Εικονικές Μηχανές, Διερμηνείς και Δυναμική Διαχείριση Μνήμης

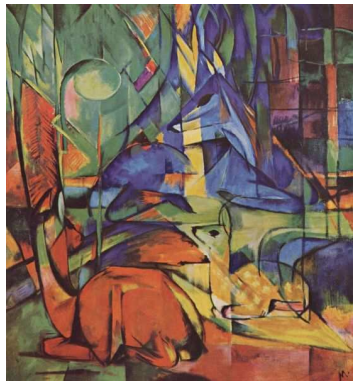

Franz Marc, *Rehe im Walde (II)*, 1913-14

Κωστής Σαγώνας <kostis@cs.ntua.gr>

Περιεχόμενα

- Εικονικές μηχανές (Virtual Machines)
- Διερμηνείς (Interpreters)
- Δυναμική διαχείριση μνήμης
  - Στοίβες (Stacks)
  - Σωροί (Heaps)
- Συλλογή σκουπιδιών (Garbage Collection)
  - Μαρκάρισμα και σκούπισμα (mark and sweep)
  - Αντιγραφή (copying)
  - Μέτρημα αναφορών (reference counting)

Εικονικές Μηχανές (Virtual Machines)

Οι εικονικές μηχανές (VMs) αποτελούν ένα ενδιάμεσο στάδιο στη μεταγλώττιση των γλωσσών προγραμματισμού

- Οι VMs είναι μηχανές διότι επιτρέπουν τη βήμα προς βήμα εκτέλεση των προγραμμάτων
- Οι VMs είναι εικονικές (ή αφηρημένες) διότι συνήθως
  - δεν υλοποιούνται στο υλικό κάποιου υπολογιστή
  - παραλείπουν πολλές από τις λεπτομέρειες των πραγματικών υπολογιστικών μηχανών (αυτών που υλοποιούνται σε hardware)
- Οι VMs συνήθως έχουν συστατικά στοιχεία που υλοποιούν λειτουργίες που είναι αναγκαίες για την υλοποίηση συγκεκριμένων (κλάσεων) γλωσσών προγραμματισμού

Εικονικές Μηχανές: Πλεονεκτήματα

- Γεφυρώνουν το χάσμα του υψηλού επιπέδου των γλωσσών προγραμματισμού και του χαμηλού επιπέδου των πραγματικών υπολογιστών μηχανών
- Απαιτούν λιγότερη προσπάθεια για την υλοποίησή τους και για τη μεταγλώττιση των προγραμμάτων
- Ο πειραματισμός και η μετατροπή τους είναι ευκολότερη από ότι η μετατροπή ενός μεταγλωττιστή για τη γλώσσα
  - Σημαντικές ιδιότητες, ειδικά για πρωτοεμφανιζόμενες γλώσσες

Εικονικές Μηχανές: Πλεονεκτήματα

- Προσφέρουν αυξημένη φορητότητα (portability)
  - Οι διερμηνείς VM συνήθως υλοποιούνται σε C
  - Ο VM κώδικας μπορεί να μεταφερθεί μέσω διαδικτύου και να τρέξει στις περισσότερες υπολογιστικές πλατφόρμες
  - Συνήθως, ο VM κώδικας για ένα πρόγραμμα είναι (σημαντικά) μικρότερος σε μέγεθος από τον αντίστοιχο κώδικα μηχανής
- Αρκετές ιδιότητες ασφάλειας του VM κώδικα μπορούν να επαληθευθούν (verified) μηχανικά
- Είναι ευκολότερο να αποδείξουμε τυπικά την ορθότητα του σχεδιασμού και της υλοποίησής των VMs
- Η μέτρηση της επίδοσης (profiling) και η αποσφαλμάτωση (debugging) προγραμμάτων είναι ευκολότερες

