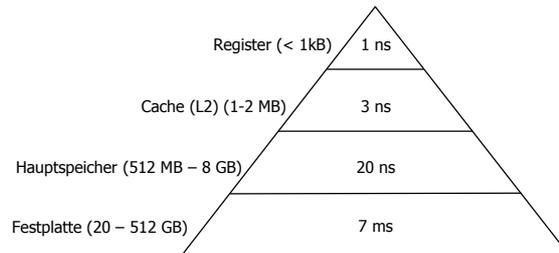




Mehrwegbäume — Motivation



- Wir haben gute Strukturen (AVL-Bäume) kennen gelernt, die die Anzahl der Operationen begrenzen
- Was ist, wenn der Baum zu groß für den Hauptspeicher ist?
- Externe Datenspeicherung → Speicherhierarchie:



- Zugriffsverhältnis zwischen Hauptspeicher und Festplatte:
$$t(P) / t(H) = (7 \cdot 10^{-3}) / (20 \cdot 10^{-9}) = 3.5 \cdot 10^5$$



- D.h., Zugriff auf (externe) Knoten sehr teuer
- Bsp. :
 - File-Tree des File-Systems
 - Datenbanken (DB2 (IBM), Sybase, Oracle, ...)
- Man hätte gerne einen Baum, der noch geringere Tiefe hat als

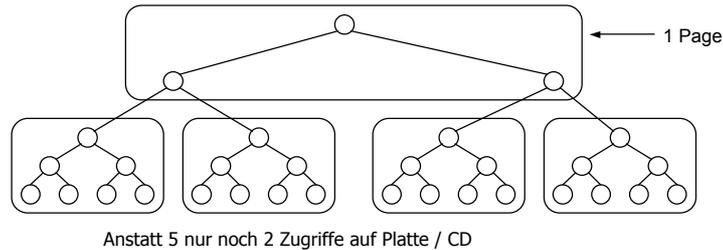
$$\log_2(n)$$

- Idee:
 - "Erhöhe die Basis des Logarithmus"
 - oder: speichere mehrere "aufeinanderfolgende" Baum-Knoten auf derselben Seite (*Page*) auf der Platte
 - reduziere damit die Anzahl der Seitenzugriffe



m-Wege-Bäume

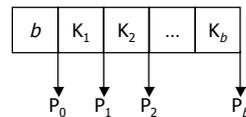
- Ein **m-Wege-Suchbaum** ist eine Verallgemeinerung eines binären Suchbaumes (d. h., ein binärer Suchbaum ist ein **2-Wege-Suchbaum**)



Definition

- In einem *m*-Wege-Baum haben alle Knoten den Grad $\leq m$
- der Baum ist entweder leer oder besitzt folgende Eigenschaften:

- jeder Knoten hat folgende Struktur:



- K_i sind die Schlüssel, $1 \leq i \leq b$
- b ist die Anzahl der Schlüssel im Knoten
- P_i sind die Zeiger zu den Unterbäumen des Knotens

- Schlüssel innerhalb eines Knotens sind aufsteigend geordnet:

- $K_1 \leq K_2 \leq \dots \leq K_b$

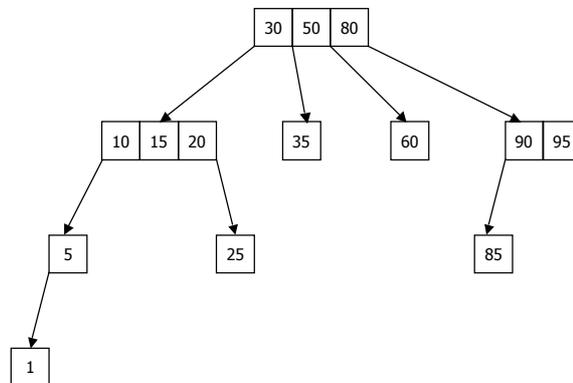
- alle Schlüssel im Unterbaum P_i sind kleiner als K_{i+1} , für $0 \leq i < b$

- alle Schlüssel im Unterbaum P_b sind größer als K_b

- Die Unterbäume P_i , für $0 \leq i \leq b$, sind ebenfalls *m*-Wege-Bäume



Beispiel



Bemerkungen

- Probleme:
 - Baum ist nicht ausgeglichen
 - Blätter sind auf verschiedenen Stufen
 - Bei Veränderungen gibt es keinen Ausgleichsalgorithmus
 - Schlechte Speicherausnutzung, kann zu verketteten Listen degenerieren

