

## 4. Suchen

---

Lineare Suche, Binäre Suche, (Interpolationssuche,) Untere Schranken  
[Ottman/Widmayer, Kap. 3.2, Cormen et al, Kap. 2: Problems 2.1-3,2.2-3,2.3-5]

# Das Suchproblem

Gegeben

- Menge von Datensätzen.

Telefonverzeichnis, Wörterbuch, Symboltabelle

- Jeder Datensatz hat einen Schlüssel  $k$ .
- Schlüssel sind vergleichbar: eindeutige Antwort auf Frage  $k_1 \leq k_2$  für Schlüssel  $k_1, k_2$ .

Aufgabe: finde Datensatz nach Schlüssel  $k$ .

# Suche in Array

Gegeben

- Array  $A$  mit  $n$  Elementen ( $A[1], \dots, A[n]$ ).
- Schlüssel  $b$

Gesucht: Index  $k$ ,  $1 \leq k \leq n$  mit  $A[k] = b$  oder "nicht gefunden".

22	20	32	10	35	24	42	38	28	41
1	2	3	4	5	6	7	8	9	10

# Lineare Suche

Durchlaufen des Arrays von  $A[1]$  bis  $A[n]$ .

# Lineare Suche

Durchlaufen des Arrays von  $A[1]$  bis  $A[n]$ .

- **Bestenfalls** 1 Vergleich.

# Lineare Suche

Durchlaufen des Arrays von  $A[1]$  bis  $A[n]$ .

- **Bestenfalls** 1 Vergleich.
- **Schlimmstenfalls**  $n$  Vergleiche.

# Lineare Suche

Durchlaufen des Arrays von  $A[1]$  bis  $A[n]$ .

- **Bestenfalls** 1 Vergleich.
- **Schlimmstenfalls**  $n$  Vergleiche.
- Annahme: Jede Anordnung der  $n$  Schlüssel ist gleichwahrscheinlich.  
**Erwartete** Anzahl Vergleiche für die erfolgreiche Suche:

# Lineare Suche

Durchlaufen des Arrays von  $A[1]$  bis  $A[n]$ .

- **Bestenfalls** 1 Vergleich.
- **Schlimmstenfalls**  $n$  Vergleiche.
- Annahme: Jede Anordnung der  $n$  Schlüssel ist gleichwahrscheinlich.  
**Erwartete** Anzahl Vergleiche für die erfolgreiche Suche:

# Lineare Suche

Durchlaufen des Arrays von  $A[1]$  bis  $A[n]$ .

- **Bestenfalls** 1 Vergleich.
- **Schlimmstenfalls**  $n$  Vergleiche.
- Annahme: Jede Anordnung der  $n$  Schlüssel ist gleichwahrscheinlich.  
**Erwartete** Anzahl Vergleiche für die erfolgreiche Suche:

$$\frac{1}{n} \sum_{i=1}^n i = \frac{n+1}{2}.$$

# Suche im sortierten Array

Gegeben

- Sortiertes Array  $A$  mit  $n$  Elementen ( $A[1], \dots, A[n]$ ) mit  $A[1] \leq A[2] \leq \dots \leq A[n]$ .
- Schlüssel  $b$

Gesucht: Index  $k$ ,  $1 \leq k \leq n$  mit  $A[k] = b$  oder "nicht gefunden".

10	20	22	24	28	32	35	38	41	42
1	2	3	4	5	6	7	8	9	10

# Divide and Conquer!

Suche  $b = 23$ .

# Divide and Conquer!

Suche  $b = 23$ .

10	20	22	24	28	32	35	38	41	42
1	2	3	4	5	6	7	8	9	10

# Divide and Conquer!

Suche  $b = 23$ .

10	20	22	24	28	32	35	38	41	42
1	2	3	4	5	6	7	8	9	10

$b < 28$

A horizontal array of 10 cells containing the values 10, 20, 22, 24, 28, 32, 35, 38, 41, and 42. Below each cell is its index from 1 to 10. A vertical red line is drawn through the cell containing 28. Blue arrows point from the bottom of the first cell (index 1) to the right and from the bottom of the last cell (index 10) to the left, indicating a search range from index 1 to index 10.

# Divide and Conquer!

Suche  $b = 23$ .

10	20	22	24	28	32	35	38	41	42	$b < 28$
1	2	3	4	5	6	7	8	9	10	

10	20	22	24	28	32	35	38	41	42	$b > 20$
1	2	3	4	5	6	7	8	9	10	


# Divide and Conquer!

Suche  $b = 23$ .

10	20	22	24	28	32	35	38	41	42	$b < 28$
1	2	3	4	5	6	7	8	9	10	
10	20	22	24	28	32	35	38	41	42	$b > 20$
1	2	3	4	5	6	7	8	9	10	
10	20	22	24	28	32	35	38	41	42	$b > 22$
1	2	3	4	5	6	7	8	9	10	


# Divide and Conquer!

Suche  $b = 23$ .



