Μεταγλωττιστές

Νίκος Παπασπύρου

{nickie}@softlab.ntua.gr

Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχ. και Μηχ. Υπολογιστών
Εργαστήριο Τεχνολογίας Λογισμικού
Πολυτεχνειούπολη, 15780 Ζωγράφου.

Μάρτιος 2008

Εισαγωγή (i)

- Γλώσσες προγραμματισμού
- Μεταγλωττιστές
- Αναγκαιότητα και ιστορική αναδρομή

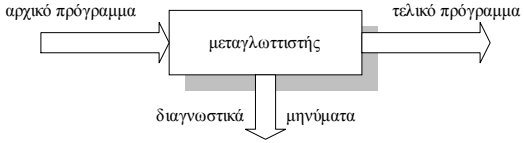

Εισαγωγή (ii)

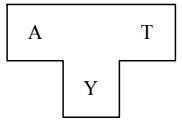

- Αρχική γλώσσα L_A
- Τελική γλώσσα L_T
- Γλώσσα υλοποίησης L_Y
- Σημασιολογία του προγράμματος P στη γλώσσα L

$$[\![P]\!]_L : Inp(P) \rightarrow Out(P)$$

- Σημασία ενός μεταγλωττιστή C

$$[\![C]\!]_{L_Y} : L_A \rightarrow L_T$$

Εισαγωγή (iii)

- Ορθότητα του μεταγλωττιστή: "το μεταγλωττισμένο πρόγραμμα πρέπει να είναι ισοδύναμο με το αρχικό"

$$[\![P]\!]_{L_A} = [\![[\![C]\!]_{L_Y}(P)]\!]_{L_T}$$

Εισαγωγή (iv)

- Είδη μεταγλωττιστών:
  - Απλοί
  - Αντίστροφοι (decompilers)
  - Μετα-μεταγλωττιστές (meta-compilers)
- Ειδικές περιπτώσεις μεταγλωττιστών:
  - Προεπεξεργαστές (preprocessors)
  - Συμβολομεταφραστές (assemblers)
  - Γεννήτορες προγραμμάτων (program generators)

Εισαγωγή (v)

- Συναφή εργαλεία
  - Διερμηνείς (interpreters)
  - Διαχειριστές βιβλιοθηκών (library managers)
  - Συνδέτες (linkers)
  - Φορτωτές (loaders)
  - Εκδότες προγραμμάτων (program editors)
  - Εντοπιστές σφαλμάτων (debuggers)
  - Στατιστικοί αναλυτές (profilers)

Κατασκευή μεταγλωττιστή (i)

- Βασικές απαιτήσεις:
  - Να λειτουργεί σωστά
  - Να συμμορφώνεται με τις προδιαγραφές της αρχικής και της τελικής γλώσσας
  - Να μεταγλωττίζει προγράμματα κάθε μεγέθους

Κατασκευή μεταγλωττιστή (ii)

- Επιπρόσθετες απαιτήσεις:
  - Να παράγει αποδοτικό κώδικα
  - Να έχει μικρό χρόνο μεταγλώττισης
  - Να έχει μικρές απαιτήσεις μνήμης κατά τη μεταγλώττιση
  - Να δίνει καλά διαγνωστικά μηνύματα
  - Να συνεχίζει ύστερα από λάθη
  - Να είναι μεταφέρσιμος

Φάσεις και προϊόντα της μεταγλώττισης

- Λεκτική ανάλυση
- Συντακτική ανάλυση
- Σημασιολογική ανάλυση
- Παραγωγή ενδιάμεσου κώδικα
- Βελτιστοποίηση
- Παραγωγή τελικού κώδικα

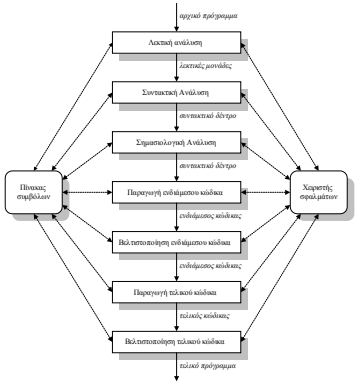

Θέματα υλοποίησης

- Οργάνωση σε περάσματα
- Οργάνωση σε εμπρόσθιο και οπίσθιο τμήμα (front-end / back-end)
- Έλεγχος ορθότητας
- Είδη διαγνωστικών μηνυμάτων και ανάνηψη
  - Εσωτερικά (internal)
  - Σφάλματα (errors)
  - Προειδοποιητικά μηνύματα (warnings)
  - Απλά μηνύματα (messages)

Εκκίνηση – bootstrapping

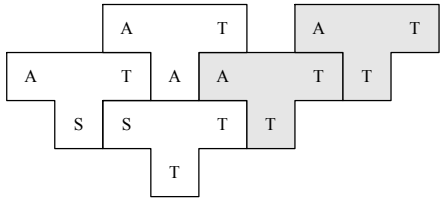

- Βήμα 1: Μεταγλωττιστής για $S \subset A$ στην T.
- Βήμα 2: Μεταγλωττιστής για την A στην S.
- Βήμα 3: Μεταγλωττιστής για την A στην A.

Οργάνωση σε ένα πέρασμα

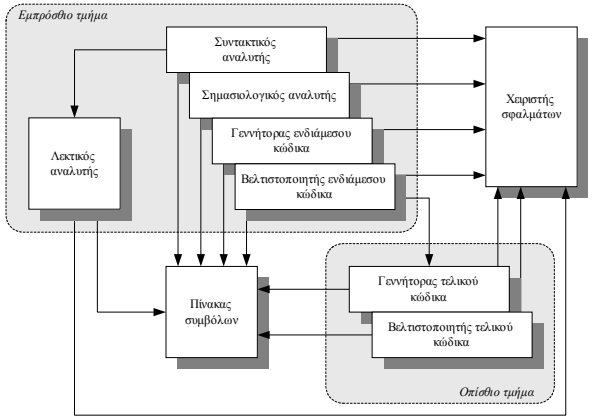

Κεφάλαιο 2:
Τυπικές γλώσσες

Τυπικές γλώσσες (i)

Βασικές έννοιες

- Αλφάβητο Σ
- Σύμβολο a
- Συμβολοσειρά α
- Μήκος συμβολοσειράς $|\alpha|$
- Σύνολο συμβολοσειρών μήκους n Σ^n
- Σύνολο όλων των συμβολοσειρών

$$\Sigma^* = \bigcup_{n=0}^{\infty} \Sigma^n$$

Τυπικές γλώσσες (ii)

Βασικές έννοιες *(συνέχεια)*

- Κενή συμβολοσειρά ϵ
- Παράθεση συμβολοσειρών $\alpha\beta$
- Παράθεση συμβολοσειράς με τον εαυτό της

$$\alpha^0 = \epsilon$$
$$\alpha^{n+1} = \alpha\alpha^n$$

- Πρόθεμα, επίθεμα, υποσυμβολοσειρά

Τυπικές γλώσσες (iii)

Βασικές έννοιες *(συνέχεια)*

- Γλώσσα $L \subseteq \Sigma^*$
- Ένωση γλωσσών

$$L_1 \cup L_2 = \{\alpha \mid \alpha \in L_1 \vee \alpha \in L_2\}$$

- Παράθεση γλωσσών

$$L_1 L_2 = \{\alpha\beta \mid \alpha \in L_1 \wedge \beta \in L_2\}$$

- Παράθεση γλώσσας με τον εαυτό της

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

- Κλείσιμο ή άστρο του Kleene

$$L^* = \bigcup_{n=0}^{\infty} L^n \qquad L^+ = LL^*$$

Τυπικές γλώσσες (iv)

Γεννητικά μοντέλα

- Γραμματική $G = (T, N, P, S)$
  - T : τερματικά σύμβολα a
  - N : μη τερματικά σύμβολα A
  - P : κανόνες παραγωγής $\alpha \to \beta$
  - S : αρχικό σύμβολο
- Παραγωγές: αν $\alpha, \beta, \gamma, \delta \in (T \cup N)^*$
  και $(\alpha \to \beta) \in P$
  τότε $\gamma\alpha\delta \Rightarrow \gamma\beta\delta$
- Γλώσσα: $L(G) = \{\alpha \in T^* \mid S \Rightarrow^+ \alpha\}$

Τυπικές γλώσσες (v)

