Προηγμένα Θέματα Θεωρητικής Πληροφορικής

Η οργάνωση του μεταγλωττιστή

Νικόλαος Καββαδίας
nkavv@uop.gr

10 Μαρτίου 2010

Αντικείμενο του μαθήματος **Προηγμένα Θέματα Θεωρητικής Πληροφορικής**

- Επιμέρους στόχοι του μαθήματος
  - Παρουσίαση θεμάτων που άπτονται του σχεδιασμού μεταγλωττιστών πέρα από τα βασικά
    - Θεωρητικό υπόβαθρο
    - Τεκμηριωμένες τεχνικές για όλα τα στάδια της μεταγλώττισης
    - Αναλύσεις, μετασχηματισμοί και βελτιστοποιήσεις
    - Τεχνικές εκμετάλλευσης της παραλληλίας σε όλα τα επίπεδα
    - Πρακτικές περιπτώσεις εφαρμογής των τεχνικών αυτών σε πραγματικούς μεταγλωττιστές
  - Άντληση γνώσης από την 'πηγή' (journal, conference and workshop papers and presentations) με υλικό για μελέτη από reading list Αγγλικής βιβλιογραφίας
  - Παρουσίαση της 'εργαλειοθήκης' του σχεδιαστή μεταγλωττιστών

Αντικείμενο του μαθήματος **Προηγμένα Θέματα Θεωρητικής Πληροφορικής** (2)

- Επιθυμητές (στην πράξη, προαπαιτούμενες) γνώσεις για επιτυχή παρακολούθηση του μαθήματος
  - ☑ Απευθύνεται σε φοιτητές που έχουν διδαχθεί και εξεταστεί επιτυχώς σε μάθημα αντίστοιχο των 'Μεταγλωττιστών Ι' και μαθήματα προγραμματισμού (όπως 1ου και 2ου εξαμήνου)
  - ☑ Η καλή γνώση προγραμματισμού σε κάποια διαδικαστική γλώσσα (C, C++, Java) και δομών δεδομένων, καθώς και γνώσεις αρχιτεκτονικής υπολογιστών είναι χρήσιμες
  - ☑ Εξοικείωση με λογισμικά εργαλεία ανάπτυξης εφαρμογών και ιδιαίτερα εργαλεία GNU όπως GCC, bison, flex είναι θεμιτή αλλά όχι απαραίτητη
  - ☑ Το κυριότερο προσόν είναι η καλή διάθεση και το προσωπικό ενδιαφέρον για το αντικείμενο του μαθήματος

Περίγραμμα μαθήματος (1)

1. Η οργάνωση του μεταγλωττιστή
2. Γέννηση ενδιάμεσης αναπαράστασης
3. Επιλογή κώδικα
4. Κατανομή καταχωρητών
5. Ανάλυση ροής δεδομένων και ελέγχου
6. Βελτιστοποιήσεις ανεξάρτητες από την αρχιτεκτονική
7. Χρονοπρογραμματισμός κώδικα και παραλληλία επιπέδου εντολών
8. Βελτιστοποιήσεις για την ανάδειξη της παραλληλίας εντολών και της τοπικότητας δεδομένων
9. Περιβάλλον χρόνου εκτέλεσης
10. Γέννηση τελικού κώδικα για αρχιτεκτονικές μηχανής
11. Διασυναρτησιακές βελτιστοποιήσεις
12. Επαναστοχεύσιμοι μεταγλωττιστές και εργαλεία ανάπτυξης μεταγλωττιστών

Περίγραμμα μαθήματος (2)

- Προχωρημένα θέματα στους μεταγλωττιστές
  - Περιβάλλον χρόνου εκτέλεσης
  - Βελτιστοποιήσεις για την εκμετάλλευση της παραλληλίας και ενίσχυση της τοπικότητας
  - Μετασχηματισμοί πηγαίου κώδικα (source-to-source transformations)
  - Επαναστοχεύσιμοι μεταγλωττιστές και εργαλεία ανάπτυξης μεταγλωττιστών
    - Μεταγλωττιστές: GCC, Portable C Compiler (PCC), LCC, LLVM, COINS, Trimaran, SUIF/Machine-SUIF, Microsoft Phoenix
    - Εργαλεία του οικοσυστήματος των μεταγλωττιστών: flex, bison, BURG clones, OLIVE, binutils, newlib, copt, superopt, Graphviz, VCG

Εισαγωγικά

- Στα πλαίσια του μαθήματος θα διδαχθεί το αντικείμενο των προηγμένων θεμάτων στη σχεδίαση μεταφραστών γλωσσών προγραμματισμού
- Το μάθημα θα εστιάσει στη σύνθεση τελικού κώδικα για αρχιτεκτονικές μηχανής (προγραμματιζόμενοι επεξεργαστές) από ενδιάμεση αναπαράσταση του πηγαίου προγράμματος
- Η σειρά διαλέξεων που θα πραγματοποιηθεί αντιστοιχεί σε ένα course **Advanced Compiler Techniques** ή **Advanced Compiler Design/Construction** των τμημάτων Computer Science των πανεπιστημίων του εξωτερικού
- Ενημέρωση για ανακοινώσεις, διαλέξεις, ύλη, εργασίες από ιστότοπο του μαθήματος που θα σας ανακοινωθεί

Κανονικές εκφράσεις (regular expressions)

- Κανονική έκφραση: αλγεβρική σημειογραφία για την περιγραφή συνόλων συμβολοσειρών (strings)
- Αποτελεί ένα είδος αναπαράστασης ένα-σε-πολλά (μία κανονική έκφραση αντιπροσωπεύει πολλές συμβολοσειρές)
- Κανόνες

Σύμβολο	Περιγραφή
?	προαιρετική εμφάνιση (0 ή 1 φορές)
*	0 ή περισσότερες εμφανίσεις
+	1 ή περισσότερες εμφανίσεις
|	εναλλαγή (διάζευξη)
\	χαρακτήρας διαφυγής
(...)	ομαδοποίηση
[...]	ορισμός κλάσης χαρακτήρων
-	διάστημα χαρακτήρων (μέσα σε κλάση)
^	συμπλήρωμα του συνόλου χαρακτήρων (μέσα σε κλάση)
.	όλοι οι χαρακτήρες εκτός από τον EOL (End Of Line)
ϵ	κενή συμβολοσειρά

Παραδείγματα κανονικών εκφράσεων

- Ένα παράδειγμα: `(ab|cd+)?(ef)*`
  - Ταυτίζεται με: `abefef`, `efefef`, `cdef`, `cddd`
  - Δεν ταυτίζεται με: `abc`, `abcd`, `abcdef`
- Συχνά χρησιμοποιούμενες κανονικές εκφράσεις

Περιγραφή	**Κανονική έκφραση**
Πεζός λατινικός χαρακτήρας	`[a-z]`
Ακέραιος αριθμός	`[+-]?[0-9]+`
Έγκυρα ονόματα αναγνωριστικών στην C	`[a-zA-Z_][a-zA-Z_0-9]*`
Αριθμοί κινητής υποδιαστολής	`[+-]?(([0-9]+(.[0-9]*)?|.[0-9]+) ([eE][+-]?[0-9]+)?)`

Περιγραφή του συντακτικού μιας πηγαίας γλώσσας

- Η περιγραφή της οργάνωσης μιας πηγαίας γλώσσας γενικά γίνεται με την διατύπωση της *γραμματικής* της
- Η γραμματική απαρτίζεται από λεκτικούς και συντακτικούς κανόνες
- Σύνθετες δηλώσεις στην πηγαία γλώσσα περιγράφονται με αναδρομική εφαρμογή απλούστερων κανόνων
- Παράδειγμα σε BNF: Backus-Naur Form

```
expr ::= literal
|| expr <+> expr
|| expr <*> expr
```

- Αποδόμηση της εισόδου σε τερματικές (+,∗, literal) και μη-τερματικές (expr) λεκτικές μονάδες
- Συντακτική (και σημασιολογική) ανάλυση με αναγνώριση των γραμματικών κανόνων

Σχεδιασμός διαγράμματος ροής (flow chart)

- Το διάγραμμα ροής αποτελεί ένα είδος αναπαράστασης προγραμματικών δομών σε μια οποιαδήποτε γλώσσα (υψηλού ή χαμηλού επιπέδου)