- Anzahl der Knoten im **vollständigen** m-Wege Baum mit Höhe h :

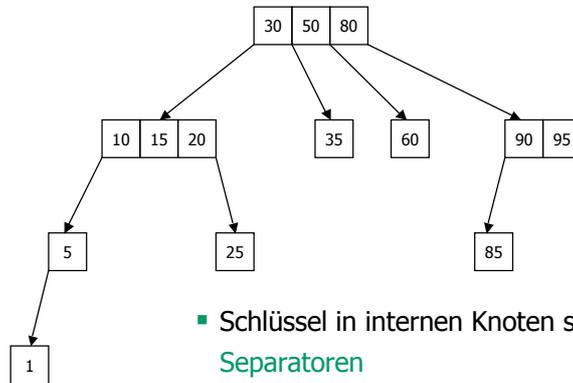
$$N = \sum_{i=0}^{h-1} m^i = \frac{m^h - 1}{m - 1}$$

- Maximale Anzahl n von Schlüsseln:
 - Sei b = Anzahl der Schlüssel im Knoten mit Grad m : $b \leq m-1$
 - $n \leq N(m-1) = m^h - 1$
- völlig degenerierter Baum: $n = N = h$
- Grenze für die Höhe eines m-Wege-Baumes: $\log_m(n+1) \leq h \leq n$



Beispiel: Einfügen in einen 4-Wege-Baum

- Einfügen von 20, 35, 5, 95, 1, 25, 85

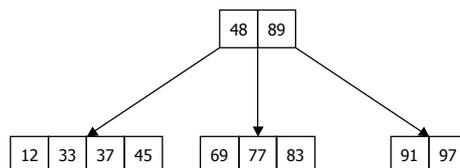


- Schlüssel in internen Knoten sind Schlüssel und Separatoren
- innerhalb eines Knotens: sequentielle Suche, auch binäre Suche möglich



B-Bäume

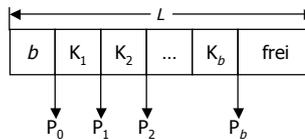
- vielleicht die Datenstruktur, die in der Praxis am meisten benutzt wird
- B-Bäume sind ausgeglichene m-Wege-Bäume
- Da ein Knoten die Größe einer Übertragungseinheit hat (eine Page der Festplatte, typ. 4-16 kBytes), sind 50 Keys pro Knoten üblich
 - sehr flache Bäume
 - kurzer Weg von der Wurzel zu den Blättern





Definition von B-Bäumen

- jeder Weg von der Wurzel zu einem Blatt ist gleich lang
- jeder Knoten (außer Wurzel) enthält mindestens k und höchstens $2k$ Schlüssel
- jeder Knoten (außer der Wurzel) hat zwischen $k+1$ und $2k+1$ Kinder (Unterbäume)
- die Wurzel ist entweder ein Blatt oder hat mindesten 2 Kinder
- jeder Knoten hat die Struktur:



- b ist die Anzahl der Schlüssel im Knoten, $k \leq b \leq 2k$
- Schlüssel in Knoten sind aufsteigend sortiert ($K_1 < K_2 < \dots < K_b$)
- (L = Größe einer Seite)



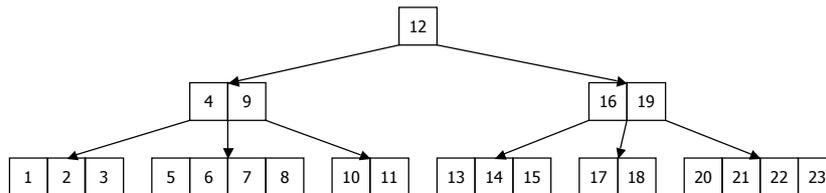
Bemerkungen

- CLRS benutzt eine etwas andere Definition:
 - Für einen B-Baum vom Grad t gilt:
 - jeder Knoten, außer der Wurzel, hat mindestens $t-1$ Schlüssel, also mindestens t Kinder
 - jeder Knoten besitzt höchstens $2t-1$ Schlüssel, also höchstens $2t$ Kinder
 - Formeln müssen „angepasst“ werden, damit sie stimmen
 - die Prüfung läuft gemäß den Folien, bei Unsicherheiten die Definition angeben



Die Klasse $\tau(k, h)$

- die Klasse $\tau(k, h)$ bezeichnet alle B-Bäume mit $k > 0$ und der Höhe $h \geq 0$
- Beispiel: B-Baum der Klasse $\tau(2, 3)$



