

# Γλώσσες

---

### 1. ΑΛΦΑΒΗΤΑ

Ας είναι  $X$  ένα πεπερασμένο σύνολο, το *αλφάβητό* μας. Τα στοιχεία του  $X$  θα τα ονομάζουμε *γράμματα*. Αν γράψουμε κάποια γράμματα του  $X$  το ένα δίπλα στο άλλο σχηματίζουμε μια *λέξη* από το  $X$ .

Ας πάρουμε για παράδειγμα το ελληνικό αλφάβητο

$$X = \{\alpha, \dots, \omega\}.$$

Τότε, οι

ψωμι, πεπονι, υπονομος

είναι μερικές λέξεις που μπορούμε να σχηματίσουμε.

Επίσης, αν πάρουμε το αλφάβητο του Morse

$$X = \{-, \cdot, | \}$$

τότε τα σήματα Morse δεν είναι παρά λέξεις από το παραπάνω αλφάβητο.

Γενικά λοιπόν, αν  $X$  είναι ένα οποιοδήποτε αλφάβητο, μια λέξη από το  $X$  είναι μια πεπερασμένη ακολουθία γραμμάτων του  $X$ :

$$x_1 \cdots x_n$$

Δύο λέξεις

$$x_1 \cdots x_m \text{ και } y_1 \cdots y_n$$

είναι *ίσες*, αν

$$m = n \text{ και } x_k = y_k, \quad k = 1, \dots, m.$$

Στη θεωρία που θ' αναπτύξουμε παρακάτω είναι απαραίτητο να εισάγουμε την *κενή* λέξη, δηλαδή τη λέξη χωρίς γράμματα. Τη λέξη αυτή τη συμβολίζουμε με το ελληνικό γράμμα  $\varepsilon$ .

Τώρα, το σύνολο όλων των λέξεων που μπορούμε να σχηματίσουμε από ένα αλφάβητο  $X$ , το συμβολίζουμε  $X^*$ , δηλαδή

$$X^* = \{\varepsilon\} \cup \{x_1 \cdots x_n \mid x_k \in X, \quad k = 1, 2, \dots\}.$$

☞ **Παράδειγμα 1.1.** Ας πάρουμε ένα αλφάβητο που ν' αποτελείται από δύο μόνο γράμματα:

$$X = \{a, b\}.$$

Τότε οι

$$aaba, bba, aa, ababa, b$$

είναι μερικές λέξεις που μπορούμε να σχηματίσουμε απ' αυτό. □

☞ **Παράδειγμα 1.2.** Ας πάρουμε τώρα το φτωχότερο αλφάβητο που μπορούμε να φανταστούμε, δηλαδή το αλφάβητο με ένα μόνο γράμμα!

$$X = \{a\}.$$


Τότε οι

$$\varepsilon, a, aa, aaa, \dots$$

είναι όλες οι λέξεις που μπορούμε να σχηματίσουμε από το  $X$ , δηλαδή

$$X^* = \{a\}^* = \{\varepsilon, a, aa, aaa, \dots\}.$$
□

☞ **Παράδειγμα 1.3.** Μερικές φορές για να παριστάνουμε τις λέξεις του  $X^*$  χρησιμοποιούμε ένα “δέντρο”, όπως αυτό που δίνουμε παρακάτω για  $X = \{0, 1\}$ :



□

☞ **Παράδειγμα 1.4.** Όπως γνωρίζουμε από τη στοιχειώδη Θεωρία Αριθμών, κάθε μη μηδενικός φυσικός αριθμός  $n$  γράφεται κατά μοναδικό τρόπο με τη μορφή

$$n = a_0 \cdot 10^k + a_1 \cdot 10^{k-1} + \dots + a_{k-1} \cdot 10 + a_k,$$

όπου

$$0 \leq a_j < 10, \quad j = 0, \dots, k \quad \text{και} \quad a_0 > 0.$$

Η λέξη

$$a_0 a_1 \dots a_{k-1} a_k$$


που σχηματίζεται από τους παραπάνω συντελεστές ονομάζεται *παράσταση του  $n$  στο δεκαδικό σύστημα* και συμβολίζεται  $[n]_{10}$ , δηλαδή

$$[n]_{10} = a_0 a_1 \dots a_{k-1} a_k.$$

Οι φυσικοί λοιπόν αριθμοί μπορούν να παρασταθούν από λέξεις του αλφαβήτου

$$X = \{0, 1, 2, \dots, 9\}.$$

□

 **Παράδειγμα 1.5.** Κάθε μη μηδενικός φυσικός αριθμός  $n$  γράφεται κατά μοναδικό τρόπο με τη μορφή

$$n = a_0 \cdot 2^k + a_1 \cdot 2^{k-1} + \dots + a_{k-1} \cdot 2 + a_k,$$

όπου

$$a_0 = 1, \quad 0 \leq a_j < 2, \quad j = 1, \dots, k.$$

Η λέξη

$$a_0 a_1 \dots a_{k-1} a_k$$

ονομάζεται *παράσταση του  $n$  στο δυαδικό σύστημα* και συμβολίζεται  $[n]_2$ , δηλαδή

$$[n]_2 = a_0 a_1 \dots a_{k-1} a_k.$$

Κάθε φυσικός αριθμός λοιπόν, μπορεί να παρασταθεί από μια λέξη που σχηματίζεται από μηδενικά και μονάδες, δηλαδή από μια λέξη του αλφαβήτου  $X = \{0, 1\}$ . Για παράδειγμα αν  $n = 2^k$ , τότε

