

## Übung 2 - Musterlösung

Abgabe 3.5.2012

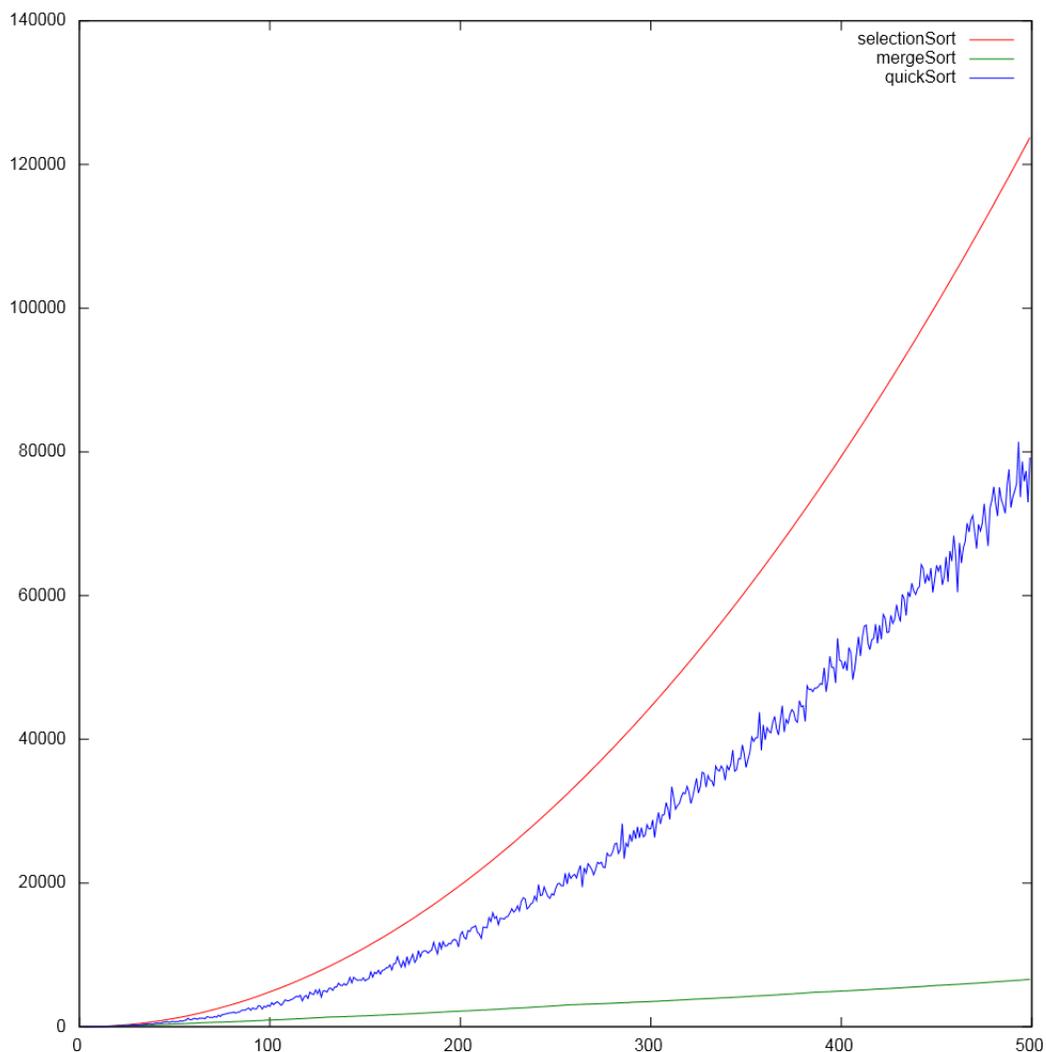
### Aufgabe 1 - Vergleichen und Testen von Sortierverfahren

