Ludwig Maximilians Universität München
Institut für Informatik
Lehr- und Forschungseinheit für Datenbanksysteme

Skript zur Vorlesung

Datenbanksysteme I

Wintersemester 2008/2009

Kapitel 9: Physische Datenorganisation

Vorlesung: Prof. Dr. Christian Böhm
Übungen: Annahita Oswald, Bianca Wackersreuther

http://www.dbs.informatik.uni-muenchen.de/Lehre/DBS

Wiederholung (1)

Permanente Datenspeicherung: Daten können auf dem sog. Externspeicher (auch Festplatte genannt) permanent gespeichert werden

- Arbeitsspeicher:
  - rein elektronisch (Transistoren und Kondensatoren)
  - flüchtig
  - schnell: 10 ns/Zugriff *
  - wahlfreier Zugriff
  - teuer: 300-400 € für 1 GByte*

Externspeicher:

- Speicherung auf magnetisierbaren Platten (rotierend)
- nicht flüchtig
- langsam: 5 ms/Zugriff *
- blockweiser Zugriff
- wesentlich billiger: 200-400 € für 100 GByte*

*April 2002

Wiederholung (2)

Aufbau einer Festplatte

- Mehrere magnetisierbare Platten rotieren um eine gemeinsame Achse
- Ein Kamm mit je zwei Schreib-/Leseköpfen pro Platte (unten/oben) bewegt sich in radialer Richtung.

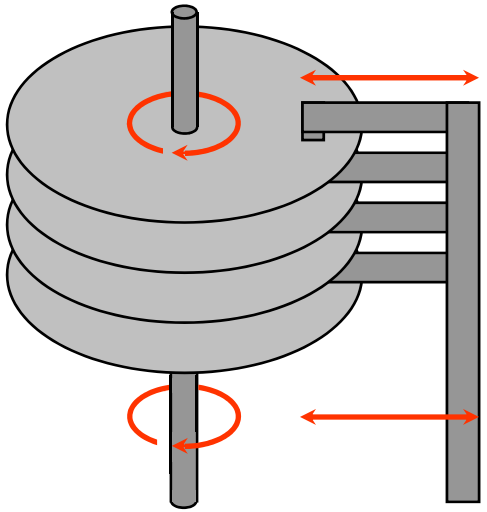

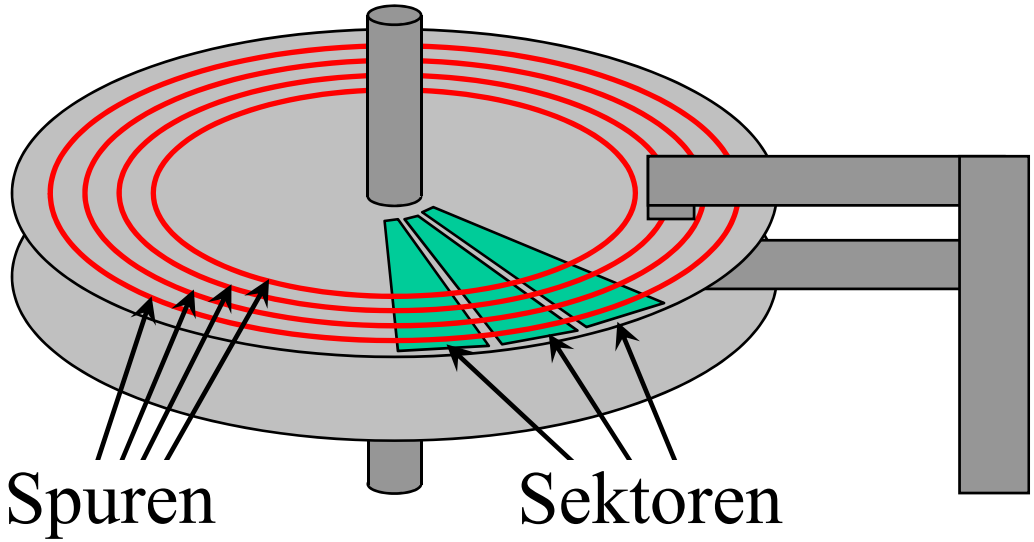

Wiederholung (3)

Intensionale Ebene vs. Extensionale Ebene

- Datenbankschema:

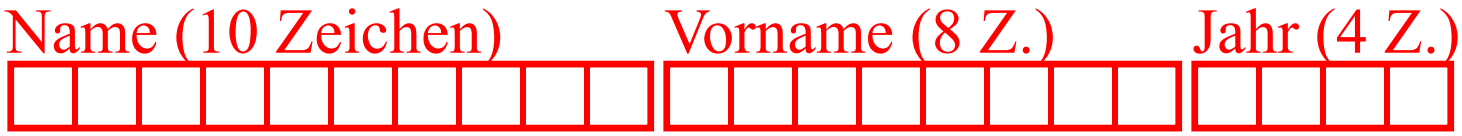

- Ausprägung der Datenbank:

Franklin	Aretha	1942
Ritchie	Lionel	1949

- Nicht nur DB-Zustand, sondern auch DB-Schema wird in DB gespeichert.
- Vorteil: Sicherstellung der Korrektheit der DB

Wiederholung (4)

Drei-Ebenen-Architektur zur Realisierung von

- **physischer**
- **und logischer**

Datenunabhängigkeit (nach ANSI/SPARC)

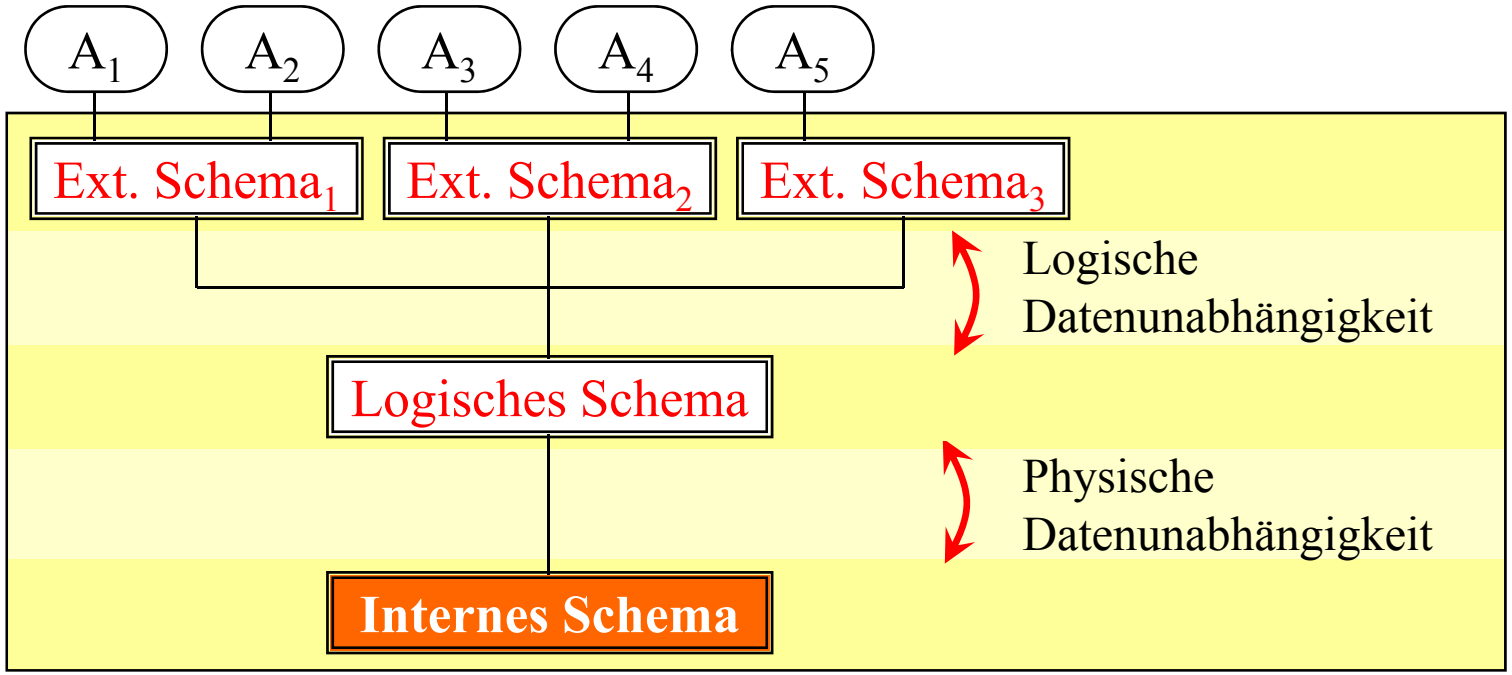

Wiederholung (5)

