

# Software Entwicklung 1

Annette Bieniusa / Arnd Poetzsch-Heffter

AG Softech  
FB Informatik  
TU Kaiserslautern

# Überblick

- Weitere Sortierverfahren
  - Merge Sort
  - Heap Sort
- Praktische Auswirkungen der Laufzeitabschätzungen
- Abstrakte Datentypen
  - Listen
  - Stapel
  - Warteschlangen

# Merge Sort

# Sortieren durch Mischen (*merge sort*)

## Algorithmische Idee (Divide-and-Conquer Strategie):

- 1 Hat die zu sortierende Folge mehr als ein Element, teile diese in zwei gleich große Teile auf (bzw. mit einem Größenunterschied von 1).
- 2 Sortiere die zwei Teilfolgen.
- 3 Füge die zwei sortierten Teilfolgen nun wieder zu einer sortierten Folge zusammen.


## Implementierung auf Arrays:

- Kopiere die sortierten Teilarrays in ein *Hilfsarray*.
- Verwende dieses, um die sortierten Teilfolgen wieder zusammenzufügen.

# Laufzeitabschätzung I

Struktur des Aufrufbaums:

(Annahme:  $N = 2^n$  für  $n \in \mathbb{N}$ )



Wie oft wird MergeSort rekursiv verschachtelt aufgerufen?

⇒  $\log N$ , da bei jedem rekursiven Aufruf das jeweilige Teilarray halbiert wird

## Laufzeitabschätzung II

In jedem Merge werden die Schlüssel des Teilarrays genau zweimal kopiert (in das Hilfsarray und zurück). Die Anzahl der Schlüsselvergleiche beträgt insgesamt pro Schlüssel max.  $\log N$ .

Schlüsselvergleiche:  $C(N) \in O(N \log N)$

Datensatzzuweisungen:  $M(N) \in O(N \log N)$

# Bemerkungen

- Es wird ein Hilfsarray benötigt, d.h. bei der Implementierung auf Arrays wird zusätzlich Speicherplatz für ein Array von gleicher Größe wie die Eingabe reserviert.
- Gut geeignet für die Sortierung von verketteten Listen ( $\Rightarrow$  siehe Übung)

# Heap Sort



# Weitere Anwendungen von Sortiertechniken

## Fragestellung:

Gegeben  $N$  Datensätze, wie finde ich die Einträge mit den  $M$  größten Schlüsseln?

Aus der Praxis:

- Top 1000 der besten Spielerergebnisse eines Online-Games
  - Aufgaben mit Prioritäten in einer Todo-List
  - Messergebnisse bei Experimenten
- Ergebnisse evtl. nicht alle direkt verfügbar (Größe  $N$  zunächst unbekannt)
- Datensätze sollten nacheinander hinzugefügt werden können

# Lösungsansatz


Entferne aus den Datensätzen  $M$ -mal den jeweils größten Datensatz!

# Datenstrukturen zur Datenrepräsentierung

- Ungeordnetes Array
  - Annahme: Arraygröße ist  $\geq N$
  - Hinzufügen von neuen Elementen  $O(1)$
  - Entfernen des Maximums  $O(N)$
- Geordnetes Array
  - Annahme: Arraygröße ist  $\geq N$
  - Entfernen des Maximums  $O(1)$
  - Hinzufügen von neuen Elementen  $O(N)$  (Insertion Sort)
- Sortierte Verlinkte Liste
  - ähnlich wie bei geordnetem Array

# Datenstruktur Heap

*Idee:* Verwende einen Binärbaum, bei dem der Schlüssel in jedem Knoten größer oder gleich der Schlüssel in den direkten Kindknoten ist  
(**Heap-Eigenschaft**)



Die Heap-Eigenschaft garantiert, dass der Schlüssel eines Knotens größer gleich *aller* Schlüssel in den Unterbäumen ist.

Insbesondere steht in der Wurzel ein Element mit einem maximalen Schlüssel.

# Bemerkung

- Achtung: Der Begriff *Heap* ist in der Informatik überladen!
- Auch der Speicher für zur Laufzeit angelegte Variablen wird im Englischen *heap* genannt.