24 Punkte

- a) Eine Möglichkeit der Implementation der Algorithmen befindet sich im Anhang. Das Plotten kann durch Gnuplot nach Ausführen von `sort.py` folgendermaßen geschehen:

```
gnuplot> set datafile separator ","
gnuplot> plot [0:500][0:140000] '/home/YOU/varyN.txt' using 1:2 with lines title
'selectionSort', \
> '/home/YOU/varyN.txt' using 1:3 with lines title 'mergeSort', \
> '/home/YOU/varyN.txt' using 1:4 with lines title 'quickSort'
gnuplot> set terminal postscript eps color solid
gnuplot> set output 'nVary.ps'
gnuplot> replot
```

Damit erhält man dann folgende Grafik:



Wie man sieht kommt man für `selectionSort()` gut an die quadratische Näherung – während `quickSort()` sehr unregelmäßig ist, da die Effizienz sehr stark von der Beschaffenheit des Anfangsarrays abhängt.

Das Fitting kann man so durchführen:

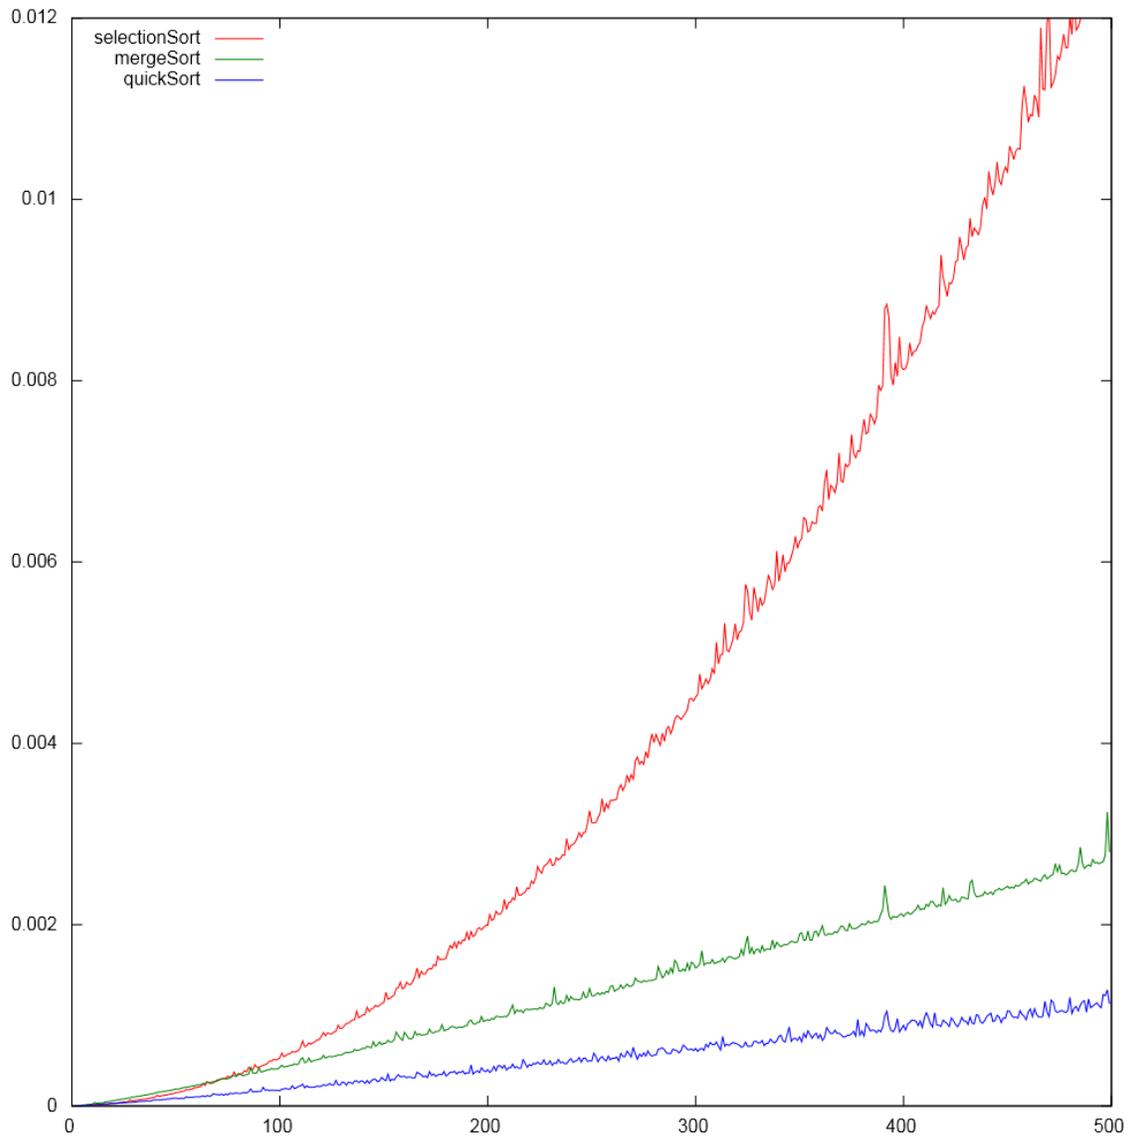
```
gnuplot> set datafile separator ","
gnuplot> f(x) = a*x**2 + b*x + c
gnuplot> g(x) = d*x*log(x)/log(2) + e*x + f
gnuplot> h(x) = g*x*log(x)/log(2) + h*x + i
gnuplot> fit f(x) '/home/YOU/varyN.txt' using 1:2 via a,b,c
gnuplot> fit g(x) '/home/YOU/varyN.txt' using 1:3 via d,e,f
gnuplot> fit h(x) '/home/YOU/varyN.txt' using 1:4 via g,h,i
```