- Das interne Schema beschreibt die systemspezifische Realisierung der DB-Objekte (physische Speicherung), z.B.
  - Aufbau der gespeicherten Datensätze
  - Indexstrukturen wie z.B. Suchbäume
- Das interne Schema bestimmt maßgeblich das Leistungsverhalten des gesamten DBS
- Die Anwendungen sind von Änderungen des internen Schemas nicht betroffen (physische Datenunabhängigkeit)

Indexstrukturen (1)

- Um Anfragen und Operationen effizient durchführen zu können, setzt die interne Ebene des Datenbanksystems geeignete Datenstrukturen und Speicherungsverfahren (**Indexstrukturen**) ein.

- **Aufgaben**
  - **Zuordnung eines Suchschlüssels** zu denjenigen physischen Datensätzen, die diese Wertekombination besitzen,

    d.h. Zuordnung zu der oder den Seiten der Datei, in denen diese Datensätze gespeichert sind.

    (VW, Golf, schwarz, M-ÜN 40) → (logische) Seite 37
  - **Organisation der Seiten** unter dynamischen Bedingungen.

    Überlauf einer Seite → Aufteilen der Seite auf zwei Seiten

Indexstrukturen (2)

- **Aufbau**
  Strukturinformation zur Zuordnung von Suchschlüsseln und zur Organisation der Datei.
  - **Directoryseiten:**
    Seiten in denen das Directory gespeichert wird.
  - **Datenseiten**
    Seiten mit den eigentlichen physischen Datensätzen.

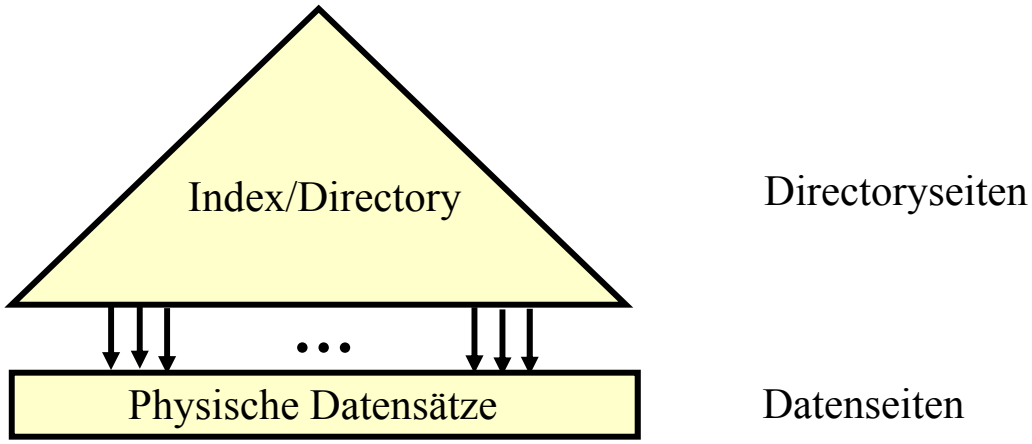

Anforderungen an Indexstrukturen (1)

- **Effizientes Suchen**
  - Häufigste Operation in einem DBS: Suchanfragen.
  - Insbesondere Suchoperationen müssen mit wenig Seitenzugriffen auskommen.

    Beispiel: unsortierte sequentielle Datei
    - Einfügen und Löschen von Datensätzen werden effizient durchgeführt.
    - Suchanfragen müssen ggf. die gesamte Datei durchsuchen.
  - Eine Anfrage sollte daher mit Hilfe der Indexstruktur möglichst schnell zu der Seite oder den Seiten geführt werden, auf denen sich die gesuchten Datensätze befinden.

Anforderungen an Indexstrukturen (2)

- **Dynamisches Einfügen, Löschen und Verändern von Datensätzen**
  - Der Datenbestand einer Datenbank verändert sich im Laufe der Zeit.
  - Verfahren, die zum Einfügen oder Löschen von Datensätzen eine Reorganisation der gesamten Datei erfordern, sind nicht akzeptabel.

    Beispiel: sortierte sequentielle Datei
    - Das Einfügen eines Datensatzes erfordert im schlechtesten Fall, dass alle Datensätze um eine Position verschoben werden müssen.
    - Folge: auf alle Seiten der Datei muss zugegriffen werden.
  - Das Einfügen, Löschen und Verändern von Datensätzen darf daher nur *lokale Änderungen* bewirken.

Anforderungen an Indexstrukturen (3)

- **Ordnungserhaltung**
  - Datensätze, die in ihrer Sortierordnung direkt aufeinander folgen, werden oft gemeinsam angefragt.
  - In der Ordnung aufeinander folgende Datensätze sollten in der gleichen Seite oder in benachbarten Seiten gespeichert werden.
- **Hohe Speicherplatzausnutzung**
  - Dateien können sehr groß werden.
  - Eine möglichst hohe Speicherplatzausnutzung ist wichtig:
    - Möglichst geringer Speicherplatzverbrauch.
    - Im Durchschnitt befinden sich mehr Datensätze in einer Seite, wodurch auch die Effizienz des Suchens steigt und die Ordnungserhaltung an Bedeutung gewinnt.

Klassen von Indexstrukturen

- **Datenorganisierende Strukturen**
  Organisiere die Menge der tatsächlich auftretenden Daten (Suchbaumverfahren)
- **Raumorganisierende Strukturen**
  Organisiere den Raum, in den die Daten eingebettet sind (dynamische Hash-Verfahren)

Anwendungsgebiete:

- **Primärschlüsselsuche** (B-Baum und lineares Hashing)
- **Sekundärschlüsselsuche** (invertierte Listen)

B-Baum (1)

Idee:

- Daten auf der Festplatte sind in Blöcken organisiert (z.B. 4 Kb Blöcke)
- Bei Organisation der Schlüssel mit einem binärem Suchbaum entsteht pro Knoten, der erreicht wird, ein Seitenzugriff auf der Platte.
  => sehr teuer

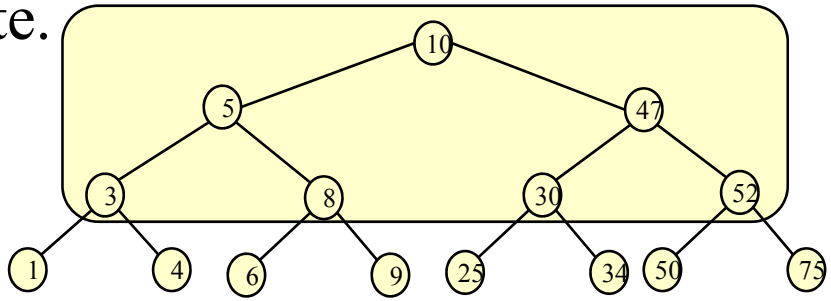

- Fasse mehrere Knoten zu einem zusammen, so dass ein Knoten im Baum einer Seite auf der Platte entspricht.

B-Baum (2)

Definition: B-Baum der Ordnung *m*
(Bayer und McCreight (1972))

(1) Jeder Knoten enthält höchstens $2m$ Schlüssel.

(2) Jeder Knoten außer der Wurzel enthält mindestens m Schlüssel.

(3) Die Wurzel enthält mindestens einen Schlüssel.

(4) Ein Knoten mit k Schlüsseln hat genau $k+1$ Söhne.

(5) Alle Blätter befinden sich auf demselben Level.

