

Algorithmen und Datenstrukturen (ESE)
Entwurf, Analyse und Umsetzung von
Algorithmen (IEMS)
WS 2014 / 2015

Vorlesung 11, Donnerstag, 15. Januar 2015
(Balancierte Suchbäume)

Junior-Prof. Dr. Olaf Ronneberger
Image Analysis Lab
Institut für Informatik
Universität Freiburg

Blick über die Vorlesung heute

■ Organisatorisches

- Ihre Erfahrungen mit dem Ü10 (Binäre Suchbäume)

■ Balancierte Suchbäume

- **Vorlesung 10:** bei binären Suchbäumen brauchen **insert** und **lookup** im worst case Zeit $\Theta(d)$, d = Tiefes des Baumes
- **Übungsblatt 10:** Tiefe kann $O(\log n)$ sein (zufällige Schlüssel), kann aber auch $\Theta(n)$ sein (Schlüssel 1, 2, 3, ...)
- **Heute:** Balancierte Suchbäume = immer Tiefe $O(\log n)$
- Kurz: AVL Bäume
- Ausführlich: (a,b) -Bäume, Korrektheitsbeweis für $(2,4)$ -Bäume
- **Übungsblatt 11:** Korrektheitsbeweis für $(4,9)$ -Bäume

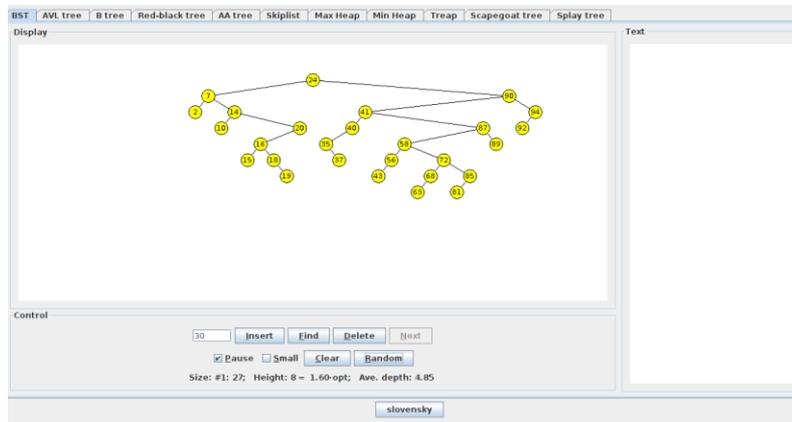
Erfahrungen mit dem Ü10 (binäre Suchbäume)

- Zusammenfassung / Auszüge (Stand 15.1. 8:30 Uhr)
 - Zeitaufwand im Mittel etwas mehr als vier Stunden
 - „segmentation fault“ → valgrind für C++ Programmierer
 - toString() Methode war nicht ganz einfach
 - ein paar Rückmeldungen zur Vorlesung → Vielen Dank!
Übernehme ich für nächstes Semester

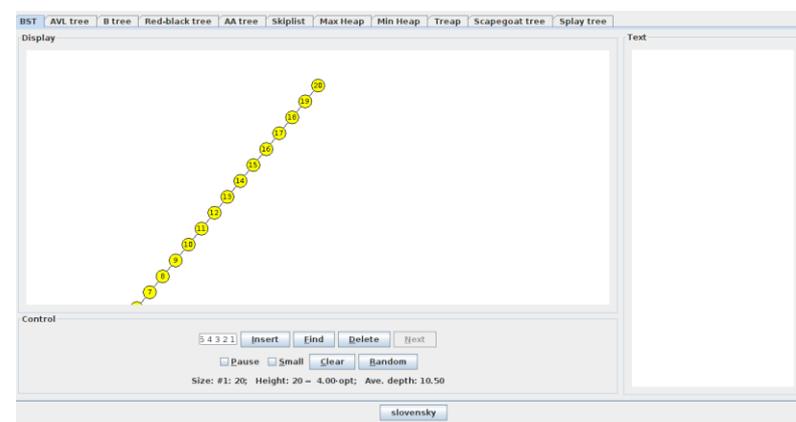
Balancierte Bäume: Motivation

- Mit `BinarySearchTree` hatten wir `lookup` und `insert` in Zeit $O(d)$, wobei d = Tiefe des Baumes
- Wenn es gut läuft ist $d = O(\log n)$
 - z.B. wenn die Schlüssel zufällig gewählt sind
- Wenn es schlecht läuft ist $d = \Theta(n)$
 - z.B. wenn der Reihe nach 20, 19, 18, ... eingefügt werden

<http://people.ksp.sk/~kuko/bak/>



(30 mal **Insert** klicken bei leerem Eingabefeld, oder 30 eintippen und auf **Random** klicken)



(„20 19 18 17 16 15 usw.“ mit Space getrennt ins Eingabefeld, dann **Insert** klicken)

Balancierte Bäume

- Wir wollen uns aber nicht auf eine bestimmte Eigenschaft der Schlüsselmenge verlassen müssen
- Und werden uns heute deswegen explizit darum kümmern, dass der Baum immer Tiefe $O(\log n)$ hat

Balancierte Bäume: Verfahren

- Wie erreicht man immer Tiefe $O(\log n)$?
- Es gibt Dutzende verschiedener Verfahren dafür:
 - **AVL-Baum:**
 - Binärbaum (2 Kinder pro Knoten)
 - Ausbalancieren durch „**Rotation**“
 - **(a,b)-Baum**, oder **B-Baum:**
 - Knoten haben zwischen **a** und **b** Kindern
 - Ausbalancieren durch **Spalten** und **Verschmelzen** der Knoten
 - Einsatz in Datenbanken und Dateisystemen
 - **Rot-schwarz-Baum**
 - Binärbaum (2 Kinder pro Knoten) mit „schwarzen“ und „roten“ Knoten
 - Ausbalancieren durch „**Rotation**“ und „**Umfärben**“
 - Einsatz in C++ `std::map`, und Java `SortedMap` und `SortedSet`
 - Kann direkt als (2,4)-Baum interpretiert werden.

AVL Baum: Definition

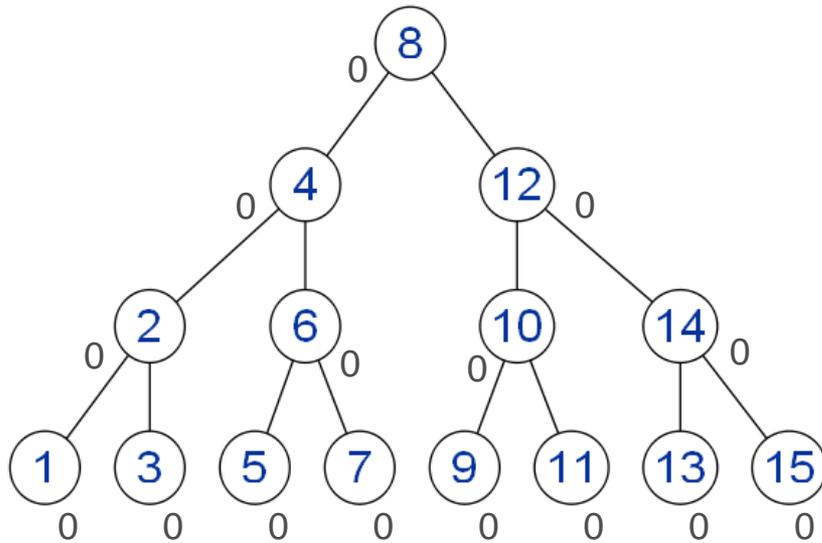
- Suchbaum mit modifizierten Einfüge- und Entferne-Operationen zur Einhaltung einer Höhenbedingung
- verhindert Degenerieren des Suchbaums
- Höhenunterschied von linkem und rechtem Teilbaum aller Knoten des Suchbaums ist maximal eins
- dadurch ist die Höhe des Suchbaums $O(\log n)$, womit alle weiteren Grundoperationen in $O(\log n)$ ausführbar sind.

Georgy Maximovich **Adelson-Velskii**, Yevgeniy Mikhailovich **Landis**,
An algorithm for the organization of information,
Doklady Akademia Nauk SSSR 1962.

