



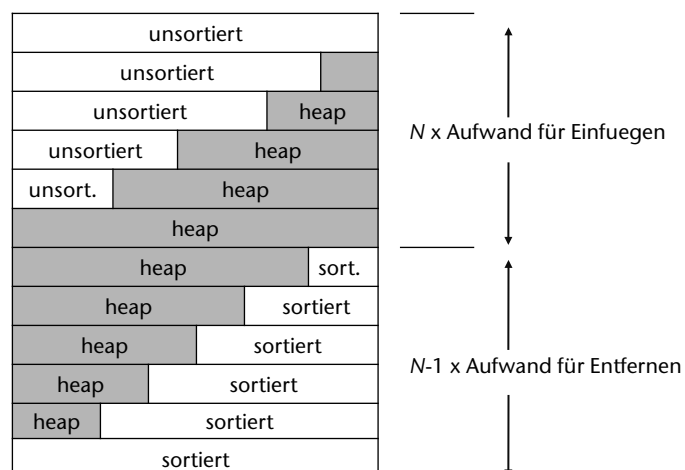
Heapsort



- Beispiel für einen eleganten Algorithmus, der auf einer effizienten Datenstruktur (dem Heap) beruht [Williams, 1964]
- Daten liegen in einem Array der Länge n vor
- 1. Erstelle aus dem gegebenen Array einen Max-Heap (**DownHeap**)
- 2. Tausche erstes und letztes Element des Arrays
 - Dann ist das größte Element an der letzten Position – wo es hingehört
 - Es bleiben $n-1$ Elemente, die an die entsprechende Position müssen
 - Das Array von $n-1$ Elementen ist jedoch kein Heap mehr
 - Stelle Heap-Eigenschaft wieder her (**DownHeap**)
 - Wiederhole Schritt 2 bis das Array sortiert ist
- Trick: verwende das Array selbst zur Speicherung des Heaps



- Prinzipielle Vorgehensweise:



Erstellung eines Heaps

- Rufe **DownHeap** für jedes Element nach der Bottom-Up-Methode auf:


```
BuildHeap(A):  
for i = n/2-1, ..., 0:  
    DownHeap( A, i, n-1 )
```

```
DownHeap(A, l, r):  
# A = array  
# A[l..r] = Bereich, der "heap-ifiziert" werden soll  
# A[l] = Wurzel, die "versickert" werden soll  
# Precondition: die beiden Kinder von A[l] sind  
# korrekte Heaps
```

Beispiel

Eingabe-Array

| | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|
| 24 | 21 | 23 | 22 | 36 | 29 | 30 | 34 | 28 | 27 |
|----|----|----|----|----|----|----|----|----|----|





Korrektheit von **BuildHeap**



- **Schleifeninvariante:** zu Beginn jeder Iteration der for-Schleife ist jeder Knoten $i+1, i+2, \dots, n-1$ die Wurzel eines Heaps
- **Initialisierung:**
 - Vor der ersten Iteration ist $i = \lfloor n/2 \rfloor$
 - Knoten $\lfloor n/2 \rfloor, \lfloor n/2 \rfloor + 1, \dots, n-1$ sind Blätter und daher (trivialerweise) Wurzeln von Heaps
- **Erhaltung der Invariante:**
 - Durch die Schleifeninvariante sind die Kinder des Knotens i Heaps
 - Daher macht **DownHeap(i)** aus Knoten i eine Heap-Wurzel (die Heap-Eigenschaft von höher nummerierten Knoten bleibt erhalten)
 - Verminderung von i stellt die Schleifen-Invariante für die nächste Iteration wieder her



Laufzeit von **BuildHeap**



- Eine lockere obere Schranke (*loose upper bound*):
 - Kosten von einem **DownHeap**-Aufruf \times Anzahl von **DownHeap**-Aufrufen $\rightarrow O(\log n) \cdot O(n) = O(n \log n)$
- Eine engere Schranke (*tighter upper bound*):
 - Kosten für einen Aufruf von DownHeap an einem Knoten hängen von seiner Höhe h ab $\rightarrow O(h)$
 - Knotenhöhe h liegt zwischen 0 und $\lfloor \log(n) \rfloor$ (hier: Blätter = Höhe 0!)
 - Anzahl der Knoten mit Höhe h ist $\left\lceil \frac{n}{2^{h+1}} \right\rceil$

- Engere Schranke (Fortsetzung):

$$\begin{aligned}
 T(\text{BuildHeap}) &\in \sum_{h=1}^{\lfloor \log(n) \rfloor} \left\lceil \frac{n}{2^{h+1}} \right\rceil O(h) \\
 &= O\left(n \underbrace{\sum_{h=1}^{\lfloor \log(n) \rfloor} \frac{h}{2^h}}_{\leq \sum_{h=0}^{\infty} \frac{h}{2^h} = 2} \right) \\
 &= O(n)
 \end{aligned}$$

- Fazit: man kann einen Heap aus einem unsortierten Array in linearer Zeit erstellen!

