ETH zürich

Departement Informatik

Programmieren und Problemlösen

Daten einlesen und Sortieren 1

Dennis Komm

Frühling 2021 – 1. April 2021

Listen

Weiterführende Konzepte

2-dimensionale Listen

Bislang beinhalten Listen Zahlen oder Zeichen

- Liste kann auch Listen beinhalten
- Solche **2-dimensionalen Listen** speichern z. B. Tabellen und Matrizen

$$M = \begin{pmatrix} 2 & 0 & 3 & 0 & 6 \\ 3 & 9 & 5 & 1 & 1 \\ 0 & 0 & 7 & 2 & 7 \\ 3 & 9 & 5 & 8 & 0 \\ 8 & 2 & 0 & 3 & 2 \\ 1 & 6 & 5 & 9 & 6 \end{pmatrix}$$

```
M = [ [2, 0, 3, 0, 6],
      [3, 9, 5, 1, 1],
      [0, 0, 7, 2, 7],
      [3, 9, 5, 8, 0],
      [8, 2, 0, 3, 2],
      [1, 6, 5, 9, 6] ]
```

- Zugriff auf `i`-te Zeile und `j`-te Spalte mit `M[i][j]`

Listen

Daten einlesen und in Listen speichern

Daten einlesen

Beispiel: Matrix in Datei gegeben

- Inhalt der Datei ist ein Text
- Matrix zeilenweise abgespeichert
- Einträge in jeder Zeile mit Kommata getrennt
- Einträge sollen als Zahlen interpretiert werden

Drei Schritte

1. Datei Zeile für Zeile einlesen
2. Einträge aus den Zeilen extrahieren (Trennsymbol: Komma)
3. Jeden Eintrag in Zahl konvertieren

Daten einlesen

1. Datei Zeile für Zeile einlesen

```
with open("daten.txt") as file:
    lines = file.read().splitlines()
```

- Datei `daten.txt` ist für den nachfolgenden Anweisungsblock geöffnet
- Zugreifbar unter dem Namen `file`
- `lines = file.read()` speichert den gesamten Text aus `daten.txt` in der Variablen `lines`
- `lines = file.read().splitlines()` speichert die einzelnen Zeilen von `daten.txt` als Einträge der Liste `lines`

Daten einlesen: Beispiel

1. Datei Zeile für Zeile einlesen

```
with open("daten.txt") as file:
    lines = file.read().splitlines()
```

daten.txt

```
2, 0, 3, 0, 6
3, 9, 5, 1, 1
0, 0, 7, 2, 7
3, 9, 5, 8, 0
8, 2, 0, 3, 2
1, 6, 5, 9, 6
```

```
lines = [ "2, 0, 3, 0, 6",
          "3, 9, 5, 1, 1",
          "0, 0, 7, 2, 7",
          "3, 9, 5, 8, 0",
          "8, 2, 0, 3, 2",
          "1, 6, 5, 9, 6" ]
```


Daten einlesen

2. Einträge aus erster Zeile extrahieren (Trennsymbol: Komma)

```
tmp = lines[0].split(",")
```

```
lines = [ "2, 0, 3, 0, 6",
          "3, 9, 5, 1, 1",
          "0, 0, 7, 2, 7",
          "3, 9, 5, 8, 0",
          "8, 2, 0, 3, 2",
          "1, 6, 5, 9, 6" ]
```

```
tmp = ["2", "0", "3", "0", "6"]
```

Daten einlesen

3. Jeden Eintrag in Zahl konvertieren

```
data = [0] * len(tmp)
for i in range(0, len(tmp)):
    data[i] = int(tmp[i])
```

```
tmp = ["2", "0", "3", "0", "6"]
```

```
data = [2, 0, 3, 0, 6]
```


Daten einlesen: Zusammenfassung

```
def readfile(filename):

    # Datei Zeile für Zeile einlesen
    with open(filename) as file:
        lines = file.read().splitlines()

    # Einträge aus erster Zeile extrahieren (Trennsymbol: Komma)
    tmp = lines[0].split(",")

    # Jeden Eintrag in Zahl konvertieren
    data = [0] * len(tmp)
    for i in range(0, len(tmp)):
        data[i] = int(tmp[i])

    return data
```


Aufgabe – Daten einlesen

Erweitern Sie die Funktion, sodass

- alle Zeilen der Datei gelesen und konvertiert werden
- der Inhalt in einer 2-dimensionalen Liste gespeichert wird

```
def readfile(filename):
    with open(filename) as file:
        lines = file.read().splitlines()
    tmp = lines[0].split(",")
    data = [0] * len(tmp)
    for i in range(0, len(tmp)):
        data[i] = int(tmp[i])
    return data
```

Daten einlesen

```
def readfile2(filename):
    # Datei Zeile für Zeile einlesen
    with open(filename) as file:
        lines = file.read().splitlines()
    data = []

    # Alle Zeilen nacheinander verarbeiten
    for i in range(0, len(lines)):
        tmp = lines[i].split(",")
        dataline = [0] * len(tmp)
        for j in range(0, len(tmp)):
            dataline[j] = int(tmp[j])
        data.append(dataline)
    return data
```

