

2. Der Blum-Floyd-Pratt-Rivest-Tarjan Selektions-Algorithmus

Definition 77

Sei $n \in \mathbb{N}$. Der **Median** (das „mittlere“ Element) einer total geordneten Menge von n Elementen ist deren i -kleinstes Element, wobei

$$i = \left\lceil \frac{n}{2} \right\rceil .$$

Bemerkung: Für gerade n wird manchmal auch $i = \left\lfloor \frac{n}{2} \right\rfloor + 1$ benutzt.


Sei m eine kleine ungerade Zahl (etwa $5 \leq m \leq 21$). Sei $S := \{a_1, \dots, a_n\}$ eine Menge von n paarweise verschiedenen Elementen. Zur Bestimmung des i -kleinsten Element in S betrachten wir folgenden Algorithmus BFPRT.

Der BFPRT-Selektions-Algorithmus (1/3)

- 1 Teile S in $\lceil \frac{n}{m} \rceil$ Blöcke auf, $\lfloor \frac{n}{m} \rfloor$ davon mit je m Elementen
- 2 Sortiere jeden dieser Blöcke
- 3 Sei S' die Menge der $\lceil \frac{n}{m} \rceil$ Mediane der Blöcke. Bestimme rekursiv den **Median** s dieser Mediane (also das $\lceil \frac{|S'|}{2} \rceil$ -kleinste Element von S').

Der BFPRT-Selektions-Algorithmus (2/3)

- ④ Partitioniere $S - \{s\}$ in $S_1 := \{x \in S : x < s\}$,
 $S_2 := \{x \in S : x > s\}$. Bemerkung: $|S_1|, |S_2| \geq \frac{n}{4}$, falls
 $n \geq 3m - 1$.



Der BFPRT-Selektions-Algorithmus (3/3)

- 5 Falls $i \leq |S_1|$, bestimme rekursiv das i -kleinste Element in S_1 .
Falls $i = |S_1| + 1$, gib s als Lösung zurück.
Ansonsten bestimme rekursiv das $(i - |S_1| - 1)$ -kleinste Element in S_2 .

Sei $T(n)$ die worst-case Anzahl von Vergleichen für $|S| = n$ des Algorithmus BFPRT. Sei C_m die # von Vergleichen, um m Elemente zu sortieren (z.B. $C_5 = 7$, $C_{11} = 26$). Es gilt:

$$T(n) \leq \underbrace{T\left(\left\lceil \frac{n}{m} \right\rceil\right)}_{3.} + \underbrace{T\left(\left\lfloor \frac{3}{4}n \right\rfloor\right)}_{5.} + \underbrace{\left\lceil \frac{n}{m} \right\rceil}_{2.} C_m + \underbrace{\left\lfloor \frac{n}{2} \right\rfloor}_{4.}$$

Satz 78

Der Selektions-Algorithmus BFPRT bestimmt das i -kleinste Element von n Elementen mit $\mathcal{O}(n)$ Vergleichen (und Zeit).

Beweis:

Annahme: $T(n) \leq c \cdot n$, wobei $c = c(m)$ konstant ist.

Die Annahme ist ok, falls $T(n) \leq$

$$T\left(\left\lceil \frac{n}{m} \right\rceil\right) + T\left(\left\lfloor \frac{3}{4}n \right\rfloor\right) + \left\lceil \frac{n}{m} \right\rceil C_m + \left\lfloor \frac{n}{2} \right\rfloor \leq cn; \text{ dies gilt, falls}$$

$$\left\lceil \frac{n}{m} \right\rceil c + \left\lfloor \frac{3}{4}n \right\rfloor c + \left\lceil \frac{n}{m} \right\rceil C_m + \left\lfloor \frac{n}{2} \right\rfloor \leq cn \quad | \cdot \frac{1}{n} \quad (\text{IA})$$

$$\Leftrightarrow (\text{bis auf } \lceil \cdot \rceil, \lfloor \cdot \rfloor) \frac{c}{m} + \frac{3}{4}c + \frac{C_m}{m} + \frac{1}{2} \leq c$$

$$\Leftrightarrow -\frac{c}{m} - \frac{3}{4}c + c \geq \frac{C_m}{m} + \frac{1}{2}$$

$$\Leftrightarrow c \geq \frac{\frac{C_m}{m} + \frac{1}{2}}{1 - \frac{3}{4} - \frac{1}{m}}$$

Bemerkung: $m = 11 \rightsquigarrow c = c(m) \approx 20$. □

Literatur:



Vaughan R. Pratt, Frances F. Yao:

On lower bounds for computing the i -th largest element

Proc. 14th Ann. IEEE SWAT, pp. 70–81 (1973)



