Datenbanken

Prof. Dr. Ralf Möller
Universität zu Lübeck
Institut für Informationssysteme

Marc Stelzner (Übungen)
Torben Matthias Kempfert (Tutor)
Maurice-Raphael Sambale (Tutor)

Architektur eines DBMS

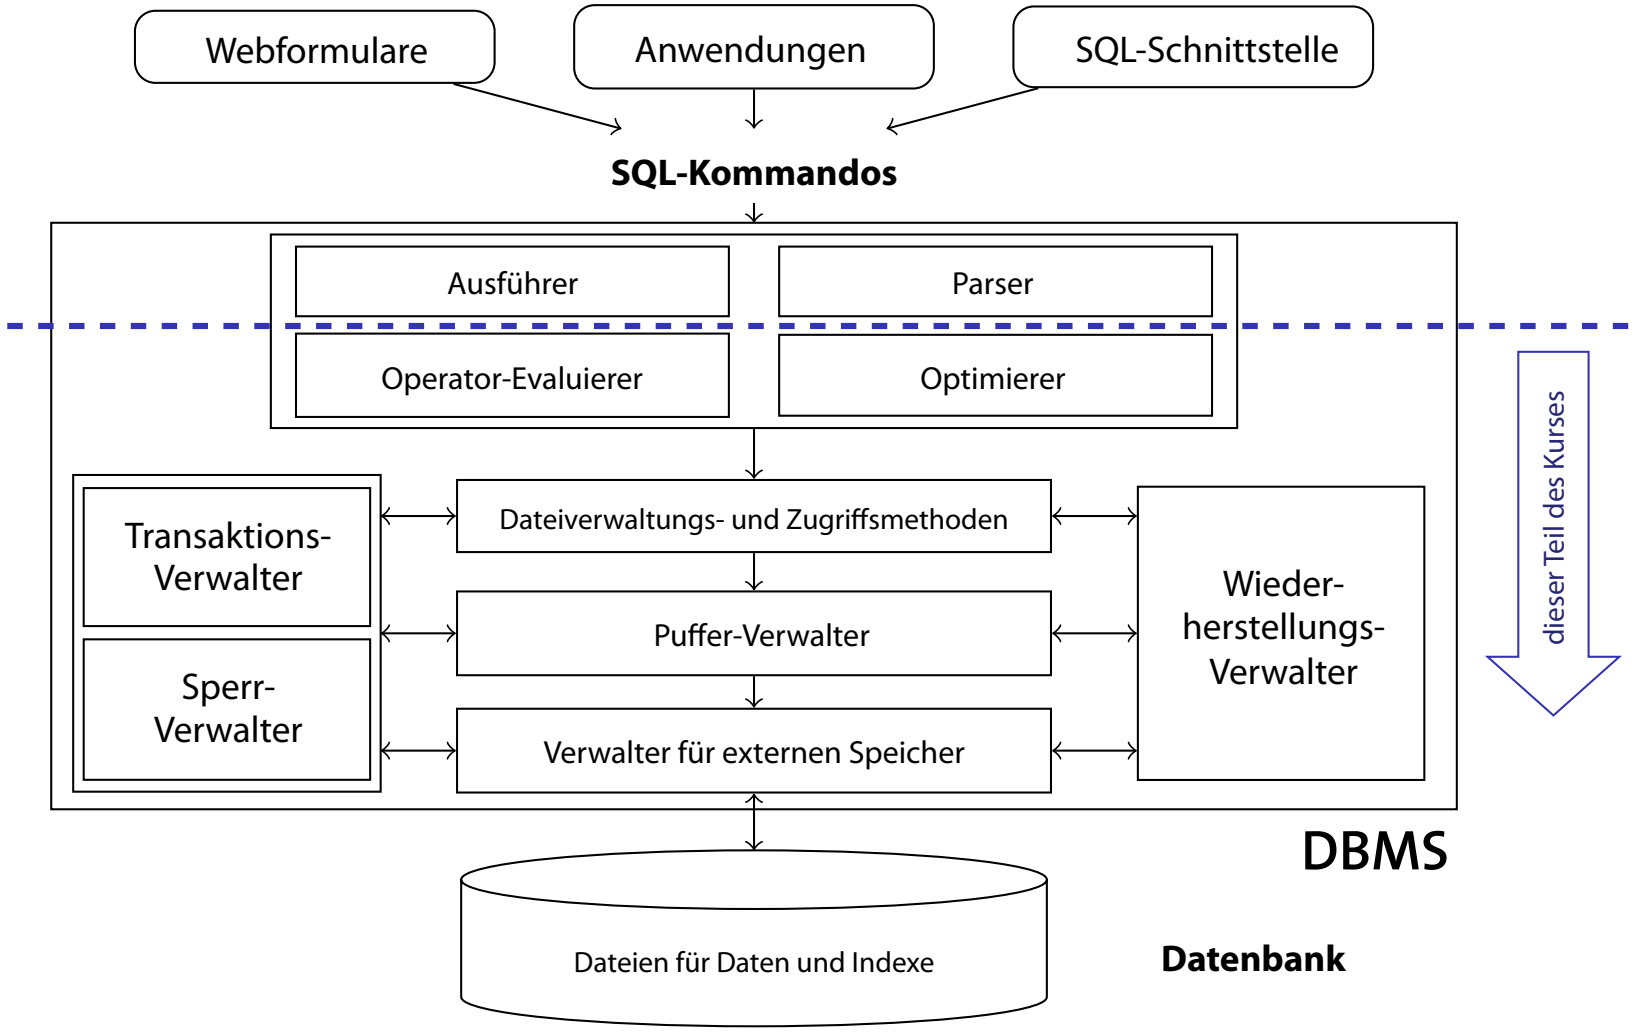

Danksagung

- 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

Speicher: Platten und Dateien

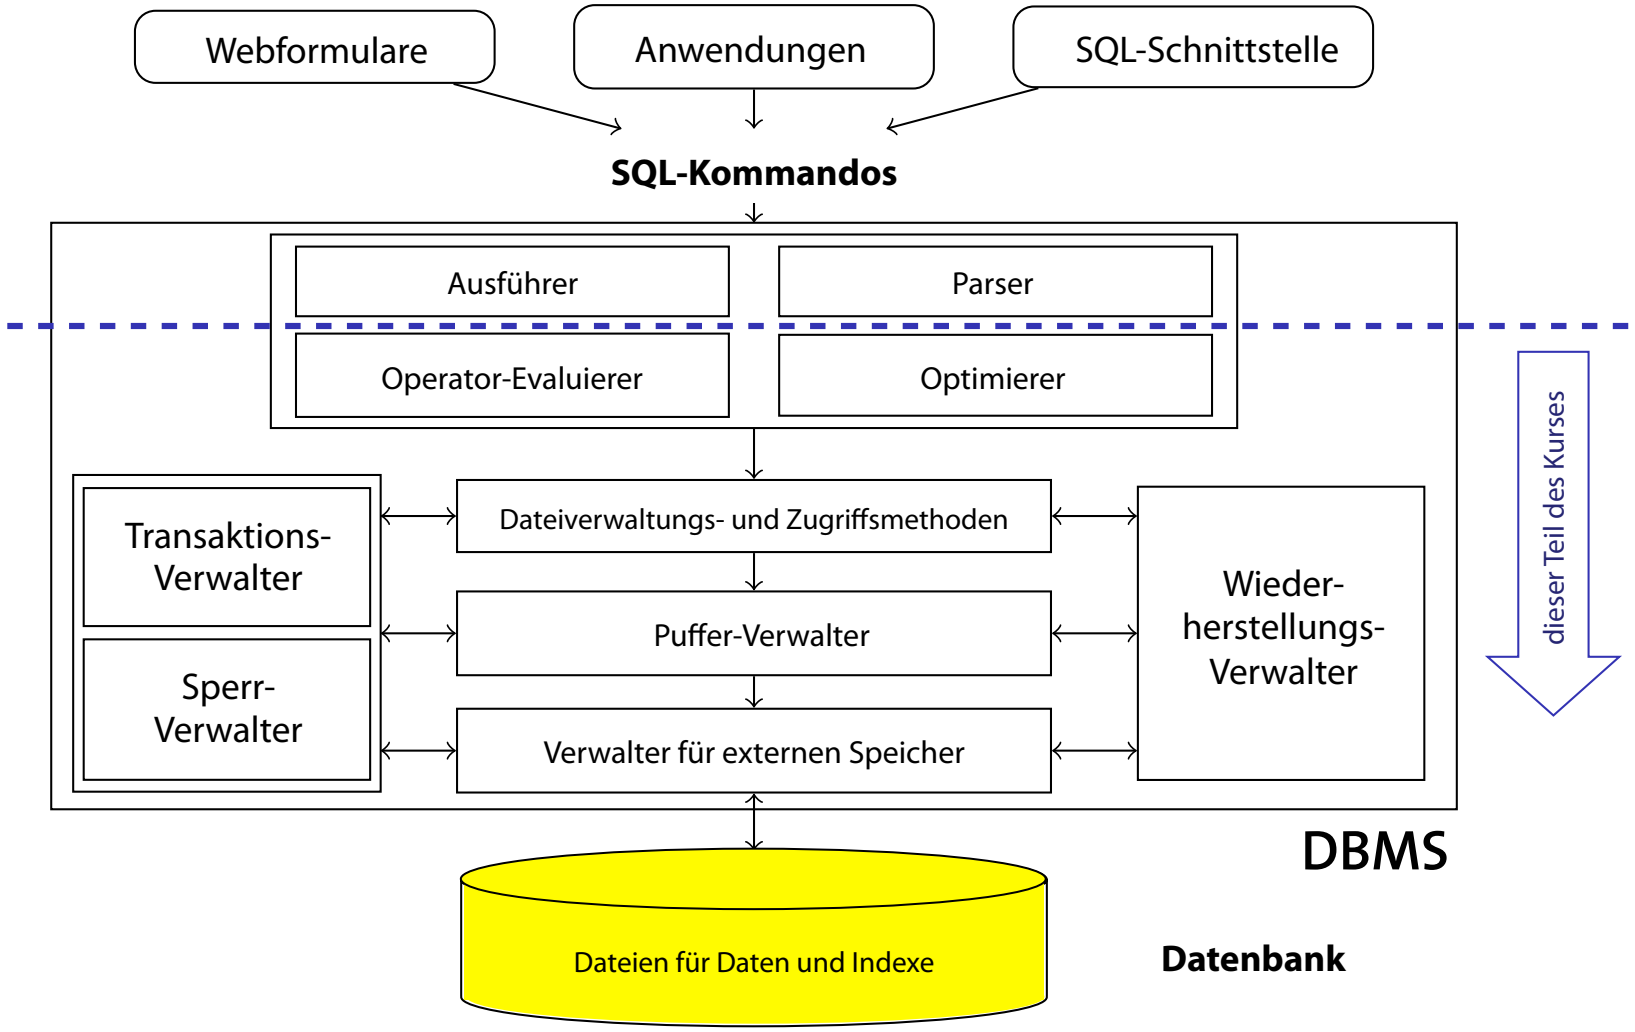

Speicherhierarchie

	Kapazität	Latenz
• CPU (mit Registern)	Bytes	< 1 ns
• Cache-Speicher	Kilo-/Mega-Bytes	< 10 ns
• Hauptspeicher	Giga-Bytes	20-100 ns
• Flash-Speicher	Giga/Tera-Bytes	30-250 µs
• Festplatte	Tera-Bytes	3-10 ms
• Bandautomat	Peta-Bytes	variierend

- Zur CPU: Schnell aber klein
- Zur Peripherie: Langsam aber groß
- Cache-Speicher zur Verringerung der Latenz

Magnetische Platten / Festplatten

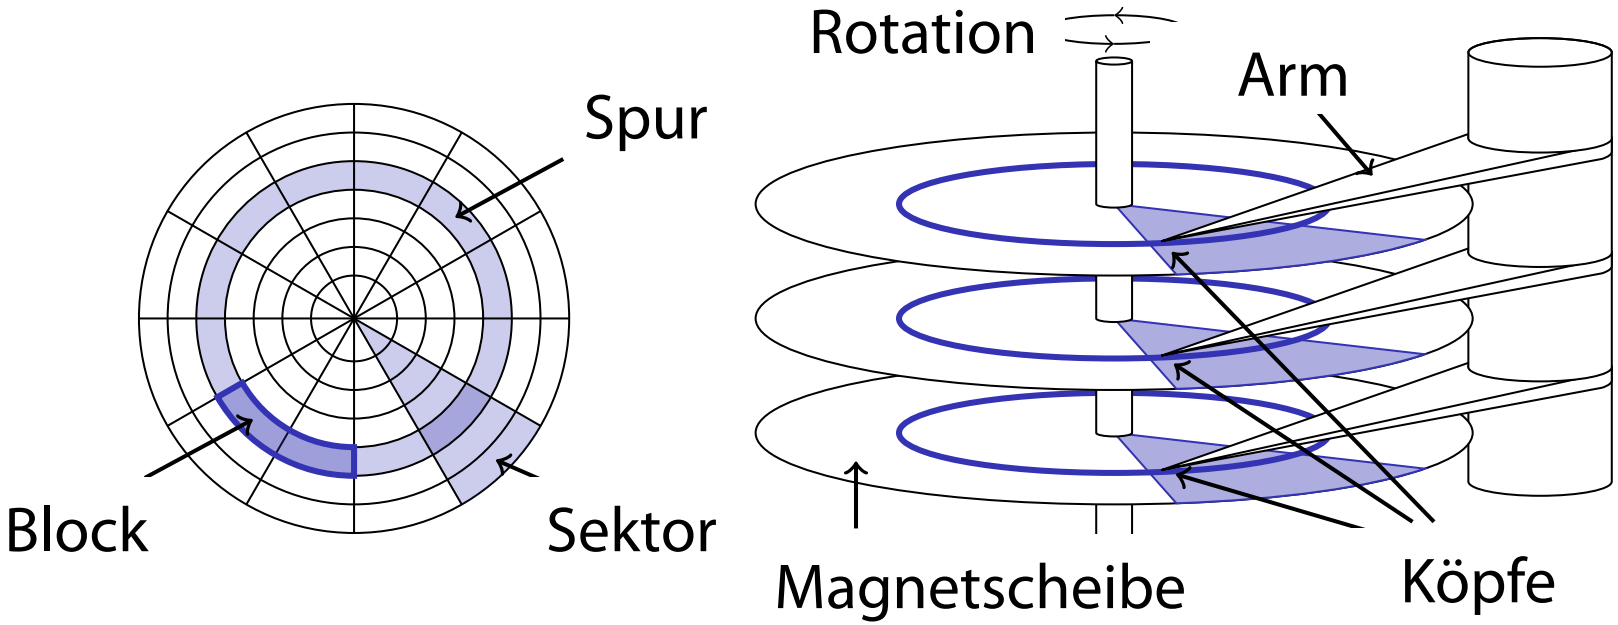

- Schrittmotor positioniert Arme auf bestimmte Spur
- Magnetscheiben rotieren ständig
- Organisation in Blöcke
- Transfer erfolgt blockweise (lesend und schreibend)

Photo: http://www.metallurgy.utah.edu/

Zugriffszeit

Konstruktion der Platten hat Einflüsse auf Zugriffszeit (lesend und schreibend) auf einen Block

1. Bewegung der Arme auf die gewünschte Spur (Suchzeit t_s)
2. Wartezeit auf gewünschten Block bis er sich unter dem Arm befindet (Rotationsverzögerung t_r)
3. Lesezeit bzw. Schreibezeit (Transferzeit t_{tr})

Zugriffszeit: $t = t_s + t_r + t_{tr}$