$$[2^k]_2 = \underbrace{10\dots 0}_k$$

διότι

$$2^k = 1 \cdot 2^k + 0 \cdot 2^{k-1} + \dots + 0 \cdot 2 + 0.$$

□

Αν

$$u = x_1 \cdots x_m, \quad v = y_1 \cdots y_n$$

είναι δύο λέξεις με γράμματα από ένα αλφάβητο  $X$ , τότε μπορούμε να δημιουργήσουμε μια νέα λέξη αν γράψουμε την  $v$  δεξιά της  $u$ :

$$x_1 \cdots x_m y_1 \cdots y_n$$


Η πράξη αυτή λέγεται *παράθεση* λέξεων. Για παράδειγμα αν  $X = \{a, b\}$  και

$$u = aa, \quad v = bbb,$$

τότε

$$uv = aabbb \quad \text{ενώ} \quad vu = bbaaa.$$

Παρατηρούμε ότι  $uv \neq vu$ .

 **Πρόταση 1.1.** Η παράθεση είναι πράξη προσεταιριστική, δηλαδή για κάθε  $\rho, \vartheta, \varphi \in X^*$  έχουμε

$$(\rho\vartheta)\varphi = \rho(\vartheta\varphi).$$


**Απόδειξη.** Ας είναι

$$\rho = x_1 \cdots x_p, \quad \vartheta = y_1 \cdots y_q, \quad \varphi = z_1 \cdots z_s$$

Τότε,

$$\begin{aligned} (\rho\vartheta)\varphi &= (x_1 \cdots x_p y_1 \cdots y_q) z_1 \cdots z_s = x_1 \cdots x_p y_1 \cdots y_q z_1 \cdots z_s = \\ &= x_1 \cdots x_p (y_1 \cdots y_q z_1 \cdots z_s) = \rho(\vartheta\varphi) \end{aligned}$$

□

 **Πρόταση 1.2.** Για κάθε λέξη  $\eta \in X^*$  έχουμε  $\eta\varepsilon = \eta = \varepsilon\eta$ , όπου  $\varepsilon$  είναι η κενή λέξη.

**Απόδειξη.** Φανερή.

□


Λίγο αργότερα θα δούμε την αλγεβρική σημασία των παραπάνω. Τώρα μας χρειάζεται ο ακόλουθος



**Ορισμός 1.1.** Ονομάζουμε *μήκος* μιας λέξης  $w$  και το συμβολίζουμε με  $|w|$ , το πλήθος των γραμμάτων που την απαρτίζουν.

Έτσι, τα μήκη των λέξεων  $aaba$ ,  $bba$ ,  $b$  που είδαμε στο παράδειγμα 1.1, είναι αντίστοιχα 4, 3 και 1, δηλαδή

$$|aaba|=4, \quad |bba|=3, \quad |b|=1.$$

 **Πρόταση 1.3.** Ισχύουν οι ισότητες

$$|\varepsilon|=0,$$

$$|uv|=|u|+|v|,$$

για κάθε  $u, v \in X^*$ , δηλαδή το μήκος της κενής λέξης είναι μηδέν, αφού στερείται γραμμάτων, και το μήκος της λέξης  $uv$  που προκύπτει από την παράθεση των  $u$  και  $v$  ισούται με το άθροισμα των μηκών των  $u$  και  $v$ .

**Απόδειξη.** Φανερή. □

Για παράδειγμα, αν  $X = \{a, b, c\}$  και

$$u = aabb, \quad v = ccc,$$

οπότε

$$uv = aabbccc,$$

θα έχουμε

$$|u|=4, \quad |v|=3, \quad |uv|=7,$$

δηλαδή

$$|uv|=|u|+|v|.$$

Σε κάθε λέξη από το αλφάβητο  $X$

$$w = x_1 \cdots x_n$$


αντιστοιχεί η λέξη

$$w^p = x_n \cdots x_1$$

που προκύπτει από τη  $w$  αντιστρέφοντας τη σειρά των γραμμάτων της. Η  $w^p$  ονομάζεται *είδωλο* της λέξης  $w$ . Για παράδειγμα το είδωλο της λέξης  $abb$  είναι η λέξη  $bba$ . Αν μια λέξη συμπίπτει με

το είδωλό της, την ονομάζουμε *παλινδρομική*. Π.χ. οι λέξεις *aba*, *baab* είναι παλινδρομικές, όπως αμέσως διαπιστώνεται.

Ισχύει η επόμενη

 **Πρόταση 1.4.** Για κάθε  $u, v \in X^*$  έχουμε  $(uv)^\rho = v^\rho u^\rho$ .

**Απόδειξη.** Αν

$$u = x_1 \cdots x_m, \quad v = y_1 \cdots y_n$$


τότε

$$(uv)^\rho = (x_1 \cdots x_m y_1 \cdots y_n)^\rho = y_n \cdots y_1 x_m \cdots x_1 = v^\rho u^\rho.$$

□

Για κάθε λέξη  $w \in X^*$  μπορούμε να ορίσουμε τη  $n$ -οστή *δύναμή της* επαγωγικά ως εξής:

$$\begin{aligned} w^0 &= \varepsilon \\ w^1 &= w \\ w^2 &= w w \\ &\vdots \\ w^{n+1} &= w^n w. \end{aligned}$$

 **Πρόταση 1.5.** Ισχύουν οι επόμενοι κανόνες:

$$u^m u^n = u^{m+n}, \quad (u^m)^n = u^{m \cdot n}$$

για κάθε λέξη  $u \in X^*$ .

