

Συμβολοσειρές και Γλώσσες

Δημήτρης Φωτάκης

Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων
Πανεπιστήμιο Αιγαίου

Αλφάβητα και Συμβολοσειρές

- **Αλφάβητο**: Πεπερασμένο μη-κενό σύνολο Σ .
Μέλη ονομάζονται **σύμβολα** ή **γράμματα**.
Π.χ. $\Sigma_2 = \{0, 1\}$, $\Sigma = \{a, b, \dots, z\}$.
- **Συμβολοσειρά** (string) w : Πεπερασμένη ακολουθία συμβόλων του Σ .
Μήκος συμβολοσειράς w : #συμβόλων στη w .
Κενή συμβολοσειρά ε ή ϵ : (μοναδική) συμβολοσειρά μήκους 0.
- Σύνολο συμβολοσειρών μήκους k : Σ^k .
Π.χ. $\{0, 1\}^2 = \{00, 01, 10, 11\}$.
- Σύνολο συμβολοσειρών του Σ : Σ^* .
Π.χ. $\{0, 1\}^* = \{\varepsilon, 0, 1, 00, 01, 10, 11, 000, \dots\}$.

Πράξεις με Συμβολοσειρές

- **Παράθεση** (concatenation) x και y : $x \circ y$ ή xy
Π.χ. Η παράθεση των $abcd$ και $efgh$ είναι $abcdefgh$.
- x **υποσυμβολοσειρά** του w : $\exists y, z \in \Sigma^*$, $w = yxz$.
Πρόθεμα αν $y = \varepsilon$. Κατάληξη αν $z = \varepsilon$.
- **Επανάληψη** της w για k φορές: $w^k = \overbrace{w \circ \dots \circ w}^{k \text{ times}}$.
Π.χ. $(ab)^3 = ababab$, $(010)^4 = 010010010010$.
- **Αντίστροφη** w^R της w : συμβολοσειρά που προκύπτει διαβάζοντας w από τέλος προς αρχή (αντίστροφα).
Π.χ. $(abcd)^R = dcba$, $(10010)^R = 01001$.
- Ν.δ.ο. για κάθε $x, y \in \Sigma^*$, $(x \circ y)^R = y^R \circ x^R$.
Υπόδειξη: μαθηματική επαγωγή. Λύση: βιβλίο, σελ. 74.

Γλώσσες

- **Γλώσσα** στο αλφάβητο Σ : οποιοδήποτε υποσύνολο του Σ^* .
Δηλαδή, γλώσσα = (πεπερασμένο ή άπειρο) **σύνολο** συμβολοσειρών.
- Μερικές γλώσσες στο $\Sigma = \{0, 1, 2\}$:
 - $L_1 = \{012, 021, 120, 102, 210, 201\}$.
 - $L_2 = \{\varepsilon, 1, 11, 111, 1111, \dots\}$.
 - $L_3 = \{x \in \Sigma^* : \text{το τελευταίο ψηφίο είναι } 0\}$.
 - $L_4 = \{\} = \emptyset$.
 - $L_5 = \{\varepsilon\}$.

Πράξεις με Γλώσσες

- Ένωση γλωσσών L_1 και L_2 : $L_1 \cup L_2$.
- Τομή γλωσσών L_1 και L_2 : $L_1 \cap L_2$.
- Διαφορά L_1 από L_2 : $L_1 - L_2$ ή $L_1 \setminus L_2$
(συμβολοσειρές που ανήκουν στη L_1 και δεν ανήκουν στη L_2).
- Συμπλήρωμα γλώσσας L : $\Sigma^* - L$
(συμβολοσειρές που δεν ανήκουν στην L).
- Παράθεση γλωσσών L_1 και L_2 : $L_1 \circ L_2$ ή $L_1 L_2$.
 $L_1 \circ L_2 = \{w \in \Sigma^* : w = x_1 \circ x_2 \text{ για κάποια } x_1 \in L_1 \text{ και } x_2 \in L_2\}$
Π.χ. αν $L_1 = \{0, 00, 11\}$ και $L_2 = \{\varepsilon, 1\}$, τότε
 $L_1 L_2 = \{0, 00, 11, 01, 001, 111\}$.

