

# Μεταγλωττιστές

Γιώργος Δημητρίου

Μάθημα 2<sup>ο</sup>

# Αλφάβητα και Γλώσσες

- Αλφάβητο: Ένα μη κενό και πεπερασμένο σύνολο συμβόλων
- Γλώσσα: Ένα οποιοδήποτε υποσύνολο των συμβολοσειρών ενός αλφαβήτου (οι προτάσεις της γλώσσας, πχ. προγράμματα)
  - Πεπερασμένη ή μη πεπερασμένη
  - Ποιες προτάσεις ανήκουν σε μια γλώσσα;
  - Υπολογίσιμες γλώσσες

# Παραδείγματα

- Αλφάβητο:  $\{‘0’, ‘1’\}$   
Γλώσσα:  $\{“1”, “110”, “01”\}$
- Αλφάβητο:  $\{‘0’, ‘1’\}$   
Γλώσσα:  $\{0^n 1^n, n > 0\}$
- Αλφάβητο: λεκτικές μονάδες C  
Γλώσσα: προγράμματα C
- Αλφάβητο: ελληνικές λέξεις  
Γλώσσα: φυσική ελληνική

# Βασικές Έννοιες

- Η κενή συμβολοσειρά:  $\varepsilon$
- Η κενή γλώσσα:  $\emptyset$
- Παράθεση γλωσσών:

$$LM = \{ xy \mid x \in L \text{ και } y \in M \}$$

$$\emptyset L = L\emptyset = \emptyset, L\{\varepsilon\} = \{\varepsilon\}L = L$$

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

- Ένωση γλωσσών:

$$L \cup M = \{ x \mid x \in L \text{ ή } x \in M \}$$

$$\emptyset \cup L = L \cup \emptyset = L$$

# Κλείσιμο Kleene

Κλείσιμο Kleene:

$$L^* = L^0 \cup L^1 \cup L^2 \cup \dots$$

- $\varepsilon \in L^*$

Θετικό κλείσιμο Kleene:

$$L^+ = LL^* = L^1 \cup L^2 \cup \dots$$

- $\varepsilon \in L^+$  μόνο αν  $\varepsilon \in L$

# Γραμματικές

- $G = ( V_N, V_T, P, S )$
- Μη τερματικά σύμβολα  $V_N$
- Τερματικά σύμβολα  $V_T, V_T \cap V_N = \emptyset$
- Συντακτικοί κανόνες  $P$ :  
 $\alpha \rightarrow \beta$   
όπου  $\alpha \in V^+, \beta \in V^*, V = V_T \cup V_N$
- Αρχικό σύμβολο  $S \in V_N$

# Παράδειγμα

- $V_N = \{S, A, B\}$
- $V_T = \{ '0', '1' \}$
- $P = \{$ 
  - $S \rightarrow 0A \mid 1B$
  - $A \rightarrow A0BA \mid B1BA \mid \varepsilon$
  - $1B \rightarrow 01BA \mid 1$
  - $0B \rightarrow 1A \mid 0$ $\}$

# Ιεραρχία Γραμματικών (Chomsky)

- Τύπου 0: Ελεύθερες γραμματικές  
 $\alpha \rightarrow \beta$ , όπου  $\alpha \in V^+$ ,  $\beta \in V^*$
- Τύπου 1: Γραμματικές με συμφραζόμενα  
 $\mu A \nu \rightarrow \mu \beta \nu$ , όπου  $\mu, \nu \in V^*$ ,  $A \in V_N$ ,  $\beta \in V^+$
- Τύπου 2: Γραμματικές χωρίς συμφραζόμενα  
 $A \rightarrow \beta$ , όπου  $A \in V_N$ ,  $\beta \in V^*$
- Τύπου 3: Κανονικές γραμματικές  
 $A \rightarrow b$ , όπου  $A \in V_N$ ,  $b \in V_T \cup \{\varepsilon\}$   
 $A \rightarrow bC$ , όπου  $A, C \in V_N$ ,  $b \in V_T$



# Διαδικασία Παραγωγής

- 
- 
- Ξεκινώντας με τη συμβολοσειρά που περιέχει μόνο το αρχικό σύμβολο της γραμματικής,
- *Παράγουμε* διαδοχικά νέες συμβολοσειρές:
  - Αντικαθιστάμε μια υποσυμβολοσειρά  $\alpha$  της τρέχουσας συμβολοσειράς με μια άλλη  $\beta$ , εάν υπάρχει συντακτικός κανόνας  $\alpha \rightarrow \beta$ ,
    - συμβολικά: αν η τρέχουσα συμβολοσειρά έχει τη μορφή  $x\alpha y$ , όπου  $x, y \in V^*$ , τότε γράφουμε  $x\alpha y \Rightarrow x\beta y$
- Μέχρι η τρέχουσα συμβολοσειρά να αποτελείται μόνο από τερματικά σύμβολα.