**Απόδειξη.** Θ' αποδείξουμε μόνο την πρώτη ισότητα με χρήση επαγωγής επάνω στο  $n$ . Για  $n=0$  η ισότητα ισχύει φανερά, διότι

$$u^m u^0 = u^m \varepsilon = u^m = u^{m+0}.$$

Ας υποθέσουμε ότι η πρότασή μας ισχύει και για το φυσικό αριθμό  $n$ , δηλαδή ότι

$$u^m u^n = u^{m+n}.$$

Θα δείξουμε ότι ισχύει και για τον  $n+1$ :

$$u^m u^{n+1} = u^m (u^n u) \stackrel{(1)}{=} (u^m u^n) u \stackrel{(2)}{=} u^{m+n} u = u^{m+n+1},$$

όπου η ισότητα (1) προέκυψε από την προσεταιριστική ιδιότητα της παράθεσης, ενώ η ισότητα (2) από την υπόθεση της επαγωγής

□

Η χρήση των δυνάμεων βοηθά στην απλοποίηση της γραφής. Έτσι, αν για παράδειγμα διαθέτουμε το αλφάβητο  $X = \{a, b, c\}$ , τότε τη λέξη

aaabbccccc

μπορούμε να τη γράψουμε απλά

$$a^3 b^2 c^4 a^2$$

και τη λέξη

bbbbbbcccc

να τη γράψουμε απλά

$$b^7 c^5.$$

~~Π~~ **Πρόταση 1.6.** Για κάθε λέξη  $w \in X^*$  και για κάθε φυσικό αριθμό  $n$  ισχύει

$$|w^n| = n \cdot |w|.$$

**Απόδειξη.** Είναι

$$|w^n| = \underbrace{|w \cdots w|}_n = \underbrace{|w| + \dots + |w|}_n = n \cdot |w|,$$

όπως το θέλαμε.

□

## 2. ΓΛΩΣΣΕΣ

Ας είναι  $X$  ένα αλφάβητο. Ένα οποιοδήποτε υποσύνολο του  $X^*$  ονομάζεται *γλώσσα*. Αφού λοιπόν οι γλώσσες από το  $X$  είναι υποσύνολα του  $X^*$ , μπορούμε να μιλάμε για την *ένωση*, την *τομή* τους, κ.λ.π.

Αν  $L_1, L_2 \subseteq X^*$  είναι δύο γλώσσες, τότε μπορούμε να δημιουργήσουμε μια νέα γλώσσα αν παραθέσουμε κάθε λέξη της  $L_1$  δίπλα σε κάθε λέξη της  $L_2$ . Τη γλώσσα που έτσι σχηματίζεται ονομάζουμε *παράθεση* των  $L_1, L_2$  και τη συμβολίζουμε  $L_1 L_2$ , δηλαδή

$$L_1L_2 = \{uw \mid u \in L_1, w \in L_2\}.$$

☞ **Παράδειγμα 2.1.** Ας είναι  $X = \{a, b, c\}$  και ας θεωρήσουμε τις γλώσσες

$$L_1 = \{ab, ba\}, \quad L_2 = \{ac, ca\}.$$

Τότε

$$L_1L_2 = \{abac, abca, baac, bacca\}.$$

□

☞ **Παράδειγμα 2.2.** Ας είναι  $X = \{a, b\}$  και ας πάρουμε τις γλώσσες

$$L_1 = \{a, a^3, a^5, \dots\}, \quad L_2 = \{b\}.$$

Τότε

$$L_1L_2 = \{ab, a^3b, a^5b, \dots\}$$

ενώ

$$L_2L_1 = \{ba, ba^3, ba^5, \dots\}.$$

□

Δύο βασικές ιδιότητες που έχει η παράθεση γλωσσών είναι ο προσεταιρισμός και ο επιμερισμός ως προς την ένωση.

☞ **Πρόταση 2.1.** Αν  $L_k \subseteq X^*$ ,  $k = 1, 2, 3$ , είναι τρεις οποιεσδήποτε γλώσσες, τότε

$$L_1(L_2L_3) = (L_1L_2)L_3,$$

$$L_1(L_2 \cup L_3) = L_1L_2 \cup L_1L_3,$$

$$(L_1 \cup L_2)L_3 = L_1L_3 \cup L_2L_3.$$

**Απόδειξη.** Για την πρώτη έχουμε:



$$\begin{aligned} L_1(L_2L_3) &= \{u(vw) \mid u \in L_1, v \in L_2, w \in L_3\} = \\ &= \{(uv)w \mid u \in L_1, v \in L_2, w \in L_3\} = (L_1L_2)L_3 \end{aligned}$$

Ας πάρουμε τώρα τη δεύτερη:

$$\begin{aligned} uw \in L_1(L_2 \cup L_3) &\Leftrightarrow \{u \in L_1 \wedge w \in (L_2 \cup L_3)\} \Leftrightarrow \\ &\Leftrightarrow \{u \in L_1 \wedge (w \in L_2 \vee w \in L_3)\} \Leftrightarrow \\ &\Leftrightarrow \{(u \in L_1 \wedge w \in L_2) \vee (u \in L_1 \wedge w \in L_3)\} \Leftrightarrow \\ &\Leftrightarrow \{uw \in L_1L_2 \vee uw \in L_1L_3\} \Leftrightarrow uw \in L_1L_2 \cup L_1L_3 \end{aligned}$$

δηλαδή

$$L_1(L_2 \cup L_3) = L_1L_2 \cup L_1L_3.$$

Όμοια εργαζόμαστε και για την τρίτη. □

Μπορούμε τώρα να ορίσουμε επαγωγικά την  $n$ -οστή δύναμη μιας γλώσσας  $L \subseteq X^*$ , ως εξής:

$$L^0 = \{\varepsilon\}, L^1 = L, L^2 = LL, \dots, L^{n+1} = L^n L.$$

000


Οι τύποι που αποδείξαμε για τις δυνάμεις μιας λέξης εξακολουθούν να ισχύουν και στην προκειμένη περίπτωση.