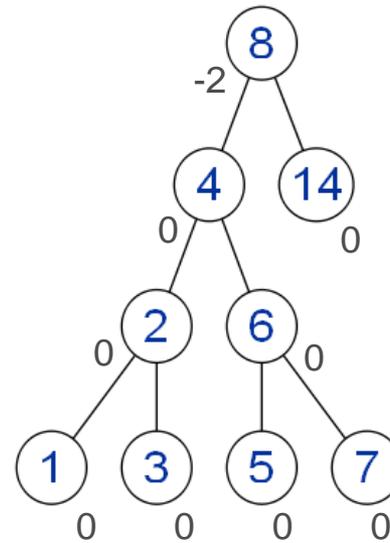
AVL-Baum: Beispiele



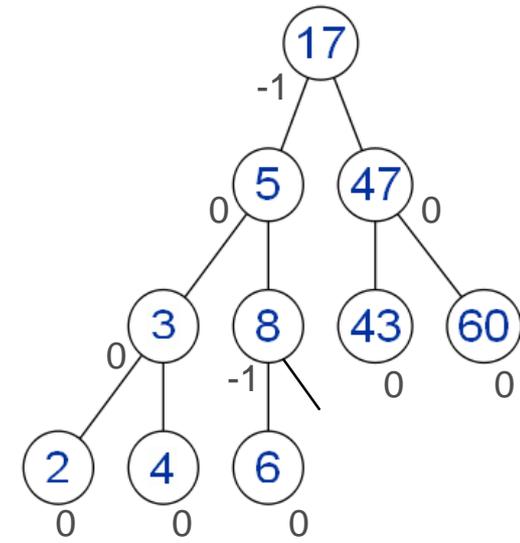
- Suchbäume mit Balance-Grad



AVL-Baum

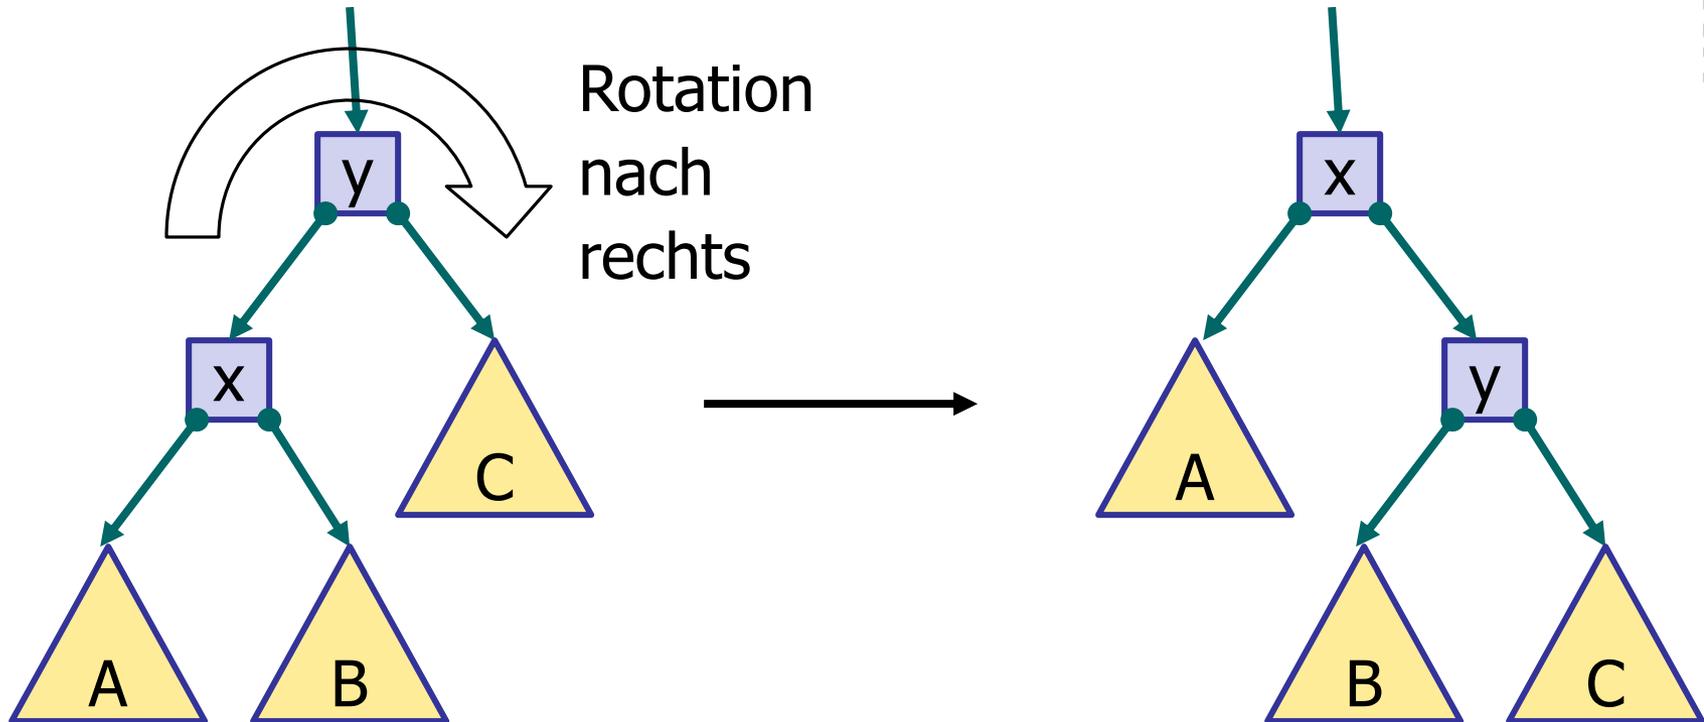


kein AVL-Baum



AVL-Baum

AVL Baum: Rebalancieren



- Zentrale Operation zum Rebalancieren: Rotation
- Beispiel: Nach der Rechtsrotation:
 - Teilbaum A ist eine Ebene höher und Teilbaum C eine Ebene tiefer
 - x und y haben ihr Eltern-Kind-Verhältnis geändert

AVL Baum Beispiel

- Sobald beim Einfügen oder Löschen eine Höhendifferenz von 2 entsteht, wird rebalanciert
- Viele Fallunterscheidungen, die wir uns nicht im Detail ansehen.
- Beispiel: Einfügen von 1,2,3,4,...
<http://people.ksp.sk/~kuko/bak/>

BST AVL tree B tree Red-black tree AA tree Skiplist Max Heap Min Heap Treap Scapegoat tree Splay tree

Display

Text

Insertion
We start at the root.

Control

15 14 13 Insert Find Delete Next

Pause Small Clear Random

Size: #1: 15; Height: 4 = 1.00-opt; Ave. depth: 3.27

slovensky

(„1 2 3 4 5 6 7 usw.“ mit Space getrennt ins Eingabefeld, dann **Insert** klicken)

AVL Baum Zusammenfassung

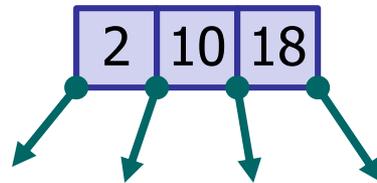
- Historisch gesehen die erste Suchbaumstruktur, die insert, remove und lookup in $O(\log n)$ ermöglicht
- Aber nicht amortisierte Update-Kosten von $O(1)$
- Zusätzliche Speicher-Kosten: In jedem Knoten die Höhendifferenz vom linken und rechten Teilbaum
- Besser (und einfacher zu implementieren) sind (a,b) -Bäume

(a,b)-Bäume Überblick

- Auch bekannt als B-Baum (B für „balanced“)
- Einsatz in Datenbanken und Dateisystemen
- Idee: Variable Anzahl von Elementen in den Knoten speichern
- Dadurch ist beim Einfügen/Ausbalancieren fast immer Platz für das neue Element.