Manuel Blum, Robert W. Floyd, Vaughan R. Pratt, Ron L. Rivest, Robert E. Tarjan:

Time bounds for selection

JCSS 7, pp. 448–461 (1973)


3. Randomisierter Median-Algorithmus

Problemstellung: Bestimme den Median von n Elementen

- 1 Wähle $n^{\frac{3}{4}}$ Elemente zufällig und gleichverteilt aus den n Elementen aus.
- 2 Sortiere diese $n^{\frac{3}{4}}$ Elemente mit einem (Standard-) $n \log n$ -Algorithmus.
- 3 Setze

$p_1 := \max\{\frac{n^{\frac{3}{4}}}{2} - \sqrt{n}, 1\}$ -kleinstes Element der $n^{\frac{3}{4}}$ Elemente.

$p_2 := \min\{\frac{n^{\frac{3}{4}}}{2} + \sqrt{n}, n^{\frac{3}{4}}\}$ -kleinstes Element der $n^{\frac{3}{4}}$ Elemente.



- 4 Partitioniere die n Elemente in

$$S_0 := \{\text{Elemente} < p_1\}$$

$$S_1 := \{p_1 \leq \text{Elemente} \leq p_2\}$$

$$S_2 := \{p_2 < \text{Elemente}\}$$

- 5 Falls $|S_0| \geq \lceil \frac{n}{2} \rceil$ oder $|S_2| \geq \lceil \frac{n}{2} \rceil$ oder $|S_1| \geq 4 \cdot n^{\frac{3}{4}}$, dann wiederhole den Algorithmus;
ansonsten sortiere S_1 und liefere das $(\lceil \frac{n}{2} \rceil - |S_0|)$ -kleinste Element davon ab.

Satz 79

Obiger randomisierter Algorithmus bestimmt den Median von n -Elementen mit einer erwarteten Anzahl von $\frac{3}{2}n + o(n)$ Vergleichen.

Beweis:


- i) Korrektheit: klar.

Beweis (Forts.):

ii) Anzahl der Vergleiche in einer Iteration:

$$\mathcal{O}(n^{\frac{3}{4}} \log n^{\frac{3}{4}}) + \text{Kosten der Partitionierung}$$

Für die Partitionierung ist der naive Ansatz zu ungünstig, stattdessen:



Wähle zuerst jeweils mit Wahrscheinlichkeit $\frac{1}{2}$ aus, ob Element x mit p_1 oder p_2 verglichen wird, mache **zweiten** Vergleich nur, falls nötig.

Beweis (Forts.):

Die erwartete Anzahl von Vergleichen ist dann

$$\begin{aligned} &= \frac{n}{2} \left(\frac{|S_0|}{n} \cdot 1 + \frac{|S_1| + |S_2|}{n} \cdot 2 \right) + \frac{n}{2} \left(\frac{|S_2|}{n} \cdot 1 + \frac{|S_0| + |S_1|}{n} \cdot 2 \right) \\ &= \frac{n}{2} \left(\frac{|S_0| + |S_2|}{n} + 2 \overbrace{\frac{|S_0| + |S_1| + |S_2| + |S_1|}{n}}^n \right) \\ &= \frac{n}{2} \left(3 + \frac{|S_1|}{n} \right) = \frac{3}{2}n + o(n) \end{aligned}$$

Wir zeigen nun, dass der Algorithmus mit Wahrscheinlichkeit $\geq 1 - \mathcal{O}(n^{-\frac{1}{4}})$ nur eine Iteration benötigt (daraus folgt dann, dass insgesamt die Anzahl der Vergleiche $\leq \frac{3}{2}n + o(n)$ ist).

Beweis (Forts.):

Dafür verwenden wir Hilfsmittel aus der Wahrscheinlichkeitstheorie/Stochastik:

- **Bernoulli-Zufallsvariable (ZV):** X , Werte $\in \{0, 1\}$ mit

$$X = \begin{cases} 1 & \text{mit WS } p \\ 0 & \text{mit WS } q = 1 - p \end{cases}$$

- **Erwartungswert** einer ZV:

$$\mathbb{E}[X] = \sum_{x \in \text{Wertebereich}} x \cdot \Pr[X = x]$$

(X ist diskret, d.h. der Wertebereich von X ist endlich)

- **Markov-Ungleichung:** $\Pr[X \geq t] \leq \frac{\mathbb{E}[X]}{t}$ für X nicht negativ
- **Chebyshev-Ungleichung:** $\Pr[|X - \mathbb{E}[X]| \geq t] \leq \frac{\text{Var}(X)}{t^2}$

Beweis (Forts.):

- **Binomialverteilung:** Seien X_1, \dots, X_n unabhängige, identisch verteilte Bernoulli-Zufallsvariablen mit $\Pr[X_i = 1] = p$.