# Divide and Conquer!

Suche  $b = 23$ .



**Input:** Sortiertes Array  $A$  von  $n$  Schlüsseln. Schlüssel  $b$ . Bereichsgrenzen

$1 \leq l, r \leq n$  mit  $l \leq r$  oder  $l = r + 1$ .

**Output:** Index  $m \in [l, \dots, r + 1]$ , so dass  $A[i] \leq b$  für alle  $l \leq i < m$  und

$A[i] \geq b$  für alle  $m < i \leq r$ .

$m \leftarrow \lfloor (l + r) / 2 \rfloor$

**if**  $l > r$  **then** // erfolglose Suche

**return**  $l$

**else if**  $b = A[m]$  **then** // gefunden

**return**  $m$

**else if**  $b < A[m]$  **then** // Element liegt links

**return** BSearch( $A, l, m - 1, b$ )

**else** //  $b > A[m]$ : Element liegt rechts

**return** BSearch( $A, m + 1, r, b$ )

# Analyse (schlechtester Fall)

Rekurrenz ( $n = 2^k$ )

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

Teleskopieren:

$$T(n) = T\left(\frac{n}{2}\right) + c$$

# Analyse (schlechtester Fall)

Rekurrenz ( $n = 2^k$ )

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

Teleskopieren:

$$T(n) = T\left(\frac{n}{2}\right) + c = T\left(\frac{n}{4}\right) + 2c$$

# Analyse (schlechtester Fall)

Rekurrenz ( $n = 2^k$ )

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

Teleskopieren:

$$\begin{aligned} T(n) &= T\left(\frac{n}{2}\right) + c = T\left(\frac{n}{4}\right) + 2c = \dots \\ &= T\left(\frac{n}{2^i}\right) + i \cdot c \end{aligned}$$

# Analyse (schlechtester Fall)

Rekurrenz ( $n = 2^k$ )

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

Teleskopieren:

$$\begin{aligned} T(n) &= T\left(\frac{n}{2}\right) + c = T\left(\frac{n}{4}\right) + 2c = \dots \\ &= T\left(\frac{n}{2^i}\right) + i \cdot c \\ &= T\left(\frac{n}{n}\right) + \log_2 n \cdot c = d + c \cdot \log_2 n \in \Theta(\log n) \end{aligned}$$

# Analyse (schlechtester Fall)

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

**Vermutung** :  $T(n) = d + c \cdot \log_2 n$

**Beweis durch Induktion:**

# Analyse (schlechtester Fall)

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

**Vermutung** :  $T(n) = d + c \cdot \log_2 n$

**Beweis durch Induktion:**

■ Induktionsanfang:  $T(1) = d$ .

# Analyse (schlechtester Fall)

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

**Vermutung** :  $T(n) = d + c \cdot \log_2 n$

**Beweis durch Induktion:**

- Induktionsanfang:  $T(1) = d$ .
- Hypothese:  $T(n/2) = d + c \cdot \log_2 n/2$

# Analyse (schlechtester Fall)

$$T(n) = \begin{cases} d & \text{falls } n = 1, \\ T(n/2) + c & \text{falls } n > 1. \end{cases}$$

**Vermutung** :  $T(n) = d + c \cdot \log_2 n$

**Beweis durch Induktion:**

- Induktionsanfang:  $T(1) = d$ .
- Hypothese:  $T(n/2) = d + c \cdot \log_2 n/2$
- Schritt ( $n/2 \rightarrow n$ )

$$T(n) = T(n/2) + c = d + c \cdot (\log_2 n - 1) + c = d + c \log_2 n.$$

## *Theorem 8*

*Der Algorithmus zur binären sortierten Suche benötigt  $\Theta(\log n)$  Elementarschritte.*

# Iterativer binärer Suchalgorithmus

**Input:** Sortiertes Array  $A$  von  $n$  Schlüsseln. Schlüssel  $b$ .

**Output:** Index des gefundenen Elements. 0, wenn erfolglos.

$l \leftarrow 1; r \leftarrow n$

**while**  $l \leq r$  **do**

$m \leftarrow \lfloor (l + r) / 2 \rfloor$

**if**  $A[m] = b$  **then**

**return**  $m$

**else if**  $A[m] < b$  **then**

$l \leftarrow m + 1$

**else**

$r \leftarrow m - 1$

**return** *NotFound*;

Algorithmus bricht nur ab, falls  $A[l..r]$  leer oder  $b$  gefunden.