Der Algorithmus für Heapsort

```

HeapSort(A):
  BuildMaxHeap(A)
  for i = n-1, ..., 1:
    swap A[0] and A[i]
    DownHeap(A, 0, i-1)

```

- BuildHeap benötigt $O(n)$ und jeder der $n-1$ Aufrufe von **DownHeap** benötigt $O(\log n)$
- Daher gilt:

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

State-of-the-Art für Heapsort-Verfahren

- HEAPSORT (Floyd 1964):

$$C_{\max}(n) = 2n \log n + O(n)$$

- BOTTOM-UP-HEAPSORT (Wegener 1993):

$$C_{\max}(n) = 1,5n \log n + O(n)$$

- WEAK-HEAPSORT (Dutton 1993):


$$C_{\max}(n) = n \log n + 0.1n$$

- RELAXED-HEAPSORT:

$$C_{\max}(n) = n \log n - 0.9n$$

Externes Sortieren

- Was macht man, wenn die Daten nicht alle auf einmal in den Speicher passen?
 - Teile die große, externe Datei D in n Teile D_1, \dots, D_n , die jeweils im Speicher intern sortiert werden können
 - Die jeweils sortierten Dateien D_1', \dots, D_n' werden anschließend zu der insgesamt sortierten Datei D' zusammengemischt





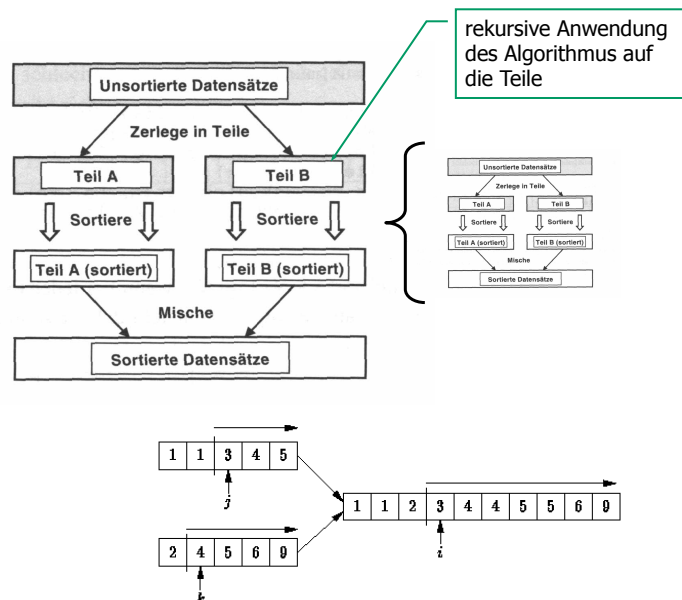
Mergesort




- Idee:
 - Teile die ursprüngliche Menge an Datensätzen in zwei Hälften
 - Sortiere die beiden Teilmengen
 - Mische die beiden sortierten Hälften wieder zusammen (engl. merge)
 - wähle dazu das kleinere der beiden Elemente, die an der jeweils ersten Stelle der beiden Datensätze stehen
 - Wende das Verfahren rekursiv auf die beiden Hälften an, um diese zu sortieren



Das Prinzip



■ Beispiel



```
def mergesort( A ):
    return rek_mergesort( A, 0, len(A)-1 )

def rek_mergesort( A, lo, hi ):
    if hi <= lo:
        return
    mid = (lo + hi) / 2
    A1 = rek_mergesort( A, lo, mid )
    A2 = rek_mergesort( A, mid+1, hi )
    return merge( A1, A2 )
```

```

def merge(a, b):
    if len(a) == 0: return b
    if len(b) == 0: return a

    result = []
    i = j = 0
    while i < len(a) and j < len(b):
        if a[i] <= b[j]:
            result.append( a[i] )
            i += 1
        else:
            result.append( b[j] )
            j += 1

    while i < len(a):
        result.append( a[i] )
    while j < len(b):
        result.append( b[j] )

    return result

```

Eigenschaften

- Algorithmus ist sehr übersichtlich und einfach zu implementieren
- Aufwand: $N \cdot \log(N)$
 - $\log(N)$ viele Etagen, Aufwand pro Etage in $O(N)$, gilt **auch im worst case**
 - Nicht besonders schnell, da viel umkopiert wird
- Optimierung:
 - Ständiges Anlegen von Hilfsarrays kostet Zeit
 - Besser ein großes Hilfsarray anlegen und immer wieder benutzen
- *In-place* Sortierung (ohne Hilfsarray) möglich, aber sehr kompliziert
- Vorteile:
 - Besser geeignet, wenn sequentieller Zugriff schnell, und "random" Zugriff langsam (z.B.: Listen, Bänder, Festplatten)
 - **Stabiler** Sortier-Algo



Algorithmus-Animationen



Animated Sorting Algorithms


BubbleSort



SelectionSort




InsertionSort




QuickSort



HeapSort



MergeSort



<http://www.inf.ethz.ch/~staerk/algorithms/SortAnimation.html>