$$X := \sum_{i=1}^n X_i .$$

X ist binomial verteilt, mit Wertebereich $\{0, 1, \dots, n\}$.

$$\Pr[X = k] = \binom{n}{k} p^k (1 - p)^{n-k}$$

$$\mathbb{E}[X] = n \cdot p$$

$$\text{Var}[X] = n \cdot p \cdot (1 - p) = n \cdot p \cdot q .$$

In Zeichen: $X \sim B(n, p)$

Beweis (Forts.):

Die Auswahl der $n^{\frac{3}{4}}$ Elemente wird wiederholt, falls $|S_0| \geq \frac{n}{2}$. Dies passiert gdw wir höchstens $\frac{1}{2}n^{\frac{3}{4}} - \sqrt{n}$ Elemente aus der Hälfte aller Elemente \leq dem Median auswählen.

Wir bestimmen die Wahrscheinlichkeit dafür, dass keine neue Auswahl der $n^{\frac{3}{4}}$ Elemente stattfinden muss.

Setze Bernoulli-Zufallsvariable X_1, \dots, X_n mit:

$$X_i = \begin{cases} 1, & \text{falls Element } i < \text{Median ausgewählt wird} \\ 0, & \text{sonst} \end{cases}$$

$X := \sum X_i$ ist binomialverteilt mit Parametern n und $\frac{1}{2}n^{-\frac{1}{4}}$, und $\mathbb{E}[X] = \frac{1}{2}n^{\frac{3}{4}}$, $\text{Var}[X] = n \cdot \frac{1}{2}n^{-\frac{1}{4}}(1 - \frac{1}{2}n^{-\frac{1}{4}}) = \frac{1}{2}n^{\frac{3}{4}}(1 - o(1))$.

Beweis (Forts.):

Die Wahrscheinlichkeit hierbei ist

$$\begin{aligned}\Pr[|S_0| \geq \frac{n}{2}] &= \Pr[X \leq \frac{1}{2}n^{\frac{3}{4}} - \sqrt{n}] \leq \Pr[|X - \mathbb{E}[X]| \geq \sqrt{n}] \\ &\leq \frac{\frac{1}{2}n^{\frac{3}{4}}(1 - o(1))}{n} \leq \frac{1}{2}n^{-\frac{1}{4}}(1 - o(1))\end{aligned}$$


Die anderen beiden Wahrscheinlichkeitsbedingungen ($\Pr[|S_2| \geq \lceil \frac{n}{2} \rceil]$ und $\Pr[|S_1| \geq 4 \cdot n^{\frac{3}{4}}]$) ergeben analoge Abschätzungen.

Damit: Wiederholung mit $WS \leq \mathcal{O}(n^{-\frac{1}{4}})$. □

4. Schönhage/Paterson/Pippenger-Median-Algorithmus

Definition 80


Sei $k \in \mathbb{N} \setminus \{0\}$. P_k ist die folgende partielle Ordnung:



Also: Spezielle Binomialbäume mit „Zentrum“.

Definition 81

- 1 Der Baum H_0 besteht aus einem Knoten, und dieser ist auch das Zentrum.
- 2 H_{2h} ($h > 0$) besteht aus zwei H_{2h-1} , deren Zentren durch eine neue Kante verbunden sind. Das Zentrum des H_{2h} ist das kleinere der beiden Zentren der H_{2h-1} .
- 3 H_{2h+1} ($h \geq 0$) besteht aus zwei H_{2h} , deren Zentren durch eine neue Kante verbunden sind, sein Zentrum ist das größere dieser beiden Zentren.




Lemma 82 (Zerlegungslemma)

- a) H_h hat 2^h Knoten, es werden $2^h - 1$ Vergleiche benötigt, um H_h zu konstruieren.
- b) H_{2h} kann zerlegt werden in
- sein Zentrum
 - eine Menge $\{H_1, H_3, \dots, H_{2h-1}\}$ von disjunkten Teilbäumen, deren Zentren alle größer sind als das Zentrum von H_{2h} .
 - eine Menge $\{H_0, H_2, H_4, \dots, H_{2h-2}\}$ von disjunkten Teilbäumen mit Zentren kleiner als das von H_{2h} .

Lemma 82 (Zerlegungslemma)

- c) H_{2k+1} kann so zerlegt werden, dass die Zusammenhangskomponente des Zentrums genau 2^k Knoten \geq dem Zentrum enthält, indem höchstens $2^{k+1} - 1$ Kanten entfernt werden.
 H_{2k} kann so zerlegt werden, dass die Zusammenhangskomponente des Zentrums genau 2^k Knoten enthält, die alle \leq dem Zentrum sind, indem höchstens $2^k - 1$ Kanten entfernt werden.
- d) Falls $k \leq 2^h - 1$, dann kann H_{2h} so zerlegt werden, dass die Zusammenhangskomponente des Zentrums genau $2k + 1$ Elemente enthält, von denen k größer und k kleiner als das Zentrum sind ($\Rightarrow P_k$).
Dazu genügt es, höchstens $3k + 2h$ Kanten zu entfernen. Die restlichen Zusammenhangskomponenten sind wieder H_i 's.


