Datenbanken

Prof. Dr. Ralf Möller

Universität zu Lübeck

Institut für Informationssysteme

Karsten Martiny (Übungen)

Architektur eines DBMS

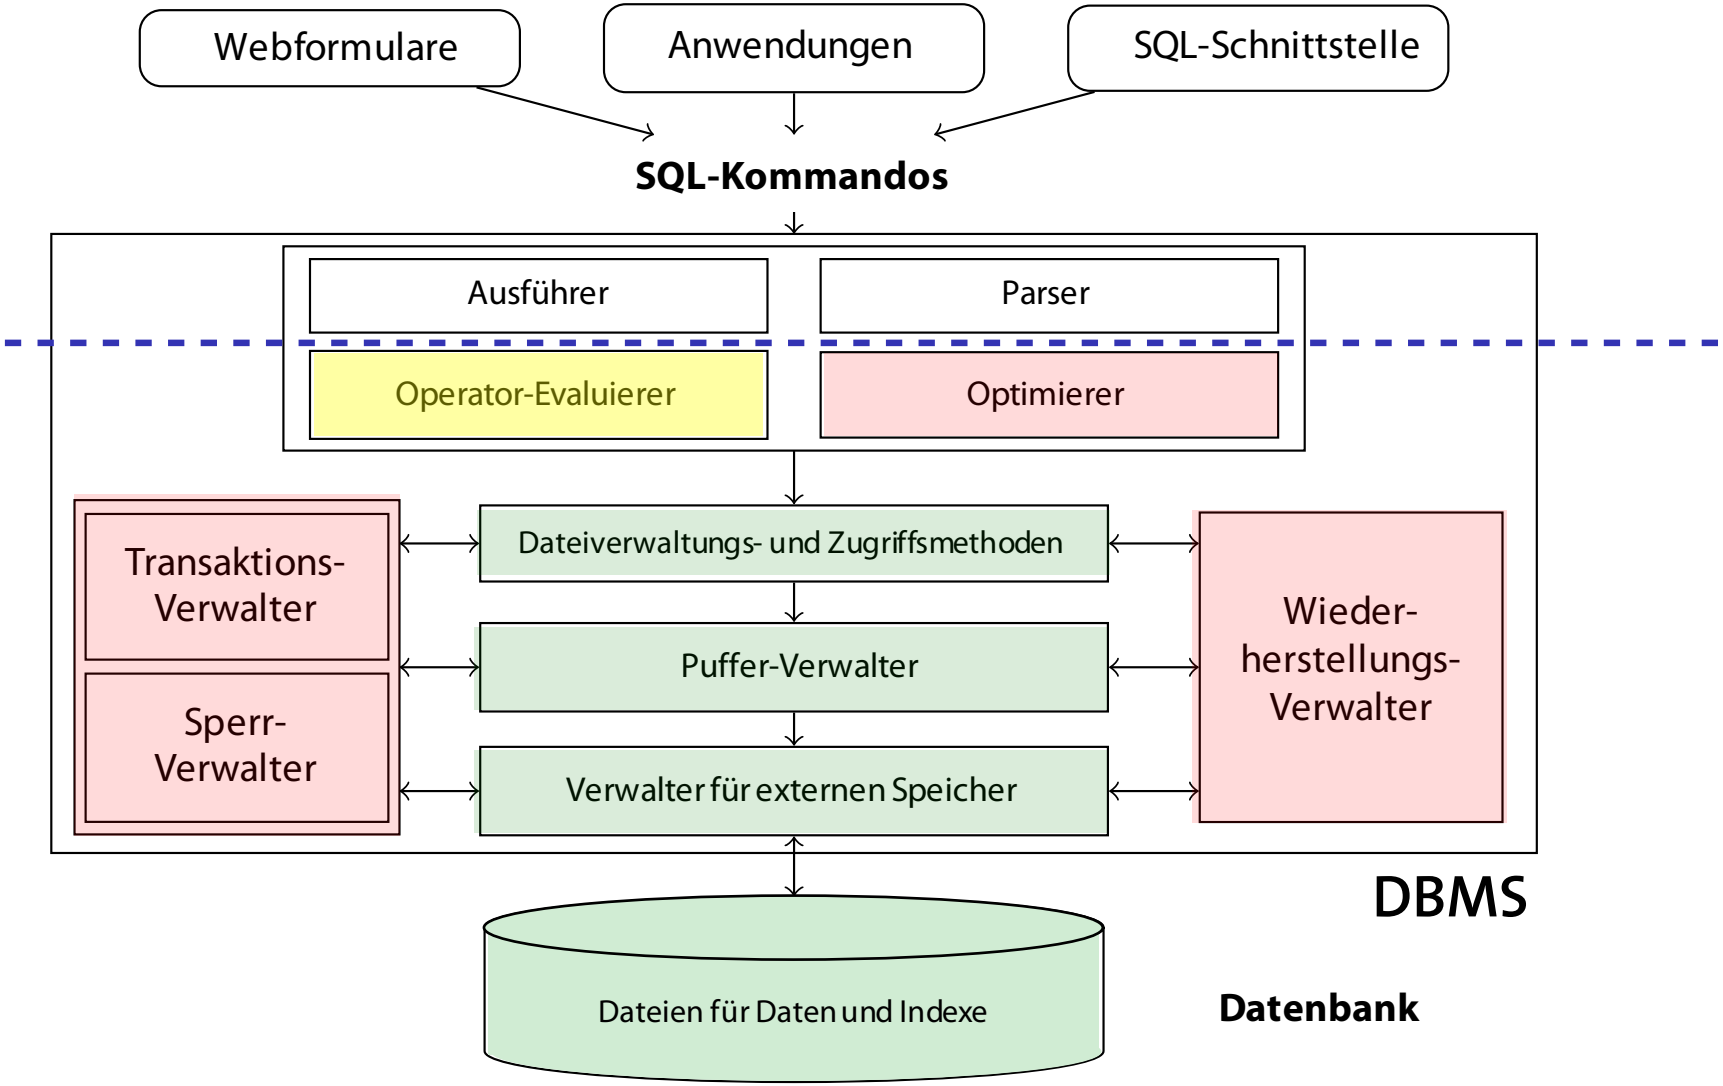

Danksagung

- Diese Vorlesung ist inspiriert von den Präsentationen zu dem Kurs:

  „Architecture and Implementation of Database Systems“ von Jens Teubner an der ETH Zürich

- Graphiken wurden mit Zustimmung des Autors aus diesem Kurs übernommen

Effiziente Evaluierung einer Anfrage

```
SELECT *
FROM CUSTOMERS
WHERE ZIPCODE BETWEEN 8800 AND 8999
```

- Sortierung der Tabelle CUSTOMERS auf der Platte (nach ZIPCODE)
- Zur Evaluierung von Anfragen Verwendung von binärer Suche, um erstes Tupel zu finden, dann Scan solange ZIPCODE < 8999