(a,b)-Bäume Definition

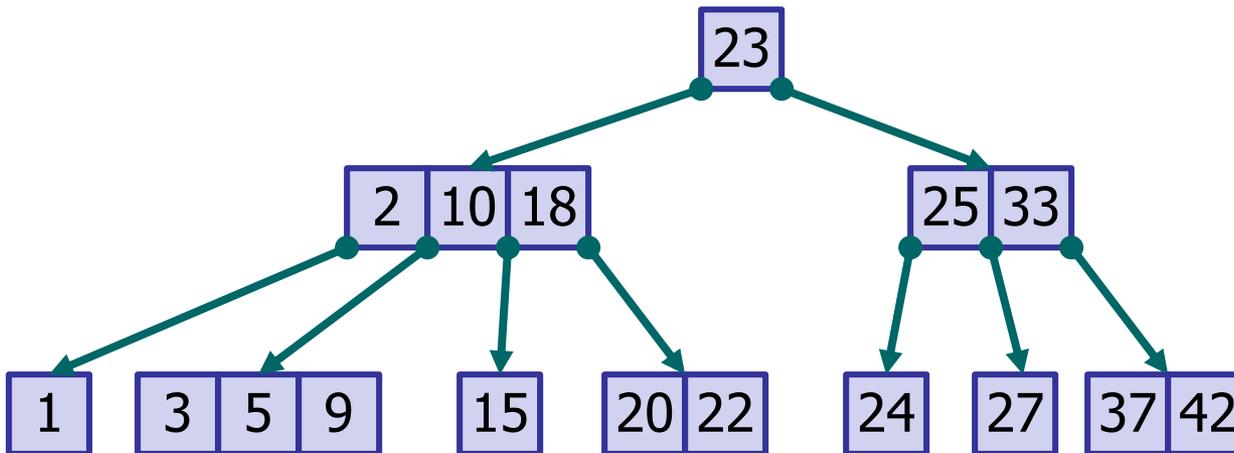
- Alle Blätter haben die gleiche Tiefe
- Jeder innere Knoten hat $\geq a$ und $\leq b$ Kinder (nur die Wurzel darf weniger Kinder haben)



- Ein Knoten mit n Kindern (bzw. n Pointern) heißt **Knoten vom Grad n** und speichert $n-1$ Elemente (sortiert)
- Unterbäume hängen „zwischen“ den Elementen
- Wir verlangen $a \geq 2$ und $b \geq 2a - 1$... warum sehen wir gleich

(a,b)-Bäume Beispiel

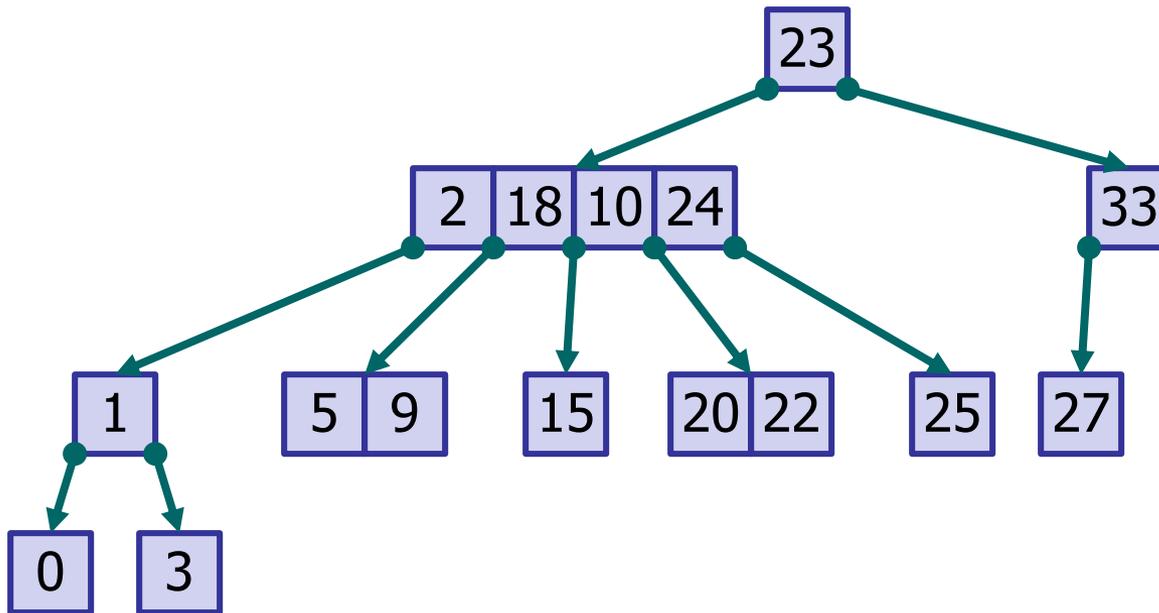
- Beispiel für einen $(2,4)$ -Baum



$(2,4)$ -Baum der Tiefe 3. Alle Knoten haben zwischen 2 und 4 Kinder, bzw. zwischen 1 und 3 Elemente

(a,b)-Bäume Gegenbeispiel

- Gegenbeispiel für einen $(2,4)$ -Baum



- Nicht korrekt sortiert (innerhalb der Knoten und Eltern-Kind)
- Grad zu klein / zu groß
- Blätter auf unterschiedlichen Ebenen

(a,b)-Bäume: lookup

■ Schlüsselsuche (Lookup)

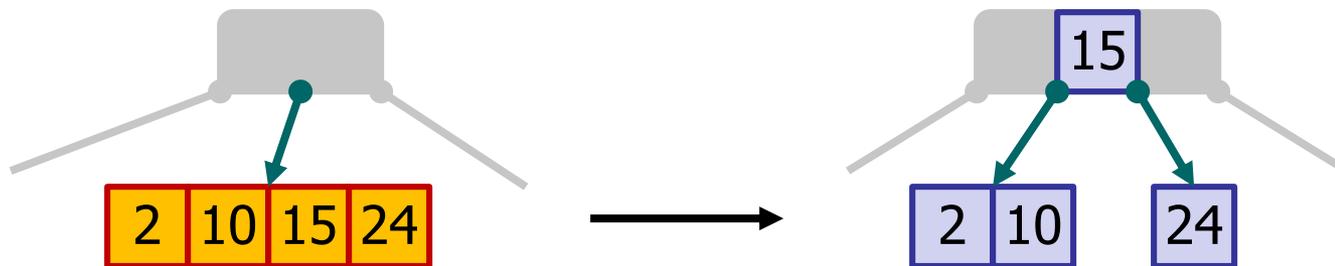
- Im Prinzip genau so wie beim [BinarySearchTree](#)
- Suche von der Wurzel abwärts
- Die Schlüssel an den inneren Knoten weisen den Weg

Size „4“ einstellen
„50“ ins Eingabefeld
Random klicken
Suchzahl eingeben
Find klicken

(a,b)-Bäume: insert

■ Einfügen eines Elementes (insert)

- Finde die Stelle, wo der neue Schlüssel einzufügen ist
- Wir landen immer in einem Blatt
- Füge das Element in diesen Knoten ein
- **Achtung:** Knoten kann jetzt ein Element zu viel haben (Grad $b+1$)
- Dann **spalten** wir den Knoten einfach auf



- in einen Knoten mit $\text{ceil}((b-1)/2)$ Elementen, ein Element für den Elternknoten, und einen Knoten mit $\text{floor}((b-1)/2)$ Elementen
- Deswegen $b \geq 2a-1$

(a,b)-Bäume: insert

- Fortsetzung: Einfügen eines Elementes (insert)
 - Der Elternknoten kann jetzt Grad $b+1$ haben
 - Dann spalten wir den auf dieselbe Weise auf ... usw.
 - Wenn das bis zur Wurzel geht, spalten wir auch die auf und erzeugen einen neuen Wurzelknoten → Baum dann **1 tiefer**

BST AVL tree B tree Red-black tree AA tree Skiplist Max Heap Min Heap Treap Scapegoat tree Splay tree

Display

Text

Insertion
We insert the key into this node.

Control

58 Insert Find Delete Next

Pause Small 4 Clear Random

#Nodes: 24; #Keys: 41 = 56% full; Height: 4

slovensky

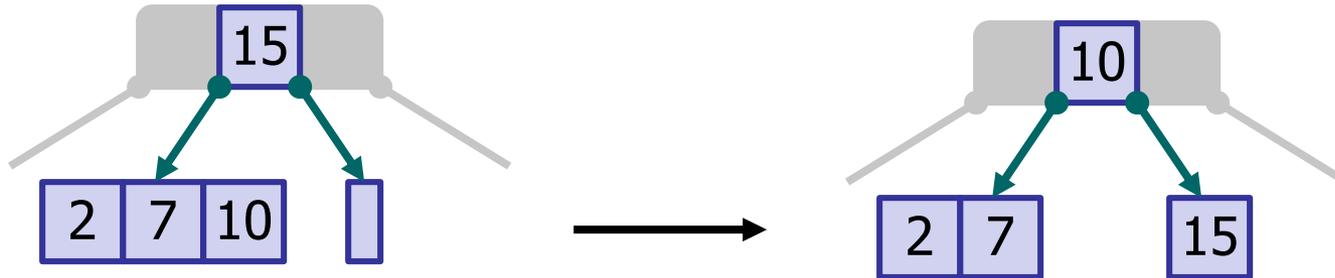
(a,b)-Bäume: remove

- Entfernen eines Elementes (remove)
 - Finde das zu entfernende Element
 - **Fall I:** Element im Blatt, entferne es direkt
 - **Fall II:** Element ist im inneren Knoten,
 - Suche seinen Nachfolger im rechten Teilbaum des Elements
 - Nachfolger steht immer in einem Blatt!
 - Ersetze Element durch den Nachfolger und entferne ihn aus dem Blatt
 - Achtung: das Blatt kann jetzt zu klein sein (Grad $a-1$)