Zerlegungslemma




Bemerkung: Bei jedem Konstruktionsschritt wird ein Vergleich durchgeführt, um zu bestimmen, welcher der beiden Teilbäume das kleinere Zentrum hat. Im Algorithmus von Schönhage, Paterson und Pippenger werden aus Teilstücken H_r größere Bäume H_{r+1} zusammengebaut, wodurch schrittweise eine partielle Ordnung auf den Eingabewerten bestimmt wird. Wurde ein Baum H_{2^h} hinreichender Größe hergestellt, so wird er durch Zerlegung in einen Baum umgewandelt, der nur noch sein altes Zentrum sowie k darüberliegende und k darunterliegende Elemente enthält, wobei $k \leq 2^h - 1$.

Beispiel 83


In diesem Beispiel wollen wir H_4 zerlegen und wählen $k = 3$:



Um einen H_4 derart zu zerlegen, müssen wir 5 Kanten aufbrechen. Dabei werden drei H_0 , ein H_1 sowie ein H_2 abgespalten.



Übrig bleibt die gewünschte Struktur mit k Knoten über dem Zentrum und k unter dem Zentrum, wodurch eine partielle Ordnung auf $2k + 1$ Eingabewerten bestimmt wurde:



$2k + 1$ Elemente

Die bei der Zerlegung angefallenen Reststücke werden beim Aufbau weiterer Bäume benutzt. So geht das bereits angesammelte Wissen über die Ordnung der Elemente nicht verloren.

Beweis von a):

Wir beweisen nun die Teile a) bis d) des Zerlegungslemmas.

Lemma 84

H_r hat 2^r Knoten, es werden $2^r - 1$ Vergleiche benötigt, um H_r aufzubauen.

Beweis:

In jedem der r Konstruktionsschritte wird die Anzahl der Knoten verdoppelt. Da wir mit einem Knoten beginnen, hat H_r folglich 2^r Knoten. Die Anzahl der notwendigen Vergleiche C_r unterliegt folgender Rekursionsgleichung ($r \geq 1$):

$$C_r = 1 + 2C_{r-1} \text{ und } C_0 = 0.$$

Damit folgt sofort $C_r = 2^r - 1$. □

Beweis von b):

Lemma 85

H_r kann in folgende disjunkte Bereiche unterteilt werden:

- sein Zentrum,
- eine Reihe H_1, H_3, \dots, H_{r-1} (r gerade) bzw. \dots, H_{r-2} (r ungerade) von Unterbäumen, deren Zentren über dem von H_r liegen,
- eine Reihe H_0, H_2, \dots, H_{r-2} (r gerade) bzw. \dots, H_{r-1} (r ungerade) von Unterbäumen, deren Zentren unter dem von H_r liegen.

Beweis von b):

Beweis:

Durch Induktion über r .

Induktionsanfang: für H_0 gilt die Behauptung.

Induktionsannahme: die Behauptung gelte für H_{r-1} .

Beweis von b):

Beweis:

- ① Sei $r = 2h, h > 0$.

H_{2h} besteht aus zwei H_{2h-1} , wobei das kleinere der beiden alten Zentren das neue Zentrum z bildet. Wende auf den H_{2h-1} , der z enthält, die Induktionsannahme an. Wir können diesen Unterbaum also in z sowie $H_1, H_3, \dots, H_{2h-3}$ (Zentren **über** z) und $H_0, H_2, \dots, H_{2h-2}$ (Zentren **unter** z) partitionieren. Zusammen mit dem H_{2h-1} , dessen Zentrum über z liegt, ergibt sich die Induktionsbehauptung für H_{2h} .

Beweis von b):

Beweis:

- ② Sei $r = 2h + 1$, $h \geq 0$. H_{2h+1} besteht aus zwei H_{2h} , wobei das größere der beiden alten Zentren das neue Zentrum z bildet. Wende auf den H_{2h} , der z enthält, die Induktionsannahme an. Wir können diesen Unterbaum also in z sowie $H_1, H_3, \dots, H_{2h-1}$ (Zentren **über** z) und $H_0, H_2, \dots, H_{2h-2}$ (Zentren **unter** z) partitionieren. Zusammen mit dem H_{2h} , dessen Zentrum unter z liegt, ergibt sich die Induktionsbehauptung für H_{2h+1} .