Hitachi Travelstar 7K200 (für Laptops)

- 4 Köpfe, 2 Magnetplatten, 512 Bytes/Sektor,
- Kapazität: 200 GB
- Rotationsgeschwindigkeit: 7200 rpm
- Mittelere Suchzeit: 10 ms
- Transferrate: ca. 50 MB/s

Wie groß ist die Zugriffszeit auf einen Block von 8 KB?

Sequentieller vs. Wahlfreier Zugriff

Beispiel: Lese 1000 Blöcke von je 8 KB

- Wahlfreier Zugriff:
  - $t_{rnd} = 1000 \cdot 14.33$ ms
- Sequentieller Zugriff:
  - Travelstar 7k200 hat 63 Sektoren pro Spur, mit einer Track-to-Track-Suchzeit von 1 ms
  - Ein Block mit 8 KB benötigt 16 Sektoren
  - $tseq = t_s + 1000 \cdot t_{tr} + 16 \cdot 1000/63 \cdot t_{s,track\text{-}to\text{-}track}$
    $= 10 \text{ ms} + 4.14 \text{ ms} + 160 \text{ ms} + 254 \text{ ms} \approx 428 \text{ ms}$

Einsicht: Sequentieller Zugriff **viel** schneller als wahlfreier Zugriff: Vermeide wahlfreie I/O wenn möglich

Beobachtung: Wenn 428 ms / 14330 ms = 3% einer Datei benötigt wird, kann man gleich die ganze Datei lesen

Tricks zur Performanzsteigerung

Spurverschiebung (track skewing)

Verschiebe Sektor 0 einer jeden Spur,
so dass Rotationsverzögerung
bei sequentiellem Abgriff minimiert wird

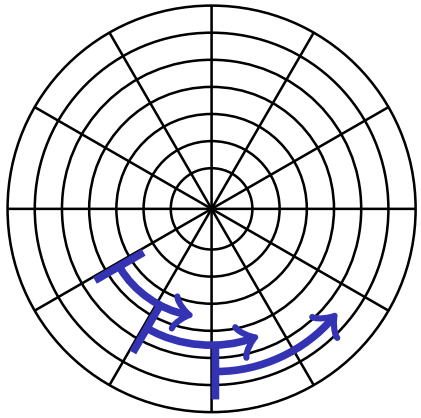

Anfrageplanung (request scheduling)

Falls mehrere Blockanfragen befriedigt werden müssen,
wähle die Anfrage, die die kleineste Armbewegung bedarf
(SPTF: shortest positioning time first)

Einteilung in unterschiedliche Zonen (zoning)

