Datenbanken 2

Physische Datenorganisation

Nikolaus Augsten

nikolaus.augsten@sbg.ac.at
FB Computerwissenschaften
Universität Salzburg

http://dbresearch.uni-salzburg.at

WS 2020/21

Version 16. Oktober 2020

Inhalt

Inhalt

Speichermedien/1

- Verschiedene Arten von Speichermedien sind für Datenbanksysteme relevant.
- Speichermedien lassen sich in Speicherhierarchie anordnen.
- Klassifizierung der Speichermedien nach:
  - Zugriffsgeschwindigkeit
  - Kosten pro Dateneinheit
  - Flüchtige vs. persistente Speicher
    - Flüchtig (volatile): Inhalt geht nach Ausschalten verloren
    - Persistent (non-volatile): Inhalt bleibt auch nach Ausschalten
  - Verlässlichkeit
    - Physische Fehler des Speichermediums
    - Datenverlust durch Stromausfall oder Systemabsturz

Speichermedien/2

- Cache
  - flüchtig
  - am schnellsten und am teuersten
  - von Prozessor verwaltet
  - 3 Levels: L1 (16kB - 64kB), L2, L3

- Hauptspeicher (RAM)
  - flüchtig
  - schneller Zugriff (unter 100 ns; 1 ns $= 10^{-9}$s)
  - Datentransferrate bis zu 25 GB/s
  - meist zu klein (oder zu teuer) um gesamte Datenbank zu speichern
    - mehrere GB weit verbreitet
    - Preise derzeit ca. 4'000 EUR/TB (DRAM)

Speichermedien/3

- Flash memory (SSD - Solid State Drive)
  - persistent
  - Speichermedium: NAND Flash Technologie (Firmware: auch NOR)
  - Zugriffmuster:
    - Random-access: Daten können in beliebiger Reihenfolge gelesen werden
    - Block-basiert: Granularität nicht Bytes sondern Seiten (z.B. à 4096 B)
    - Puffer-basiert: Daten müssen für Zugriff in RAM geladen werden
  - Lesezugriff langsamer als RAM (x0 bis x00 μs; 1 μs $= 10^{-6}$s)
  - schnellster persistenter Speicher
  - hohe sequentielle Datentransferrate (bis 500 MB/s)
  - größer und billiger als Hauptspeicher
  - Preise derzeit ca. 100 EUR/TB
  - weit verbreitet in Embedded Devices (z.B. Digitalkamera)
  - auch als EEPROM bekannt (Electrically Erasable Programmable Read-Only Memory)

Speichermedien/4

- Festplatte
  - persistent
  - Daten sind auf Magnetscheiben gespeichert, mechanische Drehung
  - Zugriffsmuster: wie SSD
  - sehr viel langsamer als RAM (Zugriff im ms-Bereich; 1 ms $= 10^{-3}$s)
  - sequentielles Lesen: 25–100 MB/s
  - billig: Preise teils unter 25 EUR/TB
  - sehr viel mehr Platz als im Hauptspeicher; derzeit x00 GB - 14 TB
  - Kapazitäten stark ansteigend (Faktor 2 bis 3 alle 2 Jahre)
  - Hauptmedium für Langzeitspeicher: speichert gesamte Datenbank
  - Diskette vs. Festplatte

Speichermedien/5

- Optische Datenträger
  - persistent
  - Daten werden optisch via Laser von einer drehenden Platte gelesen
  - lesen und schreiben langsamer als auf magnetischen Platten
  - sequentielles Lesen: 1 Mbit/s (CD) bis 400 Mbit/s (Blu-ray)
  - verschiedene Typen:
    - CD-ROM (640 MB), DVD (4.7 bis 17 GB), Blu-ray (25 bis 129 GB)
    - write-once, read-many (WORM) als Archivspeicher verwendet
    - mehrfach schreibbare Typen vorhanden (CD-RW, DVD-RW, DVD-RAM)
    - M-Disc (Millenial Disk)
  - Jukebox-System mit austauschbaren Platten und mehreren Laufwerken sowie einem automatischen Mechanismus zum Platten wechseln – "CD-Wechsler" mit hunderten CD, DVD, oder Blu-ray disks

Speichermedien/6

- Band
  - persistent
  - Zugriff sehr langsam, da sequentieller Zugriff
  - Datentransfer jedoch z.T. wie Festplatte (z.B. 120 MB/s, komprimiert 240MB/s)
  - sehr hohe Kapazität (mehrere TB)
  - sehr billig (ab 10 EUR/TB)
  - hauptsächlich für Backups genutzt
  - Band kann aus dem Laufwerk genommen werden
  - Band Jukebox für sehr große Datenmengen
    - x00 TB (1 terabyte = 10^{12} bytes) bis Petabyte (1 petabyte = 10^{15} bytes)

Speichermedien/7

- Speichermedien können hierarchisch nach Geschwindigkeit und Kosten geordnet werden:
- Primärspeicher: flüchtig, schnell, teuer
  - z. B. Cache, Hauptspeicher
- Sekundärspeicher: persistent, langsamer und günstiger als Primärspeicher
  - z. B. Magnetplatten, Flash Speicher
  - auch Online-Speicher genannt
- Tertiärspeicher: persistent, sehr langsam, sehr günstig
  - z. B. Magnetbänder, optischer Speicher
  - auch Offline-Speicher genannt