B-Baum (3)

Beispiel: B-Baum der Ordnung 2

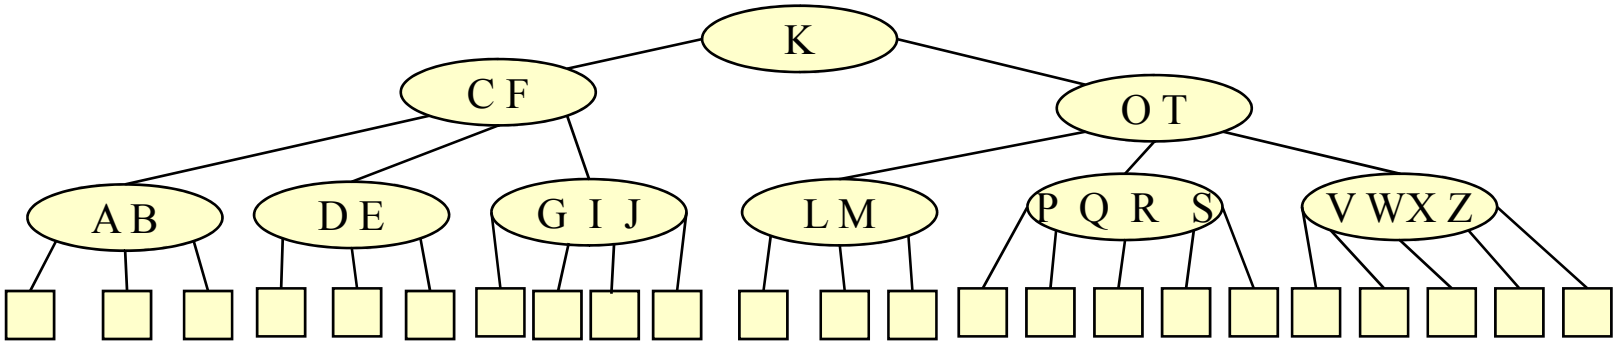

- max Höhe: $h \leq \left\lfloor \log_{m+1}\left(\frac{n+1}{2}\right)\right\rfloor + 1$

- Ordnung in realen B-Bämen: 600-900 Schlüssel pro Seite
- Effiziente Suche in den Knoten ? => binäre Suche

Einfügen in B-Baum

Einfügen eines Schlüssels ***k***:

- Suche Knoten ***B*** in den ***k*** eingeordnet werden würde. (Blattknoten bei erfolgloser Suche)
- 1. Fall: ***B*** enthält ≤ 2***m*** Schlüssel
  => füge ***k*** in ***B*** ein
- 2. Fall: ***B*** enthält 2***m*** Schlüssel
  => Overflow Behandlung
  - Split des Blattknotens

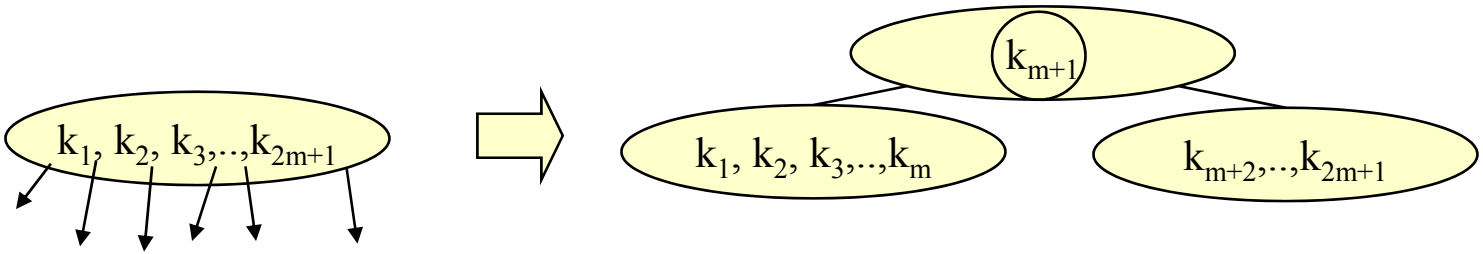

- Split kann sich über mehrere Ebene fortsetzen bis zur Wurzel

Entfernen aus B-Baum

Lösche Schlüssel ***k*** aus Baum:

- Suche Schlüssel
- Falls Schlüssel in inneren Knoten, vertausche Schlüssel mit dem größten Schlüssel im linkem Teilbaum (=> Rückführung auf Fall mit Schlüssel in Blattknoten)
- Falls Schlüssel im Blattknoten ***B***:
  - 1. Fall: ***B*** hat noch mehr als ***m*** Schlüssel, => lösche Schlüssel
  - 2. Fall: ***B*** hat genau ***m*** Schlüssel

    => Underflow

Underflow-Behandlung im B-Baum

- Betrachte Bruderknoten (immer den rechten falls vorhanden)
- 1.Fall: Bruder hat mehr als m Knoten => ausgleichen mit Bruder

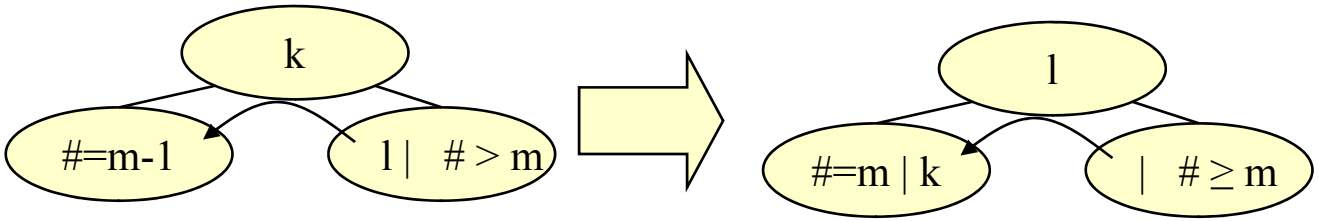

- 2. Fall: Bruder hat genau m Knoten => Verschmelzen der Brüder

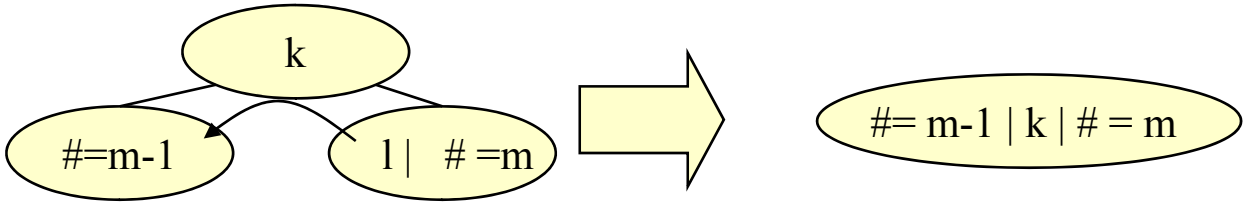

- Verschmelzen kann sich bis zur Wurzel hin fortsetzen.

B+-Baum (1)

- Häufig tritt in Datenbankanwendungen neben der Primärschlüsselsuche auch sequentielle Verarbeitung auf.
- **Beispiele für sequentielle Verarbeitung:**
  - *Sortiertes Auslesen aller Datensätze*, die von einer Indexstruktur organisiert werden.
  - *Unterstützung von Bereichsanfragen* der Form:
  - "Nenne mir alle Studenten, deren Nachname im Bereich [Be ... Brz] liegt."
- →Die Indexstruktur sollte die *sequentielle Verarbeitung* unterstützen, d.h. die Verarbeitung der Datensätze in aufsteigender Reihenfolge ihrer Primärschlüssel.

B+-Baum (2)

Grundidee:

- Trennung der Indexstruktur in *Directory* und *Datei*.
- *Sequentielle Verkettung* der Daten in der Datei.

B+-Datei:

- Die Blätter des B+-Baumes heißen ***Datenknoten*** oder ***Datenseiten***.
- Die Datenknoten enthalten alle Datensätze.
- Alle Datenknoten sind entsprechend der Ordnung auf den Primärschlüsseln *verkettet*.