Mehr Sektoren in den längeren äußeren Spuren
unterbringen

Verbesserung der Festplattentechnologie

Latenz der Platten über die letzten 10 Jahre
nur marginal verbessert (≈ 10% pro Jahr)

Aber:

- Durchsatz (Transferraten) um ≈ 50% pro Jahr verbessert
- Kapazität der Festplatten um ≈ 50% pro Jahr verbessert

Daher:

- Kosten für wahlfreien Zugriff über die Zeit hinweg relativ gesehen immer bedeutsamer

Wege zur Verbesserung der I/O-Performanz

Latenzproblem kaum zu vermeiden

Aber:

- Durchsatz kann recht leicht gesteigert werden durch Ausnutzung von Parallelität
- Idee: Verwende mehrere Platten und greife parallel auf Daten zu

TPC-C: Ein Industrie-Laufzeittest für OLTP (V5.11)

Kennzeichen des im Jahre 2013 besten Systems (Oracle 11g auf SPARC T5-8 Server):

- Server-CPU: SPARC T5 3,6 GHz, #Prozessoren: 8, #Kerne (total): 128
- Client-CPUs: Intel Xeon E5-2690 2,9 GHz, #Clients: 8, #Proz. 32, #Kerne: 256
- In der Summe 8,5 Mio Transaktionen pro Minute
- Kosten: $4.663.073 USD

Spiegelung von Festplatteninhalten

- Replizierung von Daten auf mehrere Platten

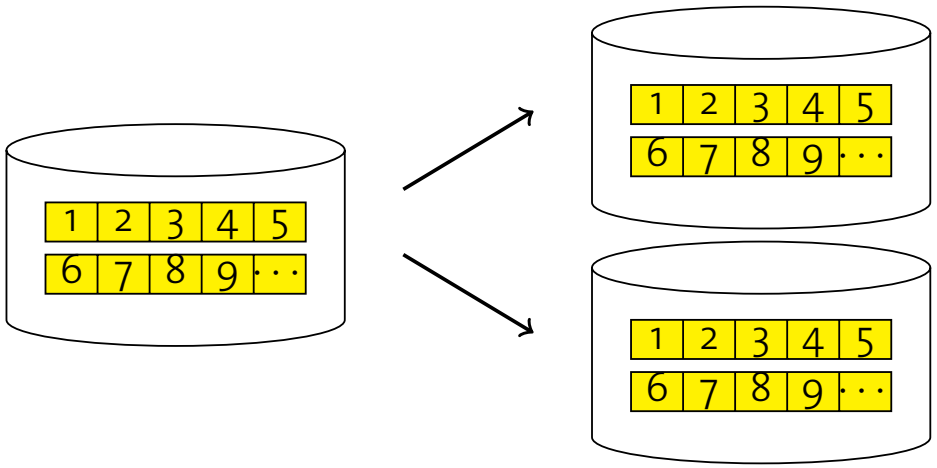

- I/O-Parallelität nur für Lesezugriffe
- Erhöhte Fehlertoleranz (überlegt Plattenfehler)
- Als RAID1 bekannt (Spiegelung ohne Parität)
  (RAID: Redundant Array of Inexpensive Disks)

Speicherung mit Streifenbildung

- Verteilung der Daten auf mehrere Platten

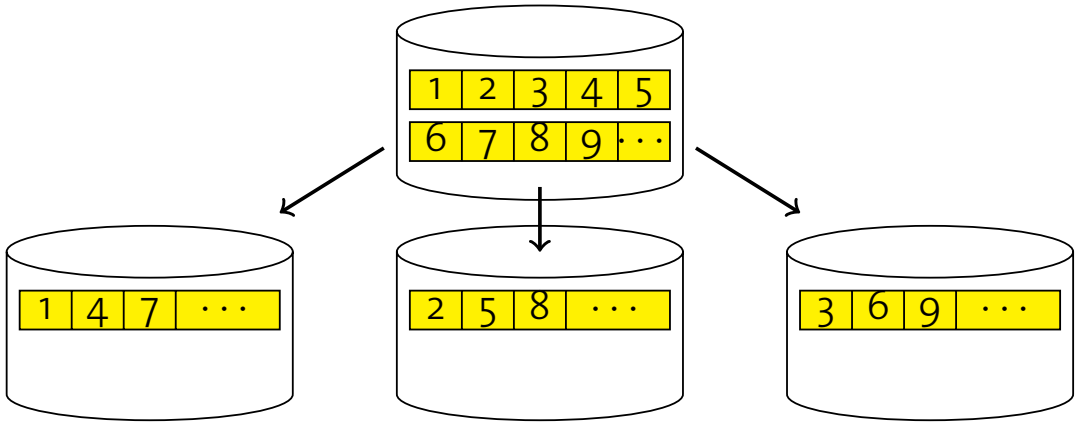

- Volle I/O-Parallelität
- Hohe Fehlerrate (hier: dreimal höheres Ausfallrisiko)
- Auch als RAID-0 bekannt (Streifenbildung ohne Parität)

Streifenbildung mit Parität

- Verteile Daten und Paritätsinformation über Platten

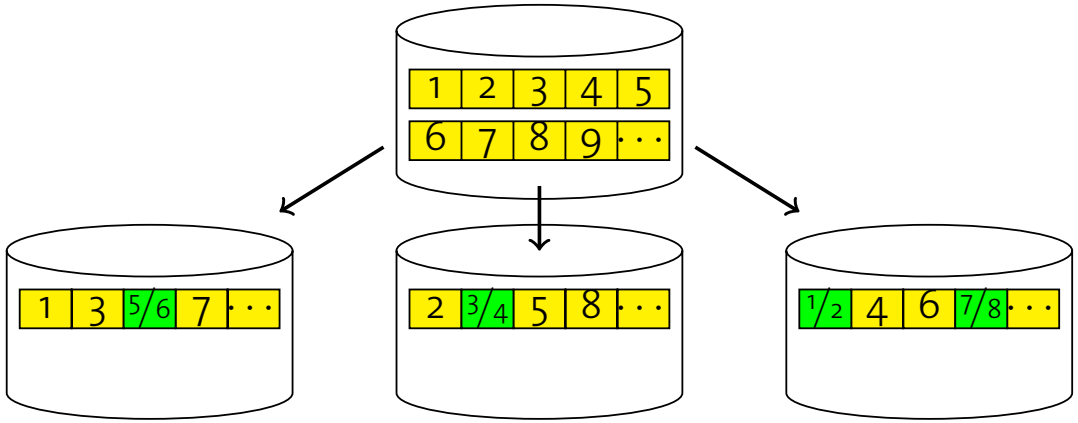

- Hohe I/O-Parallelität
- Fehlertoleranz: Eine Platte kann ausfallen, ohne dass Daten verloren gehen
- RAID-5 (Streifenbildung mit verteilter Parität)

Solid-State Disks als Alternative zur Festplatte

Anpassung von Datenbanken auf Geräteeigenschaften ist immer noch Forschungsgegenstand

	MLC-NAND-Flash-Laufwerk 1,0″ bis 3,5″	RAM-Disk als Teil des Arbeitsspeichers	Festplatte 1,0″ bis 3,5″
Größe (keine Raidlaufwerke)	bis 4 TB	bis 32 GB je Modul	bis 8 TB
Preis pro TB (Stand Oktober 2014)	ab ≈ 330 €[7]	ab ≈ 4990 €[105]	ab ≈ 27,30 €
Anschluss	S-ATA, P-ATA, mSATA, PCIe	hauptsächlich DIMM-Connector	S-ATA, P-ATA, SCSI, SAS
Lesen (kein RAID)	bis 510 MB/s[106]	bis 51200 MB/s[107]	bis ca. 227 MB/s[108]
Schreiben (kein RAID)	bis 490 MB/s[106]	bis 51200 MB/s[107]	bis ca. 160 MB/s[108]
Mittlere Zugriffszeit lesen	ab 0,031 ms[109]	0,000.02 ms	ab 3,5 ms
Mittlere Zugriffszeit schreiben	ab 0,023 ms[109]	0,000.02 ms	ab 3,5 ms
Überschreibbar (Zyklen)	3 bis 10 tausendmal (MLC)	$> 10^{15}$ [110]	ca. 10 Mrd. (3 Jahre)[111]

Quelle: Wikipedia Solid-State Disk

Netzwerk-Speicher ist kein Flaschenhals

- Durchsatz Festplatte: >500 MB/s (Serial ATA)
- SDRAM: 50 Gbit/s (Latenz: ~ ns)
- Ethernet
  - 100-Gbit/s heute (Latenz: ~ μs)
  - 400 Gbit/s erwartet in 2017

Warum also nicht Datenbank-Speicher über das Netzwerk referenzieren?

