Datenbanksysteme I
Datenbanken und Informationssysteme

Prof. Dr. Viktor Leis

WS 2019/2020

Professur für Datenbanken und Informationssysteme

Physische Datenorganisation

Speicherhierarchie

- Verschiedene Schichten der Speicherung
- Je höher in der Hierarchie, desto schneller, teurer und kleiner
- Unterschiede sind meistens in Größenordnungen
- Am wichtigsten für DBMS: Hauptspeicher und Sekundärspeicher (Festplatten/SSDs)

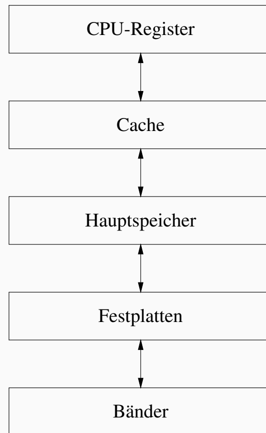

Speicherhierarchie (2)

	Bandbreite	Zugriffslatenz	Kapazität
CPU-Register (10)	10TB/s	0.25ns	10KB
L1 Cache (10)	5TB/s	1ns	500KB
L3 Cache	0.5TB/s	10ns	10MB
RAM (6)	100GB/s	100ns	100GB
Flash SSDs (4)	10GB/s	100us	5TB
Festplatten (10)	1GB/s	10ms	50TB

in Klammern: Anzahl CPU-Kerne/Einheiten

ungefähre Angaben, 2019

Aufbau einer Festplatte

- Lesen eines Blocks:
  1. Positionierung des Kopfes (Seek-Time)
  2. Rotation zum Anfang des Blocks (Latenzzeit)
  3. Lesen des Blocks (Lesezeit)

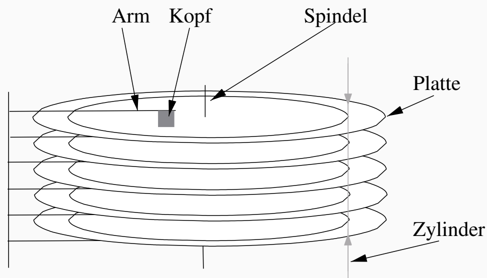

a. Seitenansicht

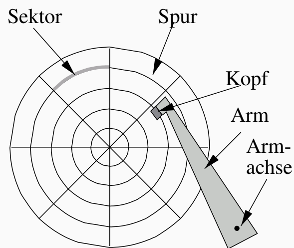

b. Aufsicht

Solid-State Drive (Flash)

- Persistente Speicherung basierend auf Halbleitern
- Keine mechanische Bewegung/Rotation
- Hoher Grad an Parallelität

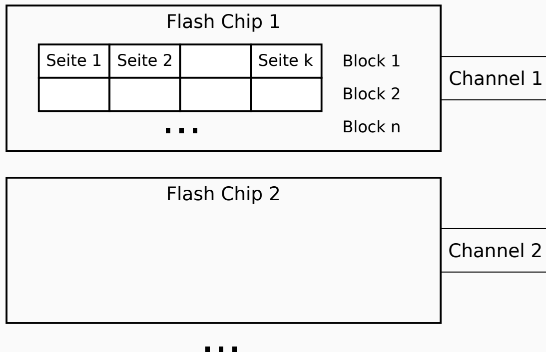

Flash Eigenschaften

- Zugriff über Seiten fester Größe (z.B. 4 KB)
- Seiten müssen explizit gelöscht werden, bevor sie überschrieben werden können
- Gelöscht werden können nur Blöcke (z.B. 2 MB) von Seiten
- Erfordert komplexe Controller-Logik
- Schreiben dauert deutlich länger als Lesen
- Anzahl Schreib-/Löschzyklen ist beschränkt (z.B. 10000)

Ausfallwahrscheinlichkeit

- Große Datenmengen passen oft nicht auf eine Festplatte, sondern man braucht mehrere
- Wenn die Ausfallwahrscheinlichkeit einer Platte in einem bestimmten Zeitraum p ist und man n Festplatten hat
  - dann ist die Wahrscheinlichkeit, dass eine ausfällt $1 - (1 - p)^n$
  - Annahme: Ausfallwahrscheinlichkeiten sind unabhängig
- Konsequenz könnte Datenverlust sein

RAID

Daten sind meistens groß und wertvoll, deshalb wird häufig RAID (redundant array of inexpensive disks) verwendet.

