γλώσσα που αναπαρίσταται από KE χωρίς *
(ισοδύναμα από DFA χωρίς «κύκλο»);
 - Είναι πεπερασμένη.
 - Ο τελεστής * (ισοδύναμα, ο κύκλος στο DFA)
μοναδικός τρόπος δημιουργίας άπειρου πλήθους συμβ/ρών.

KE και DFA

- $R^{[k]}(i, j)$ με κανονικές εκφράσεις: επαγωγή στο k .

$$R^{[0]}(i, j) = \begin{cases} \{\sigma \in \Sigma : \delta(q_i, \sigma) = q_j\} & \text{αν } i \neq j \\ \{\epsilon\} \cup \{\sigma \in \Sigma : \delta(q_i, \sigma) = q_i\} & \text{αν } i = j \end{cases}$$

$$R^{[k]}(i, j) = R^{[k-1]}(i, j) \cup R^{[k-1]}(i, k) \cdot R^{[k-1]}(k, k) \cdot R^{[k-1]}(k, j)$$

- Επίσης βλ. αλγόριθμο Floyd-Warshall για συντομότερα μονοπάτια και μεταβατική κλειστότητα.

- Δυναμικός προγραμματισμός (bottom-up):

- Συνδυάζουμε γλώσσες που αποδέχονται περιορισμένα τμήματα του αυτομάτου για να βρούμε γλώσσα που αποδέχεται όλο το αυτόματο.

Δύο Χαρακτηριστικά Κανονικών Γλωσσών

- Η μνήμη για αναγνώριση συμβ/ράς κανονικής γλώσσας εξαρτάται από γλώσσα αλλά όχι συμβολοσειρά.
 - Ένδειξη ότι $\{1^n0^n : n \geq 0\}$ δεν είναι κανονική.
- Άπειρες κανονικές γλώσσες: DFA με κύκλους.
 - Απλή επαναληπτική δομή / περιοδικότητα.
 - Ένδειξη ότι $\{1^n : n \text{ πρώτος}\}$ δεν είναι κανονική.
- Ανάγκη (μαθηματικού) εργαλείου για απόδειξη ότι γλώσσα είναι μη κανονική.

Λήμμα Άντλησης (Pumping Lemma)

- Έστω L μια άπειρη κανονική γλώσσα. Υπάρχει $k \geq 1$ τ.ω. κάθε $w \in L$, $|w| \geq k$, γράφεται $w = xyz$, $y \neq \epsilon$, $|xy| \leq k$, και $xy^n z \in L$ για κάθε $n \geq 0$.
 - DFA $M(Q, \Sigma, \delta, s, F)$ με k καταστάσεις που αποφασίζει L .
 - Έστω $w \in L : |w| = \ell \geq k$. Υπολογισμός $M(w)$:
 $(q_0, w_1 w_2 \dots w_\ell) \vdash_M (q_1, w_2 \dots w_\ell) \vdash_M \dots \vdash_M (q_\ell, \epsilon)$
 - ... διέρχεται από **iδια** κατάσταση του λάχιστον 2 φορές. Υπάρχουν $0 \leq i < j \leq k$, ώστε $q_i = q_j$.
 - Έστω $x = w_1 \dots w_i, y = w_{i+1} \dots w_j, z = w_{j+1} \dots w_\ell$
 - M δέχεται $xy^n z : x$ οδηγεί M στην q_j , y^n κάνει η κύκλους με αφετηρία και κατάληξη q_j , και z οδηγεί M σε **τελική**.

Μη Κανονικότητα Γλωσσών

- N.δ.o. $L = \{0^n 1^n : n \geq 0\}$ **δεν είναι κανονική**.
 - L άπειρη. Άρα αν είναι κανονική, ισχύει το Λ. Άντλησης.
 - Av L κανονική, υπάρχει $k > 0$, τ.ω. για κάθε $w \in L$, $|w| \geq k$, υπάρχουν x, y, z συμ/ρές, $w = xyz$, $|xy| \leq k$, $y \neq \epsilon$, και $x y^n z \in L$ για κάθε $n \geq 0$.
 - Πρέπει $x y z \in L$ ($n = 1$).
 - Av y αποτελείται μόνο από 0, $x y^0 z \notin L$ (ποιο πολλά 1).
 - Av y αποτελείται μόνο από 1, $x y^0 z \notin L$ (ποιο πολλά 0).
 - Av y αποτελείται από 0 ακολουθούμενα από 1, $x y^2 z \notin L$ (γιατί $0^{+1+0+1^+} \dots$).
 - Άρα L δεν είναι κανονική.

Μη Κανονικότητα Γλωσσών

- N.δ.o. $L = \{1^n : n$ πρώτος} **δεν είναι κανονική**.
 - L άπειρη. Άρα αν είναι κανονική, ισχύει το Θ. Άντλησης.
 - Av L κανονική, υπάρχουν x, y, z συμ/ρές, $y \neq \epsilon$, ώστε $x y^n z \in L$ για κάθε $n \geq 0$.
 - Δηλαδή $|x| + n|y| + |z|$ πρώτος.
 - **Δεν** ισχύει για $n = |x| + 2|y| + |z| + 2$, αφού:
 $|x| + (|x| + 2|y| + |z| + 2)|y| + |z| = (|x| + 2|y| + |z|)(|y| + 1)$
που δεν είναι πρώτος!
 - L **δεν είναι κανονική**.

Μη Κανονικότητα Γλωσσών

- N.δ.o. $L = \{w \in \{0, 1\}^*: w$ έχει **iδιο αριθμό 0 και 1**} **δεν είναι κανονική**.
 - $L \cap 0^* 1^* = \{0^n 1^n : n \geq 0\}$, που **δεν είναι κανονική**.
 - $0^* 1^*$ κανονική.
 - Κανονικές γλώσσες **κλειστές** ως προς **τομή**.
 - Άρα L **δεν είναι κανονική**.