Informatik I

14. Fingerübung: Ein Interpreter für Brainf*ck

Bernhard Nebel

Albert-Ludwigs-Universität Freiburg

29. November 2013

Informatik I

29. November 2013 — 14. Fingerübung: Ein Interpreter für Brainf*ck

14.1 Motivation

Brainf*ck: Eine minimale Sprache

- Jeder *Informatiker* sollte mindestens 2 Programmiersprachen beherrschen!
- Wir wollen heute eine minimale Programmiersprache kennen lernen, ...
- ... uns freuen, dass wir bisher eine sehr viel komfortablere Sprache kennen lernen durften,
- ... dazu einen Interpreter bauen,
- ... der Daten-getriebene Programmierung einsetzt.
- Außerdem sehen wir I/O, Exceptions im Einsatz.
- Heute: Keine *rekursiven* Datentypen oder Funktionen!

Entstehungsgeschichte

- Urban Müller hat die Sprache 1993 beschrieben, die 8 verschiedene Befehle kennt, und einen Compiler mit weniger als 200 Byte dafür geschrieben
- Die Sprache wird gerne für „Fingerübungen“ im Kontext Interpreter/Compiler benutzt.
- Obwohl minimal, ist die Sprache doch mächtig genug, alle berechenbaren Funktionen zu implementieren: Sie ist Turing-vollständig.

14.2 Programmiersprache

Programmiersprache und Berechnungsmodell

- Programme bestehen aus einer Abfolge von ASCII-Zeichen (Unicode-Wert 0 bis 127).
- Bedeutungstragend sind aber nur die acht Zeichen:

  `< > + - . , [ ]`

  Alles andere ist Kommentar.
- Das Programm wird Zeichen für Zeichen abgearbeitet, bis das Ende des Programms erreicht wird.
- Es gibt einen ASCII-Eingabestrom und einen ASCII-Ausgabestrom (normalweise die Konsole)
- Die Daten werden in einer Liste gehalten: ar. Wir reden hier von Zellen.
- Es gibt einen Datenzeiger, der initial 0 ist: `ptr`.

Die Befehle

Die aktuelle Zelle ist das Listenelement, auf die der Datenzeiger zeigt: `ar[ptr]`.

- `>` Bewege den Datenzeiger nach rechts `ptr += 1`.
- `<` Bewege den Datenzeiger nach links `ptr -= 1`.
- `+` Erhöhe den Wert in der aktuellen Zelle: `ar[ptr] += 1`.
- `-` Erniedrige den Wert in der aktuellen Zelle: `ar[ptr] -= 1`.
- `.` Gebe ein ASCII-Zeichen ensprechend dem Wert in der aktuellen Zelle aus: `print(chr(ar[ptr]), end='')`.
- `,` Lese ein ASCII-Zeichen und lege den Wert in der aktuellen Zelle ab: `ar[ptr] = ord(f.read(1))`.

Ein Beispiel

Ein Programm ohne Verzweigungen und Schleifen, das einen Großbuchstaben in den entsprechenden Kleinbuchstaben übersetzt.

konvert1.bf

```
Lese ein Zeichen (Annahme: Grossbuchstabe)
,
Konvertiere in Kleinbuchstabe
++++++++++++++++++++++++++++++++
Gebe das Zeichen aus
.
Und hier ist das Programm zu Ende
```

Probiere aus auf: `http://pccprogram.twbbs.org/download/2013/6/Brainfuck-Visualizer-Release.html`

Schleifen

- Aus „normalen“ Programmiersprachen kennen wir die `while`-Schleife.
- Diese Rolle spielt in Brainf*ck das Paar `[ ]`:

  `[` Falls die aktuelle Zelle = 0 ist (`ar[ptr] == 0`), dann springe zum Befehl nach der zugehörigen schließenden Klammer (beachte Klammerungsregeln). Ansonsten setzte die Ausführung mit dem Befehl nach `[` fort.