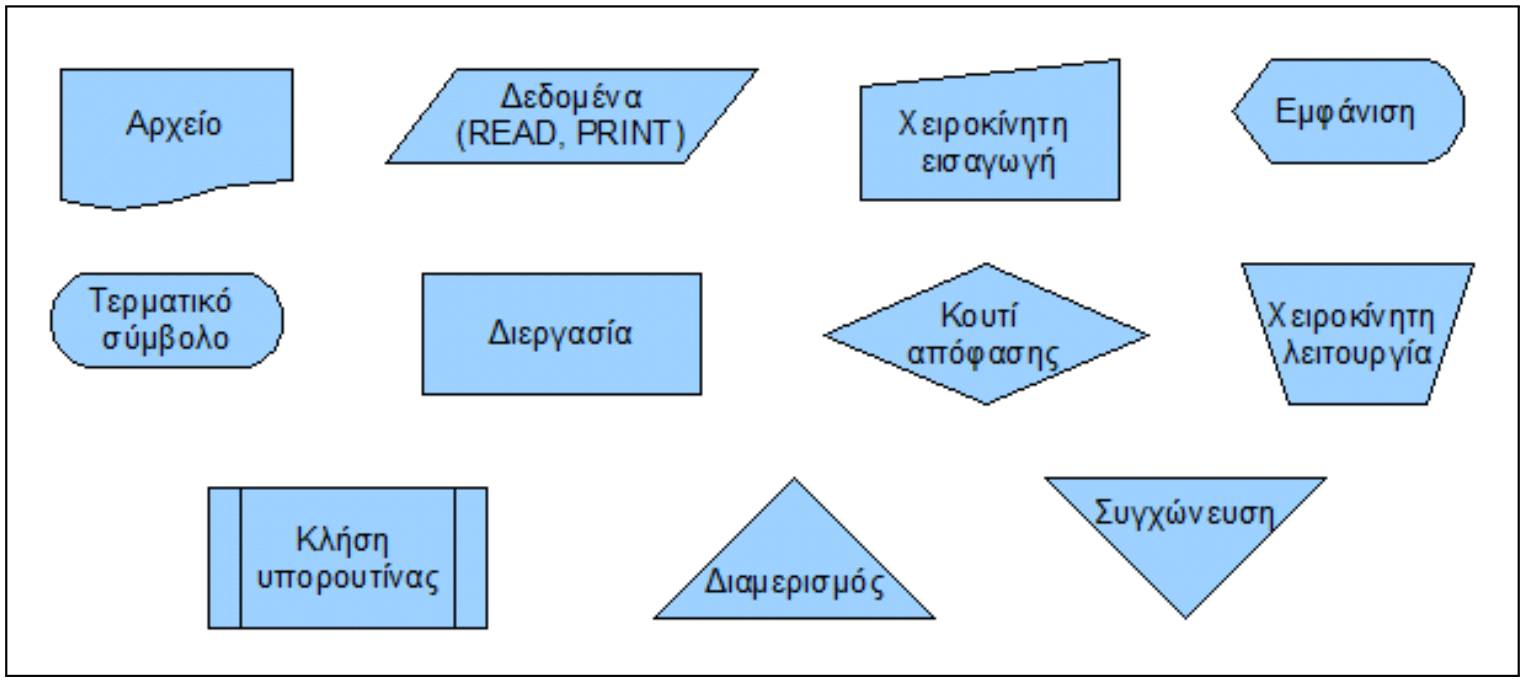

Σχεδιασμός διαγράμματος ροής (στα Αγγλικά)

- Οι χρησιμοποιούμενες διεθνώς ονομασίες των ενεργειών (προγραμματικών δομών) που μπορούν να αναπαρασταθούν σε ένα flow chart

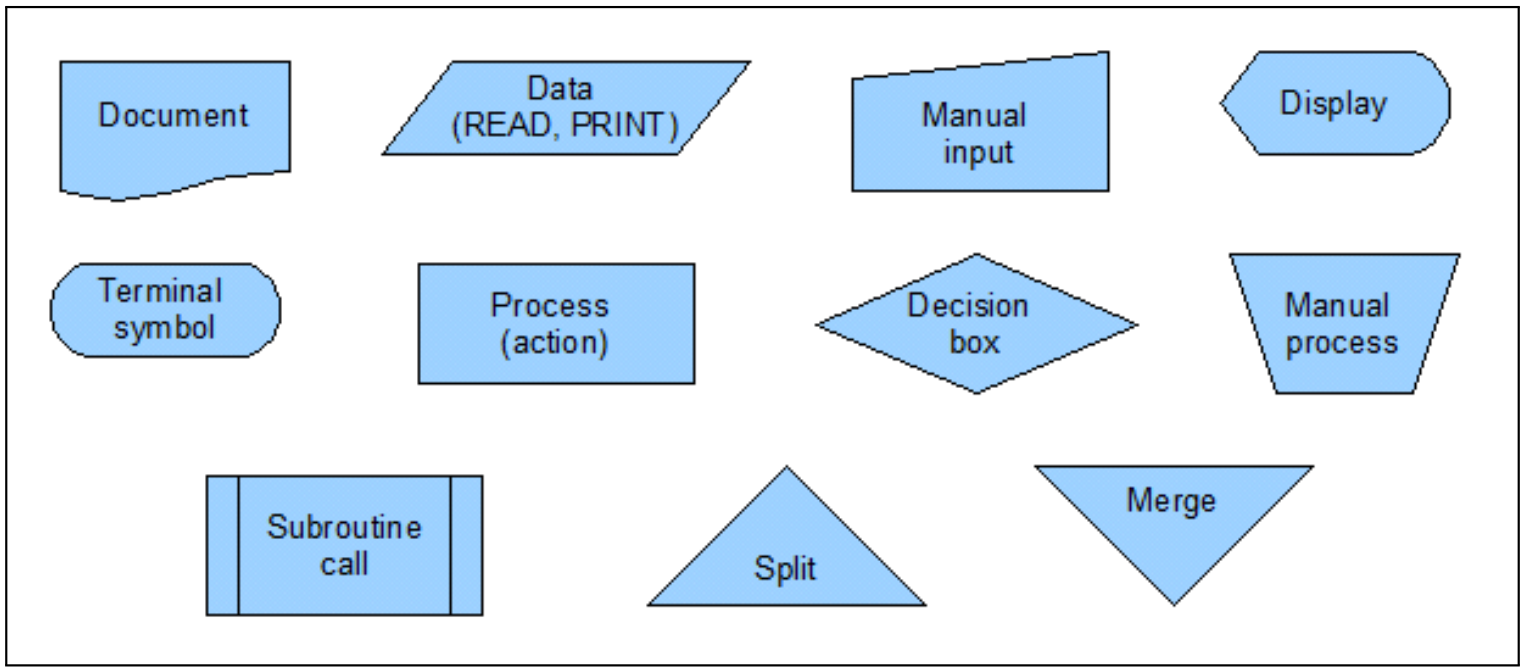

Η γλώσσα ANSI C [K&R, 1988]

- Η C είναι η συχνότερα χρησιμοποιούμενη γλώσσα για τον προγραμματισμό ενσωματωμένων συστημάτων (embedded systems) και εξακολουθεί να απολαμβάνει εκτίμησης για τον προγραμματισμό συστημάτων (UNIX, GNU software, Linux kernel)
- Ακολουθεί το διαδικαστικό μοντέλο προγραμματισμού
- Προσφέρεται για προγραμματισμό σε χαμηλό επίπεδο (κοντά στη γλώσσα μηχανής) και για αυτό συχνά αποκαλείται 'high-level assembly' ή 'portable assembly'
- Χαρακτηρίζεται από πολύ καλή μεταφερτότητα: μεταγλωττιστές για την C υφίστανται σχεδόν για οποιονδήποτε εμπορικό επεξεργαστή
- Η διαδικασία της μεταγλώττισης από την C είναι σχετικά απλή και κατανοητή

Προκαθορισμένοι τύποι δεδομένων στην C

- Βασικοί τύποι δεδομένων: `char`, `int`, `float`, `double`
- Η δήλωση `void` εκφράζει την απουσία τύπου
- Τα προσδιοριστικά `signed`, `unsigned` καθορίζουν το πρόσημο του αριθμού (μόνο για ακεραίους) και τα `short`, `long` το εύρος του σε bit (για `char` και `int`, το `long` μπορεί να χρησιμοποιηθεί και στη δήλωση ενός `double`)
- Οι τύποι `float` και `double` δηλώνουν αριθμούς κινητής υποδιαστολής απλής και διπλής ακρίβειας κατά το πρότυπο IEEE-754
- Το εύρος τιμών των `char`, `int` συνήθως εξαρτάται από το εύρος bit των καταχωρητών του επεξεργαστή και των δυνατοτήτων χειρισμού τους
- Υπάρχουν τρόποι για την υποστήριξη
  - Αριθμητικής αυθαίρετης ακρίβειας με χρήση κατάλληλων βιβλιοθηκών λογισμικού, π.χ. *gmp*
  - Εξομοίωσης της αριθμητικής κινητής υποδιαστολής από ρουτίνες πράξεων μόνο με ακεραίους: *SoftFloat*