Ιεραρχία Chomsky

- Τύπου 0: όλες οι γραμματικές, $\alpha \to \beta$
- Τύπου 1: γραμματικές με συμφραζόμενα (context-sensitive), $\alpha \to \beta$ με $|\alpha| \leq |\beta|$
- Τύπου 2: γραμματικές χωρίς συμφραζόμενα (context-free) $A \to \beta$
- Τύπου 3: κανονικές γραμματικές (regular) $A \to aB$ ή $A \to a$
- Ειδική περίπτωση: γλώσσες που παράγουν την κενή συμβολοσειρά

Τυπικές γλώσσες (vi)

Αναγνωριστές

- Τύπου 0: μηχανή Turing
- Τύπου 1: γραμμικά περιορισμένη μηχανή Turing
- Τύπου 2: αυτόματα στοίβας (push-down automata)
  - Χρήσιμα στη συντακτική ανάλυση
- Τύπου 3: πεπερασμένα αυτόματα (finite automata)
  - Χρήσιμα στη λεκτική ανάλυση

Κανονικές γλώσσες (i)

- Κανονικές γραμματικές
  - Μόνο κανόνες $A \to aB$ ή $A \to a$
  - ισοδύναμα $A \to Ba$ ή $A \to a$
- Κανονικές εκφράσεις (regular expressions)
  - Κενή συμβολοσειρά: ϵ
  - Κάθε σύμβολο του Σ: a
  - Παράθεση δύο κανονικών εκφράσεων: (rs)
  - Διάζευξη δύο κανονικών εκφράσεων: $(r|s)$
  - Κλείσιμο (ή άστρο) Kleene: (r^*)
- Συντομογραφίες:
  - απαλοιφή περιττών παρενθέσεων
  - r^+ $[a_1, a_2, \ldots, a_n]$ $[a_1 - a_2]$ $r?$.

Κανονικές γλώσσες (ii)

Παραδείγματα κανονικών εκφράσεων

- Ακέραιες σταθερές χωρίς πρόσημο στην Pascal
  - ένα ή περισσότερα δεκαδικά ψηφία

  [0-9]$^+$
- Αριθμητικές σταθερές χωρίς πρόσημο στη C
  - ακέραιο μέρος που δεν αρχίζει με μηδέν, εκτός αν είναι μηδενικό (γιατί;)
  - προαιρετικά: υποδιαστολή και κλασματικό μέρος
  - προαιρετικά: εκθέτης με ή χωρίς πρόσημο

  ([1-9][0-9]*|0)(\.[0-9]$^+$)?((E|e)(+|−)?[0-9]$^+$)?

Πεπερασμένα αυτόματα (i)

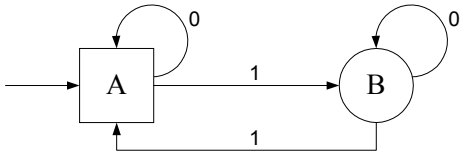

- Καταστάσεις και μεταβάσεις
- Ντετερμινιστικά (ΝΠΑ), μη ντετερμινιστικά (ΜΠΑ) και ΜΠΑ με κενές μεταβάσεις (ΜΠΑ-ϵ)
- Αρχική κατάσταση, τελικές καταστάσεις

Πεπερασμένα αυτόματα (ii)

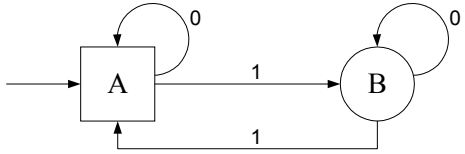

- Ποια γλώσσα αναγνωρίζει;
- Τη γλώσσα των συμβολοσειρών που αποτελούνται από 0 και 1 και περιέχουν άρτιο αριθμό 1

Κανονικές γλώσσες, ανασκόπηση

Αναγωγές και ισοδυναμίες

- κανονική γραμματική ⇒ ΜΠΑ-ϵ
- ΜΠΑ-ϵ ⇒ κανονική γραμματική
- κανονική έκφραση ⇒ ΜΠΑ-ϵ
- ΜΠΑ-ϵ ⇒ κανονική έκφραση
- ΜΠΑ-ϵ ⇒ ΝΠΑ
- Ελαχιστοποίηση ΝΠΑ

Κεφάλαιο 3:
Λεκτική ανάλυση

Λεκτική ανάλυση

- Λεκτικές μονάδες (tokens)
- Αναγνωρίζονται με πεπερασμένα αυτόματα που:
  - διαβάζουν ενδεχομένως περισσότερους χαρακτήρες
  - οπισθοδρομούν αν χρειαστεί
  - διαθέτουν έξοδο που χρησιμοποιείται στη συντακτική ανάλυση
- Ειδικός συμβολισμός: διαγράμματα μετάβασης

Διαγράμματα μετάβασης (i)

- Αναγνωριστικά της Pascal

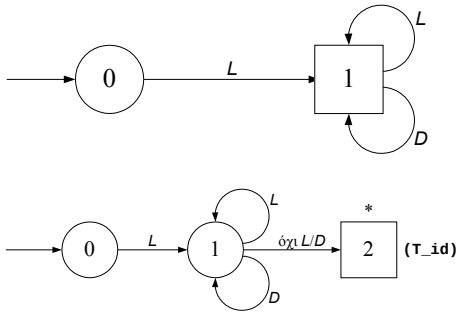

Διαγράμματα μετάβασης (ii)

- Τελεστές > και >=

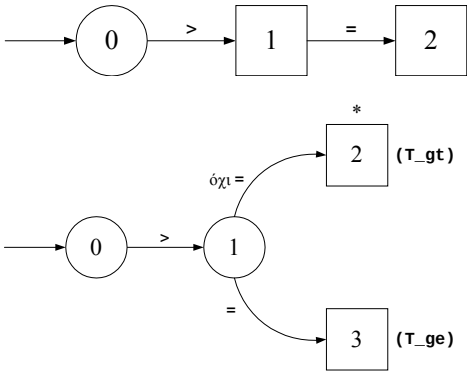

Κατασκευή του ΛΑ (i)

- Καταγραφή και ταξινόμηση χαρακτήρων

  $mapping \quad : \quad (\text{ASCII} \cup \{\texttt{EOF}\}) \rightarrow \Sigma$
- Καταγραφή και ταξινόμηση λεκτικών μονάδων
  - Κωδικοποίηση λεκτικών μονάδων
  - Ακολουθία χαρακτήρων (lexeme)
- Σχεδίαση του διαγράμματος μετάβασης
- Υλοποίηση του λεκτικού αναλυτή

Κατασκευή του ΛΑ (ii)

- Επιμέρους θέματα
  - Τρόπος διαχωρισμού λεκτικών μονάδων
  - Σχόλια
  - Διάκριση πεζών / κεφαλαίων γραμμάτων
  - Ενδιάμεση μνήμη (buffer)
  - Ανάνηψη από σφάλματα

Κατασκευή του ΛΑ (iii)

Σχεδίαση συνολικού διαγράμματος μετάβασης

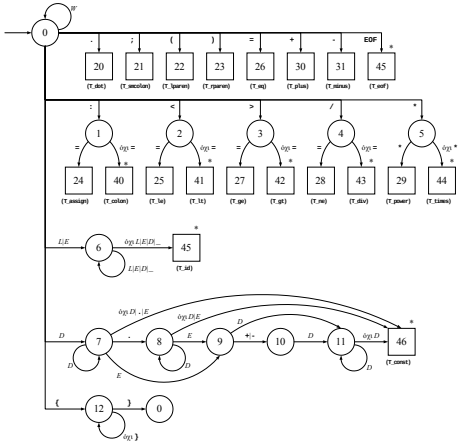

Κατασκευή του ΛΑ (iv)

- Εναλλακτικοί τρόποι υλοποίησης:
  - Χειρωνακτικά
  - Με πίνακα μεταβάσεων
  - Με το μεταεργαλείο flex

Υλοποίηση ΛΑ με το flex (i)

- Μεταεργαλείο flex: γεννήτορας ΛΑ
- Είσοδος: μεταπρόγραμμα που περιγράφει τις λεκτικές μονάδες
- Έξοδος: πρόγραμμα σε C
  - Η συνάρτηση yylex υλοποιεί το ΛΑ
  - Επιστρέφει τον κωδικό της λεκτικής μονάδας που αναγνωρίστηκε, ή 0 στο τέλος της συμβολοσειράς εισόδου
  - Τοποθετεί στη μεταβλητή yytext την αντίστοιχη ακολουθία χαρακτήρων (lexeme)

