

## Übungsblatt 10

Gesundes neues Jahr – wünscht das Übersetzerbau-Team ☺

### Wichtig: Abgabe des vierten Meilensteins

Bitte denken Sie daran, Ihre Implementierung des vierten Meilensteins bis spätestens **14.01.** fertigzustellen und die entsprechend markierte Revision auf den git-Server des Lehrstuhls zu pushen.

### Dokumentation zur x86-64-Architektur

Auf der Internetseite zur Übung finden Sie einen Verweis auf die Dokumentation zur x86-64-Architektur.

### Aufgabe 10.1: x86-64: Fibonacci (iterativ), Assembler `as`, Binder `ld`, `objdump`

In dieser Aufgabe implementieren Sie ein erstes einfaches Programm in x86-64-Assembler und bringen dieses zur Ausführung auf einem Linux-System.

- Auf der Internetseite zur Übung finden Sie ein Grundgerüst für das Programm, das aus zwei Dateien `fib.s` und `exit.s` besteht. Erweitern Sie das Programm so, dass es die  $n$ -te Fibonacci-Zahl *iterativ* berechnet.
- Assemblieren Sie die beiden Module jeweils mittels `as`.
- Binden Sie die erzeugten Objektmodule mittels `ld` zu einem ausführbaren Programm.
- Führen Sie das Programm aus. Das Ergebnis der Berechnung wird als *Exit-Code* an das Betriebssystem zurückgegeben. Sie können sich diesen am Anschluss an die Ausführung mittels „echo \$?“ in der Kommandozeile ausgeben lassen. Überprüfen Sie das Ergebnis.
- Verwenden Sie das Werkzeug `objdump`, um das Programm vor und nach dem Binden zu disassemblieren. Worin unterscheiden sich die Programme?

### Aufgabe 10.2: Debugger `gdb`

Im Rahmen dieser Aufgabe machen Sie sich mit dem Debugger `gdb` vertraut. Laden Sie sich dazu zunächst das Assembler-Programm `fib_fail.s` von der Internetseite zur Übung herunter und versuchen Sie, das Programm zu verstehen. Erzeugen Sie anschließend mittels `as` und `ld` ein ausführbares Programm.

- Die Funktion `fib` liefert falsche Werte zurück. Wie können Sie dies feststellen, ohne das Programm zu verändern (d.h. insbesondere ohne Ausgabeanweisungen hinzuzufügen)?
- Verwenden Sie `gdb`, um die fehlerhaften Stellen zu identifizieren. Setzen Sie dazu *Breakpoints* an „interessanten“ Stellen, um die Ausführung des Programms an diesen zu unterbrechen und um sich die zu diesem Zeitpunkt berechneten Zwischenergebnisse ansehen zu können.
- Beheben Sie die identifizierten Fehler und übersetzen Sie das Programm erneut. Testen Sie ihre verbesserte Version erneut mittels `gdb`.

### Hinweise zur Verwendung von `gdb`:

- Debugger starten:
  - `gdb <Programm>`: startet den Debugger für das angegebene `<Programm>`
  - `run`: führt das Programm bis zum ersten *Breakpoint* (s.u.) aus
  - `file`: lädt das Programm (bspw. nach einer erneuten Übersetzung) neu, behält *Breakpoints*