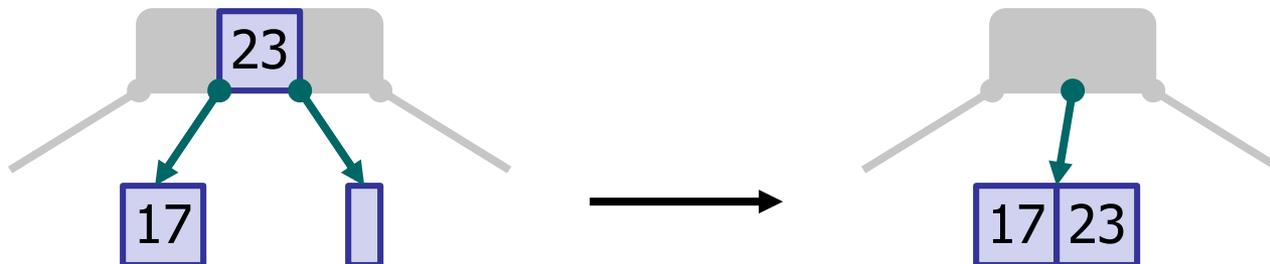
(a,b)-Bäume: remove

■ Fortsetzung: Entfernen eines Elementes (remove)

- **Fall 1:** Falls der linke oder rechte Bruder Grad $> a$ hat, **klauen** eins von da weg und sind fertig



- **Fall 2:** Sonst **verschmelzen** wir den Knoten mit seinem linken oder rechten Bruder.



(a,b)-Bäume: remove

■ Fortsetzung: Entfernen eines Elementes (remove)

- Nach einem Verschmelzen hat der Elternknoten jetzt ein Kind weniger und kann Grad $a-1$ haben ... und so weiter evtl. bis zur Wurzel
- Wenn die Wurzel am Ende nur noch ein Kind hat, mache dieses Kind zur neuen Wurzel → Baum dann **1 weniger tief**

The screenshot shows a B-tree visualization tool with the following components:

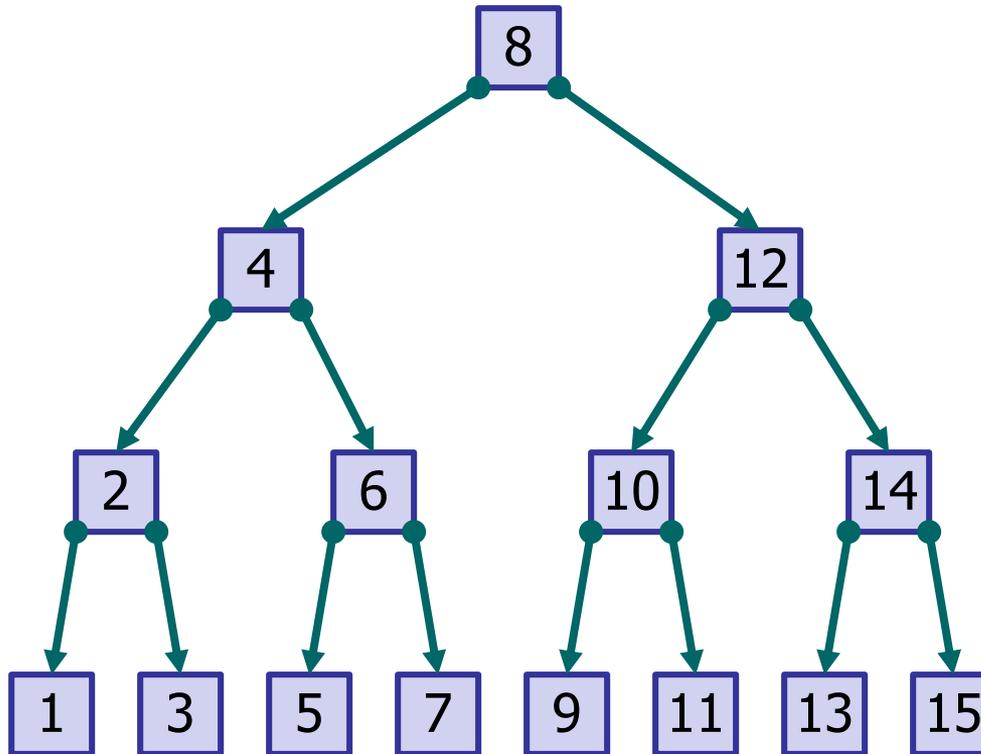
- Navigation Bar:** BST, AVL tree, B tree, Red-black tree, AA tree, Skiplist, Max Heap, Min Heap, Treap, Scapegoat tree, Splay tree.
- Display Area:** A B-tree diagram with root node 65. The root has two children: (19, 52) and (84). Node (19, 52) has three children: (5, 12), (39), and (59). Node (84) has two children: (72) and (89, 94). The leaf nodes under (5, 12) are (2, 3), (6, 7), (13, 15). The leaf nodes under (39) are (21, 34), (40, 42), (57, 58). The leaf nodes under (59) are (60, 62), (70, 71), (74, 75), (88, 90). The leaf nodes under (72) are (74, 75), (88, 90). The leaf nodes under (89, 94) are (92), (96, 99). The node (88, 90) is highlighted in red.
- Text Area:** Deletion
88 < 89, we go along the 1. link.
- Control Area:** Input field with 88, buttons for Insert, Find, Delete, Next, Pause, Small, Clear, Random. Statistics: #Nodes: 20; #Keys: 33 = 55% full; Height: 4.
- Footer:** slovensky

Analyse (a,b)-Bäume

■ Komplexität für **lookup**, **insert**, **remove**

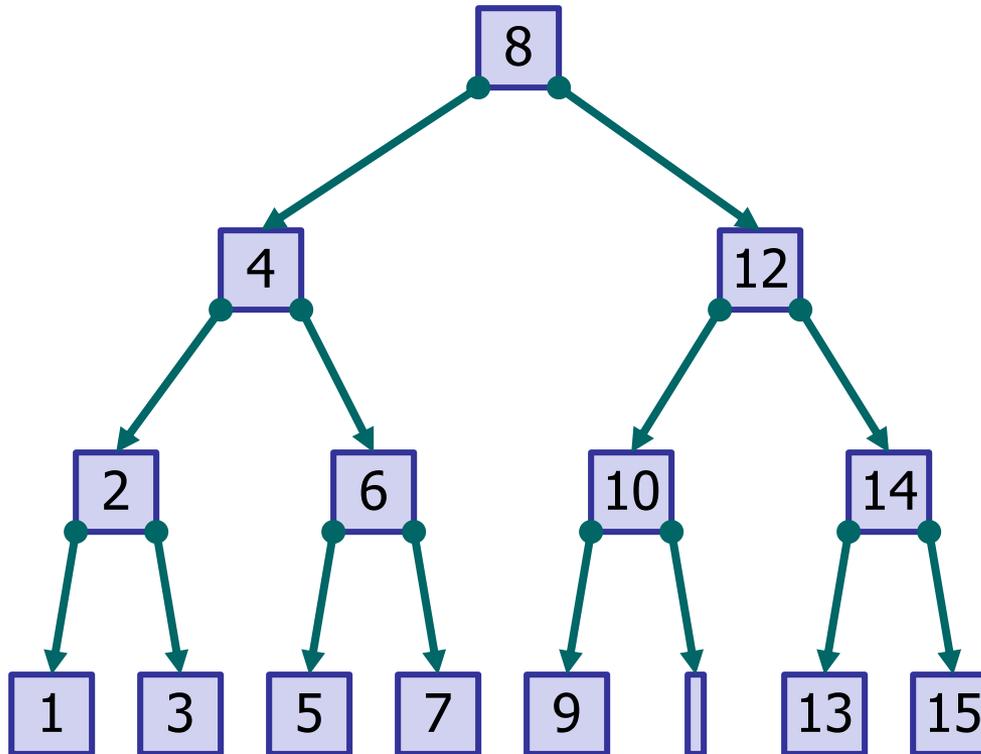
- Gehen alle in Zeit $O(d)$, wobei d = Tiefe des Baumes
- Jeder Knoten, außer evtl. der Wurzel, hat $\geq a$ Kinder
deshalb $n \geq a^{d-1}$ und deshalb $d \leq 1 + \log_a n = O(\log_a n)$
- Bei genauerem Hinsehen fällt auf
 - Die Operation **lookup** braucht immer Zeit $\Theta(d)$
 - Aber **insert** und **remove** scheinen oft in $O(1)$ zu gehen
(nur im schlechtesten Fall müssen alle Knoten auf dem Weg zur Wurzel gespalten / verschmolzen werden)
- Das wollen wir jetzt genauer analysieren
- Dafür reicht $b \geq 2a - 1$ allerdings nicht, wir brauchen **$b \geq 2a$**
- Gegenbeispiel für (2,3)-Bäume, Analyse für (2,4)-Bäume