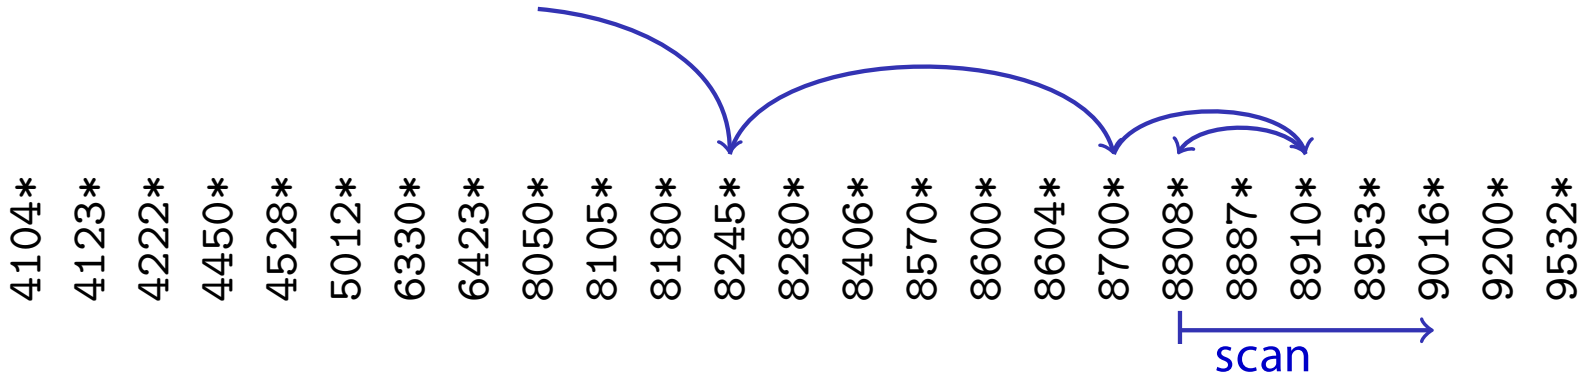

k* denotiert einen Datensatz mit Schlüssel k

Geordnete Dateien und binäre Suche

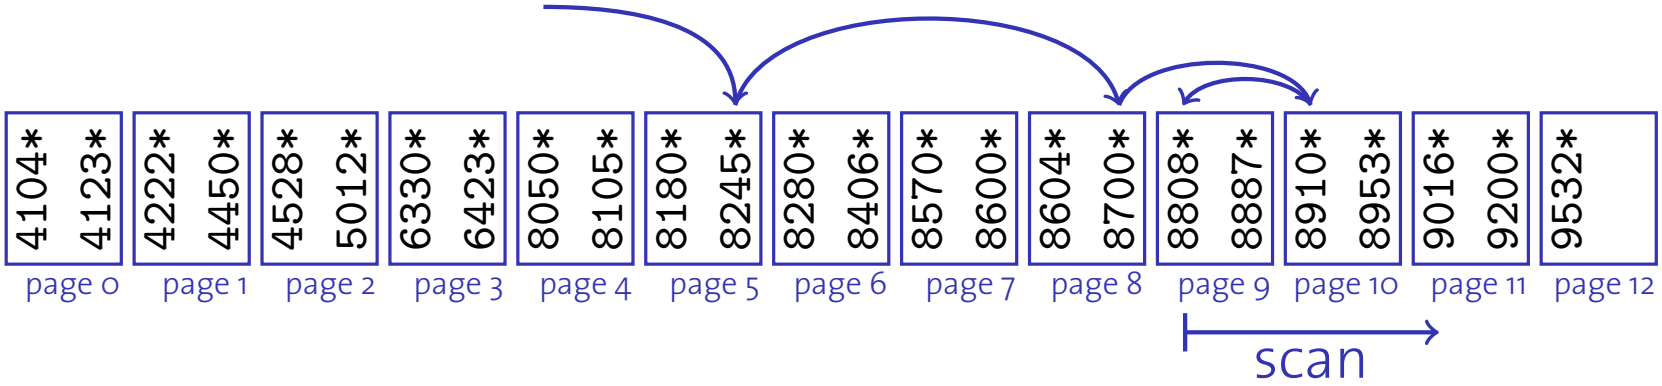

✓ Sequentieller Zugriff während der Scan-Phase

Es müssen $\log_2$(#Tupel) während der Such-Phase gelesen werden

✗ Für jeden Zugriff eine Seite!

- Weite Sprünge sind die Idee der binären Suche
- Kein Prefetching möglich

ISAM: Indexed Sequential Access Method

Idee: Beschleunige die Suchphase durch sog. Index

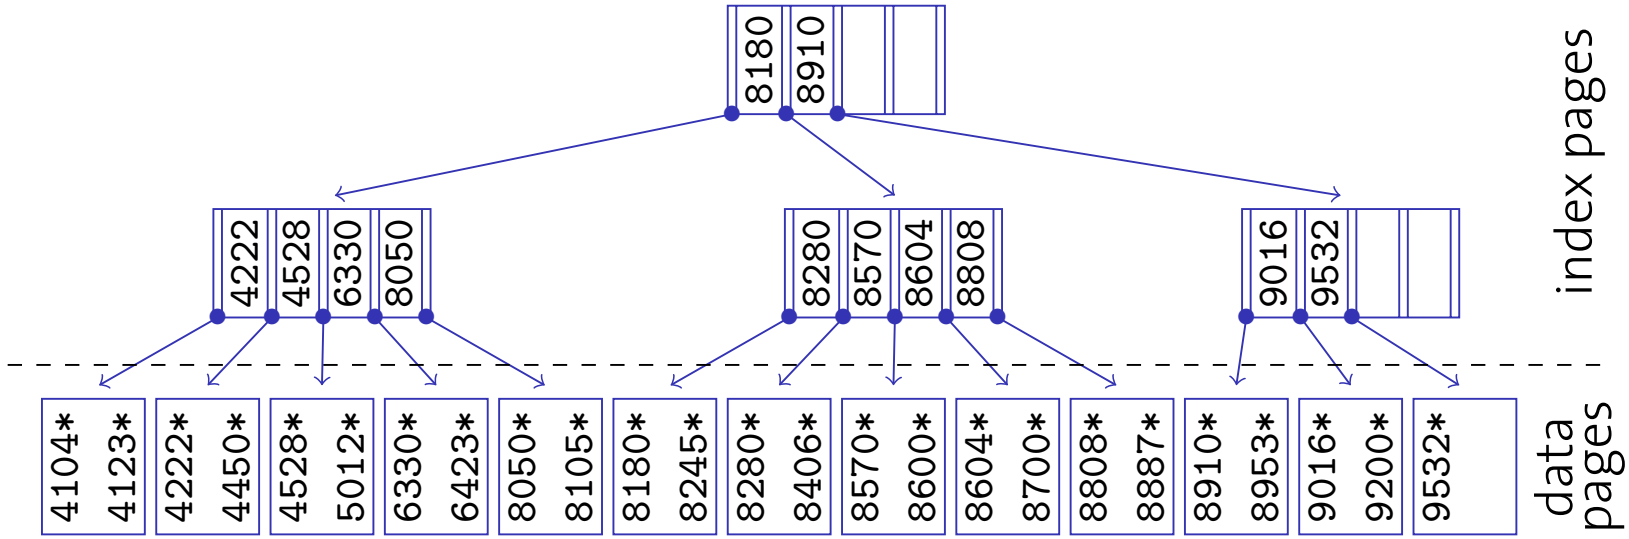

- Knoten von der Größe einer Seite
  - Hunderte Einträge pro Seite
  - Hohe Verzweigung, kleine Tiefe
- Suchaufwand: $\log_{\text{Verzweigung}}(\#\text{Tupel})$

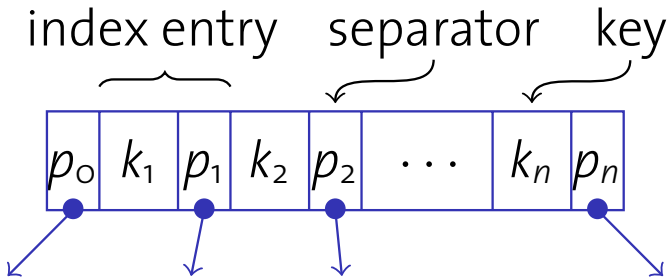

ISAM-Index: Aktualisierungsoperationen

ISAM-Indexe sind statisch

- **Löschen** einfach: Lösche Datensatz von Datenseite
- **Einfügen** von Daten aufwendig
  - Falls noch Platz auf Blattseite, füge Datensatz ein (z.B. nach einer vorherigen Löschung)
  - Sonst füge **Überlauf-Seite** ein (zerstört sequentielle Ordnung)
  - ISAM-Index **degeneriert**

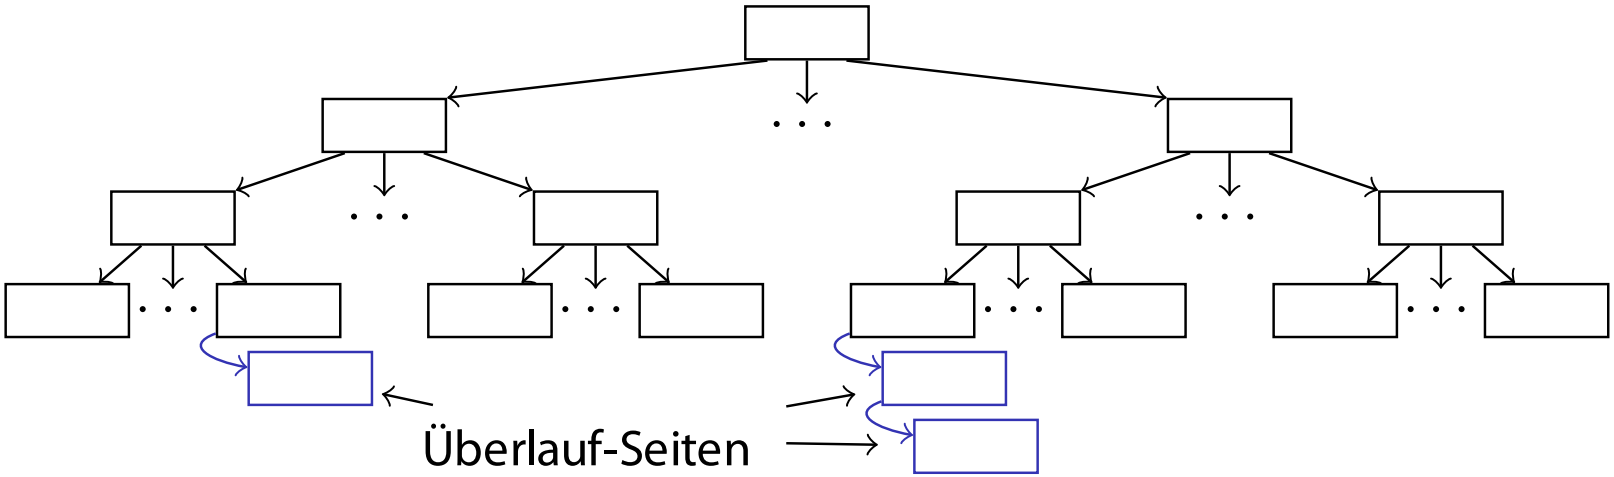

Anmerkungen

- Das Vorsehen von Freiraum bei der Indexerzeugung reduziert das Einfügeproblem (typisch sind 20% Freiraum)
- Da Seiten statisch, keine Zugriffskoordination nötig
  - Zugriffskoordination (Sperren) vermindert gleichzeitigen Zugriff (besonders nahe der Wurzel) für andere Anfragen
- ISAM ist nützlich für (relativ) statische Daten

B^+-Bäume: Eine dynamische Indexstruktur

B^+-Bäume von ISAM-Index abgeleitet, sind aber dynamisch

- Keine Überlauf-Ketten
- Balancierung wird aufrechterhalten
- Behandelt insert und delete angemessen

Minimale Besetzungsregel für B^+-Baum-Knoten (außer der Wurzel): 50% (typisch sind 67%)

- Verzweigung nicht zu klein (Zugriff O(log n))
- Indexknotensuche nicht zu linear

R. Bayer and E. M. McCreight, Organization and Maintenance of Large Ordered Indexes, Acta Informatica, vol. 1, no. 3, **1972**

