Μεταγλωττιστές

Νίκος Παπασπύρου
nickie@softlab.ntua.gr

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

Εισαγωγή (i)

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

Εισαγωγή (ii)

- 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 της μεταγλώττισης

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

Φάσεις και προϊόντα

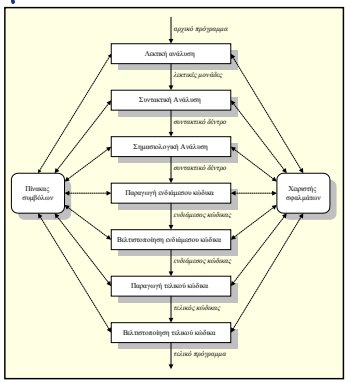

Θέματα υλοποίησης

- 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.

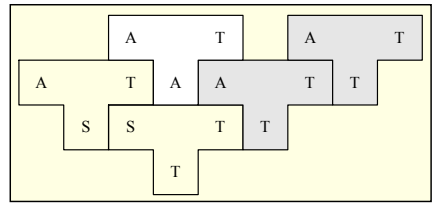

Οργάνωση σε ένα πέρασμα

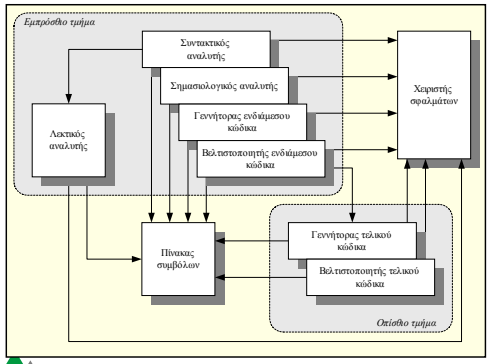

Τυπικές γλώσσες

- 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: $L(G) = \{\, \alpha \in T^* \mid S \Rightarrow^+ \alpha \,\}$

Ιεραρχία Chomsky

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

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

- Κανονικές εκφράσεις (regular expressions)
  - Κενή συμβολοσειρά: ϵ
  - Κάθε σύμβολο: $a \in \Sigma$
  - Παράθεση δύο κανονικών εκφράσεων: (rs)
  - Διάζευξη δύο κανονικών εκφράσεων: $(r|s)$
  - Κλείσιμο (ή άστρο) Kleene: (r^*)
- Συντομογραφίες:
  - απαλοιφή περιττών παρενθέσεων
  - r^+ $[a_1, a_2, \ldots, a_n]$ $r?$.

Πεπερασμένα αυτόματα

- Καταστάσεις και μεταβάσεις
- Ντετερμινιστικά (ΝΠΑ), μη ντετερμινιστικά (ΜΠΑ) και ΜΠΑ με κενές μεταβάσεις (ΜΠΑ-ϵ)

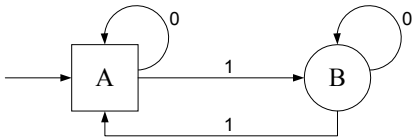

- Η γλώσσα των συμβολοσειρών που αποτελούνται από 0 και 1 και περιέχουν άρτιο αριθμό 1

Αναγωγές και ισοδυναμίες

- κανονική γραμματική $\Rightarrow$ ΜΠΑ-ϵ
- ΜΠΑ-ϵ $\Rightarrow$ κανονική γραμματική
- κανονική έκφραση $\Rightarrow$ ΜΠΑ-ϵ
- ΜΠΑ-ϵ $\Rightarrow$ κανονική έκφραση
- ΜΠΑ-ϵ $\Rightarrow$ ΝΠΑ
- Ελαχιστοποίηση ΝΠΑ

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

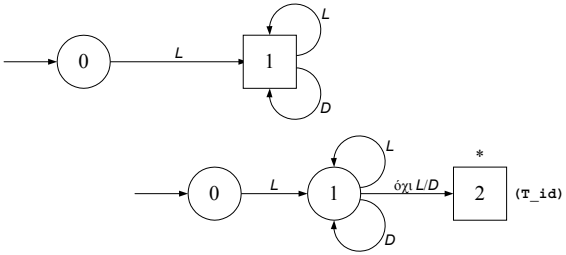

Διαγράμματα μετάβασης (ii)

- Τελεστές $>$ και $>=$

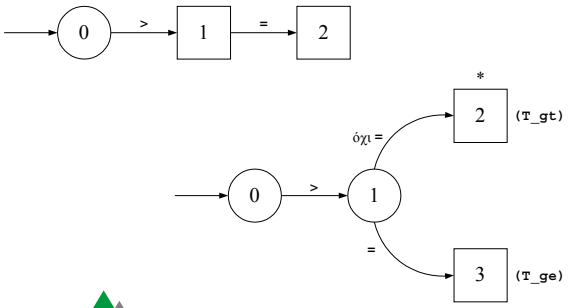

Κατασκευή του ΛΑ (i)

- Καταγραφή και ταξινόμηση χαρακτήρων

$$mapping \ : \ (\text{ASCII} \cup \{\texttt{EOF}\}) \rightarrow \Sigma$$

- 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

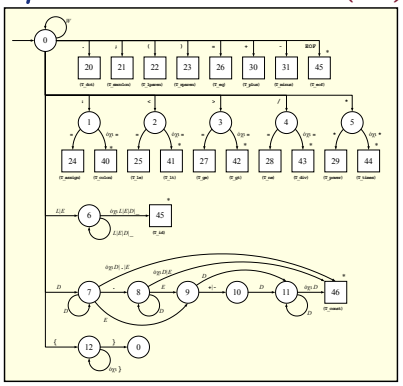

Κατασκευή του ΛΑ (iv)

- 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.

Υλοποίηση ΛΑ με το flex (vii)

- Κανονικές εκφράσεις (συνέχεια)

`[^a-z]`	Ένας από τους χαρακτήρες εκτός όσων ανήκουν στην περιοχή a έως z.
`{name}`	Η κανονική έκφραση με μνημονικό όνομα name.
rs	Η παράθεση των r και s.
$r\|s$	Η διάζευξη των r και s.
r/s	Η κανονική έκφραση r αλλά μόνο αν ακολουθεί η κανονική έκφραση s.
(r)	Η κανονική έκφραση r. Οι παρενθέσεις χρησιμοποιούνται για ομαδοποίηση.

Υλοποίηση ΛΑ με το flex (viii)

- Κανονικές εκφράσεις (συνέχεια)

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.
^r	Η r αλλά μόνο στην αρχή μιας γραμμής.
$r$$	Η r αλλά μόνο στο τέλος μιας γραμμής.

Υλοποίηση ΛΑ με το flex (ix)

- Κανονικές εκφράσεις (συνέχεια)

<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.
<<EOF>>	Το τέλος του αρχείου εισόδου.

Υλοποίηση ΛΑ με το flex (x)

- 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 (xi)

- Μέρος Γ, περιέχει κώδικα C
- Παράδειγμα

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


Υλοποίηση ΛΑ με το flex (xii)

- 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 (xiii)

- 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 (xiv)

- 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 (xv)