Ο τελεστής sizeof

- Η C προσφέρει ένα μοναδιαίο τελεστή ο οποίος επιστρέφει το μέγεθος του ορίσματός του σε bytes
- Η απόκρισή του εξαρτάται από τον μεταγλωττιστή της C και χρησιμοποιεί την γνώση του για την αντιστοίχιση των βασικών τύπων δεδομένων με πόρους του επεξεργαστή
- Κανόνες

$$\begin{aligned}
&\text{sizeof(char)} = \text{sizeof(signed char)} = \text{sizeof(unsigned char)} \\
&\text{sizeof(char)} \leq \text{sizeof(short int)} \leq \text{sizeof(int)} \leq \text{sizeof(long int)} \\
&\text{sizeof(float)} \leq \text{sizeof(double)} \leq \text{sizeof(long double)}
\end{aligned}$$

- Παράδειγμα

```
char a; short int b; unsigned int c; long int d;
long long int e; float f; double g; long double h;
printf("Results: %d, %d, %d, %d, %d, %d, %d, %d\n",
sizeof(a), sizeof(b), sizeof(c), sizeof(d),
sizeof(e), sizeof(f), sizeof(g), sizeof(h));
```

- Αποτελέσματα σε έναν desktop x86: 1, 2, 4, 8, 4, 8, 12

Βασικές δομές ελέγχου: Δήλωση if-then-else

- Αναπαράσταση της δήλωσης `if` σε διαγράμματα ροής

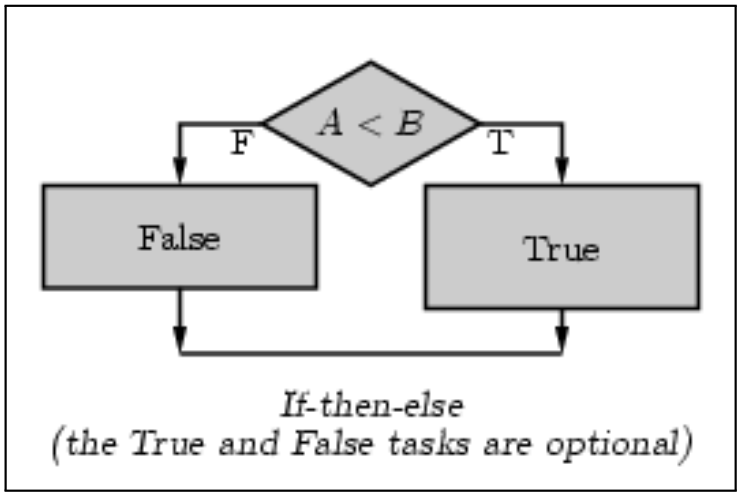

If-then-else
(the True and False tasks are optional)

- Δήλωση `if-else` στην C

```
if (A < B) {
  True;
} else {
  False;
}
```

Βασικές δομές ελέγχου: Δήλωση case

- Αναπαράσταση της δήλωσης `case` σε διαγράμματα ροής

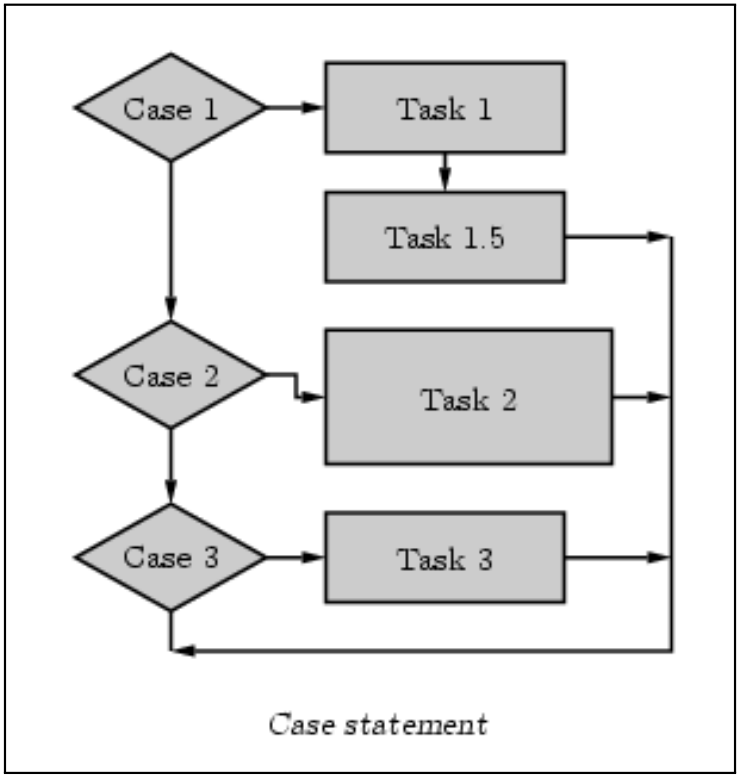

- Δήλωση `switch-case` στην C

```
switch (...) {
  case 1:
    Task 1;
    Task 1.5;
    break;
 case 2:
    Task 2;
    break;
  case 3;
    Task 3;
    break;
}
```

- Χωρίς `break` οι δηλώσεις `case` είναι fall-through
- `default: break;` μετά την τελευταία `case`

Βασικές δομές επανάληψης: Δήλωση while-do

- Έλεγχος συνθήκης πριν την εκτέλεση της πρώτης επανάληψης
- Αναπαράσταση της δήλωσης `while-do` σε διαγράμματα ροής

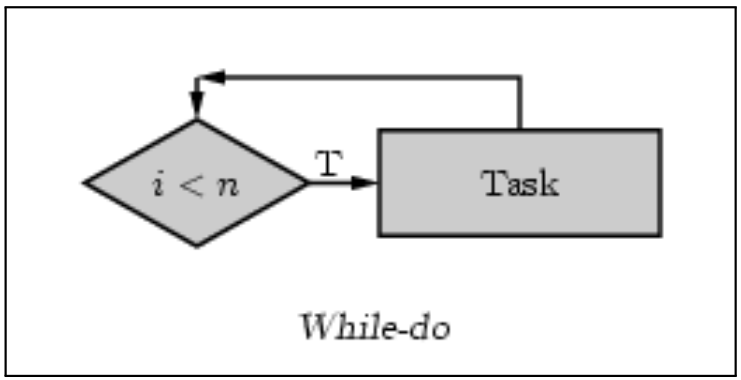

- Δήλωση `while-do` στην C

```
while (i < n) {
  Task;
}
```

- Είναι η θεμελιώδης δομή επανάληψης στην C. Οι δομές `for` και `do-while` μπορούν να εκφραστούν με τη βοήθεια της `while-do`

Βασικές δομές επανάληψης: Δήλωση repeat-until

- Εκτέλεση της πρώτης επανάληψης πριν τον έλεγχο της συνθήκης
- Αναπαράσταση της δήλωσης `repeat-until` σε διαγράμματα ροής

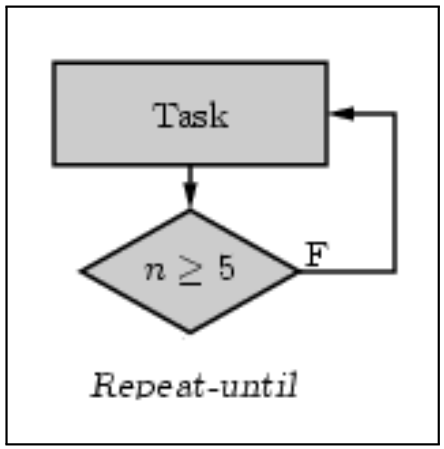

- Αντιστοιχεί στη δήλωση `do-while` της C
- ☞ Στην `do-while` χρησιμοποιείται η **ΣΥΜΠΛΗΡΩΜΑΤΙΚΗ** συνθήκη ελέγχου

```
do {
  Task;
} while (n < 5);
// uses the
// complementary
// condition of
// (n >= 5)
```