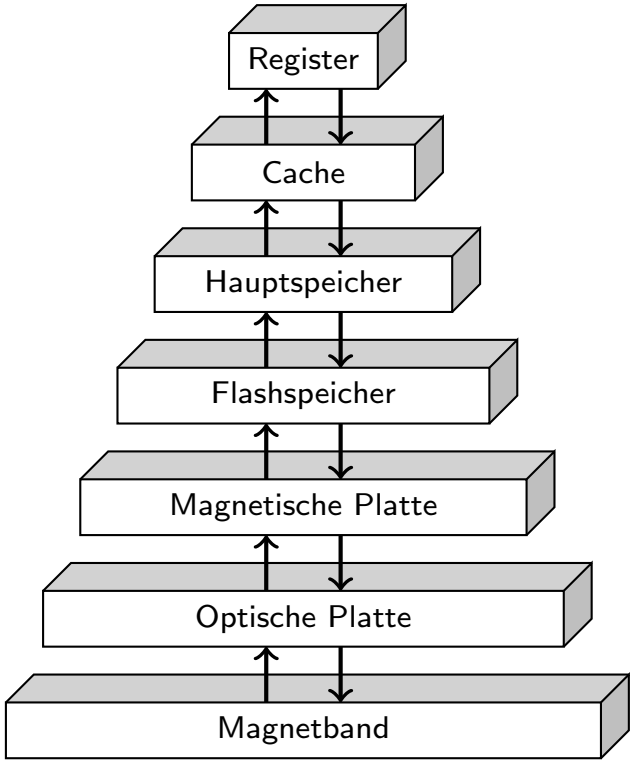

- Datenbank muss mit Speichermedien auf allen Ebenen umgehen

Aktuelle Entwicklung: Non-Volatile Memory - NVRAM

- Ziel: Lücke zwischen RAM und SSD/Festplatte füllen
  - verwendbar wie RAM (Byte-Adressierung und geringe Latenz)
  - jedoch persistent (non-volatile)
  - günstiger als RAM

  $\rightarrow$ verschiedene Technologien werden erforscht
- 3D XPoint Technologie (Intel & Micron) seit 2017 auf dem Markt
  - als Speichermodul wie RAM (Intel Optane Memory, 128/256/512 GB Module)
  - auf SSD-Laufwerken verbaut (Intel Optane SSD)
- Geschwindigkeit zwischen RAM und SSD (z.B. Latenz ca. 300 ns)
- sehr interessant für Datenbanksysteme:
  - speichern von Log
  - Hybrid-Speicher in Kombination mit SSD oder Festplatte
  - Ersatz für langsamere, persistente Speicher

Festplatten/1

- Meist sind Datenbanken auf magnetischen Platten gespeichert, weil:
  - die Datenbank zu groß für den Hauptspeicher ist
  - der Plattenspeicher persistent ist
  - Plattenspeicher billiger als Hauptspeicher ist
- Schematischer Aufbau einer Festplatte:

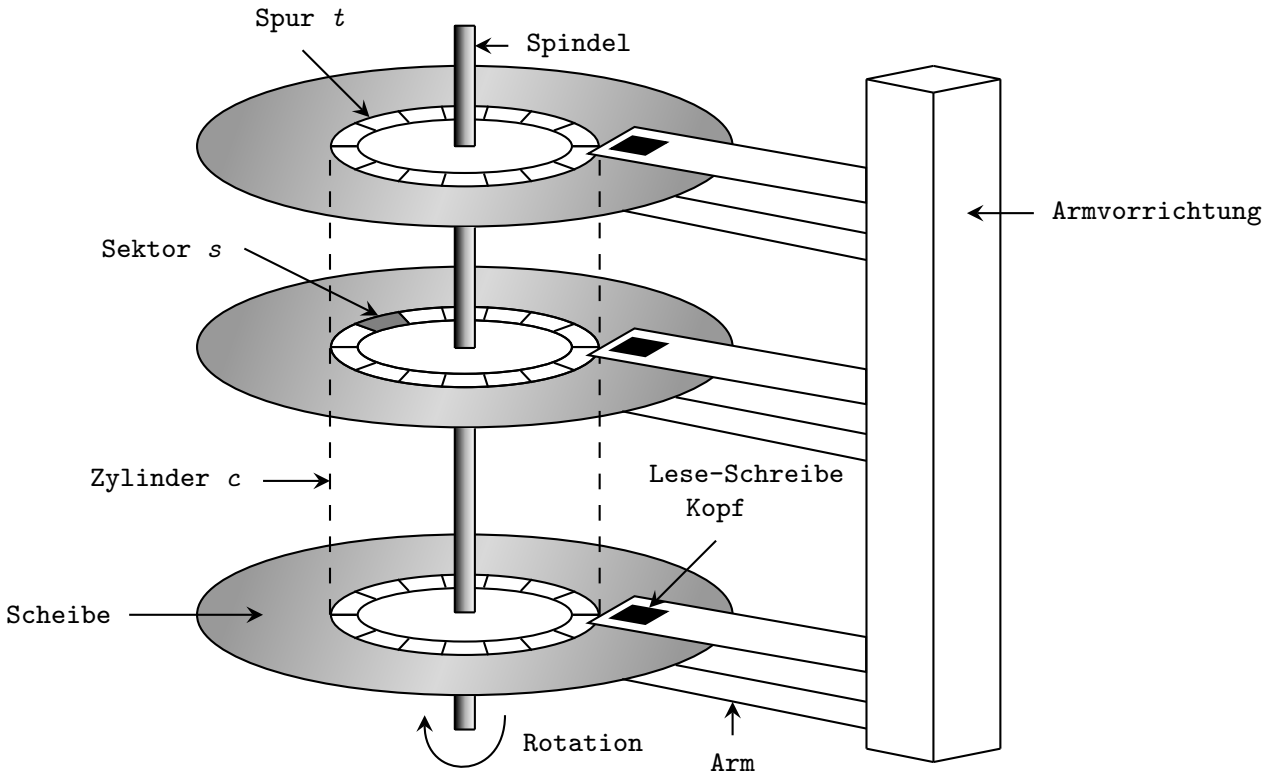

Festplatten/2

- Controller: Schnittstelle zwischen Computersystem und Festplatten:
  - übersetzt high-level Befehle (z.B. bestimmten Sektor lesen) in Hardware Aktivitäten (z.B. Disk Arm bewegen und Sektor lesen)
  - für jeden Sektor wird Checksum geschrieben
  - beim Lesen wird Checksum überprüft

