

Quicksort

- empirisch das schnellste Sortierverfahren
- worst-case-Laufzeit: $\mathcal{O}(n^2)$
- average-case-Laufzeit: $\mathcal{O}(n \log n)$

Der Algorithmus

Gegeben: Array vec mit $n \in \mathbb{N}$ Einträgen

Wähle einen beliebigen Pivoteintrag $vec[pivot]$



↑
pivot-Eintrag

Zerlege das Array in zwei Teilbereiche

→ $vec[0], \dots, vec[k-1]$

⏟
Einträge i mit $vec[i] \leq vec[pivot]$

53	24	12	35	72	10	4	4	63
				↑		↑		

Tausche ...

53	24	12	35	44	18	72		63
					↑↑			

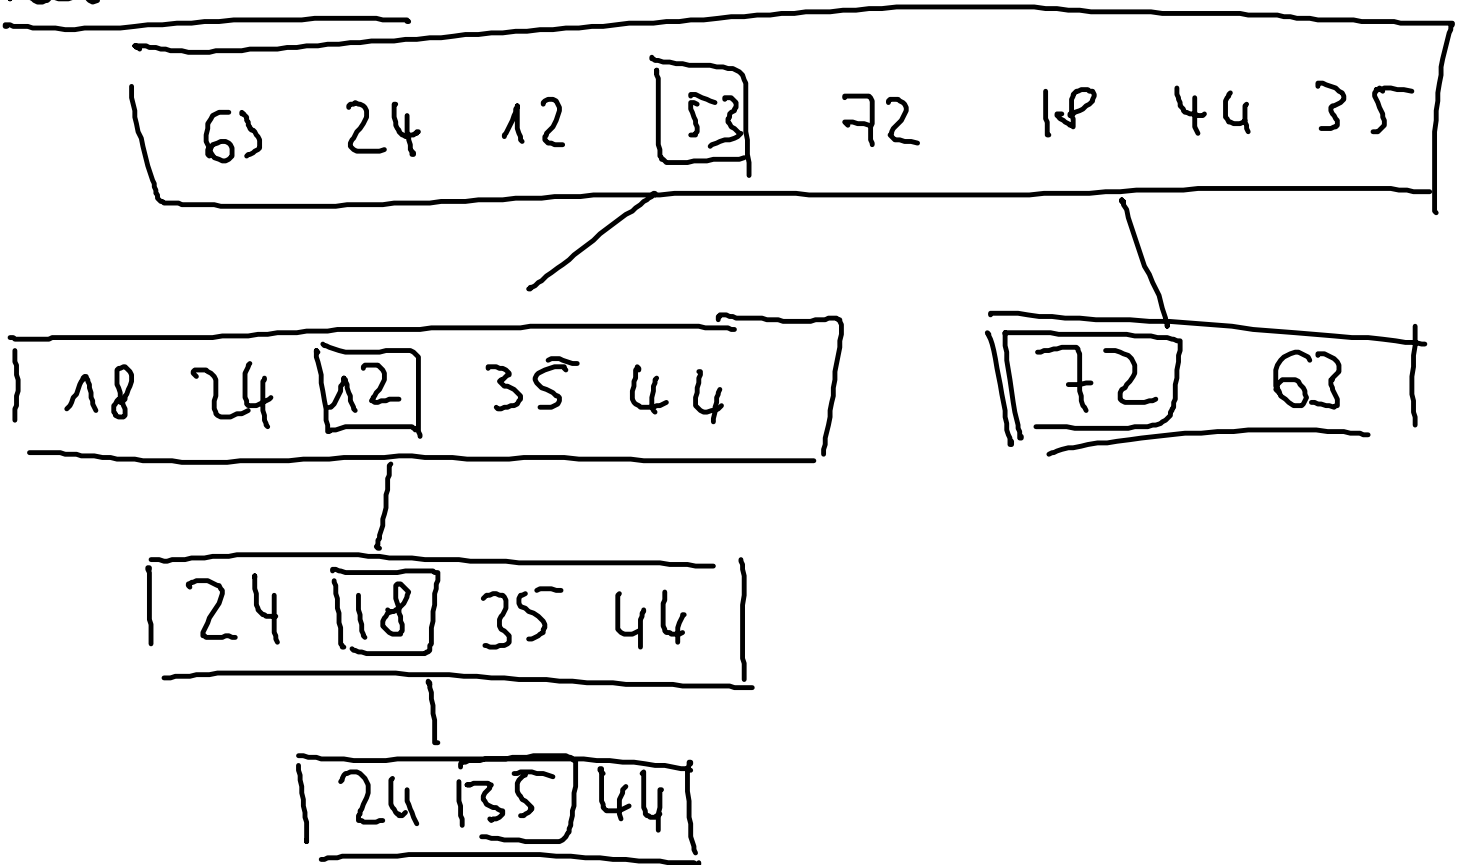
53	24	12	35	44	18	72		63
					↑	↑		
					highswap	lowswap		