Speichernetzwerk (Storage Area Network, SAN)

- Block-basierter Netzwerkzugriff auf Speicher
  - Als logische Platten betrachtet
    (Suche Block 4711 von Disk 42)
  - Nicht wie bei NFS (Network File System)
- SAN-Speichergeräte abstrahieren von RAID oder physikalischen Platten und zeigen sich dem DBMS als logische Platten
  - Hardwarebeschleunigung und einfachere Verwaltung
- Üblicherweise lokale Netzwerke mit multiplen Servern und Speicherressourcen
  - Bessere Fehlertoleranz und erhöhte Flexibilität

Cloud-Speicher

- Cluster von vielen Standard-PCs (z.B. Google, Amazon)
  - Systemkosten vs. Zuverlässigkeit und Performanz
  - Verwendung massiver Replikation von Datenspeichern
- CPU-Zyklen und Disk-Kapazität als Service
  - Amazons „Elastic Compute Cloud (EC_2)“
    - Kosten pro Stunde <10 Cent
  - Amazons „Simple Storage System (S3)“
    - Unendlicher Speicher für Objekte in einer Größe zwischen 1 Byte und 5 GB mit Key-Value-Struktur
      - Latenz: 100 ms bis 1s
- Datenbank auf Basis von S3 entwickelt in 2008

M. Brantner, D. Florescu, D. Graf, D. Kossmann, T. Kraska, Building a database on S3, Proceedings of the 2008 ACM SIGMOD International Conference on Management of Data (SIGMOD '08), S. 251-264, **2008**

Architektur eines DBMS

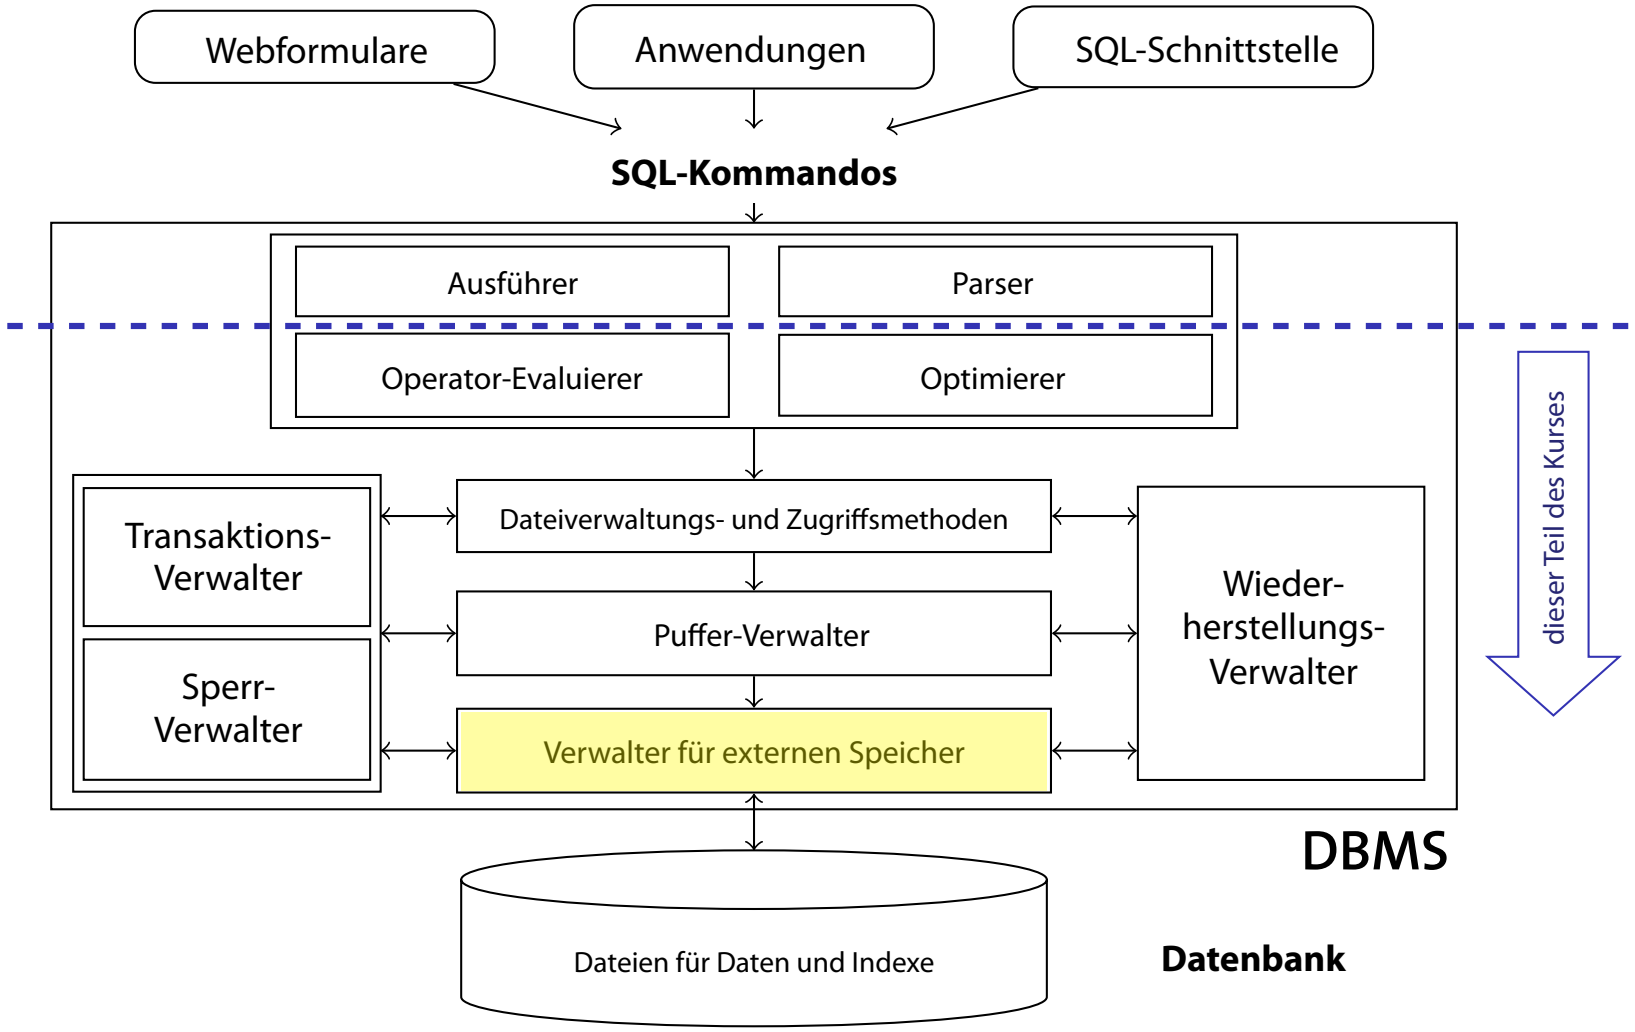

Verwaltung des externen Speichers

- Abstraktion von technischen Details der Speichermedien
- Konzepte der Seite (page) mit typischerweise 4-64KB als Speichereinheiten für die restlichen Komponenten
- Verzeichnis für Abbildung

  Seitennummer → Physikalischer Speicherort

  wobei der physikalische Speicherort
  - eine Betriebssystemdatei inkl. Versatz,
  - eine Angabe Kopf-Sektor-Spur einer Festplatte oder
  - eine Angabe für Bandgerät und -nummer inkl. Versatz

  sein kann

Verwaltung leerer Seiten

Verwendete Techniken:

1. Liste der freien Seiten
   - Hinzufügung falls Seite nicht mehr verwendet
2. Bitmap mit einem Bit für jede Seite
   - Umklappen des Bits k, wenn Seite k (de-)alloziert wird

Aufgabe

Verwendete Techniken:

1. Liste der freien Seiten
   - Hinzufügung falls Seite nicht mehr verwendet
2. Bitmap mit einem Bit für jede Seite
   - Umklappen des Bits k, wenn Seite k (de-)alloziert wird

Zur Erhöhung des **sequentiellen Zugriffs** sollten **hintereinanderliegende Seiten** verwendet werden.

Welche Technik, 1. oder 2., würden Sie wählen, um dieses zu unterstützen?