- Παράδειγμα: Αρίθμηση γραμμών (διόρθωση)

```
%x COMMENT

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


Γλώσσες χωρίς συμφραζόμενα

- Γραμματικές χωρίς συμφραζόμενα: $A \to \alpha$
- Αριστερότερη / δεξιότερη παραγωγή (leftmost / rightmost derivation)
- Συντακτικά δέντρα (parse trees)

$S \Rightarrow_L aABC \Rightarrow_L aAbBc$
$\Rightarrow_L acSBbBc \Rightarrow_L acBbBc$
$\Rightarrow_L acabBc \Rightarrow_L acabac$

$S \Rightarrow_R aABc \Rightarrow_R aAac$
$\Rightarrow_R aAbac \Rightarrow_R acSBbac$
$\Rightarrow_R acSabac \Rightarrow_R acabac$

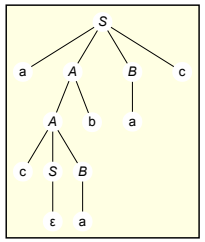

Διφορούμενες γραμματικές (i)

- Μια γραμματική είναι διφορούμενη (ambiguous) όταν υπάρχουν δύο ή περισσότερα συντακτικά δέντρα για την ίδια παραγόμενη συμβολοσειρά
- Γραμματικές και γλώσσες εγγενώς διφορούμενες (inherently ambiguous)
- Παράδειγμα διφορούμενης γραμματικής: ξεκρέμαστο if (dangling if)

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

και η συμβολοσειρά: if c1 if c2 s1 else s2

Διφορούμενες γραμματικές (ii)

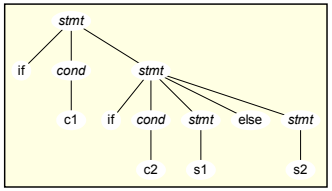

if c1 (if c2 s1 else s2)

if c1 (if c2 s1) else s2

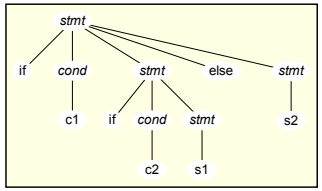

Συμβολισμός BNF/EBNF

- Backus-Naur Form
  - Σύμβολο ::= στους κανόνες
  - Μη τερματικά σύμβολα σε γωνιακές παρενθέσεις, π.χ. ⟨expr⟩
  - Σύμβολο | για διάζευξη
- Extended Backus-Naur Form
  - Τερματικά σύμβολα σε εισαγωγικά
  - Παρενθέσεις για ομαδοποίηση
  - Αγκύλες για προαιρετικά τμήματα
  - Σύμβολα ∗ και + για επανάληψη

Συντακτική ανάλυση

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

Top-down και bottom-up

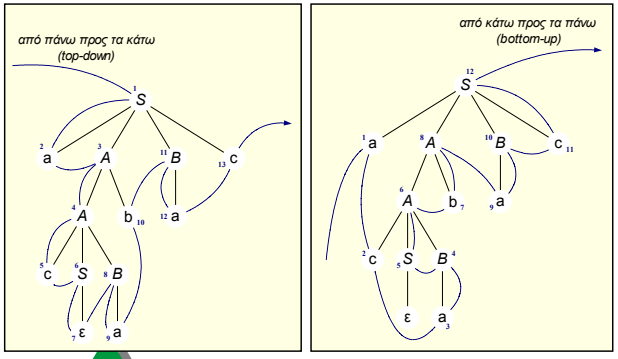

Βοηθητικές έννοιες (i)

- 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 $\alpha \Rightarrow \epsilon$, τότε $\epsilon \in \text{FIRST}(\alpha)$

Βοηθητικές έννοιες (ii)

- Σύνολα FOLLOW
  - Έστω μη τερματικό σύμβολο A
  - Το σύνολο $\text{FOLLOW}(A) \subseteq (T \cup \{\texttt{EOF}\})$ 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 $\texttt{EOF} \in \text{FOLLOW}(A)$

Υπολογισμός FIRST (i)

- $\text{FIRST}(\epsilon) = \{\epsilon\}$
- $\text{FIRST}(\mathsf{a}\beta) = \{\mathsf{a}\}$
- 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

$$
\begin{aligned}
\text{FIRST}(E) &= \{\mathsf{id}, (\,\} \\
\text{FIRST}(T) &= \{\mathsf{id}, (\,\} \\
\text{FIRST}(F) &= \{\mathsf{id}, (\,\} \\
\text{FIRST}(E') &= \{+, \epsilon\} \\
\text{FIRST}(T') &= \{*, \epsilon\}
\end{aligned}
$$

$$
\begin{aligned}
E &\to T\ E' \\
E' &\to \epsilon \\
E' &\to +\ T\ E' \\
T &\to F\ T' \\
T' &\to \epsilon \\
T' &\to *\ F\ T' \\
F &\to (\ E\ ) \\
F &\to \mathsf{id}
\end{aligned}
$$

Υπολογισμός FOLLOW (i)

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

Υπολογισμός FOLLOW (ii)

- Παράδειγμα

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

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

$$
\begin{aligned}
E &\to T\ E' \\
E' &\to \epsilon \\
E' &\to +\ T\ E' \\
T &\to F\ T' \\
T' &\to \epsilon \\
T' &\to *\ F\ T' \\
F &\to (\ E\ ) \\
F &\to \text{id}
\end{aligned}
$$

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)

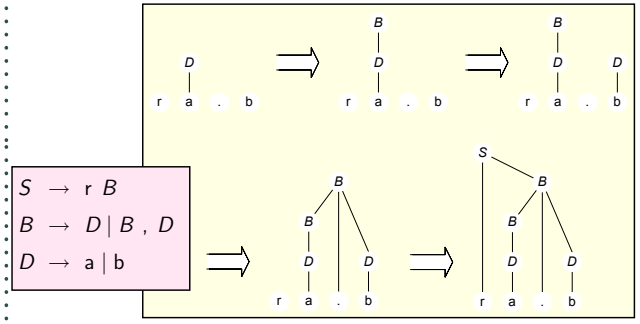

ΣΑ bottom-up (iii)

- 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)

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

shift/reduce conflict

reduce/reduce conflict

ΣΑ bottom-up (v)

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

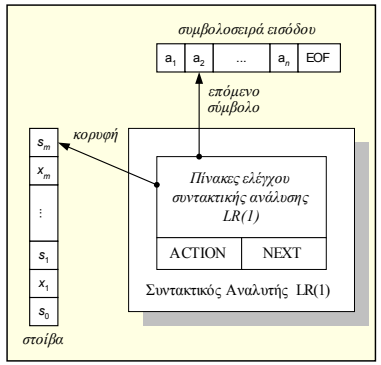

Υλοποίηση ΣΑ με το bison(i)

- 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:

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

Υλοποίηση ΣΑ με το bison(vii)

- 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(viii)

- 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(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

$$\begin{aligned} E &\rightarrow T \\ E &\rightarrow E + T \\ T &\rightarrow F \\ T &\rightarrow T * F \\ F &\rightarrow (E) \\ F &\rightarrow \text{num} \end{aligned}$$

- 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

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

Makefile

- 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

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

- Αριστερή παραγοντοποίηση

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

- Απαλοιφή άμεσης αριστερής αναδρομής

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

ΣΑ αναδρομικής κατάβασης

$A \rightarrow \alpha_1 \mid \ldots \mid \alpha_n$

μετατρέπεται σε κώδικα της μορφής:

αν $token \in \text{FIRST}(\alpha_1)$ **τότε**
  κώδικας για την αναγνώριση της α_1
  ...
αλλιώς αν $token \in \text{FIRST}(\alpha_n)$ **τότε**
  κώδικας για την αναγνώριση της α_n
αλλιώς αν $\epsilon \notin \text{FIRST}(\alpha_1) \cup \ldots \cup \text{FIRST}(\alpha_n)$ **τότε**
  συντακτικό σφάλμα
αλλιώς αν $token \notin \text{FOLLOW}(A)$ **τότε**
  συντακτικό σφάλμα
τέλος αν

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)

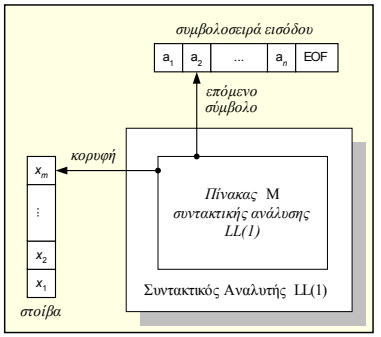

Κατασκευή ΣΑ LL(1)

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

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

	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	$F \rightarrow$ 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	$F \rightarrow$ id
3	$E'\ T'$ 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	$F \rightarrow$ id
9	$E'\ T'$ 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	$F \rightarrow$ id
13	$E'\ T'$ id	id EOF	
14	$E'\ T'$	EOF	$T' \rightarrow\ \epsilon$
15	E'	EOF	$E' \rightarrow\ \epsilon$
16	ϵ	EOF	αναγνώριση

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)

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

Σημασιολογικοί κανόνες

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	$\mathrm{O}(n)$
δυαδικό δέντρο αναζήτησης	$\mathrm{O}(\log n)$
πίνακας κατακερματισμού	$\mathrm{O}(n/k)$

Υλοποίηση με ΠΚ

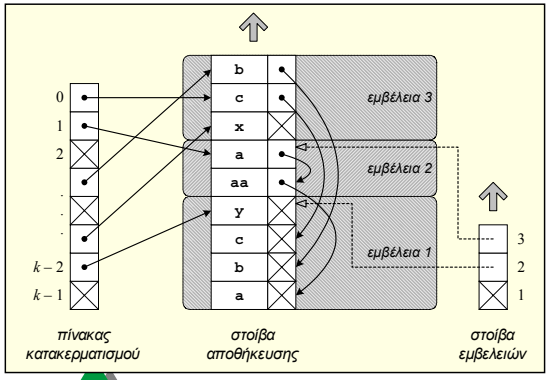

Σύνταξη και σημασιολογία

- 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

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

- 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

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

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

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

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

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

  - Δηλωτική σημασιολογία

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

  - Αξιωματική σημασιολογία

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

Σημασιολογικός έλεγχος

- Έλεγχος τύπων
- Έλεγχος ροής
- Έλεγχος ύπαρξης ονομάτων
- Έλεγχος μοναδικότητας
- Έλεγχος συνέπειας

Σύστημα τύπων (i)

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

Σύστημα τύπων (ii)

- Μετατροπές τύπων (type casting)
- Υπερφόρτωση τελεστών (operator overloading)
- Πολυμορφικοί τελεστές (polymorphic operators)
- Υποσύνολα τύπων και υπο-τύποι (subtypes)
- Πολυμορφικά συστήματα τύπων (polymorphic type systems)
- Στατική και δυναμική αντιστοίχιση τύπων (type binding)
- 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
```

  αν `i` ≥ 0 και `i` ≤ 100 **τότε**
    κώδικας για την ανάθεση του 42 στο `a[i]`
  αλλιώς
    σφάλμα εκτέλεσης
  τέλος αν

Έλεγχος και εξαγωγή τύπων

- Έλεγχος τύπων (type checking)
  - Δίνονται: Γ, E, τ
  - Ζητείται: η παραγωγή $\Gamma \vdash E : \tau$
  - Τί γίνεται αν δεν υπάρχει;
- Εξαγωγή τύπων (type inference)
  - Δίνονται: Γ, E
  - Ζητείται: τ και η παραγωγή $\Gamma \vdash E : \tau$
  - Τί γίνεται αν δεν υπάρχουν;

Εξαγωγή τύπων (i)

- Ιδέα: μετασχηματισμός του προβλήματος $\Gamma \vdash E : ?$ σε ένα σύνολο εξισώσεων
- Αν αυτό έχει λύση, βρίσκουμε ένα τ τέτοιο ώστε $\Gamma \vdash E : \tau$
- Διαφορετικά δεν υπάρχει τ τέτοιο ώστε $\Gamma \vdash E : \tau$

Εξαγωγή τύπων (ii)

- Επέκταση των τύπων με μεταβλητές τύπων

  $\tau ::= int \mid bool \mid \tau \to \tau \mid \alpha$
- Αντικατάσταση τύπων (type substitution): απεικόνιση μεταβλητών τύπων σε τύπους