# Γραμματικές και Γλώσσες

- Γλώσσα μιας γραμματικής: Η γλώσσα που παράγεται από τη γραμματική
- Ισοδύναμες γραμματικές: Αυτές που παράγουν την ίδια γλώσσα
- Τυπικές γλώσσες: Οι γλώσσες που μπορούν να παραχθούν από γραμματικές
- Τύποι γλωσσών: Οι τύποι της γραμματικής που τις παράγουν

# Ανάλυση Σύνταξης

- 
- 
- Δεδομένης μιας γραμματικής:
- 1. Να αποφανθούμε εάν μια πρόταση που αποτελείται από τερματικά σύμβολα της γραμματικής ανήκει στη γλώσσα που περιγράφει η γραμματική
- 2. Αν ναι, να βρούμε μια παραγωγή της γραμματικής που δίνει αυτή την πρόταση

# Εργαλεία Ανάλυσης Σύνταξης

- Θεωρητικά μοντέλα αφηρημένων μηχανών για την επίλυση προβλημάτων σαν αποδοχή των προτάσεων μιας γραμματικής (μηχανές Turing – αυτόματα)
- Εφαρμόζονται στους μεταγλωττιστές για τα προβλήματα της λεκτικής και της συντακτικής ανάλυσης
- Διάφορα είδη αυτομάτων για τους διαφορετικούς τύπους γραμματικών

# Κανονικές Γραμματικές (ΚΓ)

- Οι λιγότερο ισχυρές γραμματικές
- Οι γλώσσες τους αναγνωρίζονται από τα πεπερασμένα αυτόματα
- Μικρότερη πολυπλοκότητα ανάλυσης σύνταξης
- Εφαρμογή στη λεκτική ανάλυση των μεταγλωττιστών

# Κανονικές Εκφράσεις (ΚΕ)

- Κάθε ΚΕ  $r$  πάνω σε ένα αλφάβητο  $\Sigma$  περιγράφει μια κανονική γλώσσα  $L(r)$  του  $\Sigma$ :

$$L(\varepsilon) = \{\varepsilon\}$$

$$L(a) = \{a\}, a \in \Sigma$$

$$L(rs) = L(r)L(s)$$

$$L(r|s) = L(r) \cup L(s)$$

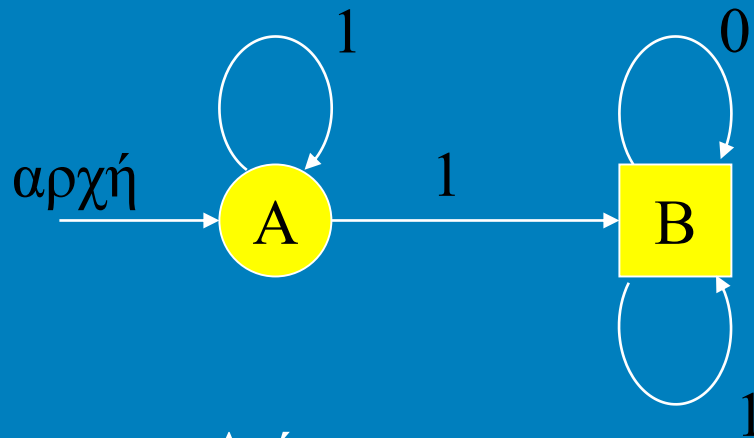
$$L(r^*) = (L(r))^*, L(r^+) = (L(r))^+$$