Architektur eines DBMS

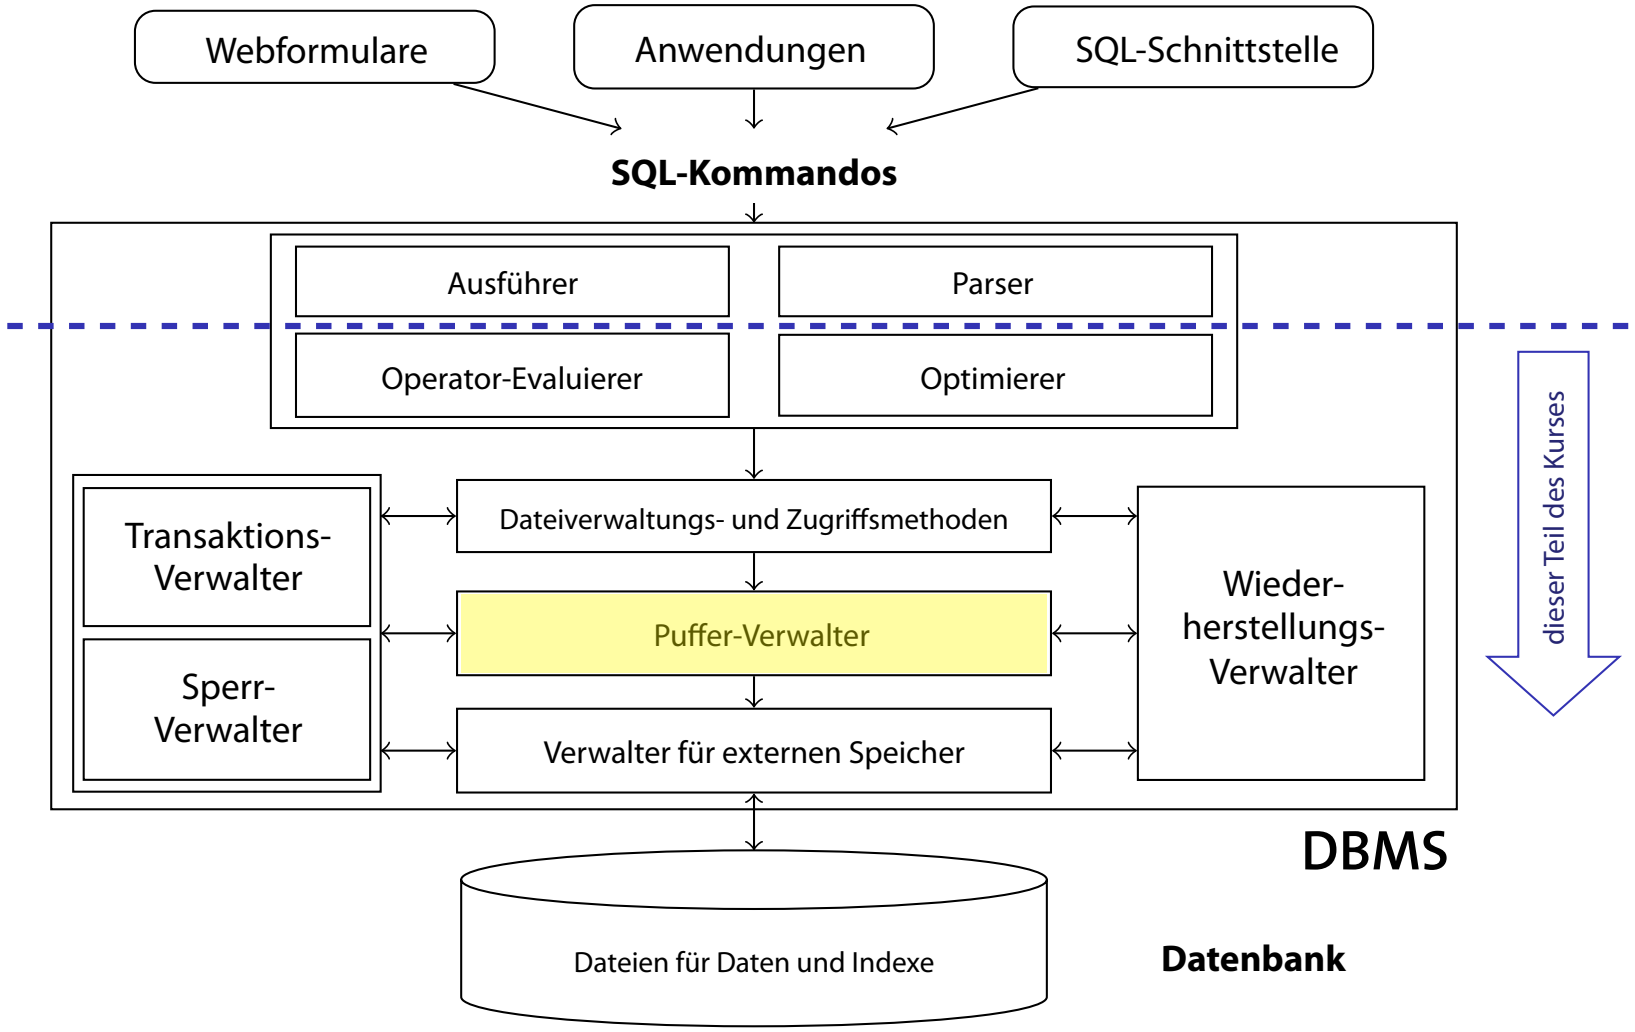

Puffer-Verwalter

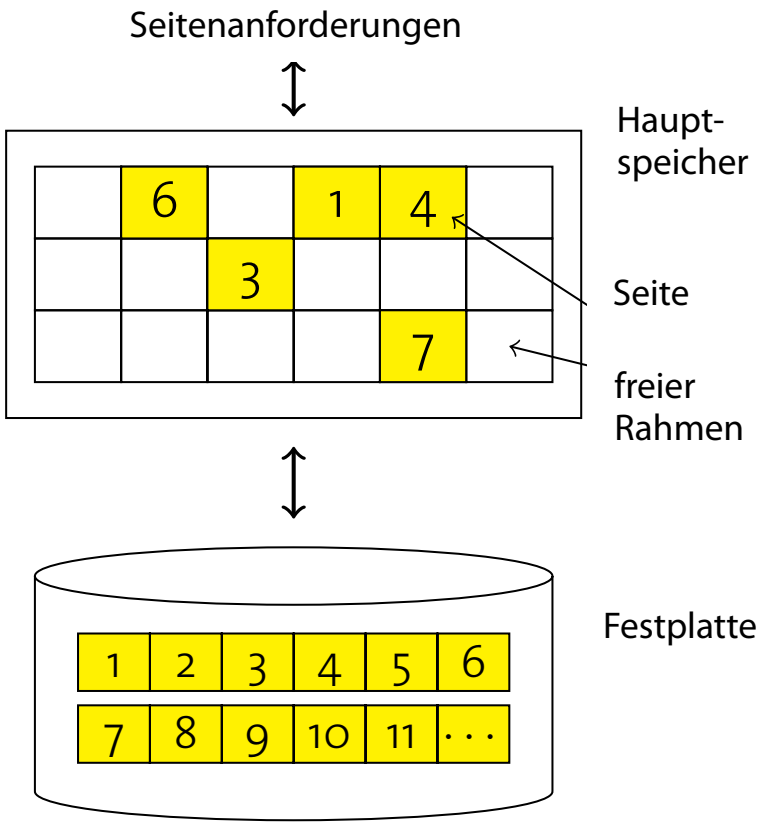

- Vermittelt zwischen externem und internem Speicher (Hauptspeicher)
- Verwaltet hierzu einen besonderen Bereich im Hauptspeicher, den Pufferbereich (buffer pool)
- Externe Seiten in Rahmen des Pufferbereichs laden
- Verdrängungsstrategie falls Pufferbereich voll

Schnittstelle zum Puffer-Verwalter

Funktion pin für Anfragen nach Seiten und
unpin für Freistellungen von Seiten nach Verwendung

- pin(pageno)
  - Anfrage nach Seitennummer pageno
  - Lade Seite in Hauptspeicher falls nötig
  - Rückgabe einer Referenz auf pageno
- unpin(pageno, dirty)
  - Freistellung einer Seite pageno zur möglichen Auslagerung
  - dirty = true bei Modifikationen der Seite

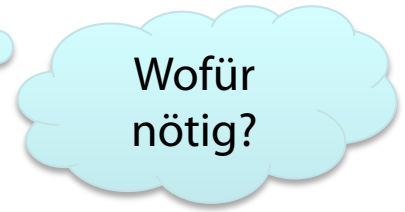

Implementation von pin()

```
1  Function: pin(pageno)
2  if buffer pool already contains pageno then
3  |   pinCount (pageno) ← pinCount (pageno) + 1 ;
4  |   return address of frame holding pageno ;
5  else
6  |   select a victim frame v using the replacement policy ;
7  |   if dirty (v) then
8  |   |   write v to disk ;
9  |   read page pageno from disk into frame v ;
10 |   pinCount (pageno) ← 1 ;
11 |   dirty (pageno) ← false ;
12 |   return address of frame v ;
```

Implementation von unpin()

```
1 Function: unpin(pageno, dirty)
2 pinCount(pageno) ← pinCount(pageno) − 1;
3 if dirty then
4     dirty(pageno) ← dirty;
```

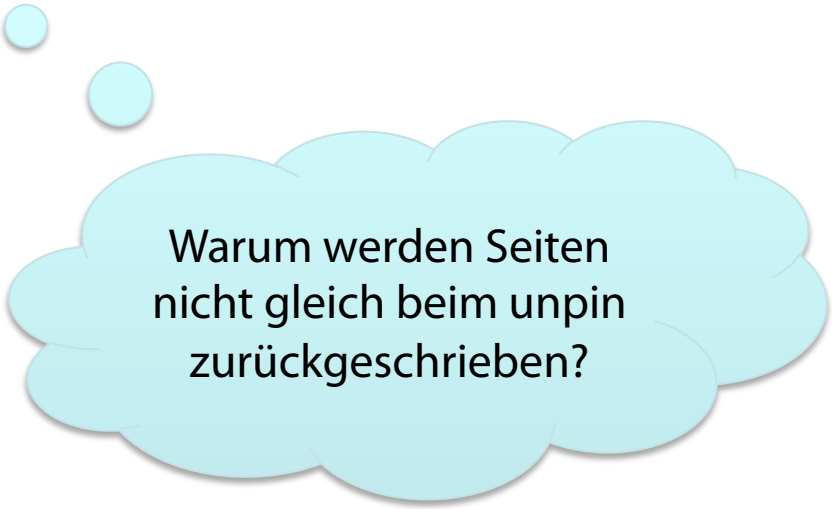

Verdrängungsstrategien

Die Effektivität des Puffer-Verwalters hängt von der gewählten Verdrängungsstrategie ab, z.B.:

- Least Recently Used (LRU)
  - Verdrängung der Seite mit längszurückliegendem unpin()
- LRU-k
  - Wie LRU, aber k-letztes unpin(), nicht letztes
- Most Recently Used (MRU)
  - Verdrängung der Seite mit jüngstem unpin()
- Random
  - Verdrängung einer beliebigen Seite

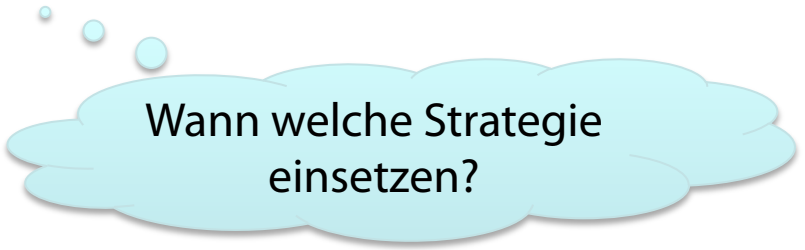

Pufferverwaltung in der Praxis

- Prefetching
  - Antizipation von Anfragen, um CPU- und I/O- zu überlappen
    - Spekulatives Prefetching: Nehme sequentiellen Seitenzugriff an und lese im Vorwege
    - Prefetch-Listen mit Instruktionen für den Pufferverwalter für Prefetch-Seiten
- Fixierungs- oder Verdrängungsempfehlung
  - Höherer Code kann Fixierung (z.B. für Indexseiten) oder schnelle Verdrängung (bei seq. Scans) empfehlen
- Partitionierte Pufferbereiche
  - Z.B. separate Bereiche für Index und Tabellen

Datenbanken vs. Betriebssysteme

- Haben wir nicht gerade ein Betriebssystem entworfen?
- Yes
  - Verwaltung für externen Speicher und Pufferverwaltung ähnlich
- Aber
  - DBMS weiß mehr über Zugriffsmuster (z.B. Prefetching)
  - Limitationen von Betriebssystemen häufig zu stark für DBMS (Obergrenzen für Dateigrößen, Plattformunabhängigkeit nicht gegeben)

Datenbanken vs. Betriebssysteme

- Gegenseitige Störung möglich
  - Doppelte Seitenverwaltung
  - DMBS-Transaktionen vs. Transaktionen auf Dateien organisiert vom Betriebssystem (journalling)
  - DBMS Pufferbereiche durch Betriebssystem ausgelagert
  - DBMS schalten Betriebssystemdienste aus
    - Direkter Zugriff auf Festplatten
    - Eigene Prozessverwaltung
    - ...

Architektur eines DBMS

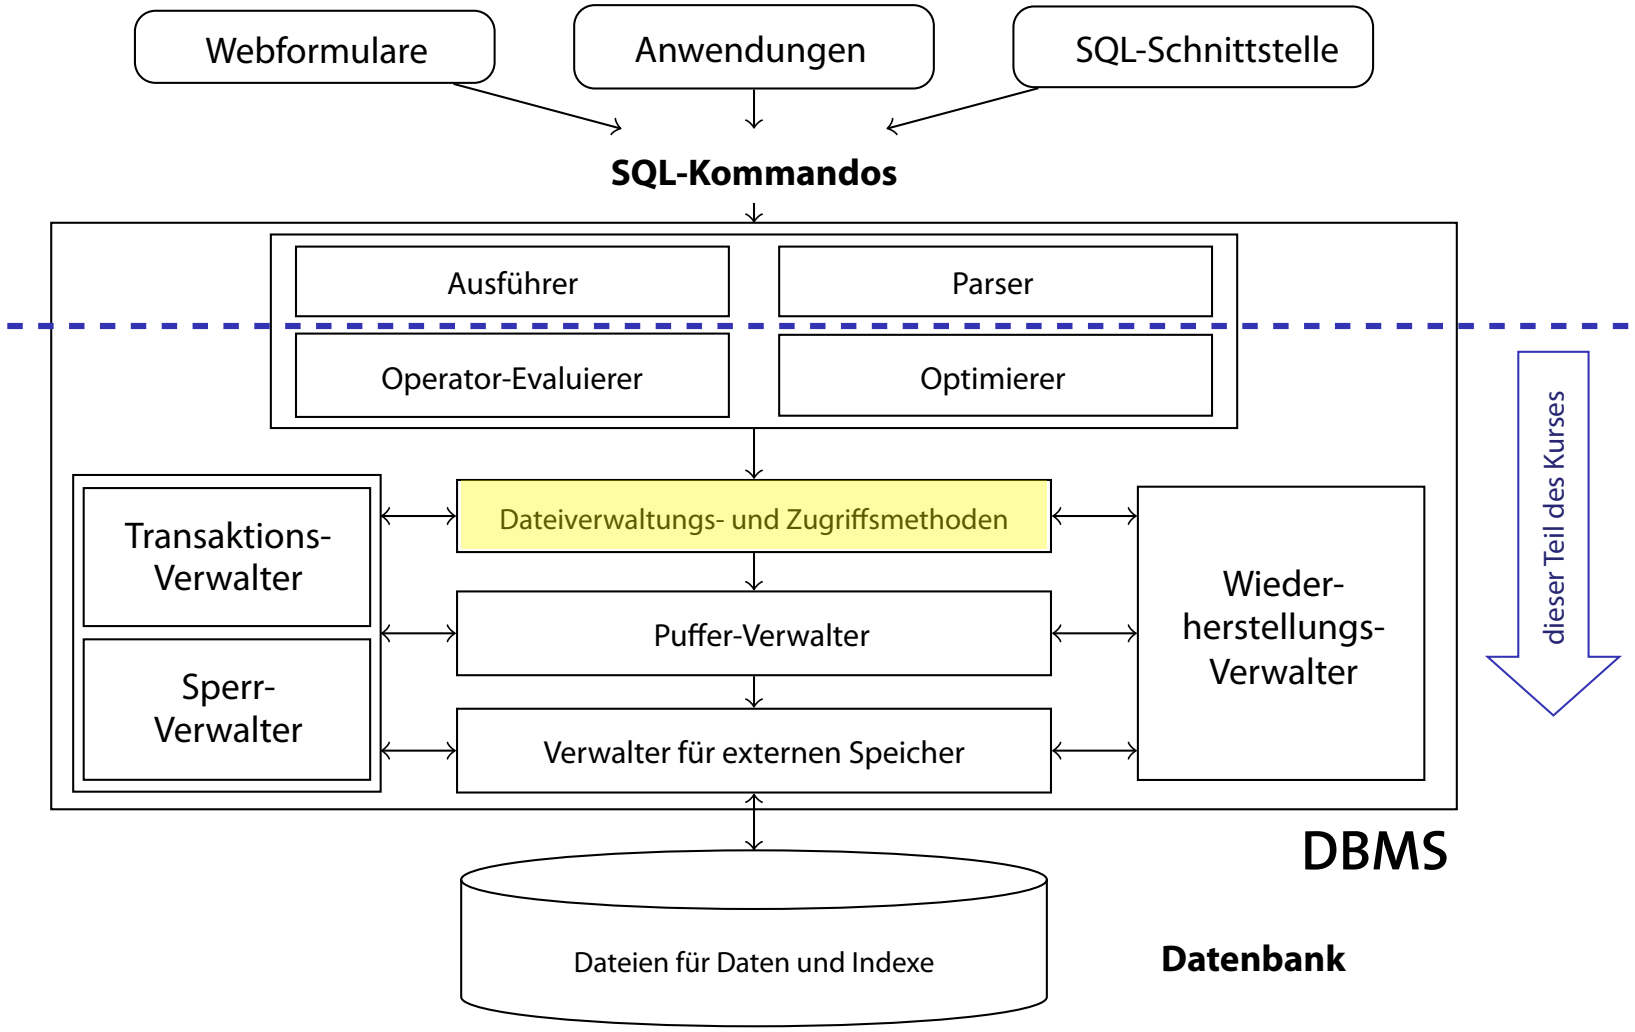

Datenbank-Dateien

- Seitenverwaltung unbeeinflusst vom Inhalt
- DBMS verwaltet Tabellen von Tupeln, Indexstrukturen, ...
- Tabellen sind Dateien von Datensätzen (records)
  - Datei besteht aus einer oder mehrerer Seiten
  - Jede Seite speichert eine oder mehrere Datensätze
  - Jeder Datensatz korrespondiert zu einem Tupel