Wichtigste RAID-Typen:

- RAID0: Striping (kein “echtes” RAID)
- RAID1: Spiegelung
- RAID0+1: Striping und Spiegelung
- RAID3/4: Striping mit Paritätsplatte (nur historische Relevanz)
- RAID5: Striping mit verteilter Parität
- RAID6: Striping mit mehreren verteilten Paritätsplatten (kann mehrere Ausfälle überleben)

RAID 0/1/0+1

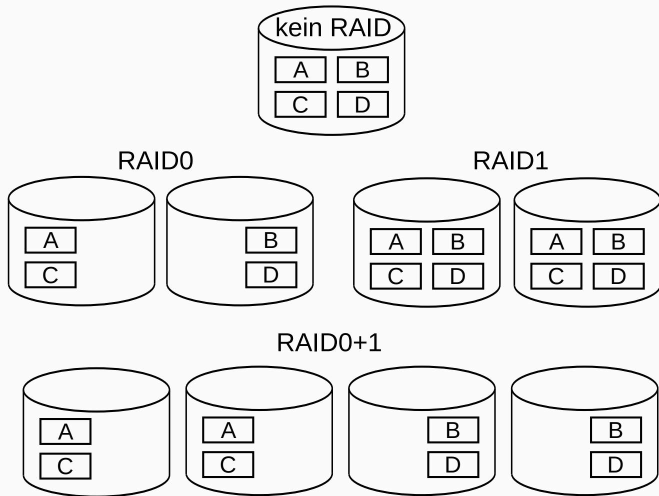

RAID 4/5

- Parität: $P_{ABC} = A \oplus B \oplus C$
- $\oplus$ ist XOR

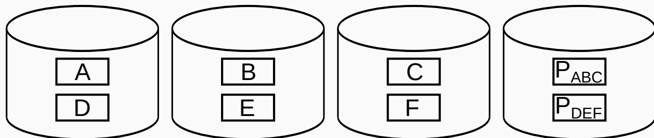

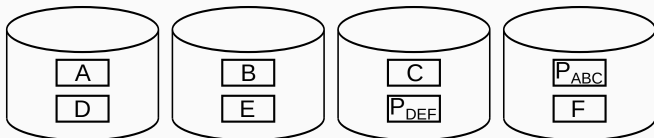

Datenbankpuffer

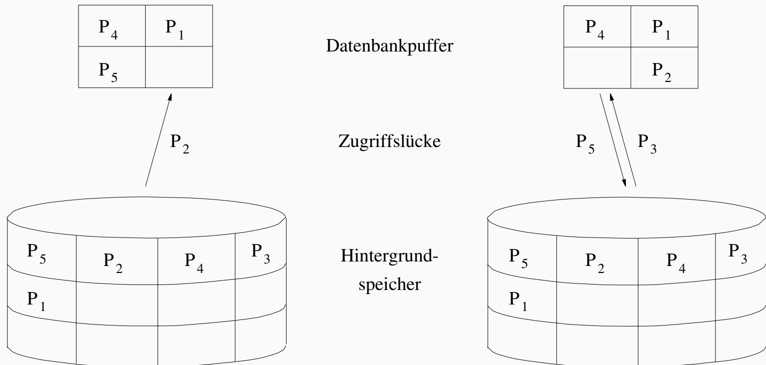

Speicherung von Relationen

- Alle Daten (Relationen, Indexe) werden auf Seiten fester Größe (z.B. 8KB) gespeichert
- Die Tupel einer Relation werden auf mehreren Seiten im Hintergrundspeicher gespeichert
- Jede Seite enthält interne Datensatztabelle mit Verweisen auf die Tupel innerhalb der Seite (slotted pages)
- Tupel werden über *Tupel-Identifikatoren* (TID) referenziert