**Invariante:** Falls  $b$  in  $A$ , dann im Bereich  $A[l..r]$


## **Beweis durch Induktion**

- Induktionsanfang:  $b \in A[1..n]$  (oder nicht)
- Hypothese: Invariante gilt nach  $i$  Schritten
- Schritt:
  - $b < A[m] \Rightarrow b \in A[l..m - 1]$
  - $b > A[m] \Rightarrow b \in A[m + 1..r]$

# Untere Schranke

Binäre Suche (im schlechtesten Fall):  $\Theta(\log n)$  viele Vergleiche.  
Gilt für *jeden* Suchalgorithmus in sortiertem Array (im schlechtesten Fall):  
Anzahl Vergleiche =  $\Omega(\log n)$ ?

# Entscheidungsbaum



- Für jede Eingabe  $b = A[i]$  muss Algorithmus erfolgreich sein  $\Rightarrow$  Baum enthält mindestens  $n$  Knoten.
- Anzahl Vergleiche im schlechtesten Fall = Höhe des Baumes = maximale Anzahl Knoten von Wurzel zu Blatt.

# Entscheidungsbaum

Binärer Baum der Höhe  $h$  hat höchstens  $2^0 + 2^1 + \dots + 2^{h-1} = 2^h - 1 < 2^h$  Knoten.

# Entscheidungsbaum

Binärer Baum der Höhe  $h$  hat höchstens  $2^0 + 2^1 + \dots + 2^{h-1} = 2^h - 1 < 2^h$  Knoten.

$$2^h > n \Rightarrow h > \log_2 n$$

Entscheidungsbaum mit  $n$  Knoten hat mindestens Höhe  $\log_2 n$ .

# Entscheidungsbaum

Binärer Baum der Höhe  $h$  hat höchstens  $2^0 + 2^1 + \dots + 2^{h-1} = 2^h - 1 < 2^h$  Knoten.

$$2^h > n \Rightarrow h > \log_2 n$$

Entscheidungsbaum mit  $n$  Knoten hat mindestens Höhe  $\log_2 n$ .  
Anzahl Entscheidungen =  $\Omega(\log n)$ .

## *Theorem 9*

*Jeder Algorithmus zur vergleichsbasierten Suche in sortierten Daten der Länge  $n$  benötigt im schlechtesten Fall  $\Omega(\log n)$  Vergleichsschritte.*

# Untere Schranke für Suchen in unsortiertem Array

## *Theorem 10*

*Jeder vergleichsbasierte Algorithmus zur Suche in **un**sortierten Daten der Länge  $n$  benötigt im schlechtesten Fall  $\Omega(n)$  Vergleichsschritte.*

Korrekt?


"Beweis": Um  $b$  in  $A$  zu finden, muss  $b$  mit jedem Element  $A[i]$  ( $1 \leq i \leq n$ ) verglichen werden.

Korrekt?

"Beweis": Um  $b$  in  $A$  zu finden, muss  $b$  mit jedem Element  $A[i]$  ( $1 \leq i \leq n$ ) verglichen werden.


Falsch! Vergleiche zwischen Elementen von  $A$  möglich!

# Besseres Argument




- Unterteilung der Vergleiche: Anzahl Vergleiche mit  $b$  :  $e$  Anzahl Vergleiche untereinander ohne  $b$  :  $i$
- Vergleiche erzeugen  $g$  Gruppen. Initial:  $g = n$ .

# Besseres Argument




- Unterteilung der Vergleiche: Anzahl Vergleiche mit  $b$  :  $e$  Anzahl Vergleiche untereinander ohne  $b$  :  $i$
- Vergleiche erzeugen  $g$  Gruppen. Initial:  $g = n$ .
- Vereinigen zweier Gruppen benötigt mindestens einen (internen Vergleich):  $n - g \leq i$ .

# Besseres Argument




- Unterteilung der Vergleiche: Anzahl Vergleiche mit  $b$  :  $e$  Anzahl Vergleiche untereinander ohne  $b$  :  $i$
- Vergleiche erzeugen  $g$  Gruppen. Initial:  $g = n$ .
- Vereinigen zweier Gruppen benötigt mindestens einen (internen Vergleich):  $n - g \leq i$ .

# Besseres Argument




- Unterteilung der Vergleiche: Anzahl Vergleiche mit  $b$  :  $e$  Anzahl Vergleiche untereinander ohne  $b$  :  $i$
- Vergleiche erzeugen  $g$  Gruppen. Initial:  $g = n$ .
- Vereinigen zweier Gruppen benötigt mindestens einen (internen Vergleich):  $n - g \leq i$ .

# Besseres Argument




- Unterteilung der Vergleiche: Anzahl Vergleiche mit  $b$  :  $e$  Anzahl Vergleiche untereinander ohne  $b$  :  $i$
- Vergleiche erzeugen  $g$  Gruppen. Initial:  $g = n$ .
- Vereinigen zweier Gruppen benötigt mindestens einen (internen Vergleich):  $n - g \leq i$ .