Tausche Einträge von $vec[0]$ und $vec[highswap]$

18	24	12	35	44	53	72	63
└──┘					┆	└──────────────────┘	
≤ 53					53	≥ 53	

Lemma: Enthält der aufzuteilende Bereich $m \in \mathbb{N}$ Einträge, so benötigen wir zum Aufteilen $m-1$ Vergleiche.

Rekursionsbaum



Überlegung: Für ein Array der Länge $n \in \mathbb{N}$,
ist die Rekursionstiefe von Quicksort

$$T(n) \leq n - 1$$

Für die Anzahl Rekursiver Aufrufe gilt
ebenfalls

$$R(n) \leq n - 1.$$

Der Worst-Case-Aufwand von Quicksort ist $O(n^2)$

$$C(n) \leq (n-1) + (n-2) + \dots + 2 + 1 = \frac{n(n-1)}{2} \in O(n^2)$$

Wollen zeigen, dass dieser Worst-Case-Fall sehr selten auftritt, und dass amortisiert über alle Permutationen eine mittlere Laufzeit von

$$O(n \log n) = \overline{C}(n)$$

gilt.

Sei Π die Menge aller Permutationen von $\{1, \dots, n\}$, und sei $C(\pi)$ die Anzahl Vergleiche, die Quicksort zum Sortieren der Permutation π benötigt, dann gilt

$$\overline{C}(n) = \frac{1}{n!} \sum_{\pi \in \Pi} C(\pi)$$

$$|\Pi| = n!$$


Für $k \in \{1, \dots, n\}$ sei $\overline{\Pi}_k \subseteq \overline{\Pi}$ die Menge der Permutationen, in denen das Pivotelement k ist.



$$|\overline{\Pi}_k| = (n-1)!$$


$$\sum_{\pi \in \overline{\Pi}_k} C(\pi) = \sum_{\pi \in \overline{\Pi}_k} [z(\pi) + C(\overline{\Pi}_1) + C(\overline{\Pi}_2)]$$

Aufwand zum Teilen des Arrays π in die Teilarrays



(rekursive) Aufwand zum Sortieren von $\overline{\Pi}_1$ bzw. $\overline{\Pi}_2$

$$\begin{aligned}
 \sum_{\pi \in \Pi_k} c(\pi) &= \sum_{\pi \in \Pi_k} z(\pi) + \sum_{\pi \in \Pi_k} c(\pi_1) + \sum_{\pi \in \Pi_k} c(\pi_2) \\
 &< \underbrace{(n-1)! \cdot n}_{= n!} + \underbrace{\frac{(n-1)!}{(k-1)!} \sum_{\pi \in \Pi_{k-1}} c(\pi)}_{= (n-1)! \bar{c}(k-1)} + \underbrace{\sum_{\pi \in \Pi_k} c(\pi_2)}_{= (n-1)! \bar{c}(n-k)} \\
 &= (n-1)! \bar{c}(k-1)
 \end{aligned}$$



Wir suchen eine rekursive Formel für $\bar{c}(n)$.