Θέτουμε

$$L^* = \{\varepsilon\} \cup L \cup L^2 \cup \dots = \bigcup_{k=0}^{\infty} L^k.$$

Η γλώσσα  $L^*$  που έτσι ορίσαμε ονομάζεται **θήκη** της γλώσσας  $L$ . Μ' άλλα λόγια η θήκη μιας γλώσσας  $L$  περιέχει κάθε λέξη που σχηματίζεται αν παραθέσουμε οποιονδήποτε αριθμό λέξεων της  $L$ . Μερικές φορές αντί της  $L^*$  χρησιμοποιούμε τη γλώσσα

$$L^+ = L^* - \{\varepsilon\} = L \cup L^2 \cup \dots = \bigcup_{k=1}^{\infty} L^k.$$

 **Παράδειγμα 2.3.** Ας είναι  $X = \{a, b\}$  και ας είναι  $L$  η γλώσσα που έχει μια μόνο λέξη, την  $ba$ , δηλαδή  $L = \{ba\}$ . Θα έχουμε διαδοχικά

$$L^0 = \{\varepsilon\},$$

$$\begin{aligned}
L^1 &= L = \{ba\}, \\
L^2 &= LL = \{baba\}, \\
L^3 &= L^2L = \{bababa\}, \\
&\vdots
\end{aligned}$$

Έτσι λοιπόν

$$L^* = \{ba\}^* = \{\varepsilon, ba, baba, bababa, \dots\} = \{\varepsilon, ba, (ba)^2, (ba)^3, \dots\}.$$

Τέλος, το *είδωλο* μιας γλώσσας  $L \subseteq X^*$ , είναι η γλώσσα που απαρτίζεται από τα είδωλα όλων των λέξεων της  $L$ , δηλαδή

$$L^p = \{w^p \mid w \in L\}.$$

### 3. ΡΗΤΕΣ ΓΛΩΣΣΕΣ

Ας είναι

$$X = \{ a, b, c, \dots, \}$$

ένα αλφάβητο. Στο εξής, χάριν απλότητας θα ταυτίζουμε τη γλώσσα  $\{a\}$  με το ίδιο το γράμμα  $a$ , τη γλώσσα  $\{b\}$  με το ίδιο το γράμμα  $b$ , κ.λ.π. Έτσι, αντί να γράφουμε

$$\{a\} \cup \{b\}$$

θα γράφουμε  $a \cup b$ , αντί να γράφουμε

$$\{a\}\{b\}$$

θα γράφουμε  $ab$ , αντί να γράφουμε

$$\{a\}^*$$

θα γράφουμε απλά  $a^*$ , κ.λ.π. Με την παραπάνω συμφωνία η γλώσσα

$$\{a\} \cup [\{b\}\{c\}^*]$$

γράφεται απλά

$$a \cup bc^*$$

ενώ η γλώσσα

$$\{a\}^* \cup [\{b\}^* \{c\} \cup \{c\}^*]^*$$

γράφεται απλά

$$a^* \cup (b^* c \cup c^*)^*$$

κ.λ.π.



**Ορισμός 3.1.** Μια γλώσσα  $L \subseteq X^*$  θα την λέμε **ρητή**, εάν προκύπτει από κάποια γράμματα του αλφαβήτου  $X$ , κάνοντας μια ή περισσότερες φορές τις ακόλουθες πράξεις:

- (α) *ένωση*,
- (β) *παράθεση*,
- (γ) *θήκη*.

Έτσι, αν  $X = \{a, b, c\}$ , η γλώσσα  $a^* \cup b^*$  είναι ρητή. Πράγματι, ξεκινώντας από τα γράμματα  $a$  και  $b$  σχηματίζουμε αρχικά τις γλώσσες  $a^*$  και  $b^*$  (πράξη (γ)) και στη συνέχεια ενώνουμε τις δύο αυτές γλώσσες για να πάρουμε την  $a^* \cup b^*$  (πράξη (α)). Όμοια, η γλώσσα

$$(b^*c \cup c^*b)^*$$

είναι ρητή. Πράγματι, ξεκινώντας από τα γράμματα  $b$  και  $c$  σχηματίζουμε αρχικά τις γλώσσες  $b^*$  και  $c^*$  (πράξη (γ)) και στη συνέχεια τις γλώσσες  $b^*c$  και  $c^*b$  (πράξη (β)). Κατόπιν τις ενώνουμε παίρνοντας την  $b^*c \cup c^*b$  (πράξη (α)) και τελικά παίρνουμε τη θήκη της λευταίας (πράξη (γ)).


Συμβολίζουμε με  $Rat(X)$  το σύνολο όλων των ρητών γλωσσών από το αλφάβητο  $X$ . Αν  $L_k \subseteq X^*$ ,  $k = 1, 2$ , είναι ρητές γλώσσες, δηλαδή και οι δυο τους προκύπτουν από κάποια γράμματα του αλφαβήτου  $X$  κάνοντας μία ή περισσότερες φορές τις πράξεις της ένωσης, παράθεσης και θήκης, τότε και οι γλώσσες  $L_1 \cup L_2$ ,  $L_1L_2$  και  $L_1^*$  προκύπτουν φανερά με τέτοιες διαδικασίες, δηλαδή είναι και αυτές ρητές γλώσσες. Έχουμε λοιπόν

$$L_1, L_2 \in Rat(X) \Rightarrow L_1 \cup L_2 \in Rat(X),$$

$$L_1, L_2 \in Rat(X) \Rightarrow L_1L_2 \in Rat(X),$$

$$L \in Rat(X) \Rightarrow L^* \in Rat(X).$$

Στην πραγματικότητα ισχύει κάτι πολύ ισχυρότερο.

