

# Vorlesung Informatik 2

## Algorithmen und Datenstrukturen

---

(20 - Bäume: Analyse nat. Bäume)

*Prof. Dr. Susanne Albers*

# Binäre Suchbäume

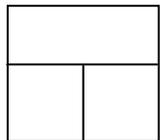
Binärbäume zur Speicherung von Mengen von Schlüsseln (in den inneren Knoten der Bäume), so dass die Operationen

- Suchen (find)
- Einfügen (insert)
- Entfernen (remove, delete)

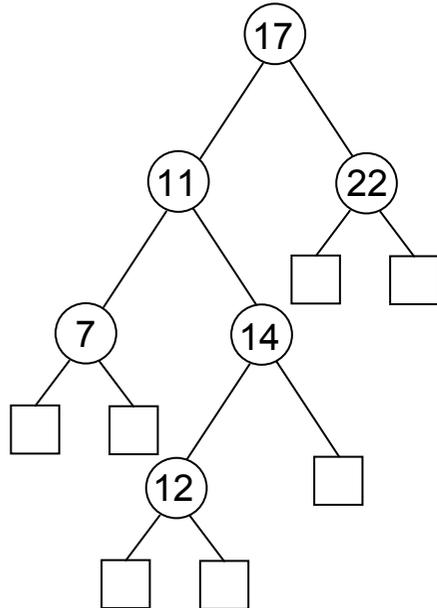
unterstützt werden.

**Suchbaumeigenschaft:** Die Schlüssel im linken Teilbaum eines Knotens  $p$  sind alle kleiner als der Schlüssel von  $p$ , und dieser ist wiederum kleiner als sämtliche Schlüssel im rechten Teilbaum von  $p$ .

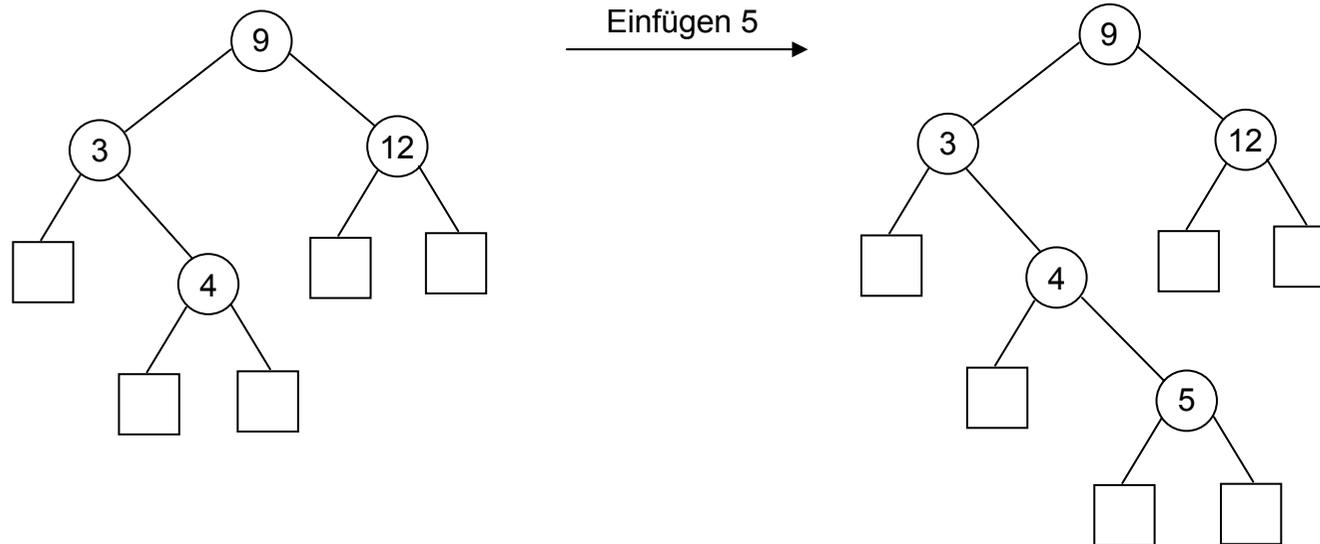
**Implementierung:**



# Beispiel für Suchen, Einfügen, Entfernen



# Natürliche Bäume



- Baum-Struktur hängt von Einfügereihenfolge in anfangs leeren Baum ab
- Höhe kann linear zunehmen, sie kann aber auch in  $O(\log n)$  sein, genau  $\lceil \log_2(n+1) \rceil$

