

Κανονικές Γλώσσες

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

Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών

Εθνικό Μετσόβιο Πολυτεχνείο



Κανονικές Γλώσσες

- Κανονική γλώσσα αν παράγεται από κανονική γραμματική.
- Παραγωγές $P \subseteq (V - \Sigma) \times \Sigma^*((V - \Sigma) \cup \epsilon)$
 - 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

Παραγωγές P_1

$$\begin{array}{c|c} S \rightarrow 1S & 0A \\ A \rightarrow 1S & 0B \\ B \rightarrow 1S & 0B | 0 \end{array}$$

Παραγωγές P_2

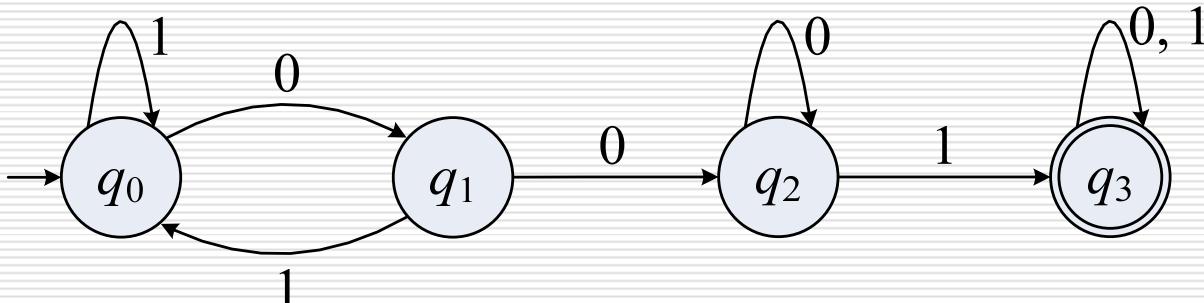
$$\begin{array}{c|c|c} S \rightarrow 1S & 1 & 0A \\ A \rightarrow 1A & 0B \\ B \rightarrow 1B & 0S & 0 \end{array}$$

Παραγωγές P_3

$$S \rightarrow 01S \mid 010S \mid \epsilon$$

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 $L = L(G)$

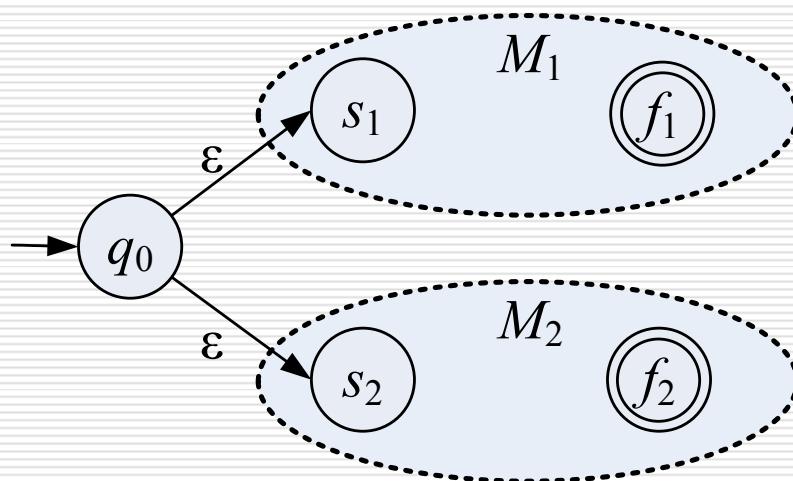


Κανονικές Γλώσσες και Αυτόματα

- Κάθε κανονική γλώσσα αποφασίζεται από (N)FA.
 - Κανονική γραμματική $G(V, \Sigma, S, P)$ που παράγει $L = L(G)$.
 - X.β.γ παραγωγές $A \rightarrow \varepsilon \mid \sigma \mid \sigma B$, $\sigma \in \Sigma, A, B \in V - \Sigma$
 - Μη-ντετερμινιστικό αυτόματο:
 - $Q = (V - \Sigma) \cup \{f\}$, $s = S$, $F = \{f\}$
 - Σχέση μετάβασης Δ : $(A, \sigma, B) \in \Delta$, κανόνας $A \rightarrow \sigma B$
 $(A, \sigma, f) \in \Delta$, κανόνας $A \rightarrow \sigma$
 $(A, \varepsilon, f) \in \Delta$, 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).