  `]` Springe zur zugehörigen öffnenden Klammer.

14.3 Beispiele

Beispiel mit Schleife

loop.bf

```
    ++++++        set cell #0 to 6
    [ > ++++++++  add 8 to cell #1
      < -         decrement loop counter cell #0
    ]
    > +           add another 1 to cell #1
    .             print ASCII 49 = '1'

    -             now cell #1 is '0'
    < ++++++++    set cell #0 to 8
    [ > .         print ASCII 48 = '0'
      < -         decrement loop counter (cell #0)
    ]
Ausgabe: 100000000
```

Hello World (1)

hello_world.bf - Part 1

```
+++++ +++++ initialize counter (cell #0) to 10
[                       use loop to set 70/100/30/10
  > +++++ ++            add 7 to cell #1
  > +++++ +++++         add 10 to cell #2
  > +++                 add 3 to cell #3
  > +                   add 1 to cell #4
  <<<< -                decrement counter (cell #0)
]
> ++ .                  print 'H'
> + .                   print 'e'
+++++ ++ .              print 'l'
.                       print 'l'
+++ .                   print 'o'
```


Hello World (2)

hello_world.bf - Part 2

```
> ++ .                  print ' '
<< +++++ +++++ +++++ .  print 'W'
> .                     print 'o'
+++ .                   print 'r'
----- - .               print 'l'
----- --- .             print 'd'
> + .                   print '!'
> .                     print '\n'
```


Programmier-Pattern

- Die Sprache ist sehr arm, aber man sieht, wie man bestimmte Dinge realisieren kann.
  - Zuweisung von Konstanten an Variable (ggfs. durch Schleifen) ist einfach.
  - Auf Null setzten (falls nur positive Werte zugelassen sind): `[-]`.
  - Übertragen des positiven Wertes von der aktuellen Zelle zu einer anderen Zelle, (mit gegebenem Abstand, z.B. +3), wenn diese 0 ist: `[->>> + <<< ]`
  - (Destruktive) Addition ist ebenfalls einfach (transferieren, wenn initialer Inhalt des Ziels der eine Summand ist).
  - Übertragen in zwei Zellen: `[->>>+>+<<<< ]`
  - Dann kann man auch einen Wert *kopieren*: Erst in zwei Zellen transferieren, dann den einen Wert zurück transferieren.
- ...aber wir wollen ja nicht wirklich Brainf*ck programmieren lernen. Falls doch: Es gibt Tutorials!

14.4 Semantik

Probleme mit der Semantik

Leider lässt die Angabe der Semantik einige Fragen offen:

```
Short:        240 byte compiler. Fun, with src. OS 2.0
Uploader:     umueller amiga physik unizh ch
Type:         dev/lang
Architecture: m68k-amigaos

The brainfuck compiler knows the following instructions:

Cmd  Effect
---  ------
+    Increases element under pointer
-    Decrases element under pointer
>    Increases pointer
<    Decreases pointer
[    Starts loop, flag under pointer
]    Indicates end of loop
.    Outputs ASCII code under pointer
,    Reads char and stores ASCII under ptr

Who can program anything useful with it? :)
```


Offene Fragen

1. Zellgröße: In der ursprünglichen Implementation 1 Byte (= 8 Bits) entsprechend den Zahlen von 0...255. Andere Implementationen benutzen aber auch größere Zellen oder sogar wie Python `bignums` (unbeschränkt große Zahlen)
2. Größe der Datenliste: Ursprünglich 30000. Aber auch andere Größen sind üblich. Manche Implementationen benutzen nur 9999, andere erweitern die Liste auch dynamisch, manchmal sogar links (ins Negative hinein).
3. Zeilenendezeichen: `\n` oder `\r\n`? Hier wird meist die Unix-Konvention verfolgt, speziell da C-Bibliotheken diese Übersetzung unter Windows unterstützen.
4. Dateiende (EOF): Hier wird beim Ausführen von `,` entweder 0 zurückgegeben, die Zelle wird nicht geändert, oder es wird (bei Implementationen mit größeren Zellen) -1 zurück gegeben.
5. Unbalancierte Klammern: Das Verhalten ist undefiniert!