# Besseres Argument



- Unterteilung der Vergleiche: Anzahl Vergleiche mit  $b$  :  $e$  Anzahl Vergleiche untereinander ohne  $b$ :  $i$
- Vergleiche erzeugen  $g$  Gruppen. Initial:  $g = n$ .
- Vereinigen zweier Gruppen benötigt mindestens einen (internen Vergleich):  $n - g \leq i$ .
- Mindestens ein Element pro Gruppe muss mit  $b$  verglichen werden:  $e \geq g$ .

# Besseres Argument



- Unterteilung der Vergleiche: Anzahl Vergleiche mit  $b$  :  $e$  Anzahl Vergleiche untereinander ohne  $b$  :  $i$
- Vergleiche erzeugen  $g$  Gruppen. Initial:  $g = n$ .
- Vereinigen zweier Gruppen benötigt mindestens einen (internen Vergleich):  $n - g \leq i$ .
- Mindestens ein Element pro Gruppe muss mit  $b$  verglichen werden:  $e \geq g$ .
- Anzahl Vergleiche  $i + e \geq n - g + g = n$ . ■

## 5. Auswählen

---

Das Auswahlproblem, Randomisierte Berechnung des Medians, Lineare Worst-Case Auswahl [Ottman/Widmayer, Kap. 3.1, Cormen et al, Kap. 9]

# Das Auswahlproblem

Eingabe

- Unsortiertes Array  $A = (A_1, \dots, A_n)$  paarweise verschiedener Werte
- Zahl  $1 \leq k \leq n$ .

Ausgabe:  $A[i]$  mit  $|\{j : A[j] < A[i]\}| = k - 1$

## Spezialfälle

$k = 1$ : Minimum: Algorithmus mit  $n$  Vergleichsoperationen trivial.

$k = n$ : Maximum: Algorithmus mit  $n$  Vergleichsoperationen trivial.

$k = \lfloor n/2 \rfloor$ : Median.

# Naiver Algorithmus

# Naiver Algorithmus

Wiederholt das Minimum entfernen / auslesen:  $\Theta(k \cdot n)$ .  
→ Median in  $\Theta(n^2)$

# Bessere Ansätze


# Bessere Ansätze

- Sortieren (kommt bald):  $\Theta(n \log n)$

# Bessere Ansätze


- Sortieren (kommt bald):  $\Theta(n \log n)$
- Pivotieren:  $\Theta(n)$  !

# Pivotieren



# Pivotieren

1. Wähle ein (beliebiges) Element  $p$  als Pivotelement




# Pivotieren

1. Wähle ein (beliebiges) Element  $p$  als Pivotelement
2. Teile  $A$  in zwei Teile auf, bestimme dabei den Rang von  $p$ , indem die Anzahl der Indizes  $i$  mit  $A[i] \leq p$  gezählt werden.




# Pivotieren

1. Wähle ein (beliebiges) Element  $p$  als Pivotelement
2. Teile  $A$  in zwei Teile auf, bestimme dabei den Rang von  $p$ , indem die Anzahl der Indizes  $i$  mit  $A[i] \leq p$  gezählt werden.




# Pivotieren

1. Wähle ein (beliebiges) Element  $p$  als Pivotelement
2. Teile  $A$  in zwei Teile auf, bestimme dabei den Rang von  $p$ , indem die Anzahl der Indizes  $i$  mit  $A[i] \leq p$  gezählt werden.



# Pivotieren

1. Wähle ein (beliebiges) Element  $p$  als Pivotelement
2. Teile  $A$  in zwei Teile auf, bestimme dabei den Rang von  $p$ , indem die Anzahl der Indizes  $i$  mit  $A[i] \leq p$  gezählt werden.
3. Rekursion auf dem relevanten Teil. Falls  $k = r$ , dann gefunden.



# Algorithmus Partition( $A, l, r, p$ )

**Input:** Array  $A$ , welches den Pivot  $p$  in  $A[l, \dots, r]$  mindestens einmal enthält.

**Output:** Array  $A$  partitioniert in  $A[l, \dots, r]$  um  $p$ . Rückgabe der Position von  $p$ .

**while**  $l \leq r$  **do**

**while**  $A[l] < p$  **do**

$l \leftarrow l + 1$

**while**  $A[r] > p$  **do**

$r \leftarrow r - 1$

    swap( $A[l], A[r]$ )

**if**  $A[l] = A[r]$  **then**

$l \leftarrow l + 1$

**return**  $l-1$

# Korrektheit: Invariante

Invariante  $I$ :  $A_i \leq p \forall i \in [0, l), A_i \geq p \forall i \in (r, n], \exists k \in [l, r] : A_k = p$ .