Damit kommt man dann auf folgende Variablen:

$$\begin{aligned} a, b, c &= 0.5, -1.5, 1 \\ d, e, f &= 1.63744, -1.70546, 8.74094 \\ g, h, i &= 82.4639, -602.685, 6760.65 \end{aligned}$$

Wie man sieht, weichen die `quickSort()` Parameter besonders stark von der Norm ab.

- b) Das ist der Fall: Die funktionelle Form bleibt erhalten, es ändern sich lediglich die Konstanten, wie man an folgendem Plot sieht:



Wie von Hand gezeichnet.



## Bonusaufgabe – Dynamisches Array mit verringertem Speicherverbrauch

10 Punkte

- a) Die Gesamtzahl der Leerstände setzt sich aus den noch nicht besetzten Pointern und den nicht besetzten Plätzen im zuletzt angehängten Subarray zusammen. Anschaulich gilt es die `None` - Einträge im ungünstigsten Fall (direkt nach der Vergrößerung der Kapazität) zu zählen. Daraus ergibt sich folgende Berechnung:

$$n_{\text{Subarray}} + n_{\text{Pointer}} = p - 1 + \frac{p}{2} \approx 1.5 * p = 1.5 * \sqrt{C} < 2 * \sqrt{C}$$

Wobei sich die Abschätzungen durch folgende Überlegungen ergeben:

$$n_{\text{Subarray}} = p - 1 \text{ (worste case: nur ein Platz besetzt)}$$

$$n_{\text{Zeilen besetzt}} = \frac{C_{\text{alt}}}{p_{\text{neu}}} = \frac{(p_{\text{old}})^2}{p_{\text{neu}}} = \frac{\left(\frac{1}{\sqrt{2}} p_{\text{neu}}\right)^2}{p_{\text{neu}}} = \frac{p_{\text{neu}}}{2}$$

- b) Die einzelnen Formeln ergeben sich zum Beispiel aus Betrachtung der folgenden Matrix (die erste Spalte symbolisiert Pointer):

$$\left( \begin{array}{c|cccccc} \rightarrow & a_{11} & a_{12} & a_{13} & a_{14} & a_{15} & a_{16} \\ \rightarrow & a_{21} & a_{22} & a_{23} & a_{24} & \text{None} & \text{None} \\ \text{None} & & & & & & \end{array} \right)$$

Will man aufs 8. Element zugreifen, muss man also auf das 2. Element im 2. Unterarray zugreifen. Die Kapazität des Speichers ist 36, und damit die Dimension der Matrix  $p = 6$ . Immer wenn das letzte Unterarray voll ist, ist die Anzahl der Elemente somit ein Vielfaches von 6. Aus diesen einfach Beispielen kann man die geforderten Formeln ableiten:

