

Programmieren 1 Übung: Arrays: Sortieren

Klaus Kusche

Diejenigen Tätigkeiten, mit denen Computer im Schnitt die meiste Zeit verbringen, sind Suchen und Sortieren.

Es gibt in der Informatik 4 Gruppen von Sortierverfahren:

- Die einfachen, aber langsamen Verfahren:

Bubblesort (Sortieren durch Vertauschen)

Insertion Sort (Sortieren durch Einfügen)

Selection Sort (Sortieren durch Auswählen)

Sie brauchen im Schnitt in etwa n^2 Vergleiche und / oder Zuweisungen, um n Werte zu sortieren, und bestehen alle aus zwei ineinander geschachtelten Schleifen.

- Die verbesserten einfachen, etwas schnelleren Verfahren:

Shellsort, Combsort, ...

Ihr Rechenaufwand wächst mit einer kleineren Potenz als n^2 , also z.B. mit $n^{1.5}$.

Sie arbeiten meist ähnlich wie der Bubble- oder Insertion Sort, aber beseitigen zuerst einmal die grobe Unordnung (auf weite Distanzen) und bringen erst dann lokal benachbarte Elemente in die richtige Reihenfolge.

- Die schnellen (aber auch ziemlich komplizierten) Sortierverfahren:

Quicksort, Heapsort, ...

Sie brauchen zum Sortieren von n Zahlen im Mittel rund $n \cdot \log(n)$ Vergleiche und Zuweisungen, was für große n sehr viel besser als n^2 ist (rechne nach!).

- Die Verfahren für Spezialzwecke:

Mergesort, Radixsort, ...

Der Mergesort ist primär für das Sortieren von Dateien statt von Daten in Arrays gedacht, und der Radixsort ist gut geeignet, wenn die Werte, nach denen sortiert wird, aus wenigen einzelnen Zeichen oder Ziffern bestehen (z.B. Autokennzeichen).

Wir wollen uns mit den einfachen Verfahren beschäftigen.

Um n Zahlen mit Index 0 bis $n-1$ zu sortieren, geht man wie folgt vor:

- **Selectionsort:** Schleife 1 macht $n-1$ Durchläufe mit **pos** von 0 bis $n-2$.
In jedem Durchlauf wählen wir das kleinste Element aus allen Elementen hinter der Stelle **pos** (dort stehen alle noch unsortierten Elemente) und vertauschen es mit dem Element an Stelle **pos**.
 - Dazu merken wir uns zuerst einmal den Wert des Elementes **pos** als vorläufig kleinsten Wert und die Position **pos** als Position des kleinsten Wertes (gibt es dahinter keinen kleineren Wert, so wird das Element an Stelle **pos** "mit sich selbst vertauscht").
 - Dann vergleichen wir in Schleife 2 jedes Element an Stelle **pos+1** bis $n-1$ mit dem aktuellen kleinsten Wert. Ist es kleiner, speichern wir es als neuen kleinsten Wert und merken uns auch seine Position.
 - Schließlich kopieren wir das Element an Stelle **pos** an die gemerkte Position des kleinsten Elementes und den gespeicherten kleinsten Wert an die Stelle **pos**.
 - **Insertionsort:** Schleife 1 macht $n-1$ Durchläufe mit **pos** von 1 bis $n-1$.
In jedem Durchlauf fügen wir das Element an Stelle **pos** an die richtige Stelle in die (schon sortierten) Elemente davor ein:
 - Wir merken uns zuerst einmal das Element an Stelle **pos** in einer Hilfsvariable **tmp**.
 - Dann gehen wir in Schleife 2 mit **i** von Stelle **pos** (incl.) abwärts, solange **i** größer 0 ist und das Element an Stelle **i-1** größer als **tmp** ist, und verschieben jedesmal das Element **i-1** in das Element **i**.
 - Sobald **i** an der richtigen Stelle ist (entweder gleich 0 , d.h. ganz vorne, oder hinter einem Element, das kleinergleich **tmp** ist), speichern wir **tmp** im Element **i**.
 - **Bubblesort:** Schleife 1 macht $n-1$ Durchläufe mit **pos** von $n-1$ bis 1 abwärts.
In jedem Durchlauf gehen wir in Schleife 2 mit **i** alle Elemente von 0 bis **pos-1** einmal durch (die Elemente ab Stelle **pos+1** sind nämlich schon richtig sortiert) und vergleichen das Element an Stelle **i** mit seinem unmittelbaren Nachfolger an Stelle **i+1**. Ist der Nachfolger kleiner, vertauschen wir die beiden Elemente.
Hinweis: Es gibt zwei Optimierungen für Bubblesort (siehe z.B. Wikipedia):
 - Hat Schleife 2 keine einzige Vertauschung gemacht, kann man sich die restlichen Durchläufe von Schleife 1 sparen und sofort aufhören.
 - Man muss mit Schleife 2 nicht bis **pos-1** gehen:
Es reicht, wenn man bis zu jenem Index geht, bei dem im vorigen Durchlauf von Schleife 1 die hinterste Vertauschung in Schleife 2 stattfand.
- Im durchschnittlichen Fall (zufällig gemischte Elemente) bringen die Optimierungen aber nicht viel, Bubblesort ist trotzdem das im Schnitt langsamste Verfahren.