B^+-Bäume: Grundlagen

B^+-Bäume ähnlich zu ISAM-Index, wobei

- Blattknoten üblicherweise nicht in seq. Ordnung
- Blätter zu doppelt verketteter Liste verbunden

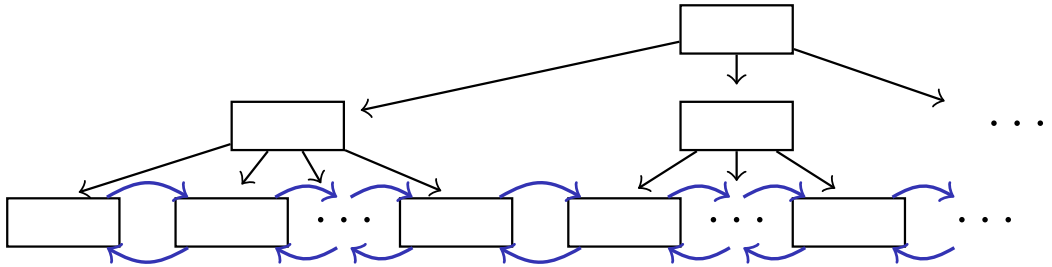

- Blätter enthalten tatsächliche Daten (wie ISAM-Index) oder Referenzen (Rids) auf Datenseiten
  - Wir nehmen im Folgenden Letzteres an
- Jeder Knoten enthält zwischen d und 2d Einträge (d heißt Ordnung des Baumes, Wurzel ist Ausnahme)

Suche im B$^+$-Baum

```
1  Function: search (k)
2  return tree_search (k, root);
```

```
1  Function: tree_search (k, node)
2  if node is a leaf then
3      return node;
4  switch k do
5      case k < k_1
6          return tree_search (k, p_0);
7      case k_i ≤ k < k_{i+1}
8          return tree_search (k, p_i);
9      case k_last < k
10         return tree_search (k, p_last);
```

$i < last \leq 2d$

- Funktionsaufruf search(k) bestimmt Blatt, das potentielle Treffer für eine Suche nach Elementen mit Schlüssel k enthält

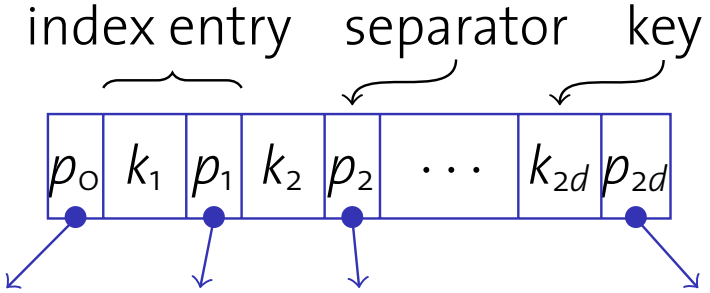

node page layout

Insert: Überblick

- B^+-Baum soll nach Einfügung balanciert bleiben
  - keine Überlauf-Seiten
- Algorithmus für insert(k, p) für Schlüsselwert k und Datenseite p
  1. Finde Blattseite n, in der Eintrag für k sein kann
  2. Falls n genug Platz hat (höchstens 2d-1 Einträge), füge Eintrag <k, p> in n ein
  3. Sonst muss Knoten n aufgeteilt werden in n und n‘ – weiterhin muss ein Separator in den Vater von n eingefügt werden

  Die mögliche Aufspaltung erfolgt rekursiv nach oben, eventuell bis zur Wurzel (wodurch sich der Baum erhöht)

Insert: Beispiel ohne Aufspaltung

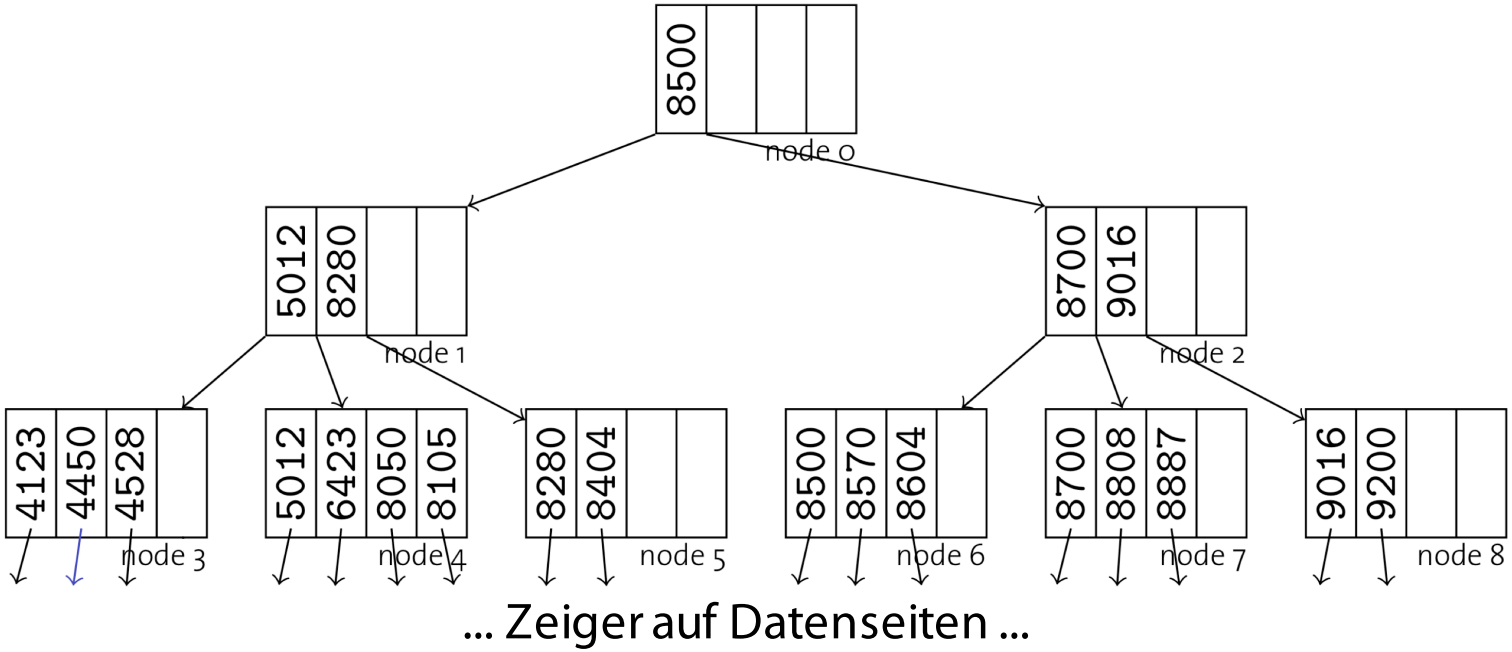

- Einfügung eines Eintrags mit Schlüssel 4222
  - Es ist genug Platz in Knoten 3, einfach einfügen
  - Erhalte Sortierung innerhalb der Knoten

Insert: Beispiel ohne Aufspaltung

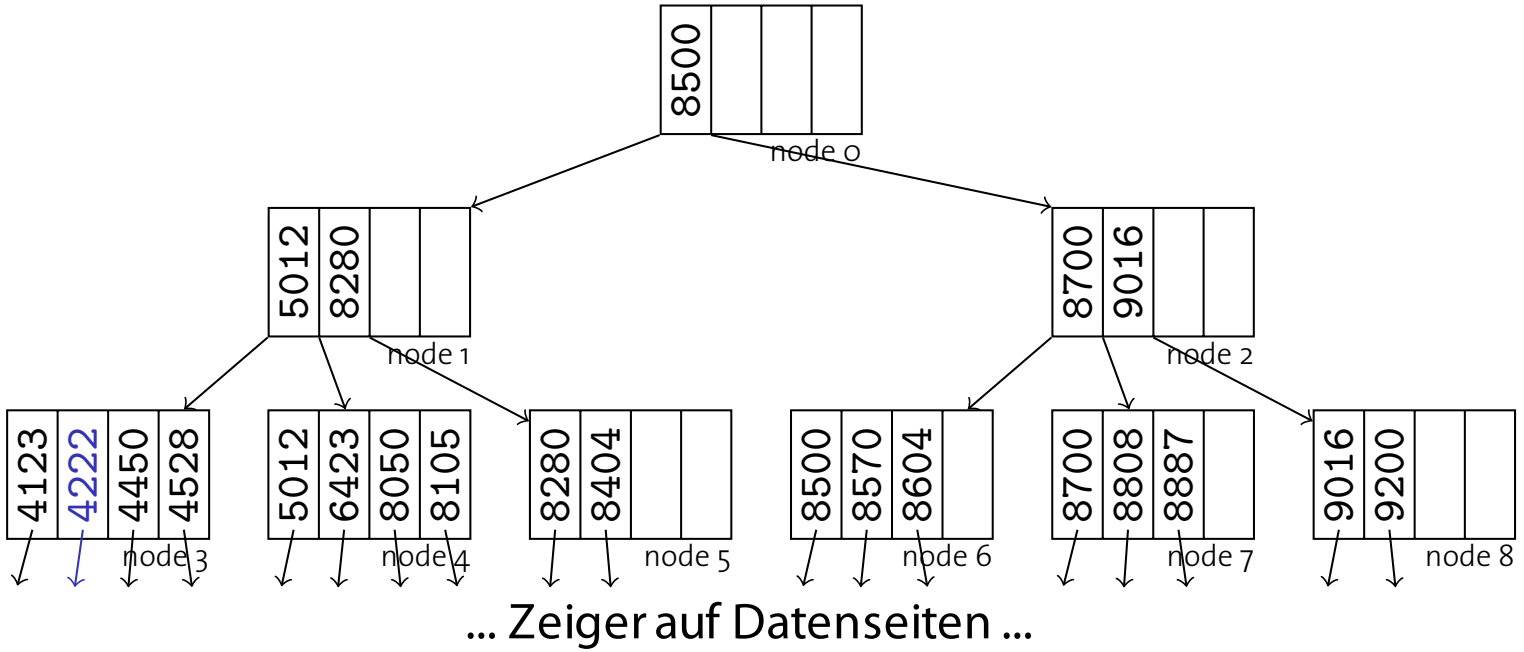

- Einfügung eines Eintrags mit Schlüssel 4222
  - Es ist genug Platz in Knoten 3, einfach einfügen
  - Erhalte Sortierung innerhalb der Knoten