Gegenbeispiel für (2,3)-Bäume

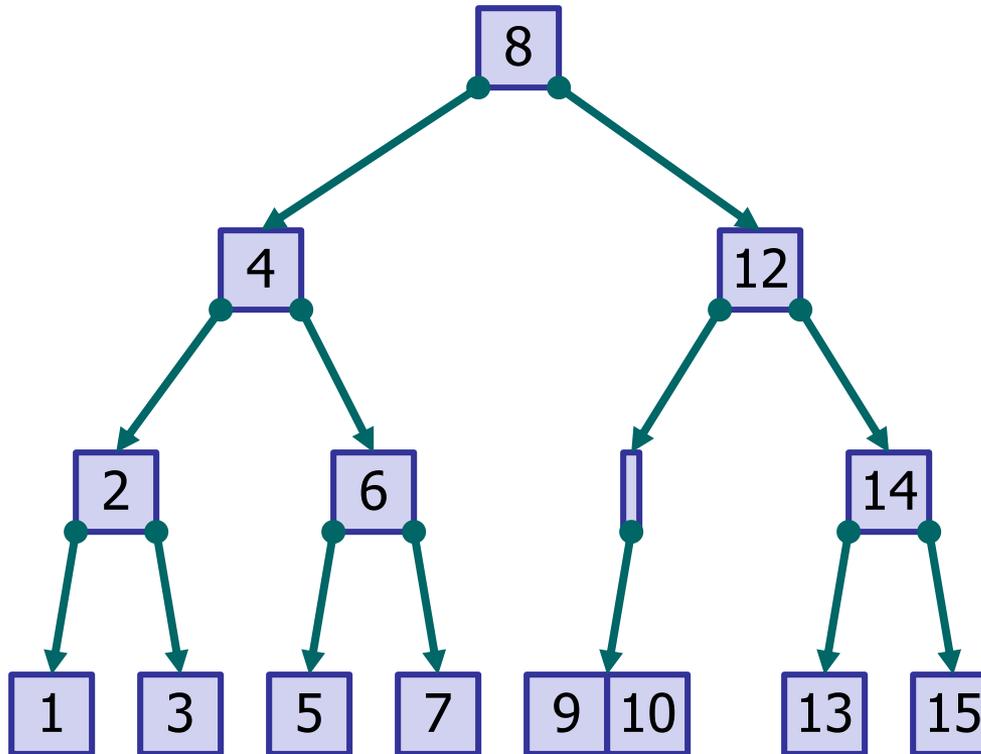


delete(11)