Das TID-Konzept

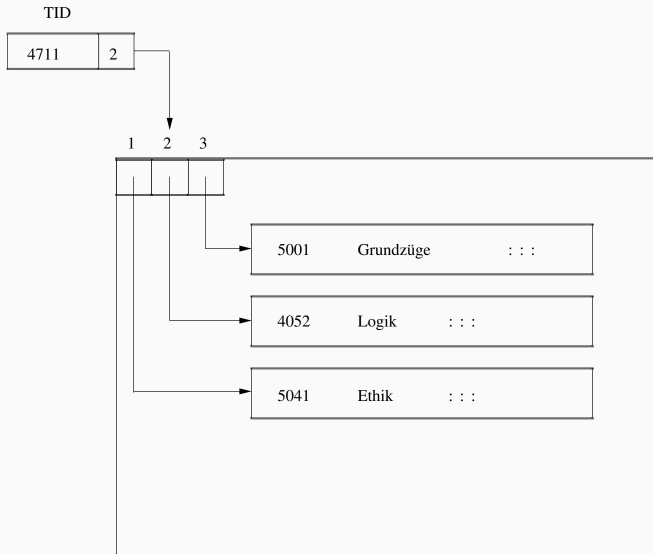

Datentransfer

- Die Tupel aller Relationen nacheinander in den Hauptspeicher zu holen, ist einfachste Art Anfragen zu bearbeiten
- Ist leider auch mit die teuerste
- Bei näherer Betrachtung stellt man folgendes fest:
    - Oft erfüllt nur ein Bruchteil der Tupel die Anfragebedingungen
    - Anfragen haben oft ähnliche Prädikate
    - Festplatten erlauben wahlfreien Zugriff

Indexstrukturen

- Indexstrukturen nutzen diese Eigenschaften von Anfragen aus, um das transferierte Datenvolumen klein zu halten
- Sie erlauben schnellen assoziativen Zugriff auf die Daten
- Nur der Teil der Daten, der zur Beantwortung der Anfrage wirklich gebraucht wird, wird in den Hauptspeicher geholt
- Zwei bedeutende Indexierungsansätze
  - Hierarchisch (Bäume)
  - Hashing (Partitionierung)

Hierarchische Indexe

- Wir betrachten zwei hierarchische Indexstrukturen:
  - ISAM (Index-Sequential Access Method)
  - B-Bäume

ISAM

- ISAM war Vorgänger von B-Bäumen
- Hauptidee ist die Tupel auf dem indexierten Attribut zu sortieren und eine Indexdatei darüber anzulegen
- Ähnlich wie ein Daumenindex an der Seite eines Buches, durch den man schnell durchblättern kann

Beispiel

- Der Student mit der Matrikelnummer 13542 wird gesucht
- Alle Tupel der Relation `Student` sind sortiert nach MatrNr

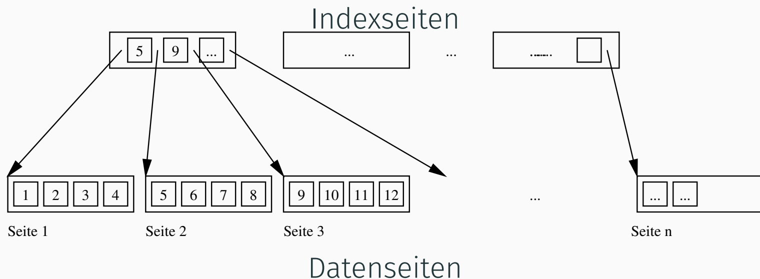

Beispiel(2)

- Während der Anfragebearbeitung geht man durch die Indexseiten und sucht die Stelle an der 13542 passt
- Von dort aus wird die referenzierte Datenseite geholt
- Vorteil: die Anzahl der Indexseiten ist normalerweise sehr viel kleiner als die Anzahl der Datenseiten, d.h. es wird I/O gespart
- Es können auch Bereichsanfragen beantwortet werden (z.B. bei einer Suche nach allen MatrNr zwischen 765 und 1232: zuerst die erste passende Datenseite finden und von dort aus sequentiell durch die Datenseiten bis MatrNr 1232 laufen)

Probleme mit ISAM

- Obwohl Suche auf ISAM einfach und schnell ist, kann die Instandhaltung des Indexes teuer werden
- Wenn ein Tupel auf eine gefüllte Datenseite eingefügt werden soll, muss Platz geschaffen werden: die Datenseite wird auf zwei Seiten aufgeteilt (wir müssen Sortierung beibehalten)
- Das erzeugt wiederum einen neuen Eintrag auf einer Indexseite
- Wenn auf der Indexseite auch kein Platz mehr ist, müssen die Einträge verschoben werden, um Platz zu schaffen