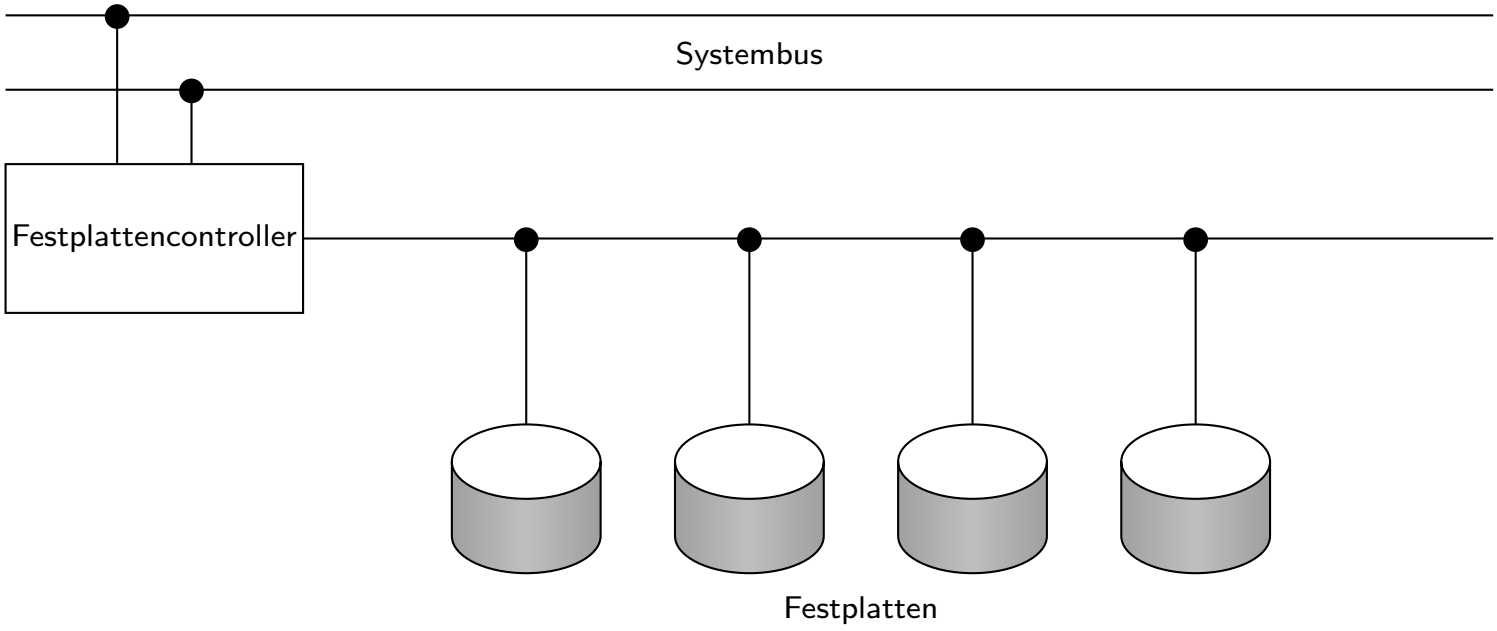

Festplatten/3

Drei Arbeitsvorgänge für Zugriff auf Festplatte:

- Spurwechsel (seek time): Schreib-/Lesekopf auf richtige Spur bewegen
- Latenz (rotational latency): Warten bis sich der erste gesuchte Sektor unter dem Kopf vorbeibewegt
- Lesezeit: Sektoren lesen/schreiben, hängt mit Datenrate (data transfer rate) zusammen

$$\text{Zugriffszeit} = \text{Spurwechsel} + \text{Latenz} + \text{Lesezeit}$$

Festplatten/4

Performance Parameter von Festplatten

- Spurwechsel: gerechnet wird mit mittlerer Seek Time (=1/2 Worst Case Seek Time)
- Latenz:
  - errechnet sich aus Drehzahl (5400rpm-15000rpm)
  - rpm = revolutions per minute
  - maximale Latenz [s] = 60 / Drehzahl [rpm]
  - mittlere Latenz: 1/2 maximale Latenz (2ms-5.5ms)
- Datenrate: Rate mit der Daten gelesen/geschrieben werden können (z.B. 25-100 MB/s)
- Mean time to failure (MTTF): mittlere Laufzeit bis zum ersten Mal ein Hardware-Fehler auftritt
  - typisch: mehrere Jahre
  - keine Garantie, nur statistische Wahrscheinlichkeit

Festplatten/5

- Block: (auch "Seite") zusammenhängende Reihe von Sektoren auf einer bestimmten Spur
- Interblock Gaps: ungenützter Speicherplatz zwischen Sektoren
- ein Block ist eine logische Einheit für den Zugriff auf Daten.
  - Daten zwischen Platte und Hauptspeicher werden in Blocks übertragen
  - Datenbank-Dateien sind in Blocks unterteilt
  - Block Größen: 4-16 kB
    - kleine Blocks: mehr Zugriffe erforderlich
    - große Blocks: Ineffizienz durch nur teilweise gefüllte Blocks

Integrierte Übung 1.1

Betrachte folgende Festplatte: Sektor-Größe $B = 512$ Bytes, Sektoren/Spur $S = 20$, Spuren pro Scheibenseite $T = 400$, Anzahl der beidseitig beschriebenen Scheiben $D = 15$, mittlerer Spurwechsel $sp = 30ms$, Drehzahl $dz = 2400rpm$ (Interblock Gaps werden vernachlässigt).

