

# Diskrete Mathematik

**Univ.-Prof. Dr. Goulmara ARZHANTSEVA**

SS 2018



universität  
wien

# Sortieralgorithmen

- 1 Sortieren durch Einfügen
- 2 Mergesort
- 3 Quicksort

# Sortieren durch Einfügen

Wir beginnen mit dem ersten Element der Liste, das eine geordnete Liste ( $a_1$ ) darstellt.

Wenn wir die ersten  $i$  Elemente in die richtige Ordnung

$$b_1 < b_2 < \dots < b_i$$

gebracht haben, dann fügen wir im folgenden Schritt  $a_{i+1}$  mit **Binary search** in die richtige Stelle ein.

## Sortieren durch Einfügen: $B(n)$

Im **schlechtesten Fall** ist also die Gesamtzahl  $B(n)$  der benötigten Vergleiche gemäß 'Binary search'

$$B(n) = \sum_{i=2}^n \lceil \log_2 i \rceil .$$

Diese Summe kann man explizit ausrechnen:

## Sortieren durch Einfügen: $B(n)$

Im **schlechtesten Fall** ist also die Gesamtzahl  $B(n)$  der benötigten Vergleiche gemäß 'Binary search'

$$B(n) = \sum_{i=2}^n \lceil \log_2 i \rceil .$$

Diese Summe kann man explizit ausrechnen:

Schreiben wir  $n$  als  $n = 2^m + r$  für natürliche Zahlen  $m$  und  $r$ , sodaß  $0 < r \leq 2^m$ . Es gilt

$$\lceil \log_2 i \rceil = k \iff 2^{k-1} < i \leq 2^k .$$

Wir partitionieren also den Summationsbereich, den  $i$  durchläuft, in die Blöcke  $\{2\}$ ,  $\{3, 4\}$ ,  $\{5, 6, 7, 8\}$ ,  $\dots$ ,  $\{2^m + 1, \dots, n\}$ .

# Sortieren durch Einfügen: $B(n)$

Im **schlechtesten Fall** ist also die Gesamtzahl  $B(n)$  der benötigten Vergleiche gemäß 'Binary search'

$$B(n) = \sum_{i=2}^n \lceil \log_2 i \rceil.$$

Diese Summe kann man explizit ausrechnen:

Schreiben wir  $n$  als  $n = 2^m + r$  für natürliche Zahlen  $m$  und  $r$ , sodaß  $0 < r \leq 2^m$ . Es gilt

$$\lceil \log_2 i \rceil = k \iff 2^{k-1} < i \leq 2^k.$$

Wir partitionieren also den Summationsbereich, den  $i$  durchläuft, in die Blöcke  $\{2\}$ ,  $\{3, 4\}$ ,  $\{5, 6, 7, 8\}$ ,  $\dots$ ,  $\{2^m + 1, \dots, n\}$ . Im Bereich  $\{2^{k-1} + 1, \dots, 2^k\}$  ist  $\lceil \log_2 i \rceil$  konstant gleich  $k$ . Der Beitrag den dieser Bereich für die Summe liefert ist daher  $2^{k-1} \cdot k$ . Insgesamt erhalten wir

$$B(n) = \sum_{k=1}^m k \cdot 2^{k-1} + (n - 2^m)(m + 1).$$

## Sortieren durch Einfügen: $B(n)$

Wenn wir die (abbrechende) geometrischen Reihe

$$\sum_{k=0}^m x^k = \frac{1 - x^{m+1}}{1 - x}$$

differenzieren, erhalten wir

$$\sum_{k=0}^m k \cdot x^{k-1} = \frac{1 - (m+1)x^m + mx^{m+1}}{(1-x)^2}.$$

Wenn wir in dieser Formel  $x = 2$  setzen, erhalten wir also zunächst

$$\sum_{k=1}^m k \cdot 2^{k-1} = 1 + (m-1)2^m,$$

und damit schließlich für  $B(n)$

$$B(n) = n(m+1) - 2^{m+1} + 1$$

oder, wenn wir  $m$  wieder durch  $n$  ausdrücken,

$$B(n) = n \lceil \log_2 n \rceil - 2^{\lceil \log_2 n \rceil} + 1.$$

## Sortieren durch Einfügen: $B(n)$

Noch einmal:

$$B(n) = n \lceil \log_2 n \rceil - 2^{\lceil \log_2 n \rceil} + 1.$$

Im Vergleich mit der Größenordnung der [informationstheoretischen Schranke](#) ist das nicht schlecht:

Der führende Term  $n \lceil \log_2 n \rceil$  ist gleich, nur der nächste Term ist kleiner, denn  $-2^{\lceil \log_2 n \rceil}$  ist ungefähr  $-n$ , während  $-n \log_2 e$  ungefähr  $-1.44 n$  ist.

# Mergesort

Eine andere Idee besteht darin, das Sortieren **rekursiv** aufzubauen:

Wir teilen die  $n$  Elemente  $a_1, a_2, \dots, a_n$  in zwei ungefähr gleich große Hälften, sortieren beide Hälften (rekursiv) nach derselben Methode, und fügen am Schluß die beiden (dann geordneten) Listen zusammen.

Dieser Algorithmus heißt **Sortieren durch Zusammenlegen** (englisch: **Merge-Sort**).

# Mergesort

Eine andere Idee besteht darin, das Sortieren **rekursiv** aufzubauen:

Wir teilen die  $n$  Elemente  $a_1, a_2, \dots, a_n$  in zwei ungefähr gleich große Hälften, sortieren beide Hälften (rekursiv) nach derselben Methode, und fügen am Schluß die beiden (dann geordneten) Listen zusammen.

Dieser Algorithmus heißt **Sortieren durch Zusammenlegen** (englisch: **Merge-Sort**).

Das Zusammenlegen erfordert aber einige Vergleiche:

Seien die Listen  $b_1 < b_2 < \dots < b_m$  und  $c_1 < c_2 < \dots < c_k$  gegeben, die wir in der richtigen Reihenfolge zusammenfügen sollen. Das Zusammenfügen können wir “reißverschlußartig” durchführen, also durch folgenden Algorithmus:

# Merge-Sort

---

{Initialisierung:}

1:  $b \leftarrow (b_1, b_2, \dots, b_m)$ ,  $c \leftarrow (c_1, c_2, \dots, c_k)$  und  $l \leftarrow ()$  ( $l$  ist die leere Liste).

{Schleife: Wird wiederholt, solange die Bedingung erfüllt ist.}

2: **while** (Bedingung: **Beide** Listen  $b$  und  $c$  sind nicht leer.) **do**

3:   Vergleiche die ersten Elemente  $b'$  und  $c'$  von  $b$  und  $c$ ; sei  $x$  das kleinere der beiden.

4:   Füge  $x$  hinten an die Liste  $l$  an {Bemerke, daß  $l$  stets richtig geordnet ist!}

5:   Entferne  $x$  aus seiner "alten" Liste (d.h., wenn  $x = b'$ , dann setze  $b \leftarrow b \setminus x$ ).

6: **end while**{Zum Schluß}

7: Falls eine der Listen  $b$ ,  $c$  nicht leer ist, füge sie an  $l$  hinten an:  $l$  ist dann die aus den ursprünglichen Listen  $b$  und  $c$  zusammengefügte geordnete Liste.

# Merge-Sort: Worst-Case Analyse

Wir brauchen für dieses Zusammenfügen im schlechtesten Fall  $m + k - 1$  Vergleiche.

Sei  $M(n)$  die Gesamtzahl der Vergleiche, die Mergesort im schlechtesten Fall für die Liste  $(a_1, a_2, \dots, a_n)$  benötigt.