- Άλλοι συμβολισμοί, όπως  $a?$   $[01a-z]$

# Πεπερασμένα Αυτόματα (ΠΑ)

- $M = (K, \Sigma, \delta, S, F)$
- Πεπερασμένο σύνολο καταστάσεων  $K$
- Αλφάβητο εισόδου  $\Sigma$
- Συνάρτηση μετάβασης καταστάσεων  $\delta$   
 $\delta(X, y) = Z$ , όπου  $X, Z \in K, y \in \Sigma$ 
  - Ντετερμινιστικά / Μη ντετερμινιστικά ΠΑ
- Αρχική κατάσταση  $S \in K$
- Σύνολο τελικών καταστάσεων  $F \subseteq K$

# Παράσταση ΠΑ



Διάγραμμα

	0	1	¬
A		A,B	
B	B	B	Αποδοχή

Πίνακας

- Το αυτόματο που αναγνωρίζει τη γλώσσα με συμβολοσειρές τουλάχιστον ενός '1', ακολουθούμενου από 0 ή περισσότερα '0' ή '1'.



# Λειτουργία ΝΠΑ

- Η κίνηση του ΝΠΑ περιγράφεται ως εξής:
  1. Διάβασε το επόμενο σύμβολο από την είσοδο και προχώρησε το δείκτη εισόδου κατά μία θέση
  2. Πήγαινε στην επόμενη κατάσταση με βάση την παρούσα κατάσταση και το σύμβολο που διάβασες

# Λειτουργία ΜΠΑ και ΜΠΑ-ε

- Στα ΜΠΑ επιλέγεις μία από τις πιθανά πολλαπλές δυνατές κινήσεις που ορίζονται από τη συνάρτηση μετάβασης
- Στα ΜΠΑ-ε μπορείς σε κάποιες περιπτώσεις να κινηθείς χωρίς ανάγνωση συμβόλου από την είσοδο (αυθόρμητη μετάβαση στην επόμενη κατάσταση)

# Αναγνώριση ή Απόρριψη

- 
- 
- Αν ολοκλήρωσες την ανάγνωση της εισόδου και βρίσκεσαι σε τελική κατάσταση, αναγνωρίζεις τη συμβολοσειρά, αλλιώς την απορρίπτεις
- Στα ΜΠΑ, καθώς και στα ΜΠΑ-ε, εξαντλείς όλες τις δυνατές επιλογές κίνησης, πριν απορρίψεις τη συμβολοσειρά

# Μετατροπή ΜΠΑ σε ΝΠΑ

- 
- 
- Κατασκευή υποσυνόλων:
  - Το σύνολο καταστάσεων του ΝΠΑ περιέχει υποσύνολα του συνόλου καταστάσεων του ΜΠΑ
  - Κάθε μετάβαση πρέπει να γίνεται σε μια το πολύ κατάσταση
- Απαιτούνται μέχρι  $2^n$  καταστάσεις του ΝΠΑ για  $n$  καταστάσεις του ΜΠΑ.

# Αριθμός Καταστάσεων ΠΑ

- Σε ένα ΠΑ μπορεί να έχουμε:
  - απρόσιτες καταστάσεις
  - ισοδύναμες καταστάσεις
- Αφαιρώντας τις απρόσιτες και συμπύσσοντας τις ισοδύναμες καταστάσεις βρίσκουμε ένα ισοδύναμο ΠΑ με ελάχιστο αριθμό καταστάσεων

# Γραμματικές χωρίς Συμφραζόμενα (ΓΧΣ)

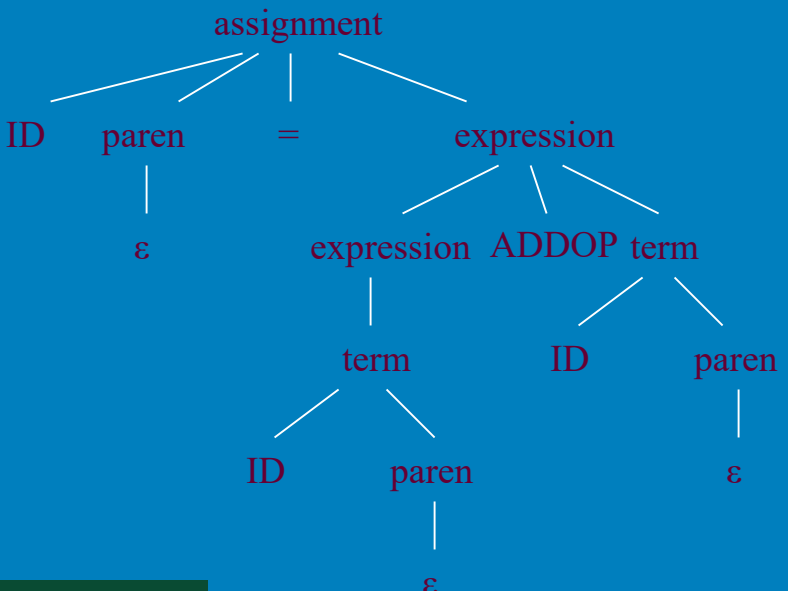
- Πιο ισχυρές από τις ΚΓ
- Οι γλώσσες τους αναγνωρίζονται από τα αυτόματα στοίβας
- Μεγαλύτερη πολυπλοκότητα ανάλυσης σύνταξης
- Εφαρμογή στη συντακτική ανάλυση των μεταγλωττιστών