Εικονικές Μηχανές: Μειοκτήματα

- Χειρότερη επίδοση (σε χρόνο) των διερμηνέων εικονικών μηχανών σε σχέση με την εκτέλεση εντολών σε γλώσσα μηχανής λόγω του
  - Επιπλέον κόστους διερμηνίας (overhead of interpretation)
  - Ότι είναι σημαντικά πιο δύσκολο να επωφεληθούμε από κάποια χαρακτηριστικά του μοντέρνου hardware των υπολογιστών (π.χ. του hardware-based branch prediction)

Ιστορία των Εικονικών Μηχανών

- Οι πρώτες VMs εμφανίστηκαν στα τέλη της δεκαετίας του 1950
- Οι πρώτες υλοποιήσεις της Lisp (1958) χρησιμοποίησαν VMs με αυτόματη ανακύκλωση μνήμης (garbage collection), sandboxing, reflection, και διαδραστικό φλοιό (interactive shell)
- Στις αρχές της δεκαετίας του 1970, η γλώσσα Forth χρησιμοποίησε μια μικρή και σχετικά εύκολα υλοποιήσιμη VM
- Η γλώσσα Smalltalk (τέλη του 1970) ήταν από τις πρώτες γλώσσες της οποίας η υλοποίηση επέτρεπε την αλλαγή του κώδικα κατά τη διάρκεια εκτέλεσης του προγράμματος (πρώτο πραγματικά διαδραστική υλοποίηση αντικειμενοστρεφούς γλώσσας προγραμματισμού)
- Η υλοποίηση της γλώσσας Self μέσω VM (τέλη του 1980), μιας γλώσσας με πολλά κοινά στοιχεία με τη Smalltalk, κατάφερε να είναι τέτοια ώστε η επίδοσή της να μη διαφέρει πολύ από αυτήν που αντίστοιχοι μεταγλωττιστές της γλώσσας επιτύγχαναν
- Η Java (μέσα του 1990) έκανε τις VMs ευρέως χρησιμοποιούμενες και γνωστές

Επιλογές σχεδιασμού των Εικονικών Μηχανών

- Κάποιες επιλογές σχεδιασμού των VMs είναι παρόμοιες με επιλογές που κάνουμε κατά το σχεδιασμό της μορφής του ενδιάμεσου κώδικα ενός μεταγλωττιστή. Για παράδειγμα
  - Θέλουμε η μηχανή να χρησιμοιποιείται σε πολλές διαφορετικές αρχιτεκτονικές και λειτουργικά συστήματα; (όπως π.χ. η JVM)
  - Θέλουμε η μηχανή να χρησιμοιποιείται σε πολλές διαφορετικές γλώσσες πηγαίου κώδικα; (όπως π.χ. το CLI/CLR (.NET))
- Κάποιες άλλες είναι παρόμοιες με αυτές του backend ενός compiler:
  - Είναι καλύτερη επίδοση πιο σημαντική από μεγαλύτερη φορητότητα;
  - Είναι η αξιοπιστία πιο σημαντική από την επίδοση;
  - Είναι το (μικρότερο) μέγεθος του κώδικα πιο σημαντικός παράγοντας από την επίδοση σε ταχύτητα της μηχανής;
- Κάποιες άλλες παρόμοιες με αυτές των λειτουργικών συστημάτων:
  - Πως υλοποιείται η διαχείριση μνήμης, ο ταυτοχρονισμός, οι εξαιρέσεις, …
  - Είναι η μικρή κατανάλωση μνήμης, το scalability, ή η ασφάλεια πιο σημαντικά χαρακτηριστικά από την επίδοση;

Συστατικά των Εικονικών Μηχανών

- Εξαρτώνται από πολλούς παράγοντες:
  - Είναι η γλώσσα (το περιβάλλον της γλώσσας) διαδραστική;
  - Η γλώσσα υποστηρίζει ενδοσκόπηση (reflection) και/ή δυναμικό φόρτωμα κώδικα (dynamic loading);
  - Είναι η επίδοση το παν;
  - Χρειάζεται η γλώσσα να υποστηρίζει ταυτοχρονισμό;
  - Είναι απαραίτητο το sandboxing;

