



Informatik II

Suchen

G. Zachmann
Clausthal University, Germany
zach@in.tu-clausthal.de



Problemstellung

- Gegeben ist eine Menge von Datensätzen $\{A_1, \dots, A_n\}$
- Gesucht sind die Datensätze, deren **Schlüssel (Key)** = $A[i].key$
- Betrachte ab jetzt o.B.d.A. nur noch die Folge der Keys, d.h., die A_i sind die Keys der Datensätze
- Allgemeine Spezifikation für das Suchproblem:
 - Eingabe: Array A, gesuchtes Element x
 - Ausgabe: Index i mit $A[i] = x$, falls x in A

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 2

Lineare Suche

- Wenn nichts über die (An-)Ordnung der Elemente **in der Datenstruktur** bekannt ist, kann nur die lineare Suche benutzt werden:
 - Besuche der Reihe nach die Elemente aus dem Container, bis ein Element mit der gewünschten Eigenschaft gefunden wurde, oder alle besucht wurden
- Beispiel: suche gegebene Telefonnummer in einem Telefonbuch
- Aufwand
 - worst case: n Schleifendurchläufe
 - average case:

$$\frac{1}{n}(1 + 2 + \dots + n) = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \frac{n(n+1)}{2} \approx \frac{n}{2}$$

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 3

Binäre Suche

- Nutze die totale Ordnung auf den Elementen
- Annahme: die n Elemente seien nun aufsteigend sortiert (geordnet), d.h.

$$\forall i, 0 \leq i < n - 1 : A_i \leq A_{i+1}$$
- Beispiel: suche nach einem Namen im Telefonbuch
- Lösungsstrategie: "**Intervallhalbierung**"
 - Schlage Telefonbuch in der Mitte auf, vergleiche gesuchten Namen mit einem Namen auf der Seite
 - Entscheide, in welcher Hälfte des Telefonbuches sich der gesuchte Name befindet (halbiert den Suchraum grob gerechnet)
 - Wiederhole Verfahren mit dieser Hälfte, bis richtige Seite gefunden ist

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 4

Beispiel

Gesucht: $x=32$

0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 : Index

12	17	23	24	31	32	36	37	42	47	53	55	67	67	87	89	91	91	93
----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----

Min=0, Max=18

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 5

Der rekursive Algorithmus ...

```
def binsearch_start( A, key ):
    """ Return index i such that 0 <= i < len(A)
    and A[i] == key, or, if no such i exists,
    returns -1. """
    if len(A) == 0: return -1
    if len(A) == 1:
        if A[0] == key: return 0
        else: return -1
    return binsearch_work( A, key, 0, len(A)-1 )

def binsearch_work( A, key, l, r ):
    """ The work horse for binsearch_start. """
    if r < l:
        return -1 # k not found
    m = (l + r) / 2
    if key < A[m]:
        return binsearch_work( A, key, l, m-1 )
    if key > A[m]:
        return binsearch_work( A, key, m+1, r )
    return m
```

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 6

... und nicht-rekursiv

```
def binsearch( A, key ):
    l = 0
    r = len(A) - 1
    while l <= r:
        m = (l + r) / 2
        if key < A[m]:
            r = m - 1
        elif key > A[m]:
            l = m + 1
        else:
            return m
    return -1
```



G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 7

Laufzeit-Analyse

- Annahme: $n = 2^k - 1$
- Beispiel:



- Worst case: #Schleifendurchläufe = $k = \log(n + 1) \approx \lceil \log n \rceil$
- Mittlere Anzahl Schleifendurchläufe: $\frac{1}{n} \sum_{i=1}^k i 2^{i-1} = \frac{1}{n} ((k-1)2^k + 1) \approx \log n$

