

Vorlesung: Rechnerstrukturen, Teil 2 (Modul IP7)

J. Zhang

zhang@informatik.uni-hamburg.de

Universität Hamburg

Fachbereich Informatik


AB Technische Aspekte Multimodaler Systeme

Inhaltsverzeichnis

5. Assembler-Programmierung	103
Assembler und Disassembler105
Einfache Addressierungsmodi (Speicherreferenzen)117
Arithmetische Operationen121
Kontrollfluss124

Assembler-Programmierung

Assembler aus der Sicht des Programmierers:



Beobachtbare Zustände (Assemblersicht)

- EIP Programmzähler
 - ◆ Adresse der nächsten Anweisung

Beobachtbare Zustände (Assemblersicht)

- EIP Programmzähler
 - ◆ Adresse der nächsten Anweisung
- Register-Bank
 - ◆ Stark benutzte Programmdate

Beobachtbare Zustände (Assemblersicht)


- EIP Programmzähler
 - ◆ Adresse der nächsten Anweisung
- Register-Bank
 - ◆ Stark benutzte Programmdate
- Zustandscodes
 - ◆ Speichern Statusinformationen über die letzte arithmetische Operation
 - ◆ Werden für Conditional Branching benutzt

Beobachtbare Zustände (Assemblersicht)

- EIP Programmzähler
 - ◆ Adresse der nächsten Anweisung
- Register-Bank
 - ◆ Stark benutzte Programmdate
- Zustandscodes
 - ◆ Speichern Statusinformationen über die letzte arithmetische Operation
 - ◆ Werden für Conditional Branching benutzt
- Speicher
 - ◆ Durch Bytes adressierbarer Array
 - ◆ Code, Nutzerdaten, (einige) OS Daten
 - ◆ Beinhaltet Kellerspeicher zur Unterstützung von Abläufen

Assembler und Disassembler

Umwandlung von C in Objektcode:



Kompilieren in Assembler

C Code

```
int sum(int x, int y)
{
    int t = x+y;
    return t;
}
```

Generated Assembly

```
__sum:
    pushl %ebp
    movl %esp, %ebp
    movl 12(%ebp), %eax
    addl 8(%ebp), %eax
    movl %ebp, %esp
    popl %ebp
    ret
```

Obtain with command

```
gcc -O -S code.c
```

Produces file code.s

Assembler Charakteristika – I

Minimale Datentypen

- Ganzzahl- Daten mit 1,2 oder 4 Bytes
 - ◆ Datenwerte
 - ◆ Adressen
- Gleitkomma-Daten mit 4,8, oder 10 Bytes
- Keine Aggregatstypen wie Arrays oder Strukturen
 - ◆ Nur fortlaufend zugeteilte Bytes im Speicher

Assembler Charakteristika – II

Primitive Operationen

- Führen am Register oder den Speicherdaten arithmetische Funktionen durch
- Transferieren Daten zwischen dem Speicher und dem Register
 - ◆ Laden Daten aus dem Speicher ins Register
 - ◆ Legen Registerdaten im Speicher ab
- Transferieren Kontrolle
 - ◆ “Unconditional Jumps” zu/von Prozeduren
 - ◆ “Conditional Branches”

Objektcode

Code for sum

```
0x401040 <sum>:  
  0x55  
  0x89      • Total of 13  
  0xe5      bytes  
  0x8b  
  0x45      • Each  
  0x0c      instruction 1,  
  0x03      2, or 3 bytes  
  0x45  
  0x08      • Starts at  
  0x89      address  
  0xec      0x401040  
  0x5d  
  0xc3
```

Assembler und Binder

Assembler

- Übersetzt .s zu .o
- Binäre Kodierung jeder Anweisung
- Fast vollständiges Bild des ausführbaren Codes
- Fehlende Verknüpfungen zwischen Codes in verschiedenen Dateien

Assembler und Binder

Assembler

- Übersetzt .s zu .o
- Binäre Kodierung jeder Anweisung
- Fast vollständiges Bild des ausführbaren Codes
- Fehlende Verknüpfungen zwischen Codes in verschiedenen Dateien

Binder (Linker)