Παράδειγμα σύνθετης δομής

- Χρησιμοποιώντας τις βασικές δομές συνθέτουμε πολυπλοκότερες δομές οι οποίες αναπαριστούν αντίστοιχα τμήματα κώδικα στην πηγαία γλώσσα

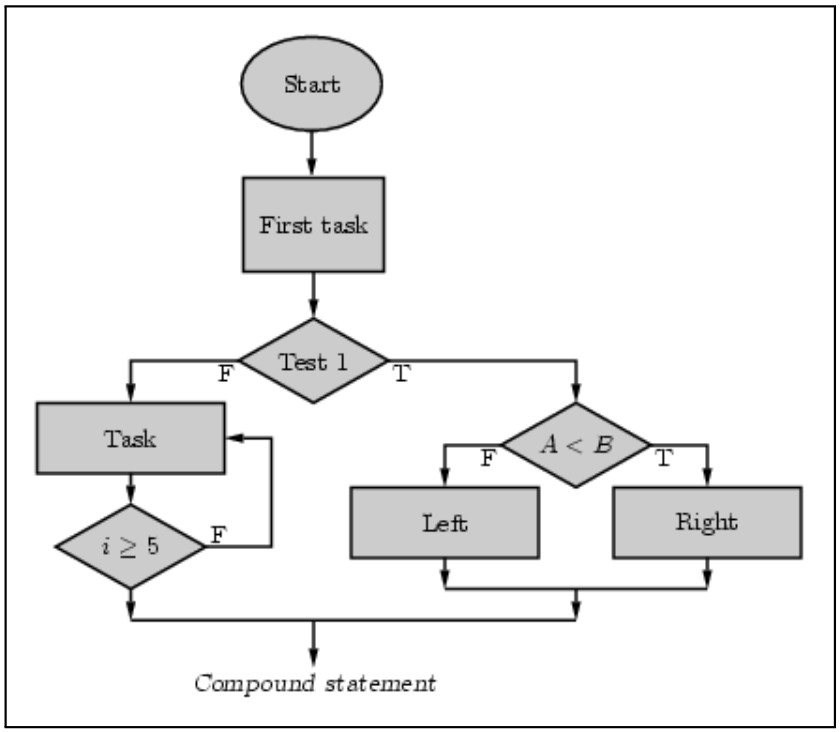

- Η σύνθετη δήλωση στην C

```
First task;
if (Test 1) {
  if (A < B) {
    Right;
  } else {
    Left;
  }
} else {
  do {
    Task;
  } while (i < 5);
}
```

Δηλώσεις άλματος

- Οι δηλώσεις άλματος (jump statements) στην C είναι: `break`, `continue`, `goto`

ℹ Και οι τρεις δηλώσεις μπορούν να αποφευχθούν όταν συντάσσουμε προγράμματα στην C

- `break;`
  - Η `break` προσφέρει πρόωρη έξοδο από τις δηλώσεις `for`, `while`, `do-while`, `switch`
  - Προκαλεί την άμεση έξοδο από τον εσώτερο βρόχο
- `continue;`
  - Χρησιμοποιείται στις δηλώσεις επανάληψης
  - Προκαλεί την άμεση έναρξη της επόμενης επανάληψης (iteration) με αντίστοιχη αύξηση του δείκτη
- `goto label;`
  - Προκαλεί άλμα στη θέση που σημειώνει η ετικέττα *label*
  - GOTO statement considered harmful ...

Πίνακες

- Οι πίνακες στην C αποτελούν συστοιχίες από ομοειδή στοιχεία τα οποία αποθηκεύονται σε διαδοχικές θέσεις στην κεντρική μνήμη του συστήματος
- Δήλωση πίνακα
  `int a[3];`
- Μηδενισμός των στοιχείων ενός πίνακα (απαραίτητος για δυναμικά καταμερισμένη μνήμη διαχειριζόμενη από συναρτήσεις τύπου `malloc()` και `free()`)
  `for (int i=0; i<len; a[i++]=0);`
- Διευθυνσιοδότηση πίνακα και χρήση δεικτών (pointers)
  - Έστω ο δείκτης `int *pa;`
  - Αντιστοίχιση στον πίνακα: `pa = a;`
  - Πρόσβαση στο στοιχείο στη θέση *i*: `a[i]` ή `*(a+i)`

Δήλωση συναρτήσεων (functions) στην C

- Η C υποστηρίζει τη δήλωση συναρτήσεων οι οποίες έχουν προαιρετικά επιστρεφόμενη τιμή και λίστα ορισμάτων
- Σύνταξη μιας συνάρτησης στην C

```
[return-type] function-name ([parameter-list]) {
  declarations
  statements
}
```

- Παράδειγμα συνάρτησης: Αναγωγή σε δύναμη

```
int power(int base, int exp)
{
  int i, p;
  p = 1;
  for (i=1; i<=exp; i++)
    p *= base;
  return p;
}
```

Η συνάρτηση `main`

- Η συνάρτηση `main` αποτελεί το σημείο εισόδου για την εκτέλεση ενός προγράμματος στην C
- Η `main` μπορεί να δηλωθεί χωρίς ορίσματα: `int main(void)` στην ISO C
- Η πλήρης δήλωσή της περιλαμβάνει τα ειδικά ορίσματα `argc` και `argv` όπως φαίνεται στο εξής πρότυπο συνάρτησης (function prototype):
  `int main(int argc, char *argv[]);`
- Με τη δήλωση αυτή, η `main` μπορεί να δεχθεί ορίσματα από τη γραμμή εντολών
- Το όρισμα `argc` (=argument counter) είναι ο αριθμός των ορισμάτων που δίνεται ως είσοδος στην εκτελέσιμη μορφή του προγράμματος από τη γραμμή εντολών
- Το όρισμα `argv` (=argument vector) είναι ένας δείκτης στον πίνακα που περιέχει τις συμβολοσειρές στις οποίες καταγράφηκαν τα ορίσματα εισόδου του προγράμματος.

Παράδειγμα πηγαίου προγράμματος σε ANSI C

- Ο αλγόριθμος του Ευκλείδη για τον Μέγιστο Κοινό Διαιρέτη

```c
// euclid.c
int gcd(int m, int n)
{
  int r;
  while ((r = m % n) != 0) {
    m = n;
    n = r;
  }
  return n;
}

int main()
{
  int result = gcd(60, 8);
  return (result);
}
```

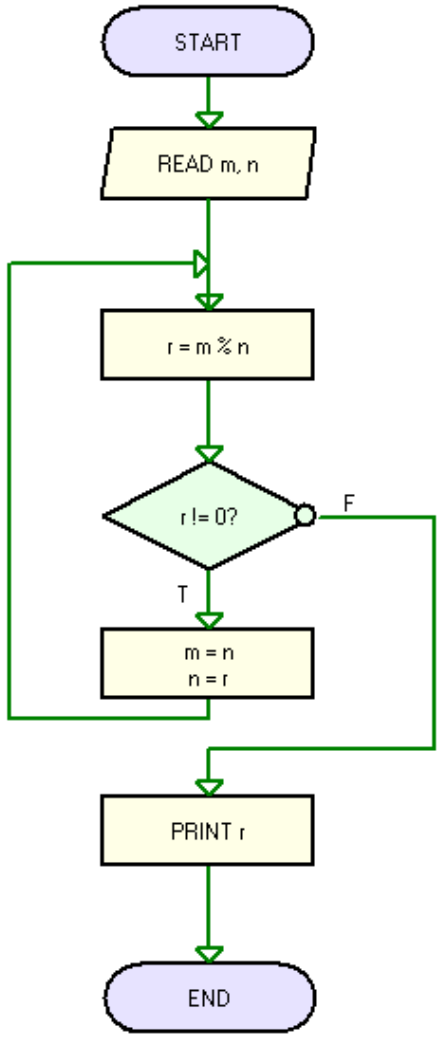

Ένα ακόμη παράδειγμα: Η συνάρτηση factorial

- Υπολογισμός του $N!$

```
// factorial.c
int factorial(int N)
{
  int M, F;

  M = 1;
  F = 1;

  for (M=1; M!=N; M++)
  {
    F = F * M;
  }

  return F;
}
```