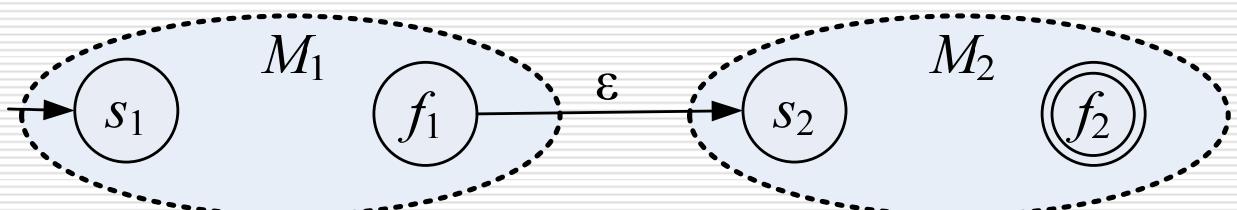
Κλειστότητα

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



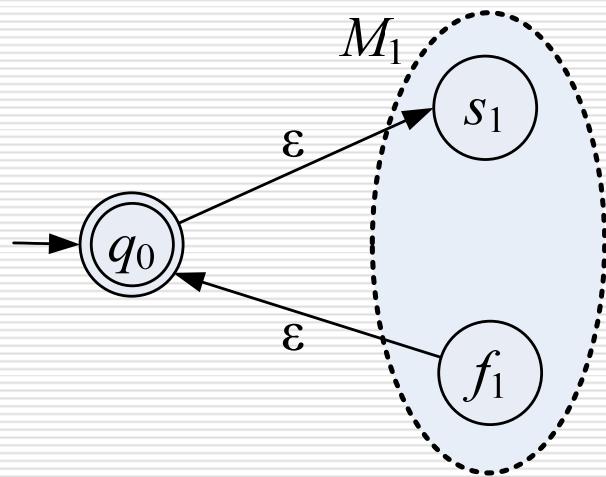
Κλειστότητα

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



Κλειστότητα

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



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 $L_1 \cap L_2 = \overline{\overline{L}_1} \cup \overline{L_2}$

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 ΚΕ, $\mathcal{L}(\alpha)$ 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. $\mathcal{L}(\alpha^*) = \mathcal{L}(\alpha)^*$
- Αναπαράσταση μιας γλώσσα με κανονική έκφραση δεν είναι κατ' ανάγκη μοναδική.
 - 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: $((a \cup b)^*(ba))$

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

Παραδείγματα

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

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

- Κάθε b ακολουθείται από a
(ή δεν περιέχει δύο συνεχόμενα b).

- Γλώσσα $(\varepsilon \cup 1 \cup 11)(0 \cup 01 \cup 011)^*$
- Δεν περιέχει 111.

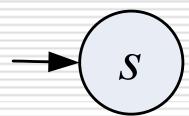
Παραδείγματα

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

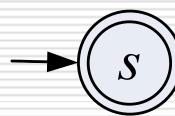
Κανονικές Εκφράσεις και Αυτόματα

- Κάθε γλώσσα που αναπαρίσταται από κανονική έκφραση αποφασίζεται από (N)FA (και είναι κανονική).