Υλοποίηση ΛΑ με το flex (ii)

- Δομή του μεταπρογράμματος

  Μέρος Α
  %%
  Μέρος Β
  %%
  Μέρος Γ

  Και τα τρία μέρη μπορούν να είναι κενά

Υλοποίηση ΛΑ με το flex (iii)

- Μέρος Α, περιέχει
  - Σχόλια, όπως στη C
  - Κώδικα C, μέσα σε %{ και %}
  - Μνημονικά ονόματα ως συντομογραφίες κανονικών εκφράσεων
  - Δηλώσεις αρχικών καταστάσεων

Υλοποίηση ΛΑ με το flex (iv)

- Μέρος Α, παράδειγμα

```
%{
#define T_eof             0
#define T_id              1
   ...
#define T_while          52

void ERROR (const char msg []);
%}

L [A-Za-z]          /* letters     */
D [0-9]             /* digits      */
W [ \t\n]           /* white space */
```

Υλοποίηση ΛΑ με το flex (v)

- Μέρος Β, περιέχει κανόνες της μορφής

  κανονική έκφραση ενέργεια

- Κάθε ενέργεια είναι μια εντολή της C
- Λειτουργία:
  - Διαβάζεται το μακρύτερο πρόθεμα της συμβολοσειράς εισόδου που μπορεί να αναγνωριστεί από κάποια κανονική έκφραση
  - Εκτελείται η αντίστοιχη ενέργεια

Υλοποίηση ΛΑ με το flex (vi)

- Κανονικές εκφράσεις

`a`	Ο χαρακτήρας a.
`.`	Οποιοσδήποτε χαρακτήρας εκτός της αλλαγής γραμμής.
`\`x	Αν x ένα από τα a, b, f, n, r, t, v ή 0, τότε όπως στη C, αλλιώς ο ίδιος ο χαρακτήρας x.
`\123`	Ο χαρακτήρας ASCII με οκταδική τιμή 123.
`\x3f`	Ο χαρακτήρας ASCII με δεκαεξαδική τιμή 3F.
`"abc"`	Η συμβολοσειρά abc.
`[abc]`	Ένας από τους χαρακτήρες a, b ή c.
`[a-z]`	Ένας από τους χαρακτήρες a έως z.
`[ac-fs]`	Ένας από τους χαρακτήρες a, c έως f, ή s.
`[^a-z]`	Ένας από τους χαρακτήρες εκτός όσων ανήκουν στην περιοχή a έως z.

Υλοποίηση ΛΑ με το flex (vii)

- Κανονικές εκφράσεις *(συνέχεια)*

`{name}`	Η κανονική έκφραση με μνημονικό όνομα name.
rs	Η παράθεση των r και s.
$r\|s$	Η διάζευξη των r και s.
(r)	Η κανονική έκφραση r. Οι παρενθέσεις χρησιμοποιούνται για ομαδοποίηση.
$r*$	Η r επαναλαμβάνεται μηδέν ή περισσότερες φορές.
$r+$	Η r επαναλαμβάνεται μια ή περισσότερες φορές.
$r?$	Η r είναι προαιρετική (επαναλαμβάνεται μηδέν ή μια φορά).
$r\{7\}$	Η r επαναλαμβάνεται ακριβώς 7 φορές.
$r\{3,5\}$	Η r επαναλαμβάνεται από 3 έως 5 φορές.
$r\{4,\}$	Η r επαναλαμβάνεται 4 ή περισσότερες φορές.

Υλοποίηση ΛΑ με το flex (viii)

- Κανονικές εκφράσεις *(συνέχεια)*

`^`r	Η r αλλά μόνο στην αρχή μιας γραμμής.
r`$`	Η r αλλά μόνο στο τέλος μιας γραμμής.
`<<EOF>>`	Το τέλος του αρχείου εισόδου.
r/s	Η κανονική έκφραση r αλλά μόνο αν ακολουθεί η κανονική έκφραση s.
`<`S`>`r	Η r αλλά μόνο όταν η τρέχουσα αρχική κατάσταση είναι η S.
`<`S_1, S_2, S_3`>`r	Η r, αλλά μόνο όταν η τρέχουσα αρχική κατάσταση είναι μια από τις S_1, S_2 ή S_3.
`<*>`r	Η r σε οποιαδήποτε αρχική κατάσταση.

Υλοποίηση ΛΑ με το flex (ix)

- Μέρος Β, παράδειγμα

```
"and"                          { return T_and;    }
   ...
"while"                        { return T_while;  }

":="                           { return T_assign; }
":"                            { return T_colon;  }

{L}({L}|{D}|_)*                 { return T_id;     }
{D}+(\.{D}*(e\-?{D}+)?)?        { return T_const;  }
{W}+                            { /* nothing */    }
"(*"([^*]+|\*+[^*)])*\*+")"     { /* nothing */    }

.                        { ERROR("illegal token"); }
```


Υλοποίηση ΛΑ με το flex (x)

- Μέρος Γ, περιέχει κώδικα C
- Παράδειγμα

```
void ERROR (const char msg [])
{
   fprintf(stderr, "ERROR: %s\n", msg);
   exit(1);
}
```

Υλοποίηση ΛΑ με το flex (xi)

- Παράδειγμα *(συνέχεια)*

```
int main ()
{
   int token;

   do {
      token = yylex();
      printf("token=%d, lexeme=\"%s\"\n",
             token, yytext);
   } while (token != T_eof);

   return 0;
}
```


Υλοποίηση ΛΑ με το flex (xii)

- Παράδειγμα: Αρίθμηση γραμμών

```
int lineno = 1;

[ \t]+     { /* nothing */ }
\n         { lineno++;     }

void ERROR (const char msg [])
{
    fprintf(stderr, "ERROR, line %d: %s\n",
            lineno, msg);
    exit(1);
}
```

- Πρόβλημα: Λάθος αρίθμηση σε σχόλια

Υλοποίηση ΛΑ με το flex (xiii)

- Αρχικές καταστάσεις
  - Κοινές: `%s`
  - Αποκλειστικές: `%x`
- Ενεργοί κανόνες σε κάποια κατάσταση
- Μετάβαση μεταξύ καταστάσεων: `BEGIN(s)`
- Αρχική κατάσταση κατά την έναρξη λειτουργίας του ΛΑ: `INITIAL`

Υλοποίηση ΛΑ με το flex (xiv)

- Παράδειγμα: Αρίθμηση γραμμών (διόρθωση)

```
%x COMMENT

"(*"                { BEGIN(COMMENT); }
<COMMENT>"*)"       { BEGIN(INITIAL); }
<COMMENT>\n         { lineno++;       }
<COMMENT>"*"        { /* nothing */   }
<COMMENT>[^*\n]+    { /* nothing */   }
```


Κεφάλαιο 2:
Τυπικές γλώσσες

(μέρος 2ο)

Γλώσσες χωρίς συμφραζόμενα (i)

- Γραμματικές χωρίς συμφραζόμενα: $A \to \alpha$
  - Σε κάθε παραγωγή ένα μη τερματικό σύμβολο αντικαθίσταται, βάσει ενός κανόνα
  - Πολλές διαφορετικές παραγωγές διαφέρουν μόνο στη σειρά των αντικαταστάσεων
- Αριστερότερη / δεξιότερη παραγωγή (leftmost / rightmost derivation)
- Συντακτικά δέντρα (parse trees)

Γλώσσες χωρίς συμφραζόμενα (ii)

- Μία παραγωγή

$\boxed{S} \Rightarrow \mathrm{a}\boxed{A}\boxed{B}\mathrm{c} \Rightarrow \mathrm{a}\boxed{A}\mathrm{b}Bc$
$\Rightarrow \mathrm{ac}\boxed{S}\boxed{B}\mathrm{b}Bc \Rightarrow \mathrm{ac}\boxed{S}\mathrm{ab}Bc$
$\Rightarrow \mathrm{acab}\boxed{B}\mathrm{c} \Rightarrow \mathrm{acabac}$

- Αριστερότερη παραγωγή

$\boxed{S} \Rightarrow_L \mathrm{a}\boxed{A}BC \Rightarrow_L \mathrm{a}\boxed{A}\mathrm{b}Bc$
$\Rightarrow_L \mathrm{ac}\boxed{S}B\mathrm{b}Bc \Rightarrow_L \mathrm{ac}\boxed{B}\mathrm{b}Bc$
$\Rightarrow_L \mathrm{acab}\boxed{B}\mathrm{c} \Rightarrow_L \mathrm{acabac}$