Bestimme die folgenden Werte:

a) Kapazität der Festplatte
b) mittlere Zugriffszeit (1 Sektor lesen)

SSD - Solid State Drive - Aufbau

- Daten werden auf Seiten gespeichert (typisch: 4kB/Seite).
- Lesen einer Seite ist sehr schnell, Richtwert 100 μs
- Seiten werden in sogenannte Erase-Blocks zusammengefasst, die aus 128-256 Seiten bestehen.
- Bevor eine Seite beschrieben werden kann, muss sie gelöscht werden (kein in-place Update).
- Löschen einzelner Seiten ist jedoch nicht möglich, sondern der gesamte Erase-Block muss gelöscht werden.
- Löschen ist teuer: 2000-5000μs

SSD - Schreibvorgang

- Schreibvorgang: logische Seite X schreiben
  - logische Seite X ist intern auf eine physische Seite Y abgebildet
  - schreiben auf Seite X: statt alte physische Seite Y zu löschen wird Schreibbefehl auf freie physische Seite Z umgelenkt
  - die Abbildung zwischen logischen und physischen Seiten wird aktualisiert: X wird nun auf Z abgebildet
  - physische Seite Y wird als "löschbar" markiert
- Garbage Collection:
  - Erase-Block mit vielen "löschbaren" Seiten wird als Ganzes gelöscht
  - erfordert gegebenenfalls noch nicht gelöschte Seiten vorher zu kopieren
- Wear Leveling
  - nur begrenzte Anzahl von Lösch-Operationen möglich: 100k-1M
  - deshalb wird versucht, Erase-Blocks gleichmäßig zu verwenden

SSD - Performance in der Praxis/1

- Theoretisch sollten SSDs:
  - für random und sequentiellen Zugriff gleich schnell sein
  - lesen sollte schneller sein als schreiben
- In der Praxis sind SSDs hoch komplex aufgebaut:

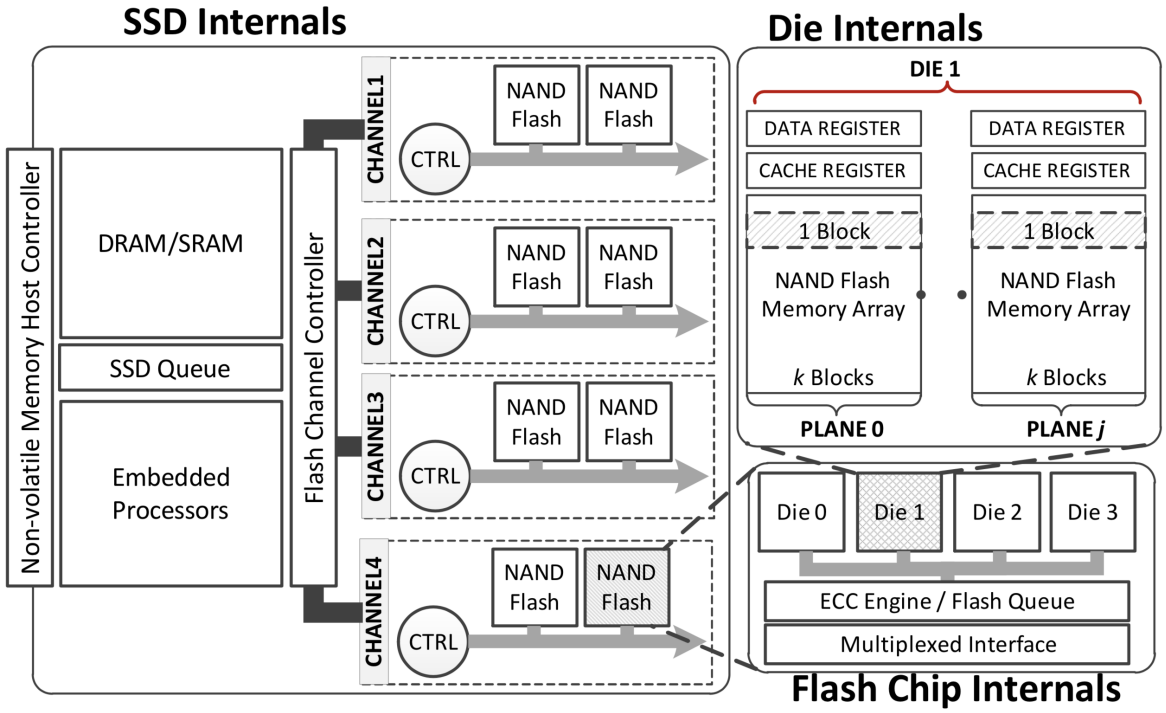

Jung, Kandemir. Revisiting widely held SSD expectations and rethinking system-level implications. SIGMETRICS'13

SSD - Performance in der Praxis/2

- Performance hängt von verschiedenen SSD-internen Effekten ab:
  - Garbage Collection, Wear Leveling
  - Interne Parallelität auf mehreren Ebenen: channels, flash chips, dies
  - Flash-Speicher wird fehleranfälliger, wenn er öfters gelesen oder geschreiben wird
  - Leseoperationen führen zu Schreiboperationen, wenn der gelesene Bereich nur mehr schwer lesbar ist

- Black-Box Verhalten:
  - Sequentielles Lesen bis 2x schneller als nicht-sequentielles (random)
  - Zugriffszeit verdoppelt sich in einem gealterten SSD Laufwerk
  - Schreibgeschwindigkeit ist zwischen random und sequentiellem Lesen
  - random Schreiben verlangsamt das spätere Lesen
  - Write Cliff: im schlimmsten Fall kann Schreiben (random) sehr langsam werden (langsamer als Festplatte)