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 8


 Beweis für $\sum_{i=1}^k i2^{i-1} = (k-1)2^k + 1$


$$\begin{aligned}
 \sum_{i=1}^k i2^{i-1} &= \left. \begin{array}{l} 2^0 + \\ 2^1 + 2^1 + \\ 2^2 + 2^2 + 2^2 + \\ \dots \\ 2^{k-1} + \dots + 2^{k-1} \end{array} \right\} k \\
 &= \sum_{i=0}^{k-1} 2^i + \sum_{i=1}^{k-1} 2^i + \dots + \sum_{i=k-1}^{k-1} 2^i \\
 &= \begin{array}{l} \downarrow \\ (2^k - 1) - \\ (2^0 - 1) \end{array} + \dots + \begin{array}{l} \downarrow \\ (2^k - 1) - \\ (2^1 - 1) \end{array} + \dots + \begin{array}{l} \downarrow \\ (2^k - 1) - \\ (2^{k-1} - 1) \end{array} \\
 &= k2^k - \sum_{i=0}^{k-1} 2^i = k2^k - (2^k - 1) = (k-1)2^k + 1
 \end{aligned}$$

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 9


 Lineare Suche vs. binäre Suche
 

- Bei großen Datenmengen ist binäre Suche wesentlich effizienter
 - Verdoppelung der Datenmenge →
 - lineare Suche: doppelter Aufwand
 - binäre Suche: ein weiterer Vergleich
- Bei kleinen Datenmengen ($n \approx 10$) ist lineare Suche schneller!
- Nicht jede Container-Datenstruktur ist für binäre Suche geeignet
- Muss man häufig in einem unsortierten Container suchen, lohnt es sich, die Elemente 1x in ein Array zu kopieren und dieses zu sortieren (*Precomputation*). Dann kann man die binäre Suche wiederholt anwenden. (Demnächst)

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 10

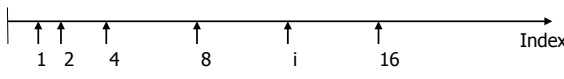
Key-Indizierte Suche

- Triviale Lösung, falls Key-Menge klein
 - Ist eigtl gar keine Suche
- Idee: Speichere Daten in einem Array "mit Lücken"
 - $A[k]$ enthält Datensatz mit Key k (inkl. "Nutzdaten")
 - Unbenutzte $A[i]$ enthalten **None**
- Suche nach Key k ist trivial: liefere $A[k]$
- Bedingungen:
 - Wertebereich der Keys muss **im voraus bekannt** sein
 - Datensätze mit gleichen Keys kann man nicht speichern
- Verallgemeinerung: Hash-Tables (später)

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 11

Exponentielle Suche

- Situation:
 - n sehr groß
 - Gesuchtes i , mit $A_i = k$, ist relativ klein
- Idee: suche zunächst "rechten Rand" r , so dass $k < A_r$
- Algo:



```

r = 1
while A[r] < key:
    r *= 2
binsearch( A, key, r/2, r )
      
```
- Analyse:
 - Rechten Rand suchen: $\lceil \log i \rceil$ viele Schleifendurchläufe
 - Binärsuche: $\sim \lceil \log i \rceil$

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 12

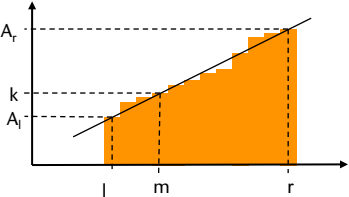
Interpolation search

- Beobachtung:
 - Bei Suche nach "Dix" oder "Zachmann" im Telefonbuch schlagen wir es eher weiter vorne bzw. weiter hinten auf
- Idee des Algorithmus':
 - **Schätze** die Position des gesuchten Keys im Array
- Erinnerung: bei binärer Suche wird das noch zu durchsuchende Index-Intervall bei $m = l + \frac{1}{2}(r - l)$ unterteilt
- Ersetze dort den Faktor 1/2 durch

$$m = l + (r - l) \frac{k - A_l}{A_r - A_l}$$
- Rest des Algo ist analog zu Binärsuche

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 13

- Klar ist: wenn Keys halbwegs linear aufsteigend sind, liegt dieses interpolierte m sehr dicht am gesuchten Key



- Voraussetzung:
 - **Ordnungsrelation** auf den Keys reicht nicht!
 - Man muss auf den Keys **rechnen** können
- Aufwand (o.Bew.)
 - Average case: $\sim \log \log n$
 - Worst case: $\sim n$ (!)

