



# Kapitel 2 - Sortieren

## Elementare Sortierverfahren

SelectionSort

InsertionSort

BubbleSort

## Höhere Sortierverfahren

MergeSort

QuickSort

HeapSort

Untere und obere Schranken für das Sortierproblem

## Spezielle Sortierverfahren

CountingSort

# Voraussetzungen

- Für nachfolgende Betrachtungen sei jeweils eine Folge  $a[1], \dots, a[n]$  von Datensätzen gegeben.
- Jeder Datensatz  $a[i]$  besitzt eine Schlüsselkomponente  $a[i].key$
- Datensätze enthalten außer der Schlüsselkomponente in der Regel weitere Informationseinheiten (z.B. Name, Adresse, PLZ, etc.).
- Sortierung erfolgt **ausschließlich** nach der Schlüsselkomponente  $key$ .
- Für Sortierung muss auf der Menge aller Schlüssel eine totale Ordnung definiert sein.

# Totale/lineare Ordnung

Sei  $M$  eine nicht leere Menge und " $\leq$ "  $\subseteq M \times M$  eine binäre Relation auf  $M$ .

Das Paar  $(M, \leq)$  heißt eine *totale (bzw. lineare) Ordnung auf  $M$* , genau dann wenn " $\leq$ " die folgenden Eigenschaften erfüllt:

**reflexiv:**  $\forall x \in M: x \leq x$

**transitiv:**  $\forall x, y, z \in M: x \leq y \wedge y \leq z \Rightarrow x \leq z$

**antisymmetrisch:**  $\forall x, y \in M: x \leq y \wedge y \leq x \Rightarrow x = y$

**total / linear:**  $\forall x, y \in M: x \leq y \vee y \leq x$

# Beispiel: Totale Ordnung

1. Bsp.:  $\leq$  auf den natürlichen Zahlen bildet eine **totale Ordnung**.
2. Bsp.: Die *lexikographische Ordnung*  $\leq_{lex}$  ist eine **totale Ordnung**.  
 Sei  $\leq$  die totale Ordnung auf den Buchstaben  $A < B < C < \dots < Y < Z$   
 Für zwei endliche Wörter  $u = u_1 u_2 \dots u_m$  und  $v = v_1 v_2 \dots v_n$  mit  $u_i, v_j \in \{A, B, C, \dots, Z\}$  gilt  $u \leq_{lex} v$  gdw.

$$(u \text{ leer}) \vee (u, v \text{ nicht-leer} \wedge (u_1 < v_1 \vee (u_1 = v_1 \wedge u_2 \dots u_m \leq_{lex} v_2 \dots v_n)))$$

Beispiel:  $FLO \leq_{lex} FLORIAN \leq_{lex} PAUL \leq_{lex} PETER$

3. Bsp. (keine totale Ordnung): Teilmengenrelation  $\subseteq$  auf Potenzmenge von  $\mathbb{N}$   
 Beweis:  $\subseteq$  ist nicht total, da weder  $\{1\} \subseteq \{2\}$  noch  $\{2\} \subseteq \{1\}$  gilt.

# Sortierproblem

- Gegeben sei eine Folge  $a[1], \dots, a[n]$  von Datensätzen mit einer Schlüsselkomponente  $a[i].\text{key}$  ( $i = 1, \dots, n$ ) und eine totale Ordnung  $\leq$  auf der Menge aller Schlüssel.
- Das **Sortierproblem** besteht darin, eine *Permutation*  $\pi$  der ursprünglichen Folge zu bestimmen, so dass gilt:

$$a[\pi_1].\text{key} \leq a[\pi_2].\text{key} \leq \dots \leq a[\pi_{n-1}].\text{key} \leq a[\pi_n].\text{key}$$

# Beispiel

---

Liste	Schlüsselement	Ordnung
Telefonbuch	Nachname	lexikographische Ordnung
Klausurergebnisse	Punktezahl	$\leq$ auf rationalen Zahlen
Lexikon	Stichwort	lexikographische Ordnung
Studentenverzeichnis	Matrikelnummer	$\leq$ auf $\mathbb{N}$
Entfernungstabelle	Distanz	$\leq$ auf $\mathbb{R}$
Fahrplan	Abfahrtszeit	„früher als“

---

# Unterscheidungskriterien

Sortieralgorithmen können nach verschiedenen Kriterien klassifiziert werden:

- **Berechnungsaufwand**
  - $O(n^2)$ ,  $O(n \log n)$ ,  $O(n)$
- **Worst Case vs. Average Case**
  - Ausnutzen von Vorsortierungen
- **Speicherbedarf**
  - In-place / in situ
  - Kopieren
- **stabil** (Reihenfolge von Records mit gleichem Schlüssel bleibt erhalten) oder nicht

# Weitere Aufgaben

Viele Aufgaben sind mit dem Sortieren verwandt und können auf das Sortierproblem zurückgeführt werden:

- **Bestimmung des Median** (der Median ist definiert als das Element an der mittleren Position der sortierten Folge)
- **Bestimmung der k kleinsten bzw. größten Elemente**

# Typen von Sortieralgorithmen

## Einfache

SelectionSort, InsertionSort, BubbleSort, ...

## Höhere

MergeSort, QuickSort, HeapSort, ...

## Spezielle

BucketSort, ...

# Swap

Im Folgenden wird häufiger der Aufruf `swap(a, i, j)` verwendet, wobei `a` ein Array ist und `i, j` int-Werte.

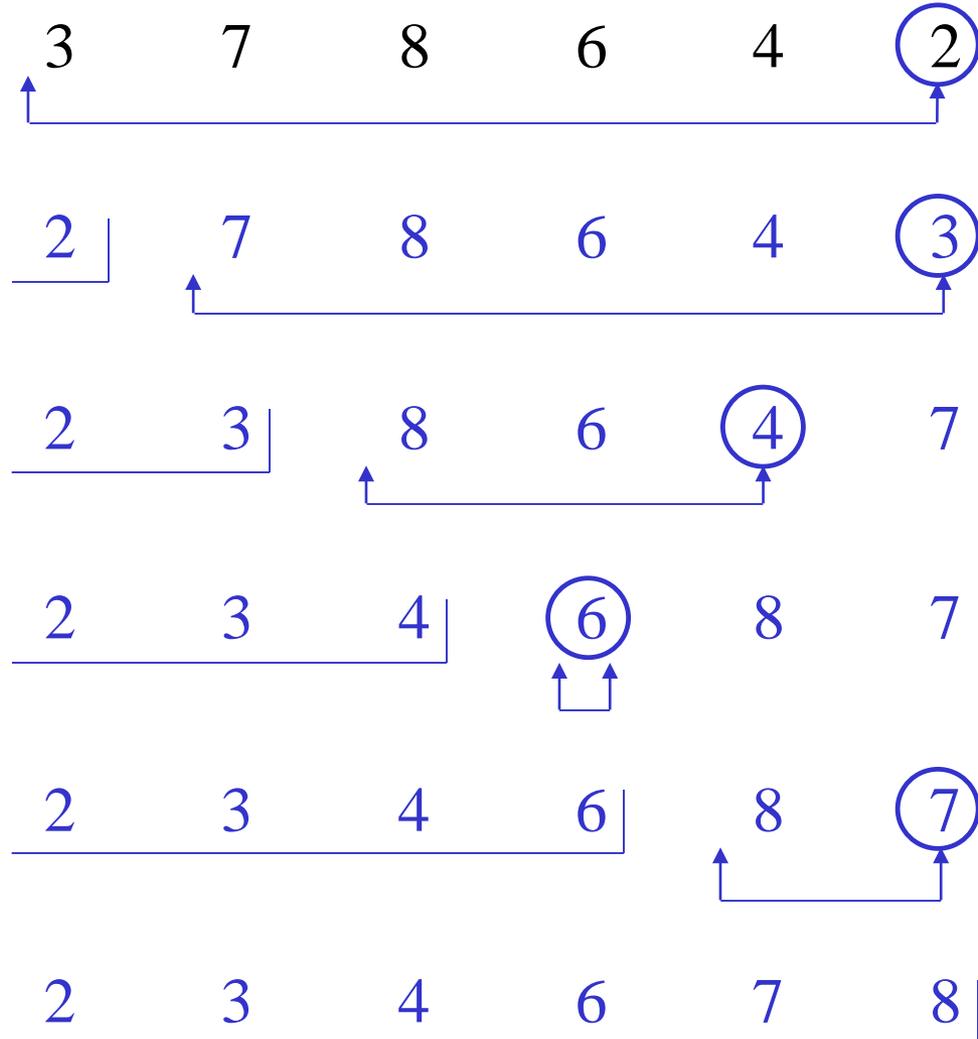
Der Aufruf ersetzt folgende drei Zuweisungen:

```
(int) h = a[i];  
a[i] = a[j];  
a[j] = h;
```

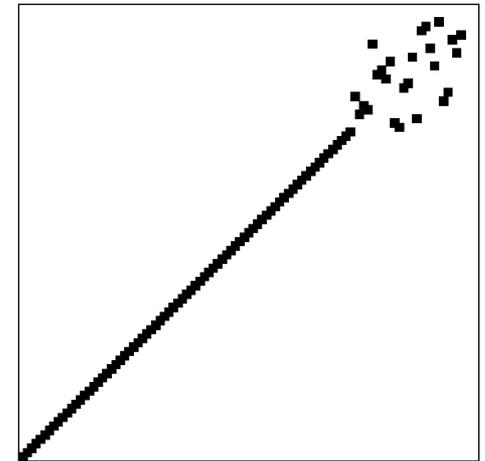
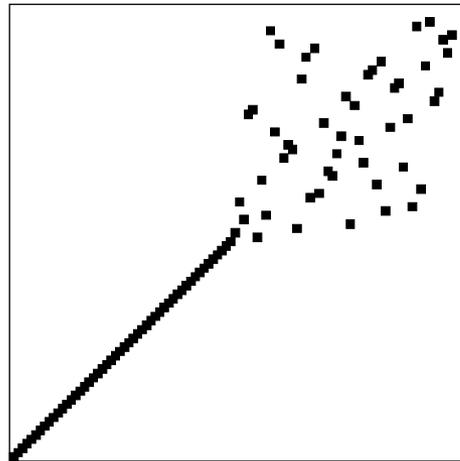
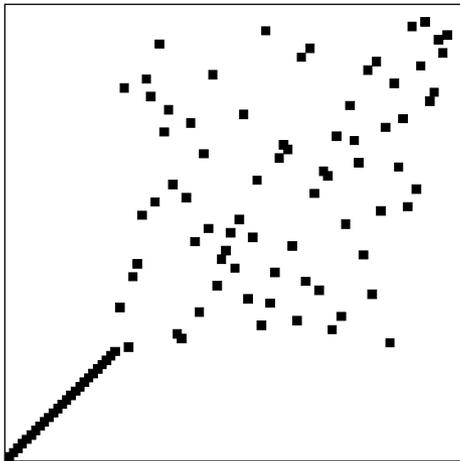
# SelectionSort: Prinzip

1. Suche kleinstes Element
2. Vertausche es mit dem Schlüssel an der ersten Stelle
3. Wende denselben Algorithmus auf die restlichen  $(n - 1)$  Elemente an

# SelectionSort: Beispiel



# SelectionSort: Visualisierung



# SelectionSort: Implementierung

```
static void selectionSort (int[] a) {  
    for (int i = 1; i <= a.length-1; ++i) {  
  
        int min = i;  
        for (int j = i+1; j <= a.length ; ++j) {  
            if (a[j] < a[min]) min = j;  
        }  
  
        swap(a, i, min);  
    }  
}
```

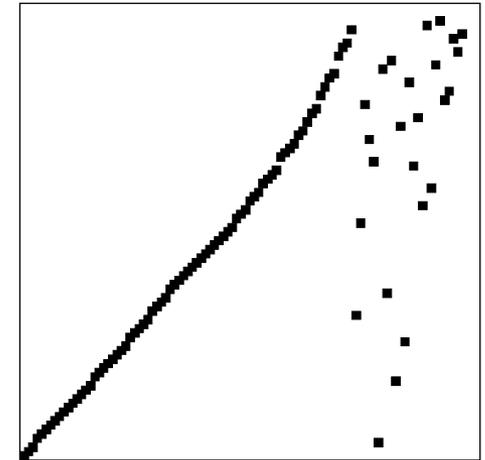
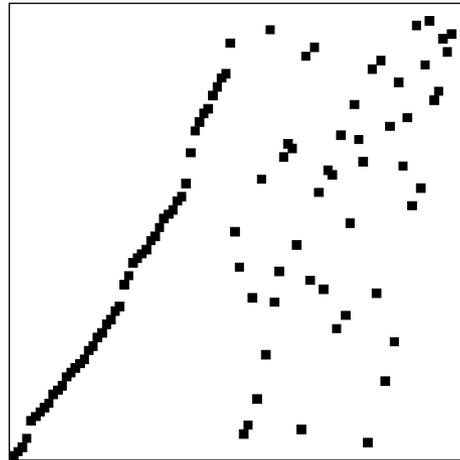
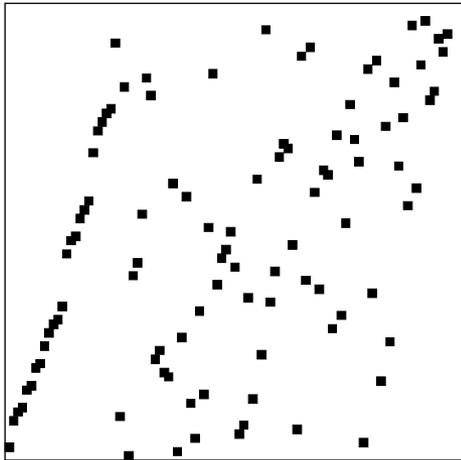
# SelectionSort: Komplexitätsanalyse