SSD - Fazit

- SSDs sind im Schnitt deutlich schneller als Festplatten
- SSDs sind auch deutlich teuerer
- random access (Lesen oder Schreiben) soll sowohl bei SSDs als auch bei Festplatten vermieden werden

Zusammenfassung

- flüchtige und persistente Speicher
- Speicherpyramide
  - Primärspeicher: Cache, RAM
  - Sekundärspeicher: SSDs, Festplatten
  - Tertiärspeicher: Bänder, optische Platten
- SSDs können Festplatten in manchen Bereichen ersetzen
- Persistenter RAM verspricht interessante Entwicklungen

Inhalt

Speicherhierarchie

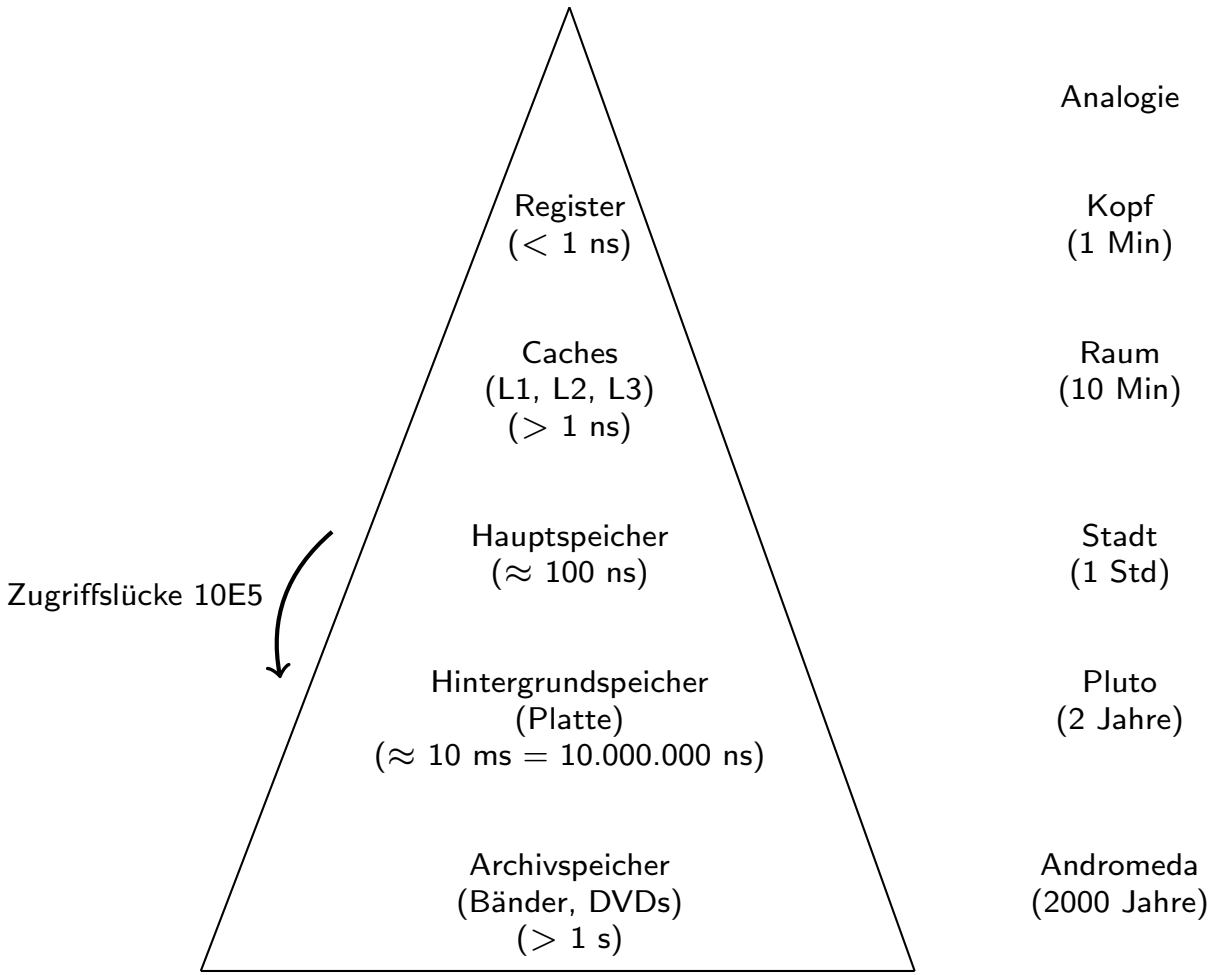

Platten Zugriff Optimieren

- Wichtiges Ziel von DBMSs: Transfer von Daten zwischen Platten und Hauptspeicher möglichst effizient gestalten.
  - optimieren/minimieren der Anzahl der Zugriffe
  - minimieren der Anzahl der gelesenen/geschriebenen Blöcke
  - so viel Blöcke als möglich im Hauptspeicher halten ($\rightarrow$ Puffer Manager)
- Techniken zur Optimierung des Block Speicher Zugriffs:
  1. Disk Arm Scheduling
  2. Geeignete Dateistrukturen
  3. Schreib-Puffer und Log Disk

Block Speicher Zugriff/1

- Disk Arm Scheduling: Zugriffe so ordnen, dass Bewegung des Arms minimiert wird.
- Elevator Algorithm (Aufzug-Algorithmus):
  - Disk Controller ordnet die Anfragen nach Spur (von innen nach außen oder umgekehrt)
  - Bewege Arm in eine Richtung und erledige alle Zugriffe unterwegs bis keine Zugriffe mehr in diese Richtung vorhanden sind
  - Richtung umkehren und die letzten beiden Schritte wiederholen