B+-Directory:

- Die inneren Knoten des B+-Baumes heißen ***Directoryknoten*** oder ***Directoryseiten***.
- Directoryknoten enthalten nur noch ***Separatoren*** s.
- Für jeden Separator s(u) eines Knotens u gelten folgende ***Separatoreneigenschaften***:
  - $s(u) > s(v)$ für alle Directoryknoten v im linken Teilbaum von s(u).
  - $s(u) < s(w)$ für alle Directoryknoten w im rechtenTeilbaum von s(u).
  - $s(u) > k(v')$ für alle Primärschlüssel k(v') und alle Datenknoten v' im linken Teilbaum von s(u).
  - $s(u) \leq k(w')$ für alle Primärschlüssel k(w') und alle Datenknoten w' im rechten Teilbaum von s(u).

B+-Baum (3)

Beispiel:

B+-Baum für die Zeichenketten:

An, And, Certain, For, From, Which, With

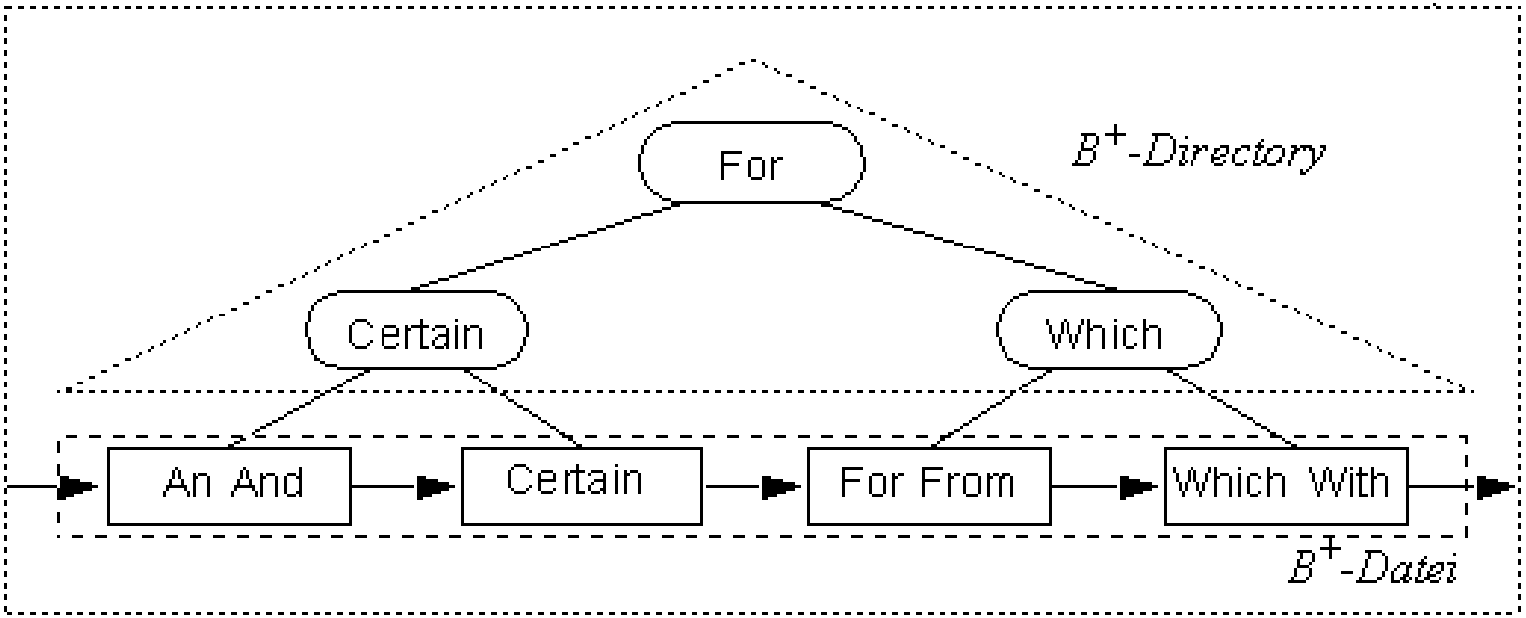

Hash-Verfahren

- Raumorganisierendes Verfahren
- **Idee**: Verwende Funktion, die aus den Schlüsseln ***K*** die Seitenadresse ***A*** berechnet. (Hashfunktion)
- **Vorteil**: Im besten Fall konstante Zugriffszeit auf Daten.
- **Probleme:**
  - Gleichmäßige Verteilung der Schlüssel über A
  - |Domain(K)|>>|A| => Kollision

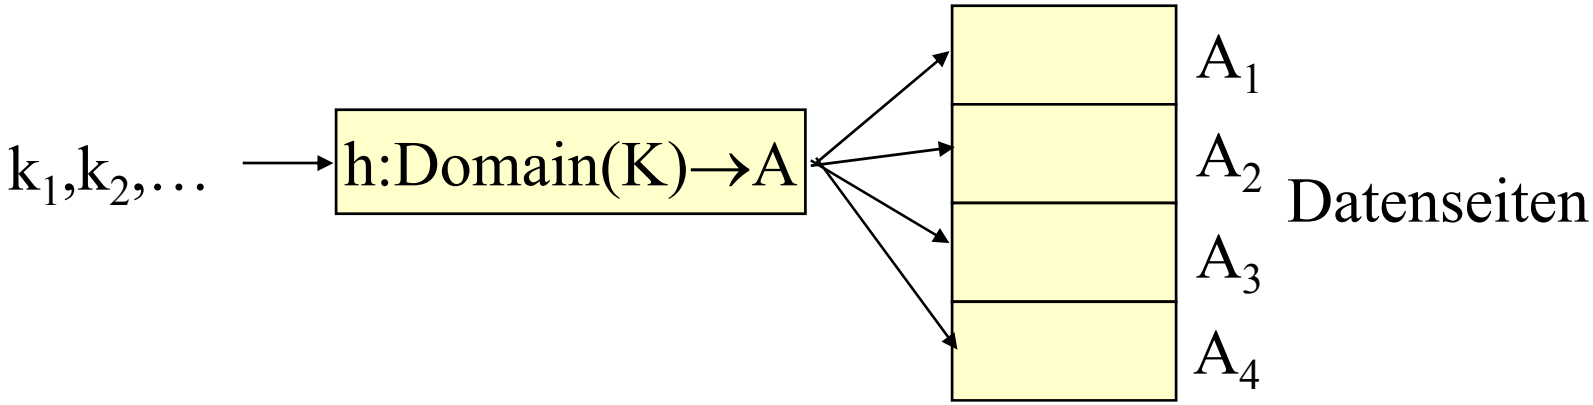

Hash-Verfahren für Sekundärspeicher

Für Sekundärspeicher sind weitere Anforderungen von Bedeutung:

- hohe Speicherplatzausnutzung
  (Datenseiten sollten über 50 % gefüllt sein)
- Gutes dynamisches Verhalten:
  schnelles Einfügen, Löschen von Schlüsseln und Datenseiten
- Gleichbleibend effiziente Suche