- (1) 

```
row = k / p      # Integer-Division mit automatischem Abrunden
column = k % p  # Rest-Berechnung mit Modulo-Operator
element = array[row][column]
```
- (2) 

```
if self.size % p == 0:
    ... # add new subArray
```
- (3) 

```
if self.size == self.capacity:
    p = max(int(round(sqrt(2)*p)), p+1) # p+1 is needed for p==1
    self.capacity = p**2
erzeugt: capacity = p2 = { 1, 4, 9, 16, 36, 64, 121, ...}
```

- c) Eine mögliche Implementation befindet sich im Anhang unter `array.py`.
  
- d) Ein Nachteil ist zum Beispiel, dass durch das bedarfsorientierte Einfügen der Zeilen die Zellen nicht mehr nacheinander im Speicher abgelegt werden können. Hierdurch verteuert sich der Zugriff, weil die Gefahr von Cache-Misses größer ist. Auch die Berechnung der Zeilen- und Spaltenindizes (eine Division, eine Modulo-Berechnung) ist teurer als der einfache Indexzugriff im gewöhnlichen dynamischen Array.

## Anhang - sort.py

```
import copy
from timeit import Timer
from random import randint

def selectionSort(inList):

    count = 0

    #iterate through all elements from left to right
    for i in range(len(inList)):

        #set swap index to refer to the i-th element
        k = i

        #iterate through list right of i
        for j in range(i, len(inList)):

            #find smallest element in this range
            if inList[j] < inList[k]:

                #remember it
                k = j

            #iterate count
            count += 1

        #and swap with the first element
        inList[i], inList[k] = inList[k], inList[i]

    return count

def merge(left, right):

    count = 0

    #initialize result list
    result = []

    #while both of them are not empty
    while len(left) > 0 and len(right) > 0:

        #compare the first element of each list, then pop the smaller one
        #and append it at the result list
```

```
if left[0] > right [0]:
    result.append(right.pop(0))
else:
    result.append(left.pop(0))

#iterate count
count += 3

#append the rest of the remaining not empty list
result.extend(right)
result.extend(left)

return result, count
```

```
def mergeSort(inList):

    count = 0

    #if its just one element or empty, return it
    if len(inList) <= 1:
        return inList, 0

    else:
        #otherwise split it in half
        left = inList[:len(inList) / 2]
        right = inList[len(inList) / 2:]

        #and do the same with the resulting two lists.
        #meanwhile, collect all counts
        leftSorted, c = mergeSort(left)
        count += c
        rightSorted, c = mergeSort(right)
        count += c

    result, c = merge(leftSorted, rightSorted)
    count += c

    #return the merged, sorted list and the accumulated sort count
    return result, count
```

```
def quickSort(inList):

    count = 0

    #if its just one element or empty, return it
    if len(inList) <= 1:
        return inList, 0

    else:
        #select the first element as the pivot element
        pivot = inList.pop(0)
```

```

#initialize less and greater lists
less, greater = [], []

#append all elements lesser than pivot to less and
#append all elements greater than pivot to greater
for i in inList:
    if i < pivot:
        less.append(i)
    else:
        greater.append(i)
#iterate count
count += 1

#do the same to the resulting less and greater lists
#and collect counts
lessSorted, c = quickSort(less)
count += c
greaterSorted, c = quickSort(greater)
count += c

#return a list concatenated in the following order and the count
result = lessSorted + [pivot] + greaterSorted
return result, count

```

```
def checkSort(inList, outList):
```

```

#make a copy of the out list
outListc = copy.deepcopy(outList)

```

```

#compare lengths
if len(inList) != len(outList):
    return False

```

```

#check for all elements to be the same
for x in inList:
    try:
        outListc.remove(x)
    except:
        return False

```

```

#check for all elements being sorted properly
for i in range(len(outList) - 1):
    if outList[i] > outList[i + 1]:
        return False

```

```

#all tests passed, return True
return True

```

```

#*****#
#           Apply algorithms and save the collected data to files           #
#*****#