# Adressierung der Knoten

- Speichern der Datensätze in einem Array statt aufwendiger Verlinkung der Knoten
- Arithmetik auf den Arrayindizes zur Navigation zwischen Knoten
- Zu einem Knoten  $k$  befindet sich
  - der linke Kindknoten an Position  $2(k + 1) - 1$
  - der rechte Kindknoten an Position  $2(k + 1)$
- Das Array darf keine "Lücken" haben.

# Begriffsklärung: Vollständiger Baum

Die **Tiefe** eines Knotens ist die Länge des Pfades von der Wurzel bis zu dem Knoten.

Die **Höhe** eines Baumes ist um eins größer als die maximalen Tiefe der Knoten.

Ein Binärbaum der Höhe  $h$  heißt **vollständig**, wenn jeder Knoten mit maximaler Tiefe ( $h - 1$ ) ein Blatt ist und jeder Knoten mit geringerer Tiefe zwei (nicht-leere) Unterbäume hat.


# Begriffsklärung: Fast vollständiger Baum

Ein Binärbaum der Höhe  $h$  heißt **fast vollständig**, wenn


- jedes Blatt die Tiefe  $h - 1$  oder  $h - 2$  hat,
- jeder Knoten mit einer Tiefe kleiner  $h - 2$  zwei (nicht-leere) Unterbäume hat, und
- für die Knoten  $k$  des Niveaus  $h - 2$  gilt:
  - 1 Hat  $k$  zwei nicht-leere Unterbäume, dann auch alle linken Nachbarn (Knoten gleicher Tiefe) von  $k$ .
  - 2 Ist  $k$  ein Blatt, dann sind auch alle rechten Nachbarn von  $k$  Blätter.
  - 3 Es gibt maximal ein  $k$  mit genau einem nicht-leeren linken Unterbaum.

Strukturskizze:

Vollständiger Baum



Fast vollständiger Baum





# Begriffsklärung: Heap

Ein markierter, fast vollständiger Binärbaum mit  $n$  Knoten, die mittels Indizes direkt referenziert werden können, heißt **Heap** der Größe  $n$ , wenn die Heap-Eigenschaft erfüllt ist:

Ist  $i$  ein Knoten und  $j$  ein Kind von  $i$ , so gilt für die Markierungen der Knoten:

$$m(i) \geq m(j)$$

# Herstellen der Heap-Eigenschaft




Gegeben sei ein markierter, fast vollständiger Binärbaum der Größe  $n$ , der die Heap-Eigenschaft nur an einem Knoten  $k$  verletzt.

Die Heap-Eigenschaft kann hergestellt werden, indem man den Knoten  $k$  *versickern* lässt.

*Idee:* Vertausche den Knoten mit dem größeren der beiden Kind-Knoten.

- Gibt es kein Kind, gibt es nichts zu tun (Heap-Eigenschaft gilt!)
- Gibt es genau ein Kind  $l$ , dann ist dies links und kinderlos:  
Falls  $m(k) < m(l)$ , vertausche die Markierungen.  
Danach gilt die Heap-Eigenschaft wieder.
- Gibt es zwei Kinder  $l$  und  $r$  und ist  $j$  das Kind mit dem größeren Schlüssel:  
Ist  $m(k) < m(j)$ , vertausche die Markierungen und fahre rekursiv mit dem Versickern fort.

# Beispiel: Versickern lassen



# Indexberechnung

```
// Index des linken Kindknotens im Array
static int leftChild(int k) {
    return 2 * (k + 1) - 1;
}
```

```
// Index des rechten Kindknotens im Array
static int rightChild(int k) {
    return 2 * (k + 1);
}
```

# Implementierung

```
static void sink (DataSet [] f, int n, int k) {
    if (leftChild(k) < n) {        // Gibt es mind. ein Kind?
        int l = leftChild(k) ;    // Index des linken Kinds
        int r = rightChild(k);    // Index des rechten Kinds

        int j = l;
        if (r < n && f[l].key < f[r].key) {
            // Falls es zwei Kinder gibt und
            // r den groesseren Schluessel hat
                j = r;
        }

        if (f[k].key < f[j].key) {
            swap(f, k, j);
            sink(f, n, j);
        }
    }
}
```

# Heapsort

Sortieren mit Hilfe der Heap-Datenstruktur

- 1. Schritt: Erstelle einen Heap auf dem Eingabearray
- 2. Schritt:
  - Tausche Maximumelement (Wurzelement) mit dem aktuell letzten Element des Heaps
  - Versickere das neue Wurzelement
  - Fahre mit Schritt 2 fort, bis der Heap leer ist

# Optimierung für Schritt 1

Die initiale Heap-Erzeugung erfolgt von rechts nach links durch die Erzeugung von Heaps auf den kleinen Teilbäumen.