Dann erhalten wir die **Rekursion**<sup>1</sup>

$$M(n) = M(\lfloor n/2 \rfloor) + M(\lceil n/2 \rceil) + n - 1.$$

Denn wir müssen zuerst die beiden Hälften mit  $\lfloor n/2 \rfloor$  und  $\lceil n/2 \rceil$  Elementen ordnen und brauchen dann schlimmstenfalls noch weitere  $n - 1$  Vergleiche, um die beiden geordneten Hälften zusammenzufügen.

---

<sup>1</sup>Das ist nicht “nur” eine obere Schranke für den worst-case, sondern der “echte” worst-case!

# Merge-Sort: Worst-Case Analyse vs $\lceil \log_2 n! \rceil$

Mit **Induktion**:  $M(n) = B(n)$  für alle  $n$ . Wir vergleichen  $M(n) = B(n)$  mit der informationstheoretischen Schranke  $\lceil \log_2 n! \rceil$ :

$n$	2	3	4	5	6	7	8	9	10	11	12
$\lceil \log_2 n! \rceil$	1	3	5	7	10	13	16	19	22	26	29
$B(n) = M(n)$	1	3	5	8	11	14	17	21	25	29	33

Für  $n \leq 11$  kann man tatsächlich Algorithmen konstruieren, die mit  $\lceil \log_2 n! \rceil$  Vergleichen auskommen.

Für  $n = 12$  hat eine Computer-Suche ergeben, daß die Minimalzahl 30 ist, also um 1 größer als die informationstheoretische Schranke.

# Quicksort–Algorithmus

Wir teilen wir die  $n$  Elemente wieder in zwei Teile, diesmal aber so, daß die Elemente **in einem Teil alle kleiner** sind als die Elemente **im anderen Teil**; ordnen jeden der Teile (rekursiv) nach derselben Methode; und fügen die Teile dann (ohne zusätzliche Arbeit wie bei Mergesort) wieder aneinander.

# Quicksort–Algorithmus

Wir teilen wir die  $n$  Elemente wieder in zwei Teile, diesmal aber so, daß die Elemente **in einem Teil alle kleiner** sind als die Elemente **im anderen Teil**; ordnen jeden der Teile (rekursiv) nach derselben Methode; und fügen die Teile dann (ohne zusätzliche Arbeit wie bei Mergesort) wieder aneinander.

Wenn wir annehmen, daß die Liste im Computer als **Vektor**

$$a = (a_1, \dots, a_n)$$

gespeichert ist (daß wir also insbesondere zwei Komponenten des Vektors vertauschen können und zu jeder Komponente des Vektors den linken bzw. rechten Nachbarn — sofern vorhanden — bestimmen können), dann können wir diese Aufteilung algorithmisch so vornehmen, daß **kein zusätzlicher Speicherplatz für die zwei Teile benötigt wird**:

# Quicksort–Algorithmus

---

{Initialisierung:}

- 1: Markiere die **letzte** Koordinate (i.e.:  $a_n$ ) des Vektors.  
{Schleife: Wird wiederholt, solange die Bedingung erfüllt ist.}
  - 2: **while** (Bedingung: Die Koordinate  $a_1$  ist nicht markiert.) **do**
  - 3: Sei  $x$  das markierte Element.
  - 4: **if** ( $a_1$  steht links von  $x$  UND  $a_1 > x$ ) ODER ( $a_1$  steht rechts von  $x$  UND  $a_1 \leq x$ ) **then**
  - 5: vertausche  $a_1$  und  $x$  (die Markierung “wandert dabei mit”)
  - 6: **end if**
  - 7: Bewege die Markierung um eine Stelle in Richtung von Element  $a_1$  (nach rechts, wenn  $a_1$  rechts von  $x$  steht, sonst nach links).
  - 8: **end while**
-

# Quicksort: $n = 9$

(aus Skriptum)

$a_1 = 4$  wird durch einen Kreis gekennzeichnet, die Markierung durch ein kleines Dreieck:

4	8	9	5	2	1	6	7	3
3	8	9	5	2	1	6	7	4
3	4	9	5	2	1	6	7	8
3	4	9	5	2	1	6	7	8
3	4	9	5	2	1	6	7	8
3	1	9	5	2	4	6	7	8
3	1	4	5	2	9	6	7	8
3	1	2	5	4	9	6	7	8
3	1	2	4	5	9	6	7	8

# Quicksort: Worst-Case Analyse

Es ist klar, daß dieser Algorithmus nach  $n - 1$  Schritten abbricht.