- Zum Sortieren der gesamten Folge  $a[1], \dots, a[n]$  werden  $n - 1$  Durchläufe benötigt.
- Pro Schleifendurchgang  $i$  gibt es eine Vertauschung, die sich aus je einer Ausführung von swap und  $n - i$  Vergleichen zusammensetzt, wobei  $n-i$  die Anzahl der noch nicht sortierten Elemente ist.
- Insgesamt ergeben sich im best, worst und average case:
  - $(n - 1)$  swaps und  $\in O(n)$
  - $(n - 1) + (n - 2) + \dots + 2 + 1 = \frac{n \cdot (n-1)}{2}$  Vergleiche  $\in O(n^2)$
  - Durch spezielle if-Abfrage ( $\text{min} == i$ ) kann Anzahl der swaps verringert werden (best case: 0 swaps); dann jedoch mehr Vergleiche notwendig
- Anzahl der Vertauschungen wächst nur linear in der Anzahl der Datensätze
  - ⇒ SelectionSort besonders für Sortieraufgaben geeignet, in denen die einzelnen Datensätze sehr groß sind

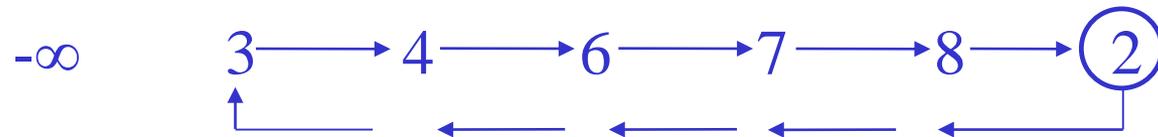
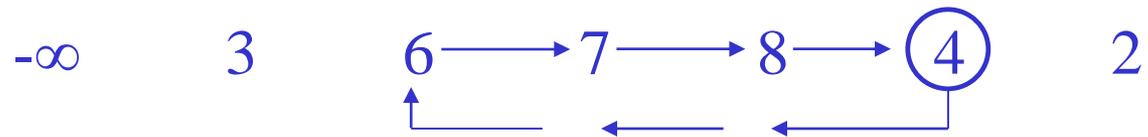
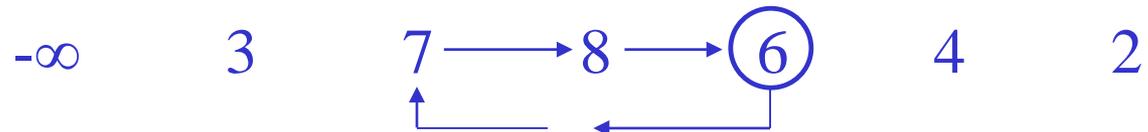
# InsertionSort: Prinzip

- nehme **sortierte** Teilfolge  $a[1], \dots, a[i-1]$  an (beginne mit  $i = 2$ )
  - füge nächsten Datensatz  $a[i]$  an korrekte Position der Teilfolge ein
- erhalte **sortierte** Teilfolge  $a[1], \dots, a[i]$
- für vollständige Sortierung  $n - 1$  Schritte ( $i = 2, \dots, n$ ) durchführen

# InsertionSort: Visualisierung



# InsertionSort: Beispiel



# InsertionSort: Implementierung

```
static void insertionSort (int[] a) {  
  
    for (int i = 2; i <= a.length; ++i) {  
        int v = a[i];  
        int j = i;  
        while ((a[j-1] > v) && (j >= 2)) {  
            a[j] = a[j-1];  
            j--;  
        }  
        a[j] = v;  
    }  
}
```

# InsertionSort: Variante zur Implementierung

- **Variante**

Verwende **Sentinel**, um in der while-Schleife eine zusätzliche Abfrage auf die linke Feldgrenze zu vermeiden (Sentinel-Element entspricht Warter; Anfangs- oder Endmarkierung)

- Aufruf wie folgt:

$a[0] := -\infty$

dann: Array um 1 verlangern; der Inhalt liegt dann in  $a[1], \dots, a[n]$

# InsertionSort: Komplexitätsanalyse

## Vergleiche

- Einfügen des Elements  $a[i]$  in die bereits sortierte Anfangsfolge  $a[1], \dots, a[i-1]$  erfordert **mindestens einen Vergleich** und **höchstens  $i$  Vergleiche**.
- Im Mittel:  $i/2$  Vergleiche, denn bei zufälliger Verteilung der Schlüssel ist die Hälfte der bereits eingefügten Elemente größer als das Element  $a[i]$ .
- Best Case  
Bei vollständig vorsortierten Folgen ergeben sich  $n - 1$  Vergleiche.
- Worst Case  
Bei umgekehrt sortierten Folgen gilt für die Anzahl der Vergleiche:

$$\sum_{i=2}^n i = \left( \sum_{i=1}^n i \right) - 1 = \frac{n(n+1)}{2} - 1 = \frac{n^2}{2} + \frac{n}{2} - 1$$

- Average Case: Die Anzahl der Vergleiche ist etwa  $\frac{n^2}{4}$

# InsertionSort: Komplexitätsanalyse

## Bewegungen

- Best Case

Bei vollständig vorsortierten Folgen  $2 \cdot (n - 1)$  Bewegungen

- Zuweisungen  $v = a[i]$  und  $a[j] = v$  in jedem Schritt notwendig
- durch zusätzliche if-Abfragen verbesserbar, dann jedoch mehr Vergleiche

- Worst Case

Bei umgekehrt sortierten Folgen  $\frac{n^2}{2}$  Bewegungen

- Average Case

$\sim \frac{n^2}{4}$  Bewegungen

# BubbleSort: Prinzip

- Grundidee ähnlich zu SelectionSort
- beim Vergleichen (zum Finden des Minimums bei SelectionSort) die Objekte direkt paarweise korrekt anordnen

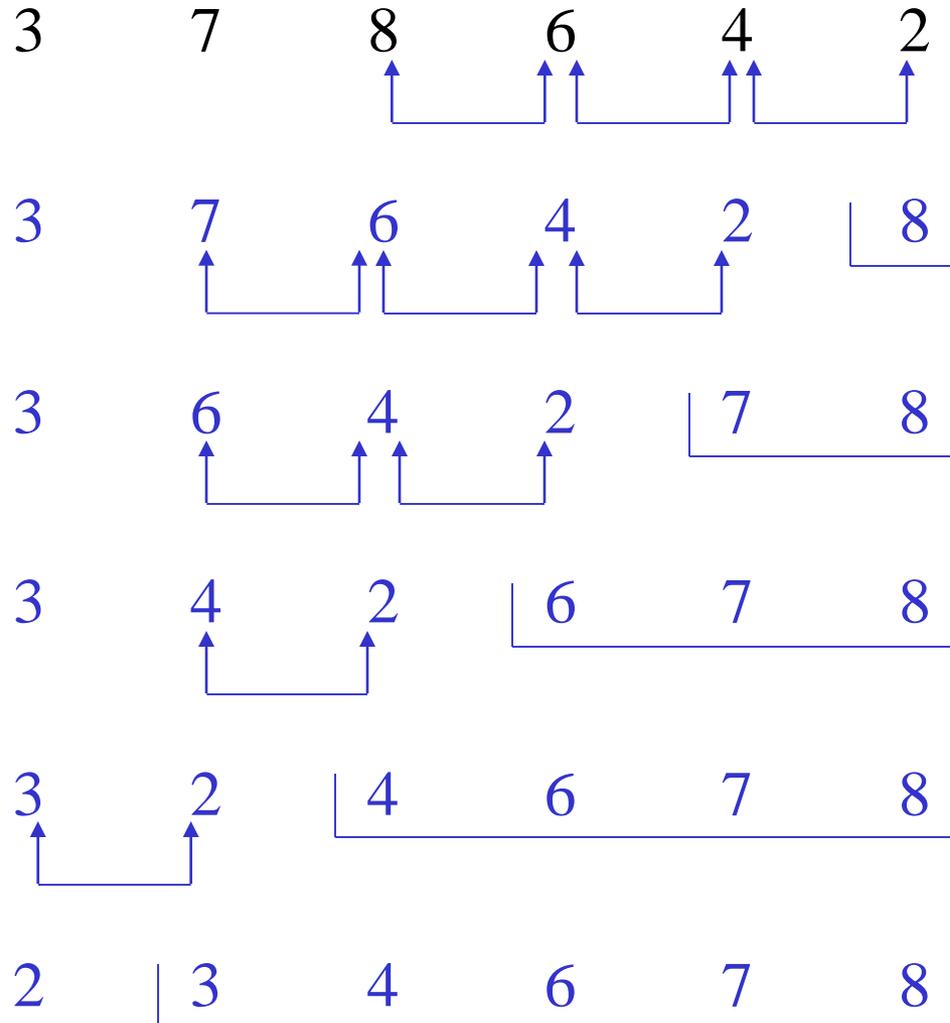
→ Nachziehen von Objekten; Aufsteigen von Blasen

- $n - 1$  Schritte,  $i = n, n - 1, \dots, 2$  ( $i$  herunterzählen)
- Für jeden dieser Schritte:

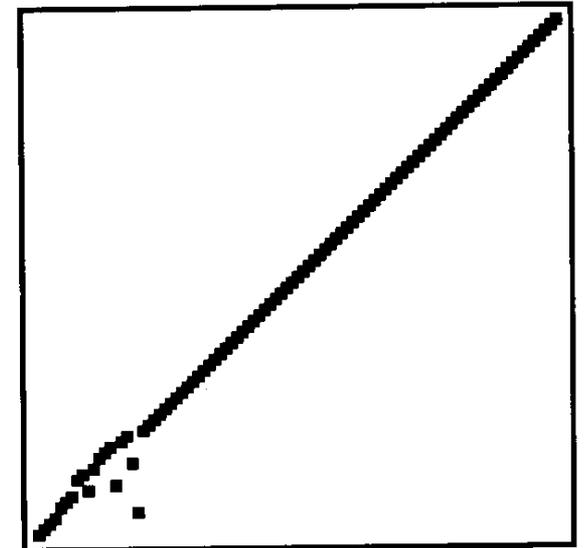
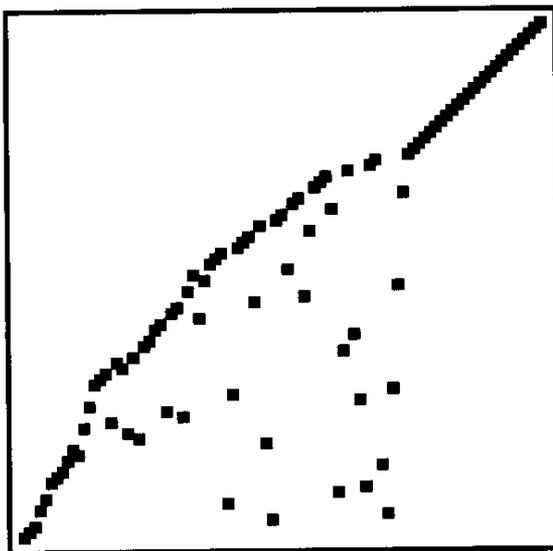
$i - 1$  Schritte,  $j = 2, \dots, i$

ordne  $a[j-1]$  und  $a[j]$

# BubbleSort: Beispiel



# BubbleSort: Visualisierung



# BubbleSort: Komplexitätsanalyse

## Vergleiche

- Anzahl der Vergleiche ist unabhängig vom Vorsortierungsgrad der Folge
  - ⇒ worst case, average case und best case sind identisch (es werden stets alle Elemente der noch nicht sortierten Teilfolge miteinander verglichen)
- Im  $i$ -ten Schleifendurchgang enthält die noch unsortierte Anfangsfolge  $n - i + 1$  Elemente
  - für diese werden  $n - i$  Vergleiche benötigt
- Um ganze Folge zu sortieren, sind  $n - 1$  Schritte erforderlich
- Gesamtzahl der Vergleiche wächst damit quadratisch in der Anzahl der Schlüsselemente:

$$\sum_{i=1}^{n-1} (n - i) = \sum_{i=1}^{n-1} i = \frac{n \cdot (n - 1)}{2} \in O(n^2)$$

# BubbleSort: Komplexitätsanalyse

## Bewegungen/Swaps

Aus der Analyse der Bewegungen für den gesamten Durchlauf ergeben sich:

- Best Case  
0 Swaps
- Worst Case  
 $\sim n^2 / 2$  Swaps
- Average Case  
 $\sim n^2 / 4$  Bewegungen