Blätter (d.h. Teilbäume der Größe 1) erfüllen die Heap-Eigenschaft direkt, daher können diese bei der Konstruktion übersprungen werden.

## **Lemma:**

In einem fast vollständigen Binärbaum der Größe  $n$  haben die Blätter die Indizes  $(n \div 2)$  bis  $n - 1$ .

# HeapSort

```
static void sort(DataSet[] f) {
    int size = f.length;

    // Schritt 1: Herstellen der Heap-Bedingung
    for (int i = size/2 - 1; i >= 0; i--) {
        sink(f, size, i);
    }

    // Schritt 2: Sortieren
    while (size > 0) {
        size--;
        swap(f, 0, size);
        sink(f, size, 0);
    }
}
```



# Grobe Laufzeitabschätzung von Heapsort I

Sei  $C$  die Anzahl der Vergleichsoperationen,  
 $M$  die Anzahl der Vertauschungen und  
 $N$  die Größe der Eingabe.

Wir betrachten hier nur den ungünstigsten Fall.

# Grobe Laufzeitabschätzung von Heapsort II

## Herstellen der Heap-Eigenschaft

Sei  $j$  die Anzahl der Niveaus im Heap, also  $2^{j-1} \leq N \leq 2^j - 1$ .

Dann gibt es auf Niveau  $k$  höchstens  $2^k$  Schlüssel und  $C_{max}$  und  $M_{max}$  sind proportional zu  $j - k$ .

Insgesamt gilt dann für die Anzahl der Operationen zur Herstellung der Heap-Eigenschaft:

$$\sum_{k=1}^{j-1} 2^k (j - k) = \sum_{i=1}^{j-1} 2^{j-i} i = 2^j \sum_{i=1}^{j-1} \frac{i}{2^i} \leq 2N * 2 \in O(N)$$

# Grobe Laufzeitabschätzung von Heapsort III

## Auswahl des Wurzelements und Versickern

Da die Höhe eines fast vollständigen Binärbaums von Ordnung  $O(\log N)$  ist, führt **sink**  $O(\log N)$  Operationen aus.

Damit ergibt sich für das Versickern aller Elemente die Komplexität  $O(N \log N)$ .

Komplexität des gesamten Algorithmus':

$$O(N \log N)$$

# Übersicht: Laufzeitverhalten der Sortieralgorithmen

Die Laufzeiten im “worst case” entsprechen folgenden Komplexitätsklassen:

Selection Sort	$O(N^2)$
Insertion Sort	$O(N^2)$
Quicksort	$O(N^2)$
Merge Sort	$O(N \log N)$
Heap Sort	$O(N \log N)$

- In der Praxis ist Quicksort (mit verfeinerten Pivotwahl) ein sehr effizienter und schneller allgemeiner Sortieralgorithmus.

# Abstrakte Datentypen

# Abstrakte Datentypen

- Ein **abstrakter Datentyp (ADT)** ist i.A. eine Menge von Elementen (bzw. Objekten) zusammen mit den Operationen, die für die Elemente der Menge charakteristisch sind.
- ADTs können unabhängig von ihrer konkreten Implementierung in verschiedenen Kontexten eingesetzt werden, einzig basierend auf einer wohldefinierten Schnittstelle.
- Java unterstützt abstrakte Datentypen durch das Interface-Konzept.
- Die Spezifikation der Operationen und der dabei verwendeten Datentypen ist durch die Signaturen der Methoden gegeben.
- Die Semantik kann entweder in einer formale Spezifikationsprache definiert oder zumindest informell durch Kommentare beschrieben werden.

# Abstrakter Datentyp: Liste

```
public interface IntList {  
  
    // Haengt ein Element an das Ende der Liste an  
    void add(int element);  
  
    // Liefert das Element an Position index  
    int get(int index);  
  
    // Entfernt das Element an Position index  
    // Liefert true im Erfolgsfall, sonst false  
    boolean remove(int index);  
  
    // Anzahl der Elemente  
    int size();  
}
```

Konkrete Implementierungen des ADTs sind z.B. einfachverkettete Listen, doppeltverkettete Listen, Array-Listen.