Und damit wir auch eine gute Vorstellung bekommen, wie diese Verfahren arbeiten, schreiben wir ein Programm mit schöner Grafik-Ausgabe.

Ich stelle dafür ein halbfertiges Programm zur Verfügung, das du ergänzen kannst.

- Wir sortieren ein Array von so vielen **int**-Werten, wie unser Fenster hoch ist (**SDL_Y_SIZE**).
- Als erstes füllen wir das Array mit den Zahlen von **1** bis **SDL_Y_SIZE**.
- Dann mischen wir die Zahlen gut:

Wir ermitteln zwei Zufallszahlen **x** und **y** zwischen **0** und **SDL_Y_SIZE-1** (sorge dafür, dass die Zufallszahlen bei jedem Programmmlauf andere sind!) und vertauschen die Array-Elemente an den Stellen **x** und **y** (erinnere dich: Was muss man tun, um zwei Array-Elemente zu vertauschen?). Das wiederholen wir 3000 Mal.

(Es gibt viel bessere Verfahren, um eine zufällige Umordnung von **n** Zahlen zu erzeugen, aber das ist nicht das Thema dieser Übung.)

- Als nächstes geben wir das Array aus, der Code dafür steht schon im gegebenen Programm.
- Schließlich sortieren wir das Array mit einem der oben beschriebenen Verfahren, wobei wir am Ende jedes einzelnen Durchlaufes von Schleife 1 (d.h. unten in der äußeren Schleife) wieder unsere Ausgabe (steht schon im Angabe-Programm) machen, damit man dem Sortieren “bei der Arbeit zusehen” kann.

Die ganz Mutigen dürfen auch den **Shellsort** probieren:

Der Shellsort ist eine Erweiterung des Insertionsorts.

Die Idee ist, beim Einfügen des aktuellen Elementes in die schon sortierten Werte davor nicht unmittelbar benachbarte Werte zu vergleichen und zu verschieben, sondern zuerst einmal die "grobe Unordnung" zu beheben, indem man Werte über große Distanzen vergleicht und verschiebt.

Man macht also mehrmals einen kompletten Insertionsort

und verringert bei jedem Insertionsort den Vergleichs- und Vertauschungsabstand:

- Nimm dein Programm für den *Insertionsort als Ausgangsbasis*.
- Leg ein *Array für die Vergleichs- und Vertauschungsabstände* an und initialisiere es mit den Werten **385, 124, 40, 13, 4** und **1** (diese Werte wurden von der Wissenschaft als ziemlich optimal ermittelt).
- Bau um deine Schleife 1 außen herum eine *neue Schleife*, die dieses Array durchgeht und die Variable **abst** der Reihe nach mit den Werten aus dem Array belegt.
- Die bisherige Schleife 1 beginnt nicht bei **1**, sondern bei **abst** zu zählen.
- Die bisherige Schleife 2 zählt mit **i** beginnend von **pos** mit Schrittweite **abst** (statt **1**) abwärts, und zwar solange **i** größergleich **abst** ist und das Element an Stelle **i-abst** größer **tmp** ist.
- In Schleife 2 wird nicht das Element **i-1**, sondern das soeben verglichene Element von Stelle **i-abst** in das Element an Stelle **i** verschoben.

Der Shellsort sieht grafisch langsamer aus als die anderen Verfahren, aber das täuscht: Wir zeichnen die Grafik beim Shellsort viel öfter neu als bei den anderen Verfahren, deshalb braucht es länger (weil nach jedem Grafik-Update gewartet wird), und man sieht mehr Zwischeschritte.

Aber zwischen zwei Updates der Grafik macht der Shellsort intern sehr viel weniger Vergleiche und Vertauschungen als die anderen Verfahren (zur Kontrolle kannst du ja bei allen Verfahren mitzählen und am Ende ausgeben, wie oft zwei Array-Elemente verglichen bzw. verschoben werden).