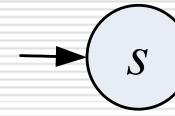
- Απόδειξη με επαγωγή στην πολυπλοκότητα της KE.
- Βάση: ορίζουμε (οτοιχειώδη) NFA για \emptyset , $\{\sigma\}$, και $\{\varepsilon\}$.



$$L = \emptyset$$

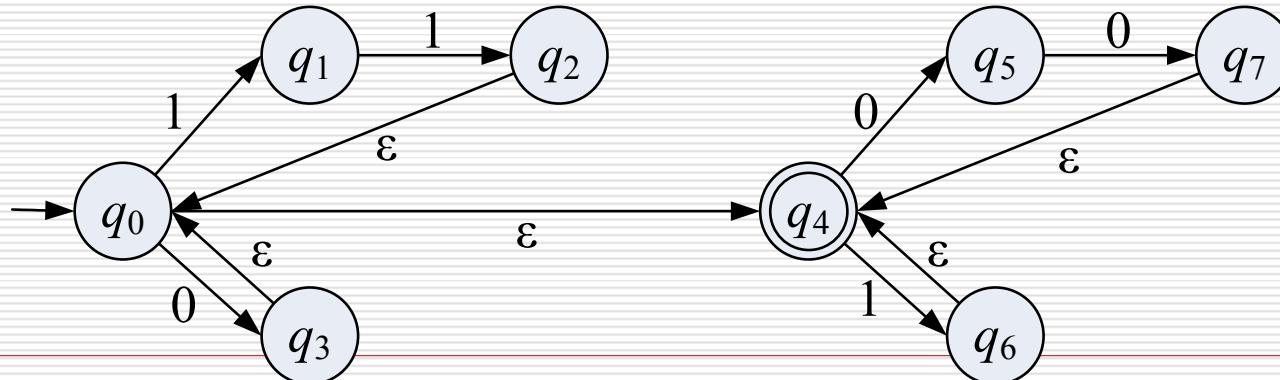


$$L = \{\varepsilon\}$$



$$L = \{\sigma\}$$

- Βήμα: για ένωση, παράθεση, $*$ βλ. προηγούμενες κατασκευές.
- Παράδειγμα: Γλώσσα $(11 \cup 0)^*(00 \cup 1)^*$



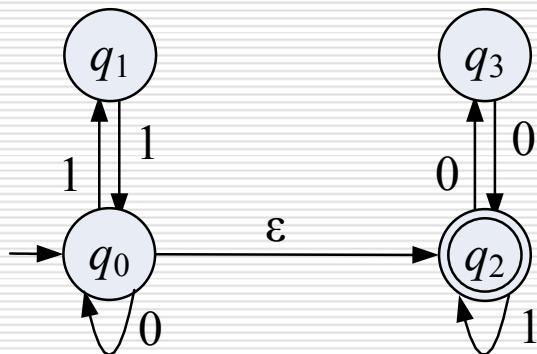
Kanovikés Eκφράσεις και Αυτόμata

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

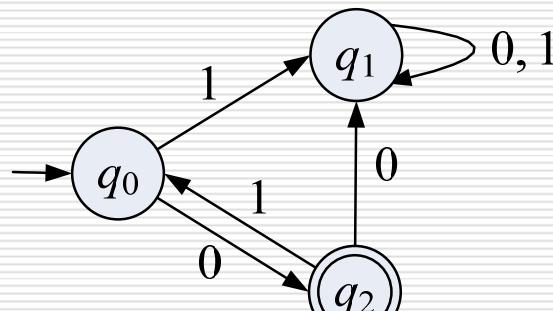
Κανονικές Εκφράσεις και Αυτόματα

- Κανονικές Εκφράσεις για γλώσσες που αναγνωρίζονται από παρακάτω αυτόματα.