Standardisierung und Portabilität ...

- Alle Programmiersprachen haben mit diesen oder ähnlichen Problemen zu kämpfen.
- Speziell der Bereich der darstellbaren Zahlen ist ein Problem.
- Oft wird festgelegt, dass es Implementations-abhängige Größen und Werte gibt.
- Außerdem gibt es immer Dinge, die außerhalb der Spezifikation einer Sprache liegen.
- Hier ist das Verhalten undefiniert, aber idealerweise wird eine Fehlermeldung erzeugt (statt erratischem Verhalten).

Implikationen für einen Interpreter

- In einem sehr Ressourcen-beschränktem Kontext (z.B. Mikrocontroller) gibt man die Beschränkungen vor ... und vertraut darauf, dass der Benutzer sie einhält.
- Will man hohe Flexibilität zusichern baut man einen Interpreter, bei dem man verschiedene Möglichkeiten vorsieht, die dann der Benutzer steuern kann.
- Insbesondere
  - sollte man statt undefiniertem Verhalten eine Fehlermeldung erzeugen;
  - und sowohl eingeschränkte (Zellgröße = 1Byte, 9999 Zellen) als auch liberale Interpretation erlauben (bignums, potentiell unendlich viele Zellen);
  - verschiedene EOF-Markierungen erlauben.

Implikationen für portable Brainf*ck-Programme

Will man Brainf*ck-Programme schreiben, die auf möglichst vielen Interpretern lauffähig sind, sollte man nur solche Sprachbestandteile nutzen, die auf allen Implementationen laufen:

- Bei Zellgröße nur ein Byte annehmen. Ggfs. sogar nur den Bereich von 0–127 nutzen, da es bei einer vorzeichenbehafteten Darstellung einen arithmetischen Überlauf geben könnte!
- Für die EOF-Markierung kann man jeweils zuerst die Zelle auf Null setzen und dann lesen. Damit bekommt man sowohl bei der Zurückgabe einer Null als auch bei der leeren Zurückgabe das gleiche Ergebnis.

14.5 Interpreter-Design

Designkriterien

Egal, was für Software Sie schreiben, Ihre Lösungen können Sie immer anhand der folgenden Kriterien bewerten:

- (Praktische) Effizienz: Wie schnell läuft das Programm und wie viel Speicher erfordert es? Gibt es schnellere oder sparsamere Alternativen? Sollte uns hier *noch* nicht interessieren!
- Skalierbarkeit: Wie stark wächst Laufzeit und Speicherbedarf mit der Größe der Eingabe?
- Eleganz: Wie „schön“ sieht das Programm aus? Z.B. viele Einzelfälle versus eine generelle Lösung.
- Lesbarkeit: Wie einfach ist das Programm zu verstehen?
- Wartbarkeit: Wie einfach ist es, Fehler zu finden oder neue Funktionalität zu integrieren?

Datenstrukturen (1)

- Welchen Datentyp sollen wir für die Darstellung des Brainf*ck-Programms wählen?
  - String?
  - Liste?
  - Tupel?
  - Rekursive Datenstruktur (organisiert entlang der Klammerstruktur)?
  - Dictionary? Wobei dann die jeweilige Stelle durch den Schlüssel beschrieben wird?
  - Datei? Zeichenweise lesen?

Datenstrukturen (2)

- Welchen Datentyp sollen wir für die Darstellung der Brainf*ck-Datenzellen wählen?
  - String?
  - Liste?
  - Tupel?
  - Dictionary? Wobei dann die jeweilige Stelle durch den Schlüssel beschrieben wird?
  - Datei? Zeichenweise lesen und schreiben?