Klassifizierung von Hash-Verfahren

- **Ohne Directory**

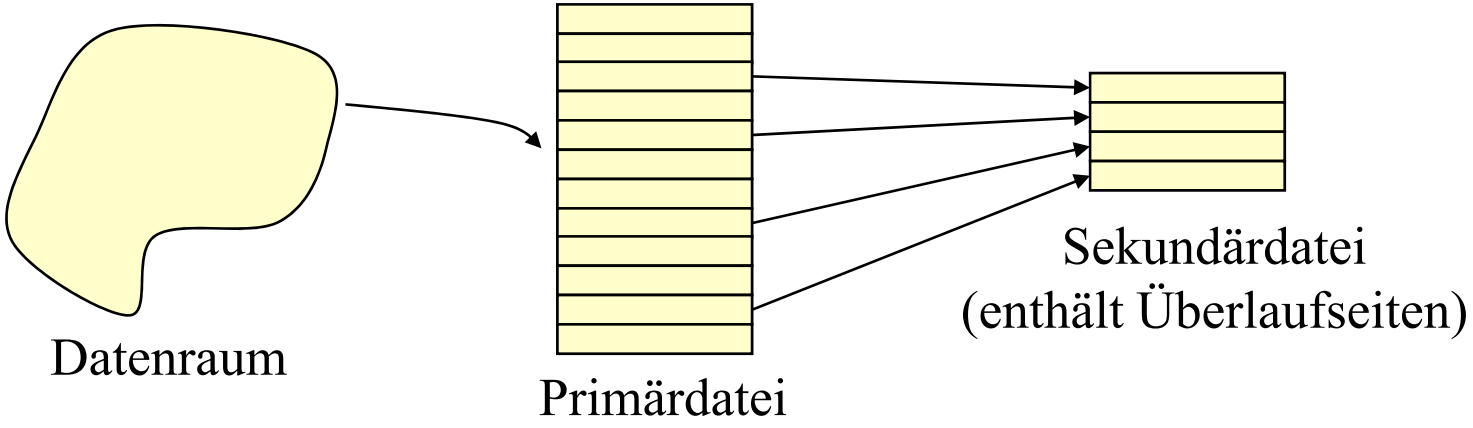

- **Mit Directory**

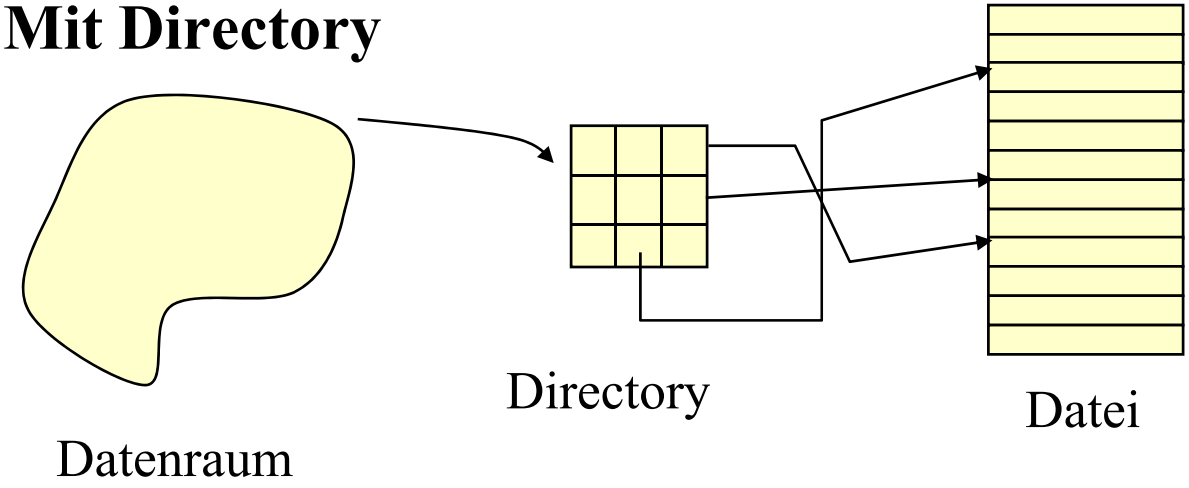

Hash-Verfahren mit Directory

Erweiterbares Hashing

- Hashfunktion: h(k) liefert Bitfolge $(b_1,b_2,\ldots,b_d,\ldots)$
- Directory besteht aus eindimensionalen Array D $[0..2^d-1]$ aus Seitenadressen. d heißt Tiefe des Directory.
- Verschiedene Einträge können auf die gleiche Seite zeigen

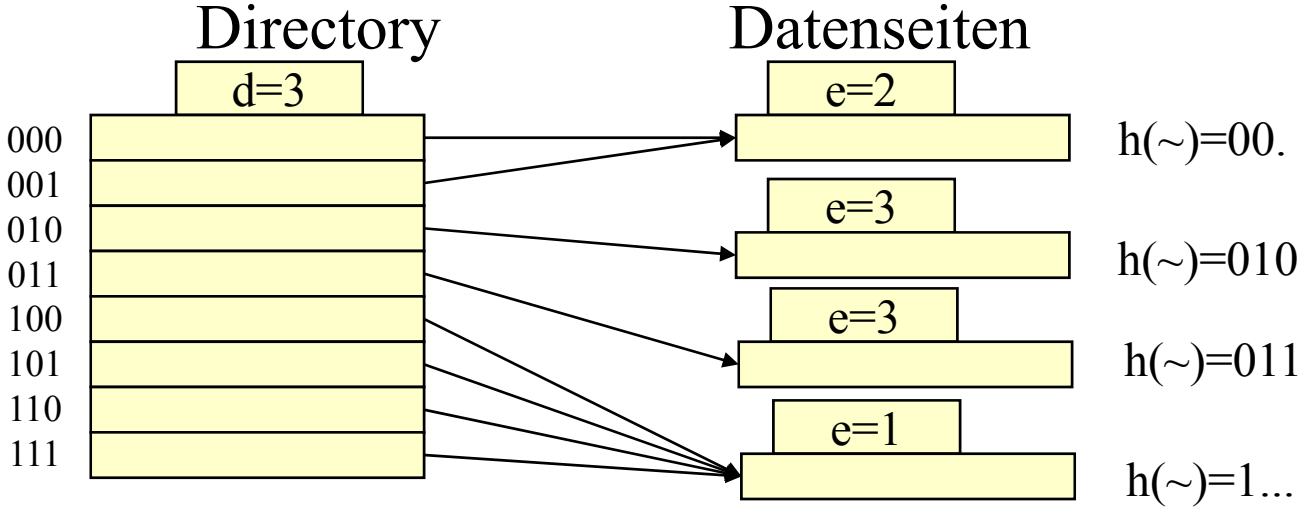

Einfügen Erweiterbares Hashing (1)

Gegeben: Datensatz mit Schlüssel k

1. Schritt: Bestimme die ersten Bits des Pseudoschlüssels $h(k) = (b_1,b_2,..,b_d,..)$
2. Schritt:
   Der Directoryeintrag $D[b_1,b_2,..,b_d]$ liefert Seitennummer.
   Datensatz wird in berechnete Seite eingefügt.

Falls Seite danach max. gefüllt:

1. Aufspalten der Datenseite.
2. Verdoppeln des Directory.

Einfügen Erweiterbares Hashing (2)

Aufspalten einer Datenseite

Aufspalten wenn Füllungsgrad einer Seite zu hoch(>90%).