Υλοποίηση των Εικονικών Μηχανών

- Οι εικονικές μηχανές συνήθως γράφονται σε “φορητές” γλώσσες προγραμματισμού όπως η C ή η C++
- Για μέρη που είναι σημαντικά για την επίδοση της εικονικής μηχανής, συνήθως χρησιμοποιούμε assembly
- Εικονικές μηχανές για κάποιες γλώσσες (π.χ. Lisp, Forth, Smalltalk) γράφονται με χρήση της ίδιας τη γλώσσας
- Πολλοί διερμηνείς για VMs γράφονται σε GNU C, για λόγους που θα γίνουν προφανείς στις επόμενες διαφάνειες

Μορφές Διερμηνέων

- Αρκετές υλοποιήσεις γλωσσών προγραμματισμού χρησιμοποιούν διερμηνείς δύο ειδών:
  - Command-line interpreter
    - Διαβάζει και αναλύει συντακτικά κομμάτια πηγαίου κώδικα της γλώσσας τα οποία και εκτελεί
    - Χρησιμοποιείται σε συστήματα που αλληλεπιδρούν με το χρήστη
  - Virtual machine instruction interpreter
    - Διαβάζει και εκτελεί εντολές μιας ενδιάμεσης μορφής εκτελέσιμου κώδικα όπως bytecode εντολών μιας εικονικής μηχανής

Υλοποίηση των Διερμηνέων

Υπάρχουν πολλοί τρόποι υλοποίησης διερμηνέων:

1. Direct string interpretation

   Source level interpreters are very slow because they spend much of their time in doing lexical analysis

2. Compilation into a (typically abstract syntax) tree and interpretation of that tree

   Such interpreters avoid lexical analysis costs, but they still have to do much list scanning (e.g. when implementing a ‘goto’ or ‘call’)

3. Compilation into a virtual machine and interpretation of the VM code

Διερμηνείς Εντολών Εικονικών Μηχανών

- By compiling the program to the instruction set of a virtual machine and adding a table that maps names and labels to addresses in this program, some of the interpretation overhead can be reduced
- For convenience, most VM instruction sets use integral numbers of bytes to represent everything
  - opcodes, register numbers, stack slot numbers, indices into the function or constant table, etc.

Example: The GET_CONST2 instruction

Μέρη της Υλοποίησης μιας Εικονικής Μηχανής

- Το μέρος που αποθηκεύεται το πρόγραμμα (ο κώδικας)
  - Το πρόγραμμα είναι μια ακολουθία από εντολές
  - Φορτωτής (loader)
- Μέρη που καταγράφουν την κατάσταση (της εκτέλεσης)
  - Στοίβα (stack)
  - Σωρός (heap)
  - Καταχωρητές (registers)
    - Ένας ειδικός καταχωρητής, ο μετρητής προγράμματος (program counter), δείχνει πάντα στην επόμενη προς εκτέλεση εντολή
- Το σύστημα χρόνου εκτέλεσης (runtime system)
  - Σύστημα παραχώρησης μνήμης (memory allocator)
  - Συλλέκτης σκουπιδιών (garbage collector)

Η βασική δομή ενός Bytecode Interpreter

```
byte *pc = &byte_program[0];
while(TRUE) {
   opcode = pc[0];
   switch (opcode) {
     …
     case GET_CONST2:
        source_reg_num = pc[1];
        const_num_to_match = get_2_bytes(&pc[2]);
        … // get_const2 code
        pc += 4;
        break;
     …
     case JUMP:
        jump_addr = get_4_bytes(&pc[1]);
        pc = &byte_program[jump_addr];
        break;
     …
   }
}
```


To align or to not align VM instructions?