**while**  $l \leq r$  **do**

**while**  $A[l] < p$  **do**

$l \leftarrow l + 1$

**while**  $A[r] > p$  **do**

$r \leftarrow r - 1$

$\text{swap}(A[l], A[r])$

**if**  $A[l] = A[r]$  **then**

$l \leftarrow l + 1$

$I$

$I$  und  $A[l] \geq p$

$I$  und  $A[r] \leq p$

$I$  und  $A[l] \leq p \leq A[r]$

$I$

**return**  $l-1$

# Korrektheit: Fortschritt

<b>while</b> $l \leq r$ <b>do</b>	
<b>while</b> $A[l] < p$ <b>do</b>	Fortschritt wenn $A[l] < p$
$l \leftarrow l + 1$	
<b>while</b> $A[r] > p$ <b>do</b>	Fortschritt wenn $A[r] > p$
$r \leftarrow r - 1$	
swap( $A[l], A[r]$ )	Fortschritt wenn $A[l] > p$ oder $A[r] < p$
<b>if</b> $A[l] = A[r]$ <b>then</b>	Fortschritt wenn $A[l] = A[r] = p$
$l \leftarrow l + 1$	
<b>return</b> $l-1$	

# Wahl des Pivots

Das Minimum ist ein schlechter Pivot: worst Case  $\Theta(n^2)$



# Wahl des Pivots

Das Minimum ist ein schlechter Pivot: worst Case  $\Theta(n^2)$



# Wahl des Pivots

Das Minimum ist ein schlechter Pivot: worst Case  $\Theta(n^2)$



# Wahl des Pivots

Das Minimum ist ein schlechter Pivot: worst Case  $\Theta(?)$




# Wahl des Pivots

Das Minimum ist ein schlechter Pivot: worst Case  $\Theta(n^2)$




# Wahl des Pivots

Das Minimum ist ein schlechter Pivot: worst Case  $\Theta(n^2)$



Ein guter Pivot hat linear viele Elemente auf beiden Seiten.




# Analyse

Unterteilung mit Faktor  $q$  ( $0 < q < 1$ ): zwei Gruppen mit  $q \cdot n$  und  $(1 - q) \cdot n$  Elementen (ohne Einschränkung  $q \geq 1 - q$ ).

$$\begin{aligned}T(n) &\leq T(q \cdot n) + c \cdot n \\&\leq c \cdot n + q \cdot c \cdot n + T(q^2 \cdot n) \leq \dots = c \cdot n \sum_{i=0}^{\log_q(n)-1} q^i + T(1) \\&\leq c \cdot n \underbrace{\sum_{i=0}^{\infty} q^i}_{\text{geom. Reihe}} + d = c \cdot n \cdot \frac{1}{1 - q} + d = \mathcal{O}(n)\end{aligned}$$

# Wie bekommen wir das hin?

Der Zufall hilft uns (Tony Hoare, 1961). Wähle in jedem Schritt einen zufälligen Pivot.



Wahrscheinlichkeit für guten Pivot nach einem Versuch:  $\frac{1}{2} =: \rho$ .

Wahrscheinlichkeit für guten Pivot nach  $k$  Versuchen:  $(1 - \rho)^{k-1} \cdot \rho$ .

Erwartete Anzahl Versuche:  $1/\rho = 2$  (Erwartungswert der geometrischen Verteilung:)

# Algorithmus Quickselect ( $A, l, r, k$ )

**Input:** Array  $A$  der Länge  $n$ . Indizes  $1 \leq l \leq k \leq r \leq n$ , so dass für alle

$x \in A[l..r] : |\{j | A[j] \leq x\}| \geq l$  und  $|\{j | A[j] \leq x\}| \leq r$ .

**Output:** Wert  $x \in A[l..r]$  mit  $|\{j | A[j] \leq x\}| \geq k$  und  $|\{j | x \leq A[j]\}| \geq n - k + 1$

**if**  $l=r$  **then**

  | return  $A[l]$ ;

$x \leftarrow$  RandomPivot( $A, l, r$ )

$m \leftarrow$  Partition( $A, l, r, x$ )

**if**  $k < m$  **then**

  | return QuickSelect( $A, l, m - 1, k$ )

**else if**  $k > m$  **then**

  | return QuickSelect( $A, m + 1, r, k$ )

**else**

  | return  $A[k]$

# Algorithmus RandomPivot ( $A, l, r$ )

**Input:** Array  $A$  der Länge  $n$ . Indizes  $1 \leq l \leq r \leq n$

**Output:** Zufälliger “guter” Pivot  $x \in A[l, \dots, r]$

**repeat**

    wähle zufälligen Pivot  $x \in A[l..r]$

$p \leftarrow l$

**for**  $j = l$  **to**  $r$  **do**

**if**  $A[j] \leq x$  **then**  $p \leftarrow p + 1$

**until**  $\lfloor \frac{3l+r}{4} \rfloor \leq p \leq \lceil \frac{l+3r}{4} \rceil$

**return**  $x$

*Dieser Algorithmus ist nur von theoretischem Interesse und liefert im Erwartungswert nach 2 Durchläufen einen guten Pivot. Praktisch kann man im Algorithmus Quickselect direkt einen zufälligen Pivot uniformverteilt ziehen oder einen deterministischen Pivot wählen, z.B. den Median von drei Elementen.*

# Median der Mediane

Ziel: Finde einen Algorithmus, welcher im schlechtesten Fall nur linear viele Schritte benötigt.