 **Πρόταση 3.1.** Η  $Rat(X)$  είναι η μικρότερη κλάση γλωσσών που περιέχει τις πεπερασμένες γλώσσες και είναι κλειστή ως προς την ένωση, την παράθεση και τη θήκη.

**Απόδειξη.** Αποδεικνύουμε πρώτα ότι κάθε πεπερασμένη γλώσσα είναι ρητή. Προς τούτο, ας είναι  $w = a_1 \cdots a_n$  μια λέξη από το αλφάβητο  $X$ . Τότε, η γλώσσα  $\{w\}$  είναι ρητή αφού προκύπτει από τα γράμματα  $a_1, \dots, a_n$  του  $X$  με την πράξη της παράθεσης. Άρα, κάθε πεπερασμένη γλώσσα

$$L = \{w_1, \dots, w_n\}$$

είναι ρητή ως ένωση ρητών γλωσσών:

$$L = \bigcup_{k=1}^n \{w_k\}.$$

Ας είναι τώρα  $\mathfrak{S}$  ένα σύνολο από γλώσσες του αλφαβήτου  $X$ , τέτοιο ώστε κάθε πεπερασμένη γλώσσα ν' ανήκει σ' αυτό και επιπρόσθετα

$$L_1, L_2 \in \mathfrak{S} \Rightarrow L_1 \cup L_2 \in \mathfrak{S},$$

$$L_1, L_2 \in \mathfrak{S} \Rightarrow L_1L_2 \in \mathfrak{S},$$

$$L \in \mathfrak{S} \Rightarrow L^* \in \mathfrak{S}.$$

Θα δείξουμε ότι

$$\text{Rat}(X) \subseteq \mathfrak{S},$$

δηλαδή ότι η κλάση  $\text{Rat}(X)$  είναι η ελάχιστη κλάση γλωσσών που περιέχει τις πεπερασμένες γλώσσες και είναι κλειστή ως προς την ένωση, την παράθεση και τη θήκη.

Πράγματι, αφού το  $\mathfrak{S}$  περιέχει όλες τις πεπερασμένες γλώσσες του  $X$ , θα περιέχει και τις γλώσσες  $\{a\}$  ( $a \in X$ ), δηλαδή θα περιέχει όλα τα γράμματα του αλφαβήτου  $X$ . Αφού όμως μια ρητή γλώσσα προκύπτει από κάποια γράμματα του αλφαβήτου  $X$  με εφαρμογή των πράξεων της παράθεσης, της ένωσης και θήκης και αφού το  $\mathfrak{S}$  από την υπόθεση είναι κλειστό ως προς αυτές τις πράξεις, προκύπτει ότι κάθε ρητή γλώσσα ανήκει στο  $\mathfrak{S}$ , πράγμα που θέλαμε ν' αποδείξουμε.  $\square$

#### 4. ΚΩΔΙΚΟΠΟΙΗΣΕΙΣ - ΑΝΤΙΚΑΤΑΣΤΑΣΕΙΣ

Ας είναι  $X$  και  $Y$  δύο αλφάβητα. Ονομάζουμε *κωδικοποίηση* του  $X$  στο  $Y$  ένα κανόνα που σε κάθε γράμμα του αλφαβήτου  $X$  αντιστοιχεί μια λέξη από το αλφάβητο  $Y$ . Μ' άλλα λόγια, μια κωδικοποίηση του  $X$  στο  $Y$  δεν είναι παρά μια απεικόνιση

$$f : X \rightarrow Y^*.$$

Αν

$$x_1 \cdots x_m$$

είναι μια τυχούσα λέξη του  $X^*$ , τότε αυτή μετασχηματίζεται από την κωδικοποίηση  $f : X \rightarrow Y^*$  στη λέξη


$$f(x_1) \cdots f(x_m)$$

του  $Y^*$ . Έτσι λοιπόν κάθε κωδικοποίηση  $f : X \rightarrow Y^*$  επεκτείνεται (επαγωγικά) σε μια απεικόνιση

$$f^* : X^* \rightarrow Y^*$$

με τον ακόλουθο τρόπο

$$\begin{cases} f^*(\varepsilon) = \varepsilon \\ f^*(x_1 \cdots x_m) = f(x_1) \cdots f(x_m) \end{cases}$$

 **Παράδειγμα 4.1.** Ας είναι

$$X = \{ a, b \} \text{ και } Y = \{ 0, 1 \}$$

και ας πάρουμε την ακόλουθη κωδικοποίηση του  $X$  στο  $Y$ :

μετασχηματίζεται στη λέξη

10100110

ενώ η λέξη

bbba

μετασχηματίζεται στη λέξη

01010110.

Ας πάρουμε τώρα την κωδικοποίηση

$$a \mapsto 1, \quad b \mapsto 1.$$


Τότε, η λέξη *baba* μετασχηματίζεται στη λέξη *1111* κ.τ.λ.