Insert: Beispiel mit Aufspaltung

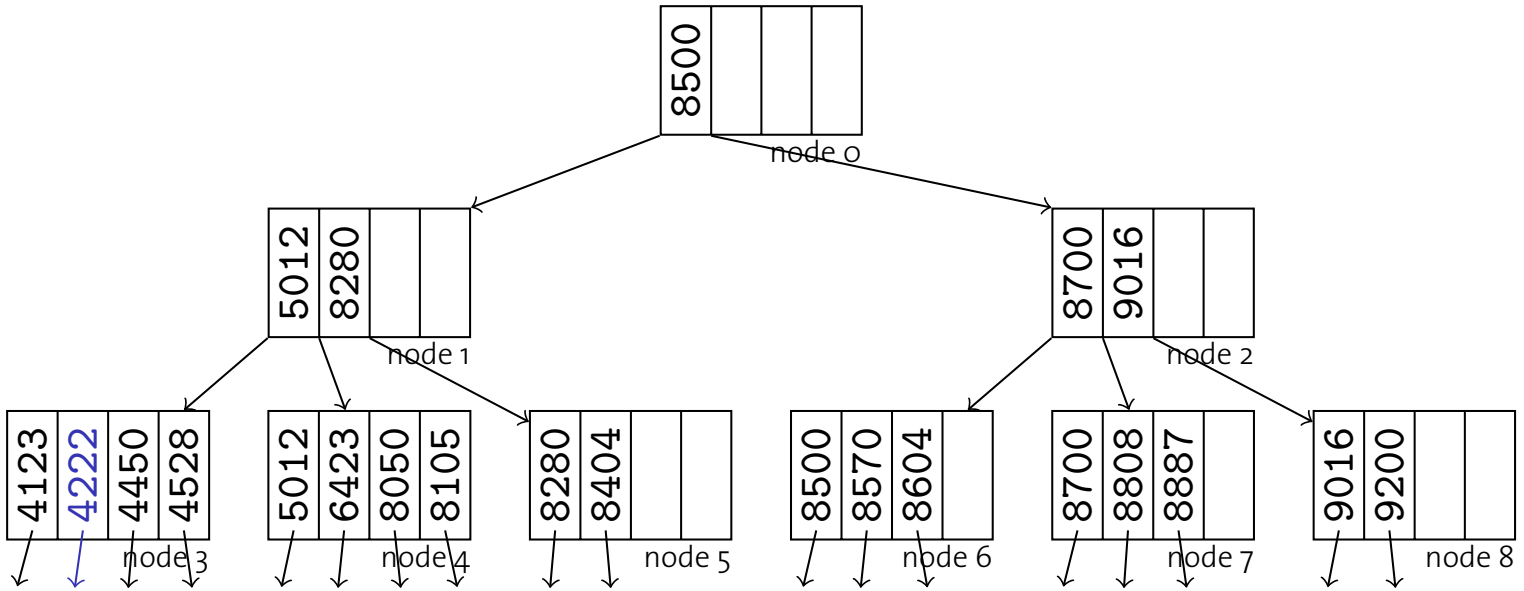

- Einfügung eines Eintrags mit Schlüssel 6330
  - Knoten 4 aufgespalten
  - Neuer Separator in Knoten 1

Insert: Beispiel mit Aufspaltung

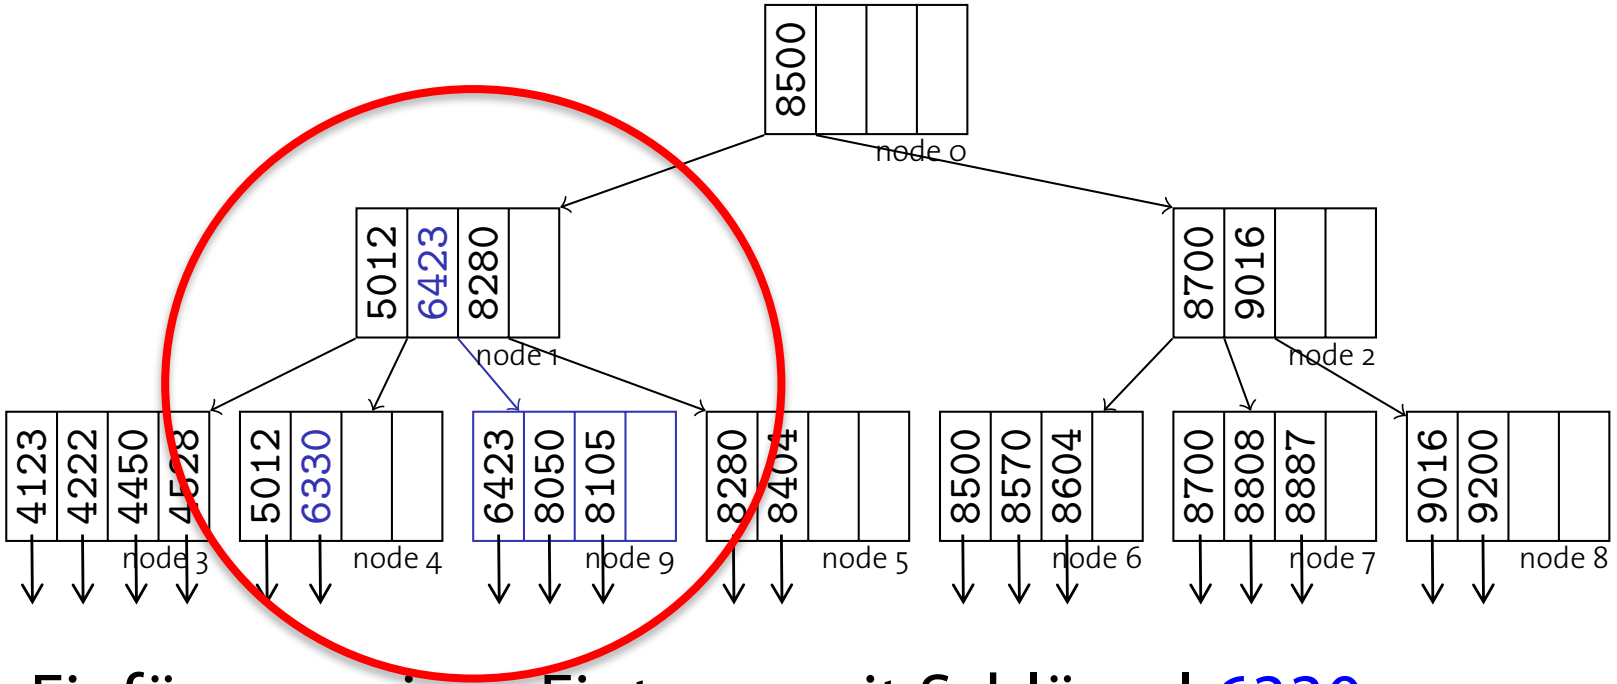

- Einfügung eines Eintrags mit Schlüssel 6330
  - Knoten 4 aufgespalten
  - Neuer Separator in Knoten 1

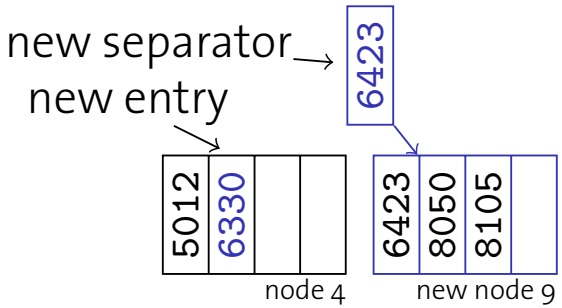

Insert: Beispiel mit Aufspaltung

- Einfügung von 8180, 8245...