# Αριστερότερη/Δεξιότερη Παραγωγή

- Αν κατά τη διαδικασία παραγωγής από μια ΓΧΣ αντικαθιστούμε το αριστερότερο μη τερματικό σύμβολο, παίρνουμε μια αριστερότερη παραγωγή
  - Παράδειγμα από γραμματική 1<sup>ου</sup> μαθήματος:  
$$\begin{aligned} \text{assignment} &\Rightarrow \text{ID paren} = \text{expression} \Rightarrow_L \text{ID} = \text{expression} \\ &\Rightarrow \text{ID} = \text{term} \Rightarrow \text{ID} = \text{ID paren} \Rightarrow \text{ID} = \text{ID} \end{aligned}$$
- Αντίστοιχα για δεξιότερη παραγωγή

# Δέντρο Ανάλυσης Σύνταξης (ΔΣΑ)

- Απεικόνιση της διαδικασίας παραγωγής
  - Ρίζα: το αρχικό σύμβολο
  - Φύλλα: μόνο τερματικά σύμβολα
- Παράδειγμα από γραμματική 1<sup>ου</sup> μαθήματος:





# Διφορούμενες Γραμματικές

- 
- 
- Μια ΓΧΣ ονομάζεται διφορούμενη, όταν υπάρχει πρότασή της που έχει περισσότερα από ένα ΔΑΣ, ή ισοδύναμα που παράγεται με περισσότερες από μία αριστερότερες (ή περισσότερες από μία δεξιότερες) παραγωγές
- Μια ΓΧΣ ονομάζεται εγγενώς διφορούμενη όταν δεν υπάρχει ισοδύναμή της μη διφορούμενη γραμματική

# Παράδειγμα: Ξεκρέμαστο else

- Διφορούμενη γραμματική:  
stmt  $\rightarrow$  IF cond stmt ELSE stmt | IF cond stmt | S1 | S2  
cond  $\rightarrow$  C1 | C2
- Ισοδύναμη μη διφορούμενη γραμματική:  
stmt  $\rightarrow$  matched | unmatched  
matched  $\rightarrow$  IF cond matched ELSE matched | S1 | S2  
unmatched  $\rightarrow$  IF cond stmt |  
IF cond matched ELSE unmatched  
cond  $\rightarrow$  C1 | C2
- Συμβολοσειρά: IF C1 IF C2 S1 ELSE S2