$$\begin{aligned}
 \bar{c}(n) &= \frac{1}{n!} \sum_{k=1}^n \sum_{\pi \in \Pi_k} c(\pi) \\
 &< \frac{1}{n!} \sum_{k=1}^n \left(n! + (n-1)! \bar{c}(k-1) + (n-1)! \bar{c}(n-k) \right) \\
 &= \frac{1}{n!} \sum_{k=1}^n 1 + \frac{1}{n} \sum_{k=1}^n \bar{c}(k-1) + \frac{1}{n} \sum_{k=1}^n \bar{c}(n-k)
 \end{aligned}$$

$$= n + \frac{1}{n} \sum_{k=0}^{n-1} \bar{c}(k) + \frac{1}{n} \sum_{k=0}^{n-1} \bar{c}(k)$$

$$= n + \frac{2}{n} \sum_{k=0}^{n-1} \bar{c}(k)$$

Wir überlegen uns: $\bar{c}(0) = 0$

$$\bar{c}(1) = 0$$

$$\bar{c}(2) = 1$$

$$\bar{c}(n) \leq n + \frac{2}{n} \sum_{k=2}^{n-1} \bar{c}(k) \quad \text{für } n \geq 2.$$

Theorem: Die Lösung $r(n)$ der

Rekursionsgleichung $r(n) \leq n + \frac{2}{n} \sum_{k=2}^{n-1} r(k)$

mit den Anfangswerten $r(0) = r(1) = 0$
 $r(2) = 1$.

erfüllt die Ungleichung

$$r(n) \leq 2n \ln(n).$$

Beweis: Durch vollständige Induktion.

Wir zeigen $r(n) \leq c \cdot n \ln(n)$ mit $c=2$.

Induktionsanfang: $r(2) = 1 \leq 2 \cdot 2 \cdot \ln(2) \approx 2.8 \dots$ ✓

Induktionsvoraussetzung: Die Behauptung gelte für
alle $k \in \{0, \dots, n-1\}$

Induktionsschluss:


$$r(n) = n + \frac{2}{n} \sum_{k=2}^{n-1} r(k)$$

$$\leq n + \frac{2}{n} \sum_{k=2}^{n-1} c \cdot k \ln(k) \quad (\text{Induktionsvoraus.})$$

$$= n + \frac{2c}{n} \left| \sum_{k=2}^{n-1} k \ln(k) \right|$$

wollen wir abschätzen.

$$f(x) = x \ln(x)$$



$$\sum_{k=2}^{n-1} k \ln(k) \leq \int_2^n x \ln(x) dx$$

Wir erhalten

$$\sum_{k=2}^{n-1} k \ln(k) \leq \int_2^n x \ln(x) dx$$

Partielle Integration:

$$\int_a^b f'(x) \cdot g(x) dx = [f(x) g(x)]_a^b - \int_a^b f(x) g'(x) dx$$

$$\begin{aligned}
\sum_{i=1}^n \dots &\leq \int x \ln(x) dx \\
&= \left[\frac{x^2}{2} \ln x \right]_2^n - \int_2^n \frac{x^2}{2} \cdot \frac{1}{x} dx \\
&= \left[\frac{x^2}{2} \ln x \right]_2^n - \left[\frac{x^2}{4} \right]_2^n \\
&= \frac{n^2}{2} \ln(n) - 2 \ln(2) - \frac{n^2}{4} + 1 \\
&\leq \frac{\left| \frac{n^2}{2} \ln(n) - \frac{n^2}{4} \right|}{n}
\end{aligned}$$

Wir erhalten

$$\begin{aligned}
r(n) &\leq n + \frac{2c}{n} \left| \sum_{k=2}^{n-1} k \ln k \right| \\
&\leq n + \frac{2c}{n} \left(\frac{n^2}{2} \ln(n) - \frac{n^2}{4} \right) \\
&= n + c \cdot n \cdot \ln(n) - \frac{c}{2} n \\
&= c \cdot n \cdot \ln(n) + n - \frac{c}{2} n
\end{aligned}$$

$$\boxed{c=2}$$

$$= 2n \ln(n) \in O(n \cdot \lg n),$$