- Löst Referenzen zwischen Dateien auf
- Kombiniert mit statischen Laufzeit-Bibliotheken
 - ◆ Z.B. Code für malloc, printf
- Manche Bibliotheken sind *dynamisch verknüpft*
 - ◆ Die Verknüpfung tritt auf, wenn das Programm mit der Durchführung beginnt

Beispiel eines Maschinenbefehls

```
int t = x+y;
```

```
addl 8(%ebp), %eax
```

Similar to
expression
`x += y`

```
0x401046:    03 45 08
```

C Code: `int t = x+y;`

- Fügt zwei Ganzzahlen mit Vorzeichen hinzu

C Code: `int t = x+y;`

- Fügt zwei Ganzzahlen mit Vorzeichen hinzu

Assembler: `addl 8(%ebp), %eax`

- Fügt 2 4-Byte Ganzzahlen hinzu
 - ◆ “Lange” Wörter in GCC Sprache
 - ◆ Der gleiche Befehl, egal ob mit oder ohne Vorzeichen

- Operanden:

```
x:    Register    %eax
y:    Speicher M[%ebp+8]
t:    Register    %eax
Resultatwert in %eax
```

C Code: `int t = x+y;`

- Fügt zwei Ganzzahlen mit Vorzeichen hinzu

Assembler: `addl 8(%ebp), %eax`

- Fügt 2 4-Byte Ganzzahlen hinzu
 - ◆ “Lange” Wörter in GCC Sprache
 - ◆ Der gleiche Befehl, egal ob mit oder ohne Vorzeichen

- Operanden:

```
x:    Register    %eax
y:    Speicher M[%ebp+8]
t:    Register    %eax
Resultatwert in %eax
```

Objektcode: `0x401046: 03 45 08`

- 3-Byte Befehl, gespeichert unter der Adresse `0x401046`

Objektcode Disassembler

00401040 <_sum>:


```
0: 55          push   %ebp
1: 89 e5       mov    %esp,%ebp
3: 8b 45 0c    mov    0xc(%ebp),%eax
6: 03 45 08    add   0x8(%ebp),%eax
9: 89 ec       mov    %ebp,%esp
b: 5d         pop   %ebp
c: c3         ret
d: 8d 76 00    lea   0x0(%esi),%esi
```

objdump -d p

- Nützliches Werkzeug zur Untersuchung des Objektcodes
- Untersucht das Bit-Muster von Anweisungsserien und rekonstruiert Assemblerquelle weitgehend
- Kann entweder auf einer a.out (vollständiges, ausführbares Programm) oder einer .o Datei ausgeführt werden

Datentransfers ("move")

Beispiel:
movl



`movl` *Source, Dest*:

- Transferiert ein 4-Byte ("long") Wort
- Kommt in typischem Code häufig vor

`movl Source, Dest:`

- Transferiert ein 4-Byte ("long") Wort
- Kommt in typischem Code häufig vor

Typen von Operanden

- Immediate: Konstante, ganzzahliges Datum
 - ◆ Wie C Konstante, aber mit dem Präfix '\$'
 - ◆ Z.B., \$0x400, \$-533
 - ◆ Kodiert mit 1,2 oder 4 Bytes
- Register: Eins von 8 ganzzahligen Registern
 - ◆ Aber %esp und %ebp für speziellen Gebrauch reserviert
 - ◆ Andere haben spezielle Verwendungen für bestimmte Anweisungen
- Speicher: 4 konsekutive Speicherbytes
 - ◆ Zahlreiche "Adressmodi"

movl Operanden-Kombinationen

	Source	Destination		C Analogon
movl	<i>Imm</i>	<i>Reg</i>	<code>movl \$0x4, %eax</code>	<code>temp = 0x4;</code>
		<i>Mem</i>	<code>movl \$-147, (%eax)</code>	<code>*p = 147</code>
	<i>Reg</i>	<i>Reg</i>	<code>movl %eax, %edx</code>	<code>temp2 = temp1;</code>
		<i>Mem</i>	<code>movl %eax, (%edx)</code>	<code>*p = temp;</code>
	<i>Mem</i>	<i>Reg</i>	<code>movl (%eax), %edx</code>	<code>temp = *p;</code>

Einfache Addressierungsmodi (Speicherreferenzen)

Normal (R) Mem [Reg [R]]