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 14

Minimumsuche mit *Golden Section Search*

- Aufgabe:
 - Gegeben eine 1-dim., stetige Funktion f
 - Entweder als mathematische Funktion $f : \mathbb{R} \rightarrow \mathbb{R}$
 - Oder als Array $f : \mathbb{N} \rightarrow \mathbb{R}$
 - Gesucht: ein **Minimum** x^* von f
- Erinnerung: Binärsuche klammert (*to bracket*) das Intervall, in dem sich der gesuchte Key befindet, und verkleinert diese Klammer sukzessive
- Frage: kann man *Bracketing* auch bei der Minimumsuche anwenden?

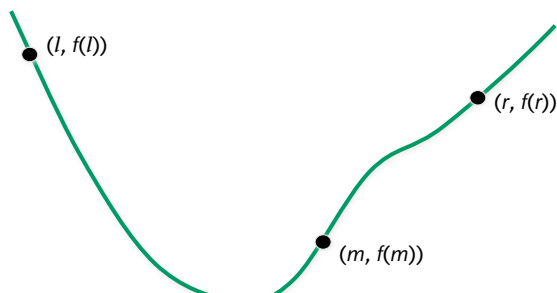
G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 15

Lemma:

Sei $l < m < r$ gegeben.
 Falls gilt

$$f(m) < f(l) \wedge f(m) < f(r)$$

dann muß (mindestens) ein (lokales) Minimum von f im Intervall $[l, r]$ liegen.



G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 16

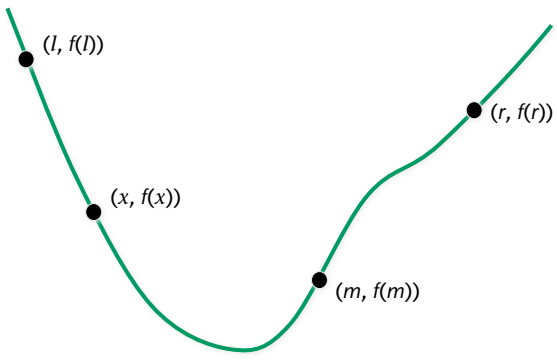
- Definition:
Im Folgenden ist eine **Klammer** (für die Minimumsuche) ein **Tripel** (l,m,r) mit $l < m < r$ und $f(m) < f(l) \wedge f(m) < f(r)$.
- Algorithmus zum Finden einer solchen initialen Klammer:


```

Input: initiales x0, increment delta
Berechne f(x0) und f(x0+delta)
If fallend: wiederhole schrittweise
nach rechts bis f wieder steigt
Else: gehe analog nach links
Erhöhe delta bei jedem Schritt
      
```

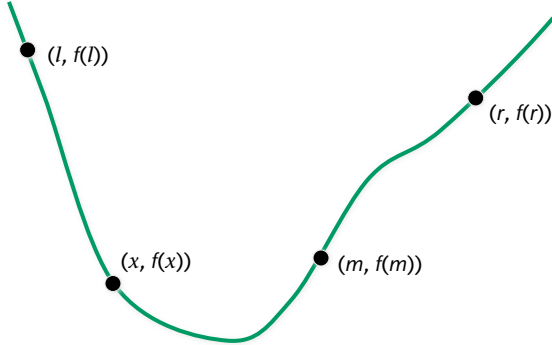
G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 17