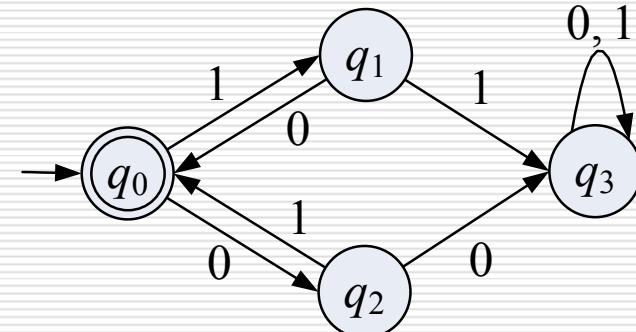
$(11 \cup 0)^*(00 \cup 1)^*$



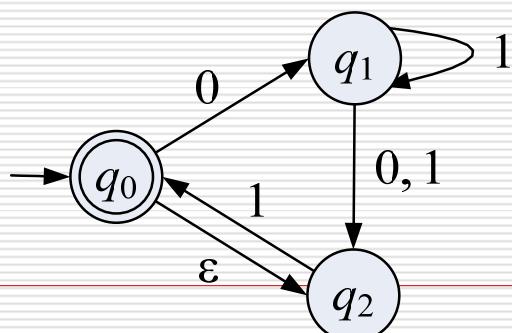
$0(10)^*$



$(10 \cup 01)^*$



$(01^*(0 \cup 1)1 \cup 1)^*$



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 $R^{[k]}(i, j) =$ σύνολο συμβ/ρών Σ^* που οδηγούν M από q_i σε q_j χωρίς να περάσει από ενδιάμεση κατάσταση με δείκτη $> k$. Αρχική q_i και τελική q_j μπορούν να έχουν δείκτη $> k$
$$R^{[n]}(i, j) = \{w \in \Sigma^* : (q_i, w) \vdash_M^* (q_j, \varepsilon)\}$$
$$L(M) = \bigcup \{R^{[n]}(1, j) : q_j \in F\}$$
 - Άν $R^{[k]}(i, j)$ αναπαρίστανται από κανονικές εκφράσεις, $L(M)$ αναπαρίσταται από κανονική έκφραση (ένωση).

ΚΕ και DFA

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

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

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

- 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.

Παρατηρήσεις

- Κάθε πεπερασμένη γλώσσα είναι κανονική.
 - Απόδειξη (εύκολη) 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.

Δύο Χαρακτηριστικά Κανονικών Γλώσσων

- Η μνήμη για αναγνώριση συμβ/ράς κανονικής γλώσσας εξαρτάται από γλώσσα **αλλά όχι** συμβολοσειρά.
 - 'Ενδειξη ότι $\{ 1^n 0^n : n \geq 0 \}$ **δεν** είναι κανονική.
- Άπειρες κανονικές γλώσσες: DFA με **κύκλους**.
 - Απλή επαναληπτική δομή / περιοδικότητα.
 - 'Ενδειξη 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 **ιδια** κατάσταση **τουλάχιστον 2 φορές**.
Υπάρχουν $0 \leq i < j \leq k$, ώστε $q_i = q_j$.
 - Έστω $x = w_1 \dots w_i$, $y = w_{i+1} \dots w_j$, $z = w_{j+1} \dots w_\ell$
 - Μ δέχεται $xy^n z$: x οδηγεί M στην q_i , y^n κάνει n κύκλους με
αφετηρία και κατάληξη q_i , και z οδηγεί M σε **τελική**.

Μη Κανονικότητα Γλωσσών

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

Μη Κανονικότητα Γλωσσών

- Ν.δ.ο. $L = \{1^n : n \text{ πρώτος}\}$ **δεν είναι κανονική.**
 - L άπειρη. Άρα αν είναι κανονική, ισχύει το Θ. Άντλησης.
 - Αν L κανονική, υπάρχουν x, y, z συμ/ρές, $y \neq \varepsilon$, ώστε $xy^n z \in L$ για κάθε $n \geq 0$.
 - Δηλαδή $|x| + n|y| + |z|$ **πρώτος** για κάθε $n \geq 0$.
 - **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

- Ν.δ.ο. $L = \{w \in \{0, 1\}^*: w \text{ έχει ίδιο αριθμό } 0 \text{ και } 1\}$
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**.