- Register R spezifiziert die Speicheradresse

```
movl (%ecx),        %eax
```

Einfache Addressierungsmodi (Speicherreferenzen)

Normal (R) Mem[Reg[R]]

- Register R spezifiziert die Speicheradresse

```
movl (%ecx), %eax
```

Displacement D(R) Mem[Reg[R+D]]

- Register R
- Konstantes "Displacement" D spezifiziert den "offset"

```
movl 8(%ebp), %edx
```

Benutzen einfacher Adressierungsmodi

```
void swap(int *xp, int *yp)
{
    int t0 = *xp;
    int t1 = *yp;
    *xp = t1;
    *yp = t0;
}
```

swap:

```
pushl   %ebp
movl    %esp,    %ebp
pushl   %ebx
movl    12(%ebp), %ecx
movl    8(%ebp), %edx
movl    (%ecx),  %eax
movl    (%edx),  %ebx
movl    %eax,    (%edx)
movl    %ebx,    (%ecx)

movl    -4(%ebp), %ebx
movl    %ebp,    %esp
popl    %ebp
ret
```

Indizierte Adressierungsmodi

Gebäuchlichste Form

$\text{Imm}(Rb, Ri, S) \quad \text{Mem}[\text{Reg}[Rb] + S * \text{Reg}[Ri] + \text{Imm}]$

- *Imm* : Offset
- *Rb* : Basisregister: Eins von 8 ganzzahligen Registern
- *Ri* : Indexregister: jedes außer %esp
 - ◆ Unwarscheinlich auch, dass %ebp benutzt wird
- *S* : “Scaling” Faktor, 1,2,4 oder 8

Indizierte Adressierungsmodi

Gebäuchlichste Form

$\text{Imm}(Rb, Ri, S) \quad \text{Mem}[\text{Reg}[Rb] + S * \text{Reg}[Ri] + \text{Imm}]$

- Imm : Offset
- Rb : Basisregister: Eins von 8 ganzzahligen Registern
- Ri : Indexregister: jedes außer %esp
 - ◆ Unwarscheinlich auch, dass %ebp benutzt wird
- S : "Scaling" Faktor, 1,2,4 oder 8

Spezielle Fälle

(Rb, Ri)	$\text{Mem}[\text{Reg}[Rb] + \text{Reg}[Ri]]$
$\text{Imm}(Rb, Ri)$	$\text{Mem}[\text{Reg}[Rb] + \text{Reg}[Ri] + \text{Imm}]$
(Rb, Ri, S)	$\text{Mem}[\text{Reg}[Rb] + S * \text{Reg}[Ri]]$

Beispiel für Adressenberechnung

<code>%edx</code>	<code>0xf000</code>
<code>%ecx</code>	<code>0x100</code>

Expression	Computation	Address
<code>0x8(%edx)</code>	<code>0xf000 + 0x8</code>	<code>0xf008</code>
<code>(%edx,%ecx)</code>	<code>0xf000 + 0x100</code>	<code>0xf100</code>
<code>(%edx,%ecx,4)</code>	<code>0xf000 + 4*0x100</code>	<code>0xf400</code>
<code>0x80(,%edx,2)</code>	<code>2*0xf000 + 0x80</code>	<code>0x1e080</code>

Arithmetische Operationen

Two Operand Instructions

Format	Operation	
addl Src, Dest	Dest = Dest + Src	
subl Src, Dest	Dest = Dest - Src	
imull Src, Dest	Dest = Dest * Src	
sall Src, Dest	Dest = Dest << Src	Also called shll
sarl Src, Dest	Dest = Dest >> Src	Arithmetic
shrl Src, Dest	Dest = Dest >> Src	Logical
xorl Src, Dest	Dest = Dest ^ Src	
andl Src, Dest	Dest = Dest & Src	
orl Src, Dest	Dest = Dest Src	

Einige Arithmetische Operationen

One Operand Instructions

Format	Operation
<code>incl Dest</code>	<code>Dest = Dest + 1</code>
<code>decl Dest</code>	<code>Dest = Dest - 1</code>
<code>negl Dest</code>	<code>Dest = - Dest</code>
<code>notl Dest</code>	<code>Dest = ~ Dest</code>