# Kapitel 2 - Sortieren

## Elementare Sortierverfahren

SelectionSort

InsertionSort

BubbleSort

## Höhere Sortierverfahren

MergeSort

QuickSort

HeapSort

Untere und obere Schranken für das Sortierproblem

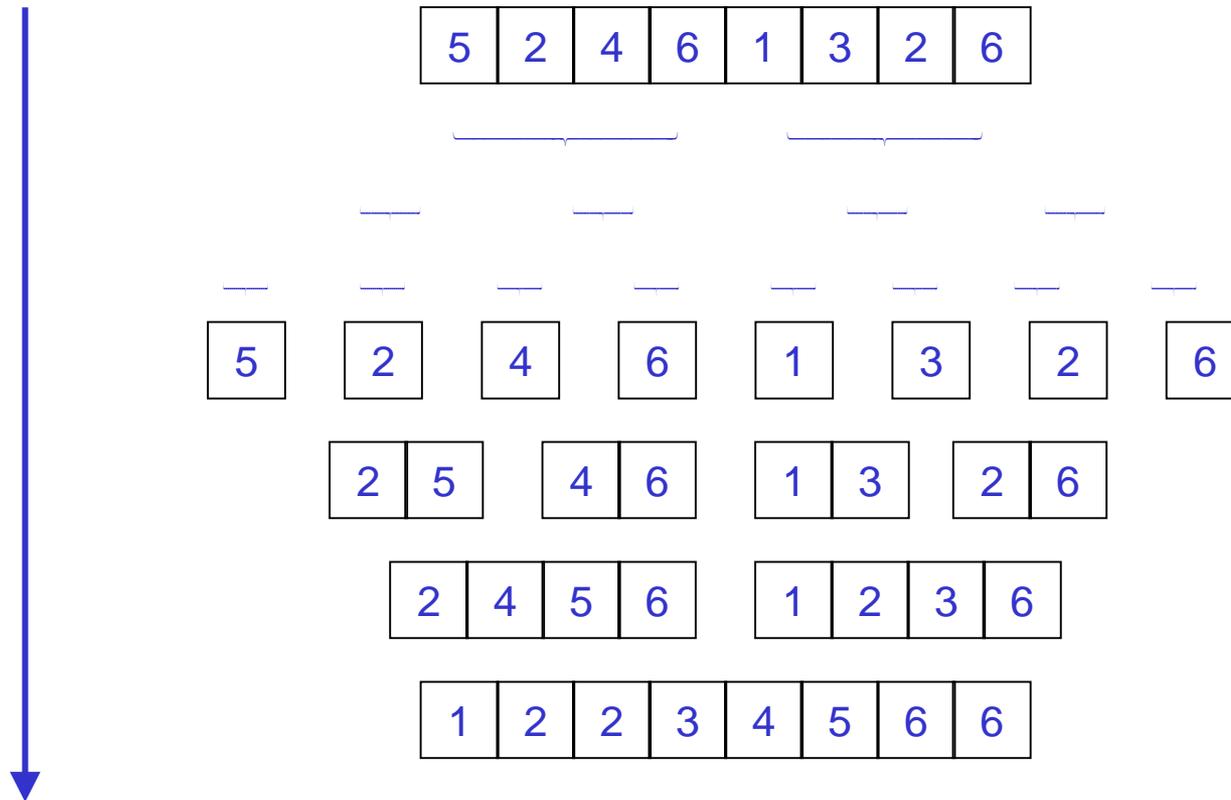
## Spezielle Sortierverfahren

CountingSort

# Höhere Sortierverfahren

- Bislang alle Algorithmen  $O(n^2)$  Vergleiche und/oder Bewegungen
- Geht es auch besser?
- Prinzip von MergeSort  
Gegeben sei eine Folge  $F = a[1] \dots a[n]$  von Schlüsselementen.
  1. **Divide:** Zerlege  $F$  in zwei etwa gleichlange Folgen  $F_1 = a[1] \dots a[\lceil n/2 \rceil]$  und  $F_2 = a[\lceil n/2 \rceil + 1] \dots a[n]$ .
  2. **Conquer:** Sortiere  $F_1$  und  $F_2$  mittels MergeSort, falls  $|F_1| > 1$  bzw.  $|F_2| > 1$ .
  3. **Merge:** Verschmelze sortierte Teilfolgen  $F_1$  und  $F_2$  zu sortierter Gesamtfolge

# MergeSort: Beispiel



# MergeSort: Implementierung

```
MergeSort(Array, left, right){  
    if (left < right) {  
        middle = ⌊(left + right)/2⌋;  
        MergeSort(Array, left, middle);  
        MergeSort(Array, middle+1, right);  
        Merge(Array, left, middle, right);  
    }  
}
```

- Schnittstelle für die Benutzung:

```
MergeSort (Array a) {  
    MergeSort(a, 0, a.length - 1);  
}
```

# Merge

```
Merge (Array, left, middle, right) {  
    int[ ] B = new int[right – left + 1];  
    int i = 0, j = left, k = middle+1;  
  
    while ((j <= middle) and (k <= right)){  
        if (Array[j] <= Array[k]) { B[i++] = Array[j++]; }  
        else { B[i++] = Array[k++]; }  
    } /* j > middle or k > right */  
  
    while (j <= middle) { B[i++] = Array[j++]; }  
    while (k <= right) { B[i++] = Array[k++]; }  
    for (i = left; i <= right; ++i) { Array[i] = B[i-left]; }  
}
```

# Paradigma: Divide-and-Conquer

- Divide-and-Conquer (Teile-und-Herrsche, Divide-et-impera)
  - Ansatz: Zerlegung von Problemen in Teilprobleme
  - Resultiert üblicherweise in rekursiven Algorithmen
- **Divide**: Zerlege das Problem in Teilprobleme
  - bis „elementar“: z.B. Liste mit nur einer Zahl
- **Conquer**: Rekursives Lösen (Beherrschen) der Teilprobleme
- **Merge**: Setze Teillösungen zusammen zur Gesamtlösung
- Top-Down-Verfahren
  - Im Gegensatz zu Bottom-Up (Bsp. dynamische Programmierung)

# MergeSort: Komplexitätsanalyse

Erster Ansatz: Bestimmung der Laufzeit mit Hilfe des Master-Theorems

Um das Master-Theorem anwenden zu können, ist es notwendig, die Laufzeit durch eine entsprechende Rekursionsformel zu beschreiben.

Sei  $T(n)$  die Anzahl der Operationen (im wesentlichen Vergleiche). Dann gilt:

$$T(n) = \begin{cases} c_1 & \text{für } n = 1 \\ 2 \cdot T\left(\frac{n}{2}\right) + c_2 \cdot n & \text{für } n > 1 \end{cases}$$

für entsprechende Konstanten  $c_1, c_2 > 0$ . Dabei charakterisiert

- $c_1$  den Aufwand für die Lösung des trivialen Problems ( $n = 1$ ) und
- $n \cdot c_2$  denjenigen für des Verschmelzen zweier Listen.

Mit Hilfe des Master-Theorems erhalten wir:

$$T(n) \in O(n \log n)$$

# MergeSort: Komplexitätsanalyse

Sei  $T(n)$  die Anzahl der Vergleiche. Die Folge wird in zwei Teilfolgen aufgeteilt:

Eine Teilfolge mit  $\lfloor \frac{n}{2} \rfloor$  Elementen und eine mit  $\lceil \frac{n}{2} \rceil$  Elementen.

Zur Verschmelzung werden  $\lfloor \frac{n}{2} \rfloor + \lceil \frac{n}{2} \rceil - 1 = n - 1$  Vergleiche benötigt.

Daher ergibt sich folgende Rekursionsgleichung:

$$T(n) = \begin{cases} 0 & \text{für } n = 1 \\ n - 1 + T\left(\lfloor \frac{n}{2} \rfloor\right) + T\left(\lceil \frac{n}{2} \rceil\right) & \text{für } n > 1 \end{cases}$$

# MergeSort: Komplexitätsanalyse

## Behauptung:

$$T(n) = n \cdot \lceil \lg(n) \rceil - 2^{\lceil \lg(n) \rceil} + 1$$

## Beweis:

Die Rekursion wird verifiziert mittels vollständiger Induktion.

Induktionsanfang:  $n = 1$  ... offensichtlich korrekt

Induktionsvoraussetzung: Die Behauptung gelte für alle natürlichen Zahlen  $m$  mit  $1 \leq m < n$ .

Induktionsschluss: ...

# MergeSort: Komplexitätsanalyse

Fall 1:  $n \neq 2^k + 1$

Dann gilt  $\lceil \lg \lceil n/2 \rceil \rceil = \lceil \lg \lfloor n/2 \rfloor \rceil = \lceil \lg(n) \rceil - 1$ , und daher

$$T(n) = n - 1 + \left\lceil \frac{n}{2} \right\rceil \cdot \left\lceil \lg \left\lceil \frac{n}{2} \right\rceil \right\rceil - 2^{\left\lceil \lg \left\lceil \frac{n}{2} \right\rceil \right\rceil} + 1$$

$$+ \left\lfloor \frac{n}{2} \right\rfloor \cdot \left\lceil \lg \left\lfloor \frac{n}{2} \right\rfloor \right\rceil - 2^{\left\lceil \lg \left\lfloor \frac{n}{2} \right\rfloor \right\rceil} + 1$$

$$= n + n(\lceil \lg(n) - 1 \rceil) - 2^{\lceil \lg(n) \rceil} + 1$$

$$= n \cdot \lceil \lg(n) \rceil - 2^{\lceil \lg(n) \rceil} + 1$$

# MergeSort: Komplexitätsanalyse

Fall 2:  $n = 2^k + 1$

Dann gilt  $\lfloor n/2 \rfloor = \lceil \lfloor n/2 \rceil \rceil = \lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 1 = \lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 2$ , und daher

$$\begin{aligned} T(n) &= n - 1 + \left\lfloor \frac{n}{2} \right\rfloor \cdot (\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 1) - 2^{\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 1} + 1 \\ &\quad + \left\lfloor \frac{n}{2} \right\rfloor \cdot (\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 2) - 2^{\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 2} + 1 \\ &= n \cdot (\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil) - \left\lfloor \frac{n}{2} \right\rfloor - 2^{\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 1} - 2^{\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 2} + 1 \\ &= n \cdot \lceil \lfloor \lceil n/2 \rceil \rfloor \rceil - 2^{\lceil \lfloor \lceil n/2 \rceil \rfloor \rceil} + 1 \end{aligned}$$

# QuickSort: Prinzip

Gegeben sei eine Folge  $F$  von Schlüsselementen.

1. **Divide:** Zerlege  $F$  bzgl. eines partitionierenden Elementes (Pivotelement)  $p \in F$  in zwei Teilfolgen  $F_1$  und  $F_2$ , so daß gilt:

$$\begin{aligned}x_1 \leq p & \quad \forall x_1 \in F_1 \\p \leq x_2 & \quad \forall x_2 \in F_2\end{aligned}$$

2. **Conquer:** Sortiere  $F_1$  und  $F_2$  durch rekursiven Aufruf und erhalte dadurch die sortierten Folgen  $F_1^S$  und  $F_2^S$
3. **Merge:** Setze Teilfolgen zusammen:  $F_1^S \circ p \circ F_2^S$

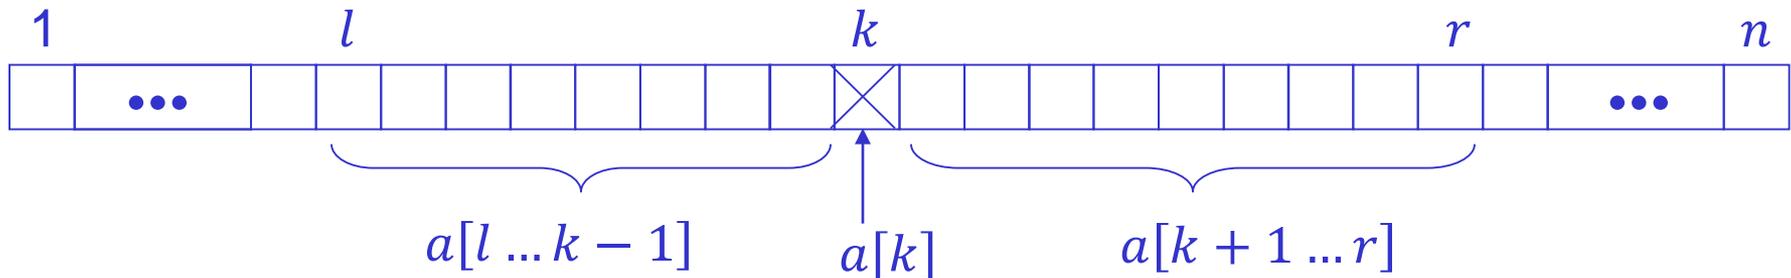
# Ankündigungen

- Übungsabgabe
  - Programmcode als **.java** abgeben (nicht als .jpg oder .pdf -- Bewertbarkeit ist sonst nicht gewährleistet)
- Übungsgruppen
  - Übungen Mo + Do 14-16 und 16-18 in Amalienstraße überlastet
  - Parallele Übungen in Freimann leer (Edmund-Rumpler-Str. 9)
  - U6 bis Freimann (9 Minuten ab Universität), dann wenige Minuten zu Fuß
- Klausurtermin
  - Di 8.8. 17-20h im Hauptgebäude

# QuickSort: Erklärung der Idee

## Ziel:

Zerlegung (Partitionierung) des (Teil-)Arrays  $a[l \dots r]$  bzgl. eines *Pivot-Elementes*  $a[k]$  in zwei Teilarrays  $a[l \dots k - 1]$  und  $a[k + 1 \dots r]$ .



so dass gilt:

$$\forall i \in \{l, \dots, k - 1\}: a[i] \leq a[k]$$

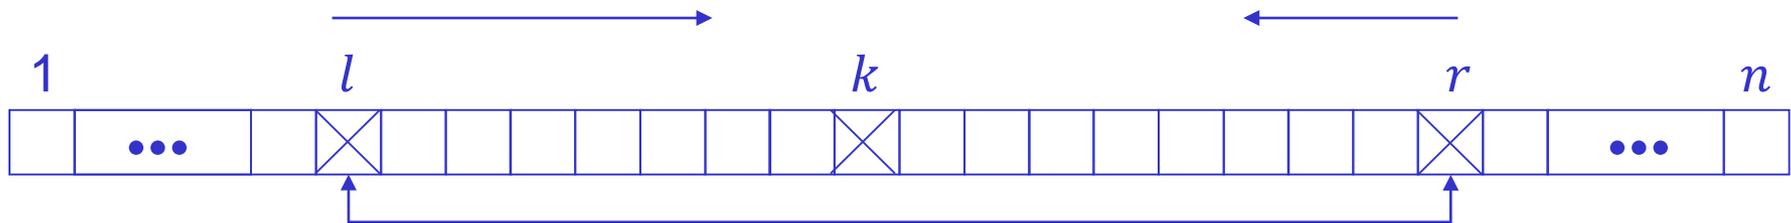
$$\forall i \in \{k + 1, \dots, r\}: a[k] \leq a[i]$$