Wenn wir  $a_1$  und das markierte Element  $x$  als “Grenzen” (also als erstes/letztes Element) eines “Intervalls” (oder Teilvektors)  $I$  von  $a$  betrachten, dann nach jedem Schritt des Algorithmus **links** von  $I$  nur Elemente kleiner  $a_1$  stehen und **rechts** von  $I$  nur Elemente größergleich  $a_1$  (denn zu Beginn ist dies leererweise richtig, und in jedem Wiederholungsschritt wird dieser Zustand aufrechterhalten).

# Quicksort: Worst-Case Analyse

Es ist klar, daß dieser Algorithmus nach  $n - 1$  Schritten abbricht.

Wenn wir  $a_1$  und das markierte Element  $x$  als “Grenzen” (also als erstes/letztes Element) eines “Intervalls” (oder Teilvektors)  $I$  von  $a$  betrachten, dann nach jedem Schritt des Algorithmus **links** von  $I$  nur Elemente kleiner  $a_1$  stehen und **rechts** von  $I$  nur Elemente größergleich  $a_1$  (denn zu Beginn ist dies leererweise richtig, und in jedem Wiederholungsschritt wird dieser Zustand aufrechterhalten).

Damit ist weiters klar, daß nach Abbruch des Algorithmus

- alle Elemente, die links von  $a_1$  stehen, kleiner sind als  $a_1$  — diese bilden also den **einen** Teil der Liste,
- alle Elemente, die rechts von  $a_1$  stehen, größergleich sind als  $a_1$  — diese bilden also den **anderen** Teil der Liste).

## Quicksort: Worst-Case Analyse

Auf diese beiden Teil-Listen wird dann dasselbe Verfahren **rekursiv** angewendet (wenn sie mehr als ein Element beinhalten), bis die ganze Liste richtig geordnet ist.

# Quicksort: Worst-Case Analyse

Auf diese beiden Teil-Listen wird dann dasselbe Verfahren **rekursiv** angewendet (wenn sie mehr als ein Element beinhalten), bis die ganze Liste richtig geordnet ist.

Die **Worst-Case Analyse** von Quicksort fällt sehr schlecht aus: Wenn die Liste  $a$  zufälligerweise bereits total geordnet sein sollte, also

$$a_1 < a_2 < \dots < a_n,$$

dann wird die Liste in jedem rekursiven Schritt stets

- in die **leere** Liste (die Teil-Liste der Elemente kleiner als das erste Element),
- und in die ursprüngliche Liste ohne ihr erstes Element (die Teil-Liste der Elemente größergleich dem ersten Element, ohne das erste Element selbst)

zerlegt. In diesem Fall benötigen wir also  $(n-1) + (n-2) + \dots + 1 = \binom{n}{2}$  Vergleiche — das sind **alle** Vergleiche von 2 Elementen aus  $a$ !

# Quicksort: Average-Case Analyse

Sei  $Q(n)$  die **durchschnittliche Anzahl** von Vergleichen, die Quicksort für eine Liste  $a$  der Länge  $n$  benötigt.

Das erste Element  $a_1$  ist jeweils mit Wahrscheinlichkeit  $1/n$  das kleinste, das zweitkleinste,  $\dots$ , oder das größte Element.

Wenn  $a_1$  das  **$s$ -kleinste Element** in  $a$  ist, dann erhalten wir eine Aufteilung in  $s - 1$  (die kleineren) und  $n - s$  (die größeren) Elemente; für jeden der Teile wiederholen wir rekursiv die Prozedur.