Ein Beispiel

```
int logical(int x, int y)
{
    int t1 = x^y;
    int t2 = t1 >> 17;
    int mask = (1<<13) - 7;
    int rval = t2 & mask;
    return rval;
}
```

$2^{13} = 8192, 2^{13} - 7 = 8185$

<code>movl 8(%ebp),%eax</code>	<code>eax = x</code>	
<code>xorl 12(%ebp),%eax</code>	<code>eax = x^y</code>	(t1)
<code>sarl \$17,%eax</code>	<code>eax = t1>>17</code>	(t2)
<code>andl \$8185,%eax</code>	<code>eax = t2 & 8185</code>	

Kontrollfluss

Themen

- Zustandscodes
 - ◆ Setzen
 - ◆ Testen

Kontrollfluss

Themen

- Zustandscodes
 - ◆ Setzen
 - ◆ Testen

- Ablaufsteuerung
 - ◆ “If-then-else” (Verzweigungen)
 - ◆ “Loop” -Variationen
 - ◆ “Switch Statements”

Zustandscodes

Einzel- Bit Register

CF Carry Flag SF Sign Flag
ZF Zero Flag OF Overflow Flag

Implizit gesetzt durch Arithmetische Operationen, z.B. `addl Src, Dest`
C analog: `t = a + b`

- CF setzen, wenn höchstwertigstes Bit Übertrag generiert
- Benutzt um Überlauf ohne Vorzeichen zu entdecken
- ZF setzen wenn $t == 0$
- SF setzen wenn $t < 0$
- OF setzen wenn das Zweierkomplement überläuft

$(a > 0 \ \&\& \ b > 0 \ \&\& \ t < 0) \ || \ (a < 0 \ \&\& \ b < 0 \ \&\& \ t \geq 0)$

Zustandscodes setzen (Forts.)

Explizit Setzen bei Vergleichsanweisung `cmpl Src2, Src1`

- `cmpl b, a` wie Berechnung von $a - b$ ohne Abspeichern des Resultats
- CF setzen, falls höchstwertigstes Bit Übertrag generiert
 - ◆ Für Vergleiche ohne Vorzeichen benutzt
- ZF setzen wenn $a = b$
- SF setzen wenn $(a - b) < 0$
- OF setzen wenn das Komplement von zwei überläuft

$(a > 0 \& \& b > 0 \& \& (a - b) < 0) \vee (a < 0 \& \& b > 0 \& \& (a - b) > 0)$

Zustandscodes setzen (Forts.)

Explizit Setzen bei Testanweisung `testl Src2, Src1`

- Setzt Zustandscodes basierend auf dem Wert von Src1 & Src2
 - ◆ Hilfreich, wenn einer der Operanden eine Bitmaske ist
 - ◆ `testl b, a` wie Berechnung von `a&b` ohne Einstellungs-Ziel
 - ◆ ZF setzen wenn $a \& b = 0$
 - ◆ Sf setzen wenn $a \& b < 0$

Zustandscodes Lesen

SetX Anweisungen

- Setzt einzelnes Byte (Ein-Byte Registerelemente) basierend auf Kombinationen von Zustandscodes

SetX	Zustand	Beschreibung
sete	ZF	Gleich/Null
setne	~ZF	Nicht gleich / Nicht Null
sets	SF	Negativ
setns	~SF	Nicht-Negativ
setg	~(SF^OF) & ~ZF	Größer (mit Vorzeichen)
setge	~(SF^OF	Größer oder Gleich (mit Vorzeichen)
setl	(SF^OF)	Kleiner (mit Vorzeichen)
setle	(S\^OF) ZF	Kleiner oder Gleich (mit Vorzeichen)
seta	~CF&~ZF	Darüber (ohne Vorzeichen)
setb	CF	Darunter (ohne Vorzeichen)

Zustandscodes Lesen (Forts.)