Algorithmus Select ( $k$ -smallest)

- Fünfergruppen bilden.
- Median jeder Gruppe bilden (naiv).
- Select rekursiv auf den Gruppenmedianen.
- Partitioniere das Array um den gefundenen Median der Mediane.  
Resultat:  $i$
- Wenn  $i = k$ , Resultat. Sonst: Select rekursiv auf der richtigen Seite.

# Median der Mediane



# Median der Mediane




1. Fünfergruppen

# Median der Mediane




1. Fünfergruppen
2. Mediane

# Median der Mediane




1. Fünfergruppen
2. Mediane
3. Rekursion für Pivot!

# Median der Mediane




1. Fünfergruppen
2. Mediane
3. Rekursion für Pivot!


# Median der Mediane



# Median der Mediane




# Median der Mediane




1. Fünfergruppen
2. Mediane
3. Rekursion für Pivot!
4. Basisfall.
5. Pivot (Level 1)

# Median der Mediane




# Median der Mediane



1. Fünfergruppen
2. Mediane
3. Rekursion für Pivot!
4. Basisfall.
5. Pivot (Level 1)
6. Partition (Level 1)
7. Median = Pivot Level 0

# Median der Mediane



# Algorithmus MMSelect( $A, l, r, k$ )

**Input:** Array  $A$  der Länge  $n$  mit paarweise verschiedenen Einträgen.

$1 \leq l \leq k \leq r \leq n$ ,  $A[i] < A[k] \forall 1 \leq i < l$ ,  $A[i] > A[k] \forall r < i \leq n$

**Output:** Wert  $x \in A$  mit  $|\{j | A[j] \leq x\}| = k$

$m \leftarrow \text{MMChoose}(A, l, r)$

$i \leftarrow \text{Partition}(A, l, r, m)$

**if**  $k < i$  **then**

  | **return** MMSelect( $A, l, i - 1, k$ )

**else if**  $k > i$  **then**

  | **return** MMSelect( $A, i + 1, r, k$ )

**else**

  | **return**  $A[i]$

# Algorithmus MMChoose( $A, l, r$ )

**Input:** Array  $A$  der Länge  $n$  mit paarweise verschiedenen Einträgen.

$$1 \leq l \leq r \leq n.$$

**Output:** Median  $m$  der Mediane

**if**  $r - l \leq 5$  **then**


| return MedianOf5( $A[l, \dots, r]$ )

**else**

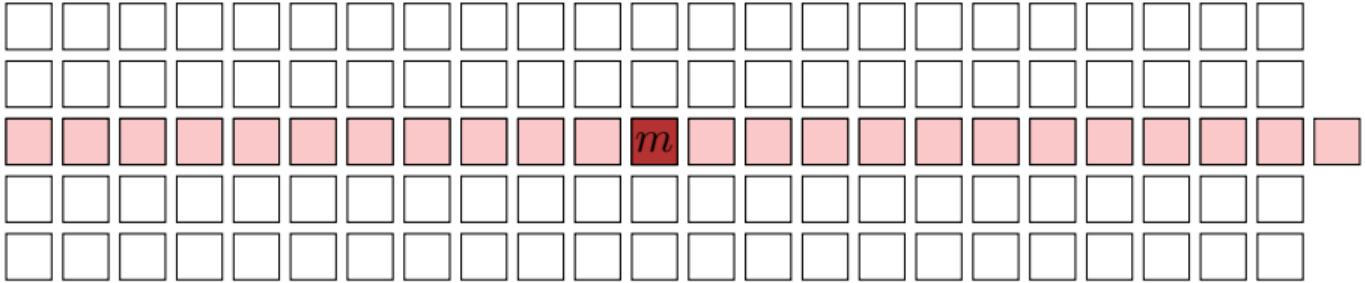
|  $A' \leftarrow$  MedianOf5Array( $A[l, \dots, r]$ )

| **return** MMSelect( $A', 1, |A'|, \lfloor \frac{|A'|}{2} \rfloor$ )

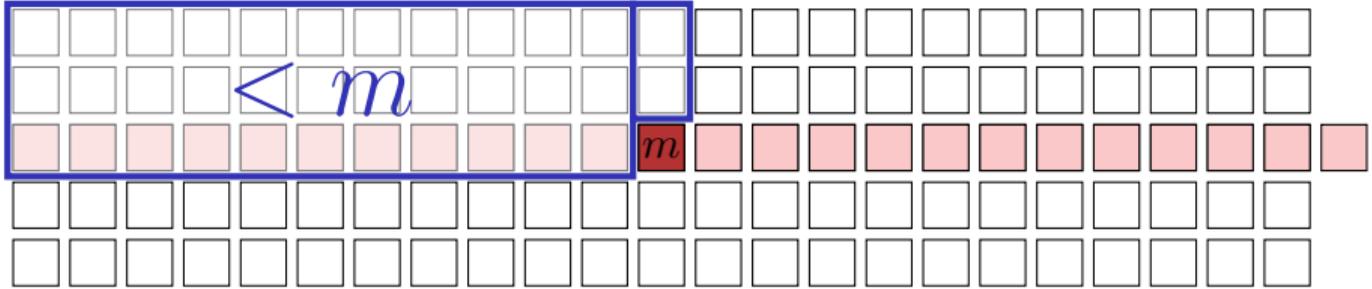
# Was bringt das?