- Δεξιότερη παραγωγή

$\boxed{S} \Rightarrow_R \mathrm{a}\boxed{A}\boxed{B}\mathrm{c} \Rightarrow_R \mathrm{a}\boxed{A}\mathrm{ac}$
$\Rightarrow_R \mathrm{a}\boxed{A}\mathrm{bac} \Rightarrow_R \mathrm{ac}\boxed{S}\boxed{B}\mathrm{bac}$
$\Rightarrow_R \mathrm{ac}\boxed{S}\mathrm{abac} \Rightarrow_R \mathrm{acabac}$

$S \rightarrow \mathrm{a}ABc \mid \epsilon$
$A \rightarrow \mathrm{c}SB \mid Ab$
$B \rightarrow \mathrm{b}B \mid \mathrm{a}$

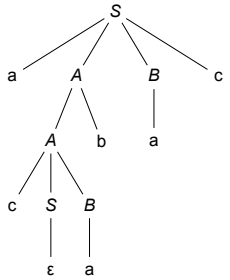

Διφορούμενες γραμματικές (i)

- Δύο γραμματικές είναι ισοδύναμες όταν παράγουν την ίδια γλώσσα.
- Μια γραμματική είναι διφορούμενη (ambiguous) αν υπάρχουν δύο ή περισσότερα συντακτικά δέντρα για την ίδια παραγόμενη συμβολοσειρά
- Γραμματικές και γλώσσες εγγενώς διφορούμενες (inherently ambiguous)
- Χρήση διφορούμενων γραμματικών στην περιγραφή της σύνταξης γλωσσών προγραμματισμού

Διφορούμενες γραμματικές (ii)

- Παράδειγμα: ξεκρέμαστο if (dangling if)

stmt → if *cond* *stmt* else *stmt* | if *cond* *stmt* | s1 | s2
cond → c1 | c2

- Διφορούμενο: σε ποιο if αντιστοιχεί το else;

if c1 if c2 s1 else s2

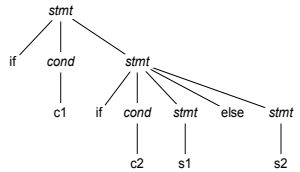

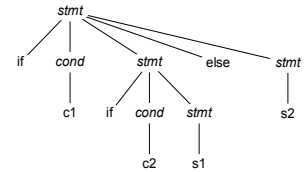

if c1 (if c2 s1 else s2) if c1 (if c2 s1) else s2

Τρόποι παράστασης γραμματικών (i)

- Backus-Naur Form (BNF)
  - Σύμβολο ::= στους κανόνες
  - Μη τερματικά σύμβολα σε γωνιακές παρενθέσεις, π.χ. ⟨expr⟩
  - Σύμβολο | για διάζευξη

⟨unsigned-number⟩ ::= ⟨integer-part⟩ ⟨dec-fraction⟩ ⟨exp-part⟩
⟨integer-part⟩ ::= ⟨digit⟩ ⟨integer-part⟩ | ⟨digit⟩
⟨dec-fraction⟩ ::= . ⟨integer-part⟩ | ϵ
⟨exp-part⟩ ::= **E** ⟨sign⟩ ⟨integer-part⟩
| **e** ⟨sign⟩ ⟨integer-part⟩ | ϵ
⟨sign⟩ ::= + | − | ϵ
⟨digit⟩ ::= **0** | **1** | **2** | **3** | **4** | **5** | **6** | **7** | **8** | **9**

Τρόποι παράστασης γραμματικών (ii)

- Extended Backus-Naur Form (EBNF)
  - Τερματικά σύμβολα σε εισαγωγικά
  - Παρενθέσεις για ομαδοποίηση
  - Αγκύλες για προαιρετικά τμήματα
  - Σύμβολα * και + για επανάληψη

⟨unsigned-number⟩ ::= ⟨digit⟩$^+$ ["." ⟨digit⟩$^+$]
[("**E**" | "**e**") ["+" | "−"] ⟨digit⟩$^+$]
⟨digit⟩ ::= "**0**" | "**1**" | "**2**" | "**3**" | "**4**"
| "**5**" | "**6**" | "**7**" | "**8**" | "**9**"

Τρόποι παράστασης γραμματικών (iii)

- Συντακτικά διαγράμματα
  - Τερματικά σύμβολα σε οβάλ
  - Μη τερματικά σύμβολα σε ορθογώνια
  - Διαδοχή συμβόλων (παράθεση) με βέλη

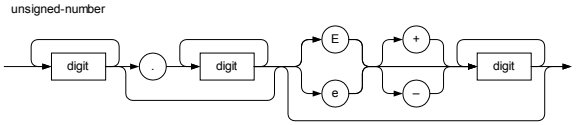

Κεφάλαιο 4:
Συντακτική ανάλυση

Συντακτική ανάλυση

- Συντακτικό δέντρο (parse tree)
- Κατασκευάζεται με δύο τρόπους:
  - Καθοδικά — Από πάνω προς τα κάτω (top-down)
    δηλαδή ξεκινώντας από τη ρίζα και
    προχωρώντας προς τα φύλλα
  - Ανοδικά — Από κάτω προς τα πάνω (bottom-up)
    δηλαδή ξεκινώντας από τα φύλλα και
    προχωρώντας προς τη ρίζα

Top-down και bottom-up

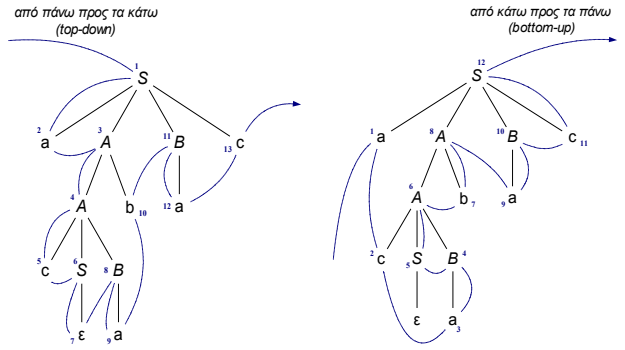

Βοηθητικές έννοιες (i)

- Σύνολα FIRST
  - Έστω συμβολοσειρά $\alpha \in (T \cup N)^*$
  - Το σύνολο $\text{FIRST}(\alpha) \subseteq T \cup \{\epsilon\}$ περιέχει τα τερματικά σύμβολα από τα οποία αρχίζουν οι συμβολοσειρές που παράγονται από την α

  - Αν $\alpha \Rightarrow^* \mathtt{a}\beta$ τότε $\mathtt{a} \in \text{FIRST}(\alpha)$
  - Αν $\alpha \Rightarrow^* \epsilon$ τότε $\epsilon \in \text{FIRST}(\alpha)$

Βοηθητικές έννοιες (ii)

- Σύνολα FOLLOW
  - Έστω μη τερματικό σύμβολο A
  - Το σύνολο $\text{FOLLOW}(A) \subseteq T \cup \{\mathtt{EOF}\}$ περιέχει τα τερματικά σύμβολα που μπορούν να ακολουθούν το A στη διάρκεια μιας παραγωγής
  - Αν το A μπορεί να είναι το τελευταίο σύμβολο σε μια παραγωγή, τότε $\mathtt{EOF} \in \text{FOLLOW}(A)$

  - Αν $S \Rightarrow^* \alpha A \mathtt{a} \beta$ τότε $\mathtt{a} \in \text{FOLLOW}(A)$
  - Αν $S \Rightarrow^* \alpha A$ τότε $\mathtt{EOF} \in \text{FOLLOW}(A)$

Υπολογισμός FIRST (i)

- $\text{FIRST}(\epsilon) = \{\epsilon\}$
- $\text{FIRST}(\mathtt{a}\beta) = \{\mathtt{a}\}$
- αν $\epsilon \notin \text{FIRST}(A)$
  τότε $\text{FIRST}(A\beta) = \text{FIRST}(A)$
- αν $\epsilon \in \text{FIRST}(A)$
  τότε $\text{FIRST}(A\beta) = (\text{FIRST}(A) - \{\epsilon\}) \cup \text{FIRST}(\beta)$
- για κάθε κανόνα $A \to \alpha$, πρέπει $\text{FIRST}(\alpha) \subseteq \text{FIRST}(A)$