  $\sigma = [\alpha \mapsto int, \beta \mapsto bool \to \alpha]$
- Εφαρμογή αντικατάστασης τύπων: ταυτόχρονα και μία φορά

  $\sigma(\alpha) = int \qquad \sigma(\beta) = bool \to \alpha$

  $\sigma(\beta \to \gamma) = (bool \to \alpha) \to \gamma$

Εξαγωγή τύπων (iii)

- Σύνθεση αντικαταστάσεων $\sigma_1 \circ \sigma_2$ έτσι ώστε $(\sigma_1 \circ \sigma_2)(\tau) = \sigma_1(\sigma_2(\tau))$
- Όπου παραλείπονται οι τύποι στο αρχικό πρόγραμμα, συμπληρώνουμε με φρέσκες μεταβλητές τύπων, έστω `@1`, `@2`, ...

```
let f g x = g x (x + 1)
and m a b = a * b
```

γίνεται:

```
let f (g : @1) (x : @2) : @3 = g x (x + 1)
and m (a : @4) (b : @5) : @6 = a * b
```


Εξαγωγή τύπων (iv)

- Το πρόβλημα $\Gamma \vdash E : ?$ ανάγεται στην εύρεση μιας αντικατάστασης σ και ενός τύπου τ ώστε $\sigma(\Gamma) \vdash \sigma(E) : \tau$
- Παράδειγμα

```
let f (g : @1) (x : @2) : @3 = g x (x + 1)
and m (a : @4) (b : @5) : @6 = a * b
in  f m 6
```

- Περιβάλλον για όλη την έκφραση: $\Gamma = \emptyset$
- Περιβάλλον για το σώμα `f m 6`: $\Gamma_b = \{\, \texttt{f} \mapsto \texttt{@1} \to \texttt{@2} \to \texttt{@3},\ \texttt{m} \mapsto \texttt{@4} \to \texttt{@5} \to \texttt{@6} \,\}$

Εξαγωγή τύπων (v)

- Παράδειγμα (συνέχεια)

```
let f (g : @1) (x : @2) : @3 = g x (x + 1)
and m (a : @4) (b : @5) : @6 = a * b
in  f m 6
```

- Μια λύση (η μοναδική)

  $\sigma = [\ \texttt{@1} \mapsto int \to int \to int,\ \texttt{@2} \mapsto int,\ \texttt{@3} \mapsto int,$
  $\texttt{@4} \mapsto int,\ \texttt{@5} \mapsto int,\ \texttt{@6} \mapsto int\ ]$

  $\tau = int$
- Γενικά οι λύσεις δεν είναι μοναδικές!

```
let f (x : @1) : @2 = x
```

Εξαγωγή τύπων (vi)

- Πώς βρίσκεται η λύση;
- Περιορισμός (constraint): εξίσωση τύπων $\tau_1 = \tau_2$
- Πρόβλημα 1: εύρεση συνόλου περιορισμών C

```
let f (g : @1) (x : @2) : @3 = g x (x + 1)
and m (a : @4) (b : @5) : @6 = a * b
in  f m 6
```

οδηγεί στο σύνολο περιορισμών:

$$C = \{\ \texttt{@1} = \texttt{@2} \to int \to \texttt{@3},\ \texttt{@2} = int,\ \texttt{@4} = int,\ \texttt{@5} = int,\ \texttt{@6} = int,\ \texttt{@1} = \texttt{@4} \to \texttt{@5} \to \texttt{@6},\ \texttt{@2} = int\ \}$$

Εξαγωγή τύπων (vii)

- Παραγωγή τύπων με περιορισμούς

$$\Gamma \vdash E : \tau' \mid C$$

- Πρόβλημα 2: επίλυση συνόλου περιορισμών
- Μια αντικατάσταση σ λέγεται ενοποιητής (unifier) για τον περιορισμό $\tau_1 = \tau_2$ αν οι τύποι $\sigma(\tau_1)$ και $\sigma(\tau_2)$ ταυτίζονται $\sigma(\tau_1) \equiv \sigma(\tau_2)$
- Λύση για το πρόβλημα της εξαγωγής τύπων:
  - ένας ενοποιητής σ για κάθε περιορισμό του C
  - ο τύπος $\tau = \sigma(\tau')$

Εξαγωγή τύπων (viii)

- Ενοποίηση: επίλυση συνόλου περιορισμών

unify$(\emptyset) = \sigma_0$ {η κενή αντικατάσταση}
unify$(\{\,\tau_1 = \tau_2\,\} \cup C) =$
  αν $\tau_1 \equiv \tau_2$ **τότε**
    unify(C)
  αλλιώς αν $\tau_1 \equiv \alpha$ και δεν εμφανίζεται στο τ_2 **τότε**
    unify$([\alpha \mapsto \tau_2]C) \circ [\alpha \mapsto \tau_2]$
  αλλιώς αν $\tau_2 \equiv \alpha$ και δεν εμφανίζεται στο τ_1 **τότε**
    unify$([\alpha \mapsto \tau_1]C) \circ [\alpha \mapsto \tau_1]$
  αλλιώς αν $\tau_1 \equiv \tau_{11} \to \tau_{12}$ και $\tau_2 \equiv \tau_{21} \to \tau_{22}$ **τότε**
    unify$(C \cup \{\,\tau_{11} = \tau_{21}, \tau_{12} = \tau_{22}\,\})$
  αλλιώς
    η ενοποίηση αποτυγχάνει

Ενδιάμεσος κώδικας (i)

- Λόγοι ύπαρξης
  - Διευκολύνει το έργο της μετάφρασης
  - Διευκολύνει τη βελτιστοποίηση
  - Διευκολύνει την κατάτμηση σε εμπρόσθιο και οπίσθιο τμήμα

Ενδιάμεσος κώδικας (ii)

- Μετάφραση οδηγούμενη από τη σύνταξη (syntax-directed translation)
  - Για κάθε δομή της γλώσσας προσδιορίζεται ο αντίστοιχος ενδιάμεσος κώδικας
  - Διευρύνεται ο συντακτικός αναλυτής με σημασιολογικές ρουτίνες που παράγουν ενδιάμεσο κώδικα
- Σχέδιο παραγωγής ενδιάμεσου κώδικα
- Μεταβλητές ιδιοτήτων (attributes) για κάθε σύμβολο της γραμματικής

Ενδιάμεση γλώσσα (i)

- Τετράδες (quadruples)

  n: op, x, y, z

- Παράδειγμα: `b*b-4*a*c`

  1: $*, \mathrm{b}, \mathrm{b}, \$1$
  2: $*, 4, \mathrm{a}, \$2$
  3: $*, \$2, \mathrm{c}, \$3$
  4: $-, \$1, \$3, \$4$

Ενδιάμεση γλώσσα (ii)

- Τριάδες (triples)

  n: op, x, y

- Παράδειγμα: `b*b-4*a*c`

  1: $*, \mathrm{b}, \mathrm{b}$
  2: $*, 4, \mathrm{a}$
  3: $*, (2), \mathrm{c}$
  4: $-, (1), (3)$

Ενδιάμεση γλώσσα (iii)

- Αφηρημένα συντακτικά δέντρα (abstract syntax trees)
- Παράδειγμα: `b*b-4*a*c`

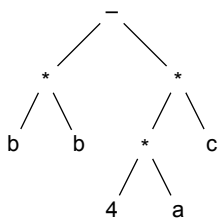

Ενδιάμεση γλώσσα (iv)

- Προθεματικός και επιθεματικός κώδικας (prefix/postfix code)
- Παράδειγμα: `b*b-4*a*c`

  $- * \mathrm{b}\ \mathrm{b} * * 4\ \mathrm{a}\ \mathrm{c}$ προθεματικός
  $\mathrm{b}\ \mathrm{b} * 4\ \mathrm{a} * \mathrm{c} * -$ επιθεματικός

Ενδιάμεση γλώσσα (v)

- Κατευθυνόμενοι ακυκλικοί γράφοι (directed acyclic graphs)
- Παράδειγμα:
  `b+(a+1)*(a+1)+c-(a+1)*(a+1)+2/(a+1)`

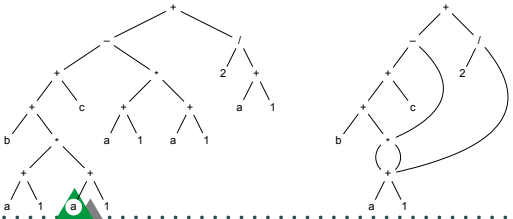

Γλώσσα τετράδων

- Μορφή τετράδας:

  n: op, x, y, z

  όπου:
  - n: ετικέτα τετράδας (φυσικός αριθμός)
  - op: τελεστής
  - x, y, z: τελούμενα
- Ανάλογα με το είδος του τελεστή, κάποια τελούμενα ενδεχομένως παραλείπονται

Τελούμενα (i)

- Σταθερά
  - ακέραια, πραγματική, λογική
  - χαρακτήρας, συμβολοσειρά, `nil`
- Όνομα
  - μεταβλητή, παραμέτρος, υποπρόγραμμα
- Προσωρινή μεταβλητή: $\$n$
- Αποτέλεσμα συνάρτησης: $\$\$$
- Αποδεικτοδότηση: $[x]$ x απλό τελούμενο
- Διεύθυνση: $\{x\}$ x απλό τελούμενο

Τελούμενα (ii)

- Ετικέτα
  - εντολής στο αρχικό πρόγραμμα
  - τετράδας
- Τρόπος περάσματος
  - V : κατ' αξία
  - R : κατ' αναφορά
  - RET : θέση αποτελέσματος συνάρτησης
- Κενό : $-$
- Προσωρινά κενό : $*$ (για backpatching)

Τελεστές (i)