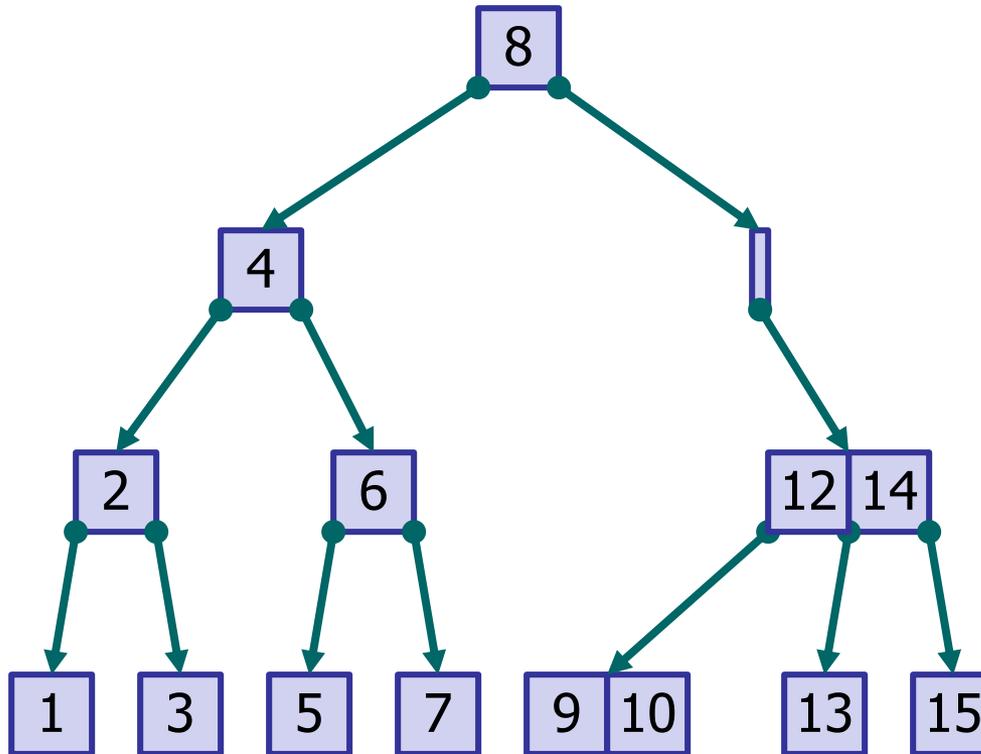
Gegenbeispiel für (2,3)-Bäume



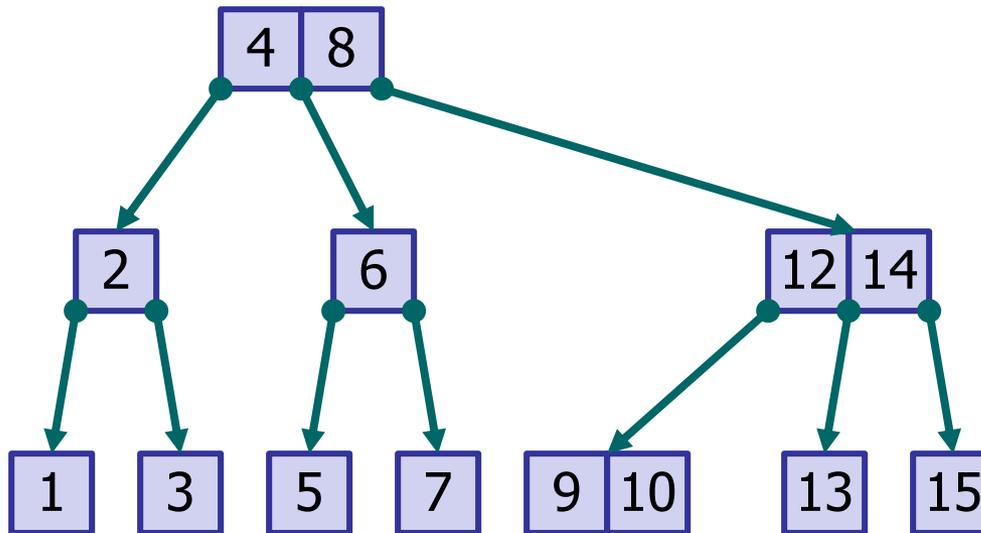
Gegenbeispiel für (2,3)-Bäume



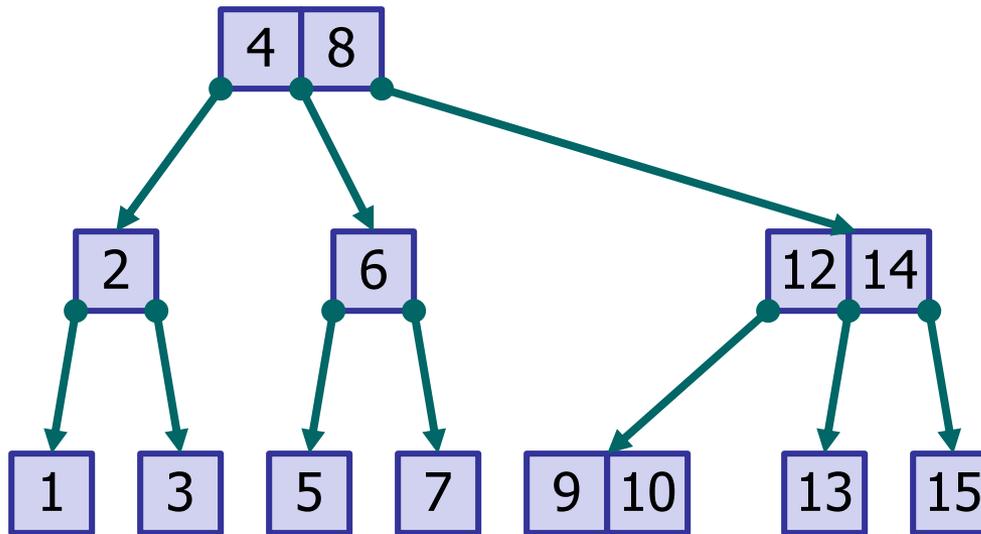
Gegenbeispiel für (2,3)-Bäume



Gegenbeispiel für (2,3)-Bäume

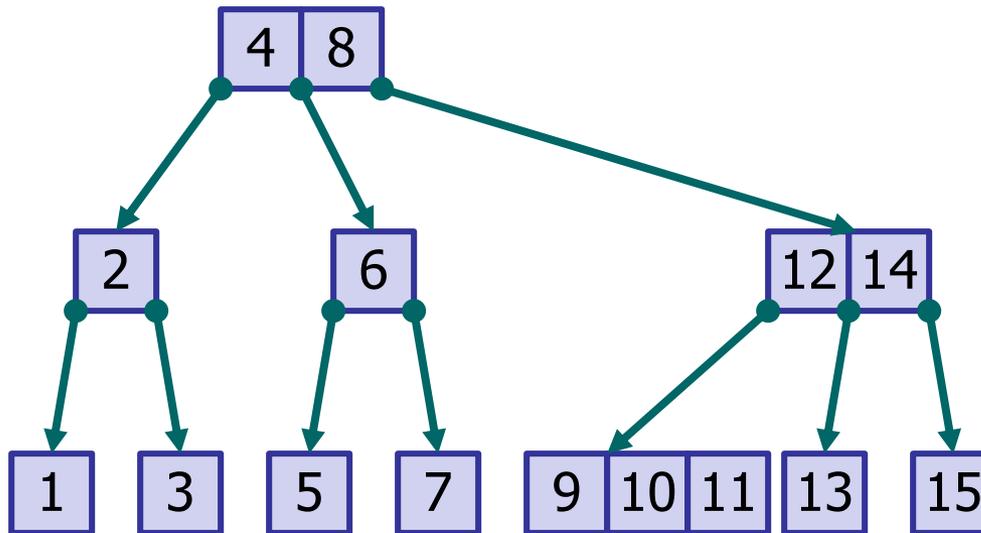


Gegenbeispiel für (2,3)-Bäume

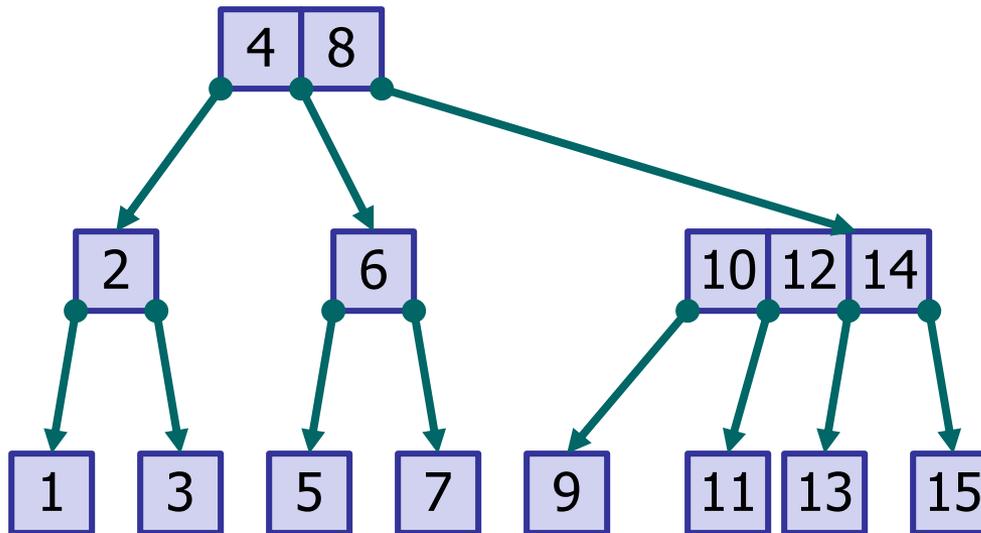


insert(11)

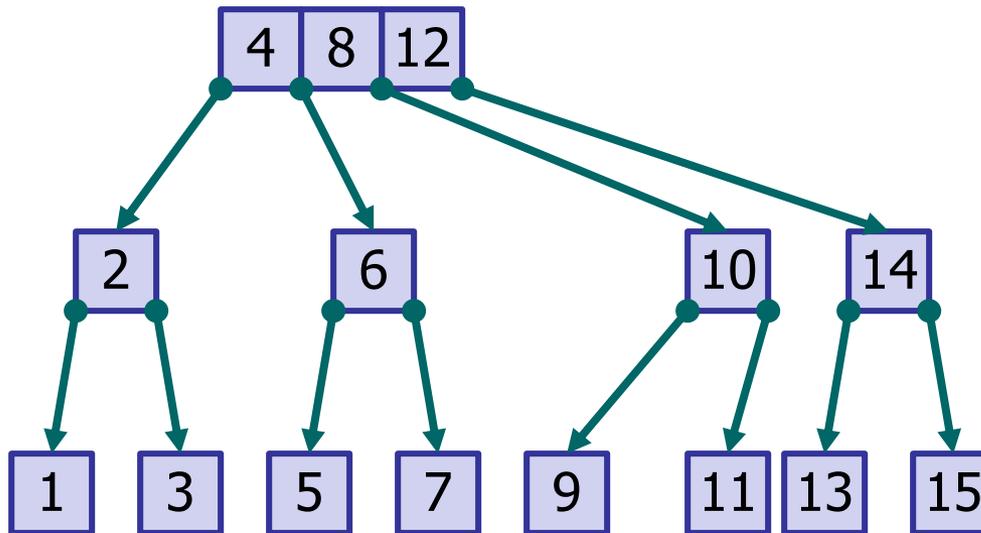
Gegenbeispiel für (2,3)-Bäume



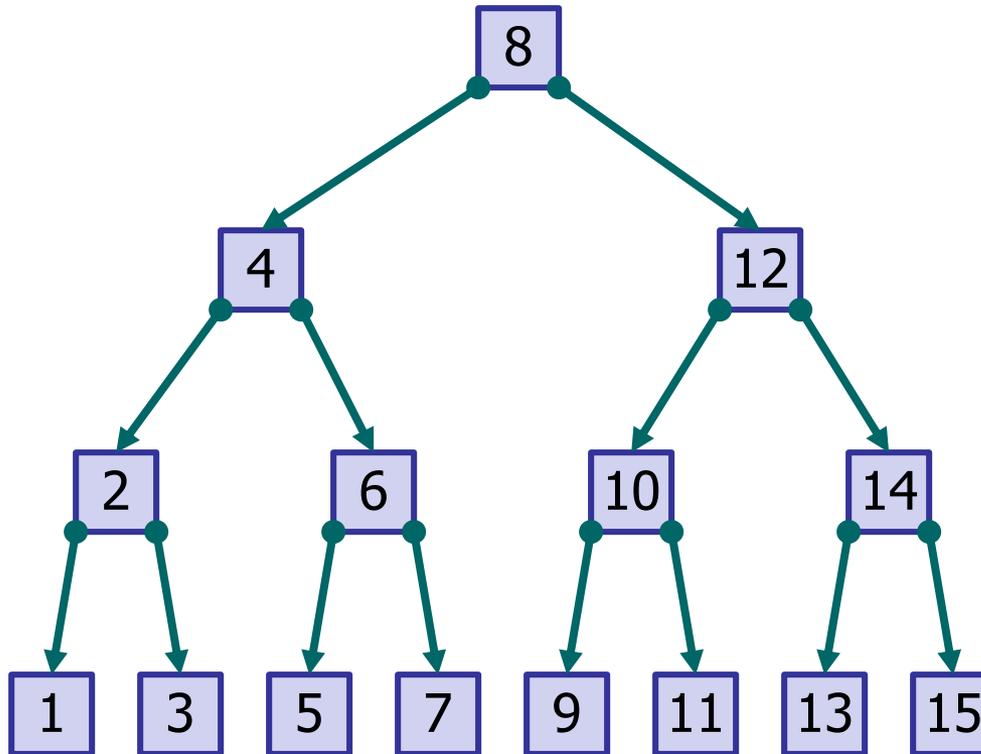
Gegenbeispiel für (2,3)-Bäume



Gegenbeispiel für (2,3)-Bäume



Gegenbeispiel für (2,3)-Bäume



- Wir sind wieder beim Anfangszustand
- Also: Wenn $b = 2a - 1$, dann gibt es eine Folge von inserts und removes, bei der jede Operation $\log n$ kostet