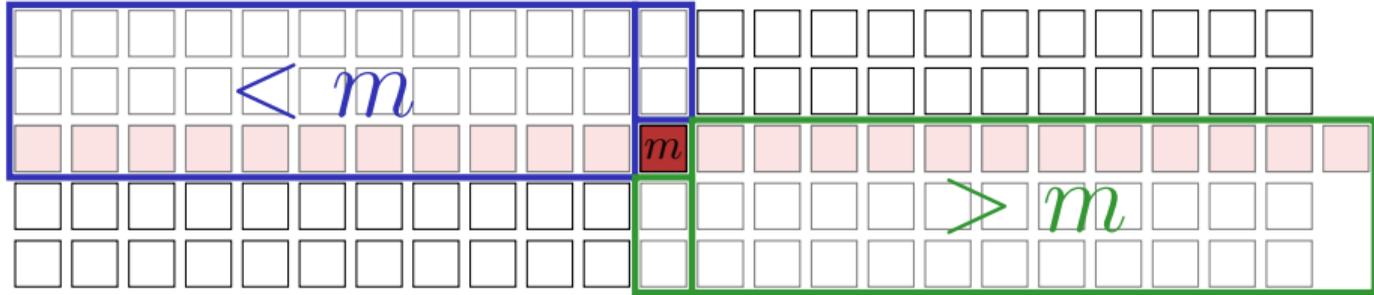
# Was bringt das?




# Was bringt das?



# Was bringt das?



# Was bringt das?

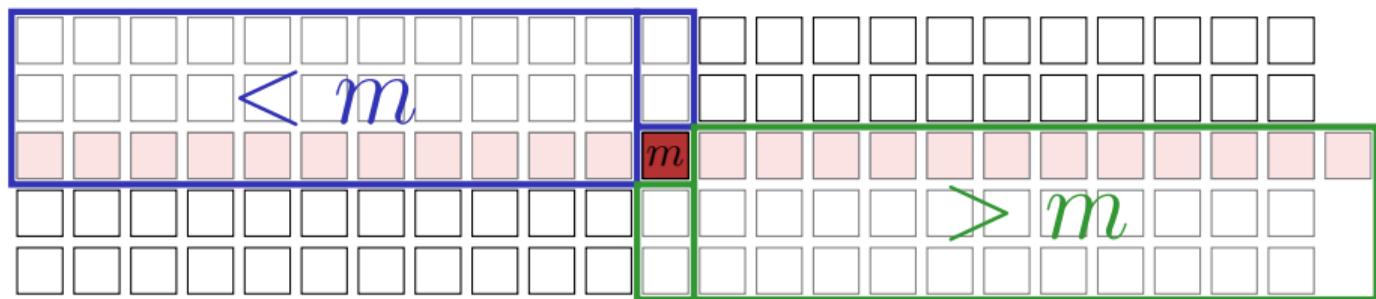


- Anzahl Fünfergruppen:  $\lceil \frac{n}{5} \rceil$ , ohne Mediengruppe:  $\lceil \frac{n}{5} \rceil - 1$
- Minimale Anzahl Gruppen links / rechts von Mediengruppe  $\lfloor \frac{1}{2} (\lceil \frac{n}{5} \rceil - 1) \rfloor$
- Minimale Anzahl Punkte kleiner / grösser als  $m$

$$3 \left\lfloor \frac{1}{2} (\lceil \frac{n}{5} \rceil - 1) \right\rfloor \geq 3 \left\lfloor \frac{1}{2} (\frac{n}{5} - 1) \right\rfloor \geq 3 \left( \frac{n}{10} - \frac{1}{2} - 1 \right) > \frac{3n}{10} - 6$$

(Fülle Restgruppe konzeptuell mit Punkten aus Mediengruppe auf)

# Was bringt das?



- Anzahl Fünfergruppen:  $\lceil \frac{n}{5} \rceil$ , ohne Mediengruppe:  $\lceil \frac{n}{5} \rceil - 1$
- Minimale Anzahl Gruppen links / rechts von Mediengruppe  $\lfloor \frac{1}{2} (\lceil \frac{n}{5} \rceil - 1) \rfloor$
- Minimale Anzahl Punkte kleiner / grösser als  $m$

$$3 \left\lfloor \frac{1}{2} (\lceil \frac{n}{5} \rceil - 1) \right\rfloor \geq 3 \left\lfloor \frac{1}{2} (\frac{n}{5} - 1) \right\rfloor \geq 3 \left( \frac{n}{10} - \frac{1}{2} - 1 \right) > \frac{3n}{10} - 6$$

(Fülle Restgruppe konzeptuell mit Punkten aus Mediengruppe auf)

⇒ Rekursiver Aufruf mit maximal  $\lceil \frac{7n}{10} + 6 \rceil$  Elementen.