- Disassemblieren:
  - disassemble: zeigt die nachfolgenden Assembler-Instruktionen ab der aktuellen Instruktion
  - disassemble <Funktion>: zeigt die Assembler-Instruktionen der angegebenen <Funktion>
- *Breakpoints* setzen:
  - break <Funktion>: setzt einen *Breakpoint* am Beginn der angegebenen <Funktion>
  - break \*<Adresse>: setzt einen *Breakpoint* an der <Adresse> (siehe Ausgabe von disassemble)
- *Breakpoints* verwalten:
  - info breakpoints: zeigt die gesetzten *Breakpoints* an
  - delete <Nummer>: entfernt den *Breakpoint* mit der angegebenen <Nummer> wieder
- Steuerung der Programmausführung nach Erreichen eines *Breakpoints*:
  - continue: führt das Programm bis zum nächsten *Breakpoint* aus
  - quit: beendet die Programmausführung
  - si: führt die nächste Instruktion aus und pausiert die Ausführung nach dieser erneut; steigt bei einer call-Instruktion in die aufgerufene Funktion ab
  - ni: wie si, aber steigt *nicht* in aufgerufene Funktionen ab
- Register/Speicher lesen und schreiben:
  - mittels info:
    - \* info registers <Reg>: zeigt den Inhalt des Registers <Reg> (z.B. \$rax) an
    - \* info registers: zeigt den Inhalt aller Register an
  - mittels print:
    - \* print <Ziel>: gibt Wert an der Stelle <Ziel> (Register oder Adresse) aus
    - \* print <Ziel> = <Wert>: setzt Wert an der Stelle <Ziel> auf den angegebenen <Wert>
    - \* Beispiele:
      - print \$rax = 0x1303: setzt den Wert von Register \$rax auf 0x1303
      - print \*(long long \*)(\$rsp+4\*8): gibt das fünfte Wort (Offset 4 mal Wortlänge 8) auf dem Stack aus (beachten Sie die C-Syntax!)
  - mittels x (nur für Speicher, vermeidet Typkonvertierung von print):
    - \* x/<Format> <Ziel>: gibt den oder die Werte an der Stelle <Ziel> im angegebenen <Format> aus; <Format> besteht dabei aus der *Anzahl* der auszugebenden Werte, dem *Format*, in dem diese ausgegeben werden sollen, sowie der *Größe* eines einzelnen Werts (Tipp: help x, siehe unten)
    - \* Beispiele:
      - x/3i 0x1234: gibt die nächsten drei Instruktionen (i) ab Adresse 0x1234 aus
      - x/g \$rsp+(4\*8): gibt das fünfte Wort auf dem Stack aus (g: *giant*, 8 Bytes)
- Sonstiges:
  - backtrace: zeigt einen *Stacktrace* der aufgerufenen Funktionen (setzt *Framepointer* voraus)
  - watch <Reg>: pausiert die Ausführung, wenn sich der Wert in dem angegebenen Register ändert
  - display/<Format> <Ziel>: gibt den Wert eines Registers bzw. einer Speicherstelle bei *jeder* Pausierung der Programmausführung aus (<Format> und <Ziel> wie bei x, siehe oben)
    - \* Beispiel: display/i \$pc: zeigt die aktuelle Instruktion bei Erreichen eines *Breakpoints* (\$pc: *Program Counter*, Adresse des aktuellen Befehls)
  - help <Kommando>: zeigt eine kurze Hilfe zu dem angegebenen <Kommando>

### Aufgabe 10.3: x86-64/Linux: Systemaufrufe

Schreiben Sie eine Assembler-Routine, die unter x86-64/Linux ein Zeichen auf der Standardausgabe ausgibt.

#### Tipps:

- „man 2 intro“ und „man 2 syscall“ liefern allgemeine Informationen zu Systemaufrufen unter Linux.
- „man 2 write“ beinhaltet Informationen zum write-Systemaufruf.
- Die im Linux-Header `sys/syscall.h` inkludierten Header-Dateien beinhalten symbolische Konstanten für die Nummern der Systemaufrufe. Der Dateipfad kann mittels „locate `sys/syscall.h`“ bestimmt werden.

### Aufgabe 10.4: x86-64: Aufrufkonventionen

Implementieren Sie ein x86-64-Programm, das mit Hilfe einer *rekursiven* Routine den Binomialkoeffizienten  $\binom{n}{k}$  zweier beliebiger natürlicher Zahlen  $n, k, n \geq k$ , berechnet und als *Exit-Code* zurückgibt:

$$\binom{n}{k} = \binom{n-1}{k-1} + \binom{n-1}{k}, \quad \binom{n}{\emptyset} = \binom{n}{n} = 1$$

Überlegen Sie sich dabei eine geeignete *Aufrufkonvention* (*Calling Convention*).

### Projektübung 6 (Abgabe bis 21.01.2018)

Im Rahmen dieser Projektübung implementieren Sie die *Speicherplatzvergabe* in Ihrem e2-Übersetzer. Dabei werden die Variablen und virtuellen Register des IR-Programms mit der Information über den jeweiligen Speicherplatz attribuiert. Diese Information wird später bei der Code-Generierung benötigt.

**Hinweis:** Ab dieser Aufgabe muss Ihr Übersetzer *keine* Unterstützung für Fließkommawerte und -operationen mehr haben. Sie *dürfen* dies jedoch selbstverständlich implementieren ☺

- a) Da auch für Parameter Speicherplätze vergeben werden müssen, müssen Sie sich eine geeignete Aufrufkonvention überlegen, die Ihr Übersetzer verwenden soll. Sie *können* sich an dem *System V ABI* für x86-64/Linux<sup>1</sup> orientieren, aber Sie dürfen sich auch eine „eigene“ Aufrufkonvention überlegen.

**Tipp:** Die Speicherplatzvergabe und insbesondere die Code-Generierung (nächste Projektübung) werden an einigen Stellen einfacher (und weniger „fehleranfällig“), wenn alle Argumente über den Stack übergeben werden. Dies führt jedoch i.A. auch zu einer geringeren Effizienz...