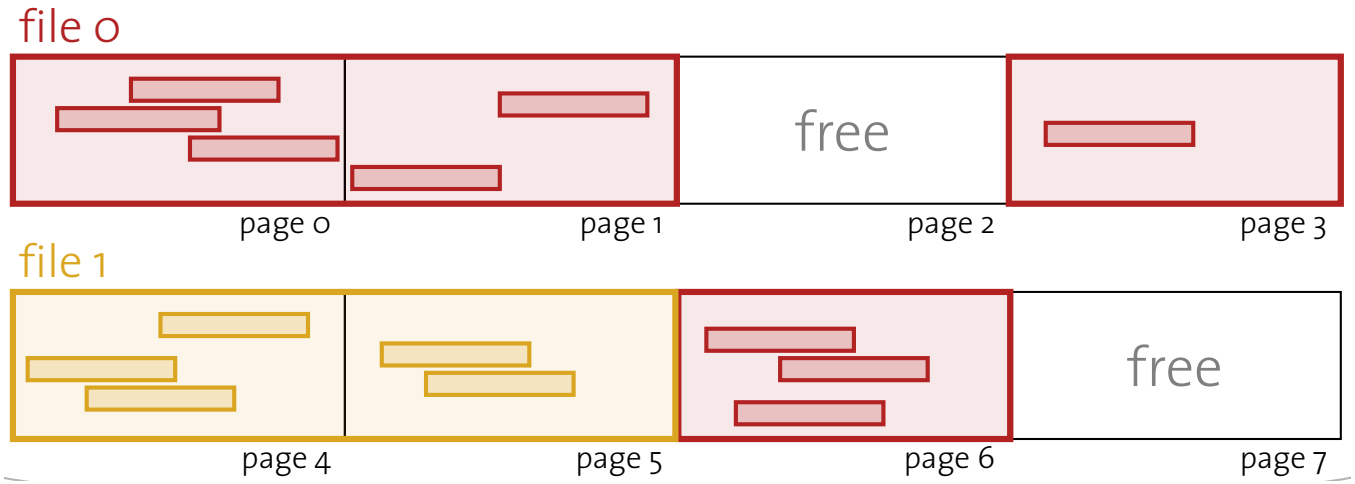

Heap-Dateien

- Wichtigster Dateityp: Speicherung von Datensätzen mit willkürlicher Ordnung (konform mit SQL)

Verkettete Liste von Seiten

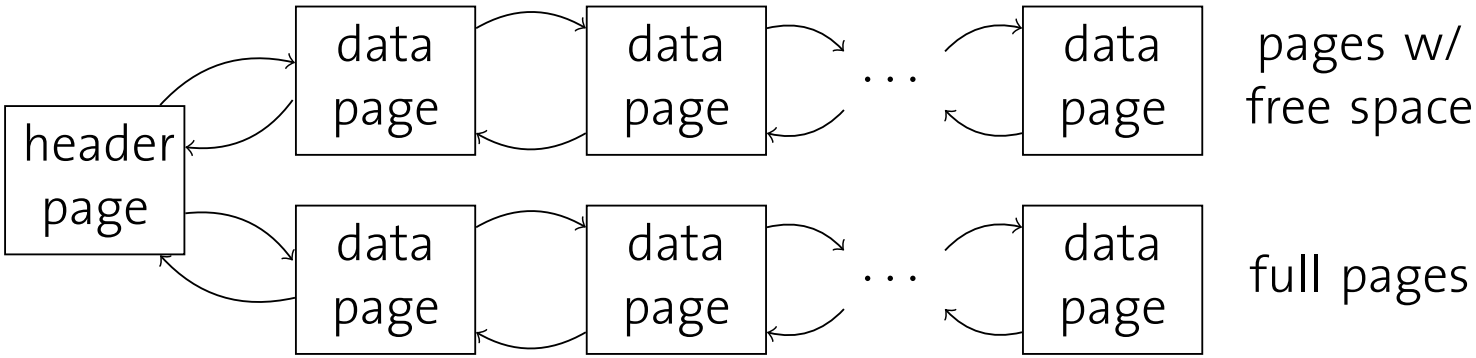

+ Einfach zu implementieren
- Viele Seiten auf der Liste der freie Seiten (haben also noch Kapazität)
- Viele Seiten anzufassen bis passende Seite gefunden

Heap-Dateien

- Verzeichnis von Seiten

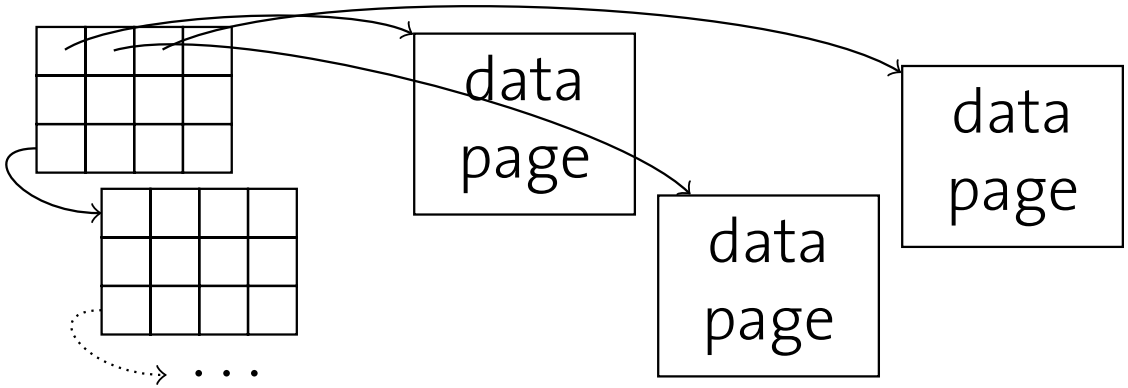

  - Verwendung als Abbildung mit Informationen über freie Plätze (Granularität ist Abwägungssache)
  + Suche nach freien Plätzen effizient
  - Zusatzaufwand für Verzeichnisspeicher

Freispeicher-Verzeichnis

Welche Seite soll für neuen Datensatz gewählt werden?

- Append Only
  - Immer in letzte Seite einfügen, sonst neue Seite anfordern
- Best-Fit
  - Alle Seiten müssen betrachtet werden, Reduzierung der Fragmentierung
- First-Fit
  - Suche vom Anfang, nehme erste Seite mit genug Platz
  - Erste Seiten füllen sich schnell, werden immer wieder betrachtet
- Next-Fit
  - Verwalte Zeiger und führe Suche fort, wo Suche beim vorigen Male endete

Inhalt einer Seite

ID	NAME	SEX
4711	John	M
~~1723~~	~~Marc~~	~~M~~
6381	Betty	F

- Datensatz-Kennung (record identifier, rid)
- Datensatz-Position (Versatz auf der Seite) Slotno x Bytes pro Slot
- Datensatz gelöscht?
  - rid sollte sich nicht ändern
  - Slot-Verzeichnis (Bitmap)

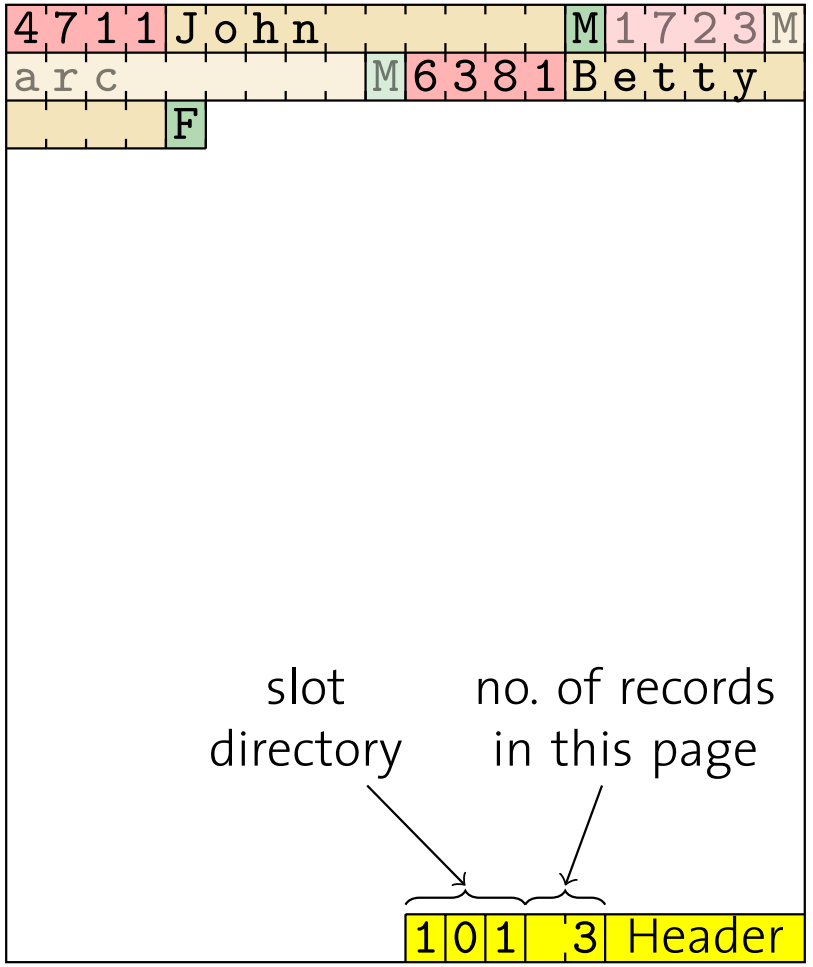

Inhalte einer Seite: Felder variabler Länge

- Felder variabler Länge zum Ende verschoben
  - Platzhalter zeigt auf Position

Warum?