# Analyse natürlicher Suchbäume

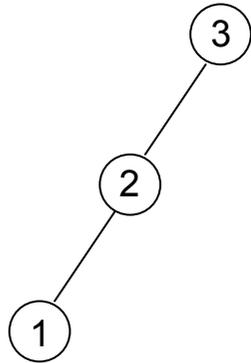
Zwei alternative Vorgehensweisen zur Bestimmung der internen Pfadlänge:

1. **Random-Tree-Analyse**, d.h. Mittelwert über alle möglichen Permutationen der (in den anfangs leeren Baum) einzufügenden Schlüssel.
2. **Gestaltanalyse**, d.h. Mittelwert über alle strukturell möglichen Bäume mit  $n$  Schlüsseln.

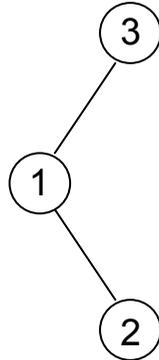
Unterschied des Erwartungswertes für die interne Pfadlänge:

1.  $\approx 1.386 n \log_2 n - 0.846 n + O(\log n)$
2.  $\approx n * \sqrt{\pi n} + O(n)$

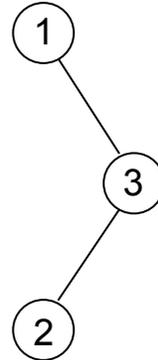
# Ursache für den Unterschied



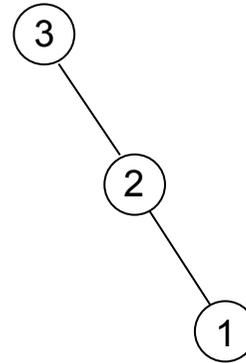
3,2,1



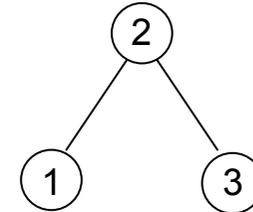
3,1,2



1,3,2



3,2,1



2,1,3 und 2,3,1

→ Bei der **Random-Tree-Analyse** werden **ausgeglichene Bäume** häufiger gezählt.

# Interne Pfadlänge

Interne Pfadlänge: Maß zu Beurteilung der Güte eines Suchbaumes.

Rekursive Definition:

1. Ist  $t$  der leere Baum, so ist

$$I(t) = 0.$$

2. Für einen Baum mit Wurzel  $t$ , linkem Teilbaum  $t_l$  und rechtem Teilbaum  $t_r$  gilt:

$$I(t) := I(t_l) + I(t_r) + \text{Zahl der Knoten von } t.$$

Offensichtlich gilt:

$$I(t) = \sum_p (Tiefe(p) + 1)$$

$p$  innerer Knoten von  $t$

# Durchschnittliche Suchpfadlänge

Für einen Baum  $t$  ist die **durchschnittliche Suchpfadlänge** definiert durch:

$$D(t) = I(t)/n, \quad n = \text{Anzahl innerer Knoten in } t$$

Frage: Wie groß ist  $D(t)$  im

- besten
- schlechtesten
- mittleren Fall

für einen Baum  $t$  mit  $n$  inneren Knoten?

# Interne Pfadlänge: Bester Fall

---

Es entsteht ein vollständiger Binärbaum

# Interne Pfadlänge: Schlechtester Fall

---

# Zufällige Bäume

---

- Seien oBdA die Schlüssel  $\{1, \dots, n\}$  einzufügen.
- Sei ferner  $s_1, \dots, s_n$  eine zufällige Permutation dieser Schlüssel.
- Somit ist die Wahrscheinlichkeit  $P(s_1 = k)$ , dass  $s_1$  gerade den Wert  $k$  hat, genau  $1/n$ .
- Wenn  $k$  der erste Schlüssel ist, wird  $k$  zur Wurzel.
- Dann enthalten der linke Teilbaum  $k - 1$  Elemente (nämlich die Schlüssel  $1, \dots, k - 1$ ) und der rechte Teilbaum  $n - k$  Elemente (d.h. die Schlüssel  $k + 1, \dots, n$ ).