Σε μια 32-bit μηχανή

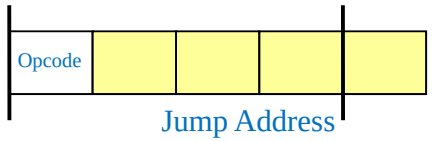

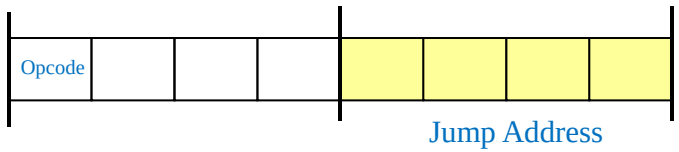

NOTE: Padding of instructions can be done by the loader.
The size of the bytecode files need not be affected.

Bytecode Interpreter with Aligned Instructions

```
byte *pc = &byte_program[0];
while(TRUE) {
   opcode = pc[0];
   switch (opcode) {
     …
     case GET_CONST2:
        source_reg_num = pc[1];
        const_num_to_match = get_2_bytes(&pc[2]);
        … // get_const2 code
        pc += 4;
        break;
     …
     case JUMP: // aligned version
        jump_addr = get_4_bytes(&pc[4]);
        pc = &byte_program[jump_addr];
        break;
     …
   }
}
```


Διερμηνέας με αφηρημένη κωδικοποίηση εντολών

```
byte *pc = &byte_program[0];
while(TRUE) {
   opcode = pc[0];
   switch (opcode) {
     …
     case GET_CONST2:
        source_reg_num = pc[GET_CONST2_ARG1];
        const_num_to_match = get_2_bytes(&pc[GET_CONST2_ARG2]);
        … // get_const2 code
        pc += GET_CONST2_SIZEOF;
        break;
     …
     case JUMP: // aligned version
        jump_addr = get_4_bytes(&pc[JUMP_ARG1]);
        pc = &byte_program[jump_addr];
        break;
     …
   }
}
```

```
#define GET_CONST2_SIZEOF 4
#define JUMP_SIZEOF 8
#define GET_CONST2_ARG1 1
#define GET_CONST2_ARG2 2
#define JUMP_ARG1 4
```


Διερμηνέας με αφηρημένο έλεγχο

```
byte *pc = &byte_program[0];
while(TRUE) {
next_instruction:
   opcode = pc[0];
   switch (opcode) {
     …
     case GET_CONST2:
        source_reg_num = pc[GET_CONST2_ARG1];
        const_num_to_match = get_2_bytes(&pc[GET_CONST2_ARG2]);
        … // get_const2 code
        pc += GET_CONST2_SIZEOF;
        NEXT_INSTRUCTION;
     …
     case JUMP: // aligned version
        jump_addr = get_4_bytes(&pc[JUMP_ARG1]);
        pc = &byte_program[jump_addr];
        NEXT_INSTRUCTION;
     …
   }
}
```

```
#define NEXT_INSTRUCTION \
    goto next_instruction
```


Έμμεσα Νηματικοί Διερμηνείς

- Σε έναν έμεσα νηματικό διερμηνέα (indirectly threaded interpreter) we do not switch on the opcode encoding; instead we use the bytecodes as indices into a table containing the addresses of the VM instructions
- The term *threaded code* refers to a code representation where every instruction is implicitly a function call to the next instruction
- A threaded interpreter can be very efficiently implemented in assembly
- In GNU CC, we can use the labels as values C language extension and take the address of a label with &&labelname
- We can actually write the interpreter in such a way that it uses indirectly threaded code if compiled with GNU CC and a switch for compatibility

Δομή ενός Έμμεσα Νηματικού Διερμηνέα

```
byte *pc = &byte_program[0];
while(TRUE) {
next_instruction:
   opcode = pc[0];
   switch (opcode) {
     …
     case GET_CONST2:
     get_const2_label:
        source_reg_num = pc[GET_CONST2_ARG1];
        const_num_to_match = get_2_bytes(&pc[GET_CONST2_ARG2]);
        … // get_const2 code
        pc += GET_CONST2_SIZEOF;
        NEXT_INSTRUCTION;
     …
     case JUMP: // aligned version
     jump_label:
        jump_addr = get_4_bytes(&pc[JUMP_ARG1]);
        pc = &byte_program[jump_addr];
        NEXT_INSTRUCTION;
     …
   }
}
```

```
static void *label_tab[] = {
   &&get_const2_label,
   &&jump_label,
}
#define NEXT_INSTRUCTION \
   goto *(void *)(label_tab[*pc])
```