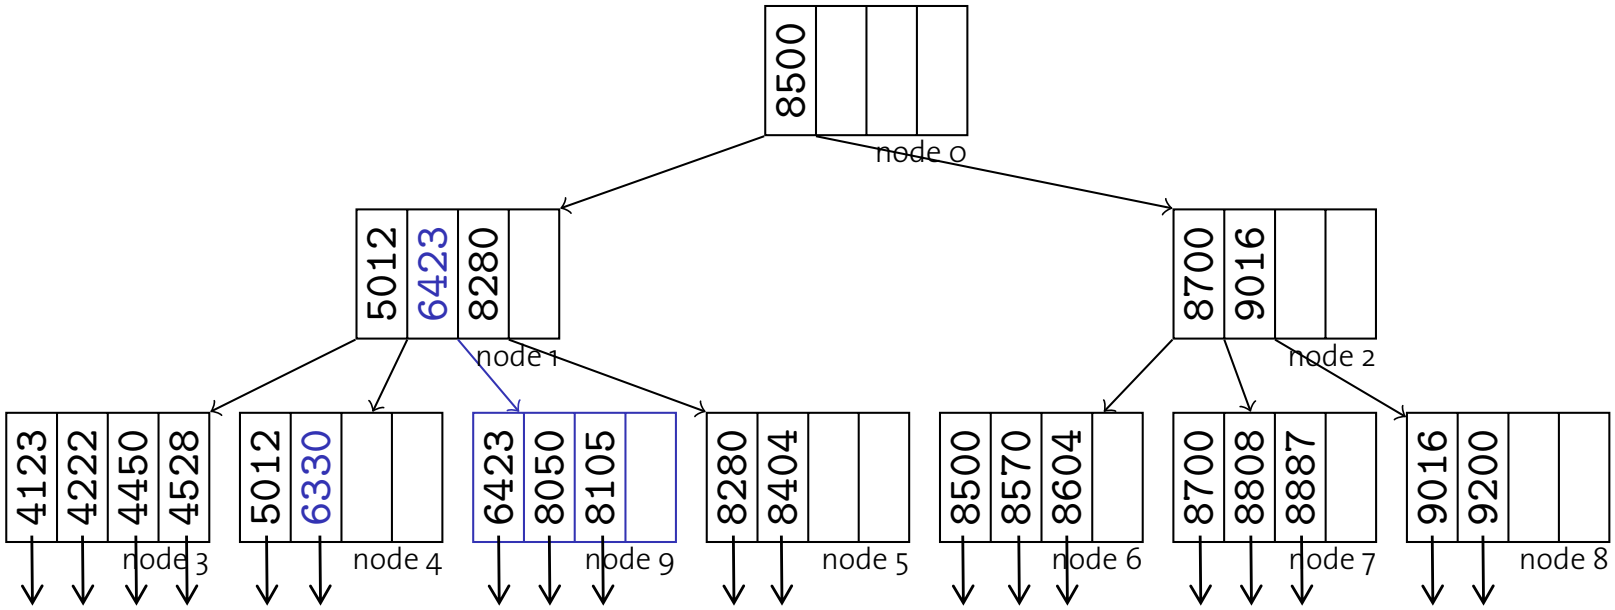

Insert: Beispiele mit Aufspaltung innerer Knoten

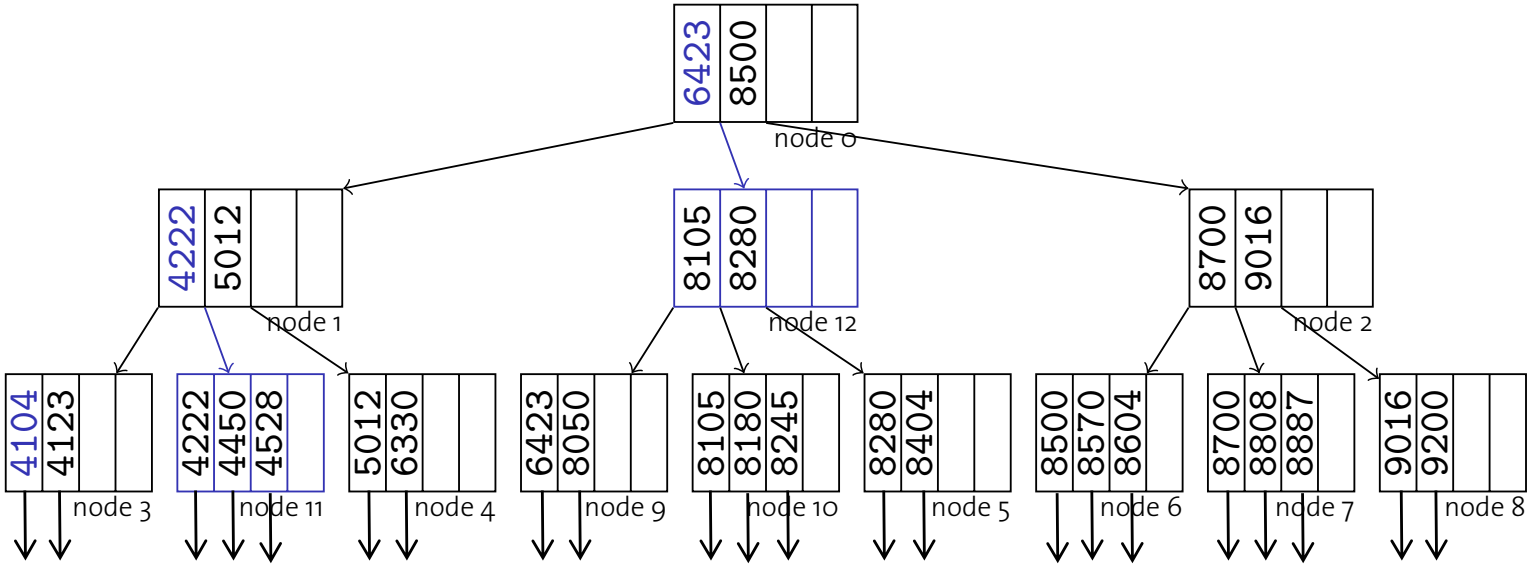

Nach 8180, 8245, füge 4104 ein

- Aufspaltung von Knoten 3 und 9
- Knoten 1 läuft über → Aufspaltung
- Neuer Separator für Wurzel

Separatorschlüssel aus inneren Knoten können sich verschieben

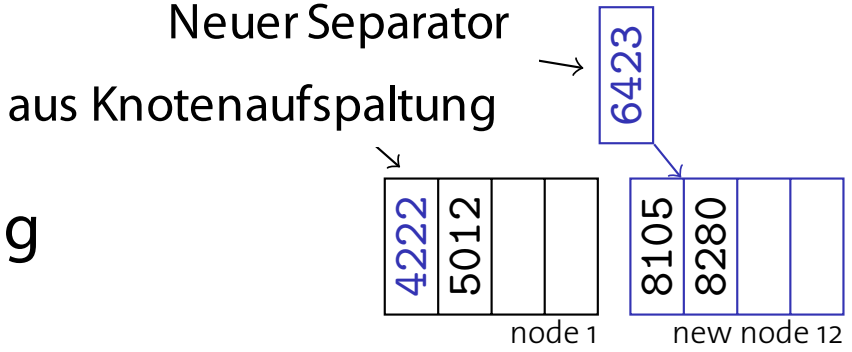

Warum?

Insert: Aufspaltung eines inneren Knotens

- Aufspaltung beginnt auf Blattebene und verläuft nach oben solange Indexknoten vollständig belegt
- Schließlich kann die Wurzel aufgespalten werden
  - Aufspaltung wie bei inneren Knoten
  - Separator für einen neuen Wurzelknoten verwenden
- Nur Wurzelknoten mit Füllgrad < 50% möglich
- Erhöhung nur bei Einfügung einer neuen Wurzel

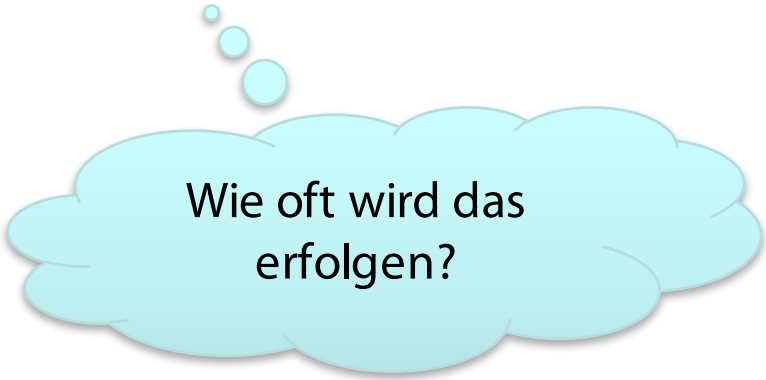

Zusammenfassung: Algorithmus tree_insert

```
1  Function: tree_insert (k, rid, node)
2  if node is a leaf then
3      return leaf_insert (k, rid, node);
4  else
5      switch k do
6          case k < k_1
7              ⟨sep, ptr⟩ ← tree_insert (k, rid, p_o);
8          case k_i ≤ k < k_{i+1}
9              ⟨sep, ptr⟩ ← tree_insert (k, rid, p_i);
10         case k_last < k
11             ⟨sep, ptr⟩ ← tree_insert (k, rid, p_last);
12     if sep is null then
13         return ⟨null, null⟩;
14     else
15         return split (sep, ptr, node);
```

} see `tree_search ()`

$i < last \leq 2d$

Algorithmus leaf_insert

```
1  Function: leaf_insert(k, rid, node)
2  if another entry fits into node then
3      insert ⟨k, rid⟩ into node ;
4      return ⟨null, null⟩;
5  else
6      allocate new leaf page p ;
7      take {⟨k_1^+, p_1^+⟩, ..., ⟨k_{2d+1}^+, p_{2d+1}^+⟩} := entries from node ∪ {⟨k, ptr⟩}
8          leave entries ⟨k_1^+, p_1^+⟩, ..., ⟨k_d^+, p_d^+⟩ in node ;
9          move entries ⟨k_{d+1}^+, p_{d+1}^+⟩, ..., ⟨k_{2d+1}^+, p_{2d+1}^+⟩ to p ;
10     return ⟨k_{d+1}^+, p⟩;
```

Algorithmus split

```
1  Function: split (k, ptr, node)
2  if another entry fits into node then
3      insert ⟨k, ptr⟩ into node ;
4      return ⟨null, null⟩;
5  else
6      allocate new node p;
7      take {⟨k_1^+, p_1^+⟩, ..., ⟨k_{2d+1}^+, p_{2d+1}^+⟩} := entries from node ∪ {⟨k, ptr⟩}
8          leave entries ⟨k_1^+, p_1^+⟩, ..., ⟨k_d^+, p_d^+⟩ in node ;
9          move entries ⟨k_{d+2}^+, p_{d+2}^+⟩, ..., ⟨k_{2d+1}^+, p_{2d+1}^+⟩ to p ;
10         set p_0 ← p_{d+1}^+ in node;
11     return ⟨k_{d+1}^+, p⟩;
```

Der erste Zeiger p_0 in der neuen Seite p wird auf p_{d+1} gesetzt. Dieser Zeiger bildet die Trennstelle, kommt demnach nicht mehr auf der alten Seite *node* vor.