- unit, $I, -, -$
- endu, $I, -, -$
  αρχή και τέλος δομικής μονάδας
- op, x, y, z $op \in \{+, -, *, /, \%\}$
  $z := x\ op\ y$
- $:=, x, -, z$
  $z := x$
- array, x, y, z
  $z :=$ η διεύθυνση του στοιχείου $x[y]$

Τελεστές (ii)

- op, x, y, z $op \in \{=, <>, >, <, >=, <=\}$
  αν $x\ op\ y$ τότε πήγαινε στην τετράδα z
- ifb, $x, -, z$
  αν η λογική τιμή x είναι αληθής τότε πήγαινε στην τετράδα z
- jump, $-, -, z$
  πήγαινε στην τετράδα z
- label, $I, -, -$
  jumpl, $-, -, I$
  ορισμός ετικέτας και άλμα προς αυτήν

Τελεστές (iii)

- call, $-, -, I$
  κάλεσε τη δομική μονάδα I
- par, $x, m, -$
  πέρασε την πραγματική παράμετρο x με τρόπο περάσματος m
- ret, $-, -, -$
  επιστροφή από την τρέχουσα δομική μονάδα

Μεταβλητές ιδιοτήτων

- *PLACE*: θέση όπου βρίσκεται αποθηκευμένη η τιμή μιας l-value ή μιας r-value
- *TYPE*: τύπος μιας l-value ή μιας r-value
- *NEXT*: λίστα από ετικέτες τετράδων που περιέχουν άλματα στην επόμενη εντολή
- *TRUE, FALSE*: λίστες από ετικέτες τετράδων που περιέχουν άλματα στον κώδικα που πρέπει να εκτελεστεί αν μια συνθήκη είναι αληθής ή ψευδής

Βοηθητικές υπορουτίνες (i)

- NEXTQUAD()
  Επιστρέφει τον αριθμό της επόμενης τετράδας
- GENQUAD(op, x, y, z)
  Γεννά την επόμενη τετράδα op, x, y, z
- NEWTEMP(t)
  Δημιουργεί μια νέα προσωρινή μεταβλητή τύπου t
- EMPTYLIST()
  Δημιουργεί μια κενή λίστα ετικετών τετράδων

Βοηθητικές υπορουτίνες (ii)

- MAKELIST(x)
  Δημιουργεί μια λίστα ετικετών τετράδων που περιέχει μόνο το στοιχείο x
- MERGE($l_1, \ldots, l_n$)
  Συνένωση των λιστών ετικετών τετράδων $l_1 \ldots l_n$
- BACKPATCH(l, z)
  Αντικαθιστά σε όλες τις τετράδες που περιέχονται στην l την άγνωστη ετικέτα τετράδας με τη z (backpatching)

Αριθμητικές εκφράσεις

- Ακέραιες σταθερές

$\langle$r-value$\rangle$ ::= $\langle$integer-const$\rangle$ { P_1 }

P_1 : { $\langle$r-value$\rangle.PLACE = \langle$integer-const$\rangle$; }

- Τελεστές με δύο τελούμενα

$\langle$r-value$\rangle$ ::= $\langle$expr$\rangle$ $\langle$binop$\rangle$ $\langle$expr$\rangle$ { P_{14} }

P_{14} : { W = NEWTEMP($\langle$r-value$\rangle.TYPE$);
GENQUAD($\langle$binop$\rangle.NAME$,
$\langle$expr$\rangle^1.PLACE$,
$\langle$expr$\rangle^2.PLACE$, W);
$\langle$r-value$\rangle.PLACE = W$; }

Λογικές εκφράσεις (i)

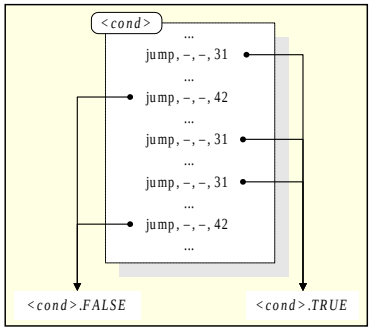

Λογικές εκφράσεις (ii)

- Λογικές εκφράσεις σε συμβολισμό 0/1

$\langle$cond$\rangle$ ::= $\langle$expr$\rangle$

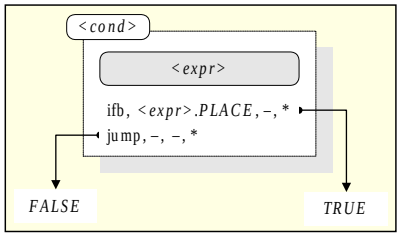

Λογικές εκφράσεις (iii)

- Λογικές εκφράσεις σε συμβολισμό 0/1

$\langle$cond$\rangle$ ::= $\langle$expr$\rangle$ { P_{21} }

P_{21} : { $\langle$cond$\rangle.TRUE$ = MAKELIST(NEXTQUAD());
GENQUAD(ifb, $\langle$expr$\rangle.PLACE, -, *$);
$\langle$cond$\rangle.FALSE$ = MAKELIST(NEXTQUAD());
GENQUAD(jump, $-, -, *$); }

Λογικές εκφράσεις (iv)

- Τελεστές σύγκρισης

$\langle$cond$\rangle$ ::= $\langle$expr$\rangle^1$ $\langle$relop$\rangle$ $\langle$expr$\rangle^2$

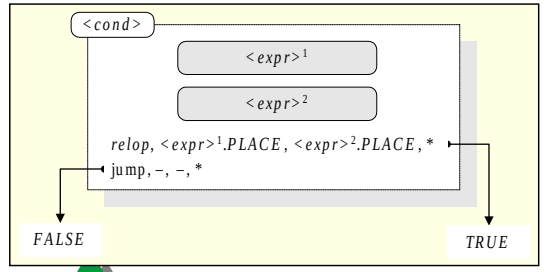

Λογικές εκφράσεις (v)

- Τελεστές σύγκρισης

⟨cond⟩ ::= ⟨expr⟩^{1} ⟨relop⟩ ⟨expr⟩^{2} { P_{23} }

P_{23} : { ⟨cond⟩.*TRUE* = MAKELIST(NEXTQUAD());
GENQUAD(⟨relop⟩.*NAME*,
⟨expr⟩^{1}.*PLACE*,
⟨expr⟩^{2}.*PLACE*, ∗);
⟨cond⟩.*FALSE* = MAKELIST(NEXTQUAD());
GENQUAD(jump, −, −, ∗); }

Λογικές εκφράσεις (vi)

- Άρνηση

⟨cond⟩ ::= "**not**" ⟨cond⟩

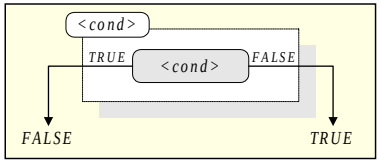

Λογικές εκφράσεις (vii)

- Σύζευξη

⟨cond⟩ ::= ⟨cond⟩^{1} "**and**" ⟨cond⟩^{2}

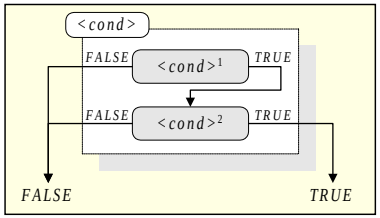

Λογικές εκφράσεις (viii)

- Σύζευξη

⟨cond⟩ ::= ⟨cond⟩$_1$ "**and**" { P_{25} } ⟨cond⟩$_2$ { P_{26} }

P_{25} : { BACKPATCH(⟨cond⟩^{1}.*TRUE*, NEXTQUAD()); }

P_{26} : { ⟨cond⟩.*FALSE* = MERGE(⟨cond⟩^{1}.*FALSE*,
⟨cond⟩^{2}.*FALSE*);
⟨cond⟩.*TRUE* = ⟨cond⟩^{2}.*TRUE*; }

Απλές εντολές

- Κενή εντολή

⟨stmt⟩ ::= ϵ { P_{29} }

P_{29} : { ⟨stmt⟩.*NEXT* = EMPTYLIST(); }

- Εντολή ανάθεσης

⟨stmt⟩ ::= ⟨l-value⟩ ":=" ⟨expr⟩ { P_{30} }

P_{30} : { GENQUAD(":=", ⟨expr⟩.*PLACE*, −,
⟨l-value⟩.*PLACE*);
⟨stmt⟩.*NEXT* = EMPTYLIST(); }

Σύνθετη εντολή (i)

⟨stmt⟩ ::= ⟨block⟩

⟨block⟩ ::= "**begin**" ⟨stmt⟩ (";" ⟨stmt⟩)* "**end**"

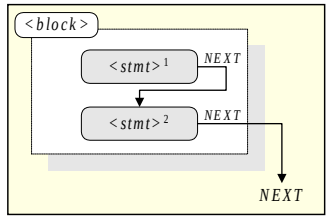

Σύνθετη εντολή (ii)

⟨stmt⟩ ::= ⟨block⟩ { P_{34} }

P_{34} : { ⟨stmt⟩.$NEXT$ = ⟨block⟩.$NEXT$; }

⟨block⟩ ::= "**begin**" ⟨stmt⟩^{1} { P_{35} }
(";" { P_{36} } ⟨stmt⟩^{2} { P_{37} })* "**end**" { P_{38} }

P_{35} : { L = ⟨stmt⟩^{1}.$NEXT$; }

P_{36} : { BACKPATCH(L, NEXTQUAD()); }

P_{37} : { L = ⟨stmt⟩^{2}.$NEXT$; }

P_{38} : { ⟨block⟩.$NEXT$ = L; }

Εντολή if (i)

⟨stmt⟩ ::= "**if**" ⟨cond⟩ "**then**" ⟨stmt⟩ ["**else**" ⟨stmt⟩]