Άμεσα Νηματικοί Διερμηνείς

- In a directly threaded interpreter, we do not use the bytecode instruction encoding at all during runtime
- Instead, the loader replaces each bytecode instruction encoding (opcode) with the address of the implementation of the instruction
- This means that we need one word for the opcode, which increases the VM code size

Δομή ενός Άμεσα Νηματικού Διερμηνέα

```
byte *pc = &byte_program[0];
while(TRUE) {
next_instruction:
   opcode = pc[0];
   switch (opcode) {
     …
     case GET_CONST2:
     get_const2_label:
        source_reg_num = pc[GET_CONST2_ARG1];
        const_num_to_match = get_2_bytes(&pc[GET_CONST2_ARG2]);
        … // get_const2 code
        pc += GET_CONST2_SIZEOF;
        NEXT_INSTRUCTION;
     …
     case JUMP: // aligned version
     jump_label:
        pc = get_4_bytes(&pc[JUMP_ARG1]);
        NEXT_INSTRUCTION;
     …
   }
}
```

```
static void *label_tab[] = {
   &&get_const2_label,
   &&jump_label,
}
#define NEXT_INSTRUCTION \
   goto **(void **)(pc)
```

```
#define GET_CONST2_SIZEOF 8
#define JUMP_SIZEOF 8
#define GET_CONST2_ARG1 5
#define GET_CONST2_ARG2 6
#define JUMP_ARG1 4
```


Νηματικός Διερμηνέας με Χρήση Prefetching

```
byte *pc = &byte_program[0];
while(TRUE) {
next_instruction:
   opcode = pc[0];
   switch (opcode) {
     …
     case GET_CONST2:
     get_const2_label:
        source_reg_num = pc[GET_CONST2_ARG1];
        const_num_to_match = get_2_bytes(&pc[GET_CONST2_ARG2]);
        pc += GET_CONST2_SIZEOF; // prefetching
        … // get_const2 code
        NEXT_INSTRUCTION;
     …
     case JUMP: // aligned version
     jump_label:
        pc = get_4_bytes(&pc[JUMP_ARG1]);
        NEXT_INSTRUCTION;
     …
   }
}
```

Subroutine Threaded Interpreter

- The only portable way to implement a threaded interpreter in C is to use subroutine threaded code
- Each VM instruction is implemented as a function and at the end of each instruction the next function is called

Stack-based vs. Register-based VMs

- A VM can either be *stack-based* or *register-based*
  - In a stack-based VM most operands are (passed) on the stack
    - The stack can grow as needed
  - In a register-based VM most operands are passed in (virtual) registers
    - These registers are often implemented using an array rather than physical machine registers
    - The number of registers is limited
- Most VMs are stack-based
  - Stack machines are simpler to implement
  - Stack machines are easier to compile to
  - Less encoding/decoding to find the right register
  - Unless virtual registers are mapped to physical registers, virtual registers are not faster than stack slots

Virtual Machine Interpreter Tuning

Common VM interpreter optimizations include:

- Writing the interpreter loop and key instructions in assembly
- Keeping important VM registers (pc, stack top, heap top) in hardware registers
  - GNU C allows global register variables
- Top of stack caching
- Splitting the most used set of instruction into a separate interpreter loop

Instruction Merging and Specialization

Instruction Merging: A sequence of VM instructions is replaced by a single (mega-)instruction

- Reduces interpretation overhead
- Code locality is enhanced
- Results in more compact bytecode
- C compiler has bigger basic blocks to perform optimizations on

Instruction Specialization: A special case of a VM instruction is created, typically one where some arguments have a known value which is hard-coded

- Eliminates the cost of argument decoding
- Results in more compact bytecode representation
- Reduces the register pressure from some basic blocks