Block Speicher Zugriff/2

- Datei Organization: Daten so in Blöcken speichern, wie sie später zugegriffen werden.
  - z.B. verwandte Informationen auf benachbarten Blöcken speichern
- Fragmentierung: Blöcke einer Datei sind nicht hintereinander auf der Platte abgespeichert
  - Gründe für Fragmentierung sind z.B.
    - Daten werden eingefügt oder gelöscht
    - die freien Blöcke auf der Platte sind verstreut, d.h., auch neue Dateien sind schon zerstückelt
  - sequentieller Zugriff auf fragmentierte Dateien erfordert erhöhte Bewegung des Zugriffsarms
  - manche Systeme erlauben das Defragmentieren des Dateisystems

Block Speicher Zugriff/3

Schreibzugriffe können asynchron erfolgen um Throughput (Zugriffe/Sekunde) zu erhöhen

- Persistente Puffer: Block wird zunächst auf persistenten RAM (RAM mit Batterie-Backup oder Flash Speicher) geschrieben; der Controller schreibt auf die Platte, wenn diese gerade nicht beschäftigt ist oder der Block zu lange im Puffer war.
  - auch bei Stromausfall sind Daten sicher
  - Schreibzugriffe können geordnet werden um Bewegung des Zugriffsarms zu minimieren
  - Datenbank Operationen, die auf sicheres Schreiben warten müssen, können fortgesetzt werden
- Log Disk: Eine Platte, auf die der Log aller Schreibzugriffe sequentiell geschrieben wird
  - wird gleich verwendet wie persistenter RAM
  - Log schreiben ist sehr schnell, da kaum Spurwechsel erforderlich
  - erfordert keine spezielle Hardware

Puffer Manager/1

- Puffer: Hauptspeicher-Bereich für Kopien von Platten-Blöcken
- Puffer Manager: Subsystem zur Verwaltung des Puffers
  - Anzahl der Platten-Zugriffe soll minimiert werden
  - ähnlich der virtuellen Speicherverwaltung in Betriebssystemen

Puffer Manager/2

- Programm fragt Puffer Manager an, wenn es einen Block von der Platte braucht.
- Puffer Manager Algorithmus:
  1. Programm fordert Plattenblock an.
  2. Falls Block nicht im Puffer ist:
     - Der Puffer Manager reserviert Speicher im Puffer (wobei nötigenfalls andere Blöcke aus dem Puffer geworfen werden).
     - Ein rausgeworfener Block wird nur auf die Platte geschrieben, falls er seit dem letzten Schreiben auf die Platte geändert wurde.
     - Der Puffer Manager liest den Block von der Platte in den Puffer.
  3. Der Puffer Manager gibt dem anfordernden Programm die Hauptspeicheradresse des Blocks im Puffer zurück.
- Es gibt verschiedene Strategien zum Ersetzen von Blöcken im Puffer.

Ersetzstrategien für Pufferseiten/1

- LRU Strategie (least recently used): Ersetze Block der am längsten nicht benutzt wurde.
  - Idee: Zugriffsmuster der Vergangenheit benutzten um zukünfiges Verhalten vorherzusagen
  - erfolgreich in Betriebssystemen eingesetzt
- MRU Strategie: (most recently used): Ersetze zuletzt benutzten Block als erstes.
  - LRU kann schlecht für bestimmte Zugriffsmuster in Datenbanken sein, z.B. wiederholtes Scannen von Daten
- Pinned block: Darf nicht aus dem Puffer entfernt werden.
- Toss Immediate Strategy: Block wird sofort rausgeworfen, wenn das letzte Tupel bearbeitet wurde.

Ersetzstrategien für Pufferseiten/2

- Anfragen in DBMSs haben wohldefinierte Zugriffsmuster (z.B. sequentielles Lesen) und das DBMS kann die Information aus den Benutzeranfragen verwenden, um zukünftig benötigte Blöcke vorherzusagen.
- Beispiel: Berechne $R \bowtie S$ mit Nested Loops:

```
für jedes Tupel tr von R:
  für jedes Tupel ts von S:
    wenn ts und tr das Join-Prädikat erfüllen, dann ...
```

- Verschiedene Zugriffsmuster für R und S
  - ein R-Block wird nicht mehr benötigt, sobald das letzte Tupel des Blocks bearbeitet wurde; er sollte also sofort entfernt werden, auch wenn er gerade erst benutzt worden ist
  - ein S-Block wird nochmal benötigt, wenn alle anderen S-Blöcke abgearbeitet sind

Ersetzstrategien für Pufferseiten/3

Informationen für Ersatzstrategien in DBMSs:

- Zugriffspfade haben wohldefinierte Zugriffsmuster (z.B. sequentielles Lesen)
- Information im Anfrageplan um zukünftige Blockanfragen vorherzusagen
- Statistik über die Wahrscheinlichkeit, dass eine Anfrage für eine bestimmte Relation kommt
  - z.B. das Datenbankverzeichnis (speichert Schema) wird oft zugegriffen
  - Heuristik: Verzeichnis im Hauptspeicher halten

Inhalt

Datei Organisation

- Datei: (file) aus logischer Sicht eine Reihe von Datensätzen
  - ein *Datensatz* (record) ist eine Reihe von Datenfeldern
  - mehrere Datensätze in einem Platten-Block
  - *Kopfteil* (header): Informationen über Datei (z.B. interne Organisation)
- Abbildung von Datenbank in Dateien:
  - eine Relation wird in eine Datei gespeichert
  - ein Tupel entspricht einem Datensatz in der Datei
- Cooked vs. raw files:
  - cooked: DBMS verwendet Dateisystem des Betriebssystems (einfacher, code reuse)
  - raw: DBMS verwaltet Plattenbereich selbst (unabhängig von Betriebssystem, bessere Performance, z.B. Oracle)
- Fixe vs. variable Größe von Datensätzen:
  - fix: einfach, unflexibel, Speicher-ineffizient
  - variabel: komplizierter, flexibel, Speicher-effizient