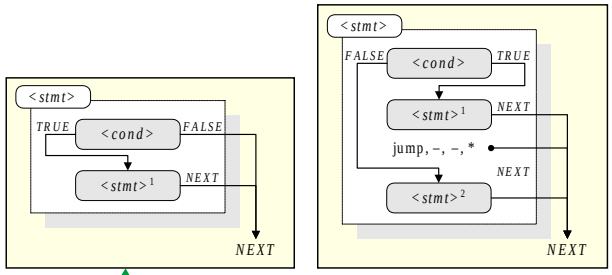

Εντολή if (ii)

⟨stmt⟩ ::= "**if**" ⟨cond⟩ { P_{39} } "**then**" ⟨stmt⟩^{1}
["**else**" { P_{40} } ⟨stmt⟩^{2} { P_{41} }] { P_{42} }

P_{39} : { BACKPATCH(⟨cond⟩.$TRUE$, NEXTQUAD());
L_1 = ⟨cond⟩.$FALSE$;
L_2 = EMPTYLIST(); }

P_{40} : { L_1 = MAKELIST(NEXTQUAD());
GENQUAD(jump, –, –, ∗);
BACKPATCH(⟨cond⟩.$FALSE$, NEXTQUAD()); }

P_{41} : { L_2 = ⟨stmt⟩^{2}.$NEXT$; }

P_{42} : { ⟨stmt⟩.$NEXT$ = MERGE(L_1, ⟨stmt⟩^{1}.$NEXT$, L_2); }

Εντολή while (i)

⟨stmt⟩ ::= "**while**" ⟨cond⟩ "**do**" ⟨stmt⟩

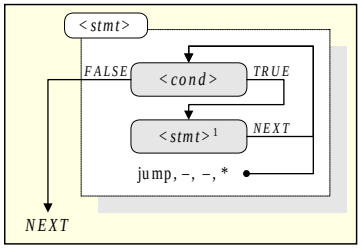

Εντολή while (ii)

⟨stmt⟩ ::= "**while**" { P_{43} } ⟨cond⟩ "**do**" { P_{44} } ⟨stmt⟩^{1} { P_{45} }

P_{43} : { Q = NEXTQUAD(); }

P_{44} : { BACKPATCH(⟨cond⟩.$TRUE$, NEXTQUAD()); }

P_{45} : { BACKPATCH(⟨stmt⟩^{1}.$NEXT$, Q);
GENQUAD(jump, –, –, Q);
⟨stmt⟩.$NEXT$ = ⟨cond⟩.$FALSE$; }

Κλήση υποπρογραμμάτων (i)

⟨call⟩ ::= ⟨id⟩ "(" [⟨expr⟩ ("," ⟨expr⟩)*] ")"

⟨r-value⟩ ::= ⟨call⟩

⟨stmt⟩ ::= ⟨call⟩

- Πέρασμα παραμέτρων με τετράδες `par`
- Πέρασμα θέσης αποτελέσματος με τετράδα `par` αν πρόκειται για συνάρτηση
- Κλήση με τετράδα `call`

Κλήση υποπρογραμμάτων (ii)

$\langle \text{call} \rangle$ ::= $\langle \text{id} \rangle$ "(" $\{ P_{46} \}$ [$\langle \text{expr} \rangle^1$ $\{ P_{47} \}$
("," $\langle \text{expr} \rangle^2$ $\{ P_{48} \}$)*] ")" $\{ P_{49} \}$

P_{46} : { $N = 1;$ }

P_{47} : { GENQUAD("**par**", $\langle \text{expr} \rangle^1.PLACE$,
PARAMMODE($\langle \text{id} \rangle, N$), $-$);
$N = N + 1;$ }

P_{48} : { GENQUAD("**par**", $\langle \text{expr} \rangle^2.PLACE$,
PARAMMODE($\langle \text{id} \rangle, N$), $-$);
$N = N + 1;$ }

Κλήση υποπρογραμμάτων (iii)

$\langle \text{call} \rangle$ ::= $\langle \text{id} \rangle$ "(" $\{ P_{46} \}$ [$\langle \text{expr} \rangle^1$ $\{ P_{47} \}$
("," $\langle \text{expr} \rangle^2$ $\{ P_{48} \}$)*] ")" $\{ P_{49} \}$

(συνέχεια)

P_{49} : { **if** (ISFUNCTION($\langle \text{id} \rangle$)) {
W = NEWTEMP(FUNCRESULT($\langle \text{id} \rangle$));
GENQUAD(par, RET, W, $-$);
$\langle \text{call} \rangle.PLACE = W;$
}
GENQUAD(call, $-$, $-$, $\langle \text{id} \rangle$); }

Κλήση υποπρογραμμάτων (iv)

- Κλήση συνάρτησης

$\langle \text{r-value} \rangle$ ::= $\langle \text{call} \rangle$ $\{ P_{50} \}$

P_{50} : { $\langle \text{r-value} \rangle.PLACE = \langle \text{call} \rangle.PLACE;$ }

- Κλήση διαδικασίας

$\langle \text{stmt} \rangle$ ::= $\langle \text{call} \rangle$ $\{ P_{51} \}$

P_{51} : { $\langle \text{stmt} \rangle.NEXT = \text{EMPTYLIST}();$ }

Κλήση υποπρογραμμάτων (v)

- Επιστροφή από υποπρόγραμμα

$\langle \text{stmt} \rangle$ ::= "**return**" [$\langle \text{expr} \rangle$ $\{ P_{52} \}$] $\{ P_{53} \}$

P_{52} : { GENQUAD(retv, $\langle \text{expr} \rangle.PLACE, -, -$); }

P_{53} : { GENQUAD(ret, $-, -, -$); }

- Δήλωση υποπρογράμματος

$\langle \text{body} \rangle$ ::= ($\langle \text{local} \rangle$)* $\{ P_{56} \}$ $\langle \text{block} \rangle$ ";" $\{ P_{57} \}$

P_{56} : { GENQUAD(unit, $I, -, -$); }

P_{57} : { BACKPATCH($\langle \text{block} \rangle.NEXT$, NEXTQUAD());
GENQUAD(endu, $I, -, -$); }

Τελικός κώδικας (i)

- Από θεωρητικής άποψης, το πρόβλημα της κατασκευής βέλτιστου τελικού κώδικα δεν έχει λύση (undecidable)
- Μορφές τελικού κώδικα:
  - Γλώσσα μηχανής σε απόλυτη μορφή (absolute)
  - Γλώσσα μηχανής σε επανατοποθετήσιμη και διασυνδέσιμη μορφή (relocatable, linkable)
  - Συμβολική γλώσσα (assembly)
  - Άλλη γλώσσα χαμηλού επιπέδου

Τελικός κώδικας (ii)

- Επιμέρους προβλήματα:
  - Επιλογή εντολών
    ⇒ Πώς μεταφράζεται κάθε εντολή του ενδιάμεσου κώδικα
    ⇒ Πώς μεταφράζονται ακολουθίες τέτοιων εντολών
  - Διαχείριση της μνήμης στο χρόνο εκτέλεσης
    ⇒ Πού αποθηκεύονται τα δεδομένα
    ⇒ Πώς γίνεται η επικοινωνία ανάμεσα στις δομικές μονάδες

Τελικός υπολογιστής (i)

- Χαρακτηριστικά:
  - Επεξεργαστής: Intel 8086
  - Λειτουργικό σύστημα: MS-DOS
  - Μοντέλο μνήμης: COM / tiny
    $\Rightarrow$ Συνολική μνήμη $\leq 64\,\mathrm{K}$
    $\Rightarrow$ Οργάνωση σε ένα segment
    $\Rightarrow$ Αρχική διεύθυνση του προγράμματος η $100h$
  - Συμβολική γλώσσα: συμβατή με το συμβολομεταφραστή MASM (Microsoft macro assembler)

Τελικός υπολογιστής (ii)

- Καταχωρητές, μεγέθους 16 bit
  - Γενικής φύσης: `ax`, `bx`, `cx`, `dx`
    $\Rightarrow$ σε ζεύγη των 8 bit: `ah`, `al`, κ.λπ.
  - Καταχωρητές δείκτες: `sp` (δείκτης στοίβας) και `bp` (δείκτης βάσης)
  - Καταχωρητές αναφοράς: `si` και `di`
  - Καταχωρητές τμημάτων: `cs` (code), `ds` (data), `ss` (stack) και `es` (extra)
  - Ειδικοί καταχωρητές: `ip` (instruction pointer) και καταχωρητής σημαιών (flags)

Τελικός υπολογιστής (iii)

- Διευθύνσεις:

  $address = segment * 16 + offset$

- Μορφή εντολής:

  $[\ label\ ]\ \ opname\ \ [\ operand_1\ [\ , operand_2\ ]\ ]$

Τελικός υπολογιστής (iv)

- Εντολές:
  - Μεταφοράς: `mov`, `lea`
  - Αριθμητικών πράξεων: `add`, `sub`, `neg`, `imul`, `idiv`, `cmp`, `cwd`
  - Λογικών πράξεων: `and`, `or`, `xor`, `not`, `test`
  - Άλματος: `jmp`, `jz`, `jnz`, `jl`, `jle`, `jg`, `jge`
  - Διαχείρισης στοίβας: `push`, `pop`
  - Υποπρογραμμάτων: `call`, `ret`
  - Πράξεων κινητής υποδιαστολής (x87 FPU)

Εντολές μεταφοράς

- `mov` *destination, source* (move)

```
mov ax,42
mov ax,bx
mov ax,[1000h]
mov ax,[si]
mov ax,[si+6]
mov ax,[bp+6]
mov ax,[si+bp+6]
```