Analyse (2,4)-Bäume: Intuition

■ Intuition

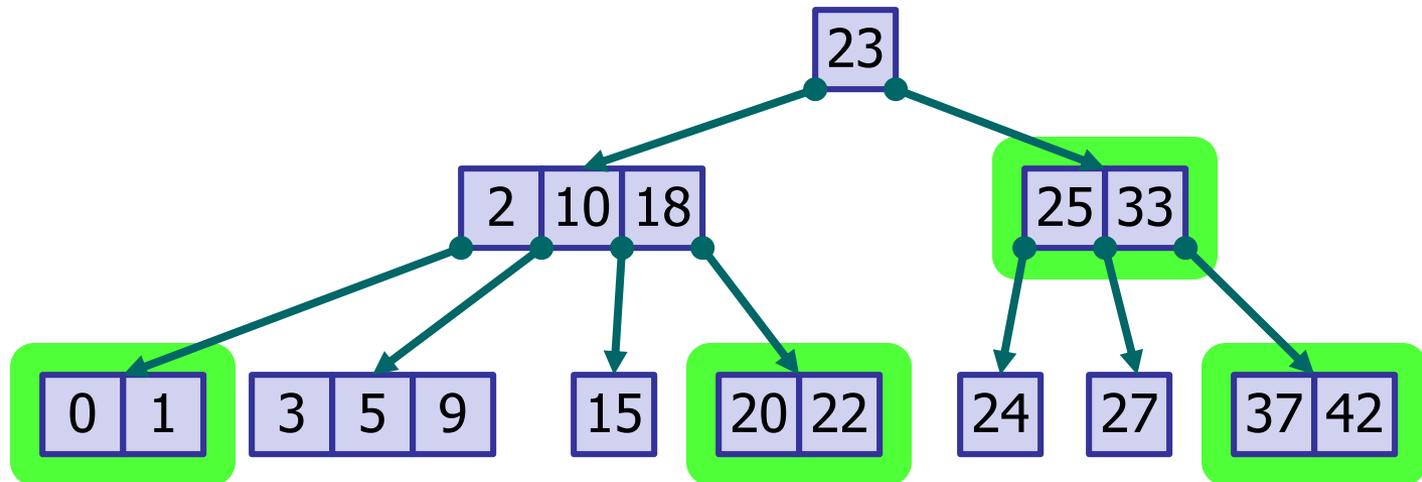
- Wenn alle Knoten im Baum **2** Kinder haben, müssen wir nach einem **remove** alle Knoten bis zur Wurzel verschmelzen
- Wenn alle Knoten im Baum **4** Kinder haben, müssen wir nach einem **insert** alle Knoten bis zur Wurzel aufspalten
- Wenn alle Knoten im Baum **3** Kinder haben, dauert es lange bis wir in eine dieser beiden Situationen kommen
- **Erkenntnis:** Die **Grad-3-Knoten sind harmlos** – weder ein **insert**, noch ein **remove** in einem solchen Knoten ziehen weitere Operationen nach sich!
- **Idee für die Analyse:** nach einer teuren Operation ist der Baum in einem Zustand, dass es dauert, bis es wieder teuer wird
- Ähnlich wie bei dynamischen Feldern:
 - Reallokation ist teuer, aber danach dauert es, bis wieder realloziert werden muss.
 - Bei geeigneter "Überallokation" Kosten im Durchschnitt $O(1)$

Analyse (2,4)-Bäume: Potential

■ Terminologie

- Wir betrachten eine Folge von n Operationen
- Sei Φ_i das Potential des Baumes nach der i -ten Operation
= die Anzahl der harmlosen Knoten (mit Grad genau 3)

Beispiel: Baum mit Potential $\Phi = 4$, (Grad-3-Knoten **umrandet**)



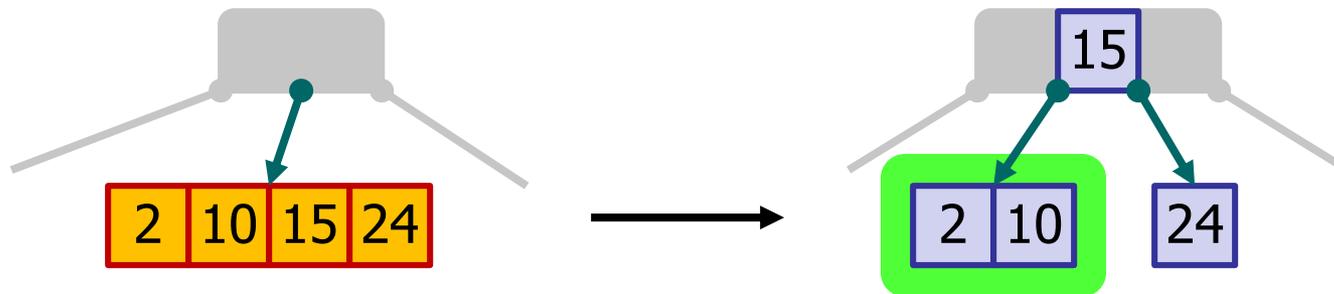
- $\Phi_0 =$ Potential am Anfang := 0 (leerer Baum)

Analyse (2,4)-Bäume: Beweis 1/7

- Forsetzung: Terminologie
 - Seien c_i die Kosten = Laufzeit der i -ten Operation
- Wir werden zeigen:
 - Jede Operation kann maximal einen harmlosen Knoten zerstören
 - Für jeden weiteren Schritt, der Kosten verursacht, erzeugt die Operation jeweils einen neuen harmlosen Knoten
- D.h. die Kosten für Operation i sind mit der Potentialdifferenz gekoppelt:
 - Es gilt $c_i \leq A \cdot (\Phi_i - \Phi_{i-1}) + B$ für irgendwelche $A > 0$ und $B > A$
Anzahl der harmlosen Knoten, die bei der i -ten Operation hinzukommen. Kann auch -1 sein, aber nicht kleiner als -1
- Dann zeigen wir, dass die Summe der Kosten $O(n)$ hat, und somit jede Operation $O(1)$ (amortisiert)

Analyse (2,4)-Bäume: Beweis 2/7

- Fall 1: i -te Operation ist ein **insert** auf einen vollen Knoten



- Beobachtung: Für jedes Aufspalten hat man nachher einen Grad-3-Knoten mehr
- Im Elternknoten kommt ein Element hinzu.
- Wenn der auch voll war, ebenfalls aufspalten, usw. bis zu einem Elternknoten von Grad 2 oder 3. Dann fertig.

Analyse (2,4)-Bäume: Beweis 3/7

- Sei m = Anzahl der Aufspaltungen
- Das Potential erhöht sich um m und erniedrigt sich am Ende evtl. um 1, wenn der "Stop-Knoten" vom Grad 3 war.

$$\begin{aligned}\Phi_i &\geq \Phi_{i-1} + m - 1 \\ \Rightarrow m &\leq \Phi_i - \Phi_{i-1} + 1\end{aligned}$$

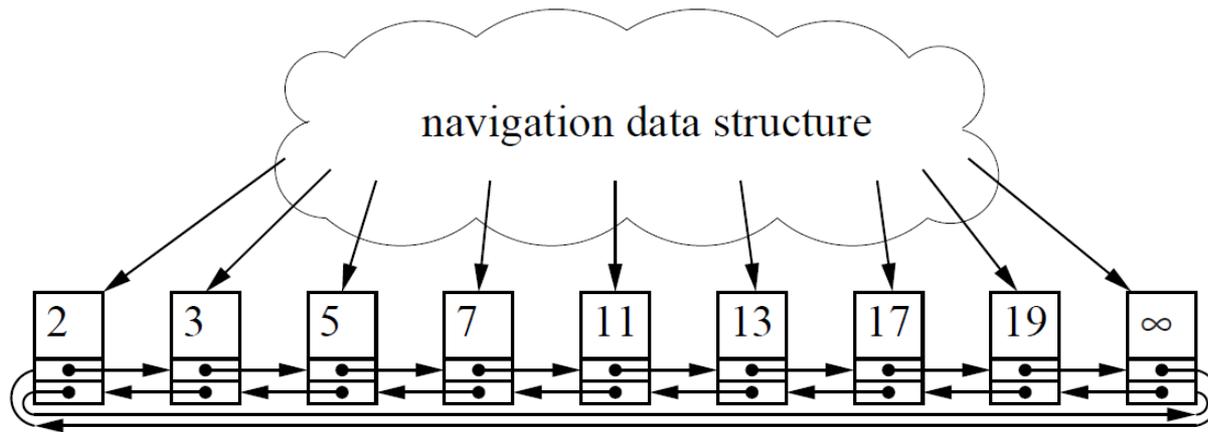
Kosten: $c_i \leq A \cdot m + B$

$$\Rightarrow c_i \leq A \cdot (\Phi_i - \Phi_{i-1} + 1) + B$$

$$c_i \leq A \cdot (\Phi_i - \Phi_{i-1}) + \underbrace{A + B}_{=: B'} \quad \square$$