SetX Anweisungen

- Setzt einzelnes Byte basierend auf Kombinationen von Zustandscodes
- Ein adressierbares Byte aus 8 wird erfasst
 - ◆ Eingebettet in die ersten 4 ganzzahligen Register
 - ◆ Verändert die 3 übrigen Bytes nicht
 - ◆ Gebraucht typischerweise movzbl um die Aufgabe zu vollenden

```
int gt (int x, int y)
{
    return x > y;
}
```

Body

```
movl 12(%ebp), %eax    # eax = y
cmpl %eax, 8(%ebp)    # Compare x : y
setg %al               # al = x > y
movzbl %al, %eax      # Zero rest of %eax
```

%eax	%ah	%al
%edx	%dh	%dl
%ecx	%ch	%cl
%ebx	%bh	%bl
%esi		
%edi		
%esp		
%ebp		

Sprungbefehle (“Jump”)

JX Anweisungen: “Jumping” zu verschiedenen Teilen des Codes abhängig von Zustandscodes

jX	Condition	Description
jmp	1	Unconditional
je	ZF	Equal / Zero
jne	$\sim ZF$	Not Equal / Not Zero
js	SF	Negative
jns	$\sim SF$	Nonnegative
jg	$\sim (SF \wedge OF) \ \& \ \sim ZF$	Greater (Signed)
jge	$\sim (SF \wedge OF)$	Greater or Equal (Signed)
jl	$(SF \wedge OF)$	Less (Signed)
jle	$(SF \wedge OF) \ \ ZF$	Less or Equal (Signed)
ja	$\sim CF \ \& \ \sim ZF$	Above (unsigned)
jb	CF	Below (unsigned)

“Conditional Branch” Beispiel

```
int max(int x, int y)
{
    if (x > y)
        return x;
    else
        return y;
}
```

```
    _max:
        pushl %ebp
        movl %esp,%ebp
        movl 8(%ebp),%edx
        movl 12(%ebp),%eax
        cmpl %eax,%edx
        jle L9
        movl %edx,%eax
    L9:
        movl %ebp,%esp
        popl %ebp
        ret
```

} Set Up

} Body

} Finish

“Conditional Branch” Beispiel (Forts.)

```
int goto_max(int x, int y)
{
    int rval = y;
    int ok = (x <= y);
    if (ok)
        goto done;
    rval = x;
done:
    return rval;
}
```

```
    movl 8(%ebp), %edx # edx = x
    movl 12(%ebp), %eax # eax = y
    cmpl %eax, %edx   # x : y
    jle L9            # if <= goto L9
    movl %edx, %eax   # eax = x } Skipped when
L9:                  # Done:
```

- C erlaubt “goto” als Mittel der Kontrollübertragung
 - ◆ Näher an Maschinen-Level Programmierungsstil
- Allgemein als schlechter Kodierungsstil angesehen

“Do-While” Loop Beispiel

Goto Version

```
int fact_goto
(int x)
{
    int result = 1;
loop:
    result *= x;
    x = x-1;
    if (x > 1)
        goto loop;
    return result;
}
```

Assembly

```
_fact_goto:
    pushl %ebp        # Setup
    movl %esp,%ebp   # !
    movl $1,%eax     # eax = 1
    movl 8(%ebp),%edx # e
    x
    imull %edx,%eax  # !
    decl %edx        # x--
    cmpl $1,%edx    # Compare
    jg L11           # if > goto loop
L11:
    movl %ebp,%esp   # !
    popl %ebp       # Finish
    ret             # Finish
```

- Benutzt “Backward branch” um “Looping” fortzusetzen
- Nimmt “Branch” nur wenn “while” Bedingung besteht

Allgemeine “Do-While” Übersetzung

CCode

```
int fact_do
(int x)
{
  int result = 1;
  do {
    result *= x;
    x = x-1;
  } while (x > 1);
  return result;
}
```

Goto Version

```
int fact_goto(int x)
{
  int result = 1;
loop:
  result *= x;
  x = x-1;
  if (x > 1)
    goto loop;
  return result;
}
```

- “Body” kann beliebige Folge von C “Statements” sein
- ◆ Test ist zurückkommende Ganzzahl
= 0 als falsch interpretiert $\neq 0$ als wahr interpretiert

“Switch Statements”

```
typedef enum
{ADD, MULT, MINUS, DIV, MOD, BAD}
  op_type;

char unparse_symbol(op_type op)
{
  switch (op) {
  case ADD :
    return '+';
  case MULT:
    return '*';
  case MINUS:
    return '-';
  case DIV:
    return '/';
  case MOD:
    return '%';
  case BAD:
    return '?';
  }
}
```