Weitere Probleme

- Obwohl die Anzahl der Indexseiten kleiner als die Anzahl der Datenseiten, kann Durchlauf der Indexseiten trotzdem lange dauern
- Idee: warum richtet man nicht Indexseiten für die Indexseiten ein?
- Das ist im Prinzip die Idee eines B-Baums

B-Baum (Beispiel)

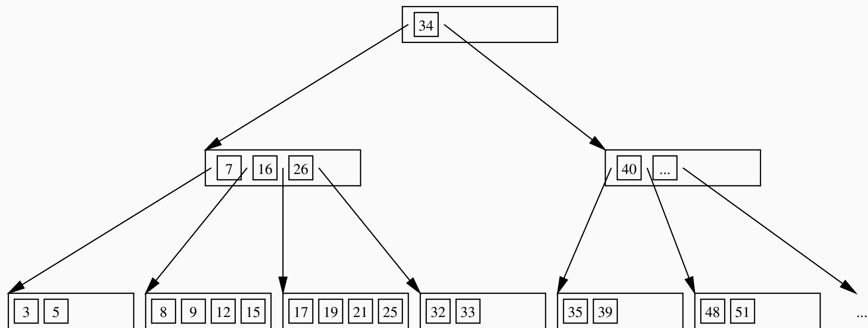

Einfügen von 14

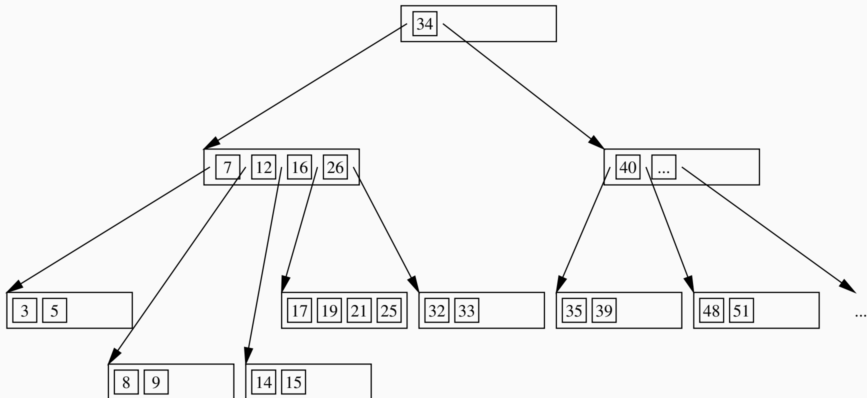

Einfügen von 20

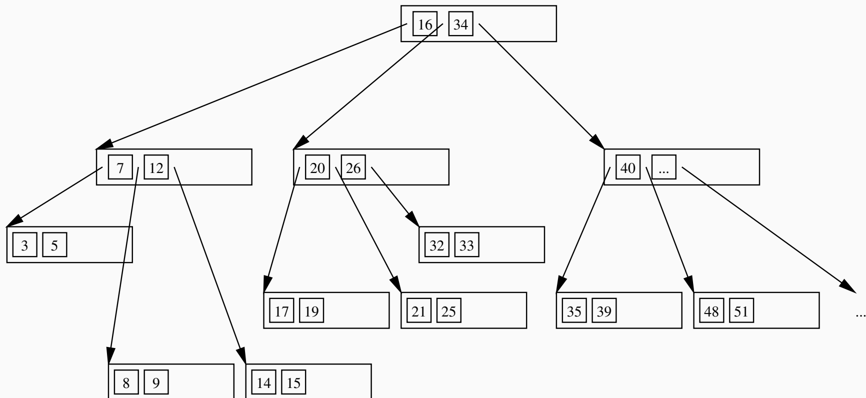

Eigenschaften eines B-Baums

- Jeder Pfad von der Wurzel zu einem Blatt hat die gleiche Länge
- Jeder Knoten (außer der Wurzel) hat mindestens k und höchstens ki Einträge (in obigem Beispiel $k = 2$)
- Die Einträge in jedem Knoten sind sortiert
- Jeder Knoten (außer Blätter) mit n Einträgen hat $n + 1$ Kinder

Eigenschaften eines B-Baums(2)