Analyse (2,4)-Bäume: Beweis 4/7

- Fall 2: i -te Operation ist ein **remove**
- Fall 2.1: Innerer Knoten:
 - Finden des Nachfolgers im Baum ist $O(d)$
 - Aber: Üblicherweise Kombination mit doppelt verketteter Liste:

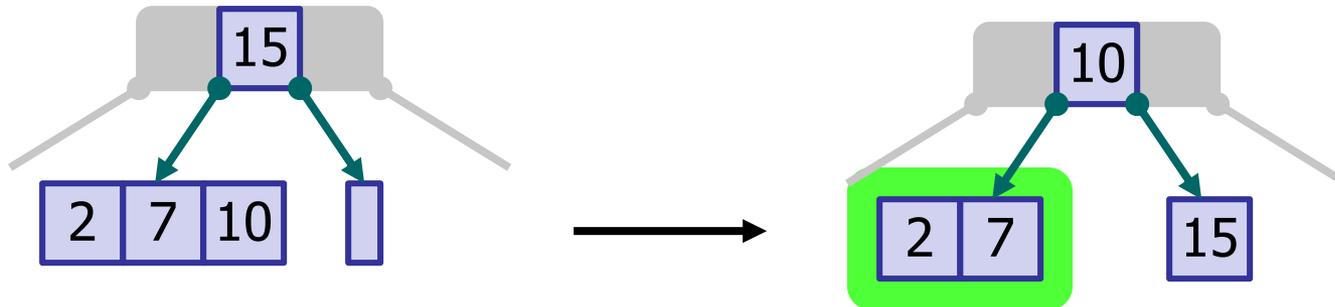


[Mehlhorn-Sanders, Fig. 7.1]

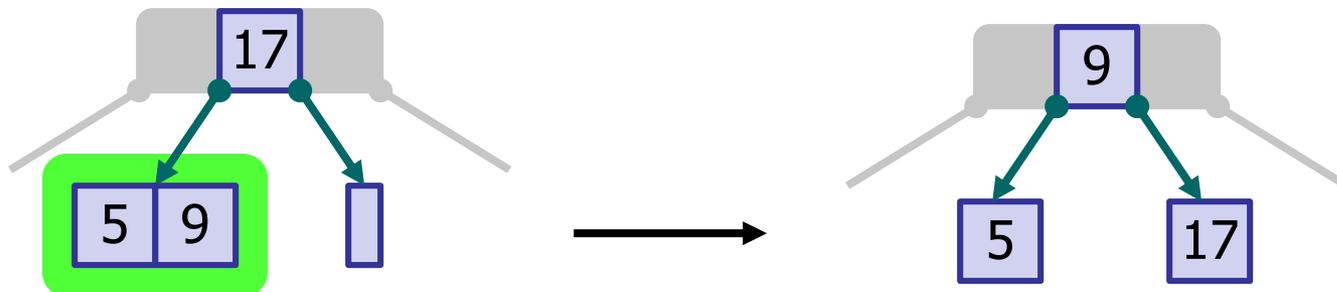
- Damit findet man man den Nachfolger in $O(1)$

Analyse (2,4)-Bäume: Beweis 5/7

- Fall 2: i -te Operation ist ein **remove**
- Fall 2.1: Klauen: Potential erhöht sich um eins:



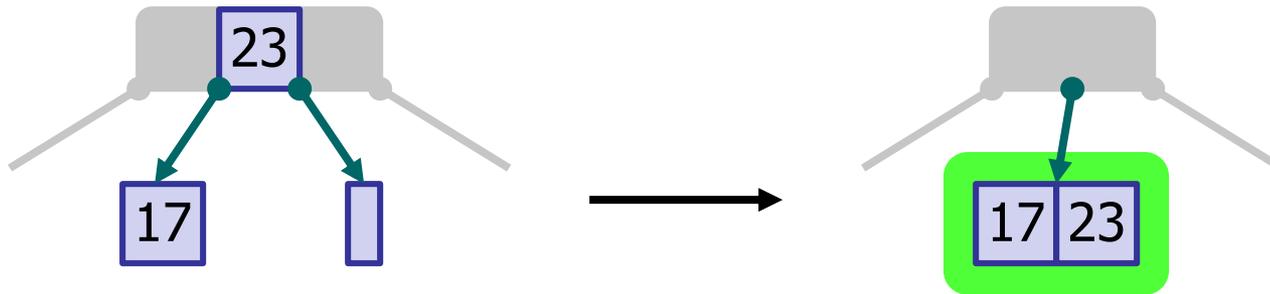
– oder Potential verringert sich um eins:



– aber nur 1mal (Operation pflanzt sich nicht nach oben fort)

Analyse (2,4)-Bäume: Beweis 6/7

- Fall 2.2: Verschmelzen: Potential erhöht sich um eins:



- pflanzt sich so lange nach oben fort, bis zu einem Knoten von Grad > 2 oder einem Grad-2-Knoten, der etwas klauen kann.
- Also auch hier m mal Potential erhöhen und am Ende evtl. 1 mal verringern:
- \rightarrow gleiche Kosten wie beim insert. \square

Analyse (2,4)-Bäume: Beweis 7/7

■ Lemma

- Es gilt $c_i \leq A \cdot \underbrace{(\Phi_i - \Phi_{i-1})}_{\text{Anzahl der Grad-3-Knoten, die bei der } i\text{-ten Operation hinzukommen}} + B$ für irgendwelche $A > 0$ und $B > A$
- Daraus folgt dann $\sum_{i=1..n} c_i = O(n)$
- Beweis:

$$\begin{aligned}
 \sum_{i=1}^n c_i &\leq \underbrace{A \cdot (\Phi_1 - \Phi_0) + B}_{\leq c_1} + \underbrace{A \cdot (\Phi_2 - \Phi_1) + B}_{\leq c_2} + \dots + \underbrace{A \cdot (\Phi_n - \Phi_{n-1}) + B}_{\leq c_n} \\
 &= A \cdot (\Phi_n - \Phi_0) + B \cdot n \quad // \text{Teleskopsumme} \\
 &= A \cdot \Phi_n + B \cdot n \quad // \text{leerer Baum am Anfang (kein Grad-3-Knoten)} \\
 &< A \cdot n + B \cdot n = O(n) \quad // \text{Anzahl Grad-3-Knoten immer } < \text{Anzahl Elemente} \\
 &\quad \square
 \end{aligned}$$

Rot-Schwarz-Bäume

Display

Control

37

Pause Small 2-3-4 mode

Size: #1: 29; Height: 6 = 1.20-opt; Ave. depth: 4.24

slovensky

Text

Insertion

That's it.

- Binärbaum mit schwarzen und roten Knoten
- Anzahl der schwarzen Knoten auf Pfad zu jedem Blatt gleich
- Kann direkt als (2,4)-Baum (auch 2-3-4 Baum genannt) interpretiert werden
 - jeder (2,4)-Baum-Knoten ist ein kleiner Rot-schwarz-Baum mit schwarzem „Einstiegsknoten“

Übungsblatt 11

- Beweis amortisiertes $O(1)$ für (4,9) Bäume

Literatur / Links

■ (a,b)-Bäume

– In Mehlhorn/Sanders:

7 Sorted Sequences [Kapitel 7.2 und 7.4]

– In Cormen/Leiserson/Rivest

14 Red-Black Trees

– In Wikipedia

[http://en.wikipedia.org/wiki/\(a,b\)-tree](http://en.wikipedia.org/wiki/(a,b)-tree) (Englisch)

[http://cs.wikipedia.org/wiki/\(a,b\)-strom](http://cs.wikipedia.org/wiki/(a,b)-strom) (Tschechisch)