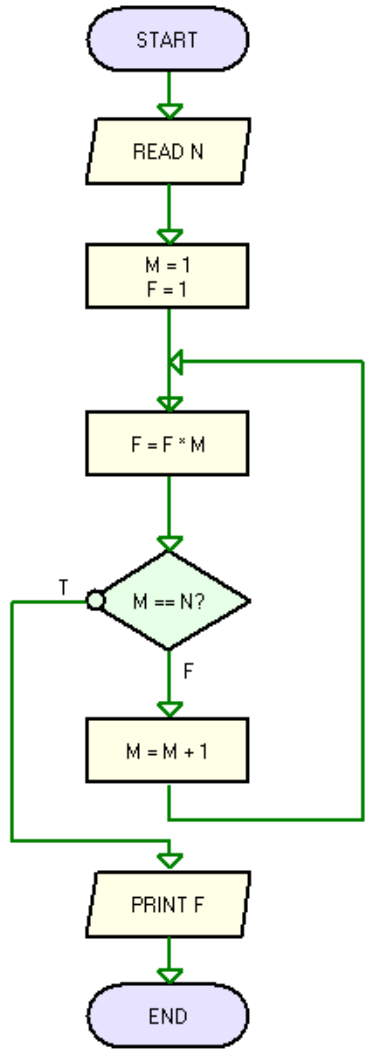

Η έννοια της μεταγλώττισης (compilation)

- Η έννοια της μεταγλώττισης στην επιστήμη των υπολογιστών είναι γενική
- Αναφέρεται στη διαδικασία της μετάφρασης (μετατροπής) από μία πηγαία γλώσσα η οποία διέπεται από λεκτικούς και συντακτικούς κανόνες (γραμματική) σε κάποια τελική γλώσσα στο ίδιο ή διαφορετικό επίπεδο αφαίρεσης
- Με τον όρο compiler αναφέρεται το λογισμικό που επιτελεί τη μετάφραση προγραμμάτων σε γλώσσα προγραμματισμού υψηλού επιπέδου (HLL) στο επίπεδο του κώδικα μιας πραγματικής ή εικονικής μηχανής

Η δομή του μεταγλωττιστή

- Η διαδικασία της μεταγλώττισης μπορεί να χωριστεί στην φάση της 'ανάλυσης' και στην φάση της 'σύνθεσης'
  - **ΑΝΑΛΥΣΗ**: αποδόμηση και κατανόηση του πηγαίου προγράμματος
  - **ΣΥΝΘΕΣΗ**: κατασκευή του αποτελέσματος στην τελική γλώσσα διατηρώντας σημασιολογική ισοδυναμία με το πηγαίο πρόγραμμα
- Οι πρακτικοί μεταγλωττιστές αποτελούνται από πολλά τμήματα τα οποία εκτελούνται διαδοχικά
- Στα επιμέρους τμήματα του μεταγλωττιστή μπορεί να πραγματοποιείται ανάλυση και ενδεχόμενα μετασχηματισμός της εισόδου

Τυπικός σχεδιασμός ενός μεταγλωττιστή ([Aho, 2008, (μετφρ. Ελληνικά), Πιντέλας, 2003])

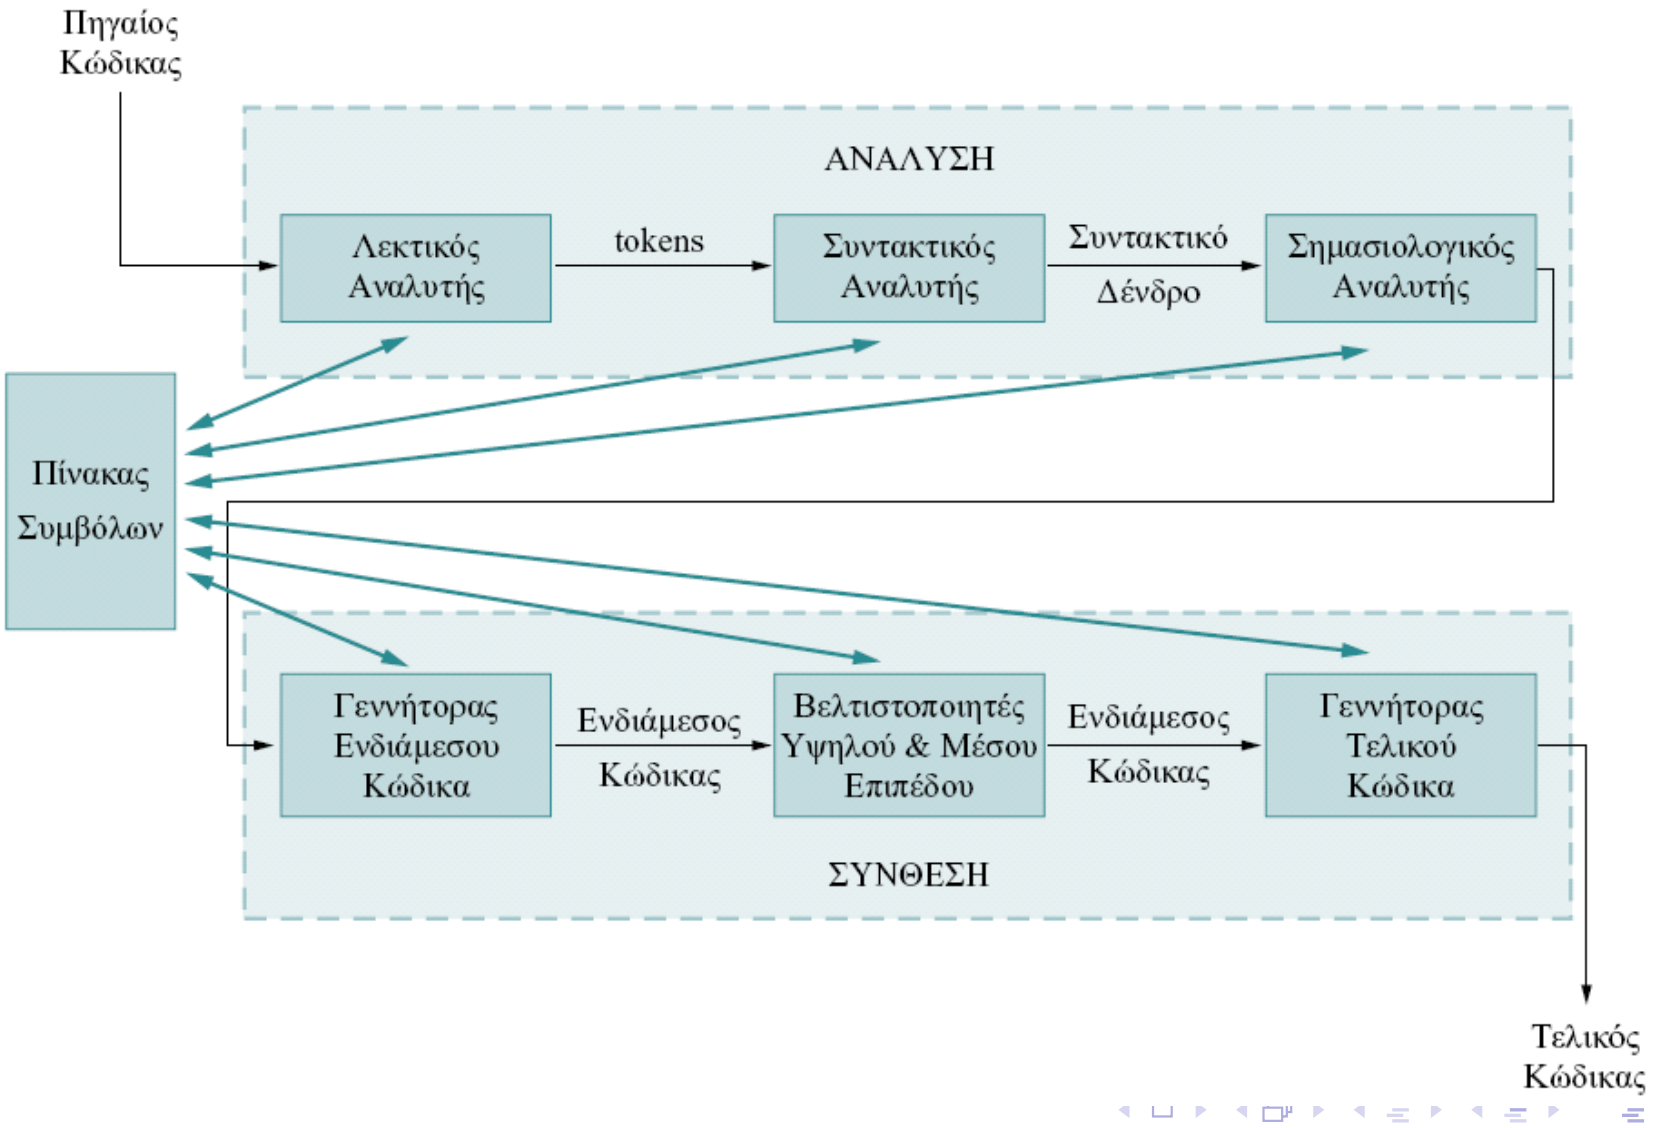

Λεκτικός αναλυτής (lexical analyzer)