Fixe Datensatzlänge/1

- Speicheradresse: i-ter Datensatz wird ab Byte $m * (i - 1)$ gespeichert, wobei m die Größe des Datensatzes ist
- mehrere Möglichkeiten zum Löschen des i-ten Datensatzes:
  - (a) verschiebe Datensätze $i + 1, ..., n$ nach $i, ..., n - 1$
  - (b) verschiebe letzten Datensatz nach i
  - (c) nicht verschieben, sondern "Free List" verwalten

record 0	A-102	Perryridge	400
record 1	A-305	Round Hill	350
record 2	A-215	Mianus	700
record 3	A-101	Downtown	500
record 4	A-222	Redwood	700
record 5	A-201	Perryridge	900
record 6	A-217	Brighton	750
record 7	A-110	Downtown	600
record 8	A-218	Perryridge	700

Fixe Datensatzlänge/2

- Free List:
  - speichere Adresse des ersten freien Datensatzes im Kopfteil der Datei
  - freier Datensatz speichert Pointer zum nächsten freien Datensatz

  → der Speicherbereich des gelöschten Datensatzes wird für Free List Pointer verwendet
- Beispiel: Free List nach löschen der Datensätze 4, 6, 1 (in dieser Reihenfolge)

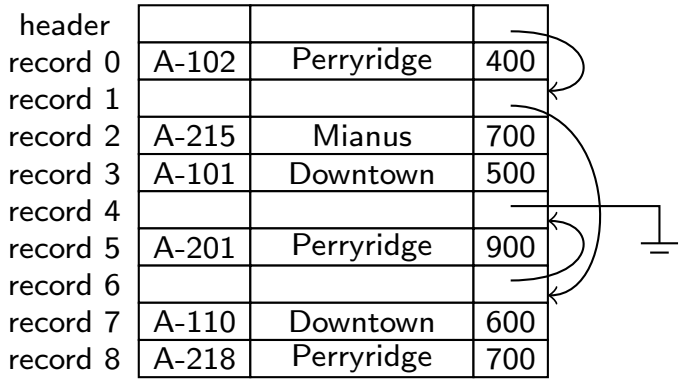

Variable Datensatzlänge/1

- Warum Datensätze mit variabler Größe?
  - Datenfelder variabler Länge (z.B., VARCHAR)
  - verschiedene Typen von Datensätzen in einer Datei
  - Platz sparen: z.B. in Tabellen mit vielen null-Werten (häufig in der Praxis)
- Datensätze verschieben kann erforderlich werden:
  - Datensätze können größer werden und im vorgesehenen Speicherbereich nicht mehr Platz haben
  - neue Datensätze werden zwischen existierenden Datensätzen eingefügt
  - Datensätze werden gelöscht (leere Zwischenräume verhindern)
- Pointer soll sich nicht ändern:
  - alle existierenden Referenzen zum Datensatz müssten geändert werden
  - das wäre kompliziert und teuer
- Lösung: Slotted Pages (TID-Konzept)

Slotted Pages/1

- Slotted Page:
  - Kopfteil (header)
  - freier Speicher (free space)
  - Datensätze (records) $d_1, d_2, \ldots, d_n$
- Kopfteil speichert:
  - Anzahl der Datensätze a
  - Ende des freien Speichers f
  - Größe g_i und Pointer p_i auf Startposition jedes Datensatzes d_i