Υπολογισμός FIRST (ii)

- Παράδειγμα

$\text{FIRST}(E) = \{\text{id}, (\}$
$\text{FIRST}(T) = \{\text{id}, (\}$
$\text{FIRST}(F) = \{\text{id}, (\}$
$\text{FIRST}(E') = \{+, \epsilon\}$
$\text{FIRST}(T') = \{*, \epsilon\}$

$E \rightarrow T\ E'$
$E' \rightarrow \epsilon$
$E' \rightarrow +\ T\ E'$
$T \rightarrow F\ T'$
$T' \rightarrow \epsilon$
$T' \rightarrow *\ F\ T'$
$F \rightarrow (\ E\ )$
$F \rightarrow \text{id}$

Υπολογισμός FOLLOW (i)

- $\texttt{EOF} \in \text{FOLLOW}(S)$
- για κάθε κανόνα $A \rightarrow \alpha B \beta$
  - $(\text{FIRST}(\beta) - \{\epsilon\}) \subseteq \text{FOLLOW}(B)$
  - αν $\epsilon \in \text{FIRST}(\beta)$
    τότε $\text{FOLLOW}(A) \subseteq \text{FOLLOW}(B)$

Υπολογισμός FOLLOW (ii)

- Παράδειγμα

$\text{FOLLOW}(E) = \{), \texttt{EOF}\}$
$\text{FOLLOW}(T) = \{+,), \texttt{EOF}\}$
$\text{FOLLOW}(F) = \{*, +,), \texttt{EOF}\}$
$\text{FOLLOW}(E') = \{), \texttt{EOF}\}$
$\text{FOLLOW}(T') = \{+,), \texttt{EOF}\}$

$\text{FIRST}(E') = \{+, \epsilon\}$
$\text{FIRST}(T') = \{*, \epsilon\}$

$E \rightarrow T\ E'$
$E' \rightarrow \epsilon$
$E' \rightarrow +\ T\ E'$
$T \rightarrow F\ T'$
$T' \rightarrow \epsilon$
$T' \rightarrow *\ F\ T'$
$F \rightarrow (\ E\ )$
$F \rightarrow \text{id}$

ΣΑ bottom-up (i)

- Η συντακτική ανάλυση ξεκινά από τα φύλλα
- Κάθε φορά, αναζητά:
  - τον αριστερότερο κόμβο του δέντρου
  - που δεν έχει ακόμα κατασκευαστεί
  - ενώ όλα τα παιδιά του έχουν κατασκευαστεί
- Επαναλαμβάνει μέχρι να κατασκευαστεί η ρίζα
- Ελάττωση (reducing): η επιλογή των κόμβων που θα αποτελέσουν τα παιδιά ενός νέου κόμβου

ΣΑ bottom-up (ii)

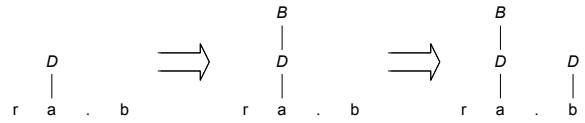

$S \rightarrow \text{r}\ B$
$B \rightarrow D \mid B\ ,\ D$
$D \rightarrow \text{a} \mid \text{b}$

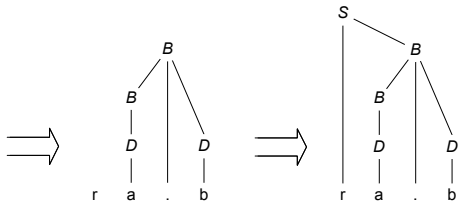

ΣΑ bottom-up (iii)

- ΣΑ ολίσθησης-ελάττωσης (shift-reduce)
  - Χρησιμοποιούν μια (αρχικά κενή) στοίβα όπου τοποθετούν σύμβολα της γραμματικής
  - Ολίσθηση (shift): μεταφορά ενός συμβόλου από την είσοδο στην κορυφή της στοίβας
  - Ελάττωση (reduce): αφαίρεση από την κορυφή της στοίβας του δεξιού μέλους ενός κανόνα και πρόσθεση του αριστερού μέλους
  - Επιτυχία: η στοίβα περιέχει μόνο το S και τα σύμβολα της εισόδου έχουν εξαντληθεί

ΣΑ bottom-up (iv)

$S \rightarrow$ r B

$B \rightarrow D \mid B$, D

$D \rightarrow$ a | b

βήμα	στοίβα	είσοδος	περιγραφή
0	ϵ	r a , b	ολίσθηση
1	r	a , b	ολίσθηση
2	r a	, b	ελάττωση με $D \rightarrow$ a
3	r D	, b	ελάττωση με $B \rightarrow D$
4	r B	, b	ολίσθηση
			(όχι ελάττωση με $S \rightarrow$ r B)
5	r B ,	b	ολίσθηση
6	r B , b	ϵ	ελάττωση με $D \rightarrow$ b
7	r B , D	ϵ	ελάττωση με $B \rightarrow B$, D
			(όχι ελάττωση με $B \rightarrow D$)
8	r B	ϵ	ελάττωση με $S \rightarrow$ r B
9	S	ϵ	αναγνώριση

ΣΑ bottom-up (v)

- LR(k)
- LR(0)
- SLR(1)
- LALR(1)
- LR(1)

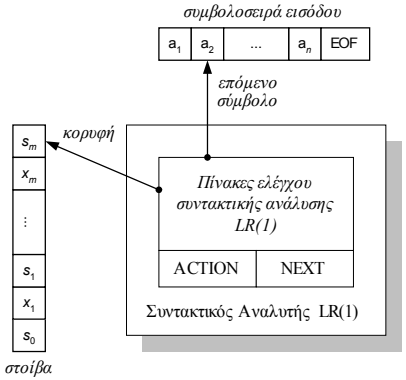

Υλοποίηση ΣΑ με το bison (i)

- Μεταεργαλείο bison: γεννήτορας ΣΑ LALR(1)
- Είσοδος: μεταπρόγραμμα που περιγράφει τη σύνταξη και τις σημασιολογικές ρουτίνες
- Έξοδος: πρόγραμμα σε C
  - Η συνάρτηση yyparse υλοποιεί το ΣΑ
  - Επιστρέφει 0 αν αναγνωριστεί η συμβολοσειρά εισόδου ή 1 σε περίπτωση συντακτικού σφάλματος
  - Συνεργάζεται με το λεκτικό αναλυτή (συνάρτηση yylex)

Υλοποίηση ΣΑ με το bison (ii)

- Δομή του μεταπρογράμματος

Μέρος Α
%%
Μέρος Β
%%
Μέρος Γ

Και τα τρία μέρη μπορούν να είναι κενά

Υλοποίηση ΣΑ με το bison (iii)

- Μέρος Α, περιέχει
  - Σχόλια, όπως στη C
  - Κώδικα C, μέσα σε %{ και %}
  - Δηλώσεις λεκτικών μονάδων
  - Δηλώσεις τελεστών της αρχικής γλώσσας (προτεραιότητα, προσεταιριστικότητα)
  - Δήλωση του συνόλου σημασιολογικών τιμών (τύπος YYSTYPE ή με χρήση του %union)
  - Δήλωση του τύπου της σημασιολογικής τιμής κάθε συμβόλου

Υλοποίηση ΣΑ με το bison (iv)

- Μέρος Α, παράδειγμα

```
%{
void ERROR (const char msg []);
%}

%token T_program "program"
%token T_div T_mod
%token T_if T_then T_else

%nonassoc '=' '<' '>'
%left '+' '-'
%left '*' '/' T_div T_mod
```

Υλοποίηση ΣΑ με το bison (v)

- Μέρος Α, παράδειγμα *(συνέχεια)*

```
%union{
  int i;
  double f;
  char str[80];
}

%token<str> T_id
%token<i>   T_int_const
%token<f>   T_float_const

%type<f>    expression
```


Υλοποίηση ΣΑ με το bison (vi)

- Μέρος Β, περιέχει:
  - τους κανόνες παραγωγής σε μορφή BNF
  - σημασιολογικές ρουτίνες που εκτελούνται κατά τη συντακτική ανάλυση
- Οι κανόνες έχουν τη μορφή:

$$\begin{array}{rcl} A & : & x_1^1\ x_2^1\ \ldots\ x_{m_1}^1 \\ & | & x_1^2\ x_2^2\ \ldots\ x_{m_2}^2 \\ & & \ldots \\ & | & x_1^n\ x_2^n\ \ldots\ x_{m_n}^n \\ & ; & \end{array}$$