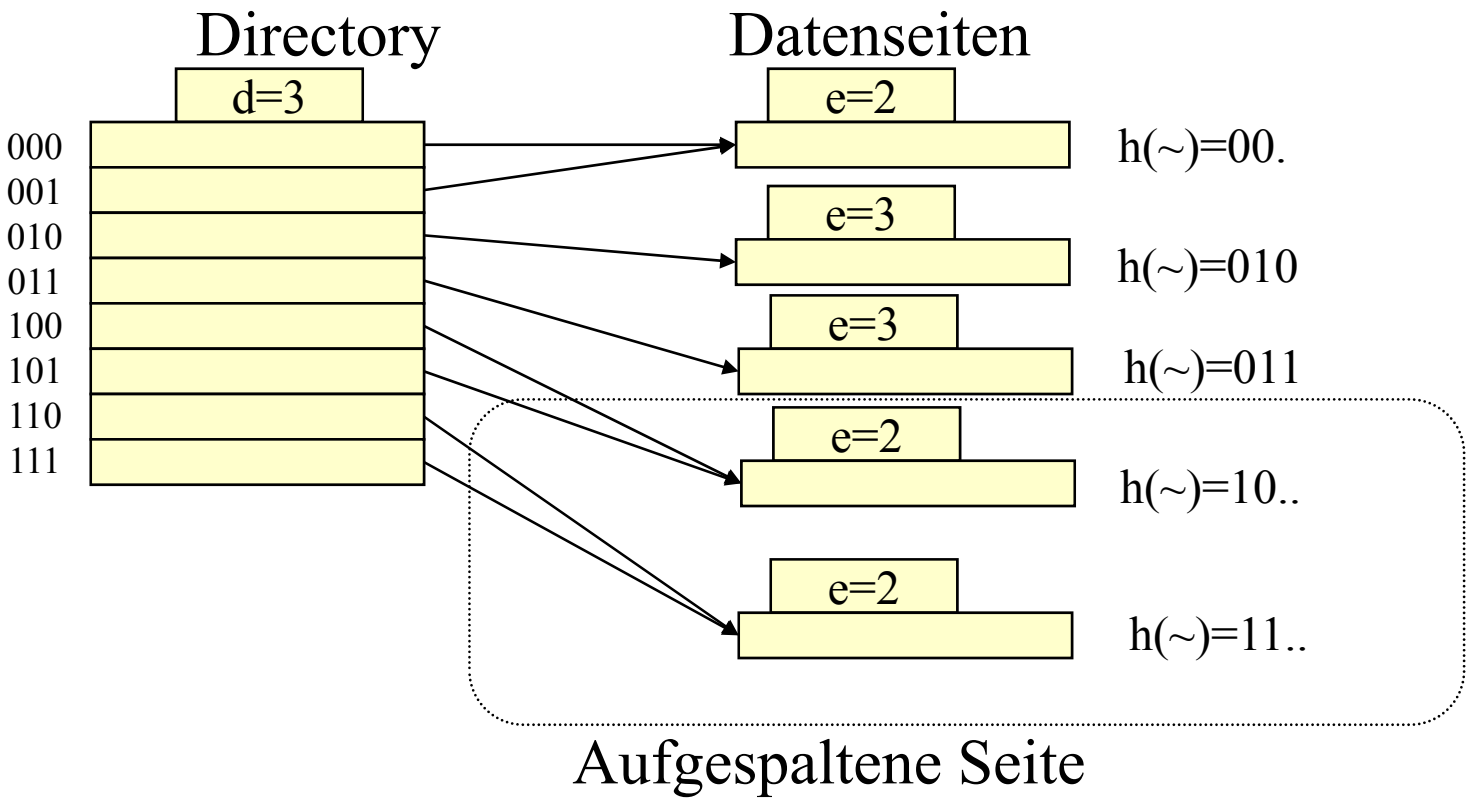

Einfügen Erweiterbares Hashing (3)

Verdopplung des Directory

Datenseite läuft über und d = e.

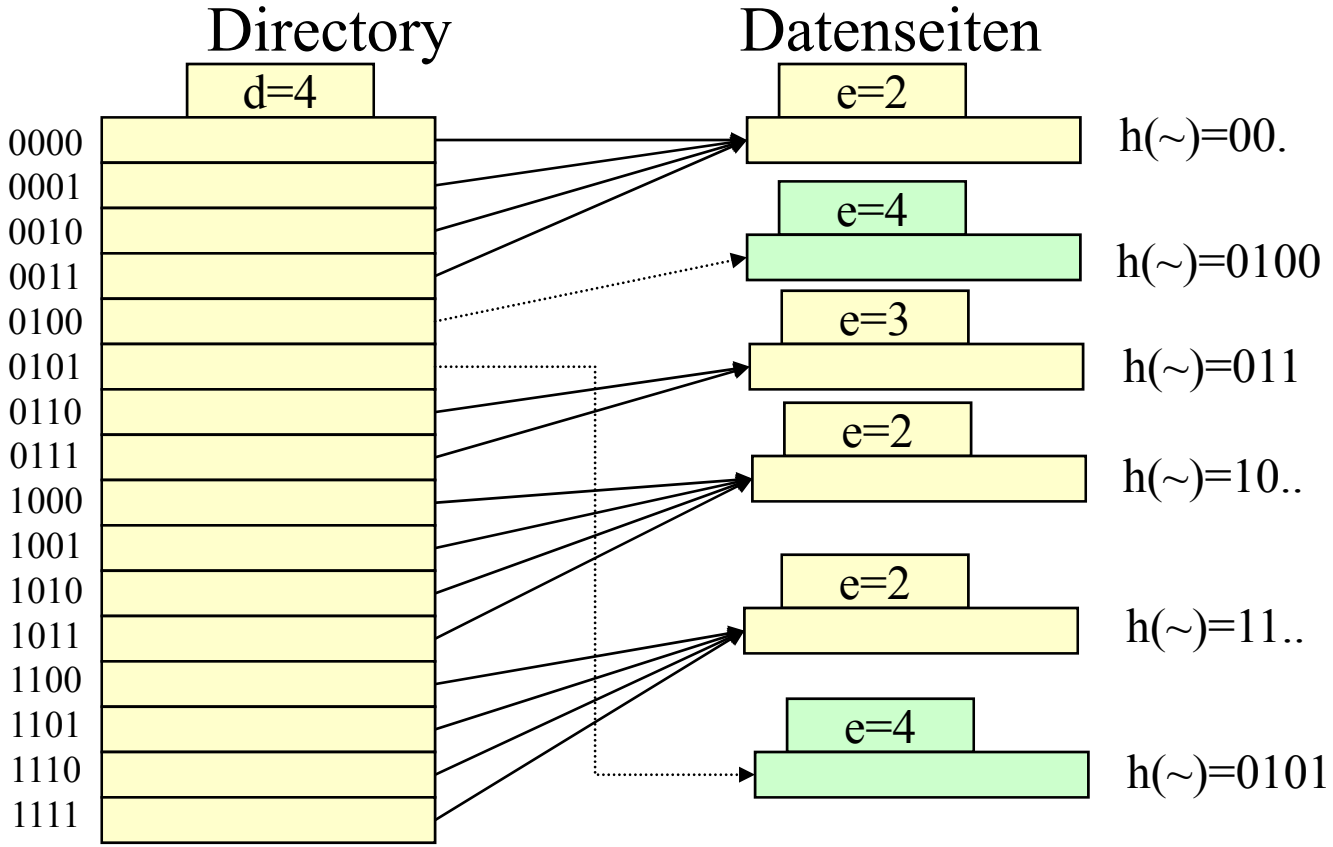

Hashing ohne Directory

Lineares Hashing

- Hash-Funktion h:K→A liefert direkt eine Seitenadresse
- Problem: Was ist wenn Datenseite voll ist ?
- Lösung: Überlaufseiten werden angehängt. Aber bei zu vielen Überlaufseiten degeneriert Suchzeit.

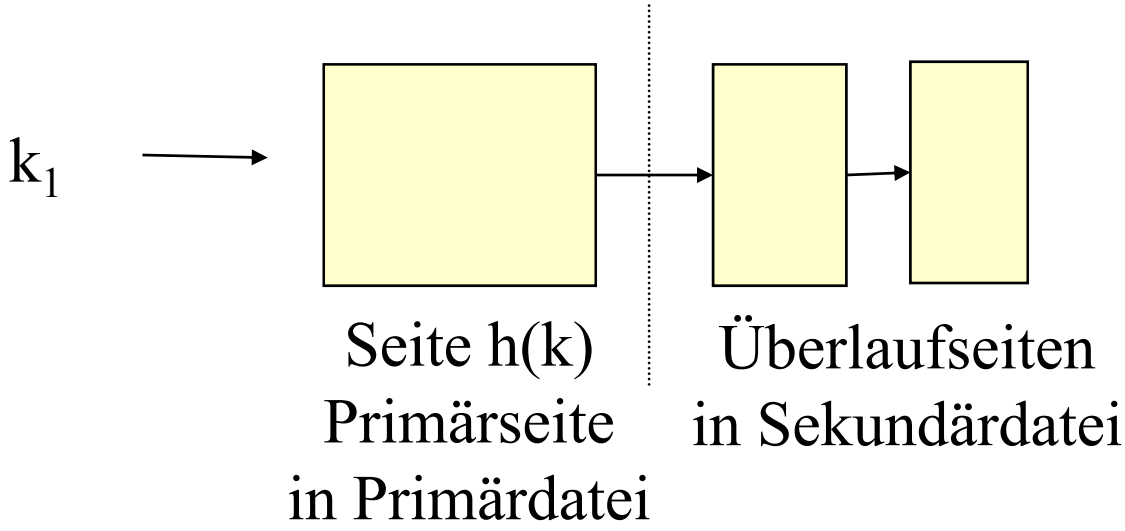

Lineares Hashing (1)