- `lea` *destination, source* (load effective address)
- Καθορισμός μεγέθους δεδομένων

```
mov ax,word ptr [bp+6]
mov al,byte ptr [bp+6]
```


Αριθμητικές πράξεις

`add` op_1, op_2	$op_1 := op_1 + op_2$
`sub` op_1, op_2	$op_1 := op_1 - op_2$
`neg` op	$op := -op$
`imul` op	$(\mathtt{dx}, \mathtt{ax}) := \mathtt{ax} * op$
`idiv` op	$\mathtt{ax} := (\mathtt{dx}, \mathtt{ax})\ \mathbf{div}\ op$ $\mathtt{dx} := (\mathtt{dx}, \mathtt{ax})\ \mathbf{mod}\ op$
`cwd`	επέκταση προσήμου του ax στον dx
`cmp` op_1, op_2	σύγκρινε τα op_1 και op_2 ενημέρωσε τις σημαίες

Λογικές πράξεις

- `and` op_1, op_2 — $op_1 := op_1$ **and** op_2
- `or` op_1, op_2 — $op_1 := op_1$ **or** op_2
- `not` op — $op :=$ **not** op
- `xor` op_1, op_2 — $op_1 := op_1$ **xor** op_2
- `test` op_1, op_2 — op_1 **and** op_2, ενημέρωσε τις σημαίες

Εντολές άλματος

- `jmp` *address* — χωρίς συνθήκη
- `jz` *address* ή `je` *address* — μηδέν / ίσο
- `jnz` *address* ή `jne` *address* — όχι μηδέν / διάφορο
- `jl` *address* — μικρότερο
- `jle` *address* — μικρότερο ή ίσο
- `jg` *address* — μεγαλύτερο
- `jge` *address* — μεγαλύτερο ή ίσο

Εντολές στοίβας

- `push` *op* — πρόσθεση στη στοίβα
  $\texttt{sp} := \texttt{sp} - 2, \quad [\texttt{sp}] := op$
- `pop` *op* — αφαίρεση από τη στοίβα
  $op := [\texttt{sp}], \quad \texttt{sp} := \texttt{sp} + 2$

⇒ Η στοίβα αυξάνει προς τα κάτω, δηλαδή προς μικρότερες διευθύνσεις

Εντολές υποπρογραμμάτων

- `call` *address* — κλήση
  $\texttt{sp} := \texttt{sp} - 2, \quad [\texttt{sp}] := \texttt{ip}, \quad \texttt{ip} := address$
- `ret` — επιστροφή
  $\texttt{ip} := [\texttt{sp}], \quad \texttt{sp} := \texttt{sp} + 2$

⇒ Η τιμή του `ip` που τοποθετείται στη στοίβα από την `call` είναι η διεύθυνση της εντολής που ακολουθεί την `call`

Εντολές x87 FPU *(i)*

⇒ Ειδική στοίβα 8 καταχωρητών: ST(0), ... ST(7)

- `fld` *source* — (load real & push)

```
fld tbyte ptr @real1
```

- `fild` *source* — (load integer & push)

```
fild word ptr [bp - 2]
```

- `fstp` *destination* — (pop & store real)

```
fld tbyte ptr [bp - 10]
```

- `fistp` *destination* — (pop & store integer)

```
fild word ptr [bp - 2]
```


Εντολές x87 FPU *(ii)*

- `faddp ST(1),ST(0)` — ST(1) := ST(1) + ST(0) & pop
- `fsubp ST(1),ST(0)` — ST(1) := ST(1) − ST(0) & pop
- `fmulp ST(1),ST(0)` — ST(1) := ST(1) ∗ ST(0) & pop
- `fdivp ST(1),ST(0)` — ST(1) := ST(1)/ST(0) & pop
- `fchs` — ST(0) := −ST(0)
- `fcompp` — ST(1) $\lessgtr$ ST(0) & pop both
- `fstsw` *destination* — (store x87 FPU flags)

```
fstsw ax
fstsw word ptr [bp - 2]
```

Διαχείριση μνήμης (i)

- Δομή ενοτήτων (block structure)
  - Μη τοπικά δεδομένα
- Εγγράφημα δραστηριοποίησης (activation record)
  - Παράμετροι
  - Αποτέλεσμα
  - Πληροφορίες κατάστασης μηχανής
  - Τοπικές μεταβλητές
  - Προσωρινές μεταβλητές

Διαχείριση μνήμης (ii)

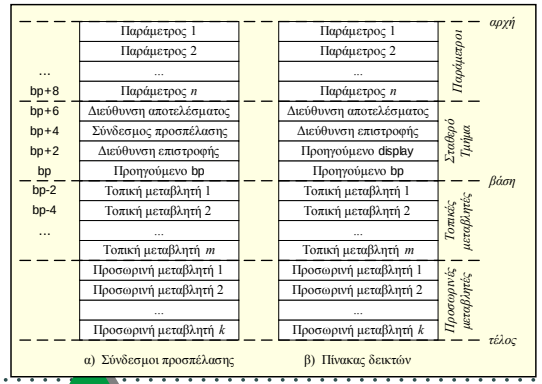

Διαχείριση μνήμης (iii)

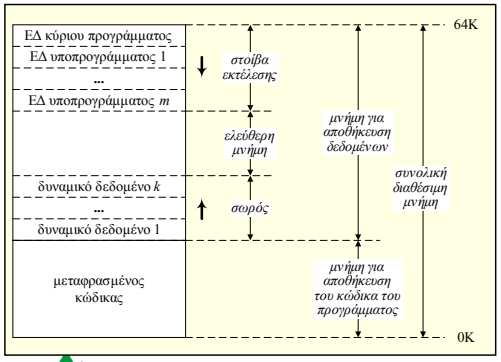

Προσπέλαση ονομάτων

- Τοπικά: $[\texttt{bp} + \mathit{offset}]$
- Μη τοπικά: $[\texttt{si} + \mathit{offset}]$

  $\Rightarrow$ ο `si` πρέπει να δείχνει στη βάση του εγγραφήματος δραστηριοποίησης όπου τα δεδομένα είναι τοπικά
- Το πρόβλημα ανάγεται στον εντοπισμό του αντίστοιχου εγγραφήματος δραστηριοποίησης
- Λύσεις που βασίζονται στο βάθος φωλιάσματος:
  - Σύνδεσμοι προσπέλασης (access links)
  - Πίνακες δεικτών (link tables / displays)

Σύνδεσμοι προσπέλασης (i)

- Αρχή λειτουργίας
  - Έστω ότι η δομική μονάδα p βρίσκεται φωλιασμένη μέσα στη δομική μονάδα q

  $\Rightarrow$ Στο ΕΔ της p τοποθετείται ένα σύνδεσμος προς τη βάση του ΕΔ της πιο πρόσφατης κλήσης της q
- Κατά την κλήση υποπρογραμμάτων, απαιτείται τελικός κώδικας για την ενημέρωση των συνδέσμων προσπέλασης

Σύνδεσμοι προσπέλασης (ii)

- Τρόπος χρήσης
  - Έστω ότι ζητείται το δεδομένο a που είναι τοπικό σε μια δομική μονάδα με βάθος φωλιάσματος n_a
  - Έστω ότι βρισκόμαστε σε μια δομική μονάδα p με βάθος φωλιάσματος $n_p \geq n_a$

  $\Rightarrow$ Ακολουθούμε $n_p - n_a$ συνδέσμους προσπέλασης
- Κατά την προσπέλαση ονομάτων, απαιτείται τελικός κώδικας για την υλοποίηση των παραπάνω

Πέρασμα παραμέτρων

- Κλήση κατ΄ αξία (call by value)
- Κλήση κατ΄ αναφορά (call by reference)
- Κλήση κατ΄ όνομα (call by name)
- Κλήση κατ΄ ανάγκη (call by need)
- Κλήση κατ΄ αξία και αποτέλεσμα (call by value-result)

⇒ Τρόπος υλοποίησης καθενός

Δέσμευση καταχωρητών (i)

- Πρόβλημα 1: επιλογή τελουμένων που θα αποθηκευτούν σε καταχωρητές
- Πρόβλημα 2: επιλογή καταχωρητών όπου θα αποθηκευτούν τα τελούμενα
- Το πρόβλημα της βέλτιστης χρήσης καταχωρητών είναι NP-complete, ακόμα και χωρίς ειδικούς περιορισμούς
- Η λύση του ανάγεται στην κατασκευή του γράφου αλληλεπιδράσεων μεταξύ των μεταβλητών και στο χρωματισμό αυτού με τόσα χρώματα όσοι οι καταχωρητές

Δέσμευση καταχωρητών (ii)

- Παράδειγμα: `d := b*b-4*a*c`

1: $*, \mathrm{b}, \mathrm{b}, \$1$
2: $*, 4, \mathrm{a}, \$2$
3: $*, \$2, \mathrm{c}, \$3$
4: $-, \$1, \$3, \$4$
5: $:=, \$4, -, \mathrm{d}$

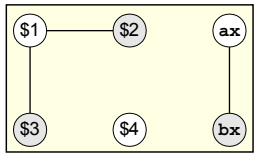

Επιλογή εντολών (i)

- Απλή αλλά κακή προσέγγιση: ενιαίο σχήμα παραγωγής τελικού κώδικα για κάθε δομή του ενδιάμεσου κώδικα
- Καλύτερη προσέγγιση: πλακόστρωση (tiling)
  - τεμαχισμός του ενδιάμεσου κώδικα σε τμήματα
  - κάθε τμήμα αντιστοιχεί σε μια εντολή
- Βέλτιστη αλλά χρονοβόρα προσέγγιση: δυναμικός προγραμματισμός (dynamic programming)