Algorithmus insert

```
1 Function: insert (k, rid)
2 ⟨key, ptr⟩ ← tree_insert (k, rid, root); // root contains the root of the index tree
3 if key is not null then
4     allocate new root page r;
5     populate r with
6         p0 ← root;
7         k1 ← key;
8         p1 ← ptr;
9     root ← r ;
```

- insert(k, rid) wird von außen aufgerufen
- Blattknoten enthalten Rids, innere Knoten enthalten Zeiger auf andere B^+-Baum-Knoten

Löschung

- Falls Knoten genügend gefüllt (mindestens d+1 Einträge), Eintrag einfach löschen
  - Hinterher können innere Knoten Schlüssel enthalten, die zu Einträgen gehören, die nicht mehr existieren.
  - Das ist OK
- Sonst verschmelze Knoten wegen Unterfüllung

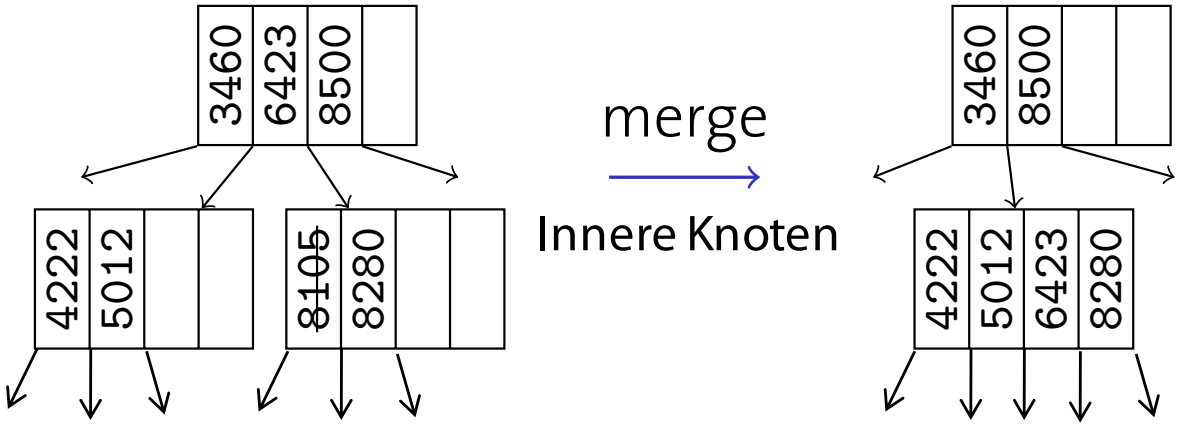

  - Ziehe Separator in den verschmolzenen Knoten

Löschung

- Leider ist die Situation nicht immer so einfach

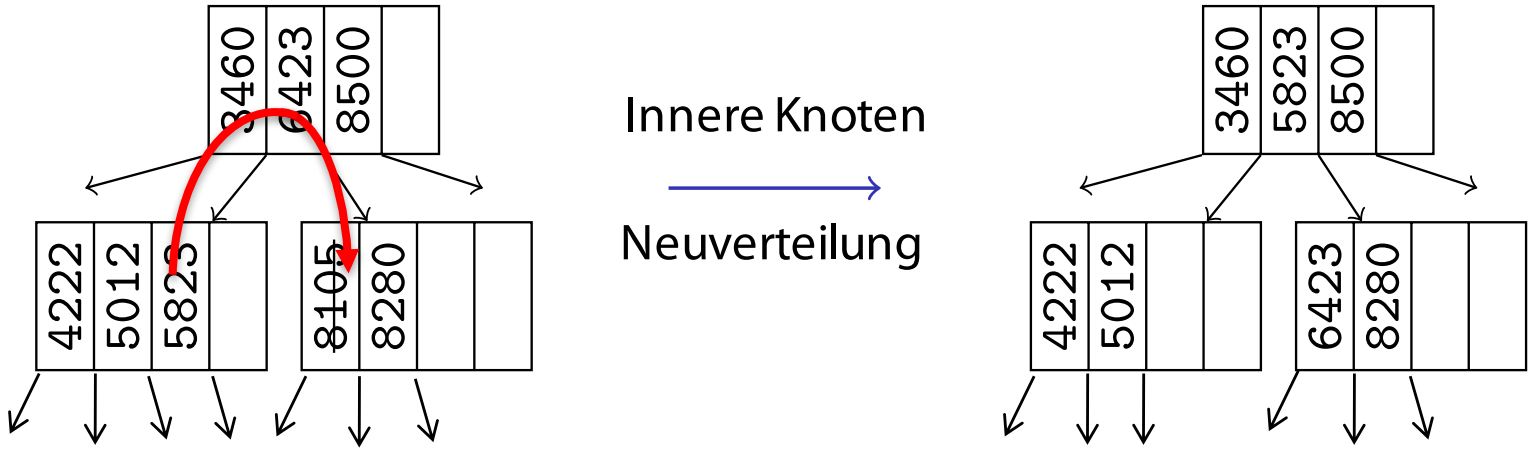

- Verschmelzung nur, wenn Nachbarknoten zu 50% voll
- Sonst muss Neuverteilung erfolgen
  - Rotiere Eintrag über den Elternknoten

B^+-Bäume in realen Systemen

- Implementierungen verzichten auf die Kosten der Verschmelzung und der Neuverteilung und weichen die Regel der Minimumbelegung auf
- Beispiel: IBM DB2 UDB
  - MINPCTUSED als Parameter zur Steuerung der Blattknotenverschmelzung (Online-Indexreorganisation)
  - Innere Knoten werden niemals verschmolzen (nur bei Reorganisation der gesamten Tabelle)
- Zur Verbesserung der Nebenläufigkeit evtl. nur Markierung von Knoten als gelöscht (keine aufwendige Neuverzeigerung)

Was wird in den Blättern gespeichert?

Drei Alternativen

1. Vollständiger Datensatz k*
   (ein solcher Index heißt geclustert, siehe unten)
2. Ein Paar <k, rid>, wobei rid (record ID) ein Zeiger auf einen Datensatz darstellt
3. Ein Paar <k, {rid_1, rid_2, ... }>, wobei alle Rids den Suchschlüssel k haben

Varianten 2. und 3. bedingen, dass Rids stabil sein müssen, also nicht (einfach) verschoben werden können

Alternative 2 scheint am meisten verwendet zu werden

Erzeugung von Indexstrukturen in SQL

Implizite Indexe

Indexe automatisch erzeugt für Primärschlüssel und Unique-Integritätsbedingungen

Explizite Indexe

- Einfache Indexe:

```
CREATE INDEX name
ON table_name(attr) ;
```

Beispiel

```
CREATE INDEX ZipcodeIndex
ON CUSTOMERS(ZIPCODE) ;
```

```
SELECT *
FROM CUSTOMERS
WHERE ZIPCODE BETWEEN 8800 AND 8999 ;
```

- Zusammengesetzte Indexe (Verbundindexe):

```
CREATE INDEX name
ON table_name(attr1, attr2, ..., attrn) ;
```

Indexe mit zusammengesetzten Schlüsseln

B$^+$-Bäume können verwendet werden, um Dinge mit einer definierten **totalen Ordnung** zu indizieren (im Prinzip[1])

- Integer, Zeichenketten, Datumsangaben, ...,
- und auch eine Hintereinandersetzung davon (basierend auf einer lexikographischen Ordnung)

Beispiel:

```
CREATE INDEX idx_lastname_firstname
ON CUSTOMERS (LASTNAME, FIRSTNAME);
```

Eine weitere Anwendung sind **partitionierte B$^+$-Bäume**

- Führende artifizielle Indexattribute partitionieren den B$^+$-Baum horizontal (z.B. zur verteilten Verarbeitung)

[1] In einigen Implementierungen können lange Zeichenketten nicht als Index verwendet werden

G. Graefe: Sorting And Indexing With Partitioned B-Trees. CIDR **2003**

B+-Bäume und Sortierung

Eine typische Situation nach Alternative 2 sieht so aus:

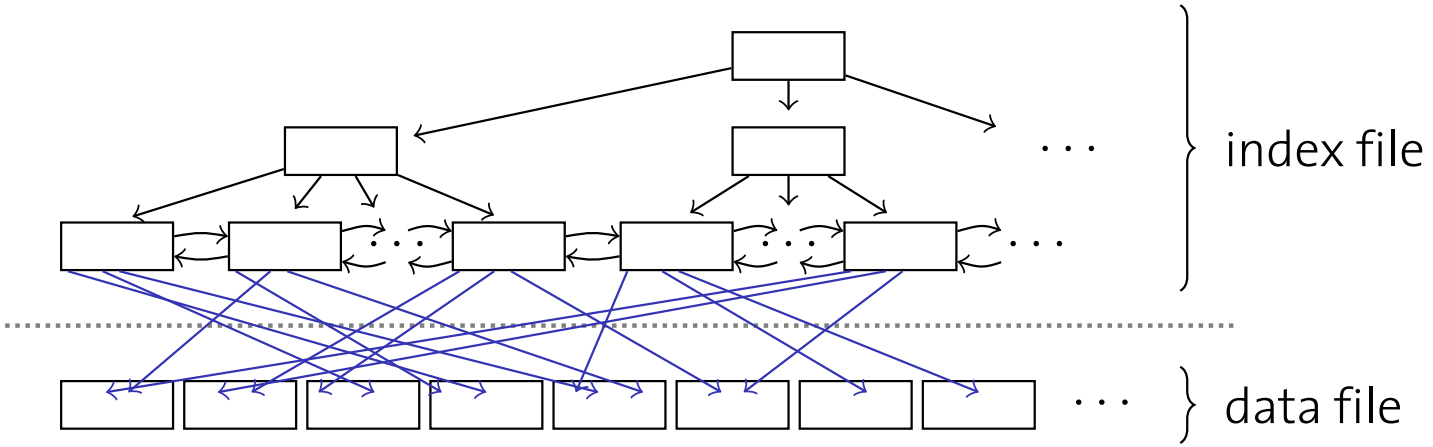

Was passiert, wenn man Folgendes ausführt?

```
SELECT * FORM CUSOTMERS ORDER BY ZIPCODE;
```

Geclusterte B$^+$-Bäume

Wenn die Datei mit den Datensätzen sortiert und sequentiell gespeichert ist, erfolgt der Zugriff schneller

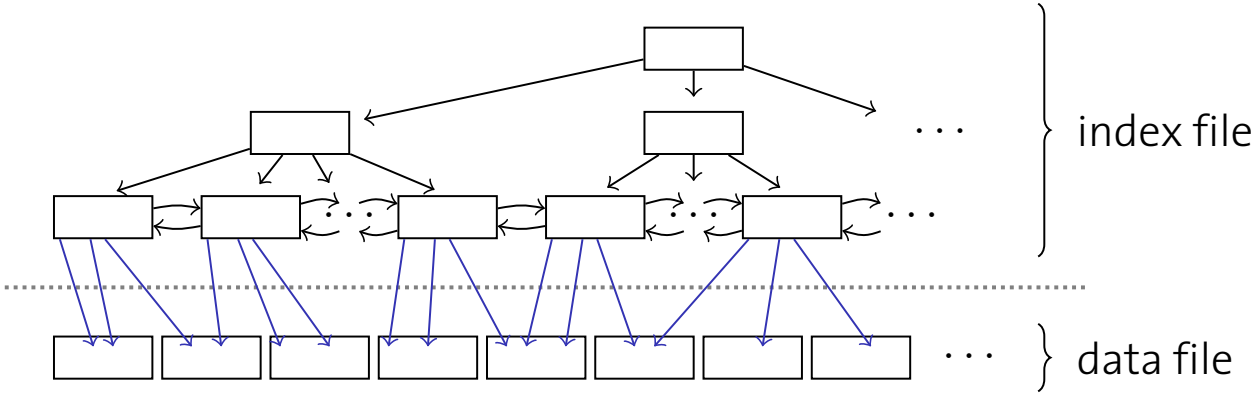

Ein so organisierter Index heißt geclusterter Index

- Sequentieller Zugriff während der Scan-Phase
- Besonders für Bereichsanfragen geeignet

Warum macht man Indexe nicht immer geclustert?

Index-organisierte Tabellen

Alternative 1 von oben ist ein Spezialfall eines geclusterten Index

- Indexdatei = Datensatz-Datei
- Eine solche Datei nennt man index-organisiert

Oracle:

```
CREATE TABLE (...
              ...,
              PRIMARY KEY (...))
ORGANIZATION INDEX;
```

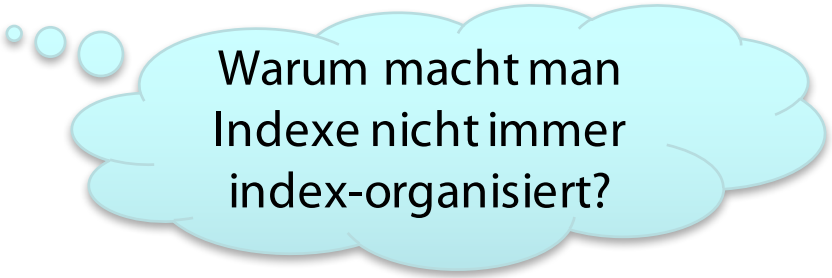

Suffix-Abschneidung

B$^+$-Baum-Verzweigung proportional zur Anzahl der Einträge pro Seite, also umgekehrt proportional zur Schlüsselgröße

- Ziel: Schlüsselgröße verringern
  (insb. relevant bei Zeichenketten variabler Länge)

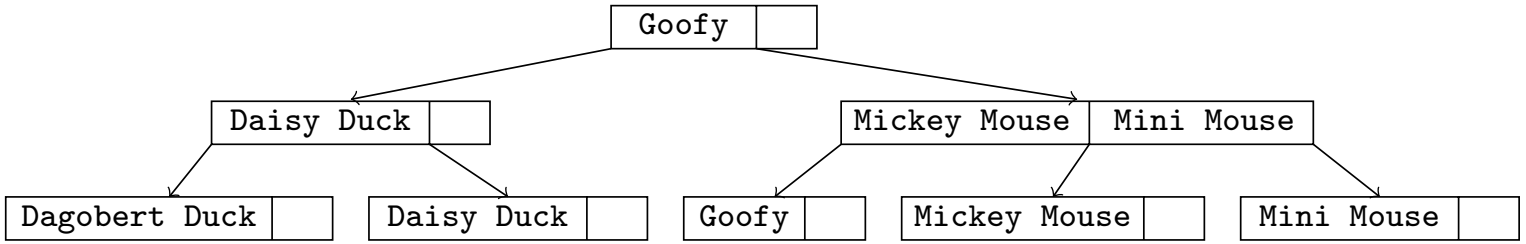

Suffix-Abschneidung: Beschränkung der Separatoren auf relevante Präfixe

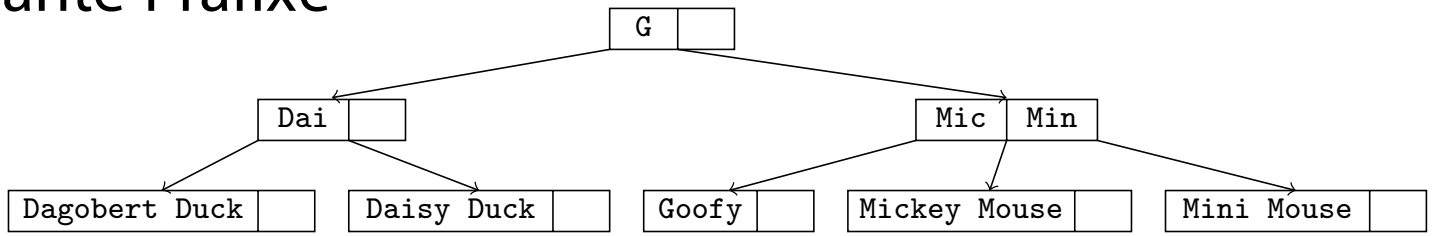

Separatoren benötigen Datenwerte nicht

Präfixabschneidung

Häufig treten Zeichenketten mit gleichem Präfix auf

- Speichere gemeinsamen Präfix nur einmal (z.B. als k_0)
- Schlüssel sind nun stark diskriminierend

Außerkraftsetzen der 50%-Füllungsregel kann Effektivität der Präfixabschneidung verbessern

Bulk-Loading von B$^+$-Bäumen

Aufbau eines B$^+$-Baums ist einfach bei sortierter Eingabe

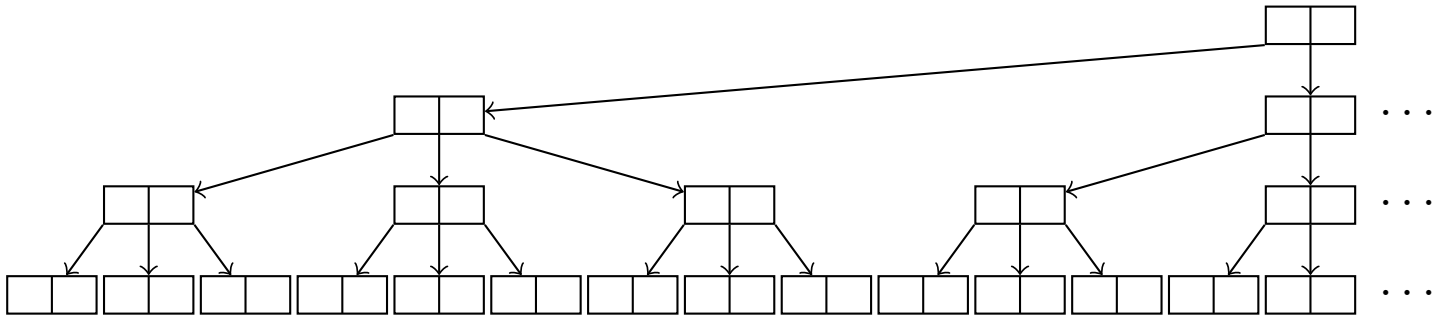

- Aufbau des B$^+$-Baumes von links nach rechts möglich
- Eventuell mit Freiraum für Updates

B, B^+, B^*, ...