- Seien $p_0, k_1, p_1, k_2, \ldots k_n, p_n$ die Einträge in einem Knoten (p_j sind Zeiger, k_j Schlüssel)
- Dann gilt folgendes:
  - Der Unterbaum der von p_0 referenziert wird, enthält nur Schüssel kleiner als k_1
  - p_j zeigt auf einen Unterbaum mit Schlüsseln zwischen k_j und k_{j+1}
  - Der Unterbaum der von p_n referenziert wird, enthält nur Schlüssel größer als k_n

Einfügealgorithmus

1. Finde den richtigen Blattknoten, um den neuen Schlüssel einzufügen
2. Füge Schlüssel dort ein
3. Falls kein Platz mehr da
    3.1 Teile Knoten und ziehe Median heraus
    3.2 Füge alle Werte kleiner als Median in linken Knoten, alle größer als Median in rechten Knoten
    3.3 Füge Median in Elternknoten ein und passe Zeiger an

Einfügealgorithmus(2)

4. Falls kein Platz in Elternknoten
    - Falls Wurzelknoten, kreiere neuen Wurzelknoten und füge Median ein, passe Zeiger an
    - Ansonsten, wiederhole 3. mit Elternknoten

Löschalgorithmus

- In einem Blattknoten kann ein Schlüssel einfach gelöscht werden
- In einem inneren Knoten muss Verbindung zu den Kindern bestehen bleiben
    - Deshalb wird der nächstgrößere (oder nächstkleinere) Schlüssel gesucht (in entsprechendem Kindknoten)
    - Dieser Schlüssel wird an die Stelle des gelöschten Schlüssels geschrieben

Löschalgorithmus(2)

- Nach Löschen eines Schlüssels kann ein Knoten unterbelegt sein (weniger als k Einträge haben)
- Dann wird dieser Knoten mit einem Nachbarknoten verschmolzen
- Das kann eine Unterbelegung im Elternknoten hervorrufen, d.h. Elternknoten muss ebenfalls verschmolzen werden
- Da dieses Verfahren relativ aufwendig ist und Datenbanken eher wachsen als schrumpfen, wird diese Verschmelzung oft nicht realisiert

B^+-Bäume

- Die Performanz eines B-Baums hängt stark von der Höhe des Baumes ab, deswegen wollen wir hohen Verzweigungsgrad der inneren Knoten
- Abspeichern von Daten in inneren Knoten reduziert den Verzweigungsgrad
- B^+-Bäume speichern lediglich Referenzschlüssel in inneren Knoten, die Daten selbst werden in Blattknoten gespeichert
- Meistens sind die Blattknoten noch verkettet, um schnelle sequentielle Suche zu ermöglichen
- B^+-Bäume werden fast immer B-Bäumen vorgezogen
- Deswegen wird häufig von B-Bäumen gesprochen auch wenn eigentlich B^+-Bäume gemeint sind

Schematische Darstellung

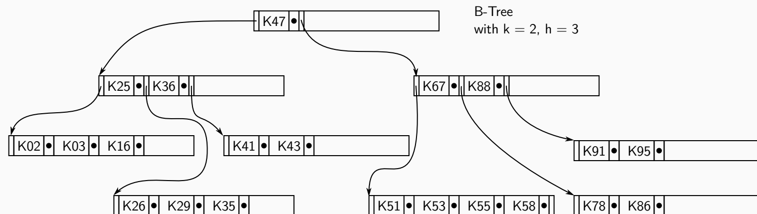

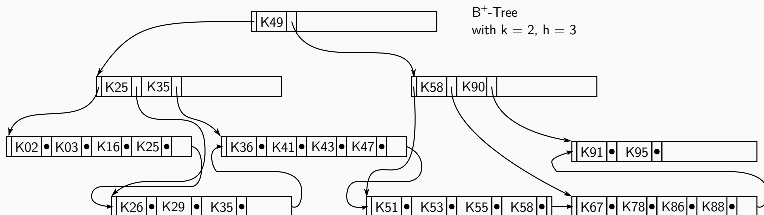

Präfix-B^+-Bäume

- Weitere Verbesserung ist der Einsatz von Referenzschlüsselpräfixen, z.B. bei langen Zeichenketten
- Es muss nur irgendein Referenzschlüssel gefunden werden, der linken vom rechten Teilbaum trennt:
  - Müller $\leq$ P $<$ Schmidt
  - Systemprogramm $\leq$? $<$ Systemprogrammierer
- Gemeinsamer Präfix aller Schlüssel einer Seite braucht nur einmal gespeichert werden