I/O-Überlegungen

Wir haben es mit drei Ein-/Ausgabeströmen zu tun:

1. Das Programm: Sollte einmal eingelesen und dann verarbeitet werden.
2. Eingabestrom: Sollte Datei oder Konsoleingabe sein können.
3. Ausgabestrom: Sollte ebenfalls Datei oder Konsolenausgabe sein.

- Das Modul `sys` stellt zwei Datei-ähnliche Objekte für die Standareingabe und Standardausgabe zur Verfügung: `sys.stdin` und `sys.stdout`

Dateien öffnen ...

`bf.py: Open files`

```
import sys

def open_files(sfn, infn, outfn):
  if infn:
      fin = open(infn, "r")
   else:
      fin = sys.stdin
   if outfn:
      fout = open(outfn, "w")
   else:
      fout = sys.stdout
   return(open(sfn, "r"), fin, fout)
```

- Falls ein Dateinname angegeben wurde, soll die dazugehörige Datei geöffnet werden.

Ausnahmebehandlung

Wo können Fehler passieren?

- Dateifehler (Existenz/Lesen/(Über-)Schreiben)
  - ...sollten wir besser behandeln/abfangen!
- Fehler beim Interpretieren des Programms
  - für die Fehlersuche erst einmal nicht abfangen, später dann schon
- Verletzung von Sprachregeln (z.B. Nicht-ASCII-Zeichen > 127)
  - speziellen Ausnahmetyp einführen, der dann speziell behandelt wird:

`Spezielle Exception`

```
class BFError(Exception):
    pass
```

Die Hauptfunktion

bf.py: Main function

```
def bf(sfn, infn, outfn):

    try:
       (src,fin,fout) = open_files(sfn, infn, outfn)
        pass # TBI: Aufruf des Interpreters
    except IOError as e:
         print("I/O-Fehler:", e)
    except BFError as e:
        print("Abbruch wegen BF-Inkompatibilität:",e)
    except Exception:
        print("Interner Interpreter-Fehler")
    finally:
        fout.close()
```

- Hier gibt es noch ein/zwei Problemchen!

Die Hauptfunktion

bf.py: Main function

```
def bf(sfn, infn, outfn):
    fout = None
    try:
       (src,fin,fout) = open_files(sfn, infn, outfn)
        pass # TBI: Aufruf des Interpreters
    except IOError as e:
         print("I/O-Fehler:", e)
    except BFError as e:
        print("Abbruch wegen BF-Inkompatibilität:",e)
    except Exception:
        print("Interner Interpreter-Fehler")
    finally:
        if fout: fout.close()
```

- Hier gab es noch ein/zwei Problemchen!

Eine erste Spaghetti-Code-Idee für den Interpreter

bf0.py

```
def bfinterpret(srctext, fin, fout):
   # Program counter points into source text
   pc = 0;
   # data pointer
   ptr = 0;
   # data cells are stored in a dict
   data = dict();

   while (pc < len(srctext)):
       if srctext[pc] == '>'
           ptr += 1
       elif srctext[pc] == '+'
           data[ptr] = data.get(ptr,0) + 1
       elif ...
       pc += 1
```


Daten-getriebene Programmierung

- Ellenlange if-else-Anweisungen sind schwer lesbar, speziell wenn dann bei jedem Fall viele Dinge passieren
- Man kann die Fallunterscheidung auch Daten-getrieben vornehmen:
  - Wir legen eine Tabelle (dict) an, die für jeden BF-Befehl die notwendigen Operationen beschreibt (in Form von Funktionen).
- Von Daten-getriebener Programmierung spricht man, wenn das Programm nicht sequentiell die Daten abarbeitet, sondern der Datenstrom die Operationen determiniert.
- Diese Unterscheidung ist oft nur eine Frage der Perspektive, macht in unserem Fall aber einiges einfacher – die Funktion passt jetzt auf eine Folie!