- Ο λεκτικός αναλυτής ομαδοποιεί τους χαρακτήρες της εισόδου σε Λεκτικές Μονάδες (tokens)
- Τα πρότυπα των λεκτικών μονάδων εκφράζονται μέσω *κανονικών εκφράσεων*
- Παράδειγμα
  `position = initial + rate*60;`
- Ανάλυση σε λεκτικές μονάδες

`position, initial, rate`	τύπου προσδιοριστή (identifier)
`60`	τύπου σταθεράς
`=, *, +`	τύπου πράξης (τελεστές)
`;`	τύπου στίξης (διαχωριστής εντολών)

Συντακτικός αναλυτής (syntax analyzer)

- Ομαδοποιεί τις λεκτικές μονάδες τις οποίες αναγνωρίζει ο λεκτικός αναλυτής σε συντακτικές μονάδες
- Παράγει αναπαράσταση του πηγαίου προγράμματος σε μορφή συντακτικού δένδρου
- Γίνεται έλεγχος για την ύπαρξη συντακτικών λαθών εφαρμόζοντας τους κανόνες της γραμματικής της γλώσσας
- Το συντακτικό δένδρο για την έκφραση `position = ...`

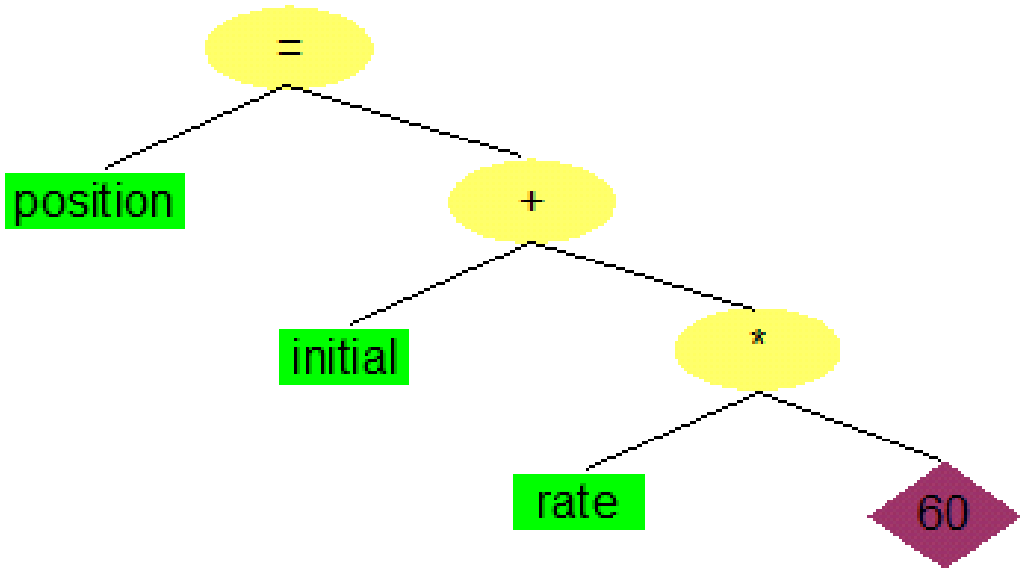

Ο σημασιολογικός αναλυτής (semantics analyzer)

- Ο σημασιολογικός αναλυτής αναλύει το συντακτικό δένδρο χρησιμοποιώντας πληροφορία που σχετίζεται τόσο με τους τύπους όσο και με τις τιμές των συμβόλων
- Στο παράδειγμα, έλεγχος των δηλώσεων (declaration) των αναγνωριστικών πριν τη χρησιμοποίηση τους στον κώδικα
- Η σημασιολογική ανάλυση ενημερώνει την αναπαράσταση συντακτικού δένδρου με πληροφορία όπως για την εγκυρότητα χρήσης των τελεστών ανάλογα με τους τύπους των αναγνωριστικών: π.χ. το αναγνωριστικό `rate` είναι τύπου `REAL`
- Σε ορισμένους απλούς μεταγλωττιστές, ο σημασιολογικός αναλυτής μπορεί να παράγει ενδιάμεσο ή τελικό κώδικα
  - Αφορά πολύ απλές μηχανές όπως επεξεργαστές στοίβας
  - Ο παραγόμενος κώδικας δεν είναι βελτιστοποιημένος

Γεννήτορας ενδιάμεσου κώδικα

- Δέχεται ως είσοδο το συντακτικό δένδρο και παράγει κώδικα για μια απλή εικονική (virtual) μηχανή
- Ενδιάμεση αναπαράσταση (IR: Intermediate Representation) όπως μορφής κώδικα τριών διευθύνσεων ή τετράδων (quadruples)
- Για το παράδειγμα:

```
temp1 = int2real(60);
temp2 = rate * temp1;
temp3 = initial + temp2;
position = temp3;
```

- Η χρήση IR επιτρέπει την παραγωγή τελικού κώδικα για διαφορετικές μηχανές (στοχευόμενες αρχιτεκτονικές) χωρίς την επανάληψη της λεκτικής, συντακτικής και σημασιολογικής ανάλυσης του πηγαίου προγράμματος
- Για κάθε νέα αρχιτεκτονική χρειάζεται το αντίστοιχο τμήμα του μεταγλωττιστή για την γέννηση τελικού κώδικα από την IR
- Το τελευταίο ισχύει στους επαναστοχεύσιμους μεταγλωττιστές (retargetable compilers)

Βελτιστοποιητές υψηλού και μεσαίου επιπέδου

- Οι βελτιστοποιητές υψηλού και μεσαίου επιπέδου περιλαμβάνουν πολλές αλληλοδιαδεχόμενες διαδικασίες: αναλύσεις ή/και μετασχηματισμούς
- ☞ Ονομάζονται 'περάσματα' (passes) του μεταγλωττιστή
- Σκοπός είναι η 'βελτίωση' του ενδιάμεσου κώδικα του πηγαίου προγράμματος
- Τελικό ζητούμενο είναι ο ταχύτερα εκτελούμενος τελικός κώδικας και οι μικρότερες απαιτήσεις μνήμης για εντολές και δεδομένα του προγράμματος
- Για το παράδειγμα, το αποτέλεσμα των βελτιστοποιήσεων θα μπορούσε να είναι:

```
temp1 = rate * 60.0;
position = initial + temp1;
```

- Η `temp1` είναι προσωρινή μεταβλητή (temporary variable)
- Οι βελτιστοποιήσεις μεταγλωττιστών αποτελούν ανοικτό πεδίο έρευνας

Γεννήτορας τελικού κώδικα

- Ο γεννήτορας τελικού κώδικα δέχεται ως είσοδο την IR και παράγει ως έξοδο τον τελικό κώδικα (γλώσσα μηχανής ή συμβολομεταφραστή)
  - Ανάθεση των μεταβλητών στις αντίστοιχες θέσεις μνήμης
  - Επιλογή των εντολών επιπέδου συμβολομεταφραστή (εντολές από το ρεπερτόριο του επεξεργαστή ή της εικονικής μηχανής)
  - Αντιστοίχιση μεταβλητών με καταχωρητές του επεξεργαστή
- Τελικός κώδικας για το παράδειγμα (MIPS32)

```
mul.s $f2, $f1, 60.0
add.s $f3, $f3, $f2
```