Zusammengesetzte Schlüssel

- Es ist möglich mehrere Attribute “gleichzeitig” mit einem Index zu indizieren:
  ```
  create index R_ab on R(a, b);
  ```
- Schlüssel werden quasi lexikografisch von links nach rechts sortiert
- Damit können z.B. folgende Anfrage vom Index beantwortet werden (? steht für Konstanten):
  - `a=? AND b=?`
  - `a=?`
  - `a>?`
  - `a=? AND b>?`
- Die Reihenfolge der Attribute ist wichtig: `b=?` kann nicht beantwortet werden

Hashing

- Bäume brauchen im Schnitt $\log_k(n)$ Seitenzugriffe, um ein Datenelement zu lesen (k=Verzweigungsgrad, n=Anzahl indexierter Datensätze)
- Hashtabellen (partitionierende Verfahren) benötigen im Schnitt zwei Seitenzugriffe

Hashing

- Hashfunktion $h(x) = x \bmod 3$

0	
1	(27550, 'Schopenhauer', 6)
2	(24002, 'Xenokrates', 18)
	(25403, 'Jonas', 12)

Hashing(2)

- Kollisionsbehandlung

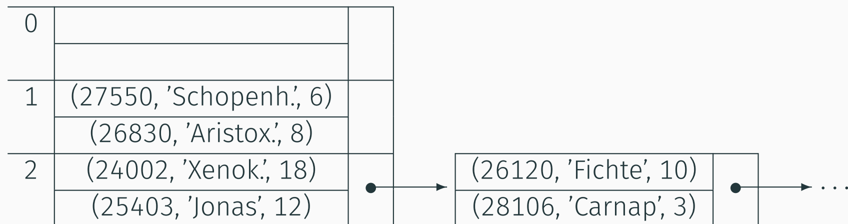

- Ineffizient bei nicht vorhersehbarer Datenmenge

Erweiterbares Hashing

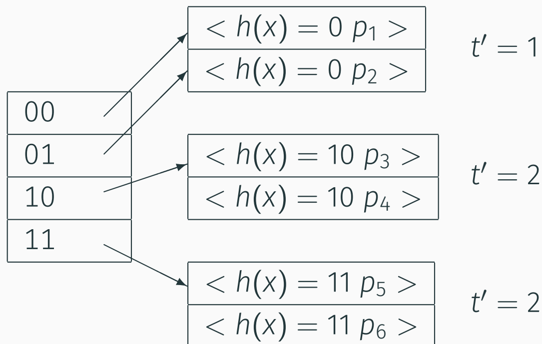

Verzeichnis

$t = 2$

Behälter

Konkretes Beispiel

x	$h(x)$	
	d	p
2125	1	01100100001
2126	0	11100100001
2127	1	11100100001

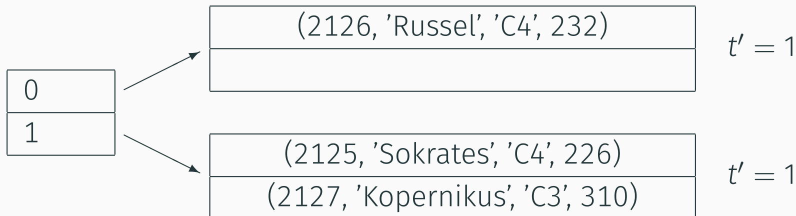

(2129, Descartes, ...) einfügen

x	$h(x)$	
	d	p
2125	10	1100100001
2126	01	1100100001
2127	11	1100100001
2129	10	0010100001