Πράξεις με Γλώσσες

- Kleene star γλώσσας L : L^* αποτελείται από συμβολοσειρές που προκύπτουν από **παράθεση** οποιουδήποτε αριθμού συμβολοσειρών της L .
 $L^* = \{w \in \Sigma^* : w = w_1 \circ \dots \circ w_k \text{ για } k \geq 0 \text{ και } w_1, \dots, w_k \in L\}$
 - Αν $L = \{1, 00\}$, τότε
 $L^* = \{\varepsilon, 1, 00, 11, 100, 001, 0000, 111, 1100, 10000, 1001, \dots\}$.
 - Αν $L = \{\varepsilon\}$, τότε $L^* = \{\varepsilon\}$.
 - Αν $L = \{\}$, τότε $L^* = \{\varepsilon\}$ (για κάθε L , $\varepsilon \in L^*$).
- $L^+ = \{w \in \Sigma^* : w = w_1 \circ \dots \circ w_k \text{ για } k \geq 1 \text{ και } w_1, \dots, w_k \in L\}$
- Πότε οι L^* και L^+ είναι διαφορετικές;
Ποιά είναι η διαφορά τους $L^* - L^+$;

Μετρήσιμα Σύνολα

- Πόσες **συμβολοσειρές** έχει ένα (πεπερασμένο) αλφάβητο Σ ;
 $|\Sigma^*| = \infty$.
- Πόσες **γλώσσες** ορίζονται στο Σ ;
 $|2^{\Sigma^*}| = \infty$.
- Διαισθητικά σαφές ότι $|2^{\Sigma^*}|$ “μεγαλύτερο” του $|\Sigma^*|$.
- **Ισάριθμα** σύνολα A και B : **Αμφιμονοσήμαντη** αντιστοιχία $f : A \mapsto B$.
- **Πεπερασμένο** σύνολο A : ισάριθμο με $\{1, \dots, |A|\}$.
- **Μετρήσιμο** σύνολο A : είτε πεπερασμένο είτε ισάριθμο του \mathbb{N} .
 - Σύνολο ζυγών αριθμών $\{0, 2, 4, 6, \dots\}$ (αντιστοιχία $f(n) = n/2$).
 - Σύνολο ακεραίων αριθμών $\{0, 1, -1, 2, -2, 3, -3, \dots\}$.
 - Σύνολο $\mathbb{N} \times \mathbb{N} = \{(0, 0), (0, 1), (1, 0), (0, 2), (1, 1), (2, 1), \dots\}$.
Αντιστοιχία $f(i, j) = \frac{1}{2}[(i + j)^2 + 3i + j]$.
 - Σύνολο **ρητών** αριθμών;

Μετρήσιμα Σύνολα

- Το Σ^* είναι **μετρήσιμο**.
- Αλφάβητο Σ πεπερασμένο (εξ' ορισμού). Έστω διάταξη συμβόλων Σ .
Λεξιλογραφική σειρά των συμβολοσειρών του Σ^* :
 - Πρώτα η συμβολοσειρά ε μήκους 0,
 - μετά συμβολοσειρές μήκους 1 (ταξινομημένες),
 - μετά συμβολοσειρές μήκους 2 (ταξινομημένες), κ.ο.κ.
- Π.χ. αν $\Sigma = \{0, 1\}$,
 $\Sigma^* = \{\varepsilon, 0, 1, 00, 01, 10, 11, 000, 001, 010, 011, 100, 101, \dots\}$.
- Στη λεξιλογραφική σειρά, **αριθμούμε** τις συμβολοσειρές του Σ^* με τους φυσικούς αριθμούς.