# Erwartete interne Pfadlänge

$EI(n)$  : Erwartungswert für die interne Pfadlänge eines zufällig erzeugten binären Suchbaums mit  $n$  Knoten

Offensichtlich gilt:  $EI(0) = 0$

$$EI(1) = 1$$

$$\begin{aligned}
 EI(n) &= \frac{1}{n} \sum_{k=1}^n (EI(k-1) + EI(n-k) + n) \\
 &= n + \frac{1}{n} \left( \sum_{k=1}^n EI(k-1) + \sum_{k=1}^n EI(n-k) \right)
 \end{aligned}$$

Behauptung:  $EI(n) \approx 1.386n \log_2 n - 0.846n + O(\log n)$ .

# Beweis (1)

$$EI(n+1) = (n+1) + \frac{2}{n+1} * \sum_{k=0}^n EI(k)$$

und daher

$$(n+1) * EI(n+1) = (n+1)^2 + 2 * \sum_{k=0}^n EI(k)$$

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

Aus den beiden letzten Gleichungen folgt

$$(n+1) EI(n+1) - n * EI(n) = 2n + 1 + 2 * EI(n)$$

$$(n+1) EI(n+1) = (n+2) EI(n) + 2n + 1$$

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

## Beweis (2)

---

Durch vollständige Induktion über  $n$  kann man zeigen, dass für alle  $n \geq 1$  gilt:

$$EI(n) = 2(n+1) H_n - 3n$$

$H_n = 1 + \frac{1}{2} + \dots + \frac{1}{n}$  ist die  $n$ -te harmonische Zahl, die wie folgt abgeschätzt werden kann:

$$H_n = \ln n + \gamma + \frac{1}{2n} + O\left(\frac{1}{n^2}\right)$$

Dabei ist  $\gamma = 0.5772 \dots$  die so genannte Eulersche Konstante.

## Beweis (3)

---

Damit ist

$$EI(n) = 2n \ln n - (3 - 2\gamma) * n + 2 \ln n + 1 + 2\gamma + O\left(\frac{1}{n}\right)$$

Und daher

$$\begin{aligned} \frac{EI(n)}{n} &= 2 \ln n - (3 - 2\gamma) + \frac{2 \ln n}{n} + \dots \\ &= \frac{2}{\log_2 e} * \log_2 n - (3 - 2\gamma) + \frac{2 \ln n}{n} + \dots \\ &= \frac{2 \log_{10} 2}{\log_{10} e} * \log_2 n - (3 - 2\gamma) + \frac{2 \ln n}{n} + \dots \\ &\approx 1.386 \log_2 n - (3 - 2\gamma) + \frac{2 \ln n}{n} + \dots \end{aligned}$$