Υλοποίηση ΣΑ με το bison (vii)

- Μέρος Β, παράδειγμα

```
program    : { count=0; } block_list
             { printf("Counted %d block(s)\n",
                      count); }
           ;

block_list : /* nothing */
           | block_list block { count++; }
           ;

block      : "begin" block_list "end"
           ;
```


Υλοποίηση ΣΑ με το bison (viii)

- Μέρος Γ, περιέχει κώδικα C
- Το μεταπρόγραμμα του bison αναλαμβάνει τον κεντρικό έλεγχο του μεταγλωττιστή που επιτυγχάνεται με τη συνεργασία των παρακάτω:
  - του λεκτικού αναλυτή
  - του συντακτικού αναλυτή
  - του πίνακα συμβόλων
  - του σημασιολογικού αναλυτή
  - του γεννήτορα ενδιάμεσου κώδικα

Υλοποίηση ΣΑ με το bison (ix)

- Μέρος Γ, παράδειγμα

```
void yyerror (const char * msg)
{
   fprintf(stderr,
           "syntax error in line %d: %s\n",
           linecount, msg);
   exit(1);
}

int main ()
{
   return yyparse();
}
```


Υλοποίηση ΣΑ με το bison (x)

- Παράδειγμα με σημασιολογικές τιμές

$E \rightarrow T$
$E \rightarrow E + T$
$T \rightarrow F$
$T \rightarrow T * F$
$F \rightarrow (E)$
$F \rightarrow \text{num}$

- Ζητούμενο: να κατασκευαστεί ΣΑ που να υπολογίζει την τιμή μιας αριθμητικής έκφρασης

Υλοποίηση ΣΑ με το bison (xi)

- Παράδειγμα *(συνέχεια)*

```
%{
typedef int YYSTYPE;
%}

%token T_num

%%

program :
   expression { printf("Value: %d\n", $1); }
 ;
```


Υλοποίηση ΣΑ με το bison (xii)

- Παράδειγμα *(συνέχεια)*

```
expression :
   term { $$ = $1; }
 | expression '+' term { $$ = $1 + $3; }
 ;

term :
   factor { $$ = $1; }
 | term '*' factor { $$ = $1 * $3; }
 ;
```


Υλοποίηση ΣΑ με το bison (xiii)

- Παράδειγμα *(συνέχεια)*

```
factor :
   '(' expression ')' { $$ = $2; }
 | T_num { $$ = $1; }
 ;

%%
```

- Παραλείπονται στο Μέρος Γ:
  - η συνάρτηση yylex (πιθανώς σε ξεχωριστό αρχείο, αν χρησιμοποιηθεί το flex)
  - οι συναρτήσεις yyerror και main

Υλοποίηση ΣΑ με το bison (xiv)

- Παράδειγμα — Υλοποίηση ΛΑ χειρωνακτικά

```
int yylex ()
{
  int c;

  while (isspace(c = fgetc(stdin)));
  if (isdigit(c)) {
    yylval = c - '0';
    while (isdigit(c = fgetc(stdin)))
      yylval = yylval * 10 + c - '0';
    ungetc(c, stdin);
    return T_num;
  }
```

Στο μέρος Γ

Υλοποίηση ΣΑ με το bison (xv)

- Παράδειγμα *(συνέχεια)*

```
  if (strchr("+*()", c)) return c;
  if (c != EOF)
    fprintf(stderr, "Illegal character: %c\n", c);
  return 0;
}
```

- Αυτοματοποίηση της μεταγλώττισης του ΣΑ

```
mytest1: mytest1.y
         bison mytest1.y
         gcc -o mytest1 mytest1.tab.c
```

Makefile

Υλοποίηση ΣΑ με το bison (xvi)

- Παράδειγμα — Υλοποίηση ΛΑ με το flex

```
%{
#include "mytest2.tab.h"
%}

%%

[0-9]+ { yylval = atoi(yytext); return T_num; }

\(|\)|\+|\* { return yytext[0]; }
[ \t\n]+    { /* nothing */ }
.           { yyerror("illegal character"); }

%%
```

mytest2.l

Υλοποίηση ΣΑ με το bison (xvii)

- Αυτοματοποίηση της μεταγλώττισης ΛΑ και ΣΑ

Makefile

```
mytest2: mytest2.l mytest2.y
        bison -d mytest2.y
        flex -s mytest2.l
        gcc -o mytest2 mytest2.tab.c lex.yy.c \
               -lfl
```

- Επίλυση συγκρούσεων στο bison
  - shift-reduce: πάντα reduce
  - reduce-reduce: ο πρώτος κανόνας

ΣΑ top-down (i)

- Η συντακτική ανάλυση ξεκινά από τη ρίζα
- Κάθε φορά, αναζητά:
  - το μη τερματικό σύμβολο που θα αντικατασταθεί
    - ⇒ συνήθως επιλέγεται το αριστερότερο
  - τον κανόνα παραγωγής που θα εφαρμοστεί
    - ⇒ βάσει των επόμενων k λεκτικών μονάδων στη συμβολοσειρά εισόδου: LL(k)
- Επαναλαμβάνεται μέχρι να εξαντληθούν τα μη τερματικά

Γραμματικές LL(1)

- Απαραίτητες προϋποθέσεις:
  - Απουσία αριστερής αναδρομής (άμεσης ή έμμεσης)
  - Απουσία κοινού προθέματος σε εναλλακτικούς κανόνες
- Μερικές φορές είναι δυνατός ο μετασχηματισμός μιας γραμματικής σε ισοδύναμη LL(1)
  - ⇒ απαλοιφή αριστερής αναδρομής
  - ⇒ αριστερή παραγοντοποίηση

Μετασχηματισμός σε LL(1)

- Αντικατάσταση

$$\begin{array}{l} A \to \alpha_1 \mid \ldots \mid \alpha_n \\ B \to \beta_1 A \beta_2 \end{array} \Rightarrow \begin{array}{l} A \to \alpha_1 \mid \ldots \mid \alpha_n \\ B \to \beta_1\alpha_1\beta_2 \mid \ldots \mid \beta_1\alpha_n\beta_2 \end{array}$$

- Αριστερή παραγοντοποίηση

$$A \to \alpha\beta_1 \mid \ldots \mid \alpha\beta_n \Rightarrow \begin{array}{l} A \to \alpha B \\ B \to \beta_1 \mid \ldots \mid \beta_n \end{array}$$

- Απαλοιφή άμεσης αριστερής αναδρομής

$$\begin{array}{l} A \to A\alpha_1 \mid \ldots \mid A\alpha_n \mid \beta_1 \mid \ldots \mid \beta_m \\ \Rightarrow \quad \begin{array}{l} A \to \beta_1 B \mid \ldots \mid \beta_m B \\ B \to \alpha_1 B \mid \ldots \mid \alpha_n B \mid \epsilon \end{array} \end{array}$$

ΣΑ αναδρομικής κατάβασης

$A \to \alpha_1 \mid \ldots \mid \alpha_n$

μετατρέπεται σε κώδικα της μορφής:

if $token \in \text{FIRST}(\alpha_1)$ **then**
  κώδικας για την αναγνώριση της α_1
  ...
else if $token \in \text{FIRST}(\alpha_n)$ **then**
  κώδικας για την αναγνώριση της α_n
else if $\epsilon \notin \text{FIRST}(\alpha_1) \cup \ldots \cup \text{FIRST}(\alpha_n)$ **then**
  συντακτικό σφάλμα
else if $token \notin \text{FOLLOW}(A)$ **then**
  συντακτικό σφάλμα
end if

ΣΑ LL(1) (i)

- Χρησιμοποιούν μια στοίβα όπου τοποθετούν σύμβολα της γραμματικής — αρχικά μόνο το S
- Κάθε φορά εξετάζεται η κορυφή της στοίβας:
  - Αν είναι τερματικό σύμβολο και είναι το ίδιο με το επόμενο της συμβολοσειράς εισόδου, τότε αφαιρούνται και τα δύο
  - Αν είναι μη τερματικό σύμβολο, τότε ανάλογα με το επόμενο της συμβολοσειράς εισόδου εφαρμόζεται κάποιος κανόνας
- Επιτυχία: η στοίβα και η συμβολοσειρά εισόδου είναι άδειες