Επιλογή εντολών (ii)

- Παράδειγμα: `d := b*b-4*a*c`

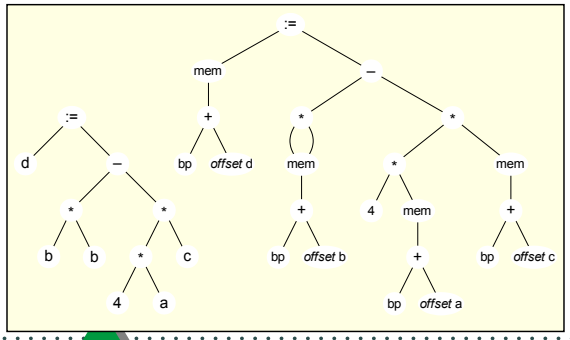

Επιλογή εντολών (iii)

- Παράδειγμα: tiling με εντολές του 8086

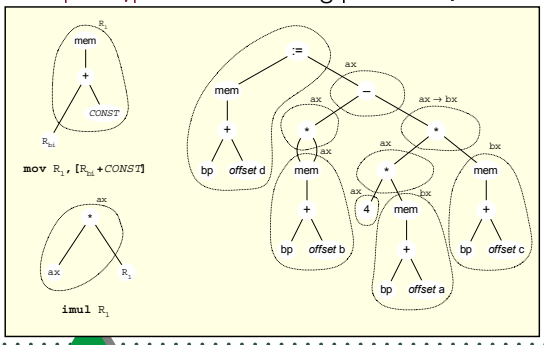

Επιλογή εντολών (iv)

- Παράδειγμα: tiling με εντολές του 80386

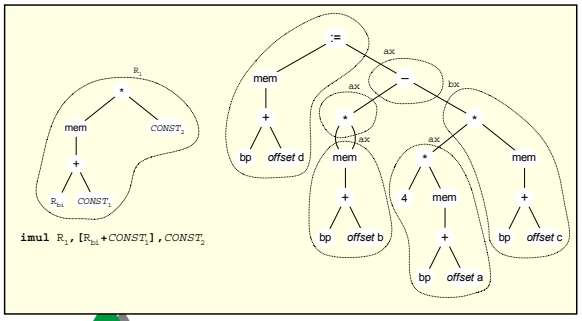

Το τελικό πρόγραμμα (i)

- Σκελετός:

```
xseg  segment  public 'code'
      assume   cs : xseg, ds : xseg, ss : xseg
      org      100h
main  proc     near
      call     near ptr program
      mov      ax, 4C00h
      int      21h
main  endp
```

... τελικός κώδικας που παράγεται ...

```
xseg  ends
      end      main
```


Το τελικό πρόγραμμα (ii)

- Βιβλιοθήκη χρόνου εκτέλεσης (run-time library)

```
extrn function : proc
```

- Σταθερές συμβολοσειρές και κινητής υποδιαστολής

```
@str1   db 'this is'
        db 10
        db 'an example'
        db 0
@real1  dt 1e-10
@real2  dt 2.0
```


Βοηθητικές ρουτίνες (i)

- getAR(a) (φόρτωση διεύθυνσης ΕΔ)

```
mov si, word ptr [bp + 4]
mov si, word ptr [si + 4]
...
mov si, word ptr [si + 4]
```

} $(n_{\text{cur}} - n_{\text{a}} - 1$ φορές)

- updateAL() (ενημέρωση συνδέσμων προσπέλασης)

(α) `push bp` αν $n_p < n_x$

(β) `push word ptr [bp + 4]` αν $n_p = n_x$

(γ)
```
mov si, word ptr [bp + 4]
mov si, word ptr [si + 4]
...
mov si, word ptr [si + 4]
```
} $(n_p - n_x - 1$ φορές)

```
push word ptr [si + 4]
```


Βοηθητικές ρουτίνες (ii)

- load(R, a) (φόρτωση τελουμένου)

	Είδος του a	Κώδικας που παράγεται
(α1)	αριθμητική σταθερά	`mov R, a`
(α2)	λογική σταθερά `true`	`mov R, 1`
(α3)	λογική σταθερά `false`	`mov R, 0`
(α4)	σταθερά χαρακτήρα	`mov R, ASCII(a)`
(α6)	σταθερά `nil`	`mov R, 0`
(β1)	τοπική οντότητα: μεταβλητή, παράμετρος κατ' αξία, ή προσωρινή μεταβλητή	`mov R, size ptr [bp + offset]`
(β2)	τοπική οντότητα: παράμετρος κατ' αναφορά	`mov si, word ptr [bp + offset]` `mov R, size ptr [si]`

Βοηθητικές ρουτίνες (iii)

- load(R, a) (φόρτωση τελουμένου)

	Είδος του a	Κώδικας που παράγεται
(γ1)	μη τοπική οντότητα: μεταβλητή, παράμετρος κατ' αξία, ή προσωρινή μεταβλητή	getAR(a) `mov R, size ptr [si + offset]`

(γ2)	μη τοπική οντότητα: παράμετρος κατ' αναφορά	getAR(a)
		`mov si, word ptr [si + offset]`
		`mov R, size ptr [si]`

(δ)	$[x]$	load(di, x) `mov R, size ptr [di]`
(ε)	$\{x\}$	loadAddr(R, x)

Βοηθητικές ρουτίνες (iv)

- loadAddr(R, a) (φόρτωση διεύθυνσης τελουμένου)

	Είδος του a	Κώδικας που παράγεται
(α5)	σταθερή συμβολοσειρά	`lea R, byte ptr a`
(β1)	τοπική οντότητα: παράμετρος κατ' αξία, ή προσωρινή μεταβλητή	`lea R,` *size* `ptr [bp +` *offset*`]`
(β2)	τοπική οντότητα: παράμετρος κατ' αναφορά	`mov R, word ptr [bp +` *offset*`]`
(γ1)	μη τοπική οντότητα: παράμετρος κατ' αξία, ή προσωρινή μεταβλητή	getAR(a) `lea R,` *size* `ptr [si +` *offset*`]`
(γ2)	μη τοπική οντότητα: παράμετρος κατ' αναφορά	getAR(a) `mov R, word ptr [si +` *offset*`]`
(δ)	[x]	load(R, x)

Βοηθητικές ρουτίνες (v)

- Παρόμοια υλοποίηση για τις:
  - loadReal(a)
  - store(R, a)
  - storeReal(a)
- Ρουτίνες για ετικέτες τελικού κώδικα:
  - name(p) _p_*num*
  - endof(p) @p_*num*
  - label(n) @n
  - label(ℓ) @p_*num*_ℓ

Παραγωγή κώδικα (i)

- Τετράδα :=, x, −, z

  load(R, x) loadReal(x)
  store(R, z) storeReal(z)

- Τετράδα array, x, y, z

```
load(ax, y)
mov  cx, size
imul cx
loadAddr(cx, x)
add  ax, cx
store(ax, z)
```


Παραγωγή κώδικα (ii)

- Τετράδες +, x, y, z −, x, y, z

```
load(ax, x)          loadReal(x)
load(dx, y)          loadReal(y)
instr  ax, dx        finstr  ST(1), ST(0)
store(ax, z)         storeReal(z)
```

instr = `add` ή `sub` *finstr* = `faddp` κ.λπ.

- Τετράδες *, x, y, z /, x, y, z %, x, y, z

```
load(ax, x)   load(ax, x)   load(ax, x)
load(cx, y)   cwd           cwd
imul cx       load(cx, y)   load(cx, y)
store(ax, z)  idiv cx       idiv cx
              store(ax, z)  store(dx, z)
```


Παραγωγή κώδικα (iii)

- Τετράδες =, x, y, z <>, x, y, z <, x, y, z
  >, x, y, z <=, x, y, z >=, x, y, z

```
load(ax, x)          loadReal(x)
load(dx, y)          loadReal(y)
cmp   ax, dx         fcompp
instr  label(z)      fstsw  ax
                     test   ax, value
instr = je, jne, κ.λπ.  instr  label(z)
```

value και *instr* από Πίνακα 9.1 σελ. 249

Παραγωγή κώδικα (iv)

- Τετράδα ifb, x, −, z

```
load(al, x)
or   al, al
jnz  label(z)
```

- Τετράδα jump, −, −, z

```
jmp  label(z)
```

- Τετράδα jumpl, −, −, z

```
jmp  label(z)
```

- Τετράδα label, −, −, z

label(z) :

Παραγωγή κώδικα (v)

- Τετράδα unit, x, −, −

```
name(x)  proc  near
         push  bp
         mov   bp, sp
         sub   sp, size
```

- Τετράδα endu, x, −, −

```
endof(x) :  mov   sp, bp
            pop   bp
            ret
name(x)     endp
```


Παραγωγή κώδικα (vi)

- Τετράδα call, −, −, z

```
sub   sp, 2                    αν z είναι διαδικασία
updateAL()
call  near ptr name(z)
add   sp, size + 4
```

- Τετράδα ret, −, −, −

```
jmp  endof(current)
```


Παραγωγή κώδικα (vii)

- Τετράδα par, x, y, −
  - αν y = V και x είναι 16 bit

```
load(ax, x)
push  ax
```

  - αν y = V και x είναι 8 bit

```
load(al, x)
sub   sp, 1
mov   si, sp
mov   byte ptr [si], al
```


Παραγωγή κώδικα (vii)

- Τετράδα par, x, y, − (συνέχεια)
  - αν y = V και x είναι 80 bit

```
loadReal(x)
sub   sp, 10
mov   si, sp
fstp  tbyte ptr [si]
```