Rekursionsungleichung:

$$T(n) \leq T\left(\left\lceil \frac{n}{5} \right\rceil\right) + T\left(\left\lceil \frac{7n}{10} + 6 \right\rceil\right) + d \cdot n.$$

mit einer Konstanten  $d$ .

Behauptung:

$$T(n) = \mathcal{O}(n).$$

# Beweis

Induktionsanfang:<sup>7</sup> Wähle  $c$  so gross, dass

$$T(n) \leq c \cdot n \text{ für alle } n \leq n_0.$$

Induktionsannahme :  $H(n)$

$$T(i) \leq c \cdot i \text{ für alle } i < n.$$

Induktionsschritt:  $H(k)_{k < n} \rightarrow H(n)$

$$\begin{aligned} T(n) &\leq T\left(\left\lceil \frac{n}{5} \right\rceil\right) + T\left(\left\lceil \frac{7n}{10} + 6 \right\rceil\right) + d \cdot n \\ &\leq c \cdot \left\lceil \frac{n}{5} \right\rceil + c \cdot \left\lceil \frac{7n}{10} + 6 \right\rceil + d \cdot n \quad (\text{für } n > 20). \end{aligned}$$

---

<sup>7</sup>Es wird sich im Induktionsschritt herausstellen, dass der Basisfall für alle  $n \leq n_0$  und ein bestimmtes (aber festes)  $n_0 > 0$  betrachtet werden muss. Da  $c$  beliebig gross gewählt werden darf und eine beschränkte Anzahl von Termen eingeht, ist das eine einfache Erweiterung des Basisfalles  $n = 1$

# Beweis

Induktionsschritt:

$$\begin{aligned} T(n) &\stackrel{n>20}{\leq} c \cdot \left\lceil \frac{n}{5} \right\rceil + c \cdot \left\lceil \frac{7n}{10} + 6 \right\rceil + d \cdot n \\ &\leq c \cdot \frac{n}{5} + c + c \cdot \frac{7n}{10} + 6c + c + d \cdot n = \frac{9}{10} \cdot c \cdot n + 8c + d \cdot n. \end{aligned}$$

Zu zeigen

$$\exists n_0, \exists c \quad \left| \quad \frac{9}{10} \cdot c \cdot n + 8c + d \cdot n \leq cn \quad \forall n \geq n_0 \right.$$

Also

$$8c + d \cdot n \leq \frac{1}{10}cn \quad \Leftrightarrow \quad n \geq \frac{80c}{c - 10d}$$


Setze z.B.  $c = 90d, n_0 = 91 \quad \Rightarrow T(n) \leq cn \quad \forall n \geq n_0$  ■

## *Theorem 11*

*Das  $i$ -te Element einer Folge von  $n$  Elementen kann im schlechtesten Fall in  $\Theta(n)$  Schritten gefunden werden.*

# Überblick

- |                                     |                                      |
|-------------------------------------|--------------------------------------|
| 1. Wiederholt Minimum finden        | $\mathcal{O}(n^2)$                   |
| 2. Sortieren und $A[i]$ ausgeben    | $\mathcal{O}(n \log n)$              |
| 3. Quickselect mit zufälligem Pivot | $\mathcal{O}(n)$ im Mittel           |
| 4. Median of Medians (Blum)         | $\mathcal{O}(n)$ im schlimmsten Fall |



## 5.1 Anhang

---

Herleitung einiger mathematischen Formeln

# [Erwartungswert der geometrischen Verteilung]

Zufallsvariable  $X \in \mathbb{N}^+$  mit  $\mathbb{P}(X = k) = (1 - p)^{k-1} \cdot p$ .

Erwartungswert

$$\begin{aligned}\mathbb{E}(X) &= \sum_{k=1}^{\infty} k \cdot (1 - p)^{k-1} \cdot p = \sum_{k=1}^{\infty} k \cdot q^{k-1} \cdot (1 - q) \\ &= \sum_{k=1}^{\infty} k \cdot q^{k-1} - k \cdot q^k = \sum_{k=0}^{\infty} (k + 1) \cdot q^k - k \cdot q^k \\ &= \sum_{k=0}^{\infty} q^k = \frac{1}{1 - q} = \frac{1}{p}.\end{aligned}$$