ΣΑ LL(1) (ii)

Ο αλγόριθμος κατασκευής του πίνακα M ορίζει την οικογένεια των γλωσσών LL(1)

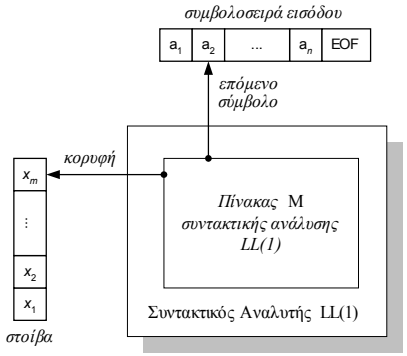

Κατασκευή ΣΑ LL(1)

$E \rightarrow T\ E'$
$E' \rightarrow +\ T\ E' \mid \epsilon$
$T \rightarrow F\ T'$
$T' \rightarrow *\ F\ T' \mid \epsilon$
$F \rightarrow (\ E\ ) \mid \mathtt{id}$

$\mathrm{FIRST}(E) = \mathrm{FIRST}(T) = \mathrm{FIRST}(F) = \{\mathtt{id}, (\}$
$\mathrm{FIRST}(E') = \{+, \epsilon\}$
$\mathrm{FIRST}(T') = \{*, \epsilon\}$
$\mathrm{FOLLOW}(E) = \mathrm{FOLLOW}(E') = \{), \mathtt{EOF}\}$
$\mathrm{FOLLOW}(T) = \mathrm{FOLLOW}(T') = \{+,), \mathtt{EOF}\}$
$\mathrm{FOLLOW}(F) = \{*, +,), \mathtt{EOF}\}$

	id	+	*	(	)	EOF
E	$E \rightarrow TE'$			$E \rightarrow TE'$		
E'		$E' \rightarrow +TE'$			$E' \rightarrow \epsilon$	$E' \rightarrow \epsilon$
T	$T \rightarrow FT'$			$T \rightarrow FT'$		
T'		$T' \rightarrow \epsilon$	$T' \rightarrow *FT'$		$T' \rightarrow \epsilon$	$T' \rightarrow \epsilon$
F	$F \rightarrow \mathtt{id}$			$F \rightarrow (E)$		

Λειτουργία ΣΑ LL(1)

0	E	id + id * id EOF	$E \rightarrow T\ E'$
1	$E'\ T$	id + id * id EOF	$T \rightarrow F\ T'$
2	$E'\ T'\ F$	id + id * id EOF	$F \rightarrow \mathtt{id}$
3	$E'\ T'\ \mathtt{id}$	id + id * id EOF	
4	$E'\ T'$	+ id * id EOF	$T' \rightarrow \epsilon$
5	E'	+ id * id EOF	$E' \rightarrow +\ T\ E'$
6	$E'\ T\ +$	+ id * id EOF	
7	$E'\ T$	id * id EOF	$T \rightarrow F\ T'$
8	$E'\ T'\ F$	id * id EOF	$F \rightarrow \mathtt{id}$
9	$E'\ T'\ \mathtt{id}$	id * id EOF	
10	$E'\ T'$	* id EOF	$T' \rightarrow *\ F\ T'$
11	$E'\ T'\ F\ *$	* id EOF	
12	$E'\ T'\ F$	id EOF	$F \rightarrow \mathtt{id}$
13	$E'\ T'\ \mathtt{id}$	id EOF	
14	$E'\ T'$	EOF	$T' \rightarrow \epsilon$
15	E'	EOF	$E' \rightarrow \epsilon$
16	ϵ	EOF	αναγνώριση

Κεφάλαιο 2:
Τυπικές γλώσσες

(μέρος 3ο)

Κατηγορικές γραμματικές (i)

- Κατηγορική γραμματική (attribute grammar): γραμματική χωρίς συμφραζόμενα όπου κάθε σύμβολο φέρει ένα σύνολο κατηγορημάτων
- Οι τιμές των κατηγορημάτων υπολογίζονται βάσει του συντακτικού δέντρου:
  - Συνθετικά κατηγορήματα: οι τιμές τους εξαρτώνται μόνο από κατηγορήματα των παιδιών κάθε κόμβου
  - Κληρονομούμενα κατηγορήματα: οι τιμές τους εξαρτώνται μόνο από κατηγορήματα του "πατέρα" και των "αδελφών" κάθε κόμβου

Κατηγορικές γραμματικές (ii)

$E \rightarrow E + T \quad \{\ E^1.val := E^2.val + T.val\ \}$
$E \rightarrow T \quad \{\ E.val := T.val\ \}$
$T \rightarrow T * F \quad \{\ T^1.val := T^2.val * F.val\ \}$
$T \rightarrow F \quad \{\ T.val := F.val\ \}$
$F \rightarrow (\ E\ ) \quad \{\ F.val := E.val\ \}$
$F \rightarrow \mathtt{num} \quad \{\ F.val := \mathtt{num}.val\ \}$

Σημασιολογικοί κανόνες

Κεφάλαιο 5:
Πίνακας συμβόλων

Πίνακας συμβόλων

- Συγκεντρώνει πληροφορίες για τα ονόματα που εμφανίζονται στο αρχικό πρόγραμμα
- Ονόματα είναι:
  - το πρόγραμμα
  - οι μεταβλητές
  - τα υποπρογράμματα (διαδικασίες, συναρτήσεις)
  - οι παράμετροι των υποπρογραμμάτων
  - οι ετικέττες εντολών
  - οι σταθερές
  - οι τύποι δεδομένων

Χαρακτηριστικά ονομάτων

- Κατηγορία αποθήκευσης (storage class)
  - Καθολικές μεταβλητές (global variables)
  - Μεταβλητές στοίβας (stack variables)
  - Στατικές μεταβλητές (static variables)
- Εμβέλεια (scope)
- Ορατότητα (visibility)
- Διάρκεια ζωής (lifetime)

Περιεχόμενα πίνακα συμβόλων

- Εμβέλεια (έμμεσα)
- Ορατότητα (έμμεσα)
- Διάρκεια ζωής
- Τύπος
- Θέση (διεύθυνση μνήμης, καταχωρητής, ...)
- Αριθμός παραμέτρων υποπρογράμματος
- Τύπος παραμέτρων υποπρογράμματος
- Τρόπος περάσματος παραμέτρων υποπρογράμματος
- Τύπος αποτελέσματος συνάρτησης

Οργάνωση πίνακα συμβόλων

- Βασικές λειτουργίες
  - Προσθήκη ονόματος
  - Αναζήτηση ονόματος
  - Διαγραφή ονόματος ή ομάδας ονομάτων
- Κόστος προσθήκης ή αναζήτησης ανάλογα με την υλοποίηση:

γραμμική λίστα	$O(n)$
δυαδικό δέντρο αναζήτησης	$O(\log n)$
πίνακας κατακερματισμού	$O(n/k)$

Υλοποίηση με ΠΚ

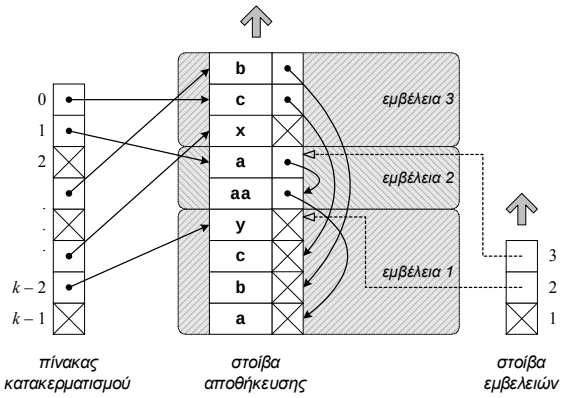

Κεφάλαιο 6:
Σημασιολογική ανάλυση

Σύνταξη και σημασιολογία

- Σύνταξη: μορφή και δομή των καλώς σχηματισμένων προγραμμάτων
- Σημασιολογία: ερμηνεία των καλώς σχηματισμένων προγραμμάτων
  - Στατική σημασιολογία: εντοπισμός σημασιολογικών σφαλμάτων κατά τη διάρκεια της μεταγλώττισης
  - Δυναμική σημασιολογία: απόδοση ερμηνείας στα προγράμματα κατά την εκτέλεσή τους

Στατική σημασιολογία (i)