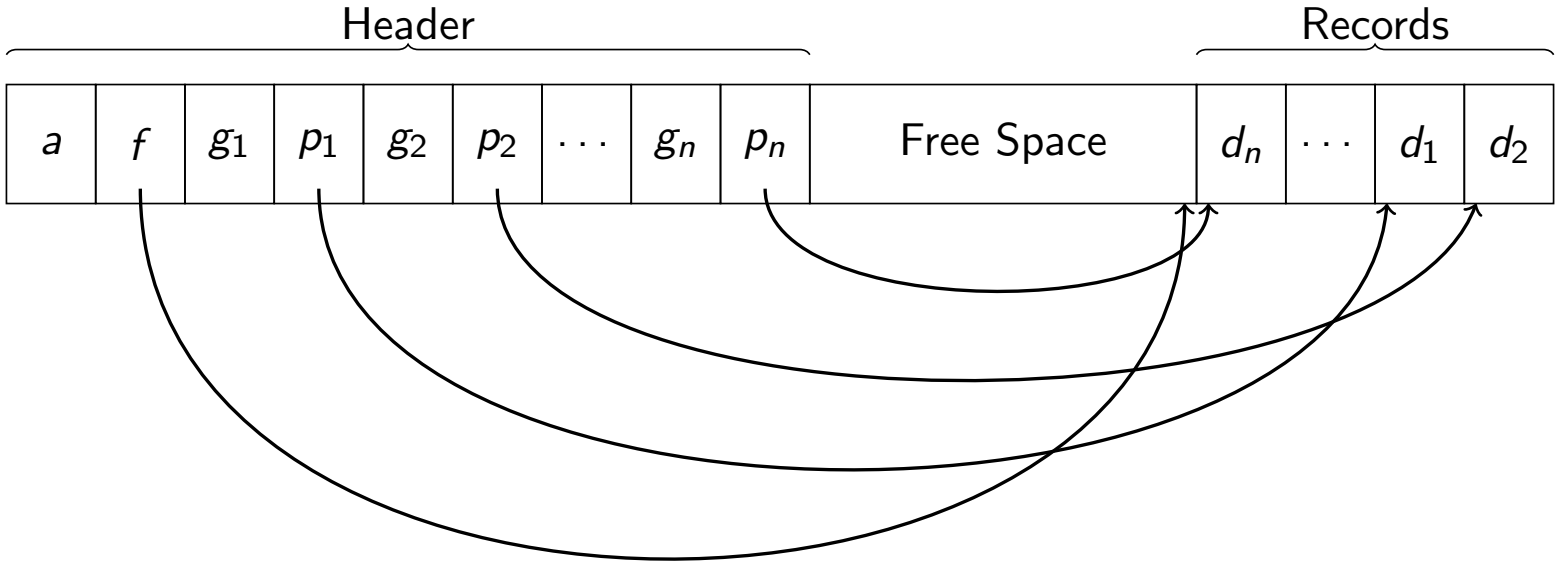

Slotted Pages/2

- TID: Tuple Identifier besteht aus
  - Nummer des Blocks (page ID)
  - Offset des Pointers zum Datensatz
- Datensätze werden nicht direkt adressiert, sondern über TID

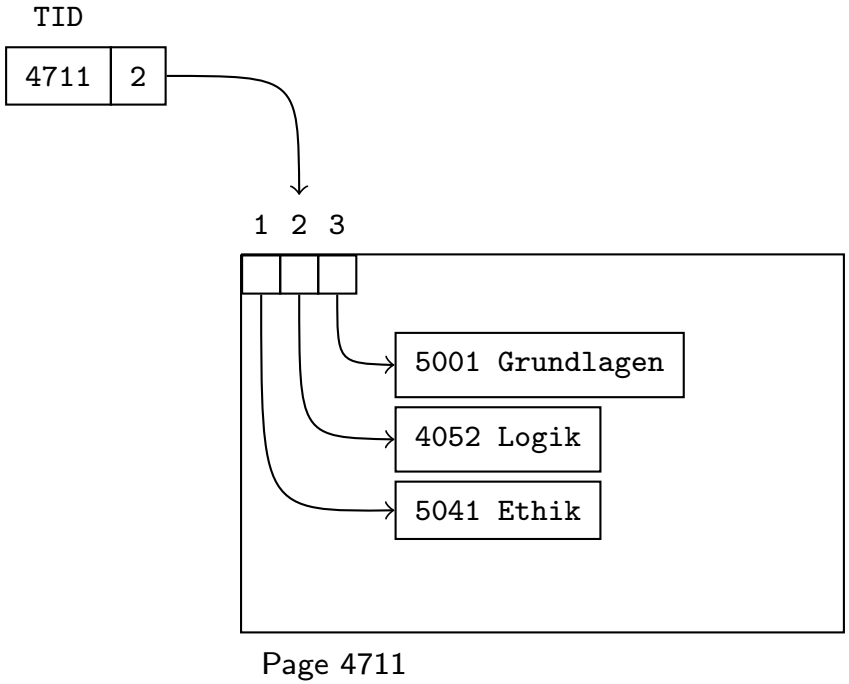

Slotted Pages/3

- Verschieben innerhalb des Blocks:
  - Pointer im Kopfteil wird geändert
  - TID ändert sich nicht

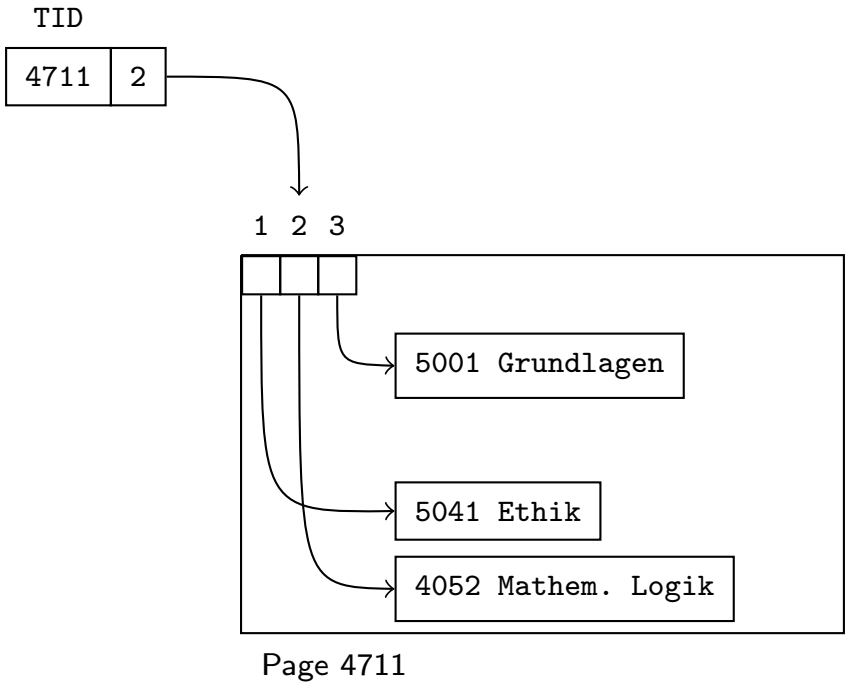

Slotted Pages/4

- Verschieben zwischen Blöcken:
  - Datensatz wird ersetzt durch Referenz auf neuen Block, welche nur intern genutzt wird
  - Zugriff auf Datensatz erfordert das Lesen von zwei Blöcken
  - TID des Datensatzes ändert sich nicht
  - weitere Verschiebungen modifizieren stets die Referenz im ursprünglichen Block (d.h. es entsteht keine verkettete Liste)