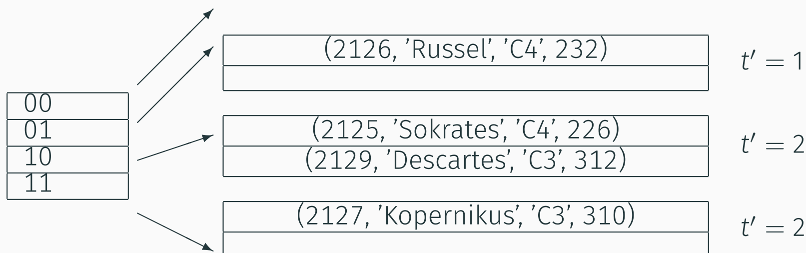

Hashing vs. B-Bäume

- Hashing benötigt weniger ($O(1)$ vs. $O \log(n)$) Seitenzugriffe
- Allerdings kann Hashing "ausarten" ($O(n)$) wenn die Hashfunktion schlecht ist
- Innere Knoten in B-Bäumen können typischerweise gepuffert werden
- Hashing randomisiert die Schlüsselverteilung was zu weniger räumlicher Lokalität führen kann
- Hashing erlaubt keine Bereichsanfragen, keine Präfixanfragen
- Deswegen ist in den meisten Datenbanksystemen der B^+-Baum die Standardindexstruktur (oder die einzige Struktur)

Ballung (Clustering)

```
select *
from   R
where  A = x;
```

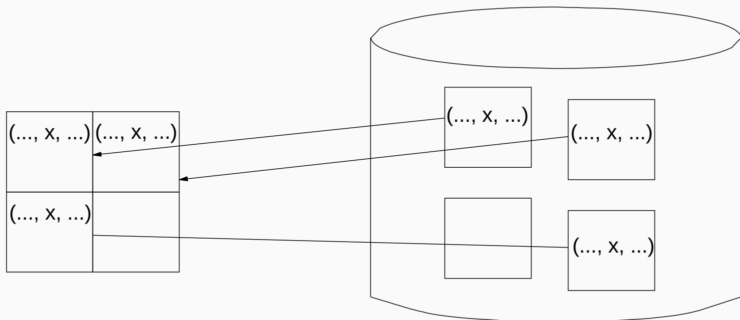

Indexe und Ballung

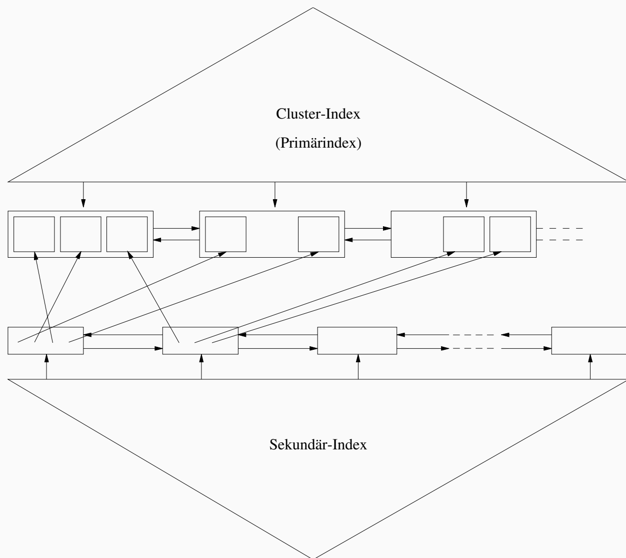

Verzahnte Ballung

Seite P_i

2125 ∘ Sokrates	∘ C4 ∘	226	•
5041 ∘ Ethik	∘ 4 ∘	2125	•
5049 ∘ Mäeutik	∘ 2 ∘	2125	•
4052 ∘ Logik	∘ 4 ∘	2125	•
2126 ∘ Russel	∘ C4 ∘	232	•
5043 ∘ Erkenntnistheorie	∘ 3 ∘	2126	•
5052 ∘ Wissenschaftstheorie	∘ 3 ∘	2126	•
5216 ∘ Bioethik	∘ 2 ∘	2126	•

Seite P_{i+1}

2133 ∘ Popper	∘ C3 ∘	52	•
5259 ∘ Der Wiener Kreis	∘ 2 ∘	2133	•
2134 ∘ Augustinus	∘ C3 ∘	309	•
5022 ∘ Glaube und Wissen	∘ 2 ∘	2134	•
⋮			

Zusammenfassung

- TIDs ist geschickte Abbildung der Relationen auf Seiten im Hintergrundspeicher
- Indexe beschleunigt Zugriffe auf Datenelemente (auf Kosten der Update-Operationen)
- B^+-Bäume sind die Standardindexstrukturen in relationalen DBMS, sowohl für Punkt- als auch für Bereichsanfragen geeignet