# QuickSort: Erklärung der Idee

## Methode:

Laufe mit zwei Indizes gegenläufig von  $l$  bzw.  $r$  zur Mitte

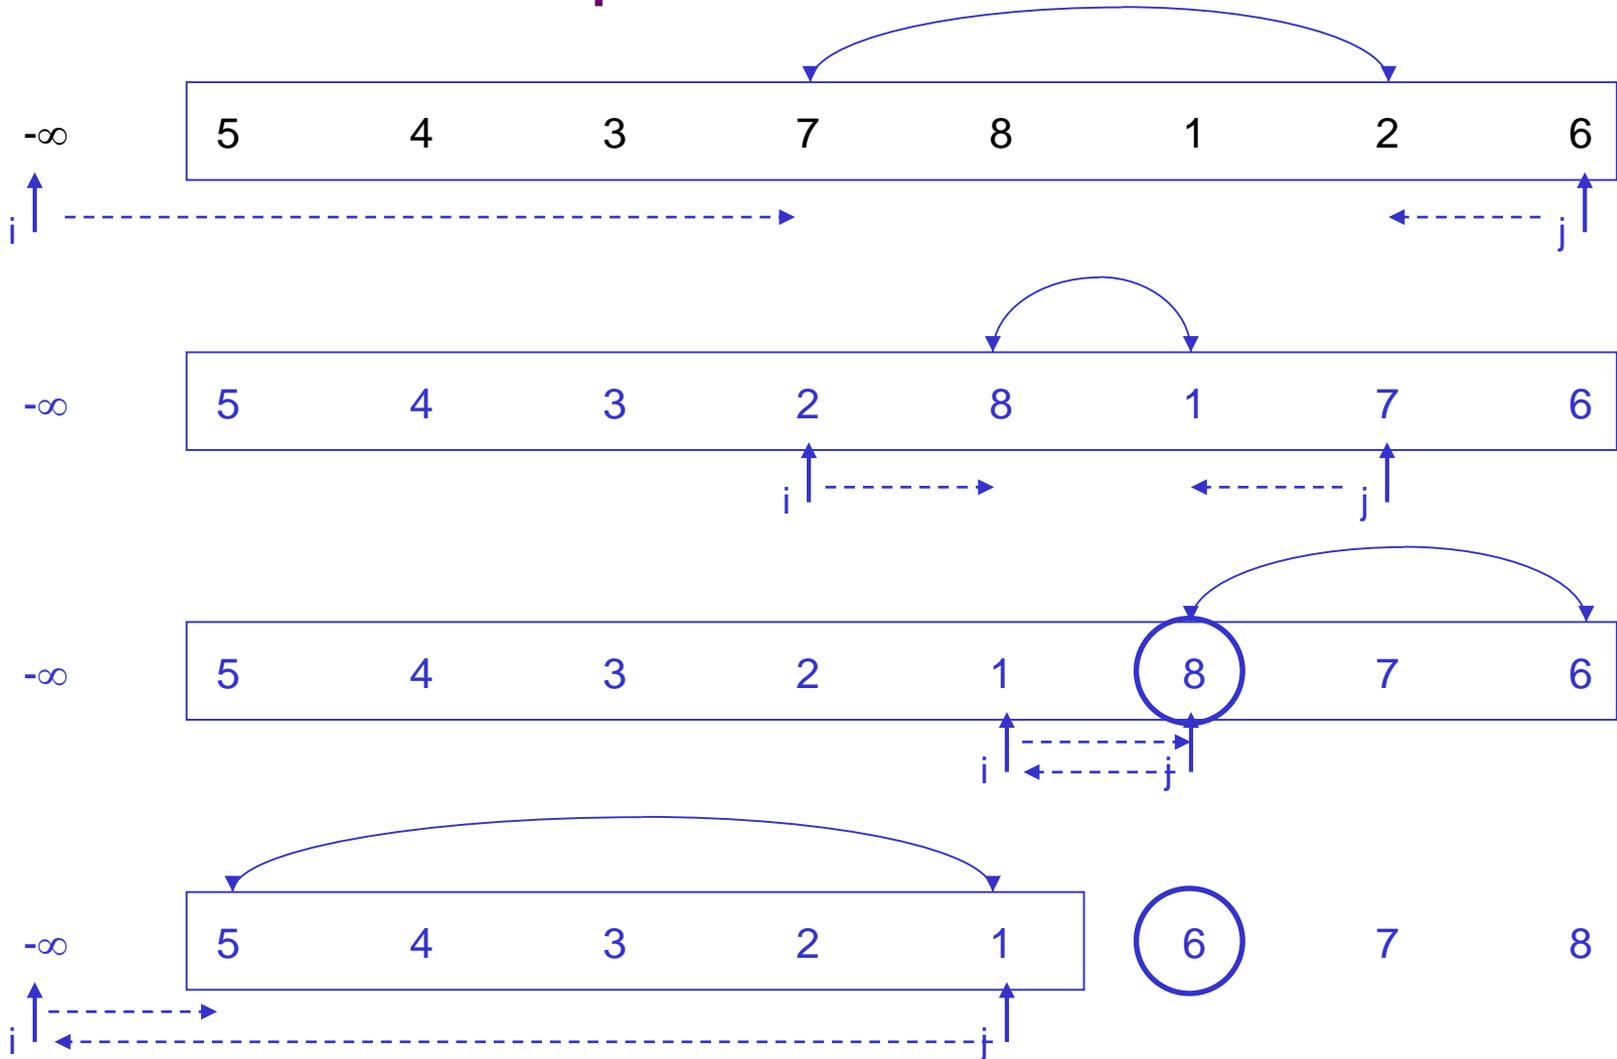
Tausche gegebenenfalls Schlüssel zwischen den Teilarrays aus



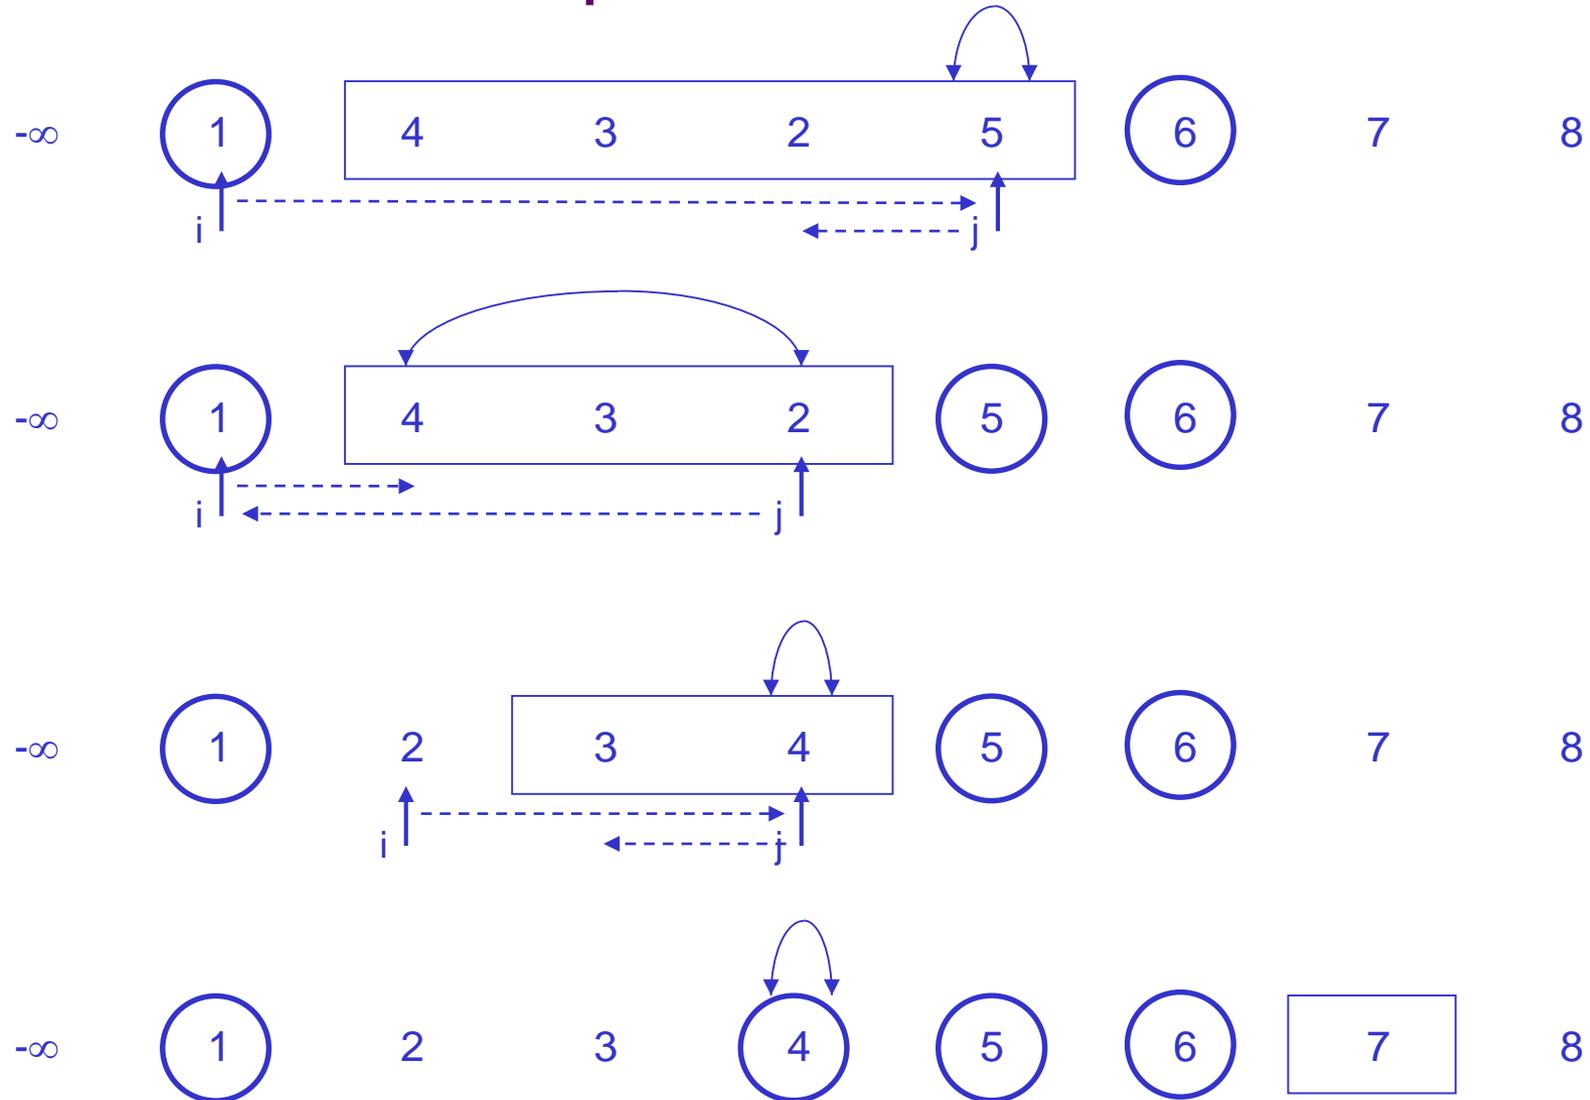
## Rekursion:

linkes Teilarray  $a[l \dots k - 1]$  und rechtes Teilarray  $a[k + 1 \dots r]$  bearbeiten