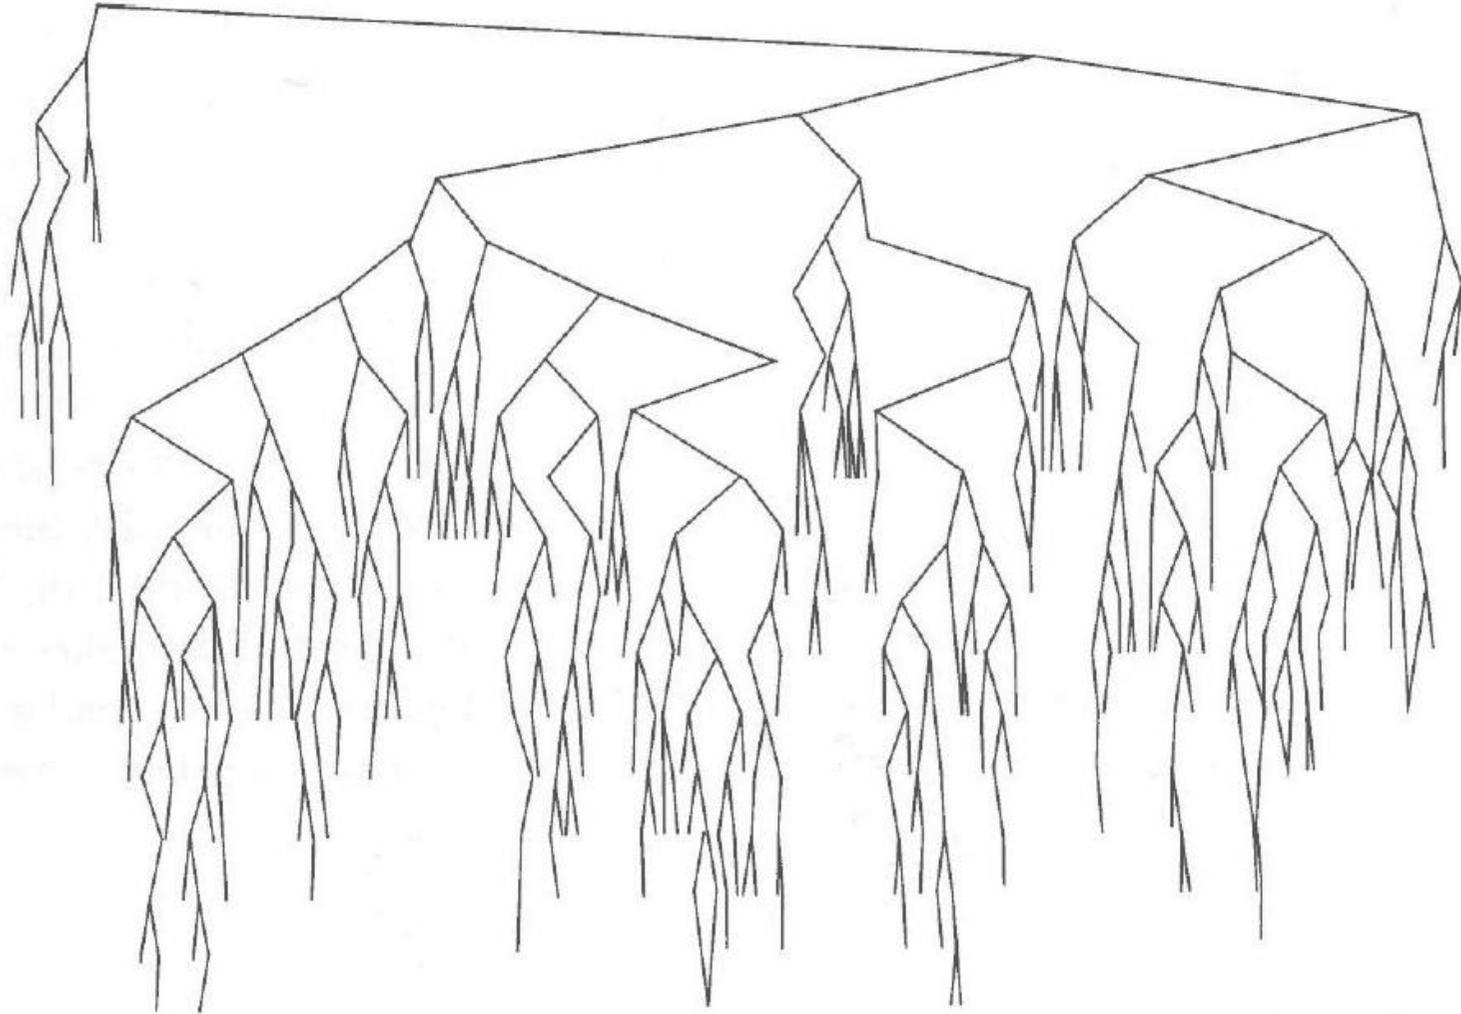
# Beobachtungen

---

- Suchen, Einfügen und Entfernen eines Schlüssels ist bei einem zufällig erzeugten binären Suchbaum mit  $n$  Schlüsseln im Mittel in  $O(\log_2 n)$  Schritten möglich.
- Im schlechtesten Fall kann der Aufwand jedoch  $\Omega(n)$  betragen.
- Man kann nachweisen, dass der mittlere Abstand eines Knotens von der Wurzel in einem zufällig erzeugten Baum nur etwa 40% über dem Optimum liegt.