Bisher B^+-Bäume diskutiert

Ursprünglicher Vorschlag von Bayer und McCreight enthielt sog. B-Bäume

- Innere Knoten enthalten auch Datensätze

Es gibt auch B*-Bäume

- Fülle innere Knoten zu 2/3 statt nur zur 1/2
- Umverteilung beim Einfügen
  (bei zwei vollen Knoten auf drei Knoten umverteilen)

B-Baum meint irgendeine dieser Formen, meist werden in realen DBs die B^+-Bäume implementiert

B^+-Bäume auch außerhalb von DBs verwendet

Indexe: Zusammenfassung

- Zugriff auf Daten von O(n) ungefähr auf O(log n)
- Kosten der Indexierung aber nicht zu vernachlässigen
  - Nicht bei „kleinen“ Tabellen
  - Nicht bei häufigen Update- oder Insert-Anweisungen
  - Nicht bei Spalten mit vielen Null-Werten
- Standardisierung nicht gegeben
- MYSQL oder PostgreSQL (Ausschnitt):

```
CREATE [UNIQUE|FULLTEXT|SPATIAL] INDEX index_name [index_type]
    ON tbl_name (index_col_name,...) [index_type]

index_col_name:
    col_name [(length)] [ASC | DESC]

index_type:
    USING {BTREE | HASH}
```

Hash-basierte Indexierung

B$^+$-Bäume dominieren in Datenbanken

Eine Alternative ist die hash-basierte Indexierung

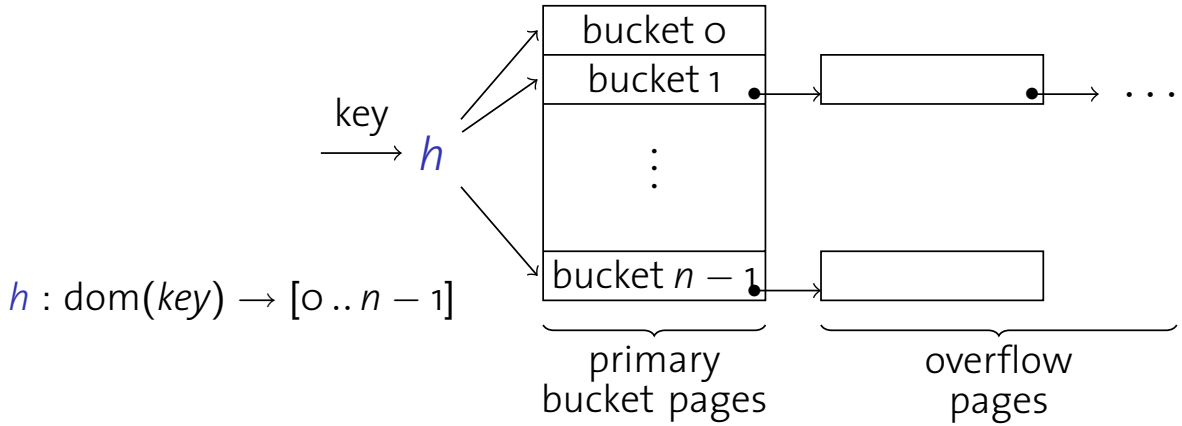

- Hash-Indexe eignen sich nur für Gleichheitsprädikate
- Insbesondere für (lange) Zeichenketten und Verbundindexe
- Statt Kollisionslisten: **Lineares** Sondieren, o.a. Techniken

Dynamisches Hashen

Problem: Wie groß soll die Anzahl n der Hash-Felder sein?

- n zu groß → schlechte Platznutzung und –Lokalität
- n zu klein → Viele Überlaufseiten, lange Listen

Datenbanken verwenden daher **dynamisches Hashen** (dynamisch wachsende und schrumpfende Bildbereiche)

- **Erweiterbares** Hashen
  (Vermeidung des Umkopierens)

Fagin, R.; Nievergelt, J.; Pippenger, N.; Strong, H. R.,
Extendible Hashing - A Fast Access Method for Dynamic Files,
ACM Transactions on Database Systems **4** (3): 315–344, **1979**

Erweiterbares Hashing (Idee am Beispiel)

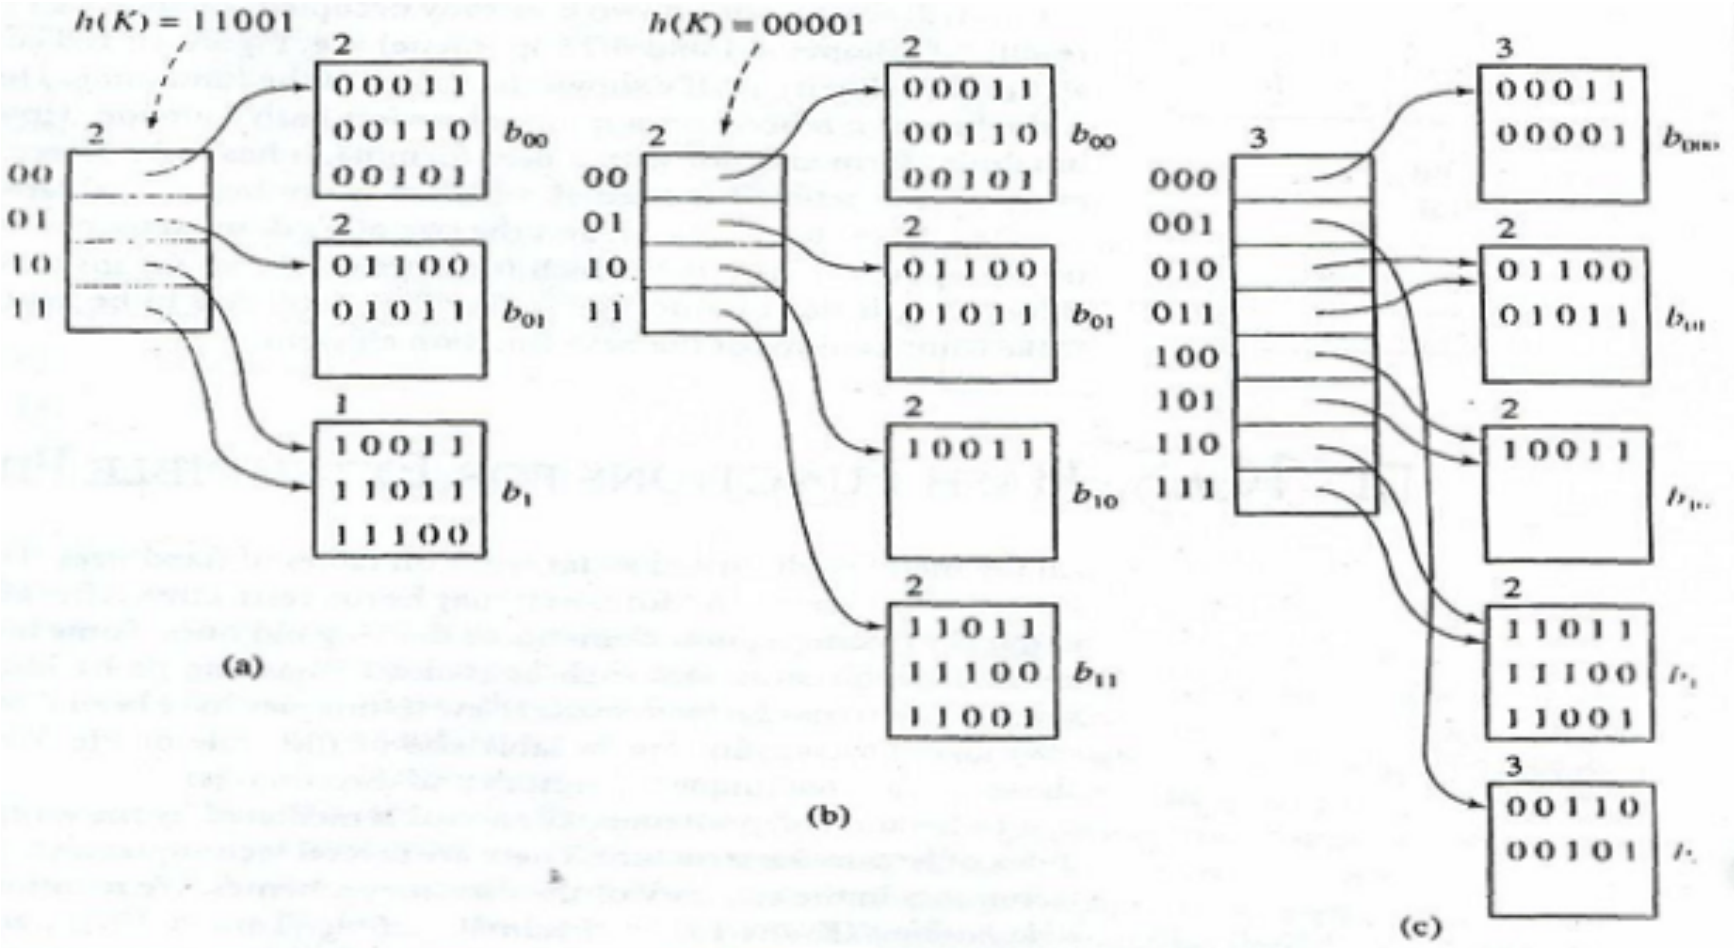

Zusammenfassung

- Index-Sequentielle Zugriffsmethode (ISAM-Index)
  - Statisch, baum-basierte Indexstruktur
- B^+-Bäume
  - Die Datenbank-Indexstruktur, auf linearer Ordnung basierend, dynamisch, kleine Baumhöhe für fokussierten Zugriff auf Bereiche
- Geclusterte vs. ungeclusterte Indexe
  - Sequentieller Zugriff vs. Verwaltungsaufwand
- Hash-basierte Indexe
  - Dynamische Anpassung des Index auf die Daten