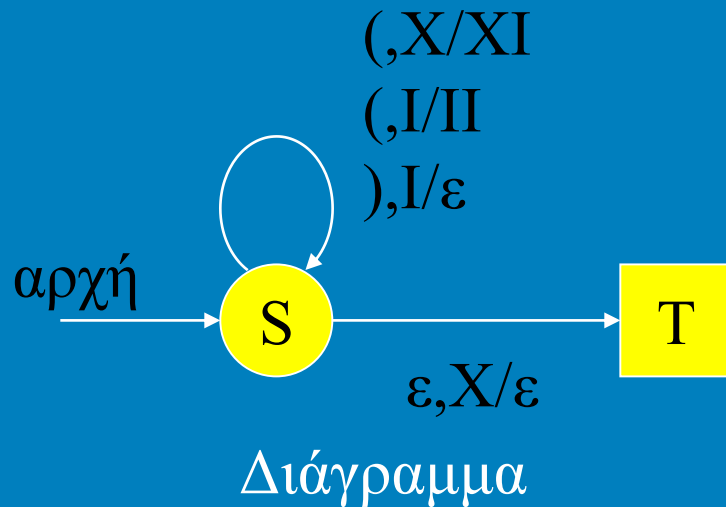
# Παράδειγμα: Αριθμητικές Εκφράσεις

- Διφορούμενη γραμματική:  
$$\text{expr} \rightarrow \text{expr} + \text{expr} \mid \text{expr} - \text{expr} \mid \text{expr} * \text{expr} \mid \text{expr} / \text{expr} \mid \text{ID} \mid \text{CONST} \mid ( \text{expr} )$$
- Ισοδύναμη μη διφορούμενη γραμματική:  
$$\begin{aligned} \text{expr} &\rightarrow \text{expr} + \text{term} \mid \text{expr} - \text{term} \mid \text{term} \\ \text{term} &\rightarrow \text{term} * \text{factor} \mid \text{term} / \text{factor} \mid \text{factor} \\ \text{factor} &\rightarrow \text{ID} \mid \text{CONST} \mid ( \text{expr} ) \end{aligned}$$
- Συμβολοσειρά:  $\text{ID} + \text{ID} - \text{CONST} / \text{ID} * \text{ID}$

# Αυτόματα Στοίβας (ΑΣ)

- $M = (K, \Sigma, \Gamma, \delta, q_0, Z_0, F)$
- Πεπερασμένο σύνολο καταστάσεων  $K$
- Αλφάβητο εισόδου  $\Sigma$
- Αλφάβητο στοίβας  $\Gamma$
- Συνάρτηση μετάβασης καταστάσεων  $\delta$   
 $\delta(q, X, \alpha) = (p, \gamma) \mid q, p \in K, X \in \Gamma, \alpha \in \Sigma \cup \{\epsilon\}, \gamma \in \Gamma^*$   
– Ντετερμινιστικά / Μη ντετερμινιστικά ΑΣ
- Αρχική κατάσταση  $q_0 \in K$
- Αρχικό σύμβολο στοίβας  $Z_0 \in \Gamma$
- Σύνολο τελικών καταστάσεων  $F \subseteq K$

# Παράσταση ΑΣ



	X	I	⊥
S	'(' ⇒ S, XI $\epsilon \Rightarrow T, \epsilon$	'(' ⇒ S, II )' ⇒ S, $\epsilon$	
T			Αποδοχή

Πίνακας

- Το αυτόματο που αναγνωρίζει ζευγάρια παρενθέσεων που ταιριάζουν:
  - Δύο καταστάσεις: S και T
  - Δύο σύμβολα στοίβας: X (αρχικό) και I

# Λειτουργία ΑΣ

- Η κίνηση του ΑΣ περιγράφεται ως εξής:
  1. Αν  $a \neq \epsilon$ , διάβασε το επόμενο σύμβολο από την είσοδο και προχώρησε το δείκτη εισόδου κατά μία θέση
  2. Αντικατάστησε το  $X$  στην κορυφή της στοίβας με τα σύμβολα του  $\gamma$
  3. Πήγαινε στην επόμενη κατάσταση με βάση την παρούσα κατάσταση και τα σύμβολα  $X, a$

# Τερματισμός Λειτουργίας ΑΣ

- Η συμβολοσειρά εισόδου αναγνωρίζεται – αναλογα με την υλοποίηση – σε μία από τις ακόλουθες περιπτώσεις:
  - Όταν η συμβολοσειρά έχει ολοκληρωθεί (με το χαρακτήρα τερματισμού \$) και το αυτόματο βρίσκεται σε τελική κατάσταση
  - Όταν η συμβολοσειρά έχει ολοκληρωθεί (με το χαρακτήρα τερματισμού \$) και η στοίβα είναι άδεια ή περιέχει το αρχικό σύμβολο
- Σε άλλες περιπτώσεις απορρίπτεται

# Ισοδυναμία Αναπαραστάσεων

- Οι ΚΓ, οι ΚΕ και τα ΠΑ είναι ισοδύναμες αναπαραστάσεις μιας κανονικής γλώσσας, και η ισοδυναμία αυτή μπορεί να αποδειχτεί με αναγωγή από τη μια αναπαράσταση στην άλλη
- Υπάρχει αντίστοιχη ισοδυναμία μεταξύ ΓΧΣ και ΑΣ