```

```
testDir = '/home/YOU/'

#open file with write access
f = open(testDir + 'varyN.txt', 'w')

#check the count of sort algorithms for lists
#between length 2 and 500
for i in range(2, 500):

    #create random list
    a = []
    for j in range(2, i):
        a.append(randint(2, i))

    #and two copies -> 3 sorting algorithms
    b = copy.copy(a)
    c = copy.copy(a)

    #create a string containing information about
    #the respective counts, write it to file
    f.write(str(i) + "," + \
            str(selectionSort(a)) + "," + \
            str(mergeSort(a)[1]) + "," + \
            str(quickSort(a)[1]) + "\n")

#close file
f.close()

#open file with write access
f = open(testDir + 'varyT.txt', 'w')

#check the duration of sort algorithms for lists
#between length 2 and 500
for i in range(2, 500):

    #create a random list
    a = []
    for j in range(2, i):
        a.append(randint(0, i))

    #and two copies -> 3 sorting algorithms
    b = copy.copy(a)
    c = copy.copy(a)

    #create a string containing information about
    #the respective durations, write it to file
    f.write(str(i) + ", " + \
            str(Timer("selectionSort(" + str(a) + ")"), 'from __main__ import selectionSort').timeit(1)) + ", " + \
            str(Timer("mergeSort(" + str(b) + ")"), 'from __main__ import mergeSort').timeit(1)) + ", " + \
            str(Timer("quickSort(" + str(c) + ")"), 'from __main__ import quickSort').timeit(1)) + "\n");

#close file
f.close()
```

## Anhang - array.py

```
from math import ceil, sqrt

class DynamicArray(object):

    def __init__(self):

        # initialize data container, size, capacity and p. It holds  $p^2$ =capacity.
        # the data structure can be visualized as a matrix
        self.data = [[None]]
        self.size = 0
        self.capacity = 1
        self.p = 1

    def append(self, item):

        # if matrix is full, extend it
        if self.size == self.capacity:

            # recalculate capacity and p, remember pOld
            pOld = self.p
            self.p = max(int(round(sqrt(2) * self.p)), p+1)
            self.capacity = self.p ** 2

            # remember old data, reallocate self.data with p "rowpointers"
            oldData = self.data
            self.data[0] = [None] * self.p

            # copy element-wise from old matrix into the new matrix
            for i in range(self.size):
                rowNew = i / self.p
                colNew = i % self.p
                rowOld = i / pOld
                colOld = i % pOld
                if self.size == self.capacity:
                    self.data[0] = [None] * self.p # allocate next row
                    self.data[rowNew][colNew] = tmp[rowOld][colOld]

            # row, column of the item in the CURRENT matrix
            row = self.size / self.p
            col = self.size % self.p

            # if row is full, create the next row
            if col == 0:
                self.data[0] = [None] * self.p

            # assign new item to its cell in the matrix
            self.data[row][col] = item

        # increment size
        self.size += 1
```

```
# implement support for 'x = a[i]'
def __getitem__(self, index):

    # check for valid index
    if index < 0 or index >= self.size:
        raise IndexError('DynamicArray: Invalid index')
    return self.data[index / self.p][index % self.p]

# implement support for 'a[i] = x'
def __setitem__(self, index, item):

    # check for valid index
    if index < 0 or index >= self.size:
        raise IndexError('DynamicArray: Invalid index')
    self.data[index / self.p][index % self.p] = item

# implement support for 'len(a)'
def __len__(self):
    return self.size

# implement support for 'print a'
def __str__(self):
    return "\n".join([str(i) for i in self.data])

# make array.py executable, add a little demonstration and test
if __name__ == "__main__":
    a = DynamicArray()
    desiredSize = 100
    print "appending", desiredSize, elements"
    for i in range(desiredSize):
        a.append(i)
        print 'Size: ', a.size
        print 'Capacity', a.capacity
    print 'a[0],a[50],a[73]: ', a[0], a[50], a[73]
    print "testing all entries:",
    assert len(a) == desiredSize
    for i in range(desiredSize):
        assert a[i] == i
    print "OK"
    a[23] = 42
    assert a[23] == 42
```