  - αν y = R ή RET

```
loadAddr(si, x)
push  si
```


Προχωρημένα θέματα

- Μεταγλώττιση αντικειμενοστρεφών γλωσσών
- Χαρακτηριστικά του αντικειμενοστρεφούς προγραμματισμού
  - λογισμικό οργανωμένο ως σύνολο από αλληλεπιδρώντα αντικείμενα
  - αντικείμενο / κλάση
  - κελυφοποίηση (encapsulation)
  - κληρονομικότητα (inheritance)
  - πολυμορφισμός υποτύπων (subtype polymorphism)

Αντικείμενα και μέθοδοι (i)

- Αντικείμενο = εγγραφή (record) + μέθοδοι
- Αναπαράσταση αντικειμένων: ίδια με την αναπαράσταση εγγραφών
  - Δεσμεύεται χώρος για τα πεδία του αντικειμένου
  - Οι μέθοδοι δε συμπεριλαμβάνονται στην αναπαράσταση
  - Οι κλήσεις μεθόδων μεταφράζονται σε κλήσεις συναρτήσεων με μια επιπλέον παράμετρο: ένα δείκτη στο αντικείμενο όπου αναφέρονται

Αντικείμενα και μέθοδοι (ii)

```
class Shape
  var posX, posY : real;

  procedure move (dx, dy : real);
  begin
    posX := posX + dx;
    posY := posY + dy
  end;
end;
```

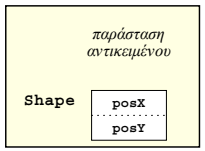

⇓

```
procedure Shape@move (var self : Shape; dx, dy : real);
begin
  self.posX := self.posX + dx;
  self.posY := self.posY + dy
end;
```

```
s.move(1, 2)    ⇒    Shape@move(s, 1, 2)
```


Κατασκευαστές & καταστροφείς

- Ίδια αντιμετώπιση με τις μεθόδους

```
class Shape
  ...
  procedure constructor (x, y : real);
  ...
  procedure destructor ();
  ...
end;
```

⇓

```
procedure Shape@constructor (var self : Shape;
                             x, y : real);
procedure Shape@destructor  (var self : Shape);

var s : Shape(10, 20);  ⇒  Shape@constructor(s, 10, 20);
                           ...
                           Shape@destructor(s);
```


Απλή κληρονομικότητα (i)

- Υποκλάση / υπερκλάση
- Επισκίαση μεθόδων (method override)
- Υποτύποι (subtypes)
- Αναπαράσταση αντικειμένων
  - Τα πεδία της υπερκλάσης τοποθετούνται πρώτα (στην αρχή του αντικειμένου)
  - Αυτό εφαρμόζεται αναδρομικά
  - Τα πεδία της υποκλάσης ακολουθούν

Απλή κληρονομικότητα (ii)

```
class Circle extends Shape
  var radius : real;
  procedure scale (s : real);
  ...
end;

class Line extends Shape
  var endX, endY : real;
  procedure move (dx, dy : real);
  ...
end;
```

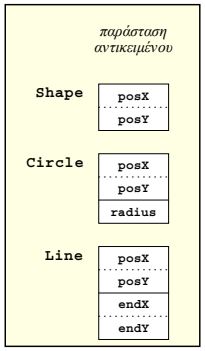

Απλή κληρονομικότητα (iii)

- Στατικό δέσιμο μεθόδων (static binding)

```
var s : Shape(10, 20);
    c : Circle(30, 30, 10);
    l : Line(10, 20, 30, 30);
    p : ^Shape;

...
p := @l;

s.move(5, 5);
c.move(5, 5);
l.move(5, 5);
c.scale(2);
p^.move(5, 5);
```

⇒

```
Shape@move(s, 5, 5);
Shape@move(c, 5, 5);
Line@move(l, 5, 5);
Circle@scale(c, 2);
Shape@move(p^, 5, 5)
```


Πολυμορφισμός υποτύπων (i)

- Δυναμικό δέσιμο μεθόδων (dynamic binding)
  - Όταν γίνεται κλήση μεθόδων μέσω δεικτών ή αναφορών σε αντικείμενα της υπερκλάσης, καλούνται οι αντίστοιχες μέθοδοι των υποκλάσεων
  - Πίνακας ανταπόκρισης μεθόδων (method dispatch table) ή περιγραφέας κλάσης (class descriptor)
  - Κοινός για όλα τα αντικείμενα μιας κλάσης

Πολυμορφισμός υποτύπων (ii)

```
class Shape
  var posX, posY : real;
  dynamic procedure move (dx, dy : real);
end;

class Line extends Shape
  var endX, endY : real;
  dynamic procedure move (dx, dy : real);
end;

var p : ^Shape;

...
p := @l;

p^.move(5, 5)
```


Πολυμορφισμός υποτύπων (iii)

```
var p : ^Shape;

...
p := @l;

p^.move(5, 5)
```

⇓

```
f := p^.dispatch^.move;
f^(p^, 5, 5)
```

- Ομοίως για αφηρημένες (abstract) μεθόδους

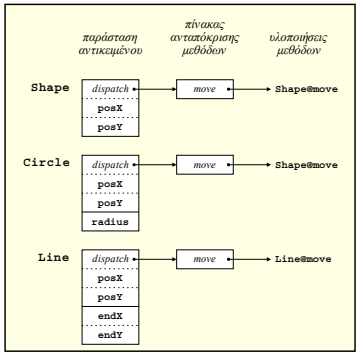

Πολλαπλή κληρονομικότητα (i)

- Πρόβλημα με την αναπαράσταση των αντικειμένων σε συνδυασμό με τους υποτύπους

```
class TwoDim
   var color : ColorType;
   abstract function area () : real;
   dynamic procedure paint (c : ColorType);
end;

class Circle extends Shape, TwoDim
   ...
   dynamic function area () : real;
end;
```


Πολλαπλή κληρονομικότητα (ii)

```
var c  : Circle(...);
    p1 : ^Shape;
    p2 : ^TwoDim;

...
p1 := @c;
p2 := @c
```

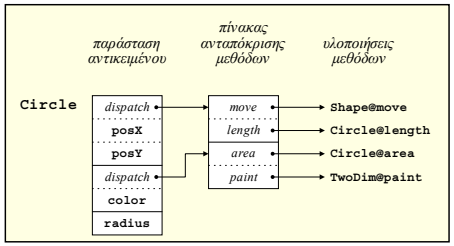

Πολλαπλή κληρονομικότητα (iii)

- Εξαρτημένη πολλαπλή κληρονομικότητα

```
class A
   var a1, a2 : integer;
   dynamic procedure m1 ();
   dynamic procedure m2 ();
end;

class B extends A
   var b1, b2 : integer;
   dynamic procedure m1 ();
   dynamic procedure m3 ();
end;
```

```
class C extends A
   var c1, c2 : integer;
   dynamic procedure m2 ();
   dynamic procedure m4 ();
end;

class D extends B, C
   var d1, d2 : integer;
   dynamic procedure m2 ();
   dynamic procedure m3 ();
   dynamic procedure m5 ();
end;
```


Πολλαπλή κληρονομικότητα (iv)

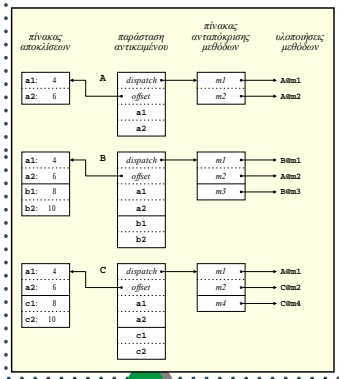

- Πίνακας αποκλίσεων (offset table)

  p^.a1 ⇒

  (p + p^.offset^.a1)^

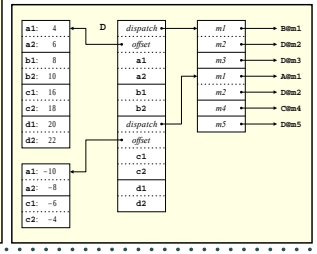

Έλεγχος υποτύπων (i)

Ερώτηση 1: σε ποια κλάση ανήκει το αντικείμενο X;
Απάντηση: απλώς σύγκρινε τους περιγραφείς κλάσης

Ερώτηση 2: ανήκει το αντικείμενο X στην κλάση $\mathcal{C}$;
Απάντηση: ...λίγο πιο δύσκολη...

```
var p : ^Shape;
...
if p^ instanceOf Circle then
   ...1...
else
   ...2...
```


Έλεγχος υποτύπων (ii)

```
  d := p^.descriptor;
loop:
  if d = Circle@descriptor
  then begin
    ...1...
    goto next
  end
  else if d = nil then
  begin
    ...2...
    goto next
  end
  else
    d = d^.super;
  goto loop;
next:
```

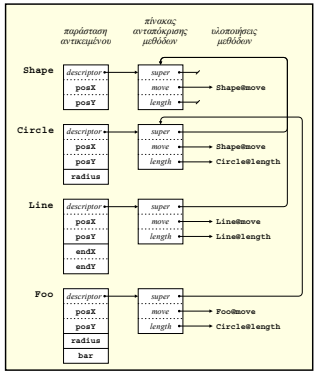

Διαπροσωπείες (i)

```
interface Printable
   dynamic procedure print ();
end;

class Circle extends Shape implements Printable
   ...
   dynamic procedure print ();
end;
```

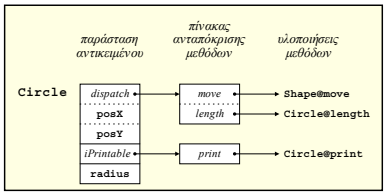

Διαπροσωπείες (ii)

```
var c : Circle(...);
    p : ^Printable;

...
p := @c;

p^.print()
```

⇓

```
p.self := @c;
p.iPrintable := c.iPrintable
```