# Abstrakter Datentyp: Stapel (engl. *stack*)

- Basiert auf dem LIFO-Prinzip (*Last-in-First out*)
- Das Element, welches zuletzt eingefügt wurde, wird als erstes wieder entfernt.
- Anwendungsbeispiel: Verwaltung von Hyperlinks im Browser (Back-Button), verschachtelter Methodenaufruf



# Spezifikation: Stapel

```
public interface StackOfInt {  
  
    // Testet, ob der Stapel leer ist.  
    boolean empty();  
  
    // Legt Element oben auf den Stapel.  
    void push(int item);  
  
    // Gibt das oberste Element vom Stapel zurueck.  
    // Wirft eine EmptyStackException, falls der Stapel leer ist.  
    int peek() throws EmptyStackException;  
  
    // Gibt das oberste Element vom Stapel zurueck  
    // und entfernt es vom Stapel.  
    // Wirft eine EmptyStackException, falls der Stapel leer ist.  
    int pop() throws EmptyStackException;  
}
```

# Stack-Implementierung mit Arrays

```
public class ArrayStackOfInt implements StackOfInt {
    private int[] elems;
    private int n;

    public ArrayStackOfInt(int max) {
        this.elems = new int[max];
    }
    public boolean empty() {
        return n == 0;
    }
    public void push(int item) {
        elems[n] = item;
        n++;
    }
    public int peek() throws EmptyStackException {
        if (empty()) throw new EmptyStackException();
        return elems[n-1];
    }
    public int pop() {
        int result = this.peek();
        n--;
        return result;
    }
}
```

# Diskussion

- Laufzeitabschätzung: Wie viele Operationen benötigt man, um ein Element einzufügen bzw. zu löschen?
- Was sind die Nachteile dieser Implementierung?

# Stack-Implementierung mit einfach verketteten Listen

```
class Node {
    int item;
    Node next;
    Node(int item, Node next) { ... }
}

public class ListStackOfInt implements StackOfInt {
    private Node first;

    public ListStackOfInt() { }

    public boolean empty() {
        return (first == null);
    }

    public void push(int item) {
        Node n = new Node(item, first);
        first = n;
    }

    public int peek() throws EmptyStackException {
        // TODO
    }

    public int pop() throws EmptyStackException {
        // TODO
    }
}
```

# Warteschlange (engl. *queue*)

- Basiert auf dem FIFO-Prinzip (*First-in-First-out*)
- Anwendungsbeispiele: Musik-Playlists, Warteschlangen beim Einkaufen, Beantworten von Server-Anfragen, Druckaufträge
- Aspekt der Fairness!

# Spezifikation: Queue

```
public interface QueueOfInt {  
    // Fuegt ein Element hinten in die Warteschlange an.  
    void add(int e);  
  
    // Gibt das erste Element in der Warteschlange zurueck.  
    int element();  
  
    // Gibt das erste Element in der Warteschlange zurueck  
    // und entfernt es aus der Warteschlange.  
    int remove();  
  
    // Testet, ob die Warteschlange leer ist.  
    boolean empty();  
}
```

# Queue-Implementierung mit einfachverketteten Listen I

```
public class ListQueueOfInt implements QueueOfInt {
    private Node first;    // Element mit laengster Verweildauer
    private Node last;    // Neuestes Element

    // Testet, ob die Warteschlange leer ist.
    public boolean empty() {
        return (first == null);
    }

    // Fuegt ein Element hinten in die Warteschlange an.
    public void add(int e) {
        Node n = new Node(e,null);
        if (empty()) {
            first = n;
        } else {
            last.next = n;
        }
        last = n;
    }
}
```

# Queue-Implementierung mit einfachverketteten Listen II

```
// Fortsetzung...

// Gibt das erste Element in der Warteschlange zurueck.
public int element() {
    return first.elem;
}

// Gibt das erste Element in der Warteschlange zurueck
// und entfernt es aus der Warteschlange.
public int remove() {
    int result = first.elem;
    first = first.next;
    if (empty()) {
        last = null;
    }
    return result;
}
}
```



# Ausblick

- Und wenn ich eine Liste/Stack/Queue mit Strings, Students, beliebigen Objekten haben will?  
⇒ Parametrisierbare Datentypen in Java (Java Generics)
- Weitere Datentypen zum Verwalten von Objekt-Sammlungen: Java Collections