Höhe eines B-Baumes

- Für die Höhe eines B-Baumes mit n Schlüsseln gilt:

$$\log_{2k+1}(n+1) \leq h \leq \log_{k+1}\left(\frac{n+1}{2}\right) + 1$$



Erklärung

- in einem **minimalen** B-Baum hat jeder Knoten die **kleinstmögliche** Anzahl an Kindern:

$$\begin{aligned} N_{\min}(k, h) &= 1 + 2 + 2 \left((k+1) + (k+1)^2 + \dots + (k+1)^{h-2} \right) \\ &= 1 + 2 \sum_{i=0}^{h-2} (k+1)^i = 1 + 2 \frac{(k+1)^{h-1} - 1}{k} \end{aligned}$$

- in einem **maximalen** B-Baum hat jeder Knoten die **größtmögliche** Anzahl $(2k+1)$ an Kindern:

$$\begin{aligned} N_{\max}(k, h) &= 1 + (2k+1) + (2k+1)^2 + \dots + (2k+1)^{h-1} \\ &= \sum_{i=0}^{h-1} (2k+1)^i = \frac{(2k+1)^h - 1}{2k} \end{aligned}$$



- die Höhe definiert eine obere und untere Schranke für die Anzahl der Knoten $N(B)$ eines beliebigen B-Baumes der Klasse $\tau(k, h)$:

$$\begin{aligned} 1 + 2 \frac{(k+1)^{h-1} - 1}{k} \leq N(B) \leq \frac{(2k+1)^h - 1}{2k} & \quad \text{für } h \geq 1 \\ N(B) = 0 & \quad \text{für } h = 0 \end{aligned}$$

- von $N_{\min}(B)$ und $N_{\max}(B)$ lässt sich ableiten:

$$\begin{aligned} n \geq n_{\min} &= 1 + 2 \frac{(k+1)^{h-1} - 1}{k} k = 2(k+1)^{h-1} - 1 \\ n \leq n_{\max} &= \frac{(2k+1)^h - 1}{2k} 2k = (2k+1)^h - 1 \end{aligned}$$

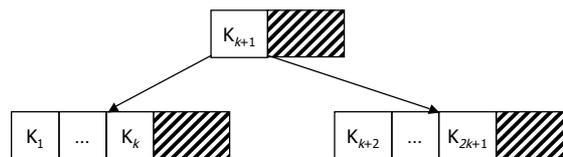
- Somit gilt für die Schlüsselanzahl in einem B-Baum:

$$2(k+1)^{h-1} - 1 \leq n \leq (2k+1)^h - 1$$



Einfügen in einen B-Baum

- füge anfangs in ein leeres Feld der Wurzel ein
- die ersten $2k$ Schlüssel werden geordnet in die Wurzel eingefügt
- der nächste, der $(2k+1)$ -te, Schlüssel passt nicht und erzeugt einen "Überlauf"
- die Wurzel wird **geteilt**, jeder der beiden Knoten bekommt k Keys, ein neuer Knoten wird Wurzel
- die ersten k Schlüssel kommen in den linken Unterbaum
- die letzten k Schlüssel kommen in den rechten Unterbaum
- Der **Median** der $(2k+1)$ Schlüssel wird zum neuen **Separator** im neuen Wurzel-Knoten



- neue Schlüssel werden in den Blättern sortiert gespeichert
- läuft ein Blatt über $(2k+1)$ Keys, wird ein **Split** durchgeführt:
 - Das Blatt wird geteilt (ergibt 2 Knoten à k Keys),
 - diese werden im Vaterknoten anstelle des ursprünglichen Blattes verankert, und
 - der Median-Schlüssel wandert in den Vaterknoten
- ist auch der Elternknoten voll, wird das Splitten fortgesetzt
- Im worst-case bis zur Wurzel