Βελτιστοποιητής χαμηλού επιπέδου

- Ο βελτιστοποιητής χαμηλού επιπέδου χρησιμοποιείται ορισμένες φορές για περαιτέρω βελτίωση του τελικού κώδικα
- Αξιοποιεί ιδιαίτερα χαρακτηριστικά της στοχευόμενης αρχιτεκτονικής
- Παραδείγματα βελτιστοποιητών χαμηλού επιπέδου
  - Χρονοπρογραμματιστής εντολών (instruction scheduler): τοποθετεί τις εντολές του επεξεργαστή σε χρονοθυρίδες (time-slots) για την παράλληλη εκτέλεσή τους
  - Υπερβελτιστοποιητής (superoptimizer): βελτιστοποιεί περιοχές του τελικού κώδικα με εφαρμογή ωμής δύναμης
  - Βελτιστοποιητής κλειδαρότρυπας (peephole optimizer): επιβάλλει μακρο-αντικαταστάσεις με ή χωρίς συνθήκη, εξετάζοντας κάθε φορά ένα 'παράθυρο' του τελικού κώδικα

Ο πίνακας συμβόλων (symbol table)

- Ο πίνακας συμβόλων βρίσκεται στην 'καρδιά' του μεταγλωττιστή
- Είναι η βάση δεδομένων για τα σύμβολα του πηγαίου προγράμματος
- Υποβοηθά όλα τα υπόλοιπα τμήματά του μεταγλωττιστή παρέχοντας τις δομές που απαιτούνται, για να τοποθετήσουν και να ανακτήσουν πληροφορίες
- Μια τυπική εγγραφή στον πίνακα συμβόλων μιας μεταβλητής περιέχει το όνομά της, τη διεύθυνση μνήμης, τον τύπο και την εμβέλειά της
- Μια εγγραφή συνάρτησης θα περιέχει μεταξύ άλλων το όνομά της, τον αριθμό και τον τύπο των ορισμάτων της

Μεταγλωττιστές για πολλές πηγαίες και τελικές γλώσσες

- Αρκετά νωρίς (αρχές ΄50) τέθηκε το πρόβλημα του μεταγλωττιστή ο οποίος κατανοεί πολλές (n) γλώσσες εισόδου και παράγει κώδικα σε (m) γλώσσες χαμηλού επιπέδου
- Ο μεταγλωττιστής αυτός θα έπρεπε να επιτελεί $n \times m$ τρόπους μετάφρασης

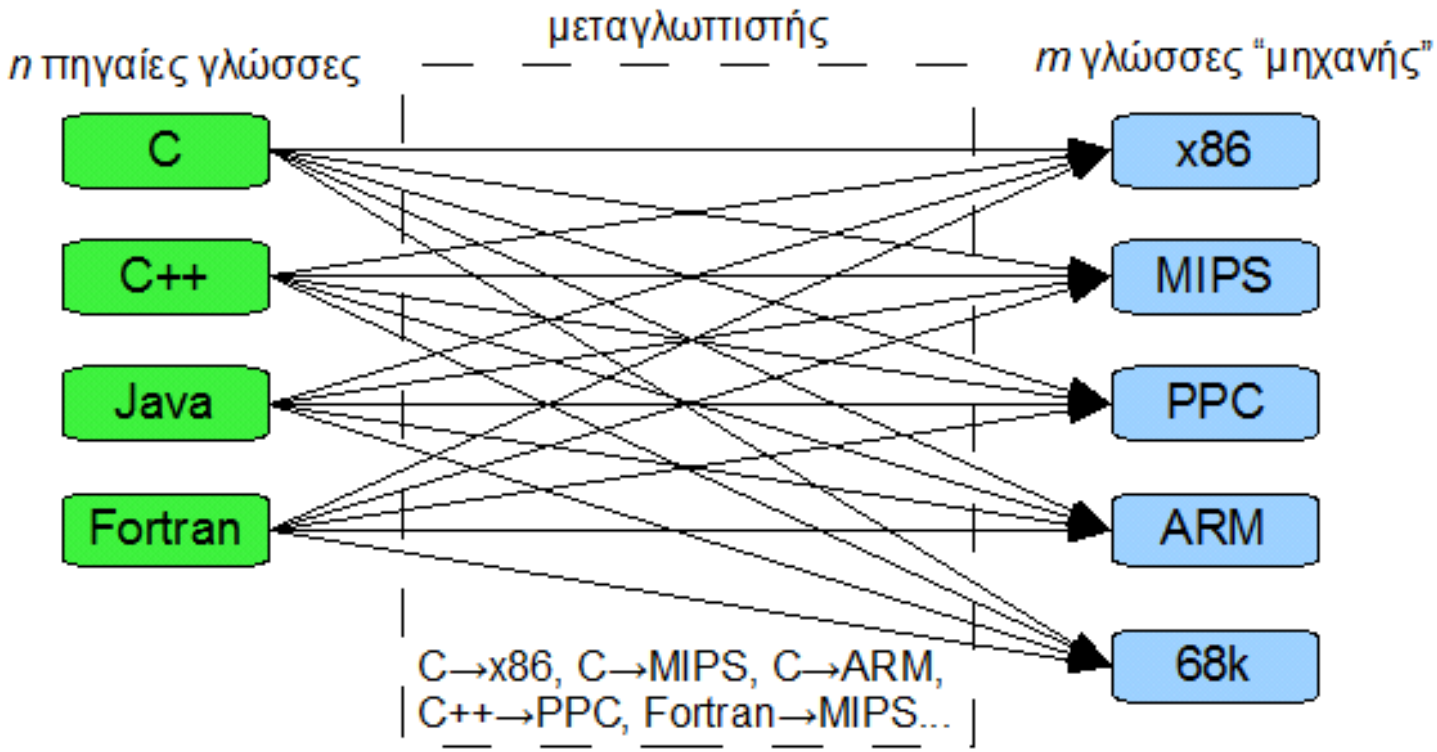

Η χρησιμότητα της ενδιάμεσης αναπαράστασης

- Λόγω της προφανούς μη πρακτικότητας, προτάθηκε διαδικασία δύο σταδίων:
  1. μετάφραση από την πηγαία γλώσσα (HLL: High-Level Language) σε μια ενδιάμεση αναπαράσταση (IR)
  2. μετάφραση από την ενδιάμεση αναπαράσταση στη γλώσσα χαμηλού επιπέδου (LLL: Low-Level Language)
- Υποστήριξη $n + m$ μηχανισμών μεταγλώττισης αντί για $n \times m$
- Το τμήμα του μεταγλωττιστή που επιτελεί την μετάφραση HLL→IR ονομάζεται *frontend*
- Το τμήμα του μεταγλωττιστή που επιτελεί την μετάφραση IR→LLL ονομάζεται *backend*