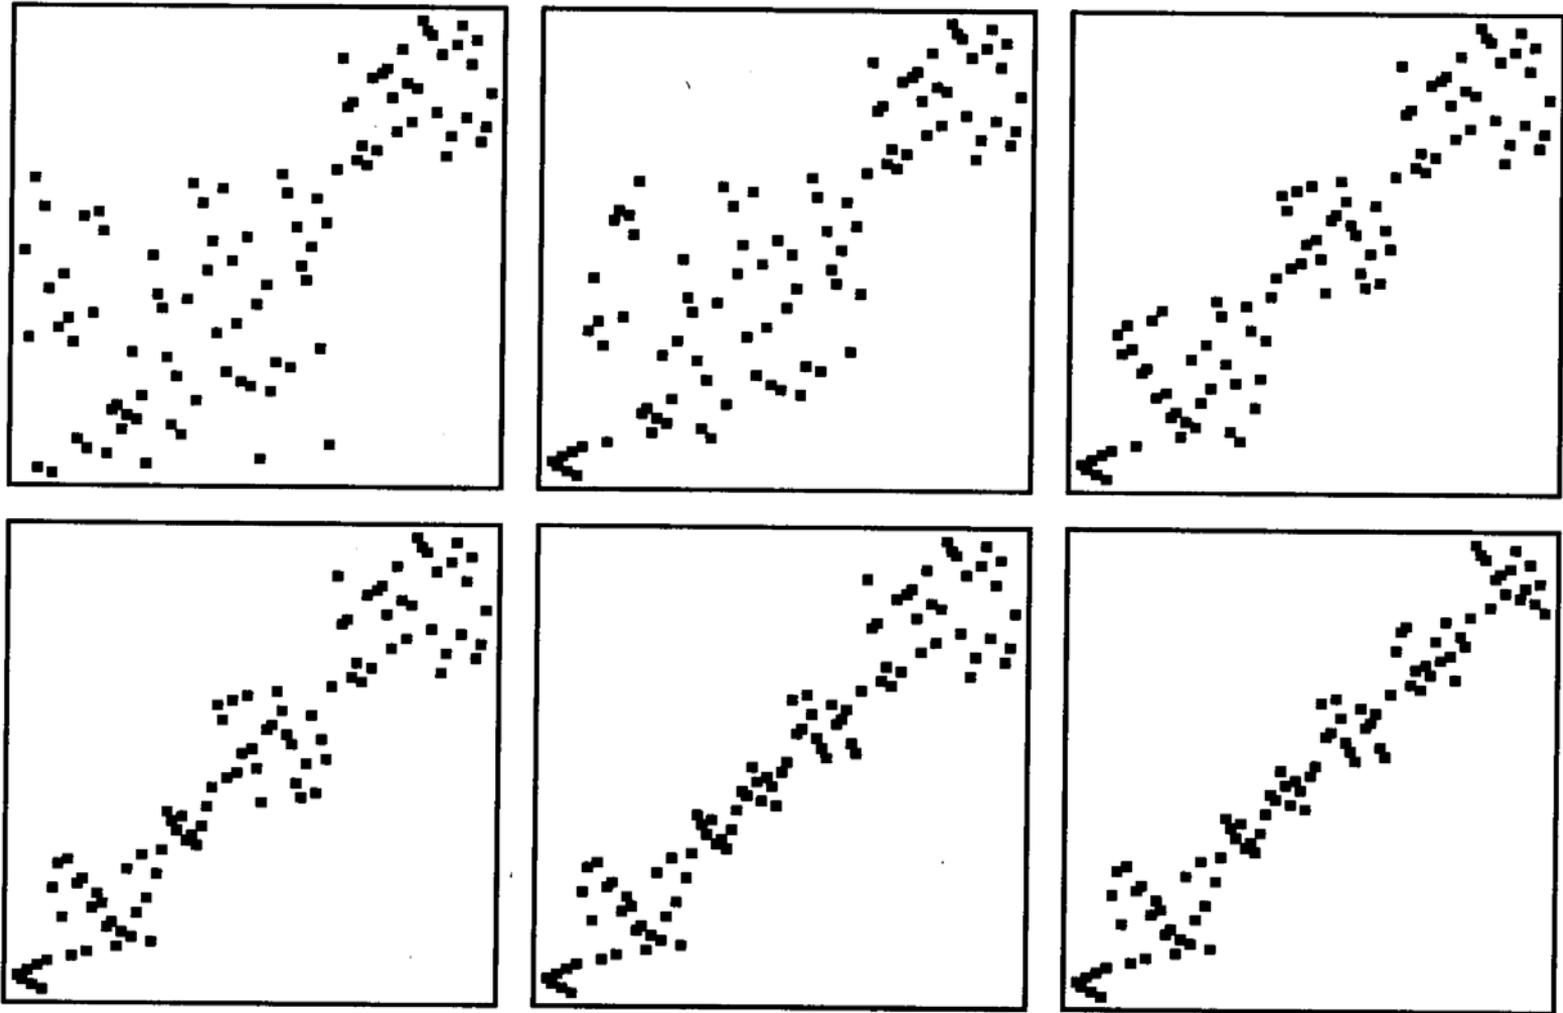
# QuickSort: Beispiel



# QuickSort: Beispiel



# QuickSort: Visualisierung



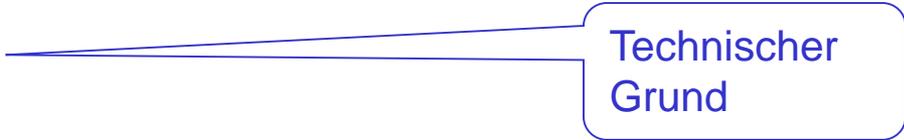
# QuickSort: Implementierung

```
static void quickSort (int[] a, int l, int r) {  
    if (l < r) {  
        int m = partition(a, l, r);  
        quickSort(a, l, m-1);  
        quickSort(a, m+1, r);  
    }  
}
```

Aufruf mit: `quickSort(a, 1, n);`

# QuickSort: Implementierung

```
static int partition (int[] a, int l, int r){  
    int i = l-1;  
    int j = r;  
    while (i < j) {  
        i++; while (a[i] < a[ r ]) {++i;}  
        j--; while (a[ j ] > a[ r ]) {--j;}  
        swap(a, i, j);  
    }  
    swap(a, i, j);  
    swap(a, i, r);  
  
    return i;  
}
```



Technischer Grund

# QuickSort: Implementierung

- **Achtung:**

Verwende **Sentinel**, um korrekte Terminierung der inneren Schleife zu garantieren.

- Aufruf mit:

```
a[0] := -∞  
QuickSort(a, 1, n);
```

- while (a[ i ] < a[ r ]) i++;

Bricht  
spätestens  
für j = r ab.

- while (a[ j ] > a[ r ]) j--;

Bricht  
spätestens  
für j = l-1 ab.

# QuickSort: Komplexitätsanalyse

**Best Case:** Folge zerfällt immer in zwei gleich große Teile

$$T(n) = 2 \cdot T\left(\frac{n}{2}\right) + O(n) \in O(n \log n)$$

**Worst Case:** Nur jeweils ein Element wird abgespalten. Bei Pivotwahl vorne oder hinten:  
falls die Folge bereits auf- oder absteigend sortiert ist:

$$T(n) = T(n - 1) + O(n) \in O(n^2)$$

**Average Case:**

$$T(n) \in O(n \log n)$$

Bei der Analyse fließen folgende Annahmen ein:

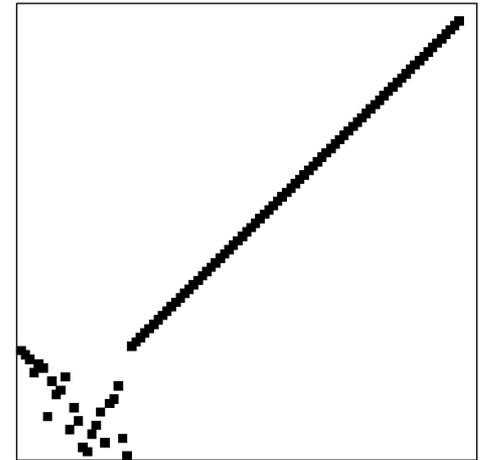
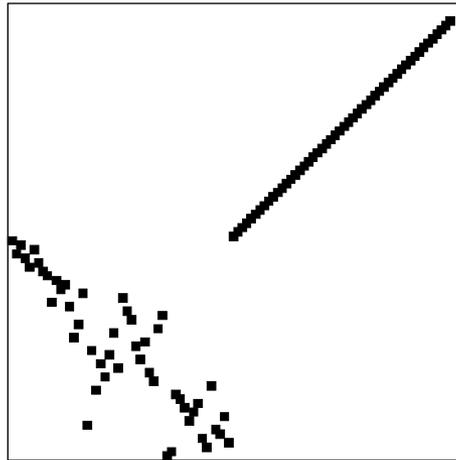
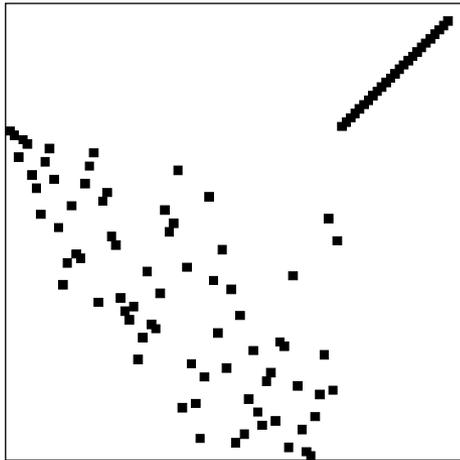
- Gleichverteilung für den Index des Pivotelements  
→ Verwendung des arithmetischen Mittels für Zeiten für die Rekursionsaufrufe
- lineare Zeit für restliche Operationen

Dies führt zu folgendem Ansatz:

$$T(n) = O(n) + \frac{1}{n} \left( \sum_{i=0}^{n-1} T(i) + T(n - 1 - i) \right) = O(n) + \frac{2}{n} \cdot \sum_{i=0}^{n-1} T(i)$$

# HeapSort: Verbessertes SelectionSort

- SelectionSort: Wähle  $n$ -mal das jeweils nächste Maximum in  $O(n)$  Zeit
- Falls das immer in  $O(\log n)$  ginge, hätten wir ein  $O(n \log n)$ -Verfahren
- Idee: Stelle das jeweils nächste Maximum in  $O(\log n)$  ganz nach vorne



# Heap: Struktur

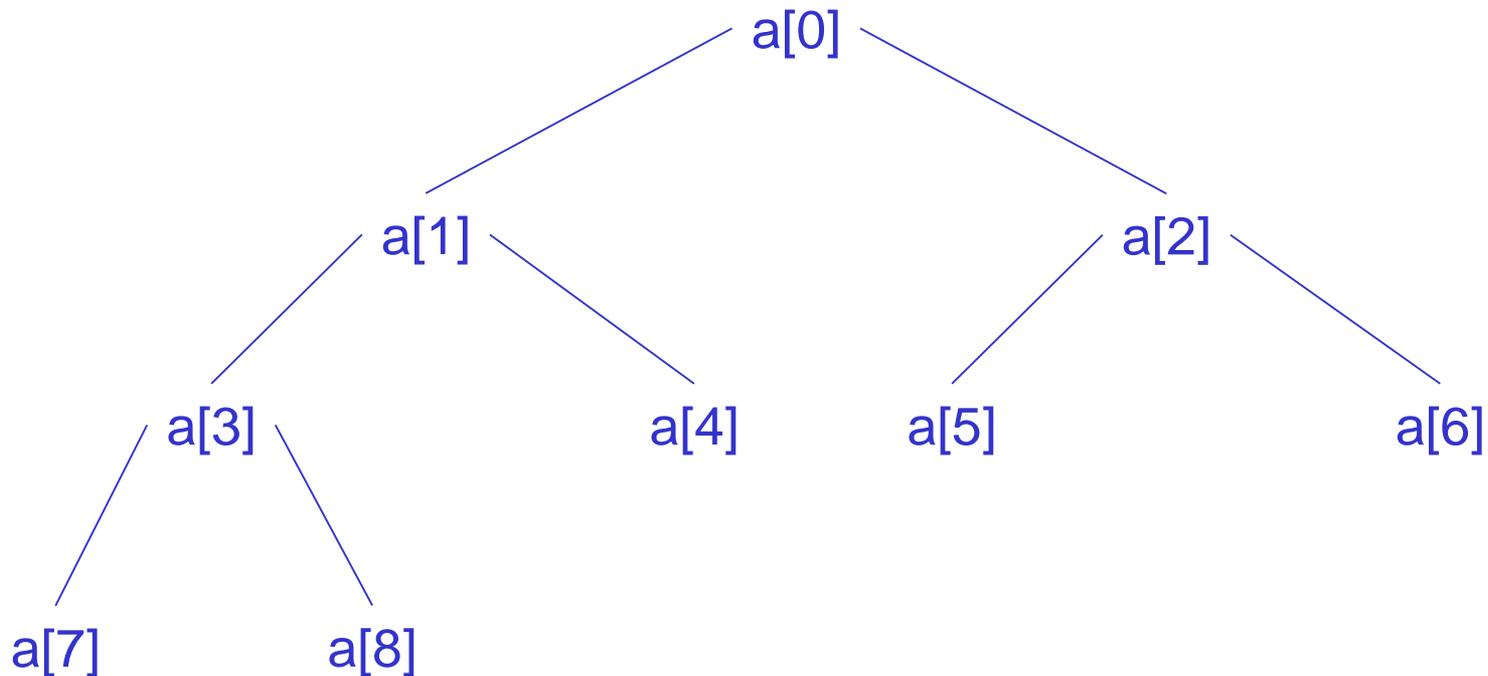
- Ein Heap ist ein **links-vollständiger Binärbaum**, der in ein Array eingebettet ist und folgende Eigenschaft erfüllt:
- Ein Array  $a$  erfüllt die Heap-Eigenschaft, falls gilt:

$$a \left[ \left\lfloor \frac{i-1}{2} \right\rfloor \right] \geq a[i] \quad \text{für } i = 1, \dots, a.\text{length} - 1$$

- Ein Array  $a$  ist ein Heap beginnend in Position  $l = 0, \dots, a.\text{length} - 1$ , falls:

$$a \left[ \left\lfloor \frac{i-1}{2} \right\rfloor \right] \geq a[i] \quad \text{für } i = 2l - 1, \dots, a.\text{length} - 1$$

# Heap: Beispiel für Einbettung



# Folgerungen der Heapeigenschaft

- In einem Heap ist der Schlüssel jedes inneren Knotens größer als die Schlüssel seiner Kinder.
- Insbesondere gilt damit für einen Heap im Array:

$$a[0] = \max\{a[i]: i = 0, \dots, a.\text{length} - 1\}$$

- Außerdem gilt folgendes Korollar:  
Jedes Array  $a[1 \dots n]$  ist ein Heap beginnend in Position

$$l = \left\lfloor \frac{a.\text{length}}{2} \right\rfloor + 1$$

# HeapSort: Ablauf

## 1. Heap-Aufbau-Phase

Wandle das Array  $a$  in einen Heap um.