- Slot-Verzeichnis zeigt auf Start eines Feldes
- Felder können auf Seite verschoben werden (z.B. wenn sich Feldgröße ändert)
- Einführung einer Vorwärtsreferenz, wenn Feld nicht auf Seite passt

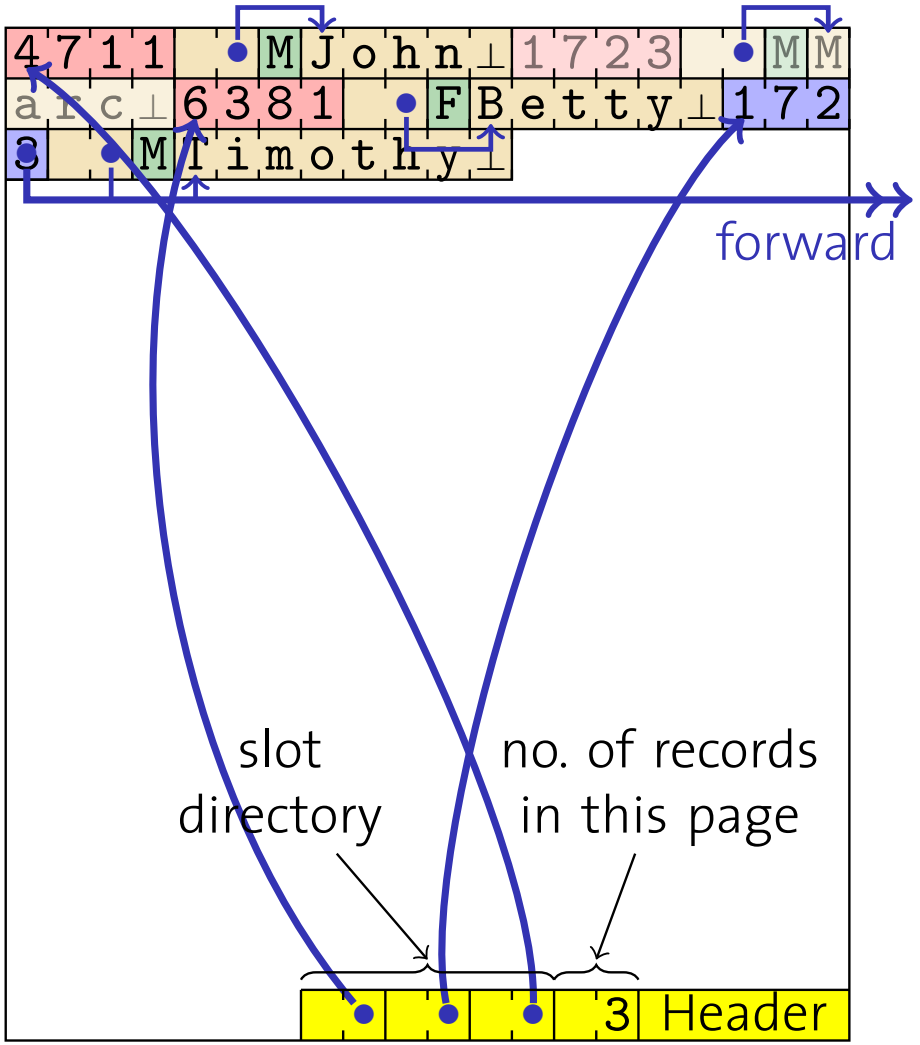

Was passiert bei Updates?

Alternative Seiteneinteilungen

- Im Beispiel wurden Datensätzen zeilenweise angeordnet:

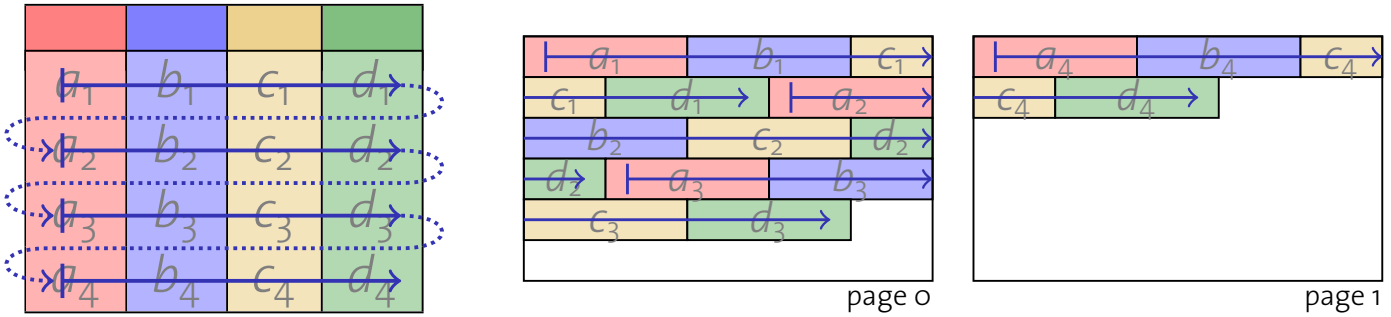

- Spaltenweise Anordnung genauso möglich:

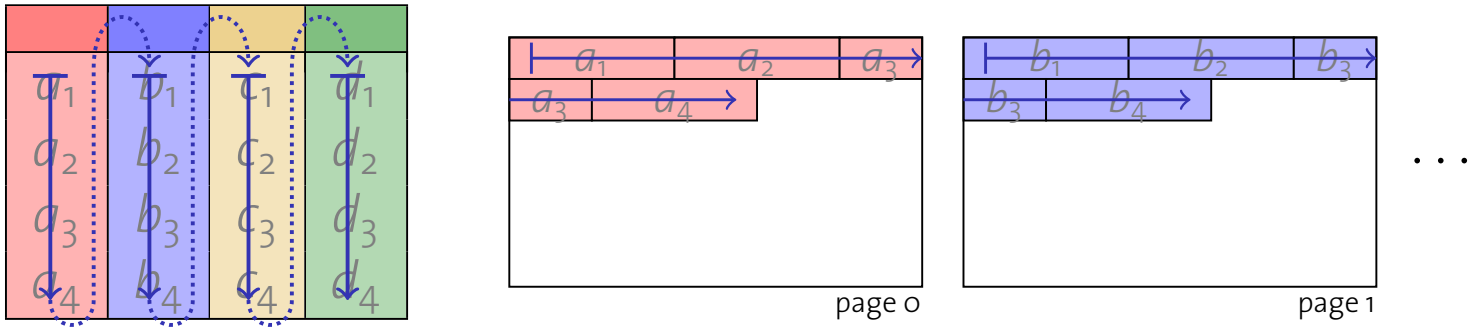

Alternative Seitenanordnungen

Vorgestellte Schemata heißen auch:

- Row-Store
- Column-Store

- Anwendungen für verschiedene Lasttypen und Anwendungs-kontexte (z.B. OLAP)
- Unterschiedliche Kompressionsmöglichkeiten
- Kombination möglich:
  - Unterteilung einer Seite in Miniseiten
  - mit entsprechender Aufteilung

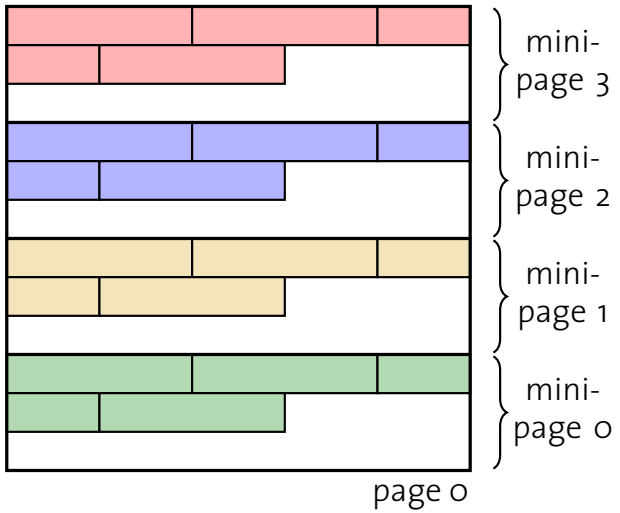

Zusammenfassung

- Kennzeichen von Speichermedien
  - Wahlfreier Zugriff langsam (I/O-Komplexität)
- Verwalter für externen Speicher
  - Abstraktion von Hardware-Details
  - Seitennummer → Physikalischer Speicherort
- Puffer-Verwalter
  - Seiten-Caching im Hauptspeicher
  - Verdrängungsstrategie
- Dateiorganisation
  - Stabile Record-Bezeichner (rids)
  - Verwaltung statischer und dynamischer Felder

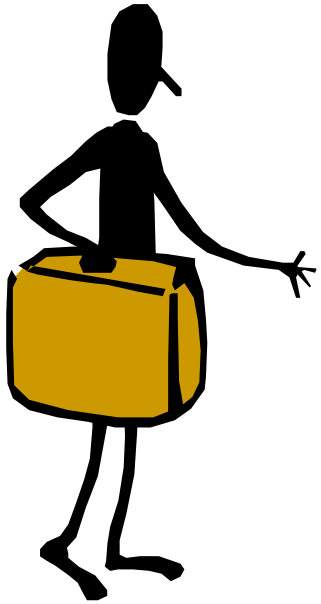

Architektur eines DBMS