□

Ας υποθέσουμε τώρα ότι διαθέτουμε μια απεικόνιση

$$g: X^* \rightarrow Y^*.$$

Πώς μπορούμε να ελέγξουμε αν αυτή προέρχεται από κάποια κωδικοποίηση; Απάντηση σ' αυτό το ενδιαφέρον ερώτημα δίνει το επόμενο

 **Θεώρημα 4.1.** Αν για μία απεικόνιση  $g: X^* \rightarrow Y^*$  ισχύει

$$(α) \quad g(\varepsilon) = \varepsilon,$$

δηλαδή η  $g$  στέλνει την κενή λέξη του  $X^*$  στην κενή λέξη του  $Y^*$  και

$$(β) \quad g(uw) = g(u)g(w)$$

για όλες τις λέξεις  $u, w \in X^*$ , τότε υπάρχει μία μοναδική κωδικοποίηση

$$f: X \rightarrow Y^*$$

της οποίας η επέκταση είναι η  $g$ :

$$f^* = g.$$

**Απόδειξη.** Ορίζουμε μια κωδικοποίηση  $f: X \rightarrow Y^*$  με τον ακόλουθο τρόπο

$$f(x) = g(x), \quad \text{για κάθε } x \in X,$$

$$f(x) = g(x), \text{ για κάθε } x \in X,$$

δηλαδή η  $f$  στέλνει κάθε γράμμα  $x \in X$  στη λέξη  $g(x) \in Y^*$ . Θα δείξουμε ότι  $f^* = g$ , δηλαδή ότι

$$f^*(w) = g(w), \text{ για κάθε } w \in X^*.$$

Για  $w = \varepsilon$ , το πράγμα είναι φανερό

$$f^*(\varepsilon) = \varepsilon = g(\varepsilon),$$

ενώ για  $w = x_1 \cdots x_m$ ,  $m \geq 1$ , έχουμε

$$\begin{aligned} f^*(w) &= f^*(x_1 \cdots x_m) = f(x_1) \cdots f(x_m) = \\ &= g(x_1) \cdots g(x_m) = g(x_1 \cdots x_m) = g(w) \end{aligned}$$

Βρήκαμε, λοιπόν, μια κωδικοποίηση  $f$  του  $X$  στο  $Y$  η οποία όταν επεκταθεί μας δίνει την  $g$ .

Αν, τώρα,  $h: X \rightarrow Y^*$  είναι μια άλλη κωδικοποίηση τέτοια ώστε  $h^* = g$ , τότε για κάθε  $x \in X$  θα είναι

$$h(x) = h^*(x) = g(x) = f(x)$$

δηλαδή  $h = f$  γεγονός που αποδεικνύει και τη μοναδικότητα. □

☞ **Παράδειγμα 4.2.** Η απεικόνιση  $g: \{a\}^* \rightarrow \{0, 1\}^*$  που ορίζεται από τη σχέση

$$g(a^k) = \begin{cases} 010, & \text{αν } k \text{ αρτιος} \\ 101, & \text{αν } k \text{ περιττος} \end{cases}$$

δεν προέρχεται από μια κωδικοποίηση διότι αν πάρουμε

$$u = a, \quad v = a^2$$

θα έχουμε

$$g(uv) = g(aa^2) = g(a^3) = 101$$

ενώ

$$g(u)g(v) = g(a)g(a^2) = 101010$$

και

$$101 \neq 101010.$$

Αντίθετα, η απεικόνιση  $g: \{a\}^* \rightarrow \{0, 1\}^*$  που ορίζεται από τη σχέση

$$g(a^k) = (101)^k, \quad k = 0, 1, \dots$$

προέρχεται από μια κωδικοποίηση αφού για κάθε  $u = a^p$ ,  $w = a^q$  έχουμε

$$\begin{aligned} g(uw) &= g(a^p a^q) = g(a^{p+q}) = (101)^{p+q} \\ &= (101)^p (101)^q = g(a^p) g(a^q) = g(u) g(w) \end{aligned}$$

και

$$g(\varepsilon) = g(a^0) = (101)^0 = \varepsilon.$$

Η κωδικοποίηση από την οποία προέρχεται η  $g$  είναι η

$$f: \{a\} \rightarrow \{0, 1\}^* \quad \text{με} \quad f(a) = 101$$

δηλαδή εκείνη που στέλνει το μοναδικό γράμμα του αλφαβήτου  $X = \{a\}$  στη λέξη  $101$  του αλφαβήτου  $Y = \{0, 1\}$ . □

Οι κωδικοποιήσεις λοιπόν από το  $X$  στο  $Y$ , συμπίπτουν με τις απεικονίσεις

$$g: X^* \rightarrow Y^*$$


για τις οποίες

$$g(\varepsilon) = \varepsilon \quad \text{και} \quad g(uw) = g(u)g(w).$$

Ας υποθέσουμε ότι σε κάθε γράμμα  $x$  του αλφαβήτου  $X$  αντιστοιχεί μια γλώσσα  $L_x$  του  $L^*$ :

$$x \mapsto L_x$$

Λέμε τότε ότι έχουμε μια *αντικατάσταση* του  $X$  στο  $Y$ . Μια αντικατάσταση ονομάζεται *ρητή*, αν όλες οι γλώσσες  $L_x$ ,  $x \in X$ , είναι ρητές.