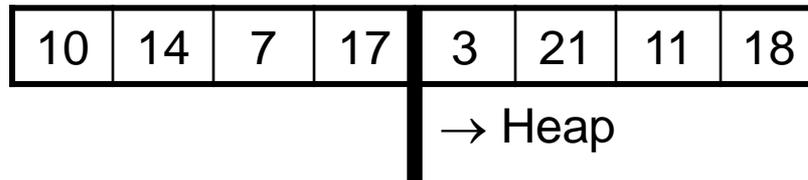
## 2. Sortierphase

for  $i := 0$  to  $(a.length - 2)$  do

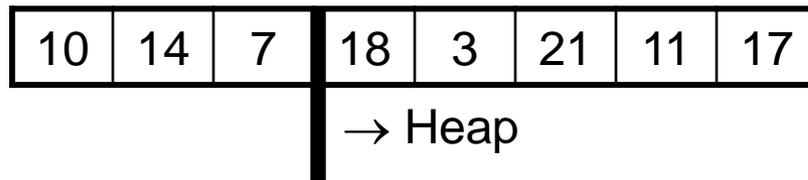
- a) Tausche Wurzel  $a[0]$  und aktuell letztes Element  $a[a.length - i]$
- b) Stelle für das Rest-Array  $a[0 \dots (a.length - i - 1)]$  die Heap-Eigenschaft wieder her (durch Versickern)

# HeapSort: Beispiel für Vertauschen

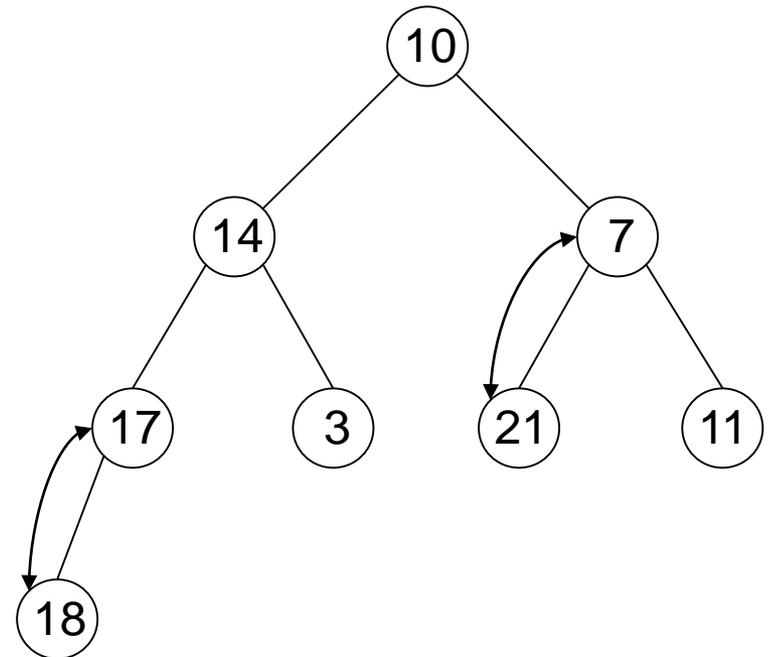
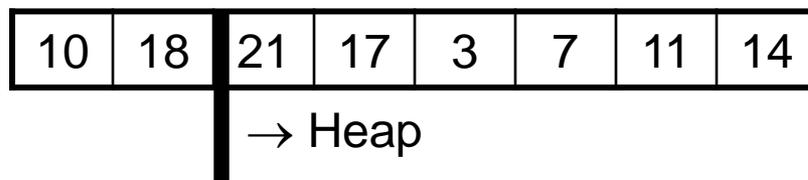
Ausgangssituation:



Vertausche 17 ↔ 18

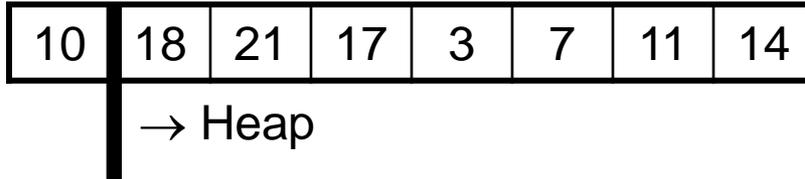


Vertausche 7 ↔ 21

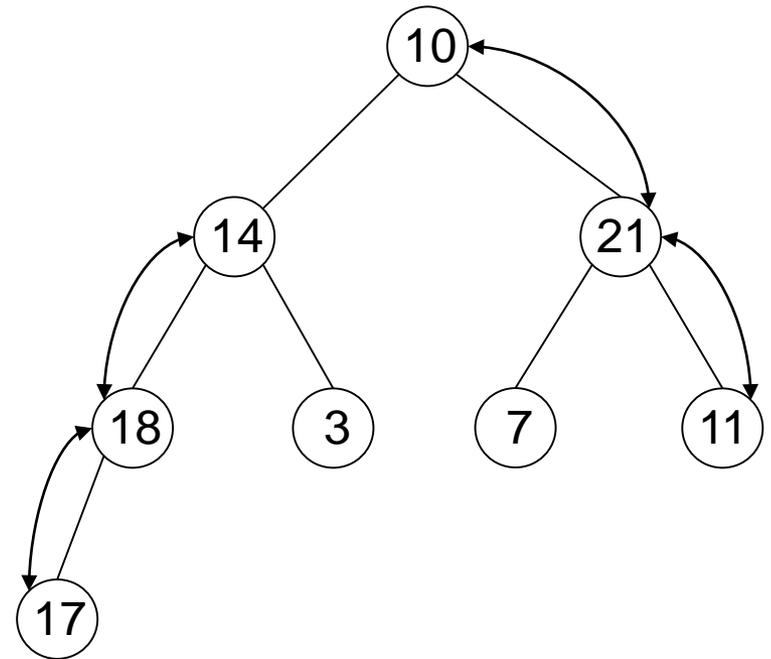


# HeapSort: Beispiel für Versickern

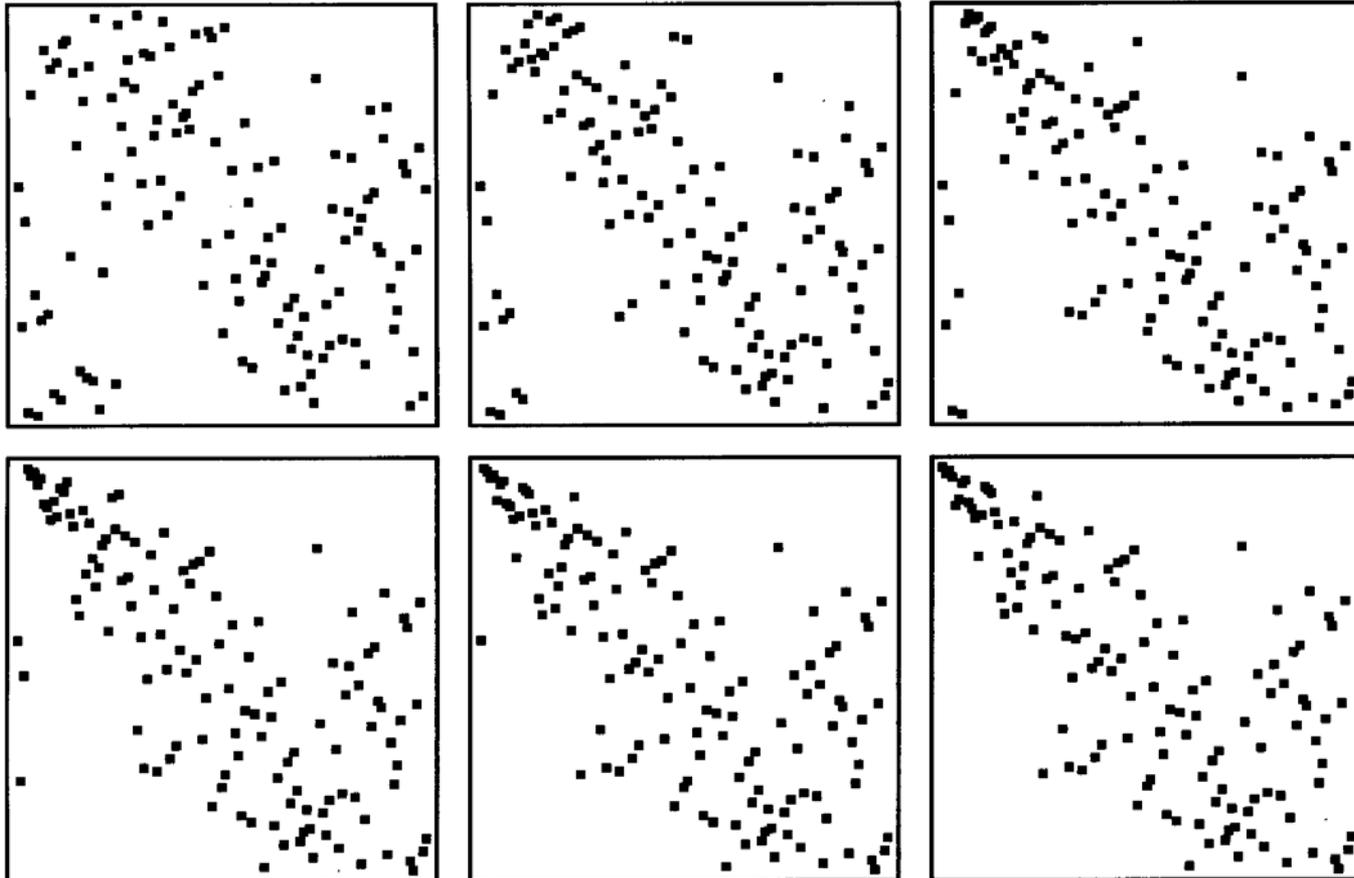
Versickere  $14 \leftrightarrow 18 \leftrightarrow 17$ :



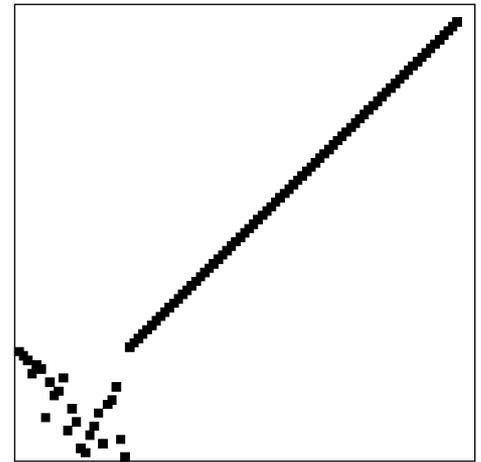
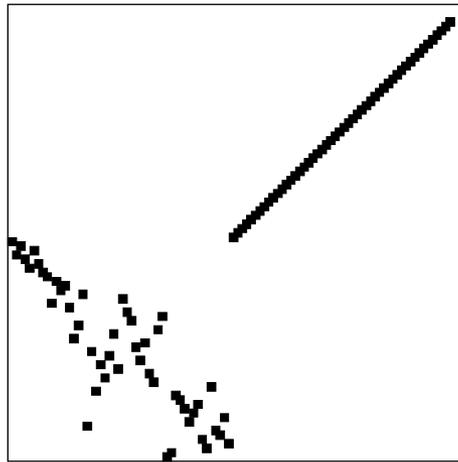
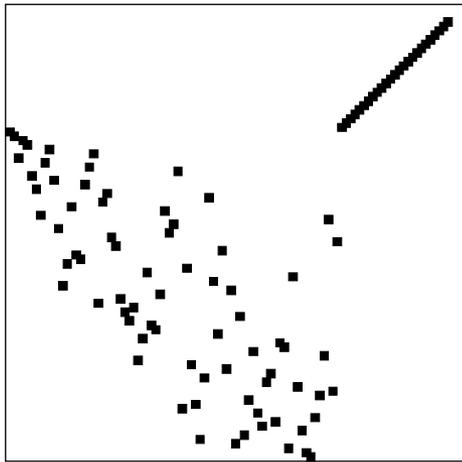
Versickere zuletzt  $10 \leftrightarrow 21 \leftrightarrow 11$ :



# HeapSort: Aufbau des Heaps



# HeapSort: Sortierphase



# HeapSort: Implementierung Heapaufbau

```
static void convertToHeap (int[] a, int n) {  
    for (int i = n/2; i >= 0; --i) {  
        sink(a, n, i);  
    }  
}
```

Wenn die Schleife bis  $i = p$  durchgelaufen ist, hat das Array  $a$  ab Index  $p$  die Heap-Eigenschaft.

# HeapSort: Implementierung Versickern

```
static void sink (int[] a, int n, int i){  
    while (i < n/2){  
        int j = 2*i;  
        if ((j < n) && (a[j+1] > a[j])) j++;  
        if (a[j] > a[i]) {  
            swap(a, j, i);  
            i = j;  
        } else {  
            i = n;  
        }  
    }  
}
```

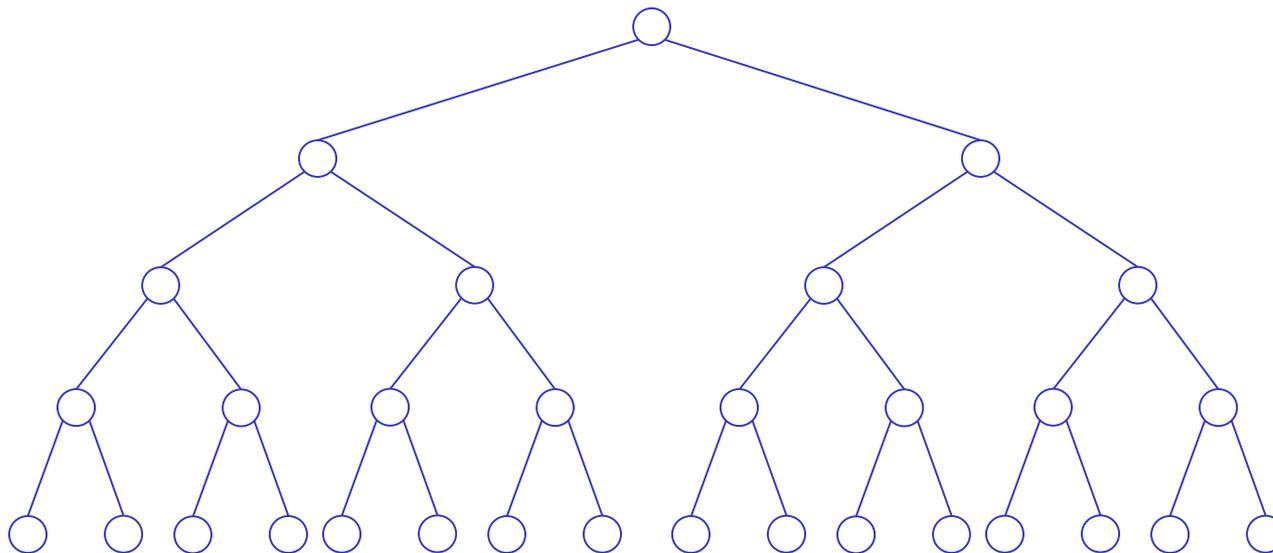
# HeapSort: Implementierung (gesamt)

```
static void heapSort(int[] a){  
    convertToHeap(a, a.length - 1);  
  
    for (int i = a.length - 1; i >= 0; --i){  
        swap(a, 0, i);  
        sink(a, i, 0);  
    }  
}
```

# HeapSort: Komplexitätsanalyse

Wir betrachten die Anzahl der Vergleiche, um ein Array der Größe  $n = 2^k - 1, k \in \mathbb{N}$  zu sortieren.