- Idee zur Verkleinerung der Klammer: werte f an einer Stelle x "in der Mitte" aus
- Fall 1: neue Klammer ist (x, m, r)



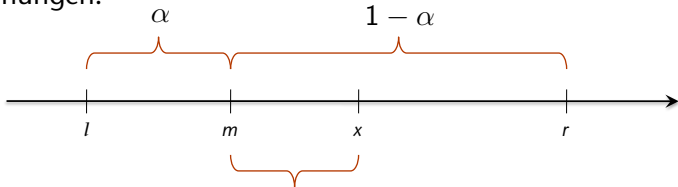
G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 18

- Idee zur Verkleinerung der Klammer: werte f an einer Stelle x "in der Mitte" aus
- Fall 2: neue Klammer ist (l, x, m)



G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 19

- Wo wählt man am besten x ?
 - Klar ist, dass man x besser in dem längeren der beiden Intervalle (l, m) und (m, r) plziert
- Gesucht ist die Stelle x (auch in folgenden Iterationen), so daß das Minimum auch dann möglichst schnell gefunden wird, wenn die Funktion so "unkooperativ" wie möglich ist
- Bezeichnungen:



$$\frac{m-l}{r-l} = \alpha \quad \beta = \frac{x-m}{r-l} \quad \frac{r-m}{r-l} = 1 - \alpha$$

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 20

- Je nach Fall hat das nächste Intervall die (relative) Länge $\alpha + \beta$ oder $1 - \alpha$
- Ziel: beide gleich groß machen
- Folgerung:

$$\beta = 1 - 2\alpha \Rightarrow \alpha < \frac{1}{2} \quad (1)$$
- Weitere Überlegung: wenn α optimal ist, muß eine **Skalenähnlichkeit** gelten, d.h. (im Fall 1)

$$\frac{\beta}{1 - \alpha} = \frac{\alpha}{1} \quad (2)$$

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 21

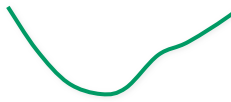
- (1) in (2) einsetzen liefert:

$$\alpha^2 - 3\alpha + 1 = 0 \Rightarrow \alpha = \frac{3 - \sqrt{5}}{2} \approx 0.38197$$
- Daher kommt der Name dieses Suchverfahrens, da

$$1 - \alpha = \bar{\varphi} \approx 0.61803$$
 der **goldene Schnitt** ist
- Laufzeit: nur lineare Konvergenz
 - Pro Schritt verkleinert sich das Intervall um ca. 30%
 - Dafür aber garantierte Konvergenz (im Gegensatz zu anderen Verfahren)

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 22

■ Definition:
Eine stetige Funktion f heißt **unimodal** im Intervall $[a,b]$ gdw.
es gibt ein eindeutiges x^* , so daß
 $f(x^*) = \text{Minimum auf } [a,b]$ und
 f ist streng monoton fallend auf $[a,x^*]$ und
streng monoton steigend auf $[x^*,b]$.



■ Klar ist:
Golden Section Search findet garantiert das globale Minimum einer unimodalen Funktion.

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 23

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 24



This is a presentation slide with a white background and a thin black border. In the top-left corner, there is a small green square containing a white logo. In the top-right corner, there is a small vertical grey bar with a white logo. The footer area is a light grey horizontal bar at the bottom. On the left side of the footer, the text "G. Zachmann Informatik 2 – SS 11" is displayed. On the right side of the footer, the text "Such-Algorithmen 25" is displayed.

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 25



This is a presentation slide with a white background and a thin black border. In the top-left corner, there is a small green square containing a white logo. In the top-right corner, there is a small vertical grey bar with a white logo. The footer area is a light grey horizontal bar at the bottom. On the left side of the footer, the text "G. Zachmann Informatik 2 – SS 11" is displayed. On the right side of the footer, the text "Such-Algorithmen 26" is displayed.

G. Zachmann Informatik 2 – SS 11 Such-Algorithmen 26