 **Παράδειγμα 4.3.** Ας είναι  $X = \{a, b, c\}$  και  $Y = \{0, 1\}$ . Τότε η απεικόνιση που ορίζεται από τις σχέσεις



$$a \mapsto 0^*, \quad b \mapsto I^* 0 I^*, \quad c \mapsto 0 I$$

είναι μια αντικατάσταση του  $\{a, b, c\}$  στο  $\{0, I\}$ . Η λέξη  $abbc$  του  $X$  μετασχηματίζεται τότε στη γλώσσα

$$0^*(I^* 0 I^*)(I^* 0 I^*) 0 I$$

ενώ η λέξη  $cac$  μετασχηματίζεται στη γλώσσα

$$0 I 0^* 0 I.$$

Η παραπάνω αντικατάσταση είναι ρητή, αφού όλες οι γλώσσες

$$0^*, \quad I^* 0 I^* \quad \text{και} \quad 0 I$$

είναι ρητές. □

Μια αντικατάσταση λοιπόν του  $X$  στο  $Y$  δεν είναι παρά μια απεικόνιση

$$F: X \rightarrow P(Y^*),$$

όπου  $P(Y^*)$  συμβολίζει το σύνολο δηλαδή των γλωσσών του  $Y^*$ . Αν  $x_1 \cdots x_p$  είναι μια λέξη του  $X^*$ , τότε αυτή μετασχηματίζεται με τη βοήθεια της απεικόνισης  $F$  στη γλώσσα

$$F(x_1) \cdots F(x_p)$$


που προκύπτει παραθέτοντας τις γλώσσες  $F(x_k)$ ,  $k = 1, \dots, p$ . Έτσι, κάθε αντικατάσταση  $F: X \rightarrow P(Y^*)$  επεκτείνεται επαγωγικά σε μια απεικόνιση

$$F^*: X^* \rightarrow P(Y^*)$$

με τον ακόλουθο τρόπο:

$$\begin{cases} F^*(\varepsilon) = \{\varepsilon\} \\ F^*(x_1 \cdots x_p) = F(x_1) \cdots F(x_p) \end{cases}$$

Και πάλι, ισχύει το επόμενο

 **Θεώρημα 4.2.** Αν μια απεικόνιση

$$S: X^* \rightarrow P(Y^*)$$

έχει τις ακόλουθες δύο ιδιότητες

$$S(\varepsilon) = \{\varepsilon\},$$

$$S(uv) = S(u)S(v), \quad \forall u, v \in X^*,$$

δηλαδή η γλώσσα  $S(uv)$  είναι η παράθεση των γλωσσών  $S(u)$  και  $S(v)$ , τότε υπάρχει μοναδική αντικατάσταση

$$F: X \rightarrow P(Y^*)$$

της οποίας η επέκταση είναι η  $S$ , δηλαδή  $F^* = S$ .

**Απόδειξη.** Είναι εντελώς παρόμοια με την απόδειξη του θεωρήματος 4.1. □


Οι αντικαταστάσεις λοιπόν από το  $X$  στο  $Y$  ταυτίζονται με τις απεικονίσεις

$$S: X^* \rightarrow P(Y^*)$$

για τις οποίες

$$S(\varepsilon) = \{\varepsilon\} \quad \text{και} \quad S(uv) = S(u)S(v).$$

Σχετικά με τις ρητές αντικαταστάσεις, αρκετά ενδιαφέρονσα είναι η επόμενη

 **Πρόταση 4.1.** Αν  $S: X^* \rightarrow P(Y^*)$  είναι μια ρητή αντικατάσταση και  $L \subseteq X^*$  είναι ρητή γλώσσα, τότε η

$$S(L) = \bigcup_{u \in L} S(u)$$

είναι ρητή γλώσσα του  $Y^*$ . Μ' άλλα λόγια, η εικόνα μιας ρητής γλώσσας μέσω μιας ρητής αντικατάστασης είναι πάλι ρητή γλώσσα.

Για την απόδειξη αυτής της πρότασης μας χρειάζεται το επόμενο



**Λήμμα 4.1.** Αν  $S: X^* \rightarrow P(Y^*)$  είναι μια αντικατάσταση, τότε για οποιοσδήποτε γλώσσες  $L, L_1, L_2 \subseteq X^*$  συμβαίνει

$$(\alpha) \quad S(L_1 \cup L_2) = \bigcup_{u \in L_1 \cup L_2} S(u) = \left[ \bigcup_{u \in L_1} S(u) \right] \cup \left[ \bigcup_{u \in L_2} S(u) \right] = S(L_1) \cup S(L_2).$$

Εύκολα φαίνεται ότι η (α) ισχύει για οσοσδήποτε γλώσσες.

$$(\beta) \quad S(L_1 L_2) = \bigcup_{\substack{u_1 \in L_1 \\ u_2 \in L_2}} S(u_1 u_2) = \bigcup_{\substack{u_1 \in L_1 \\ u_2 \in L_2}} S(u_1) S(u_2) = \\ = \left[ \bigcup_{u_1 \in L_1} S(u_1) \right] \left[ \bigcup_{u_2 \in L_2} S(u_2) \right] = S(L_1) S(L_2)$$

(γ) Λαμβάνοντας υπόψη τις (α) και (β) έχουμε:


$$S(L^*) = S\left(\bigcup_{k=0}^{\infty} L^k\right) = \bigcup_{k=0}^{\infty} S(L^k) = \bigcup_{k=0}^{\infty} [S(L)]^k = [S(L)]^*.$$

□

**Απόδειξη της πρότασης 4.1.** Αφού η γλώσσα  $L$  είναι ρητή, θα προκύπτει από κάποια γράμματα  $x_j$ ,  $j=1, \dots, k$ , του αλφαβήτου  $X$  κάνοντας μία ή περισσότερες φορές τις πράξεις της ένωσης, παράθεσης και θήκης. Κατά συνέπεια, σύμφωνα με το προηγούμενο λήμμα, η γλώσσα  $S(L)$  θα προκύπτει από τις ρητές γλώσσες  $S(x_j)$ ,  $j=1, \dots, k$ , του αλφαβήτου  $Y$ , κάνοντας τις ίδιες ακριβώς πράξεις. Ωστε, σύμφωνα με την πρόταση 3.1, η  $S(L)$  είναι ρητή.