- b) Machen Sie sich mit den vorgegebenen Klassen in dem Paket `e2c.backend.memory` zur Repräsentation von Speicherstellen (mit der gemeinsamen Oberklasse `MemoryLocation`) vertraut:
- Globale Variablen liegen an statischen Adressen, die im Assembler-Code über symbolische Namen adressiert werden können. Diese werden durch Instanzen der Klasse `StaticLocation` repräsentiert.
  - Eine Instanz der Klasse `HardwareRegister` repräsentiert ein physikalisches Register (z.B. `%rax`).
  - Werte auf dem Stack sollen mit Hilfe eines Offsets relativ zum *Framepointer* adressiert werden. Ein solcher Speicherplatz soll durch eine Instanz der Klasse `StackFrameLocation` repräsentiert werden.
- c) Die Vorlage stellt außerdem das Interface `e2c.backend.memory.assignment.MemoryLocationAssigner` zur Verfügung. Klassen, die dieses Interface implementieren, stellen mit `assignMemoryLocations()` eine Methode zur Vergabe von Speicherplätzen bereit, und zwar *unabhängig* von der Zielarchitektur (damit kann derselbe Algorithmus zur Speicherplatzvergabe für unterschiedliche Backends verwendet werden). Zu diesem Zweck bekommt die Methode eine Instanz der Klasse `TargetInfo` übergeben, die u.a. die auf der tatsächlichen Zielarchitektur verfügbaren Register beschreibt.

Sie haben im Rahmen dieser Projektübung zwei Möglichkeiten:

<sup>1</sup>siehe bspw. <https://software.intel.com/sites/default/files/article/402129/mpx-linux64-abi.pdf>

- Ihre Speicherplatzvergabe implementiert das Interface `MemoryLocationAssigner`. In diesem Fall müssen Sie auch eine Unterklasse von `TargetInfo` für die x86-64-Architektur und die von Ihnen gewählte Aufrufkonvention implementieren (bspw. in `e2c.backend.codegen.x64.TargetInfoX64`).
  - Sie ignorieren die Interfaces `MemoryLocationAssigner` und `TargetInfo` und implementieren die Speicherplatzvergabe fest für die x86-64-Architektur.
- d) Implementieren Sie die eigentliche Speicherplatzvergabe. Dabei muss jeder `IRVariable` des Programms genau ein Speicherplatz zugewiesen werden (Methode `setMemoryLocation()`). Des Weiteren sollten Sie sich für die spätere Code-Generierung für jede Funktion des Eingabeprogramms merken, wie groß der jeweilige Kellerrahmen ist (d.h. wie viel Platz zu Beginn der Funktion auf dem Stack reserviert werden muss, Methode `setStackSize()`). Die Klasse `IRFunction` erlaubt außerdem die Speicherung der innerhalb der jeweiligen Funktion verwendeten Caller-Save- und Callee-Save-Register. Dies ist u.U. bei der späteren Code-Generierung hilfreich, um die „richtigen“ Register zu sichern bzw. zu restaurieren.

Es ist Ihnen überlassen, wie „gut“ Sie die Speicherplatzvergabe implementieren; je nach Implementierung unterscheiden sich die Effizienz und der Speicherverbrauch des am Ende generierten Programms stark...

**Tipp 1:** Die naive (und im Rahmen der Projektübungen völlig ausreichende) Lösung platziert alle lokalen Variablen und virtuellen Register auf dem Stack (es werden also keine Register verwendet; dies macht insbesondere auch die spätere Code-Generierung einfacher und weniger „fehleranfällig“). Dabei erhält jede Variable und jedes virtuelle Register einen *eigenen Speicherplatz*<sup>2</sup> im Kellerrahmen. Die Implementierung der gesamten Projektübung sollte in diesem Fall in **ca. 100 Zeilen Java-Code** machbar sein... ☺

**Tipp 2:** Sollten Sie eine „bessere“ Speicherplatzvergabe implementieren, die Gebrauch von physikalischen Registern macht, sollten Sie mindestens zwei Register „freilassen“ (sog. *Scratch Register*). Diese können Sie später bei der Code-Generierung für die Speicherung von Zwischenergebnissen o.ä. verwenden, ohne diese sichern und restaurieren zu müssen.

**Hinweis:** Es gibt *keine* Testfälle zu dieser Aufgabe. Es kann durchaus sein, dass Sie bei der Implementierung der Code-Generierung in der nächsten Projektübung feststellen, dass Ihre Speicherplatzvergabe fehlerhaft ist...

**Tipp:** Testen Sie Ihre Implementierung selbst, indem Sie diese für einige Testprogramme geeignet aufrufen und sich den zugewiesenen Speicherplatz für jede Variable des Eingabeprogramms ausgeben lassen.

---

<sup>2</sup>Achtung: Die Kellerrahmen werden dabei je nach Funktion u.U. *sehr* groß.