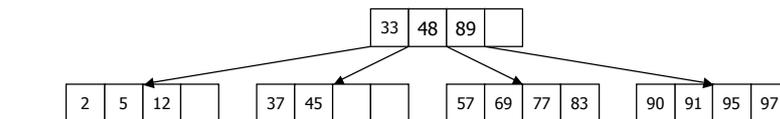
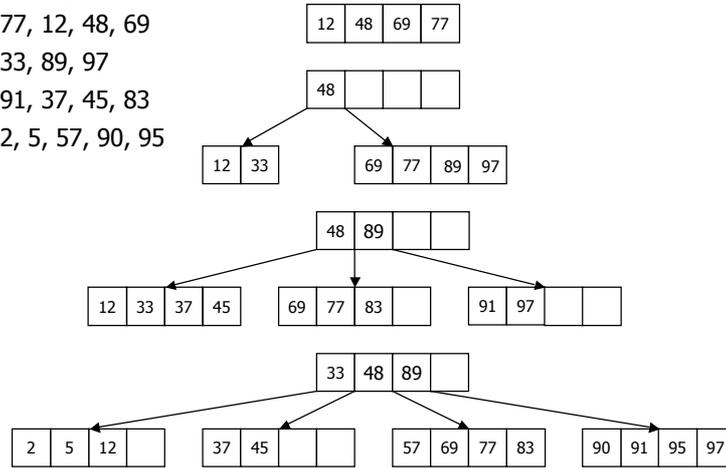


Beispiel

- $k = 2 \rightarrow 2 \leq \# \text{Schlüssel} \leq 4$ (außer Wurzel)

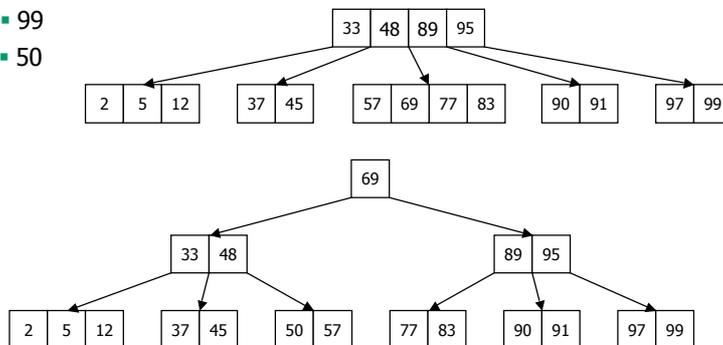
- **Einzufügende Schlüssel:**

- 77, 12, 48, 69
- 33, 89, 97
- 91, 37, 45, 83
- 2, 5, 57, 90, 95



- **Einzufügende Schlüssel:**

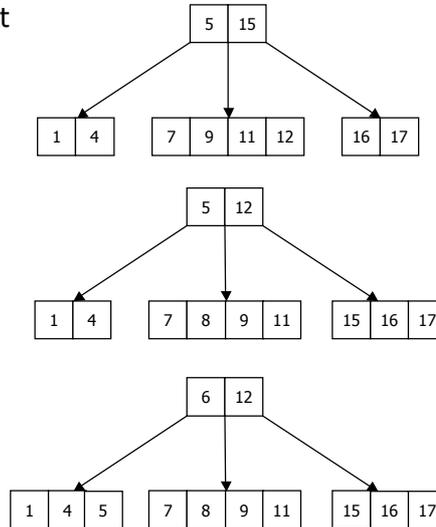
- 99
- 50





Variante statt Split (B*-Baum)

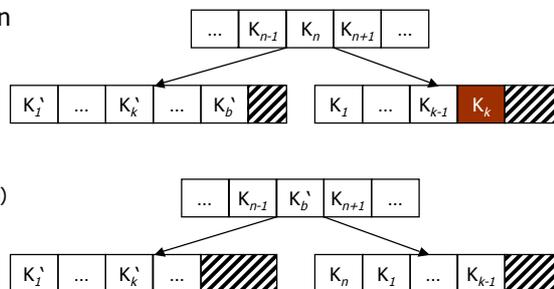
- Idee: Ausgleich mit Nachbarknoten statt Split
- füge ein:
 - 8
 - 6



Löschen in einem B-Baum

- Bedingung durch Def.: minimale Belegung eines Knotens erhalten
- Methoden:
 - Ausgleich mit Nachbarknoten (**Rotation**)
 - Mischung (**Merge**)
- Beispiel: K_k wird gelöscht:

- Wende **Rotation** an
- Schlüssel K_b' wird in den Vaterknoten verschoben, Schlüssel K_n kommt in den rechten Knoten (mit $k-1$ Knoten)



- um wiederholte Anpassungen (durch neue Löschoptionen) zu vermeiden, kann mehr als ein Schlüssel rotiert werden
 - beide Knoten haben danach ungefähr die gleiche Schlüsselanzahl
- Beispiel: 33 soll entfernt werden