- dynamisches Wachstum der Primärdatei
- Folge von Hash-Funktionen: h_0, h_1, h_2, …
- Erweitern der Primärdatei um jeweils eine Seite
- feste Splitreihenfolge
- Expansionzeiger zeigt an welche Seite gesplittet wird
- Kontrollfunktion: Wann wird gesplittet ?
  Belegungsfaktor übersteigt Schwellwert:
  z.B.

$$80\% < \frac{\#\,abgespeicherte\;\;Datensätze}{\#\,mögl.\;\;Datensätze\;\;in\;\;Primärdatei}$$

Lineares Hashing (2)

- Hashfunktionen: $h_0(k)=k \; mod(5)$, $h_1(k)=k \; mod(10)$, …

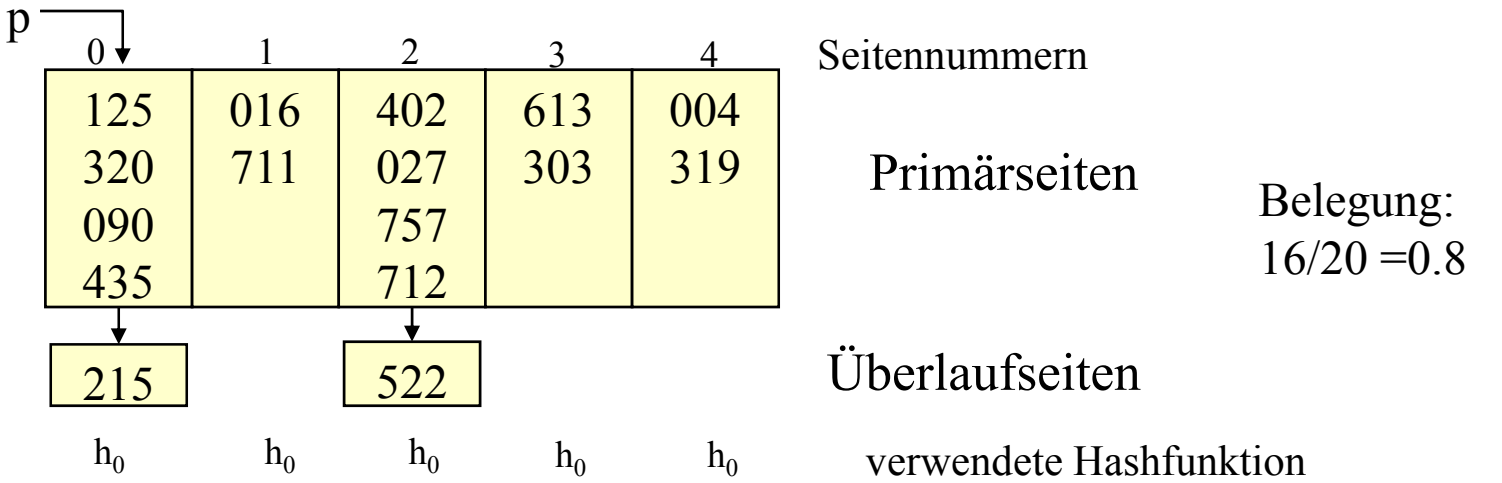

Einfügen von Schlüssel 438:

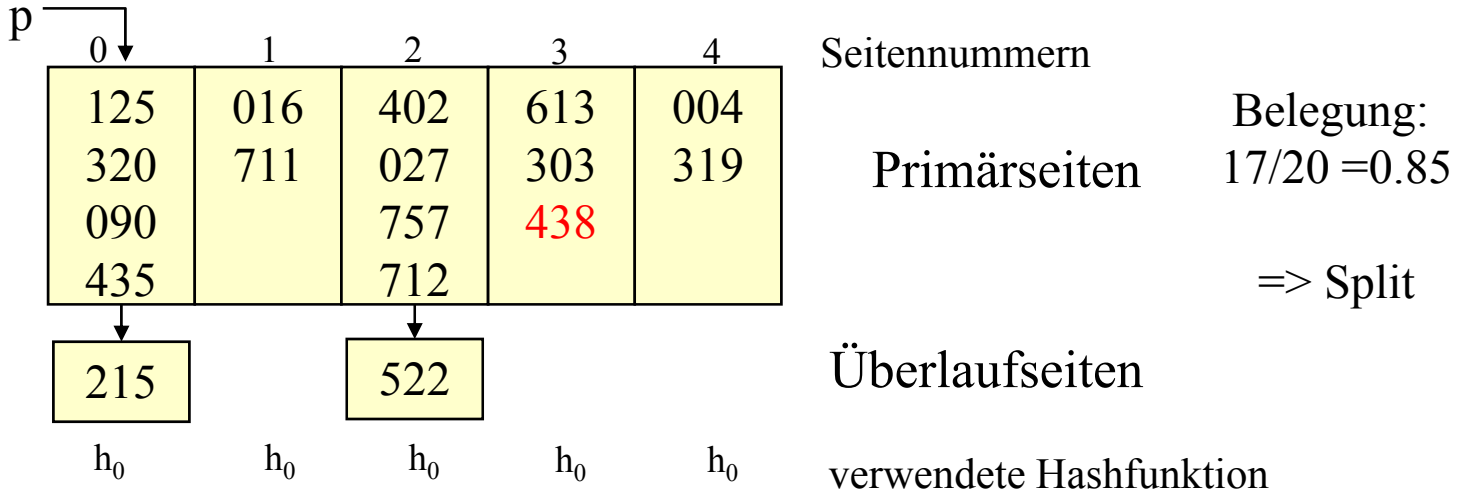

Lineares Hashing (3)

Expansion der Seite 0 auf die Seiten 0 und 5:

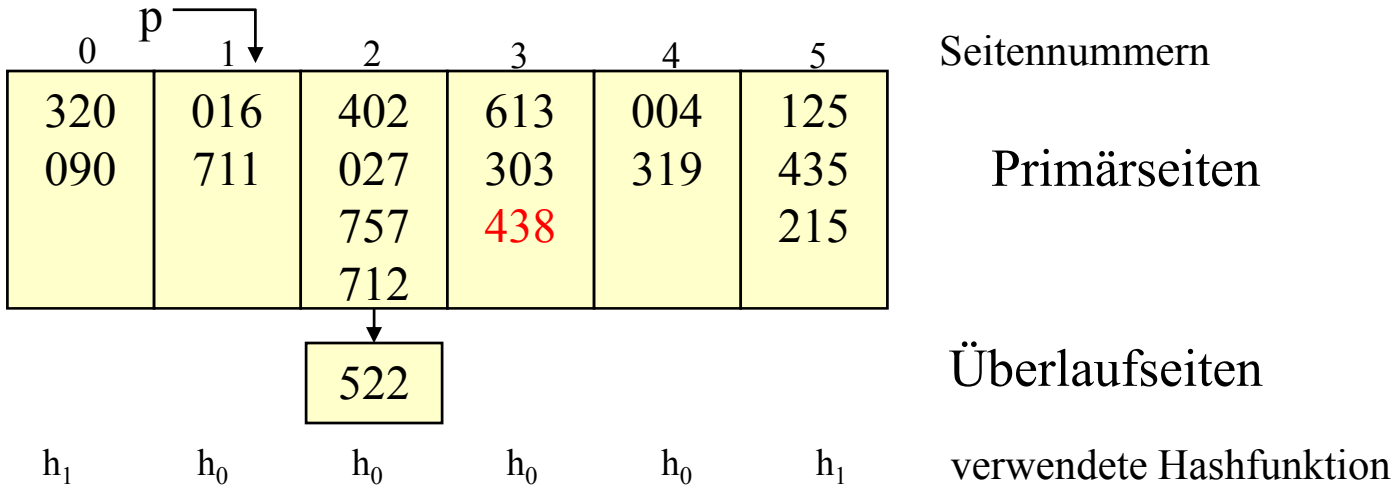

- Umspeichern aller Datensätze mit $h_1(k) = 5$ in neue Seite
- Datensätze mit $h_1(k) = 0$ bleiben

Lineares Hashing (4)

Prinzip der Expansion:

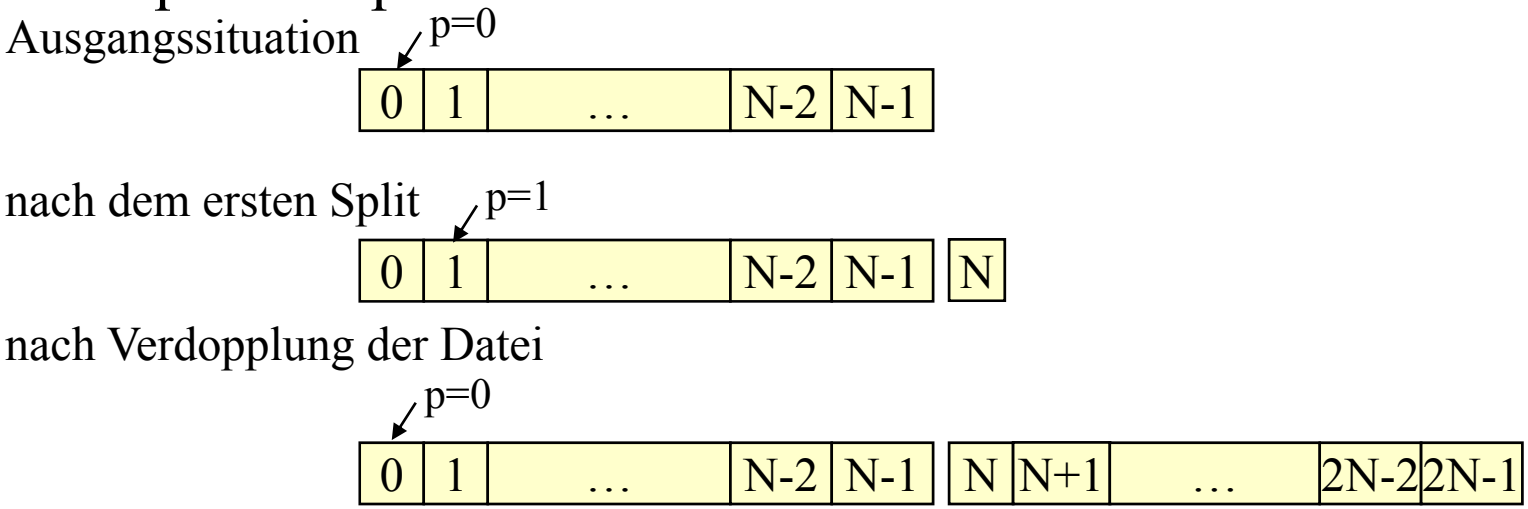

- Split in fester Ordnung (nicht: Split der vollen Seiten)
- trotzdem wenig Überlaufseiten
- gute Leistung für gleich verteilte Daten
- Adreßraum wächst linear

Lineares Hashing (5)

Anforderungen an die Hashfunktionen $\{h_i\}$, $i>0$:

1.) Bereichsbedingung:

$h_{L:}\ \text{domain}(k) \rightarrow \{0,1,\ldots,(2^L * N)-1\},\ L \geq 0$

2.) Splitbedingung:

$h_{L+1}(k)=h_L(k)$ oder

$h_{L+1}(k)=h_L(k) + 2^L * N,\ L \geq 0$

L gibt an wie oft sich Datei schon vollständig verdoppelt hat.

Beispiel:

$h(k)= k \bmod (2^L * N)$

Anfragen auf mehreren Attributen (1)

Invertierte Listen (häufigste Lösung)

- jedes relevante Attribute wird mit eindimensionalem Index verwaltet.
- Suche nach mehreren Attributen $a_1,a_2,..,a_d$
- Erstellen von Ergebnislisten mit Datensätzen d bei denen $d.a_1$ der Anfragebedingung genügt.

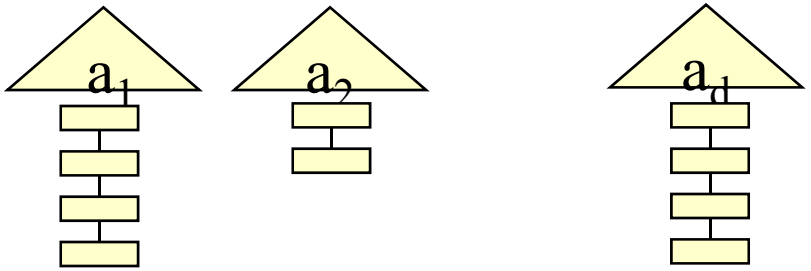

- Bestimmen des Ergebnis über mengentheoretischen Verknüpfung (z.B. Schnitt) der einzelnen Ergebnislisten.

Anfragen auf mehreren Attributen (2)

Eigenschaften Invertierter Listen:

- Die Antwortzeit ist nicht proportional zur Anzahl der Antworten.
- Suchzeit wächst mit Anzahl der Attribute
- genügend Effizienz bei kleinen Listen
- Sekundärindizes für nicht Primärschlüssel beeinflussen die physikalische Speicherung nicht.
- zusätzliche Sekundärindizes können das Leistungsverhalten bei DB-Updates stark negativ beeinflussen.

Index-Generierung in SQL

- Generierung eines Index:

  CREATE INDEX *index-name* ON *table* (a_1, a_2, ..., a_n);

  Ein *Composite Index besteht aus mehr als einer Spalte. Die Tupel sind dann nach den* Attributwerten (lexikographisch) geordnet:

  Für den Vergleich der einzelnen Attribute gilt die jeweils übliche Ordnung:

  $t_1 < t_2$ *gdw.*

  $t_1.a_1 < t_2.a_1$ *oder* ($t_1.a_1 = t_2.a_1$ *und* $t_1.a_2 < t_2.a_2$) *oder* ...

  numerischer Vergleich für numerische Typen, lexikographischer Vergleich bei **CHAR,** Datums-Vergleich bei **DATE** usw**.**

- Löschen eines Index:

  DROP INDEX *index-name;*

- Verändern eines Index:

  ALTER INDEX *index-name ...;*

  (betrifft u.a. Speicherungs-Parameter und Rebuild)

Durch Index unterstützte Anfragen

- **Exact match query:**

  SELECT * FROM *t* WHERE a_1 = ... AND ... AND a_n =...

- **Partial match query:**

  SELECT * FROM *t* WHERE a_1 = ... AND ... AND a_i = ...

  für $i < n$, *d.h. wenn die exakt spezifizierten Attribute ein Präfix der indizierten Attribute sind.*

  Eine Spezifikation von a_{i+1} *kann i.a. nicht genutzt werden, wenn* a_i *nicht spezifiziert ist.*

- **Range query:**

  SELECT * FROM *t* WHERE a_1 = ... AND ... AND a_i = ... AND a_{i+1} <= ...

  auch z.B. für '**>**' **oder 'BETWEEN'**

- **Pointset query:**

  SELECT * FROM *t* WHERE a_1 = ... AND ... AND a_i = ... AND a_{i+1} IN *(7,17,77)*

  auch z.B. (***a_{i+1}*=... *OR* a_{i+1} =... *OR ...)***

Durch Index unterstützte Anfragen

- **Pattern matching query:**

  SELECT * FROM *t* WHERE a_1=... AND ... AND a_i=... AND a_{i+1} LIKE *'c_1c_2... c_k%'

  Problem: Anfragen wie ***wort*** **LIKE *'%system'*** werden nicht unterstützt.
  Man kann aber z.B. eine Relation aufbauen, in der alle Wörter revers gespeichert werden und dann effizient nach ***revers_wort*** **LIKE *'metsys%'*** suchen lassen.

Zusammenfassung

- Um Anfragen und Operationen effizient durchführen zu können, setzt die interne Ebene des Datenbanksystems geeignete Datenstrukturen und Speicherungsverfahren (**Indexstrukturen**) ein.

- Primärindizes verwalten Primärschlüssel
- Sekundärindizes unterstützen zusätzliche Suchattribute oder Kombinationen von diesen.

- Ein Beispiel für eine solche Indexstruktur sind B+-Baum und dynamische Hash-Verfahren.

- Anfragen auf mehreren Attributen werden meist mit invertierten Listen realisiert.