Μη-Μετρήσιμα Σύνολα

- Το 2^{Σ^*} (σύνολο γλωσσών στο Σ) είναι **μη-μετρήσιμο**.
- Έστω μετρήσιμο: Γλώσσες απαριθμούνται σαν **ακολουθία** L_1, L_2, L_3, \dots . Κατασκευάζουμε **γλώσσα** D στο Σ που **διαφέρει** από κάθε $L_i, i = 1, 2, \dots$.
- Έστω w_1, w_2, \dots λεξιμογραφική σειρά συμβολοσειρών του Σ . $D = \{w_i : w_i \notin L_i, i = 1, 2, \dots\}$, δηλαδή $w_i \in D \Leftrightarrow w_i \notin L_i$.
- Η γλώσσα D διαφέρει (στο w_i) από κάθε L_i , **άτοπο!**
- Άτοπο από αμφιμονοσήμαντη αντιστοιχία ανάμεσα **στις γλώσσες και τις συμβολοσειρές** του Σ .
- Ομοίως, $2^{\mathbb{N}}$ **μη-μετρήσιμο** (Θεώρημα 1.5.2, σελ.54).

Διαγωνιοποίηση

- Έστω $R \subset A \times A$.
 $\forall x \in A, R_x = \{y \in A : (x, y) \in R\}$ η αντίστοιχη **γραμμή της R** .
Έστω **διαγώνιο σύνολο** της R : $D = \{x \in R : (x, x) \notin R\}$

	a	b	c	d	e
a	×		×		×
b			×	×	×
c		×		×	
d	×			×	×
e		×	×		

$$D = \{b, c, e\}$$

$$R_a = \{a, c, e\}$$

$$R_b = \{c, d, e\}$$

$$R_c = \{b, d\}$$

$$R_d = \{a, d, e\}$$

$$R_e = \{b, c\}$$

- Το διαγώνιο σύνολο D είναι **διαφορετικό** από κάθε γραμμή της R . Διαφέρει από το R_a στο a , από το R_b στο b , κοκ.
- Ο Georg Cantor εισήγαγε την **αρχή της διαγωνιοποίησης** στα 1891.
- Με διαγωνιοποίηση μπορούμε ν.δ.ο το \mathbb{R} **είναι μη-μετρήσιμο**.

Πεπερασμένη Αναπαράσταση Γλωσσών

- Αναπαράσταση είναι **συμβολοσειρά** κάποιου πεπερασμένου αλφάβητου. Δυνατότητα αναπαράστασης για **μετρήσιμα** διαφορετικές γλώσσες.
- Υπάρχουν **μη-μετρήσιμα** διαφορετικές γλώσσες:
Άρα, υπάρχουν γλώσσες που **δεν έχουν** πεπερασμένη αναπαράσταση.
- Υπάρχει γλώσσα που κανένα πρόγραμμα C δεν την τυπώνει.
- Θα ασχοληθούμε αποκλειστικά με γλώσσες που έχουν πεπερασμένη αναπαράσταση.
- Θα ορίσουμε **μορφές αναπαραστάσεων** και υπολογιστές που τις αναγνωρίζουν.

Υπόθεση του Συνεχούς

- Κάθε **μη-μετρήσιμο** σύνολο **περιέχει** ένα υποσύνολο ισοδύναμο με το \mathbb{R} .
- Διαισθητικά, δεν υπάρχει σύνολο μεγαλύτερο του \mathbb{N} και μικρότερο του \mathbb{R} .
- Gödel (1937) έδειξε ότι η υπόθεση είναι συμβατή με τα αξιώματα της συνολοθεωρίας (άρα δεν υπάρχει **αντιπαράδειγμα**).
- Cohen (1963) έδειξε ότι η **άρνηση** της υπόθεσης είναι επίσης συμβατή με τα αξιώματα της συνολοθεωρίας (άρα δεν υπάρχει **απόδειξη**).
- Συνεπώς η Υπόθεση του Συνεχούς δεν μπορεί ούτε να αποδειχθεί ούτε να καταρριφθεί.