Implementierungsoptionen

- Serie von “Conditionals”
 - ◆ Gut falls wenige Fälle
 - ◆ Langsam bei vielen Alternativen
- “Jump Table”
 - ◆ “Lookup Branch Target”
 - ◆ Vermeidet “Conditionals”
 - ◆ Möglich falls Alternativen kleine ganzzahlige Konstanten sind
- GCC
 - ◆ Wählt eine der beiden Varianten basierend auf der Fallstruktur
- Bug im Beispielcode
 - ◆ keine Vorgabe gegeben

“Jump Table” Struktur

Switch Form


```
switch(op) {  
  case val_0:  
    Block 0  
  case val_1:  
    Block 1  
    . . .  
  case val_n-1:  
    Block n-1  
}
```

Jump Table

jtab:

Targ0
Targ1
Targ2
•
•
•
Targn-1

Jump Targets



Approx. Translation

```
target = JTab[op];  
goto *target;
```

“Switch Statement” Beispiel

Branching Possibilities

```
typedef enum
{ADD, MULT, MINUS, DIV, MOD, BAD}
  op_type;

char unparse_symbol(op_type op)
{
  switch (op) {
    . . .
  }
}
```

Enumerated Values

ADD	0
MULT	1
MINUS	2
DIV	3
MOD	4
BAD	5

Setup:

unparse_symbol:

```
pushl %ebp      # Setup
movl %esp,%ebp  # Setup
movl 8(%ebp),%eax # eax = op
cmpl $5,%eax   # Compare op : 5
ja .L49        # If > goto done
jmp *.L57(,%eax,4) # goto Table
```

[op]

Assembler-Setup Erklärung

Symbolische Labels

- Labels der Form `.LXX` werden von Assembler in Adressen übersetzt

“Table” Struktur

- Jedes Ziel erfordert 4 Bytes
- Basisadresse bei `.L57`

“Switch Statement” (Abschluss)

Jumping

```
jmp .L49
```

- “Jump Target” wird mit Label .L49 gekennzeichnet

```
jmp * :L57(,%eax, 4)
```
- Start des “Jump Table” wird mit Label .L57 gekennzeichnet
- Register %eax hält op
- Muss mit dem Faktor 4 skaliert werden um “offset” ins “Table” zu bekommen
- Holt “Target” von der effektiven Adresse $.L57 + op * 4$

Vorteil des “Jump Table”

- Kann k-way branch in $O(1)$ Operationen durchführen

“Jump Table” aus “Binary” Extrahieren

“Jump Table” in “Read Only” Datensegment gespeichert (.rodata)

- Zahlreiche feste Werte von Ihrem Code benötigt

Kann mit `objdump` untersucht werden:

```
objdump code-examples -s --section=.rodata
```

- Zeigt alles im angegebenen Segment.

Schwer zu lesen

- “Jump Table” Einträge mit umgekehrter Byte-Anordnung gezeigt

Zusammenfassung

C Kontrollstrukturen

- “If-then-else”
- “do-while”
- “while”
- “switch”

Assembler Kontrolle

- “Jump”
- “Conditional Jump”

Compiler

- Muss Assembler Code generieren, um komplexere Kontrolle zu implementieren

Standard Techniken

- Alle loops konvertiert zu “do-while” Form
- Große “Switch Statements” verwenden “Jump Tables”

CISC Bedingungen

- CISC Maschinen haben im Allgemeinen Zustandscode-Register

RISC Bedingungen

- Benutzen Universalregister um Zustandsinformationen zu speichern
- Spezielle Vergleichs-Anweisungen
- Z.B. auf Alpha
cmple \$16, 1, \$1
 - ◆ Stellt Register \$1 auf 1 wenn Register \$16 \leq 1

Ergänzende Literatur

Zur Rechnerarchitektur (3. Termin):

Literatur

- [1] Randal E. Bryant and David O'Hallaron. *Computer Systems*. Pearson Education, Inc., New Jersey, 2003.
- [2] David A. Patterson and John L. Hennessy. *Computer Organization and Design. The Hardware / Software Interface*. Morgan Kaufmann Publishers, Inc., San Francisco, 1998.
- [3] Andrew S. Tanenbaum. *Computerarchitektur*. Pearson Studium München, 2006.