Zur Veranschaulichung betrachten wir die Analyse exemplarisch für ein Array der Größe  $n = 2^5 - 1 = 31$  (also  $k = 5$ ).



$i = 0:$        $2^0 = 1$       Knoten

$i = 1:$        $2^1 = 2$       Knoten

$i = 2:$        $2^2 = 4$       Knoten

$i = 3:$        $2^3 = 8$       Knoten

$i = 4:$        $2^4 = 16$       Knoten

# HeapSort: Komplexitätsanalyse

## Heap-Aufbau für Array mit $n = 2^k - 1$ Knoten

- Auf der Ebene  $i, i = 0, \dots, k - 1$ , gibt es  $2^i$  Knoten.
- Wir fügen ein Element auf dem Niveau  $i = (k - 2), (k - 3), \dots, 0$  hinzu
- Dieses Element kann maximal auf Niveau  $k - 1$  sinken.
- Pro Niveau werden dazu höchstens zwei Vergleiche benötigt:
  1. Vergleich: **IF**  $a[j] \leq v$  **THEN** ...  
Wird bei jedem Durchlauf der **WHILE-Schleife** ausgeführt, die ihrerseits bei jedem Prozeduraufruf **DownHeap**( $i, k, a$ ) mindestens einmal durchlaufen wird.
  2. Vergleich: **IF**  $a[j] < a[j+1]$  **THEN** ...  
Wird ausgeführt, falls zweites Kind existiert.

Für die Gesamtzahl der Vergleiche ergibt sich damit die obere Schranke:

$$\sum_{i=0}^{k-2} 2 \cdot (k - 1 - i) = 2^{k+1} - 2(k + 1)$$

Beweis durch vollständige Induktion über  $k$ .

# HeapSort: Komplexitätsanalyse

## Sortierphase

- Nach Aufbau des Heaps muß noch die endgültige Ordnung auf dem Array hergestellt werden
  - Dazu wird ein Knoten der Tiefe  $i$  auf die Wurzel gesetzt
  - Dieser Knoten kann mit DownHeap maximal um  $i$  Niveaus sinken
  - Pro Niveau sind hierzu höchstens zwei Vergleiche erforderlich
  - Damit ergibt sich für die Anzahl der Vergleiche die obere Schranke:

$$\sum_{i=0}^{k-1} 2i \cdot 2^i = 2(k-2) \cdot 2^k + 4$$

Beweis durch vollständige Induktion über  $k$

# HeapSort: Komplexitätsanalyse

## Zusammen

Sei  $n = 2^k - 1$ , dann gilt für die Anzahl  $T(n)$  der Vergleiche:

$$\begin{aligned} T(n) &\leq 2^{k+1} - 2(k+1) + 2(k-2) \cdot 2^k + 4 = 2k \cdot (2^k - 1) - 2 \cdot (2^k - 1) \\ &= 2n \cdot \text{ld}(n+1) - 2n \in O(n \log n) \end{aligned}$$

Für  $n \neq 2^k - 1$  erhält man ein ähnliches Ergebnis. Die Rechnung gestaltet sich jedoch umständlicher.

## Resultat

HeapSort sortiert jede Folge  $a[1..n]$  mit höchstens  $2n \cdot \text{ld}(n+1) - 2n \in O(n \log n)$  Vergleichen.



# Kapitel 2 - Sortieren

## Elementare Sortierverfahren

SelectionSort

InsertionSort

BubbleSort

## Höhere Sortierverfahren

MergeSort

QuickSort

HeapSort

## **Untere und obere Schranken für das Sortierproblem**

## Spezielle Sortierverfahren

CountingSort

# Untere und obere Schranken für das Sortierproblem

## bisher:

Komplexität eines Algorithmus

## jetzt:

Komplexität eines Problems (Aufgabenstellung)

## Ziel:

$T_A(n) :=$  Zahl der Schlüsselvergleiche, um eine  $n$ -elementige Folge von Schlüsselementen mit Algorithmus  $A$  zu sortieren.

$T_{\min}(n) :=$  Zahl der Vergleiche für den effizientesten Algorithmus

# Suche nach einer unteren Schranke

Gibt es ein  $T_0(n)$ , so dass

$$T_0(n) \leq T_A(n) \quad \forall A$$

gilt, d.h. jeder *denkbare* Algorithmus braucht in diesem Fall mindestens  $T_0(n)$  Vergleiche?

# Suche nach einer oberen Schranke

Wir wählen einen (möglichst effizienten) Sortieralgorithmus  $A$  mit Komplexität  $T_A(n)$ .

## **Sprechweise:**

$T_A(n)$  Vergleiche reichen, um jedes Sortierproblem zu lösen.

# Untere und obere Schranke zusammen

$$T_0(n) \leq T_{\min}(n) \leq T_A(n)$$

## Wunsch:

$T_0(n)$  und  $T_A(n)$  sollen möglichst eng zusammen liegen.

## Konkret:

- Im folgenden betrachten wir für das Sortierproblem nur *Vergleichsoperationen*
  - Beschränkung auf Algorithmen, die Wissen über die Anordnung der Eingabefolge allein durch (binäre) Vergleichsoperationen erhalten

# Obere Schranke

Wir wählen als effizienten Algorithmus MergeSort.

$$\begin{aligned} T_A(n) &= n \lceil \lg n \rceil - 2^{\lceil \lg n \rceil} + 1 \\ &\leq n \lceil \lg n \rceil - n + 1 \end{aligned}$$

# Untere Schranke

Gegeben sei eine  $n$ -elementige Folge.

Sortieren: entspricht Auswahl einer Permutation dieser Folge

Es gibt  $n!$  Permutationen, aus denen die „richtige“ auszuwählen ist.

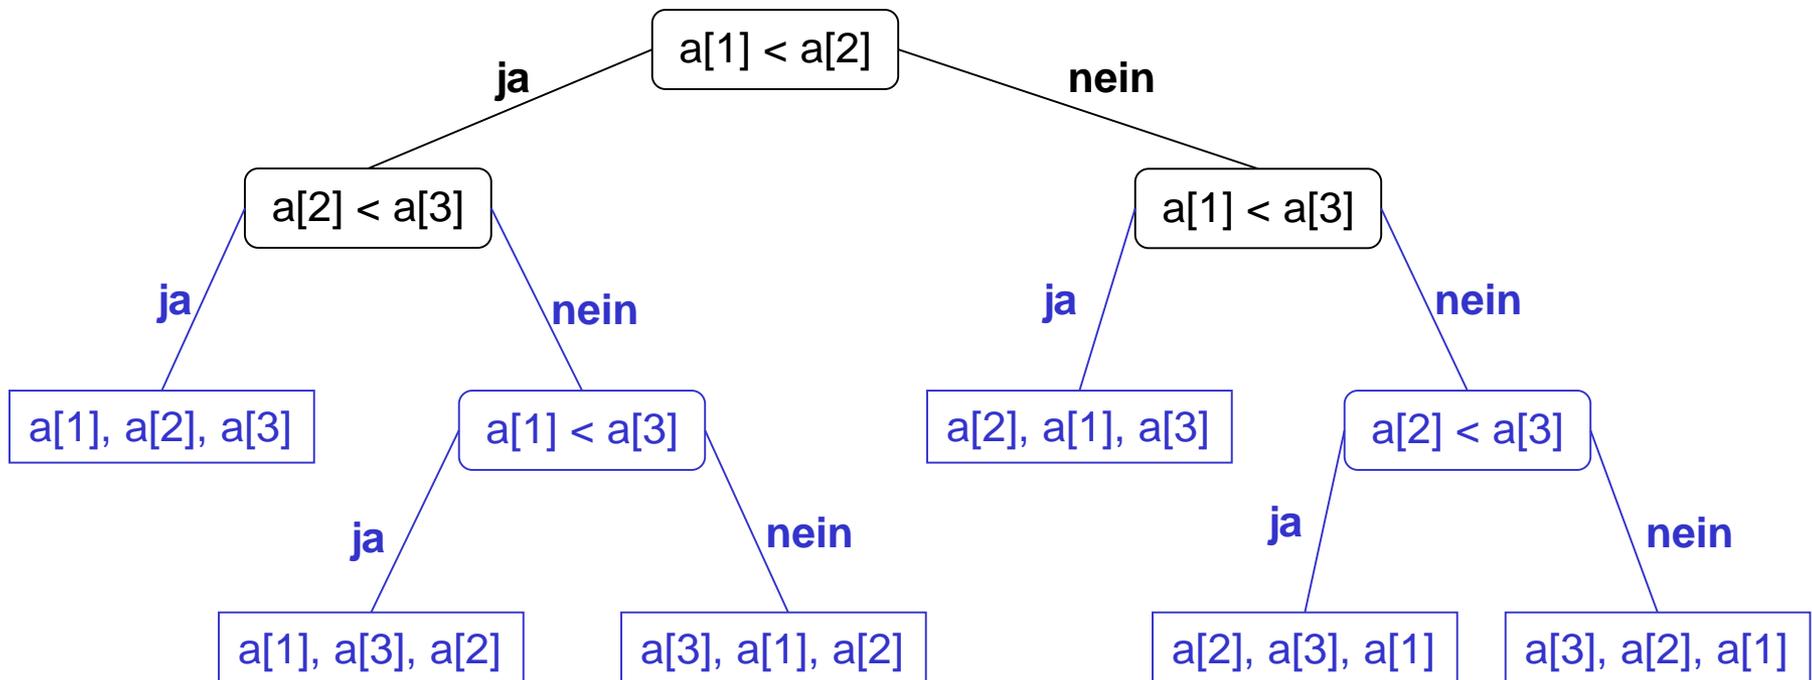
# Entscheidungsbaum

Der Ablauf eines nur auf Vergleichen basierenden Sortieralgorithmus kann durch **einen Entscheidungsbaum** dargestellt werden:

- innerer Knoten entspricht **Vergleich**
- Blatt entspricht **Permutation**

# Entscheidungsbaum - Beispiel

Der folgende binäre Entscheidungsbaum „sortiert“ ein 3-elementiges Array  $a[1\dots 3]$ . Da  $3! = 6$ , muß der Entscheidungsbaum 6 Blätter besitzen. Wegen  $\lg 6 \approx 2.58$  existiert in dem Baum mindestens ein Pfad der Länge 3.



# Entscheidungsbaum

Ein binärer Entscheidungsbaum für das Sortierproblem **besitzt genau  $n!$  Blätter**. Damit ergibt sich als untere Schranke für das Sortierproblem:

$$n! \leq \lceil n! \rceil \leq T_0(n)$$

Mit der Ungleichung (Beweis: siehe folgende Folien)

$$n \lg n - n \lg e \leq n!$$

erhalten wir das Ergebnis:

$$n \lg n - n \lg e \leq T_{\min}(n) \leq n \lceil n! \rceil - n + 1$$

# Einfache Schranken für $n!$

## Obere Schranke:

$$n! = \prod_{i=1}^n i \leq \prod_{i=1}^n n = n^n$$

## Untere Schranke:

$$n! = \prod_{i=1}^n i \geq \prod_{i=\lfloor \frac{n}{2} \rfloor}^n i \geq \prod_{i=\lfloor \frac{n}{2} \rfloor}^n \lfloor \frac{n}{2} \rfloor \geq \left(\frac{n}{2}\right)^{\frac{n}{2}}$$

## Zusammen:

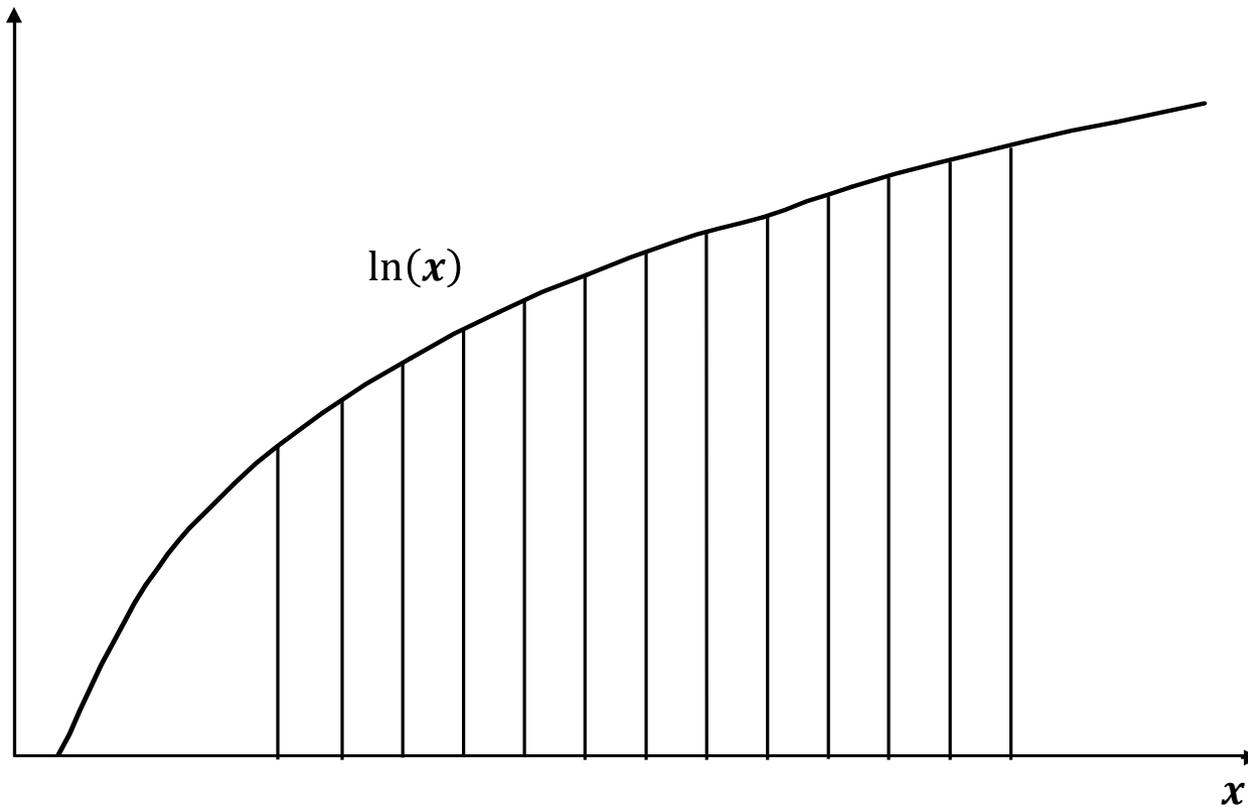
$$\left(\frac{n}{2}\right)^{\frac{n}{2}} \leq n! \leq n^n$$

# Integral-Methode

- Engere Schranken für  $n!$  mittels der *Integral-Methode*
  - das Flächenintegral monotoner und konvexer Funktionen wird von oben und unten durch Trapezsummen approximiert.
  