Ο πρακτικός μεταγλωττιστής

- Με χρήση της IR απαιτούνται 9 μηχανισμοί μεταγλώττισης αντί για 20

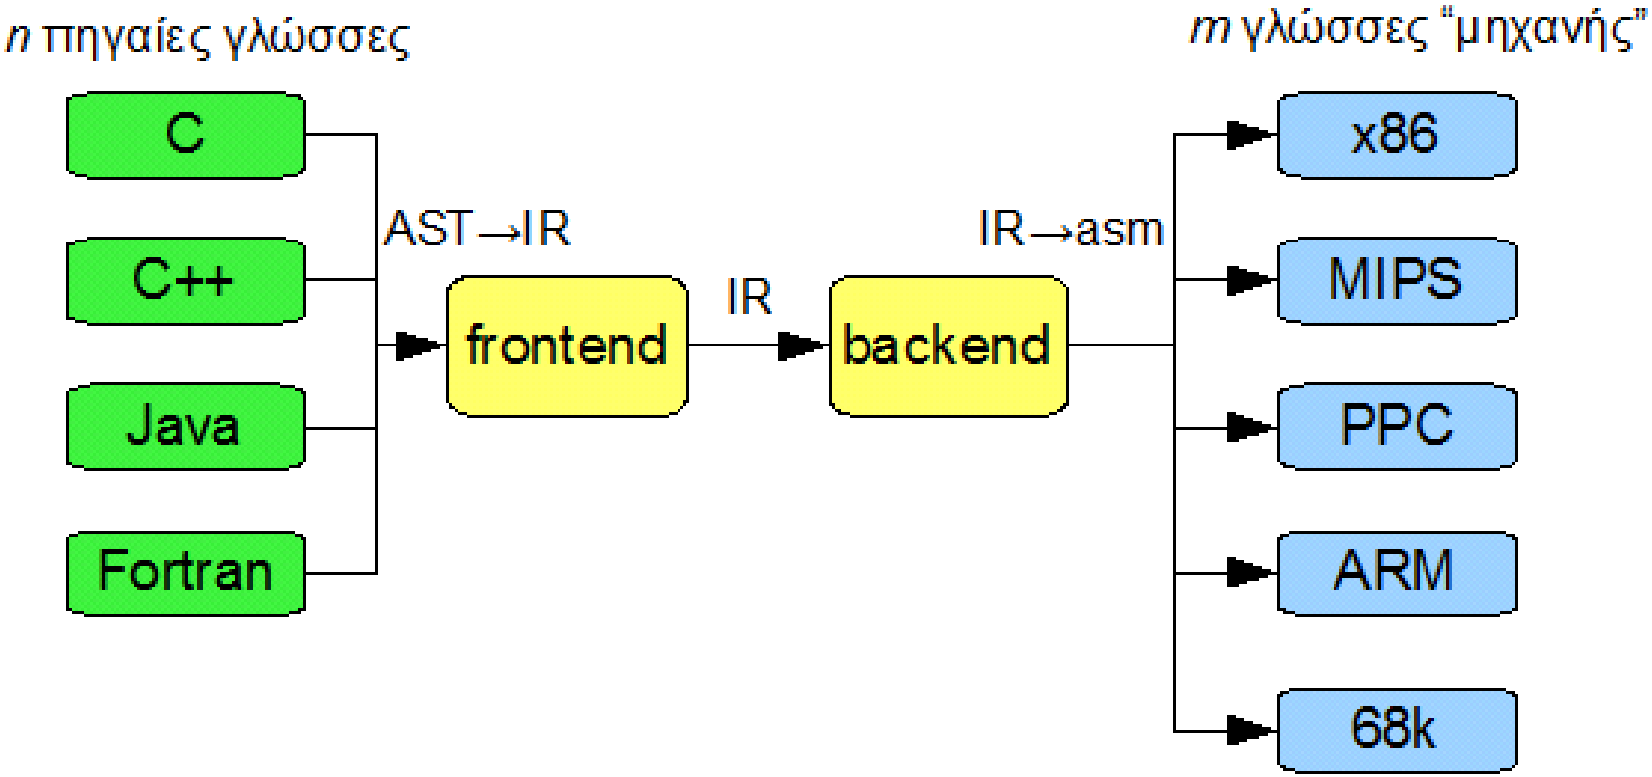

Βασικά εργαλεία στην ανάπτυξη λογισμικού: Ορισμοί ([Δ. Σπινέλλης: Computers for all])

- Κειμενογράφος/Διορθωτής (Editor):
  Επιτρέπει τη συγγραφή και την αλλαγή του προγράμματος
- Προεπεξεργαστής (Preprocessor):
  Επεξεργάζεται το πρόγραμμα εκτελώντας απλούς συμβολικούς μετασχηματισμούς και παράγει ένα ισοδύναμο πρόγραμμα (αφορά τις C, C++, Fortran)
- Συμβολομεταφραστής (Assembler):
  Μετατρέπει τη συμβολική γλώσσα του επεξεργαστή σε γλώσσα μηχανής
- Μεταγλωττιστής (Compiler):
  Μεταφράζει μια γλώσσα υψηλού επιπέδου σε γλώσσα επιπέδου μηχανής
- Διερμηνευτής (Interpreter):
  Εκτελεί άμεσα ένα πρόγραμμα σε γλώσσα υψηλού επιπέδου
- Συνδέτης (Linker):
  Συρράφει τμήματα ενός προγράμματος που έχουν μεταγλωττιστεί ξεχωριστά σε ένα ενιαίο πρόγραμμα
- Φορτωτής (Loader):
  Φορτώνει το πρόγραμμα στη μνήμη του επεξεργαστή διορθώνοντας αναφορές σε θέσεις μνήμης εντολών και δεδομένων του προγράμματος
- Αποσφαλματωτής (Debugger):
  Επιτρέπει την εκτέλεση του προγράμματος βήμα-βήμα με σκοπό την ανίχνευση λαθών που μπορεί να περιέχει το πρόγραμμα

Η εργαλειοθήκη του σχεδιαστή μεταγλωττιστών

- Κειμενογράφος/Διορθωτής:
  vi, emacs, Geany, Context
- Λεκτική/συντακτική ανάλυση:
  lex+yacc, flex+bison, ANTLR (πρώην PCCTS), GOLD Parser Builder
- Συμβολομεταφραστής-Συνδέτης-Αποσυμβολομεταφραστής:
  binutils (as, ld, objdump)
- Μεταγλωττιστής (Compiler):
  GCC, LCC, LLVM, COINS, Phoenix, PCC, Trimaran, SUIF/Machine-SUIF, ACSE, xcc, jackcc
- Πρότυπη βιβλιοθήκη της C:
  glibc, newlib, uclibc
- Αποσφαλματωτής (Debugger):
  GDB
- Γεννήτορες γεννητόρων κώδικα:
  BURG, IBURG, LBURG, OLIVE
- Οπτικοποίηση γράφων:
  Graphviz, VCG
- Άλλα εργαλεία:
  sparse, Aha!, superopt, copt

Χρήσιμα βιβλία

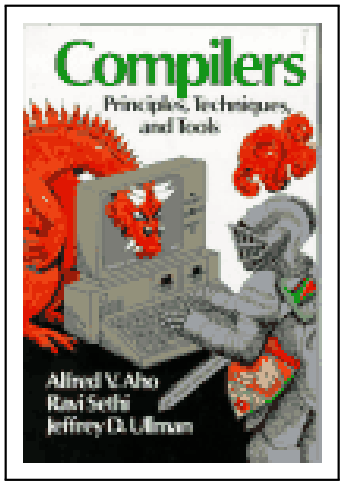

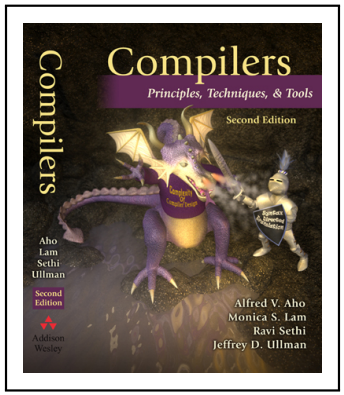

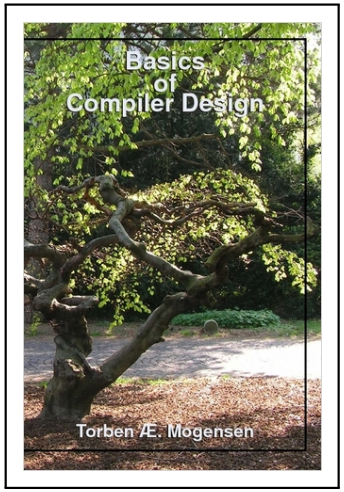

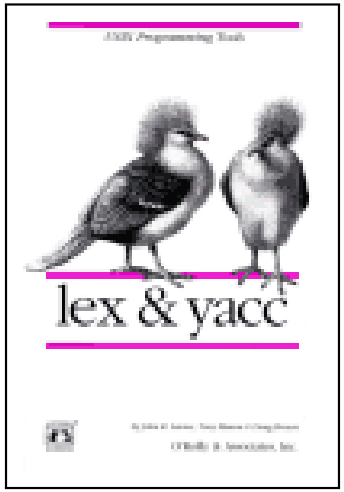

Αναφορές του μαθήματος Ι


B. W. Kernighan and D. M. Ritchie, *The C Programming Language*, 2nd ed. Prentice Hall PTR, One Lake Street, Upper Saddle River, New Jersey 07458, USA: Prentice-Hall, 1988.


A. V. Aho, R. Sethi, and J. D. Ullman, *Μεταγλωττιστές: Αρχές, Τεχνικές και Εργαλεία*, με την επιμέλεια των: Αγγελος Σπ. Βώρος και Νικόλαος Σπ. Βώρος και Κων/νος Γ. Μασσέλος, **κεφάλαια 1.1, 3.3**, Εκδόσεις Νέων Τεχνολογιών, 2008. Website for the English version: `http://dragonbook.stanford.edu`


Παναγιώτης Πιντέλας και Παναγιώτης Αλεφραγκής, *Μεταγλωττιστές (Πρακτική Εξάσκηση σε Θέματα Λογισμικού: Τόμος Ά)*, ***κεφάλαια 1, 2.3***. Ελληνικό Ανοικτό Πανεπιστήμιο, 2003. [Online]. Available: `http://www.pli.eap.gr/pdf/PLH40/PLH40-1/pintellas2.pdf`


Διομήδης Σπινέλλης. Σειρά διαλέξεων: "Computers For All". [Online]. Available: `http://www.dmst.aueb.gr/dds/cfa/`