Oft sind Daten als solche `csv`-Dateien (Comma Separated Values) gegeben

Sortieren 1

Sortieren und Suchen

Sortieren und Suchen

Daten suchen und **sortieren** sind zwei der grundlegendsten Aufgaben von Informatikerinnen und Informatikern

Standardwerk dreht sich nur um diese Themen

- Gegeben seien n positive ganze Zahlen
- Genauer **unsortierte** Liste `data` mit `n = len(data)`
- Wir betrachten n als Eingabelänge
- Zahlen können mehrfach auftauchen
- **Sortiere** mit möglichst kleiner Zeitkomplexität

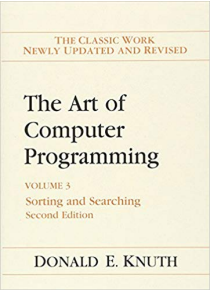

Sortieren 1

Bubblesort

Bubblesort

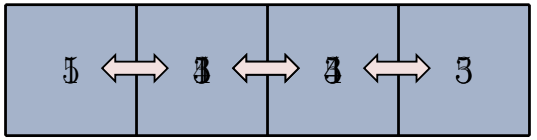

Bubblesort

Idee

Sortieren durch wiederholtes Finden des Maximums

Ziel

Liste `data` mit `n` Elementen sortieren, also Bereich $0, \ldots, n-1$

- Finde Maximum und schiebe es an die letzte Position
- Vergleiche hierzu iterativ alle benachbarten Elemente
- Maximum wandert wie Luftblase durch Liste an letzte Position
- Wiederholen mit Bereich $0, \ldots, n-2$
- Fahre fort, bis `data` sortiert ist

Aufgabe – Eine Bubble-Sequenz

Implementieren Sie eine Bubble-Sequenz

- Laufe einmal durch `data`
- Vergleiche jeweils benachbarte Paare
- Vertausche, wenn das erste Element grösser ist
- Maximum „bubblet“ nach rechts

Eine Bubble-Sequenz

Eine Bubble-Sequenz in Python

```
data = [6, 22, 61, 1, 89, 31, 9, 10, 76]
n = len(data)

for i in range(0, n-1):
    if data[i] > data[i+1]:
        tmp = data[i]
        data[i] = data[i+1]
        data[i+1] = tmp
```


Aufgabe – Bubblesort

Implementieren Sie den vollständigen Algorithmus

- Iteriere Bubble-Sequenzen
- Nach k-ter Sequenz sind die letzten k Elemente von `data` sortiert
- Bubble-Sequenzen werden mit jeder Iteration kürzer
- Verwende hierzu eine äussere Schleife

Bubblesort

```
def bubblesort(data):
    n = len(data)
    for d in range(n, 1, -1):
        for i in range(0, d-1):
            if data[i] > data[i+1]:
                tmp = data[i]
                data[i] = data[i+1]
                data[i+1] = tmp
    return data


print(bubblesort([6, 22, 61, 1, 89, 31, 9, 10, 76]))
```


Sortieren 1

Minsort

Minsort

Idee

Sortieren durch wiederholtes Finden des Minimums

- Anders als bei Bubblesort werden nicht benachbarte Elemente verglichen
- Aktuelles Minimum wird gespeichert
- Jedes Element wird mit diesem verglichen
- Falls es kleiner ist, werden beide miteinander vertauscht
- Nach einer Iteration wird Minimum an (aktuellen) Anfang kopiert
- Fahre fort, bis `data` sortiert ist

Minsort

```
def minsort(data):
    n = len(data)
    for current in range(0, n-1):
        minimum = data[current]
        for i in range(current+1, n):
            if data[i] < minimum:
                tmp = data[i]
                data[i] = minimum
                minimum = tmp
        data[current] = minimum
    return data

print(minsort([6, 22, 61, 1, 89, 31, 9, 10, 76]))
```

Sortieren 1

Zeitkomplexität von Bubblesort und Minsort

Zeitkomplexität von Bubblesort und Minsort

Zähle die Vergleiche von jeweils zwei Zahlen

- $n - 1$ Vergleiche, um das Maximum zu finden
- $n - 2$ Vergleiche, um das zweitgrösste Element zu finden
- ...
- 1 Vergleich, um die beiden kleinsten Elemente zu sortieren

⇨ Insgesamt $\sum_{i=1}^{n-1} i = (n-1) \cdot n/2 = (n^2 - n)/2$ Vergleiche

⇨ Quadratisch viele Vergleiche

Die Laufzeit von Bubblesort ist in $\mathcal{O}(n^2)$

Die Laufzeit von Minsort ist (mit ähnlichen Argumenten) in $\mathcal{O}(n^2)$

Zeitkomplexität von Bubblesort und Minsort