- Περιβάλλοντα τύπων

$$\Gamma_1 \;=\; \{\, \mathtt{i} \mapsto \mathit{integer}, \mathtt{x} \mapsto \mathit{real} \,\}$$

- Σχέση αντιστοίχισης τύπων

$$\Gamma \vdash E : \tau$$

- Κανόνες τύπων

$$\frac{\Gamma \vdash E_1 : \mathit{integer} \qquad \Gamma \vdash E_2 : \mathit{integer}}{\Gamma \vdash E_1 \texttt{+} E_2 : \mathit{integer}}$$

Στατική σημασιολογία (ii)

- Παραγωγές τύπων

$$\frac{\dfrac{\Gamma_1 \vdash \mathtt{i} : \mathit{integer} \qquad \Gamma_1 \vdash \mathtt{1} : \mathit{integer}}{\Gamma_1 \vdash \mathtt{i+1} : \mathit{integer}} \qquad \Gamma_1 \vdash \mathtt{x} : \mathit{real}}{\Gamma_1 \vdash \mathtt{(i+1)*x} : \mathit{real}}$$

- Η αντιστοίχιση τύπων με κανόνες τύπων επεκτείνεται σε όλα τα τμήματα προγράμματος

$$\frac{\Gamma \vdash E : \mathit{boolean} \qquad \Gamma \vdash S : \mathit{stmt}}{\Gamma \vdash \mathtt{while}\ E\ \mathtt{do}\ S : \mathit{stmt}}$$

Δυναμική σημασιολογία (i)

- Λειτουργική σημασιολογία (operational semantics)
  - ⇒ ακολουθία υπολογιστικών βημάτων
- Δηλωτική σημασιολογία (denotational semantics)
  - ⇒ μαθηματική συνάρτηση από το πεδίο των δεδομένων εισόδου στο πεδίο των αποτελεσμάτων
- Αξιωματική σημασιολογία (axiomatic semantics)
  - ⇒ η ερμηνεία καθορίζεται έμμεσα μέσω λογικών προτάσεων που περιγράφουν ιδιότητες του προγράμματος

Δυναμική σημασιολογία (ii)

- Η εντολή ανάθεσης I=E
  - Λειτουργική σημασιολογία

$$\frac{\langle E, \sigma \rangle \;\rightarrow\; v}{\langle I\texttt{=}E, \sigma \rangle \;\rightarrow\; \sigma[I \mapsto v]}$$

  - Δηλωτική σημασιολογία

$$\mathcal{C}[\![I\texttt{=}E]\!](s) \;=\; s[I \mapsto \mathcal{E}[\![E]\!](s)]$$

  - Αξιωματική σημασιολογία

$$\{\, P[I \mapsto E] \,\}\ I\texttt{=}E\ \{\, P \,\}$$

Σημασιολογικός έλεγχος (i)

- Έλεγχος τύπων
  π.χ. οι τελεστές εφαρμόζονται σε κατάλληλα τελούμενα
- Έλεγχος ροής
  π.χ. όχι continue έξω από βρόχο (C)
  π.χ. οι μεταβλητές αρχικοποιούνται πριν τη χρήση (Java)
- Έλεγχος ύπαρξης ονομάτων
  π.χ. οι μεταβλητές ορίζονται πριν τη χρήση τους
- Έλεγχος μοναδικότητας
  π.χ. οι σταθερές σε μία δομή case είναι μοναδικές (Pascal)
- Έλεγχος συνέπειας
  π.χ. σωστό όνομα υποπρογράμματος στο end (Ada)

Σημασιολογικός έλεγχος (ii)

- Απουσία σημασιολογικών σφαλμάτων $\not\Rightarrow$ απουσία σφαλμάτων εκτέλεσης
- Μερικές φορές όμως είναι δυνατό να προβλεφθούν σφάλματα εκτέλεσης

```
program p;
var x, y : integer;
begin
   read(x);
   y := 5/(x-x)
end.
```


Σύστημα τύπων

- Βασικοί τύποι (integer, boolean, real, char, ...)
- Σύνθετοι τύποι
  - Πίνακες (arrays)
  - Ζεύγη (products) και πλειάδες (tuples)
  - Εγγραφές (records)
  - Δείκτες (pointers)
  - Συναρτήσεις (functions)
- Τύποι και τιμές πρώτης τάξης (first class)

Απλές εκφράσεις, βασικοί έλεγχοι (i)

- Σημασιολογική ανάλυση στο bison
- Σκοπός: υπολογισμός του πεδίου type

```
%{
typedef enum { TY_int, TY_real, TY_bool } Type;
%}

%union{
  char * n;
  Type t;
  struct { Type type; /* other fields */ } v;
  ...
}

%type<n> T_id
%type<t> typename
%type<v> expression
```


Απλές εκφράσεις, βασικοί έλεγχοι (ii)

```
expression :
    T_intconst          { $$.type = TY_int;  }
  | T_realconst         { $$.type = TY_real; }
  | '(' expression ')'  { $$.type = $2.type; } ;


expression : T_id
  {
    Entry * id = lookup($1);

    if (id != NULL && id->kind == K_variable)
      $$.type = id->type;
    else
      yyerror("identifier not found");
  } ;
```


Απλές εκφράσεις, βασικοί έλεγχοι (ii)

```
expression : expression "mod" expression
  {
    if ($1.type == TY_int && $3.type == TY_int)
      $$.type = TY_int;
    else
      yyerror("type mismatch");
  } ;


statement : "while" expression "do" statement
  {
    if ($2.type != TY_bool)
      yyerror("condition type mismatch")
  } ;
```

Μετατροπές τύπων

(Type casting)

```
expression : '(' typename ')' expression
  {
    if (isCastAllowed($2, $4.type))
      $$.type = $2;
    else
      yyerror("illegal type cast");
  } ;
```


Υπερφόρτωση τελεστών

(Overloading)

```
expression : expression '+' expression
  {
    if ($1.type == TY_int)
      if ($3.type == TY_int)       $$.type = TY_int;
      else if ($3.type == TY_real) $$.type = TY_real;
      else yyerror("type mismatch");
    else if ($1.type == TY_real)
      if ($3.type == TY_int)       $$.type = TY_real;
      else if ($3.type == TY_real) $$.type = TY_real;
      else yyerror("type mismatch");
    else
      yyerror("type mismatch");
  } ;
```


Πολυμορφικοί τελεστές

(Polymorphic operators)

```
typedef struct type_str {
   enum { TY_integer, TY_real, TY_boolean, TY_ptr } code;
   struct type_str * ptr_type;
} Type;

expression : expression '^'
  {
    if ($1.type.code == TY_ptr)
      $$.type = *($$.type.ptr_type);
    else
      yyerror("type mismatch");
  } ;
```


Συνώνυμα και ισοδυναμία τύπων

- Συνώνυμα τύπων (type aliases)

```
type complex = record
                 re, im : real
               end;
```

- Ισοδυναμία τύπων (type equivalence)
  - Δομική ισοδυναμία
  - Ονομαστική ισοδυναμία
  - (Δηλωτική ισοδυναμία)

Υποσύνολα τύπων και υποτύποι

(Subset types and subtyping)

```
var indexSmall   : 1..10;
    indexLarge   : 1..1000;
    indexGeneral : integer;

indexGeneral := indexSmall
indexLarge := indexGeneral
```

- Υποτύποι
  - ⇒ κυρίως σε αντικειμενοστρεφείς γλώσσες

Πολυμορφικοί τύποι

(Polymorphic types)

- Παραμετρικός πολυμορφισμός (templates, generics)

```
template <class T>
bool exists (int length, T array [], T element)
{
   for (int i=0; i < length; i++)
      if (array[i] == element)
         return true;
   return false;
}
```

- Συναρτησιακές γλώσσες

Αντιστοίχιση τύπων

- Στατική
- Δυναμική

Εξαγωγή τύπων

(Type inference)

Δυναμικός έλεγχος τύπων

- Επιβάλλεται όταν υπάρχει δυναμική αντιστοίχιση τύπων
- Πολλές φορές όμως απαιτείται και σε στατική αντιστοίχιση τύπων, π.χ. έλεγχος ορίων σε arrays της Pascal:

```
a[i] := 42
```

if `i` ≥ 0 και `i` ≤ 100 **then**
  κώδικας για την ανάθεση του 42 στο `a[i]`
else
  σφάλμα εκτέλεσης
end if