□

Καθώς μια κωδικοποίηση είναι ειδική περίπτωση ρητής αντικατάστασης, συνάγουμε ότι

 **Πόρισμα 4.1.** Η εικόνα μιας ρητής γλώσσας μέσω μιας κωδικοποίησης είναι πάλι ρητή γλώσσα.

## 5. ΡΗΤΕΣ ΕΚΦΡΑΣΕΙΣ


Οι ρητές εκφράσεις είναι “σχήματα” που αντιπροσωπεύουν τις ρητές γλώσσες. Συγκεκριμένα  
ας θεωρήσουμε ένα αλφάβητο

$$X = \{x_1, \dots, x_n\}.$$

Το σύνολο των *ρητών εκφράσεων* από το  $X$  (που συμβολίζεται  $RE(X)$ ), ορίζεται επαγωγικά ως  
εξής:

(α) Τα στοιχεία  $\emptyset$ ,  $\varepsilon$ ,  $x_1$ ,  $\dots$ ,  $x_n$  είναι ρητές εκφράσεις

(β) Αν  $E_1, E_2$  είναι ρητές εκφράσεις, τότε και τα *δένδρα*





είναι ρητές εκφράσεις.


(γ) Αν  $E$  είναι ρητή έκφραση, τότε και το δένδρο



είναι ρητή έκφραση. Έτσι βλέπουμε ότι οι ρητές εκφράσεις από το  $X$  δεν είναι παρά δένδρα που  
σχηματίζονται με τον παραπάνω τρόπο.

Ας δούμε μερικές ρητές εκφράσεις από το αλφάβητο  $X = \{a, b\}$ .





Σε κάθε ρητή έκφραση  $t$  από το  $X$ , αντιστοιχεί μια ρητή γλώσσα που τη συμβολίζουμε  $Rat(t)$ . Έτσι, για τις προηγούμενες ρητές εκφράσεις έχουμε

$$Rat(t_1) = a \cup b^*, \quad Rat(t_2) = a \cup a^*(b^*)^*, \quad Rat(t_3) = (a^* \cup a^*b^*)^*,$$

κ.λ.π. Βάζοντας αυστηρά τα πράγματα κάτω, η  $Rat$  είναι μια απεικόνιση από το σύνολο  $RE(X)$  στο σύνολο  $P(X^*)$  όλων των γλωσσών από το  $X$ , δηλαδή

$$Rat : RE(X) \rightarrow P(X^*)$$

που ορίζεται με τον ακόλουθο τρόπο:


$$1) \quad Rat(\emptyset) = \emptyset, \quad Rat(\varepsilon) = \{\varepsilon\}, \quad Rat(x_s) = \{x_s\},$$

$$2) \quad Rat \left( \begin{array}{c} + \\ / \quad \backslash \\ E_1 \quad E_2 \end{array} \right) = Rat(E_1) \cup Rat(E_2),$$

$$\text{Rat} \left( \begin{array}{c} \bullet \\ / \quad \backslash \\ E_1 \quad E_2 \end{array} \right) = \text{Rat}(E_1)\text{Rat}(E_2),$$

$$3) \text{Rat} \left( \begin{array}{c} * \\ | \\ E \end{array} \right) = [\text{Rat}(E)]^*.$$

Είναι δυνατό διαφορετικές ρητές εκφράσεις να ορίζουν την ίδια ρητή γλώσσα όπως π.χ. συμβαίνει με τις εκφράσεις




Και οι δύο τους ορίζουν την ίδια ρητή γλώσσα:  $b(ab)^* = (ba)^*b$  (άσκηση).


Ας πάρουμε τώρα μια ρητή γλώσσα  $L \subseteq X^*$  και όλες τις ρητές εκφράσεις που την ορίζουν, δηλαδή το σύνολο

$$\{t \in RE(X) \mid \text{Rat}(t) = L\}.$$

Ένα φυσικό ερώτημα που εγείρεται είναι αν μπορούμε να προσδιορίσουμε αλγοριθμικά μια ρητή έκφραση  $t$  της  $L$  η οποία να περιέχει τον μικρότερο δυνατό αριθμό αστερίσκων κι ακόμη ισχυρότερα αν μπορούμε να προσδιορίσουμε μια ρητή έκφραση  $t$  της  $L$  με το μικρότερο δυνατό “αστροβάθος”. Το αστροβάθος  $h(t)$  είναι ο μέγιστος αριθμός αστεριών που βρίσκονται στον ίδιο κλάδο της ρητής έκφρασης  $t$ . Π.χ. για την έκφραση  $t_2$  που είδαμε προηγουμένως είναι  $h(t_2) = 2$ , αφού ο κλάδος



περιέχει δύο αστερίσκους ενώ οι υπόλοιποι κλάδοι



περιέχουν κανέναν και έναν αστερίσκο αντίστοιχα.

Φορμαλιστικά, η απεικόνιση

$$h : RE(X) \rightarrow N \text{ (= οι φυσικοί αριθμοί)}$$

ορίζεται με τον ακόλουθο τρόπο:

$$1) h(\emptyset) = 0, \quad h(\varepsilon) = 0, \quad h(x_k) = 0, \quad k = 1, \dots, n,$$