- Die Einschränkung auf den symmetrischen Nachfolger verschlechtert jedoch das Verhalten.
- Führt man in einem zufällig erzeugten Suchbaum mit  $n$  Schlüsseln  $n^2$  Update-Operationen durch, so ist der Erwartungswert für die durchschnittliche Suchpfadlänge lediglich  $\Theta(\sqrt{n})$ .

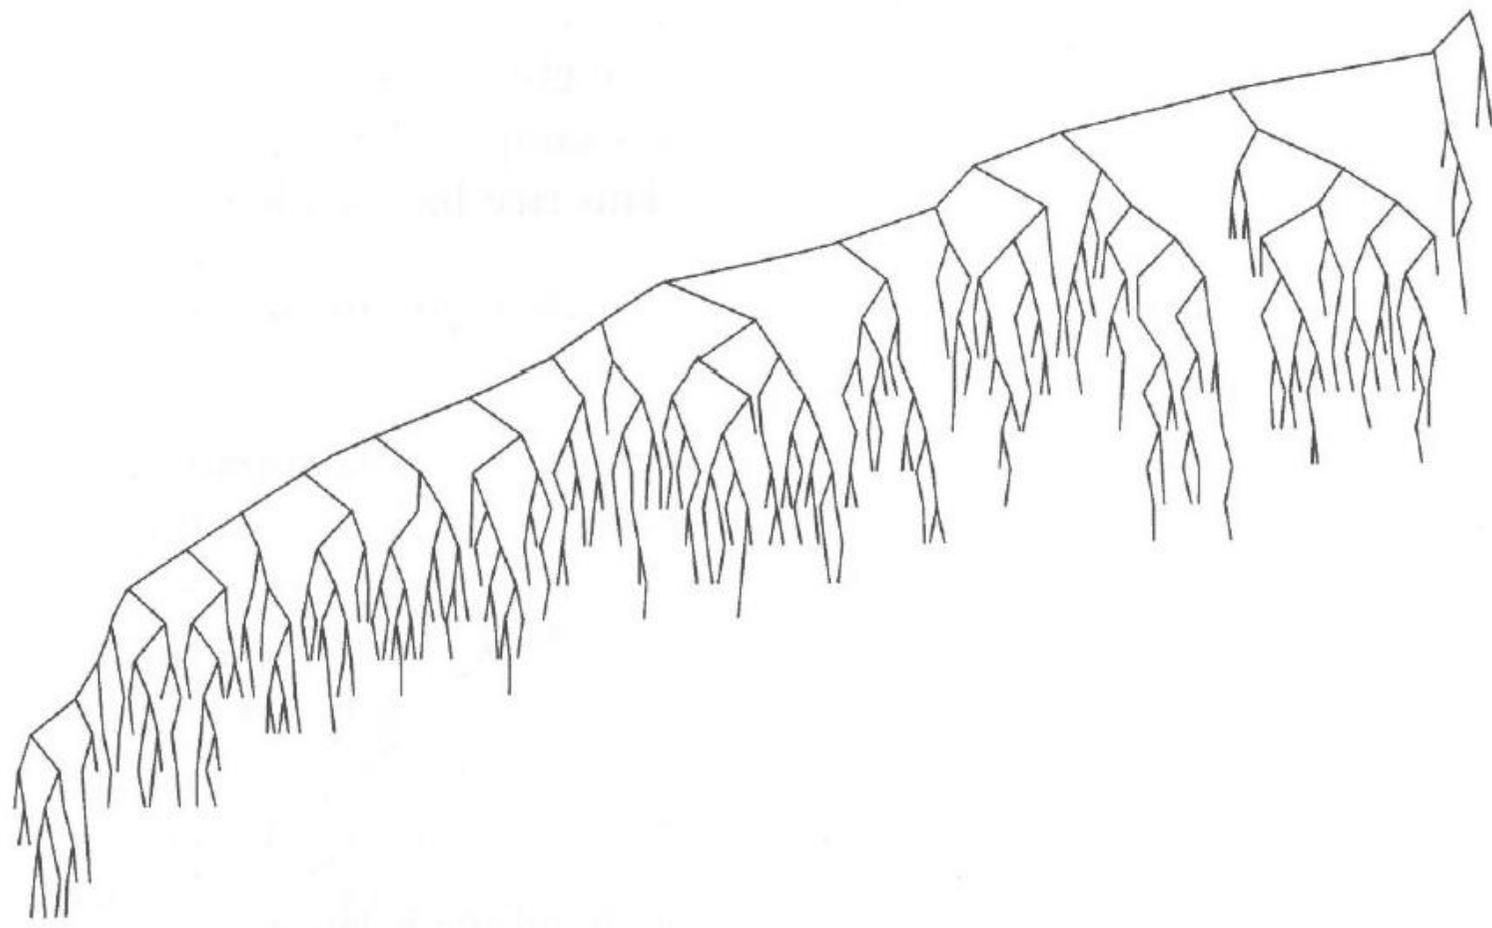
# Typischer Binärbaum für eine zufällige Schlüsselsequenz