Umsetzung des Daten-getriebenen Entwurfs

Jetzt passt die Interpreter-Funktion auf eine Folie:

bf.py: Main interpreter loop

```
def bfinterpret(srctext, fin, fout):
   pc = 0;
   ptr = 0;
   data = dict();
   while (pc < len(srctext)):
       (pc, ptr) = instr.get(srctext[pc],noop)(pc,
                       ptr, srctext, data, fin, fout)
        pc += 1
```

Wir benötigen also jetzt ein `dict` instr, in dem mit jeder BF-Instruktion eine Funktion assoziiert wird, die 6 Parameter besitzt und die ein Paar `(pc, ptr)` zurückgibt.

Die Instruktionstabelle

bf.py: instr_table

```
instr = { '<': left, '>': right,
          '+': incr, '-': decr,
          '.': ch_out, ',': ch_in,
          '[': beginloop, ']': endloop }
```

- Diese Tabelle darf erst definiert werden, nachdem alle Funktionen definiert wurden.

Die einfachen Fälle (1)

bf.py: Simple cases

```
def noop(pc, ptr, src, data, fin, fout):
    return(pc, ptr)

def left(pc, ptr, src, data, fin, fout):
    return(pc, ptr - 1)

def right(pc, ptr, src, data, fin, fout):
    return(pc, ptr + 1)
```

Beachte: Die Variable `pc` wird in der Hauptschleife erhöht!

Die einfachen Fälle (2)

bf.py: Simple cases

```
def incr(pc, ptr, src, data, fin, fout):
    data[ptr] = data.get(ptr,0) + 1
    return(pc, ptr)

def decr(pc, ptr, src, data, fin, fout):
    data[ptr] = data.get(ptr,0) - 1
    return(pc, ptr)
```

Beachte: Wir lassen auch negative Indizes zu und es sind beliebig viele Zellen erlaubt.

I/O

bf.py: I/O

```
def ch_in(pc, ptr, src, data, fin, fout):
    ch = fin.read(1)
    if ch:
        data[ptr] = ord(ch)
        if data[ptr] > 127:
            raise BFError(
               "Non-ASCII-Zeichen gelesen")
    return(pc, ptr)

def ch_out(pc, ptr, src, data, fin, fout):
    if data.get(ptr,0) > 127:
        raise BFError(
          "Ausgabe eines Non-ASCII-Zeichen")
    print(chr(data.get(ptr,0)), end='')
    return(pc, ptr)
```


Schleifen (1)

bf.py: Loop begin

```
def beginloop(pc, ptr, src, data, fin, fout):
  if data.get(ptr,0): return (pc, ptr)
  loop = 1;
  while loop > 0:
      pc += 1
      if src[pc] == ']':
          loop -= 1
      elif src[pc] == '[':
          loop += 1
  return(pc, ptr)
```

Frage: Was passiert bei unbalancierten Klammern?

Schleifen (1')

bf.py: Loop begin

```
def beginloop(pc, ptr, src, data, fin, fout):
  if data.get(ptr,0): return (pc, ptr)
  loop = 1;
  while loop > 0:
      pc += 1
      if pc >= len(src):
          raise BFError(
                 "Kein passendes ']' gefunden")
      if src[pc] == ']':
          loop -= 1
      elif src[pc] == '[':
          loop += 1
  return(pc, ptr)
```


Schleifen (2)

bf.py: Loop end

```
def endloop(pc, ptr, src, data, fin, fout):
  loop = 1;
  while loop > 0:
      pc -= 1
      if src[pc] == ']':
          loop += 1
      elif src[pc] == '[':
          loop -= 1
  return(pc - 1, ptr)
```

Frage: Was passiert bei unbalancierten Klammern?

Schleifen (2')

bf.py: Loop end

```
def endloop(pc, ptr, src, data, fin, fout):
  loop = 1;
  while loop > 0:
      pc -= 1
      if pc < 0:
          raise BFError(
                 "Kein passendes '[' gefunden")
      if src[pc] == ']':
          loop += 1
      elif src[pc] == '[':
          loop -= 1
  return(pc - 1, ptr)
```