

Algorithmen und Datenstrukturen (für ESE) WS 2010 / 2011

Vorlesung 4, Montag, 15. November 2010
(Assoziative Arrays)

Prof. Dr. Hannah Bast
Lehrstuhl für Algorithmen und Datenstrukturen
Institut für Informatik
Universität Freiburg

Blick über die Vorlesung heute

■ Organisatorisches

- Morgen ist wieder eine Übungsgruppe
- Ihre Erfahrungen mit dem 3. Übungsblatt

■ Assoziative Arrays

- Wir werden an einem typischen Beispiel sehen, was das ist und wofür sie gut sind
- Die Übungsaufgabe wird diesmal ein Programm sein, wo man assoziative Arrays gut gebrauchen kann

Ihre Erfahrungen mit dem 3. Ü-Blatt

- Zusammenfassung von Ihrem Feedback
 - Ein sehr mathe-lastiges Übungsblatt
 - Die meisten fanden es diesmal vom Aufwand und Schwierigkeitsgrad her angemessen
 - "Ich konnte dieses Mal viel mehr mit der Vorlesung anfangen und das Blatt ist im Allgemeinen leichter gefallen. Falls jedoch alles falsch ist, war die Vorlesung nicht gut."
 - LaTeX hat für einige viel Zeit gekostet
 - Was muss man beweisen und was darf man einfach so behaupten? Zum Beispiel $2^n > n$ für alle $n \geq 1$
 - Gute Frage ohne einfache Antwort

Normale vs. Assoziative Arrays

■ Normales Array

- Zugriff auf eine (große) Anzahl von gleichartigen Elementen über einen fortlaufenden Index

$A_0, A_1, A_2, A_3, A_4, A_5, \dots$

- Beispielanfrage: das Element mit Index 3

■ Assoziatives Array

- Zugriff auf eine (große) Anzahl von gleichartigen Elementen über einen beliebigen sog. Schlüssel (Key)

– $A_{\text{Paprika}}, A_{\text{Sellerie}}, A_{\text{Kohlrabi}}, A_{\text{Tomate}}, \dots$

- Beispielanfrage: das Element mit Schlüssel Kohlrabi

- Die Schlüssel können auch (beliebige) Zahlen sein

Und wofür braucht man das?

■ In der Praxis ...

- ... gibt es kaum ein größeres Programm wo man nicht irgendwo ein assoziatives Array braucht

■ Ein typisches Beispiel

- Gegeben eine lange Liste von Anfragen an eine Suchmaschine
- Wir wollen wissen, welche Anfrage am häufigsten vorkommt
- Man beachte, dass es theoretisch unendlich viele verschiedene Anfragen gibt, von denen aber nur relativ wenige tatsächlich vorkommen
- Wir werden uns **drei** Lösungen für dieses Problem anschauen: mit Sortieren, mit einem normalen Array und mit einem assoziativem Array

Lösung 1: Sortieren

■ Idee

- Wir sortieren die Anfragen lexikographisch
- Dann haben wir Blöcke von gleichen Anfragen
- Die Größe von jedem Block können wir zählen
- Und dann den größten Block finden

■ Nachteil

- Wir müssen einmal alles sortieren, das ist teuer und kostet außerdem Platz
- Wir müssen zweimal über die ganzen Daten laufen

■ Vorteil

- Algorithmisch einfach + geht von der Kommandozeile aus mit einfachen Unix/Linux-Befehlen

Lösung 2: Normales Array

■ Idee

- Wir merken uns für jede Anfrage, wie oft wir sie schon gesehen haben
- Dabei können wir uns auch leicht zu jedem Zeitpunkt die bis dahin häufigste Anfrage merken

■ Problem

- Nehmen wir an, wir haben schon n verschiedene Anfragen gesehen
- Wie finden wir dann für die nächste Anfrage heraus, ob es eine neue oder eine von diesen n ist?
- Mit einem normalen Array geht das in $O(n)$ Zeit
- Bei n verschiedenen Anfragen also insgesamt $\Theta(n^2)$ Zeit

Lösung 3: Assoziatives Array

■ Idee

- Ein assoziatives Array von Zählern mit der Suchanfrage als Index
- Und wie vorher merken wir uns zu jedem Zeitpunkt die bis dahin häufigste Suchanfrage

■ Vorteil

- Nehmen wir an wir können in Zeit $O(1)$ auf einen der schon vorhandenen Zähler zugreifen bzw. herausfinden, dass es für diesen Index noch keinen Zähler gibt
- Dann hat unser Programm für eine Liste von n Suchanfragen Laufzeit $O(n)$

Effiziente assoziative Arrays

- In der C++ STL bzw. in java/util ...
 - ... heißt das assoziative Array einfach **map**
 - Der Index heißt dort **key**, das Element heißt **value**
 - Eine **map** unterstützt u.a. die folgenden Operationen
 - **insert(key, value)** : Einfügen von Element **value** mit Schlüssel **key**
 - **get(key)**: Zugriff auf das Element mit Schlüssel **key**
 - **erase(key)** : Löschen des Elementes mit Schlüssel **key**
- Effizienz
 - Hängt von der Implementierung ab
 - Das machen wir in der nächsten Vorlesung, da bauen wir uns unsere eigene map ... und analysieren sie dann

Vorsicht bei der STL map

- Sie hat ein besonderes "feature"

- Nehmen wir an, wir haben eine `map` mit Schlüsseln vom Typ `std::string` und Elementen vom Typ `int`

```
std::map<std::string, int> M;
```

- Dann kann man auf Elemente einfach mit dem `[]` Operator zugreifen wie bei einem normalen Array

```
M["kohlrabi"] = 5;
```

```
M["sellerie"] = -12;
```

- Aber Vorsicht, wenn das Element vorher nicht in der `map` war, wird es durch `[]` angelegt, mit dem Defaultwert für den Typ von `value`, für `int` ist das `0`.

```
if (M["birne"] > 0) ... // Inserts "birne" with value 0.
```

```
if (M.count("birne") > 0) ... // Only asks if "birne" is there.
```

■ Assoziative Arrays

– In Mehlhorn/Sanders:

4 Hash Tables and Associative Arrays (das führt schon weiter)

– In Cormen/Leiserson/Rivest

12 Hash Tables (das ebenso)

– In Wikipedia

http://de.wikipedia.org/wiki/Assoziatives_Array

http://en.wikipedia.org/wiki/Associative_array

■ Map in C++ und Java

<http://www.cplusplus.com/reference/stl/map/>

<http://download.oracle.com/javase/1.4.2/docs/api/java/util/Map.html>