---



# Resultierender Binärbaum nach $n^2$ Updates

---



# Strukturelle Analyse von Binärbäumen

**Frage:** Wie groß ist die durchschnittliche Suchpfadlänge eines Binärbaumes mit  $n$  inneren Knoten, wenn man bei der Durchschnittsbildung jeden strukturell möglichen Binärbaum mit  $n$  inneren Knoten genau einmal zählt?

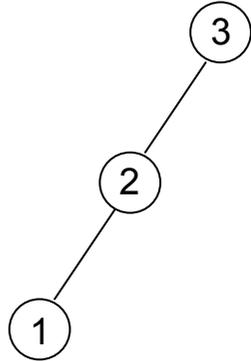
**Antwort:** Sei

$I_n$  = gesamte interne Pfadlänge aller strukturell verschiedenen Binärbäume mit  $n$  inneren Knoten

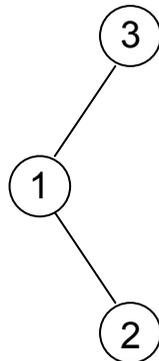
$B_n$  = Anzahl aller strukturell verschiedenen Bäume mit  $n$  inneren Knoten

Dann ist  $I_n/B_n =$

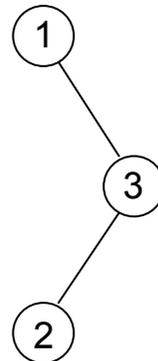
# Strukturell verschiedene Binärbäume



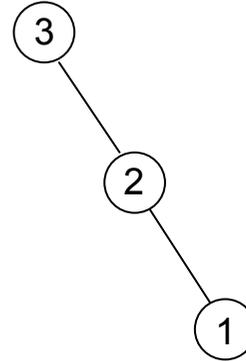
3,2,1



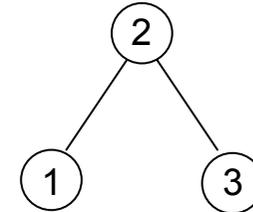
3,1,2



1,3,2



3,2,1



2,1,3 und 2,3,1

# Anzahl strukturell verschiedener Binärbäume

# Gesamte interne Pfadlänge aller Bäume mit $n$ Knoten

- Für jeden Baum  $t$  mit linkem Teilbaum  $t_l$  und rechtem Teilbaum  $t_r$  gilt:

# Zusammenfassung

---

Die durchschnittliche Suchpfadlänge in einem Baum mit  $n$  inneren Knoten (gemittelt über alle strukturell möglichen Bäume mit  $n$  inneren Knoten) ist:

$$1/n \sum_{B_n} l(B_n)$$