Unterlauf

G. Zachmann Informatik 2 - SS 06 Bäume 112

- Zweite Art der Unterlauf-Behandlung: **Mischen**
 - wird benutzt, wenn es einen Unterlauf gibt und beide Nachbarknoten genau k Schlüssel haben
 - d.h., man kann nichts vom linken / rechten Knoten "stehlen"
 - Beispiel: K_k löschen

- Der Separator und Schlüssel $k-1$ werden mit den k Schlüsseln im anderen Knoten eingefügt

G. Zachmann Informatik 2 - SS 06 Bäume 113



B⁺-Bäume

- in einem B-Baum haben die Schlüssel K_i 2 Funktionen:
 - K_i dienen als Separatoren
 - Nutzdaten werden mit im Baum gespeichert (auch in inneren Knoten)
- ein B⁺-Baum teilt diese Eigenschaften auf:
 - K_i werden nur als Separatoren benutzt (ergibt einen flacheren Baum)
 - Schlüssel werden redundant gespeichert (vereinfachte Löschoptionen wiegen den zusätzlichen Speicherbedarf auf)
 - die Blätter werden zu einer Liste verlinkt
 - auf die Daten kann man in sequentieller Ordnung zugreifen
- interne Knoten sind ein sog. **Index** auf die Blätter



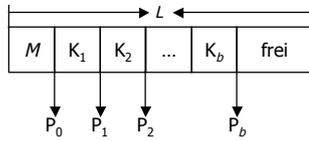
Definition eines B⁺-Baum

- Seien k, l, h ganze Zahlen mit $h \geq 0, k > 0, l > 0$
- Ein B⁺-Baum der Klasse $\tau(k, l, h)$ ist entweder ein leerer Baum oder ein sortierter Baum mit den folgenden Eigenschaften:
 1. alle Wege von der Wurzel zu einem Blatt haben die gleiche Länge
 2. jeder innere Knoten (außer Wurzel) enthält mindestens k und höchstens $2k$ Schlüssel
 3. jeder innere Knoten (außer der Wurzel) hat zwischen $k+1$ und $2k+1$ Kinder
 4. alle Blätter (außer der Wurzel als Blatt) haben mindestens l und höchstens $2l$ Schlüssel
 5. Schlüssel können **mehrfach** auf einem Weg zu den Blättern vorkommen
 1. in inneren Knoten nur Separatoren ohne Nutzdaten ("*satellite data*")
 2. an Blättern zusammen mit den Nutzdaten
 6. Alle Blätter sind zu einer sortierten Liste verlinkt



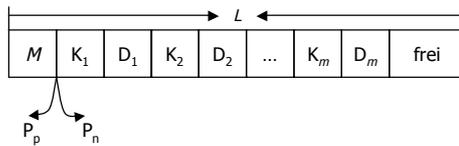
Format der Knoten

- die **internen** Knoten haben folgendes Format:



- M gibt den Typ des Knoten und die Anzahl der Schlüssel ($k \leq b \leq 2k$) an

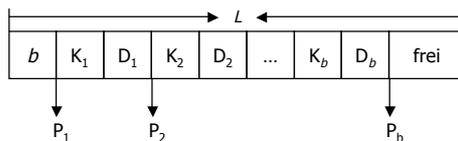
- die **Blätter** haben folgendes Format:



- M gibt den Typ des Knoten und die Anzahl der Schlüssel ($l \leq m \leq 2l$) an
- P_p zeigt auf den vorhergehenden und P_n auf den nächsten Blatt-Knoten



Größe der Knoten im B-Baum



- b ist die Anzahl der Elemente, mit Länge L_b
- Elemente mit fester Länge (L_K und L_D)
- Zeiger haben Länge L_P
- Max. Anzahl der Einträge ist also:

$$b_{\max} = \left\lfloor \frac{L - L_b - L_P}{L_K + L_D + L_P} \right\rfloor = 2k$$



Größe der Knoten im B⁺-Baum

- für Knoten mit fester Länge L kann k aus L errechnet werden

- interne Knoten:

$$L = L_M + L_P + 2k(L_K + L_P)$$

$$k = \left\lfloor \frac{L - L_M - L_P}{2(L_K + L_P)} \right\rfloor$$

- Blätter:

$$L = L_M + 2L_P + 2l(L_K + L_D)$$

$$l = \left\lfloor \frac{L - L_M - 2L_P}{2(L_K + L_D)} \right\rfloor$$



Beispiel

- B⁺-Baum der Klasse $\tau(3, 2, 3)$

[$k = 3, l = 2, h = 3$]