## Quicksort: Average-Case Analyse

Zusammen mit den  $n - 1$  Vergleichen mit  $a_1$  erhalten wir also die Rekursion

$$Q(n) = n - 1 + \frac{1}{n} \sum_{s=1}^n (Q(s-1) + Q(n-s))$$

mit dem Anfangswert  $Q(0) = 0$ . Die rechte Seite können wir vereinfachen:

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

# Quicksort: Average-Case Analyse

Zusammen mit den  $n - 1$  Vergleichen mit  $a_1$  erhalten wir also die Rekursion

$$Q(n) = n - 1 + \frac{1}{n} \sum_{s=1}^n (Q(s - 1) + Q(n - s))$$

mit dem Anfangswert  $Q(0) = 0$ . Die rechte Seite können wir vereinfachen:

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

Wir multiplizieren beide Seiten mit  $n \dots$

$$nQ(n) = n(n - 1) + 2 \sum_{k=0}^{n-1} Q(k)$$

$\dots$  und schreiben dieselbe Gleichung mit  $n - 1$  statt  $n$  nochmals an:

$$(n - 1)Q(n - 1) = (n - 1)(n - 2) + 2 \sum_{k=0}^{n-2} Q(k).$$

## Quicksort: Average-Case Analyse

Nun subtrahieren wir die beiden obigen Gleichungen und erhalten

$$nQ(n) - (n-1)Q(n-1) = 2(n-1) + 2Q(n-1),$$

oder vereinfacht

$$Q(n) = \frac{n+1}{n}Q(n-1) + 2\frac{n-1}{n}.$$

Das ist eine lineare Rekursion, die aber keine konstanten Koeffizienten hat.

Durch Iteration [erraten](#) wir eine Summendarstellung für  $Q(n)$ ,

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

die man mit [Induktion nach  \$n\$](#)  leicht nachprüfen kann.

# Quicksort: Average-Case Analyse

Wenn wir die folgende “Partialbruchzerlegung”

$$\begin{aligned}\frac{k}{(k+1)(k+2)} &= \frac{k+2-2}{(k+1)(k+2)} \\ &= \frac{1}{k+1} - \frac{2}{(k+1)(k+2)} \\ &= \frac{1}{k+1} - \left( \frac{2}{k+1} - \frac{2}{k+2} \right)\end{aligned}$$

verwenden, dann vereinfacht sich die obige Summe (Teleskopsumme!) zu

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

# Quicksort: Average-Case Analyse

Die Summe auf der rechten Seite ist die **harmonische Zahl**

$H_n := \sum_{k=1}^n 1/k$ ; wir erhalten also

$$Q(n) = 2(n+1)H_n - 4n.$$

Da  $H_n \sim \log n$ , gelangen wir schließlich zu

$$Q(n) \sim 2n \log n = 2n \log_2 n / \log_2 e \approx 1.38 n \log_2 n.$$

Wenn wir dieses Resultat wieder mit der informationstheoretischen Schranke  $\lceil \log_2 n! \rceil$  vergleichen, dann sehen wir aus

$$\lceil \log_2 n! \rceil \sim n \log_2 n - n \log_2 e:$$

Die Größenordnung  $n \log_2 n$  ist “optimal”, nur haben wir hier noch die multiplikative Konstante von  $\approx 1.38$ .

# Sortieralgorithmen: Bemerkung

Die “Effizienz” eines Algorithmus in der Praxis der Computerprogrammierung nicht allein mit der Anzahl der benötigten (abstrakten) Schritte (Tests) gemessen wird.

Es ist z.B. ein Nachteil des **Sortierens durch Einfügen**, daß man jedes Mal, wenn man den richtigen Platz für das neue Element  $a_{i+1}$  in der bereits geordneten Liste gefunden hat, alle größeren Elemente verschieben muß, um für  $a_{i+1}$  Platz zu schaffen.

Das **Sortieren durch Zusammenlegen** hat einen anderen Nachteil: Die Teillisten müssen der rekursiv aufgerufenen Funktion immer als Argument übergeben werden, dafür muß also stets neuer Speicherplatz verwendet werden. Insgesamt entsteht dadurch ein sehr großer Speicherbedarf.