- Für die Fakultätsfunktion gilt:

$$\ln(n!) = \ln \prod_{i=1}^n i = \sum_{i=1}^n \ln i$$

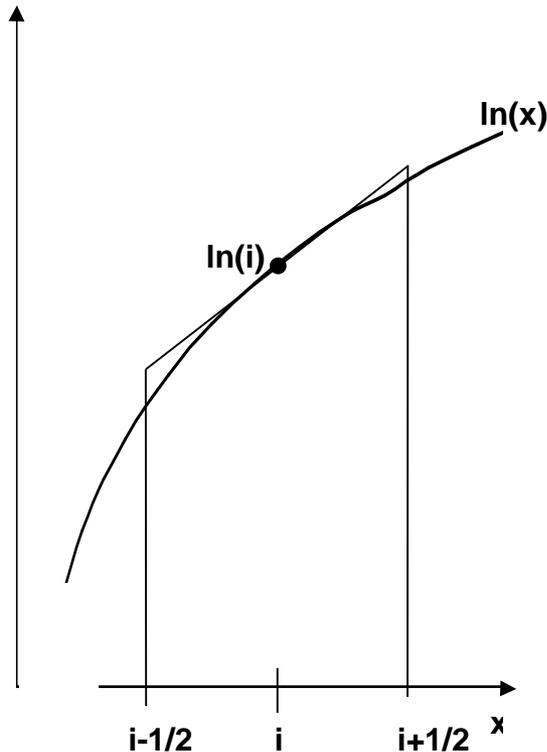
# Graph zu $\ln(x)$



# Untere Schranke

Die Logarithmusfunktion  $x \rightarrow f(x) := \ln(x)$  ist **monoton und konvex**.  
Daher:

$$\int_{i-\frac{1}{2}}^{i+\frac{1}{2}} \ln(x) dx \leq \ln(i)$$



# Untere Schranke für $n!$

Summation von  $i = 1, \dots, n$  ergibt:

$$\int_{\frac{1}{2}}^{n+\frac{1}{2}} \ln(x) dx \leq \sum_{i=1}^n \ln(i) = \ln(n!)$$

Mit  $\int_a^b \ln(x) dx = x \cdot \ln(x) - x \Big|_a^b$  folgt die untere Schranke für  $\ln(n!)$ :

$$\begin{aligned} \ln(n!) &\geq \left(n + \frac{1}{2}\right) \cdot \ln\left(n + \frac{1}{2}\right) - n - \frac{1}{2} - \frac{1}{2} \cdot \ln\left(\frac{1}{2}\right) + \frac{1}{2} \\ &= n \cdot \ln\left(n + \frac{1}{2}\right) + \ln\left(n + \frac{1}{2}\right) - n \cdot \ln(e) + \frac{1}{2} \cdot \ln(2) \\ &\geq n \cdot \ln(n) - n \cdot \ln(e) \end{aligned}$$

→  $n \lg n - n \lg e \leq \lg n!$  (wie vorne genutzt)

# Obere Schranke für $n!$

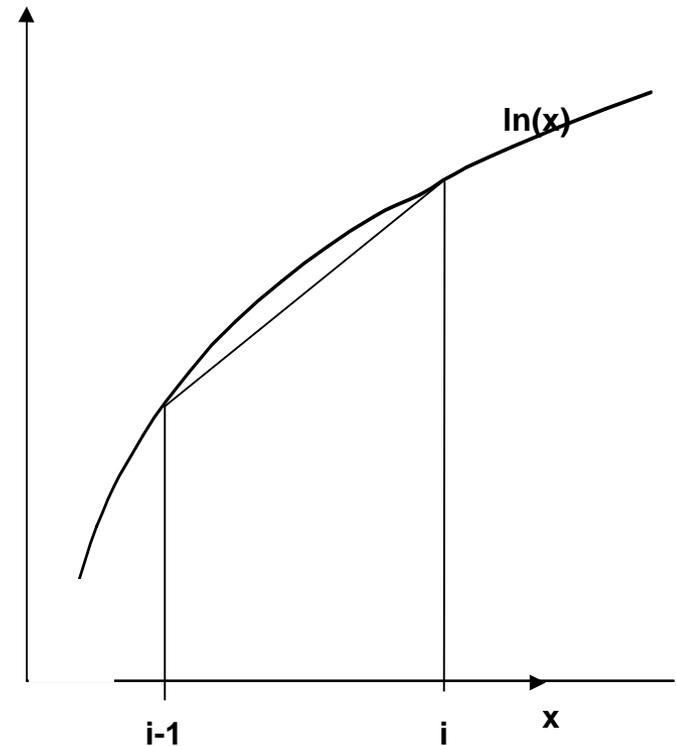
Das Integral über  $\ln(x)$  in den Grenzen  $i-1$  und  $i$  ist **eine obere Schranke** der zugehörigen Trapezuntersumme:

$$\frac{1}{2} \cdot [\ln(i-1) + \ln(i)] \leq \int_{i-1}^i \ln(x) dx$$

Summation von  $i = 2, \dots, n$  ergibt:

$$\ln(n!) - \frac{1}{2} \ln(n) \leq \int_1^n \ln(x) dx = n \cdot \ln(n) - n \ln(e) + 1$$

$$\Rightarrow \ln(n!) \leq n \cdot \ln\left(\frac{n}{e}\right) + \frac{1}{2} \cdot \ln(n) + 1$$



# Beide Schranken zusammen

Aus den vorherigen Berechnungen ergibt sich

$$n \cdot \ln\left(\frac{n}{e}\right) + \frac{1}{2} \cdot \ln(n) + \frac{1}{2} \cdot \ln(2) \leq \ln(n!) \leq n \cdot \ln\left(\frac{n}{e}\right) + \frac{1}{2} \cdot \ln(n) + 1$$
$$\Leftrightarrow \ln\left(\left(\frac{n}{e}\right)^n\right) + \ln(\sqrt{n}) + \ln(\sqrt{2}) \leq \ln(n!) \leq \ln\left(\left(\frac{n}{e}\right)^n\right) + \ln(\sqrt{n}) + \ln(e)$$

Und somit:

$$\left(\frac{n}{e}\right)^n \sqrt{2n} \leq n! \leq \left(\frac{n}{e}\right)^n \sqrt{2n} \frac{e}{\sqrt{2}}$$

# Stirlingsche Formel

Es gilt:

$$n! \approx \sqrt{2\pi n} \left(\frac{n}{e}\right)^n e^{\Theta\left(\frac{1}{n}\right)}$$

mit

$$\frac{1}{12n+1} < \Theta\left(\frac{1}{n}\right) < \frac{1}{12n}$$

Der Fehler  $\Theta(1/n)$  strebt sehr schnell gegen 0:

$$\lim_{n \rightarrow \infty} \Theta\left(\frac{1}{n}\right) = 0$$



# Kapitel 2 - Sortieren

## Elementare Sortierverfahren

SelectionSort

InsertionSort

BubbleSort

## Höhere Sortierverfahren

MergeSort

QuickSort

HeapSort

Untere und obere Schranken für das Sortierproblem

## **Spezielle Sortierverfahren**

**CountingSort**

# Spezielle Sortierverfahren: CountingSort

## Voraussetzung:

Schlüssel sind darstellbar als ganzzahlige Werte im Bereich  $0, \dots, M-1$ , sodass sie als Array-Index verwendet werden können.

$$a[i] \in \{0, \dots, M - 1\} \quad \forall i=1, \dots, n$$

## Arbeitsweise:

1. Erstelle ein **Histogramm**, d.h. zähle für jeden Schlüsselwert, wie häufig er vorkommt.
2. Berechne aus dem Histogramm die Position für jeden Record.
3. Bewege die Records an ihre errechnete Position.

# CountingSort: Beispiel

- 4 Schlüsselwerte: A, B, C und D
- Array mit 14 Einträgen:

A B B A C A D A B B A D D A

1. Zählen der Häufigkeit jedes Schlüssels

A	B	C	D
6	4	1	3

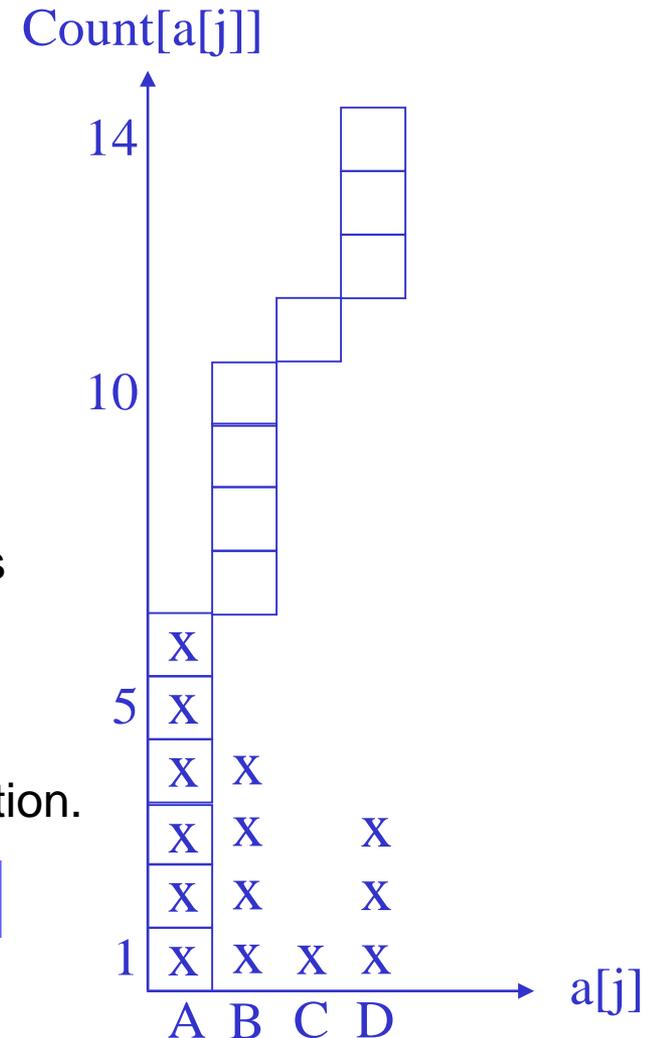
2. Berechnen der höchsten Position jedes Eintrags

A	B	C	D
6	10	11	14

3. Einfügen der Elemente an der berechneten Position.

A A A A A A B B B B C D D D

Rückwärtiges Durchlaufen gewährleistet Stabilität



# CountingSort: Implementierung

```
static int[] countingSort(int[] array, int keysCount){  
    int[] histogram = new int [keysCount];  
    for (int i = 0; i < array.length ; i++){  
        histogram[ array[i] ]++;  
    }  
    for (int i = 1; i < keysCount; i++){  
        histogram[i] += histogram[i-1]  
    }  
    int[] result = int [array.length]  
    for (int i = array.length; i >= 0; i--){  
        result [histogram[array[i]]] = array[i];  
        histogram [array[i]]--;  
    }  
}
```

$O(n)$

$O(M)$

$O(n)$

CountingSort hat eine Zeitkomplexität von  $T(n) \in O(n + M) = O(\max\{n, M\})$

# CountingSort: Komplexität

- Komplexität von CountingSort:

$$T(n) \in O(n + M) = O(\max\{n, M\})$$

- Für **kleine Schlüsselmengen** ist CountingSort besser als die von uns bewiesene Schranke! Wie ist das möglich?
- CountingSort beruht **nicht** auf **Vergleichen**.
- Beim Beweis der unteren Schranke haben wir vorausgesetzt, dass Elemente durch Vergleichen sortiert werden.

# BucketSort

- Für große oder nicht endliche Anzahl von Schlüsseln
- Aufteilung der Schlüssel in Gruppen (Buckets)
- Grobe Sortierung der Elemente anhand der Gruppen
- Algorithmus entsprechend CountingSort
  
- Beispiele:
  - Sortierung von Klausuren anhand der ersten Ziffern der Matrikelnummer
  - Sortierung von Briefen anhand der ersten zwei Ziffern der PLZ
  - Sortierung nach Namen anhand des Anfangsbuchstaben



# Kapitel 2 - Sortieren

## Elementare Sortierverfahren

SelectionSort

InsertionSort

BubbleSort

## Höhere Sortierverfahren

MergeSort

QuickSort

HeapSort

Untere und obere Schranken für das Sortierproblem

## Spezielle Sortierverfahren

CountingSort